

# Detector Baseado no Índice de Gini e na Decomposição de Cholesky para Sensoriamento Espectral em Canais com Alto Fator de Rice

Dayan Adionel Guimarães

**Resumo**—Recentemente, o detector GID (*Gini index detector*) foi desenvolvido para a sensoriamento espectral cooperativo, sendo indicado para canais com alto fator de Rice. Neste artigo propõe-se o detector CGID (*Cholesky-based GID*), que aplica a decomposição de Cholesky à matriz de covariância do sinal recebido, em seguida operando a parte real do resultado como na estatística de teste GID. O CGID herda os atributos atrativos do GID, com custo computacional 22% menor em termos de taxa de crescimento do tempo de execução, com latência aproximadamente 8,5 vezes menor e com desempenho igual ao do GID quando o fator de Rice do canal de sensoriamento é alto.

**Palavras-Chave**—Acesso dinâmico ao espectro, detector GID, rádio cognitivo, sensoriamento espectral.

**Abstract**—The Gini index detector (GID) was recently developed for cooperative spectrum sensing, being suitable for channels with high Rice factor. This article proposes the Cholesky-based GID (CGID), which applies the Cholesky decomposition to the sample covariance matrix of the received signal, subsequently operating the real part of the result likewise the GID test statistic. The CGID inherits the attractive attributes of GID, exhibiting 22% lower computational cost in terms of runtime growth rate, latency approximately 8.5 times smaller, and performance equal to the GID's when the Rice factor of the channel is large.

**Keywords**—Cognitive radio, dynamic spectrum access, Gini index detector, spectrum sensing.

## I. INTRODUÇÃO

A proliferação de sistemas de comunicação sem fio nos últimos anos fez com que o espectro de radiofrequência (*radio-frequency*, RF) se tornasse um recurso escasso, o que se deve à adoção da política de alocação fixa de espectro, na qual uma rede de usuário primários (*primary users*, PUs) detém direitos exclusivos de uso de uma determinada faixa de RF. No entanto, estudos mostram que muitas bandas de RF já alocadas permanecem subutilizadas em certas regiões e períodos, levando ao uso ineficiente do espectro [1]–[3].

O cenário de escassez de espectro de RF tende a se agravar à medida que a Internet das Coisas (*Internet of things*, IoT) e as redes 5G se expandem e as redes 6G se tornam realidade, o que exigirá larguras de banda maiores e resultará em ainda mais competição pelo já limitado espectro [4].

Dayan. A. Guimarães, Instituto Nacional de Telecomunicações – Inatel, Santa Rita do Sapucaí, MG, Brasil. E-mail: dayan@inatel.br. Este trabalho foi parcialmente financiado pela RNP, com recursos do MCTIC, processo 01245.020548/2021-07, sob o projeto Brasil 6G do Centro de Referência em Radiocomunicações (CRR) do Inatel, pela Huawei, sob o projeto Formação Avançada em Redes e Sistemas de Telecomunicações, processo PPA6001BRA23032110257684, e pelo CNPq, processo 302589/2021-0.

Uma solução potencial para o problema do uso ineficiente do espectro é a adoção de redes de rádio cognitivo (*cognitive radio*, CR) [5], nas quais se podem identificar bandas vagas resultantes da ocupação variável do espectro da rede primária no tempo e no espaço. Nesse caso, uma política de acesso dinâmico ao espectro (*dynamic spectrum access*, DSA) pode ser adotada, na qual os terminais cognitivos de usuários secundários (*secondary users*, SU) usam oportunisticamente bandas de frequência desocupadas. O chamado sensoriamento de espectro, com ou sem o auxílio de uma base de dados de ocupação do espectro de RF, é a técnica usada pela rede secundária para detectar lacunas espectrais, também chamadas de espaços em branco (*whitespaces*) [3], [4], [6]–[8].

Enquanto o sensoriamento individual de espectro por cada SU pode ser comprometido pela ação de desvanecimento por multipercurso, sombreamento de sinal e terminais ocultos, o sensoriamento espectral cooperativo (*cooperative spectrum sensing*, CSS) envolve vários SUs para melhorar a acurácia das decisões sobre o estado de ocupação da banda sensoriada.

Neste artigo, um CSS centralizado com fusão de dados é considerado, no qual as amostras do sinal recebido pelos SUs são transmitidas ao centro de fusão (*fusion center*, FC) para cálculo da estatística de teste e comparação desta com um limiar de decisão, objetivando chegar-se à decisão global sobre o estado de ocupação da banda monitorada.

