

# Nova Estratégia de Distribuição de Ganho de Adaptação Aplicada ao Algoritmo IAF-PNLMS

Fábio Luis Perez, Francisco das Chagas de Souza e Rui Seara

**Resumo**—Este artigo apresenta uma abordagem alternativa à política de distribuição de ganho usada no algoritmo IAF-PNLMS (*individual-activation-factor proportionate normalized least-mean-square*). Através da estimativa da taxa de variação da magnitude dos coeficientes, o novo algoritmo reduz o ganho atribuído aos coeficientes ativos que atingiram convergência, i.e., que alcançaram a vizinhança de seu valor ótimo, redistribuindo-o a outros coeficientes. A abordagem proposta leva a uma melhor distribuição de ganho do que a do IAF-PNLMS original, melhorando a velocidade de convergência global do algoritmo como também reduzindo o desalinhamento em regime permanente. Resultados de simulação mostram a eficácia da abordagem proposta.

**Palavras-Chave**—Algoritmo IAF-PNLMS, convergência dos coeficientes, filtragem adaptativa, identificação de sistemas.

**Abstract**—This paper presents an alternative approach to the gain distribution policy used in the individual-activation-factor proportionate normalized least-mean-square (IAF-PNLMS) algorithm. Through the estimate of the coefficient magnitude variation rate, the new algorithm reduces the gain assigned to the active coefficients that have achieved convergence, i.e., that have attained the vicinity of their optimal values, redistributing it to the other coefficients. The novel approach leads to a better gain distribution than that of the IAF-PNLMS algorithm, increasing the global convergence speed as well as reducing the misalignment in steady state. Simulation results show that the proposed algorithm outperforms the IAF-PNLMS in all assessed scenarios.

**Keywords**—IAF-PNLMS algorithm, coefficient convergence, adaptive filtering, system identification.

## I. INTRODUÇÃO

Os algoritmos LMS (*least-mean-square*) e NLMS (*normalized LMS*) são bastante populares em aplicações de filtragem adaptativa, devido principalmente à sua baixa complexidade e muito boa característica de estabilidade [1], [2]. Contudo, para muitas aplicações reais, tais como cancelamento de eco, equalização de canais e processos sísmicos, na qual a resposta ao impulso da planta é esparsa [3]-[5], esses algoritmos (que utilizam o mesmo valor de passo de adaptação para todos os coeficientes do filtro) têm suas

Fábio Luis Perez e Rui Seara, LINSE – Laboratório de Circuitos e Processamento de Sinais, Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, SC, e-mails: fabioperez@linse.ufsc.br; seara@linse.ufsc.br.

Fábio Luis Perez é também Professor do Departamento de Engenharia Elétrica e Telecomunicações da Universidade Regional de Blumenau (FURB), Blumenau, SC, Brasil.

Francisco das Chagas de Souza, LSAPS - Laboratório de Sistemas Adaptativos e Processamento de Sinais, Departamento de Engenharia de Eletricidade, Universidade Federal do Maranhão, São Luis-MA, Brasil, e-mail: fsouza@dee.ufma.br.

Este trabalho foi parcialmente financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

