

Amostragem em redes de difusão adaptativas na presença de ruído impulsivo

Vitor H. Duque, Daniel G. Tiglea e Magno T. M. Silva

Resumo—Neste artigo é proposto um algoritmo de amostragem para redes de difusão adaptativas em ambientes com ruído impulsivo. Baseado no critério da máxima correntropia (*maximum correntropy criterion* – MCC), o algoritmo proposto busca manter os nós amostrados quando o MCC é baixo e deixa de amostrá-los caso contrário, reduzindo significativamente o custo computacional e de memória associados à aprendizagem. As simulações mostram que a solução proposta é mais robusta a ruído impulsivo que algoritmos existentes na literatura em diferentes cenários.

Palavras-Chave—processamento distribuído de sinais, redes de difusão adaptativas, amostragem, critério da máxima correntropia, ruído impulsivo.

Abstract—In this paper, a sampling algorithm is proposed for adaptive diffusion networks in environments with impulsive noise. Based on the maximum correntropy criterion (MCC), the proposed algorithm seeks to maintain the nodes sampled when the MCC is low and to stop sampling them otherwise, thereby significantly reducing the computational and memory costs associated with learning. Simulations show that the proposed solution is more robust to impulsive noise than existing algorithms in the literature in different scenarios.

Keywords—Distributed signal processing, adaptive diffusion networks, sampling, maximum correntropy criterion, impulsive noise.

I. INTRODUÇÃO

As redes de difusão adaptativas se consolidaram como ferramentas para o processamento distribuído de sinais, encontrando relevância em diversos problemas, como robótica de enxame, serviços de computação em nuvem, troca de informações em redes sociais, localização e rastreamento de alvos, sensoriamento espectral em redes móveis, aplicações médicas, entre outros (veja, e.g., [1]–[4] e suas inúmeras referências). Essas redes consistem em um conjunto de agentes que medem e processam localmente dados em tempo real com um objetivo comum, como identificar um sistema desconhecido, por exemplo. Além disso, eles são capazes de se comunicar e cooperar entre si para melhorar o desempenho da rede como um todo [1]–[3].

Na implementação dessas soluções, é desejável reduzir a quantidade de dados medidos, processados e transmitidos através da rede com o objetivo de reduzir o consumo energético e/ou computacional. Dentre as técnicas propostas para reduzir o consumo de energia nessas soluções, destacam-se as técnicas de *censura*, que procuram restringir a transmissão de certos

nós para seus vizinhos [3], [4]. Além disso, quando o custo de medição e processamento dos dados disponíveis em cada nó é proibitivamente elevado, é necessário empregar técnicas de amostragem [5], [6], o que pode reduzir significativamente o custo computacional e de memória associados à aprendizagem.

Para evitar um impacto negativo da amostragem e censura sobre o desempenho da rede, algoritmos foram propostos e analisados em [4], [7]–[9]. Esses algoritmos adaptam localmente o número de nós amostrados de acordo com o erro quadrático médio (*mean squared error* – MSE) da vizinhança de um dado agente. Dessa forma, eles reduzem o custo computacional associado à tarefa de aprendizado quando o MSE é baixo, por exemplo, durante o estado estacionário, e mantêm a amostragem dos nós em outros casos, o que permite uma convergência rápida durante o transitório. No entanto, como o MSE é sensível a *outliers*, é de se esperar que esses algoritmos não funcionem adequadamente na presença de ruído impulsivo [10], [11].

Na literatura de filtragem adaptativa, há algumas soluções para lidar com ruído não gaussiano e impulsivo. Alguns exemplos de algoritmos rejeitam sinais contaminados por ruído impulsivo por meio da estimação de um limite superior para a potência do sinal desejado [12]. Outros exemplos buscam aprender a distribuição do erro [13]. Apesar dessas soluções terem sido amplamente estudadas, este é um tópico que foi pouco explorado no contexto de redes de difusão adaptativas.

A proposta deste trabalho é modificar o algoritmo de amostragem AS-dLMS (*adaptive sampling diffusion least mean square*) de [7] para torná-lo robusto a ruído impulsivo. Para tal, se propõe utilizar o critério da máxima correntropia (*maximum correntropy criterion* – MCC) [14]–[16] como forma de dessensibilizar a rede a elevações abruptas na magnitude do erro em decorrência do ruído impulsivo.

O artigo está organizado da seguinte forma. Na Seção II, é apresentada a formulação do problema de estimação em redes de difusão adaptativas e descrito o modelo do ruído impulsivo utilizado. Na Seção III, o algoritmo AS-dNLMS de [7] é revisitado. Na Seção IV, são apresentadas as modificações propostas para o algoritmo a fim de torná-lo robusto a ambientes impulsivos. Resultados de simulação e as conclusões são apresentados nas Seções V e VI, respectivamente.

