

Um esquema para restauração cega de imagens baseado em combinação de algoritmos adaptativos

Daniela Brasil Silva e Magno T. M. Silva

Resumo—Neste artigo, é proposto um esquema para restauração cega de imagens baseado na combinação convexa de um equalizador cego com um equalizador no modo de decisão direta. A combinação também é adaptada de forma cega, o que possibilita o chaveamento automático entre os filtros componentes. Dessa forma, o esquema proposto é capaz de atingir o desempenho de um algoritmo de filtragem adaptativa supervisionada sem o conhecimento prévio da imagem sem degradação. Simulações ilustram o desempenho do esquema proposto com relação aos métodos de restauração de imagens baseados em algoritmos de equalização cega.

Palavras-Chave—Restauração cega de imagens, combinação de algoritmos adaptativos, algoritmo do módulo constante, modo de decisão direta, filtragem adaptativa.

Abstract—In this paper, we propose a scheme for blind image restoration based on the convex combination of a blind equalizer with a decision-directed equalizer. The combination is also adapted in a blind manner, which allows the automatic switching between the component filters. Thus, the proposed scheme is able to achieve the performance of a technique based on a supervised adaptive filtering with no previous knowledge about the undegraded image. Simulations illustrate the performance of the propose scheme with respect to existing image deconvolution techniques based on blind equalization algorithms.

Keywords—Blind image restoration, combination of adaptive algorithms, constant modulus algorithm, decision-directed mode, adaptive filtering.

I. INTRODUÇÃO

O objetivo da restauração cega de imagens é melhorar a qualidade de uma imagem degradada sem usar informações sobre a degradação causada pela função de espalhamento de ponto (*point spread function* – PSF) [1]. Nas últimas décadas, várias técnicas para restauração cega de imagens têm sido propostas na literatura (ver, e.g., [1]–[4] e suas referências). Algumas dessas técnicas minimizam uma função custo combinada com um termo de regularização associado a uma informação *a priori* da imagem degradada (a borda, por exemplo). Isso implica a utilização de um critério de parada no algoritmo para evitar a degradação do desempenho [3], [4]. Embora esses métodos levem a bons resultados, eles são relativamente complexos, possuem parâmetros difíceis de escolher e apresentam alto custo computacional.

Em equalização cega de canais de comunicação, o algoritmo do módulo constante (*constant modulus algorithm* – CMA) é o mais popular para adaptação de equalizadores de resposta ao pulso unitário finita e é amplamente utilizado mesmo para constelações de módulo não constante, como é o caso

de *N*-PAM (*pulse amplitude modulation*) com $N > 2$ [5]. Embora o CMA possua um custo computacional baixo, seu principal problema é a convergência para mínimos locais indesejáveis. Neste caso, ele pode atingir um nível de erro quadrático médio (*mean-square error* – MSE) alto em regime. Além disso, o CMA pode atingir um MSE igual a zero apenas para sinais de módulo constante em um ambiente estacionário e sem ruído e considerando sobreamostragem (ver, e.g., [6]). Diante disso, é comum chavear do modo de treinamento cego com o CMA para o modo de decisão direta (*decision-directed* – DD). No modo DD, a decisão tomada sobre a saída do equalizador faz o papel de sinal desejado, que por sua vez, é utilizado em um algoritmo de filtragem adaptativa supervisionada, como o algoritmo NLMS (*normalized least-mean-squares*), por exemplo [7]. O bom desempenho global do equalizador depende da seleção do limiar de MSE adequado para o chaveamento [8]. No entanto, essa não é uma tarefa simples, já que esse limiar depende da constelação do sinal transmitido, do canal de comunicação, da razão sinal-ruído, entre outros fatores [8]. Para evitar a necessidade de se selecionar um limiar de MSE para o chaveamento abrupto (*hard switching*) entre os modos cego e de decisão direta, vários esquemas de chaveamento suave foram propostos na literatura (ver, e.g., [9], [10]). Além disso, algoritmos de equalização cega com bom desempenho no transitório e em regime têm sido propostos a fim de evitar o mecanismo de chaveamento para o modo DD (ver, e.g., [11] e suas referências). Entretanto, esses esquemas são tipicamente difíceis de ajustar e o desempenho alcançado ainda é dependente do ambiente particular em que são aplicados. Neste contexto, foi proposto em [12] um esquema que combina de forma adaptativa um equalizador cego com um equalizador no modo de decisão direta funcionando em paralelo. A combinação é adaptada de forma cega e conseqüentemente, o esquema proposto possibilita o chaveamento automático entre os filtros componentes, evitando a seleção *a priori* de um nível de MSE para a transição. As simulações de [12] indicam que o desempenho desse esquema supera os de outros equalizadores com chaveamento suave existentes na literatura em termos de velocidade de convergência e MSE em regime.

