

基于在线学习的车辆经济自适应巡航控制

司明玉,周金应,褚观耀,龙军,程前
(中国汽车工程研究院股份有限公司,重庆 401122)

摘要:设计一种经济自适应巡航控制器,用于降低道路车辆在跟随过程中的燃油消耗,提高行车安全。基于执行依赖启发式动态规划的方法控制车轮牵引力,从而保证安全行车所需的车辆间距。提出一种在线换挡控制策略来调整发动机的工作点,以改善发动机的燃油经济性。所提出的控制策略不依赖于车辆模型,可以适应不同的行驶工况。为验证控制器的有效性,分别进行城市道路循环工况和高速公路燃油经济性的仿真试验。仿真结果表明:该系统具有良好的速度跟踪性能和较高的燃油经济性。

关键词:自适应巡航;神经网络;动态规划

中图分类号:TP273+.2 **文献标志码:**B **文章编号:**1671-5276(2021)06-0211-05

Adaptive Cruise Control for Vehicle Economy Based on Online Learning

SI Mingyu, ZHOU Jinying, CHU Guanyao, LONG Jun, CHENG Qian

(China Automotive Engineering Research Institute Co., Ltd., Chongqing 401122, China)

Abstract: An economic adaptive cruise controller is designed to reduce the fuel consumption of road vehicles during the following process and improve driving safety. The method of implementing dependent heuristic dynamic programming is used to control the wheel traction, so as to ensure the necessary vehicle spacing for safe driving. An on-line shift control strategy is proposed to adjust the working point of the engine to improve its fuel economy. The proposed control strategy does not depend on the vehicle model and can adapt to different driving conditions. To verify the effectiveness of the controller, the simulation tests of urban road cycling conditions and highway fuel economy are carried out respectively. The formulation results show that the system has good speed tracking performance and higher fuel economy.

Keywords: adaptive cruise control; neural network; dynamic programming

0 引言

自适应巡航控制系统作为一种先进的驾驶辅助系统,可以实时控制自车与前车的距离,显著提高了道路车辆的行驶安全性,受到了广泛的关注。文献[1-2]研究了自适应巡航控制的经济性,采用基于动态规划的算法,兼顾了安全与节油。文献[3]提出了基于多目标优化的模型预测控制算法,以提高车辆跟随工况下的燃油经济性和跟随性能。文献[4]设计了一种鲁棒的自适应巡航控制器,用于改善车辆加速度和换挡策略,使车辆在不同交通状况下都能保持良好的燃油经济性,但由于换挡策略是离线设计的,无法保证发动机处于最佳工作点。文献[5-6]采用脉冲滑模控制方法,使发动机在高效率的区域工作,可有效降低车辆行驶时的燃油消耗。文献[7-8]将道路坡度和车距信息加入到控制系统,优化了车辆的加速度输出,可改善车辆的燃油经济性。

综上所述,针对自适应巡航控制的研究日益得到重视,但对于如何基于车辆的动力响应特性,实现安全与节油的协同控制并兼顾控制的最优性,还有待进一步研究。

本文以自适应巡航控制器为研究对象,在分析其结构

与特性的基础上,提出一种基于在线学习的经济自适应巡航控制器,该控制器可以同时实现换挡控制和牵引力控制,以提高燃油经济性和行驶安全性。基于执行依赖启发式动态规划(ADHDP)方法得到车轮牵引力,控制车辆速度,确保安全行驶。通过设定换挡控制策略,调整发动机工作点,从而提高车辆的燃油经济性。

本文设计的经济自适应巡航控制器的主要优点有:1)所提出的控制方法是基于在线学习的,不依赖于车辆动力学模型,可以适应不同的行驶工况;2)将牵引力与换挡控制相结合,兼顾车辆的燃油经济性和行车安全性,可实现在线计算。

1 系统动力学建模

本文研究的汽车跟随过程如图1所示。 v_p 和 v_h 分别表示前车和自车速度, L 为两车的实际距离,可以通过雷达传感器等测得。在跟随前车过程中,自车在自适应巡航控制器的作用下,保持期望的安全距离 L_{des} 行驶。

