

CONTRIBUIÇÕES AO ESTUDO
SOBRE SENSORIAMENTO
ESPECTRAL BASEADO EM
AUTOVALOR PARA APLICAÇÕES
EM SISTEMAS DE RÁDIO
COGNITIVO

JOÃO SCUDELER NETO

OUTUBRO/ 2011

“Contribuições ao Estudo sobre Sensoriamento Espectral Baseado em Autovalor para Aplicações em Sistemas de Rádio Cognitivo”

JOÃO SCUDELER NETO

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

ORIENTADOR: Prof. Dr. Dayan Adionel Guimarães

Santa Rita do Sapucaí
2011

FOLHA DE APROVAÇÃO

Dissertação defendida e aprovada em ____ / ____ / ____, pela comissão julgadora:

Prof. Dr. Dayan Adionel Guimarães
INATEL

Prof. Dr. Daniel Benevides da Costa
UFC

Prof. Dr. Rausley Adriano Amaral de Souza
INATEL

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

DEDICATÓRIA

Aos meus pais, João e Fátima, pelos ensinamentos e sacrifícios empenhados a mim e aos meus queridos irmãos Pedro e Luís Antônio os quais também homenageio.

A minha amada companheira Ana Carolina, aos seus pais, Walter e Adriane, e suas irmãs, Ana Elisa e Maria Thereza, pela compreensão, carinho e paciência.

Em especial, a memória de meu saudoso avô João Scudeler, pelo belíssimo exemplo de vida.

AGRADECIMENTOS

Não tenho outro modo para demonstrar meu sentimento, a não ser registrando aqui a imensa gratidão a todos que, direta ou indiretamente, contribuíram para a execução e conclusão deste trabalho.

Ao Professor Dr. Dayan Adionel Guimarães, agradeço pela valiosa orientação prestada, e também pelo apoio, amizade, compreensão e confiança durante todo nosso convívio.

Aos Professores Dr. Antônio Marcos Alberti, Dr. Carlos Ynoguti, Dr. Geraldo Gil, Dr. Luciano Leonel e Dr. Rausley A. A. de Souza, por me proporcionarem uma rica formação acadêmica.

Ao Professor Dr. José Marcos Câmara Brito, por ter acreditado em minha capacidade, oferecendo a oportunidade de ministrar minhas primeiras aulas no Inatel, exercitando-me antecipadamente rumo ao meu objetivo de atuar na honrosa atividade de docência.

Aos Professores Dr. Carlos Nazareth e MSc. André Abbade, por me apoiarem desde o início desta jornada.

A toda comunidade INATEL, em especial aos funcionários e estimados amigos, Gisele Moreira dos Santos e Antonio Alves, pela presteza e atenção.

Aos amigos André dos Anjos, Bruno Borsato, Ricardo Augusto, Marco Aurélio e Lucas Chaves, por tornarem as disciplinas que juntos cursamos ainda mais interessantes devido aos excelentes momentos de troca de informações.

A CAPES, pelo apoio financeiro.

E acima de tudo, a Deus, que me sustentou em suas mãos nos momentos mais difíceis.

ÍNDICE

Lista de Figuras	vii
Lista de Tabelas	viii
Lista de Abreviaturas e Siglas	ix
Lista de Símbolos	x
Resumo	xii
Abstract	xiii
1 INTRODUÇÃO	1
1.1 Contextualização	1
1.2 Rádio Cognitivo	3
1.3 Estrutura e contribuições da dissertação	5
1.4 Publicações	6
2 SENSORIAMENTO ESPECTRAL	7
2.1 Identificação de oportunidades de transmissão	7
2.2 Desafios para a implementação do sensoriamento espectral	8
2.2.1 Requisitos de hardware	8
2.2.2 Duração e frequência do sensoriamento	8
2.2.3 O usuário primário oculto	10
2.3 Técnicas de sensoriamento espectral	10
2.3.1 Sensoriamento por filtro casado	11
2.3.2 Sensoriamento baseado em cicloestacionariedade	11
2.3.3 Sensoriamento por detecção de energia	13
2.3.4 Tabela comparativa e o surgimento da detecção por autovalores	14
2.3.5 Sensoriamento Cooperativo e Não Cooperativo	15
3 SENSORIAMENTO BASEADO EM AUTOVALORES	17
3.1 Introdução	17
3.2 Modelo utilizado	17
3.3 Algoritmos de detecção	21
3.4 Limiar de decisão	22
3.4.1 Expressão de γ versus P_{FA} - análise assintótica	26
3.4.2 Expressão de γ versus P_{FA} - análise não assintótica	27
3.4.3 Análise de γ versus P_{FA} via Monte Carlo	28
3.4.4 A curva ROC	29

4	INVESTIGAÇÕES ENVOLVENDO A TÉCNICA MED	32
4.1	Introdução.....	32
4.2	Estimativas para a matriz de covariância por média amostral.....	32
4.2.1	Método 1 de estimação da matriz de covariância por média amostral.....	32
4.2.2	Método 2 de estimação da matriz de covariância por média amostral.....	33
4.2.3	Método 3 de estimação da matriz de covariância por média amostral.....	33
4.2.4	Método 4 de estimação da matriz de covariância por média amostral.....	35
4.3	Influência do método de estimação da matriz de covariância por média amostral.....	36
4.3.1	Sensoriamento espectral por máximo autovalor não cooperativo....	36
4.3.2	Sensoriamento espectral por máximo autovalor cooperativo	39
4.4	Influência do número de amostras coletadas no desempenho da técnica MED	42
4.5	Análise da distribuição do máximo autovalor sob a hipótese H_1	43
4.5.1	O teste de Kolmogorov-Smirnov	44
4.5.2	Procedimentos para se obter a distribuição de λ_{\max} sob H_1	45
4.5.3	Execução do procedimento para se obter a distribuição de λ_{\max} sob H_1	47
4.5.4	Cálculo de P_D versus γ baseado na distribuição Log-Pearson 3	49
5	CONCLUSÕES	52
	REFERÊNCIAS BIBLIOGRÁFICAS	55
	APÊNDICES	58
1	Cálculo da expressão (3.35).....	58
2	Cálculo de P_{FA} versus γ via Monte Carlo.....	59
3	Cálculo de P_D a partir do limiar γ	60
4	Cálculo de P_{FA} versus γ via Monte Carlo para o detector de energia.....	61
5	Cálculo de P_D a partir do limiar γ para o detector de energia	62
6	Cálculo de P_{FA} versus γ para MED não cooperativa considerando SMOOTHING FACTOR	63
7	Cálculo de P_D versus SNR para MED não cooperativa considerando SMOOTHING FACTOR	64
8	Cálculo de P_{FA} versus γ para MED não cooperativa sem considerar SMOOTHING FACTOR	66
9	Cálculo de P_D versus SNR para MED não cooperativa sem considerar SMOOTHING FACTOR	67

10	Cálculo de P_{FA} versus γ para MED cooperativa sem considerar SMOOTHING FACTOR	69
11	Cálculo de P_D versus SNR para MED cooperativa sem considerar SMOOTHING FACTOR	70
12	Cálculo de P_{FA} versus γ para MED cooperativa considerando SMOOTHING FACTOR	72
13	Cálculo de P_D versus SNR para MED cooperativa considerando SMOOTHING FACTOR	73
14	Rotina para geração de uma amostras tamanho N da variável aleatória λ_{\max}	75

LISTA DE FIGURAS

1.1	Medidas de ocupação espectral feita na cidade de Chicago –USA	2
1.2	Princípio de operação do Rádio Cognitivo	4
2.1	Interferência causada pelo Rádio Cognitivo	10
2.2	Função de autocorrelação cíclica para um sinal AM-DSB (a) e para um sinal PAM (b)	12
2.3	Diagramas em bloco do detector de energia: (a) implementação com um pré-filtro analógico, (b) implementação utilizando FFT	14
2.4	Cenário constituído por p transmissores primários e m Rádios Cognitivos	16
3.1	Ilustração da relação entre P_{FA} e P_D	25
3.2	Valores de γ e P_{FA} teóricos e obtidos por simulação	28
3.3	ROC para a técnica MED e ED com $m=6$, $n=50$ e $SNR=-10dB$	30
4.1	Matriz de covariância por média amostral de ordem 20	34
4.2	Curvas de P_D para a técnica MED não cooperativa com fator de alisamento e sinal transmitido com amostras correlacionadas em comparação com a curva do detector de energia (ED)	38
4.3	Curvas de P_D para a técnica MED não cooperativa com fator de alisamento e sinal transmitido com amostras i.i.d. em comparação com a curva do detector de energia (ED)	38
4.4	Curvas de P_D para a técnica MED não cooperativa sem fator de alisamento em comparação com a curva do detector de energia (ED) para sinal transmitido com amostras i.i.d. ou correlacionadas	39
4.5	Curva de P_D versus SNR para o sensoriamento espectral cooperativo sem fator de alisamento	41
4.6	Curva de P_D versus SNR para o sensoriamento espectral cooperativo com fator de alisamento	42
4.7	Curva de P_D versus n para um sensoriamento espectral por máximo autovalor cooperativo	43
4.8	Ilustração de curvas de distribuição de probabilidade cumulativa empírica (curvas em escada) e teórica (curvas contínuas) para um bom e mau ajuste	45
4.9	Fluxograma do processo para se obter a distribuição de λ_{max} sob a hipótese H_1 para um valor específico de m , n e SNR	46
4.10	Print Screen de uma janela de resultados do programa EASYFIT	47
4.11	Histograma da amostra de λ_{max} para os valores de $m=3$, $n=5$ e $SNR=0dB$ sobreposta a função densidade de probabilidade da distribuição de Log-Pearson 3 correspondente	50
4.12	Valores de γ e P_D teóricos e obtidos por simulação	51

LISTA DE TABELAS

2.1	Comparativo entre os três métodos de identificação de oportunidades de transmissão.....	8
2.2	Comparação entre técnicas de sensoriamento espectral.....	15
4.1	Valores críticos para a estatística de teste D quando $N > 40$	45
4.2	Valores de m , n e SNR utilizados para se determinar a distribuição empírica de λ_{\max}	47
4.3	Listas ordenadas das distribuições teóricas que mais se assemelham com a distribuição empírica de λ_{\max} para os casos de m , n e SNR investigados.....	48
4.4	Alguns valores de m , n e SNR com a respectiva relação com os parâmetros α , β e g da distribuição Log-Pearson 3.....	50

LISTA DE ABREVIATURAS E SIGLAS

3G	Sistema de telefonia móvel de terceira geração
AM-DSB	<i>Amplitude Modulated - Double Side Band</i>
ANATEL	Agência Nacional de Telecomunicações
AWGN	<i>Additive White Gaussian Noise</i>
BCED	<i>Blindly Combined Energy Detection</i>
CDF	<i>Cumulative Distribution Function</i>
CFAR	<i>Constant False Alarm Rate</i>
ED	<i>Energy Detection</i>
FCC	<i>Federal Communication Commission</i>
FFT	<i>Fast Fourier Transform</i>
GPS	<i>Global Positioning System</i>
i.i.d.	Independentes e identicamente distribuídas
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
ITU	<i>International Telecommunication Union</i>
MED	<i>Maximum Eigenvalue Detection</i>
MME	<i>Maximum-Minimum Eigenvalue Detection</i>
PAM	<i>Pulse Amplitude Modulated</i>
PDF	<i>Probability Density Function</i>
RF	Radiofrequência
RLRT	<i>Roy Largest Root Test</i>
ROC	<i>Receiver Operating Characteristic</i>
SNR	<i>Signal-to-noise Ratio</i>
UHF	<i>Ultra High Frequency</i>
VHF	<i>Very High Frequency</i>
WRAN	<i>Wireless Regional Area Network</i>
WRC	<i>World Radio Conference</i>

LISTA DE SÍMBOLOS

$(\cdot)^\dagger$	Conjugado transposto de (\cdot)
${}_1F_1(\cdot; \cdot; \cdot)$	Função hipergeométrica de primeiro tipo com argumento matricial
a	Parâmetro de forma da distribuição Log-Pearson 3
b	Parâmetro de escala da distribuição Log-Pearson 3
B	Banda de frequências
c	Parâmetro de posição da distribuição Log-Pearson 3
$C\Gamma_m(\cdot)$	Função gamma complexa
$\det[\cdot]$	Determinante de $[\cdot]$
D	Estatística do teste de Kolmogorov-Smirnov
$E[\cdot]$	Valor esperado de $[\cdot]$
$f_{0MED}(t)$	Distribuição de probabilidade de T_{MED} sob H_0
$f_{1MED}(t)$	Distribuição de probabilidade de T_{MED} sob H_1
$f_{0MME}(t)$	Distribuição de probabilidade de T_{MME} sob H_0
$f_{1MME}(t)$	Distribuição de probabilidade de T_{MME} sob H_1
F	Fator de correlação
$F(x)$	Distribuição de probabilidade cumulativa teórica da variável aleatória X
$f(x)$	Função densidade de probabilidade da variável aleatória X
$F_N(x)$	Distribuição de probabilidade cumulativa empírica da variável aleatória X
\mathbf{H}	Matriz do canal de comunicação
H_0	Hipótese que considerada que o sinal primário não está presente na banda de frequências sensoriada
H_1	Hipótese que considerada que o sinal primário está presente na banda de frequências sensoriada
H_a	Hipótese que considera que a distribuição selecionada representa os dados de forma adequada
H_b	Hipótese que considera que a distribuição selecionada não representa os dados de forma adequada
h_{ij}	Ganho de canal entre o transmissor primário j e o Rádio Cognitivo i
\mathbf{I}	Matriz identidade de mesma ordem que \mathbf{R}_Y
\mathbf{I}_m	Matriz identidade de ordem m
L	Fator de alisamento
m	Número de Rádios Cognitivos
N	Número de observações de uma variável aleatória qualquer
n	Número de amostras
p	Número de transmissores primários
P_{BE}	Probabilidade de encontrar um buraco espectral
P_D	Probabilidade de detecção
P_{FN}	Probabilidade de falso negativo
P_{FA}	Probabilidade de falso alarme ou falso positivo
$\Pr[\cdot]$	Probabilidade de ocorrência do evento $[\cdot]$
$R_x(t, \tau)$	Função de autocorrelação
$R_x^\alpha(\tau)$	Função de autocorrelação cíclica

\mathbf{R}_Y	Matriz de covariância de \mathbf{Y}
\mathbf{R}_{Y_s}	Matriz de covariância de \mathbf{Y} calculada por média amostral
\mathbf{R}_N	Normalização de \mathbf{R}_{Y_s}
T_0	Período da função de autocorrelação cíclica
T_{ED}	Estatística de teste para o detector de energia
T_{MME}	Estatística de teste para o detector baseado na relação entre o máximo e o mínimo autovalores
T_{MED}	Estatística de teste para o detector baseado na relação entre o máximo autovalor e a potência de ruído
\mathbf{V}	Matriz de ruído
\mathbf{X}	Matriz dos sinais transmitidos
\mathbf{X}_C	Matriz formada pela concatenação da matriz \mathbf{X} com as F primeiras colunas de \mathbf{X}
\mathbf{Y}	Matriz de recepção para fins de sensoriamento
α	Frequência cíclica
α_{KS}	Níveis de significância para o teste de Kolmogorov-Smirnov
γ	Limiar de decisão
$\Gamma(\cdot)$	Função gamma
λ	Autovalor da matriz de covariância de \mathbf{Y}
λ_{\max}	Autovalor máximo da matriz de covariância de \mathbf{Y}
λ_{\min}	Autovalor mínimo da matriz de covariância de \mathbf{Y}
ρ	Autovalor da matriz de covariância de \mathbf{X}
σ_v^2	Potência de ruído
τ	Deslocamento temporal
Σ	Matriz de covariância de \mathbf{X}

RESUMO

Diante do cenário de escassez espectral resultante da política de alocação fixa adotada pelos órgãos regulatórios, pesquisas foram feitas e notou-se que, embora a maior parte do espectro de frequência já esteja alocada, uma considerável subutilização existe. Neste contexto surgiu o revolucionário conceito de Rádio Cognitivo, que pode se tornar o novo *Big Bang* em comunicações sem fio. Dentre as funcionalidades de um Rádio Cognitivo, o sensoriamento espectral é uma das principais. Graças a ela é possível explorar a subutilização do espectro de maneira oportunista. As técnicas de sensoriamento mais comuns e os desafios ligados à sua implementação são abordados nesta dissertação. Entre as mais recentes e promissoras técnicas encontra-se a detecção cooperativa baseada em autovalores, com destaque especial para a detecção por máximo autovalor, representando esta o enfoque principal do trabalho.

Palavras chave - Sensoriamento cooperativo, detecção por autovalores, rádio cognitivo, sensoriamento espectral.

ABSTRACT

The scenario of spectrum scarcity resulting from the fixed allocation policy adopted by regulatory governmental agencies has motivated research efforts which demonstrated that, although most of the frequency spectrum is already allocated, significant under-utilization exists. In this context emerged the revolutionary Cognitive Radio concept, which is expected to be a new Big Bang in wireless communications. Among its functionalities, spectrum sensing is one of the most important. Thanks to spectrum sensing, it is possible to exploit the underutilized spectrum opportunistically. The most common sensing techniques available in the literature and the challenges associated with their implementation will be discussed here. Among the most recent and promising techniques, the eigenvalue-based cooperative detection is the main focus of this thesis.

Keywords - Cognitive radio, spectrum sensing, cooperative sensing.

CAPÍTULO 1 – INTRODUÇÃO

1.1 Contextualização

A necessidade de comunicação da sociedade vem desde as eras mais antigas, quando homens utilizavam desenhos, pinturas ou sinais de fumaça para transmitirem informações entre si. No final do Século XIX, por meio da teoria eletromagnética formulada por James Clerk Maxwell e de experimentos que evidenciavam a existência de ondas de rádio proposta por Heinrich Hertz, Marconi realizou sua primeira transmissão sem fio a uma grande distância: 2720 km, de Cornwall - Inglaterra a Newfoundland - Canadá [1]. Com isto o caminho estava aberto para uma enorme evolução tecnológica.

Atualmente sistemas de comunicação estão presentes em nossa vida das mais diversas formas possíveis. Sinais de TV, telefone celular ou de um serviço de Internet *wireless* são apenas alguns exemplos mais comuns. Na realidade a lista de aplicações que envolvem transmissões e recepções sem fio é muito extensa e a cada dia que passa se torna ainda maior.

A fim de coordenar a operação desses sistemas, existem órgãos governamentais que regulamentam o uso do espectro de frequência. A nível internacional essa tarefa está sob a responsabilidade da ITU (*International Telecommunication Union*), agência das Nações Unidas responsável por assuntos tecnológicos que, entre outras coisas, organiza a cada três ou quatro anos o WRC (*World Radio Conference*), fórum internacional onde são discutidas questões relacionadas à regulamentação de rádio. A nível nacional, cada país possui um órgão responsável. No Brasil essa tarefa fica por conta da ANATEL (Agência Nacional de Telecomunicações) e nos Estados Unidos por conta da FCC (*Federal Communication Commission*), por exemplo.

A política de alocação espectral vigente é conhecida como política de alocação fixa. Para cada tipo de serviço é destinada uma banda de frequência e sua utilização normalmente é vinculada ao pagamento de uma licença de uso. Porém, como o espectro é limitado, observa-se que em determinadas faixas de frequência não há mais espaço para alocar novos serviços ou a disputa pelo que resta é muito acirrada. Uma evidência deste fato foi o alto valor arrecadado (5,338 bilhões de Reais) pela ANATEL no leilão realizado em 2007 para a concessão de licenças destinadas à operação de telefonia celular de terceira geração (3G), com o preço final de alguns lotes ultrapassando 200% do valor mínimo que se esperava [2]. Este mesmo exemplo aplica-se também na Europa, onde o preço chegou a 90 bilhões de Euros [3].

Outro problema reside no fato de que os serviços já alocados exigem cada vez maiores taxas de transmissão. É possível através do uso de esquemas de modulação

mais eficientes ou através da implementação de códigos corretores de erros mais robustos atingir-se uma melhor eficiência espectral, porém o avanço da tecnologia nesta linha já foi tamanha que ganhos expressivos são mais difíceis de serem alcançados. Uma solução para atender ao requisito de maiores taxas de transmissão seria o aumento da banda de frequência ocupada, o que também esbarra na limitação do espectro.

Diante deste cenário de escassez espectral resultante da política de alocação vigente, pesquisas foram feitas e um interessante fato foi constatado: embora a maior parte das faixas de frequência já esteja alocada, uma subutilização é observada. A Figura 1.1 ilustra uma medição feita em 2005 na cidade de Chicago – USA em uma faixa de 30MHz a 2.9GHz [4]. Nota-se nesta figura que em nenhuma faixa de frequências apresentada houve um aproveitamento total da banda (ocupação espectral de 100%).




Figura 1.1 - Medidas de ocupação espectral feita na cidade de Chicago –USA.

Outros estudos registrados em [5] e em [6] também evidenciam o mesmo fato de baixa utilização. Em outras palavras, a maior parte do espectro está alocada, porém em certo período do dia não está sendo utilizada e não pode ser reutilizada por outros sistemas.

