

Análise das Distribuições $S\alpha S$ e αSG na Modelagem do Ruído de Camarão-de-Estalo

Luiz Gustavo Barros Guedes e Dayan Adionel Guimarães

Resumo—Sistemas de comunicação subaquáticos por ondas acústicas estão sujeitos à degradação de desempenho causada pelo ruído impulsivo gerado pelo crustáceo camarão-de-estalo. Em análises matemáticas ou simulações, esse ruído é comumente modelado por meio de amostras temporalmente decorrelacionadas seguindo a distribuição alfa-estável simétrica (*symmetric alpha-stable*, $S\alpha S$). Neste artigo analisa-se a adequação dessa distribuição em contraste com a distribuição alfa-sub-Gaussiana (*alpha-sub-Gaussian*, αSG) com correlação temporal não nula, no contexto do sensoriamento espectral subaquático.

Palavras-Chave—Camarão-de-estalo, comunicação subaquática, ruído impulsivo, sensoriamento espectral.

Abstract—Underwater acoustic communication systems are prone to performance degradation caused by the impulsive noise generated by snapping shrimps. In mathematical analysis or simulations, this noise is commonly modeled via temporally uncorrelated samples following the symmetric alpha-stable ($S\alpha S$) distribution. In this article, the adequacy of this distribution is analyzed in contrast to the alpha-sub-Gaussian (αSG) distribution with non-zero temporal correlation, in the context of underwater spectrum sensing.

Keywords—Impulsive noise, snapping shrimp, spectrum sensing, underwater communication.

I. INTRODUÇÃO

A crescente demanda por serviços de comunicação sem fio, em uma conjuntura de política de alocação fixa de banda, tem provocado escassez de faixas espectrais. Uma possível solução para esse problema consiste na adoção de uma política de alocação dinâmica do espectro, implementada por meio de redes secundárias de rádios cognitivos realizando sensoriamento espectral, com o objetivo de se detectar e, posteriormente, utilizar faixas destinadas a redes primárias que estejam momentaneamente desocupadas [1].

Não somente os sistemas de comunicação sem fio que usam radiofrequência estão sujeitos à citada escassez de espectro. Sistemas de comunicação subaquática [2] também sofrem do mesmo problema, uma vez que os serviços estão alocados em uma faixa de frequências bastante limitada, entre dezenas de Hertz e centenas de quilohertz.

A propagação multipercurso do sinal transmitido, o ruído e possíveis interferências são fatores que afetam o desempenho de sistemas de comunicação em geral e de sistemas de sensoriamento espectral em particular. Referindo-se ao ruído, além

do ruído térmico inato a qualquer sistema de comunicação, pode-se também ter a presença de ruídos impulsivos [3], os quais correspondem a sinais esporádicos, de curta duração e elevada intensidade.

Um tipo de ruído impulsivo presente em comunicações subaquáticas é o ruído do camarão-de-estalo [2]. Esse crustáceo, ao fechar rapidamente a maior de suas garras em formato de pinça, produz um jato de água de elevada velocidade que induz uma súbita despressurização da água com consequente formação e ruptura de bolhas de cavitação, produzindo um ruído acústico de grande intensidade.

Em análises matemáticas ou simulações de sistemas subaquáticos, o ruído de camarão-de-estalo é comumente modelado por meio de amostras temporalmente decorrelacionadas seguindo a distribuição alfa-estável simétrica (*symmetric alpha-stable*, $S\alpha S$) [3], [4]. Entretanto, há dúvida se a distribuição $S\alpha S$ é a mais adequada, particularmente no caso da análise de desempenho do sensoriamento espectral.

A. Contribuições

Neste artigo, analisa-se a adequação das distribuições $S\alpha S$ e α -sub-Gaussiana (*alpha-sub-Gaussian*, αSG) [5], [6] à modelagem do ruído de camarão-de-estalo. Essa adequação é analisada de duas maneiras: i) estatisticamente e ii) por meio do desempenho do sensoriamento espectral cooperativo centralizado com fusão de dados. Na primeira análise, comparam-se as matrizes de covariância e as funções de autocorrelação de ruídos gerados sob as distribuições mencionadas e um ruído gerado a partir de um arquivo de áudio do ruído de camarão-de-estalo real, obtido por aquisição de dados via hidrofones. Na segunda análise, faz-se a avaliação de desempenho do sensoriamento espectral sob ruído impulsivo via áudio e via modelos $S\alpha S$ e αSG . São comparados o detector de energia (*energy detector*, ED), o detector pela razão entre raios e centros de Gerschgorin (*Gerschgorin radii and centers ratio*, GRCR), os detectores baseados no índice Gini (*Gini index detector*, GID) e no índice Pietra-Ricci (*Pietra-Ricci index detector*, PRIDe) e o detector baseado no teste local invariante (*locally most powerful invariant test*, LMPIT).

