

基于改进PointNet++隧道衬砌渗漏水识别方法

杨子涵, 陶为戈*

江苏理工学院电气信息工程学院, 江苏 常州

收稿日期: 2026年3月26日; 录用日期: 2026年4月23日; 发布日期: 2026年4月30日

摘要

本研究针对传统点云投影方法在隧道衬砌渗漏水识别中的信息损失和投影角度依赖性强等问题, 提出了一种基于改进PointNet++的直接三维识别方法。该方法通过在三维空间中直接处理点云数据, 避免了降维带来的几何信息损失。通过引入强度感知采样策略、反射强度加权聚合机制和病害注意力机制, 充分利用渗漏水的物理特性(低反射强度、竖向流淌方向)增强特征表达能力。进一步采用主成分分析(PCA)降维优化计算效率, 并使用Focal Loss解决样本不均衡问题。实验结果表明, 所提方法在自建隧道衬砌渗漏水点云数据集上的F1-Score达到85.8%, IoU达到73.9%, 相比基线PointNet++模型分别提升7.3和9.2个百分点, 满足实际工程应用需求。该方法为隧道衬砌渗漏水的自动化检测提供了有效的技术参考。

关键词

点云识别, PointNet++, 渗漏水检测, 特征融合

A Tunnel Lining Leakage Detection Method Based on the Improved PointNet++

Zihan Yang, Weige Tao*

School of Electrical and Information Engineering, Jiangsu University of Technology, Changzhou Jiangsu

Received: March 26, 2026; accepted: April 23, 2026; published: April 30, 2026

Abstract

This study addresses the issues of information loss and strong projection angle dependence in traditional point cloud projection methods for identifying tunnel lining leakage water. It proposes a direct three-dimensional recognition method based on the improved PointNet++. This method directly processes point cloud data in three-dimensional space, avoiding the geometric information

*通讯作者。

loss caused by dimension reduction. By introducing intensity-aware sampling strategy, reflection intensity weighted aggregation mechanism, and disease attention mechanism, it fully utilizes the physical characteristics of leakage water (low reflection intensity, vertical flow direction) to enhance feature expression ability. Further, principal component analysis (PCA) is used to reduce dimensionality and optimize computational efficiency, and Focal Loss is employed to solve the problem of sample imbalance. Experimental results show that the proposed method achieves an F1-Score of 85.8% and an IoU of 73.9% on the self-built tunnel lining leakage water point cloud dataset. Compared with the baseline PointNet++ model, it improves by 7.3 and 9.2 percentage points respectively, meeting the requirements of practical engineering applications. This method provides an effective technical reference for the automatic detection of tunnel lining leakage water.

Keywords

Point Cloud Recognition, PointNet++, Leakage Detection, Feature Fusion

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着“一带一路”倡议的深入推进和城镇化建设的加快,我国地下工程建设进入快速发展阶段。截至2024年底,我国铁路、公路及地铁累计运营里程分别达到19,630 km、21999.3 km和6280.8 km [1]。

“十三五”期间新增运营里程分别增长9%、23%和184%,地下空间开发规模显著扩大。然而,随着服役期延长与地质条件复杂化,隧道衬砌结构在大埋深、高地应力条件下面临严峻的安全挑战[2]。

渗漏水是隧道最常见的病害,会导致衬砌腐蚀、冻融破坏,严重威胁隧道安全。国内外检测方法主要分为三类:

接触式检测方法包括人工巡检、光纤传感器[3]和探地雷达[4],存在效率低、成本高、主观性强等局限。

基于2D图像的方法近年来发展迅速。早期采用边缘检测、纹理分析等传统技术[5],近期多采用深度学习:张振海等基于MDS-YOLO实现裂缝检测,准确率达83.4%;方力涵等[6]提出改进YOLOv5,多类病害检测精度达74.7%。但2D图像固有的透视畸变和几何信息缺失限制了其应用。

基于3D点云的方法可分为间接和直接两种策略。间接方法将点云投影为2D图像再识别[7];潘国兵等[8]提出基于点云密度自适应的VAlpha-Shapes算法,实现隧道渗漏水病害快速自动化检测与分析;王健等[9]对激光点云反射强度进行修正,通过灰度图像建立渗漏水病害数据集,最后在Mask RCNN算法中引入空洞卷积和变形卷积,实现了隧道渗漏水病害的快速检测;周宝定等[10]以Mask R-CNN (Region-CNN)模型为基准框架,采用Swin transformer网络作为底层特征提取网络,实现了对隧道渗水病害的快速检测。

现有方法的不足:(1)投影方法损失三维信息,受视角影响大;(2)直接方法未针对渗漏水物理特性(低反射强度、重力方向性)设计专门机制;(3)缺乏多模态特征融合;(4)样本不均衡问题处理不足。

针对上述问题,本文改进PointNet++算法来检测隧道衬砌渗漏水病害。主要贡献包括:(1)采用强度感知采样策略,使渗漏水边缘等强度变化显著区域获得更高采样优先级;(2)设计反射强度加权聚合机制,充分捕捉邻域点间的空间上下文关系;(3)引入病害注意力机制,有效区分渗漏水与污渍、阴影等相似目

标。实验表明, 本文方法 F1-Score 达 85.8%, IoU 达 73.9%, 较基线 PointNet++ 分别提升 7.3 和 9.2 个百分点。

2. PointNet++ 网络架构

PointNet 网络直接对无序点集中的各个点独立提取特征, 在最大池化完成聚合, 这一设计虽然简洁高效, 但缺乏局部结构信息。为弥补这一不足, PointNet++ 在其基础上引入采样层(Sampling Layer)与分组层(Grouping Layer), 将点云划分为多个局部邻域, 并通过多层神经网络实现层次化特征提取。该网络结构可分为特征提取模块与特征传播模块两部分, 其中前者由多层集合抽象层(Set Abstraction Layer)构成, 每层包括采样、分组与局部特征提取操作。其网络结构如图 1 所示[11]。

