

•人工智能•

DOI:10.12454/j.jsuese.202201161



一种受监督热图隧道衬砌线识别算法

宋恒, 张宜声*, 耿天宝, 王东杰

(中国中铁四局集团有限公司 管理与技术研究院, 安徽 合肥 230000)

摘要: 衬砌线识别作为隧道缺陷检测分析的关键步骤, 长期面临检测数据解析困难问题, 为突破传统解析方法的局限性, 提高解析结果的准确性、鲁棒性, 本文对CenterNet算法进行改进, 提出了受监督热图算法的隧道衬砌线关键点识别算法。该算法主要分为关键点检测和曲线拟合两个阶段, 包括网格分类任务、外围点监督、抗噪声扰动3种改进方法。双阶段共同训练时, 在关键点检测阶段, 首先, 新增网格分类任务, 依据分类结果监督热图拟合过程, 以改进CenterNet算法对于密集关键点的热图拟合能力; 其次, 在训练的前10轮中额外输出一定数量外围点热图, 通过外围点监督热图拟合, 配合网络分类任务改进热图拟合能力。曲线拟合阶段微调训练时, 对该阶段的输入加入抗噪声扰动, 以缓解图像噪声干扰。为验证本文算法的改进效果, 构建了隧道衬砌数据集, 先验证单独使用网格分类任务、外围点监督、抗噪声扰动3种具体改进方法对衬砌线识别的影响; 再通过消融实验, 进一步展示3种改进方法的组合对算法识别结果的影响。实验结果表明: 本文算法对比CenterNet和CornerNet算法识别效果提升明显, 使用网格分类任务识别的曲线间距误差均降低约0.4个像素点; 训练过程前10轮使用8~10个外围点监督模型学习, 识别效果提升最大; 抗噪声扰动强度 σ 为0.08时识别效果最佳, 且抗噪声扰动强度不宜过大; 此外, 以上3种改进方法的任意组合均能有效提升识别效果。本文提出的受监督热图隧道雷达数据衬砌线识别算法可为工程建设领域探地雷达无损检测数据解译工作提供技术支撑。

关键词: 探地雷达; 衬砌线检测; 网格分类任务; 外围点监督; 抗噪声扰动

中图分类号: TP183

文献标志码: A

文章编号: 2096-3246(2024)04-0078-10

隧道工程作为地下隐蔽工程^[1], 易受地下水侵蚀性和各种静动荷载作用, 在运营期间出现衬砌变形、裂缝、渗漏等多种病害^[2-3]。衬砌是支持和维护隧道的长期稳定和耐久性的永久结构物, 随着隧道运营时间的增加, 各种诱导因素^[4]对衬砌结构损伤的影响程度不断加剧, 衬砌厚度不足将产生应力集中, 造成开裂掉块等病害, 危及隧道日常运营安全。探地雷达检测法因其穿透力强、探测深度大、速度快、分辨率高、无污染、无辐射等优点, 目前被广泛应用于隧道病理无损检测^[5-6]。该方法包括数据采集和图像分析两方面内容: 数据采集过程中, 检测人员手持探地雷达紧贴隧道墙面沿测线移动, 采集的原始数据经信号处理转化为2维雷达图像^[7]; 组织相关专家针对2维

雷达图像研讨分析, 识别衬砌线来判断衬砌结构情况。但是, 该方法准确性十分依赖专家经验, 主观意见强烈, 缺乏统一尺度标准, 结果可靠性难以保证, 且费时费力效率低下。

使用2维雷达图像智能化识别衬砌线以取代专家人工分析势在必行。随着深度学习在图像识别^[8]、关键点检测^[9]和目标检测^[10]等领域的发展, 相关技术在越来越多领域内被使用。在隧道衬砌线识别领域中, 现有方法大体分为传统方法和通用的目标检测两类方法。传统方法中, Li等^[11]利用菲涅尔反射系数和衰减系数, 开发了一种自动识别衬砌层和估计二衬层厚度的方法。通用的目标检测方法中, Wang等^[12]基于旋转区域可变形卷积神经网络, 实现了探

收稿日期: 2022-10-26 修回日期: 2024-03-15 网络出版日期: 2024-07-04

基金项目: 中国中铁股份有限公司2021年度揭榜挂帅重大项目(2021-重大-14)

作者简介: 宋恒(1979—), 高级工程师, 博士。研究方向: 智能信号处理。E-mail: songhengyang@163.com

*通信作者: 张宜声, 助理工程师, E-mail: ethonzhang@163.com

地雷达(GPR)图像中任意方向的缺陷、钢筋、衬砌的自动识别方案。吴雅琴等^[13]使用改进的Faster R-CNN模型对脱空、空洞、天线脱空3类衬砌病害进行检测。余绍淮等^[14]基于YOLACT构建了病害轮廓及类型识别网络模型,生成仿真探地雷达数据集进行模型训练,对裂缝、空洞、脱空、含水裂缝、含水空洞和含水脱空6类典型隧道衬砌病害的类别和轮廓的识别平均准确率达92.28%。衬砌线的识别与车道线检测^[15]具有一定相似性,该领域中,Wang等^[16]根据B-Snake模型,通过控制一簇控制点来描述曲线对车道线进行拟合,实现车道线的检测和跟踪。Shi等^[17]将道路图像划分为若干像素块,判断像素块内是否包含车道线,对包含车道线的像素块用Hough变换进行线段检测,最后将所有检测到的线段连接构成车道线。Ko等^[18]将车道线图像划分为一个个网格,在网格中定位车道线的关键点,最后通过后处理方法拟合关键点,实现车道线的检测。在复杂场景目标检测领域中,目标特征信息提取困难、漏检频繁,CenterNet^[19]和CornerNet^[20]算法因其无锚框检测速度快、精度高,得到广泛应用。例如:王蓉蓉等^[21]针对水下图像质量低下导致目标特征信息提取困难、目标漏检等问题,提出了一种基于改进的CenterNet水下目标检测算法,实现对水下扇贝、海参、海星、海胆等目标的检测。邹盛等^[22]针对煤矿井下光线昏暗、照明不均匀、背景复杂、行人目标小而密集的难题,基于CornerNet算法实现煤矿井下行人检测。

