

DOI:10.16136/j.joel.2023.01.0160

# 基于多残差学习与注意力融合的中值滤波检测

胡万<sup>1</sup>, 张玉金<sup>1\*</sup>, 张涛<sup>2</sup>, 沈万里<sup>1</sup>

(1. 上海工程技术大学 电子电气工程学院, 上海 201620; 2. 常熟理工学院 计算机科学与工程学院, 江苏 常熟 215500)

**摘要:**针对小尺寸 JPEG 压缩图像携带有效信息较少、中值滤波痕迹不明显的问题,提出一种基于多残差学习与注意力融合的图像中值滤波检测算法。该算法将多个高通滤波器与注意力模块相结合,获取带权值的多残差特征图作为特征提取层的输入,特征提取层采用分组卷积形式,对输入的多残差特征图进行多尺度特征提取,融合不同尺度的特征信息,同时采用密集连接方式,每一层卷积的输入来自前面所有卷积层的输出和。实验结果表明,针对小尺寸 JPEG 压缩图像的中值滤波检测,本文算法比现有算法具有更高的检测精度,且能更有效地检测与定位局部篡改区域。

**关键词:**多残差学习; 中值滤波检测; 预处理; 通道注意力; 多尺度特征

**中图分类号:** TP309 **文献标识码:** A **文章编号:** 1005-0086(2023)01-0081-09

## Median filtering detection based on multiple-residual learning with attention fusion

HU Wan<sup>1</sup>, ZHANG Yujin<sup>1\*</sup>, ZHANG Tao<sup>2</sup>, SHEN Wanli<sup>1</sup>

(1. School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China; 2. School of Computer Science and Engineering, Changshu Institute of Technology, Changshu, Jiangsu 215500, China)

**Abstract:** A median filter detection algorithm based on multi-residual learning and attention fusion is proposed for small size JPEG compressed images carrying less effective information and less obvious median filter traces. In this algorithm, multiple high-pass filters are combined with the attention module to obtain multi-residual feature maps with weights as the input of the feature extraction layer, and the feature extraction layer adopts the form of grouped convolution to perform multi-scale feature extraction on the input multi-residual feature maps and fuse the feature information with different scales, while the dense connection is used, and the input of each convolution layer comes from the output sum of all previous convolution layers. The experimental results show that the proposed algorithm in this paper has higher detection accuracy than existing algorithms for median filter detection of small JPEG compressed images, and can detect and locate local tampered regions more effectively.

**Key words:** multiple-residual learning; median filtering detection; preprocessing; channel attention; multi-scale feature

## 0 引言

随着信息技术的不断发展,各种简单快捷的图像处理工具层出不穷,人们可以在没有任何专业知识的情况下对一幅图像进行自由编辑,例如

将一幅图像的部分区域复制并粘贴到另一幅图像中,同时利用中值滤波平滑边缘以生成逼真的伪造图像。对于数字图像取证来说,图像操作历史的溯源将有助于伪造图像的鉴定,伪造区域可能经历过的常规图像处理包含重采样<sup>[1-3]</sup>、JPEG 压

\* E-mail: yjzhang@sues.edu.cn

收稿日期:2022-03-14 修订日期:2022-04-16

基金项目:国家自然科学基金(62072057)和上海市自然科学基金(17ZR1411900)资助项目

缩<sup>[4]</sup>、中值滤波<sup>[5-13]</sup>等。

中值滤波是一种非线性平滑滤波,已被广泛地应用于信号的去噪<sup>[14]</sup>和平滑处理<sup>[15]</sup>,由于中值滤波具有的高度非线性,近年来也被应用于反取证技术中,使其成为了用于掩盖其他图像操作所留痕迹的有效工具,因此对中值滤波进行检测变得尤为重要。目前中值滤波检测有以下两个方面的问题:1) 图像尺寸,当图像尺寸较小时,所带有效信息较少,使得中值滤波痕迹较难被获取,导致检测效果不尽人意;2) 分辨率低的图像,网络上大多数图像都经过 JPEG 压缩,其中的量化操作会破坏中值滤波痕迹,给现有的中值滤波检测增加了取证难度。

KIRCHNER 等<sup>[5]</sup>以 0 和 1 在一阶差分域的数量比作为中值滤波图像的判断依据。CAO 等<sup>[6]</sup>提出以融合图像纹理区域特征和一阶差分特征后的零点概率作为中值滤波检测特征。YUAN 等<sup>[7]</sup>将基于排序统计特性和灰度值的特征作为判断依据。但这 3 种传统算法对 JPEG 压缩图像检测性能较差。KANG 等<sup>[8]</sup>利用自回归模型拟合的中值滤波残差(median filtering residual, MFR),有效改善了 JPEG 压缩场景下的检测性能,但在小尺寸图像检测过程中效果一般。CHEN 等<sup>[9]</sup>提出了由全局概率特征和局部相关特征组成的 GLF(global and local feature)特征,提升了小尺寸和 JPEG 压缩场景下的检测性能。YANG 等<sup>[10]</sup>针对 JPEG 压缩图像,计算其 MFR、均值滤波残差和高斯滤波残差,利用二维自回归模型拟合这些残差以鉴定中值滤波。

