

Uma Estratégia de Identificação de Dispositivo de Aquisição de Imagens Baseada em PRNU

Hermeson Barbosa da Costa, Eduardo Luiz Ortiz Batista e Rui Seara

Resumo—A não uniformidade da fotorresposta (*photo-response nonuniformity* – PRNU) é uma característica de fotossensores utilizada em análise forense para identificação de dispositivos de aquisição de imagens. As taxas de sucesso das técnicas baseadas nessa característica tendem a ser limitadas para imagens de baixa resolução. Nesse contexto, este trabalho propõe uma abordagem baseada em PRNU para identificação de dispositivos na qual a imagem é decomposta em subimagens visando reduzir o efeito da interpolação e melhorar a estimativa da PRNU. Assim, resultados melhores para imagens de baixa resolução são obtidos, conforme observado em experimentos realizados com imagens de câmeras de celulares.

Palavras-Chave—Identificação de dispositivo de aquisição, imagem digital, PRNU, ruído de interpolação.

Abstract—The photo-response nonuniformity (PRNU) is a characteristic of photosensors used in forensic analysis for the identification of image acquisition devices. The success rates of the techniques based on such a characteristic tend to be limited for low-resolution images. In this context, this paper proposes a new PRNU-based approach in which the image is decomposed in sub-images aiming to reduce the impact of the interpolation and thus to enhance the PRNU estimate. Thereby, improved results even on low-resolution images are obtained, as illustrated in experiments carried out using images from cellphone cameras.

Keywords—Acquisition device identification, digital image, interpolation noise, PRNU.

I. INTRODUÇÃO

Em análise forense, uma das perícias de maior interesse é a identificação de dispositivo de aquisição [1]. Tal prática tem por objetivo responder se uma mídia (imagem ou vídeo) investigada foi adquirida por um determinado dispositivo (e.g., câmera digital ou celular) sob suspeição em casos envolvendo, por exemplo, pirataria ou pedofilia. Algumas das metodologias empregadas para realizar essa perícia são baseadas em informações inseridas na mídia pelo equipamento de aquisição, como o número de série do dispositivo no cabeçalho de arquivo ou a marca d'água digital [1]. Uma outra classe de técnicas de identificação de dispositivos baseia-se na exploração de artefatos deixados na imagem durante o processo de aquisição, como, por exemplo, distorções das lentes, padrão de interpolação, poeiras no sensor, defeitos dos elementos fotossensores, ou ruído de padrão fixo [1]. Além de tais artefatos, uma outra característica que vem sendo explorada

com sucesso é a não uniformidade da fotorresposta (*photo-response nonuniformity* – PRNU). A PRNU é um padrão de ruído causado pelas imperfeições do processo de manufatura do fotossensor e apresenta as seguintes características: a) é única para cada sensor; b) está presente em todas as imagens adquiridas pelo sensor; c) é robusta às várias operações de processamento de imagem, tais como compressão com perdas e rotação; d) é estável no tempo. Como consequência, a PRNU é usualmente considerada a *impressão digital* ou *marca d'água natural* do dispositivo, o que motiva o seu uso em aplicações forenses de identificação de dispositivo.

O processo de identificação de dispositivo de aquisição baseado em PRNU envolve duas etapas distintas: *estimação* e *deteção*. Na primeira, estima-se a impressão digital (PRNU) da câmera suspeita a partir de um conjunto de imagens comprovadamente adquiridas por ela. Segundo [2], essa estimativa pode ser realizada através da média de várias imagens de cenas aleatórias. Para reduzir o número de imagens necessárias, um filtro de extração de ruído é utilizado visando suprimir o conteúdo da imagem. Na segunda etapa do processo de identificação (a deteção), utiliza-se alguma métrica de similaridade estatística para avaliar a presença dessa impressão digital na imagem investigada. Caso o valor obtido por essa métrica seja maior do que um limiar de decisão pré-definido, diz-se que a imagem foi adquirida pela câmera suspeita. Uma métrica comumente utilizada é o coeficiente de correlação de Pearson (*Pearson's correlation coefficient* – CC).