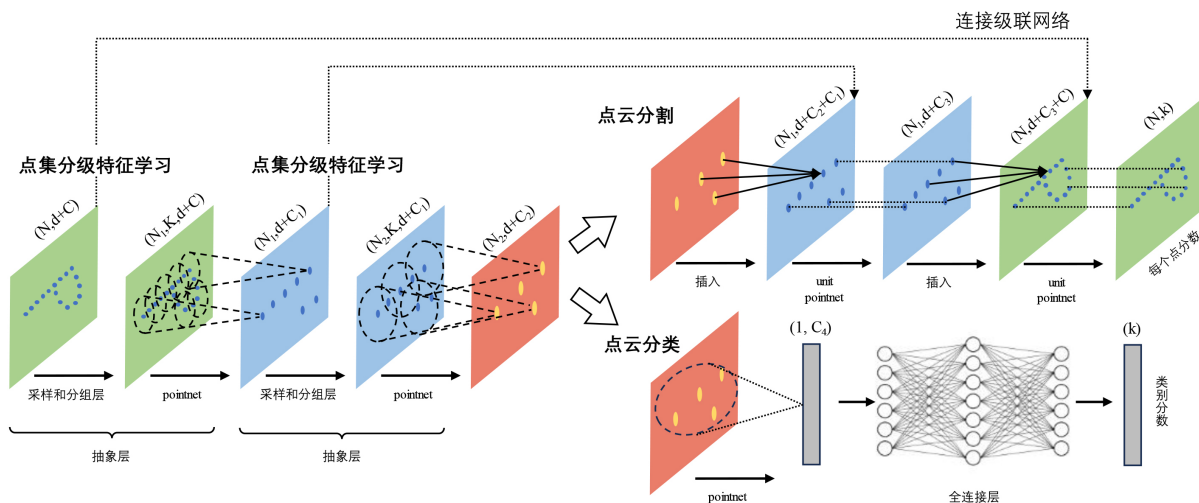


Figure 1. The structure of the PointNet++ network

图 1. PointNet++ 网络结构

PointNet++ 能有效提取点云的局部上下文信息, 但在处理隧道衬砌病害点云时仍存在对邻域点间空间关系捕捉不足、特征聚合过于粗糙等问题, 限制了其在复杂场景下的识别性能。

3. 改进的 PointNet++ 网络

3.1. 改进动机

PointNet++ 作为经典的点云分割网络, 其层次化采样与局部特征学习策略在复杂场景中表现优异, 且计算成本低于 DGCNN 等动态图方法。然而, 其局部特征提取采用与 PointNet 相同的策略: 对邻域点独立处理后通过最大池化聚合特征, 存在两个方面不足:

- (1) 未充分捕捉邻域点间的空间上下文关系;
- (2) 最大池化忽略了邻域点的特征多样性和贡献差异。

隧道场景中存在管线、接缝、污渍等多种地物, 渗漏水病害面积小(占比 < 10%)、特征微弱且易受噪声干扰。若仅依赖通用特征提取, 难以实现精准判别。因此, 需要针对渗漏水的物理特性(低反射强度、竖向流淌)设计专门的特征增强和判定机制。

3.2. 改进策略

基于上述分析, 本文提出以下改进策略, 旨在提升 PointNet++ 在隧道衬砌病害识别中的适用性:

(1) 强度感知采样策略: 通过计算邻域反射强度的标准差表征局部强度变化剧烈程度, 并将该指标融入采样距离度量中, 使得在选择最远点时优先考虑强度特征显著的区域。这样使得渗漏水边缘等强度变化显著区域获得更高的采样密度。

(2) 反射强度加权聚合机制: 针对最大池化忽略邻域点贡献差异的问题, 在集合抽象层的多尺度特征提取中引入反射强度加权机制。该机制综合距离权重、强度异常权重, 通过逐元素相乘得到每个邻域点的综合权重, 对局部特征向量进行加权求和, 使反射强度相似的点在特征提取中获得更高贡献权重, 充分捕捉邻域点间的几何一致性和空间上下文关系。

(3) 病害注意力机制: 针对病害特征不稳定问题, 设计病害注意力单元, 根据渗漏水的物理特性(低反射强度、竖向流淌方向、空间连续性)生成渗漏水置信度分数, 并与特征向量逐元素相乘, 确保病害显著区域的特征响应被放大, 而正常区域特征被相对抑制, 有效区分渗漏水与污渍、阴影等干扰目标。

4. 隧道衬砌病害识别方法构建

4.1. 方法整体框架

改进后的网络架构如图 2 所示, 主要包括输入层、特征提取层、特征传播层和输出层四个部分。

输入层: 将原始三维点云 (x, y, z) 扩展为四维数据 (x, y, z, I) , 其中 I 为归一化后的反射强度值。四维输入使网络能够同时学习几何特征和强度特征。

特征提取层: 包含两个改进的集合抽象(Set Abstraction, SA)模块。第一层 SA 模块对输入点云进行降采样, 将输入点云从 N 个点压缩至 1024 个点, 输出 64 维局部特征; 第二层 SA 模块进一步降采样至 256 个点, 提取 128 维特征。每个 SA 模块包含强度感知采样、多尺度邻域查询和反射强度加权聚合三个子模块。在第一层 SA 模块之后引入病害注意力机制, 增强渗漏水区域的特征响应。

特征传播层: 包含两个特征传播(Feature Propagation, FP)模块, 通过距离加权插值和跳跃连接逐层恢复点云分辨率。

输出层: 采用三层共享 MLP (128-64-2)对每个点进行分类, 最后通过 Softmax 函数输出类别概率。训练阶段使用 Focal Loss 作为损失函数。

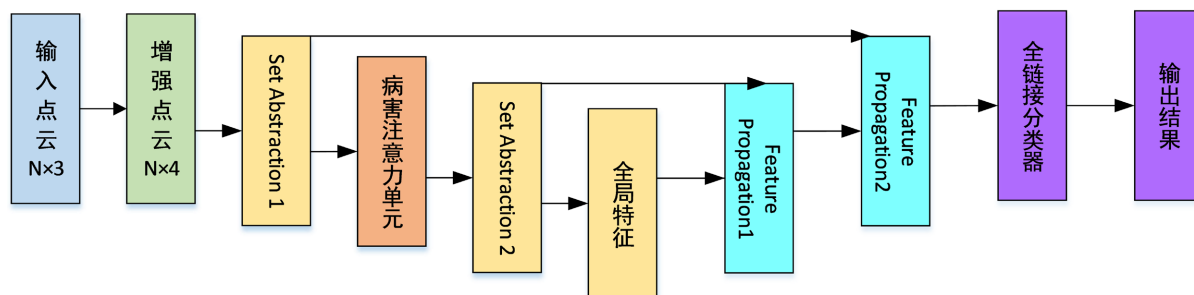


Figure 2. Framework diagram of the improved PointNet++ algorithm

图 2. 改进 PointNet++ 算法框架图

4.2. 点云数据预处理

为确保后续特征提取和病害识别的准确性, 对原始点云数据进行系统的预处理。由于隧道工程的空间跨度通常达数公里甚至数十公里, 单次扫描难以完整处理, 本文采用搭载激光扫描仪的巡检车进行连续扫描采集。巡检车沿隧道行进过程中实时获取衬砌表面的三维点云数据, 形成连续的点云序列。预处理流程主要包括点云分段切片和噪声滤除两个关键步骤。

