

刘洋, 张玉金. 融合残差频域特征的图像重采样检测模型[J]. 智能计算机与应用, 2024, 14(11): 74-79. DOI: 10.20169/j.issn.2095-2163.241110

融合残差频域特征的图像重采样检测模型

刘洋, 张玉金

(上海工程技术大学 电子电气工程学院, 上海 201620)

摘要: 数字图像重采样检测是图像取证领域的重要任务之一,其目的是判断图像是否经过缩放、旋转等重采样操作。基于传统特征的图像重采样检测方法较为依赖手工特征的提取,对复杂场景和干扰的鲁棒性较差,而现有的基于深度学习的图像重采样检测方法也较少考虑图像的频域特征。为了解决这一问题,本文提出了一种融合残差频域特征的图像重采样检测模型,该模型以卷积神经网络为基本结构,通过预处理层提取图像残差,通过频域转换模块实现对输入图像的频域残差特征的提取,并与空间域残差特征进行融合,从而有效提高模型的检测能力。实验结果表明,与现有方法相比,本文模型分别在无损格式、JPEG 压缩格式、不同滤波后处理的场景中都能够更加高效地检测图像中的重采样特征,并具有更低的计算复杂度。

关键词: 图像重采样检测; 卷积神经网络; 快速傅里叶变换; 残差滤波; 注意力机制

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2024)11-0074-06

Image resampling detection model fused with residual and frequency domain features

LIU Yang, ZHANG Yujin

(School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

Abstract: Digital image resampling detection is one of the important tasks in the field of image forensics, aiming to determine whether an image has undergone resampling operations such as scaling or rotation. Traditional feature-based image resampling detection methods heavily rely on manual feature extraction, which results in poor robustness to complex scenes and interference. Existing deep learning-based image resampling detection methods also pay less attention to the frequency domain characteristics of images. To address this issue, this paper proposes an image resampling detection model that integrates residual and frequency domain features. The model adopts a convolutional neural network as the basic structure, extracts image residuals through a preprocessing layer, extracts frequency domain residual features of the input image through a frequency domain transformation module, and fuses them with spatial domain residual features to effectively enhance the detection capability of the model. Experimental results demonstrate that compared to existing methods, the proposed model can efficiently detect resampling features in images in lossless formats, JPEG compressed formats, and scenes with different post-processing filtering, while having lower computational complexity.

Key words: image resampling detection; convolutional neural network; fast Fourier transform; residual filtering; attention mechanism

0 引言

随着图像编辑软件性能的不断优化,篡改数字图像也不再成为难题。图像重采样操作是图像篡改的常见形式,研究图像重采样检测技术,对于保障数字图像的真实性和可信度,减少取证的时间和降低成本具有非常重要的意义。

目前,已经相继提出了一些基于传统特征的图像重采样检测方法。Popescu 等学者^[1]提出的通过期望值最大化算法从重采样图像中提取相邻像素间存在的统计相关性;重采样图像概率图的傅里叶幅度谱中出现的周期性峰值。这种方法可以在没有任何数字水印和数字签名的情况下检测到图像重采样痕迹。为了估计 JPEG 压缩重采样图像的缩放因

基金项目: 上海市自然科学基金(17ZR1411900)。

作者简介: 刘洋(1998—),男,硕士研究生,主要研究方向:计算机视觉,图像取证。

通信作者: 张玉金(1982—),男,博士,副教授,主要研究方向:多媒体内容安全,图像处理与模式识别。Email: yjzhang@sues.edu.cn。

收稿日期: 2023-05-26

子, Liu 等学者^[2]通过对平滑块进行插值的方法消除 JPEG 压缩带来的影响, 再利用平方图像差分自动估计重采样图像的缩放因子。Le 等学者^[3]提出了一种关于 TIFF 格式的重采样图像的完整处理过程分析的统计模型, 并根据该模型设计了基于最大似然比检验和支持向量机的检测器用于检测 TIFF 格式的重采样图像。但这些方法通常需要依赖人工特征提取和参数设置, 比较容易受到复杂场景和噪声等因素的干扰, 因此检测的效果不佳。