上述文献所提方法中,传统方法如利用菲涅尔反射系数和衰减系数识别衬砌线,门槛高,监测效率低下且抗干扰能力较差;通用目标检测方法中,可变形卷积神经网络、改进的Faster R-CNN方法的定位范围偏大,识别精度较低,病害轮廓及类型识别网络仅能识别类别和大致轮廓,难以满足衬砌线检测的精度;与车道线特征不同,衬砌线布局走势多变,时序规律性弱,与环境区分不明显,现有车道线识别模型难以高效适用;此外,以CenterNet和CornerNet为代表的基于关键点的方法对稠密小目标拟合能力有限,检测能力不足。

鉴于此,本文提出了一种受监督热图的隧道雷达数据衬砌线识别算法,对传统的CenterNet结构进行改进,在双阶段共同训练时,使用网格分类任务和外围点监督,以改进关键点热图拟合能力。在曲线拟合阶段单独微调时,对输入加入抗噪声扰动,以缓解图像噪声干扰。将改进后的算法在新建数据集上进行实验,实验结果表明,改进后的算法在不增加推理耗时的前提下,显著改进了衬砌线的识别效果。

1 方法

1.1 衬砌线识别问题

衬砌结构在雷达2维图像上呈现类似不规则的带状线形态,位于拱架上方,拱架形态上表现为开口向下的双曲线,如图1(a)所示,图像中衬砌结构具有多解性,即不同结构的特征之间无明显区分,衬砌位置存在多种可能性,不同于其他通用的目标具有可明显区分的检测特点,隧道衬砌线的识别难度较大;为便于理解,采用若干关键点标识出衬砌线的位置,如图1(b)所示。




图1 衬砌结构的雷达2维图像及关键点标注

Fig. 1 Radar 2D images and key point annotations of lining structures

1.2 整体架构

本文提出的隧道衬砌线识别方法主要包括2个阶段:关键点检测阶段和曲线拟合阶段。其中:关键点检测阶段由基于CenterNet的关键点检测网络实现,包括主干网络和预测头两部分,该阶段负责提取雷达2维图像特征,输出衬砌线关键点;曲线拟合阶段采用多层感知机^[23]预测衬砌线位置,输入衬砌线关键点,输出衬砌线预测结果。以上2个阶段组成本文识别算法的全推理流程。

关键点检测阶段的主干网络与CenterNet主干网络基本一致,主干网络结构非本论文重点,不再过多阐述。关键点检测的预测头的主要任务是处理输出的 N 个特征图热图与 N 个关键点坐标的对应关系。为了使梯度流从坐标点流到高斯热图,减少热图转化成坐标关键点的量化损失,且不增加额外参数和计算量,选用可微空间数值变换(differentiable spatial to numerical transform, DSNT)结构^[24],对热图中关键点的坐标添加正则化因子进行监督。预测头的工作计算流程为:对于输出的特征热图先进行softmax归一化操作,得到只有一个峰值的离散概率分布,再将此离散概率分布输入至DSNT模块后,可直接获取坐标点信息。

曲线拟合阶段选用多层感知机进行数据拟合,

将关键点检测阶段输出的关键点集合 $X = \{X_1, X_2\}$ 作为此阶段的输入, 分别乘以参数 $\theta_0, \theta_1, \theta_M$, 并将二者乘积作为偏置项, 记为 h_i^n , 表示第 n 个隐藏层的第 i 个神经元的输出; 采用 ReLU 作为激活函数, 去除网络输出的线性化; 最终整个网络的输出为标记了衬砌线的雷达 2 维图像。

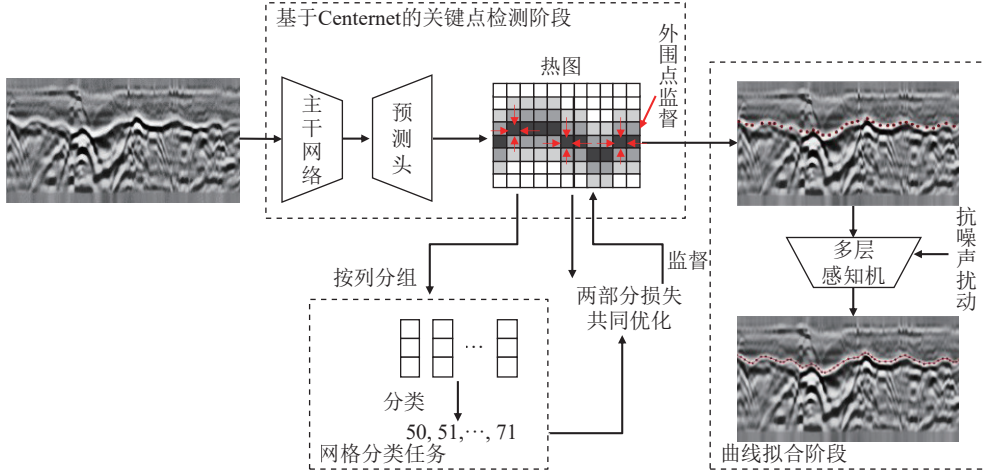


图 2 隧道衬砌线识别算法整体框架

Fig. 2 Overall framework of the tunnel lining identification algorithm

1.3 网格分类任务改进

在整个算法双阶段共同训练过程中, 关键点检测阶段加入网格分类任务, 辅助监督热图回归, 加快训练速度及精度。网格分类任务的大体思路是将热图分组后进行序列分类, 依据分类结果得到衬砌线所在位置信息, 依旧位置信息监督, 加速热图拟合和提高精度。