Neste contexto surge então o conceito de Rádio Cognitivo, uma revolucionária tecnologia que, entre outras funcionalidades, tem como objetivo explorar a subutilização do espectro de uma maneira oportunista. Espera-se ser este o novo *Big Bang* em comunicações sem fio [7].

1.2 Rádio Cognitivo

Embora seja uma tecnologia relativamente recente, existem muitas definições para Rádio Cognitivo presentes na literatura, dentre elas destacando-se:

- Mitola [8]:

“Um transceptor de radiofrequência desenvolvido para inteligentemente detectar se um particular seguimento do espectro de rádio está em uso, e saltar muito rapidamente para o espectro temporariamente não usado, sem interferência na transmissão de outros usuários autorizados.”

- Haykin [9]:

“Um sistema de comunicação sem fio inteligente que está ciente do seu ambiente circundante (isto é, do mundo exterior) e utiliza metodologia de compreensão por construção do aprendizado com o ambiente, adaptando seus estados internos às variações estatísticas nos estímulos de RF e fazendo correspondentes mudanças em certos parâmetros de funcionamento, em tempo real, com dois objetivos principais:

- *Comunicação altamente confiável, sempre e onde for necessário.*
- *Utilização eficiente do espectro de radiofrequência.”*

- FCC [10]

“Rádio que pode mudar seus parâmetros de transmissão com base na interação com o ambiente no qual ele está operando.”

Das definições acima destacam-se duas características dos Rádios Cognitivos:

- Capacidade cognitiva: habilidade para capturar ou detectar informação do ambiente de radiofrequência.

- Reconfigurabilidade: permite que o Rádio Cognitivo seja dinamicamente programado de acordo com o ambiente.

Uma rede de Rádios Cognitivos pode ser subdividida em duas partes:

- Rede Primária: rede que tem direito exclusivo de uso de certa banda de frequências do espectro. Na realidade, esta parte representa a infra-estrutura já instalada ou a instalar, seguindo os moldes de alocação fixa de espectro. É constituída pelas operadoras de telefonia móvel celular atuais ou as transmissoras de TV, por exemplo. Os usuários dessa rede são conhecidos como usuários primários ou licenciados.
- Rede Secundária: ou Rede Cognitiva, é aquela que não possui licença para operar na banda desejada e, portanto, o faz de forma oportunista. Os usuários dessa rede são conhecidos como usuários secundários ou não licenciados, ou ainda usuários cognitivos.

A Figura 1.2 ilustra o princípio de operação do Rádio Cognitivo [11]. O usuário secundário, com base na sua capacidade cognitiva, identifica as oportunidades de transmissão correspondentes às partes do espectro temporariamente fora de uso, conhecidas como *Spectrum Holes* ou buracos espectrais, e inicia a sua transmissão. Quando a banda de frequência em questão é acessada pelo usuário primário, o Rádio Cognitivo altera sua frequência de operação para outro buraco espectral disponível ou altera seus parâmetros de transmissão (como potência ou esquema de modulação, por exemplo) a fim de não interferir neste usuário licenciado que está entrando em operação.

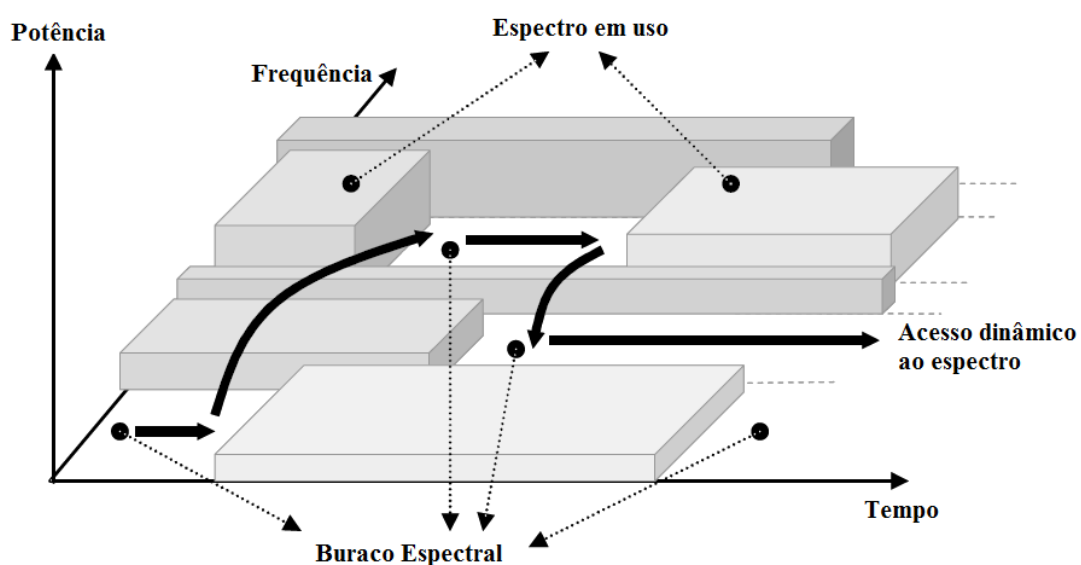


Figura 1.2 - Princípio de operação do Rádio Cognitivo.

Neste contexto, a seguir são sumarizadas as principais funções do Rádio Cognitivo:

- Sensoriamento espectral: objetiva determinar quais bandas de frequência do espectro estão disponíveis e identificar a presença dos usuários primários.
- Gerenciamento espectral: dentre as bandas classificadas como disponíveis, tem a função de escolher a que melhor atende os requisitos do usuário.
- Mobilidade espectral: também conhecida como *Handoff* espectral, é a funcionalidade que permite o usuário secundário migrar de uma banda de frequência para outra sem causar interrupção na comunicação.
- Compartilhamento espectral: tem por função promover de maneira justa o múltiplo acesso ao canal disponível.

O primeiro padrão que utiliza a tecnologia de Rádio Cognitivo é o padrão IEEE 802.22 [12]. Nele é prevista a operação de redes sem fio regionais (WRAN – *Wireless Regional Area Network*), de maneira oportunista, nas faixas de VHF e UHF alocadas para serviços de radiodifusão de sinais de TV e para dispositivos licenciados de baixa potência, como microfones sem fio. Uma das principais aplicações do 802.22 consiste na viabilização do acesso à Internet em banda larga em áreas remotas de difícil atendimento por parte das tecnologias atuais.

1.3 Estrutura e contribuições da dissertação

Dentre as funções do Rádio Cognitivo listadas na seção anterior, o sensoriamento espectral é uma das principais [13]. Devido a este fato, o estudo de tal funcionalidade será tomado como objetivo deste trabalho.

O Capítulo 2 ressalta inicialmente o motivo pelo qual o sensoriamento espectral é um atrativo método de identificação de oportunidades de transmissão, permitindo o acesso oportunista ao espectro de frequência. Também são abordados os maiores desafios quanto à sua implementação e as principais técnicas de sensoriamento presentes na literatura.

O Capítulo 3 apresenta um estudo detalhado sobre o sensoriamento espectral baseado nos autovalores da matriz de covariância do sinal recebido. Neste capítulo são definidas as métricas utilizadas para análise de desempenho (probabilidade de falso alarme e probabilidade de detecção), bem como sua relação com o limiar de decisão utilizado no receptor cognitivo a fim de se decidir sobre a presença ou ausência do sinal primário na banda de frequências analisada. Serão consideradas análises assintóticas, não assintóticas e por simulação no caso de detecção por máximo autovalor (MED – *Maximum Eigenvalue Detection*).

O Capítulo 4 trata de maiores investigações a respeito da técnica MED, representando este o enfoque principal do trabalho.

Finalmente o Capítulo 5 traz as conclusões e propostas para trabalhos futuros.

Dentre as principais contribuições do trabalho, destacam-se:

- Desenvolvimento de programas em MATLAB e MATHCAD úteis para análise de desempenho da técnica de sensoriamento espectral utilizada.
- Avaliação e identificação das limitações de uma expressão que determina a relação entre a probabilidade de falso alarme e o limiar de decisão utilizado no receptor, aplicável a técnica MED e obtida através de análise não assintótica.
- Determinação da relação entre a probabilidade de falso alarme e o limiar de decisão utilizado no receptor através de simulação de Monte Carlo, aplicável a técnica MED.
- Investigação de diferentes formas de se estimar a matriz de covariância do sinal recebido para fins de sensoriamento.
- Interpretação do parâmetro chamado fator de alisamento.
- Análise da influência do método de estimação da matriz de covariância no desempenho da técnica MED.
- Análise da influência do número de amostras coletadas no desempenho da técnica MED.
- Determinação de maneira empírica da distribuição do máximo autovalor da matriz de covariância do sinal recebido para o caso onde o Rádio Cognitivo recebe sinal mais ruído, isto é, quando o sinal de usuário primário está presente na banda de frequências analisada, já que não há solução presente na literatura para tal propósito.

1.4 Publicações

Os seguintes artigos foram elaborados com base nos conteúdos que serão apresentados nesta dissertação:

- Sensoriamento Espectral Cooperativo Baseado em Autovalores para Rádios Cognitivos, submetido em 30/08/2011 para a Revista Telecomunicações.
- Estimação Empírica da Distribuição da Estatística de Teste para o Sensoriamento Espectral por Máximo Autovalor sob a Hipótese H_1 , que será submetido ao SBrT'12.

CAPÍTULO 2 – SENSORIAMENTO ESPECTRAL

2.1 Identificação de oportunidades de transmissão

A fim de determinar quais bandas do espectro de frequência estão disponíveis para uso secundário, há três métodos que merecem destaque [14]:

- Registros em bancos de dados.
- Sinais balizadores.
- Sensoriamento espectral.

No método de registro em banco de dados os usuários primários armazenam em um servidor centralizado informações relevantes de seu estado, tais como posição que se encontram, potência irradiada ou tempo total estimado de conexão. Os usuários secundários, através de uma conexão com a Internet, acessam tais informações a fim de determinar as oportunidades de transmissão.

No método de sinais balizadores as informações relevantes dos usuários primários são transmitidas na interface aérea através de balizadores ao invés de serem armazenadas em um banco de dados. Basta aos usuários secundários monitorarem um canal de controle padronizado a fim de determinar quais porções do espectro eletromagnético podem ser utilizadas.

O grande problema dos métodos descritos é que os sistemas legados, ou seja, aqueles já implementados seguindo os moldes de alocação fixa do espectro de frequência, não foram projetados prevendo a interação entre usuários primários e secundários, havendo a necessidade de serem modificados a fim de se estabelecer compatibilidade. Outro fator que os prejudica é seu maior custo de implementação decorrente da necessidade de serem equipados com dispositivos de posicionamento como, por exemplo, o GPS (*Global Positioning System*).

No método de sensoriamento espectral para determinar os buracos espectrais os usuários secundários fazem uma leitura direta na banda de interesse (através de técnicas específicas que serão descritas adiante), dispensando a necessidade da participação dos usuários de sistemas já implementados, o que o torna mais atrativo que as outras abordagens. Um detalhe que deve ser cuidadosamente observado nesse cenário é que, devido à não interação entre usuários primários e secundários e ao fato de que a utilização do espectro pode ser bastante variável em determinadas bandas de frequência, a técnica empregada no sensoriamento deve ser rápida o bastante para perceber tais variações. Isto demanda um monitoramento contínuo ou frequente ao classificar o canal observado como ocupado ou livre, já que a não interferência nos sistemas primários é um requisito fundamental do sistema.

Na Tabela 2.1 apresenta-se um resumo comparativo entre as três abordagens descritas.

Tabela 2.1 - Comparativo entre os três métodos de identificação de oportunidades de transmissão.

	Registros em bancos de dados	Sinais balizadores	Sensoriamento espectral
Custo	Alto	Alto	Baixo
Compatível com sistemas legados?	Não	Não	Sim
Necessita de dispositivos de posicionamento?	Sim	Sim	Não
Necessita de conexão com a Internet?	Sim	Não	Não
Necessita de canal de controle?	Não	Sim	Sim
Necessita de monitoramento frequente?	Não	Não	Sim

2.2 Desafios para a implementação do sensoriamento espectral

Existe uma série de fatores que tornam o sensoriamento uma tarefa difícil de ser implementada. O objetivo desta seção é listar os principais desafios que devem ser observados.

2.2.1 Requisitos de hardware

Os sistemas de comunicação existentes atualmente foram projetados para operar dentro de uma determinada faixa de frequência e com sinais bem conhecidos. Como consequência, é possível desenvolver receptores ótimos com relativa baixa complexidade. Porém, em sistemas que utilizam Rádio Cognitivo, quanto maior a banda sensoriada e quanto mais rápido for o processamento das informações coletadas, mais oportunidades de transmissão poderão ser encontradas. Para tal propósito há necessidade de dispositivos (antenas e amplificadores, por exemplo), que operem em faixas largas e conversores analógico-digitais de alta resolução, acompanhados de processadores de alta velocidade.

2.2.2 Duração e frequência do sensoriamento

Como já comentado, as técnicas de sensoriamento espectral devem ser capazes de identificar as transmissões dos usuários primários dentro de certo tempo. Nesse processo, há dois parâmetros temporais de suma importância:

- Tempo de detecção do canal.
- Período de sensoriamento.

O tempo de detecção do canal representa uma relação de compromisso entre a confiabilidade da identificação (canal ocupado ou livre) e o número de oportunidades identificadas.

Tem-se mais certeza sobre o resultado da classificação quanto à ocupação de um determinado canal quando há um maior tempo disponível para que o sensoriamento seja executado [15]. À medida que esse tempo vai sendo reduzido, piora-se a qualidade da classificação. Por outro lado sobra mais tempo para que outras bandas sejam sensoriadas.

A periodicidade do sensoriamento espectral, ou seja, quantas vezes ele é executado em um intervalo de tempo, tem impacto direto na interferência no usuário primário. Uma vez encontrado um canal livre, o usuário secundário inicia sua transmissão. Porém, deve executar o sensoriamento frequentemente a fim de identificar uma possível atividade do usuário primário. Se o tempo entre um sensoriamento e outro é grande, corre-se risco da reativação do usuário primário não ser percebida, resultando em transmissão simultânea do usuário primário e do usuário secundário, caracterizando um cenário de interferência.

A escolha dos parâmetros temporais listados acima representa um grande desafio no projeto de técnicas de sensoriamento espectral. Seus valores dependem, entre outras coisas, das características dos sinais primários observados. A transmissão de um sinal de TV, por exemplo, muda pouco ao longo do tempo. Assim, o tempo total gasto com o sensoriamento pode ser maior. No padrão IEEE 802.22, por exemplo, recomenda-se um tempo de detecção menor que 2 segundos com uma periodicidade de 30 segundos [16].

Outro fator que é afetado pelos requisitos temporais é a eficiência de transmissão do rádio. Na arquitetura padrão, toda vez que o usuário secundário executa o sensoriamento espectral sua transmissão é interrompida, já que não é possível sensoriar e transmitir ao mesmo tempo. Desta maneira, quanto maior o tempo gasto com o sensoriamento espectral, menor será o tempo remanescente para transmissão, caracterizando menor eficiência e consequente redução no *throughput* do usuário secundário. Como solução para tal problema, em [15] é proposta uma arquitetura com dois rádios: um rádio é utilizado exclusivamente para desempenhar o sensoriamento espectral através de específicas técnicas como as que serão apresentadas na Seção 2.3 e o outro fica dedicado à transmissão de dados. Nesta arquitetura não há redução na eficiência de transmissão, mas é nitidamente observado um maior custo de implementação e um aumento do consumo de energia.

2.2.3 O usuário primário oculto

Considere a Figura 2.1, onde ilustra-se um transmissor primário com seu respectivo receptor e um Rádio Cognitivo operando na mesma frequência.




Figura 2.1 - Interferência causada pelo Rádio Cognitivo.

O usuário primário pode iniciar sua transmissão a qualquer momento por ser licenciado. Já o Rádio Cognitivo só poderá transmitir nos momentos em que o usuário primário não estiver transmitindo. Devido a algum desvanecimento profundo causado por uma propagação por múltiplos percursos ou sombreamento, o Rádio Cognitivo pode não conseguir detectar a transmissão do usuário primário. Nesta situação diz-se que o usuário primário estaria oculto, pois sua transmissão não pode ser percebida. Em outras palavras, o Rádio Cognitivo pode identificar aquele instante como uma oportunidade de transmissão e assim sua transmissão causará interferência no receptor primário.

Uma possível solução para mitigar tal problema é a utilização de sensoriamento cooperativo. Neste esquema, ao invés da ocupação do canal ser decidida baseada na informação coletada por um único Rádio Cognitivo, outros usuários secundários também participam do processo. Desta maneira, o que o usuário sombreado erroneamente identifica como canal livre, outros usuários que não estão sofrendo com desvanecimento profundo identificam como ocupado (ou seja, percebem a presença do transmissor primário), tornando o sensoriamento mais preciso. Mais detalhes sobre as diferenças, vantagens e desvantagens do sensoriamento cooperativo em comparação com o não cooperativo serão abordadas na Seção 2.3.5.

2.3 Técnicas de sensoriamento espectral

Uma vez descrito o método de sensoriamento espectral como uma forma atrativa de identificação de oportunidades de transmissão e listados os principais desafios quanto sua implementação, o objetivo desta seção é descrever as técnicas mais comuns presentes na literatura, comentar sobre o surgimento da técnica de sensoriamento baseado no máximo autovalor da matriz de covariância do sinal considerado para fins

de sensoriamento e, por fim, apresentar as diferenças, vantagens e desvantagens do sensoriamento cooperativo em comparação com o não cooperativo.

2.3.1 Sensoriamento por filtro casado

A fim de se ter uma detecção do sinal transmitido de forma ótima, torna-se necessário que, no momento da decisão, as amostras do sinal recebido apresentem a maior relação sinal-ruído (SNR – *Signal-to-noise Ratio*) possível, o que se consegue com o uso da detecção por filtro casado [17]. Neste tipo de abordagem requer-se que o sinal recebido seja efetivamente demodulado a fim de se decidir sob a presença ou ausência do sinal primário. Desta maneira, um Rádio Cognitivo que emprega tal técnica para fins de sensoriamento espectral deve ter um perfeito conhecimento *a priori* das características do sinal transmitido, como formato do pulso de transmissão, tipo e ordem da modulação empregada, bem como do canal de comunicação, além da necessidade do estabelecimento de sincronismo de portadora para detecção coerente.

A principal vantagem de se empregar um filtro casado com a finalidade de sensoriar o espectro de frequência é que necessita-se um baixo tempo de processamento da informação coletada para se atingir uma detecção com alta probabilidade de acerto [16]. Sua principal desvantagem é que, caso o sensoriamento seja executado em uma faixa de frequência que contenha vários tipos de sinais primários, o circuito final do Rádio Cognitivo se torna muito complexo, já que é requerido um receptor dedicado para cada tipo de usuário primário analisado, além do perfeito conhecimento das características do sinal.

2.3.2 Sensoriamento baseado em cicloestacionariedade

Como mencionado na subseção anterior, quando há um perfeito conhecimento do sinal analisado e do canal, o filtro casado representa um detector ótimo. Porém, na prática dificilmente tem-se tal conhecimento. No entanto, alguns atributos são intrínsecos à banda de frequência verificada. Por exemplo, ao se sensoriar uma faixa alocada para radiodifusão de sinais de TV, embora não se conheça com precisão o sinal a ser analisado, algumas de suas características básicas, como tipo de modulação ou frequência da portadora empregada são amplamente conhecidos em decorrência do processo de padronização imposto pelo órgão regulador do espectro de frequência. Neste contexto podem ser empregados detectores de cicloestacionariedade.

Em geral os sinais de sistemas de comunicação exibem alguma periodicidade com relação aos seus parâmetros estatísticos de segunda ordem, decorrentes, entre outras coisas, de processos de modulação por portadoras senoidais, amostragem ou codificação por sequências de espalhamento espectral. Tais sinais são ditos cicloestacionários e sua análise pode ser baseada na correspondente função de

autocorrelação, que é periódica com período denotado por T_0 , permitindo, assim, ser representada pela série de Fourier [13]

$$R_y(t, \tau) = E[y(t + \tau)y(t)] = \sum_{\alpha} R_y^{\alpha}(\tau)e^{j2\pi\alpha t}, \quad (2.1)$$

onde $E[x]$ é o valor esperado de x , $y(t)$ representa o sinal analisado, e as frequências $\{i/T_0\}$, $i \in \mathbb{Z}$, denotadas por α são conhecidas como frequências cíclicas. O termo $R_y^{\alpha}(\tau)$ é conhecido como função de autocorrelação cíclica e representa a correlação ao longo do tempo entre as componentes de frequência do sinal espaçadas por α e calculada entre as amostras de $y(t)$ distanciadas por τ no eixo do tempo, ou seja,

$$R_y^{\alpha}(\tau) = E[y(t)y(t + \tau)e^{-j2\pi\alpha t}], \quad (2.2)$$

onde a correlação temporal entre as componentes espectrais de $y(t)$ distanciadas por α é obtida graças ao termo $e^{-j2\pi\alpha t}$ que, de acordo com as propriedades da transformada de Fourier, representa um deslocamento de α no domínio da frequência.