深度学习方法具有优秀的特征提取和图像分类能力, 也具有更高的自动化程度和检测效率, 能有效解决传统方法中存在的问题。Bayar 等学者^[4]提出了一种基于约束卷积神经网络的重采样图像检测方法, 可以自动学习图像中的重采样特征而不受图像内容的干扰, 在图像重采样检测问题中取得了重要进展, 但这种方法也有一定的局限性, 例如没有考虑重采样因子的连续性和随机性等。Chen 等学者^[5]考虑到大部分的图像操作具有方向不变的特性, 引入了各向同性滤波器处理网络的输入, 并借鉴 DenseNet^[6]的结构设计网络, 实现了通用图像操作检测。Cao 等学者^[7]提出了一种基于由一对低阶高通滤波器构成的噪声提取层和双流卷积神经网络框架构成的深度学习模型, 大量实验证明了其在检测重采样方面优于之前的方法, 但网络结构较为复杂, 在训练和检测时的计算复杂度较高。Ding 等学者^[8]根据能量密度特性构建了可测量能量层以消除与重采样检测无关的纹理和其他信息, 并借鉴 Inception 结构^[9]设计预处理层, 从而通过能量密度有效区分不同的重采样因子, 进而辅助估计重采样率。Peng 等学者^[10]将重采样因子估计视为多分类问题并做了公式化的描述, 设计了一种基于双滤波

结构预处理层的卷积神经网络用于重采样参数估计, 但仅针对未压缩的图像进行了实验, 没有对 JPEG 压缩的图像进行研究。文献[11]提出了一种基于相关感知卷积神经网络(CA-CNN)的方法, 通过提取重采样特征从而检测混合篡改攻击。CA-CNN 首先将输入图像分割成 64 个小的图像块, 然后将图像块分别输入用于捕获图像水平特征和垂直特征的双流卷积神经网络, 并将提取到的水平流特征和垂直流特征利用相关感知核计算相关性, 最后利用这 3 层分别提取重采样特征并聚合构建分类器。

上述工作在图像重采样检测问题中取得了一定的成果, 但仍然存在特征提取效果差、检测精度低、计算复杂度高问题。本文设计了一种融合残差频域特征的图像重采样检测模型, 通过 2 个高效的残差滤波器对输入图像进行预处理, 并通过 SE (Squeeze-and-excitation) 注意力机制^[12]对这些残差滤波器进行动态赋权, 将得到的残差特征进行频域转换处理, 处理后的频域特征与原空间域残差特征进行融合训练, 从而高效提取出图像中的高维重采样特征, 提升网络的检测性能。

1 本文模型设计

本文将重采样检测视为模式分类问题, 设计了一种以卷积神经网络为基础的图像重采样检测模型。该模型首先通过一组精心研发的预处理残差滤波器对输入图像提取蕴含图像重采样特征的残差信息, 再对残差信息利用频域转换模块提取其残差频域信息, 将得到的残差频域信息与原空间域残差信息进行融合后输入到卷积神经网络的卷积模块中进行处理, 最后通过分类器对输入图像进行分类。具体架构如图 1 所示。

