基于三维探地雷达多视图融合的道路隐蔽裂缝识别

钟燕辉[1]，邵艳浩[1]，张瑞丰[2]，李清波[2]，王　翔[1]，张　蓓[1]

（1.郑州大学 水利与交通学院，河南 郑州 450001；2.河南交通投资集团有限公司开封分公司，河南 开封 475000）

摘　要：针对现有方法多依赖单视图雷达图像，忽视三维探地雷达多视图互补信息的问题，构建一种基于多视图融合与深度学习的道路隐蔽裂缝识别方法。采用 gprMax 软件建立沥青路面三维正演模型，获取 B-scan、C-scan 和 D-scan 这 3 个正交方向的雷达剖面，结合正演模拟与实测数据构建了包含 3 437 组三视图样本的数据集。以 DenseNet121 和 ResNet50 为主干网络，引入 SE 通道注意力机制，构建三分支并行结构，设计视图间注意力融合模块实现多视图特征的自适应加权融合。实验结果表明，DenseNet121-TB 模型准确率、精确率、召回率和 $F1$ 分别达到 98.60%、98.71%、98.60%和 98.65%，较最优单视图模型准确率提升 4.19 百分点。消融实验验证了各模块对性能的正向贡献。现场钻孔取芯验证表明，三视图特征与取芯结果具有良好对应关系，所提方法具有一定工程适用性。

关键词：探地雷达；道路裂缝；多视图融合；注意力机制；深度学习

中图分类号：TP391.41；U416.217　　**文献标志码**：A　　**doi**：10.13705/j.issn.1671-6833.2027.01.005

中国公路建设规模持续扩大，“半刚性基层+沥青路面”结构体系是高速公路建设中的常见结构形式[1]。道路内部隐蔽裂缝不易通过表观检测发现，一旦贯穿结构层，水分下渗会引发基层软化、沥青剥离等病害，削弱道路承载能力与使用寿命[2]。因此，路面内部隐蔽裂缝的检测是道路养护和病害预防中的重要环节。

探地雷达（ground penetrating radar，GPR）具有无损、连续、高效等特点，在道路、堤坝及地下管线等基础设施检测中应用广泛[3-5]。Diamanti 等[6]使用数值模型研究了裂缝填充材料、裂缝宽度等对雷达响应的影响，展示了 GPR 检测垂直裂缝的能力；卢成明等[7]利用数值模拟与物理实验相结合，确定了公路结构层垂直裂缝的信号特征；Tong 等[8]构建了卷积神经网络模型用于路基缺陷的自动分类。基于单视图雷达图像的深度学习方法不断发展，Liu 等[9]采用改进 mask R-CNN 实现沥青路面裂缝的像素级检测；Que 等[10]提出基于生成对抗网络的数据增强方法并结合改进 VGG 进行裂缝分类，有效提升了裂缝识别的自动化水平。但上述方法多以单一方向剖面作为输入，对三维 GPR 数据中其他视图所携带的互补信息利用尚不充分。

三维探地雷达能够同时提供 B-scan、C-scan 和 D-scan 多个方向的视图，围绕多视图信息的关联利用已开展了一系列研究。Kim 等[11]提出将 B-scan 和 C-scan 两个视图按空间关系组合为二维网格图像，输入卷积神经网络进行地下目标分类，验证了双视图组合的分类效果优于单视图；Kim 等[12]进一步构建由 B-scan、C-scan 和 D-scan 组成的三平面输入方式，证明三平面图像的分类效果优于单一 B-scan，说明增加视图数量可带来额外判别信息；Li 等[13]提出 GPR-RCNN 算法，将 B-scan 二维特征与三维数据体特征融合，实现机场跑道病害识别；Li 等[14]进一步提出 MV-GPRNet，融合 C-scan 三维特征图与 Top-scan 二维特征图，在多个国际机场实测数据上完成多类道面病害检测，验证了多视图融合对病害识别

收稿日期：2026-09-06；**修订日期**：2026-10-08

基金项目：国家自然科学基金资助项目（52578540，52478477）；河南省自然科学基金交叉学科创新研究群体项目（252300421827）

作者简介：钟燕辉（1975—），男，湖北钟祥人，郑州大学教授，博士，博士生导师，主要从事工程安全防护理论与技术的研究，E-mail：zhong_yanhui@163.com。

通信作者：张蓓（1968—），女，河南南阳人，郑州大学教授，博士，博士生导师，主要从事交通及岩土基础工程安全防护理论与技术的研究，E-mail：beizhang@126.com。

精度的提升作用；Moalla 等[15]采用 CNN 与循环神经网络构建双路径结构处理三维 GPR 数据和多方向视图，完成埋藏危险物检测；韩海航等[16]将注意力机制引入三维探地雷达道路病害检测，对多视图特征进行自适应加权融合，完成双分支的病害检测；Zhou 等[17]提出 GPR-MVFD 框架，构建多视图 GPR 路基病害数据集，结合多视图蒸馏与注意力融合机制开展病害检测，以增强路基病害的特征提取能力。Yamaguchi 等[18]将三维卷积神经网络与 Kirchhoff 偏移结合用于地下管道识别，验证了三维方法较二维方法的分类精度优势。

