

全自动无人驾驶列车障碍物检测的轨道区域 检测算法

盛峰^{1,2}, 沈拓^{3,5}, 谢远翔^{3,4}, 张颖^{3,4}, 曾小清^{3,4}, 朱明昌^{3,4}, 张轩雄⁵

(1. 清华大学土木水利学院, 北京 100084; 2. 中电建路桥集团有限公司, 北京 100070;

3. 同济大学上海市轨道交通结构耐久与系统安全重点实验室, 上海 201804;

4. 同济大学道路与交通工程教育部重点实验室, 上海 201804; 5. 上海理工大学光电与计算机工程学院, 上海 200093)

摘要: 针对轨道交通全自动无人驾驶列车轨道障碍物检测领域中的轨道区域分割问题, 提出一种基于视觉传感器的非接触式轨道区域检测算法。算法使用帧间差分阈值和灰度分布特征提取方法完成对视频图像数据的场景识别和标记; 基于图像场景识别结果能够自适应调整参数输入的自适应边缘检测模块完成对图像的预处理和轨道轮廓的边缘检测; 基于类滑动窗格的轨道区域边界搜寻模块构建滑动窗格搜索子模块和通带搜索子模块完成对轨道轮廓曲线的提取, 最后使用卡尔曼滤波器提升检测结果的准确性和鲁棒性。实验结果表明该算法具备良好的检测性能。

关键词: 轨道交通; 全自动无人驾驶; 障碍物检测; 轨道区域分割; 机器视觉

中图分类号: U239.5; TP391.41

文献标志码: A

Track Area Detection Algorithm for Obstacle Detection of Fully Automatic Driverless Train

SHENG Feng^{1,2}, SHEN Tuo^{3,5}, XIE Yuanxiang^{3,4},
ZHANG Ying^{3,4}, ZENG Xiaoqing^{3,4}, ZHU Mingchang^{3,4},
ZHANG Xuanxiong⁵

(1. School of Civil Engineering, Tsinghua University, Beijing 100084, China; 2. Powerchina Roadbridge Group Co., Ltd., Beijing 100070, China; 3. Shanghai Key Laboratory of Rail Infrastructure Durability and System Safety, Tongji University, Shanghai 201804, China; 4. Key Laboratory of Road and Traffic Engineering of the Ministry of Education, Tongji University, Shanghai 201804, China; 5. School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: A non-contact detection algorithm based on vision sensors is proposed to address the issue of track area segmentation in the context of fully automatic driverless trains for rail transit. The algorithm uses frame difference threshold and grayscale distribution feature extraction methods to perform scene recognition and labeling of video image data. Image preprocessing and edge detection of the track contour are completed by an adaptive edge detection module, which adjusts the parameter input based on the results of image scene recognition. The track area boundary search module consists of two submodules: the sliding pane search submodule and the passband search submodule, based on the sliding pane-like approach, in order to extract the track outline curve. Finally, a Kalman filter is used to improve the accuracy and robustness of the detection results. The experimental results show that the algorithm exhibits strong detection performance on track boundaries.

Keywords: rail transit; fully automatic driverless system; obstacle detection, track area segmentation; machine vision

轨道交通领域全自动无人驾驶成为新的发展趋势, 截至 2022 年底我国城市轨道交通运营线路总长 10 287 km, 包含 15 座城市的 30 条全自动无人驾驶线路, 运营总里程达 716 km, 总体呈明显的上升趋势。全自动无人驾驶列车运行控制系统集成了列车自动运行系统(ATO)、列车自动防护系统(ATP)等

收稿日期: 2024-01-05

基金项目: 校企战略合作专项高速铁路绿色智能施工关键技术研究(kh0160020230946_LQKY2022-01-1);

国家重点研发计划(2022YFB4300501); 上海市科委课题(23DZ2204900)

第一作者: 盛峰, 教授级高工, 博士生, 主要研究方向为轨道交通控制、土木水利工程。

E-mail: s18663726777@126.com

通信作者: 曾小清, 教授, 博士生导师, 工学博士, 主要研究方向为轨道交通控制与安全。

E-mail: zengxq@tongji.edu.cn



论文
拓展
介绍

功能,具有先进的移动授权管理^[1]等功能,可以有效防止列车与列车之间的冲突。然而,列车运行控制系统无法防范异物入侵的危险事件,因异物入侵轨道区域导致的轨道交通事故时有发生。2022年8月9日,北京地铁2号线朝阳门站有乘客翻越站台闯入轨道正线,被撞身亡;2021年1月22日,南宁地铁1号线隧道顶部被上方施工打穿,列车与钻头发生碰撞,事故导致行车中断近2h,直接经济损失306万余元。轨道交通一旦发生事故,不仅会造成人员伤亡,还会带来巨大的经济损失。因此,以防止异物入侵轨道区域引发安全事故、保障行车安全、减少经济损失为目的的轨道障碍物检测成为行业研究热点。同时,现有关于轨道障碍物检测的研究多侧重于提升检测距离,而在提高检测准确性方面则存在明显不足,导致障碍物检测系统在实际工程应用时虚警率过高,可用性较差。

