

基于深度学习的动车组制动盘闸片视觉定位检测

管春玲¹ 许迎杰² 宋跃超³

(1. 广州铁路职业技术学院车辆学院, 510430, 广州; 2. 中国铁路广州局集团有限公司广州动车段, 510665, 广州;
3. 北京纵横机电科技有限公司, 100094, 北京)

摘要 [目的] 随着轨道交通行业的不断发展, 其运营规模和安全保障要求不断提高。为了解决动车组制动盘闸片人工检测效率低下、漏检、误检等问题, 有必要研究动车组制动盘闸片视觉定位检测方法。[方法] 提出一种基于深度学习的动车组制动盘闸片视觉定位检测方法; 针对实际场景中图像特征不明显的问题, 以 Faster R-CNN (快速区域卷积神经网络) 算法为基础, 引入边缘检测分支, 同时在损失函数中添加目标边缘损失函数, 合并附加辅助网络的边缘信息。采用双线性插值法计算特征像素值, 保留更多动车组制动盘闸片特征信息。[结果及结论] 所提改进的 Faster R-CNN 模型能够在边缘处进行细节处理, 加快网络的收敛速度, 学习更多动车组制动盘闸片的边缘特征。通过双线性插值法减小了 ROI (检测候选框区域) 池量化过程中目标特征的错位误差。所提闸片检测方法的平均精度为 98.42%, FPS (每秒帧数) 为 27.77%。

关键词 动车组; 制动盘闸片; 定位检测; 深度学习

中图分类号 U279.323

DOI: 10.16037/j.1007-869x.2024.12.011

Visual Positioning Detection of EMU Brake Pad Based on Deep Learning

GUAN Chunling¹, XU Yingjie², SONG Yuechao³

(1. Guangzhou Railway Polytechnic Locomotive & Car College, 510430, Guangzhou, China; 2. China Railway Guangzhou Group Co., Ltd., Guangzhou EMU Depot, 510665, Guangzhou, China; 3. Beijing Zongheng Electro-Mechanical Technology Co., Ltd., 100094, Beijing, China)

Abstract [Objective] With the continuous development of the rail transit industry, its operation scale and safety requirements are constantly increasing. To address the issues of low efficiency, missed and false detections in the manual inspection of EMU (electric multiple unit) brake pads, it is necessary to study visual positioning detection methods for EMU brake pads. [Method] A visual positioning detection method for EMU brake pads based on deep learning is proposed. To address the issue of indistinct image features in real-world scenarios, based on the Faster R-CNN (region convolutional neural network) algorithm, an edge detection branch is introduced,

and a target edge loss function is added to the loss function, integrating edge information from an auxiliary network. Bilinear interpolation is used to calculate feature pixel values, preserving more feature information of the EMU brake pads. [Result & Conclusion] The improved Faster R-CNN model proposed here can handle details at the edges, accelerate network convergence, and learn more edge features of the EMU brake pads. Through the bilinear interpolation method, the misalignment errors of target features during ROI (region of interest) pooling quantization process are reduced. The proposed brake pad detection method achieves an average precision of 98.42% and an FPS (frames per second) of 27.77%.

Key words EMU train; brake pad; positioning detection; deep learning

0 引言

动车组制动盘闸片是动车组制动系统的核心零件, 其在运行过程中可能会出现不同程度的裂纹缺陷及磨损, 严重影响行车安全。因此, 对动车组制动盘闸片的质量进行严格检测具有十分重要的现实意义。

目前, 工业零件缺陷检测方法大致分为传统检测方法和基于深度学习的目标检测方法。传统检测方法是基于人工特征构建的, 通过区域选择分析零件的纹理特征, 并从中提取图片特征, 从而区分缺陷产品和正常产品。文献[1]在检测陶瓷瓦表面裂纹时, 提取陶瓷瓦图片中的红色通道作为预处理图像, 先以图像中的重要成分重构出陶瓷瓦图像, 然后采用二值化算法, 根据裂纹信息检测出裂纹区域。文献[2]采用 SVM (支持向量机) 算法学习汽车刹车蹄块灰度图的特征信息, 并对采集到的图像进行梯度信息提取、灰度共生矩阵计算、有关特征量提取等操作, 最后获得能够区分刹车蹄块正常区域和裂纹区域的数学模型。传统特征检测方法往往受到人为的主观影响, 算法的鲁棒性不强, 此外