Diversos trabalhos dedicados à identificação de dispositivos baseada em PRNU podem ser encontrados na literatura. Por exemplo, Chen *et al.* [3] propuseram um estimador de máxima verossimilhança da PRNU e observaram que estimativas da impressão digital de dispositivos de mesmo modelo contém alguns artefatos indesejados. Para suprimir tais artefatos, a média de cada linha e coluna da PRNU é removida e, em seguida, um filtro de Wiener no domínio da frequência é aplicado. Em tal trabalho, outra métrica foi utilizada na etapa de deteção, o pico de energia de correlação (*peak-to-correlation energy* – PCE), considerado mais estável do que o CC. Em [4], foi apresentada uma estratégia de definição do limiar de decisão utilizando o PCE. No entanto, para imagens de baixa resolução, o desempenho de tal métrica tende a piorar [5]. Kang *et al.* [5] transformaram o ruído residual da imagem em um sinal com espectro de frequência plano para eliminar a interferência dos detalhes da imagem e das operações de compressão com perdas, e também do processo de interpolação. A estimativa da PRNU é obtida pela média dos ruídos de no mínimo 100 imagens. Tais autores também apresentaram uma métrica de similaridade estatística que mede a razão entre a correlação e a norma da correlação cruzada

Hermeson Barbosa da Costa, Eduardo Luiz Ortiz Batista e Rui Seara, LINSE – Laboratório de Circuitos e Processamento de Sinais, Departamento de Engenharia Elétrica e Eletrônica, Universidade Federal de Santa Catarina, Florianópolis - SC, Brasil, E-mails: hermeson@linse.ufsc.br, ebatista@ieee.org, 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).

circular (*correlation over circular cross-correlation norm* – CCN), resultando em menor taxa de erro comparada com o PCE. Qu *et al.* [6] propuseram a criação de um banco de imagens extraídas de ruídos aleatórios (exibidos em um monitor de alta definição) e apresentaram uma metodologia de estimação da PRNU baseada na filtragem homomórfica da média dessas imagens. Em [7], foi desenvolvido um estimador da média da PRNU em conjunto com um filtro de extração de ruído baseado no algoritmo de interpolação de contexto adaptativo. Essa metodologia requer um conjunto de no mínimo 100 imagens para fornecer estimativas adequadas da PRNU [7]. Além disso, a metodologia apresentada em [8] consiste em decompor a imagem em quatro subimagens e aplicar, em cada subimagem, o filtro de extração de ruído. Em seguida, os ruídos extraídos das quatro subimagens são reagrupados para formar o ruído residual que será submetido a um estimador de máxima verossimilhança para obtenção da PRNU. Essa decomposição visa atenuar o impacto do ruído de interpolação na estimação do ruído residual da imagem e, assim, melhorar o processo de identificação.

Este trabalho propõe uma abordagem que, similarmente à dada em [8], é baseada na decomposição da imagem em subimagens visando atenuar o impacto do ruído de interpolação. A diferença da abordagem proposta aqui, em relação à de [8], está no fato de que todo o processo de estimação da PRNU (estimador de máxima verossimilhança e operações de pós-processamento [3]) é realizado com as subimagens. Assim, sub-PRNUs são obtidas a partir das subimagens, sendo tais sub-PRNUs agrupadas para formar a PRNU que é utilizada na etapa de detecção do processo de identificação de dispositivo. Dessa forma, melhores estimativas de PRNU são obtidas como consequência do melhor desempenho alcançado através das operações de pós-processamento. Experimentos realizados com imagens adquiridas por câmeras de celulares mostram que a metodologia proposta apresenta melhor desempenho em termos de taxa de sucesso, particularmente, para imagens de baixa resolução.

O restante deste trabalho está organizado como segue. A Seção II apresenta um modelo simplificado do processo de aquisição de imagens digitais e revê o processo de identificação de dispositivo de aquisição. A Seção III introduz a abordagem proposta neste trabalho. Na Seção IV, os experimentos realizados e os resultados obtidos são discutidos. Por fim, a Seção V apresenta as conclusões deste trabalho de pesquisa.

II. IDENTIFICAÇÃO DE DISPOSITIVOS DE AQUISIÇÃO BASEADA EM PRNU

Esta seção descreve sucintamente um modelo de aquisição de imagem digital de duas dimensões (2D) e revisita a metodologia de identificação de dispositivo baseada em PRNU.

