

基于 Boosting-Monodepth 的管道病害深度估计与 三维重建

方宏远¹, 姜 雪¹, 王念念¹, 胡群芳^{2,3}, 雷建伟¹, 王 飞^{2,3}, 赵继成⁴, 代 毅⁵

(1. 郑州大学 黄河实验室(郑州大学), 河南 郑州 450001; 2. 上海防灾救灾研究所, 上海 200092;

3. 城市安全风险监测预警应急管理部重点实验室, 上海 200092;

4. 北京北排建设有限公司, 北京 100071; 5. 深圳市博铭维技术股份有限公司, 广东 深圳 518000)

摘要: 城市地下管道是城市的血脉经络, 但随着排水管道的大量投入运营和使用年限增加, 引发了一系列的管道病害安全隐患, 如管道整体结构变形、内表面破裂和管中异物插入等问题, 传统的病害图像视频采集、检测和后期病害分类甄选都是从二维视角出发, 欠缺对三维空间信息(深度)的考虑。针对上述 3 种病害从生成深度图、由二维深度图重建三维管道病害这两方面进行研究, 提出了一种基于 boosting-monodepth 的双重深度估计方法以提升深度图效果, 最终生成画面连续一致、轮廓清晰的深度图。性能评估方面采用 Abs-Rel、RMSE、SqRel、ORD 和 D³R 等通用指标, 与传统算法对比, 结果显示 boosting-monodepth 的 RMSE 值降低了 30%, 精确度指标 $\delta < 1.25$ 时, 模型深度信息预测精确度提高了 18%, 此后以得到的深度图为基础重建管道病害三维点云, 并在 CloudCompare 软件上三维可视化, 最后采用随机采样一致算法测算病害深度并和实测数据对比证明其有效性和准确性。

关键词: 管道病害; 深度估计; 三维重建

中图分类号: U178

文献标志码: A

Pipeline Damage Depth Estimation and 3D Reconstruction Based on Boosting- Monodepth Algorithm

FANG Hongyuan¹, JIANG Xue¹, WANG Niannian¹,
HU Qunfang^{2,3}, LEI Jianwei¹, WANG Fei^{2,3},
ZHAO Jicheng⁴, DAI Yi⁵

(1. Yellow River Laboratory, Zhengzhou University, Zhengzhou 450001, China; 2. Shanghai Institute of Disaster Prevention and Relief, Shanghai 200092, China; 3. Key Laboratory of Urban Safety Risk Monitoring and Early Warning of the Ministry of Emergency Management, Shanghai 200092, China; 4. Beijing

Beipai Construction Co., Ltd., Beijing 100071, China;
5. Shenzhen Bomingwei Technology Co., Ltd., Shenzhen 518000, China)

Abstract: Urban underground pipelines are the blood channels of the city. However, with the large number of drainage pipelines put into operation and their service life increasing, a series of hidden dangers of pipeline diseases have arisen, such as the overall structural deformation of the pipeline, internal surface cracking, and the insertion of foreign matters in the pipeline. Traditional disease image video capture, detection, and later disease classification and selection are conducted from a two-dimensional (2D) perspective, lacking consideration of three-dimensional spatial information (depth). Aimed at the above three diseases, an experiment is conducted from generating depth maps and reconstructing three-dimensional (3D) pipeline diseases from 2D depth maps. A dual depth estimation method based on boosting-monodepth is proposed to improve the effect of depth maps, and finally a depth map with continuous and consistent images and clear outlines is generated. In terms of performance evaluation, Abs-Rel, RMSE, SqRel, ORD, D³R and other general indexes are compared with those of the traditional algorithm, and the results show that the boosting-monodepth is reduced by 30% at RMSE and increased by 18% at a threshold of $\delta < 1.25$. Afterwards, the 3D point cloud of pipeline disease is reconstructed based on the depth map obtained, and 3D visualization is performed on CloudCompare. Finally, the disease depth is calculated using the random sampling consistent algorithm and compared with the real

收稿日期: 2022-11-24

基金项目: 国家自然科学基金(51978630); 国家重点研发计划(2022YFC3801000)

第一作者: 方宏远(1982—), 男, 教授, 博士生导师, 工学博士, 主要研究方向为地下排水管网非开挖修复。

E-mail: 18337192244@163.com

通信作者: 王念念(1989—), 女, 教授, 硕士生导师, 工学博士, 主要研究方向为排水管道智能检测。

E-mail: wnnian@zzu.edu.cn



论文
拓展
介绍

measured data to prove its effectiveness and accuracy.

Key words: pipeline disease; depth estimation; three-dimensional reconstruction

城市地下管道作为城市建设中举足轻重的一部分,对城市发展起着至关重要的作用,主要承担公路纵横向排水、市政工程中供热、处理污水净水等任务。目前大部分地下管道设施的建设已经初具规模或已成型,城市发展中对管道的侧重点也逐渐从施工铺设转向养护保修。随着管道投入使用的年限逐步增长,初期施工的质量不一和地面沉降等问题引发了一系列管道病害^[1-3],如管道整体结构的变形和破裂、管道内部的腐蚀与障碍物和异物插入等,这都会导致地下管道无法顺利有效地发挥功能,从而影响城市运行和交通管控^[4-7]。因此,定期对管道进行病害检测和修复,保证安全性、提升管道的运行质量十分必要。当前管道病害的检测防治主要依赖人工检修和机器探测,人工检测病害的效率不一且需要从业人员有较高的水平,尤其是管道内部光线阴暗、狭窄潮湿,技术人员更加难以进入,完成整个检测过程往往费时费力^[8-10]。相比之下使用影像设备采集管道图片或视频,再通过机器视觉技术处理数据会更加准确高效^[11],这也是计算机图像分析研究领域的热点^[12-15]。在实际应用中,无论是技术人员后期观看视频或图片来分辨病害种类还是管道机器人实时提取图片特征,都欠缺对物体三维立体信息的考虑,基于深度学习的单目图像深度估计可以从二维图像估计出三维空间一部分信息(即深度),对某些管道病害如破裂、障碍物等进行三维还原或重建,具有广泛的应用前景。

