

基于高斯增强模块的相机模型辨别

黄远航, 边山, 王春桃

引用本文

黄远航, 边山, 王春桃. 基于高斯增强模块的相机模型辨别[J]. 计算机科学, 2024, 51(6A): 230700125-5.

HUANG Yuanhang, BIAN Shan, WANG Chuntao. [Gaussian Enhancement Module for Reinforcing High-frequency Details in Camera Model Identification](#) [J]. Computer Science, 2024, 51(6A): 230700125-5.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向产线AI质检的少样本评测方法研究和验证](#)

Study and Verification on Few-shot Evaluation Methods for AI-based Quality Inspection in Production Lines

计算机科学, 2024, 51(6A): 230700086-8. <https://doi.org/10.11896/jsjcx.230700086>

[基于BERT和CNN的药物不良反应个案报道文献分类方法](#)

Literature Classification of Individual Reports of Adverse Drug Reactions Based on BERT and CNN

计算机科学, 2024, 51(6A): 230400049-6. <https://doi.org/10.11896/jsjcx.230400049>

[DUWe:动态未知词嵌入方法在Web异常检测中的应用](#)

DUWe:Dynamic Unknown Word Embedding Approach for Web Anomaly Detection

计算机科学, 2024, 51(6A): 230300191-5. <https://doi.org/10.11896/jsjcx.230300191>

[WiCare:一种非接触式的老人如厕跌倒监测模型](#)

WiCare:Non-contact Fall Monitoring Model for Elderly in Toilet

计算机科学, 2024, 51(6A): 230700044-8. <https://doi.org/10.11896/jsjcx.230700044>

[深度学习驱动下IaaS云运维异常检测算法的研究进展](#)

Research Progress of Anomaly Detection in IaaS Cloud Operation Driven by Deep Learning

计算机科学, 2024, 51(6A): 230400016-8. <https://doi.org/10.11896/jsjcx.230400016>

基于高斯增强模块的相机模型辨别

黄远航^{1,2} 边山^{1,2,3} 王春桃^{1,2}

1 华南农业大学数学与信息学院 广州 510642

2 农业农村部华南热带智慧农业技术重点实验室 广州 510642

3 广东省智能信息处理重点实验室 深圳市媒体信息安全重点实验室 广东 深圳 518060

(806834034@qq.com)

摘要 在多媒体取证中,高通滤波器是卷积神经网络常用的预处理层之一,用于抑制图像内容的影响,只强调高频特征。但与此同时,其他一些包含取证痕迹的有用信息也将被不加区别地剔除。为了解决这一问题,文中提出了一个简单而高效的高斯增强模块(Gaussian Enhancement Module, GEM)来提取“扩展的”高频特征,即在维持原有特征强度的基础上增强高频细节信息。GEM由两个连续的一维低通高斯滤波器组成,以获得一个模糊版本的特征图,并进一步得到相应的扩展高频残差。通过以高频残差作为空间掩膜,它可以自适应地强化脆弱和细微的低级取证特征,并防止在特征传递过程中出现衰减现象。在相机模型辨别数据集上进行实验,通过将模块插入多个主流骨干网络,GEM仅仅带来非常轻微模型复杂度的增加,网络性能和鲁棒性却显著提高,表明该模块支持“即插即用”,与特定的网络架构无关。

关键词: 相机模型辨别;深度学习;图像取证;高通滤波器;高斯增强

中图分类号 TP391.41

Gaussian Enhancement Module for Reinforcing High-frequency Details in Camera Model Identification

HUANG Yuanhang^{1,2}, BIAN Shan^{1,2,3} and WANG Chuntao^{1,2}

1 College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China

2 Key Laboratory of Smart Agricultural Technology in Tropical South China, Ministry of Agriculture and Rural Affairs, Guangzhou 510642, China

3 Guangdong Provincial Key Laboratory of Intelligent Information Processing & Shenzhen Key Laboratory of Media Security, Shenzhen, Guangdong 518060, China

