

Inatel

Instituto Nacional de Telecomunicações

Análise Comparativa de Técnicas
de Sensoriamento Espectral
baseadas em Redes Neurais,
Matriz de Covariância e Densidade
Espectral de Potência

WESLEY REIS DA SILVA

NOVEMBRO / 2023



**ANÁLISE COMPARATIVA DE
TÉCNICAS DE SENSORIAMENTO
ESPECTRAL BASEADAS EM RE-
DES NEURAI, MATRIZ DE CO-
VARIÂNCIA E DENSIDADE ESPEC-
TRAL DE POTÊNCIA**

WESLEY REIS DA SILVA

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

ORIENTADOR: Prof. Dr. Rausley Adriano Amaral de Souza

Silva, Wesley Reis da

S586a

Análise Comparativa de Técnicas de Sensoriamento Espectral baseadas em Redes Neurais, Matriz de Covariância e Densidade Espectral de Potência / Wesley Reis da Silva.– Santa Rita do Sapucaí, 2023.

63 p.

Orientador: Prof. Dr. Rausley Adriano Amaral de Souza

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

Inclui bibliografia.

1. Sensoriamento espectral cooperativo 2. Rádio cognitivo 3. Redes neurais convolucionais 4. WCFCPSC 5. Ruído dinâmico 6. Mestrado em Telecomunicações. I. Souza, Rausley Adriano Amaral de II. Instituto Nacional de Telecomunicações – INATEL. III. Título.

CDU 621.39

FOLHA DE APROVAÇÃO

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

Prof. Dr. Rausley Adriano Amaral de Souza
INATEL

Prof. Dr. Luiz Carlos Branquinho Caixeta Ferreira
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO SUL
DE MINAS GERAIS, CAMPUS POÇOS DE CALDAS

Prof. Dr. Guilherme Augusto Barucke Marcondes
INATEL

Coordenador do Curso de Mestrado
Prof. Dr. Jose Marcos Camara Brito

*“Milagres só acontecem com as
pessoas que não desistem”*

Emporio Ivankov - One Piece

*Aos meus pais,
meus primeiros grandes professores.*

Agradecimentos

Gostaria de agradecer a todos que de alguma forma de ajudaram a chegar até aqui. Especialmente ao meu pai (Francisco), minha mãe (Lúcia) e minha namorada (Andreza) a qual foram os maiores incentivadores.

Gostaria de agradecer ao meu cunhado, Prof. Dr. Leandro Carvalho Bassotto por seus conselhos e ajudas nos trabalhos acadêmicos.

Agradeço também a meu orientador Prof. Dr. Rausley Adriano Amaral de Souza pelo apoio e orientações durante esta caminhada. A todos os professores por me auxiliar no crescimento profissional e pessoal durante estes anos.

Por fim, agradeço ao Instituto Nacional de Telecomunicações (INATEL) pelo suporte aos meus estudos durante a elaboração deste trabalho. Este trabalho foi parcialmente financiado pelo CNPq (Contratos N° 311470/2021-1 e 403827/2021-3), pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) (2021/06946-0) e pela RNP, com recursos do MCTIC, processo N° 01245.020548/2021-07, sob o projeto Brasil 6G do Centro de Referência em Radiocomunicações (CRR) do Instituto Nacional de Telecomunicações – Inatel, Brasil, e pela Huawei, sob o projeto Formação Avançada em Redes e Sistemas de Telecomunicações, contrato N° PPA6001BRA2303-2110257684.

Wesley Reis da Silva

Sumário

Sumário	x
Lista de Figuras	xi
Lista de Tabelas	xiii
Lista de Abreviaturas e Siglas	xv
Lista de Símbolos	xvii
Resumo	xix
Abstract	xxi
1 Introdução	1
1.1 Contextualização	1
1.2 Trabalhos Relacionados	4
1.3 Contribuições e Estrutura da Dissertação	4
1.4 Publicações	5
2 Sensoriamento Espectral Cooperativo	7
2.1 Sensoriamento Espectral como Teste de Hipótese Binário	7
2.2 Modelo do Sistema	8
2.3 Canal de Sensoriamento	8
2.4 GLRT	10
2.5 PRIDe e GID	11
2.6 CFCPSC	12
2.7 WCFCPSC	14
2.8 Redes Neurais Artificiais	16
2.8.1 VGG16	16
2.8.2 Inception	17
2.8.3 ResNet	18
2.8.4 DenseNet	19
2.8.5 EfficientNet	19
2.9 Análise de Complexidade	20
3 Sensoriamento Espectral Cooperativo sob Ruído Não Uniforme	21

3.1	Modelos de Ruído	21
3.2	Resultados Numéricos	22
4	Sensoriamento Espectral Cooperativo sob Ruído Não Uniforme e Dinâmico	25
4.1	Modelo de Ruído Dinâmico	25
4.2	Datasets	25
4.3	Redes Neurais	26
4.3.1	Pré-Processamento	26
4.3.2	Treinamento	27
4.3.3	Comparativo Entre Modelos	29
4.4	Resultados Numéricos	30
5	Conclusões e Trabalhos Futuros	33
5.1	Conclusões	33
5.2	Trabalhos Futuros	34
	Referências Bibliográficas	35

Lista de Figuras

1.1	Sensoriamento espectral cooperativo.	2
2.1	Ilustração do modelo 3D de canal com sombreamento espacialmente correlacionado.	9
2.2	Representação gráfica da SCM sob \mathcal{H}_0 e \mathcal{H}_1	12
2.3	DEPs hipotéticas do sinal dos UP (QPSK) e do sinal recebido nos USs (QPSK mais ruído).	13
2.4	Estrutura da VGG16	17
2.5	Estrutura da InceptionV3	17
2.6	Estrutura da ResNet	18
2.7	Estrutura da DenseNet	19
2.8	Estrutura da EfficientNetB0	20
3.1	Curvas ROCs das técnicas WCFCPSC, CFCPSC e GLRT sob os cenários definidos na Tabela 3.1.	24
4.1	Desempenho da DenseNet sob diferentes pré-processamentos dos dados de entrada.	27
4.2	Função de perda e acurácia da DenseNet no treinamento.	28
4.3	ROCs das RNAs DenseNet201, VGG16, ResNet152V2, InceptionV31 e EfficientNetB7.	30
4.4	ROCs sob diferente cenários conforme Tabela 4.1.	31
4.5	Gráfico da AUC versus o número de amostras coletadas por símbolo.	32

Lista de Tabelas

3.1	Cenários de sensoriamento.	23
4.1	Cenários de sensoriamento sob ruído não uniforme e dinâmico.	26

Lista de Abreviaturas e Siglas

2D	Bidimensional
3D	Tridimensional
3GPP	<i>(third generation partnership project)</i>
5G	Quinta geração
6G	Sexta geração
AUC	área sob a curva (<i>area under curve</i>)
AWGN	Ruído aditivo Gaussiano branco (<i>additive white Gaussian noise</i>)
CF	Centro de fusão
CFCPSC	Cancelamento cooperativo por divisão da densidade espectral de potência com dobramento circular (<i>circular folding cooperative power spectral density split cancellation</i>)
CNN	Redes neurais convolucionais (<i>convolutional neural networks</i>)
DFT	Transformada discreta de Fourier (<i>discrete Fourier transform</i>)
ED	Deteção de energia (<i>energy detection</i>)
FFT	Transformada rápida de Fourier (<i>fast Fourier transform</i>)
GID	Detector por índice de Gini (<i>Gini index detector</i>)
GLRT	Teste de máxima verossimilhança generalizado (<i>generalized likelihood ratio test</i>)
GPU	Unidade de processamento gráfico (<i>graphics processing unit</i>)
i.i.d.	Independente e identicamente distribuída
IoT	Internet das coisas (<i>Internet of things</i>)
LoS	Linha de visada (<i>line-of-sight</i>)
PRIDe	Detector por índice de Pietra-Ricci (<i>Pietra-Ricci index detector</i>)
DEP	Densidade espectral de potência
QPSK	<i>(quadrature phase-shift keying)</i>
RC	Rádio cognitivo
RNA	Rede neural artificial
ROC	Característica de operação do receptor (<i>receiver operating characteristic</i>)
SCM	Matriz de covariância amostral (<i>sample covariance matrix</i>)
SNR	Relação sinal-ruído (<i>signal-to-noise ratio</i>)
SP	Período de sensoriamento (<i>sensing period</i>)
UP	Usuário primário
US	Usuário secundário
WCFCPSC	Cancelamento cooperativo por divisão da densidade espectral de potência ponderada e com dobramento circular (<i>weighted circular folding co-</i>

operative power spectral density split cancellation)

Lista de Símbolos

$(\cdot)^\dagger$	Conjugado transposto de (\cdot)
d	Número de camadas convolucionais
D	Tamanho da janela de sobreposição
D_{dec}	Distância de decorrelação
$\mathbb{E}[\cdot]$	Valor esperado de (\cdot)
$\eta_u(n)$	n -ésima amostra de ruído AWGN coletada pelo u -ésimo RC
F_u^{full}	Potência total da banda analisada
$F_{u,\ell}$	Densidade de potência da ℓ -ésima banda do u -ésimo RC
$F'_u(n)$	Densidade espectral de potência instantânea do sinal amostrado
γ	Limiar de decisão
$h_u(n)$	n -ésima amostra de ganho do canal que afeta o u -ésimo RC
\mathcal{H}_0	Hipótese correspondente à ausência do sinal primário
\mathcal{H}_1	Hipótese correspondente à presença do sinal primário
$h_u^f(z)$	Ganho do canal referente ao desvanecimento multipercurso para o u -ésimo RC
$h_u^s(z)$	Ganho do canal referente ao sombreamento para o u -ésimo RC
L	Número de sub-bandas
λ	Autovalores da matriz de covariância amostral
M	Número de rádios cognitivos
m_ℓ	Tamanho espacial do mapa de recursos de saída da ℓ -ésima camada de uma rede convolucional
N	Número de amostra coletadas do sinal primário
n_ℓ	Número de canais da ℓ -ésima camada de uma rede convolucional
P_y	Potência do sinal recebido
P_d	Probabilidade de detecção
P_{fa}	Probabilidade de falso alarme
Pr	Probabilidade de um evento
r	Vetor formado pelo empilhamento das colunas da matriz \mathbf{R}
\mathbf{R}	Matriz de covariância amostral
r_ℓ^{avg}	Estatística de teste do CFCPSC para ℓ -ésima banda
$r_\ell^{\text{avg-w}}$	Estatística de teste do WFCPSC para ℓ -ésima banda
\bar{r}	Valor médio do vetor r
ρ	Fator de variação da dinamicidade do ruído
$s(n)$	Amostra discreta do sinal transmitido pelo usuário primário
s_ℓ	Tamanho espacial do filtro da ℓ -ésima camada de uma rede convolucional
σ^2	Potência do ruído

$\tilde{\sigma}^2$	Potência do ruído dinâmico
S'	Sombreamento que afeta o sinal recebido
T	Estatística de teste
T_{GLRT}	Estatística de teste do GLRT
T_{PRIDe}	Estatística de teste do PRIDe
$(\cdot)^T$	Transposto de (\cdot)
U	Número de rádios cognitivos
\mathcal{U}	Variável aleatória uniforme
w_ℓ	Ponderação da ℓ -ésima sub-banda
\mathbf{Y}	Matriz do contendo as amostras de sinais recebidos de todos rádios cognitivos
$y_u(n)$	n -ésima amostras do sinal recebido pelo u -ésimo RC
Z	Quantidade de derivações do modelo de canal com desvanecimento seletivo

Resumo

O algoritmo de cancelamento cooperativo por divisão da densidade espectral de potência com dobramento circular (*circular folding cooperative power spectral density split cancellation*, CFCPSC) é baseado em periodogramas e projetado para detectar sinais primários, via rádios cognitivos, no sensoriamento espectral cooperativo centralizado com fusão de dados. Suas principais vantagens são: baixa complexidade de implementação, robustez em cenários sob ruído não uniforme, além de se mostrar efetivo em cenários sob canais seletivos em frequência e/ou com sombreamento correlacionado. O algoritmo *weighted CFCPSC*, ou WCFCPSC, é a nova versão ponderada do CFCPSC com maior poder estatístico de detecção. Neste trabalho é realizada, primeiramente, a análise do desempenho da técnica WCFCPSC sob os cenários supracitados em comparação com o teste de razão de verossimilhança generalizada (*generalized likelihood ratio test*, GLRT) e seu antecessor CFCPSC. Posteriormente expandem-se as análises para outras técnicas de sensoriamento espectral cooperativo e centralizado com fusão de dados, sendo elas: detector de índice de Gini (*Gini index detector*, GID), detector de índice de Pietra-Ricci (*Pietra-Ricci index detector*, PRIDe) além de um modelo de rede neural artificial, a DenseNet. As simulações foram conduzidas em uma variedade de cenários, considerados canais seletivos em frequência, sombreamento espacialmente correlacionado, ruído uniforme e não uniforme e, também, ruído dinâmico. Os resultados evidenciaram a robustez e desempenho dos detectores WCFCPSC e DenseNet diante das situações propostas e variações no canal sensoriado.

