



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于ResNeSt网络路面状态识别的主动悬架模型预测控制

寇发荣, 胡凯仑, 陈若晨, 何海洋

引用本文:

寇发荣, 胡凯仑, 陈若晨, 何海洋. 基于ResNeSt网络路面状态识别的主动悬架模型预测控制[J]. 控制与决策, 2024, 39(6): 1849–1858.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1392>

您可能感兴趣的其他文章

Articles you may be interested in

[基于MCPDDPG的智能车辆路径规划方法及应用](#)

The method and application of intelligent vehicle path planning based on MCPDDPG
控制与决策. 2021, 36(4): 835–846 <https://doi.org/10.13195/j.kzyjc.2019.0460>

[区分交通流模式的混合服务路口信号控制策略](#)

Signal control strategies of mixed service intersections to discriminate traffic flow patterns
控制与决策. 2021, 36(6): 1509–1515 <https://doi.org/10.13195/j.kzyjc.2019.1520>

[基于强化学习的倒立摆分数阶梯度下降RBF控制](#)

Reinforcement learning based fractional gradient descent RBF neural network control of inverted pendulum
控制与决策. 2021, 36(1): 125–134 <https://doi.org/10.13195/j.kzyjc.2019.0816>

[输入约束不确定系统的点对点迭代学习控制与优化](#)

Point-to-point iterative learning control and optimization for uncertain systems with constrained input
控制与决策. 2021, 36(6): 1435–1441 <https://doi.org/10.13195/j.kzyjc.2019.0908>

[参数未知的离散系统Q-学习优化状态估计与控制](#)

Q-learning optimal state estimation and control for discrete systems with unknown parameters
控制与决策. 2020, 35(12): 2889–2897 <https://doi.org/10.13195/j.kzyjc.2019.0180>

基于 ResNeSt 网络路面状态识别的主动悬架模型预测控制

寇发荣[†], 胡凯仑, 陈若晨, 何海洋

(西安科技大学 机械工程学院, 西安 710054)

摘要: 为了提升不同运行工况下的路面状态识别精度及主动悬架平顺性控制性能, 提出一种基于 ResNeSt 网络路面状态识别的主动悬架模型预测控制 (MPC) 方法. 首先, 搭建基于多路径分散注意力思想的 ResNeSt 网络架构, 建立面向主动悬架实时控制的路面状态识别算法, 采用交叉熵目标损失函数和 AdamW 梯度下降算法进行网络训练以及测试实验验证; 然后, 在此基础上设计基于路面状态识别的主动悬架 MPC 控制算法, 根据离散状态空间方程推导悬架系统预测模型, 以悬架预测输出和控制力输入为性能指标建立目标函数, 并考虑不同路面的控制策略确定加权矩阵取值, 在系统约束条件下, 将 MPC 目标函数转化为二次最优规划问题的求解; 最后, 将所提出控制算法与被动悬架、LQG 控制进行对比仿真分析, 结果表明: ResNeSt 网络可以快速准确地识别多种路面状态, 所提出控制算法能够根据路面状态对悬架进行实时瞬态主动控制, 簧载质量加速度、悬架动挠度和轮胎动载荷的均方根值平均值相比 LQG 控制分别降低 36.56%、32.99% 和 36.28%.

关键词: 路面状态识别; ResNeSt; 深度学习; 残差卷积神经网络; 主动悬架; 模型预测控制

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1392

开放科学(资源服务)标识码(OSID):



引用格式: 寇发荣, 胡凯仑, 陈若晨, 等. 基于 ResNeSt 网络路面状态识别的主动悬架模型预测控制[J]. 控制与决策, 2024, 39(6): 1849-1858.

Model predictive control of active suspension based on road surface condition recognition by ResNeSt

KOU Fa-rong[†], HU Kai-lun, CHEN Ruo-chen, HE Hai-yang

(School of Mechanical Engineering, Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: To improve the road state recognition efficacy and the ride comfort control performance of the active suspension system, a model predictive control (MPC) based active suspension control method is proposed based on road state recognition by the residual convolutional neural networks with split-attention (ResNeSt). First, the road state recognition algorithm scheme with respect to the active suspension control is established by the ResNeSt network considering the multi-path split attention mechanism. The proposed network is trained and tested via utilizing the cross-entropy objective loss function and the AdamW gradient descent algorithm. Then, the MPC-based active suspension control algorithm is developed based on road state recognition. Specifically, the prediction model is derived from the discrete state space equation and the objective function is constructed by the performance indexes of the prediction outputs and the control inputs. Moreover, the weighting matrix values are determined by the recognized road surface results. The objective function of the MPC is transformed into the quadratic programming (QP) to obtain the global optimum while satisfying the constraints. Comparative studies of the passive suspension and the LQR control are performed to demonstrate the effectiveness of the proposed architecture. The results show that the ResNeSt network is capable of identifying different kinds of road states with guaranteed precision and computational performance. The proposed active suspension control algorithm provides satisfactory real-time and transient active control of the suspension based on different road conditions. Compared with the LQG algorithm, quantitative results for the mean RMS values of spring mass acceleration, suspension dynamic deflection and tire dynamic load are reduced by 36.56%, 32.99% and 36.28%.

Keywords: road surface condition recognition; ResNeSt; deep learning; residual convolutional neural networks; active suspension; model predictive control

收稿日期: 2022-08-02; 录用日期: 2022-12-20.

基金项目: 国家自然科学基金项目(51275403); 陕西省重点研发计划项目(2020GY-128).

[†]通讯作者. E-mail: koufarong@xust.edu.cn.

0 引言

路面状况直接影响车辆操纵稳定性、乘坐舒适性及驾驶安全性,实时准确地感知前方路况并结合车辆动力学控制尤其是悬架控制对提升车辆性能具有重要意义.随着车辆环境感知技术^[1-3]的发展,目前主动悬架路面状态识别的方法主要分为间接识别和直接识别两种方式.间接识别法基于车辆动力学参数建模,根据系统状态间接获取路面状态信息;直接识别法则主要利用激光雷达^[4]、视觉摄像头^[5-6]等车载传感器直接感知路面状态.间接识别法结合悬架动力学控制不需要借助额外的传感器,但比较依赖悬架模型的建模精度,且仅能识别当前轮胎下的路面状态^[7-10].激光雷达虽然能够识别到前方未知的路面状态,但激光雷达获取的数据稀疏无序且没有颜色和纹理信息,在复杂行驶环境下的识别效果难以得到保证^[11-13].视觉传感器能获取路面高帧率、高分辨率图像信息^[14-18],利用深度学习主干网络对图像进行特征提取以识别路面,如: AlexNet^[19]、VggNet^[20]、GoogleNet^[21]、ResNet^[22]等.使用端到端的训练方式对图像数据进行特征变换,从大量样本中自动学习得到层次化的特征表示,识别准确率高且实时性好,适用于悬架系统的瞬态控制,但以上研究尚未将该方法与主动悬架动力学控制相结合.

