

# Sobre a escolha do limiar do algoritmo *set-membership* em redes de sensores sem fio com nós sujeitos a diferentes potências de ruído

Amanda de Paula, Cristiano Panazio

**Resumo**— Este artigo analisa o desempenho do algoritmo *set-membership least mean square* (SM-LMS) em uma rede de sensores em os nós possuem diferentes potências de ruído. Através de uma breve análise, é apresentado e justificado um limiar diferente do convencionalmente utilizado e que permite atingir um desempenho superior ao explorar a variação de potência do ruído entre os nós da rede. Em seguida, considerando as limitações de trocas de informação, é mostrada no mesmo contexto uma extensão da técnica SM-LMS, chamada de *reduced feedback* (RF)-SM-LMS, que permite reduzir o envio de estimativas entre os nós, poupando assim energia destes. Simulações para diferentes distribuições de potência são apresentadas e mostra-se a efetividade das técnicas propostas em relação ao algoritmo convencional do tipo LMS.

**Palavras-Chave**— Estimação, processamento distribuído, filtragem adaptativa, algoritmo *set-membership*, redes de sensores sem fio.

**Abstract**— This paper analyzes the performance of the *set-membership least mean square* (SM-LMS) algorithm in a wireless sensor network with nodes that experience different levels of noise power. Through a brief analysis, an adaptation threshold value for each node of the network that allows superior performance than the conventional one is given and justified. In the following, in the same context but also by considering the constraints imposed in the information exchanged among the nodes, it is also shown a *reduced feedback* (RF) version of the SM-LMS algorithm that can reduce the need to send the estimated parameters, reducing the energy consumption of these nodes. Simulations are presented for different noise power distributions and it is shown the effectiveness of the proposed techniques with regard to the conventional LMS algorithm.

**Keywords**— Estimation, distributed processing, adaptive filtering, *set-membership* algorithm, wireless sensor networks.

## I. INTRODUÇÃO

A estimação de parâmetros em redes de sensores sem fio (RSSF) é um tópico consideravelmente explorado na literatura (e.g., [1]–[3]). Tal técnica pode ser aplicada a uma variedade de contextos. Por exemplo, na agricultura, em que parâmetros como a temperatura, umidade ou velocidade do vento são de grande importância para as colheitas, ou ainda na área da saúde, em que dados fisiológicos dos pacientes devem ser monitorados.

Uma boa parte das implementações de RSSF utiliza um centro de fusão de dados para que se possa fazer a estimação, tal como nos sistemas descritos em [2] e [4]. O maior problema

com este tipo de implementação é um consumo de energia significativo, o que impactaria negativamente na autonomia dos dispositivos, uma vez que estes costumam ter baterias de pequena capacidade. De forma a mitigar este problema, implementações que evitam o uso de um centro de fusão ganharam atenção nos últimos anos [5]–[7].

Uma proposta interessante é a utilização de filtros adaptativos distribuídos [8], [9]. A maioria dos algoritmos mais clássicos usados em filtragem adaptativa pode ser aplicada ao contexto de estimação distribuída. Por exemplo, o algoritmo *least man square* (LMS) foi aplicado em [9] e o *recursive least squares* (RLS), em [10].

Visando aumentar a eficiência energética em RSSF, é natural que uma solução de filtragem adaptativa distribuída empregue algoritmos baseados na técnica *set-membership* (SM) [11], pois tal técnica é capaz de reduzir a complexidade de processamento. A aplicação do algoritmo SM no contexto de estimação distribuída foi inicialmente explorada em [12], em que é mostrado que o consumo de energia pode ser consideravelmente reduzido quando comparado a técnicas que utilizam o algoritmo LMS, não só reduzindo o processamento em cada nó, mas também reduzindo o envio de informações entre os mesmos, com mínimo impacto no desempenho. Isto é altamente desejável, pois em RSSF, a transmissão de sinais é a principal fonte de consumo de energia.

Outro aspecto importante que merece atenção na análise de algoritmos de estimação distribuída é o caso em que a observação em cada nó da rede não provê a mesma confiabilidade em relação a estimação do parâmetro desconhecido. Neste caso, a estimação gerada em nós que geram as estimativas menos confiáveis tendem a deteriorar a estimativa global da rede. Tal cenário de nós em condições heterogêneas de estimação em RSSF pode ocorrer por diversas razões. Por exemplo, no caso de uma rede cognitiva em que se faz sensoriamento espectral do canal entre os usuários secundários e o usuário primário, a relação sinal-ruído é distinta entre cada um deles [13]. Uma solução possível para otimizar a estimação de parâmetros nesta situação de nós heterogêneos é utilizar um esquema adaptativo cooperativo tal como em [14], ou usar um LMS com passo variável tal como proposto em [15] e [16].