Abstract In multimedia forensics, a high-pass filter is one of the commonly used pre-processing layers by convolutional neural network to depress the impact of image content and only highlight high-frequency features. However, some other useful information containing forgery traces would also be removed indiscriminately in the meantime. To address this issue, in this paper, a simple yet effective Gaussian enhancement module is proposed to extract “extended” high-frequency features, namely, reinforce high-frequency details while maintaining the original feature strength. The GEM comprises two successive low-pass Gaussian filters to acquire a blurry version of the feature map and further get the corresponding extended high-frequency residual. It can strengthen fragile and subtle low-level forgery features adaptively and prevent feature attenuation as well. Experiments are conducted on the camera-model identification dataset by plugging the module into several mainstream backbone networks, indicating that it supports “plug and play” and is non-related to the specific network architecture. The proposed GEM brings a significant improvement both in the performance and the robustness of networks with the slightly increased complexity of models.

Keywords Camera model identification, Deep learning, Image forensics, High-pass filter, Gauss enhancement

1 引言

随着图像编辑技术的进步,图像的修改变得越来越容易。这些修改可以会弱化数字媒介与捕获设备之间的联系,从而引发一系列版权纠纷、所有权侵犯问题。因此,发展安全可靠

的数字图像溯源取证工具来检测数字媒介的来源,保护其真实性和原始性免受潜在的攻击变得尤为重要。

图像源信息可以从相应的元文件中获取,比如 EXIF 标签,它包含了源相机的具体参数设置。但是这些附属信息是非常脆弱的,它能够很轻易地被恶意攻击者所修改,或者被不

基金项目:广东省智能信息处理重点实验室(2023B1212060076);国家自然科学基金(62172165);广东省自然科学基金(2022A1515010325);广州市基础和应用基础研究项目(202201010742)

This work was supported by the Guangdong Provincial Key Laboratory of Intelligent Information Processing(2023B1212060076), National Natural Science Foundation of China(62172165), Natural Science Foundation of Guangdong Province, China(2022A1515010325) and Guangzhou Basic and Applied Basic Research Project(202201010742).

通信作者:边山(bianshan@scau.edu.cn)

恰当的重保存、重压缩方式所破坏。实际上,每幅图像都有其独特的统计特征。在图像采集周期中,捕获设备中的硬件和软件会在其生成介质上留下一定的痕迹,这被称为图像指纹。由于采集设备留下这些独特的伪影痕迹,盲分析取证在检测恶意修改方面变得切实可行,也能识别哪个相机拍摄了特定的图像。

在过去,一系列基于特定手工特征的传统方法被提出。传统方法主要聚焦于提取相机处理技术中引入的痕迹,包括传感器模式噪声^[1]、光学镜头失真^[2]、去马赛克策略^[3]、JPEG压缩痕迹^[4]等。然而这类传统方法严重受限于预定义的手工特征,因此实用性不强、适用度不高,难以在现实场景中处理复杂多变的情况。