1.1 纵向动力学模型

自车的纵向动力学模型如式(1)所示。




图1 跟车工况

$$\begin{aligned} \dot{x}_h &= v_h \\ \dot{v}_h &= a_h \end{aligned} \quad (1)$$

$$a_h = \frac{F_t}{m} - \frac{\rho A C_d v_h}{2m} - g f \cos \alpha = g \sin \alpha$$

其中: F_t 是车轮的牵引力,当 $F_t < 0$ 时,表示其为制动力; ρ 为空气密度; A 为车身迎风面积; C_d 为空气阻力系数; m 为车辆质量; f 为滚动阻力系数; α 为路面坡度。

1.2 发动机模型

燃油消耗率如图2所示。燃油消耗率是发动机转矩 T_e 和发动机转速 ω_e 的非线性函数,可表示为

$$\dot{m}_f = f(T_e, \omega_e) \quad (2)$$




图2 燃油消耗率图

1.3 传动系统模型

自车采用自动机械传动 (AMT), 将发动机转矩传递到车轮上, 以满足行驶动力要求, 发动机和车轮的速度和转矩关系分别由下式确定:

$$\begin{aligned} \omega_e &= \frac{v_h}{r_w} i_g(g) \\ T_e &= \frac{F_t r_w \eta_g}{i_g(g)} \quad F_{\text{trac}} > 0 \end{aligned} \quad (3)$$

其中: i_g 为齿轮位置 g 对应的传动比; r_w 为车轮半径; η_g 为传动效率。

AMT 中的换挡策略决定了齿轮传动比, 并以此调整发动机的工作点。为了避免跳跃式换挡所带来的车辆舒适性变差的问题, 仅允许顺序换挡。设计的换挡策略根据上一时刻的齿轮位置 $g(t-1)$ 来控制当前时间步长的齿轮位置 $g(t)$, 并且根据如下的动态模型来发出换挡指令:

$$g(t) = g(t-1) + u_g(t) \quad (4)$$

其中: u_g 属于集合 $\{-1, 0, 1\}$, -1 表示下降, 1 表示上升, 0 表示保持不变。

在车辆跟随情况下, 经济自适应巡航控制的目标有两

个: 最低燃油消耗率和为了保证安全行驶所需的期望车辆间距 L_{des} 。车辆距离偏差定义为 $\Delta L = L - L_{\text{des}}$, 相对速度偏差定义为 $\Delta v = v_p - v_h$, L_{des} 的表达式如下:

$$L_{\text{des}} = \tau_h v_h + d_0 \quad (5)$$

其中: τ_h 是采样时间间隔; d_0 是静止距离。

车辆距离偏差 ΔL 和相对速度偏差 Δv 的动态模型可以表示为:

$$\begin{aligned} \dot{\Delta L} &= v_p - v_h - \tau_h a_h \\ \dot{\Delta v} &= a_p - a_h \end{aligned} \quad (6)$$

其中 a_p 是前车加速度。

通过车辆距离偏差和车速偏差来评价车辆跟车工况下的跟踪性能, 为了改善燃油经济性和跟踪性能, 设置目标函数为

$$J = \int_0^{T_{\text{cyc}}} (\Delta L^2 + \Delta v^2 + \dot{m}_f) dt \quad (7)$$

其中 T_{cyc} 是车辆的行驶里程。

经济自适应巡航控制的最优问题是综合考虑经济和安全指标, 求解控制变量 $u = [F_t, u_g]^T$, 使得目标函数式(7)最小。因此, 设置如下的约束条件:

$$\begin{aligned} a_{\min} &\leq a_h \leq a_{\max} \\ \Delta L_{\min} &\leq \Delta L \leq \Delta L_{\max} \\ \Delta v_{\min} &\leq \Delta v \leq \Delta v_{\max} \\ T_{e, \min} &\leq T_e \leq T_{e, \max} \\ \omega_{e, \min} &\leq \omega_e \leq \omega_{e, \max} \\ i_g &\in \{i_{g1}, i_{g2}, i_{g3}, i_{g4}, i_{g5}\} \end{aligned} \quad (8)$$

