

文章编号:1001-7372(2023)03-0001-11

基于多目视觉深度神经网络的路面 宏观纹理三维重建方法

马涛,童峥*,张一鸣,张伟光

(东南大学 交通学院,江苏 南京 211189)

摘要:为提升路面宏观纹理三维重建的精度与效率,实现路面抗滑与抗磨损性能的精准评估,提出了一种基于多目视觉深度神经网络的路面宏观纹理三维重建方法。首先,采用多目相机采集沥青路面多视角图像;其次,针对各个视角沥青路面图像,使用深度卷积神经网络提取与宏观纹理相关的高维特征向量,采用特征映射单元将特征向量映射为三维矩阵,使用多个反卷积层将三维矩阵转化为三维体素模型;最后,多目视觉组合模块采用贝叶斯规则融合不同视角的三维体素模型,该模型即为路面宏观纹理三维重建模型,可用于评估路面抗滑与抗磨损性能。使用多目相机采集16条沥青路面的多目视觉图像,并用三维扫描仪采集三维点云数据,构建数据集验证该方法的准确性与稳定性。试验结果表明:多目视觉深度神经网络能准确地重建路面宏观纹理,50 DPI(Dots Per Inch)与70 DPI分辨下三维重建结果与三维点云数据的体积交并比分别为0.858、0.769,且交并比不受路面材料与背景噪音影响,具有高准确性与高稳定性;该方法准确性与稳定性优于MVF-CNN、3D-FHNET、Stereo-vision等已有先进三维重建方法。路面宏观纹理三维重建结果可用于评估路面抗磨损性能与抗滑性能,实测误差分别为6.82%、7.28%,精度满足路面性能检测需求。此外,基于路面三维宏观纹理的平均构造深度与动态抗滑系数的测试速度为 $60\text{ km}\cdot\text{h}^{-1}$,具有高效性。路面宏观纹理三维模型未来可用于构建公路数字孪生体。

关键词:道路工程;路面宏观纹理;深度神经网络;多目视觉;目标三维重建

中图分类号:U416.2

文献标志码:A

A Three-dimensional Reconstruction method of Pavement Macro-texture Using a Multi-View Deep Neural Network

MA Tao, TONG Zheng*, ZHANG Yi-ming, ZHANG Wei-guang

(School of Transportation, Southeast University, Nanjing 211189, Jiang Su, China)

Abstract: To improve the accuracy and efficiency of the three-dimensional (3D) reconstruction of pavement macro-texture and to achieve high accurate evaluation of pavement anti-skid and anti-abrasive performances, a multi-view deep neural network has been proposed to perform pavement macro-texture reconstruction. First, a multi-view camera was used to collect pavement images with different perspectives. Then, a deep convolutional neural network was used to extract high-dimension features from each image, and the features were then mapped into a 3D matrix by a feature mapping unit. The 3D matrix was converted into a 3D voxel model by several

收稿日期:2022-12-20

基金项目:国家重点研发计划项目(2020YFB1600102);国家自然科学基金优秀青年科学基金项目(51922030)

作者简介:马涛(1981-),男,江苏徐州人,教授,博士研究生导师,工学博士,E-mail:matao@seu.edu.cn。

*通讯作者:童峥(1992-),男,浙江舟山人,副教授,工学博士,E-mail:tongzheng@seu.edu.cn。

deconvolution layers. Finally, the 3D voxel models in different views were combined by Bayesian rule, which was the 3D reconstruction result of pavement macro-texture, which was used to evaluate the anti-skid and anti-abrasive performances. The multi-view images and the 3D point cloud data were collected from 16 asphalt pavements by a multi-view camera and a 3D scanner, respectively. The two types of pavement data were combined to build a dataset to demonstrate the accuracy and stability of the proposed method. The test results showed that the multi-view deep neural network reconstructed the pavement macro-texture with the values of intersection over union (IoU) of 0.858 and 0.769 under 50 DPI and 70 DPI resolutions. The IoU results were not affected by the road surface material and background noise. The accuracy and stability of the proposed method were better than that of MVF-CNN, 3D-FHNET and stereo-vision methods. The 3D reconstruction results were used to evaluate mean texture depth (MTD) and dynamic friction coefficient (DFC) with the measured error is 6.82% and 7.28%, respectively, which meet the requirements of pavement performance detection. In addition, the test speed of MTD and DFC was $60 \text{ km} \cdot \text{h}^{-1}$, which had high efficiency. The 3D model of pavement macro-texture can be used to build the highway digital twin in the future.

Keywords: road engineering; pavement macro-texture; deep neural network; multi-view images; three-dimensional object reconstruction

Received 20 Dec. 2022

Funding: National Key Research and Development Program (2020YFB1600102); National Science Fund for Excellent Young Scholars (51922030)

* Corresponding author. *E-mail address:* tongzheng@seu.edu.cn.

<https://doi.org/10.19721/j.cnki.1001-7372.2023.03.000>

0 引言

路面宏观纹理是波长在 $0.5 \sim 50 \text{ mm}$ 的路表纹理结构,用于评估沥青路面服役性能,如抗滑性^[1]、排水性^[2]、抗磨耗性^[3]。此外,它对车辆运营^[4]、噪音吸收^[5]、燃油消耗^[6]也有重要影响。因此,三维重构路面宏观纹理并进行路面性能评估是路面检测的重要环节。

评估与三维重构路面宏观纹理的方法有 3 类:指标法、模型法、图像法。指标法是通过内在与外在指标表征纹理特性,例如摆式摩擦系数^[7],平均构造纹理深度(MTD)^[8]和平均轮廓深度(MPD)^[9]。实践中,常用铺沙法测量 MTD 与 MPD 或用动态摩擦测试仪测量摆式摩擦系数^[10-11]。此类方法存在 3 个问题:①适用性不广,如铺沙法不适用于多孔路面与新建路面^[12-14];②效率不高,铺沙法与摩擦测试仪需要封闭交通与人工操作,不易大范围测量;③代表性不强,仅测量路面局部区域,评价结果不确定性大,稳定性差。

