

基于改进的 GoogleNet-ResNet 算法的路基病害智能分类方法

陈登峰¹, 杨小燕¹, 张温², 何拓航¹, 陈俊彤³

(1. 西安建筑科技大学 建筑设备科学与工程学院, 西安 710000;

2. 西安建筑科技大学 管理学院, 西安 710000;

3. 西安建筑科技大学 公共管理学院, 西安 710000)

摘要: 针对路基病害分类算法存在的复杂病害辨识难度大、多视图雷达图像特征利用不充分等问题, 提出一种基于改进的 GoogleNet-ResNet 算法的路基病害智能分类方法; 首先, 引入坐标注意力和改进的 Inception 模块对 GoogleNet 网络结构进行优化; 然后, 利用改进的 GoogleNet 学习 c-scan 数据特征剔除非目标病害, 实现病害目标的粗分类; 最后, 将分类成病害的 b-scan 数据输入基于迁移学习的 ResNet50, 实现病害的细分类; 实验表明, 改进的 GoogleNet 进行病害粗分类的准确率可达 98.2%, 检测速度可达 90.9 fps; 基于迁移学习的 ResNet50 进行病害细分类的准确率可达 90.5%, 检测速度可达 52.6 fps; 该算法的准确率比单独的改进的 GoogleNet 网络高 10.1%, 比单独的 ResNet50 网络高 7.4%, 有效地提高了道路路基病害的识别精度与效率。

关键词: 道路工程; 路基病害识别; 级联神经网络; 多视图雷达图像; 三维探地雷达

Intelligent Classification Method for Subgrade Disease Based on Improved GoogleNet-ResNet Algorithm

CHEN Dengfeng¹, YANG Xiaoyan¹, ZHANG Wen², HE Tuohang¹, CHEN Juntong³

(1. School of Building Services Science and Engineering, Xi'an University of Architecture and Technology, Xi'an 710000, China;

2. School of Management, Xi'an University of Architecture and Technology, Xi'an 710000, China;

3. School of Public Management, Xi'an University of Architecture and Technology, Xi'an 710000, China)

Abstract: There are the shortages of complex disease identification and poor utilization of multi-view radar image features in subgrade disease classification algorithms, an intelligent classification method for roadbed diseases based on an improved GoogleNet-ResNet algorithm is proposed. Firstly, the coordinate attention and improved Inception modules are introduced to optimize the GoogleNet network structure. Then, the improved GoogleNet is utilized to learn the c-scan data features and eliminate non-target diseases, achieving the coarse classification of the disease targets. Finally, the b-scan data classified as the diseases is input into the ResNet50 model based on the transfer learning to achieve the fine classification of the diseases. The results show that the accuracy of the improved GoogleNet reaches by 98.2% for coarse disease classification, and the detection speed by 90.9 fps. The accuracy of the disease sub-classification of ResNet50 based on the transfer learning reaches by 90.5%, and the detection speed by 52.6 fps. The accuracy of the proposed algorithm is 10.1% higher than that of the improved GoogleNet network, and 7.4% higher than that of the ResNet50 network. This algorithm effectively improves the recognition accuracy and efficiency of roadbed disease detection.

Keywords: road engineering; subgrade disease recognition; cascade neural network; multi view radar images; 3D ground penetrating radar

0 引言

由于受到雨雪等自然天气、车辆荷载等人为因素的影响, 道路在运营过程中会出现不同程度的路基病害, 严重影响国民出行安全以及交通安全, 因此及时检测和维

护十分必要。探地雷达因其快速便捷、场地适应能力强等优势, 广泛应用于地雷探测^[1]、道路检测^[2]等领域。由于道路地下目标具有复杂的几何形状且容易受到其他物体的干扰, 需要专家对雷达图像进行解译, 而这一过程费时费力。随着人工智能算法的快速发展, 深度学习方法具有更高的

收稿日期: 2023-07-31; 修回日期: 2023-11-23。

基金项目: 陕西省软科学研究计划项目(2021KRM029); 西安市高校院所人才服务企业项目(23GXFW0045)。

作者简介: 陈登峰(1976-), 男, 博士, 硕士生导师。

通讯作者: 张温(1994-), 男, 博士研究生。

引用格式: 陈登峰, 杨小燕, 张温, 等. 基于改进的 GoogleNet-ResNet 算法的路基病害智能分类方法[J]. 计算机测量与控制, 2024, 32(8): 250-256, 294.