2 经济自适应巡航控制器设计

本节介绍基于 Actor-Critic 结构的自适应动态规划 (ADP), 并讨论其在经济自适应巡航控制中的应用。

2.1 ADP 简述

ADP 作为强化学习的一种主要变体, 是一种基于学习的控制方法, 它根据与环境的交互进行决策。

如图3所示的 Actor-Critic 结构, 从 Actor 网络中可生成一个行为, 并使用 Critic 网络进行评估, 得到一个增强信号。通过最小化从 Critic 网络获得的值来改善控制策略。ADP 通常可以在不依赖系统模型的情况下, 在线近似地求解最优控制问题^[9]。




图3 Actor-Critic 结构

设有如下非线性离散时间系统:

$$V(x_t) = \sum_{i=t}^{\infty} \beta^{i-t} r(x_i, u_i) = \sum_{i=t+1}^{\infty} \beta^{i-(t+1)} r(x_i, u_i) + r(x_t, u_t) = r(x_t, u_t) + \beta V(x_{t+1}) \quad (9)$$

其中 $0 < \beta < 1$; $r(x_i, u_i)$ 是根据控制输入 u_i 和状态量 x_i 得到的瞬时值。

$u_i = h(x_i)$ 的贝尔曼最优方程如下:

$$V^*(x_t) = \min_{h(\cdot)} [r(x_t, h(x_t)) + \beta V^*(x_{t+1})] \quad (10)$$

由式(10)可得

$$h^*(x_t) = \operatorname{argmin} [r(x_t, h(x_t)) + \beta V^*(x_{t+1})] \quad (11)$$

1) Critic 网络和在线学习

如图4所示, $\hat{V}(x_t)$ 是一个由 m 维状态向量 x_t 和 n 维动作向量 u_t 形成的非线性映射, Critic 网络通过 $\hat{V}(x_t)$ 来近似求解最优目标函数。

$w_c^{(1)}(t)$ 是输入神经元到隐藏神经元的加权矩阵, 每个隐藏神经元 k 的所有输入加权和为

$$\sigma_{ck}(t) = \sum_{i=1}^m w_{cki}^{(1)}(t) x_{it} + \sum_{j=1}^n w_{ckj}^{(1)}(t) u_{jt}$$

由于双曲正切函数 $\phi(x) = \frac{1-e^{-x}}{1+e^{-x}}$ 比线性基函数能更准确地平滑逼近非线性函数, 因此可采用该函数作为隐藏神经元的激活函数。每个隐藏神经元的输出为

$$\phi(\sigma_{ck}(t)) = \frac{1-e^{-\sigma_{ck}(t)}}{1+e^{-\sigma_{ck}(t)}}, \text{隐藏层到输出神经元的权矩阵为}$$

$$w_c^{(2)}, \text{最终计算得到 Critic 网络的输出 } \hat{V} = w_c^{(2)}(t) q_c(t) = \sum_{k=1}^{N_{ch}} w_c^{(2)}(t) q_{ck}(t)。$$




图4 Critic 网络的结构

Critic 网络的误差函数定义为估计值与实际值之间的误差, 如下所示:

$$e_c(t) = \hat{V}(x_t) - [\hat{V}(x_{t-1}) - r(t)] \quad (12)$$

其中 $r(t)$ 为外部增强信号。

Critic 网络的学习目标是通过更新参数 w_c , 使误差函数 $e_c(t)$ 最小化, 如下所示:

$$\min_{w_c} E_c(t) = \min_{w_c} \frac{1}{2} e_c^2(t) \quad (13)$$

基于链推导规则的梯度下降自适应算法可用于更新权重, 得到修正的权重为^[10]:

$$w_c(t+1) = w_c(t) + \Delta w_c(t)$$

$$\Delta w_c(t) = \eta_c(t) \left[-\frac{\partial E_c(t)}{\partial w_c(t)} \right]$$

$$\frac{\partial E_c(t)}{\partial w_c(t)} = \frac{\partial E_c(t)}{\partial e_c(t)} \cdot \frac{\partial e_c(t)}{\partial V(t)} \cdot \frac{\partial \hat{V}(t)}{\partial w_c(t)} \quad (14)$$