Dentre os vários detectores para sensoriamento espectral propostos na literatura, este trabalho considera apenas recentes detectores cegos, os quais não fazem uso de nenhuma informação sobre o sinal detectado ou sobre a variância do ruído, a saber: o detector de razão de Hadamard (*Hadamard ratio*, HR) [9], o detector de média aritmética por geométrica (*arithmetic to geometric mean*, AGM) [10], os detectores baseados em volume (*volume-based detectors*, VDs) número 1 (VD1) e número 2 (VD2) [11], o detector por máximo-mínimo autovalor (*maximum-minimum eigenvalue detector*, MMED) [12], o teste da razão de verossimilhança generalizada baseado em autovalores (*generalized likelihood ratio test*, GLRT) [12], o detector baseado no índice de Gini (*Gini index detector*, GID) [13], o detector por razão entre raios e centros de Gerschgorin (*Gerschgorin radii and centers ratio*, GRCR) [14], e o detector baseado no índice de Pietra-Ricci (*Pietra-Ricci index detector*, PRIDE) [15].

A carga computacional requerida para formar as estatísticas de teste de tais detectores varia a depender das operações necessárias: o HR e o VD dependem principalmente do cálculo do determinante da matriz de covariância amostral (*sample co-*

variance matrix, SCM). Os detectores AGM, MMED e GLRT fazem uso das estimativas dos autovalores dessa matriz. Já o GID, o GRCR e o PRIDE operam diretamente os elementos da SCM. O GID, GRCR e PRIDE são particularmente dignos de nota por terem menor complexidade computacional e serem mais robustos contra variações de potência de sinal e ruído do que os demais detectores aqui mencionados. Dentre estes, o PRIDE tem a menor complexidade, seguido de perto pelo GID e pelo GRCR [13]–[15].

O detector GID é explorado neste trabalho. Sua estatística de teste foi desenvolvida com base no índice de Gini, que é uma métrica de dispersão estatística comumente usada em Economia e Ciências Sociais para medida de desigualdade [13].

Embora a estatística de teste GID não faça uso de autovalores ou determinantes da SCM, sua carga computacional é penalizada devido ao ônus relativamente alto associado ao cálculo da magnitude dos elementos complexos da SCM, ou a magnitude de resultados de operações feitas nos elementos complexos da SCM. Nesse contexto, o presente trabalho visa reduzir o custo computacional do detector GID, o que é obtido realizando a decomposição de Cholesky da SCM e operando a parte real do resultado como na estatística de teste GID. O detector resultante, denominado CGID (*Cholesky-based GID*) herda os atributos atrativos do GID, com custo computacional menor em termos de taxa de crescimento do tempo de execução, com latência muitas vezes menor e com desempenho praticamente igual àquele fornecido pelo GID quando o fator de Rice do canal de sensoriamento é alto.

O restante do artigo está organizado da seguinte forma: na Seção II descrevem-se os modelos de sinal, ruído e canal; as estatísticas de teste GID e CGID são abordadas na Seção III; resultados numéricos e interpretações são fornecidos na Seção IV e as conclusões do trabalho estão na Seção V.

## II. MODELOS DE SINAL, RUÍDO E CANAL

O modelo para CSS centralizado com fusão de dados aqui adotado é baseado em [13], [15], mas com uma importante alteração no cômputo da razão sinal-ruído (*signal-to-noise ratio*, SNR) e na forma de determinar as potências dos sinais recebidos nos SUs. Consideram-se  $m$  SUs em cooperação, cada um coletando  $n$  amostras do sinal primário durante um intervalo de sensoriamento. As amostras coletadas são transmitidas ao FC por um canal de controle livre de erros, formando a matriz de amostras  $\mathbf{Y} \in \mathbb{C}^{m \times n}$ , dada por

$$\mathbf{Y} = \mathbf{h}\mathbf{x}^T + \mathbf{V}, \quad (1)$$

em que o vetor  $\mathbf{x} \in \mathbb{C}^{n \times 1}$  contém as amostras do sinal primário, as quais são modeladas como variáveis aleatórias Gaussianas complexas de média zero. O vetor de canal  $\mathbf{h} \in \mathbb{C}^{m \times 1}$  é formado por elementos  $h_i$  que representam os ganhos dos canais entre o transmissor PU e o  $i$ -ésimo SU, para  $i = 1, \dots, m$ . A variação desses ganhos ao longo do tempo modela o efeito de desvanecimento produzido no sinal devido à propagação multipercurso do sinal. Tem-se  $\mathbf{h} = \mathbf{G}\mathbf{a}$ , em que  $\mathbf{G}$  é uma matriz de ganhos a ser definida mais adiante, e  $\mathbf{a} \in \mathbb{C}^{m \times 1}$  é um vetor formado por variáveis aleatórias Gaussianas complexas  $a_i \sim \mathcal{CN}[\sqrt{K/(2K+2)}, 1/(K+1)]$ , sendo  $K =$