模型法是采用三维激光成像技术采集路面宏观纹理点云,用于三维重建宏观纹理并进行服役性能

评估^[11]。三维激光基本不受光照^[12]、湿度^[13]、路表状态^[14]等因素影响,具有良好的稳定性。现阶段,三维面激光的扫描分辨率可到达 $1 \sim 3 \text{ mm}$,初步满足了路面宏观纹理数据采集的精度需求^[15]。然而,Ioannidou 等^[16]指出由于三维数据的复杂性,模型法存在延纵向测量精度低^[17]、与先进算法结合困难^[18]、三维重建易漏点^[19]等问题。

图像法是使用单目或多目路面数字图像三维重构路面宏观纹理^[20]。单目与多目路面图像分别指单视角与多视角采集的路面图像与路面图像组。用单目或双目相机对路面图像进行采集,设备成本较低,可通过简易组装获取不同视角下的路面纹理图像^[21]。图像中包含除纹理外的其他丰富信息,如图像中不同色彩区域、路表纹理的实时状态,可用于重构过程中的补充修正^[22]。同时,路面图像数据结构简单,易与先进的图像处理算法结合进行目标三维重构,因此,近年基于多目路面图像的路面宏观纹理三维重构方法在效率上优于模型法与指标法^[16],准确率得到了显著提高。然而,图像法易受路表材料与背景噪声影响,稳定性较差。

现有研究^[23-27]表明:基于深度学习的目标空间

形态三维重建方法可以压制目标表面材料与背景噪声的影响。现阶段,从数据解释的角度出发,基于深度学习的目标空间形态三维重建方法可分为3个方向:①采用深度学习模型直接分析三维点云或者体素数据来完成三维重建,此类方法准确性最高,但是需要三维数据作为支持^[28];②采用深度学习模型分析单视角图像与目标距离数据^[29],这种方法要求在获取图像数据的基础上还需要匹配获取图像各区域距离相机的距离数据;③采用深度学习模型提取多视角目标图像的空间形态特征^[30]。随着深度学习在道路工程中广泛应用,基于深度神经网络与多视角目标图像的路表三维重建方法具有3个潜在优势:鲁棒性、自动化、和易性。鲁棒性指深度神经网络能一定程度克服路表材料与背景噪声对三维重建准确性的影响;自动化指深度神经网络能自动提取多目路面图像中与宏观纹理相关的特征,进而完成三维重建,过程无需人工辅助,效率高;和易性是指多视角路面图像易与先进的深度学习算法结合,构建高精度路面宏观纹理。然而,现阶段针对路面宏观纹理三维重建的多目视觉深度神经网络模型与方法尚不完善,亟待进一步研究。

根据深度学习在目标三维重建领域的优势,本文提出一种基于多目视觉深度神经网络的路面宏观

纹理三维重建方法,实现基于三维宏观纹理的路面抗滑与抗磨损性能预测。该方法首先采用多目相机采集沥青路面多视角图像;其次,针对各个视角沥青路面图像,使用深度卷积神经网络提取与宏观纹理相关的高维特征向量,采用特征映射单元将特征向量映射为三维矩阵,使用多个反卷积层将三维矩阵转化为三维体素模型;最后,多目视觉组合模块采用贝叶斯规则融合不同视角的三维体素模型,该模型即为路面宏观纹理三维重建模型,可用于评估路面抗滑与抗磨损性能。本文主要创新点包括:

(1)基于多目视觉深度神经网络的路面宏观纹理三维重建方法,可使用任意数量不同视角的路面图像进行宏观纹理三维重建,精度高且不受路面材料与背景噪声影响。

(2)路面宏观纹理三维重建结果可用于评估路面性能,如抗磨损性能与抗滑性能,有望代替三维扫描仪进行高速、高精路面性能检测。

1 路面宏观纹理三维重建方法

1.1 概述

基于多目视觉深度神经网络的路面宏观纹理三维重建方法流程如图1所示,包括以下3个步骤:




图1 基于多目视觉深度学习的路面宏观纹理三维重建方法流程

Fig. 1 Process of Three-dimensional Reconstruction on Pavement Macro-texture Using Multi-view Deep learning

步骤1:若干个“编码器-解码器”式单目视觉深度神经网络分别对不同视角路面图像进行特征提取,每个视角的路面图像被转化为一个高维度特征向量,特征向量是路面宏观纹理的高维空间特征。每个深度神经网络由1个编码器与1个解码器组成,编码器由若干个卷积层与池化层组成,解码器由若干个反卷积层组成。“编码器-解码器”式深度神经网络将在本文第2.2节具体介绍。

步骤2:特征映射单元将不同视角图像的特征向量转换为三维矩阵,并使用多个反卷积层进行反卷积操作,获取多个基于单目视觉的路面三维宏观纹理结果。特征映射单元将在本文第2.2节具体介绍。基于单目视觉的路面三维宏观纹理结果以体素网格形式展现,其体素点为二分布概率,分别表示体素点区域内存在纹理与不存在纹理的概率。各视角路面三维宏观纹理结果体素点数量相同。

步骤 3:多目视觉组合模块采用贝叶斯规则将多个基于单目视觉的路面三维宏观纹理结果融合为一个路面三维宏观纹理结果,即基于多视角路面图像的三维宏观纹理重建模型,该模型可用于评估路面服役性能。多目视觉组合模块将在本文第 1.3 节具体介绍。

