

基于 CAN 数据和图像数据融合算法的 商用车能量智能优化系统

彭旺, 梁丰收, 文李华, 郭琪, 卢逸飞

(比亚迪汽车工业有限公司, 广东深圳 518118)

摘要:针对当前纯 CAN 数据和纯图像数据的不足,提出基于 CAN 数据和图像数据融合算法,并根据该算法输出的 8 种工况和特征开发能量智能优化系统。仿真分析表明,该能量智能优化系统能有效地节约能量。

关键词:纯电商用车; CAN 数据; 图像数据; 融合算法; 能量优化

中图分类号:U461.8

文献标志码:A

文章编号:1006-3331(2024)02-0006-05

Intelligent Optimization System of Commercial Vehicle Energy Based on CAN Data and Image Data Fusion Algorithm

PENG Wang, LIANG Fengshou, WEN Lihua, GUO Qi, LU Yifei

(BYD Automotive Industry Co., Ltd., Shenzhen 518118, China)

Abstract: In view of the shortcomings of current pure CAN data and pure image data, this paper proposes an algorithm based on the fusion of CAN data and image data, and develops an energy intelligent optimization system based on the 8 working conditions and characteristics by the algorithm output. The simulation analysis shows that the energy intelligent optimization system can effectively save energy.

Key words: pure electric commercial vehicle; CAN data; image data; fusion algorithm; energy optimization

目前,混合动力汽车的能量分配策略、制动能量再回收和高效能量管理系统已有大量研究。文献[1]借助交通平台获取预行驶路段道路信息,制定对应路段的速度曲线,实现电池 SOC 轨迹规划的能量管理策略。文献[2]基于 PSO-BP 神经网络的能耗等级辨识驾驶风格。文献[3]基于双模混合动力车辆通过 K 均值聚类算法识别平稳工况和快变工况,从而制定能量优化策略。文献[4]采用自组织映射神经网络和灰狼算法,离线识别行驶工况。

上述文献^[1-4]均采用单一的数据进行工况、驾驶风格和道路场景识别,并制定能量优化策略,鲜有采用多种数据融合算法来制定车辆控制策略以实现节能的研究。本文基于 CAN 数据和图像数据融合算

法,开发一种用于提升纯电动车续航里程的能量智能优化系统。

1 CAN 数据和图像数据的融合算法

1.1 融合算法框架

在基于 CAN 数据的驾驶风格和场景识别分析的基础上,为更精确分类和预测道路工况,本文加入了前向单目图像数据进行道路场景识别和拥堵识别。两种数据的融合算法框架如图 1 所示。融合算法通过接收 CAN 数据和前向单目摄像数据,使用两种算法(CAN 数据算法和图像数据算法)实时输出驾驶风格、道路场景和拥堵情况等数据,再通过这些数据的融合构建能量优化工况库。

收稿日期:2024-03-14。

基金项目:国家重点研发计划项目(2021YFB2501700)。

第一作者:彭旺(1982—),男,高级工程师;主要从事新能源商用车设计研发工作。E-mail:peng.wang@byd.com。

通讯作者:文李华(1991—),男,博士;主要从事新能源汽车智能驾驶感知算法研发工作。E-mail:wen.lihua@byd.com。

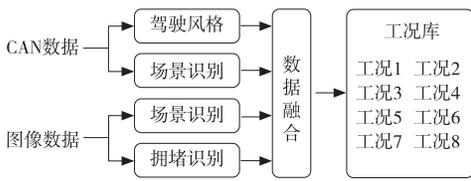


图 1 CAN 数据和图像数据融合算法框架

1.2 CAN 数据算法

CAN 数据中包含众多车辆行驶时的数据, 本文仅解析车速、加速踏板深度(对应加速度)和制动踏板深度(对应减速度)3 种数据用于驾驶风格(激进型和保守型)和道路场景识别(城市和高速)算法的开发。算法框架如图 2 所示。