本文提出一种基于 ResNeSt (residual convolution neural networks with split-attention) 网络路面状态识别的主动悬架模型预测控制 (model predictive control, MPC) 方法.采用视觉传感器的直接识别方法获取路面图像,搭建 ResNeSt 网络主体架构,根据所采集路面图像构建数据集对网络模型进行端到端的训练学习以识别路面状态.设计基于路面状态识别的主动悬架 MPC 控制算法,根据前方路面状态调节控制器参数对悬架进行实时瞬态主动控制,实现车辆在不同路面上操纵稳定性和行驶平顺性的协调优化.

1 基于 ResNeSt 网络的路面状态识别算法

1.1 ResNeSt 网络架构

ResNeSt 是基于多路径分散注意力 (split-attention) 思想的残差卷积神经网络 (residual convolution neural networks)^[23], split-attention 思想使卷积模块的注意力能在特征图组间获取不同的权重特征,有利于特征图的多样性,通过模块化分支结构跨越特征图组进行信息交互. ResNeSt block 如图 1 所示,最初输入高、宽、通道数分别为 H_{in} 、 W_{in} 、 C_{in} 的路面特征图,通过多路径分支结构分为 L 个基数组;然后对基数组引入切片将其分为 R 个分支,每个分支的特征图通道数为 $C_{in}/L/R$,则第 l (取值范围为 $1 \sim L$) 组特征图可以表示为

$$\hat{U}^l = \sum_{j=R(l-1)+1}^{Rl} U_j, \quad (1)$$

其中 U_j 为本组第 j 个分支的特征图.

为增加特征图多样性,将 R 个分支的特征图通道数升维至 C' ,依次经过 1×1 和 3×3 的卷积核做卷积操作后通道数变为 C'/L .通过 split-attention block 赋予不同的权重, split-attention block 如图 2 所示.将 R 个特征图逐元素相加再经过跨空间维度的全局平均池化进行降维得到

$$s_{c'}^l = \frac{1}{H_{in} \times W_{in}} \sum_{i=1}^{H_{in}} \sum_{j=1}^{W_{in}} \hat{U}_{c'}^l(i, j). \quad (2)$$

其中: $\hat{U}_{c'}^l(i, j)$ 为第 l 组特征图 \hat{U}^l 的第 c' (取值范围为“ $1 - C'/L$ ”) 个通道的第 (i, j) 个像素.

将 C'/L 维向量 s^l 送入全连接层,经过批归一化和 ReLU 激活函数层激活后通过 r -Softmax 分类器进行分类,得到各通道的权重向量,最后与残差模块的输出进行线性组合得到特征图 V 为

$$V_{c'}^l = \sum_{i=1}^R a_i^l(c') U_{R(L-1)+i}. \quad (3)$$

其中 $a_i^l(c')$ 为每个特征图组的权重,可表示为

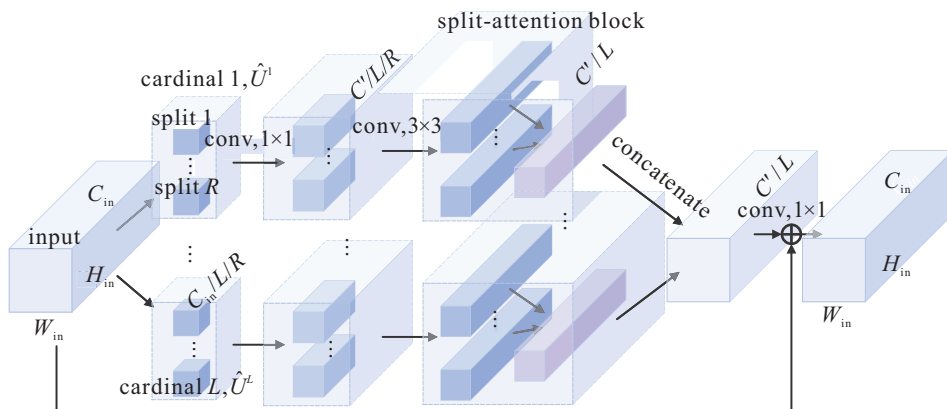


图1 ResNeSt block




图2 split-attention block

$$a_i^l(c') = \begin{cases} \frac{\exp(\zeta_i^{c'}(s^l))}{\sum_{j=0}^R \exp(\zeta_i^{c'}(s^l))}, & R > 1; \\ \frac{1}{1 + \exp(-\zeta_i^{c'}(s^l))}, & R = 1. \end{cases} \quad (4)$$

这里 $\zeta_i^{c'}$ 为特征图间的映射关系, 决定全局纹理表达向量 s^l 的每一组权重.

split-attention block 将 L 个组进行聚合再与残差特征图进行跳层连接得到 ResNeSt block 的输出, 进行 Flatten 展平处理和全连接层后, 通过 Softmax 分类器得到一维实向量 δ 为

$$\delta(z_i) = \frac{e^{z_i}}{\sum_{j=1}^{N_t} e^{z_j}}. \quad (5)$$

其中: z_i 为 N_t 维向量 z 中的第 i 个元素, N_t 为路面状态的个数.

通过 Softmax 分类器输出当前的路面状态以及属于该路面的概率, 最终将路面状态输入至主动悬架控制器用于控制参数的调节.