切片阶段采用固定步长的滑动窗口策略: 沿隧道轴向每隔 5 米截取一段, 每段长度为 10 米, 保证相邻段有 50% 重叠以避免边界病害遗漏。具体示例如图 3 所示。




Figure 3. Tunnel slice diagram
图 3. 隧道切片图

点云采集过程中不可避免地会引入噪声点, 主要来自隧道螺栓、管线、电缆等附属设施; 施工人员及检测设备; 激光散射与多路径效应。这些噪声点若不加以处理, 将严重影响病害识别的准确性。

本文采用多层次滤波策略去除噪声点。首先, 统计离群点检测方法通过计算每个点与其 K 邻域点的平均距离, 将超过均值若干倍标准差的离群点判定为噪声并剔除。其次, 针对管线等线性结构干扰, 采用基于法向量一致性的区域增长算法, 将曲率与衬砌表面不符的点剥离。最后, 通过半径滤波器进一步去除孤立噪声点。经过三级滤波处理有效保留了病害区域的几何特征。滤波结果如图 4 所示。

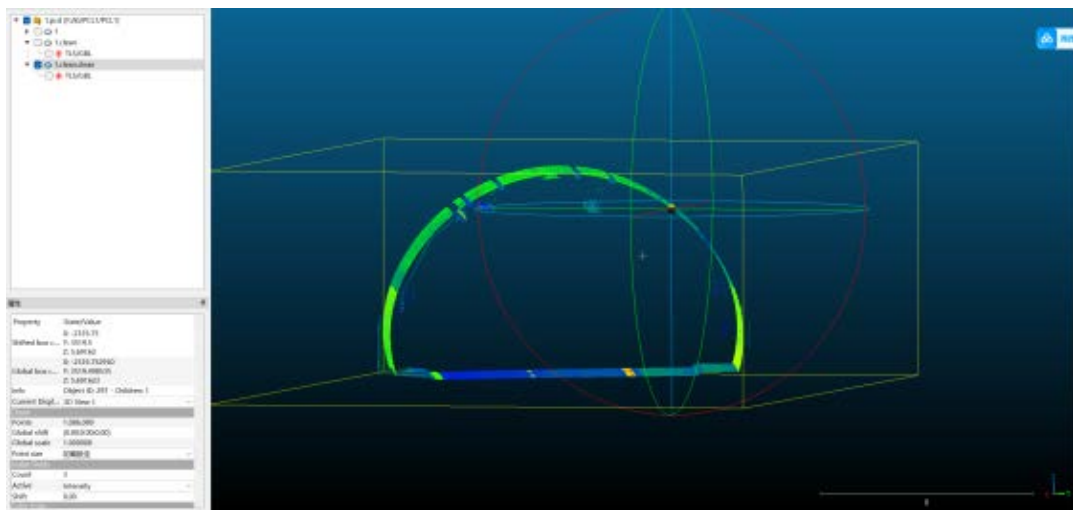


Figure 4. Noise filtering
图 4. 噪声滤除

4.3. 强度感知采样

传统 FPS 算法在选择采样点时, 仅考虑候选点与已选点集的最小欧氏距离, 未能反映点云的属性分布特征。渗漏水边缘区域的反射强度变化剧烈, 这些区域包含丰富的判别信息, 应当获得更高的采样优先级。

为解决这一问题, 本文对包含坐标和反射强度的点云进行渐进式特征抽象。首先, 通过改进的采样策略选取 1024 个代表性点作为中心点。具体而言, 该改进策略通过计算每个候选点邻域内反射强度的标

准差 $\sigma_i(i)$ 来表征局部强度变化剧烈程度, 并将该指标融入采样距离度量中, 构建综合评分函数:

$$S_i = d_i \times [1 + \lambda \cdot \sigma_i(i)] \quad (1)$$

其中 d_i 表示已选点集到候选点 i 的最小欧氏距离, $\sigma_i(i)$ 表示点 i 邻域内反射强度的标准差, 表征局部亮度差异, λ 表示强度变化权重系数。

阈值的确定基于统计分析, 对训练集中 2307 万个点进行邻域强度标准差计算, 如图 5 所示, 正常区域的 $\sigma_i(i)$ 均值为 8.3, 标准差为 3.2; 渗漏水边缘区域的 $\sigma_i(i)$ 均值为 21.7, 标准差为 6.5。取两者分布的交叉点 15 作为阈值, 此时可将约 85% 的渗漏水边缘点与正常区域点区分开。这样使得渗漏水边缘等强度变化显著区域获得更高的采样密度。统计结果如图 5 所示。

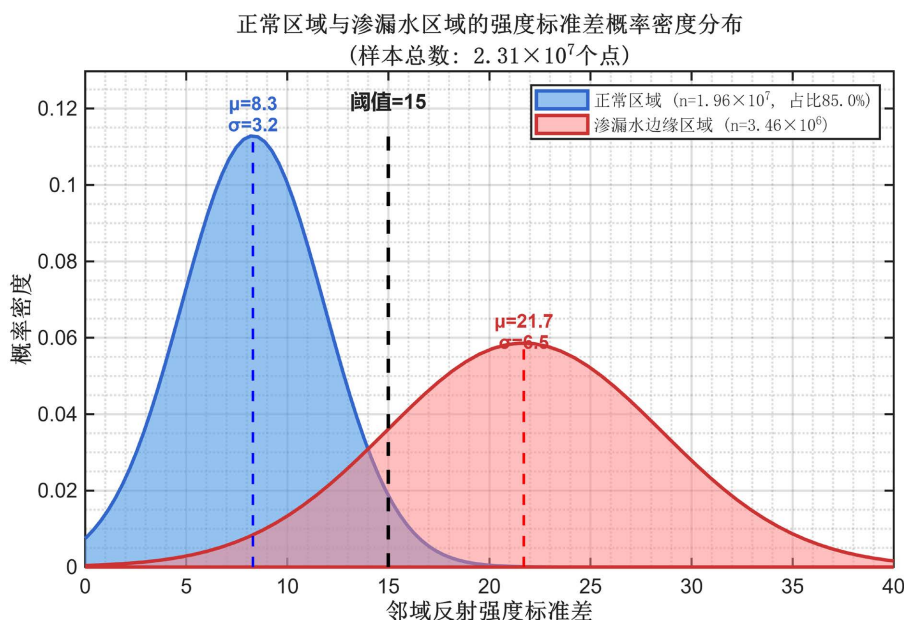


Figure 5. Distribution of standard deviation of strength
图 5. 强度标准差分布

4.4. 反射强度加权聚合

采样完成后, 基于采样得到的中心点, 采用 PointNet++ 的 Set Abstraction 架构进行特征提取。标准 SA 层包含采样层(Sampling layer), 分组层(Grouping layer)和特征提取层(PointNet layer), 本文保留采样结果, 改进分组层的特征聚合策略。