Palavras-Chave: Sensoriamento espectral cooperativo, rádio cognitivo, redes neurais convolucionais, WCFCPSC, ruído dinâmico

Abstract

The CFCPSC (*circular folding cooperative power spectral density split cancellation*) is a periodogram-based algorithm designed to detect primary signals via cognitive radios, in centralized cooperative spectral sensing with data fusion. Its main advantages are: low implementation complexity, robustness in scenarios under non-uniform noise, in addition to being effective in scenarios under frequency-selective channels and/or with correlated shadowing. The weighted CFCPSC algorithm, or WCFCPSC, is the new weighted version of CFCPSC with greater statistical detection power. In this work, firstly, the analysis of the performance of the WCFCPSC technique under the aforementioned scenarios is carried out in comparison with GLRT (*generalized likelihood ratio test*) and its predecessor CFCPSC. Subsequently, the analyses are expanded to other cooperative and centralized spectral sensing techniques with data fusion, namely: GID (*Gini index detector*), PRIDe (*Pietra-Ricci index detector*) and an artificial neural network model called DenseNet. Simulations were conducted for a variety of scenarios, considering frequency-selective channels, spatially correlated shadowing, uniform and non-uniform noise, and also dynamic noise. The results showed the robustness and performance of the WCFCPSC and DenseNet detectors in the face of the proposed situations and variations in the sensed channel.

Keywords: Spectrum sensing, cognitive radio, convolutional neural networks, WCFCPSC, dynamic noise

Capítulo 1

Introdução

1.1 Contextualização

O espectro de frequências é um recurso valioso na área de comunicação sem fio. Porém, por limitações técnicas e políticas, apenas uma pequena porção pode ser utilizada, tornando-o escasso e caro. A expansão da demanda por novos serviços de comunicação é a principal razão para o problema da escassez espectral. Por isso, tal problema torna-se ainda mais evidente com os adventos da quinta geração (5G) e da sexta geração (6G) dos sistemas de comunicação e a Internet das coisas (*Internet of things*, IoT), pois preveem coexistência entre um enorme número de dispositivos transceptores [1], bem como novas aplicações [2]. Contudo, pesquisas recentes mostram que o espectro de frequências se encontra contraditoriamente subutilizado [3], já que faixas ociosas podem ser frequentemente encontradas em determinadas localizações geográficas e determinados períodos de tempo. A ineficiência do uso do espectro se deve especialmente à política de acesso fixo em vigor, que concede direito de uso exclusivo a usuários contratantes, também chamados de usuários primários (UPs), durante o período de tempo contratado.

Percebeu-se que uma mudança da atual política de acesso fixo para uma política de acesso dinâmico poderia reduzir conjuntamente a ineficiência no uso do espectro e a escassez espectral. Nessa nova política de acesso, o espectro, outrora exclusivo para UPs, tornar-se-ia compartilhado oportunisticamente com usuários não contratantes, ou usuários secundários (USs), desde que canais primários ociosos pudessem ser detectados. Logo, seria imperativo que USs fossem capazes de detectar oportunidades de acesso aos canais primários. Nesse contexto surgiu o conceito de sensoriamento espectral baseado em rádio cognitivo (RC). Um RC é então um dispositivo equipado com uma capacidade de cognição tal que o habilita a observar e inferir sobre o estado

de ocupação de um canal via sensoriamento dos sinais emitidos pelos UPs.

É inegável, então, a importância dos esforços de pesquisa direcionados às técnicas de sensoriamento espectral. Esses esforços são agora ainda mais importantes motivados pela aprovação, por parte da Agência Nacional de Telecomunicações (Anatel), de resolução [4] que atribui e destina faixas de radiofrequências de TV e aprova o Regulamento sobre Condições de Uso das Faixas de Radiofrequências de 54 MHz a 72 MHz, 174 MHz a 216 MHz, 470 MHz a 608 MHz e 614 a 698 MHz por dispositivos de espectro ocioso, mais conhecido como Regulamento de *TV White Spaces*. “O normativo regulamenta a aplicação dessa tecnologia, que permite designar para os serviços de telecomunicações, de forma dinâmica, radiofrequências destinadas à radiodifusão que não estejam autorizadas. Com isso, aumenta-se a eficiência de uso do espectro, recurso limitado, com vantagens características das faixas de frequência de TV, como longo alcance e tolerância a obstáculos” [4].

O sensoriamento espectral em sistemas de rádio cognitivo pode ser feito de forma cooperativa ou não cooperativa. Na abordagem não cooperativa, cada RC realiza o monitoramento do espectro de forma independente, sem compartilhar informações com outros RCs. Outra abordagem seria o sensoriamento cooperativo com fusão de dados, no qual vários RCs coletam informações de um canal e as enviam para um centro de fusão (CF), que calcula a estatística de teste e pode tomar uma decisão mais confiável sobre o estado de ocupação do canal, conforme ilustrado na Figura 1.1.

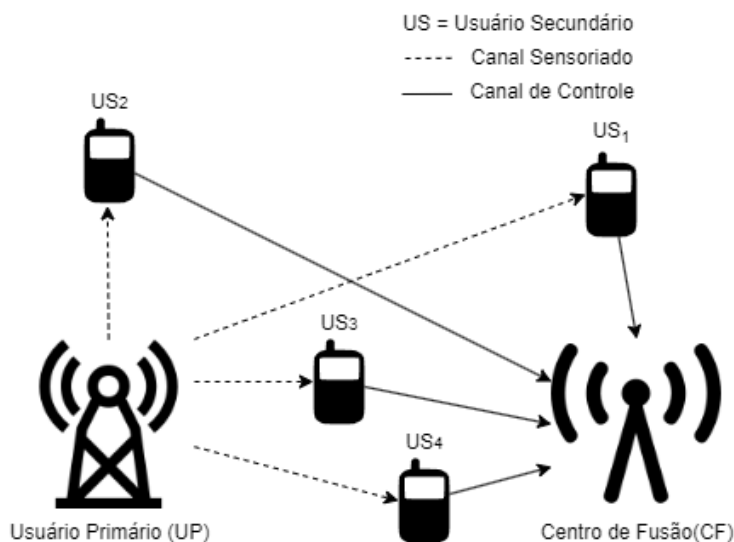


Figura 1.1: *Sensoriamento espectral cooperativo.*

Existem diversas técnicas utilizadas para o cálculo da estatística de teste. São exemplos bastante conhecidos as técnicas baseadas:

- No cálculo da energia do sinal recebido, detecção de energia (*energy detection*, ED).
- Nas propriedades da matriz de covariância amostral (*sample covariance matrix*, SCM), o detector por índice de Gini (*Gini index detector*, GID) [5], o detector por índice de Pietra-Ricci (*Pietra-Ricci index detector*, PRIDE) [6] e o teste de máxima verossimilhança generalizado (*generalized likelihood ratio test*, GLRT) [7].
- Na estimativa da densidade espectral de potência (DEP), o cancelamento cooperativo por divisão da densidade espectral de potência com dobramento circular (*circular folding cooperative power spectral density split cancellation*, CFCPSC) [8] e o cancelamento cooperativo por divisão da densidade espectral de potência ponderada e com dobramento circular (*weighted circular folding cooperative power spectral density split cancellation*, WCFCPSC) [9].

Além dos modelos estatísticos tradicionais anteriormente citados, outros modelos, ainda incipientes, são baseados em rede neural artificial (RNA) [10–12]. Com base nas amostras coletadas, esses modelos conseguem aprender a extrair características do sinal e utilizá-las para o processo de tomada de decisões, permitindo alcançar alta eficiência na detecção do UP. Em contrapartida, o desempenho desses modelos está atrelado a fatores não determinísticos, tais como arquitetura e configuração [13], além de requererem elevados recursos computacionais para execução e treinamento, de modo que a tarefa de encontrar RNAs que atinjam os melhores resultados para o objetivo proposto seja mais complexa.

Durante a análise do desempenho das técnicas de sensoriamento espectral, um fator importante a se atentar é o modelo de sistema utilizado no ensaio. Efeitos que afetem o canal sensoriado como presença e tipo de desvanecimento (*fading*), sombreamento (*shadowing*) e ruído, interferem diretamente no desempenho final de cada técnica. Quanto mais fiel ao cenário real é o modelo do sistema, mais complexo ele se torna e mais difícil é para os detectores identificarem a presença do UP.

Por isso, em função da influência dos efeitos do canal sobre o desempenho de um sistema de sensoriamento espectral e considerando a importância do sensoriamento espectral na otimização do uso do espectro, é conveniente estudar os desempenhos das técnicas sob tais circunstâncias, assim como avaliar o desempenho de novos modelos baseados em RNA.

1.2 Trabalhos Relacionados

Inicialmente, em [8] foi proposto o método CFCPSC. Uma técnica de sensoriamento espectral cooperativo que requer baixo custo computacional para sua execução e não necessita de informações acerca do sinal transmitido nem do ruído que afeta a transmissão para seu funcionamento, a chamada detecção cega. Os resultados reportados em [8] mostraram que o CFCPSC é robusto na detecção do UP mesmo sob diferentes potências de ruídos afetando os USs.

Posteriormente, uma evolução do CFCPSC foi proposta em [9], intitulada WCFCPSC. Essa nova versão aplica pesos às contribuições de cada sub-banda da DEP do sinal, no cálculo da estatística de teste. Favorecendo assim, as decisões tomadas por sub-bandas localizadas em regiões com maior relação sinal-ruído (*signal-to-noise ratio*, SNR), resultando em um maior poder estatístico de detecção. Entretanto, nesse trabalho não foi analisado o desempenho do WCFCPSC sob os mesmo cenários usados em [8].

Com o avanço da inteligência artificial, as técnicas de aprendizado de máquina (*machine learning*) são cada vez mais aplicadas na tarefa de sensoriar o espectro. Os autores em [14] citam diversos estudos que aplicaram aprendizado de máquina e aprendizado profundo (*deep learning*) na detecção de espectro. Os autores também realizam comparações de técnicas tradicionais do sensoriamento cooperativo com fusão de decisões; como as regras E, OU e majoritária com o desempenho de alguns detectores baseados em redes neurais convolucionais (*convolutional neural networks*, CNN) (LeNet, AlexNet e VGG-16), em que as redes convolucionais apresentam melhores desempenhos que as demais. Outros trabalhos, como em [15], também apontam as rede convolucionais como bons modelos de RNA a serem aplicadas no sensoriamento espectral.

1.3 Contribuições e Estrutura da Dissertação

Neste trabalho é realizada uma análise comparativa de desempenho das técnicas CFCPSC, WCFCPSC, GID, PRIDE, GLRT e RNA. Diversos cenários foram considerados, como canais seletivos em frequência, sombreamento espacialmente correlacionado, ruído uniforme e não uniforme, bem como ruído dinâmico. O objetivo final do trabalho é o de apresentar novas conclusões a respeito das técnicas avaliadas, contribuindo para o avanço do conhecimento na área de sensoriamento espectral e oferecendo informações valiosas para a escolha adequada das técnicas em diferentes situações.

As análises foram motivadas pelo potencial que o WCFCPSC apresentou em [9],

como sendo um detector robusto e com baixa complexidade mesmo sob cenários complexos. Assim como pelo desempenho apresentado dos modelos de CNN em comparação às técnicas tradicionais.