Uma extensão do CMA para desconvolução cega de imagens foi proposta em [13]. Nesse trabalho, os pixels da imagem original são mapeados em um sinal PAM, o que pode ser feito incluindo um dispositivo de mapeamento no sistema de aquisição da imagem. Por exemplo, uma imagem com dois bits/pixel pode ser interpretada como um sinal 4-PAM, uma vez que seus bits/pixel são mapeados em quatro níveis, i.e., ± 1 e ± 3 . Depois da desconvolução, o sinal recuperado deve

Daniela Brasil Silva e Magno T. M. Silva, Depto. Engenharia de Sistemas Eletrônicos, Universidade de São Paulo, São Paulo, SP, Brasil, e-mails: {daniela.brasil, magno.silva}@usp.br. Este trabalho foi financiado pela CAPES (bolsa da cota institucional) e CNPq (304275/2014-0).

sofrer um mapeamento inverso para se obter a estimativa da imagem original. Por meio de simulações, foi mostrado que o desempenho do algoritmo depende do número de níveis de cinza da imagem original e também da razão sinal-ruído. Embora a abordagem de [13] seja inovadora, alguns avanços recentes em algoritmos cegos para equalização de canais de comunicação podem ser estendidos para restauração cega de imagens para se obter uma redução da degradação de forma mais efetiva. Nesse sentido, os trabalhos [14], [15] estenderam o algoritmo multimódulo regional (*regional multimodulus algorithm* – RMA) de [11] para desconvolução cega de imagens. Apesar do desempenho do RMA nessa aplicação também ser melhor que o do CMA de [13], notou-se a partir das simulações de [15] a necessidade de um critério de parada do algoritmo para evitar degradação do desempenho, similar ao que ocorre com as técnicas de [3], [4].

Como o esquema de [12] apresenta um desempenho melhor que o RMA em equalização de canais de comunicação, espera-se que o mesmo aconteça na restauração de imagens, algo que ainda não foi explorado na literatura. Neste artigo, o esquema de [12] é estendido para desconvolução cega de imagens. Para isso, as questões de implementação, como a janela e o percurso de varredura, propostas em [14], [15] são levadas em conta. O artigo é organizado como se segue. A formulação do problema é apresentada na Seção II. O esquema proposto é apresentado na Seção III. Os resultados de simulação e as conclusões são mostrados nas Seções IV e V, respectivamente.

II. FORMULAÇÃO DO PROBLEMA

O esquema da desconvolução de uma imagem com o uso de algoritmos de equalização cega é mostrado na Figura 1. Considera-se que a imagem original \mathbf{F} de dimensão $N_1 \times N_2$ e B bits/pixel é mapeada em um sinal 2^B -PAM, modelado pelo alfabeto $\pm 1, \pm 3, \dots, \pm (2^B - 1)$ [13]. Essa imagem sofre os efeitos da PSF e do ruído, resultando na imagem degradada \mathbf{G} . Utilizando uma janela de seleção e um percurso de varredura específicos (definidos abaixo), uma matriz \mathbf{U}_n de dimensão $M \times M$ é definida para cada pixel da imagem. Os elementos dessa matriz são rearranjados em um vetor coluna $\mathbf{u}(n)$. Esse vetor é utilizado como entrada de um filtro adaptativo com M^2 coeficientes, agrupados no vetor coluna $\mathbf{w}(n-1)$. A saída desse filtro é calculada pelo produto interno $y(n) = \mathbf{u}^T(n)\mathbf{w}(n-1)$, em que $(\cdot)^T$ indica transposição. A saída $y(n)$ entra em um decisor e uma estimativa do pixel $\mathbf{F}(k_1, k_2)$, designada por $\hat{\mathbf{F}}(k_1, k_2)$, é obtida. Usando $y(n)$, $\hat{\mathbf{F}}(k_1, k_2)$ e informações estatísticas de \mathbf{F} , o algoritmo atualiza $\mathbf{w}(n-1)$. Para que a estimativa $\hat{\mathbf{F}}$ seja boa, é necessário que o algoritmo adaptativo estime cada pixel mais de uma vez. Até o algoritmo atingir o regime estacionário, as estimativas em geral não são boas. Dessa forma, quando o algoritmo chega ao fim de uma imagem, a filtragem deve continuar até que a convergência seja alcançada por todos os pixels. O número de repetições necessárias depende do nível da degradação causada pela PSF [1], [13]–[15].