características de convergência prejudicadas [6]-[8]. Visando melhorar o desempenho de convergência para ambientes com respostas ao impulso esparsas, o algoritmo PNLMS (*proportionate NLMS*) é proposto em [9]. O PNLMS utiliza ganho individual para atualizar cada coeficiente do filtro proporcionalmente à sua magnitude, resultando em um algoritmo com maior velocidade de convergência. Entretanto, sua convergência rápida inicial não é mantida durante todo o processo adaptativo [8], [10]. Além disso, o algoritmo PNLMS apresenta baixa velocidade de convergência para plantas com média e baixa esparsidades [6], [7]. Para contornar tais problemas, diversas versões do algoritmo PNLMS vêm sendo propostas na literatura [6], [7], [8], [11]-[13]. Por exemplo, o PNLMS++ alterna entre os algoritmos NLMS e PNLMS nas iterações pares e ímpares [6]. O IPNLMS (*improved PNLMS*) também emprega uma mistura de adaptação proporcional e não proporcional. Essa mistura (controlada por um específico parâmetro) é realizada a cada iteração, o que proporciona uma melhor característica de convergência (do que aquela do algoritmo PNLMS) para uma maior faixa de valores de esparsidade [7]. Utilizando fatores de ativação individuais, os algoritmos IAF-PNLMS (*individual-activation-factor PNLMS*) e EIAF-PNLMS (*enhanced IAF-PNLMS*) são introduzidos em [12] e [13], respectivamente. Tais algoritmos exibem maior velocidade de convergência para plantas com resposta ao impulso de alta esparsidade. Buscando maior robustez com vistas a variações de esparsidade da planta, os algoritmos SC-PNLMS (*sparseness controlled PNLMS*) e SC-IPNLMS (*sparseness controlled IPNLMS*) são apresentados em [14] e [15], respectivamente. Esses algoritmos possuem um desempenho muito bom para plantas com média e alta esparsidades; no entanto, tais algoritmos são computacionalmente muito mais complexos do que o PNLMS. Visando prover rápida velocidade de convergência durante todo o processo de adaptação, os algoritmos PNLM com lei  $\mu$  (MPNLMS) e o AMPNLMS (*adaptive MPNLMS*) são discutidos em [10] e [16], respectivamente; contudo, ambos os algoritmos apresentam também elevada carga computacional. Baseado na minimização do erro quadrático médio para sinal de entrada branco, o algoritmo *water-filling* é discutido em [16] e [17]. Também em [17], visando reduzir a complexidade computacional do *water-filling*, o algoritmo proporcional ao desvio quadrático médio dos coeficientes ( $z^2$ -*proportionate*) é introduzido. Em contraste com os algoritmos tipo PNLMS, que determinam o ganho em função da magnitude dos coeficientes, esses algoritmos usam uma estimativa do desvio quadrático médio dos coeficientes combinado com um ganho unitário, tal que a distribuição de ganho de adaptação seja uniforme em regime permanente. Essa combinação se faz necessária visto que o ruído de medição se torna preponderante no sinal de erro, degradando a estimativa do desvio quadrático médio dos coeficientes em regime permanente.

Neste trabalho, uma nova estratégia de distribuição de ganho de adaptação aplicada ao algoritmo IAF-PNLMS é apresentada. A abordagem proposta considera que a filosofia

proporcional, a qual é o fundamento básico dos algoritmos do tipo proporcional, não necessita ser aplicada durante todo o processo adaptativo, visto que atribuir ganhos elevados a coeficientes que tenham encontrado a vizinhança de seu valor ótimo não tem praticamente efeito algum sobre a convergência global do algoritmo [13]. Assim, essa nova estratégia é aqui aplicada ao algoritmo IAF-PNLMS. O algoritmo resultante supera o IAF-PNLMS em termos de características de convergência para plantas com resposta ao impulso de alta e média esparsidades. Através de simulações numéricas, usando, como modelo de plantas, respostas ao impulso de caminho de eco reais, a efetividade do algoritmo proposto é avaliada.

Este artigo está organizado como segue. A Seção II revisita o algoritmo IAF-PNLMS e apresenta uma breve discussão de sua distribuição de ganho. A Seção III apresenta o algoritmo proposto, descrevendo um procedimento para a estimativa da taxa de variação da magnitude do coeficiente, usada como métrica de convergência do coeficiente. Na Seção IV, resultados de simulação numérica atestam o desempenho do algoritmo proposto. Finalmente, a Seção V apresenta os comentários e conclusões deste trabalho de pesquisa.

## II. REVISITANDO O ALGORITMO IAF-PNLMS

Nesta seção, uma revisão das expressões gerais do algoritmo IAF-PNLMS é apresentada bem como uma breve discussão sobre sua estratégia de distribuição de ganho.

### A. Algoritmo IAF-PNLMS

O algoritmo IAF-PNLMS é formulado pelo seguinte conjunto de equações [12]:

Atualização dos coeficientes

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \frac{\beta \mathbf{G}(k) \mathbf{x}(k) e(k)}{\mathbf{x}^T(k) \mathbf{G}(k) \mathbf{x}(k) + \xi} \quad (1)$$

Sinal de erro

$$e(k) = d(k) - \mathbf{w}^T(k) \mathbf{x}(k) + v(k) \quad (2)$$

Matriz de distribuição de ganho

$$\mathbf{G}(k) = \text{diag}[g_1(k) \ g_2(k) \ \dots \ g_N(k)] \quad (3)$$

Ganho individual

$$g_i(k) = \frac{\phi_i(k)}{\sum_{l=1}^N \phi_l(k)}, \quad i = 1, 2, \dots, N \quad (4)$$

