

沈东明, 刘翔, 尚岩峰, 等. 改进 ResNet 的地下排水管道缺陷智能识别方法[J]. 智能计算机与应用, 2024, 14(10): 92-98.
DOI: 10.20169/j.issn.2095-2163.241012

改进 ResNet 的地下排水管道缺陷智能识别方法

沈东明¹, 刘翔¹, 尚岩峰², 汤显¹

(1 上海工程技术大学 电子电气工程学院, 上海 201620; 2 公安部第三研究所 物联网技术研发中心, 上海 200031)

摘要: 针对城市排水管道缺陷检测存在自动化程度不高、依赖人工和效率低下的问题, 本文在 ResNet50 图像分类网络的基础上, 根据排水管道缺陷的纹理特征对网络进行优化, 提出一种改进 ResNet50 的排水管道缺陷自动识别方法。通过改进基础残差块, 增强模型对管道缺陷纹理特征的提取能力, 同时嵌入改进的通道和空间注意力机制, 让网络自适应地调节特征权重, 提升网络的特征表达能力; 并提出一种特征保留模块, 增强网络的特征提取能力, 提升模型分类精度。实验结果表明, 本文提出的分类模型对管道病害图像的识别准确率达到 96.34%, 相比于 ResNet50 算法, 改进后的模型分类准确率提升了 1.76%, 具有更好的识别效果。

关键词: 排水管道; 深度学习; 缺陷识别; ResNet; 图像分类; 特征提取

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2024)10-0092-07

Intelligent defect recognition method for underground drainage pipelines based on improved ResNet network

SHEN Dongming¹, LIU Xiang¹, SHANG Yanfeng², TANG Xian¹

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

2 Internet of Things R&D Technology Center, Third Research Institute of the Ministry of Public Security, Shanghai 200031, China)

Abstract: In response to the issues of low automation, dependence on manual intervention, and low efficiency in the detection of defects in urban sewage pipelines, this study proposes an improved approach for automatic recognition of sewage pipeline defects based on the ResNet50 image classification network. The network is optimized according to the texture features of sewage pipeline defects. By improving the basic residual blocks, the model's ability to extract texture features of pipeline defects is enhanced. Additionally, improved channel and spatial attention mechanisms are embedded to allow the network to adaptively adjust feature weights and improve the network's feature representation capability. Furthermore, a feature preservation module is introduced to enhance the network's feature extraction ability and improve the model's classification accuracy. Experimental results demonstrate that the proposed classification model achieves an identification accuracy of 96.34% for pipeline defect images. Compared with the ResNet50 algorithm, the improved model shows a 1.76% increase in classification accuracy, indicating better recognition performance.

Key words: drainage pipeline; deep learning; defect identification; ResNet; image classification; feature extraction

0 引言

地下排水管道是保障城市运行的重要技术设施, 但随着排水管道的长期使用, 难免出现老化问题^[1-2], 由此带来的各种管道缺陷必然影响城市居

民的正常生活。因此, 定期对管道的健康状况进行检测是市政维护的重要工作^[3]。

目前, 国内排水管道缺陷检测主要使用闭路电视检测系统^[4] (Closed-Circuit Television, CCTV), 其工作流程包括: 使用摄像小车获取管道内部视频图

基金项目: 国家自然科学基金面上项目 (61873337); 上海市青年科技英才扬帆计划 (20YF1409300); 中国高校产学研创新基金 (2021FNB02001)。

作者简介: 沈东明 (1994-), 男, 硕士研究生, 主要研究方向: 深度学习, 模式识别。

通讯作者: 刘翔 (1972-), 男, 博士, 副教授, 硕士生导师, 主要研究方向: 计算机视觉, 机器学习。Email: xliu@sues.edu.cn

收稿日期: 2023-05-18

哈尔滨工业大学主办 ◆ 学术研究与应用

像、人工观看视频图像寻找管道缺陷、根据缺陷信息整理检测报告。其中,人工寻找管道缺陷的步骤存在自动化程度不高、人工效率低下的问题。从大量管道视频中寻找管道缺陷,不仅时间成本巨大,也极易造成视觉疲劳,有产生误判的可能。因此,研究一套能够精确检测排水管道缺陷的视觉系统,对实现城市地下排水管网的高效维护有重要的研究价值和现实意义。

