

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL

FACULDADE DE ENGENHARIA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

LUDIMILA LA ROSA CENTENO

**SENSORIAMENTO DE ESPECTRO E CLASSIFICAÇÃO DE SINAIS
EM RÁDIO COGNITIVO POR DECOMPOSIÇÃO EM SUBESPAÇOS E
REDES NEURAIS RBF**

Porto Alegre – RS, Brasil

2014

LUDIMILA LA ROSA CENTENO

**SENSORIAMENTO DE ESPECTRO E CLASSIFICAÇÃO DE SINAIS
EM RÁDIO COGNITIVO POR DECOMPOSIÇÃO EM SUBESPAÇOS E
REDES NEURAIAS RBF**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica do Rio Grande do Sul, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Sinais, Sistemas e Tecnologia da Informação.

Linha de Pesquisa: Telecomunicações.

Orientador: Fernando César Comparsi de Castro

Coorientadora: Maria Cristina Felippetto de Castro

Porto Alegre – RS, Brasil

2014



Pontifícia Universidade Católica do Rio Grande do Sul

FACULDADE DE ENGENHARIA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

SENSORIAMENTO DE ESPECTRO E CLASSIFICAÇÃO DE SINAIS EM RÁDIO COGNITIVO POR DECOMPOSIÇÃO EM SUBESPAÇOS E REDES NEURAIS RBF

CANDIDATA: LUDIMILA LA ROSA CENTENO

Esta Dissertação de Mestrado foi julgada para obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica do Rio Grande do Sul.




DR. FERNANDO CÉSAR COMPARSI DE CASTRO - ORIENTADOR



DRA. MARIA CRISTINA F. DE CASTRO - CO-ORIENTADORA

BANCA EXAMINADORA



DR. MAX HENRIQUE MACHADO COSTA - PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E COMPUTAÇÃO - DEPARTAMENTO DE COMUNICAÇÕES - UNICAMP



DR. ALEXANDRE ROSA FRANCO - DO PPGE/FENG - PUCRS

PUCRS

Campus Central
Av. Ipiranga, 6681 - Prédio 30 - Sala 103 - CEP: 91219-900
Telefone: (51) 3320.3540 - Fax: (51) 3320.3625
E-mail: engenharia.pg.eletrica@pucrs.br
www.pucrs.br/feng

Sandro,

“Me and you

Got nothing better to do

Than to push each other around

In our own way”

(Nada Surf)

Agradecimentos

Sou grata ao Sandro por ter me acompanhado nessa jornada. Muitas outras virão e o caminho é mais fácil ao teu lado. Agradeço ao Fernando por entender a minha capacidade de ser não-ortodoxa e me oferecer uma orientação segura, sem a qual esse trabalho não seria possível. Agradeço também a Cristina pela orientação e por fazer perguntas difíceis que contribuíram para o amadurecimento deste trabalho. Agradeço a toda minha família, especialmente aos meus pais, Loiva e João Antonio, por me apoiarem incondicionalmente e compreenderem a minha ausência. Sou igualmente grata à Pontifícia Universidade Católica do Rio Grande do Sul pelo período de bolsa concedida, sem a qual a conclusão deste trabalho dificilmente teria acontecido.

*“Aprendi a não tentar convencer ninguém. O trabalho de convencer é uma
falta de respeito, é uma tentativa de colonização do outro”
(José Saramago)*

Resumo

A possibilidade de escassez e saturação do espectro, aliadas às demandas crescentes por maiores capacidades de transmissão, são fatores que impulsionam a pesquisa de soluções no âmbito das redes de rádios cognitivos. O sensoriamento do espectro constitui um dos maiores desafios para o desenvolvimento comercial dos sistemas de rádio cognitivo, pois a verificação da presença de um usuário primário é uma tarefa complexa que exige alta confiabilidade. A proposta deste trabalho é elaborar um classificador de sinais capaz de verificar a presença de um usuário primário num determinado canal do espectro de rádio. O classificador proposto realiza a decomposição em subespaços da matriz de covariância do sinal, visando extração de características que possam indicar a presença de usuário primário. A decomposição do sinal em subespaços permite a determinação de bancos de filtros aos quais novos sinais são submetidos. Redes neurais do tipo RBF são utilizadas para análise de características dos sinais filtrados e decisão sobre a presença de um determinado tipo de usuário primário. Com base na regulamentação IEEE 802.22, o processo de classificação é executado na rádio-base cognitiva, responsável pelo controle de todos os usuários e canais na sua área de cobertura. Os resultados indicam que o custo computacional da decomposição em subespaços, que é executada de forma cíclica em métodos similares, pode ser reduzido através da abordagem proposta, sem comprometimento da qualidade da detecção.

Palavras-chave: Sensoriamento de espectro. Redes de rádios cognitivos. Decomposição em subespaços. Redes neurais. Classificação de sinais. Autovalores e autovetores.

Abstract

The possibility of spectrum shortage and saturation, combined with the increasing demands for higher transmission rates are driving factors for research within cognitive radio networks. Spectrum sensing is one of the major challenges for the commercial development of cognitive radio systems, since the verification of a primary user presence is a complex task that requires high reliability. The proposal of this work is to develop a signal classifier capable of verifying the primary user presence on a particular channel of the radio spectrum. The proposed classifier performs subspace decomposition of the signal covariance matrix, in order to obtain characteristics that may indicate the presence of a primary user. The subspace decomposition enables the design of filter banks to which new signals are submitted. RBF neural networks are used to analyze the filtered signal characteristics and to decide about the presence of a particular type of primary user. Based on IEEE 802.22 regulations, the classification process is performed at the cognitive radio base station, which is responsible for controlling all users and channels in its coverage area. The results indicate that the computational cost of subspace decomposition, which is cyclically performed in similar methods, can be reduced through the proposed approach without jeopardizing the detection quality.

Keywords: Spectrum sensing. Cognitive radio networks. Subspace decomposition. Neural networks. Signal classification. Eigenvalues and eigenvectors.

Lista de Figuras

Figura 2.1 – Diagrama em blocos de um sistema de comunicação	24
Figura 2.2 – Blocos de um transmissor de RF	25
Figura 2.3 – Blocos de um receptor de RF.....	26
Figura 2.4 – Bandas de frequência para canal wireless.....	28
Figura 2.5 – Canal AWGN.....	29
Figura 2.6 – Canal AWGN limitado em banda.....	29
Figura 2.7 – Espectro de potência de um processo limitado em banda	30
Figura 2.8 – Exemplo de multipercurso.....	31
Figura 2.9 – ISI causada por multipercurso.....	32
Figura 2.10 – Processo de modulação de portadora.....	33
Figura 2.11 – (a) Espectro de um sinal <i>baseband</i> e (b) espectro do mesmo sinal modulado em amplitude	34
Figura 2.12 – Sinal FM	35
Figura 2.13 – Subdivisão da banda W de um canal em subcanais de largura de banda Δf	36
Figura 2.14 – Representação gráfica de oito <i>subcarriers</i> ortogonais formando um símbolo OFDM.....	37
Figura 2.15 – Sistemas de DTV ao redor do mundo	39
Figura 2.16 – Ruído AWGN, PDF e função de auto-correlação	40
Figura 3.1 – Oportunidades para acesso	43
Figura 3.2 – Compartilhamento horizontal e vertical de espectro.....	44
Figura 3.3 – Acesso <i>Overlay</i> e <i>Underlay</i>	44
Figura 3.4 – <i>Transceiver</i> SDR.....	46
Figura 3.5 – Camadas de protocolos da RRC.....	47
Figura 3.6 - Principais funções do rádio cognitivo.....	47
Figura 3.7 – Arquitetura com e sem infraestrutura	48
Figura 3.8 – Relação entre métodos de acesso e infraestrutura	49
Figura 4.1 – Períodos de silêncio	53

Figura 4.2 – Técnicas cegas e não-cegas.....	54
Figura 4.3 – Representação de um <i>Eigenfilter bank</i>	59
Figura 5.1 – Resoluções IEEE para comunicação <i>wireless</i>	62
Figura 5.2 – Arquitetura da RRC conforme IEEE 802.22	62
Figura 5.3 – Funcionalidades definidas pela IEEE 802.22 associadas ao plano cognitivo	63
Figura 5.4 – Entradas e saídas para o SSF	68
Figura 5.5 – Estrutura de <i>superframes</i>	69
Figura 6.1 – Elementos básicos de um neurônio artificial	73
Figura 7.1 – Sistema para classificação de sinais por decomposição em subespaços para sensoriamento de espectro de rádio cognitivo.	80
Figura 7.2 – Autovalores significativos	83
Figura 7.3 – Detalhamento de um <i>eigenfilter bank</i>	85
Figura 7.4 – (a) Projeções do sinal resultantes da filtragem pelos <i>eigenfilters</i> 1, 2 e 3 e (b) zoom da imagem (a).....	86
Figura 7.5 – Etapa de filtragem	88
Figura 7.6 – Resultado da operação $ \cdot ^2$ para as projeções resultantes dos <i>eigenfilters</i> 1, 2 e 3.	89
Figura 7.7 - Resultado da filtragem LPF MA (projeções filtradas) para as projeções <i>eigenfilters</i> 1, 2 e 3.....	90
Figura 7.8 – Resultado da média subamostrada para as projeções filtradas resultantes dos <i>eigenfilters</i> 1, 2 e 3.	92
Figura 7.9 – (a) Amostras de ruído e PDF teórica e (b) Função de autocorrelação do ruído AWGN.....	93
Figura 7.10 – (a) Ruído AWGN após filtragem pelos <i>eigenfilters</i> 1, 2 e 3 e (b) zoom da imagem (a).....	95
Figura 7.11 – Ruído AWGN após filtragem LPF MA das projeções resultantes dos <i>eigenfilters</i> 1, 2 e 3.....	96
Figura 7.12 – Resultado da média subamostrada para as projeções filtradas relativas ao ruído AWGN resultante dos <i>eigenfilters</i> 1, 2 e 3.	97
Figura 7.13– RBF1 associada ao <i>eigenfilter bank</i> 1	100
Figura 7.14 – Interface do programa RBF Neural Net Training/Validation	101

Figura 7.15 – Periodograma para (a) Microfone no modo <i>Soft Speaker</i> , (b) Microfone no modo <i>Loud Speaker</i> e (c) Microfone no modo <i>Silent</i>	109
Figura 7.16 – Periodograma do sinal <i>bandpass</i> correspondente a microfone em modo <i>Soft Speaker</i>	111
Figura 7.17 – Bloco de conversão (<i>Downconverter</i>) do sinal <i>bandpass</i> de microfone sem fio para banda-base.	111
Figura 7.18 – Resposta em magnitude do filtro adotado para sinais de microfone sem fio	112
Figura 7.19 – Periodograma do sinal banda-base correspondente a microfone em modo <i>Soft Speaker</i>	112
Figura 7.20 – Autovalores dos sinais de (a) <i>Soft Speaker</i> , (b) <i>Loud Speaker</i> e (c) <i>Silent</i>	113
Figura 7.21 – Eigenfilter banks <i>Soft Speaker</i> , <i>Loud Speaker</i> e <i>Silent</i>	115
Figura 7.22 – Resultado da operação $ \cdot ^2$ para o sinal de microfone no modo <i>Soft</i> para $l = 1, 2$ e 3 do <i>eigenfilter bank Soft</i>	116
Figura 7.23 - Resultado da filtragem MA para o sinal de microfone no modo <i>Soft</i> para $l = 1, 2$ e 3 do <i>eigenfilter bank Soft</i>	116
Figura 7.24 - Resultado da média subamostrada para o sinal de microfone no modo <i>Soft</i> para $l = 1, 2$ e 3 do <i>eigenfilter bank Soft</i>	117
Figura 7.25 – Redução da quantidade de redes neurais RBFs necessária para análise da presença de UP, no cenário de microfone sem fio	118
Figura 7.26 – Periodograma do sinal de TV digital utilizado para simulação	120
Figura 7.27 – Autovalores significativos para o sinal DVB-T. A imagem inferior (b) é uma aproximação da imagem superior (a).....	121
Figura 7.28 – Processo de detecção para um módulo de classificação.....	123
Figura 7.29 – Processo de detecção.....	124
Figura 7.30 – Detector de energia padrão.....	126
Figura 7.31 – Detector de energia implementado	127
Figura 7.32 – Detector de energia para (a) sinal de microfone sem fio e para (b) sinal OFDM.....	128
Figura 8.1 – Avaliação do módulo de classificação OFDM.	131
Figura 8.2 – Curvas de decaimento dos autovalores para sinal OFDM 256.	135

Figura 8.3 – Análise do módulo de classificação OFDM quando analisando sinais distintos do OFDM 256.....	138
Figura 8.4 – Autovalores para sinal OFDM com cenários de multipercurso.....	140
Figura 8.5 – Avaliação do módulo de classificação OFDM Brasil A.....	143
Figura 8.6 – Avaliação do módulo de classificação OFDM Brasil D.....	145
Figura 8.7 – (a) Módulo do sinal OFDM com multipercurso Brasil A e 3 impulsos de ruído e (b) Módulo do sinal OFDM com multipercurso Brasil A e 5 impulsos de ruído.	148
Figura 8.8 – Avaliação do módulo de classificação OFDM Brasil A sob cenário de ruído impulsivo.....	149
Figura 8.9 – Avaliação do módulo de classificação WMIC Eigenfilter Bank Loud...	151
Figura 8.10 – Avaliação do módulo de classificação WMIC <i>Eigenfilter Bank Soft</i>	153
Figura 8.11 – Avaliação do módulo de classificação WMIC <i>Eigenfilter Bank Silent</i>	155
Figura 8.12 – Avaliação do módulo de classificação DVB-T.....	157
Figura 8.13 – Avaliação do módulo de classificação DVB-T quando analisando sinais distintos do DVB-T.....	159

Lista de Tabelas

Tabela 7.1 – Pseudocódigo do filtro LPF SA.....	91
Tabela 7.2 – Informações do arquivo de treino e validação do programa <i>RBF Trainer/Validation</i>	102
Tabela 7.3 – Resumo de algumas das RBFs testadas para cenário de sinal OFDM com tamanho 256 e CP $\frac{1}{4}$ e ruído AWGN.	104
Tabela 7.4 – (a) Informações gerais da RBF e (b) Variância dos centros da RBF e sinapses dos neurônios de saída	105
Tabela 7.5 – Resumo do procedimento para obtenção de um módulo de classificação composto de um <i>eigenfilter bank</i> , uma etapa de filtragem e uma rede neural RBF.....	106
Tabela 7.6 – Parâmetros para simulação de sinal de microfones sem fio	108
Tabela 7.7 – Resumo de algumas das RBFs testadas para cenário de sinal de microfone sem fio.	119
Tabela 8.1 – (a) Informações gerais da RBF OFDM e (b) Variância dos centros da RBF OFDM e sinapses dos neurônios de saída.....	130
Tabela 8.2 – (a) Informações gerais da RBF OFDM BA e (b) Variância dos centros da RBF OFDM BA e sinapses dos neurônios de saída.	142
Tabela 8.3 – (a) Informações gerais da RBF OFDM BD e (b) Variância dos centros da RBF OFDM BD e sinapses dos neurônios de saída.	144
Tabela 8.4 – (a) Informações gerais da RBF WMIC e (b) Variância dos centros da RBF WMIC e sinapses dos neurônios de saída.	150
Tabela 8.5 – (a) Informações gerais da RBF DVB-T e (b) Variância dos centros da RBF DVB-T e sinapses dos neurônios de saída.....	157
Tabela 8.6 – Avaliação dos resultados obtidos	160

Lista de Abreviaturas e Siglas

AAC	<i>Advanced Audio Coding</i>
AGC	<i>Automatic Gain Control</i>
ATSC	<i>Advanced Television Systems Committee</i>
AVC	<i>Advanced Video Coding</i>
AWGN	<i>Additive White Gaussian Noise</i>
A/D	<i>Analog to Digital</i>
CCSS	<i>Cooperative Centralized Spectrum Sensing</i>
CD	<i>Cyclostationary Detection</i>
CDSS	<i>Cooperative Distributed Spectrum Sensing</i>
COFDM	<i>Coded OFDM</i>
CogAP	<i>Cognitive Access Point</i>
CP	<i>Cyclic Prefix</i>
CPC	<i>Cognitive Pilot Channel</i>
CPE	<i>Customer Premise Equipment</i>
DOA	<i>Direction of Arrival</i>
DS	<i>Database Service</i>
DTMB	<i>Digital Terrestrial Multimedia Broadcasting</i>
DTTB	<i>Digital Terrestrial Television Broadcasting</i>
DTV	<i>Digital Television</i>
DVB-T	<i>Digital Video Broadcasting Terrestrial</i>

ED	<i>Energy Detection</i>
EME	<i>Energy with Minimum Eigenvalue</i>
ERB	<i>Estação Rádio-Base</i>
ETSI	<i>European Telecommunications Standards Institute</i>
FCC	<i>Federal Communications Commission</i>
FDM	<i>Frequency-Division Multiplexing</i>
FFT	<i>Fast Fourier Transform</i>
FI	<i>Frequência Intermediária</i>
FIR	<i>Finite Impulse Response</i>
FM	<i>Frequency Modulating</i>
GL	<i>Geolocation services</i>
GSM	<i>Global System for Mobile communications</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
IFFT	<i>Inverse Fast Fourier Transform</i>
ISI	<i>Inter-symbol Interference</i>
ISDB-T	<i>Integrated Services Digital Broadcasting Terrestrial</i>
LNA	<i>Low Noise Amplifier</i>
LPF	<i>Low-pass Filter</i>
MA	<i>Moving Average</i>
MAC	<i>Media Access Control</i>
MF	<i>Matched Filter</i>
MIB	<i>Management Information Base</i>
MLP	<i>Multilayer Perceptrons</i>
MME	<i>Maximum-minimum Eigenvalue</i>
MPEG	<i>Moving Picture Experts Group</i>
MSE	<i>Mean Square Error</i>

MUSIC	<i>Multiple Signal Classification</i>
NSA	<i>Negotiated Spectrum Access</i>
OA	<i>Overlay Access</i>
OFDM	<i>Orthogonal Frequency Division Multiplexing</i>
OFDMA	<i>Orthogonal Frequency Division Multiple Access</i>
OSA	<i>Opportunistic Spectrum Access</i>
PD	<i>Probability of Detection</i>
PFA	<i>Probability of False Alarm</i>
PHY	<i>Physical Layer</i>
PS	Período de Silêncio
QoS	<i>Quality of Service</i>
RBF	<i>Radial Basis Function</i>
RF	Radiofrequência
RNA	Redes Neurais Artificiais
RC	Rádio Cognitivo
RRC	Rede de Rádios Cognitivos
SDR	<i>Software-Defined Radio</i>
SMo	<i>Spectrum Mobility</i>
SNMP	<i>Simple Network Management Protocol</i>
SNR	<i>Signal-to-Noise Ratio</i>
SS	<i>Spectrum Sensing</i>
SSA	<i>Spectrum Sensing Automaton</i>
SSF	<i>Spectrum Sensing Function</i>
SSh	<i>Spectrum Sharing</i>
SSL	<i>Security Socket Layer</i>
SM	<i>Spectrum Manager</i>

TDS	<i>Time Domain Synchronous</i>
UA	<i>Underlay Access</i>
UHF	<i>Ultra High Frequency</i>
UP	Usuário Primário
US	Usuário Secundário
VHF	<i>Very High Frequency</i>
VSWR	<i>Voltage Standing Wave Ratio</i>
WCDMA	<i>Wideband Code Division Multiple Access</i>
WLAN	<i>Wireless Local Area Networks</i>
WRAN	<i>Wireless Regional Area Network</i>
3GPP	<i>3rd Generation Partnership Project</i>
8VSB	<i>8-Level Vestigial Sideband Modulation</i>

Sumário

1	Introdução	20
2	Transmissão em Canais Sem Fio	24
2.1	Transmissor de RF	24
2.2	Receptor de RF	26
2.3	Canais e Multipercurso	28
2.4	Banda-base	32
2.5	Modulação de Sinais	34
2.5.1	FM	35
2.5.2	<i>Orthogonal Frequency Division Multiplexing</i>	36
2.5.3	TV Digital	38
2.6	Ruído	39
3	Rádios Cognitivos	41
3.1	Acesso Dinâmico ao Espectro	42
3.2	<i>Software-Defined Radio (SDR)</i>	45
3.3	Arquitetura e Funções da RRC	46
4	Sensoriamento do Espectro	50
4.1	Detecção de Oportunidades	51
4.2	Técnicas de Sensoriamento de Espectro	53
4.2.1	Técnicas Não-cegas	54
4.2.2	Técnicas Cegas	55
4.2.2.1	Detecção de Energia	55
4.2.2.2	Decomposição em Subespaços	55
5	Regulamentação IEEE 802.22	61
5.1	Gerenciamento de Espectro	64
5.2	<i>Spectrum Sensing Automaton</i>	66
5.2.1	<i>Spectrum Sensing Function</i>	67
5.2.2	Períodos de Silêncio	68
5.3	Inicialização da WRAN	70

6	Redes Neurais	72
6.1	<i>Radial Basis Function</i>	74
6.2	Redes Neurais e Rádio Cognitivo	76
7	Sistema Proposto	77
7.1	Delimitações de Escopo	78
7.2	Arquitetura do Sistema	80
7.2.1	Sinal OFDM do padrão IEEE WiMAX 802.16.....	81
7.2.1.1	Determinação dos <i>Eigenfilter Banks</i>	81
7.2.1.2	Determinação das RBFs	99
7.2.2	Sinal de Microfone Sem Fio	107
7.2.3	Sinal de TV Digital.....	119
7.3	Processo de Detecção	123
7.4	Detector de Energia e Decisor	125
8	Resultados Obtidos.....	130
8.1	Cenário 1: Sinal OFDM	130
8.2	Cenário 2: Análise de Outros Sinais.....	137
8.3	Cenário 3: Multipercurso	140
8.4	Cenário 4: Ruído Impulsivo	147
8.5	Cenário 5: Sinal de Microfone Sem Fio.....	150
8.6	Cenário 6: Sinal de TV Digital	156
8.7	Avaliação dos Resultados Obtidos.....	160
9	Conclusão	162
	Referências	166
	Apêndice A.....	173
	Apêndice B.....	176
	Apêndice C.....	178
	Apêndice D.....	179
	Apêndice E.....	181
	Apêndice F	183
	Apêndice G	184
	Apêndice H.....	185
	Anexo A1	186
	Anexo B1	187
	Anexo C1	188

1 Introdução

A sociedade moderna tornou-se dependente do espectro de rádio e é possível que este seja o recurso natural mais valioso na era da informação (CALABRESE; SNIDER, 2003). É igualmente possível que o espectro de rádio seja um dos recursos mais controlados do planeta.

Existem diversas regulamentações para utilização do espectro de rádio, mas de forma geral, os sistemas atuais de comunicação estão concentrados na faixa do espectro inferior a 10 GHz (STAPLE; WERBACH, 2004) e, devido a esta concentração, torna-se cada vez mais difícil inserir novos serviços ou adicionar recursos aos serviços existentes sem causar ou sofrer interferências.

Analisando o assunto por outra perspectiva, sugere-se que o problema não está relacionado à ocupação do espectro em si, mas sim a utilização ineficiente que fazemos dele. Informações sobre a ocupação preliminar do espectro podem ser obtidas através de documentos sobre o licenciamento das faixas de frequência, entretanto, detalhes essenciais sobre localização dos transmissores e potência destes podem não fazer parte da documentação disponível. Além disso, as licenças não especificam o tempo em que efetivamente uma faixa do espectro permanece ocupada (WANG, 2012).

Independentemente da abordagem adotada, a proliferação de serviços e aplicações sem fio (do inglês, *wireless*) é indiscutível e torna-se necessária a utilização inteligente dos recursos do espectro a fim de acomodar as demandas.

O conceito de rádio cognitivo (RC), introduzido por Joseph Mitola III (MITOLA, 2000), pode ser usado como ferramenta para alcançar uma utilização mais inteligente do espectro. Na visão inicial de Mitola o rádio cognitivo seria possível através da integração entre um modelo baseado na razão e o *software* do rádio, tornando o rádio “treinável” ao invés de simplesmente “programável”. Já Haykin (HAYKIN, 2005) define o rádio cognitivo como um rádio capaz de perceber a situação ao seu redor, aprender e adaptar seus parâmetros de operação de acordo com esse ambiente. Podemos perceber que existem definições distintas para o rádio cognitivo, algumas mais amplas, outras mais restritas, mas as definições compartilham ideias associadas à adaptabilidade e inteligência.

Seja pela escassez de espectro ou pelo gerenciamento ineficiente de sua utilização, o conceito de uma rede de rádios cognitivos (RRC) pode viabilizar a utilização dinâmica do espectro. O acesso oportunístico aos recursos do espectro pode proporcionar incremento no reuso de frequências e permitir aumento de capacidade para aplicações de comunicação.

A regulamentação do espectro de rádio está sujeita a normas internacionais e também a legislações locais, que normalmente sofrem variação de um país para outro. Esta variabilidade nas regras para utilização dos recursos do espectro faz com que bandas de frequência e serviços ofertados em um país operem em outras faixas noutro país. Mesmo com as diferenças na regulamentação, podemos dividir o espectro de rádio em duas grandes famílias: bandas licenciadas e não-licenciadas.

As bandas licenciadas são aquelas designadas com exclusividade para um usuário licenciado, como uma operadora de telefonia móvel, por exemplo. As bandas não-licenciadas são de uso livre e compreendem dispositivos WLAN IEEE 802.11 (2.4 GHz), dispositivos Bluetooth e fornos de micro-ondas (WYGLINSKI; NEKOVEE; HOU, 2010).

Aplicando-se o conceito de rede de rádios cognitivos torna-se importante definir os usuários conforme a faixa de frequência do serviço que utilizam. Um usuário primário (UP) utiliza serviços em uma faixa de frequência licenciada, enquanto que um usuário secundário (US) é um usuário da rede de rádios cognitivos, que utilizará porções disponíveis do espectro, licenciadas ou não.

A verificação da presença de um usuário primário é uma das tarefas mais complexas da rede de rádios cognitivos, pois exige grande confiabilidade. O sucesso das etapas posteriores depende da correta detecção dos sinais dos usuários primários. Na literatura sobre rádio cognitivo esta etapa é denominada sensoriamento de espectro (SS, do inglês *Spectrum Sensing*) e compreende uma grande variedade de métodos pelos quais a presença do usuário primário pode ser detectada.

Dentre os métodos de detecção conhecidos, as técnicas de detecção cega (do inglês, *blind techniques*), são de grande interesse no desenvolvimento desta área, pois não requerem conhecimento prévio sobre o usuário primário. Em

particular, a decomposição em subespaços (*Eigen*-decomposição) representa uma alternativa bastante promissora dentre as diversas técnicas cegas de detecção.

Numa tentativa de universalizar o acesso à internet banda larga, os espaços brancos (do inglês, *white spaces*) na banda de TV dos EUA foram abertos pela FCC (do inglês, *U.S. Federal Communications Commission*) para uso não licenciado (FCC 08-260, 2008) e (WYGLINSKI; NEKOVEE; HOU, 2010). Com variadas definições de rádio cognitivo sendo apresentadas na literatura, a necessidade de padronização dos conceitos e de regulamentação técnica cresceu. O IEEE (do inglês, *Institute of Electrical and Electronics Engineers*) criou então um grupo de trabalho visando a padronização da interface aérea cognitiva para WRANs (do inglês, *Wireless Regional Area Networks*) operando em canais de TV não utilizados das bandas VHF/UHF (do inglês, *Very High Frequency* e *Ultra High Frequency*) entre 54 e 862 MHz (BERLEMANN; MANGOLD, 2009). Esse grupo de trabalho deu origem a resolução IEEE 802.22 (2011), que proporciona regulamentação para acesso banda larga sem fio a partir de uma estação rádio-base (ERB) para áreas de baixa densidade populacional (BERLEMANN; MANGOLD, 2009).

Apesar da resolução IEEE 802.22 (2011) regulamentar um cenário particular, pode-se dizer que ela representa o primeiro grande passo na especificação de sistemas que pretendam operar de acordo com o conceito de rede de rádios cognitivos, sendo a proteção aos usuários primários uma das suas maiores preocupações.

Mesmo com a existência de regulamentação e diversas pesquisas, a rede de rádios cognitivos ainda não é uma realidade comercial. Existem inúmeros desafios a serem superados até que a implantação destas redes possa tornar-se uma prática comum. Em se tratando de uma área onde ainda há muito a ser descoberto e solucionado, não é incomum observarmos a combinação de diversos recursos e técnicas na busca de soluções.

Como mencionado anteriormente, as diversas definições de rádio cognitivo compartilham a ideia de “inteligência”. Da mesma forma, existem diversas técnicas de inteligência artificial disponíveis dentre as ferramentas de engenharia. As Redes Neurais Artificiais (RNAs) são uma das técnicas de inteligência artificial disponíveis para análise de padrões e tendências. Assim como as técnicas cegas de sensoriamento de espectro, elas também não requerem conhecimento prévio sobre

os dados para serem capazes de analisá-los. Dessa forma, é bastante razoável considerar a união do conceito de inteligência associado a ambos os assuntos, propondo soluções para problemas ainda em discussão no universo do rádio cognitivo.

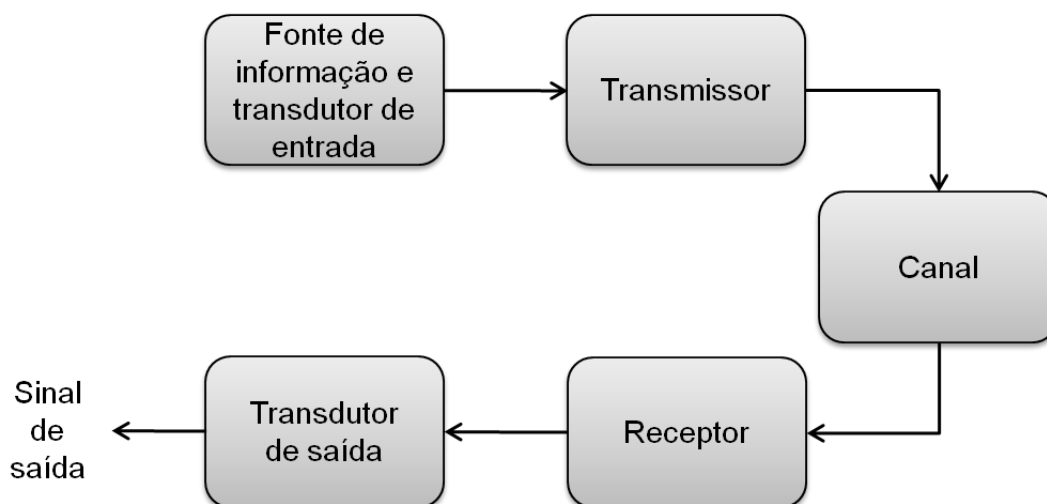
As redes neurais do tipo RBF (do inglês, *Radial Basis Function*) são aproximadoras universais. As redes neurais RBF possuem custo computacional de treinamento reduzido quando comparadas a uma rede MLP (do inglês, *Multilayer Perceptrons*) (DE CASTRO, 2001). Elas também apresentam excelente capacidade de aprendizado e generalização. Estas foram algumas das razões pelas quais as redes RBF foram escolhidas para utilização neste trabalho.

A proposta deste trabalho é elaborar um classificador de sinais capaz de determinar a presença ou não de um usuário primário num determinado canal do espectro de rádio. Para alcançar tal objetivo é proposta a decomposição da matriz de covariância do sinal em subespaços (*Eigen*-decomposição), visando extração de características que possam indicar a presença de usuário primário. A decomposição do sinal permitirá a determinação de bancos de filtros com os quais novos sinais poderão ser comparados, possibilitando assim a classificação de sinais por similaridade de características. Também é proposta a utilização de redes neurais RBF para análise destas características e decisão sobre a ocupação do espectro. Ao longo deste trabalho serão detalhadas as características construtivas do classificador proposto.

2 Transmissão em Canais Sem Fio

Rádio é uma palavra usada para definir um sistema envolvendo a transmissão e recepção de uma onda eletromagnética na qual foi inserida alguma forma de informação (OLEXA, 2005). A transmissão da informação pode ser feita de forma unidirecional, onde um transmissor envia informação para vários receptores, ou de forma bi-direcional, quando transmissores e receptores enviam e recebem informações. No caso da comunicação bi-direcional, o conjunto transmissor e receptor é conhecido como *transceiver*. A Figura 2.1 ilustra o processo de transmissão de informação.

Figura 2.1 – Diagrama em blocos de um sistema de comunicação



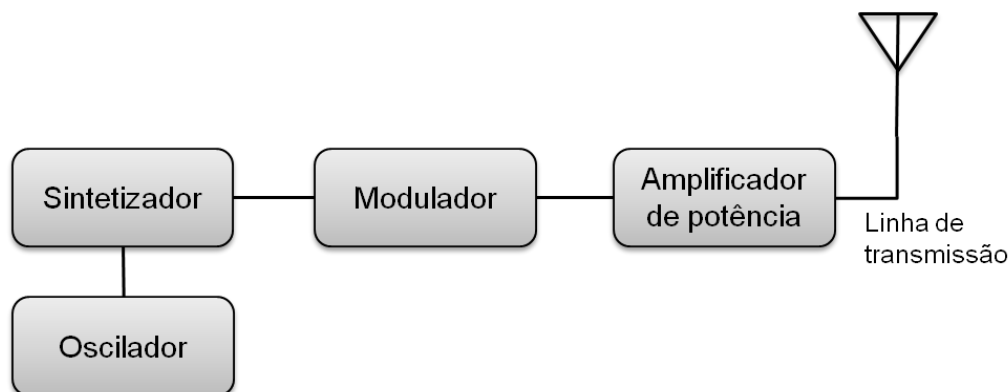
Fonte: adaptado de Proakis; Salehi (2002)

Os blocos de transdutores são normalmente necessários para converter a informação em sinal elétrico passível de ser transmitido. Também é comum uma operação contrária no receptor.

2.1 Transmissor de RF

O transmissor é o responsável pela geração do sinal de radiofrequência que contém a informação a ser transmitida. Ele é formado por blocos com funções específicas.

Figura 2.2 – Blocos de um transmissor de RF



Fonte: adaptado de Olexa (2005)

O oscilador é responsável pela geração do sinal base de RF na frequência desejada para operação do transmissor. Seu funcionamento baseia-se nos princípios de amplificação, *feedback* e ressonância. Nos sistemas de comunicação atuais requer-se operação estável numa ampla faixa de frequências, entretanto os osciladores operam numa frequência única. Para contornar esse problema, utiliza-se um sintetizador de frequência (*frequency synthesizer*), que de forma resumida pode ser descrito como um oscilador digital capaz de tornar o transmissor sintonizável.

O modulador é o bloco responsável por adicionar a informação a ser transmitida à onda portadora (*carrier wave*). É possível transmitir informação através da modulação de qualquer das propriedades da onda portadora: tempo, frequência, amplitude ou fase. Posteriormente algumas técnicas de modulação serão descritas neste trabalho.

A função do bloco de amplificador de potência (*power amplifier*) é amplificar o sinal de forma que ele tenha energia suficiente para vencer o percurso entre transmissor e receptor. Parâmetros como potência de saída, linearidade e eficiência são importantes na escolha do amplificador (OLEXA, 2005).

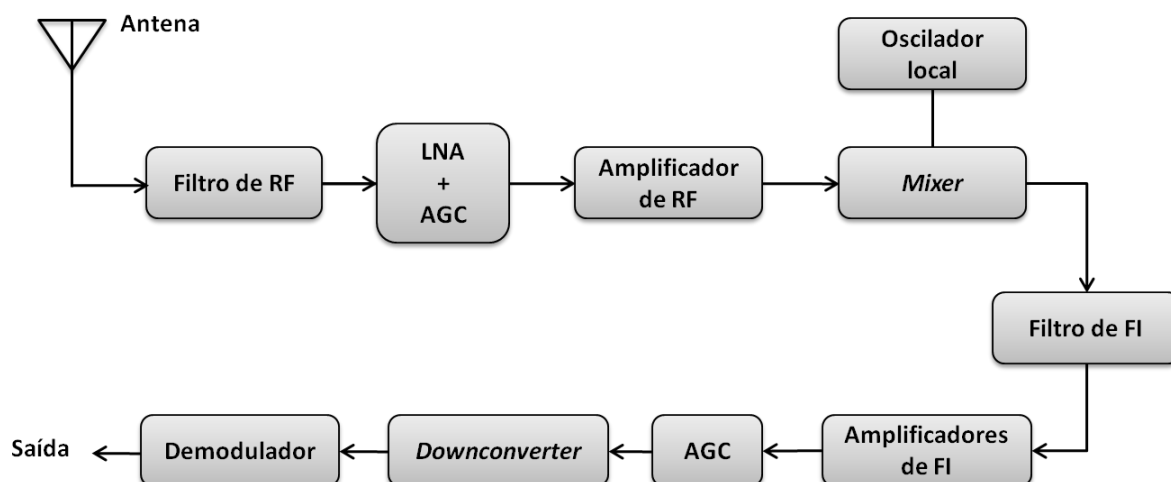
O conjunto final do transmissor é composto pela antena e pela *feedline* (linha de transmissão entre o estágio de amplificação e a antena). A antena é o elemento responsável por irradiar o sinal a ser transmitido. Existe uma miríade de tipos, formatos e tamanhos de antenas. A escolha de um modelo em particular está relacionada com a frequência de operação, sendo que cada antena possui atributos que a tornarão adequada para um propósito específico (OLEXA, 2005). A escolha da *feedline* é muito importante e deve buscar-se o casamento de impedâncias entre ela

e a antena, garantido assim que a energia flua com o mínimo de reflexão (VSWR, do inglês *voltage standing wave ratio*).

2.2 Receptor de RF

No receptor de RF ocorre o processo inverso, ou seja, a informação é extraída do sinal que foi recebido.

Figura 2.3 – Blocos de um receptor de RF



Fonte: a autora.

A onda eletromagnética incidindo na antena é transformada em sinal AC que será encaminhado ao amplificador de RF, entretanto, o sinal recebido foi atenuado durante a sua transmissão através do canal. Além disso, o sinal também está interferido com sinais oriundos de outras fontes e ruídos. Portanto, a primeira ação é filtrar o sinal (com um filtro passa-banda, por exemplo) a fim de remover qualquer sinal que esteja fora da banda de interesse (OLEXA, 2005).

O LNA (do inglês, *Low Noise Amplifier*) é projetado para lidar com sinais muito fracos. Como o sinal recebido é de ordem muito pequena e o fator de amplificação desejado é alto, o LNA precisa gerar o mínimo possível de ruído durante o processo de amplificação do sinal. Junto ao LNA existe o AGC (do inglês, *Automatic Gain Control*) cujo papel é tentar manter a amplitude do sinal relativamente constante, ou seja, reduzindo a faixa de variação do sinal apresentado aos estágios seguintes.

Como a ordem do sinal recebido é muito pequena é comum no receptor existirem vários estágios de amplificação do sinal. O amplificador de RF também é projetado para lidar com sinais muito pequenos, inserindo o mínimo possível de ruído. Existem vários parâmetros que podem ser utilizados para avaliar a efetividade do amplificador de RF, sendo que dois deles destacam-se: sensibilidade e ponto de interceptação (*intercept point*). A sensibilidade mede sua capacidade de detectar um sinal fraco, enquanto que o *intercept point* indica a capacidade de manter a linearidade na presença de sinais de grande magnitude (OLEXA, 2005). O AGC anteriormente mencionado controla o limite máximo de incremento de sinal de forma a proteger o sistema como um todo.

O sinal $r(t)$ na saída do amplificador de RF apresenta níveis ajustados para ser processado pelo *mixer*, que efetua o produto no tempo do sinal $r(t)$ com o sinal senoidal de frequência f_o gerado pelo oscilador local. Seja f_r a frequência central do espectro do sinal $r(t)$. Idealmente, o produto efetuado no *mixer*, que também é denominado de heterodinação, tem como efeito transladar o espectro de $r(t)$ centrado em f_r para duas novas frequências centrais: $(f_r + f_o)$ e $(f_r - f_o)$. Na prática, devido à não idealidades no *mixer*, é usual que ocorram produtos de heterodinação em sua saída também nas frequências f_r e f_o . O único sinal de interesse é o originado pela diferença $(f_r - f_o)$, ou seja, o de frequência mais baixa.

Estes sinais são encaminhados ao filtro de frequência intermediária (FI) que está sintonizado apenas na frequência da diferença $(f_r - f_o)$, eliminando assim todas as outras. A etapa de amplificadores de FI executa novas amplificações do sinal. Apesar de todos os processos executados nas etapas anteriores, podem existir ainda sinais fortes (picos) que estejam dentro da faixa de frequência do filtro de FI. A adição de um segundo AGC é opcional e pode prevenir a saturação do conversor A/D presente no demodulador. O bloco *Downconverter* realiza a conversão do sinal para banda-base, a ser abordada na Seção 2.4.

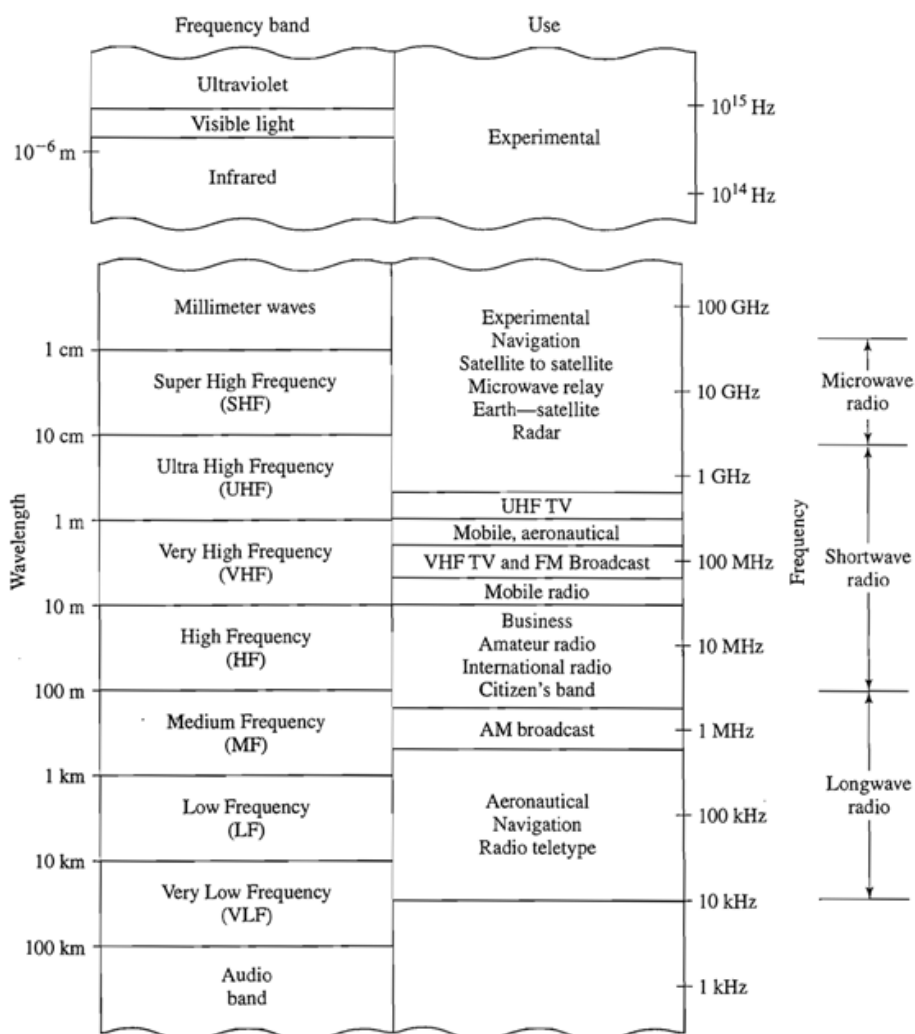
Finalmente, o demodulador executa a operação de extração da informação que foi transmitida.

2.3 Canais e Multipercurso

Como mostrado na Figura 2.1, entre o transmissor e o receptor de RF existe o canal de comunicação, que é o meio físico pelo qual o sinal propaga-se. O sinal que é recebido pelo receptor está degradado por outros sinais e ruídos além de ter sofrido distorções causadas pelo canal de comunicação.

O canal de comunicação pode ser de diversos tipos, tais como: *wireline* (fio ou cabo), *wireless* (sem fio), acústico ou óptico. Neste trabalho o canal *wireless* é o objeto de interesse. A propagação do sinal no canal *wireless* está associada com a faixa de frequência e a antena a ser utilizada. A Figura 2.4 ilustra as bandas de frequência para o canal *wireless*.


Figura 2.4 – Bandas de frequência para canal wireless



O canal de comunicação pode ser modelado matematicamente, de acordo com o tipo de distorção que ele insere no sinal.

