

Análise Estatística do Algoritmo ϵ LMS no Domínio Transformado em Ambientes Não-estacionários

Elen M. Lobato, Orlando J. Tobias e Rui Seara

Resumo—Este artigo propõe um modelo analítico do algoritmo ϵ LMS no domínio transformado (TD- ϵ LMS) operando em um ambiente não-estacionário. O modelo é derivado para sinais de entrada Gaussianos, grau de não-estacionariedade pequeno e condição de adaptação lenta. Através de simulações numéricas, constata-se uma boa concordância entre os resultados de simulação Monte Carlo e os obtidos através do modelo proposto, tanto para o comportamento médio dos coeficientes quanto para o erro quadrático médio.

Palavras-Chave—Domínio transformado, filtragem adaptativa, modelagem estatística, não-estacionariedade.

Abstract—This paper proposes an analytical model of the transform-domain ϵ LMS algorithm (TD- ϵ LMS) operating in a nonstationary environment. The model is derived for Gaussian inputs, small degree of nonstationary, and slow adaptation condition. Through numerical simulations one verifies a very good agreement between the results obtained by the Monte Carlo method and the ones from the proposed analytical model for both mean coefficient behavior and mean-square error.

Keywords—Transform domain, adaptive filtering, statistical modeling, nonstationary.

I. INTRODUÇÃO

O algoritmo LMS é um dos algoritmos mais empregados em filtragem adaptativa [1]-[3]. Isso se deve à sua simplicidade, robustez e baixa complexidade computacional requeridas em muitas aplicações. Entretanto, esse algoritmo apresenta uma séria limitação quando o sinal de entrada é correlacionado: sua velocidade de convergência torna-se muito baixa. Com vistas a superar tal problema, Narayan *et al.* [4] introduziram o algoritmo LMS no domínio transformado (TD-LMS). Nesse algoritmo, o sinal de entrada é pré-processado pela transformada discreta de Fourier (TDF), ou por alguma outra transformação ortogonal. Após tal transformação, o passo de adaptação é normalizado segundo a potência média do sinal de entrada para cada coeficiente do filtro adaptativo.

Elen M. Lobato, Orlando J. Tobias e Rui Seara, LINSE – Laboratório de Circuitos e Processamento de Sinais, Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, SC, E-mails: {elen, orlando, seara}@linse.ufsc.br.

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

A análise estatística do algoritmo TD-LMS como também do TD- ϵ LMS para ambientes estacionários tem sido objeto de um bom número de trabalhos apresentados na literatura [5]-[10]. No entanto, para ambientes não-estacionários, em nosso conhecimento, somente umas poucas análises constam da literatura da área. Em [11], uma análise do algoritmo adaptativo para ambientes não-estacionários usando uma abordagem baseada em energia é discutida. Uma característica interessante dessa análise é a independência do tipo de não-linearidade usado e da função densidade de probabilidade do sinal de entrada considerada. Contudo, tal abordagem não permite obter modelos teóricos para prever a evolução do comportamento médio dos pesos e do erro quadrático médio.

Este artigo tem como propósito desenvolver uma análise estatística do algoritmo TD- ϵ LMS para o caso de ambientes não-estacionários.

O artigo está organizado como segue. A Seção II apresenta a formulação do problema de rastreamento de uma planta variante no tempo. Na Seção III, é definido o vetor de erro do algoritmo TD- ϵ LMS para uma planta variante. A análise estatística do algoritmo TD- ϵ LMS é considerada na Seção IV. A Seção V apresenta e discute os resultados obtidos via simulação Monte Carlo (MC) e através do modelo estatístico proposto. Finalmente, na Seção VI, são expostas as conclusões finais do trabalho.

II. FORMULAÇÃO DO PROBLEMA DE RASTREAMENTO

O sinal desejado é modelado como sendo um regressor linear múltiplo caracterizado pela seguinte equação [2]:

$$d(n) = \mathbf{x}^T(n) \mathbf{w}^o(n) + z(n), \quad (1)$$

onde $\mathbf{x}(n) = [x(n) \ x(n-1) \ \dots \ x(n-N+1)]^T$ é o vetor constituído pelo sinal de entrada; $\mathbf{w}^o(n) = [w_0^o(n) \ w_1^o(n) \ \dots \ w_{N-1}^o(n)]^T$ é o vetor de coeficientes da planta; e $z(n)$ representa o ruído de medição. Mapeando-se os vetores $\mathbf{x}(n)$ e $\mathbf{w}^o(n)$ para o domínio transformado, obtém-se $\mathbf{w}_T^o(n) = \mathbf{T} \mathbf{w}^o(n)$ e $\mathbf{x}_T(n) = \mathbf{T} \mathbf{x}(n)$ [2], onde \mathbf{T} é a matriz de transformação ortogonal. Assim, pode-se rescrever (1) como

$$d(n) = \mathbf{x}_T^T(n) \mathbf{w}_T^o(n) + z(n), \quad (2)$$

onde $\mathbf{x}_T(n) = [x_{T,0}(n) \ x_{T,1}(n) \ \dots \ x_{T,N-1}(n)]^T$ é o vetor do

sinal de entrada transformado e $\mathbf{w}_T^o(n) = [w_{T,0}^o(n) \ w_{T,1}^o(n) \ \dots \ w_{T,N-1}^o(n)]^T$ é o vetor de coeficientes da planta, representados no domínio transformado. O vetor de coeficientes da planta variante é um processo caracterizado pela seguinte equação de diferenças:

$$\mathbf{w}_T^o(n+1) = \mathbf{w}_T^o(n) + \mathbf{g}(n), \quad (3)$$

onde $\mathbf{g}(n)$ é o vetor de perturbação do processo.

