

基于BP神经网络的EHB主缸液压力估计*

史彪飞¹ 王磊² 梁海强² 李荣利² 梁超²

(1.清华大学,北京 100084;2.北京汽车研究总院有限公司,北京 101300)

【摘要】电子液压制动(EHB)系统主缸液压力估计对降低EHB的传感器依赖性至关重要,基于BP神经网络进行主缸液压力估计。首先开展了实车道路试验,并采集车速、主缸活塞位移、主缸活塞速度和主缸液压力等数据。然后,以主缸活塞位移和主缸活塞速度为特征输入、以实际主缸液压力为目标输出建立BP神经网络,并采用训练集数据及梯度下降算法对BP神经网络进行训练。最后,利用测试集数据对液压力估计效果进行验证。结果表明,所提算法比基于动态位移压力模型和基于LSTM的估计算法估计误差分别减小38%和15%。

关键词:电子液压制动 主缸液压力估计 位移压力模型 BP神经网络

中图分类号:U461 文献标志码:A DOI: 10.19620/j.cnki.1000-3703.20240045

BP Neural Network-Based Master Cylinder Pressure Estimation for EHB

Shi Biaofei¹, Wang Lei², Liang Haiqiang², Li Rongli², Liang Chao²

(1. Tsinghua University, Beijing 100084; 2. Beijing Automotive Technology Center, Beijing 101300)

【Abstract】The master cylinder pressure estimation of the Electro-Hydraulic Brake (EHB) system is crucial to reduce the sensor dependence of EHB. In this paper, the master cylinder pressure is estimated based on BP neural network. First, a real-vehicle road test is carried out and data such as vehicle speed, master cylinder piston displacement, master cylinder piston speed and master cylinder pressure are collected. Second, a BP neural network is established using the master cylinder piston displacement and master cylinder piston speed as feature inputs and the real master cylinder pressure as target output. Third, the BP neural network is trained by the training dataset and gradient-descent algorithm. Finally, the pressure estimation performance is verified by the testing dataset. The results show that the proposed algorithm reduces the estimation error by 38% and 15%, compared with the dynamic pressure-displacement model and the LSTM-based estimation algorithm, respectively.

Key words: Electro-Hydraulic Brake (EHB), Master cylinder pressure estimation, Displacement-pressure model, BP neural network

【引用格式】史彪飞,王磊,梁海强,等.基于BP神经网络的EHB主缸液压力估计[J].汽车技术,2025(1):57-62.

SHI B F, WANG L, LIANG H Q, et al. BP Neural Network-Based Master Cylinder Pressure Estimation for EHB[J]. Automobile Technology, 2025(1): 57-62.

1 前言

汽车线控制动(Brake-By-Wire, BBW)系统是汽车制动领域的研发热点^[1]。电子液压制动(Electro-Hydraulic Brake, EHB)系统是市场主流的BBW解决方案^[2]。

作为汽车的关键安全部件之一, EHB需要满足较高的汽车安全完整性等级(Automotive Safety Integrity

Level, ASIL)^[3]要求。EHB主缸液压力闭环控制依赖液压力传感器,一旦传感器失效,基于传感器的液压力控制系统将失效,严重影响EHB的功能安全性。因此,有必要研究主缸液压力估计算法,用于传感器的故障诊断及容错控制,从而降低EHB对液压力传感器的过度依赖,提升系统可靠性。

EHB保留了传统液压制动回路,主缸活塞位移与

*基金项目:山东省重点研发计划(2023CXGC010214)。

通信作者:史彪飞,清华大学车辆与运载学院博士后,主要研究方向为线控底盘、汽车动力学与控制。Email:1935792849@qq.com。

主缸液压力的关系称为位移压力特性。现有EHB的主缸液压力估计算法大多基于位移压力特性,液压力估计的关键在于精确的位移压力模型。

根据建模方法不同,现有位移压力模型可分为理论模型和经验模型。文献[4]对位移压力特性进行了理论研究,通过由制动回路变形表示的制动液等效体积弹性模量与含气制动液自身的等效体积弹性模量相等,得出了主缸活塞位移与液压力之间的数学关系。然而,该模型仅适用于主缸活塞缓慢运行的工况。由于位移压力特性复杂、难以进行精确的理论建模,现有研究更多的是直接基于试验数据将位移压力特性拟合为主缸活塞位移多项式的经验模型^[5-12]。然而该类模型只能表征增、减压位移压力曲线的平均值,而忽略了滞回特性。文献[13]定性分析了主缸活塞速度与滞回特性的关系,提出了一种动态位移压力模型,该模型在主缸活塞位移多项式的基础上引入主缸活塞速度,能在一定程度上表征滞回特性,试验表明,相比基于多项式的位移压力模型,动态位移压力模型具有更高的精度和响应速度。然而,该模型只能定性描述主缸活塞速度对滞回特性的影响,更精确的位移压力模型有待进一步研究。

