

# Algoritmo Set-Membership CMA no modo Difusão Aplicado a Redes de Sensores

Fábio F. de Assis e Aline Neves

**Resumo**— Este artigo combina o chamado Algoritmo do Módulo Constante no modo Difusão (CMAD), que é uma técnica de filtragem adaptativa aplicável a redes de sensores em que os nós trabalham sem sinal de referência, com o conceito de Set-Membership (SM), no contexto de filtragem adaptativa autodidata, aplicado em redes de sensores. Como resultado, surge o Algoritmo Set-Membership CMA no modo Difusão (SM-CMAD) proposto e que é comparado via simulação com o algoritmo CMAD. O SM-CMAD tem como propósito reduzir o custo computacional principalmente em aplicações de tempo real. Os resultados são interessantes e mostram vantagens da proposta sobre o CMAD, anteriormente apresentado.

**Palavras-Chave**—Filtragem Adaptativa Autodidata, Algoritmo do Módulo Constante no modo Difusão (CMAD), Algoritmo Set-Membership (SM), Rede de Sensores Sem Fio.

**Abstract**— This article combines the so-called Diffusion Constant Modulus Algorithm (CMAD), which is an adaptive filtering technique applicable to sensor networks in which nodes work without a reference signal, with the concept of Set-Membership (SM), in the context of blind adaptive filtering, applied in sensor networks. As a result, the Diffusion Set-Membership CMA (SM-CMAD) arises and is compared via simulation with the CMAD algorithm. The purpose of SM-CMAD is to reduce computational cost mainly in real-time applications. The results are interesting and show advantages of the proposed technique over CMAD, previously introduced.

**Keywords**—Blind Adaptive Filtering, Diffusion Constant Modulus Algorithm (DCMA), Set-membership Algorithm (SM), Wireless Sensor Network.

## I. INTRODUÇÃO

Há muitos anos a sociedade utiliza tecnologias que exigem recursos de alto desempenho e complexidade computacional. Este fato associado às inúmeras descobertas na área de ciências e tecnologia, culminou na busca por soluções cada vez mais eficientes principalmente em aplicações que fazem uso de redes de sensores. As aplicações de tais redes ocorrem em diversos contextos, como comunicação e localização de objetos, além de inúmeras aplicações específicas em áreas como ambiental, agrícola, aviação, militar, médica, dentre outras.

Neste trabalho, abordaremos o problema de filtragem adaptativa dentro do contexto de redes de sensores sem fio. No contexto de técnicas supervisionadas, diversos algoritmos foram propostos e analisados na literatura [1, 2, 3, 4, 5, 6]. Neste contexto, o algoritmo mais utilizado é o *Least Mean Squares*

(LMS). Em [1], foram apresentadas as estratégias *Adapt-then-Combine* (ATC) e *Combine-then-Adapt* (CTA), focadas em soluções adaptativas baseadas no algoritmo LMS em modo difusão. Em [2], foi utilizada a técnica *set-membership* (SM) em conjunto com o LMS, para analisar o desempenho de uma rede de sensores onde os nós possuem diferentes potências de ruído. Estes algoritmos possuem a grande vantagem de economizar energia, recurso crucial dentro do contexto de redes de sensores sem fio. Dentro deste contexto, os nós da rede só trocam informação se esta for relevante para o nó em questão. Estudos anteriores mostram que, mesmo não havendo troca de informação em todas as iterações, os algoritmos apresentam desempenhos similares às suas versões clássicas, mantendo inclusive velocidades de convergência similares.