O mais simples dos modelos de canais de comunicação é o AWGN (do inglês, *Additive White Gaussian Noise*), indicado na Figura 2.5. Neste modelo o sinal transmitido $s(t)$ é corrompido por um processo de ruído randômico aditivo $n(t)$. Este tipo de ruído é estatisticamente caracterizado como um processo de ruído Gaussiano e seu uso resulta num modelo de canal matematicamente tratável e largamente utilizado para representar o canal nos sistemas de comunicação atuais (PROAKIS; SALEHI, 2002).


Figura 2.5 – Canal AWGN



Fonte: adaptado de Proakis; Salehi (2002).

Outro modelo de canal extremamente importante é o canal AWGN limitado em banda. Este modelamento de canal é muito útil já que na maioria dos sistemas de comunicação é necessário garantir que o sinal transmitido não exceda a largura de banda do canal, ou seja, não interfira em outros canais. Geralmente estes canais são matematicamente caracterizados como um filtro linear (PROAKIS; SALEHI, 2002).

Figura 2.6 – Canal AWGN limitado em banda



Fonte: adaptado de Proakis; Salehi (2002)

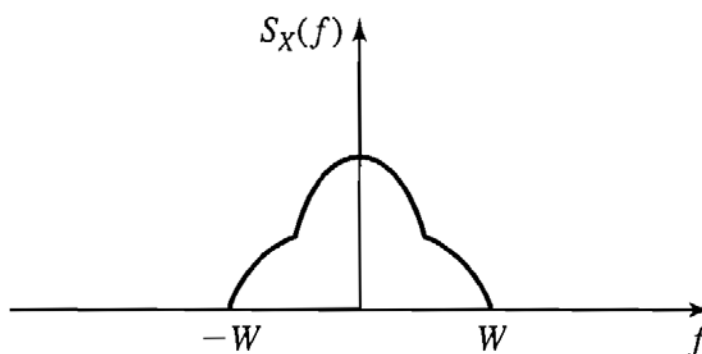
A capacidade de um canal AWGN é estabelecida pelo teorema de Shannon-Hartley (SKLAR, 2001):

$$C = W \log_2 \left(1 + \frac{S}{N} \right) \text{ bits/s} \quad (2.1)$$

Onde S é a potência média do sinal recebido, N é a potência média do ruído aditivo e W é a largura de banda do canal.

Um processo randômico com largura de banda limitada é aquele cuja densidade espectral de potência ocupa uma banda finita. Quase todos os processos encontrados na natureza são limitados em largura de banda porque há limite para a largura de banda nos sistemas físicos (PROAKIS; SALEHI, 2002).

Figura 2.7 – Espectro de potência de um processo limitado em banda

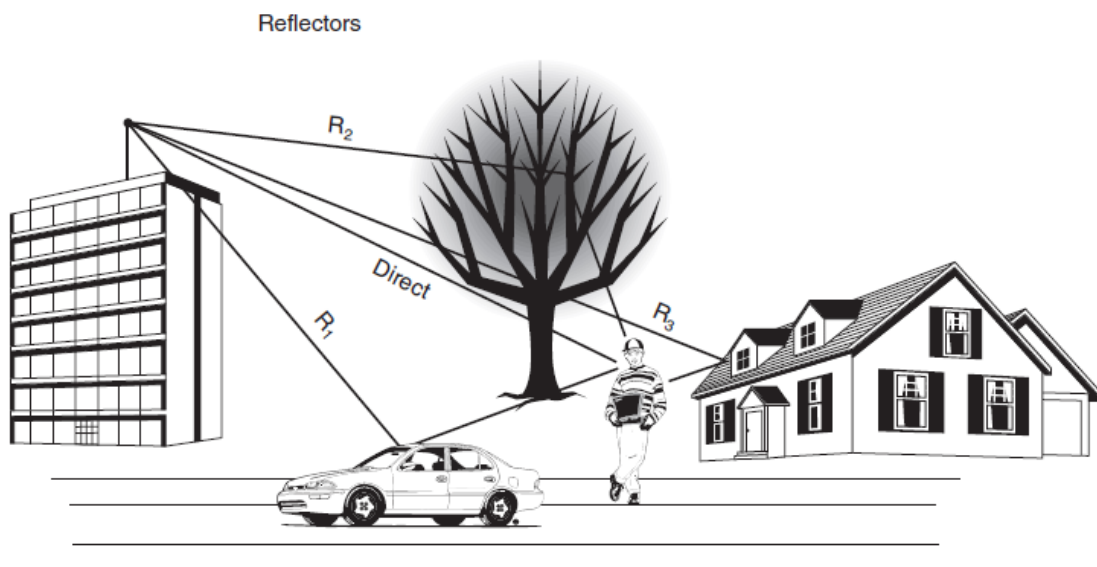


Fonte: Proakis; Salehi (2002)

Um sinal transmitido num canal modelado como AWGN limitado em banda precisa satisfazer as restrições de largura de banda que são impostas pelo canal.

O sinal transmitido num canal *wireless* propaga-se por múltiplos caminhos até chegar ao receptor. Este efeito é denominado de multipercurso (*multipath*) e é causado por reflexão, absorção, difração e espalhamento da energia eletromagnética por objetos ou discontinuidades do meio no percurso entre o transmissor e o receptor. Os caminhos que o sinal pode percorrer possuem tamanhos distintos, o que faz com que múltiplas versões do sinal atinjam o receptor em momentos também distintos, com um atraso proporcional ao comprimento do caminho percorrido (GHAVAMI; MICHAEL; KOHNO, 2007). A Figura 2.8 ilustra um cenário do multipercurso.

Figura 2.8 – Exemplo de multipercurso




Fonte: Olexa (2005)

As múltiplas versões do sinal que atingem o receptor podem somar-se de forma construtiva ou destrutiva. O *delay spread* é uma métrica indicativa do quanto o sinal foi diluído no tempo. O *maximum delay time spread* indica o intervalo de tempo durante o qual reflexões (versões) do sinal com energia significativa chegam ao receptor (GHAVAMI; MICHAEL; KOHNO, 2007).

Nos sistemas de comunicação, a informação é codificada e transmitida em forma de símbolos. A interferência inter-simbólica (ISI, do inglês *Inter-Symbol Interference*) é uma forma de distorção do sinal na qual um símbolo interfere nos símbolos subsequentes, devido à sobreposição de símbolos. A ISI é usualmente causada pelo multipercurso e é um efeito indesejado porque causa erros na detecção da informação. A Figura 2.9 ilustra a ISI.

Figura 2.9 – ISI causada por multipercurso



Fonte: National Instruments (2013)

A utilização de técnicas de equalização ou de códigos corretores de erro estão entre as formas de mitigar os efeitos do canal *wireless* e da ISI nos sistemas de comunicação.

2.4 Banda-base

Nos sistemas de comunicação a informação passa por algum processo de digitalização, normalmente composto por etapas de amostragem, quantização e codificação, que resulta em sua transformação numa sequência de dígitos binários.

Estes dígitos binários precisam ser transmitidos por um canal de comunicação, entretanto, não existem canais apropriados para transmissão de dígitos binários sem que estes sejam primeiramente transformados em formas de onda compatíveis com o canal pelo qual deseja-se transmitir a informação (SKLAR, 2001).

O termo banda-base (do inglês, *baseband*) é um adjetivo que descreve sinais e sistemas cuja faixa de frequência é medida desde valores próximos a zero Hertz até uma dada frequência de corte (máxima largura de banda ou frequência mais alta do sinal). *Baseband* é um sinônimo para passa-baixa (*lowpass*) ou não-modulado, pois se refere à faixa de frequência original de um sinal, antes dele sofrer qualquer tipo de conversão ou modulação para outra faixa de frequência.

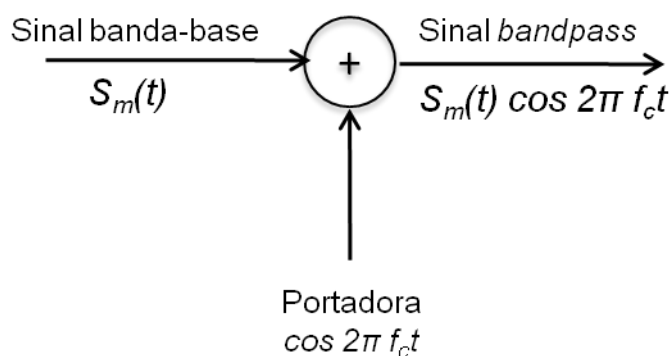
Um *baseband channel* é aquele cuja banda de passagem inclui a frequência zero, enquanto um *bandpass channel* tem sua banda de passagem bastante afastada da frequência zero (PROAKIS; SALEHI, 2002).

Para *baseband channels*, a forma de onda compatível para transmissão de informação são pulsos (SKLAR, 2001). Quando a informação é transmitida por um *baseband channel*, não há necessidade de utilizar-se uma onda portadora (*carrier frequency*).

Nos sistemas de comunicação atuais muitos canais são limitados em largura de banda, ou seja, *bandpass channels*. Nestes casos o sinal que carrega a informação é inserido numa onda portadora, cuja frequência é adequada à banda passante do canal. Diz-se que o sinal é transmitido por modulação de portadora (*carrier modulation*) (PROAKIS; SALEHI, 2002).

A conversão de um sinal *baseband* em *bandpass* é realizada através da multiplicação do sinal em *baseband* por uma portadora senoidal na forma $\cos 2\pi f_c t$ onde f_c é a frequência da portadora e corresponde também a frequência central do canal.


Figura 2.10 – Processo de modulação de portadora



Fonte: adaptado de Proakis; Salehi (2002).

A transformação do sinal de *baseband* para *bandpass* desloca o espectro de frequência da informação de acordo com f_c e coloca o sinal a ser transmitido dentro da faixa de frequência adequada ao *bandpass channel*.

Figura 2.11 – (a) Espectro de um sinal *baseband* e (b) espectro do mesmo sinal modulado em amplitude



Fonte: Proakis; Salehi (2002).

O processo de *carrier modulation* é revertido no receptor de RF. Neste trabalho, os sinais utilizados para análise estão todos em banda-base.

2.5 Modulação de Sinais

A modulação de portadora é um passo essencial para todos os sistemas envolvendo transmissão de rádio (SKLAR, 2001). O processo de modular um sinal consiste em transformá-lo numa forma de onda compatível com as características do canal pelo qual desejamos transmiti-lo. Entretanto, a necessidade de modulação não reside apenas nas limitações impostas pelo canal.

As ondas eletromagnéticas são transmitidas por antenas e sabe-se que o seu tamanho depende do comprimento de onda da frequência de operação. A transmissão de sinais em *baseband* implica em antenas maiores, e em alguns casos, de tamanhos simplesmente impraticáveis.

Através de técnicas de modulação é possível transmitir mais de um sinal em um único canal. Também existem técnicas de modulação que podem reduzir os efeitos da interferência.

A seguir algumas técnicas de modulação correspondentes a sinais utilizados na validação deste trabalho serão abordadas.

2.5.1 FM

Como mencionado na Seção 2.1, a modulação pode ser realizada através das propriedades da onda portadora: tempo, frequência, amplitude ou fase. Na modulação FM (do inglês, *Frequency Modulating*) é realizada a variação da frequência da portadora.

Seja:


- $V_m(t)$ o sinal *baseband* contendo a informação
- $V_c(t) = V_{co} \sin(2\pi f_c t + \phi)$ o sinal senoidal representando a portadora, com amplitude máxima V_{co} , frequência f_c e fase ϕ .

A modulação em frequência (FM) do sinal $V_m(t)$ resulta em:

$$V_{FM}(t) = V_{co} \sin(2\pi [f_c + (\Delta f / V_{mo}) V_m(t)] t + \phi) \quad (2.2)$$

O termo correspondente à frequência da portadora foi substituído por um termo de frequência variante no tempo e foi introduzido o termo Δf , representando o pico de desvio de frequência. Percebe-se que o termo $f_c + (\Delta f / V_{mo}) V_m(t)$ varia entre os extremos compreendidos por $f_c - \Delta f$ e $f_c + \Delta f$. O parâmetro Δf indica o quão afastado da frequência original o sinal FM pode estar.

Figura 2.12 – Sinal FM



A FM é uma técnica de modulação que apresenta alta imunidade ao ruído (PROAKIS; SALEHI, 2002). É amplamente utilizada para transmissão de música em alta fidelidade e em sistemas de comunicação ponto a ponto, onde a potência do transmissor é limitada.


2.5.2 Orthogonal Frequency Division Multiplexing

Como mencionado na Seção 2.3 a ISI (*intersymbol interference*) pode ocorrer em decorrência do multipercurso. Neste caso ocorre a distorção do sinal, devido ao *delay spread*, que faz com que um símbolo sobreponha-se aos símbolos subsequentes, causando redução do desempenho de transmissão.

Se um *bandpass channel* foi utilizado para transmissão significa que o sinal em banda-base foi trasladado para a frequência adequada ao *bandpass channel*. Neste caso, existe uma única onda portadora (*single carrier*) transportando a informação.

Uma outra abordagem para tentar reduzir os efeitos danosos do canal de transmissão é subdividi-lo em vários canais. Nesta abordagem, cada subcanal possui uma largura de banda suficientemente estreita, de modo que as características de suas respostas em frequência aproximam-se do ideal (PROAKIS; SALEHI, 2002).

Figura 2.13 – Subdivisão da banda W de um canal em subcanais de largura de banda Δf




Fonte: Proakis; Salehi (2002).

Desta forma foram criados $K = W/\Delta f$ subcanais nos quais diferentes símbolos podem ser transmitidos simultaneamente, ou seja, uma multiplexação através de divisão de frequência (FDM, do inglês *Frequency-Division Multiplexing*).

A cada subcanal associa-se uma portadora, criando-se assim uma subportadora (*subcarrier*). A ortogonalidade entre as *subcarriers* é obtida através da seleção de uma taxa de transmissão de símbolos (*symbol rate* - $1/T$) igual à separação Δf de *subcarriers* adjacentes. Neste caso dizemos que as *subcarriers* são ortogonais no intervalo do símbolo (T).

O intervalo de um símbolo OFDM pode ser ajustado de forma a ser significativamente maior do que o *delay spread* do canal. Nos sistemas OFDM utiliza-se a inserção de um prefixo cíclico (CP, do inglês *Cyclic Prefix*) com duração maior ou igual ao *delay spread* do canal. Esta ação elimina a interferência nas portadoras do símbolo OFDM $n+1$ causada pelos ecos das portadoras do símbolo OFDM n . Em termos práticos, o prefixo cíclico é uma repetição do final do símbolo que é adicionada ao seu início, normalmente de tamanho variando entre $1/4$ e $1/32$ do tamanho do símbolo. O receptor descarta essa informação nas etapas de demodulação.

Figura 2.14 – Representação gráfica de oito *subcarriers* ortogonais formando um símbolo OFDM



Fonte: De Castro (2012).

O OFDM permite a transmissão de vários símbolos em paralelo, onde a duração do símbolo é aumentada proporcionalmente, o que reduz os efeitos da ISI (GHAVAMI; MICHAEL; KOHNO, 2007).

O OFDM proporciona flexibilidade, já que é possível transmitir informação em diferentes taxas de bits/símbolo em cada *subcarrier*. Uma *subcarrier* com SNR (do inglês, *Signal-to-Noise Ratio*) mais alta pode ser modulada para carregar mais bits/símbolo do que outra com SNR baixa (PROAKIS; SALEHI, 2002).

2.5.3 TV Digital

A transmissão digital de TV (DTV, do inglês *Digital Television*) não segue um único padrão no mundo inteiro, portanto diversas tecnologias de transmissão estão em uso. Na DTV a transmissão de áudio e vídeo é realizada através de sinais digitais, em faixas de frequência distintas das utilizadas para transmissão analógica. Muitos países estão substituindo a transmissão analógica por DTV e implantando padrões de transmissão (*broadcasting standards*) variados. Dentre os diversos padrões DTTB (do inglês, *Digital Terrestrial Broadcasting Standards*), destacam-se:

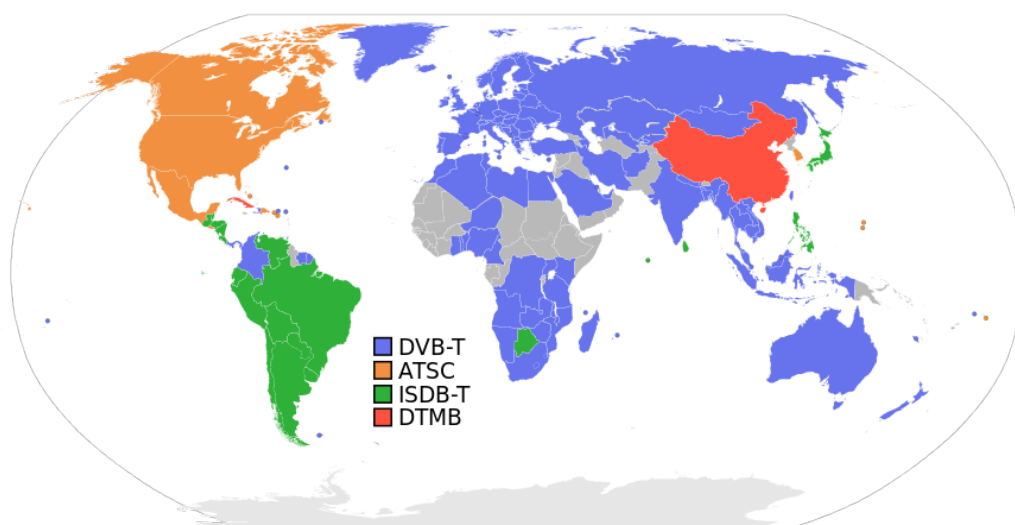
- ATSC (do inglês, *Advanced Television System Committee*), que utiliza oito níveis de banda lateral vestigial (8VSB, do inglês *8-Level Vestigial Sideband Modulation*) para a transmissão DTV. De forma resumida, 8VSB é uma modulação onde o sinal binário é convertido em uma representação octal, através da modulação em amplitude de uma portadora, que pode assumir um dentre oito níveis de amplitude (FCC OET Report 99-2, 1999). Este padrão foi adotado em países como Estados Unidos, Canadá e Coréia do Sul, dentre outros.
- DTMB (do inglês, *Digital Terrestrial Multimedia Broadcasting*), que adota TDS-OFDM (do inglês, *Time Domain Synchronous-OFDM*) e suporta transmissão de imagens em alta resolução para sistemas fixos e móveis, apresentando bastante flexibilidade quanto aos serviços ofertados (KARAMCHEDU, 2009). É o padrão desenvolvido e adotado pela China.
- ISDB-T (do inglês, *Integrated Services Digital Broadcasting Terrestrial*), que é um sistema projetado para prover boa recepção em receptores fixos ou móveis. Utiliza OFDM para modulação, suporta até três níveis de transmissão hierárquica, utiliza MPEG-2 e AAC para vídeo e áudio. A versão ISDB-T *International* utiliza H.264 e MPEG-4

AVC e foi adotada em grande parte da América do Sul e países de língua portuguesa na África.

- DVB-T (do inglês, *Digital Video Broadcasting Terrestrial*), que utiliza modulação COFDM (do inglês, *Coded OFDM*), MPEG-2 para áudio e vídeo e também suporta transmissão hierárquica. É o padrão adotado na Europa, Austrália e Nova Zelândia (ETSI EN 300 744, 2009).

A Figura 2.15 ilustra a utilização dos diversos sistemas no mundo.

Figura 2.15 – Sistemas de DTV ao redor do mundo



Fonte: DVB.org

Neste trabalho, sinais DVB-T foram utilizados para testes e validação.

2.6 Ruído

Nos sistemas de comunicação o ruído é uma perturbação randômica indesejada, que altera o sinal de comunicação, induzindo erros no sinal recebido pelo receptor quando comparado ao sinal originalmente transmitido. O ruído pode ser de origem natural ou gerado por artefatos e equipamentos criados pelo homem.

Existe diferença entre ruído, interferência e distorção. A distorção é um efeito indesejado pelo qual ocorre alteração na forma de onda do sinal de comunicação, normalmente causada pelo próprio equipamento de comunicação. A interferência, por sua vez, é a contaminação do sinal de comunicação por outros sinais oriundos de outras fontes humanas, como uma linha de transmissão de energia elétrica, por

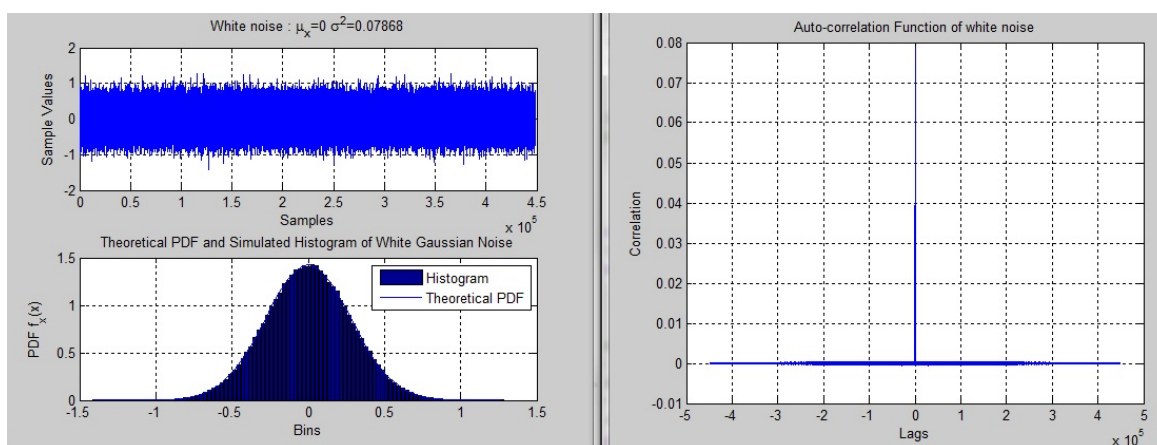
exemplo. A interferência não desaparece quando o sinal de comunicação está desativado.

Na validação deste trabalho foram utilizadas duas categorias de ruído: impulsivo e AWGN (do inglês, *Additive White Gaussian Noise*).

O ruído impulsivo causa falhas nos sistemas de comunicação, devido ao seu comportamento de curta duração e alta intensidade. Normalmente origina-se devido a descargas elétricas (raios) ou ignição de máquinas elétricas e motores.

O ruído AWGN é modelado de forma a mimetizar o efeito de processos randômicos da natureza. Ele apresenta uma distribuição Gaussiana no domínio tempo e possui distribuição de potência uniforme. A Figura 2.17 apresenta uma amostra de ruído AWGN gerada para teste do sistema.

Figura 2.16 – Ruído AWGN, PDF e função de auto-correlação



Fonte: a autora.

3 Rádios Cognitivos

O termo rádio cognitivo (RC) foi cunhado inicialmente por Joseph Mitola III (MITOLA, 2000) e visava representar a integração entre a inteligência computacional e o domínio de radiofrequência. Na sua visão inicial, os elementos do domínio de rádio seriam capazes de tomar decisões visando o bem do usuário durante a utilização do espectro de frequências. O objetivo sempre foi o de utilizar o espectro de forma mais eficiente, mas as decisões tomadas no âmbito do rádio cognitivo não necessariamente visavam o bem da rede, e sim o bem do usuário.

Este conceito inicial evoluiu, popularizou-se e sofreu reinterpretações, adquirindo um viés mais associado à adaptabilidade e visando o bem da rede ao invés do bem do usuário. Isso não significa necessariamente uma degradação do conceito, mas sim uma forma de interpretação mais alinhada com as necessidades atuais. A ideia que norteia o conceito de rádio cognitivo é a de que rádios possam tornar-se tão inteligentes quanto necessário a ponto de descobrir, de forma autônoma, como, quando e onde utilizar os recursos do espectro de frequência (MITOLA, 2000).

No universo do rádio cognitivo é importante salientar que adaptabilidade e cognição são conceitos distintos. Adaptabilidade requer ação que, normalmente, é executada após a percepção de alguma condição presente no ambiente. Um telefone celular operando em modo adaptativo, por exemplo, é capaz de alterar sua taxa de transmissão de dados de alta para baixa, uma vez que tenha detectado uma condição de sinal desfavorável a altas taxas de transmissão. Este mesmo telefone poderia observar as condições de sinal ao longo do tempo, realizar correlação destas condições com a sua localização, detectar a necessidade do usuário de permanecer conectado e, executar ações para atingir este objetivo, mesmo não tendo sido pré-programado para este caso específico. Nesta situação, este telefone estaria exibindo um comportamento cognitivo (MITOLA, 2006).

Segundo Fette (2006), rádios que percebem todo ou parte do seu ambiente são considerados sistemas conscientes (do inglês, *aware systems*), e essa consciência permite que tomem apenas decisões simples, tais como uma mudança

de protocolo. Um rádio que, de forma autônoma, modifica seus parâmetros de operação é considerado adaptativo. Apenas quando um rádio é consciente, adaptativo e capaz de aprender ele é considerado um rádio cognitivo.

A capacidade da tecnologia em aumentar a eficiência na utilização do espectro cresce num ritmo inferior à demanda por bandas adicionais (BERLEMANN; MANGOLD, 2009). Mesmo que o conceito original de rádio cognitivo tenha sofrido alguma simplificação com foco na adaptabilidade, ainda assim é uma alternativa bastante promissora para a questão da escassez de espectro.

3.1 Acesso Dinâmico ao Espectro

O rádio cognitivo é a tecnologia que, de forma dinâmica, permite melhor utilização do espectro (CHEN; PRASAD, 2009). Através do acesso dinâmico ao espectro (DSA, do inglês *Dynamic Spectrum Access*) é possível compartilhar canais *wireless* com usuários primários, de maneira oportunística. Desta forma, o rádio cognitivo é vislumbrado com capacidade de prover grande largura de banda para usuários móveis, através de arquiteturas heterogêneas de redes sem fio e técnicas de DSA (CHEN; PRASAD, 2009).

Grande parte do espectro de rádio é alocado para serviços licenciados, o que tipicamente implica em uma transação comercial com pagamento de taxas para obtenção do privilégio. Portanto, as bandas licenciadas são aquelas designadas com exclusividade para um usuário licenciado. Os usuários primários utilizam serviços ofertados na banda licenciada.

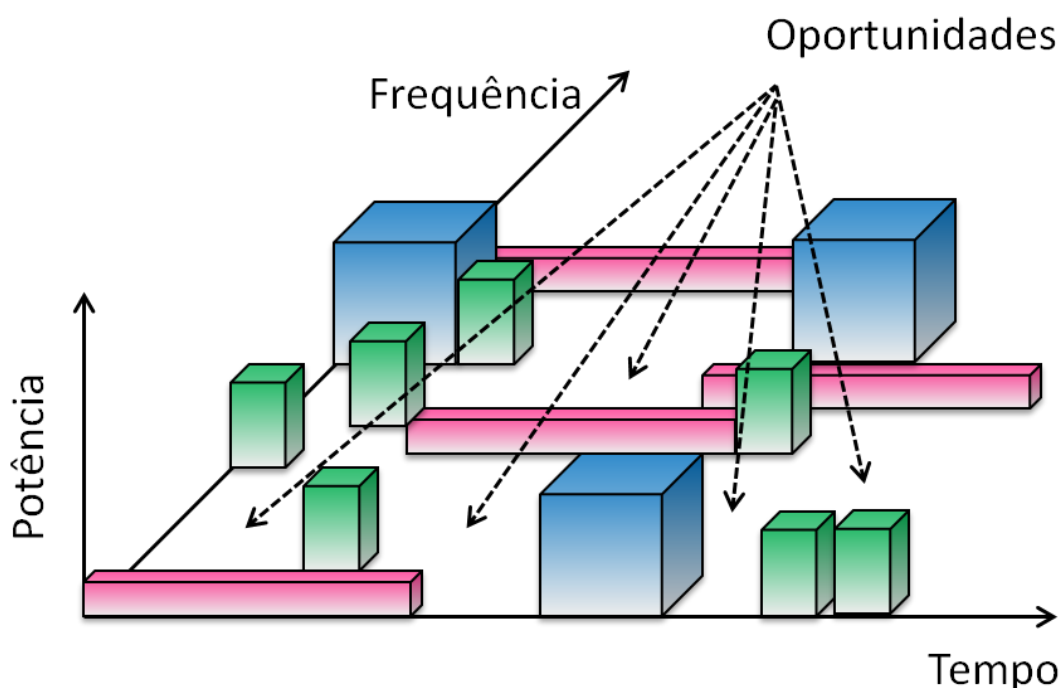
As bandas não-licenciadas são de uso livre e não estão sujeitas a regulamentação rigorosa. Os usuários secundários utilizarão porções disponíveis do espectro, licenciadas ou não. Exemplos de bandas não-licenciadas são as faixas utilizadas para dispositivos WLAN IEEE 802.11 (2.4 GHz), dispositivos *Bluetooth* e fornos de micro-ondas (WYGLINSKI; NEKOVEE; HOU, 2010).

O acesso licenciado ao espectro geralmente é definido por frequência de operação, potência de transmissão, tipo de uso e duração da licença. Também é comum que o detentor da licença cumpra as especificações associadas à faixa cuja licença ele detém. Esses limites e restrições impostos pelas regras do licenciamento

acabam resultando em baixa utilização do espectro. Essencialmente, a atual forma estática de licenciamento do espectro proporciona o surgimento de oportunidades (*spectrum holes* ou *white spaces*) (HOSSAIN; NIYATO; HAN, 2009).

As oportunidades (*spectrum holes* ou *white spaces*) são definidas como faixas de frequência alocadas para usuários licenciados, mas que em alguns locais e em alguns momentos não são utilizadas por seus detentores, sendo, portanto passíveis de acesso por usuários não-licenciados (HAYKIN, 2005). A Figura 3.1 ilustra as oportunidades.

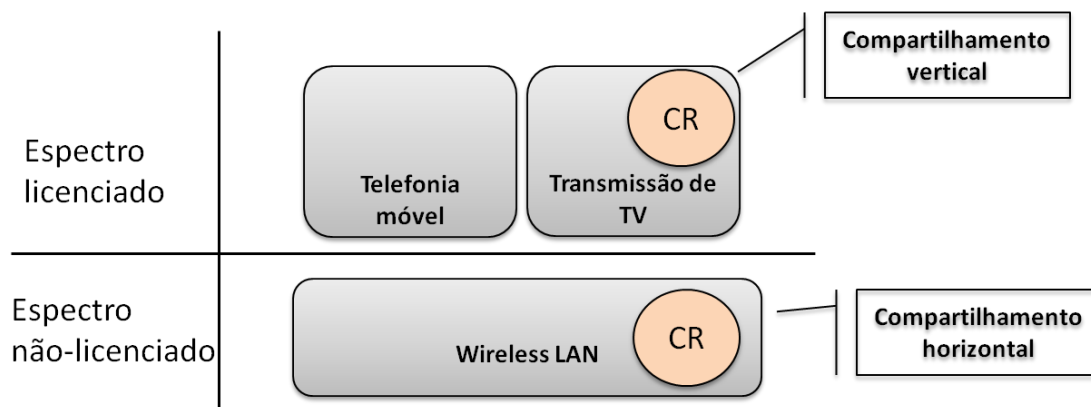
Figura 3.1 – Oportunidades para acesso



Fonte: a autora.

O compartilhamento do espectro pode ser classificado como horizontal e vertical. No compartilhamento vertical, sistemas primários e secundários compartilham uma mesma faixa do espectro. Nessa modalidade os usuários primários convivem com os secundários, entretanto, os usuários primários possuem acesso prioritário aos recursos da rede. O compartilhamento horizontal ocorre quando sistemas com regulamentação similar utilizam a mesma banda, por exemplo, um usuário do rádio cognitivo compartilhando a faixa de 2.4 GHz com sistemas WLAN (do inglês, *Wireless Local Area Networks*). A Figura 3.2 ilustra o compartilhamento vertical e horizontal.

Figura 3.2 – Compartilhamento horizontal e vertical de espectro



Fonte: a autora.

Com base no método de coexistência entre os usuários primários e secundários, o acesso ao espectro é classificado em *overlay access* (OA) e *underlay access* (UA). No *overlay access* (OA) o usuário secundário pode acessar apenas porções do espectro não utilizadas pelos usuários primários. Na abordagem *underlay access* (UA) o usuário primário tolera um certo nível pré-estabelecido de interferência, possibilitando assim, que o usuário secundário acesse faixas do espectro, mesmo que estejam ocupadas por usuários primários (WYGLINSKI; NEKOVEE; HOU, 2010). A Figura 3.3 demonstra ambas as formas de acesso ao espectro.

Figura 3.3 – Acesso *Overlay* e *Underlay*

(a) Acesso *Overlay*

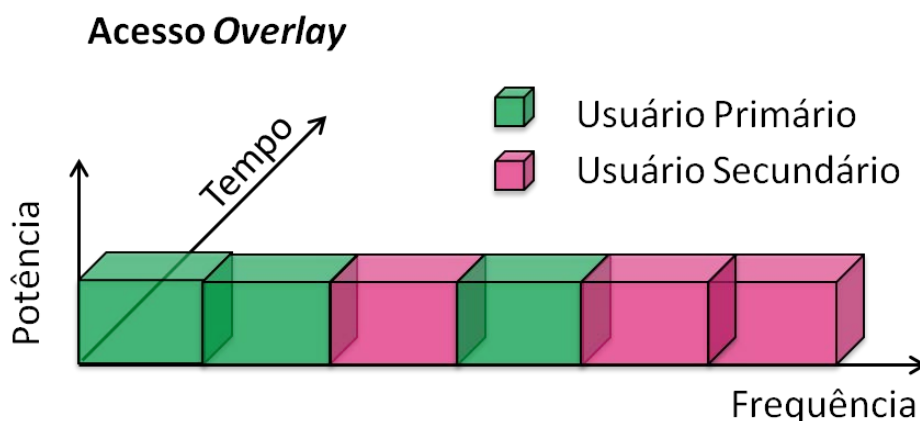



Figura 3.3 – Acesso *Overlay* e *Underlay*(b) Acesso *Underlay*

Fonte: a autora.

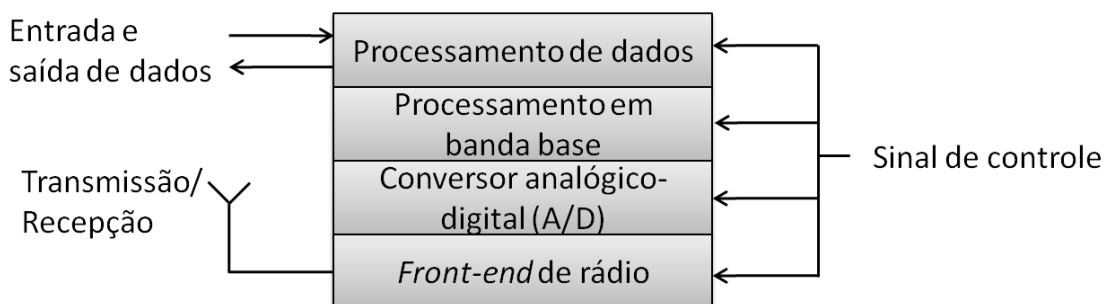
3.2 *Software-Defined Radio* (SDR)

Um *transceiver* que possa adaptar-se em função do ambiente em que está inserido representa uma flexibilidade enorme em termos de utilização de espectro de rádio. Segundo a FCC (*U.S. Federal Communications Commission*), a maioria dos CRs serão, muito provavelmente, do tipo SDR (WYGLINSKI; NEKOVEE; HOU, 2010). Embora este tipo de rádio não seja um requerimento obrigatório para o rádio cognitivo, é difícil visualizar outra forma de viabilizar a sua implantação em larga escala sem o SDR.

O SDR é um rádio cujos parâmetros de operação, tais como frequência da portadora, largura de banda e modulação, são definidos por software (FETTE, 2006). De forma simplificada, num SDR as funções que normalmente são executadas por dispositivos físicos (*hardware*) são substituídas por módulos de *software*, de forma que ele torna-se um rádio definido por *software*. Ao substituir-se *hardware* por *software* espera-se adquirir flexibilidade quanto à forma de operação do rádio, sendo que um SDR ideal deve ser capaz de operar em diversas configurações.

Considerando o SDR como parte fundamental da evolução do rádio cognitivo, é possível presumir que ele precise adquirir inteligência e real capacidade cognitiva. Na Figura 3.4 está representada a estrutura de um SDR, na qual pode ser observada uma *interface* de controle (*control signal*) pela qual o SDR recebe as informações necessárias para sua operação.

Figura 3.4 – *Transceiver SDR*



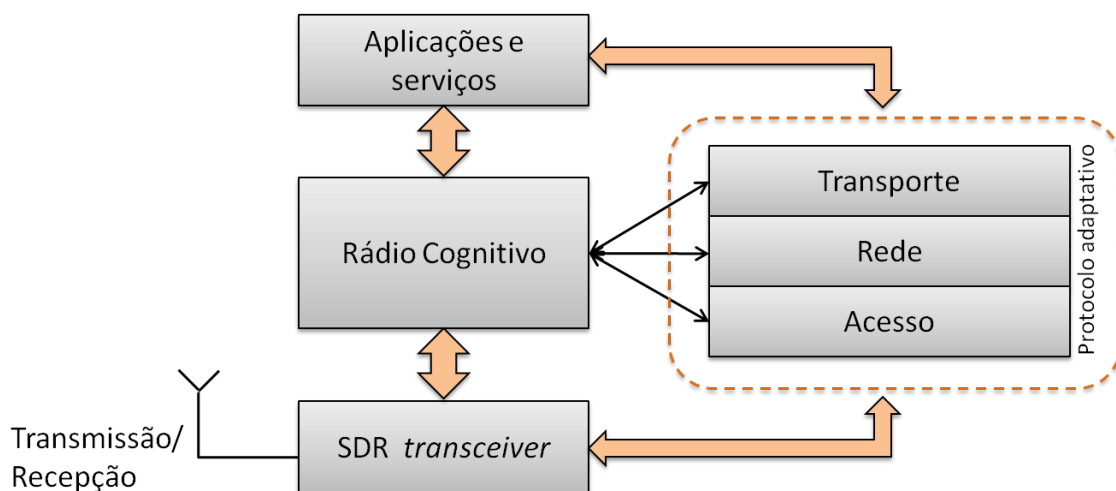
Fonte: a autora.

3.3 Arquitetura e Funções da RRC

A rede de rádios cognitivos (RRC), implementada com base no SDR (*Software-Defined Radio*), possui como objetivos principais melhorar a utilização do espectro de frequência e prover comunicação sem fio de alta confiabilidade e eficiência (HOSSAIN; NIYATO; HAN, 2009).

A RRC precisa gerenciar todos os elementos constituintes da rede, portanto, existe comunicação entre estes, através de protocolos específicos. Informações de controle, assim como informações oriundas do ambiente de RF (requisições de transmissão, variação de qualidade de canais, atividade dos usuários primários, etc.) precisam ser repassadas entre os elementos do sistema. A Figura 3.5 apresenta as camadas de protocolos da RRC.

Figura 3.5 – Camadas de protocolos da RRC

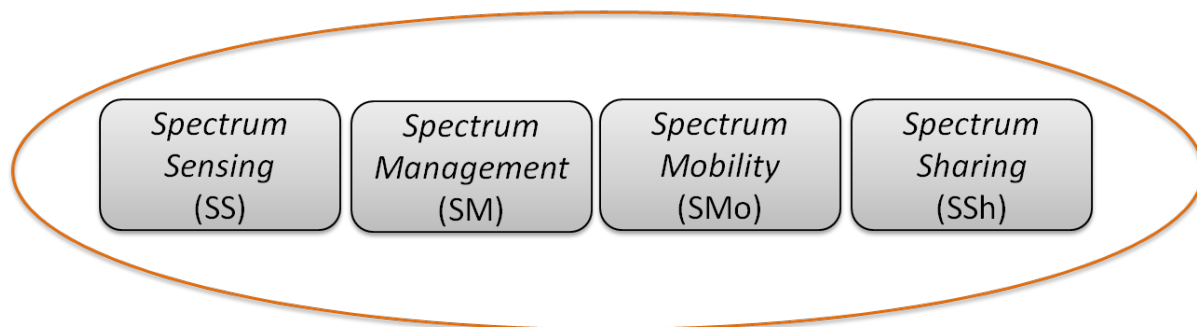


Fonte: adaptado de IEEE 802.22 (2011).

Segundo Chen e Prasad (2009), cada rádio cognitivo (RC) em uma rede de rádios cognitivos (RRC) precisa ser capaz de:

- Determinar as porções disponíveis do espectro, na etapa de sensoriamento de espectro (SS, do inglês *Spectrum Sensing*).
- Selecionar o melhor canal disponível, na etapa de gerenciamento de espectro (SM, do inglês *Spectrum Management*).
- Coordenar o acesso ao canal selecionado com outros usuários, na etapa de compartilhamento de espectro (SSh, do inglês *Spectrum Sharing*).
- Desocupar o canal quando um usuário licenciado for detectado, na etapa de mobilidade de espectro (SMo, do inglês *Spectrum Mobility*).

Figura 3.6 - Principais funções do rádio cognitivo.

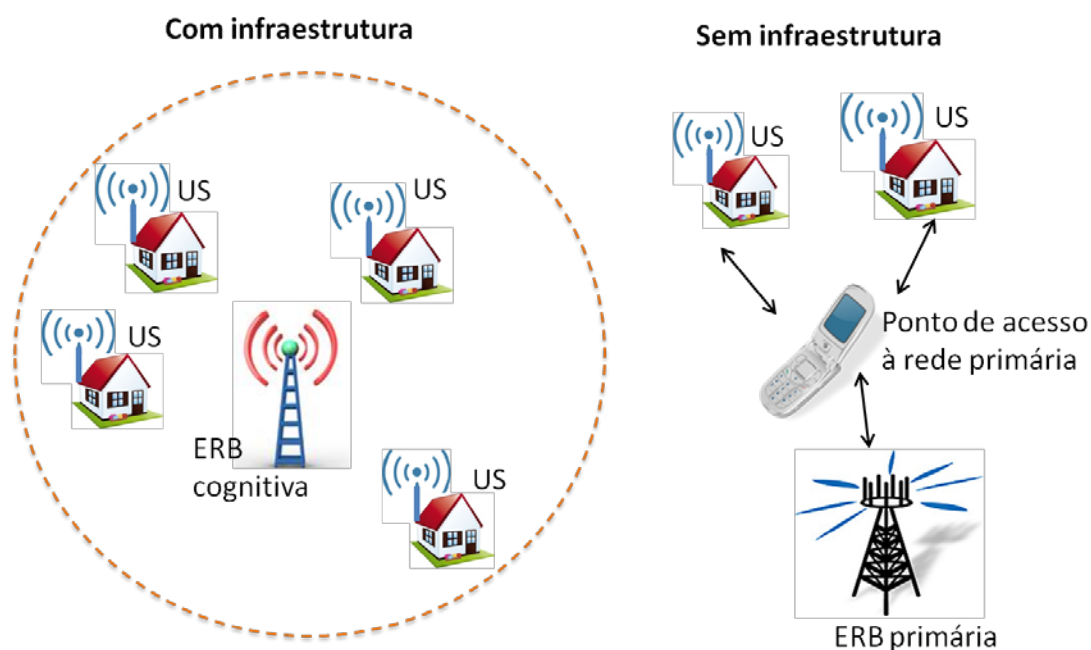


Fonte: a autora.

No Capítulo 4 a etapa de sensoriamento do espectro será abordada em maior detalhamento, pois está fortemente conectada à proposta aqui apresentada. A importância da etapa de gerenciamento de espectro será também discutida em maiores detalhes no Capítulo 5.

Existem duas possibilidades quanto à arquitetura para a RRC: com infraestrutura e sem infraestrutura. No cenário com infraestrutura existe a estação rádio-base (ERB) e os dispositivos de usuário (CPE, do inglês *Customer Premise Equipment*), que são controlados pela ERB. Uma ERB e o seu conjunto de CPEs formam uma célula, que pode, ou não, comunicar-se com outras células (YU, 2011). No cenário sem infraestrutura não há ERB para controle da comunicação.

Figura 3.7 – Arquitetura com e sem infraestrutura



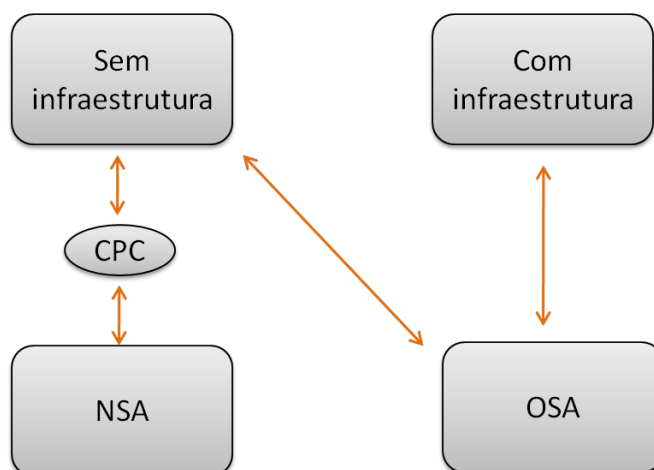
Fonte: a autora

O acesso ao espectro pode ser oportunístico (OSA, do inglês *Opportunistic Spectrum Access*) ou negociado (NSA, do inglês, *Negotiated Spectrum Access*). No cenário OSA o usuário secundário (US) acessa as oportunidades no espectro sem qualquer interação com o usuário primário (UP), ou seja, o UP não sabe da existência do US e vice-versa. Esta opção pode ser implementada numa arquitetura com ou sem infraestrutura, porém, no segundo caso, o CPE precisa ter grande capacidade de processamento e inteligência, pois será responsável por todas as funções que seriam realizadas pela ERB cognitiva.