Notação. São utilizadas letras em fontes convencionais para escalares e minúsculas em negrito para vetores. Além disso, $(\cdot)^T$ denota transposição, $E\{\cdot\}$ a esperança matemática, $\|\cdot\|$ a norma euclidiana e $N(0, \sigma)$ a distribuição normal com média zero e desvio padrão σ .

II. FORMULAÇÃO DO PROBLEMA

Seja uma rede com V nós e uma topologia pré-definida. Dois nós são considerados vizinhos se eles podem se comunicar. Nesse caso, a vizinhança do nó k é dada pelo conjunto de seus vizinhos, incluindo o próprio nó k , e é denotada por \mathcal{N}_k . A cada iteração, cada nó k tem acesso a um sinal de entrada $u_k(n)$ e a um sinal de referência $d_k(n)$ [1], [17].

Um modelo comumente adotado para o sinal desejado em cada nó k é dado por [1], [17]

$$d_k(n) = \mathbf{u}_k^T(n) \mathbf{w}^o + v_k(n), \quad (1)$$

em que $\mathbf{u}_k(n) = [u_k(n) \ u_k(n-1) \ \dots \ u_k(n-M+1)]^T$ é um vetor regressor de comprimento M , \mathbf{w}^o é um vetor coluna de dimensão M , que representa o sistema que se pretende estimar e $v_k(n)$ é o ruído de medição no nó k com variância $\sigma_{v_k}^2$. O objetivo da rede é estimar \mathbf{w}^o de maneira distribuída resolvendo-se o problema de minimização $\min_{\mathbf{w}} \sum_{k=1}^V \mathbb{E}\{|d_k(n) - \mathbf{u}_k^T(n) \mathbf{w}|^2\}$ [1], [17].

Dentre os algoritmos propostos para esse problema, o *diffusion least-mean-squares* (dLMS) é o mais utilizado [1]. Esse algoritmo é caracterizado por duas equações, conhecidas como as etapas de *adaptação* e de *combinação*. A sequência com que essas etapas são realizadas dá origem a duas abordagens: ATC (*adapt-then-combine*) e CTA (*combine-then-adapt*). Na abordagem ATC, as equações são dadas por [1]

$$\boldsymbol{\psi}_k(n+1) = \mathbf{w}_k(n) + \mu_k \mathbf{u}_k(n) e_k(n) \quad (2a)$$

$$\mathbf{w}_k(n+1) = \sum_{i \in \mathcal{N}_k} c_{ik} \boldsymbol{\psi}_i(n+1), \quad (2b)$$

em que $\boldsymbol{\psi}_k$ e \mathbf{w}_k representam respectivamente as estimativas local e combinada de \mathbf{w}^o no nó k , $e_k(n) = d_k(n) - \mathbf{u}_k^T(n) \mathbf{w}_k(n)$ é o erro de estimação e μ_k é um passo de adaptação. Por fim, $\{c_{ik}\}$ são pesos de combinação que satisfazem $c_{ik} \geq 0$, $\sum_{i \in \mathcal{N}_k} c_{ik} = 1$ e $c_{ik} = 0$ se $i \notin \mathcal{N}_k$ [1], [17]. Possíveis escolhas para $\{c_{ik}\}$ incluem as regras Uniforme, Metropolis e do Grau Relativo, entre outras [1], [3]. Como métrica de desempenho, é comum adotar o desvio quadrático médio da rede (NMSD – *network mean-square deviation*), dado por $\text{NMSD}(n) = \frac{1}{V} \sum_{k=1}^V \mathbb{E}\{\|\mathbf{w}^o - \mathbf{w}_k(n)\|^2\}$. Cabe observar que neste artigo, consideram-se apenas a regra Metropolis e a abordagem ATC nas simulações.

Para finalizar essa seção, descreve-se a seguir o modelo de ruído impulsivo usado para gerar $v_k(n)$ nas simulações. O ruído impulsivo é modelado como um ruído gaussiano de variância várias ordens de grandeza maior que a variância do ruído de fundo com probabilidade de ocorrência p_{imp} [12], [18]. Portanto, para o nó k

$$v_k(n) = v_{g,k}(n) + b_k(n) v_{\text{imp},k}(n), \quad (3)$$

em que $v_{g,k} \sim N(0, \sigma_{g,k})$ e $v_{\text{imp},k} \sim N(0, \sigma_{\text{imp},k})$. Além disso, b_k segue uma distribuição de Bernoulli tal que $P(b_k(n) = 1) = p_{\text{imp}}$. A potência do ruído impulsivo é frequentemente descrita em relação à potência do ruído de fundo $\eta = \sigma_{\text{imp},k}^2 / \sigma_{g,k}^2$ [12], [18].