1.2 路面信息采集与数据集构建

根据中国常见道路类型, 在实验车辆上安装路面信息采集系统对 7 种路面图像和路面不平度进行采集, 如图 3 所示. 路面图像数据集的每种路面设置 5 000 个样本, 共计 35 000 个样本, 按 70 : 15 : 15 的比例划分为训练集、验证集和测试集. 提取路面图像的感兴趣区域 (region of interest, ROI) 并进行数据增强, 处理后的图像和路面不平度的空间函数曲线如图 4、图 5 所示. 将所采集的 7 种路面的功率谱密度与国家标准等级路面功率谱密度 (PSD) 进行对比, 如图 6 所示 (双对数坐标系). 优质、普通和劣质沥青路基本与 B 级、C 级和 D 级路面分别重合, 优质水泥路面在 C 级



图3 路面信息采集系统




图4 原始路面图像及处理后图像

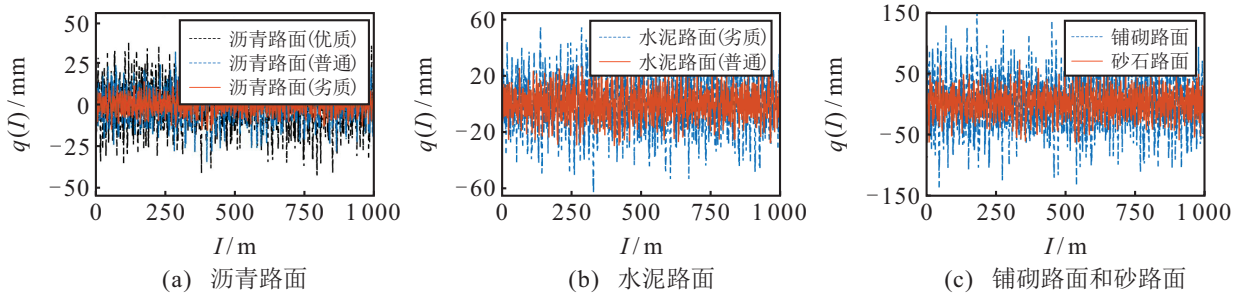


图5 路面不平度曲线




图6 7种路面功率谱密度与国家标准等级功率谱密度

与D级路面之间,普通水泥路面比D级路面略微偏大,铺砌路面在D级与E级路面之间,砂石路面在E级与F级路面之间.

1.3 ResNeSt网络训练

网络搭建完成后采用监督学习的方式进行训练,训练完成的网络将用于路面状态识别.定义交叉熵为目标损失函数,计算预测结果与真实结果的损失值,假设标注数据和网络预测数据的概率分布分别为 σ 和 τ ,则 σ 相对于 τ 的交叉熵为

$$\varphi(\sigma, \tau) = -\sigma \log(\tau). \quad (6)$$

交叉熵目标损失函数为

$$\Theta(\theta) = -\frac{1}{N} \sum_{i=1}^N \sum_{r=1}^M \sigma_{ir} \log(\tau_{ir}). \quad (7)$$

其中: N 为数据集的大小, M 为类别数量, τ_{ir} 为样本 i 属于类别 r 的网络预测概率, σ_{ir} 为实际概率.

在样本参数的反向传播及迭代过程中使用指数衰减学习率,其计算公式为

$$lr_d = lr_i \times \lambda^{N_i/\mu}. \quad (8)$$

其中: lr_i 、 lr_d 分别为初始和衰减后的学习率, λ 为衰减系数, N_i 为迭代轮数, μ 为衰减速度.

构建AdamW(adam with decoupled weight decay)梯度下降法寻求目标损失函数的最优解.该算法结合了批量梯度下降、动量法、RMSProp等算法^[24]的优点,通过增加权重衰减解决其存在的收敛问题,可以自适应改变学习率快速寻优.参数 θ 迭代更新如下:

$$g_t = \nabla \Theta_t(\theta_{t-1}) + \lambda \theta_{t-1}, \quad (9)$$

$$\eta_t = \beta_1 \eta_{t-1} + (1 - \beta_1) g_t, \quad (10)$$

$$\nu_t = \beta_2 \nu_{t-1} + (1 - \beta_2) g_t^2, \quad (11)$$

$$\hat{\eta}_t = \frac{\eta_t}{1 - \beta_1^t}, \quad (12)$$

$$\hat{\nu}_t = \frac{\nu_t}{1 - \beta_2^t}, \quad (13)$$

$$\theta_t = \theta_{t-1} - lr \left(\frac{\hat{\eta}_t}{\sqrt{\hat{\nu}_t + \epsilon}} + \gamma \theta_{t-1} \right). \quad (14)$$

其中: t 为迭代步数, g 为梯度, η 为一阶动量, ν 为二阶动量, β_1 、 β_2 分别为梯度衰减因子和平方梯度衰减因子, γ 为权重衰退因子, ϵ 为偏执小量.

训练完成后将最优的模型参数固化并保存,用于路面状态的识别,流程如图7所示.根据识别结果选MPC控制加权重 Γ_{q_1} 、 Γ_{q_2} 、 Γ_{ρ_1} 、 Γ_u 的取值,实时瞬态对主动悬架MPC控制器进行调节以提升车辆性能.

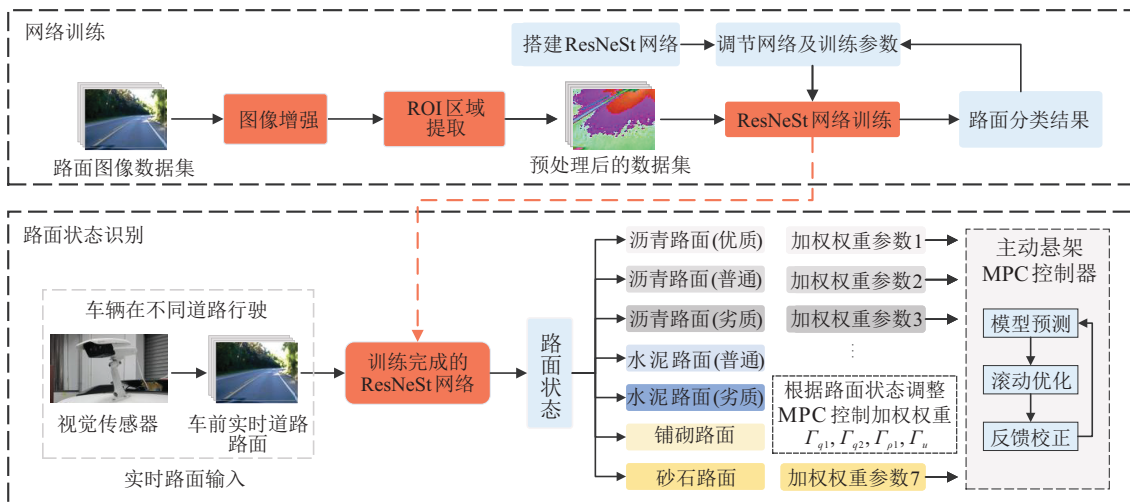


图7 路面状态识别流程

2 路面状态识别算法验证

2.1 实验环境配置

根据所构建的路面图像数据集进行端到端的训练及测试实验,验证基于ResNeSt网络的路面状态识别算法的实时性和可靠性.实验过程需要大量样本经过多轮迭代来寻求最优解,包含大量矩阵运算和浮点运算,需要较高的环境配置.本文路面识别算法验证所使用的实验环境配置如表1所示.