No cenário NSA, o US acessa a rede através de negociação com a rede primária, ou seja, precisa negociar o acesso através de comunicação com um UP ou com um elemento que tenha função de ponto de acesso à rede primária. Nesta situação é preciso haver uma forma de comunicação entre UPs e USs. Para a troca de informação entre UPs e USs é prevista a utilização de um canal piloto (CPC, do inglês *Cognitive Pilot Channel*).

O cenário NSA elimina a ERB cognitiva, portanto, para comunicação entre o US e o UP torna-se um pré-requisito a existência do CPC (WYGLINSKI; NEKOVEE; HOU, 2010). A Figura 3.8 ilustra a relação entre os métodos de acesso e a infraestrutura.

Figura 3.8 – Relação entre métodos de acesso e infraestrutura



Fonte: a autora.

4 Sensoriamento do Espectro

A detecção da presença do usuário primário (UP) é crítica no rádio cognitivo (RC) por duas razões principais: é imperativo evitar que os usuários secundários (US) interfiram de forma danosa nos usuários primários (UP) e, é necessário identificar porções disponíveis do espectro. Na prática o desempenho da detecção é frequentemente comprometido por fatores como multipercurso, sombreamento (do inglês, *shadowing*) e questões de incerteza do receptor (AKYILDIZ; BALAKRISHNAN, 2010).

O sensoriamento do espectro pode ser conduzido de forma individual ou cooperativa. Na forma individual de sensoriamento, cada US realiza detecção no ambiente de rádio e toma decisões sobre a ocupação. Neste cenário, a detecção realizada por um dado US pode ser deficiente, caso ele esteja submetido a uma condição de multipercurso ou sombreamento, por exemplo. Na modalidade cooperativa de sensoriamento, um grupo de USs realiza a detecção de forma colaborativa, o que pode melhorar significativamente o desempenho da detecção (YU, 2011).

Hossain, Niyato e Han (2009) classificam as abordagens adotadas para o sensoriamento do espectro em:

- CCSS (do inglês, *Cooperative Centralized Spectrum Sensing*), na qual os usuários secundários (USs) realizam a detecção nos canais alvo e reportam os resultados para um controlador central. O controlador processa os resultados e os utiliza para decidir se o espectro pode ser acesso pelo US.
- CDSS (do inglês, *Cooperative Distributed Spectrum Sensing*), na qual os usuários secundários (USs) trocam entre si os resultados da detecção nos canais alvo. Neste cenário a decisão sobre o acesso ao espectro é tomada de forma local, por cada um dos USs. Este tipo de detecção não requer controle central.

- Redes de sensoriamento, na qual não são usados recursos dos USs para detecção do espectro, mas sim uma rede externa, dedicada para esta função. Nesta modalidade os resultados da rede de sensoriamento são enviados para o US, a fim de que ele possa tomar a decisão final sobre utilização do espectro. Esta abordagem retira do US a tarefa de detecção, reduzindo assim sua complexidade, mas requer uma infraestrutura extra que pode ter custo elevado.
- Banco de dados e predição, na qual o US mantém um banco de dados com informações de ocupação do espectro pelos usuários licenciados e, através de algoritmos de predição, é capaz de antecipar e identificar oportunidades.

A forma de executar a etapa de sensoriamento do espectro pode também ser uma combinação de abordagens.

A natureza do canal *wireless* pode impedir que um UP seja detectado, por questões de somreamento, multipercurso ou outra forma de bloqueio do sinal. Este é um problema fundamental que nenhuma abordagem individual de sensoriamento de espectro consegue resolver. As abordagens cooperativas são uma possível solução para este problema (WYGLINSKI; NEKOVEE; HOU, 2010).

4.1 Detecção de Oportunidades

A detecção de oportunidade depende da decisão entre duas hipóteses distintas: presença ou ausência de usuário primário (UP). Estas hipóteses foram formuladas por Chen e Prasad (2009) como:

$$y[n] = \begin{cases} w[n] & H_0 \\ hs[n] + w[n] & H_1 \end{cases} \quad n = 1, \dots, N \quad (4.1)$$

Sendo $y[n]$ o sinal complexo recebido pelo RC, $s[n]$ o sinal transmitido pelo UP e $w[n]$ o ruído AWGN. O fator h é a transmitância do canal entre o transmissor primário e o usuário secundário e N é o intervalo de observação. Se o canal não for ideal o termo $hs[n]$ é convoluído ao invés de multiplicado, situação em que h passa a ser a resposta ao impulso do canal. Desta forma, a hipótese H_1 indica a presença de UP enquanto H_0 representa ausência de UP.

São consideradas duas métricas para o processo de sensoriamento do espectro: probabilidade de alarme falso (PFA, do inglês *Probability of False Alarm*) e probabilidade de detecção (PD, do inglês *Probability of Detection*). No primeiro caso o RC declara que o UP está presente quando na verdade a porção do espectro analisada está livre. Já no segundo caso, o RC corretamente declara que o UP está presente quando ele de fato está utilizando o espectro.

É estabelecido um limiar para a decisão, indicado por Λ , sendo:

$$P_D = P(\Lambda > \lambda | H_1) \quad (4.2)$$

$$P_{FA} = P(\Lambda > \lambda | H_0) \quad (4.3)$$

Onde o limiar de decisão é λ .

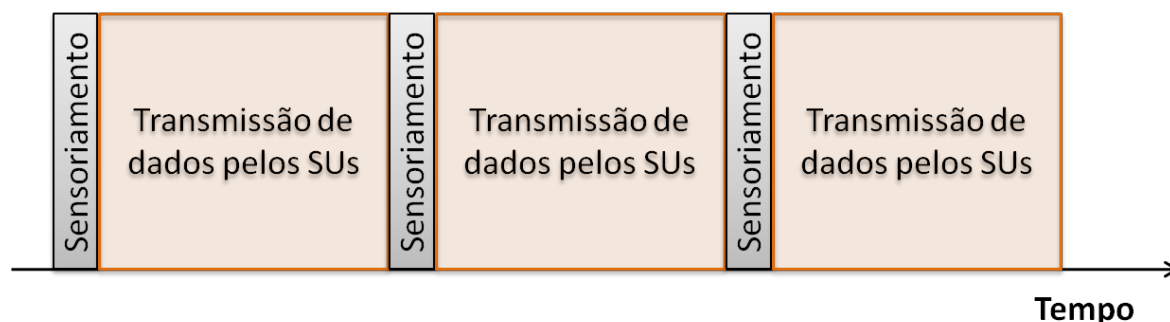
De forma geral, busca-se maximizar a probabilidade de detecção (P_D) sujeita à probabilidade de alarme falso (P_{FA}). O limiar de decisão (λ) é definido conforme a técnica de sensoriamento de espectro adotada.

As curvas de ROC (do inglês, *Receiver Operating Characteristic*) nos permitem visualizar o domínio da probabilidade de alarme falso (P_{FA}) e da probabilidade de detecção (P_D) (VAN TREES, 2001). No Capítulo 8 são apresentados os gráficos de probabilidade de detecção, probabilidade de falso alarme e também da ROC para o classificador proposto.

Com o intuito de proteger os usuários primários (UPs) de qualquer interferência e também permitir aos usuários secundários (USs) encontrar oportunidades de acesso, o espectro precisa ser periodicamente verificado. Este processo periódico de sensoriamento é denominado período de silêncio (PS) ou ainda período de sensoriamento.

O PS é um intervalo de tempo no qual toda a transmissão dos usuários secundários é interrompida para realizar o sensoriamento do espectro. Entretanto, durante a transmissão, o US permanecerá não ciente dos UPs, ou seja, até o próximo período de silêncio. Num cenário com um único *transceiver* o espectro não pode ser acessado e detectado ao mesmo tempo pelo mesmo usuário (HOSSAIN; NIYATO; HAN, 2009). A Figura 4.1 mostra o processo de períodos de silêncio.

Figura 4.1 – Períodos de silêncio



Fonte: a autora.

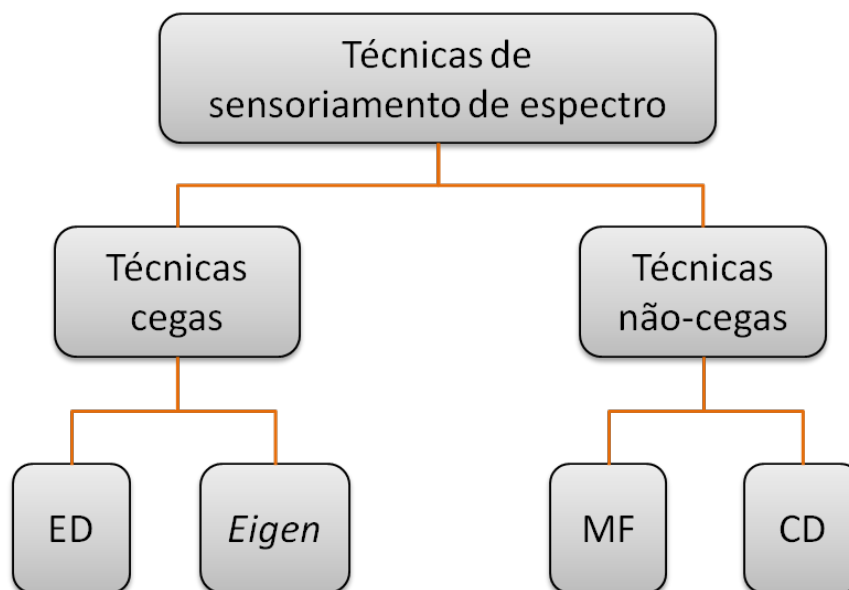
Existe um compromisso entre os períodos de silêncio e os períodos de transmissão. Caso o período dedicado para sensoriamento seja pequeno, o período de transmissão aumenta, mas nesse caso existe maior risco de executar uma detecção incorreta, devido ao tempo de observação do espectro ser insuficiente. Numa situação contrária, o período dedicado para transmissão de dados pode tornar-se insuficiente para atender as demandas dos SUs. A otimização destes períodos é importante e diretamente ligada ao resultado da detecção.

4.2 Técnicas de Sensoriamento de Espectro

A necessidade de conhecimento prévio das características do sinal do UP é uma das formas mais comuns de classificação das técnicas de sensoriamento de espectro. As técnicas de sensoriamento podem ser classificadas como cegas (do inglês, *blind*) ou não-cegas (do inglês, *nonblind*). No primeiro caso, nenhuma suposição com relação ao sinal do UP é feita, enquanto que no segundo caso, são utilizadas características previamente conhecidas do sinal do UP para realizar a detecção (WYGLINSKI; NEKOVEE; HOU, 2010).

A Figura 4.2 ilustra a classificação adotada neste trabalho e também indica quais técnicas serão descritas nas seções subsequentes.

Figura 4.2 – Técnicas cegas e não-cegas



Fonte: a autora.

4.2.1 Técnicas Não-cegas

Dentre as técnicas não-cegas, duas das mais comuns são: filtro casado (MF, do inglês *Matched Filter*), e detecção por cicloestacionariedade (CD, do inglês *Cyclostationary Detection*).

A técnica de MF parte do princípio de que a forma de onda do sinal do UP é conhecida de antemão. Esta é uma técnica de detecção que maximiza a SNR do sinal recebido, mas requer a demodulação do sinal do UP (YU, 2011). A demodulação do sinal do UP pode ser bastante complicada, uma vez que, dependendo do tipo de modulação usada, pode ser necessário sincronismo perfeito ou aplicação de técnicas de equalização/estimação de canal.

Para utilização desta técnica, o RC precisa ter uma base de dados com informações do UP (tipos de modulação, formas de onda, etc.). Isto é realizável porque a maioria dos sinais associados aos UPs possui algum tipo de piloto, preâmbulo ou codificação que pode ser utilizado para detecção. Uma desvantagem significativa desta técnica é a necessidade de um receptor dedicado para cada classe de UP (YU, 2011).

Normalmente os sinais modulados são acoplados com padrões (portadoras senoidais, trens de pulsos, sequências de controle, etc.). Essas características

podem ser usadas, em conjunto com estatísticas do sinal, para detectar se há um UP presente ou não. Este é o princípio de funcionamento da detecção por cicloestacionariedade (CD), que exige um maior esforço de processamento para executar a correlação espectral.

A implementação desta técnica de detecção é computacionalmente custosa, especialmente se considerarmos múltiplos sistemas de comunicação ativos simultaneamente. Além disso, esta técnica requer períodos mais longos de observação do espectro, o que pode fazer com que oportunidades de duração menor não sejam exploradas de forma eficiente (CHEN; PRASAD, 2009).

4.2.2 Técnicas Cegas

Das técnicas cegas de sensoriamento de espectro, duas são de especial interesse para o desenvolvimento deste trabalho: detecção de energia (ED, do inglês *Energy Detection*) e decomposição em subespaços (*Eigen*-decomposição).

4.2.2.1 Detecção de Energia

A técnica de ED estima a potência do sinal recebido pelo UP. Nesta abordagem a energia do sinal recebido é medida durante um intervalo de tempo e comparada com o limiar de decisão (λ) (CHEN; PRASAD, 2009). É declarada a presença de um UP caso o valor medido seja superior ao limiar de decisão.

Nesta técnica existe incerteza sobre a potência do ruído, logo, quando a relação sinal-ruído é baixa, ocorrem falsas detecções. Na verdade, a ED não diferencia sinais modulados, ruído ou interferência (YU, 2011).

A ED pode ser considerada uma técnica de detecção de fácil implementação. Sua utilização em conjunto com outras técnicas de sensoriamento pode trazer bons resultados.

4.2.2.2 Decomposição em Subespaços

A matriz de covariância de um sinal geralmente é diferente da matriz de covariância do ruído (LIU; WANG, 2011). A diferença entre estas matrizes pode ser utilizada para detecção de um sinal inserido num ambiente sujeito à presença de

ruído. Para utilização de uma técnica de sensoriamento baseada na matriz de covariância do sinal é necessária a decomposição desta matriz em subespaços, ou seja, o cálculo dos seus autovalores e autovetores, conforme demonstrado por Zeng e Liang (2007).

Buscando uma técnica de sensoriamento de espectro cega, que não fosse suscetível aos problemas da detecção de energia (ED), Zeng e Liang (2007) propuseram dois novos métodos de detecção baseados na decomposição em subespaços (*eigenvalues*). Eles demonstraram que a relação entre o máximo e o mínimo autovalor da matriz de covariância do sinal recebido pode ser usada para detectar a presença de UP. De forma similar, demonstraram que também é possível realizar a detecção avaliando a relação entre o autovalor médio e o mínimo autovalor da matriz de covariância do sinal.

O primeiro algoritmo proposto por Zeng e Liang (2007) é denominado MME (do inglês, *Maximum-minimum Eigenvalue Detection*). Neste primeiro algoritmo é computada a matriz de covariância do sinal recebido e, através desta matriz, obtém-se o máximo e o mínimo autovalor (λ_{max} e λ_{min}). O usuário primário (UP) é considerado presente caso a relação abaixo seja atendida, onde γ_1 é um limiar pré-estabelecido.

$$\lambda_{max} / \lambda_{min} > \gamma_1 \quad (4.4)$$

No segundo algoritmo, denominado EME (do inglês, *Energy with Minimum Eigenvalue*), também é computada a matriz de covariância do sinal recebido. Através desta matriz obtém-se o mínimo autovalor (λ_{min}). Calcula-se a potência média do sinal recebido, $T(N_s)$, onde N_s é o número de amostras utilizado para cálculo da potência média do sinal. A decisão sobre a presença do UP baseia-se na relação expressa na Equação 4.5, onde γ_2 é um outro limiar pré-estabelecido.

$$T(N_s) / \lambda_{min} > \gamma_2 \quad (4.5)$$

Os métodos MME e EME não necessitam de qualquer estimativa ou informação sobre a potência do ruído, o que os torna vantajosos quando comparados com a técnica de ED.

Outras abordagens foram propostas utilizando os métodos MME e EME como fundamento. Estas abordagens visam reduzir o custo computacional do cálculo dos autovalores e autovetores, que pode ser bastante alto, de acordo com o tamanho da matriz de covariância do sinal (ZHIWEN; HANG; SHAOFAN; DESHENG, 2010), (SHIBING; JIAOJIAO; LILI, 2012) e (DIKMESE; WONG; GOKCEOGLU; GUZZON; VALKAMA; RENFORS, 2013).

Em caso de sinais altamente correlacionados, os métodos MME e EME mostraram resultados melhores do que o método de ED, além de superar a questão da incerteza do ruído (ZENG; LIANG, 2007).

Os métodos MME e EME fazem uso da matriz de covariância do sinal recebido e dos autovalores desta matriz. Entretanto, o processo de cálculo dos autovalores é computacionalmente dispendioso e, em alguns casos, demorado. Os elementos constituintes do RC serão os responsáveis por executar o sensoriamento do espectro, desta forma, é razoável buscar soluções de detecção que aliem baixo custo computacional e alta velocidade de detecção.

Conforme mencionado na Seção 4.1, o período dedicado para sensoriamento, período de silêncio, precisa ser ajustado de forma a atender as necessidades da técnica de detecção, além dos requisitos de transmissão dos usuários secundários (USs). Um período de silêncio muito pequeno pode não ser suficiente para uma detecção precisa.

Nos métodos MME e EME, a matriz de covariância é criada a partir do sinal recebido. A dimensão desta matriz depende do número de amostras de sinal que foram recebidas no período de sensoriamento. Durante um período de silêncio, o RC precisa receber o sinal, obter a matriz de covariância deste, determinar os autovalores, determinar potência média do sinal recebido (apenas no caso de utilização do algoritmo EME), além de decidir sobre a presença ou não de um UP através da comparação com limiares pré-estabelecidos. E este processo repete-se a cada período de silêncio.

Neste trabalho é proposta uma alternativa ao processo cíclico de cálculo dos autovalores, que é a parte do algoritmo que demanda maior custo computacional. Na abordagem aqui adotada, que terá seus detalhes de implementação descritos no

Capítulo 7, os sinais serão classificados de acordo com as características de suas matrizes de covariância.

Foi demonstrado por Svantesson (1999 e 2001) que é possível realizar a decomposição em subespaços (*Eigen*-decomposição) da matriz de covariância de um sinal em duas partes: uma formada por autovetores (*eigenvectors*) correspondentes a autovalores (*eigenvalues*) iguais à variância do ruído; enquanto que a segunda parte é relacionada ao sinal. É importante salientar que nesta análise o sinal e o ruído são descorrelacionados. A Equação 4.6 descreve a referida decomposição da matriz de covariância.

$$R = E_S \Lambda_S E_S^H + \sigma^2 E_n E_n^H \quad (4.6)$$

Sendo R a matriz de covariância do sinal recebido, E_S o subespaço do sinal, Λ_S é a matriz cuja diagonal representa os autovalores (*eigenvalues*) do sinal e E_n o subespaço do ruído. Devido à ortogonalidade dos autovetores, os subespaços E_S e E_n são ortogonais (KRIM; VIBERG, 1996) e (GODARA, 2001).

É importante salientar aqui que não é possível eliminar o ruído do subespaço de sinal, uma vez que o ruído está presente em todos os subespaços. A referida ortogonalidade trata-se principalmente de um jargão utilizado na área de antenas.

Alguns processos que determinam a localização de fontes de sinal (DOA, do inglês, *Direction Of Arrival*), utilizam algoritmos baseados na decomposição em subespaços da matriz de covariância do sinal. Um dos mais conhecidos destes algoritmos é o MUSIC (do inglês, *Multiple Signal Classification*), que baseia-se no fato de que os autovetores do ruído são perpendiculares ao subespaço do sinal (SVANTESSON, 2001).

Zeng e Liang (2007) também utilizaram-se da decomposição da matriz de covariância para fundamentar os algoritmos MME e EME.

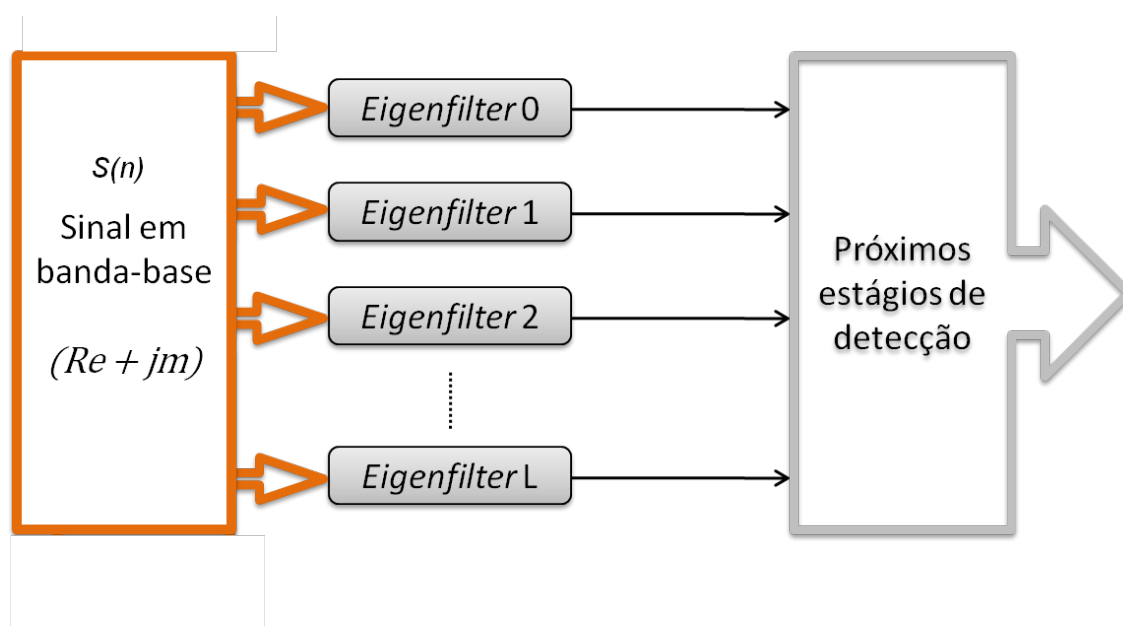
Desta forma, na abordagem aqui proposta, a estação rádio-base (ERB) cognitiva realizará a monitoração de um dado sinal, por tanto tempo quanto seja necessário, para obtenção de uma matriz de covariância representativa de suas

características. Após a obtenção da matriz de covariância, serão determinados os autovalores e os autovetores desta matriz. Os subespaços de ruído e de sinal serão separados, mediante análise dos autovalores significativos. Os autovetores associados aos autovalores significativos serão utilizados como coeficientes de filtros, denominados, neste projeto, *eigenfilters* (HAYKIN, 1996). Cada tipo de sinal analisado dará origem a um grupo de *eigenfilters* específico, que será utilizado para detecção de sinais com características similares àquele monitorado. Cada grupo de *eigenfilters* referentes a um tipo específico de sinal é denominado *eigenfilter bank*.

Este processo será repetido para uma quantidade de sinais conhecidos durante a operação normal da rede cognitiva e, após a conclusão desta etapa, serão obtidos conjuntos de *eigenfilter banks*. Cada *eigenfilter bank* neste conjunto é representativo de um tipo específico de sinal que foi monitorado durante a operação da rede.

Uma vez estando o *eigenfilter bank* concluído, cada nova sequência de amostras de sinal recebido será submetida à filtragem dos *eigenfilters* constituintes do *eigenfilter bank*. A maior projeção no respectivo subespaço será obtida apenas na saída do *eigenfilter bank* cujos coeficientes foram gerados a partir de uma sequência de amostras de sinal similar à atual. A saída de todos os *eigenfilters* será encaminhada para o próximo estágio de detecção, conforme indicado na Figura 4.3.

Figura 4.3 – Representação de um *Eigenfilter bank*



Fonte: a autora.

Com a abordagem proposta, reduz-se o custo computacional das operações cíclicas de obtenção da matriz de covariância e determinação de autovalores e autovetores, uma vez que para a detecção é necessária apenas a filtragem da amostra de sinal pelo *eigenfilter bank* previamente determinado nos domínios da ERB.

A determinação do *eigenfilter bank* pode ser uma tarefa executada antes do início da operação cíclica do sistema, conforme proposição a ser detalhada no Capítulo 7.

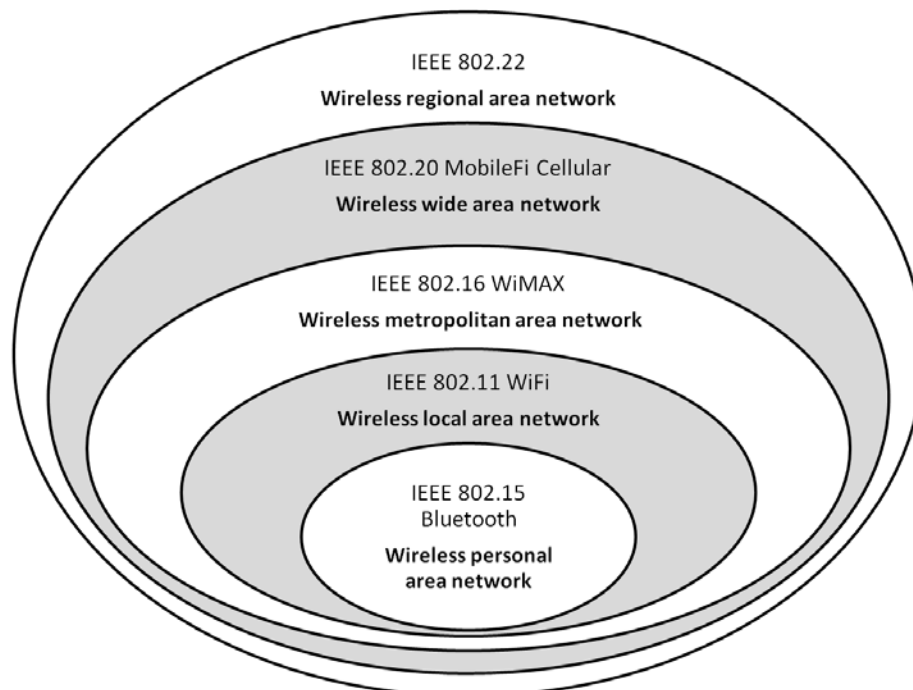
5 Regulamentação IEEE 802.22

Para implementação prática do RC os desafios são muitos. A identificação de usuários primários (UPs), verificação de canais livres e definição de níveis de potência para evitar interferência com as bandas adjacentes são fatores críticos para o sucesso da RRC.

Com a abertura, para uso não licenciado, dos espaços brancos na banda de TV dos EUA (FCC 08-260, 2008) o IEEE criou um grupo de trabalho visando a padronização da interface aérea cognitiva para WRANs (do inglês, *Wireless Regional Area Networks*). Esse grupo de trabalho deu origem a regulamentação IEEE 802.22, cujo escopo é a padronização da interface área, incluindo as camadas MAC (do inglês, *Medium Access Control*) e PHY (do inglês, *Physical Layer*), de WRANs operando nas bandas de TV de VHF/UHF entre 54 MHz e 862 MHz em regiões de baixa densidade populacional (IEEE 802.22, 2011).

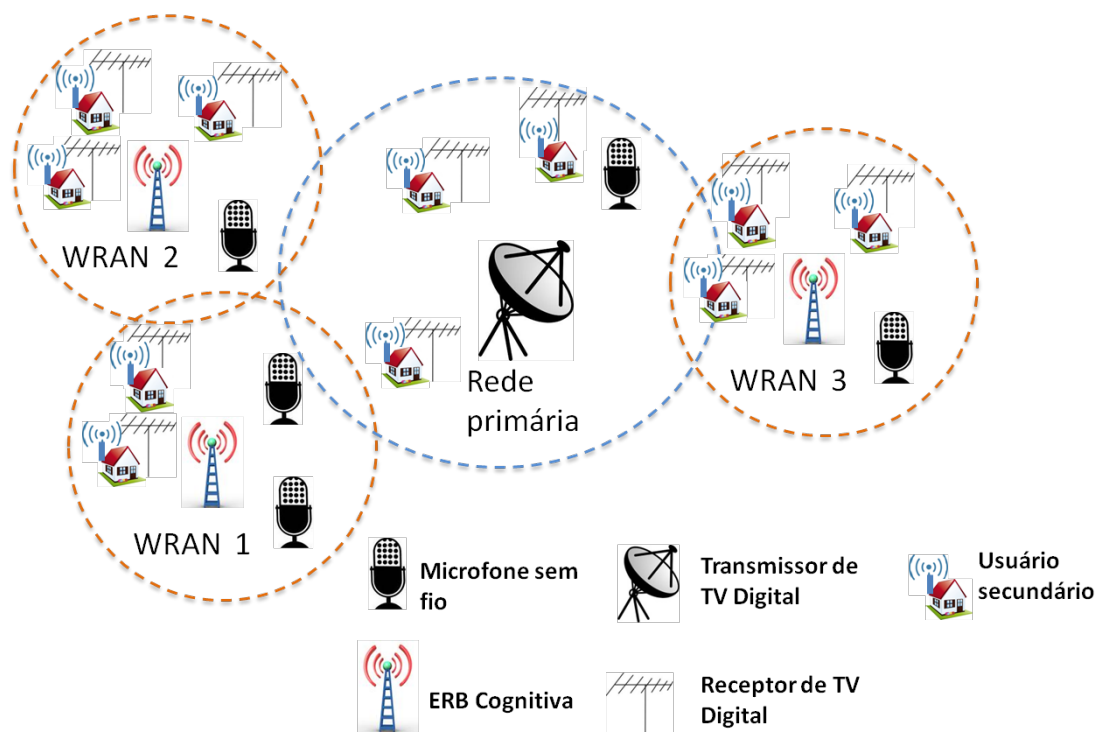
A resolução IEEE 802.22 (2011) também prevê uma arquitetura em que as WRANs contêm dois tipos de usuários secundários (USs): estações rádio-base (ERB) e terminais de usuário (CPE, do inglês *Customer Premise Equipment*). A Figura 5.1 indica as resoluções IEEE para comunicação *wireless* e a Figura 5.2 mostra um exemplo da arquitetura considerada na resolução IEEE 802.22 (2011).

Figura 5.1 – Resoluções IEEE para comunicação *wireless*



Fonte: a autora.

Figura 5.2 – Arquitetura da RRC conforme IEEE 802.22



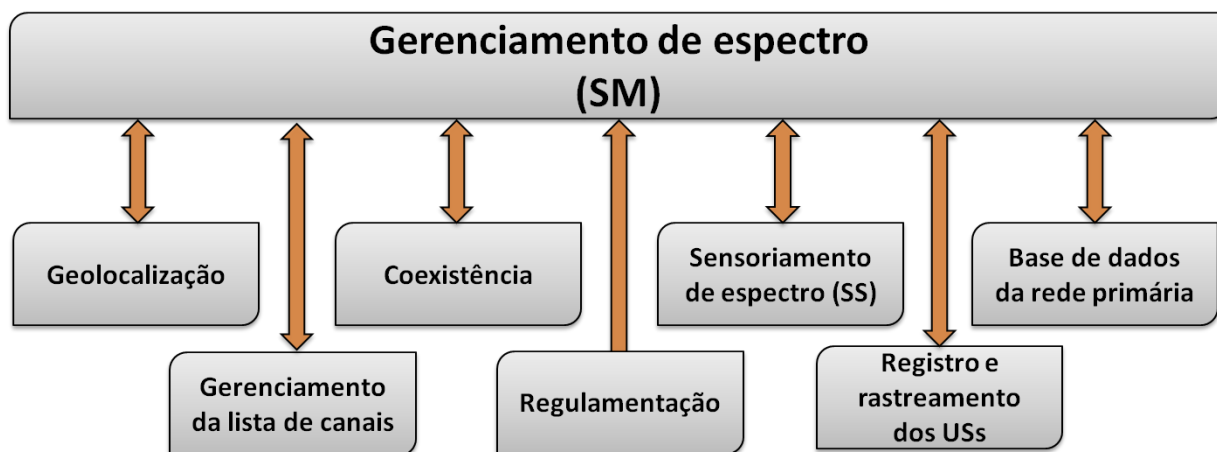
Fonte: a autora.

Ainda segundo a IEEE 802.22 (2011), as ERBs controlam todos os CPEs, determinando quando estes devem enviar dados e em quais canais. Os CPEs são utilizados também para realizar o sensoriamento de espectro na sua vizinhança.

Uma das maiores preocupações da resolução IEEE 802.22 (2011) é que seja garantida a proteção aos UPs. Em Cordeiro, Challapali, Birru e Shankar (2005) diversos cenários são analisados. Os autores concluem que numa situação prática os CPEs provavelmente estarão localizados a distâncias distintas da ERB e, portanto, sujeitos a diferentes SNRs. Para aumentar a eficiência do sistema a ERB precisa ter capacidade de ajustar dinamicamente seus parâmetros de operação, tais como largura de banda, modulação e codificação. A modulação OFDM, apresentada na Seção 2.5.2 deste trabalho, apresenta-se como uma escolha adequada para atender estes requisitos, já que permite alocação eficiente de subportadoras (do inglês, *subcarriers*) de forma a atender os requisitos dos CPEs. A resolução IEEE 802.22 (2011) também especifica os períodos de silêncio, onde todos os CPEs e ERB realizarão o sensoriamento do espectro para verificar a presença de UPs.

A IEEE 802.22 prevê que uma ERB atenda até 512 CPEs, num raio de cobertura de até 30 km. Também é prevista utilização de técnicas para mitigar interferência, incluindo capacidade de geolocalização, acesso a base de dados com informações de serviço e sensoriamento de espectro para detecção de usuários primários (IEEE 802.22, 2011). A Figura 5.3 indica as funcionalidades definidas pela IEEE 802.22 (2011) associadas ao plano cognitivo (do inglês *cognitive plane*).

Figura 5.3 – Funcionalidades definidas pela IEEE 802.22 associadas ao plano cognitivo



Fonte: adaptado de IEEE 802.22 (2011).

5.1 Gerenciamento de Espectro

A IEEE 802.22 define que a entidade gerenciamento do espectro (SM, do inglês *Spectrum Manager*) sempre deve estar presente nas estações rádio-base (ERB), sendo responsável pelas tarefas mais importantes do plano cognitivo (IEEE 802.22, 2011).

Numa WRAN, o gerenciamento do espectro é a parte central da ERB, pois esta entidade centraliza as decisões essenciais com relação à utilização do espectro. Conforme a IEEE 802.22 (2011), algumas de suas atribuições são:

- Manutenção da informação de disponibilidade do espectro;
- Classificação, seleção e gerenciamento de canais;
- Acesso à base de dados da rede primária;
- Garantir o cumprimento das políticas de regulamentação;
- Agendamento dos períodos de silêncio para sensoriamento do espectro;
- Implementar mecanismos de coexistência numa rede WRAN;
- Tomar decisões relativas à utilização de um canal ou célula para um CPE ou grupo de CPEs.

A IEEE 802.22 não especifica formas de implementação do gerenciamento do espectro, descrevendo apenas o comportamento obrigatório da entidade a fim de que seja considerada em conformidade com a regulamentação.

A IEEE 802.22 define ainda que o gerenciamento do espectro deve agregar informações oriundas da base de dados dos usuários primários (DS, do inglês *Database Service*), dos serviços de geolocalização (GL) e do módulo de gerenciamento do espectro, a fim de controlar a disponibilidade de canais. Há possibilidade do gerenciamento do espectro agregar informações oriundas de outros módulos, mas DS, GL e SS são considerados requisitos mínimos obrigatórios (IEEE 802.22, 2011).

O DS proporciona ao gerenciamento do espectro o acesso à base de dados da rede primária, de onde são obtidas informações sobre as regras para acesso a

canais e máxima potência permitida para transmissão. O DS pode estar sob controle da operadora da rede primária ou do órgão regulatório, mas em ambos os casos deve conter informação precisa sobre a rede primária.

O GL deve fornecer a localização da própria ERB, de todos os CPEs associados a esta ERB e daqueles que requisitem acesso na área de cobertura da ERB.

Para a tarefa de sensoriamento do espectro (SS) a IEEE 802.22 prevê a utilização de uma entidade chamada SSA (do inglês, *Spectrum Sensing Automaton*), que executa os comandos enviados pelo SM. O SSA interage com uma função de sensoriamento espectral (SSF, do inglês *Spectrum Sensing Function*). O SSA e o SSF devem estar presentes na ERB e em todos os CPEs.

Através das camadas MAC (*Media Access Control*) e PHY (*Physical Layer*) o SM se comunica com os SSAs e requisita que executem o sensoriamento do espectro e enviem relatórios de utilização do mesmo. O SM deve combinar o resultado do sensoriamento local com os resultados enviados pelos CPEs (IEEE 802.22, 2011). Na Seção 5.2 serão detalhadas as funções do SSA e SSF.

Conforme as informações obtidas do DS, GL e SS o SM classifica os canais disponíveis numa das categorias a seguir.

- *Disallowed*: canais que não podem ser utilizados pela WRAN devido à restrições informadas pela operadora ou restrições regulamentares.
- *Operating*: canal que está sendo utilizado para comunicação entre a ERB e os CPEs numa célula WRAN.
- *Backup*: canais que estão desocupados e podem tornar-se *operating channel*, caso a ERB necessite trocar o atual *operating channel*.
- *Candidate*: canais que podem ser promovidos à *backup channel*, mediante SS requisitado pelo SM. Para um *candidate channel* tornar-se *backup channel* é necessário que não sejam detectados usuários primários (UPs) num período de sensoriamento realizado a cada 6 segundos durante ao menos 30 segundos.
- *Protected*: canais ocupados por um UP ou por um usuário secundário (US) de outra WRAN. Estes canais podem tornar-se *candidate*

channels caso não sejam detectados usuários num período de sensoriamento realizado a cada 6 segundos durante ao menos 30 segundos.

- *Unclassified*: canais para os quais o SM ainda não solicitou *sensing*. Eles podem ser classificados como *protected* ou *candidate channel* dependendo do resultado do sensoriamento.

5.2 Spectrum Sensing Automaton

Como mencionado na Seção 5.1, o SSA executa os comandos relacionados a sensoriamento do espectro enviados pelo SM. A ERB, através do SM nela localizado, controla o comportamento do SSA. Entretanto, a IEEE 802.22 (2011) prevê que o próprio SSA deve exercer controle sobre o seu comportamento durante:

- A inicialização da ERB, antes que ela inicie a transmissão de qualquer sinal;
- A inicialização do CPE, antes que ele esteja associado a uma ERB;
- Os períodos de silêncio dedicados para *in-band sensing*, definidos pelo SM;
- Os períodos de silêncio dedicados para *out-of-band sensing*, quando a ERB não está transmitindo;
- Os períodos disponíveis, quando a ERB não atribuiu tarefa específica ao CPE;
- Os períodos em que o CPE perca contato com a ERB.

Estão previstas duas formas de SS, de acordo com a IEEE 802.22: *in-band sensing* e *out-of-band sensing*.

No procedimento de *in-band sensing* o SSA deve realizar o *sensing* em N canais, além de $N \pm 1$ canais, durante o período de silêncio agendado pelo SM. O resultado deste sensoriamento deve ser enviado para o SM.

O procedimento de *out-of-band sensing* é executado em três situações: na inicialização da ERB ou do CPE, no tempo livre do CPE ou quando o CPE perde

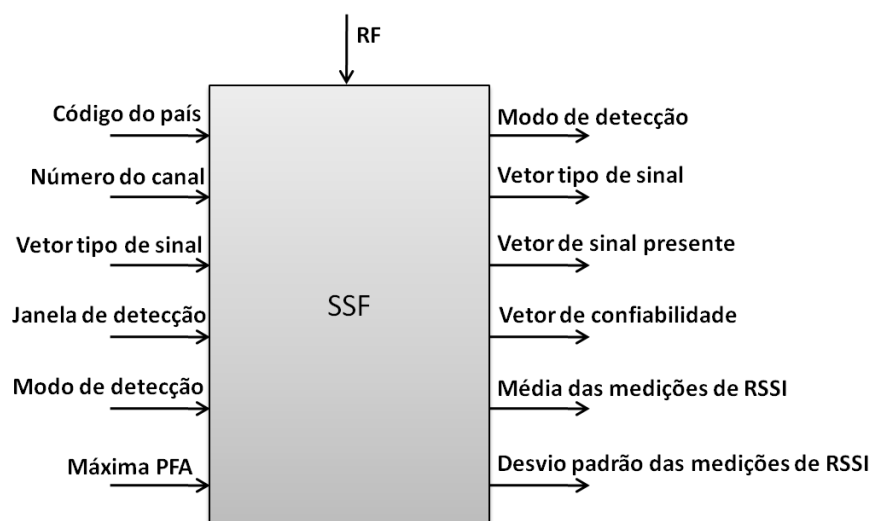
contato com a ERB. Na situação de inicialização o SSA deve realizar o sensoriamento em um canal específico, uma faixa de canais ou todos os canais previamente configurados como acessíveis para a WRAN. Há uma diferença entre este procedimento quando executado na ERB e quando executado no CPE. O objetivo de uma ERB durante a sua inicialização é encontrar um canal livre onde ela possa estabelecer seu serviço. No caso da inicialização de um CPE, o primeiro objetivo é identificar uma WRAN à qual ele possa associar-se. Como estes objetivos não são totalmente compatíveis, a IEEE 802.22 (2011) prevê processos de inicialização diferentes para o SSA na ERB e no CPE.

Quando o CPE não estiver realizando tarefa específica atribuída pela ERB ele deve realizar o *out-of-band sensing*, a fim de verificar a situação dos canais na sua lista de *backup/candidate channels*. O SSA localizado no CPE precisa ter um mínimo de inteligência que lhe permita, no caso de perda de contato com a ERB, evitar causar interferência nos UPs e realizar um número razoável de tentativas de reconexão.

5.2.1 *Spectrum Sensing Function*

A IEEE 802.22 (2011) prevê que a ERB e todos os CPEs precisam implementar a SSF (*Spectrum Sensing Function*), que é conduzida pelo SSA. O SSF efetivamente realiza a observação do espectro e, através da camada MAC, a ERB pode interagir com o SSF localizado no CPE. A Figura 5.4 (IEEE 802.22, 2011) especifica as principais entradas e saídas possíveis para o SSF.

Figura 5.4 – Entradas e saídas para o SSF



Fonte: adaptado de IEEE 802.22 (2011)

A IEEE 802.22 não especifica o método a ser utilizado para realizar a SSF, entretanto, seu Anexo C sugere algumas técnicas de detecção possíveis. As técnicas de decomposição em subespaços (MME e EME) abordadas na Seção 4.2.2.2 fazem parte do referido anexo, o que reforça a utilização deste tipo de abordagem para sensoriamento de espectro.

O vetor tipo de sinal (do inglês, *signal type array*), indicado na Figura 5.4, pode assumir 33 valores distintos, cada um deles indicando um tipo de sinal a ser detectado. Este vetor indica que o SSF pode ser configurado para procurar um tipo específico de sinal, ou avaliar o espectro de forma geral.

Em termos práticos, existe um número finito de modulações em uso nos sistemas de comunicação atuais. No contexto deste trabalho, podemos assumir que o processo de classificação de sinais precisa conhecer um certo número de possibilidades. Em outras palavras, obter um conjunto de *eigenfilter banks* representativo dos sinais dos usuários primários (UPs).

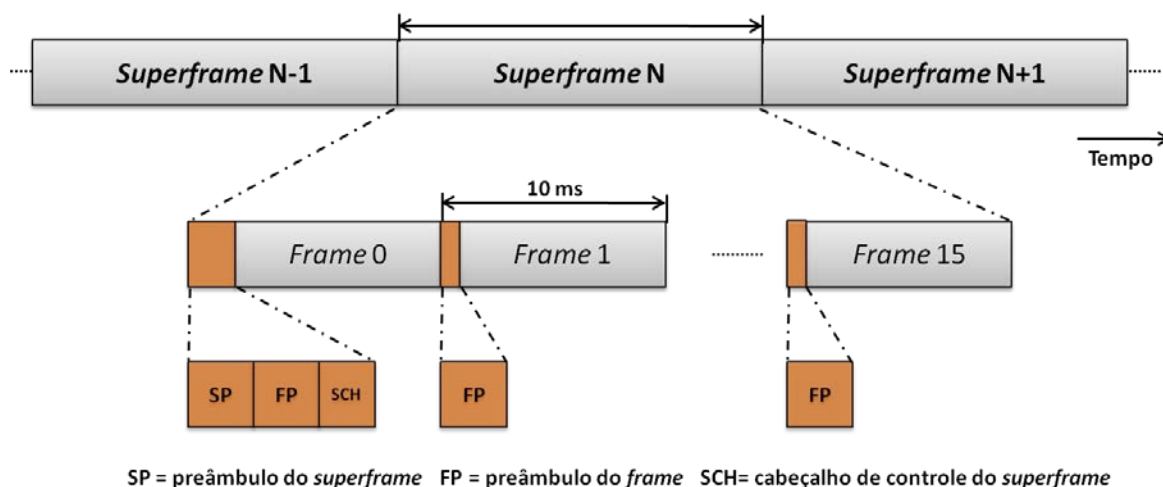
5.2.2 Períodos de Silêncio

A IEEE 802.22 (2011) define que podem ser agendados múltiplos períodos de silêncio, cuja soma agregada não pode ultrapassar 200 ms. Também é definido que a técnica de sensoriamento do espectro precisa ser capaz de detectar qualquer tipo de sinal num período máximo de 2 segundos.