还容易受到光照不均等环境因素的影响,进而影响最终的检测性能。

与传统检测方法不同,基于深度学习的目标检测方法无需单独进行图片的手工设计和特征提取,拥有更高的识别精度。Faster R-CNN(快速区域卷积神经网络)算法、YOLO 算法和 SSD(单次多候选框检测)网络算法是深度学习目标检测的代表性算法。文献[3]基于 Faster R-CNN 算法,学习钢铁锻造过程中锻件的裂纹特征,通过各类锻造裂纹图片构建数据集,采用 ResNet50 作为主干特征提取网络,结合 FPN(特征金字塔网络)模块构造,经过训练获得了能够检测裂纹区域的数学模型。文献[4]为了解决伪装目标的检测问题,创建名为 COD10K 的新型数据集,并提出了搜寻识别网络 SINet(自监督内在网络)的 COD(对象对比网络)框架。文献[5]为了解决小样本目标检测问题,提出了含有 Attention RPN(注意力区域候选网络)模块的多重关系检测网络模型。

动车组制动盘闸片视觉定位检测的关键在于,如何准确地检测出制动盘闸片在图像中的位置。虽然目前的检测方法能够实现目标的抓取,但实际运用和检修环境较为复杂,且可能存在目标物互相遮挡的问题。鉴于此,为了解决上述问题,本文提

出一种改进的 Faster R-CNN 模型,通过引入边缘检测分支,利用 Sobel 滤波器学习动车组制动盘闸片的边缘特征,并基于这些特征生成候选方案的最终目标。同时,构造新的损失函数,将边缘检测损失纳入训练过程,去除 ROI(检测候选框区域)池化过程中的量化操作,利用双线性插值保留更多动车组制动盘闸片特征信息。本文的研究目的在于通过对模型加入新的特征分支,提升其在复杂场景中的检测准确性和鲁棒性。

1 改进的动车组闸片检测方法

1.1 动车组制动盘闸片数据集

在轨旁布置 CCD(电荷耦合)照相机,以获取动车组制动盘闸片数据集,如图 1 所示。本文收集了 1 000 张动车组制动盘闸片图像,图像分辨率范围为 1 280 像素 \times 720 像素至 1 920 像素 \times 1 200 像素,其中,700 张图像用于训练网络,300 张图像用于测试网络。为了减少网络训练成本,训练图像被均匀缩放至 515 像素 \times 512 像素。此外,利用标注工具 Labellmg 对图像进行标记,以获得动车组制动盘闸片在图像中的位置和边缘信息。此过程中,不对成像区域不清楚及被遮挡区域超过 75% 的图像进行标记,以确保数据集的正确性。



图 1 动车组闸片数据集


Fig. 1 Dataset of EMU brake pads

1.2 动车组制动盘闸片检测网络

Faster R-CNN 的目标检测过程可分为 3 个阶段:① 将图像输入特征提取网络,以提取特征映射;② 根据上一步中提取的特征映射,由 RPN(区域候选网络)生成多个候选区域;③ 将 RPN 生成的候选区域窗口和特征图像输入 Fast R-CNN,进行检测细化和目标识别。

VOC 2012 数据集包含了较多遮挡、模糊成像的挑战数据,而 COCO 2017 数据集包含了 80 个类别的数据,图像数量庞大,Faster R-CNN 在 VOC

2012 和 COCO 2017 数据集中均呈现出强大的鲁棒性和泛化性能。然而,由于所检测的数据集中,动车组制动盘闸片存在大小不同、图像模糊、特征单一等特点,Faster R-CNN 无法准确检测出动车组制动盘闸片,即出现了错检和漏检的问题。为了解决这一问题,本文在 Faster R-CNN 中添加了一个能够提取动车组制动盘闸片边缘特征的边缘检测层,改进后的 Faster R-CNN 网络结构示意图如图 2 所示。此外,为了进一步提高动车组制动盘闸片的检测精度,本文还改进了 ROI 池化函数和损失函数。