设置训练的超参数如表2所示,训练集样本 N 为

表1 实验环境配置

操作系统	CPU	GPU	框架	计算架构
Windows10 64位	i7-12500H	NVIDIA GTX3070Ti	Pytorch	CUDA CUDNN

35 000,每次在训练集随机抽取每份64大小的小批量,统一进行数据增强和ROI区域提取处理后输入到网络,共计迭代轮数 $N_i = 100$.学习率采用指数型衰减策略,AdamW小批量梯度下降优化算法权重衰减系数 γ 设置为 5×10^{-5} .

表 2 训练超参数

项目	参数	数值
图像输入	图像尺寸 $H_{in} \times W_{in}$	224×224
	通道数 C_{in}	64
	单次输入参数量	0.57
网络结构	基数组个数 L	8
	分支个数 R	4
	通道数 C'	128
训练参数	初始学习率 lr_i	0.001
	学习率衰退系数 λ	0.9
	学习率衰退速度 μ	50
AdamW 相关	优化器权重衰减系数 γ	5×10^{-5}
	梯度衰减因子 β_1	0.9
	平方梯度衰减因子 β_2	0.999
	偏置小量 ϵ	1×10^{-8}

2.2 实验结果

网络训练经过20轮后达到稳定的收敛状态,未发生过拟合现象,最终训练集和验证集的 Accuracy、Loss 曲线如图8所示。

网络训练完成后,保存最优模型参数并采用路面数据集的测试集对模型进行测试,测试集结果的混淆矩阵如图9所示。预测结果与真实标签类别基本一致,单张图片识别平均时间为26.33 ms。由于优质沥青路面、普通水泥路面和铺砌路面的特征较为显著,




图 8 Accuracy 和 Loss 曲线

网络模型更容易捕捉,准确率达到100%。而劣质水泥路面部分图像与普通水泥路面的图像特征容易混淆,因此准确率相对较低,其中98.61%的劣质水泥路面预测标签与真实标签一致,1.39%的水泥路面真实标签劣质被错误预测为普通。




图 9 测试结果混淆矩阵

使用精确率 pre (precision)、召回率 rec (recall) 和 F_1 值 (F_1 score) 3 个评价指标对路面识别结果进行评估,计算公式为

$$pre = \frac{TP_i}{TP_i + FP_i}, \quad (15)$$

$$rec = \frac{TP_i}{TP_i + FN_i}, \quad (16)$$

$$F_1 = \frac{2pre \times rec}{pre + rec}. \quad (17)$$

其中: TP为真阳性, FP为假阳性, FN为假阴性。

评估结果如图10所示,同一路面状态的pre和rec均有较高的值且接近, F_1 值也相应较高,表明对不同路面状态的识别有一致较好的结果。考虑实际识别

效果,采用路面图像连续帧对算法进行测试,测试视频帧率为30 FPS,每帧平均识别时间为25.62 ms,部分帧路面状态实时识别效果如图11所示。




图 10 pre、rec、 F_1 评估结果



图 11 连续帧测试效果

3 基于路面状态识别的主动悬架MPC控制

3.1 1/4车辆主动悬架建模

建立1/4车辆主动悬架动力学模型如图12所示,根据牛顿第二定律得出运动学方程组为

$$\begin{cases} m_s \ddot{x}_s + k_s(x_s - x_u) + c_s(\dot{x}_s - \dot{x}_u) = u, \\ m_u \ddot{x}_u - k_s(x_s - x_u) - c_s(\dot{x}_s - \dot{x}_u) + k_t(x_u - x_r) = -u. \end{cases} \quad (18)$$

其中: x_s 为簧载质量位移, \dot{x}_s 为簧载质量速度, \ddot{x}_s 为簧载质量加速度, x_u 为非簧载质量位移, \dot{x}_u 为非簧载质量速度, \ddot{x}_u 为非簧载质量加速度, u 为作动器输出力, m_s 为簧载质量, m_u 为非簧载质量, x_r 为路面激励输入, k_s 为弹簧刚度, k_t 为轮胎刚度, c_s 为减振器阻尼系数.




图 12 1/4车辆主动悬架动力学模型

定义悬架模型的状态变量和输出变量分别为

$$X = [x_s - x_u \quad \dot{x}_s \quad x_u - x_r \quad \dot{x}_u]^T, \quad (19)$$

$$Y = [x_s - x_u \quad \dot{x}_s \quad x_u - x_r]^T. \quad (20)$$

控制输入为 $U = [u]$, 扰动输入为路面高度变化 $W = [x_r]$. 则系统状态空间形式可表示为

$$\begin{cases} \dot{X} = AX + BU + EW, \\ Y = CX + DU. \end{cases} \quad (21)$$

其中: A 为状态矩阵, B 为控制矩阵, E 为扰动输入矩

阵, C 为输出矩阵, D 为传递矩阵.

3.2 预测模型

根据基于路面状态识别的主动悬架MPC控制算法原理如图13所示,使用前向欧拉法将1/4车辆主动悬架系统状态空间方程离散化得到

$$\begin{cases} x(k+1) = A_b x(k) + B_u u(k) + E_d w(k), \\ y_b(k) = C_b x(k) + D_b u(k), \\ y_c(k) = C_c x(k). \end{cases} \quad (22)$$

其中: k 为系统当前时刻, $x(k) \in R^{n_x}$, $u(k) \in R^{n_u}$, $w(k) \in R^{n_w}$ 分别为当前时刻的状态量、控制输入量、外部扰动量, $y_b(k) \in R^{n_b}$ 为控制输出量, $y_c(k) \in R^{n_c}$ 为约束输出量, A_b 、 B_u 、 C_b 、 C_c 、 D_b 、 E_d 为相应维数的系数矩阵.

