DOI:10.11918/202412014

融合 CBAM 的双向递归门控残差图像 Copy-Move 篡改检测

马 颖,伊力哈木·亚尔买买提,侯雪扬,程铄棋

(新疆大学 电气工程学院,乌鲁木齐 830017)

摘 要:为解决卷积神经网络的图像 Copy-Move 篡改检测网络中对小尺度篡改的检测不敏感及细节敏感性低的问题,提出融合卷积块注意力模块(convolutional block attention module,CBAM)的双向递归门控残差图像 Copy-Move 篡改检测网络。通过两种残差块构建编码器-解码器结构,使网络对小尺度篡改区域识别更加敏感;在此基础上,引入 CBAM 注意力机制,以增强特征表达能力,自适应地聚焦于关键的篡改区域;融合双向门控循环单元(bidirectional gated recurrent unit,Bi-GRU),交互前后向信息,耦合宏微观特征,建模长距离依赖;最后,通过跳跃连接机制,促进多尺度特征融合,强化网络的识别能力。在公共数据集 CASIA2.0 和 CoMoFoD 上进行实验,结果表明:本文所提网络在 CASIA2.0 数据集中的准确率和 F_1 分数分别达到95.78%和82.08%,验证了其在小尺度篡改检测方面的有效性;在 CoMoFoD 数据集中的准确率和 F_1 分数分别达到 92.36%和55.72%,进一步证实了其对复杂篡改场景的泛化能力。所提网络能准确实现对 Copy-Move 篡改图像的检测,可为篡改检测领域的后续研究提供技术支撑。

关键词:图像篡改检测;细节敏感度;注意力机制;双向门控循环单元;多尺度特征融合

中图分类号:TP391 **文献标志码**:A **文章编号**:0367-6234(2026)09-0154-09

Fusion of CBAM with bidirectional recurrent gated residual network for image Copy-Move forgery detection

Ma Ying, Yilihamu Yaermaimaiti, Hou Xueyang, Cheng Shuoqi

(School of Electrical Engineering, Xinjiang University, Urumqi 830017, China)

Abstract: To address the issue of insensitivity to small-scale tampering detection and low detail sensitivity in convolutional neural networks for image Copy-Move forgery detection, a bidirectional recurrent gated residual image Copy-Move forgery detection network incorporating the convolutional block attention module (CBAM) is proposed. An encoder-decoder structure is constructed using two types of residual blocks to enhance the network's sensitivity to identify small-scale tampered regions. Building on this, the CBAM attention mechanism is introduced to strengthen feature representation capabilities and adaptively focus on critical tampered regions. Bidirectional gated recurrent units (Bi-GRU) are incorporated to interact forward and backward information, couple macro and micro features, and model long-range dependencies. Finally, a skip connection mechanism is employed to facilitate multi-scale feature fusion and strengthen the network's recognition capability. Experiments are conducted on the public datasets CASIA2.0 and CoMoFoD. On the CASIA2.0 dataset, the proposed network achieves an accuracy of 95.78% and an F_1-score of 82.08%, validating its effectiveness in small-scale tampered region detection. On the CoMoFoD dataset, it achieves an accuracy of 92.36% and an F_1-score of 55.72%, further confirming its generalization capability for complex tampering scenarios. The proposed network can accurately detect Copy-Move forged images, providing technical support for subsequent research in the field of tampering detection.

Keywords: image forgery detection; detail sensitivity; attention mechanism; bidirectional gated recurrent unit; multi-scale feature fusion

在信息爆炸的数字化时代,图像以其直观、传递复杂信息迅速等特点,广泛应用于各个领域,深刻影响着人类生活、文化和社会发展。然而,随着图像处理软件的普及,图像篡改已变得常见,若未及时识别,可能对新闻、刑侦等领域造成严重后果。因此,图像取证在现实中具有重要意义[1]。

收稿日期:2024-12-04;**录用日期**:2025-01-07;**网络首发日期**:2025-06-25
网络首发地址:https://link.cnki.net/urlid/23.1235.t.20250624.1659.010
基金项目:国家自然科学基金(62362063);新疆维吾尔自治区自然科学基金(2023D01C21)
作者简介:马 颖(1994—),女,硕士研究生;伊力哈木·亚尔买买提(1978—),男,教授,硕士生导师
通信作者:伊力哈木·亚尔买买提,65891080@qq.com

数字图像取证是信息安全的重要领域，主要分为主动取证技术和被动取证技术。主动取证技术通常需要在图像中预先嵌入水印、指纹等先验信息，因此在实际应用中存在较大的局限性。与之相比，被动取证技术通过分析图像本身的内容来判断其是否被篡改，因而具有更广阔的应用前景，也是当前图像取证研究的主流方向[2]。图像被动取证技术主要包括图像篡改检测、图像源识别和操作历史跟踪，其中，图像篡改检测是被动取证技术研究重点之一[3]。图像 Copy-Move 篡改是指将图像中的一部分内容复制，并经过旋转、缩放等处理后粘贴至同一图像的其他区域。由于篡改内容来源于图像本身，且许多重要信息高度相似，使得与其他类型的图像篡改相比，Copy-Move 篡改更难以检测。