A. Aquisição de Imagem Digital

Um sistema de aquisição de imagem digital comum à maioria dos dispositivos de aquisição [9] é ilustrado na Fig. 1. Os raios de luz da cena real passam pela lente que os focaliza sobre um arranjo de filtros de cor (*color filter array* – CFA).

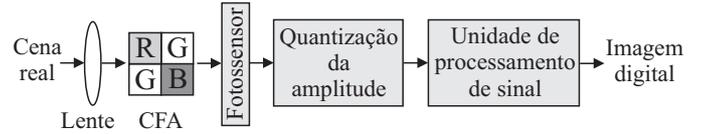


Fig. 1. Processo de aquisição de imagem digital de duas dimensões (2D).

O CFA é utilizado para separar as informações de cor da luz, dado que os fotossensores não possuem essa capacidade. Usualmente, o CFA utilizado é o filtro de *Bayer* [10], que decompõe a luz em seus componentes vermelho, verde e azul, i.e., padrão RGB. Seguindo o processo de aquisição, a luz incide sobre o fotossensor, que é uma matriz de elementos semicondutores fotossensíveis feitos de silício e que capturam a luz incidente, convertendo os fótons em elétrons através do efeito fotoelétrico. A carga que deixa o fotossensor é amplificada e convertida em sinal digital por um conversor analógico-digital. O sinal digitalizado segue até a unidade de processamento de sinais, que realiza, dentre outros processamentos, a interpolação dos canais de cores (*demosaicing*), a correção gama e a codificação, geralmente JPEG [9]. Por fim, tem-se um conjunto de elementos de imagem discretos, denominados *pixels*, que formam a imagem digital.

O processo de aquisição de um canal de cor de uma imagem digital colorida pode ser modelado como [11]

$$\mathbf{I} = g^\gamma [\mathbf{Y} + \mathbf{Y}\mathbf{K} + \mathbf{\Omega}]^\gamma + \mathbf{Q} \quad (1)$$

onde g é o fator de ganho (diferente para cada canal cromático), \mathbf{Y} é a intensidade luminosa que incide sobre o fotossensor, \mathbf{K} é um ruído de média zero que representa a PRNU, $\mathbf{\Omega}$ denota uma combinação de várias outras fontes de ruído, como corrente negra e ruído de leitura, γ é o fator de correção gama (geralmente, $\gamma \cong 0.45$), e \mathbf{Q} representa o ruído de quantização e/ou codificação introduzido pelo sistema de aquisição. É importante ressaltar que, neste trabalho, todas as operações envolvendo matrizes são do tipo elemento-a-elemento.

B. Estimação

Dado o modelo de aquisição de imagem descrito por (1), a estimativa de máxima verossimilhança da PRNU pode ser computada por [3]

$$\hat{\mathbf{K}} = \frac{\sum_{k=1}^d \mathbf{W}_k \mathbf{I}_k}{\sum_{k=1}^d \mathbf{I}_k^2} \quad (2)$$

onde $\hat{\mathbf{K}}$ é uma estimativa de \mathbf{K} , \mathbf{I}_k corresponde a k -ésima imagem obtida pela câmera suspeita, d é o número de imagens usadas na estimação, e $\mathbf{W}_k = \mathbf{I}_k - F(\mathbf{I}_k)$ é o ruído residual obtido usando um filtro de extração de ruído $F(\cdot)$. Detalhes sobre o filtro usado neste trabalho podem ser encontrados em [11] e [12]. Conforme descrito em [11] e [13], as melhores imagens para estimar a PRNU são as de alta luminosidade e pouca variância. Assim, recomenda-se o uso, por exemplo, de imagens de céu nublado. A quantidade de imagens d a ser utilizada depende da câmera em questão. Em geral, estimativas adequadas são obtidas com $d = 20$ [13].