No contexto não supervisionado, também conhecido como técnicas autodidatas ou cegas, poucos trabalhos podem ser encontrados. R. Abdolee e B. Champagne [7], foram os pioneiros neste contexto, adaptando o algoritmo do módulo constante (CMA) para o contexto de redes de sensores, mas ficando restrito ao caso de redes com topologia em anel. Em [8], tal técnica foi estendida para redes com qualquer topologia. O algoritmo foi chamado de algoritmo do módulo constante no modo difusão (CMAD). Tal trabalho considera que todos os nós têm capacidade de processar a informação recebida e os nós vizinhos trocam informações entre si. Em [8], foi mostrado que o desempenho do algoritmo depende da matriz de combinação sendo utilizada, diferentemente de algoritmos supervisionados [3]. Além disso, dependendo da topologia da rede e inicialização dos nós, a cooperação entre os nós permite que se consiga convergir para boas soluções mesmo que alguns nós tenham inicializações ruins, ganhando certa robustez contra convergências para mínimos locais.

O algoritmo set-membership CMA, foi primeiramente proposto por S. Gollamudi, S. Nagaraj e Y.F. Huang em [10], em um contexto cego. Outros trabalhos também estudaram tal técnica no contexto semi-cego com bons resultados como [11, 12]. Contudo não foram encontrados trabalhos no contexto de redes de sensores no modo difusão.

Com o intuito de explorar as vantagens das técnicas *set-membership* dentro do contexto autodidata no modo difusão, este trabalho propõe utilizar tal técnica, em conjunto com o algoritmo do módulo constante no modo difusão (CMAD) proposto em [8].

Assim, considerando os resultados já obtidos em [8], analisamos o algoritmo proposto levando em conta os possíveis efeitos da matriz de combinação no desempenho do algoritmo e comparamos o resultado obtido com o CMAD. Avaliamos

Fábio Ferreira de Assis e Aline Neves, estão no Centro de Engenharia e Modelagem, Universidade Federal do ABC (UFABC), Santo André-SP, Brasil, e-mails: fabio.assis@ufabc.edu.br, aline.neves@ufabc.edu.br

também os efeitos dos parâmetros do algoritmo no seu desempenho.

A organização deste artigo segue da seguinte forma. Seção II contempla o modelo de rede e definições do sistema utilizado neste trabalho. Na Seção III descrevemos o algoritmo CMA no modo difusão, seguido da Seção IV que descreve o algoritmo *Set-membership*. A combinação dos dois algoritmos é apresentada na Seção V. Por fim a Seção VI apresenta e discute os resultados das simulações seguida das conclusões que são apresentadas na Seção VII.

## II. MODELO DO SISTEMA

O modelo de rede adotado opera em modo difusão com estrutura distribuída homogênea e estática baseado em [7, 8]. Consideraremos que a topologia não varia no tempo, todos os nós têm poder de processamento local e trocam informações com seus nós vizinhos adjacentes, ou seja, cada nó  $k$  só se comunica com os nós vizinhos diretamente conectados a ele. O objetivo é equalizar o canal desconhecido, recuperando o sinal transmitido  $s(i)$ , sem a necessidade de transmitir um sinal de referência junto com o sinal de interesse. No problema de equalização em redes de sensores, cada nó irá possuir um filtro adaptativo que é usado para reverter as distorções introduzidas por um canal de comunicação qualquer. O sistema em estudo será modelado por um filtro FIR.

Seguindo o modelo em [8], o sinal recebido por cada nó  $k$  é dado por:

$$u_k(i) = \sum_{m=0}^q e^{j\theta_k} h_m s(i-m) + v_k(i) \quad (1)$$

onde  $u_k(i)$  é o sinal recebido,  $h_m$  com  $m = \{0, \dots, q-1\}$ , corresponde os coeficientes de resposta ao impulso finita do canal,  $v_k(i)$  é o ruído branco e Gaussiano do  $k$ -ésimo nó. O deslocamento de fase do sinal recebido por cada nó é dado por  $\theta_k$ , variável aleatória independente e identicamente distribuída entre  $[0, 2\pi]$ .

A Fig. 1 representa a topologia de rede utilizada nos cenários de simulação deste artigo. Tal rede foi desenhada de modo a ter nós com muitos vizinhos e nós com poucos vizinhos adjacentes conectados entre si. Desta forma é possível verificar as vantagens da cooperação entre os nós.

