

基于 YOLOv5 的网联汽车迁移学习智能装调方法

王汝艮, 张胜宾, 车志, 颜奕政

(广东交通职业技术学院, 广东 广州 510650)

摘要: 在智能网联汽车产业迅速发展的背景下, 车辆装调的智能化水平已成为衡量行业竞争力的重要标志。智能装调作为智能网联汽车故障诊断流程中的关键环节, 其效率与精度直接影响整车智能排故的准确性与实效性。为满足智能装调对高效率、高精度的要求, 提出一种基于 YOLOv5 的迁移学习智能装调方法。该方法充分利用 YOLOv5 模型在目标检测任务中的高效性与准确性, 结合迁移学习在降低数据依赖、提升泛化能力方面的优势, 使模型能够快速适应智能装调场景的特定需求。经实验室装调数据集验证, 该方法仅经过 10 次迭代训练后即可达到 98% 的识别准确率, 充分证实了其有效性与优越性。

关键词: 智能装调; 深度学习; 小样本; 迁移学习

中图分类号: TP181; U466

文献标识码: A

An Intelligent Assembly and Adjustment Method for Connected Vehicles Using the Transferred YOLOv5 Model

WANG Rugen, ZHANG Shengbin, CHE Zhi, YAN Yizheng

(Guangdong Communication Polytechnic, Guangzhou 510650, Guangdong, China)

Abstract: Under the background of the rapid development of the intelligent connected vehicle industry, the intelligence level of vehicle assembly and adjustment has become an important indicator of industry competitiveness. As the key of the fault diagnosis process for intelligent connected vehicles, the efficiency and accuracy of intelligent assembly and adjustment directly affect the accuracy and effectiveness of intelligent troubleshooting for the entire vehicle. To meet the high efficiency and high accuracy requirements of intelligent assembly and adjustment, this paper proposes an intelligent assembly and adjustment method for connected vehicles using the transferred YOLOv5 model. This method combines the efficiency and accuracy of the YOLOv5 model in object detection tasks with the advantages of transfer learning in reducing data dependence and improving generalization ability, enabling the model to adapt to the specific needs of intelligent assembly and adjustment scenarios quickly. The results on a laboratory assembly and adjustment dataset show that the proposed method achieves a 98% recognition accuracy after only 10 iterations of training, verifying the effectiveness and superiority of the proposed method.

Key words: intelligent assembly and adjustment; deep learning; few shot; transfer learning

随着汽车产业向电动化、智能化、网联化转型, 传统人工经验与孤立设备的装配调试模式已无法满足复杂车载系统高效精准排故需求。智能装调方法融合人工智能、物联网等技术, 可高效

检测车载核心部件, 提升生产效率与装配质量、降低成本, 对网联汽车智能制造、排故意义重大^[1]。网联汽车集成大量智能硬件与复杂软件, 故障具有“多源性、关联性、隐蔽性”特征, 传

收稿日期: 2026-01-13

作者简介: 王汝艮, 讲师, 博士, 研究方向为工业大数据分析、智能运维、人工智能

基金项目: 广东交通职业技术学院青年科研启动基金项目(自然科学)(编号: GDGP-ZX-2025-073-N1); 职业院校运输类专业智能座舱实训课程产教融合教学方法研究(编号: JYYSJZW2025A23); 2026 年国家级职业教育教师教学创新团队特色项目-汽车制造与试验技术(编号: ZM-A-04-26-10101)

