



UNIVERSIDADE
ESTADUAL DE LONDRINA

AISLAN GABRIEL HERNANDES

**OTIMIZAÇÃO E APRENDIZADO EM REDES DE RÁDIO
COGNITIVO COM ELEVADO NÚMERO DE ANTENAS**

Londrina
2022

AISLAN GABRIEL HERNANDES

**OTIMIZAÇÃO E APRENDIZADO EM REDES DE RÁDIO
COGNITIVO COM ELEVADO NÚMERO DE ANTENAS**

**OPTIMIZATION AND LEARNING IN COGNITIVE RADIO
NETWORKS WITH A HIGH NUMBER OF ANTENNAS**

Tese apresentada ao Programa de Doutorado Associado em Engenharia Elétrica da UEL/UTFPR-CP como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica.

Orientador: Prof. Dr. Taufik Abrão -
Departamento de Engenharia Elétrica -
Universidade Estadual de Londrina - UEL.

Londrina
2022

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UEL

Hernandes, Aislan Gabriel.

Otimização e Aprendizado em Redes de Rádio Cognitivo com Elevado Número de Antenas / Aislan Gabriel Hernandez. - Londrina, 2022.
122 f. : il.

Orientador: Prof. Dr. Taufik Abrão.

Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual de Londrina, Centro de Tecnologia e Urbanismo, Programa de Pós-Graduação em Engenharia Elétrica, 2022.

Inclui bibliografia.

1. Rádio Cognitivo - Tese. 2. Sensoriamento Espectral - Tese. 3. Rede Neural Convolutiva - Tese. 4. Múltiplas Antenas Massivas - Tese. I. Abrão, Prof. Dr. Taufik . II. Universidade Estadual de Londrina. Centro de Tecnologia e Urbanismo. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

CDU 62

AISLAN GABRIEL HERNANDES

OTIMIZAÇÃO E APRENDIZADO EM REDES DE RÁDIO COGNITIVO COM ELEVADO NÚMERO DE ANTENAS

Tese apresentada ao Programa de Doutorado Associado em Engenharia Elétrica da UEL/UTFPR-CP como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica.

BANCA EXAMINADORA

Orientador: Prof. Dr. Taufik Abrão
Departamento de Engenharia Elétrica
Universidade Estadual de Londrina - UEL

Prof. Dr. Fabrício Braga Soares de Carvalho
Departamento de Engenharia Elétrica
Universidade Federal da Paraíba/CEAR -
UFPB

Prof. Dr. Glauber Gomes de Oliveira Brante
Departamento Acadêmico de Eletrotécnica
Universidade Tecnológica Federal do Paraná
- Curitiba - UTFPR/CTB

Prof. Dr. José Carlos Marinello Filho
Departamento de Engenharia Elétrica
Universidade Tecnológica Federal do Paraná
- Cornélio Procópio - UTFPR/CP

Prof. Dr. Mario Lemes Proença Jr.
Departamento de Ciência da Computação
Universidade Estadual de Londrina - UEL

Londrina, 29 de junho de 2022.

AGRADECIMENTOS

Meus agradecimentos ao Prof. Dr. Taufik Abrão por sua orientação nos últimos anos. À minha família pelo apoio durante todo este tempo. A todos os membros do Laboratório de Telecomunicações e Processamento de Sinais da UEL que contribuíram direta ou indiretamente para o aperfeiçoamento deste trabalho de tese. À banca julgadora deste trabalho pelos comentários e sugestões que contribuíram para a melhoria do texto final. Por fim, mas não menos importante, à Fundação Araucária, governo do Paraná, pelo apoio financeiro durante todo desenvolvimento deste trabalho.

“Todo o nosso conhecimento começa com os sentidos, prossegue para o entendimento e termina com a razão. Não há nada maior do que a razão.”

Immanuel Kant

RESUMO

Neste trabalho de tese, desenvolvemos uma análise de parâmetros e otimização do desempenho do sensoriamento espectral cooperativo (*cooperative spectrum sensing*, CSS) baseado no consenso médio distribuído (*distributed average consensus*, DAC), levando-se em consideração a topologia da rede, representado por matrizes de adjacência em redes de rádio cognitivo *ad hoc*. O desempenho do CSS é analisado pelas probabilidades de detecção, de falso alarme e de erro; além do limiar de decisão (*threshold*) e o número de amostras coletadas (*samples*). Para esta configuração, todos os usuários secundários são equipados com um simples detector de energia (*energy detector*, ED). Apesar da técnica DAC ter sido implantada com sucesso no contexto de CSS distribuído, no entanto, uma descrição analítica completa, levando-se em conta os efeitos conjuntos da topologia da rede e a otimizados dos parâmetros do sistema, ainda permanece desconhecida. Além disso, o limiar de decisão da rede CSS foi otimizado utilizando-se o critério de minimização da probabilidade de erro. Resultados numéricos baseados em simulações de Monte-Carlo (*Monte-Carlo Simulation*, MCS) corroboraram as expressões analíticas propostas.

Na segunda parte propomos um esquema de sensoriamento espectral (*spectrum sensing*, SS) para sistemas de múltiplas antenas massivos (*massive MIMO*) baseado na otimização do limiar de decisão dado um subconjunto fixo de antenas e tamanho de amostra capaz de minimizar a probabilidade total de erro, sujeito a uma determinada probabilidade de detecção e falso alarme. Esta formulação resulta em um problema de otimização não linear (*nonlinear optimization problem*, NLP). Expressões empíricas baseadas no teorema do limite central (*central limit theorem*, CLT) com valores estimados para os parâmetros média e variância foram propostas tendo em vista obter o limite de decisão ótimo. Dois modos operacionais são propostos: modo que prioriza a eficiência espectral (*spectral efficiency*, SE), ou seja, baixo número de amostras combinado a um elevado número de antenas, implicando em um tempo de sensoriamento reduzido e um aumento na taxa de transmissão de dados; modo energeticamente eficiente (*energy efficiency*, EE), o que significa um número reduzido de antenas para sensoriamento e um maior número de amostras de processamento, enquanto as antenas restantes estão em modo de suspensão, economizando energia. Para resolver o NLP, um algoritmo baseado na programação quadrática sequencial (*sequential quadratic programming*, SQP) é proposto, sendo capaz de atingir a convergência em poucas iterações. Além disso, para lidar com antenas descalibradas, no contexto MIMO massivo são evocados detectores mais elaborados, incluindo o detector de Hadamard (*Hadamard detector*, HD), detector de volume (*volume detector*, VD) e o detector de covariância (*covariance detector*, CAV). Os parâmetros dos detectores são otimizados no sentido de otimizar o SS sujeito aos efeitos das antenas massivas descalibradas.

Na terceira parte, implementamos uma rede neural convolucional (*convolutional neural network*, CNN) para aprender e refinar o teste estatístico SS em redes sem fio com múltiplos usuários primários (*primary users*, PUs) em um sistema com antenas massivas descalibradas nos usuários secundários (*secondary users*, SUs). O método SS baseado em aprendizado profundo (*deep learning*, DL) proposto utiliza uma arquitetura CNN com capacidade de extração de características das matrizes de covariância das amostras (*sample covariance matrices*, SCMs) calculadas à entrada da rede, melhorando o desempenho geral e a robustez. O método CNN-SS para antenas massivas proposto é comparado a outros nove métodos SS recentes para sistemas equipados com múltiplas antenas e comparado ainda a cinco metodologias recentes de SS baseadas em CNN. A relação desempenho-complexidade dos métodos SS propostos nesta etapa e de referência são corroborados por meio de MCS. O método CNN proposto sob antenas massivas descalibradas revela benefícios substanciais em relação aos métodos de referência, sendo competitivo em relação a outras metodologias CNN, tanto em termos de complexidade quanto de desempenho.

Palavras-chave: sensoriamento espectral cooperativo (*cooperative spectrum sensing*, CSS), consenso médio distribuído (*distributed average consensus*, DAC), eficiência espectral (*spectral efficiency*, SE), eficiência energética (*energy efficiency*, EE), limiar de decisão (*threshold*), rede neural convolucional (*convolutional neural network*, CNN), múltiplas antenas massivas (*massive MIMO*), antenas descalibradas.

ABSTRACT

In this thesis work, we developed a parameter and optimization analyses with the objective of performance characterization of cooperative spectrum sensing (CSS) based on distributed average consensus (DAC), taking into account the cognitive network topology effect given by the adjacency matrices in *ad hoc* networks. CSS performance is considered by detection probability, false alarm probability and error probability; in addition to the decision criterion, given by the threshold and number of collected samples. We employ simple energy detection (ED). Despite DAC being deployed with success in distributed CSS networks, a complete description taking into consideration the defined network topology effects and system parameters effects remains unknown. Moreover, the decision threshold of the CSS network was optimized using the error probability minimization criterion. Numerical results based on Monte-Carlo simulations corroborate the proposed approximated analytical expressions.

Furthermore, we propose a spectrum sensing (SS) design for a massive antenna system (massive MIMO) based on threshold optimization given a fixed subset of antennas and sample size capable of minimizing the total error probability subject to a given probability of detection and false alarm. This formulation results in a nonlinear optimization problem (NLP). Central limit theorem (CLT) is used to derive simple expressions with estimated values of mean and variance parameters aiming to find the optimal decision threshold. Two considered operational modes are proposed: *a*) spectral efficiency (SE) mode, that combine a high number of antennas, implying a reduced sensing time and an increase of the transmission data rate; *b*) energy efficient (EE) mode, which use a reduced number of sensing antennas and a large number of processing samples, saving energy. To solve the NLP, a sequential programming algorithm (SQP) is proposed, being able to attain convergence in few iterations. In addition, to deal with uncalibrated antennas, more elaborate detectors are invoked, including the Hadamard detector (HD), volume detector (VD) and the covariance detector (CAV). Such detector parameters are optimized in the sense of maximizing the SS subject to uncalibrated antennas effects.

Finally, we implement a Convolutional Neural Network (CNN) to learn and adjust the statistical test in SS with multiple sources or primary users (PUs) system operating under massive uncalibrated antennas in the SU. The SS method based on deep learning (DL) is implemented by employing a CNN architecture that has the ability of extracting characteristics from sample covariance matrices (SCMs), improving overall performance and robustness. The proposed CNN is compared with nine state-of-the-art MIMO SS methodologies and with five state-of-art SS systems based on recent CNN topologies. The performance-complexity tradeoff of the proposed CNN method and of benchmark methods

are corroborated through MCS. The proposed CNN method under uncalibrated massive antennas reveals substantial benefits over reference methods and it has demonstrated be competitive with other CNN methodologies. However, the proposed CNN-based SS detector results in computational complexity increasing. Thus, to be effective, such superior operational performance requires a very efficient processing structure.

Keywords: cooperative spectrum sensing (CSS), distributed average consensus (DAC), spectral efficiency (SE), energy efficiency (EE), threshold, convolutional neural network (CNN), massive MIMO, uncalibrated antennas.

LISTA DE FIGURAS

<p>Figura 1 – Time-slots para os diversos links dos SUs nas etapas de sensoriamento espectral e transmissão. Fonte: Autoria própria.</p>	46
<p>Figura 2 – Topologia de Rede com $N = 6$ SUs e 1 PU para diferentes coeficientes de perda de percurso; a matriz de adjacência \mathbf{A}_i é indicada. Fonte: Autoria própria.</p>	54
<p>Figura 3 – Topologias de Rede com $N = 10, 15$ e 20 SUs para o coeficiente de perda de percurso $\beta = 2.5$. Fonte: Autoria própria.</p>	55
<p>Figura 4 – Convergência em termos de NMSE para diferentes matrizes de adjacência geradas pelo conjunto de coeficientes de perda de percurso. ROC comparando as regras de combinação DAC, EGC e OR para a matriz de adjacência \mathbf{A}_1 com $k = 5$ iterações e $M = 100$ amostras. Fonte: Autoria própria.</p>	57
<p>Figura 5 – Convergência em termo da saída do ED representado pelo teste estatístico em dB em função do número de iterações, k para o conjunto dos coeficientes de perda de percurso. Fonte: Autoria própria.</p>	58
<p>Figura 6 – Convergência em termos do teste estatístico (em dB) em função do número de iterações usando: a) limite próximo ao inferior $\alpha = 0.001$; e b) valor dado pela regra MD. Coeficiente de perda de percurso $\beta = 2.5$. Fonte: Autoria própria.</p>	59
<p>Figura 7 – a) ROC simulada e analítica, equação (2.30), para o nó $i = 2$ com $k = 5$ iterações e diferentes matrizes de adjacência geradas pelo conjunto de coeficientes de perda de percurso; b), c), d) ROC simulada e analítica para $k = 1, 2$ e 5 iterações, respectivamente utilizando os nós $i = 2, 4$ e 6 para um $\beta = 2.5$. Fonte: Autoria própria.</p>	60
<p>Figura 8 – Limiar simulado em função do Limiar analítico, comparados em termos de probabilidade de detecção (P_d), probabilidade de falso alarm (P_f) e probabilidade de falha (P_m) para $k = 5$ iterações em uma rede sujeita a diferentes coeficientes de perda de percurso $\beta = 2.5, 3.5, 4.5, 5.5$. Fonte: Autoria própria.</p>	61

Figura 9 – Probabilidade de detecção simulada e analítica (P_d) em função do número de amostras (M), equação (2.33), para $k = 5$ iterações e uma rede sujeita a diferentes probabilidades de falso alarme de referência: a) $P_f = 0.01$; b) $P_f = 0.1$; e c) $P_f = 0.2$, considerando SUs $\in [6; 10; 15; 20]$. Fonte: Autoria própria.	62
Figura 10 – Probabilidade de erro (P_e) em função do limiar de detecção (λ), para $k = 5$ iterações e coeficiente de perda de percurso $\beta = 2.5$. Limiar ótimo (λ^*) determinado a partir de (2.42). Fonte: Autoria própria.	63
Figura 11 – Probabilidade de erro simulada e analítica (P_e) em função do número de amostras (M), para $k = 5$ iterações, $\beta = 2.5$ e $N \in [6; 10; 15; 20]$ SUs. Fonte: Autoria própria.	63
Figura 12 – Topologia para a redes primária e rede secundária munida de uma BS equipada com um número massivo de antenas. Fonte: Autoria própria.	69
Figura 13 – Estrutura da Camada MAC adotada. Fonte: Autoria própria.	70
Figura 14 – Topologia para o sistema MIMO massivo secundário transmitido e recebido ($M \times L$). Configuração das Antenas do sistema secundário operando em fase de transmissão de dados e informações (<i>spectrum sharing</i>). Sistema SU MIMO massivo com $L \ll M$ podendo representar L SUs com uma única antena (separados espacialmente) ou um único SU equipado com L antenas; Fonte: Autoria própria.	77
Figura 15 – Probabilidade de Erro \times a) SNR; b) número de amostras; c) número de antenas no SU (operando no modo EE); λ definido pela equação (4.32). Fonte: Autoria própria.	82
Figura 16 – Complexidade Computacional para os detectores CAV, HD e VD em operações de pontos flutuantes [flops]. Fonte: Autoria própria.	83
Figura 17 – Probabilidades de erro, falso alarme e detecção \times limiar de detecção para os detectores CAV, VD e HD operando nos modos SE e EE. Fonte: Autoria própria.	84
Figura 18 – Eficiência Espectral (SE) e Eficiência Energética (EE) <i>versus</i> número de antenas na BS SU, M analisado no modo SE ($N = 200$ amostras) e modo EE ($N = 500$ amostras). Fonte: Autoria própria.	86

Figura 19 – a) Eficiência Espectral (SE) [bits] e b) Eficiência Energética (EE) [bits/Joule] \times número de antenas (M), avaliado para valores extremos de amostras coletadas [10; $2 \cdot 10^5$] amostras. Fonte: Autoria própria.	86
Figura 20 – a) SE \times Potência transmitida [W], e b) SE \times número de amostras (N) testados para os modos SE e EE. Fonte: Autoria própria.	87
Figura 21 – Eficiência Energética (EE) [bits/Joule] \times a) Potência transmitida [W], b) número de amostras coletadas, N testadas para os modos SE e EE. Fonte: Autoria própria.	88
Figura 22 – Topologia das redes primária e secundária. Fonte: Autoria própria.	94
Figura 23 – Arquitetura típica de uma CNN. Fonte: Autoria própria.	98
Figura 24 – Função perda (<i>cross-entropy</i>) vs. Épocas de treinamento. Fonte: Autoria própria.	105
Figura 25 – <i>Receiver Operating Characteristics</i> . Fonte: Autoria própria.	107
Figura 26 – Probabilidade de Detecção vs. Número de Antenas, M . Fonte: Autoria própria.	108
Figura 27 – Probabilidade de Detecção vs. Número de fontes primárias; $M = 64$. Fonte: Autoria própria.	109
Figura 28 – Probabilidade de Detecção vs. Tamanho das amostras. Fonte: Autoria própria.	109
Figura 29 – Probabilidade de Detecção vs. SNR Média. Fonte: Autoria própria.	110
Figura 30 – <i>Receiver Operating Characteristic</i> para os métodos de SS de última geração baseados em CNNs vs. o método proposto. Fonte: Autoria própria.	111
Figura 31 – Complexidade Computacional [Flops] \times Número de Antenas \times Número de Amostras. Fonte: Autoria própria.	113

LISTA DE TABELAS

Tabela 1 – Configuração dos Parâmetros de Canal e Sistema	53
Tabela 2 – Erro quadrático médio normalizado ($NMSE^{Pe}$) para curvas de probabilidade de erro analíticas e de simulação da Figura 11	64
Tabela 3 – Complexidade por Amostras em [Pontos Flutuantes (Flops)] dos Detectores analisados.	72
Tabela 4 – Modos SE e EE aplicados em Redes Cognitivas com Antenas Massivas.	76
Tabela 5 – Configuração dos Parâmetros de Simulação	80
Tabela 6 – Valores do Limiar de Detecção Ótimo nos modos SE e EE.	83
Tabela 7 – Valores de Limiar de Detecção Ótimo utilizando os métodos SQP e NR.	85
Tabela 8 – Configurações gerais de Parâmetros	103
Tabela 9 – Configuração dos hiperparâmetros da CNN	104
Tabela 10 – Três Estruturas MLP implementadas no Treinamento Offline da CNN .	106
Tabela 11 – Complexidade Computacional por amostra C_{PS} [Flops] dos detectores utilizados para SS.	112

LISTA DE ABREVIATURAS E SIGLAS

5G	quinta-geração (<i>fifth generation</i>)
6G	sexta-geração (<i>sixth generation</i>)
AC	consenso médio (<i>average consensus</i>)
ADMM	método alternativo de direção dos multiplicadores (<i>alternating direction method of multipliers</i>)
AGM	detector de média aritmético-geométrico (<i>arithmetic-to-geometric mean detector</i>)
AI	inteligência artificial (<i>artificial intelligence</i>)
AoA	ângulo de chegada (<i>angle of arrival</i>)
avgpool	<i>pooling</i> médio (<i>average pooling</i>)
AWGN	ruído branco Gaussiano aditivo (<i>additive white Gaussian noise</i>)
B5G	além do 5G (<i>beyond 5G</i>)
BPSK	modulação por deslocamento de fase (<i>binary phase shift keying</i>)
BS	estação rádio-base (<i>base-station</i>)
CAV	detector de covariância (<i>covariance detector</i>)
CDF	função distribuição acumulada (<i>cumulative distribution function</i>)
CFAR	taxa de falso alarme constante (<i>constant false alarm rate</i>)
CH	endurecimento de canal (<i>channel hardening</i>)
CHDM	método de detecção circular de Hadamard (<i>circular Hadamard detection method</i>)
CLAV	detector de variância média local circular (<i>circular local average variance detector</i>)
CLDNN	rede neural convolucional de termo longo-curto (<i>convolutional long short term deep neural network</i>)
CLT	teorema do limite central (<i>central limit theorem</i>)

CNN	rede neural convolucional (<i>convolutional neural network</i>)
CR	rádio cognitivo (<i>cognitive radio</i>)
CRAN	rede de rádio cognitivo <i>ad-hoc</i> (<i>cognitive radio ad-hoc network</i>)
CSI	informação do estado do canal (<i>channel state information</i>)
CSS	sensoriamento espectral cooperativo (<i>cooperative spectrum sensing</i>)
DAC	consenso médio distribuído (<i>distributed average consensus</i>)
dB	decibel
DL	aprendizagem profunda (<i>deep learning</i>)
DoA	direção de chegada (<i>direction of arrival</i>)
DSA	acesso dinâmico ao espectro (<i>dynamic spectrum access</i>)
ED	detector de energia (<i>energy detector</i>)
EE	eficiência energética (<i>energy efficiency</i>)
EGC	combinação de igual ganho (<i>equal gain combining</i>)
EM	algoritmo de maximização de expectativa (<i>expectation-maximization algorithm</i>)
EVD	decomposição em autovalores (<i>eigenvalues decomposition</i>)
FC	central de fusões ou completamente conectada (<i>fusion center</i> ou <i>fully connected</i>)
FCC	comissão federal de comunicações (<i>federal communications commission</i>)
GLRT	teste generalizado da razão de verossimilhança (<i>generalized likelihood ratio test</i>)
GMM	modelo de misturas Gaussianas (<i>Gaussian mixture model</i>)
HD	detector de Hadamard (<i>Hadamard detector</i>)
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos (<i>Institute of Electrical and Electronics Engineers</i>)
i.i.d.	independente e indenticamente distribuído (<i>independent and identically distributed</i>)

iMB-SS	sensoriamento espectral multi-banda melhorado (<i>improved multi-band spectrum sensing</i>)
IoT	internet das coisas (<i>internet of things</i>)
IQ	em fase e quadratura (<i>in-phase and quadrature</i>)
IWAC	consenso médio com pesos melhorado (<i>improved weighted average consensus</i>)
JD	detector de John (<i>John's detector</i>)
KKT	condições de Karush–Kuhn–Tucker (<i>Karush–Kuhn–Tucker conditions</i>)
K-NN	K-vizinho mais próximo (<i>K-nearest neighbour</i>)
LAV	detector de variância média local (<i>local average variance detector</i>)
LB	detector de Ljung-Box (<i>Ljung-Box detector</i>)
LE	detector de maior autovalor (<i>largest eigenvalue detector</i>)
LMPIT	teste localmente mais poderoso (<i>locally most powerful test</i>)
LMS	algoritmo de mínimos quadrados médio (<i>least mean square algorithm</i>)
LRT	teste de razão de verossimilhança (<i>likelihood ratio test</i>)
LSTM	memória de curto prazo longa (<i>long short-term memory</i>)
M-MIMO	MIMO massivo (<i>massive MIMO</i>)
MAC	camada de múltiplo acesso (<i>multiple access layer</i>)
MAP	estimativa de probabilidade máxima <i>a posteriori</i> (<i>maximum a posteriori estimation</i>)
maxpool	<i>pooling</i> máximo (<i>maximum pooling</i>)
MCS	simulação Monte-Carlo (<i>Monte-Carlo simulation</i>)
MD	regra máximo grau (<i>maximum degree</i>)
MIMO	múltiplas entradas e múltiplas saídas (<i>multiple input multiple output</i>)
ML	aprendizado de máquina (<i>machine learning</i>)
MLE	estimativa de máxima verossimilhança (<i>maximum likelihood estimation</i>)
MLP	<i>perceptron</i> de múltiplas camadas (<i>multilayer perceptron</i>)

MME	detector de máximo-mínimo autovalores (<i>maximum-minimum eigenvalue detector</i>)
MRC	combinação de máxima razão (<i>maximum ratio combining</i>)
MSEE	detector de autovalor extremo médio-quadrático (<i>mean-to-square extreme eigenvalue detector</i>)
NB	classificador de Naive Bayes (<i>Naive Bayes classifier</i>)
NC	não-circular (<i>non-circular</i>)
NCC	covariância não-circular (<i>non-circular covariance</i>)
NLoS	sem linha de visada (<i>non line-of-sight</i>)
NLP	programação não-linear (<i>nonlinear programming</i>)
NMSE	erro quadrático médio normalizado (<i>normalized mean squared error</i>)
NN	rede neural (<i>neural network</i>)
NP	critério Neyman-Pearson (<i>Neyman-Pearson criterion</i>)
OEW	detector de autovalores ótimos (<i>optimum eigenvalue weighted detector</i>)
OFDM	multiplexação por divisão de frequências ortogonais (<i>orthogonal frequency division multiplexing</i>)
PDF	função densidade de probabilidade (<i>probability density function</i>)
PSD	densidade espectral de potência (<i>power spectral density</i>)
PU	usuário primário (<i>primary user</i>)
QP	programação quadrática (<i>quadratic programming</i>)
QPSK	modulação de amplitude em quadratura (<i>Quadrature Amplitude Modulation</i>)
Re-GR2	detector real de <i>rank-2</i> geral (<i>real general rank-2 detector</i>)
ReLU	retificador (<i>rectified linear units</i>)
RF	radiofrequência (<i>radiofrequency</i>)
RIS	superfície reflexiva inteligente (<i>reflexive intelligent surface</i>)
ROC	característica de operação do receptor (<i>receiver operating characteristic</i>)

r.v.	variável aleatória (<i>random variable</i>)
RWCD	detector de covariância real com pesos (<i>real weighted covariance detector</i>)
SAE	rede <i>autoencoder</i> empilhada (<i>stacked autoencoder</i>)
SCF	função de correlação espectral (<i>spectral correlation function</i>)
SCM	matriz de covariância amostral (<i>sampled covariance matrix</i>)
SD	detector esférico (<i>sphericity detector</i>)
SE	eficiência espectral (<i>spectral efficiency</i>)
SFET	teste de estimativa de função de separação (<i>separating function estimation test</i>)
SGD	algoritmo de gradiente descendente estocástico (<i>stochastic gradient descent algorithm</i>)
SLE	detector de maior autovalor escalonado (<i>scaled largest eigenvalue detector</i>)
SNR	relação sinal-ruído (<i>signal-to-noise ratio</i>)
SQP	programação quadrática sequencial (<i>sequential quadratic programming</i>)
SS	sensoriamento espectral (<i>spectrum sensing</i>)
STFT	transformada de Fourier de curto período (<i>short time Fourier transform</i>)
SU	usuário secundário (<i>secondary user</i>)
SVM	máquina de vetor de suporte (<i>support vector machine</i>)
TL	aprendizagem por transferência (<i>transfer learning</i>)
TR-MRC	combinação da máxima razão de reversão
TR-WL	reversão de tempo amplamente linear (<i>time reverse-widely linear</i>)
ULA	arranjo de antenas uniforme linear (<i>uniform linear array</i>)
VD	detector de volume (<i>volume detector</i>)
XL-MIMO	MIMO extremamente largo (<i>extremely large MIMO</i>)
WAC	consenso médio com pesos (<i>weighted average consensus</i>)
WAC-AE	consenso médio com pesos por troca de precisão (<i>weighted average consensus-accuracy exchange</i>) no tempo (<i>time reverse-MRC</i>)

WCD detector de covariância com pesos (*weighted covariance detector*)

WCSS CSS largo (*wide CSS*)

LISTA DE SÍMBOLOS

$\Pr(\mathcal{H}_0)$	probabilidade de que o canal primário esteja desocupado
$\Pr(\mathcal{H}_1)$	probabilidade de que o canal primário esteja ocupado
T_i	teste estatístico do i -ésimo SU
$y_i(t)$	sinal recebido no i -ésimo SU
h_i	ganho de canal no i -ésimo SU
$n_i(t)$	ruído AWGN no i -ésimo SU
$s(t)$	sinal transmitido pelo PU
E_s	energia do sinal primário transmitido
σ_i^2	potência do ruído AWGN no i -ésimo SU
\mathcal{G}	grafo que representa a rede de comunicação
\mathcal{V}	vértices do grafo ou nós da rede de comunicação (SUs)
\mathcal{E}	bordas do grafo (canais de comunicação)
\mathcal{N}_i	vizinhos do i -ésimo SU
\mathbf{A}	matriz de adjacência do grafo (capítulo 2)
\mathbf{L}	matriz Laplaciana do grafo
\mathbf{D}	matriz diagonal de grau do grafo
\mathbf{W}	matriz de pesos de Perron do grafo
α	tamanho do passo no procedimento de DAC
SNR_{ij}	SNR entre o i -ésimo e j -ésimo SUs
P_s	potência de transmissão do sinal primário
σ_{ij}^2	potência de ruído AWGN entre o i -ésimo e j -ésimo SUs
d_{ij}	distância entre o i -ésimo SU e o j -ésimo SU
β	coeficiente da perda de percurso
SNR_{th}	SNR alvo

d_{th}	distância de referência
λ_i	limiar de decisão do i -ésimo SU
T_f^{HD}	teste estatístico final nos métodos de decisão abrupta
P_d^{HD}	probabilidade de detecção para os métodos de decisão abrupta
T_f^{SD}	teste estatístico final nos métodos de decisão suave
P_d^{SD}	probabilidade de detecção para os métodos de decisão suave
\mathbf{g}	ganho médio quadrático do vetor de canal
$\mathbf{1}$	vetor com elementos unitários
$\Sigma_0(0)$	matriz de covariância sob hipótese de canal vazio na iteração $k = 0$
$\Sigma_1(0)$	matriz de covariância sob hipótese de canal ocupado na iteração $k = 0$
β_{th}	coeficiente da perda de percurso alvo
$P_d^i(k)$	probabilidade de detecção para o método baseado em consenso do i -th SU na k -ésima iteração
$P_f^i(k)$	probabilidade de falso alarme para o método baseado em consenso do i -ésimo SU na k -ésima iteração
$\lambda_i^{\text{NP}}(k)$	limiar de detecção para o método baseado em consenso do i -ésimo SU na k -ésima iteração
$M_{\min.}^i(k)$	número mínimo de amostras para atingir as probabilidades de detecção e falso alarme alvos para o método baseado em consenso do i -ésimo SU na k -ésima iteração
$P_e^i(k)$	probabilidade de erro para o método baseado em consenso do i -ésimo SU na k -ésima iteração
$P_{md}^i(k)$	probabilidade de falha para o método baseado em consenso do i -ésimo SU na k -ésima iteração
$\lambda_i^*(k)$	limiar de decisão ótimo capaz de minimizar a probabilidade de erro total
\mathbf{X}	matriz do sinal recebido na BS da rede secundária empregando antenas massivas descalibradas
\mathbf{A}	matriz diagonal de amplitude do sinal primário (capítulo 3)

\mathbf{h}	vetor de ganho do canal
\mathbf{s}	vetor do sinal primário transmitido
\mathbf{N}	matriz de ruído AWGN nos receptores secundários
\mathbf{R}	matriz de covariância amostral
\mathbf{I}	matriz identidade
T_{MME}	teste estatístico para o detector MME
T_{AGM}	teste estatístico para o detector AGM
T_{JD}	teste estatístico para o detector de John
T_{CAV}	teste estatístico para o detector de covariância
T_{HD}	teste estatístico para o detector de Hadamard
T_{VD}	teste estatístico para o detector de volume
T_{CHDM}	teste estatístico para o detector CHDM
\mathbf{Y}	matriz de sinal recebido no Rx. SU MIMO
\mathbf{D}	matriz de efeitos de grande escala dado pela perda de percurso
\mathbf{H}	matriz dos efeitos de desvanecimento do canal sem fio entre os SUs Tx. e Rx. (capítulo 2)
\mathbf{X}	matriz do sinal Tx. pelo secundário na fase de transmissão de dados
\mathbf{Z}	matriz do ruído AWGN que captura os efeitos das antenas descalibradas
$\mathcal{R}(\mathcal{M}, N)$	capacidade de Tx. do secundário em função do número de antenas ativas e do número de amostras coletadas
$\mathcal{E}(\mathcal{M}, N)$	eficiência energética em função do número de antenas ativas e do número de amostras coletadas no secundário
	T período de quadro (<i>frame</i>)
f_s	frequência de amostragem do sinal primário
τ	período do SS
E	consumo total de energia
P_e	probabilidade de erro

P_d	probabilidade de detecção
P_f	probabilidade de falso alarme
\overline{P}_d	probabilidade de detecção alvo
\overline{P}_f	probabilidade de falso alarme alvo
\mathbf{X}	matriz do sinal recebido na BS secundária equipada com um grande número de antenas descalibradas (capítulo 3)
T_{GLRT}	teste estatístico para o detector GLRT
T_{LMPIT}	teste estatístico para o detector LMPIT
\mathbf{J}	função de perda (<i>cross-entropy</i>)
θ	pesos (parâmetros) da NN do tipo MLP
$\mathcal{L}(\theta)$	função de verossimilhança
θ^*	pesos ótimos (parâmetros) da NN do tipo MLP
T_{CNN}	teste estatístico para o detector proposto baseado na CNN

LISTA DE NOTAÇÕES

\in	pertence a
\forall	para todos
s.a.	sujeito a
<i>a</i>	letras em itálico minúsculas representam escalares
a	letras em negrito minúsculas representam vetores
A	letras em negrito maiúsculas representam matrizes
\mathbb{R}	representa o conjunto dos números reais
\mathbb{C}	representa o conjunto dos números complexos
$\sum_{i=1}^N(\cdot)$	representa o operador de soma
$\prod_{i=1}^N(\cdot)$	representa o operador de produto
$\lceil \cdot \rceil$	representa o operador que converte o argumento no menor número inteiro maior ou igual ao próprio argumento
$\text{arg.min.}(\cdot)$	retorna o mínimo do argumento
$\text{max}(\cdot)$	retorna o valor máximo de um conjunto de elementos
$\binom{a}{b}$	representa o operador de coeficiente binomial
$\text{Re}(\cdot)$	retorna a parte real do argumento
$\text{Im}(\cdot)$	retorna a parte imaginária do argumento
$\exp(\cdot)$	representa o operador exponencial
$\ln(\cdot)$	representa o operador de logaritmo natural
$\log_2(\cdot)$	representa o operador de logaritmo de base 2
$\ \cdot\ _2$	representa o operador de norma euclidiana ou norma-2
$\ \cdot\ _F$	representa o operador de norma de Frobenius de uma matriz
$(\cdot)^T$	representa o operador de transposição
$(\cdot)^{-1}$	representa o operador de inversão

$(\cdot)^H$	representa o operador hermitiano
$\det(\cdot)$	representa o operador determinante de uma matriz
$\text{diag}(\cdot)$	representa o operador de diagonalização de uma matriz
$\text{Tr}(\cdot)$	representa o operador de traço de uma matriz
$\lim_{x \rightarrow \infty}(\cdot)$	representa o operador de limite de funções
$a \otimes b$	representa o operador de convolução de funções
$\nabla(\cdot)$	representa o operador gradiente
$\nabla^2(\cdot)$	representa o operador Hessiano
$\frac{\partial(\cdot)}{\partial a}$	representa o operador de derivada parcial de uma função em relação à a .
$\text{Pr}(\cdot)$	representa o operador de probabilidade estatística
$\mathbb{E}(\cdot)$	representa o operador de esperança estatística
$\text{Var}(\cdot)$	representa o operador de variância estatística
$Q(\cdot)$	função Q do argumento (relacionada com a função erro complementar de Gauss $\text{erfc}(\cdot)$)
$\mathcal{B}(\cdot, \cdot, \cdot)$	representa a distribuição estatística binomial
$\mathcal{U}(\cdot, \cdot)$	representa a distribuição estatística uniforme
$\mathcal{N}(\cdot, \cdot)$	representa a distribuição estatística normal ou Gaussiana
$\text{sort}(\cdot)$	ordenação de conjunto em ordem crescente

SUMÁRIO

1	INTRODUÇÃO	30
1.1	Conceitos Introdutórios e Motivação	30
1.2	Justificativa e Desafios em Redes de Rádio Cognitivo	32
1.3	Escopo e Objetivos da Pesquisa	33
1.4	Organização do Texto da Tese	34
1.5	Publicações Associadas ao Trabalho da Tese	34
1.5.1	<i>Produções Diretamente Relacionadas à Tese</i>	35
1.5.2	<i>Trabalhos Correlatos à Tese</i>	37
2	OTIMIZAÇÃO DO CONSENSO MÉDIO DISTRIBUÍDO PARA SENSORIAMENTO ESPECTRAL COOPERATIVO EM REDES AD-HOC DE RÁDIO COGNITIVO	39
2.1	Introdução	39
2.2	Contribuições	41
2.3	Modelo de Sistema	41
2.3.1	<i>Modelo da Rede Cooperativa baseado na Teoria Algébrica dos Grafos</i>	42
2.3.2	<i>Modelo da Rede Secundária Ad-Hoc</i>	42
2.4	Métodos de CSS Centralizados e Distribuídos	43
2.4.1	<i>Decisão Abrupta</i>	43
2.4.2	<i>Decisão Suave</i>	44
2.4.3	<i>Sensoriamento Espectral Cooperativo Distribuído baseado em Consenso Médio</i>	45
2.4.4	<i>Análise de Convergência para o DAC</i>	47
2.4.5	<i>Análise Estatística do CSS com base no DAC</i>	48
2.5	Análise de Desempenho baseado nas Probabilidades Locais, no Limiar de Decisão e na quantidade de Amostras	48
2.6	Limiar de Decisão Ótimo para a Minimização da Probabilidade de Erro Total	51
2.7	Resultados Numéricos	52
2.7.1	<i>Topologia Ad-Hoc Secundária baseada nas SNRs dos Links de Comunicação</i>	53
2.7.2	<i>Critério de Convergência baseado em NMSE</i>	53
2.7.3	<i>ROC para o CSS baseado em DAC utilizando diferentes Topologias de Rede</i>	56
2.7.4	<i>Probabilidade de Detecção, Falso Alarme e Erro em termos do Limiar de Decisão</i>	59
2.7.5	<i>Número de Amostras em função das Probabilidades de Detecção, Erro e Limiar de Decisão</i>	60
2.8	Conclusões	64

3	OTIMIZAÇÃO DO SENSORIAMENTO ESPECTRAL EM REDES COGNITIVAS COM ELEVADO NÚMERO DE ANTENAS DESCALIBRADAS	65
3.1	Introdução	65
3.1.1	<i>Contribuições</i>	68
3.2	Modelo de Sistema	69
3.2.1	<i>Receptores MIMO Massivos Descalibrados</i>	71
3.3	Testes Estatísticos e Desempenho do SS para Sistemas MIMO	71
3.3.1	<i>Detector de Máximo-Mínimo Autovalores - MME</i>	71
3.3.2	<i>Detector Aritmético-Geométrico - AGM</i>	72
3.3.3	<i>Detector de John - JD</i>	72
3.3.4	<i>Detector de Covariância - CAV</i>	72
3.3.5	<i>Detector de Hadamard - HD</i>	73
3.3.6	<i>Detector de Volume - VD</i>	73
3.3.7	<i>Detector de Hadamard Circular - CHDM</i>	73
3.3.8	<i>Complexidade Computacional dos Detectores para SS em sistemas MIMO</i>	73
3.3.9	<i>Desempenho dos Detectores de HD, VD e CAV operando em Sistemas Cognitivos munidos de Antenas Descalibradas</i>	74
3.4	Modos de Operação que favorecem a Eficiência Espectral (SE) e a Eficiência Energética (EE)	75
3.4.1	<i>Eficiência Energética e Espectral na etapa de Transmissão de Dados</i>	76
3.4.2	<i>Otimização do Limiar de Decisão sob a condição de Minimização da Probabilidade de Erro</i>	78
3.5	Resultados Numéricos	79
3.5.1	<i>Complexidade Computacional para os detectores usados para o SS</i>	81
3.5.2	<i>Limiares de Detecção Ótimos nos modos de Operação SE e EE</i>	81
3.5.3	<i>Análise de Eficiência Espectral (SE) e Eficiência Energética (EE)</i>	85
3.6	Conclusões	88
4	SENSORIAMENTO ESPECTRAL DE MÚLTIPLAS FONTES PRIMÁRIAS AUXILIADO POR REDES NEURAS CONVOLUCIONAIS EM SISTEMAS SECUNDÁRIOS COM ELEVADO NÚMERO DE ANTENAS DESCALIBRADAS	89
4.1	Introdução	89
4.1.1	<i>Contribuições</i>	93
4.2	Modelo de Sistema	93
4.2.1	<i>Receptores MIMO Massivos Descalibrados</i>	95
4.3	Métodos Clássicos para SS em Sistemas MIMO	95
4.3.1	<i>Generalized Likelihood Ratio Test - GLRT</i>	95
4.3.2	<i>Locally Most Powerful Invariant Test - LMPIT</i>	96

4.3.3	<i>Maximum-Minimum Eigenvalue Detector - MME</i>	96
4.3.4	<i>Arithmetic-Geometric Detector - AGM</i>	96
4.3.5	<i>John's Detector - JD</i>	96
4.3.6	<i>Covariance Detector - CAV</i>	96
4.3.7	<i>Sphericity Detector - SD</i>	97
4.3.8	<i>Hadamard Detector - HD</i>	97
4.3.9	<i>Volume Detector - VD</i>	97
4.4	Teste Estatístico baseado em CNN para Múltiplas Fontes Primárias aplicado em SS para Sistemas Cognitivos equipados com Múltiplas Antenas Massivas Descalibradas	97
4.4.1	<i>Estrutura das CNNs</i>	97
4.4.1.1	<i>Operação de Convolução</i>	98
4.4.1.2	<i>Funções de Ativação</i>	98
4.4.1.3	<i>Camadas Convolucionais</i>	99
4.4.1.4	<i>Camadas de Pooling</i>	99
4.4.1.5	<i>Camada Totalmente Conectada (Fully Connected Layer)</i>	99
4.4.1.6	<i>Otimização por meio de Back-Propagation</i>	100
4.4.2	<i>Fase de Treinamento Off-Line</i>	100
4.4.3	<i>Fase de Validação Online</i>	101
4.4.4	<i>Fase de Teste Online</i>	102
4.5	Resultados Numéricos	102
4.5.1	<i>Estrutura, Treinamento e Etapas de Teste da CNN</i>	103
4.5.2	<i>Receiver Operating Characteristic (ROC)</i>	106
4.5.3	<i>Probabilidade de Detecção vs. Número de Antenas ($P_d \times M$)</i>	107
4.5.4	<i>Probabilidade de Detecção vs. Número de Fontes Primárias ($P_d \times P$)</i>	107
4.5.5	<i>Probabilidade de Detecção vs. Tamanho das Amostras Coletadas ($P_d \times N$)</i>	108
4.5.6	<i>Probabilidade de Detecção vs. Variações na SNR Média ($P_d \times SNR$)</i>	108
4.5.7	<i>Comparação entre as metodologias para SS baseadas em CNNs de última geração</i>	110
4.5.8	<i>Complexidade Computacional</i>	111
4.6	Conclusões	114
5	CONCLUSÕES FINAIS E TRABALHOS FUTUROS	115
5.1	Perspectivas e Continuidade da Pesquisa	116
	REFERÊNCIAS BIBLIOGRÁFICAS	117

1 INTRODUÇÃO

Neste capítulo, são apresentados e explicados conceitos introdutórios relacionados ao tema de tese. Apresenta-se também a organização do texto e o resumo dos trabalhos desenvolvidos. Além disso, são descritos os resultados de investigação obtidos durante o processo de pesquisa.