Função de proporcionalidade

$$\phi_i(k) = \max[f_i(k), |w_i(k)|] \quad (5)$$

Fator de ativação individual

$$f_i(k) = \begin{cases} \frac{1}{2} |w_i(k)| + \frac{1}{2} \phi_i(k-1), & k = mN, m = 1, 2, 3, \dots \\ f_i(k-1), & \text{caso contrário} \end{cases} \quad (6)$$

onde  $\beta$  é o parâmetro de passo,  $\xi > 0$  é um parâmetro de regularização que previne a divisão por zero em (1) e estabiliza a solução. A variável  $d(k)$  denota o sinal desejado e  $v(k)$ , um sinal de ruído independente e identicamente distribuído (i.i.d.) com média zero e variância  $\sigma_v^2$ . Os vetores

$\mathbf{x}(k) = [x(k) \ x(k-1) \ \dots \ x(k-N+1)]^T$  e  $\mathbf{w}(k) = [w_1(k) \ w_2(k) \ \dots \ w_N(k)]^T$  representam, respectivamente, o sinal de entrada e os coeficientes adaptativos, ambos de dimensão  $N$ .

### B. Avaliação da Distribuição de Ganho do Algoritmo IAF-PNLMS

Nesta seção, uma breve análise da política de distribuição de ganho do algoritmo IAF-PNLMS é apresentada. Essa política está diretamente associada à magnitude do coeficiente e aos fatores de ativação individuais.

Visto que o termo no denominador em (4) é comum para todos os ganhos  $g_i(k)$ , com vistas à simplificação da notação, esse termo é expresso aqui por

$$\Phi(k) = \sum_{l=1}^N \phi_l(k). \quad (7)$$

Assim, de (4), (5) e (6), pode-se elencar as seguintes propriedades [12]:

i) Fator de ativação para coeficientes ativos. No instante  $k = mN$ , o fator de ativação  $f_i(k)$  é dado por

$$f_i(mN) = \frac{1}{2} |w_i(mN-1)| + \frac{1}{2} |w_i(mN)| \quad (8)$$

e a função de proporcionalidade  $\phi_i(k)$  é

$$\phi_i(mN) = \max \left\{ \frac{1}{2} |w_i(mN-1)| + \frac{1}{2} |w_i(mN)|, |w_i(mN)| \right\}. \quad (9)$$

ii) Fator de ativação para coeficientes inativos. No instante  $k = mN$ , o fator de ativação  $f_i(k)$  é dado por

$$f_i(mN) = \frac{1}{2^m} f_i(0) + \frac{1}{2^m} |w_i(N)| + \frac{1}{2^{m-1}} |w_i(2N)| + \dots + \frac{1}{2} |w_i(mN)| \quad (10)$$

e a função de proporcionalidade  $\phi_i(k)$  é

$$\phi_i(mN) = \max \left\{ \frac{1}{2^m} f_i(0) + \frac{1}{2^m} |w_i(N)| + \frac{1}{2^{m-1}} |w_i(2N)| + \dots + \frac{1}{2} |w_i(mN)|, |w_i(mN)| \right\}. \quad (11)$$

À medida que  $m$  aumenta e  $|w_i(mN-1)| \rightarrow |w_i(mN)|$ , pode-se observar que  $\phi_i(mN) \rightarrow |w_i(mN)|$  tanto para coeficientes ativos quanto inativos; dessa forma, o ganho individual  $g_i(mN)$  tende a ser proporcional a  $|w_i(mN)|$  para todos os coeficientes do filtro. Além disso, o ganho total distribuído aos coeficientes pode ser determinado por

$$\begin{aligned} g_{\text{total}}(k) &= g_1(k) + g_2(k) + \dots + g_N(k) \\ &= \frac{\phi_1(k) + \phi_2(k) + \dots + \phi_N(k)}{\sum_{l=1}^N \phi_l(k)} = 1. \end{aligned} \quad (12)$$

Note que, como resultado da normalização, o ganho total distribuído dentre os coeficientes é constante. Como consequência dessa política de distribuição de ganho, o algoritmo IAF-PNLMS atribui ganhos mais altos aos coeficientes com maiores magnitudes (mais significativos) do que o PNLMS e, por essa razão, alcança uma velocidade de convergência inicial maior para plantas exibindo alta

esparsidade. Entretanto, como o ganho total é constante [veja (12)], para atribuir ganhos mais elevados aos coeficientes mais significativos, o algoritmo IAF-PNLMS diminui o ganho atribuído aos coeficientes inativos. Como resultado, depois da convergência dos coeficientes ativos, a velocidade de convergência global é fortemente afetada, visto que o ganho alocado aos coeficientes inativos é baixo. Ressalta-se aqui que, em virtude do ganho atribuído aos coeficientes ativos permanecer alto (mesmo após esses coeficientes alcançarem a vizinhança de seus valores ótimos), o ganho alocado aos coeficientes inativos se mantém baixo por todo o processo adaptativo.