O restante do trabalho foi organizado da seguinte forma:

O Capítulo 2 define a decisão de ocupação dos canais dos UPs no sensoriamento espectral como um teste binário de hipóteses, bem como apresenta o modelo do sistema, incluindo o modelo de canal de sensoriamento e uma breve explicação a respeito das técnicas GLRT, GID, PRIDe, CFCPSC, WFCPSC e RNA.

O Capítulo 3 define o modelo de ruído não uniforme aplicado, assim como apresenta os resultados das comparações de desempenho das técnicas GLRT, CFCPSC e WFCPSC sob canal com seletividade em frequência, sombreamento e ruído não uniforme.

O Capítulo 4 expande as análises realizadas no capítulo anterior. Inicialmente, o modelo de ruído dinâmico que foi utilizado é definido. Na sequência, diversos modelos de RNA são avaliados na tarefa de detectar a presença do UP, a fim de que o melhor seja usado para comparações com outras técnicas tradicionais de sensoriamento de espectro. Finaliza-se o capítulo apresentando-se o resultado das simulações das técnicas GLRT, GID, PRIDe, WFCPSC e DenseNet sob os mesmo cenários já analisados, acrescido do ruído dinâmico.

Por fim, no Capítulo 5 são apresentadas as conclusões e propostas para trabalhos futuros.

1.4 Publicações

Os seguintes artigos foram produzidos como resultado das pesquisas relacionadas a este trabalho:

- ❶ **Análise Comparativa de Técnicas de Sensoriamento Espectral baseadas em Redes Neurais, Matriz de Covariância e Densidade Espectral de Potência.** Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, (SBrT). São José dos Campos 2023.
- ❷ **Desempenhos do Sensoriamento Espectral via Periodograma Ponderado sob Ruído não Uniforme e Canais Seletivos e com Sombreamento.** Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, (SBrT). Fortaleza 2021.

Capítulo 2

Sensoriamento Espectral Cooperativo

2.1 Sensoriamento Espectral como Teste de Hipótese Binário

No sensoriamento espectral, a decisão sobre o estado de ocupação de um canal do UP sob sensoriamento por um ou mais RCs, ou USs, pode ser modelada como um teste binário de hipóteses, \mathcal{H}_0 e \mathcal{H}_1 , sendo elas:

$$\begin{aligned}\mathcal{H}_0 &: \text{canal livre} \\ \mathcal{H}_1 &: \text{canal ocupado pelo UP.}\end{aligned}\tag{2.1}$$

O desempenho dessa decisão é comumente mensurado pela probabilidade de falso alarme, P_{fa} , e pela probabilidade de detecção, P_d , definidas como

$$\begin{aligned}P_{fa} &= \Pr\{\text{decisão} = \mathcal{H}_1 | \mathcal{H}_0\} = \Pr\{T > \gamma | \mathcal{H}_0\} \\ P_d &= \Pr\{\text{decisão} = \mathcal{H}_1 | \mathcal{H}_1\} = \Pr\{T > \gamma | \mathcal{H}_1\}.\end{aligned}\tag{2.2}$$

P_{fa} é a probabilidade de haver uma decisão em favor de \mathcal{H}_1 , dado que o canal está sob hipótese \mathcal{H}_0 (livre), o que é equivalente à hipótese da estatística de teste T ser maior que o limiar de decisão predefinido γ , ou seja $T > \gamma$, dado \mathcal{H}_0 . Já P_d é a probabilidade de haver uma decisão em favor de \mathcal{H}_1 , dado que o canal está de fato sob hipótese \mathcal{H}_1 (ocupado), o que é equivalente à possibilidade de $T > \gamma$, dado \mathcal{H}_1 . As análises de desempenho são geralmente realizadas graficamente por meio da curva característica de operação do receptor (*receiver operating characteristic*, ROC), que mapeia P_{fa} e P_d com a variação do limiar de decisão γ , bem como por meio da área sob a curva (*area under curve*, AUC). Vale ressaltar que o uso de AUCs como alternativa ao uso de ROCs nas análises de desempenho são especialmente úteis quando necessita-se

analisar diversos desempenhos muito próximos entre si e/ou que se cruzam em algum ponto do gráfico.

2.2 Modelo do Sistema

Seja uma rede secundária com U USs, cada um com uma única antena e coletando N amostras do sinal recebido a cada período de sensoriamento em determinado canal do UP. Seja também uma rede primária contendo apenas um transmissor primário. O objetivo do sensoriamento é decidir se o canal do UP está livre ou ocupado com base nas amostras de sensoriamento de cada US, a fim de prover acesso oportunista ao espectro. Seja $y_u(n)$ a n -ésima amostra recebida no u -ésimo US, com $u = 1, 2, \dots, U$ e $n = 1, 2, \dots, N$. Sob \mathcal{H}_0 ou \mathcal{H}_1 , tem-se

$$y_u(n) = \begin{cases} \eta_u(n) & ; \mathcal{H}_0 \\ \sum_{z=0}^{Z-1} h_u(z)s(n-z) + \eta_u(n) & ; \mathcal{H}_1 \end{cases} \quad (2.3)$$

tal que $\eta_u(n)$ e $s(n)$ representam a n -ésima amostra complexa de ruído aditivo Gaussiano branco (*additive white Gaussian noise*, AWGN), com média zero e variância σ^2 , e a n -ésima amostra complexa do sinal (*quadrature phase-shift keying*, QPSK) emitido pelo transmissor primário, respectivamente. A parcela $\sum_{z=0}^{Z-1} h_u(z)s(n-z)$ é o resultado da operação de convolução entre a n -ésima amostra do sinal do UP e a resposta ao impulso do canal de sensoriamento entre o transmissor primário e o u -ésimo US. A resposta ao impulso é variante no tempo e possui linha de atraso com Z derivações. Com $Z = 1$, $h_u(z)$ modela um canal com sombreamento e desvanecimento plano e lento, e com $Z > 1$ um canal com sombreamento e desvanecimento lento e seletivo em frequência [8].

2.3 Canal de Sensoriamento

Os canais de sensoriamento formados entre o UP e os USs levam em conta o modelo Rayleigh-lognormal proposto em [16]. Os ganhos dos Z percursos de propagação entre o transmissor primário e o u -ésimo US em (2.3), $h_u(z)$, $z = 0, 1, \dots, Z-1$, podem ser escritos como

$$h_u(z) = h_u^f(z) + h_u^s(z), \quad (2.4)$$

sendo $h_u^f(z)$ e $h_u^s(z)$ os valores dos ganhos de canal referentes ao desvanecimento multipercurso (*multipath fading*) e sombreamento (*shadowing*), respectivamente. Os Z ganhos de percurso podem ser organizados em um vetor $(\mathbf{h}_u^f)^\dagger \in \mathbb{C}^{Z \times 1}$, em que \dagger repre-

senta a operação conjugado transposto. Cada elemento deste vetor possui distribuição Gaussiana complexa independente e identicamente distribuída (i.i.d.), com média zero e variância unitária, i.e., $\mathbb{E}[\mathbf{h}_u^f (\mathbf{h}_u^f)^\dagger] = 1$, tal que $\mathbb{E}[\cdot]$ representa o operador esperança estatística. Os ganhos são mantidos constantes em um dado período de sensoriamento e variando entre um período e outro, simulando um canal com desvanecimento lento e seletivo em frequência. Já o vetor $(\mathbf{h}_u^s)^T \in \mathbb{C}^{Z \times 1}$, em que T indica operação de transposição, possui elementos idênticos, cujos módulos têm distribuição normal em escala logarítmica (*lognormal*) e fase com distribuição uniforme em $[0, 2\pi)$. Ressalta-se que estes elementos são idênticos porque representam o sombreamento sobre todos os ganhos de percurso do canal entre o transmissor primário e o u -ésimo US.

Os USs operam sob canais com sombreamento espacialmente correlacionado segundo o modelo tridimensional (3D) proposto em [16]. Esse modelo é baseado em *grid points*, como mostra a Figura 2.1(a), na qual o espaço tridimensional, com $K \times K \times K$ metros cúbicos, é a região de operação dos USs. Os *grid points* determinam os pontos onde a correlação é nula. Assim, USs localizados exatamente em diferentes *grid points* irão operar sob canais totalmente decorrelacionados. Por isso, a distância entre *grid points* adjacentes é chamada de distância de decorrelação (D_{dec}).




Figura 2.1: Ilustração do modelo 3D de canal com sombreamento espacialmente correlacionado.

A Figura 2.1(b) mostra uma versão ampliada de um dos cubos da Figura 2.1(a). Por meio dela, nota-se que o nível de correlação do sombreamento aumenta com o aumento de D_{dec} se os deslocamentos que separam dois ou mais USs forem menores que o aumento de D_{dec} . O oposto ocorre com a redução de D_{dec} se os deslocamentos

que separam dois ou mais USs forem menores que esta redução. A posição do u -ésimo US é determinada pelas coordenadas x_u , y_u e z_u em relação a um ponto específico do cubo em que se encontra. Na Figura 2.1(b), este ponto específico é o *grid point* A . No exemplo da Figura 2.1(b), os sombreamentos que afetam os sinais recebidos nos USs 1 e 2 possuem correlação não nula, já que ambos se encontram dentro do mesmo conjunto de *grid points* e suas coordenadas são inferiores as destes *grid points*. Cada *grid point* representa uma amostra Gaussiana de média zero e desvio padrão σ_{dB} , sendo esse o desvio padrão do sombreamento. Os pontos A, B, C, D, E, F, G e H , portanto, representam amostras Gaussianas dadas por $S_a, S_b, S_c, S_d, S_e, S_f, S_g$ e S_h , respectivamente.

A correlação espacial do sombreamento que afeta o u -ésimo US é produzida por meio de uma combinação linear associada aos 8 *grid points*, aos quais pertence esse US. Por exemplo, dados os *grid points* de A a H da Figura 2.1(b), uma amostra de sombreamento para o u -ésimo US é obtida como $S_u = [(A\tilde{x}'_u + B\tilde{x}_u)\tilde{y}'_u + (C\tilde{x}'_u + D\tilde{x}_u)\tilde{y}_u]\tilde{z}'_u + [(E\tilde{x}'_u + F\tilde{x}_u)\tilde{y}'_u + (G\tilde{x}'_u + H\tilde{x}_u)\tilde{y}_u]\tilde{z}_u$, em que $\tilde{x}_u = x_u/D_{dec}$, $\tilde{y}_u = y_u/D_{dec}$ e $\tilde{z}_u = z_u/D_{dec}$ são distâncias normalizadas em relação ao *grid point* de referência (*grid point* A), e $\tilde{x}'_u = 1 - \tilde{x}_u$, $\tilde{y}'_u = 1 - \tilde{y}_u$ e $\tilde{z}'_u = 1 - \tilde{z}_u$. Para que o desvio padrão de S_u seja igual a σ_{dB} , deve-se fazer a correção [16]

$$S'_u = \frac{S_u}{\sqrt{(1-2\tilde{x}_u+2\tilde{x}_u^2)(1-2\tilde{y}_u+2\tilde{y}_u^2)(1-2\tilde{z}_u+2\tilde{z}_u^2)}}, \quad (2.5)$$

sendo S'_u a variável Gaussiana final que representa a amostra de sombreamento que afeta o sinal recebido no u -ésimo US.

Nota-se que a correlação entre as amostras de sombreamento geradas pelo modelo apresentado são dependentes das coordenadas dos USs e do valor de D_{dec} . Vale ressaltar que com $z_u = 0$ este modelo 3D se converte no modelo bidimensional (2D) apresentado em [16].