1.1 Conceitos Introdutórios e Motivação

A demanda por novos serviços de telecomunicações tem sido o principal propulsor das pesquisas sobre novas tecnologias, como se observa, por exemplo, os recentes avanços envolvendo a quinta e sexta gerações (5G e 6G) de sistemas de comunicações sem fio e da internet das coisas (*internet-of-things*, IoT).

No entanto, para viabilizar a maioria dos serviços de comunicações, o espectro de frequências é um recurso muito importante, pois é necessário um alto número de frequências ociosas para acomodar um alto número de transmissores e receptores planejados para as atuais redes 5G e também para as futuras redes 6G. Isso se deve ao fato de que, na atual política de alocação de frequências, o direito de ocupação é dado apenas ao usuário contratado, também chamado de usuário licenciado ou usuário primário (*primary user*, PU) (HAYKIN, 2005). Acredita-se que a atual política de alocação dos espectros não seja adequada para acomodar a expansão dos serviços de sistemas de comunicação sem que haja um elevado consumo de recursos, primariamente energia e espectro. Assim, deve-se implementar uma nova e mais adequada política de alocação dinâmica dos recursos, capaz de explorar o fato de que o espectro de radiofrequências (RF) realmente é subutilizado, visto que em grande parte do tempo e em determinadas regiões geográficas ocorrem ociosidades de porções significativas do espectro em diferentes faixas de RF.

Recentemente, a instalação dos sistemas 5G foi iniciada globalmente (2021/2022). Diferentes recursos do sistema 5G deve ser implementado gradualmente, como ultra-confiabilidade, conectividade em massa e baixa latência específica. Ademais, espera-se que as redes CR de sexta geração (6G) incorporem as tecnologias habilitadoras de uso inovadores e métricas de desempenho, como por exemplo sejam capazes de oferecer cobertura mundial, eficiência de custos, espectro aprimorado, inteligência aprimorada em energia e segurança. Para atingir esses requisitos, os próximos CRNs 6G devem implementar novas tecnologias capacitadoras. Arquitetura de rede inovadora e tecnologias de transmissão e de interface aérea serão fundamentais, como novos esquemas de múltiplo acessos, inovadores design de forma de onda, tecnologias multiantenas massivas e esquemas de codificação de canal. Características fundamentais em redes CRN-6G incluem: a) Cobertura mundial: não haverá limite de 6G para redes globais de comunicação CR que podem precisar ser

completadas com redes de transmissão, como redes de comunicação via satélite; portanto, alcançando uma rede de comunicação integrada marítima; b) Os espectros usados nas CRNs serão abrangentes para acomodar taxas de dados com diferentes densidades de conexão envolvendo bandas de frequência óptica, ondas milimétricas (mmWave), sub-6 GHz e terahertz (THz); c) grandes conjuntos de dados serão criados por causa de redes de comunicação CR tremendamente variadas, combinado a antenas massivas, diversos cenários de comunicação, novas necessidades de provisão, ampla largura de banda, as CRNs 6G permitirão uma variedade inovadora de aplicativos inteligentes com a assistência de big data e tecnologias de inteligência artificial (IA); d) Necessidade de melhorar a segurança da rede ao implantar a tecnologia 6G em redes CR. 6G é uma rede descentralizada, planejada, inteligente, inovadora e distribuída (ASLAM et al., 2021).

Na política de alocação dinâmica de recursos assume-se que um usuário não licenciado, também chamado de usuário secundário (*secondary user*, SU) (HAYKIN, 2005), pode utilizar o espectro de uma rede primária licenciada. As transmissões do SU podem ser realizadas em conjunto com as transmissões do PU, desde que não cause interferência prejudicial, aproveitando as oportunidades de transmissão em sistemas de comunicações de usuários licenciados que estão ociosos em algum período de tempo ou localização no espaço (HAYKIN, 2005).

Nesse contexto, surge o conceito de rádio cognitivo (*cognitive radio*, CR) (MITOLA; MAGUIRE, 1999), (HAYKIN, 2005), que é um dispositivo transceptor inteligente que, através do sensoriamento espectral (*spectrum sensing*, SS) é capaz de identificar bandas de frequência ociosas para uso oportunista. Um CR possui diversas funções de que permitem se adaptar ao ambiente e a rede sem fio em que está inserido, desta forma, o SS é uma das principais metodologias que permitem o acesso dinâmico do espectro (*dynamic spectrum access*, DSA).

Além disso, uma nova técnica chamada Rádio Simbiótico (*Symbiotic Radio*, SR), foi implementado primeiramente para IoT passivo, onde o dispositivo de retroalimentação (*Backscatter device*, BD) é integrado ao transmissor primário. O dispositivo IoT é o usuário secundário. A tecnologia é uma mistura de CR e *ambient backscattering communications* (AmBC). O transmissor secundário transmite informações ao receptor secundário sobrepostas aos sinais de RF provenientes do transmissor primário baseado nas comunicações do BD; assim, o sistema secundário compartilha não só o espectro de rádio, mas também a energia/potência e infra-estrutura com o sistema primário. Em contrapartida, a transmissão secundária fornece diversidade multipercorso para a transmissão primária. Desta forma, os dois sistemas formam um compartilhamento de espectro simbiótico (LONG et al., 2020; LIANG et al., 2022). Os autores em (ZHANG; LIANG; POOR, 2019), propuseram a associação de usuários primários a cada dispositivo IoT a um usuário de celular apropriado, maximizando a taxa de soma de todos os dispositivos IoT. No entanto, a dificuldade

em obter todas as informações do canal em tempo real limita o projeto e a obtenção de uma política ótima para esse problema de sensoriamento. Para superar esse problema, os autores propuseram um algoritmo de aprendizado por reforço profundo (*deep reinforcement learning*, DRL).

Dentre os diversos cenários para as redes 5G e futuras redes 6G, a cobertura para áreas remotas e rurais são de grande interesse para a sociedade, em função do impacto social e econômico. Nesse cenário, o custo operacional da rede deve ser baixo e o raio de cobertura deve ser alto o suficiente para garantir um número razoável de usuários por célula. O uso de canais de TV ociosos (também chamados de buracos de espectro ou espaços em branco) (HAYKIN, 2005), utilizando a tecnologia CR é apontado como o grande facilitador desse modo de operação das redes 5G e futuras redes 6G.

1.2 Justificativa e Desafios em Redes de Rádio Cognitivo

Existem inúmeros desafios e muitas oportunidades de pesquisa com relação ao sensoriamento espectral cooperativo (*cooperative spectrum sensing*, CSS) aplicado a redes de CR (AKYILDIZ; LO; BALAKRISHNAN, 2011). Tais desafios podem ser classificados de acordo com as etapas do processo como um todo: o próprio sensoriamento e a fusão das informações do sensoriamento (fusão de dados) assim como o emprego de sistemas com múltiplas antenas (AKYILDIZ; LO; BALAKRISHNAN, 2011). Todos esses tópicos são desafios de pesquisa no contexto do SS dizem respeito a aspectos da camada física.

Quanto aos desafios inerentes ao próprio sensoriamento, a investigação procura desenvolver ou adaptar detectores otimizados e tão robustos quanto possível, que sejam preferencialmente viáveis do ponto de vista do tratamento matemático e/ou implementação por meio de simulações. Como exemplo, detectores robustos em cenários de desvanecimento com adição dos efeitos de perda de percurso ou atenuação por distância ou outros mecanismos de propagação. Além disso, cenários específicos, como redes de múltiplas antenas aplicadas em sistemas 5G usando elementos de RF descalibrados em termos de potência de ruído que se torna um problema sério para sistemas que realizam o SS.

No que diz respeito à técnica de fusão de dados em redes cooperativas distribuídas, ou seja, sem centrais de fusão (*fusion center*, FC), os desafios dizem respeito ao desenvolvimento de esquemas distribuídos que sejam robustos comparáveis a esquemas centralizados já existentes, com baixa complexidade computacional e aplicável em redes *ad-hoc* e de sensores. Os métodos existentes não são completos em termos de desenvolvimento analítico, portanto, nenhuma otimização é realizada nesse sentido.

1.3 Escopo e Objetivos da Pesquisa

Neste trabalho de Tese, considera-se o estudo e o desenvolvimento de esquemas de SS focado no desenvolvimento de sistemas de comunicações sem fio 5G e 6G.

Deste ponto de vista, esquemas distribuídos podem ser interessantes para desenvolver métodos de SS em redes *ad-hoc* sem uma decisão centralizada de fusão de dados. Esquemas de consenso médio distribuído (*distributed average consensus*, DAC) são interessantes nesses cenários por fornecerem desempenho adequado comparável a esquemas de CSS centralizados sem a necessidade de uma rede estruturada. Neste trabalho, a determinação do desempenho analítico foi desenvolvida utilizando o DAC como dados de fusão em CSS. Além disso, considerou-se o procedimento de otimização de limiar de decisão, cuja probabilidade de erro é minimizada.

Os atuais sistemas 5G são equipados com um grande número de antenas; portanto, o SS nesses cenários é um tópico de pesquisa interessante com muitos desenvolvimentos possíveis. Neste trabalho de Tese, a aplicação de antenas massivas como forma de realizar o SS está focado em dois modos de operação extremos: *modo de máxima eficiência espectral* (max-SE) e *modo de máxima eficiência energética* (max-EE), os quais dependem da configuração adotada para o número da amostras coletadas e o número de antena no SU. Além disso, cenários realistas munidos de múltiplas antenas com potência de ruídos descalibrados é um desafio para a correta determinação de desempenho do SS em cenários com antenas massivas. Assim, tendo como base esta limitação, foram otimizados detectores para SS em receptores descalibrados, como o detector de Hadamard (*Hadamard detection*, HD), detector de volume (*volume detector*, VD) e o detector de covariância (*covariance detector*, CAV), com a ressalva de que tais detectores possuem expressões analíticas de desempenho de difícil manipulação e otimização; portanto, expressões empíricas ou aproximadas, baseadas no teorema do limite central (*central limit theorem*, CLT) foram desenvolvidas para facilitar a análise e permitir a otimização eficiente e efetiva do processo de SS. Uma otimização do limiar de detecção foi realizada de tal sorte a oferecer o ponto de mínimo para a probabilidade de erro de detecção.

Finalmente, as técnicas de aprendizado profundo (*deep learning*, DL) têm se revelado de grande interesse de aplicação em sistemas de comunicações sem fio. Do ponto de vista do problema SS, os esquemas baseado em DL têm sido aplicados com sucesso, fornecendo resultados promissores para as atuais redes 5G e também para as futuras redes 6G baseadas em inteligência artificial (*artificial intelligence*, AI). As técnicas promissoras mais estudadas em SS são baseadas em redes neurais convolucionais (*convolutional neural networks*, CNNs), pois resultam robustas aos sinais corrompidos utilizados para realizar o SS, que se encontram em valores na faixa dos -20 [dB]. Neste trabalho de Tese, desenvolvemos uma CNN que permite obter um teste estatístico robusto e cego capaz de aprender com grande confiabilidade operacional em cenários descalibrados e com múltiplas

fontes primárias de sinais.

1.4 Organização do Texto da Tese

Este documento de Tese está organizado em cinco capítulos:

- **Capítulo 1:** Este capítulo fornece os conceitos introdutórios e a motivação da pesquisa, a justificativa e os desafios pertinentes ao problema tratado, o escopo e os objetivos da pesquisa além das publicações associadas ao trabalho de tese;
- **Capítulo 2:** Este capítulo discute os resultados numéricos de pesquisa, bem como as contribuições relacionadas ao tema de CSS baseado em DAC como fusão de dados aplicada a redes cognitivas *ad-hoc*;
- **Capítulo 3:** Este capítulo estabelece os resultados de pesquisa obtidos, além das contribuições relacionadas ao tema de *otimização* da etapa SS em sistemas cognitivos equipados com *antenas massivas descalibradas*;
- **Capítulo 4:** Este capítulo sintetiza os resultados e contribuições científicas e tecnológicas relacionados ao desenvolvimento do tema SS aplicado às múltiplas fontes primárias com decisões guiadas por aprendizado de máquinas, especificamente CNN, realizadas em sistemas de comunicação cognitivos equipados com antenas massivas descalibradas;
- **Capítulo 5:** Este capítulo conclusivo estabelece uma síntese dos principais resultados de investigação alcançados, bem como sugere algumas direções de pesquisa e/ou de desenvolvimentos tecnológicos futuros.

1.5 Publicações Associadas ao Trabalho da Tese

O produto da pesquisa associado a este trabalho de Tese inclui: *i*) três artigos científicos completos diretamente relacionados ao conteúdo da Tese; *ii*) dois artigos científicos completos correlatos e diretamente relacionados ao tema de Tese, sendo o último trabalho um artigo em co-autoria.

O primeiro artigo foi desenvolvido sob o tema de CSS distribuído utilizando o DAC como fusão de dados; o segundo *paper* é focado na otimização do SS para sistemas de antenas massivas descalibradas e o terceiro artigo é desenvolvido sobre o tema de DL em SS de sistemas primários com múltiplas fontes para sistemas secundários munidos de antenas massivas descalibradas. O quarto artigo refere-se a uma proposta de uma nova técnica DAC para o CSS distribuído aplicável ao problema de SS. O quinto artigo em co-autoria discute o sensoriamento espectral em sistemas multibanda utilizando metodologias baseadas em *wavelets*. A seguir, subseções 1.5.1 e 1.5.2, apresentamos o resumo e os demais dados de

identificação de cada trabalho desenvolvido durante o período de doutoramento (2017/2S a 2022/1S).

Com a publicação do terceiro artigo científico, abriu-se a perspectiva de continuidade do trabalho de tese focado no desenvolvimento de esquemas para SS aplicáveis a sistemas 5G baseado em métodos de aprendizado de máquinas. Tais estudos foram focados em estruturas de aprendizagem de máquina do tipo redes neurais convolucionais (CNN), suas variantes topológicas, metodologia de dimensionamento e otimização de parâmetros da rede NN. Comparações com outras técnicas clássicas de aprendizado de máquinas aplicáveis ao problema SS, tais como K-Means, K-Vizinho mais próximo (k-NN), modelo de mistura de Gaussianas (GMM) e máquina de vetor de suporte (SVM). As novas arquiteturas de NN aplicáveis ao problema SS devem ser comparadas com o estado da arte na literatura, com foco no compromisso desempenho-complexidade.

Além disso, novas tecnologias vêm sendo desenvolvidas recentemente para as futuras redes sem fio de sexta-geração (6G), sendo uma delas as *superfícies reflexivas inteligentes* (RIS), constituídas de elementos reflexivos passivos controláveis. Tal estrutura baseada em metamateriais possuem funcionalidades semelhantes aos *relays* em redes cooperativas, porém com a propriedade de ajustar dinamicamente a fase de cada elemento RIS e outros atributos dos sinais eletromagnéticos com os quais possibilitam alcançar importantes melhorias de confiabilidade do link e do desempenho geral da rede ao custo de um consumo energético menor. Como continuidade do trabalho, tais elementos RIS podem ser instalados em locais adequados para a melhoria da confiabilidade do link originalmente sem linha de visada (NLoS), tais como em superfícies prediais, auxiliando as redes cognitivas tanto nas etapas de SS quanto nas etapas de transmissão e recepção de dados. Nesse sentido, o estudo do emprego de painéis RIS às redes cognitivas torna-se atrativo para futuras aplicações em redes 6G.

1.5.1 *Produções Diretamente Relacionadas à Tese*

1. HERNANDES, A.G., ABRÃO, T., "Distributed Average Consensus Optimization for Cooperative Spectrum Sensing in Cognitive Radio Ad hoc Networks", *Transactions on Emerging Telecommunications Technologies*, v. 31, p. e3965, 2020. DOI: <http://dx.doi.org/10.1002/ett.3965>

Abstract: *In this paper, we develop a parameter and optimization analyses aiming at characterizing the performance of cooperative spectrum sensing (CSS) based on the distributed average consensus (DAC), taking into account the network topology effect, represented by adjacency matrices in cognitive radio ad-hoc networks (CRANs). The CSS performance is analysed by the probability of detection, probability of false alarm and probability of miss detection, besides the decision threshold and the number of collected samples. In this work, all secondary users*

(SUs) are equipped with a simple energy detector (ED). Despite the DAC technique has been successfully deployed in the distributed CSS context, however, a full analytical description taking into account the joint effects of the network topology and all the optimized system parameters remains unknown. Moreover, the CSS network decision threshold was optimized using the error probability minimization criterion. Numerical results deploying extensive Monte Carlo simulations (MCS) have corroborated the proposed analytical expressions.

Keywords: Distributed average consensus (DAC); cooperative spectrum sensing (CSS), cognitive radio *ad-hoc* networks (CRANs); probability of detection, probability of false alarm; threshold decision; number of samples; error probability.

2. HERNANDES, A.G., ABRÃO, T., "Spectrum Sensing Optimization in Uncalibrated Massive Antennas Systems", *Physical Communication*; v. 49, p. 101484, 2021. <<http://dx.doi.org/10.1016/j.phycom.2021.101484>>

Abstract: *In this paper, we propose a spectrum sensing (SS) design for massive MIMO (M-MIMO) antennas system based on decision threshold optimization given a fixed subset of antennas and sample size able to minimize the total error probability subject to target detection and false alarm probabilities. This formulation results in a nonlinear optimization problem (NLP). Empirical expressions based on the central limit theorem (CLT) with estimated sample-mean parameter values are deployed to find the optimal decision threshold. Two operational modes are considered: (i) spectral-efficient (SE) mode, i.e., low number of samples combined with a high number of antennas, implying in a reduced sensing time and increased transmission rate; (ii) energy-efficient (EE) mode, meaning reduced number of sensing antenna and massive number of processing samples, while the remaining antennas are in sleep mode, saving energy. To solve the NLP, an algorithm based on the sequential quadratic programming (SQP) is proposed, being able to attain convergence in a few iterations. Moreover, to deal with uncalibrated antennas, more elaborated detectors are evoked, including the Hadamard detector (HD), volume detector (VD) and the covariance detector (CAV). Such detector parameters are optimized in the sense of maximizing the SS task subject to uncalibrated massive antennas effects.*

Keywords: massive antennas (M-MIMO), spectrum sensing, sample size, spectrum sharing, Hadamard detector (HD), volume detector (VD), covariance detector (CAV), optimization.

3. HERNANDES, A. G.; ABRÃO, T. CNN-aided multiple PU spectrum sensing in uncalibrated massive antennas SU system. *Physical Communication*, v. 53, p. 101715-101727, 2022. DOI: <<http://dx.doi.org/10.1016/j.phycom.2022.101715>>

Abstract: *This paper deploys the Convolutional Neural Network (CNN) to learn and set the statistical test in Spectrum Sensing (SS) task of multiple primary user (PU) sources in massive uncalibrated antennas of secondary users (SU) sharing the same spectrum resources. The proposed deep learning-based SS method (DL-SS) is based on the CNN architecture that has the capability of*

extracting features of the sample covariance matrices (SCMs) that are given as the network input, improving the overall performance and robustness. The proposed CNN-SS method is compared with nine recent multiple-antennas SS methods, namely the arithmetic–geometric detector (AGM), John’s detector (JD), sphericity detector (SD), generalized likelihood test (GLRT), locally most powerful invariant test (LMPIT), maximum–minimum eigenvalue detector (MME), covariance detector (CAV), Hadamard detector (HD) and volume detector (VD) methods; besides, the proposed method is also compared with five recent state-of-art CNN-based SS methodologies. Performance-complexity trade-off of the proposed and reference SS methods are corroborated via Monte Carlo Simulations (MCS). The proposed CNN-SS method under uncalibrated massive antennas reveals substantial benefits w.r.t. the reference methods and is competitive with others CNN-SS methodologies, both in terms of complexity and performance, achieving detection probability of under very low false alarm probability. Under different figures of merit, the performance of the CNN-based SS detector has revealed to be indubitably superior regarding the state-of-art SS detectors. However, the proposed CNN-based SS detector presents relative computational complexity increases. Hence, to be effective, such a superior operational performance requires a very efficient processing structure in the SU base stations.

Keywords: Convolutional neural networks (CNN), Multiple PUs, Uncalibrated massive antennas, Spectrum sensing.

1.5.2 Trabalhos Correlatos à Tese

4. HERNANDES, A. G. ; LEMES PROENÇA Jr., M.; ABRÃO, T.. **Improved weighted average consensus in distributed cooperative spectrum sensing networks.** *Transactions on Emerging Telecommunications Technologies*, v. 29, p. e3259, 2017. DOI: <<http://dx.doi.org/10.1002/ett.3259>>

Abstract: *This work proposes a fully distributed improved weighted average consensus (IWAC) technique applied to a cooperative spectrum sensing (CSS) problem in cognitive radio systems. This method allows the secondary users to cooperate based on only local information exchange without a fusion centre. We have compared 4 rules of average consensus (AC) algorithms. The first rule is the simple AC without weights. The AC rule presents performance comparable to the traditional CSS techniques such as the equal gain combining rule, which is a soft combining centralised method. Another technique is the weighted AC (WAC) rule, using the weights based on the SUs’ channel condition. This technique results in a performance similar to that of the maximum ratio combining with soft combining (centralised CSS). Two new AC rules are analysed, namely, WAC accuracy exchange (WAC-AE) and IWAC; the former relates the weights to the channel conditions of the SUs’ neighbours, whereas the latter combines the conditions of WAC and WAC-AE in the same rule. All methods are compared with each other and with the hard combining centralised CSS. The WAC-AE results in a similar performance of the WAC technique but with fast convergence, whereas the IWAC can deliver suitable performance with small complexity*

increment. Moreover, the IWAC method results in a similar convergence rate than the WAC-AE method but slightly higher than the AC and WAC methods. Hence, the computational complexity of IWAC, WAC-AE, and WAC is proven to be very similar. The analyses are based on numerical Monte Carlo simulations, whereas the algorithm's convergence is evaluated for both fixed and dynamic mobile communication scenarios and under additive white Gaussian noise and Rayleigh channels.

Keywords: Average consensus, Cooperative spectrum sensing (CSS), cognitive radio systems.

5. Kobayashi, R. T.; HERNANDES, A. G. ; Proença Jr, M. L. ; ABRAO, T. **Improved Multi-Band Cognitive Radio Spectrum Sensing using Wavelet Spectrum Filtering.** *Journal of Circuits and Systems and Computers*, v. 28, p. 1950136-1-1950136-22, 2019. DOI: <<http://dx.doi.org/10.1142/S0218126619501366>>

Abstract: *In cognitive radio (CR), the sensed aggregate bandwidth could be as large as several GHz. This is especially challenging if the bandwidths and central frequencies of the sensed signals are unknown and need to be estimated. This work discusses a new improved method for MB spectrum sensing (iMB-SS) based on edge detection and using Wavelet Spectrum Filtering. The proposed iMB-SS method uses a Welch power spectrum density (PSD) estimate and a multi-scale Wavelet approach to reveal the spectrum transition (edges), which is deployed to characterize the spectrum occupancy in CR scenarios where the operation frequencies of the primary users (PUs) are unknown. The focus of this work lies in improving the performance of the MB spectrum sensor, particularly by refining the spectral edge location and reducing misleading detection. A comprehensive analytical description and numerical analysis have been carried out by focusing on orthogonal-frequency-division-multiplexing (OFDM) signal applications in CR networks. Numerical results corroborate the effectiveness of the proposed iMB-SS approach. The simulated results for the multiple-PU's OFDM-based transmission CR system demonstrate that the proposed iMB-SS method can achieve high performance even under low signal-to-noise ratio (SNR) regime, turning it out as an attractive choice for SS in the MB CR systems.*

Keywords: Cognitive radio, MB spectrum sensing, Gaussian filtering, Welch PSD estimation, wavelet.

2 OTIMIZAÇÃO DO CONSENSO MÉDIO DISTRIBUÍDO PARA SENSORIA- MENTO ESPECTRAL COOPERATIVO EM REDES *AD-HOC* DE RÁDIO COGNITIVO

2.1 Introdução

Nas últimas duas décadas, o uso do espectro em comunicações sem fio tornou-se problemático principalmente devido à escassez de frequências eletromagnéticas disponíveis, aliado mais recentemente à demanda explosiva por serviços de comunicação móveis na última década. A Comissão Federal de Comunicações (*Federal Communications Commission*, FCC) demonstrou que a maior parte do espectro alocado não é utilizado de forma eficiente. Essa situação motiva o projeto de rádios cognitivos (CRs), ou seja, a proposição e a caracterização de novos dispositivos e topologias de comunicação com características de decisão baseada em inteligência artificial (*artificial intelligence*, AI), incluindo o aprendizado, a adaptação e a cooperação entre os terminais (MITOLA; MARGUIRE, 1999),(HAYKIN, 2005), podendo ainda utilizar o espectro de forma oportunista, melhorando assim a eficiência espectral (SE) do sistema.

A principal tarefa realizada pelo CR é o sensoriamento espectral (SS) (YUCEK; ARSLAN, 2009; LIANG et al., 2008). Geralmente, esta tarefa pode ser dividida em duas classes principais: não cooperativo ou cooperativo, sendo o último realizado basicamente de forma *i*) distribuída, *ii*) agrupada ou *iii*) centralizada (AKYILDIZ; LO; BALAKRISHNAN, 2011). Em cenários de comunicação sem fio com efeitos de sombreamento e desvanecimento, as técnicas não cooperativas resultam em baixo desempenho. Dentre as possíveis soluções, técnicas de SS com consenso (CSS) são geralmente utilizadas; técnicas CSS possibilitam a difusão de informações entre os usuários da rede sem fio; portanto, a má condição do canal pode ser parcialmente mitigada devido ao ganho de diversidade obtido por meio dos métodos cooperativos (GANESAN; LI, 2007a; GANESAN; LI, 2007b). No contexto de CSS, usuários secundários (SUs) podem ser implantados com a funcionalidade de compartilhamento de suas decisões de SS com nós adjacentes, sendo ainda denominados usuários cooperativos.

No modo cooperativo centralizado, uma estação rádio-base (*base station*, BS) chamada central de fusões (*fusion center*, FC) é empregada para processar as informações de cada SU e retornar uma decisão para todos os usuários. O desempenho dos métodos cooperativos centralizados em canais com desvanecimento e somente ruído branco aditivo Gaussiano (*additive white Gaussian noise*, AWGN) são bem conhecidos e podem ser classificados como combinação abrupta (*hard combination*) e combinação suave (*soft combination*). Dentre as regras de combinação abrupta, o desempenho mais confiável é alcançado na maioria dos casos pela regra OR seguida pela regra *Majority* e AND;

enquanto entre a combinação suave, a combinação de igual ganho (*equal gain combining*, EGC) sempre resulta em pior desempenho do que a combinação de máxima proporção (*maximum ratio combining*, MRC); de fato, para sistemas cooperativos, a regra de decisão para sensoriamento espectral que resulta no melhor desempenho possível (AKYILDIZ; LO; BALAKRISHNAN, 2011).

Na abordagem de CSS distribuído, a decisão final é baseada nas informações trocadas entre cada SU que anteriormente tomou uma decisão local. No CSS distribuído, o algoritmo que emprega o procedimento DAC (XIAO; BOYD, 2004; XIAO; BOYD; KIM, 2007) é uma técnica promissora, pois permite o sensoriamento espectral na ausência de um centro de fusão (receptor FC), ou seja, de forma totalmente distribuída e escalável (LI; YU; HUANG, 2010; YU; HUANG; TANG, 2010). Em (LI; YU; HUANG, 2010), os autores propõem um CSS baseado em DAC para SS em cenários com desvanecimento e sujeitos a falhas de comunicação entre os usuários cooperativos. Em (YU; HUANG; TANG, 2010), os autores propõem um CSS baseado em DAC para tratar a falsificação de dados em SS. Em (ASHRAFI; MALMIRCHEGINI; MOSTOFI, 2011), uma técnica de consenso binário é desenvolvida para garantir um desempenho superior ao DAC convencional quantizado. Os autores em (TANG et al., 2012) propõem um esquema de autenticação usando identidade baseada em criptografia para resolver problemas de segurança causados por falsificação de dados em CSS usando DAC como fusão de dados. Um CSS baseado em DAC é desenvolvido em (TEGUIG et al., 2015), tendo como referência o teste de ajuste de qualidade de Darling-Anderson. Em (ZHANG et al., 2015), foi proposto uma nova técnica baseado em DAC capaz de alcançar o desempenho esperado pelas técnicas de CSS centralizado suave (ambos MRC e EGC), essa técnica é chamada de DAC com pesos (*weighted average consensus*, WAC), onde os pesos definem o desempenho equivalente aos métodos MRC e EGC. O desempenho do WAC é analisado para redes sem fio fixas e aleatórias (aquelas que apresentam falhas de comunicação). Além disso, em (VOSOUGHI; CAVALLARO; MARSHALL, 2016), um método DAC de gerenciamento com reconhecimento de confiança é aplicado no CSS distribuído usando o algoritmo *Gossip* para resolver problemas de segurança em CSS sob ataques de falsificação de dados. Já em (KAILKHURA; BRAHMA; VARSHNEY, 2017) é proposto uma nova técnica baseada em DAC para tratar com a segurança em uma rede cognitiva em um sistema sujeito a ataques Bizantinos, que também é um problema de falsificação de dados muito empregado em CSS. Por fim, os autores em (WEI; ZHAO; SU, 2019) propõem um novo esquema baseado em DAC para CSS aplicados em *clusters* com mecanismos de segurança que podem reduzir a sobrecarga de comunicação e o ataque de dados falsos.

Os métodos de difusão também podem ser utilizados no contexto do CSS distribuído. Nas referências (HAJIHOSEINI; GHORASHI, 2017; GAZESTANI; GHORASHI, 2018), os autores propuseram o uso de métodos de difusão em CSS; os resultados mostram que a taxa de convergência é aumentada com métodos de difusão em comparação com o DAC;

no entanto, pode-se observar um baixo desempenho das técnicas de difusão em termos de operação característica do receptor (*receiver operating characteristic*, ROC), enquanto o desempenho alcançado com métodos de consenso aproxima-se ao desempenho do método centralizado, como explanado anteriormente. Além disso, em (AINOMÄE; BENGTTSSON; TRUMP, 2018) foi utilizado o mínimo quadrático adaptativo (*least mean squared*, LMS) como um método de difusão em CSS distribuído para SUs equipados com o detector de maior autovalor (*largest eigenvalue*, LE).

2.2 Contribuições

Com base nos resultados da revisão da literatura, observamos escassez ou mesmo ausência de análises analíticas para o método CSS baseado em DAC. Consequentemente, análises de otimização para SS baseadas em consenso são escassas ou mesmo inexistentes na literatura. Motivados por este fato, nesta etapa de desenvolvimento da Tese propusemos uma descrição analítica e uma metodologia de otimização dos parâmetros no contexto de CSS baseado em DAC. Mais especificamente, podemos destacar duas contribuições nesta etapa: *i*) Com base nos resultados do teorema do limite central (*central theorem limit*, CLT) e no fato dos SUs serem equipados com detectores de energia (*energy detectors*, EDs), nesta etapa foram derivadas as expressões analíticas para a probabilidade de detecção, probabilidade de falso alarme, probabilidade de erro, limiar de decisão (*threshold*) e número de amostras, bem como uma análise geral do desempenho do CSS distribuído com base no DAC; *ii*) otimização de alguns dos parâmetros do sistema CSS-DAC, como por exemplo o limiar de decisão, no sentido de minimizar a probabilidade total de erros de detecção.

2.3 Modelo de Sistema

Consideramos uma rede *Ad-Hoc* de rádio cognitivo (*cognitive radio ad-hoc network*, CRAN) com N SUs e uma única fonte primária. Todos os SUs fazem a estimativa de ocupação do espectro e cooperam entre si para determinar qual a decisão final. Por uma questão de simplicidade, adotamos o ED. Para o i -ésimo SU, o sinal recebido é definido como uma condição binária dada por (ZHANG et al., 2015)

$$y_i(t) = \begin{cases} n_i(t) & , \mathcal{H}_0 \\ h_i s(t) + n_i(t) & , \mathcal{H}_1; \end{cases} \quad (2.1)$$

onde \mathcal{H}_0 é a hipótese que o canal esteja desocupado, \mathcal{H}_1 é a hipótese que o canal esteja ocupado, $y_i(t)$ é o sinal recebido pelo i -ésimo SU, $s_i(t)$ é o sinal com modulação BPSK transmitido pela fonte primária, $n_i(t)$ é o ruído AWGN não-correlacionado com distribuição estatística $\mathcal{N}(0, \sigma_i^2)$, sendo que a variância pode ser expressa na forma de vetor como $\sigma^2 = [\sigma_1^2, \dots, \sigma_N^2]^T$, h_i é o ganho de amplitude do canal que representa o efeito de desvanecimento multipercurso Rayleigh.

A relação sinal-ruído (*signal-to-noise ratio*, SNR) local média no i -ésimo SU é dado por $\eta_i = \frac{E_s |h_i|^2}{\sigma_i^2}$, onde E_s é a energia do sinal transmitido pela fonte primária definido como $E_s = \sum_{t=0}^{M-1} |s_i(t)|^2$.

Utilizando o ED (URKOWITZ, 1967; KAY, 1998), cada SU calcula o teste estatístico T_i baseado nas M amostras de sinais coletadas considerando uma banda de sensoriamento em comum. O teste estatístico para o i -ésimo SU pode ser descrito como (YUCEK; ARSLAN, 2009)

$$T_i = \sum_{t=0}^{M-1} |y_i(t)|^2. \quad (2.2)$$

Em seguida, o decisor do i -ésimo SU compara o resultado do cálculo de T_i em (2.2) com um limiar de decisão predefinido λ da seguinte forma

$$\text{Decisão}_i = \begin{cases} \mathcal{H}_1, & T_i > \lambda \\ \mathcal{H}_0, & \text{caso contrário.} \end{cases} \quad (2.3)$$

Genericamente, as equações (2.2) e (2.3) definem o teste estatístico para o problema de sensoriamento espectral realizado pelo i -ésimo SU.

2.3.1 Modelo da Rede Cooperativa baseado na Teoria Algébrica dos Grafos

As CRANs distribuídas podem ser modeladas com base na teoria algébrica dos grafos. Definimos os elementos da rede como os vértices (representando os SUs) e os links de comunicação (representando o canal sem fio) como as arestas do grafo.

Consideramos N SUs interligados e representados por um grafo não-direcionado, assim a rede sem fio é descrita pelo grafo $\mathcal{G} = (\mathcal{V}, \mathcal{E})$, onde $\mathcal{V} = \{1, 2, \dots, N\}$ são os nós e $\mathcal{E} \subseteq \mathcal{V} \times \mathcal{V}$ são as arestas; O conjunto de elementos vizinhos ao i -ésimo SU é $\mathcal{N}_i = \{j \in \mathcal{V} : (i, j) \in \mathcal{E}\}$. Finalmente, a matriz de adjacência é dada por $\mathbf{A} = [a_{ij}]_{N \times N}$, onde os elementos da matriz são $a_{ij} = 1$ se $(i, j) \in \mathcal{E}$ e $a_{ij} = 0$ se não há nenhuma conexão disponível com o elemento vizinho da rede (XIAO; BOYD, 2004).

A matriz Laplaciana do grafo \mathcal{G} é definida como sendo $\mathbf{L} = \mathbf{D} - \mathbf{A}$, onde \mathbf{D} é a matriz diagonal de máximo grau do grafo definida como $\mathbf{D} = \text{diag}(\mathbf{A} \cdot \mathbf{1})$ (XIAO; BOYD, 2004). Além disso, também podemos definir a matriz de Perron (ou matriz de pesos) como sendo $\mathbf{W} = \mathbf{I} - \alpha \mathbf{L}$, onde α é o tamanho da etapa de iterações do algoritmo de consenso calculado como

$$0 < \alpha < \frac{1}{\max(\text{diag}(\mathbf{L}))}, \quad (2.4)$$

sendo $\frac{1}{\max(\text{diag}(\mathbf{L}))}$ denominado regra *maximum degree* (MD) para técnicas de consenso.

2.3.2 Modelo da Rede Secundária Ad-Hoc

Usando a teoria dos grafos, podemos descrever a rede *Ad-Hoc* sem fio por meio das matrizes definidas na seção anterior. Nesta etapa, assumimos que cada SU transmite com

um nível de potência constante P_s e os receptores SU tenham uma potência de ruído σ_{ij}^2 , ambos dados em *Watt* (W). Consideramos que os SUs que não são vizinhos, não causam interferência significativa entre si, portanto, elementos considerando as interferências podem ser ignorados nesta análise. Assim, a transmissão entre o i -ésimo SU e o j -ésimo SU é assegurada (definidos como vizinhos pela representação em grafos) quando a SNR entre os i -ésimo e os j -ésimo SUs são superiores ou iguais a uma SNR operacional (alvo), representado por SNR_{th} , como

$$\text{SNR}_{ij} = \frac{P_s}{\sigma_{ij}^2 d_{ij}^\beta + \mathcal{I}_i} \geq \text{SNR}_{\text{th}}, \quad \text{sendo} \quad \text{SNR}_{\text{th}} = \frac{P_s}{\sigma_{ij}^2 d_{\text{th}}^\beta}, \quad (2.5)$$

d_{ij} é a distância (em metros) entre os i -ésimo e os j -ésimo SUs, β é o coeficiente de perda de percurso na rede de comunicação (QUAN et al., 2009) e \mathcal{I}_i a interferência gerada pelos demais SUs não pertencentes à vizinhança do i -ésimo SU¹. Ademais, essa desigualdade de SNRs fornece a SNR mínima necessária para garantir uma comunicação confiável entre os elementos da rede sem fio distribuída.

2.4 Métodos de CSS Centralizados e Distribuídos

Os métodos de CSS centralizados precisam de uma estação FC para operarem da forma correta. Uma rede cooperativa usa os SUs para sensoriarem o espectro e um FC para computar a decisão final, que representa o teste estatístico.

No FC, existem algumas formas de determinar a decisão final, incluindo a combinação abrupta (*hard decision*), que pode utilizar diferentes regras de decisão, como as regras OR, *Majority* e AND, e o modo de combinação suave (*soft decision*), ou seja, baseados nas regras de combinação EGC (*equal gain combining*) ou MRC (*maximal ratio combining*). Nesta seção discutiremos aspectos teóricos das combinações abrupta e suave, com destaque para a regra OR (decisão abrupta) e EGC (decisão suave).

