

融合多重注意力机制的图像篡改检测与识别方法

李 帅¹ 吴宗胜² 薛 茹¹ 马毓洋¹ 泽仁玉珍¹
LI Shuai WU Zongsheng XUE Ru MA Yuyang Zeren Yuzhen

摘要

随着数字图像处理技术的飞速发展,图像篡改成为威胁信息安全和真实性的严重问题之一。而现有的图像篡改检测方法大多只针对单一篡改方式进行检测,或仅能定位篡改区域,无法有效识别篡改的具体类型,进而限制了其在实际应用场景中的泛化能力。对此,提出了一种融合多重注意力机制的图像篡改检测与识别方法,旨在提高对多种篡改方式的检测精度与泛化能力。通过引入通道注意力机制和空间注意力机制,增强模型在提取和表达图像特征时的局部和全局感知能力。通道注意力机制有助于捕捉图像中不同通道之间的相关性,提升对篡改信息的精细化检测;而空间注意力机制则增强了模型对图像不同位置间关联的理解,进一步提高了对篡改区域的定位精度。最终在 NIST16、Columbia 和 CASIA 三个公开数据集上进行测试, F_1 值分别取得 41.7%、45.2% 和 34.1% 的成绩。通过观察与现有的检测方法对比以及可视化检测结果证明,所提方法具备较强的泛化性,且能够同时检测和识别多种篡改手段。

关键词

图像篡改;篡改定位;注意力机制;Transformer

doi: 10.3969/j.issn.1672-9528.2025.05.009

0 引言

随着数字媒体的广泛传播,图像作为信息传递的重要媒介,在新闻报道、信息安全、社交媒体等领域中占据了关键地位。然而,随着图像编辑技术和生成技术的快速发展,图像篡改变得更为简单且隐蔽,给社会带来了巨大的信任危机。尤其是在司法鉴定和信息安全等领域,图像的真实性和完整性更为重要。

因此,图像篡改检测与识别技术逐渐成为一个研究热点。有效地检测图像篡改并识别篡改类型,不仅是保障信息可信度的重要手段,也是打击虚假信息传播的技术基础。

目前,大多数图像篡改检测方法在性能上仍存在一定的局限性。许多研究只针对特定类型的篡改(如拼接、复制粘贴等)进行检测,缺乏对多种篡改方式的泛化能力。此外,现有方法通常只能定位出篡改区域,但对篡改类型的区分能力不足。鉴于篡改手段的多样性和复杂性,如何设计出一种既能精确检测篡改区域,又能准确识别篡改类型的通用模型,成为该领域的重要挑战。

为了解决这些问题,本文提出了一种融合通道注意力机

1. 西藏民族大学信息工程学院 陕西咸阳 712000

2. 咸阳师范学院计算机学院 陕西咸阳 712000

[基金项目] 西藏自治区自然科学基金重点项目
(XZ202301ZR0042G)

[10] 彭铎,谢堃,刘明硕.基于改进 RSSI 测距的 WSN 机动目标跟踪算法[J].物联网技术,2024,14(8):41-45.

[11] 王龙旭.基于数据融合技术的室内定位系统研究[D].长春:吉林建筑大学,2017.

[12] 刘博,李卓,刘伟,等.基于改进麻雀搜索算法优化的 RSSI 定位[J].传感器与微系统,2024,43(9):127-130.

[13] 韩世杰.基于无线传感技术的多维度定位系统研究与设计[D].长春:吉林建筑大学,2023.

[14] 李婷婷,韩成浩.基于卡尔曼滤波的建筑物内人员定位系统研究[J].吉林建筑大学学报,2015,32(3):68-70.

[15] WANG Y, FU S Q, WANG F H. Improved maximum correntropy criterion Kalman filter with adaptive behaviors for INS/UWB fusion positioning algorithm[J].Alexandria

engineering journal,2024,109:702-714.