2.4 GLRT

O GLRT é um teste estatístico aplicado a partir do cálculo dos autovalores da matriz de covariância, \mathbf{R} , das amostras do sinal recebido. No sensoriamento espectral cooperativo centralizado com fusão de dados, \mathbf{R} é computada no CF a partir da matriz de amostras recebidas, \mathbf{Y} , que contém as amostras enviadas por todos os USs em cooperação. Então, sejam as UN amostras complexas recebidas no CF organizadas na matriz $\mathbf{Y} \in \mathbb{C}^{U \times N}$, tal que $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_U]^T$, sendo $\mathbf{y}_u = [y_u(1), y_u(2), \dots, y_u(N)]^T$ um vetor contendo as N amostras coletadas pelo u -ésimo

US (vide Eq. (2.3)). A matriz de covariância amostral (*sample covariance matrix*, SCM) é dada por

$$\mathbf{R} = \mathbf{Y}\mathbf{Y}^\dagger/N, \quad \mathbf{R} \in \mathbb{C}^{U \times U}. \quad (2.6)$$

A estatística de teste do GLRT pode ser então calculada como

$$T_{\text{GLRT}} = \frac{\lambda_1}{\frac{1}{U} \sum_{i=1}^U \lambda_i}, \quad (2.7)$$

tal que $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{U-1} \geq \lambda_U$ são os autovalores da matriz \mathbf{R} organizados em ordem decrescente. Ou seja, a estatística de teste do GLRT é computada pela razão entre o máximo autovalor e a média dos autovalores da matriz de covariância amostral \mathbf{R} . A decisão de ocupação é obtida comparando-se T_{GLRT} com um limiar de decisão predefinido, γ . Decide-se em favor de \mathcal{H}_1 se $T_{\text{GLRT}} > \gamma$ e em favor de \mathcal{H}_0 caso contrário.

2.5 PRIDe e GID

O PRIDe é um detector utilizado no sensoriamento espectral cooperativo centralizado com fusão de amostras, baseado no índice de Pietra-Ricci (*Pietra-Ricci index*, *Hoover index*, *Robin Hood index* ou *Schutz index*). O índice de Pietra-Ricci é utilizado na economia e ciências sociais como medida de desigualdade. No contexto do sensoriamento espectral ele utiliza a desigualdade entre os elementos da SCM para detectar a presença do UP.

Sob a hipótese \mathcal{H}_0 os elementos fora da diagonal principal tendem a 0 enquanto os elementos da diagonal principal tendem aos valores das potências dos ruídos, comportamento que não ocorre sob \mathcal{H}_1 . Dessa forma, é possível distinguir os cenários, dado que a desigualdade nos elementos da SCM sob \mathcal{H}_0 é maior que \mathcal{H}_1 . A Figura 2.2 apresenta a SCM de forma gráfica nas hipóteses \mathcal{H}_0 e \mathcal{H}_1 , no qual se pode facilmente notar a distinção do comportamento da SCM.

A estatística de teste do detector PRIDe é calculada como

$$T_{\text{PRIDe}} = \frac{\sum_{i=1}^{U^2} |r_i|}{\sum_{i=1}^{U^2} |r_i - \bar{r}|}, \quad (2.8)$$

em que U é o número de RCs cooperantes, r é o vetor formado pelo empilhamento (concatenação) das colunas da SCM e \bar{r} é o valor médio de todos os elementos, calculado por

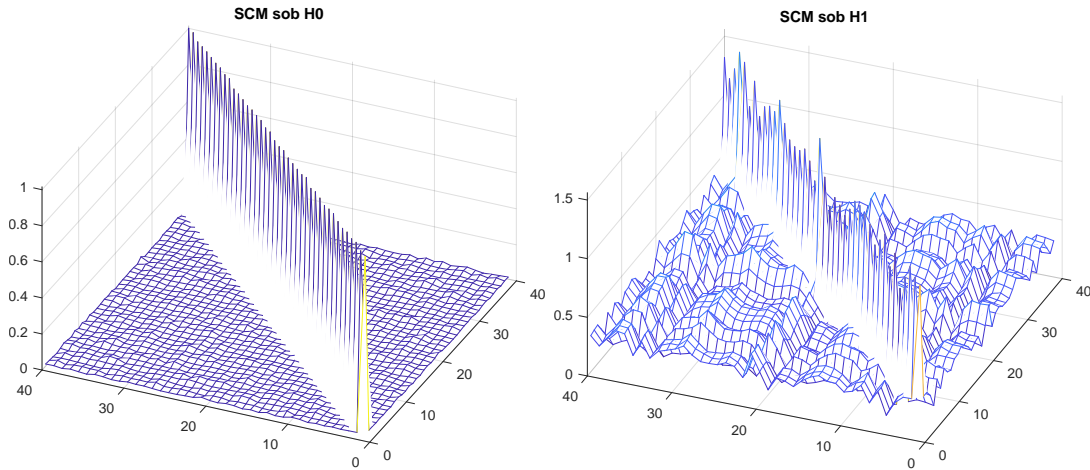


Figura 2.2: Representação gráfica da SCM sob \mathcal{H}_0 e \mathcal{H}_1

$$\bar{r} = \frac{1}{U^2} \sum_{i=1}^{U^2} r_i. \quad (2.9)$$

O GID, assim como PRIDE, também é um detector utilizado no sensoriamento espectral cooperativo centralizado com fusão de amostras que utiliza das desigualdades da SCM para detecção do UP. Entretanto, o GID utiliza-se do índice de Gini (*Gini index*, *Gini coefficient* ou *Gini Ratio*) como base para o cálculo de sua estatística de teste.

A estatística de teste do detector GID é calculada como

$$T_{\text{GID}} = \frac{\sum_{i=1}^{U^2} |r_i|}{\sum_{i=1}^{U^2} \sum_{j=1}^{U^2} |r_i - r_j|}, \quad (2.10)$$

em que U é o número de RCs cooperantes e r é o vetor formado pelo empilhamento (concatenação) das colunas da SCM.

2.6 CFCPSC

O CFCPSC [8] é um algoritmo baseado na estimativa da DEP, ou periodograma, das amostras do sinal recebido durante o sensoriamento realizado por cada US. A título de ilustração, a Figura 2.3 mostra uma DEP hipotética teórica de um sinal QPSK, representativa de uma DEP do sinal transmitido por determinado UP, e esta mesma DEP somada com um certo nível de potência de ruído na recepção, a fim de representar a DEP do sinal recebido em um dado US.

No algoritmo CFCPSC a DEP, estimada via amostras do u -ésimo US, é dividida

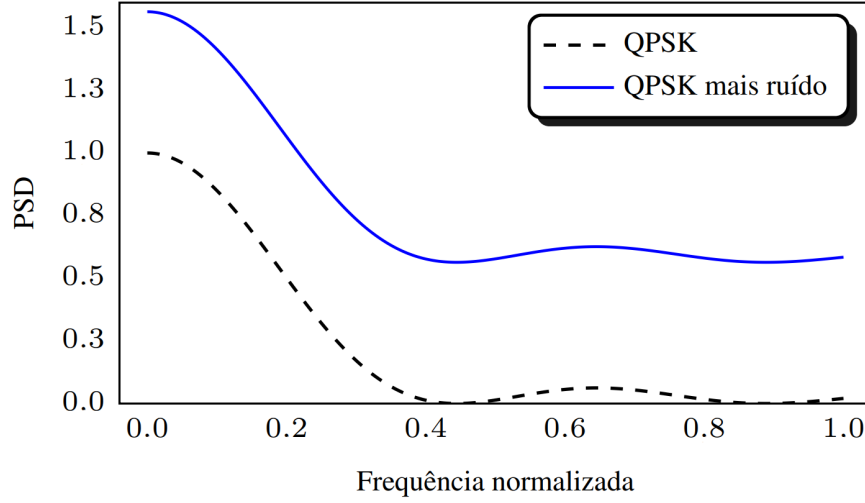


Figura 2.3: *DEPs hipotéticas do sinal dos UP (QPSK) e do sinal recebido nos USs (QPSK mais ruído).*

em L sub-bandas e, após a combinação dos dados de todos os USs, uma decisão sobre a presença do sinal do UP é tomada em relação à ℓ -ésima sub-banda, com $\ell = 1, 2, \dots, L$. Esta decisão é obtida por meio do cálculo da ℓ -ésima estatística de teste, dada por r_ℓ^{avg} . A decisão final de ocupação do canal do UP sensoriado é tomada após a combinação das decisões individuais em relação a cada sub-banda. O maior poder estatístico do CFCPSC, portanto, é proporcional à maior concentração da DEP nas sub-bandas localizadas em baixas frequências. Em outras palavras, as decisões sobre a presença do sinal do UP nestas sub-bandas são mais precisas, quando comparadas às decisões tomadas em sub-bandas localizadas em altas frequências, melhorando o desempenho da decisão final. Isso porque essas sub-bandas localizam-se em regiões de maior SNR em relação às sub-bandas localizadas mais à direita da DEP (Imaginar a divisão da DEP da Figura 2.3 em L sub-bandas de mesmo tamanho pode ser útil para identificar as regiões de maior SNR). Os passos a seguir podem ser usados para descrever o algoritmo CFCPSC no CF:

1. Estime a DEP de $y_u(n)$ em (2.3) via transformada discreta de Fourier (*discrete Fourier transform*, DFT) como

$$F'_u(n) = \frac{1}{N} |\text{DFT}\{y_u(n)\}|^2; \quad (2.11)$$

2. Realize o dobramento circular de $F'_u(n)$ como

$$F_u(n) = \begin{cases} \frac{F'_u(1) + F'_u(N/2 + 1)}{2}, & n = 1 \\ \frac{F'_u(n) + F'_u(N - n + 2)}{2}, & n = 2, 3, \dots, N; \end{cases} \quad (2.12)$$

3. Divida $F_u(n)$ em L sub-bandas, com $V = N/(2L)$ amostras cada, e então calcule a quantidade

$$F_{u,\ell} = \sum_{n=1}^V F_u((\ell - 1)V + n) \quad (2.13)$$

na ℓ -ésima sub-banda, $\ell = 1, 2, \dots, L$;

4. Calcule a energia total do sinal proveniente do u -ésimo US via

$$F_u^{\text{full}} = \sum_{n=1}^{N/2} F_u(n); \quad (2.14)$$

5. Calcule

$$r_{u,\ell} = F_{u,\ell}/F_u^{\text{full}} \quad (2.15)$$

para a ℓ -ésima sub-banda referente ao u -ésimo US;

6. Calcule a média de $r_{u,\ell}$ em relação a todos os USs na ℓ -ésima sub-banda, resultando nas estatísticas de teste r_ℓ^{avg} , ou seja

$$r_\ell^{\text{avg}} = \frac{1}{U} \sum_{u=1}^U r_{u,\ell}; \quad (2.16)$$

7. Compare r_ℓ^{avg} com um limiar de decisão γ predefinido e tome a decisão de ocupação em relação à ℓ -ésima sub-banda como \mathcal{H}_0 se $r_\ell^{\text{avg}} < \gamma$, ou \mathcal{H}_1 se $r_\ell^{\text{avg}} > \gamma$;
8. Tome a decisão de ocupação do canal do UP como \mathcal{H}_0 se todas as decisões por sub-banda forem em favor de \mathcal{H}_0 ; ou \mathcal{H}_1 se pelo menos uma das decisões por sub-banda for em favor de \mathcal{H}_1 .