2.4.1 Decisão Abrupta

Nos métodos de decisão abrupta, N SUs cooperativos detectam o espectro utilizado pelo(s) PU(s) de modo simultâneo e enviam as decisões locais ao FC de modo sequencial, isto é, compartilham o canal de controle por multiplexagem no tempo. A decisão final é dada pela seguinte métrica, formando o teste estatístico final T_f^{HD} como

$$T_f^{\text{HD}} = \text{round} \left[\frac{1}{N} \sum_{i=1}^N D_i \right] \quad (2.6)$$

¹ Neste capítulo, admitiremos que a interferência \mathcal{I}_i pode ser desprezada no caso dos nós secundários interferentes suficientemente distanciados do i -ésimo SU, com $d_{i,j} \gg d_{\text{th}}$ e $j \notin \mathcal{V}_i$, sendo \mathcal{V}_i o conjunto de nós vizinhos ao i -ésimo SU, os quais atende à eq. (2.5).

sendo D_i a decisão local do i -ésimo SU com $D_i \in \{0, 1\}$, baseado em (2.3), onde $D_i = 0$ se o PU está ausente (banda desocupada) ou $D_i = 1$ se o PU está presente, ocupando a banda analisada.

O desempenho do sensoriamento espectral baseado em decisão abrupta é dado em termos de uma expressão de probabilidade generalizada de detecção (CHAUDHARI et al., 2012):

$$\begin{aligned} P_d^{\text{HD}} &= \sum_{q=1}^N \binom{N}{q} \left[\prod_{a=1}^q P_d^a \times \prod_{b=1}^{N-q} (1 - P_d^b) \right] \\ &= 1 - \mathcal{B}(q-1, N, P_d), \end{aligned} \quad (2.7)$$

sendo P_d a probabilidade de detecção de cada SU e $\mathcal{B}(k, n, p)$ a função distribuição cumulativa (*cumulative distribution function*, CDF) da distribuição binomial, definida como $\mathcal{B}(i, n, p) = \sum_{i=0}^n \binom{n}{i} (p)^i (1-p)^{n-i}$ para o CSS centralizado de combinação abrupta. Em suma, resultados iguais a 1, garantem o mínimo de interferência às fontes primárias.

Neste trabalho consideramos a regra de decisão OR. Sob essa regra, o PU será considerado presente na banda avaliada se pelo menos um SU identificar a presença do PU (hipótese \mathcal{H}_1), enviando a decisão 1 ao FC, ou seja, basta o teste estatístico de algum SU resultar 1. Pode-se ver que a regra OR é muito conservadora para os SUs acessarem a banda licenciada. Dessa forma, a chance de causar interferência no PU é mitigada devido a regra de decisão OR. A regra OR é construída a partir de um limiar de decisão λ para o CSS centralizado de combinação abrupta. Além disso, sob a regra OR, a probabilidade analítica de detecção pode ser calculada quando $i = 1$, resultando em

$$P_d^{\text{OR}} = 1 - \prod_{i=1}^N (1 - P_d^i), \quad (2.8)$$

onde a probabilidade de detecção local após a aplicação das condições CLT é $P_d^i = Q\left(\frac{\lambda - (M + \eta_i)\sigma^2}{\sqrt{2(M + 2\eta_i)\sigma^4}}\right)$.

2.4.2 Decisão Suave

O teste estatístico de cada i -ésimo SU é enviado ao FC, que coleta todos os valores de testes estatísticos de todas os SUs. Em seguida, o teste estatístico final T_f^{SD} é calculado no FC como

$$T_f^{\text{SD}} = \sum_{i=1}^N w_i T_i = \mathbf{w}^T \mathbf{t}. \quad (2.9)$$

onde w_i são os pesos que podem ser escrito na forma de um vetor compacto $\mathbf{w} = [w_1, \dots, w_N]^T$; além disso, se todos os pesos w_i têm o mesmo valor, a técnica cooperativa satisfaz a combinação EGC. Se os pesos w_i são proporcionais a SNR, ou seja, SNR_i , o

desempenho corresponde a combinação MRC². Além disso, os testes estatísticos de todas as SUs podem ser escritos também em forma vetorial compacta como $\mathbf{t} = [T_1, \dots, T_N]$. A decisão final no FC é obtida comparando-se o T_f^{SD} com limiar λ , isto é, o mesmo critério estabelecido em (2.3).

Usando o CLT e seguindo (ZHANG et al., 2015), a decisão final T_f^{SD} , sob certas condições, apresentará distribuição estatística Gaussiana (Normal), com médias e variâncias dadas por:

$$\mathbb{E}(T_f^{\text{SD}}) = \begin{cases} \sum_{i=1}^M w_i M \sigma_i^2 & , \mathcal{H}_0 \\ \sum_{i=1}^M w_i (M \sigma_i^2 (1 + \eta_i)) & , \mathcal{H}_1; \end{cases} \quad (2.10)$$

$$\text{Var}(T_f^{\text{SD}}) = \begin{cases} \sum_{i=1}^M w_i^2 (2M \sigma_i^4) & , \mathcal{H}_0 \\ \sum_{i=1}^M w_i^2 (2M \sigma_i^4 + 4\eta_i \sigma_i^4) & , \mathcal{H}_1. \end{cases} \quad (2.11)$$

A probabilidade de detecção em CSS *soft* centralizado pode ser avaliado para uma probabilidade de falso alarme desejada (alvo) P_f como

$$P_d^{\text{SD}} = Q \left(\frac{\kappa \sqrt{\text{Var}(T_f^{\text{SD}}|\mathcal{H}_0)} - \mathbb{E}(T_f^{\text{SD}}|\mathcal{H}_1) + \mathbb{E}(T_f^{\text{SD}}|\mathcal{H}_0)}{\sqrt{\text{Var}(T_f^{\text{SD}}|\mathcal{H}_1)}} \right), \quad (2.12)$$

sendo $\kappa = Q^{-1}(P_f)$. Usando ferramentas de vetores e matrizes compactas, podemos reescrever a expressão em (2.12) como

$$P_d^{\text{SD}} = Q \left(\frac{\kappa \sqrt{\mathbf{w}^T \boldsymbol{\Sigma}_0 \mathbf{w}} - \mathbf{w}^T (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_0)}{\sqrt{\mathbf{w}^T \boldsymbol{\Sigma}_1 \mathbf{w}}} \right). \quad (2.13)$$

onde $\boldsymbol{\Sigma}_0$ e $\boldsymbol{\Sigma}_1$ são as matrizes de covariância para o canal desocupado e ocupado e $\boldsymbol{\mu}_0$ e $\boldsymbol{\mu}_1$ são as médias para os mesmos casos anteriores.

2.4.3 Sensoriamento Espectral Cooperativo Distribuído baseado em Consenso Médio

No DAC a estimativa da energia do sinal do i -ésimo SU é atualizada no momento das iterações $k = 1, 2, \dots$ de acordo com a regra dada em (YU; HUANG; TANG, 2010)

$$x_i(k+1) = x_i(k) + \alpha \sum_{j \in \mathcal{N}_i} (x_j(k) - x_i(k)). \quad (2.14)$$

Os elementos da matriz de adjacência a_{ij} definem a topologia da rede sem fio.

Os valores de energia iniciais na iteração ($k = 0$), antes da ocorrência da fusão de dados, são definidos por $x_i(0) = T_i$, ou seja o algoritmo de consenso recebe os dados iniciais dos SUs, os quais são os valores dos testes estatísticos locais de cada SU baseados no ED. Por ser distribuída, a decisão final (local) é obtida comparando-se a estimativa

² Deve-se garantir que os valores de SNR sejam conhecidos ou pelo menos estimados com certa acurácia no FC. Neste sentido, a regra EGC apresenta vantagem por não requer a estimação das SNR de todos os nós SUs no FC.

atualizada da energia do sinal do i -ésimo SU, eq. (2.14) com um limiar de decisão local predefinido λ_i da seguinte forma:

$$\text{Decisão}_i = \begin{cases} \mathcal{H}_1 & , x_i > \lambda_i \\ \mathcal{H}_0 & , \text{caso contrário.} \end{cases} \quad (2.15)$$

Agora considerando a forma compacta de vetor-matriz, o consenso pode ser escrito como (ZHANG et al., 2015)

$$\mathbf{x}(k+1) = \mathbf{W}\mathbf{x}(k), \quad (2.16)$$

sendo $\mathbf{W} = \mathbf{I} - \alpha\mathbf{L}$ a matriz de Perron do grafo ou matriz de pesos. Aqui, a matriz Laplaciana do grafo é definida como sendo $\mathbf{L} = \mathbf{D} - \mathbf{A}$, onde \mathbf{D} e \mathbf{A} são as matrizes diagonal de grau e a matriz de adjacência respectivamente.

A convergência do DAC é afetada pela escolha do tamanho dos passos de iteração. Se o tamanho do passo de iteração for escolhido próximo ao limite inferior de $0 \lesssim \alpha$, a convergência do DAC torna-se lenta. Para acelerar a convergência do DAC, a melhor escolha consiste em selecionar valores próximos ao limite superior da regra MD, conforme definido na equação (2.4).

Do ponto de vista de operações de consenso médio distribuído (DAC) na camada MAC, a Figura 1 apresenta um esboço da ocorrência das etapas de sensoriamento e de transmissão de dados síncronas dos nós SUs. Consideramos que o processo de sensoriamento+controle+transmissão nos SUs seja síncrono e que não ocorram interferências (colisão) entre os links. Assim, por exemplo, na etapa de transmissão o Link 2 (relativo ao SU-2) não colide com o Link M (SU- M), isto é, os SUs utilizam o canal primário para transmissão de seus dados, mas somente um SU poderá fazê-lo em cada *slot* temporal para que não haja colisão entre os sinais dos SUs.




Figura 1 – Time-slots para os diversos links dos SUs nas etapas de sensoriamento espectral e transmissão.

Fonte: Autoria própria.

2.4.4 Análise de Convergência para o DAC

A análise de convergência do DAC é apresentada levando em consideração as matrizes dos grafos da rede pré-definidas nas subseções anteriores, conforme revisitado na subseção 2.3.1. Definimos o conjunto $\mathcal{S} = \{\mathbf{W} \in \mathbb{R}^{N \times N} | w_{ij} \neq 0, \text{ se } (i, j) \in \mathcal{E} \text{ e } i \neq j\}$. Essa configuração indica uma maneira de determinar os pesos para as decisões de consenso.

A equação iterativa do DAC pode ser escrita como uma função da estimativa inicial $\mathbf{x}(0)$, e a k -th potência da matriz de pesos como (XIAO; BOYD, 2004)

$$\mathbf{x}(k) = \mathbf{W}^k \mathbf{x}(0). \quad (2.17)$$

A convergência final é obtida a partir da operação de limite para um número infinito de iterações, sendo expressa como (XIAO; BOYD, 2004)

$$\begin{aligned} \lim_{k \rightarrow \infty} \mathbf{x}(k) &= \lim_{k \rightarrow \infty} \mathbf{W}^k \mathbf{x}(0) = \mathbf{J} \mathbf{x}(0) \\ &= \frac{\mathbf{1}\mathbf{1}^T}{N} \mathbf{x}(0), \end{aligned} \quad (2.18)$$

sendo a matriz $\mathbf{J} = \frac{\mathbf{1}\mathbf{1}^T}{N}$. Observe que durante as fases de sensoriamento e cooperação, o tamanho da rede e a vizinhança são mantidos fixos. Além disso, todos os nós secundários estão sincronizados durante a fase de cooperação. Para este cenário, garantimos que o DAC converge para a média dos valores iniciais $\mathbf{x}(0)$. As configurações de convergência podem ser resumidas por três condições, como em (XIAO; BOYD, 2004)

Condição 1: Certifique-se que os autovalores da matriz de Perron estejam no intervalo $(-1, 1)$ seguindo o teorema do disco de Gershgorin em (GOLUB; LOAN, 2013). Essa suposição pode ser expressa matematicamente como

$$\|\mathbf{W} - \mathbf{J}\|_2 < 1. \quad (2.19)$$

Condição 2: Certifique-se que o autovetor à direita sempre é igual ao vetor unitário, e está relacionado com a condição anterior.

$$\mathbf{W}\mathbf{1} = \mathbf{1}. \quad (2.20)$$

Condição 3: Semelhante à segunda condição, certifique-se que o autovetor à esquerda é igual ao vetor unitário.

$$\mathbf{1}^T \mathbf{W} = \mathbf{1}^T. \quad (2.21)$$

Se todas essas três condições forem satisfeitas simultaneamente, pode-se afirmar que o DAC converge para um número finito de iterações.

2.4.5 Análise Estatística do CSS com base no DAC

O teste estatístico baseado em ED sujeito a canais Rayleigh produz variáveis aleatórias que seguem a distribuição qui-quadrado na hipótese \mathcal{H}_0 e a distribuição exponencial sob a hipótese \mathcal{H}_1 . Expressões de probabilidades de detecção e falso alarme exatas são muito complicadas de serem obtidas, mesmo para o caso não cooperativo, e crescem em complexidade matemática para casos cooperativos suaves, tais como as combinações EGC e MRC (DIGHAM; ALOUINI; SIMON, 2007). O mesmo comportamento é esperado para o caso do DAC. No entanto, para um número suficientemente grande de amostras, o CLT pode ser empregado resultando em uma distribuição Gaussiana no estágio final dos EDs. Assim, definindo a distribuição estatística do DAC como

$$\mathbf{x}(k) \sim \begin{cases} \mathcal{N}(\mathbf{W}^k \boldsymbol{\mu}_0(0), \mathbf{W}^k \boldsymbol{\Sigma}_0(0) \mathbf{W}^k), & \text{para } \mathcal{H}_0 \\ \mathcal{N}(\mathbf{W}^k \boldsymbol{\mu}_1(0), \mathbf{W}^k \boldsymbol{\Sigma}_1(0) \mathbf{W}^k), & \text{para } \mathcal{H}_1, \end{cases} \quad (2.22)$$

a função densidade de probabilidade (*probability density function*, PDF) multivariada do processo pode ser escrita

$$p(\mathbf{x}, \mathcal{H}_{0,1}) = \frac{1}{2\pi^{\frac{N}{2}} \sqrt{\det(\boldsymbol{\Phi})}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\eta})^T \boldsymbol{\Phi}^{-1}(\mathbf{x} - \boldsymbol{\eta})\right\}, \quad (2.23)$$

onde $\boldsymbol{\mu}_0(0)$, $\boldsymbol{\mu}_1(0)$, $\boldsymbol{\Sigma}_0(0)$ e $\boldsymbol{\Sigma}_1(0)$ são os valores de média e matrizes de covariância na presença e ausência de sinal da rede primária, respectivamente. Todos esses parâmetros são calculados quando $k = 0$ iterações. A matriz de covariância $\boldsymbol{\Phi}$, e o vetor de média $\boldsymbol{\eta}$ são dados por: $\boldsymbol{\Phi} = \mathbf{W}^k \boldsymbol{\Sigma}_{0,1}(0) \mathbf{W}^k$, e $\boldsymbol{\eta} = \mathbf{W}^k \boldsymbol{\mu}_{0,1}(0)$, respectivamente.

2.5 Análise de Desempenho baseado nas Probabilidades Locais, no Limiar de Decisão e na quantidade de Amostras

Seguindo a expressão dada pela equação (2.12) para o caso do CSS centralizado, nesta seção, derivamos expressões para a probabilidade local (distribuída) de detecção e falso alarme, considerando dados do DAC.

Portanto, como na equação (2.12), aqui para a abordagem distribuída, é necessário determinar a média e a variância sob as hipóteses \mathcal{H}_0 e \mathcal{H}_1 . Essa suposição é verdadeira para o caso de um grande número de amostras; e usando o CLT pode-se afirmar que a probabilidade de detecção e falso alarme podem ser aproximadas por distribuições Gaussianas como em (QUAN; CUI; SAYED, 2008; QUAN et al., 2009; QUAN et al., 2010; TARICCO, 2011). No caso de estimativa distribuída, o desempenho é dado localmente em termos do número de iterações k e para o i -ésimo SU separadamente. Como esperado, quando k aumenta o desempenho de todos os i -ésimo SUs estão próximos uns dos outros. Finalmente, quando $k \rightarrow \infty$ todos os SUs apresentam e compartilham o mesmo desempenho.

Genericamente, para o i -ésimo SU na k -ésima iteração, as probabilidades de detecção e falso alarme podem ser escritas, respectivamente, como

$$P_d^i(k) = Q \left(\frac{\kappa \sqrt{\text{Var}(x_i|\mathcal{H}_0)} - \mathbb{E}(x_i|\mathcal{H}_1) + \mathbb{E}(x_i|\mathcal{H}_0)}{\sqrt{\text{Var}(x_i|\mathcal{H}_1)}} \right), \quad (2.24)$$

$$P_f^i(k) = Q \left(\frac{\lambda_i(k) - \mathbb{E}(x_i|\mathcal{H}_0)}{\sqrt{\text{Var}(x_i|\mathcal{H}_0)}} \right), \quad (2.25)$$

onde as expressões para a média e a variância são dadas por

$$\mathbb{E}(x_i|\mathcal{H}_{0,1}) = \begin{cases} (\mathbf{W}^k \boldsymbol{\mu}_0(0))_i & , \quad \mathcal{H}_0 \\ (\mathbf{W}^k \boldsymbol{\mu}_1(0))_i & , \quad \mathcal{H}_1, \end{cases} \quad (2.26)$$

$$\text{Var}(x_i|\mathcal{H}_{0,1}) = \begin{cases} (\mathbf{W}^k \boldsymbol{\Sigma}_0(0) \mathbf{W}^k)_{ii} & , \quad \mathcal{H}_0 \\ (\mathbf{W}^k \boldsymbol{\Sigma}_1(0) \mathbf{W}^k)_{ii} & , \quad \mathcal{H}_1, \end{cases} \quad (2.27)$$

com $\boldsymbol{\Sigma}(0) \triangleq \mathbb{E}[(\mathbf{x}(0) - \mathbb{E}(\mathbf{x}(0)))(\mathbf{x}(0) - \mathbb{E}(\mathbf{x}(0)))^T]$ sendo a matriz de covariância do vetor $\mathbf{x}(0)$, e $\lambda_i(k)$ é o limiar de decisão local.

Portanto, para alcançar o consenso, as matrizes de covariância iniciais sob as hipóteses \mathcal{H}_0 e \mathcal{H}_1 devem ser definidas como

$$\begin{aligned} \boldsymbol{\Sigma}_0(0) &= 2M \text{diag}^2(\boldsymbol{\sigma}^2), \\ \boldsymbol{\Sigma}_1(0) &= 2M \text{diag}^2(\boldsymbol{\sigma}^2) + 4 \cdot E_s \cdot \text{diag}(\mathbf{g}) \cdot \text{diag}(\boldsymbol{\sigma}^2), \end{aligned} \quad (2.28)$$

sendo $\mathbf{g} = [|h_1|^2, \dots, |h_N|^2]^T$ o vetor de ganho de potência médio do canal. As matrizes diagonais são valores quadráticos devido a definição que são dadas para matrizes de covariância e o cálculo para o vetor de energia inicial no consenso \mathbf{x} , que coincide com o mesmo vetor de energia coletado pelos EDs individuais \mathbf{t} . Enquanto a média sob as hipóteses de canal desocupado e ocupado podem ser calculadas, respectivamente, como

$$\begin{aligned} \boldsymbol{\mu}_0(0) &= M(\boldsymbol{\sigma}^2)^T, \\ \boldsymbol{\mu}_1(0) &= (M\boldsymbol{\sigma}^2 + E_s \mathbf{g})^T. \end{aligned} \quad (2.29)$$

Nesta etapa, estamos interessados em obter as probabilidades locais de detecção e falso alarme. A matriz de Perron (matriz de pesos) e a matriz Laplaciana são funções da matriz de adjacência e da matriz de grau \mathbf{D} . Com isso, definindo $\boldsymbol{\mu} = \boldsymbol{\mu}_1 - \boldsymbol{\mu}_0$, pode-se descrever tais probabilidades em função da topologia da rede. Assim, a probabilidade local de detecção e falso alarme podem ser reformuladas como as expressões (2.30) e (2.31), respectivamente,

$$P_d^i(k) = Q \left(\frac{\kappa \sqrt{([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\Sigma}_0(0) [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_{ii} - \varpi}}{\sqrt{([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\Sigma}_1(0) [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_{ii}}} \right), \quad (2.30)$$

sendo $\varpi = ([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\mu})_i$ e

$$P_{\text{f}}^i(k) = Q \left(\frac{\lambda_i(k) - ([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\mu}_0)_i}{\sqrt{([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\Sigma}_0(0) [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_{ii}}} \right). \quad (2.31)$$

Além disso, com base nas equações (2.30) e (2.31), o limiar ótimo de decisão local para uma dada probabilidade local de falso alarme alvo pode ser adaptado, obtendo-se a equação (2.33). Esta expressão é formalmente obtida como a solução do seguinte problema de otimização que garante o critério de Neyman-Pearson (NP)

$$\begin{aligned} \lambda_i^{\text{NP}}(k) &= \arg . \max . P_{\text{d}}^i(k)(\lambda_i(k)), \\ \text{s.a. } P_{\text{f}}^i(k)(\lambda_i(k)) &\leq \bar{P}_{\text{f}}. \end{aligned} \quad (2.32)$$

A solução de (4.29) garante que a primeira derivada da probabilidade de detecção e falso alarme em relação ao limiar de decisão local são funções negativas e o máximo é obtido quando a restrição assume o valor desejado (alvo) para a probabilidade de falso alarme, \bar{P}_{f} . Assim, com base nesta suposição, o valor limiar de decisão ótimo pode ser obtido por

$$\begin{aligned} \lambda_i^{\text{NP}}(k) &= M((\boldsymbol{\sigma}^2)^T [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_i \\ &+ \kappa \sqrt{([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\Sigma}_0(0) [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_{ii}}. \end{aligned} \quad (2.33)$$

Além disso, pode-se derivar o número mínimo de amostras do sinal primário para atingir uma probabilidade local conjunta de detecção e falso alarme desejáveis. A expressão resultante é dada por (2.37). Esta expressão é obtida usando (2.28) e (2.29). Observe que ambas as equações são descritas em função do tamanho da amostra M ; portanto, combinando essas expressões com (2.30) e (2.31), e isolando o tamanho de amostras em função da probabilidade de detecção e probabilidade de falso alarme, pode-se encontrar o número mínimo de amostras dado pela equação (2.37). Mais especificamente, em primeiro lugar, simplificamos a matriz de covariância quando a hipótese ocupada é considerada como sendo $\boldsymbol{\Sigma} = \sigma_i^2 \mathbf{I} + 2\text{diag}(\mathbf{g})$. Com base nesse fato, para determinar a expressão de $M_{\text{min}}^i(k)$ devemos considerar as expressões para probabilidades de detecção e falso alarme como

$$P_{\text{d}}^i(k) = Q \left(\frac{\lambda_i - M \mathbf{W}^k (\sigma_i^2 \mathbf{1} + \mathbf{g}_i)}{\sigma_i \sqrt{2M (\mathbf{W}^k \boldsymbol{\Sigma} \mathbf{W}^k)_{ii}}} \right), \quad (2.34)$$

$$P_{\text{f}}^i(k) = Q \left(\frac{\lambda_i - M \mathbf{W}^k \sigma_i^2 \mathbf{1}}{\sigma_i \sqrt{2M (\mathbf{W}^k \mathbf{W}^k)_{ii}}} \right). \quad (2.35)$$

A variável do tamanho da amostra está incorporada nas expressões anteriores. Tomando as expressões em 2.34 e 2.35 e manipulando obtemos a equação

$$\sigma_i^2 \sqrt{2M (\mathbf{W}^k \boldsymbol{\Sigma} \mathbf{W}^k)_{ii}} Q^{-1}(P_{\text{d}}) = \sigma_i^2 \sqrt{2M (\mathbf{W}^k \mathbf{W}^k)_{ii}} Q^{-1}(P_{\text{f}}) - M (\mathbf{W}^k \mathbf{g})_i. \quad (2.36)$$

Resolvendo a expressão a partir do uso do simulador MAPLE (MONAGAN et al., 2005; MAPLESOFT, 2022), o qual opera com valores simbólicos, finalmente chegamos à equação (2.37)

$$M_{\min}^i(k) = \left\lceil \frac{2\sigma_i^2(\mathbf{W}^k \boldsymbol{\Sigma} \mathbf{W}^k)_{ii}(Q^{-1}(P_d))^2 + \chi}{(\mathbf{W}^k \mathbf{g})_i^2} \right\rceil, \quad (2.37)$$

sendo $\chi = -2\sigma_i^3 \sqrt{2(\mathbf{W}^k \boldsymbol{\Sigma} \mathbf{W}^k)_{ii} Q^{-1}(P_d) Q^{-1}(P_f)} \sqrt{2(\mathbf{W}^k \mathbf{W}^k)_{ii} + 2\sigma_i^4 (\mathbf{W}^k \mathbf{W}^k)_{ii} (Q^{-1}(P_f))^2}$ e o operador $\lceil \cdot \rceil$ converte um número real no menor número inteiro maior ou igual ao número convertido.

2.6 Limiar de Decisão Ótimo para a Minimização da Probabilidade de Erro Total

A expressão analítica para o limiar de decisão local ótimo que minimiza a probabilidade de erro de detecção de espectro total é obtida nesta seção. A probabilidade total de erro pode ser definida como (CHATZIANTONIOU; ALLEN; VELISAVLJEVIC, 2015)

$$P_e^i(k)(\lambda_i(k)) = P_f^i(k)(\lambda_i(k)) + P_{\text{md}}^i(k)(\lambda_i(k)), \quad (2.38)$$

onde a probabilidade de falha é definida como $P_{\text{md}}^i(k) = 1 - P_d^i(k)$. Pode-se formular este problema como um problema de otimização não-linear da seguinte forma (BOYD; VANDENBERGHE, 2004)

$$\lambda_i^*(k) = \arg \min P_e^i(k)(\lambda_i(k)) \quad (2.39)$$

Para resolver este problema, devemos tomar a primeira derivada parcial em relação ao limiar de decisão local e igualar a zero. Seguindo isso temos

$$\frac{\partial P_e^i(k)(\lambda_i(k))}{\partial \lambda_i(k)} = \frac{\partial P_f^i(k)(\lambda_i(k))}{\partial \lambda_i(k)} + \frac{\partial P_{\text{md}}^i(k)(\lambda_i(k))}{\partial \lambda_i(k)} = 0,$$

que é semelhante a

$$\frac{\partial P_e^i(k)(\lambda_i(k))}{\partial \lambda_i(k)} = \frac{\partial P_f^i(k)(\lambda_i(k))}{\partial \lambda_i(k)} - \frac{\partial P_d^i(k)(\lambda_i(k))}{\partial \lambda_i(k)} = 0. \quad (2.40)$$

Fazendo a primeira derivada parcial da soma de funções Q em relação ao limite de decisão local λ_i resulta na expressão (2.41). Assim, após algumas manipulações, podemos transformar a expressão transcendental em uma equação polinomial de segunda ordem que gera a solução ótima (toma-se a solução com valor positivo), dada pela equação (2.42)

$$\begin{aligned} \frac{\partial P_e^i(k)(\lambda_i(k))}{\partial \lambda_i(k)} &= \frac{\exp \left[\frac{-(-M((\boldsymbol{\sigma}^2)^T [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_i - (E_s \mathbf{g}^T (\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})^k)_i + \lambda_i(k))^2}{2([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\Sigma}_1(0) [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_{ii}} \right]}{\sqrt{2\pi([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\Sigma}_1(0) [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_{ii}}} \\ &\quad - \frac{\exp \left[\frac{-(-M((\boldsymbol{\sigma}^2)^T [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_i + \lambda_i(k))^2}{2([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\Sigma}_0(0) [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_{ii}} \right]}{\sqrt{2\pi([\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k \boldsymbol{\Sigma}_0(0) [\mathbf{I} - \alpha(\text{diag}(\mathbf{A}\mathbf{1}) - \mathbf{A})]^k)_{ii}}} = 0, \end{aligned} \quad (2.41)$$

$$\lambda_i^*(k) = \frac{M((\boldsymbol{\sigma}^2)^T \mathbf{W}^k)_i [(\mathbf{W}^k \boldsymbol{\Sigma}_0(0) \mathbf{W}^k)_{ii} - (\mathbf{W}^k \boldsymbol{\Sigma}_1(0) \mathbf{W}^k)_{ii}] + (E_s \mathbf{g}^T \mathbf{W}^k)_i (\mathbf{W}^k \boldsymbol{\Sigma}_0(0) \mathbf{W}^k)_{ii}}{(\mathbf{W}^k \boldsymbol{\Sigma}_0(0) \mathbf{W}^k)_{ii} - (\mathbf{W}^k \boldsymbol{\Sigma}_1(0) \mathbf{W}^k)_{ii}} + \frac{\sqrt{-2(\mathbf{W}^k \boldsymbol{\Sigma}_0(0) \mathbf{W}^k)_{ii}^2 (\mathbf{W}^k \boldsymbol{\Sigma}_1(0) \mathbf{W}^k)_{ii} \ln \left(\sqrt{\frac{(\boldsymbol{\Sigma}_1(0))_{ii}}{(\boldsymbol{\Sigma}_0(0))_{ii}}} \right) + 2(\mathbf{W}^k \boldsymbol{\Sigma}_0(0) \mathbf{W}^k)_{ii} (\mathbf{W}^k \boldsymbol{\Sigma}_1(0) \mathbf{W}^k)_{ii}^2 \ln \left(\sqrt{\frac{(\boldsymbol{\Sigma}_1(0))_{ii}}{(\boldsymbol{\Sigma}_0(0))_{ii}}} \right) + C}}{(\mathbf{W}^k \boldsymbol{\Sigma}_0(0) \mathbf{W}^k)_{ii} - (\mathbf{W}^k \boldsymbol{\Sigma}_1(0) \mathbf{W}^k)_{ii}}. \quad (2.42)$$

Nesta expressão, o valor de C é definido como

$$C = (\mathbf{W}^k \boldsymbol{\Sigma}_0(0) \mathbf{W}^k)_{ii} (\mathbf{W}^k \boldsymbol{\Sigma}_1(0) \mathbf{W}^k)_{ii} \times \left[(M(\boldsymbol{\sigma}^2)^T \mathbf{W}^k)_i^2 - 2(M(\boldsymbol{\sigma}^2)^T \mathbf{W}^k)_i (M(\boldsymbol{\sigma}^2)^T \mathbf{W}^k + E_s \mathbf{g}^T \mathbf{W}^k)_i + (M(\boldsymbol{\sigma}^2)^T \mathbf{W}^k + E_s \mathbf{g}^T \mathbf{W}^k)_i^2 \right]. \quad (2.43)$$

Note-se que a obtenção do threshold ótimo λ_i^* para decisão local do i -ésimo SU depende da CSI \mathbf{g} . Tendo em vista tornar a análise mais expedita, pode-se substituir a CSI instantânea pela CSI média, $\bar{\mathbf{g}} = \mathbb{E}(\mathbf{g})$, aproximando ou mesmo simplificando a Eq. (2.42), de forma a evitar a explícita e frequente re-estimativa de canal em cada SU.

2.7 Resultados Numéricos

Esta seção analisa vários aspectos do CSS baseado em DAC. Dentre esses aspectos, investigou-se os efeitos do canal sem fio na topologia da rede *Ad-Hoc*, a convergência do DAC aplicada ao problema de CSS com base no erro quadrático médio (*mean squared error*, MSE), bem como os vetores de energia evoluindo em relação as iterações. Além disso, o desempenho dos dados de fusão de consenso é comparado com as conhecidas regras de combinação EGC e OR aplicadas à classe do CSS centralizado. Em seguida, analisamos o efeito da topologia da rede no desempenho em termos de ROC, bem como o efeito do número de iterações.

A configuração dos parâmetros do sistema e do canal está descrita na Tabela 1. Nesta seção, os resultados numéricos foram obtidos como uma média sobre $\mathbb{T} = 10000$ simulações de Monte-Carlo. A rede é representada por um modelo de grafo algébrico baseado nas conexões da matriz de adjacência; especificamente, implantamos $N = 6, 10, 15$ e 20 SUs distribuídos aleatoriamente e uniformemente em uma área quadrada de 25×25 m², conforme mostrado nas Figuras 2 e 3. A posição dos SUs é selecionado em uma única tentativa e mantém a estatística ao longo das tentativas MCS. Além disso, o CSS é avaliado assumindo canais com desvanecimento plano entre o nó primário e os SUs. O tamanho das amostras e o número de iterações do DAC são escolhidos com base em valores operacionais suficientes para esses parâmetros. Além disso, a potência de transmissão dos SUs é mantida fixa como $P_s = 3$ mW e a potência de ruído como 1 nW. Por fim, selecionamos o conjunto de coeficientes de perda de percurso com base no ambiente de comunicação. Se um ambiente urbano típico é esperado, selecionamos um coeficiente $\beta = 2.5$ ou $\beta = 3.5$ e para ambientes urbanos sombreados, selecionamos um coeficiente $\beta = 4.5$ ou $\beta = 5.5$.

Tabela 1 – Configuração dos Parâmetros de Canal e Sistema

Parâmetros	Valores Adotados
Tamanho das Amostras	$M \in \{10, 20, 50, 100\}$
Testes de Monte-Carlo	$T = 10000$
# Iterações do DAC	$k \in \{1, 2, 5\}$
# SUs	$N \in \{6, 10, 15, 20\}$
# PUs	1
Área da Rede	Quadrada $25 \times 25 \text{ m}^2$
Potência secundária transmitida	$P_s = 3 \text{ mW}$
Distância de referência	$d_{\text{th}} = 12.5 \text{ m}$
Coefficientes de perda de percurso	$\beta \in \{2.5; 3.5\}$ (urbano típico) $\beta \in \{4.5; 5.5\}$ (urbano c/ sombreamento)
Coefficiente perda de percurso de Ref.	$\beta_{\text{th}} = 3.5$
Desvanecimento Rayleigh	$\mathcal{CN}(0; 1)$
Potência de ruído	$\sigma_{ij}^2 = 1 \text{ nW}$

2.7.1 Topologia Ad-Hoc Secundária baseada nas SNRs dos Links de Comunicação

Nesta parte da análise numérica, geramos quatro redes diferentes com base nas condições do canal descritas pelos parâmetros resumidos na Tabela 1. Como esperado, variando o coeficiente de perda de percurso na faixa $\beta \in [2.5, 3.5, 4.5, 5.5]$ pode-se emular redes mais conectadas para valores mais baixos de β e redes mais esparsas selecionando grandes valores de β (QUAN; KAISER; SAYED, 2009). A Figura 2 representa a rede com a respectiva vizinhança indicada por linhas azuis para diferentes coeficientes de perda de percurso. Para $\beta = 2.5$, a rede resultante está quase totalmente conectada. Com uma perda de percurso de $\beta = 3.5$, a vizinhança da rede torna-se mais esparsa, resultando na exclusão do 6-th SU na decisão baseada em consenso; obviamente com impacto negativo na taxa de convergência e também na cooperação em geral. Esta rede tem apenas quatro arestas para cinco SUs. Comportamento similar pode ser observado nas outras duas redes.

Além disso, para caracterizar diferentes tamanhos de rede, também consideramos um número diferente de nós. A Figura 3 mostra redes com 10, 15 e 20 SUs considerando o coeficiente de perda de percurso como $\beta = 2.5$. O usuário primário não está incluído na figura para evitar algumas confusões, porém, a posição do PU é a mesma da Figura 2.

2.7.2 Critério de Convergência baseado em NMSE

A análise de convergência é fornecida pela implantação do critério de erro quadrático médio normalizado (NMSE), definido como

$$\text{NMSE} = \frac{\sum_{i=1}^N |T_i - \bar{T}|^2}{N \sum_{i=1}^N T_i^2}, \quad (2.44)$$

sendo \bar{T} o valor médio do teste estatístico que representa o verdadeiro valor do DAC, e T_i é o valor do teste estatístico do i -th SU, que depende do número de iterações. Assim, o

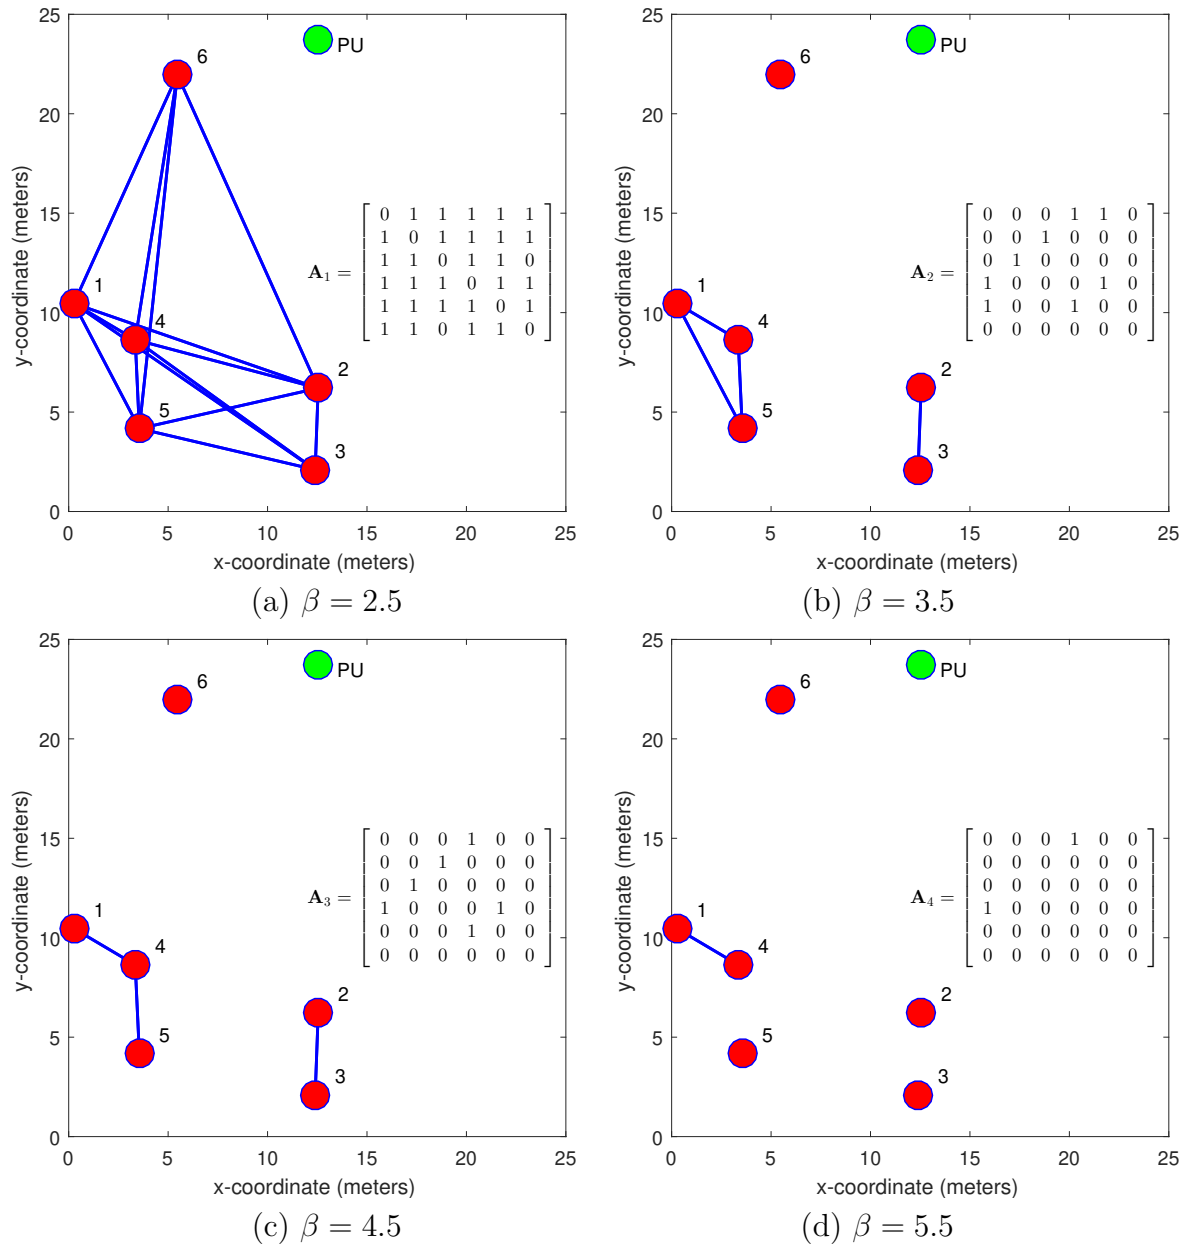


Figura 2 – Topologia de Rede com $N = 6$ SUs e 1 PU para diferentes coeficientes de perda de percurso; a matriz de adjacência A_i é indicada.