$10^{K^{(\text{dB})}/10}$  o fator de Rice dos canais entre PU e SUs, com  $K^{(\text{dB})} = 10 \log_{10}(K)$ , em dB. A partir de medições relatadas em [16], concluiu-se que  $K^{(\text{dB})}$  é uma variável aleatória dependente do ambiente e que pode ser bem caracterizada por uma distribuição Gaussiana com média  $\mu_K$  e desvio padrão  $\sigma_K$ , ambos em dB, ou seja,  $K^{(\text{dB})} \sim \mathcal{N}[\mu_K, \sigma_K]$ . Valores típicos de  $\mu_K$  e  $\sigma_K$  são determinados de acordo com as características de propagação impostas pelo ambiente [16]. Por exemplo, em áreas urbanas tem-se tipicamente  $\mu_K = 1,88$  dB e  $\sigma_K = 4,13$  dB. Em áreas rurais ou abertas,  $\mu_K = 2,63$  dB e  $\sigma_K = 3,82$  dB. Regiões suburbanas são comumente associadas a  $\mu_K = 2,41$  dB e  $\sigma_K = 3,84$  dB [16].

A presente modelagem também admite que os níveis de potência do sinal recebido pelos SUs podem ser desiguais e variantes no tempo devido às diferentes distâncias entre o transmissor PU e os SUs, e também devido à variação dessas distâncias em diferentes eventos de sensoriamento causada pelo movimento dos SUs. Nesse caso a matriz de ganho  $\mathbf{G} \in \mathbb{R}^{m \times m}$  anteriormente mencionada é dada por  $\mathbf{G} = \text{diag}(\sqrt{\mathbf{p}/P_{\text{tx}}})$ , em que  $\mathbf{p} = [P_{\text{rx}1}, \dots, P_{\text{rx}m}]^T$  é o vetor de potências do sinal PU recebido pelos  $m$  SUs, com  $[\cdot]^T$  denotando transposição.  $P_{\text{tx}}$  é a potência de transmissão do PU, em watts, e  $\text{diag}(\cdot)$  retorna uma matriz diagonal cuja diagonal é formada pelos elementos do vetor no argumento.

O modelo de previsão de atenuação de distâncias logarítmicas (*log-distance*) [17] é aqui utilizado para calcular a potência de sinal recebida pelo  $i$ -ésimo SU, em watts, dada por

$$P_{\text{rx}i} = P_{\text{tx}} \left( \frac{d_0}{d_i} \right)^\eta, \quad (2)$$

em que  $d_0$  é uma distância de referência na região de campo distante da antena transmissora,  $d_i$  é a distância entre o PU e o  $i$ -ésimo SU e  $\eta$  é o expoente de perdas. Quanto maior o valor de  $\eta$ , maior a atenuação do sinal a uma determinada distância. Todas as distâncias são dadas em metros.

Diferenças e variações das potências de ruído nos receptores dos SUs podem ocorrer devido a variações de temperatura, diferenças entre os *front-ends* e sinais indesejados que adentram os receptores e agem como ruído. Com o objetivo de modelar tais diferenças e variações, os elementos da  $i$ -ésima linha da matriz  $\mathbf{V} \in \mathbb{C}^{m \times n}$  dada em (1) são variáveis aleatórias Gaussianas de média nula e variância

$$\sigma_i^2 = (1 + \rho u_i) \bar{\sigma}^2, \quad (3)$$

em que  $u_i$  é a realização de uma variável aleatória uniforme,  $U_i$ , no intervalo  $[-1, 1]$ ,  $\bar{\sigma}^2$  é a potência média de ruído nos SUs e  $0 \leq \rho < 1$  é a fração de variação da potência de ruído  $\sigma_i^2$  em torno de  $\bar{\sigma}^2$ .

A razão sinal-ruído instantânea nos SUs,  $\gamma$ , é uma variável aleatória, pois depende de  $\sigma_i^2$  e  $d_i$ , que são aleatórios. À luz de (2) e (3), uma realização de  $\gamma$  é dada por

$$\gamma = \frac{1}{m} \sum_{i=1}^m \frac{P_{\text{tx}} (d_0/d_i)^\eta}{(1 + \rho u_i) \bar{\sigma}^2}. \quad (4)$$

Assim, a SNR média dos SUs é dada por  $\text{SNR} = \mathbb{E}[\gamma]$ , sendo  $\mathbb{E}[\gamma]$  o valor esperado de  $\gamma$ . Para realização desse modelo de SNR, calcula-se primeiro o valor esperado de  $\gamma'$ ,

esta definida para  $\bar{\sigma}^2 = 1$  e  $\{d_i\}$ . Pode-se mostrar [18] que tal valor esperado é dado por

$$\mathbb{E}[\gamma'] = \ln \left( \frac{1+\rho}{1-\rho} \right) \frac{1}{2\rho m} \sum_{i=1}^m P_{\text{rx}i}, \quad (5)$$

para  $0 < \rho < 1$ , sendo que para  $\rho = 0$  tem-se

$$\mathbb{E}[\gamma'] = \frac{1}{m} \sum_{i=1}^m P_{\text{rx}i}. \quad (6)$$

Como  $\text{SNR} = \mathbb{E}[\gamma] = \mathbb{E}[\gamma']/\bar{\sigma}^2$ , o valor calibrado da potência de ruído é calculado por