2.7 WCFCPSC

O WCFCPSC [9] é a versão ponderada do algoritmo CFCPSC que possui maior poder estatístico de detecção. A única diferença entre eles é a proposta para o esquema de ponderação que concede maior peso às estatísticas de teste das sub-bandas localizadas nas regiões de maior SNR da DEP do sinal recebido (vide Figura 2.3, curva “QPSK mais ruído”). Conseqüentemente, o algoritmo WCFCPSC é computado com os mesmos Passos 1, 2, 3, 4, 5 e 8 do CFCPSC. O Passo 6, porém, é modificado a fim de que a estatística de teste da ℓ -ésima sub-banda, r_ℓ^{avg} , seja ponderada pelo peso

$$w_\ell = \frac{L - \ell + 1}{L}. \quad (2.17)$$

A ℓ -ésima estatística de teste ponderada é então dada por

$$r_\ell^{\text{avg-w}} = w_\ell r_\ell^{\text{avg}}, \quad (2.18)$$

em que o fator $1/U$, usado no cálculo de r_ℓ^{avg} , pode ser suprimido ou incorporado em w_ℓ , já que esta constante não altera o desempenho. No Passo 7, substitui-se r_ℓ^{avg} por $r_\ell^{\text{avg-w}}$. Assim o algoritmo do WCFCPSC pode se descrever como:

1. Estime a DEP de $y_u(n)$ em (2.3) via DFT como

$$F'_u(n) = \frac{1}{N} |\text{DFT}\{y_u(n)\}|^2; \quad (2.19)$$

2. Realize o dobramento circular de $F'_u(n)$ como

$$F_u(n) = \begin{cases} \frac{F'_u(1)+F'_u(N/2+1)}{2}, & n = 1 \\ \frac{F'_u(n)+F'_u(N-n+2)}{2}, & n = 2, 3, \dots, N; \end{cases} \quad (2.20)$$

3. Divida $F_u(n)$ em $2L$ sub-bandas, com $V = N/(2L)$ amostras cada, e então calcule a quantidade

$$F_{u,\ell} = \sum_{n=1}^V F_u((\ell-1)V+n) \quad (2.21)$$

na ℓ -ésima sub-banda, $\ell = 1, 2, \dots, L$;

4. Calcule a energia total do sinal proveniente do u -ésimo US via

$$F_u^{\text{full}} = \sum_{n=1}^{N/2} F_u(n); \quad (2.22)$$

5. Calcule

$$r_{u,\ell} = F_{u,\ell}/F_u^{\text{full}} \quad (2.23)$$

para a ℓ -ésima sub-banda referente ao u -ésimo US;

6. Calcule a média de r_ℓ na ℓ -ésima sub-banda, resultando nas estatísticas de teste

$$r_\ell^{\text{avg-w}} = w_\ell \sum_{u=1}^U r_{u,\ell}, \quad (2.24)$$

com $w_\ell = \frac{L-\ell+1}{L}$;

7. Compare $r_\ell^{\text{avg-w}}$ com um limiar de decisão γ predefinido e tome a decisão de ocupação em relação à ℓ -ésima sub-banda como \mathcal{H}_0 se $r_\ell^{\text{avg-w}} < \gamma$, ou \mathcal{H}_1 se

$$r_{\ell}^{\text{avg-w}} > \gamma;$$

8. Tome a decisão de ocupação do canal do UP como \mathcal{H}_0 se todas as decisões por sub-banda forem em favor de \mathcal{H}_0 ; ou \mathcal{H}_1 se pelo menos uma das decisões por sub-banda for em favor de \mathcal{H}_1 .

Nota-se que (2.17) caracteriza-se por um esquema de pesos com decaimento linear à medida que o valor de ℓ aumenta. Por exemplo, se $L = 5$, então $w_{\ell} = [1; 0.8; 0.6; 0.4; 0.2]$ para $\ell = 1, 2, \dots, 5$, respectivamente. Por isso, considerando que o sinal primário é determinístico, QPSK, e portanto possui DEP com formato semelhante ao mostrado na Figura 2.3, então (2.18) favorece os valores de r_{ℓ}^{avg} correspondentes às sub-bandas com maior SNR, enquanto penaliza os valores correspondentes à cauda da DEP do sinal recebido, região em que a SNR do sinal recebido é menor. Por este motivo o WCFCPSC possui maior poder estatístico de detecção que o CFCPSC.

2.8 Redes Neurais Artificiais

Existem inúmeros tipos de RNAs, cada uma possuindo seus atributos e aplicações específicos. As redes convolucionais ficaram bem conhecidas por seus desempenhos em tarefas de reconhecimento de imagem, mas estudos também mostraram que esses modelos apresentam uma boa atuação no processo de sensoriamento espectral [10–12]. Por isso, esse modelo foi escolhido para este trabalho.

No Capítulo 4 são avaliados alguns modelos de redes convolucionais, a fim de escolher o que apresenta o melhor desempenho na tarefa do sensoriamento espectral. Os modelos que foram avaliados são: VGG16 [17], Inception [18], ResNet [19], DenseNet [20] e a EfficientNet [21]. As seções a seguir apresentam brevemente os modelos citados.

2.8.1 VGG16

O VGG16 é um modelo de rede neural convolucional, proposto em 2015, composto por dezesseis camadas com pesos, sendo treze camadas de convoluções e três camadas totalmente conectadas, como mostra a Figura 2.4. Seu diferencial está no aumento da profundidade da rede utilizando camadas convolucionais com *kernels* (filtros convolucionais) pequenos, permitindo assim um aprendizado mais detalhado dos dados.

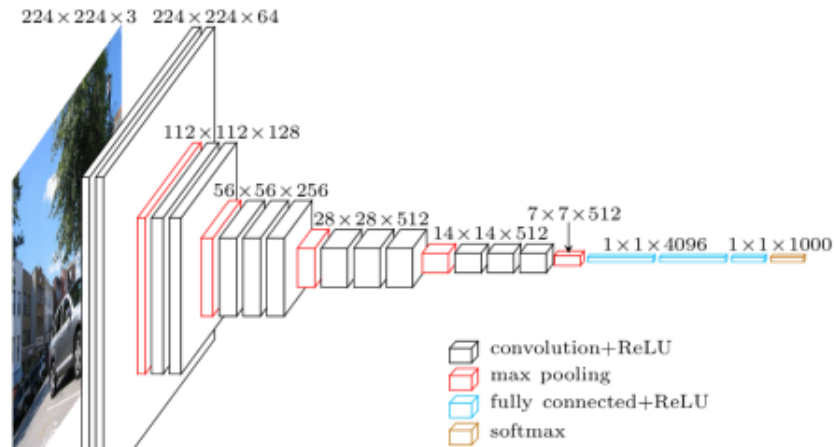


Figura 2.4: Estrutura da VGG16 [22].

2.8.2 Inception

O modelo de rede neural Inception, também conhecido como GoogLeNet, é um modelo de rede convolucional projetado para ser eficiente no uso de recursos computacionais. Sua idealização foi baseada na dificuldade de escolher o tamanho do *kernel* para as convoluções, pois um dado de entrada pode possuir suas informações distribuídas globalmente, sendo preferido um *kernel* maior; ou informações distribuídas localmente, no qual um *kernel* menor é privilegiado. A fim de solucionar esse problema, a Inception utiliza de blocos que combinam filtros de convolução com diferentes tamanhos, como pode ser visto na Figura 2.5.




Figura 2.5: Estrutura da InceptionV3 [23].

2.8.4 DenseNet

Densely Connected Convolutional Networks ou DenseNet são redes neurais convolucionais que utilizam de conexões densas para conectar as camadas da rede. São semelhantes as ResNets por também possuírem atalhos entre camadas a fim de solucionar problemas de dissipação do gradiente. Seu diferencial é que todas as camadas recebem como entrada as saídas das anteriores, como pode ser observado na Figura 2.7




Figura 2.7: Estrutura da DenseNet [20].

2.8.5 EfficientNet

Redes convolucionais podem ser escaladas de diversas formas, sendo aumentar arbitrariamente o número de camadas e/ou a largura da rede as maneiras mais usuais. Geralmente necessitando de ajustes manuais e não garantido uma melhora no desempenho. EfficientNet é uma arquitetura de rede neural combinada com um método de escalonamento baseado em um coeficiente composto, que permite ampliar os modelos de redes convolucionais com melhor precisão e eficiência.

A arquitetura base da EfficientNet, apresentada na Figura 2.8, é chamada de EfficientNetB0. Os demais membros da família, EfficientNetB1 a EfficientNetB7, são obtidos aplicando o método de escalonamento sob o modelo base.




Figura 2.8: Estrutura da *EfficientNetB0* [24].

2.9 Análise de Complexidade

A complexidade computacional tanto para o GID quanto para o PRIDE é dominada pela tarefa de se calcular a SCM, a qual é $\mathcal{O}(NU^2)$ [6], em que N é o número de amostras coletadas e U o número de RCs. Acrescido da necessidade de cômputo da SCM, o GLRT necessita realizar o cômputo dos autovalores da SCM, acrescentando uma complexidade de $\mathcal{O}(U^3)$ [6] à execução dessa técnica. Para o WCFCPSC, a operação mais custosa é a estimativa da DEP, que possui complexidade $\mathcal{O}(N \log D)$ [25], sendo D o tamanho da janela de sobreposição utilizada. Já para as rede neurais convolucionais, a complexidade computacional para cálculo da estatística de teste de uma rodada de sensoriamento é dada por [26] $\mathcal{O}\left(\sum_{\ell=1}^d n_{\ell-1} s_{\ell}^2 n_{\ell} m_{\ell}^2\right)$, em que d o número de camadas convolucionais que existe na rede (profundidade da rede), n_{ℓ} o número de canais da ℓ -ésima camada, s_{ℓ} é o tamanho espacial do filtro e m_{ℓ} o tamanho espacial do mapa de recursos de saída. Desta maneira, pelas expressões apresentadas, é direto concluir que RNAs possuem uma maior complexidade computacional para a tomada de decisões.

Capítulo 3

Sensoriamento Espectral Cooperativo sob Ruído Não Uniforme

Este capítulo apresenta as configurações das simulações, definição do ruído não uniforme e os resultados numéricos das simulações das técnicas GLRT, CFCPSC e WCFCPSC sob os cenários de canal seletivo, sombreamento e ruído não uniforme.

3.1 Modelos de Ruído

Os cenários abordados nesse capítulo utilizam dois tipos de ruído: o ruído uniforme e o não uniforme.

Diversos fatores influenciam na potência de ruído que afeta um RC. Fatores como temperatura, condições de operação do receptor, posição da antena e interferência eletromagnética de outras fontes são alguns exemplos. O modelo mais simples de ruído adotado neste trabalho, o ruído uniforme, não leva em consideração esses fatores. Assim, admite-se que a potência do ruído que afeta todos os RC é a mesma e constante durante toda a simulação. O ruído uniforme pode ser considerado um modelo não realista, já que no mundo real os RC estão dispersos em diferentes localizações e sob diferentes condições de operação. Entretanto, é importante a análise neste cenário dado ser esse um ambiente, a princípio, de desempenho ótimo sob o ponto de vista da investigação do impacto da potência de ruído. O modelo de ruído não-uniforme considera que as particularidades de cada RC influenciam de forma diferente a potência do ruído. Desta forma, a potência do ruído que perturba cada RC é diferente, porém constante para toda a simulação.

3.2 Resultados Numéricos

As simulações¹ foram feitas em Matlab com 50.000 eventos de Monte Carlo, e a atividade do transmissor do UP foi simulada como uma variável aleatória de Bernoulli, com 50% do tempo em estado inativo, para cômputo de falsos alarmes, e 50% em estado ativo, para cômputo de detecções.

Os demais parâmetros utilizados nas simulações foram:

- Sensoriamento realizado por $U = 6$ RCs;
- Amostras enviadas para o CF por meio de um canal de controle perfeito (livre de erros);
- Potência do ruído uniforme

$$\sigma_u^2 = 1, \forall u; \quad (3.1)$$

- Potência do ruído não uniforme

$$[\sigma_1^2; \sigma_2^2; \dots; \sigma_6^2] = [0.8; 0.9; 0.95; 1.1; 0.85; 1.15]; \quad (3.2)$$

- UP transmitindo sinal QPSK gerado com amostras i.i.d. a cada período de sensoriamento;
- Taxa de amostragem de 4 amostras por símbolo;
- Cada RC coletando 40 símbolos, resultando em $N = 160$ amostras;
- Potência ajustada para

$$P_y = \frac{10^{\text{SNR}/10}}{U} \sum_{u=1}^U \sigma_u^2 \quad (3.3)$$

a fim de manter a SNR média desejada de -10 dB.

- Adotou-se $L = 5$ sub-bandas para ambos, CFCPSC e WCFCPSC;
- Para cada canal de sensoriamento considerou-se Z ganhos de percursos i.i.d., sendo:
 - $Z = 1$ para canal plano e lento;
 - $Z = 4$ para canal seletivo em frequência;
 - Resposta ao impulso no formato exponencial com ganhos médios iguais a $[1; 0.464; 0.215; 0.1]$.
- Sombreamento:
 - A área de operação dos USs de $K \times K \times K$ metros cúbicos, com $K = 60$;

¹Código disponível em <https://github.com/wesleyreis1808/codigo-dissertacao-mestrado>

- As coordenadas dos USs, x_u , y_u e z_u , variaram uniformemente entre $[0, K]$ metros a cada período de sensoriamento;
- Processo de sombreamento i.i.d. entre um período de sensoriamento e outro, com desvio padrão $\sigma_{dB} = 4$;
- Distância de decorrelação $D_{dec} = 30$ metros;

A Figura 3.1 mostra as curvas ROCs e seus respectivos valores de AUCs ao se utilizar as técnicas WCFCPSC, CFCPSC e GLRT nos 4 cenários adotados em [8]. Estes cenários são formados de acordo com as configurações dos canais de sensoriamento e do ruído na recepção conforme mostra a Tabela 3.1.