III. ALGORITMO ϵ LMS NO DOMÍNIO TRANSFORMADO (TD- ϵ LMS)

A equação de adaptação do vetor de coeficientes do algoritmo TD- ϵ LMS [2] é dada por

$$\mathbf{w}_T(n+1) = \mathbf{w}_T(n) + 2\mu\mathbf{D}^{-1}(n)e(n)\mathbf{x}_T(n), \quad (4)$$

onde $e(n)$ representa o sinal de erro escrito como

$$e(n) = d(n) - \mathbf{x}_T^T(n)\mathbf{w}_T(n). \quad (5)$$

Em (4), o vetor $\mathbf{w}_T(n) = [w_{T,0}(n) \ w_{T,1}(n) \ \dots \ w_{T,N-1}(n)]^T$ é o vetor de coeficientes no domínio transformado e $\mathbf{D}^{-1}(n)$ é uma matriz diagonal, definida por

$$\mathbf{D}^{-1}(n) = \{\text{diag}[\sigma_{T,0}^2(n) + \epsilon \ \sigma_{T,1}^2(n) + \epsilon \ \dots \ \sigma_{T,N-1}^2(n) + \epsilon]\}^{-1}, \quad (6)$$

onde $\sigma_{T,i}^2(n)$ para $i = 0, 1, \dots, N-1$ denota a variância de cada sub-banda do sinal transformado e ϵ é um parâmetro de regularização que assegura a estabilidade numérica do algoritmo caso o sinal de entrada assuma valores muito pequenos.

Uma vez aplicada a transformação ortogonal, efetua-se através da matriz $\mathbf{D}^{-1}(n)$ a normalização do sinal de entrada. Substituindo-se (2) em (5) e o resultado em (4), obtém-se

$$\mathbf{w}_T(n+1) = \mathbf{w}_T(n) + 2\mu\mathbf{D}^{-1}(n)\mathbf{x}_T(n)[\mathbf{x}_T^T(n)\mathbf{w}_T^o(n) + z(n) - \mathbf{x}_T^T(n)\mathbf{w}_T(n)]. \quad (7)$$

Definindo-se o vetor de erro no domínio transformado $\mathbf{v}_T(n) = \mathbf{w}_T(n) - \mathbf{w}_T^o(n)$ e considerando (3) e (7), obtém-se

$$\mathbf{v}_T(n+1) = [\mathbf{I} - 2\mu\mathbf{D}^{-1}(n)\mathbf{x}_T(n)\mathbf{x}_T^T(n)]\mathbf{v}_T(n) + 2\mu\mathbf{D}^{-1}(n)\mathbf{x}_T(n)z(n) - \mathbf{g}(n). \quad (8)$$

IV. ANÁLISE

A. Momento de Primeira Ordem

Tomando-se o valor esperado de ambos os lados de (8), tem-se

$$E[\mathbf{v}_T(n+1)] = E[\mathbf{v}_T(n)] + 2\mu E[\mathbf{D}^{-1}(n)\mathbf{x}_T(n)z(n)] - 2\mu E[\mathbf{D}^{-1}(n)\mathbf{x}_T(n)\mathbf{x}_T^T(n)\mathbf{v}_T(n)] - E[\mathbf{g}(n)]. \quad (9)$$

Antes de proceder com a determinação dos valores esperados em (9), devem-se estabelecer algumas hipóteses simplificativas para tal análise.

i) $z(n)$ é descorrelacionado de qualquer outro sinal, possui média nula e variância σ_z^2 ;

ii) $\mathbf{g}(n)$ é um vetor independente com média nula e com matriz de autocorrelação $\mathbf{G} = \sigma_g^2 \mathbf{I}$;

iii) $\mathbf{x}_T(n)$ é um processo estacionário com distribuição Gaussiana e matriz de autocorrelação \mathbf{R}_T ;

iv) $\mathbf{v}_T(n)$ e $\mathbf{x}_T(n)$ são processos estatisticamente independentes;

v) $\mathbf{D}^{-1}(n)$ e $\mathbf{x}_T(n)\mathbf{x}_T^T(n)$ são processos conjuntamente estacionários, tal que $\mathbf{D}^{-1}(n)$ varie lentamente em relação a $\mathbf{x}_T(n)\mathbf{x}_T^T(n)$ (Princípio da Média [12]).