Neste artigo, é mostrado como escolher de forma eficiente o limiar para adaptação dos algoritmos do tipo SM para aplicações em que os nós apresentam diferentes níveis de ruído. Além da justificativa teórica, são mostradas curvas de simulação que corroboram a eficiência dos algoritmos SM nesses cenários. Considerando o mesmo cenários, também

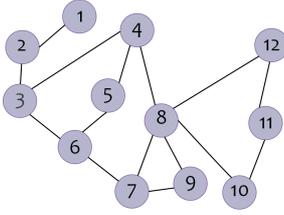


Fig. 1. Rede de difusão

é proposta e analisada uma técnica em que o conceito dos algoritmos SM é utilizado para reduzir o envio de informações através do canal de *feedback* na rede distribuída.

O restante do artigo está organizado da seguinte forma. Na seção II é mostrada a topologia da rede e a modelo de sistema usado neste artigo, seguida pela seção III, em que se descreve os algoritmos utilizados no processamento em cada nó da rede. A seção IV apresenta o algoritmo SM utilizada para redução de uso do canal de *feedback*. Já a seção V mostra os resultados de simulação do artigo e, finalmente, as conclusões são apresentadas na seção VI.

## II. MODELO DE SISTEMA PARA ESTIMAÇÃO DISTRIBUÍDA

Neste artigo, é considerado que a cooperação entre nós ocorre de acordo com a regra de difusão [8] no modo ATC (do inglês, *adapt-then-combine*). Neste modo de cooperação, cada nó pode trocar sua estimativa com um conjunto de nós e essa cooperação é realizada de forma que a combinação das estimativas em cada nó da rede se dá depois do processo de adaptação. Em [17] e [18] é mostrado que a técnica ATC é mais eficiente do que a técnica CTA (do inglês, *combine-then-adapt*), principalmente em cenários nos quais o passo de adaptação do algoritmo é pequeno. Por este motivo, neste artigo, abordaremos algoritmos aplicando a técnica ATC.

Em relação à topologia da rede, utiliza-se no restante deste artigo a topologia mostrada na Fig. 1. A escolha desta topologia foi tal que são necessárias algumas iterações até que os nós das redes tenham acesso às estimativas dos demais nós.

Tal como na maioria dos artigos de RSSF, considera-se que as trocas de informação entre os nós se dão sem erros e somente através dos caminhos que definem a rede. Além disso, é assumido que a rede é bidirecional de tal modo que, se o  $k$ -ésimo nó está conectado ao  $l$ -ésimo nó, ambos podem trocar informações um com o outro. Ainda com relação à topologia da rede, define-se a vizinhança do  $k$ -ésimo nó,  $\mathcal{N}_k$ , como o conjunto de nós que se conectam a ele, incluindo ele próprio.

É adotado um modelo linear para geração do sinal desejado, de tal forma que o  $k$ -ésimo nó possui acesso ao conjunto de medidas  $\{\mathbf{u}_k(n), d_k(n)\}$ , que se relacionam da seguinte forma:

$$d_k(n) = \mathbf{u}_k(n)^T \mathbf{w}_{opt} + \eta_k(n), \quad (1)$$

em que  $\mathbf{w}_{opt}$  é o vetor de coeficientes ótimos a ser estimado,  $\eta_k(n)$  é uma variável aleatória gaussiana de média nula e variância  $\sigma_{\eta,k}^2$  que representa o ruído e  $n$  representa o  $n$ -ésimo instante de tempo.