近年来,计算机视觉和深度学习技术常用于各类缺陷检测任务中,也有学者使用该技术对 CCTV 视频中的管道缺陷问题展开研究^[5-6]。Li 等学者^[7]提出了一种基于两级层次深度卷积神经网络的污水管网病害自动分类系统,该系统在分类精度方面表现出较高的性能。Kumar 等学者^[8]开发了一种卷积神经网络来对根部侵入、沉积和裂缝 3 种管道缺陷进行分类,得到的测试准确性、精确率和召回率分别为 86.2%、87.7% 和 90.6%。Situ 等学者^[9]采用了最先进的生成式对抗网络(StyleGANs)模型,利用合成图像对 7 个已知的 CNN 模型进行进一步的微调 and 训练,所训练的 CNN 分类器中,Inception_v3^[10] 的检测精度最高,平均检测准确率为 94%。

在与管道缺陷检测相似的其他缺陷检测任务中,赵辉等学者^[11]利用改进的 ResNet50 分类网络实现果实外观的病害分类,分类精度达到 99.7%。刘欢等学者^[12]针对焊缝缺陷的检测问题,提出一种 CC-ResNet 模型,将不同尺度的卷积核复合为一层卷积,替换单个卷积核结构,并对模型训练过程中的损失函数进行优化。实验可得,该网络的平均召回率和平均准确率为 98.52% 和 95.23%。何静等学者^[13]在处理列车轮对踏面损伤的问题时,将 ResNet50 残差块中的 3×3 卷积替换为一种金字塔拆分注意力(PA)模块,通过车轮对踏面损伤情况的诊断实验表明:该方法能够有效识别列车轮对踏面损伤状态以及周围环境间存在的局部细微差异,诊断精度可达 99.79%。

目前,已有的基于深度学习方法提出的排水管道缺陷检测技术使用数据集中的缺陷样本丰富度较低,鲁棒性较差^[14-15]。

为此,本文以 ResNet 网络为基础,根据排水管道缺陷纹理复杂的特征,对原网络模型进行改进和优化,并利用国外的公开管道缺陷数据集进行数据扩充,经过训练后生成的模型取得了更高的管道缺陷识别能力。

1 数据获取与处理

为了模拟国内城市排水管道检测的实际工作环境,本文使用上海市护塘路地下排水管道某次检修时获取到的 CCTV 视频数据。研究给出的采集装置示意如图 1 所示。



图 1 CCTV 摄像机器人

Fig. 1 CCTV camera robot

在获取的管道视频中截取各类图像共 4 000 张,其中不含缺陷的正常管道图像 3 549 张,含有缺陷的管道图像 445 张,并将管道中最常见的缺陷类型根据其形态特征分为沉积障碍物、管道变型、树根侵入、管道脱节 4 类。由于在实际图像采集过程中能遇到的管道缺陷数量较少,导致同类管道缺陷的丰富度不够,为了提升模型的鲁棒性和实用性,结合 Joakim Bruslund Haurum 提出的大型新颖且公开可用的多标签分类管道缺陷数据集 Sewer-ML^[16-17],来提升不同种类管道缺陷数据的丰富度,并平衡不同管道缺陷图像的数量。最终,通过实际截取与公开数据集的筛选总计得到 6 861 张管道图像。具体分布见表 1。

表 1 分类数据集缺陷分布

Table 1 Defect distribution of image classification data set

| 缺陷种类 | 图像数量 |
|-------|-------|
| 正常管道 | 3 549 |
| 沉积障碍物 | 874 |
| 管道变型 | 966 |
| 管道脱节 | 724 |
| 树根侵入 | 748 |