其中 $\eta_c(t)$ 是 Critic 网络的学习速率。

2) Action 网络与在线学习

采用三层网络作为 Action 网络, 以接近于输入为状态向量 x_t , 输出为动作向量 u_t 的控制策略。隐藏层包含具有双曲正切传递函数的 N_{ah} 神经元。将 $w_a^{(1)}$ 定义为输入神经元到隐藏神经元的加权矩阵, 每个隐藏神经元 k 的值为

$$\sigma_{ak}(t) = \sum_{i=1}^m w_{aki}^{(1)} x_{it}, \text{每个隐藏神经元的输出为 } q_{ak}(t) =$$

$$\phi(\sigma_{ak}(t)) = \frac{1-e^{-\sigma_{ak}(t)}}{1+e^{-\sigma_{ak}(t)}}。 \text{每个输出节点的输入为 } u_j(t) =$$

$$\sum_{k=1}^{N_{ah}} w_{abj}^{(2)}(t) q_{ak}(t), \text{其中 } w_a^{(2)} \text{ 是隐藏神经元到输出神经元的加权向量。最终 Action 网络的输出是动作变量的 } n \text{ 维}$$

向量, 其中 $u_j(t) = \frac{1-e^{-u_j(t)}}{1+e^{-u_j(t)}}, j=1, 2, \dots, n。$

系统的状态作为输入变量, Action 网络通过调整权重 w_a 使 \hat{V} 最小化, 从而生成最优控制。因此, 学习目标可以定义为

$$\min_{w_a} E_a(t) = \min_{w_a} \hat{V}(t) \quad (15)$$

Action 网络的训练和 Critic 网络类似, 其权重如下所示:

$$w_a(t+1) = w_a(t) + \Delta w_a(t)$$

$$\Delta w_a(t) = \eta_a(t) \left[-\frac{\partial E_a(t)}{\partial w_a(t)} \right] \quad (16)$$

$$\frac{\partial E_a(t)}{\partial w_a(t)} = \frac{\partial E_a(t)}{\partial \hat{V}(t)} \cdot \frac{\partial \hat{V}}{\partial u_t} \cdot \frac{\partial u_t}{\partial w_a(t)}$$

其中 $\eta_a(t)$ 是 Action 网络的学习速率。

2.2 经济自适应巡航控制

经济自适应巡航控制的目标是保持与前车的安全距离, 并且使相同时间内的燃油消耗最小。通过调整牵引力 F_t 来控制自车的速度, 使其跟随前车安全行驶, 并由最优换挡控制 u_g 来调整发动机工作点, 总体控制算法如图5所示。

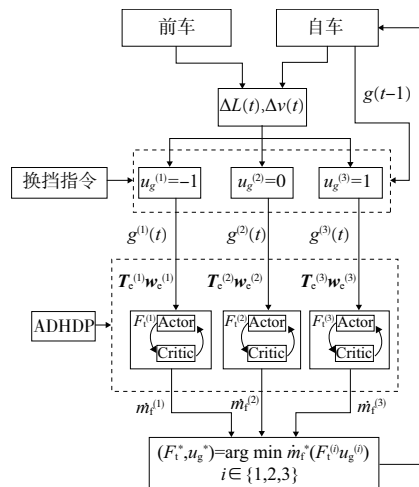


图5 控制算法

假设已经测得车辆距离偏差 ΔL 和车速偏差 Δv , 在每个时间步长, 可以从集合 $\{-1, 0, 1\}$ 选择换挡指令 u_g 。由式(3)和式(4)可得 u_g 对应的发动机转矩和发动机转速。牵引力 F_t 可由 Action 网络中的 ADHDP 方法计算得到。

选取 ADHDP 的状态变量为 $x = [\Delta L(t), \Delta v(t)]^T$, 将增强信号定义为 $r = \Delta L^2(t) + \Delta v^2(t) + m_t(t)$, 使式(7)的目标函数最小化。在自主学习过程中, 利用 Action 网络得到牵引力 F_t 的最优控制策略。通过比较各个换挡指令的燃油消耗率, 可以获得最优牵引力 F_t^* 和产生最小燃料消耗的最优换挡指令 u_g^* 。