Assim, considerando-se as hipóteses (i), (ii), (iii) e (iv) em (9), obtém-se

$$E[\mathbf{v}_T(n+1)] \cong [\mathbf{I} - 2\mu E[\mathbf{D}^{-1}(n)]\mathbf{R}_T]E[\mathbf{v}_T(n)]. \quad (10)$$

O valor esperado de $\mathbf{D}^{-1}(n)$ é obtido conforme [9]-[10], sendo sua expressão dada por

$$E[\mathbf{D}^{-1}(n)] = \frac{M}{(M-2)}[\text{diag}(\mathbf{R}_T)]^{-1} - \epsilon \frac{M^2}{(M-2)(M-4)}[\text{diag}(\mathbf{R}_T^2)]^{-1}. \quad (11)$$

Substituindo-se (11) em (10), obtém-se a expressão recursiva que descreve o comportamento médio do vetor de erro nos coeficientes do algoritmo TD- ϵ LMS. Assim,

$$E[\mathbf{v}_T(n+1)] = E[\mathbf{v}_T(n)] - 2\mu \frac{M}{(M-2)}[\text{diag}(\mathbf{R}_T)]^{-1}\mathbf{R}_T E[\mathbf{v}_T(n)] + 2\mu\epsilon \frac{M^2}{(M-2)(M-4)}[\text{diag}(\mathbf{R}_T^2)]^{-1}\mathbf{R}_T E[\mathbf{v}_T(n)]. \quad (12)$$

A partir de (12), verifica-se que o momento de primeira ordem dos coeficientes do filtro adaptativo não é afetado pela perturbação $\mathbf{g}(n)$ dada em (3).

B. Erro Quadrático Médio e Momento de Segunda Ordem

Nesta seção, é determinada a expressão que descreve o erro quadrático médio (EQM) do algoritmo TD- ϵ LMS. Partindo-se então do erro de adaptação, definido por

$$e(n) = d(n) - \mathbf{x}_T^T(n)\mathbf{w}_T(n), \quad (13)$$

substituindo-se (2) em (13) e utilizando o vetor de erro nos coeficientes $\mathbf{w}_T(n) = \mathbf{v}_T(n) + \mathbf{w}_T^o(n)$, obtém-se

$$e(n) = z(n) - \mathbf{x}_T^T(n)\mathbf{v}_T(n). \quad (14)$$

Elevando-se ao quadrado ambos os lados de (14), tomando-se o valor esperado da expressão resultante e fazendo-se uso das considerações (i) e (iv) da Seção IV, tem-se

$$E[e^2(n)] = E[z^2(n)] + E[\mathbf{v}_T^T(n)\mathbf{x}_T(n)\mathbf{x}_T^T(n)\mathbf{v}_T(n)]. \quad (15)$$

O termo $E[\mathbf{v}_T^T(n)\mathbf{x}_T(n)\mathbf{x}_T^T(n)\mathbf{v}_T(n)]$ é um escalar, logo pode ser reescrito como

$$E[\mathbf{v}_T^T(n)\mathbf{x}_T(n)\mathbf{x}_T^T(n)\mathbf{v}_T(n)] = \text{tr}\{\mathbf{R}_T E[\mathbf{v}_T(n)\mathbf{v}_T^T(n)]\}, \quad (16)$$

onde $\text{tr}\{\cdot\}$ representa o traço da matriz. Substituindo-se (16) em (15), obtém-se:

$$E[e^2(n)] = \sigma_z^2 + \text{tr}\{\mathbf{R}_T E[\mathbf{v}_T(n)\mathbf{v}_T^T(n)]\}. \quad (17)$$

Para analisar o comportamento do EQM, é necessário obter uma expressão que permita calcular a matriz de covariância do vetor de erro $\mathbf{K}(n) = E[\mathbf{v}_T(n)\mathbf{v}_T^T(n)]$. Para tal, multiplica-se (8) pelo seu transposto e calcula-se o valor esperado da expressão resultante, levando-se em conta as hipóteses simplificativas da Seção IV. Assim, obtém-se a expressão recursiva que descreve a evolução da matriz de covariância do vetor de erro, dada por

$$\begin{aligned} \mathbf{K}(n+1) &= \mathbf{K}(n) - 2\mu\mathbf{K}(n)\mathbf{R}_T E[\mathbf{D}^{-1}(n)] \\ &\quad - 2\mu E[\mathbf{D}^{-1}(n)]\mathbf{R}_T \mathbf{K}(n) \\ &\quad + 4\mu^2 E[\mathbf{D}^{-1}(n)]\{2\mathbf{R}_T \mathbf{K}(n)\mathbf{R}_T \\ &\quad + \mathbf{R}_T \text{tr}\{\mathbf{R}_T \mathbf{K}(n)\} E[\mathbf{D}^{-1}(n)] \\ &\quad + 4\mu^2 \sigma_z^2 E[\mathbf{D}^{-1}(n)]\mathbf{R}_T E[\mathbf{D}^{-1}(n)]\} + \mathbf{G}, \end{aligned} \quad (18)$$

onde $\mathbf{G} = E[\mathbf{g}(n)\mathbf{g}_T^T(n)]$.