A estimativa $\hat{\mathbf{K}}$ da PRNU contém alguns artefatos introduzidos por operações, tais como interpolação dos canais de cores e compressão com perdas [3]. Esses artefatos são comuns a impressões digitais de dispositivos de aquisição de mesmo modelo (ou design) do fotossensor e, portanto, eles podem aumentar a taxa de erro do sistema de identificação. Os artefatos causados pelos algoritmos de interpolação são, em geral, periódicos e dependem do padrão do CFA implementado. Tais ruídos podem ser suprimidos removendo as médias de cada linha e coluna de $\hat{\mathbf{K}}$. Os demais artefatos podem ser atenuados por um filtro de Wiener no domínio da frequência [3], i.e.,

$$\mathbf{F} = \mathcal{F}(\hat{\mathbf{K}}), \quad \hat{\mathbf{K}} \leftarrow \text{Real} \left[\mathcal{F}^{-1} \left(\mathbf{F} \cdot \frac{|\mathbf{F}| - W(|\mathbf{F}|, \sigma^2)}{|\mathbf{F}|} \right) \right] \quad (3)$$

onde $\mathcal{F}(\cdot)$ é o operador de transformada de Fourier, $W(\cdot, \cdot)$ é o filtro de Wiener, e σ^2 é a variância de $\hat{\mathbf{K}}$ [13]. No caso de imagens coloridas, as estimativas da PRNU são obtidas de cada canal, sendo tais estimativas posteriormente combinadas utilizando uma conversão para escala de cinza.

C. Detecção

Como descrito na Seção I, após a estimação da PRNU da câmera suspeita, utiliza-se alguma métrica de similaridade estatística para verificar se a imagem investigada contém essa impressão digital. Este trabalho utiliza a CCN, que de acordo com [5], apresenta uma menor taxa de erro do que o PCE. Essa métrica é definida como [5]

$$c(\mathbf{x}, \mathbf{y}) = \frac{r_{\mathbf{xy}}(0, 0)}{\sqrt{\frac{1}{MN-|\mathbf{A}|} \sum_{i,j \notin \mathbf{A}} r_{\mathbf{xy}}^2(i, j)}} \quad (4)$$

onde $r_{\mathbf{xy}}(i, j)$ é a correlação cruzada circular entre \mathbf{x} e \mathbf{y} , \mathbf{A} denota uma área em torno de $r_{\mathbf{xy}}(0, 0)$, $|\mathbf{A}|$ é o tamanho de \mathbf{A} , e \mathbf{x} e \mathbf{y} são definidos como $\mathbf{x} = \hat{\mathbf{K}}\mathbf{I}_t$ e $\mathbf{y} = \mathbf{W}_t$, onde \mathbf{W}_t é o ruído da imagem de teste \mathbf{I}_t após passar pelas mesmas operações de pós-processamento de $\hat{\mathbf{K}}$, descritas na Seção II-B. O valor de CCN obtido é comparado com um limiar de decisão τ . Então, se $c(\mathbf{x}, \mathbf{y}) > \tau$, a imagem é dita adquirida pela câmera suspeita.

III. ABORDAGEM PROPOSTA

Como descrito na Seção II-A, a maioria dos equipamentos de aquisição usa um CFA para decompor a luz em seus componentes cromáticos. Dessa forma, considerando o padrão RGB apresentado na Fig. 1, nota-se que apenas um componente cromático é efetivamente adquirido pelo fotossensor em cada posição (i, j) da imagem digital. Os demais componentes são resultantes das combinações de suas amostras vizinhas dentro de uma janela de observação. Esse processo é conhecido como interpolação. As técnicas mais simples de interpolação processam cada canal de forma independente, enquanto outras utilizam informações de mais de um canal. Independentemente do algoritmo utilizado, a interpolação insere um tipo específico de correlação entre as amostras da imagem [10], o que afeta a estimação da PRNU e prejudica o processo de identificação do dispositivo.

Para avaliar o impacto da interpolação na estimação da PRNU, considera-se inicialmente que $\mathbf{I}(i, j)$ representa o *pixel* na posição (i, j) de um canal de cor (vermelho, verde ou azul) de uma imagem digital interpolada e também que o algoritmo de interpolação seja linear e utilize apenas amostras do mesmo canal. Assim, pode-se dizer que $\mathbf{I}(i, j)$ pertence a um dos seguintes grupos: M_1 se a amostra foi capturada pelo fotossensor ou M_2 caso ela seja resultante de uma operação de interpolação. Desse modo, o modelo de imagem descrito em (1) pode ser reescrito como

$$\mathbf{I} = \begin{cases} g^\gamma [\mathbf{Y} + \mathbf{Y}\mathbf{K} + \boldsymbol{\Omega}]^\gamma + \mathbf{Q}, & \mathbf{I}(i, j) \in M_1 \\ g^\gamma \left[\sum_{l,m} \alpha_{l,m} (\mathbf{Y} + \mathbf{Y}\mathbf{K} + \boldsymbol{\Omega}) \right]^\gamma + \mathbf{Q}, & \mathbf{I}(i, j) \in M_2 \end{cases} \quad (5)$$