特征学习能力和表征能力, 因此已经被广泛应用于道路地下目标的自动检测^[3], 有效地提高了雷达图像的解析效率。

二维探地雷达因其便携、价格便宜等优势, 被广泛应用于各大科研院所、高校。研究人员针对二维探地雷达数据展开自动化路基病害检测研究。文献 [4-6] 分别利用 Faster RCNN^[7] 研究了不同场景下 b-scan 图像中的双曲线检测问题。文献 [8] 利用 YOLOV3^[9] 网络模型研究城市地下空间中典型目标的双曲线检测方法。文献 [10] 建立多级 CNN 对路基病害进行自动分类识别。文献 [11] 研究基于 GAN 的深度学习框架, 生成新的训练数据并通过端到端的网络检测双曲线特征。文献 [12] 利用 YOLOV4^[13] 研究针对道路中亚表面裂纹和空洞的自动检测方法。然而, 上述方法都是基于单输入的雷达图像数据进行实现的, 不适用于目前常见的三维探地雷达收集到的多视图雷达图像数据。且仅使用 b-scan 图像, 无法将具有相似的双曲线特征的脱空和管道区分开。

随着技术的进步和三维探地雷达在道路检测领域的推广^[14], 越来越多的多视图雷达图像数据被采集, 为病害的分类提供了更多的信息。研究人员开始利用三维数据块或多视图雷达图像并结合深度学习算法来识别道路路基病害。文献 [15] 提出一种基于三维卷积神经网络, 直接使用三维数据块进行道路地下目标分类的方法。文献 [16] 将三维卷积神经网络与 Kirchhoff 偏移相结合来检测地下管道, 并证明三维卷积神经网络比二维卷积神经网络具有更好的分类精度。文献 [17] 将深度三维卷积网络和多镜像编码用于三维探地雷达数据, 进行地下目标分类。这种将三维数据输入三维卷积网络的方法, 可以完全保留三维数据的完整特征, 但是计算量很大, 对硬件要求很高。面对现实工程雷达数据, 需要当场检测、当场对疑似病害进行钻孔验证, 因此过长的耗时制约了这类算法在实际工程中的应用。文献 [18] 利用了新颖的二维网格图像, 该图像由三维数据中若干个横向和纵向图像组成, 通过训练 AlexNet 网络进行道路地下目标分类。文献 [19] 利用二维网格图像训练卷积神经网络来检测地下空腔。这种融合多视图雷达图像的方法, 由于病害体积差异较大, 选取的多张 b-scan 或 c-scan 图像可能不包含病害信息, 向网络引入无关特征, 不利于病害识别。

级联网络可以适应特定的网络任务^[20], 允许每个网络集中学习其特定任务的相关特征从而提高网络检测的整体性能, 已广泛应用于医学^[21]、遥感^[22]、交通^[23]、人脸识别^[24]等领域。不同视图的雷达图像在识别任务中发挥的作用和适用的网络均有所不同, 因此在该识别任务中有必要引入级联网络进行雷达图像的分析 and 特征挖掘。

基于此, 本文提出一种基于级联结构的多视图特征融合的深度学习网络结

构, 针对不同视图的图像特征设计合适的网络结构, 从而提升路基病害的识别准确率。首先, 通过采集道路路基病害的多视图雷达图像构建道路路基病害数据集。其次, 利用改进的 GoogleNet 学习 c-scan 的数据特征剔除非病害目标, 实现病害目标粗分类。最后, 使用基于迁移学习的 ResNet50 学习病害目标的 b-scan 图像特征, 实现病害目标的细分类。所提出的算法通过在中国广东省广州市的城市道路上的现场应用得到验证。

1 基于改进的 GoogleNet-ResNet 的路基病害分类方法

1.1 道路地下目标特征分析

三维探地雷达系统探测道路地下目标时, 多组单通道雷达同时工作可形成 b-scan、c-scan、d-scan 共 3 个视图的雷达图像, 可以很好地表征道路地下目标的空间信息。由于 d-scan 视图的雷达图像不能反映完整的病害信息, 因此本文仅分析道路地下目标 b-scan 以及 c-scan 的雷达图像特征。图 1 分别为管道、竖井、正常区域、疏松、脱空的 b-scan、c-scan 图像。管道在 b-scan 图像中呈现双曲线形状, 在 c-scan 图像中呈现四边形特征。竖井在 b-scan 图像中呈现黑白交替条状特征, 在 c-scan 图像中呈现圆形特征。正常区域在 b-scan 图像、c-scan 图像中无明显特征。疏松在 b-scan 图像中呈现不规则的波浪形状且明暗交错, c-scan 图像会出现不规则的亮色区域。脱空随病害体积的不同, 特征也不尽相似。当脱空病害体积较小时, 其 b-scan 图像呈现类似双曲线特征, c-scan 图像呈现小面积不规则亮色区域。当脱空病害体积较大时, b-scan 图像出现明暗相交的横直条纹, c-scan 图像呈现不规则的亮色区域。