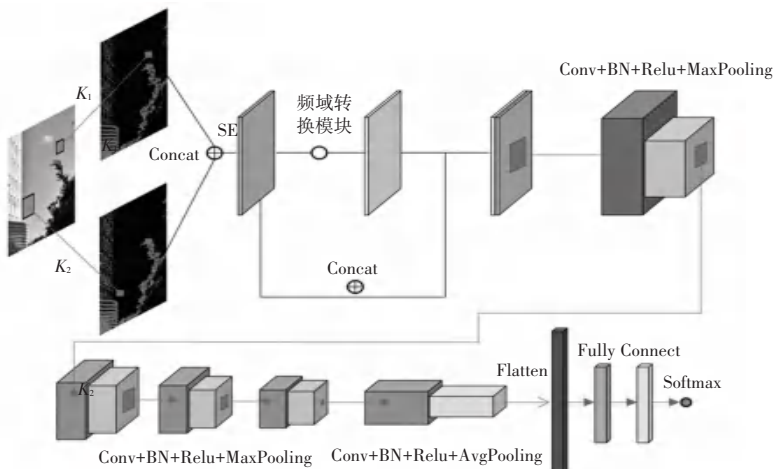


图 1 本文模型结构

Fig. 1 Model structure of the paper

1.1 预处理模块

在基于深度学习方法的图像重采样检测过程中,会在网络模型训练真正开始之前让图像数据经过残差滤波器的先期处理。这是因为重采样特征往往蕴含在与图像内容无关的高频残差信息中。因此通过设计残差滤波器对输入图像进行预处理,既可以降低图像内容对模型性能的影响,又能更大程度地突显图像中的重采样信息。这个过程可以被表示为:

$$Res = f(I) - I \quad (1)$$

其中, Res 表示残差输出; $f(\cdot)$ 表示残差计算

$$K_2 = \begin{pmatrix} \hat{e} & \hat{e} & \hat{e} & \hat{e} & \hat{e} \\ \hat{e} & \hat{e} & \hat{e} & \hat{e} & \hat{e} \\ \hat{e} & \hat{e} & \hat{e} & \hat{e} & \hat{e} \\ \hat{e} & \hat{e} & \hat{e} & \hat{e} & \hat{e} \\ \hat{e} & \hat{e} & \hat{e} & \hat{e} & \hat{e} \end{pmatrix} = \begin{pmatrix} -0.0904 & 0.0284 & 0.0860 & 0.0284 & -0.0904 \\ 0.0284 & 0.0838 & 0.1138 & 0.0838 & 0.0284 \\ 0.0860 & 0.1138 & -1.0000 & 0.1138 & 0.0860 \\ 0.0284 & 0.0838 & 0.1138 & 0.0838 & 0.0284 \\ -0.0904 & 0.0284 & 0.0860 & 0.0284 & -0.0904 \end{pmatrix} \quad (3)$$

设计不同尺寸的滤波器是因为小尺寸滤波器可以更好地捕捉局部细节和纹理,大尺寸由于其更大的感受野可以更好地捕获全局特征,如此就能有效配合后续的 SE 注意力模块对经过这 2 个滤波器处理的通道进行动态权重调整,从而最大程度地适配卷积神经网络自适应调节参数的能力。

1.2 SE 模块

考虑到经残差滤波器处理后输出的特征通道与其对应的残差滤波器唯一相关,因此可以通过通道注意力机制来对不同残差滤波器进行动态赋权。

本文在经残差滤波器处理后的融合残差特征图后引入 SE 模块^[12],其结构如图 2 所示。该模块可以显式地构建通道间的依赖关系,通过计算每个特征通道的权重来增强重要通道的表示,并抑制不重要的通道。其核心思想是对输入特征进行特征压缩和特征激励两个步骤。其中,特征压缩是对输入特征在每个通道进行全局平均池化操作,将每个通道的特征值压缩为一个标量;特征激励通过一个全连接网络来学习每个通道的权重,再将这些权重应用到原始输入特征通道上。




图 2 SE 注意力机制

Fig. 2 SE attention mechanism

方式; I 表示输入图像。

不同的残差滤波器表示不同的残差计算方式,对图像处理后得到不同的残差输出结果,从而可以不同程度地突显重采样图像的重采样特征。因此,考虑图像重采样操作的各向同性,本文分别设计了一个 3×3 大小的残差滤波器 K_1 和一个 5×5 大小的残差滤波器 K_2 , 对应的表达式分别如下:

$$K_1 = \begin{pmatrix} \hat{e} & \hat{e} & \hat{e} \\ \hat{e} & \hat{e} & \hat{e} \\ \hat{e} & \hat{e} & \hat{e} \end{pmatrix} = \begin{pmatrix} -0.0239 & 0.2739 & -0.0239 \\ 0.2739 & -1.0000 & 0.2739 \\ -0.0239 & 0.2739 & -0.0239 \end{pmatrix} \quad (2)$$