注:VGG 为视觉几何组。

图2 改进后的 Faster R-CNN 网络结构示意图

Fig. 2 Diagram of improved Faster R-CNN network structure

目标边缘通常位于具有较大一阶差分的像素上,在边缘检测中采用 Sobel 算子计算图像的一阶微分。通过计算每个像素上、下、左、右四个邻域的加权灰度值来实现边缘检测,计算过程为:采用两个 3×3 矩阵对输入图像进行加权,分别得到水平和垂直方向上的图像梯度;根据水平和垂直方向上的图像梯度,计算每个像素的梯度值和梯度方向。当某一点的渐变值超过阈值时,则判断该点位于图像的边缘。

图像水平、垂直梯度矩阵,以及图像梯度计算式为:

$$S_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (1)$$

$$S_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (2)$$

$$G = \sqrt{G_x^2 + G_y^2} \quad (3)$$

$$\theta = \arctan\left(\frac{G_y}{G_x}\right) \quad (4)$$

式中:

S_x ——水平梯度矩阵;

S_y ——垂直梯度矩阵;

G ——像素梯度的模;

G_x ——像素水平梯度值;

G_y ——像素垂直梯度值;

θ ——像素梯度方向。

式(3)涉及到增加计算开销的平方和平方根计算,因此,本文优化了梯度值 G 的计算过程,则有:

$$G = |G_x| + |G_y| \quad (5)$$

改进 ROI 池化层将预测目标区域的位置坐标映射到特征图上的相应位置,并通过池化操作生成一个固定大小的特征图,用于后续的目标分类和边界盒回归。

ROI 池化层示意图如图 3 所示。ROI 池化操作步骤为:① 将 ROI 映射到位于特征图上的相应区域;② 将 ROI 平均划分为 $N \times N$ 个区域;③ 对每个区域执行最大池化操作。ROI 池化层在步骤①和步骤②中量化了区域大小,例如,ROI 的大小为 500 像素 \times 480 像素,映射到特征图上的大小为 15.625 像素 \times 15.000 像素。由于像素点是离散的,ROI 被量化到 15 像素 \times 15 像素,这将导致特征错位,进而影

响检测精度。




图 3 ROI 池化层示意图

Fig. 3 Diagram of ROI pooling

为了解决这个问题,本文删去了步骤②的量化操作,并使用双线性插值方案来计算与浮点数对应的像素值。双线性插值示意图如图 4 所示。在 ROI 划分的每个区域采样前 4 个点(见图 4 中圆点),通过式(6)计算每个采样点的像素值,选取像素值中的最大值作为该区域的输出值,则有:

$$f(x, y) = [1 - x \quad x] \begin{bmatrix} f_1 & f_2 \\ f_3 & f_4 \end{bmatrix} \begin{bmatrix} 1 - y \\ y \end{bmatrix} \quad (6)$$

式中:

$f(x, y)$ ——采样点的像素值;

f_1, f_2, f_3, f_4 ——特征图最近的 4 个像素点;

x ——区域相对横坐标;

y ——区域相对纵坐标。




图 4 双线性插值示意图

Fig. 4 Diagram of bilinear interpolation

1.3 损失函数

Faster R-CNN 方法的损失函数 $L_{\text{Faster R-CNN}}$ 包括 RPN 损失 L_{RPN} 和 Fast R-CNN 损失 $L_{\text{Fast R-CNN}}$, 则有:

$$L_{\text{Faster R-CNN}} = L_{\text{RPN}} + L_{\text{Fast R-CNN}} \quad (7)$$

Sobel 滤波网络的边缘检测方案示意图如图 5 所示。网络的输入是对象的预测和真实数据边界框与一组 Sobel 滤波器卷积,以确定预测和真实数据边界框之间的边缘差。最后,利用均方误差计算两个边界框之间的误差,得到边缘检测损失函数 L_{edge} 。