将训练集、验证集和测试集的图像数量比例定为 8 : 1 : 1,用于后续的管道病害分类训练。图 2 为各类管道缺陷示例。

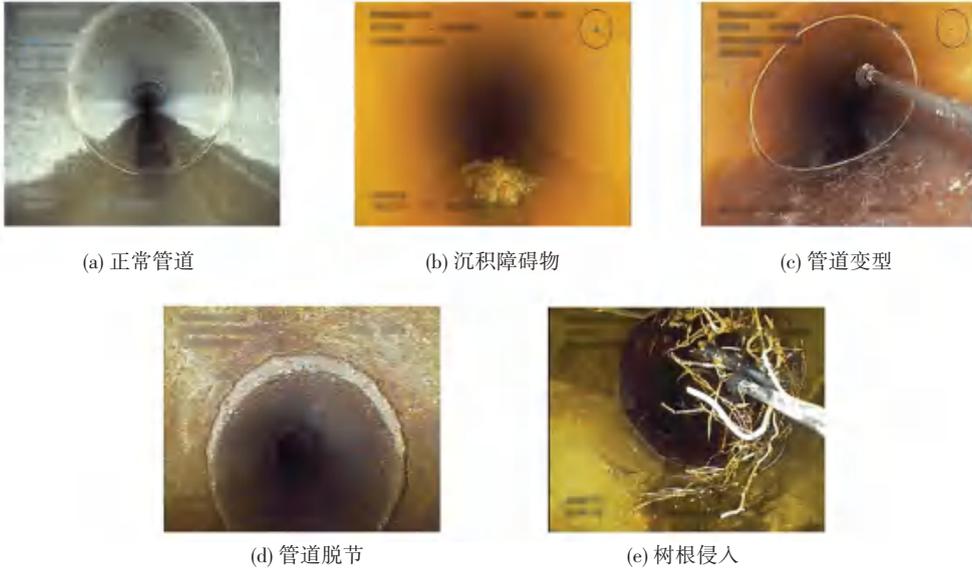


图2 管道图像示例

Fig. 2 Example of pipeline image

2 改进的排水管道缺陷分类算法

本文以 ResNet50^[18]为基础,提出了一种改进的排水管道缺陷分类算法,具体步骤如下:

(1)对 ResNet50 的残差块进行改进,通过并行卷积操作和池化操作,增强管道缺陷纹理的显著特征。

(2)通过注意力机制对(1)中并行操作提取的特征进行权重调节。

(3)使用并联的3个特征提取操作代替网络浅层的3×3池化,从图像的多个维度提取特征,保留更多的原始细节特征。

(4)将主干网络多个阶段提取的特征进行融合,丰富特征的语义信息,提升网络对管道病害的识别精度。

2.1 增强注意力模块

卷积块注意力模块(Convolutional Block Attention Module, CBAM)^[19]是一种将通道注意力模块(Channel Attention Module, CAM)和空间注意力模块(Spatial Attention Module, SAM)串联执行的即插即用模块。

其中,通道注意力模块旨在学习每个通道的重要性权重,并根据这些权重自适应地调整通道的特征响应。具体为:

$$\mathbf{A}_c(\mathbf{F}) = \sigma(M(P_{ca}(\mathbf{F})) + M(P_{cm}(\mathbf{F}))) \quad (1)$$

其中, $\mathbf{A}_c \in R^{C \times 1 \times 1}$ 表示通道注意力模块; $\mathbf{F} \in R^{C \times H \times W}$ 表示输入特征; $P_{ca}(\mathbf{F})$ 表示全局平均池化;

$P_{cm}(\mathbf{F})$ 表示全局最大池化; M 表示多层感知器; σ 表示 Sigmoid 激活函数。在通道注意力模块中,本文将特征图经过池化后的操作改为2个1×1卷积,再使用 Sigmoid 激活函数进行激活,这样可以在提升网络特征表达能力的同时,避免全连接的降维操作产生的信息损失。具体为:

$$\mathbf{A}_c(\mathbf{F}) = \sigma(f^{1 \times 1}(f^{1 \times 1}(P_{ca}(\mathbf{F}))) + f^{1 \times 1}(f^{1 \times 1}(P_{cm}(\mathbf{F})))) \quad (2)$$

空间注意力模块的目标是学习每个空间位置的重要性权重,并根据这些权重自适应地调整空间位置的特征响应。具体为:

$$\mathbf{A}_s(\mathbf{F}) = \sigma(f^{7 \times 7}[P_{ca}(\mathbf{F}); P_{cm}(\mathbf{F})]) \quad (3)$$

其中, $\mathbf{A}_s \in R^{1 \times H \times W}$ 表示空间注意力模块, $f^{7 \times 7}$ 表示核为7的卷积。该模块通过分别提取特征通道上的最大值和平均值来获取特征的空间信息,但是这种处理方式存在空间信息利用不充分的问题。本文在原有操作的基础上,增加一个1×1卷积操作挤压特征通道,输出一个通道为1的特征图,以此获取更丰富的空间特征信息。改进后的空间注意力模块将3个特征图进行拼接,最终采用7×7卷积核进行运算以得到空间注意力图,从而更好地把握空间信息。具体为:

$$\mathbf{A}_s(\mathbf{F}) = \sigma(f^{7 \times 7}[P_{ca}(\mathbf{F}); P_{cm}(\mathbf{F}); f^{1 \times 1}(\mathbf{F})]) \quad (4)$$