Ainda, além do par  $\{\mathbf{u}_k(n), d_k(n)\}$ , cada nó da rede possui acesso às estimativas de  $\mathbf{w}_{opt}$  geradas por seus vizinho,

LMS distribuído - ATC	
$e(n) = d(n) - \psi_k(n)^T \mathbf{u}_k(n)$	
$\phi_k(n+1) = \psi_k(n) + \mu_k e(n) \mathbf{u}_k(n)$	
$\psi_k(n) = \sum_{l \in \mathcal{N}_k} c_{k,l} \phi_l(n)$	

TABELA I

ALGORITMO LMS DISTRIBUÍDO - ATC

definidas como  $\phi_l$ ,  $l \in \mathcal{N}_k$ . Assim, a estimativa que agrega sua própria estimativa e a dos vizinhos,  $\psi_k$ , pode ser obtida através de uma combinação linear dada por:

$$\psi_k(n) = \sum_{l \in \mathcal{N}_k} c_{k,l} \phi_l(n), \quad (2)$$

em que  $c_{k,l}$  são coeficientes que são calculados segundo algum critério.

Em [9], tais coeficientes são dispostos em uma matriz  $\mathbf{C}$  e assume-se que a soma dos coeficientes em cada coluna deve ser igual a um, ou seja:

$$\sum_{l \in \mathcal{N}_k} c_{k,l} = 1. \quad (3)$$

Para atingir tal condição e dado o problema estudado, foi escolhida a regra Metropolis [9]:

$$c_{k,l} = \begin{cases} \frac{1}{\max\{n_k, n_l\}}, & k \in \mathcal{N}_l \\ 0, & k \notin \mathcal{N}_l \\ 1 - \sum_{l \in \mathcal{N}_k, l \neq k} c_{k,l} & k = l \end{cases}, \quad (4)$$

em que  $n_k$  e  $n_l$  representam o número de nós conectados no  $k$ -ésimo e  $l$ -ésimo nós, respectivamente.

## III. PROCESSAMENTO LOCAL

Localmente, cada nó na rede pode aplicar vários tipos algoritmos para atualizar suas estimativas. Com o objetivo de manter uma baixa complexidade computacional, é comum aplicar versões do algoritmo do gradiente descendente. Neste artigo, foram considerados o LMS, para servir de referência de desempenho, e o algoritmo *set-membership* LMS (SM-LMS) com limiar adaptado para o contexto estudado, ambos descritos nas subseções a seguir.

### A. Algoritmo LMS

Considerando o algoritmo LMS com a estratégia ATC, a estimativa local  $\phi_k(n)$  é atualizada como descrito na Tabela 1.

O parâmetro  $\mu_k$  na Tabela 1 é o passo de adaptação do algoritmo LMS para o  $k$ -ésimo nó.

Nos casos em que a rede de sensores é heterogênea, no sentido de que alguns nós são mais ruidosos que os demais, é interessante o emprego de diferentes valores de passo de adaptação para cada um dos nós da rede. Em [16], é mostrado que a configuração ótima de passo de adaptação é dada por:

$$\mu_k = \frac{\bar{\mu}}{\sigma_{\eta,k}^2} \text{harm}(\sigma_{\eta,k}^2), \quad (5)$$

em que  $\bar{\mu}$  é o valor de passo de adaptação médio,  $\sigma_{\eta,k}$  é o valor de potência de ruído no nó  $k$ ,  $\text{harm}(\cdot)$  representa

o operador média harmônica e  $\sigma_\eta^2$  indica um vetor com as potências de ruído em cada um dos nós da rede. Fixado  $\bar{\mu}$ , a distribuição de potência na rede pode ser tal que (5) gere valores de passo de adaptação que levem à divergência do algoritmo. Por este motivo, deve-se ter especial cuidado ao se escolher essa abordagem para algoritmos de estimação em redes em que os nós apresentam diferentes potências de ruído.

### B. Algoritmo SM-LMS

O algoritmo LMS pode ser facilmente modificado de modo a introduzir a ideia do algoritmo SM.

A característica principal dos algoritmos do tipo SM diz respeito ao fato de que a solução fornecida pelo o algoritmo não ser única. Todos os elementos do chamado conjunto viável (do inglês, *feasible set*) são admitidos como possíveis soluções do algoritmo. Dessa forma, a taxa de atualização do algoritmo é menor do que a de um algoritmo adaptativo clássico. Essa é uma estratégia especialmente interessante no caso em que o consumo de energia é um parâmetro crítico do sistema, assim como ocorre no caso em redes de sensores.