现有方法多仅使用两个视图或单一方向剖面，极少同时应用 3 种视图进行联合分析。为此，本文构建一种基于三视图融合的道路隐蔽裂缝识别方法，探究三视图信息互补对道路隐蔽裂缝识别精度的提升作用，主要工作包括：运用 gprMax 软件开展道路隐蔽裂缝的三维正演模拟，获取模拟的多视图雷达图像；在 DenseNet121 与 ResNet50 模型中引入 SE 通道注意力机制，构建三分支并行结构，通过视图间注意力机制实现多视图特征融合。

1　三维正演模拟

1.1　数值模型建立与参数设置

为研究探地雷达对道路内部隐蔽裂缝的电磁响应特征，采用基于时域有限差分法（finite-difference time-domain，FDTD）的 gprMax 软件建立三维数值模型。部分模型参数设置如下：模型空间尺寸为 1.2 m×0.9 m×1.0 m，顶部设置 0.10 m 厚空气层，其余为路面结构层，网格步长为 0.002 m。道路结构自上而下依次为沥青面层、半刚性基层（上基层、下基层）、底基层与土基，各层厚度、相对介电常数及电导率等参数见表 1。

表 1　不同道路结构层参数

Table 1　Parameters of various road structural layers

结构层	厚度/cm	相对介电常数	电导率/(S·m^{-1})
沥青面层	18	6	0.005
上基层	20	8	0.050
下基层	20	9	0.060
底基层	20	7	0.070
土基	12	12	0.100

雷达激励源采用 Ricker 子波，布置于空气与面层交界处。模型四周采用厚度为 10 个网格的完美匹配层（PML）作为吸收边界。模拟中分别选取 0.9，1.2，1.5 GHz 这 3 种中心频率进行计算。

模拟中设置了垂直规则裂缝、倾斜裂缝和不规则裂缝 3 类典型隐蔽裂缝，裂缝宽度在 1 cm 内，部分模型如图 1 所示。垂直规则裂缝模拟基层因温度收缩产生的贯穿性裂缝；倾斜裂缝模拟应力分布不均导致的倾斜扩展；不规则裂缝模拟荷载反复作用下形成的曲折、分叉等复杂走向。

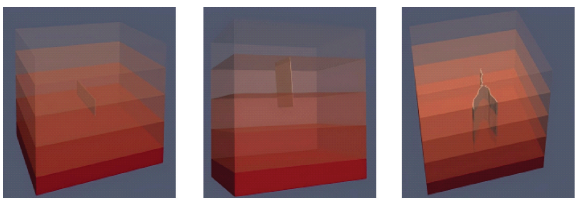

(a) 垂直规则裂缝　(b) 倾斜裂缝　(c) 不规则裂缝

图 1　三维裂缝正演模型

Figure 1　3D forward model of cracks

1.2　数据采集与三维成像实现

使用 Python 调用 gprMax3.0 软件开展正演模拟。在道路纵向进行 B-scan 扫描，横向按 0.05 m 间距布设多条平行测线。由于裂缝内空气与周围结构层的相对介电常数差异显著，电磁波在裂缝边缘发生绕射，形成双曲线反射特征。

通过 MATLAB 和 Python 将多条 B-scan 剖面按空间坐标插值拼接，合并为 HDF5 格式的三维探地雷达数据体，数据维度为测线数×道数×时间采样点。对于模拟数据，根据裂缝预设坐标直接选取切片：B-scan 选择最靠近裂缝中心的测线，D-scan 选取最接近裂缝中心的道号，C-scan 在裂缝埋深范围内挑选反射响应最明显的深度层，部分模拟雷达图像如图 2 所示。对于实测数据，选取双曲线反射最显著的测线作为目标 B-scan，从双曲线顶点对应的道号提取 D-scan，双程走时换算裂缝深度后，选择异常响应最明显的水平切片作为 C-scan。

(a) B-scan　(b) C-scan　(c) D-scan

图 2　模拟的多视图雷达图像

Figure 2　Simulated multi-view radar images

1.3　数据集构建

数据集由正演模拟与实测数据两部分构成。模拟样本基于 gprMax 软件生成，涵盖不同裂缝宽度、埋深、倾斜角度及天线频率的参数组合，裂缝位置已知，共 400 组；实测样本取自连霍高速开封段，使用 GeoScope™ MK Ⅳ三维探地雷达采集，结合现场病害信息与钻孔验证完成标注，共 1 202 组。每组样本包含同一裂缝位置的 B-scan、C-scan 和 D-scan 这