近年来,基于卷积神经网络(Convolutional Neural Network, CNN)的方法取得了比传统方法更令人满意的表现。比如, Tuama等^[5]、Yao等^[6]和 Bayar等^[7]采用堆叠的卷积层作为浅层 CNN 以施行源相机模型辨别任务。具体而言, Tuama等^[5]采用 Qian等^[8]所提出的固定权重高通滤波器作为预处理层对 CNN 进行训练,在 Dresden 数据集^[9]和 12, 14, 33 个相机模型的私人数据集上分别达到 98.00%, 97.09%和 91.9%的准确率。Yao等^[6]提出了一个配备投票策略的鲁棒多分类网络,达到了接近 100%的平均准确率。Bayar等^[7]通过平行地使用受限卷积层^[10-11]和非线性残差特征提取器,显著地提升了网络的鲁棒性。但是,这些浅层神经网络面临着梯度消失或者爆炸的风险,并且缺乏足够的拟合数据分布。现代神经网络利用其深而窄的架构实现了更强大的特征学习和映射能力。基于此,Chen等^[12]首次将 ResNet^[13]用于品牌归属、模型归属、设备归属等多个相机模型辨别任务上。为了获得更优的表现,Ding等^[14]建立了一种基于 ResNet 的多尺度特征提取器和层次多任务监督分类器。Kuzin等^[15]和 Rafi等^[16]在不同设备属性并且未见过的测试集上验证了 DenseNet^[17]及其变体的泛化能力。Ferreira等^[18]特别设计了一个双分支平行的 Inception 架构融合网络,并在高分辨图像和低分辨图像块上展示了其有效性。但值得注意的是,相较于低等级取证特征(如相邻像素之间的局部依赖关系),深度神经网络(Deep Neural Networks, DNN)更偏向于学习表达高级的图像内容(被视作干扰特征),并且在训练过程中总是存在特征衰减现象(尤其是高频成分)^[16]。因此,一系列的高通滤波器被发明用以抑制图像内容影响并强化细微的低等级取证特征,如用于重捕获取证检测的 Laplacian 滤波器^[19]和暴露噪声残差的 SRM 滤波器^[20-21]等。然而,这些高通滤波器可能并不是图像取证的最佳选择,因为其他一些包含潜在取证痕迹的有用信息也会被不加区别地剔除,而仅仅保留高频特征。

为了解决这一问题,本文提出了一个简单而高效的高斯增强模块(GEM)用于多媒体取证分析,并将其应用于相机模型辨别领域以验证其有效性。通过连续两个低通高斯滤波器获得一个模糊版本的特征图,并进一步得到相应的高频残差,GEM 可以自适应地增强脆弱和细微的低层次取证特征,防止深度特征的衰减。本文的主要贡献有以下 3 点:

1) 提出了一个新颖的用于多媒体取证的高斯增强模块。GEM 以网络学习偏好的方式自适应地强化辨别性特征,而不是不加区别地剔除干扰特征和剩余的有用特征。在相机模型辨别数据集上进行的实验表明,与其他高通滤波器相比,

GEM 具有显著的优越性。

2) 所提出的 GEM 是一个轻量化模块,支持“即插即用”,与特定的网络架构无关。因此,它可以插入不同的骨干网络中,如 DenseNet^[17]、ResNet^[13]、VGG^[22]和 InceptionNet^[23]等,以提升性能。

3) 配备了 GEM 的骨干网络在较大程度上提高了应对各种社交平台传输攻击的鲁棒性,并且只需非常少的额外参数量和运算量,使其在实际应用中更加可靠。

2 本文方法

主流的计算机视觉任务与多媒体取证之间存在着较大的差异,前者注重学习表达图像内容,忽略了来自噪声的干扰,后者则强调低级的细微痕迹,降低视觉内容的影响。因此,大多数研究工作倾向于在 CNN 之前添加一个预处理层,以克服 DNN 的固有属性。其中,用于隐写分析的高通滤波器作为一种有效的方法得到了广泛应用,但由于权重固定,只有预选择的特征才能通过。Bayar 进一步扩展了这一思想,提出了一个通用的预处理层,即 Bayar 层^[10-11,24],它能够自动学习特征并执行多种操纵检测任务^[25-28]。具体而言,Bayar 层提取高频残差特征通过满足一定的约束条件,并在每次迭代后重置滤波器的系数,可表示如下:

$$\begin{cases} W_B^i(0,0) = -1 \\ \sum_{m,n \neq 0} W_B^i(m,n) = 1 \end{cases}, \text{for } i = 1, 2, 3. \quad (1)$$

其中, W_B^i 表示该层中 W_B 的第 i ($i = 1, 2, 3$) 个通道。然而,这种强制更新模式倾向于在数据分布中引入干扰^[29],使得网络仍然难以以偏好的方式获取信息。为此,本文从一个全新的角度来解决这个问题——不再精心设计预处理层,而是从特征传递过程考虑。具体来说,因为特征传递过程中衰减现象的存在,本文的目标便是在传递过程中增强特征图和强化高频细节。