III. REVISITANDO O ALGORITMO AS-dLMS

O algoritmo AS-dLMS [7] mantém a etapa de combinação inalterada, mas modifica a etapa de adaptação do dLMS ao

multiplicar o termo de correção em cada nó k por uma variável binária $\bar{s}_k(n) \in \{0,1\}$, ou seja,

$$\boldsymbol{\psi}_k(n+1) = \mathbf{w}_k(n) + \bar{s}_k(n) \mu_k \mathbf{u}_k(n) e_k(n). \quad (4)$$

Quando $\bar{s}_k(n) = 1$, a etapa de adaptação é executada como de costume. Porém, quando $\bar{s}_k(n) = 0$, não há necessidade de amostrar $d_k(n)$, nem de calcular $\mathbf{u}_k^T(n) \mathbf{w}_k(n)$ e $e_k(n)$, pois nessas condições (4) se resume a $\boldsymbol{\psi}_k(n+1) = \mathbf{w}_k(n)$. Consequentemente, há uma economia de custo computacional.

Para adaptar $\bar{s}_k(n)$, adota-se uma abordagem inspirada na combinação convexa de filtros adaptativos [19]. Assim, define-se uma variável auxiliar $\alpha_k(n) \in [-\alpha^+, \alpha^+]$, em que α^+ denota o maior valor que $\alpha_k(n)$ pode assumir. Na literatura, usualmente se adota $\alpha^+ = 4$ [19]. Em seguida, define-se a função $\phi[\cdot]$ dada por [7], [19]

$$\phi[\alpha_k(n)] \triangleq \frac{\text{sgm}[\alpha_k(n)] - \text{sgm}[-\alpha^+]}{\text{sgm}[\alpha^+] - \text{sgm}[-\alpha^+]}, \quad (5)$$

em que $\text{sgm}[x] = (1 + e^{-x})^{-1}$ é a função sigmoide. A relação entre $\bar{s}_k(n)$ e $\alpha_k(n)$ é estabelecida fazendo-se $\bar{s}_k(n) = 0$ para $\phi[\alpha_k(n)] < 0,5$ e $\bar{s}_k(n) = 1$ caso contrário. Como $\phi[\cdot]$ cresce monotonicamente com o aumento de $\alpha_k(n)$ no intervalo $[-\alpha^+, \alpha^+]$ e $\phi[0] = 0,5$, essa relação pode ser reescrita como

$$\bar{s}_k(n) = \begin{cases} 1, & \text{se } \alpha_k(n) \geq 0, \\ 0, & \text{c.c.} \end{cases} \quad (6)$$

A fim de tornar a notação mais enxuta, $\phi[\alpha_k(n)]$ será denotado por $\phi_k(n)$. Procura-se então minimizar a seguinte função custo com relação a $\alpha_k(n)$ [7]:

$$J_{\alpha_k}(n) = \phi_k(n) \beta \bar{s}_k(n) + [1 - \phi_k(n)] \sum_{i \in \mathcal{N}_k} c_{ik} e_i^2(n) \quad (7)$$

em que $\beta > 0$ é um parâmetro utilizado para controlar a penalização da amostragem. Interpretando-se $e_i^2(n)$ como uma aproximação instantânea para $\text{MSE}_i(n)$, ou seja, $\widehat{\text{MSE}}_i(n) = e_i^2(n)$, o somatório $\sum_{i \in \mathcal{N}_k} c_{ik} e_i^2(n)$ pode ser entendido como a média dos $\widehat{\text{MSE}}_i(n)$ para $i \in \mathcal{N}_k$, ponderada pelos pesos de combinação c_{ik} . O intuito é que quando o MSE for elevado na vizinhança k , $J_{\alpha_k}(n)$ seja minimizada tornando $\phi_k(n)$ próximo de um, o que leva à amostragem do nó k . O mesmo vale quando o nó k não é amostrado ($\bar{s}_k = 0$), o que assegura que a sua amostragem seja eventualmente restabelecida. Em contrapartida, quando o nó k é amostrado ($\bar{s}_k = 1$) e o MSE é suficientemente pequeno, $J_{\alpha_k}(n)$ é minimizada fazendo-se $\phi_k(n)$ próximo de zero, o que faz com que o nó k deixe de ser amostrado [7].