1 相关工作

目前已有的深度估计方法主要分为传统方法^[16]和深度学习方法^[17]2类,传统深度估计中基于线索的方法依赖于光影、纹理、遮挡或相机和场景的运动变化(structure from motion, SFM)^[18-19],基于参数的方法如:刘芳等^[20]加入语义信息的马尔可夫随机场(MRF),程婷婷等^[21]提出的条件随机场(CRF),研究者们通过学习输入图像与输出深度之间的关系,分区域分层建立深度图的模型,在计算中引入纹理、模糊、消失点等特征,取得了突破性进步。

丰富的数据集也促进了深度学习的发展,

MAKE 3D(2008年)、NYU Depth(2012年)、KITTI(2013年)的出现也促使人们由传统方法转向关注全监督、无监督和弱监督的深度学习方法。然而在管道方面,采集到的图像重复率比较高,实际可用的数据量并不庞大,国内相关研究还不充分。对于管道病害的三维重建方法主要有激光雷达扫描、机器视觉和传感器法,吴恩启^[22]通过光影变化设计了一种检测微细管道内部的方法,对物体截面重建出立体轮廓。叶晶等^[23]考虑傅里叶变换设计了一种基于三维成像重构小型管道内表面的技术,盛沙等^[24]提出了一项基于超声波的管道内部病害检测方法也可达到同样的效果且更为高效,Chae等^[25]提出一种新型数字管道扫描技术,采用移动检测设备进入管道内部,对采集到的图像数据进行失真调整并生成报告。与此类似,甘小明等^[26]通过结合环形激光器和机器视觉设计出一款小型管道机器人,该设备针对管道内部细微缺陷进行检测,再引入相机运动估计可完成三维重建。Moraleda等^[27]致力于排水管道内部故障检测,并提出一种测算三维空间中裂缝长度和直径的方法,Zhou等^[28]利用相机和场景变化(SFM)原理对目标进行连续跟踪来估计单目相机的位姿,最终可以重建出管道的立体结构。

2 理论方法

2.1 网络结构

2.1.1 生成器

深度估计网络采用基于通用U-Net的Pixel2Pixel结构,相比于传统的自编码网络Auto-Encoder,U-Net增加了跳跃连接,如图1所示。在处理图像任务时,跳跃连接可以将低频信息包括图像的边缘、轮廓、形状、颜色和纹理直接传输到高层特征图上,很好地保留了一些低层信息。编码器采用尺寸为 256×256 的图像作为Pixel2Pixel的输入,网格维度为(256, 256, 1)、初始通道为64,图中下采样中的箭头表示 4×4 的卷积核+ReLU+BN的卷积操作。编码过程每次下采样通道数扩大2倍,一共进行3次下采样操作直至网格维度为(1, 1, 512)。上采样过程使用反卷积将网格维度(1, 1, 512)重新扩张到(256, 256, 1)再输出,编解码之间对应的特征图按通道相连接,用以共享一些具体的语义信息,提高网络的训练速度。