Em [7] há uma lista com alguns tipos de sinais e suas respectivas frequências cíclicas. A Figura 2.2 representa uma ilustração da função de autocorrelação cíclica de um sinal AM-DSB (*Amplitude Modulated – Double Side Band*) na parte (a) e de um sinal PAM (*Pulse Amplitude Modulated*) na parte (b).




Figura 2.2 - Função de autocorrelação cíclica para um sinal AM-DSB (a) e para um sinal PAM (b).

Na ausência do sinal primário tem-se

$$R_x^{\alpha}(\tau) = 0 \quad \forall \quad \alpha \neq 0. \quad (2.3)$$

Percebe-se que a função de autocorrelação cíclica apresentada na parte (a) da Figura 2.2 é diferente da apresentada na parte (b). Então conclui-se que, além de ser possível detectar a presença do usuário primário analisando a função de autocorrelação do sinal no canal monitorado, consegue-se também distinguir o tipo do sinal sensoriado, já que diferentes sinais apresentam diferentes frequências cíclicas ou diferentes formatos de função de autocorrelação cíclica. Esta é a principal vantagem da técnica de sensoriamento espectral baseada em cicloestacionariedade. Seu ponto negativo é o alto tempo requerido para detecção, este decorrente do tempo necessário para estimação da função de autocorrelação, além da necessidade do sinal exibir características cicloestacionárias.

2.3.3 Sensoriamento por detecção de energia

Uma das desvantagens das técnicas de sensoriamento descritas anteriormente consiste da necessidade de total ou parcial conhecimento das características dos sinais a serem detectados e do canal de comunicação entre o transmissor primário e o Rádio Cognitivo. Considerando a operação de um Rádio Cognitivo em um cenário onde não se tem nenhuma informação *a priori* sobre as características dos sinais dos usuários primários, tais técnicas tornam-se impraticáveis.

Para estes casos, uma alternativa simples para detectar um sinal consiste em utilizar um detector de energia. Um receptor equipado com tal funcionalidade mede a energia presente em uma faixa de frequências primária durante um intervalo de observação e compara o resultado da medição com a potência de ruído ponderada por um limiar pré-estabelecido. Caso o valor esteja abaixo da referência, considera-se o canal como livre, representando uma oportunidade de transmissão para o usuário secundário. Caso o valor esteja acima da referência, considera-se o canal como ocupado.

Em [18] são apresentados dois possíveis diagramas do detector de energia, conforme ilustrado na Figura 2.3. Na configuração (a) o primeiro estágio é constituído por um filtro, cuja função é reduzir a influência dos canais adjacentes e do ruído fora da faixa de frequência de interesse no processo de sensoriamento espectral. Sendo assim, dado um sinal primário de banda B , deseja-se que a banda do filtro seja da mesma ordem de grandeza, o que torna a implementação pouco flexível. Uma alternativa é a utilização da configuração (b), a qual sugere um processamento das amostras no domínio da frequência através da aplicação da FFT (*Fast Fourier Transform*) de K pontos configuráveis.

Na sequência, ambas as configurações contêm um dispositivo de função de transferência quadrática (para cálculo da energia). Após ser realizada a média das n amostras do sinal, tem-se a estatística de teste T_{ED} :

$$T_{ED} = \frac{1}{n} \sum_{i=1}^n |y[i]|^2. \quad (2.4)$$

Tal estatística é comparada com um limiar de decisão γ que depende da potência do ruído σ_v^2 : Se $T_{ED} > \gamma \sigma_v^2$ decide-se pela presença do sinal primário; caso contrário decide-se pela ausência de sinal.

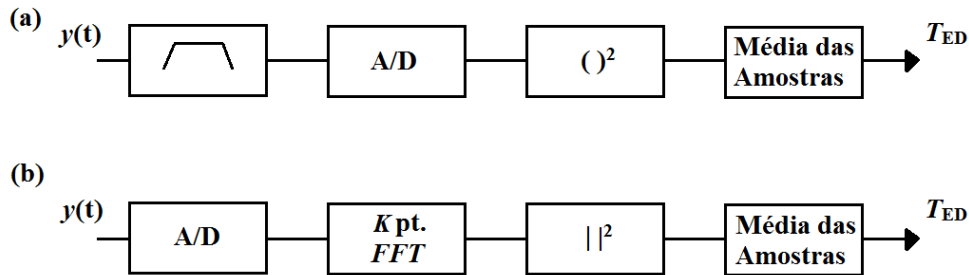


Figura 2.3 - Diagramas em bloco do detector de energia: (a) implementação com um pré-filtro analógico, (b) implementação utilizando FFT.

A principal vantagem da técnica de sensoriamento por detecção de energia é a sua baixa complexidade de implementação. Sua principal desvantagem é a alta sensibilidade quanto à incerteza sobre a potência do ruído no canal monitorado, que pode inclusive ser variável ao longo do tempo. A fim de diminuir esta incerteza, sugere-se em [19] que a potência do ruído seja medida em um canal de referência sobre o qual se sabe *a priori* que está desocupado.

2.3.4 Tabela comparativa e o surgimento da detecção por autovalores

A Tabela 2.2 resume as principais vantagens e desvantagens das três técnicas de sensoriamento descritas anteriormente.

Das técnicas listadas, a detecção de energia é a solução mais largamente citada na literatura. Em [20], onde trata-se de sensoriamento espectral não cooperativo, é referida como um esquema de detecção ótimo quando as amostras do sinal sensoriado são independentes e identicamente distribuídas (i.i.d.) e a potência de ruído é conhecida. Quando as amostras do sinal não são i.i.d. ou quando considera-se sensoriamento cooperativo, tal técnica não é ótima. Diante desse fato surgem novas técnicas de sensoriamento espectral cujo processo de detecção é baseado nos autovalores da matriz de covariância do sinal recebido. No Capítulo 3 serão apresentadas duas destas técnicas.

Tabela 2.2 - Comparação entre técnicas de sensoriamento espectral.

Técnica	Vantagens	Desvantagens
Sensoriamento por filtro casado	<ul style="list-style-type: none"> •detecção ótima •curto tempo requerido para o sensoriamento 	<ul style="list-style-type: none"> •requer perfeito conhecimento do sinal a ser sensoriado e do canal •necessita de sincronismo temporal e de portadora •torna-se complexo quando há muitos tipos de sinais primários a serem sensorizados
Sensoriamento baseado em cicloestacionariedade	<ul style="list-style-type: none"> •permite não só a detecção do sinal primário, mas também sua identificação 	<ul style="list-style-type: none"> •requer o conhecimento de alguns parâmetros do sinal sensoriado •necessita um alto tempo para concluir o sensoriamento
Sensoriamento por detecção de energia	<ul style="list-style-type: none"> •simples de implementar •não necessita de informação <i>a priori</i> sobre o sinal primário 	<ul style="list-style-type: none"> •é sensível à variação temporal da potência do ruído

2.3.5 Sensoriamento Cooperativo e Não Cooperativo

A Figura 2.4 ilustra um cenário formado por p transmissores primários e m Rádios Cognitivos com h_{ij} , $i=1,2,\dots,m$, $j=1,2,\dots,p$, representando o coeficiente do canal entre o transmissor primário j e o Rádio Cognitivo i . Caso o processo de detecção quanto à presença ou ausência do sinal primário na banda de frequência analisada seja baseado na observação de um único Rádio Cognitivo, tem-se o sensoriamento não cooperativo. Por outro lado, caso o mesmo processo seja baseado na observação de mais de um Rádio Cognitivo, tem-se o sensoriamento cooperativo.

Embora a implementação do sensoriamento não cooperativo seja mais simples se comparada com o sensoriamento cooperativo, observa-se que tal abordagem é mais susceptível às degradações do sinal impostas pelo canal de comunicação. Caso o Rádio Cognitivo que esteja sensoriando o espectro enfrente um desvanecimento profundo no momento da decisão de classificar o canal como ocupado ou livre, tal rádio não conseguirá perceber a presença do usuário primário e assim sua transmissão representará uma interferência no usuário primário. Já no sensoriamento cooperativo, têm-se maior confiança no resultado da classificação se o espectro de frequência está vago ou não, visto que a decisão é tomada em conjunto. Sua maior complexidade de implementação é oriunda do processamento adicional necessário para o

compartilhamento das informações de sensoriamento entre os usuários que participam do processo de detecção. Tais informações representam um *overhead* e são transmitidas através de um canal de controle dedicado.

O foco deste trabalho será o cenário de sensoriamento cooperativo, embora no Capítulo 4 também sejam apresentados alguns resultados a respeito de sensoriamento não cooperativo. A Seção 4.3.1 trará um maior detalhamento a respeito do sensoriamento não cooperativo e a Seção 4.3.2 um maior detalhamento para o sensoriamento cooperativo.




Figura 2.4 - Cenário constituído por p transmissores primários e m Rádios Cognitivos.

CAPÍTULO 3 - SENSORIAMENTO BASEADO EM AUTOVALORES

3.1 Introdução

O objetivo deste capítulo é apresentar um estudo sobre duas técnicas de sensoriamento espectral cuja decisão quanto à ocupação do canal é tomada com base nos autovalores da matriz de covariância do sinal coletado. A primeira técnica utiliza a relação entre o máximo e o mínimo autovalores, enquanto a segunda utiliza a relação entre o autovalor máximo e a potência de ruído.

Assim como para detecção de energia, tais técnicas são classificadas como técnicas cegas por não necessitarem de nenhuma informação *a priori* sobre os sinais transmitidos, tornando-se então muito atrativas para implementação em Rádios Cognitivos.

3.2 Modelo utilizado

De acordo com o cenário ilustrado na Figura 2.4, considere que as amostras coletadas para fins de sensoriamento estão dispostas em uma matriz $\mathbf{Y}_{m \times n}$ dada por:

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

onde

$$\mathbf{Y} = [\mathbf{y}_1 \quad \mathbf{y}_2 \quad \dots \quad \mathbf{y}_n],$$

com cada \mathbf{y}_i , $i=1,2,\dots,n$, sendo um vetor coluna aleatório complexo contendo m elementos.

Ainda com referência à equação (3.1), a matriz \mathbf{X} , que representa o sinal transmitido, é dada por:

$$\mathbf{X} = [\mathbf{x}_1 \quad \mathbf{x}_2 \quad \dots \quad \mathbf{x}_n],$$

onde cada \mathbf{x}_i , $i=1,2,\dots,n$, é um vetor coluna aleatório complexo contendo p elementos.

A matriz \mathbf{H} em (3.1) representa o canal e é dada por:

$$\mathbf{H} = \begin{bmatrix} h_{11} & h_{12} & \cdots & h_{1p} \\ h_{21} & h_{22} & \cdots & h_{2p} \\ \vdots & \vdots & \cdots & \vdots \\ h_{m1} & h_{m2} & \cdots & h_{mp} \end{bmatrix},$$

onde cada elemento aleatório complexo $\{h_{ij}\}$, $i=1,2,\dots,m$, $j=1,2,\dots,p$, representa o coeficiente de canal existente entre o transmissor primário j e o Rádio Cognitivo i .

Finalmente a matriz \mathbf{V} em (3.1) representa o ruído e é dada por:

$$\mathbf{V} = [\mathbf{v}_1 \quad \mathbf{v}_2 \quad \cdots \quad \mathbf{v}_n],$$

onde cada \mathbf{v}_i , $i=1,2,\dots,n$, é um vetor coluna gaussiano complexo com elementos i.i.d. de média 0 e variância σ_v^2 , contendo m elementos. Vale ressaltar que as matrizes \mathbf{V} e \mathbf{X} são independentes.

Considere as duas possíveis hipóteses:

- H_0 : o sinal primário não está presente no sinal observado.
- H_1 : o sinal primário está presente no sinal observado.

Das alternativas listadas, \mathbf{Y} pode ser descrito como:

$$\begin{aligned} H_0: \quad \mathbf{Y} &= \mathbf{V} \\ H_1: \quad \mathbf{Y} &= \mathbf{H}\mathbf{X} + \mathbf{V}. \end{aligned} \tag{3.2}$$

A matriz de covariância do sinal recebido é definida por [21]:

$$\mathbf{R}_Y = E[\mathbf{Y}\mathbf{Y}^\dagger], \tag{3.3}$$

onde \dagger representa o operador conjugado transposto.

Sob a hipótese H_0 tem-se:

$$\mathbf{R}_Y = E[\mathbf{Y}\mathbf{Y}^\dagger] = E[\mathbf{V}\mathbf{V}^\dagger] = \sigma_v^2 \mathbf{I}_m, \tag{3.4}$$

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

A fim de determinar os autovalores de \mathbf{R}_Y , utiliza-se a seguinte equação característica [22]:

$$\det[\mathbf{R}_Y - \lambda \mathbf{I}] = 0, \quad (3.5)$$

onde \mathbf{R}_Y é a matriz de interesse, λ representa os autovalores de \mathbf{R}_Y e \mathbf{I} é uma matriz identidade de mesma ordem que \mathbf{R}_Y .

Usando $\mathbf{R}_Y = \sigma_v^2 \mathbf{I}_m$, tem-se:

$$\det \left[\underbrace{\begin{bmatrix} \sigma_v^2 & 0 & \dots & 0 \\ 0 & \sigma_v^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_v^2 \end{bmatrix}}_{m \text{ colunas}} - \underbrace{\begin{bmatrix} \lambda & 0 & \dots & 0 \\ 0 & \lambda & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda \end{bmatrix}}_{m \text{ colunas}} \right] = 0 \quad (3.6)$$

$$\det \left[\underbrace{\begin{bmatrix} \sigma_v^2 - \lambda & 0 & \dots & 0 \\ 0 & \sigma_v^2 - \lambda & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_v^2 - \lambda \end{bmatrix}}_{m \text{ colunas}} \right] = 0$$

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

Logo; $\lambda_1 = \sigma_v^2, \lambda_2 = \sigma_v^2, \dots, \lambda_m = \sigma_v^2$.

Dáí conclui-se que:

$$\begin{aligned} \lambda_{\max} &= \sigma_v^2 \\ \lambda_{\min} &= \sigma_v^2 \\ \lambda_{\max} / \lambda_{\min} &= 1. \end{aligned} \quad (3.7)$$

Sob a hipótese H_1 tem-se:

$$\mathbf{R}_Y = E[\mathbf{Y}\mathbf{Y}^\dagger] = E[(\mathbf{H}\mathbf{X} + \mathbf{V})(\mathbf{H}\mathbf{X} + \mathbf{V})^\dagger] = E[(\mathbf{H}\mathbf{X} + \mathbf{V})(\mathbf{H}\mathbf{X})^\dagger + \mathbf{V}^\dagger]. \quad (3.8)$$

Usando a propriedade $(AB)^\dagger = B^\dagger A^\dagger$ [22] obtém-se

$$\begin{aligned} \mathbf{R}_Y &= E[(\mathbf{H}\mathbf{X} + \mathbf{V})(\mathbf{X}^\dagger \mathbf{H}^\dagger + \mathbf{V}^\dagger)] \\ &= E[\mathbf{H}\mathbf{X}\mathbf{X}^\dagger \mathbf{H}^\dagger + \mathbf{H}\mathbf{X}\mathbf{V}^\dagger + \mathbf{V}\mathbf{X}^\dagger \mathbf{H}^\dagger + \mathbf{V}\mathbf{V}^\dagger]. \end{aligned} \quad (3.9)$$

Da propriedade $E[A + B + C + D] = E[A] + E[B] + E[C] + E[D]$ [23] tem-se

$$\mathbf{R}_Y = E[\mathbf{H}\mathbf{X}\mathbf{X}^\dagger \mathbf{H}^\dagger] + E[\mathbf{H}\mathbf{X}\mathbf{V}^\dagger] + E[\mathbf{V}\mathbf{X}^\dagger \mathbf{H}^\dagger] + E[\mathbf{V}\mathbf{V}^\dagger]. \quad (3.10)$$

Fazendo o uso da propriedade $E[aA] = aE[A]$ [23] tem-se

$$\mathbf{R}_Y = \mathbf{H}E[\mathbf{X}\mathbf{X}^\dagger]\mathbf{H}^\dagger + \mathbf{H}E[\mathbf{X}\mathbf{V}^\dagger] + \mathbf{H}^\dagger E[\mathbf{V}\mathbf{X}^\dagger] + \sigma_v^2 \mathbf{I}_m. \quad (3.11)$$

Da propriedade $E[AB] = E[A]E[B]$ [23] para variáveis aleatórias A e B independentes, pode-se escrever

$$\mathbf{R}_Y = \mathbf{H}E[\mathbf{X}\mathbf{X}^\dagger]\mathbf{H}^\dagger + \mathbf{H}E[\mathbf{X}]E[\mathbf{V}^\dagger] + \mathbf{H}^\dagger E[\mathbf{V}]E[\mathbf{X}^\dagger] + \sigma_v^2 \mathbf{I}_m. \quad (3.12)$$

Mas $E[\mathbf{V}] = 0$, o que leva a

$$\mathbf{R}_Y = \mathbf{H}E[\mathbf{X}\mathbf{X}^\dagger]\mathbf{H}^\dagger + \sigma_v^2 \mathbf{I}_m, \quad (3.13)$$

onde o termo $E[\mathbf{X}\mathbf{X}^\dagger]$ representa a matriz de covariância do sinal analisado separadamente. Denominando-se esta parcela de Σ , tem-se

$$\mathbf{R}_Y = \mathbf{H}\Sigma\mathbf{H}^\dagger + \sigma_v^2 \mathbf{I}_m. \quad (3.14)$$

Neste caso, seja $\lambda_1 > \lambda_2 > \dots > \lambda_m$ os autovalores de \mathbf{R}_Y e $\rho_1 > \rho_2 > \dots > \rho_m$ os autovalores de $\mathbf{H}\Sigma\mathbf{H}^\dagger$. Então, finalmente, $\lambda_i = \rho_i + \sigma_v^2$, $i = 1, 2, \dots, m$.

Dáí conclui-se que:

$$\begin{aligned}\lambda_{\max} &= \rho_{\max} + \sigma_v^2 \\ \lambda_{\min} &= \rho_{\min} + \sigma_v^2 \\ \lambda_{\max}/\lambda_{\min} &> 1.\end{aligned}\tag{3.15}$$

Com base nas expressões (3.7) e (3.15), observa-se que os autovalores da matriz de covariância do sinal recebido podem ser utilizados para detectar a presença do usuário primário na banda de frequências sensoriada, já que sob a hipótese H_1 $\lambda_{\max} > \sigma_v^2$ e $\lambda_{\max}/\lambda_{\min} > 1$, enquanto que sob H_0 $\lambda_{\max} = \sigma_v^2$ e $\lambda_{\max}/\lambda_{\min} = 1$.

3.3 Algoritmos de detecção

O objetivo dessa seção é apresentar os algoritmos utilizados nas duas técnicas de sensoriamento espectral destacadas no início do capítulo:

- Detecção baseada na relação entre o máximo e o mínimo autovalores da matriz de covariância do sinal recebido (técnica MME – *Maximum-Minimum Eigenvalue Detection*).
- Detecção baseada no máximo autovalor da matriz de covariância do sinal recebido (técnica MED – *Maximum Eigenvalue Detection*).

O primeiro passo para ambas as técnicas consiste em determinar a matriz de covariância do sinal recebido. Utiliza-se aqui o cálculo da matriz de covariância do sinal por média amostral (*Sample Covariance Matrix*), como definida em [24] por:

$$\mathbf{R}_{Y_s} = \frac{1}{n} \sum_{i=1}^n \mathbf{y}_i \mathbf{y}_i^\dagger,\tag{3.16}$$

ou na forma matricial:

$$\mathbf{R}_{Y_s} = \frac{1}{n} \mathbf{Y} \mathbf{Y}^\dagger.\tag{3.17}$$

Com base nessa definição, tem-se os algoritmos:

- Técnica MME:

PASSO 1: estime a matriz de covariância por média amostral.

PASSO 2: obtenha o máximo e o mínimo autovalores de tal matriz.

PASSO 3: dado um limiar de decisão γ , decida de acordo com:

$$\begin{cases} \text{Se } \lambda_{\max}/\lambda_{\min} > \gamma & : \text{ sinal existe} \\ \text{caso contrário} & : \text{ sinal não existe.} \end{cases} \quad (3.18)$$

- Técnica MED:

PASSO 1: estime a matriz de covariância por média amostral.

PASSO 2: obtenha o máximo autovalor de tal matriz.

PASSO 3: dado um limiar de decisão γ , decida de acordo com:

$$\begin{cases} \text{Se } \lambda_{\max} > \gamma\sigma_v^2 & : \text{ sinal existe} \\ \text{caso contrário} & : \text{ sinal não existe.} \end{cases} \quad (3.19)$$

3.4 Limiar de decisão

Como pode ser observado na última seção, o princípio básico de funcionamento das técnicas de sensoriamento espectral consiste em extrair-se algum parâmetro do sinal recebido, denominado variável de decisão, e compará-lo com uma referência, denominada limiar de decisão.