3 个视图,原始数据共 1 602 组,模拟与实测比例约为 1∶3,裂缝类与非裂缝类分布均衡。最终数据集共 3 437 组,其中训练集 2 463 组、验证集 616 组、测试集 358 组。数据集的 DOI 编号为 10.57760/sciencedb.38587。

2 多视图注意力融合改进算法

2.1 主干网络结构

由于与本文所采用的三维探地雷达三视图裂缝识别任务类似的公开方法较少,为从三维探地雷达图像中提取裂缝特征信息,本文采用 DenseNet121[19] 和 ResNet50[20] 两种卷积神经网络作为主干网络。DenseNet121 采用密集连接结构,增强特征传递与复用,有利于保留裂缝边界、纹理等细节信息,且参数量较小,在小样本数据上不易过拟合。ResNet50 通过残差连接缓解梯度消失问题,对噪声及局部伪反射等复杂 GPR 图像具有较好的鲁棒性。

2.2 多视图注意力融合改进结构

2.2.1 三分支并行的多视图结构

本文以 DenseNet121 和 ResNet50 两种卷积神经网络作为主干网络,在此基础上引入 Squeeze-and-Excitation(SE)通道注意力机制,分别构建了 DenseNet121-SB(single branch)和 ResNet50-SB 两个单视图模型,网络结构如图 3 和图 4 所示。在单视图模型基础上,构建三分支并行的多视图结构,得到 DenseNet121-TB(triple branch)和 ResNet50-TB 两个多视图融合模型,网络结构如图 5 和图 6 所示。单视图模型以 B-scan、C-scan 或 D-scan 中的某一种图像作为输入,对应记为 SB(ZD)、SB(SP)和 SB(HD);多视图模型则同时以 3 种视图作为输入进行特征融合。

2.2.2 通道间注意力机制

为增强裂缝特征通道的响应权重,在 DenseNet121 和 ResNet50 主干网络中引入 SE 模块。在 DenseNet121-SB 中对 DenseNet121 的过渡层进行