Na próxima seção, uma nova estratégia (baseada na convergência individual do coeficiente) visando redefinir a distribuição de ganho usada no algoritmo IAF-PNLMS é proposta. Para tal, a nova abordagem “reduz” o ganho atribuído a coeficientes que já atingiram a convergência e o “redistribui” dentre aqueles que ainda não convergiram, i.e., os que não alcançaram a vizinhança de seu valor ótimo; como resultado, o novo algoritmo aumenta a velocidade de convergência e reduz o desalinhamento em regime permanente quando comparado com o algoritmo IAF-PNLMS original.

### III. ALGORITMO PROPOSTO

A estratégia de distribuição de ganho aqui discutida visa realocar para outros coeficientes o ganho atribuído aos coeficientes que tenham atingido a vizinhança  $\Psi_o$  de seu valor ótimo, definida como [13]

$$|w_i^0 - w_i(\kappa_i)| \leq \Psi_o, \quad i=1,2,\dots,N \quad (13)$$

onde  $w_i^0$  denota o  $i$ -ésimo coeficiente da planta e  $\kappa_i$ , o número de iterações necessário para que o  $i$ -ésimo coeficiente do filtro adaptativo atinja sua convergência. Assim, no instante  $\kappa_i$ , o coeficiente  $w_i(k)$  praticamente convergiu e não mais requer um ganho proporcional à sua magnitude. Dessa forma, através da avaliação de convergência do coeficiente, a expressão de ganho individual do algoritmo IAF-PNLMS é substituída por

$$g_i(k) = \begin{cases} \frac{1}{N\Phi(k)}, & |w_i^0 - w_i(\kappa_i)| \leq \Psi_o \\ \frac{1}{\Phi(k)}\phi_i(k), & \text{caso contrário.} \end{cases} \quad (14)$$

A partir de (14), pode-se constatar que o conhecimento *a priori* da resposta ao impulso da planta  $\mathbf{w}^0$  é requerido, o que geralmente não está disponível em aplicações reais. Assim, para contornar tal problema, uma estimativa da taxa de variação da magnitude do coeficiente como uma métrica para a avaliação de convergência do coeficiente é utilizada. Para tal, a seguinte estratégia é aplicada:

$$V_i(k) = \begin{cases} \frac{|Q_i(k) - P_i(k)|}{\min[Q_i(k), P_i(k)]}, & k = m\Delta, \quad m = 1, 2, 3, \dots \\ V_i(k-1), & \text{caso contrário} \end{cases} \quad (15)$$

com

$$Q_i(k) = |w_i(k)| + |w_i(k-1)| + \dots + |w_i(k - \frac{\Delta}{2} + 1)|, \quad 1 \leq i \leq N \quad (16)$$

e

$$P_i(k) = |w_i(k - \frac{\Delta}{2})| + |w_i(k - \frac{\Delta}{2} - 1)| + \dots + |w_i(k - \Delta + 1)|, \quad 1 \leq i \leq N \quad (17)$$

onde  $\Delta$  define o número de amostras de  $w_i(k)$  usada para estimar a taxa de variação da magnitude do correspondente coeficiente. As variáveis  $P_i(k)$  e  $Q_i(k)$  denotam a somatória da magnitude do coeficiente  $w_i(k)$  na primeira e segunda metade do intervalo  $\Delta$ , respectivamente,  $V_i(k)$  caracteriza a estimativa da taxa de variação da magnitude do coeficiente. As estimativas da taxa de variação são computadas por (15)-(17) somente a cada  $\Delta$  iterações e após um período de aprendizagem de  $N$  amostras. Assim, considerando a estimativa da taxa de variação da magnitude obtida a partir de (15), o ganho individual do  $i$ -ésimo coeficiente dado por (14) é revisado para

$$g_i(k) = \begin{cases} \frac{1}{N\Phi(k)}, & V_i(k) \leq \varepsilon \\ \frac{1}{\Phi(k)}\phi_i(k), & \text{caso contrário} \end{cases} \quad (18)$$

com  $\varepsilon$  sendo um parâmetro de limiar.