近年来，图像篡改检测技术取得了显著进展。Kwon 等[4]提出了采用离散余弦变换（discrete cosine transform，DCT）系数定位图像操作的卷积神经网络（convolutional neural network，CNN）。Dong 等[5]提出了红绿蓝色彩流和噪声流的多视点特征学习网络，该网络通过多流网络架构协同分析输入图像的篡改边界伪影和噪声视角信息，同时改进了提取边界的卷积网络，从而获得了优异的篡改检测效果。Islam 等[6]提出了用于图像 Copy-Move 篡改检测与定位的双阶注意力生成对抗网络（dual-order attentive generative adversarial network，DOA-GAN），该网络显著提升了 Copy-Move 伪造检测的精度。Gu 等[7]提出了一种基于 DCT 的多任务学习图像篡改检测方法，多任务学习能同时学习多个相关任务，显著提升了网络的泛化能力。Thakur 等[8]提出了一种深度卷积神经网络（deep convolutional neural networks，DCNN），该网络将图像分为伪造类别和真实类别，而且其能够提取图像的全局特征，利用训练后的网络权重对图像进行分类，从而判断图像是否存在篡改。Wu 等[9]设计了 BusterNet 端到端网络，该网络采用双分支并行架构，其中，视觉伪影检测分支负责定位图像中潜在的篡改操作痕迹区域（如模糊、重压缩伪影等），而视觉相似性匹配分支则专门用于识别并匹配 Copy-Move 篡改区域中的相似内容。然而，上述深度学习网络在多尺度特征提取方面存在不足，视野较为单一，导致以往网络对小尺度篡改的检测不敏感，从而影响了检测的全面性[10]。此外，这些网络容易受到针对性攻击，例如，简单地添加噪声或干扰信息即可能导致网络输出错误结果，暴露出其鲁棒性不足的问题。

针对上述不足，本文提出一种融合卷积块注意力模块（convolutional block attention module，CBAM）的双向递归门控残差图像 Copy-Move 篡改检测网络。该网络结合局部空间注意力信息与全局时序依赖信息，采用 CBAM 增强的自定义残差块提升多层次特征提取能力，并引入双向门控循环单元（bidirectional gated recurrent unit，Bi-GRU）跨尺度时序建模机制与 U-Net 跳跃连接（skip connections）以实现精准的 Copy-Move 篡改检测。通过实验验证本文所提网络的有效性，旨在为图像 Copy-Move 篡改检测提供新的思路。

1　相关理论

1.1　SegNet 网络[11]

SegNet 网络结构包括编码器和解码器两部分，如图 1 所示。

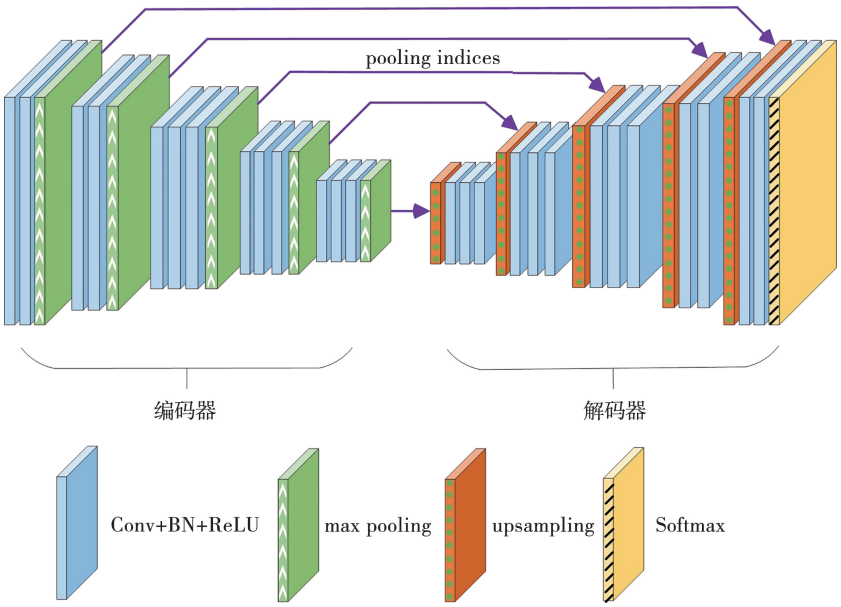


图 1　SegNet 网络结构

Fig. 1　SegNet network structure

SegNet 编码器的结构与 VGG16(visual geometry group 16-layer network)相似,单个模块堆叠 2 ~ 3 个卷积单元,各单元依次含卷积层(convolution,Conv)、批量归一化(batch normalization,BN)、ReLU 激活函数,模块间以最大池化(max pooling)串联;解码器是由与编码器对称的卷积层、上采样(upsampling)和 Softmax 分类器构成。

在编码阶段,通过卷积层逐层提取局部空间特征,利用最大池化操作在降低图像分辨率的同时保留池化位置索引(pooling indices)。随着卷积和池化操作的逐层进行,图像分辨率不断降低,特征图逐渐压缩并蕴含更丰富的高层语义信息。在解码阶段,网络将编码器保存的池化索引作为空间引导,通过非对称反池化操作实现特征图的精准上采样。每次上采样后,通过对称的卷积层逐步细化特征,在扩大感受野的同时完成深层语义融合。这种机制不仅能优化梯度传播,还能有效增强边缘特征,抑制背景噪声,提升篡改检测任务的精度和效率。最终,解码器输出的高分辨率特征图经由逐像素的 Softmax 分类器进行密集预测,生成与输入图像空间尺寸一致的语义分割结果。

SegNet 网络能高效地执行全像素图像分割,在保持计算效率的同时精确恢复空间信息[11]。具体而言,该网络通过编码器和解码器的协同作用,最终经过逐像素的 Softmax 分类器输出精细的分割结果,确保每个像素均得到准确分类。

尽管 SegNet 在图像检测中能够有效提取图像的高级特征,并在较大规模图像处理任务中具有一定的优势,即能够快速识别并区分不同物体或区域,但在一些精细分割任务中的准确度不如主流篡改检测网络。基于此,本文参考 SegNet 网络的编码器–解码器架构,并针对其图像篡改检测能力的不足进行改进。

1.2 本文网络整体结构

本文提出的融合 CBAM 的双向递归门控残差图像 Copy-Move 篡改检测网络结构如图 2 所示。该网络采用编码器–解码器结构,并设计两种残差块:基础模块 a 型(basic block a)和基础模块 b 型(basic block b)。两种残差块均基于典型的残差块,并在其基础上添加了额外的卷积层和 CBAM 模块,从而使得特征提取和表示更加丰富且有效。编码器借鉴了 SegNet 的结构设计,由两个 basic block a 和 3 个 basic block b 依次堆叠组成,并在每个 basic block a 或 basic block b 之后加入 1 次 2 × 2 最大池化操作;逐步增加通道数,依次为 64、64、128、256 和 512。解码器则对称地由 3 个 basic block b 和两个 basic block a 组成,并在每个 basic block a 或 basic block b 之前加入 1 次上采样操作;逐层减少通道数,依次为 256、128、64、64,最终输出 1 个通道。