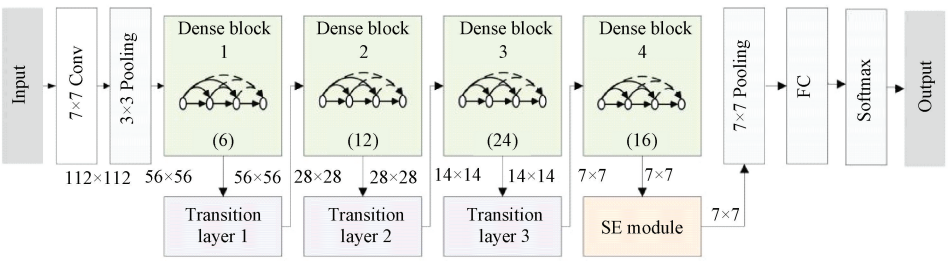

图 3 DenseNet121-SB 网络结构

Figure 3 Structure of DenseNet121-SB

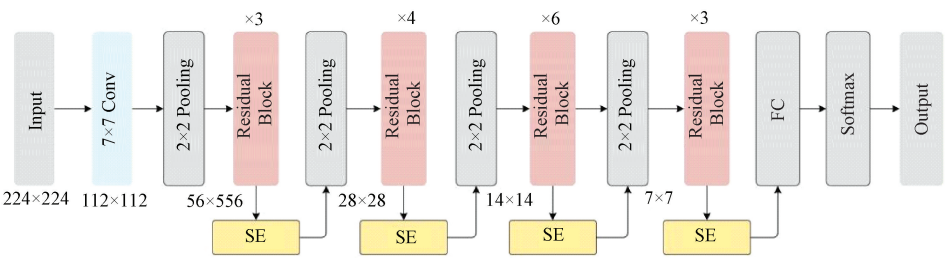

图 4 ResNet50-SB 网络结构

Figure 4 Structure of ResNet50-SB

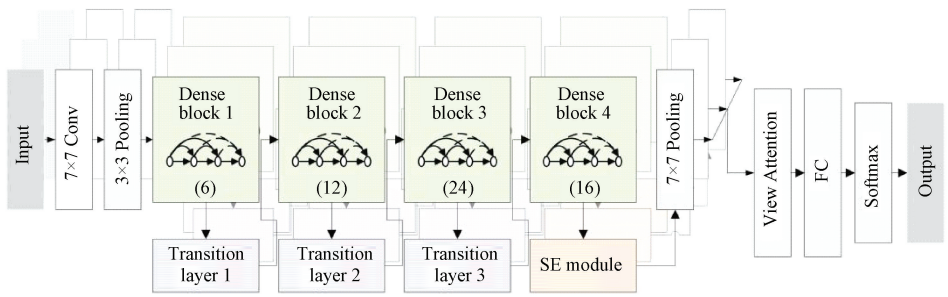

图 5 DenseNet121-TB 网络结构

Figure 5 Structure of DenseNet121-TB

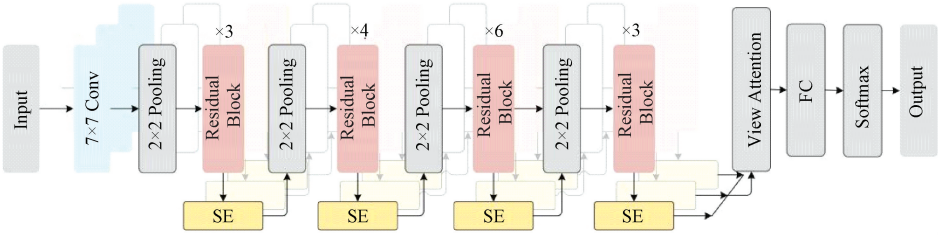

图 6　ResNet50-TB 网络结构

Figure 6　Structure of ResNet50-TB

改造,在“1×1 卷积层+2×2 平均池化”中插入 SE 模块,如图 7 所示。在 ResNet50-SB 模型中,在每个残差阶段的输出端加入 SE 模块,对特征通道进行自适应重加权。

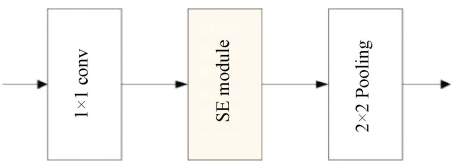

图 7　改进后的过渡层

Figure 7　Improved Transition layer

SE 模块结构[21]如图 8 所示。设输入特征图为 $\boldsymbol{U}$,首先,通过压缩操作 $F_{sq}(\cdot)$ 对 $\boldsymbol{U}$ 进行全局平均池化(global average pooling,GAP),将每个通道的空间信息压缩为通道级统计量,得到通道描述向量 z。将 z 输入激励操作 $F_{ex}(\cdot,\boldsymbol{W})$,其中 $\boldsymbol{W}$ 为由两层全连接层构成的可学习参数。该操作通过非线性映射建模通道间的依赖关系,生成各通道的重要性权重向量 $\boldsymbol{\gamma}$。最后,通过重标定操作 $F_{scale}(\cdot,\cdot)$,将重要性权重向量 $\boldsymbol{\gamma}$ 逐通道作用于原始输入特征 $\boldsymbol{U}$,得到加权后的输出特征 $\widetilde{\boldsymbol{U}}$。该模块通过自适应重标定特征通道,抑制背景噪声响应,增强裂缝特征响应,从而提升特征的判别能力。

通过在两个主干网络中引入 SE 模块,增强单视图特征的判别性,为后续多视图特征融合提供更具区分度的特征表示。

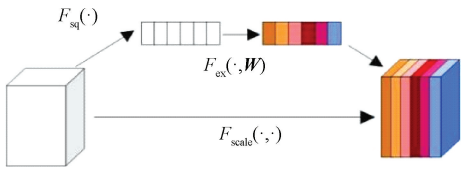

图 8　SE 模块

Figure 8　SE module

2.2.3　视图间注意力机制

在引入 SE 模块的基础上,于三分支并行的多视图网络中引入视图间注意力机制,对来自 B-scan、C-scan 和 D-scan 的特征进行自适应加权融合,其融合机制见图 9。

三分支并行结构分别提取各自视图的空间特征图,并通过全局平均池化压缩为全局特征向量:

$$\boldsymbol{F}_i = \frac{1}{H \times W}\sum_{h=1}^{H}\sum_{w=1}^{W}\boldsymbol{F}_i^{\text{spatial}}(h,w)。\qquad(1)$$

式中:$\boldsymbol{F}_i^{\text{spatial}}$ 为第 i 个视图的空间特征图;H、W 为特征图的高度与宽度;$\boldsymbol{F}_i$ 为第 i 个视图的全局特征向量。

将三个视图的全局特征向量 $\boldsymbol{F}_B$、$\boldsymbol{F}_C$、$\boldsymbol{F}_D$ 在特征维度上拼接得到拼接特征向量 $\boldsymbol{F}_{concat}$,并将其输入注意力模块计算注意力原始得分向量 $\boldsymbol{s}$:

$$\boldsymbol{s} = \boldsymbol{W}_2 \cdot \text{ReLU}(\boldsymbol{W}_1 \cdot \boldsymbol{F}_{concat} + \boldsymbol{b}_1) + \boldsymbol{b}_2。\qquad(2)$$

式中:$\boldsymbol{F}_{concat}$ 为 3 个视图特征的拼接特征向量;$\boldsymbol{W}_1$、$\boldsymbol{W}_2$ 分别为第一、二层全连接层的权重矩阵;$\boldsymbol{b}_1$、$\boldsymbol{b}_2$ 分别为第一、二层全连接层的偏置向量;$\boldsymbol{s}$ 为 3 个视图的注意力原始得分向量;ReLU 为非线性激活函数。