由于神经网络具有以任意精度逼近任意非线性映射的能力^[14],本文以EHB为研究对象,针对位移压力特性建模及主缸液压力估计问题进行研究,开展实车道路试验,基于试验数据采用BP神经网络拟合位移压力特性并进行液压力估计,以进一步提高液压力估计精度。

2 EHB结构及工作原理

EHB原理如图1所示^[5],常规制动工况下,驾驶员踩下制动踏板,EHB控制器通过踏板行程传感器信号解析驾驶员制动需求,并通过液压力传感器反馈的实际液压力控制永磁同步电机输出适当的力矩,电机力矩通过减速机构推动主缸活塞往复运动,使制动回路中的液压力增大或减小,以此实现制动控制。

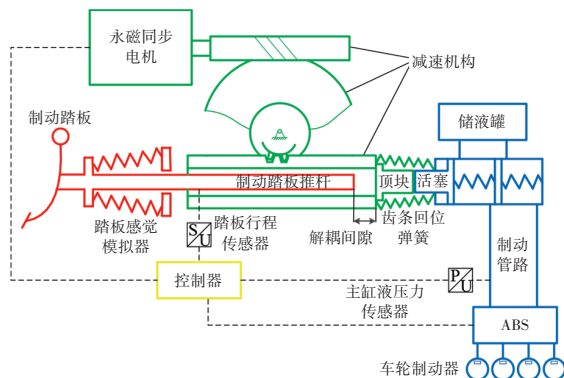


图1 电子液压制动系统原理


制动时,主缸活塞首先要越过主缸补油孔将制动回路密封,之后克服制动器间隙使制动衬片和制动盘贴合,继而压缩制动液使制动回路产生液压力^[4]。受间隙、制动软管及含气制动液等非弹性元件的影响,位移压力特性具有很强的非线性和滞回特性。另外,受防抱死制动系统(Anti-Lock Brake System, ABS)电磁阀节流特性的影响,位移压力特性还与制动速度有关^[15]。

3 位移压力特性测试及分析


为获取实际驾驶中真实的位移压力特性、保证所提方法的普适性,本文进行了实车道路试验并采集了试验数据。试验方法为由熟练驾驶员驾驶搭载EHB的试验车在一段约10 km的城郊公路上正常行驶,记录单程的实车数据。

试验车为纯电前驱SUV,整车质量为1 580 kg。试验车的制动能量回收功能处于关闭状态,制动力全部由EHB提供。试验车配备ABS,可由其得到车速信号。EHB永磁同步电机自带电机转子角位置传感器,可由其计算主缸活塞位移。EHB配备的主缸液压力传感器可采集实际主缸液压力信号。试验车及信号交互详见文献[16]。所采集的车速、主缸活塞位移、主缸活塞速度(由主缸活塞位移差分得到)和主缸液压力如图2所示,试验时长约1 300 s,数采周期为10 ms,共约130 000个采样点。


试验数据的车速范围约为0~120 km/h,主缸液压力范围约为0~10 MPa,从而涵盖了绝大部分制动工况(本文暂不考虑ABS触发的工况),如图3所示。




(a) 车速



(b) 主缸活塞位移



(c)主缸活塞速度(滤波后)



(d)主缸液压力

图2 实车试验数据




图3 位移压力特性

由于制动间隙的存在,主缸活塞位移在0~5 mm范围内时几乎没有液压力,当主缸活塞位移大于5 mm后,液压力随主缸活塞位移增大而增大,且呈现出非线性。从数据密集程度可知,通常情况下,制动液压力集中在3 MPa以内。另外,对于同一主缸活塞位移,增压时的液压力大于减压时液压力,即滞回特性。

由以上分析可知,主缸液压力与主缸活塞位移并非一一对应关系,因此只以主缸活塞位移作为输入对位移压力特性进行建模是不准确的。为此,引入主缸活塞速度分析位移-速度-液压力的关系,如图4所示。