网格分类任务的具体步骤为: 首先, 使用 Transformer^[25] 结构对热图列数据建模分类, 将热图沿垂直方向 (A-scan) 以少量若干列为一组进行分组, 分组得到的网格序列由于在原热图水平方向 (B-scan) 跨度极小, 故网格序列中仅包含线关键点的深度信息。然后, 将网格序列沿垂直方向 (A-scan) 按若干份均划分, 依据网格序列中关键点所处位置对其划分类别, 例如: 将网格序列划分为 50 等份, 若关键点位于第 20 个小份内, 则将该网格序列标为“20”; 若该序列中不存在衬砌关键点, 则标为“0”。最后, 通过监督学习训练方式基于 Transformer 实现网格序列到分类标签的直接映射, 分类结果对关键点检测起监督作用。

1.4 外围点监督改进

在整个算法双阶段共同训练过程中, 前 10 轮关键点检测阶段会在输出每一个关键点的热图基础上, 额外输出外围关键点的热图; 通过外围点位置信息的监督, 加速网络的收敛。

然而, 仅仅上述 2 个阶段识别隧道衬砌线, 衬砌线识别精度无法满足要求, 为进一步提升识别精度, 本文将训练过程按先后顺序分为两个步骤: 双阶段共同训练和曲线拟合阶段单独微调训练, 前一步骤中使用网格分类任务和外围点监督改进方法, 后一步骤中使用抗噪声扰动改进方法, 如图 2 所示。

10 轮之后的训练中, 通过计算关键点之间的关系, 获取各关键点之间的矢量关系图, 如图 3 所示。图 3 中: 外围蓝点 $P_{ki} (i=1, 2, 3, \dots)$ 是预测的关键点坐标位置; 中心红点 P_C 为衬砌线预测范围内的中心位置; $V'_m(p_j) (j=1, 2, 3, \dots)$ 为关键点位置关系向量, 其是由中心红点坐标减去外围蓝点坐标得到的, 因此, 可通过位置关系向量反向调整模型参数, 以实现关键点位置的正确预测。

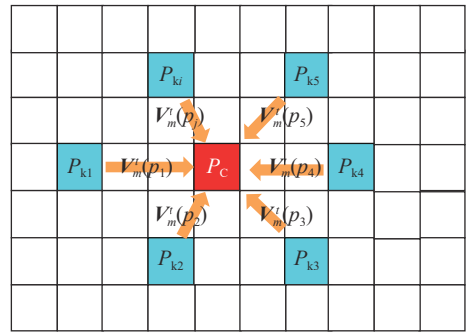


图 3 关键点位置矢量图

Fig. 3 Vector diagram of true keypoint locations

1.5 双阶段训练的损失函数

双阶段训练的损失函数包括: 坐标回归正则项, 即坐标的真实值与预测值之间的欧几里得损失, 记为 f'_S ; 通过热图计算的 Jensen-Shannon^[26] 分布正则损失, 记为 f'_L ; 外围点与预测点坐标之间的相对位置损失, 记为 f'_V ; 网格分类任务的损失, 记为 f'_R ; 其计算公式如式 (1)~(4) 所示:

$$f_S^t = \sum_{p=1}^P \mathbf{W}(p) \cdot \|S^t(p) \hat{S}^t(p)\|_2^2 \quad (1)$$

$$f_L^t = \sum_{c=1}^C \sum_{p=1}^P \mathbf{W}(p) \cdot \|L_c^t(p) \hat{L}_c^t(p)\|_2^2 \quad (2)$$

$$f_V^t = \sum_{m=1}^M \sum_{p=1}^P \mathbf{W}(p) \cdot \|V_m^t(p) \hat{V}_m^t(p)\|_2^2 \quad (3)$$

$$f_R^t = \sum_{r=1}^R \frac{1}{R} (y_r - \hat{y}_r)^2 \quad (4)$$

关键点预测网络的优化目标 L_k 为:

$$L_k = \frac{(f_S^t + f_L^t)}{2} + \alpha f_V^t + \beta f_R^t \quad (5)$$

式(1)~(5)中: p 为坐标位置; t 为时间; c 为相邻关键点; m 为外围点; C 为所有相邻关键点; M 为所有外围点; $S^t(p)$ 为该坐标位置的真实热图值; $\hat{S}^t(p)$ 为预测热图值; $L_c^t(p)$ 为真实关键点与相邻关键点连接区域关系的标签矢量图; $\hat{L}_c^t(p)$ 为相应预测的矢量图; $V_m^t(p)$ 为真实关键点与外围点的2维向量; $\hat{V}_m^t(p)$ 为相应的预测2维向量; $\mathbf{W}(p)$ 为2值掩码矩阵,通常用于表示目标的分割区域,当该位置为背景时 $\mathbf{W}(p)$ 等于0,当该位置为目标时 $\mathbf{W}(p)$ 等于1; y_r 为第 r 个分类任务标签值; \hat{y}_r 为对应的预测值; R 为所有外围点; α 和 β 为权重因子,用于调节外围点对关键点坐标的损失影响权重。

曲线拟合的损失函数采用均方误差值,记为 L_{MSE} ,如式(6)所示:

$$L_{MSE} = \sum_{u=1}^U \frac{1}{U} (y_u - \hat{y}_u)^2 \quad (6)$$

式中, y_u 为 u 点的真实位置, \hat{y}_u 为预测坐标, U 为曲线的所有点。

整个算法双阶段训练的网络优化目标为 L_k 与 L_{MSE} 之和。

1.6 曲线拟合阶段微调的抗噪声扰动改进

为进一步改进曲线拟合阶段的鲁棒性和泛化能力,针对曲线拟合阶段进行微调,冻结关键点检测阶段参数,单独训练曲线拟合阶段参数。在关键点预测之后输入神经网络拟合曲线的向量中加入图像高斯噪声扰动^[27],曲线拟合阶段单独训练,使得该阶段的损失函数在无扰动和抗噪声扰动方法下损失之和达到最小。不加扰动的损失函数 L_e 为:

$$L_e = \sum_{x \in \{x_1, x_2\}} MMD(\hat{D}_x, D_x) + \lambda_e \sum_{x \in \{x_1, x_2\}} (E(\hat{D}_x) - D_x)^2 \quad (7)$$

