

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

Wesley Reis da Silva, André Antônio dos Anjos e Rausley Adriano Amaral de Souza

Resumo—Neste artigo será apresentada uma análise comparativa de desempenho de várias técnicas de sensoriamento espectral cooperativo e centralizado com fusão de dados, a saber: *Gini index detector (GID)*, *Pietra-Ricci index detector (PRIDe)*, *generalized likelihood ratio test (GLRT)*, *weighted circular folding cooperative power spectral density split cancellation (WFCPSC)* e uma rede neural artificial (RNA) DenseNet. A análise é conduzida em uma variedade de cenários, nos quais serão considerados canais seletivos em frequência, sombreamento espacialmente correlacionado, ruído uniforme e não uniforme e, também, ruído dinâmico. Por meio dessa análise, apresentam-se novas conclusões sobre as técnicas avaliadas, contribuindo para o avanço do conhecimento na área de sensoriamento espectral e fornecendo direcionamentos importantes para a escolha da técnica mais adequada em diferentes contextos.

Palavras-Chave—Sensoriamento espectral cooperativo, rádios cognitivos, RNA, TV White Spaces, ruído dinâmico.

Abstract—This article presents a comparative performance analysis of various cooperative and centralized spectral sensing techniques with data fusion, namely GID, PRIDe, GLRT, WFCPSC, and the DenseNet neural network. The analysis is conducted in a variety of scenarios, considering selective frequency channels, spatially correlated shadowing, uniform and non-uniform noise, and also dynamic noise. Through this analysis, new conclusions are presented about the evaluated techniques, contributing to the advancement of knowledge in the field of spectral sensing and providing important insights for choosing the most appropriate technique in different contexts.

Keywords—Cooperative spectrum sensing, cognitive radios, artificial neural networks, TV White Spaces, dynamical noise.

I. INTRODUÇÃO

O espectro de frequências é um recurso valioso na área de comunicação sem fio, porém, por limitações técnicas e políticas, apenas uma pequena porção pode ser utilizada, tornando-o escasso e caro. O crescimento no número de sistemas de comunicação e dispositivos transceptores agrava ainda mais essa situação [1]. Nesse contexto, uma solução

promissora é o conceito de rádio cognitivo (RC), que permite o acesso dinâmico e oportunista por um usuário secundário (US) a determinadas faixas de frequências não utilizadas pelos usuários primários (UPs), por meio do sensoriamento do espectro, melhorando a eficiência de uso desse recurso.

É inegável, então, a importância dos esforços de pesquisa direcionados às técnicas de sensoriamento espectral. Esses esforços são agora ainda mais importantes motivados pela aprovação, por parte da Agência Nacional de Telecomunicações (Anatel), de resolução [2] que atribui e destina faixas de radiofrequências de TV e aprova o Regulamento sobre Condições de Uso das Faixas de Radiofrequências de 54 MHz a 72 MHz, 174 MHz a 216 MHz, 470 MHz a 608 MHz e 614 a 698 MHz por Dispositivos de Espectro Ocioso, mais conhecido como Regulamento de TV White Spaces. “O normativo regulamenta a aplicação dessa tecnologia, que permite designar para os serviços de telecomunicações, de forma dinâmica, radiofrequências destinadas à radiodifusão que não estejam autorizadas. Com isso, aumenta-se a eficiência de uso do espectro, recurso limitado, com vantagens características das faixas de frequência de TV, como longo alcance e tolerância a obstáculos” [2].

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

Existem diversas técnicas utilizadas para o cálculo da estatística de teste. São exemplos bastante conhecidos as técnicas baseadas: i) no cálculo da energia do sinal recebido, o detector de energia; ii) nas propriedades da matriz de covariância amostral (*sample covariance matrix, SCM*), o *Gini index detector (GID)* [3], o *Pietra-Ricci index detector (PRIDe)* [3] e o teste de razão de máxima verossimilhança generalizado (*generalized likelihood ratio test, GLRT*) [4]; e iii) na estimativa da densidade espectral de potência (DEP), o cancelamento cooperativo por divisão da densidade espectral de potência ponderada e com dobramento circular (*weighted circular folding cooperative power spectral density split cancellation, WFCPSC*) [4].