改进之后的注意力机制结构如图3所示,将改进的通道注意力模块和改进的空间注意力模块按照原来的串联方式进行结合,形成增强注意力模块(Enhanced Attention Module, EAM)。

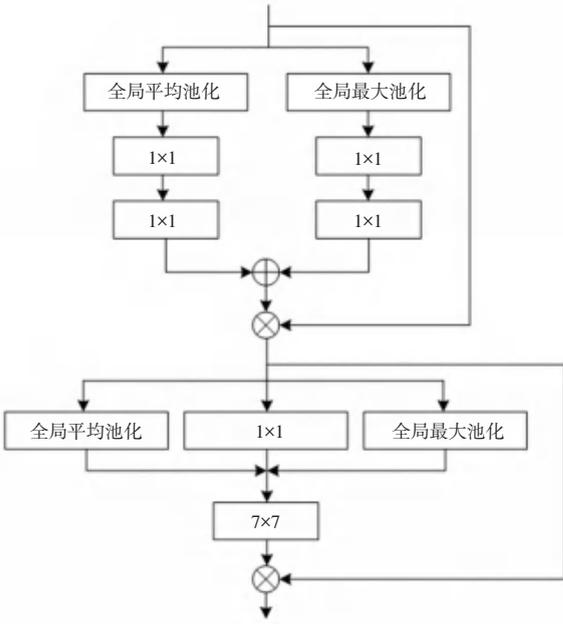


图 3 增强注意力模块 (EAM) 处理流程

Fig. 3 Flowchart of Enhanced Attention Module processing

2.2 MEAM-Res 模块

在排水管道病害的实际分类任务中,由于存在管道背景复杂、病害种类多、病害大小不同并且形态各异、病害类内差异大、类间差异小等特点,容易出现错分类的情况,从而限制模型的精度。因此,需要网络提取出更有用的信息,突出关键特征,来做出更精准的判断。因此,本文在 ResNet 模型的每一个基础残差块中添加 EAM 注意力机制,让网络自适应调节特征层的权重,抑制无效特征。并在此基础上做进一步改进,提出 MEAM-Res 模块。

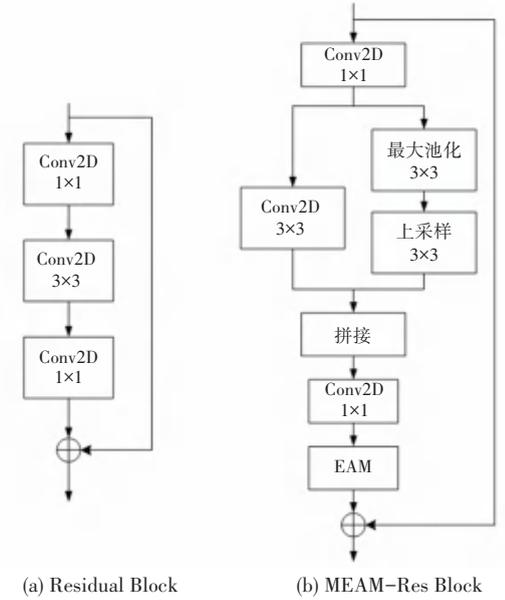
残差块及改进结构处理流程如图 4 所示。MEAM-Res 模块将残差连接中的卷积层替换成一个并联的多分支结构。将一个最大池化和上采样操作与 3×3 卷积并联,最大池化层能够保留特征图一定范围内的最大值、即特征图中的显著特征,再利用上采样操作放大显著特征,恢复原有特征图尺寸。此后将并行处理得到的特征图进行拼接,利用 1×1 卷积调整通道数。

并行的多分支模块只是在通道维度上将不同尺度的特征进行拼接,不能反映不同通道间特征的相关性和重要性,而 EAM 模块中的通道注意力机制可以学习通道之间的关系,对每个通道的权重进行分配,实现通道间特征的融合。