式中, λ_e 为无扰动的权重平衡因子, $MMD(\cdot)$ 表示取最大平均差异损失, $E(\cdot)$ 表示取期望值, \hat{D}_x 为预测值, D_x 为真实坐标, x_1 和 x_2 分别为点位置坐标。

增加扰动的损失函数 L_g 为:

$$L_g = \sum_{x \in \{x_1, x_2\}} MMD(\tilde{D}_x, D_x) + \lambda_o \sum_{x \in \{x_1, x_2\}} (E(\tilde{D}_x) - D_x)^2 \quad (8)$$

式中, λ_o 为抗扰动的权重平衡因子, \tilde{D}_x 为扰动条件下的预测坐标。

曲线拟合阶段微调训练的总损失函数 L 为:

$$L = L_e + \lambda_a L_g \quad (9)$$

式中, λ_a 为扰动平衡因子。微调训练的目标即为该式(9)的损失函数最小。

2 实验

2.1 数据准备

对衬砌线雷达原始数据进行增益、滤波、均值等预处理后,进行关键点标注,以每个关键点为中心,生成对应的高斯热图。考虑到数据标注的真实性,隧道场景下无法针对每个数据实地钻孔验证,标注过程中,组织多位专家对已标注数据进行审核,仅对有争议的数据钻孔验证,无争议数据视为标注无误。

制作整理数据集,数据集共包含4799张、图片尺寸为512×512的雷达2维图像,数据集整体分为训练集、测试集、验证集,具体数据集见表1。

表1 数据集参数及规模

Tab.1 Dataset parameters and size			
数据集	数据规模	衬砌关键点量	数据大小/GB
训练集	3200	753 562	12.35
测试集	999	236 742	3.52
验证集	600	188 635	2.88

2.2 网格分类任务改进方法的效果验证

以图像形式展示改进方法对识别结果的改进效果,具体地,以网格分类任务为例进行展示,其余改进方法类似,故不再赘述。

为直观体现本文提出的网格分类任务改进方法的有效性,在验证数据集上分别使用CenterNet、CornerNet及本文提出的网格分类任务改进方法进行关键点检测,并将关键点图像进行输出,选取两个样本结果对比展示衬砌识别效果,如图4所示。图4中各数据样本均一致。

由图4可知:使用CenterNet进行关键点检测的结果(图4(b))中,部分衬砌线段关键点存在少量漏检,甚至在衬砌线模糊时,发生连续漏检;个别局部关键点检测位置偏移较大,不利于后续的曲线拟合;使用

CornerNet进行关键点检测的结果(图4(c))中,关键点检测位置偏移现象略有好转,但部分位置检测到的关键点过于密集,拟合过度;与以上两种算法相比,使用本文提出的网格分类任务改进方法监督关键点

检测的结果(图4(d))中,关键点分布匀称,与衬砌线贴合较为紧密,无明显漏检、错检的现象。图5对比展示了CenterNet、CornerNet算法及本文提出的网格分类任务改进方法所生成的关键点进行曲线拟合的效果。