1.2 单目视觉深度神经网络

单目视觉深度神经网络模型由 1 个“编码器-解码器”式深度神经网络、1 个特征映射单元、1 个 Softmax 层组成,用于提取单视角路面图像中与宏观纹理相关的特征,并将其映射至三维体素网格,如图 2 所示。




图 2 单目视觉深度神经网络

Fig. 2 Single-view Deep Neural Network

编码器由若干组 Block 组成,每个 Block 包括多个卷积层与池化层,用于提取与宏观纹理相关的高维特征向量。卷积层与池化层介绍见文献[31]。特征映射单元将编码器输出的特征向量转换为三维矩阵。设 $\mathbf{F} = \{F_1, F_2, \dots, F_d\}$ 是编码器输出的特征向量, d 是 $\mathbf{F}$ 的维度。特征映射单元采用式(1)将 $\mathbf{F}$ 转化为三维矩阵

$$V_{ijk} = g(\omega_{ijk}^f \mathbf{F} + b_{ijk}^f) \quad (1)$$

式中: V_{ijk} 是三维矩阵 $\mathbf{V}$ 坐标 (i, j, k) 的值; $g(\cdot)$ 为 TanH 激活函数; ω_{ijk}^f 与 b_{ijk}^f 分别为特征映射单元的权重和偏值。

解码器由若干个反卷积层组成,用于将三维矩阵转化为基于单视角路面图像的三维体素模型。解码器的输入是三维矩阵 $\mathbf{V}$,反卷积层进行式(2)操作

$$\mathbf{c} = \sum_{ijk} f\left(b_{ijk}^{fc} + \sum_i V_{ijk} * \omega_{ijk}^{fc}\right) \quad (2)$$

式中: $\mathbf{c}$ 为三维体素模型; ω_{ijk}^{fc} 与 b_{ijk}^{fc} 分别为反卷积层的权重和偏值; $*$ 为反卷积运算。

最后,Softmax 层对三维体素模型 $\mathbf{c}$ 的各个体素点进行概率归一化,获得基于单目视觉的路面三维宏观纹理结果。路面三维宏观纹理结果以体素网格形式展现,其体素点用二分布概率 $[p_{h,i,j,k}^1, p_{h,i,j,k}^2]$ 表征,分别表示第 h 个路面视角的体素点 (i, j, k) 区域内存在纹理与不存在纹理的概率。

1.3 多目视觉组合模块

单一视角路面图像仅能提供在该视角中的宏观纹理信息。然而,由于纹理自遮挡作用,部分纹理特征无法准确展示,导致基于单一视角路面图像的三维重建结果精度不高、稳定性差。因此,本文使用多目视觉组合模块融合不同单目视觉路面宏观三维体素模型,建立多目视觉路面三维宏观纹理模型。

多目视觉组合模块融合的输入是若干个不同视角的三维体素模型 $\mathbf{c}_h$,其中 $h=1, 2, \dots, H$ 。模型 $\mathbf{c}_h$ 的体素点 (i, j, k) 用二分布概率 $[p_{h,i,j,k}^1, p_{h,i,j,k}^2]$ 表示。对于 H 个不同视角三维体素模型,其体素点 (i, j, k) 的贝叶斯概率融合方式为

$$\left. \begin{aligned} u_{i,j,k,h}^1 &= u_{i,j,k,(h-1)}^1 \cdot p_{i,j,k,h}^1 & h=2, 3, \dots, H \\ u_{i,j,k,h}^2 &= u_{i,j,k,(h-1)}^2 \cdot p_{i,j,k,h}^2 & h=2, 3, \dots, H \\ u_{i,j,k,1} &= [p_{1,i,j,k}^1, p_{1,i,j,k}^2] \end{aligned} \right\} \quad (3)$$

多目视觉组合模块通过式(3)进行迭代运算,实现 H 个三维体素模型融合,输出 1 个多视角三维体素模型 $\mathbf{u}$, $u_{i,j,k,h}$ 为 $\mathbf{u}$ 中体素点 (i, j, k) 区域内存在纹理与不存在纹理的概率。依据概率分布确定体素点 (i, j, k) 是否存在纹理点

$$\mathbf{u} = \arg \max \mathbf{u}_{i,j,k,h} = \arg \max_{l=0,1} u_{i,j,k,h}^l \quad (4)$$

式(4)计算结果即为多目视觉路面三维宏观纹理重建结果。

1.4 端对端训练方法

采用随机梯度下降算法训练多目视觉深度神经网络。设 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m\}$ 为一组多视角路面图像,宏观纹理三维重建结果损失函数为

$$\mathcal{L}(\mathbf{X}) = \sum_{j=1}^o y_* \log(u_{i,j,k,h}^0) + (1 - y_*) \log(u_{i,j,k,h}^1) \quad (5)$$

$$y_* = \begin{cases} 1 & u_{i,j,k,h}^0 = u_{i,j,k,h}^1 \\ 0 & u_{i,j,k,h}^0 \neq u_{i,j,k,h}^1 \end{cases}$$

式中: $u_{i,j,k,h}^0$ 为体素点 (i, j, k) 是否存在纹理点的真实情况,通过三维扫描仪的点云数据确定。

与传统深度神经网络相比,多目视觉深度神经网络存在多目视觉组合模块,损失函数偏导在多目视觉组合模块的反向传递为

$$\frac{\partial \mathcal{L}(\mathbf{X})}{\partial u_{i,j,k,h}^l} = \frac{\partial \mathcal{L}(\mathbf{X})}{\partial u_{i,j,k,h}^l} \frac{\partial u_{i,j,k,h}^l}{\partial p_{i,j,k,h}^l} = - \left(\frac{y_*}{u_{i,j,k,h}^0} + \frac{1-y_*}{u_{i,j,k,h}^1} \right) \cdot \frac{u_{i,j,k,h}^l}{u_{i,j,k,(h-1)}^l} \quad l=0, 1 \quad (6)$$