模块的设计必须满足两个准则:一是应该维持原有特征强度或至少不被削弱;二是局部特征增强的程度应由网络本身来决定。所提出的算法思路简单而有效,可以表述如下:

$$y = (\text{sigmoid}(x - \text{Gaussian}(x)) * \alpha + 1) * x \quad (2)$$

其中, α 是一个可学习的参数, x 是输入的特征图, y 是输出的增强特征图, $\text{Gaussian}(\cdot)$ 表示模糊当前特征图的高斯函数。我们将 sigmoid 激活函数放在获得的高频特征的末端,作为一个软注意掩模机制。由于 sigmoid 函数产生的值在 0 到 1 之间,这种空间激活使一些信息在接近 1 时保持,而接近 0 的信息则会被抑制。并且我们进一步添加了一个短径参数形成残差跳跃连接,以维持原始的特征强度。因此,该模块的构造如图 1 所示。




图 1 高斯增强模块

Fig. 1 Gaussian enhancement module

在实际应用中,二维高斯矩阵的计算可以用两个独立的一维矩阵来代替,以达到相同的效果,称为空间可分离滤波。本文使用两个高斯滤波器来分别关注宽度相关和高度相关的信息,即序列化使用两个高斯核。它们的核大小分别是 $1 \times n$ 和 $n \times 1$,这个属性将时间复杂性从 $O(M \times N \times n \times n)$ 降低至 $O(M \times N \times n) + O(M \times N \times n)$ 。其中, M 是特征图的宽度, N 是特征图的高度。一维高斯函数可以表示为:

$$G(u) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{u^2}{2\sigma^2}} \quad (3)$$

其中, u 为单轴上到原点的距离, σ 为高斯分布的标准差。需要注意的是,是网络本身决定了模糊强度,所以高斯核以预定义的方式初始化,然后在每次迭代后对参数进行归一化操作。在本文的方法中,选择如图 3(c) 所示的并行结构来执行序列化高斯滤波,以获得特征图的模糊版本(参考 3.3 节)。

所提出的 GEM 是深度卷积,即在每个输入通道上独立执行空间卷积。通过这种方式,每个特征图的高频分量都能得到有效增强,这些细微的取证痕迹也可以再次被放大。为了防止深度特征衰减并获得最佳性能,本文建议将 $GEM(\cdot)$ 放置在骨干网络的每个阶段(即 $Exact(\cdot)$)之前,其中阶段指一组在具有相同空间分辨率特征图上操作的块(见图 2)。这可以用公式概念化表达为式(4):

$$\begin{cases} y_s = GEM_s(x_s) \\ y_s' = Exact_s(y_s) \end{cases}, \text{ for } s=1, \dots, n \quad (4)$$

其中,下标 s 表示网络内的第 s 个阶段, n 为阶段数。




图 2 配备了 GEM 的网络概览图

Fig. 2 Schematic overview of network equipped with GEM

此外,算法 1 中给出了训练过程的完整伪代码。

算法 1 GEM 的训练算法

1. 以高斯标准差 σ 初始化并正则化高斯模糊滤波器;初始化 $\alpha: = 1$;
 $i: = 1$
2. For $i \leq \max_step$ do
3. 执行前项传播;
4. 根据误差损失进行反向传播;
5. 通过梯度下降更新参数;
6. 正则化高斯模糊滤波器参数;
7. $i: = i + 1$;
8. if 验证损失无法下降 then
9. 跳出循环;
10. End if
11. end for

3 评价实验以及分析

3.1 数据集描述与数据增强方式

实验在由 35 个移动设备组成的 VISION 数据集^[30]上进行,每个设备类别包含 160 张自然图像,共计 $35 \times 160 = 5600$ 张图像。该数据集还提供了通过 FaceBook 和 WhatsApp 社交平台交换版本的图像,以衡量取证工具的鲁棒性。本文将