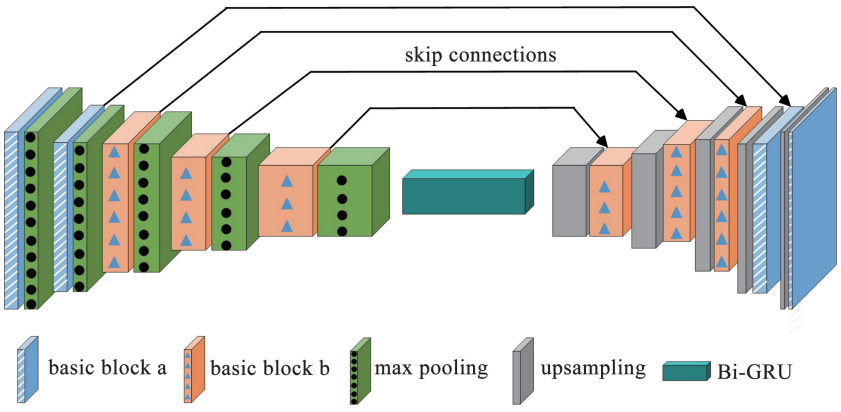


图 2 融合 CBAM 的双向递归门控残差网络

Fig. 2 Bidirectional recursive gating residual network fused with CBAM

编码阶段先通过两个 basic block a 捕获细节特征,再由 3 个 basic block b 提取高级语义;解码阶段则逆向执行,先由 basic block b 重建全局结构,再由 basic block a 精修局部细节,形成“细节—全局—全局—细节”的特征处理闭环。两者结合,使网络在处理复杂特征时既保持细节精度,又增强全局信息表达能力,最终提高图像处理的精度和细节识别能力。在编码器和解码器之间,融入了 Bi-GRU,进一步提升特征的时序建模能力。

此外,借鉴 U-Net 网络的跳跃连接(skip connections)机制,从编码器的第 2 个残差块开始,通过通道拼接的方式将生成的特征图直接传递至解码器中对应层级的特征图,从而充分融合多尺度特征信息,提升网络的分割精度。

1.3 残差块

以往的篡改检测网络通常对小尺度篡改的检测

不够敏感，限制了检测的全面性。为此，本文设计了两种残差块，以提高网络对小尺度篡改的识别能力，进而增强检测的全面性。第 1 种残差块为 basic block a，主分支包括两个 3 × 3Conv，卷积层卷积步长（s）为 1，特征图边缘添加的边界（p）为 1。每个卷积层后接 BN 和 ReLU 激活函数。旁路分支通过 1 个步长为 1 的 1 × 1Conv 连接 BN 以匹配主分支的维度和特征表达。主分支输出与旁路分支输出进行逐元素相加，随后经过 CBAM 进一步提取重要特征，最终通过 ReLU 激活函数输出。第 2 种残差块为 basic block b。该模块是在 basic block a 的主分支基础上增加了 1 次 3 × 3Conv 及 BN 和 ReLU 激活函数。两种残差模块在保留残差网络优点的基础上，通过引入 CBAM 提升特征选择能力，使得网络在处理细节区域时更加智能化，自适应地聚焦关键特征，从而增强细节区域的识别效果。两种残差块的结构如图 3 和图 4 所示。

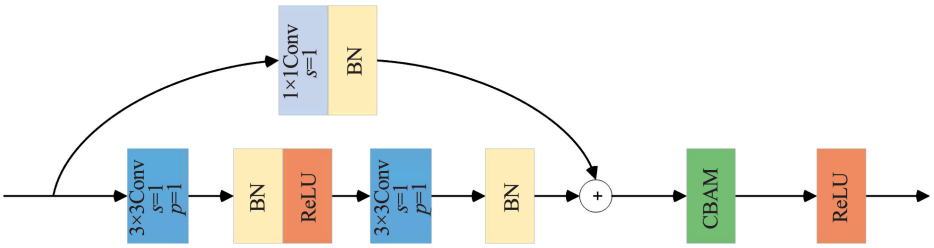


图 3　Basic block a 结构

Fig. 3　Structure of basic block a

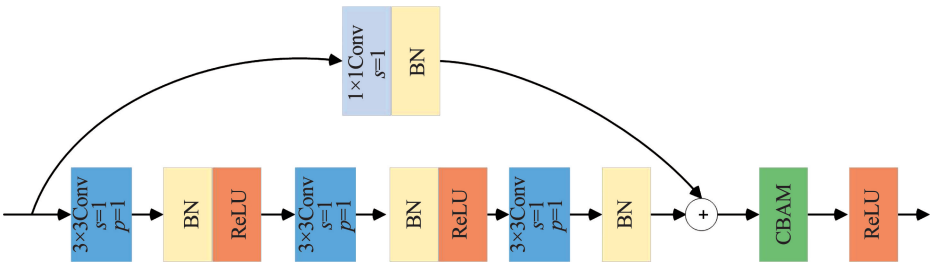


图 4　Basic block b 结构

Fig. 4　Structure of basic block b

本文网络采用 basic block a 和 basic block b 两种残差块的协同设计，即 basic block a 采用浅层结构专注提取局部细节特征，而 basic block b 通过增加卷积深度强化全局上下文建模能力，两者结构互补，且均采用残差连接以确保梯度稳定传播，提升网络性能。同时，利用 CBAM 的双重注意力机制，网络可以自动识别并强化篡改相关的特征响应，提升定位和识别能力。