[16] WEI X J. Machine learning-based strategy for efficient node localization in wireless sensor networks[J].Journal of ambient intelligence and humanized computing,2025,16:67-84.

【作者简介】

林娅茹(2000—),女,山东青岛人,硕士研究生,研究方向:工地人员定位系统设计。

韩成浩(1972—),通信作者(email:784220625@qq.com),男,吉林图们人,博士,教授,研究方向:建筑火灾风险防控与应急救援。

(收稿日期:2024-12-29 修回日期:2025-04-29)

制和空间注意力机制的图像篡改检测与识别方法。通道注意力机制通过捕捉不同通道间的特征重要性,有效提升了篡改检测的准确性;空间注意力机制则帮助模型在二维空间中更好地定位篡改区域。通过这两种机制的结合,本文提出的方法能够同时实现篡改区域的精准定位和篡改类型的有效识别。

本文主要工作如下:

(1) 提出一种基于多注意力机制的图像篡改检测与识别框架,利用通道和空间注意力机制,有效提升了模型对篡改区域的定位与类型识别能力。

(2) 针对目前方法只能处理单一篡改类型的局限性,本文方法能够泛化到多种篡改类型,提升了检测的鲁棒性。

(3) 在公开数据集 NIST16、Columbia 和 CASIA 上进行了实验验证,取得了显著的检测准确率,证明了该方法在不同数据集和不同篡改类型上的有效性。

1 相关工作

早期的图像篡改检测方法大多基于图像的低层次特征,可以分为三种^[1],分别是基于图像篡改痕迹、基于设备固有属性和通过观察图像内在统计特征的变化。

随着深度学习的发展,卷积神经网络(CNN)逐渐成为篡改检测领域的主流技术。Bayar 等人^[2]提出的基于 CNN 的图像篡改检测方法通过自动学习图像中的篡改特征,不再依赖于手工特征提取,从而达到检测目的。Zhou 等人^[3]则通过设计混合网络,将图像分割与篡改区域检测相结合,提高了篡改区域的定位准确率。然而,这些方法通常只关注篡改区域的定位,而忽略了对篡改类型的识别,无法应对多样化的篡改手段。

在篡改类型识别方面,现有方法主要针对特定的篡改类型,如拼接、复制粘贴和删除等。Bappy 等人^[4]提出的双流网络模型,通过提取图像的 RGB 特征流和噪声残差流,能够较为有效地区分不同篡改类型。但这种方法在面对更多复杂的篡改手段时仍表现出局限性。此外, Li 等人^[5]提出了基于生成对抗网络(GAN)的图像篡改检测模型,通过学习生成模型中的特征,提升了对生成图像的检测能力。然而, GAN 类方法对生成图像表现良好,但在应对真实篡改图像时效果不佳。

注意力机制近年来在计算机视觉领域广泛应用,并被证明能够显著提升模型的性能。Squeeze-and-Excitation 网络^[6]引入了通道注意力机制,通过权重调整不同通道的特征,提升了模型对特征重要性的捕捉能力。Woo 等人^[7]提出了卷积块注意力模块(CBAM),将通道注意力与空间注意力相结合,在不同维度上增强了特征提取的效果。尽管这些注意力机制在分类任务中表现优异,但在图像篡改检测与识别领域的应用还相对较少,尤其是对篡改区域的精准定位和篡改类型的识别尚未得到充分探索。

文献[8-10]在检测上具有篡改方式单一、检测背景特殊

等局限性,可能导致在实际环境中不能得到理想的处理结果。对此,本文融合了通道和空间注意力机制,通过充分利用图像的不同维度特征,有效提升了篡改区域的定位精度和篡改类型的识别能力。与现有方法相比,本文方法不仅能够准确定位篡改区域,还能识别多种篡改类型,并在多个公开数据集上取得了较为优异的检测效果。