数据集分为训练集(70%)、验证集(5%)和测试集(25%),这些数据集之间彼此不重叠。采用随机裁剪、随机水平、垂直翻转等在线数据增强方式,以确保数据的多样性。在网络推理阶段,为了适应网络的输入大小,我们从每幅图像的 4 个角和中心裁剪 5 个补丁,并选择平均预测值作为最终结果。

3.2 实验设置

该方法由 PyTorch 深度学习框架^[1]实现,在 Ubuntu 20.04 系统上进行训练,该系统使用英伟达 GeForce RTX 3080 显卡,具有 10 GB 显存。批处理大小和初始学习率分别设置为 16 和 2×10^{-4} 。为了简单起见,本文使用交叉熵作为损失函数,Adam 及其默认参数作为优化器。当验证损失在 5 个周期内没有减少,学习率就会减半;当验证损失在 15 个周期内没有减少时,训练阶段就停止。为了在效率和性能之间取得平衡,本文将 GEM 的高斯模糊滤波器中的 n 固定设置为 5。在实践中,超过 $3 \times \sigma$ 距离的像素影响非常小,可以认为接近为零。为了得到一个足够接近于整个高斯分布所给出的结果,本文将 σ 设为 5/6。

3.3 消融实验

由于有几种方法可以获得特征映射簇的模糊版本,因此在本节中探究了 GEM 的不同内部结构。图 3 给出了一些参考的变体和具体的配置。具体来说,变体 A 和变体 B 在处理序列一维高斯函数后,分别缩小特征通道,得到一个单一的模糊特征图,其中主要的区别是变体 A 在较早阶段收缩,而变体 B 在较晚阶段收缩。本文所采用的变体 C 可以并行处理所有的特征映射,而不改变通道数量,每个特征图都有其相应的模糊版本。



注:粉色的圆圈表示对应的特征映射,而绿色的线是序列化的高斯滤波器。

图 3 GEM 中高斯模糊的参考变体

Fig. 3 Referred variants in Gaussian blur of GEM

本节使用配备了这 3 种不同变体的 ResNet-50 来评估其性能,如表 1 所列。结果表明,变体 C 得到的效益最大,准确率约为 97.21%。这主要是因为每个特征图所关注的特征信息不同,而收缩版本(变体 A 或变体 B)没有充足的非线性表达能力,很难具备代表性。

表 1 不同变体的 top-1 和 top-5 准确率

	ACC1	ACC5
变体 A	96.64	100
变体 B	96.93	100
变体 C(本文算法)	97.21	100


3.4 对比实验

本节使用多媒体取证领域中常用的骨干网络对 GEM 的通用性进行评估,包括 ResNet-50, DenseNet-121, VGG16-bn 和 Inception-v3。图 4 给出了是否配备 GEM 的 ResNet-50 生

¹⁾ 实验采用 FP16 的数据精度

成的热力图。可以观察到,配备了 GEM 以后,更高的响应扩散到整个图像中,这意味着细微的痕迹被有效地放大了。为了进行比较,实验还对取证领域引用量较高的 Bayar 层作为通用预处理层配备在骨干网络前的性能进行了评估。表 2 列出了包括浮点运算量(FLOPs)、参数量和准确率(Top-1 和 Top-5)在内的几个指标的实验结果,以便进行综合分析。可以看到,尽管原始骨干网络已经达到了非常高的准确率,所有配备了 GEM 的网络的性能平均提高了约 1%。其中,vgg16-bn 具有较为规则的结构特性,没有任何跳跃连接,具有较高的语义敏感性,因而难以传输低级的高频取证特征。在配备了 GEM 以后,VGG16-bn 转向捕获与语义无关的特征,并获得最大的增益。然而,Inception-v3 的增长相对较小,约为 0.43%,主要原因是网络前端的两个最大值池化层很容易扰

