

DOI: 10.20271/j.cnki.1673-9833.2026.1012

# 相机源识别方法中的 自适应注意力密集网络结构研究

吴昊璇, 文志强

(湖南工业大学 计算机与人工智能学院, 湖南 株洲 412007)

**摘要:** 为了提高深度学习模型在相机源识别领域的识别精度, 设计了自适应注意力密集网络结构, 并提出了自适应权重注意力方法。设计的网络结构包括预处理结构、密集连接结构、注意力结构、正则化结构4部分。注意力机制结构中采用自适应权重注意力方法, 通过引入自适应权重因子, 实现参数自适应优化, 以便获取适应不同数据特点的最优注意力权重, 提升模型特征学习和特征表达能力。并在两个经典数据集上进行了对比实验和消融实验。在对比实验中, 与3个经典网络进行了比较, 实验结果表明设计网络的识别性能在两个数据集上分别比其他3个网络至少提高了5.547%, 9.58%; 消融实验结果表明, 提出方法的识别性能在两个数据集上分别比其他消融方法至少提高了2.107%, 4.732%。

**关键词:** 相机源识别; 注意力机制; 自适应权重; 卷积神经网络

**中图分类号:** TP391

**文献标志码:** A

**文章编号:** 1673-9833(2026)01-0085-07

**引文格式:** 吴昊璇, 文志强. 相机源识别方法中的自适应注意力密集网络结构研究 [J]. 湖南工业大学学报, 2026, 40(1): 85-91.

## Research on Adaptive Attention Dense Network in Camera Source Recognition Method

WU Haoxuan, WEN Zhiqiang

(School of Computer Science and Artificial Intelligence, Hunan University of Technology, Zhuzhou Hunan 412007, China)

**Abstract:** In view of an improvement of the recognition accuracy of deep learning models in the field of camera source recognition, an adaptive attention dense network structure has thus been designed, with an adaptive weighted attention method proposed. The designed network structure includes four parts: prepossessing structure, dense connection structure, attention structure, and regularization structure. The adaptive weight attention method is adopted in the attention mechanism structure so as to introduce adaptive weight factors for an parameter adaptive optimization, thus obtaining the optimal attention weight that adapts to different data characteristics and improve the model's feature learning and feature expression capabilities. Comparative experiments and ablation experiments are conducted on two classic datasets. In the comparative experiment, a comparison is made between the designed network and three classical networks, with the experimental results showing that the recognition performance of the designed network is improved by at least 5.547% and 9.283% on two datasets, respectively, compared to the other three networks. The results of the ablation experiment show that the recognition performance of the proposed method is at least 1.143% and 5.000% higher than other ablation methods on two datasets, respectively.

**Keywords:** camera source recognition; attention mechanism; adaptive weight; convolution neural network

收稿日期: 2024-09-27

基金项目: 湖南省自然科学基金资助项目(2022JJ50051, 2024JJ7149); 湖南省教育厅科学研究基金资助项目(22A0414, 21A0350)

作者简介: 吴昊璇, 女, 湖南工业大学硕士生, 主要研究方向为计算机视觉与图像处理, E-mail: 18570488219@163.com

通信作者: 文志强, 男, 湖南工业大学教授, 博士, 主要研究方向为模式识别与图像处理, E-mail: zhqwen20001@163.com

## 1 研究背景

相机源识别对于保护数字图像的知识产权、确保其可靠性及准确性极为重要,同时在社会各领域展现出广泛的应用潜力。由于在相机成像过程中,相机硬件电子元件和内部图像处理算法的差异,在生成的数字图像中会留下独有的痕迹。相机源识别技术旨在通过分析这些痕迹来辨识图像的来源设备。