B. Trabalhos relacionados e estrutura do artigo

Em [7] propõe-se uma análise teórica do desempenho do detector de energia em canais com desvanecimento e ruído impulsivo, este caracterizado por um modelo Bernoulli-Gaussiano. Segundo os autores, esse modelo tem significativo apelo prático em sistemas de transmissão multiportadora baseados em multiplexação por divisão de frequências ortogonais.

Luiz G. B. Guedes e Dayan A. Guimarães, Instituto Nacional de Telecomunicações - Inatel, Santa Rita do Sapucaí - MG, e-mail: luiz.guedes@mtel.inatel.br, dayan@inatel.br. Este trabalho foi financiado em parte pela RNP, com recursos do MCTIC, processo N° 01245.010604/2020-14, sob o projeto Brasil 6G do Centro de Referência em Radiocomunicações (CRR) do Inatel, e em parte pelo CNPq e pela FAPEMIG.

O trabalho desenvolvido em [8] propõe um esquema de sensoriamento espectral com detector de energia baseado em tangente hiperbólica (*hyperbolic tangent-based energy detector*, HT-ED) com objetivo de melhorar o desempenho sob ruídos não-Gaussianos, como o ruído impulsivo. Duas distribuições são utilizadas na modelagem desse tipo de ruído: Laplace e S α S.

A distribuição S α S é amplamente utilizada na modelagem do ruído impulsivo nos artigos mais recentes que analisam o desempenho do sensoriamento espectral em redes de rádios cognitivos. Citam-se [9]–[14] como exemplos.

Em nenhum dos trabalhos analisados se faz uso da distribuição α SG para modelar o ruído impulsivo na avaliação de desempenho do sensoriamento espectral, reforçando a contribuição do presente artigo.

O restante do artigo está assim organizado: a Seção II apresenta as distribuições S α S e α SG. Na Seção III, descreve-se o modelo de sensoriamento espectral e apresentam-se as estatísticas de teste avaliadas. A Seção IV destina-se à análise estatística dos ruídos com distribuição S α S e α SG, bem como do áudio gravado de camarão-de-estalo. Na Seção V, avalia-se o desempenho do sensoriamento espectral sob os ruídos impulsivos analisados e a Seção VI conclui o trabalho.

II. RUÍDOS S α S E α SG

A distribuição α -estável não apresenta forma fechada geral para sua função densidade de probabilidade, mas pode ser descrita por sua função característica [15]

$$\Phi(\omega) = \exp \{j\delta\omega - \gamma|\omega|^\alpha [1 + j\beta \text{sign}(\omega)\kappa(\omega, \alpha)]\}, \quad (1)$$

em que $\kappa(\omega, \alpha) = \tan(\pi\alpha/2)$, para $\alpha \neq 1$, ou $\kappa(\omega, \alpha) = (2/\pi)\log|\omega|$, para $\alpha = 1$ e $\text{sign}(\cdot)$ corresponde à função sinal. O expoente característico $\alpha \in (0, 2]$ é inversamente proporcional à impulsividade. O parâmetro de escala (intensidade) é $\gamma \in (0, \infty)$. O parâmetro de localização é $\delta \in \mathbb{R}$ e o parâmetro de simetria em torno de δ é $\beta \in [-1, 1]$ [4]. Quando $\beta = 0$, tem-se a distribuição S α S que, quando $\delta = 0$, modela o ruído aditivo Gaussiano branco (*additive white Gaussian noise*, AWGN) de fundo somado a picos de amplitude esporádicos, com elevada intensidade e curta duração [4], comumente denominado ruído S α S (S α S noise, S α SN).

Quando utilizado para descrever o ruído do camarão-de-estalo, o S α SN é incapaz de modelar a correlação temporal existente nesse tipo de ruído, mesmo tendo grande aderência com suas variações de amplitude.

A distribuição α SG é uma possível solução quanto à modelagem da correlação temporal do ruído impulsivo. A função característica [5] α SG é dada por

$$\Phi_{\mathbf{w}}(\boldsymbol{\omega}) = \exp \left[- \left(\frac{1}{2} \boldsymbol{\omega}^T \mathbf{M} \boldsymbol{\omega} \right)^{\frac{\alpha}{2}} \right], \quad (2)$$

em que $\mathbf{w} = [w_1 \ w_2 \ \dots \ w_p]^T$ tem elementos com distribuição α SG, $\boldsymbol{\omega} = [\omega_1 \ \omega_2 \ \dots \ \omega_p]^T$, p e \mathbf{M} denotam a dimensão e a matriz de covariância de \mathbf{w} , respectivamente. O operador T indica transposição.