三维探地雷达数据包含更丰富的多视图雷达图像信息, 即使不同的道路地下目标的一个视图雷达图像特征相似, 但在另一个视图的雷达图像中特征会存在差异。例如, 管道和空洞在 b-scan 图像中会呈现相似的双曲线特征, 但在 c-scan 图像中会存在不同的特征。脱空和疏松在 c-scan 图像中均呈现不规则的亮色区域, 但是在 b-scan 图像中特征会存在较大差异。因此, 本文使用道路地下目标的 b-scan 和 c-scan 图像共同构建合适的网络模型实现道路路基病害分类, 以提高分类精度。

1.2 网络结构

由于 c-scan 数据集的背景区域与目标区域色彩、纹理

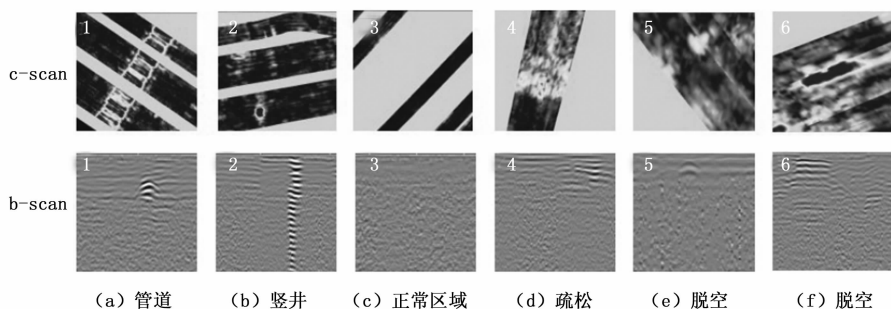


图 1 GPR 图像特征

等特征差异较大，易于用底层特征进行分类，且不同目标的尺寸差异较大，需多尺度感受野提取特征区域，防止局部信息丢失；而 b-scan 数据集的背景区域与目标区域色彩、纹理等特征差异较小，需高层特征辅助病害识别。GoogleNet^[25] 中包括多个 inception 模块，该结构提高了网络内部计算资源的利用率，在增加网络的深度和宽度的同时保证计算预算不变；并且该结构具有多尺度卷积核可提取多尺度特征，可以更快学习 c-scan 数据中的颜色、形状特征。ResNet50^[26] 中残差结构有较强的特征提取能力，能够解决网络深度带来的网络退化和梯度消失等问题，而且残差块中的跳跃连接没有增加模型计算量，可以提取 b-scan 数据的高层语义特征。

因此，本文提出一种基于级联结构的多视图特征融合的深度神经网络结构，由改进的 GoogleNet 和基于迁移学习的 ResNet50 网络组成。第一级网络利用改进的 GoogleNet 学习道路地下目标的 c-scan 图像特征，从而实现病害目标与非病害目标的快速初筛。将第一级网络得到的疑似病害目标对应的 b-scan 图像输入基于迁移学习的 ResNet50 中，实现路基病害的精确分类。具体结构如图 2 所示。该网络结构可以充分利用多视图雷达图像的特征信息，从而提高模型对易混淆目标的识别能力。

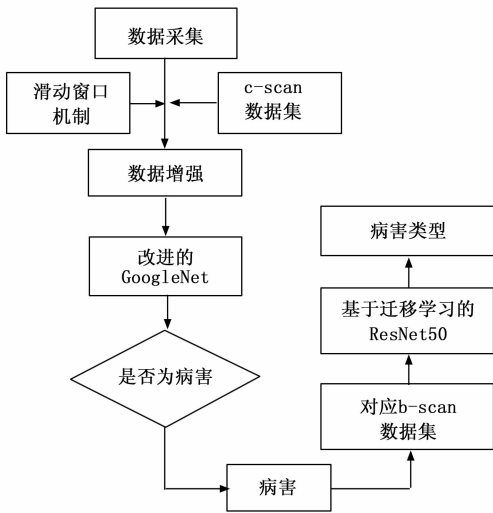


图 2 所提算法流程图

1.2.1 改进的 GoogleNet

1.2.1.1 坐标注意力机制

坐标注意力机制 (CA)^[27] 可以在保持通道信息的同时获取位置信息，它包括坐标信息嵌入模块和坐标注意力生成模块。

坐标信息嵌入模块首先使用尺寸为 $(H, 1)$ 或 $(1, W)$ 的池化核分别沿着水平坐标和垂直坐标对每个通道进行编码，得到两个独立的方向感知特征图。两个嵌入特定方向信息的特征图被编码成两个注意力图，每个注意力图都能捕获输入特征图在一个空间方向上的长程依赖。高度