根据离散状态方程建立悬架系统预测模型,以最新测量值为系统的初始条件,设定预测时域为 p , 控制时域为 m , 且 $m \leq p$. 基于1/4车辆主动悬架的线性离散模型(22)以及当前状态量 $x(k)$ 和路面扰动 $w(k)$, 预测悬架系统未来 p 步的状态和悬架控制输出量, 经过MPC控制器优化得到 m 步最优控制输入量. 假设可测干扰量 k 时刻后不变, 定义系统从 k 时刻起未来 p 步预测输出量序列 $Y(k+1|k)$ 、 m 步控制输入量序列 $U(k)$ 分别为

$$Y(k+1|k) \stackrel{\text{def}}{=} \begin{bmatrix} y_b(k+1|k) \\ y_b(k+2|k) \\ \vdots \\ y_b(k+p|k) \end{bmatrix}_{p \times 1}, \quad (23)$$

$$U(k) \stackrel{\text{def}}{=} \begin{bmatrix} u(k) \\ u(k+1) \\ \vdots \\ u(k+m-1) \end{bmatrix}_{m \times 1}. \quad (24)$$

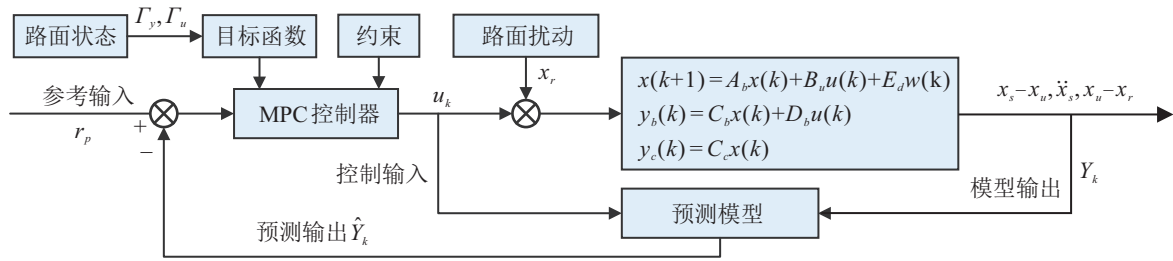


图 13 基于路面状态识别的主动悬架MPC控制算法

预测时域内 k 时刻未来 p 步的悬架系统输出状态为

$$Y(k+1|k) = S_x x(k) + S_u U(k) + S_d w(k). \quad (25)$$

其中

$$S_x = [C_b A_b \quad C_b A_b^2 \quad \dots \quad C_b A_b^p]^T_{p \times 1},$$

$$S_u = \begin{bmatrix} C_b B_u & D_b & 0 & \dots & 0 \\ C_b A_b B_u & C_b B_u & D_b & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ C_b A_b^{m-2} B_u & C_b A_b^{m-3} B_u & \dots & \dots & D_b \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ C_b A_b^{p-1} B_u & C_b A_b^{p-2} B_u & \dots & \dots & C_b B_u \end{bmatrix}_{p \times m},$$

$$S_d = \begin{bmatrix} C_b E_d & 0 & 0 & \dots & 0 \\ C_b A_b E_d & C_b E_d & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ C_b A_b^{m-1} E_d & C_b A_b^{m-2} E_d & \dots & \dots & C_b E_d \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ C_b A_b^{p-1} E_d & C_b A_b^{p-2} E_d & \dots & \dots & C_b E_d \end{bmatrix}_{p \times m}.$$

3.3 目标函数

在滚动优化过程中,系统输出值会同时受控制量 $U(k)$ 和干扰量 $w(k)$ 的影响.当模型预测系统的状态和输出时,给定控制输出参考序列 $R_p(k+1)$,当前时刻的路面扰动为 $w(k)$,建立以悬架系统预测输出变量和作动器控制输入变量为性能指标的目标函数

$$J(x(k), U(k)) = \|\Gamma_y(Y(k+1k) - R_p(k+1))\|^2 + \|\Gamma_u U(k)\|^2. \quad (26)$$

Γ_y 和 Γ_u 分别为预测输出和控制输入的加权矩阵, $R_p(k+1)$ 为控制输出参考序列,可表示为

$$\Gamma_y = \text{diag}(\Gamma_{q_1, i}, \Gamma_{\rho_1, i}, \Gamma_{q_2, i}), \quad i = 1, 2, \dots, p; \quad (27)$$

$$\Gamma_u = \text{diag}(\Gamma_{u, i}), \quad i = 1, 2, \dots, p; \quad (28)$$

$$R_p(k+1) = [r_p(k+1) \quad r_p(k+2) \quad \dots \quad r_p(k+p)]^T. \quad (29)$$

其中: Γ_{q_1} 、 Γ_{q_2} 、 Γ_{ρ_1} 、 Γ_u 分别为悬架动挠度加权权重、轮胎动变形加权权重、簧载质量加速度加权权重、控制输入加权权重.

为方便对权重参数进行优化,设定一个默认的权重参数组合和数值区间^[25].参数组合选取为: $\Gamma_{q_1} = 100$, $\Gamma_{q_2} = 8000$, $\Gamma_{\rho_1} = 10$, $\Gamma_u = 0.01$. Γ_{q_1} 的参数值区间选取为 $[0, 1 \times 10^3]$, Γ_{q_2} 参数值区间选取为 $[0, 1 \times 10^4]$, Γ_{ρ_1} 参数值区间选取为 $[0, 1 \times 10^2]$. Γ_u 选取4个数量级的值: 1×10^{-3} 、 1×10^{-2} 、 1×10^{-1} 、1.在每个权重值区间内,采用交叉对比法确定每种路面的权重参数的取值.由于部分路面状态不平度较为相近,将其权重合并后最终确定5种路面状态的 Γ_{q_1} 、 Γ_{q_2} 、 Γ_{ρ_1} 、 Γ_u 取值如表3所示.然后将预测输入代入目标函数,得到

$$J = U(k)^T S_u^T \Gamma_y^T \Gamma_y S_u U(k) + U(k)^T \Gamma_u^T \Gamma_u U(k) - 2E_p(k+1|k) \Gamma_y^T \Gamma_y S_u U(k) + E_p(k+1|k)^T \Gamma_y^T \Gamma_y E_p(k+1|k), \quad (30)$$

其中 $E_p(k+1|k) \stackrel{\text{def}}{=} -S_x x(k) - S_d w(k)$.