Em [4], [5], o WFCPSC foi comparado com outras es-

Wesley R. da Silva e Rausley A. A. de Souza, Instituto Nacional de Telecomunicações (Inatel), Santa Rita do Sapucaí, MG, e-mail: wesley.reis@mtel.inatel.br, rausley@inatel.br. André A. dos Anjos, Universidade Federal de Uberlândia (UFU), Patos de Minas, e-mail: andre.anjos@ufu.br. Este trabalho foi parcialmente financiado pelo CNPq (Contratos No 311470/2021-1 e 403827/2021-3), pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) (2021/06946-0) e pela RNP, com recursos do MCTIC, processo No 01245.020548/2021-07, sob o projeto Brasil 6G do Centro de Referência em Radiocomunicações (CRR) do Instituto Nacional de Telecomunicações – Inatel, Brasil, e pela Huawei, sob o projeto Formação Avançada em Redes e Sistemas de Telecomunicações, contrato No PPA6001BRA23032110257684.

tatísticas de teste sobre diferentes cenários, cujos resultados evidenciaram a sua superioridade no poder de detecção e sua robustez à seletividade de canal, ao sombreamento, à presença de ruído não uniforme (quando cada RC opera sob uma potência média de ruído distinta) e ruído dinâmico (quando os RCs operam sob potência de ruído variante no tempo).

Além dos modelos estatísticos tradicionais anteriormente citados, outros modelos, ainda incipientes, são baseados em redes neurais artificiais (RNAs) [6], [7]. Com base nas amostras coletadas, esses modelos conseguem aprender a extrair características do sinal e utilizá-las para o processo de tomada de decisões, permitindo alcançar alta eficiência na detecção do UP. Em contrapartida, o desempenho desses modelos está atrelado a fatores não determinísticos, tais como arquitetura e configuração [8], além de requererem elevados recursos computacionais para execução e treinamento, de modo que a tarefa de encontrar RNAs que atinjam os melhores resultados para o objetivo proposto seja mais complexa.

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

II. SENSORIAMENTO ESPECTRAL E MODELO DO SISTEMA

Seja uma rede secundária constituída de U RCs, cada um possuindo uma única antena e coletando N amostras do sinal recebido a cada período de sensoriamento em um determinado canal do UP. Considera-se também uma rede primária contendo apenas um transmissor primário. O objetivo do sensoriamento é decidir se o canal do UP está livre ou ocupado com base nas amostras de sensoriamento de cada RC a fim de prover acesso oportunista ao espectro. Seja $y_u(n)$ a n -ésima amostra recebida no u -ésimo RC, com $u = 1, 2, \dots, U$ e $n = 1, 2, \dots, N$. Nas técnicas de sensoriamento espectral, a decisão sobre o estado de ocupação de um canal do UP geralmente é modelada como um teste binário de hipóteses, \mathcal{H}_0 e \mathcal{H}_1 , sendo \mathcal{H}_0 e \mathcal{H}_1 as hipóteses desse canal estar livre ou ocupado, respectivamente. Sob \mathcal{H}_0 ou \mathcal{H}_1 , tem-se

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

em que $\eta_u(n)$ e $s(n)$ representam, respectivamente, a n -ésima amostra complexa de ruído aditivo Gaussiano branco (*additive white Gaussian noise*, AWGN) no u -ésimo RC, com média zero e variância σ^2 , e a n -ésima amostra complexa do sinal emitido pelo transmissor primário, no qual se considera um sinal com modulação QPSK (*quadrature phase-shift keying*, QPSK). A parcela $\sum_{z=0}^{Z-1} h_u(z)s(n-z)$ corresponde ao resultado da operação de convolução entre a n -ésima amostra do sinal do UP e a resposta ao impulso do canal de sensoriamento entre o transmissor primário e o u -ésimo RC. A resposta ao

impulso é variante no tempo e possui linha de atraso com Z derivações. Quando $Z = 1$, $h_u(z)$ configura-se como um canal com sombreamento e desvanecimento plano e lento, e quando $Z > 1$, como um canal com sombreamento e desvanecimento lento e seletivo em frequência.