2.1.2 判别器

传统的GAN(generative adversarial nets)方法通

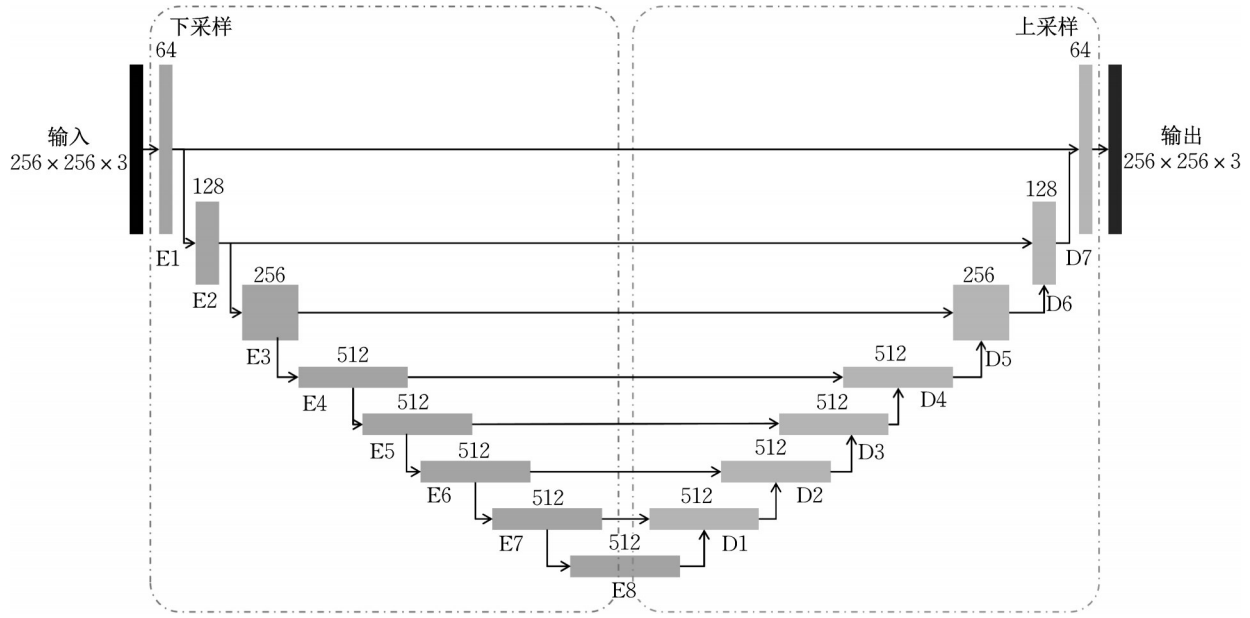


图1 Pixel2Pixel生成器网络结构

Fig. 1 Network structure of Pixel2Pixel generator

常使用整个图片作为网络输入,这样会使得生成的图片难以兼顾一些细节信息,整体较为模糊。可以注意到 L_1 、 L_2 此类的损失函数虽然会导致部分图片模糊,但是具有很好的提取和处理低频信息的能力,因此Pixel2Pixel架构使用 L_1 loss重建来处理低频部分,高频信息部分使用一种“图像块”的patchGAN进行学习。patchGAN判别器基于马尔科夫随机场设计,即把图像分成尺寸为 $n \times n$ 的图像块,将不同大小的patch依次输入判别器,逐一验证生成的图像块是否为真,而不需要输入整张图片再去判别全局是否为真。因为patchGAN是马尔可夫性的,不同patch大小的像素之间相互独立,将 N 取不同值的判断结果取平均值再输出到判别器,即为最终结果。已有的实验结果表明, N 越大,模型处理图像细节纹理的效果就越好,输出图的整体效果也越好。当 N 取70时,网络训练的参数量适中,patchGAN判别器的处理速度最快,它只需要注重图像局部信息,运算速度有所提升。

2.1.3 损失函数

普通GAN的目标函数 $L_{GAN}(G, D)$ 如式(1)所示,其仅表示为真实图像 y 经过生成器(Generator)和判别器(Discriminator)的处理结果(结果分别为 G, D)。而此处Pixel2Pixel架构的输入图像改变了,其条件GAN(cGan, ConditionGAN)的损失函数 $L_{cGAN}(G, D)$ 也需要调整,如式(2)所示引入了条件变量 x ,式中 $D(x, y)$ 表示判别器通过观察原始输入图像轮廓 x 和真实图像 y 的判断结果, $D(x, G(x, z))$ 表

示图像轮廓 x 和生成器生成的 $G(x)$ 的判别结果。

$$L_{GAN}(G, D) = E_y[\lg D(y)] + E_{x,z}[\lg(1 - D(G(x, z)))] \quad (1)$$

$$L_{cGAN}(G, D) = E_{x,y}[\lg D(x, y)] + E_{x,z}[\lg(1 - D(x, G(x, z)))] \quad (2)$$

除了改善传统GAN函数,还添加了 L_1 正则化即 $L_{L1}(G)$ 对网络进行优化,如式(3), L_1 损失函数计算的是单一的绝对差,生成的图缺乏多样性更趋于真值ground truth,但是鲁棒性强。相比于 L_2 损失函数, L_1 可以更有效地减少模糊,有利于生成清晰的图像,提高输出图的质量。

$$L_{L1}(G) = E_{x,y,z}[\|y - G(x, z)\|_1] \quad (3)$$

最终的目标函数 G^* 如式(4),其中 λ 为超参量。式(4)表示在 L_1 正则约束下生成器和判别器的maximize & minimize 博弈,生成器不断尝试最小化目标函数以欺骗判别器,而判别器又为了输出最大化目标函数不断迭代,相互牵制抗衡以此输出最优结果。

$$G^* = \arg \min_G \max_D L_{cGAN}(G, D) + \lambda L_{L1}(G) \quad (4)$$

2.2 Merge Net

2.2.1 双重估计

用来训练和测试的图片往往以固定分辨率输入网络,较小的分辨率可以保留图像的整体结构,场景一致性较好,但容易错失局部细节信息,相反较大的分辨率可以捕捉到局部细节轮廓,但场景的一致性又随着分辨率的增大而持续降低,同时还会产生一

部分低频伪影。深度估计的模型和感受野都是固定的,如图2所示,改变输入图像的分辨率会不同程度地影响感受野(方框标注)所能“看到”的场景和线索。为了获得具备连续一致的场景和兼顾高频细节的深度估计图,boosting-monodepth设计了一个融合网络,将高分辨率深度估计图中的高频信息整合到低分辨率深度估计图中,形成一个两方面都能取得较好效果的基本估计(base estimation)。此方法适用需要百万像素级别深度图的情景,且无需太多的计算量和运行成本。

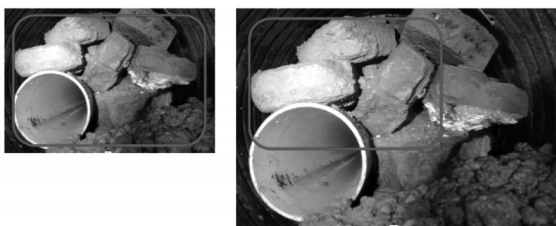


图2 感受野与不同分辨率图像

Fig.2 Receptive fields and images with different resolutions

图像边缘是影响深度估计网络性能的重要因素,它与上下文线索存在一定联系,将原始RGB图像进行色彩梯度阈值处理得到粗略边缘图,再作为上下文线索估计整个图片的深度可取得比较不错的效果。如图2,感受野大小不变时,越大分辨率的图细粒度信息越容易捕捉,但也有一定像素缺少上下文线索,场景也开始变得不连续。当感受野都能覆盖到上下文线索时,此时的分辨率定义为 R_0 ,也是最适应图像场景内容的;当图中有20%的内容与上下文线索的距离超过感受野大小的一半时,此时的分辨率定义为 R_{20} ,它也能同时保持场景的一致性和提取到丰富细节的分辨率。