相机源识别研究主要分为两种方法:传统统计学方法和深度学习方法<sup>[1]</sup>。传统统计学方法的核心在于特征提取,即通过将原始图像转换为代表性的特征向量来进行处理。文献[2]采用了多种基线去马赛克算法对图像进行处理,提取了图像残差,并设计了多类集成分类器。这些分类器基于提取的颜色值相关性特征来识别相机源。文献[3]在相机源识别领域引入了集成分类器,捕获融合特征,这些特征包括数字相机在图像上留下的软件相关、硬件相关以及统计特征,从而实现了相机源的识别。文献[4]提出了一种基于离散余弦变换残差特征的相机源识别方法。文献[5]提出了一种通过强调 PRNU (photo response non-uniformity) 模式中影响传感器噪声的像素块来识别相机源方法。文献[6]基于对 PRNU 噪声的研究,引入非线性映射以改进乘法模型,减少了残差的影响,实现了相机源识别。

这些传统统计学方法高度依赖于特征提取,导致其自动化程度低且难以适应相机源的变化。在处理大规模数据集时,其计算和分析效率低,耗时长。并且,这些方法的特征选择有限,往往只能基于颜色值和基本统计特征,无法充分捕获相机源的复杂特征。因此,目前关于相机源识别的研究主要集中在深度学习方法方面。

深度学习方法简化了传统需人工选取和提取特征的复杂流程,减少了因特征提取不足或不精确而对效率和准确度造成的影响,因此在实际应用中展现出巨大优势<sup>[7]</sup>。文献[8]提出了一种相机源识别方法,该方法结合了卷积神经网络和 SVM 分类器,所展现的识别效果不仅不逊于传统统计学方法,还为该领域的研究提供了新思路。文献[9]提出了一种基于知识驱动的相机源识别方法。文献[10]提出了具有出色相机源识别能力的 Remnet 网络结构。文献[11]引入了批处理归一化技术,进一步提高了相机源识别效果。文献[12]提出了一种专注于图像中同质区域的识别方法。通过将图像分割成固定大小的重叠块,并使用卷积网络识别每个块的相机品牌。

这些深度学习方法虽然相较于传统统计学方法

展现了显著的优势,但也存在一些局限。现有模型在相机源识别精度上仍有较大提升空间。并且,训练模型通常需要大量的标注数据和计算资源,这导致在数据稀缺或资源有限的情况下难以有效训练。尽管基于深度学习的相机源识别研究已取得一定进展,但这些局限问题仍需进一步研究和解决。

文献[13]发现,引入注意力机制至卷积神经网络可提升模型的鲁棒性,进而提高识别正确率。文献[14]认为,注意力机制正逐渐成为深度学习领域的主流研究方向和热点,它能有效地优化模型的识别性能。文献[15]强调,注意力机制通过动态为输入数据的不同部分分配权重,模仿人类的注意力分配,使模型集中于关键信息,减少无关信息的干扰。当前主流的注意力机制通过分析输入数据的不同部分与当前任务的关联性来确定其注意力权重,但这种直接关联性分析的方法并不全面,可能无法应对相机源识别任务的复杂性和多样性。

为增强相机源识别应用场景下模型特征学习和表达的准确性,提高卷积神经网络模型在相机源识别应用中的识别精度,本研究设计了一个自适应注意力密集网络(adaptive attention dense network, AADNet),并在该结构中引入自适应权重注意力方法(adaptive weighted attention method, AWAM)。该方法通过引入自适应权重因子,在训练过程中不断调整注意力权重,获得最优缩放比例,并通过实验验证了该方法的有效性。

## 2 AADNet 网络

AADNet 的数据输入是二维图像,输出是二维图像对应的分类结果,其包括 4 部分结构(见图 1)。

第一部分:预处理结构。该结构包括二维卷积模块、批标准化处理模块、激活函数模块,以及最大池化层。二维卷积模块初步提取输入数据的特征。批标准化处理模块对输入数据的每个通道进行标准化处理,使输入数据的分布更加稳定。激活函数模块是 ReLU 函数将所有负值映射为 0,而正值保持不变,简化梯度计算和反向传播的过程。最大池化层实现了降维操作,减少了数据空间尺寸,提取了数据全局特征。