Para que se consiga realizar o processo de decisão sobre a ocupação espectral, é necessário a definição de um limiar de decisão, γ , e uma variável de decisão, T , gerada pelo processamento das amostras coletadas pelos RCs, o que irá depender da técnica selecionada para o sensoriamento. Assim, se $T > \gamma$, decide-se pela ocupação espectral, caso contrário o espectro é considerado livre. O desempenho em sistemas de sensoriamento espectral é frequentemente avaliado pela probabilidade de falso alarme, $P_{fa} = \Pr\{\text{decisão} = \mathcal{H}_1 | \mathcal{H}_0\} = \Pr\{T > \gamma | \mathcal{H}_0\}$, e pela probabilidade de detecção, $P_d = \Pr\{\text{decisão} = \mathcal{H}_1 | \mathcal{H}_1\} = \Pr\{T > \gamma | \mathcal{H}_1\}$.

As análises de desempenho apresentadas neste trabalho serão realizadas por meio da curva característica de operação do receptor (*receiver operating characteristic*, ROC), que mapeia P_{fa} e P_d com a variação do limiar de decisão γ , bem como por meio da área abaixo da curva ROC (*area under the ROC curve*, AUC). Vale ressaltar que o uso de AUCs como alternativa ao uso de ROCs nas análises de desempenho são especialmente úteis quando necessita-se analisar diversos desempenhos muito próximos entre si e/ou que se cruzam em algum ponto do gráfico.

A. Canal de Sensoriamento

Os canais de sensoriamento formados entre o UP e os RCs levam em conta o modelo de desvanecimento composto Rayleigh-lognormal proposto em [9]. Os ganhos dos percursos de propagação entre o transmissor primário e o u -ésimo RC em (1), $h_u(z)$, $z = 0, 1, \dots, Z - 1$, são equacionados por

$$h_u(z) = h_u^f(z) + h_u^s(z), \quad (2)$$

em que $h_u^f(z)$ e $h_u^s(z)$ representam os ganhos de canal referentes ao desvanecimento de curto-prazo (*multipath fading*) e desvanecimento de longo-prazo (*shadowing*), respectivamente. Os ganhos de percurso aqui são organizados em um vetor $(\mathbf{h}_u^f)^\dagger \in \mathbb{C}^{Z \times 1}$, em que \dagger representa a operação conjugado transposto. Os elementos deste vetor são variáveis aleatórias independentes e identicamente distribuídas com distribuição Gaussiana complexa de média zero e variância unitária, i.e., $\mathbb{E}[\mathbf{h}_u^f (\mathbf{h}_u^f)^\dagger] = 1$, em que $\mathbb{E}[\cdot]$ representa o operador esperança estatística. Os ganhos são mantidos constantes em um dado período de sensoriamento e variado entre um período e outro, simulando um canal com desvanecimento lento e seletivo em frequência. Já o vetor $(\mathbf{h}_u^s)^\top \in \mathbb{C}^{Z \times 1}$, em que \top indica operação de transposição, possui elementos idênticos, cujos módulos têm distribuição normal em escala logarítmica (*log-normal*) e fase com distribuição uniforme em $[0, 2\pi)$. Ressalta-se que estes elementos são idênticos porque representam o sombreamento sobre todos os ganhos de percurso do canal entre o transmissor primário e o u -ésimo RC. Os RCs operam sob canais com sombreamento espacialmente correlacionado segundo o modelo tridimensional (3D) proposto em [9].

B. Estatísticas de Teste Tradicionais

A técnica WCFCPSC utiliza a estimativa da DEP como base para o cálculo da estatística de teste e pondera a contribuição de cada sub-banda, conforme o algoritmo descrito em [4, Section III].

Já as técnicas GID e PRIDe utilizam como base a SCM [3]. Mais especificamente, essas técnicas aplicam nos elementos da SCM índices normalmente usados nos campos social e econômico como medida de desigualdades. Sob a hipótese \mathcal{H}_0 os elementos fora da diagonal principal tendem a 0 enquanto os elementos da diagonal principal tendem aos valores das potências dos ruídos, comportamento que não ocorre sob \mathcal{H}_1 . Dessa forma, é possível distinguir os cenários, dado que o valor da desigualdade de uma SCM sob \mathcal{H}_0 é maior que \mathcal{H}_1 . As estatísticas de teste dos detectores GID e PRIDe são calculadas como [3]

$$T_{\text{GID}} = \frac{\sum_{i=1}^{U^2} |r_i|}{\sum_{i=1}^{U^2} \sum_{j=1}^{U^2} |r_i - r_j|} \quad (3)$$

$$T_{\text{PRIDe}} = \frac{\sum_{i=1}^{U^2} |r_i|}{\sum_{i=1}^{U^2} |r_i - \bar{r}|} \quad (4)$$

em que U é o número de RCs cooperantes, r é o vetor formado pelo empilhamento (concatenação) das colunas da SCM, e \bar{r} é o valor médio de todos os elementos, calculado por $\bar{r} = (1/U^2) \sum_{i=1}^{U^2} r_i$.