onde α modela os coeficientes do algoritmo de interpolação, $\alpha = \{\alpha_{l,m} | -N \leq l, m \leq N\}$ (N é um número inteiro). Para facilitar o entendimento, os índices (i, j) não são representados em (5), lembrando que todas as operações envolvendo matrizes são do tipo elemento-a-elemento. Analisando (5), é possível verificar que as amostras do grupo M_2 não apresentam informações novas sobre a PRNU, que é o sinal de interesse. Portanto, o melhor cenário para estimar \mathbf{K} seria aquele em que a configuração CFA da câmera sob suspeição é conhecida. Dessa forma, apenas as amostras capturadas pelo fotossensor (grupo M_1) deveriam ser utilizadas. No entanto, a maioria dos equipamentos de aquisição não informam a estrutura CFA implementada [8], o que impede o uso de tal informação para seleção dos *pixels* e estimação da PRNU.

A abordagem de estimação da PRNU descrita na Seção II-B utiliza a imagem completa, sem distinção entre os *pixels* do grupo M_1 e M_2 . Desse modo, baseado em (5), as amostras da PRNU $\hat{\mathbf{K}}$ obtidas por (2) podem ser classificadas como

$$\hat{\mathbf{K}} = \begin{cases} \mathbf{K} + \boldsymbol{\Xi}, & \hat{\mathbf{K}}(i, j) \in M_1 \\ \sum_{l,m} \beta_{l,m} \mathbf{K} + \boldsymbol{\Xi}, & \hat{\mathbf{K}}(i, j) \in M_2 \end{cases} \quad (6)$$

onde $\boldsymbol{\Xi}$ modela a combinação dos artefatos causados por operações de compressão com perdas, interpolação e erro de estimação [3], e β são os coeficientes que ponderam a combinação das amostras de M_1 , $\beta = \{\beta_{l,m} | -M \leq l, m \leq M\}$ (M é um número inteiro). Então, $\hat{\mathbf{K}}$ é submetido a operações de pós-processamento [3] que incluem o filtro de Wiener descrito em (3) para suprimir $\boldsymbol{\Xi}$. Esse filtro considera que as amostras da PRNU são independentes e identicamente distribuídas (i.i.d) [12], o que, de acordo com (6), não é o caso para $\hat{\mathbf{K}}$. Assim, o filtro de Wiener tende a atenuar também informações relevantes da PRNU.

Visando amenizar o impacto do processo de interpolação e compressão na estimação da PRNU e com isso obter melhores resultados no processo de identificação de dispositivo, a abordagem proposta neste trabalho baseia-se inicialmente na decomposição da imagem em subimagens de forma similar a [8]. Assim, cada canal de uma imagem de resolução $m \times n$ é separado em quatro subimagens de tamanho $m/2 \times n/2$, como mostrado na Fig. 2. Em seguida, contrastando com a abordagem de [8], a abordagem aqui proposta consiste em

aplicar os processos de extração de ruído e estimação da PRNU (veja Seção II-B) em cada uma das subimagens. Com isso, melhores resultados podem ser obtidos levando em conta que: *i*) a correlação entre as amostras da subimagem é menor, proporcionando um melhor desempenho do filtro de extração de ruído [11], [12]; e *ii*) apenas as amostras capturadas pelo fotossensor estarão presentes em algumas das subimagens, resultando em melhores estimativas da PRNU. Então, as quatro subestimativas da PRNU obtidas para cada canal são reagrupadas para formar a impressão digital da câmera. Vale ressaltar que, para imagens coloridas, as estimativas da PRNU de cada canal são combinadas em uma única estimativa através de uma conversão para escala de cinza. Esse mesmo procedimento de decomposição em subimagens é aplicado à imagem de teste. Na etapa de detecção (veja Seção II-C), utiliza-se os sinais de dimensão $m \times n$. Assim, o algoritmo completo aqui proposto para identificação de dispositivos a partir da PRNU pode ser resumido pela seguinte sequência de passos:

Estimação da impressão digital

- 1) Adquirir n imagens com a câmera suspeita;
- 2) Para cada canal I de resolução $m \times n$ da k -ésima imagem do conjunto de estimação:
 - a) Separar I em quatro subimagens de resolução $m/2 \times n/2$, como ilustrado na Fig. 2;
 - b) Para cada subimagem I_s :
 - i) Estimar o ruído W_s ;
 - ii) Acumular $W_s I_s$;
 - iii) Acumular I_s^2 .
- 3) Obter as estimativas \hat{K}_s (2) de resolução $m/2 \times n/2$;
- 4) Remover a média de cada linha e coluna de \hat{K}_s ;
- 5) Aplicar o filtro de Wiener no domínio da frequência (3) em \hat{K}_s ;
- 6) Compor a estimativa \hat{K} de resolução $m \times n$ a partir das estimativas \hat{K}_s .

Detecção da impressão digital

- 1) Para cada canal I_t de resolução $m \times n$ da imagem de teste:
 - a) Separar I_t em quatro subimagens de resolução $m/2 \times n/2$, como mostrado na Fig. 2;
 - b) Para cada subimagem I_{ts} :
 - i) Estimar o ruído W_{ts} ;
 - ii) Remover a média de cada linha e coluna de W_{ts} ;
 - iii) Aplicar o filtro de Wiener no domínio da frequência (3) em W_{ts} .
- 2) Compor W_t de resolução $m \times n$;
- 3) Calcular a CCN (4) entre $\hat{K} I_t$ e W_t ;
- 4) Comparar o valor de CCN com um limiar de decisão τ .

IV. EXPERIMENTOS E RESULTADOS

Esta seção apresenta resultados experimentais obtidos visando comparar o desempenho da abordagem proposta em relação às metodologias apresentadas em [4] e [8], as quais

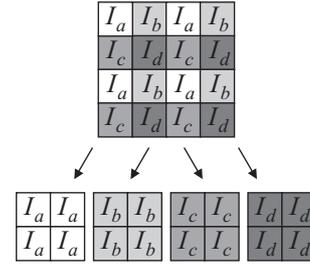


Fig. 2. Separação de uma imagem de resolução $m \times n$ em quatro subimagens de tamanho $m/2 \times n/2$.

TABELA I
CÂMERAS DE CELULARES UTILIZADAS NOS EXPERIMENTOS.

Quantidade	Modelo	Máxima resolução
1	APPLE iPhone 4	2592 × 1936
1	APPLE iPhone 4S	3264 × 2448
1	LG E400	2048 × 1536
1	NOKIA C2 06	1600 × 1200
1	SAMSUNG GT I9070	2560 × 1920
2	SAMSUNG GT I9300	3264 × 2448
1	SAMSUNG GT S5301B	1600 × 1200
1	SAMSUNG GT S5367	2048 × 1536
1	SAMSUNG GT S6102B	2048 × 1536
1	SONY C1604	2048 × 1536
1	SONY ST25a	2592 × 1944

são denominadas aqui como abordagem de Goljan [4] e abordagem de Li [8].

A. Procedimentos Experimentais

A Tabela I descreve as 12 câmeras de celulares utilizadas nos experimentos. Com cada uma dessas câmeras, são adquiridas 30 imagens de céu nublado para estimar a PRNU e 100 imagens de cenas aleatórias, em ambientes *indoor* e *outdoor*, para testes. Para cada um dos 11 modelos de celulares, são baixadas da *web*¹ 100 imagens do mesmo modelo e de mesma resolução. No total, 2300 imagens de teste estão disponíveis. Assim, nos experimentos com uma dada câmera, são utilizadas 100 imagens adquiridas por ela (classe positiva) e 2200 não adquiridas (classe negativa). Na estimação da impressão digital do dispositivo, são utilizados blocos de dimensão 1024×1024 *pixels* retirados da parte central da imagem. Das imagens de testes, são extraídos blocos de dimensão 1024×1024 , 512×512 , 256×256 e 128×128 *pixels*, também da parte central. O filtro de extração de ruído [11], [12] é configurado com variância de ruído $\sigma^2 = 4$ [11].