第二部分:密集连接结构。在密集连接结构中,通过堆叠 4 个密集连接块(DenseBlock)和相应的过渡层(\_Transition)实现了密集连接。在每个密集连接块内部,将 16 个线性层(Layer)基于特征正向连接,将特征图进行拼接,实现了正向的特征传递,再通过每个线性层与其前层相拼接,实现了特征的反



向特征融合。这种特征传递和特征融合相结合实现了一种基于特征的密集连接,促进了特征信息流动,使设计的网络更高效。

第三部分:注意力结构。为了适应复杂的数据特征,提出了AWAM,用于动态分配注意力权重。通过分析输入数据每个通道的重要性,自适应地调整模型对特征的关注程度。AWAM能够使得模型更聚焦于数据的重要特征,减少数据中无关信息对模型的干

扰,提高模型的鲁棒性和泛化能力。

第四部分:正则化结构。包括全局平均池化层、正则化层和全连接层。正则化层通过在训练过程中随机地将网络部分输出置为零,减少网络结构之间的依赖关系,抑制训练中的过拟合现象,提高了模型的泛化能力。全连接层通过学习权重和偏置项,挖掘特征之间的复杂关系,实现高维特征组合和映射。




图1 AADNet 结构框图

Fig. 1 AADNet structure

设计的卷积神经网络中采用交叉熵损失函数来衡量模型预测结果与实际类别之间的差异。通过观察交叉熵损失函数值的变化,不断优化模型参数,使其预测结果更接近真实标签,提高模型的分类能力。损失函数的公式为

$$Loss = -\sum_{i=1}^N p_i \log(k_i). \quad (1)$$

式中:  $Loss$  为网络模型损失值;  $N$  为类别数;  $p_i$  为第  $i$  个类别概率;  $k_i$  为模型预测的第  $i$  个类别概率。

### 3 AWAM 方法

在AWAM中,引入自适应权重因子  $q$ , 通过网络训练,获得最优参数  $q$ , 从而增强模型的鲁棒性。这种自适应优化参数方法能适应应用场景变化,有助于提高模型在面对不同任务时的稳定性。

AWAM主要由自适应平均池化层、两个线性层、激活函数 ReLU、Sigmoid 组成,如图2所示。图2中,两个线性层分别用  $L_1$  和  $L_2$  表示。 $L_1$  层实现特征通道数压缩,具体方法为

$$c' = c \times r. \quad (2)$$

式中:  $c'$  为压缩后特征的通道数;  $c$  为原始特征的道数;  $r$  为压缩比例。

道数;  $r$  为压缩比例。

再通过 ReLU 激活函数,将  $L_1$  层的输出中负值映射为 0,正值保持不变。 $L_2$  层将经 ReLU 函数处理后的特征通道数增加至原始数量,再通过 Sigmoid 函数,将最终  $L_2$  层的输出限制在 0 到 1 之间。




图2 AWAM 结构

Fig. 2 AWAM structure

自适应权重因子  $q_t$  表示第  $t$  次迭代时的权重因子  $q$ 。在迭代过程中,随着  $t$  的变化,不断优化调整,最终获得最优值。在第  $t$  次迭代时,利用梯度下降算法,优化  $q_t$  值,获得第  $t+1$  次迭代权重因子  $q_{t+1}$ ,具体优化策略见式(3)。

$$q_{t+1} = q_t - \alpha_t \cdot \nabla Loss_t. \quad (3)$$

式中:  $\alpha_t$  为第  $t$  次迭代的学习率;  $\nabla Loss_t$  为第  $t$  次迭代损失函数的梯度。

AWAM 的输入为图像的初始特征  $X_0$ ，其形状为  $(b, c, h, w)$ ，其中  $b$  为输入特征的批处理大小， $c$  为输入的通道数， $h$  和  $w$  分别为特征的高和宽，输出为第  $t$  次迭代的注意力权重  $y'_t$  ( $t=0, 1, \dots, n$ )，其形状为  $(b, c)$ 。AWAM 的步骤如下所示。

