Classificador SLFN-ELM aplicado à verificação de adulteração de imagens baseada em padrão CFA

Camilo Lélis Assis Gonçalves e Ronaldo de Freitas Zampolo

***Resumo*— A disponibilidade atual de softwares de edição de imagens de grande qualidade e custo cada vez menor tem motivado o desenvolvimento de técnicas automáticas para verificação de adulterações em imagens e vídeos digitais. Neste trabalho, é proposta uma estratégia de decisão baseada em classificadores SLNF-ELM para um detector de adulterações que analisa a integridade do padrão de interpolação CFA. A validade da proposta é avaliada mediante apresentação e discussão de resultados tanto para padrões CFA sintéticos quanto reais. As taxas de acerto de classificação apresentadas demonstram que a abordagem proposta possui potencial para uso em situações práticas.**

***Palavras-Chave*— Detecção automática de adulteração, classificador SLFN, Extreme Learning Machine, Algoritmo EM, arranjos de filtros de cor.**

***Abstract*— Current availability of image editing software with high levels of quality and continuously decreasing cost has been motivating the development of automatic techniques for detecting digital image forgeries. In this paper, we propose a decision strategy based on SLNF-ELM classifiers for a forgery detector that considers the integrity of CFA interpolation pattern. The effectiveness of the proposal is assessed by the presentation and discussion of results for synthetic as well as actual CFA interpolation. Classification accuracy figures show the proposed approach is feasible to be used in practical situations.**

***Keywords*— Automatic forgery detection, SLFN classifier, Extreme Learning Machine, EM, colour filter array.**

I. Introdução

Sistemas de aquisição de imagens digitais, embarcados ou não em dispositivos móveis, estão cada vez mais sofisticados e com custo relativo menor. Esse desenvolvimento tem sido acompanhado de perto pelo lançamento de softwares de edição de imagens igualmente acessíveis ao usuário comum.

A qualidade do resultado final obtida por esses softwares é tão boa, em termos visuais, que a verificação de adulteração torna-se difícil, mesmo para especialistas (ver exemplos em http://area.autodesk.com/fakeorfoto e https://www.reddit.com/r/photoshopbattles).

Tal contexto vem motivando pesquisas no desenvolvimento de técnicas automáticas para detecção de fraudes em imagens digitais. Os dois principais problemas para os quais se busca solução nessa área são [1]: (a) identificação de dispositivo; e (b) detecção de adulteração. A identificação de dispositivo tem por objetivo descobrir se uma câmera sob suspeição produziu uma determinada imagem. Por sua vez, a detecção de adulteração procura avaliar se uma imagem em particular foi de alguma forma alterada ou modificada. As diferentes técnicas propostas podem ser classificadas em [2]–[4]: (a) ativas; e (b) passivas ou cegas. As técnicas ativas pressupõem pré-processamento e inserção de informações de autenticação durante o processo de criação de imagem, tal como as técnicas de marca d'água digital. Por sua vez, as técnicas passivas assumem que tanto sistemas de aquisição quanto procedimentos de adulteração deixam traços na imagem resultante que podem ser avaliados *a posteriori*. Uma possível categorização das técnicas passivas considera as cinco principais classes [3]: (a) no domínio do pixel; (b) baseadas em formato; (c) baseadas nas características da câmera; (d) baseadas na física da aquisição; e (e) baseadas na geometria da aquisição. Dentre as técnicas passivas baseadas nas características da câmera, há uma abordagem de especial interesse para esse trabalho: a que explora as correlações entre pixels introduzidas pelas operações de interpolação que decorrem do uso de arranjo de filtros de cor (CFA, color filter array) superposto ao foto sensor [5]–[13].

O propósito deste trabalho é apresentar uma estratégia de decisão aplicada ao problema de verificação de adulteração de imagens, baseada em classificadores SLFN-ELM (single hidden layer feedforward network - extreme learning machine) [14]. Tal estratégia de decisão é usada em conjunto com a técnica elaborada por Pospescu e Farid [6], em que o algoritmo EM (expectation-maximization) [15] é empregado para estimar a probabilidade de cada região de uma imagem ter sido obtida por interpolação CFA.