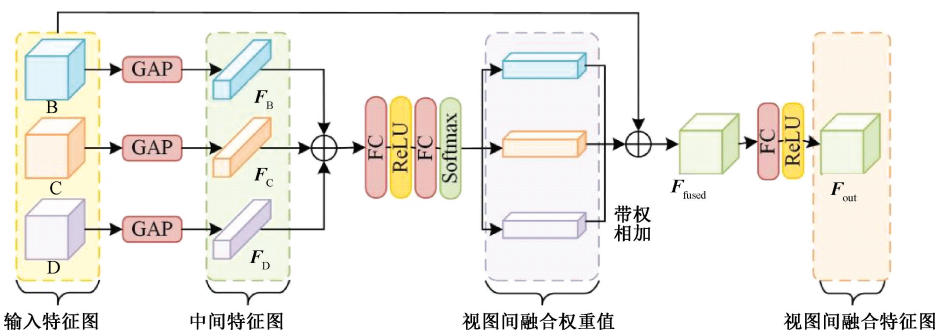

图 9　视图间注意力融合机制

Figure 9　Inter-view attention fusion mechanism

获得注意力原始得分向量 $\boldsymbol{s}$ 后，通过 Softmax 函数归一化(式(3))，得到 3 个视图的最终权重系数。

$$\alpha_i = \frac{\exp(s_i)}{\sum_{j\in\{B,C,D\}}\exp(s_j)}。\tag{3}$$

式中：s_i 为视图 i 的注意力原始得分；α_i 为视图 i 的归一化注意力权重系数。

$$\boldsymbol{F}_{\text{fused}} = \alpha_B\cdot\boldsymbol{F}_B + \alpha_C\cdot\boldsymbol{F}_C + \alpha_D\cdot\boldsymbol{F}_D;\tag{4}$$

$$\boldsymbol{F}_{\text{out}} = \text{ReLU}(\boldsymbol{W}_f\cdot\boldsymbol{F}_{\text{fused}} + \boldsymbol{b}_f)。\tag{5}$$

式中：$\boldsymbol{F}_{\text{fused}}$ 为加权融合后的特征向量；$\boldsymbol{W}_f$ 为融合输出层的权重矩阵；$\boldsymbol{b}_f$ 为融合输出层的偏置向量；$\boldsymbol{F}_{\text{out}}$ 为模块最终输出特征向量。

视图间注意力机制能够根据成像质量和裂缝显著程度动态调整 3 种视图的权重分配。

3 实验结果与分析

3.1 实验设置

(1)数据预处理。原始雷达数据依次进行零点校正、去直达波和时间增益控制，再从三维数据体中提取三种视图图像。数据集按相互独立原则随机划分，数据增强仅应用于训练集，包括随机翻转、平移、小幅度旋转、亮度与对比度变化及高斯噪声等常规操作，验证集与测试集不作增强。所有样本统一缩放并归一化。

(2)优化策略。采用 AdamW 优化器进行参数更新，其自适应学习率特性适用于小规模数据集的训练。训练过程中通过验证集监控损失与准确率，保存验证集上表现最优的模型。

(3)损失函数。采用交叉熵损失函数。定义为 $\mathcal{L} = -\sum_{c=1}^{C} y_c \ln \hat{y}_c$。其中 y_c 为真实标签的 one-hot 编码，$\hat{y}_c$ 为第 c 类预测概率，$C=2$。三分支模型以视图间注意力融合后的输出统一计算损失，各分支参数独立更新，实现端到端联合训练。

(4)训练参数。初始学习率设为 0.000 1，batch size 设为 16，最大训练轮次设为 100。模型参数采用随机初始化，未使用预训练权重。

(5)评价指标。选取准确率 A、精确率 P、召回率 R 和 $F1$ 这 4 项指标进行定量分析。

(6)硬件环境。实验基于 PyTorch 深度学习框架，在 Windows 11 操作系统、Python 3.10、NVIDIA RTX GPU 环境下完成。

3.2 实验分析

采用单视图模型与多视图模型进行训练与验证，并加入 Swin Transformer[22]、ConvNeXt V2[23]、RepViT[24]为主干网络的三视图模型作为对比基线，测试集上的性能评估结果如表 2 所示。

表 2 不同模型的评估指标

Table 2 Evaluation metrics of different models

深度学习模型	A/%	P/%	R/%	$F1$/%
DenseNet121-TB	98.60	98.71	98.60	98.65
DenseNet121-SB(ZD)	94.41	95.97	94.41	95.18
DenseNet121-SB(SP)	93.58	95.33	93.58	94.45
DenseNet121-SB(HD)	84.92	91.67	84.92	88.17
ResNet50-TB	94.13	95.64	94.13	94.88
ResNet50-SB(ZD)	90.22	93.79	90.22	91.97
ResNet50-SB(SP)	92.46	94.77	92.46	93.60
ResNet50-SB(HD)	82.68	91.06	82.68	86.65
Swin Transformer-TB	87.15	90.66	87.15	88.86
ConvNeXt V2-TB	82.96	89.79	82.96	86.24
RepViT-TB	94.97	95.63	94.97	95.30