1.4　CBAM

CBAM 结构如图 5 所示。该模块主要由通道注意力模块（channel attention module）和空间注意力模块（spatial attention module）两部分组成[12]。通过在通道和空间两个维度上进行注意力加权，CBAM 使 CNN 能够自适应聚焦图像中的关键特征，同时抑制不重要的信息，从而提升特征提取能力和网络整体性能。

给定一个中间特征映射 $\boldsymbol{F} \in \mathbf{R}^{C\times H\times W}$ 作为输入，CBAM 依次推导出一维通道注意力映射 $\boldsymbol{M}_{\mathrm{ch}} \in \mathbf{R}^{C\times 1\times 1}$ 和二维空间注意力映射 $\boldsymbol{M}_{\mathrm{sp}} \in \mathbf{R}^{1\times H\times W}$，其中 H、W、C 分别表示特征图的高度、宽度、通道数。CBAM 过程表达式为

$$\begin{cases} \boldsymbol{F}' = \boldsymbol{M}_{\mathrm{ch}}(\boldsymbol{F}) \otimes \boldsymbol{F} \\ \boldsymbol{F}'' = \boldsymbol{M}_{\mathrm{sp}}(\boldsymbol{F}') \otimes \boldsymbol{F}' \end{cases} \tag{1}$$

式中：$\boldsymbol{F}'$ 为经过通道注意力模块后的输出特征，$\otimes$ 为逐元素乘法，$\boldsymbol{F}''$ 为最终的精炼输出。

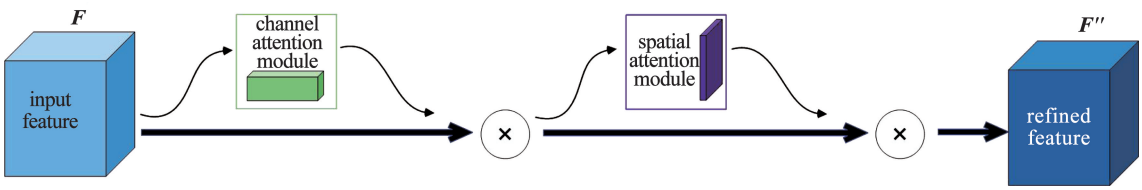


图 5　CBAM 结构

Fig. 5　Structure of CBAM

1.5 Bi-GRU

门控循环单元(gated recurrent unit,GRU)是一种递归神经网络(recurrent neural network,RNN)的变体,与长短期记忆网络(long short-term memory,LSTM)相比,具有更少的参数和更低的计算复杂度[13]。GRU 通过门控单元有效地控制信息流动,在处理长期依赖关系时表现出更优的性能。GRU 结构如图 6 所示,其中㊀为向量元素减法,⊕为矩阵相加。每个 GRU 单元通过更新门和重置门控制信息流动。更新门决定是否更新当前状态,而重置门则决定如何结合过去的状态和当前的输入,从而有效解决传统 RNN 中的长距离依赖问题,使得网络在处理长序列时表现出更好的效果。

GRU 过程表达式为

$$\boldsymbol{R}_t=\sigma(\boldsymbol{X}_t\boldsymbol{W}_{\mathrm{xr}}+\boldsymbol{H}_{t-1}\boldsymbol{W}_{\mathrm{hr}}+\boldsymbol{b}_{\mathrm{r}}) \tag{2}$$

$$\boldsymbol{Z}_t=\sigma(\boldsymbol{X}_t\boldsymbol{W}_{\mathrm{xz}}+\boldsymbol{H}_{t-1}\boldsymbol{W}_{\mathrm{hz}}+\boldsymbol{b}_{\mathrm{z}}) \tag{3}$$

$$\tilde{\boldsymbol{H}}_t=\tanh(\boldsymbol{X}_t\boldsymbol{W}_{\mathrm{xh}}+(\boldsymbol{R}_t\otimes\boldsymbol{H}_{t-1})\boldsymbol{W}_{\mathrm{hh}}+\boldsymbol{b}_{\mathrm{h}}) \tag{4}$$

$$\boldsymbol{H}_t=\boldsymbol{Z}_t\otimes\boldsymbol{H}_{t-1}+(1-\boldsymbol{Z}_t)\otimes\tilde{\boldsymbol{H}}_t \tag{5}$$

式中:$\boldsymbol{X}_t$ 为 t 时刻位置输入信息,$\sigma(\cdot)$为 Sigmoid 激活函数,$\boldsymbol{R}_t$ 为重置门,$\boldsymbol{Z}_t$ 为更新门,$\boldsymbol{H}_t$、$\boldsymbol{H}_{t-1}$分别为 t、$t-1$ 时刻的隐藏状态,$\tilde{\boldsymbol{H}}_t$ 为候选隐藏状态,$\boldsymbol{b}_{\mathrm{r}}$、$\boldsymbol{b}_{\mathrm{z}}$ 分别为重置门、更新门的偏置项,$\boldsymbol{b}_{\mathrm{h}}$ 为候选隐藏状态的偏置项,$\boldsymbol{W}_{\mathrm{xr}}$、$\boldsymbol{W}_{\mathrm{xz}}$、$\boldsymbol{W}_{\mathrm{xh}}$为与输入$\boldsymbol{X}_t$ 相关的权重矩阵,$\boldsymbol{W}_{\mathrm{hr}}$、$\boldsymbol{W}_{\mathrm{hz}}$、$\boldsymbol{W}_{\mathrm{hh}}$为与隐藏状态$\boldsymbol{H}_{t-1}$相关的权重矩阵。

Bi-GRU 由两个方向的 GRU 网络组成,一个用于前向处理时间序列,另一个用于后向处理。通过同时捕捉过去和未来的信息,Bi-GRU 能够更全面地建模时序关系。Bi-GRU 结构如图 7 所示,其中,$\boldsymbol{X}_1,\cdots,\boldsymbol{X}_n$ 为输入序列中的各个时间步的数据,$\boldsymbol{y}_1,\cdots,\boldsymbol{y}_m$ 为输出序列对应的预测结果,$\boldsymbol{W}_1$、$\boldsymbol{W}_2$、$\boldsymbol{W}_3$和$\boldsymbol{W}_4$、$\boldsymbol{W}_5$、$\boldsymbol{W}_6$ 分别为前向 GRU 和后向 GRU 对应的更新门、重置门、候选隐藏状态的权重矩阵。