O ruído α -sub-Gaussiano com parâmetro de memória m (α -sub-Gaussian noise with memory of order m , α S α GN(m)) [5],

[6] é oriundo da distribuição α SG ($m+1$)-dimensional, correspondente a uma subclasse da distribuição S α S com $\delta = \beta = 0$, que pode ser representado pela série temporal $\mathbf{w}_{t,m} = \mathbf{w}_m = [w_{t-m} \ w_{t-m+1} \ \dots \ w_t]^T$. Essa série corresponde a uma janela composta por $m+1$ amostras a partir do instante discreto t , inclusive. Tal ruído é estacionário e tem distribuição S α S para a amplitude de cada amostra, com quaisquer $m+1$ amostras adjacentes seguindo a distribuição α SG, o que assegura que entre elas haja correlação temporal determinada por \mathbf{M} .

O α S α GN(m) pode, então, ser parametrizado por α e por uma matriz de covariância Toeplitz simétrica, \mathbf{M} , independente do tempo. O fator de escala γ está implícito em \mathbf{M} .

III. SENSORIAMENTO ESPECTRAL

A. Modelo de sinais

O sensoriamento espectral pode ser feito de maneira individual pelos terminais dos usuários secundários (*secondary users*, SUs) ou de forma cooperativa (*cooperative spectrum sensing*, CSS). No CSS com fusão de dados, n amostras provenientes dos sinais transmitidos por s usuários primários (*primary users*, PUs) são coletadas por cada um dos d SUs em cooperação e transmitidas ao centro de fusão (*fusion center*, FC) da rede secundária. No FC será formada uma estatística de teste por meio das dn amostras recebidas a fim de se decidir sobre o estado de ocupação da banda de interesse.

O modelo ora descrito é similar àquele em [1]. Detalhes são aqui omitidos por concisão. Nesse modelo, tem-se que

$$\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{V} + \mathbf{W}, \quad (3)$$

em que $\mathbf{Y} \in \mathbb{C}^{d \times n}$ é a matriz que contém as amostras recebidas no FC. A matriz $\mathbf{X} \in \mathbb{C}^{s \times n}$ é composta pelas n amostras Gaussianas complexas de média zero e variância definida de acordo com a relação sinal-ruído (*signal-to-noise ratio*, SNR) média nos SUs, correspondentes a cada um dos s PUs. A matriz de canal $\mathbf{H} \in \mathbb{C}^{d \times s}$ contém elementos que caracterizam os ganhos do canal de sensoriamento entre o j -ésimo PU e o i -ésimo SU. Essa matriz é dada por

$$\mathbf{H} = \mathbf{G}\mathbf{A}, \quad (4)$$

sendo $\mathbf{A} \in \mathbb{C}^{d \times s}$ uma matriz formada por variáveis aleatórias a_{ij} de média $\sqrt{\kappa_{ij}/(2\kappa_{ij}+2)}$ e variância $1/(\kappa_{ij}+1)$, em que κ_{ij} modela o fator de Rice do canal entre o j -ésimo PU e o i -ésimo SU. A matriz $\mathbf{G} \in \mathbb{R}^{d \times d}$ é dada por

$$\mathbf{G} = \text{diag} \left(\sqrt{\frac{\eta}{\eta_{\text{avg}}}} \right), \quad (5)$$

para $\boldsymbol{\eta} = [\eta_1 \ \eta_2 \ \dots \ \eta_d]^T$ contendo as potências de sinal recebido nos SUs e $\eta_{\text{avg}} = \frac{1}{d} \sum_{i=1}^d \eta_i$. Ao se considerar níveis de potência de sinal recebidos diferentes e variantes no tempo entre os SUs, faz-se η_i uniformemente distribuída em $[(1-\rho_S)\eta_{\text{avg}}, (1+\rho_S)\eta_{\text{avg}}]$ em cada intervalo de sensoriamento, tendo-se $0 \leq \rho_S < 1$ como uma fração configurável da variação da potência de sinal recebido em torno da média.