多目视觉深度神经网络其他结构的损失函数偏导传递与参数更新可由 Tensorflow 自动求导模块完成。

2 现场试验

2.1 数据库与实施细节

为训练与测试多目视觉深度神经网络,本文构建了一个由多视角沥青路面图像及其相应的三维点云数据构成的数据库。数据库图像与点云数据来自16个不同的沥青路面,包括苯乙烯-丁二烯-苯乙烯(SBS)改性沥青混凝土(AC-16)、沥青混凝土(AC-13和AC-16)和沥青玛蹄脂(SMA-13)。为生成该数据库,使用手持式三维扫描仪采集路表宏观纹理三维点云数据,并用多目摄像机采集该区域的路表图像,如图3所示。车载多目摄像机可在 $60 \text{ km} \cdot \text{h}^{-1}$ 行驶速度下采集路面多目图像;为实现单车道覆盖,车载多目摄像机每秒采集 $n \times 6$ 张路面图像, n 为视角数。采集过程选择了不同手持式三维扫描仪扫描分辨率,分别为每英寸50、70、90、110 DPI (Dots Per Inch)。数据库共包括“多视角沥青路面图像-点云数据”样本1500组。数据库按4:1的比例分为训练集与测试集。在训练集与测试集中,4种道路材料的样本比例接近1:1:1:1。为确定多目视觉深度神经网络结构的最优超参数,如卷积层层数、反卷积层内核数、步长等,采用训练集的5-fold交叉验证。多目视觉深度神经网络的“编码器-解码器”式深度神经网络与特征映射单元结构参数如表1所示,浮点操作数(Floating Point Operations, FLOPs)为413 GFLOPs。




图3 三维宏观纹理与多目图像数据采集

Fig. 3 Three-dimensional Macro-texture and Multi-view Image Data Collection

在训练过程中采用了先进参数优化方法来提高模型性能,如表2所示。表2中基础模型为多目视觉深度神经网络模型,迭代批量为2,采用对数递减学习率,基础学习率为0.01,冲量与权值衰减分别为0.9与0.005;模型1~3为在基础模型上采用表2技术进行训练的模型。上述训练与测试在配备

表1 多目视觉深度神经网络结构参数

Table 1 Structure Parameters of Multi-view

Deep Neural Network

模块	层位	参数
输入	#1	$256 \times 256 \times 3 \times H$ 多目图像组
编码器	#2	7×7 Max. conv. 96 ReLu with Stride with Stride 2
	#3	3×3 Stochastic Pooling Stride 2
	#4	5×5 Max. conv. 256 ReLu with Stride 2
	#5	3×3 Stochastic Pooling Stride 2
	#6	3×3 Max. conv. 384 ReLu with Stride 1
	#7	3×3 Max. conv. 384 ReLu with Stride 1
	#8	3×3 Max. conv. 256 ReLu with Stride 1
特征映射单元	#9	$16 \times 16 \times 3$ fully Connected Layer 256 TanH
解码器	#10	$3 \times 3 \times 3$ Deconv. 256 ReLu with Stride 1
	#11	$3 \times 3 \times 3$ Deconv. 384 ReLu with Stride 1
	#12	$5 \times 5 \times 3$ Deconv. 256 ReLu with Stride 4
	#13	$7 \times 7 \times 3$ Deconv. 96 ReLu with Stride 4
Softmax	#14	Softmax
多目视觉组合模块	#15	贝叶斯融合

表2 多目视觉深度神经网络训练技术

Table 2 Training Technologies on

Multi-view Deep Neural Network

模型	层序单位方差初始(LSUV) ^[35]	最大化(Maxout)反卷积 ^[36]	数据增强 ^[37]
基础模型	-	-	-
模型1	√	-	-
模型2	√	√	-
模型3	√	√	√

Intel(R)Core(TM)i7-8750H CPU、32.00 GB RAM和NVIDIA GeForce GTX 3090 GPU的工作站上完成,该GPU单精度浮点计算能力为 $3.57 \times 10^4 \text{ GFLOPs} \cdot \text{s}^{-1}$ 。因此,当视角数 $n \leq 4$ 时,工作站支持基于多目摄像机与多目视觉深度神经网络的实时路面宏观纹理三维重建。为验证多目视觉深度神经网络的优越性,将该方法与3个现有宏观纹理三维重建方法(MVF-CNN^[32]、3D-FHNET^[33]、Stereo Vision^[34])对比。

2.2 评价指标

三维重建准确性采用交并比(Intersection Over Union, IoU)^[38]评估,如图4所示。交并比 $\text{IoU} \in [0, 1]$,表征多目视觉深度神经网络输出的三维重建模型与手持式三维扫描仪获取的三维扫描模型的重叠度。交并比越大说明三维重建模型与三维扫描模型重叠度与相似度越高。现有研究表明 $\text{IoU} > 0.65$




图4 三维重建任务的交并比定义

Fig. 4 Intersection over Union on a Three-dimensional Reconstruction Task

时可认为2个模型相似度较高^[35]。因此,当三维重建结果交并比大于0.65时,可认为基于多目视觉深度神经网络的三维重建模型与手持式三维扫描仪获取的三维扫描模型空间形态接近。