A técnica GLRT se baseia no cálculo dos autovalores da SCM, valendo-se da relação que os autovalores possuem com a potência do sinal recebido [4]. A estatística de teste do GLRT é dada por

$$T_{\text{GLRT}} = \frac{\lambda_1}{\frac{1}{U} \sum_{i=1}^U \lambda_i}, \quad (5)$$

em que $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_U$ são os autovalores calculados a partir da SCM. Portanto, o GLRT é a relação do maior autovalor com a média de todos os autovalores.

C. Redes Neurais Artificiais

Existem inúmeros tipos de RNAs, cada uma possuindo seus atributos e aplicações específicas. As redes convolucionais ficaram bem conhecidas por seus desempenhos em tarefas de reconhecimento de imagem, mas estudos também mostraram que esses modelos apresentam uma boa atuação no processo de sensoriamento espectral [7]. Por isso, esse modelo foi escolhido para este trabalho. Diversos modelos de redes convolucionais foram avaliados a fim de escolher o que apresentasse melhor desempenho na tarefa do sensoriamento espectral. Entre os modelos testados, destacam-se as redes VGG16 [10], EfficientNet [11], InceptionV3 [12] e a DenseNet [13]. Todas as redes foram avaliadas com o mesmo dataset, utilizado durante as simulações. A DenseNet201 foi o modelo selecionado devido à sua superioridade na acurácia da detecção das oportunidades no espectro perante às demais. A principal característica do modelo DenseNet são suas conexões entre as camadas, de forma que todas as próximas camadas recebem como entrada as saídas das anteriores. Essa abordagem visa solucionar os problemas de dissipação de gradiente (*vanishing*)

que redes profundas possuem ao propagar as informações de entrada ou o gradiente pela rede. A Figura 1 apresenta a estrutura do modelo.

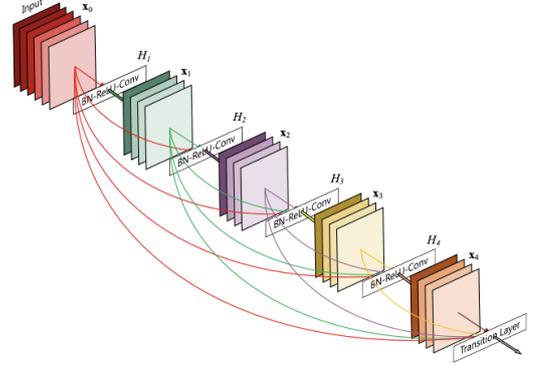


Fig. 1: Estrutura de uma RNA DenseNet [13].

D. Análise de Complexidade

A complexidade computacional tanto para o GID quanto para o PRIDe é dominada pela tarefa de se calcular a SCM, a qual é $\mathcal{O}(NU^2)$ [3], em que N é o número de amostras coletadas e U o número de RCs. Acrescido da necessidade de cômputo da SCM, o GLRT necessita realizar o cômputo dos autovalores da SCM, acrescentando uma complexidade de $\mathcal{O}(U^3)$ [3] à execução dessa técnica. Para o WCFCPSC, a operação mais custosa é a estimativa da DEP, que possui complexidade $\mathcal{O}(N \log M)$ [14], sendo M o tamanho da janela de sobreposição utilizada. Já na DenseNet, que é uma rede neural convolucional, a complexidade computacional para cálculo da estatística de teste de uma rodada de sensoriamento é dada por [15] $\mathcal{O}\left(\sum_{\ell=1}^d n_{\ell-1} s_{\ell}^2 n_{\ell} m_{\ell}^2\right)$, em que d o número de camadas convolucionais que existe na rede (profundidade da rede), n_{ℓ} o número de filtros na ℓ -ésima camada, $n_{\ell-1}$ o número de canais de entrada da camada ℓ -ésima, s_{ℓ} é o tamanho espacial do filtro e m_{ℓ} o tamanho espacial do mapa de recursos de saída. Desta maneira, pelas expressões apresentadas, é direto concluir que RNAs possuem uma maior complexidade computacional para a tomada de decisões.