A ERB precisa gerenciar o agendamento dos períodos de silêncio de forma a garantir a proteção aos UPs e também atender os requisitos de QoS dos USs. Os CPEs podem realizar *in-band* e *out-of-band sensing*, sendo que o segundo tipo pode ocorrer mediante requisição da ERB.

O processo de comunicação previsto na IEEE 802.22 (2011) utiliza *frames* de 10 ms agrupados em *superframes* de 160 ms, conforme apresentado na Figura 5.5.

Figura 5.5 – Estrutura de *superframes*



Fonte: adaptado de IEEE 802.22 (2011).

É prevista a adoção de dois estágios de *sensing*: *Intra-frame sensing* e *Inter-frame sensing*. No *Intra-frame sensing* ocorre um período de silêncio por *frame*. Este tipo de período de silêncio atende algoritmos de detecção que requerem períodos de sensoriamento menores do que um *frame* (menores do que 10 ms). O resultado desses períodos de silêncio pode ser consolidado ao final de um *superframe* e utilizado como base para a decisão sobre a execução do *Inter-frame sensing*.

No caso de *Inter-frame sensing* é agendado um período de silêncio longo, com finalidade de atender os requisitos de técnicas de detecção mais lentas. A duração do *Inter-frame sensing* é definida pela ERB e pode chegar até 160 ms, ou seja, a duração de um *superframe*. A utilização deste tipo de expediente pode degradar de forma substancial o QoS da WRAN, já que a transmissão é interrompida por longos períodos.

No contexto deste trabalho, a existência de um conjunto de *eigenfilter banks*, com sinais conhecidos já mapeados, pode ser usada de forma a reduzir a

necessidade de *Inter-frame sensing*. Considerando também a restrição máxima de 2 segundos para detecção de qualquer sinal, deve-se buscar técnicas de sensoriamento que consigam atender este requisito.

5.3 Inicialização da WRAN

Antes que um CPE possa efetivamente iniciar a transmissão de dados na WRAN, ele precisa passar por procedimentos de registro e autenticação na célula. A IEEE 802.22 (2011) prevê verificações e procedimentos que os CPEs devem executar na etapa de inicialização e registro. Um destes procedimentos consiste na obtenção dos parâmetros operacionais que o CPE deve utilizar durante o seu acesso à WRAN.

Os parâmetros operacionais são solicitados pelo CPE à ERB. Eles são enviados através de mensagens da camada MAC. A mensagem *TFTP Configuration File* é enviada pelo CPE a um servidor que contém os parâmetros operacionais. Este servidor pode estar localizado na ERB. Após o servidor enviar as configurações para o CPE, este deve informar o recebimento destas à ERB, através da mensagem **TFTP-CPLT** (*Config File TFTP Complete*). A ERB envia a mensagem **TFTP-TSP** (*Config File TFTP Complete Response*) ao CPE e, a partir desta, o CPE está apto a iniciar a sua transmissão de dados.

A resolução IEEE 802.22 (2011) também prevê a utilização de MIBs (*Management Information Base*) para organização hierárquica da informação. O acesso às MIBs é realizado conforme protocolo SNMP (*Simple Network Management Protocol*). Através do acesso às MIBs pode-se implementar a atualização de informações durante a inicialização ou operação regular do sistema. A MIB **wranIfSsaMib**, por exemplo, deve conter informações relacionadas a configuração, operação e monitoramento do SSA, já que este precisa saber o tipo de sensoriamento que deve ser executado.

No âmbito deste trabalho, adota-se a utilização das mensagens de *TFTP Configuration File* ou das MIBs para envio de informações da ERB para os CPEs. A ERB, com maior capacidade de processamento do que os CPEs, pode ser a responsável pelo processo de criação dos *eigenfilter banks*. Neste caso a ERB envia aos CPEs apenas a informação necessária para que estes possam realizar o

sensoriamento do espectro na sua vizinhança, ou seja, apenas os coeficientes dos *eigenfilters* que compõe os *eigenfilter banks*. Este cenário é uma contextualização da aplicação do método aqui proposto, sendo que os testes de validação foram executados assumindo-se que todo o processo foi executado nos domínios da ERB.

O cenário de aplicação prática do RC, conforme critérios previstos na regulamentação IEEE 802.22, pode parecer um pouco limitado, entretanto, estatísticas mostram que as taxas de ocupação da maioria das bandas em VHF e UHF são inferiores a 10% do total. A distribuição de faixas brancas no espectro indica que as bandas são capazes de executar comunicação banda larga sem fio (WANG, 2012). É possível imaginar a expansão do conceito a outras bandas além da de TV, utilizando a IEEE 802.22 como referência para regulamentação. Nas definições do sistema aqui proposto a IEEE 802.22 (2011) foi utilizada como referência, quando pertinente.

6 Redes Neurais

As Redes Neurais Artificiais (RNAs) representam um meio computacional de resolução de problemas complexos que, intencionalmente, busca imitar a forma de processamento de informações realizada pelo cérebro humano.

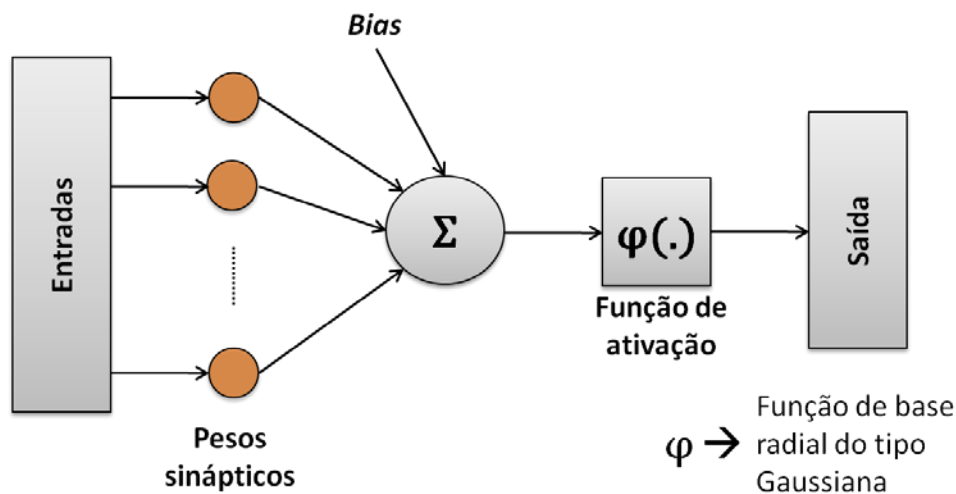
No contexto deste trabalho as RNAs são responsáveis pela classificação dos sinais a partir dos dados obtidos após a etapa de decomposição em subespaços, abordada na Seção 4.2.2.2. Em linhas gerais, as RNAs serão as responsáveis pela avaliação das hipóteses H_0 (ausência de UP) e H_1 (presença de UP), conforme Seção 4.1.

Os neurônios são as unidades fundamentais de processamento de informação numa RNA e cada neurônio artificial possui três elementos básicos (HAYKIN, 1999):

- Conjunto de sinapses ou elos de conexão caracterizados por um peso ou força própria;
- Um combinador linear, que soma os sinais de entrada ponderados pelas sinapses do neurônio;
- Uma função de ativação que restringe a amplitude da saída do neurônio.

Pode-se ainda aplicar um *bias* (polarização), que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação. A Figura 6.1 indica os elementos básicos de um neurônio artificial não-linear.

Figura 6.1 – Elementos básicos de um neurônio artificial



Fonte: a autora.

Existem diversas formas de implementação de RNAs e, de forma geral, elas buscam atingir um nível de funcionamento onde a resposta da rede artificial se assemelhe ao comportamento humano inteligente em uma mesma situação. Numa RNA o conhecimento é adquirido a partir de seu ambiente, através de um processo de aprendizagem. Os pesos sinápticos representam a força de conexão entre neurônios da rede e são utilizados para armazenar o conhecimento adquirido (HAYKIN, 1999).

Os pesos sinápticos significam o grau de importância ou influência que uma determinada entrada possui na resposta de um neurônio específico. O conjunto dos pesos sinápticos atribuídos aos neurônios de uma RNA possui influência direta na resposta que esta rede vai apresentar. Os processos de aprendizagem da rede levam à obtenção de valores coerentes para estes pesos sinápticos.

Quando uma rede já foi testada com diferentes pesos sinápticos e atingiu o nível de resposta esperado, diz-se que a rede foi treinada. Todos os testes executados antes da configuração final são considerados treinamentos da rede. Existem algoritmos que fazem o treinamento de uma rede, ou seja, realizam muitos testes alterando os pesos sinápticos das entradas e observando o resultado da saída. A grande vantagem destes algoritmos é que eles modificam os pesos sinápticos de uma forma sistemática buscando atingir o objetivo projetado para a rede.

O sucesso na utilização de uma rede neural depende da escolha de uma arquitetura adequada ao problema que se pretende resolver. Também é preciso que os conjuntos de treino sejam representativos do problema a ser resolvido e que os resultados obtidos sejam criteriosamente analisados.

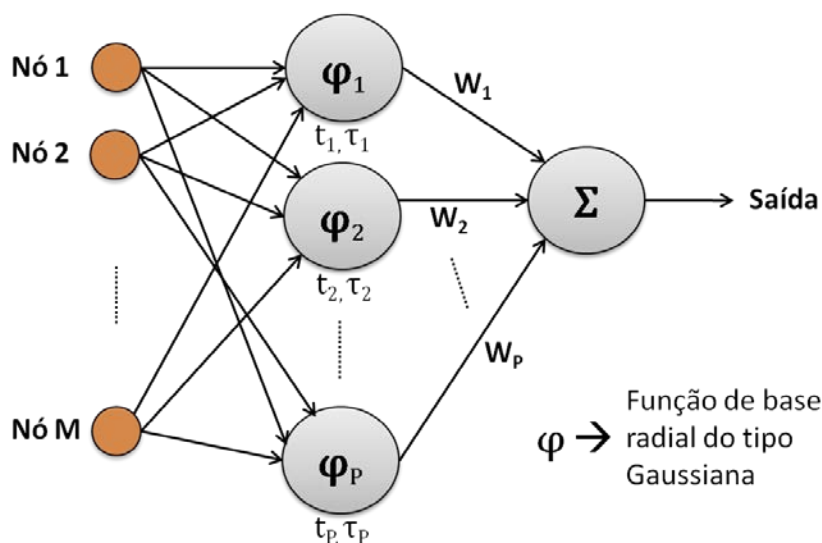
6.1 Radial Basis Function

Conforme mencionado no Capítulo 1, as redes neurais do tipo RBF (do inglês, *Radial Basis Function*) são aproximadoras universais. As redes RBF possuem custo computacional de treinamento reduzido quando comparadas a uma rede MLP (do inglês, *Multilayer Perceptrons*) (DE CASTRO, 2001). Elas também apresentam excelente capacidade de aprendizado e generalização.

É comum que as RBFs apresentem uma arquitetura simples, apenas com duas camadas de pesos sinápticos: uma delas contendo os parâmetros das funções de base radial e a outra sendo responsável por gerar a saída, através de combinações lineares das funções de ativação de base radial (BISHOP, 1995).

Os nós de entrada conectam a rede ao ambiente e a camada escondida aplica uma função de transformação não-linear, a partir do espaço de entrada para o espaço escondido. A camada de saída, que é linear, indica a resposta da rede para a entrada que foi aplicada (HAYKIN, 1999). A Figura 6.2 indica um exemplo de uma rede neural do tipo RBF.

Figura 6.2 – Rede neural do tipo *Radial Basis Function*



Segundo Haykin (1999), numa RBF a aprendizagem é equivalente a encontrar uma superfície em um espaço multidimensional que forneça um melhor ajuste para os dados de treinamento, ou seja, uma melhor aproximação num espaço multidimensional.

Numa rede neural o treinamento pode ser supervisionado ou não-supervisionado. No aprendizado supervisionado existe um conjunto de entradas e as saídas correspondentes, conhecidas e corretas, para cada uma destas entradas. Já no aprendizado não-supervisionado não existe o conceito de saída correta. O objetivo neste método de treinamento é identificar a estrutura subjacente dos dados de entrada, buscando padrões ou classificando os dados por similaridades (HOSSAIN; NIYATO; HAN, 2009).

Numa RBF a ativação de uma unidade escondida é determinada por uma função não-linear, da distância entre o vetor de entrada e um vetor de referência. O seu treinamento é normalmente executado em duas etapas: na primeira busca-se definir as funções de base radial através de algoritmos de treinamento não-supervisionados, usando apenas os dados de entrada. Na segunda etapa utilizam-se métodos supervisionados e lineares, que garantem convergência mais rápida (BISHOP, 1995).

A possibilidade de adotar duas estratégias de treinamento faz com que as redes neurais do tipo RBF tenham velocidade de treinamento reduzida, quando comparadas às redes do tipo MLP, por exemplo. As RBFs são flexíveis e capazes de resolver problemas relacionados à classificação de padrões complexos. Estas foram algumas das razões pelas quais as RBFs foram escolhidas para utilização neste trabalho.

Todas as redes neurais utilizadas no escopo deste trabalho são do tipo RBF e foram treinadas em duas etapas: com algoritmo *K-means* para treinamento não supervisionado, disponível no Anexo B1, e com método do gradiente estocástico na etapa supervisionada. O algoritmo utilizado para treinamento e validação das RBFs foi o *Radial Basis Function Neural Net Training/Validation program V1.0.d* (DE CASTRO, 2001).

No Capítulo 7 as RBFs adotadas para simulação do sistema proposto serão detalhadas.

6.2 Redes Neurais e Rádio Cognitivo

Os conceitos de inteligência e aprendizado associados às RNAs podem ser uma forma de solucionar alguns dos problemas práticos para implantação do rádio cognitivo (RC). Dentre as diversas técnicas de inteligência artificial disponíveis, as RNAs são uma das melhores alternativas para análise de padrões e tendências. Como as RNAs não requerem conhecimento prévio sobre os dados para serem capazes de analisá-los, podem ser projetadas para lidar com dados oriundos de ambientes dinâmicos, como o espectro de rádio.

Através da combinação de técnicas de correlação espectral e redes neurais, Fehske, Gaedert e Reed (2005) mostram que o uso de redes neurais pode contribuir para redução da carga computacional num sistema de classificação de sinais.

Mitola (2006) indica que as redes neurais poderiam ser utilizadas para aprender sobre preferências dos usuários e generalizá-las no domínio de rádio.

Em Yu (2011) é apresentada a aplicação CogAP (do inglês, *Cognitive Access Point*), que é uma plataforma para acesso *Wi-Fi* e redes *wireless* domésticas. A CogAP é constituída por um módulo de detecção de tráfego e outro de controle cognitivo. O módulo de controle cognitivo possui funções de predição de tráfego e controle de decisão, sendo que ambas as funções são implementadas com o uso de redes neurais.

Pode-se dizer que os algoritmos de inteligência artificial possuem duas etapas principais: treinamento e decisão. Na etapa de treinamento são usadas amostras ou dados, referentes a experiências passadas, para construção de conhecimento sobre o ambiente ou sistema. As decisões ou inferências executadas na segunda etapa são baseadas no conhecimento que foi construído.

As RNAs são uma das técnicas de inteligência artificial disponíveis para modelar relações complexas entre entradas e saídas. Por esta razão, sua utilização no contexto de rádio cognitivo (RC) pode ser vantajosa, conforme demonstrado nos exemplos apresentados.

7 Sistema Proposto

Este trabalho tem como objetivo apresentar uma nova abordagem para o problema de detecção da presença de um usuário primário (UP). Nele é proposto um classificador de sinais, capaz de determinar a presença do sinal de um UP num determinado canal do espectro de rádio bem como identificar o tipo de UP.

Uma vez recebido o sinal de um UP desconhecido pelo classificador é efetuada a sua *eigen*-decomposição (HAYKIN, 1996), através da qual é obtido o conjunto de autovalores e autovetores da matriz de covariância do sinal. Os autovetores relativos aos autovalores mais significativos representam um *eigenfilter*. Os componentes do ℓ -ésimo autovetor correspondem aos coeficientes do filtro FIR que o ℓ -ésimo *eigenfilter* representa, $\ell = 1, 2, \dots, L$, onde L corresponde ao número de autovalores mais significativos dentre a totalidade de autovalores obtidos pela *eigen*-decomposição.

Ao aplicar-se sinal na entrada de um *eigenfilter* obtém-se em sua saída a projeção do sinal no subespaço que o autovetor representa. Cada tipo de sinal é representado por tantos *eigenfilters* quanto for o número de autovalores significativos que representam o sinal. Somando-se as saídas de todos os *eigenfilters* reconstrói-se o sinal a partir destas saídas, as quais representam as respectivas projeções do sinal em cada subespaço. Um *eigenfilter bank* é o conjunto de *eigenfilters* que reconstrói o sinal original a partir da soma de suas respectivas projeções.

A variância ou potência P_ℓ do sinal na saída do ℓ -ésimo *eigenfilter* de um *eigenfilter bank* corresponde à variância da ℓ -ésima projeção de um sinal S_{in} em sua entrada. Se o sinal S_{in} é o próprio sinal original S_o que deu origem ao *eigenfilter bank* através do processo de *eigen*-decomposição acima referido, então P_ℓ tende ao ℓ -ésimo autovalor da matriz de covariância de S_o . Esta projeção obtida em sua saída resulta da ação do *eigenfilter* em projetar o sinal S_{in} em sua entrada no subespaço representado pelo autovetor associado ao ℓ -ésimo *eigenfilter*. Se a variância (normalizada em relação ao maior autovalor) da ℓ -ésima projeção é de valor semelhante à variância normalizada da ℓ -ésima projeção do sinal S_o que deu origem

ao *eigenfilter bank* através do processo de *eigen*-decomposição acima referido, então S_{in} é similar a S_0 quanto à ℓ -ésima projeção.

Se o sinal S_{in} na entrada do *eigenfilter bank* é o próprio sinal S_0 original que deu origem ao *eigenfilter bank* através do processo de *eigen*-decomposição então o conjunto das P_ℓ potências, $\ell = 1, 2, \dots, L$ respectivas às L projeções nas saídas dos respectivos *eigenfilters* tende ao conjunto de autovalores do sinal original S_0 , onde L corresponde número de autovalores significativos. Assim, o conjunto $\{P_\ell\}$ pode ser usado para identificar S_{in} como sendo ou não o sinal S_0 original mediante a análise da semelhança ou não do conjunto $\{P_\ell\}$ obtido para S_{in} com o conjunto $\{P_\ell\}$ original obtido para S_0 .

Esta análise da semelhança entre os dois conjuntos de potências $\{P_\ell\}$ será efetuada por uma rede neural RBF (*Radial Basis Functions*) (HAYKIN, 1999), que será treinada com o conjunto $\{P_\ell\}$ original obtido para S_0 . A rede RBF decidirá se S_{in} é ou não o sinal S_0 a partir da apresentação em seus nós de entrada do conjunto $\{P_\ell\}$ obtido para S_{in} , conforme será explanado adiante.

Uma vez decidindo que S_{in} é ou não o sinal de um UP correspondente ao sinal S_0 , a rede RBF identifica que este tipo de UP está ou não ocupando o canal analisado. Cada tipo de UP tem um sinal característico S_0 que determina um classificador constituído de um *eigenfilter bank* e de uma rede neural RBF.

Ao longo deste capítulo será apresentado o classificador proposto.

7.1 Delimitações de Escopo

Para efeito de contextualizar a atuação do classificador proposto em uma RRC, é necessário delimitar o seu escopo funcional. Para tanto, utilizaremos conceitos apresentados em capítulos anteriores.

Na Seção 3.3 as arquiteturas para a RRC foram discutidas. No sistema proposto considera-se uma arquitetura com infraestrutura, ou seja, existe uma estação rádio-base (ERB) controlando todos os CPEs (*Customer Premise Equipments*). No cenário de validação considerou-se apenas uma única WRAN (*Wireless Regional Area Network*). O cenário em que a ERB exerce controle sobre todos os CPEs também é adotado na resolução IEEE 802.22 (2011), discutida no

Capítulo 5. Desta forma, a decisão sobre a presença do UP é considerada de responsabilidade única da ERB.

Ainda em conformidade com a IEEE 802.22 (2011), é assumido que a ERB seja dotada de capacidade de monitorar o espectro na sua vizinhança, durante um tempo pré-estabelecido, antes do início de sua operação comercial. Neste período, a ERB realiza o sensoriamento do espectro de todos os canais, na faixa do espectro determinada para sua operação. Este processo é previsto na IEEE 802.22 (2011) através das definições do SSA (*Spectrum Sensing Automaton*) que, durante a inicialização da ERB, deve executar o *out-of-band sensing*, conforme descrito na Seção 5.2. O *out-of-band sensing* pode ser executado em um canal específico, uma faixa de canais ou todos os canais previamente configurados como acessíveis para a WRAN. Em termos práticos, é bastante provável que exista uma faixa de frequência pré-definida para a operação da WRAN, logo, esta faixa seria objeto do procedimento de *out-of-band sensing*.

Todos os sinais utilizados para a determinação, testes e validação do sistema proposto estão em banda-base (*baseband*) conforme descrito na Seção 2.4. Assume-se que a ERB seja dotada de um módulo de recepção capaz de converter o sinal captado em *bandpass* para *baseband*. Neste caso, o módulo de gerenciamento de espectro (SM) na ERB é o responsável por manter a informação de qual canal está sendo monitorado. Esta premissa está em concordância com a resolução IEEE 802.22 (2011) que define como tarefa do SM a manutenção da informação de disponibilidade do espectro e a classificação, seleção e gerenciamento de canais, conforme visto na Seção 5.1.

A Seção 2.6 discorre sobre os ruídos AWGN e impulsivo, ambos utilizados no contexto deste trabalho. Estes dois ruídos são descorrelacionados com os sinais digitalmente modulados a serem detectados e classificados pelo classificador aqui proposto.

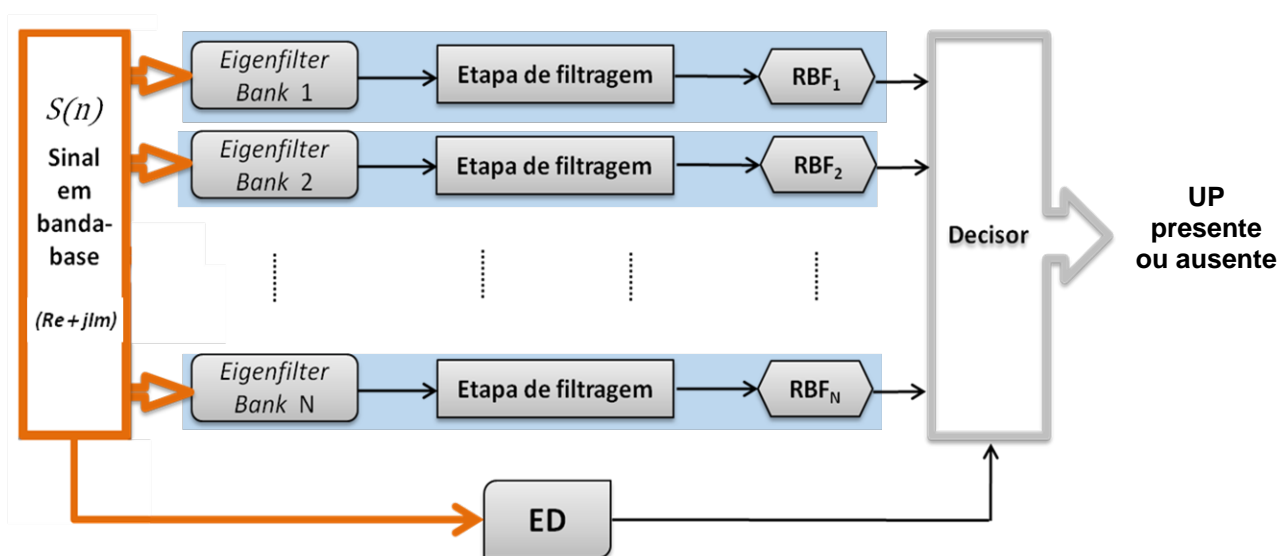
Para efeitos de análise, considera-se que os sinais recebidos na ERB foram submetidos às etapas de ajuste de ganho (AGC) e amplificação, descritas na Seção 2.2.

Os algoritmos desenvolvidos para o sistema proposto foram implementados em scripts para MATLAB (MathWorks, 2012). Algoritmos auxiliares não desenvolvidos especificamente para este trabalho estão devidamente referenciados.

7.2 Arquitetura do Sistema

Existem duas etapas funcionais distintas para o sistema proposto: a determinação numérica dos módulos de classificação dos sinais dos UPs e a detecção do sinal de UP em *background* de ruído. Nesta seção serão abordados os métodos adotados para a construção dos módulos e sua arquitetura. A Figura 7.1 apresenta os módulos de classificação, cujo detalhamento é apresentado ao longo deste capítulo. Para que seja obtida a potência P_ℓ do sinal na saída do ℓ -ésimo *eigenfilter* de um *eigenfilter bank*, conforme discutido no início deste capítulo, a *Etapa de Filtragem* é composta por um bloco que realiza a operação de módulo ao quadrado do argumento complexo seguida de um filtro passa baixa do tipo média móvel e ainda de um filtro de média subamostrada. O bloco ED corresponde a um detector de energia que atua como forma de contingência para o processo de detecção e sua descrição detalhada é apresentada na Seção 7.4. Este bloco atua na determinação se o sinal recebido é o sinal de um UP desconhecido/conhecido pelo classificador, conforme discutido no início deste capítulo.

Figura 7.1 – Sistema para classificação de sinais por decomposição em subespaços para sensoriamento de espectro de rádio cognitivo.



A Figura 7.1 apresenta o sistema de classificação proposto, no qual pode-se observar vários módulos de classificação, cada um deles composto por *eigenfilter bank*, etapa de filtragem e rede neural RBF. Conforme discutido no início deste capítulo, cada tipo de UP tem um sinal característico S_0 que determina um módulo de classificação constituído por um *eigenfilter bank*, uma etapa de filtragem e uma rede neural RBF.

No cenário apresentado neste trabalho, serão observados três tipos de sinal: um sinal referente a uma transmissão OFDM do padrão IEEE WiMAX 802.16 (IEEE 802.16, 2012), um sinal de microfone sem fio e um sinal de TV digital no padrão DVB-T (ETSI EN 300 744, 2009). Estes sinais foram adotados para que fosse possível realizar a prova de conceito de forma alinhada com a resolução IEEE 802.22 (2011), que especifica a necessidade de detecção de UPs cujos sinais correspondam a sinais de TV digital e a sinais de microfones sem fio. As seções seguintes deste trabalho serão abordadas de acordo com o tipo de sinal a ser detectado.

7.2.1 Sinal OFDM do padrão IEEE WiMAX 802.16

7.2.1.1 Determinação dos *Eigenfilter Banks*

A primeira providência para determinar os *eigenfilters* é a obtenção de uma sequência de amostras do sinal em banda-base de um UP, a partir da monitoração de um dado canal, por um dado período de tempo. Especificamente, a ERB periodicamente efetua a varredura em frequência de todos os canais disponíveis, monitorando cada um deles, trazendo os sinais monitorados para banda-base. Note que os sinais monitorados pela ERB não precisam ser demodulados nem sincronizados para o fim aqui proposto. Como estamos tratando de sinais em banda-base, não é relevante a informação de qual portadora estava sendo utilizada para a transmissão da informação.

O primeiro tipo de sinal gerado para validação é um sinal OFDM semelhante ao do padrão IEEE WiMAX 802.16 (IEEE 802.16, 2012), conforme abordado na Seção 2.5.2, com tamanho de símbolo 256 e prefixo cíclico (CP) de $\frac{1}{4}$ do tamanho do símbolo, totalizando 320 amostras complexas. Na versão atualizada do padrão

WiMAX (IEEE 802.16.1.a, 2013) não é mais utilizado o tamanho de 256 para IFFT, entretanto, neste trabalho foi mantido o especificado na versão anterior (IEEE 802.16, 2012), pois este tamanho de símbolo mostrou-se viável em termos de complexidade computacional da simulação para efeito de prova de conceito. Este sinal é modulado em 16-QAM. Para geração deste sinal foi utilizado o *script* “*Simulador_OFDM_V1.8 - ACPR*”, desenvolvido em MATHCAD (DE CASTRO, 2012).

A captura das amostras deve ser equivalente a um sinal recebido por um receptor, desta forma, as amostras foram coletadas no ponto de recepção, após conversão para banda-base e ajustes de ganho. Numa analogia com a Figura 2.3, apresentada na Seção 2.2, a coleta das amostras é realizada imediatamente antes da etapa de demodulação, após o bloco *Downconverter*. Neste ponto, todas as etapas de ajuste de ganho e amplificação já foram executadas, restando apenas o sinal, na forma de números complexos ($Re + jIm$). O sinal capturado corresponde, portanto, a uma sequência de números complexos em banda-base.


Para determinação dos *eigenfilters* foi considerada uma sequência de números complexos em banda-base do sinal de um UP, sinal este que é assumido ter sido transmitido através de um canal de transmissão ideal, ou seja, sem ruído e sem multipercurso. O efeito do ruído e multipercurso é levado em conta adiante, na detecção/identificação pela rede neural RBF. Também é importante salientar que o ponto de captura das amostras é anterior a qualquer etapa de demodulação ou sincronização do sinal, o que é condizente com a definição das técnicas cegas de sensoriamento de espectro, abordadas na Seção 4.2.2 e também com as premissas adotadas na resolução IEEE 802.22 (2011), descritas no Capítulo 5.

Dada a sequência de amostras $S_o(n)$ do sinal S_o em banda-base de um UP, sendo n o índice temporal da amostra, e sabendo de antemão que o tamanho de um símbolo OFDM somado com o prefixo cíclico totaliza $M = 320$ amostras, obtêm-se os autovalores e autovetores da matriz de covariância \mathbf{C} deste sinal. Especificamente, a sequência de amostras complexas $S_o(n)$ é importada no aplicativo MATLAB (MathWorks, 2012) e normalizada em relação à amostra de maior módulo de modo que todas as amostras de $S_o(n)$ assim normalizado tenham módulo máximo unitário. A seguir, cada sequência consecutiva de M amostras complexas de $S_o(n)$ é atribuída a uma respectiva linha da denominada matriz de

observação \mathbf{X} . Caso as últimas amostras de $S_0(n)$ não completem às M posições da última linha de \mathbf{X} efetua-se o preenchimento com zero das posições faltantes. Obtêm-se então a matriz de covariância \mathbf{C} do sinal S_0 através do comando $\mathbf{C}=\text{cov}(\mathbf{X})$ do MATLAB. Os M autovalores λ_m e os M autovetores $\underline{v}^{(m)}$, $m = 1, 2, \dots, M$, são obtidos através do comando $[\mathbf{V}, \mathbf{\Lambda}] = \text{eig}(\mathbf{C})$. A m -ésima coluna da matriz resultante $\mathbf{V}[M \times M]$ corresponde ao m -ésimo autovetor $\underline{v}^{(m)}$. O m -ésimo elemento da diagonal principal da matriz resultante $\mathbf{\Lambda}[M \times M]$ corresponde ao m -ésimo autovalor λ_m .

Para este sinal OFDM do padrão IEEE WiMAX 802.16, conforme mostra a Figura 7.2, observa-se que dos $M = 320$ autovalores apenas $L = 215$ são significativos.

Figura 7.2 – Autovalores significativos



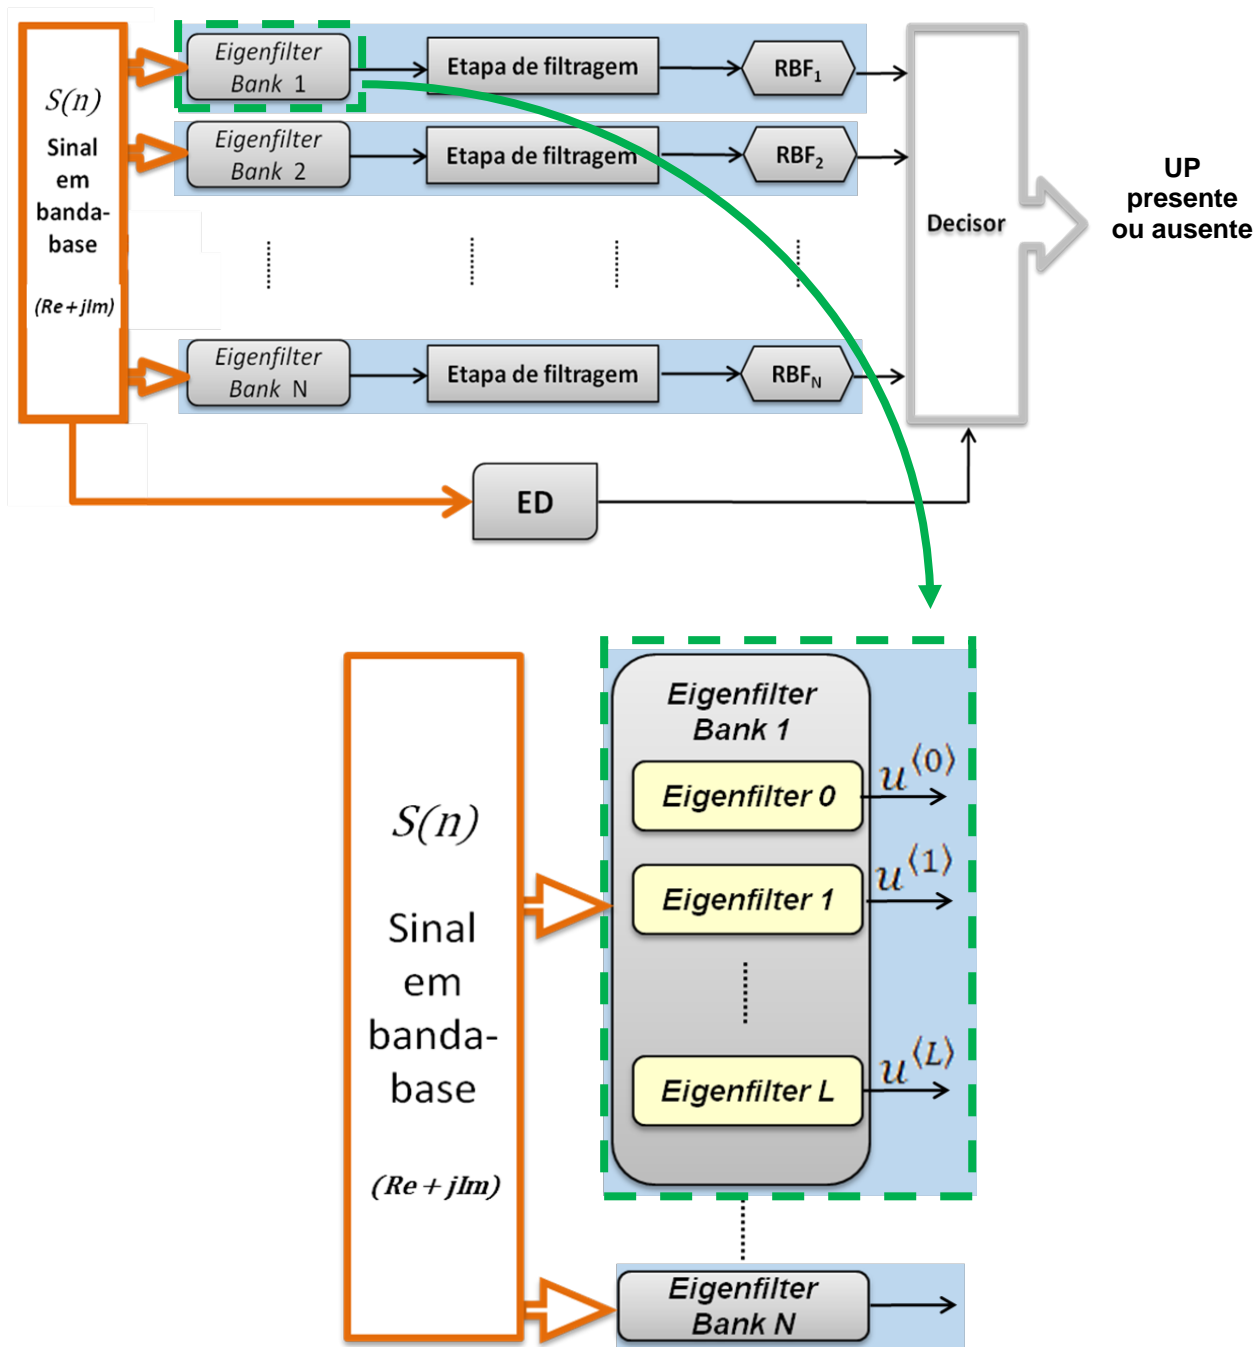
Fonte: a autora.

Note que ao identificarmos os $L = 215$ autovalores λ_ℓ , $\ell = 1, 2, \dots, L$ dentre a totalidade de $M = 320$ autovalores, estamos qualificando-os conforme o procedimento descrito na Seção 4.2.2.2. Em outras palavras, está sendo executada a decomposição da matriz de covariância do sinal em duas partes, separando-se o subespaço de ruído do subespaço de sinal, conforme Equação 4.6. Note que, como

estamos aqui assumindo inexistência de ruído no canal, os autovalores de ruído são todos nulos na Figura 7.2.

Considerando-se os algoritmos definidos por Zeng e Liang (2007), abordados na Seção 4.2.2.2, a verificação da presença de um usuário primário é obtida através da avaliação da razão entre o máximo e mínimo autovalor. Isto significa que o mínimo autovalor, apesar de representar parte do subespaço de ruído, carrega em si informação importante que pode garantir a detecção do sinal do UP em presença de ruído. Desta forma, para efeito de decisão/treino da rede neural RBF a partir do conjunto $\{P_\ell\}$ das potências das projeções conforme discutido no início deste capítulo, além dos $L = 215$ autovetores $\underline{v}^{(\ell)}$, $\ell = 1, 2, \dots, L$, associados ao subespaço de sinal, também é adicionalmente utilizado na formação do *eigenfilter bank* o autovetor $\underline{v}^{(0)}$ correspondente ao menor autovalor, ou seja, correspondente à menor projeção do subespaço de ruído.

Os $L + 1$ autovetores $\underline{v}^{(\ell)}$ assim obtidos para um sinal S_0 , $\ell = 0, 1, \dots, L$, incluindo o autovetor de ruído $\underline{v}^{(0)}$, representam um respectivo *eigenfilter* do *eigenfilter bank* que identifica o sinal S_0 em presença de ruído. Os componentes do ℓ -ésimo autovetor $\underline{v}^{(\ell)}$ correspondem aos coeficientes do filtro FIR que o ℓ -ésimo *eigenfilter* representa. A Figura 7.3 detalha um *eigenfilter bank* assim obtido para um sinal S_0 .

Figura 7.3 – Detalhamento de um *eigenfilter bank*


Fonte: a autora.

Consideremos o *eigenfilter bank* obtido para um sinal S_0 . Um sinal idêntico a S_0 é aplicado na entrada do *eigenfilter bank*. Os $L + 1 = 216$ *eigenfilters* FIR com resposta ao impulso dada por $\underline{v}^{(\ell)}$, $\ell = 0, 1, \dots, L$, efetuam a convolução da respectiva resposta ao impulso representada por $\underline{v}^{(\ell)}$ com a sequência de amostras de $S_0(n)$ na entrada do ℓ -ésimo *eigenfilter* FIR do *eigenfilter bank*. A sequência $u^{(\ell)}(n)$ resultante na saída do ℓ -ésimo *eigenfilter* FIR é a projeção da sequência


$S_o(n)$ no sub-espaço que o autovetor $\underline{v}^{(\ell)}$ representa, conforme mostra a Figura 7.4 para $\ell = 1, 2$ e 3.

Figura 7.4 – (a) Projeções do sinal resultantes da filtragem pelos *eigenfilters* 1, 2 e 3 e (b) zoom da imagem (a).

(a) Projeções do sinal resultantes da filtragem pelos *eigenfilters* 1, 2 e 3



(b) zoom da imagem (a)



Fonte: a autora.

Conforme já discutido no início deste capítulo, o conjunto das P_ℓ potências, $\ell = 1, 2, \dots, L$, relativas às projeções $u^{(\ell)}$ nas saídas dos respectivos *eigenfilters*

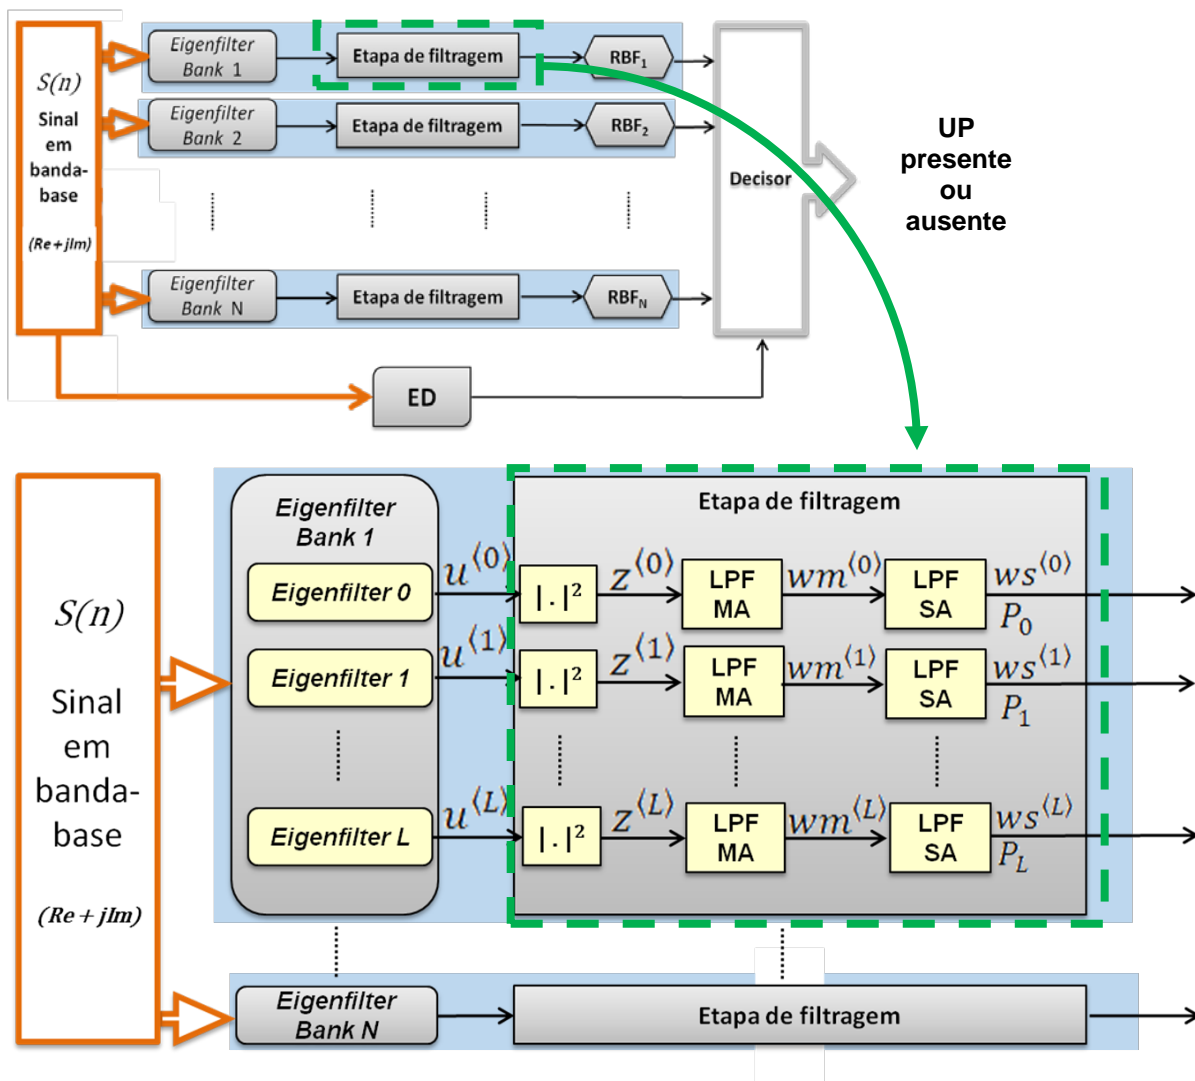
tende ao conjunto de autovalores λ_ℓ do sinal original S_0 que determinou os *eigenfilters* do *eigenfilter bank*, onde L corresponde ao número de autovalores significativos.