1.3 频域转换模块

图像的重采样特征通常存在于边缘、纹理等这些高频信息当中,但是在空间域中,只能通过像素值的变化来粗略确定这些高频细节,将图像通过离散傅里叶变换 (Discrete Fourier transform, DFT) 方法转换到频率域,可以更好地捕捉到图像中高频部分的细节信息,从而更精准地实现重采样特征的提取。DFT 被广泛应用于频域转换算法中,其一维形式表示为:

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j\frac{2\pi}{N}kn} \quad (4)$$

其中, $x[n]$ 表示第 n 个采样点的值, $X[k]$ 表示变换后的数据。

本文利用快速傅里叶变换 (Fast Fourier transform, FFT) 将经 SE 模块处理后的残差特征图转换为频域特征图,其结构如图 3 所示,通过二维快速傅里叶变换提取输入特征图的实部和虚部分别进行卷积操作后逆变换回空间域。后续的 Concat 操作使模型不仅可以捕获空间域中蕴含的重采样特征,也能从频域信息中获得启发,从而提高模型的性能。




图 3 频域转换模块

Fig. 3 Frequency domain transformation module

1.4 网络结构

由图 1 看到,输入网络的 $256 \times 256 \times 1$ 大小的灰度图像首先经预处理层的 2 个残差滤波器分别进行处理,并按通道进行 Concat 操作后得到 $256 \times 256 \times 2$ 大小的残差图像特征图。通过 SE 模块对拼接后的

2 个通道动态赋权, 从而让网络自适应地调整对提取重采样特征更为有效的残差滤波器的重要程度。经 SE 模块处理后的输出特征图本身与通过频域转换模块在频域进行训练后输出的特征图按通道进行 Concat 操作, 得到 $256 \times 256 \times 4$ 大小的输出特征图。该特征图开始进入 5 个卷积结构构成的卷积神经网络中进行训练, 这 5 个卷积结构依次相连, 前 4 个卷积结构分别由标准卷积层、批标准化层、ReLU 激活函数和最大值池化层依次组成, 其中最大值池化层的窗口大小是 3×3 、步长为 2。不同的是各个卷积结构中卷积层的卷积核大小与步长各有所异, 如第一个卷积结构中卷积层的卷积核尺寸为 7×7 、步长为 2, 第二和第三个卷积结构中卷积层的卷积核尺寸为 5×5 、步长为 1, 第四个卷积结构中卷积层的卷积核尺寸为 3×3 、步长为 1。在最后一个卷积结构中, 卷积层卷积核的尺寸为 1×1 、步长为 1。与前 4 个卷积结构不同的是, 该卷积结构中由平均值池化层替换最大值池化层, 但其窗口大小和步长保持不变。经卷积结构处理后的特征图由 Flatten 函数将其展平为一维向量, 通过两层全连接层和中间一层 ReLU 激活函数将该向量进行映射计算, 大小变化分别为 1 152 到 200, 200 到 200, 最后通过 Softmax 层预测其类别。

2 实验结果与分析

2.1 实验说明

2.1.1 实验环境与细节

本文所有实验都基于 Pytorch 框架和 NVIDIA RTX 2080TI GPU 实现。每个实验进行 35 轮的训练, 并在每轮结束后在测试数据集上记录模型的预测准确率, 训练和测试的过程分离。使用 Adam 优化器训练本文模型, *Batch_size* 设置为 16, 初始学习率设置为 0.001, 每 6 个 *epoch* 学习率下降为此前的一半。

2.1.2 原始数据集制作

本文实验使用 RAISE^[13] 数据集作为数据来源, RAISE 数据集是图像取证领域常用的图像数据集。该数据集包含 8 156 幅高分辨率的 TIF 格式图像, 图像内容包含各种主题和场景。本文将其中的 1 400 幅分别按照 512×512 的分辨率进行切割, 生成 35 000 幅 512×512 大小的子图像。该子图像集将作为本文实验中使用到的原始图像数据集。

2.1.3 评价指标之预测准确率

预测准确率是深度学习分类模型中常用的一种评价指标, 用于衡量模型对于测试数据集中新样本

的分类准确性。数据集中的每张图像均会被设置一个标签, 使用模型对图像的标签进行预测, 预测准确率 *Accuracy* 的计算公式为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