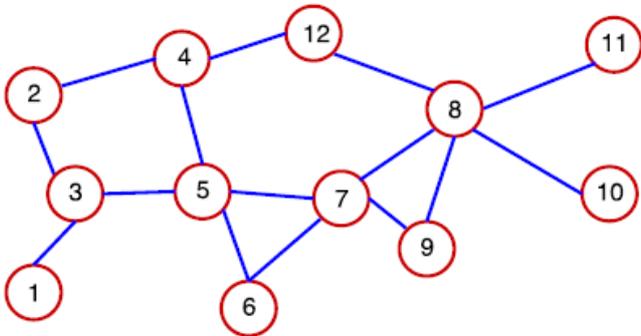


Fig. 1. Rede com 12 nós aleatório no modo difusão.

A topologia da rede é mapeada nos algoritmos estudados através do uso de matrizes de combinação [8]. Várias regras

podem ser empregadas para definir esta matriz. A matriz de combinação tem a função de informar a topologia da rede para o algoritmo, coletando a informação de como os nós estão conectados entre si. Tal matriz é de ordem  $N$  quadrada, onde  $N$  é o número de nós da rede. A matriz deve sempre satisfazer a propriedade de que o somatório dos coeficientes referentes a cada nó seja igual a 1, ou seja, os valores de cada linha da matriz devem ter seu somatório igual a 1.

Podemos representar a vizinhança do nó  $k$  simplesmente por  $\mathcal{N}_k$ . O grau do nó é representado por  $n_k$ , e é definido como o conjunto de todos os nós que estão conectados ao nó  $k$ , incluindo ele próprio.

Diversas técnicas permitem realizar este mapeamento [8]:

- Regra de Metropolis - *Metropolis Rule* (MR).

$$c_{kl} = \begin{cases} \frac{1}{\max\{n_k, n_l\}}, & l \in \mathcal{N}_k \\ 1 - \sum_{l \in \mathcal{N}_k, l \neq k} c_{kl}, & k = l \\ 0, & c. c. \end{cases} \quad (2)$$

$n_k$  e  $n_l$  representam os graus do  $k$ -ésimo e  $l$ -ésimo nós, respectivamente

- Regra de Laplace - *Laplacian Rule* (LR).

$$C = I_N - \gamma \mathcal{L}, \quad (3)$$

onde  $I_N$  é a matriz identidade de ordem  $N$ ,  $\gamma = 1/n_{max}$  e  $\mathcal{L} = D - A$ , com  $D$  sendo a matriz diagonal formada pelos graus dos nós de 1 a  $N$  e  $A$  representa a matriz adjacente de ordem  $N \times N$

$$[A]_{kl} = \begin{cases} 1, & l \in \mathcal{N}_k \\ 0, & c. c. \end{cases} \quad (4)$$

- Regra do Grau Máximo - *Maximum Degree Rule* (MD).

$$c_{kl} = \begin{cases} \frac{1}{N}, & l \in \mathcal{N}_k \\ 1 - \sum_{l \in \mathcal{N}_k, l \neq k} c_{kl}, & k = l \\ 0, & c. c. \end{cases} \quad (5)$$

- Regra do Vizinho Mais Próximo - *Nearest Neighbor Rule* (NN).

$$c_{kl} = \begin{cases} \frac{1}{n_k}, & l \in \mathcal{N}_k \\ 0, & c. c. \end{cases} \quad (6)$$

- Regra do Grau Relativo - *Relative Degree Rule* (RD).

$$c_{kl} = \begin{cases} \frac{n_l}{\sum_{m \in \mathcal{N}_k} n_m}, & l \in \mathcal{N}_k \\ 0, & c. c. \end{cases} \quad (7)$$

É interessante notar que, dependendo da topologia e tamanho da rede, tais regras influem no desempenho dos métodos baseado no algoritmo do módulo constante no modo difusão (CMAD) [8, 9].