多目视觉深度神经网络输出的三维重建模型可用于评估路面性能,如路面平均构造纹理深度MTD^[39]和动态摩擦系数DFC^[40]。采用平均误差评价基于三维宏观纹理模型的评估结果与实测结果的差异,如式(7)所示

$$E_A = \sum_{i=1}^I \frac{p_i - t_i}{t_i} \quad (7)$$

式中: p_i 与 t_i 分别为基于三维宏观纹理模型的评估结果与实测结果; I 为测试样本数量。

3 结果与讨论

3.1 宏观纹理三维重建

采用数据库的训练集训练表2中4个多目视觉深度神经网络,训练过程的测试损失函数值如图5所示。模型3在1100次迭代后达到最小损失值,这表明采用LSUV、Maxout反卷积、数据增强可以显著提高模型的训练效率与精度。模型1~3在第1~800次迭代过程中的收敛速度比基础模型快,且测试损失波动小,这表明采用LSUV和Maxout反卷积可以促进模型的收敛,避免训练的局部波动。此外,模型3的损失值在1000次迭代后无显著增加,而基础模型、模型1、模型2均存在1000次迭代后损失函数值上升的问题,这表明数据扩容可一定程度避免模型过拟合问题。

表3为模型3的路面宏观纹理三维重建准确性评估结果。三维重建交并比随视角数增加而增长,这主要是由于多视角路面图像提供了更加完善的路面宏观纹理信息,多目视觉深度神经网络依据完善的纹理信息可以进行准确的三维重建。图6展示了纹理自遮挡作用的影响,每个视角的路面图像仅反




图5 多目视觉深度神经网络损失函数

Fig. 5 Loss Function of Multi-View Deep Neural Networks

表3 路面宏观纹理三维重建测试交并比

Table 3 Intersection over Union of the Testing Set on Pavement Macro-Texture Three-Dimensional Reconstruction

视角数		1	2	3	4
扫描分辨率 (DPI)	40	0.829	0.845	0.852	0.860
	50	0.825	0.842	0.851	0.858
	60	0.813	0.832	0.846	0.853
	70	0.736	0.759	0.765	0.769
	90	0.705	0.726	0.735	0.742
	110	0.673	0.682	0.685	0.688

映了部分纹理信息,如遮挡示例中被蓝色区域遮盖了黄色区域,这使得多目视觉深度神经网络仅能准确重建部分纹理区域,如图6的单目视觉重建结果中黄色区域是遮挡缺失区域。然而,当视角数量大于3时三维重建交并比不再显著增加,这是因为当视角数量大于3时多视角路面图像已经完整地展现了路面宏观纹理信息,此时影响三维重建准确性的主要因素是深度神经网络的特征提取能力。因此,为平衡计算效率与准确率,在路面宏观纹理三维重建中推荐视角数为3和4,避免冗余计算。




图6 单视角路面宏观纹理三维重建结果示例

Fig. 6 Three-dimensional Reconstruction Results of Single-view Pavement Macro-texture Three-dimensional Reconstruction

三维重建交并比随着扫描分辨率的增加而降低(表3),这是因为手持式三维扫描仪扫描分辨率增加时,

扫描点云数据增加,导致体素模型体素点数量增加;但多目视觉深度神经的特征提取能力有限,主要取决于编码器和解码器的神经网络结构,无法满足过高分辨率需求。未来可通过以下2个途径提升三维重建分辨率:①采用更先进的神经网络特征提取结构获取更加完善的纹理信息,如Transformer等;②采用更先进的多目图像采集设备获取更加准确的纹理信息,如事件型相机。因此,多目视觉深度神经网络能满足分辨率不大于70 DPI的三维重建需求,满足路面宏观纹理定义与测量需求。此外,40~60 DPI时,多目视觉深度神经的交并比基本一致且高于70~110 DPI时的交并比。DPI越高,三维重建分辨率越好,故多目视觉深度神经的最佳 DPI 在50~60 之间。

多目视觉深度神经网络的三维重建结果也能够用于检测和测量路面病害。如图7所示,路面裂缝与坑槽区域可以在三维重建模型中准确表征。与单目视觉二维图像相比,三维重建模型可以表征裂缝与坑槽区域深度信息,这为路面病害三维测量提供了一种新方法。此外,图7绿色区域为渲染过程中路面宏观纹理三维点云的少量漏点区域,主要是路面阴影或者其他环境因素导致的,未来可以考虑采用插值方法补齐。漏点区域占三维点云模型比例较小,采用插值方法补齐后基本不影响建模准确率。




图7 基于多目视觉深度神经网络的路面宏观纹理三维重建结果示例

Fig. 7 Examples of Pavement Macro-texture Three-dimensional Reconstruction Based on the Multi-view Deep Neural Network

图8为不同路面材料的路面宏观纹理三维重建交并比测试结果。多目视觉深度神经网络的交并比基本不受材料特性影响,而单目视觉深度神经网络的交并比一定程度受材料特性影响。这表明基于多目视觉深度神经网络的三维重建方法具有较高的稳定性。因此,该方法克服了传统路面宏观纹理测量方法适用性不强的问题,如铺砂法不适用于SMA路面与新建路面^[12]。此外,图8(d)表明四视角宏观




图8 不同路面材料的路面宏观纹理三维重建测试交并比结果

Fig. 8 Intersection Over Union Results of Pavement Macro-texture with Different Materials

三维纹理重建受材料特性的影响相较于三视角变大,这是因为随着视角数的增加,特征提取的复杂度不断增加,深度神经网络的特征提取能力有限,导致部分与材料相关的特征提取存在偏差,进而导致宏观纹理三维重建结果受材料特性的影响较大,但是四视角深度神经网络的算法稳定性仍满足三维重建需求。