III. RESULTADOS NUMÉRICOS

A. Datasets

Os *datasets* foram gerados utilizando a linguagem Python. Cada *dataset* contém 30000 atividades do transmissor do UP, 50% sob a hipótese \mathcal{H}_0 e 50% sob a hipótese \mathcal{H}_1 transmitindo um sinal QPSK com relação sinal-ruído de -10 dB. No sensoriamento, foram utilizados $U = 6$ RCs, cada um coletando $N = 160$ amostras a uma taxa de 4 amostras por símbolo. Sob ruído uniforme considerou-se $\sigma_u^2 = 1, u = 1, 2, \dots, U$, e sob ruído não uniforme $[\sigma_1^2; \sigma_2^2; \dots; \sigma_6^2] = [0.8; 0.9; 0.95; 1.1; 0.85; 1.15]$. Quando aplicado o ruído dinâmico, a potência do ruído é uma variável aleatória $\tilde{\sigma}_u^2$ uniformemente distribuída entre $\sigma_u^2(1 - \rho)$ e $\sigma_u^2(1 + \rho)$, sendo $\rho > 0$ o fator de variação da dinamicidade do ruído e σ_u^2

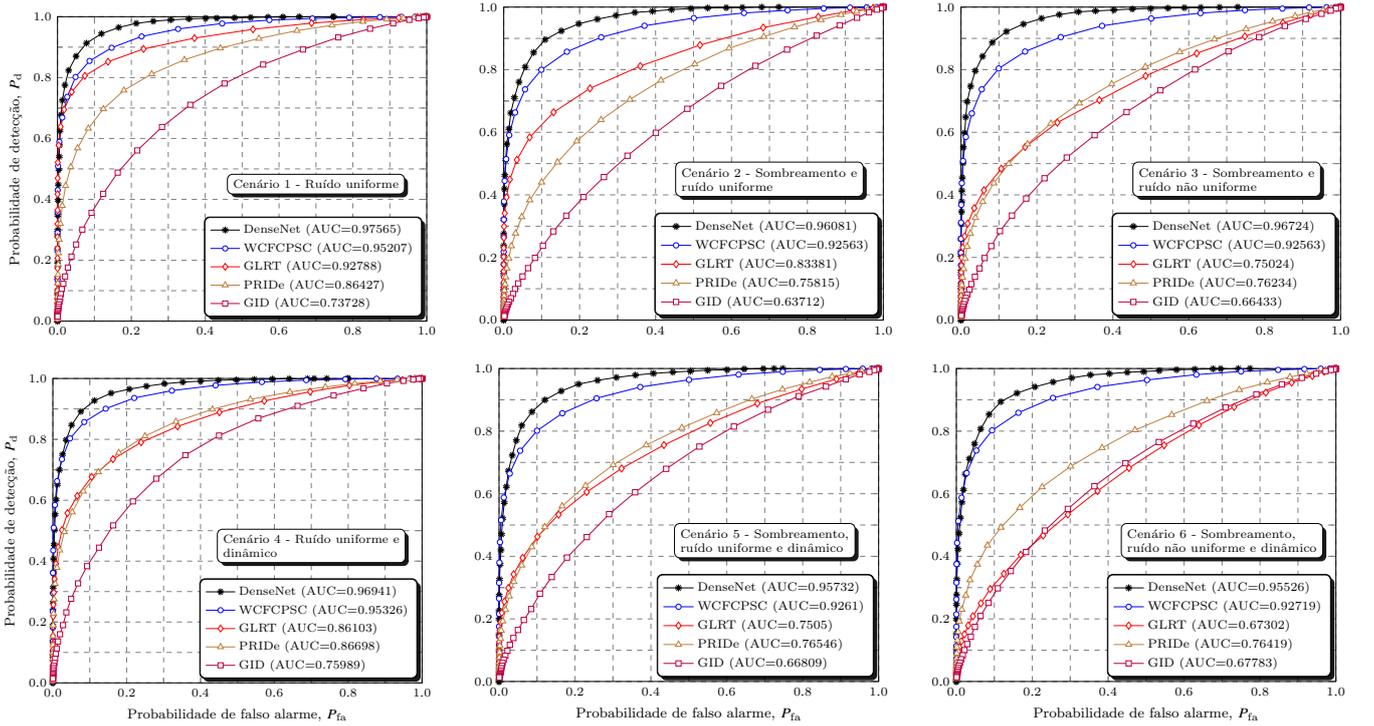


Fig. 2: ROCs sob diferente cenários conforme Tabela I.