乱脆弱的取证特征,从而干扰 GEM 在接下来的阶段发挥作用。此外,还可以观察到 GEM 以非常小的计算成本提升了性能。例如,DenseNet-121 + GEM 仅具有额外的 0.35% GFLOPs 和 0.16% 参数量,却在 Top-1 准确率上比原始网络高出 0.57% 以上。



注:较亮的颜色表示更高的响应。放大可以观察到更多细节信息。

图 4 由 Grad-CAM^[31]生成的热力图

Fig. 4 Heatmaps generated by Grad-CAM^[31]

表 2 比较结果(ACC Top-1/Top-5)

Table 2 Comparison results(ACC Top-1/Top-5)

方法	参数量	浮点运算量 (十亿)	Nat_flat/%	Nat/%	FBH/%	FBL/%	WA/%
ResNet-50	23579747	4.12	96.36/100	94.22/100	15.26/43.93	5.55/20.81	14.10/37.69
ResNet-50+Bayar	23579972	4.12	96.21/100	94.10/100	9.36/34.68	3.93/21.73	12.02/30.52
ResNet-50+GEM	23602019	4.14	97.21/100	95.61/100	21.04/47.98	6.82/25.32	16.53/41.16
DenseNet-121	6989731	2.88	96.86/100	95.03/100	11.91/42.54	5.32/22.20	11.56/37.23
DenseNet-121+Bayar	6989956	2.88	96.57/100	95.14/100	10.64/36.42	3.01/20.81	7.51/30.75
DenseNet-121+GEM	7001251	2.89	97.43/100	96.07/100	12.49/41.97	4.28/22.54	11.68/37.23
VGG16-bn	134412387	15.53	95.86/100	93.64/100	9.25/32.72	3.47/18.96	5.90/29.13
VGG16-bn+Bayar	134412612	15.53	95.86/99.93	93.53/99.88	8.09/23.82	3.24/18.61	7.75/28.32
VGG16-bn+GEM	134423907	15.54	96.93/100	95.26/100	8.09/29.13	3.12/15.84	7.05/26.94
Inception-v3	21857283	2.85	96.71/100	94.91/100	20.00/43.93	5.32/26.36	12.72/35.03
Inception-v3+Bayar	21857508	2.85	93.21/100	90.75/100	13.18/34.34	3.58/18.38	9.02/30.98
Inception-v3+GEM	21884547	2.85	97.14/100	95.49/100	19.65/41.27	5.90/21.73	13.18/36.88

注:“Nat_flat”表示同时有纹理丰富图像和平滑图像,“Nat”代表仅有纹理丰富的图像,“FBH/FBL”表示通过 Facebook 平台高/低质量下载交换的图像,“WA”表示通过 WhatsApp 平台交换的图像。加粗值代表最优结果。

此外,可以观察到与 Bayar 层相结合的骨干网络性能明显下降。主要原因有两个:首先,这种类型的高通滤波器删除了大部分有用的信息,只保留了高频残差;其次,具有强制更新模式的 Bayar 层会对数据分布产生扰动。

请注意,以上所探讨的指标增益是在平滑图像占比 37.5% 的情况下,即表中的“Nat_flat”一列。如果丢弃平滑像,只保留纹理丰富的图像,即表 2 的“Nat”,ResNet-50, DenseNet-121, VGG16-bn 和 Inception-v3 的差距分别被进一步放大到 1.39%, 1.04%, 1.62% 和 0.58% 以上。原因是这些“Nat”图像中的纹理内容有更多的干扰,使得识别更加困难,但同时也带来了更多的统计信息。然而,鉴于 GEM 的良好性能,本文有理由相信它在复杂和多样化的场景中更具潜力、能表现得更好。