表 4 为不同路面宏观纹理三维重建方法对比结果。多目视觉深度神经网络交并比高于 MVF-CNN 与 3D-FHNET, 这表明多视角融合建模方法有助于提高深度神经网络三维重建目标的准确性。与 3 种深度学习方法相比, 基于 Stereo-Vision 立体视觉技术的三维重建方法整体准确性与稳定性不佳。此外, 四视角 70 DPI 的路面宏观纹理三维重建结果与手持式三维扫描仪获取的三维扫描模型具有较高的交并比, 即两者空间形态相似。综上, 基于多目视觉深度神经网络的路面宏观纹理三维重建方法具有技术先进性, 有望替代手持式三维扫描仪进行路面纹理检测。

表 4 四视角 70 DPI 的路面宏观纹理三维重建方法对比结果

Table 4 Result Comparison of Different Pavement Macrotexture Three-dimensional Reconstruction Methods on Four Views and 70 Dots Per Inch

模型	模型 3	MVF-CNN ^[24-25]	3D-FHNET ^[25]	Stereo-Vision ^[26]
平均交并比	0.769	0.765	0.755	0.550
AC-13	0.795	0.763	0.723	0.580
AC-16	0.775	0.750	0.739	0.487
SBS 改性 AC-16	0.768	0.773	0.777	0.519
SMA-13	0.738	0.775	0.782	0.612

3.2 路面性能评估

路面平均构造深度 MTD 表征了路面抗磨损性能。本文使用路面三维宏观纹理模型与式(8)计算 δ_{MTDp}

$$\delta_{\text{MTDp}} = \frac{\max(\Gamma) + \max(\Gamma - \max(\Gamma))}{z} - \frac{\sum_{\gamma_j \in \Gamma} \gamma_j}{|\Gamma|} \quad (8)$$

式中: $\Gamma = \{\gamma_1, \gamma_2, \dots, \gamma_o\}$, 为多目视觉深度神经网络输出的路面三维宏观纹理模型 Z 坐标集合。

采用四视角与 70 DPI 的多目视觉深度神经网络重建数据库测试集的路面三维宏观纹理, 将模型评估 δ_{MTDp} 结果与铺沙法 δ_{MTDT} 结果的差值作为平均构造深度评估误差, 如式(7)所示。测试集中三维重建模型评估结果与铺沙法结果的平均误差为 6.82%, 表明多目视觉深度神经网络输出的路面三维宏观纹理模型可以准确表征路面宏观纹理深度 MTD, 未来可用于分析路面抗磨损性能。因此, 路面三维宏观纹理模型有望取代铺沙法评估路面平均构造深度。此外, 平均误差结果表明, 分辨率为 70 DPI 的三维宏观纹理满足路面状况评估的要求。




图 9 测量 MTD(x 坐标) vs. 预测 MTD(y 坐标)

Fig. 9 Measured MTD (x-axis) vs. Predicted MTD (y-axis)

图 9 是不同路面材料工况下模型评估 δ_{MTDp} 结果与铺沙法 δ_{MTDT} 结果。测试样本在 $y=x$ 线附近分布且 $R^2 > 0.85$, 表明路面三维宏观纹理模型评价平均构造深度 MTD 基本不受 AC-13、AC-16、SBS 改性 AC-16 和 SMA-13 等材料影响, 克服了路面材料与背景噪音对路面抗滑性能评估的影响。因此, 基于多目视觉深度神经网络的路面三维宏观纹理重建方法适用性广于传统铺沙法, 例如该方法可用于 SMA-13 路面平均构造深度的评估。此外, 基于路

面三维宏观纹理的MTD测试速度为 $60 \text{ km} \cdot \text{h}^{-1}$, 解决了平均构造深度低速测量的问题。

同时,路面三维宏观纹理模型还可以作为评估路面抗滑性能DFC的重要依据。基于宏观纹理三维重建结果,采用文献[31]的式(1)~(5)及表2计算 δ_{DFCp} 。模型评估 δ_{DFCp} 结果与动态摩擦测试仪测得 δ_{DFCT} 结果的差值作为抗滑性能评估误差,如式(7)所示。测试样本在 $y=x$ 线附近分布且 $R^2 > 0.85$,相关性较高。测试集中三维重建模型评估结果与动态摩擦测试仪结果的平均误差为7.28%,表明多目视觉深度神经网络输出的路面三维宏观纹理模型可以作为表征路面抗滑性能评估的重要依据。此外,采用三维宏观纹理模型作为DFC评估的重要依据可以减少路面材料与背景噪音的影响,如图10所示。当视角数 $n \leq 4$ 时,本研究支持实时基于多目摄像机与多目视觉深度神经网络的路面宏观纹理三维重建,故 $60 \text{ km} \cdot \text{h}^{-1}$ 行驶速度下基于路面宏观纹理的DFC测量具有可行性,有望解决动态摩擦测试仪低速测量的问题。

4 结 语

本文提出了一种基于多目视觉深度神经网络的路面宏观纹理三维重建方法,并运用于16条高速公路抗滑与抗磨损性能评估,主要结论如下:

(1)多目视觉深度神经网络可以重建路面宏观纹理,50、70、90、110分辨率时纹理重建交并比分别为0.858、0.769、0.742、0.688,精度满足路面宏观纹理检测需求;该方法准确性优于MVF-CNN、3D-FHNET、Stereo-Vision等已有先进方法。

(2)基于多目视觉深度神经网络的路面宏观纹理三维重建方法精度基本不受路面材料与背景噪音影响,在AC-13、AC-16、SBS改性AC-16、SMA-13等常见沥青路面上三维重建交并比不低于0.725,稳定性满足路面宏观纹理检测需求。

(3)路面宏观纹理三维重建结果可用于评估路面抗磨损性能MTD与抗滑性能DFC,实测误差分别为6.82%、7.28%,精度满足路面性能检测需求;此外,基于路面三维宏观纹理的MTD与DFC测试速度可达到 $60 \text{ km} \cdot \text{h}^{-1}$,显著提升检测效率。研究表明,路面宏观纹理三维重建结果可应用于MTD与DFC计算。路面宏观纹理、抗磨损性能、抗滑性能的相关性仍待进一步研究。