### III. ALGORITMO CMA EM DIFUSÃO

O algoritmo do módulo constante no modo difusão (CMAD) foi proposto inicialmente em [8]. Os coeficientes do filtro adaptativo existente em cada nó serão denotados por  $\boldsymbol{\psi}_k = [\psi_{k0} \psi_{k1} \dots \psi_{kL-1}]$  também chamados de estimativa local. Além disso cada nó obtém uma estimativa agregada a partir da fusão das estimativas locais dos nós da rede com seus vizinhos:

$$\boldsymbol{\phi}_k(i) = f_k(\boldsymbol{\psi}_l(i)) \quad l \in \mathcal{N}_k, \quad (8)$$

onde  $f_k$  é chamada de função de combinação. Aqui será usado combinação linear. Desta forma podemos representar  $\boldsymbol{\phi}_k(i)$  por:

$$\boldsymbol{\phi}_k(i) = \sum_{l \in \mathcal{N}_k} c_{kl} \boldsymbol{\psi}_l(i), \quad (9)$$

onde os coeficientes  $c_{kl}$  vem da matriz de combinação  $C$ , que possui as informações sobre o mapeamento da topologia da rede.

A saída do equalizador  $y$  no nó  $k$  é obtida pela seguinte expressão:

$$y_k(i) = \boldsymbol{\phi}_k(i) \mathbf{u}_k^T(i), \quad (10)$$

onde  $\mathbf{u}_k(i) = [u_k(i) \ u_k(i-1) \ \dots \ u_k(i-L+1)]$ .

Tendo como base o critério do módulo constante, o erro é calculado por:

$$e_k(i) = y_k(i)(R_2 - |y_k(i)|^2), \quad (11)$$

onde  $R_2$  é baseado nas características estatísticas do sinal de entrada, dado pela seguinte relação:

$$R_2 = \frac{E\{|s(i)|^4\}}{E\{|s(i)|^2\}} \quad (12)$$

Por fim, os pesos do equalizador do nó  $k$  serão atualizados, levando em conta que estes utilizam a estimativa agregada  $\boldsymbol{\phi}_k(i)$  que é obtida a partir da troca de informações com os nós vizinhos. A adaptação dos coeficientes é realizada da seguinte forma:

$$\boldsymbol{\psi}_k(i+1) = \boldsymbol{\phi}_k(i) + \mu e_k(i) \mathbf{u}_k(i) \quad (13)$$

Uma grande vantagem desta técnica é que a falha de um nó não compromete o funcionamento do algoritmo, pois os outros nós são capazes de processar o algoritmo e continuar compartilhando suas informações. Contudo, o desempenho da rede pode ser comprometido dependendo da topologia e do nó que falhar.

Uma proposta que será apresentada na próxima Seção define uma solução para reduzir a troca de informação desnecessária na rede, usando a ideia dos métodos *set-membership*.

### IV. ALGORITMO SET-MEMBERSHIP

A estratégia que torna os algoritmos da família *set-membership* referência em filtragem adaptativa é o fato de que, em suas soluções, todos os elementos do conjunto viável - (do

inglês *feasible set*) são considerados como possíveis soluções do algoritmo [2]. Portanto as taxas de atualização destes algoritmos são menores do que nos algoritmos adaptativos clássicos. Em redes de sensores tal fato tem impactos diretos como menor consumo de energia e menos trocas de informações desnecessárias entre os nós.

O intuito em uma rede de sensores distribuída com processamento local eficiente é que um nó sensor só transmita informação na rede caso esta informação seja diferente da última transmitida e seja útil para o seu vizinho, evitando fluxo desnecessário de dados.

As técnicas *set-membership* são baseadas na proposta de um limiar para o erro, de forma que só existe atualização dos coeficientes do equalizador se o erro calculado for maior do que este limiar denotado por  $\bar{\gamma}_k$ . Em [2] tal operação é realizada considerando-se:

$$\mu_k(i) = \begin{cases} 0, & |e_k(i)| < \bar{\gamma}_k \\ \bar{\mu} \left(1 - \frac{\bar{\gamma}_k}{|e_k(i)|}\right) & c. c., \end{cases} \quad (14)$$

onde  $\mu_k(i)$  representa o passo de adaptação na iteração  $i$  e  $\bar{\mu}$  representa o passo médio de adaptação. Assumindo que o erro de equalização possua probabilidade aproximadamente gaussiana, e considerando que a probabilidade de atualização depende da variância do ruído, considerou-se o limiar conforme sugerido em [2], dado pela seguinte expressão:

$$\bar{\gamma}_k = (\tau \sigma_{\eta,k}^2)^m, \text{ com } m > 0.5, \quad (15)$$

onde  $\sigma_{\eta,k}^2$  é a variância do erro no  $k$ -ésimo e  $\tau$  é uma constante positiva.