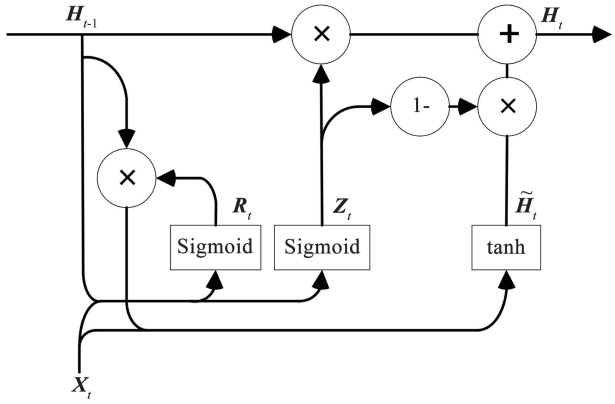


图 6 GRU 结构

Fig. 6 Structure of GRU

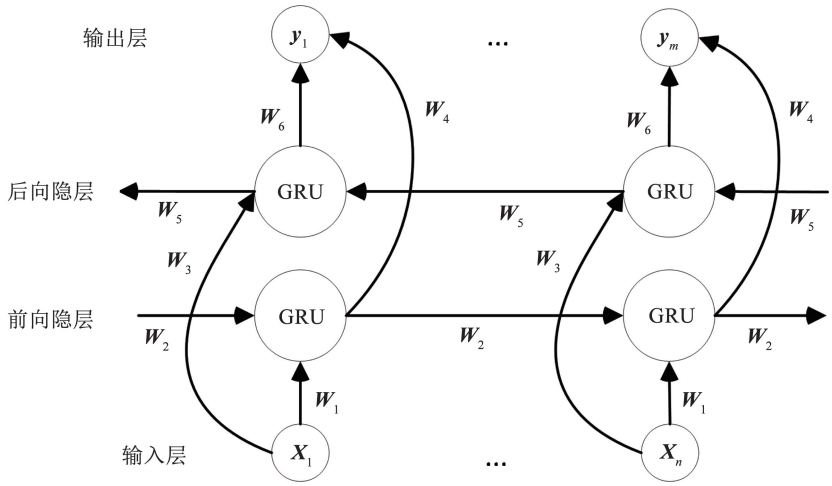


图 7 Bi-GRU 结构

Fig. 7 Structure of Bi-GRU

2 实验结果及分析

2.1 数据集

本文在公共数据集 CASIA2.0 上进行训练、验证、测试,以评估网络的性能。此外,为进一步验证所提出网络的泛化能力和适应性,还在另一个公共数据集 CoMoFoD 上进行了测试。在两个数据集上进行实验,可以更全面地了解网络在不同篡改场景下的有效性和鲁棒性,从而验证其在实际应用中的潜在适用性。实验前,所有输入图像的尺寸均统一调整像素为 256 × 256。数据集分类见表 1,其中 Copy-Move 表示篡改数据集,AU 表示未篡改原图数据集。

2.2 实验参数

实验采用 PyTorch 深度学习框架,在 Python 3.11 的 Windows 11 系统环境中进行,显卡为 NVIDIA

GeForce RTX 4060 Laptop GPU。训练轮数设置为 150，批次大小为 32，学习率为 0.001。

表 1　数据集分类

Tab. 1　Dataset classification

数据集	类别	训练集	验证集	测试集
CASIA2.0	Copy-Move	1 062	120	131
	AU	400	104	114
CoMoFoD	Copy-Move			200
	AU			

2.3　评价指标

在图像 Copy-Move 篡改检测性能评估中，选择合适的评价指标至关重要。本文采用准确率（A）、精确率（P）、召回率（R）和 F_1 分数（F_1）作为评价指标，以全面衡量模型的分类性能。

A 是衡量图像级别最为常用的评估方式之一，其公式为

$$A=\frac{T_{(P)}+T_{(N)}}{T_{(P)}+T_{(N)}+F_{(P)}+F_{(N)}} \tag{6}$$

式中：$T_{(P)}$ 为 Copy-Move 篡改的图像样本被正确识别的数量，$F_{(P)}$ 为真实图像样本被识别为篡改图像的数量，$F_{(N)}$ 为 Copy-Move 篡改的图像样本被识别为真实图像样本的数量，$T_{(N)}$ 为真实图像样本被识别正确的数量。

F_1 视为衡量像素级二分类问题的一个重要指标，是 P 和 R 的加权平均。三者的计算式分别为

$$P=\frac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{P}}} \tag{7}$$

$$R=\frac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{N}}} \tag{8}$$

$$F_1=2\times\frac{P\times R}{P+R} \tag{9}$$

式中：T_{P} 为被正确检测为篡改区域的像素值，F_{P} 为原始区域检测为篡改区域的像素值，F_{N} 为篡改区域检测为原始区域的像素值，T_{N} 为被正确检测为原始区域的像素值。

2.4　消融实验

为验证 CBAM、GRU、跳跃连接对本文所提网络的作用，在 CASIA2.0 上进行消融实验，结果见表 2。其中 Ours-CBAM 表示本文所提网络去掉 CBAM 模块；Ours-CBAM-(Bi-GRU) + RNN 表示本文所提网络去掉 CBAM 模块和 Bi-GRU 模块后，再融入 RNN 模块；Ours-CBAM-skip connections 表示本文所提网络去掉 CBAM 模块和跳跃连接。