Adotando-se uma estratégia do tipo gradiente descendente para a minimização de $J_{\alpha_k}(n)$, e levando-se em conta algumas considerações práticas, obtém-se

$$\alpha_k(n+1) = \alpha_k(n) + \mu_s \phi'_k(n) \left[\sum_{i \in \mathcal{N}_k} c_{ik} e_i^2(n) - \beta \bar{s}_k(n) \right], \quad (8)$$

em que $\mu_s > 0$ é um passo de adaptação, $\varepsilon_i(n)$ é a última medida de $e_i(n)$ a que se tem acesso, dada por $\varepsilon_i(n) = \bar{s}_i(n) e_i(n) + [1 - \bar{s}_i(n)] \varepsilon_i(n-1)$, e

$$\phi'_k(n) = \frac{d\phi[\alpha_k(n)]}{d\alpha_k(n)} = \frac{\text{sgm}[\alpha_k(n)] \{1 - \text{sgm}[\alpha_k(n)]\}}{\text{sgm}[\alpha^+] - \text{sgm}[-\alpha^+]}. \quad (9)$$

Nota-se que o algoritmo AS-dLMS requer que cada nó amostrado i transmita $\varepsilon_i^2(n) = e_i^2(n)$ aos seus vizinhos. Entretanto, $\varepsilon_i^2(n)$ pode ser enviado em conjunto com $\psi_i(n)$ de modo a não aumentar o número de transmissões. Quando os parâmetros β e μ_s são adequadamente selecionados, é possível obter um bom desempenho com o AS-dLMS em diversas situações, pois ele tende a manter os nós amostrados enquanto o MSE é elevado, como no transitório, e a deixar de amostrá-los quando este se torna suficientemente pequeno [7]. Porém, como o MSE é sensível a *outliers*, ele se torna uma métrica potencialmente inadequada na presença de ruído impulsivo. Diante disso, na seção seguinte, será proposta uma versão modificada do mecanismo de amostragem do AS-dLMS com o objetivo de torná-lo mais robusto nesse tipo de situação.

IV. O ALGORITMO PROPOSTO

Medidas baseadas em teoria da informação têm sido usadas para adaptação robusta em ambientes com ruídos não gaussianos e de cauda pesada. Uma medida que se destaca é a *correntropia* [16]. A correntropia entre duas variáveis aleatórias é dada por $V(X, Y) = E\{\kappa_\sigma(X - Y)\}$ e uma maneira de estimá-la por realizações das variáveis aleatórias é pela média de N realizações de $\kappa_\sigma(x_i - y_i)$, onde que κ_σ se refere ao kernel gaussiano com largura de banda σ , dado por

$$\kappa_\sigma(x - y) = \exp\left(-\frac{(x - y)^2}{2\sigma^2}\right). \quad (10)$$

A correntropia pode ser vista como uma função de correlação entre duas variáveis aleatórias, além de ser uma medida de similaridade em uma vizinhança determinada por σ . Essa medida localizada é útil na redução dos efeitos de *outliers*, incluindo ruído impulsivo [16].

O MCC é o critério que maximiza a correntropia entre a estimativa $\mathbf{u}^T(n)\mathbf{w}(n)$ e o sinal desejado $d(n)$. Definindo a função custo $CL = 1 - E\{\kappa_\sigma(e(n))\}$ e utilizando o método do gradiente estocástico, foi proposto em [14], [16], [20] um filtro adaptativo robusto a ruído impulsivo com equação de adaptação semelhante à do LMS, dada por

$$\mathbf{w}(n + 1) = \mathbf{w}(n) + \mu\kappa_\sigma(e(n))e(n)\mathbf{u}(n). \quad (11)$$

Diante disso, para lidar com ruído impulsivo nas redes de difusão adaptativas levando-se em conta a amostragem, propõe-se substituir (4) por

$$\psi_k(n + 1) = \mathbf{w}_k(n) + \bar{s}_k(n)\mu_k\kappa_\sigma(e_k(n))\mathbf{u}_k(n)e_k(n). \quad (12)$$

Adequando-se a nomenclatura adotada em [16] ao contexto das redes de difusão adaptativas, o algoritmo formado pela junção da Eq. (12) com (2b) será denotado neste trabalho por “dMCC” (*diffusion* MCC).

A adaptação de α no algoritmo AS-dLMS foi obtida a partir da minimização instantânea do MSE, que, por sua vez, é vulnerável a *outliers*. Quando $b_k(n) = 1$ em (3) e $\eta \gg 1$, o valor de $e_k^2(n)$ se torna elevado e isso afeta a adaptação de α_i , $\forall i \in \mathcal{N}_k$. Isso pode levar a rede a manter ou retomar a amostragem de vários nós. Além disso, como o valor de α_i pode aumentar significativamente devido à ocorrência da parcela impulsiva, é possível que sejam necessárias várias

iterações até que os nós na vizinhança de k deixem de ser amostrados novamente. Diante disso, constata-se que o algoritmo pode, na média, manter mais nós amostrados do que seria necessário.