Aplicando a estratégia SM no processamento local do sistema, a adaptação ocorre sempre que o erro de estimação no nó for maior que um determinado limiar,  $\bar{\gamma}_k$ . Desta forma, pode-se analisar o algoritmo SM como um algoritmo LMS de passo variável, dado por:

$$\mu_k(n) = \begin{cases} 0, & |e_k(n)| < \bar{\gamma}_k \\ \mu_0 \left(1 - \frac{\bar{\gamma}_k}{|e_k(n)|}\right), & c.c. \end{cases}, \quad (6)$$

em que  $\bar{\gamma}_k$  é um limiar que define o valor de erro mínimo necessário para a adaptação do algoritmo no  $k$ -ésimo nó. Em geral, o limiar  $\bar{\gamma}_k$  é expresso na forma  $\bar{\gamma}_k = \sqrt{\tau \sigma_{\eta,k}^2}$  [19], em que  $\tau$  é uma constante positiva. Se o limiar  $\bar{\gamma}_k$  for definido dessa forma, a probabilidade de atualização do algoritmo é independente da potência do ruído, fato que será explicado mais adiante.

No entanto, considerando o contexto de estimação distribuída em que os nós das redes apresentam diferentes potências de ruído, é interessante que os nós mais ruidosos apresentem uma menor probabilidade de atualização. A motivação por trás deste raciocínio é a de que nós mais ruidosos deveriam contribuir menos na combinação para gerar a estimativa do parâmetro de interesse. Assim, almeja-se que o passo de adaptação, mostrado na eq. (6), atue de tal forma que este pondere as estimativas adequadamente segundo a potência do ruído em cada nó. Para tanto, note que o algoritmo será atualizado com a seguinte probabilidade no instante  $n$  e no  $k$ -ésimo nó:

$$P_{up}(k, n) = P\{|e_k(n)| > \bar{\gamma}_k\}. \quad (7)$$

Dessa forma, assumindo que o erro de estimação em cada nó apresenta distribuição de probabilidade aproximadamente gaussiana [20], as probabilidades de atualização serão dadas por:

$$P_{up}(k, n) = P\{|e_k(n)| > \bar{\gamma}_k\} = 2P\{e_k(n) > \bar{\gamma}_k\} = 2Q\left(\frac{\bar{\gamma}_k}{\sigma_{e(n),k}}\right), \quad (8)$$

em que  $\sigma_{e(n),k}^2$  corresponde à variância do erro no  $k$ -ésimo nó e no instante  $n$ , e que em regime pode-se aproximar  $\sigma_{e(n),k}^2$  por  $\sigma_{\eta,k}^2$ , tal que a eq. (8) pode ser reescrita como:

$$P_{up}(k, n) \approx 2Q\left(\frac{\bar{\gamma}_k}{\sigma_{\eta,k}}\right), \quad (9)$$

e  $Q(x)$  é a função erro definida como:

$$Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^\infty \exp\left(-\frac{t^2}{2}\right) dt. \quad (10)$$

Note que dada a hipótese acima, se fosse adotado o tradicional limiar  $\bar{\gamma}_k = \sqrt{\tau \sigma_{\eta,k}^2}$ , a probabilidade de atualização de todos os nós só dependeria do valor de  $\tau$  (que é comum a todos os nós), tal como foi afirmado anteriormente. Assim, para que a probabilidade de atualização passasse a depender da variância do ruído, considerou-se que  $\bar{\gamma}_k = (\tau \sigma_{\eta,k}^2)^m$ , com  $m > 0,5$ .

Através de simulações para vários valores de  $m$ , chegou-se ao resultado de que  $m = 1$  apresentava um comportamento ótimo em termos desvio quadrático médio em relação aos demais valores para uma dada velocidade de convergência. Deste modo, a probabilidade de atualização pode ser escrita por:

$$P_{up}(k) \approx 2Q(\tau \sigma_{\eta,k}). \quad (11)$$

Perceba que como a função  $Q(x)$  é monotonicamente decrescente, os nós sujeitos à maior potência de ruído apresentarão uma taxa de atualização mais baixa. Portanto, em média, contribuirão menos para a estimativa geral da rede.

Por fim, pode-se estender a ideia de minimizar a troca de informação entre os nós, tal como mostrado na seção seguinte.