近年来,深度神经网络在计算机视觉任务中取得了优异的性能<sup>[16]</sup>,CHEN 等<sup>[11]</sup>首次将卷积神经网络(convolutional neural network, CNN)用于图像中值滤波检测,与传统的 CNN 模型不同,通过添加一个滤波层,将 MFR 作为 CNN 网络的输

入。LIU 等<sup>[12]</sup>在 CNN 的输入端添加傅里叶变换层,提取频域特征以识别平滑滤波操作的模板参数。YU 等<sup>[13]</sup>提出使用多个高通滤波器初始化预处理层的权值,获得多个不同特征残差,再将多残差作为 CNN 的输入。

传统算法通过分析小尺寸或者 JPEG 压缩图像的特点,手工提取特定特征,鲁棒性不强。现有的基于 CNN 的图像中值滤波算法存在一定可改进的地方,例如预处理层输出的多残差之间的关系并不明确,特征提取层对特征学习不够深入,影响了小尺寸 JPEG 压缩图像的特征提取和学习难度。因此,本文提出了基于多残差学习与注意力融合的图像中值滤波检测算法,主要工作如下:

1) 不同阶数的高通滤波残差之间存在一定的关联性,进而导致特征信息冗余,在预处理层嵌入一种有效通道注意力(efficient channel attention, ECA)模块,自适应地赋予每个通道不同的权重,减少信息冗余,强化重要信息。

2) 针对小尺寸 JPEG 压缩图像携带的有效信息较少问题,设计一个多尺度深度特征提取模块,将滤波层输出的不同残差特征图直接输入 3 组带有不同大小卷积核的分支中,扩大感受野,捕获更多有效信息,将每一层的卷积输出作为接下来每一个卷积层的输入,减少有效信息在传递过程中的损失。

## 1 本文算法

### 1.1 网络总体框架

基于多残差学习与注意力融合的中值滤波检测网络结构如图 1 所示,本文在现有的图像中值滤波检测网络的基础上,首先对预处理层进行优化,通过添加多个不同的高通滤波器,来获取丰富的多残差特征,为了减少多个高通滤波残差之间存在的信息冗余,将多残差学习与注意力机制相

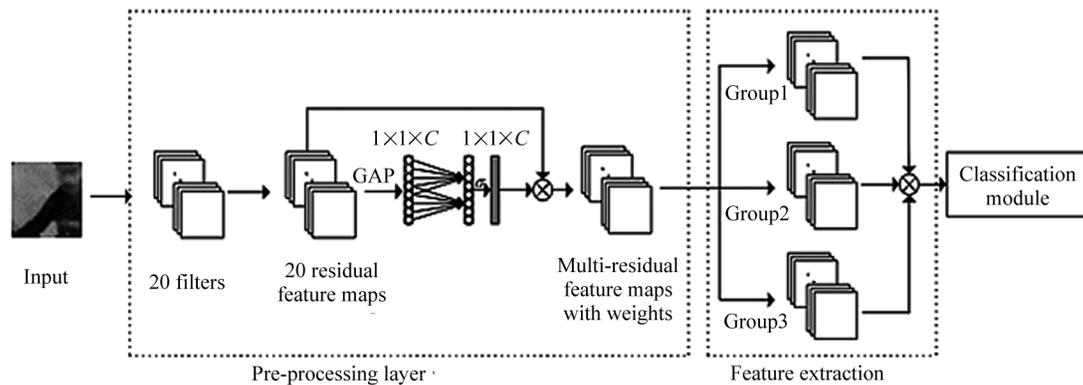


图 1 网络总体结构图

Fig. 1 Diagram of overall network structure

结合,获得带权重的多残差特征,并以此作为 CNN 的输入。由于小尺寸图像携带信息较少,传统的 CNN 难以有效地捕捉中值滤波痕迹,本文采用分组卷积的形式,设计 3 组带有不同大小卷积核的 CNN,扩大感受野,从不同尺度提取并学习多残差特征。与此同时,为了减少特征信息在传递过程中的丢失,本文采用密集连接,CNN 的每一层输出逐层向下传递,在进行多尺度特征提取,最大化提取有用信息的同时,减轻梯度消失问题,更有效地利用了特征信息。

### 1.2 通道注意力机制

WANG 等<sup>[17]</sup>提出了一种局部跨通道交互的 ECA 机制,该模块通过快速一维卷积实现无降维的通道信息交互,自适应标定每个特征通道的重要程度。考虑每个通道及其相邻  $k$  个通道之间的交互信息,共同预测一个通道的权值。如图 2 所示,通过特征重标定的方式来自适应地调整通道之间的特征响应,网络结构简单,易与其他网络相结合,在增加少量参数量的情况下,能够有效提高网络的表达能力。

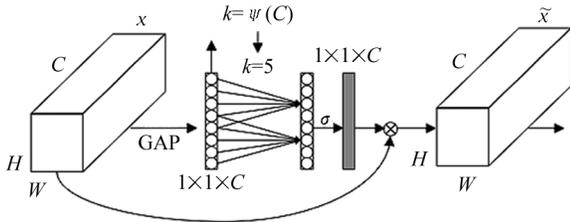


图 2 ECA 模块结构图

Fig. 2 Diagram of ECA block structure

首先,将单个通道内整个空间编码为一个全局特征,通过全局平均池化的方式在  $H \times W$  的空间维度上收缩,定义如下:

$$Z_c = F_{sq}(x_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j), \quad (1)$$