从骨干网络对比来看，DenseNet121 整体表现优于 ResNet50，DenseNet121-TB 准确率达 98.60%，较 ResNet50-TB 高 4.47 百分点。3 种对比基线中，RepViT-TB 表现最优，准确率为 94.97%，其重参数化结构在保持轻量化的同时具备较强的局部特征提取能力；Swin Transformer-TB 准确率为 87.15%，其窗口自注意力机制虽能建模较大范围的空间依赖，但在样本量有限的条件下全局建模优势难以充分发挥；ConvNeXt V2-TB 准确率仅 82.96%，该模型依赖掩码自编码器预训练，在随机初始化条件下训练，其性能受到明显限制。3 种新型架构均低于 DenseNet121-TB，主要原因在于此类模型面向大规模自然图像数据集设计，模型容量较大且通常依赖预训练权重，而本文数据集规模有限；相比之下，DenseNet121 通过密集连接实现特征复用，参数量较小，更适合小样本雷达图像识别任务。

从单视图结果来看，D-scan 在两种骨干网络中准确率均最低，B-scan 与 C-scan 准确率相近，均具备较强的独立判别能力。多视图融合模型性能显著优于所有单视图模型，较各自最优单视图模型，DenseNet121-TB 提升 4.19 百分点，ResNet50-TB 提升 1.67 百分点，融合模型同时改善了单视图中精确率与召回率不均衡的问题。

图 10 和图 11 分别展示了 4 个代表性模型的准确率与精确率变化曲线，DenseNet121-TB 在两种曲线中整体保持最高水平，且中后期波动最小，表现出最优的收敛性能与稳定性。

综上，DenseNet121-TB 表现最佳，多视图融合通过注意力机制整合互补信息，有效减少漏检并保持较低误报率，可为道路隐蔽裂缝识别提供技术支撑。

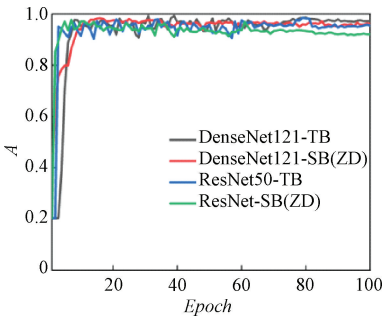

图 10　不同模型的准确率曲线

Figure 10　Accuracy curves of different models

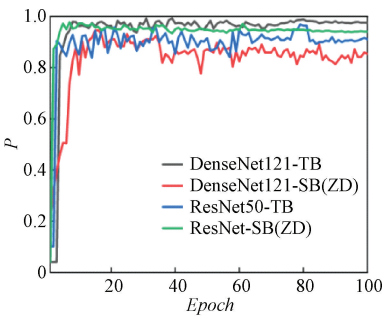

图 11　不同模型的精确率曲线

Figure 11　Precision curves of different models

3.3　消融实验

为验证各模块的有效性，在 DenseNet121-TB 基础上开展消融实验，每次仅改变一个变量，结果如表 3 所示。

表 3　消融实验结果

Table 3　Results of ablation experiments

SE 模块	融合策略	独立分支	*A*/%	*F*1/%
√	注意力融合	√	98.60	98.65
×	注意力融合	√	96.93	97.05
√	特征相加	√	95.81	96.14
√	特征拼接	√	98.04	98.07
√	注意力融合	×	97.49	97.42

在融合策略方面，将视图间注意力融合替换为特征相加后，准确率降至 95.81%，降幅最大（2.79 百分点），说明简单相加难以反映视图间的贡献差异；替换为特征拼接后准确率为 98.04%，仅下降 0.56 百分点，表明拼接能较完整保留多视图信息，但整体效果仍略逊于注意力融合。在分支结构方面，将三分支独立权重改为权重共享后准确率降至 97.49%，说明各视图特征存在差异性，独立分支有助于学习视图特有表示。在通道注意力方面，去除 SE 模块后准确率降至 96.93%，表明通道注意力对特征筛选具有积极作用。综上，3 个模块均有正向贡献，完整模型取得最优结果。

3.4　现场验证

为验证所提方法的工程适用性，在山东高速某路段使用 GeoScope™ MK Ⅳ三维探地雷达采集数据并输入 DenseNet121-TB 模型进行识别，选取 10 处典型位置进行钻孔取芯验证，结果均存在裂缝，与模型识别结果一致。

K139+973.8 处三维探地雷达图像如图 12 所示，B-scan 双曲线反射、C-scan 条带状高亮异常与 D-scan 局部反射条带在深度和位置上相互印证，对应深度范围约为面层底部至上基层顶部。该处取芯结果如图 13 所示，孔壁可见明显裂缝痕迹，芯样长约 38 cm，面层与基层交界处存在近竖直贯穿性裂缝，裂缝深度与 B-scan 反射深度一致。