C. Análise em Regime Permanente

Lembrando-se que o erro em excesso é definido como a diferença entre o EQM e o EQM para a solução ótima (EQM mínimo), tem-se

$$\xi_{\text{exc}}(n) = \text{tr}\{\mathbf{R}_T \mathbf{K}(n)\}. \quad (19)$$

Pré-multiplicando ambos os lados de (18) pela matriz inversa de $E[\mathbf{D}^{-1}(n)]$ e assumindo-se que em regime permanente $\mathbf{K}(n+1) = \mathbf{K}(n) = \mathbf{K}_\infty$, obtém-se

$$\begin{aligned} 2\mu\{E[\mathbf{D}^{-1}(n)]\}^{-1}\mathbf{K}_\infty\mathbf{R}_T E[\mathbf{D}^{-1}(n)] + 2\mu\mathbf{R}_T \mathbf{K}_\infty \\ = 8\mu^2 \mathbf{R}_T \mathbf{K}_\infty \mathbf{R}_T E[\mathbf{D}^{-1}(n)] + \{E[\mathbf{D}^{-1}(n)]\}^{-1}\mathbf{G} \\ + 4\mu^2 \mathbf{R}_T \text{tr}\{\mathbf{R}_T \mathbf{K}_\infty\} E[\mathbf{D}^{-1}(n)] \\ + 4\mu^2 \sigma_z^2 \mathbf{R}_T E[\mathbf{D}^{-1}(n)]. \end{aligned} \quad (20)$$

Tomando-se o traço de ambos os lados de (20), tem-se

$$\begin{aligned} 2\mu \text{tr}\{\{E[\mathbf{D}^{-1}(n)]\}^{-1}\mathbf{K}_\infty\mathbf{R}_T E[\mathbf{D}^{-1}(n)]\} + 2\mu \text{tr}\{\mathbf{R}_T \mathbf{K}_\infty\} \\ = 8\mu^2 \text{tr}\{\mathbf{R}_T \mathbf{K}_\infty \mathbf{R}_T E[\mathbf{D}^{-1}(n)]\} + \text{tr}\{\{E[\mathbf{D}^{-1}(n)]\}^{-1}\mathbf{G}\} \\ + 4\mu^2 \text{tr}\{\mathbf{R}_T E[\mathbf{D}^{-1}(n)]\} \text{tr}\{\mathbf{R}_T \mathbf{K}_\infty\} \\ + 4\mu^2 \sigma_z^2 \text{tr}\{\mathbf{R}_T E[\mathbf{D}^{-1}(n)]\}. \end{aligned} \quad (21)$$

Utilizando-se então a identidade matricial $\text{tr}[\mathbf{AB}] = \text{tr}[\mathbf{BA}]$, obtém-se

- a) $\text{tr}\{\{E[\mathbf{D}^{-1}(n)]\}^{-1}\mathbf{K}_\infty\mathbf{R}_T E[\mathbf{D}^{-1}(n)]\} = \text{tr}\{\mathbf{R}_T \mathbf{K}_\infty\}$,
- b) $\text{tr}\{\mathbf{R}_T \mathbf{K}_\infty \mathbf{R}_T E[\mathbf{D}^{-1}(n)]\} = \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T \mathbf{K}_\infty \mathbf{R}_T\}$,
- c) $\text{tr}\{\mathbf{R}_T E[\mathbf{D}^{-1}(n)]\} = \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\}$.

Assim,

$$\begin{aligned} 2\xi_{\text{exc}} = 4\mu \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T \mathbf{K}_\infty \mathbf{R}_T\} + \frac{1}{2\mu} \text{tr}\{\{E[\mathbf{D}^{-1}(n)]\}^{-1}\mathbf{G}\} \\ + 2\mu \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\} \xi_{\text{exc}} + 2\mu \sigma_z^2 \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\}. \end{aligned} \quad (22)$$

Dado que na convergência os coeficientes do filtro tendem para os valores ótimos, ou seja $\mathbf{K}_\infty \approx 0$, o termo $4\mu \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T \mathbf{K}_\infty \mathbf{R}_T\}$ pode ser desconsiderado. Logo, (22) pode ser escrita como

$$\xi_{\text{exc}} = \frac{\frac{1}{4\mu} \text{tr}\{\{E[\mathbf{D}^{-1}(n)]\}^{-1}\mathbf{G}\}}{1 - \mu \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\}} + \frac{\mu \sigma_z^2 \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\}}{1 - \mu \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\}}. \quad (23)$$

Então, o desajuste do algoritmo TD-εLMS para o caso não-estacionário é dado por

$$\begin{aligned} \mathcal{M} &= \frac{\xi_{\text{exc}}}{\xi_{\text{min}}} \\ &= \frac{\frac{1}{4\mu} \sigma_z^{-2} \text{tr}\{\{E[\mathbf{D}^{-1}(n)]\}^{-1}\mathbf{G}\}}{1 - \mu \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\}} + \frac{\mu \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\}}{1 - \mu \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\}}. \end{aligned} \quad (24)$$

A partir de (24), verifica-se que o desajuste (assim como o erro em excesso) apresenta uma parcela diretamente proporcional à perturbação $\mathbf{g}(n)$.