其中, *TP* (True Positive) 表示真正例, 即模型正确预测为正例的数量; *TN* (True Negative) 表示真负例, 即模型正确预测为负例的数量; *FP* (False Positive) 表示假正例, 即模型错误预测为正例的数量; *FN* (False Negative) 表示假负例, 即模型错误预测为负例的数量。

预测准确率的取值范围为 0~1, 数值越接近 1, 表示模型预测的准确率越高, 模型性能越好。

2.2 实验结果与分析

本节将通过大量实验来评估本文模型的合理性和有效性, 为了在保证公平性的前提下进行对比, 本文分别根据文献[4, 7, 10]对其中的模型进行了复现, 从而使这些模型运行在同样的实验环境和数据集上进行训练与预测。

2.2.1 固定重采样因子的无损图像实验结果

本小节将在具有固定重采样因子的无损格式的重采样图像数据集上评估本文模型的性能。首先, 制作一个未经重采样处理的数据集, 对 2.1.2 节中制作的原始图像数据集中每张图像的 256×256 中心区域进行裁剪后保存为 TIF 格式; 然后, 制作固定重采样因子的数据集, 将原始图像数据集中的图像分别重采样到 768×768 、 256×256 大小, 重采样插值方法为双线性插值。这样设计是为了可以分别评估模型在上采样和下采样场景中的性能, 接下来分别裁剪每张图像的 256×256 中心区域。这样共得到了 1 个 35 000 张图像的未重采样图像数据集和 2 个 35 000 张图像的重采样图像数据集。将未重采样图像数据集分别与另外 2 个重采样图像数据集进行分组实验, 每组实验中 60 000 幅图像用于训练, 10 000 幅图像用于测试。

各模型预测准确率见表 1。由表 1 可以看出, 无论是在上采样、还是下采样场景中, 各模型对于无损格式重采样图像的预测准确率均达到了较高的水准, 而本文模型和 Cao 等学者^[7] 的模型相较于另外 2 种模型具有更大的优势。尽管本文模型并未在预测准确率上领先 Cao 等学者^[7] 的模型较多, 但本文模型在计算复杂度上占据一定的优势。本小节同时记录了实验中各模型的总运行时间, 用总运行时间除以总轮数 *epoch*, 可以得到各模型的每轮运行时

间,从而作为衡量模型复杂度的一个指标。其中,本文模型的每轮运行时间为 175 s, Cao 等学者^[7]的模型每轮运行时间为 375 s, 所以本文模型以更加轻量型的网络结构就达到了以往需要复杂网络结构才能达到的预测准确率。在后续实验中, 本文模型的运行时间也均保持优势。

表 1 固定重采样因子的无损图像实验结果

Table 1 Experimental results of uncompressed image with fixed resampling factor

模型	预测准确率/%	
	768×768	256×256
Bayar 等学者 ^[4] 的模型	98.47	96.99
Cao 等学者 ^[7] 的模型	98.85	98.79
Peng 等学者 ^[10] 的模型	98.04	97.54
本文模型	98.84	99.05

2.2.2 固定重采样因子的 JPEG 压缩图像实验结果

数字图像通常需要大量的存储空间和带宽才能进行传输或处理, JPEG 压缩算法使得数字图像在网络上更容易传输和存储。然而压缩使得的信息丢失使重采样特性减弱,这就使得原本针对无损图像的重采样检测算法性能大幅降低,因此针对 JPEG 压缩后的重采样图像进行检测具有更重大的研究意义。

因此本小节将在经重采样处理的 JPEG 图像数据集上评估模型性能。数据集制作方法如下: 首先创建没有重采样的图像数据集, 在原始图像数据集中对每张图像的 256×256 中心区域进行裁剪, 然后使用 JPEG 品质因子 $Q = 50, 70, 75, 90$ 分别对图像进行压缩。紧接着创建经重采样处理的图像数据集, 亦是将原始图像数据集中的每张图像分别重采样到 768×768、256×256 的尺寸, 重采样插值方法为双线性插值, 然后对其 256×256 中心区域进行裁剪, 使用 JPEG 品质因子 $Q = 50, 70, 75, 90$ 分别对图像进行压缩。从而根据重采样因子和 JPEG 品质因子的不同生成了 8 个子数据库。每个子数据库由 35 000 张未重采样的 JPEG 压缩图像和相应的 35 000 张重采样的 JPEG 压缩图像组成。对于每个子数据库, 其中 60 000 张用于训练, 10 000 张用于测试。