as potências de ruído supracitadas para os cenários uniforme e não uniforme. Adotou-se o valor de $\rho = 0.25$ para os cenários que consideram variação na potência de ruído. Para o canal seletivo em frequência utilizou-se $Z = 4$ ganhos de percursos, com resposta ao impulso no formato exponencial com ganhos médios iguais a $[1; 0.464; 0.215; 0.1]$. Adotou-se para o sombreamento $\sigma_{dB} = 4$ dB, $D_{dec} = 30$ metros e $K = 60$ metros, em que σ_{dB} é desvio padrão da variável aleatória do sombreamento, D_{dec} é distância de decorrelação e K é a dimensão das laterais do espaço tridimensional no qual as coordenadas dos RCs se encontram, seguindo o modelo [9].

B. Treinamento

O *dataset* foi fracionado em três partes: treinamento, teste e validação, na porcentagem de 60%, 20% e 20%, respectivamente. O desempenho final do modelo está atrelado aos dados utilizados durante o treinamento, de forma que etapas de pré-processamento do *dataset* podem impactar significativamente. Diante disso, foi analisado o comportamento do modelo após o treinamento sob três entradas de dados diferentes: a primeira, sem pré-processamento; a segunda, calculando-se a SCM, mesma informação base utilizado pelo GID, PRiDe e GLRT, ou seja, as entradas da RNA são SCMs; e a terceira, calculando-se a transformada rápida de Fourier (*fast Fourier transform*, FFT) das amostras do *dataset*, assim as entradas da RNA são valores da densidade espectral de potência dos sinais coletados, semelhante ao realizado no primeiro passo do algoritmo do WCFCPSC. Ao final das análises, o pré-processamento usando FFT foi o escolhido perante sua melhor acurácia na detecção da presença do UP.

O treinamento e avaliação da RNA foi realizado em linguagem Python com a biblioteca Keras, utilizando uma GPU NVIDIA RTX A4000. O modelo foi treinado sob o cenário de canal seletivo, sombreamento, ruído não uniforme e dinâmico. A duração do treinamento foi configurada para 50 épocas, podendo este ser cessado antecipadamente caso ocorram 5 épocas sem evolução. Para as camadas decisórias, adicionadas à saída da DenseNet, foram usadas 2 camadas densas com 50 e 20 neurônios com função de ativação ReLu e uma última camada densa com 2 neurônios utilizando a função Softmax. Além disso, utilizou-se como métrica a acurácia, como função de perdas a entropia cruzada categórica, como otimizador o Adam e o tamanho de lote de 32 amostras.

C. Resultados Numéricos

Os gráficos da Figura 2 apresentam os desempenhos, na forma de curvas ROC e valores de AUCs, das técnicas DenseNet, WCFCPSC, PRiDe, GID e GLRT nos seis cenários descritos na Tabela I, sem a presença de ruído dinâmico, nos Cenários 1, 2 e 3, e com a presença de ruído dinâmico, nos Cenários 4, 5 e 6.

TABELA I: Cenários de Sensoriamento.

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

Primeiramente pode-se notar que a técnica GLRT é bastante sensível a canais com sombreamento, ruído não uniforme

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

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

O desempenho de todas as técnicas é impactado diretamente pelo número de amostras coletadas por símbolo. Esse comportamento é especialmente importante na análise de desempenho da técnica WCFCPSC, dado que essa técnica tem seu desempenho atrelado à concentração da DEP do sinal [4]. Esta concentração é controlada pelo número de amostras coletadas por símbolo. A Figura 3 apresenta o desempenho na forma de AUC das técnicas para diferentes valores do número de amostras coletadas por símbolo, análise realizada especificamente para o Cenário 3. Como era de se esperar, todas as técnicas apresentam um aumento de desempenho à medida que o número de amostras por símbolo aumenta. Entretanto, observa-se uma saturação no desempenho à medida que esse número amostras torna-se elevado. Notoriamente, a técnica WCFCPSC é a mais impactada. Ainda mais importante é verificar que o desempenho do WCFCPSC iguala-se ao desempenho de uma RNA DenseNet a partir de 7 amostras por símbolo e ultrapassa ligeiramente o desempenho da técnica concorrente quando se utilizam 10 amostras por símbolo.