提高分辨率的同时可搜索的深度线索也在变少,网络可以获得的像素信息也趋于匮乏,这样会导致网络估计的准确性降低,boosting-monodepth深度估计网络基于图像内容自适应输入的分辨率,低分辨率输入取感受野的大小(小于感受野并不会优化全景结构,反而会导致没有充分利用网络容量而削弱性能),高分辨输入取 R_{20} 。再通过融合网络将2个深度估计结果进行合并,把 R_{20} 的细粒度细节赋在低分辨率估计上,可以取得物体轮廓清晰且伪影较少的深度图。

2.2.2 补丁估计

当图像中某些场景比感受野的接受域更深更远

时,深度估计网络难以获得这些像素和区域周围的信息,一味地提高输入分辨率反而会破坏输出深度图的细节,合适的输入分辨率随图像中内容的不同而有所差异。图像中某些内容丰富的地方也具备更高的上下文线索密度,因此再次利用融合网络对这些“块”进行单独估计有利于提高最终深度图的准确度,这种分块估计称为“patch estimation”。

patch的选择主要分为2个步骤。首先按感受野的大小平铺整个图像,平铺过程保证每个相邻的patch之间有1/3的重叠,如图3所示。为了充分利用网络容量,让更多的patch搜索到足够的上下文信息,当patch框选到的上下文线索密度小于整张图的上下文线索密度时,此类patch可用性低,直接丢弃;当patch框选到的内容具有更丰富高频的边缘信息时,保留此类patch并将它扩大到和原始图像尺寸相同(如图4),这样可以有效地提取到最具价值的像素。

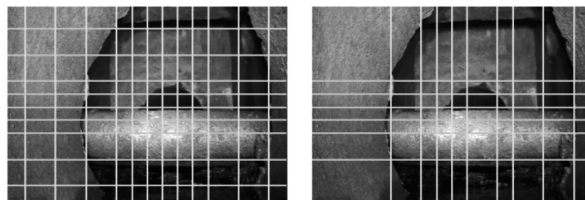


图3 补丁选择第1步

Fig.3 Step 1: Patch selection



图4 补丁扩张第2步

Fig.4 Step 2: Patch expansion

一张图中会有多个patch,对这些patch再依次进行双重估计以取得边缘清晰的局部深度图,然后将这些结果通过融合网络合并到之前的深度估计结果上,即先前由 R_0 和 R_{20} 生成的base estimation。至此已经获得了细节较为丰富的深度图(Mid-DepEst),为了发挥出网络的最大效能,最后能呈现出完整连续且像素过渡柔和的图像,再将Mid-DepEst和base estimation通过融合网络,整合出最终的深度估计图,全部过程一共进行了3次合并,整

个技术路线流程如图5。

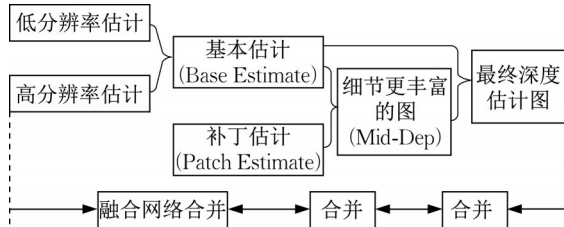


图5 技术路线

Fig. 5 Technical route

3 管道病害二维深度图生成和三维重建

3.1 数据集

以图形、纹理和颜色等信息为源数据的计算机视觉依赖大量的图片来训练网络,基于单目图像的深度估计分为无监督、有监督和自监督(弱监督)这几类。其中有监督学习的训练集是大量带有深度真值的RGB-D图像集,此类数据集获取难度较大且可采集到的数据量有限,网络计算难度也较高,相比之下自监督更灵活且使用的图像无需带有深度标签。深度估计方面目前应用最广泛的公共数据集有3种情形,室内场景如NYU Depth V2数据集;室外场景包括KITTI、NUScenes、MAKE 3D、CityScapes;合成数据集如Scene Flow。本文使用KITTI数据集来训练神经网络,该数据集由德国卡尔斯鲁厄理工学院和丰田美国技术研究院共同开发,主要用于双目立体匹配、单目深度估计、光流、3D目标检测和跟踪等。采集数据的设备为一辆搭载彩色相机、灰度相机、激光扫描仪和GPS导航系统等各类传感器的汽车,训练集包含39 810张图片,验证集包括4 424张图片。此外,排水管道内部的病害图片难以人工获取,为了得到比较好的识别和深度估计效果,选取变形、破裂、异物插入这3类管道病害进行研究,并在这几类病害中再择优选取尺寸和分辨率都较大的图片来测试。

3.2 参数细节和深度图生成

训练的自监督单目深度估计模型基于Pytorch框架,选用Linux系统、NVIDIA RTX 3080Ti GPU计算模块,并用公共数据集KITTI进行预训练,训练批大小为12,迭代(epochs)为20,此外初始学习率过小会导致网络收敛缓慢,为了避免进入局部最优区域,初始学习率设置为 10^{-4} 。在图像处理方面,输入网络前对图像采取随机旋转、翻转镜像、裁剪和缩放

进行数据增强,部分由视频(采集帧数为30fps)分割出来的图片每隔50张抽取一个样本作为训练数据。

对于boosting-monodepth,输入图像尺寸最大采用 $1\,920 \times 1\,080$,而对于较小尺寸的图,Pixel2Pixel的10层U-net网络会将小尺寸图像上采样至 $1\,024 \times 1\,024$ 的分辨率。monodepth2的初始默认分辨率为 640×192 ,对于管道图片将其修改为 640×480 (需为32的倍数)。选取3个具有代表性的管道病害进行研究,分别是变形、破裂和异物插入,这几类病害结构形变较为明显,更容易被观察,其中变形图片532张,破裂589张,异物插入456张,通过在ImageNet上的预训练模型初始化Resnet101权重参数。