2.3 特征保留模块

本文将 ResNet50 网络的浅层在处理输入数据的时候用到的池化层进行优化,使用一个特征保留模块 (Feature Retaining Block, FRB),将池化操作调

整为 3 个同时进行的特征提取操作,用于从图像的多个维度提取特征,并且使用空洞卷积^[20]来提升网络的感受野,最后将并行操作得到的特征进行融合。特征保留模块 (FRB) 处理过程如图 5 所示。



(a) Residual Block (b) MEAM-Res Block

图 4 残差块及改进结构处理流程

Fig. 4 Residual block and its improved structure processing flow

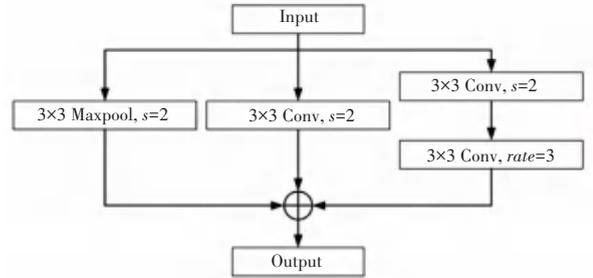


图 5 特征保留模块 (FRB) 处理流程

Fig. 5 Flowchart of Feature Retaining Block processing

FRB 模块包含 3 个分支,分别为:池化分支、卷积分支和空洞卷积分支。其中,池化分支使用大小为 3×3、步长为 2 的最大池化;卷积分支使用卷积核大小为 3×3、步长为 2 的卷积操作;空洞卷积分支则是在卷积操作后再进行膨胀系数为 3、步长为 1 的空洞卷积。将这 3 个分支的输出进行特征融合,以提取更加丰富的图像特征,从而提高模型性能。

2.4 多尺度特征融合

由于排水管道背景比较复杂,管道缺陷的类内差异较大,为了提高模型对管道病害的识别能力,需要获取更丰富的管道纹理特征。为此,本文使用一种垂直信息融合的多尺度特征融合方式。

残差块是 ResNet 的基本结构,而整个 ResNet50 的网络结构可以看成是由 4 个大残差块组成,每一个大残差块又由多个基础残差块组成。本文的多尺

度特征融合方式如图6所示。

第1个大残差块输出的特征经过多次下采样,分别和第2个、第3个、第4个大残差块输出的特征进行融合。这里,第1个大残差块输出的特征尺度为 $56 \times 56 \times 256$,第2个大残差块输出的特征尺度为 $28 \times 28 \times 512$,第3个大残差块输出的特征尺度为 $14 \times 14 \times 1024$,第4个大残差块输出的特征尺度为 $7 \times 7 \times$

2048 。下采样包括2个卷积操作,用1个卷积核为 2×2 、步长为2的卷积操作调整特征的长度和宽度,再用1个 1×1 的卷积核来调整通道数。通过求和运算的方式融合多个特征。

同理,第2个大残差块的输出和第3个大残差块的输出分别经过下采样之后和第4个大残差块的输出融合。

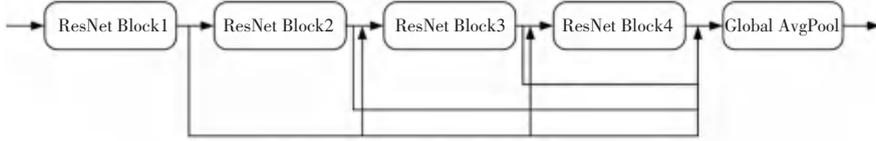


图6 多尺度特征垂直融合示意图

Fig. 6 Schematic diagram of vertical fusion of multi-scale features

3 整体结构设计

本文算法流程如图7所示。在ResNet50网络的基础上,将浅层的特征处理时使用的 3×3 池化层替换成FRB模块;基本残差块替换成MEAM-Res模块,最后使用多尺度特征融合方式提高特征表达能力。