Após o cálculo da CCN (4), são analisadas as curvas ROCs (*receiver operating characteristic*) das técnicas de identificação avaliadas. A curva ROC apresenta a taxa de verdadeiro positivo (TVP) versus a taxa de falso positivo (TFP) em função da variação do limiar de decisão τ . Caso a imagem seja adquirida pela câmera suspeita e o valor de $c(\mathbf{x}, \mathbf{y}) > \tau$, diz-se que ocorre um verdadeiro positivo. Caso a imagem não seja tirada pela câmera suspeita e tem $c(\mathbf{x}, \mathbf{y}) > \tau$, diz-se que tem-se um falso positivo. Por fim, divide-se a quantidade de verdadeiros positivos e falsos positivos pelo número de imagens de cada classe, 1200 e 26400, respectivamente, para obter a TVP e TFP.

¹As imagens baixadas da *web* são encontradas na página do Flickr (<https://www.flickr.com>).

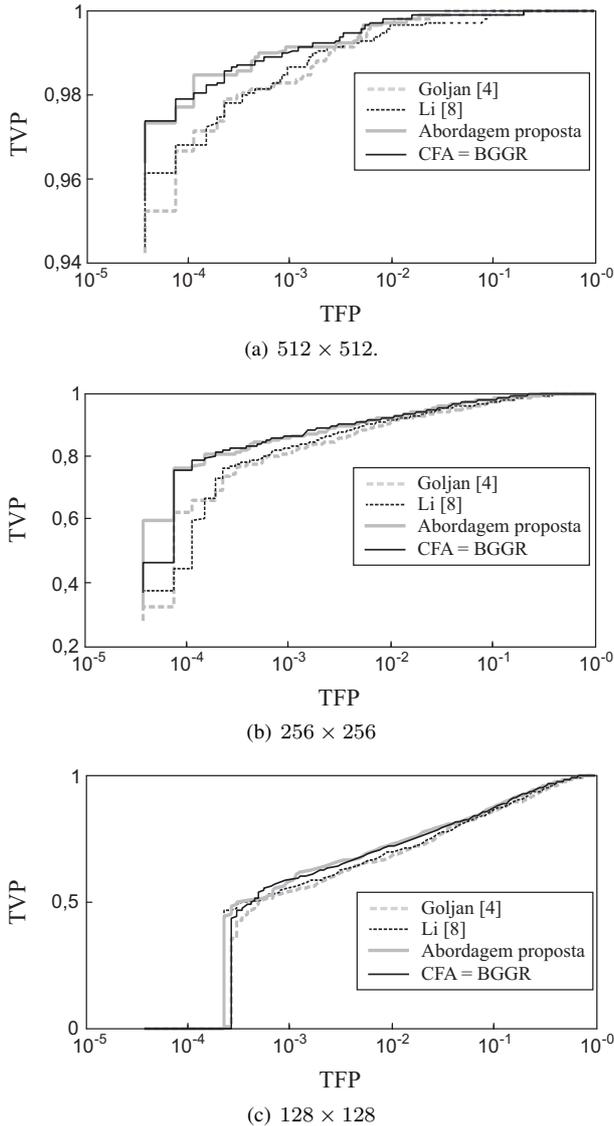


Fig. 3. Curvas ROCs de diversos métodos de identificação de dispositivo de aquisição baseado em PRNU com imagens de teste de diferentes tamanhos (512×512 , 256×256 e 128×128 pixels).

B. Resultados Experimentais

Para mostrar que o processo de interpolação influencia no desempenho do filtro de extração de ruído, considera-se que todas as câmeras implementam o mesmo CFA. Portanto, é utilizado apenas um terço das amostras de cada imagem. São testados os seguintes filtros de Bayer: RGGB (ilustrado na Fig. 1), BGGR, GBRG e GRBG. Como essas configurações resultam em curvas ROC's aproximadamente iguais, são mostrados os resultados apenas da primeira configuração, denominada "CFA = RGGB". A Fig. 3 apresenta os resultados obtidos com as imagens de teste de resolução 512×512 , 256×256 e 128×128 pixels. Para imagens de teste de 1024×1024 pixels, todas as técnicas separam as classes de imagens, classe positiva e classe negativa, ou seja, para $TFP = 0$, $TVP = 1$. Note que a utilização de apenas um terço das amostras, curva ROC "CFA = RGGB", apresenta resultados semelhantes à abordagem proposta. A vantagem

de se usar apenas um terço das amostras é que o tempo total do processo de identificação de dispositivo é reduzido. Para imagens de resolução 128×128 , Fig. 3(c), todas as técnicas apresentam baixas TVPs para $TFP < 10^{-3}$. Essas TVPs podem ser inviáveis em aplicações forenses.

