

基于模糊神经网络的车辆运行状态 多维智能监测方法研究

范文明^{1†}, 马宏伟², 杨晓峰²

(1. 国能铁路装备有限责任公司, 北京 100010; 2. 天津哈威克科技有限公司, 天津 301799)

摘 要: 车辆自动驾驶领域, 其运行状态数据种类较多, 特征模糊化明显, 难以准确采集, 导致车辆运行状态监测存在准确度低、精度低、时效慢等问题。为此, 提出了基于模糊神经网络的车辆运行状态多维智能监测方法。首先, 通过多传感器采集车辆运行状态数据, 并使用自适应加权平均算法对采集到的数据实行融合处理; 其次, 通过自适应遗传算法和浮动搜索算法, 获取车辆运行状态多融合数据的最优特征子集; 最后, 将车辆运行状态最优特征子集输入至模糊神经网络模型完成车辆运行状态多维智能监测。实验结果表明, 所提方法能够实现对减速、正常、加速、抗蛇行四种车辆运行状态的准确监测, 且对车辆运行状态的监测时效高, 适用于实际应用。

关键词: 车辆运行状态监测; 多传感器; 自适应加权平均算法; 最优特征子集; 模糊神经网络模型
中图分类号: TP391 **文献标识码:** A

Research on Multi-Dimensional Intelligent Monitoring Method for Vehicle Operation Status Based on Fuzzy Neural Network

FAN Wenming^{1†}, MA Hongwei², YANG Xiaofeng²

(1. China Energy Railway Equipment Limited Liability Company, Beijing 100010, China;
2. Tianjin Hveic Technologies Co., Ltd., Tianjin 301799, China)

Abstract: In the field of vehicle autonomous driving, there are many types of operating status data, with obvious feature fuzziness and difficulty in accurately collecting, which leads to problems such as low accuracy, low accuracy, and slow time efficiency in vehicle operating status monitoring. Therefore, a multi-dimensional intelligent monitoring method for vehicle operation status based on fuzzy neural network is proposed. Firstly, vehicle operating status data is collected through multiple sensors, and the collected data is fused using an adaptive weighted average algorithm. Secondly, by using adaptive genetic algorithm and floating search algorithm, the optimal feature subset of vehicle operating state multi fusion data is obtained. Finally, the optimal feature subset of vehicle operation status is input into the fuzzy neural network model to complete multi-dimensional intelligent monitoring of vehicle operation status. The experimental results show that the proposed method can achieve accurate monitoring of four vehicle operating states: deceleration, normal, acceleration, and anti hunting, and has high monitoring efficiency for vehicle operating states, making it suitable for practical applications.

Key words: vehicle operation status monitoring; multiple sensors; adaptive weighted average algorithm; optimal feature subset; fuzzy neural network model

随着工业技术的发展,汽车被广泛应用于人们的生活之中,交通事故威胁着人民生命健康,在智能汽车领域,车辆运行状态实时监测,保障车辆的安全运行一直是研究的重点问题之一。车辆在长时间运行过程中,由于受外界因素的影响,如路面状况、气候等,或者是车辆本身零部件的老化、磨损等原因,会导致车辆运行状态不稳定和出现异常状况。这些异常情况可能严重影响车辆的行驶安全和稳定性,如何获取高精度、高准确性的车辆运行状态智能监测方法,成为目前智能汽车领域研究的重点^[1,2]。

当前已有相关领域研究学者对车辆运行状态多维智能监测方法作出了研究。门元昊等^[3]首先采集车辆运行数据信息,并合并成可表达车辆状态的特征子集;其次,通过 XGBoost 算法学习车辆运行状态关系;最后,通过 XGBoost 模型完成车辆运行状态监测。该方法存在车辆运行状态监测准确度低的问题。王剑等^[4]首先通过自适应卡尔曼滤波方法获取车辆的位置信息和方向预测;其次,通过长短期记忆方法更新车辆预测实时模型;最后,通过组合预测 VB 捕获方法完成车辆运行状态监测。该方法存在车辆运行状态监测精确度不高的问题。田祥宏等^[5]首先设计船舶状态运行监测模型;其次,通过 RW-LSSVR 方法获取船舶参数;最后,通过参数辨识实现船舶运行状态监测。该方法存在运行状态监测时间长的问题。