图4 位移压力特性

从图4可看出,同时以主缸活塞位移和主缸活塞速度为输入,则主缸液压力与输入之间的一一对应关系更明显,为利用神经网络进行位移压力特性拟合做好了铺垫。

4 BP神经网络建立

本文根据位移压力特性的特点及对位移压力特性进行建模的需求,权衡模型精度和复杂度,选取精度高且计算量小的3层BP神经网络拟合位移压力特性^[14],如图5所示,包括1个输入层、1个隐含层和1个输出层。其中,输入层包括主缸活塞位移和主缸活塞速度,输出层为主缸液压力。

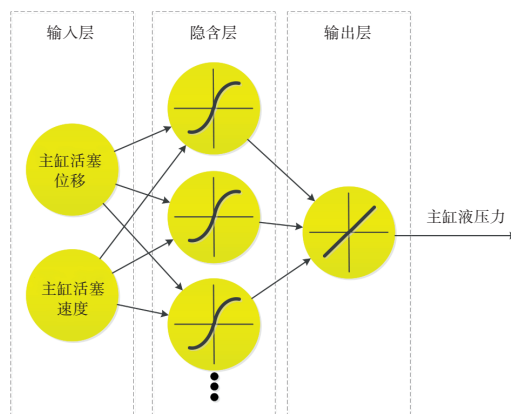


图5 BP神经网络

隐含层的神经元如图6所示。主缸活塞位移和主缸活塞速度通过加权求和和增加偏置转化为神经元的净输入,见式(1)。净输入经过激活函数的作用后成为单个神经元的输出,见式(2)。本文选取双曲正切函数作为激活函数,见式(3)。

$$n = \mathbf{x}\mathbf{w} + b \tag{1}$$

$$a = f(n) \tag{2}$$

$$f(\bullet) = \frac{e^{\bullet} - e^{-\bullet}}{e^{\bullet} + e^{-\bullet}} \tag{3}$$

式中: n 为神经元中间变量; $\mathbf{x} = [x \ \dot{x}]$, x 、 \dot{x} 分别为主缸活塞位移和速度; $\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \end{bmatrix}$ 为权重矩阵; b 为偏置; a 为神经元输出。

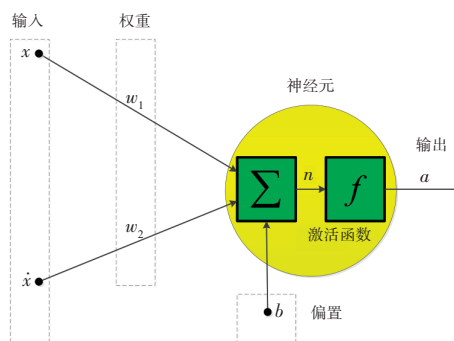


图6 隐含层神经元模型

隐含层各神经元的输出作为输出层神经元的输入,经过加权求和及增加偏置后,成为BP神经网络的最终输出。

5 BP神经网络训练

5.1 数据预处理

主缸活塞速度由主缸活塞位移差分得到(即相邻两个时刻的位移差除以时间间隔),存在很大噪声,直接用于神经网络会导致估计的液压力噪声较大,不利于故障诊断及容错控制。本文采用滤波器对主缸活塞速度的原始数据进行滤波,将滤波后的数据用于神经网络的训练。在使用训练好的神经网络时,先对主缸活塞速度的原始数据进行同样的滤波处理再输入到神经网络中。采用式(4)对其进行滤波。

$$\dot{x}(s) = \dot{x}_{\text{original}}(s) \frac{1}{\tau s + 1} \quad (4)$$

式中: s 为复变量; $\dot{x}_{\text{original}}$ 为原始主缸活塞速度; $\tau \in (0, +\infty)$ 为滤波器参数,其值越大,滤波后的信号越平稳,神经网络的输出也越平稳,同时,过大的滤波器参数会导致信号延迟和失真程度过大,降低神经网络的精度。

由于主缸液压力估计主要用于与实际主缸液压力进行对比,进而进行故障诊断,或者直接替换主缸液压力传感器进行容错控制,因此,在调试滤波器参数时,要保证神经网络的估计值的噪声不高于液压力传感器所采集的实际液压力的噪声。经过调试,取 $\tau = 0.1$,部分原始与滤波后的主缸活塞速度如图7所示。




图7 原始与滤波后的主缸活塞速度

5.2 数据划分及网络训练

将试验数据(主缸活塞位移、主缸活塞速度和主缸液压力)按照70%和30%的比例划分为训练集数据和测试集数据,分别用于网络训练和网络测试。采用标准BP算法进行训练,即以输入数据(主缸活塞位移、主缸活塞速度)前向传播、误差(网络输出值与实际主缸液压力的差值)反向传播、梯度计算及参数(权重和偏置)更新的方式循环迭代^[17]。