A análise feita em [2] mostra como escolher o limiar de adaptação na técnica *Set-membership Least Mean Squares* (SM-LMS). Tal proposta apresenta vantagens em relação ao algoritmo clássico LMS, principalmente nos casos onde existe diferentes potências de ruído entre os nós.

### V. ALGORITMO SM-CMAD

O algoritmo *set-membership* combinado com o algoritmo CMA no modo difusão, pode ser compreendido como um algoritmo de passo dinâmico e aqui será denotado como Algoritmo *Set-membership* - CMA no modo Difusão (SM-CMAD). Utilizando (13) e (14), podemos definir o algoritmo conforme Tabela 1.

TABELA I. ALGORITMO PROPOSTO SM-CMAD

Algoritmo SM-CMAD
$y_k(i) = \boldsymbol{\phi}_k(i) \mathbf{u}_k^T(i)$
$\boldsymbol{\phi}_k(i) = \sum_{l \in \mathcal{N}_k} c_{kl} \boldsymbol{\psi}_l(i)$
$e_k(i) = y_k(i)(R_2 -  y_k(i) ^2)$
$\bar{\gamma}_k = (\tau \sigma_{\eta,k}^2)^m, \text{ com } m > 0.5$
$\mu_k(i) = \begin{cases} 0, &  e_k(i)  < \bar{\gamma}_k \\ \bar{\mu} \left(1 - \frac{\bar{\gamma}_k}{ e_k(i) }\right) & c. c., \end{cases}$
$\boldsymbol{\psi}_k(i+1) = \boldsymbol{\phi}_k(i) + \mu_k(i) e_k(i) \mathbf{u}_k(i)$

Em seguida, analisaremos o desempenho do algoritmo SM-CMAD em vários cenários e utilizando diversas matrizes de combinação comparando os resultados com o algoritmo CMAD.

## VI. SIMULAÇÕES DO SISTEMA

As simulações foram realizadas no seguinte contexto: o sinal de entrada é *Binary Phase Shift Keying* (BPSK), a rede possui  $N = 12$  nós, topologia aleatória, seguindo o modelo da Fig. 1. Foi considerado a média de 100 simulações. A inicialização dos coeficientes do equalizador segue a estratégia “center spike”, ou seja,  $\psi_k = [0, \dots, 1, \dots, 0]$ , para  $k = 1, \dots, L$ , onde  $L$  é o tamanho do equalizador. Foram testadas todas as matrizes de combinação citadas na Seção II. A medida de desempenho utilizada em todos os cenários de simulação foi à Interferência Intersimbólica média (IIS), expressa na equação abaixo:

$$IIS(i) = \frac{1}{N} \sum_{k=1}^N \frac{\sum_m |\alpha_{k_m}(i)|^2 - |\alpha_k(i)|_{max}^2}{|\alpha_k(i)|_{max}^2}, \quad (16)$$

sendo  $\alpha_k(i) = h * \phi_k(i)$ , o símbolo  $*$  representa a operação de convolução,  $h$  representa a resposta ao impulso do canal e  $\phi_k$  é a estimativa agregada definida em (9).

**Cenário de simulação 1:** O canal utilizado foi  $h = [1 \ 0.5 \ 0.2]$ , incluindo deslocamento de fase e ruído conforme (1). A relação sinal ruído usada foi  $SNR = 30\text{dB}$  igual para todos os nós. Foi utilizado um filtro  $\psi$  com comprimento  $L = 7$ , em todas as simulações.