3.5 鲁棒性分析

图像在传输过程中可能会受到各种后处理攻击,因此衡量 GEM 对常用社交平台处理的鲁棒性是非常重要的。本节使用社交平台(Facebook 和 WhatsApp)交换版本中纹理丰富的图像,来评估其鲁棒性,如表 2 右边三列所列。可以观察到大多数指标都会急剧下降,因为这些细微而脆弱的低级特征已经被社交媒体严重破坏。但是,配备 GEM 的骨干网络仍然具有一定程度的鲁棒性。特别是 ResNet-50 + GEM 保持了相对较好的整体性能,即 ACC1 比原始骨干的 FBH, FBL 和 WA 分别提高了 5.78%, 1.27% 和 2.43%。实际上,大多数骨干网络(包括 DenseNet-121, VGG16-bn 和 Inception-v3)

都采用最大值池化层来降低特征图分辨率,这会进一步破坏残余的有用信息,而 ResNet-50 利用 $stride=2$ 的卷积有助于提升 ResNet-50 + GEM 对来自社交平台攻击的鲁棒性。

结束语 本文提出了一个新颖的高斯增强模块来强调高频特征,并保留一些低等级的取证特征,以防止在信息传输过程出现特征衰减。该模块采用两个连续的低通高通滤波器对每个特征图进行模糊处理,并进一步得到相应的高频残差,以自适应地增强低等级细微痕迹。本文在多媒体取证领域常用的骨干网络上验证了其有效性,表明使用所提出的模块可以在很大程度上提升骨干网络的性能和鲁棒性。

该模块能够在更多样化的场景中表现得更优异,而不仅仅局限于相机模型的辨别任务。因此,在未来的工作中,我们将把 GEM 推广到其他图像取证领域,并进一步探索一个更合适的解决方案用于在传输过程中抑制语义相关信息。

参考文献

- [1] FILLER T, FRIDRICH J, GOLJAN M. Using sensor pattern noise for camera model identification[C]// 2008 15th IEEE International Conference on Image Processing. IEEE, 2008; 1296-1299.
- [2] SAN CHOI K, LAM E Y, WONG K K Y. Automatic source camera identification using the intrinsic lens radial distortion [J]. Optics Express, 2006, 14(24): 11551-11565.
- [3] MILANI S, BESTAGINI P, TAGLIASACCHIM, et al. Demosaicing strategy identification via eigenalgorithms [C] // 2014 IEEE International Conference on Acoustics, Speech and Signal