2 关键技术实现

2.1 算法提出动机

图像篡改检测的挑战在于如何准确地识别和定位篡改区域。尽管卷积神经网络(CNN)在图像分析任务中表现出色,但在处理复杂的篡改图像时,仍面临许多困难。

在篡改检测任务中, SCSE^[11]机制的引入具有显著的优势, SCSE 机制是通道注意力机制(CSE)和空间注意力机制(SSE)的结合。首先,通道注意力机制使模型能够突出与篡改相关的特征通道,增强对篡改信息的敏感性。例如,当篡改区域具有特定的纹理或色彩变化时,通道注意力机制能够自动加强这些特征的响应,从而提高检测准确性。其次,空间注意力机制通过加权特定空间位置的特征,帮助模型更准确地定位篡改区域。这对于处理复杂的篡改图像尤为重要,因为篡改区域往往具有局部特征的细微变化。

基于以上动机,提出了一种结合 SCSE 机制的图像篡改检测算法,该算法不仅能够准确定位篡改区域,同时对图像的篡改类别也可以进行有效识别。

2.2 融合多重注意力机制的篡改检测网络

本文提出的生成图像检测网络的整体架构主要由特征提取网络、Transformer 编码器、多尺度适配器和 Transformer 解码器组成,如图 1 所示。

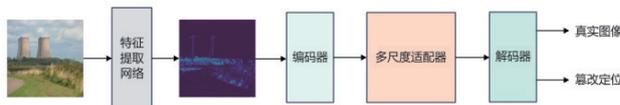


图 1 网络整体架构

2.2.1 特征提取网络

本文提出的网络旨在对图像的篡改区域进行检测及定位。特征提取网络的目的是从输入的图像中提取到图像底层特征,利用篡改特征与原始特征之间的一致性帮助编解码器区分篡改区域与真实区域。

本文采用 ResNet50 作为特征提取网络的主体,其主体由四部分组成,而每部分则分别由 3、4、6、3 个 Bottleneck 组成。其中, Bottleneck 分为 Bottleneck1 和 Bottleneck2,每一部分只含有一个 Bottleneck1 且位于第一位。因传统的卷积会自动关注图像的内容信息,忽略篡改特征的信息^[12],因此,决定引入空间与通道注意力机制,通过在每一个 Bottleneck 模块的最后一次卷积后进行空间注意力以及通道注意力的计算,

增强网络对篡改特征的关注，网络结构如图 2 所示。

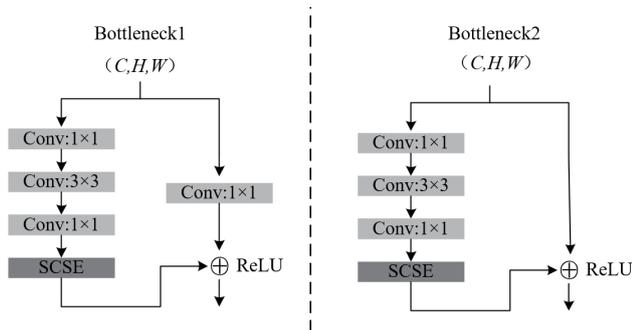


图 2 特征提取网络架构

SCSE 模块主要由空间注意力(SSE)和通道注意力(CSE)两个分支组成，如图 3 (a) (b) 每个分支分别在空间域和通道域进行特征再校准。

对于给定的潜在特征映射 $F \in \mathbb{R}^{H \times W \times C}$ ，空间再校准模块首先生成一个重新加权矩阵 $S \in \mathbb{R}^{H \times W}$ 。

$$S = \text{Sigmoid}(W_1 \otimes F) \quad (1)$$

式中： W_1 表示卷积层的权值； \otimes 表示卷积算子。

然后将重新加权矩阵 S 与特征映射 F 按空间方向相乘，实现自适应激励，得到的重新校准的空间特征用 F_s 表示：

$$F_s = \text{Sigmoid}(W_1 \otimes F) \odot_s F \quad (2)$$

式中： \odot_s 表示空间方向的乘法。

对于 CSE，通过引入全局平均池化层，通道重新校准，首先生成一个中间向量 $v \in \mathbb{R}^{1 \times 1 \times C}$ 。通过使用基于通道依赖性的自门控操作进一步改进该向量：