3.3 定性分析

在本次实验中,从管道3类病害图片测试集中挑选了几张具有代表性的深度估计图与Zhou等^[28]的方法进行定性对比分析,并用boosting-monodepth作为最优深度估计效果展示。3类管道病害用不同方法的深度估计结果如图6—8所示,为了更直观地观察到各类病害,在图中用框标注出深度估计效果显著的地方。由图6可见,深度估计效果较为突出,排水管道变形明显处可以有效识别。由图7可见,排水管道破裂较大处可以估计,部分较深的裂缝可以清楚地估计出轮廓。

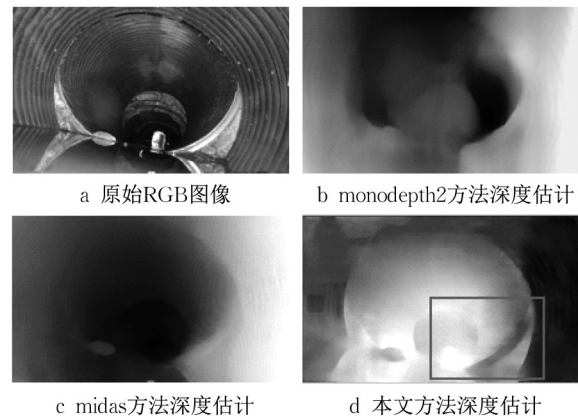


图6 变形

Fig. 6 Deformation

除了识别出常规的支管插入,有些近景物体也能估计。从图6—8可以看出,相比于其他方案,本文的boosting-monodepth深度估计方法在管道病害图片测试集上显示出的效果更好,在管道发生明显塑性形变和裂缝处可以清晰地估计出轮廓形状。异物插入病害中除了远距离大体积的支管,画面中近景小物体也能感知估计,可见boosting-monodepth深

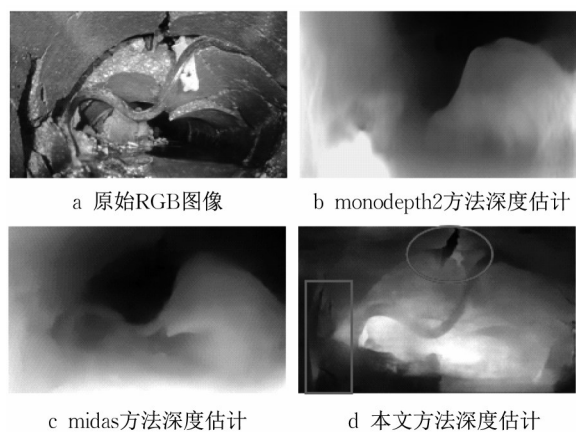


图7 破裂
Fig. 7 Rupture

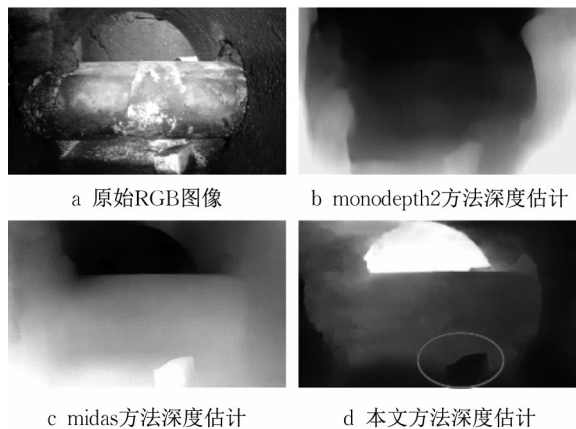


图8 异物插入
Fig. 8 Foreign body penetration

度估计方法在场景中无论近远景物体都能估计出深度连续一致、像素过渡柔和的图像,并且因为此方法的融合网络对多尺度多分辨率的图像进行采样处理时场景中的低频伪影被有效降低,一些小物体的边界轮廓表现也不错。

同时,boosting-monodepth深度估计方法也存在一些不足,有些清晰度不高的原始图像所估计出来的深度图效果不算太理想,非常细小的裂痕深度图细节还原度不高,管道内部表面腐蚀的此类病害因没有突出的明暗或距离变化而难以估计,但总体效果相比其他深度估计方案具有更好的效果。

3.4 定量分析

对于深度估计任务,利用2种数据源(公共数据集KITTI和自采管道病害数据)来对不同的深度估计方法(monodepth2、midas、本文所使用的boosting-monodepth)进行训练测试,并对比分析在相同的评价指标下,本文方法和目前已有的深度估计网络之间的差异和优劣。表1给出了不同深度估计方法的定量分析结果,其中 monodepth2 和 boosting-monodepth 均是自监督学习,采用广泛使用的 Abs-Rel(绝对相对误差)、RMSE(均方根误差)、SqRel(平方相对误差)、D³R和ORD(内置函数)评价指标来评估深度估计网络在预测KITTI和管道病害图片方面的性能,以上5个指标数值越低越好,同时也纳入了深度信息预测值与真实值对比的精确度指标 δ ,在阈值为1.25范围内, δ 数值越高越好,表示具有更高的准确性。

从表1可以看出,在相同的定量评估指标下,与近段时间现有的经典方法相比,本文所采用的双重估计方法取得了更好的效果,尤其是RMSE值明显降低,boosting-monodepth通过融合网络对低分辨率的深度图上采样得到较大的尺寸,再和高分辨率的深度估计图中的高频细节信息进行3次合并,在阈值为1.25时,本文提出的方法深度信息预测精确度指标 δ 比另外2种方法提高了约18%,进一步验证了boosting-monodepth深度估计方法的有效性。