#### A. Nova Política de Distribuição de Ganho

Visando simplificar a análise da distribuição de ganho, é assumido aqui que o fator de proporcionalidade seja igual à magnitude do coeficiente, i.e.,  $\phi_i(k) = |w_i(k)|$ . Tal condição é verdadeira para coeficientes ativos e caracteriza uma aproximação para os inativos [veja (9) e (11)]. No entanto, como a velocidade de convergência dos coeficientes inativos do algoritmo IAF-PNLMS é baixa, é plausível admitir que uma eventual mudança de ganho (devido à proximidade do coeficiente ao seu valor ótimo) ocorrerá quando  $\phi_i(k) \equiv |w_i(k)|$ . Assim, assumindo que  $\phi_i(k)$  seja igual a  $|w_i(k)|$  para todos os coeficientes no algoritmo IAF-PNLMS, as seguintes considerações são estabelecidas:

- i) Ganho dos coeficientes que atingiram a convergência  $g_i^{\text{conv}}(k)$ . Se  $V_i(k) \leq \varepsilon$ , é assumido que o  $i$ -ésimo coeficiente  $w_i(k)$  convergiu e seu ganho associado, obtido a partir de (18), é

$$g_i^{\text{conv}}(k) = \frac{1}{N\Phi(k)}. \quad (19)$$

- ii) Ganho dos coeficientes que não atingiram a convergência  $g_i^{\text{nconv}}(k)$ . Se  $V_i(k) > \varepsilon$ , é assumido que o  $i$ -ésimo coeficiente  $w_i(k)$  não convergiu e seu ganho associado, dado por (18), é expresso como

$$g_i^{\text{nconv}}(k) = \frac{1}{\Phi(k)}|w_i(k)| \quad (20)$$

onde  $\Phi(n)$  é o fator de normalização dado por (7).

Dessa forma, o ganho total do novo algoritmo pode ser expresso como

$$g_{\text{total}} = \frac{1}{\Phi(k)} \left[ \sum_{i \in (A+B-C)} |w_i(k)| + \sum_{i \in C} \frac{1}{N} \right] = 1 \quad (21)$$

onde  $A$  é o conjunto de índices associados com as posições dos coeficientes ativos,  $B$ , associado aos inativos e  $C$ , associado aos coeficientes que já atingiram a convergência. Visto que o número de coeficientes que atingem a convergência, denotado aqui por  $N_{\text{conv}}(k)$ , se altera durante o processo adaptativo, os valores e quantidades de elementos nas duas parcelas no segundo termo de (21) são variáveis e apresentam as seguintes características:

a) No início, não há coeficientes que atingiram a convergência, portanto  $N_{\text{conv}}(k)=0$  e, por consequência,  $C$  é um conjunto vazio. Nessa situação, a distribuição de ganho do novo algoritmo é idêntica à do IAF-PNLMS original; assim, a velocidade de convergência inicial do IAF-PNLMS é também mantida para o algoritmo proposto.

b) À medida que os coeficientes se aproximam de seu valor ótimo, a taxa de variação da magnitude diminui e, assim que  $V_i(k) \leq \varepsilon$ , é assumido que o coeficiente  $w_i(k)$  atingiu a convergência. Com isso, há uma alteração no valor de  $N_{\text{conv}}(k)$  e  $C$  deixa de ser um conjunto vazio. Dessa forma, o número de elementos associados à primeira parcela do lado direito de (21) diminui, aumentando o número de coeficientes com ganho igual a  $1/N$ ; como resultado, o ganho atribuído aos coeficientes ativos [primeira parcela do lado direito de (21)] é reduzido. Em uma situação ideal (em regime permanente), todos os coeficientes atingiriam a convergência; como consequência,  $N_{\text{conv}}(k)=N$  e  $(A-C) \rightarrow \emptyset$ , de modo que todos os coeficientes receberiam o mesmo ganho  $1/N$  e o algoritmo se comportaria agora como o NLMS.

c) Sempre que um coeficiente atingir a convergência, seu ganho associado muda de  $\frac{1}{\Phi(k)} |w_i(k)|$  para  $\frac{1}{N\Phi(k)}$ ; assim, o ganho distribuído aos demais coeficientes é igual à diferença dos ganhos dada por

$$dif_i(k) = \frac{1}{\Phi(k)} |w_i(k)| - \frac{1}{N\Phi(k)} = \frac{1}{\Phi(k)} \left[ |w_i(k)| - \frac{1}{N} \right]. \quad (22)$$

Note que, quanto maior a magnitude do coeficiente, maior será o ganho distribuído aos demais coeficientes. Ressalta-se ainda que outros métodos para avaliar a convergência do coeficiente podem ser considerados em (18) sem alterar a distribuição de ganho proposta.