$$v^* = \text{Sigmoid}(W_2 \otimes \text{ReLU}(W_3 \otimes v)) \quad (3)$$

式中： W_2 和 W_3 表示两个完全连接层的权值。

最后通道重新校准的特征 F_c 由 F 和 v^* 的乘积所得，用公式表示为：

$$F_c = v^* \otimes_c F \quad (4)$$

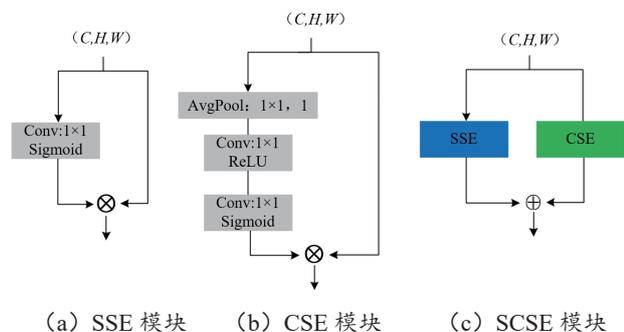


图 3 SCSE 结构图

2.2.2 编码器与解码器

编码器与解码器采用 Transformer 结构，利用其全局自注意力机制，编码器可以捕捉图像中不同区域的依赖关系，

解码器则通过一组查询生成篡改区域的边界框和类别预测。边界框 $B=[x_1, y_1, x_2, y_2]$ 用于标识篡改区域的位置，其中 $[x_1, y_1]$ 和 $[x_2, y_2]$ 分别表示边界框的左上角和右下角坐标。类别标签 C 用于区分篡改区域和未篡改区域。最后，通过上采样将特征图恢复至原图尺寸，生成篡改区域定位图。

模型的损失函数由分类损失 L_{cls} 和边界框回归损失 L_{bbox} 组成。分类损失用于优化类别标签的预测为：

$$L_{cls} = -\sum_{i=1}^N [C_{true}^{(i)} \log C_{pred}^{(i)} + (1 - C_{true}^{(i)}) \log(1 - C_{pred}^{(i)})] \quad (5)$$

式中： C_{true} 是真实的类别标签； C_{pred} 是模型的预测概率； N 是总样本数。边界框回归损失包括 L1 损失和广义交并比损失 (GIoU) 为：

$$L_{bbox} = \lambda_1 \sum_{i=1}^N \|B_{pred}^{(i)} - B_{true}^{(i)}\|_1 + \lambda_2 \sum_{i=1}^N \left(1 - \frac{\text{Area}(B_{pred}^{(i)} \cap B_{true}^{(i)})}{\text{Area}(B_{pred}^{(i)} \cup B_{true}^{(i)})}\right) \quad (6)$$

式中： B_{pred} 是预测的边界框； B_{true} 是真实的边界框； λ_1 和 λ_2 分别是 L1 损失和 GIoU 损失的权重系数； \cap 和 \cup 分别是预测框和真实框的交集和并集； $\text{Area}()$ 是交接区域面积。

总损失由分类损失和边界框损失的加权和得出：

$$L_{total} = \alpha_1 L_{cls} + \alpha_2 L_{bbox} \quad (7)$$

式中： α_1 和 α_2 是权重系数，用于平衡各个损失项在损失计算中的权重。

此外，网络使用匈牙利算法 (Hungarian Algorithm) 来匹配模型的预测结果和真实标签，这种优化策略能够有效提高边界框的定位精度和分类准确性，从而提升对篡改区域的检测效果。