V. CONCLUSÕES

Este trabalho apresentou uma técnica de identificação de dispositivo de aquisição de imagens baseada em PRNU. Tal abordagem consiste em separar a imagem em subimagens e utilizar as subimagens no processo de estimação da PRNU. Dessa forma, os efeitos do ruído de interpolação na estimativa da impressão digital do dispositivo são atenuados. Os testes realizados com imagens de baixa resolução adquiridas por câmeras de celulares do mesmo modelo mostraram que esta técnica apresenta um melhor desempenho em termos de taxa de verdadeiro positivo e taxa de falso positivo, comparada com aquelas apresentadas em [4], [8]. Trabalhos futuros investigarão como identificar a configuração CFA da câmera suspeita para obter melhores estimativas da PRNU e reduzir o tempo computacional do processo de identificação de dispositivo.

REFERÊNCIAS

- [1] J. A. Redi, W. Taktak, and J.-L. Dugelay, "Digital image forensics: a booklet for beginners," *Multimedia Tools Appl.*, vol. 51, no. 1, pp. 133–162, Jan. 2011.
- [2] J. Lukáš, J. Fridrich, and M. Goljan, "Digital camera identification from sensor pattern noise," *IEEE Trans. Inf. Forensics Security*, vol. 1, no. 2, pp. 205–214, Jun. 2006.
- [3] M. Chen, J. Fridrich, and M. Goljan, "Digital imaging sensor identification (further study)," in *Proc. SPIE Security, Steganography, and Watermarking of Multimedia Contents*, vol. 6505, San Jose, California, Feb. 2007, pp. 0P–0Q.
- [4] M. Goljan, J. Fridrich, and T. Filler, "Large scale test of sensor fingerprint camera identification," in *Proc. SPIE, Electronic Imaging, Media Forensics and Security*, vol. 7254, San Jose, California, Feb. 2009, pp. 17–21.
- [5] X. Kang, Y. Li, Z. Qu, and J. Huang, "Enhancing source camera identification performance with a camera reference phase sensor pattern noise," *IEEE Trans. Inf. Forensics Security*, vol. 7, no. 2, pp. 393–402, Apr. 2012.
- [6] Z. Qu, X. Kang, J. Huang, and Y. Li, "Forensic sensor pattern noise extraction from large image data set," in *Proc. IEEE Int. Conf. Acoust. Speech, Signal Process. (ICASSP)*, Vancouver, Canada, May 2013, pp. 3023–3027.
- [7] X. Kang, J. Chen, K. Lin, and P. Anjie, "A context-adaptive SPN predictor for trustworthy source camera identification," *EURASIP J. Image and Video Processing*, vol. 2014, no. 1, p. 19, Apr. 2014.
- [8] C.-T. Li and Y. Li, "Color-decoupled photo response non-uniformity for digital image forensics," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 22, no. 2, pp. 260–271, Feb. 2012.
- [9] R. C. Gonzalez and R. E. Woods, "Digital image fundamentals," in *Digital Image Processing*, 3rd ed. Upper Saddle River, NJ: Prentice-Hall, Inc., 2007, pp. 57–125.
- [10] A. C. Popescu and H. Farid, "Exposing digital forgeries in color filter array interpolated images," *IEEE Trans. Signal Process.*, vol. 53, no. 10, pp. 3948–3959, Oct. 2005.
- [11] J. Fridrich, "Digital image forensics," *IEEE Signal Process. Mag.*, vol. 26, no. 2, pp. 16–37, Mar. 2009.
- [12] M. K. Mihcak, I. Kozintsev, and K. Ramchandran, "Spatially adaptive statistical modeling of wavelet image coefficients and its application to denoising," in *Proc. IEEE Int. Conf. Acoust., Speech, and Signal Process. (ICASSP)*, vol. 6, Phoenix, AZ, Mar. 1999, pp. 3253–3256.
- [13] J. Fridrich, "Sensor defects in digital image forensic," in *Digital Image Forensics: There is More to a Picture Than Meets the Eye*, H. T. Sencar and N. Memon, Eds., New York: Springer, 2013, pp. 179–218.