Na Figura 2, é mostrada a janela \mathbf{U}_n de dimensão $M \times M$ usada para estimar o pixel central $\mathbf{F}(k_1, k_2)$, representado por \star . Essa janela é importante quando se utiliza filtros adaptativos para restauração de imagens, uma vez que os pixels

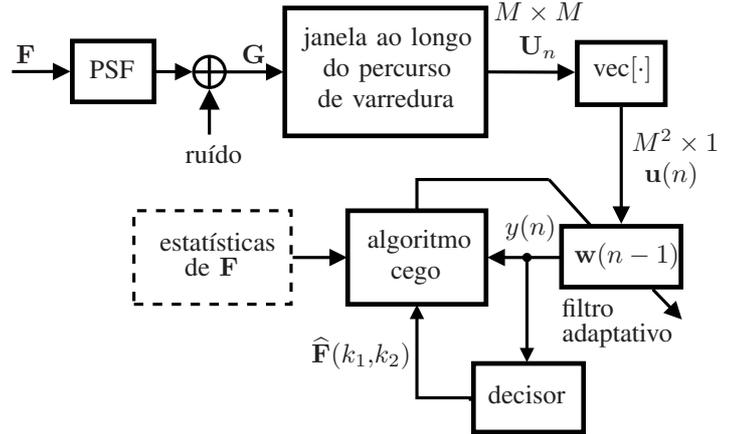


Fig. 1. Desconvolução de imagens usando algoritmos de equalização cega.

nas vizinhanças de um dado $\mathbf{G}(k_1, k_2)$ são usados para estimar $\mathbf{F}(k_1, k_2)$ [14], [15].

Como os pixels das regiões das bordas não têm vizinhança definida, o uso da janela centralizada requer um tratamento de borda específico ao redor de toda imagem. Esse tratamento de borda pode ser visto como uma condição de inicialização e também está representado na Figura 2. Para facilitar o trabalho dos filtros adaptativos, mudanças bruscas na imagem devem ser evitadas quando possível. Assim, optou-se por uma interface de borda replicada e reversa de comprimento igual a $(M-1)/2$ pixels, obtida por meio do espelhamento dos pixels mais externos da borda da imagem degradada [14], [15].

O percurso de varredura refere-se ao caminho que a janela percorre sobre a imagem para estimar cada pixel [15]. Para evitar variações abruptas entre uma janela e outra, foi considerado um esquema alternado de varredura horizontal e vertical como mostrado na Figura 3. Assim, uma varredura horizontal completa é efetuada na imagem, e então, a partir do pixel da última iteração, uma varredura vertical é aplicada, seguida por outra varredura horizontal, e finalmente por uma última varredura vertical. Esse conjunto de varreduras compõe um ciclo de atualização, que é denominado por *ciclo de varredura* e é repetido até se obter a convergência do algoritmo [15]. Por fim, cabe observar que ao se utilizar o operador $\text{vec}[\cdot]$, os elementos da matriz \mathbf{U}_n são rearranjados no vetor $\mathbf{u}(n)$ para estimar cada pixel $\mathbf{F}(k_1, k_2)$ da imagem. Isso torna mais simples a extensão dos algoritmos de equalização adaptativa para restauração de imagens.

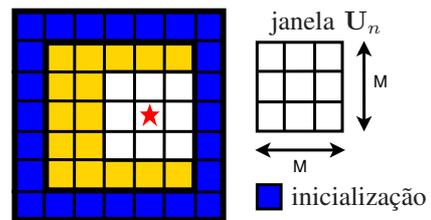


Fig. 2. Modelo de seleção de janela (dimensão $M \times M$ e M ímpar) e inicialização de borda. Figura 4 de [15].

III. ESQUEMA PROPOSTO

O filtro adaptativo da Figura 1 pode ser substituído por uma combinação convexa de um equalizador cego e um equalizador

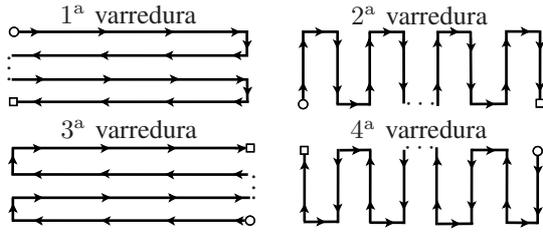


Fig. 3. Combinação dos percursos de varreduras horizontais e verticais. Figura adaptada de [15].

no modo de decisão direta (DD), como esquematizado na Figura 4. Neste trabalho, o CMA é utilizado na atualização do equalizador cego e o algoritmo NLMS na adaptação do equalizador no modo de decisão direta. No entanto, o esquema da Figura 4 funciona com outros algoritmos como mostrado em [12] para equalização de canais de comunicação.