为 h 的第 c 通道的输出，如式 (1) 所示，宽度为 w 的第 c 通道的输出，如式 (2) 所示：

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (1)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq i < H} x_c(j, w) \quad (2)$$

其中： h 和 w 是与当前注意模块相对应的输入特征图的高度和宽度， H 和 W 为池化核的尺寸， $z_c^h(h)$ 表示高度为 h 的第 c 通道的输出， $z_c^w(w)$ 宽度为 w 的第 c 通道的输出。

坐标注意力生成模块将获取到的 2 幅特征图像拼接，然后采用 1×1 卷积操作将通道维数压缩，并使用 ReLU 函数进行非线性激活，再将获取到的结果沿空间维度分解为水平注意张量和垂直注意张量，再使用 2 组 1×1 的卷积增加图像通道数，并使用 Sigmoid 函数进行非线性激活。最后，将获取的 2 个注意力图像与输入特征图像相乘，完成坐标注意力的施加。CA 模块的具体结构如图 3 所示。

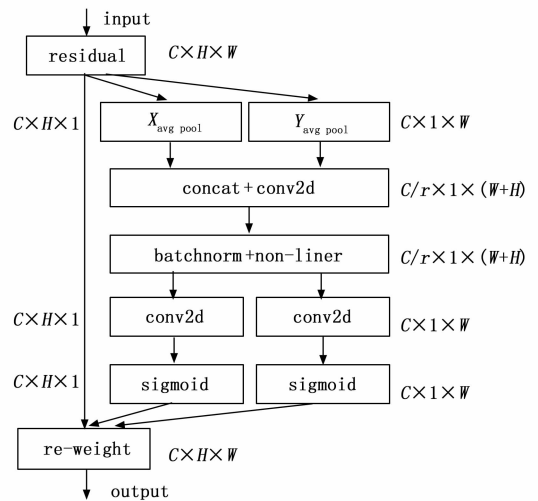


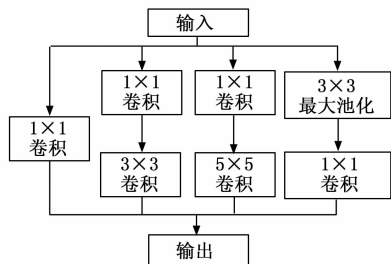
图 3 坐标注意力机制

1.2.1.2 改进的 Inception 模块

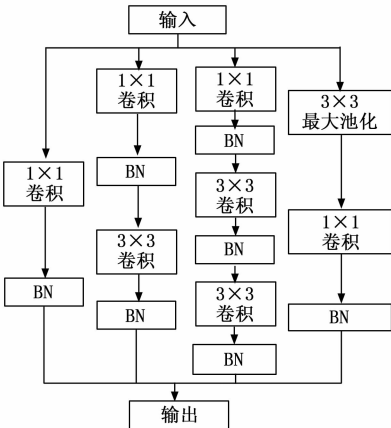
Inception 模块的大尺度卷积核获得大感受野的同时也带来了更多的参数，原始 Inception 模块如图 4 (a) 所示。改进的 Inception 模块通过 2 个 3×3 的卷积核代替 5×5 的卷积核，在不改变感受野大小的同时，能大大减少模型参数。此外，批归一化 (BN) 操作可以在不增加模型参数的同时提升模型计算速度和训练精度，因此，本文在 Inception 模块的卷积层后分别添加 BN 层，改进的 Inception 模块如图 4 (b) 所示。

1.2.1.3 改进的 GoogleNet 网络

原始的 GoogleNet 网络由 9 个 Inception 模块、3 个卷积层、3 个池化层、2 个辅助分类器模块以及 1 个全连接层组成。本文首先简化 GoogleNet 的网络结构从而减少模型参数量，然后引入注意力机制提高模型的特征表达能力，改进后 GoogleNet 网络结构如图 5 所示。首先，删除 Inception



(a) 原始的Inception模块



(b) 改进的Inception模块

图 4 Inception 模块结构

模块之前的两个局部响应归一化层; 然后, 使用 8 个改进的 Inception 模块代替原始的 9 个 Inception 模块; 其次, 只保留 1 个辅助分类器模块并将其放在第 5 个改进的 Inception 模块之后; 最后, 将模型最后的全连接层替换成全局平均池化层, 加快模型计算速度。同时, 在第 4 个改进的 In-