现有轨道障碍物检测方法根据检测原理的不同可分为接触式检测和非接触式检测两大类。接触式障碍物检测,如使用检测车在轨道上移动,当发生碰撞时,则表示该处存在障碍物,此方法原理简单,但检测成本高,检测效率低。非接触式轨道障碍物检测方法使用视觉传感器、激光雷达^[2]、超声波雷达^[3]、红外传感器^[4]、激光扫描仪^[5]等获取轨道区域位置并实现障碍物检测。轨道区域检测主要采用基于视觉传感器实现的非接触式检测,检测方法包括传统式图像处理方法和基于深度学习的方法,利用卷积神经网络(Convolutional Neural Networks, CNN)建立特征提取和目标检测算法是目前的研究热点。郭宝清等^[6]提出一种基于PTZ(Pan-Tilt-Zoom)相机极向投影识别铁路轨道区域的方法,利用小波分析、形态学运算和连通域标记进行图像预处理,利用霍夫变换和钢轨极向投影检测图像中钢轨位置的限界区域标记。He等^[7]设计了一种名为深度语义分割卷积神经网络的新型端到端语义分割网络,用于像素级铁路场景分割,实现对铁路场景关键部位的定位。Li等^[8]研究了基于深度多任务学习的消失点检测和轨道分割算法,该算法可根据消失点的变化识别摄像机的调整,并自动从分割的轨道中确定报警区域。Wang等^[9]提出一种基于卷积神经网络的自适应分割算法,该算法利用铁路场景的强线性特征和局部区域的典型类别,采用自适应特征分布提取器分割铁路轨道区域。Ye等^[10]设计了一种有效的差分特征融合CNN来实现对轨道区域和入侵障碍物的检测。张林等^[11]通过数据增强策略平衡样本数量,并

将FPN(Feature Pyramid Network)网络与原始的Faster R-CNN(Region-based Convolutional Neural Network)骨干网络进行特征融合,提升了轨道区域和小型障碍物的检测率。上述方法均需要预先搜集和处理大量的训练样本,算法时效性较低,面对具有复杂背景的特殊场景算法可靠性降低。Gong等^[12]首次将小样本学习(Few-shot learning, FSL)算法应用于铁路轨道区域入侵检测,开发了一种使用增强型FSL的轨道区域入侵检测算法,算法训练规模降低,算法经济型和性能得到一定提升。目前基于神经网络的轨道区域分割算法因模型较大、时延较长、对硬件设备要求较高,在实际工程应用和部署中尚存在一定的局限性。

轨道区域分割经常作为轨道障碍物检测的预处理步骤,通过算法定位出警戒区、预警区和安全区^[13],其检测精度将直接影响障碍物检测的准确性和可靠性。本文面向列车自主障碍物检测,特别是全自动无人驾驶列车的障碍物检测,提出了一种基于视觉传感器的轨道区域检测算法,该算法设计了基于类滑动窗格的轨道区域边界搜寻模块,通过两级帧间差分阈值法完成对视频帧的动静检测,使用灰度分布特征提取和参数自适应的边缘检测等方法提升对图像的场景识别和边缘检测的准确性和完整性,基于类滑动窗格的轨道区域边界搜寻模块完成对轨道区域边界的提取,最后利用卡尔曼滤波提升检测结果的准确性和鲁棒性。

1 轨道区域检测算法

1.1 算法流程

基于类滑动窗格的轨道区域检测算法流程如图1所示,首先对输入的视频图像进行列车运行场景识别;然后根据场景识别结果进行自适应边缘检测,得到含有轨道边界特征的二值化图像;再基于类滑动窗格的轨道区域边界搜寻模块搜索轨道轮廓候选像素点,得到关于轨道轮廓曲线的候选坐标集合,并拟合图像中的轨道曲线;最后对拟合得到的轨道曲线参数进行卡尔曼滤波并返回检测结果。

1.2 场景识别

在进行图像处理之前,对列车运行场景进行粗分类,可以方便算法参数的设置和调整,让算法在进行图像处理时更有针对性。场景识别具体是指对列车运行场景进行划分,使用灰度直方分布特征识别列车的运行场景。