式中,  $F_{sq}(\cdot)$  表示全局平均池化,  $x_c(\cdot)$  表示特征图的第  $c$  个通道,得到全局特征描述后,通过通道维数函数来自适应地确定一维卷积核的大小,它代表了局部交叉通道相互作用的覆盖范围,定义如下:

$$k = \Psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}}, \quad (2)$$

式中,  $C$  表示通道总数,  $\psi(C)$  表示通道数为  $C$  的局部交叉通道的个数,  $\lfloor t \rfloor_{\text{odd}}$  表示与  $t$  最接近的奇数,  $\gamma$  和  $b$  为常数,本文分别将其设置为 2 和 1,注意力模块输出权重定义如下:

$$\omega = \sigma(W_k Z_c), \quad (3)$$

式中,  $W_k$  包含  $k \times C$  个参数,定义为:

$$\begin{bmatrix} \omega_1^1 & \cdots & \omega_1^k & 0 & 0 & \cdots & \cdots & 0 \\ 0 & \omega_2^2 & \cdots & \omega_2^{k+1} & 0 & \cdots & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & \cdots & 0 & 0 & \cdots & \omega_C^{C-k+1} & \cdots & \omega_C^C \end{bmatrix}, \quad (4)$$

$\sigma(\cdot)$  表示 Sigmoid 非线性激活函数:

$$\sigma(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1}. \quad (5)$$

式(3)避免了不同通道之间完全独立,在实现局部跨通道交互的同时保证了效率和有效性,  $z_c$  的权重仅通过考虑与其相邻的  $k$  个元素之间的相互作用来计算:

$$\rho_c = \sigma\left(\sum_{j=1}^k \omega_c^j y_c^j\right), y_c^j \in \Omega_c^k, \quad (6)$$

式中,  $\Omega_c^k$  表示与  $y_c$  相邻的  $k$  个通道的集合。为了降低模型的复杂度,所有通道可以共享相同的参数,即:

$$\rho_i = \sigma\left(\sum_{j=1}^k \omega^j y_c^j\right), y_c^j \in \Omega_c^k, \quad (7)$$

式中,  $\rho_c$  被用来建模特征之间的相关性,第  $c$  个通道包含的 MFR 特征图越重要,对应的  $\rho_c$  就越大,表示模型对该通道的关注程度就越大。式(7)可以进一步简化为一维卷积操作:

$$\rho = \sigma(H^{(k)} * z), \quad (8)$$

式中,  $H$  表示一维卷积核,  $k$  为对应卷积核的大小,代表了局部跨通道交互作用的覆盖范围,由式(2)可确定。

### 1.3 预处理层

YU 等<sup>[13]</sup>使用多个高通滤波器来初始化预处理层权值,然而,经过多个高通滤波器输出的不同残差特征图具有不同的分类性能。为解决此问题,本文将多残差学习与注意力融合,通过网络学习,自适应地重新标定各通道的权值,将中值滤波痕迹明显的残差特征图给与更多的关注,结构如图 3 所示。

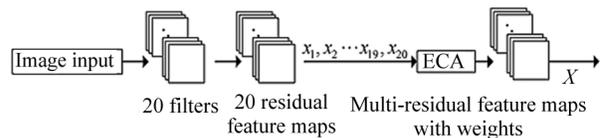


图 3 结合 ECA 的预处理层结构图

Fig. 3 Pre-processing layer structure diagram with ECA

滤波层输出的多残差特征图,通过 ECA 模块进行权重分配,经过全局平均池化表示每一个通道特征,再由相邻几个输入通道共同参与一个通道的预测,对残差特征图进行权重重标定,权值大小代表了该通道特征信息的重要程度。该结构可以有效强化重要特征信息,减少特征信息冗余。

$$X = \{X_i = \omega_i x_i (i = 1, 2, 3, \dots, 20)\}, \quad (9)$$

式中,  $X$  表示预处理层的输出,  $\omega$  表示权重,  $x$  表示通道,  $\omega_i x_i$  表示第  $i$  个通道输出的带权值的残差特征图,将 20 个带不同权值的残差特征图融合,作为特征提取模块的输入。

### 1.4 多尺度深度特征提取模块

为了更有效地捕捉中值滤波痕迹,本文使用 3 种不同大小的卷积核构建 CNN 以提取多尺度深度特征,每一层卷积的输入为该层之前所有卷积层输出的和:

$$X_l = H_l([X_0, X_1, \dots, X_{l-1}]), \quad (10)$$

式中,  $X_l$  表示  $l$  层的输出,  $H_l$  表示一个非线性变换,通过对每一层的输出逐层进行传递,减少输入信息损失的同时,可以有效避免梯度消失现象。本文借鉴 DenseNet 网络思想<sup>[18]</sup>,结合分组卷积网络结构,设计并搭建了中值滤波检测网络中的多尺度深度特征提取模块,如图 4 所示。