### B. Complexidade Computacional

Com respeito à carga computacional do algoritmo proposto comparada à do algoritmo IAF-PNLMS, observa-se um aumento de complexidade devido à computação requerida por (15)-(17) (veja Tabela I). Além disso,  $N$  comparações adicionais são requeridas para avaliar se a taxa de variação da magnitude do coeficiente é igual ou menor do que o limiar de convergência  $\varepsilon$ . Note que o algoritmo proposto exige adicionalmente  $N(N-1)$  adições,  $N$  divisões e  $N$  comparações a cada  $\Delta$  iterações. A Tabela I mostra uma comparação de carga computacional considerando  $\Delta=N$ ; dessa forma, verifica-se que o algoritmo proposto requer  $N-1$  adições, 1 divisão e 1 comparação suplementares por iteração.

TABELA I. Comparação de Carga Computacional com  $\Delta=N$

Algoritmo	Adições	Multiplicações	Divisões	Comparações
IAF-PNLMS	$4N$	$4N+3$	1	$N$
Proposto	$5N-1$	$4N+3$	2	$N+1$

### IV. RESULTADOS DE SIMULAÇÃO

Nesta seção, o desempenho do algoritmo proposto é avaliado. Para tal, simulações de Monte Carlo (média de 100 realizações independentes) são realizadas considerando um problema de identificação de sistema. Em nossas simulações, duas respostas ao impulso de planta com comprimento  $N=128$  são utilizadas. Tais respostas são obtidas a partir dos

modelos de caminho de eco definidas pela Recomendação G.168 do ITU-T [18, Modelos 1 e 4], denominadas aqui  $\mathbf{w}_A^0$  e  $\mathbf{w}_B^0$ , apresentando graus de esparsidade (veja definição em [13]) 0,78 e 0,43, respectivamente. Para todos os exemplos, é considerado um sinal de entrada com média zero e variância  $\sigma_x^2$  unitária, um ruído de medição branco com variância  $\sigma_v^2=0,001$  ( $\text{SNR}=30 \text{ dB}$ ), passo de adaptação  $\beta=0,1$ , fator de ativação inicial  $f_i(0)=10^{-4}$  e parâmetro de regularização  $\xi=10^{-4}$ . Para o algoritmo proposto, o número de amostras  $\Delta$  utilizado para computar a taxa de variação da magnitude do coeficiente é  $N$ , i.e., igual ao comprimento do filtro adaptativo. O parâmetro de limiar utilizado é  $\varepsilon=5\times10^{-2}$ .

#### A. Exemplo 1

Neste exemplo, o comportamento do algoritmo proposto é avaliado com respeito à esparsidade da planta considerando um sinal de entrada branco. Para tal, a resposta ao impulso da planta inicial  $\mathbf{w}_A^0$  é mudada para a resposta  $\mathbf{w}_B^0$  na iteração  $k=10000$ . A Fig. 1 mostra as curvas de desalinhamento normalizado (veja definição em [12]) do algoritmo IAF-PNLMS original e do algoritmo proposto. Observa-se que o algoritmo proposto supera o IAF-PNLMS independentemente do grau de esparsidade da planta.

#### B. Exemplo 2

Este exemplo ilustra o comportamento do algoritmo proposto considerando uma perturbação na resposta ao impulso da planta. Para tal, um sinal de entrada branco é aplicado e o vetor de coeficientes da planta  $\mathbf{w}_A^0$  é deslocado de 12 amostras para a direita na iteração  $k=10000$ . A Fig. 2 ilustra as curvas de desalinhamento normalizado do algoritmo IAF-PNLMS original e do algoritmo proposto. A partir da Fig. 2, constata-se que o algoritmo proposto novamente apresenta características de convergência melhores do que a do IAF-PNLMS.