实验结果如图 4、图 5 所示。由图可知, 本文模型在不同 JPEG 品质因子的压缩图像重采样检测场景中仍然具有一定的优势。具体表现为当 JPEG 品质因子 $Q = 50, 70, 75, 90$ 时, 图像被上采样到 768×768 大小时, 本文模型分别领先 Cao 等学者^[7]的模型 0~0.32%, 领先另外 2 种模型 2.40%~4.64%; 而当图

像被下采样到 256×256 大小时, 在上述 JPEG 品质因子的研究场景中, 本文模型的预测准确率先领先 Cao 等学者^[7]的模型 0.43%~1.85%, 领先另外 2 种模型 3.84%~6.02%。本小节实验测试进一步说明了本文方法的有效性, 在解决相对更困难的 JPEG 压缩图像重采样检测问题时具有更好的效果。




图 4 上采样到 768×768 的 JPEG 实验结果

Fig. 4 JPEG experimental results upsampled to 768×768

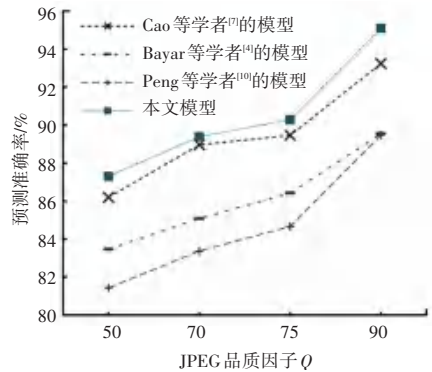


图 5 下采样到 256×256 的 JPEG 实验结果

Fig. 5 JPEG experimental results downsampled to 256×256

2.2.3 图像滤波后处理对模型的影响

为了验证本文方法是否能在更复杂的情况下继续保持出色的性能, 本小节进一步增加检测难度, 引入不同的图像滤波方法对重采样图像进行干扰, 而后再进行 JPEG 压缩操作。首先制作未经重采样处理的图像数据集, 将原始图像数据集中的每张图像分别按均值滤波、高斯滤波、中值滤波和双边滤波进行处理, 然后取其中心 256×256 大小区域按 JPEG 品质因子 $Q = 75$ 保存为 jpg 格式的图像, 得到未经重采样处理的图像数据集; 稍后制作经重采样处理的图像数据集, 将原始图像数据集中的每张图像分别按 768×768、256×256 大小重采样, 重采样插值方法为双线性插值, 接着分别进行均值滤波、高斯滤波、中值滤波和双边滤波处理, 将中心 256×256 大小区域按 JPEG 品质因子 $Q = 75$ 保存为 jpg 格式的图像, 得到经重采样处理的图像数据集。将未经重采样处理

的图像数据集按不同的滤波算法分别与经重采样处理的图像数据集进行训练,其中每组 60 000 张用于训练,10 000 张用于测试。

实验结果见表 2、表 3。在本小节的实验中,由于在重采样操作后增加了滤波操作和 JPEG 压缩处理,导致图像中的重采样特征被严重破坏,各模型相应实验中的预测准确率均出现了一定程度的下降,但本文模型仍然在各模型中处于优势地位。如在下采样到 256×256 大小的均值滤波场景中,本文模型的预测准确率要高于 Cao 等学者^[7]的模型 1.44%,而在下采样到 256×256 大小的双边滤波场景中,本文模型的预测准确率要略低于 Cao 等学者^[7]的模型 0.28%。但在本小节其他实验中,本文模型的预测准确率均高于其他模型,达到 0.22%~9.77%。通过本小节的实验,说明本文方法能够适应更加复杂的滤波后处理的图像重采样检测问题。