D. Passo de Adaptação Ótimo

O passo de adaptação ótimo, que minimiza o EQM em excesso e, conseqüentemente, o desajuste do algoritmo TD-εLMS, é obtido derivando (23) em relação ao fator μ e igualando-se a zero a expressão resultante. Assim, fazendo-se $a = \text{tr}\{E[\mathbf{D}^{-1}(n)]\mathbf{R}_T\}$ e $b = \text{tr}\{\{E[\mathbf{D}^{-1}(n)]\}^{-1}\mathbf{G}\}$, a derivada da expressão (23) é dada por

$$\frac{d\xi_{\text{exc}}}{d\mu} = \frac{d}{d\mu} \left[\frac{1}{1 - \mu a} \left(\frac{b}{4\mu} + \mu \sigma_z^2 a \right) \right] = 0. \quad (25)$$

Através de algumas manipulações matemáticas, chega-se ao valor de passo de adaptação ótimo que minimiza o EQM. Assim,

$$\mu_{\text{ótimo}} = \frac{-ab + \sqrt{(ab)^2 + 4\sigma_z^2 ab}}{4\sigma_z^2 a}. \quad (26)$$

E. Grau de Não-estacionariedade

O grau de não-estacionariedade [1], denotado por α , é definido como

$$\alpha = \left[\frac{E[|\mathbf{g}^H(n)\mathbf{x}_T(n)|^2]}{E[|z(n)|^2]} \right]^{1/2}. \quad (27)$$