表 3 加权权重取值

路面状态	加权权重			
	Γ_{q_1}	Γ_{q_2}	Γ_{ρ_1}	Γ_u
沥青路面(优质)	103	8180	10.1	0.01
沥青路面(普通)	126	7650	11.8	0.01
水泥路面(普通)	141	7360	13.5	0.01
铺砌路面	162	6850	15.6	0.01
砂石路面	218	5530	19.3	0.01

忽略与控制输出 u 无关的变量,最终目标函数为

$$J = U(k)^T H_k S_u U(k) - G(k+1|k)^T U(k). \quad (31)$$

其中

$$H_k = S_u^T \Gamma_y^T \Gamma_y S_u + \Gamma_u^T \Gamma_u,$$

$$G(k+1|k) = 2S_u^T \Gamma_y^T \Gamma_y E_p(k+1|k).$$

3.4 约束条件

MPC最显著的特点是显式地处理约束的能力,其开环优化问题需要设置约束条件.主动悬架系统作动器的控制力输入存在上下限,设置为 u_{\max} 和 u_{\min} ,则控制输入的约束表示为

$$u_{\min} \leq u(k+i) \leq u_{\max}, \quad i = 1, 2, \dots, m-1. \quad (32)$$

悬架动挠度约束要求避免减振器撞击限位块,

设置减振器最大行程为 S_{\max} , 则悬架动挠度需满足 $|x_s - x_u| \leq S_{\max}$. 为确保轮胎始终与地面接触, 要求轮胎的动载荷小于轮胎静载荷 f_{ku} , 可表示为

$$|k_t(x_u - x_r)| \leq f_{ku}. \quad (33)$$

则最终输出约束应满足

$$y_{\min} \leq y_c(k + i|k) \leq y_{\max}, \quad i = 1, 2, \dots, p. \quad (34)$$

其中

$$y_{\min} = \begin{bmatrix} -S_{\max} \\ -f_{ku}/k_t \end{bmatrix}, \quad y_{\max} = \begin{bmatrix} S_{\max} \\ f_{ku}/k_t \end{bmatrix}.$$

在相关约束下, MPC 目标函数的优化问题转化为二次最优规划(QP)问题, 在满足约束的情况下寻求最小量 $\min J$, 表示为

$$\begin{aligned} \min_{U(k)} J &= U(k)^T H_k S_u U(k) - G(k + 1|k)^T U(k). \\ \text{s.t. } &u_{\min} \leq u(k + i) \leq u_{\max}, \quad i = 1, 2, \dots, m - 1; \\ &y_{\min} \leq y_c(k + i) \leq y_{\max}, \quad i = 1, 2, \dots, p. \end{aligned} \quad (35)$$

3.5 仿真结果与分析

为验证所提出基于路面状态识别的MPC控制算法的可行性和有效性, 使用各路面状态所对应的不平度信号对其进行仿真分析. 以第3.1节建立的1/4车辆主动悬架系统为研究对象建立仿真模型, 车辆悬架模型各项参数如表4所示. 设计基于路面状态识别的主动悬架MPC控制器, 并设置预测控制参数及相关约束条件如表5所示.

在约束条件下对比仿真分析被动悬架(Passive)、LQG控制(linear quadratic gaussian control)^[26]、MPC控制3种系统的控制效果. 系统仿真过程中各路面

表4 车辆模型参数

车辆模型参数	符号	数值
簧载质量/kg	m_s	406
非簧载质量/kg	m_u	52
轮胎刚度/(kN/m)	k_t	192
悬架刚度/(kN/m)	k_s	26.8
悬架阻尼系数/(kN·s/m)	c_s	1.5

表5 MPC控制器仿真参数

仿真参数	数值
车速/(km/h)	20
预测/控制时域	10/2
采样时间/s	0.01
控制力约束/N	$-1\,000 \leq u \leq 1\,000$
悬架动挠度约束/m	$-0.1 \leq x_s - x_u \leq 0.1$
轮胎动载荷约束/N	$-4\,580 \leq k_t(x_u - x_r) \leq 4\,580$

状态所对应LQG控制的权重系数根据文献[26]的结果进行设置, MPC控制的权重系数根据表3进行调节. 系统仿真结果的各项性能指标响应曲线如图14所示. 由图14(a)可知, MPC控制的悬架作动器主动控制力满足输入约束(32), 路面状态切换过程能够实时瞬态调节以适应当前路面, 且相较于LQG控制, MPC控制降低了悬架作动器主动控制力达到峰值的概率, 提高了悬架系统的可靠性.

由图14(b)和图14(c)可知, MPC控制的悬架动挠度满足约束(34), 减振器位移限制得到了保证, 减缓了车轮对减振器的力与冲击, 有效降低了减振器撞击限位块的概率. 在0~20s内, MPC控制的轮胎动载荷小于静载荷, 即满足控制输出约束(34), 避免了轮跳行程过大而脱离地面的危险现象发生. 20~25s内, 当车辆在砂石路面等恶劣环境行驶时同时也减