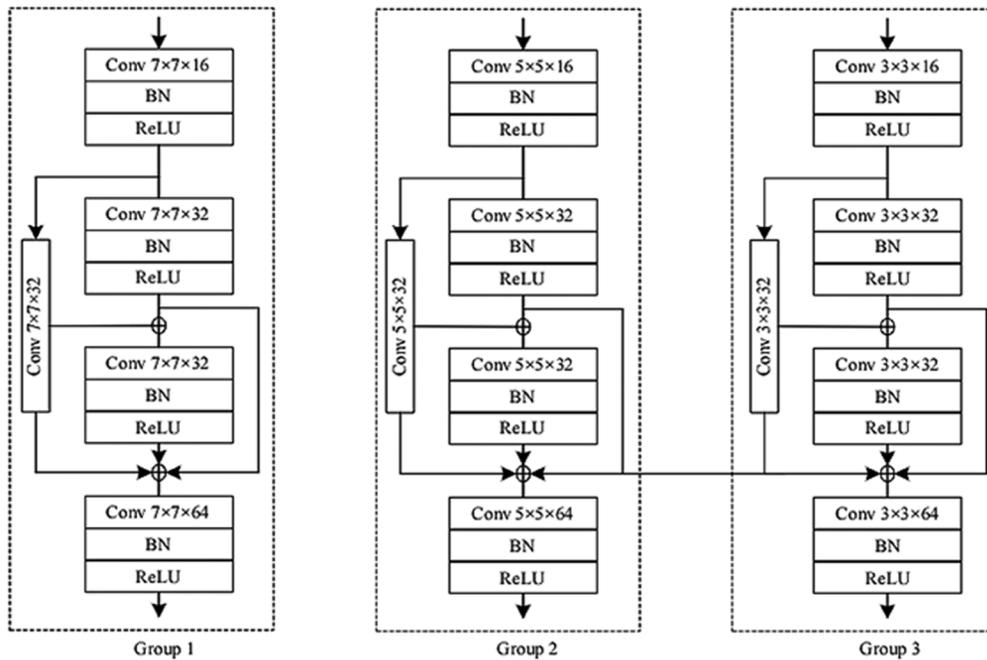


图 4 多尺度深度特征提取模块

Fig. 4 Multi-scale deep feature extraction module

在图 4 中,预处理模块获取的 20 个残差特征图分别输入 3 组卷积,从左往右依次为 Group1、Group2 和 Group3,分别输出 64 个特征图。其中,3 个分支所用卷积模板大小分别为  $7 \times 7$ 、 $5 \times 5$ 、 $3 \times 3$ ,每条分支的卷积核个数依次为 16、32、32 和 64,最后将 3 组不同尺度的特征图进行融合,得到 64 个特征图。该结构的使用,降低了网络的参数量,充分利用了预处理层输出的残差特征图,使得特征和梯度的传递更加有效;此外,3 个不同大小的卷积核扩大了感受野的范围,从不同尺度学习残差特征,增强了网络的分类性能。

## 2 实验结果与分析

### 2.1 实验数据集与算法评价指标

本文使用合成数据集来验证所提出的基于多残差学习与注意力融合的图像中值滤波检测模型,合成数据集来源于 BOSSbase1.01<sup>[19]</sup>、UCDI<sup>[20]</sup>、Dresden<sup>[21]</sup>和 NRCS<sup>[22]</sup>4 个被广泛使用的数据库,库中的原始图像均是未经 JPEG 压缩的,从中依次选取 10 000、1 338、1 491 和 2 171 幅图像构成 15 000 幅图像集。为了验证本文算法对经过 JPEG 压缩的小尺寸中值滤波图像的检测性能,根据图像尺寸、滤波模板和品质因子(quality factor,  $QF$ )制作小尺寸正负样本数据集。具体来说,对于原始 15 000 幅图像集

中的每一幅图像,首先从其中心像素位置向外进行裁剪,生成  $64 \times 64$  和  $32 \times 32$  两种小尺寸图像,然后以  $3 \times 3$  和  $5 \times 5$  滤波窗口对这两种小尺寸图像分别进行中值滤波,最后以  $QF$  为 70 和 90 分别保存为 JPEG 格式以生成正样本;而负样本则不做滤波处理,对上述两种小尺寸图像直接以  $QF$  为 70 和 90 分别保存为 JPEG 格式。以上述方式生成的正负样本数据集如表 1 和表 2 所示,表中相应行的正负样本集用以评估本文模型的性能,共有 8 组不同尺寸不同压缩率的实验数据集。对每组实验数据集,从正样本中随机选取一半,并与相应的负样本一起构成训练集,剩余的正负样本作为测试集。

表 1 正样本数据集

Tab. 1 Positive sample datasets

Size	$QF$	Filter size	Number
$64 \times 64$	70	$3 \times 3$	15 000
	70	$5 \times 5$	15 000
	90	$3 \times 3$	15 000
	90	$5 \times 5$	15 000
$32 \times 32$	70	$3 \times 3$	15 000
	70	$5 \times 5$	15 000
	90	$3 \times 3$	15 000
	90	$5 \times 5$	15 000