图 5 Sobel 滤波网络的边缘检测方案示意图

Fig. 5 Diagram of Sobel filtering network edge detection plan

因此,本文提出的 Faster R-CNN 模型方法的总损失函数 L 为:

$$L = L_{\text{RPN}} + L_{\text{Fast R-CNN}} + L_{\text{edge}} \quad (8)$$

2 试验和结果

所提改进的 Faster R-CNN 模型旨在提高复杂环境下的动车组制动盘闸片检测性能,为了提高模型的检测精度,本文采用 1.1 节中介绍的数据集。

2.1 试验设置

1) 试验参数:利用 i9-9900KF CPU(中央处理器)和 Nvidia GeForce RTX 3090 GPU(图形处理器)进行训练和测试,操作系统为 Ubuntu 18.04,深度学习框架为 PyTorch 1.6。训练参数设置如下:批次大小为 50,批量大小为 8,初始学习率为 0.005(随着学习率调度器中的训练时代而进行调整),在学习率调整策略中的步长设为 5。

2) 评价标准:对于动车组制动盘闸片检测,通常需通过计算 TP(真阳性)、FN(假阴性)和 FP(假阳性)获得 PR(召回率)和精度,然后基于精度、PR、AP(平均精度)和处理时间等参数进行评价。PR 用于表征测试结果的完整性,而精度用于表征测试结果的准确性。

2.2 结果分析


为了说明该方法的检测性能,将改进的 Faster R-CNN 模型与 4 种深度学习方法进行对比,其主干模型和损失函数如表 1 所示,其中 MSE 为均方误差。

训练的轮数是影响深度网络性能的一个因素,充分训练历元保证了整个训练过程的收敛性,可以在特定的参数配置下获得最佳的网络性能。本文采用 50 个循环周期。训练期间,不同计算方法网络训练的训练集损失值和测试集精度对比,如图 6 所示。


表 1 不同计算方法的主干模型与损失函数

Tab. 1 Mainstream model and loss function of different calculation methods

模型名称	主干模型	损失函数
SSD	VGG-16	MSE
YOLO-V3	Darknet-53	MSE
Faster R-CNN	VGG-16	MSE
RetinaNet	ResNet-50	Focal Loss
改进的 Faster R-CNN	VGG-16	MSE



a) 损失值



b) 检测精度

图 6 不同计算方法网络训练的训练集损失值和测试集精度对比

Fig. 6 Comparison of training set loss values and accuracy in test set network training of different calculation methods

均低于 0.05。对于 Faster R-CNN 模型和 SSD 模型而言,在 50 个循环周期后的精度约为 0.95 和 0.87,但其损失值较 RetinaNet 模型和本文所提改进的 Faster R-CNN 模型更大。而 YOLO-V3 模型在 50