在学习过程开始时, Critic 和 Action 网络的参数在 $[0, 0.4]$ 中随机选取。在每一个时间步长中, 利用 Critic 网络对式(13)进行迭代。迭代停止判据为最大迭代次数 N_c 和容差 T_c 。如果迭代满足任意一个条件, 则停止迭代过程, 并从 Critic 网络中导出近似值函数。同理, 利用 Action 网络对式(15)进行迭代, 迭代停止判据为最大迭代次数 N_a 和容差 T_a , 当满足任意一个条件时, 停止迭代过程, 并从 Action 网络中导出最优牵引力和换挡指令, 最终应用于车辆。

3 仿真测试及有关分析

针对城市道路和高速公路的行驶场景, 对所提出的控制方法进行了仿真。仿真参数如表 1 所示。

表 1 仿真参数

N_{ah}	N_{ch}	η_a	η_c	N_a	N_c	T_a	T_c
20	20	5×10^{-5}	10^{-3}	20	20	10^{-8}	10^{-8}

3.1 城市道路循环工况仿真

针对城市道路循环工况 (UDDS) 进行了经济自适应巡航控制器的仿真。前 300 s 的仿真结果如图 6 所示, 自车的速度曲线与前车的速度曲线非常接近, 距离偏差保持在 $-2 \text{ m} \sim 2 \text{ m}$ 的范围内, 这表明车辆具有良好的跟踪性能和安全性。车辆的加速度 $< 2 \text{ m/s}^2$, 可保证良好的乘坐舒适性。





图 6 城市道路循环工况 (UDDS) 仿真

与文献[11]中给出的基于规则控制策略产生的档位相比, 获得了更高的档位, 这有利于发动机燃油经济性。

UDDS 工况仿真的燃油消耗量如表 2 所示。相比本文提出的换挡策略, 基于规则的换挡控制方法的燃油消耗率要高出 23.3%。另外, 在仿真过程中, 前车所消耗的燃油量比同一档位的自车多 3.7% 左右。由此表明, 本文设计的经济自适应巡航控制器不仅能保证行车安全, 而且能够提高燃油经济性。

表 2 UDDS 仿真燃油消耗量对比

车辆	换挡	油耗/g	幅值/%
自车	在线换挡	396.7	—
自车	基于规则	489.1	+23.3
前车	在线换挡	411.4	+3.7

3.2 高速公路燃油经济性测试仿真

高速公路燃油经济性测试 (HWFET) 工况前 300 s 仿真结果如图 7 所示。自车的速度可以很好地跟随前车的速度, 使得车距偏差的变化范围很小, 并保持安全行车所需的车辆间距。

车辆行驶过程中, 加速度始终处于小范围内, 因此可以保证车辆具有良好的舒适性。相对于基于规则的控制策略, 本文所提出的换挡方案能够产生更高的档位调节发动机工作点, 从而改善车辆的燃油经济性。




图 7 HWFET 仿真

表3给出了高速公路燃油经济性测试的仿真燃油消耗量。基于规则的控制方案燃油消耗比本文所提出的换挡策略高3.8%,并且,与相同换挡控制的前车相比,自车的燃油消耗少0.7%。

表3 HWFET 仿真燃油消耗量对比

车辆	换挡	油耗/g	幅值/%
自车	在线换挡	537.2	—
自车	基于规则	557.4	+3.8
前车	在线换挡	540.9	+0.7

4 结语

本文基于车辆纵向动力学特性分析与辨识,设计了一种兼顾安全与节油的车辆经济自适应巡航控制器。采用执行依赖启发式动态规划(ADHDP)方法控制车轮的牵引力,实现跟车功能。通过设置在线换挡策略来调整发动机工作点,从而改善车辆的燃油经济性。通过仿真对比,验证了系统的有效性,得出如下结论:

1)基于在线学习的经济自适应巡航控制器,在保证安全跟车的前提下,改善车辆的燃油经济性。仿真结果表明,该控制器实现了车辆的安全与节油的协同优化。

2)设计的控制器无需模型,通过在线计算可以适应不同的行驶工况,在兼顾最优性的同时,能够保证控制的实时性。

参考文献:

- [1] BORIBOONSOMSIN K, VU A, BARTH M. Eco-driving: pilot evaluation of driving behavior changes among US drivers [J]. University of California Transportation Center, 2010
- [2] SIVAK M, SCHOETTLE B. Eco-driving: strategic, tactical, and operational decisions of the driver that influence vehicle fuel

economy [J]. Transport Policy, 2012, 22:96-99.