表 2 负样本数据集

Tab. 2 Negative sample datasets

Size	$QF$	Filter size	Number
$64 \times 64$	70	—	15 000
	70	—	15 000
	90	—	15 000
	90	—	15 000
$32 \times 32$	70	—	15 000
	90	—	15 000
	90	—	15 000
	90	—	15 000

本文以检测精度( $A_b$ )作为指标来评价不同中值滤波检测模型的性能:

$$A_b = \frac{c}{n}, \quad (11)$$

式中, $b$  表示预测正确的测试图像个数, $n$  表示测试图像总数。

## 2.2 实验环境与参数设置

本文实验均在一台安装有 Windows10 操作系统的台式工作站上进行,使用 PyCharm 编程软件和深度学习框架 Tensorflow1.13.1 进行仿真,工作站的

处理器为 Intel(R) Xeon(R) CPU E5-2650 v4 @ 2.20 GHz,内存容量为 16 G,显卡类型为 NVIDIA Quadro M4000。在训练过程中,采用自适应动量随机优化方法(Adam)<sup>[18]</sup>来最小化损失函数。

## 2.3 实验结果

### 2.3.1 网络结构有效性分析

为了验证本文所提出的多残差学习与注意力机制 ECA 模块融合的效果,在滤波层随机选取 3 个输出的残差特征图,然后在注意力模块后面选取对应的 3 个残差特征图,并且计算每一个残差特征图在经过注意力模块前后的像素值,实验结果如图 5 所示。

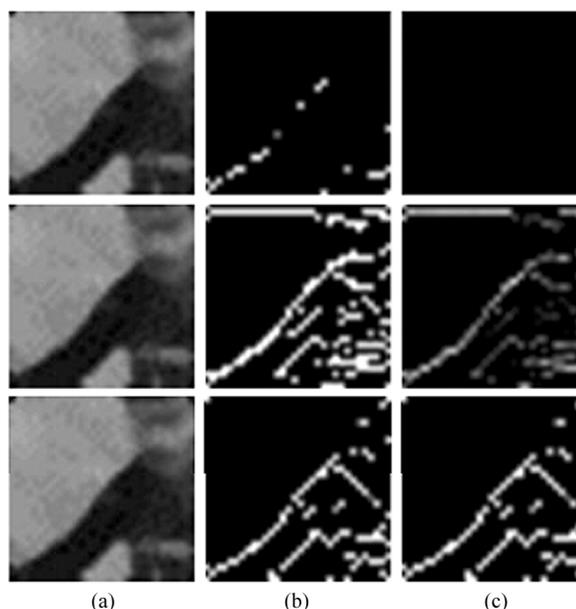


图 5 残差权重分配前后的特征图对比:

(a) 输入图像; (b) 权重分配前的 3 种残差特征图;  
(c) 权重分配后的 3 种残差特征图

Fig. 5 Comparison of feature graphs before and after residual weight distribution: (a) Input image; (b) Three residual feature graphs before weight distribution; (c) Three residual feature graphs after weight distribution

图 5(a)(第 1 列)为输入图像,图 5(b)(第 2 列)从上至下依次为一阶滤波器输出图像、二阶滤波器输出图像和“EDGE $3 \times 3$ ”滤波器输出图像,图 5(c)(第 3 列)为对应滤波器输出的残差特征图经过 ECA 模块赋予权值后的残差特征图,通过将图像转换成像素矩阵,求得经过一阶滤波器得到的残差特征图,注意力模块给予的权值为  $1.2489 \times 10^{-7}$ ,经过二阶

滤波器得到的残差特征图,注意力模块给予的权值为 0.005 2,经过“EDGE3×3”滤波器得到的残差特征图,注意力模块给予的权值为 0.999 8。由此可见,引入 ECA 注意力模块后,对滤波器输出的残差特征图进行了权值分配,一些带有重要特征的残差特征图被给予了更大的权重,优化了预处理层的结构,减少了特征信息的冗余,强化了重要特征,为深度特征提取模块提供了更加有效的输入。

为了进一步验证 ECA 模块对本文所提出的图像中值滤波检测网络性能的影响,本文测试了引入 ECA 模块的中值滤波检测网络和未引入 ECA 模块的中值滤波检测网络的检测精度,并与文献[11]进行了性能对比。测试图像大小为 32×32 和 64×64,正样本均先经过窗口大小为 3×3 的中值滤波,再经过 QF 为 70 的 JPEG 压缩共同处理,实验结果如表 3 所示。

表 3 注意力模块的有效性(单位:%)

Tab. 3 The effectiveness of attention modules(Unit:%)

Image size	Ref. [11]	Without ECA	Proposed
64×64	87.61	95.23	<b>97.64</b>
32×32	81.84	93.89	<b>97.27</b>