$$\bar{\sigma}^2 = \frac{\mathbb{E}[\gamma']}{\text{SNR}}. \quad (7)$$

Esse valor de  $\bar{\sigma}^2$  é então aplicado em (3), juntamente com uma realização  $u_i$  da variável aleatória  $U_i$ , para que se determine  $\sigma_i^2$ , que é a variância das amostras de ruído na  $i$ -ésima linha de  $\mathbf{V}$ . Novos valores de  $\{\sigma_i^2\}$  são calculados a cada evento de sensoriamento, conferindo variabilidade temporal à potência de ruído. O presente modelo de calibração de SNR corrige aquele adotado em [13], no qual a SNR é definida como a razão entre as potências médias de sinal e de ruído.

### III. ESTATÍSTICAS DE TESTE GID E CGID

A matriz  $\mathbf{Y}$  definida em (1) é formada no FC a partir das  $mn$  amostras enviadas pelos SUs. Sob a hipótese  $\mathcal{H}_1$ , o sinal primário está presente na banda sensoriada, ou seja,  $\mathbf{Y} = \mathbf{h}\mathbf{x}^T + \mathbf{V}$ . Sob a hipótese  $\mathcal{H}_0$  o sinal primário está ausente, levando a  $\mathbf{Y} = \mathbf{V}$ . A partir de  $\mathbf{Y}$  computa-se no FC a SCM de ordem  $m \times m$ , dada por

$$\mathbf{R} = \frac{1}{n} \mathbf{Y}\mathbf{Y}^\dagger, \quad (8)$$

com  $\dagger$  denotando o complexo conjugado transposto. Seja  $r_i$  o  $i$ -ésimo elemento do vetor  $\mathbf{r}$  formado pelo empilhamento das colunas de  $\mathbf{R}$ , para  $i = 1, \dots, m^2$ . A estatística de teste GID proposta em [13] é calculada no FC de acordo com

$$T_{\text{GID}} = \frac{2(m^2 - m) \sum_{i=1}^{m^2} |r_i|}{\sum_{i=1}^{m^2} \sum_{j=1}^{m^2} |r_i - r_j|}. \quad (9)$$

A decisão sobre o estado de ocupação da banda sensoriada é tomada comparando-se  $T_{\text{GID}}$  com um limiar de decisão  $\lambda$  definido *a-priori*, de acordo com a taxa de alarme falso desejada. Se  $T_{\text{GID}} > \lambda$ , a decisão é tomada a favor de  $\mathcal{H}_1$ . Caso contrário,  $\mathcal{H}_0$  é escolhida.

O cálculo da magnitude de cada valor complexo contido em  $\mathbf{r}$  é responsável pela grande carga computacional associada a (9). Tal cálculo corresponde à raiz quadrada da soma da parte real e imaginária ao quadrado do valor, sendo justamente a raiz quadrada quem demanda maior esforço computacional. Para agravar o problema, tal cálculo deve ser feito  $m^2$  vezes no numerador e  $m^4$  vezes no denominador de (9).

Propõe-se que estatística de teste do detector CGID seja

$$T_{\text{CGID}} = \frac{\sum_{i=1}^L |c_i|}{\sum_{i=1}^L \sum_{j=i}^L |c_i - c_j|}, \quad (10)$$

em que  $L = (m^2 + m)/2$  e  $c_i$  é o  $i$ -ésimo elemento do vetor  $\mathbf{c} \in \mathbb{R}^{L \times 1}$  formado pelo empilhamento das colunas de  $\mathbf{C} = \Re[\text{chol}(\mathbf{R})]$ , em que  $\mathbf{C}$  é a matriz triangular superior formada pela parte real dos elementos da matriz resultante da decomposição de Cholesky de  $\mathbf{R}$ .

Três medidas de redução de carga computacional foram aplicadas em (10), em relação a (9): i) a constante  $2(m^2 - m)$  foi removida por não afetar o desempenho; ii) os valores operados são reais em vez de complexos; iii) a quantidade de termos nos somatórios foi reduzida de  $m^2$  para  $(m^2 + m)/2$  no numerador; no denominador, pode-se mostrar que a redução foi de  $m^4$  para  $(L^2 + L)/2 = (m^4 + 2m^3 + 3m^2 + 2m)/8$  (note que o somatório da direita inicia em  $j = i$ ).

Objetivando demonstrar de forma quantitativa a redução de carga computacional obtida pelo CGID, foram realizadas medidas de tempo de execução (*run-time*) dos detectores GID e CGID em função de  $m$ , via funções `tic` e `toc` do Matlab, usando um computador com processador Intel Core i7-11800H Geração 11 @ 2.30 GHz, com 64 GB de RAM e executando o Matlab R2018b de 64 bits no Windows 11 Professional. A Fig. 1 apresenta os resultados.