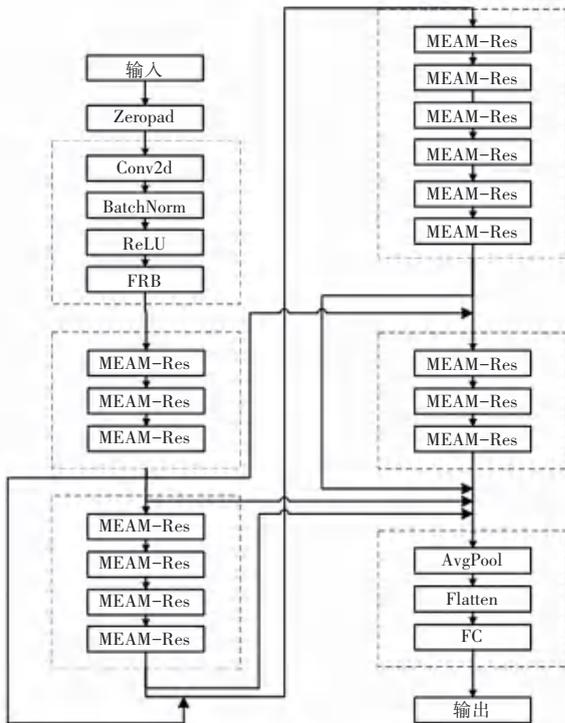


图7 改进ResNet50网络结构图

Fig. 7 Diagram of improved ResNet50 network structure

4 实验与结果分析

4.1 评价指标

为了验证改进的ResNet50网络的分类性能,需

要设置评估指标。学术界普遍接受的评价指标是使用精确率(Precision, P)、召回率(Recall, R)和准确率(Accuracy, Acc)。表达式如下:

$$P = \frac{TP}{TP + FP} \quad (5)$$

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

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

其中, P 表示模型正确预测的正样本数占所有正样本数的比例; R 表示模型正确预测的正样本数占所有正样本数的比例; Acc 表示模型正确分类的样本数占总样本数的比例; TP 表示预测为正且真实为正的样本数; FP 表示预测为正但真实为负的样本数; FN 表示预测为负但真实为正的样本数; TN 表示预测为负且真实为负的样本数。

4.2 训练方式

为了缩短模型训练时间和减少资源消耗,同时降低过拟合风险并提高模型泛化能力和训练效果,在训练开始前使用mini-ImageNet数据集对改进后的模型进行预训练,并使用预训练好的权重进行模型初始化。使用SGD优化器进行网络优化,训练200个epoch,Batch Size设置为128,设置使用cos方式进行学习率的自适应调整。

4.3 模型性能评估

本文使用包含5类管道图像的测试集对最终模型进行了评估,分别为正常管道(NM)、沉积障碍物(AF)、管道变型(DE)、管道脱节(FS)和树根侵入(RO)。采用混淆矩阵对模型进行了可视化的评估,详见图8。图8的混淆矩阵中,浅色部分表示分类

错误的样本数量, 对角线上的深色部分表示分类正确的样本数量。

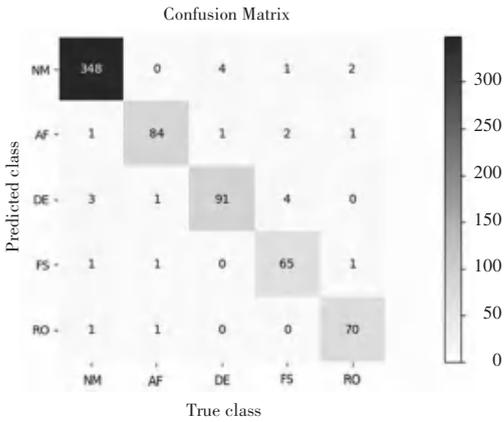


图 8 本文算法在测试集上的混淆矩阵

Fig. 8 Confusion matrix of the proposed algorithm on test set

可以看出, 683 个测试样本中, 共有 25 个样本被误分类, 准确率 (Acc) 为 96.34%。其中, 3 个正常管道被识别成变型管道, 4 个变型管道被识别成正常管道, 主要原因是有一些管道在维修之后, 形态上和正常管道有些许差异, 容易被识别成存在变型的问题。有 1 个正常管道被识别成管道脱节, 也有 1 个管道脱节被认为是正常管道, 是因为在管道的接口处原本就会存在一些缝隙, 容易发生混淆。有 4 个脱节被误识别成了变型, 主要原因是脱节和变型经常会同时存在。树根侵入和正常管道发生混淆的也较多, 主要是有的树根比较细小, 不易察觉。