Para lidar com o problema da amostragem na presença de ruído impulsivo, propõe-se substituir o MSE em (7) por CL, o que leva a

$$J_{CL, \alpha_k}(n) = \phi_k(n)\beta\bar{s}_k(n) + [1 - \phi_k(n)] \sum_{i \in \mathcal{N}_k} c_{ik} [1 - \kappa_\sigma(e_i(n))]. \quad (13)$$

A minimização dessa função custo leva a uma equação de adaptação com estrutura similar à (8), dada por

$$\alpha_k(n + 1) = \alpha_k(n) + \mu_s \phi_k'(n) [1 - \sum_{i \in \mathcal{N}_k} c_{ik} \kappa_\sigma(e_i(n)) - \beta\bar{s}_k(n)]. \quad (14)$$

O mecanismo de amostragem descrito pela Eq. (14) será denotado por RAS (*robust adaptive sampling*). Em particular, utilizando-se (12) e (14) obtém-se o algoritmo denominado RAS-dMCC. Com ele, espera-se mitigar os efeitos do ambiente com ruído impulsivo tanto na adaptação dos nós quanto na amostragem.

V. RESULTADOS DE SIMULAÇÃO

Os resultados apresentados a seguir foram obtidos a partir de uma média de 100 realizações. Considerou-se um vetor \mathbf{w}^o com $M = 30$ coeficientes gerados aleatoriamente segundo uma distribuição uniforme no intervalo $[-1, 1]$. Em seguida, o vetor foi normalizado de modo a apresentar $\|\mathbf{w}^o\| = 1$. A rede de difusão adaptativa foi gerada conforme [9] com $V = 20$ nós. A variância do ruído de fundo $\sigma_{g,k}$ de cada nó é amostrada de uma distribuição uniforme entre $[0,001, 0,01]$. Os algoritmos executados pelos agentes em todos os casos usam $\mu = 0,1$. Além disso, os algoritmos de amostragem adaptativa usam $\beta = 0,0285$ e $\mu_s = 57,47$. A largura de banda do kernel gaussiano é $\sigma^2 = 0,5$. Esses valores foram escolhidos de modo a obter um bom desempenho, mantendo-se poucos nós amostrados em regime permanente.

Na Figura 1(a), apresenta-se o NMSD obtido com quatro soluções diferentes: os algoritmos dLMS e dMCC com todos os $V = 20$ nós amostrados, bem como os algoritmos AS-dMCC e RAS-dMCC. É possível constatar que, nestas circunstâncias, o dLMS converge para um patamar de aproximadamente 10 dB de NMSD em regime permanente, ao contrário das técnicas baseadas em MCC, que alcançam aproximadamente -35 dB. Isso mostra que uma estratégia do tipo LMS é inadequada para a adaptação das estimativas locais em cenários com a presença significativa de ruído impulsivo, como esperado. Por sua vez, as abordagens que utilizam uma adaptação do tipo MCC apresentam desempenho semelhante entre si, o que decorre do fato de que os algoritmos AS-dMCC e RAS-dMCC mantêm a amostragem dos nós durante o transitório, preservando a taxa de convergência do dMCC. Além disso, é possível observar uma ligeira redução no valor do NMSD. Uma análise teórica realizada em [4], [9] mostrou que este fenômeno é esperado em situações como a considerada nessa simulação. Na Figura 1(b), é apresentado o número médio de nós amostrados ao longo das iterações. É possível observar nessa figura que o algoritmo AS-dMCC amostra, em média,

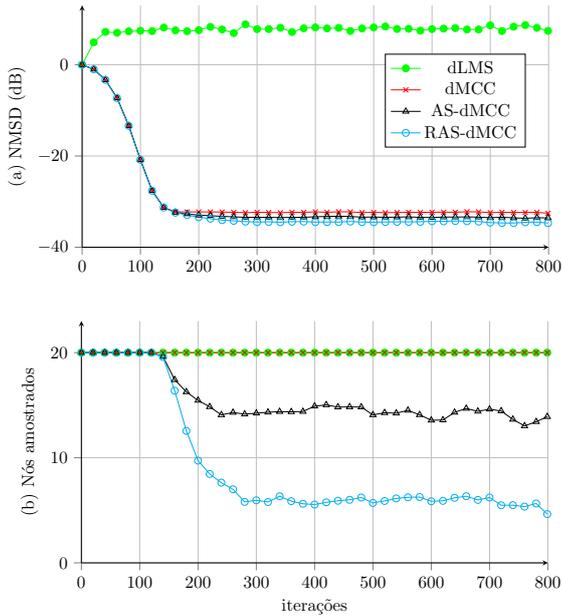


Fig. 1. (a) NMSD e (b) número médio de nós amostrados ao longo das iterações. O ruído impulsivo tem como características $p_{imp} = 0,01$ e $\eta = 10^6$.

aproximadamente 15 nós por iteração em regime permanente, ao passo que o RAS-dMCC mantém aproximadamente 6 nós amostrados por iteração na média. Este resultado está de acordo com a avaliação feita na Seção IV de que um mecanismo adaptativo de amostragem baseado em MSE deve manter mais nós amostrados por iteração do que seria necessário em um cenário na presença de ruído impulsivo. Em contrapartida, os resultados apontam para uma maior robustez por parte do algoritmo RAS-dMCC nestas condições.