- Processing(ICASSP). IEEE,2014;2659-2663.
- [4] ALLES E J,GERADTS Z J M H,VEENMANC J. Source camera identification for low resolution heavily compressed images [C]//2008 International Conference on Computational Sciences and Its Applications. IEEE,2008;557-567.
- [5] TUAMA A,COMBY F,CHAUMONTM. Camera model identification with the use of deep convolutional neural networks [C]//2016 IEEE International Workshop on Information Forensics and Security(WIFS). IEEE,2016;1-6.
- [6] YAO H,QIAO T,XU M,et al. Robust multi-classifier for camera model identification based on convolution neural network [J]. IEEE Access,2018,6:24973-24982.
- [7] BAYAR B,STAMM M C. Augmented convolutional feature maps for robust cnn-based camera model identification [C] // 2017 IEEE International Conference on Image Processing (ICIP). IEEE,2017;4098-4102.
- [8] QIAN Y,DONG J,WANG W,et al. Deep learning for steganalysis via convolutional neural networks[C]//Media Watermarking,Security,and Forensics 2015. SPIE,2015,9409:171-180.
- [9] GLOE T,BÖHME R. The 'Dresden Image Database' for benchmarking digital image forensics [C] // Proceedings of the 2010 ACM Symposium on Applied Computing. 2010; 1584-1590.
- [10] BAYAR B,STAMM M C. Constrained convolutional neural networks:A new approach towards general purpose image manipulation detection[J]. IEEE Transactions on Information Forensics and Security,2018,13(11):2691-2706.
- [11] BAYAR B,STAMM M C. A deep learning approach to universal image manipulation detection using a new convolutional layer [C]//Proceedings of the 4th ACM Workshop on Information Hiding and Multimedia Security. 2016;5-10.
- [12] CHEN Y,HUANG Y,DING X. Camera model identification with residual neural network [C] // 2017 IEEE International Conference on Image Processing(ICIP). IEEE,2017;4337-4341.
- [13] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016;770-778.
- [14] DING X,CHEN Y,TANG Z,et al. Camera identification based on domain knowledge-driven deep multi-task learning[J]. IEEE Access,2019,7:25878-25890.
- [15] KUZIN A,FATTAKHOV A,KIBARDIN I,et al. Camera model identification using convolutional neural networks[C]//2018 IEEE International Conference on Big Data (Big Data). IEEE, 2018;3107-3110.
- [16] RAFI A M,KAMAL U,HOQUE R,et al. Application of DenseNet in Camera Model Identification and Post-processing Detection[C]//CVPR Workshops. 2019;19-28.
- [17] HUANG G,LIU Z,VAN DER MAATEN L,et al. Densely connected convolutional networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017; 4700-4708.
- [18] FERREIRA A,CHEN H,LI B,et al. An inception-based data-driven ensemble approach to camera model identification [C] // 2018 IEEE International Workshop on Information Forensics and Security(WIFS). IEEE,2018;1-7.
- [19] YANG P,NI R,ZHAO Y. Recapture image forensics based on Laplacian convolutional neural networks [C] // Digital Forensics and Watermarking: 15th International Workshop(IWDW 2016). Revised Selected Papers 15. Springer International Publishing,2017;119-128.
- [20] LUO Y,ZHANG Y,YAN J,et al. Generalizing face forgery detection with high-frequency features [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021;16317-16326.
- [21] ZHOU P,HAN X,MORARIU V V I,et al. Learning rich features for image manipulation detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018;1053-1061.
- [22] KAREN S,ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition [J]. arXiv:1409.1556, 2014.
- [23] SZEGEDY C,VANHOUCKE V,IOFFE S,et al. Rethinking the inception architecture for computer vision [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016;2818-2826.
- [24] BAYAR B,STAMM M C. Design principles of convolutional neural networks for multimedia forensics [J]. Electronic Imaging,2017,29:77-86.
- [25] CHEN X,DONG C,JI J,et al. Image manipulation detection by multi-view multi-scale supervision [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021; 14185-14193.
- [26] DONG C,CHEN X,HU R,et al. Mvss-net:Multi-view multi-scale supervised networks for image manipulation detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2022,45(3):3539-3553.
- [27] HU X,ZHANG Z,JIANG Z,et al. SPAN: Spatial pyramid attention network for image manipulation localization [C] // Computer Vision — ECCV 2020: 16th European Conference, Glasgow, UK, Part XXI 16. Springer International Publishing, 2020; 312-328.
- [28] WU Y,ABDALMAGEED W,NATARAJAN P. Mantra-net: Manipulation tracing network for detection and localization of image forgeries with anomalous features [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019;9543-9552.
- [29] HUANG Y,BIAN S,LI H,et al. DS-UNet:A dual streams UNet for refined image forgery localization [J]. Information Sciences,2022,610:73-89.
- [30] SHULLANI D,FONTANI M,IULIANI M,et al. Vision;a video and image dataset for source identification [J]. EURASIP Journal on Information Security,2017,2017(1):1-16.
- [31] SELVARAJU R R,COGSWELL M,DAS A,et al. Grad-cam: Visual explanations from deep networks via gradient-based localization [C] // Proceedings of the IEEE International Conference on Computer Vision. 2017;618-626.



HUANG Yuanhang, born in 1997, post-graduate, is a member of CCF (No. C0385G). His main research interests include camera model identification and image forgery localization.



BIAN Shan, born in 1986, Ph.D, associate professor, is a member of CCF (No. 21153M). Her main research interests include video forensics and tampering detection.