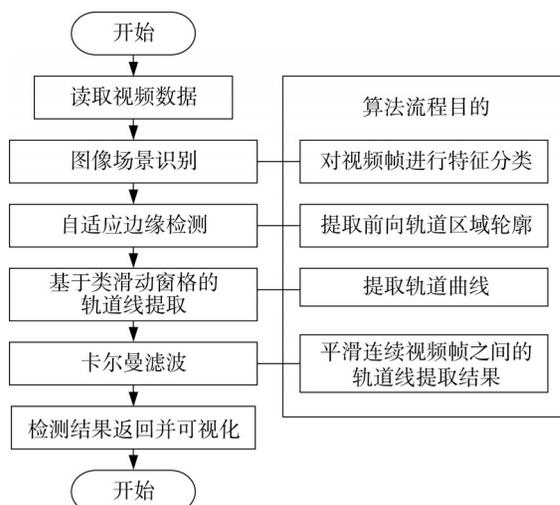


图 1 基于类滑动窗格的轨道区域检测算法流程

Fig. 1 Process of track boundary detection algorithm based on sliding pane-like approach

基于图像灰度直方分布特征的场景划分策略为

$$r_i = \frac{H_i}{U} \quad (1)$$

$$c_i = \begin{cases} 0 & r_i < s_1 \\ 1 & s_1 \leq r_i < s_2 \\ 2 & s_2 \leq r_i < s_3 \\ \vdots & \\ k & r_i \geq s_k \end{cases} \quad (2)$$

式中: H_i 为灰度值大于等于阈值 W 的像素点数目; U 为像素点总数; c_i 为图像的场景类别标记; s_k 为场景划分分段阈值。经过实验验证, 设置 $W=70$, $r_1=0.65$, 将场景划分为 0、1 两类时, 即可实现场景划分的目的, 同时还能保证算法性能。

1.3 自适应边缘检测

根据图像场景识别结果, 首先进行图像预处理, 具体包括图像灰度化、透视变换和感兴趣区域标定等步骤。对经过预处理后的图像进行自适应边缘检测, 以得到含有轨道轮廓曲线特征的二值化图像。

灰度化是指将 RGB 通道的彩色图像转化为单通道的灰度图像, 其转化公式为

$$S = 0.299 \cdot R + 0.587 \cdot G + 0.144 \cdot B \quad (3)$$

式中: S 为单通道灰度值; R 为红色通道灰度值; G 为绿色通道灰度值; B 为蓝色通道灰度值。透视变换的本质是将图像投影到一个新的视平面, 其通用变换公式为

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} \beta_{11} & \beta_{12} & \beta_{13} \\ \beta_{21} & \beta_{22} & \beta_{23} \\ \beta_{31} & \beta_{32} & \beta_{33} \end{bmatrix} \begin{bmatrix} x \\ y \\ z \end{bmatrix} \quad (4)$$

$$\begin{cases} x' = \frac{X}{Z} = \frac{\beta_{11}x + \beta_{12}y + \beta_{13}}{\beta_{31}x + \beta_{32}y + \beta_{33}} \\ y' = \frac{Y}{Z} = \frac{\beta_{21}x + \beta_{22}y + \beta_{23}}{\beta_{31}x + \beta_{32}y + \beta_{33}} \\ z' = \frac{Z}{Z} = 1 \end{cases} \quad (5)$$

式中: (x, y, z) 为原始图像像素点的齐次坐标; (x', y', z') 为经透视变换之后的图像像素点的齐次坐标。

使用 X 方向的 Sobel 算子对经过预处理后的灰度图像进行边缘检测, 期望提取出纵向的轨道轮廓特征。在此过程中, 可通过添加灰度梯度阈值, 剔除部分明显不是轨道轮廓的干扰像素点, 实现对轨道轮廓像素点的粗筛。选择 3×3 大小的卷积核 $H_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$ 与灰度图进行卷积运算, 并对图像中的

每个像素点得到的卷积结果取绝对值, 即得到像素点所在位置的灰度梯度, 在得到每个像素点所在位置的灰度梯度后, 根据场景识别结果, 自适应地选择相应的灰度阈值集合, 对该像素点进行二值化处理, 最终得到边缘检测二值化图像序列。

如图 2 所示为像素点二值化处理的具体方法: 设定一组阈值 (L_v, H_v), 其中 H_v 为高阈值, L_v 为低阈值, 当像素点所在位置的灰度梯度大于 H_v 时 (A 段) 对该点灰度赋值为 255, 当像素点所在位置的灰度梯度小于 L_v 时则对该点灰度赋值为零, 当像素点所在位置的灰度梯度介于 H_v 和 L_v 之间时, 再判断该像素点周围 (8 个像素点) 是否有灰度值为 255 的像素点与之邻接, 若有 (B 段), 则对该像素点灰度赋值 255, 若没有 (C 段), 则对该像素点灰度赋值为零。