O restante deste texto encontra-se organizado como segue. Na Seção II são comentados os princípios da técnica proposta por Popescu e Farid [6]. Na Seção III são apresentados detalhes da estratégia de classificação proposta. Em seguida, na Seção IV, são definidos os procedimentos experimentais de avaliação de desempenho do sistema de detecção de adulteração em imagens digitais, bem como apresentados os resultados correspondentes. As conclusões são enumeradas na Seção V, e em seguida encontra-se a lista de referências.

II. Uso do padrão de interpolação CFA para avaliar adulteração de imagens

Nesta seção, encontram-se resumidos os principais conceitos da técnica detalhada em [6]. Tal resumo contextualiza a proposta apresentada neste texto, auxiliando no seu entendimento.

A. O arranjo de Bayer

A maioria das câmeras digitais comercialmente disponíveis são equipadas com apenas um foto sensor, elemento capaz

Camilo Lélis Assis Gonçalves e Ronaldo de Freitas Zampolo, Faculdade de Engenharia da Computação e Telecomunicações, Instituto de Tecnologia, Universidade Federal do Pará, Belém-PA, Brasil, E-mails: camilo.goncalves@itec.ufpa.br, zampolo@ufpa.br.

de converter intensidade luminosa em corrente elétrica, porém com pouca ou nenhuma especificidade espectral. Para contornar esse problema, e portanto permitir que haja discriminação cromática em câmeras digitais, são utilizados *arranjos de filtros de cor* (CFA, *color filter array*), composições de pequenas cavidades revestidas por um material que atua como filtro óptico passa-banda, permitindo que apenas determinadas faixas do espectro luminoso incidente sejam transmitidos para o sensor.

Na Figura 1 está ilustrado o arranjo de Bayer [16], um dos padrões CFA mais conhecidos e que será utilizado como base nesse estudo. Pode-se observar nessa figura que os canais de cor estão sub-amostrados. Assim, para se obter uma imagem com canais de cor completos, os pixels ausentes em cada canal precisam ser estimados a partir de pixels vizinhos, um procedimento conhecido como interpolação CFA ou demosaificação, havendo várias técnicas propostas nesse sentido [17].

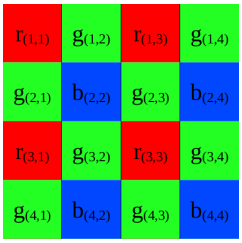

Fig. 1. Arranjo de Bayer, ilustrando a disposição dos padrões cromáticos de amostragem de uma imagem.

B. Estimação dos parâmetros de interpolação CFA via algoritmo EM

Considerando $f^i(x,y)$ um pixel de um dos canais de cor $i = \{r, g, b\}$ de uma imagem formada por interpolação CFA, assume-se que cada $f^i(x,y)$ pertence a uma das duas classes: M_1 para um pixel obtido por interpolação, e M_2 para um pixel não obtido por interpolação.

Os pixels interpolados são genericamente modelados como

$$f^i(x,y) = \sum_{u,v=-N}^{N} \alpha^i_{uv} f^i(x+u, y+v) + \eta^i(x,y), \qquad (1)$$

onde α^i_{uv} representa os parâmetros de interpolação para o canal i; N é um inteiro que determina a vizinhança de interpolação; e o termo $\eta^i(x,y)$ acomoda os desajustes de modelagem, sendo considerado como um processo aleatório do tipo branco gaussiano de média zero e variância desconhecida.

Na etapa E do algoritmo EM, a probabilidade de cada elemento $f^i(x,y)$ pertencer à classe M_1 é estimada, enquanto que no passo M, uma estimativa ótima dos parâmetros α^i_{uv} é computada. Os passos E e M são executados iterativamente até que uma estimativa estável dos termos α^i_{uv} seja alcançada, a partir da qual se cria um mapa da probabilidade $w^i(x,y)$ de cada pixel do canal de cor sob análise ter sido gerado mediante interpolação.

C. Detectando alterações em uma imagem

Os mapas de probabilidade de cada canal de cor i são divididos em regiões não superpostas j de dimensões $L \times L$, denominadas $w^i_j(x,y)$. A hipótese assumida é que a interpolação CFA impõe um padrão periódico no mapa de probabilidades que pode ser facilmente detectado no domínio de Fourier. Qualquer adulteração realizada em uma região da imagem afeta esse padrão, como mostrado na Figura 2.