## IV. SET-MEMBERSHIP DISTRIBUÍDO COM REDUÇÃO DE FEEDBACK

A ideia que fundamenta os algoritmos do tipo *set-membership* também pode ser aplicada a fim de reduzir a troca de informações na rede, tal como em [12], em que é introduzida a ideia do algoritmo SM-LMS com *feedback* reduzido, o qual será denotado por RF-SM-LMS. Em [12], antes de enviar a estimativa aos nós vizinhos, cada nó realiza um teste de modo a avaliar se a estimativa será relevante para o seu vizinho. Para tanto, se define o conjunto:

$$\mathcal{H}_l(n) = \{\phi \mid |d_l(n) - \mathbf{u}_l(n)^T \phi| < \gamma_{fb,l}\}. \quad (12)$$

em que  $\gamma_{fb,l}$  é o limiar que determina se é necessário enviar a informação. Se  $\phi_k(n) \in \mathcal{H}_l(n)$ , significa que a estimativa  $\phi_k(n)$  não é relevante para o  $l$ -ésimo nó e, por essa razão, ela não deve ser transmitida.

Observe que essa abordagem realmente diminui a taxa de ocupação de canal e a energia despendida para o envio dessa informação, mas que ainda requer o conhecimento dos pares  $\{\mathbf{u}_l(n), d_l(n)\}$ ,  $\forall l \in \mathcal{N}_k$ . Neste trabalho, entretanto, assume-se que as únicas informações trocadas entre os nós são as estimativas  $\phi$ . Por essa razão, se faz necessário definir um outro critério para decidir se a estimativa deve ser enviada aos nós vizinhos. Nesse contexto, definimos um critério local, baseado apenas no par  $\{\mathbf{u}_k(n), d_k(n)\}$ . O nó  $k$  transmitirá sua estimativa aos vizinhos se o erro de estimação for acima de um

limiar local  $\gamma_{fb,k}^{loc}$ . De modo análogo ao caso da seção anterior, foram considerados diferentes limiares e chegou-se que um bom compromisso entre redução de *feedback* e desempenho era obtido para  $\gamma_{fb,k}^{loc} = \sqrt{\tau_{fb}^{loc} \sigma_\eta}$ .

## V. RESULTADOS DE SIMULAÇÃO

Nesta seção, os algoritmos propostos serão simulados e será observado o comportamento de em cenários em que há uma distribuição desigual de potência de ruído entre os nós da rede. Em cada cenário, a distribuição de potência de ruído é dada por:

$$\sigma_{\eta,k}^2 = \overline{\sigma_\eta^2} \exp(-\alpha k) K \frac{1 - \exp(-\alpha)}{1 - \exp(-K\alpha)} \quad 0 \leq k \leq K - 1, \quad (13)$$

em que  $K = 12$  é o número de nós da rede,  $\alpha$  é uma constante real positiva e  $\overline{\sigma_\eta^2}$  é a potência média de ruído nos nós da rede. Ainda, assume-se que tais valores são perfeitamente conhecidos quando do cálculo dos limiares  $\overline{\gamma}_k$  e  $\gamma_{fb,k}^{loc}$ .

Note que se  $\alpha = 0$ , todos os nós da rede apresentam a mesma potência de ruído  $\sigma_{\eta,k}^2 = \overline{\sigma_\eta^2}$ ,  $\forall k$ . Quanto maior o valor de  $\alpha$ , mais desigual é a distribuição de potência de ruído na rede.

Para todos os cenários de simulação, a topologia de rede utilizada foi a mostrada na Fig. 1. O vetor a ser estimado é definido com  $M = 5$  coeficientes e variância unitária:  $\mathbf{w}_{opt} = [1, 1, \dots, 1] / \sqrt{M}$ . Além disso, o sinal de entrada  $u_k(n)$  é uma variável aleatória gaussiana de média nula e variância unitária. Os algoritmos foram analisados utilizando como métrica a média instantânea global do desvio médio quadrático (MSD, do inglês *mean-square deviation*), dado por:

$$\text{MSD}(n) = \frac{1}{K} \sum_{k=1}^K \|\psi_k(n) - \mathbf{w}_{opt}\|^2, \quad (14)$$

em que  $K$  é o número total de nós da rede.

O passo de adaptação do algoritmo LMS foi fixado em  $\mu = 0,038$  para todos os nós da rede. Já para o algoritmo SM-LMS, o parâmetro  $\mu_0$  foi fixado em  $\mu_0 = 0,05$  e o parâmetro  $\tau$  foi fixado em  $\tau = 2$ . Esses parâmetros foram escolhidos de modo que o MSD em regime fosse o mesmo para os dois algoritmos, para o caso em que a potência de ruído é a mesma em todos os nós da rede, *i.e.*,  $\alpha = 0$ . Em todos os casos, foi considerado que a potência média de ruído nos nós é dada por  $\overline{\sigma_\eta^2} = 10^{-1}$ .