表1 不同深度估计方法评估结果

Tab. 1 Evaluation results of different depth estimation methods

估计方法	有无监督	数据源	估计次数	绝对相对误差	ORD	D ³ R	RMSE	平方相对误差	$\delta < 1.25$
monodepth2	自监督	KITTI	单次	0.115			4.701	0.882	0.879
midas	无监督	KITTI	单次	0.155	0.347	0.158	0.197		0.713
boosting—monodepth(本文)	自监督	KITTI	双重		0.388	0.242	0.156		0.789
monodepth2	自监督	管道病害	单次	0.208			6.856	1.768	0.678
midas	无监督	管道病害	单次	<u>0.117</u>	0.554	0.467	0.479		0.693
boosting—monodepth(本文)	自监督	管道病害	双重		<u>0.394</u>	<u>0.322</u>	<u>0.159</u>		<u>0.873</u>

注:下划线表示管道病害数据源方面的每项指标的最优结果。

3.5 基于二维转三维的管道病害重建

3.5.1 坐标系转换

从深度信息转化到三维点云是以不同的坐标系之间相互转换完成的,由二维深度图重建出三维模

型是一个信息扩增过程,这个过程涉及4个坐标系,分别是世界坐标系、相机坐标系、图像坐标系和像素坐标系,它们之间一一对应,可以通过各种矩阵变换或者量化模型完成,其中三维重建主要是从图像坐

标系到世界坐标系的变换。位于三维世界中的任意一点 P ,它在三维空间中的坐标是 $P(x,y,z)$,这个世界坐标系也是我们日常生活的客观世界,以此为基准可以描述相机的摆放位置以及物体的具体位点,即 $P_w(x_w,y_w,z_w)$,以相机坐标系的坐标原点为相机的光心,在此坐标系下 P 点坐标为 $P_c(x_c,y_c,z_c)$,由世界坐标转换到相机坐标的变换为式(5):

$$P_c = [R | T] P_w \quad (5)$$

其为刚体变换,各坐标系对应点的具体变换为式(6):

$$\begin{pmatrix} x_c \\ y_c \\ z_c \end{pmatrix} = R \begin{pmatrix} x_w \\ y_w \\ z_w \end{pmatrix} + T \quad (6)$$

$$R = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix}, T = [t_x \quad t_y \quad t_z] \quad (7)$$

式中: R 为旋转矩阵; T 为平移矩阵。它们是相机的外参,和相机内参共同组成了坐标系变换的约束条件。式(6)反映了三维立体世界中的物体投影到二维平面的过程,由此反推可以得到二维的像素点一一映射到三维空间的转换关系,即图像坐标系转换为世界坐标系,如式(8),其中 D 为深度, (x,y,z) 为点云坐标, x',y' 为图像坐标,有

$$\begin{pmatrix} x \\ y \\ z \end{pmatrix} = D \begin{bmatrix} \frac{1}{f_x} & 0 & 0 \\ 0 & \frac{1}{f_y} & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} \quad (8)$$

3.5.2 三维点云重建和可视化

通过深度估计方法已获得高质量的深度图,从中选取3种具有代表性的管道病害来重建三维结构,Matlab软件可以较好地访问提取图像的深度信息,通过式(8)的转换关系使用Matlab软件作为二维深度图像转化三维点云的平台。

为了更直观地观察三维重建效果和测算深度,管道病害立体图用CloudCompare进行展示,图9—11即为效果图,为了更容易看出病害破损程度,三维效果图选取最优管道截面视角并用框标识。

本文研究的管道均为排水管道,管道半径均为5.0~6.5m,在具体深度值方面,本文采用随机采样一致算法模拟管道表面,选定管道病害损伤点到管道面的距离然后测算其深度,同时在CloudCompare软件中测距并与现场实测数据做对比。从表2可以看出,对大型管道测量的数据的单位有效位数在毫

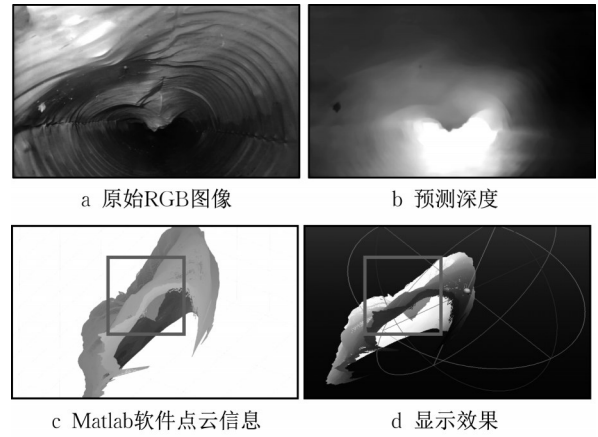


图9 变形(三维)

Fig. 9 Deformation(3D)

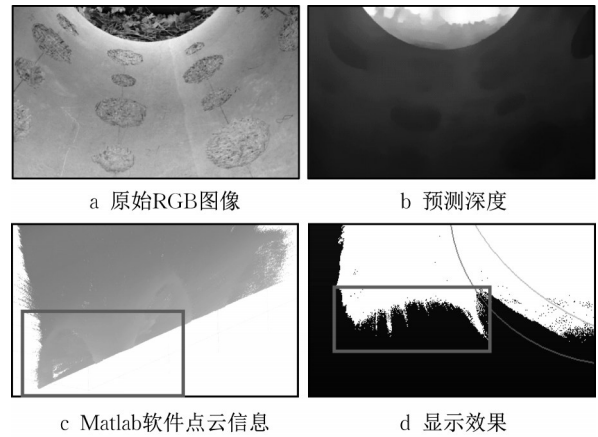


图10 破裂(三维)