Devido à natureza aleatória do sinal recebido, o parâmetro escolhido também é uma variável aleatória. Para as duas técnicas apresentadas as variáveis de decisão são:

$$\begin{aligned} T_{MME} &= \frac{\lambda_{\max}}{\lambda_{\min}} \\ T_{MED} &= \frac{\lambda_{\max}}{\sigma_v^2}. \end{aligned} \quad (3.20)$$

Assim, ao se classificar um canal como livre ou ocupado não há certeza no resultado e sim uma probabilidade associada a esta classificação. Para cada hipótese considerada na Seção 3.2, as variáveis aleatórias T_{MME} e T_{MED} apresentarão uma função densidade de probabilidade (PDF – *Probability Density Function*) diferente, aqui denominadas de:

$f_{0_{MME}}(t) = \text{PDF de } T_{MME} \text{ sob } H_0$

$f_{1_{MME}}(t) = \text{PDF de } T_{MME} \text{ sob } H_1$

$f_{0_{MED}}(t) = \text{PDF de } T_{MED} \text{ sob } H_0$

$f_{1_{MED}}(t) = \text{PDF de } T_{MED} \text{ sob } H_1.$

A função do algoritmo de sensoriamento empregado é estimar qual hipótese é a correta dado uma observação. Assim os seguintes resultados são possíveis:

- Estimar a hipótese correta como H_0 e de fato H_0 ser a correta. A esta situação associa-se a seguinte probabilidade:

$$P_{BE} = \Pr\left[\hat{\theta} = H_0 \mid \theta = H_0\right], \quad (3.21)$$

denominada de probabilidade de encontrar um buraco espectral.

- Estimar a hipótese correta como H_1 e de fato H_1 ser a correta. A esta situação associa-se a seguinte probabilidade:

$$P_D = \Pr\left[\hat{\theta} = H_1 \mid \theta = H_1\right], \quad (3.22)$$

denominada de probabilidade de detecção.

- Estimar a hipótese correta como H_0 , porém de fato H_1 ser a correta. A esta situação associa-se a seguinte probabilidade:

$$P_{FN} = \Pr\left[\hat{\theta} = H_0 \mid \theta = H_1\right], \quad (3.23)$$

denominada de probabilidade de falso negativo.

- Estimar a hipótese correta como H_1 , porém de fato H_0 ser a correta. A esta situação associa-se a seguinte probabilidade:

$$P_{FA} = \Pr\left[\hat{\theta} = H_1 \mid \theta = H_0\right], \quad (3.24)$$

denominada de probabilidade de falso alarme ou falso positivo.

Das probabilidades listadas acima, utiliza-se tipicamente a P_{FA} ($P_{FA} = 1 - P_{BE}$) e a P_D ($P_D = 1 - P_{FN}$) para a avaliação do desempenho da técnica de sensoriamento empregada.

É possível então relacionar o limiar de decisão γ com P_{FA} e P_D envolvendo as distribuições de probabilidade das variáveis aleatórias T_{MME} e T_{MED} sob cada hipótese apresentada:

- Para a técnica MME:

$$\begin{aligned}
 P_{FA} &= \Pr[T_{MME} > \gamma | H_0] = \int_{\gamma}^{\infty} f_{0_{MME}}(t) dt \\
 P_D &= \Pr[T_{MME} > \gamma | H_1] = \int_{\gamma}^{\infty} f_{1_{MME}}(t) dt.
 \end{aligned}
 \tag{3.25}$$

- Para a técnica MED:

$$\begin{aligned}
 P_{FA} &= \Pr[T_{MED} > \gamma | H_0] = \int_{\gamma}^{\infty} f_{0_{MED}}(t) dt \\
 P_D &= \Pr[T_{MED} > \gamma | H_1] = \int_{\gamma}^{\infty} f_{1_{MED}}(t) dt.
 \end{aligned}
 \tag{3.26}$$

A escolha do limiar γ tem impacto direto no desempenho do algoritmo utilizado. Deseja-se idealmente o maior valor possível de P_D e o menor valor possível de P_{FA} . Alto P_D traduz-se em baixa interferência no usuário primário: nessa situação o algoritmo empregado seria capaz de detectar com alta probabilidade a presença do usuário primário, diminuindo a chance de haver transmissões simultâneas entre primário e secundário, o que caracterizaria uma interferência. Um baixo valor para P_{FA} traduz-se em maior eficiência espectral: nessa situação, de todos os buracos espectrais existentes em um dado período, ter-se-ia uma baixa probabilidade do algoritmo empregado classificar erradamente um buraco, possibilitando maior aproveitamento das oportunidades.

No entanto não é possível aumentar P_D e diminuir P_{FA} ao mesmo tempo. A Figura 3.1 ilustra tal afirmação, onde observam-se as seguintes situações: se o valor de γ for aumentado (deslocando a referência γ para a posição 1, por exemplo), diminui-se P_{FA} e P_D (P_{FN} aumenta e $P_D = 1 - P_{FN}$ diminui); se o valor de γ for diminuído

(deslocando a referência γ para a posição 2, por exemplo) aumenta-se P_{FA} e P_D (P_{FN} diminui e $P_D = 1 - P_{FN}$ aumenta).




Figura 3.1 - Ilustração da relação entre P_{FA} e P_D .

Uma solução consiste em calcular o valor de γ a fim de atender a um requisito de P_{FA} ou P_D . Para as técnicas MME e MED, determinar uma expressão de γ em função de P_D ou vice-versa é uma questão pouco investigada na literatura, pois isto requer, a princípio, o conhecimento das distribuições de T_{MME} e T_{MED} sob a hipótese H_1 , as quais ainda não foram determinadas de maneira exata. Para determinar uma expressão de γ em função de P_{FA} considera-se a hipótese H_0 como referência, ou seja, o caso onde somente há ruído presente na banda analisada, podendo-se então reescrever a matriz de covariância por média amostral definida em (3.16) como:

$$\mathbf{R}_{Y_s} = \frac{1}{n} \sum_{i=1}^n \mathbf{y}_i \mathbf{y}_i^\dagger = \frac{1}{n} \sum_{i=1}^n (\mathbf{H} \mathbf{x}_i + \mathbf{v}_i)(\mathbf{H} \mathbf{x}_i + \mathbf{v}_i)^\dagger. \quad (3.27)$$

Mas sob H_0 , $\mathbf{x}_i = 0$, então:

$$\mathbf{R}_{Y_s|H_0} = \mathbf{R}_{V_s} = \frac{1}{n} \sum_{i=1}^n \mathbf{v}_i \mathbf{v}_i^\dagger. \quad (3.28)$$

Na forma matricial:

$$\mathbf{R}_{V_s} = \frac{1}{n} \mathbf{V} \mathbf{V}^\dagger. \quad (3.29)$$

Dada a natureza do ruído considerado no modelamento apresentado na Seção 3.2, tal matriz pode ser considerada uma Matriz Wishart [25], cujo estudo da distribuição de seus autovalores é a chave para determinar-se uma expressão que relaciona γ e P_{FA} . A partir do próximo subitem desta seção serão apresentados os cálculos envolvendo análise assintótica, análise não assintótica e análise baseada em uma simulação de Monte Carlo. Finaliza-se com uma curva de P_{FA} versus P_D .

Será considerado como referência deste estudo o sensoriamento por máximo autovalor MED, já que em [26] são apresentados resultados que evidenciam seu melhor desempenho em relação à técnica MME. Vale atentar para o detalhe que em [26] a técnica MED é chamada de BCED (*Blindly Combined Energy Detection*). Outro detalhe importante que deve ser destacado é que, conforme observado na expressão (3.20), a técnica MED apresenta a desvantagem de depender do conhecimento da potência do ruído para que o algoritmo de detecção seja implementado. No entanto, caso tal potência seja desconhecida, é possível estimá-la como a média dos autovalores (excetuando o maior) da matriz de covariância. Neste caso o desempenho da técnica MED ainda é superior ao desempenho da técnica MME conforme sugerido em [27].

Nos resultados de simulação que serão apresentados no final deste capítulo e ao longo do Capítulo 4 considerou-se que a potência do ruído era conhecida.

3.4.1 Expressão de γ versus P_{FA} - análise assintótica

O objetivo desta seção é apresentar uma expressão que relaciona o limiar de decisão γ com o requerido valor de P_{FA} , aplicável à técnica MED. Com esta finalidade, deseja-se descobrir a distribuição dos autovalores da matriz de covariância do sinal recebido por média amostral \mathbf{R}_{V_s} que é do tipo Wishart. Como pode ser observado em (3.29), \mathbf{R}_{V_s} é calculada a partir da matriz de ruído \mathbf{V} de ordem $m \times n$. Uma primeira possibilidade é considerar que os valores de m e n são muito grandes (tendendo ao infinito). A este tipo de consideração dá-se o nome de análise assintótica. Desta maneira, baseado nos estudos propostos em [28] e [29], apresenta-se em [26] a seguinte expressão:

$$\gamma = \frac{(\sqrt{n} + \sqrt{m})^2}{n} \left(1 + \frac{(\sqrt{n} + \sqrt{m})^{-2/3}}{nm^{1/6}} F_2^{-1}(1 - P_{FA}) \right), \quad (3.30)$$

onde F_2^{-1} representa a função inversa da distribuição de probabilidade cumulativa (CDF – *Cumulative Distribution Function*) da distribuição de Tracy-Widom de ordem 2.

O grande limitador de se utilizar a expressão (3.30) é que o valor de γ obtido em função do requerido valor de P_{FA} é válido para altos valores de m e n , posto que foi considerada uma análise assintótica na determinação de tal expressão. Na prática tal situação traduz-se em um grande tempo de sensoriamento e numa maior complexidade do receptor devido à necessidade de processar matrizes de covariância de ordem elevada. Traduz-se também em números não realistas para a quantidade de amostras e Rádios Cognitivos que cooperam.

3.4.2 Expressão de γ versus P_{FA} - análise não assintótica

O objetivo dessa seção é apresentar uma expressão que relaciona o limiar de decisão γ com o requerido valor de P_{FA} , baseado em uma análise não assintótica aplicável à técnica MED. Como no subitem anterior, o primeiro passo consiste em descobrir a distribuição dos autovalores da matriz de covariância do sinal recebido por média amostral \mathbf{R}_{v_s} , que é do tipo Wishart.

Considere a normalização de \mathbf{R}_{v_s} como a seguir:

$$\mathbf{R}_N = \frac{n\mathbf{R}_{v_s}}{\sigma_v^2}. \quad (3.31)$$

Segundo proposta apresentada em [26], a CDF do máximo autovalor de \mathbf{R}_N é definida por:

$$\Pr[\lambda_{\max}(\mathbf{R}_N) < x] = \frac{C\Gamma_m(m)}{C\Gamma_m(n+m)} x^{mn} {}_1F_1(n; n+m; -x\mathbf{I}_m), \quad (3.32)$$

onde \mathbf{I}_m é uma matriz identidade de ordem m , ${}_1F_1(\cdot; \cdot; \cdot)$ é a função hipergeométrica de primeiro tipo com argumento matricial [30] e $C\Gamma_m$ é dado pela expressão a seguir:

$$C\Gamma_m(x) = \pi^{m(n-1)/2} \prod_{k=1}^m \Gamma(x-k+1), \quad (3.33)$$

onde x representa o argumento considerado e $\Gamma(\cdot)$ é a função Gama [31].

Assim tem-se:

$$P_{FA} = \Pr[T_{MED} > \gamma | H_0] = \Pr[\lambda_{\max}(\mathbf{R}_N) > \gamma] = 1 - \Pr[\lambda_{\max}(\mathbf{R}_N) < \gamma]. \quad (3.34)$$

Substituindo (3.32) em (3.34), tem-se:

$$P_{FA} = 1 - \frac{C\Gamma_m(m)}{C\Gamma_m(n+m)} \gamma^{nm} {}_1F_1(n; n+m; -\gamma \mathbf{I}_m). \quad (3.35)$$

O cálculo da função hipergeométrica com argumento matricial é feito através de um programa em MATLAB disponível em [30]. Tal programa, nomeado de “mhgi”, está listado no Apêndice 1.

3.4.3 Análise de γ versus P_{FA} via Monte Carlo

É possível também obter uma relação entre P_{FA} e γ através de uma simulação de Monte Carlo. Utiliza-se para isso o programa em MATLAB presente no Apêndice 2. Seu princípio básico de funcionamento consiste em calcular a matriz de covariância do sinal recebido por média amostral sob a hipótese H_0 (ou seja, considerando a ausência do sinal primário), extrair seu máximo autovalor e compará-lo com o limiar de decisão, a fim de decidir sob a existência ou ausência do sinal primário. O resultado do programa em questão é uma curva que relaciona P_{FA} (ordenada) com valores de γ (abscissa) que foram considerados como entrada.

A fim de validar tal simulação, a Figura 3.2 traz uma relação entre P_{FA} e γ para alguns valores de m e n . As curvas tracejada, pontilhada e contínua representam o cálculo teórico realizado através da expressão (3.35) e os quadrados, círculos e losangos correspondem a resultados da simulação de Monte Carlo.

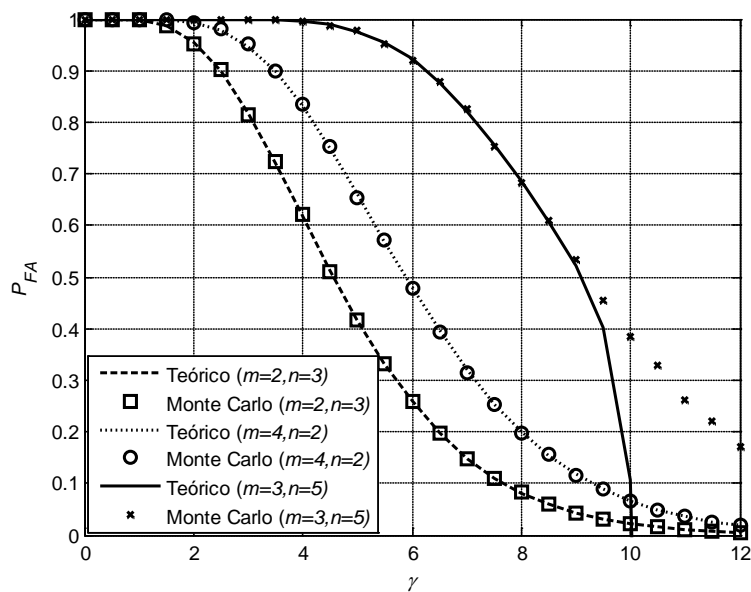


Figura 3.2 – Valores de γ e P_{FA} teóricos e obtidos por simulação.

Como pode ser observado na Figura 3.2, para $m=3$, $n=5$ e $\gamma > 9$ há um erro entre a curva teórica e a obtida por simulação. Plamen Koev, um dos autores da rotina “mhgi” utilizada para o cálculo da função hipergeométrica com argumento matricial ${}_1F_1$, através de uma comunicação via e-mail justificou que a razão para tal comportamento se dá devido ao fato de sua rotina levar em consideração expansões em série de Taylor que por sua vez apresentam problemas de convergência quando o argumento da série é grande. Para melhor entendimento, Plamen Koev sugeriu considerar a função e^x expandida em série de Taylor como ilustração. Seja então

$$e^x = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \frac{x^4}{4!} + \dots \quad (3.36)$$

Para $x=-3$, observa-se que o resultado calculado com a função e^x ou com sua correspondente expansão em série de Taylor representa o mesmo valor:

$$e^{-3} = 0,0498$$

$$\underbrace{1 + (-3) + \frac{(-3)^2}{2!} + \frac{(-3)^3}{3!} + \frac{(-3)^4}{4!} + \dots}_{100 \text{ termos}} = 0,0498. \quad (3.37)$$

Já para $x=-100$ observa-se um enorme erro entre o cálculo realizado diretamente com a função e^x e com sua correspondente expansão em série de Taylor:

$$e^{-100} = 3,72 \cdot 10^{-44}$$

$$\underbrace{1 + (-100) + \frac{(-100)^2}{2!} + \frac{(-100)^3}{3!} + \frac{(-100)^4}{4!} + \dots}_{100 \text{ termos}} = 1,30 \cdot 10^{43}. \quad (3.38)$$

Retomando a análise das curvas presentes na Figura 3.2, observa-se que, com exceção do caso comentado acima, há uma grande aderência entre os resultados teóricos e aqueles obtidos por simulação. Sendo assim, pode-se considerar que o processo de simulação de Monte Carlo está correto e que se pode confiar nos resultados por ele obtidos.

3.4.4 A curva ROC

A escolha do limiar de decisão γ representa uma relação de compromisso entre o valor de P_{FA} e P_D . Para cada valor de γ determinado a fim de se atingir um específico requisito de P_{FA} haverá uma probabilidade de detecção P_D correspondente. Na

simulação citada na Seção 3.4.3 considerou-se a hipótese H_0 como referência. Assim obteve-se uma relação entre γ e P_{FA} . Tomando como base a hipótese H_1 (ou seja, considerando a presença do sinal primário), tal simulação pode ser reescrita resultando na rotina presente no Apêndice 3, de onde obtêm-se um valor de P_D em função da relação sinal-ruído (SNR) e do limiar de decisão γ considerado. Desta maneira é possível representar diversos valores de P_{FA} em relação a P_D para uma determinada SNR através de uma curva chamada ROC (*Receiver Operating Characteristic*). Tal curva é obtida variando-se o limiar γ de tal sorte que a faixa de valores desejados para P_D e P_{FA} seja obtida.

A Figura 3.3 reproduz duas curvas ROC apresentadas na referência [27], onde foi considerado $m=6$, $n=50$, $SNR=-10dB$, ruído AWGN (*Additive White Gaussian Noise*), e um cenário contendo uma única antena transmissora ($p=1$). A curva contínua representa a ROC para a técnica MED e a curva tracejada representa a curva ROC para a técnica de detecção de energia (ED – *Energy Detection*). Deve-se atentar para o detalhe que em [27] a técnica MED é chamada de RLRT (*Roy's Largest Root Test*). Os valores de P_{FA} e P_D para a técnica de detecção de energia foram obtidos através da simulação presente nos Apêndices 4 e 5, respectivamente. Observa-se nesta figura que, para uma P_{FA} requerida de até aproximadamente 0.8 a técnica MED apresenta melhor probabilidade de detecção se comparada com a técnica de detecção de energia. Investigações preliminares não registradas nesta dissertação indicam ainda que a técnica MED é superior a técnica de ED na presença de ruído impulsivo. Isto torna ainda mais atrativo o uso da MED. A conclusão de tais investigações resultará na elaboração de um artigo sobre esta questão.




Figura 3.3 - ROC para a técnica MED e ED com $m=6$, $n=50$ e $SNR=-10dB$.

O próximo capítulo trará outras investigações a respeito do sensoriamento baseado no máximo autovalor da matriz de covariância do sinal recebido, envolvendo procedimentos equivalentes aos apresentados neste capítulo.

CAPÍTULO 4 – INVESTIGAÇÕES ENVOLVENDO A TÉCNICA MED

4.1 Introdução

O objetivo deste capítulo é apresentar investigações a respeito do sensoriamento baseado em máximo autovalor. Inicia-se com a apresentação de diferentes formas de se estimar a matriz de covariância do sinal recebido por média amostral. Em seguida investiga-se qual o impacto da estimação no desempenho da técnica de sensoriamento empregada. Na sequência é apresentado o que ocorre com o valor da probabilidade de detecção à medida que se aumenta o número de amostras coletadas. Finaliza-se com uma proposta para determinar a distribuição do máximo autovalor sob a hipótese H_1 , ou seja, considerando que no sinal recebido haja sinal mais ruído, para então determinar uma expressão que relaciona a probabilidade de detecção P_D com o limiar de decisão γ .

4.2 Estimativas para a matriz de covariância por média amostral

Existem diferentes formas de se estimar a matriz de covariância do sinal recebido definida em (3.3). O objetivo desta seção é descrever quatro distintas formas de cálculo que serão, mais adiante, aplicadas em diferentes cenários de sensoriamento espectral.

4.2.1 Método 1 de estimação da matriz de covariância por média amostral

O Método 1 pode ser denominado de método convencional. Seja \mathbf{Y} a matriz de ordem $m \times n$ representada a seguir:

$$\mathbf{Y} = \begin{bmatrix} y_{11} & y_{12} & y_{13} & \cdots & y_{1n} \\ y_{21} & y_{22} & y_{23} & \cdots & y_{2n} \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ y_{m1} & y_{m2} & \cdots & \cdots & y_{mn} \end{bmatrix}. \quad (4.1)$$

Seja \mathbf{y}_i , $i=1,2,\dots,n$, cada coluna de tal matriz. Obtém-se a matriz de covariância por média amostral segundo o Método 1 através de:

$$\mathbf{R}_{Ys1} = \frac{1}{n} \sum_{i=1}^n \mathbf{y}_i \mathbf{y}_i^\dagger = \frac{1}{n} \mathbf{Y} \mathbf{Y}^\dagger. \quad (4.2)$$

Observa-se que este foi o mesmo método aplicado na simulação de Monte Carlo descrita na Seção 3.4.3 e na Seção 3.4.4.