No caso em que os nós apresentam diferentes potências de ruído, o algoritmo SM-LMS mostra uma clara vantagem em relação ao LMS como indicado nos resultados apresentados na Fig 2. O ganho de desempenho é crescente em relação ao parâmetro  $\alpha$ , o que mostra que o algoritmo SM-LMS realmente é uma boa alternativa ao LMS de passo fixo, pois este último apresenta comportamento oposto, em que há uma pequena degradação do MSD com o aumento do parâmetro  $\alpha$ .

Na Fig. 3 é simulado o LMS com passo ótimo para cada nó dado pela eq. (5) para  $\alpha = 0,5$ , no cenário 2. Neste caso, o LMS consegue se equiparar ao SM-LMS. Todavia, para que o LMS com passo ótimo convergisse, foi preciso adotar uma velocidade de convergência menor do que a apresentada na

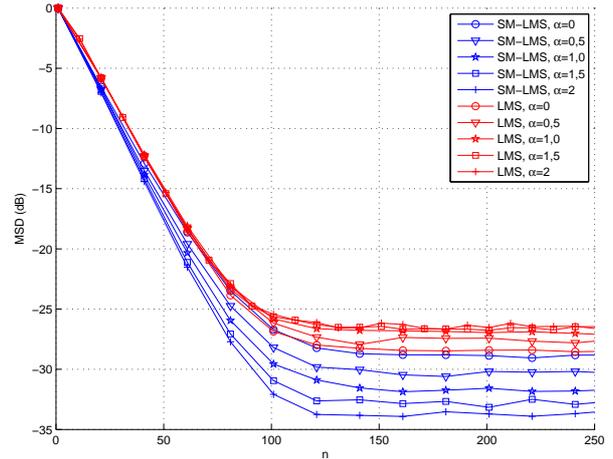


Fig. 2. Comparação de desempenho entre os algoritmos LMS e SM-LMS, considerando que a potência de ruído em cada nó da rede é a dada por (13).

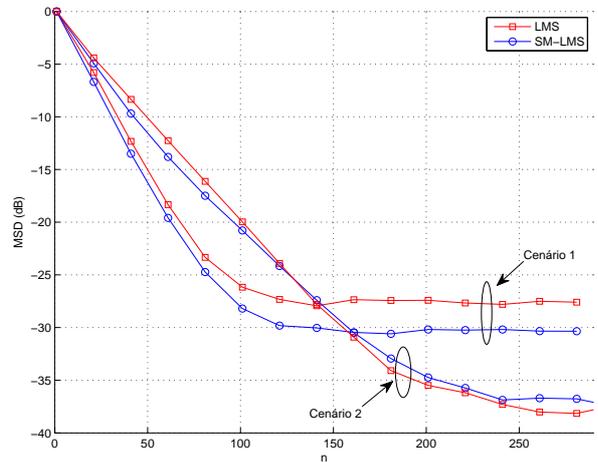


Fig. 3. Comparação de desempenho entre os algoritmos LMS com passo ótimo e SM-LMS, considerando  $\alpha = 0,5$ . O cenário 1 corresponde ao simulado da Fig. 2 com LMS com passo fixo para efeito de comparação, e o cenário 2 utiliza o LMS com passo ótimo (eq. (5)), em que  $\mu = 0,05$  e o SM-LMS adota  $\tau = 12$  e  $\mu_0 = 0,044$ .

Fig. 2, reproduzida, para efeito de comparação, como cenário 1 na Fig. 3.

A Fig. 4 mostra a probabilidade de atualização em regime e em função da potência de ruído em cada nó da rede. Note que a estimativa de probabilidade de atualização obtida por simulação mostra a efetividade da aproximação dada por (11).