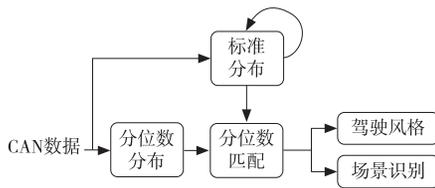


图 2 CAN 数据算法框架

其中“分位数分布”表示一段时间内某个变量的统计情况。以分析速度的变化情况为例, 具体操作是对 60 s 内速度的连续监测值排序, 然后在每十分之一的位置取一个值, 总共选取 10 个值用于表示这段时间内的速度特征。该方法的优点是能表示一段时间内数值的整体情况且稳定性强。如果使用“直方分布图”等方法也能达到类似统计效果, 但当速度集中在某个区间时, 直方分布图的利用效率低, 而统计分位数分布则不受此影响。

本文对行驶速度、加速度和减速度三类 CAN 数据进行实时的分位数分布统计, 并用两个分支进行处理: 历史 CAN 数据用于构建、迭代优化标准分布库; 实时 CAN 数据提取当前分位数分布, 通过对比标准分布, 判断驾驶风格和道路场景。

为了计算标准分位数分布, 设计了如下迭代优化流程: ①估测一个标准分布作为初始值; ②根据当前的标准分布对已有历史数据分类; ③根据置信度较高的分类结果, 重新估计一个标准分布; ④重复②~③直至结果收敛。

实时判断时, 计算当前分位数分布和工况标准分布之间的“欧氏距离”, 从而计算出驾驶风格类别(概

率 P_j) 和场景类别(概率 P_{CAN})。

1.3 图像数据算法

图像数据可以提供丰富的道路环境和交通状况等视觉信息, 比单纯的 CAN 数据更加直观和稳定。利用图像数据, 可以获取车前的实时道路场景和拥堵情况, 其算法框架如图 3 所示。

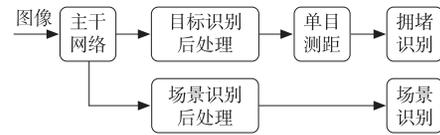


图 3 图像数据算法框架

图像数据算法使用主干神经网络(图 3 中简称主干网络)提取图像特征^[5-8]。其目标识别后处理和场景识别后处理模块接收主干神经网络输出的图像特征, 根据后面任务(拥堵识别和场景识别)的不同, 设计不同的算法。为使算法效率和精度满足实时性要求, 本文选用像素为 224×224 的图像, 利用 YOLOv7 (You Only Look Once)^[9]中的主干神经网络算法提取图像中的特征, 输出特征图像的像素(有效特征数)为 28×28。下面介绍两个后处理模块的算法。

1.3.1 拥堵识别后处理模块

该模块首先进行目标识别。在图像坐标系下获得目标类别和目标框参数 (x, y, w, h) , 其中 (x, y) 代表目标框中心点在图像中的坐标, (w, h) 代表目标框的宽度和高度, 如图 4 所示。目标类别包括: 车辆(客车、货车、专用车和自行车)和行人。单目摄像测距模块基于目标识别结果, 利用单目测距返回一个角度和距离, 进行目标距离计算、车前目标计数和方向角计算。该算法模块接收摄像机相关参数和目标框参数 (x, y, w, h) , 输出目标的距离(在摄像机坐标系 O_c 下), 计算过程如下。

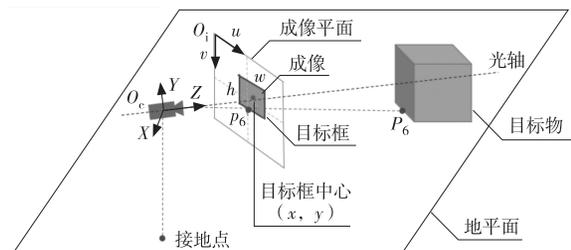


图 4 单目成像及单目测距原理图

1) 4中涉及3个坐标系:世界坐标系 O_w 、摄像机坐标系 O_c 和图像坐标系 O_i 。其中 O_w 和 O_c 为同一坐标系,原点在摄像机中心, X 轴为水平方向, Y 轴为垂直方向, Z 轴为摄像机光轴方向; O_i 坐标系的原点在成像平面的左上角点, u 、 v 分别为成像平面的水平方向和垂直方向。摄像机固定在客车中控台仪表台中间位置,挡风玻璃后,摄像机镜头朝前,离地高度1.5 m。