从表 3 中的实验结果可知,在图像经过窗口大小为 3×3 的中值滤波且 QF 为 70 的压缩情况下,文献[11]所用的图像中值滤波检测算法的检测精度为 87.61%和 81.84%,均低于 90%,而本文所提算法对于两种图像尺寸均取得了优于文献[11]的检测性能。此外,在未引入 ECA 模块对多残差特征进行自适应权值分配的情况下,本文算法检测精度分别为 95.23%和 93.89%,对比文献[11]有较大提升,原因在于文献[11]仅将单个残差特征图作为 CNN 的输入,进而进行特征提取与分类,单个残差特征图和卷积核使得网络无法有效应对小尺寸压缩图像。本文通过分组卷积,使用不同大小的卷积核来捕捉小尺寸图像携带的微弱的中值滤波痕迹。为了进一步分析多残差特征之间的关系,本文在改进特征提取层的基础上,引入 ECA 模块对多残差特征进行权值分配,特征的有效性显著增强,检测精度分别提升到 97.64%和 97.27%。

2.3.2 与现有算法的检测精度比较

为了叙述方便,“JPEG\_70”表示只经过 QF 为 70 的 JPEG 压缩图像,“MF3\_JPEG\_70”表示先经过窗口大小为 3×3 的中值滤波处理,再经过 QF 为 70

的 JPEG 压缩共同处理的图像,其他类似的表示与上述规则相同。本文与现有的 4 种中值滤波检测算法进行了定量比较与分析,如表 4 所示。从表中数据分析可知,在检测同等尺寸和相同压缩率的图像时,5×5 中值滤波检测性能比 3×3 中值滤波检测性能更好。在图像分辨率为 64×64、QF 为 90、滤波窗口大小为 3×3 的情况下,表中所示各种算法均取得了不错的检测效果,本文算法的检测精度达到了 98.02%,当图像分辨率不变,QF 变为 70 的情况下,现有算法的检测精度均有明显下降,而本文算法的检测精度仅略微下降,依然保持在 98%左右。当图像分辨率为 32×32 时,现有算法的检测精度明显降低,原因在于小图像携带的信息少,中值滤波痕迹不明显,增加了图像中值滤波检测的难度,本文算法能够通过权重分配和特征重利用的方式更好地捕捉滤波痕迹,即使在小尺寸图像中值滤波检测过程中,依然能够达到很好的检测效果。在区分检测正负样本 MF3\_JPEG\_70 和 JPEG\_70 时,随着图像分辨率的降低,文献[12]所提出算法的检测精度由 85.50%下降到 76.64%,文献[11]所提出的算法的检测精度由 87.61%下降到 81.86%,均有大幅度的下降,这两种算法的检测性能对图像块分辨率的改变不够鲁棒,而本文算法的检测精度依旧保持在 97%以上。综上所述,本文所提出的基于多残差学习与注意力融合的图像中值滤波检测算法拥有比其他 4 种算法更好的检测性能。

为了验证本文所提算法在跨库检测上的性能,使用合成数据集训练网络模型,然后在 BOSSbase1.01、UCID、Dresden 和 NRCS 4 个数据集上进行测试,训练和测试图像均被预处理为灰度图像,裁剪成 32×32 大小,且经过 3×3 中值滤波和 QF 为 70 的 JPEG 压缩处理,测试结果如表 5 所示。

从表 5 可以看出,本文算法在 4 种数据集中均取得了较好的检测性能,明显优于其他 4 种图像中值滤波检测算法。尤其在 BOSSbase1.01 数据集上,本文算法取得了 98.21%的测试精度,相较于文献[8]所提算法提高了约 21 个百分点,性能提升明显。主要原因在于文献[8]所提的算法将自回归系数作为检测特征,当图像尺寸较大时,模型拟合性能较好,该算法能够取得较好的检测结果;而当图像尺寸变小时,中值滤波痕迹微弱,图像携带的有效信息较少,模型拟合优度低,检测精度显著降低。本文使用的多个高通滤波器可有效去除图像内容干扰,得到更有效的多残差特征图,突显小尺寸图像滤波痕迹。

此外,在卷积过程中采用密集连接方式,将每一层卷积输出向下逐层传递,特征信息在传递过程中的损失将有效减少,进一步提升了模型的泛化能力。

表 4 合成数据集中各算法的检测精度(单位:%)

Tab. 4 Detection accuracy of different methods in composite datasets(Unit:%)

Image size	Method	JPEG_90	JPEG_90	JPEG_70	JPEG_70
		VS MF3_JPEG_90	VS MF5_JPEG_90	VS MF3_JPEG_70	VS MF5_JPEG_70
64×64	Ref. [8]	89.49	94.39	78.99	87.63
	Ref. [10]	93.63	96.47	88.42	92.94
	Ref. [11]	93.98	97.24	87.61	93.46
	Ref. [12]	92.71	97.52	85.50	91.15
	Proposed	<b>98.02</b>	<b>98.83</b>	<b>97.64</b>	<b>98.64</b>
32×32	Ref. [8]	83.95	90.29	75.88	82.57
	Ref. [10]	92.19	94.57	88.75	92.03
	Ref. [11]	87.19	93.42	81.86	86.38
	Ref. [12]	88.17	93.40	76.64	88.06
	Proposed	<b>97.85</b>	<b>98.42</b>	<b>97.26</b>	<b>98.01</b>

表 5 不同数据集测试精度(单位:%)

Tab. 5 Test accuracy in Different datasets(Unit:%)