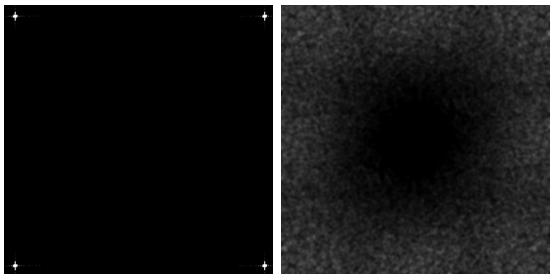

(a) (b)

Fig. 2. Magnitude da Transformada de Fourier dos mapas de probabilidade: (a) região não adulterada; (b) região adulterada.

Na proposta original [6], para se determinar se uma região j da imagem foi ou não adulterada, calcula-se a correlação entre as magnitudes das transformadas de Fourier do mapa de probabilidade estimado $w^i_j(x,y)$ e de um mapa de probabilidade sintético $s^i_j(x,y)$:

$$s^i_j(x,y) = \begin{cases} 0, & \text{para } f^i_j(x,y) \text{ não interpolado} \\ 1, & \text{para } f^i_j(x,y) \text{ interpolado} \end{cases} \qquad (2)$$

onde i representa um determinado canal de cor e j uma região.

Caso a correlação calculada esteja abaixo de um determinado limiar, considera-se que as correlações introduzidas por interpolação CFA não estão presentes na região, ou seja, que a região foi adulterada.

III. Estratégia de decisão proposta

A estratégia de classificação utilizando limiares simples apresenta problemas, pois observa-se experimentalmente que os valores ótimos de limiar variam de acordo com a imagem e com o tamanho das regiões. Tal dificuldade motivou a elaboração de uma abordagem de decisão alternativa, baseada em redes neurais do tipo SLFN (single hidden layer feed-forward network) cujas entradas são estatísticas relacionados aos mapas de probabilidade no domínio de Fourier.

A. Atributos de entrada

Dentre diferentes possibilidades testadas, os dois atributos que resultaram em melhores taxas de classificação são os apresentados a seguir:

1) Correlação normalizada (C): O atributo de correlação normalizada é definido por

$$C^i_j(W,S) = \frac{\sum_{m,n} |W^i_j(m,n)| \cdot |S^i_j(m,n)|}{\sum_{m,n} |W^i_j(m,n)|} \qquad (3)$$

onde (m,n) representa coordenadas no domínio de Fourier; $|\cdot|$ refere-se ao operador de módulo; e $W^i_j(m,n)$ e $S^i_j(m,n)$

são as transformadas de Fourier dos mapas de probabilidade $w_j^i(x,y)$ e $s_j^i(x,y)$, respectivamente.

Quanto maior o valor da razão na Equação 3 maior é a probabilidade da região ter tido a interpolação CFA preservada, ou seja, não ser sido adulterada. A normalização em relação à magnitude $W_j^i(m,n)$ visa compensar diferenças em termos de tamanho de região avaliada e conteúdo de imagem.

2) Variância da magnitude da Transformada de Fourier normalizada (V): A finalidade deste atributo é representar a informação a respeito da concentração de coeficientes no domínio transformado, sendo definido como

$$V_j^i(W) = \text{var}\left(\frac{W_j^i}{\max(W_j^i)}\right) \tag{4}$$

onde var$(\cdot)$ indica o cálculo da variância e $\max(\cdot)$ representa o operador de valor máximo.

Quanto menor o valor de V_j^i, maior é a probabilidade da região analisada ter tido a interpolação CFA preservada.

IV. Procedimento experimental e resultados

A metodologia utilizada para avaliar a estratégia proposta consistiu na análise de dois casos. No primeiro, objetivou-se estabelecer condições controladas, aplicando um procedimento específico a fim de substituir o padrão de interpolação CFA original de imagens de teste por técnicas de interpolação conhecidas pelos experimentadores. No segundo caso, a fim de criar um ambiente de trabalho mais realístico, as imagens de teste utilizadas não foram submetidas ao mesmo procedimento do primeiro caso, assim preservando o padrão CFA real do equipamento de aquisição, bem como outros fatores introduzidos tais como, por exemplo, compressão JPEG.