2) 以地面上任意一点(P_6 点)为例,单目测距模块旨在求出其成像所对应的像素点 p_6 在摄像机坐标系 $O_c(O_w)$ 下的三维位置(X_6, Y_6, Z_6),其计算公式为:

$$\begin{bmatrix} X_6 \\ Y_6 \\ Z_6 \\ 1 \end{bmatrix} = Z_c \begin{bmatrix} \mathbf{R} & \mathbf{t}_{\text{cam}} \\ 0 & 1 \end{bmatrix}^{-1} \begin{bmatrix} f_u & 0 & u_0 & 0 \\ 0 & f_v & v_0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}^{-1} \begin{bmatrix} u_6 \\ v_6 \\ 1 \end{bmatrix} \quad (1)$$

式中: Z_c 为摄像机的深度值; u_0 和 v_0 分别代表摄像机成像平面主点在图像坐标系 u 和 v 轴方向上的坐标值, \mathbf{R} 和 \mathbf{t}_{cam} 分别代表摄像机的旋转矩阵和平移向量, f_u 、 f_v 分别表示焦距在 u 和 v 轴方向上的分量;矩阵中的“1”用于补位构成齐次矩阵。

3) 通过式(1)可获得点 P_6 在 O_c 坐标系下的三维坐标信息,进而可计算出目标点 P_6 与摄像机之间的距离。由于摄像机安装高度固定,因此只需计算该距离在地面上的投影大小 d :

$$d = \sqrt{X_6^2 + Y_6^2} \quad (2)$$

4) 在摄像机坐标系 O_c 下的 XZ (即水平)平面,计算目标点 P_6 与摄像机光轴在水平面上的夹角(即为目标点 P_6 的方向角),用于确定目标点所在车道位置。

$$\theta = \arctan(X_6/Z_6) \quad (3)$$

5) 拥堵识别。假设车道宽2.5 m,旁车道以2 m宽的小车为目标,则若上述计算出的 $\theta \leq |10^\circ|$,说明前方目标与本车在同一车道,此时若上述计算出的 $d \leq 0.5$ m(也可设定为其他合适值),则判定为拥堵场景;若上述计算出的 $\theta \geq |80^\circ|$,说明前方目标在本车的左或右边车道,此时若上述计算出的 $d \leq 2.8$ m(与

前面的0.5 m相关联),则判定为拥堵场景;其他的定义为非拥堵场景。拥堵场景输出概率 $P_y = 1$,非拥堵场景输出概率 $P_y = 0$ 。

1.3.2 道路场景识别

基于前述 224×224 像素图像的道路场景识别算法,将主干神经网络输出的 28×28 像素的图像特征馈入场景识别的后处理模块进行道路场景(城市道路和高速道路)识别。神经网络演绎一般分为两个阶段:神经网络训练阶段和神经网络推理阶段。

1) 神经网络训练阶段。将已有的上万张图像的每一张,根据道路环境(多车道和路面状况等)和是否有除车辆以外的其他目标(人、骑车的人等)等特征,人工标注一个高速道路场景或城市道路场景标签,再将带标签的图像送入神经网络,用于训练神经网络的参数。

2) 推理阶段。车辆行驶中实时拍摄的未带标签的道路图像被输入到上述训练好的神经网络,用于提取图像中的道路特征,最后通过激活函数层输出两个道路特征概率值,如果高速道路场景特征多,则高速道路场景的概率值大于城市道路场景的概率值,反之亦然。

道路场景识别后处理模块算法的具体过程如下:

1) 3层卷积层。卷积层用于神经网络进一步提取像素为 28×28 的图像特征,输出像素为 28×28 的卷积特征图像,为后续提供更准确的特征(点、线、面、形状等)。

2) 1个 2×2 池化层。该层又称为下采样层,旨在将像素为 $n \times n$ (如前所述,本文 n 取值28)的卷积特征图像,通过下采样降为 $n/2 \times n/2$ (即 14×14)像素的特征图。