Fig. 10 Rupture (3D)

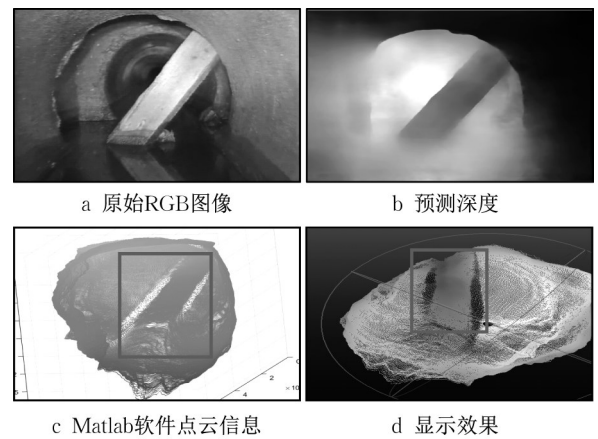


图11 异物插入(三维)

Fig. 11 Foreign body penetration (3D)

米级不容易展现,随物体体积变大或管径长度的增加误差也在一定程度上变大,但在实际研究范围内仍具有一定的准确性和参考价值。

表 2 深度对比

Tab. 2 Contrast of depth

病害种类	测算深度/mm	真实深度/mm
破裂	25.99	27.81
变形	2 377.43	2 531.00
异物插入	9 076.49	9 255.00

4 结论

城市地下管道是城市能量传输的重要载体,关乎整个城市的正常运作,管道的大量投入使用也导致了其内部结构的改变和表面的腐蚀破损,而以往对于管道病害的拍摄采集和后期人为分辨病害种类都是从二维角度出发,缺乏对三维空间信息(深度)的考量,针对此问题选取 3 类病害,即破裂、变形和异物插入,进行二维转三维的研究,具体工作如下:

提出了一种基于 boosting-monodepth 的提升图像深度估计效果的方法,相比于传统的自监督深度学习,该深度估计方法采用双重估计策略,通过融合合并网络将不同分辨率大小的管道病害图像多次整合,生成了画面场景一致、像素过渡柔和的深度图,尤其在管道发生明显结构变形和较大较深裂缝处,可以得到轮廓边界清晰的高质量深度图。同时本文在不同的测试集上验证了 boosting-monodepth 的有效性,并与经典的 monodepth2 和 midas 深度估计效果进行定量比较,结果表明相比于另 2 种方法,boosting-monodepth 方法的均方根误差 RMSE 降低了约 30%, $\delta < 1.25$ 时,模型精确度指标 δ 提高了约 18%。得到了较好的深度图之后通过具有较好的深度信息访问功能的 Matlab 软件进行三维点云重建,以小孔成像理论为基础完成二维图像坐标系到三维点云世界坐标系的转换,同时在 CloudCompare 软件上可视化显示,同时运用随机采样一致算法测算深度并和真实现场实测数据进行比较,可知其具有不错的准确率和实际参考价值。

作者贡献声明:

方宏远:论文思路指导、论文撰写、实验规划。

姜 雪:论文撰写、数据分析、实验结果可视化。

王念念:论文审阅及修订、论文思路指导。

胡群芳:总体技术方案及实验方法设计与数据分析。

雷建伟:现场管道实验部署与数据采集。

王 飞:论文指导与数据分析。

赵继成:实验数据提供及结果验证。

代 毅:提供实验设备、数据采集。

参考文献:

- [1] BAAH K, DUBEY B, HARVEY R, *et al.* A risk-based approach to sanitary sewer pipe asset management[J]. *Science of the Total Environment*, 2015, 505: 1011.
- [2] LI Linyi, YANG Junsheng, GAO Chao, *et al.* Simulation tests on structural deformation and seepage field of high-speed railway tunnels under drainage clogging[J]. *Chinese Journal of Geotechnical Engineering*, 2021, 43(4): 715.
- [3] CAO Jingguo. Engineering demonstration of cured in place pipe repair material for urban drainage canals [J]. *Water & Wastewater Engineering*, 2020, 46(1): 115.
- [4] 车毅峰. 城市排洪管道对城市应急系统的影响[J]. *四川水泥*, 2017 (12): 288.
CHE Yifeng. Influence of urban flood discharge pipeline on urban emergency system [J]. *Sichuan Cement*, 2017 (12): 288.
- [5] ANBARI M J, TABESH M, ROOZBAHANI A. Risk assessment model to prioritize sewer pipes inspection in wastewater collection networks [J]. *Journal of Environmental Management*, 2017, 190: 91.
- [6] 金惠玲,孙振平,杨海静,等. 排水管道非开挖修复技术的应用现状及展望[J]. *混凝土世界*, 2022(9): 82.
JIN Huiling, SUN Zhenping, YANG Haijing, *et al.* Application status and prospect of trenchless repair technology for drainage pipes [J]. *Concrete World*, 2022(9): 82.
- [7] QIN Chaokui, LI Jun, YanMingjun, *et al.* Analysis of failure probability of urban underground gas pipelines under corrosion effect[J]. *Natural Gas Industry* 2015, 35(5): 85.
- [8] YANG Lijian, SHEN Bo, GAO Songwei. Method of pipeline geographic measurement applied to pipeline inspection Gauge [J]. *Instrument Technique and Sensor*, 2013(11): 84.
- [9] HUANG J, LEUNG K E, VERCELES R, *et al.* Automated detection of sewer pipe structural defects using machine learning [C]//WEFTEC 2017. [s. l.]: Water Environment Federation, 2017: 4605-4615.
- [10] 俞树荣,何娜,顾生斌. 基于成本的长输管道腐蚀缺陷检测及维修规划[J]. *煤气与热力*, 2010, 30(5): 21.
YU Shurong, HE Na, GU Shengbin. Cost based inspection and maintenance planning for corrosion defects of long-distance pipeline [J]. *Gas & Heat*, 2010, 30(5): 21.
- [11] 徐小云,颜国正,鄢波. 一种新型管道检测机器人系统[J]. *上海交通大学学报*, 2004, 38(8): 1324.
XU Xiaoyun, YAN Guozheng, YAN Bo. A new style pipeline inspection robot system [J]. *Journal of Shanghai Jiaotong University*, 2004, 38(8): 1324.
- [12] YE Wenwei, ZHOU Tianfu, HUANG Jinxuan, *et al.* Design of dual-vision double telecentric optical system based on machine vision[J]. *Laser & Optoelectronics Progress*, 2020, 57(1): 012202.
- [13] LIU Yan, WANG Gang, WANG Guodong, *et al.* For machine vision image acquisition and image processing of weld