车辆自动驾驶领域,其运行状态数据种类较多,特征模糊化明显,难以准确采集,导致车辆运行状态监测存在准确度低、精度低、时效慢等问题,提出基于模糊神经网络的车辆运行状态多维智能监测方法研究。

1 多传感器车辆运行数据采集及融合

通过多传感器采集车辆运行状态数据,并使用自适应加权平均算法实行多数据融合处理^[6-7]。该算法首先从每个传感器的预处理数据中提取车辆运行状态特征,利用自适应加权平均算法为每个传感器设置初始权值,根据数据质量评估结果,更新每个传感器的权值。根据更新后的权值对各个传感器的数据进行加权平均。可以使用简单的加权平均公式来计算融合后的结果,作为最终的数据融合结果。

通过 ADXL345 加速度传感器、DHT12 温湿度传感器采集车辆在运行过程中湿度、温度、车速、

转速、加速度数据信息^[8-9]。使用适用于数据融合的自适应加权平均算法对同个环境内通过多个传感器采集到的环境多源信息实行融合处理。

用 $c_1, c_2, \dots, c_n$ 表示多传感器的数据采集量,对每个传感器进行性能评估,包括精度、准确性、稳定性、噪声水平等指标,通过对传感器性能的分析 and 比较,初步确定传感器的权值。并用 $\xi_1, \xi_2, \dots, \xi_n$ 表示传感器权值,在同一环境、同一时刻, n 个传感器同时采集车辆运行状态数据,状态数据融合后权值 $\bar{c}$ 公式表达如下:

$$\bar{c} = \sum_{a=1}^n \xi_a \times c_a \quad (1)$$

其中, c_a 表示传感器采集的数据, ξ_a 表示某传感器的加权值, a 表示时刻。进一步推导出多传感器同时采集车辆运行状态数据融合的特征向量 $T(a)$, 公式表达如下:

$$T(a) = c_a 2 \sum_{a=1}^n \frac{\bar{c}^2}{\xi_a} \quad (2)$$

根据多传感器采集数据的无偏估计可知,每个传感器采集的车辆运行状态数据均为独立存在。进一步推导出状态数据融合特征均方误差最小时传感器的加权值公式,表达如下:

$$\xi_a^* = \frac{1}{\sum_{a=1}^n T(a)^2}, a = 1, 2, \dots, n \quad (3)$$

最后获取多传感器车辆数据融合结果如下:

$$\zeta = \frac{\sum_{a=1}^n T(a)}{\xi_a^*}, a = 1, 2, \dots, n \quad (4)$$

本文采集车辆运行过程中湿度、温度、车速、转速、加速度数据信息,提取的特征是一个 5 维向量,则融合后特征也将是一个 5 维向量。基于此,完成车辆运行状态数据的采集与融合处理。

2 最优车辆运行状态特征数据子集计算

若直接使用上一节获取的车辆运行状态多融合数据完成车辆运行状态监测,则存在数量过多不利于监测效率和大量冗余数据干扰监测准确性的问题,故通过自适应遗传算法和浮动搜索算法提取车辆运行状态数据的最优特征子集,以提高车辆运行状态监测性能^[10,11]。

在完成车辆运行状态多融合数据的选择时,通常存在对数据参数子集和数据参数边界实行搜索的两种情况,故使用内外两层循环的方式完成车辆运行状态多融合数据的最优特征子集选择。外环

通过自适应遗传算法对车辆运行状态数据的边界搜索以生成多融合数据特征参数全局,内环通过浮动搜索算法进一步对获取的多融合数据特征参数实行最优特征子集的选择。外环为全局搜索,内环为局部搜索。选用数据参数边界 b_1 、 b_2 、 b_3 、 t_1 、 t_2 、 s_1 、 s_2 作为自适应遗传算法的优化参数,再对其实行约束。自适应遗传算法目标函数公式表达如下:

$$g_1 = A_v A_q (E_s T_{acc} + E_G M_{sw} - \zeta)$$

(5)

其中, E_s 表示识别准确度权重, T_{acc} 表示识别准确度, E_G 表示数据参数子集中参数个数的权重, M_{sw} 表示数据参数子集的数据个数, A_v 表示交叉概率, A_q 表示变异概率。