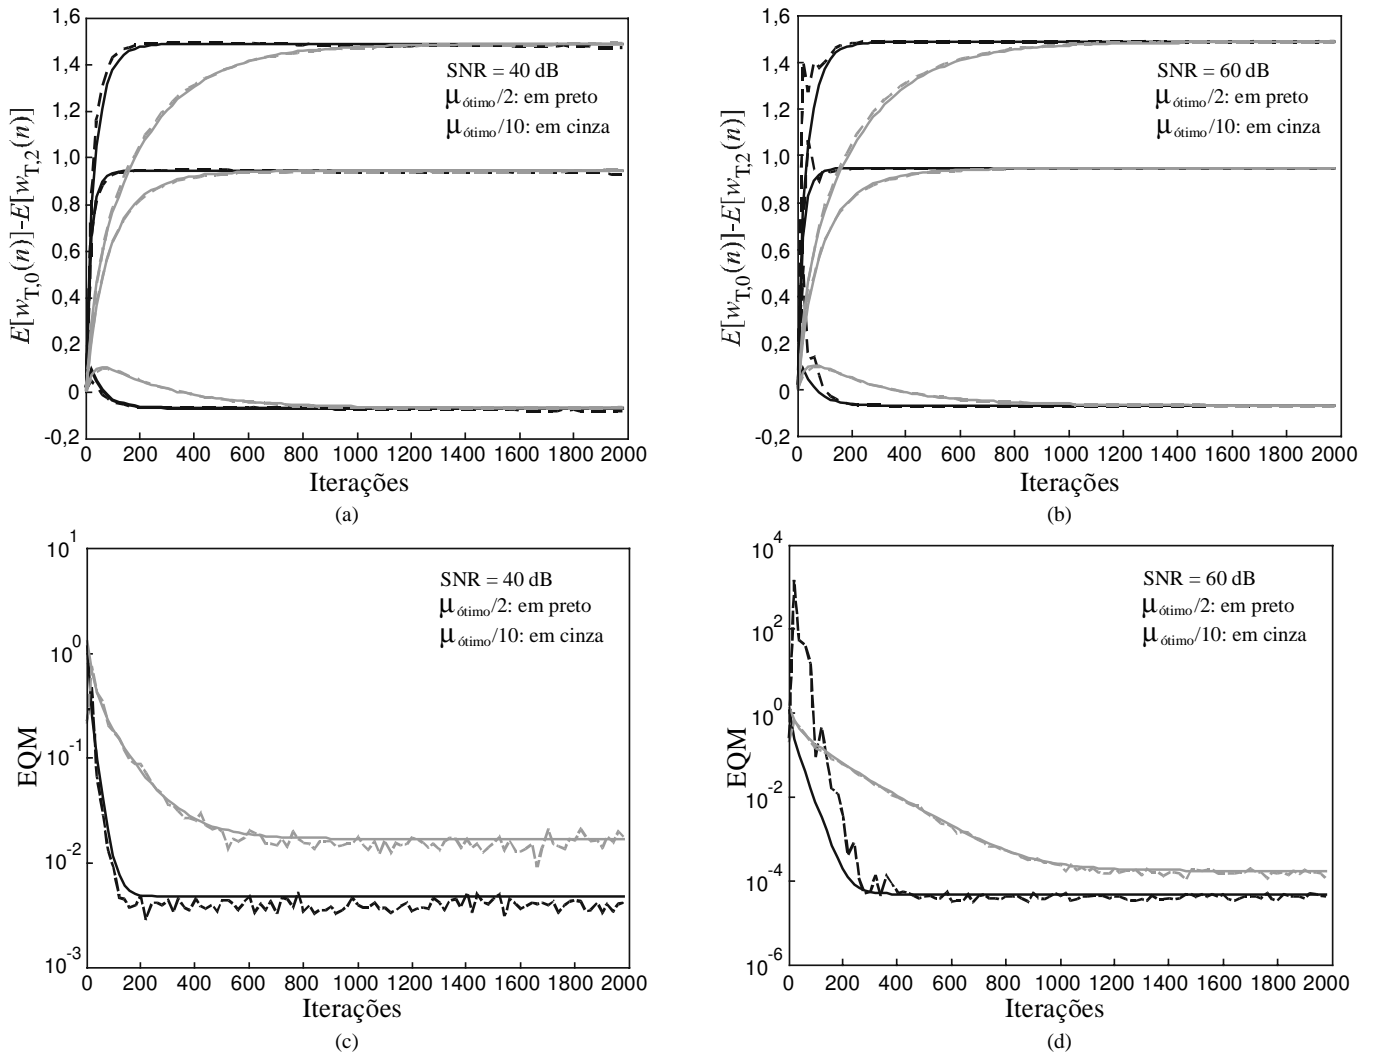


Fig. 1. Exemplo 1. Dispersão dos autovalores igual a 81 e $\alpha = 2$. (a) e (b) Curvas de comportamento médio dos coeficientes do filtro obtidas através de simulação MC (linhas tracejadas) e do modelo proposto $E[w_{T,i}(n)]$, $i = 0, 1, 2$ (linhas contínuas). (c) e (d) Curvas de EQM: simulação MC (linhas tracejadas) e modelo proposto Eqs. (17)-(18) (linhas contínuas).

Considerando-se que $\mathbf{g}(n)$ e $\mathbf{x}_T(n)$ são independentes, o numerador de (27) pode ser reescrito como segue:

$$E[|\mathbf{g}^H(n)\mathbf{x}_T(n)|^2] = \text{tr}[\mathbf{G}\mathbf{R}_T]. \quad (28)$$

Agora, dado que o denominador de (27) é a variância do ruído de medição $z(n)$, o grau de não-estacionariedade pode então ser escrito como

$$\begin{aligned} \alpha &= \frac{1}{\sigma_z} \{\text{tr}[\mathbf{G}\mathbf{R}_T]\}^{1/2} = \frac{1}{\sigma_z} [(\sigma_0^2 + \sigma_1^2 + \dots + \sigma_{N-1}^2)\sigma_g^2]^{1/2} \\ &= \frac{\sigma_g}{\sigma_z} [\text{tr}(\mathbf{R}_T)]^{1/2}. \end{aligned} \quad (29)$$

V. RESULTADOS DE SIMULAÇÃO

O modelo estatístico do TD- ϵ LMS aqui proposto é verificado a partir de um problema de identificação de sistemas. Os sinais de entrada utilizados são correlacionados e têm distribuição Gaussiana. Eles são obtidos de um processo AR(2) dado por

$$x(n) = a_1 x(n-1) + a_2 x(n-2) + v(n), \quad (30)$$

onde $v(n)$ é um ruído branco com variância σ_v^2 de modo que a variância do sinal $x(n)$ seja igual a 1. Os coeficientes do processo auto-regressivo são: $a_2 = -0,85$ e a_1 selecionado de modo a controlar a dispersão dos autovalores do sinal de entrada $x(n)$. Dois valores de variância do ruído de medição $z(n)$ são considerados: 10^{-4} (SNR = 40dB) e 10^{-6} (SNR = 60dB). Note que, uma vez dados os parâmetros σ_z^2 e α como também a transformação ortogonal, obtém-se a partir de (29) a variância do processo de perturbação. Todas as simulações MC são obtidas utilizando-se uma média de 500 realizações independentes. Os coeficientes variantes no tempo da planta são obtidos da expressão (3), repetida aqui por conveniência. Assim,

$$\mathbf{w}_T^o(n+1) = \mathbf{w}_T^o(n) + \mathbf{g}(n),$$

onde,

$$\mathbf{w}_T^o(0) = \mathbf{T}[\text{sinc}(0) \text{ sinc}(1/N) \dots \text{sinc}(N-1/N)]^T. \quad (31)$$