**步骤 1** 设定迭代次数为  $n$ ，初始化自适应平均池化层权重、注意力权重  $y_0$  以及自适应权重因子  $q_0$ ，初始图像特征  $X_0$ ， $t=0$ 。

**步骤 2** 通过与自适应平均池化层权重结合计算，将初始图像特征  $X_0$  的维度降为  $(b, c)$ ，表示为全局特征  $G_t$ 。

**步骤 3** 全局特征  $G_t$  在全连接层中，利用式 (2)，通过  $L_1$  进行通道数压缩后与全连接层进行计算，再通过  $L_2$  进行通道数还原，得到注意力权重  $y'_t$ 。

**步骤 4** 利用公式  $y_t = y'_t \times q_t$ ，获得缩放后的注意力权重  $y_t$ 。

**步骤 5** 将全局特征  $G_t$  与注意力权重  $y_t$  相乘，得到加注意力后的新特征  $X'_t$ ，即  $X'_t = G_t \times y_t$ 。

**步骤 6** 利用式 (1) 计算第  $t$  次迭代的损失值梯度  $\nabla Loss_t$ 。

**步骤 7** 如果  $\|\nabla Loss_t\|_2 \leq \varepsilon$  且  $t \leq n$ ，则根据式 (3) 获得第  $t+1$  次迭代的  $q_{t+1}$ ，并且令  $t=t+1$ ，转至步骤 2。否则，算法结束。

图 3 是在两个经典数据集上进行权重因子  $q$  关于迭代次数  $t$  的实验结果。




图 3 不同数据集上  $q$  值收敛曲线

Fig. 3 Convergence curves of  $q$  on different datasets

从图 3 中可看出，在两个数据集上的  $q$  值均从 1.0 开始随迭代次数增加而逐步降低，并趋于某个固定值，但在不同的数据集环境下，趋向值不相同。

## 4 实验

### 4.1 实验环境

实验是在 Windows 11 操作系统的计算机上进行的。主要硬件配置包括：Intel i7 CPU 和 GeForce RTX 3050 显卡。软件环境方面，选择 Python 3.6.13

为实验开发语言，采用 PyTorch 1.10.2 为开发框架，采用 CUDA 11.8 作为加速器。

为了评估模型的性能和效果，实验选用模型的精确率 ( $P$ )，准确率 ( $A$ )，召回率 ( $R$ ) 和  $F_1$  分数 ( $F_1$ ) 作为实验的数值化指标，可由以下公式得出：

$$P = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FN} + N_{FP} + N_{TN}}, \quad (4)$$

$$A = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (5)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (6)$$

$$F_1 = \frac{2 \times R \times P}{R + P}. \quad (7)$$

式 (4)~(7) 中： $N_{TP}$  为模型预测的真正类样本数量； $N_{FN}$  为模型预测的假负类样本数量； $N_{FP}$  为模型预测的假正类样本数量； $N_{TN}$  为模型预测的真负类样本数量。

为了测试提出方法的性能，在两个公开数据集上进行了实验。第一个数据集是 SPC2018 数据集<sup>[16]</sup>，相机型号和标签如表 1 所示。

表 1 SPC2018 数据集

Table 1 SPC2018 dataset

| 相机型号           | 标签 | 相机型号         | 标签 |
|----------------|----|--------------|----|
| 索尼 NEX-7       | 0  | LG Nexus 5x  | 5  |
| 三星盖乐世 Note 3   | 1  | 苹果 iPhone 6  | 6  |
| 摩托罗拉 MotoX     | 2  | 苹果 iPhone 4s | 7  |
| 摩托罗拉 Nexus 6   | 3  | HTC One M7   | 8  |
| 摩托罗拉 DROIDMAXX | 4  | 三星 Galaxy S4 | 9  |

第二个数据集是 Dresden 数据集<sup>[17]</sup>。该数据集提供了图像处理和评估任务的基准数据，实验采用该数据集的数据子集，其相机型号及标签见表 2。