3) 1个Resize层。将上述 $n/2 \times n/2$ 像素的特征图像按行排为 $n/2 \times n/2$ 的一维向量,用于下一步中全连接层采用一维卷积神经网络提取图像特征。

4) 一个全连接层。全连接层用一维卷积神经网络进一步提取上一步的 $n/2 \times n/2$ (即 $14 \times 14 = 196$ 个数据)的一维向量中的两个特征,并输出对应的两个数值 z_1 和 z_2 (z_1 代表高速道路场景, z_2 代表城市道路场景)。

5) 一个激活函数层。激活函数层接受全连接层输出的两个数值构成一个向量 $\mathbf{z} = [z_1, z_2]$, 然后输入到激活函数(Softmax)按式(4)求出各自的占比, 其中高速道路为 P_1 , 城市道路为 P_2 , 如式(5)所示。如果高速道路场景值的占比大, 则识别为高速道路场景, 反之则识别为城市道路场景。

$$P_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (4)$$

式中: P_i 是向量 \mathbf{z} 中第 i 个元素经过 Softmax 函数后的值; e 是自然对数的底; K 是总的道路场景数, 本文取值 2。

$$P_1 = \frac{e^{z_1}}{e^{z_1} + e^{z_2}}, P_2 = \frac{e^{z_2}}{e^{z_1} + e^{z_2}} \quad (5)$$

1.4 数据融合算法

融合算法根据融合阶段的不同可分为: 前融合、特征融合和结果融合^[10]。本文属于工况识别结果的融合, 结果融合的算法有: 对应数值直接取均值、数值取最大值和数值串联。本文采用取均值方法融合基于 CAN 数据识别的结果和基于图像数据识别的结果。

现结合图 1 描述数据融合的具体方法。CAN 数据算法分别输出驾驶风格类别(保守、激进)的概率 P_j 和道路场景识别(城市、高速)的概率 P_{CAN} ; 图像数据算法分别输出道路场景识别(城市、高速)的概率 P_t 和拥堵识别(拥堵、非拥堵)的概率 P_y 。数据融合模块对基于 CAN 数据算法输出的道路场景识别概率 P_{CAN} 和基于图像数据算法输出的道路场景识别概率 P_t 进行融合计算, 以确定最终道路场景和道路场景的概率 P_a , 公式见式(6)。

$$P_a = \begin{cases} P_{CAN}, P_{CAN} > P_t (\text{场景不同}) \\ P_t, P_{CAN} \leq P_t (\text{场景不同}) \\ \frac{P_{CAN} + P_t}{2} (\text{场景相同}) \end{cases} \quad (6)$$

1) 当两种方法输出的场景不同时, 最终道路场景为概率较大值所对应的场景; P_a 取两种算法中的较大值(如果两值相等, P_a 取 P_t 的值, 但实际上这两个值不可能完全相等)。

2) 当两种方法输出的场景相同时, 最终道路场景为两者所对应相同场景; P_a 取 P_{CAN} 和 P_t 的均值。

将融合计算出的 P_a 及 CAN 数据计算出的驾驶风格的概率 P_j 和图像数据计算出的拥堵场景的概率 P_y 对应的特征进一步融合在一起, 用于构建工况库, 工况库包含 8 种工况: 保守-城市-拥堵, 保守-城市-非拥堵, 保守-高速-拥堵, 保守-高速-非拥堵, 激进-城市-拥堵, 激进-城市-非拥堵, 激进-高速-拥堵, 激进-高速-非拥堵。每种工况对应的概率值和特征输入到本文第 2 部分(能量智能优化系统)进行仿真, 获取扭矩曲线用以控制加速踏板和制动踏板开度。

本文采用的融合算法具有以下特点:

- 1) 输入数据包含 CAN 数据和前向单目图像数据, 数据丰富、互补, 结果更稳定。
- 2) 拥堵识别和场景识别算法采用主干神经网络提取图像特征, 进行驾驶风格、拥堵识别和场景识别, 通过后融合使得算法的性能更具有鲁棒性。