Tabela 3.1: *Cenários de sensoriamento.*

Cenário	Ruído	Seletivo	Sombreamento
1	uniforme	–	–
2	uniforme	✓	–
3	uniforme	✓	✓
4	não uniforme	✓	✓

Primeiramente, em [8], nos Cenários 1 e 2, ou seja, USs operando sob ruído uniforme e/ou sob canais seletivos, o GLRT superou significativamente o CFCPSC. Já no Cenário 3, USs sob ruído uniforme, canais seletivos e com sombreamento correlacionado, o CFCPSC obteve desempenhos ligeiramente superiores ao GLRT. Por fim, com os USs sob canais seletivos, com sombreamento correlacionado e sob ruído não uniforme, o CFCPSC superou consideravelmente o GLRT em [8]. O melhor desempenho do CFCPSC pode ser visto no Cenário 4 da Figura 3.1. Veja, no entanto, que o WCFCPSC superou o CFCPSC em todos os cenários, bem como superou o GLRT nos cenários em que este havia superado o CFCPSC. Observando as degradações de desempenhos provocadas pela mudança dos Cenários de 1 ao 4, nota-se que o GLRT possui maior sensibilidade a canais seletivos, com sombreamento correlacionado e, especialmente, sob ruído não uniforme. A maior robustez do CFCPSC e WCFCPSC nestes cenários é facilmente percebida, bem como a superioridade do WCFCPSC em todos eles.

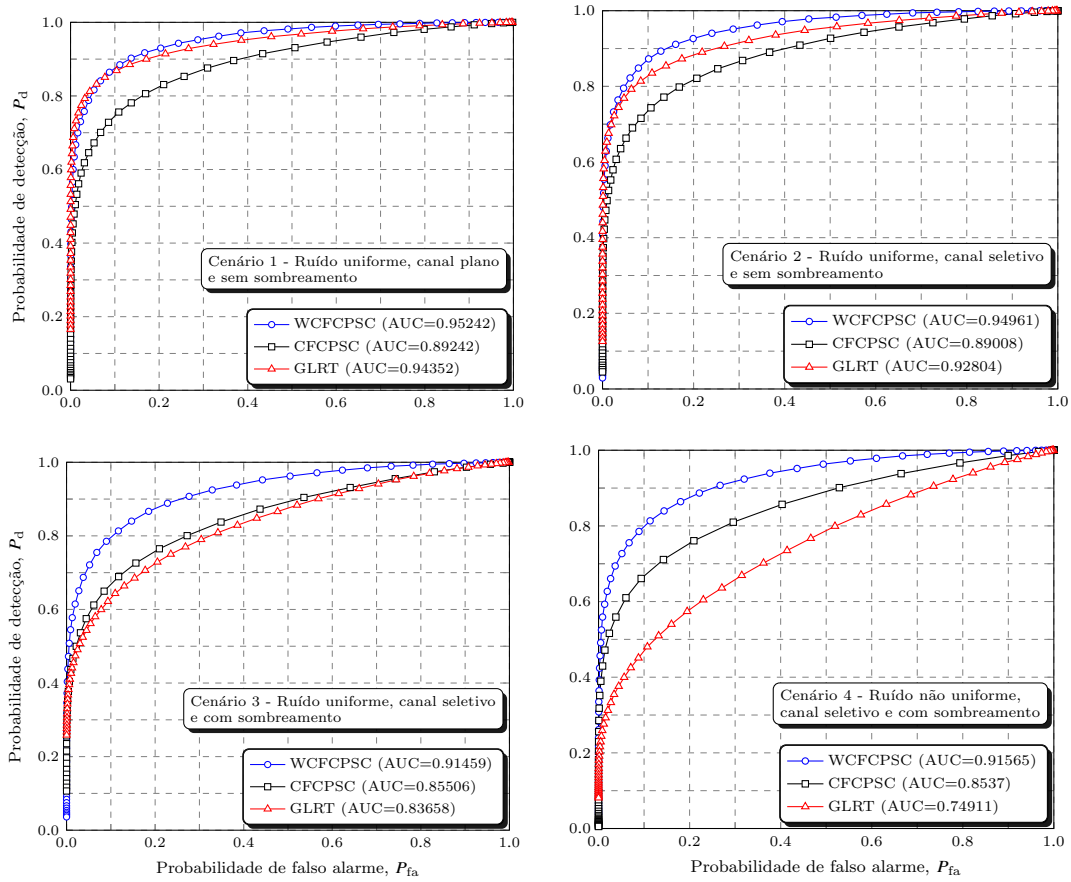


Figura 3.1: Curvas ROCs das técnicas WFCPSC, CFCPSC e GLRT sob os cenários definidos na Tabela 3.1.

Capítulo 4

Sensoriamento Espectral Cooperativo sob Ruído Não Uniforme e Dinâmico

4.1 Modelo de Ruído Dinâmico

Além dos modelos de ruído citados na Seção 3.1, os cenários utilizados neste capítulo também contam com ruído dinâmico. O ruído dinâmico simula a variação da estimativa da potência de ruído que afeta os RCs. Desta forma os RCs operam sob potência de ruído variante no tempo.

Quando aplicado o ruído dinâmico, a potência do ruído é uma variável aleatória $\tilde{\sigma}_u^2$ uniformemente distribuída entre $\sigma_u^2(1 - \rho)$ e $\sigma_u^2(1 + \rho)$, ou seja,

$$\tilde{\sigma}_u^2 \sim \mathcal{U}[\sigma_u^2(1 - \rho), \sigma_u^2(1 + \rho)], \quad (4.1)$$

sendo $\rho > 0$ o fator de variação da dinamicidade do ruído e σ_u^2 as potências de ruído apresentadas nas equações (3.1) e (3.2) para os cenários de ruído uniforme e não uniforme, respectivamente.

Adotou-se o valor de $\rho = 0.25$ para os cenários que consideram variação na potência de ruído.

4.2 Datasets

Para as simulações e treinamento da RNA foram gerados 6 *datasets* seguindo os cenários descritos na Tabela 4.1. Os parâmetros utilizados na construção dos dataset foram:

Tabela 4.1: *Cenários de sensoriamento sob ruído não uniforme e dinâmico.*

Cenário	Canal Seletivo	Ruído	Sombreamento
1	✓	uniforme	—
2	✓	uniforme	✓
3	✓	não uniforme	✓
4	✓	uniforme e dinâmico	—
5	✓	uniforme e dinâmico	✓
6	✓	não uniforme e dinâmico	✓

- 30000 atividades do transmissor do UP, 50% sob a hipótese \mathcal{H}_0 e 50% sob a hipótese \mathcal{H}_1 ;
- UP transmitindo sinal QPSK;
- SNR = -10 dB;
- Sensoriamento realizado por $U = 6$ RCs;
- Cada RC um coletando $N = 160$ amostras;
- Taxa de amostragem de 4 amostras por símbolo;
- Canal de controle perfeito (livre de erros);
- Para o canal seletivo em frequência:
 - $Z = 4$ ganhos de percursos;
 - Resposta ao impulso no formato exponencial com ganhos médios iguais a $[1; 0.464; 0.215; 0.1]$.
- Sombreamento seguindo o modelo apresentado em [16]:
 - Desvio padrão da variável aleatória do sombreamento de $\sigma_{\text{dB}} = 4$ dB;
 - Distância de decorrelação $D_{\text{dec}} = 30$ metros;
 - Dimensão das laterais do espaço tridimensional $K = 60$ metros.

4.3 Redes Neurais

4.3.1 Pré-Processamento

O desempenho final do modelo está atrelado aos dados utilizados durante o treinamento, de forma que etapas de pré-processamento do *dataset* podem impactar significativamente no desempenho. Diante disso, foram analisados os comportamentos do modelo após o treinamento sob três entradas de dados diferentes, sendo elas:

- Sem pré-processamento, ou seja, diretamente com o uso das amostras coletadas;

- Calculando-se a SCM, mesma informação base utilizada pelo GID, PRIDe e GLRT, ou seja, as entradas da RNA são SCMs;
- Calculando-se a transformada rápida de Fourier (*fast Fourier transform*, FFT) das amostras do *dataset*, assim as entradas da RNA são valores da densidade espectral de potência dos sinais coletados, semelhante ao realizado no primeiro passo do algoritmo do WCFCPSC.

A Figura 4.1 apresenta o gráfico comparativo do desempenho da RNA DenseNet no sensoriamento espectral cooperativo sob canal seletivo, sombreamento e ruído não uniforme, utilizando os três tipos de entradas de dados. Pode-se notar que todos obtiveram bons resultados, AUC acima de 0.9, porém o pré-processamento usando FFT obteve melhor resultado que os demais. Diante disso, o pré-processamento usando FFT foi o escolhido para ser usado nas simulações.

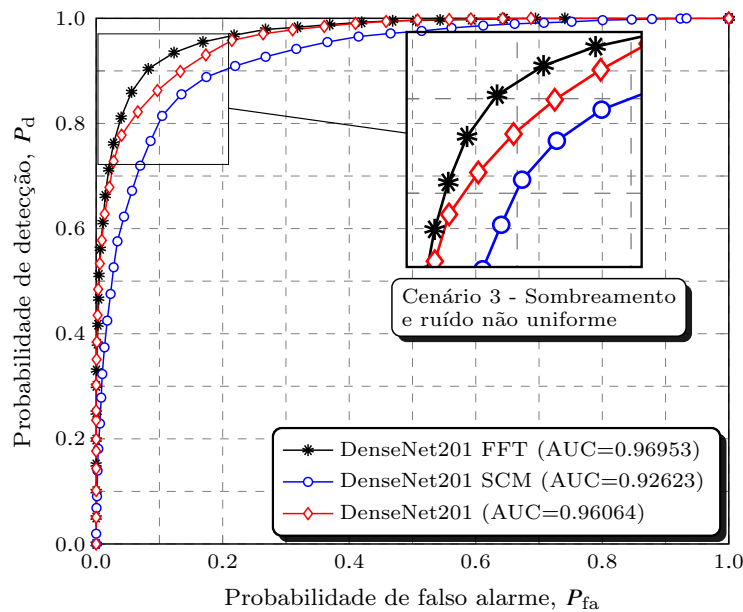


Figura 4.1: Desempenho da DenseNet sob diferentes pré-processamentos dos dados de entrada.

4.3.2 Treinamento

Os treinamentos das RNAs foram realizados em linguagem Python utilizando a biblioteca TensorFlow e os modelos de RNA convolucionais disponíveis na biblioteca Keras. O hardware utilizado no treinamento dos modelos consiste em uma unidade de processamento gráfico (*graphics processing unit*, GPU) NVIDIA RTX A4000 com 16GB de memória dedicada e 6144 CUDA Cores, um processador Intel Xeon Silver 4314 e 256GB de memória RAM.

O *dataset* escolhido para os treinamentos considera o cenário de canal seletivo em frequência, sombreamento espacialmente correlacionado, ruído não uniforme e dinâmico, sendo este fracionado em três partes: treinamento, teste e validação, na porcentagem de 60%, 20% e 20%, respectivamente.

Os parâmetros utilizados no treinamento foram:

- A duração do treinamento foi configurada para 50 épocas, podendo este ser cesado antecipadamente caso ocorram 5 épocas sem evolução na acurácia sobre o conjunto de dados de validação (*val_acc*);
- Camadas decisórias compostas por camadas densas com 50 e 20 neurônios com função de ativação ReLu e uma última camada densa com 2 neurônios utilizando a função Softmax;
- Métrica de treinamento utilizada foi a acurácia;
- Otimizador Adam;
- Tamanho de lote de 32 amostras.

Ademais, a cada época de treinamento, caso houvesse melhora na *val_acc* os pesos do modelo eram salvos, para que ao final do treinamento o melhor conjunto de pesos fosse utilizado.

A Figura 4.2 apresenta os gráficos de função de perda e da acurácia do modelo DenseNet durante o treinamento. Pode-se perceber que a partir da 5ª época de treinamento o modelo começa a sofrer sobre-ajuste (*overfitting*), no qual há melhora no desempenho do modelo para os dados de treinamento, visível na melhora da acurácia e redução das perdas, que não se reflete nos dados de validação. Dessa forma, treinamento para na 10ª época devido às 5 épocas de paciência adotada, de forma que, os pesos utilizados são os da 5ª época de treinamento.