4.2.2 Método 2 de estimação da matriz de covariância por média amostral

Seja \mathbf{Y} uma matriz linha dada por:

$$\mathbf{Y} = [y_1 \quad y_2 \quad y_3 \quad \cdots \quad y_n]. \quad (4.3)$$

Considere a partição de tal matriz em k pedaços consecutivos de n/k elementos cada, nomeados por \mathbf{y}_i , $i=1,2,\dots,k$, como ilustrado no exemplo a seguir para $n=6$ e $k=3$:

$$\mathbf{Y} = \left[\underbrace{y_1 \quad y_2}_{\mathbf{y}_1} \quad \underbrace{y_3 \quad y_4}_{\mathbf{y}_2} \quad \underbrace{y_5 \quad y_6}_{\mathbf{y}_3} \right]. \quad (4.4)$$

Para este caso a matriz de covariância por média amostral pode ser computada por meio de:

$$\mathbf{R}_{Ys2} = \frac{1}{k} \sum_{i=1}^k \mathbf{y}_i \mathbf{y}_i^\dagger. \quad (4.5)$$

Observe que, mesmo por ter uma notação ligeiramente diferenciada, este método é equivalente ao Método 1. No entanto, esta pequena diferenciação será de grande valia nas investigações deste capítulo.

4.2.3 Método 3 de estimação da matriz de covariância por média amostral

Seja \mathbf{Y} uma matriz linha como apresentado em (4.3). Seja L um parâmetro chamado de fator de alisamento (*Smoothing Factor*) [20]. Considere \mathbf{Y}_p como sendo uma matriz linha formada pelos $L-1$ primeiros elementos de \mathbf{Y} . Define-se então \mathbf{Y}_s como a concatenação de \mathbf{Y} e \mathbf{Y}_p . Seja \mathbf{y}_i um vetor linha constituído do elemento i até o elemento $i+L-1$ de \mathbf{Y}_s , $i=1,2,\dots,n$, como ilustrado no exemplo a seguir para $n=6$ e $L=3$:

$$\begin{array}{rcl}
i=1 & \mathbf{Y}_s = [y_1 & y_2 & y_3 & y_4 & y_5 & y_6 & \mathbf{y}_1 & \mathbf{y}_2] \\
& & \underbrace{\hspace{2cm}} & & & & & & \\
& & \mathbf{y}_1 & & & & & & \\
i=2 & \mathbf{Y}_s = [y_1 & y_2 & y_3 & y_4 & y_5 & y_6 & \mathbf{y}_1 & \mathbf{y}_2] \\
& & \underbrace{\hspace{2cm}} & & & & & & \\
& & \mathbf{y}_2 & & & & & & \\
\vdots & & & & & \vdots & & & \\
i=n & \mathbf{Y}_s = [y_1 & y_2 & y_3 & y_4 & y_5 & y_6 & \mathbf{y}_1 & \mathbf{y}_2] \\
& & & & & & \underbrace{\hspace{2cm}} & & \\
& & & & & & \mathbf{y}_n & &
\end{array} \tag{4.6}$$

Define-se então:

$$\mathbf{R}_{Ys3} = \frac{1}{n} \sum_{i=1}^n \mathbf{y}_i^{\dagger} \mathbf{y}_i. \tag{4.7}$$

A Figura 4.1 ilustra a influência do fator de alisamento L no cálculo da matriz de covariância por média amostral. Na parte (a) tem-se uma representação de uma matriz de covariância de ordem 20 onde foi utilizado o fator de alisamento $L=20$ no cálculo, conforme formulação definida em (4.7). Em (b) tem-se uma representação onde não foi utilizado o fator de alisamento no cálculo ($L=1$). Nota-se que a matriz em (a) apresenta variações mais suaves se comparada com a matriz em (b). Tal constatação justifica o nome do parâmetro L . Em ambos os casos os valores nos eixos x e y correspondem aos índices dos elementos da matriz de covariância estimada e o eixo z corresponde aos valores de tais elementos.

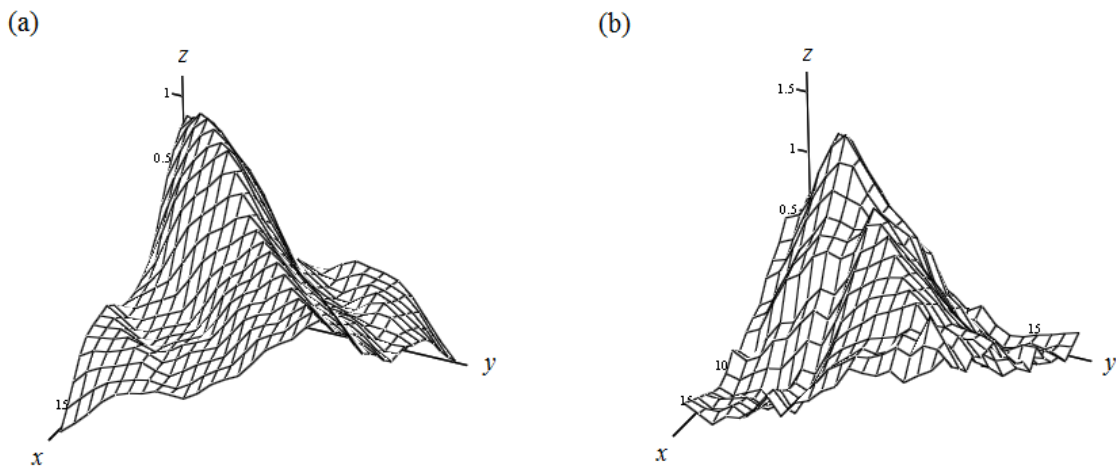


Figura 4.1 - Matriz de covariância por média amostral de ordem 20.

4.2.4 Método 4 de estimação da matriz de covariância por média amostral

Seja \mathbf{Y} uma matriz de ordem $m \times n$, como em (4.1). Seja L o fator de alisamento já definido. Neste contexto \mathbf{Y}_p representa uma matriz constituída pelas $L-1$ primeiras colunas de \mathbf{Y} . Define-se então \mathbf{Y}_s como a concatenação de \mathbf{Y} e \mathbf{Y}_p (extensão cíclica). Seja \mathbf{Y}_i uma matriz constituída pela coluna i até a coluna $i+L-1$ de \mathbf{Y}_s , $i=1,2,\dots,n$, como ilustrado no exemplo a seguir para $m=3$, $n=6$ e $L=3$:

$$\begin{aligned}
 i=1 \quad \mathbf{Y}_s &= \begin{bmatrix} \boxed{y_{11} \quad y_{12} \quad y_{13}} & y_{14} & y_{15} & y_{16} & y_{11} & y_{12} \\ y_{21} & y_{22} & y_{23} & y_{24} & y_{25} & y_{26} & y_{21} & y_{22} \\ y_{31} & y_{32} & y_{33} & y_{34} & y_{35} & y_{36} & y_{31} & y_{32} \end{bmatrix} \\
 &\quad \underbrace{\hspace{10em}}_{\mathbf{Y}_1} \\
 i=2 \quad \mathbf{Y}_s &= \begin{bmatrix} y_{11} & \boxed{y_{12} \quad y_{13} \quad y_{14}} & y_{15} & y_{16} & y_{11} & y_{12} \\ y_{21} & y_{22} & y_{23} & y_{24} & y_{25} & y_{26} & y_{21} & y_{22} \\ y_{31} & y_{32} & y_{33} & y_{34} & y_{35} & y_{36} & y_{31} & y_{32} \end{bmatrix} \\
 &\quad \underbrace{\hspace{10em}}_{\mathbf{Y}_2} \\
 &\quad \vdots \hspace{10em} \vdots \\
 i=n \quad \mathbf{Y}_s &= \begin{bmatrix} y_{11} & y_{12} & y_{13} & y_{14} & y_{15} & \boxed{y_{16} \quad y_{11} \quad y_{12}} \\ y_{21} & y_{22} & y_{23} & y_{24} & y_{25} & y_{26} & y_{21} & y_{22} \\ y_{31} & y_{32} & y_{33} & y_{34} & y_{35} & y_{36} & y_{31} & y_{32} \end{bmatrix} \\
 &\quad \underbrace{\hspace{10em}}_{\mathbf{Y}_n}
 \end{aligned} \tag{4.8}$$

A matriz de covariância estimada segundo o Método 4 é:

$$\mathbf{R}_{\mathbf{Y}_{s4}} = \frac{1}{n} \sum_{i=1}^n \mathbf{Y}_i \mathbf{Y}_i^\dagger. \tag{4.9}$$

Vale citar que as extensões cíclicas presentes em \mathbf{Y}_s em (4.6) e (4.8) são conhecidas como *padding* e que, alternativamente, poderia ser feito com zero (*zero padding*).

4.3 Influência do método de estimação da matriz de covariância por média amostral

Uma vez apresentadas as diferentes formas de se estimar a matriz de covariância por média amostral do sinal recebido, esta seção tem como objetivo investigar a influência do método de estimação utilizado no desempenho da técnica MED de sensoriamento espectral. Inicia-se a investigação considerando o cenário de

sensoriamento não cooperativo, para na sequência tratar-se do cenário de sensoriamento cooperativo. Das duas métricas utilizadas para análise de desempenho apresentadas na Seção 3.4 (P_{FA} e P_D), será considerado aqui como referência uma P_{FA} fixa (CFAR – *Constant False Alarm Rate*) de 0.1 (10%), por este valor estar de acordo com o requisito previsto no padrão IEEE 802.22 [12], e o valor de P_D será estimado para diferentes valores de relação sinal-ruído.

4.3.1 Sensoriamento espectral por máximo autovalor não cooperativo

O sensoriamento espectral não cooperativo, como brevemente comentado no Capítulo 2, é aquele onde o processo de detecção baseia-se na observação feita por um único Rádio Cognitivo. Neste contexto, o vetor \mathbf{Y} de dimensão $1 \times n$ definido em (4.3) representa o sinal recebido durante 1 período de sensoriamento, onde o parâmetro n representa o número de amostras coletadas pelo sensor:

$$\mathbf{Y} = [y_1 \quad y_2 \quad y_3 \quad \cdots \quad y_n] \rightarrow \text{amostras coletadas pelo Rádio Cognitivo (sensor).}$$

O cálculo de \mathbf{Y} é baseado na expressão (3.1), $\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{V}$. Considera-se aqui o seguinte modelo:

- \mathbf{V} : vetor de ruído de dimensão $1 \times n$. Cada elemento complexo v_j de \mathbf{V} representa a amostra de ruído considerada pelo receptor cognitivo no j -ésimo instante de observação, modelado como um ruído AWGN de média 0 e variância σ_v^2 .
- \mathbf{X} : matriz de sinal de dimensão $p \times n$. O parâmetro p representa o número de usuários primários que estão transmitindo cada um n amostras durante o período de sensoriamento. Sendo assim, cada elemento complexo x_{ij} de \mathbf{X} representa a amostra transmitida pelo i -ésimo usuário primário no j -ésimo instante de observação. Serão consideradas duas possibilidades: na primeira as amostras de \mathbf{X} são i.i.d. e na segunda as amostras de \mathbf{X} apresentam correlação temporal. Seja F um parâmetro aqui denominado de fator de correlação e \mathbf{X}_c uma matriz formada pela concatenação de \mathbf{X} com as F primeiras colunas de \mathbf{X} . A correlação temporal é estabelecida por uma filtragem do tipo Média Móvel dos elementos de \mathbf{X} , de acordo com [32]:

$$X^{(k)} = \frac{1}{\sqrt{F}} \sum_{j=k}^{k+F-1} X_c^{(j)}, \quad (4.10)$$

onde o termo $X^{(k)}$ representa a coluna k de \mathbf{X} e $X_c^{(j)}$ representa a coluna j de \mathbf{X}_c . A multiplicação pelo inverso da raiz quadrada de F torna-se necessária para que a potência do sinal antes e após o processo de filtragem permaneça a mesma.

- **H**: vetor do canal de comunicação de dimensão $1 \times p$. Cada elemento h_j de **H** representa o ganho existente entre o j -ésimo transmissor primário e o receptor cognitivo em questão, modelado como um processo Gaussiano complexo de média 0 e variância unitária (canal do tipo Rayleigh). Considera-se aqui que o canal não muda durante um período de sensoriamento.

Uma vez definido **Y**, o próximo passo consiste em calcular a matriz de covariância por média amostral. Consideram-se duas propostas: sensoriamento espectral não cooperativo com fator de alisamento e sensoriamento espectral não cooperativo sem fator de alisamento.

Na abordagem onde leva-se em consideração o fator de alisamento, como proposto em [33], utiliza-se o Método 3 de estimação da matriz de covariância por média amostral do sinal **Y** como descrito na Seção 4.2.3. Considerando a hipótese H_0 , determina-se através do programa em MATLAB presente no Apêndice 6 o valor de γ a fim de se atingir o valor de P_{FA} requerido. De posse do limiar γ e considerando a hipótese H_1 como referência, é possível através do programa em MATLAB presente no Apêndice 7 estimar o valor da probabilidade de detecção P_D em função da SNR considerada como dado de entrada. A Figura 4.2 apresenta os resultados obtidos para $p=1$, $P_{FA}=0.1$ (10%), $n=100$, $L=1, 2, 10, 20$ ou 40 e sinal transmitido com correlação temporal ($F=50$). Observa-se a partir da expressão (4.7) que para um $L=1$ tem-se como resultado um cálculo de energia assim como apresentado na expressão (2.4). Conclui-se neste caso que a técnica MED não cooperativa que utiliza o Método 3 de estimação da matriz de covariância apresenta melhor desempenho que o detector de energia, conforme sugerido em [20]. No entanto, em tal referência foram apresentados resultados para L fixo. Observa-se aqui que é possível obter-se maior ganho de desempenho à medida que se aumenta L . No entanto, nota-se também que o ganho obtido tende a ser menor para valores de L mais elevados. Foram investigados outros valores para n ($n=50$ e $n=200$), F (10, 20, 100) e p (2, 3) e o mesmo comportamento foi verificado.

É também sugerido em [20] que quando as amostras do sinal transmitido são i.i.d. a técnica de detecção de energia apresenta melhor desempenho que a técnica MED não cooperativa para o modelo considerado nesta seção. Ratifica-se tal conclusão a partir dos resultados apresentados na Figura 4.3. Nota-se também que neste caso o aumento de L foi prejudicial ao desempenho.




Figura 4.2 - Curvas de P_D para a técnica MED não cooperativa com fator de alisamento e sinal transmitido com amostras correlacionadas em comparação com a curva do detector de energia (ED).




Figura 4.3 - Curvas de P_D para a técnica MED não cooperativa com fator de alisamento e sinal transmitido com amostras i.i.d. em comparação com a curva do detector de energia (ED).

Na sequência analisa-se o que ocorre com o desempenho da técnica MED não cooperativa caso não seja utilizado o fator de alisamento no cálculo da matriz de covariância. Para tal propósito utiliza-se o Método 2 de estimação descrito na Seção 4.2.2. Através do programa em MATLAB presente no Apêndice 8 determina-se o limiar de decisão γ a fim de se atingir valor de P_{FA} requerido e a probabilidade de detecção P_D

estimada é obtida através do programa em MATLAB presente no Apêndice 9. A Figura 4.4 apresenta os resultados obtidos para $p=1$, $P_{FA}=0.1$ (10%), $n=100$ e $k=5$. Para as curvas que representam o sinal transmitido com correlação temporal utilizou-se $F=50$. Observa-se a partir da expressão (4.5) que para um $k=1$ tem-se como resultado um cálculo de energia assim como apresentado na expressão (2.4). Observa-se neste caso que para a detecção de energia não houve diferença de desempenho quando as amostras do sinal transmitido apresentaram correlação temporal ou não. Já para a técnica MED não cooperativa que utiliza o Método 2 de estimação da matriz de covariância notou-se diferença. Para o sinal transmitido com amostras i.i.d. foi possível obter-se melhor desempenho com o detector de energia. Tal constatação também foi observada para o caso apresentado no parágrafo anterior. Para o sinal transmitido com amostras correlacionadas observou-se praticamente o mesmo desempenho entre as duas técnicas. Neste caso, porém, esperava-se que a técnica MED não cooperativa apresentasse um melhor desempenho conforme resultados já apresentados na Figura 4.3, referente à técnica MED não cooperativa que utiliza fator de alisamento para o cálculo da matriz de covariância. Foram investigados outros valores de k ($k=10$, $k=20$) e os mesmos resultados foram observados. Neste caso conclui-se que sob o ponto de vista de desempenho é mais adequado utilizar o método de estimação da matriz de covariância que considera o fator de alisamento do que o método que não o considera.




Figura 4.4 - Curvas de P_D para a técnica MED não cooperativa sem fator de alisamento em comparação com a curva do detector de energia (ED) para sinal transmitido com amostras i.i.d. ou correlacionadas.

4.3.2 Sensoriamento espectral por máximo autovalor cooperativo

O sensoriamento espectral cooperativo, como brevemente comentado no Capítulo 2, é aquele onde mais de um Rádio Cognitivo participa do processo de

detecção. Neste contexto, a matriz \mathbf{Y} de dimensão $m \times n$ apresentada em (4.1) representa o sinal recebido durante 1 período de sensoriamento. O parâmetro m representa o número de usuários cognitivos que participarão do processo de detecção e o parâmetro n representa o número de amostras coletadas por cada rádio:

$$\mathbf{Y} = \begin{bmatrix} y_{11} & y_{12} & y_{13} & \cdots & y_{1n} \\ y_{21} & y_{22} & y_{23} & \cdots & y_{2n} \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ y_{m1} & y_{m2} & \cdots & \cdots & y_{mn} \end{bmatrix} \begin{array}{l} \rightarrow \text{amostras coletadas pelo Rádio Cognitivo 1} \\ \rightarrow \text{amostras coletadas pelo Rádio Cognitivo 2} \\ \vdots \\ \rightarrow \text{amostras coletadas pelo Rádio Cognitivo } m. \end{array}$$

O cálculo de \mathbf{Y} é também baseado na expressão (3.1), $\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{V}$. Considera-se aqui o seguinte modelo:

- \mathbf{V} : matriz de ruído de dimensão $m \times n$. Cada elemento complexo v_{ij} de \mathbf{V} representa a amostra de ruído considerada pelo i -ésimo receptor cognitivo no j -ésimo instante de observação, modelada como um ruído AWGN de média 0 e variância σ_v^2 .
- \mathbf{X} : matriz de sinal de dimensão $p \times n$. Segue o mesmo modelamento descrito na Seção 4.3.1.
- \mathbf{H} : matriz do canal de comunicação de dimensão $m \times p$. Cada elemento h_{ij} de \mathbf{H} representa o ganho existente entre o j -ésimo transmissor primário e o i -ésimo receptor cognitivo e é modelado como um processo Gaussiano complexo de média 0 e variância unitária (canal do tipo Rayleigh). Considera-se aqui que o canal não muda durante um período de sensoriamento, embora cada receptor cognitivo observe uma resposta diferente.

Uma vez definido \mathbf{Y} , o próximo passo consiste em calcular a matriz de covariância por média amostral de tal sinal. Consideram-se duas propostas: sensoriamento espectral cooperativo sem fator de alisamento e sensoriamento espectral cooperativo com fator de alisamento.

Na abordagem onde não se leva em consideração o fator de alisamento utiliza-se o Método 1 de estimação descrito na Seção 4.2.1. Considerando a hipótese H_0 , determina-se através do programa em MATLAB presente no Apêndice 10 o valor de γ a fim de se atingir o valor de P_{FA} requerido. De posse do limiar γ e considerando a hipótese H_1 com referência é possível através do programa em MATLAB presente no Apêndice 11 estimar o valor da probabilidade de detecção P_D em função da SNR considerada como dado de entrada. A Figura 4.5 apresenta os resultados obtidos para $p=1$, $P_{FA}=0.1$ (10%), $m=5$, $n=10, 20$ ou 40 e $F=5$. Nota-se que não há diferença de desempenho quando o sinal transmitido apresenta distribuição i.i.d. e quando há

correlação temporal entre suas amostras para os diferentes pares de (m,n) analisados. Foram investigados outros valores para F ($F=2, 4, 10, 20$ ou 40) e p (2, 3) e o mesmo comportamento foi observado.




Figura 4.5 - Curva de P_D versus SNR para o sensoriamento espectral cooperativo sem fator de alisamento.

Na sequência analisa-se o que ocorreria com o desempenho da técnica MED cooperativa caso seja utilizado o fator de alisamento no cálculo da matriz de covariância por média amostral do sinal recebido. Para tal propósito, utiliza-se o Método 4 de estimação descrito na Seção 4.2.4. Através do programa em MATLAB presente no Apêndice 12 determina-se o limiar de decisão γ a fim de se atingir valor de P_{FA} requerido e a probabilidade de detecção P_D estimada é obtida através do programa em MATLAB presente no Apêndice 13. A Figura 4.6 apresenta os resultados obtidos para $p=1$, $P_{FA}=0.1$ (10%), $m=5$, $n=20$, $L=4$ ou 12 e $F=5$. Assim como comentado no parágrafo anterior, nota-se novamente que não há diferença de desempenho quando o sinal transmitido apresenta distribuição i.i.d. e quando há correlação temporal entre suas amostras. Observa-se também que o fator de alisamento não causa nenhum impacto. Foram investigados outros valores para F ($F=2, 5, 10, 20$ ou 40), para n ($n=10$ e $n=40$) e para p (2, 3) e o mesmo comportamento foi observado. Desta maneira, conclui-se que no cenário de sensoriamento espectral por máximo autovalor cooperativo é mais adequado utilizar o método de estimação da matriz de covariância que não considera o fator de alisamento do que o método que o considera.




Figura 4.6 - Curvas de P_D versus SNR para o sensoriamento espectral cooperativo com fator de alisamento.