3 实验结果

3.1 数据来源与评价指标

为验证本文提出的多注意力机制图像篡改检测方法的有效性，实验采用了自制训练集和 3 个公开的测试集。训练集通过随机从 COCO2017 数据集中抽取样本，并利用 OpenCV 进行图像篡改操作。具体的篡改方法包括图像拼接、复制粘贴篡改等，以丰富模型的训练数据并增强其泛化能力。数据集包含移除、拼接、复制粘贴 1 782 张篡改样本，其中 1 382 张样本作为训练集，400 张样本作为验证集。测试集采用 3 个公开的图像篡改检测数据集：NIST16、Columbia^[13] 和 CASIA^[14] 进行测试。其中 NIST16 包含移除、拼接和复制粘贴 3 种方式篡改 564 张样本，分辨率从 500 px × 500 px 到 5 616 px × 3 744 px 不等；Columbia 包含了 180 张拼接篡改方式的样本，分辨率从 757 px × 568 px 到 1 152 px × 768 px 不等；CASIA V2.0 包含了 5 123 张拼接和复制移动的篡改样本，分辨率从 320 px × 240 px 到 800 px × 600 px 不等，测试时从原数据集中随机抽取了 215 张样本进行测试。

本文采用召回率 (Recall)、精确率 (Precision) 以及 F_1 值作为模型性能的评价指标，计算公式分别为：

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (8)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (9)$$

$$F_1 = 2 \times \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (10)$$

式中：TP (True Positive) 表示检测正确的正类 bbox 数量；FP (False Positive) 表示检测错误的正类 bbox 数量；FN (False Negative) 表示检测错误的负类 bbox 数量。

3.2 实验环境

硬件：Intel Xeon E5-2678 处理器，GPU 加速器为 NVIDIA GeForce RTX 3080 Ti。

软件：Windows10 专业版，深度学习框架 PyTorch1.10.0 + CUDA11.3 + python3.7 + MMCV1.7.0 + mmdetection2.25.3。

实验设置：训练批次大小 (batch) 为 16，迭代轮次为 12 个 epoch，迭代 1 044 次。

3.3 对比实验

本文在 3 个数据集上与多个典型方法进行对比，最终证明本模型在性能上与训练速度上优于其他模型。其中 ELA^[15]、NOI^[16] 和 CFA^[17] 属于传统的基于手工特征的检测方法，该方法需要有一定的先验知识对某一种篡改方式的特征进行检测。HFDA-Net 与 PSCC-Net 是基于通道以及空间上的方向对图像的篡改进行检测以及定位。各个模型在公开数据集上的表现如表 1 所示。

表 1 不同方法在公开数据集上的 F_1 值

方法	NIST16	Columbia	CASIA V2.0
ELA	0.236	0.072	0.214
NOI	0.285	0.132	0.263
CFA	0.174	0.110	0.207
ManTra-NET	0.088	0.357	0.130
HFDA-Net	0.452	0.398	0.325
PSCC-Net	0.423	0.401	0.312
IID-Net	0.400	0.365	0.290
CIMD	0.430	0.355	0.300
Coverage Dataset	0.410	0.380	0.285
U-Net Based Method	0.395	0.360	0.270
Ours	0.417	0.452	0.341

ELA：利用图像文件压缩算法在保存 JPEG 格式图像时的特性，检测篡改的痕迹。

NOI：提出相机成像时会引入各种噪声，而在篡改的过程中会引入额外的噪声从而改变现有的噪声特征。该方法通过比对原始图像和样本图像的噪声水平从而判断篡改位置。

CFA：利用彩色滤波矩阵捕获图像中的彩色信息，利用这些信息对图像进行细粒度分析来检测图像中的篡改位置。

ManTra-NET^[18]：利用 CNN 架构提取特征的端到端模型，然后将全局特征与局部特征相结合的方式检测图像中的篡改。

HFDA-Net：提出了一种高频双注意力网络，通过捕捉图像的高频噪声特征，利用双重注意力机制（通道注意力和空间注意力）来聚焦伪造区域中的细节特征。

PSCC-Net：采用了一种逐步进化的策略，结合空间和通道的注意力机制，增强对篡改区域的定位能力。

IID-Net^[19]：该方法基于改进的 ID-Net 模型，用于检测图像修复 (inpainting) 的痕迹。模型增强了对不同类型的修复方法的鲁棒性，特别是在处理由深度学习生成的修复图像时，能够更精确地分辨出篡改区域与真实部分的区别。