图 5 改进的 GoogleNet 网络结构


ception 模块后加入一个 CA 模块, 使网络模型聚焦在感兴趣的局部信息中, 从而提高对小目标的检测准确率。

1.2.2 基于迁移学习的 ResNet50


第二级网络为基于迁移学习的 ResNet50, 图像传入网络后, 经过第一次卷积池化后传入 16 个残差块中, 在随后的每个 Stage 中都要经过卷积 (Conv) 和 BN 的操作, 即 Conv Block, 然后经过多个输入和输出维度都一致的 Identity Block, 在经过 Stage 2~5 的卷积之后, 通过全局平均池化层 (GAP) 将数据压缩成一维数组, 再与全连接层 (FC) 和 softmax 层连接, 输出待评估图像属于某类病害, 如图 6 (a) 所示。

其中, Conv Block 用于改变网络的维度, 先通过 1×1 卷积降维, 再进行 3×3 卷积, 再通过 1×1 卷积升维, 虚线用 1×1 卷积降维, 如图 6 (b) 所示。Identity Block 用于加深网络, 不经过卷积网络降维, 直接将输入与 1×1 卷积输出相加, 如图 6 (c) 所示。


由于道路路基病害的 b-scan 图像具有类间差异小、类内差异大等特征, 需要大量的路基病害数据集来训练 ResNet50, 然而道路路基发生病变的概率较低导致可用的带有



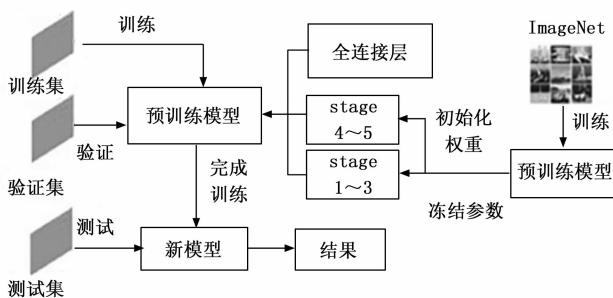
(a) ResNet50网络结构



(b) Conv Block结构



(c) Identity Block结构



(d) 迁移学习的流程

图 6 基于迁移学习的 ResNet50

标注的病害图像数量有限。因此，先采用 ImageNet 数据集^[28]对 ResNet50 进行预训练。利用迁移学习，从源域和目标域的数据中找到可以共享的模型参数，再将经过微调的权重和参数加载到基于 ResNet50 的深度学习模型中。文献^[29]试验发现低层特征具有很强的迁移能力，而高层卷积层的特征都是和具体任务相关的抽象特征，不适合进行迁移，需要在新数据集上再学习训练。基于此结论，本文采用低层网络参数冻结，高层网络参数使用路基病害图像数据训练的迁移学习方法，如图 6 (d) 所示。

2 多视图雷达图像数据集

2.1 数据采集

本研究利用意大利 IDS 公司 STREAM-UP 三维探地雷达采集中国广东省广州市道路地下目标的三维探地雷达多视图图像数据，对提出的方法进行实验验证。对广东省广州市多条城市道路进行三维雷达探测，共采集 370 个管道、370 个竖井、370 个正常区域、370 个脱空病害和 370 个疏松病害。为了验证 GPR 检测的正确性，对脱空和疏松病害进行钻孔取样。为了保证采集得到的样本 b-scan 和 c-scan 图像的位置关系一一对应，对每个样本首先采集 c-scan 图像并确定样本的中心位置，然后选取样本中心位置对应的 b-scan 图像。

2.2 数据增强

实际工程中能采集到的样本数量较少，为提高模型鲁棒性，需进行数据扩增操作。首先将 b-scan、c-scan 图像的大小统一为 (224, 224)；然后，按照 8 : 1 : 1 的比例划分成训练集、验证集、测试集；最后，使用数据增强技术分别对训练集、验证集和测试集进行数据扩充，增加数据集的样本多样性，提高模型在实际应用中的鲁棒性。本文主要采用水平翻转、旋转、随机擦除、平移和亮度调整来增强数据集，具体图像扩增示例如图 7 所示。

2.3 数据集制作

本文需要制作两个数据集，一个数据集用于本文所提的方法，该数据包括用于第一级网络的 c-scan 数据集和用于第二级网络的 b-scan 数据集。第二个数据集用于对照实验，将 b-scan、c-scan 拼接成二维图像，作为单级网络的输入。

制作第一级网络输入的 c-scan 数据集时，为保证样本均衡选择 370 个管道、370 个竖井、370 个正常区域、185

个脱空病害和 185 个疏松病害的 c-scan 图像，并将脱空、疏松归为同一类，管道、竖井、正常区域各自为一类，并按上述扩增方法进行扩增。制作第二级网络输入的 b-scan 数据集时，仅使用 370 个脱空和 370 个疏松的 b-scan 图像，并按上述扩增方法进行扩增。表 1 描述了文章所提方法的数据集大小。