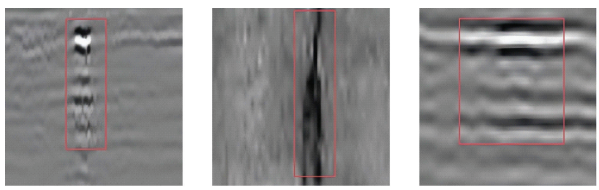

(a) B-scan　(b) C-scan　(c) D-scan

图 12　K139+973.8 三维探地雷达图像

Figure 12　3D ground penetrating radar image at K139+973.8

(a) 钻孔内部　(b) 芯样

图 13　K139+973.8 处钻孔取芯结果

Figure 13　Core drilling results at K139+973.8

K140+032.9 处位于超车道，取芯结果如图 14 所示，中部可见横向裂缝痕迹，孔壁亦可见裂缝开口，与模型识别结果一致。两处点位的三视图特征与取芯揭示的裂缝位置、深度和形态均具有良好对应关系，表明本方法能够有效检测路面内部隐蔽裂缝，具有工程应用价值。

(a) 芯样　(b) 裂缝孔壁

图 14　K140+032.9 处钻孔取芯结果

Figure 14　Core drilling results at K140+032.9

4　结论

针对现有方法多利用单视图雷达图像而忽视三

维探地雷达多视图互补信息的问题,提出一种基于三维探地雷达多视图融合与深度学习的道路隐蔽裂缝识别方法,主要结论如下。

(1) B-scan、C-scan 和 D-scan 这 3 个视图对裂缝的电磁响应特征具有互补性,多视图融合能有效弥补单视图的局限性,实现三维信息的充分利用。

(2) DenseNet121-TB 模型整体效果最优,准确率达 98.60%,较最优单视图模型提升 4.19 百分点,验证了多视图融合策略的有效性。

(3)消融实验表明,视图间注意力融合优于特征拼接与特征相加等策略,能更有效地学习视图间互补关系,提高检测精度。

本文仍存在不足:数据集规模有限,未来需扩充样本并涵盖更多裂缝类型;后续将探索轻量化方法及 CNN-Transformer 混合架构,并推广至脱空、松散等其他道路病害的检测。本文方法的源代码在 https://github.com/fengsyh/Multi-View-GPR-Crack-Detection。

参考文献:

[1] Sha Aimin. Material characteristics of semi-rigid base [J]. China Journal of Highway and Transport, 2008, 21(1): 1-5. [沙爱民. 半刚性基层的材料特性[J]. 中国公路学报, 2008, 21(1): 1-5.]

[2] Li Fabin, Yang Li, Wang Shengqi, et al. Analysis on the set expression and dimension ranking of expressway bituminous pavement crack classification [J]. Highway, 2025, 70(5): 7-12. [李法滨, 杨莉, 王圣棋, 等. 高速公路沥青路面裂缝分类的集合表达及其维度排序方法[J]. 公路, 2025, 70(5): 7-12.]

[3] Liu Hai, Chen Junhong, Zhang Xiaoyu, et al. Collaborative imaging of subsurface cavities using ground-pipeline penetrating radar [J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 3002205.

[4] Fang Hongyuan, Dong Zhifeng, Xue Binghan, et al. Analysis of ground penetrating radar wave field characteristics of dam face disengaging repaired by polymer grouting[J]. Journal of Zhengzhou University (Engineering Science), 2024, 45(3): 1-6. [方宏远, 董智峰, 薛冰寒, 等. 高聚物注浆修复的面板堤坝探地雷达波场特征分析[J]. 郑州大学学报(工学版), 2024, 45(3): 1-6.]

[5] Liu Hai, Yue Yunpeng, Liu Chao, et al. Automatic recognition and localization of underground pipelines in GPR B-scans using a deep learning model[J]. Tunnelling and Underground Space Technology, 2023, 134: 104861.

[6] Diamanti N, Redman D. Field observations and numerical models of GPR response from vertical pavement cracks [J]. Journal of Applied Geophysics, 2012, 81: 106-116.

[7] Lu Chengming, Qin Zhen, Zhu Hailong, et al. Practical methods for detection of concealed cracks in highway pavement using ground penetration radar data[J]. Chinese Journal of Geophysics, 2007, 50(5): 1558-1568. [卢成明, 秦臻, 朱海龙, 等. 探地雷达检测公路结构层隐含裂缝实用方法研究[J]. 地球物理学报, 2007, 50(5): 1558-1568.]

[8] Tong Zheng, Gao Jie, Zhang Haitao. Innovative method for recognizing subgrade defects based on a convolutional neural network[J]. Construction and Building Materials, 2018, 169: 69-82.