表 2 不同滤波算法处理后的 256×256 下采样 JPEG 图像实验结果
Table 2 Experimental results of JPEG images downsampled to 256×256 after processing with different filtering algorithms

模型	预测准确率/%			
	均值滤波	高斯滤波	中值滤波	双边滤波
Bayar 等学者 ^[4] 的模型	76.89	78.08	73.79	76.10
Cao 等学者 ^[7] 的模型	80.45	84.29	79.39	79.38
Peng 等学者 ^[10] 的模型	76.70	75.66	72.46	72.93
本文模型	81.89	85.31	79.64	79.10

表 3 不同滤波算法处理后的 768×768 下采样 JPEG 图像实验结果
Table 3 Experimental results of JPEG images downsampled to 768×768 after processing with different filtering algorithms

模型	预测准确率/%			
	均值滤波	高斯滤波	中值滤波	双边滤波
Bayar 等学者 ^[4] 的模型	76.51	84.34	79.01	76.89
Cao 等学者 ^[7] 的模型	82.28	87.90	82.83	79.26
Peng 等学者 ^[10] 的模型	73.99	81.88	78.02	74.77
本文模型	82.58	88.60	83.82	79.48

3 结束语

本文提出了一种融合残差频域特征的图像重采样检测模型,引入 SE 注意力模块对预处理层中的残差滤波器进行动态赋权,通过频域转换模块提取残差特征图的频域特征以提升模型提取重采样特征的能力。相关实验结果表明,本文模型的性能在无损格式、JPEG 压缩处理、滤波后处理等重采样图像

场景中优于现有检测算法。未来研究中,本文模型仍有进一步优化的空间,如网络结构的设计、频域转换模块中卷积结构的改进等,使其能够更加有效地实现图像重采样检测。

参考文献

- [1] POPESCU A C, FARID H. Exposing digital forgeries by detecting traces of resampling[J]. IEEE Transactions on Signal Processing, 2005, 53(2): 758-767.
- [2] LIU Xianjin, LU Wei, HUANG Tao, et al. Scaling factor estimation on jpeg compressed images by cyclostationarity analysis[J]. Multimedia Tools and Applications, 2019, 78: 7947-7964.
- [3] LE N, RETRAINT F. Statistical detector of resampled tiff images[C]//2018 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT). Piscataway, NJ: IEEE, 2018: 398-401.
- [4] 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.
- [5] CHEN Y, KANG X, WANG Z J, et al. Densely connected convolutional neural network for multi-purpose image forensics under anti-forensic attacks[C]//Proceedings of the 6th ACM Workshop on Information Hiding and Multimedia Security. New York: ACM, 2018: 91-96.
- [6] HUANG Gao, LIU Zhuang, MAATEN V D L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2017: 4700-4708.
- [7] CAO Gang, ZHOU Antao, HUANG Xianglin, et al. Resampling detection of recompressed images via dual-stream convolutional neural network[J]. Mathematical Biosciences and Engineering, 2019, 16(5): 5022-5040.
- [8] DING Feng, WU Hanzhou, ZHU Guopu, et al. METEOR: Measurable energy map toward the estimation of resampling rate via a convolutional neural network[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(12): 4715-4727.
- [9] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2015: 1-9.
- [10] PENG Lin, LIAO Xin, CHEN Mingliang. Resampling parameter estimation via dual-filtering based convolutional neural network[J]. Multimedia Systems, 2021, 27(3): 363-370.
- [11] SHIVANANDAPPA M, PATIL M M. Extraction of image resampling using correlation aware convolution neural networks for image tampering detection[J]. International Journal of Electrical and Computer Engineering, 2022, 12(3): 3033.
- [12] HU Jie, SHEN Li, ALBANIE S, et al. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2018: 7132-7141.
- [13] DANG-NGUYEN D T, PASQUINI C, CONOTTER V, et al. RAISE: A raw images dataset for digital image forensics[C]//Proceedings of the 6th ACM Multimedia Systems Conference. New York: ACM, 2015: 219-224.