As matrizes \mathbf{V} e \mathbf{W} compõem o ruído presente no sistema. A matriz $\mathbf{V} \in \mathbb{C}^{d \times n}$ modela o ruído AWGN, cujos elementos na i -ésima linha dessa matriz são amostras Gaussianas independentes e identicamente distribuídas, com média zero e variância σ_i^2 que, por serem variantes no tempo, têm distribuição

uniforme em torno de sua média, σ_{avg}^2 , na faixa $[(1-\rho_N)\sigma_{\text{avg}}^2, (1+\rho_N)\sigma_{\text{avg}}^2]$, com $0 \leq \rho_N < 1$ e $\sigma_{\text{avg}}^2 = \frac{1}{d} \sum_{i=1}^d \sigma_i^2$. Já a matriz $\mathbf{W} \in \mathbb{C}^{d \times n}$ contém as amostras de ruído impulsivo S α SN, α SGN(m) ou de camarão-de-estalo.

Com \mathbf{Y} no FC, computa-se a matriz de covariância amostral

$$\hat{\mathbf{R}} = \frac{1}{n} \mathbf{Y} \mathbf{Y}^\dagger, \quad (6)$$

em que \dagger denota complexo conjugado transposto.

B. Estatísticas de teste

O teste de hipótese binário correspondente ao sensoriamento espectral associa a hipótese nula, \mathcal{H}_0 , à ausência do sinal primário na banda sensoriada e a hipótese alternativa, \mathcal{H}_1 , à presença do sinal primário. Realiza-se o teste comparando uma estatística de teste T , formada a partir das amostras em \mathbf{Y} , com um limiar de decisão λ . Decide-se em favor de \mathcal{H}_1 se $T > \lambda$, ou de \mathcal{H}_0 se $T < \lambda$.

O desempenho do sensoriamento é comumente medido por meio da probabilidade de detecção, P_d , e da probabilidade de falso alarme, P_{fa} . A P_d é a probabilidade de se considerar o sinal primário presente na banda sensoriada, estando ele de fato presente, enquanto que a P_{fa} é a probabilidade de se julgar presente tal sinal, uma vez que ele esteja ausente.

A estatística de teste do ED é dada por [1]

$$T_{\text{ED}} = \sum_{i=1}^d \frac{1}{\sigma_i^2} \sum_{j=1}^n |y_{ij}|^2, \quad (7)$$

em que y_{ij} é a j -ésima amostra coletada pelo i -ésimo SU.

A estatística de teste do detector GRCR é dada por [16]

$$T_{\text{GRCR}} = \frac{\sum_{i=1}^d \sum_{j=1, j \neq i}^d |r_{ij}|}{\sum_{i=1}^d r_{ii}}, \quad (8)$$

sendo r_{ij} o elemento da i -ésima linha e j -ésima coluna de $\hat{\mathbf{R}}$.

As estatísticas de teste dos detectores GID [17] e PRIDe [18] são dadas respectivamente por

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

$$T_{\text{PRIDe}} = \frac{\sum_{i=1}^{d^2} |r_i|}{\sum_{i=1}^{d^2} |r_i - \bar{r}|}, \quad (10)$$

em que r_i é o i -ésimo elemento do vetor \mathbf{r} formado pelo empilhamento das colunas de $\hat{\mathbf{R}}$, e $\bar{r} = (1/d^2) \sum_{i=1}^{d^2} r_i$.

Por fim, para o detector LMPIT [19], tem-se

$$T_{\text{LMPIT}} = \sum_{i=1}^d \sum_{j=1}^d |c_{ij}|^2, \quad (11)$$

em que c_{ij} é o elemento da i -ésima linha e j -ésima coluna da matriz $\mathbf{C} = \mathbf{E}^{-1/2} \hat{\mathbf{R}} \mathbf{E}^{-1/2}$, sendo \mathbf{E} uma matriz diagonal cujos elementos são iguais aos da diagonal principal de $\hat{\mathbf{R}}$.

Os detectores GRCR, GID, PRIDe e LMPIT são cegos, ou seja, não requerem informações a respeito do ruído, ao contrário do ED. Além disso apresentam baixa complexidade computacional e são robustos por apresentarem pequena ou nenhuma mudança em seu desempenho com a variação temporal do sinal recebido, do ruído ou de ambos [1].

IV. ANÁLISE ESTATÍSTICA

Nesta seção, analisam-se a função de autocorrelação e a matriz de covariância de séries temporais formadas por amostras de áudio do ruído de camarão-de-estalo real e por amostras dos ruídos α SGN(m) e S α SN.

A função de autocovariância discreta normalizada [20, p. 31] da série temporal $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_p]^\text{T}$ de variáveis aleatórias reais é computada pelo Matlab por meio de

$$C(k) = \frac{1}{\hat{\sigma}_{\mathbf{x}}^2 p} \sum_{t=1}^{p-k} (x_t - \mu_{\mathbf{x}})(x_{t+k} - \mu_{\mathbf{x}}), \quad (12)$$

em que $k = 0, 1, 2, \dots, K$ é um atraso relativo discreto (*time lag*) com $K \ll p$, $\hat{\sigma}_{\mathbf{x}}^2$ e $\mu_{\mathbf{x}}$ são, respectivamente, a variância e a média estimada das componentes de \mathbf{x} . Se $\mu_{\mathbf{x}} = 0$, $C(k)$ é chamada de função de autocorrelação discreta normalizada.