Assim, o conjunto das $L + 1$ potências $\{P_\ell\}$ das respectivas sequências de saída $u^{(\ell)}(n)$ dos *eigenfilters* com resposta ao impulso $\underline{v}^{(\ell)}$, $\ell = 0, 1, \dots, L$, incluindo a potência na saída do *eigenfilter* de ruído com resposta ao impulso $\underline{v}^{(0)}$, pode ser usado para identificar um sinal S_{in} em presença de ruído como sendo ou não o sinal S_0 original. Esta identificação é feita mediante a análise da semelhança ou não do conjunto $\{P_\ell\}$ obtido para S_{in} com o conjunto $\{P_\ell\}$ original obtido para S_0 .

A potência P_ℓ da projeção na saída do ℓ -ésimo *eigenfilter* é dada pela média dos valores quadráticos do módulo das amostras complexas da sequência $u^{(\ell)}(n)$ na saída do *eigenfilter*, conforme mostra o retângulo tracejado na Figura 7.5. Note que na saída da cada bloco “Etapa de Filtragem” nesta figura obtém-se idealmente um nível DC proporcional à potência da projeção no subespaço representado pelo ℓ -ésimo *eigenfilter*.

É importante salientar que neste ponto, após a obtenção da potência das projeções, já é possível aplicar os algoritmos de detecção propostos por Zeng e Liang (2007), pois nesta etapa já é possível avaliar a razão entre as potências da máxima projeção e da mínima projeção, que é a técnica básica de detecção dos referidos algoritmos. Entretanto, aqui buscamos mais do que apenas detectar a presença de um UP. Buscamos classificar os sinais, obtendo informações sobre o tipo de UP que está utilizando o espectro.


Figura 7.5 – Etapa de filtragem



Fonte: a autora.

A sequência $z^{(\ell)}(n)$ resultante na saída do ℓ -ésimo bloco de $|\cdot|^2$ é a projeção da sequência $S_0(n)$ no sub-espço que o autovetor $\underline{v}^{(\ell)}$ representa, conforme mostra a Figura 7.6 para $\ell = 1, 2$ e 3.

Figura 7.6 – Resultado da operação $|\cdot|^2$ para as projeções resultantes dos *eigenfilters* 1, 2 e 3.




Fonte: a autora.

Após a operação $|\cdot|^2$ ser aplicada sobre a saída $u^{(\ell)}(n)$ do ℓ -ésimo *eigenfilter*, a sequência resultante $z^{(\ell)}(n)$ é apresentada a um filtro passa baixa (LPF, do inglês, *Low-Pass Filter*) onde a componente AC da potência do sinal P_ℓ no subespaço é removida, restando apenas o valor DC resultante do ℓ -ésimo *eigenfilter*. Neste trabalho são adotados filtros do tipo média móvel (MA, do inglês *Moving Average*) como passa baixa (HAYKIN, 1996). Na Figura 7.5 estes filtros estão representados pelos blocos *LPF MA*.

A janela adotada para cálculo da média móvel dos filtros LPF MA foi experimentalmente ajustada para o valor de 5000 amostras, $J_{MA}=5000$. A Figura 7.7 mostra o resultado desta etapa para $\ell = 1, 2$ e 3. Ao filtrar a sequência $z^{(\ell)}(n)$ é obtida a sequência $wm^{(\ell)}(n)$, denominada como *projeção filtrada*.

Figura 7.7 - Resultado da filtragem LPF MA (projeções filtradas) para as projeções *eigenfilters* 1, 2 e 3.



Fonte: a autora.

Observando-se o resultado do filtro LPF MA, conforme a Figura 7.7, é possível perceber que, apesar da sequência $wm^{(\ell)}(n)$ não apresentar flutuações transitórias, ainda há uma variação significativa nos valores em torno do valor médio, o que poderia prejudicar a formação dos conjuntos de treino das RBFs ou mesmo o processo de decisão das mesmas. Desta forma, foi adicionalmente inserido o bloco *LPF SA*, conforme Figura 7.5, que corresponde a um filtro de média subamostrada.

Seja F o número total de amostras na sequência $wm^{(\ell)}(n)$ (projeção filtrada). Seja $J_{MA}=5000$ amostras, correspondente a janela para cálculo da média móvel dos filtros LPF MA. Apenas as amostras n' , fora do intervalo do regime transitório do filtro LPF MA, tal que $J_{MA} < n' < F - J_{MA}$, serão utilizadas na etapa seguinte. Desta forma, descarta-se as primeiras e as últimas 5000 amostras, da projeção filtrada $wm^{(\ell)}(n)$ tal que sejam consideradas apenas amostras fora do intervalo inicial e fora do intervalo final do regime transitório do filtro LPF MA.

Assim, definimos o tamanho útil α das projeções como sendo:

$$\alpha = F - 2 * J_{MA} \quad (7.1)$$

A sequência de amostras $wm^{(\ell)}(n')$ será encaminhada para filtragem do bloco LPF SA, cujo passo de subamostragem adotado corresponde a $PA=5000$ amostras.

Seja $\underline{wm}^{(\ell)}$ o vetor cujos componentes correspondem às amostras da sequência $wm^{(\ell)}(n')$, onde $\underline{wm}^{(\ell)} = [wm_1 \quad wm_2 \quad \dots \quad wm_\alpha]^T$. Seja $\underline{ws}^{(\ell)} = [ws_1 \quad ws_2 \quad \dots \quad ws_{N_s}]$ o vetor cujas componentes correspondem às amostras da sequência de saída $ws^{(\ell)}(n)$ do filtro LPF SA, onde n representa o índice do tempo discreto para esta sequência e $N_s = \alpha/PA$ representa o tamanho do vetor $\underline{ws}^{(\ell)}$. Seja $mod(x, y)$ o operador que retorna o resto da divisão inteira de x por y . A sequência $ws^{(\ell)}(n)$ é dada pelo pseudocódigo apresentado na Tabela 7.1:

Tabela 7.1 – Pseudocódigo do filtro LPF SA

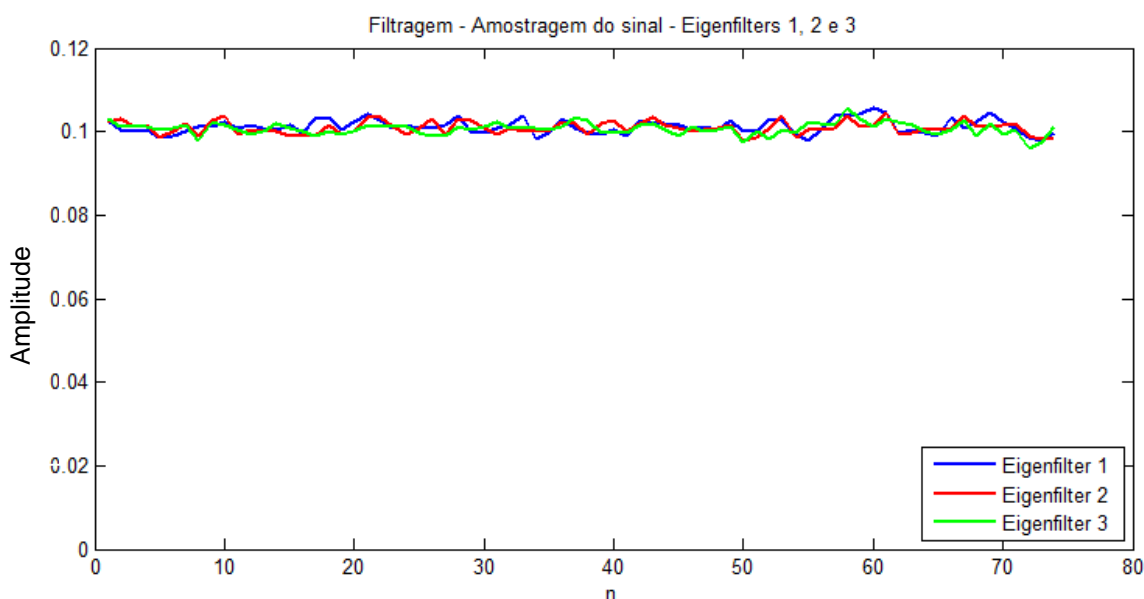
Etapa	Procedimento
1	Inicializar o indexador de iterações n : $n \leftarrow 1$
2	Inicializar o acumulador Acc : $Acc \leftarrow 0$
3	Executar <i>loop</i> para obtenção da sequência $ws^{(\ell)}(n)$: for $i = 1, 2, \dots, \alpha$ $Acc \leftarrow Acc + wm_i$ if ($mod(i, PA) == 0$) { $ws_n \leftarrow Acc/PA$ $Acc \leftarrow 0$ $n \leftarrow n + 1$ }

Fonte: a autora.

Portanto, a cada $PA = 5000$ amostras de $wm^{(\ell)}(n')$ obtém-se uma amostra de $ws^{(\ell)}(n)$. A n -ésima amostra em $ws^{(\ell)}(n)$ é entregue ao ℓ -ésimo nó de entrada da rede RBF no instante discreto n . A saída $d(n)$ desejada da rede RBF para os $L + 1$ valores de $ws^{(\ell)}(n)$ apresentados aos nós de entrada da RBF no instante n , com $\ell = 0, 1, \dots, L$, é, portanto, associada a cada $ws^{(\ell)}(n)$, constituindo o conjunto de treino da rede RBF. Caso o classificador não esteja sendo usado para treinar a rede

RBF, mas sim, esteja avaliando se um sinal S_{in} é ou não de um UP, então o n -ésimo $ws^{(\ell)}(n)$ constitui um conjunto de potências $\{P_\ell\}$ que será avaliado pela rede RBF no n -ésimo ciclo de avaliação. A Figura 7.8 exemplifica o resultado do processo de obtenção das projeções subamostradas $ws^{(\ell)}(n)$ para $\ell = 1, 2$ e 3 , onde ocorre a redução da dimensão dos dados entregues à RBF.

Figura 7.8 – Resultado da média subamostrada para as projeções filtradas resultantes dos *eigenfilters* 1, 2 e 3.



Fonte: a autora.

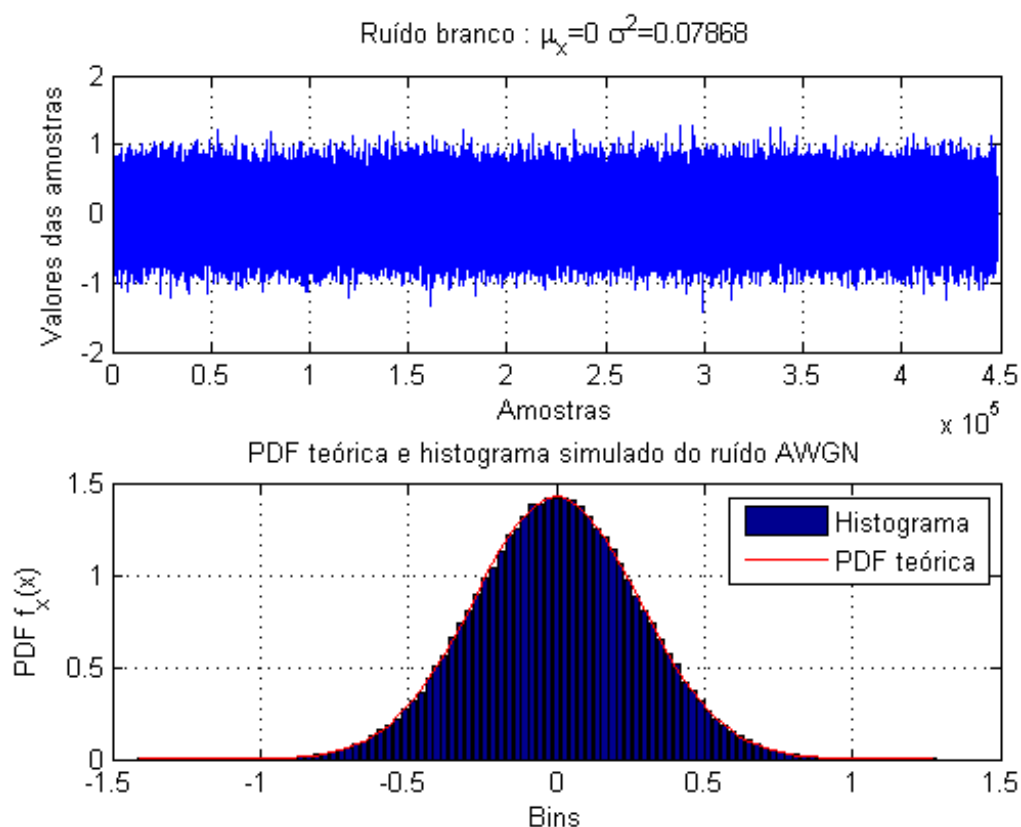
Especificamente, o vetor $\underline{ws}^{(\ell)} = [ws_1 \quad ws_2 \quad \dots \quad ws_{N_S}]$, cujas componentes correspondem às amostras da sequência de saída $ws^{(\ell)}(n)$ do ℓ -ésimo filtro LPF SA, é atribuído à ℓ -ésima coluna da matriz $\mathbf{WS}[N_S \times (L + 1)]$. A matriz \mathbf{WS} representa, portanto, o conjunto das $L + 1 = 216$ projeções subamostradas $ws^{(\ell)}(n)$ com N_S amostras, cada amostra representando um instante n de avaliação pela rede RBF. No cenário indicado pela Figura 7.8, temos $N_S = 74$, ou seja, 74 avaliações serão realizadas pela RBF. A matriz \mathbf{WS} é normalizada em relação ao seu maior valor e reservada para ser utilizada como conjunto de treinamento da RBF. Como a matriz \mathbf{WS} originou-se a partir do sinal S_0 ela é armazenada com o nome \mathbf{WS}_{S_0} . O processo de obtenção da RBF será detalhado na Seção 7.2.1.2.

Na Seção 4.1 foi definida a detecção de oportunidade como sendo uma decisão entre duas hipóteses, conforme Equação 4.1. Na ausência de um usuário primário (UP) a hipótese H_0 é verdadeira e, neste caso, o sinal recebido $y[n]$ é

composto apenas por ruído AWGN. A partir desta premissa foi gerado um conjunto de amostras de ruído AWGN para validar tal hipótese. O ruído AWGN gerado tem média zero ($\mu_x = 0$) e variância (σ^2) equivalente à do sinal (S_0) utilizado na validação da hipótese H_1 , ou seja, presença de UP. Esta equivalência das variâncias foi adotada porque, conforme visto na Seção 2.2, o receptor de RF possui um estágio AGC que estabiliza a amplitude do sinal que é recebido. Esta ação estabilizadora ocorre para todo o sinal que ele recebe, sem distinção entre sinal ou ruído. Mesmo na ausência de UP, quando apenas ruído AWGN será recebido, existirá algum tipo de amplificação deste ruído e, portanto, é coerente e mais realista imaginar este cenário. Desta forma, foi calculada a variância (σ^2) do sinal OFDM S_0 , utilizado anteriormente ($\sigma^2 = 0,07868$) e aplicou-se esta durante a geração do ruído AWGN. A Figura 7.9 mostra detalhes do ruído utilizado.

Figura 7.9 – (a) Amostras de ruído e PDF teórica e (b) Função de autocorrelação do ruído AWGN.


(a) Amostras de ruído e PDF teórica



Fonte: a autora.

Figura 7.9 – (a) Amostras de ruído e PDF teórica e (b) Função de autocorrelação do ruído AWGN.

(b) Função de autocorrelação do ruído AWGN



Fonte: a autora.


Conforme discutido no início deste capítulo, cada tipo de UP tem um sinal característico S_0 que determina um módulo de classificação constituído por um *eigenfilter bank*, uma etapa de filtragem e uma rede neural RBF. Na ausência de UP, o sinal recebido é apenas ruído AWGN, portanto, para simular a ausência de UP, o ruído AWGN é apresentado ao *eigenfilter bank* anteriormente formado, como se fosse um sinal de entrada S_{in} . Entretanto, não é realizado novo cálculo de autovalores e autovetores, nem tampouco nova obtenção da matriz de covariância \mathbf{C} do ruído. Conforme definido nas Seções 4.2.2.2 e 7.1, os ruídos e sinais são descorrelacionados e, conceitualmente, os ruídos apresentam-se distribuídos em todas as frequências do espectro.

Sendo assim, a sequência de amostras complexas $S_{in}(n)$ referentes ao ruído AWGN foi importada no aplicativo MATLAB (MathWorks, 2012) e normalizada em relação à amostra de maior módulo, de modo que todas as amostras de $S_{in}(n)$ assim normalizadas tenham módulo máximo unitário. $S_{in}(n)$ é submetido à filtragem dos $L + 1 = 216$ *eigenfilters* FIR anteriormente obtidos, ou seja, a sequência $S_{in}(n)$ de ruído AWGN é convoluída, individualmente, com resposta ao impulso dada por $\underline{v}^{(\ell)}$,

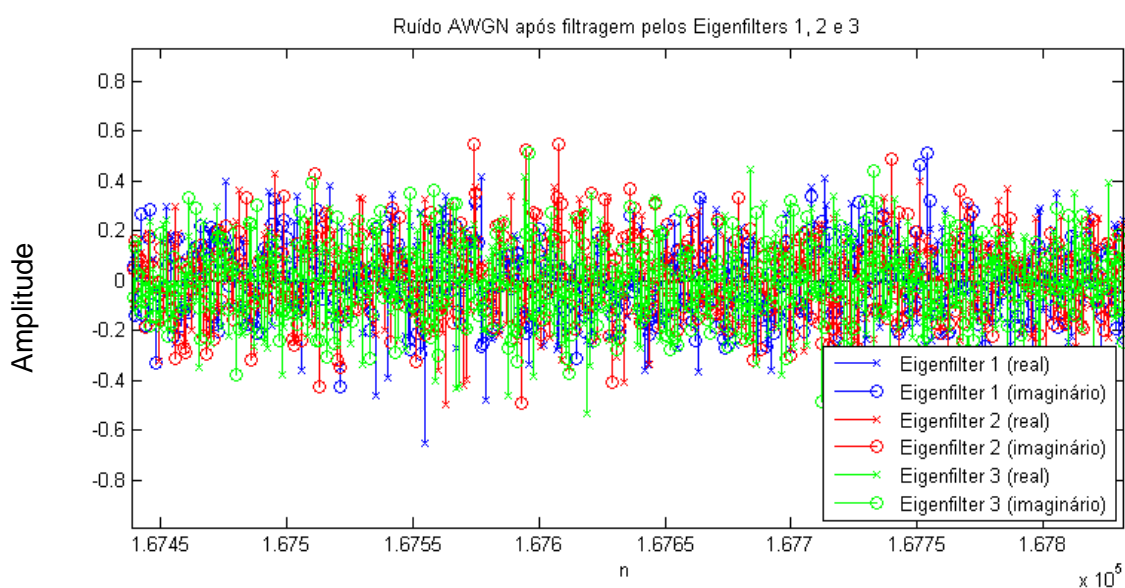
$\ell = 0, 1, \dots, L$ dos $L + 1 = 216$ *eigenfilters* FIR constituintes do *eigenfilter bank*. Desta forma, sequência $u^{(\ell)}(n)$ resultante na saída do ℓ -ésimo *eigenfilter* FIR é a projeção da sequência $S_{in}(n)$ no sub-espço que o autovetor $\underline{v}^{(\ell)}$ representa, conforme mostra a Figura 7.10 para $\ell = 1, 2$ e 3. Na saída do ℓ -ésimo *eigenfilter* FIR obtém-se a respectiva projeção do ruído AWGN no subespaço representado pelo autovetor $\underline{v}^{(\ell)}$ cujos componentes são os coeficientes do *eigenfilter*.

Figura 7.10 – (a) Ruído AWGN após filtragem pelos *eigenfilters* 1, 2 e 3 e (b) zoom da imagem (a).

(a) Ruído AWGN após filtragem pelos *eigenfilters* 1, 2 e 3




(b) zoom da imagem (a).



Fonte: a autora.

Todas as *Etapas de Filtragem*, indicadas na Figura 7.5, que foram executadas para o sinal OFDM S_0 são também executadas para o sinal S_{in} . A janela anteriormente adotada para cálculo da média móvel dos filtros LPF MA foi mantida ($J_{MA}=5000$). A Figura 7.11 mostra as projeções filtradas $wm^{(\ell)}(n)$ para $\ell = 1, 2$ e 3 no cenário em que S_{in} corresponde à ruído AWGN.


Figura 7.11 – Ruído AWGN após filtragem LPF MA das projeções resultantes dos *eigenfilters* 1, 2 e 3.



Fonte: a autora.

Dando continuidade as *Etapas de Filtragem*, indicadas na Figura 7.5, e mantendo-se o passo de subamostragem $PA = 5000$, são obtidas as projeções subamostradas $ws^{(\ell)}(n)$ referentes ao sinal S_{in} , conforme pseudocódigo definido na Tabela 7.1. A Figura 7.12 apresenta as projeções subamostradas $ws^{(\ell)}(n)$ para $\ell = 1, 2$ e 3.

Figura 7.12 – Resultado da média subamostrada para as projeções filtradas relativas ao ruído AWGN resultante dos *eigenfilters* 1, 2 e 3.



Fonte: a autora.

A partir do conjunto das $L + 1 = 216$ projeções subamostradas $ws^{(\ell)}(n)$ é formada a matriz $WS[N_S \times (L + 1)]$, que possui $N_S = 87$ linhas e $L + 1 = 216$ colunas. No cenário indicado pela Figura 7.12, temos $N_S = 87$, ou seja, 87 avaliações serão realizadas pela RBF. Esta matriz WS , gerada a partir do sinal S_{in} correspondente a ruído AWGN, é normalizada em relação ao seu maior valor e reservada com o nome WS_{AWGN} para também ser utilizada como conjunto de treinamento da RBF, a ser detalhado na Seção 7.2.1.2.

A detecção de um usuário primário é realizada com base no sinal deste usuário que está sendo recebido e, por esta razão, é muito provável que este sinal seja de baixa amplitude e esteja inserido num *background* de ruído. Portanto, para simular esta situação, a amostra de sinal OFDM S_0 inicialmente utilizada para obtenção do *eigenfilter bank* é corrompida através de adição de ruído AWGN, dando origem a um novo sinal S_{in} . Adotou-se uma SNR de -5 dB para adição do ruído, o que significa que a relação sinal-ruído é de aproximadamente 0,3 vezes.

Este novo sinal S_{in} , agora degradado pela presença de ruído AWGN, é apresentado ao *eigenfilter bank* anteriormente formado. Sendo assim, a sequência de amostras complexas $S_{in}(n)$ referentes ao sinal OFDM degradado pela presença de ruído AWGN é importada no aplicativo MATLAB (MathWorks, 2012) e

normalizada em relação à amostra de maior módulo, de modo que todas as amostras de $S_{in}(n)$ assim normalizadas tenham módulo máximo unitário. A sequência $S_{in}(n)$ é submetida à filtragem dos $L + 1 = 216$ *eigenfilters* FIR anteriormente determinados, ou seja, a sequência $S_{in}(n)$ de sinal OFDM degradado pela presença de ruído AWGN é convoluída, individualmente, com resposta ao impulso dada por $\underline{v}^{(\ell)}$, $\ell = 0, 1, \dots, L$ dos $L + 1 = 216$ *eigenfilters* FIR constituintes do *eigenfilter bank*.

Desta forma, a sequência $u^{(\ell)}(n)$ resultante na saída do ℓ -ésimo *eigenfilter* FIR é a projeção da sequência $S_{in}(n)$ no subespaço que o autovetor $\underline{v}^{(\ell)}$ representa. Na saída do ℓ -ésimo *eigenfilter* FIR obtém-se a ℓ -ésima projeção do sinal OFDM degradado pela presença de ruído AWGN no subespaço representado pelo autovetor $\underline{v}^{(\ell)}$ cujos componentes são os coeficientes do *eigenfilter*.

De forma análoga ao processo executado para ruído AWGN, todas as *Etapas de Filtragem*, indicadas na Figura 7.5, que foram executadas para o sinal S_{in} , são novamente aqui executadas para o caso do sinal OFDM com $SNR = -5$ dB. A janela anteriormente adotada para cálculo da média móvel dos filtros LPF MA é mantida ($J_{MA}=5000$) assim como o passo de subamostragem ($PA = 5000$).

A partir do conjunto das $L + 1 = 216$ projeções subamostradas $ws^{(\ell)}(n)$ é formada a matriz $\mathbf{WS}[N_S \times (L + 1)]$, que possui $N_S = 74$ linhas e $L + 1 = 216$ colunas. Esta matriz \mathbf{WS} , gerada a partir do sinal S_{in} correspondente a sinal OFDM degradado pela presença de ruído AWGN, é normalizada em relação ao seu maior valor e reservada com o nome \mathbf{WS}_{SN} para também ser utilizada como conjunto de treinamento da RBF, a ser detalhado na Seção 7.2.1.2.

Sendo assim, a partir da análise do sinal OFDM em situação ideal (S_0), do ruído AWGN puro e do sinal OFDM degradado por ruído AWGN foram obtidas as matrizes \mathbf{WS}_{S_0} , \mathbf{WS}_{AWGN} e \mathbf{WS}_{SN} para treinamento da RBF, a ser descrito na Seção 7.2.1.2.

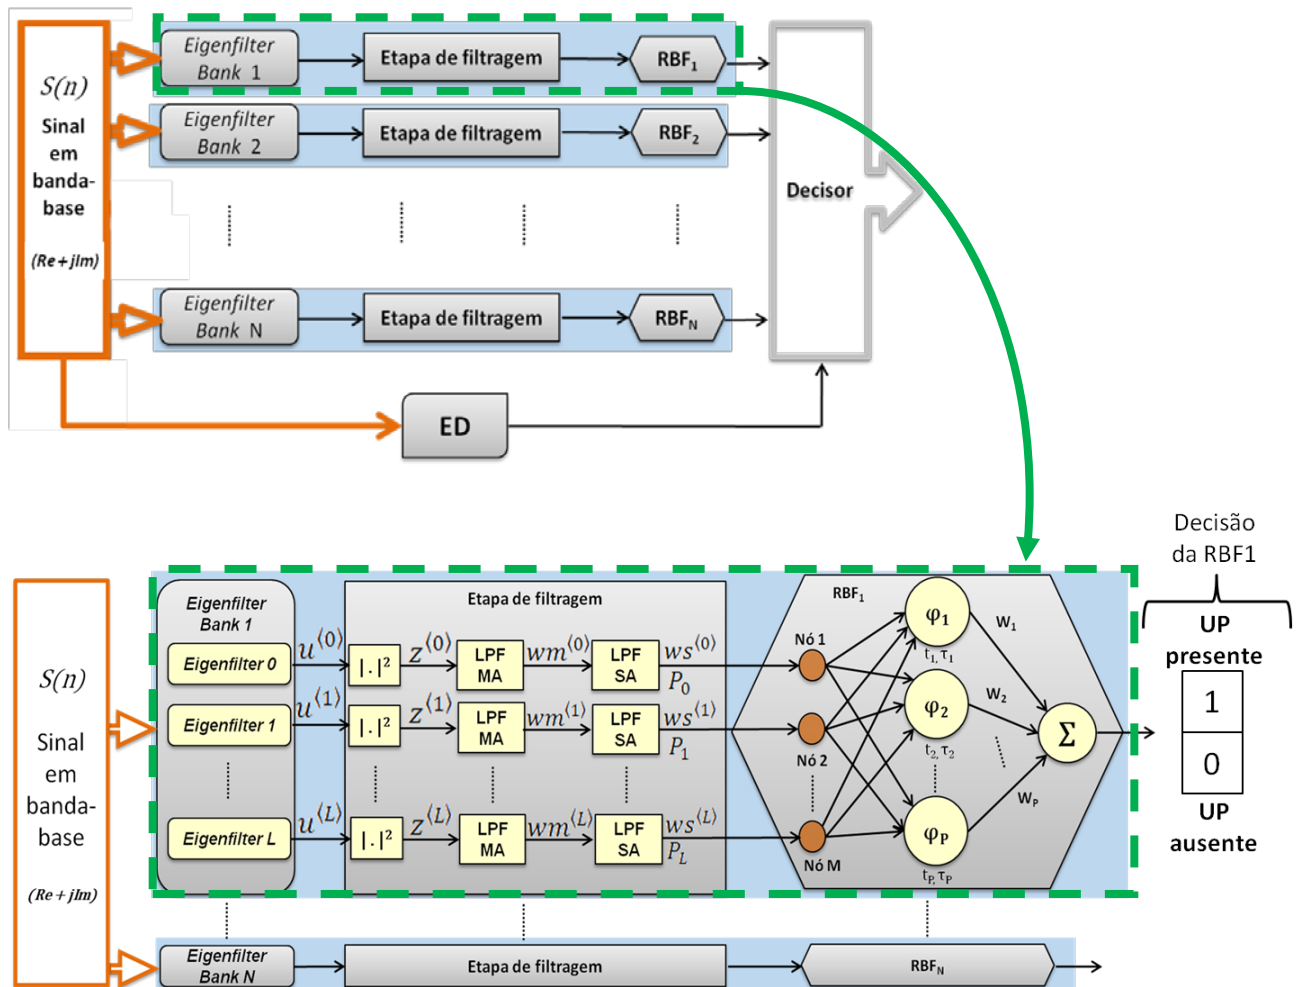
O algoritmo que implementa as etapas descritas nesta seção está disponível no Apêndice A.

7.2.1.2 Determinação das RBFs

Após a obtenção das projeções subamostradas (matrizes WS_{S_0} , WS_{AWGN} e WS_{S_N}) do *eigenfilter bank* para o sinal OFDM, para o ruído AWGN e para o sinal OFDM corrompido por ruído AWGN, conforme descrito na Seção 7.2.1, iniciou-se o processo de determinação e treino de uma RBF capaz de reconhecer a presença do sinal e diferenciá-lo do ruído.

Como mencionado no início deste capítulo, a análise da semelhança entre os conjuntos de potências $\{P_\ell\}$ será efetuada pela rede neural RBF. As matrizes WS_{S_0} , WS_{AWGN} e WS_{S_N} formam o conjunto de treino e validação da RBF, que será responsável por decidir se um sinal S_{in} é, ou não, o sinal S_0 que deu origem ao *eigenfilter bank*.

Em outras palavras, buscou-se uma configuração de RBF capaz de diferenciar as hipóteses H_0 (ausência de UP) e H_1 (presença de UP). O cenário de validação da ausência de UP corresponde a ruído AWGN, enquanto que para validar a presença de UP, foram usados os sinais OFDM, com tamanho de símbolo 256 e CP $\frac{1}{4}$, e a versão deste mesmo sinal corrompida por ruído AWGN com SNR -5 dB. A Figura 7.13 indica a etapa de determinação da RBF para um *eigenfilter bank* específico.

Figura 7.13– RBF1 associada ao *eigenfilter bank* 1

Fonte: a autora.

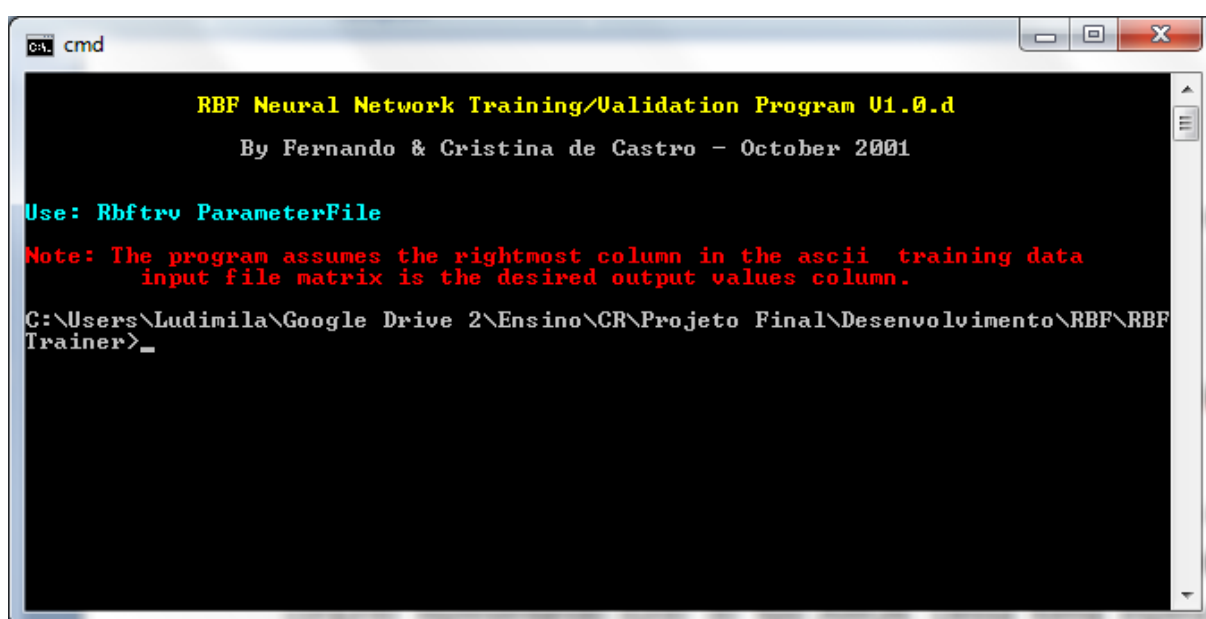
As matrizes WS_{S_0} , WS_{AWGN} e WS_{S_N} de sinal e de ruído geradas a partir das projeções subamostradas, conforme descrição da Seção 7.2.1, formam os conjuntos de treino e validação da RBF. O conjunto de treino ideal para a RBF não deve apresentar muita variabilidade para um mesmo nó de entrada, sob pena da rede não ser capaz de encontrar uma solução para o problema.

No cenário aqui proposto, deseja-se que a resposta da RBF seja 1 quando o sinal S_{in} apresentado for muito similar ao sinal S_0 utilizado para determinação do *eigenfilter bank*, ou seja, corresponder a um UP. No caso do sinal S_{in} não guardar similaridade ao sinal S_0 , deseja-se que a RBF indique 0 como resposta, ou seja, ausência de UP do tipo S_0 ou somente presença de ruído AWGN.

Conforme descrito na Seção 6.1, todas as redes neurais utilizadas no escopo deste trabalho são do tipo RBF e foram treinadas em duas etapas: com

algoritmo *K-means* para treinamento não supervisionado e com método do gradiente estocástico na etapa supervisionada. O aplicativo utilizado para treinamento e validação das RBFs é o “*Radial Basis Function Neural Net Training/Validation program V1.0.d*” (DE CASTRO, 2001). Este programa utiliza como entrada um arquivo texto com as configurações desejadas para treino da RBF. O conjunto de treino e de validação deve ser especificado também em arquivos de texto, onde a saída desejada da rede é indicada na última coluna. A Figura 7.14 mostra a tela inicial do programa.

Figura 7.14 – Interface do programa RBF Neural Net Training/Validation



```
cmd

RBF Neural Network Training/Validation Program V1.0.d
By Fernando & Cristina de Castro - October 2001

Use: Rbftrv ParameterFile
Note: The program assumes the rightmost column in the ascii training data
input file matrix is the desired output values column.
C:\Users\Ludimila\Google Drive 2\Ensino\CR\Projeto Final\Desenvolvimento\RBF\RBF
Trainer>_
```

Fonte: De Castro (2001).

O formato do arquivo com as especificações da rede a ser treinada e validada segue o padrão indicado na Tabela 7.2. Os valores exibidos no campo *Valor* são exemplos, enquanto que os valores do campo *Descrição* correspondem à descrição presente no programa. O arquivo de parametrização do programa deve ser alterado conforme a rede que se pretende treinar.

Tabela 7.2 – Informações do arquivo de treino e validação do programa *RBF Trainer/Validation*

Valor	Descrição
cj_treino.txt	Arquivo de treinamento (<i>TDIF</i>)
cj_validacao.txt	Arquivo de validação (<i>VDIF</i>)
RBF_especificacao.txt	Arquivo com a especificação final da RBF
MSEtvo.txt	Arquivo com MSE de treino e validação
RBFo.txt	Arquivo com resultado da validação
1.00E-03	Critério de parada (<i>StC</i>) - MSE de validação (<i>VMSE</i>)
1.00E-06	Critério de parada (<i>APMChRStC</i>) - Percentual absoluto de variação de <i>VMSE</i>
100	Número de variações consecutivas do <i>VMSE</i> abaixo do <i>APMChRStC</i> , para o qual o programa assume convergência para um mínimo.
0.8	Faixa de inicialização randômica das sinapses dos neurônios de saída
0.2	Coordenadas dos vetores dos centros - Taxa de aprendizado do <i>K-means</i>
1	Critério de parada do <i>K-means</i> - Percentual global de variação da norma dos vetores dos centros
0.8	Coordenadas dos vetores dos centros - Taxa de aprendizado do Gradiente Estocástico
0.8	Variância dos vetores dos centros - Taxa de aprendizado do Gradiente Estocástico
0.8	Sinapses dos neurônios de saída - Taxa de aprendizado do Gradiente Estocástico
4	Número de vetores dos centros Gaussianos

Fonte: De Castro (2001).

Na Seção 7.2.1 foi demonstrado que havia $L + 1 = 216$ autovetores $\underline{v}^{(\ell)}$ obtidos para um sinal S_0 , $\ell = 0, 1, \dots, L$, incluindo o autovetor de ruído $\underline{v}^{(0)}$, que representam um respectivo *eigenfilter* do *eigenfilter bank* que identifica o sinal S_0 em presença de ruído. Portanto, as matrizes \mathbf{WS}_{S_0} , \mathbf{WS}_{AWGN} e \mathbf{WS}_{SN} de sinal e de ruído, oriundas das projeções subamostradas, possuem $L + 1 = 216$ colunas. A quantidade de linhas varia de acordo com a variável N_S , definida na Equação 7.2. Conforme mencionado anteriormente, a amostra de sinal OFDM para esta análise resultou numa matriz com $N_S = 74$ linhas e $L + 1 = 216$ colunas, enquanto que a amostra de ruído resultou numa matriz de $N_S = 87$ linhas e $L + 1 = 216$ colunas. A amostra de sinal OFDM corrompido por ruído AWGN também resultou em uma matriz de $N_S = 74$ linhas e $L + 1 = 216$ colunas. Por limitações de tamanho, estas matrizes não serão reproduzidas da íntegra neste trabalho.

As matrizes WS_{S0} e WS_{SN} correspondem aos dados de sinal, portanto, uma coluna extra foi adicionada em ambas, preenchida com o valor 1, indicando a saída desejada $d(n) = 1$ para a rede RBF. Em outras palavras, as matrizes WS_{S0} e WS_{SN} possuem agora $L + 2 = 217$ colunas, sendo que a última coluna refere-se à saída desejada $d(n)$ a ser avaliada pelo programa *RBF Trainer/Validation*. À matriz WS_{AWGN} também foi adicionada uma coluna extra, resultando em $L + 2 = 217$ colunas, sendo que esta coluna adicional foi preenchida com o valor $d(n) = 0$, ou seja, saída desejada para a RBF na condição de presença de ruído AWGN.

Das novas matrizes WS_{S0} , WS_{AWGN} e WS_{SN} , agora com $L + 2 = 217$ colunas, foram separadas nove linhas para validação, sendo três referentes a ruído (WS_{AWGN}), três a sinal OFDM (WS_{S0}) e mais três correspondentes ao sinal OFDM degradado por ruído AWGN (WS_{SN}), gerando assim a matriz de validação da RBF, doravante denominada VWS . O restante das linhas das matrizes WS_{S0} , WS_{AWGN} e WS_{SN} foi agrupado em uma matriz de treinamento, denominadas matriz TWS .

Para as matrizes de treino (TWS) e validação (VWS) foram treinadas e testadas diversas redes. O programa *RBF Trainer/Validation* gera um arquivo de saída com a especificação da rede obtida.

Foi desenvolvido um procedimento que importa as configurações de rede determinadas pelo *RBF Trainer/Validation*, ou seja, importa a RBF no ambiente do MATLAB (MathWorks, 2012). Este algoritmo está disponível no Apêndice B. Uma vez a RBF tendo sido determinada e importada ela precisa ser apenas simulada. O processo de simulação implica em apresentar à RBF uma entrada e obter a sua resposta para esta entrada. O algoritmo que executa a simulação da rede está disponível no Apêndice C.

Após a obtenção da rede com o programa *RBF Trainer/Validation* foi executada uma nova validação no ambiente do MATLAB (MathWorks, 2012), com outros arquivos de sinal e ruído, ou seja, foram geradas novas amostras de sinal OFDM, ruído AWGN e sinal OFDM degradado por ruído AWGN para que a RBF pudesse ser avaliada. Isto é necessário para verificar a capacidade de generalização da rede obtida, quando a ela submetidas amostras de sinal e ruído que não tenham sido usadas para seu treinamento.

A Tabela 7.3 apresenta, a título de exemplo, um resumo de algumas das redes testadas e suas respostas.

Tabela 7.3 – Resumo de algumas das RBFs testadas para cenário de sinal OFDM com tamanho 256 e CP $\frac{1}{4}$ e ruído AWGN.

Rede	Neurônios de saída	Parâmetro	Sinal	Ruído
RBFS_6	4	<i>Avaliações</i>	74	8
		<i>Acertos</i>	74	8
		<i>Mínima</i>	0.8095	-0.0466
		<i>Máxima</i>	1.1057	0.0625
RBFS_5	4	<i>Avaliações</i>	74	8
		<i>Acertos</i>	74	8
		<i>Mínima</i>	0.9089	-0.0284
		<i>Máxima</i>	1.0546	0.0423
RBFS_4	4	<i>Avaliações</i>	74	8
		<i>Acertos</i>	74	8
		<i>Mínima</i>	0.8135	-0.0188
		<i>Máxima</i>	0.9962	0.1066
RBFS_8	4	<i>Avaliações</i>	74	8
		<i>Acertos</i>	74	8
		<i>Mínima</i>	0.8379	-0.0371
		<i>Máxima</i>	1.0868	0.0565

Fonte: a autora.

Na Tabela 7.3, o parâmetro *Acertos* contabiliza as *Avaliações* para as quais a RBF apresentou resposta correta. Os valores *Mínima* e *Máxima* correspondem, respectivamente, à mínima e máxima resposta da rede para os vetores apresentados para sua análise. Pode-se verificar, por exemplo, que a rede denominada RBFS_5 apresentou respostas mais próximas do ideal, ou seja, 0 ou 1, para ausência ou presença de UP, respectivamente. Entretanto, isto não garante que esta seja a melhor rede para solução do problema proposto, pois ela pode não ser capaz de generalização quando a ela submetidos vetores desconhecidos. Para o classificador proposto não é necessária uma rede extremamente especializada, que retorne valores exatamente iguais a 0 ou 1. Para verificar a presença de um UP é possível trabalhar-se com valores próximos do cenário ideal, uma vez que estamos avaliando similaridade entre os sinais S_0 e S_{in} . Além disso, o sistema proposto conta com uma etapa de decisão, a ser abordada na Seção 7.4, onde os resultados indicados por cada uma das RBFs constituintes do classificador são avaliados.

A título de detalhamento, a Tabela 7.4 apresenta algumas das configurações da rede RBFS_5, onde MSE significa o erro médio quadrático (do inglês, *mean square error*).

Tabela 7.4 – (a) Informações gerais da RBF e (b) Variância dos centros da RBF e sinapses dos neurônios de saída

(a) Informações gerais da RBF

Número de neurônios da camada oculta	4
Número de nós de entrada	216
Número de épocas de treinamento com K-Means	16
Número de épocas de treinamento com Gradiente Estocástico	610
MSE de treino	0.000887744
MSE de validação	0.00085937
BIAS	0.402513

(b) Variância dos centros da RBF e sinapses dos neurônios de saída

Variância dos centros da RBF	Sinapses dos neurônios de saída
243.611	-0.784678
243.524	1.54276
243.591	-0.905166
243.652	1.63941

Fonte: a autora.

No Capítulo 8 serão detalhados testes que consideram a capacidade de generalização das RBFs, ou seja, o desempenho das redes será avaliado em cenários onde o sinal apresentado difere do conjunto de treino e de ruído AWGN. Desta forma, no Capítulo 8 são apresentadas as melhores configurações de RBF obtidas para a classificação dos sinais.

Considerando a Figura 7.13, podemos dizer que após as etapas até aqui descritas, obteve-se um módulo de classificação, composto por um *eigenfilter bank*, uma etapa de filtragem e uma rede neural RBF, apto a executar a classificação de um sinal OFDM com características específicas. A Tabela 7.5 apresenta, de forma resumida, os passos executados para obtenção de um módulo de classificação.