总之, 由于管道缺陷存在类内差异大、类间形态相似的问题, 总会有些轻度的管道缺陷出现误识别, 但是如果缺陷情况比较严重, 一般不会出现错误分类。

4.4 注意力机制选择

本文在改进残差块时嵌入了注意力机制来抑制

无效的特征信息, 提升模型的特征表达能力, 而在深度学习图像处理中有多种不同的注意力机制实现方式, 常见的有 SENet、ECA、CBAM 等。

为了在改进残差块时选用合适的注意力机制, 分别在残差块中嵌入不同的注意力机制进行对比实验, 验证不同注意力机制对提升模型预测能力的有效性。实验模型为本文改进后的模型, 实验结果见表 2。

表 2 不同注意力机制性能对比

Table 2 Comparison of the performance of different attention mechanisms

| 注意力机制 | 精确率/% | 召回率/% | 准确率/% |
|---------|--------------|--------------|--------------|
| SE | 94.82 | 93.79 | 95.90 |
| ECA | 95.07 | 94.54 | 96.05 |
| CBAM | 95.53 | 93.85 | 96.19 |
| EAM(本文) | 95.43 | 94.90 | 96.34 |

由表 2 可以看出, 相对于单纯使用通道注意力机制 (1、2 两行), 使用通道和空间注意力机制相结合的方式 (3、4 两行) 对本文的改进模型有更好的特征权重调节效果。对比嵌入不同注意力机制的模型准确率可知, 模型中嵌入 EAM 模块较 CBAM 模块有更好的识别性能。

4.5 消融实验

本文比较了 4 种网络模型的性能: 原始 ResNet50 网络、原始 ResNet50 网络加入本文 2.2 小节提出的 MEAM-Res 模块得到的 ResNet50-a 模型、ResNet50-a 模型加入 2.3 小节提出的 FRB 模块得到 ResNet50-b 模型、ResNet50-b 模型使用 2.4 小节的方法融合多尺度特征信息得到 ResNet50-c 模型。模型构成和实验结果见表 3。

表 3 实验模型比较

Table 3 Comparison of experimental models

| 网络模型 | 模型构成 | 精确率/% | 召回率/% | 准确率/% |
|------------|--------------------|--------------|--------------|--------------|
| ResNet50 | ResNet50 | 93.07 | 93.25 | 94.58 |
| ResNet50-a | ResNet50+MEAM-Res | 95.53 | 93.85 | 95.90 |
| ResNet50-b | ResNet50-a+FRB | 95.90 | 94.11 | 96.05 |
| ResNet50-c | ResNet50-b+多尺度特征融合 | 95.43 | 94.90 | 96.34 |

表 3 显示了使用本文测试集对使用相同训练策略的 4 个网络模型训练后得到的结果。从表 3 中可以得知, 与原始 ResNet50 网络相比, 仅改进残差块部分, 分类准确率提升了 1.32 个百分点, 加入 FRB 模块后, 分类准确率又提升了 0.15 个百分点, 最后再使用多尺度特征融合方式提升网络的特征丰富

度, 得到的分类准确率为 96.34%, 与原始网络模型相比, 精确度提升了 1.76 个百分点。说明本文提出的 3 种改进方式都能有效提高网络模型对排水管道缺陷的分类精度, 同时在召回率和精确率上都有较好的表现。

4.6 不同算法模型对比

本文网络算法分别与文献[7]、文献[8]和文献[9]进行对比,同时,本文也和一些经典的分类网络在网络训练的准确率上做了对比。其对比结果见表4。由表4可以看到,本文提出的模型在准确率上比文献[7]、文献[8]和文献[9]分别高出3.95、0.73和0.59个百分点,并且在精确率和召回率上,本文的模型都有更好的表现。与VGG16、AlexNet和GoogleNet对比,本文网络也有更好的识别准确率。

表4 不同模型对比实验

Table 4 Comparative experiments of different models %

| 网络模型 | 精确率 | 召回率 | 准确率 |
|-----------|--------------|--------------|--------------|
| VGG16 | 94.07 | 90.41 | 93.70 |
| AlexNet | 89.79 | 90.21 | 91.65 |
| GoogleNet | 94.19 | 92.54 | 94.44 |
| 文献[7] | 90.75 | 90.83 | 92.39 |
| 文献[8] | 95.26 | 94.00 | 95.61 |
| 文献[9] | 94.90 | 94.22 | 95.75 |
| 本文 | 95.43 | 94.90 | 96.34 |