表 2 Dresden 数据集

Table 2 Dresden dataset

| 相机型号                | 标签 | 相机型号               | 标签 |
|---------------------|----|--------------------|----|
| Agfa_DC-733s        | 0  | Kodak_M1063        | 5  |
| Agfa_DC-830i        | 1  | Nikon_D200         | 6  |
| Agfa_Sensor530s     | 2  | Panasonic_DMC-FZ50 | 7  |
| Canon_Ixus55        | 3  | Samsung_L74wide    | 8  |
| FujiFilm_FinePixJ50 | 4  | Sony_DSC-H50       | 9  |

实验参数设定初始  $q_0$  为 1.0，迭代次数  $n$  为 300，批处理大小  $b$  为 64，通道数  $c$  为 3，图像高和宽 ( $h, w$ ) 均为 224 个像素，压缩比例  $r$  为 16，初始学习率  $\alpha_0=0.001$ ，并采用自定义函数衰减学习率调整策略，将第  $t$  次迭代的学习率定义为关于迭代次数  $t$  的  $\cos$  函数，实现了学习率的动态调整。

首先将数据集中图像调整成大小为  $224 \times 224$  像

素,并进行数据增强操作,随机水平翻转,随机垂直翻转,调整对比度、亮度等操作。然后,将数据集中的图像按照 8:1:1 的分配比例随机分成训练集、验证集和测试集。再将训练集图像输入神经网络进行训练,产生模型,并利用验证集对模型进行调参。最后,利用测试集测试网络模型的效果来评价模型性能。

#### 4.2 对比实验


为了验证设计网络结构 AADNet 的优越性,与 3 种经典卷积神经网络进行比较。这 3 种网络如下。

1) 多样性增强块预测网络 (DEPS)<sup>[18]</sup>。该方法根据多个标准选择代表性补丁,以增强训练数据的多样性,提出细粒度多尺度预测模块,以减少场景内容的干扰。


2) 深度残差网络 (RES)<sup>[19]</sup>。通过引入残差连接,将残差块的输入通过跳跃连接直接传递到输出,实现特征在网络中直接传递,保持了特征的完整性。

3) EfficientNetV2 网络 (ENV2)<sup>[20]</sup>。通过训练感知神经架构的搜索和缩放,实现共同优化训练速度和参数效率,同时结合一种改进的渐进式学习方法,以根据图像大小自适应调整正则化策略。

4 种网络在 Spc2018 数据集上实验的准确率和损失值变化如图 4 所示。



a) 准确率变化曲线




b) 损失值变化曲线

图 4 Spc2018 数据集试验结果


Fig. 4 Experimental results of Spc2018 dataset

在 Dresden 数据集上实验的准确率和损失值变化如图 5 所示。由图 4a 和图 5a 可知,4 种卷积神经网络的准确率曲线均呈上升趋势,并且最终上升至最

高值,高于其他 3 种网络。在迭代次数  $t$  小于 15 时, AADNet 的准确率与其他 3 种网络不相上下。在迭代次数  $t$  大于 15 时, AADNet 的准确率明显均高于其他 3 种网络。由图 4b 和图 5b 可知, AADNet 的损失值曲线均呈下降趋势。在 Spc2018 数据集上实验迭代次数  $t$  小于 18 时, AADNet 的损失值和其他 3 种方法几乎保持一致,但从  $t > 18$  时, AADNet 的损失值小于其他 3 种网络。在 Dresden 数据集上实验的损失值大体上与其他三种网络保持一致。当  $t > 45$  时, AADNet 的损失值明显小于其他 3 种网络。