(4)未来研究需要考虑将路面宏观纹理三维模型用于构建公路数字孪生体,提升孪生体的精度。




图10 测量DFC(x坐标)vs预测DFC(y坐标)

Fig.10 Measured DFC (x-axis) vs. Predicted DFC (y-axis)
路面宏观纹理三维模型可用于构建公路数字孪生底座的路表部分,结合力学仿真模拟来评估与分析路面全寿命周期抗磨损性能与抗滑性能,实现精细化公路数字孪生体的构建。

参考文献:

References:

- [1] 黄晓明,郑彬双. 沥青路面抗滑性能研究现状与展望[J]. 中国公路学报, 2019, 32(4): 32-49.
- HUANG Xiao-ming, ZHENG Bin-shuang. Research status

- and progress for skid resistance performance of asphalt pavements [J]. *China Journal of Highway and Transport*, 2019, 32 (4): 32-49.
- [2] SOHANEY R C, RAMUSSEN R O. Pavement Texture Evaluation and Relationships to Rolling Resistance at Mn-ROAD [M]. Ireland: Minnesota Department of Transportation, 2013.
- [3] SERNAS O, ZOFKA A, VAITKUS A, et al. The effect of exposed aggregate concrete gradation on the texture characteristics and durability [J]. *Construction and Building Materials*, 2020, 261: 119921.
- [4] 王大为, 吕浩天, 汤伏蛟, 等. 基于三维探地雷达的沥青路面层间接触状态智能诊断技术[J]. *北京工业大学学报*, 2022, 48 (6): 572-579.
- WANG Da-wei, LV Hao-tian, TANG Fu-jiao, et al. Intelligent Detection Technology of Contact State Between Asphalt Pavement Layers Based on 3D Ground Penetrating. *Journal of Beijing University of Technology*, 2022, 48 (6): 572-579.
- [5] STAIANO M A. Tire-pavement noise and pavement texture [J]. *Journal of Transportation Engineering Part B Pavements*, 2018, 144 (3): 15-28.
- [6] ŚWIECZKO-ŻUREK B, RONOWSKI G, EJSMONT J. Tyre rolling resistance and its influence on fuel consumption [J]. *Combustion Engines*, 2017, 168: 62-67.
- [7] LI L A, MAN B, MHN B, et al. Temporal and spatial evolution of soil surface roughness on stony plots [J]. *Soil and Tillage Research*, 2020, 200: 104526.
- [8] CUI X, ZHOU X, LOU J, et al. Measurement method of asphalt pavement mean texture depth based on multi-line laser and binocular vision [J]. *The international journal of pavement engineering*, 2017, 18 (5/6): 459-471.
- [9] PRATICO F G, AVIANA R. A study on the relationship between mean texture depth and mean profile depth of asphalt pavements [J]. *Construction and Building Materials*, 2015, 101 (1): 72-79.
- [10] 黄宝涛, 田伟平, 李家春, 等. 沥青路面抗滑性能定量评价的分形方法[J]. *中国公路学报*, 2008, 21 (4): 12-17.
- HUANG Bao-tao, TIAN Wei-ping, LI Jia-chun, et al. Fractal method based on quantitative evaluation of asphalt pavement anti-slide performance [J]. *China Journal of Highway and Transport*, 2008, 21 (4): 12-17.
- [11] 周兴林, 蒋难得, 肖旺新, 等. 基于激光视觉的沥青路面构造深度测量方法[J]. *中国公路学报*, 2014, 27 (3): 12-16.
- ZHOU Xing-lin, JIANG Nan-de, XIAO Wang-xin, et al. Measurement method for mean texture depth of asphalt pavement based on laser vision [J]. *China Journal of Highway and Transport*, 2014, 27 (3): 12-16.
- [12] 周兴林, 祝媛媛, 冉茂平, 等. 基于分段变维的沥青路表纹理磨光行为分析[J]. *中国公路学报*, 2019, 32 (4): 188-195.
- ZHOU Xing-lin, ZHU Yuan-yuan, RAN Mao-ping, et al. Polishing behavior analysis of asphalt pavement surface texture based on piecewise variable dimension fractal [J]. *China Journal of Highway and Transport*, 2019, 32 (4): 188-195.
- [13] ZHANG A, WANG K, LI B, et al. Automated pixel-level pavement crack detection on 3D asphalt surfaces using a deep-learning network [J]. *Computer-aided Civil and Infrastructure Engineering*, 2017, 32 (10): 805-819.
- [14] SOLLAZZO G, WANG K C P, BOSURGI G, et al. Hybrid procedure for automated detection of cracking with 3D pavement data [J]. *Journal of Computing in Civil Engineering*, 2016, 30 (6): 04016032.
- [15] 阳恩慧, 陈强, 李杰, 等. 沥青路面表面纹理重构与构造深度预测模型[J]. *中国公路学报*, 2023, 36 (2): 1-12.
- YANG En-hui, CHEN Qiang, LI Jie, et al. Surface Texture Reconstruction and Mean Texture Depth Prediction Model of Asphalt Pavement [J]. *China Journal of Highway and Transport*, 2023, 36 (2): 1-12.
- [16] IOANNIDOU A, CHATZILARI E, NIKOLOPOULOS S, et al. Deep Learning Advances in Computer Vision with 3D Data: A Survey [J]. *ACM Computing Surveys*, 2017, 50 (2): 1-38.
- [17] XIN Q, QIAN Z, MIAO Y, et al. Three-dimensional characterisation of asphalt pavement macrotexture using laser scanner and micro element [J]. *Road Materials and Pavement Design*, 2017, 18 (3): 190-199.
- [18] FENG Z, ISSAOUI E I, LEHTOMAKI M, et al. Pavement distress detection using terrestrial laser scanning point clouds: Accuracy evaluation and algorithm comparison [J]. *ISPRS Open Journal of Photogrammetry and Remote Sensing*, 2022, 3: 100010.
- [19] LI Z, CHENG C, KWAN M, et al. Identifying asphalt pavement distress using UAV LiDAR point cloud data and random forest classification [J]. *ISPRS International Journal of Geo-Information*, 2019, 8 (1): 39.
- [20] MATHAYAN S, KUMAR A, KAMAL K, et al. Fast segmentation of industrial quality pavement images using Laws texture energy measures and k-means clustering [J]. *Journal of Electronic Imaging*, 2016, 25 (5): 053010.
- [21] 江荣, 朱攀, 周兴林, 等. 基于双目视觉算法的路面三维纹理信息获取[J]. *激光与光电子学进展*, 2022, 59 (14): 284-292.
- JIANG Rong, ZHU Pan, ZHOU Xing-lin, et al. Three-dimensional Pavement Texture Information Acquisition Based on Binocular Vision Algorithm [J]. *Laser & Optoelectronics Progress*, 2022, 59 (14): 284-292.
- [22] HOANG N D. Automatic Detection of Asphalt Pavement Raveling Using Image Texture Based Feature Extraction and Stochastic Gradient Descent Logistic Regression [J]. *Automation in Construction*, 2019, 105: 102843.
- [23] LECUN Y, BENGIO Y, HINTON G. Deep Learning [J]. *Nature*, 2015, 521 (7553): 436-444.
- [24] ZHU Z, WANG X, BAI S, et al. Deep learning representation using autoencoder for 3D shape retrieval [J]. *Neurocomputing*, 2016, 204: 41-50.

