

基于深度学习的道路裂缝快速检测方法研究

陈晓东

新疆兵团水利水电工程集团有限公司 新疆 乌鲁木齐 830011

摘要：本文围绕道路裂缝检测展开，剖析传统检测方法在人工巡检与图像处理应用中的局限，系统介绍深度学习从理论到模型架构及训练机制的相关知识。在此基础上，构建基于深度学习的道路裂缝快速检测方法，通过合理选择模型架构、开展全面的数据采集与预处理，以及对模型进行训练与优化，实现对道路裂缝的高效检测。该研究有望推动道路裂缝检测技术的发展，助力道路养护管理工作的高效开展。

关键词：深度学习；道路裂缝；快速检测方法

引言

道路作为交通系统的关键基础设施，其路面状况直接影响交通安全与使用寿命。道路裂缝作为常见病害，不仅破坏道路外观，还会降低路面承载能力，加速路面损坏。早期道路裂缝检测依赖人工巡检，效率与准确性欠佳。随着计算机技术的发展，基于图像处理的检测方法虽有所进步，但因道路环境复杂，仍难以满足需求。深度学习技术的兴起，为解决道路裂缝检测难题提供新途径，有望实现裂缝的快速、准确检测，为道路养护管理提供技术支撑。

1 道路裂缝检测概述

1.1 道路裂缝类型及特点

道路裂缝依据形态和成因，主要分为横向裂缝、纵向裂缝、网状裂缝和块状裂缝。横向裂缝通常垂直于道路中心线，多由温度变化、地基不均匀沉降引发；纵向裂缝则平行于道路中心线，常因路基压实不均或路面结构设计不合理导致；网状裂缝呈不规则网状分布，主要由路面材料老化、疲劳损坏造成；块状裂缝将路面分割成不规则块状，通常与路基病害及路面长期使用有关。这些裂缝不仅形态各异，在尺寸、宽度和密度上也存在较大差异，为检测工作带来诸多挑战。

1.2 传统检测方法的局限性

早期道路裂缝检测主要依靠人工巡检，检测人员凭借肉眼和简单工具，如直尺、放大镜，对道路表面进行观察和测量。这种方法不仅劳动强度大、效率低，检测结果还受检测人员主观因素影响，难以保证准确性和一致性。后来，基于图像处理的方法逐渐兴起，这类方法通过对采集到的道路图像进行灰度化、滤波、边缘检测等处理，提取裂缝特征。然而，由于道路环境复杂，存在光照不均、噪声干扰等问题，基于传统图像处理算法的检测方法抗干扰能力弱，对于复杂背景下的裂缝检测

效果欠佳，且难以实现自动化和实时检测。

2 深度学习基础理论

2.1 深度学习发展历程

深度学习起源于人工神经网络研究，经历了从感知机到多层神经网络，再到深度学习的发展过程。2006年，Hinton等人提出深度信念网络，通过无监督预训练解决了深层神经网络训练困难的问题，推动深度学习进入快速发展阶段。随后，卷积神经网络、循环神经网络等深度学习模型相继被提出，并在图像识别、语音识别、自然语言处理等领域取得显著成果，为道路裂缝检测提供了有力技术支持。

2.2 神经网络架构

神经网络是一种模拟人类大脑神经元结构的计算模型，由大量节点和连接这些节点的边组成。在深度学习中，最常用的神经网络架构是多层感知机、卷积神经网络和循环神经网络。

多层感知机由输入层、隐藏层和输出层组成，层与层之间通过权重连接。隐藏层可以有多个，每个隐藏层的神经元通过激活函数对输入数据进行非线性变换，从而学习到数据的复杂特征。

卷积神经网络引入卷积层、池化层等特殊结构，有效减少模型参数数量，降低计算复杂度，同时保留图像的空间结构信息^[1]。卷积层利用卷积核在图像上滑动卷积，以此提取图像局部特征，捕捉空间层次信息。池化层则对卷积层输出的特征图进行下采样，减少数据量，降低过拟合风险。

循环神经网络可处理序列数据，其隐藏层融合当前输入与上一时刻隐藏状态，有效捕捉数据中的时间依赖关系。在道路裂缝检测中，卷积神经网络因其对图像数据的强大处理能力，成为应用最为广泛的模型架构。

2.3 深度学习训练机制

深度学习模型训练依赖反向传播算法,该算法先计算预测值与真实标签误差,再从输出层起反向传播误差信号,调整各层的权重参数,使误差逐渐减小。在模型训练中,需定义损失函数评估预测值与真实标签的差距。常用损失函数有均方误差损失和交叉熵损失等。