A saída global da combinação é dada por

$$y(n) = \lambda(n)y_1(n) + [1 - \lambda(n)]y_2(n), \quad (1)$$

em que $\lambda(n) \in [0, 1]$ é o parâmetro de mistura e $y_i(n) = \mathbf{u}^T(n)\mathbf{w}_i(n-1)$ são as saídas dos equalizadores cego e DD, respectivamente para $i = 1, 2$. A saída global $y(n)$ passa por um decisor, resultando no pixel $\hat{\mathbf{F}}(k_1, k_2)$, que é então usado como sinal desejado pelo filtro NLMS. No início das iterações, quando as estimativas $\hat{\mathbf{F}}(k_1, k_2)$ são ruins, o NLMS apresenta um desempenho inferior ao do CMA, de modo que $y(n)$ se aproxima da saída do CMA e portanto $\lambda \approx 1$. Conforme o CMA converge, as estimativas $\hat{\mathbf{F}}(k_1, k_2)$ melhoram, o que possibilita o bom funcionamento do NLMS no modo de decisão direta. Quando isso acontece, $y(n)$ se aproxima da saída do NLMS e $\lambda \approx 0$ [12].

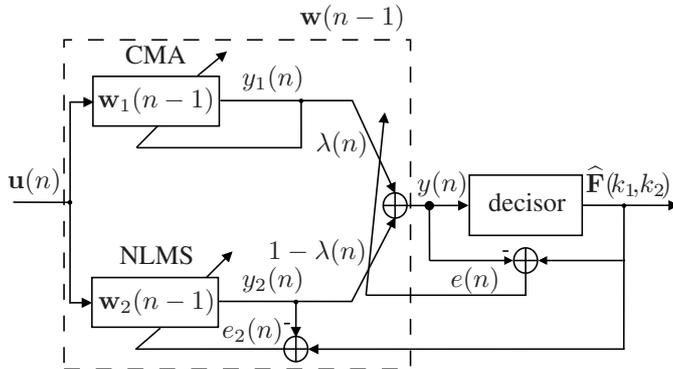


Fig. 4. Combinação convexa do CMA com o NLMS.

O CMA é um algoritmo do tipo gradiente estocástico que minimiza a função custo instantânea $J_{\text{CMA}}(n) = [r - y_1^2(n)]^2$, sendo $r \triangleq E\{\mathbf{F}^4(k_1, k_2)\}/E\{\mathbf{F}^2(k_1, k_2)\}$ o fator de dispersão que contém informações estatísticas da imagem original e $E\{\cdot\}$ indica o operador esperança matemática. A atualização dos coeficientes do CMA é dada por

$$\mathbf{w}_1(n) = \mathbf{w}_1(n-1) + \mu_1 e_1(n)\mathbf{u}(n), \quad (2)$$

sendo μ_1 o passo de adaptação e $e_1(n)$ o “erro de estimação” do algoritmo, dado por

$$e_1(n) = [r - y_1^2(n)]y_1(n). \quad (3)$$

A atualização dos coeficientes do algoritmo NLMS no modo de decisão direta é dada por [7]

$$\mathbf{w}_2(n) = \mathbf{w}_2(n-1) + \frac{\mu_2}{\delta + \|\mathbf{u}(n)\|^2} e_2(n)\mathbf{u}(n), \quad (4)$$

sendo que $\|\cdot\|$ representa a norma euclidiana, $0 < \mu_2 < 2$ é o passo de adaptação, δ é uma constante usada para evitar divisão por zero e $e_2(n)$ é o erro de decisão, definido por

$$e_2(n) = \hat{\mathbf{F}}(k_1, k_2) - y_2(n). \quad (5)$$

Cabe observar que $\hat{\mathbf{F}}(k_1, k_2)$ faz o papel do sinal desejado em (5) e corresponde à decisão tomada sobre a saída global da combinação $y(n)$. Dessa forma, diferente dos esquemas de combinação comumente propostos na literatura (ver, e.g., [16], [17] e suas referências), os filtros do esquema da Figura 1 não são desacoplados, pois o bom funcionamento do DD depende da qualidade da estimativa $\hat{\mathbf{F}}(k_1, k_2)$, que por sua vez, depende do desempenho do CMA.