自适应遗传算法通过选择、杂交和变异来模拟车辆运行状态多融合数据的自然选择过程。通过轮盘赌模型选择车辆运行状态多融合数据的特征数据信息。交叉概率 A_v 公式表达如下:

$$A_v = \begin{cases} \frac{g_{best} - g_o}{g_{best} - g_{avg}}, g_o > g_{avg} \\ 1, g_o \leq g_{avg} \end{cases}$$

(6)

其中, g_{best} 表示最高个体适应度, g_{avg} 表示平均适应度, g_o 表示交叉的两个个体中较高的适应度。变异概率 A_q 公式表达如下:

$$A_q = \begin{cases} 0.3 \frac{g_{best} - g_o}{g_{best} - g_{avg}}, g_o > g_{avg} \\ 0.3, g_o \leq g_{avg} \end{cases}$$

(7)

对适应度较小的车辆运行状态数据个体,使用固定概率实行交叉和变异操作;对适应度较大的车辆运行状态数据个体,使用小概率实行交叉和变异操作,获取车辆运行状态多融合数据全局特征参数。分析车辆运行状态多融合数据全局特征参数可知,车辆运行状态数据间具有类似性,故使用个体间遗传和种群间遗传两种方法获取浮动搜索的起始点。

种群间遗传的浮动搜索算法:评价根据遗传算法获取的车辆运行状态数据的特征参数子集,并将获取的最优子集遗传下去,通过浮动搜索在新的种群生成后,选择上一个种群作为起始点,获取车辆多融合数据的最优特征子集。个体间遗传的浮动搜索算法步骤如图 1 所示。

完成遗传算法后,评价车辆融合数据的最优特征子集,若该子集优于原子集,则取代原子集,并遗传下去;如该子集不优于原子集,则放弃该子集,从当前最优子集中选择起始点实行浮动搜索,获取车辆多融合数据的最优特征子集。




图 1 个体间遗传的浮动搜索算法步骤

3 车辆运行状态智能监测

将提取到的车辆运行状态最优特征子集输入模糊神经网络中,实现车辆运行状态多维智能监测^[12-13]。

模糊神经网络模型结构如图 2 所示。




图 2 模糊神经网络模型

在模糊神经网络输入层,将获取的车辆运行状态最优特征子集以矩阵 $T \times W$ 的形式输入,其中, W 表示最优特征子集样本数, T 表示最优特征子集向量维度。

接着在模糊层,通过隶属度函数将输入车辆运行状态最优特征子集实行模糊化处理。针对不同维度的车辆运行状态最优特征子集,通过模糊聚类算法在模糊层分类最优特征子集为 M 个模糊子空间^[14-15]。

在得到输入的 T 维最优特征子集的 $T \times M$ 个聚类中心后(M 表示聚类分类数),聚类宽度 ζ_{ok}^2 公式表达如下:

$$\zeta_{ok}^2 = g_1 \frac{\|c_o - v_{ok}\|^2}{m_k} \tag{8}$$

其中, m_k 表示第 k 类最优特征子集的数目, c_o 表示第 o 维输入车辆运行状态最优特征子集, v_{ok} 表示第 o 维第 k 类聚类中心。

使用高斯模糊函数作为模糊神经网络模糊层的隶属度函数 i_{uk}^{ko} , 其公式表达如下:

$$i_{uk}^{ko} = \frac{\exp(-(c_{uk} - v_{ok})^2)}{\zeta_{ok}^2} \tag{9}$$

其中, c_{uk} 表示第 k 类第 w 个输入最优特征子集。

将模糊处理后的车辆运行状态最优特征子集模隶属度值继续输入推理层实行模糊规则计算。

经模糊规则计算得到的推理层输出 ω_{uu} 公式表达如下:

$$\omega_{uu} = \prod_{o=1}^T i_{uo}^{ok} \tag{10}$$

在与推理层相连的归一化中,归一化处理推理层获取的输出值,得到归一化输出值 $\bar{\omega}_{uu}$ 公式表达如下:

$$\bar{\omega}_{uu} = \frac{\omega_{uu}}{\sum_{a=1}^{M^T} \omega_{ua}} \tag{11}$$