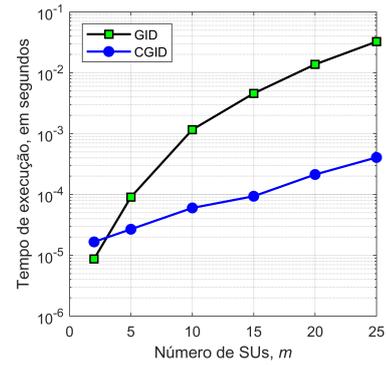


Fig. 1: Tempo de execução das estatísticas de teste dos detectores GID e CGID.

Um ajuste de curva de potência do tipo  $ax^b + c$  foi aplicado aos resultados, produzindo  $a \approx 1,1 \times 10^{-7}$ ,  $b \approx 3,9$  e  $c \approx 9,9 \times 10^{-6}$  para o GID e  $a \approx 1,3 \times 10^{-8}$ ,  $b \approx 3,1$  e  $c \approx 1,8 \times 10^{-5}$  para o CGID. Com esse procedimento verifica-se que, como esperado, o tempo de execução para o GID cresce segundo  $\mathcal{O}(m^4)$  na notação big- $\mathcal{O}$ , enquanto o crescimento para o CGID segue  $\mathcal{O}(m^{3,1})$ , representando uma redução de cerca de 22%. Por outro lado, o fator de escala do tempo de execução para o GID é cerca de 8,5 vezes maior, o que significa que a estatística de teste CGID utiliza aproximadamente 12% do tempo de cômputo da estatística de teste GID, o que pode ser traduzir em significativa redução da latência do processo de sensoriamento de espectro. É interessante notar que o aumento de carga computacional do CGID devido à decomposição de Cholesky é sobrecompensado pela redução trazida pelos cálculos de valor absoluto de grandezas reais em vez de complexas.

Em [13] demonstrou-se que o detector GID tem a propriedade de taxa de falso alarme constante (*constant false alarm rate*, CFAR). Para verificar se o detector CGID também tem essa propriedade, a Fig. 2 mostra as funções densidade de

probabilidade (*probability density functions*, PDFs) empíricas de  $T_{\text{CGID}}$  sob  $\mathcal{H}_0$  e  $\mathcal{H}_1$ , para  $\bar{\sigma}^2 \approx 4,2 \times 10^{-6}$  se  $P_{\text{tx}} = 5$  watts e para  $\bar{\sigma}^2 \approx 3,2 \times 10^{-5}$  se  $P_{\text{tx}} = 50$  watts, com  $\text{SNR} = -13$  dB em ambos os casos. Observa-se que, sob  $\mathcal{H}_0$ , a estatística de teste do detector CGID mantém seu suporte independentemente do valor de  $\bar{\sigma}^2$ . Isso significa que a taxa de falso alarme será constante, pois o limiar de decisão configurado não será alterado com a alteração de  $\bar{\sigma}^2$ .

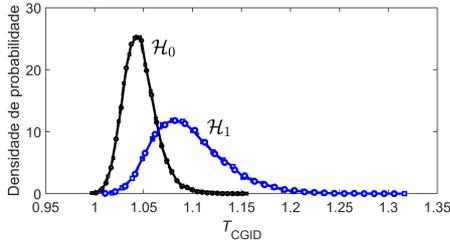


Fig. 2: PDFs empíricas de  $T_{\text{CGID}}$  sob  $\mathcal{H}_0$  e  $\mathcal{H}_1$ , para dois valores distintos de  $\bar{\sigma}^2$ .

#### IV. RESULTADOS NUMÉRICOS

Nesta seção comparam-se os desempenhos dos detectores GID e CGID, bem como dos detectores listados na Seção I, a saber: PRIDe, HR, VD1, GLRT, MMED, AGM e GRCR. As estatísticas de teste desses detectores concorrentes são fornecidas na Tabela I, onde  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$  são os autovalores de  $\mathbf{R}$ ,  $\det(\mathbf{R})$  é o determinante of  $\mathbf{R}$ ,  $r_i$  é o  $i$ -ésimo elemento de  $\mathbf{r}$ ,  $r_{i,j}$  é o elemento na  $i$ -ésima linha e  $j$ -ésima coluna de  $\mathbf{R}$  e, por fim,  $\mathbf{E} = \text{diag}(\mathbf{e})$ , em que  $\text{diag}(\mathbf{e})$  resulta na matriz diagonal cuja diagonal principal forma o vetor  $\mathbf{e} = [e_1, e_2, \dots, e_m]$ , com  $e_i = \|\mathbf{R}(i, :)\|_2$  sendo a norma Euclidiana da  $i$ -ésima linha de  $\mathbf{R}$ .