Na Fig. 2 o valor do passo de adaptação médio no SM-CMAD foi  $\bar{\mu} = 0.01$ , com  $\tau = 4$  e  $m = 1.5$ . Para o CMAD foi utilizado um  $\mu = 0.01$ . Os parâmetros foram escolhidos através de uma série de simulações, adotando-se a combinação que levou aos melhores resultados.

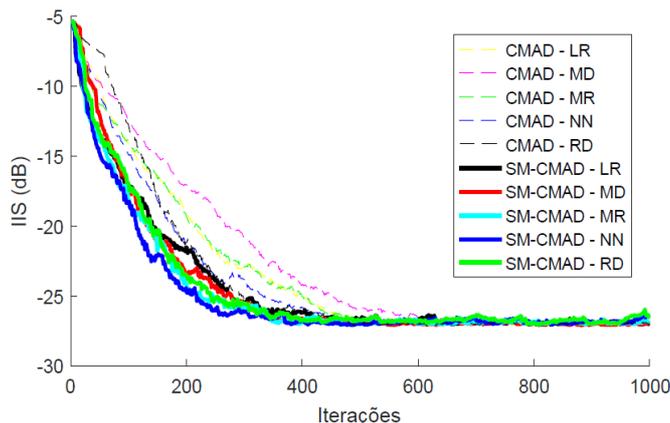


Fig. 2. Comparação das matrizes de combinação com os algoritmos CMAD e SM-CMAD, com 12 nós.

A Fig. 2 mostra o resultado da comparação entre o algoritmo CMAD e o SM-CMAD, sendo simulado com todas as matrizes de combinação descritas na Seção II. É possível ver que o algoritmo SM-CMAD converge mais rápido e para o mesmo patamar de IIS residual que o CMAD, mesmo utilizando menos processamento para atingir tal resultado. Também é possível

verificar que as diferentes matrizes de combinação possuem um efeito maior no desempenho do CMAD do que no do SM-CMAD. Ainda assim, a regra NN foi a que levou o algoritmo a convergir mais rapidamente.

A Fig. 3 mostra como o desempenho do algoritmo SM-CMAD varia com  $\tau$ . A matriz utilizada foi a NN e  $m = 1$ ,  $SNR = 30\text{dB}$  igual para todos os nós. O valor do passo de adaptação médio no SM-CMAD foi  $\bar{\mu} = 0.03$ . Vemos que existe um valor de  $\tau$  para o qual o desempenho é melhor, tanto em termos de velocidade de convergência, como em relação ao patamar de IIS residual. O menor valor de  $\tau$  considerado foi 0.7. Abaixo disso o algoritmo começa a oscilar muito, tendendo a divergir.

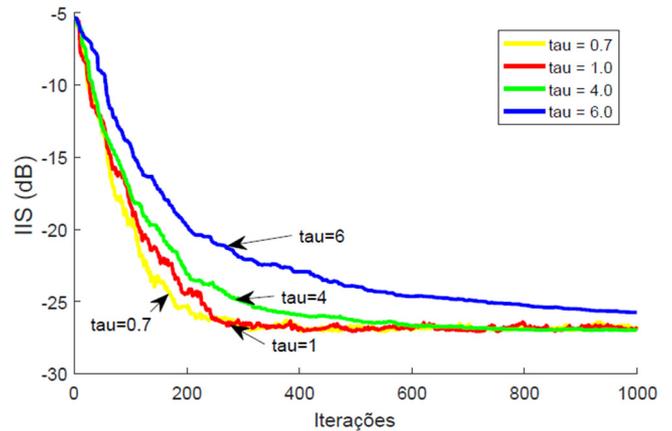


Fig. 3. Comparação do valor de  $\tau$  no SM-CMAD com a matriz NN.

Foi testado também a variação do  $m$  e sua influência sobre o algoritmo. A matriz utilizada foi a NN e  $\tau = 1$ ,  $SNR = 30\text{dB}$  igual para todos os nós. O valor de  $\bar{\mu} = 0.03$ , sendo apresentado o resultado na Fig. 4.