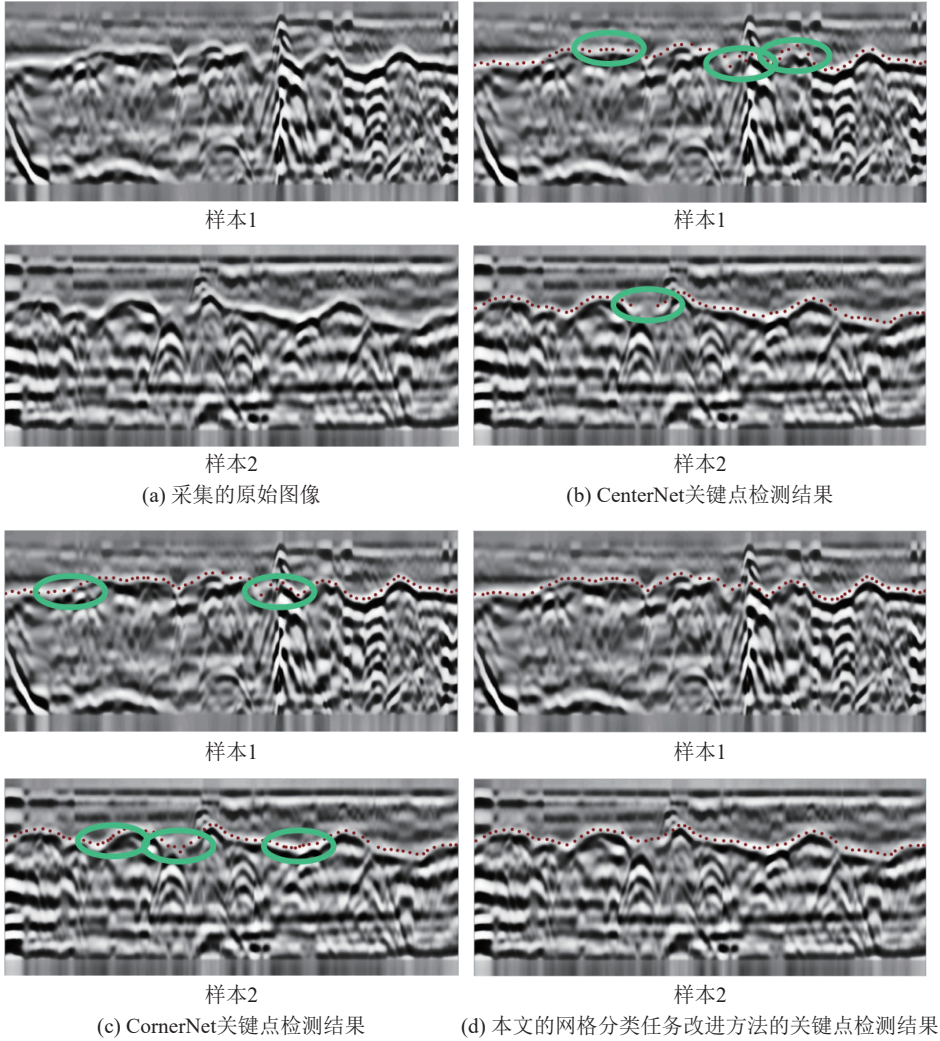


图 4 不同算法的关键点检测效果

Fig. 4 Key point detection effects of different algorithms




图 5 基于不同算法的曲线拟合效果

Fig. 5 Curve fitting effects based on different algorithms

由图5可见:最终衬砌线的拟合效果取决于关键点预测的位置信息,关键点稀疏将导致曲线不接近真实衬砌线;对于同一个输入样本图像,使用本文提出的网格分类任务改进方法后拟合的衬砌线最贴合真实衬砌线,而其他两个对比算法存在拟合曲线与实际衬砌线贴合不紧密或重叠的情况。

2.3 对比实验

基于测试数据集先分别验证3种改进方法各自的改进效果,再对3种方法进行消融实验,验证不同方法任意组合使用对隧道衬砌线识别的改进效果。

首先,为进一步验证本文提出的网格分类任务改进方法对CenterNet、CornerNet算法进行隧道衬砌线识别的整体效果的改进,开展详细的对比实验。先

表2 本文提出的网格分类任务改进方法与CenterNet和CornerNet方法的衬砌线识别效果对比

Tab. 2 Comparison of lining line recognition effects between the grid classification task proposed in this paper with the CenterNet and CornerNet methods

算法	欧氏距离	曼哈顿距离	切比雪夫距离	曲线间距	推理耗时/ms
CenterNet(ResNet)	6.33	8.48	5.67	3.47	11
CenterNet(DLA-34)	5.56	7.64	5.01	3.06	19
CenterNet(Hourglass-104)	4.73	6.38	4.02	2.51	71
CornerNet	5.72	7.82	4.95	2.95	23
本文提出的网格分类任务改进方法+CenterNet(ResNet)	5.54	7.02	4.91	3.07	11
本文提出的网格分类任务改进方法+CenterNet(DLA-34)	4.81	6.58	4.22	2.66	19
本文提出的网格分类任务改进方法+CenterNet(Hourglass-104)	3.76	4.95	3.01	2.23	71
本文提出的网格分类任务改进方法+CornerNet	4.63	6.93	4.02	2.61	23

由表2可知:在4种基础算法中加入本文提出的网格分类任务改进方法后形成的相应算法,在欧氏距离、曼哈顿距离、切比雪夫距离、曲线间距4个指标上,比对应的基础算法均有更明显的精度提升,其中,加入本文提出的网格分类任务改进方法的CenterNet(Hourglass-104)算法在4个指标上精度均最高,欧氏距离为3.76个像素点,曼哈顿距离为4.95个像素点,切比雪夫距离为3.01个像素点,曲线间隔为2.23个像素点。加入本文提出的网格分类任务改进方法后对算法的推理耗时无影响,其原因在于本文提出的网格分类任务仅存在于训练过程。

接下来,验证外围点训练轮次数、外围点个数及高斯噪声强度(σ)变化分别对使用本文提出的外围点监督和抗噪声扰动改进方法进行衬砌线识别效果的影响,其中,CenterNet算法的主干网络分别选取ResNet、DLA-34、Hourglass-104,结果如图6所示。由图6(a)可知:随着使用外围点监督训练轮次的增加,本文提出的外围点监督改进方法的识别效果不断提升;在第10轮次时,本文提出的外围点监督改进方法

选用CenterNet和CornerNet作为对比算法进行4组基础实验,其中,CenterNet主干网络分别选用ResNet^[28]、DLA-34^[29]、Hourglass-104^[30]3种结构;再将这4组基础算法中均加入本文提出的网格分类任务改进方法,来对比验证该方法对衬砌线识别的改进效果。实验中,将计算预测关键点坐标与真实关键点之间的曼哈顿距离、欧氏距离、切比雪夫距离作为关键点检测阶段的评价指标;在已标注衬砌线上先按水平方向200等分选取采样点,再依据水平坐标在预测的衬砌线上选取采样点,计算预测的采样点坐标与真实采样点坐标之间垂直方向像素点平均距离记为曲线间距,作为曲线拟合阶段的评价指标;将推理耗时作为算法开始识别到识别完成所需时间的评价指标。具体结果见表2。

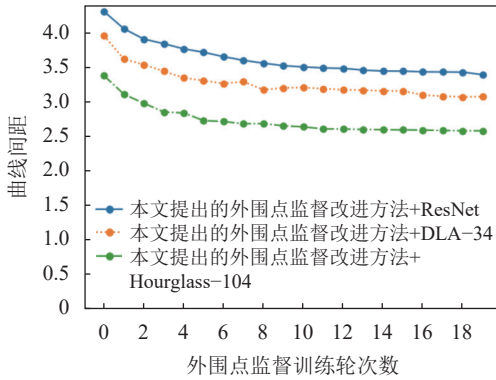
表2 本文提出的网格分类任务改进方法与CenterNet和CornerNet方法的衬砌线识别效果对比

的识别效果最佳,基于ResNet、DLA-34、Hourglass-104的识别效果分别为3.50、3.21、2.61个像素点,但10轮后其识别效果有限且趋于稳定。由图6(b)可知:初始阶段,随着外围点数量的增加,本文提出的外围点监督改进方法的识别效果明显提升;在8~10个外围点监督下,其识别效果最明显;后续随着外围点数量的增加,其识别效果逐渐变差。由图6(c)可知, σ 在0.08左右时,本文提出的抗噪声扰动改进方法的识别效果最佳,基于ResNet、DLA-34、Hourglass-104的识别效果分别为3.60、3.11、2.45个像素点; σ 过大即噪声过大,不利于本文提出的抗噪声扰动改进方法对衬砌线的识别。