归一化层输出值继续在与之相连的反模糊化层实行计算。

连接矩阵 E 公式表达如下:

$$E = \frac{U}{B} \tag{12}$$

其中, B 表示归一化输出矩阵, U 表示模糊神经网络的输出。

进一步推导出模糊神经网络模型的输出公式表达如下:

$$\bar{\omega}_{uu} = E \frac{\omega_{uu}}{\sum_{a=1}^{M^T} \omega_{ua}} \tag{13}$$

基于此,在模糊神经网络输出层获取车辆运行状态监测结果,从而实现车辆运行状态的多维智能监测。

4 实验与分析

为了验证基于模糊神经网络的车运行状态多维智能监测方法的有效性,对其完成如下测试。

4.1 实验环境及实验数据

在 Windows 7、Intel core i7-4210H、8 GB 操作系统,编程环境为 Python 3.7 的计算机上使用 MATLAB 软件完成实验。采用基于模糊神经网络的车运行状态多维智能监测方法(本文所提方法)、基于 XGBoost 模型的车运行状态多维智能监测方法(文献[3]方法)和基于虚拟应答器捕获方法的车运行状态多维智能监测方法(文献[4]方法)完成实验测试。测试试验车辆分别在主干道、高速公路和 S 形山路三种路况下,在 0—160 s 行驶时间内的车辆运行状态,得出车辆运行状态数据如表 1 所示。

表 1 车辆运行状态数据

路况	主干道	高速公路	S 形山路
减速状态	0—25s	45—65s	80—98s
正常状态	25—52s、 103—160s	0—45s、 126—160s	48—64s
加速状态	52—83s	65—104s	64—80s
抗蛇行状态	83—103s	104—126s	0—48s、 98—160s

分析表 1 可知,试验车辆在主干道、高速公路和 S 形山路三种路况存在四种运行状态,分别为减速状态、正常状态、加速状态和抗蛇行状态。

(1)减速状态:车辆在行驶过程中降低速度或减小加速度的状态。这可能是由道路条件、交通情况或驾驶员的意图导致的。在减速状态下,车辆的速度会逐渐降低,以适应前方的情况。

(2)正常状态:车辆在正常行驶条件下保持稳定的状态。这包括车辆以合理的速度行驶,保持适当的加速度和制动力,以及与周围车辆和道路环境保持安全距离和合理的操控。

(3)加速状态:车辆在行驶过程中增加速度或增大加速度的状态。这可能是为了超车、快速通过交叉口或加入高速公路等而进行的。在加速状态下,车辆的速度会逐渐增加,以达到预期的目标速度。

(4)抗蛇行状态:车辆在高速行驶时抑制车辆蛇行或失控的状态。蛇行是指车辆在直线行驶时出现左右摇摆的情况,可能由路面不平、风力影响或操控不当等引起。抗蛇行状态通过控制车辆的制动和转向系统来稳定车辆,确保安全行驶。

4.2 实验结果分析


(1)车辆运行状态监测精度

试验车辆分别在主干道、高速公路和 S 形山路三种路况下,用状态 1、状态 2、状态 3、状态 4 分表示减速、正常、加速、抗蛇行四种运行状态,采用本文所提方法、文献[3]方法和文献[4]方法完成车辆运行状态监测,记录三种方法的车辆运行状态监测情况,如图 3 所示。


分析图 3 可知,以主干道为例,文献[3]方法在 0—40 s 处于抗蛇行状态、在 40—64 s 处于正常状态、在 64—116 s 处于加速状态、在 116—160 s 处于正常状态;文献[4]方法在 0—60 s 处于加速状态、在 60—94 s 处于正常状态、在 94—120 s 处于抗蛇行状态、在 120—160 s 处于正常状态。上述两种方法监测到的车辆运行状态与实际状态相差较大,监测精度不佳,而本文所提方法在 0—32 s 处于减速状态、在 32—56 s 处于正常状态、在 56—86 s 处于加速状态、在 86—106 s 处于抗蛇行状态、在 106—160 s 处于正常状态。本文所提方法的车辆运行状态监测结果与实际车辆运行状态更相符,表明所提方法的车辆运行状态监测精度更高。

(2)监测时间

采用本文所提方法、文献[3]方法和文献[4]方法完成车辆运行状态多维智能监测,记录三种方法对车辆运行状态的监测耗时,如表 2 所示。



(b)高速公路



(c)S形山路


图 3 三种方法的车辆运行状态监测情况

表 2 车辆运行状态监测耗时对比

时间(s)			
实验次数	文献[3]方法	文献[4]方法	本文所提方法
1	95	90	46
2	97	85	56
3	106	89	51
4	105	95	60
5	101	92	49