a) 准确率变化



b) 损失值变化

图 5 Dresden 数据集实验结果

Fig. 5 Experimental results of Dresden dataset

4 种网络在两个数据集上的精确率、准确率、召回率等比较结果见表 3。

表 3 实验结果比较

Table 3 Comparison of experimental results

| 数据集         | 方法     | 精确率/%  | 准确率/%  | 召回率/%  | $F_1$ /% |
|-------------|--------|--------|--------|--------|----------|
| Spc2018 数据集 | DEPS   | 79.642 | 80.529 | 79.642 | 80.745   |
|             | RES    | 75.714 | 76.59  | 75.714 | 75.714   |
|             | ENV2   | 93.214 | 93.418 | 93.214 | 93.214   |
|             | AADNet | 98.928 | 98.965 | 98.928 | 98.928   |
| Dresden 数据集 | DEPS   | 79.500 | 80.720 | 79.499 | 79.499   |
|             | RES    | 70.000 | 71.883 | 70.000 | 70.000   |
|             | ENV2   | 48.500 | 56.029 | 48.500 | 48.500   |
|             | AADNet | 90.000 | 90.300 | 90.000 | 90.000   |

由表 3 可知,在 Spc2018 数据集上, AADNet 的精确率达到 98.928%, 准确率达到 98.965%, 召回



率达到 98.928%,  $F_1$  分数为 98.928%; 在 Dresden 数据集上, AADNet 的精确率达 90.000%, 准确率达到 90.300%, 召回率达到 90.000%,  $F_1$  分数为 90.000%。对于两个数据集上的 4 组实验, AADNet 的精确率、准确率、召回率、 $F_1$  分数均高于其他 3 种网络。在 Spc2018 数据集上, AADNet 的识别效果至少比其他 3 种网络提高 5.547%, 在 Dresden 数据集上 AADNet 的识别效果至少比其他 3 种网络提高 9.58%。

综上所述, 根据 4 个指标 (精确率、准确率、召回率和  $F_1$  分数) 综合评估, AADNet 在两个数据集上均表现最佳, 在一定程度上体现了其鲁棒性。

#### 4.3 消融实验

为了验证提出的 AWAM 方法对 AADNet 结构的有效影响, 在两个数据集上分别进行了消融实验。未引入注意力机制且未引入自适应权重因子的方法, 记为 NATW; 引入注意力机制且未引入自适应权重因子, 记为 RAM 方法; 引入空间注意力机制<sup>[21]</sup>的记为 SPAM 方法; 引入自注意力机制<sup>[22]</sup>的记为 SELFAM 方法; 引入通道注意力机制<sup>[23]</sup>的记为 CNAM 方法。

在消融实验中, 先对数据集图像进行预处理, 并通过随机翻转、调整对比度和亮度等进行数据增强。再将训练集的图像输入神经网络进行训练, 通过反向传播算法不断优化模型的权重参数。使用验证集进行模型调参, 以优化超参数, 提高模型在未见数据上的表现。最后, 利用测试集对训练后的模型进行评估, 并计算每种方法实验数据评价指标数值。6 组消融实验的精确率、准确率、召回率和  $F_1$  分数值如表 4 所示。

表 4 消融实验结果  
Table 4 Results of ablation experiments

| 实验组别           | 方法     | 精确率/%  | 准确率/%  | 召回率/%  | $F_1$ /% |
|----------------|--------|--------|--------|--------|----------|
| Spc2018<br>数据集 | NATW   | 96.071 | 96.313 | 96.071 | 96.071   |
|                | RAM    | 96.785 | 96.858 | 96.785 | 96.785   |
|                | AWAM   | 98.928 | 98.965 | 98.928 | 98.928   |
|                | SPAM   | 95.200 | 95.400 | 94.800 | 94.999   |
|                | SELFAM | 94.500 | 94.700 | 94.200 | 94.349   |
|                | CNAM   | 93.800 | 94.000 | 93.500 | 93.649   |
| Dresden<br>数据集 | NATW   | 83.500 | 84.898 | 83.500 | 83.500   |
|                | RAM    | 85.000 | 85.575 | 85.000 | 85.000   |
|                | AWAM   | 90.000 | 90.307 | 90.000 | 90.000   |
|                | SPAM   | 84.200 | 84.900 | 83.800 | 83.999   |
|                | SELFAM | 82.500 | 83.000 | 81.000 | 81.743   |
|                | CNAM   | 81.000 | 82.000 | 80.500 | 80.749   |