Tabela 7.5 – Resumo do procedimento para obtenção de um módulo de classificação composto de um *eigenfilter bank*, uma etapa de filtragem e uma rede neural RBF

Passo	Procedimento
1	A partir de uma amostra de sinal OFDM (S_0) é obtida a sua matriz de covariância (\mathbf{C}), bem como seus M autovalores λ_m e os M autovetores $\underline{v}^{(m)}$, $m = 1, 2, \dots, M$.
2	A partir dos L autovetores $\underline{v}^{(\ell)}$, $\ell = 1, 2, \dots, L$, associados ao subespaço de sinal e do autovetor $\underline{v}^{(0)}$ correspondente à menor projeção do subespaço de ruído, é criado um banco de filtros FIR (<i>eigenfilter bank</i>).
3	O sinal original S_0 é filtrado por cada <i>eigenfilter</i> FIR constituinte do <i>eigenfilter bank</i> . As projeções filtradas $u^{(\ell)}$ resultantes dessa operação são encaminhadas para uma segunda etapa de filtragem.
4	Após a operação $ \cdot ^2$ ser aplicada sobre as projeções filtradas $u^{(\ell)}$ do ℓ -ésimo <i>eigenfilter</i> , é obtida a sequência $z^{(\ell)}(n)$. Utiliza-se um filtro de média móvel, LPF MA, para obtenção da $wm^{(\ell)}(n')$.
5	A sequência resultante do Passo 4 é submetida a um filtro de média subamostrada, LPF SA, de onde origina-se um conjunto de treino (WS_{S_0}) referente ao sinal S_0 .
6	Uma amostra de ruído AWGN (S_{in}) é apresentada ao <i>eigenfilter bank</i> obtido no Passo 2. Sobre esta nova amostra S_{in} são executados os Passos 3, 4 e 5, de onde origina-se um segundo conjunto de treino (WS_{AWGN}), referente ao ruído AWGN.
7	Uma amostra de sinal OFDM (S_{in}), degradada pela presença de ruído AWGN com SNR de -5 dB, é apresentada ao <i>eigenfilter bank</i> obtido no Passo 2. Sobre esta nova amostra S_{in} são executados os Passos 3, 4 e 5, de onde origina-se um terceiro conjunto de treino (WS_{SN}), referente ao sinal OFDM degradado.
8	Os três conjuntos (WS_{S_0} , WS_{AWGN} e WS_{SN}) foram adaptados e transformados nas matrizes de treino (TWS) e validação (VWS) utilizadas para obtenção de RBFs, até que uma configuração adequada foi encontrada.

Fonte: a autora.

Os procedimentos descritos nas Seções 7.2.1.1 e 7.2.1.2 deram origem a um *eigenfilter bank*, uma etapa de filtragem e uma rede neural RBF que, quando utilizados em conjunto, conforme Figura 7.13, são capazes de detectar se um novo sinal S_{in} , com características similares ao sinal S_o , está presente. Neste caso, a ERB é capaz de reconhecer a presença do mesmo tipo de sinal, no mesmo canal ou em outro canal da faixa, uma vez que as características principais de um dado tipo de sinal mantêm-se similares independentemente do tempo ou do canal.

Através da heurística aqui adotada, foi possível comprovar que um novo sinal S_{in} , com grande similaridade ao sinal S_o que foi utilizado para construir-se um dado módulo de classificação, é reconhecido por este módulo, gerando na saída da RBF associada o valor máximo igual a 1 ou um valor muito próximo deste. De forma análoga, na ausência de UP (apenas ruído AWGN), verificou-se que o módulo foi capaz de indicar valores próximos de zero. Desta forma foi atingida a prova do conceito aqui proposto.

No Capítulo 8 serão apresentadas variações do cenário descrito na Seção 7.2.1, onde serão abordados os efeitos do multipercurso e da presença de ruído impulsivo na detecção do sinal do UP.

7.2.2 Sinal de Microfone Sem Fio

A resolução IEEE 802.22 (2011) especifica que o rádio cognitivo (RC) deve ser capaz de detectar transmissões de microfones sem fio na área de cobertura da WRAN. A detecção do sinal de microfones sem fio é tão importante que levou o IEEE a criar uma especificação de como estes sinais devem ser simulados para testes em cenários de RC. O documento *IEEE 802.22-07/0124r0 Wireless Microphone Signal Simulation Method* (CLANTON, KENKEL, TANG; 2007) descreve as técnicas para modelamento dos sinais de microfones sem fio e suas características de propagação, utilizando equipamentos de laboratório ou ferramentas de simulação. Este documento foi adotado como referência para geração dos sinais de microfone sem fio neste trabalho.

A maioria dos microfones sem fio utiliza modulação FM, conforme descrição da Seção 2.5.1, e alguma onda portadora na faixa de UHF ou VHF (Figura 2.4). O método de simulação sugere duas condições: ambiente externo (*outdoor*) e

ambiente interno (*indoor*). O ambiente *outdoor* é modelado como um canal AWGN enquanto que o ambiente *indoor* é modelado como um canal do tipo Rayleigh (CLANTON, KENKEL, TANG; 2007). Tendo em vista a resolução IEEE 802.22 (2011), que trata os usuários secundários como tendo localização fixa, neste trabalho foi adotada a geração de sinais referentes apenas ao ambiente *outdoor*.

Os sinais de ambiente *outdoor* representam três situações possíveis de operação de um microfone sem fio: *silent*, *soft speaker* e *loud speaker*. Cada uma destas situações é simulada a partir de uma frequência única, ou seja, de acordo com a Equação 2.2, o sinal $V_m(t)$ assume três valores possíveis, cada um deles correspondendo à uma situação de operação do microfone. A Tabela 7.6 apresenta os parâmetros utilizados para a geração dos sinais representativos de um microfone sem fio (CLANTON, KENKEL, TANG; 2007).

Tabela 7.6 – Parâmetros para simulação de sinal de microfones sem fio


	<i>Soft Speaker</i>	<i>Loud Speaker</i>	<i>Silent</i>
Frequência $V_m(t)$ [kHz]	3.9	13.4	32
Desvio de frequência Δf [kHz]	± 15	± 32.6	± 5

Fonte: a autora.


Para efetivamente gerar os sinais de simulação foi implementado o algoritmo do Apêndice D. Adotou-se a frequência de 3 MHz para a portadora (f_c), modulação FM e uma frequência da amostragem (f_s) de 18 MHz. Para o canal AWGN foi considerada uma SNR de 20 dB (TACHWALI, BARNES, BASMA, REFAI; 2010). A Figura 7.15 apresenta o espectro dos sinais gerados.


Figura 7.15 – Periodograma para (a) Microfone no modo *Soft Speaker*, (b) Microfone no modo *Loud Speaker* e (c) Microfone no modo *Silent*

(a) Microfone no modo *Soft Speaker*



(b) Microfone no modo *Loud Speaker*




(c) Microfone no modo *Silent*

Fonte: a autora.

Os sinais modulados em FM, referentes a cada um dos modos de operação do microfone sem fio, foram armazenados para serem utilizados como amostras de sinal S_0 , na etapa de construção dos *eigenfilter banks* referentes à microfones. Entretanto, como neste trabalho foram adotadas técnicas cegas de detecção, conforme Seção 4.2.2, os sinais gerados para simulação do microfone sem fio não podem ser demodulados. A única operação que pode e deve ser realizada é a conversão destes sinais para banda-base.

Os sinais (S_0) de microfone anteriormente gerados estão localizados no espectro conforme a frequência portadora que foi determinada ($f_c = 3\text{MHz}$), sendo assim, cada sinal apresenta um periodograma com máxima SNR centralizada em f_c conforme demonstrado na Figura 7.16.

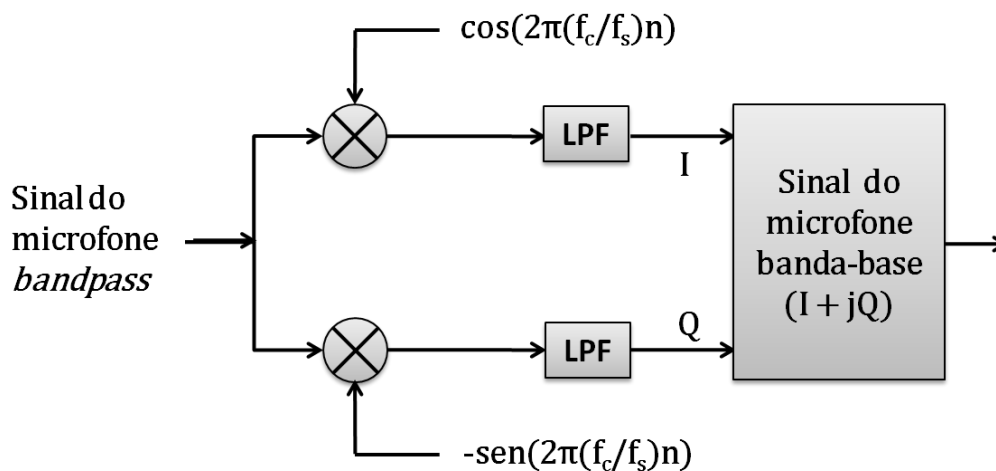
Figura 7.16 – Periodograma do sinal *bandpass* correspondente a microfone em modo *Soft Speaker*



Fonte: a autora.

O processo de conversão do sinal para banda-base ocorre conforme o *Downconverter* especificado na Figura 7.17. O algoritmo que executa esta conversão é apresentado no Apêndice E. Conforme abordado na Seção 2.4, ao realizar o deslocamento do espectro para banda-base é necessária a utilização de um filtro passa-baixa para eliminar a componente que surge na frequência $2f_c$ (6MHz).


Figura 7.17 – Bloco de conversão (*Downconverter*) do sinal *bandpass* de microfone sem fio para banda-base.



Fonte: a autora.

O filtro adotado é do tipo FIR, com ordem 118 e frequência de corte próxima de 450 kHz, o que é perfeitamente suficiente para permitir apenas a passagem do sinal referente ao microfone, cuja largura de banda é de 200 kHz. A resposta em magnitude deste filtro pode ser verificada na Figura 7.18.

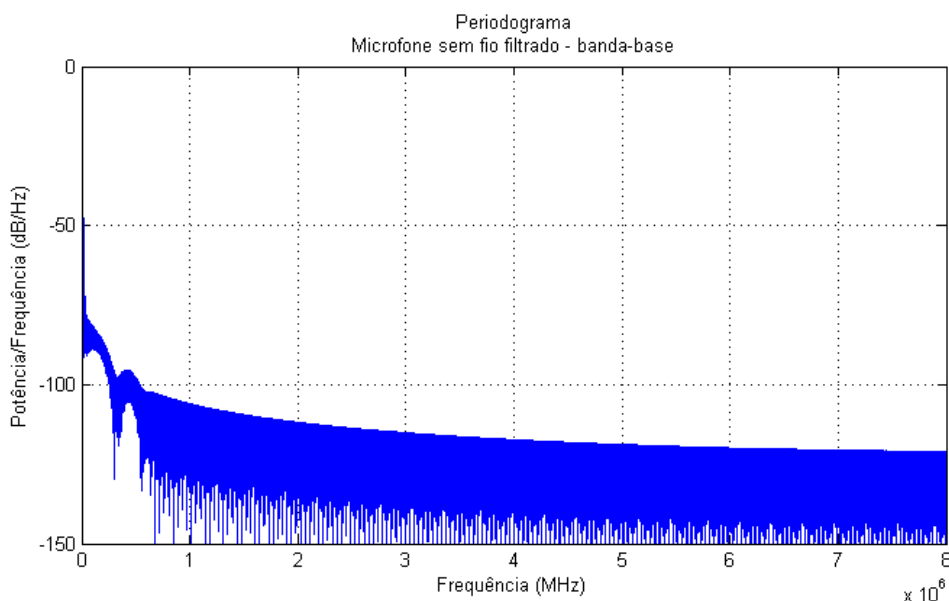
Figura 7.18 – Resposta em magnitude do filtro adotado para sinais de microfone sem fio



Fonte: a autora.

Após esta etapa o sinal do microfone (S_0) está em banda-base e, portanto, pode ser submetido aos procedimentos indicados na Tabela 7.5. A Figura 7.19 apresenta o periodograma do sinal (S_0) após conversão para banda base e filtragem.

Figura 7.19 – Periodograma do sinal banda-base correspondente a microfone em modo *Soft Speaker*




Fonte: a autora.

Os sinais de amostra (S_0) de cada um dos modos de operação do microfone sem fio foram submetidos aos procedimentos descritos na Tabela 7.5. Foi adotada uma janela de $M = 320$ amostras, de forma análoga ao sinal OFDM, para fins de comparação dos resultados referentes aos dois tipos de sinal.

Os resultados obtidos para esta etapa podem ser verificados na Figura 7.20, na qual percebe-se poucos autovalores significativos para os sinais de microfone. Este comportamento era esperado, pois o sinal de microfone é altamente correlacionado.

Figura 7.20 – Autovalores dos sinais de (a) *Soft Speaker*, (b) *Loud Speaker* e (c) *Silent*.

(a) *Soft Speaker* (a imagem à direita é uma aproximação da imagem à esquerda).



(b) *Loud Speaker* (a imagem à direita é uma aproximação da imagem à esquerda).





Figura 7.20 – Autovalores dos sinais de (a) *Soft Speaker*, (b) *Loud Speaker* e (c) *Silent*.

(c) *Silent* (a imagem à direita é uma aproximação da imagem à esquerda).



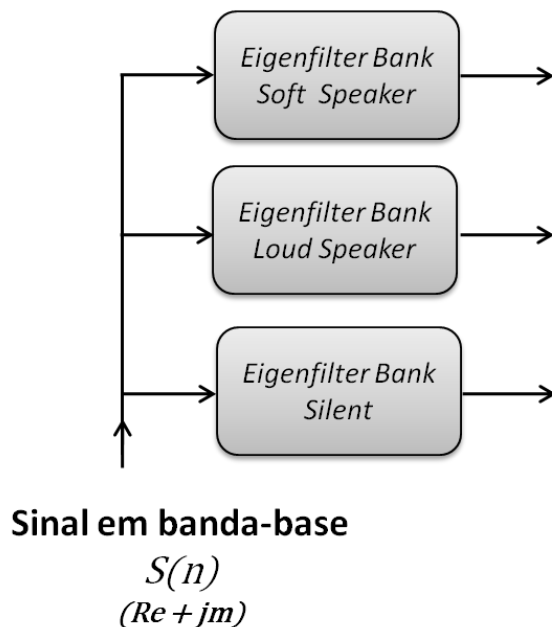
Fonte: a autora.

Através da análise da Figura 7.20, tomando-se como exemplo o sinal referente ao modo *Soft Speaker*, verifica-se que existem apenas dois autovalores significativos, implicando em apenas dois *eigenfilters*, ou seja, numa RBF com apenas dois nós de entrada. Se analisarmos o sinal referente ao modo *Loud Speaker*, encontraremos uma situação similar, com apenas três *eigenfilters*. No cenário *Silent*, temos quatro autovalores significativos, embora suas amplitudes sejam pequenas quando comparadas aos demais cenários.

Buscando-se uma configuração de RBF capaz de atender às necessidades de classificação dos três modos de operação dos microfones sem fio, adotou-se a determinação de seis *eigenfilters* para cada cenário de microfone abordado. Desta forma, para cada sinal (S_θ) foram selecionados os $L = 6$ autovetores $\underline{v}^{(\ell)}$, $\ell = 1, 2, \dots, L$ associados aos $L = 6$ maiores autovalores. Também foi selecionado o autovetor $\underline{v}^{(0)}$ correspondente à menor projeção do subespaço de ruído, o que resultou em $L + 1 = 7$ autovetores $\underline{v}^{(\ell)}$, $\ell = 0, 1, \dots, L$. Os componentes do ℓ -ésimo autovetor $\underline{v}^{(\ell)}$ correspondem aos coeficientes do filtro FIR que o ℓ -ésimo *eigenfilter* representa. Desta forma obteve-se um *eigenfilter bank* para cada modo de operação do microfone sem fio (*eigenfilter banks Soft, Silent e Loud*). Esta heurística garantiu que todos os L autovalores significativos fossem selecionados, possibilitou a obtenção de conjuntos de treino maiores e permitiu a determinação de uma RBF

única para análise de todas as situações operacionais do microfone. A Figura 7.21 apresenta a configuração obtida.

Figura 7.21 – Eigenfilter banks *Soft Speaker*, *Loud Speaker* e *Silent*.




Fonte: a autora.

Caso o sinal de um microfone sem fio seja detectado (UP), independentemente do modo de operação deste microfone, um usuário secundário (US) não deve utilizar o espectro, sob pena de causar interferência sobre o UP. Portanto, no cenário proposto, não é relevante a detecção do modo de operação do microfone, bastando, para fins de proteção do UP, que se saiba sobre a sua presença.

De forma análoga ao procedimento executado para o sinal OFDM, descrito na Seção 7.2.1.1, as amostras de sinal de microfone foram geradas e submetidas aos passos descritos na Tabela 7.5.

A Figura 7.22 apresenta as projeções resultantes da operação $|\cdot|^2$ para $\ell = 1, 2$ e 3 do *eigenfilter bank Soft*, considerando sinal de microfone também no modo *Soft*.


Figura 7.22 – Resultado da operação $|\cdot|^2$ para o sinal de microfone no modo *Soft* para $\ell = 1, 2$ e 3 do *eigenfilter bank Soft*.



Fonte: a autora.

A janela para cálculo da média móvel dos filtros MA, J_{MA} , foi ajustada para o valor de $J_{MA}=5000$ amostras. A Figura 7.23 apresenta as projeções resultantes para $\ell = 1, 2$ e 3 do *eigenfilter bank Soft*, considerando sinal de microfone também no modo *Soft*.


Figura 7.23 - Resultado da filtragem MA para o sinal de microfone no modo *Soft* para $\ell = 1, 2$ e 3 do *eigenfilter bank Soft*.



Fonte: a autora.

Para o cenário de microfone sem fio, o passo de subamostragem PA foi reduzido para $PA = 100$ amostras, uma vez que a variabilidade do sinal de microfone sem fio é menor do que a do sinal OFDM, apresentando valores estáveis com passo de amostragem menor. A Figura 7.24 apresenta as projeções resultantes para $\ell = 1, 2$ e 3 do *eigenfilter bank Soft*, considerando sinal de microfone também no modo *Soft*.

Figura 7.24 - Resultado da média subamostrada para o sinal de microfone no modo *Soft* para $\ell = 1, 2$ e 3 do *eigenfilter bank Soft*.



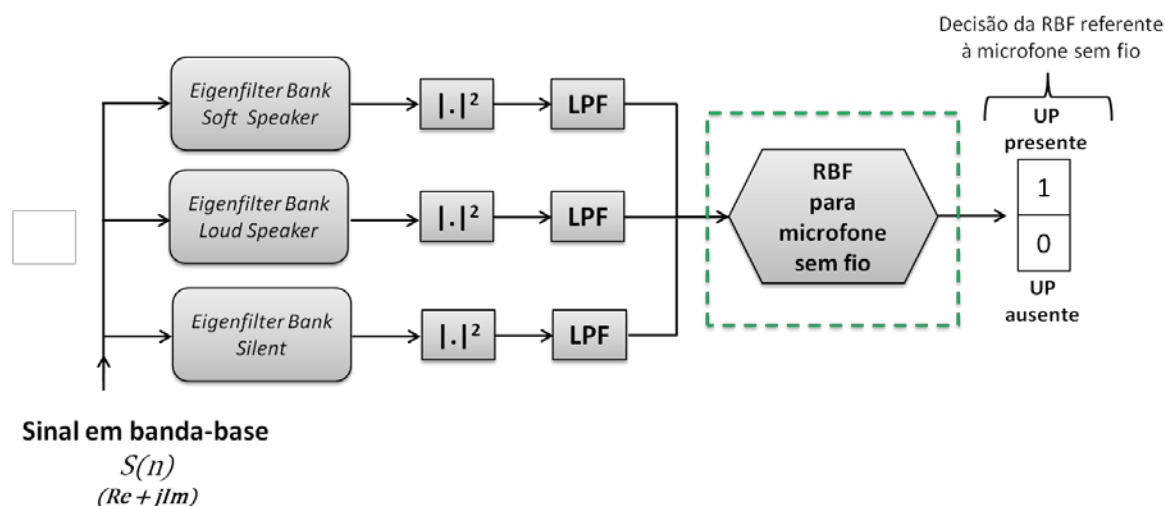
Fonte: a autora.

Assim foi obtida a matriz WS_{S_0} referente a sinais de microfone sem fio. Posteriormente, ruído AWGN e sinais de microfone degradados por ruído AWGN com SNR de -5 dB também foram apresentados a cada um dos *eigenfilter banks* referentes a sinais de microfone sem fio (*eigenfilter banks Soft, Silent e Loud*), de acordo com o procedimento descrito na Tabela 7.5, de onde obteve-se as matrizes WS_{AWGN} e WS_{SN} . Ao final deste processo foram obtidas as matrizes TWS e VWS para treinamento e validação da RBF classificadora de sinais de microfone sem fio.

Um processo de sensoriamento de espectro num contexto de rádio cognitivo precisa ser capaz de detectar a presença de um sinal de microfone sem fio, esteja este microfone em qualquer um dos modos de operação. Entretanto, o processo de sensoriamento de espectro não precisa, necessariamente, diferenciar os modos de operação do microfone. Isto quer dizer que a rede neural RBF para esta análise

precisa ser inteligente o suficiente para detectar a presença do sinal de microfone, mas não especializada a ponto de saber o seu modo de operação. Em resumo, este cenário permite que seja reduzida a quantidade de redes neurais RBF para análise, conforme indicado na Figura 7.25.

Figura 7.25 – Redução da quantidade de redes neurais RBFs necessária para análise da presença de UP, no cenário de microfone sem fio



Fonte: a autora.

Para o cenário de microfone sem fio, a etapa de treinamento de RBFs ocorreu de forma análoga ao descrito na Seção 7.2.1.2, respeitando-se o fato das matrizes TWS e VWS possuírem número de colunas condizente ao cenário de sinal de microfone sem fio. Na Tabela 7.7 apresenta-se um resumo de algumas das RBFs testadas para o cenário de microfone sem fio.

Tabela 7.7 – Resumo de algumas das RBFs testadas para cenário de sinal de microfone sem fio.

Rede	Neurônios de saída	Parâmetro	Eigenfilter bank					
			Soft Speaker		Loud Speaker		Silent	
			Sinal	Ruído	Sinal	Ruído	Sinal	Ruído
RBFS_WMIC_3	4	Avaliações	1654	34	1654	34	1654	34
		Acertos	1654	34	1654	34	1654	34
		Mínima	1.029	0.0034	1.0013	0.022	1.0649	0.0049
		Máxima	1.043	0.0912	1.0284	0.0993	1.0763	0.1018
RBFS_WMIC_4	4	Avaliações	1654	34	1654	34	1654	34
		Acertos	1654	34	1654	34	1654	34
		Mínima	0.987	-0.047	1.002	-0.0453	1.0188	-0.044
		Máxima	1.011	0.0205	1.0252	0.0302	1.032	0.0157
RBFS_WMIC_5	3	Avaliações	1654	34	1654	34	1654	34
		Acertos	1654	34	1654	34	1654	34
		Mínima	0.993	-0.053	0.9905	-0.0215	1.0046	-0.047
		Máxima	1.005	-0.023	1.0147	0.0041	1.0183	-0.014
RBFS_WMIC_8	2	Avaliações	1654	34	1654	34	1654	34
		Acertos	1654	34	1654	34	1654	34
		Mínima	0.987	-0.067	0.996	-0.0438	1.0013	-0.049
		Máxima	0.997	0.0443	1.0158	0.0678	1.0113	0.0409

Fonte: a autora.

Qualquer uma das RBFs descritas na Tabela 7.7, em conjunto com os *eigenfilter banks* referentes ao sinal de microfones sem fio, é capaz de detectar a presença de um usuário primário (UP) do tipo microfone sem fio. No Capítulo 8 será apresentada a RBF que obteve melhores resultados quanto à classificação de sinais de microfone sem fio e também serão detalhados testes que consideram a capacidade de generalização desta RBF, avaliando o seu desempenho em cenários onde o sinal apresentado difere de forma significativa do seu sinal de referência.

7.2.3 Sinal de TV Digital


Conforme verificado no Capítulo 5, a resolução IEEE 802.22 (2011) padroniza a interface área, incluindo as camadas MAC e PHY, de WRANs operando nas bandas de TV de VHF/UHF entre 54 MHz e 862 MHz em regiões de baixa densidade populacional. Num cenário de uma rede de rádios cognitivos (RRC) é bastante provável que parte dos usuários primários (UPs) seja referente à sinais de

TV. Por esta razão, a construção de um módulo classificador capaz de detectar este tipo de sinal foi implementada.

Dentre os diversos padrões DTTB abordados da Seção 2.5.3, escolheu-se o padrão DVB-T (do inglês, *Digital Video Broadcasting Terrestrial*) (ETSI-EN-300744, 2009) para uso neste trabalho, pois é um dos padrões mais difundidos no mundo.

O simulador “*DVB-T 2k Mode, Nonhierarchical Transmission*” disponível no programa MATLAB (MathWorks, 2012) foi utilizado para a geração do sinal de TV utilizado neste trabalho. O simulador é baseado na referência ETSI-EN-300744 (2009) que regulamenta o padrão de transmissão DVB-T. A Figura 7.26 mostra um exemplo de periodograma do sinal gerado com este simulador, já em banda-base.

Figura 7.26 – Periodograma do sinal de TV digital utilizado para simulação




Fonte: a autora.


Uma vez gerado o sinal DVB-T, este foi submetido ao mesmo processo descrito na Tabela 7.5, de forma análoga ao aplicado aos sinais OFDM e de microfone sem fio, conforme descrito nas Seções 7.2.1.1 e 7.2.2, respectivamente. No caso do sinal DVB-T, foram observados $L = 80$ autovalores significativos, num conjunto de $M = 2048$. O tamanho $M = 2048$ deve-se ao fato do simulador utilizado gerar símbolos com este tamanho. A Figura 7.27 apresenta os autovalores significativos para o sinal DVB-T.

Figura 7.27 – Autovalores significativos para o sinal DVB-T. A imagem inferior (b) é uma aproximação da imagem superior (a).

(a) Autovalores significativos para o sinal DVB-T



(b) aproximação da imagem superior (a)



Fonte: a autora.

Desta forma, para o sinal DVB-T (S_0) foram selecionados os $L = 80$ autovetores $\underline{v}^{(\ell)}$, $\ell = 1, 2, \dots, L$ associados aos $L = 80$ maiores autovalores. Também foi selecionado o autovetor $\underline{v}^{(0)}$ correspondente à menor projeção do subespaço de ruído, o que resultou em $L + 1 = 81$ autovetores $\underline{v}^{(\ell)}$, $\ell = 0, 1, \dots, L$. Os componentes do ℓ -ésimo autovetor $\underline{v}^{(\ell)}$ correspondem aos coeficientes do filtro FIR que o ℓ -ésimo *eigenfilter* representa. Portanto, para o cenário DVB-T, obteve-se $L + 1 = 81$ *eigenfilters*, que formaram o que denominou-se como *eigenfilter bank* DVB-T.

Os procedimentos descritos na Tabela 7.5 foram aplicados ao sinal S_0 . A janela para cálculo da média móvel dos filtros MA, J_{MA} , foi ajustada para o valor de $J_{MA}=5000$ amostras. No caso específico do sinal DVB-T, descartaram-se as primeiras 15000 e as últimas 5000 amostras, assim excluindo do conjunto de treino da RBF quaisquer valores transitórios oriundos do filtro LPF MA. O passo de subamostragem PA foi configurado para $PA = 5000$ amostras.

. Assim foi obtida a matriz WS_{S_0} referente ao sinal DVB-T. Posteriormente, ruído AWGN e sinal DVB-T degradado por ruído AWGN com SNR de -1 dB também foram submetidos ao procedimento descrito na Tabela 7.5, de onde obteve-se as matrizes WS_{AWGN} e WS_{SN} . Ao final deste processo foram obtidas as matrizes TWS e VWS para treinamento e validação da RBF classificadora de sinais DVB-T.

Através de inspeção visual e avaliação dos valores das projeções subamostradas obtidas para o cenário de sinal DVB-T degradado por ruído AWGN com SNR de -5 dB foi possível verificar que estas projeções eram muito similares às projeções do ruído AWGN puro. Isto significa dizer que o conjunto de treinamento a ser oferecido para a RBF resultaria numa situação onde não haveria convergência do algoritmo, pois o ruído e o sinal degradado possuem grande similaridade e a RBF seria incapaz de diferenciá-los. Desta forma, adotou-se uma SNR menor (-1 dB), para manter diferenciação entre ruído AWGN e sinal degradado por ruído, oferecendo a RBF um conjunto de dados para o qual fosse possível atingir convergência.

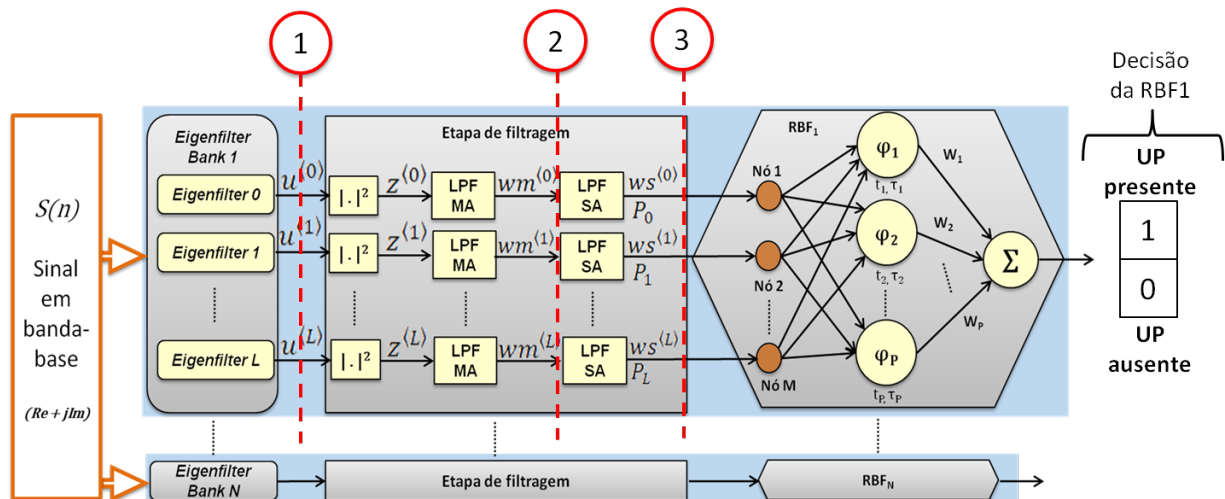
A partir das matrizes TWS e VWS foram treinadas e testadas diversas RBFs para detecção de sinais DVB-T. A melhor configuração de RBF obtida será apresentada no Capítulo 8, onde também será avaliada a sua capacidade de

generalização e seu desempenho quando submetidos à sua análise sinais que diferem, de forma significativa, do seu sinal de referência.

7.3 Processo de Detecção

Uma vez concluído o processo de determinação dos módulos de classificação, a cada novo sinal (S) a ser classificado são realizadas apenas as *Etapas de Filtragem* e análise dos dados pela RBF, conforme indicado na Figura 7.13, sem necessidade de determinação de matrizes de covariância (C) ou cálculo de autovalores λ_m e autovetores $\underline{v}^{(m)}$. Para conveniência do leitor, a Figura 7.28 destaca na Figura 7.13 os principais pontos do processo de classificação, a serem abordados com exemplos numéricos na sequência desta Seção.

Figura 7.28 – Processo de detecção para um módulo de classificação.




Fonte: a autora.

Considerando um exemplo numérico, uma projeção $u^{(\ell)}$ composta de 400 mil números complexos (ponto 1), após a etapa de filtragem por média móvel, LPF MA, resultará em uma projeção $wm^{(\ell)}$ com 390 mil números complexos (ponto 2), se a janela de média móvel for de $J_{MA} = 5000$ amostras. Desta forma o tamanho útil (α) da projeção $wm^{(\ell)}$, conforme definido pela Equação 7.1, é $\alpha = 390$ mil amostras. Sendo $PA = 5000$ amostras o passo de subamostragem, para cada *eigenfilter* ℓ são obtidas $N_S = 78$ subamostras $ws^{(\ell)}$ para análise pela RBF (ponto 3).

Tomando-se como base um sistema de transmissão de TV digital, com um *clock* da FFT aproximado de 8 MHz, a cada 1/8MHz teremos uma amostra no domínio tempo. Portanto, para a obtenção de 10 mil amostras, são necessários 1,25 ms de monitoração do espectro. Neste cenário, com apenas 10 mil amostras o classificador proposto é capaz de informar uma decisão sobre a presença de usuário primário (UP). A Figura 7.29 ilustra este exemplo, no qual no ponto indicado por N_{S1} a rede RBF já seria capaz de informar uma decisão sobre a presença de um UP.

Figura 7.29 – Processo de detecção.



Fonte: a autora.

O referido intervalo de tempo de 1,25 ms é significativamente menor do que o determinado pela IEEE 802.22 (2011), a qual especifica que qualquer técnica de detecção deve ser capaz de verificar a presença de um UP em no máximo 2 segundos, sendo que os períodos de silêncio não devem ultrapassar 200 ms na soma agregada de tempo. A velocidade da resposta do classificador pode ser ainda reduzida, dependendo dos valores configurados para janela de filtros média móvel (J_{MA}) e passo de subamostragem (PA).

A complexidade agregada dos algoritmos EME e MME, desenvolvidos por Zeng e Liang (2007), é de ordem $O(N^2) + O(N^3)$, sendo a primeira parte associada ao cálculo da matriz de covariância (\mathbf{C}) enquanto a segunda parte refere-se ao cálculo dos autovalores λ_m . No classificador proposto, a maior complexidade computacional atingida é $O(N^2)$, que ocorre na filtragem dos *eigenfilters* FIR e nos filtros LPF MA e LPF SA. A etapa de avaliação da RBF possui complexidade $O(N)$ (MORSE, YOO; 2001). Desta forma, a complexidade dominante no caso do classificador proposto é $O(N^2)$, o que representa redução do custo computacional da

detecção em relação aos métodos apresentados por Zeng e Liang (2007), cuja complexidade dominante é $O(N^3)$, já que o cálculo dos autovalores λ_m é necessário a cada detecção realizada com os algoritmos EME ou MME.

7.4 Detector de Energia e Decisor

Imaginando um cenário prático de RRC, após a determinação dos módulos de classificação, a ERB está apta a realizar a detecção de sinais na área de abrangência da WRAN. Uma ERB cognitiva pode observar o espectro nas suas cercanias e, através da obtenção de amostras dos sinais presentes (S_0), determinar os módulos de classificação, compostos por *eigenfilter banks*, etapas de filtragem e redes neurais RBFs, de forma automática. A entidade de gerenciamento de espectro (SM), prevista na resolução IEEE 802.22 (2011) e abordada no Capítulo 5, poderia ser responsável pelo processo de análise e construção destes bancos. Desta forma, uma ERB seria capaz de reconhecer todos os tipos de UP presentes na sua área de cobertura.

Na prática, sabe-se que há um número finito de sinais em uso comercial e, portanto, não é impossível que uma ERB venha a conhecer todos estes sinais. Entretanto, o processo de aprendizado de um sinal depende da ERB ter recebido uma amostra (S_0) deste sinal e ter determinado o respectivo módulo de classificação para sua análise. É razoável prever que um novo UP, utilizando um equipamento cujo tipo de sinal (S) transmitido é desconhecido pela ERB, pode adentrar a área de cobertura da WRAN a qualquer momento. Neste cenário, a ERB não seria capaz de reconhecer o tipo de sinal do UP, pois ainda não existe o módulo de classificação para análise deste novo sinal. Pode acontecer também que o sinal de um UP já conhecido seja recebido sob um cenário de multipercurso não conhecido tal que o mesmo degrade o sinal do UP além da capacidade de generalização da rede RBF classificadora. Nesta situação de multipercurso desconhecido a rede RBF seria incapaz de reconhecer o sinal como sendo de um UP, e poderia classificá-lo erroneamente como ruído. No entanto, não sendo ruído, este sinal deve ser classificado como um novo sinal de UP. Para contornar a falha do classificador na situação em que o sinal do UP é desconhecido, o sistema proposto adota um detector de energia (ED, do inglês *Energy Detector*) que substitui o módulo

classificador quando a entidade de gerenciamento de espectro (SM) da ERB cognitiva efetua a varredura do espectro (para efeito de determinação dos *eigenfilter banks* e redes RBFs da base de sinais armazenados na ERB) e capta durante esta varredura o sinal de um UP desconhecido à SM.

Conforme exposto na Seção 4.2.2.1, a detecção de energia é uma das técnicas cegas de sensoriamento de espectro.


O processo de detecção de um sinal na presença de ruído depende do quanto se conhece das características deste sinal e do ruído. Quando o sinal é conhecido, pode-se optar por técnicas não-cegas, como as mencionadas na Seção 4.2.1, mas quando as características do sinal são desconhecidas é apropriado considerá-lo como uma amostra de um processo randômico (URKOWITZ, 1967).

Na situação aqui prevista, não se conhece a forma do sinal (S), portanto, não é possível fazer suposições a seu respeito. Entretanto, este sinal é considerado determinístico, pois apesar de seus detalhes serem desconhecidos, a região no espectro na qual ele está confinado é conhecida (URKOWITZ, 1967).

O detector de energia aqui implementado mede a energia do sinal num determinado intervalo de tempo. Como apenas a energia do sinal é relevante nesta análise, o detector de energia pode ser utilizado para qualquer sinal determinístico.

A Figura 7.30 apresenta o formato construtivo do detector de energia padrão (JUNWEI, YUNXIAO; 2009).


Figura 7.30 – Detector de energia padrão



Fonte: adaptado de Junwei, Yunxiao (2009).

Através da análise da Figura 7.30 nota-se que a implementação do detector é relativamente simples, pois consiste de um bloco que determina a potência do sinal seguido de um bloco integrador. O pré-filtro serve para limitar a banda do ruído. Neste trabalho o pré-filtro é assumido estar já implementado no *front-end* de RF do receptor e o integrador é aproximado por um filtro de média móvel (MA, do inglês *Moving Average*), conforme Figura 7.31.

Figura 7.31 – Detector de energia implementado



Fonte: a autora.

A escolha do intervalo de integração T do sinal é uma questão de conveniência, no entanto T deve ser tão longo quanto possível, para evitar falsos alarmes por ruído impulsivo. Note que o ED atua somente enquanto a entidade SM da ERB cognitiva efetua a varredura do espectro visando a determinação dos módulos de classificação (*eigenfilter banks* e redes RBFs) da base de sinais armazenados na ERB. Pelo fato do ED não atuar durante a operação de detecção realizada pelo módulo de classificação, um T longo não atrasará o tempo de detecção de UPs já conhecidos da base de sinais da entidade SM. Neste tipo de detector, a decisão sobre a existência de um sinal obedece às mesmas hipóteses de detecção apresentadas na Seção 4.1.

No cenário aqui vislumbrado, a ERB não conhece ainda este novo sinal (S) e, portanto, não existe um módulo de classificação apto a realizar a sua detecção. Não é possível prever a resposta exata que os módulos de classificação existentes terão ao analisarem este novo sinal, mas sabe-se que a sua resposta não será idêntica ao sinal (S_0) por eles conhecido e tampouco ao ruído AWGN. Sendo assim, a resposta dos módulos de classificação existentes para um sinal desconhecido pode não ser conclusiva para determinar-se a presença de um UP.

A Figura 7.1 apresenta a arquitetura do sistema proposto, a qual conta com um bloco *Decisor*, responsável pela análise de todas as saídas das RBFs e avaliação sobre a presença de um UP. É previsto que este bloco também considere a informação enviada pelo detector de energia. Desta forma, nos cenários para os quais as saídas das RBFs não indicarem informação conclusiva, a resposta do detector de energia pode ser utilizada a fim de evitar alocação de espectro que esteja ocupado por um UP, protegendo assim os usuários licenciados. Com esta abordagem, mesmo que o sistema não seja capaz de determinar com exatidão qual tipo de UP está utilizando o espectro, ele possuirá condições de determinar que o canal em questão não está livre para alocação. A entidade de gerenciamento de

espectro (SM), prevista na resolução IEEE 802.22 (2011) e abordada no Capítulo 5, poderia também utilizar a informação do detector de energia como gatilho para a determinação de novos módulos de classificação.

O processo *Decisor* baseia-se essencialmente na avaliação das saídas das RBFs para um sinal (S) recebido pela ERB. A RBF que indicar a saída mais próxima do valor 1 representa a maior correlação do sinal recebido com o modelo treinado, ou seja, o sinal recebido (S) possui grande similaridade ao sinal (S_0) usado para treinamento do módulo. Na presença de ruído AWGN, todas as RBFs indicarão saídas próximas à zero. Caso nenhuma RBF indique similaridade superior a um limiar de decisão pré-estabelecido, a resposta do detector de energia ED deve ser avaliada.

A janela de cálculo da média móvel J_{MA} adotada no detector de energia implementado foi de $J_{MA} = 20$ mil amostras. O algoritmo utilizado para implementação deste detector está disponível no Apêndice H. A Figura 7.32 apresenta a resposta do detector de energia implementado quando submetido a sinais de microfone sem fio e OFDM, comparados a ruído AWGN. Em ambos os cenários é possível distinguir claramente o sinal do ruído, o que permite ajustar com folga um limiar de detecção adequado.

Figura 7.32 – Detector de energia para (a) sinal de microfone sem fio e para (b) sinal OFDM

(a) Detector de energia para sinal de microfone sem fio





Figura 7.32 – Detector de energia para (a) sinal de microfone sem fio e para (b) sinal OFDM

(b) Detector de energia para sinal de microfone OFDM



Fonte: a autora.

Conforme mencionado na Seção 4.2.2.1, a detecção de energia não diferencia sinais modulados, ruído ou interferência (YU, 2011), portanto, o ajuste do limiar de detecção por energia pode ser uma tarefa complicada num cenário que exija velocidade de detecção. Entretanto, no cenário aqui proposto, não existe a demanda por rapidez na avaliação, uma vez que, conforme já discutido anteriormente nesta seção, o detector de energia implementado é apenas uma forma secundária de detecção que visa proteger os usuários primários, na ocorrência de um sinal que o classificador ainda não esteja apto a classificar. Em outras palavras, em caso de dúvida, o sistema deve assumir que a porção do espectro avaliada está ocupada, evitando assim qualquer impacto aos usuários primários (UPs).

8 Resultados Obtidos

Neste capítulo são abordados os principais resultados obtidos com o classificador proposto. Para maior clareza, os resultados estão agrupados por cenários.

8.1 Cenário 1: Sinal OFDM

Neste cenário foi utilizado o módulo de classificação obtido para o sinal OFDM 256, conforme descrito na Seção 7.2.1.1. Diversas RBFs foram treinadas para operação neste módulo de classificação, conforme exemplificado na Seção 7.2.1.2. Dentre as diversas redes obtidas e testadas, os melhores resultados de detecção de usuário primário (UP) ocorreram com a RBF denominada RBF_{FS_OFDM_256_216_3}. Para fins de exposição de resultados, esta RBF será doravante denominada apenas como RBF OFDM. O resumo da sua configuração é apresentado na Tabela 8.1.

Tabela 8.1 – (a) Informações gerais da RBF OFDM e (b) Variância dos centros da RBF OFDM e sinapses dos neurônios de saída

(a) Informações gerais da RBF OFDM

Número de neurônios da camada oculta	4
Número de nós de entrada	216
Número de épocas de treinamento com K-Means	43
Número de épocas de treinamento com Gradiente Estocástico	7840
MSE de treino	0.00970639
MSE de validação	0.0419945
BIAS	1.08642

(b) Variância dos centros da RBF OFDM e sinapses dos neurônios de saída

Variância dos centros da RBF	Sinapses dos neurônios de saída
179.928	-39.2805
193.595	36.0767
188.349	22.6325
191.38	22.8529

Fonte: a autora.


O *eigenfilter bank* referente ao sinal OFDM 256, a etapa de filtragem e a RBF OFDM formam o módulo de classificação OFDM, conforme ilustrado na Figura 7.13. Este módulo é apto a realizar a detecção de sinais OFDM similares ao sinal (S_0) utilizado para sua determinação.

O procedimento de avaliação do módulo de classificação consiste em gerar uma nova amostra de sinal OFDM, com as mesmas características, e degradar esta amostra, aplicando ruído AWGN com diferentes SNRs, verificando assim a capacidade de detecção do classificador sob condições adversas. A saída da RBF OFDM é observada para cada situação e, para fins de contabilização de erros e acertos, adotou-se o limiar de 0,5 para avaliação da resposta da RBF. Idealmente, na presença de sinal, a saída da RBF deve resultar num valor próximo de 1, enquanto que na ausência de sinal (apenas ruído AWGN) a sua saída deve resultar num valor próximo de 0.

A Figura 8.1 apresenta o desempenho do módulo de classificação OFDM para o cenário proposto.

Figura 8.1 – Avaliação do módulo de classificação OFDM.

(a) Gráfico de avaliações, acertos e percentual de acertos do módulo de classificação OFDM.




Fonte: a autora.