2 能量智能优化系统

本文设计的能量智能优化系统, 旨在车辆通过识别上述 8 种行驶工况, 自动控制车辆加速踏板和制动踏板开度(0 代表开度最小, 1 代表开度最大), 以实现最佳性能和电机效率的平衡。纯电商用车智能优化系统主要分为三大模块: 驾驶员信息采集模块、目标多状态扭矩控制模块和扭矩输出模块。

1) 驾驶员动作采集模块。该模块的主要功能是采集加速踏板、制动踏板的状态与开度信息和前向单目图像信息。模块传感器采集的数据通过 CAN 数据和图像融合算法获得 8 种工况特征, 算法详见第 1 部分。

2) 目标多状态扭矩控制模块。该模块结合 8 种工况信息的概率值(P_a 、 P_j 和 P_y) 和最后的特征, 兼顾动力性、安全性、舒适性和经济性, 通过 Simulink 仿真分析获得 8 种工况对应的 3 种扭矩曲线。这 3 种扭矩曲线及其功能如下:

① 驱动状态下的车速-加速踏板开度-驱动扭矩曲线: 根据车速和加速踏板开度, 生成最优的驱动扭矩曲线, 以实现理想的动力性能。

② 松油门回馈状态下的车速-加速踏板开度-松油门回馈扭矩曲线: 当驾驶员放开加速踏板时, 根据

车速和加速踏板开度,生成松油门回馈扭矩曲线,以保证车辆平稳过渡并提供舒适的驾驶体验。

③制动回馈状态下的车速-制动踏板开度-制动回馈扭矩曲线:当制动踏板被踩下时,根据车速和制动踏板开度,生成制动回馈扭矩曲线,以提供安全的制动性能并减少制动时的不适感。

3) 扭矩输出模块。根据第1部分算法输出的实时工况(8种工况之一),智能匹配实时工况对应的3种扭矩曲线。随后,扭矩输出模块在驱动电机与驱动桥的扭矩加、卸载速率规定范围内,智能地确定当前状态电机输出扭矩的加载、卸载速率。最终,该模块智能控制车辆扭矩的输出,实现对车辆能量的智能优化。通过优化扭矩输出,车辆能够在不同工况下高效地利用能量,从而降低能源消耗、提高车辆效率,并改善整体驾驶体验。

3 效果分析

经过数据采集和预处理,算法模型建立阶段可用的有效数据数量为:摄像机数据约31万张,CAN数据约260万条,具体见表1。两种数据分为训练数据和预测数据,比值为7:3。

表1 有效数据详情

工况	图像数据	CAN数据
城市	204 326	1 649 721
高速	116 652	1 012 352
总计	310 978	2 662 073

基于在深圳九月(最低温度22℃,最高温度38℃)采集的上述多场景数据,应用Simulink进行商用车能量流管理的动力控制仿真分析^[11]。通过仿真获得8种工况对应的3种扭矩曲线,用于车辆智能控制加速踏板和制动踏板的开度,以达到节能的目的。某12m纯电客车搭载本文设计的能量智能优化系统后,车辆根据仿真获得的扭矩曲线智能控制加速踏板和制动踏板的开度,再进行能耗仿真分析,能耗结果见表2,节能效果提升了7.2%。表中涉及11段不同驾驶风格、不同道路场景和不同拥堵情况的数据,数据总里程超过5000km。

表2 搭载能量智能优化系统前后能耗对比

数据集	能耗/[(kW·h)·100 km ⁻¹]		性能提升比/%
	优化前	优化后	
数据1	47.30	44.69	5.51
数据2	41.13	38.68	5.96
数据3	62.80	61.18	2.58
数据4	37.19	36.32	2.34
数据5	51.07	47.53	6.93
数据6	41.85	40.70	2.70
数据7	41.58	40.21	3.30
数据8	46.71	42.43	9.15
数据9	51.79	47.17	8.91
数据10	57.93	54.07	6.65
数据11	47.40	44.07	7.03
总和	50.03	47.33	7.24%