TABELA I: Estatísticas de teste dos detectores concorrentes.

$T_{\text{PRIDe}} = \frac{\sum_{i=1}^m  r_i }{\sum_{i=1}^m  r_i - \bar{r} }$	$T_{\text{AGM}} = \frac{\frac{1}{m} \sum_{i=1}^m \lambda_i}{(\prod_{i=1}^m \lambda_i)^{1/m}}$
$T_{\text{HR}} = \frac{\det(\mathbf{R})}{\prod_{i=1}^m r_{i,i}}$	$T_{\text{GLRT}} = \frac{\lambda_1}{\sum_{i=1}^m \lambda_i}$
$T_{\text{VD1}} = \log[\det(\mathbf{E}^{-1}\mathbf{R})]$	$T_{\text{MMED}} = \frac{\lambda_1}{\lambda_m}$
$T_{\text{GRCR}} = \frac{\sum_{i=1}^m \sum_{j=1, j \neq i}^m  r_{i,j} }{\sum_{i=1}^m r_{i,i}}$	

Os desempenhos aqui reportados são medidos em termos da probabilidade de detecção,  $P_d$ , para uma probabilidade de falso alarme  $P_{\text{fa}} = 0,1$ , em função de alguns dos principais parâmetros do sistema. Todos os resultados foram gerados por meio de simulações de Monte Carlo no Matlab R2018a.

A topologia CSS adotada consiste de uma rede secundária com  $m$  SUs uniformemente distribuídos em uma área de cobertura circular de raio  $r$  e centrada em  $(x, y) = (0, 0)$ , com o transmissor PU localizado em  $(x, y) = (r, r)$  e o FC localizado no centro da área de cobertura. Cada evento de sensoriamento corresponde a novas posições dos SUs, visando simular mobilidade.

A Fig. 3 apresenta  $P_d$  versus SNR para  $\rho = 0,5$  (Fig. 3a) e  $P_d$  versus  $\rho$  para  $\text{SNR} = -13$  dB (Fig. 3b), considerando  $m = 6$ ,  $n = 250$ ,  $r = 1$  km,  $\mu_K = 20$  dB e  $\eta = 2,5$ . Como esperado, a Fig. 3a mostra que todos os detectores têm desempenhos melhorados à medida que a SNR aumenta, com destaque para os detectores GID e CGID, os quais se equiparam e superam os demais na situação analisada, correspondente a significativa visada direta entre transmissor primário e SUs. Os detectores GLRT, MMED e AGM também conseguem atingir desempenhos satisfatórios, mas às custas de altos valores de SNR, fato devido à baixa robustez frente a variações nas potências dos sinais recebidos e do ruído. A Fig. 3b revela justamente tal grau de robustez. Percebe-se que os detectores GID, CGID, PRIDe, HR, VD1 e GRCR são os mais robustos, pois sofrem pouca variação de desempenho, desde que  $\rho$  esteja entre 0 e  $\approx 0,8$ .

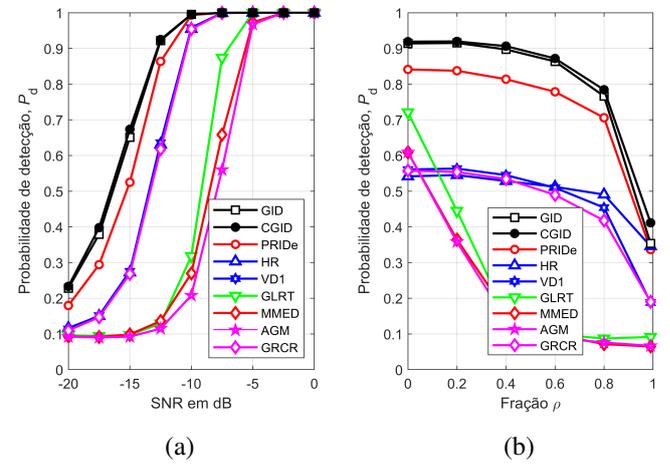


Fig. 3:  $P_d$  versus SNR para  $\rho = 0,5$  (a) e  $P_d$  versus  $\rho$  para  $\text{SNR} = -13$  dB (b).