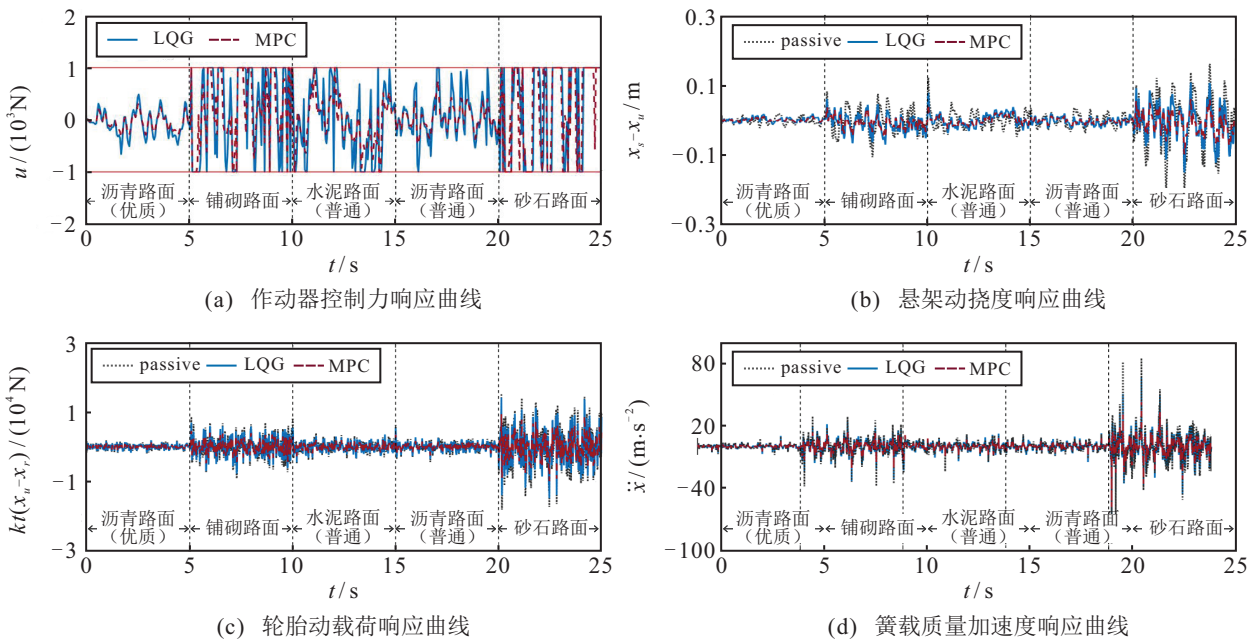


图14 各项性能指标响应曲线

缓了此现象,提升了汽车的驾驶安全性. 由图14(c)和图14(d)可知,相较于Passive和LQG控制,MPC控制的主动悬架具有更小的簧载质量加速度峰值,有效抑制了路面颠簸所导致的车身振动,减缓悬架系统对车身的高频冲击,改善了车辆的行驶平顺性. 并且MPC控制能够更好地处理车辆的操纵稳定性与行驶平顺性之间的矛盾,在改善平顺性的同时降低了轮胎动载荷,避免了垂直载荷过大导致的轮胎侧偏力减小现象,从而提升操纵稳定性.

各项性能指标均方根值对比如表6所示. 在优质和普通沥青路面上的主要控制目标为提高操纵稳定性和保障驾驶安全,此时MPC控制的主动悬

架轮胎动载荷均方根值相较于LQG控制分别降低38.89%和38.11%,车辆的操纵稳定性得到提升. 在行驶环境较差的铺砌路面和砂石路面上主要控制目标为改善车辆的行驶平顺性,此时MPC控制的簧载质量加速度均方根值相较于LQG控制分别降低37.79%和39.56%,并且悬架动挠度分别降低32.25%和38.91%,车辆的行驶平顺性和驾驶安全性均得到改善. 综合上述分析,基于路面状态识别的MPC控制系统在多种路面均可有效降低悬架动挠度、轮胎动载荷和簧载质量加速度的均方根值,实现了车辆操纵稳定性和行驶平顺性的协调优化,有效提升了悬架系统的综合性能.

表6 各项性能指标均方根值对比

系统类型	指标	沥青路面 (优质)	铺砌路面	水泥路面 (普通)	沥青路面 (普通)	砂石路面	平均值
Passive	$\ddot{x}_s/(m \cdot s^{-2})$	1.8073	7.7096	4.4047	3.2632	15.4466	6.5263
	$x_s - x_u/m$	0.0087	0.0343	0.0245	0.0161	0.0743	0.0316
	$k_t(x_u - x_r)/N$	877.5	3829.0	2285.8	1611.1	7045.7	3129.8
LQG (相比Passive)	$\ddot{x}_s/(m \cdot s^{-2})$	1.5476 (-14.37%)	6.7023 (-13.07%)	3.9699 (-9.87%)	2.9328 (-10.13%)	12.6945 (-17.82%)	5.5694 (-13.05%)
	$x_s - x_u/m$	0.0066 (-23.54%)	0.0259 (-24.53%)	0.0176 (-28.12%)	0.0101 (-37.19%)	0.0506 (-31.94%)	0.0222 (-29.06%)
	$k_t(x_u - x_r)/N$	755.0 (-13.96%)	3323.6 (-13.20%)	2019.8 (-11.64%)	1394.8 (-13.43%)	5844.0 (-17.06%)	2667.4 (-13.86%)
MPC (相比LQG)	$\ddot{x}_s/(m \cdot s^{-2})$	1.0122 (-34.60%)	4.1693 (-37.79%)	2.5482 (-35.81%)	1.9052 (-35.04%)	7.6730 (-39.56%)	3.4616 (-36.56%)
	$x_s - x_u/m$	0.0044 (-33.78%)	0.0175 (-32.35%)	0.0121 (-31.07%)	0.0072 (-28.85%)	0.0309 (-38.91%)	0.0144 (-32.99%)
	$k_t(x_u - x_r)/N$	461.4 (-38.89%)	2149.3 (-35.33%)	1267.0 (-37.27%)	863.2 (-38.11%)	3986.5 (-31.78%)	1745.5 (-36.28%)

4 结论

本文提出了一种基于ResNeSt网络路面状态识别的主动悬架模型预测控制方法. 根据所采集的7种路面状态信息对所设计基于ResNeSt网络的路面状态识别算法进行训练和测试实验,准确率在98.61%以上,连续帧测试的每帧平均识别时间为25.62ms. 在此基础上设计基于路面状态识别的主动悬架MPC控制算法,推导主动悬架MPC预测模型,设定不同路面的控制目标及悬架系统的约束条件,根据各路面状态的不平度信号对算法的可行性和有效性进行对比仿真分析. 所设计算法相较于LQG控制系统,簧载质量加速度、悬架动挠度和轮胎动载荷的均方根值平均值分别降低36.56%、32.99%和36.28%,有效提升了悬架系统的综合性能.