4 结束语

本文基于CAN数据和图像融合算法得到8种工况及其对应的概率和特征,通过Simulink建模与仿真,获取8种工况对应的扭矩曲线,最终构建了端对端的能量智能优化系统。通过对大量实车仿真工况进行分析,本文设计的能量智能优化系统可使12m纯电客车综合节能7.2%。未来工作中,将进一步研究纯电动商用车基于更多数据源融合的能量智能优化系统,包括不同数据的融合方法和能量智能优化系统。

参考文献:

- [1] 刘春娜. 基于工况识别和多目标优化的PHEV能量管理策略研究[D]. 济南:山东大学,2022.
- [2] 李沛润. 基于驾驶风格的纯电动汽车制动能量回收优化控制策略研究[D]. 盐城:盐城工学院,2023.
- [3] 丁峰,王伟达,项昌乐,等. 基于行驶工况分类的混合动力车辆速度预测方法与能量管理策略[J]. 汽车工程,2017,39(11):1223-1231.
- [4] 郭志奇. 基于行驶工况感知的四驱PHEV自适应优化能量管理策略研究[D]. 长春:吉林大学,2023.

整车性能仿真分析指标主要关注续驶里程、能量消耗率和最高车速等。经济性主要以 CCBC 循环工况和 40 km/h 等速工况续驶里程作为评价指标^[10], 经仿真分析两种工况续驶里程分别为 444.2 km 和 590.1 km, 满足设计要求; 动力性能仿真最高车速为 98 km/h, 满足最高车速不低于 70 km/h 的设计要求; 最大爬坡度 14.5% 满足厦门 BRT 实际路况需求。

3 结束语

该纯电动铰接客车经实车运营验证, 乘客出行体验良好, 其行驶操纵稳定性、舒适性及维修性等得到了较高的评价。本文为纯电动铰接客车提供了一种有效的设计思路。

参考文献:

- [1] 梁浩. 我国快速公交系统发展特征研究[J]. 江苏科技信息, 2022, 39(27): 78-80.
- [2] 快速公交这十年——快速公交研究会 2020 年度工作报告(内容节选)[J]. 人民公交, 2021(1): 34-36.
- [3] 张斯阳, 盛志前, 曹雄超, 等. 快速公交与其他公共交通方式比选及融合发展[J]. 城市交通, 2022, 20(3): 55-63.
- [4] 张伟. 大型后驱铰接式系列客车底盘的研究和开发[J]. 汽车实用技术, 2012(6): 25-28.
- [5] 张利新, 刘逸群, 明杰婷. 纯电动城市客车动力系统匹配设计及仿真分析[J]. 客车技术与研究, 2022, 44(3): 15-18.
- [6] 陈笃廉. 一种纯电动客车用弓式充电系统[J]. 福建农机, 2017(3): 35-38.
- [7] 徐威, 夏修龙. 新能源客车的自动充电系统设计[J]. 中国新技术新产品, 2020(9): 18-20.
- [8] 曾志俊. XML6125JEV 纯电动城市客车中置后驱底盘设计开发[J]. 客车技术与研究, 2016, 38(1): 14-16.
- [9] 中华人民共和国公安部. 机动车安全技术检验项目和方法: GB 21861—2014[S]. 北京: 中国标准出版社, 2015: 9.
- [10] 李廷朋, 封进, 张瑞宾, 等. 纯电动客车动力系统参数匹配与仿真分析[J]. 机电工程技术, 2022, 51(9): 170-173.
- [5] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016: 779-788.
- [6] LIU Wei, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox Detector [C] // European Conference on Computer Vision, 2016: 21-37.
- [7] GIRSHICK R. Fast R-CNN [C] // 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015: 1440-1448.
- [8] REN Shaoqing, HE Kaiming, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal Networks [J]. in IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [9] WANG Yaochien, BOCHKOVSKIY A, LIAO M H Y. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C] // 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver, BC, Canada, 2023: 7464-7475.
- [10] WEN Lihua, JO Kang-Hyun. Deep learning-based perception systems for autonomous driving: a comprehensive survey [J]. Neurocomputing, 2022(489): 255-270.
- [11] 王自强, 严运兵. 纯电动商用车能量回收策略优化[J]. 农业装备与车辆工程, 2024, 62(1): 39-44.

(上接第 10 页)