Para finalizar esta seção, resta mais um comentário a respeito da Figura 4.5 já apresentada. Observa-se que é possível obter uma maior probabilidade de detecção à medida que se aumenta o número de amostras coletadas n . Por exemplo, para uma SNR=-5dB observa-se um $P_D=0.75$ para $n=10$ e um $P_D=0.88$ para $n=20$. Tal questão será melhor investigada na próxima seção.

4.4 Influência do número de amostras coletadas no desempenho da técnica MED

Como apresentado na seção anterior, é possível obter uma melhor probabilidade de detecção P_D à medida que se aumenta o número de amostras coletadas n . A fim de melhor investigar tal afirmação, uma opção seria selecionar um determinado valor de SNR, uma específica quantidade m de Rádios Cognitivos que participarão do processo de detecção e então variar n observando qual o impacto de tais escolhas na probabilidade de detecção do algoritmo. Vale lembrar que para cada situação analisada deve-se considerar um valor de P_{FA} fixo a fim de promover justiça na comparação do valor de P_D obtido para cada valor de n considerado. O valor de P_{FA} fixo é obtido fazendo um ajuste no limiar de decisão γ à medida que se varia n . Através do programa em MATLAB presente no Apêndice 10 determina-se o limiar de decisão γ a fim de se atingir valor de P_{FA} desejado e a probabilidade de detecção P_D estimada pode ser obtida através do programa em MATLAB presente no Apêndice 11. A Figura 4.7 apresenta os resultados obtidos para SNR=-5dB, $m=5$, $P_{FA}=0.1$ (10%) e $n=1,5,10,\dots,40$. Considerou-se um cenário constituído de um único transmissor primário ($p=1$). Observa-se, como esperado, que à medida que se aumenta o número de amostras n

consideradas no processo de sensoriamento espectral, tem-se um aumento na probabilidade de detecção do algoritmo. Porém, nota-se também que a diferença entre o valor de P_D para n amostras e o valor de P_D para $n - x$ amostras com $n > x$ torna-se cada vez menor à medida que se aumenta n , mantendo a relação $n-x$ fixa. Observe, por exemplo, que aumentando n de 5 para 10 tem-se um aumento de P_D de aproximadamente 20%. No entanto, aumentando n de 10 para 15 o aumento de P_D é reduzido para 8%, aproximadamente. Conclui-se desta maneira que chega-se a um ponto onde a melhora de desempenho não justifica o aumento de carga computacional do receptor devido à necessidade de se processar mais amostras.




Figura 4.7 - Curva de P_D versus n para um sensoriamento espectral cooperativo por máximo autovalor.

4.5 Análise da distribuição do máximo autovalor sob a hipótese H_1

O objetivo dessa seção é encontrar a distribuição de probabilidade do máximo autovalor da matriz de covariância do sinal recebido sob a hipótese H_1 , ou seja, considerando o caso onde o Rádio Cognitivo recebe sinal mais ruído. Como comentado no Capítulo 2, não há solução analítica geral presente na literatura para tal propósito, já que para determinar a distribuição do máximo autovalor dever-se-ia conhecer as características do sinal e do canal de comunicação. Desta maneira propõe-se determinar a distribuição de λ_{\max} de maneira empírica. O conhecimento de tal distribuição é importante porque através dela é possível computar a probabilidade de detecção do algoritmo de maneira teórica. Existe em [27] uma proposta para o cálculo de P_D . No entanto, trata-se de uma análise assintótica, logo não realista. Desta maneira, através do procedimento que será apresentado neste capítulo torna-se possível determinar uma expressão de P_D versus γ válida para valores práticos de m , n e SNR.

Antes de apresentar o procedimento utilizado para obter a distribuição de λ_{\max} sob a hipótese H_1 , serão abordados no próximo subitem conceitos preliminares sobre o teste de aderência (*goodness-of-fit*) de Kolmogorov-Smirnov [34].

4.5.1 O teste de Kolmogorov-Smirnov

Com base em um conjunto de dados provenientes da observação de uma variável aleatória X qualquer, é possível selecionar uma distribuição de probabilidade teórica que a represente. A fim de comprovar se a seleção foi feita de forma adequada, é possível utilizar, dentre outros, o teste de aderência de Kolmogorov-Smirnov.

Seja $F(x)$ a distribuição de probabilidade cumulativa teórica assumida para os dados estudados e $F_N(x)$ a distribuição de probabilidade cumulativa definida como:

$$F_N(x) = \frac{1}{N} \sum_{i=1}^N (I_{x_i} \leq x), \quad (4.11)$$

onde x_i representa a observação i , $i=1,2,\dots,N$, da variável aleatória X em questão e $I_{x_i} \leq x$ é a função indicadora igual a 1 se $x_i \leq x$ e igual a 0 caso contrário.

Define-se então a estatística do teste de Kolmogorov-Smirnov como a máxima distância vertical entre os gráficos da função teórica $F(x)$ e empírica $F_N(x)$ nos pontos x_i e x_{i-1} como expresso abaixo:

$$D = \max_{1 \leq i \leq N} [F(x_i) - F_N(x_{i-1}), F_N(x_i) - F(x_i)], \quad (4.12)$$

Desta maneira, existem duas hipóteses:

- H_A : a distribuição selecionada representa os dados de forma adequada.
- H_B : a distribuição selecionada não representa os dados de forma adequada.

Quando $N > 40$, a hipótese H_A será rejeitada se D for maior que o valor crítico apresentado na Tabela 4.1 para diferentes níveis de significância α_{KS} . Para valores de N menores ou iguais a 40 o princípio é mesmo, porém os valores críticos podem ser obtidos através da tabela disponível em [35].

Tabela 4.1 – Valores críticos para a estatística de teste D quando $N > 40$.

α_{KS}	0.2	0.1	0.05	0.02	0.01
Valor crítico	$\frac{1.07}{\sqrt{N}}$	$\frac{1.22}{\sqrt{N}}$	$\frac{1.36}{\sqrt{N}}$	$\frac{1.52}{\sqrt{N}}$	$\frac{1.63}{\sqrt{N}}$

Caso D seja menor que o valor crítico considerado, conclui-se que os dados analisados seguem a distribuição estipulada com $(1-\alpha_{KS}) \cdot 100\%$ de confiança.

A Figura 4.8 ilustra duas possíveis situações onde se tem um bom e um mau ajuste entre a curva empírica (curva em escada) e a curva teórica (curva contínua).

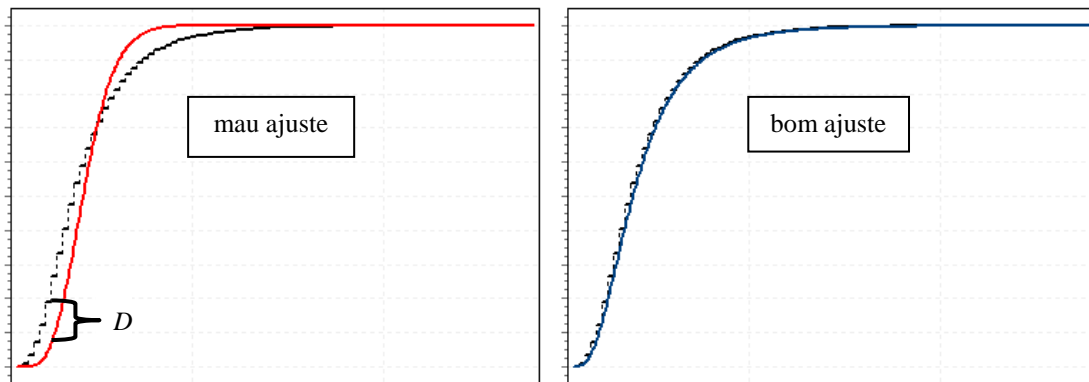


Figura 4.8 - Ilustração de curvas de distribuição de probabilidade cumulativa empírica (curvas em escada) e teórica (curvas contínuas) para um bom e mau ajuste.

4.5.2 Procedimentos para se obter a distribuição de λ_{\max} sob H_1

A Figura 4.9 representa o fluxograma do processo que foi utilizado para determinar a distribuição de λ_{\max} sob a hipótese H_1 para um valor específico de m (número de Rádios Cognitivos que participa do processo de sensoriamento), n (número de amostras coletadas por cada Rádio Cognitivo) e SNR (relação sinal-ruído considerada). De posse destes 3 parâmetros gerou-se a matriz do sinal transmitido \mathbf{X} , a matriz de ruído \mathbf{V} e a matriz do canal de comunicação \mathbf{H} segundo o modelo apresentado na Seção 4.3.2. O sinal recebido \mathbf{Y} foi composto a partir da expressão (3.1) e a matriz de covariância por média amostral de tal sinal foi determinada através do Método 1 de estimação descrito na Seção 4.2.1. A partir de tal matriz, extraiu-se seu máximo autovalor, representando este a primeira observação da variável aleatória λ_{\max} . Repetindo o processo N vezes obteve-se então uma amostra de tamanho N da variável aleatória λ_{\max} . Baseado em tal amostra, calculou-se sua distribuição de probabilidade cumulativa empírica como descrito no subitem anterior. Desta maneira, através do teste de Kolmogorov-Smirnov foi possível selecionar dentre uma lista de distribuições de

probabilidade teóricas conhecidas, aquelas que representaram os dados analisados de maneira mais adequada.

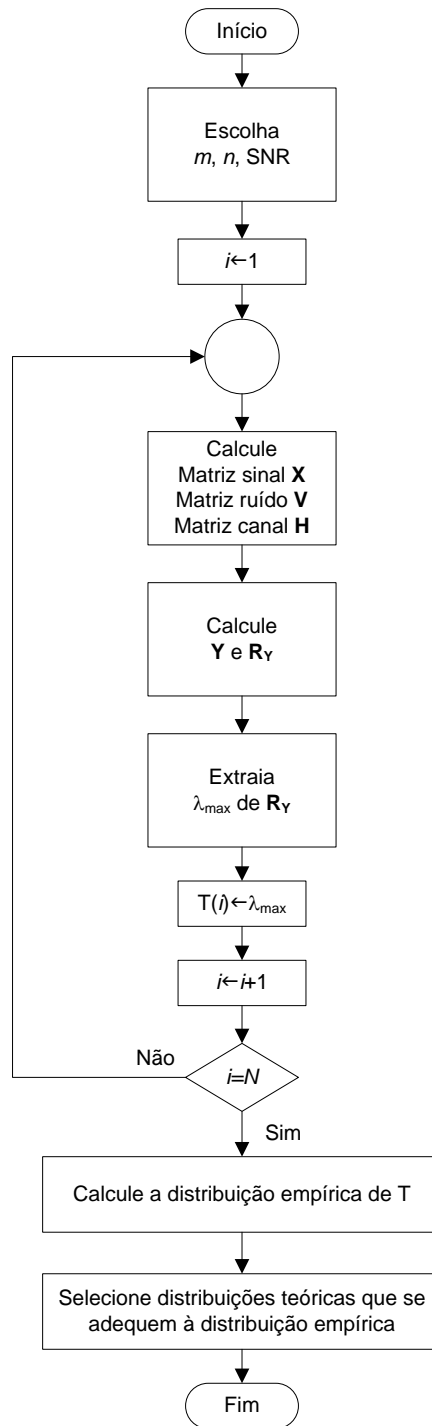


Figura 4.9 - Fluxograma do processo para se obter a distribuição de λ_{max} sob a hipótese H_1 para um valor específico de m , n e SNR .

O algoritmo descrito no parágrafo anterior foi repetido para diferentes valores de m , n e SNR e os resultados obtidos são apresentados na próxima seção.

4.5.3 Execução do procedimento para se obter a distribuição de λ_{\max} sob H_1

O procedimento descrito no subitem anterior foi executado para os diferentes valores de m , n e SNR representados na Tabela 4.2 a seguir.

Tabela 4.2 - Valores de m , n e SNR utilizados para se determinar a distribuição empírica de λ_{\max} .

m	2	3	4	5	2	3	4	5	2	3	4	5	2	3	4	5
n	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
SNR	-20	-20	-20	-20	-10	-10	-10	-10	0	0	0	0	10	10	10	10
m	2	3	4	5	10	10	10	20	20	20						
n	5	5	5	5	10	10	10	20	20	20						
SNR	20	20	20	20	0	-20	20	0	-20	20						

Através do programa em MATHCAD presente no Apêndice 14 obteve-se uma amostra de tamanho N da variável aleatória λ_{\max} para cada combinação de m , n e SNR considerada. Adotou-se um cenário constituído por um único usuário primário ($p=1$) e $N=5000$. Para se calcular a distribuição de probabilidade empírica de cada amostra e posteriormente atribuir a cada uma um conjunto de distribuições de probabilidade teóricas que as descrevem de maneira adequada, utilizou-se o programa EASYFIT [36]. A Figura 4.10 representa um *print screen* de uma janela de resultados de tal programa quando considerou-se como dado de entrada as amostras da variável aleatória λ_{\max} para os valores de $m=3$, $n=5$ e SNR=0dB, por exemplo. A tabela apresentada em tal figura representa um conjunto de distribuições classificadas quanto à similaridade em relação à distribuição de probabilidade empírica considerada, medida através da estatística de teste D do algoritmo de Kolmogorov-Smirnov apresentada na terceira coluna. Na primeira coluna é apresentado o número de identificação da distribuição teórica e na segundo o seu nome.

#	Distribution	Kolmogorov Smirnov	
		Statistic	Rank
38	Log-Pearson 3	0.00865	1
47	Pearson 6	0.00924	2
30	Johnson SB	0.0094	3
46	Pearson 5 (3P)	0.01017	4
48	Pearson 6 (4P)	0.01024	5
41	Lognormal (3P)	0.01106	6
35	Log-Gamma	0.01165	7
21	Gen. Extreme Value	0.01197	8
18	Frechet (3P)	0.0141	9
29	Inv. Gaussian (3P)	0.01456	10

Figura 4.10 - Print Screen de uma janela de resultados do programa EASYFIT.

Como foram considerados 26 diferentes valores de m , n e SNR, foram obtidas 26 listas semelhantes à apresentada na Figura 4.10 anterior. Baseado em tais listas fez-se o levantamento apresentado na Tabela 4.3. A parte (a) representa uma contagem do número de vezes que cada distribuição teórica foi classificada em primeiro lugar, em segundo lugar e assim sucessivamente até o décimo lugar nas 26 listas. Na parte (b) repetiu-se o processo de contagem, porém considerando classificações do primeiro ao quinto lugar. Observou-se que nas duas partes a distribuição Log-Pearson 3 apareceu mais vezes entre as primeiras colocadas. Conclui-se desta maneira que tal distribuição representa uma boa estimativa para a distribuição do máximo autovalor λ_{\max} sob a hipótese H_1 para os casos estudados.

Tabela 4.3 - Listas ordenadas das distribuições teóricas que mais se assemelham com a distribuição empírica de λ_{\max} para os casos de m , n e SNR investigados.

(a)	1	2	3	4	5	6	7	8	9	10	
Log Pearson 3	3	3	8	3	2	1	2	3	0	0	25
Pearson 6	0	2	5	0	4	2	0	1	5	2	21
Fatigue life 3P	4	1	4	3	0	2	2	1	2	1	20
Lognormal	1	0	0	4	3	4	5	1	2	0	20
Johnson SB	4	1	3	5	3	0	0	2	0	1	19
Gen. Gamma	3	7	1	2	2	0	1	1	1	0	18
Pearson 6	0	4	0	1	0	3	2	3	3	1	17
Pearson 5	2	3	0	1	1	0	0	1	1	5	14
GEV	2	0	2	0	2	1	1	4	0	1	13
Inv. Gaussian	1	2	1	1	2	3	0	0	1	2	13
Burr	1	2	0	1	1	0	0	4	0	2	11
Gamma	0	0	1	1	2	0	1	1	2	2	10
Beta	2	0	0	1	1	0	1	0	0	1	6
Gen. Gamma	0	0	0	0	0	0	2	0	3	0	5
Dagum	0	0	0	0	0	2	0	0	1	2	5
Burr	0	0	0	0	0	0	4	1	0	0	5
Gamma	0	0	0	0	1	2	0	0	0	1	4
Johnson SU	1	0	0	1	0	0	0	1	0	1	4
Log Gamma	0	0	0	0	0	2	2	0	0	0	4
Lognormal	0	0	0	0	0	1	0	0	2	1	4
Log Logistic	0	0	0	0	0	0	1	1	1	0	3
Frechet	0	0	0	0	0	0	1	0	1	1	3
Gen. Pareto	1	0	0	0	1	0	0	0	0	0	2
Pareto 2	0	0	1	0	0	0	0	0	0	0	1
Weibull	0	0	0	1	0	0	0	0	0	0	1
Weibull	0	0	0	0	0	0	0	0	0	1	1
Erlang	0	0	0	0	0	1	0	0	0	0	1

(b)	1	2	3	4	5	
Log Pearson 3	3	3	8	3	2	19
Johnson SB	4	1	3	5	3	16
Gen. Gamma	3	7	1	2	2	15
Fatigue life 3P	4	1	4	3	0	12
Pearson 6	0	2	5	0	4	11
Lognormal	1	0	0	4	3	8
Pearson 5	2	3	0	1	1	7
Inv. Gaussian	1	2	1	1	2	7
GEV	2	0	2	0	2	6
Pearson 6	0	4	0	1	0	5
Burr	1	2	0	1	1	5
Gamma	0	0	1	1	2	4
Beta	2	0	0	1	1	4
Johnson SU	1	0	0	1	0	2
Gen. Pareto	1	0	0	0	1	2
Gamma	0	0	0	0	1	1
Pareto 2	0	0	1	0	0	1
Weibull	0	0	0	1	0	1
Gen. Gamma	0	0	0	0	0	0
Dagum	0	0	0	0	0	0
Burr	0	0	0	0	0	0
Log Gamma	0	0	0	0	0	0
Lognormal	0	0	0	0	0	0
Log Logistic	0	0	0	0	0	0
Frechet	0	0	0	0	0	0
Weibull	0	0	0	0	0	0
Erlang 3P	0	0	0	0	0	0

4.5.4 Cálculo de P_D versus γ baseado na distribuição Log-Pearson 3

O objetivo desta seção é apresentar uma expressão que relaciona a probabilidade de detecção P_D com o limiar de decisão γ . A base de tal cálculo é a distribuição do máximo autovalor da matriz de covariância do sinal recebido sob a hipótese H_1 , estimada aqui como uma distribuição Log-Pearson 3, cuja função densidade de probabilidade é dada por [37]:

$$f(x) = \frac{1}{x|b|\Gamma(a)} \left(\frac{\ln(x) - c}{b} \right)^{a-1} \exp\left(-\frac{\ln(x) - c}{b} \right), \quad (4.13)$$

onde a , b e c são respectivamente os parâmetros de forma, escala e posição de tal distribuição.

Conforme apresentado no Capítulo 3:

$$P_D = \Pr[T_{MED} > \gamma | H_1]. \quad (4.14)$$

Mas $T_{MED} = \lambda_{\max} / \sigma_v^2$ como definido em (3.20). Assim tem-se:

$$P_D = \Pr[T_{MED} > \gamma | H_1] = \Pr\left[\frac{\lambda_{\max}}{\sigma_v^2} > \gamma | H_1 \right] = \Pr[\lambda_{\max} > \gamma \sigma_v^2 | H_1]. \quad (4.15)$$

A partir de (4.13) é possível reescrever (4.15) como:

$$P_D = \int_{\gamma \sigma_v^2}^{\infty} \frac{1}{x|b|\Gamma(a)} \left(\frac{\ln(x) - c}{b} \right)^{a-1} \exp\left(-\frac{\ln(x) - c}{b} \right) dx, \quad (4.16)$$

o que resulta em:

$$P_D = \frac{\Gamma(a, (\ln(\gamma \sigma_v^2) - g)/b)}{\Gamma(a)}. \quad (4.17)$$

A Tabela 4.4 representa 3 valores de m , n e SNR com a respectiva relação com os parâmetros a , b e c da distribuição Log-Pearson 3.

A Figura 4.11 representa o histograma das amostras de λ_{\max} para os valores de $m=3$, $n=5$ e $SNR=0dB$ sobreposta à função densidade de probabilidade da distribuição de Log-Pearson 3 correspondente. Tal resultado ratifica a conclusão apresentada no subitem anterior que a distribuição Log-Pearson 3 representa a distribuição de λ_{\max} sob H_1 de forma adequada.

Finalmente a Figura 4.12 traz a relação P_D versus γ para os 3 valores de m , n e SNR apresentados na Tabela 4.4. As curvas tracejada, pontilhada e contínua representam o cálculo teórico realizado através da expressão (4.16) e os quadrados, círculos e losangos correspondem a resultados da simulação de Monte Carlo presente no Apêndice 11. Observa-se que há uma grande aderência entre os resultados teóricos e aqueles obtidos por simulação. Sendo assim, pode-se considerar que o processo utilizado para se determinar a expressão teórica de P_D versus γ está correto e que se pode confiar nos resultados obtidos.