为了直观验证本文提出的网格分类任务、外围点监督、抗噪声扰动3种改进方法对CenterNet算法的衬砌线识别的改进效果,基于主干网络为Hourglass-104的CenterNet算法进行消融实验,即对本文提出的网格分类任务、外围点监督、抗噪声扰动3种改进方法进行排列组合,再分别对该主干网络模型进行改进和训练,选用欧氏距离和曲线间距作为精度指标,

实验结果见表3。由表3可知:单独使用本文提出的网格分类任务、外围点监督、抗噪声扰动3种改进方法,均能有效提高识别的精度,其中,单独使用本文提出网格分类任务改进方法的识别精度在三者中最高,但其内存占用也最高;使用网格分类任务、外围点监


督、抗噪声扰动3种改进方法的两两组合,均比仅使用单一改进方法的识别精度更高;同时使用3种改进方法的识别精度达到最高,其曲线间距仅为2.23个像素点,内存占用也达到最高的308 MB,未明显增加计算资源需求,常见计算资源即可满足。



(a) 监督训练轮次数对本文提出的外围点监督改进方法识别结果的影响



(b) 外围点数量对本文提出的外围点监督改进方法的识别结果的影响



(c) 噪声强度对本文提出的抗噪声扰动改进方法识别结果的影响

图 6 外围点训练轮次数、外围点个数及高斯噪声强度变化对本文提出的外围点监督、抗噪声扰动改进方法的识别结果的影响

Fig. 6 Influence of the number of outer-points training rounds, the number of outer-points and the Gaussian noise intensity on the recognition results of the proposed improved method of outer-points supervision and anti-noise disturbance

表 3 本文提出的网格分类任务、外围点监督、抗噪声扰动3种改进方法的消融实验

Tab. 3 Ablation experiments of the three improved methods proposed in this paper: grid classification task, outer-points supervision, and anti-noise disturbance

方法	欧氏距离	曲线间距	内存占用/MB
CenterNet(Hourglass-104)	4.73	2.51	213
本文提出的网格分类任务改进方法+ Hourglass-104	4.33	2.42	282
本文提出的外围点监督改进方法+Hourglass-104	4.58	2.46	232
本文提出的抗噪声扰动改进方法+ Hourglass-104	4.65	2.47	219
本文提出的网格分类任务+外围点监督两种改进方法+ Hourglass-104	4.02	2.30	301
本文提出的网格分类任务+抗噪声扰动两种改进方法+Hourglass-104	4.11	2.35	290
本文提出的外围点监督+抗噪声扰动两种改进方法+ Hourglass-104	4.30	2.40	245
本文提出的网格分类任务+外围点监督+抗噪声扰动3种改进方法+ Hourglass-104	3.76	2.23	308

综上所述,本文提出的3种改进方法均能有效提升现有的CenterNet算法的衬砌线的识别效果,因为

其预测的衬砌线关键点更接近真实的坐标信息,所以本文所提的衬砌线识别算法的改进效果明显。

3 结论

针对目前隧道无损监测过程面临的检测数据解析困难问题,本文对传统基于热图的CenterNet算法进行了网格分类任务、外围点监督、抗噪声扰动3种改进。首先,在双阶段共同训练时,使用网格分类任务和外围点监督,以改进关键点热图拟合能力。在曲线拟合阶段单独微调时,对输入加入抗噪声扰动,以缓解图像噪声干扰。在新建数据集上进行对比实验,验证了3种改进方法在各自参数变化、各方法单独使用和组合使用等不同情况下对隧道衬砌线识别效果的改进。实验结果表明,本文的改进方法对CenterNet算法识别效果提升明显,使用网格分类任务识别的曲线间距误差均降低约0.4个像素点;训练过程前10轮使用8~10个外围点监督模型学习,识别效果提升最大;抗噪声扰动强度为0.08时识别效果最佳;以上3种改进方法的任意组合均能有效提升识别效果。本文的改进方法为将来雷达数据解译工作提供借鉴与支持。

目前,本文在曲线拟合阶段采用的改进方法较为简单,后续拟进一步研究,以提高衬砌线总体识别精度。

参考文献:

- [1] Editorial Department of China Journal of Highway and Transport. Review on China's tunnel engineering research: 2015[J]. *China Journal of Highway and Transport*, 2015, 28(5): 1-65. [《中国公路学报》编辑部. 中国隧道工程学术综述·2015[J]. *中国公路学报*, 2015, 28(5): 1-65.]
- [2] Yan Jinxiu. Achievements and challenges of tunneling technology in China over past 40 years[J]. *Tunnel Construction*, 2019, 39(4): 537-544. [严金秀. 中国隧道工程技术发展40年[J]. *隧道建设(中英文)*, 2019, 39(4): 537-544.]
- [3] Wang Mengshu. An overview of development of railways, tunnels and underground works in China[J]. *Tunnel Construction*, 2010, 30(4): 351-364. [王梦恕. 中国铁路、隧道与地下空间发展概况[J]. *隧道建设*, 2010, 30(4): 351-364.]
- [4] Ma Fangping, Chen Ying, Huang Huibao, et al. Analysis on the inducement of defects in the lining bottom plate of hydraulic tunnel and its influence on the structural safety[J]. *Science Technology and Engineering*, 2023, 23(33): 14349-14356. [马芳平, 陈英, 黄会宝, 等. 水工隧洞衬砌底板缺陷诱因及其对结构安全的影响分析[J]. *科学技术与工程*, 2023, 23(33): 14349-14356.]
- [5] Wai-Lok Lai W, Dérobert X, Annan P. A review of ground penetrating radar application in civil engineering: A 30-year journey from locating and testing to imaging and diagnosis [J]. *NDT & E International*, 2018, 96: 58-78.
- [6] Zhang Dingli, Zhang Sulei, Fang Qian, et al. Study of contact