考虑到在不同尺度下提取到的特征存在差异, 在每个中心点周围构建三个并行分支, 如表 1 所示。

Table 1. Multi-scale grouping
表 1. 多尺度分组

尺度分支	球形领域半径(米)	邻近点数量	特征捕捉目标
小尺度	0.05	16	细微强度纹理特征
中尺度	0.1	32	渗漏水主体形态
大尺度	0.2	64	周围上下文信息

在每个分辨率分支的特征聚合过程中引入反射强度加权机制, 即对每个分辨率分支中局部邻域内的点计算两种权重并进行综合:

距离权重 ω_d : 采用高斯核函数确保空间邻近点获得更高权重。具体公式如下:

$$\omega_d = e^{\frac{-d^2}{2\sigma^2}} \tag{2}$$

强度异常权重 ω_l : 计算邻域点反射强度偏离邻域平均值的程度: 具体公式如下:

$$\omega_l = e^{-\frac{|I_p - \mu_l|}{\sigma_l}} \tag{3}$$

其中 I_p 为邻域点反射强度, μ_l 为邻域平均强度, σ_l 为邻域强度标准差, 使得强度异常的点(渗漏水特征)贡献更大:

综合权重计算: $\omega_i = \omega_d \times \omega_l$, 然后对每个中心点的周边邻域点权重进行归一化处理(使其总和为 1), 该归一化后的权重矩阵用于对邻域点的 64 维局部特征向量进行加权求和, 从而得到中心点在该尺度下的 64 维局部聚合特征。

三个尺度分支的输出特征(每个尺度分支的 64 维局部聚合特征)通过拼接操作融合为 192 维特征向量, 再经过一维卷积层降维至 64 维。

具体如图 6 所示。

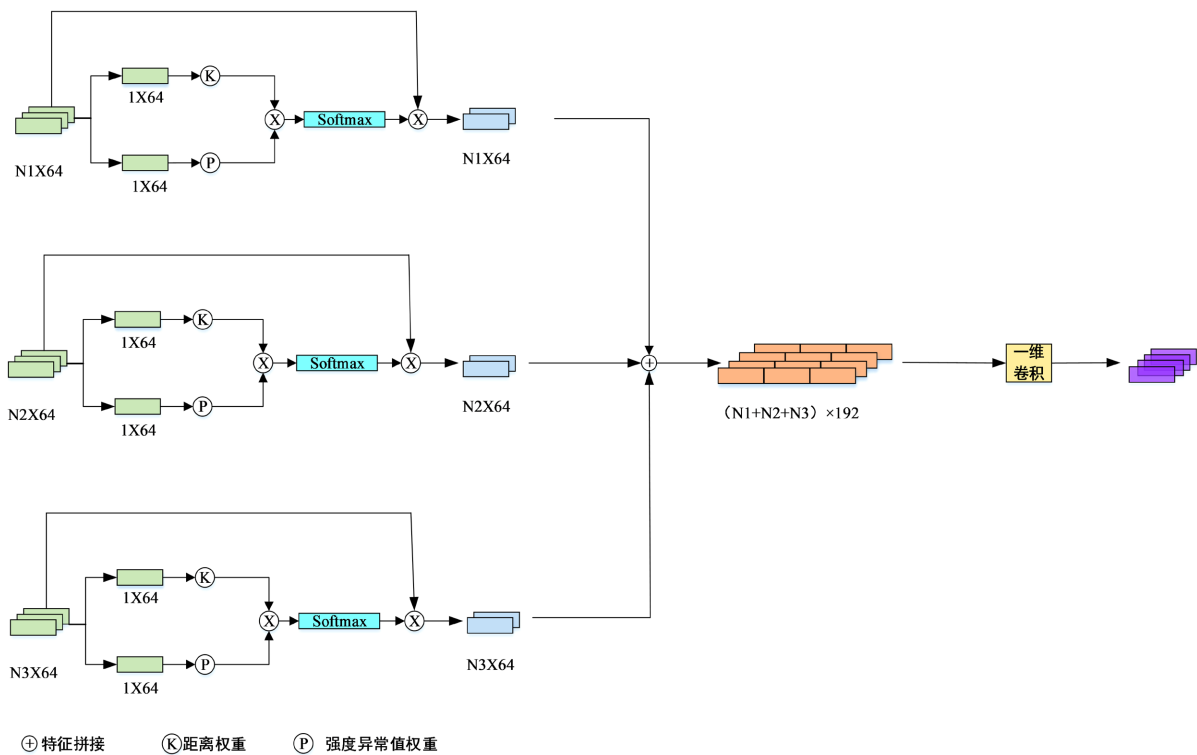


Figure 6. Schematic diagram of weighted aggregation of reflection intensity

图 6. 反射强度加权聚合示意图

4.5. 病害注意力机制

为进一步提升对渗漏水区域的判别能力, 在第一层集合抽象模块(SA1)之后引入病害注意力机制。该

机制根据渗漏水物理特性(低反射强度、竖向流淌方向)生成每个点的病害置信度分数, 用于增强特征。具体实施如下:

反射强度异常度计算: 由于水分吸收激光能量, 渗漏区域的反射强度显著低于干燥混凝土表面。统计分析表明, 正常区域的反射强度分布在 15,000 以上之间, 而渗漏区域通常低于 15,000。定义反射强度异常度: 来衡量每个点的强度偏离程度, 当点的反射强度 I 低于阈值 T (设为 60) 时, 异常度 α_i 大于 0, 反射强度越低异常度越高。

$$\alpha_i = \max\left(0, \frac{T-I}{T}\right) \tag{4}$$

其中 I 为点的归一化反射强度(取值范围[0, 255]), T 为强度阈值。

方向性约束: 渗漏水受重力作用沿竖直方向流淌, 形成竖向条带状分布模式。在每个疑似渗漏点周围设置球形邻域半径 0.15 米, 通过主成分分析获取疑似渗漏点邻域的主方向向量 \mathbf{d}_i , 并计算该方向与重力方向的夹角 β_i 。根据夹角的大小, 定义了方向性得分, 得分越大表示疑似渗漏区域的主方向与重力方向越接近, 越符合水流的物理特性。

$$\beta_i = \arccos\left(\frac{|\mathbf{d}_i \cdot \mathbf{g}|}{|\mathbf{d}_i||\mathbf{g}|}\right) \tag{5}$$