[9] Liu Zhen, Yeoh J K W, Gu Xingyu, et al. Automatic pixel-level detection of vertical cracks in asphalt pavement based on GPR investigation and improved mask R-CNN [J]. Automation in Construction, 2023, 146: 104689.

[10] Que Yun, Dai Yi, Ji Xue, et al. Automatic classification of asphalt pavement cracks using a novel integrated generative adversarial networks and improved VGG model[J]. Engineering Structures, 2023, 277: 115406.

[11] Kim N, Kim S, An Y K, et al. A novel 3D GPR image arrangement for deep learning-based underground object classification[J]. International Journal of Pavement Engineering, 2021, 22(6): 740-751.

[12] Kim N, Kim S, An Y K, et al. Triplanar imaging of 3-D GPR data for deep-learning-based underground object detection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(11): 4446-4456.

[13] Li Haifeng, Li Nansha, Wu Renbiao, et al. GPR-RCNN: an algorithm of subsurface defect detection for airport runway based on GPR[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3001-3008.

[14] Li Nansha, Wu Renbiao, Li Haifeng, et al. MV-GPR-Net: multi-view subsurface defect detection network for airport runway inspection based on GPR[J]. Remote Sensing, 2022, 14(18): 4472.

[15] Moalla M, Frigui H, Karem A, et al. Application of convolutional and recurrent neural networks for buried threat detection using ground penetrating radar data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(10): 7022-7034.

[16] Han Haihang, Mo Jiadi, Zhou Chunpeng, et al. Road disease detection for 3D-GPR maps based on attention fusion[J]. Computer Engineering and Design, 2022(9): 2669-2677. [韩海航, 莫佳笛, 周春鹏, 等. 基于注意力融合的三维探地雷达道路病害检测[J]. 计算机工程与设计, 2022(9): 2669-2677.]

[17] Zhou Chunpeng, Ning Kangjie, Wang Haishuai, et al. Multi-view fusion and distillation for subgrade distresses detection based on 3D-GPR[PP/OL]. V1. arXiv (2023-08-09)[2026-09-07]. https://doi.org/10.48550/arXiv.2308.04779.

[18] Yamaguchi T, Mizutani T, Nagayama T. Mapping subsurface utility pipes by 3-D convolutional neural network and Kirchhoff migration using GPR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(8): 6525-6536.

[19] Huang Gao, Liu Zhuang, Van Der Maaten L, et al. Densely connected convolutional networks[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2017: 2261-2269.

[20] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 770-778.

[21] Hu Jie, Shen Li, Sun Gang. Squeeze-and-excitation networks[C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 7132-7141.

[22] Liu Ze, Lin Yutong, Cao Yue, et al. Swin Transformer: hierarchical vision Transformer using shifted windows[C]//Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2021: 9992-10002.

[23] Woo S, Debnath S, Hu Ronghang, et al. ConvNeXt V2: co-designing and scaling ConvNets with masked autoencoders[C]//Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2023: 16133-16142.

[24] Wang Ao, Chen Hui, Lin Zijia, et al. RepViT: revisiting mobile CNN from ViT perspective[C]//Proceedings of the 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2024: 15909-15920.

Recognition of Road Subsurface Cracks in Pavement Based on 3D Ground Penetrating Radar Multi-view Fusion

ZHONG Yanhui[1], SHAO Yanhao[1], ZHANG Ruifeng[2], LI Qingbo[2], WANG Xiang[1], ZHANG Bei[1]

(1. School of Water Conservancy and Transportation, Zhengzhou University, Zhengzhou 450001, China; 2. Kaifeng Branch, Henan Transport Investment Group Co., Ltd., Kaifeng 475000, China)

Abstract: To address the problem that existing methods rely predominantly on single-view radar images while ignoring the complementary multi-view information of three-dimensional ground penetrating radar, a road subsurface crack recognition method based on multi-view fusion and deep learning was developed. A three-dimensional forward model of asphalt pavement was established using gprMax to obtain B-scan, C-scan, and D-scan radar profiles from three orthogonal directions, and a dataset comprising 3 437 triple-view samples was constructed by combining forward simulation with field measurement data. DenseNet121 and ResNet50 were adopted as backbone networks, with a SE channel attention mechanism introduced, a triple-branch parallel structure constructed, and an inter-view attention fusion module designed for adaptive weighted fusion of multi-view features. Experimental results showed that the DenseNet121-TB model achieved accuracy, precision, recall, and $F1$ of 98.60%, 98.71%, 98.60%, and 98.65%, respectively, with accuracy 4.19 percentage points higher than that of the best single-view model. Ablation experiments verified the positive contribution of each module to recognition performance. Field core drilling validation demonstrated good correspondence between the three-view features and the drilling results, indicating that the proposed method had practical engineering applicability.

Keywords: ground penetrating radar; pavement crack; multi-view fusion; attention mechanism; deep learning