个循环周期后的精度最低,约为 0.80;其损失值最大,约为 3.2。

不同样本下,不同计算方法的动车组制动盘闸片检测结果,如图 7 所示。试验中,将交并比阈值设

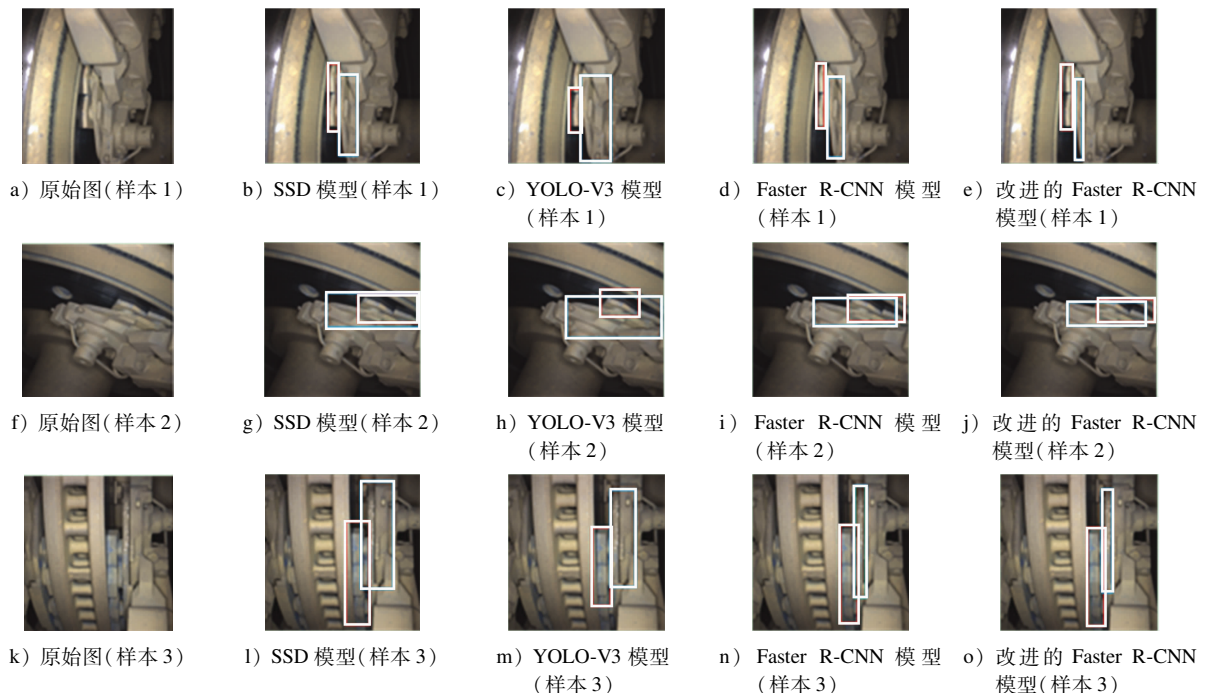


图 7 不同样本下不同计算方法的动车组制动盘闸片检测结果

Fig. 7 Detection results of EMU brake pads of different samples using different calculation methods

为 0.5, 以确保可信的动车组制动盘闸片检测。各模型均能大致定位出动车组制动盘闸片的所在位置。针对检测结果的细节进行分析时, 在样本 1 和样本 2 中, YOLO-V3 模型对动车组制动盘闸片的检测不完整, 仅检测到动车组制动盘闸片的部分内容。针对动车组制动盘闸片连接处的识别, SSD 模型和 YOLO-V3 模型的定位偏差较大, Faster R-CNN 模型虽然能够大致定位, 但动车组制动盘闸片及连接处的整体检测效果不如本文所提改进的 Faster R-CNN 模型。综上所述, 与 Faster R-CNN 模型、SSD 模型和 YOLO-V3 模型相比, 本文所提改进的 Faster R-CNN 模型对于动车组制动盘闸片的检测更准确, 鲁棒性更好, 适合用于不同现场环境下的动车组闸片检测。

为了验证所提 Faster R-CNN 模型在整个动车组制动盘闸片数据集上的检测有效性, 本文对测试集上的试验结果进行了定量评价。不同计算方法的 AP(0.5) (AP(0.5) 表示预测结果与真实结果的重合率为 0.5) 和 FPS (每秒帧数) 如表 2 所示。本文所提改进的 Faster R-CNN 模型的 AP(0.5) 为 0.984, 高于其他计算方法。由此可知, 本文所提改

进的 Faster R-CNN 模型可以更准确地检测图像中的动车组制动盘闸片。此外, 虽然本文所提改进的 Faster R-CNN 模型的 FPS 为 27.77%, 低于 SSD 模型和 YOLO-V3 模型, 但其与 Faster R-CNN 模型的 FPS 较接近, 并略高于 Faster R-CNN 模型的 FPS 值, 能够满足实际应用的需求。

表 2 不同计算方法的 AP(0.5) 和 FPS

Tab. 2 AP (0.5) and FPS with different calculation methods

模型	测试集图片数量/张	主干模型	AP(0.5)	FPS/%
SSD	100	VGG-16	0.904	37.81
YOLO-V3	100	Darknet-53	0.824	44.29
Faster R-CNN	100	VGG-16	0.941	26.36
改进的 Faster R-CNN	100	VGG-16	0.984	27.77

2.3 消融试验

为了研究边缘检测和改进的 ROI 池化方案对动车组制动盘闸片检测精度的影响, 本文对比了 Faster R-CNN、Faster R-CNN + 边缘检测, 以及 Faster R-CNN + 改进 ROI 池化层 3 种检测方法的消融试验结果, 如图 8 所示。对于样本 1 和样本 3, Faster




图 8 不同样本下 3 种模型的消融试验结果

Fig. 8 Ablation test results of three models under different samples

R-CNN 检测方法出现了遗漏检测的情况,而 Faster R-CNN + 边缘检测方法和 Faster R-CNN + 改进 ROI 池化层检测方法均准确地检测出所有的动车组制动盘闸片。对于样本 2,虽然所有检测方法都存在一些错误检测,但 Faster R-CNN + 边缘检测方法和 Faster R-CNN + 改进 ROI 池化层检测方法的错误检