5 结束语

本文根据排水管道图像背景复杂、缺陷识别难度高的特点,提出了一种改进ResNet50的神经网络分类模型,通过改进网络的基础残差块,增强模型对管道缺陷纹理特征的提取能力。使用特征保留模块代替浅层网络的池化操作,从图像的多个维度提取特征,避免因池化操作产生的特征信息丢失,提升了模型的分类精度。最后通过融合多尺度特征,获取更丰富的特征信息,增强网络输出特征的丰富度。实验结果表明,在排水管道缺陷图像分类问题中,本文提出的网络可以更好地获得图像信息,抽取更有效的图像特征,识别的准确率可以应用于工程实际。

参考文献

- [1] 肖倩, 王俊然, 陈辉, 等. 深圳市某片区排水管道 CCTV 检测评估与修复方案[J]. 给水排水, 2019, 55(9): 109-114.
- [2] WIRAHADIKUSUMAH R, ABRAHAM D, ISELEY T. Challenging issues in modeling deterioration of combined sewers [J]. Journal of Infrastructure Systems, 2001, 7(2): 77-84.
- [3] 高原, 王红武, 张善发, 等. 合流制排水管道沉积物及其模型研究进展[J]. 中国给水排水, 2010, 26(2): 15-18, 27.
- [4] 冯成会, 郑洪标. CCTV 检测与评估技术在水库排水涵管检测

- 中的应用[J]. 测绘通报, 2013 (S2): 131-134.
- [5] 王俊岭, 邓玉莲, 李英. 排水管道检测与缺陷识别技术综述[J]. 科学技术与工程, 2020, 20(33): 13520-13528.
- [6] ROMANOVA A, HOROSHENKOV K V, TAIT S J, et al. Sewer inspection and comparison of acoustic and CCTV methods [J]. Water Management, 2013, 166(2): 70-80.
- [7] LI Dawei, XIE Qian, YU Zhenghao, et al. Sewer pipe defect detection via deep learning with local and global feature fusion [J]. Automation in Construction, 2021, 129: 103823.
- [8] KUMAR S S, ABRAHAM D M, JAHANSAHI M R, et al. Automated defect classification in sewer closed circuit television inspections using deep convolutional neural networks [J]. Automation in Construction, 2018, 91: 273-283.
- [9] SITU Z, TENG Shuai, LIU Hanlin, et al. Automated sewer defects detection using style-based generative adversarial networks and fine-tuned well-known CNN classifier [J]. IEEE Access, 2021, 9: 59498-59507.
- [10] SZEGEDY C, VANHOUCHE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA; IEEE, 2016: 2818-2826.
- [11] 赵辉, 乔艳军, 王红君, 等. 基于双通道注意力机制的 ResNet 果实外观品质分类[J]. 光电子·激光, 2022, 33(6): 643-651.
- [12] 刘欢, 刘晓佳, 王宇斐, 等. 基于复合卷积层神经网络结构的焊缝缺陷分类技术[J]. 航空学报, 2022, 43(S1): 165-172.
- [13] 何静, 侯娜, 张昌凡, 等. 基于金字塔拆分注意力的列车轮对踏面损伤诊断[J]. 中国安全科学学报, 2022, 32(5): 35-40.
- [14] HALFAWY M R, HENGMEECHAI J. Automated defect detection in sewer closed circuit television images using histograms of oriented gradients and support vector machine [J]. Automation in Construction, 2014, 38: 1-13.
- [15] CHENG J C P, WANG Mingzhu. Automated detection of sewer pipe defects in closed-circuit television images using deep learning techniques [J]. Automation in Construction, 2018, 95: 155-171.
- [16] 陈希刚. 市政管道 CCTV 检测技术应用 [J]. 水利水电施工, 2019(1): 102-105.
- [17] HAURUM J B, MOESLUND T B. Sewer-ML: A multi-label sewer defect classification dataset and benchmark [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA; IEEE, 2021: 13456-13467.
- [18] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA; IEEE, 2016: 770-778.
- [19] SANGHYUN W, JONGCHAN P, JOON-YOUNG L, et al. CBAM convolutional block attention module [C]//Proceedings of the European Conference on Computer Vision (ECCV). Munich, Germany; Springer, 2018: 3-19.
- [20] YU F, KOLTUN V, FUNKHOUSER T. Dilated residual networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Hawaii, USA; IEEE, 2017: 472-480.