其中 \mathbf{d}_i 为疑似渗漏点区域的主方向, \mathbf{g} 重力方向 $\mathbf{g} = [0, 0, -1]^T$ 。

空间连续性特征 ρ : 计算邻域内低反射强度点的密度, 密度越高表示渗漏水区域的连续性越强。

$$\rho = \frac{N_{low}}{N_{total}} \tag{6}$$

其中 N_{low} 为反射强度 $< T$ 的点数, N_{total} 为邻域总点数。

为消除三个先验特征因统计特性差异可能引入的偏置, 在送入 MLP 之前对反射强度异常度 α 、方向性得分 β 、空间连续性 ρ 三均按训练集统计量进行 Min-Max 归一化, 将各维映射至 [0, 1] 区间。将这 3 个特征拼接为三维向量, 输入两层多层感知神经网络(3→16→8→1)并经 Sigmoid 激活, 生成每个点的渗漏水置信度分数。将邻域内每个点的渗漏水置信度分数求平均获取邻域置信度分数 S 并与第一层集合抽象单元得到的 64 维特征向量逐元素相乘, 得到增强的 64 维特征。该操作确保渗漏水显著区域的特征响应被放大, 而正常区域的特征被相对抑制。增强后的特征传递给第二层集合抽象单元进行进一步的高层语义抽象。示意图如图 7 所示。




Figure 7. Schematic diagram of pest damage attention mechanism

图 7. 病害注意力机制示意图

4.6. 特征降维与分类决策

在 PointNet++ 网络的第二层集合抽象模块后, 点云特征维度已扩展至 128 维。尽管高维特征空间能

够编码更丰富的几何与语义信息,但也带来了计算复杂度的显著增加和潜在的特征冗余问题。为在保持特征判别能力的前提下提升模型的计算效率,本研究在特征提取流程中引入主成分分析(Principal Component Analysis, PCA)降维单元。PCA 降维单元位置在第二层集合抽象模块(SA2)输出之后、特征传播(FP)模块之前,这一位置的选择基于以下两点考量。

(1) SA2 层在融合多尺度分组特征时,将三个尺度分支各 64 维的局部聚合特征拼接为 192 维,再经一维卷积压缩至 128 维;该压缩过程由卷积核端到端学习,不以消除线性相关性为目标,因此跨尺度的重叠信息难以被完全去除。

(2) FP 模块在上采样阶段需对每个目标点进行距离加权插值,运算量正比于特征维度与点数之积。以 FP1 为例,需将 256 个点的特征插值传播至 1024 个点,若以 128 维特征作为插值对象,该过程涉及数千万次浮点运算;在 SA2 之后率先降至 64 维,可使 FP 阶段逐点插值的计算量减少约 50%,冗余在向全部点云传播之前即被消除。相比之下,若将 PCA 置于 SA1 之后,高层语义特征尚未充分形成,过早压缩将损失判别信息;若置于 FP 之后,冗余已随插值传播至全部点云,降维效益大打折扣。

在降维方式的选择上,PCA 较可学习的 1×1 卷积降维更为适宜,原因如下。本研究数据集规模有限(320 个点云片段),在此约束下引入额外参数的卷积层存在过拟合风险;而 PCA 以最大化方差保留为准则,通过对训练集特征协方差矩阵进行特征分解确定投影方向,属确定性线性变换,不引入任何可学习参数,因此不增加过拟合风险,与小样本场景高度契合。

PCA 作为经典的线性降维方法,通过正交变换将可能相关的高维特征映射到线性无关的低维主成分空间。具体而言,设第二层集合抽象后提取的特征矩阵为 $F \in R^{N \times 128}$,其中 N 为点云数量。首先对特征矩阵进行中心化处理:

$$F_{centered} = F - \mu \quad (7)$$

其中 μ 为各特征维度的均值向量。随后计算协方差矩阵:

$$C = \frac{1}{N-1} F_{centered}^T F_{centered} \quad (8)$$

并对其进行特征值 $\lambda_1 > \lambda_2 > \dots > \lambda_{128}$ 分解得到特征值及对应的特征向量 v_1, v_2, \dots, v_{128} 。

主成分的选择遵循累计方差贡献率准则。第 k 个主成分的方差贡献率定义为:

$$\eta_k = \frac{\lambda_k}{\sum_{i=1}^{128} \lambda_i} \quad (9)$$

累计方差贡献率为 $\sum_{i=1}^k \eta_i$ 本研究设定阈值为 95%,即选择前 k 个主成分使得

$$\sum_{i=1}^k \eta_i > 0.95 \quad (10)$$

经过实验验证, $k = 64$ 时即可满足该条件,实现从 128 维到 64 维的降维,特征维度压缩率达 50%。降维后的特征表示为:

$$F_{reduced} = F_{centered} \cdot [v_1, v_2, \dots, v_{64}] \quad (11)$$

从理论分析角度,PCA 将特征维度从 128 维压缩至 64 维,压缩率达 50%,直接减少了后续 MLP 分类器的参数量和计算量。在降维完成后,通过两层特征传播(Feature Propagation, FP)模块逐层恢复点云的空间分辨率。FP 模块采用距离加权插值策略,结合跳跃连接(skip connection)机制,将编码阶段不同层级的特征进行融合。具体来说,FP1 模块将 256 个点的特征上采样至 1024 个点,FP2 模块进一步将特征恢复至与输入点云相同的分辨率(2048 个点)。经过特征传播后,每个点的特征通过跳跃连接融合了多层级

信息, 形成 128 维的综合特征表示。该特征向量随后输入至分类决策模块, 完成逐点类别预测。分类模块由三层共享 MLP 构成, 通道数依次为 128-64-2, 最后通过 Softmax 函数输出每个点属于渗漏水或正常区域的概率。融合特征既包含了经 PCA 降维后的高层语义信息, 又通过跳跃连接保留了原始输入的精细几何与光谱特征, 确保了分类决策的准确性。

5. 模型训练与评估

5.1. 试验环境搭建

试验采用 4 折交叉验证方法, 批处理大小为 16, 点云块大小为 1.0 m × 1.0 m × 1.0 m, 采样点数为 15,000。所有试验在相同环境配置下进行, 具体配置如表 2 所示。

Table 2. Environmental configuration table

表 2. 环境配置表

	类别	参数
硬件	GPU	RTX 4060
	CPU	Intel Core i5-12600K CPU, 3.40 GHz
软件	深度学习框架	PyTorch 1.10.0
	系统	Windows
	编程语言	Python 3.8
	CUDA 型号	11.3