A. Caso 1

Foram utilizadas dez imagens geradoras do conjunto de teste, sendo sete obtidas por câmeras de diferentes aparelhos celulares e três obtidas por câmeras digitais convencionais (standalone, não embarcadas).

A fim de destruir as correlações introduzidas pela interpolação CFA nativa do dispositivo de origem, cada uma das imagens geradoras do conjunto de teste teve seus canais de cor independentemente filtrados (filtro binomial 3×3) e subamostrados por um fator de dois. Em seguida, foram criadas cópias de cada versão das imagens obtidas. Cada cópia teve seus canais cromáticos amostrados conforme o arranjo de Bayer (Fig. 1) a fim de simular as imagens em mosaico obtidas pelos dispositivos de captura antes da execução do processo de interpolação nativa do mesmo. Em seguida imagens com canais de cor completos são determinadas através da interpolação dos mosaicos utilizando os métodos de interpolação *Bilinear*, *Bicúbica*, *Transição Suave de matiz de Saturação* [18], por *Filtro de Mediana* [19], *Baseada em Gradientes* [20] e *Planos de Cor Adaptativos* [21]. Ao todo foram geradas 70 imagens: 60 com interpolação conhecida e 10 sem interpolação.

Visando a reprodutibilidade dos resultados aqui apresentados, a implementação utilizada, bem como imagens de teste e tabelas contendo exemplos rotulados, estão disponíveis em https://github.com/TheCamilovisk/cfa_detector. No arquivo de descrição do projeto (arquivo README, no mesmo repositório) estão especificados os parâmetros iniciais adotados.

1) Treinamento e teste do classificador: Para a classificação das imagens em interpolada ou não-interpolada, foram treinadas redes SLFN com algoritmo ELM (extreme learning machine), uma para cada método de interpolação utilizado neste estudo. A razão da escolha dessa abordagem foi a baixa complexidade computacional na fase de treinamento e dos bons resultados obtidos em comparação com as soluções obtidas por estratégias de treinamento convencionais [14].

Dentre as imagens interpoladas, foram escolhidas aleatoriamente 5 de cada tipo de interpolação. Cada imagem e suas versões não interpoladas foram recortadas para as dimensões de 1536×1024 pixels e processadas segundo a metodologia descrita em II-C para a obtenção dos mapas de probabilidade correspondentes, que foram divididos igualmente em regiões não sobrepostas de dimensões arbitrárias. Em seguida, vetores de características como o descrito na Figura 3 foram computados para cada região. Tais vetores foram utilizados como entradas para os classificadores SLFN-ELM.

Referente ao canal vermelho		Referente ao canal verde		Referente ao canal azul	
V_j^r	C_j^r	V_j^g	C_j^g	V_j^b	C_j^b

Fig. 3. Vetor de características referente a uma região j utilizado como entrada do classificador SLFN-ELM.

Neste estudo foram utilizadas regiões de duas dimensões diferentes: $L = 128$, resultando em 960 exemplos rotulados (480 regiões não-interpoladas e 480 regiões interpoladas) para cada classificador; e $L = 256$, resultando em 240 exemplos rotulados (120 regiões não-interpoladas e 120 regiões interpoladas) para cada classificador. Para o treinamento, foram aleatoriamente selecionados 80% do total de exemplos, enquanto os 20% restantes formaram o conjunto de teste.

2) Testes de desempenho dos classificadores: Nas Figuras 4 e 5 são exibidos os gráficos da média da taxa de acerto de classificação na fase de teste (ϕ) em função do número de neurônios presentes na camada escondida, para cada tipo de interpolação usada. Neste estudo define-se a taxa de acerto como a razão entre o número de classificações corretas e o número total de classificações realizadas. Tanto na fase de treinamento quanto na de testes, o número de neurônios na camada oculta foi variado de 5 a 100, com um passo de uma unidade. Cada ponto no gráfico representa a média da taxa de acertos na etapa de teste proveniente de 20 realizações do classificador SLFN-ELM para um determinado número de neurônios da camada oculta.

3) Detecção de traços de interpolação CFA em uma imagem: Foi escolhida uma imagem não pertencente ao conjunto de imagens utilizado para a criação da base de dados de treinamento, e foram executados os procedimentos mencionados anteriormente para a obtenção de uma versão sem interpolação e versões interpoladas para cada método de interpolação escolhido para estudo. A fim de simular imagens adulteradas, cada versão interpolada foi dividida em regiões de dimensões 256×256, e 30% das regiões foram escolhidas aleatoriamente

TABELA I
MÉDIA DE TAXA DE ACERTO DE CLASSIFICAÇÃO PARA UMA DAS IMAGENS DE TESTE USADAS.