#### C. Exemplo 3

Neste exemplo, o comportamento do algoritmo proposto é avaliado, considerando a planta esparsa  $\mathbf{w}_A^0$  e um sinal de entrada correlacionado, obtido de um processo AR(2) dado por

$$x(k) = b_1 x(k-1) + b_2 x(k-2) + \eta(k) \quad (23)$$

onde  $\eta(k)$  é um sinal branco com variância  $\sigma_\eta^2=0,36$ ,  $b_1=0,75$  e  $b_2=-0,75$ , resultando em uma dispersão dos autovalores da matriz de autocorrelação do vetor de entrada  $\chi=120$ . A Fig. 3 mostra as curvas de desalinhamento normalizado dos algoritmos avaliados. Note que, independente da correlação do sinal de entrada, o algoritmo proposto supera o algoritmo IAF-PNLMS.

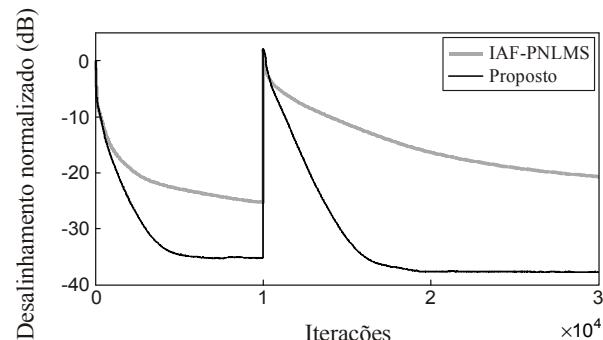


Fig. 1. Exemplo 1. Curvas de desalinhamento normalizado dos algoritmos IAF-PNLMS e proposto para sinal de entrada branco e  $\text{SNR}=30 \text{ dB}$ . A resposta ao impulso da planta  $\mathbf{w}_A^0$  é mudada para resposta  $\mathbf{w}_B^0$  na iteração  $k=10000$ .

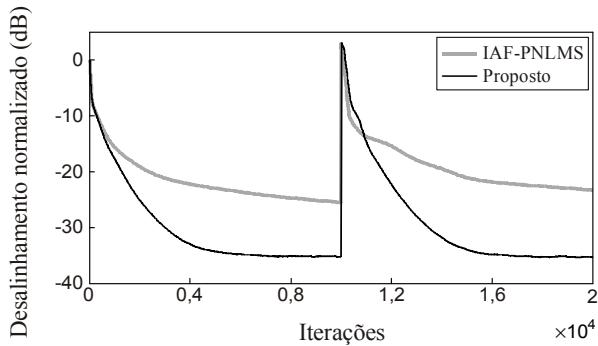


Fig. 2. Exemplo 2. Curvas de desalinhamento normalizado dos algoritmos IAF-PNLMS e proposto para sinal de entrada branco e SNR = 30 dB. A resposta ao impulso da planta  $w_A^0$  é deslocada de 12 amostras para a direita na iteração  $k=10000$ .

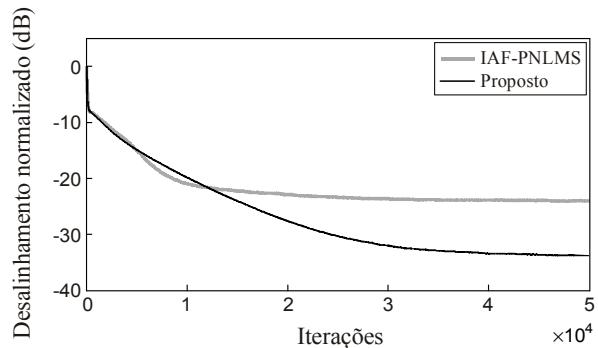


Fig. 3. Exemplo 3. Curvas de desalinhamento normalizado dos algoritmos IAF-PNLMS e proposto para sinal de entrada correlacionado e SNR = 30 dB.

## VI. COMENTÁRIOS E CONCLUSÕES FINAIS

Neste trabalho, uma abordagem alternativa à política de distribuição de ganho usada no algoritmo IAF-PNLMS foi discutida. Tal abordagem reduz o ganho atribuído aos coeficientes ativos que alcançaram a vizinhança de seu valor ótimo, i.e., que atingiram convergência, redistribuindo essa parcela de ganho a coeficientes que ainda não convergiram. A nova estratégia utiliza uma estimativa da taxa de variação da magnitude do coeficiente como uma métrica de avaliação de convergência do coeficiente. Resultados de simulação mostraram que o novo algoritmo melhorou consideravelmente a taxa de convergência (para todos os cenários avaliados), quando comparada com a do algoritmo IAF-PNLMS original.