Fonte: Autoria própria.

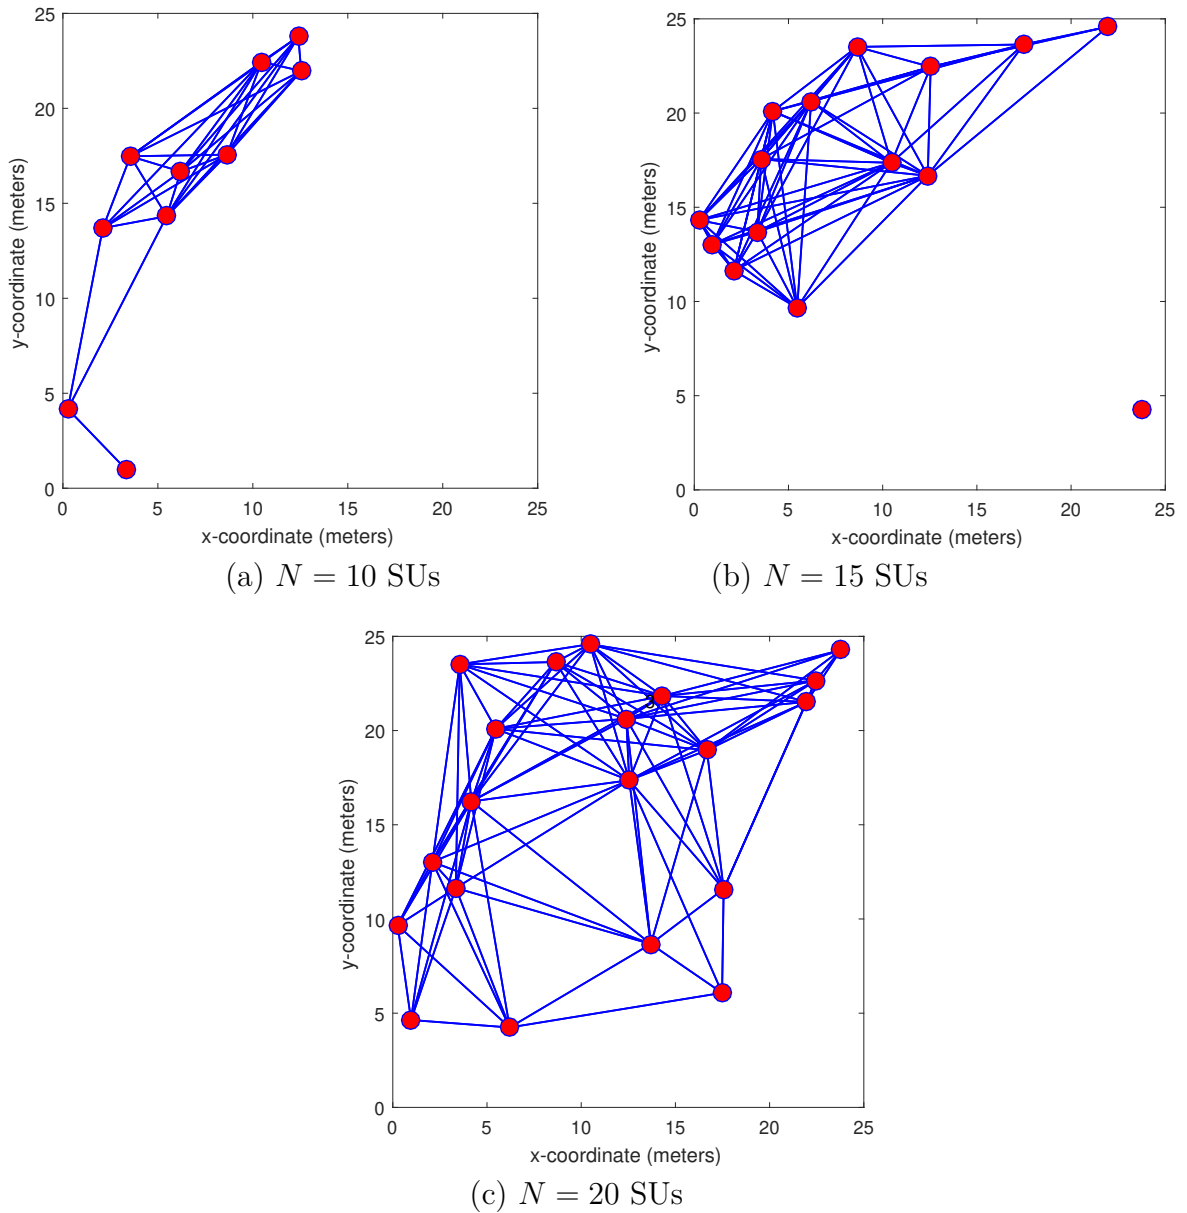


Figura 3 – Topologias de Rede com $N = 10, 15$ e 20 SUs para o coeficiente de perda de percurso $\beta = 2.5$. Fonte: Autoria própria.



NMSE em função do número de iterações é representado na Figura 4.(a). Assim, dada uma rede caracterizada pela matriz de adjacência \mathbf{A}_1 na Figura 2.(a), o consenso pode ser alcançado com um $\text{NMSE} = 10^{-4}$ usando menos iterações ($\simeq 4$). Por outro lado, as demais redes esboçadas na Figura 2 não atingiram bons valores de NMSE, ou seja, 10^{-1} ou menor, caracterizando baixa taxa de convergência e considerável impacto negativo no desempenho do CSS. A Figura 4.(b) mostra o desempenho em termos de ROC para o DAC em comparação com duas outras regras de combinação. As regras escolhidas são a EGC (regra suave) e OR (regra abrupta) para o CSS centralizado. Nós usamos $M = 100$ amostras; como esperado, o critério OR tem o pior desempenho seguido pelo desempenho semelhante das regras de consenso e EGC.

Além disso, a convergência do DAC por meio da evolução do teste estatístico dos SUs (teste estatístico do ED) variando o número de iterações é mostrada na Figura 5, onde a convergência do CSS pode ser analisada sob a perspectiva de diferentes coeficientes de perda de percurso utilizando a saída dos EDs, que é equivalente ao teste estatístico como critério. Pode-se observar que para valores de coeficiente de perda de percursos baixo, a convergência do DAC é garantida e um bom desempenho do CSS é esperado, enquanto que para coeficientes de perda de percursos com alto valores influenciam na conectividade que é severamente afetada.

Para complementar a análise de convergência do CSS, a Figura 6 mostra a convergência em termos do resultado do ED (teste estatístico em dB) em função do número de iterações para ambos os limites de α , dado pela equação (2.4). Pode-se observar que se o tamanho de passo de iteração assume valores baixos ($0 \lesssim \alpha$), obtém-se uma convergência para o consenso muito lenta, que do ponto de vista prático impactará no rendimento dos CRs. Assim, a melhor opção é escolhida para o tamanho do passo de iteração maior possível respeitando a regra, próximo ao limite superior $\frac{1}{\max(\text{diag}(\mathbf{L}))}$, determinado pelo valor da regra MD.

2.7.3 ROC para o CSS baseado em DAC utilizando diferentes Topologias de Rede

Os efeitos da topologia da rede no desempenho em termos de ROC, ou seja, uma figura de mérito conectando a probabilidade de detecção e falso alarme (KAY, 1998) são analisados nesta subseção. O efeito de um número limitado de iterações é avaliado e o desempenho do consenso dos SUs locais operando sob um número reduzido de iterações também é quantificado. A Figura 7 (a) representa o desempenho em termos de ROC variando a topologia da rede; como esperado, para redes esparsas (maiores β), o desempenho da rede piora. Novamente, o melhor desempenho possível é alcançado pela rede com matriz de adjacência \mathbf{A}_1 , resultando em um $P_d \simeq 0.9$ para $P_f \simeq 0.1$. Além disso, simulações numéricas na Figura 7 validam as expressões analíticas (2.30) e (2.31), apresentando excelentes resultados de ajuste de desempenho entre os resultados teóricos e as simulações

(a) NMSE em função do número de iterações, k 

(b) ROC para o DAC, EGC e a regra OR

Figura 4 – Convergência em termos de NMSE para diferentes matrizes de adjacência geradas pelo conjunto de coeficientes de perda de percurso. ROC comparando as regras de combinação DAC, EGC e OR para a matriz de adjacência \mathbf{A}_1 com $k = 5$ iterações e $M = 100$ amostras.

Fonte: Autoria própria.

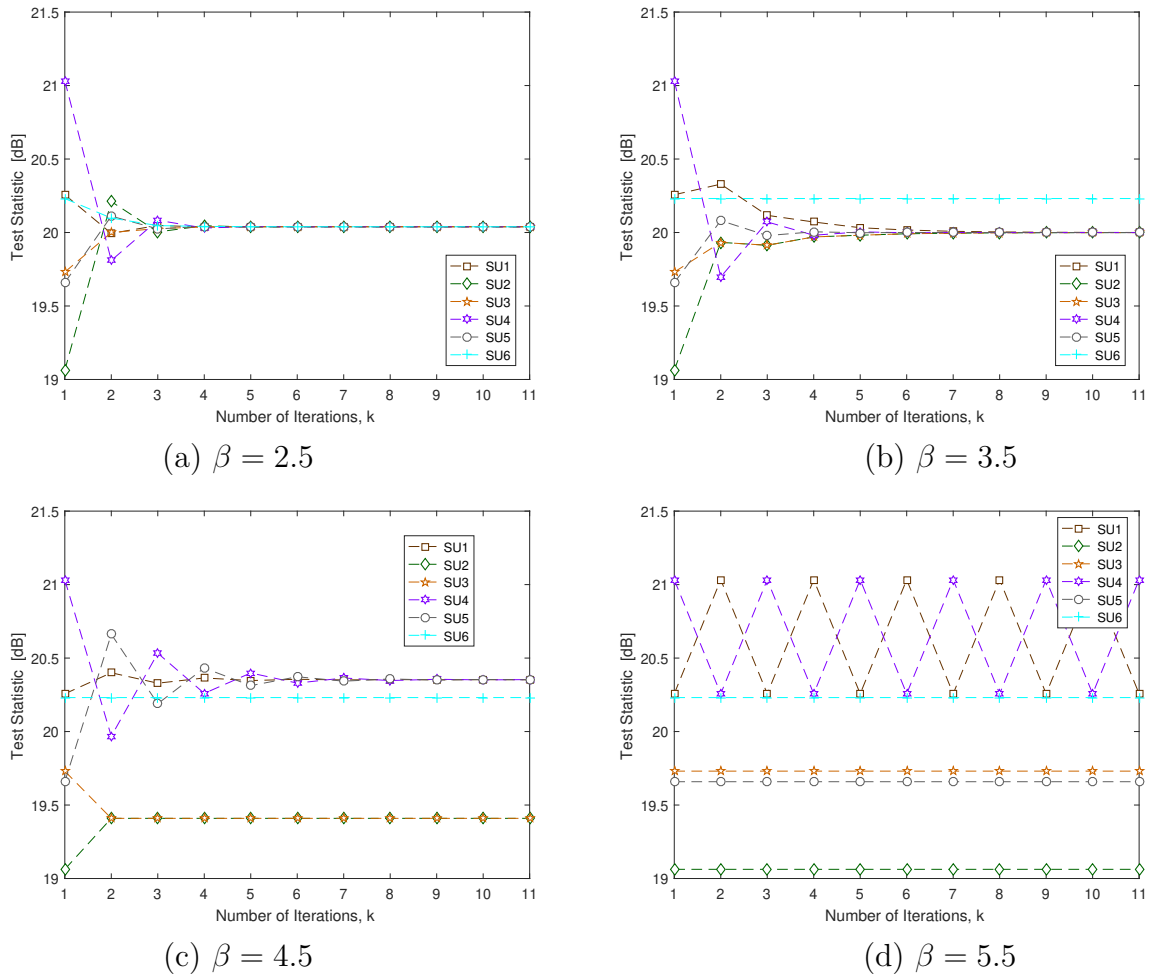


Figura 5 – Convergência em termo da saída do ED representado pelo teste estatístico em dB em função do número de iterações, k para o conjunto dos coeficientes de perda de percurso.

Fonte: Autoria própria.

de Monte Carlo.

Além disso, a dependência da convergência do DAC em relação ao número de iterações é analisada na Figura 7 (b), (c) e (d), respectivamente, considerando 1, 2 e 5 iterações. O desempenho em termos de ROC para os nós (SUs) 2, 4 e 6 é melhorado quando o número de iterações aumenta. Como esperado, o desempenho do CSS é divergente para um número reduzido de iterações, mas melhora substancialmente quando o número de iterações se aproxima da condição de convergência. Neste caso, todas os SUs resultam em desempenho similar, implicando que todas os SUs alcançaram a mesma decisão final. Por enquanto, por conveniência, consideramos que a rede atinge o consenso e escolhemos apenas um SU para a análise dos parâmetros.

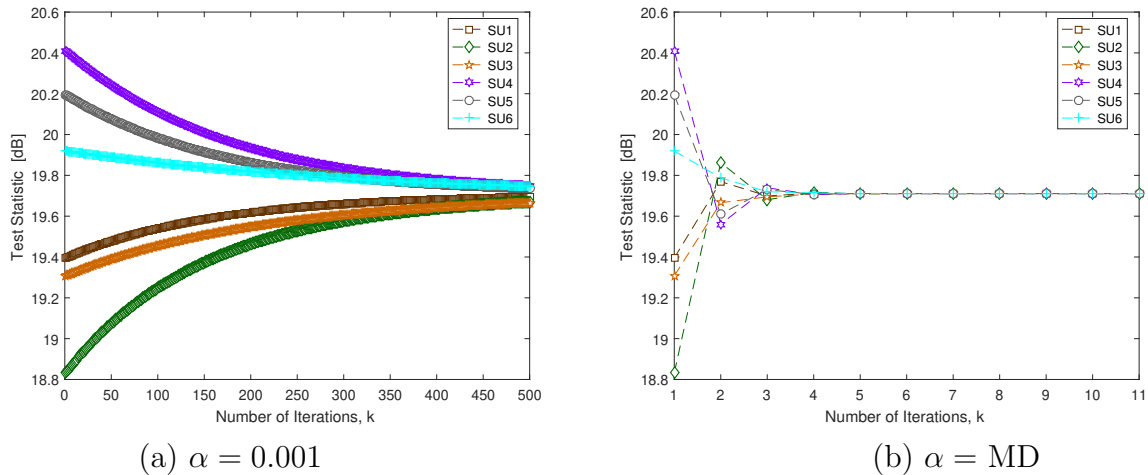


Figura 6 – Convergência em termos do teste estatístico (em dB) em função do número de iterações usando: a) limite próximo ao inferior $\alpha = 0.001$; e b) valor dado pela regra MD. Coeficiente de perda de percurso $\beta = 2.5$.

Fonte: Autoria própria.

2.7.4 Probabilidade de Detecção, Falso Alarme e Erro em termos do Limiar de Decisão

Nesta seção, analisamos o efeito do limiar de decisão λ_i sobre o desempenho do SS. Na Figura 8 usamos um método empírico para escolher o limiar (rotulado simplesmente como “Limiar” na figura). Assim, variando em uma grande faixa os valores de energia e detectando qual faixa gera valores significativos para as probabilidades de detecção, falso alarme e erros, pode-se determinar o valor ideal para λ_i pela busca exaustiva. Para obter mais informações, aqui, comparamos o desempenho da CRAN alcançado pelo limiar de decisão empírico com o desempenho obtido pelo limiar analítico definido pela equação (2.33). Observe que o limiar analítico em (2.33) resultou bem ajustado aos valores empíricos (simulados). Assim, pode-se inferir que tanto os limiares simulados quanto os analíticos seguem o critério NP, ou seja, o limiar de decisão que maximiza a probabilidade de detecção quando a probabilidade de falso alarme é fixa (KAY, 1998). Como resultado, o desempenho do CSS em termos de falso alarme e falhas é dependente da topologia da rede, piorando sob maior coeficiente de perda de percurso, como pode ser visto na Figura 8. Observe que para $\beta = 2.5, 3.5, 4.5$ e 5.5 , o limiar ótimo é de aproximadamente 13, no entanto, o desempenho alcançado não é o mesmo resultando aproximadamente $P_f = 0.1$ para $\beta = 2.5$ e 3.5 e aproximadamente $P_f = 0.2$ para $\beta = 4.5$ e 5.5 . Nos próximos resultados, discutiremos que este valor é o limite ótimo para minimizar a probabilidade de erro para uma rede com 6 SUs dada pela equação (2.42).

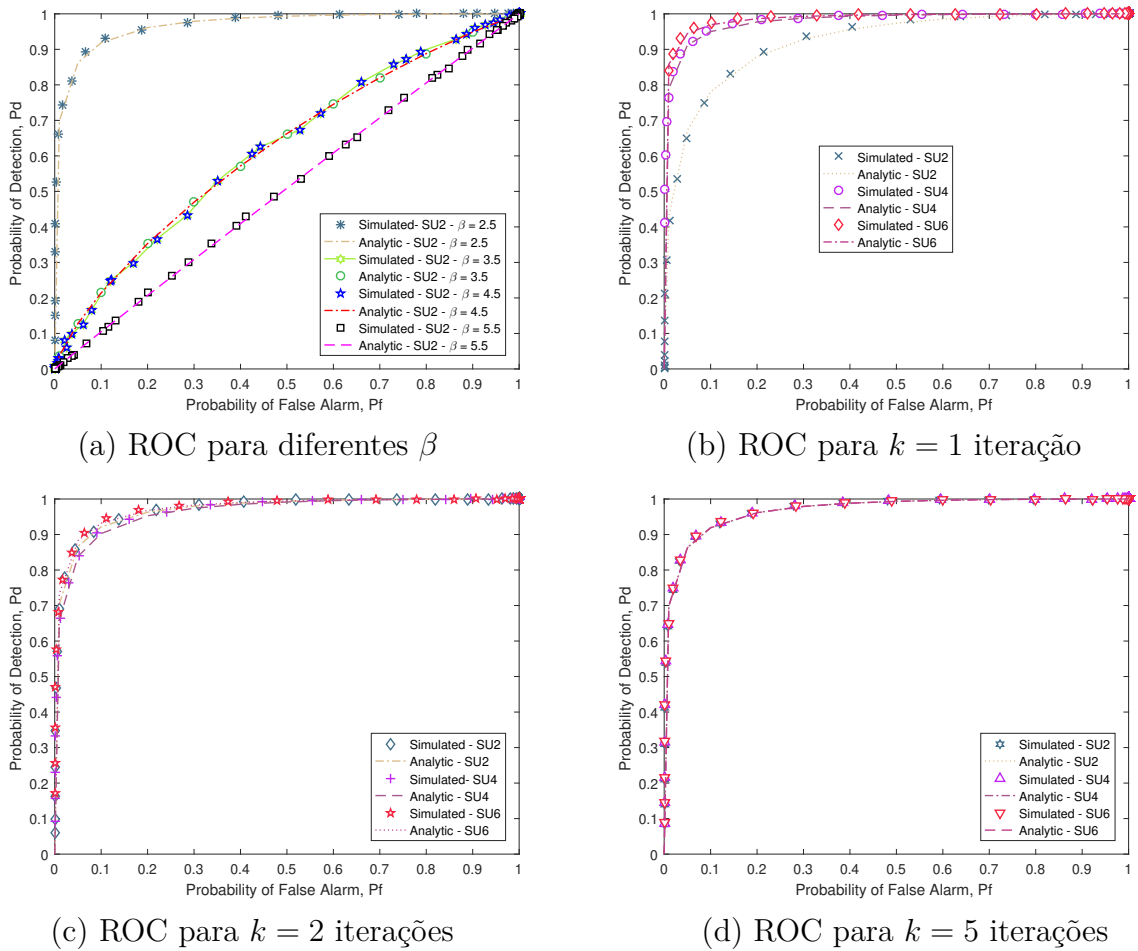


Figura 7 – **a)** ROC simulada e analítica, equação (2.30), para o nó $i = 2$ com $k = 5$ iterações e diferentes matrizes de adjacência geradas pelo conjunto de coeficientes de perda de percurso; **b), c), d)** ROC simulada e analítica para $k = 1, 2$ e 5 iterações, respectivamente utilizando os nós $i = 2, 4$ e 6 para um $\beta = 2.5$.
Fonte: Autoria própria.

2.7.5 Número de Amostras em função das Probabilidades de Detecção, Erro e Limiar de Decisão

Outro parâmetro importante que deve ser otimizado no SS é o número de amostras coletadas. No caso do ED, o número de amostras impacta diretamente no tempo de sensoriamento, o que constitui outra importante figura de mérito quando a qualidade de serviço dos SUs é analisada em termos de capacidade de transmissão. Se o tempo de sensoriamento for alto, restará menos tempo para estabelecer uma comunicação eficaz (reduzindo a capacidade de transmissão). Levando em consideração este fato, é muito importante descrever o desempenho do CSS em termos do número de amostras. Uma análise interessante pode ser realizada usando (2.37), na qual é obtido o número mínimo de amostras para um falso alarme de referência específico e probabilidades de detecção específicas. Para apoiar esta constatação, foram simuladas curvas de probabilidade de detecção em função do tamanho das amostras; topologias de rede com 6, 10, 15 e 20 SUs,

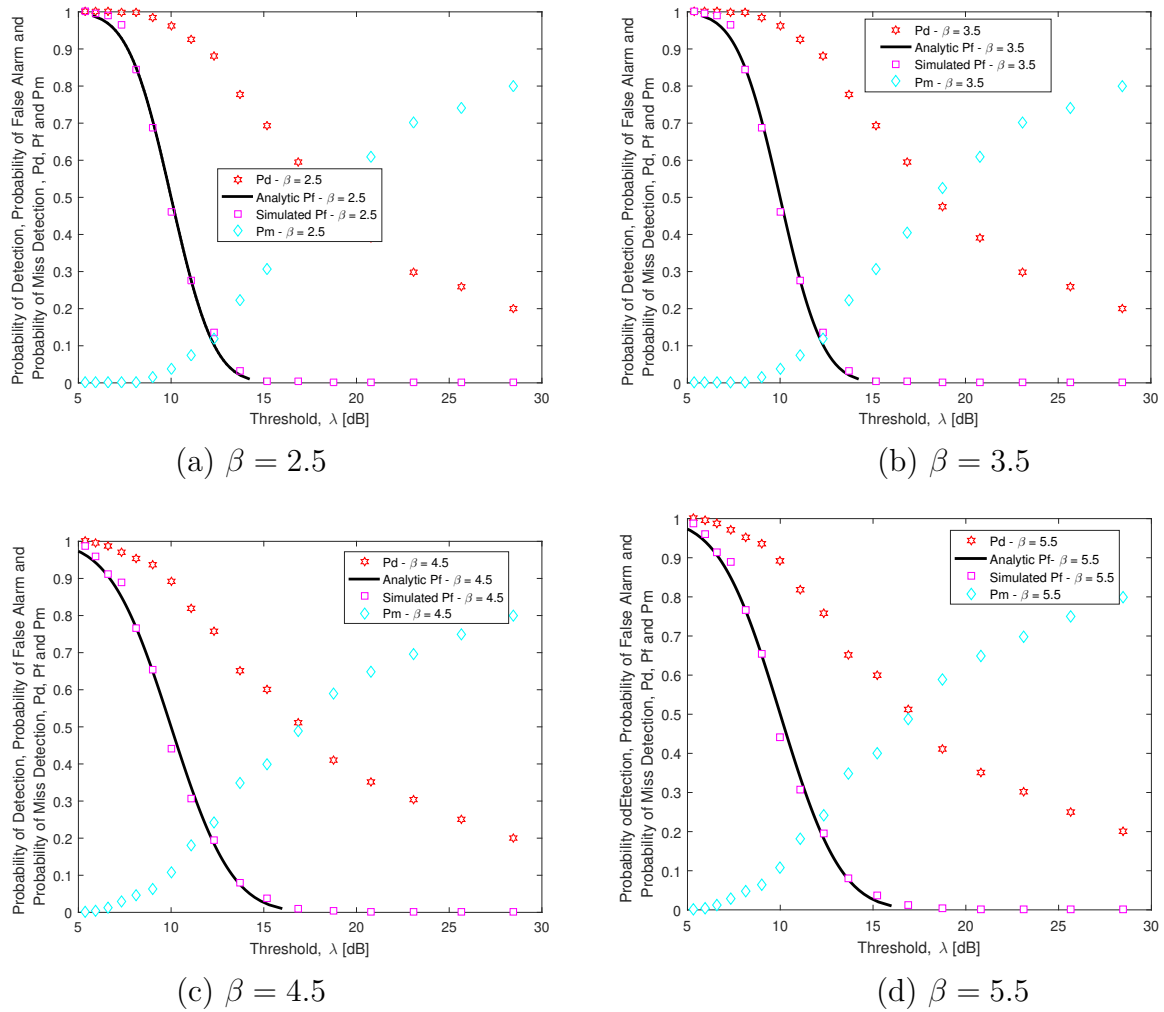


Figura 8 – Limiar simulado em função do Limiar analítico, comparados em termos de probabilidade de detecção (P_d), probabilidade de falso alarm (P_f) e probabilidade de falha (P_m) para $k = 5$ iterações em uma rede sujeita a diferentes coeficientes de perda de percurso $\beta = 2.5, 3.5, 4.5, 5.5$.

Fonte: Autoria própria.

conforme descrito nas Figuras 2 e 3 foram utilizadas. A Figura 9 corrobora que para 6 SUs temos um $P_d = 0.9$ para $M \simeq 11$ quando $P_f = 0.01$; enquanto para $M \simeq 10$ quando $P_f = 0.1$, e $M \simeq 6$ quando $P_f = 0.2$. Assim, quando a rede apresenta mais nós o número necessário de amostras é menor, como pode ser visto em 10, 15 e 20 SUs.

Do ponto de vista prático, o limiar de decisão ótimo é interessante para otimizar o desempenho do CSS usando simplesmente um nível de energia constante que pode ser gerado por circuitos elétricos comuns. O efeito do limiar na probabilidade de erro é representado na Figura 10 em termos de a) número de amostras; b) tamanho da rede. Assim, para uma rede com 6 SUs e $M = 10$ amostras, Figura 10 (a), o limiar de decisão ideal para garantir a probabilidade de erro mínima é $\lambda^* \approx 13$. Este valor cresce progressivamente quando o número de amostras aumenta de $M = 10$ para 100. Isso ocorre porque o limiar é

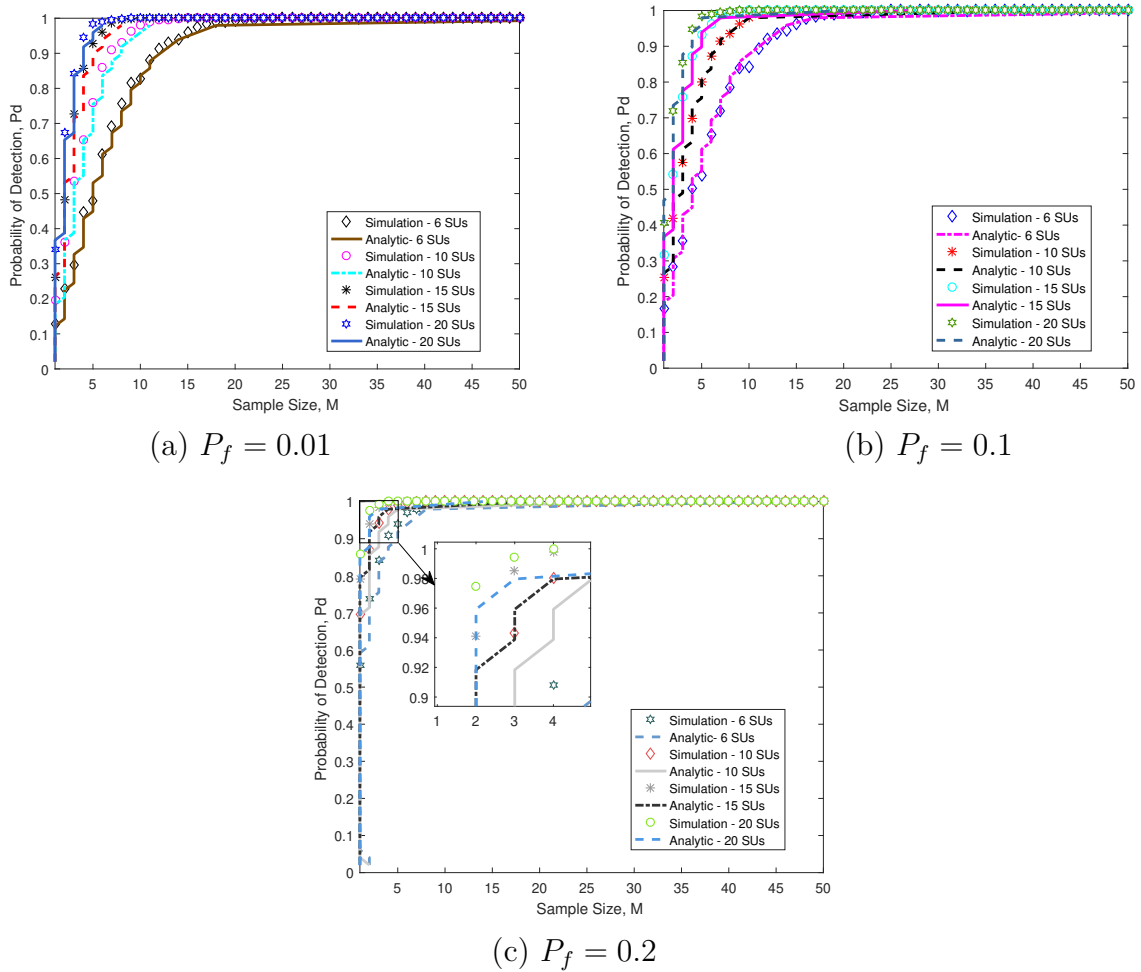


Figura 9 – Probabilidade de detecção simulada e analítica (P_d) em função do número de amostras (M), equação (2.33), para $k = 5$ iterações e uma rede sujeita a diferentes probabilidades de falso alarme de referência: **a)** $P_f = 0.01$; **b)** $P_f = 0.1$; e **c)** $P_f = 0.2$, considerando SUs $\in [6; 10; 15; 20]$.
Fonte: Autoria própria.

um valor de energia e com mais amostras avaliadas pelo detector ED, mais energia está disponível para comparação com algum limiar. Pode-se observar também que quando M aumenta, a probabilidade de erro diminui. Além disso, a Figura 10 (b) mostra o efeito do tamanho da rede (número de SUs) sobre a probabilidade de erro em função do limiar; aqui, definimos $M = 10$ amostras e $N = 6, 10, 15$ e 20 SUs. Como resultado, pode-se observar que o valor de limiar ótimo é quase o mesmo para todos os tamanhos de rede considerados, ou seja $\lambda^* \approx 13$, e apenas dependente do número de amostras coletadas. No entanto, com mais nós cooperativos o desempenho é melhor em termos de probabilidade de erro, levando a valores de probabilidade de erro muito baixos ($\simeq 0.03$) para 20 SUs.

Por fim, para corroborar a validade da expressão analítica para o limiar ótimo, equação (2.42), a probabilidade de erro em função do número de amostras M foi comparado na Figura 11 considerando diferentes tamanhos de rede e um intervalo de número de

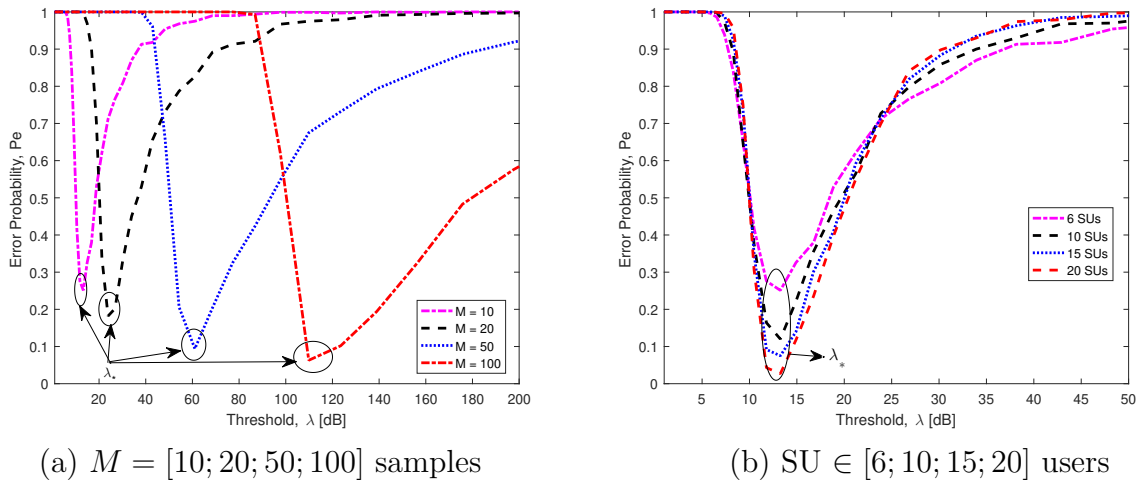


Figura 10 – Probabilidade de erro (P_e) em função do limiar de detecção (λ), para $k = 5$ iterações e coeficiente de perda de percurso $\beta = 2.5$. Limiar ótimo (λ^*) determinado a partir de (2.42).

Fonte: Autoria própria.

amostras. A partir da figura, pode-se confirmar um bom ajuste das curvas analíticas com os valores simulados correspondentes, validando a expressão derivada para o limiar ótimo, que é dependente do tamanho da amostra. De fato, para obter mais informações sobre a expressão (2.42), o NMSE entre as curvas analítica e simulada, dado por $NMSE^{P_e} = \frac{\sum_{i=1}^M |P_e^{an} - P_e^{sim}|^2}{M \sum_{i=1}^M P_e^{an2}}$, é determinado na Tabela 2. Como resultado, para todos os cenários considerados na Figura 11, um $NMSE \approx 10^{-4}$ é atingido, corroborando a validade da expressão de limiar de decisão proposta.




Figura 11 – Probabilidade de erro simulada e analítica (P_e) em função do número de amostras (M), para $k = 5$ iterações, $\beta = 2.5$ e $N \in [6; 10; 15; 20]$ SUs.

Fonte: Autoria própria.

Tabela 2 – Erro quadrático médio normalizado (NMSE^{P_e}) para curvas de probabilidade de erro analíticas e de simulação da Figura 11

# SUs	$M = 10$	$M = 20$	$M = 30$	$M = 40$	$M = 50$
6	1.1664×10^{-4}	1.2144×10^{-4}	1.1553×10^{-4}	1.1664×10^{-4}	1.1933×10^{-4}
10	9.3636×10^{-4}	9.2877×10^{-4}	9.5217×10^{-4}	9.2119×10^{-4}	9.1239×10^{-4}
15	7.7587×10^{-4}	7.2356×10^{-4}	7.2557×10^{-4}	7.9661×10^{-4}	7.1527×10^{-4}
20	3.4484×10^{-4}	3.2516×10^{-4}	3.4382×10^{-4}	3.5289×10^{-4}	3.2467×10^{-4}

2.8 Conclusões

Os resultados de simulação mostraram a validade das expressões numéricas desenvolvidas e uma série de análises pertinentes puderam ser realizadas a partir destes resultados. Resultados de probabilidades de detecção, falso alarme e erro além dos resultados para o tamanho das amostras e limiar de detecção são de extrema importância para se determinar a performance em SS. Além disso, outro importante resultado possível a partir desta análise consiste na determinação do limiar de detecção ótimo o qual permite minimizar a probabilidade de erro total.

3 OTIMIZAÇÃO DO SENSORIAMENTO ESPECTRAL EM REDES COGNITIVAS COM ELEVADO NÚMERO DE ANTENAS DESCALIBRADAS

3.1 Introdução

As redes 5G exigem simultaneamente a transmissão e recepção de altas taxas de dados, baixo consumo de energia, alta confiabilidade e baixa latência de comunicação. Uma das principais técnicas estudadas e aplicadas em sistemas de comunicação sem fio 5G é o uso de antenas massivas ou mesmo extragrandes para transmissão ou recepção de comunicação, ou seja, sistemas MIMO massivo e XL-MIMO, respectivamente. O artigo seminal de Marzetta (MARZETTA, 2010) propõe o uso de um grande número de antenas em sistemas de comunicações e mostra seus benefícios. Além disso, como visto no capítulo 2 o CR, proposto por Mitola, (MITOLA; MAGUIRE, 1999; HAYKIN, 2005) é outra tecnologia que proporciona alta SE em sistemas de comunicação por meio do acesso dinâmico ao espectro (*dynamic access spectrum*, DAS). O DAS é implementado usando os SUs que transmitem de forma oportunista no espectro do usuário licenciado.

Como visto no capítulo 2 desta Tese, uma das tarefas mais importantes no CR é o SS, que é a estimativa dos parâmetros do espectro para determinar o nível de ocupação do usuário primário. Um dos maiores desafios no SS de múltiplas antenas é o problema do receptor/sensor descalibrado, que é uma característica importante das antenas massivas, resultando em baixa fidelidade para reduzir custos de implementação. O problema do receptor descalibrado consiste nos diferentes níveis de potência de ruído detectadas em cada antena individual, portanto, a potência do SS pode diminuir substancialmente em certos cenários de interesse. Observe que a avaliação das imperfeições práticas são muito importantes para a implementação bem sucedida das tecnologias baseadas em CRs. As principais imperfeições que podem ocorrer nos sistemas CR mais amplamente utilizados, bem como possíveis abordagens para mitigar tais imperfeições são discutidas amplamente em (AKYILDIZ; LO; BALAKRISHNAN, 2011).

Progressos e desafios para o SS distribuído em redes de CR são abordados em (HERNANDES; JR; ABRAO, 2018). Especificamente, em (HERNANDES; JR; ABRAO, 2018), é proposta uma técnica de consenso médio ponderado totalmente distribuído (*improved weighted average consensus*, IWAC) aplicada ao CSS em redes de CRs. Este método permite que os usuários secundários cooperem com base apenas na troca de informações locais sem a necessidade de um FC. Dois novos esquemas de SS baseados em DAC foram comparados em termos de desempenho e complexidade, enquanto a convergência do algoritmo é avaliada para cenários de comunicação móvel fixos e dinâmicos, bem como sob canais puramente AWGN e canais com desvanecimento Rayleigh. Além disso, em (DEY et al., 2020) uma técnica de SS usando o FC foi investigado no contexto

do CSS de banda larga baseado em sistemas *orthogonal frequency division multiplexing* (OFDM). O sistema implementa um FC equipado com múltiplas antenas de recepção. Três regras de reversão de tempo para o FC foram propostas para mitigar os efeitos do canal em banda larga, tais como o desvanecimento seletivo de frequências e a interferência entre as portadoras.

Nos últimos anos, vários métodos de SS em sistemas cognitivos munidos de múltiplas antenas foram propostos. Em (ZENG; LIANG, 2009a), um detector baseado no maior e menor autovalores da matriz de covariância (*maximum-minimum eigenvalue*, MME) foi proposto para explorar as informações dos autovalores da matriz de covariância de sinal primário e do ruído do canal de comunicação. Este detector é cego, ou seja, não necessita de informações extras relativas ao sinal primário, tais como, amplitude, fase, tipo de modulação, correlação, etc e é muito robusto em cenários degradados pelo desvanecimento; no entanto, possui uma alta complexidade computacional em comparação com o ED, dado que necessita realizar o cálculo da decomposição em autovalores da matriz de covariância. Além disso, o detector MME não é robusto para detectar a ocupação do espectro quando as antenas estão descalibradas, o que representa um cenário prático importante de aplicação e de muito interesse em sistemas 5G como visto anteriormente.

Outros dois detectores representativos em cenários com múltiplas antenas são o detector aritmético-geométrico (*arithmetic-to-geometric mean*, AGM) e o detector de John (*John's detector*, JD). No entanto, ambos os detectores possuem alta complexidade computacional e são muito sensíveis aos cenários de receptores descalibrados (HUANG et al., 2015). Além disso, um detector promissor chamado detector de covariância (*covariance detector*, CAV) foi proposto em (ZENG; LIANG, 2009b) e tem as mesmas propriedades dos detectores baseados em autovalores, ou seja, cego e robusto aos efeitos de desvanecimento do canal, com a vantagem de possuir uma menor complexidade computacional. Além disso, o detector CAV demonstrou robustez em configurações de antenas descalibradas, tornando-se um candidato interessante a ser aplicado em tais cenários.