由表 4 数据可知, 在 Spc2018 数据集上的消融实验结果中, AWAM 的精确率、准确率、召回率和

$F_1$  分数均可高达 98%; 在 Dresden 数据集上进行的实验结果中, AWAM 的实验数据可达 90% 左右。在 Spc2018 数据集上, AWAM 的识别率比其他消融方法至少提高 2.107%, 在 Dresden 数据集上, AWAM 的识别率比其他消融方法至少提高 4.732%。综上两组消融实验结果表明, AWAM 比其他两组消融方法要好。主要原因是通过引入自适应权重因子, 能更好地捕捉输入数据的重要特征, 提高模型的准确性, 增强模型的鲁棒性。

## 5 结论

针对相机源识别问题, 设计了 AADNet 结构, 并提出了一种 AWAM 方法。设计的网络结构 AADNet 包括预处理结构、密集型结构、注意力结构、正则化结构, 其中注意力结构中采用 AWAM 方法来实现优化, 提高识别鲁棒性。AWAM 方法引入了自适应权重因子  $q$ , 通过自适应权重注意力机制中的正向传播和梯度下降优化策略不断修正  $q$ , 实现了自适应优化, 获得最优  $q$  值, 从而优化调整注意力权重, 提升模型特征学习和特征表达的能力, 提高模型的鲁棒性。实验阶段, 给出了实验环境、实验比较结果和消融实验结果。实验比较结果表明, AADNet 网络在 Spc2018 数据集和 Dresden 数据集上, 分别比其他 3 种网络至少提高 5.547%, 9.58%。消融实验结果表明 AWAM 方法在 Spc2018 数据集和 Dresden 数据集上, 分别比其他消融方法至少提高 2.107%, 4.732%。

当前相机源识别研究集中在深度学习领域, 虽然 AADNet 结构和 AWAM 方法在一定程度上能解决相机源识别的准确率不足的问题, 但深度学习技术在相机源识别研究中的应用还存在着许多值得研究与改进的问题。传统深度学习技术通常需要大量的标注数据进行训练, 从而获得识别准确率较高的模型, 但获取足量的标注数据需要耗费大量人力物力, 在实际应用场景中局限性较大。难以获得足量数据进行训练则会导致模型的泛化能力受到限制, 特别是在面对复杂或罕见情境时, 模型识别的准确率将会降低。目前已知融合小样本学习能对于上述问题有所帮助, 但小样本学习使得模型在面对相机源识别任务时难以充分学习数据的复杂特征, 容易导致过拟合现象, 即在训练数据上表现良好但在实际场景中泛化能力不足。因此, 未来的研究将会专注于针对小样本问题的创新性方法, 如迁移学习、数据增强和元学习等, 以提高深度学习模型在相机源识别任务中的鲁棒性和泛化性能。