- [3] LI S B, LI K Q, RAJAMANI R, et al. Model predictive multi-objective vehicular adaptive cruise control [J]. IEEE Transactions on Control Systems Technology, 2011, 19(3):556-566.
- [4] SHAO Y L, SUN Z X. Robust eco-cooperative adaptive cruise control with gear shifting [C]//2017 American Control Conference (ACC). Seattle, WA, USA: IEEE, 2017: 4958-4963.
- [5] LI S E, PENG H E, LI K Q, et al. Minimum fuel control strategy in automated car-following scenarios [J]. IEEE Transactions on Vehicular Technology, 2012, 61(3):998-1007.
- [6] XU S B, LI S E, ZHANG X W, et al. Fuel-optimal cruising strategy for road vehicles with step-gear mechanical transmission [J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(6): 3496-3507.
- [7] KAMAL M A S, MUKAI M, MURATA J, et al. Ecological vehicle control on roads with up-down slopes [J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(3):783-794.
- [8] LIM H, SU W C, MI C C. Distance-based ecological driving scheme using a two-stage hierarchy for long-term optimization and short-term adaptation [J]. IEEE Transactions on Vehicular Technology, 2017, 66(3):1940-1949.
- [9] LEWIS F L, VRABIE D. Reinforcement learning and adaptive dynamic programming for feedback control [J]. IEEE Circuits and Systems Magazine, 2009, 9(3):32-50.
- [10] SI J, WANG Y T. Online learning control by association and reinforcement [J]. IEEE Transactions on Neural Networks, 2001, 12(2):264-276.
- [11] MARKEL T, BROOKER A, HENDRICKS T, et al. Advisor: a systems analysis tool for advanced vehicle modeling [J]. Journal of Power Sources, 2002, 110(2):255-266.

收稿日期:2020-09-15

(上接第201页)

2)设计了抛丸机实时状态监测系统架构,确定了合理的传感器固定位置。

3)选取冲击特征敏感的峭度指标和反映轴承故障严重程度度的方均根指标作为轴承健康状态指标,设置合理的阈值,对主轴支撑轴承进行实时监测和分析,通过实例验证了方案的可行性,可以实现基于设备状态的维修,提高了生产平稳性和效率。

参考文献:

- [1] WANG S R, SONG L H, QIAO Y, et al. Effect of carbide orientation on impact-abrasive wear resistance of high-Cr iron used in shot blast machine [J]. Tribology Letters, 2013, 50(3): 439-448.
- [2] 黄强. 抛丸机故障分析及改进 [J]. 冶金设备, 2017(2):64-67.
- [3] XUE C, HU Y. The small road surface shot blasting cleaning

machine design [J]. Advanced Materials Research, 2014, 1061/1062:858-861.

- [4] 文廉辉. Q7550 抛丸清理机的改进 [J]. 中国铸造装备与技术, 2002(1):49.
- [5] 黄轶春, 黄军宜, 陈康, 等. 提升抛丸机设备可靠性的方法研究 [J]. 装备制造技术, 2019(6):166-169.
- [6] LI Y, CHENG G, LIU C. Research on bearing fault diagnosis based on spectrum characteristics under strong noise interference [J]. Measurement, 2021, 169:108509.
- [7] 何勇, 王红, 谷穗. 一种基于遗传算法的 VMD 参数优化轴承故障诊断新方法 [J]. 振动与冲击, 2021, 40(6):184-189.
- [8] 剡昌锋, 朱涛, 吴黎晓, 等. 基于马田系统的滚动轴承初始故障检测和状态监测 [J]. 振动与冲击, 2017, 36(12):155-162, 188.

收稿日期:2021-05-12