Method	BOSSbase1.01	UCID	Dresden	NRCS
Ref. [8]	76.89	75.62	77.59	76.46
Ref. [10]	89.93	87.45	89.61	88.31
Ref. [11]	83.84	81.69	84.47	82.67
Ref. [12]	78.88	76.27	78.36	77.85
Proposed	<b>98.21</b>	<b>97.14</b>	<b>97.65</b>	<b>96.69</b>

2.3.3 算法运行效率比较

为了测试算法的运行效率,以图像尺寸 32×32 对 5 种算法进行效率评估,从 3.1 节所述的合成数据集中选取中值滤波窗口大小为 3×3、QF 为 70 的正负样本作为不同模型的输入,这些算法的运行时间如表 6 所示。由于本文提出的基于多残差学习与注意力融合的图像中值滤波检测网络采用分组卷积的模式,提高了网络运行效率,从表 6 的结果可以看出,本文算法相较于其他算法运行效率更高。

表 6 不同深度学习算法的运行效率(单位:s)

Tab. 6 Running efficiency of different deep learning algorithms(Unit:s)

Method	Proposed	Ref. [11]	Ref. [12]
Time/s	<b>1 260</b>	2 045	2 352

2.3.4 图像拼接篡改区域定位

在图像拼接篡改过程中,中值滤波可作为一种有效地去噪和平滑拼接边缘的后处理操作,减弱因拼接带来的伪造痕迹,从而改善图像拼接效果。图 6

是一个图像拼接篡改实例,其中图 6(a)为源图像,图 6(b)为目标图像,均为未经 JPEG 压缩的图像。首先对源图像进行窗口大小为 3×3 的中值滤波处理,然后利用 Photoshop 软件将其中的游船区域复制并粘贴到图 6(b)中,最后将篡改图像以 QF 为 70 的 JPEG 格式保存,如图 6(c)所示。

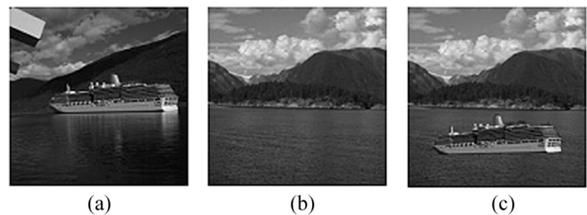


图 6 图像拼接篡改实例:(a) 源图像; (b) 目标图像; (c) 篡改图像

Fig. 6 An example of splicing forgery: (a) Source image; (b) Target image; (c) Tampered image

本文使用上述 5 种中值滤波检测方法对篡改图像(图 6(c))进行检测,首先对合成图像进行图像块分割(分割成不重叠的、大小为 32×32 的图像块),然后对每个图像块进行中值滤波检测,并以“红色空心正方形”对被检测出的中值滤波图像块进行可视化标注。在本实验中,所有方法均在同一训练集中训练,即大小为 32×32 且 QF 为 70 的小尺寸 JPEG 压缩图像训练集,篡改区域定位结果如图 7 所示。

图 7(a)为文献[8]所提算法的定位结果,图 7(b)为文献[10]所提算法的定位结果,图 7(c)为文献

[12]所提算法的定位结果,图 7(d)为文献[11]所提算法的定位结果,图 7(e)为本文所提算法的定位结果。从实验结果可知,各种算法均能从不同程度上定位伪造区域,但文献[8]—[12]所提出的算法出现较多的误判区域或未能较完整检测出篡改区域,而本文算法几乎完整地检测出被篡改区域,仅存在极少量的误判区域。由此可见,本文所提的基于多残差与注意力融合的图像中值滤波检测算法能够更有效地检测与定位局部篡改区域。

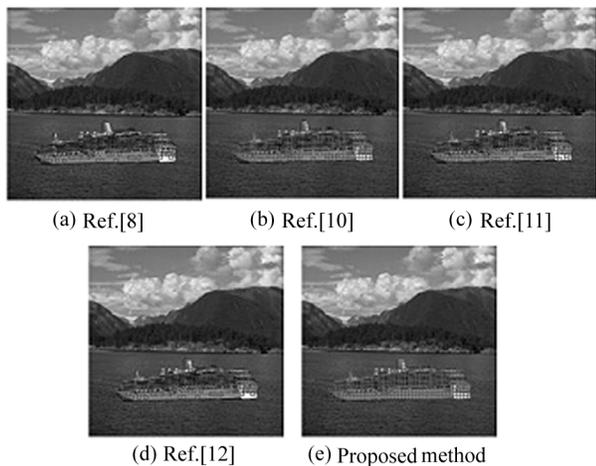


图 7 各种方法的篡改定位结果:

Fig. 7 Tampering location results of various methods

### 3 结 论

本文提出一种基于多残差学习与注意力融合的图像中值滤波检测算法,不同于已有的图像中值滤波检测算法预处理层结构,本文在使用多个高通滤波器去除图像内容干扰的同时,引入注意力机制对多残差特征图进行权重分配,减少由于不同滤波器之间存在一定关联所带来的信息冗余,强化重要信息,为特征提取模块提供更有效的输入;构建多尺度特征提取模块,减少有效信息在传递过程中的损失,提取更加丰富的特征,提高了分类准确率。实验结果表明,在合成数据集上本文方法比现有方法具有更好的检测性能,且能更有效地检测与定位局部篡改区域。