- [J]. Computer Engineering and Applications, 2014, 2014 (5):135.
- [14] WANG Weidong, ZHANG Kanghui, LI Ziqi, *et al.* Machine vision detection of foreign objects in coal using deep learning [J]. Journal of Mining Science and Technology, 2021, 6 (1): 115.
- [15] 李康. 基于机器视觉的管道内表面缺陷检测方法研究[D]. 包头:内蒙古科技大学, 2019.
- LI Kang. Research on detection method of inner surface defects of pipeline based on machine vision [D]. Baotou: Inner Mongolia University of Science & Technology, 2019.
- [16] 李耀宇, 王宏民, 张一帆, 等. 基于结构化深度学习的单目图像深度估计[J]. 机器人, 2017, 39(6): 812.
- LI Yaoyu, WANG Hongmin, ZHANG Yifan, *et al.* Structured deep learning based depth estimation from a monocular image[J]. Robot, 2017, 39(6): 812.
- [17] 曾一鸣, 胡瑜, 韩银和, 等. 利用稀疏点云偏序关系的半监督单目图像深度估计[J]. 计算机辅助设计与图形学学报, 2019, 31(11): 2038.
- ZENG Yiming, HU Yu, HAN Yinhe, *et al.* Exploiting partial order relationship of sparse point cloud for semi-supervised monocular image depth estimation [J]. Journal of Computer-Aided Design & Computer Graphics, 2019, 31(11): 2038.
- [18] SNAVELY N. Scene reconstruction and visualization from internet photo collections: A survey[J]. IPSJ Transactions on Computer Vision and Applications, 2011, 3: 44.
- [19] YUAN Hongxing, WU Shaoqun, YU Huiqing, *et al.* A 2D-to-3D method via semantic depth transfer[J]. Journal of Computer-Aided Design & Computer Graphics, 2014, 26(1): 72.
- [20] 刘芳, 刘东升, 桂志国. 基于马尔科夫随机场的图像锐化方法[J]. 计算机工程, 2011, 37(1): 224.
- LIU Fang, LIU Dongsheng, GUI Zhiguo. Image sharpening method based on markov random field [J]. Computer Engineering, 2011, 37(1): 224.
- [21] 程婷婷, 郭立君, 黄元捷. 基于鲁棒高阶条件随机场的视频自动分割[J]. 计算机工程, 2015, 41(7): 261.
- CHENG Tingting, GUO Lijun, HUANG Yuanjie. Automatic video segmentation based on robust higher order conditional random field[J]. Computer Engineering, 2015, 41(7): 261.
- [22] 吴恩启. 微细管道内表面检测及三维重建关键技术研究[D]. 杭州: 浙江大学, 2005.
- WU Enqi. Research on key technologies of inner surface detection and 3D reconstruction of micro-pipe [D]. Hangzhou: Zhejiang University, 2005.
- [23] 叶晶, 周常河, 贾伟. 小型管道内壁三维成像测量系统[J]. 中国激光, 2010, 37(8): 2025.
- YE Jing, ZHOU Changhe, JIA Wei. Small pipe inner wall three-dimensional imaging measurement system [J]. Chinese Journal of Lasers, 2010, 37(8): 2025.
- [24] 盛沙, 戴波, 谢祖荣. 管道超声内检测三维成像技术研究[J]. 北京石油化工学院学报, 2012, 20(1): 1.
- SHENG Sha, DAI Bo, XIE Zurong. Research on 3D imaging technology for ultrasonic internal inspection of pipeline [J]. Journal of Beijing Institute of Petrochemical Technology, 2012, 20(1): 1.
- [25] CHAE M J, KIM W, HWANG H K. Digital pipeline image scanning and intelligent data management for sewer pipelines [C]// International Pipelines Conference. Atlanta: [S. n.]: 2008: 1046-1056.
- [26] 甘小明, 徐滨士, 张旭明, 等. 基于微型CCD的管道缺陷检测系统[J]. 机械工程师, 2004 (1): 77.
- GAN Xiaoming, XU Binshi, ZHANG Xuming, *et al.* Pipeline defect detection system based on micro CCD [J]. Mechanical Engineer, 2004 (1): 77.
- [27] MORALED A J, OLLERO A, ORTE M. A robotic system for internal inspection of water pipelines[J]. IEEE Robotics & Automation Magazine, 1999, 6(3): 30.
- [28] ZHOU T, BROWN M, SNAVELY N, *et al.* Unsupervised learning of depth and ego-motion from video[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Hawaii: IEEE, 2017: 1851-1858.