- state behind tunnel lining in process of railway operation and its analysis[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2013, 32(2): 217-224. [张顶立, 张素磊, 房倩, 等. 铁路运营隧道衬砌背后接触状态及其分析[J]. *岩石力学与工程学报*, 2013, 32(2): 217-224.]
- [7] Lin Chunjin, Wang Xintong, Li Yao, et al. Forward modelling and GPR imaging in leakage detection and grouting evaluation in tunnel lining[J]. *KSCE Journal of Civil Engineering*, 2020, 24(1): 278-294.
- [8] Wang Haoyu, Cheng Yuhu, Philip Chen C L, et al. Broad graph convolutional neural network and its application in hyperspectral image classification[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2023, 7(2): 610-616.
- [9] Liu Cuiyin, Xu Jishang, Wang Feng. A review of keypoints' detection and feature description in image registration[J]. *Scientific Programming*, 2021, 2021: 8509164.
- [10] Kang J, Tariq S, Oh H, et al. A survey of deep learning-based object detection methods and datasets for overhead imagery[J]. *IEEE Access*, 2022, 10: 20118-20134.
- [11] Li Chuan, Li Mengjuan, Zhao Yonggui, et al. Layer recognition and thickness evaluation of tunnel lining based on ground penetrating radar measurements[J]. *Journal of Applied Geophysics*, 2011, 73(1): 45-48.
- [12] Wang Jing, Zhang Jiaqi, Cohn A G, et al. Arbitrarily-oriented tunnel lining defects detection from ground penetrating radar images using deep convolutional neural networks[J]. *Automation in Construction*, 2022, 133: 104044.
- [13] 吴雅琴, 方思南, 郑鈇彬, 等. 基于改进Faster R-CNN算法的隧道衬砌病害识别研究[C]//中国地球物理学会. 2022年中国地球科学联合学术年会论文集——专题十七: 电磁地球物理学研究应用及其新进展、专题十八: 探地雷达新进展. 北京: 北京伯通电子出版社, 2022: 91-94.
- [14] Yu Shaohuai, Yu Fei, Luo Boren, et al. YOLACT based targets categorization and shape identification from ground penetrating radar images[J]. *Progress in Geophysics*, 2023, 38(3): 1408-1415. [余绍淮, 余飞, 罗博仁, 等. 探地雷达图像隧道衬砌病害智能识别与形态分割方法[J]. *地球物理学进展*, 2023, 38(3): 1408-1415.]
- [15] Li Yihong, Ni Xinglong, Sun Renyun. Design of lane keeping assist system[J]. *Automobile Applied Technology*, 2024, 49(6): 88-93. [李乙洪, 倪兴龙, 孙仁云. 车道保持辅助系统设计[J]. *汽车实用技术*, 2024, 49(6): 88-93.]
- [16] Wang Yue, Teoh E K, Shen Dinggang. Lane detection and tracking using B-Snake[J]. *Image and Vision Computing*, 2004, 22(4): 269-280.
- [17] Shi Xuejie, Kong Bin, Zheng Fei. A new lane detection method based on feature pattern[C]//Proceedings of the 2009 2nd International Congress on Image and Signal Processing.

- Tianjin:IEEE,2009:1–5.
- [18] Ko Y, Lee Y, Azam S, et al. Key points estimation and point instance segmentation approach for lane detection[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7):8949–8958.
- [19] Duan Kaiwen, Bai Song, Xie Lingxi, et al. CenterNet: Keypoint triplets for object detection[C]//*Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV)*. Seoul:IEEE, 2019:6568–6577.
- [20] Law H, Deng Jia. CornerNet: Detecting objects as paired keypoints[J]. *International Journal of Computer Vision*, 2020, 128(3):642–656.
- [21] Wang Rongrong, Jiang Zhongyun. Underwater object detection algorithm based on improved CenterNet[J]. *Laser & Optoelectronics Progress*, 2023, 60(2):3788/LOP212230. [王蓉蓉, 蒋中云. 基于改进CenterNet的水下目标检测算法[J]. *激光与光电子学进展*, 2023, 60(2):3788/LOP212230.]
- [22] Zou Sheng, Zhou Libing, Ji Liang, et al. A pedestrian target detection method for underground coal mine based on image fusion and improved CornerNet-Squeeze[J]. *Journal of Mine Automation*, 2023, 49(2):77–84. [邹盛, 周李兵, 季亮, 等. 基于图像融合和改进CornerNet-Squeeze的煤矿井下行人检测方法[J]. *工矿自动化*, 2023, 49(2):77–84.]
- [23] Desai M, Shah M. An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network(MLP) and Convolutional neural network(CNN)[J]. *Clinical eHealth*, 2021, 4:1–11.
- [24] Nibali A, He Zhen, Morgan S, et al. Numerical coordinate regression with convolutional neural networks[EB/OL]. [2022–10–01]. <http://arxiv.org/abs/1801.07372>.
- [25] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook: Curran Associates Inc, 2017:6000–6010.
- [26] Menéndez M L, Pardo J A, Pardo L, et al. The Jensen-Shannon divergence[J]. *Journal of the Franklin Institute*, 1997, 334(2):307–318.
- [27] Qin Zhiyuan, Wu Bing, Wang Yan, et al. The comparison study on image smoothing algorithms & improve strategy[J]. *Journal of Institute of Surveying and Mapping*, 2005, 22(2):103–106. [秦志远, 吴冰, 王艳, 等. 图像平滑算法比较研究及改进策略[J]. *测绘学院学报*, 2005, 22(2):103–106.]
- [28] 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)*. Las Vegas:IEEE, 2016:770–778.
- [29] Yu F, Wang Dequan, Shelhamer E, et al. Deep layer aggregation[C]//*Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018:2403–2412.
- [30] Susanto Y, Livingstone A G, Ng B C, et al. The hourglass model revisited[J]. *IEEE Intelligent Systems*, 2020, 35(5):96–102.