Interpolação	$L = 128$	$L = 256$
Bilinear	0.9861	1.0000
Bicúbica	0.9583	1.0000
Transição suave de matiz [18]	0.9722	1.0000
Filtro de mediana 5×5 [19]	0.9166	0.9444
Baseada em gradientes [20]	0.9583	1.0000
Planos de cor adaptativos [21]	0.9166	1.0000

e substituídas pelas regiões correspondentes na versão sem interpolação. Os mapas de probabilidade de cada imagem foram computados, divididos em regiões de dimensões $L \times L$ e seus vetores de características foram calculados e fornecidos de entrada para os classificadores. Na Tabela I são exibidas as médias de taxa de acerto na classificação para cada método de interpolação e dimensões de blocos utilizadas. O número de neurônios escolhido para camada oculta da SLFN, com base nos gráficos das Figuras 4 e 5 foi de 80.

4) Análise de resultados: Pode-se observar nas Figuras 4 e 5 que o desempenho do sistema de detecção de adulterações varia em função tanto do tipo de interpolação utilizado, quanto dos valores de L. Nota-se, especificamente, tendência à melhora de desempenho com o aumento de L. Não obstante, em todos os testes realizados, verifica-se média de taxa de acerto não inferior a 90%. As principais razões para tais níveis de acerto são, provavelmente, o fato de se ter treinado um classificador específico para cada tipo de interpolador, bem como

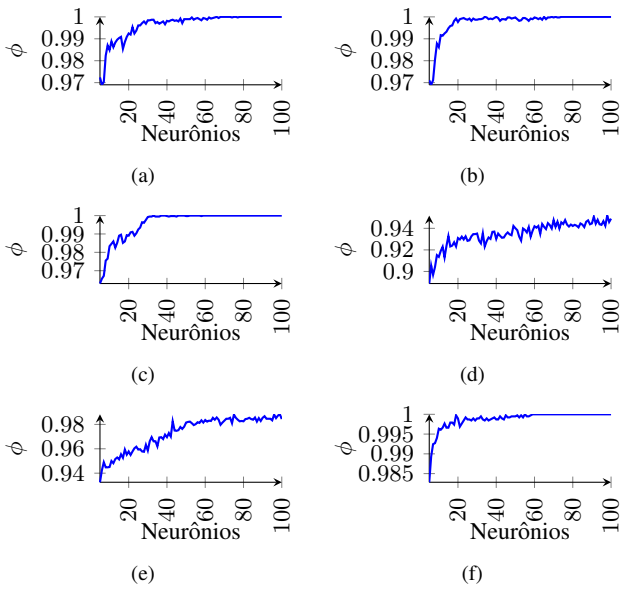

Fig. 4. Média da taxa de acerto de classificação na fase de teste (ϕ) para $L = 128$ para vários tipos de interpolação: (a) bilinear, (b) bicúbica, (c) transição suave de matriz de saturação, (d) filtro de mediana 5×5, (e) baseada em gradiente, e (f) planos de cor adaptativos.