Tabela 4.4 - Alguns valores de m , n e SNR com a respectiva relação com os parâmetros a , b e c da distribuição Log-Pearson 3.

m	n	SNR	a	b	c
2	5	0	110.87	0.05098	-2.9981
3	5	0	117.39	0.04581	-2.3863
4	5	0	70.02	0.05724	-0.7596

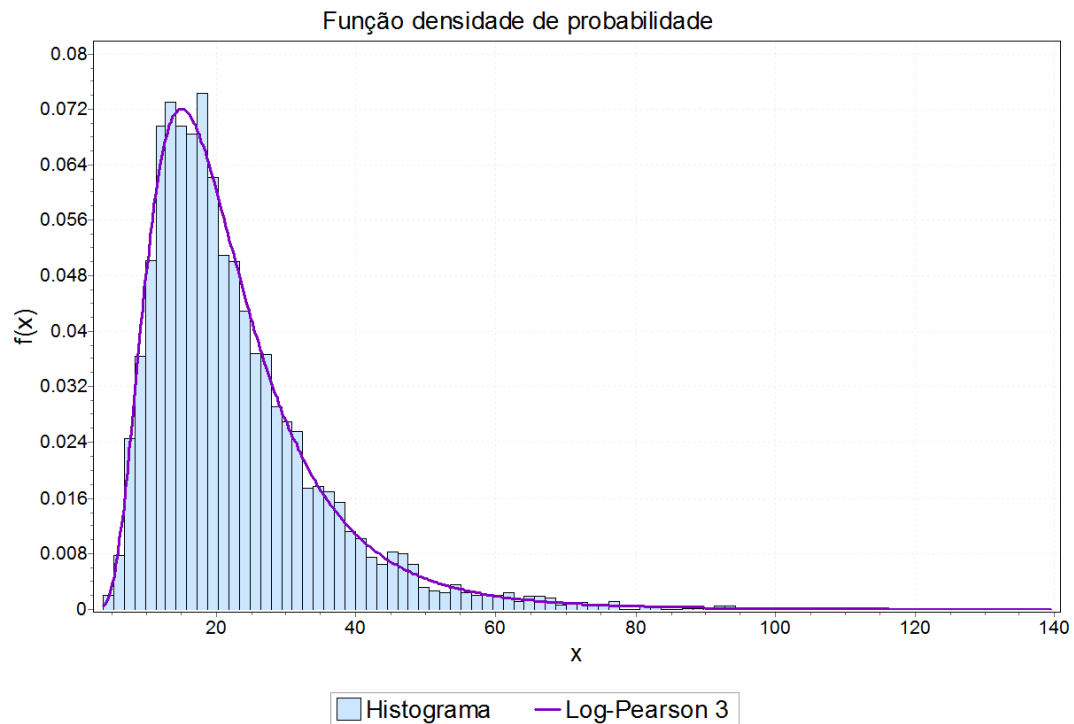


Figura 4.11 - Histograma da amostra de λ_{\max} para os valores de $m=3$, $n=5$ e $SNR=0dB$ sobreposta a função densidade de probabilidade da distribuição de Log-Pearson 3 correspondente.

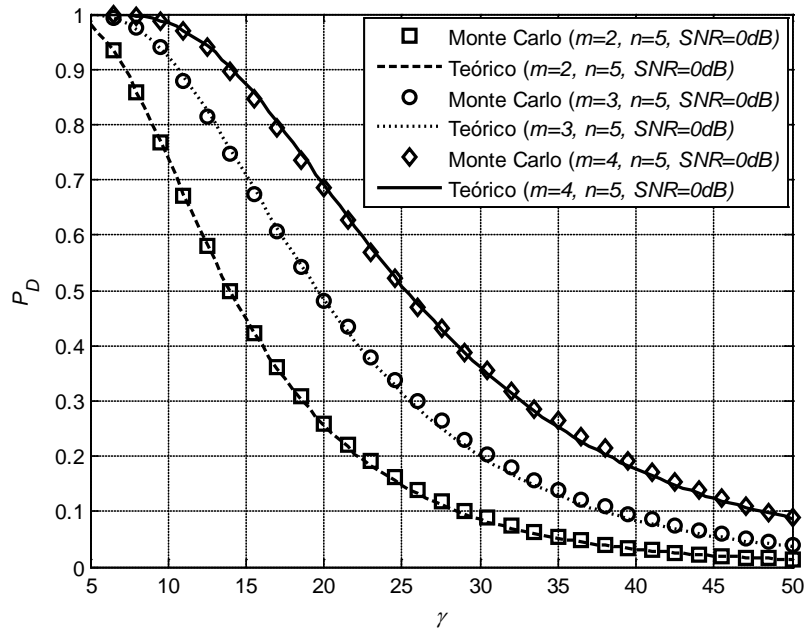


Figura 4.12 – Valores de γ e P_D teóricos e obtidos por simulação.

CAPÍTULO 5 – CONCLUSÕES

Diante do cenário de escassez espectral resultante da política de alocação fixa adotada pelos órgãos regulatórios, pesquisas foram feitas e observou-se que embora a maior parte do espectro de frequência já esteja alocada, existe considerável subutilização. Neste contexto surgiu o Rádio Cognitivo, uma revolucionária tecnologia que espera-se ser o novo *Big Bang* em comunicações sem fio. Dentre suas funções, o sensoriamento espectral é a principal tarefa a ser executada.

O Capítulo 2 ressaltou inicialmente que dentre os diferentes métodos apresentados a fim de se identificar as oportunidades de transmissão, o sensoriamento espectral é o mais atrativo, pois não depende da participação dos usuários primários para determinar se o canal analisado está ocupado ou não. Também pôde ser concluído neste capítulo que sistemas que utilizam Rádio Cognitivo devem ser implementados com dispositivos que operem em faixas largas e com processadores de alta velocidade, já que quanto maior a banda de frequência sensoriada e quanto mais rápido for o processamento das informações coletadas, mais oportunidades de transmissão poderão ser encontradas. A periodicidade que o sensoriamento é executado depende das características dos sinais primários observados e, para se evitar o problema da redução de eficiência de transmissão causado pelas interrupções nas transmissões do usuário secundário nos momentos que o sensoriamento é executado, foi sugerido em [15] uma arquitetura constituída de 2 rádios: um somente para sensoriar e um somente para transmitir. A fim de mitigar o problema do usuário oculto considera-se a utilização do sensoriamento espectral cooperativo, onde mais de um usuário cognitivo participa do processo de detecção. Na sequência foram apresentadas as principais técnicas de sensoriamento espectral presente na literatura. Foi observado que, devido ao fato de não necessitarem de nenhuma informação *a priori* sobre o sinal primário a ser detectado, a técnica baseada em detecção de energia e a técnica baseada em autovalores tornaram-se muito atrativas para implementação em Rádios Cognitivos.

No Capítulo 3 foi apresentado um estudo detalhado sobre o sensoriamento baseado nos autovalores da matriz de covariância do sinal recebido. Neste capítulo foram definidas as estatísticas de teste utilizadas para se decidir sobre a existência ou ausência do sinal primário na banda de frequência analisada, bem com as métricas utilizadas para análise de desempenho: probabilidade de detecção P_D e probabilidade de falso alarme P_{FA} . Foi observado que, embora seja desejado o maior valor de probabilidade de detecção e o menor valor de probabilidade de falso alarme possível, tais objetivos são conflitantes e dependem do limiar de decisão γ que foi ajustado. Para se obter uma menor P_{FA} , o valor do limiar γ deve ser aumentado. Para se aumentar P_D , o valor do limiar de decisão γ deve ser diminuído. Uma solução consiste em determinar o valor de γ a fim de atender a um requisito de P_{FA} ou de P_D . O enfoque principal deste

trabalho foi a investigação da técnica de sensoriamento baseada no máximo autovalor da matriz de covariância do sinal recebido. Neste sentido foram apresentadas duas diferentes formas de determinação do limiar de decisão de maneira analítica em função da probabilidade de falso alarme requerida: uma considerando uma análise assintótica e a outra uma análise não assintótica. A expressão obtida ao considerar análise assintótica apresenta a limitação de ser válida somente para altos valores de m e n . Tal situação traduz-se na prática em um grande tempo de sensoriamento e maior complexidade do receptor devido à necessidade de processar matrizes de covariância de ordem elevada. Para o cálculo da expressão obtida através de uma análise não assintótica, os autores em [26] propõem a utilização de um programa em MATLAB presente em [30]. Tal rotina foi testada e observou-se uma limitação para certos valores de m e n . A fim de contornar este problema, foi proposta uma forma de determinação do limiar de decisão através de um processo de simulação de Monte Carlo.

O Capítulo 4 iniciou-se apresentando 4 diferentes formas de se estimar a matriz de covariância do sinal recebido. Após a definição do Método 2 e 3 de estimação, foi possível constatar que o parâmetro L definido em [20] é chamado de fator de alisamento, pois sua utilização resulta em uma suavização das variações da matriz de covariância estimada. Na sequência foi avaliado, através de simulações, a influência do método de estimação no desempenho da técnica de sensoriamento empregada. Neste sentido, fixou-se uma P_{FA} alvo de 0.1 e o valor de P_D foi investigado para diferentes situações. Num primeiro momento foi possível constatar que o desempenho da técnica de sensoriamento espectral baseada no máximo autovalor e não cooperativa é influenciado pelo fato do sinal transmitido apresentar ou não correlação temporal entre suas amostras. Para sinal transmitido com amostras correlacionadas conclui-se que com a utilização do método de estimação da matriz de covariância do sinal recebido que considera o fator de alisamento é possível obter melhor resultado em termos de probabilidade de detecção do que com a utilização do método de estimação que não o considera. Neste caso observou-se que a melhora de desempenho obtida à medida que se aumenta o valor de L tende a ser menor para valores de L mais elevados. Para sensoriamento cooperativo foi constatado que o desempenho da técnica baseada em máximo autovalor não é influenciado pelo fato do sinal transmitido apresentar ou não correlação temporal. Também foi possível concluir que, neste cenário, é mais adequado utilizar o método de estimação da matriz de covariância que não considera o fator de alisamento, já que a utilização deste fator não representou nenhuma influência no desempenho para os casos estudados. Com relação à influência do número de amostras coletadas, concluiu-se que é possível obter melhora na probabilidade de detecção à medida que se aumenta o número de amostras n consideradas no processo de sensoriamento espectral. Porém, nota-se também que a diferença entre o valor de P_D para n amostras e o valor de P_D para $n - x$ amostras com $n > x$ torna-se cada vez menor à medida que se aumenta n e mantém-se a relação $n - x$ fixa, chegando-se em um ponto em que a melhora de desempenho não justifica o aumento de complexidade do receptor devido à necessidade de se processar mais amostras. Finalizou-se o capítulo com o procedimento proposto para se determinar a distribuição do máximo autovalor da matriz

de covariância para o caso onde o Rádio Cognitivo recebe sinal mais ruído, isto é, sob a hipótese H_1 , já que não há solução presente na literatura para tal propósito. Concluiu-se, com o auxílio do teste de aderência de Kolmogorov-Smirnov, que a distribuição Log-Pearson 3 é uma boa estimativa para a distribuição do máximo autovalor sob a hipótese H_1 para os casos estudados. Através de tal distribuição foi possível determinar uma expressão que relaciona P_D com o limiar de decisão γ .

Como perspectivas para trabalhos futuros ficam as seguintes propostas:

- Encontrar uma relação entre os parâmetros da distribuição Log-Pearson 3 e os seguintes parâmetros de projeto: número de rádios que participarão do processo de detecção, número de amostras coletadas por cada rádio e SNR.
- Estender as investigações sobre a distribuição do máximo autovalor sob a hipótese H_1 para o cenário onde tem-se $p > 1$.
- Avaliar o que ocorrerá com o desempenho do algoritmo de detecção caso o canal de comunicação varie durante o período de sensoriamento.
- Promover investigações considerando que o canal de comunicação seja do tipo Nakagami, Rice ou α - μ .

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] S. Haykin, “Communication Systems”, John Wiley, New York, 2001.
- [2] IBPT, Anatel encerra leilão de celular 3G com arrecadação de R\$ 5,338 bilhões. Available at: http://www.ibpt.com.br/home/publicacao.view.php?publicacao_id=3523&pagina=9804 (last access: on July 2011).
- [3] C. Cordeiro, et al., “Spectrum Sensing for Dynamic Spectrum Access of TV Bands” (invited paper), in 2nd Int. Conference on Cognitive Radio Oriented Wireless Networks and Communications, 2007.
- [4] M. A. McHenry, P. A. Tenhula and D. McCloskey, “Chicago Spectrum Occupancy Measurements & Analysis and a Long-term Studies Proposal”, Shared Spectrum Co. Report, November 2005.
- [5] Federal Communications Commission, “Spectrum policy task force report, FCC 02-155”, November 2002.
- [6] M. H. Islam, C. L. Koh, S. W. Oh, et al., “Spectrum survey in Singapore: occupancy measurements and analysis,” in Proceedings of the 3rd International Conference on Cognitive Radio Oriented Wireless Networks and Communications (CROWNCOM '08), Singapore, May 2008.
- [7] Y. Zeng, et al., “A Review on Spectrum Sensing for Cognitive Radio: Challenges and Solutions”, EURASIP Journal on Advances in Signal Processing, vol. 2010.
- [8] J. Mitola, and G. Q. Maguire, “Cognitive radio: making software radios more personal,” IEEE Personal Communications, vol. 6, no. 4, pp. 13-18, 1999.
- [9] S. Haykin, “Cognitive radio: Brain-empowered wireless communications”, IEEE J. Sel. Areas Commun., vol. 23, no. 2, pp. 201–220, Feb. 2005.
- [10] Federal Communications Commission, “Notice of proposed rule making and order, FCC 03-222”, December 2003.
- [11] I. F. Akyildiz, W. Y. Lee, M. C. Vuran, and S. Mohanty, “Next generation/dynamic spectrum access/cognitive radio wireless networks: a survey,” Computer Networks Journal, vol. 50, no.13, pp. 2127–2159, 2006.
- [12] C. Cordeiro, et al., “IEEE 802.22: The First Worldwide Wireless Standard based on Cognitive Radios”, In: Proc. of the IEEE DySPAN, Nov. 2005.
- [13] 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.

- [14] A. Ghasemi, and E. S. Sousa, "Spectrum Sensing in Cognitive Radio Networks: Requirements, Challenges and Design Trade-offs", *IEEE Comm. Magazine*, pp. 32-39, April 2008.
- [15] C. S. SHANKAR, C. Cordeiro and K. CHALLAPALI, "Spectrum agile radios: utilization and sensing architectures", *Proc. IEEE Int. Symposium on New Frontiers in Dynamic Spectrum Access Networks*, p. 160–169, 2005.
- [16] H. Arslan (Ed.), "Cognitive Radio, Software Defined Radio, and Adaptive Wireless Systems", Springer-Verlag: Dordrecht, The Netherlands, 2007.
- [17] D. A. Guimarães, "Digital Transmission", Springer-Verlag: Dordrecht, Berlin, 2009.
- [18] D. Cabric, A. Tkachenko, R. W. Brodersen, "Spectrum Sensing Measurements of Pilot, Energy, and Collaborative Detection", *Military Communication Conference (MILCOM)*, October 2006.
- [19] P. P. Hoseini, and N. C. Beaulieu, "Optimal Wideband Spectrum Sensing Framework for Cognitive Radio Systems", *IEEE Transactions on Signal Processing*, vol. 59, no. 3, March 2011.
- [20] Y. Zeng, C. L. Koh, and Y. C. Liang, "Maximum Eigenvalue Detection- Theory and Application", In: *Proc. of the IEEE ICC 2008*.
- [21] A. Kortun, T. Ratnarajah, M. Sellathurai, C. Zhong and C. B. Papadias, "On the Performance of Eigenvalue-based Spectrum Sensing for Cognitive Radio", In: *Proc. of the IEEE DySPAN, 2010*.
- [22] B. Noble and J. W. Daniel, "Applied Linear Algebra", 2nd ed., Prentice Hall, New Jersey, 1977.
- [23] R. D. Yates and D. J. Goodman, "Probability and Stochastic Process", 2nd ed., John Wiley & Sons, 2005.
- [24] R. Vershynin, "How close is the sample covariance matrix to the actual covariance matrix", arXiv: 1004.3484v1 [math.PR], April 2010.
- [25] Wikipedia, Wishart Distribution. Available at: http://en.wikipedia.org/wiki/Wishart_distribution (last access: on July 2011).
- [26] A. Kortun, T. Ratnarajah, and M. Sellathurai, "Exact Performance Analysis of Blindly Combined Energy Detection for Spectrum Sensing", *IEEE 21st Int. Symp. on Personal Indoor and Mobile Radio Comm. (PIMRC)*, 2010.
- [27] 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*.
- [28] Z. D. Bai, "On the distribuion of largest eigenvalue in principle components analysis", *Analysis Statistics*, Vol. 29, No. 2, pp. 295-327, 2001.

- [29] Z. D. Bai, “Methodologies in spectral analysis of large dimensional random matrices, a review”, *Statistica Sinica*, vol. 9, pp. 611–677, 1999.
- [30] Plamen Koev and Alan Edelman, The efficient evaluation of the hypergeometric function of a matrix argument, *Math. Comp.* 75 (2006), 833-846.
- [31] M. R. Spiegel and J. Liu, “Mathematical Handbook of Formulas and Tables”, 2nd ed., McGraw-Hill, 1999.
- [32] A. V. Oppenheim, A. S. Willsky and S. H. Nawab, “Signals & Systems”, 2nd ed., New Jersey, Prentice-Hall, 1997.
- [33] Y. Zeng, and Y. C. Liang, “Eigenvalue-Based Spectrum Sensing Algorithms for Cognitive Radio”, *IEEE Trans. Comm.*, vol. 57, no. 6, June 2009.
- [34] Wikipedia, Teste Kolmogorov-Smirnov. Available at: http://pt.wikipedia.org/wiki/Teste_Kolmogorov-Smirnov (last access: on July 2011).
- [35] ESTV, Valores Críticos da Distribuição da Estatística D_n . Available at: http://www.estv.ipv.pt/PaginasPessoais/psarabando/TabelaK_S.pdf (last access: on July 2011).
- [36] Mathwave, EasyFit – Distribution Fitting Made Easy. Available at: <http://www.mathwave.com> (last access: on July 2011).
- [37] M. Naghettini and E. J. A. Pinto, “Hidrologia Estatística”, CPRM, Belo Horizonte, 2007.