统人工排查成本高、定位难、标准化程度低,且核心部件(如激光雷达)的校准依赖人工经验^[2]。

目前,智能装调相关研究主要集中在网联汽车技术课程的教学改革领域^[3],而网联汽车相关的排故方法研究,则重点聚焦于动力电池^[4-5]以及旋转零部件^[6-7]等部件的故障诊断技术。相比之下,针对网联汽车智能装调在具体实施过程中的研究较为匮乏。YOLO系列模型以“端到端”架构平衡检测速度与精度,YOLOv5作为经典迭代版本,经网络结构优化等设计迭代,提升了小目标检测性能和模型泛化能力,广泛应用于工业检测等领域^[8]。它无须复杂图像预处理,可直接输出目标信息,适配装调多目标、动态化检测需求,推动装调自动化升级。但网联汽车装调场景专业性强,构建全覆盖标注数据集成本高、周期长,难以满足生产需求。迁移学习技术能有效解决此难题,它将预训练模型在通用数据集的通用特征迁移至特定任务,仅需少量标注样本就能微调适配,不仅降低数据成本,提升小样本场景下检测精度与收敛速度,还能增强模型对复杂环境的适应力^[9],为装调质量监控提供技术支撑。

基于上述背景,本文结合YOLOv5模型与迁移学习技术,搭建了一种YOLOv5的迁移学习模型,并将其应用于网联汽车智能装调过程。该方法以预训练的YOLOv5模型作为初始化模型,以实验室所采集的装调数据集为训练集,逐层设置学习率,以动态调整模型损失的方式对YOLOv5模型进行微调,由此得到最终的智能装调诊断模型。本文的主要贡献如下:

(1) 搭建了一种YOLOv5的迁移学习智能装调模型,实现了装调故障的智能模式识别。

(2) 通过装调数据集验证了前述方法在收敛性与识别精度上的优越性及其在实际应用中的有效性。

1 迁移学习智能装调方法

在目标检测领域,YOLO系列算法在各类复杂环境中均展现出较强的鲁棒性,在复杂工况下的光照变化场景中以及远距离小目标识别任务中均表现出良好的检测效果。其中,YOLOv5在检测速度与精度之间取得了良好平衡,也是目前应用最广泛的版本之一^[10]。该模型的网络结构如图1所示,主要由输入层、骨干网络、颈部结构和预测层组成。本研究采用YOLOv5s作为基础模

型,原因在于该模型的规模适中、计算效率高,能够满足实时推理和部署需求,最常用于工业场景中。




图1 YOLOv5 模型结构

为快速适配特定分类任务的数据集,通常会尽可能减少训练数据量以缩短训练周期。迁移学习作为一种机器学习技术,核心逻辑是将在某一任务上训练完成的模型,迁移至另一相关任务中复用。借助该技术,可将原有任务积累的知识迁移到新任务场景,无须使用大规模数据集从零开始训练,在保障模型性能的前提下,实现对有限训练数据的高效利用。

本研究借助迁移学习技术,以预训练YOLOv5s模型为基础(该模型已在包含80个类别、超20万张标注图像的通用数据集上完成训练),直接加载该预训练模型的权重参数,通过微调模型所有网络层参数,在较小变动范围内快速适配网联汽车装调数据集,大幅提升模型训练效率与适配效果。

2 智能装调模型的训练

迁移学习可以将某一任务上训练完成的模型应用于另一相关任务。通过这种方式,模型可将源任务中学习到的知识迁移到新的目标任务中,从而在仅使用少量标注数据的情况下快速构建适用于智能装调诊断的模型。在本研究中,保留YOLOv5模型的全部预训练权重,并在特定装调数据集上进行参数更新。图2展示了基于YOLOv5的迁移学习装调方法流程。

首先,模型在源任务(X_s, Y_s),即COCO数据集上完成训练,得到源任务的识别模型 $M(X_s, \theta_s)$,及其初始化参数 $\theta_s = (\theta_{i,s}, i=1, 2, \dots, N_p)$,其中 N_p 为模型迭代次数。这些源参数对特征提取具有重要作用,能够帮助模型在目标任务(X_t, Y_t)中更快地学习新的特征表示,从而提升对装调场景的适应性。

加载源任务的预训练参数 θ_s ,在目标数据集




图 2 模型训练过程

(装调数据集, (X_T, Y_T)) 上进行全局微调, 以损失值 $Loss < l_k$ 或迭代次数 $Epoch < e_k$ 为停止条件, 使用梯度下降法不断调整模型参数:

$$\begin{cases} \theta_{i,s} = \theta_{i,s} - \eta_{i,s} \frac{\partial \mathcal{L}}{\partial \theta_{i,s}} \\ \theta_{i,t} = \theta_{i,t} - \eta_{i,t} \frac{\partial \mathcal{L}}{\partial \theta_{i,t}}, \text{ (若 } i \neq 0, \theta_{i,t} = \theta_{i,s} \text{)} \end{cases} \quad (1)$$