O detector de Hadamard (*Hadamard detector*, HD) para aplicações em SS foi estudado em (HUANG; XIAO; ZHANG, 2015), pode operar no modo cego, sendo robusto em cenários com desvanecimento; possui a capacidade de tratar com as configurações de antenas descalibradas. Em (HUANG et al., 2015), os autores propuseram o detector de volume (*volume detector*, VD) que também é capaz de operar com receptores descalibrados. No entanto, tanto o HD quanto o VD resultam em uma alta complexidade computacional e expressões analíticas para as métricas de performance, tais como, probabilidade de detecção e falso alarme são muito complicadas matematicamente (fazendo uso de funções especiais, tais como, a função Gama) para serem implementadas em sistemas que requerem a rápida e expedita otimização destes parâmetros.

Além disso, as principais técnicas de SS e os avanços mais recentes foram explorados

na pesquisa do artigo (ALI; HAMOUDA, 2017). Outra tendência importante com resultados relevantes em aplicações de SS é baseada em métodos de aprendizado profundo (*deep learning*, DL). Em (LIU et al., 2019) os autores aplicam a técnica baseada em aprendizado chamada rede neural convolucional (*convolutional neural network*, CNN) em SS, resultando em uma opção promissora mesmo em cenários com SNR muito baixa (na faixa de valores entre -15 a -20 dB). A análise e otimização de SS em sistemas MIMO massivos são muito escassas na literatura. Um esquema usando um grande número de antenas para sensoriar o espectro e outro que seleciona apenas um certo número de antenas, enquanto o restante do conjunto massivo de antenas é usado para transmitir em um modo de compartilhamento de espectro, aumentando a SE geral do sistema, são analisados em (KOBESSI et al., 2019). Além disso, os autores consideram o uso de detectores baseados nos autovalores da matriz de covariância. Diferentemente de (KOBESSI et al., 2019), aqui neste capítulo, consideramos cenários com antenas massivas descalibradas e uma análise geral da otimização da probabilidade de erro aplicando os detectores HD, VD e CAV.

Recentemente, a tecnologia MIMO massiva tem sido investigada e agregada ao SS em redes de CRs. Em (WEI et al., 2020) os autores investigam o papel dos sensores multiantenas na melhoria do desempenho de detecção da rede primária, implantando uma rede de SS multiantenas baseada em MIMO massivo distribuído. A política de alocação de sensores de potência baseada no método de multiplicadores de direção alternada (*alternating direction method o multipliers*, ADMM) é estabelecida com o objetivo de alcançar uma maior probabilidade de detecção. Além disso, apenas o estado estatístico do canal é necessário em cenários de antenas massivos, o que evita a enorme sobrecarga de informações de estado do canal (*channel state information*, CSI). Em (DEY; CIUNZO; ROSSI, 2020), uma FC equipada com um grande conjunto de antenas, atendendo a um número de usuários secundários que competem pelo espectro, é implantado para realizar CSS baseado em transmissão OFDM em redes com alta densidade de usuários. O receptor do canal de comunicação no FC está equipado com a reversão de tempo amplamente linear (*time reverse-widely linear*, TR-WL) e combinação da máxima razão de reversão no tempo (*time reverse-MRC*, TR-MRC) como regras para a fusão de dados. Ambos os detectores de regras de combinação baseados em TR demonstram eficácia no combate à interferência inter-símbolo e interportadora em relação aos equivalentes convencionais (não-TR). Os efeitos do canal nas regras de fusão propostas pelos autores são investigados através de simulações de Monte-Carlo. Além disso, o desempenho com expressões matemáticas (falso alarme e probabilidades de detecção) é derivado para as regras de fusão propostas. Aspectos práticos da implantação do FC distribuído baseado em MIMO massivo virtual para SS de banda larga colaborativa (*wide CSS*, WCSS) em redes de CRs são discutidos em (DEY; CIUNZO; ROSSI, 2020). Uma medição em campo foi realizada para capturar as estatísticas de propagação de canais MIMO massivos com 4×64 antenas em subportadoras de 20 MHz em uma configuração do tipo OFDM. Uma Regra de fusão baseada na razão de

verossimilhança e três conjuntos diferentes de regras de fusão subótimas, conjuntamente com regras de reversão no tempo (As versões TR visto anteriormente) são formuladas para combinar decisões sobre a disponibilidade de cada subportadora transmitida pelos SUs. As características do canal extraídas são incorporadas na análise de desempenho das regras de fusão para comparação e teste de validade do FC distribuído em cenário com aplicação de CSS realistas.

O problema de SS em redes de CRs com receptores equipados com múltiplas antenas descalibradas, levando em consideração a covariância padrão e a informação de covariância complementar do sinal não circular, é abordada em (CHEN; SHI, 2020; CHEN et al., 2021). Um novo método de SS robusto baseado na covariância não circular é proposto, levando em consideração a propriedade estatística dos sinais não circulares. Os autores derivam a distribuição estatística assintótica sob a hipótese de ausência de sinal primário e obtêm o limiar teórico de decisão para o método proposto. Em (POURGHAREHKHAN; TAHERPOUR; GAZOR, 2019), os autores propõem dois novos detectores aplicados em SS, a saber, o teste de Rao (bem conhecido em teoria de decisão estatística) e o teste SFET (*separating function estimation test*) para o SS operando em sistemas com antenas descalibradas. Expressões matemáticas para as probabilidades de detecção e falso alarme para o Teste Rao e expressões aproximadas para o teste SFET são derivadas, enquanto simulações de Monte-Carlo confirmam a validade das expressões propostas. Em (JALALI; ZAIMBASHI, 2020) é proposto um teste robusto e cego para SS em sistemas com múltiplas antenas com a propriedade (que aliás é obrigatória quando se projeta um novo teste estatístico) de taxa de falso alarme constante (*constant false alarm rate*, CFAR) baseado no teste de razão de verossimilhança sob antenas recebidas descalibradas e combinado com o problema de IQ desbalanceado no Tx. e Rx. Simulações de Monte-Carlo demonstram a superioridade do detector proposto comparado com os detectores de literatura de última geração. Por fim, os autores em (TAHERPOUR; TOGHRAEI, 2019) propõem um novo método para SS em sistemas com múltiplas antenas para sistemas com CRs baseado no teste de Rao complexo. Casos especiais de matrizes de covariância foram estudados; o primeiro caso é um sistema de antena calibrado, ou seja, com variações de ruído na entrada das antenas conhecidas; o outro caso implantando antenas descalibradas com variações de ruído desconhecidas.

3.1.1 Contribuições

Inicialmente, propomos dois modos de operação possíveis para o SS em sistemas cognitivos munidos de múltiplas antenas massivas, a saber o modo que privilegia a eficiência espectral(SE), e o modo de operação que privilegia a eficiência energética (EE). Tais modos são definidos dependendo da proporção entre o número de antenas e o número de amostras do sinal primário disponíveis para o SS. Propomos também um procedimento empírico rápido para obter expressões simples para a probabilidade de detecção e falso alarme

considerando os detectores CAV, HD e VD. O procedimento invoca o teorema do limite central (*central limit theorem*, CLT) e as expressões resultantes podem ser escritas como funções Q. Além do mais, propomos um procedimento iterativo com o objetivo de resolver o problema de otimização do limiar de decisão para atingir um determinado desempenho de detecção e falso alarme e minimizar a probabilidade de erro baseado no algoritmo de programação quadrática sequencial (*sequential quadratic programming*, SQP).

3.2 Modelo de Sistema

Neste capítulo a topologia de rede sem fio adotada consiste de uma estação radio-base (*base-station*, BS) para os SUs que realiza o SS. O sistema secundário opera sem um FC (dado que a própria BS secundária funciona como um FC, só que empregando múltiplas antenas massivas e empregando técnicas de SS para sistemas MIMO, portanto, podemos enxergar o processo que emprega múltiplas antenas para SS como um procedimento de CSS) e é equipado com um total de M antenas massivas, que coletam MN amostras de sinal primário, onde N é o número de amostras coletadas por antena, de uma única fonte primária equipada com uma única antena. A Figura 12 apresenta a topologia geral da rede PU e SU com a BS equipada com *massive* MIMO, evidenciando aspectos da camada física para o problema SS considerado neste capítulo.




Figura 12 – Topologia para a redes primária e rede secundária munida de uma BS equipada com um número massivo de antenas.

Fonte: Autoria própria.

A macroestrutura temporal da camada de controle de acesso (*medium access control*, MAC) adotada neste capítulo é mostrada na Figura 13 (LIANG et al., 2008). Há K frames de duração T segundos cada. No k -ésimo frame, τ [sec] são dedicados ao sensoriamento espectral, contendo N amostras com duração T_s [sec] cada. Assim, $T - \tau$ [sec] são dedicados à transmissão de informação em cada frame. De fato, na etapa de transmissão de dados, os SUs se comunicam entre si via SU BS equipada com número massivo de antenas em uma porção do tempo de quadro (*frame*) $T - \tau$, sendo $\tau = \frac{N}{f_s}$ o período de sensoriamento.

Considerando a estrutura de sinais, na etapa de SS, o sinal recebido na BS secundária pode ser escrito como

$$\mathbf{X} = \mathbf{A}hs + \mathbf{N}, \quad (3.1)$$

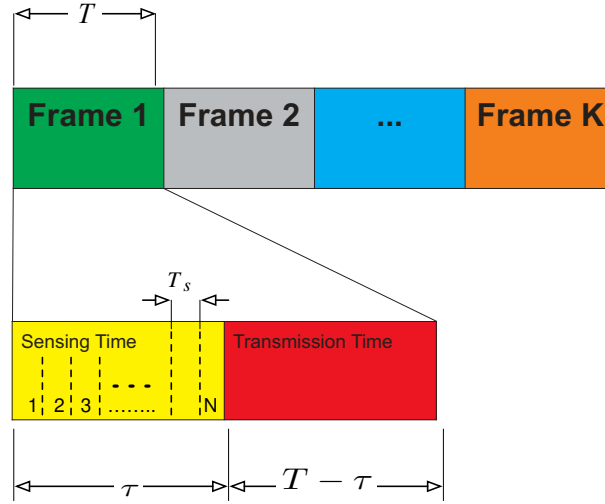


Figura 13 – Estrutura da Camada MAC adotada.
Fonte: Autoria própria.

sendo $\mathbf{X} \in \mathbb{R}^{M \times N}$ o sinal recebido na BS secundária, $\mathbf{A} \in \mathbb{R}^{M \times M}$ a matriz de amplitude do sinal primário definida como $\mathbf{A} = \text{diag} \left(\sqrt{\frac{p_i}{\bar{p}}} \right)$ dado o vetor de potências recebido em cada antena por $\mathbf{p} = [p_1, p_2, \dots, p_M]$ e seu valor médio $\bar{p} = \frac{1}{M} \sum_{i=1}^M p_i$; sendo que $\mathbf{h} \in \mathbb{C}^{M \times 1}$ é independente e identicamente distribuído (*independent and identically distributed*, i.i.d.), $\mathbf{s} \in \mathbb{C}^{1 \times N}$ é o vetor de N amostras do sinal primário transmitido, e $\mathbf{N} \in \mathbb{C}^{M \times N}$ é a matriz de amostras de ruído recebido na BS secundária.

O teste estatístico binário associado pode ser definido por duas hipóteses

$$\begin{cases} \mathcal{H}_0 : \mathbf{X} = \mathbf{N}, \\ \mathcal{H}_1 : \mathbf{X} = \mathbf{A}\mathbf{h}\mathbf{s} + \mathbf{N}. \end{cases} \quad (3.2)$$

Além disso, a matriz de covariância é definida como

$$\mathbf{R} = \mathbb{E}(\mathbf{X}\mathbf{X}^H), \quad (3.3)$$

sendo $\mathbf{R} \in \mathbb{C}^{M \times M}$ e $\mathbb{E}(\cdot)$ o operador esperança estatística. Seguindo esta definição, podemos reformular a hipótese binária em termos das matrizes de covariância do sinal recebido e do ruído como

$$\begin{cases} \mathcal{H}_0 : \mathbf{R} = \mathbf{R}_N, \\ \mathcal{H}_1 : \mathbf{R} = \mathbf{R}_S + \mathbf{R}_N, \end{cases} \quad (3.4)$$

onde \mathbf{R}_N é a matriz de covariância de ruído e \mathbf{R}_S é a matriz de covariância do sinal primário. Devido às propriedades estacionárias e de ergodicidade do sinal recebido, pode-se aproximar a matriz de covariância como uma média sobre as N amostras de sinal recebidas no sensoriamento:

$$\mathbf{R} \simeq \frac{1}{N} \mathbf{X}\mathbf{X}^H. \quad (3.5)$$

3.2.1 Receptores MIMO Massivos Descalibrados

A utilização de elementos de RF altamente escaláveis em sistemas com um grande número antenas, o baixo custo e o consumo de potência reduzido são fundamentais. Como consequência, as variâncias de ruído σ_n^2 resultam diferentes por refletir a tolerância potencial nos componentes da cadeia de antenas massivas de RF. Para a descrição teórica, consideramos que as variações de ruído à entrada da n -ésima antenadescalibrada do sistema secundário apresentam a seguinte propriedade:

$$\sigma_n^2 \neq \sigma_m^2, \text{ sendo } n \neq m, \forall m, n \in \{1, 2, \dots, M\}. \quad (3.6)$$

Assim, para fins de modelagem estocástica, pode-se descrever tal efeito como uma variável aleatória (*random variable*, r.v.) para diferenciar e modelar as variâncias de ruído em cada antena da BS do sistema SU. Neste capítulo, consideramos uma distribuição uniforme $\mathcal{U}[\cdot, \cdot]$ em torno da potência de ruído para modelar os elementos de antena massivas descalibradas na BS do sistema secundário, Figura 12:

$$\sigma_n^2 \sim \mathcal{U} \left[m_{\sigma_n^2}, \text{Var}(\sigma_n^2) \right], \quad \forall n \in \{1, 2, \dots, M\}, \quad (3.7)$$

com o primeiro e o segundo parâmetros da distribuição uniforme $\mathcal{U}[\cdot, \cdot]$ indicando a média e a variância da variável aleatória¹ σ_n^2 . Abordagem semelhante pode ser considerada no módulo estatístico da potência de transmissão no lado do transmissor primário.

3.3 Testes Estatísticos e Desempenho do SS para Sistemas MIMO

Nesta seção revisitamos os principais testes estatísticos clássicos empregados em SS para sistemas com múltiplas antenas. Para uma análise justa e representativa, selecionamos seis detectores multi-antenas: *a*) detector de máximo-mínimo autovalores (MME); *b*) detector aritmético-geométrico (AGM); *c*) detector de John (JD); *d*) detector de covariância (CAV); *e*) detector de Hadamard (HD); *f*) detector de volume (VD). Na sequência, é fornecida uma breve descrição, bem como a complexidade computacional associada, para cada um dos testes estatísticos mencionados.

3.3.1 Detector de Máximo-Mínimo Autovalores - MME

O teste estatístico do detector MME é dado por

$$T_{\text{MME}} = \frac{\lambda_1(\mathbf{R})}{\lambda_m(\mathbf{R})}, \quad (3.8)$$

onde λ_1 e λ_m são os autovalores mínimo e máximo de \mathbf{R} respectivamente. Este detector é cego e robusto a canais desvanecidos, porém, sua complexidade computacional é alta devido ao procedimento de decomposição de autovalores (*eigenvalue decomposition*, EVD).

¹ Alternativamente, a distribuição uniforme é descrita por $\mathcal{U}[a, b]$, com $m_{\sigma_n^2} = \frac{a+b}{2}$ e $\text{Var}(\sigma_n^2) = \frac{(b-a)^2}{12}$.

3.3.2 *Detector Aritmético-Geométrico - AGM*

O teste estatístico para o detector AGM é dado por

$$T_{\text{AGM}} = \frac{\frac{1}{m} \text{Tr}(\mathbf{R})}{\det(\mathbf{R}^{\frac{1}{m}})}, \quad (3.9)$$

onde $m \leq M$ é o número de autovalores significativos de \mathbf{R} . Este detector é cego e robusto aos sinais primário recebidos, porém, sua complexidade computacional é alta devido ao cálculo do determinante de $\mathbf{R}^{1/m}$.

3.3.3 *Detector de John - JD*

O teste estatístico para o JD é dado por (HUANG et al., 2015), (HUANG; XIAO; ZHANG, 2015)

$$T_{\text{JD}} = \frac{\text{Tr}(\mathbf{R}^2)}{[\text{Tr}(\mathbf{R})]^2}. \quad (3.10)$$

O detector de John é cego e robusto, sendo baseado na multiplicação de matrizes, resultando, como esperado, em alta complexidade computacional (GOLUB; LOAN, 2013).

3.3.4 *Detector de Covariância - CAV*

O teste estatístico do detector de CAV é dado por

$$T_{\text{CAV}} = \frac{\sum_{i,j=1}^m |r_{ij}|}{\text{Tr}(\mathbf{R})}. \quad (3.11)$$

sendo r_{ij} o (i, j) -ésimo elemento de \mathbf{R} . O detector de covariância também é cego e robusto e possui boa performance quando aplicado a sistemas MIMO descalibrados; além disso, é menos complexo do ponto de vista computacional quando comparado aos detectores MME, AGM e JD (CHEN; SHI, 2020).

Tabela 3 – Complexidade por Amostras em [Pontos Flutuantes (Flops)] dos Detectores analisados.

Detec. SS	Adições	Produtos	Total
CAV	$M^2 + M$	–	$M^2 + M$
HD	$M^3 - M/6$	$M^3/6 + M^2 - 7M/6$	$M^3/3 + M^2 - 4M/3$
VD	$\frac{5M^3}{3} - \frac{3M^2}{2} + \frac{5M}{6}$	$\frac{5M^3}{3} + \frac{5M^2}{2} - \frac{13M}{6} + 1$	$\frac{10M^3}{3} + M^2 + \frac{4M}{3} + 1$
MME	$M^3/6 - M/6$	$M^3 + M^2 - 13M/6 + 1$	$M^3/3 + M^2 - 7M/3 + 1$
AGM	$M^3/6 - 5M/6$	$M^3/6 + M^2 - 13M/6 + 1$	$M^3/3 + M^2 - M/3 + 1$
JD	$M^3 - M^2 + 2M$	M^3	$2M^3 - M^2 + 2M$
CHDM	$M^3 - M/6$	$M^3/6 + M^2 - 7M/6$	$M^3/3 + M^2 - 4M/3$
Etapa comum de cálculo da matriz de covariância: $MN^2 + N(M - N/2) - N/2$			

3.3.5 *Detector de Hadamard - HD*

Para o detector de HD, o teste estatístico pode ser escrito como

$$T_{\text{HD}} = \frac{\det(\mathbf{R})}{\prod_{i=1}^m r_{ii}}. \quad (3.12)$$

sendo r_{ii} o i -ésimo elemento da diagonal principal de \mathbf{R} . Este detector foi originalmente proposto para operar com cenários descalibrados (SEDIGHI et al., 2015). No entanto, sua complexidade computacional é alta, enquanto sua descrição de desempenho analítica não foi até o momento relatada com precisão na literatura, tendo apenas resultados aproximados de sua performance estatística.

3.3.6 *Detector de Volume - VD*

O teste estatístico para o detector de VD é definido por

$$T_{\text{VD}} = \log(\det(\mathbf{G}^{-1}\mathbf{R})), \quad (3.13)$$

onde $\mathbf{G} = \text{diag}(\mathbf{s})$, $\mathbf{s} = [s_1, \dots, s_m]$, para cada elemento sendo definido como $s_i = \|\mathbf{R}(i, :)\|_2$. VD é outro detector proposto na literatura aplicado em SS proposto para tratar com cenários descalibrados (HUANG et al., 2015). No entanto, sua complexidade computacional é alta e como no caso do HD sua descrição de desempenho é complexa e ainda encontra-se em uma etapa em que apenas estatísticas aproximadas foram consideradas nas formulações.

3.3.7 *Detector de Hadamard Circular - CHDM*

Este detector foi proposto para operar com cenários descalibrados em conjunto com sinais primários sujeitos a desequilíbrio de IQ (*in-phase and quadrature*) (JALALI; ZAIMBASHI, 2020). Sua complexidade computacional e desempenho são semelhantes aos obtidos com o HD. Para o detector CHDM, o teste estatístico é escrito como

$$T_{\text{CHDM}} = \frac{\prod_{i=1}^m r_{ii}}{\det(\mathbf{R})}. \quad (3.14)$$

3.3.8 *Complexidade Computacional dos Detectores para SS em sistemas MIMO*

A Tabela 3 resume as operações em pontos flutuantes (flops) de soma e multiplicação necessárias para cada detector analisado. Pode-se concluir que a maior parte dos detectores aplicados em SS requer uma ordem de complexidade computacional assintótica de $\mathcal{O}(M^3)$. Exceto o detector de CAV, sendo o único detector que apresenta complexidade computacional de ordem assintótica $\mathcal{O}(M^2)$.

Observe que, o número total de flops utilizados para o cálculo da matriz de covariância é $MN^2 + N(M - N/2) - N/2$, que é uma etapa inerente comum a todos os detectores aplicado ao SS.

3.3.9 Desempenho dos Detectores de HD, VD e CAV operando em Sistemas Cognitivos munidos de Antenas Descalibradas

Nesta etapa, apresentamos o ajuste Gaussiano para os dados estatísticos realizado pelo SS visando obter expressões expeditas (aproximadas e empíricas) e úteis para representar as probabilidades de detecção e falso alarme dos detectores de Hadamard, volume e covariância. Uma suposição válida aqui é considerar a aplicação do teorema do limite central (*central limit theorem*, CLT). Basicamente, a probabilidade de falso alarme (P_f) e a probabilidade de detecção (P_d) podem ser escritas respectivamente como

$$P_f = Q\left(\frac{\lambda - \mathbb{E}(T|\mathcal{H}_0)}{\sqrt{\sigma_{T|\mathcal{H}_0}^2}}\right), \quad (3.15)$$

$$P_d = Q\left(\frac{\lambda - \mathbb{E}(T|\mathcal{H}_1)}{\sqrt{\sigma_{T|\mathcal{H}_1}^2}}\right), \quad (3.16)$$

sendo $Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^\infty \exp(-\frac{u^2}{2}) du$ a função Q (relacionada com a função erro complementar de Gauss). Os argumentos da função Q é dado pelo limiar de decisão λ , a média estatística do teste estatístico $\mathbb{E}(T|\mathcal{H}_{0,1})$ e a respectiva variância $\sigma_{T|\mathcal{H}_{0,1}}^2$. Genericamente, o teste T pode ser T_{HD} , T_{VD} ou T_{CAV} . Como já comentado, expressões analíticas para HD, VD e CAV (HUANG et al., 2015), (HUANG; XIAO; ZHANG, 2015) e (ZENG; LIANG, 2009a) são complicadas para serem utilizadas em problemas de otimização. Para evitar expressões matemáticas sobrecarregadas, pode-se supor que a média estatística e a variância do teste estatístico podem ser conhecidas a partir de dados empíricos (supostos ergódicos), ou seja, por meio de estimativas. Usando todos os testes estatísticos, onde os ensaios de Monte-Carlo são definidos por S , pode-se calcular os parâmetros do primeiro e segundo momentos estatísticos de T pelas estimativas

$$\mathbb{E}[T|\mathcal{H}_{0,1}] \approx \frac{1}{S} \sum_{p=1}^S (T|\mathcal{H}_{0,1})(p), \quad (3.17)$$

$$\sigma_{T|\mathcal{H}_{0,1}}^2 \approx \mathbb{E}[T^2|\mathcal{H}_{0,1}] - (\mathbb{E}[T|\mathcal{H}_{0,1}])^2. \quad (3.18)$$

Por fim, o limiar de decisão pode ser obtido a partir da probabilidade de falso alarme. Na próxima seção, otimizamos o limiar de decisão λ no sentido de minimizar a probabilidade de erro de detecção do espectro.

Observe que a generalização de (3.17) e (3.18) permite-nos descrever as probabilidades de detecção e falso alarme para todas as classes de detectores SS, incluindo os detectores MME, AGM e JD. No entanto, a validade é sempre dependente do CLT e deve ser sempre satisfeita para sua perfeita aplicação.

3.4 Modos de Operação que favorecem a Eficiência Espectral (SE) e a Eficiência Energética (EE)

Dois modos possíveis de operação no sistema MIMO massivo aplicado ao SS são estabelecidos neste capítulo:

- i) Modo Eficiência Espectral melhorado (SE)* combina um grande número de antenas no sistema secundário (M) a um número baixo de amostras coletadas (N) visando reduzir o tempo de sensorimento e melhorar a taxa de transmissão de dados;
- ii) Modo Eficiência Energética melhorado (EE)* combina um reduzido número de antenas ativas na BS secundária (M) a um grande número de amostras coletadas N na etapa de SS, sendo que as antenas secundárias restantes permanecem em modo de suspensão, aumentando assim a EE geral do sistema.

Além disso, uma segunda situação pode ser projetada sob o modo de operação EE consistindo na tarefa de SS utilizando um subconjunto com um número fixo de antenas garantindo desempenho adequado enquanto outra parcela de antenas é empregada para transmitir em modo *full duplex*, aumentando a SE empregando o *spectrum sharing* em uma banda desocupada.

Nesta etapa do trabalho concentramo-nos em analisar os modos SE e EE em SS e *spectrum sharing* aplicados em sistemas cognitivos empregando múltiplas antenas massivas descalibradas, que podem ser caracterizados pelo *trade-off* entre a quantidade de amostras coletadas e o número de antenas secundárias utilizadas na etapa de SS. No modo SE, o grande número de antenas M combinado a um tamanho reduzido de amostras N revela uma melhoria notável na eficiência geral do espectro da rede, graças ao alto ganho da matriz de canal propiciado pelo endurecimento do canal (*channel hardening*, CH) e efeitos de propagação favoráveis (*favorable propagation*, FP) que surgem em sistemas que empregam múltiplas antenas massivas. Por outro lado, no modo EE, o número reduzido de antenas de sensoriamento ativas combinado ao número reduzido de amostras coletadas resulta em um aumento substancial na economia geral de energia gasta pelo sistema. De fato, considerando que a ativação de cada elemento de antena em um sistema com antenas massivas requer tipicamente entre 0.5 a 2 [W], a economia de energia torna-se substancial desativando 30% a 50% das antenas do sistema enquanto mantém-se a condição de CH (MARINELLO et al., 2020). A Tabela 4 resume as características dos modos SE e EE avaliados neste capítulo.

Basicamente, um grande número de antenas pode ser considerado a partir de valores superiores a uma centena, ou seja, tipicamente valores na faixa de $M = 128$, $M = 256$ antenas ou superior podem ser consideradas como representativo. Além disso, um número reduzido de antenas são valores no intervalo $M \in \{50; 64\}$, e que ainda pode ser

Tabela 4 – Modos SE e EE aplicados em Redes Cognitivas com Antenas Massivas.

Modo (SU)	M Antenas	N Amostras	SE	EE
SE	grande (> 100)	baixo (200)	alto	médio
EE	reduzido (< 50)	baixo-moderado (500)	médio	alto

considerado o valor mínimo para definir o sistema como MIMO massivo, atendendo ainda as características de CH e FP. O impacto do número de antenas pode ser medido pelo *custo de ativação* que é basicamente definido como o consumo de energia para ativar cada antena. Cada antena ativa consome alguma energia que contribui para reduzir a eficiência energética geral. Além disso, o *número de amostras* também impacta na eficiência do SS. Assim, baixo número de amostras pode ser considerado valores em torno de $N = 200$ e baixo-moderado pode ser considerado como $N = 500$ amostras, enquanto um número alto de amostras está além de $N > 1000$ amostras por operação de SS. Como esperado, o tempo de detecção é dependente do número de amostras e impacta ambas as eficiências, sendo mais importante no modo SE, *que pode reduzir ou aumentar notavelmente a SE do sistema*. Observe que a estrutura da camada de controle de acesso (MAC) é a mesma da Figura 13.

3.4.1 Eficiência Energética e Espectral na etapa de Transmissão de Dados

A topologia do sistema na etapa de transmissão e recepção de dados pelos SUs massivos operando em *spectrum sharing* é representado pela Figura 14. Todas as M antenas transmitem o mesmo sinal (modo diversidade). O sinal recebido nos SUs na fase de transmissão de dados é definido como

$$\mathbf{Y} = \mathbf{D}\mathbf{H}\mathbf{X} + \mathbf{Z}, \quad (3.19)$$

sendo $\mathbf{Y} \in \mathbb{C}^{L \times N}$ o sinal recebido pelo receptor do SU MIMO, com $L \ll M$ podendo representar L SUs com uma única antena separados espacialmente ou um único SU equipado com L antenas; $\mathbf{D} \in \mathbb{C}^{L \times L}$ é a matriz de efeito de grande escala definida pela perda de percurso definida como $\mathbf{D} = \text{diag}\left(\sqrt{\frac{\bar{\chi}}{\chi}}\right)$, ou seja, $\boldsymbol{\chi} = [\chi_1, \dots, \chi_L]$ onde $\chi_\ell = \beta_\ell \cdot P_t$, com β_ℓ a perda de percurso (distintos) no modo multi-usuário secundários ($\ell = 1, \dots, L$) separados espacialmente², P_t é a potência total de transmissão através das M antenas para o $\ell = 1, 2, \dots, L$ antenas SU, e $\bar{\chi}$ é o valor de perda de percurso médio calculado como:

$$\bar{\chi} = \frac{1}{L} \sum_{\ell=1}^L \chi_\ell, \quad \text{com } \chi_\ell = \frac{\chi_0}{\bar{d}_\ell^\alpha}, \quad (3.20)$$

onde χ_ℓ é o ℓ -th coeficiente de perda de percurso, \bar{d}_ℓ é a distância média entre as BS secundária munida de M antenas e o SU munido da ℓ th antena, χ_0 é o fator de atenuação a uma distância de referência de $d_0 = 1\text{m}$ entre as antenas da BS e do SU; e α é o coeficiente de perda de percurso relacionado ao ambiente de comunicação.

² Note-se que $\beta_\ell = \beta_k, \forall \ell, k$ no modo antenas co-localizadas (único SU equipado com L antenas).




Figura 14 – Topologia para o sistema MIMO massivo secundário transmitido e recebido ($M \times L$). Configuração das Antenas do sistema secundário operando em fase de transmissão de dados e informações (*spectrum sharing*). Sistema SU MIMO massivo com $L \ll M$ podendo representar L SUs com uma única antena (separados espacialmente) ou um único SU equipado com L antenas; Fonte: Autoria própria.

O efeito do desvanecimento de canal entre o m -th transmissor e o ℓ -th receptor SU é descrito pela matriz $\mathbf{H} \in \mathbb{C}^{L \times M}$, enquanto que $\mathbf{X} \in \mathbb{C}^{M \times N}$ é o sinal transmitido pelo sistema secundário, supostamente idêntico ao longo das M antenas; N é o número de amostras coletadas, e $\mathbf{Z} \in \mathbb{C}^{L \times N}$ é o ruído térmico equivalente, que captura os efeitos das antenas descalibradas do *front-end* de RF altamente escalável no transmissor e receptor secundário, conforme discutido na Seção 4.2.1.

Matematicamente, o modo SE pode ser descrito com base na equação de capacidade de Shannon e levando-se em consideração o tempo total de quadro disponível para o SS e a transmissão do sistema secundário (MOGHIMI; MALLIK; SCHOBBER, 2012; HU; ZHANG; LIANG, 2016) equipado com múltiplas antenas massivas descalibradas. A capacidade de transmissão em função do número de antenas ativas na fase de sensoriamento \mathcal{M} , bem como o número de amostras coletadas N é descrito por

$$\mathcal{R}(\mathcal{M}, N) = \Pr(\mathcal{H}_0) \cdot (1 - P_f) \cdot \left(\frac{T - \tau}{T} \right) \cdot \log_2 \det \left(\mathbf{I}_L + \mathbf{D} \mathbf{H} \mathbf{H}^H \mathbf{I} \right) \quad [\text{bits}], \quad (3.21)$$

onde $\Pr(\mathcal{H}_0)$ é a probabilidade do canal estar ocioso. Além disso, cada antena tem igual período de sensoriamento

$$\tau = \frac{N}{f_s} = N \cdot T_s, \quad (3.22)$$

que depende do número de amostras e da frequência de amostragem. A potência recebida sujeita à perda de percurso é descrita pela matriz \mathbf{D} , enquanto o efeito de descalibração de ruído nas L antenas receptoras é descrito pelo vetor das potências de ruído $\mathbf{I} = \text{diag}(\boldsymbol{\eta})$, sendo $\boldsymbol{\eta} = \left[\frac{1}{\sigma_1^2}, \frac{1}{\sigma_2^2}, \dots, \frac{1}{\sigma_L^2} \right]$. Além disso, o número de antenas ativas na fase de SS é definida como sendo

$$\mathcal{M} = \begin{cases} M, & \text{modo SE} \\ M_E < M. & \text{modo EE} \end{cases} \quad (3.23)$$

Também podemos descrever o modo EE usando a equação (3.21), resultando em:

$$\mathcal{E}(\mathcal{M}, N) = \frac{\mathcal{R}(\mathcal{M}, N)}{E} \quad \left[\frac{\text{bit}}{\text{Joule}} \right]. \quad (3.24)$$

O denominador de (3.24) representa o consumo total de energia, dado por

$$E = [\tau + \Pr(\mathcal{H}_0)(1 - P_f)(T - \tau)] \cdot (\varrho \cdot P_t + P_c + \mathcal{M} \cdot P_a) \quad [\text{Joule}], \quad (3.25)$$

sendo P_s, P_c, P_t e P_a a potência gasta durante o SS, consumo dos elementos de circuitos, fase de transmissão do sinal secundário e potência gasta por antena ativada, respectivamente; enquanto ϱ indica a ineficiência em termos de potência do sistema de RF.

3.4.2 Otimização do Limiar de Decisão sob a condição de Minimização da Probabilidade de Erro

Para otimizar o limite de decisão λ (*threshold*) para atingir uma determinada performance em termos de probabilidade de detecção e probabilidade de falso alarme sob o critério de minimização de erro, o seguinte problema geral de otimização com restrições é formulado:

$$\begin{aligned} \lambda^* &= \arg \min_{\lambda} P_e(\lambda) = \Pr(\mathcal{H}_0)P_f(\lambda) + \Pr(\mathcal{H}_1)P_m(\lambda), \\ \text{s.a. } P_f(\lambda) &\leq \overline{P}_f, \\ P_d(\lambda) &\geq \overline{P}_d, \end{aligned} \quad (3.26)$$

sendo a probabilidade de erro composta pelas probabilidades de alarme falso e falha. A probabilidade de falha é o complemento estatístico da probabilidade de detecção, *i.e.*, $P_d = 1 - P_m$. As probabilidades de canal primário ocioso e ocupado são assumidas como $\Pr(\mathcal{H}_0)$ e $\Pr(\mathcal{H}_1)$, respectivamente, enquanto as restrições \overline{P}_f e \overline{P}_d são a probabilidade de falso alarme alvo e a probabilidade de detecção alvo, respectivamente.

Programação Quadrática Sequencial-SQP: para resolver o problema de otimização em (4.29) empregamos o algoritmo baseado na SQP que é um procedimento iterativo baseado nas condições KKT (*Karush-Kuhn-Tucker (KKT) conditions*) de segunda ordem, empregando a matriz Hessiana da função Lagrangiana associada ao problema (4.29), assumindo uma aproximação polinomial quadrática para o problema de otimização não-linear original. O algoritmo SQP resolve sub-problemas de programação quadrática (*quadratic programming, QP*) sequencialmente com base na aproximação quadrática da função Lagrangiana. Assim, considerando o problema de otimização em (4.29), a função Lagrangiana resulta

$$\mathcal{L}(\lambda, \mu, \kappa) = P_e(\lambda) + \mu P_f(\lambda) - \kappa P_d(\lambda), \quad (3.27)$$

onde μ e κ são os multiplicadores de Lagrange da função.

Como resultado, o k -th correspondente sub-problema de programação quadrática pode ser formulado como

$$\begin{aligned} d^* &= \arg . \min ._d P_e(\lambda_k) + \nabla_\lambda P_e(\lambda_k)d + \frac{1}{2}d\nabla_{\lambda\lambda}^2\mathcal{L}(\lambda_k, \mu_k, \kappa_k)d, \\ \text{s.a.} \quad &- P_f(\lambda_k) - \nabla_\lambda P_f(\lambda_k)d \geq 0, \\ &P_d(\lambda_k) + \nabla_\lambda P_d(\lambda_k)d \geq 0, \end{aligned} \quad (3.28)$$

sendo ∇^2 o operador Hessiano. A matriz Hessiana da função Lagrangiana pode ser descrita como

$$\nabla_{\lambda\lambda}^2\mathcal{L}(\lambda_k, \mu_k, \kappa_k) = \nabla_{\lambda\lambda}^2P_e(\lambda_k) + \mu_k\nabla_{\lambda\lambda}^2P_f(\lambda_k) - \kappa_k\nabla_{\lambda\lambda}^2P_d(\lambda_k). \quad (3.29)$$

O objetivo é obter uma direção de busca d no plano tangente construído pelas restrições que interceptam a função objetivo quadrática. Tal direção é incrementada sequencialmente, levando a uma solução de limiar de decisão associada ao problema não-linear original, atualizando iterativamente o $\lambda_{k+1} = \lambda_k + d_k$, para $k = 1, \dots, K$, sendo K o número mínimo de iterações do algoritmo SQP para garantir a convergência do procedimento, sujeito ao critério de convergência adotado $\|\lambda_{k+1} - \lambda_k\|_2 < \varepsilon$.

Para resolver o problema SQP resultante propomos o Algoritmo iterativo 2, onde o valor $\varepsilon \in \{10^{-6}; 10^{-3}\}$ define o critério de parada. Observe que o problema QP resultante pode ser facilmente resolvido usando algum pacote computacional de otimização convexa, por exemplo, o pacote *Optimization Toolbox* no software MATLAB.

Algoritmo 1 - SQP - Limiares de Decisão λ para Minimização de P_e

Inicialização: $\lambda_0, \mu_0, \varepsilon$ e κ_0

Definir $k = 0$;

Repetir até convergência dada por $\|\lambda_{k+1} - \lambda_k\|_2 < \varepsilon$

Calcular $P_e(\lambda_k), \nabla_\lambda P_e(\lambda_k), \nabla_{\lambda\lambda}^2\mathcal{L}(\lambda_k, \mu_k, \kappa_k), P_f(\lambda_k)$ e $P_d(\lambda_k)$

Resolver o problema QP resultante na equação (3.28) para obter d_k, μ_k e κ_k

Definir $k = k + 1, \lambda_{k+1} = \lambda_k + d_k, \mu_{k+1} = \mu_k$ e $\kappa_{k+1} = \kappa_k$

Fim

3.5 Resultados Numéricos

Nesta seção, analisamos as métricas de desempenho para os métodos de SS em sistemas secundários equipados com múltiplas antenas descalibradas. A Tabela 8 resume os valores adotados para os parâmetros nesta seção de resultados numéricos. Observe que os modos SE e EE são caracterizados pelo *trade-off* entre o tamanho das amostras coletadas e número de antenas ativas no sistema cognitivo. No modo SE, o grande número de antenas combinado com um reduzido tamanho de amostras resulta em um aumento na SE. Por outro lado, no modo EE, o número reduzido de antenas empregadas combinado

com um número moderado de amostras coletadas resulta em um aumento substancial na EE.

Para a caracterização dos modos SE-EE, na fase de transmissão ajustamos a potência de sensoriamento como $P_s = 40$ [mW], a potência consumida pelo circuito como $P_c = 80$ [mW], a potência de transmissão da BS como $P_t = 2$ [W] e a potência para ativação de cada elemento de antena como $P_a = 1$ [W]. A potência média transmitida P_{avg} está relacionada a SNR média e ao ruído de potência médio σ_{avg}^2 . Além disso, consideramos um cenário prático de múltiplas antenas, onde a potência de ruído e a potência transmitida são selecionadas aleatoriamente (desconhecidas no sensor), seguindo uma distribuição uniforme. Finalmente, os resultados numéricos são calculados sobre $\mathcal{S} = 10^4$ realizações, considerando a metodologia de simulação de Monte-Carlo.