由表 2 可以看出：相较于 SegNet 网络，本文所提网络的 A、P、R、F_1 分别提升了 3.93%、20.35%、13.61%、16.69%；对比第 5 行和第 4 行，CBAM 使得所提网络的 A、P、R、F_1 分别提升了 0.13%、1.02%、0.30%、0.61%；对比第 4 行和第 3 行，双向 GRU 门控结构使得网络的 A、P、R、F_1 分别提升了 0.45%、5.17%、1.99%、3.37%；对比第 4 行和第 2 行，跳跃连接使得网络的 A、P、R、F_1 分别提升了 0.50%、3.22%、1.42%、2.19%。表明各个模块的引入均显著提升了整体网络的性能，验证了改进方案的有效性。

表 2　消融实验

Tab. 2　Ablation experiment　　%

网络	A	P	R	F_1
SegNet	91.85	64.93	65.86	65.39
Ours-CBAM-skip connections	95.15	81.04	77.75	79.28
Ours-CBAM-(Bi-GRU) + RNN	95.20	79.09	77.18	78.10
Ours-CBAM	95.65	84.26	79.17	81.47
本文网络	**95.78**	**85.28**	**79.47**	**82.08**

2.5　对比实验

为验证本文所提网络的检测效果，将所提网络与 SegNet、ManTra-Net[14]、ObjectFormer[15]、FCN[16]、DeepLab V3+[17]、U-Net[18]、RCG-UNet（在 U-Net 网络基础上融入了残差、CBAM 和 Bi-GRU，各模块的嵌入位置与本文网络一致，因网络是由 U-Net + Residual + CBAM + Bi-GRU 构成，故本文将该网络命名为 RCG-UNet）、RRU-Net[19] 深度学习网络在 CASIA2.0 和 CoMoFoD 数据集上进行对比。所有网络的训练集、验证集、测试集均相同，对比结果见表 3。

由表 3 可以看出：RCG-UNet 在 CASIA2.0 数据集上的 A 略高于本文所提网络，说明其在未篡改图像的识别方面更为准确，但在篡改图像的识别能力方面略显不足；SegNet 在 CoMoFoD 数据集上的 P 相比本文所提网络高 40.69%，可能是较高的决策阈值有效地控制了假阳性，但这也导致了 R 和 F_1 的下降，使得 SegNet 对篡改图像的误检较多，从而影响了整体性能。综合所有指标，本文所提网络明显优于现有主流深度学习网络。原因是编码器–解码器结构解决了传统网络在特征提取过程中存在的效率低下和表征能力不足的问题，实现了对图像关键特征更精准的捕捉；跳跃连接机制解决了以往深层网络中特征信息逐层衰减的问题，确保了多尺度特征的充分融合与互补；Bi-GRU 不仅弥补了传统 CNN 在时序特征建模方面的固有局限，还增强了图像区域间的空间关联建模能力，从而提升了网络对篡改区域的识别精度。

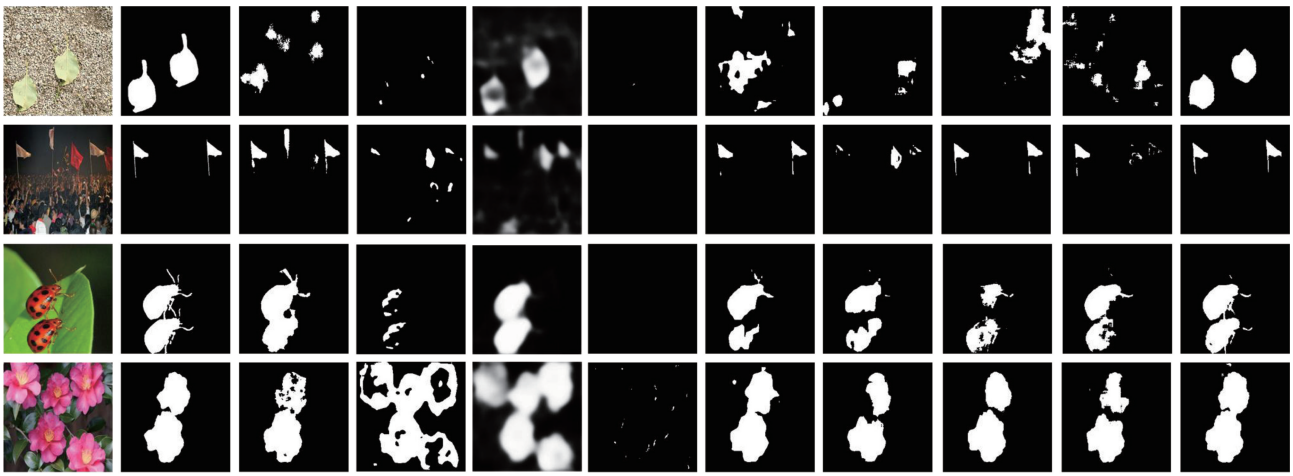
表 3 对比实验结果

Tab. 3 Comparative experimental results

网络	CASIA2.0				CoMoFoD			
	A/%	P/%	R/%	F_1/%	A/%	P/%	R/%	F_1/%
SegNet	91.85	64.93	65.86	65.39	91.93	**99.59**	0.39	0.78
ManTra-Net	87.42	16.42	27.97	20.69	62.62	7.41	50.41	12.93
ObjectFormer	87.20	41.20	34.70	36.30	88.70	16.40	36.00	20.30
FCN	93.92	64.65	50.08	48.60	92.29	46.15	50.00	48.00
DeepLab V3+	94.30	79.21	69.23	72.99	91.06	51.68	50.45	49.81
U-Net	92.73	57.58	52.75	53.50	89.97	68.60	52.29	52.06
RCG-UNet	**95.90**	82.91	78.00	80.22	88.86	47.85	48.95	48.20
RRU-Net	95.04	81.91	70.41	74.68	92.34	54.30	51.24	51.21
本文网络	95.78	**85.28**	**79.47**	**82.08**	**92.36**	58.90	**54.55**	**55.72**