## REFERÊNCIAS

- [1] B. Widrow and S. D. Stearns, *Adaptive Signal Processing*. Englewood Cliffs, NJ: Prentice-Hall, 1985.
- [2] S. Haykin, *Adaptive Filter Theory*, 4th ed. Upper Saddle River, NJ: Prentice-Hall, 2002.
- [3] R. K. Martin, W. A. Sethares, R. C. Williamson, and C. R. Johnson, Jr., “Exploiting sparsity in adaptive filters,” *IEEE Trans. Signal Process.*, vol. 50, no. 8, pp. 1883-1894, Aug. 2002.
- [4] Y. Huang, J. Benesty, and J. Chen, *Acoustic MIMO Signal Processing*. Secaucus, NJ: Springer-Verlag, 2006.
- [5] C. Paleologu, J. Benesty, and S. Ciochina, *Sparse Adaptive Filters for Echo Cancellation*. San Rafael, CA: Morgan and Claypool, 2010.
- [6] S. L. Gay, “An efficient, fast converging adaptive filter for network echo cancellation,” in *Proc. 32nd Asilomar Conf. Signals, Syst. Comput.*, Pacific Grove, CA, Nov. 1998, vol. 1, pp. 394-398.
- [7] J. Benesty and S. L. Gay, “An improved PNLS algorithm,” in *Proc. IEEE Int. Conf. Acoust., Speech, Signal Process. (ICASSP)*, Orlando, FL, May 2002, vol. 2, pp. 1881-1884.

- [8] P. A. Naylor, J. Cui, and M. Brookes, “Adaptive algorithms for sparse echo cancellation,” *Signal Process.*, vol. 86, no. 6, pp. 1182-1192, Jun. 2006.
- [9] D. L. Duttweiler, “Proportionate normalized least-mean-squares adaptation in echo cancelers,” *IEEE Trans. Speech Audio Process.*, vol. 8, no. 5, pp. 508-518, Sept. 2000.
- [10] H. Deng and M. Doroslovacki, “Proportionate adaptive algorithms for network echo cancellation,” *IEEE Trans. Signal Process.*, vol. 54, no. 5, pp. 1794-1803, May 2006.
- [11] H. Deng and M. Doroslovacki, “Improving convergence of the PNLS algorithm for sparse impulse response identification,” *IEEE Signal Process. Lett.*, vol. 12, no. 3, pp. 181-184, Mar. 2005.
- [12] F. das C. de Souza, O. J. Tobias, R. Seara, and D. R. Morgan, “A PNLS algorithm with individual activation factors,” *IEEE Trans. Signal Process.*, vol. 58, no. 4, pp. 2036-2047, Apr. 2010.
- [13] F. das C. de Souza, R. Seara, and D. R. Morgan, “An enhanced IAF-PNLMS adaptive algorithm for sparse impulse response identification,” *IEEE Trans. Signal Process.*, vol. 60, no. 6, pp. 3301-3307, Jun. 2012.
- [14] P. Loganathan, A. W. H. Khong, and P. A. Naylor, “A sparseness-controlled proportionate algorithm for acoustic echo cancellation,” in *Proc. Eur. Signal Process. Conf. (EUSIPCO)*, Lausanne, Switzerland, Aug. 2008, pp. 1-5.
- [15] A. W. H. Khong and P. A. Naylor, “Efficient use of sparse adaptive filters,” in *Proc. 40th Asilomar Conf. Signals, Syst. Comput.*, Pacific Grove, CA, Oct 2006, pp. 1375-1379.
- [16] K. T. Wagner and M. I. Doroslovacki, “Gain allocation in proportionate-type NLMS algorithms for fast decay of output error at all times,” in *Proc. IEEE Int. Conf. Acoust., Speech, Signal Process. (ICASSP)*, Taipei, Taiwan, April 2009, pp. 3117-3120.
- [17] K. Wagner and M. Doroslovacki, “Proportionate-type normalized least mean square algorithms with gain allocation motivated by mean-square-error minimization for white input,” *IEEE Trans. Signal Process.*, vol. 59, no. 5, pp. 2410-2415, May 2011.
- [18] ITU-T Recommendation G.168, *Digital Network Echo Cancellers*, Geneva, Switzerland: Int. Telecomm. Union, 2007.