多次重复实验表明, 场景 0 灰度梯度阈值组设置为 (10, 30), 场景 1 灰度梯度阈值组设置为 (70, 220) 时, 可以得到较好的关于轨道轮廓特征边缘检测效果。

1.4 基于类滑动窗格的轨道区域边界提取

原始图像经自适应边缘检测后, 得到的二值化图像还存在一些轨道附近设施设备边界的干扰像素点。设计基于类滑动窗格的轨道区域边界搜寻模块, 筛选轨道轮廓候选像素点, 以此滤除轨道附近的干扰像素点。基于类滑动窗格的轨道区域边界搜寻模块在算法的具体实现上分为基于当前帧的滑动窗格搜索和基于历史帧的通带搜索 2 个子模块, 2 种搜索算法旨在搜索边缘检测二值化图像中的轨道轮廓像素点, 并基于搜索到的坐标序列通过最小二乘法

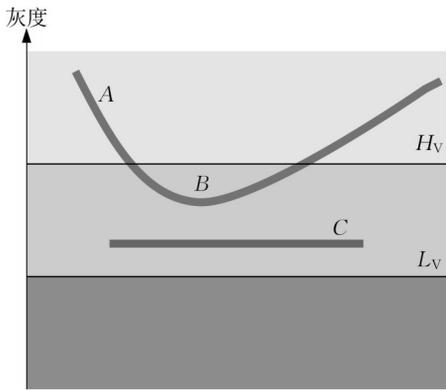


图2 像素点边缘检测二值化处理示意

Fig. 2 Pixel dot binarization process

拟合二次曲线得到最终的轨道曲线。

1.4.1 基于当前帧的滑动窗格搜索

基于当前帧的滑动窗格搜索子模块也是轨道线提取的初始化过程,当算法未接收到轨道线提取的历史帧数据或当历史帧轨道线提取返回失败时,算法即调用滑动窗格搜索子模块。

基于当前帧的滑动窗格搜索子模块算法步骤如下:①人工标定图像下边界处的轨道轮廓中轴线像素点坐标 P_b 作为轨道的生长基点,同时标定图像平行轨道间距 d_t 。②基于标定的轨道下边界生长基点,确定初始滑动窗格位置,具体方式是将基点坐标作为滑动窗格下边缘的中点坐标,并设置滑动窗格的宽度为 S_w ,高度为 S_h 。③根据步骤②确定的初始滑动窗格位置坐标,搜索矩形框内的白像素点(灰度值为 255),并将这些白像素点的图像坐标 P_{ij} 记

录到轨道轮廓候选坐标集合 R 中,同时统计窗格内的白像素点数目 W_n 。④预设窗格内白像素点数目判断阈值 W_N ,比较 W_n 与 W_u 以确定滑动窗格向图像上边缘生长方法。当 $W_n \geq W_u$ 时,计算窗格内所有白像素点横坐标平均值 \bar{x} ,作为下一个滑动窗格下边框中点横坐标,而当窗格内白像素点数目过少($W_n < W_N$)时,不足以用来表示轨道的轮廓特征,则仍以当前窗格的下边框横坐标作为下一个滑动窗格的下边框中点横坐标,滑动窗格每向上生长一次,生长出的新滑动窗格下边框与生长前滑动窗格上边框的纵坐标相同。⑤迭代,滑动窗格向上生长后,重复步骤③和④,直至矩形滑动窗格上边框到达图像上边界处,迭代结束。⑥采用最小二乘法对轨道边界候选坐标序列 R 拟合二次曲线 $x = a_2 y^2 + a_1 y + a_0$,并得到关键参数 (a_0, a_1, a_2) 。由于轨道在较短距离(相机拍摄有效距离 < 200 m)内不会出现驻点,因此采用二次曲线拟合轨道线既符合实际,同时又能提高算法效率。

多次重复实验表明,设置 $S_w = 30$ 、 $S_h = 25$ 、 $W_N = 35$ 时,检测效果最好。

图3a为基于当前帧的滑动窗格轨道轮廓像素点搜索示意图,图像下边界三角点即为标定的轨道生长基点,图3b为一侧搜索结果。可以看出,边缘检测二值化图像中绝大多数干扰像素点均被滤除,通过对搜索到的候选轨道边界坐标集合进行二次曲线拟合,即可得到较为准确的轨道轮廓曲线。