参考文献(References)

[1] Chen Q P, Xie Y F, Guo S F, et al. Sensing system of environmental perception technologies for driverless

vehicle: A review of state of the art and challenges[J]. Sensors and Actuators A: Physical, 2021, 319: 112566.

[2] 尹慧琳, 伍淑莉, 王亚伟, 等. 基于层次因子图的智能车环境感知和态势认知模型[J]. 控制与决策, 2020, 35(10): 2528-2534.
(Yin H L, Wu S L, Wang Y W, et al. An intelligent vehicle environment perception and situation cognition model based on hierarchical factor graph[J]. Control and Decision, 2020, 35(10): 2528-2534.)

[3] Zhu H, Yuen K V, Mihaylova L, et al. Overview of environment perception for intelligent vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(10): 2584-2601.

[4] 卢健, 贾旭瑞, 周健, 等. 基于深度学习的三维点云分割综述[J]. 控制与决策, 2023, 38(3): 595-611.
(Lu J, Jia X R, Zhou J, et al. A review of deep learning based on 3D point cloud segmentation[J]. Control and Decision, 2023, 38(3): 595-611.)

[5] Rateke T, Justen K A, Chiarella V F, et al. Passive vision region-based road detection: A literature review[J]. ACM

- Computing Surveys, 2019, 52(2): 31.
- [6] 孔玮, 刘云, 李辉, 等. 基于深度学习的行人轨迹预测方法综述[J]. 控制与决策, 2021, 36(12): 2841-2850. (Kong W, Liu Y, Li H, et al. Survey of pedestrian trajectory prediction methods based on deep learning[J]. Control and Decision, 2021, 36(12): 2841-2850.)
- [7] Zhao L, Yu Y, Zhou C, et al. A hydraulic semi-active suspension based on road statistical properties and Its road Identification[J]. Applied Sciences-Basel, 2018, 8(5): 740.
- [8] Wang S, Lu Z, Liu X, et al. Active control of hydropneumatics suspension parameters of wheel loaders based on road condition identification[J]. International Journal of Advanced Robotic Systems, 2018, 15(6): 1725.
- [9] Wang Z, Dong M, Qin Y, et al. Suspension system state estimation using adaptive Kalman filtering based on road classification[J]. Vehicle System Dynamics, 2017, 55(3): 371-398.
- [10] Čerškus A, Lenkutis T, Šešok N, et al. Identification of road profile parameters from vehicle suspension dynamics for control of damping[J]. Symmetry, 2021, 13(7): 1149.
- [11] Li Y, Yong B, Wu H Y, et al. Road detection from airborne LiDAR point clouds adaptive for variability of intensity data[J]. Optik, 2015, 126(23): 4292-4298.
- [12] Asvadi A, Premevida C, Peixoto P, et al. 3D Lidar-based static and moving obstacle detection in driving environments: An approach based on voxels and multi-region ground planes[J]. Robotics and Autonomous Systems, 2016, 83(6): 299-311.
- [13] Theunissen J, Sornioti A, Gruber P, et al. Regionless explicit model predictive control of active suspension systems with preview[J]. IEEE Transactions on Industrial Electronics, 2019, 67(6): 4877-4888.
- [14] 王世峰, 都凯悦, 孟颖, 等. 基于机器学习的车辆路面类型识别技术研究[J]. 兵工学报, 2017, 38(8): 1642-1648. (Wang S F, Du K Y, Meng Y, et al. Machine learning-based road terrain recognition for land vehicles[J]. Acta Armamentarii, 2017, 38(8): 1642-1648.)
- [15] Cheng L S, Zhang X, Shen J. Road surface condition classification using deep learning[J]. Journal of Visual Communication and Image Representation, 2019, 64: 102638.
- [16] Dewangan D K, Sahu S P. RCNet: Road classification convolutional neural networks for intelligent vehicle system[J]. Intelligent Service Robotics, 2021, 14(2): 199-214.
- [17] Nolte M, Kister N, Maurer M. Assessment of deep convolutional neural networks for road surface classification[C]. The 21st International Conference on Intelligent Transportation Systems. Piscataway: IEEE, 2018: 381-386.
- [18] Sun J W, Cong J Y. Deep learning based road recognition for intelligent suspension systems[J]. Journal of Theoretical and Applied Mechanics, 2021: 493-508.
- [19] Alex K, Ilya S, Geoffrey E H. Image net classification with deep convolutional neural networks[C]. Proceedings of the 26th Conference on Neural Information Processing Systems. Piscataway: IEEE, 2012: 1106-1114.
- [20] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[C]. Proceedings of the 3rd International Conference on Learning Representations. Piscataway: IEEE, 2015: 1-8.
- [21] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]. IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2015: 1-9.
- [22] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 770-778.
- [23] Zhang H, Wu C R, Zhang Z Y, et al. ResNeSt: Split-attention networks[J/OL]. 2020, arXiv: 2004.08955.
- [24] Ruder S. An overview of gradient descent optimization algorithms[J/OL]. 2016, arXiv: 1609.04747.
- [25] Mai V N, Yoon D S, Choi S B, et al. Explicit model predictive control of semi-active suspension systems with magneto-rheological dampers subject to input constraints[J]. Journal of Intelligent Material Systems and Structures, 2020, 31(9): 1157-1170.
- [26] 寇发荣, 高亚威, 景强强, 等. 基于路面等级自适应的主动悬架LQG控制[J]. 振动与冲击, 2020, 39(23): 30-37. (Kou F R, Gao Y W, Jing Q Q, et al. LQG control of active suspension based on adaptive road surface level[J]. Journal of Vibration and Shock, 2020, 39(23): 30-37.)

作者简介

寇发荣(1973—), 男, 教授, 博士生导师, 从事车辆系统动力学、振动控制与能量回收、智能车辆与智能控制技术等研究, E-mail: koufarong@xust.edu.cn;

胡凯仑(1998—), 男, 硕士生, 从事车辆智能悬架路面识别与主动控制的研究, E-mail: 1981873870@qq.com;

陈若晨(1997—), 男, 硕士生, 从事车辆主动悬架容错控制的研究, E-mail: 1017503711@qq.com;

何海洋(1998—), 男, 硕士生, 从事车辆智能决策与路径规划的研究, E-mail: 2413588148@qq.com.