Figura 4.2: Função de perda e acurácia da DenseNet no treinamento.

A função Softmax utilizada no final das camadas decisórias do modelo tem a finalidade de padronizar os sinais de saída da rede, produzindo valores no intervalo de 0 a 1 para cada neurônio de saída, cuja soma resulte em 1. Desse modo, pode-se interpretar a saída dos neurônios como $T_{\mathcal{H}_0}$ e $T_{\mathcal{H}_1}$, indicador de hipótese \mathcal{H}_0 e \mathcal{H}_1 , respectivamente. Assim, pode-se decidir pela ocupação ou não do canal por meio da regra

$$\begin{array}{c} \mathcal{H}_1 \\ T_{\mathcal{H}_0} \leq T_{\mathcal{H}_1} \\ \mathcal{H}_0 \end{array} \quad (4.2)$$

Para gerar a gráfico da ROC, é necessário comparar os indicadores com diferentes limiares de decisão, sendo necessário incluir essa comparação à regra de decisão. Dado que $T_{\mathcal{H}_0} = 1 - T_{\mathcal{H}_1}$ pode-se reescrever a regra de decisão como

$$\mathcal{H}_0 \begin{cases} T_{\mathcal{H}_0} < \gamma \\ T_{\mathcal{H}_1} > 1 - \gamma \end{cases} \quad e \quad \mathcal{H}_1 \begin{cases} T_{\mathcal{H}_0} > \gamma \\ T_{\mathcal{H}_1} < 1 - \gamma \end{cases}, \quad (4.3)$$

e as equações de P_d e P_{fa} podem ser descritas como

$$\begin{aligned} P_{fa} &= \Pr\{\text{decisão} = \mathcal{H}_1 | \mathcal{H}_0\} = \Pr\{T_{\mathcal{H}_0} > \gamma | \mathcal{H}_0\} = \Pr\{T_{\mathcal{H}_1} < 1 - \gamma | \mathcal{H}_0\} \\ P_d &= \Pr\{\text{decisão} = \mathcal{H}_1 | \mathcal{H}_1\} = \Pr\{T_{\mathcal{H}_0} > \gamma | \mathcal{H}_1\} = \Pr\{T_{\mathcal{H}_1} < 1 - \gamma | \mathcal{H}_1\}. \end{aligned} \quad (4.4)$$

4.3.3 Comparativo Entre Modelos

O desempenho de uma RNA depende de vários fatores independentes, entre eles a arquitetura da rede, configuração do treinamento, inicialização dos pesos e dataset. Devido à complexidade desses fatores e à natureza não linear das RNAs, não é possível determinar previamente seu resultado ou quais características serão aprendidas. Portanto, a prática mais comum é experimentar diversos modelos e/ou configurações de treinamento diferentes e comparar seus resultados, com o intuito de encontrar o melhor modelo para um problema.

A fim de escolher um modelo de RNA para comparação com as técnicas tradicionais de sensoriamento espectral, as redes DenseNet201, VGG16, ResNet152V2, InceptionV31 e EfficientNetB7 foram treinadas e avaliadas na tarefa de detecção do UP. Para essa comparação, o Cenário 3 (Tabela 4.1) foi utilizado.

A Figura 4.3 apresenta o gráfico com as curvas ROCs das RNAs avaliadas, bem como seus respectivos valores de AUCs. Pode-se perceber que o DenseNet201 apresentou o melhor resultado dentre os modelos analisados, portanto, ele foi escolhido

para as simulações.

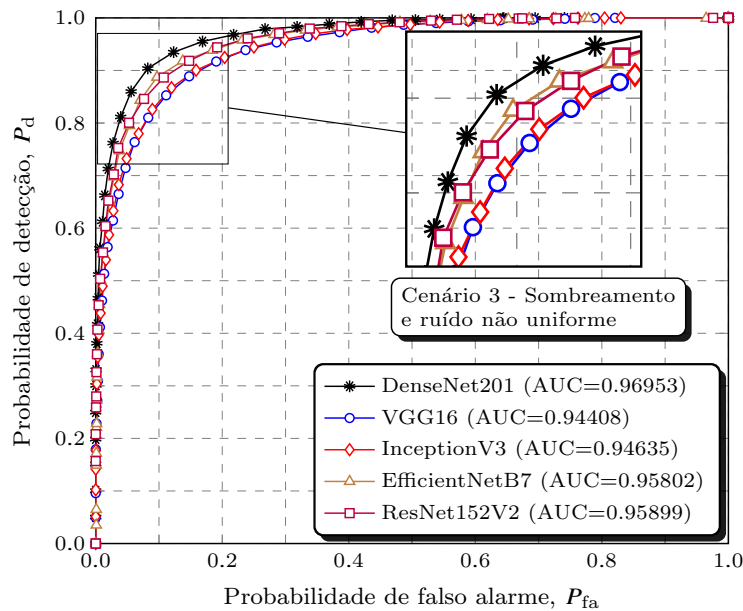


Figura 4.3: ROCs das RNAs DenseNet201, VGG16, ResNet152V2, InceptionV31 e Eficient-NetB7.

4.4 Resultados Numéricos

Os gráficos da Figura 4.4 apresentam os desempenhos¹, na forma de curvas ROC e valores de AUCs, das técnicas DenseNet, WCFCPSC, PRIDe, GID e GLRT nos 6 cenários descritos na Tabela 4.1, sem a presença de ruído dinâmico, nos Cenários 1, 2 e 3, e com a presença de ruído dinâmico, nos Cenários 4, 5 e 6. Adotou-se $L = 5$ sub-bandas para o cálculo da estatística de teste do WCFCPSC.

Primeiramente pode-se notar que a técnica GLRT é bastante sensível a canais com sombreamento, ruído não uniforme e ruído dinâmico, conforme pode ser visto pela queda no desempenho, i.e. menores valores de AUC, comparando-se os Cenários 1 com 2, 2 com 3 e 3 com 6, respectivamente. A técnica GID apresentou o pior desempenho em 5 dos 6 cenários testados. As técnicas GID e PRIDe mostraram-se mais sensíveis ao efeito do canal seletivo com sombreamento, visível na degradação do desempenho comparando os Cenários 1 com 2 e 4 com 5, mas robustos quanto a ruído não uniforme (Cenários 2 com 3 e 5 com 6) e dinâmico (Cenários 2 com 5 e 3 com 6). Nota-se que o WCFCPSC é uma técnica robusta nos diversos cenários testados, mantendo-se o valor da AUC sempre acima da 0.92.

¹Código disponível em <https://github.com/wesleyreis1808/codigo-dissertacao-mestrado>

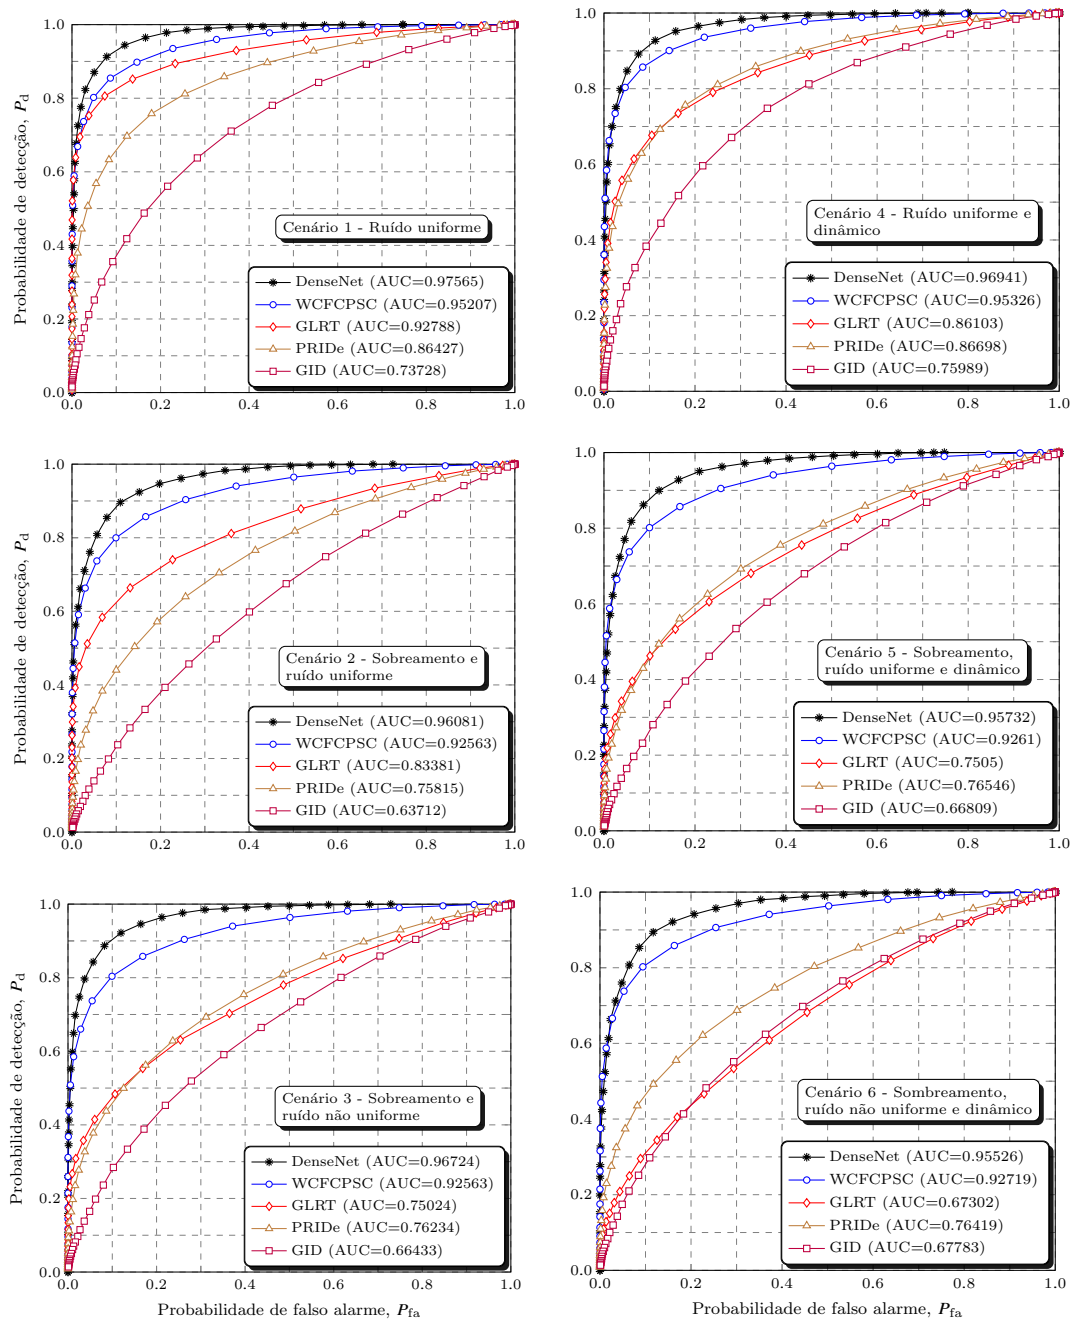


Figura 4.4: ROCs sob diferente cenários conforme Tabela 4.1.

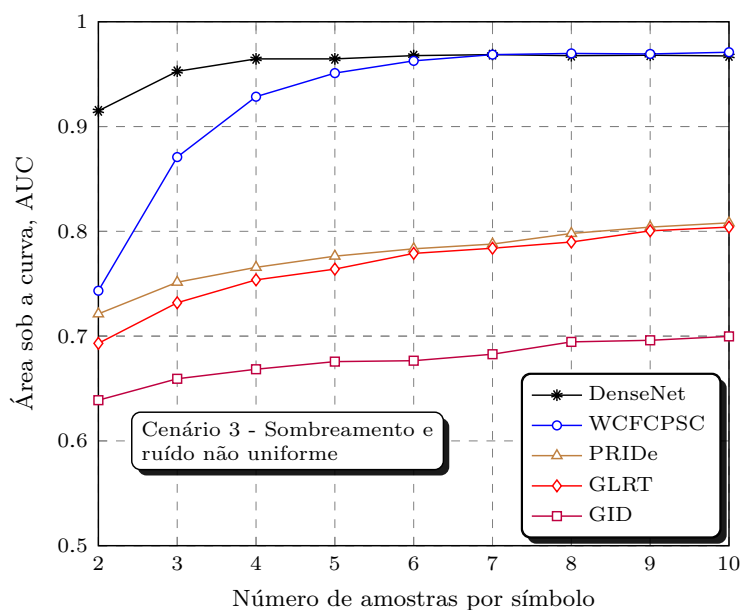


Figura 4.5: Gráfico da AUC versus o número de amostras coletadas por símbolo.