为直观展示本文所提网络对 Copy-Move 篡改图像的检测能力，图 8 给出了篡改图像的检测结果与真实蒙版的可视化效果对比。

由图 8 可以看出：本文所提网络在 Copy-Move 篡改检测任务中表现出明显优势，不仅能够准确识别并定位 Copy-Move 篡改区域的空间位置，避免了其他网络中常见的区域误匹配和边界模糊问题，而且在 Copy-Move 篡改区域形状还原度上也表现优异，能够更完整地保留 Copy-Move 篡改区域的几何特征和边缘细节；与之相较，其他对比网络在检测结果中普遍存在对 Copy-Move 篡改区域匹配不准确、边界不连续或内部空洞等问题。说明本文所提网络在复杂场景下的 Copy-Move 篡改检测任务中具有更高的检测能力。



(a) 篡改图 (b) 真实蒙版 (c) SegNet (d) ManTra-Net (e) ObjectFormer (f) FCN (g) DeepLab V3+ (h) U-Net (i) RCG-UNet (j) RRU-Net (k) 本文网络

图 8 部分篡改图像不同网络可视化效果

Fig. 8 Visualization effects of partial tampered images under different networks

2.6 抗干扰测试

为验证本文所提网络的抗干扰能力，对 9 种网络在 CASIA2.0 数据集上分别进行了椒盐噪声干扰测试（椒盐噪声密度分别为 0.001、0.002、0.004、0.006、0.008、0.010）及高斯低通模糊干扰测试（滤波器分别为 3×3(3)、5×5(5)、7×7(7)）。测试结果如图 9 和图 10 所示。

由图 9 可以看出，本文所提网络在面对不同密度椒盐噪声干扰攻击时，仍然保持了较强的鲁棒性。无论噪声密度如何变化，所提网络均能有效抵抗各种噪声干扰，展现出了在图像 Copy-Move 篡改检测任务中的稳定性和高效性。

由图 10 可以看出：在经受高斯低通模糊攻击干扰条件下，各对比网络的检测性能均出现不同程度的波动；相比之下，本文所提网络在 P、R、F_1 上均保持稳定，展现出优异的抗模糊鲁棒性。这一特性使得网络在面对经过模糊处理的篡改图像时，仍能有效完成 Copy-Move 区域的检测与定位任务。

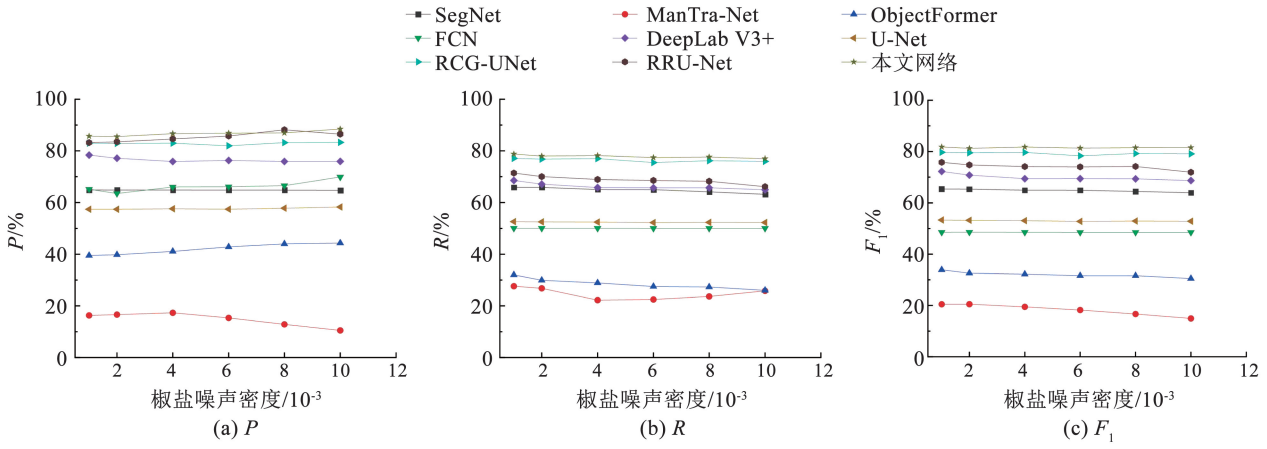


图 9　不同网络面对椒盐噪声攻击的结果

Fig. 9　Results of different networks facing salt-and-pepper noise attacks

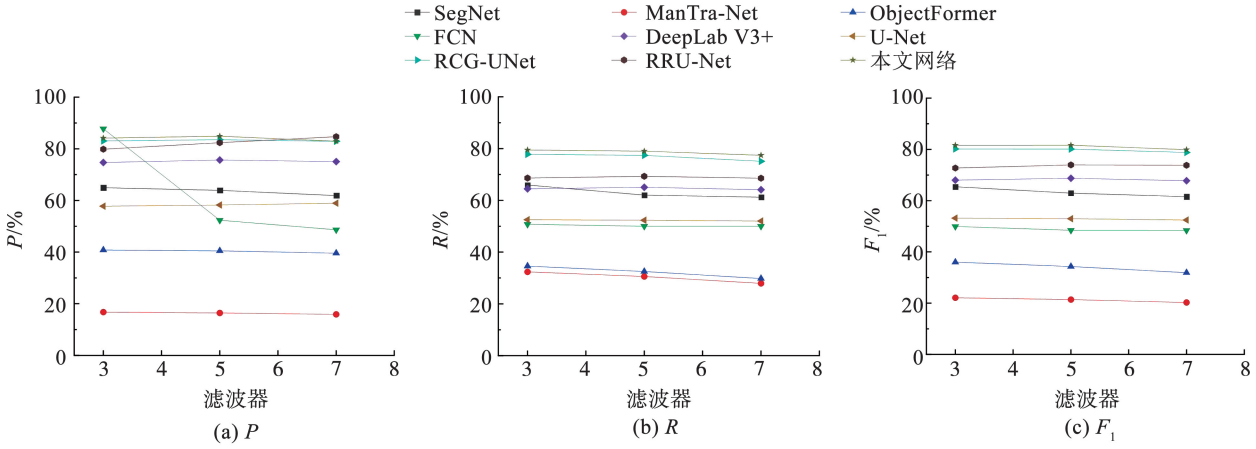


图 10　不同网络面对高斯低通模糊攻击的结果

Fig. 10　Results of different networks facing Gaussian low-pass fuzzy attacks

3　结　论

1)本文提出了一种融合 CBAM 的双向递归门控残差检测网络,该网络采用两种残差块构建编码器–解码器结构,解决了传统网络在小尺度检测中的不足。CBAM 通过通道和空间注意力机制自适应聚焦重要特征,增强了对篡改区域的识别能力,使网络 F_1 分数提升 0.61%。