为防过拟合,常采用L1、L2等正则化技术,通过约束模型复杂度提升泛化能力。此外,还可以通过调整学习率、选择合适的优化算法(如随机梯度下降(SGD)、Adagrad、Adadelta、Adam等)来提高模型的训练效率和收敛速度。

3 基于深度学习的道路裂缝快速检测方法构建

3.1 模型架构选择

在构建道路裂缝快速检测模型时,需要综合考虑检测精度和速度。对于实时性要求较高的场景,如车载实时检测系统,需要选择轻量级的模型架构。MobileNet采用深度可分离卷积,将传统的卷积操作分解为深度卷积和逐点卷积,大大减少了模型的参数数量和计算量。ShuffleNet通过通道洗牌操作,提高了特征的利用率,进一步降低了模型的复杂度。这些轻量级模型在保证一定检测精度的前提下,能够显著提高检测速度,满足实时性要求。

对于对检测精度要求较高的场景,如道路养护部门对道路状况进行详细评估时,可以选择性能更强大的模型。ResNet通过引入残差结构,解决了深层神经网络训练过程中的梯度消失和梯度爆炸问题,使得模型能够加深到数百层,从而学习到更复杂的特征。DenseNet通过密集连接,使每一层都能直接获取前面所有层的特征信息,提高了特征的利用率,进一步提升了模型的性能^[2]。在使用这些模型时,可以结合适当的优化策略,如剪枝、量化等,在不显著降低检测精度的前提下,减少模型的参数数量和计算量,提高检测速度。

此外,还可以根据道路裂缝的特点对模型进行针对性改进。道路裂缝具有细长的形状,为了增强模型对裂缝特征的关注,可以在模型中引入注意力机制。注意力机制能够让模型自动学习到不同区域的重要性,对裂缝区域给予更多的关注,从而提高裂缝检测的准确性。多尺度特征融合技术也可以应用于道路裂缝检测模型中。不同尺度的裂缝在图像中表现出不同的特征,通过融合不同尺度的特征图,模型能够获取更全面的裂缝信息,提高对不同尺度裂缝的检测能力。

3.2 数据采集与预处理

3.2.1 数据采集

高质量的数据集是训练有效深度学习模型的基础。

数据采集可以通过车载摄像头、无人机航拍等方式获取道路图像。车载摄像头能够在车辆行驶过程中实时采集道路图像,适用于对城市道路和高速公路的检测。无人机航拍则可以获取大面积道路的图像,对于乡村道路和偏远地区的道路检测具有优势。

为了提高模型的泛化能力,采集的图像应涵盖不同类型的道路,包括高速公路、城市道路、乡村道路等。不同类型的道路在路面材质、交通流量、养护状况等方面存在差异,采集多样化的道路图像能够使模型学习到不同场景下的裂缝特征。路面材质也是影响裂缝特征的重要因素,水泥路面和沥青路面的裂缝表现形式有所不同,因此采集的图像应包括不同路面材质的道路。此外,光照条件和天气状况对图像质量和裂缝特征的提取有较大影响。在不同光照条件下,裂缝的对比度和清晰度会发生变化;在雨天、雪天等恶劣天气条件下,路面可能会积水、积雪,掩盖裂缝特征。因此,采集的图像应包括不同光照条件和天气状况下的道路图像。

对采集到的图像进行标注是数据采集的重要环节。标注内容包括裂缝的位置、形状等信息。常用的标注工具包括Labelme、VGG Image Annotator等。标注人员需要具备一定的专业知识,准确地标注出裂缝的边界和类型,为模型训练提供准确的标签。

3.2.2 数据预处理

数据预处理是提高模型训练效率和检测性能的重要环节。常见的数据预处理操作包括图像增强、归一化和数据划分。

图像增强通过对原始图像进行旋转、缩放、裁剪、添加噪声等操作,扩充数据集规模,增加数据的多样性^[3]。旋转操作可以将图像按照一定的角度进行旋转,使模型能够学习到不同角度的裂缝特征。缩放操作可以改变图像的大小,模拟不同距离下拍摄的图像。裁剪操作可以从图像中提取不同区域的子图像,增加数据的丰富性。添加噪声操作可以模拟实际采集过程中图像受到的噪声干扰,提高模型的抗干扰能力。通过图像增强,模型能够学习到更广泛的裂缝特征,提高模型的泛化能力。

归一化将图像的像素值映射到特定的范围,如[0,1]或[-1,1]。在深度学习模型训练过程中,归一化能够使不同特征具有相同的尺度,加速模型的收敛速度。常见的归一化方法有Min-Max归一化和Z-Score归一化。Min-Max归一化将像素值映射到[0,1]范围内,通过减去最小值并除以最大值与最小值的差来实现。Z-Score归一化则将像素值映射到均值为0,标准差为1的分布上,通过减去均值并除以标准差来实现。