Nas simulações das Figuras 2(a) e 2(b), repetiram-se os experimentos das Figuras 1(a) e 1(b), mas na metade de cada realização inverteu-se a ordem dos coeficientes de \mathbf{w}^o para simular uma mudança abrupta no ambiente. Na Figura 2(a), é mostrado o NMSD e na Figura 2(b), o número de nós amostrados por iteração. É possível constatar que os algoritmos dMCC, AS-dMCC e RAS-dMCC apresentam desempenhos semelhantes em termos de NMSD, sendo que novamente a amostragem de menos nós levou a um nível ligeiramente menor de NMSD em regime permanente. Além disso, percebe-se que os três algoritmos são capazes de reagir à mudança abrupta e rastrear as alterações no vetor \mathbf{w}^o . Em particular, o AS-dMCC e o RAS-dMCC apresentam a mesma taxa de convergência que o dMCC tanto durante o transitório inicial como logo após a mudança abrupta. Analisando-se a Figura 2(b), é possível perceber que isso se deve ao fato de que ambos os algoritmos retomam a amostragem de todos os nós após detectarem a alteração no ambiente. É interessante notar que o RAS-dMCC amostra menos nós por iteração na média em comparação com o AS-dMCC, uma vez que é mais robusto aos picos que ocorrem no erro quadrático em função do ruído impulsivo, mas mantém a sensibilidade a alterações no vetor \mathbf{w}^o , o que é desejável para manter a rastreabilidade.

A fim de verificar o efeito da probabilidade de ocorrência do ruído impulsivo sobre o comportamento dos algoritmos

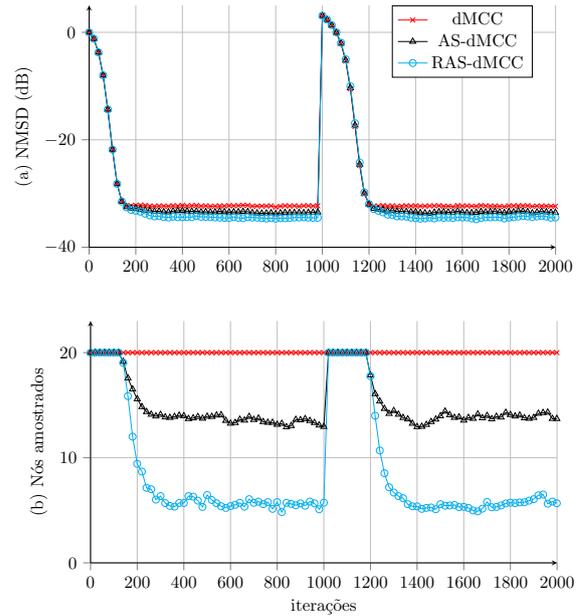


Fig. 2. (a) NMSD e (b) número médio de nós amostrados ao longo das iterações. Para simular uma mudança abrupta no ambiente, na metade de cada realização inverteu-se a ordem dos coeficientes de \mathbf{w}^o . O ruído impulsivo tem como características $p_{imp} = 0,01$ e $\eta = 10^6$.

AS-dLMS, dMCC, AS-dMCC e RAS-dMCC em regime permanente, eles foram testados em simulações considerando-se diferentes valores de p_{imp} no intervalo $[0, 0,05]$. O NMSD e o número médio de nós amostrados por iteração são mostrados nas Figuras 3(a) e 3(b), respectivamente. Nessas simulações, considerou-se um vetor \mathbf{w}^o com $M = 10$ coeficientes e $\eta = 10^6$. Consta-se que quando não há ruído impulsivo, ou seja, $p_{imp} = 0$, todos os algoritmos alcançam um patamar próximo a -35 dB. Nessas circunstâncias, o dMCC apresenta um NMSD ligeiramente maior do que o das outras soluções, o que pode ser atribuído ao efeito da amostragem como mostrado em [4], [9]. Conforme p_{imp} aumenta, o desempenho do AS-dLMS se deteriora perceptivelmente, enquanto os outros se mantêm em patamares próximos a -32 dB. Na Figura 3(b), é possível notar que o aumento de p_{imp} leva à amostragem de mais nós tanto pelo AS-dMCC quanto pelo RAS-dMCC. Porém, o segundo mantém menos nós amostrados até $p_{imp} = 0,03$. A partir dessa probabilidade, o ambiente se torna tão ruidoso que todos os nós são utilizados. Esse comportamento é condizente com as simulações anteriores e avaliação da Seção IV.