A Fig. 5 mostra o desempenho do algoritmo SM com redução de *feedback* comparado com os algoritmos LMS e SM-LMS. A potência de ruído em cada nó da rede é dada por (13) com o parâmetro  $\alpha = 1$ , para o cenário simulado. Os parâmetros de simulação são os mesmos daqueles do resultado mostrado na Fig. 2 e  $\tau_{fb}^{loc} = 6$  para o algoritmo RF-SM-LMS. A análise dos resultados mostra que o desempenho do algoritmo RF-SM-LMS é levemente inferior em relação ao do algoritmo SM-LMS. A grande vantagem do uso do algoritmo RF-SM-LMS é que houve troca de informações

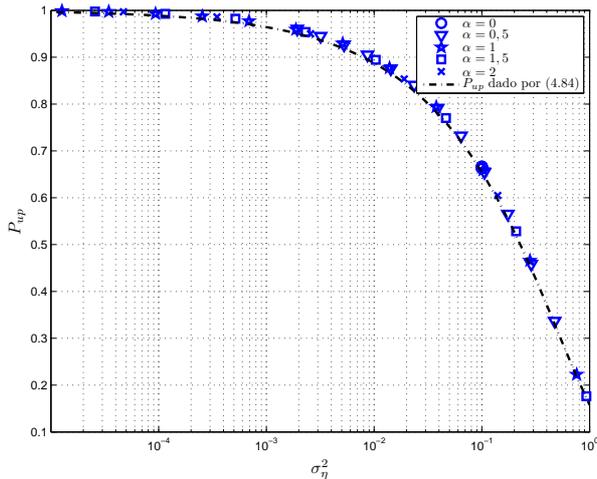


Fig. 4. Probabilidade de atualização em função da potência de ruído considerando que a potência de ruído em cada nó da rede é a dada por (13).

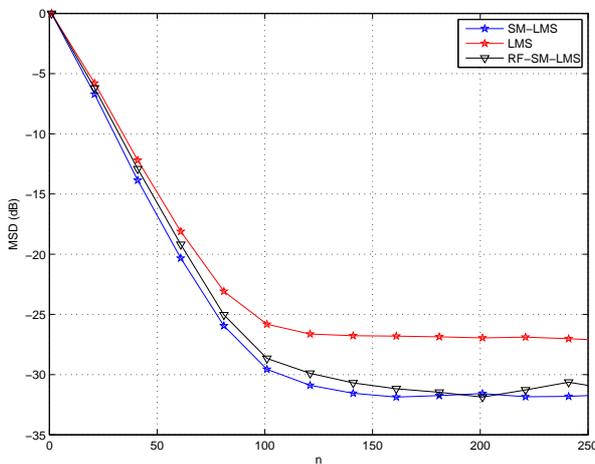


Fig. 5. Comparação de desempenho entre os algoritmos LMS, SM-LMS e sua versão com *feedback* reduzido RF-SM-LMS para  $\alpha = 1$ .

entre os nós da rede em apenas 12,0% das iterações. Todavia, é importante enfatizar que ambas as versões do tipo *set-membership* apresentam desempenho superior em relação ao LMS com passo fixo em termos de velocidade de convergência e custo computacional para um mesmo nível de MSD.

Além do ganho de desempenho, deve-se destacar a menor complexidade computacional envolvida na implementação do algoritmo SM-LMS em comparação com o LMS [19], já que o algoritmo atualiza apenas em algumas iterações.

## VI. CONCLUSÃO

Este artigo mostra como obter uma escolha adequada do limiar de adaptação na técnica SM-LMS que permita melhorar o desempenho do sistema no caso em que os nós da RSSF apresentam diferentes potências de ruído. Foi mostrada através de simulações que tal técnica permite uma velocidade de convergência superior ao LMS convencional e que tal diferença é tanto maior quanto mais heterogênea for a potência do ruído entre os nós que compõem a RSSF. Ainda, foi mostrada uma extensão da técnica SM-LMS com redução de

*feedback* (RF-SM-LMS) no contexto proposto e que consegue obter resultados semelhantes ao SM-LMS, mas que permite reduzir a troca de informações entre os nós, atingindo uma economia adicional de energia nos nós da rede. Tem-se como perspectivas deste trabalho uma investigação mais rigorosa e aprofundada dos limiares usados no SM-LMS e RF-SM-LMS, de modo a validar os resultados aqui obtidos.