Na Fig. 4 tem-se  $P_d$  versus  $\mu_K$  para  $\eta = 2,5$  (Fig. 4a) e  $P_d$  versus  $\eta$  para  $\mu_K = 20$  dB (Fig. 4b), considerando  $m = 6$ ,  $n = 250$ ,  $\text{SNR} = -12$  dB,  $\rho = 0,5$  e  $r = 1$  km. A Fig. 4a tem como principal objetivo revelar a adequação dos detectores GID e CGID a canais com alto fator de Rice: note que para  $\mu_K > 0$  dB, GID e CGID superam os demais detectores, exceto o PRIDe, que é também superado a partir de  $\mu_K = 5$  dB. Note também que os detectores GID e CGID convergem em desempenho à medida que  $\mu_K$  aumenta. Os detectores HR, VD1 e GRCR têm desempenhos pouco afetados por  $\mu_K$ , suplantando todos os detectores em baixos valores de  $\mu_K$ . Os detectores GLRT, MMED e AGM apresentam desempenhos extremamente baixos, pois não são robustos frente a variações nas potências dos sinais recebidos e do ruído, como também se pode ver na Fig. 4b. A Fig. 4b também revela que os desempenhos dos detectores robustos piora à medida que  $\eta$  aumenta, mas isso não ocorre devido ao aumento da atenuação do sinal entre o transmissor primário e os SUs, já que a SNR foi configurada para ser a mesma em qualquer  $\eta$ . Tal redução de desempenho se deve às maiores diferenças entre as potências dos sinais recebidos à medida que  $\eta$  aumenta.

Por fim, considerando  $\text{SNR} = -14$  dB,  $\rho = 0,5$ ,  $r = 1$  km,  $\mu_K = 20$  dB e  $\eta = 2,5$ , a Fig. 5 mostra que o aumento de  $m$

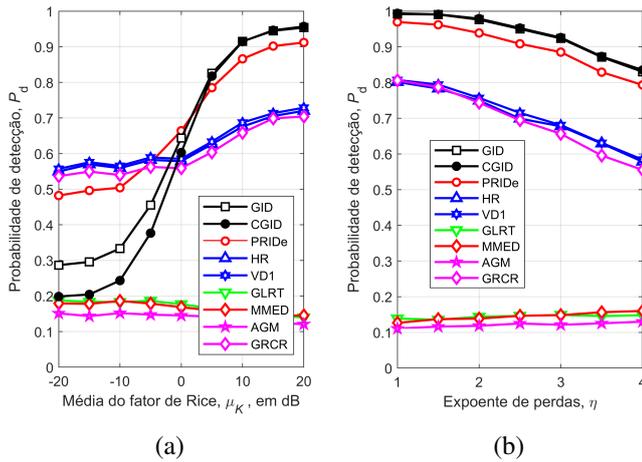


Fig. 4:  $P_d$  versus  $\mu_K$  para  $\eta = 2,5$  (a) e  $P_d$  versus  $\eta$  para  $\mu_K = 20$  dB (b).

ou de  $n$  (ou de ambos) melhora desempenho dos detectores, como já se esperava, com exceção do GLRT, MMED e AGM, mais uma vez devido à baixa robustez desses detectores contra variações de níveis de sinal recebido e de ruído. Os detectores GID e CGIC se destacam uma vez mais e com desempenhos praticamente iguais, devido a ter-se  $\mu_K = 20$  dB. O detector PRIDe vem em seguida, apresentando desempenho pior que os detectores GID e CGIC, mas melhor que os detectores HR, VD1 e GRGR (e, obviamente, melhor que os detectores GLRT, MMED e AGM).

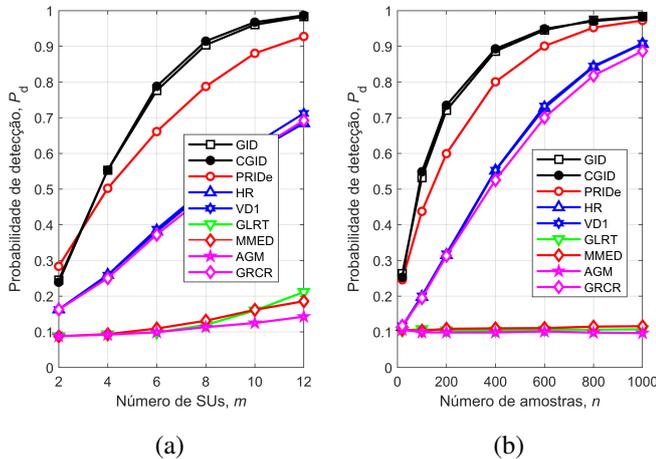


Fig. 5:  $P_d$  versus  $m$  para  $n = 250$  (a) e  $P_d$  versus  $n$  para  $m = 6$  (b).

## V. CONCLUSÕES

Este artigo propôs o detector CGID (*Cholesky-based GID*), o qual aplica a decomposição de Cholesky à matriz de covariância do sinal recebido, em seguida operando a parte real do resultado da mesma forma que seu antecessor, o GID. Verificou-se que o CGID herdou os atributos atrativos do GID, a saber: taxa de falso alarme constante, robustez contra variações de potências dos sinais recebidos e de ruído nos SUs, e a não necessidade de conhecimento de características do

sinal primário, nem da variância de ruído. Verificou-se também que o custo computacional do CGID é cerca de 22% menor que no caso do GID em termos de taxa de crescimento do tempo de execução, com latência aproximadamente 8,5 vezes menor e com desempenho equivalente ao GID quando o fator de Rice do canal de sensoriamento é alto. Tais benefícios fazem com que o CGID seja candidato em potencial para reais aplicações práticas no sensoriamento espectral cooperativo para sistemas de rádios cognitivos, contribuindo para a viabilização do acesso dinâmico ao espectro almejado para as redes 5G e 6G.