A matriz de covariância \mathbf{M} de \mathbf{x} , em sua forma Toeplitz [20, p. 26], é computada a partir de (12), levando a

$$\hat{\mathbf{M}} = \begin{bmatrix} C(0) & C(1) & C(2) & \dots & C(K) \\ C(1) & C(0) & C(1) & \dots & C(K-1) \\ C(2) & C(1) & C(0) & \dots & C(K-2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ C(K) & C(K-1) & C(K-2) & \dots & C(0) \end{bmatrix}. \quad (13)$$

Em [21] há diversas rotinas associadas à estimação de parâmetros e à correspondente geração de amostras de ruído α SGN(m). A primeira rotina aqui explorada refere-se à estimação da matriz de covariância normalizada do vetor de amostras do áudio do camarão-de-estalo, $\hat{\mathbf{M}}_n$, assim como dos seus parâmetros α e γ . A partir de $\hat{\mathbf{M}}_n$, pode-se calcular [6] a matriz de covariância do áudio, $\hat{\mathbf{M}}$, como

$$\hat{\mathbf{M}} = \gamma^2 \hat{\mathbf{M}}_n. \quad (14)$$

Destaca-se que a estimação da matriz de covariância realizada pela rotina supracitada se limita às dimensões $(m+1) \times (m+1) = 10 \times 10$, conforme justificado em [21]. Utilizando essa rotina, os parâmetros de impulsividade e escala estimados para o ruído gerado pelo áudio foram $\alpha = 1.53$ e $\gamma = 0.0074$, com a correspondente matriz de covariância normalizada

$$\hat{\mathbf{M}}_n^{\text{áudio}} = \begin{bmatrix} 1 & 0.639 & 0.035 & -0.167 & -0.065 & -0.055 & -0.140 & -0.168 & -0.177 & -0.200 \\ 0.639 & 1 & 0.639 & 0.035 & -0.167 & -0.065 & -0.055 & -0.140 & -0.168 & -0.177 \\ 0.035 & 0.639 & 1 & 0.639 & 0.035 & -0.167 & -0.065 & -0.055 & -0.140 & -0.168 \\ -0.167 & 0.035 & 0.639 & 1 & 0.639 & 0.035 & -0.167 & -0.065 & -0.055 & -0.140 \\ -0.065 & -0.167 & 0.035 & 0.639 & 1 & 0.639 & 0.035 & -0.167 & -0.065 & -0.055 \\ -0.055 & -0.065 & -0.167 & 0.035 & 0.639 & 1 & 0.639 & 0.035 & -0.167 & -0.065 \\ -0.140 & -0.055 & -0.065 & -0.167 & 0.035 & 0.639 & 1 & 0.639 & 0.035 & -0.167 \\ -0.168 & -0.140 & -0.055 & -0.065 & -0.167 & 0.035 & 0.639 & 1 & 0.639 & 0.035 \\ -0.177 & -0.168 & -0.140 & -0.055 & -0.065 & -0.167 & 0.035 & 0.639 & 1 & 0.639 \\ -0.200 & -0.177 & -0.168 & -0.140 & -0.055 & -0.065 & -0.167 & 0.035 & 0.639 & 1 \end{bmatrix}.$$

Tal matriz é idêntica àquela estimada a partir de (12) e (13), o que permite afirmar que o procedimento adotado pela rotina de [21] também faz uso de (12) e (13).

A segunda rotina de [21] aqui explorada gera as amostras α SGN(m) a partir do parâmetro α e de uma matriz de covariância de entrada. Utilizando como entrada a matriz $\hat{\mathbf{M}}_n^{\text{áudio}}$ anteriormente apresentada, gerou-se o ruído α SGN(9). Com esse ruído como entrada da primeira rotina, estimou-se a matriz de covariância $\hat{\mathbf{M}}_n^{\alpha\text{SGN}(9)}$ a seguir, a qual tem elementos com valores muito próximos de $\hat{\mathbf{M}}_n^{\text{áudio}}$, validando, assim, a correta geração do ruído α SGN(m).