### 参考文献:

- [1] HILAL A. Image re-sampling detection through a novel interpolation kernel [J]. *Forensic Science International*, 2018, 287: 25-35.
- [2] BIANCHI T, PIVA A. Detection of nonaligned double JPEG compression based on integer periodicity maps [J]. *IEEE Transactions on Information Forensics and Security*, 2011, 7(2): 842-848.
- [3] ZHANG Q, LU W, HUANG T, et al. On the robustness of JPEG post-compression to resampling factor estimation [J]. *Signal Processing*, 2020, 168: 107371.
- [4] ESMAELZEHY A, AHMAD M O, SWAMY M N S. Development of new fractal and non-fractal deep residual networks for deblocking of JPEG decompressed images [C]//2020 IEEE International Conference on Image Processing (ICIP), October 25-28, 2020, Abu Dhabi, United Arab. New York: IEEE, 2020: 1271-1275.
- [5] KIRCHNER M, FFIDRICH J. On detection of median filtering in digital images [C]//Media forensics and security II. International Society for Optics and Photonics, January 27, 2010, San Jose, California, United States. Bellingham, WA, USA: SPIE, 2010, 7541: 754110.
- [6] CAO G, ZHAO Y, NI R, et al. Forensic detection of median filtering in digital images [C]//2010 IEEE International Conference on Multimedia and Expo, July 19-23, 2010, Singapore. New York: IEEE, 2010: 89-94.
- [7] YUAN H D. Blind forensics of median filtering in digital images [J]. *IEEE Transactions on Information Forensics and Security*, 2011, 6(4): 1335-1345.
- [8] KANG X, STAMM M C, PENG A, et al. Robust median filtering forensics using an autoregressive model [J]. *IEEE Transactions on Information Forensics and Security*, 2013, 8(9): 1456-1468.
- [9] CHEN C, NI J, HUANG J. Blind detection of median filtering in digital images: A difference domain based approach [J]. *IEEE Transactions on Image Processing*, 2013, 22(12): 4699-4710.
- [10] YANG J, REN H, ZHU G, et al. Detecting median filtering via two-dimensional AR models of multiple filtered residuals [J]. *Multimedia Tools and Applications*, 2018, 77(7): 7931-7953.
- [11] CHEN J, KANG X, LIU Y, et al. Median filtering forensics based on convolutional neural networks [J]. *IEEE Signal Processing Letters*, 2015, 22(11): 1849-1853.
- [12] LIU A, ZHAO Z, ZHANG C, et al. Smooth filtering identification based on convolutional neural networks [J]. *Multimedia Tools and Applications*, 2019, 78(19): 26851-26865.
- [13] Yu L, Zhang Y J, Han H, et al. Robust median filtering forensics by CNN-based multiple residuals learning [J]. *IEEE Access*, 2019, 7: 120594-120602.
- [14] ZHANG H J, ZHANG D M, YAN W, et al. Wavelet transform image denoising algorithm based on improved threshold function [J]. *Application Research of Comput-*

- ers, 2020, 343(5):1545-1548+1552.
- 张绘娟, 张达敏, 闫威, 等. 基于改进阈值函数的小波变换图像去噪算法[J]. 计算机应用研究, 2020, 343(5): 1545-1548+1552.
- [15] CAO G, ZHAO Y, NI R, et al. Forensic detection of median filtering in digital images[C]//2010 IEEE International Conference on Multimedia and Expo. July 19-23, Singapore. New York: IEEE, 2010: 89-94.
- [16] YANG M H, CHEN L, LIU H, et al. Multi-label remote sensing image classification based on graph convolutional network[J]. Application Research of Computers, 2021, 361(11): 3439-3445.
- 杨敏航, 陈龙, 刘慧, 等. 基于图卷积网络的多标签遥感图像分类[J]. 计算机应用研究, 2021, 361(11): 3439-3445.
- [17] 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), June 13-19, 2020, Seattle, WA, USA. New York: IEEE, 2020: 11531-11539.
- [18] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks[C]//IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 4700-4708.
- [19] BAS P, FILLER T, PEVNY T. Break our steganographic system: the ins and outs of organizing BOSS[C]//International Workshop on Information Hiding, May 18-20, 2011, Prague, Czech Republic. Berlin: Springer, 2011: 59-70.
- [20] SCHAEFER G, STICH M. UCID: an un-compressed color image database[C]//Storage and Retrieval Methods and Applications for Multimedia 2004. International Society for Optics and Photonics, December 18, 2003, San Jose, California, United States. Bellingham, WA, USA: SPIE, 2003, 5307: 472-480.
- [21] GLOE T, BÖHME R. Dresden image database for benchmarking digital image forensics[C]//Proceedings of the 2010 ACM Symposium on Applied Computing, March 22-26, 2010, Sierre, Switzerland. New York: ACM, 2010: 1584-1590.
- [22] United States Department of Agriculture. Natural resource conservation service photo gallery[OL]. <http://photo-gallery.nrcs.usda.gov>.

#### 作者简介:

张玉金 (1982—), 男, 博士, 副教授, 硕士生导师, 主要研究方向为多媒体内容安全、图像处理和模式识别等。