经过调试,本文将标准BP算法的误差函数设为均方误差,学习率设为0.001,不同隐含层神经元数量的神经网络训练结果如图8所示。

模型精度随隐含层神经元数量的变化而稍作波

动,隐含层神经元数量为40个时误差函数最低,为0.003 013。训练过程中误差函数随迭代次数变化如图9所示,当迭代次数为189时误差函数基本不再变化,停止训练,所需训练时间为42 s。




图8 隐含层神经元数量对模型精度的影响




图9 误差函数随迭代次数变化

6 液压力估计效果及分析

6.1 与动态位移压力模型对比

为验证基于BP神经网络的位移压力模型的估计精度,令其与动态位移压力模型进行对比。首先利用相同的训练集数据通过最小二乘算法^[13]对动态位移压力模型进行参数辨识。动态位移压力模型如下:

$$p = A + Bx + Cx^2 + Dx \quad (5)$$

式中: p 为主缸液压力; A 、 B 、 C 、 D 为模型参数,辨识结果分别为-1.261、-0.939 6、0.234 3、0.108 7。


利用相同的测试集数据,以主缸活塞位移和主缸活塞速度作为输入,分别测试基于BP神经网络模型的位移压力模型和动态位移压力模型的液压力估计精度,不同液压力下的估计结果如图10所示。

不同液压力下,2种位移压力模型均能较准确地估计主缸液压力,基于BP神经网络的位移压力模型估计精度更高,其与动态位移压力模型的均方根误差(Root Mean Square Error, RMSE)分别为0.050 32 MPa和0.081 50 MPa,降低了38%。另外,由图10e可知,基于BP神经网络的估计值的噪声小于实际值,从而证实了第5.1节中滤波器形式及滤波器参数选取的合理性。


6.2 与长短期记忆单元对比

本文另外开展了基于长短期记忆(Long-Short Term Memory, LSTM)单元进行位移压力特性建模及液压力估计的对比工作。LSTM是一种可以处理时序数据


的神经网络,通过其内部的门控结构可以学习数据的历史依赖关系。文献[18]通过实车试验采集了制动液压力、车速、加速度、电机电流、电机力矩、电池电压、SOC等信号,利用LSTM对当前时刻及对未来时刻的液压力进行估计和预测。




(a)最大液压力10 MPa




(b)最大液压力6.6 MPa



(c)最大液压力3.35 MPa



(d)最大液压力1.7 MPa



(e)最大液压力1.7 MPa(图4d的局部图)

图10 BP神经网络与动态位移压力模型的液压力估计效果

为验证LSTM用于位移压力特性建模及液压力估计的性能,并与所设计的BP神经网络进行对比,按照前述BP神经网络的网络结构设计LSTM的网络结构,不同的只是隐含层设置为40个LSTM单元。之后,采用相同的训练集数据进行训练,训练方法为带动量的随机梯度下降法,当误差函数基本不再变化时停止训练。最后,采用相同的测试集数据对基于LSTM的位移压力模型进行验证。为消除随机误差,进行了5次训练及验证,模型值与实际值的RMSE分别为0.067 99 MPa、0.068 10 MPa、0.081 78 MPa、0.059 46 MPa和0.081 94 MPa,最低值为0.059 46 MPa,大于BP神经网络模型的0.050 32 MPa。可见,虽然LSTM具有较强的时序数据处理能力,但对位移压力特性的拟合精度略低于BP神经网络。

7 结束语

本文以电子液压制动系统为研究对象,针对液压力估计中位移压力特性难以精确建模的问题开展研究。进行了实车道路试验,分析了位移压力特性,构建了以主缸活塞位移和主缸活塞速度为输入、液压力为输出的BP神经网络并基于试验数据进行训练。与以动态位移压力模型和LSTM为代表的基准模型相比,所提出的BP神经网络位移压力模型的主缸液压力估计误差分别减小了38%和15%,从而提高了液压力估计精度及EHB的可靠性。