$$\hat{M}_n^{\alpha\text{SGN}(9)} = \begin{bmatrix} 1 & 0.648 & 0.046 & -0.179 & -0.092 & -0.063 & -0.127 & -0.158 & -0.184 & -0.218 \\ 0.648 & 1 & 0.648 & 0.046 & -0.179 & -0.092 & -0.063 & -0.127 & -0.158 & -0.184 \\ -0.179 & 0.648 & 1 & 0.648 & 0.046 & -0.179 & -0.092 & -0.063 & -0.127 & -0.158 \\ -0.092 & 0.046 & 0.648 & 1 & 0.648 & 0.046 & -0.179 & -0.092 & -0.063 & -0.127 \\ -0.063 & -0.179 & 0.046 & 0.648 & 1 & 0.648 & 0.046 & -0.179 & -0.092 & -0.063 \\ -0.127 & -0.063 & -0.092 & -0.179 & 0.046 & 0.648 & 1 & 0.648 & 0.046 & -0.179 \\ -0.158 & -0.127 & -0.063 & -0.092 & -0.179 & 0.046 & 0.648 & 1 & 0.648 & 0.046 \\ -0.184 & -0.158 & -0.127 & -0.063 & -0.092 & -0.179 & 0.046 & 0.648 & 1 & 0.648 \\ -0.218 & -0.184 & -0.158 & -0.127 & -0.063 & -0.092 & -0.179 & 0.046 & 0.648 & 1 \end{bmatrix}$$

Para completar a análise estatística referente às matrizes de covariância, amostras do ruído S α SN foram geradas via comando `random` do Matlab, usando como entrada os parâmetros $\alpha = 1.53$ e $\gamma = 0.0074$ já estimados, $\beta = \delta = 0$ e a quantidade de amostras desejadas igual à quantidade de amostras do vetor correspondente ao áudio. Utilizando a primeira rotina de [21], estimou-se a matriz de covariância $\hat{M}_n^{\text{S}\alpha\text{S}}$ dada por

$$\hat{M}_n^{\text{S}\alpha\text{S}} = \begin{bmatrix} 1 & 0 & -0.001 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & -0.001 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.001 & 0 & 1 & 0 & -0.001 & 0 & 0 & 0 & 0 & 0 \\ 0 & -0.001 & 0 & 1 & 0 & -0.001 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.001 & 0 & 1 & 0 & -0.001 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.001 & 0 & 1 & 0 & -0.001 & 0 & 0 \\ 0 & 0 & 0 & 0 & -0.001 & 0 & 1 & 0 & -0.001 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0.001 & 0 & 1 & 0 & -0.001 \\ 0 & 0 & 0 & 0 & 0 & 0 & -0.001 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & -0.001 & 0 & 1 \end{bmatrix}$$

Nota-se que $\hat{M}_n^{\text{S}\alpha\text{S}}$ é muito similar a uma matriz identidade, a qual se refere a uma série temporal com correlação nula entre amostras adjacentes, tal como esperado pela geração do ruído S α SN via comando `random` do Matlab.

Quanto à análise das funções de autocorrelação, a Fig. 1 apresenta tais funções normalizadas, obtidas por meio de (12), para o sinal de áudio gravado do camarão-de-estalo, para o ruído α SGN(9) e para o ruído S α SN. Tais funções estão plotadas até o atraso relativo $k = 20$ para melhor visualização da região de maior relevância, nas proximidades de $k = 0$.

Nas três funções apresentadas na Fig. 1, têm-se $C(0) = 1$. À medida que se aumenta o valor de k , os valores de autocorrelação diminuem, evidenciando que amostras mais distantes entre si são menos correlacionadas. Verifica-se que há grande similaridade entre os valores de $C(k)$ para o ruído α SGN(9) e para o áudio até $k = 10$. Essa similaridade era esperada, sendo que a dissimilaridade se torna mais evidente para $k > 10$, devido ao fato de que a rotina de [21] que gera o ruído α SGN(m) tem memória $m = 9$ como máximo, limitando assim o alcance da matriz de covariância de entrada no que tange à representatividade de toda estrutura de correlação do ruído de referência do áudio.

Também como esperado, a função de autocorrelação das amostras S α SN é praticamente nula para $k \neq 0$, consequência do fato de que amostras adjacentes geradas pelo comando `random` do Matlab são descorrelacionadas temporalmente.

Vale notar que os valores de cada uma das funções de autocorrelação mostradas na Fig. 1 para $k \leq 9$ são iguais aos valores na primeira linha de cada uma das correspondentes matrizes de covariância $\hat{M}_n^{\text{áudio}}$, $\hat{M}_n^{\alpha\text{SGN}(9)}$ e $\hat{M}_n^{\text{S}\alpha\text{S}}$.




Fig. 1: Função de autocorrelação discreta normalizada do áudio e dos ruídos α SGN(9) e S α SN, com um atraso relativo máximo de $k = 20$.