## REFERÊNCIAS

- [1] Federal Communications Commission, FCC, *Spectrum Policy Task Force Report*. FCC, 2002. [Online]. Available: <https://books.google.com.br/books?id=p9MQtwAACAAJ>.
- [2] D. Das and S. Das, "A survey on spectrum occupancy measurement for cognitive radio," *Wirel. Pers. Commun.*, vol. 85, no. 4, p. 2581–2598, Dec 2015, doi: 10.1007/s11277-015-2921-1.
- [3] Y. Arjoune and N. Kaabouch, "A comprehensive survey on spectrum sensing in cognitive radio networks: Recent advances, new challenges, and future research directions," *Sensors*, vol. 19, no. 1, 2019, doi: 10.3390/s19010126.
- [4] A. Nasser, H. Al Haj Hassan, J. Abou Chaaya, A. Mansour, and K.-C. Yao, "Spectrum sensing for cognitive radio: Recent advances and future challenge," *Sensors*, vol. 21, no. 7, 2021. [Online]. Available: <https://www.mdpi.com/1424-8220/21/7/2408>
- [5] J. Mitola III and G. Q. Maguire Jr., "Cognitive radio: making software radios more personal," *IEEE Personal Commun. Mag.*, vol. 6, no. 4, pp. 13–18, Aug 1999.
- [6] Y. Zeng, Y.-C. Liang, A. Hoang, and R. Zhang, "A review on spectrum sensing for cognitive radio: Challenges and solutions," *EURASIP Journal on Advances in Signal Processing*, vol. 2010, no. 1, p. 381465, 2010, doi: 10.1155/2010/381465.
- [7] I. F. Akyildiz, B. F. Lo, and R. Balakrishnan, "Cooperative spectrum sensing in cognitive radio networks: A survey," *Elsevier Physical Comm.*, vol. 4, pp. 40–62, mar 2011, doi: 10.1016/j.phycom.2010.12.003.
- [8] D. A. Guimarães, "Spectrum sensing: A tutorial," *Journal of Communication and Information Systems*, vol. 37, no. 1, pp. 10–29, Feb. 2022. [Online]. Available: <https://jcis.sbrt.org.br/jcis/article/view/811>
- [9] L. Huang, Y. Xiao, H. C. So, and J. Fang, "Accurate performance analysis of Hadamard ratio test for robust spectrum sensing," *IEEE Trans. Wirel. Commun.*, vol. 14, no. 2, pp. 750–758, Feb 2015.
- [10] R. Zhang, T. J. Lim, Y. C. Liang, and Y. Zeng, "Multi-antenna based spectrum sensing for cognitive radios: A GLRT approach," *IEEE Trans. Commun.*, vol. 58, no. 1, pp. 84–88, Jan 2010.
- [11] L. Huang, C. Qian, Y. Xiao, and Q. T. Zhang, "Performance analysis of volume-based spectrum sensing for cognitive radio," *IEEE Trans. Wirel. Commun.*, vol. 14, no. 1, pp. 317–330, Jan 2015.
- [12] B. Nadler, F. Penna, and R. Garelo, "Performance of eigenvalue-based signal detectors with known and unknown noise level," in *IEEE Int. Conf. Commun.*, Jun 2011, pp. 1–5.
- [13] D. A. Guimarães, "Gini index inspired robust detector for spectrum sensing over Ricean channels," *Electronics Letters*, November 2018, doi: 10.1049/el.2018.7375.
- [14] —, "Robust test statistic for cooperative spectrum sensing based on the Gerschgorin circle theorem," *IEEE Access*, vol. 6, pp. 2445–2456, 2018, doi: 10.1109/ACCESS.2017.2783443.
- [15] —, "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, doi: 10.1109/TVT.2020.3009440.
- [16] S. Zhu, T. S. Ghazaany, S. M. R. Jones, R. A. Abd-Alhameed, J. M. Noras, T. Van Buren, J. Wilson, T. Suggett, and S. Marker, "Probability distribution of Rician  $K$ -factor in urban, suburban and rural areas using real-world captured data," *IEEE Trans. Antennas Propag.*, vol. 62, no. 7, pp. 3835–3839, Jul 2014, doi: 10.1109/TAP.2014.2318072.
- [17] T. S. Rappaport, *Wireless Communications: Principles And Practice*, 2nd ed. Pearson Education, 2010.
- [18] D. A. Guimarães, "Modified Gini index detector for cooperative spectrum sensing over line-of-sight channels," *Sensors*, vol. 23, no. 12, 2023. [Online]. Available: <https://www.mdpi.com/1424-8220/23/12/5403>