A fim de restringir esse parâmetro ao intervalo $[0, 1]$ e reduzir o ruído de gradiente quando $\lambda \approx 0$ e $\lambda \approx 1$, uma transformação não linear e uma variável auxiliar $\alpha(n)$ são usadas [16], [18]. Dessa forma, o parâmetro de mistura $\lambda(n)$ é definido como

$$\lambda(n) = \varphi[\alpha(n-1)] = \frac{\text{sgm}[\alpha(n-1)] - \text{sgm}[-\alpha^+]}{\text{sgm}[\alpha^+] - \text{sgm}[-\alpha^+]}, \quad (6)$$

em que $\text{sgm}[x] = [1 + e^{-x}]^{-1}$ é a função sigmoideal e α^+ é o valor máximo que $|\alpha(n)|$ pode assumir. A função $\varphi[\cdot]$, proposta em [18], é uma versão escalonada e deslocada da função sigmoideal, atingindo valor um quando $\alpha(n) = \alpha^+$ e zero quando $\alpha(n) = -\alpha^+$.

Utilizando o método do gradiente estocástico para minimizar o erro de decisão global ao quadrado $e^2(n) = [\hat{\mathbf{F}}(k_1, k_2) - y(n)]^2$ e considerando a normalização do passo de adaptação proposta em [17], obtém-se a seguinte equação de atualização para a variável auxiliar

$$\alpha(n) = \alpha(n-1) + \frac{\mu_\alpha}{p(n)} e(n)[y_1(n) - y_2(n)]\varphi'[\alpha(n-1)], \quad (7)$$

em que

$$\varphi'[\alpha(n-1)] = \frac{\text{sgm}[\alpha(n-1)]\{1 - \text{sgm}[\alpha(n-1)]\}}{\text{sgm}[\alpha^+] - \text{sgm}[-\alpha^+]}, \quad (8)$$

$$p(n) = \eta p(n-1) + (1 - \eta)[y_1(n) - y_2(n)]^2, \quad (9)$$

$0 \ll \eta < 1$ (e.g., $\eta = 0,9$) e μ_α é o passo de adaptação. A variável auxiliar $\alpha(n)$ deve ser restrita por saturação ao intervalo $[-\alpha^+, \alpha^+]$, pois quando $|\alpha(n)|$ é muito grande, o termo $\varphi'[\alpha(n-1)]$ é nulo e a adaptação deixaria de acontecer. Uma escolha comum na literatura é $\alpha^+ = 4$ (ver, e.g., [16]–[18]). As equações (1)–(9) resumam a combinação convexa proposta. O algoritmo apresenta um custo computacional de $5M^2 + 16$ multiplicações, $5M^2 + 8$ somas, 2 divisões, 1 comparação e 2 não-linearidades por iteração. As não linearidades podem ser implementadas utilizando-se uma tabela.

É importante observar que a utilização do erro de decisão global para atualizar $\alpha(n)$ foi descartada em [12] no problema de equalização de canais de comunicação. Nesse caso, a minimização da função custo do módulo constante calculada com a saída global da combinação levou a resultados melhores em termos de taxa de erro de símbolo. Para restauração de

imagens, no entanto, a combinação só funcionou adequadamente com o erro de decisão global na atualização de $\alpha(n)$. Acredita-se que isso se deve ao efeito da PSF sobre os dados da imagem, que é diferente do efeito do canal de comunicação, e deverá ser melhor investigado em um trabalho futuro.

IV. SIMULAÇÕES

Nesta seção, o esquema de combinação proposto é comparado com os algoritmos NLMS, CMA e RMA [15], levando-se em conta as questões de implementação discutidas na Seção II. Por utilizar a imagem original como sinal desejado, o NLMS é considerado como referência. Para avaliar a qualidade das imagens restauradas, utilizaram-se duas métricas: o erro quadrático médio percentual (%MSE) [1, Eq. (25)] e o índice de similaridade estrutural média (*mean structural similarity* – MSSIM) [19, Eq. (17)]. O %MSE é baseado no erro quadrático médio e é obtido por meio da comparação entre a imagem restaurada e a original. O MSSIM mede a similaridade entre duas imagens e funciona como uma medida de qualidade de uma imagem em relação a outra, assumindo valor máximo igual a um quando as duas imagens são iguais. No cálculo do MSSIM, foi usado o código em MATLAB disponível em <https://ece.uwaterloo.ca/~z70wang/research/ssim/> com $K = [0.01 \ 0.03]$ e $\text{window} = \text{fspecial}('gaussian', 11, 1.5)$.