V. DESEMPENHO DO SENSORIAMENTO ESPECTRAL

Nesta seção são apresentados resultados de simulação computacional do CSS na ausência e na presença de ruído impulsivo em termos da curva característica de operação do receptor (*receiver operating characteristic*, ROC) que mostra P_d versus P_{fa} , para os detectores ED, GRCR, GID, PRIDe e LMPIT. Inseriu-se a área sob a curva (*area under the curve*, AUC) ROC como métrica auxiliar. Cada ponto sobre uma ROC foi gerado a partir de 10000 eventos de Monte Carlo, via Matlab.

Considerou-se $s = 1$ PU e $d = 6$ SUs, cada um deles coletando $n = 300$ amostras complexas do sinal recebido em cada intervalo de sensoriamento, sob uma SNR média igual a -11.42 dB. Esse valor de SNR foi ajustado para que o desempenho do melhor detector, na ausência de ruído impulsivo, atingisse $P_{fa} = 0.1$ e $P_d = 0.9$. Para modelar as flutuações da envoltória de um sinal modulado e filtrado o sinal primário é representado por variáveis aleatórias Gaussianas complexas com média zero e variância dependente da SNR média. O fator de Rice do canal de sensoriamento foi considerado como uma variável aleatória Gaussiana de média $\mu_{\kappa} = 1.88$ dB e desvio padrão $\sigma_{\kappa} = 4.13$ dB [1].

A Fig. 2 mostra as ROCs e AUCs na ausência de ruído impulsivo e em três diferentes cenários de presença de tal ruído: sob influência do áudio real do ruído de camarão-de-estalo e sob os ruídos α SGN(9) e S α SN. Verifica-se uma evidente degradação no desempenho do sensoriamento espectral para todos os detectores quando há ruído impulsivo. Nessa situação, o ED apresentou desempenho consideravelmente inferior aos demais detectores, enquanto que o detector PRIDe sofreu a menor degradação.

Ainda que o α SGN(m) não reflita a completa estrutura de correlação do áudio devido à limitação do valor de m , percebe-se boa similaridade entre os desempenhos alcançados por todos os detectores sob ambos os ruídos, como se pode ver nas curvas da Fig 2b e da Fig. 2c e seus valores de AUC associados. Essa importante constatação revela que a correlação temporal do ruído impulsivo tem influência no desempenho do sensoriamento espectral, fato reforçado pela grande dissimilaridade entre os desempenhos sob o ruído S α SN em relação aos correspondentes desempenhos sob o ruído real do camarão-de-estalo e sob o ruído α SGN.

VI. CONCLUSÕES

Este artigo avaliou a adequação das distribuições S α S e α SG na modelagem do ruído de camarão-de-estalo no contexto

REFERÊNCIAS




Fig. 2: P_d versus P_{fa} nos seguintes cenários: ausência de ruído impulsivo (2a), presença de ruído impulsivo real (2b), ruído α SGN(9) (2c) e ruído $S\alpha$ SN (2d).

do sensoriamento espectral em sistemas de comunicação subaquáticos. Os resultados obtidos revelaram que há correlação entre as amostras do ruído de camarão-de-estalo real, o qual pode ser modelado pelo ruído α SGN(m). Entretanto, o valor máximo do parâmetro de memória, $m = 9$, pode ser incapaz de mimetizar a completa estrutura de correlação presente em um ruído real. O ruído $S\alpha$ SN, embora mimetize adequadamente as variações de amplitude do ruído de camarão-de-estalo, apresenta amostras descorrelacionadas e, portanto, não é adequado para modelar esse ruído. Avaliou-se também o desempenho do CSS com fusão de dados na presença de ruído impulsivo, comparando-se os detectores ED, GRCC, GID, PRIDe e LMPIT. Os resultados mostraram que a não modelagem da correlação temporal no $S\alpha$ SN faz com o que o desempenho seja subestimado em relação ao áudio e ao α SGN(m).

AGRADECIMENTOS

Ao Capitão-de-Mar-e-Guerra RM1-T, Marcos Vinícius da Silva Simões, Grupo Acústica Submarina, Marinha do Brasil, ref. Ofício nº 239/IEAPM-MB, e ao Prof. Dr. José Santo Guiscafré Panaro, Universidade Federal Fluminense (UFF-RJ), pela disponibilização dos arquivos de áudio referentes ao ruído de camarão-de-estalo gravado.