CIMD：提供了一个包含多种复杂篡改类型的数据集，还提出了结合局部和全局特征，用于更准确地检测挑战性的图像篡改检测模型。

Coverage Dataset^[20]：提出一个专注于拼接篡改检测的新数据集，并基于深度学习模型来检测图像中的拼接痕迹。通过利用拼接图像的边缘不连续性和过渡区域的异常检测图像中不同来源部分的拼接篡改。

U-Net Based Method^[21]：该方法基于 U-Net 架构，通过其对图像像素级别的细粒度分析，该方法能够在像素级别准确定位篡改区域。

从表 1 的对比结果可以看出，深度学习方法普遍优于传统方法（如 ELA、NOI、CFA 等），这是因为深度学习模型能够自动学习复杂的特征表示，而传统方法依赖手工设计的特征，难以适应不同的篡改类型。特别是传统方法在 Columbia 和 CASIA 数据集上的 F_1 值普遍较低，表明其泛化性能有限。本方法在 NIST16 数据集上的 F_1 值略低于 HFDA-Net，但总体表现仍然优于大多数其他方法。HFDA-Net 在特定场景下的优势可能归因于其高频特征的关注，能够更有效地检测局部边缘或高频噪声。相比之下，本方法尽管在 NIST16 数据集上的性能稍弱，但在 Columbia 和 CASIA 两个数据集上取得了最佳成绩，展示了其更强的泛化能力和对不同篡改类型的鲁棒性。

本方法不仅在 F_1 值上表现优异，同时在召回率和精确率上也优于其他模型，如表 2 和表 3 所示。其多注意力机制有效结合了通道和空间信息，增强了对细粒度篡改区域的检测能力。通过对比分析发现，本方法在不同数据集上的精确率和召回率表现更加平衡，这表明其不仅能够准确定位篡改区域，还能避免漏检，提高整体检测性能。

表 2 部分模型在不同数据集上的精确率

方法	NIST16	Columbia	CASIA V2.0
HFDA-Net	0.651	0.351	0.289
IID-Net	0.351	0.301	0.250
Coverage Dataset	0.467	0.314	0.247
Ours	0.328	0.400	0.295

表 3 部分模型在不同数据集上的召回率

方法	NIST16	Columbia	CASIA V2.0
HFDA-Net	0.345	0.462	0.367
IID-Net	0.470	0.471	0.349
Coverage Dataset	0.371	0.493	0.344
Ours	0.577	0.601	0.577

因此，虽然在特定数据集上表现略有不足，但在绝大多数情况下，本方法能够取得最优成绩，表现出良好的泛化性和稳健性。这些结果表明，利用多注意力机制的特征融合策略能够有效提升图像篡改检测的整体性能。

最后，通过可视化检测效果图进一步验证了本方法在不同篡改类型上的表现。在测试样本中，分别从 3 个数据集中随机挑选了 7 张样本，包括拼接篡改、复制粘贴篡改、移除篡改 3 种篡改方式，检测效果图如图 4 所示。