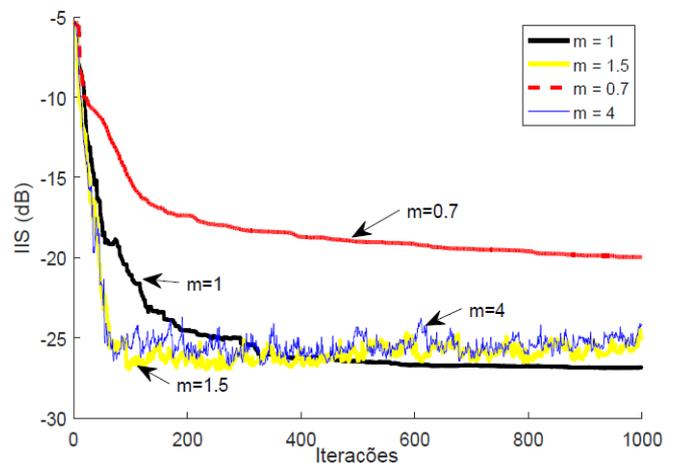


Fig. 4. Comparação do valor de  $m$  no SM-CMAD com a matriz NN.

É possível ver na Fig. 4 que um  $m = 1$  permite uma convergência para o menor patamar de IIS residual. Aumentando o valor de  $m$ , o algoritmo começa a oscilar cada vez mais, tendendo a divergir.

**Cenário de simulação 2:** Utilizamos agora o canal  $h = [0.3482 \ -0.8704 \ 0.3482]$ . A relação sinal ruído usada foi  $SNR = 10\text{dB}$  igual para todos os nós.

A simulação da Fig. 5 utilizou um filtro com comprimento de  $L = 7$  e inicialização “center spike”. O valor do passo de adaptação médio no SM-CMAD foi  $\bar{\mu} = 0.001$ , com  $\tau = 1$  e  $m = 1$ , no CMAD foi utilizado um  $\mu = 0.0002$ .

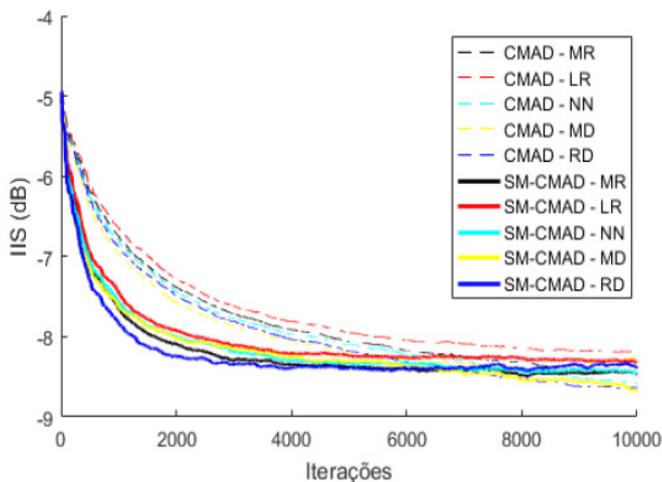


Fig. 5. Comparação das matrizes de combinação com os Algoritmos CMAD e SM-CMAD, cenário 2.

A Fig. 5 mostra que mesmo utilizando um canal mais difícil de equalizar o algoritmo SM-CMAD, obteve melhores resultados em termos de velocidade de convergência, chegando a patamares mais baixos em relação à IIS, do que o CMAD. Neste caso a matriz RD obteve resultados superiores as demais matrizes, em ambos algoritmos. Sendo que todas as outras apresentaram resultados bastante similares.

Resumindo os resultados obtidos, foi verificado que, para cada valor de  $\tau$ , é possível definir um valor de  $m$  para o qual o algoritmo apresenta bom desempenho. Em geral, o algoritmo perde desempenho quando os valores dos dois parâmetros são muito discrepantes entre si. Além disso, conferindo a troca de informação necessária entre os nós, foi verificado que o SM-CMAD apresenta uma economia de cerca de 18% em média, economizando energia e recursos do sistema.