APÊNDICE 1 – Cálculo da expressão (3.35)

```
%função que calcula a expressão (3.35)
%
%sintaxe: y=gammacomplexo_m(a,m)
% y= valor que a função retorna
% a= argumento da função
% m= numero de receptores

function y=gammacomplexo_m(a,m)

arg_do_produtorio=1;

for k=1:m
    arg_do_produtorio=arg_do_produtorio.*gamma(a-k+1);
end

y=pi.^(m.*(m-1)/2).*arg_do_produtorio;

end

%implementação da expressão (3.57) onde é apresentado uma relação entre gamma versus
pfa.
%
%sintaxe: pfat=gamma_pfa_teorico(m,n,x)
% pfat= pfa teorico
% m= numero de receptores
% n= numero de amostras
% x= threshold

function pfat=gamma_pfa_teorico(m,n,x)

pfa=1-
(gammacomplexo_m(m,m)./gammacomplexo_m(m+n,m)).*(x.^(m*n)).*mhgi(80,1,[n],[n+m],m,-[x]);
%função mhgi presente na referencia [30]

pfat=pfa;

plot(x,pfa,'-','Linewidth',2,'Color','k');
grid on;

end
```

APÊNDICE 2 – Cálculo de P_{FA} versus γ via Monte Carlo

```
%função que gera como saída uma curva que relaciona gamma versus pfa através do método
%iterativo de Monte Carlo
%
%sintaxe: pfae=gammapfa_empirico(m,n,x)
% pfae= pfa empirico
% m= numero de receptores
% n= numero de amostras
% x= threshold

function pfae=gammapfa_empirico(m,n,x)

[aux1 aux2]=size(x);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pfa=0;
    cont_total=0;

    matrizcov=zeros(m,m);

    while cont_pfa<10000
        v=zeros(m,n);
        for i=1:n
            v(:,i)=(sqrt(2)./2).*randn(m,1)+j*(sqrt(2)./2).*randn(m,1);
        end
        matrizcov=v*v';
        auto=eig(matrizcov);
        maximo=max(auto);
        maximo=abs(maximo);
        t=x(f);
        if (maximo>t)
            cont_pfa=cont_pfa+1;
        end
        cont_total=cont_total+1;
    end

    aux3(f)=cont_pfa/cont_total;

end

pfae=aux3;

plot(x,pfae,'x','Linewidth',2,'Color','k');
grid on;

end
```

APÊNDICE 3 – Cálculo de P_D a partir do limiar γ

```
%função que calcula o valor de pd a partir do limiar de decisão gamma calculado através
da %rotina presente no Apendice 2
%
%sintaxe: pd=pd_SNR(m,n,p,gamma,SNR)
%
% m= numero de receptores
% n= numero de amostras
% p= numero de primários
% gamma= limiar de decisão
% SNR= relação sinal ruido desejada

function pd=pd_SNR(m,n,p,gamma,SNR)

cont_pd=0;
cont_total=0;

while cont_pd<10000

    v=zeros(m,n);
    x=zeros(p,n);
    y=zeros(m,n);
    H=zeros(m,p);

    %matriz de canal

    %canal constante
    H=(sqrt(2)/2).*ones(m,p)+(sqrt(2)/2).*j*ones(m,p);
    %canal complexo gaussiano
    H=(sqrt(2)/2).*randn(m,p)+(sqrt(2)/2).*j*randn(m,p);

    %sinal e ruido

    %sinal transmitido
    x=(sqrt((1/2)*10^(SNR/10))).*randn(p,n)+j*(sqrt((1/2)*10^(SNR/10))).*randn(p,n);
    %ruido
    v=(sqrt(2)/2).*randn(m,n)+j*(sqrt(2)/2).*randn(m,n);

    y=H*x+v;

    matrizcov=y*y';

    auto=eig(matrizcov);
    maximo=max(auto);
    maximo=abs(maximo);

    if (maximo>gamma)
        cont_pd=cont_pd+1;
    end
    cont_total=cont_total+1;
end

aux3=cont_pd/cont_total;

pd=aux3;

end
```

APÊNDICE 4 – Cálculo de P_{FA} versus γ via Monte Carlo para o detector de energia

```
%função que gera Pfa versus gamma para o detector de energia
%
%sintaxe: pfaed=gammapfa_energia(m,n,x)
%
% x= threshold
% m= numero de receptores
% n= numero de amostras

function pfaed=gammapfa_energia(m,n,x)

[aux1 aux2]=size(x);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pfa=0;
    cont_total=0;

    matrizcov=zeros(m,m);

    while cont_pfa<10000
        v=zeros(m,n);
        for i=1:n
            v(:,i)=(sqrt(2)./2).*randn(m,1)+j*(sqrt(2)./2).*randn(m,1);
        end
        v=reshape(v,1,m*n);
        energia=(1/(m*n)).*(v*v');

        t=x(f);
        if (energia>t)
            cont_pfa=cont_pfa+1;
        end
        cont_total=cont_total+1;
    end

    aux3(f)=cont_pfa/cont_total;

end

pfaed=aux3;

end
```

APÊNDICE 5 – Cálculo de P_D a partir do limiar γ para o detector de energia

```
%função que calcula o valor de pd para o detector de energia a partir do limiar de
%decisão gamma calculado através da rotina presente no Apendice 4
%
%sintaxe: pded=pded_SNR(m,n,p,gamma,SNR)
%
% m= numero de receptores
% n= numero de amostras
% p= numero de primários
% gamma= limiar de decisão
% SNR= relação sinal ruido desejada

function pded=pded_SNR(m,n,p,gamma,SNR)

[aux1 aux2]=size(SNR);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pd=0;
    cont_total=0;
    pedaco=0;

    while cont_pd<10000

        v=zeros(m,n);
        x=zeros(p,n);
        y=zeros(m,n);
        H=zeros(m,p);

        %matriz de canal

        for g=1:p
            %canal constante
            H(:,g)=(sqrt(2)./2).*ones(m,1)+j*(sqrt(2)./2).*ones(m,1);
            %canal complexo gaussiano
            H(:,g)=(sqrt(2)./2).*randn(m,1)+j*(sqrt(2)./2).*randn(m,1);
        end

        for i=1:n

            x(:,i)=(sqrt((1/2)*10^(SNR(f)/10))).*randn(p,1)+j*(sqrt((1/2)*10^(SNR(f)/10)
            )).*randn(p,1);
            v(:,i)=(sqrt(2)./2).*randn(m,1)+j*(sqrt(2)./2).*randn(m,1);

            y(:,i)=H*x(:,i)+v(:,i);

        end

        y=reshape(y,1,m*n);
        energia=(1/(m*n)).*(y*y');

        if (maximo>gamma)
            cont_pd=cont_pd+1;
        end

        cont_total=cont_total+1;

    end

    aux3(f)=cont_pd/cont_total;

end

pded=aux3;

end
```

APÊNDICE 6 – Cálculo de P_{FA} versus γ para MED não cooperativa considerando SMOOTHING FACTOR

```
%SENSORIAMENTO NÃO COOPERATIVO COM SMOOTHING FACTOR
%
%função que gera Pfa versus gamma
%
%sintaxe: Pfa_gamma_NAOcoop_comL(n,x,L)
%
% n= numero de amostras
% x= threshold
% L=smoothing factor

function Pfa_gamma_NAOcoop_comL(n,x,L)

[aux1 aux2]=size(x);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pfa=0;
    cont_total=0;

    while cont_pfa<10000

        v=(sqrt(2)./2).*randn(1,n)+j*(sqrt(2)./2).*randn(1,n);

        vp=v(1:L);
        vs=[v vp];
        matrizcovS=zeros(L,L);
        for g=1:n
            matrizcovS=matrizcovS+(vs(g:(L-1)+g))'*vs(g:(L-1)+g);
        end
        matrizcovS=(1/n).*matrizcovS;

        auto=eig(matrizcovS);
        maximo=max(auto);
        maximo=abs(maximo);
        t=x(f);

        if (maximo>t)
            cont_pfa=cont_pfa+1;
        end

        cont_total=cont_total+1;
    end

    aux3(f)=cont_pfa/cont_total;

end

pfa=aux3;

plot(x,pfa,'LineWidth',2,'Color','k');

end
```

APÊNDICE 7 – Cálculo de P_D versus SNR para MED não cooperativa considerando SMOOTHING FACTOR

```

%SENSORIAMENTO NÃO COOPERATIVO COM SMOOTHING FACTOR
%
%função que gera Pd versus SNR
%
%sintaxe: Pd_SNR_NAOcoop_comL(n,p,gamma,SNR,L)
%
% n= numero de amostras
% p= numero de usuários primários
% gamma= threshold
% SNR= relação sinal ruído
% L=smoothing factor

function TESTE_xxxx_Pd_SNR_NAOcoop_comL(n,p,gamma,SNR,L)

[aux1 aux2]=size(SNR);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pd=0;
    cont_total=0;
    pedaco=0;

    while cont_pd<100

        %=====geração do sinal Y=====

        %canal

        H=(sqrt(2)./2).*randn(1,p)+j*(sqrt(2)./2).*randn(1,p);

        %sinal

        x=(sqrt(2)./2).*randn(p,n)+j*(sqrt(2)./2).*randn(p,n);
        numTermos=100;
        pad=zeros(p,numTermos-1);
        x=[x pad];
        aux=1;
        for k=(n)+1:(n)+numTermos-1
            x(:,k)=x(:,aux);
            aux=aux+1;
        end
        for k2=1:(n)
            aux=sum(x(:,k2:(numTermos-1+k2)),2);
            xsoma(:,k2)=aux;
        end
        xsoma=(1/sqrt(numTermos)).*xsoma;
        for i=1:p
            potX=(1/n)*(xsoma(i,:)*xsoma(i,:));
            xsoma(i,:)=(1/sqrt(potX)).*xsoma(i,:);
        end

        %ruído

        v=(sqrt((1/2)/10^(SNR(f)/10))).*randn(1,n)+j*(sqrt((1/2)/10^(SNR(f)/10))).*randn(1,n);

        y=H*(xsoma)+v;

        %=====algoritmo de detecção=====

        yp=y(1:L);
        ys=[y yp];
        matrizcovS=zeros(L,L);
        for g=1:n
    
```

```

        matrizcovS=matrizcovS+(ys(g:(L-1)+g))*ys(g:(L-1)+g);
    end
    matrizcovS=(1/n).*matrizcovS;

    auto=eig(matrizcovS);
    maximo=max(auto);
    maximo=abs(maximo);

    if (maximo>gamma.*(1/(10^(SNR(f)/10))))
        cont_pd=cont_pd+1;
    end

    cont_total=cont_total+1;
end

aux3(f)=cont_pd/cont_total;

end

pd=aux3;

plot(SNR,pd,'LineWidth',2,'Color','k');
grid on;

end

```


APÊNDICE 8 – Cálculo de P_{FA} versus γ para MED não cooperativa sem considerar SMOOTHING FACTOR

```
%SENSORIAMENTO NÃO COOPERATIVO SEM SMOOTHING FACTOR
%
%função que gera Pf versus gamma
%
%sintaxe: Pfa_gamma_NAOcoop_semL(k,nk,x)
%
% k= numero de pedaços
% nk= numero de amostras cada pedaço
% x= threshold

function Pfa_gamma_NAOcoop_semL(k,nk,x)

[aux1 aux2]=size(x);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pfa=0;
    cont_total=0;

    while cont_pfa<10000

        v=(sqrt(2)./2).*randn(1,k*nk)+j*(sqrt(2)./2).*randn(1,k*nk);
        v=reshape(v,k,nk);

        matrizcov=zeros(nk,nk);
        for i=1:k
            matrizcov=matrizcov+v(i,:)'*v(i,:);
        end
        matrizcov=(1/k).*matrizcov;

        auto=eig(matrizcov);
        maximo=max(auto);
        maximo=abs(maximo);
        t=x(f);

        if (maximo>t)
            cont_pfa=cont_pfa+1;
        end

        cont_total=cont_total+1;
    end

    aux3(f)=cont_pfa/cont_total;

end

pfa=aux3;

plot(x,pfa,'LineWidth',2,'Color','g');
grid on;

end
```

APÊNDICE 9 – Cálculo de P_D versus SNR para MED não cooperativa sem considerar SMOOTHING FACTOR

```

%SENSORIAMENTO NÃO COOPERATIVO SEM SMOOTHING FACTOR
%
%função que gera Pd versus SNR
%
%sintaxe: Pd_SNR_NAOcoop_semL(k,nk,gamma,SNR)
%
% k= numero de pedaços
% nk= numero de amostras cada pedaço
% gamma= threshold
% SNR= relação sinal ruído

function Pd_SNR_NAOcoop_semL(k,nk,gamma,SNR)

[aux1 aux2]=size(SNR);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pd=0;
    cont_total=0;
    pedaco=0;

    while cont_pd<10000

        %=====gerando o sinal Y=====

        %canal

        H=(sqrt(2)./2).*randn(1,1)+j*(sqrt(2)./2).*randn(1,1);

        %sinal

        x=(sqrt(2)./2).*randn(1,k*nk)+j*(sqrt(2)./2).*randn(1,k*nk);
        numTermos=1;
        pad=zeros(1,numTermos-1);
        x=[x pad];
        aux=1;
        for K=(nk*k)+1:(nk*k)+numTermos-1
            x(K)=x(aux);
            aux=aux+1;
        end
        for K2=1:(k*nk)
            aux=sum(x(K2:(numTermos-1+K2)));
            xsoma(K2)=aux;
        end
        xsoma=(1/sqrt(numTermos)).*xsoma;

        potX=(1/(nk*k)).*(xsoma*xsoma');
        xsoma=(1/sqrt(potX)).*xsoma;

        xsoma=reshape(xsoma,k,nk);

        %ruído

        v=(sqrt((1/2)/10^(SNR(f)/10))).*randn(1,k*nk)+j*(sqrt((1/2)/10^(SNR(f)/10))).*r
        andn(1,k*nk);
        v=reshape(v,k,nk);

        y=H.*xsoma+v;

        %=====algoritmo de detecção=====

        matrizcov=zeros(nk,nk);
        for i=1:k
            matrizcov=matrizcov+y(i,:)'*y(i,:);
        end
    end
end

```

```

end
matrizcov=(1/k).*matrizcov;

auto=eig(matrizcov);
maximo=max(auto);
maximo=abs(maximo);

if (maximo>gamma.*(1/(10^(SNR(f)/10))))
    cont_pd=cont_pd+1;
end

cont_total=cont_total+1;
end

aux3(f)=cont_pd/cont_total;

end

pd=aux3;

plot(SNR,pd,'LineWidth',2,'Color','k');
grid on;

end

```

APÊNDICE 10 – Cálculo de P_{FA} versus γ para MED cooperativa sem considerar SMOOTHING FACTOR

```
%SENSORIAMENTO COOPERATIVO SEM SMOOTHING FACTOR
%
%função que gera Pfa versus gamma
%
%sintaxe: Pfa_gamma_COOPERATIVO_semL(m,n,x)
%
%   x= threshold
%   m= numero de sensores
%   n= numero de amostras

function Pfa_gamma_COOPERATIVO_semL(m,n,x)

[aux1 aux2]=size(x);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pfa=0;
    cont_total=0;

    matrizcov=zeros(m,m);

    while cont_pfa<10000
        v=zeros(m,n);
        for i=1:n
            v(:,i)=(sqrt(2)./2).*randn(m,1)+j*(sqrt(2)./2).*randn(m,1);
        end
        matrizcov=(1/n).*(v*v');
        auto=eig(matrizcov);
        maximo=max(auto);
        maximo=abs(maximo);
        t=x(f);
        if (maximo>t)
            cont_pfa=cont_pfa+1;
        end
        cont_total=cont_total+1;
    end

    aux3(f)=cont_pfa/cont_total;

end

pfa=aux3;
plot(x,pfa,'LineWidth',2,'Color','r');
grid on;

end
```

APÊNDICE 11 – Cálculo de P_D versus SNR para MED cooperativa sem considerar SMOOTHING FACTOR

```

%SENSORIAMENTO COOPERATIVO SEM SMOOTHING FACTOR
%
%função que gera Pd versu SNR
%
%sintaxe: Pd_SNR_COOPERATIVO_semL(m,n,p,gamma,SNR)
%
% m= numero de sensores
% n= numero de amostras
% p= numero de primários
% gamma= threshold
% SNR= relação sinal ruido desejada

function Pd_SNR_COOPERATIVO_semL(m,n,p,gamma,SNR)

[aux1 aux2]=size(SNR);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pd=0;
    cont_total=0;
    pedaco=0;

    while cont_pd<10000

        v=zeros(m,n);
        x=zeros(p,n);
        y=zeros(m,n);
        H=zeros(m,p);

        %=====gerando o sinal Y=====

        %canal

        for g=1:p
            H(:,g)=(sqrt(2)/2).*randn(m,1)+j*(sqrt(2)/2).*randn(m,1);
        end

        %sinal e ruido

        for i=1:n
            x(:,i)=(sqrt(2)/2).*randn(p,1)+j*(sqrt(2)/2).*randn(p,1);
            v(:,i)=(sqrt((1/2)/10^(SNR(f)/10))).*randn(m,1)+j*(sqrt((1/2)/10^(SNR(f)/10)
            )).*randn(m,1);
        end
        numTermos=5;
        pad=zeros(p,numTermos-1);
        x=[x pad];
        aux=1;
        for k=n+1:(n+numTermos-1)
            x(:,k)=x(:,aux);
            aux=aux+1;
        end
        for k2=1:n
            aux=sum(x(:,k2:(numTermos-1+k2)),2);
            xsoma(:,k2)=aux;
        end
        xsoma=(1/sqrt(numTermos)).*xsoma;
        for i=1:p
            potX=(1/n)*(xsoma(i,:)*xsoma(i,:)');
            xsoma(i,:)=(1/sqrt(potX)).*xsoma(i,:);
        end

        y=H*xsoma+v;

        %=====algoritmo de detecção=====
    end
end

```

```

matrizcov=(1/n).*(y*y');

auto=eig(matrizcov);
maximo=max(auto);
maximo=abs(maximo);

if (maximo>gamma.*(1/(10^(SNR(f)/10))))
    cont_pd=cont_pd+1;
end

cont_total=cont_total+1;
end

aux3(f)=cont_pd/cont_total;

end

pd=aux3;

plot(SNR,pd,'LineWidth',2,'Color','k');
grid on;

end

```

APÊNDICE 12 – Cálculo de P_{FA} versus γ para MED cooperativa considerando SMOOTHING FACTOR

```
%SENSORIAMENTO COOPERATIVO COM SMOOTHING FACTOR
%
%função que gera Pfa versus gamma
%
%sintaxe: Pfa_gamma_COOPERATIVO_comL(m,n,x,L)
%
% x= threshold
% m= numero de sensores
% n= numero de amostras
% L= smoothing factor

function Pfa_gamma_COOPERATIVO_comL(m,n,x,L)

[aux1 aux2]=size(x);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pfa=0;
    cont_total=0;

    matrizcovS=zeros(m,m);

    while cont_pfa<10000
        v=zeros(m,n);
        for i=1:n
            v(:,i)=(sqrt(2)./2).*randn(m,1)+j*(sqrt(2)./2).*randn(m,1);
        end
        vp=v(:,1:L);
        vs=[v vp];
        matrizcovS=zeros(m,m);
        for g=1:n
            matrizcovS=matrizcovS+vs(:,g:(L-1)+g)*(vs(:,g:(L-1)+g))';
        end
        matrizcovS=(1/(n*L)).*matrizcovS;
        auto=eig(matrizcovS);
        maximo=max(auto);
        maximo=abs(maximo);
        t=x(f);
        if (maximo>t)
            cont_pfa=cont_pfa+1;
        end
        cont_total=cont_total+1;
    end

    aux3(f)=cont_pfa/cont_total;

end

pfa=aux3;
plot(x,pfa, 'LineWidth', 2, 'Color', 'b');
grid on;

end
```

APÊNDICE 13 – Cálculo de P_D versus SNR para MED cooperativa considerando SMOOTHING FACTOR

```

%SENSORIAMENTO COOPERATIVO COM SMOOTHING FACTOR
%
%função que gera Pd versus SNR
%
%sintaxe: Pd_SNR_COOPERATIVO_comL(m,n,p,gamma,SNR,L)
%
% m= numero de sensores
% n= numero de amostras
% p= numero de primários
% gamma= threshold
% SNR= relação sinal ruido desejada
% L= smoothing factor

function Pd_SNR_COOPERATIVO_comL(m,n,p,gamma,SNR,L)

[aux1 aux2]=size(SNR);
aux3=zeros(1,aux2);

for f=1:aux2

    cont_pd=0;
    cont_total=0;
    pedaco=0;

    while cont_pd<10000

        v=zeros(m,n);
        x=zeros(p,n);
        y=zeros(m,n);
        H=zeros(m,p);

        %canal

        for g=1:p
            H(:,g)=(sqrt(2)/2).*randn(m,1)+j*(sqrt(2)/2).*randn(m,1);
        end

        %sinal e ruido

        for i=1:n
            x(:,i)=(sqrt(2)/2).*randn(p,1)+j*(sqrt(2)/2).*randn(p,1);
            v(:,i)=(sqrt((1/2)/10^(SNR(f)/10))).*randn(m,1)+j*
                (sqrt((1/2)/10^(SNR(f)/10))).*randn(m,1);
        end
        numTermos=3;
        pad=zeros(p,numTermos-1);
        x=[x pad];
        aux=1;
        for k=n+1:(n+numTermos-1)
            x(:,k)=x(:,aux);
            aux=aux+1;
        end
        for k2=1:n
            aux=sum(x(:,k2:(numTermos-1+k2)),2);
            xsoma(:,k2)=aux;
        end
        xsoma=(1/sqrt(numTermos)).*xsoma;
        for i=1:p
            potX=(1/n)*(xsoma(i,:)*xsoma(i,:)');
            xsoma(i,:)=(1/sqrt(potX)).*xsoma(i,:);
        end

        y=H*xsoma+v;

        %-----algoritmo de detecção-----

```



```

yp=y(:,1:L);
ys=[y yp];
matrizcovS=zeros(m,m);
for g=1:n
    matrizcovS=matrizcovS+ys(:,g:(L-1)+g)*(ys(:,g:(L-1)+g))';
end
matrizcovS=(1/(n*L)).*matrizcovS;

auto=eig(matrizcovS);
maximo=max(auto);
maximo=abs(maximo);

if (maximo>gamma.*(1/(10^(SNR(f)/10))))
    cont_pd=cont_pd+1;
end

cont_total=cont_total+1;
end

aux3(f)=cont_pd/cont_total;

end

pd=aux3;

plot(SNR,pd,'LineWidth',2,'Color','b');
grid on;

end

```

APÊNDICE 14 – Rotina para geração de uma amostras tamanho N da variável aleatória λ_{\max}

```

 $T_N := 0$ 
for  $pt \in 0..N - 1$ 
  for  $j \in 0..p - 1$ 
     $H^{(j)} \leftarrow \text{norm}\left(m, 0, \sqrt{\frac{1}{2}}\right) + j \cdot \left(\text{norm}\left(m, 0, \sqrt{\frac{1}{2}}\right)\right)$ 
  for  $k \in 0..n - 1$ 
     $x^{(k)} \leftarrow \text{norm}\left(p, 0, \sqrt{\frac{1}{2} \cdot 10^{10} \cdot \sigma^2}\right) + j \cdot \left(\text{norm}\left(p, 0, \sqrt{\frac{1}{2} \cdot 10^{10} \cdot \sigma^2}\right)\right)$ 
     $v^{(k)} \leftarrow \text{norm}\left(m, 0, \sqrt{\frac{1}{2} \cdot \sigma^2}\right) + j \cdot \left(\text{norm}\left(m, 0, \sqrt{\frac{1}{2} \cdot \sigma^2}\right)\right)$ 
     $y^{(k)} \leftarrow H \cdot x^{(k)} + v^{(k)}$ 
   $nR_y \leftarrow y \cdot (y)^T$ 
   $T_{N_{pt}} \leftarrow \left| \frac{\max(\text{eigenvals}(nR_y))}{\sigma^2} \right|$ 
 $T_N$ 

```