Tabela 5 – Configuração dos Parâmetros de Simulação

Parâmetros	Valores Adotados
Amostras e # SU Antenas	$N = 200$ e $M = 100$ (modo SE) $N = 500$ e $M = 20$ (modo EE)
SNR Média	-15 [dB]
# PU	1 usuário
modelo Perda de Percurso	atenuação @ $d_0 = 1$ m: $\chi_0 = -25$ [dB] coeficiente de perda de percurso $\alpha = 3$
Potência de ruído média	$\sigma_{avg}^2 = 1$ [W] (normalizada)
Rx potência de ruído	$\sigma_i^2 \sim \mathcal{U}[0.05, 1.95]\sigma_{avg}^2$ (descalibrado)
Potência dinâmica de transmissão	$P \sim \mathcal{U}[0.05, 1.95]P_{avg}$
Modulação do sinal Tx.	QPSK
$\Pr(\mathcal{H}_1), \Pr(\mathcal{H}_0)$	0.5
Prob. detecção alvo	$\overline{P}_d = 0.9$
Prob. falso alarme alvo	$\overline{P}_f = 0.1$
Potência de sensoriamento	$P_s = 40$ [mW]
Potência dos circuitos consumida	$P_c = 80$ [mW]
Potência para ativação antena	$P_a = 1$ [W]
Potência TX pelo SU	$P_t = 2$ [W]
Ineficiência dos circuitos de RF do SU	$\varrho = 1.7$
# MIMO antenas no RX. SU	$L = 4$
período quadro camada MAC	$T = 100$ [ms]
frequência de amostragem	$f_s = 5$ [MHz]
Inicialização do algoritmo SQP	$\varepsilon \in \{10^{-6}; 10^{-3}\}$; $\lambda_0 = 0, \mu_0 = 0, \kappa_0 = 0$
Iterações algoritmo SQP	$K \in \{3, 4, 5\}$
Simulações de Monte-Carlo	$\mathcal{S} = 10000$ realizações

A Figura 15 apresenta a probabilidade de erro em função da SNR média, tamanho das amostras e do número de antenas no sistema cognitivo, considerando o limiar de decisão adequado, mas não otimizado λ . Devido às dificuldades em encontrar expressões para o limiar de detecção para cada detector, uma regra empírica foi concebida com base na hipótese de canal desocupado, introduzindo a variável auxiliar $z = \text{sort}(\mathbf{T}_{\mathcal{H}_0})$, e

calculando o limiar de decisão a partir de

$$\lambda = z[(1 - P_f) \cdot N], \quad (3.30)$$

sendo $T_{\mathcal{H}_0}$ o teste estatístico para cada detector SS operando sob a hipótese de inatividade. Especificamente, a Figura 15 (a) mostra a robustez de cada detector quando o SU opera no modo EE; pode-se observar que o VD é mais robusto que o HD e próximo ao detector CAV. Os outros detectores são mais pobres em termos de robustez neste cenário. Na sequência, a Figura 15 (b) mostra a probabilidade de erro quando o tamanho das amostras aumenta. A tendência anterior se mantém, pode-se concluir que o detector VD requer menos amostras para atingir um valor com baixa probabilidade de erro. O segundo melhor detector é o CAV seguido pelo HD. Observe que os outros detectores ainda resultam em desempenho inferior e degradado mesmo aumentando o tamanho das amostras coletadas. Finalmente, na Figura 15 (c) a probabilidade de erro em termos do aumento do número de antenas é analisada; de fato, o desempenho do detector VD é superior em comparação com os outros detectores SS que precisam de menos antenas para garantir baixa probabilidade de erro, os outros detectores permanecem com a mesma tendência como observado nas simulações anteriores.

3.5.1 Complexidade Computacional para os detectores usados para o SS

Para ilustrar a complexidade computacional da Tabela 3, a Figura 16 mostra a complexidade computacional em função da variação do tamanho das amostras $N \in [200; 500]$ e o número de antenas $M \in [20; 100]$. O detector CAV é menos complexo computacionalmente comparado ao detector HD e ao detector VD. Isso se explica essencialmente observando o teste estatístico do CAV, HD e VD; o teste estatístico de HD depende do determinante da matriz de covariância, que é assintoticamente $\mathcal{O}(M^3)$, enquanto o teste estatístico VD depende do determinante e da multiplicação da matriz de covariância, sendo mais complexo que o HD. Observe que o cálculo da inversa de uma matriz diagonal é apenas assintoticamente $\mathcal{O}(M)$.

3.5.2 Limiares de Detecção Ótimos nos modos de Operação SE e EE

A probabilidade de erro, falso alarme e detecção quando a SU BS opera no modo SE estão ilustrados na Figura 17.a) para o CAV; Figura 17.b) para o detector VD; e Figura 17.c) para detector HD. Podemos observar que todas as curvas simuladas estão próximas das curvas analíticas calculadas por meio das equações (3.15) e (3.16) com parâmetros empíricos (média amostral e variância amostral) dados pela equação (3.17) e (3.18). Em termos do modo EE, a mesma conclusão pode ser obtida inspecionando a Figura 17.d) (CAV), Figura 17.e) (VD), e Figura 17.f) (HD). Pode-se concluir que para os tamanhos de amostras selecionados no SU BS operando nos modos SE e EE, a abordagem analítica adotando a aproximação por meio das funções Q , seguindo o teorema do limite

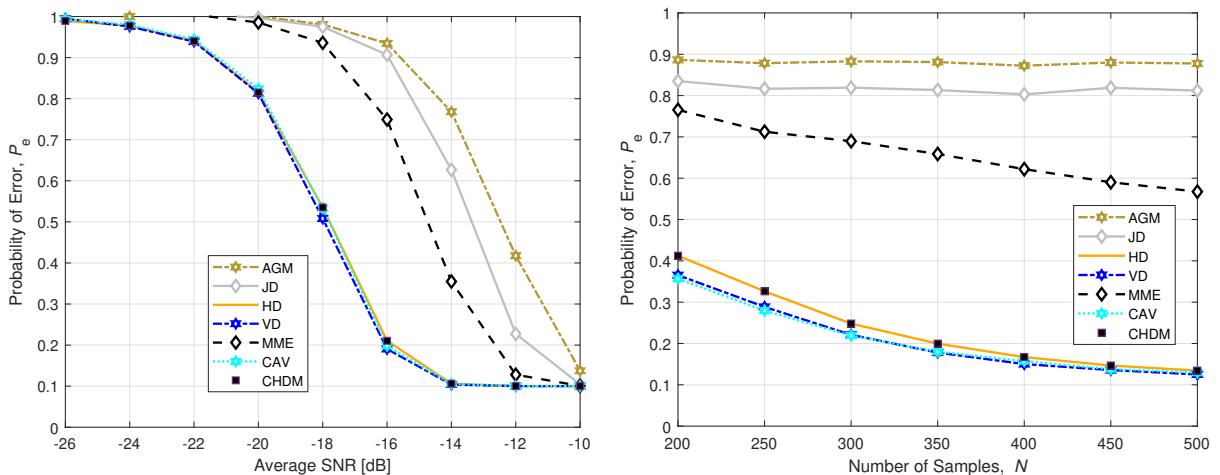

a) $P_e \times \text{SNR}$, modo EE ($M = 20$ antenas)b) $P_e \times \#$ amostras, modo EE ($M = 20$ antenas)c) $P_e \times$ número de antenas, usando $N = 500$ amostras

Figura 15 – Probabilidade de Erro \times a) SNR; b) número de amostras; c) número de antenas no SU (operando no modo EE); λ definido pela equação (4.32).

Fonte: Autoria própria.

central (CLT), é adequada e bem ajustada ao valor numérico obtidos via Simulações de Monte-Carlo.

Na sequência, estamos interessados em resolver o problema de otimização conforme formulado em (4.29), encontrando o limiar de decisão ótimo λ^* analiticamente. Pode-se resolver este problema usando algoritmos iterativos, como por exemplo, a programação quadrática sequencial (SQP), conforme descrito brevemente na subseção 3.4.2, e comparando a principal figura de mérito obtida por simulação numérica conforme descrito em Figura 17. Tomando o SQP com poucas iterações, ou seja, $\mathcal{I} = 4$ ou 5 com a suposição de encontrar um ponto ótimo adequado, pode-se implementar o método SQP analítico-iterativo para encontrar com sucesso o limiar de decisão ideal λ^* . Para facilitar, a solução inicial para cada detector pode ser tomada como o limiar mínimo representado nas curvas da Figura 17. Observe que os valores de $P_e \times \lambda$ para todos os detectores analisados obtidos analiticamente

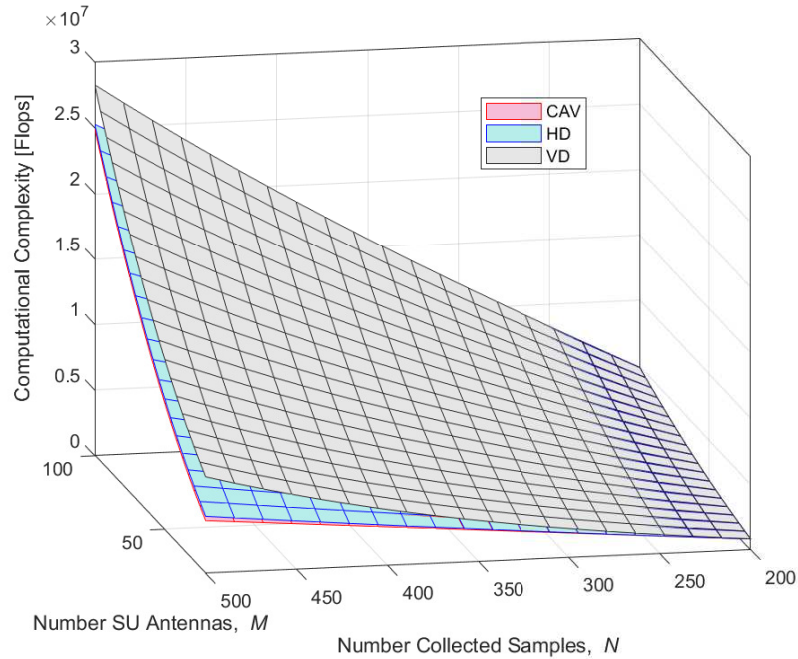


Figura 16 – Complexidade Computacional para os detectores CAV, HD e VD em operações de pontos flutuantes [flops].

Fonte: Autoria própria.

(Ana.) ajustam-se muito bem com os valores obtidos por simulação (Sim.). Como resultado, a Tabela 6 resume os valores ótimos de limiar para a BS SU equipada com diferentes detectores analisados operando nos modos SE e EE, com suas respectivas probabilidades de erro. Pode-se concluir que as soluções para o limiar ótimo estão próximas aos valores observados diretamente na Figura 17, tanto para o modo SE quanto para o EE, validando o algoritmo SQP analítico-iterativo proposto com baixo número de iterações, resolvendo o problema do limiar de decisão ótimo em projetos de SS para sistemas MIMO massivos.

Tabela 6 – Valores do Limiar de Detecção Ótimo nos modos SE e EE.

SS	Limiar Ótimo	Prob. de Erro
Detector	λ^*	P_e
Modo SE		
CAV	6.8635	0.0041
VD	61.6563	0.0254
HD	-1.1×10^{-14}	0.0150
Modo EE		
CAV	1.7641	0.0793
VD	1.2493	0.1193
HD	-0.6378	0.0404

A Tabela 7, compara as soluções obtidas via SQP e NR. Note-se que praticamente todos os valores de limiar de decisão obtidos respectivamente com as técnicas de otimização convexa SQP e NR são idênticos entre si para cada tipo de detector SS (CAV, VD e

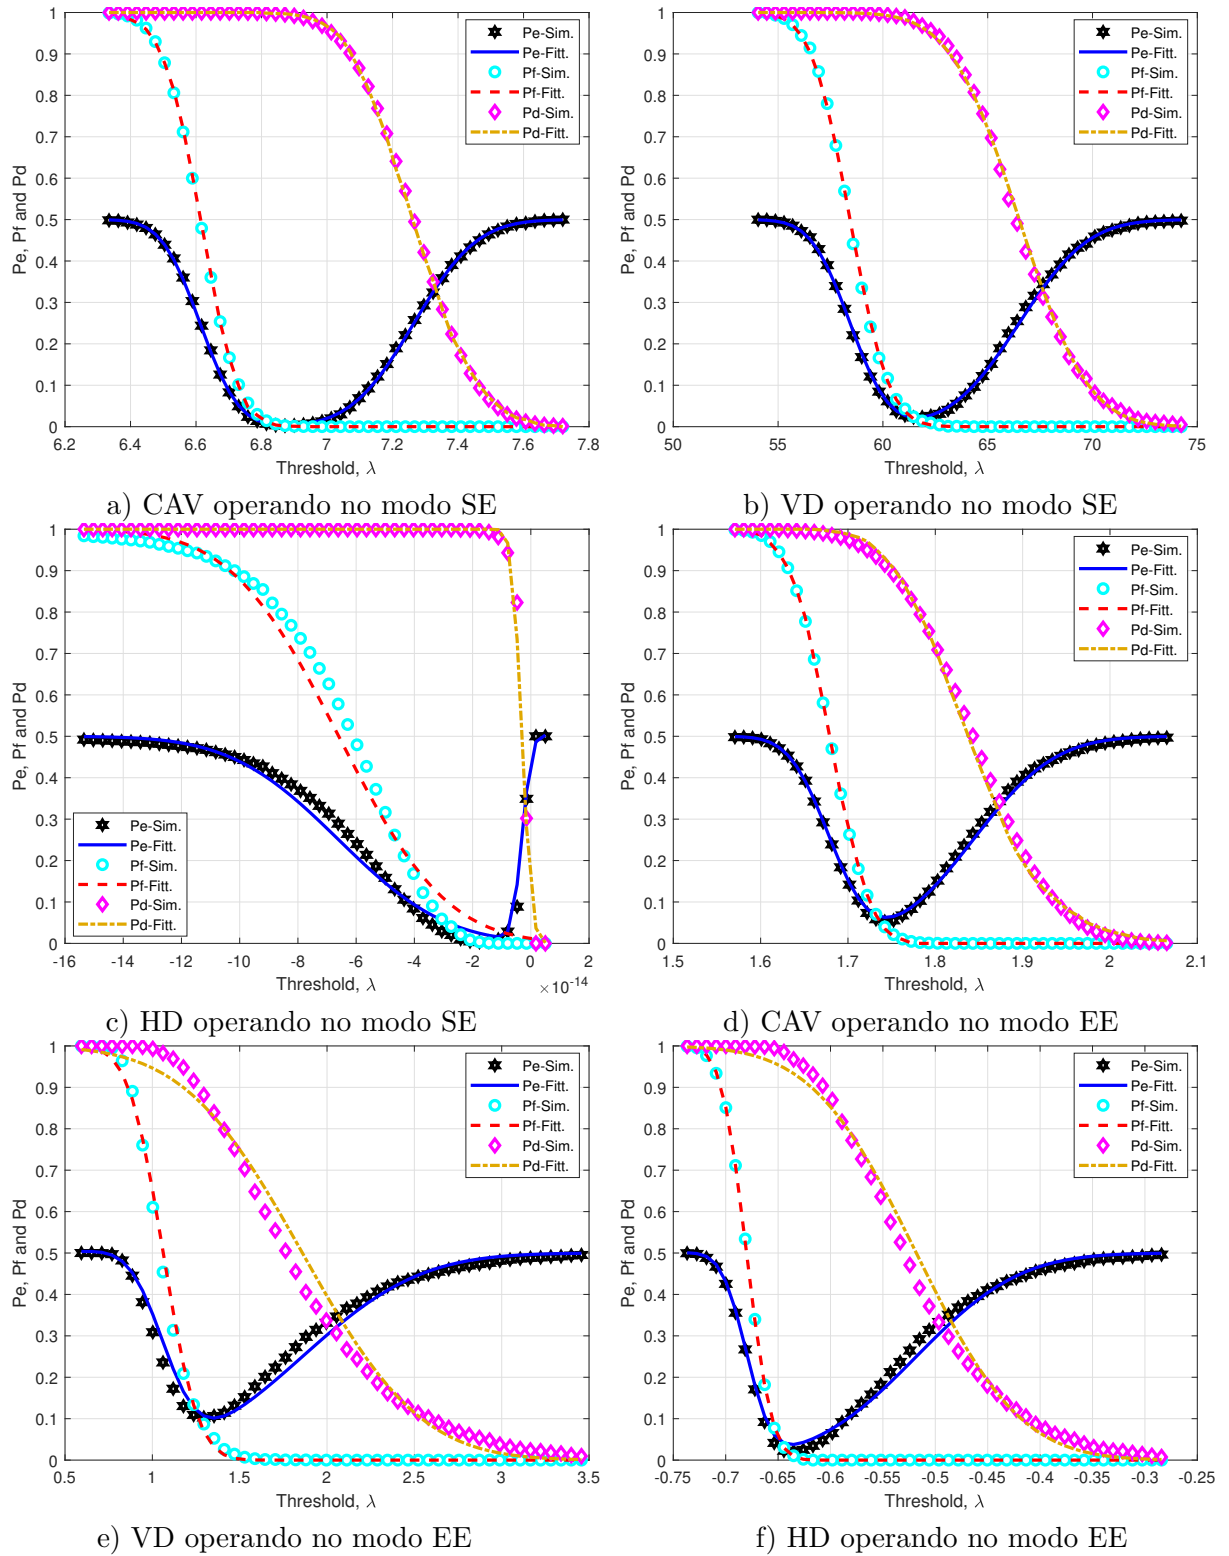


Figura 17 – Probabilidades de erro, falso alarm e detecção \times limiar de detecção para os detectores CAV, VD e HD operando nos modos SE e EE.

Fonte: Autoria própria.

HD), resultando em leve discrepância entre os valores de limiar para o mesmo detector. Além disso, podem ser notadas diferenças no tempo de convergência para os métodos SQP versus NR. Em todos os cenários examinados, o método NR converge mais rapidamente (em segundos) que o algoritmo SQP. A complexidade computacional assintótica para a técnica NR resulta da ordem de $\mathcal{O}(M^2)$, enquanto que o algoritmo baseado em SQP requer $\mathcal{O}(M^3)$ operações.

Tabela 7 – Valores de Limiar de Detecção Ótimo utilizando os métodos SQP e NR.

	Limiar Ótimo	Convergência (s)
Detec-Alg	λ^*	t_c
Modo SE		
CAV-SQP	6.8646	0.8521
CAV-NR	6.8635	0.8440
VD-SQP	61.6532	0.9545
VD-NR	61.6563	0.8893
HD-SQP	-1.14×10^{-14}	1.002
HD-NR	-1.13×10^{-14}	0.9334
Modo EE		
CAV-SQP	1.7625	0.8235
CAV-NR	1.7611	0.8097
VD-SQP	1.2493	0.9396
VD-NR	1.2422	0.8792
HD-SQP	-0.6378	0.9852
HD-NR	-0.6366	0.8936

3.5.3 Análise de Eficiência Espectral (SE) e Eficiência Energética (EE)

Finalmente nesta parte, analisamos a eficiência espectral (SE) e a eficiência energética (EE) nas fases de sensoriamento e transmissão e recepção (*spectrum sharing*). Com tal análise demonstramos a adequação da escolha dos parâmetros sob o modo SE e o modo EE conforme discutido na Seção 3.4. Em primeiro lugar, vamos considerar os parâmetros de configuração da Tabela 8.

A Figura 18 mostra o comportamento em termos de SE e EE com respeito ao número de antenas SU (BS ou Tx.) variando de $M \in [1; 200]$. Na Figura 18.a), o SE em [bits] aumenta com o número de antenas na BS secundária. As curvas para os modos SE e EE resultam iguais neste caso considerando $N = 200$ (modo SE) e $N = 500$ amostras (modo EE). Na Figura 18.b), como esperado, o EE primeiro aumenta, depois diminui com o crescimento do número de antenas na BS secundária, com um ponto ótimo de operação em termos de EE quando $M \approx 5$ antenas. Novamente, as curvas EE resultam iguais para os modos SE e EE.

As Figuras 19.a) e 19.b) representam o $SE \times M$ e $EE \times M$, respectivamente, considerando agora o número extremo de pontos amostrais, ou seja, $N = 10$ amostras

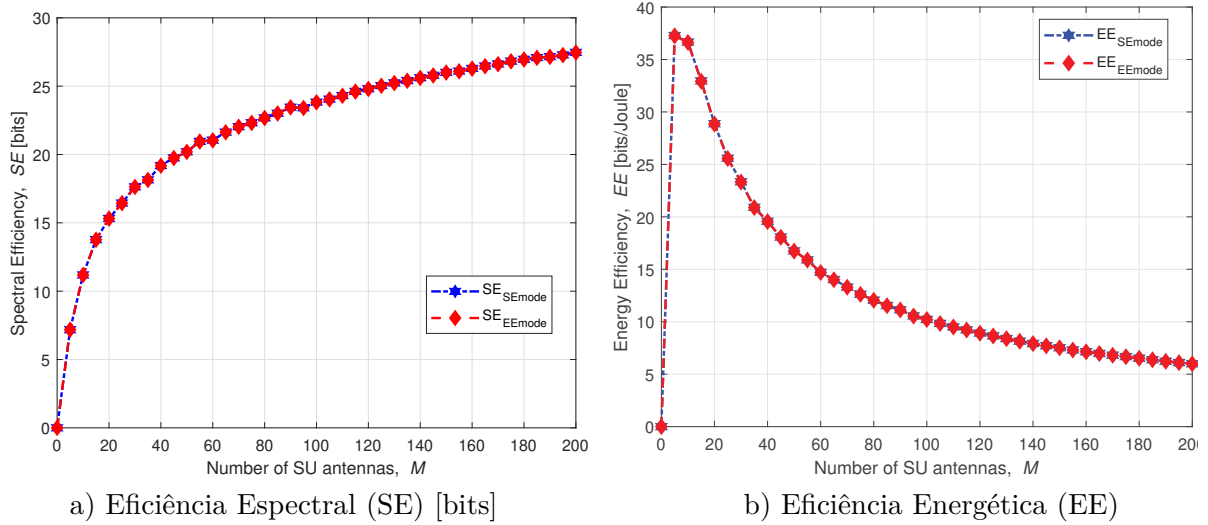


Figura 18 – Eficiência Espectral (SE) e Eficiência Energética (EE) *versus* número de antenas na BS SU, M analisado no modo SE ($N = 200$ amostras) e modo EE ($N = 500$ amostras).

Fonte: Autoria própria.

(mínimo para considerar o CLT válido), e $N = 2 \cdot 10^5$ amostras (valor muito alto). Nesse número extremamente baixo e alto de amostras de sensoriamento, pode-se observar diferenças significativas nas curvas SE e EE. De fato, quando $N = 10$, obtêm-se SE e EE muito melhores em relação às amostras $N = 2 \cdot 10^5$; isso acontece porque a SE diminui consideravelmente quando o tempo de sensoriamento é alto e vice-versa. Da mesma forma, pode-se inferir a mesma tendência das curvas EE com respeito ao número de amostras de sensoriamento, pois o denominador de (3.24) é definido pelo SE enquanto o denominador (consumo total de energia) apresenta a mesma dependência com N ou τ .




Figura 19 – a) Eficiência Espectral (SE) [bits] e b) Eficiência Energética (EE) [bits/Joule] \times número de antenas (M), avaliado para valores extremos de amostras coletadas [10; $2 \cdot 10^5$] amostras.

Fonte: Autoria própria.

Figura 20.a) analisa o comportamento em termos de SE com respeito ao parâmetro de potência de transmissão $P_t \in [0.1; 3.5]$ em $[W]$. Pode-se observar o aumento da SE para mais potência de transmissão exigida pelo sistema. Novamente, observando as curvas para modo SE e modo EE, o desempenho mais favorável do sistema é obtido sob o modo SE, que é representado por $M = 100$ antenas e $N = 200$ amostras.




Figura 20 – a) SE \times Potência transmitida $[W]$, e b) SE \times número de amostras (N) testados para os modos SE e EE.

Fonte: Autoria própria.

Além disso, a Figura 20.b) revela a tendência da SE para com a variação do número de amostras coletadas variando de $N \in [0; 5 \cdot 10^5]$. Pode-se observar a diminuição da SE quando o número de amostras N cresce; isso se deve ao aumento do tempo de sensoriamento, e o modo SE resulta em melhor eficiência espectral do sistema do que o modo EE.

Finalmente, na Figura 21.a) e 21.b) consideramos o comportamento da EE para variações na potência transmitida, P_t , e o número de amostras coletadas, N , respectivamente. Como esperado, na Figura 21.a) pode-se observar que a curva EE no modo EE resulta em valores muito maiores do que a curva EE no modo SE, ou seja, quase 300% maior @ $P_t = 1[W]$; o ponto ótimo (máximo EE) é mais saliente no modo EE. Finalmente, na Figura 21.b) é investigado o efeito da variação do número de amostras coletadas na EE. Pode-se observar que a EE diminui substancialmente e rapidamente para maior número de amostras; portanto, valores baixos e médios de N devem ser considerados para atingir o desempenho adequado em termos de EE.

As análises desenvolvidas nesta seção revelam a seguinte recomendação para garantir a operacionalidade dos modos SE e EE propostos para sistemas secundários equipados com múltiplas antenas massivas descalibradas:

$$\text{modo SE: } M = 100 \text{ antenas; } N = 200 \text{ amostras}$$

modo EE: $M = 20$ antenas; $N = 500$ amostras




Figura 21 – Eficiência Energética (EE) [bits/Joule] \times a) Potência transmitida [W], b) número de amostras coletadas, N testadas para os modos SE e EE.

Fonte: Autoria própria.

3.6 Conclusões

O estudo de sistemas cognitivos empregando um alto número de sensores/receptores (próximo a centenas de antenas) é de fundamental importância para os sistemas sem fio 5G. Neste capítulo o emprego de múltiplas antenas massivas em uma BS secundária tornou o SS mais robusto podendo-se aplicar técnicas de SS já conhecidas na literatura, tais como os detectores CAV, HD e VD. Além disso, efeitos de descalibração das antenas devem ser considerados como forma de adotar modelos mais realistas de estruturas da camada física de comunicação.

O uso de sistemas equipados com um número grande de antenas nos permitiu adotar regras para garantir melhores SE e EE, baseadas nas escolhas dos tamanhos das amostras de sinal primário coletadas na BS secundária e o número de antenas utilizadas (ou não, reduzindo assim a potência gasta pelo sistema) durante o SS. Estas antenas podem assumir basicamente duas formas de operação, sendo totalmente desligadas ou mesmo transmitindo em bandas já sensoriadas, em um esquema de *spectrum sharing*.

Além disso, os limiares de detecção das técnicas de SS foram determinadas por meio de um procedimento analítico-iterativo de otimização de tal forma que minimize a probabilidade total de erro garantindo assim mais robustez as melhores técnicas de SS utilizadas neste capítulo (CAV, HD e VD).

4 SENSORIAMENTO ESPECTRAL DE MÚLTIPLAS FONTES PRIMÁRIAS AUXILIADO POR REDES NEURAI CONVOLUCIONAIS EM SISTEMAS SECUNDÁRIOS COM ELEVADO NÚMERO DE ANTENAS DESCALIBRADAS

4.1 Introdução

Um problema recorrente em sistemas de comunicação sem fio é a demanda cada vez maior por altas taxas de dados impactando cada vez mais os recursos escassos de espectro disponíveis. Como já visto nos capítulos 2 e 3 desta tese, dentre as tecnologias sem fio propostas para resolver esse desafio, a alocação dinâmica de espectro (*dynamic spectrum allocation*, DSA) por SUs usando CRs tornou-se particularmente popular nos últimos anos. Os CRs devem detectar possíveis buracos no espectro para usar de forma eficiente como um usuário oportunista empregando metodologias SS. O problema chave em SS é desenvolver um teste estatístico que garanta alta probabilidade de detecção (P_d) sujeito a uma probabilidade mínima de falso alarme (P_f). Além disso, um limiar de detecção eficiente deve ser projetado para garantir essas restrições.

Ultimamente, sistemas empregando SUs equipados com antenas massivas foram implantados para realizar SS, garantindo desempenho superior em comparação aos sistemas de única antena (KOBESSI et al., 2019), (DEY; CIUNZO; ROSSI, 2020) e (DEY et al., 2020). Por exemplo, os autores em (KOBESSI et al., 2019), empregam um sistema secundário com múltiplas antenas massivas em um esquema usando algumas antenas para sensoriar o espectro e o restante para outras atividades, como transmissão, etc. Isso é possível por meio de uma otimização entre o número de antenas e o tamanho das amostras coletadas. Em (DEY; CIUNZO; ROSSI, 2020), os autores propõem um FC composto com antenas massivas para detectar cooperativamente um PU de múltiplos canais baseado no sistema de multiplexação por divisão de frequências ortogonais (*orthogonal frequency multiplexing*, OFDM). Os mesmos autores em (DEY et al., 2020) usando os resultados de (DEY; CIUNZO; ROSSI, 2020) em um trabalho experimental garantem com sucesso a aplicação da metodologia do FC equipado com antenas massivas. Atualmente, esses dois artigos constituem as principais referências tratando SS em cenários com antenas massivas.

Por outro lado, os SUs munidos com sistemas MIMO convencional têm sido amplamente empregados no problema de SS. Em (HUANG et al., 2015), os autores propuseram um SS cego e robusto baseado na detecção de Hadamard (HD) para sistemas não circulares (*noncircular*, NC) em MIMO-CRs. O teste estatístico proposto foi comparado com o detector AGM, JD, ED e detector de maior autovalor (*scaled largest eigenvalue*, SLE). Os autores em (HUANG et al., 2015) discutem o desempenho teórico do detector HD aplicado ao SS em sistemas MIMO-CRs. Da mesma forma, em (YANG et al., 2018) expressões analíticas para o P_f e o limiar de decisão são derivados para o detector HD.

Os autores em (LIU et al., 2017) propõem um sistema MIMO-SS baseado em detectores de ponderação de autovalor ótimo (*optimal eigenvalue weighted*, OEW). Os pesos no método dos autovalores são basicamente determinados por meio de uma otimização que garante a solução do teste de razão de verossimilhança (*likelihood-ratio test*, LRT) seguindo o critério NP para obter o esquema SS ótimo. Em (MEHRABIAN; ZAIMBASHI, 2018) um detector de autovalor robusto e cego foi proposto para operar com múltiplas antenas empregadas em SS sujeitas ao desequilíbrio em fase e quadratura (*in-phase/quadrature-phase imbalance*, IQI). O detector proposto é referido como detector Geral Real de Rank-2 (*real-general rank 2*, Re-GR2) e é comparado com o VD, CAV, AGM, JD, HD e SLE resultando no melhor desempenho entre todos. Finalmente, em (BOUALLEGUE et al., 2018), os autores propõem um detector para SS cego e robusto usando os autovalores extremos (maior e menor) da matriz de covariância, ou seja, autovalor extremo médio quadrático (*mean-to-square extreme eigenvalue*, MSEE), que é baseado no detector AGM usando apenas os autovalores extremos. Os resultados numéricos mostram que o MSEE resulta em melhor desempenho do que o detector MME, AGM, assim por diante.

Um tipo de detector de covariância é proposto em (CHEN; SHI, 2020) com o objetivo de operar com o sinal NC em cenários com múltiplas antenas descalibradas. O detector proposto foi chamado de covariância NC (*noncircular covariance*, NCC) e é comparado com alguns detectores de última geração, como CAV, HD, VD, detector de variância local média (*local average variance*, LAV), teste de estimativa de função de separação (*separating function estimation test*, SFET) e teste invariante localmente mais poderoso (*locally most powerful invariant test*, LMPIT). Os resultados numéricos mostram as vantagens do NCC sobre os detectores de última geração para $SNR \in (-7, -13)$ [dB] em termos de desempenho com baixa complexidade computacional. Em (CHEN et al., 2021), os autores propuseram um novo detector SS para funcionar com a correlação e descalibração de antenas em múltiplas antenas para SS. O detector foi chamado de variância média local baseada em correlação (*correlation local average variance*, CLAV). O detector tem a vantagem de operar com a correlação de antenas em comparação com outros detectores de última geração. O artigo (CHEN; SHI, 2018) propõe o método do detector de covariância ponderada de valor real (*real weighted covariance detector*, RWCD) para diminuir a complexidade computacional do detector de covariância ponderada (*weighted covariance detector*, WCD) que são detectores SS para sistemas com múltiplas antenas correlacionadas. Além disso, em (CHEN; SHI; HE, 2018) foi proposto um detector para SS cego e robusto para um sistema munido com múltiplas antenas correlacionadas baseado no teste estatístico Ljung-Box (LB), que é baseado em funções de autocorrelação e funcionou muito bem para antenas que possuem baixa correlação. Por fim, em (CHEN et al., 2019), os autores propuseram o detector NC-LAV para tratar com o sinal não circular em múltiplas antenas empregadas para o SS garantindo baixa complexidade computacional.

Além disso, em (POURGHAREHKHAN; TAHERPOUR; GAZOR, 2019) os autores

apresentam os detectores Rao e SFET para operar com o arranjo (*array*) de antenas lineares uniformes (*uniform linear antennas*, ULA) descalibradas para realizar o SS. Os detectores foram comparados com o LMPIT, teste de razão de verossimilhança generalizada (*generalized likelihood ratio test*, GLRT) entre outros e apresentaram bom desempenho com baixa complexidade computacional. Os autores em (JALALI; ZAIMBASHI, 2020) projetaram um detector para realizar o SS sob o IQI no transmissor e receptor e também sujeito a antenas receptoras descalibradas. No artigo (TAHERPOUR; TOGHRAEI, 2019) foi proposto um detector para SS geral para CRs utilizando múltiplas antenas equipadas com o detector Rao complexo e no (GETU; AJIB; LANDRY, 2018) o teste F com expressões analíticas de desempenho simples foi obtido para aplicação em SS munido de múltiplas antenas em contraponto aos detectores cegos com expressões analíticas complicadas.

Em (YANG et al., 2019), (SMITH et al., 2019) e (SENANAYAKE et al., 2020), o detector de esfericidade (*sphericity detector*, SD) foi estudado. Em (YANG et al., 2019) resultados analíticos são derivados para o SD usando várias fontes primárias. O artigo (SMITH et al., 2019) propõe uma forma distribuída de detector SD. E finalmente, em (SENANAYAKE et al., 2020) os autores propuseram um detector que mistura os detectores ED e SD.

Para os sistemas atuais de redes sem fio baseados na quinta geração (5G) e para as futuras redes sem fio, nomeadamente para além do 5G (*beyond 5G*, B5G), e sexta geração (6G), a inteligência artificial (*artificial intelligence*, AI) tem e terá um papel fundamental. Mais especificamente, o aprendizado profundo (*deep learning*, DL) que é um subcampo da teoria de aprendizado de máquina (*machine learning*, ML) vem ganhando grande interesse para sistemas cognitivos que inevitavelmente devem empregar o SS periodicamente (NAWAZ et al., 2019). Por exemplo, os autores em (GAO et al., 2019) propõem um método DL baseado em uma rede neural convolucional chamada *convolutional long short-term deep neural network* (CLDNN) para resolver o problema envolvendo SS explorando as informações de sinais modulados; além disso, em (LEE; KIM; CHO, 2019) uma CNN é aplicada à fusão cooperativa de informações concernentes ao SS usando informações do ED e sinalização multi-banda. O método proposto resulta melhor em termos de desempenho em comparação com as metodologias tradicionais de CSS e o método ML de máquinas de vetores de suporte (*support vector machine*, SVM).

Os autores em (LIU et al., 2019), (XIE et al., 2019) propõem um teste estatístico construído a partir da saída de uma CNN, tendo como entrada a matriz de covariância dos sinais recebidos da rede primária. Como se sabe, os métodos baseados em CNN são instrumentais e muito populares nos campos de processamento de imagens. As redes convolucionais têm a capacidade de extrair características da imagem de entrada. Semelhante a aplicação em processamento de imagem, a CNN em cenários que aplicam o SS tem poderosas capacidades de aprender características espaciais das matrizes de

covariância de entrada e extrair informações valiosas no domínio do tempo, por exemplo, energia e correlação das matrizes de entrada. Assim, aprender características espaciais em redes cooperativas implica em mais informações sobre os sinais das redes primárias que impactam diretamente no desempenho do SS. Os resultados numéricos mostram a capacidade superior em termos de SS que a CNN possui em comparação com detectores de última geração, como CAV, ED e assim por diante. No entanto, foi observado um aumento na complexidade computacional devido ao processo de treinamento *offline* e à complexidade da estrutura não linear da CNN. Além disso, em (XIE et al., 2020) os autores propuseram uma estrutura baseada em uma CNN em conjunto com o método DL de memória de curto longo prazo (*long short-term memory*, LSTM) visando aumentar a capacidade de desempenho extraindo as características temporais da entrada. Mais uma vez, a complexidade computacional foi aumentada pela adição de mais processamento na rede neural. Além disso, em (CHEN et al., 2021) uma estrutura CNN é implantada em conjunto com a transformada de Fourier de curta duração (*short time Fourier transform*, STFT) para explorar informações no domínio da frequência das amostras do sinal da rede primária. Por fim, em (PENG et al., 2020) uma abordagem de *transfer learning* (TL) é incorporada à CNN visando aumentar a robustez do processo.

Em (TEKBİYİK et al., 2021), um modelo utilizando uma CNN empregando a função de correlação espectral (*spectral correlation function*, SCF) para caracterização de propriedades de cicloestacionaridade é proposto para uso em SS. O método proposto classifica sinais sem fio sem informação *a priori* e é implementado em duas configurações diferentes, onde os sinais podem ser detectados e classificados de forma conjunta ou sequencial. O método CNN em (TEKBİYİK et al., 2021) não requer um processo de decisão estatística e não precisa conhecer as características distintas dos sinais antecipadamente. Avançando um pouco mais, é bem conhecido que os sinais OFDM são difíceis de sensoriar pelos CRs. Em (CHENG et al., 2019), os autores propuseram um método baseado em DL utilizando *autoencoder* empilhado (*stacked autoencoder*, SAE) para sensoriar sinais OFDM, enquanto em (TIAN et al., 2019) foi usado um classificador ML do tipo *naive Bayes* (NB) para detectar sinais OFDM. Outra abordagem que também pode ser usada no problema empregado pelo SS é a TL (PENG et al., 2020), (LIU et al., 2021), (MAJUMDER, 2022). A metodologia TL armazena o aprendizado de conhecimento de outro problema conectado e pode ser aplicada a problemas diferentes, mas relacionados. Em (PENG et al., 2020), os autores propõem um método de DL baseado na CNN. Em alguns cenários, o desempenho de detecção é degradado. O método TL foi incorporado para solucionar o problema, melhorando o desempenho em termos de SS. Um problema semelhante é tratado por (LIU et al., 2021) em que o sensoriamento do sinal é realizado em um sistema de comunicação de retroespalhamento. Novamente, o TL é usado e ajuda a melhorar o desempenho em termos de SS.

Um modelo de mistura Gaussiana (*Gaussian mixture model*, GMM) com o objetivo

de melhorar o SS baseado em autovalores em sistemas de comunicação utilizando múltiplas antenas descalibradas é proposto em (MAJUMDER, 2022). O autor usa os componentes dos autovalores como vetores de decisão de treinamento que se aproximam do GMM, e os parâmetros de configuração são calculados usando o conhecido algoritmo de maximização de expectativa (*expectation-maximization*, EM). Com os valores dos parâmetros obtidos, calcula-se a probabilidade *a posteriori* dos vetores de decisão, e o canal é classificado como ocupado ou ocioso.

4.1.1 Contribuições

Propomos uma abordagem baseada em uma CNN para utilizar no SS de múltiplas fontes primárias operando com SUs equipados com antenas massivas descalibradas com o objetivo de aprender e determinar o teste estatístico mais adequado para cada cenário de sensoriamento; além disso, analisamos extensivamente e caracterizamos estatisticamente a topologia SS baseada em CNN proposta operando sob antenas de recepção massivas descalibradas, comparando: a) probabilidade de detecção *versus* probabilidade de falso alarme (curvas $P_d \times P_f$), ou seja, a ROC; b) Robustez em termos de P_d operando sob SNR muito baixa; c) a influência do número de amostras no desempenho da rede CNN; d) o número de antenas utilizadas pelo SU; e) o impacto do número de fontes primárias na probabilidade de detecção; bem como f) a complexidade computacional por amostra dos dez métodos SS analisados/comparados considerando um sistema que emprega o SS com múltiplas fontes primárias e o SU equipado com antenas massivas descalibradas.

4.2 Modelo de Sistema

Adotamos uma estação rádio-base secundária sensoriando o espectro equipada com um total de M antenas massivas descalibradas. Cada antena coleta N amostras de sinal; assim, MN é o total de amostras coletadas de fontes da rede primária munida com P PUs. As fontes primárias são transmitidas com diferentes níveis de potência equipadas com uma única antena. A Figura 22 mostra a topologia geral para a rede primária com múltiplas fontes conjuntamente com a rede secundária com *base-station* (BS) munida de múltiplas antenas descalibradas.