Na primeira simulação, considerou-se a imagem *camera-man* de dimensão 128×128 e 4 bits/pixel, mostrada na Figura 5(a). Essa imagem foi degradada por uma PSF Gaussiana 2D, dada por $\mathbf{H}(k_1, k_2) = K \exp[-(k_1^2 + k_2^2)/(2\sigma^2)]$, para $k_1 = -(L_1-1)/2, \dots, -1, 0, 1, \dots, (L_1-1)/2$ e $k_2 = -(L_2-1)/2, \dots, -1, 0, 1, \dots, (L_2-1)/2$, em que σ^2 é a variância, que determina a severidade da PSF, e K é uma constante escolhida para que $\sum_{k_1} \sum_{k_2} \mathbf{H}(k_1, k_2) = 1$ [1]. Na simulação, foram considerados $L_1 = L_2 = 5$ e $\sigma^2 = 0,64$. A imagem degradada é mostrada na Figura 5(b) e as imagens restauradas pelos algoritmos NLMS, CMA, RMA e pela combinação depois de 10^4 ciclos são mostradas respectivamente nas Figuras 5(c), 5(d), 5(e) e 5(f). A imagem degradada apresenta %MSE de 4,87, sendo que o %MSE atingido pela combinação ao final dos 10^4 ciclos foi igual a 0,40, valor próximo ao do NLMS (0,34) e inferior ao do RMA (0,76) e do CMA (5,17). Ao comparar a imagem restaurada com o CMA (Figura 5(d)) com a imagem original (Figura 5(a)), é possível perceber que o algoritmo não foi capaz de mitigar completamente a degradação, como o NLMS, RMA e a combinação. O MSSIM, mostrado na Figura 6 em função do ciclo de varredura corrobora com essa observação. O MSSIM da imagem degradada era de 0,79. Ao final dos ciclos, os valores alcançados pelos algoritmos foram: 0,992 (NLMS), 0,977 (RMA), 0,871 (CMA) e 0,990 (Combinação). Dessa forma, a combinação foi a que mais se aproximou do algoritmo NLMS, graças ao chaveamento automático para o modo de decisão direta, o que pode ser confirmado pelo comportamento do parâmetro de mistura médio ($\bar{\lambda}$), mostrado na Figura 6.

Na segunda simulação, considerou-se a imagem *Lenna* de dimensão 128×128 e 5 bits/pixel, mostrada na Figura 7(a). Essa imagem foi degradada pela PSF $\mathbf{H}(k_1, k_2) = K(\beta^2 + n_1^2 + n_2^2)^{-3/2}$, para $k_1 = -(L_1-1)/2, \dots, -1, 0, 1, \dots, (L_1-1)/2$ e $k_2 = -(L_2-1)/2, \dots, -1, 0, 1, \dots, (L_2-1)/2$, em que β é o parâmetro que

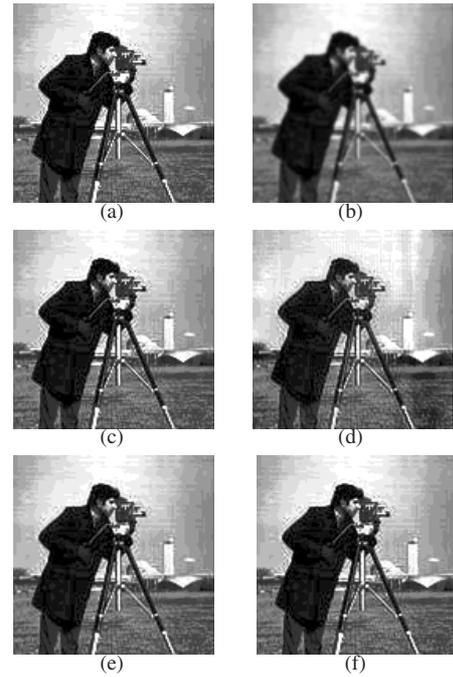


Fig. 5. Imagens: (a) original (128×128 , 4-bits/pixel); (b) degradada (sem ruído, $L_1 = L_2 = 5$, $\sigma^2 = 0.64$, %MSE = 4,8740); (c) NLMS (%MSE = 0,3380, $\mu = 10^{-2}$); (d) CMA (%MSE = 5,1754, $\mu = 10^{-8}$); (e) RMA (%MSE = 0,7632, $\mu = 10^{-4}$); (f) Combinação (%MSE = 0,4022, $\mu_1 = 10^{-8}$, $\mu_2 = 10^{-4}$, $\mu_\alpha = 10^{-4}$).