- [25] LENG B, SHUANG G, ZHANG X, et al. 3D object retrieval with stacked local convolutional autoencoder [J]. *Signal Processing*, 2015, 112 (7): 119-128.
- [26] LENG B, LIU Y, YU K, et al. 3D object understanding with 3D convolutional neural networks [J]. *Information Sciences*, 2016: 188-201.
- [27] SU H, MAJI S, KALOGERAKIS E, et al. Multi-view convolutional neural networks for 3D shape recognition [C] // BAJCSY R, HAGER G, MA Y, et al. *Proceedings of the 2015 IEEE International Conference on Computer Vision. Araucano Park; IEEE Xplore*, 2015: 945-953.
- [28] BU S, LIU Z, HAN J, et al. Learning high-level feature by deep belief networks for 3-D model retrieval and recognition [J]. *IEEE Transactions on Multimedia*, 2014, 16 (8): 2154-2167.
- [29] SCHWARZ M, SCHULZ H, BEHNKE S. RGB-D object recognition and pose estimation based on pretrained convolutional neural network features [C]// HAGER G, MOREL Y, COBANO J, et al. *Proceedings of the 2015 IEEE international conference on robotics and automation. Washington; IEEE Xplore*, 2015: 1329-1335.
- [30] XIE Z, XU K, SHAN W, et al. Projective feature learning for 3D shapes with multi-view depth images [J]. *Computer Graphics Forum*, 2015, 34 (7): 1-11.
- [31] 沙爱民,童 峥,高 杰.基于卷积神经网络的路表病害识别与测量[J]. *中国公路学报*, 2018, 31(1): 1-10.
SHA Ai-min, TONG Zheng, GAO Jie. Recognition and measurement of pavement disasters based on convolutional neural networks [J]. *China Journal of Highway and Transport*, 2018, 31(1): 1-10.
- [32] LIU C, LI Juan, GAO Jie, et al. Three-dimensional texture measurement using deep learning and multi-view pavement images [J]. *Measurement*, 2021, 172: 108828.
- [33] 刘存强,童 峥,袁东东,等.一种基于多视角深度学习的路面宏观纹理重建方法:CN112489202A[P]. 2021-03-12.
LIU Cun-qiang, TONG Zheng, YUAN Dong-dong, et al. A method for pavement macro-texture reconstruction based on multi-view deep learning; CN112489202A [P]. 2021-03-12.
- [34] LU Q, LU Y, XIAO M, et al. 3D-FHNet: Three-dimensional fusion hierarchical reconstruction method for any number of views [J]. *IEEE Access*, 2019, 7: 172902-172912.
- [35] CHEN J, HUANG X, ZENG B, et al. Real-time identification system of asphalt pavement texture based on the close-range photogrammetry [J]. *Construction and Building Materials*, 2019, 226: 910-919.
- [36] SONG L, WANG X. Faster region convolutional neural network for automated pavement distress detection [J]. *Road Materials and Pavement Design*, 2021, 22 (1): 23-41.
- [37] MISHKIN D, MATAS J. All you need is a good init [C] // LAROCHELLE H. *Proceedings of the 4th International Conference on Learning Representations. Puerto Rico; ICLR*, 2016: 56-73.
- [38] REZATOFIGHI H, TSOI N, GWAK J, et al. Generalized intersection over union: A metric and a loss for bounding box regression [C] // DAVIS L, TORR P, ZHU S, et al. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, Long Beach; CVPR*, 2019: 658-666.
- [39] TONG Z, GAO J, YUAN D. Advances of deep learning applications in ground-penetrating radar: A survey [J]. *Construction and Building Materials*, 2020, 258: 120371.
- [40] HU L, YUN D, LIU Z, et al. Effect of three-dimensional macrotexture characteristics on dynamic frictional coefficient of asphalt pavement surface [J]. *Construction & Building Materials*, 2016, 126 (15): 720-729.