## REFERÊNCIAS

- [1] J.-F. Chamberland and V.V. Veeravalli, "Wireless sensors in distributed detection applications," *IEEE Signal Processing Magazine*, vol. 24, no. 3, pp. 16–25, May 2007.
- [2] M. Guerriero, L. Svensson, and P. Willett, "Bayesian data fusion for distributed target detection in sensor networks," *IEEE Transactions on Signal Processing*, vol. 58, no. 6, pp. 3417–3421, June 2010.
- [3] J.N. Tsitsiklis, "Decentralized detection," *Advances in Signal Processing*, vol. 2, pp. 197–344, 1993.
- [4] R. Viswanathan and P.K. Varshney, "Distributed detection with multiple sensors i. fundamentals," *Proceedings of the IEEE*, vol. 85, no. 1, pp. 54–63, Jan. 1997.
- [5] S. Barbarossa and G. Scutari, "Decentralized maximum-likelihood estimation for sensor networks composed of nonlinearly coupled dynamical systems," *IEEE Transactions on Signal Processing*, vol. 55, no. 7, pp. 3456–3470, July 2007.
- [6] Qing Ling and Zhi Tian, "Decentralized sparse signal recovery for compressive sleeping wireless sensor networks," *IEEE Transactions on Signal Processing*, vol. 58, no. 7, pp. 3816–3827, July 2010.
- [7] S. Barbarossa, S. Sardellitti, and Paolo Lorenzo, *Academic Press Library in Signal Processing: Communications and Radar Signal Processing*, vol. 2, pp. 329–408, Academic Press, 2014.
- [8] C.G. Lopes and A.H. Sayed, "Incremental adaptive strategies over distributed networks," *IEEE Transactions on Signal Processing*, vol. 55, no. 8, pp. 4064–4077, Aug. 2007.
- [9] C.G. Lopes and A.H. Sayed, "Diffusion least-mean squares over adaptive networks: Formulation and performance analysis," *IEEE Transactions on Signal Processing*, vol. 56, no. 7, pp. 3122–3136, July 2008.
- [10] F.S. Cattivelli, C.G. Lopes, and A.H. Sayed, "Diffusion recursive least-squares for distributed estimation over adaptive networks," *IEEE Transactions on Signal Processing*, vol. 56, no. 5, pp. 1865–1877, May 2008.
- [11] S. Gollamudi, S. Nagaraj, S. Kapoor, and Yih-Fang Huang, "Set-membership filtering and a set-membership normalized LMS algorithm with an adaptive step size," *IEEE Signal Processing Letters*, vol. 5, no. 5, pp. 111–114, May 1998.
- [12] S. Werner, Yih-Fang Huang, M.L.R. de Campos, and V. Koivunen, "Distributed parameter estimation with selective cooperation," in *IEEE International Conference on Acoustics, Speech and Signal Processing, 2009. ICASSP 2009.*, April 2009, pp. 2849–2852.
- [13] F.S. Cattivelli and A.H. Sayed, "Distributed detection over adaptive networks using diffusion adaptation," *IEEE Transactions on Signal Processing*, vol. 59, no. 5, pp. 1917–1932, May 2011.
- [14] N. Takahashi, I. Yamada, and A.H. Sayed, "Diffusion least-mean squares with adaptive combiners: Formulation and performance analysis," *IEEE Transactions on Signal Processing*, vol. 58, no. 9, pp. 4795–4810, Sept. 2010.
- [15] A. Rastegarnia, M.A. Tinati, and A. Khalili, "A distributed incremental LMS algorithm with reliability of observation consideration," in *IEEE International Conference on Communication Systems (ICCS), 2010*, Nov. 2010, pp. 67–70.
- [16] A. S. de Paula, *Sistemas de Sensoriamento Espectral Cooperativos*, Ph.D. thesis, EPUSP, 2014.
- [17] Sheng-Yuan Tu and A.H. Sayed, "Diffusion strategies outperform consensus strategies for distributed estimation over adaptive networks," *Signal Processing, IEEE Transactions on*, vol. 60, no. 12, pp. 6217–6234, Dec 2012.
- [18] F.S. Cattivelli and A.H. Sayed, "Diffusion LMS strategies for distributed estimation," *Signal Processing, IEEE Transactions on*, vol. 58, no. 3, pp. 1035–1048, march 2010.
- [19] P. S. R. Diniz, *Adaptive Filtering: Algorithms and Practical Implementation*, Springer, 2008.
- [20] M.V.S. Lima and P.S.R. Diniz, "On the steady-state MSE performance of the set-membership NLMS algorithm," in *7th International Symposium on Wireless Communication Systems (ISWCS), 2010*, Sept. 2010, pp. 389–393.