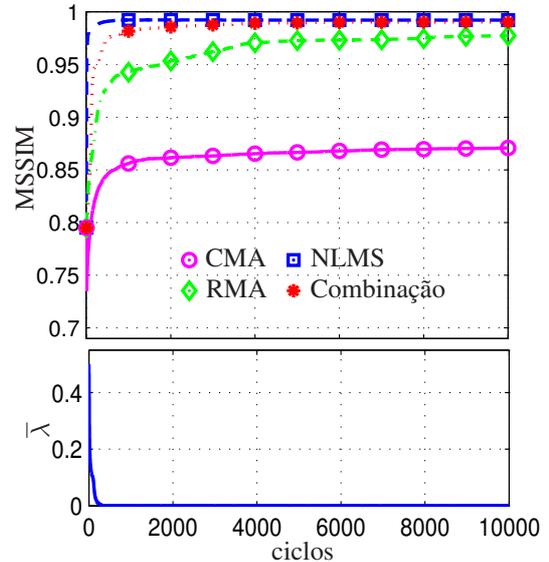


Fig. 6. Similaridade estrutural média (MSSIM) de cada algoritmo e valor médio do parâmetro de mistura ($\bar{\lambda}$) ao longo dos ciclos de varredura.

indica a severidade da degradação e K é uma constante de normalização para que $\sum_{n_1} \sum_{n_2} \mathbf{H}(n_1, n_2) = 1$ [13]. As simulações foram feitas com $L_1 = L_2 = 9$ e $\beta = 1,5$. A imagem degradada é mostrada na Figura 7(b) e as imagens restauradas pelos algoritmos NLMS, CMA, RMA e pela combinação depois de 10^4 ciclos são mostradas respectivamente nas Figuras 7(c), 7(d), 7(e) e 7(f). Neste caso, o %MSE da imagem degradada era de 9,6952, e o %MSE da combinação (0,2772) também ficou próximo ao do NLMS (0,1802), sendo ambos inferiores ao do RMA (4,9926) e ao do CMA (6,5201). O MSSIM dos algoritmos é mostrado na

Figura 8-(a) em função do ciclo de varredura. O MSSIM da imagem degradada era de 0,7092 e ao final dos 10^4 ciclos, os valores alcançados pelos algoritmos foram: 0,9912 (NLMS), 0,8530 (RMA), 0,8304 (CMA) e 0,9839 (Combinação). Novamente, graças ao chaveamento automático para o modo de DD, a combinação conseguiu se aproximar do NLMS, como pode ser confirmado pelo comportamento do parâmetro de mistura médio ($\bar{\lambda}$) da Figura 8. Dessa forma, a combinação é um esquema cego que pode restaurar a imagem quase que perfeitamente. Por fim, cabe observar que a falta de um critério de parada causa uma degradação no desempenho do CMA, o que não foi observado nos demais algoritmos. Como vantagem adicional da combinação, o valor do parâmetro de mistura pode ser utilizado como critério de parada, o que será investigado em um trabalho futuro.



Fig. 7. Imagens: (a) original (128×128 , 5-bits/pixel); (b) degradada (sem ruído, $L_1 = L_2 = 9$, $\beta = 1,5$, $\%MSE = 9,6952$); (c) NLMS ($\%MSE = 0,1802$, $\mu = 5 \times 10^{-2}$); (d) CMA ($\%MSE = 6,5201$, $\mu = 10^{-10}$); (e) RMA ($\%MSE = 4,9926$, $\mu = 5 \times 10^{-4}$); (f) Combinação ($\%MSE = 0,2772$, $\mu_1 = 10^{-10}$, $\mu_2 = 5 \times 10^{-2}$, $\mu_\alpha = 10^{-4}$).

V. CONCLUSÕES

O chaveamento automático para o modo de decisão direta possibilita que o esquema proposto tenha um desempenho próximo ao do algoritmo NLMS supervisionado, que usa a imagem sem degradação como sinal desejado. Esse esquema pode ainda apresentar um desempenho superior aos dos algoritmos cegos, como o CMA e o RMA. Além disso, resultados preliminares indicam que o parâmetro de mistura pode ser usado como critério de parada desse esquema, o que pode evitar uma eventual degradação de desempenho. Em trabalhos futuros, pretende-se comparar o esquema proposto com outras técnicas de restauração cega de imagens (e.g, [3], [4]).

REFERÊNCIAS

[1] D. Kundur and D. Hatzinakos, "Blind image deconvolution," *IEEE Signal Process. Mag.*, vol. 13, pp. 43–64, May 1996.
 [2] P. Campisi and Egiarian. K., Eds., *Blind image deconvolution: theory and applications*, CRC Press, New York, 2007.