- [1] 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.sbrrt.org.br/jcis/article/view/811>
- [2] B. Mishachandar and S. Vairamuthu, "An underwater cognitive acoustic network strategy for efficient spectrum utilization," *Applied Acoustics*, vol. 175, p. 107861, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0003682X2030966X>
- [3] T. Shongwe, A. J. H. Vinck, and H. C. Ferreira, "A study on impulse noise and its models," *SAIEE Africa Research Journal*, vol. 106, no. 3, pp. 119–131, 2015.
- [4] P. Georgiou, P. Tsakalides, and C. Kyriakakis, "Alpha-stable modeling of noise and robust time-delay estimation in the presence of impulsive noise," *IEEE Transactions on Multimedia*, vol. 1, no. 3, pp. 291–301, 1999.
- [5] A. Mahmood and M. Chitre, "Modeling colored impulsive noise by Markov chains and alpha-stable processes," in *OCEANS 2015 - Genova*, 2015, pp. 1–7.
- [6] —, "Optimal and near-optimal detection in bursty impulsive noise," *IEEE Journal of Oceanic Engineering*, vol. 42, no. 3, pp. 639–653, 2017.
- [7] J. V. M. Cardoso, W. J. L. Queiroz, H. Liu, and M. S. Alencar, "On the performance of the energy detector subject to impulsive noise in $\kappa - \mu$, $\alpha - \mu$, and $\eta - \mu$ fading channels," *Tsinghua Science and Technology*, vol. 22, no. 4, pp. 360–367, 2017.
- [8] H. Qu, X. Xu, J. Zhao, F. Yan, and W. Wang, "A robust hyperbolic tangent-based energy detector with Gaussian and non-Gaussian noise environments in cognitive radio system," *IEEE Systems Journal*, vol. 14, no. 3, pp. 3161–3172, 2020.
- [9] H. E. Adardour and S. Kameche, "Identify the primary signal buried under impulsive noise channel in cognitive radio networks using MAF-KF-NPD," in *2018 International Conference on Applied Smart Systems (ICASS)*, 2018, pp. 1–6.
- [10] P. H. C. de Souza, D. A. Guimarães, and G. P. Aquino, "Efficient fusion of spectrum sensing information under parameter uncertainty and impulsive noise," *Journal of Communication and Information Systems*, vol. 33, no. 1, Apr. 2018. [Online]. Available: <https://jcis.sbrrt.org.br/jcis/article/view/494>
- [11] A. Halaki, C. Manohar, S. Gurugopinath, and R. Muralishankar, "Entropy-based spectrum sensing under symmetric alpha stable impulsive noise," in *2019 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET)*, 2019, pp. 140–145.
- [12] L. d. S. Costa and R. A. A. de Souza, "Performance of blind cooperative spectrum sensing under impulsive noise," in *2020 IEEE Latin-American Conference on Communications (LATINCOM)*, 2020, pp. 1–6.
- [13] A. Mehrabian, M. Sabbaghian, and H. Yanikomeroglu, "Spectrum sensing for symmetric α -stable noise model with convolutional neural networks," *IEEE Transactions on Communications*, vol. 69, no. 8, pp. 5121–5135, 2021.
- [14] S. Lee, S. R. Park, Y. H. Kim, and I. Song, "Spectrum sensing for cognitive radio network with multiple receive antennas under impulsive noise environments," *Journal of Communications and Networks*, vol. 23, no. 3, pp. 171–179, 2021.
- [15] M. Shao and C. Nikias, "Signal processing with fractional lower order moments: stable processes and their applications," *Proceedings of the IEEE*, vol. 81, no. 7, pp. 986–1010, 1993.
- [16] D. A. Guimarães, "Robust test statistic for cooperative spectrum sensing based on the Gerschgorin circle theorem," *IEEE Access*, vol. 6, pp. 2445–2456, 2018.
- [17] —, "Gini index inspired robust detector for spectrum sensing over rician channels," *Electronics Letters*, 11 2018.
- [18] —, "Pietra-Ricci index detector for centralized data fusion cooperative spectrum sensing," *IEEE Transactions on Vehicular Technology*, vol. 69, no. 10, pp. 12 354–12 358, 2020.
- [19] D. Ramirez, J. Via, I. Santamaria, and L. L. Scharf, "Locally most powerful invariant tests for correlation and sphericity of gaussian vectors," *IEEE transactions on information theory*, vol. 59, no. 4, pp. 2128–2141, 2013.
- [20] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed., ser. Forecasting and Control Series. Hoboken, New Jersey, USA: Prentice Hall, 2016, doi: 10.1111/jtsa.12194/978-1-118-67502-1.
- [21] A. Mahmood, "The α SGN m toolbox for Matlab," July 2018. [Online]. Available: <https://github.com/ahmd-mahm/alpha-SGNm#the-%CE%B1sgnm-matlab-toolbox>