表 1 级联网络数据集

数据集	类型	训练集	验证集	测试集
c-scan	管道	888	111	11
	竖井	888	111	11
	疏松 脱空	888	111	11
	正常区域	888	111	11
b-scan	疏松	888	111	11
	脱空	888	111	11

对照数据集将脱空、疏松、竖井和管道中的同一病害对应的 b-scan 和 c-scan 图像拼接起来。数据集共 4 440 张图像，其中各类数据均为 1 110 张。

3 实验结果与分析

本文实验数据均来自广东省广州市实际道路检测中。本文实验在 Window10 操作系统上完成，运行内存 8.0 GB，CPU 为 Intel (R) Core (TM) i5-7500 CPU @ 3.40 GHz，GPU 为 GeForce RTX 1080Ti，深度学习网络框架为 Tensorflow2.0.0。本文使用准确率 (accuracy)、查准率 (precision)、查全率 (recall)、 F_1 分数 (F_1 -score)、Frames Per Second (fps) 和混淆矩阵来评价模型优劣。

3.1 本文算法结果

本文提出的改进的 GoogleNet-ResNet 算法在城市道路病害识别过程中，第一级网络使用改进的 GoogleNet 实现病害目标和非病害目标的粗分类。该网络训练时，学习率设为 0.000 1，批处理大小为 32，训练 50 轮。其训练集准确率为 100%，验证集准确率为 98.2%，测试集准确率为 98.2%，图像处理速度为 90.9 fps，满足实时检测要求。其中，正常区域、竖井、脱空和疏松目标的识别率 100%，管道的识别率 92.3%，部分识别结果如图 8 所示。分析误判的样本可知，由于部分管道的直径较小导致在 c-scan 图像中只有部分区域为红色区域，因此，容易被误判成竖井或者脱空疏松。

第二级网络使用基于迁移学习的 ResNet50 进行病害目标的细分类，训练时，学习率设为 0.000 01，批处理大小为 32，训练 50 轮。其训练集准确率为 100%，验证集准确率为 90.1%，测试集准确率为 90.5%，图像处理时间 52.6 fps，满足实时检测要求。其中，疏松的识别率为 91.0%，脱空的识别率为 90.1%，部分识别结果如图 9 所示。分析误判的样本可知，脱空和疏松的体积大小在一定程度上影响了病害的识别结果。具体而言，当疏松的体积