Já a técnica de sensoriamento utilizando-se uma RNA DenseNet mostrou-se superior ao WCFCPSC e a todas as demais técnicas em todos os cenários, sendo ligeiramente superior nos cenários 1 e 4, comparando-se com o WCFCPSC, e com superioridade mais evidente nos cenários 2, 3, 5 e 6. A pouca variabilidade no desempenho da RNA nos cenários avaliados explicita a robustez da técnica quanto aos efeitos do canal com sombreamento, ruído não uniforme e dinâmico.

O desempenho de todas as técnicas é impactado diretamente pelo número de amostras coletadas por símbolo. Esse comportamento é especialmente importante na análise de desempenho da técnica WCFCPSC, dado que essa técnica tem seu desempenho atrelado à concentração da DEP do sinal [9]. Esta concentração é controlada pelo número de amostras coletadas por símbolo. A Figura 4.5 apresenta o desempenho na forma de AUC das técnicas para diferentes valores do número de amostras coletadas por símbolo, análise realizada especificamente para o Cenário 3. Como era de se esperar, todas as técnicas apresentam um aumento de desempenho à medida que o número de amostras por símbolo aumenta. Entretanto, observa-se uma saturação no desempenho à medida que esse número amostras torna-se elevado. Notoriamente, a técnica WCFCPSC é a mais impactada. Ainda mais importante é verificar que o desempenho do WCFCPSC iguala-se ao desempenho de uma RNA DenseNet a partir de 7 amostras por símbolo e ultrapassa ligeiramente o desempenho da técnica concorrente quando se utilizam 10 amostras por símbolo.

Capítulo 5

Conclusões e Trabalhos Futuros

5.1 Conclusões

Este trabalho teve como objetivo analisar o desempenho do WCFCPSC e de outras técnicas de sensoriamento espectral cooperativo e centralizado com fusão de amostras sob cenários de canais de sensoriamento seletivos em frequência, com sombreamento espacialmente correlacionado e afetado por ruído não uniforme e dinâmico. A análise foi motivada pelos resultados de [9], em que o WCFCPSC apresentou o melhor desempenho na comparação realizada, assim como uma baixa complexidade de implementação.

Inicialmente, como expansão do trabalho [9], realizou-se a análise do desempenho das técnicas WCFCPSC, CFCPSC e GLRT sob os mesmos cenários utilizados em [8], ou seja, sensoriamento espectral cooperativo e centralizado, com fusão de dados, sob ruído não uniforme e canais seletivos em frequência e com sombreamento espacialmente correlacionado. Os desempenhos do WCFCPSC e CFCPSC foram comparados com os desempenhos obtidos pelo bem conhecido teste GLRT e mostram o melhor desempenho do WCFCPSC até mesmo nos casos em que a versão original CFCPSC obteve desempenhos inferiores aos obtidos pelo GLRT. Além disso, os desempenhos do GLRT mostraram-se consideravelmente mais sensíveis a ruído não uniforme.

Após a análise inicial, introduziram-se às comparações novos cenários que adicionavam ruído dinâmico às amostras coletadas, a fim de simular variação temporal da potência de ruído que afeta cada RC. Modelos de RNAs convolucionais foram avaliados na tarefa de sensoriamento do espectro, considerando diferentes etapas de pré-processamento. Ao final, o modelo DenseNet utilizando o pré-processamento FFT foi escolhido para incorporar as análises. As estatísticas de testes GID e PRIDe também foram incluídas. A escolha por essas técnicas se basearam no fato delas serem técnicas

cegas (não precisam de informações *a priori* para tomada de decisão) que, em alguns casos, possuem complexidade de implementação ainda menores que o WCFCPSC.

Finalmente, foram comparados os desempenhos de cinco detectores (GID, PRIDe, WCFCPSC, GLRT e DenseNet) no sensoriamento espectral cooperativo e centralizado com fusão de dados, sob canais seletivos em frequência, sombreamento espacialmente correlacionado, ruído não uniforme e dinâmico.

Os resultados evidenciaram duas importantes conclusões. Primeiramente, uma RNA, aqui especificamente uma DenseNet, é capaz de realizar a tarefa do sensoriamento espectral de forma a suplantiar o desempenho de técnicas tradicionais baseadas no cálculo de estatísticas de testes. Isto abre um campo de pesquisa para a busca de novas configurações de RNAs no sentido de se melhorar o processo de detecção de oportunidades espectrais. Por outro lado, processos baseados em RNAs carregam como desvantagem a necessidade da etapa de treinamento e o elevado custo computacional no processo de decisão. Em segundo lugar é importante destacar que o WCFCPSC mais uma vez mostra-se superior a diversas técnicas tradicionais. Mesmo quando o WCFCPSC é inferior em termos de desempenho em comparação a uma RNA, isto ocorre apenas em cenários em que o número de amostras coletadas por símbolo é baixo. Desta forma, o WCFCPSC tem a vantagem de possuir um custo computacional menor, além de não necessitar da etapa de treinamento.

5.2 Trabalhos Futuros

Como pode ser percebido nas comparações, variações nos cenários podem impactar de forma relevante o desempenho das técnicas de sensoriamento espectral. Evidenciando se os modelos são robustos ou sensíveis às alterações. Assim, estender as análises realizadas, a outros cenários, torna-se relevante. Por exemplo, poder-se-ia adotar outros modelos de canal de sensoriamento, como o modelo 3D desenvolvido pelo (*third generation partnership project, 3GPP*), que leva em conta perda de percurso (*path-loss*) e probabilidade de linha de visada (*line-of-sight, LoS*) e/ou canal de controle imperfeito, bem como modelos de seletividade em frequência mais realistas. De forma semelhante, avaliar também a extensão da habilidade de generalização dos modelos de RNAs sob esses outros cenários.

Além disso, sugere-se para estudos futuros que outros modelos de aprendizado de máquina sejam analisados, a fim de encontrar modelos com melhores desempenhos e menores custos computacionais.

Referências Bibliográficas

- [1] L. Chettri and R. Bera, “A comprehensive survey on Internet of things (IoT) toward 5G wireless systems,” *IEEE Internet Things J.*, vol. 7, no. 1, pp. 16–32, 2020.
- [2] J. M. C. Brito, L. L. Mendes, and J. G. S. Gontijo, “Brazil 6G project - an approach to build a national-wise framework for 6G networks,” in *2020 2nd 6G Wireless Summit (6G SUMMIT)*, 2020, pp. 1–5.
- [3] M. A. McHenry, P. A. Tenhula, D. McCloskey, D. A. Roberson, and C. S. Hood, “Chicago spectrum occupancy measurements & analysis and a long-term studies proposal,” in *Proc. of the first int. workshop on Technology and policy for accessing spectrum*. ACM, 2006, p. 1.
- [4] “Resolução ANATEL N° 747,” Conselho director Anatel, 10/2021, 2021, Access in April 2023. [Online]. Available: <https://www.gov.br/anatel/pt-br/assuntos/noticias/anatel-publica-resolucao-para-uso-de-espectro-ocioso>
- [5] D. A. Guimarães, “Gini index inspired robust detector for spectrum sensing over ricean channels,” *Electronics Letters*, vol. 55, no. 12, pp. 713–714, 2019.
- [6] D. A. Guimarães, “Pietra-ricci index detector for centralized data fusion cooperative spectrum sensing,” *IEEE Trans. Veh. Technol.*, vol. 69, no. 10, pp. 12 354–12 358, 2020.
- [7] B. Nadler, F. Penna, and R. Garelo, “Performance of eigenvalue-based signal detectors with known and unknown noise level,” in *2011 IEEE Int. Conf. on Commun. (ICC)*, 2011, pp. 1–5.
- [8] R. C. D. V. Bomfin, R. A. A. de Souza, and D. A. Guimarães, “Circular folding cooperative power spectral density split cancellation algorithm for spectrum sensing,” *IEEE Commun. Lett.*, vol. 21, no. 2, pp. 250–253, 2017.
- [9] L. S. Costa, D. A. Guimarães, E. P. Frigieri, and R. A. A. de Souza, “Weighted circular folding cooperative power spectral density split cancellation algorithm,” *IEEE Trans. Veh. Technol.*, vol. 70, no. 1, pp. 1062–1066, 2021.

- [10] Z. Chen, Y.-Q. Xu, H. Wang, and D. Guo, “Deep STFT-CNN for spectrum sensing in cognitive radio,” *IEEE Commun. Lett.*, vol. 25, no. 3, pp. 864–868, 2021.
- [11] J. Xie, J. Fang, C. Liu, and X. Li, “Deep learning-based spectrum sensing in cognitive radio: A CNN-LSTM approach,” *IEEE Commun. Lett.*, vol. 24, no. 10, pp. 2196–2200, 2020.
- [12] Z. Chen, D. Guo, and J. Zhang, “Deep learning for cooperative spectrum sensing in cognitive radio,” in *2020 IEEE 20th International Conference on Communication Technology (ICCT)*, 2020, pp. 741–745.
- [13] M. Adil, R. Ullah, S. Noor, and N. Gohar, “Effect of number of neurons and layers in an artificial neural network for generalized concrete mix design,” *Neural Computing and Applications*, vol. 34, no. 11, pp. 8355–8363, Jun. 2022.
- [14] Y. Tan and X. Jing, “Cooperative spectrum sensing based on convolutional neural networks,” *Applied Sciences*, vol. 11, no. 10, 2021. [Online]. Available: <https://www.mdpi.com/2076-3417/11/10/4440>
- [15] S. Solanki, V. Dehalwar, and J. Choudhary, “Deep learning for spectrum sensing in cognitive radio,” *Symmetry*, vol. 13, no. 1, 2021. [Online]. Available: <https://www.mdpi.com/2073-8994/13/1/147>
- [16] R. C. D. V. Bomfin and R. A. A. de Souza, “A new spatially correlated shadowed channel model with cognitive radio application,” in *2015 IEEE 81st Veh. Technol. Conf. (VTC Spring)*, 2015, pp. 1–5.
- [17] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv:1409.1556*, 2014.
- [18] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 2818–2826.
- [19] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” *CoRR*, vol. abs/1512.03385, 2015. [Online]. Available: <http://arxiv.org/abs/1512.03385>
- [20] G. Huang, Z. Liu, L. V. D. Maaten, and K. Q. Weinberger, “Densely connected convolutional networks,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Los Alamitos, CA, USA: IEEE Computer Society, jul 2017, pp. 2261–2269.
- [21] M. Tan and Q. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” in *Proceedings of the Intern. Conf. on Machine Learning*, ser. Proceedings of Machine Learning Research, vol. 97. PMLR, 2019, pp. 6105–

6114.

- [22] T. Sugata and C. Yang, “Leaf app: Leaf recognition with deep convolutional neural networks,” *IOP Conference Series: Materials Science and Engineering*, vol. 273, p. 012004, 11 2017.
- [23] Google, “Advanced guide to inception v3,” 2023, [Online; accessed September, 2023]. [Online]. Available: <https://cloud.google.com/tpu/docs/inception-v3-advanced>
- [24] M. Tan and Q. V. Le, “Efficientnet: Improving accuracy and efficiency through automl and model scaling,” May 2019, [Online; accessed September, 2023]. [Online]. Available: <https://blog.research.google/2019/05/efficientnet-improving-accuracy-and.html?m=1>
- [25] J. Proakis and D. Manolakis, *Digital Signal Processing: Principles, algorithms, and applications*, 3rd ed. Pearson Education, Inc., 1995, ch. Power Spectrum Estimation, p. 919–920.
- [26] K. He and J. Sun, “Convolutional neural networks at constrained time cost,” 2014. [Online]. Available: <https://arxiv.org/abs/1412.1710>