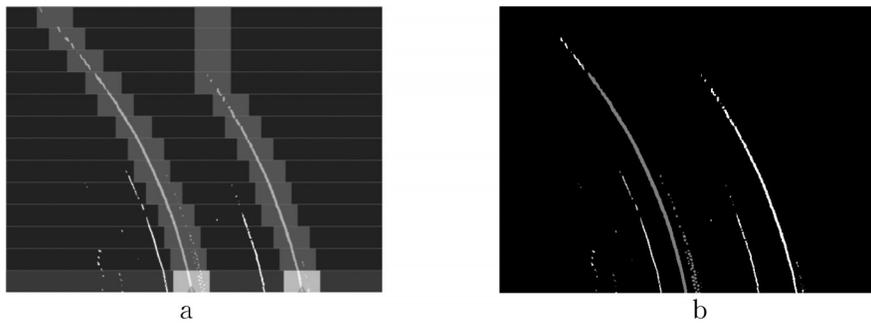


图3 滑动窗格搜索子模块轨道轮廓像素点搜索示意

Fig. 3 Schematic of sliding pane track outline pixel point search

1.4.2 基于历史帧的通带搜索

基于历史帧的通带搜索子模块作为基于当前帧的类滑动窗格搜索子模块的补充,既能保证轨道轮廓候选像素点筛选效果,同时又能一定程度上提升算法检测效率。相机在极短时间内拍摄到的相邻

帧图像中的轨道线坐标不会发生突变,基于此,可在上一帧检测的轨道线临近区域搜索当前帧的轨道轮廓像素点。当算法接收到轨道线提取的历史帧数据时,算法即调用通带搜索子模块。

基于历史帧的通带搜索子模块算法步骤如下:

① 输入上一帧轨道线拟合结果参数 (a_0, a_1, a_2) , 并在当前帧图像中确定上一帧拟合轨道线所在位置 $x = a_2 y^2 + a_1 y + a_0$ 。② 以上一帧拟合的轨道线结果, 分别向图像左侧和右侧平移固定距离 $d_p/2$, 形成一条以上一帧拟合轨道线为中轴线的等宽通带, 通带宽度为 d_p , 本研究设置 $d_p = 30$; ③ 搜索通带在边缘检测二值化图像中所覆盖的白像素点并记录坐

标生成候选坐标集合 R' 。④ 使用最小二乘法对坐标集合 R' 拟合二次曲线 $x = a_2 y^2 + a_1 y + a_0$, 得到关于当前帧的轨道轮廓曲线参数 (a_0, a_1, a_2) 。

图4a为基于历史帧的通带子模块轨道轮廓像素点搜索示意图, 图4b为一侧搜索结果。由图可以看出, 当前帧的轨道轮廓像素点基本被通带覆盖并筛选出来, 而其他的干扰像素点则被滤除。

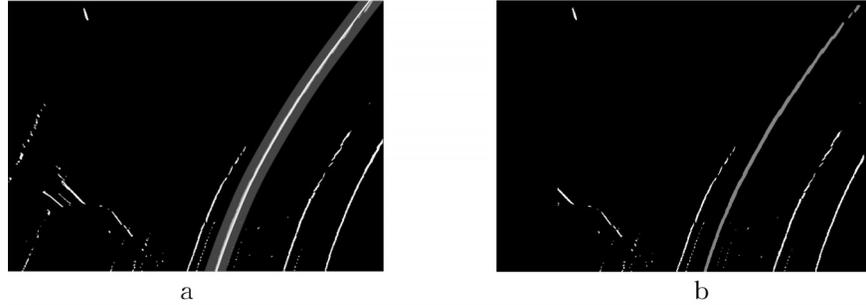


图4 通带搜索子模块轨道轮廓像素点搜索示意

Fig. 4 Schematic of passband track outline pixel point search

1.5 基于卡尔曼滤波的轨道轮廓平滑

得到逐帧的轨道轮廓曲线参数后, 给算法装载滤波模块, 用以降低连续视频帧轨道线提取的波动, 提高轨道轮廓曲线提取的稳定性和可靠性。先后使用中值滤波器、递推平均滤波器、一阶滞后滤波器和卡尔曼滤波器等方法对轨道轮廓曲线进行滤波平滑处理, 实验结果显示卡尔曼滤波器综合效果最优。

卡尔曼滤波器是一种最优化自回归数据处理方法, 具有良好的实时性和准确性, 其基本思想是利用前一时刻状态, 根据状态空间模型, 得到当前时刻估计值, 并结合当前时刻观测值更新对当前状态的估计, 从而得到满足最小均方差的当前状态量^[14]。

针对轨道曲线提取结果滤波所构建的卡尔曼滤波器相关参数如下。轨道曲线的系统动态空间描述为

$$\begin{cases} \hat{x}_t^- = F\hat{x}_{t-1}^- + A\mu_{t-1} \\ y_t = H\hat{x}_t + \gamma \end{cases} \quad (6)$$