## 参考文献:

- [1] 陈艺芳, 何自强, 文冠臣, 等. 图像源辨识取证研究综述[J]. 信号处理, 2021, 37(12): 2302–2322.  
CHEN Yifang, HE Ziqiang, WEN Guanchen, et al. A Survey of Forensics Research on Image Source Identification Forensics[J]. Journal of Signal Processing, 2021, 37(12): 2302–2322.
- [2] CHEN C, STAMM M C. Robust Camera Model Identification Using Demosaicing Residual Features[J]. Multimedia Tools and Applications, 2021, 80(8): 11365–11393.
- [3] WANG B, ZHONG K, LI M. Ensemble Classifier Based Source Camera Identification Using Fusion Features[J]. Multimedia Tools and Applications, 2019, 78(7): 8397–8422.
- [4] MANDELLI S, BONETTINI N, BESTAGINI P. Source Camera Model Identification[M]. Singapore: Springer Singapore, 2022: 133–173.
- [5] FLOR E, AYGUN R, MERCAN S, et al. PRNU-Based Source Camera Identification for Multimedia Forensics[C]//2021 IEEE 22nd International Conference on Information Reuse and Integration for Data Science (IRI). Las Vegas: IEEE, 2021: 168–175.
- [6] FERNÁNDEZ-MENDUIÑA S, PÉREZ-GONZÁLEZ F, MASCIOPINTO M. Source Camera Attribution via PRNU Emphasis: Towards a Generalized Multiplicative Model[J]. Signal Processing: Image Communication, 2023, 114: 116944.
- [7] DONG S, WANG P, ABBAS K. A Survey on Deep Learning and Its Applications[J]. Computer Science Review, 2021, 40: 100379.
- [8] BONDI L, BAROFFIO L, GÜERA D, et al. First Steps Toward Camera Model Identification with Convolutional Neural Networks[J]. IEEE Signal Processing Letters, 2016, 24(3): 259–263.
- [9] DING X H, CHEN Y S, TANG Z, et al. Camera Identification Based on Domain Knowledge-Driven Deep Multi-Task Learning[J]. IEEE Access, 2019, 7: 25878–25890.
- [10] RAFI A M, TONMOY T I, KAMAL U, et al. RemNet: Remnant Convolutional Neural Network for Camera Model Identification[J]. Neural Computing and Applications, 2021, 33(8): 3655–3670.
- [11] FREIRE-OBREGÓN D, NARDUCCI F, BARRA S, et al. Deep Learning for Source Camera Identification on Mobile Devices[J]. Pattern Recognition Letters, 2019, 126: 86–91.
- [12] BENNABHAKTULAGS, ALEGRE E, KARASTOYANOVA D, et al. Camera Model Identification Based on Forensic Traces Extracted from Homogeneous Patches[J]. Expert Systems with Applications, 2022, 206: 117769.
- [13] BENNABHAKTULA G S, ALEGRE E, KARASTOYANOVA D, et al. Camera Model Identification Based on Forensic Traces Extracted from Homogeneous Patches[J]. Expert Systems with Applications, 2022, 206: 117769.
- [14] NIU Z, ZHONG G, YU H. A Review on the Attention Mechanism of Deep Learning[J]. Neurocomputing, 2021, 452: 48–62.
- [15] BRAUWERS G, FRASINCAR F. A General Survey on Attention Mechanisms in Deep Learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(4): 3279–3298.
- [16] NIU Z Y, ZHONG G Q, YU H. A Review on the Attention Mechanism of Deep Learning[J]. Neurocomputing, 2021, 452: 48–62.
- [17] NWOKEJI C E, SHEIKH-AKBARI A, GORBENKO A, et al. Source Camera Identification Techniques: A Survey[J]. Journal of Imaging, 2024, 10(2): 31.
- [18] GLOE T, BÖHME R, GLOE T, et al. The ‘Dresden Image Database’ for Benchmarking Digital Image Forensics[C]//Proceedings of the 2010 ACM Symposium on Applied Computing. Sierre: ACM, 2010: 1584–1590.
- [19] LIU Y X, ZOU Z Y, YANG Y, et al. Efficient Source Camera Identification with Diversity-Enhanced Patch Selection and Deep Residual Prediction[J]. Sensors, 2021, 21(14): 4701.
- [20] CHEN Y S, HUANG Y, DING X H. Camera Model Identification with Residual Neural Network[C]//2017 IEEE International Conference on Image Processing (ICIP). Beijing: IEEE, 2017: 4337–4341.
- [21] GORDIENKO Y, GORDIENKO N, FEDUNYSHYN R, et al. Multibackbone Ensembling of EfficientNetV2 Architecture for Image Classification[C]//International Conference on Trends in Sustainable Computing and Machine Intelligence. Springer: Singapore, 2025: 55–69.
- [22] ZHU X Z, CHENG D Z, ZHANG Z, et al. An Empirical Study of Spatial Attention Mechanisms in Deep Networks[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019: 6688–6697.
- [23] QIAN X F, ZHANG C Q, CHEN L, et al. Deep Learning-Based Identification of Maize Leaf Diseases Is Improved by an Attention Mechanism: Self-Attention[J]. Frontiers in Plant Science, 2022, 13: 864486.
- [24] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 11534–11542.

(责任编辑: 申 剑)