Nas simulações da Figura 4, fixou-se $p_{imp} = 0,01$ e consideraram-se diferentes valores de $\eta \in [10^2, 10^8]$. Os valores de NMSD e o número médio de nós amostrados em regime permanente são exibidos para os algoritmos dMCC, AS-dMCC e RAS-dMCC nas Figuras 4(a) e (b), respectivamente. Como os três algoritmos em questão são apropriados para lidar com ruídos impulsivos, o NMSD se mantém num patamar inferior a -32 dB em todos os casos. Entretanto, em decorrência da amostragem, o RAS-dMCC apresenta níveis ligeiramente menores de NMSD em comparação com as outras soluções. A Figura 4(b) também mostra que o RAS-dMCC leva à amostragem de, na média, 8 nós a menos por iteração em comparação com o AS-dMCC para valores elevados de η . É

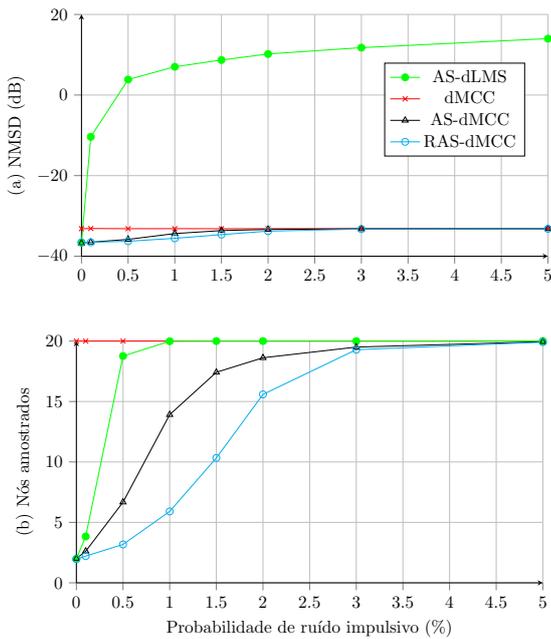


Fig. 3. (a) NMSD e (b) número médio de nós amostrados por probabilidades de ruído impulsivo. Utilizou-se $\eta = 10^6$ e $p_{\text{imp}} \in [0, 0,05]$.

interessante notar que os algoritmos em questão se mostraram menos sensíveis ao valor de η do que ao da probabilidade p_{imp} . Isso pode ser atribuído ao fato da função custo baseada no MCC ser limitada, o que leva a uma saturação no efeito da potência do ruído impulsivo.

VI. CONCLUSÕES

Neste trabalho, foi proposto um algoritmo para redes de difusão adaptativas que é robusto à presença de ruído impulsivo. Ele incorpora um mecanismo adaptativo de amostragem dos nós que é também pouco sensível à ocorrência desse tipo de ruído, mas que pode responder adequadamente a mudanças abruptas no ambiente. Simulações computacionais indicam o bom desempenho das técnicas propostas em situações em que algoritmos menos robustos apresentam comportamento insatisfatório. Vale ressaltar que o algoritmo proposto foi testado considerando-se diferentes probabilidades de ocorrência e diferentes níveis de potência de ruído impulsivo. Os resultados indicam um desempenho satisfatório em diferentes situações. Em trabalhos futuros, pretende-se testar o algoritmo proposto em outros cenários de simulação e analisá-lo teoricamente para selecionar melhor seus parâmetros.

REFERÊNCIAS

- [1] A. H. Sayed, *Adaptation, Learning, and Optimization over Networks*, vol. 7, Fdns. and Trends in Machine Learning, now Publishers, 2014.
- [2] S. Vlaski, S. Kar, A. H. Sayed, and J. M. F. Moura, "Networked signal and information processing: Learning by multiagent systems," *IEEE Signal Process. Mag.*, vol. 40, pp. 92–105, 2023.
- [3] D. G. Tiglea, R. Candido, and M. T. M. Silva, "Adaptive diffusion networks: An overview," *Signal Process.*, vol. 223, pp. 109570, 2024.
- [4] D. G. Tiglea, *Can adaptive diffusion networks do better with less data?*, Tese de Doutorado, Escola Politécnica da USP, São Paulo, 2024.
- [5] P. Di Lorenzo, P. Banelli, E. Isufi, S. Barbarossa, and G. Leus, "Adaptive graph signal processing: Algorithms and optimal sampling strategies," *IEEE Trans. Signal Process.*, vol. 66, pp. 3584–3598, 2018.
- [6] P. Di Lorenzo, P. Banelli, S. Barbarossa, and S. Sardellitti, "Distributed adaptive learning of graph signals," *IEEE Trans. Signal Process.*, vol. 65, pp. 4193–4208, 2017.