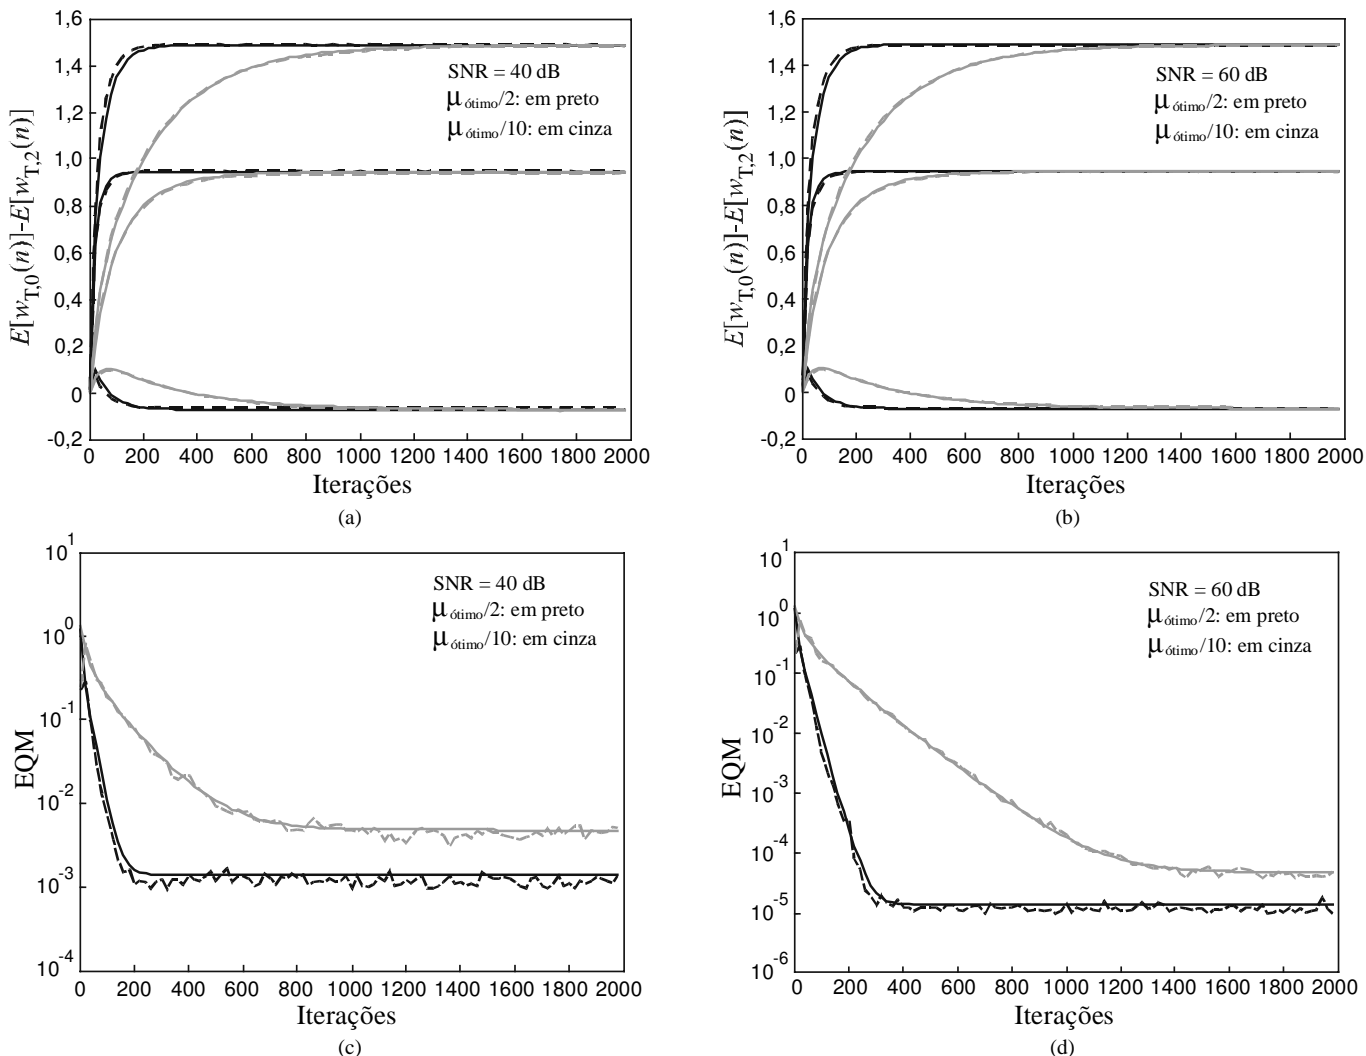


Fig. 2. Exemplo 2. Dispersão dos autovalores igual a 81 e $\alpha=1$. (a) e (b) Curvas de comportamento médio dos coeficientes do filtro obtidas através de simulação MC (linhas tracejadas) e do modelo proposto $E[w_{T,i}(n)]$, $i=0, 1, 2$ (linhas contínuas). (c) e (d) Curvas de EQM: simulação MC (linhas tracejadas) e modelo proposto Eqs. (17)-(18) (linhas contínuas).

A transformada ortogonal usada em todos os exemplos é a DCT; no entanto, deve ser ressaltado que o modelo aqui proposto não depende do tipo de transformação utilizado. O efeito da transformação é evidenciado a partir de sua habilidade em decorrelacionar o sinal de entrada.

O passo de adaptação μ usado nos exemplos é relacionado com o valor de passo ótimo $\mu_{\text{ótimo}}$ determinado em (26). A constante $\varepsilon = 0,001$ (parâmetro de regularização) é também considerada em todos os exemplos.