5.2. 评价指标

为全面评估本文改进算法在隧道衬砌病害识别任务中的性能, 采用精确率(Precision)、召回率(Recall)、F1-Score、交并比(IoU)等指标进行定量分析。

其中, Precision 与 Recall 分别反映模型的识别准确性与检出能力; F1-Score 作为两者的调和平均值, 能够综合衡量模型在误报与漏检间的平衡表现。IoU 主要用于评估预测结果与真实标签的重叠程度, 是语义分割任务的重要指标各指标取值范围均为[0, 1], 数值越高表示模型性能越优。

5.3. 实验设置

实验采用自建隧道衬砌病害点云数据集进行验证。数据采集自某隧道, 使用 Pandar XT-16 激光扫描仪进行采集, 扫描分辨率为 0.5 mm, 有效扫描距离为 0.6~330 m, 点云密度约为 5000 点/m²。数据采集涵盖不同光照条件、扫描角度及多种病害类型场景, 确保数据集的多样性与代表性。

数据集共包含 320 个点云片段, 总点数约 2307 万个, 每个片段平均含 72,094 个采样点。其中渗漏水病害样本 223 个、正常区域样本 97 个。按照 7:2:1 的比例划分训练集、验证集与测试集, 分别包含 224、64 和 32 个片段, 以确保模型的泛化性能。数据标注由 3 名具有隧道工程背景的专业人员完成, 采用 CloudCompare 软件进行手工标注。

模型训练采用 AdamW 优化器, 初始学习率设为 0.001, 并引入余弦退火(Cosine Annealing)学习率调度策略以实现动态更新。批处理大小(Batch Size)设为 16, 训练轮次(Epoch)为 150。所有实验在配置为 NVIDIA RTX 4060 GPU、Intel Core i5-12600K CPU 及 32GB 内存的工作站上完成。为增强模型的鲁棒性

与泛化能力, 数据预处理阶段引入多种数据增强策略, 包括随机旋转、随机缩放、随机平移等。

6. 实验结果与分析

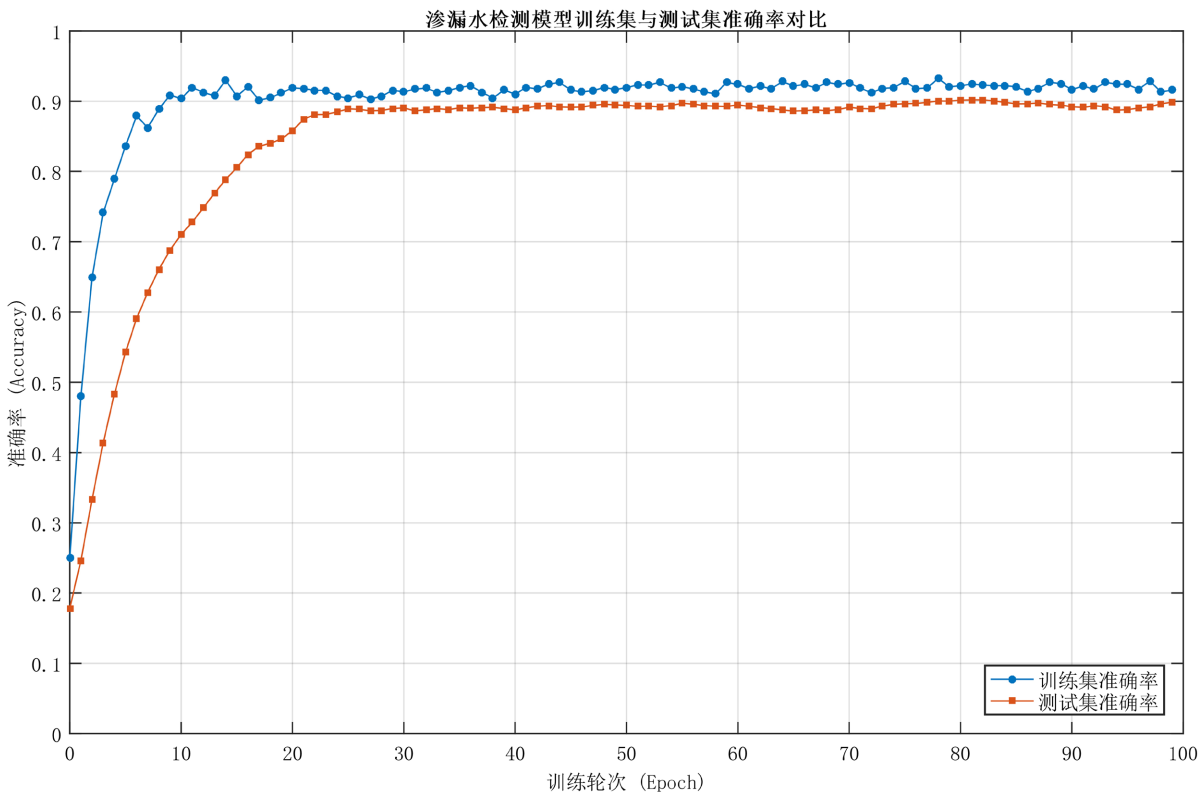
6.1. 模型有效性验证

本实验对深度学习模型进行了完整的训练过程监控, 通过 100 个 epoch 的迭代优化, 观察模型的收敛特性和泛化能力。训练过程中同时记录了训练集与测试集的准确率和损失值的变化轨迹, 为模型性能评估提供了全面的数据支持。训练曲线如图 8 所示。