数据划分时将数据集分为训练集、验证集和测试集，训练集用于模型学习特征规律。验证集用于调整模型的超参数，如学习率、迭代次数等，防止模型过拟合。测试集用于评估模型的性能，检验模型在未知数据上的泛化能力。

3.3 模型训练与优化

3.3.1 训练过程

模型训练需先选定适配的损失函数与优化算法，以指导模型学习。对于道路裂缝检测任务，如果将其看作分类任务，即判断图像中是否存在裂缝，常用的损失函数是交叉熵损失函数。如果将其看作目标检测任务，需要同时考虑分类损失和回归损失，分类损失用于判断裂缝的类型，回归损失用于定位裂缝的位置。常用的目标检测损失函数包括Smooth L1损失、IoU损失等。对于语义分割任务，Dice损失函数可有效衡量预测与真实标签相似度，交叉熵损失函数亦为常用选择，二者各具优势。

优化算法通常选择随机梯度下降及其变体。Adagrad算法能够自适应地调整学习率，根据每个参数的梯度历史信息来调整学习率，对于稀疏数据具有较好的效果。Adadelta算法在Adagrad的基础上进行了改进，通过使用梯度的平方和的移动平均来代替梯度的平方和，避免了学习率过早衰减^[4]。RMSProp算法也采用了梯度平方和的移动平均来调整学习率，能够有效缓解梯度下降过程中的振荡问题。Adam算法融合了Adagrad与RMSProp优势，可自适应调整学习率，兼具快速收敛特性，有效应对稀疏梯度与噪声问题，在深度学习训练中应用广泛。

设置合适的训练参数对于模型的训练效果至关重要。学习率决定了模型参数更新的步长，过大的学习率可能导致模型在训练过程中无法收敛，出现振荡现象；过小的学习率则会使训练过程变得缓慢，消耗大量的时间和计算资源。通常，在训练初期可以选择较大的学习率，加快模型的收敛速度，在训练后期逐渐减小学习率，使模型能够更好地收敛到最优解。迭代次数和批量大小需要根据数据集规模和模型复杂度进行调整。如果数据集规模较大，模型复杂度较高，需要适当增加迭代次数和批量大小，以保证模型能够充分学习到数据中的特征。

3.3.2 模型优化

为防止模型过拟合，可采用正则化技术。L1、L2正则化通过在损失函数中加入参数绝对值或平方的惩罚项，约束参数规模，避免模型复杂化。L1正则化会使模型的参数变得稀疏，有助于特征选择；L2正则化则能够使模型的参数更加平滑，提高模型的稳定性。Dropout作为一种正则化技术，在深度学习模型训练过程中，会以一定概率随机丢弃部分神经元，切断神经元间特定共适应关系，防止模型过度依赖特定神经元，从而有效提升模型的泛化能力。

模型融合技术也可以用于提高道路裂缝检测模型的性能。将多个不同的模型进行组合，综合利用各个模型的优势。投票法是一种简单的模型融合方法，通过多个模型的预测结果进行投票，选择得票最多的类别作为最终的预测结果。加权平均法根据每个模型的性能表现，为每个模型分配不同的权重，将多个模型的预测结果进行加权平均，得到最终的预测结果。通过模型融合，可以提高模型的检测精度和稳定性。

结束语

本文对道路裂缝检测进行了系统研究，从传统检测方法的不足出发，引入深度学习理论，构建了基于深度学习的快速检测体系。然而，当前基于深度学习的道路裂缝检测仍存在对复杂环境适应性不足、模型可解释性欠缺等问题。未来需进一步探索新的检测策略，优化模型性能，提升检测技术的可靠性与实用性，推动道路裂缝检测技术迈向新高度，为道路养护与管理提供更坚实的技术保障。

参考文献

- [1]赵旭辉,谢梦洁,杨飏,等.低秩表示与深度学习结合的裂缝检测与样本生成方法[J].测绘学报,2023,52(11):1917-1928.
- [2]郎洪,温添,陆键,等.基于深度学习的三维路面裂缝类病害检测方法[J].东南大学学报(自然科学版),2021,51(1):53-60.
- [3]孔超.基于YOLO算法深度学习的路面病害检测方法研究[J].建筑机械化,2024,45(7):24-27.
- [4]陈江,原野,郎洪,等.基于多分支深度学习的沥青路面多病害检测方法[J].东南大学学报(自然科学版),2023,53(1):123-129.