图 7 图像扩增示例

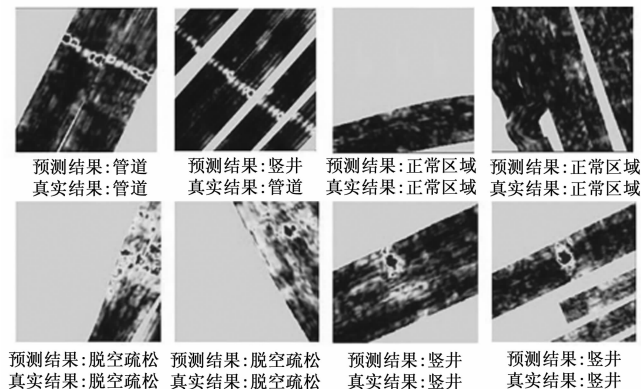


图 8 一级网络的部分识别结果

较大时, 部分雷达图像呈现出类似的横直条纹, 从而被误判为脱空。而当脱空的体积较小时, 雷达图像呈现小区域的波浪形状, 导致被误判为疏松。

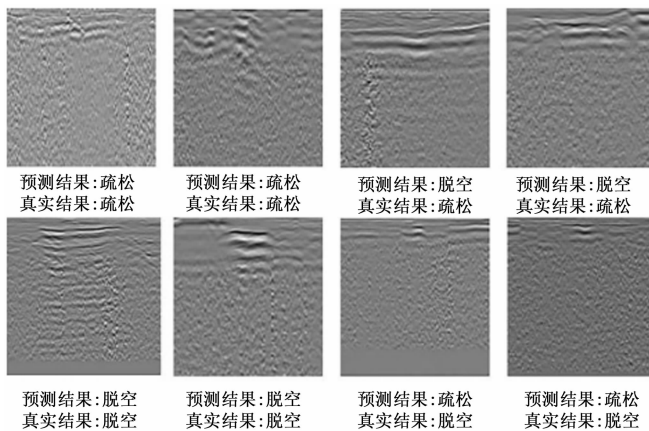


图 9 二级网络的部分识别结果

3.2 第一级网络的性能对比

为验证改进的 GoogleNet 的优势, 本文分别在 GoogleNet、改进的 GoogleNet 以及当前主流轻量化网络 MobilenetV3 模型上, 对雷达图像的 c-scan 数据集进行训练。实验发现, 在同一测试集上, 改进的 GoogleNet 各方面性能更好, 准确率比原始 GoogleNet、MobilenetV3 分别高 5.6%、6.3%。查准率比原始 GoogleNet、MobilenetV3 分别高 5.6%、6.4%。查全率比原始 GoogleNet、MobilenetV3 分别高 5.7%、6.5%。F₁-score 比原始 GoogleNet、MobilenetV3 分别高 5.6%、6.4%。且图像处理速度比原始 GoogleNet、MobilenetV3 分别高 24.2 fps、20.5 fps, 如表 2 所示。通过对模型结构进行合适的简化, 并引入适用于轻量化模型的注意力机制, 可以在较小的计算开销下显著提高网络的检测速度和识别准确率。

表 2 优化网络的结果对比

模型	准确率/%	查准率/%	查全率/%	F ₁ -score/%	fps
GoogleNet	92.6	92.6	92.6	92.6	66.7
improved GoogleNet	98.2	98.2	98.3	98.2	90.9
MobilenetV3	91.9	91.8	91.8	91.8	71.4

图 10 为 GoogleNet、改进的 GoogleNet 和 MobilenetV3 模型识别的混淆矩阵结果。改进的 GoogleNet 网络对竖井、脱空疏松和正常区域的识别准确率都到达 100%。而 GoogleNet 和 MobilenetV3 模型只对正常区域的识别率达到 100%, 其余 3 类的识别准确率都明显低于改进的 GoogleNet 网络。改进的 GoogleNet 模型的分能力大幅提升可能是由于引入注意力机制模块, 从而提高对小目标的检测能力。




图 10 各模型的混淆矩阵

3.3 不同的 ResNet50 迁移方案对比

为验证迁移方案的合理性, 本文设计 4 种迁移方案: 方案 1 用迁移获得的权重初始化, 并重新训练所有权重。方案 2 冻结 stage1~2 的权重, 训练 stage3~5 的权重。方案 3 冻结 stage1~3 的权重, 训练 stage4~5 的权重。方案 4 冻结 stage1~4 的权重, 训练 stage5 的权重。实验发现, 在同一测试集上, 方案 3 的迁移方案各方面性能更好, 准确率比方案 1、方案 2、方案 4 分别高 6.3%、2.7%、4.0%。查准率比其方案 1、方案 2、方案 4 分别高 6.4%、2.7%、4.1%。查全率比方案 1、方案 2、方案 4 分别高 5.6%、2.5%、3.5%。F₁-score 比其方案 1、方案 2、方案 4 分别高 6.5%、2.8%、4.2%。推理速度与其他方案相比无明显提升, 如表 3 所示。由此可知, 针对特定的小样本数据集进行模型训练时, 选用特定的参数迁移方案可提高模型的检测准确率。

表 3 迁移方案结果对比

方案	准确率/%	查准率/%	查全率/%	F ₁ -score/%	fps
1	84.2	84.2	85.0	84.1	50
2	87.8	87.9	88.1	87.8	52.6
3	90.5	90.6	90.6	90.6	52.6
4	86.5	86.5	87.1	86.4	50

图 11 (a) ~ (d) 分别为 4 种迁移方案的混淆矩阵。第三种迁移方案对病害的识别能力高于其余 3 种, 尤其是对疏松的识别率达 91.0%, 比其他 3 种方案分别高 14.4%、7.2%、10.8%。

3.4 级联网络与非级联网络结构对比

为验证本文网络结构的合理性, 本文设置两种非级联网络结构实验: 方案 1 将病害的 b-scan 和 c-scan 图像拼接后的数据集输入改进的 GoogleNet。方案 2 将病害的拼接数据集输入基于迁移学习的 ResNet50。实验发现, 在同一测

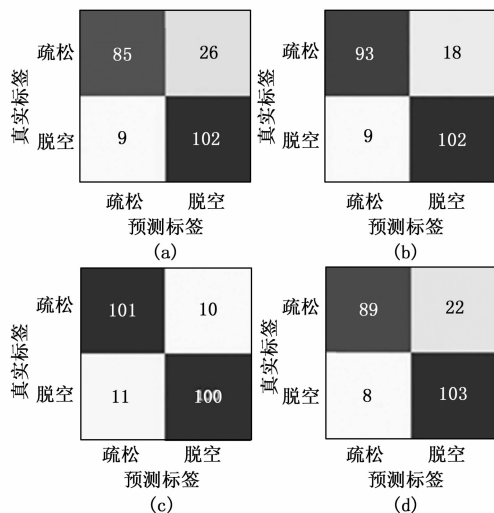


图 11 各迁移方案的混淆矩阵

试集上，本文提出的级联结构比方案 1、方案 2 的准确率分别高 10.1%，7.4%；级联结构比方案 1、方案 2 的查准率分别高 10.2%，7.5%；级联结构比方案 1、方案 2 的查全率分别高 9.0%，6.1%；级联结构比方案 1、方案 2 的 F_1 -score 分别高 9.7%，7.6%，如表 4 所示。由此可知，对比将拼接数据集输入单级网络进行路基病害识别的方案，级联网络可以针对不同视图的雷达图像特征设计更合适的网络结构，从而提高路基病害的识别准确率。