## VII. CONCLUSÃO

Neste artigo propusemos um novo algoritmo para ser usado no contexto de algoritmos autodidatas aplicados a redes de sensores, estendendo o algoritmo CMAD para o contexto *set-membership* resultando no algoritmo SM-CMAD.

Através de simulações, verificamos os melhores valores para os parâmetros  $m$  e  $\tau$ , verificando que existe uma certa correlação entre os dois. Vimos que o algoritmo SM-CMAD consegue um melhor desempenho do que o CMAD, ainda com a vantagem de economizar cerca de 18% da troca de informação necessária entre os nós.

## REFERÊNCIAS

- [1] F.S. Cattivelli e A.H. Sayed. Diffusion LMS strategies for distributed estimation. *Signal Processing, IEEE Transactions on*, 58(3): páginas 1035-1048, Março 2010.
- [2] A. de Paula e C. Panazio. Sobre a escolha do limiar do algoritmo Set-membership em redes de sensores sem fio com nós sujeitos a diferentes potências de ruído. Em XXXIV Simpósio Brasileiro de

Telecomunicações e Processamento de Sinais– SBrT2016, Santarém, PA-Brasil, Setembro 2016.

- [3] A. de Paula e C. Panazio. Analysis of distributed parameter estimation in WSN with unreliable nodes. Em *Wireless Communication Systems (ISWCS), 2012 International Symposium on*, páginas 116-120, Agosto 2012.
- [4] F. S. Cattivelli e A. H. Sayed. Diffusion LMS algorithms with information exchange. Em *Signals, Systems and Computers, 2008 42nd Asilomar Conference on*, páginas 251-255, Outubro 2008.
- [5] C. G. Lopes e A. H. Sayed. Diffusion least-mean squares over adaptive networks. Em *Acoustics, Speech and Signal Processing, 2007. ICASSP 2007. IEEE International Conference on*, volume 3, páginas III-917-920, Abril 2007.
- [6] C. G. Lopes e A. H. Sayed. Diffusion least-mean squares over adaptive networks: Formulation and performance analysis. *Signal Processing, IEEE Transactions on*, 56(7): páginas 3122-3136, Julho 2008.
- [7] R. Abdolee e B. Champagne. Distributed blind adaptive algorithms based on constant modulus for wireless sensor networks. Em *Wireless and Mobile Communications (ICWMC), 2010 6th International Conference on*, páginas 303-308, Setembro 2010.
- [8] S. B. dos Santos. Estudo de Algoritmos Adaptativos Aplicados a Rede de Sensores Sem Fio: Caso Supervisionado e Não Supervisionado. Dissertação de Mestrado, UFABC, Santo André, SP-Brasil, 2014.
- [9] S. B. dos Santos e A. Neves. Diffusion Constant Modulus Algorithm for Wireless Sensor Networks. Em XXXIV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais– SBrT2016, Santarém, PA-Brasil, Setembro 2016.
- [10] S. Gollamudi, S. Nagaraj e Y.F. Huang. "Blind equalization with a deterministic constant modulus cost-a set-membership filtering approach," 2000 IEEE International Conference on Acoustics, Speech, and Signal Processing. *Proceedings (Cat. No.00CH37100)*, Istanbul, 2000, páginas 2765-2768 vol.5.
- [11] R. C. de Lamare e P. S. R. Diniz, "Blind Adaptive Interference Suppression Based on Set-Membership Constrained Constant-Modulus Algorithms With Dynamic Bounds," in *IEEE Transactions on Signal Processing*, vol. 61, no. 5, páginas 1288-1301, Março 1, 2013.
- [12] W. A. Martins, M. V. S. Lima, P. S. R. Diniz, "Semi-blind data-selective equalizers for QAM", *Signal Processing Advances in Wireless Communications 2008. SPAWC 2008. IEEE 9th Workshop on*, páginas 501-505, 2008.