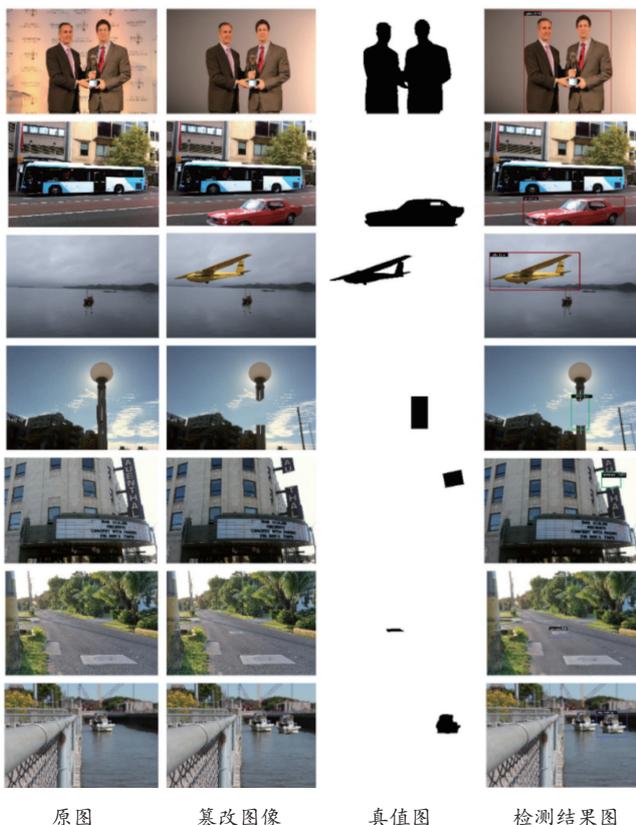


图 4 测试结果图

其中第一列为未经篡改的原始图像；第二列为篡改后的图像；第三列为篡改图像的真值图；第四列为模型的检测结果。具体来说，拼接篡改的 3 张样本中，模型能够准确识别篡改边界并成功定位出篡改区域。对于复制粘贴篡改的两张样本，模型能够精确区分篡改区域与原始图像，避免过多的误检或漏检。在移除篡改的两张样本中，模型同样可以精确地捕捉到被篡改区域的边缘，展现了对篡改区域的强鲁棒性。

由可视化检测结果图可以看出，本模型在处理不同类型的篡改方式时都表现出了较高的检测精度和鲁棒性。通过多尺度适配器和多注意力机制，本方法能够有效捕捉不同尺度下的篡改特征，确保了对篡改区域的准确定位，并能够识别出其篡改类型。整体而言，实验结果验证了本方法在多种篡改类型下的优越性能，进一步说明该模型具有良好的泛化能力，适用于复杂多样的篡改场景。

4 结论

本文提出了一种融合多注意力机制的图像篡改检测与识别方法，解决了现有方法在多种篡改类型下检测准确性和泛化能力不足的问题。通过结合通道注意力机制与空间注意力机制，本方法能够充分利用图像中的局部与全局信息，在多种篡改场景下稳定，精准地定位篡改区域，同时能够识别篡改的具体类型。通过在公共数据集上实验，验证了本方法的有效性，特别是在大多数数据集上取得了当前最优的检测成绩。

然而，本文的方法仍然存在一些不足之处。首先，在 NIST16 数据集上的表现略逊于部分方法，表明模型在处理某些特定场景或高频信息时的能力尚有提升空间。其次，在模型的效率上，由于含有多个 Transformer 模块，模型参数量较大，训练和预测所需的计算资源较多，导致模型在进行训练时需要消耗大量时间，特别是面对大规模数据集或实时应用时，如何在保证检测精度的同时提高计算效率，是未来需要进一步研究的问题。

参考文献：

- [1] 杨滨. 图像克隆拼接篡改盲取证技术研究 [D]. 长沙: 湖南大学, 2014.
- [2] 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. New York: ACM, 2016: 5-10.
- [3] ZHOU P, HAN X T, MORARIU V I, et al. Learning rich features for image manipulation detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 1053-1061.