A Tunnel Lining Line Identification Algorithm Based on Supervised Heatmap

SONG Heng, ZHANG Yisheng^{*}, GENG Tianbao, WANG Dongjie

(Management and Technol. Inst., China Railway No.4 Eng. Group Co., Ltd., Hefei 230000, China)

Abstract:

Objective As a critical step in tunnel defect detection and analysis, lining line identification has long faced challenges in analyzing detection data. This study proposes using supervised heatmap algorithms and anti-noise disturbance techniques to recognize keypoints of lining lines, based on the CenterNet algorithm, to overcome the limitations of traditional analysis methods and enhance the accuracy and robustness of the results.

Methods The algorithm is divided into two stages: keypoint detection and curve fitting. It includes three improvement methods: grid classification task, peripheral point supervision, and anti-noise disturbance. Initially, during the two-stage training process, the keypoint detection phase aims to improve the CenterNet algorithm's limited heatmap fitting capability for dense keypoints by incorporating a heatmap grid classification task. The grid sequence, aligned in the vertical (A-scan) direction, is divided equally into several segments. These segments are categorized based on the location of keypoints within the sequence. A transformer is employed to learn the mapping from grid sequences to classification labels through supervised training. This supervision of the heatmap fitting process is based on the classification results. Simultaneously, a certain number of outer-point heatmaps are produced in the initial training rounds, and the model's learning process is constrained through the positional information between outer points and keypoints. In the fine-tuning stage of curve fitting, Gaussian noise is introduced to the curve, and anti-noise disturbance is applied to counteract image noise interference. Finally, the tunnel lining dataset, divided into training, validation, and test sets, is utilized. The training set contains 3 200 images with 753 562 keypoints and a data size of 12.35 GB. The validation set comprises 600 images with 188 635 keypoints and a data size of 2.88 GB. The test set consists of 999 images, including 236 742 keypoints, and a data size of 3.52 GB. This dataset is test data in the experimental stage to compare the CenterNet, CornerNet, and the proposed algorithm. The effects of the three specific improvement methods, grid classification task, peripheral point supervision, and noise resistance, on lining line recognition are initially verified.

Through ablation experiments based on the CenterNet algorithm, the impacts of various improvement measures on the algorithm's performance are further demonstrated.

Results and Discussions The experimental results showed that different algorithms' lining line recognition performance significantly improves after being supervised by the grid classification task. The curve spacing errors of the recognition results from the CenterNet algorithm, employing the backbone networks ResNet, DLA-34, and Hourglass-104, respectively, are reduced by 0.40, 0.40, and 0.28 pixels. The inference times are 11, 19, and 71 milliseconds, respectively. The CornerNet algorithm reduces errors by 0.34 pixels, with an inference time of 23 milliseconds. The grid classification task exists only during the training process, so it does not impact the inference time. Additionally, using outer points to supervise the heatmap fitting process also improves recognition accuracy. The more supervision training rounds, the better the recognition performance. After incorporating outer-point supervision in the first 10 rounds, the curve spacing errors recognized by different algorithms are 3.56, 3.20, and 2.65 pixels, showing improvement effects of 0.75, 0.75, and 0.73 pixels, respectively. Continuing the training beyond 10 rounds results in limited further improvements. By increasing the number of outer points, significant enhancements are initially observed. The optimal effect occurs when 8~10 outer points are used, with curve spacing errors of 3.48, 3.13, and 2.44 pixels, respectively, and improvement effects of 1.84, 1.88, and 2.08 pixels. As more outer points are added, the effect gradually diminishes. Therefore, using 8~10 outer points to supervise model learning in the first 10 rounds yields the most significant improvements. When noise is introduced early in the curve fitting input, recognition accuracy improves, with optimal noise disturbance intensity at approximately 0.08. The curve spacing errors recognized by different algorithms are 3.59, 3.20, and 2.49 pixels, respectively, with improvement effects of 1.73, 1.81, and 2.03 pixels. As noise intensity increases, the overall recognition effect deteriorates sharply. In the ablation experiment, the CenterNet algorithm with the Hourglass-104 backbone network is visually employed to verify the impact of different improvement measures on algorithm recognition performance. The results showed that the three measures of classification task supervision, outer-point supervised training, and anti-noise disturbance improve recognition accuracy by 0.09, 0.05, and 0.04 pixels, respectively, with memory consumption increases of 69, 19, and 6 MB. When classification task supervision and outer-point supervision training are employed simultaneously, the result is improved by 0.21 pixels, with a memory consumption increase of 88 MB. Similarly, when classification task supervision and noise disturbance are combined, the result improves by 0.16 pixels, and memory consumption increases by 77 MB. When outer-point supervised training and anti-noise disturbance are used together, the result improves by 0.11 pixels, and memory consumption rises by 32 MB. Implementing all three measures simultaneously effectively improves accuracy by 0.28 pixels and increases memory consumption by 95 MB.

Conclusions The results showed that the grid classification task, outer-point supervision, and anti-noise disturbance proposed in this study can effectively enhance the effectiveness of tunnel lining line identification and mitigate the challenge of detecting dense keypoints. The proposed algorithm can provide technical support for interpreting ground-penetrating radar non-destructive testing data in engineering construction.

Key words: ground penetrating radar; lining line detection; grid classification task; outer-points supervision; anti-noise disturbance

(编辑 赵婧)

引用格式: Song Heng,Zhang Yisheng,Geng Tianbao,et al.A tunnel lining line identification algorithm based on supervised heatmap[J].Advanced Engineering Sciences,2024,56(4):78-87.[宋恒,张宜声,耿天宝,等.一种受监督热图隧道衬砌线识别算法[J].工程科学与技术,2024,56(4):78-87.]