2)在编码器和解码器之间融入了双向 GRU 单元,强化时序和上下文建模,增强了网络对篡改区域的感知能力,使网络能更全面和准确地进行篡改区域的检测。跳跃连接机制将编码器中每个残差块的特征图通过通道拼接的方式传递至解码器对应层级。多尺度特征融合策略进一步增强了网络的细节捕捉能力,提高了分割精度。Bi-GRU、跳跃连接可分别使网络的 F_1 分数提升 3.37%、2.19%。

3)在 CASIA2.0 数据集上,本文所提网络在多项性能指标上均优于 SegNet 基准网络及当前主流深度学习网络。在 CoMoFoD 数据集上,本文所提网络的 P 相较于借鉴的 SegNet 低了 40.69%,但综合考虑 A、P、R、F_1 指标,所提网络的整体性能明显优于 SegNet。所提网络在面对不同攻击时展现出了良好的鲁棒性和稳定性,以及在各种场景下的适应能力。

4)尽管本文所提网络在多个指标上取得了较好的表现,但其泛化性仍有提升空间。未来将在网络结构优化方面进一步改进,以增强网络的泛化能力,进一步提升图像识别与检测的整体性能。

参考文献

[1]王立召. 基于超像素与四元数的彩色图像复制粘贴篡改检测研究[D]. 兰州: 西北师范大学, 2020:1
Wang Lizhao. Research on color image Copy-Move forgery detection based on superpixel and quaternion [D]. Lanzhou: Northwest Normal University, 2020: 1. DOI:10.27410/d.cnki.gxbfu.2020.001737

[2]Lin Xiang, Li Jianhua, Wang Shilin, et al. Recent advances in passive digital image security forensics: a brief review [J]. Engineering, 2018, 4(1): 29. DOI:10.1016/j.eng.2018.02.008

[3]蒋春桃. 基于被动取证的同/异源图像拼接检测方法研究[D].

西安: 西安理工大学, 2020: 3
Jiang Chuntao. Research on passive-forensics-based detection method for homologous/heterologous image splicing [D]. Xi′an: Xi′an University of Technology, 2020: 3. DOI:10.27398/d.cnki.gxalu.2020.000790

[4] Kwon M J, Nam S H, Yu I J, et al. Learning JPEG compression artifacts for image manipulation detection and localization [J]. International Journal of Computer Vision, 2022, 130(8): 1875. DOI:10.1007/s11263-022-01617-5

[5] Dong Chengbo, Chen Xinru, Hu Ruohan, et al. MVSS-Net: multi-view multi-scale supervised networks for image manipulation detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(3): 3539. DOI: 10.1109/TPAMI.2022.3180556

[6] Islam A, Long Chengjiang, Basharat A, et al. DOA-GAN: dual-order attentive generative adversarial network for image copy-move forgery detection and localization[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 4675. DOI:10.1109/CVPR42600.2020.00473

[7] Gu A R, Nam J H, Lee S C. FBI-Net: frequency-based image forgery localization via multitask learning with self-attention [J]. IEEE Access, 2022, 10: 62751. DOI: 10.1109/ACCESS.2022.3182024

[8] Thakur A, Jindal N. Hybrid deep learning and machine learning approach for passive image forensic [J]. IET Image Processing, 2020, 14(10): 1952. DOI:10.1049/iet-ipr.2019.1291

[9] Wu Yue, Abdalmageed W, Natarajan P. BusterNet: detecting copy-move image forgery with source/target localization[C]//Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018: 170. DOI:10.1007/978-3-030-01231-1_11

[10] 向浩鸣, 夏晓华, 葛兆凯, 等. 仿人眼双目图像特征点提取与匹配方法[J]. 哈尔滨工业大学学报, 2024, 56(4): 92
Xiang Haoming, Xia Xiaohua, Ge Zhaokai, et al. Feature point extraction and matching method of humanoid-eye binocular images [J]. Journal of Harbin Institute of Technology, 2024, 56(4): 92. DOI: 10.11918/202305044

[11] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481. DOI:10.1109/TPAMI.2016.2644615

[12] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module [C]//Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018: 3. DOI: 10.1007/978-3-030-01234-2_1

[13] Fu Bo, Yuan Wangjun, Cui Xiaolong, et al. Correlation analysis and augmentation of samples for a bidirectional gate recurrent unit network for the remaining useful life prediction of bearings [J]. IEEE Sensors Journal, 2021, 21(6): 7989. DOI:10.1109/JSEN.2020.3046653

[14] Wu Yue, Abdalmageed W, Natarajan P. ManTra-Net: manipulation tracing network for detection and localization of image forgeries with anomalous features[C]//32nd IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 9535. DOI:10.1109/CVPR.2019.00977

[15] Wang Junke, Wu Zuxuan, Chen Jingjing, et al. ObjectFormer for image manipulation detection and localization [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 2354. DOI: 10.1109/CVPR52688.2022.00240

[16] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640. DOI: 10.1109/TPAMI.2016.2572683

[17] Chen L C, Zhu Yukun, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018: 833. DOI:10.1007/978-3-030-01234-2_49

[18] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation [C]//Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer, 2015: 234. DOI:10.1007/978-3-319-24574-4_28

[19] Bi Xiuli, Wei Yang, Xiao Bin, et al. RRU-Net: the ringed residual U-Net for image splicing forgery detection [C]//32nd IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Long Beach: IEEE, 2019: 30. DOI: 10.1109/CVPRW.2019.00010