测情况更少。3 种检测方法的评价指标如表 3 所示。加入边缘检测和改进 ROI 池化层后,AP(0.5)提高了约 2%,漏检率分别下降了约 1.7% 和 1.3%,误检率分别下降了约 1.3% 和 1.5%。由此可知,边缘检测和改进 ROI 池化层可以提高动车组制动盘闸片的检测精度。

表 3 3 种检测方法的评价指标

Tab. 3 Evaluation indicators of 3 types of detection methods

模型	测试集图片数量/张	主干模型	AP(0.5)	漏检率	误检率	FPS/%
Faster R-CNN	100	VGG-16	0.941	0.052	0.058	26.36
Faster R-CNN + 边缘检测	100	VGG-16	0.953	0.035	0.045	26.45
Faster R-CNN + 改进 ROI 池化层	100	VGG-16	0.965	0.039	0.043	26.72

此外,为了探究边缘检测分支对网络训练损失值和收敛性的影响,对比了 Faster R-CNN 和 Faster R-CNN + 边缘检测方法的 RPN 损失值及收敛行为。不同检测方法的 RPN 损失值与循环周期间的关系,如图 9 所示。Faster R-CNN 检测方法的 RPN 初始损失值约为 2.47, Faster R-CNN + 边缘检测方法的 RPN 初始损失值约为 0.87。随着循环周期的增加, Faster R-CNN + 边缘检测方法的 RPN 损失值迅速减小,大约稳定在第 8 个循环周期,最终收敛值约为 0.027; Faster R-CNN 检测方法的 RPN 损失值减小较慢,约稳定在第 16 个循环周期,最终收敛值约为 0.513。由此可知,添加边缘检测分支可以有效加快网络训练的收敛性,减少网络的整体损失。




图 9 不同检测方法的 RPN 损失值与循环周期间的关系

Fig. 9 Relation between RPN loss values and cycles with different detection methods

3 结语

本文提出一种改进的 Faster R-CNN 模型,其扩展了 Faster R-CNN 方法,包含一个边缘检测分支及改进的 ROI 池化层和边缘损失函数。考虑到动车


组制动盘闸片周边部件密集和相互遮挡导致的错误或遗漏检测问题,使用 Sobel 滤波器构造一个边缘检测分支,将附加辅助网络的边缘信息合并到网络中。所提改进的 Faster R-CNN 模型能够在边缘处进行细节处理,加快网络的收敛速度,学习更多动车组制动盘闸片的边缘特征。此外,通过双线性插值法减小了 ROI 池化层量化过程中目标特征的错位误差。与 Faster R-CNN 模型、YOLO-V3 模型、SSD 模型相比,本文所提改进的 Faster R-CNN 模型的平均精度为 98.42%,FPS 为 27.77%。

参考文献

- [1] PAPAGEORGIOU C P, OREN M, POGGIO T. A general framework for object detection[C] // Sixth International Conference on Computer Vision. New York: IEEE, 1998: 555.
- [2] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C] // 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). New York: IEEE, 2005: 886.
- [3] 刘建红. 基于深度学习的锻造裂纹检测研究[J]. 大型铸锻件, 2020(5): 47.
LIU Jianhong. Forging crack detection research based on deep learning[J]. Heavy Casting and Forging, 2020(5): 47.
- [4] 李强, 曾曙光, 郑胜, 等. 基于机器视觉的陶瓷瓦表面裂纹检测方法[J]. 激光与光电子学进展, 2020, 57(8): 51.
LI Qiang, ZENG Shuguang, ZHENG Sheng, et al. Machine vision based detection method for surface crack of ceramic tile[J]. Laser & Optoelectronics Progress, 2020, 57(8): 51.
- [5] 黄永华, 林振衡, 陈学军. 一种基于 SVM 的刹车蹄块片摩擦块表面裂纹检测法[J]. 延边大学学报(自然科学版), 2019, 45(2): 175.