参 考 文 献

- [1] MENG B M, YANG F F, LIU J G, et al. A Survey of Brake-By-Wire System for Intelligent Connected Electric Vehicles[J]. IEEE Access, 2020, 8: 225424-225436.
- [2] LI D, TAN C, GE W, et al. Review of Brake-By-Wire System and Control Technology[J]. Actuators, 2022, 11(3): 80.
- [3] 高云峰. 基于功能安全的线控底盘电液混合制动系统研究[D]. 长沙: 湖南大学, 2021.
GAO Y F. Research on Electro-Hydraulic Hybrid Braking System of Wire Control Chassis Based on Functional Safety[D]. Changsha: Hunan University, 2021.
- [4] 余卓平, 史彪飞, 卓桂荣, 等. 集成式电子液压制动系统位移压力特性理论研究[J]. 机械工程学报, 2022, 58(22): 294-303.
YU Z P, SHI B F, ZHUO G R, et al. Theoretical Research on Pressure-Position Relationship of the Integrated Electronic-hydraulic Brake System[J]. Journal of Mechanical Engineering, 2022, 58(22): 294-303.
- [5] GUANG X L, XIONG L, XU S Y, et al. Design and Experiment of Electro-Hydraulic Brake System[C]// 2014

- IEEE Conference and Expo Transportation Electrification Asia-Pacific (ITEC Asia-Pacific). Beijing: IEEE, 2014: 1-5.
- [6] HAN W, XIONG L, YU Z P. Pressure Estimation Algorithms in Decoupled Electro-Hydraulic Brake System Considering the Friction and Pressure-Position Relationship[J]. IEEE Transactions on Vehicular Technology, 2023(72): 1748-1762.
- [7] YONG J W, GAO F, DING N G, et al. Pressure-Tracking Control of A Novel Electro-Hydraulic Braking System Considering Friction Compensation[J]. Journal of Central South University, 2017, 24(8): 1909-1921.
- [8] ZHAO J, HU Z Q, ZHU B. Pressure Control for Hydraulic Brake System Equipped with An Electro-Mechanical Brake Booster[J]. SAE Technical Paper, 2018-01-0829, 2018.
- [9] HAN W, XIONG L, YU Z P et al. Adaptive Cascade Optimum Braking Control Based on A Novel Mechatronic Booster[J]. SAE Technical Paper, 2017-01-2514, 2017.
- [10] SHI Q, HE L. A Model Predictive Control Approach for Electro-Hydraulic Braking by Wire[J]. IEEE Transactions on Industrial Informatics, 2022, 19(2): 1380-1388.
- [11] HAN W, XIONG L, YU Z P. Braking Pressure Control in Electro-Hydraulic Brake System Based on Pressure Estimation with Nonlinearities and Uncertainties[J]. Mechanical Systems and Signal Processing, 2019, 131: 703-727.
- [12] HO L M, SATZGER C, DE CASTRO R. Fault-tolerant Control of An Electrohydraulic Brake Using Virtual Pressure Sensor[C]// 2017 International Conference on Robotics and Automation Sciences (ICRAS). Hong Kong, China: IEEE, 2017: 76-82.
- [13] SHI B F, XIONG L, YU Z P. Master Cylinder Pressure Estimation of the Electro-Hydraulic Brake System Based on Modeling and Fusion of the Friction Character and the Pressure-Position Character[J]. IEEE Transactions on Vehicular Technology, 2022, 72(2): 1748-1762.
- [14] AL-SHARMAN M, MURDOCH D, CAO D P, et al. A Sensorless State Estimation for A Safety-Oriented Cyber-Physical System in Urban Driving: Deep Learning Approach[J]. IEEE/CAA Journal of Automatica Sinica, 2020, 8(1): 169-178.
- [15] 史彪飞,熊璐,刘洋,等.考虑主、轮缸液压力差异的制动增强控制[J].同济大学学报(自然科学版),2022,50(11):1667-1675.
- SHI B F, XIONG L, LIU Y, et al. Braking Enhancement Control Considering the Difference in Pressure Between the Master Cylinder and the Wheel Cylinder[J]. Journal of Tongji University (Natural Science), 2022, 50(11): 1667-1675.
- [16] SHI B F, XIONG L, YU Z P. Pressure Estimation Based on Vehicle Dynamics Considering the Evolution of the Brake Linings' Coefficient of Friction[J]. Actuators, 2021, 10(4): 76.
- [17] LV C, XING Y, ZHANG J Z, et al. Levenberg - Marquardt Backpropagation Training of Multilayer Neural Networks for State Estimation of A Safety-Critical Cyber-Physical System[J]. IEEE Transactions on Industrial Informatics, 2017, 14(8): 3436-3446.
- [18] XING Y, LV C. Dynamic State Estimation for the Advanced Brake System of Electric Vehicles by Using Deep Recurrent Neural Networks[J]. IEEE Transactions on Industrial Electronics, 2019, 67(11): 9536-9547.

(责任编辑 王 一)

修改稿收到日期为2024年1月24日。