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

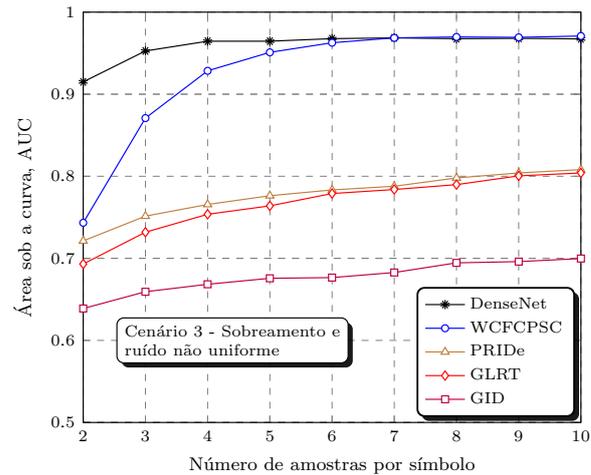


Fig. 3: AUCs versus o número de amostras coletadas por símbolo.

REFERÊNCIAS

- [1] L. Chettri and R. Bera, "A comprehensive survey on Internet of things (IoT) toward 5G wireless systems," *IEEE Internet Things J.*, vol. 7, no. 1, pp. 16–32, 2020.
- [2] "Resolução ANATEL N° 747," Conselho director Anatel, 10/2021, 2021, Access in April 2023. [Online]. Available: <https://www.gov.br/anatel/pt-br/assuntos/noticias/anatel-publica-resolucao-para-uso-de-espectro-ocioso>
- [3] D. A. Guimarães, "Pietra-ricci index detector for centralized data fusion cooperative spectrum sensing," *IEEE Trans. Veh. Technol.*, vol. 69, no. 10, pp. 12 354–12 358, 2020.
- [4] L. S. Costa, D. A. Guimarães, E. P. Frigieri, and R. A. A. de Souza, "Weighted circular folding cooperative power spectral density split cancellation algorithm," *IEEE Trans. Veh. Technol.*, vol. 70, no. 1, pp. 1062–1066, 2021.
- [5] L. S. Costa, W. Silva, and R. A. A. de Souza, "Desempenhos do sensoriamento espectral via periodograma ponderado sob ruído não uniforme e canais seletivos e com sombreamento," *Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*, 2021.
- [6] J. Xie, J. Fang, C. Liu, and X. Li, "Deep learning-based spectrum sensing in cognitive radio: A CNN-LSTM approach," *IEEE Commun. Lett.*, vol. 24, no. 10, pp. 2196–2200, 2020.
- [7] Z. Chen, D. Guo, and J. Zhang, "Deep learning for cooperative spectrum sensing in cognitive radio," in *2020 IEEE 20th International Conference on Communication Technology (ICCT)*, 2020, pp. 741–745.
- [8] M. Adil, R. Ullah, S. Noor, and N. Gohar, "Effect of number of neurons and layers in an artificial neural network for generalized concrete mix design," *Neural Computing and Applications*, vol. 34, no. 11, pp. 8355–8363, Jun. 2022.
- [9] R. C. D. V. Bomfin and R. A. A. de Souza, "A new spatially correlated shadowed channel model with cognitive radio application," in *2015 IEEE 81st Veh. Technol. Conf. (VTC Spring)*, 2015, pp. 1–5.
- [10] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [11] M. Tan and Q. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," in *Proceedings of the Intern. Conf. on Machine Learning*, ser. Proceedings of Machine Learning Research, vol. 97. PMLR, 2019, pp. 6105–6114.
- [12] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," in *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 2818–2826.
- [13] G. Huang, Z. Liu, L. V. D. Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Los Alamitos, CA, USA: IEEE Computer Society, jul 2017, pp. 2261–2269.
- [14] J. Proakis and D. Manolakis, *Digital Signal Processing: Principles, algorithms, and applications*, 3rd ed. Pearson Education, Inc., 1995, ch. Power Spectrum Estimation, p. 919–920.
- [15] K. He and J. Sun, "Convolutional neural networks at constrained time cost," 2014. [Online]. Available: <https://arxiv.org/abs/1412.1710>