O sinal recebido na BS secundária equipada com um grande número de antenas M pode ser escrito como

$$\mathbf{X} = \mathbf{A}\mathbf{H}\mathbf{S} + \mathbf{N}, \quad (4.1)$$

onde a matriz $\mathbf{A} \in \mathbb{R}^{M \times M}$ é a matriz de amplitude dos sinais $\mathbf{A} = \text{diag}\left(\sqrt{\frac{p_i}{\bar{p}}}\right)$ dado o vetor de potência recebido em cada antena SU por $\mathbf{p} = [p_1, p_2, \dots, p_M]$ e seu valor médio $\bar{p} = \frac{1}{M} \sum_{i=1}^M p_i$; observe que $\mathbf{H} \in \mathbb{C}^{M \times P}$ é a matriz de desvanecimento do canal que é independente e identicamente distribuído (i.i.d.), $\mathbf{S} \in \mathbb{C}^{P \times N}$ é o N é o vetor de amostras do sinal da fonte primária, e $\mathbf{N} \in \mathbb{C}^{M \times N}$ é a matriz de ruído recebido nos SUs.

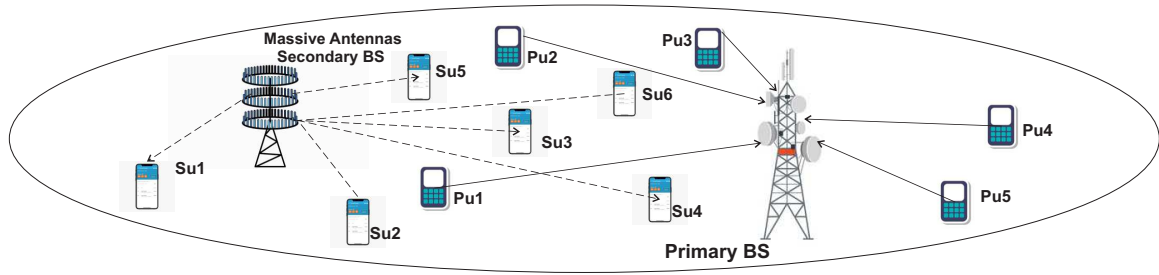


Figura 22 – Topologia das redes primária e secundária.
Fonte: Autoria própria.

Um modelo de sistema mais completo poderia incluir os vetores de direção, que requerem determinação da direção de chegada (*direction of arrival*, DoA) e/ou ângulo de chegada (*angle of arrival*, AoA) para operação de SS. No entanto, para o propósito estabelecido nesta etapa, o modelo de sistema modelado pela equação (4.1) é suficiente para descrever o sistema e é muito útil para comparação de esquemas de SS aqui estabelecidos.

O teste estatístico binário associado nas M antenas massivas da rede secundária pode ser definido por duas hipóteses

$$\begin{cases} \mathcal{H}_0 : \mathbf{X} = \mathbf{N}, \\ \mathcal{H}_1 : \mathbf{X} = \mathbf{AHS} + \mathbf{N}. \end{cases} \quad (4.2)$$

Além disso, a matriz de covariância pode ser definida como

$$\mathbf{R} = \mathbb{E}(\mathbf{X}\mathbf{X}^H), \quad (4.3)$$

sendo $\mathbb{E}(\cdot)$ a esperança estatística. Seguindo esta definição, podemos reformular a hipótese binária em termos das matrizes de covariância do sinal recebido como

$$\begin{cases} \mathcal{H}_0 : \mathbf{R} = \mathbf{R}_N, \\ \mathcal{H}_1 : \mathbf{R} = \mathbf{R}_S + \mathbf{R}_N. \end{cases} \quad (4.4)$$

sendo \mathbf{R}_N a matriz de covariância do ruído e \mathbf{R}_S a matriz de covariância dos sinais primários. Devido às propriedades estacionárias e de ergodicidade do sinal recebido, pode-se aproximar a matriz de covariância como média de amostras sobre N amostras de sinal recebidas na etapa de SS, ou seja, a matriz de covariância de amostra (SCM) que contém informações sobre energia e correlação dos sinais primários

$$\mathbf{R} \simeq \frac{1}{N} \mathbf{X}\mathbf{X}^H. \quad (4.5)$$

4.2.1 Receptores MIMO Massivos Descalibrados

Por uma questão de unidade do capítulo revisitaremos as informações contidas no capítulo 3 que descrevem as condições que fazem com que os receptores baseados em múltiplas antenas sejam descalibrados. Em elementos de RF altamente escaláveis com um grande número antenas, o baixo custo e o consumo reduzido são fundamentais. Como consequência, as variações de ruído σ_n^2 resultam diferentes por refletir a tolerância potencial nos componentes da cadeia de antenas massivas de RF. Para a descrição teórica, consideramos que as variações de ruído na entrada da n th antena do sistema secundário possuem a seguinte propriedade

$$\sigma_n^2 \neq \sigma_m^2, \text{ onde } n \neq m, \forall m, n \in \{1, 2, \dots, M\}. \quad (4.6)$$

Assim, para fins de modelagem, pode-se descrever tal efeito como uma variável aleatória (*random variable*, r.v.) entre as variâncias de ruído. Neste artigo, consideramos uma distribuição uniforme $\mathcal{U}[\cdot, \cdot]$ em torno da variância de ruído e média de ruído para modelar os elementos de antena massivos descalibrados

$$\sigma_n^2 \sim \mathcal{U} [m_{\sigma_n^2}, \text{Var}(\sigma_n^2)], \quad \forall n \in \{1, 2, \dots, M\}, \quad (4.7)$$

onde o primeiro e o segundo parâmetros na distribuição uniforme $\mathcal{U}[\cdot, \cdot]$ representam a média e a variância da variável aleatória σ_n^2 . Modelagem semelhante pode ser considerada na potência de transmissão no lado do transmissor primário.

4.3 Métodos Clássicos para SS em Sistemas MIMO

Métodos clássicos e avançados utilizados em SS disponíveis na literatura são revisados nesta parte. Consideramos diferentes teste estatísticos para SS em sistemas com múltiplas antenas disponíveis na literatura. Para uma análise justa e representativa, selecionamos nove detectores multi-antenas utilizados para SS: a) GLRT; b) LMPIT; c) MME; d) CAV; e) HD; f) VD; g) SD; h) JD e i) AGM. Na sequência, é fornecida uma breve descrição de cada um desses testes estatísticos mencionados. Por uma questão de unidade do capítulo revisitaremos alguns detectores já vistos no capítulo 3.

4.3.1 Generalized Likelihood Ratio Test - GLRT

O teste estatístico do detector GLRT é dado por (WANG et al., 2010)

$$T_{\text{GLRT}} = \frac{\lambda_1(\mathbf{R})}{(1/M)\text{Tr}(\mathbf{R})}, \quad (4.8)$$

onde λ_1 é o autovalor mínimo da matriz \mathbf{R} .

4.3.2 Locally Most Powerful Invariant Test - LMPIT

O teste estatístico do detector LMPIT é dado por (PRIES; RAMÍREZ; SCHREIER, 2018)

$$T_{\text{LMPIT}} = \|\mathbf{C}\|_F^2, \quad (4.9)$$

sendo $\mathbf{C} = \mathbf{D}^{-\frac{1}{2}} \mathbf{R} \mathbf{D}^{-\frac{1}{2}}$. A matriz $\mathbf{D} = \text{diag}(\text{diag}(\mathbf{R}))$ é uma matriz diagonal dos principais elementos diagonais da matriz de covariância \mathbf{R} . A norma $\|\cdot\|_F$ é a norma de Frobenius da matriz.

4.3.3 Maximum-Minimum Eigenvalue Detector - MME

O teste estatístico do detector MME é dado por (ZENG; LIANG, 2009a)

$$T_{\text{MME}} = \frac{\lambda_1(\mathbf{R})}{\lambda_M(\mathbf{R})}, \quad (4.10)$$

onde λ_M e λ_1 é o máximo e mínimo autovalor da matriz \mathbf{R} respectivamente.

4.3.4 Arithmetic-Geometric Detector - AGM

O teste estatístico do detector AGM é dado por (WANG et al., 2010)

$$T_{\text{AGM}} = \frac{\frac{1}{M} \text{Tr}(\mathbf{R})}{\det(\mathbf{R}^{\frac{1}{M}})}, \quad (4.11)$$

onde M é o número de autovalores de \mathbf{R} . Este detector é cego, porém, sua complexidade computacional é alta devido ao cálculo do determinante da matriz de covariância $\mathbf{R}^{1/M}$.

4.3.5 John's Detector - JD

O teste estatístico do JD é dado por (HUANG; XIAO; ZHANG, 2015)

$$T_{\text{JD}} = \frac{\text{Tr}(\mathbf{R}^2)}{[\text{Tr}(\mathbf{R})]^2}. \quad (4.12)$$

O JD é cego pois requer apenas o cálculo da matriz de correlação de N amostras do sinais primários no canal sensoriado; o detector JD está baseado na multiplicação de matrizes, resultando, como esperado, em alta complexidade computacional.

4.3.6 Covariance Detector - CAV

O teste estatístico do detector CAV é dado por (ZENG; LIANG, 2009b)

$$T_{\text{CAV}} = \frac{\sum_{i,j=1}^M |r_{ij}|}{\text{Tr}(\mathbf{R})}. \quad (4.13)$$

4.3.7 Sphericity Detector - SD

O teste estatístico do SD é dado por (SMITH et al., 2019)

$$T_{SD} = \frac{\det(\mathbf{R})}{\left(\frac{1}{M} \text{Tr}(\mathbf{R})\right)^M}. \quad (4.14)$$

4.3.8 Hadamard Detector - HD

Para o HD, o teste estatístico pode ser escrito como (HUANG; XIAO; ZHANG, 2015)

$$T_{HD} = \frac{\det(\mathbf{R})}{\prod_{i=1}^M r_{ii}}. \quad (4.15)$$

Este detector foi originalmente proposto para funcionar em cenários descalibrados (HUANG; XIAO; ZHANG, 2015). A descrição teórica do desempenho do HD até agora não foi relatada com precisão na literatura.

4.3.9 Volume Detector - VD

Para o VD, o teste estatístico pode ser escrito como (HUANG; XIAO; ZHANG, 2015)

$$T_{VD} = \log(\det(\mathbf{G}^{-1} \mathbf{R})), \quad (4.16)$$

onde $\mathbf{G} = \text{diag}(\mathbf{s})$, $\mathbf{s} = [s_1, \dots, s_M]$, e para cada elemento sendo definido como $s_i = \|\mathbf{R}(i, :)\|_2$. O VD é outro detector para SS proposto para operar em cenários descalibrados.

4.4 Teste Estatístico baseado em CNN para Múltiplas Fontes Primárias aplicado em SS para Sistemas Cognitivos equipados com Múltiplas Antenas Massivas Descalibradas

Nesta seção, a determinação do teste estatístico baseado em CNN é derivada para sistemas secundários com múltiplas antenas descalibradas para SS de múltiplas fontes primárias. Basicamente, o processo é dividido em treinamento *offline* e a validação *online*. As fundações teóricas das CNNs são revisitadas a seguir.

4.4.1 Estrutura das CNNs

As redes neurais convolucionais (*convolutional neural networks*, CNNs) são redes neurais com uma pré-etape de processamento dos dados de entrada fazendo o uso de convoluções no lugar de multiplicações gerais de matrizes em pelo menos uma das camadas da rede neural (GOODFELLOW; BENGIO; COURVILLE, 2016). A motivação é baseada na neurociência, mais especificamente, no funcionamento do córtex visual do cérebro. A estrutura geral da CNN adotada neste trabalho está representada na Figura 23.

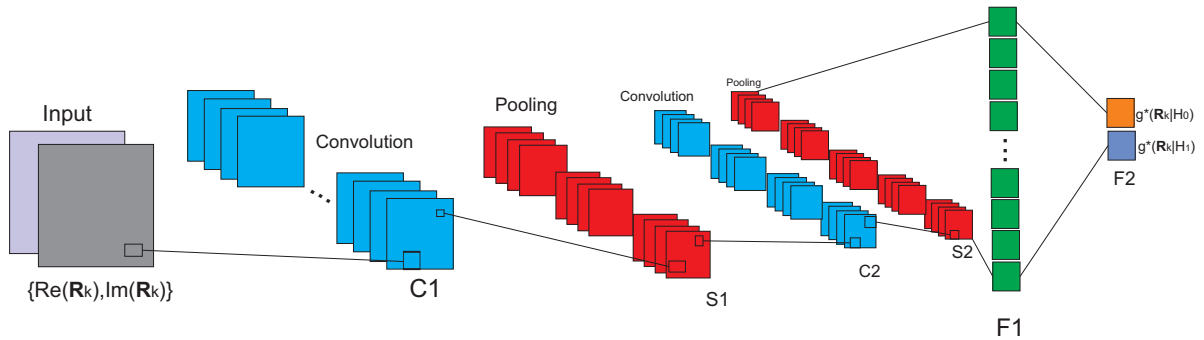


Figura 23 – Arquitetura típica de uma CNN.
Fonte: Autoria própria.

4.4.1.1 Operação de Convolução

Basicamente, a operação de convolução para entradas com valores contínuos é descrita como

$$s(t) = \int x(a)w(t-a)da = (x \otimes w)(t), \quad (4.17)$$

onde x é a entrada, w é o *kernel* (ou filtro, núcleo) e s é a saída, também chamada de mapa de recursos (*feature map*). Para sistemas discretos temos

$$s(k) = (x \otimes w)(k) = \sum_{a=-\infty}^{\infty} x(a)w(k-a). \quad (4.18)$$

Considerando dados 2D de entrada, por exemplo, matrizes, imagens, etc. A operação de convolução discreta é calculada como

$$S(i, j) = (I \otimes K)(i, j) = \sum_m \sum_n I(m, n)K(i-m, j-n), \quad (4.19)$$

onde o elemento de entrada 2D é $I(i, j)$, e o elemento que constitui o *kernel* 2D é definido por $K(i, j)$. Mais especificamente, para as matrizes \mathbf{I} e o *kernel* \mathbf{K} , a saída da operação de convolução 2D é

$$\mathbf{S} = \begin{bmatrix} aw + bx + ey + fz & bw + cx + fy + gz & cw + dx + gy + hz \\ ew + fx + iy + jz & fw + gx + jy + kz & gw + hx + ky + lz \end{bmatrix},$$

$$\mathbf{I} = \begin{bmatrix} a & b & c & d \\ e & f & g & h \\ i & j & k & l \end{bmatrix} \quad \text{e} \quad \mathbf{K} = \begin{bmatrix} w & x \\ y & z \end{bmatrix}.$$

4.4.1.2 Funções de Ativação

Uma função de ativação em uma rede neural (*neural network*, NN) é definida como a soma ponderada da entrada e transformada em uma saída de um nó ou nós em uma

camada da rede. Neste capítulo utilizaremos duas funções de ativação, a unidade linear retificada (*rectified linear unit*, ReLU) e a *softmax*.

A função de ativação *Rectified Linear Unit* (ReLU) é definida como

$$\text{ReLU}(x) = \max(0, x) = \begin{cases} x, & x > 0, \\ 0, & x \leq 0. \end{cases} \quad (4.20)$$

Softmax é uma função de ativação implementada na saída da NN para classificação binária e é definida como

$$\text{Softmax}(x)_i = \frac{\exp(x)_i}{\sum_{j=1}^n \exp(x)_j}. \quad (4.21)$$

4.4.1.3 Camadas Convolucionais

As Camadas Convolucionais são responsáveis pela operação de convolução. Depende do tamanho dos dados de entrada, que podem ser 1D (escalares ou vetores), ou 2D (matrizes), ou mesmo 3D (matrizes e tensores). O processo de convolução garante seletividade e melhor visualização das informações dos dados de entrada, em um processo semelhante ao realizado pelo cérebro a partir das imagens captadas pela visão humana.

4.4.1.4 Camadas de Pooling

A camada de *pooling* é uma nova camada adicionada após uma camada convolucional. Camadas de *pooling* são utilizadas para reduzir as dimensões dos *featured maps*. Assim, esta camada é responsável por reduzir o número de parâmetros a serem aprendidos e a quantidade de etapas de computação realizada pela rede. A camada de *pooling* resume os *features* presentes em uma região do mapa gerada por uma camada de convolução. Basicamente, a principal operação de *pooling* é o *pooling* máximo (*maxpool*) ou o *pooling* médio (*mean*) (*avgpool*), definido, respectivamente, por:

$$\begin{aligned} y_{\text{maxpool}} &= \max \{x_{i,j}\}_{i,j=1}^{h,w}, \\ &\text{e} \\ y_{\text{avgpool}} &= \frac{1}{hw} \sum_{i,j=1}^{h,w} x_{i,j}. \end{aligned} \quad (4.22)$$

4.4.1.5 Camada Totalmente Conectada (*Fully Connected Layer*)

Todos os *feature maps* de saída da última camada convolucional + camada de *pooling* são conectados às camadas ocultas (*hidden*) da rede neural (camada densa), que é uma NN *feedforward* ou uma *perceptron* de múltiplas camadas (*multilayer perceptron*, MLP) para otimizar (minimizar) alguma função de perda (que representa a regra de

aprendizado da NN). A função de perda *cross-entropy* é definida como

$$\mathcal{J} = \sum_{i=1}^O (-d_i \log(y_i) - (1 - d_i) \log(1 - y_i)), \quad (4.23)$$

onde O é o número de camadas ocultas (*hidden*) da NN, d_i é a saída atual da NN (dados de treinamento) e y_i é a saída anterior.

4.4.1.6 Otimização por meio de *Back-Propagation*

A otimização por meio de *Back-Propagation* é baseada no algoritmo *iterative stochastic gradient descent* (SGD). Tal procedimento é utilizado para resolver o problema de otimização associado no aprendizado da NN. O algoritmo SGD calcula o erro para cada dado de treinamento e ajusta/atualiza os pesos (parâmetros de otimização de NN) $\boldsymbol{\theta}$ como

$$\boldsymbol{\theta}(i + 1) = \boldsymbol{\theta}(i) - \eta \nabla J(\boldsymbol{\theta}), \quad (4.24)$$

em que o problema de otimização (minimização) é formulado como

$$\boldsymbol{\theta}^* = \arg . \min ._{\boldsymbol{\theta}} J(\boldsymbol{\theta}) \quad (4.25)$$

onde a função objetivo do problema de otimização é $J = \frac{1}{n} \sum_{j=1}^n \mathcal{J}$ e η é o passo de iteração do algoritmo SGD.

4.4.2 Fase de Treinamento *Off-Line*

Nesta fase, a CNN usa K amostras de dados de treinamento. Basicamente, podemos assumir o conjunto de treinamento *offline* como

$$(\mathcal{R}, \mathcal{Z}) = \{(\mathbf{R}_1, z_1), (\mathbf{R}_2, z_2), \dots, (\mathbf{R}_K, z_K)\}, \quad (4.26)$$

onde $k = 1, 2, \dots, K$ é o número de conjuntos de dados de treinamento, $\text{Re}(\mathbf{R}_k)$ e $\text{Im}(\mathbf{R}_k)$ são as partes real e imaginária dos elementos da matriz de covariância amostral (*sample covariance matrix*, SCM) como dados de entrada e $z \in \{0, 1\}$ é a seleção da hipótese binária. A saída da CNN é um classificador binário que está relacionado à hipótese de probabilidade condicional ociosa e ocupada dada pelas funções de *score*, ou seja,

$$g_{\boldsymbol{\theta}^* | \mathcal{H}_0}(\mathbf{R}_k) \quad \text{e} \quad g_{\boldsymbol{\theta}^* | \mathcal{H}_1}(\mathbf{R}_k). \quad (4.27)$$

Na camada *fully connected* (FC), o problema de otimização pode ser descrito a partir da perspectiva da estimativa baseada em máxima verossimilhança (*maximum likelihood estimation*, MLE), como uma função de perda (*loss function*) ou regra de aprendizado $L(\boldsymbol{\theta}) = \Pr(\mathcal{Z} | \mathcal{R}; \boldsymbol{\theta})$, onde $\boldsymbol{\theta}$ são os parâmetros da NN a serem otimizados (pesos da

rede). Tomando o logaritmo da expressão da função de perda (*loglikelihood function*) $\mathcal{L}(\boldsymbol{\theta}) = \log L(\boldsymbol{\theta})$, resulta

$$\mathcal{L}(\boldsymbol{\theta}) = \frac{1}{K} \sum_{k=1}^K z_k \log g_{\boldsymbol{\theta}}(\mathbf{R}_k) + (1 - z_k) \log(1 - g_{\boldsymbol{\theta}}(\mathbf{R}_k)). \quad (4.28)$$

O objetivo da camada FC (NN) é otimizar a probabilidade condicional *a posteriori* $\Pr(\mathcal{Z}|\mathcal{R}; \boldsymbol{\theta})$ selecionando os melhores pesos $\boldsymbol{\theta}^*$ para a NN. Desta forma, o problema de otimização se torna

$$\boldsymbol{\theta}^* = \arg . \max ._{\boldsymbol{\theta}} \Pr(\mathcal{Z}|\mathcal{R}; \boldsymbol{\theta}). \quad (4.29)$$

Na teoria Bayesiana em processamento de sinais estatísticos, esta formulação corresponde ao critério de máximo *a posteriori* (*maximum a posteriori probability*, MAP). Agora, podemos obter a probabilidade *a posteriori* da hipótese binária como

$$\begin{cases} \mathcal{H}_0 : \Pr(\mathcal{H}_0|\mathbf{R}) = g_{\boldsymbol{\theta}^*|\mathcal{H}_0}(\mathbf{R}_k), \\ \mathcal{H}_1 : \Pr(\mathcal{H}_1|\mathbf{R}) = g_{\boldsymbol{\theta}^*|\mathcal{H}_1}(\mathbf{R}_k). \end{cases} \quad (4.30)$$

Pelo critério ótimo de Neyman-Pearson (NP) e teorema de Bayes para maximizar P_d para um dado P_f , o teste estatístico pode ser calculado e comparado ao limiar de decisão λ_{CNN} como

$$T_{\text{CNN}} = \frac{\Pr(\mathcal{H}_1|\mathbf{R})}{\Pr(\mathcal{H}_0|\mathbf{R})} = \frac{g_{\boldsymbol{\theta}^*|\mathcal{H}_1}(\mathbf{R}_k)}{g_{\boldsymbol{\theta}^*|\mathcal{H}_0}(\mathbf{R}_k)} > \lambda_{\text{CNN}}. \quad (4.31)$$

Limiar de Decisão, λ_{CNN} : antes de explicar como se proceder a validação online, definimos como calcular o limiar de decisão para justa comparação do teste estatístico obtido por meio da CNN. Com base na Simulação de Monte-Carlo, e devido às dificuldades em encontrar expressões de limiar de detecção fechadas analiticamente, vislumbramos uma regra empírica baseada na hipótese de ociosidade do canal primário. Assim, introduzindo a variável $\ell = \text{sort}(T_{\text{CNN}}|\mathcal{H}_0)$, pode-se determinar por observação o limiar de decisão do detector baseado em CNN simplesmente como

$$\lambda_{\text{CNN}} = \ell \cdot (1 - \overline{P_f}) \cdot N, \quad (4.32)$$

onde N é o número de realizações Monte-Carlo utilizadas na simulação.

4.4.3 Fase de Validação Online

Para avaliar a qualidade das soluções obtidas na fase de treinamento, uma parte do conjunto de dados de entrada total foi usado na CNN como o conjunto de dados de validação. Os conjuntos de dados de treinamento, validação e teste para o método proposto são baseados na emulação de canais estatísticos. Para tornar o modelo robusto

contra mudanças ambientais, diferentes localizações de fontes primárias e secundárias foram emuladas. As localizações dos pontos transmissores e receptores podem ser vistas na Figura 22, onde foi adotado uma célula sem fio de $r = 500\text{m}$. A SNR média é unificada da seguinte forma: para cada sinal observado na banda do sistema, 10 níveis diferentes de SNR na faixa de $[-28; -10]$ dB foram gerados. Cada nível consiste no mesmo número de sinais que é 10^5 . Portanto, sinais de 10^6 no total são registrados e incluídos no conjunto de dados. Quando o método proposto é considerado, o conjunto de dados é dividido em dados de treinamento, validação e teste com a proporção de 70% e 10% e 20%, respectivamente.

4.4.4 Fase de Teste Online

Com base em N amostras do sinal primário coletadas online, podemos calcular a matriz de covariância amostral (SCM). Finalmente, podemos usar a CNN treinada para calcular o teste estatístico online com as matrizes SCM como entrada. Todo o processo de detecção baseado na CNN está resumido no Algoritmo 2.

Algoritmo 2 - Procedimento para determinar o Teste Estatístico para SS utilizando uma CNN

Inicialização:

- ◇ Definir $i = 0$ e θ com pesos pequenos e aleatórios

Fase de Treinamento Offline:

- ◇ Tome o conjunto de treinamento com as matrizes SCMs e a hipótese binária como $\{(\mathbf{R}_1, z_1, \dots, \mathbf{R}_K, z_K)\}$, $k \in \{1, \dots, K\}$ e $z_k \in \{0, 1\}$.

enquanto $i \leq i_{\max}$ **faça**

atualize θ usando o algoritmo SGD;

$i = i + 1$

fim enquanto

Fase de Validação Offline:

- ◇ confirme se os parâmetros θ aprendidos (otimizados) são adequados (sem *overfitting*)

Fase de Teste Online:

- ◇ use θ da etapa de Treinamento Offline;
 - ◇ determine λ_{CNN} , dado pela equação, (4.32), da etapa de Treinamento Offline;
 - ◇ obter os dados de sensoriamento online (matrizes SCM) e a entrada para a CNN.
 - ◇ tomar as decisões a partir da saída da CNN de acordo com (4.31).
-

4.5 Resultados Numéricos

Nesta seção, analisamos os resultados numéricos para o método proposto para SS baseado na CNN em comparação com os detectores de última geração aplicados em sistemas

cognitivos MIMO. A Tabela 8 resume os principais valores dos parâmetros adotados nesta seção. A estrutura da CNN implantada é mostrada na Figura 23.

Tabela 8 – Configurações gerais de Parâmetros

Parameters	Valores adotados
amostras de SCM	$N = 200$ (valid.)
# SU Antenas	$M = 64$
# PU	$P = 6$
SNR média	-15 [dB]
Potência de ruído média	$\sigma_{avg}^2 = 1$ [W] (normalizada)
Potência de ruído no Rx.	$\sigma_i^2 \sim \mathcal{U}[0.05, 1.95]\sigma_{avg}^2$ (descalibrado)
Potência Tx. dos PUs	$\mathcal{P} \sim \mathcal{U}[0.05, 1.95]P_{avg}$
Tipo de Modulação	QPSK
Probabilidade de Falso Alarme	$\bar{P}_f = 0.1$ (alvo)
Simulações de Monte-Carlo	$\mathcal{S} = 5000$ realizações

Definimos o tamanho das amostras como $N = 200$ contendo as matrizes de covariância amostral (SCMs) usadas no processo de validação de aprendizado da CNN. O número de antenas massivas na BS SU é fixado em $M = 64$ antenas. Além disso, definimos o número de fontes primárias como $P = 6$ PUs equipados com uma única antena. A operação de SNR média na rede é tão baixa quanto -15 [dB] devido ao grande número de antenas em cada SU.

A potência de ruído do receptor e potência transmitida pelas PUs varia seguindo uma distribuição uniforme em torno da potência média de ruído e potência média transmitida, que pode ser modelada basicamente por

$$P_{avg} = \sigma_{avg}^2 \cdot 10^{\frac{SNR}{10}},$$

onde a potência de ruído recebida nas antenas secundárias massivas é modelada como em (4.7), e aqui é definida por uma variável aleatória uniformemente distribuída como $\sigma_i^2 \sim \mathcal{U}[0.05, 1.95]\sigma_{avg}^2$, resultando em um sistema sensor com antenas massivas descalibradas operando sob múltiplas fontes primárias com diferentes níveis de potência, também modelados como $\mathcal{P} \sim \mathcal{U}[0.05, 1.95]P_{avg}$. Finalmente, a simulação de Monte-Carlo (MCS) foi definida para $\mathcal{S} = 5000$ realizações.

4.5.1 Estrutura, Treinamento e Etapas de Teste da CNN

Na etapa de treinamento, validação e inferência do algoritmo de SS baseado em CNN foi empregado o pacote Deep Learning disponível na plataforma de simulação matemática MATLAB 2018. Neste pacote há comandos específicos para definir e carregar os conjuntos de treinamento e validação, definir a arquitetura de rede conforme os hiperparâmetros adotados e especificar as opções de treinamento.

A Tabela 9 mostra os hiperparâmetros da CNN usados no processo de aprendizagem offline e online. O treinamento dos dados é definido como $K = 10000$ (número de matrizes

de covariância de amostra), onde na entrada da CNN, cada SCM é uma matriz $M \times M \times 2$ de 3 dimensões. Aqui, duas matrizes são geradas separando as partes reais e imaginárias das matrizes SCMs como $\mathbf{R}(i, j) = \text{Re}(\mathbf{R})_{i,j,1}$ e $\mathbf{I}(i, j) = \text{Im}(\mathbf{R})_{i,j,2}$ respectivamente. Na primeira camada da CNN definimos 20 filtros convolucionais (*kernels*) com tamanho 5×5 para ambos os dois canais dados pela parte real e imaginária dos SCMs. A função ReLU é adotada como função de ativação. Na sequência, a camada de *pooling* é definida como uma *max. pooling* com dimensão 2×2 , como ilustrado na Figura 23. Além disso, uma camada convolucional é repetida tomando 50 filtros convolucionais (*kernels*) com dimensão 5×5 para os dois canais seguidos por mais uma camada de *max. pooling*. Usando uma MLP, definimos a primeira camada FC com 2.048 neurônios e a segunda camada da FC como 1.024 neurônios. Utilizando um esquema de *backpropagation* baseado no algoritmo SGD, a estrutura MLP é treinada até atingir a convergência. A convergência é medida pela função de perda (*loss function*) definida pela função *cross-entropy*, como em (4.23). Finalmente, usando a função de ativação do tipo *softmax* para realizar a classificação binária, a saída da CNN é definida por um vetor de dimensão 2×1 representando as probabilidades ociosas e ocupadas do canal primário.

Tabela 9 – Configuração dos hiperparâmetros da CNN

Camada	Dimensão	FA
dados de treinamento (SCMs)	$K = 10000$	–
SCMs de Entrada	$64 \times 64 \times 2$ (Real/Imag.)	–
Convol. C_1	20 filtros convol. $\times 2$ (5×5)	ReLU
Pool. P_1	1 <i>max. pool.</i> (2×2)	–
Convol. C_2	50 filtros convol. $\times 2$ (5×5)	ReLU
Pool. P_2	1 <i>max. pool.</i> (2×2)	–
FC F_1	2048 neu.	ReLU
FC F_2	1024 neu.	ReLU
Saída	2 (hipótese vazia & ocupada)	<i>Softmax</i>

FC: *full connected*; FA: função de ativação

Os valores de hiperparâmetros adotados aqui seguem uma metodologia de ajuste empírico (tentativa e erro), com refinamentos ou reajustes iterativos. Basicamente, tamanhos padrão para filtros de convoluções são definidos por matrizes 3×3 (tamanho reduzido), 5×5 (médio a grande) ou até mesmo 7×7 (elevado); neste trabalho, adotamos filtros de convolução de dimensão 5×5 em número de 20 filtros, ou seja, filtros de tamanho médio, onde mais informação pode ser extraída comparada com um filtro de convolução de pequena dimensão, entretanto às custas de um incremento na complexidade da rede neural convolucional. Ademais, adotamos valores típicos para as matrizes da camada de *pooling*, isto é 2×2 ou até mesmo 4×4 ; neste trabalho adotamos matrizes *pooling* de tamanho 2×2 , que reduzem um pouco o tamanho das *features* das camadas de convolução, entretanto são parâmetros comumente utilizados nas aplicações de SS. Na segunda camada de convolução aumentamos o número de filtros de convoluções para 50, garantindo assim uma maior

extração nas informações das camadas anteriores às custas de um incremento relativo de complexidade da CNN. Por fim, tomamos três redes neurais MLPs com diferentes números de neurônios, ou seja, a rede CNN_1 , CNN_2 e CNN_3 , com um número crescente de neurônios para cada uma delas: na CNN_1 adotou-se 1024 e 512 neurônios para a primeira e segunda camada, respectivamente. Os resultados de treinamento mostraram que os pesos da MLP foram otimizados, entretanto, não de forma completamente satisfatória. Assim, aumentamos o número de neurônios para 2048 na primeira camada e observamos a melhoria em termos de otimização da função de perda, porém, essa rede pôde ser otimizada aumentando-se o número de neurônios da segunda camada para 1024, resultando na rede CNN_3 , que para uma certa quantidade de épocas de treinamento otimiza muito bem a função de perda para nosso problema de SS. A Figura 24 mostra o progresso de treinamento e convergência para as três CNNs, considerando 200 épocas de treinamento e função de perda baseada na *cross-entropy*.




Figura 24 – Função perda (*cross-entropy*) vs. Épocas de treinamento.
Fonte: Autoria própria.

Treinamento Offline da CNN. Na etapa de treinamento, todas as K matrizes SCMs por SNR são usadas para melhorar o aprendizado da CNN. Assim, para cada SCM as duas tarefas convolucionais são feitas com suas operações de agrupamento (*pooling*) respectivamente. A MLP é treinada, ou seja, os pesos (parâmetros) da rede (θ) são otimizados utilizando o algoritmo *iterative stochastic gradient descent* (SGD) até a convergência medida pelas informações da entropia cruzada (*cross-entropy function*). A Figura 24 mostra o progresso de treinamento e convergência para uma época de treinamento de 200 SGD sob a figura de mérito da função *cross-entropy*. Para operar com a arquitetura

CNN mais adequada em termos de desempenho-complexidade, testamos três configurações MLP para os parâmetros convolucionais e de *pooling* previamente definidos. Dentre as três configurações de CNNs, selecionamos a melhor em termos de convergência (função de perda \times # épocas de treinamento) para o problema de SS. A Tabela 10 mostra as estruturas MLP adotadas na etapa de treinamento offline, assumindo a CNN₁ como uma rede neural com as camadas convolucionais e de *pooling* adotadas pelos hiperparâmetros definidos anteriormente e com a MLP composta por 1024 e 512 neurônios para a primeira e a segunda camadas respectivamente. A CNN₂ assume 2048 e 512 neurônios, enquanto a CNN₃ adota 2048 e 1024 neurônios para a primeira e segunda camada, respectivamente. Como se pode inferir da Figura 24, a melhor rede neural é a configuração CNN₃ que, dentre as redes treinadas, garante a mínima *cross-entropy* para um determinado número de épocas de treinamento.

Tabela 10 – Três Estruturas MLP implementadas no Treinamento Offline da CNN

Config. CNN	# F_1 neur.	# F_2 neur.
CNN ₁	1024	512
CNN ₂	2048	512
CNN ₃	2048	1024

Métricas de Complexidade Computacional e de Desempenho utilizando o Detector baseado na CNN para o SS. Considerando que CNN mais apropriada e bem treinada, foi selecionada a rede CNN₃, para todos os K SCMs, a próxima tarefa é aplicar a metodologia CNN ao nosso problema de SS para sistemas cognitivos usando múltiplas antenas massivas descalibradas e múltiplas fontes primárias. Nas próximas subseções, avaliamos as principais figuras de mérito com o objetivo de caracterizar de forma completa e abrangente o detector baseado no teste estatístico construído a partir da CNN proposta; tais métricas de desempenho incluem: a) *receiver operating characteristic* (ROC); b) probabilidade de detecção *vs.* número de antenas; c) probabilidade de detecção *vs.* número de fontes primárias; d) probabilidade de detecção *vs.* número de amostras; e) probabilidade de detecção para diferentes regimes de SNR; f) complexidade computacional em FLOPS. Além disso, avaliamos e comparamos as curvas de ROC para nossa proposta de SS com outros cinco métodos de SS baseados em CNN de última geração disponíveis na literatura.

4.5.2 Receiver Operating Characteristic (ROC)

A *receiver operating characteristic* (ROC) para o detector baseado em CNN é comparada com os detectores AGM, JD, GLRT, SD, HD, VD, MME, CAV e LMPIT na Figura 25. Para a configuração adotada dada na Tabela 8, pode-se observar a robustez da abordagem de SS baseada na CNN em comparação com os outros nove detectores. Além disso, a CNN é cega, portanto depende apenas das características da matriz de covariância.

De acordo com as propriedades da SCM, o detector para SS bem treinado baseado na CNN selecionado é capaz de alcançar uma probabilidade de detecção próxima a 1 mesmo para níveis de SNR muito baixo de -15 [dB], múltiplas fontes primárias e com antenas massivas descalibradas.




Figura 25 – *Receiver Operating Characteristics*.
Fonte: Autoria própria.

4.5.3 Probabilidade de Detecção vs. Número de Antenas ($P_d \times M$)

O número de antenas no sistema secundário impacta diretamente na probabilidade de detecção. A Figura 26 revela a influência do número de antenas $M \in [45; 80]$ sobre a probabilidade de detecção. Aumentar o número de antenas na BS secundária melhora diretamente a robustez do detector baseado na CNN devido ao fenômeno de endurecimento do canal (*channel hardening*). Notavelmente, a probabilidade de detecção baseada na CNN é próxima de 1, para todas as antenas $M \geq 45$. Com base neste resultado, a escolha mais adequada para sistemas de antenas massivas é considerar as antenas $M \geq 64$. Interessante, lembre-se que nesse cenário analisado, todas as antenas estão descalibradas devido ao sistema de comunicação de baixo custo e baixa fidelidade.

4.5.4 Probabilidade de Detecção vs. Número de Fontes Primárias ($P_d \times P$)

Figura 27 revela a influência do número de fontes primárias na probabilidade de detecção. Variando o número de fontes primárias, equipadas com única antena, na faixa de $P = [1, 20]$ PUs, pode-se observar a grande vantagem do detector baseado na CNN em comparação com os nove detectores de última geração. A probabilidade de detecção

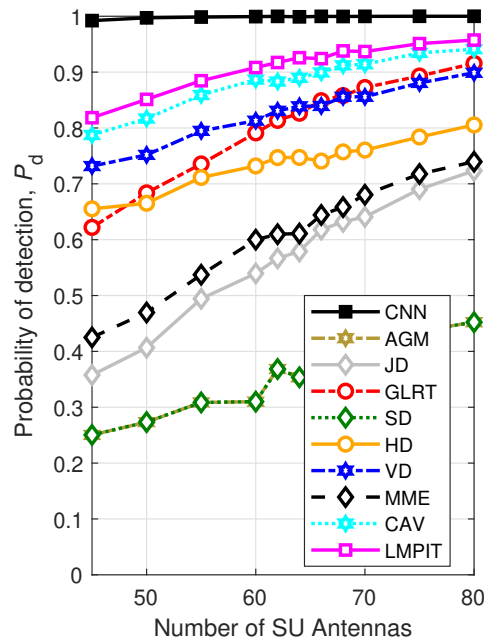


Figura 26 – Probabilidade de Detecção vs. Número de Antenas, M .
Fonte: Autoria própria.

manteve-se muito próxima de 1 para todo o número de fontes primárias selecionadas. Vale ressaltar que todas as fontes primárias possuem diferentes níveis de potência, distribuídos uniformemente. Novamente, o detector baseado na CNN resulta muito mais robusto em contraste com outros detectores para SS de última geração. Tomando $P = 6$ PUs, infere-se claramente a diferença na qualidade de desempenho de todos os detectores.

4.5.5 Probabilidade de Detecção vs. Tamanho das Amostras Coletadas ($P_d \times N$)

Como se sabe, o número de amostras coletadas online N também impacta na probabilidade de detecção. A Figura 28 mostra a influência das amostras (variação das SCMs) online na probabilidade de detecção. De fato, variando o tamanho das amostras no intervalo $N = [100; 1000]$, pode-se observar a robustez superior do detector baseado na CNN em relação aos demais detectores ao longo de todo o tamanho das amostras. De fato, a probabilidade de detecção fornecida pelo teste estatístico baseado na CNN é muito próxima ou igual a 1 para toda faixa de N analisada. Portanto, uma boa escolha é considerar amostras de $N = 200$ SCMs, que ainda possuem um resultado de probabilidade de detecção muito bom (muito próximo de 1).