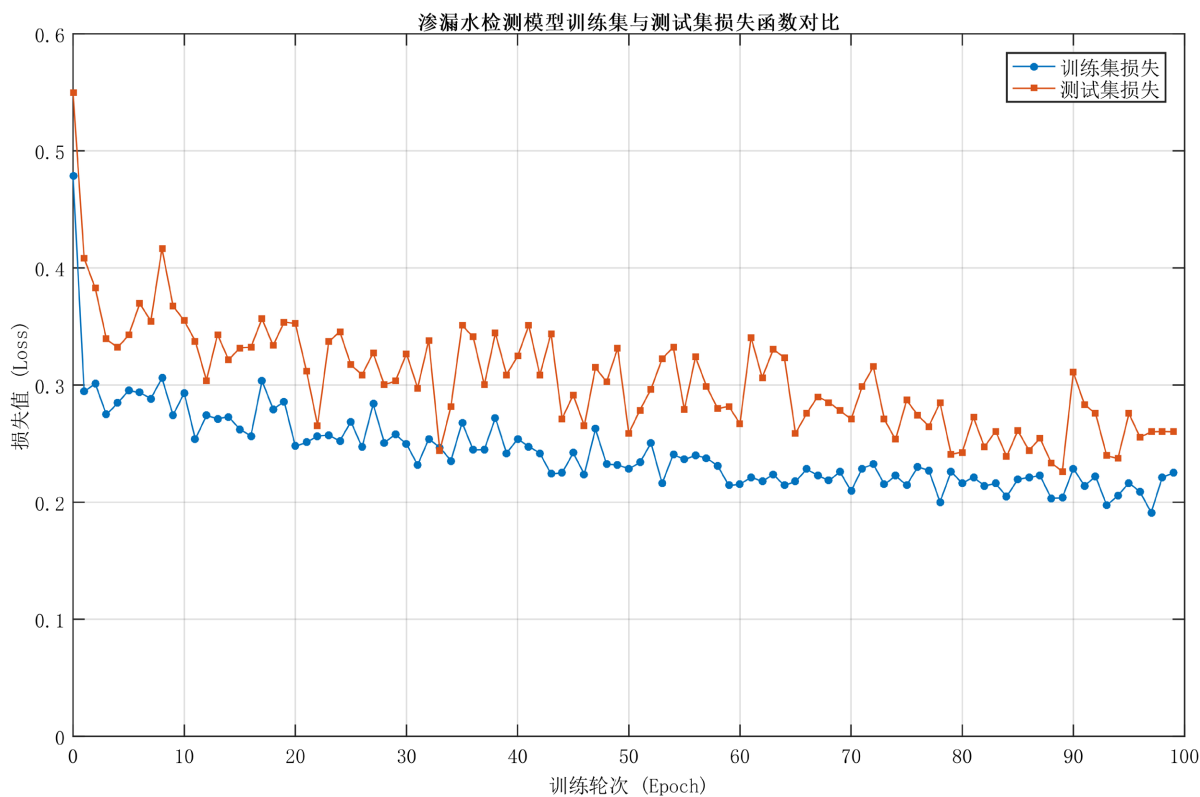
训练集准确率呈现出典型的快速收敛特征。在训练初期(前 10 个 epoch), 准确率经历了急剧上升阶段, 从接近 0 快速攀升至 0.9 以上, 展现出模型强大的学习能力。进入第 10~20 个 epoch 后, 准确率增长速度明显放缓, 逐步逼近 0.92 左右的稳定值。在第 20 个 epoch 之后, 训练准确率基本稳定。

测试集准确率的变化趋势与训练集相似但存在明显差异。测试集准确率同样在前 10 个 epoch 快速上升, 但上升速度相对较慢, 在第 20 个 epoch 左右达到约 0.88 的稳定值。值得注意的是, 训练集与测试集准确率之间存在约 0.04 的差距, 这一差距在整个训练过程中保持相对稳定, 说明模型具有良好的泛化能力, 没有出现严重的过拟合现象。

训练集损失在训练初期(前 5 个 epoch)从初始的高位快速下降至 0.3 左右, 反映出模型预测误差的迅速减小。在第 5~20 个 epoch 区间, 损失曲线继续平稳下降, 最终稳定在 0.2~0.25 的低位水平。测试集损失的变化规律与训练集基本一致, 但整体数值略高于训练集损失, 逐渐稳定在 0.25~0.30 区间。整体而言, 两条损失曲线的平滑收敛特性说明训练过程稳定, 未出现明显的震荡或发散现象, 模型达到了较为理想的训练效果。



(a) 准确率曲线



(b) 损失函数曲线

Figure 8. Training curve of leakage water model

图 8. 渗漏水模型训练曲线图

6.2. 整体性能对比

不同算法检测性能对比如表 3 所示, 从结果上看, 本文方法在各项指标上均取得最优性能。与原始 PointNet++相比, Precision 提升 5.8 个百分点, Recall 提升 8.7 个百分点, F1-Score 提升 7.3 个百分点, IoU 提升 9.2 个百分点, 验证了各改进模块在提升模型准确性与完整性方面的有效性。与其他主流方法相比, 本文方法的 F1-Score 较 DGCNN 提升 7.1 个百分点, 较 PointCNN 提升 5.6 个百分点, 充分证明了所提改进策略的优越性。

Table 3. Comparison of water leakage detection performance of different methods

表 3. 不同方法的渗漏水检测性能对比

方法	Precision (%)	Recall (%)	F1-Score (%)	IoU (%)
PointNet	80.3	65.5	72.2	56.5
PointNet++	84.7	73.0	78.5	64.7
DGCNN	83.4	74.4	78.7	64.9
PointCNN	85.5	75.4	80.2	67.0
本文方法	90.5	81.7	85.8	73.9

6.3. 消融实验分析

为验证各模块对性能的贡献, 设计了消融实验, 结果如表 4 所示。

Table 4. Results of the ablation experiment

表 4. 消融实验结果

模型配置	强度采样	加权聚合	注意力	F1-Score (%)	IoU (%)
Baseline	-	-	-	78.5	64.7
1	√	-	-	80.1	68.1
2	-	√	-	82.7	71.5
3	-	-	√	81.1	66.9
4	√	√	-	83.5	72.3
5	√	-	√	83.2	71.8
6	-	√	√	84.7	73.5
7	√	√	√	85.8	73.9

从消融实验结果可以归纳出以下规律:

(1) 加权聚合是最核心的单模块。模型 2 (仅加权聚合)使 F1-Score 提升 4.2%, 显著高于强度采样(1.6%) 和病害注意力(2.6%)。这说明在特征聚合阶段直接融入强度信息, 比在采样阶段调整点分布更能触及渗漏水识别的瓶颈。

(2) 强度采样与加权聚合存在一定信息重叠。模型 4 (采样 + 聚合)的 F1-Score 为 83.5%, 而若两者贡献完全独立, 预期值应约为 84.3%。实际值低于预期, 表明二者均以反射强度为核心线索, 存在一定特征冗余。这提示未来设计时, 可考虑将两者合并为统一的“强度感知特征提取”模块, 以降低网络复杂度。

(3) 加权聚合与病害注意力具有良好协同效应。模型 6 (聚合 + 注意力)的 F1-Score (84.7%)接近三模块完整版(85.8%), 且高于其他双模块组合。其机制在于: 加权聚合提供精细的局部特征描述, 病害注意力则在全局层面筛选高置信度区域, 两者分别作用于特征的“质量”和“选择性”, 形成互补。

(4) 三模块集成的边际收益递减。在模型 6 基础上加入强度采样后(完整模型 7), F1-Score 仅提升 1.1%, 表明在加权聚合和注意力机制已充分利用强度信息的情况下, 强度采样的边际贡献有所压缩。该模块的价值更多体现在 IoU 的稳定提升上(73.5% → 73.9%), 即对渗漏水区域边界定位的改善。