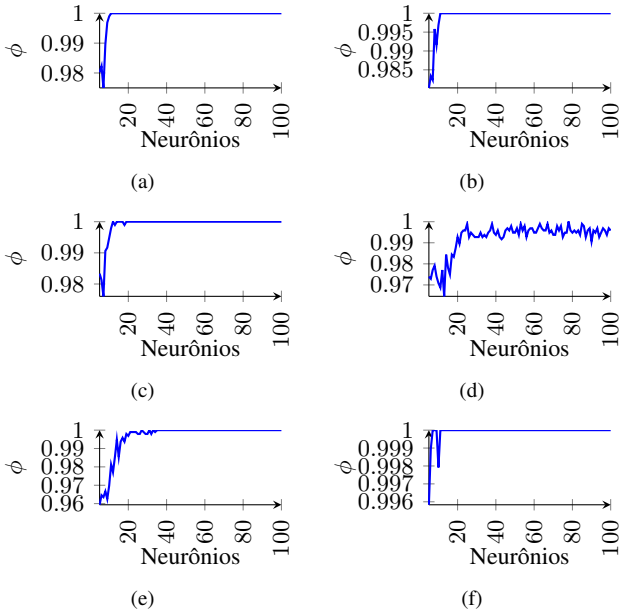

Fig. 5. Média da taxa de acerto de classificação na fase de teste (ϕ) para $L = 256$ para vários tipos de interpolação: (a) bilinear, (b) bicúbica, (c) transição suave de matriz de saturação, (d) filtro de mediana 5×5, (e) baseada em gradiente, e (f) planos de cor adaptativos.

assumir conhecidas as dimensões das regiões adulteradas.

Apesar do aspecto restritivo em termos práticos, considerar classificadores específicos é factível em situações reais, desde que se conheça, ao menos, o modelo de câmera usado na aquisição de uma imagem suspeita, o que permitiria a realização de ensaios que resultassem em classificadores otimizados para o padrão CFA do referido modelo. Por outro lado, como as regiões eventualmente adulteradas de uma imagem podem ter localização e área arbitrárias, as estratégias de detecção em maior sintonia com uma aplicação real deveriam permitir que L fosse adaptativo.

B. Caso 2

Foram coletadas 6 imagens de uma câmera digital modelo *Sony Cyber-shot DSC-H400*, sendo três de resolução 5152×3864 e outras três de resolução 2592×1944, salvas em formato JPEG. Para cada uma das imagens, foi criada uma versão obtida por filtro de má focalização gaussiana disponível no software GIMP. Tal processo de filtragem teve por objetivo alterar as correlações existentes devido à interpolação CFA, formando, assim, as imagens consideradas adulteradas.

Uma base de dados foi gerada utilizando as imagens coletadas e filtradas seguindo as mesmas diretrizes da Seção IV para $L = 512$. Em seguida a base foi submetida ao teste descrito em IV-A.2. Os resultados são exibidos na Figura 6.

A Figura 7 mostra o resultado para o teste de detecção de interpolação CFA descrito em IV-A.3 repetido para uma imagem da mesma câmera com resolução 5152×3864, onde em (a) são indicadas as posições das regiões adulteradas da imagem de teste, enquanto em (b) são exibidas as regiões estimadas como adulteradas. Com o auxílio da Figura 6, o número de neurônios na camada escondida escolhido foi de 60. Neste teste, a taxa de acerto foi de aproximadamente 0.9142.

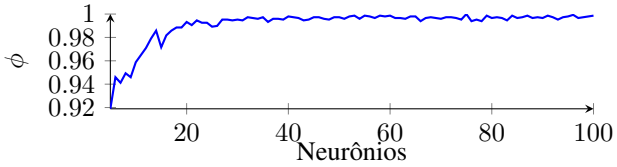

Fig. 6. Média da taxa de acerto de classificação na fase de teste (ϕ) para $L = 512$.

(a)

(b)

Fig. 7. Exemplo de um resultado prático: (a) imagem de teste onde estão indicadas as regiões adulteradas (em preto); (b) resultado obtido pelo classificador proposto, onde as regiões estimadas como adulteradas estão indicadas em vermelho.

1) Análise de resultados: Pode-se constatar que, apesar de ser um bom resultado, o exemplo da Figura 7 apresenta uma taxa de acerto de classificação abaixo do que seria esperado pelo gráfico da Figura 6. É importante ressaltar que, para o treinamento do classificador, os vetores de características provenientes de blocos rotulados como interpolados e não interpolados são originários de imagens que, respectivamente, não sofreram qualquer tipo de alteração e que foram totalmente adulteradas, ao passo que o mapa de probabilidade estimado na fase de teste foi obtido de uma imagem que contém tanto regiões adulteradas quanto não adulteradas.

V. Conclusão

Neste trabalho, foi proposto o uso de um classificador SLFN-ELM na etapa de decisão da técnica para verificação de adulteração de imagens apresentada por Farid et al. [6]. Ressalta-se a proposição adicional de duas funções cujos valores são usados como atributos de entrada do referido classificador. Os resultados, obtidos tanto de imagens em que o padrão CFA é conhecido e imposto, quanto de imagens com padrão CFA desconhecido, demonstram o potencial de utilização prática da técnica, ao passo que suscitam a necessidade de investigação mais ampla sobre o desempenho da estratégia proposta para imagens com diferentes padrões de interpolação CFA, bem como sobre o impacto que a presença combinada de regiões adulteradas e não adulteradas na imagem sob análise pode ter na classificação.