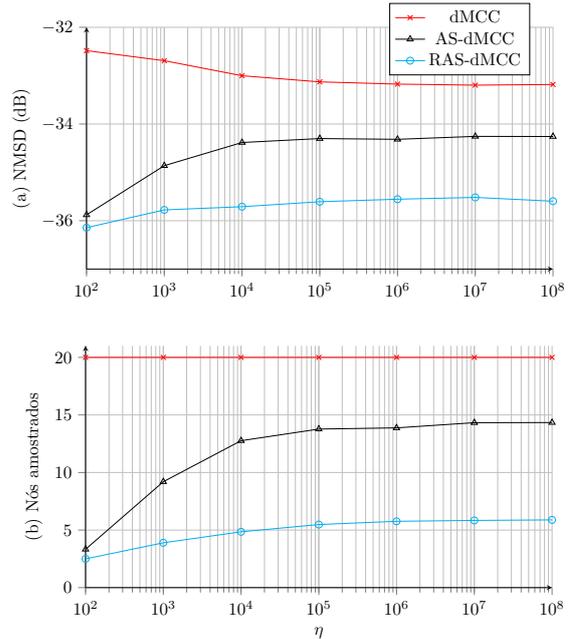


Fig. 4. (a) NMSD e (b) número médio de nós amostrados por η . Utilizou-se $p_{\text{imp}} = 0,01$ e $\eta \in [10^2, 10^8]$.

- [7] D. G. Tiglea, R. Candido, and M. T. M. Silva, "A low-cost algorithm for adaptive sampling and censoring in diffusion networks," *IEEE Trans. Signal Process.*, vol. 69, pp. 58–72, Jan. 2021.
- [8] D. G. Tiglea, R. Candido, and M. T. M. Silva, "An adaptive algorithm for sampling over diffusion networks with dynamic parameter tuning and change detection mechanisms," *Digital Signal Process.*, vol. 127, pp. 103587, 2022.
- [9] D. G. Tiglea, R. Candido, and M. T. M. Silva, "Can adaptive diffusion networks do better with less data?," in *19th Int. Symp. Wireless Commun. Syst. (ISWCS)*, 2024.
- [10] M. P. Shinde and S. N. Gupta, "A model of HF impulsive atmospheric noise," *IEEE Trans. Electromagn. Compat.*, vol. EMC-16, pp. 71–75, 1974.
- [11] T. K. Blankenship, D. M. Kriztman, and T. S. Rappaport, "Measurements and simulation of radio frequency impulsive noise in hospitals and clinics," in *IEEE 47th Veh. Technol. Conf.*, 1997, vol. 3, pp. 1942–1946.
- [12] J. Jeong and S. Kim, "Robust adaptive filter algorithms against impulsive noise," *Circuits, Syst., and Signal Process.*, vol. 38, 2019.
- [13] S. Al-Sayed, A. M. Zoubir, and Ali H. Sayed, "Robust adaptation in impulsive noise," *IEEE Trans. Signal Process.*, vol. 64, pp. 2851–2865, 2016.
- [14] B. Chen, L. Xing, J. Liang, N. Zheng, and J. C. Principe, "Steady-state mean-square error analysis for adaptive filtering under the maximum correntropy criterion," *IEEE Signal Process. Lett.*, vol. 21, pp. 880–884, 2014.
- [15] L. Zhu, C. Song, L. Pan, and J. Li, "Adaptive filtering under the maximum correntropy criterion with variable center," *IEEE Access*, vol. 7, 2019.
- [16] A. Singh and J. C. Principe, "Using correntropy as a cost function in linear adaptive filters," in *Int. Joint Conf. Neural Netw.*, 2009, pp. 2950–2955.
- [17] A. H. Sayed, "Diffusion adaptation over networks," in *Academic Press Library in Signal Process.: array and statistical signal processing*, R. Chellappa and S. Theodoridis, Eds., vol. 3, chapter 9, pp. 323–456. Academic Press, 2014.
- [18] A. Wilson, T. Panigrahi, and A. Dubey, "Robust distributed Lorentzian adaptive filter with diffusion strategy in impulsive noise environment," *Digital Signal Process.*, vol. 96, pp. 102589, 2019.
- [19] M. Lázaro-Gredilla, L. A. Azpicueta-Ruiz, A. R. Figueiras-Vidal, and J. Arenas-Garcia, "Adaptively biasing the weights of adaptive filters," *IEEE Trans. Signal Process.*, vol. 58, pp. 3890–3895, 2010.
- [20] D. Commiello and J. C. Principe, Eds., *Adaptive Learning Methods for Nonlinear System Modeling*, Butterworth-Heinemann, 2018.