分析表 2 可知,文献[3]方法的车辆运行状态监测耗时在 95—106 s 之间,文献[4]方法的车辆运行状态监测耗时在 85—95 s 之间,本文所提方法的车辆运行状态监测耗时在 46—60 s 之间,本文所提方法的车辆运行状态监测耗时低于文献[3]方法和文献[4]方法,表明本文所提方法车辆运行状态监测耗时短、速率高。

通过上述实验可知,本文所提方法通过多传感器采集车辆运行状态数据并通过自适应加权算法对其实行融合处理,提高了车辆运行状态监测精度;通过自适应遗传算法和浮动搜索算法提取了车



(a)主干道

辆运行状态数据的最优特征子集,提高了车辆监测速度,获得了更好的车辆运行状态多维智能监测性能。

5 结 论

对车辆运行状态实行监测,是提高汽车安全性能的必要手段,是汽车领域研究的重点内容之一。本文提出了基于模糊神经网络的车辆运行状态多维智能监测方法,通过使用多传感器来检测车辆的加速度、角速度和方向等相关参数,从而实现对车辆运行状态的准确监测。实验结果表明,该方法能够准确监测减速、正常、加速和抗蛇行四种车辆运行状态,并且监测时效高,因此,该方法具有实际可行性,可以用于车辆运行状态的智能监测和控制。

参考文献

[1] 赵飞,宁静,方明宽,等. 基于动力学仿真数据的高速列车蛇行状态识别[J]. 中国测试,2021,47(1):120—126.

[2] 吴丹,甄昊涵,雷珽,等. 基于 CNN 和 LSTM 混合网络的电动汽车充电桩运行状态预测方法[J]. 电机与控制应用,2022,49(2):83—89.

[3] 门元昊,吴亮,刘晓双,等. 基于 XGBoost 模型的地铁列车运行状态仿真方法[J]. 城市轨道交通研究,2022,25(3):102—106.

[4] 王剑,王思琦,蔡伯根,等. 基于列车运行状态组合预测的虚拟应答器捕获方法[J]. 中国铁道科学,2023,44(1):202—213.

[5] 田祥宏. 基于可信时空协议的无线传感器网络地理路由协议[J]. 南京理工大学学报,2018,42(6):671—677+699.

[6] 彭宅铭,程龙生,姚启峰. 多传感器数据融合的复杂系统退化模式挖掘[J]. 振动与冲击,2022,41(13):239—245+251.

[7] 刘康,何明浩,韩俊,等. 基于多传感器的雷达对抗侦察数据融合算法[J]. 系统工程与电子技术,2023,45(1):101—107.

[8] 王妮,孙书利. 带相关噪声多传感器系统的事件触发贯序和分布式融合估计[J]. 空军工程大学学报(自然科学版),2021,22(2):60—67.

[9] 滕洪钊,邓朝晖,吕黎曙,等. 多传感器信息融合的加工过程状态监测研究[J]. 机械工程学报,2022,58(6):26—41.

[10] 徐建中,孙颖,孙晓光. 基于遗传搜索权重的模糊 C-均值-VIKOR 模型的绿色供应商选择[J]. 统计与决策,2021,37(4):159—163.

[11] 张俊杰,仇润鹤. 认知超密集网络用户关联与资源分配联合优化遗传算法[J]. 计算机应用,2022,42(12):3856—3862.

[12] 张铁,康中强,邹焱飏,等. 用于残余振动抑制的深度神经网络输入整形器[J]. 华南理工大学学报(自然科学版),2021,49(8):103—112.

[13] 任燕飞,杜盈,张劲东. 基于深度神经网络的自适应波束形成算法[J]. 电讯技术,2022,62(7):852—858.

[14] 徐庆婷,张兰芳,朱新华. 综合语义技术与 LSTM 神经网络的主观题自适应评卷方法[J]. 广西师范大学学报(自然科学版),2021,39(2):51—61.

[15] 刘湘楠,赵学智,何宽芳. 圆柱滚子轴承振动信号时频特征提取及状态识别[J]. 振动工程学报,2022,35(4):932—941.