- [4] BAPPY J H, SIMONS C, NATARAJ L, et al. Hybrid LSTM and encoder–decoder architecture for detection of image forgeries[J]. IEEE transactions on image processing, 2019, 28(7): 3286-3300.
- [5] MAZAHARI G, MITHUN N C, BAPPY J H, et al. A Skip Connection Architecture for Localization of Image Manipulations[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops 2019.Piscataway: IEEE, 2019: 119-129.
- [6] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway:IEEE, 2018: 7132-7141.
- [7] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Computer Vision–ECCV 2018. Berlin: Springer, 2018: 3-19.
- [8] LIU C G, CHEN X, XU T, et al. HFDA-Net: utilizing high-frequency feature and dual-attention to enhance image manipulation detection and localization[C]//Artificial Neural Networks and Machine Learning – ICANN 2024. Cham: Springer, 2024: 304-319.
- [9] LIU X H, LIU Y J, CHEN J, et al. PSCC-Net: progressive spatio-channel correlation network for image manipulation detection and localization[J]. IEEE transactions on circuits and systems for video technology, 2022, 32(11): 7505-7517.
- [10] ZHANG Z F, LI M Y, CHANG M C. A new benchmark and model for challenging image manipulation detection[C]// Proceedings of the Thirty-Eighth AAAI Conference on Artificial Intelligence and Thirty-Sixth Conference on Innovative Applications of Artificial Intelligence and Fourteenth Symposium on Educational Advances in Artificial Intelligence. Palo Alto: AAAI Press, 2024: 7405-7413.
- [11] ROY A G, NAVAB N, WACHINGER C. Concurrent spatial and channel squeeze & excitation in fully convolutional networks[C]//2018 Medical Image Computing and Computer Assisted Intervention. Berlin: Springer, 2018: 421-429.
- [12] 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.
- [13] HSU Y F, CHANG S F. Detecting image splicing using geometry invariants and camera characteristics consistency[C]//2006 IEEE International Conference on Multimedia and Expo.Piscataway:IEEE,2006: 549-552.
- [14] DONG J, WANG W, TAN T N. CASIA image tampering detection evaluation database[C]//2013 IEEE China Summit and International Conference on Signal and Information Processing. Piscataway:IEEE, 2013: 422-426.
- [15] SUDIATMIKA I B K, RAHMAN F, TRISNO T, et al. Image forgery detection using error level analysis and deep learning[J]. Telecommunication computing electronics and control, 2019, 17(2): 653-659.
- [16] MAHDIAN B, SAIC S. Using noise inconsistencies for blind image forensics[J]. Image and vision computing, 2009, 27(10): 1497-1503.
- [17] POPESCU A C, FARID H. Exposing digital forgeries in color filter array interpolated images[J]. IEEE transactions on signal processing, 2005, 53(10): 3948-3959.
- [18] 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. Piscataway:IEEE,2019: 9543-9552.
- [19] WU H W, ZHOU J T. IID-Net: image inpainting detection network via neural architecture search and attention[J]. IEEE transactions on circuits and Systems for video technology, 2021, 32(3): 1172-1185.
- [20] RAO Y, NI J Q. A deep learning approach to detection of splicing and copy-move forgeries in images[C]//2016 IEEE International Workshop on Information Forensics and Security (WIFS). Piscataway:IEEE, 2016: 1-6.
- [21] HEBBAR N K, KUNTE A S. Image forgery localization using U-Net based architecture and error level analysis[C]//2021 3rd International Conference on Advances in Computing, Communication Control and Networking (ICAC3N). Piscataway: IEEE, 2021: 1992-1996.

【作者简介】

李帅(1999—),男,河南鹤壁人,硕士研究生,研究方向:计算机视觉。

吴宗胜(1974—),男,广西梧州人,博士,副教授,研究方向:计算机视觉。

薛茹(1974—),女,陕西西安人,博士,教授,研究方向:数字图像处理。

马毓洋(2001—),女,陕西咸阳人,硕士研究生,研究方向:网络空间安全。

泽仁玉珍(1999—),女,西藏昌都人,硕士研究生,研究方向:网络空间安全。

(收稿日期: 2024-12-16 修回日期: 2025-04-29)