卡尔曼滤波状态更新方程为

$$\begin{cases} P_t^- = FP_{t-1}^- F^T + V \\ K_t = \frac{P_t^- H^T}{HP_t^- H^T + M} \\ P_t = (E - K_t H) P_t^- \end{cases} \quad (7)$$

结合动态空间方程的轨道曲线预测结果为

$$\hat{x}_t = \hat{x}_t^- + K_t(y_t - H\hat{x}_t^-) \quad (8)$$

式中: \hat{x}_t^- 为当前时刻预测量; \hat{x}_{t-1} 为上一时刻状态

量; \hat{x}_t 为当前时刻状态量; F 为系统转移矩阵; A 为控制变量矩阵; y_t 为观测量; H 为状态量到观测量的转移矩阵; γ 和 μ_{t-1} 分别为高斯白噪声; K_t 为卡尔曼增益, 又称状态更新矩阵; P_t^- 为预测量 \hat{x}_t^- 的协方差; P_t 和 P_{t-1} 分别为状态量 \hat{x}_t 和 \hat{x}_{t-1} 的协方差; V 和 M 分别为系统预测噪声和测量噪声的协方差矩阵; E 为单位矩阵。卡尔曼滤波器的状态向量为轨道线拟合参数 $[a_2 \ a_1 \ a_0]^T$ 。图5为轨道轮廓曲线提取的卡尔曼滤波示意图。

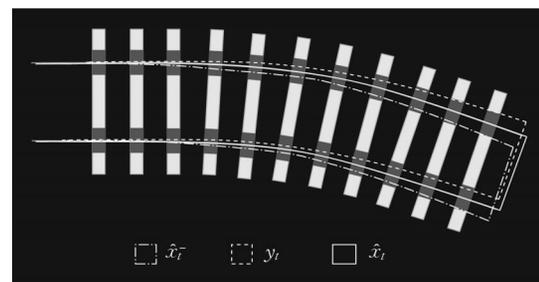


图5 轨道轮廓曲线提取卡尔曼滤波示意

Fig. 5 Schematic of Kalman filter for track outline curve extraction

2 实验验证

2.1 实验数据

为验证本文算法, 在某地铁线路采集了一段列车在地面、高架和隧道运行过程中的视频数据, 视频

帧率为30 fps,分辨率为1 080 p,视频数据的有效帧数为20 270帧。浏览整段视频数据,列车所处的运行场景主要有光照较为充足的高架区间、光照缺乏的隧道区间以及存在明显光影变化的站台区间,视频数据中列车运行时所处的弯道和光照存在明显变化的节点等特殊场景是算法效果验证的重点关注区域。

2.2 实验环境

算法运行的实验平台配置为:CPU Inter(R) Xeon(R) E-2224G, CPU主频3.50 GHz,内存7.6 GiB, GPU NVIDIA GeForce GTX 1030,使用的操作系统为Ubuntu18.04,编程语言为C++。

2.3 实验结果分析

将整段视频数据输入算法进行处理,得到如图

6—8所示的轨道区域检测结果示意图。从整体上看,列车运行过程中各场景下的轨道区域均被准确检测出来,附带的场景识别结果和算法检测帧率也在图像的左上角同步显示出来。图6为光照充足的高架区域检测结果,分别为直道、弯道、道岔区段和轨旁设施设备影响光照4种情况;图7为光照缺乏的隧道区域检测结果,分别为圆形直道、圆形弯道、矩形直道和矩形复杂背景4种情况;图8为站台区域,分别为高架站台驶入、高架站台驶出、隧道站台驶入和隧道站台驶出4种情况。上述检测结果表明,该算法不仅实现了轨道区域分割的目的,而且具备良好的场景适应性,算法在地铁列车运行时所处的高架区域、隧道区域和站台区域等复杂运营环境和背景下都能够准确检测轨道区域。



图6 高架区域检测结果

Fig. 6 Results of elevated area detection

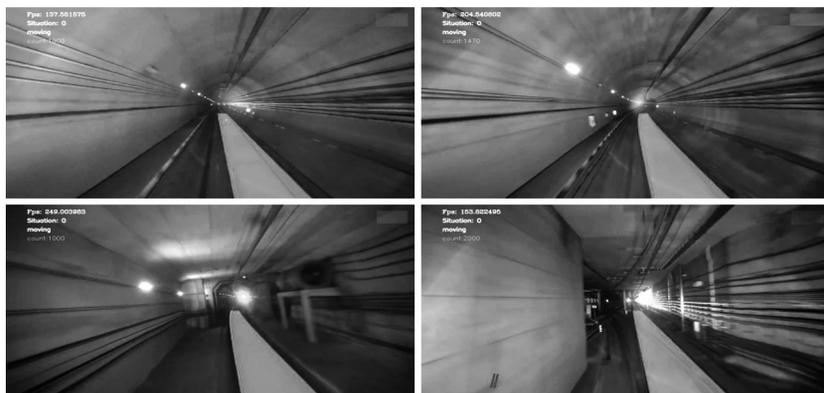


图7 隧道区域检测结果

Fig. 7 Results of tunnel area detection

表1展示了算法对地铁列车运行的不同区间位置、不同场景下的轨道区域检测实验数据,其中场景0和1数量比例显示了不同区域位置的场景划分结果,基本符合高架光照充足、隧道光照缺乏的实验预