Referências

[1] Tian Tsong Ng, Shih Fu Chang, Ching Yung Lin, and Qibin Sun. Passive-blind Image Forensics. *Multimedia Security Technologies for Digital Rights Management*, (October):383–412, 2006.

[2] Weiqi Luo, Zhenhua Qu, Feng Pan, and Jiwu Huang. A survey of passive technology for digital image forensics. *Frontiers of Computer Science in China*, 1(2):166–179, may 2007.

[3] Hany Farid. Image forgery detection. *IEEE Signal Processing Magazine*, 26(2):16–25, 2009.

[4] Babak Mahdian and Stanislav Saic. A bibliography on blind methods for identifying image forgery. *Signal Processing: Image Communication*, 25(6):389–399, 2010.

[5] Hong Cao and Alex C. Kot. Accurate detection of demosaicing regularity for digital image forensics. *IEEE Transactions on Information Forensics and Security*, 4(4):899–910, 2009.

[6] A.C. Popescu and H. Farid. Exposing digital forgeries in color filter array interpolated images. *Signal Processing, IEEE Transactions on*, 53(10):3948–3959, Oct 2005.

[7] Ashwin Swaminathan, Min Wu, and K. J Ray Liu. Digital image forensics via intrinsic fingerprints. *IEEE Transactions on Information Forensics and Security*, 3(1):101–117, 2008.

[8] Andrew C Gallagher, Tsuhan Chen, and Eastman Kodak Company. Image Authentication by Detecting Traces of Demosaicing. 2008.

[9] Babak Mahdian and Stanislav Saic. Blind authentication using periodic properties of interpolation. *IEEE Transactions on Information Forensics and Security*, 3(3):529–538, 2008.

[10] Matthias Kirchner. Efficient estimation of cfa pattern configuration in digital camera images. volume 7541, pages 754111–754111–12, feb 2010.

[11] Pasquale Ferrara, Tiziano Bianchi, Alessia De Rosa, and Alessandro Piva. Image forgery localization via fine-grained analysis of CFA artifacts. *IEEE Transactions on Information Forensics and Security*, 7(5):1566–1577, 2012.

[12] Chang Hee Choi, Hae Yeoun Lee, and Heung Kyu Lee. Estimation of color modification in digital images by CFA pattern change. *Forensic Science International*, 226(1-3):94–105, 2013.

[13] Tang You Chang, Shen Chuan Tai, and Guo Shiang Lin. A passive multi-purpose scheme based on periodicity analysis of CFA artifacts for image forensics. *Journal of Visual Communication and Image Representation*, 25(6):1289–1298, 2014.

[14] Guang-Bin Huang, Qin-Yu Zhu, and Chee-Kheong Siew. Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3):489 – 501, 2006. Neural Networks Selected Papers from the 7th Brazilian Symposium on Neural Networks (SBRN '04) 7th Brazilian Symposium on Neural Networks.

[15] A. P. Dempster, N. M. Laird, and D. B. Rubin. Maximum likelihood from incomplete data via the em algorithm. *JOURNAL OF THE ROYAL STATISTICAL SOCIETY, SERIES B*, 39(1):1–38, 1977.

[16] B.E. Bayer. Color imaging array, July 20 1976. US Patent 3,971,065.

[17] Rajeev Ramanath, Wesley E. Snyder, Griff L. Bilbro, and William A. Sander Iii. Demosaicking methods for bayer color arrays. *Journal of Electronic Imaging*, 11:306–315, 2002.

[18] D.R. Cok. Signal processing method and apparatus for producing interpolated chrominance values in a sampled color image signal, February 10 1987. US Patent 4,642,678.

[19] W.T. Freeman. Median filter for reconstructing missing color samples, February 9 1988. US Patent 4,724,395.

[20] R.H. Hibbard. For processing a digitized image signal, January 17 1995. US Patent 5,382,976.

[21] J.E. Adams and J.F. Hamilton. For processing a digitized image signal, July 29 1997. US Patent 5,652,621.