式中, $\eta_{i,s}$ 、 $\eta_{i,t}$ 的取值分别为:

$$\begin{cases} \eta_{i,s} = 0.01 \\ \eta_{i,t} = 0.01 \times 0.1^{\text{int}(\frac{\xi}{8})} \end{cases} \quad (2)$$

式 (2) 中, ξ 表示网络层数, 其系数取值为 1/8, 以保证学习率呈逐级递减的趋势。

模型训练过程的总体损失函数定义为:

$$\mathcal{L} = \alpha L_{cls} + \beta L_{obj} + \gamma L_{CloU} \quad (3)$$

式中, α 、 β 、 γ 为可学习性参数, L_{cls} 、 L_{obj} 、 L_{CloU} 分别为类别损失、置信度损失、定位损失^[11]。

终止训练后得到适配目标任务的模型参数及最终识别模型 $M(X_T, \theta_T)$, $M(X_T, \theta_T)$ 可实现装调任务的故障模式识别。

3 试验验证

3.1 数据集设置

智能装调实验台如图 3 所示, 其核心组件包括米文计算平台、惯导、交换机、电台等, 这些组件分别承担着感知强化、定位校准、数据调度、通信互联的关键功能, 精准排查这些核心组件的故障, 对保障智能驾驶系统的稳定运行具有重要意义。

结合工作人员的实操经验, 本研究共设置了 11 种典型故障类型, 每种故障类型包含 200 个样本。数据集按训练集与测试集 7 : 3 的比例划分, 即每种故障类型的训练集样本为 140 个、测试集样本为 60 个, 数据集具体见表 1。




图 3 智能装调实验台

表 1 数据集设置

故障类型	标签	#训练样本	#测试样本
电台无天线	no tianxian		
电台无 DB9 插头	no DB9		
电台无电源线	no power		
米文无 HDMI 线	no HDMI		
米文无网线	no wangxian		
米文无集成线束 1	no jcxsl	140	60
米文无集成线束 2	no jcxsl2		
惯导无定向天线	no GNSS1		
惯导无定位天线	no GNSS2		
惯导无 4G 天线	no 4G		
惯导无集成线束	no dianlan		

3.2 模型性能评估

本次实验运行环境如下: 所用工作站搭载 Windows 10 Pro 64 位操作系统、第 13 代英特尔酷睿 i7-13600HX 处理器, 12G 显存的 NVIDIA GeForce RTX 4060 Ti 显卡, 深度学习框架采用 Pytorch v2.8.0, 编程语言为 Python 3.13。评估指标采用平均识别精度。

图 4 展示了使用随机初始化参数的模型 (对比方法) 和本文所提迁移学习方法的训练过程的损失及其诊断精度。从图 4 (a) 中可以看出, 随着迭代次数的增加, 两种模型的三种损失都呈现下降趋势, 后逐渐趋于稳定 (收敛); 在相同的迭代次数下, 所提方法的各项损失 (定位损失、类别损失、置信度损失) 普遍低于对比方法的对应损失, 且所提方法的损失下降更快、最终稳定值更低, 说明其训练效率优于对比方法。从图 4 (b) 中可看出, 在整个迭代过程中, 所提方法的精度始终高于对比方法, 这表明所提方法在迭代初期就能快速提升精度, 收敛速度更快, 能够更快达到较好的性能水平。




图4 对比方法与所提方法训练过程的比较

4 结论

为提高网联汽车智能装调准确性与高效性,提出了一种基于YOLOv5模型的网联汽车迁移学习智能装调方法,该方法在训练过程中只需要较少的标签数据、较短的训练时间,即可实现较高的故障识别精度。所提方法首先调用已训练好的YOLOv5模型进行智能装调的初始化,再采用已收集的装调数据作为训练集,并对各层模型的学习率及动态调整损失权重进行迭代优化。在网联汽车装调实验台上验证了该方法的有效性,评价指标表明该方法能够在更少的迭代次数(10代)内趋于稳定,并达到相对较高的精度(98%),未来的研究将致力于模型泛化能力的提升。