6.4. 训练结果可视化

图 9 展示了本文方法在隧道衬砌点云上的渗漏水识别效果对比。图中蓝色区域表示正常衬砌表面, 红色区域表示识别出的渗漏水病害。从整体视觉效果来看, 两者在渗漏水区域的空间分布、形态特征和边界轮廓上具有高度一致性, 证明了本文方法的有效性。

具体而言, 检测结果在以下方面表现出良好性能:

(1) 区域定位准确。隧道两侧壁面的渗漏水分布位置被准确捕捉, 左侧条带状区域与右侧大面积区域的空间位置均与真值标注吻合, 体现了模型良好的空间感知能力。

(2) 形态特征保持。渗漏水的竖向条带状分布特征得到较好保留。强度 - 方向性联合判定机制通过重

力方向性验证(夹角 $< 30^\circ$)有效约束了空间形态, 避免误检为离散点状分布。

(3) 边界识别清晰。渗漏水与正常区域的边界过渡清晰可辨, 未出现明显模糊或过度分割。右侧壁面边缘的锯齿状轮廓被较好还原, 表明 PCA 多模态特征融合模块能有效提取边界处的细微几何变化。

(4) 误差分析。右侧壁面检测范围略大于真值标注, 模型在边界模糊区域倾向保守判定以降低漏检风险; 左侧壁面检测结果与真值重合度极高。




Figure 9. Comparison chart of true values and detection results
图 9. 真值与检测结果对比图

7. 结论

本文针对传统点云投影方法在隧道衬砌渗漏水识别中存在的信息损失和投影角度依赖性问题, 提出了一种基于改进 PointNet++ 的识别方法。主要结论如下:

(1) 提出了强度感知采样策略, 通过融合反射强度标准差信息优化采样过程, 使渗漏水边缘等强度变化显著区域获得更高采样密度, F1-Score 相比基线模型提升 1.6 个百分点。

(2) 设计了反射强度加权聚合机制, 综合距离权重和强度异常权重调制邻域特征贡献, 充分捕捉邻域点间的空间上下文关系, 使 F1-Score 进一步提升 4.2 个百分点。

(3) 引入了病害注意力机制, 通过反射强度异常度、方向性约束和空间连续性三重约束生成置信度分数, 有效区分了渗漏水与污渍、阴影等干扰目标, 使 F1-Score 提升 2.6 个百分点。

(4) 采用 PCA 降维优化计算效率, 在保持特征判别能力的前提下将特征维度从 128 维压缩至 64 维, 参数量减少 50%。使用 Focal Loss 解决样本不均衡问题, 最终在自建数据集上达到 85.8% 的 F1-Score 和 73.9% 的 IoU, 相比基线 PointNet++ 分别提升 7.3 和 9.2 个百分点。

本研究方法在以下方面仍存在内在局限, 值得深入探讨:

(1) 形态先验的局限性。病害注意力机制中的方向性约束(夹角 $< 30^\circ$)依赖渗漏水“竖向流淌”的物理假设。然而, 实际工程中存在多种非竖向形态的渗漏: 隧道顶拱的滴水(从点状或弧形缝隙渗出, 无显著方向性)、水平施工缝处的横向渗水(主方向接近水平)等。当前方法对这类形态的处理能力尚未验证, 未来工作中需采集涵盖上述场景的数据, 并研究更具普适性的方向性约束机制(如松弛夹角阈值或引入多方向先验)。

(2) 相似目标的混淆问题。实际隧道中, 沥青渗漏、机油污染等同样表现为低反射强度且可能呈竖向分布, 与渗漏水在特征空间高度相似。未来工作应重点研究基于时间序列(如同一区域多期扫描)或多模态融合(如可见光 + 点云)的鉴别方法, 以提升对相似低反射目标的辨别能力。

(3) 动态场景下的泛化性。当前数据集采集自单一隧道, 扫描条件相对固定。不同隧道类型(盾构隧

道/矿山法隧道)的衬砌材质和表面纹理存在差异,可能导致正常区域反射强度阈值漂移。未来研究跨域自适应策略,如基于目标隧道少量标注样本的微调方法,提升模型跨场景的实用性。

(4) 扩展数据集与轻量化。在扩充数据集时,需重点补充非竖向渗漏、临界状态(初始渗漏)以及与污渍共存的复杂场景样本。在轻量化方面,可结合 PCA 压缩的思路,探索在移动端激光扫描设备上实现实时检测的可行性。

参考文献

- [1] 刘欢欢. 基于三维点云数据的道路三维病害检测[J]. 中国科技信息, 2025(14): 91-93.
- [2] 邹政, 刘丰军, 陆键. 基于三维点云的路面多类型病害识别研究[J/OL]. 物流科技, 1-7. <https://link.cnki.net/urlid/10.1373.F.20250619.1013.004>, 2025-10-30.
- [3] 付勤友. 基于分布式光纤测温系统的综合管廊管道渗漏监测研究[D]: [硕士学位论文]. 武汉: 湖北工业大学, 2021.
- [4] 张旻. 移动式三维激光扫描系统在地铁隧道病害检测中的应用[J]. 铁道勘察, 2024, 50(6): 6-11.
- [5] 张振海, 孙岩, 李哲远. 基于 MDS-YOLO 的轻量级隧道表观病害检测算法[J/OL]. 交通运输工程学报, 1-14. <https://doi.org/10.19818/j.cnki.1671-1637.2025.06.022>, 2025-11-01.
- [6] 方力涵, 张庆文, 李卫国, 等. 基于改进 YOLOv5 的隧道衬砌病害精确检测方法[J]. 科学技术与工程, 2025, 25(16): 6812-6820.
- [7] 王秋生, 李佳豪, 贺鹏, 等. 基于 LiDAR 技术的地铁隧道渗漏水识别方法及应用[J]. 应用基础与工程科学学报, 2025, 33(3): 792-802.
- [8] 潘国兵, 赵雪妍, 陈昌文, 等. 基于点云密度自适应 VAlpha-Shapes 算法的隧道渗漏水检测[J]. 测绘工程, 2025, 34(2): 1-7+23.
- [9] 王健, 郑理科, 吴斌杰, 等. 改进 Mask RCNN 的盾构隧道渗漏水检测方法[J]. 测绘通报, 2024(2): 170-177.
- [10] 刘育初. 基于深度学习的隧道衬砌渗漏水智能识别[J]. 土木工程, 2023, 12(8): 1123-1128.
- [11] 赵怡荣. 基于改进 PointNet++的船体分段合拢面点云语义分割算法研究[D]: [硕士学位论文]. 大连: 大连理工大学, 2024.