期,说明算法达到了良好的场景划分效果;跟踪丢失次数是指算法通带搜索子模块接收历史帧检测数据失败的次数,丢失指数则是指跟踪丢失次数与总帧数比值的百分数值。在本实验中,算法在隧道区间



图8 站台区域检测结果

Fig. 8 Results of platform area detection

内的丢失指数明显高于高架区间,隧道站台的丢失指数略低于隧道区间,高架站台次之,高架区间的丢失指数最低,相应的该区间的轨道区域检测效果最好;丢失重检帧数和检测异常帧数表现出相似分布情况;平均检出率是指准确检测帧数和总帧数的比值,算法对所有复杂运营环境下的轨道区域检出率均高于90%,检测效果良好,对高架区间的检出率

最高,高架站台检出率略低,隧道区间检出率次之,而隧道站台的检出率最低,说明算法在光照存在明暗变化的站台和光照缺乏的隧道区域检出率都有所降低。综合以上实验结果,基于视觉的全自动无人驾驶列车轨道区域检测算法检测效果受光照影响明显,在光照充足的高架区间检测效果最好。

对采集到的视频数据全程进行算法运行时耗分

表1 复杂运营环境下不同场景算法轨道区域检测效率

Tab.1 Efficiency of algorithmic track limit detection for different scenarios in complex operational environments

数据属性	总帧数	区间数	场景0和1数量比例	跟踪丢失次数	丢失指数/%	丢失重检帧数	检测异常帧数	准确检测帧数	平均检出率/%
隧道区间	7 300	22	7 100 : 200	84	1.15	181	240	7 060	96.70
高架区间	4 010	9	70 : 3 940	8	0.2	18	18	3 992	99.50
隧道站台	6 420	21	5 710 : 710	66	1.03	320	461	5 959	92.80
高架站台	2 540	7	220 : 2 320	13	0.51	45	66	2 474	97.40

析,其结果如图9所示,可以看出,该算法单帧图像处理时耗集中分布在4~8 ms,平均时耗约为5.57 ms。将算法运行时耗换算成视频帧率大于100 fps,高于视频数据的原始帧率30 fps,能够满足列车运行时轨道区域实时检测的性能需求。

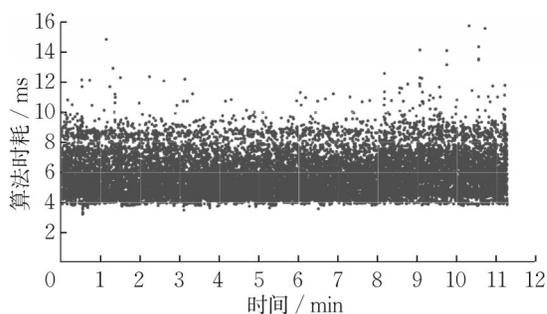


图9 算法运行时耗分析

Fig. 9 Analysis of algorithm runtime consumption

3 结论与展望

提出了一种面向全自动无人驾驶列车的基于视觉传感器的轨道区域检测算法,设计基于类滑动窗格的轨道区域边界搜寻模块搜索边缘检测二值化图像中的轨道轮廓像素点,完成对列车前方轨道区域的检测。主要结论如下:

(1)基于帧间差分阈值和灰度分布特征提取的场景识别算法,完成对视频图像数据的场景特征识别和标记;自适应边缘检测算法基于图像场景识别结果自适应调整参数输入,完成对图像的预处理和轨道轮廓的边缘检测。

(2)基于类滑动窗格的轨道区域检测算法,构建基于当前帧的滑动窗格搜索子模块和基于历史帧的通带搜索子模块搜索轨道轮廓像素点,完成对轨道

轮廓曲线的提取;最后使用卡尔曼滤波器提升检测结果的准确性和鲁棒性,完成对列车前方轨道区域的检测。

(3)实验结果表明,算法在列车运行时所处的各种复杂场景和背景下,其轨道区域检出率均在90%以上,算法平均时耗为5.57 ms,实现了良好的轨道区域检测效果和检测性能。