É possível perceber que ocorre redução da quantidade de acertos a partir de valores de SNR inferiores à -5 dB. Foram realizadas 74 avaliações para cada cenário de SNR, sendo que o classificador obteve 100% de sucesso na classificação até SNR de -5 dB.

A Figura 8.1b apresenta a faixa de variação das respostas da RBF OFDM, onde é possível verificar que os valores de saída decaem conforme o sinal apresentado está mais severamente afetado por ruído.

Figura 8.1 – Avaliação do módulo de classificação OFDM.

(b) Faixa de excursão de valores de resposta da rede neural RBF do módulo de classificação OFDM




Fonte: a autora.

É importante salientar que esta RBF desconhece a maioria dos cenários de degradação de sinal, uma vez que ela foi treinada apenas com amostras do sinal sem qualquer degradação, com degradação de -5 dB e com ruído AWGN puro. Portanto, fica confirmada a capacidade de generalização da RBF OFDM para situações de degradação de sinal por ela desconhecidas.


Conforme discutido no Capítulo 4 o módulo de classificação OFDM foi também avaliado sob o aspecto das probabilidades de detecção (P_D) e probabilidades de falso alarme (P_{FA}), conforme ilustrado nas Figuras 8.1c e 8.1d.

Figura 8.1 – Avaliação do módulo de classificação OFDM.

(c) Probabilidade de detecção do módulo de classificação OFDM



(d) Probabilidade de falso alarme do módulo de classificação OFDM




Fonte: a autora.

A curva da ROC do módulo de classificação OFDM foi obtida para diferentes limiares de decisão (λ), conforme apresentado na Figura 8.1e.

Figura 8.1 – Avaliação do módulo de classificação OFDM.

(e) ROC do módulo de classificação OFDM




Fonte: a autora.

Para o limiar de decisão adotado no desenvolvimento deste trabalho, $\lambda=0.5$, destacado na Figura 8.1e, a probabilidade de detecção corresponde a $P_D=0.945$ enquanto que a probabilidade de falso alarme corresponde a $P_{FA}=0.055$.

A presença de ruído AWGN altera a forma de decaimento da curva dos autovalores significativos. Conforme o ruído aumenta, maior tornam-se os autovalores referentes ao subespaço de ruído. A Figura 8.2 ilustra esse comportamento.

Figura 8.2 – Curvas de decaimento dos autovalores para sinal OFDM 256.

(a) Autovalores para sinal OFDM 256 sem ruído



(b) Autovalores para sinal OFDM 256 com SNR de 10 dB





Figura 8.2 – Curvas de decaimento dos autovalores para sinal OFDM 256.

(c) Autovalores para sinal OFDM 256 com SNR de 5 dB.



Fonte: a autora.

Analisando a resposta do classificador proposto em comparação com os métodos de detecção propostos por Zeng e Liang (2007) conclui-se que os algoritmos EME e MME são capazes de avaliar a presença de UP sob SNRs da ordem de -20 dB. O classificador proposto apresentou 20% de acertos para uma SNR de -15 dB. A grande diferença entre os algoritmos EME e MME e o método aqui proposto reside no fato de que com o uso do classificador é possível saber que tipo de sinal está sendo transmitido no canal de comunicação. Nos métodos propostos por Zeng e Liang (2007) não há possibilidade de obter-se esse tipo de informação. Além disso, com a utilização do classificador, não há necessidade de cálculo da matriz de covariância (\mathbf{C}) e dos autovalores λ_m a cada sensoriamento do espectro, bastando um processo de filtragem e análise dos valores pela RBF para obter-se uma resposta sobre a presença de UP no canal analisado, conforme demonstrado na Seção 7.3.

Apesar do classificador não ter sido capaz de realizar a detecção sob SNR de -20 dB é importante salientar que a sua utilização pode reduzir significativamente o tempo necessário para o processo de detecção. Com os algoritmos EME e MME é


necessário o cálculo dos autovalores λ_m a cada ciclo de sensoriamento, operação esta que é computacionalmente dispendiosa, conforme apresentado na Seção 7.3. No caso da utilização do classificador proposto, uma vez formado o conjunto de módulos de classificação, o processo de detecção, descrito na Seção 7.3, é menos complexo e bastante rápido.

8.2 Cenário 2: Análise de Outros Sinais

No classificador proposto, cada novo sinal recebido (S) é apresentado ao conjunto de módulos de classificação. A maior correlação, ou similaridade, deve ocorrer quando um módulo receber um sinal (S) similar àquele (S_0) para o qual foi configurado e treinado. Entretanto, além de avaliar a capacidade de um módulo de classificação reconhecer o sinal para o qual foi projetado, é importante avaliar a resposta deste módulo quando submetidos sinais distintos daquele que é o seu ideal de detecção. Um módulo de classificação que foi determinado para sinal OFDM não deve indicar valor de saída próximo de 1 no caso de analisar um sinal de TV digital, por exemplo. Portanto, a cada módulo de classificação foram submetidos sinais para os quais estes não foram determinados e as respostas obtidas avaliadas. A Figura 8.3 mostra a resposta do módulo de classificação OFDM quando este analisa outros sinais.

Figura 8.3 – Análise do módulo de classificação OFDM quando analisando sinais distintos do OFDM 256.

(a) Respostas do módulo de classificação OFDM quando analisando sinais distintos do OFDM 256




Fonte: a autora.

Através da Figura 8.3a é possível verificar que o módulo determinado para reconhecimento de sinais OFDM não indicou presença de usuário primário (UP) quando foram submetidos outros tipos de sinal à sua análise. Este comportamento demonstra a especificidade do módulo, uma vez que ele é capaz de generalizar sinais OFDM com diferentes níveis de degradação, mas sem perder a capacidade de classificação. Desta forma, o classificador garante que o módulo de classificação do sinal OFDM indicará presença de sinal OFDM apenas quando esta condição for verdadeira.

Figura 8.3 – Análise do módulo de classificação OFDM quando analisando sinais distintos do OFDM 256.

(b) Faixa de excursão de valores de resposta da rede neural RBF OFDM



Fonte: a autora.

Também é possível verificar que o módulo de classificação indicou um erro de detecção durante as avaliações do ruído AWGN. O classificador entendeu que uma das amostras de ruído AWGN a ele submetida possuía similaridade com um cenário correspondente à sinal OFDM. Em termos práticos, este erro está associado à probabilidade de falso alarme (P_{FA}), descrita na Seção 4.1, pois o classificador indicou a presença de um UP quando na verdade ele não estava presente. Este tipo de erro não provoca danos aos UPs, uma vez que não ocorre a alocação do espectro. A oportunidade de alocação é desperdiçada, mas os UPs estão protegidos nesta condição.

Outro fator importante a destacar quanto a este erro é que o classificador proposto permite a realização de múltiplas avaliações num único período de sensoriamento. Como não há necessidade de cálculo da matriz de covariância (\mathbf{C}) ou dos autovalores λ_m , todas as amostras de sinal recebido podem ser submetidas para a análise da RBF, resultando em várias avaliações. A decisão final sobre a presença do UP pode ser tomada com base na análise de múltiplas avaliações.

8.3 Cenário 3: Multipercurso

Conforme abordado na Seção 2.3, o multipercurso é um problema ao qual os sistemas de comunicação sem fio estão sujeitos devido aos inevitáveis pontos de reflexão da onda eletromagnética ao longo de sua propagação através do espaço que interliga transmissor e receptor. Em termos práticos, o sinal que é recebido numa estação rádio-base (ERB) cognitiva é acompanhado de múltiplas réplicas atenuadas e atrasadas no tempo devido ao cenário de reflexões. Os efeitos deste fenômeno são, portanto, inevitáveis em comunicação sem fio.

O tipo específico de multipercurso ao qual um sinal estará submetido depende de diversos fatores, mas existem modelos de canais conhecidos que podem ser utilizados para simular os efeitos do canal de propagação. Neste trabalho foram adotados os cenários de multipercurso conhecidos como *Brasil A* e *Brasil D*. O *delay profile* destes canais foi utilizado na configuração de canal de transmissão, inserindo assim os efeitos destes cenários de multipercurso no sinal (SPIB, 2006). Para cada um dos modelos *Brasil A* e *Brasil D*, disponibilizados no Anexo A1, foi determinado um novo módulo de classificação, conforme processo descrito na Seção 7.2.1.1, que contempla as características dos canais. A Figura 8.4 apresenta os autovalores obtidos para cada um destes modelos.

Figura 8.4 – Autovalores para sinal OFDM com cenários de multipercurso.

(a) Autovalores para sinal OFDM com multipercurso Brasil A





Figura 8.4 – Autovalores para sinal OFDM com cenários de multipercurso.

(b) Autovalores para sinal OFDM com multipercurso Brasil D



Fonte: a autora.

Analisando a Figura 8.4 percebe-se que o multipercurso possui efeito sobre o decaimento da curva dos autovalores, que é bastante diferente da Figura 8.2a, que aborda um cenário sem a presença de multipercurso. Da mesma forma, a delimitação entre o subespaço de sinal e o de ruído, que pode ser claramente visualizada na Figura 8.2a, agora não é tão evidente.

Embora o cenário de ruído AWGN seja válido para análise é importante que os efeitos do multipercurso sejam considerados, pois um sistema real estará invariavelmente submetido a este fenômeno. Em Zeng e Liang (2007) e em outros trabalhos similares, onde os algoritmos MME e EME são utilizados, apenas a abordagem de ruído AWGN é considerada (ZHIWEN; HANG; SHAOFAN; DESHENG, 2010), (SHIBING; JIAOJIAO; LILI, 2012) e (DIKMESE; WONG; GOKCEOGLU; GUZZON; VALKAMA; RENFORS, 2013).

Os melhores resultados de detecção de UP sob condição de multipercurso *Brasil A* foram obtidos com a RBFS_OFDM_BA_216_5, doravante denominada RBF OFDM BA. O resumo da sua configuração é apresentado na Tabela 8.2.

Tabela 8.2 – (a) Informações gerais da RBF OFDM BA e (b) Variância dos centros da RBF OFDM BA e sinapses dos neurônios de saída.

(a) Informações gerais da RBF OFDM BA

Número de neurônios da camada oculta	8
Número de nós de entrada	216
Número de épocas de treinamento com K-Means	14
Número de épocas de treinamento com Gradiente Estocástico	2653
MSE de treino	0.0022301
MSE de validação	0.00814137
BIAS	-1.27856

(b) Variância dos centros da RBF OFDM BA e sinapses dos neurônios de saída


Variância dos centros da RBF	Sinapses dos neurônios de saída
149.771	-0.606164
146.821	-41.606
147.443	-48.3602
148.997	-61.025
147.087	-45.0321
147.347	-47.5078
149.76	-13.2992
145.986	-24.2573

Fonte: a autora.

A Figura 8.5 apresenta o resultado do módulo de classificação OFDM Brasil A determinado para avaliação do cenário de multipercurso *Brasil A*.

Figura 8.5 – Avaliação do módulo de classificação OFDM Brasil A.

(a) Gráfico de avaliações, acertos e percentual de acertos do módulo de classificação OFDM Brasil A




Fonte: a autora.

Analisando a Figura 8.5a é possível verificar que o módulo determinado foi capaz de realizar a detecção em cenário de multipercurso Brasil A com 100% de acerto para SNR de até -8 dB. Observa-se também que a capacidade de detecção apresentou queda brusca após este valor de SNR, resultando em baixa capacidade de detecção para cenários com SNR menores do que -10 dB.

Figura 8.5 – Avaliação do módulo de classificação OFDM Brasil A.

(b) Faixa de excursão de valores de resposta da rede neural do módulo de classificação OFDM Brasil A.



Fonte: a autora.

Através da análise da Figura 8.5b verifica-se que para SNRs inferiores à - 8dB a faixa de resposta da rede neural RBF do módulo de classificação OFDM Brasil A é inferior ao limiar estabelecido para detecção ($\lambda=0,5$).

De forma similar, outro módulo de classificação foi determinado para classificação de sinais com o cenário de multipercurso *Brasil D*. A Tabela 8.3 apresenta detalhes da melhor RBF encontrada para detecção neste cenário, doravante denominada RBF OFDM BD.

Tabela 8.3 – (a) Informações gerais da RBF OFDM BD e (b) Variância dos centros da RBF OFDM BD e sinapses dos neurônios de saída.

(a) Informações gerais da RBF OFDM BD

Número de neurônios da camada oculta	9
Número de nós de entrada	216
Número de épocas de treinamento com K-Means	11
Número de épocas de treinamento com Gradiente Estocástico	2774
MSE de treino	0.000262984
MSE de validação	0.000986396
BIAS	-1.07716

Tabela 8.3 – (a) Informações gerais da RBF OFDM BD e (b) Variância dos centros da RBF OFDM BD e sinapses dos neurônios de saída.

(b) Variância dos centros da RBF OFDM BD e sinapses dos neurônios de saída


Variância dos centros da RBF	Sinapses dos neurônios de saída
133.019	-27.3253
133.093	-27.6623
137.423	-6.97728
133.135	-27.8131
133.177	-27.9455
132.95	-26.4326
132.99	-27.0484
133.639	-0.693679
133.23	-35.242

Fonte: a autora.

A Figura 8.6 apresenta o resultado do módulo de classificação OFDM Brasil D determinado para avaliação do cenário de multipercurso *Brasil D*.

Figura 8.6 – Avaliação do módulo de classificação OFDM Brasil D.

(a) Gráfico de avaliações, acertos e percentual de acertos do módulo de classificação OFDM Brasil D




Fonte: a autora.

Através da análise da Figura 8.6a é possível verificar que o módulo determinado foi capaz de realizar a detecção em cenário de multipercorso Brasil D com 100% de acerto para SNR de até -10 dB. Para a SNR de -11 dB o módulo obteve 44% de acertos. A capacidade de detecção apresentou queda para SNRs inferiores à -11 dB, resultando na incapacidade de detecção para SNRs inferiores a este limiar.

Figura 8.6 – Avaliação do módulo de classificação OFDM Brasil D.

(b) Faixa de excursão de valores de resposta da RBF OFDM BD



Fonte: a autora.

Através da análise da Figura 8.6b verifica-se que para SNRs inferiores à -11dB a faixa de resposta da rede neural RBF do módulo de classificação OFDM Brasil D é inferior ao limiar estabelecido para detecção ($\lambda=0,5$).

De forma geral, o módulo de classificação OFDM *Brasil D* teve desempenho levemente superior ao módulo de classificação OFDM *Brasil A*, pois conseguiu realizar detecções para SNRs mais baixas.

A resposta do classificador proposto aos cenários de multipercorso indica que a abordagem adotada é adequada para sensoriamento do espectro. Através da monitoração do espectro durante a determinação dos módulos de classificação, diversos cenários de multipercorso, referentes a região de cobertura da WRAN, podem ser mapeados. Dessa forma, o classificador permite que a ERB obtenha a

informação do cenário de multipercurso ao qual o usuário primário (UP) está sujeito. Os métodos similares indicados neste trabalho executam tão somente a avaliação da presença do UP em cenário de ruído AWGN, sem qualquer informação adicional sobre as condições deste (ZENG; LIANG, 2007), (ZHIWEN; HANG; SHAOFAN; DESHENG, 2010), (SHIBING; JIAOJIAO; LILI, 2012) e (DIKMESE; WONG; GOKCEOGLU; GUZZON; VALKAMA; RENFORS, 2013).

8.4 Cenário 4: Ruído Impulsivo

Outro cenário importante a ser considerado num processo de sensoriamento do espectro é a ocorrência de ruído impulsivo. Conforme Seção 2.6, o ruído impulsivo é capaz de causar falhas de comunicação e afetar severamente os sistemas de comunicação sem fio.


Para análise dos efeitos do ruído impulsivo sobre o sinal, adotou-se o cenário de multipercurso *Brasil A* ao qual ainda foi adicionado ruído impulsivo. Nenhum *eigenfilter bank* ou rede RBF foi determinado para tratar este tipo de cenário, uma vez que não se pode prever com exatidão a sua ocorrência. A heurística adotada para os testes foi a utilização do módulo de classificação previamente determinado para o cenário *Brasil A*, avaliando sua resposta quando o sinal a ele submetido foi corrompido com diversos níveis de ruído impulsivo. O algoritmo utilizado para geração do ruído impulsivo está disponível no Apêndice G.

Foi adotada uma sequência de mil amostras complexas para cada pulso de ruído impulsivo. Quando a amostra disponível de sinal foi corrompida por apenas um pulso de ruído, escolheu-se um número randômico dentro do intervalo da amostra e, a partir desta posição, mil amostras complexas do sinal foram substituídas por um pulso de ruído. No caso de corromper o sinal com três pulsos de ruído, foram escolhidas, de forma randômica, três posições do sinal a partir das quais mil amostras complexas de sinal foram substituídas por ruído impulsivo. O processo foi executado da mesma forma para qualquer número de pulsos que se desejava inserir. A amplitude do ruído impulsivo foi limitada em um valor 6 dB acima do sinal. Esta medida está em conformidade com o modo de operação dos AGCs, abordados na Seção 2.2, pois estes, entre outras funções, limitam os valores de sinal a serem repassados as etapas seguintes de demodulação, a fim de evitar a saturação dos


conversores A/D existentes nos receptores. A título de ilustração a Figura 8.7 mostra amostras de sinal corrompidas por diferentes quantidades de pulsos de ruído impulsivo.

Figura 8.7 – (a) Módulo do sinal OFDM com multipercurso Brasil A e 3 impulsos de ruído e (b) Módulo do sinal OFDM com multipercurso Brasil A e 5 impulsos de ruído.

(a) Módulo do sinal OFDM com multipercurso Brasil A e 3 impulsos de ruído



(b) Módulo do sinal OFDM com multipercurso Brasil A e 5 impulsos de ruído




Fonte: a autora.

Através de simulações, observou-se que o módulo de classificação OFDM *Brasil A* não apresentou erros de detecção quando submetido à sinais corrompidos por até 30 pulsos de ruído. Desta forma, foi alterada a largura do pulso de ruído, de mil para dez mil amostras complexas. No novo cenário, com ruído presente por um

intervalo de tempo muito maior, foi possível observar a degradação da capacidade de classificação do sistema. A Figura 8.8 mostra a ocorrência de erros de detecção para este cenário.

Figura 8.8 – Avaliação do módulo de classificação OFDM Brasil A sob cenário de ruído impulsivo



Fonte: a autora.

A Figura 8.8 mostra a resposta do classificador proposto apresentada quando analisando sinais corrompidos por ruído impulsivo. Erros de detecção ocorreram apenas mediante alargamento excessivo do pulso de ruído. Em situações práticas, a duração do ruído impulsivo costuma ser pequena quando comparada com o tempo de sensoriamento do espectro, mas o classificador proposto mostra-se apto a realizar a detecção mesmo que o sinal recebido para análise esteja bastante comprometido por este fenômeno.

Também é importante salientar que a decisão final sobre a ocupação do espectro pode ser tomada com base em múltiplas avaliações e não apenas em uma única avaliação. No classificador proposto, como não é necessário cálculo da matriz de covariância do sinal (\mathbf{C}) ou dos seus autovalores λ_m durante as detecções cíclicas, o período de sensoriamento pode ser utilizado de forma quase que integral para sensoriamento do espectro, provendo assim amostras maiores de sinal para avaliação.

8.5 Cenário 5: Sinal de Microfone Sem Fio

Para a classificação de sinais de microfone sem fio foi adotada a abordagem descrita na Seção 7.2.2, que resultou na determinação de três *eigenfilter banks* e uma única rede neural RBF. Cada um dos *eigenfilter banks* foi determinado conforme um dos modos de operação do microfone: *Loud Speaker*, *Soft Speaker* ou *Silent*. Uma única rede neural RBF foi determinada com a finalidade de detectar a presença de um UP correspondente a um microfone. O procedimento de validação do módulo de classificação de sinais de microfone foi realizado variando-se a SNR do sinal, de forma a degradá-lo e verificar assim a capacidade do módulo de ainda detectá-lo. As Figuras 8.9, 8.10 e 8.11 apresentam os resultados desta análise, agrupados por *eigenfilter bank*, enquanto que a Tabela 8.4 apresenta detalhes da rede neural RBF adotada, doravante denominada RBF WMIC.

Tabela 8.4 – (a) Informações gerais da RBF WMIC e (b) Variância dos centros da RBF WMIC e sinapses dos neurônios de saída.

(a) Informações gerais da RBF WMIC

Número de neurônios da camada oculta	4
Número de nós de entrada	7
Número de épocas de treinamento com K-Means	121
Número de épocas de treinamento com Gradiente Estocástico	72868
MSE de treino	0.00230999
MSE de validação	0.0177376
BIAS	-2.88614

(b) Variância dos centros da RBF WMIC e sinapses dos neurônios de saída


Variância dos centros da RBF	Sinapses dos neurônios de saída
78.468	-7.21047
85.5999	-37.1237
50.0187	-5.59362
2.72705	-1.6179

Fonte: a autora.

A Figura 8.9 apresenta a avaliação do módulo de classificação WMIC *Eigenfilter Bank Loud*.

Figura 8.9 – Avaliação do módulo de classificação WMIC Eigenfilter Bank Loud.

(a) Avaliações, acertos e percentual de acertos do módulo de classificação WMIC Loud




Fonte: a autora.

Pode-se verificar através da análise da Figura 8.9a que o módulo WMIC *Eigenfilter Bank Loud* realizou 100% de detecções corretas para sinais com SNR de até -10 dB.

Figura 8.9 – Avaliação do módulo de classificação WMIC Eigenfilter Bank Loud.

(b) Faixa de excursão de valores de resposta da rede neural RBF WMIC




Fonte: a autora.

Através da análise da Figura 8.9b verifica-se que apenas para SNRs próximas de -20dB a faixa de resposta da rede neural RBF é inferior ao limiar estabelecido para detecção ($\lambda=0,5$).

Figura 8.9 – Avaliação do módulo de classificação WMIC Eigenfilter Bank Loud.

(c) Resposta do módulo WMIC para outros sinais.




Fonte: a autora.

Através da Figura 8.9c é possível verificar que o módulo de classificação WMIC Eigenfilter Bank Loud não indicou presença de usuário primário (PU) quando foram submetidos outros tipos de sinal à sua análise. Este comportamento demonstra a especificidade do módulo.

A Figura 8.10 apresenta a avaliação do módulo de classificação WMIC *Eigenfilter Bank Soft*.

Figura 8.10 – Avaliação do módulo de classificação WMIC *Eigenfilter Bank Soft*.

(a) Gráfico de avaliações, acertos e percentual de acertos do módulo WMIC *Eigenfilter Bank Soft*




Fonte: a autora.

O módulo de classificação WMIC *Eigenfilter Bank Soft* apresentou melhores resultados de detecção que o módulo WMIC *Eigenfilter Bank Loud*, obtendo 100% de sucesso na classificação para sinais com SNR de -15 dB e ainda atingindo 26% de acertos para SNR de -20 dB.

Figura 8.10 – Avaliação do módulo de classificação WMIC *Eigenfilter Bank Soft*.

(b) Faixa de excursão de valores de resposta da RBF WMIC




Fonte: a autora.

Através da análise da Figura 8.10b verifica-se que mesmo para uma SNR de -20dB a rede neural RBF WMIC ainda foi capaz de detectar a presença de usuário primário, apresentando respostas superiores ao limiar estabelecido para detecção ($\lambda=0,5$).

Figura 8.10 – Avaliação do módulo de classificação WMIC *Eigenfilter Bank Soft*.

(c) Resposta do módulo WMIC para outros sinais




Fonte: a autora.

Através da Figura 8.10c é possível verificar que o módulo de classificação WMIC *Eigenfilter Bank Soft* não indicou presença de usuário primário (UP) quando foram submetidos outros tipos de sinal à sua análise, ficando assim comprovada a especificidade do módulo.

A Figura 8.11 apresenta a avaliação do módulo de classificação WMIC *Eigenfilter Bank Silent*.

Figura 8.11 – Avaliação do módulo de classificação WMIC *Eigenfilter Bank Silent*.

(a) Gráfico de avaliações, acertos e percentual de acertos do módulo WMIC *Eigenfilter Bank Silent*




Fonte: a autora.

O módulo de classificação WMIC *Eigenfilter Bank Silent* apresentou resultados de detecção similares ao módulo de classificação *Eigenfilter Bank Soft*, obtendo também 100% de sucesso na classificação para sinais com SNR de -15 dB e atingindo 14% de acertos para SNR de -20 dB.

Figura 8.11 – Avaliação do módulo de classificação WMIC *Eigenfilter Bank Silent*.

(b) Faixa de excursão de valores de resposta da RBF WMIC.




Fonte: a autora.

Através da análise da Figura 8.11b verifica-se que mesmo para uma SNR de -20dB a rede neural RBF WMIC ainda foi capaz de detectar a presença de usuário primário, apresentando respostas superiores ao limiar estabelecido para detecção ($\lambda=0,5$).

Figura 8.11 – Avaliação do módulo de classificação WMIC *Eigenfilter Bank Silent*.

(c) Resposta do módulo WMIC para outros sinais



Fonte: a autora.

Através da Figura 8.11c é possível verificar que o módulo de classificação WMIC *Eigenfilter Bank Silent* não indicou presença de usuário primário (UP) quando foram submetidos outros tipos de sinal à sua análise, ficando assim comprovada a especificidade do módulo.

8.6 Cenário 6: Sinal de TV Digital

De forma análoga aos cenários anteriores, aqui avaliou-se a resposta do módulo de classificação DVB-T determinado para classificação de sinais DVB-T. As características da rede neural RBF adotada para este cenários, RBF DVB-T, são apresentadas na Tabela 8.5.

Tabela 8.5 – (a) Informações gerais da RBF DVB-T e (b) Variância dos centros da RBF DVB-T e sinapses dos neurônios de saída.

(a) Informações gerais da RBF DVB-T

Número de neurônios da camada oculta	5
Número de nós de entrada	81
Número de épocas de treinamento com K-Means	22
Número de épocas de treinamento com Gradiente Estocástico	91295
MSE de treino	4.04E-05
MSE de validação	0.00879523
BIAS	3.78795

(b) Variância dos centros da RBF DVB-T e sinapses dos neurônios de saída


Variância dos centros da RBF	Sinapses dos neurônios de saída
114.391	19.561
108.326	26.0546
124.467	13.4721
7.7058	25.8061
118.673	11.323

Fonte: a autora.

A Figura 8.12 apresenta a avaliação do módulo de classificação DVB-T.

Figura 8.12 – Avaliação do módulo de classificação DVB-T.

(a) Gráfico de avaliações, acertos e percentual de acertos do módulo de classificação DVB-T




Fonte: a autora.

Observou-se que o módulo de classificação DVB-T foi capaz de realizar a classificação dos sinais DVB-T com 100% de detecções corretas para SNR de até -2 dB. Entretanto, este módulo não foi capaz de realizar detecções corretas para SNRs inferiores à -5 dB, valor para o qual atingiu apenas 4% de detecções corretas.

Figura 8.12 – Avaliação do módulo de classificação DVB-T.

(b) Faixa de excursão de valores de resposta da RBF DVB-T.




Fonte: a autora.

Através da análise da Figura 8.12b verifica-se que para SNRs de até -5dB a rede neural RBF DVB-T ainda foi capaz de detectar a presença de usuário primário em algumas avaliações, apresentando respostas superiores ao limiar estabelecido para detecção ($\lambda=0,5$).

A Figura 8.13 apresenta os resultados de detecção do módulo de classificação DVB-T quando a ele submetidos sinais não correspondentes à TV digital.

Figura 8.13 – Avaliação do módulo de classificação DVB-T quando analisando sinais distintos do DVB-T.

(a) Respostas do módulo de classificação DVBT-T quando analisando sinais distintos do DVB-T




Fonte: a autora.

Apesar do módulo de classificação DVB-T não ter apresentado desempenho excelente nos casos de SNR inferior à -5 dB, a sua capacidade de generalização é boa, pois realizou detecções corretas nos casos de sinais distintos do padrão DVB-T.

Figura 8.13 – Avaliação do módulo de classificação DVB-T quando analisando sinais distintos do DVB-T.

(b) Faixa de excursão de valores de resposta da RBF DVB-T



Fonte: a autora.

Através da Figura 8.13b é possível verificar que o módulo de classificação DVB-T não indicou presença de usuário primário (UP) quando foram submetidos outros tipos de sinal à sua análise, ficando assim comprovada a especificidade do módulo.

8.7 Avaliação dos Resultados Obtidos

A Tabela 8.6 apresenta um compilado geral dos módulos de classificação e sinais avaliados.

Tabela 8.6 – Avaliação dos resultados obtidos

SNR	SINAIS						
	OFDM	OFDM_BA	OFDM_BD	WMIC Loud	WMIC Soft	WMIC Silent	DVB-T
SNR com 100% de acertos (dB)	-5	-8	-10	-10	-15	-15	-2
SNR com mínimo de acertos (dB)	-17	-10	-11	-15	-20	-20	-5

Fonte: a autora.

Mesmo utilizando-se técnicas individuais de sensoriamento de espectro e nenhum recurso de diversidade, os módulos de classificação foram capazes de realizar a detecção da presença dos usuários primários, mesmo sob condições severas de degradação. O módulo de classificação OFDM foi capaz de realizar detecções com 100% de acertos para SNRs de até -5 dB, ainda realizando detecções corretas para SNRs de até -17 dB.

Os módulos de classificação referentes aos sinais de microfones sem-fio realizaram 100% de detecções corretas para SNRs de até -15 dB e ainda obtiveram percentuais de detecção superiores à 15% para SNRs de -20 dB.

O módulo de classificação DVB-T apresentou capacidade de detecção reduzida quando comparado aos demais módulos de classificação, entretanto, salienta-se que um receptor de TV digital dificilmente opera de forma satisfatória quando submetido à SNRs da ordem de -5 ou -10 dB. Além disso, o classificador aqui proposto não conta com recursos de diversidade, o que pode melhorar de forma significativa sua capacidade de detecção.

O classificador proposto apresentou robustez em cenários de ruído impulsivo e capacidade de detecção mesmo sob condições de multipercurso. Os resultados obtidos demonstram também que foi possível determinar o tipo de usuário primário que utiliza o canal de comunicação e verificou-se que os módulos de classificação apresentam respostas específicas para detecção correta dos sinais para os quais foram determinados.

De forma geral, os resultados obtidos indicam que a abordagem proposta é viável no cenário de rádio cognitivo, representando uma alternativa para detecção da presença de usuários primários.

9 Conclusão

Em 1798 Thomas Malthus publicou o livro “Ensaio sobre o Princípio Populacional” onde apresentou uma análise sobre os perigos do crescimento populacional. Segundo Malthus, o crescimento da população é limitado pelos meios de subsistência e o descontrole populacional levaria a uma catástrofe mundial. O crescimento incessante da população acarreta em maior demanda por tudo: alimentos, água, materiais e demais recursos naturais. Por esta razão, governos e empresas buscam desenvolver formas sustentáveis de atender a todas as demandas.

No âmbito da comunicação móvel, a possibilidade de escassez do espectro de rádio é um problema sério que tem mobilizado diversas iniciativas, buscando atingir a máxima eficiência na sua utilização e evitar um possível colapso. A maioria dos países e agências regulatórias adota a política de divisão do espectro em bandas e realiza o licenciamento destas. Portanto, para adicionar capacidade aos sistemas existentes são necessárias novas bandas ou novas tecnologias que permitam maiores taxas de transmissão. O uso de bandas de frequência em faixas mais altas, tais como 60 GHz, tem sido objeto de alguns estudos, mas as propriedades físicas desta faixa para transmissão de dados não são ideais (HIGGINBOTHAM, 2009). Novas tecnologias emergem com mais frequência, mas a possibilidade de encontrar uma solução milagrosa para multiplicação da capacidade é bastante remota.

Nos últimos anos ocorreram vários avanços no campo dos rádios cognitivos com relação a capacidade de percepção do espectro. Também ocorreram avanços nas técnicas de transmissão de dados, que são capazes de garantir comunicação mesmo em ambientes com variabilidade de condições dos canais de transmissão. Desta forma, o conceito inicialmente proposto por Mitola III (2000) pode tornar-se uma realidade, permitindo a utilização do espectro de rádio de forma mais eficiente, através do desenvolvimento efetivo dos sistemas baseados em rádio cognitivo (RC).

Mesmo ainda havendo necessidade de evolução, sistemas baseados nos conceitos de RC estão sendo testados, utilizando as oportunidades das bandas de

TV. Uma parceria entre Microsoft e a Universidade de Limpopo, na África do Sul, deu origem a um projeto piloto, utilizando os espaços brancos da banda de TV para fornecer acesso à internet em escolas da zona rural (VAN DER BERG, 2014). Utilizando energia solar, as estações rádio-base (ERBs) cognitivas provêm velocidades de conexão entre 4 e 6 Mbit/s, através do uso dos espaços brancos. Um projeto similar, encabeçado pela Google, foi conduzido na África do Sul (TENET, 2013) e outros estão em andamento em países como Gana, Tanzânia e Quênia.

A solução proposta neste trabalho apresenta as seguintes vantagens:

- Redução da complexidade computacional da operação de sensoriamento de espectro;
- Obter informação sobre o tipo de UP para efeito de gerenciamento de interferências na RRC;
- Capacidade de detecção de UP mesmo sob multipercurso e ruído impulsivo;
- Aplicável a outros tipos de sinal de UP;
- Possibilita otimização dos períodos de silêncio.

A detecção de oportunidades no espectro é crítica para o desenvolvimento das tecnologias de RC. As técnicas cegas de sensoriamento do espectro que utilizam decomposição em subespaços demandam um custo computacional elevado e não mantêm histórico, ou seja, existe o esforço computacional de monitorar o espectro, calcular os autovalores, decidir sobre a presença do usuário primário (UP) e descartar essa informação. Esse ciclo é executado constantemente, o que exige um compromisso com o período de sensoriamento. Com a solução proposta neste trabalho, além de verificar a presença de um usuário primário através de comparação, não há necessidade de cálculo cíclico de matrizes de covariância e autovalores, o que reduz a complexidade do processo.

O classificador proposto também permite a obtenção de informação estatística sobre a utilização do espectro, uma vez que possibilita a identificação do tipo de usuário primário. Para efeitos de gerenciamento de interferências numa RRC este tipo de informação é crucial.

O desempenho do classificador proposto foi bastante satisfatório quando submetido a cenários de multipercurso e ruído impulsivo, o que demonstra sua capacidade de adaptação à ambientes reais. A classificação de sinais mostrou-se capaz de realizar a detecção de usuários primários, mesmo em cenários com SNR baixa, provando assim que o conceito apresentado é viável e pode ser facilmente expandido para análise de outros tipos de sinais.

Também é possível conceber a ideia de que os módulos de classificação podem ser atualizados periodicamente, tornando assim a ERB capaz de detectar alterações no seu ambiente (inserção de novos tipos de UPs ou novas condições de multipercurso, por exemplo). Na prática temos apenas um dado número de sistemas em operação comercial, o que implica num número finito e não muito grande de módulos de classificação. Além disso, considerando a resolução IEEE 802.22 (2011) como guia, é bastante provável que uma ERB pertencente à RRC possa operar apenas em uma determinada faixa do espectro e não em toda sua extensão.

Monitorar o espectro por muito tempo aumenta a precisão da detecção, mas reduz o tempo útil para transmissão de dados, ao passo que monitorá-lo por pouco tempo pode não ser suficiente para encontrar correlação do sinal, gerando assim erros de detecção. A utilização do classificador proposto permite que o período de silêncio seja utilizado para efetiva monitoração do espectro, pois não há necessidade de utilização deste período para cálculo de autovalores ou determinação de matrizes de covariância, uma vez que o processo de detecção consiste de filtragem do sinal monitorado e análise deste por redes neurais.

A utilização de redes neurais RBFs para o reconhecimento de padrões e classificação dos sinais mostrou-se adequada para solução do problema abordado, além de adicionar flexibilidade ao sistema.

Em termos de desenvolvimento futuro, o método de detecção proposto pode beneficiar-se de um sensoriamento cooperativo, onde os *eigenfilter banks* previamente obtidos pela ERB seriam repassados aos terminais de usuário (CPEs). Desta forma, os CPEs poderiam realizar análises locais e enviar informações mais detalhadas à ERB, melhorando assim a sua capacidade de classificação. Esta seria uma forma de continuidade do sistema aqui proposto.

Outras estratégias de decisão sobre a presença de um usuário primário podem ser implementadas, como por exemplo, decisão conjunta baseada na avaliação da saída de cada módulo de classificação e do detector de energia ou ainda um decisor Fuzzy.

A utilização de recursos de diversidade pode também contribuir de forma significativa para a detecção dos UPs, além de permitir uma comparação direta entre os resultados do classificador proposto com outros métodos de detecção. A comparação dos resultados obtidos para o classificador proposto com os algoritmos EME e MME, por exemplo, pode ser realizada desde que sejam agregados ao classificador os mesmos recursos utilizados na avaliação destes algoritmos, de forma que a comparação dos resultados possa ser realizada sob uma condição de igualdade de critérios.

As perspectivas futuras para RC são boas, mas é claro que serão necessárias pesquisas de longo prazo para identificação de bandas com baixa utilização, assim como será importante o desenvolvimento de tecnologias de compartilhamento e gerenciamento de espectro e novas políticas regulatórias do seu uso. Novas tecnologias nas áreas de detecção e alocação de espectro, antenas inteligentes, alocação de canais e técnicas de modulação também são fundamentais para que a RC torne-se uma realidade mundialmente difundida. Numa área onde a pesquisa de soluções está em franca expansão, o classificador aqui proposto apresenta-se como uma alternativa viável para a solução de um dos problemas críticos da CR, que é a detecção da presença de um usuário primário.

Referências

AKYILDIZ, I. F., LO, I. F., BALAKRISHNAN, B. F. **Cooperative spectrum sensing in cognitive radio networks: A survey**. 2010. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S187449071000039X>>. Acesso em: 30 mar. 2014.

ASSOCIATION OF RADIO INDUSTRIES BUSINESSES. **ARIB-STD-B31: Transmission System for Digital Terrestrial Television Broadcasting version 1.6**. 2005. Disponível em: <<http://www.arib.or.jp/english/index.html>> Acesso em: 04 ago. 2014.

BERLEMANN, L., MANGOLD, S. **Cognitive Radio and Dynamic Spectrum Access**. Reino Unido: Wiley, 2009.

BISHOP, C. **Neural Networks for Pattern Recognition**. Reino Unido: Clarendon Press Oxford, 1995.

CALABRESE, M., SNIDER. **Up in the Air**. The Atlantic Monthly, New America Foundation. 2003.

CHEN, K., PRASAD, R. **Cognitive Radio Networks**. Reino Unido: John Wiley & Sons Inc, 2009.

CLANTON, C., KENKEL, M., TANG Y. **IEEE 802.22-07/0124r0: Wireless Microphone Signal Simulation Method**. 2007. Disponível em: <<https://mentor.ieee.org/802.22/dcn/07/22-07-0124-00-0000-wireless-microphone-signal-simulation.doc>>. Acesso em: 20 ago. 2014.

CORDEIRO, C., CHALLAPALI, K., BIRRU, D., SHANKAR, S. **IEEE 802.22: An Introduction to the First Wireless Standard based on Cognitive Radios**. First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks. 2005. Disponível em: <<http://www.cs.uc.edu/~cordeicm/papers/jcm06.pdf>>. Acesso em: 09 set. 2014.

COMMUNICATIONS RESEARCH CENTRE CANADA. **Results of the Laboratory Evaluation of an 8 MHz ADTB-T Television System for Terrestrial Broadcasting for HDTV TEEG China, Final Report.** 2003. Disponível em: <http://www.rthk.org.hk/about/digitalbroadcasting/DSBS/TEEG_REPORT_ADTB_T_3.pdf>. Acesso em: 03 ago. 2014

DE CASTRO, M., DE CASTRO, F. **Radial Basis Function Neural Net Training/Validation program, V1.0.d.** Disponível em: <http://www.feng.pucrs.br/~decastro/C/RBFTrainer_V1.0.d.zip>. Acesso em: 12 ago. 2014.

DE CASTRO, M. **Predição Não-Linear de Séries Temporais Usando Redes Neurais RBF por Decomposição em Componentes Principais.** Tese de Doutorado em Engenharia Elétrica. Universidade Estadual de Campinas. 2001.

DIKMESE, S., WONG, J. L., GOKCEOGLU, A., GUZZON, E., VALKAMA, M., RENFORS, M. **Reducing Computational Complexity of Eigenvalue Based Spectrum Sensing for Cognitive Radio.** 2013. 8th International Conference on Cognitive Radio Oriented Wireless Networks (CROWNCOM). Disponível em: <<http://dx.doi.org/10.1109/CROWNCom.2013.6636795>>. Acesso em: 30 mar. 2014.

DIGITAL VIDEO BROADCASTING PROJECT. **DVB.org.** Disponível em: <https://www.dvb.org/resources/public/images/site/dvb-t_map.pdf>. Acesso em: 04 ago. 2014.

EUROPEAN TELECOMMUNICATIONS STANDARDS INSTITUTE. **ETSI EN 300 744 : Digital Video Broadcasting (DVB); Framing structure, channel coding and modulation for digital terrestrial television V1.6.1.** 2009. Disponível em: <http://www.etsi.org/deliver/etsi_en/300700_300799/300744/01.06.01_60/en_300744_v010601p.pdf>. Acesso em: 04 ago. 2014.

FEHSKE, A., GAEDDERT, J., REED, J. **A new approach to signal classification using spectral correlation and neural networks.** First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks (DySPAN '05). 2005. p. 144–150

FETTE, B. **Cognitive Radio Technology.** Burlington: Elsevier, 2006.

GHAVAMI, M., MICHAEL, L.B., KOHNO, R. **Ultra Wideband Signals and Systems in Communication Engineering**. Reino Unido: John Wiley & Sons Ltd, 2007.

GODARA, L. C. **Handbook of Antennas in Wireless Communications**. Boca Raton: CRC Press, 2001.

HAYKIN, S. **Cognitive radio: Brain-empowered wireless communications**. IEEE Journal on Selected Areas in Communications, vol. 23. 2005. p. 201–220.

HAYKIN, S. **Neural Networks, A Comprehensive Foundation**. Nova Jersey: Prentice Hall International, 1999.

HAYKIN, S. **Adaptive Filter Theory**. Nova Jersey: Prentice Hall. 1996.

HAYKIN, S. **Redes neurais: princípios e prática, 2ª ed**. Porto Alegre: Bookman, 2001.

HIGGINBOTHAM, S. **Forget Microwaves: Startup Vubiq Banks on Millimeter Waves**. 2009. Disponível em: <<http://gigaom.com/2009/07/26/startup-vubiq-goes-long-on-shortwave-radios/>>. Acesso em: 08 set. 2014.

HOSSAIN, E., NIYATO, D., HAN, Z. **Dynamic Spectrum Access and Management in Cognitive Radio Networks**. Cambridge: Cambridge University Press, 2009.

INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS. **IEEE 802.22**: IEEE Standard for Information Technology Telecommunications and information exchange between systems. Wireless Regional Area Networks (WRAN) Specific requirements. Part 22: Cognitive Wireless RAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications: Policies and Procedures for Operation in the TV Bands. Nova York: 2011. Disponível em: <<http://standards.ieee.org/getieee802/download/802.22-2011.pdf>>. Acesso em: 02 abr. 2014.

INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS. **IEEE 802.16**: IEEE Standard for Air Interface for Broadband Wireless Access Systems. Nova York: 2012. Disponível em: <<http://standards.ieee.org/getieee802/download/802.16-2012.pdf>>. Acesso em: 12 set. 2014.

JUNWEI, H, YUNXIAO, Z. **An Enhanced Energy Detection Algorithm in Cognitive Radio**. 5th International Conference on Wireless Communications, Networking and Mobile Computing, WiCom '09. 2009. Disponível em: <<http://dx.doi.org/10.1109/WICOM.2009.5300870>>. Acesso em: 24 ago. 2014.

KARAMCHEDU, R. **Does China Have the Best Digital Television Standard on the Planet?** 2009. Disponível em: <<http://spectrum.ieee.org/consumer-electronics/standards/does-china-have-the-best-digital-television-standard-on-the-planet>>. Acesso em: 08 ago. 2014.

KRIM, H., VIBERG, M. **Two Decades of Array Signal Processing Research: The Parametric Approach**. IEEE Signal Processing Magazine, vol. 13. 1996. p. 67–94.

LIU, R., WANG, B. **Cognitive Radio Networking and Security – A Game-Theoretic View**. Cambridge: Cambridge University Press, 2011.

MATLAB and Statistics Toolbox Release 2012a, The MathWorks, Inc., Natick, Massachusetts, United States.

MATLAB and Statistics Toolbox Release 2012a. **DVB-T 2k Mode, Nonhierarchical Transmission**. The MathWorks, Inc., Natick, Massachusetts, United States.

MITOLA, J. **Cognitive radio: An integrated agent architecture for software defined radio**. Estocolmo: KTH, 2000. Doutorado em Tecnologia, Royal Inst. Technol. (KTH). Suécia: 2000.