4.5.6 Probabilidade de Detecção vs. Variações na SNR Média ($P_d \times SNR$)

Agora, vamos avaliar o desempenho da probabilidade de detecção dessas dezenas de detectores sob valores de SNR operacionais muito práticos e interessantes na faixa de $SNR \in [-28; -10]$ [dB]. Na Figura (29), pode-se observar a robustez do detector baseado

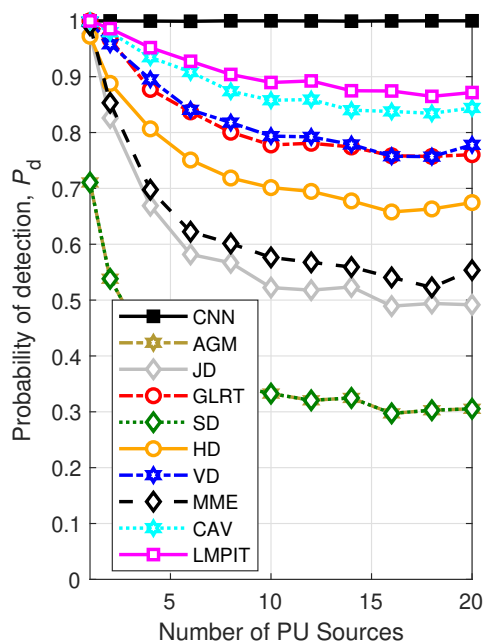


Figura 27 – Probabilidade de Detecção *vs.* Número de fontes primárias; $M = 64$.
Fonte: Autoria própria.

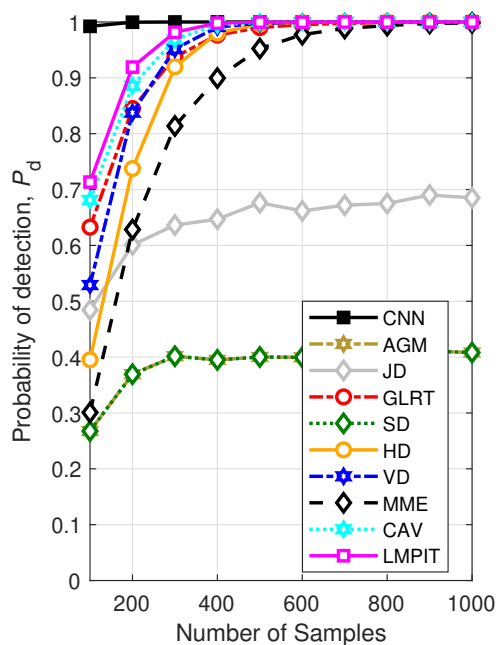


Figura 28 – Probabilidade de Detecção *vs.* Tamanho das amostras.
Fonte: Autoria própria.

na CNN em comparação com os nove detectores de última geração, garantindo muito boa probabilidade de detecção mesmo para valores de SNR muito baixos, por exemplo, o detector baseado na CNN garante $P_d = 0,9$ para uma SNR tão baixa quanto -20 [dB], enquanto os outros detectores atingem no máximo $P_d = 0.22$ para a mesma SNR -20 [dB]. É interessante destacar aqui que o padrão IEEE802.22 regulamenta que os detectores práticos e operacionais devem satisfazer a condição $P_d = 0,9$ para $P_f = 0,1$ em um valor SNR muito baixo de -22 [dB].

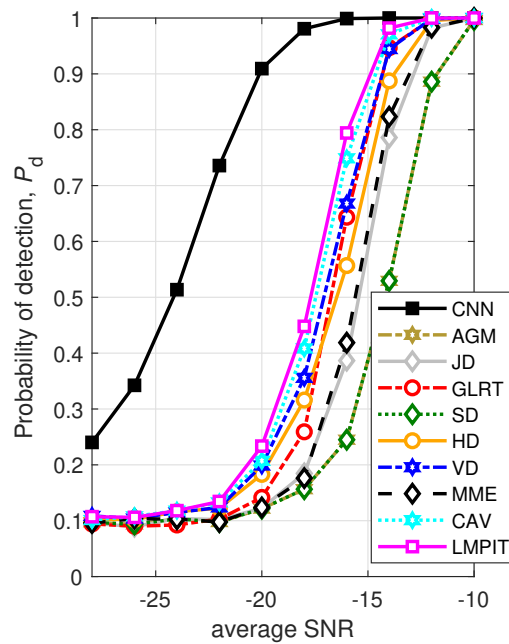


Figura 29 – Probabilidade de Detecção *vs.* SNR Média.
Fonte: Autoria própria.

4.5.7 Comparação entre as metodologias para SS baseadas em CNNs de última geração

As curvas de (ROC) para cinco detectores empregados em SS baseados em CNNs, recentemente disponíveis na literatura, mais especificamente, os detectores em (LIU et al., 2019; XIE et al., 2019; XIE et al., 2020; CHEN et al., 2021; PENG et al., 2020), foram comparados com nosso detector para SS baseado na CNN proposto na Figura 30. Para a configuração adotada dada na Tabela 8 com uma probabilidade de falso alarme de alvo selecionada como $P_f = 0.01$ e seguindo as características dos hiperparâmetros, treinamento e validação das cinco metodologias CNN, pode-se observar a robustez de todas as metodologias aplicadas em SS baseadas em CNNs em termos de ocorrências de alarmes falsos (muito baixos). Além disso, as metodologias híbridas com CNN propostas pelos autores Chen et al. em (CHEN et al., 2021) como o STFT-CNN e Xie et al., (XIE et al., 2020) com o CNN-LSTM resulta em desempenho marginalmente melhor em comparação com os outros detectores baseados em CNN. Essa superioridade marginal se deve à capacidade desses detectores de extrair informações de domínio de tempo-

frequência e correlação de energia, respectivamente, resultando em mais capacidade de aprendizado de recursos de entrada. No entanto, tais metodologias híbridas requerem maior complexidade computacional. Nesse caso, tanto o STFT-CNN quanto o CNN-LSTM aumentam a complexidade computacional inerente dos métodos baseados em CNNs, devido a etapa de cálculos da STFT e do treinamento do LSTM, respectivamente.

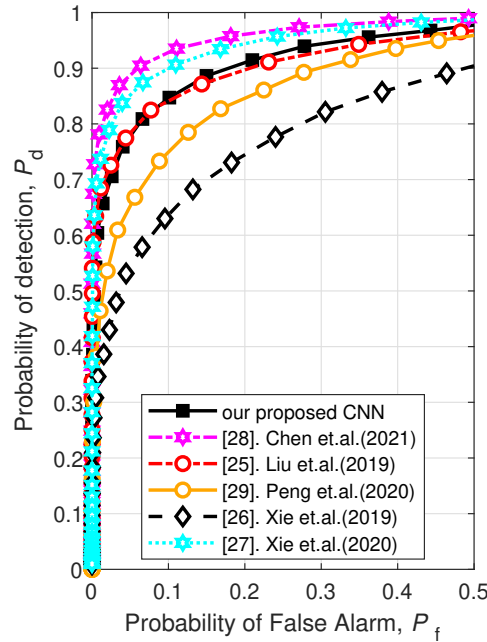


Figura 30 – *Receiver Operating Characteristic* para os métodos de SS de última geração baseados em CNNs *vs.* o método proposto.
Fonte: Autoria própria.

4.5.8 Complexidade Computacional

A Tabela 11 resume a complexidade computacional por amostra em *floating point operations* (Flops) para todos os dez detectores para SS analisados, com o passo em comum do cálculo da matriz de covariância resultando em

$$\mathcal{C}_{\text{SCM}} = MN^2 + N(M - N/2) - N/2 \quad [\text{Flops}],$$

exceto para a CNN que é calculada levando em consideração as partes *online* e *offline*

$$\mathcal{C}_{\text{SCM}}^{\text{CNN}} = \mathcal{C}_{\text{SCM}}^{\text{ONLINE}} + \mathcal{C}_{\text{SCM}}^{\text{OFFLINE}} \quad [\text{Flops}].$$

Na parte *online* a complexidade computacional é igual ao da matriz de covariância comum $\mathcal{C}_{\text{SCM}} = \mathcal{C}_{\text{SCM}}^{\text{ONLINE}}$. Na parte *offline* está relacionada à fase de treinamento e é calculada como [Flops]

$$\begin{aligned} \mathcal{C}_{\text{SCM}}^{\text{OFFLINE}} &= MN^2KN_{\text{EPOCH}} + NKN_{\text{EPOCH}}(M - N/2) - \\ &\quad - \frac{NKN_{\text{EPOCH}}}{2} \quad [\text{Flops}], \end{aligned} \quad (4.33)$$

onde K é o número de matrizes SCMs treinadas e N_{EPOCH} é o número total de épocas de treinamento para garantir uma convergência apropriada da NN.

Tabela 11 – Complexidade Computacional por amostra \mathcal{C}_{PS} [Flops] dos detectores utilizados para SS.

Det. SS	Adições	Produtos	Total
CAV	$M^2 + M$	–	$M^2 + M$
HD	$M^3 - M/6$	$M^3/6 + M^2 - 7M/6$	$M^3/3 + M^2 - 4M/3$
VD	$5M^3/3 - 3M^2/2 + 5M/6$	$5M^3/3 + 5M^2/2 - 13M/6 + 1$	$10M^3/3 + M^2 + 4M/3 + 1$
MME	$M^3/6 - M/6$	$M^3 + M^2 - 13M/6 + 1$	$M^3/3 + M^2 - 7M/3 + 1$
LMPIT	$9M^3/7 - 4M^2/3 + 6M/5$	$M^3 + 4M^2/3 - 11M/5 + 1$	$16M^3/7 + M + 1$
GLRT	$M^3 - 2M/7$	$M^3/5 + 2M^2 - 2M/3$	$6M^3/5 + 2M^2 - 20M/21$
AGM	$M^3/6 - 5M/6$	$M^3/6 + M^2 - 13M/6 + 1$	$M^3/3 + M^2 - M/3 + 1$
JD	$M^3 - M^2 + 2M$	M^3	$2M^3 - M^2 + 2M$
SD	$M^3/6 - 5M/6$	$M^3/6 + M^2 - 13M/6 + 1$	$M^3/3 + M^2 - M/3 + 1$
Etapa de cálculo da matriz de covariância: $\mathcal{C}_{\text{SCM}} = MN^2 + N(M - N/2) - N/2$			
Det.SS	Total Online	Total Offline	Total
CNN	$\mathcal{C}_{\text{ONLINE}} = \mathcal{C}_{\text{CONV.}} + \mathcal{C}_{\text{POOL.}}$	$\mathcal{C}_{\text{OFFLINE}} = \mathcal{C}_{\text{CONV.}} + \mathcal{C}_{\text{POOL.}} + \mathcal{C}_{\text{MLP.}}$	$\mathcal{C}_{\text{PS}} = 2\mathcal{C}_{\text{CONV.}} + 2\mathcal{C}_{\text{POOL.}} + \mathcal{C}_{\text{MLP.}}$
Covariance matrix: $\mathcal{C}_{\text{SCM}} = MN^2 + N(M - \frac{N}{2}) - \frac{N}{2} + MN^2KN_{\text{EPOCH}} + NK N_{\text{EPOCH}}(M - \frac{N}{2}) - \frac{NK N_{\text{EPOCH}}}{2}$			

Além disso, a complexidade computacional operacional \mathcal{C}_{OP} é comum a todos os detectores para SS; o \mathcal{C}_{OP} está descrito na Tabela 11; assim, a complexidade [computacional](#) por amostra é definida como

$$\mathcal{C}_{\text{PS}} = \mathcal{C}_{\text{OP}} + \mathcal{C}_{\text{SCM}} \quad [\text{Flops}].$$

No caso do detector baseado na CNN, a complexidade computacional operacional resulta em

$$\mathcal{C}_{\text{OP}}^{\text{CNN}} = \mathcal{C}_{\text{ONLINE}} + \underbrace{\mathcal{C}_{\text{CONV.}} + \mathcal{C}_{\text{POOL.}} + \mathcal{C}_{\text{MLP.}}}_{= \mathcal{C}_{\text{OFFLINE}}}.$$

Os cálculos mais custosos são devidos à parte *offline* $\mathcal{C}_{\text{OFFLINE}}$, onde o primeiro termo $\mathcal{C}_{\text{CONV.}}$ está relacionado a camada convolucional, o segundo à camada de *pooling* e o último associado à MLP. A complexidade *offline* pode ser calculada como

$$\begin{aligned} \mathcal{C}_{\text{OFFLINE}} = & \sum_{h \in H_{\text{CONV.}}} 2C_{h-1}C_h N_h^{\text{KER.}} N_h + \sum_{h \in H_{\text{POOL.}}} C_h N_h (N_h^{\text{POOL.}} - 1) \\ & + \sum_{h \in H_{\text{MLP}}} 2C_h N_h + 2C_h N_h N_{\text{DENS.}} + 2N_{\text{DENS.}} N_{\text{OUT.}}, \end{aligned} \quad (4.34)$$

onde h é o número de camadas ocultas (*hidden*), N_h é o comprimento do vetor de *feature* da h -th camada oculta, $N_{\text{OUT.}}$ é o tamanho de saída, $N_{\text{DENS.}}$ é o tamanho da camada densa (MLP), $N_h^{\text{KER.}}$ é o tamanho do *kernel* (filtro convolucional) da h -th camada oculta, $N_h^{\text{POOL.}}$ é o fator de agrupamento na h -th camada oculta, C_h é o número de filtros na h -th camada, $H_{\text{CONV.}}$ é o conjunto de camadas convolucionais, $H_{\text{POOL.}}$ é o conjunto de camadas de *pooling* e H_{MLP} é o conjunto de camadas densas na NN MLP.

A parte *online* é semelhante à *offline*, ou seja, dependente da complexidade computacional da camada convolucional e da camada de *pooling*. No entanto, nenhum treinamento

é necessário e a complexidade da camada densa é irrelevante na análise. Por esta razão consideramos que $\mathcal{C}_{\text{ONLINE}} \approx \mathcal{C}_{\text{CONV.}} + \mathcal{C}_{\text{POOL.}}$.

A Figura 31 mostra a complexidade computacional em [Flops] \times número de antenas \times número de amostras. Como esperado, a complexidade computacional é alta para o detector para SS baseado na CNN em comparação com os detectores LMPIT e CAV. Selecionamos tais detectores uma vez que o CNN, LMPIT e CAV obtiveram desempenho superior em comparação com os outros detectores para SS aqui avaliados. No entanto, o desempenho do detector baseado na CNN, medido usando diferentes figuras de mérito, mostrou-se indubitavelmente superior, considerando uma estrutura de processamento viável na BS secundária; portanto, o detector para SS baseado na CNN provou ser o melhor detector entre os nove detectores SS convencionais de última geração.

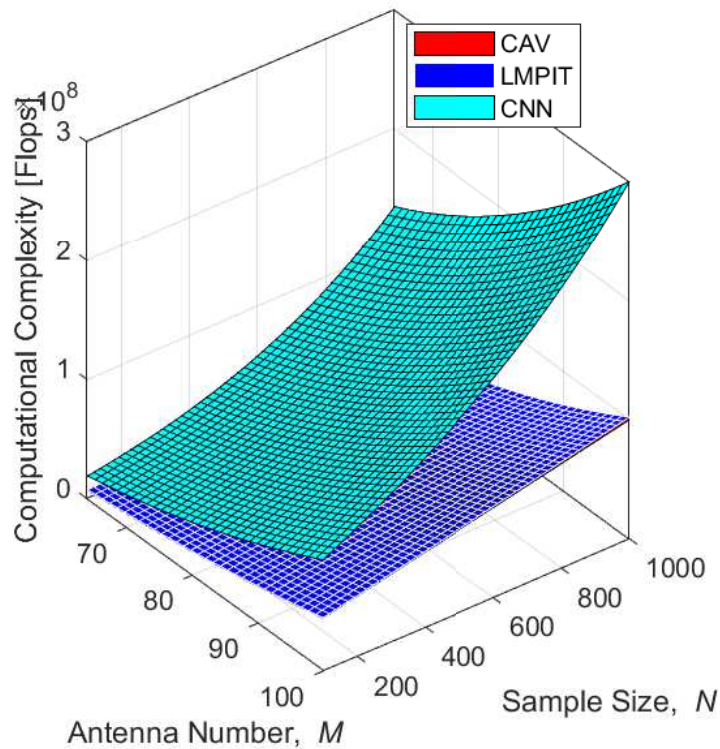


Figura 31 – Complexidade Computacional [Flops] \times Número de Antenas \times Número de Amostras.

Fonte: Autoria própria.

Por fim, para uma análise simplificada de complexidade porém ainda efetiva, pode-se ignorar a parte *offline*, permitindo uma comparação mais específica das características intrínsecas de cada método. Neste sentido, ao ignorarmos a parte *offline*, a comparação pode se tornar mais justa, uma vez que o treinamento da rede raramente é feito devido a robustez do treinamento para redes com diferentes SNRs. Assim, pode ser mais adequado calcular apenas a complexidade *online*, dado que somente uma vez, ou poucas vezes é feito o treinamento da rede neural completamente.

4.6 Conclusões

Estudos recentes em sistemas sem fio B5G/6G propõem a utilização de técnicas de aprendizagem de máquinas e AI para auxiliarem na melhoria em termos de desempenho dos futuros sistemas de comunicação. Para o SS diversas técnicas baseadas em ML e DL estão sendo utilizadas. Dentre elas, o uso de CNNs têm oferecido grandes vantagens em termos de desempenho nas etapas de SS.

Propomos uma CNN capaz de proporcionar o cálculo de um teste estatístico aplicando o critério MAP (teste Bayesiano) para estimação de sinais corrompidos por ruídos. Entretanto a capacidade de aprendizado da NN possibilita trabalhar também com os efeitos degradantes do desvanecimento sem fio que comumente é capaz de reduzir a performance do SS. Além disso, o emprego deste teste estatístico em sistemas secundários munidos de múltiplas antenas massivas descalibradas em ambientes com múltiplas fontes primárias demonstrou-se ser de grande utilidade dado o desempenho superior obtido pelo detector comparado com detectores clássicos aplicados em SS-MIMO e desempenho comparável aos métodos estado-da-arte que empregam CNNs.

Entretanto, o desempenho obtido pelo detector proposto implica em um custo em termos de complexidade computacional, levando a concluir que o procedimento de SS aplicando a metodologia proposta neste capítulo deva ser feito por sistemas com bom grau de processamento computacional, portanto, a aplicação na rede sem fio onde o sistema secundário é uma BS munida de um grande número de antenas tratada neste capítulo de tese se faz necessário e ainda aproveita as estruturas físicas atuais utilizadas nos sistemas 5G.

5 CONCLUSÕES FINAIS E TRABALHOS FUTUROS

Neste trabalho de tese, analisamos e otimizamos o desempenho do esquema de SS baseado em DAC para redes *ad hoc* representadas por matrizes de adjacência de grafos. Para tanto, foram desenvolvidas expressões analíticas para caracterizar o desempenho do SS; mais especificamente, probabilidades de detecção, probabilidade de falso alarme e erros. Além disso, determinamos uma expressão para o número mínimo de amostras para atingir uma probabilidade de detecção e falso alarme detecção específicas, bem como uma abordagem analítica para determinar o valor do limiar de decisão ótimo visando otimizar o procedimento CSS sob o critério NP, minimizando a probabilidade de erro total.

O problema estatístico original leva a expressões complicadas, uma vez que o processo aleatório é caracterizado por distribuições qui-quadrado e exponenciais. Para facilitar o desenvolvimento das expressões analíticas, o CLT foi amplamente evocado. Assim, com base no CLT, todas as expressões derivadas podem ser escritas como funções Q. Por fim, os resultados numéricos demonstram a validade das expressões analíticas *aproximadas* propostas, validando nossas suposições apoiadas em extensas MCS.

Além disso, um método robusto para SS em sistemas MIMO massivos descalibrados e operando a partir dos modo SE ou EE é proposto. O primeiro modo SE garante alta eficiência espectral, proporcionando redução no tempo de detecção. Neste modo selecionamos um grande número de antenas para realizar o SS com um pequeno número de amostras. Por outro lado, no modo EE, um pequeno número de antenas combinadas com um tamanho de amostras suficiente é selecionado. Neste caso, o EE aumenta desligando um número substancial de antenas. O desempenho numérico demonstra ganhos em termos de SE e EE, quando considerados os dois modos. Encontramos três detectores SS robustos para operar em cenários realistas descalibrados (CAV, VD e HD) e propusemos uma forma empírica de descrever e ajustar equações para avaliar o desempenho do detector.

Em conclusão, os três detectores SS robustos operando nos modos SE e EE são semelhantes em desempenho e complexidade quando os limites são ajustados; porém, com parâmetros semelhantes, o HD é o melhor detector entre os analisados, seguido pelo CAV e VD. Finalmente, a complexidade computacional de segunda ordem deve ser levada em consideração, o CAV resulta um pouco menos complexo em comparação com HD e VD.

Finalmente, um esquema SS baseado em CNN é proposto operando sob cenário de interesse prático realista com múltiplos PUs e com antenas SU massivas descalibradas revelou características promissoras e métrica de desempenho superior em comparação com detectores SS de última geração. Sob tal cenário, os detectores baseados em CNN alcançaram a notável probabilidade de detecção para SNR operacionais baixas sob probabilidade

de alarme falso muito tolerável. Isso representa um ganho operacional médio de SNR de 6 a 9 dB sobre os detectores SS de última geração.

Além disso, as análises de desempenho sob diferentes números de amostras, número de antenas SU, número de PUs e SNR média também revelam um desempenho claramente superior para todas as faixas de parâmetros do sistema selecionadas. No entanto, o detector SS baseado em CNN proposto sofre de uma desvantagem relativa à complexidade computacional. Portanto, esse desempenho superior requer uma estrutura de processamento muito eficiente na estação rádio-base SU.

5.1 Perspectivas e Continuidade da Pesquisa

Como Pesquisas Futuras, sugere-se a continuidade do estudo que foram feitos neste trabalho de tese, estendendo a análise para outros métodos de SS baseados em DL, tais como, autoencoders e LSTM, por exemplo. Além disso, um dos temas mais estudados atualmente são sistemas eficientes para futuras redes sem fio de sexta-geração (6G). Uma das mais promissoras técnicas é o uso de superfícies inteligentes reflexivas (*Reflexive Intelligence Surfaces*, RIS). O RIS consiste em um grande número de elementos eletromagnéticos passivos reflexivos (que são propriedades dos materiais utilizados) que podem ser reconfigurados por um controlador e ajustar suas amplitudes de reflexão e/ou deslocamentos de fase, assim aumentando ou suprimindo cooperativamente a potência de sinal refletida em direções designadas. Assim, o RIS fornece soluções mais eficazes para compensar o desvanecimento do canal sem fio e perda de percurso e torná-los programáveis. Pode-se estender o modelo de sistema utilizando o RIS em conjunto com a rede proposta no capítulo 4 e utilizar as técnicas baseadas em DL, mais especificadamente, a CNN para realizar o SS. Além disso, pode-se também otimizar os parâmetros relacionados ao SS (probabilidades de detecção, falso alarme, falta, erro, SE, EE, limiar de decisão e número de amostras) aplicados a redes cognitivas auxiliadas pelo RIS utilizando os métodos utilizados nesta tese.

REFERÊNCIAS BIBLIOGRÁFICAS

- AINOMÄE, A.; BENGTSSON, M.; TRUMP, T. Distributed largest eigenvalue-based spectrum sensing using diffusion lms. **IEEE Transactions on Signal and Information Processing over Networks**, v. 4, n. 2, p. 362–377, 2018.
- AKYILDIZ, I. F.; LO, B. F.; BALAKRISHNAN, R. Cooperative spectrum sensing in cognitive radio networks: A survey. **Physical Communication**, v. 4, n. 1, p. 40–62, 2011. ISSN 1874-4907. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S187449071000039X>>.
- ALI, A.; HAMOUDA, W. Advances on spectrum sensing for cognitive radio networks: Theory and applications. **IEEE Communications Surveys Tutorials**, v. 19, n. 2, p. 1277–1304, 2017.
- ASHRAFI, S.; MALMIRCHEGINI, M.; MOSTOFI, Y. Binary consensus for cooperative spectrum sensing in cognitive radio networks. In: **2011 IEEE Global Telecommunications Conference - GLOBECOM 2011**. [S.l.: s.n.], 2011. p. 1–6.
- ASLAM, M. M. et al. Sixth generation (6g) cognitive radio network (crn) application, requirements, security issues, and key challenges. **Wireless Communications and Mobile Computing**, id.1331428-2021, n. 1, p. 1–18, 2021.
- BOUALLEGUE, K. et al. Blind spectrum sensing using extreme eigenvalues for cognitive radio networks. **IEEE Communications Letters**, v. 22, n. 7, p. 1386–1389, 2018.
- BOYD, S.; VANDENBERGHE, L. **Convex Optimization**. [S.l.]: Cambridge University Press, 2004. ISBN 0521833787.
- CHATZIANTONIOU, E.; ALLEN, B.; VELISAVLJEVIC, V. Threshold optimization for energy detection-based spectrum sensing over hyper-rayleigh fading channels. **IEEE Communications Letters**, v. 19, n. 6, p. 1077–1080, 2015.
- CHAUDHARI, S. et al. Cooperative sensing with imperfect reporting channels: Hard decisions or soft decisions? **IEEE Transactions on Signal Processing**, v. 60, n. 1, p. 18–28, 2012.
- CHEN, A.-Z.; SHI, Z.-P. A real-valued weighted covariance-based detection method for cognitive radio networks with correlated multiple antennas. **IEEE Communications Letters**, v. 22, n. 11, p. 2290–2293, 2018.
- _____. Covariance-based spectrum sensing for noncircular signal in cognitive radio networks with uncalibrated multiple antennas. **IEEE Wireless Communications Letters**, v. 9, n. 5, p. 662–665, 2020.
- CHEN, A.-Z.; SHI, Z.-P.; HE, Z.-Q. A robust blind detection algorithm for cognitive radio networks with correlated multiple antennas. **IEEE Communications Letters**, v. 22, n. 3, p. 570–573, 2018.

CHEN, A.-Z. et al. Robust spectrum sensing based on correlation for cognitive radio networks with uncalibrated multiple antennas. **IEEE Communications Letters**, v. 25, n. 5, p. 1665–1668, 2021.

_____. A low-complexity spectrum sensing method for noncircular signal in cognitive radio networks with multiple receive antennas. **IEEE Communications Letters**, v. 23, n. 7, p. 1190–1193, 2019.

CHENG, Q. et al. Sensing ofdm signal: A deep learning approach. **IEEE Transactions on Communications**, v. 67, n. 11, p. 7785–7798, 2019.

DEY, I.; CIUONZO, D.; ROSSI, P. S. Wideband collaborative spectrum sensing using massive mimo decision fusion. **IEEE Transactions on Wireless Communications**, v. 19, n. 8, p. 5246–5260, 2020.

DEY, I. et al. Experimental analysis of wideband spectrum sensing networks using massive mimo testbed. **IEEE Transactions on Communications**, v. 68, n. 9, p. 5390–5405, 2020.

DIGHAM, F. F.; ALOUINI, M.-S.; SIMON, M. K. On the energy detection of unknown signals over fading channels. **IEEE Transactions on Communications**, v. 55, n. 1, p. 21–24, 2007.

GANESAN, G.; LI, Y. Cooperative spectrum sensing in cognitive radio, part i: Two user networks. **IEEE Transactions on Wireless Communications**, v. 6, n. 6, p. 2204–2213, 2007.

_____. Cooperative spectrum sensing in cognitive radio, part ii: Multiuser networks. **IEEE Transactions on Wireless Communications**, v. 6, n. 6, p. 2214–2222, 2007.

GAO, J. et al. Deep learning for spectrum sensing. **IEEE Wireless Communications Letters**, v. 8, n. 6, p. 1727–1730, 2019.

GAZESTANI, A. H.; GHORASHI, S. A. Distributed diffusion-based spectrum sensing for cognitive radio sensor networks considering link failure. **IEEE Sensors Journal**, v. 18, n. 20, p. 8617–8625, 2018.

GETU, T. M.; AJIB, W.; LANDRY, R. Simple f -test-based spectrum sensing techniques for multi-antenna cognitive radios. **IEEE Transactions on Communications**, v. 66, n. 11, p. 5081–5096, 2018.

GOLUB, G.; LOAN, C. V. **Matrix Computations**. Johns Hopkins University Press, 2013. (Johns Hopkins Studies in the Mathematical Sciences). ISBN 9781421407944. Disponível em: <https://books.google.com.br/books?id=X5YfsuCWpxMC>.

GOODFELLOW, I. J.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge, MA, USA: MIT Press, 2016. <http://www.deeplearningbook.org>.

HAJIHOSEINI, A.; GHORASHI, S. A. Distributed spectrum sensing for cognitive radio sensor networks using diffusion adaptation. **IEEE Sensors Letters**, v. 1, n. 5, p. 1–4, 2017.

-
- HAYKIN, S. Cognitive radio: brain-empowered wireless communications. **IEEE Journal on Selected Areas in Communications**, v. 23, n. 2, p. 201–220, 2005.
- HERNANDES, A. G.; JR, M. L. P.; ABRAO, T. Improved weighted average consensus in distributed cooperative spectrum sensing networks. **Transactions on Emerging Telecommunications Technologies**, Wiley Online Library, v. 29, n. 3, p. e3259, 2018.
- HU, H.; ZHANG, H.; LIANG, Y.-C. On the spectrum- and energy-efficiency tradeoff in cognitive radio networks. **IEEE Transactions on Communications**, v. 64, n. 2, p. 490–501, 2016.
- HUANG, L. et al. Performance analysis of volume-based spectrum sensing for cognitive radio. **IEEE Transactions on Wireless Communications**, v. 14, n. 1, p. 317–330, 2015.
- HUANG, L.; XIAO, Y.-H.; ZHANG, Q. T. Robust spectrum sensing for noncircular signal in multiantenna cognitive receivers. **IEEE Transactions on Signal Processing**, v. 63, n. 2, p. 498–511, 2015.
- JALALI, F.; ZAIMBASHI, A. Cognitive radio spectrum sensing under joint tx/rx i/q imbalance and uncalibrated receiver. **IEEE Systems Journal**, v. 14, n. 1, p. 105–112, 2020.
- KAILKHURA, B.; BRAHMA, S.; VARSHNEY, P. K. Data falsification attacks on consensus-based detection systems. **IEEE Transactions on Signal and Information Processing over Networks**, v. 3, n. 1, p. 145–158, 2017.
- KAY, S. **Fundamentals of Statistical Signal Processing: Detection theory**. Prentice-Hall PTR, 1998. (Fundamentals of Statistical Si). ISBN 9780133457117. Disponível em: <<https://books.google.com.br/books?id=vA9LAQAIAAJ>>.
- KOBEISSI, H. et al. Elastic- enabling massive-antenna for joint spectrum sensing and sharing: How many antennas do we need? **IEEE Transactions on Cognitive Communications and Networking**, v. 5, n. 2, p. 267–280, 2019.
- LEE, W.; KIM, M.; CHO, D.-H. Deep cooperative sensing: Cooperative spectrum sensing based on convolutional neural networks. **IEEE Transactions on Vehicular Technology**, v. 68, n. 3, p. 3005–3009, 2019.
- LI, Z.; YU, F. R.; HUANG, M. A distributed consensus-based cooperative spectrum-sensing scheme in cognitive radios. **IEEE Transactions on Vehicular Technology**, v. 59, n. 1, p. 383–393, 2010.
- LIANG, Y.-C. et al. Symbiotic communications: Where marconi meets darwin. **IEEE Wireless Communications**, v. 29, n. 1, p. 144–150, 2022.
- _____. Sensing-throughput tradeoff for cognitive radio networks. **IEEE Transactions on Wireless Communications**, v. 7, n. 4, p. 1326–1337, 2008.
- LIU, C. et al. Optimal eigenvalue weighting detection for multi-antenna cognitive radio networks. **IEEE Transactions on Wireless Communications**, v. 16, n. 4, p. 2083–2096, 2017.

_____. Deep cm-cnn for spectrum sensing in cognitive radio. **IEEE Journal on Selected Areas in Communications**, v. 37, n. 10, p. 2306–2321, 2019.

_____. Deep transfer learning for signal detection in ambient backscatter communications. **IEEE Transactions on Wireless Communications**, v. 20, n. 3, p. 1624–1638, 2021.

LONG, R. et al. Symbiotic radio: A new communication paradigm for passive internet of things. **IEEE Internet of Things Journal**, v. 7, n. 2, p. 1350–1363, 2020.

MAJUMDER, S. A gaussian mixture model method for eigenvalue-based spectrum sensing with uncalibrated multiple antennas. **Signal Processing**, v. 192, p. 108404, 2022. ISSN 0165-1684. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165168421004412>>.

MAPLESOFT. Factorization and solving equations. online help: MAPLE. In: **Maple Help Online**. [s.n.], 2022. Disponível em: <<https://www.maplesoft.com/support/help/maple/view.aspx?path=solve>>.

MARINELLO, J. C. et al. Antenna selection for improving energy efficiency in xl-mimo systems. **IEEE Transactions on Vehicular Technology**, v. 69, n. 11, p. 13305–13318, 2020.

MARZETTA, T. L. Noncooperative cellular wireless with unlimited numbers of base station antennas. **IEEE Transactions on Wireless Communications**, v. 9, n. 11, p. 3590–3600, 2010.

MEHRABIAN, A.; ZAIMBASHI, A. Robust and blind eigenvalue-based multiantenna spectrum sensing under iq imbalance. **IEEE Transactions on Wireless Communications**, v. 17, n. 8, p. 5581–5591, 2018.

MITOLA, J.; MAGUIRE, G. Cognitive radio: making software radios more personal. **IEEE Personal Communications**, v. 6, n. 4, p. 13–18, 1999.

MOGHIMI, F.; MALLIK, R. K.; SCHOBER, R. Sensing time and power optimization in mimo cognitive radio networks. In: **2012 IEEE Global Communications Conference (GLOBECOM)**. [S.l.: s.n.], 2012. p. 1138–1143.

MONAGAN, M. B. et al. **Maple 10 Programming Guide**. Waterloo ON, Canada: Maplesoft, 2005.

NAWAZ, S. J. et al. Quantum machine learning for 6g communication networks: State-of-the-art and vision for the future. **IEEE Access**, v. 7, p. 46317–46350, 2019.

PENG, Q. et al. Robust deep sensing through transfer learning in cognitive radio. **IEEE Wireless Communications Letters**, v. 9, n. 1, p. 38–41, 2020.

POURGHAREHKHAN, Z.; TAHERPOUR, A.; GAZOR, S. Spectrum sensing using a uniform uncalibrated linear antenna array for cognitive radios. **IEEE Transactions on Wireless Communications**, v. 18, n. 2, p. 741–752, 2019.

PRIES, A.; RAMÍREZ, D.; SCHREIER, P. J. Lmpit-inspired tests for detecting a cyclostationary signal in noise with spatio-temporal structure. **IEEE Transactions on Wireless Communications**, v. 17, n. 9, p. 6321–6334, 2018.

-
- QUAN, Z.; CUI, S.; SAYED, A. H. Optimal linear cooperation for spectrum sensing in cognitive radio networks. **IEEE Journal of Selected Topics in Signal Processing**, v. 2, n. 1, p. 28–40, 2008.
- QUAN, Z. et al. Optimal multiband joint detection for spectrum sensing in cognitive radio networks. **IEEE Transactions on Signal Processing**, v. 57, n. 3, p. 1128–1140, 2009.
- QUAN, Z.; KAISER, W. J.; SAYED, A. H. Innovations diffusion: A spatial sampling scheme for distributed estimation and detection. **IEEE Transactions on Signal Processing**, v. 57, n. 2, p. 738–751, 2009.
- QUAN, Z. et al. Optimal linear fusion for distributed detection via semidefinite programming. **IEEE Transactions on Signal Processing**, v. 58, n. 4, p. 2431–2436, 2010.
- SEDIGHI, S. et al. On the performance of hadamard ratio detector-based spectrum sensing for cognitive radios. **IEEE Transactions on Signal Processing**, v. 63, n. 14, p. 3809–3824, 2015.
- SENANAYAKE, R. et al. Mixture detectors for improved spectrum sensing. **IEEE Transactions on Wireless Communications**, v. 19, n. 6, p. 4335–4348, 2020.
- SMITH, P. J. et al. Distributed spectrum sensing for cognitive radio networks based on the sphericity test. **IEEE Transactions on Communications**, v. 67, n. 3, p. 1831–1844, 2019.
- TAHERPOUR, A.; TOGHRAEI, M. A universal multiple antenna test for spectrum sensing. **IEEE Communications Letters**, v. 23, n. 2, p. 326–329, 2019.
- TANG, H. et al. Distributed consensus-based security mechanisms in cognitive radio mobile ad hoc networks. **IET Commun.**, v. 6, p. 974–983, 2012.
- TARICCO, G. Optimization of linear cooperative spectrum sensing for cognitive radio networks. **IEEE Journal of Selected Topics in Signal Processing**, v. 5, n. 1, p. 77–86, 2011.
- TEGUIG, D. et al. Consensus algorithms for distributed spectrum sensing based on goodness of fit test in cognitive radio networks. In: **2015 International Conference on Military Communications and Information Systems (ICMCIS)**. [S.l.: s.n.], 2015. p. 1–5.
- TEKBİYİK, K. et al. Spectrum sensing and signal identification with deep learning based on spectral correlation function. **IEEE Transactions on Vehicular Technology**, v. 70, n. 10, p. 10514–10527, 2021.
- TIAN, J. et al. A machine learning-enabled spectrum sensing method for ofdm systems. **IEEE Transactions on Vehicular Technology**, v. 68, n. 11, p. 11374–11378, 2019.
- URKOWITZ, H. Energy detection of unknown deterministic signals. **Proceedings of the IEEE**, v. 55, n. 4, p. 523–531, 1967.
- VOSOUGHI, A.; CAVALLARO, J. R.; MARSHALL, A. Trust-aware consensus-inspired distributed cooperative spectrum sensing for cognitive radio ad hoc networks. **IEEE Transactions on Cognitive Communications and Networking**, v. 2, n. 1, p. 24–37, 2016.

- WANG, P. et al. Multiantenna-assisted spectrum sensing for cognitive radio. **IEEE Transactions on Vehicular Technology**, v. 59, n. 4, p. 1791–1800, 2010.
- WEI, G. et al. Massive mimo-based distributed signal detection in multi-antenna wireless sensor networks. **Sensors**, v. 20, n. 7, 2020. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/20/7/2005>>.
- WEI, Z.; ZHAO, B.; SU, J. Cooperative sensing in cognitive radio ad hoc networks. In: **ICC 2019 - 2019 IEEE International Conference on Communications (ICC)**. [S.l.: s.n.], 2019. p. 1–6.
- XIAO, L.; BOYD, S. Fast linear iterations for distributed averaging. **Systems and Control Letters**, v. 53, n. 1, p. 65–78, 2004. ISSN 0167-6911. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167691104000398>>.
- XIAO, L.; BOYD, S.; KIM, S.-J. Distributed average consensus with least-mean-square deviation. **Journal of Parallel and Distributed Computing**, v. 67, n. 1, p. 33–46, 2007. ISSN 0743-7315. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0743731506001808>>.
- XIE, J. et al. Deep learning-based spectrum sensing in cognitive radio: A cnn-lstm approach. **IEEE Communications Letters**, v. 24, n. 10, p. 2196–2200, 2020.
- _____. Activity pattern aware spectrum sensing: A cnn-based deep learning approach. **IEEE Communications Letters**, v. 23, n. 6, p. 1025–1028, 2019.
- YANG, X. et al. Analytical expressions for the probability of false-alarm and decision threshold of hadamard ratio detector in non-asymptotic scenarios. **IEEE Communications Letters**, v. 22, n. 5, p. 1018–1021, 2018.
- _____. Threshold setting for multiple primary user spectrum sensing via spherical detector. **IEEE Wireless Communications Letters**, v. 8, n. 2, p. 488–491, 2019.
- YU, F. R.; HUANG, M.; TANG, H. Biologically inspired consensus-based spectrum sensing in mobile ad hoc networks with cognitive radios. **IEEE Network**, v. 24, n. 3, p. 26–30, 2010.
- YUCEK, T.; ARSLAN, H. A survey of spectrum sensing algorithms for cognitive radio applications. **IEEE Communications Surveys Tutorials**, v. 11, n. 1, p. 116–130, 2009.
- ZENG, Y.; LIANG, Y.-C. Eigenvalue-based spectrum sensing algorithms for cognitive radio. **IEEE Transactions on Communications**, v. 57, n. 6, p. 1784–1793, 2009.
- _____. Spectrum-sensing algorithms for cognitive radio based on statistical covariances. **IEEE Transactions on Vehicular Technology**, v. 58, n. 4, p. 1804–1815, 2009.
- ZHANG, Q.; LIANG, Y.-C.; POOR, H. V. Intelligent user association for symbiotic radio networks using deep reinforcement learning. In: **2019 IEEE Global Communications Conference (GLOBECOM)**. [S.l.: s.n.], 2019. p. 1–6.
- ZHANG, W. et al. Distributed consensus-based weight design for cooperative spectrum sensing. **IEEE Transactions on Parallel and Distributed Systems**, IEEE Computer Society, Los Alamitos, CA, USA, v. 26, n. 01, p. 54–64, jan 2015. ISSN 1558-2183.