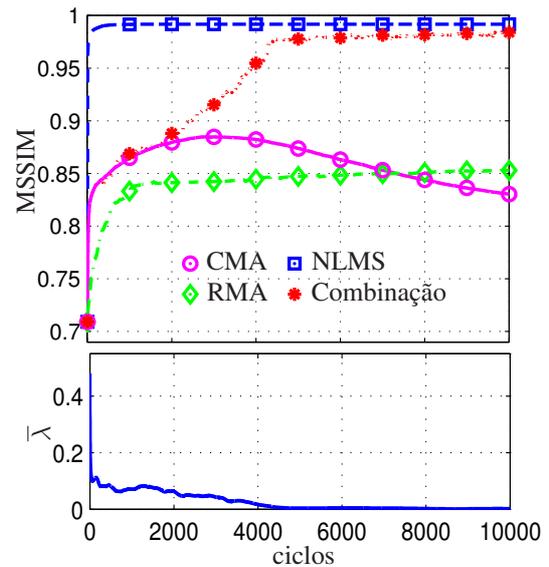


Fig. 8. Similaridade estrutural média (MSSIM) de cada algoritmo e valor médio do parâmetro de mistura ($\bar{\lambda}$) ao longo dos ciclos de varredura.

[3] M. S. C. Almeida and L. B. Almeida, "Blind and semi-blind deblurring of natural images," *IEEE Trans. on Image Process.*, vol. 19, pp. 36–52, Jan 2010.
 [4] M. S. C. Almeida and M. A. T. Figueiredo, "Parameter estimation for blind and non-blind deblurring using residual whiteness measures," *IEEE Trans. on Image Process.*, vol. 22, pp. 2751–2763, 2013.
 [5] C. R. Johnson-Jr. et al., "Blind equalization using the constant modulus criterion: a review," *Proc. IEEE*, vol. 86, pp. 1927–1950, Oct. 1998.
 [6] M. T. M. Silva and V. H. Nascimento, "Tracking analysis of the Constant Modulus Algorithm," in *Proc. IEEE Int. Conf. Acoustics, Speech, and Signal Process.*, Las Vegas, NV, 2008, pp. 3561–3564.
 [7] A. H. Sayed, *Fundamentals of Adaptive Filtering*, Wiley, NJ, 2003.
 [8] C. R. Johnson-Jr. et al., "The core of FSE-CMA behavior theory," in *Unsupervised adaptive filtering: blind equalization*, S. Haykin, Ed., vol. II. Wiley, NY, 2000.
 [9] F. C. C. De Castro, M. C. F. De Castro, and D. S. Arantes, "Concurrent blind deconvolution for channel equalization," in *Proc. of ICC'2001*, 2001, vol. 2, pp. 366–371.
 [10] S. Chen, "Low complexity concurrent constant modulus algorithm and soft directed scheme for blind equalization," *IEE Proceedings - Vision, Image, and Signal Process.*, vol. 150, pp. 312–320, Oct. 2003.
 [11] J. Mendes-Filho, M. D. Miranda, and M. T. M. Silva, "A regional multimodulus algorithm for blind equalization of QAM signals: introduction and steady-state analysis," *Signal Process.*, vol. 92, pp. 2643–2656, Nov. 2012.
 [12] M. T. M. Silva and J. Arenas-García, "A soft-switching blind equalization scheme via convex combination of adaptive filters," *IEEE Trans. on Signal Process.*, vol. 61, pp. 1171–1182, Mar. 2013.
 [13] C. Vural and W. A. Sethares, "Blind image deconvolution via dispersion minimization," *Digital Signal Process.*, vol. 16, pp. 137–148, 2006.
 [14] R. Abreu and M. T. M. Silva, "A multimodulus algorithm for blind image deconvolution," in *Proc. of Int. Workshop on Telecommunications (IWT)*, Rio de Janeiro, Brazil, 2011, pp. 35–41.
 [15] J. Mendes Filho, M. D. Miranda, and M. T. M. Silva, "A regional multimodulus algorithm for blind image deconvolution," in *Proc. IEEE Int. Conf. on Image Process. (ICIP)*, Paris, France, 2014, pp. 4512–4516.
 [16] J. Arenas-García, A. R. Figueiras-Vidal, and A. H. Sayed, "Mean-square performance of a convex combination of two adaptive filters," *IEEE Trans. on Signal Process.*, vol. 54, pp. 1078–1090, Mar. 2006.
 [17] L. A. Azpicueta-Ruiz, A. R. Figueiras-Vidal, and J. Arenas-García, "A normalized adaptation scheme for the convex combination of two adaptive filters," in *Proc. IEEE Int. Conf. Acoustics, Speech, and Signal Process.*, Las Vegas, NV, 2008, pp. 3301–3304.
 [18] M. Lázaro-Gredilla, L. A. Azpicueta-Ruiz, A. R. Figueiras-Vidal, and J. Arenas-García, "Adaptively biasing the weights of adaptive filters," *IEEE Trans. on Signal Process.*, vol. 58, pp. 3890–3895, Jul. 2010.
 [19] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: from error visibility to structural similarity," *IEEE Trans. Image Process.*, vol. 13, no. 4, pp. 600–612, 2004.