参考文献:

- [1] 朱冰,党瑞捷,赵健,等. 智能汽车冗余电控制动系统电流传感器故障容错控制[J]. 中国公路学报, 2023, 36(4): 249-260.
- [2] 贾宏颖,李玉峰. 智能网联汽车一体化安全问题与内生安全[J]. 电信科学, 2024, 40(12): 15-29.
- [3] 罗建辉. 人工智能与“岗课赛证”融合的高职智能控制技术专业课程实施路径探索:以“智能控制系统集成与装调”课程为例[J]. 湖南教育(D版), 2025(11): 37-39.
- [4] ZHANG C, TU L, YANG Z, et al. A CMMOG-based lithium-battery SOH estimation method using multi-task learning framework [J]. Journal of Energy Storage, 2025, 107:114884.
- [5] SEO Y, KIM T, BARDE S. Enhancing battery SOH prediction with butler-volmer informed neural networks in data-scarce environments[J]. Energy, 2025:138316.
- [6] HE D, ZHANG Z, JIN Z, et al. RTSMFFDE-HKRR: a fault diagnosis method for train bearing in noise environment[J]. Measurement, 2025, 239:115417.
- [7] TAO L, LIU H, NING G, et al. LLM-based framework for bearing fault diagnosis[J]. Mechanical Systems and Signal Processing, 2025, 224:112127.
- [8] 候欣耀,曾昊,彭靖波,等. 基于改进YOLOv11的航空发动机叶片多模态多尺度损伤高精度检测技术[J/OL]. 推进技术, 1-17.
- [9] THUKRAL M, HARESAMUDRAM H, PIOETZ T. Cross-domain HAR: few-shot transfer learning for human activity recognition[J]. ACM Transactions on Intelligent Systems and Technology, 2025, 16(1): 1-35.
- [10] SAPKOTA R, KARKEE M. Ultralytics YOLO evolution: an overview of YOLO26, YOLO11, YOLOv8 and YOLOv5 object detectors for computer vision and pattern recognition[EB/OL]. (2025-10-07) [2026-01-13]. <http://arxiv.org/abs/2510.09653>.
- [11] REDMON J, DIVVALA K S, GIRSH B R, et al. You only look once: unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.

(上接第56页)

- [11] 任思儒,李郇,陈婷婷. 改革开放以来粤港澳经济关系的回顾与展望[J]. 国际城市规划, 2017, 32(3): 21-27.
- [12] 何斌,史凯旋,刘菁. 粤港澳大湾区陆路口岸旅客通关模式优化研究[J]. 港澳研究, 2024(2): 82-92, 96.
- [13] 谭泽芳,周军,黄嘉俊,等. 深圳市跨界交通调查理论与技术研究[J]. 城市交通, 2025, 23(2): 106-116.
- [14] 胡一冰,胡家琦,许项东,等. 考虑群体行为异质性的深港跨界口岸交通需求模型[J]. 交通与运输, 2024, 40(4): 8-13.
- [15] 深圳市规划和自然资源局. 2024年深港莞惠跨界交

- 通调查[R]. 深圳:深圳市规划和自然资源局, 2024.
- [16] 香港规划署. “北往南来”:二零一七年年跨界旅运统计调查[R]. 香港:香港规划署, 2018.
- [17] 李锋. 通过规划审核和综合决策完善轨道交通客流预测[J]. 城市交通, 2009, 7(1): 26-30.
- [18] 胡明伟,史其信,牛永宁. 深港西部通道过境交通量预测的比较研究[J]. 道路交通与安全, 2009, 9(3): 45-48.
- [19] 姚展鹏. 香港回归前后重大项目规划政策比较:以机场及高铁为例[D]. 北京:清华大学, 2011.