Exemplo 1

Para este exemplo, os seguintes parâmetros são considerados: $N=8$, $M=32$ e $\mu_{\text{ótimo}}=0,0585$. A dispersão dos autovalores da matriz de autocorrelação do sinal de entrada é 81 e o grau de não-estacionaridade, dado por (29), é $\alpha=2$. Nas Figs. 1(a) e 1(c) são ilustrados os momentos de primeira e segunda ordens dos coeficientes do filtro adaptativo para SNR de 40 dB, enquanto nas Figs. 1(b) e 1(d) é mostrado o caso com 60 dB. Para facilitar a

visualização das curvas, nas figuras onde é ilustrada a evolução do valor esperado, apenas quatro coeficientes são plotados. Através das curvas do EQM, pode ser observado um descasamento entre o modelo proposto e o resultado de simulação durante a fase transitória. Tal descasamento é mais evidente para valores de passo de adaptação próximo a $\mu_{\text{ótimo}}$. Isso é decorrente das considerações simplificadoras usadas, as quais estão baseadas na condição de adaptação lenta ($\mu \ll \mu_{\text{ótimo}}$). Note, entretanto, que o comportamento médio dos coeficientes não apresenta tal descasamento, mesmo para valores maiores do passo de adaptação. As previsões teóricas para o caso de SNR = 60dB apresentam uma melhor concordância com os resultados de simulação devido à menor variância do processo de perturbação $\mathbf{g}(n)$.

Exemplo 2

Para este exemplo, são usados os mesmos parâmetros do Exemplo 1, porém com um diferente grau de não-estacionaridade $\alpha=1$. Os resultados obtidos são

mostrados na Fig. 2, seguindo o mesmo padrão de apresentação utilizado para a Fig. 1. Nesse caso, devido ao menor grau de não-estacionaridade, a precisão do modelo é melhor para ambos os valores de SNR usados.

VI. CONCLUSÕES

Este trabalho apresenta uma análise estatística do algoritmo ϵ LMS no domínio transformado (TD- ϵ LMS) operando em ambientes não-estacionários. Essa análise é independente da ordem do filtro bem como do tipo de transformação ortogonal utilizado. A comparação entre os resultados de simulação numérica e as previsões obtidas pelo modelo proposto confirmam a eficácia das condições e simplificações de modelagem consideradas.

REFERÊNCIAS

- [1] S. Haykin, *Adaptive Filter Theory*, 3ed. Englewood Cliffs, NJ: Prentice-Hall, 1996.
- [2] B. Farhang-Boroujeny, *Adaptive Filters: Theory and Applications*, John Wiley & Sons, 1998.
- [3] B. Widrow and S. D. Stearns, *Adaptive Signal Processing*, Englewood Cliffs, NJ: Prentice-Hall, 1985.
- [4] S. S. Narayan, A. M. Peterson, and M. J. Narasimha, "Transform domain LMS algorithm," *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 31, no. 3, pp. 609-615, June 1983.
- [5] S. Hosur and A. H. Tewfik, "Wavelet transform domain adaptive FIR filtering," *IEEE Trans. Signal Process.*, vol. 45, no. 3, pp. 617-630, Mar. 1997.
- [6] S. J. Chern, J. C. Hornig, and K. M. Wong, "The performance of the hybrid LMS adaptive algorithm," *Elsevier Signal Processing*, vol. 44, pp. 67-88, June 1995.
- [7] D. I. Kim and P. De Wilde, "Performance analysis of the DCT-LMS adaptive filtering algorithm," *Elsevier Signal Processing*, vol. 80, pp. 1629-1654, Aug. 2000.
- [8] E. M. Lobato, O. J. Tobias e R. Seara, "Análise estatística do algoritmo LMS no domínio transformado," *Anais do XX Simpósio Brasileiro de Telecomunicações*, Rio de Janeiro, RJ, Out. 2003, pp. 1-6.
- [9] E. M. Lobato, O. J. Tobias e R. Seara, "Modelo analítico do algoritmo ϵ LMS no domínio transformado para sinais de entrada Gaussianos," *Anais do XXI Simpósio Brasileiro de Telecomunicações*, Belém, PA, CD-ROM, artigo nº 282, Set. 2004, pp. 1-6.
- [10] E. M. Lobato, O. J. Tobias e R. Seara, "A stochastic model for the transform-domain LMS algorithm," *Proc. 12th European Signal Process. Conf.*, Vienna, Austria, Sep. 2004, pp. 1833-1836.
- [11] A. H. Sayed and T. Y. Al-Naffouri, "Mean-square analysis of normalized leaky adaptive filters," *Proc. IEEE Int. Conf. Acoust., Speech, Signal Process.*, Salt Lake City, USA, vol. 6, May 2001, pp. 3873-3876.
- [12] C. G. Samson and U. Reddy, "Fixed point error analysis of the normalized ladder algorithm," *IEEE Trans. Acoust., Speech, Signal Process.*, vol. 31, no. 5, pp. 1177-1191, Oct. 1983.