表 4 非级联网络实验结果对比

模型	准确率/%	查准率/%	查全率/%	F_1 -score/%
improved GoogleNet	80.4	80.4	81.6	80.9
ResNet50	83.1	83.1	84.5	83.0
本文算法	90.5	90.6	90.6	90.6

4 结束语

本文针对三维探地雷达收集的多视图雷达图像数据集，提出了一种基于改进的 GoogleNet-ResNet 算法的道路路基病害分类方法，实现道路路基病害的准确分类。首先，通过坐标注意力机制和改进的 Inception 模块对 GoogleNet 网络结构进行优化并简化模型结构，提高初筛网络的检测准确率和效率。然后，使用特定的迁移学习方案对 ResNet50 网络参数进行初始化，训练路基病害细分类模型。实验结果表明，与非级联网络模型相比，本文提出的方法对基于多视图雷达图像的路基病害分类任务有较高的准确性。未来，我们将进一步研究基于多视图雷达图像的路基病害定位方法。

参考文献:

[1] JIN T, SONG Q, SUN X K, et al. Study of subsurface metallic landmine 2-dimensional electromagnetic signature in ground pen-

etrating synthetic aperture radar [J]. Tien Tzu Hsueh Pao/Acta Electronica Sinica, 2006, 34 (12): 2246 - 2249.

[2] TORBAGHAN E M, LI W, METJE N, et al. Automated detection of cracks in roads using ground penetrating radar [J]. Journal of Applied Geophysics, 2020, 179: 104118.

[3] KANG M S, AN Y K. Frequency-wavenumber analysis of deep learning-based super resolution 3D GPR images [J]. Remote Sensing, 2020, 12 (18): 3056.

[4] PHAM M T, LEFÈVRE S. Buried object detection from B-scan ground penetrating radar data using fasterR-CNN [C] // IEEE International Geoscience and Remote Sensing Symposium (IGARSS-2018). IEEE, 2018: 6804 - 6807.

[5] LEI W, HOU F, XI J, et al. Automatic hyperbola detection and fitting in GPR B-scan image [J]. Automation in Construction, 2019, 106: 102839.

[6] WANG H, OUYANG S, LIAO K, et al. GPR B-SCAN image hyperbola detection method based on deep learning [J]. ACTA Electronica Sinica, 2021, 49 (5): 953.

[7] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39 (6): 1137 - 1149.

[8] BISHENG Y, ZELIANG Z, CHI C, et al. Real time approach for underground objects detection from vehicle-borne ground penetrating radar [J]. Acta Geodaetica et Cartographica Sinica, 2020, 49 (7): 874.

[9] REDMON J, FARHADI A. Yolov3: an incremental improvement [J/OL]. Arxiv Preprint ArXiv: 1804.02767, 2018. <https://arxiv.org/abs/1804.02767>.

[10] TONG Z, GAO J, HAN Z, et al. Recognition of asphalt pavement crack length using deep convolutional neural networks [J]. Road Materials and Pavement Design, 2018, 19 (6): 1334 - 1349.

[11] ZHANG X, HAN L, ROBINSON M, et al. A GANs-based deep learning framework for automatic subsurface object recognition from ground penetrating radar data [J]. IEEE Access, 2021, 9: 39009 - 39018.

[12] LI Y, LIU C, YUE G, et al. Deep learning-based pavement subsurface distress detection via ground penetrating radar data [J]. Automation in Construction, 2022, 142: 104516.

[13] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [J/OL]. Arxiv Preprint Arxiv: 2004.10934, 2020.

[14] LIU H, SHI Z, LI J, et al. Detection of road cavities in urban cities by 3D ground-penetrating radar [J]. Geophysics, 2021, 86 (3): WA25 - WA33.

[15] KHUDOYAROV S, KIM N, LEE J J. Three-dimensional convolutional neural network-based underground object classification using three-dimensional ground penetrating radar data [J]. Structural Health Monitoring, 2020, 19 (6): 1884 - 1893.

(下转第 294 页)