MITOLA, J. **Cognitive radio architecture: the engineering foundations of radio XML**. Nova Jersey: John Wiley & Sons Inc, 2006.

MORSE, B.S., YOO, T.S. **Interpolating Implicit Surfaces From Scattered Surface Data Using Compactly Supported Radial Basis Functions**. 2001. Disponível em: <<http://dx.doi.org/10.1109/SMA.2001.923379>>. Acesso em: 20 set. 2014.

NATIONAL INSTRUMENTS. **OFDM and Multi-Channel Communication Systems, NI-Tutorial-3740**. 2013. Disponível em: <<http://www.ni.com/white-paper/3740/en/>> Acesso em: 03 ago. 2014.

OLEXA, R. **Implementing 802.11, 802.16, and 802.20 Wireless Networks**. Burlington: Elsevier, 2005.

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL. Biblioteca Central Ir. José Otão. **Modelo para apresentação de trabalhos acadêmicos, teses e dissertações elaborado pela Biblioteca Central Irmão José Otão.** 2011. Disponível em: <www.pucrs.br/biblioteca/trabalhosacademicos>. Acesso em: 20 ago. 2014.

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL. Biblioteca Central Ir. José Otão. **Modelo de Referências Elaborado pela Biblioteca Central Irmão José Otão.** Disponível em: <<http://www3.pucrs.br/portal/page/portal/biblioteca/Capa/BCEPesquisa/BCEPesquisaModelos>>. Acesso em: 20 ago. 2014.

PROAKIS, J., SALEHI, M. **Communication Systems Engineering.** Nova Jersey: Prentice-Hall, 2002.

QSL.NET, Amateur Radio Community. **Modulação angular: FM e PM.** Disponível em: <<http://www.qsl.net/py4zbz/teoria/fmpm.htm>>. Acesso em: 04 ago. 2014.

ROSU, I. **Automatic Gain Control (AGC) in Receivers.** Disponível em: <http://www.qsl.net/va3iul/Files/Automatic_Gain_Control.pdf>. Acesso em: 01 ago. 2014.

ROSU, I. **LNA (Low Noise Amplifiers) Design.** Disponível em: <<http://www.qsl.net/va3iul/LNA%20design.pdf>>. Acesso em: 01 ago. 2014.

SHIBING, Z., JIAOJIAO, Y., LILI, G. **Eigenvalue-Based Cooperative Spectrum Sensing algorithm.** Second International Conference on Instrumentation & Measurement, Computer, Communication and Control. 2012. Disponível em: <<http://dx.doi.org/10.1109/IMCCC.2012.92>>. Acesso em: 30 mar. 2014.

SKLAR, B. **DIGITAL COMMUNICATIONS Fundamentals and Applications.** Nova Jersey: Prentice Hall, 2001.

SPIB, Signal Processing Information Base. **Channel Impulse Responses.** Cornell University. 2006. Disponível em: <<http://spib.linse.ufsc.br/microwave.html>>. Acesso em: 07 set. 2014.

STAPLE, G., WERBACH, K. **The End of Spectrum Scarcity.** 2004. Disponível em: <<http://spectrum.ieee.org/telecom/wireless/the-end-of-spectrum-scarcity>>. Acesso em: 09 set. 2014.

SVANTESSON, T. **Direction Finding in the Presence of Mutual Coupling.** **Licenciate Thesis Technical Report No. 307L.** Suécia: Chalmers Reproservice, 1999.

SVANTESSON, T. **Antennas and Propagation from a Signal Processing Perspective.** Thesis for the degree of Doctor of Philosophy, Technical Report No. 407. Suécia: Chalmers Reproservice, 2001.

TACHWALI, Y., BARNES, W., BASMA, F., REFAI, H. **The Feasibility of a Fast Fourier Sampling Technique for Wireless Microphone Detection in IEEE 802.22 Air Interface.** INFOCOM IEEE Conference on Computer Communications Workshops. 2010. Disponível em: <<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=5466621>>. Acesso em: 20 ago. 2014.

TERTIARY EDUCATION AND RESEARCH NETWORK OF SOUTH AFRICA. **TENET: The Cape Town TV White Spaces Trial.** 2013. Disponível em: <<http://www.tenet.ac.za/tvws>>. Acesso em: 08 set. 2014.

URKOWITZ, H. **Energy Detection of Unknown Deterministic Signals.** Proceedings of the IEEE, VOL. 55, NO. 4, 1967. Disponível em: <<http://dx.doi.org/10.1109/PROC.1967.5573>>. Acesso em: 24 ago. 2014.

U.S. FEDERAL COMMUNICATIONS COMMISSION. **FCC 08-260:** Second report and order and memorandum: In the matter of unlicensed operation in the TV broadcast bands—ET Docket No. 04-186 and additional spectrum for unlicensed devices below 900 MHz and in the 3 GHz band—ET Docket No. 02-380. 2008.

U.S. FEDERAL COMMUNICATIONS COMMISSION. **OET Report 99-2:** DTV Report on COFDM and 8-VSB Performance. 1999.

VAN DER BERG, R. **Microsoft unveils TV white-spaces trial.** 2014. Disponível em: <<http://www.techcentral.co.za/microsoft-unveils-tv-white-spaces-trial/48948/>>. Acesso em: 08 set. 2014.

VAN TREES, H. **Detection, Estimation, and Modulation Theory, Part I: Detection, Estimation, and Linear Modulation Theory.** Nova York: John Wiley & Sons, Inc, 2001.

WANG, Z. **Measurement and Statistics of Spectrum Occupancy, Advances in Cognitive Radio Systems.** InTech. 2012. Disponível em: <<http://cdn.intechopen.com/pdfs-wm/37693.pdf>>. Acesso em: 29 set. 2014.

WYGLINSKI, A. M., NEKOVEE, M., HOU, Y.T. **Cognitive Radio Communications and Networks Principles and Practice.** Burlington: Elsevier, 2010.

YU, F. R. **Cognitive Radio Mobile Ad Hoc Networks.** Nova York: Springer, 2011.

ZENG, Y., LIANG, Y. **Covariance Based Signal Detections for Cognitive Radio.** IEEE 2nd International Symposium on New Frontiers in Dynamic Spectrum Access Networks. 2007. p.202-207.

ZENG, Y., LIANG, Y. **Maximum-Minimum Eigenvalue Detection for Cognitive Radio.** IEEE 18th International Symposium on Personal, Indoor and Mobile Radio Communications. 2007. p.1-5.

ZENG, Y., LIANG, Y. **Eigenvalue-Based Spectrum Sensing Algorithms for Cognitive Radio.** IEEE Transactions On Communications, VOL. 57, NO. 6. 2009.

ZHIWEN, L., HANG, Z., SHAOFAN, S., DESHENG, Z. **Analysis and Improvement of Eigenvalue Spectrum Sensing in Cognitive Radio Networks.** 2010. Disponível em: <<http://dx.doi.org/10.1109/WCSP.2010.5633521>>. Acesso em: 30 mar. 2014.

Apêndice A

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PUCRS - Mestrado em Engenharia Eletrica
% Aluna: Ludimila La Rosa Centeno
% CLASSIFICAÇÃO DE SINAIS POR DECOMPOSIÇÃO EM SUBESPAÇOS PARA SENSORIAMENTO
% ESPECTRAL DE RÁDIO COGNITIVO
%
% Este algoritmo importa arquivo com sinal e cria banco de Eigenfilters
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%%
tic;
addpath(genpath('C:\Users\Ludimila\Google Drive 2\Ensino\CR\'));
cd 'C:\Users\Ludimila\Google Drive 2\Ensino\CR\Projeto
Final\Desenvolvimento\';

% Menu de configuracao
[arquivo,arquivo_Es,RBF_file,abort,savefile,controle_Eigen,EIGFBANK_type_se
lection]=config_menu();

if strcmp(abort,'true')==1
    return
end

if controle_Eigen==0
    disp('Escolha o tamanho do simbolo e CP')
    reply = input(' (1) OFDM [1] \n (2) WMIC \n (3) DVBT \n');
    if isempty(reply)
        reply = 1;
    end
    if reply==1
        EIGFBANK_type_selection='OFDM';
    end
    if reply==2
        EIGFBANK_type_selection='WMIC';
    end
    if reply==3
        EIGFBANK_type_selection='DVBT';
    end
end

end
%%
% Definicoes principais

controle_RBF=0; % Decide se vai importar RBF ou usar a que estiver no
workspace
                % Para importar RBF do arquivo --> controle_RBF=0
                % Para usar a do workspace --> controle_RBF=1

%Escolha de tamanho de simbolo e CP
if strcmp(EIGFBANK_type_selection,'OFDM')==1
    % Sinal OFDM
    simb_OFDM=256;
    CP_size=64;
    window_size=5000;
```

```

        step_amostragem=5000;
        n_autovetor_ruido=105;
    end

    if strcmp(EIGFBANK_type_selection, 'WMIC')==1
        % Sinal WMIC
        simb_OFDM=256;
        CP_size=64;
        window_size=5000;
        step_amostragem=100;
        n_autovetor_ruido=314;
    end

    if strcmp(EIGFBANK_type_selection, 'DVB-T')==1
        % Sinal DVB-T
        simb_OFDM=1536;
        CP_size=512;
        window_size=5000;
        step_amostragem=5000;
        n_autovetor_ruido=1968;
    end

    %%
    % Loop para Sinal
    sinal=importdata(arquivo);
    sinal_norm=sinal./max(abs(sinal(:)));
    if controle_Eigen==0
        matriz=vec2mat(sinal_norm,(simb_OFDM+CP_size));
        cov_matrix=cov(matriz);
        [evecs,evals]=eig(cov_matrix,'nobalance');
        tamanho=size(evecs)-n_autovetor_ruido;
        [D,I]=sort(diag(evals),1,'descend');
        evecs_temp=evecs(:,I);
        Es=evecs_temp(:,1:tamanho(1));
        menor_eigen=evecs_temp(:,end);
        Es_final=cat(2,Es,menor_eigen);
        save(savefile,'Es_final');
    end

    %%
    % Loop filtros FIR
    if controle_Eigen==1
        Es=importdata(arquivo_Es);
    end
    [tamanho_filtro]=size(Es);
    for k=1:tamanho_filtro(2)
        coeficientes=(Es(:,k)).';
        filteredOutput(:,k) = conv(sinal_norm,coeficientes);
    end

    %%
    % Loop |abs(sinal)|^2
    for k=1:tamanho_filtro(2)
        filteredOutput_squared(:,k)=(abs(filteredOutput(:,k))).^2;
    end

    %%
    % Loop média móvel
    b=ones(1,window_size)/window_size;
    a=1;
    for k=1:tamanho_filtro(2)
        filtradoMA(:,k)=filter(b,a,filteredOutput_squared(:,k));
    end

    %%
    % Loop subamostragem

```

```

        comprimento=length(filtradoMA((windowsize:length(filtradoMA)-
windowsize)));
        for k=1:size(filtradoMA,2)
            contador=1;
            for l=windowsize:step_amostragem:comprimento

media_MA(contador,k)=mean(filtradoMA(l:l+step_amostragem,k));
            contador=contador+1;
            end
        end
        media_MA_norm=media_MA/max(max(media_MA));
%%
        if isempty(RBF_file)
            disp('Execução encerrada - Arquivo de RBF não selecionado')
            disp(['Novo Eigenfilter Bank calculado: ',savefile])
            return
        else
            if controle_RBF==0
                % Importa RBF

[Tset_avg_vector,Tset_stdev_vector,Norm_parameters,Centers_SG,Centers_var,B
IAS,Synapses,Nr_centers,Nr_input_nodes]=importa_RBF(RBF_file);
            end
        end
%%
        %Simula RBF
        if strcmp(EIGFBANK_type_selection,'DVBT')==1
            media_MA_norm=media_MA_norm(3:end,:);
        end

RBF_out=simula_RBF(media_MA_norm,Tset_avg_vector,Tset_stdev_vector,Norm_par
ameters,Centers_SG,Centers_var,BIAS,Synapses,Nr_centers);
        diary on
        disp('Resultado da detecção')
        disp(['Nº de vetores analisados pela RBF: ',num2str(length(RBF_out))])
        disp(['Mínimo valor retornado pela RBF: ',num2str(min(RBF_out))])
        disp(['Máximo valor retornado pela RBF: ',num2str(max(RBF_out))])
        disp(['Quantidade de valores menores do que 0.5:
',num2str(size(RBF_out(RBF_out<=0.5),1))])
        diary off
        toc;

```

Apêndice B

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PUCRS - Mestrado em Engenharia Eletrica
% Aluna: Ludimila La Rosa Centeno
% CLASSIFICAÇÃO DE SINAIS POR DECOMPOSIÇÃO EM SUBESPAÇOS PARA SENSORIAMENTO
% ESPECTRAL DE RÁDIO COGNITIVO
%
% Este algoritmo importa a RBF selecionada no ambiente MATLAB
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%
%Define strings padrao do arquivo
function
[Tset_avg_vector,Tset_stdev_vector,Norm_parameters,Centers_SG,Centers_var,B
IAS,Synapses,Nr_centers,Nr_input_nodes]=importa_RBF(arquivo_RBF)
STR1='The training set average vector: ';
STR2='The training set standard deviation vector: ';
STR3='The training desired output set D normalization parameters A_n and
B_n, such that Dn=A_n*D+B_n where Dn lies in the range [-1,1]: ';
STR4='RBF Centers Vectors determined by K-Means';
STR5='RBF Centers Vectors determined by SG';
STR6='The respective RBF centers Variance: ';
STR7='The RBF output neuron Synapses Vector (leftmost component - Bias
Synapse): ';
STR8='RBFTRV parameter file and its date & time.';
STR9='% The number of hidden neurons in the RBF.';
STR10='% The number of input nodes in the RBF.';
RBF_file_strings=char(STR1,STR2,STR3,STR4,STR5,STR6,STR7,STR8,STR9,STR10);
RBF_file_strings_length=[33,44,130,48,43,37,75,43,43,40];
%%
% Importa arquivo da RBF
RBF_file=fopen(arquivo_RBF);
RBF_file_contents=fscanf(RBF_file,'%c');
fclose(RBF_file);
%%
% Encontra posicao inicial de cada uma das strings de referencia
str_position=zeros(size(RBF_file_strings_length));
for i=1:(size(RBF_file_strings,1))
    str_position(i) =
    strfind(RBF_file_contents,(strcat(RBF_file_strings(i,:))));
end
%%
% Inicia segmentacao de dados
RBF_tset_avg_vector=RBF_file_contents((str_position(1)+RBF_file_strings_len
gth(1)):(str_position(2)-1));
RBF_tset_stdev_vector=RBF_file_contents((str_position(2)+RBF_file_strings_l
ength(2)):(str_position(3)-1));
RBF_norm_parameters=RBF_file_contents((str_position(3)+RBF_file_strings_len
gth(3)):(str_position(4)-7));
RBF_centers_SG=RBF_file_contents((str_position(5)+RBF_file_strings_length(5
)+29):(str_position(6)-1));
RBF_centers_var=RBF_file_contents((str_position(6)+RBF_file_strings_length(
6)):(str_position(7)-1));
RBF_output_BIAS_synapse=RBF_file_contents((str_position(7)+RBF_file_strings
_length(7)):end);
```



```
RBf_nr_centers=RBf_file_contents((str_position(8)+RBf_file_strings_length(8
)): (str_position(9)-1));
RBf_nr_input_nodes=RBf_file_contents((str_position(9)+RBf_file_strings_leng
th(9)): (str_position(10)-1));
%%
%Separacao dos dados em vetores
temp=strread(RBf_tset_avg_vector);
Tset_avg_vector=temp(1:end-1);
temp=strread(RBf_tset_stdev_vector);
Tset_stdev_vector=temp(1:end-1);
temp=strread(RBf_norm_parameters);
Norm_parameters=temp(1:end-1);
temp=strread(RBf_centers_SG);
Centers_SG=temp(:,1:end-1);
temp=strread(RBf_centers_var);
Centers_var=temp(1:end-1);
temp=strread(RBf_output_BIAS_synapse);
BIAS=temp(1);
Synapses=temp(2:end-1);
temp=strread(RBf_nr_centers);
Nr_centers=temp(1:end-1);
temp=strread(RBf_nr_input_nodes);
Nr_input_nodes=temp(1:end-1);
```

Apêndice C

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PUCRS - Mestrado em Engenharia Eletrica
% Aluna: Ludimila La Rosa Centeno
% CLASSIFICAÇÃO DE SINAIS POR DECOMPOSIÇÃO EM SUBESPAÇOS PARA SENSORIAMENTO
% ESPECTRAL DE RÁDIO COGNITIVO
%
% Este algoritmo simula a RBF
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% Remove Training Set Average Vector do vetor de entrada e realiza sua
% normalizacao pelo Training Set Standard Deviation Vector
function
saida_RBF=simula_RBF(xValues,Tset_avg_vector,Tset_stdev_vector,Norm_paramet
ers,Centers_SG,Centers_var,BIAS,Synapses,Nr_centers)
for k=1:size(xValues,1)
    for i=1:size(xValues,2)
        xValues_new(1,i)=(xValues(k,i)-
Tset_avg_vector(1,i))/Tset_stdev_vector(1,i);
    end
% Calcula distancia Euclidiana
    for j=1:Nr_centers
        distancia = dist_euclid(xValues_new,Centers_SG(j,:));
        NDN = distancia / Centers_var(j);
        phy = exp(-NDN);
        hOutputs(j) = phy;
    end

% Calcula output
    outputs=0;
    for i=1:Nr_centers
        outputs=outputs+(hOutputs(i)*Synapses(i));
    end
    outputs=outputs - BIAS;
    outputs=(outputs - Norm_parameters(2))/Norm_parameters(1);
    saida_RBF(k,1)=outputs;
end
```

Apêndice D

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PUCRS - Mestrado em Engenharia Eletrica
% Aluna: Ludimila La Rosa Centeno
% CLASSIFICAÇÃO DE SINAIS POR DECOMPOSIÇÃO EM SUBESPAÇOS PARA SENSORIAMENTO
% ESPECTRAL DE RÁDIO COGNITIVO
%
% Este algoritmo gera os sinais de microfone sem fio conforme
% IEEE recommendation to simulate Wireless Mic Signals
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
clear all;close all;
%SILENT - Tipo=0
%SOFT SPEAKER - Tipo=1
%LOUD SPEAKER - Tipo=2
Tipo=0;
SNR_activate=1; %1 para adicionar SNR
SNR=20; %valor da SNR
if Tipo==0
    %SILENT - Tipo=0
    fc=3*10^(6); %Carrier
    fs=18*10^(6); %Sampling Rate
    dph=5*10^(3); %Frequency Deviation
    ini_phase=0;
    F1=32*10^(3); %Frequency of Silent Tone
end
if Tipo==1
    %SOFT SPEAKER - Tipo=1
    fc=3*10^(6); %Carrier
    fs=18*10^(6); %Sampling Rate
    dph=15*10^(3); %Frequency Deviation
    ini_phase=0;
    F1=3.9*10^(3); %Frequency of soft speaker
end
if Tipo==2
    %LOUD SPEAKER - Tipo=2
    fc=3*10^(6); %Carrier
    fs=18*10^(6); %Sampling Rate
    dph=32.6*10^(3); %Frequency Deviation
    ini_phase=0;
    F1=13.4*10^(3); %Frequency of Silent Tone
end
t = 0:1/fs:0.01;
A1 = 1;
x=A1*sin(2*pi*F1*t); %Informacao
if SNR_activate==1
    x=awgn(x,SNR,'measured');
end
y=fmmod(x,fc,fs,dph,ini_phase); %frequency modulation
figure ('Name','Mensagem');
subplot(2,1,1);
plot(x);
title('Sinal de informação');
subplot(2,1,2);
plot(y);
title('Modulação FM');
```

```

h = spectrum.periodogram('hamming');
hopts = msspectrumopts(h,y);
set(hopts,'Fs',fs,'SpectrumType','twosided','centerdc',true);
figure('Name','PSD');
msspectrum(h,y,hopts);
set(gcf,'Color',[1 1 1])
if Tipo==0
    if SNR_activate==1
        title({strcat('Periodograma');strcat('Microfone sem fio - Silent -
SNR (20dB)')})
    else
        title({strcat('Periodograma');strcat('Microfone sem fio -
Silent')})
    end
    set(gca,'YGrid','on','XGrid','on','xlim',[2.9 3.1],'ylim',[-100
0],'box','on')
    xlabel('Frequência (MHz)');
    ylabel('Potência/Frequência (dB/Hz)');
end
if Tipo==1
    if SNR_activate==1
        title({strcat('Periodograma');strcat('Microfone sem fio - Soft
Speaker - SNR (20dB)')})
    else
        title({strcat('Periodograma');strcat('Microfone sem fio - Soft
Speaker')})
    end
    set(gca,'YGrid','on','XGrid','on','xlim',[2.9 3.1],'ylim',[-100
0],'box','on')
    xlabel('Frequência (MHz)');
    ylabel('Potência/Frequência (dB/Hz)');
end
if Tipo==2
    if SNR_activate==1
        title({strcat('Periodograma');strcat('Microfone sem fio - Loud
Speaker - SNR (20dB)')})
    else
        title({strcat('Periodograma');strcat('Microfone sem fio - Loud
Speaker')})
    end
    set(gca,'YGrid','on','XGrid','on','xlim',[2.9 3.1],'ylim',[-100
0],'box','on')
    xlabel('Frequência (MHz)');
    ylabel('Potência/Frequência (dB/Hz)');
end

```

Apêndice E

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PUCRS - Mestrado em Engenharia Eletrica
% Aluna: Ludimila La Rosa Centeno
% CLASSIFICAÇÃO DE SINAIS POR DECOMPOSIÇÃO EM SUBESPAÇOS PARA SENSORIAMENTO
% ESPECTRAL DE RÁDIO COGNITIVO
%
% Filtra sinal do Microfone sem fio para análise posterior
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
arquivo='C:\Users\Ludimila\Google Drive 2\Ensino\CR\Projeto
Final\Desenvolvimento\WM\WMIC_Silent_SNR20.mat';
xin=importdata(arquivo);
Fc=3*10^(6); %Carrier
Fs=18*10^(6); %Sampling Rate
figure('Name','PSD sinal WMIC');
psd(spectrum.periodogram,xin,'Fs',Fs)
xlabel('Frequência (MHz)');
ylabel('Potência/Frequência (dB/Hz)');
title({strcat('Periodograma');strcat('Microfone sem fio sem filtragem')}})
% Direct Digital Synthesizer
    ddsRealRx = zeros(1, length(xin));
    ddsImagRx = zeros(1, length(xin));
    for n=1:1:length(ddsRealRx)
        ddsRealRx(1,n)= xin(n) * cos(2*pi*(Fc/Fs)*n); %Sinal_I
        ddsImagRx(1,n)= xin(n) * sin(2*pi*(Fc/Fs)*n); %Sinal_Q
    end;
Sinal_I=ddsRealRx;
Sinal_Q=ddsImagRx;
%LPF
hFIR = dsp.FIRFilter;
hFIR.Numerator = fir1(118,0.05); %118
[h,w] = freqz(hFIR.Numerator,1,128);
figure('Name','Filtro');plot(w/pi,abs(h));
hSR = dsp.SignalReader(Sinal_I);
hLog = dsp.SignalLogger;
    while ~isDone(hSR)
        input = step(hSR);
        filteredOutputI = step(hFIR,input);
        step(hLog,filteredOutputI);
    end
figure('Name','Espectro I');
filteredResultI = hLog.Buffer;
one=psd(spectrum.periodogram,filteredResultI,'Fs',Fs);
two=psd(spectrum.periodogram,Sinal_I,'Fs',Fs,'SpectrumType','onesided');
plot(two.Frequencies,10*log10(two.Data),'b');
hold all
plot(one.Frequencies,10*log10(one.Data),'r');
grid on;
xlabel('Frequência (MHz)');
ylabel('Potência/Frequência (dB/Hz)');
title({strcat('Periodograma');strcat('Microfone sem fio - Espectro I')}})
legend('Sinal original','Sinal filtrado')
hSR = dsp.SignalReader(Sinal_Q);
hLog = dsp.SignalLogger;
    while ~isDone(hSR)
```

```

    input = step(hSR);
    filteredOutputQ = step(hFIR,input);
    step(hLog,filteredOutputQ);
end
figure('Name','Espectro Q');
filteredResultQ = hLog.Buffer;
one=psd(spectrum.periodogram,filteredResultQ,'Fs',Fs);
two=psd(spectrum.periodogram,Sinal_Q,'Fs',Fs,'SpectrumType','onesided');
plot(two.Frequencies,10*log10(two.Data),'b');
hold all
plot(one.Frequencies,10*log10(one.Data),'r');
grid on;
xlabel('Frequência (MHz)');
ylabel('Potência/Frequência (dB/Hz)');
title({strcat('Periodograma');strcat('Microfone sem fio - Espectro Q')})
legend('Sinal original','Sinal filtrado')
sinal_junto=complex(filteredResultI,filteredResultQ);
figure('Name','Sinal WMIC em banda-base');
one=psd(spectrum.periodogram,sinal_junto,'Fs',Fs,'SpectrumType','onesided',
'centerdc',true);
plot(one.Frequencies,10*log10(one.Data),'b');
xlabel('Frequência (MHz)');
ylabel('Potência/Frequência (dB/Hz)');
title({strcat('Periodograma');strcat('Microfone sem fio filtrado - banda-
base')})
grid on;
set(gca,'YGrid','on','XGrid','on','xlim',[-100 8e6],'ylim',[-150
0],'box','on')

```

Apêndice F

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PUCRS - Mestrado em Engenharia Eletrica
% Aluna: Ludimila La Rosa Centeno
% CLASSIFICAÇÃO DE SINAIS POR DECOMPOSIÇÃO EM SUBESPAÇOS PARA SENSORIAMENTO
% ESPECTRAL DE RÁDIO COGNITIVO
%
% Gera ruido Gaussiano
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
clear all; clc; close all;
L=448000;
mu=0;
sigma=0.2805;
X=sigma*randn(L,1)+mu;
figure();
subplot(2,1,1)
plot(X);
title(['Ruído branco : \mu_x=',num2str(mu), ' \sigma^2=',num2str(sigma^2)])
xlabel('Amostras')
ylabel('Valores das amostras')
grid on;
subplot(2,1,2)
n=100;
[f,x]=hist(X,n);
bar(x,f/trapz(x,f)); hold on;
g=(1/(sqrt(2*pi)*sigma))*exp(-((x-mu).^2)/(2*sigma^2));
plot(x,g,'r');hold off; grid on;
title('PDF teórica e histograma simulado do ruído AWGN');
legend('Histograma','PDF teórica');
xlabel('Bins');
ylabel('PDF f_x(x)');
figure();
Rxx=1/L*conv(flipud(X),X);
lags=(-L+1):1:(L-1);
plot(lags,Rxx);
title('Função de Autocorrelação do ruído AWGN');
xlabel('Atrasos')
ylabel('Correlação')
grid on;
```

Apêndice G

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PUCRS - Mestrado em Engenharia Eletrica
% Aluna: Ludimila La Rosa Centeno
% CLASSIFICAÇÃO DE SINAIS POR DECOMPOSIÇÃO EM SUBESPAÇOS PARA SENSORIAMENTO
% ESPECTRAL DE RÁDIO COGNITIVO
%
% Gera ruído impulsivo usando a função GAUSSMIX
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
clear all;
v1=0.0001;
v2=0.0011;
a=0.5;
M=1e3;
N=1;
n_ruidos=5;
for x=1:n_ruidos
    imp_noise(:,x)=gaussmix(M,N,a,v1,v2);
end
sinall=load('C:\Users\Ludimila\Google Drive 2\Ensino\CR\Projeto
Final\Desenvolvimento\Sinais\OFDM_256_16QAM_CP4_1200S.mat');
amostral=sinall.data;
amostral_norm=amostral./max(abs(amostral(:)));
sinal_pow=sum(abs(amostral).^2)/length(amostral);
disp('Potencia do SINAL');disp(sinal_pow);
sinal_powdb=10*log10(sinal_pow);
disp('Potencia do sinal em dB');disp(sinal_powdb);
ruído_pow=sum(abs(imp_noise(:,1)).^2)/length(imp_noise(:,1));
disp('Potencia do RUIDO');disp(ruido_pow);
ruído_powdb=10*log10(ruido_pow);
disp('Potencia do ruído em dB');disp(ruido_powdb);
SNR=10*log10(sinal_pow/ruído_pow);
disp(['SNR é ' num2str(SNR) ' dB'])
figure('Name','Zoom sinal');
stem(abs(amostral));hold all;
for x=1:n_ruidos
    insert_noise=randi((size(amostral,1)-(M+1)),1);
    amostral(insert_noise:(insert_noise+(M-
1)),:)=complex(imp_noise(:,x),0);
end
stem(abs(amostral));
```


Apêndice H

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PUCRS - Mestrado em Engenharia Eletrica
% Aluna: Ludimila La Rosa Centeno
% CLASSIFICAÇÃO DE SINAIS POR DECOMPOSIÇÃO EM SUBESPAÇOS PARA SENSORIAMENTO
% ESPECTRAL DE RÁDIO COGNITIVO
%
% Implementa detecção de energia
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
clear all;
sinall=load('C:\Users\Ludimila\Google Drive 2\Ensino\CR\Projeto
Final\Desenvolvimento\Sinais\OFDM_256_16QAM_CP4_1200S.mat');
ruído=load('C:\Users\Ludimila\Google Drive 2\Ensino\CR\Projeto
Final\Desenvolvimento\Sinais\GN_448K.mat');
ruído_norm=ruído./max(abs(ruído(:)));
amostra1=sinall.data;
%Adiciona ruído gaussiano
amostra2=awgn(amostra1,10,'measured',0);
amostra3=awgn(amostra1,20,'measured',0);
amostra4=awgn(amostra1,30,'measured',0);
amostra5=awgn(amostra1,35,'measured',0);
amostra1_norm=amostra1./max(abs(amostra1(:)));
amostra2_norm=amostra2./max(abs(amostra2(:)));
amostra3_norm=amostra3./max(abs(amostra3(:)));
amostra4_norm=amostra4./max(abs(amostra4(:)));
amostra5_norm=amostra5./max(abs(amostra5(:)));
windowsize=20000;
b=ones(1,windowsize)/windowsize;
a=1;
ruído_sq=ruído_norm.^2;
filtradoMA_ruído=filter(b,a,ruído_sq);
amostra1_sq=(abs(amostra1_norm)).^2;
filtradoMA_amostra1=filter(b,a,amostra1_sq);
amostra2_sq=(abs(amostra2_norm)).^2;
filtradoMA_amostra2=filter(b,a,amostra2_sq);
amostra3_sq=(abs(amostra3_norm)).^2;
filtradoMA_amostra3=filter(b,a,amostra3_sq);
amostra4_sq=(abs(amostra4_norm)).^2;
filtradoMA_amostra4=filter(b,a,amostra4_sq);
amostra5_sq=(abs(amostra5_norm)).^2;
filtradoMA_amostra5=filter(b,a,amostra5_sq);

figure('Name','Ruído e Sinais');
set(plot(filtradoMA_ruído),'Linewidth',2);hold all;
set(plot(filtradoMA_amostra1),'Linewidth',2);
set(plot(filtradoMA_amostra2),'Linewidth',2);
set(plot(filtradoMA_amostra3),'Linewidth',2);
set(plot(filtradoMA_amostra4),'Linewidth',2);
set(plot(filtradoMA_amostra5),'Linewidth',2);
    legend('Ruído','Sinal','Sinal-SNR10','Sinal-SNR20','Sinal-
SNR30','Sinal-SNR35','Location','Best');
```

Anexo A1

Tabela de *delay profile*.

MULTIPATH PROFILE DETAILS

Multipath Ensemble	Channel Simulator Parameter	Path 1	Path 2	Path 3	Path 4	Path 5	Path 6	
Calibration	Delay (μ s)	0	OFF	OFF	OFF	OFF	OFF	
	Attenuation (dB)	0						
	Phase (degrees)	0						
Brazil A	Delay (μ s)	0	0.15	2.22	3.05	5.86	5.93	
	Attenuation (dB)	0	13.8	16.2	14.9	13.6	16.4	
	Phase (degrees)	0	0	0	0	0	0	
Brazil B	Delay (μ s)	0	0.30	3.50	4.40	9.50	12.70	
	Attenuation (dB)	0	12.0	4.0	7.0	15.0	22.0	
	Phase (degrees)	0	0	0	0	0	0	
Brazil C	Delay (μ s)	0	0.089	0.419	1.506	2.322	2.799	
	Attenuation (dB)	2.80	0	3.8	0.1	2.5	1.3	
	Phase (degrees)	0	0	0	0	0	0	
Brazil D	Delay (μ s)	0.15	0.63	2.22	3.05	5.86	5.93	
	Attenuation (dB)	0.1	3.8	2.6	1.3	0	2.8	
	Phase (degrees)	0	0	0	0	0	0	
Brazil E	Delay (μ s)	0	1.0	2.0	OFF	OFF	OFF	
	Attenuation (dB)	0	0	0				
	Phase (degrees)	0	0	0				
Special Brazil C	Delay (μ s)	0	0.089	1.506	1.506	2.322	2.799	
	Attenuation (dB)	2.80	0	20	0	2.5	1.3	
	Phase or Doppler	0°	0°	0.05 Hz	0°	0°	0°	
Modified Brazil C	Delay (μ s)	0	0.089	0.419	1.506	2.322	2.799	
	Attenuation (dB)	2.80	0	3.8	Variable	2.5	1.3	
	Phase or Doppler	0°	0°	0°	0.05 Hz	0°	0°	
Modified Brazil D	Delay (μ s)	0.15	0.630	2.22	3.05	5.86	5.93	
	Attenuation (dB)	Variable	3.8	2.6	1.3	0	2.8	
	Phase or Doppler	0.05 Hz	0°	0°	0°	0°	0°	
CRC Dynamic	Delay (μ s)	0	-1.8	0.15	1.8	5.7	35	
	Attenuation (dB)	#1	0	20	20	10	Varied to reach TOV	18
		#2	0	17	17	7		15
		#3	0	14	14	4		12
		#4	0	11	11	1		9
Phase or Doppler	0	125°	80°	45°	1 or 5 Hz	90°		
ACATS Ensemble A	Delay (μ s)	0	-1.8	0.15	1.8	5.7	18	
	Attenuation (dB)	0	20	20	10	Variable	18	
	Phase (degrees)	0	$\phi+288^\circ$	ϕ	$\phi+72^\circ$	$\phi+144^\circ$	$\phi+216^\circ$	

ACATS Ensemble A: Where ϕ is the phase of the shortest echo such that the null within the channel is offset with respect to the carrier (or pilot) frequency by +1.327320 MHz. Once the phase of the shortest delay is found, the phase of the other delay of the ensemble shall be: +72, +144, +216, and +288 degrees with respect to the shortest delay.

Special Brazil C: Echo Path 3 and 4 are assigned same delay (1.506 μ s), but different amplitude and phase. The Path 4 is 0 dB amplitude and 0 degree phase, while Path 3 is -20 dB amplitude and 0.05 Hz Doppler phase shift. The combined effect of Path 3 and 4 creates a flat fading environment so that the combined multipath amplitude goes higher and lower than 0 dB in a 0.05 Hz cycle.

Anexo B1

Algoritmo *k-means*.

- 1. Initialization.** Choose random values for the initial centers $\mathbf{t}_k(0)$; the only restriction is that these initial values be different. It may also be desirable to keep the Euclidean norm of the centers small.
- 2. Sampling.** Draw a sample vector \mathbf{x} from the input space \mathcal{X} with a certain probability. The vector \mathbf{x} is input into the algorithm at iteration n .
- 3. Similarity matching.** Let $k(\mathbf{x})$ denote the index of the best-matching (winning) center for input vector \mathbf{x} . Find $k(\mathbf{x})$ at iteration n by using the minimum-distance Euclidean criterion:

$$k(\mathbf{x}) = \operatorname{argmin}_k \|\mathbf{x}(n) - \mathbf{t}_k(n)\|, \quad k = 1, 2, \dots, m_1 \quad (5.154)$$

where $\mathbf{t}_k(n)$ is the center of the k th radial-basis function at iteration n .

- 4. Updating.** Adjust the centers of the radial-basis functions, using the update rule:

$$\mathbf{t}_k(n+1) = \begin{cases} \mathbf{t}_k(n) + \eta[\mathbf{x}(n) - \mathbf{t}_k(n)], & k = k(\mathbf{x}) \\ \mathbf{t}_k(n), & \text{otherwise} \end{cases} \quad (5.155)$$

where η is a *learning-rate parameter* that lies in the range $0 < \eta < 1$.

- 5. Continuation.** Increment n by 1, go back to step 2, and continue the procedure until no noticeable changes are observed in the centers \mathbf{t}_k .

Fonte: Haykin (1999).

Anexo C1

Excerto da resolução IEEE 802.22 (2011).

C.1.2 Eigenvalue sensing technique

This sensing technique is blind since it does not rely on the specific signal characteristics. It is a coarse sensing technique for DTV detection but it meets the fine sensing requirements for wireless microphones.

C.1.2.1 Eigenvalue-based sensing algorithms

Let $y(t)$ be the continuous time received signal. Assume that we are interested in the frequency band with central frequency f_c and bandwidth W . We sample the received signal $y(t)$ at a sampling rate f_s . In some applications, such as DTV detection, it is better that the sampling rate is larger than the channel bandwidth W . Let $T_s = 1/f_s$ be the sampling period. The received discrete signal is then $x(n) = y(nT_s)$. There are two hypotheses: H_0 : signal not exists; and H_1 : signal exists. The received signal samples under the two hypotheses are therefore respectively as follows:

$$H_0 : x(n) = \eta(n)$$
$$H_1 : x(n) = s(n) + \eta(n),$$

where $s(n)$ is the transmitted signal passed through a wireless channel (including fading and multipath effect), and $\eta(n)$ is the white noise samples. Note that $s(n)$ can be a superposition of multiple signals. The received signal is generally passed through a filter. Let $f(k)$, $k = 0, 1, \dots, K$ be the filter. The value of K is ... After filtering, the received signal is turned to

$$\tilde{x}(n) = \sum_{k=0}^K f(k)x(n-k), \quad n = 0, 1, \dots$$

Let

$$\tilde{s}(n) = \sum_{k=0}^K f(k)s(n-k), \quad n = 0, 1, \dots$$
$$\tilde{\eta}(n) = \sum_{k=0}^K f(k)\eta(n-k), \quad n = 0, 1, \dots$$

Then

$$H_0 : \tilde{x}(n) = \tilde{\eta}(n)$$
$$H_1 : \tilde{x}(n) = \tilde{s}(n) + \tilde{\eta}(n)$$

Note that here the noise samples $\tilde{\eta}(n)$ are correlated. If the sampling rate f_s is larger than the channel bandwidth W , we can down-sample the signal. Let $M \geq 1$ be the down-sampling factor. If the signal to be detected has a much narrower bandwidth than W , it is better to choose $M > 1$. For notation simplicity, we still use $\tilde{x}(n)$ to denote the received signal samples after down-sampling, that is: $\tilde{x}(n) \approx \tilde{x}(Mn)$.

Choose a smoothing factor $L > 1$ and define

$$\mathbf{x}(n) = [\tilde{x}(n) \quad \tilde{x}(n-1) \quad \dots \quad \tilde{x}(n-L+1)]^T, \quad n = 0, 1, \dots, N_s - 1$$

A suggested value of L is about 10. Define a $L \times (K+1+(L-1)M)$ matrix as

$$X = \begin{bmatrix} f(0) & \dots & \dots & f(K) & 0 & \dots & 0 \\ 0 & \dots & f(0) & \dots & f(K) & \dots & 0 \\ & & \dots & & \dots & & \\ 0 & \dots & \dots & \dots & f(0) & \dots & f(K) \end{bmatrix}$$

Let $\mathbf{G} = \mathbf{X}\mathbf{X}^H$. Decompose the matrix into $\mathbf{G} = \mathbf{Q}\mathbf{Q}^H$, where \mathbf{Q} is a $L \times L$ Hermitian matrix. The matrix \mathbf{G} is not related to signal and noise and can be computed offline. If analog filter or both analog

filter and digital filter are used, the matrix \mathbf{G} should be revised to include the effects of all the filters. In general, \mathbf{G} can be obtained to be the covariance matrix of the received signal, when the input signal is white noise only (this can be done in laboratory offline). The matrix \mathbf{G} and \mathbf{Q} are computed only once and only \mathbf{Q} is used in detection.

C.1.2.1.1 Maximum-minimum eigenvalue (MME) detection

Step 1: Sample and filter the received signal as described above.

Step 2: Choose a smoothing factor L and compute the threshold γ to meet the requirement for the probability of false alarm.

Step 3: Compute the sample covariance matrix

$$\mathbf{R}(N_s) = \frac{1}{N_s} \sum_{n=0}^{N_s-1} \mathbf{x}(n)\mathbf{x}^H(n)$$

where N_s is the number of samples.

Step 4: Transform the sample covariance matrix to obtain

$$\tilde{\mathbf{R}}(N_s) = \mathbf{Q}^{-1}\mathbf{R}(N_s)\mathbf{Q}^{-H}$$

Step 5: Compute the maximum eigenvalue and minimum eigenvalue of the matrix $\tilde{\mathbf{R}}(N_s)$ and denote them as λ_{\max} and λ_{\min} , respectively.

Step 6: Determine the presence of the signal based on the eigenvalues and the threshold: if $\lambda_{\max} / \lambda_{\min} > \gamma$, signal exists; otherwise, signal not exists.

C.1.2.1.2 Energy with minimum eigenvalue (EME) detection

Step 1: Sample and filter the received signal as described above.

Step 2: Choose a smoothing factor L and compute the threshold γ to meet the requirement for the probability of false alarm.

Step 3: Compute the sample covariance matrix

$$\mathbf{R}(N_s) = \frac{1}{N_s} \sum_{n=0}^{N_s-1} \mathbf{x}(n)\mathbf{x}^H(n)$$

Step 4: Transform the sample covariance matrix to obtain

$$\tilde{\mathbf{R}}(N_s) = \mathbf{Q}^{-1}\mathbf{R}(N_s)\mathbf{Q}^{-H}$$

Step 5: Compute the average energy of the received signal ρ , and the minimum eigenvalue of the matrix $\tilde{\mathbf{R}}(N_s)$, λ_{\min} .

Step 6: Determine the presence of the signal: if $\rho / \lambda_{\min} > \gamma$, signal exists; otherwise, signal not exists.

C.1.2.2 Performance of the algorithms

The threshold γ in MME is determined by the ratio $\lambda_{\max} / \lambda_{\min}$ and the required probability of false alarm (P_{fa}). When there is no signal, the ratio is not related to noise power at all. Hence, it does not have the noise uncertainty problem. The same is valid for EME. Both methods do not need noise power estimation. The performances of the methods are not only related to SNR but also related to signal statistic properties.

In the following the performances of the methods are given based on simulations, where $L = 10$. The required SNR is the lowest SNR which meets the requirement of $P_{fa} \leq 0.1$ and the probability of misdetection $P_{md} \leq 0.1$. Note that the SNR is always measured in one TV channel with 6 MHz bandwidth. For DTV, the results are averaged on the 12 specified DTV signals. Note that the performance of the methods can always be improved by increasing the sensing time.

a) Simulations for DTV (single channel sensing). The simulation is done at IF band.

Table C.2—Required SNR for DTV signal detection (single channel)

Method	4 ms	8 ms	16 ms	32 ms
MME	-11.6 dB	-13.2 dB	-15 dB	-16.9 dB
EME	-10.5 dB	-12.1 dB	-14 dB	-15.8 dB

- b) Simulations for wireless microphone. The wireless microphone signal is down-converted into baseband. Table C.3 gives the simulation results for wireless microphone signals [average on 3 types of signals: soft speaker, loud speaker, and silence (Clanton, Kenkel, and Tang [3])]. The settings and procedures for the simulation are as follows. Baseband microphone signal is generated. The signal is sampled at sampling rate 12 MHz. The signal is then filtered with a low-pass filter with 6 MHz bandwidth. The signal is passed through a multipath simulator (Rayleigh fading with 5 taps). White noise samples (sampling rate 12 MHz) are generated and passed through the same filter. The signal and scaled noise are added together and then down-sampled (decimated) by a factor $M = 2$.

Table C.3—Required SNR for wireless microphone signal detection

Method	4 ms	10 ms
MME	-21.0 dB	-23.1 dB
EME	-16.4 dB	-18.4 dB

- c) Simulations for DTV (multiple channel sensing). The method can be used to detect multiple consecutive channels at the same time. Here an example is given for detecting three consecutive channels at the same time. The input signal is the captured DTV signal (one channel is occupied and the remaining two channels are vacant). The signal is down-converted into baseband. The signal and noise are then filtered by a baseband filter with bandwidth 18 MHz.

Table C.4—Required SNR for DTV signal detection (three consecutive channels)

Method	4 ms	16 ms
MME	-17.5 dB	-20.9 dB
EME	-15.6 dB	-19.1 dB

Fonte: IEEE 802.22 (2011).