实验表明算法能够准确、快速、稳定的跟踪检测运行列车前方的轨道区域,并且具有内存占用小、推理延迟短,轻量化的优点,对降低障碍物检测的虚警率,提高异物入侵检测的准确性,保障行车安全,提高列车运行效率具有一定的实际意义。

算法轨道区域检测准确性强依赖于光照条件,后续进一步研究可考虑使用多源传感器融合检测的方式,如使用红外图像与可见光图像融合、雷达点云数据与图像数据融合等方式以提升算法检测的环境适应性和准确性。

作者贡献声明:

盛峰:实验思路构建,初稿撰写。

沈拓:算法思路构建。

谢远翔:算法设计与编程。

张颖:实验验证。

曾小清:算法设计指导。

朱明昌:数据处理。

张轩雄:实验装置设计。

参考文献:

- [1] SONG Haifeng, SHEN Tuo, WANG Weiyang. Train-centric communication-based close proximity driving train movement authority system[J]. IEEE Intelligent Transportation Systems Magazine, 2018, 10(3): 22.
- [2] 沈拓, 钱沿佐, 谢兰欣, 等. 考虑反射强度的全自动运行列车障碍物检测算法研究[J]. 同济大学学报(自然科学版), 2022, 50(1): 6.
SHEN Tuo, QIAN Yanzuo, XIE Lanxin, *et al.* Obstacle detection algorithm of fully automatic train considering reflection intensity[J]. Journal of Tongji University (Natural Science), 2022, 50(1): 6.
- [3] SUAIF A, GANI F Q. Implementation of ultrasonic sensor as a radar for obstacle detection[J]. Andalus Journal of Electrical and Electronic Engineering Technology, 2021, 1(1): 12.
- [4] CHEN Y, ZHU N, WU Q, *et al.* MRSI: A multimodal proximity remote sensing data set for environment perception in rail transit[J]. International Journal of Intelligent Systems, 2022, 37(9): 5530.
- [5] 黄希, 姚连璧, 杨璐璟. 基于移动激光扫描的轨道交通建筑限界一体化检测[J]. 测绘通报, 2023(3): 84.
HUANG Xi, YAO Lianbi, YANG Lujing. Integrated detection of rail transit building limit based on mobile laser scanning[J]. Surveying and Mapping Bulletin, 2023(3): 84.
- [6] 郭保青, 马学志, 余祖俊, 等. 基于PTZ相机极向投影的铁路限界自动识别方法[J]. 铁道学报, 2018, 40(11): 62.
GUO Baoqing, MA Xuezhi, YU Zujun, *et al.* Automatic railway clearance recognition method based on polar projection of PTZ camera[J]. Journal of Railway, 2018, 40(11): 62.
- [7] HE Zhengwei, TANG Peng, JIN Weidong, *et al.* Deep semantic segmentation neural networks of railway scene[C]//2018 37th Chinese Control Conference (CCC). Wuhan: IEEE, 2018: 9095-9100.
- [8] LI Xingxin, Zhu Liqiang, YU Zujun, *et al.* Vanishing point detection and rail segmentation based on deep multi-task learning[J]. IEEE Access, 2020, 8: 163015.
- [9] WANG Yang, ZHU Liqiang, YU Zujun, *et al.* An adaptive track segmentation algorithm for a railway intrusion detection system[J]. Sensors, 2019, 19(11): 2594.
- [10] YE Tao, ZHANG Xi, ZHANG Yi, *et al.* Railway traffic object detection using differential feature fusion convolution neural network [J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(3): 1375.
- [11] 张林, 沈拓, 张轩雄. 城市轨道交通小型障碍物检测[J]. 上海理工大学学报, 2021, 43(5): 468.
ZHANG Lin, SHEN Tuo, ZHANG Xuanxiong. Detection of small obstacles in urban rail transit[J]. Journal of University of Shanghai for Science and Technology, 2021, 43(5): 468.
- [12] GONG Xiao, CHEN Xi, ZHONG Zhangdui, *et al.* Enhanced few-shot learning for intrusion detection in railway video surveillance [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(8): 11301.
- [13] 王洋. 高速铁路场景分割与识别算法研究[D]. 北京:北京交通大学, 2019.
WANG Yang. Research on segmentation and recognition algorithm for high-speed railway[D]. Beijing: Beijing Jiaotong University, 2019.
- [14] 尹爱军, 朱文浩, 戴宗贤, 等. 模糊推理和深度学习数模融合的卡尔曼滤波腐蚀预测[J]. 电子测量与仪器学报, 2023, 37(4): 27.
YIN Aijun, ZHU Wenhao, DAI Zongxian, *et al.* Kalman filter corrosion prediction based on data and physical model fusion driven using fuzzy reasoning and deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(4): 27.