(下转第 80 页)

在事件触发控制协议下,每列跟随列车在不同运行时间下触发的控制输入更新次数示意图,如图6所示。该虚拟编组列车系统控制有效地排除了Zeno行为,相比于时间触发机制,有效降低了各列车间的通信压力。



注:图中每个点表示每列跟随列车更新1次。

图6 每列跟随列车在不同运行时间下触发的控制输入更新次数示意图

Fig.6 Diagram of number of control input updates triggered by each following train at different running times

5 结语

本文针对虚拟编组列车控制系统,考虑存在扰动的情况下,提出一种基于事件触发的分布式控制器,跟随列车可在事件触发时刻与领航列车进行信息交互,有效地减少了通信压力,节约了资源。应用Lyapunov稳定性理论对虚拟编组列车进行了稳定性证明,同时排除了Zeno行为。仿真结果表明,所提算法可以使跟随列车有效控制自身状态,并与领航列车的速度保持一致,且每列列车之间的间距保持稳定,进而形成稳定的虚拟编组队形。

参考文献

- [1] SCHUMANN T. Increase of capacity on the shinkansen high-speed line using virtual coupling[J]. International Journal of Transport Development and Integration, 2017, 1(4): 666.
- [2] FELEZ J, KIM Y, BORRELLI F. A model predictive control approach for virtual coupling in railways[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(7): 2728.
- [3] 荀径,陈明亮,宁滨,等. 虚拟重联条件下地铁列车追踪运行性能衡量[J]. 北京交通大学学报, 2019, 43(1): 96.
XUN Jing, CHEN Mingliang, NING Bin, et al. Train tracking performance measurement under virtual coupling in subway[J]. Journal of Beijing Jiaotong University, 2019, 43(1): 96.
- [4] 曹源,温佳坤,马连川. 重大疫情下的列车动态编组与调度[J]. 交通运输工程学报, 2020, 20(3): 120.
CAO Yuan, WEN Jiakun, MA Lianchuan. Dynamic marshalling and scheduling of trains in major epidemics[J]. Journal of Traffic and Transportation Engineering, 2020, 20(3): 120.
- [5] 张志雄,杨凯军. 具有避碰和保持连通的多智能体鲁棒编队控制[J]. 电光与控制, 2022, 29(8): 28.
ZHANG Zhixiong, YANG Kaijun. Robust formation control of multi-agent systems with collision avoidance and connection preservation[J]. Electronics Optics & Control, 2022, 29(8): 28.
- [6] 申通,唐晔,李立. 基于事件触发机制的自主车辆队列协同控制[J]. 计算机应用研究, 2021, 38(3): 792.
SHEN Tong, TANG Ye, LI Li. Consensus for autonomous vehicle platoon system via event-triggered control[J]. Application Research of Computers, 2021, 38(3): 792.
- [7] BOYD S, EL GHAOU L, FERON E, et al. Linear Matrix Inequalities in System and Control Theory[M]. Philadelphia: Society for Industrial and Applied Mathematics, 1994.
- [8] 施维嘉. 基于事件触发的多智能体编队控制应用研究[D]. 南京:南京信息工程大学, 2022.
SHI Weijia. Application research of multi-agent formation control based on event triggering[D]. Nanjing: Nanjing University of Information Science & Technology, 2022.
- [9] 李建雄. 面向动态编组和紧密追踪的虚拟编组列控方法研究[D]. 北京:北京交通大学, 2021.
LI Jianxiong. Research on virtual marshalling train control method for dynamic marshalling and close tracking[D]. Beijing: Beijing Jiaotong University, 2021.

· 收稿日期:2023-05-24 修回日期:2023-07-05 出版日期:2024-12-10
Received:2023-05-24 Revised:2023-07-05 Published:2024-12-10
· 通信作者:魏文景,硕士研究生,1163223601@qq.com
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

(上接第74页)

HUANG Yonghua, LIN Zhenheng, CHEN Xuejun. A surface crack detection method for friction block of brake pad based on SVM[J]. Journal of Yanbian University (Natural Science Edition), 2019, 45(2): 175.

· 收稿日期:2023-11-27 修回日期:2024-03-28 出版日期:2024-12-10

Received:2023-11-27 Revised:2024-03-28 Published:2024-12-10
· 第一作者:管春玲,副教授,gclbgs@163.com
通信作者:宋跃超,高级工程师,songyuechao22@163.com
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license