

doi: 10.19562/j.chinasae.qcgc.2025.04.012

物理-数据混合驱动的车辆质心侧偏角估计*

李 琴¹, 张博远¹, 谢智航¹, 王 勇², 汤建明¹, 陈 勇¹

(1. 广西大学机械工程学院, 南宁 530000; 2. 北京理工大学机械与车辆学院, 北京 100080)

[摘要] 质心侧偏角是车辆动力学中的关键变量。针对现有基于模型方法严重依赖动力学模型精度和数据驱动方法在面临陌生工况场景时鲁棒性差等问题, 本文提出了一种物理-数据混合驱动(DeepPhy)的质心侧偏角估计方法, 旨在结合物理模型与数据驱动模型的优势, 实现对质心侧偏角的可靠与准确估计。DeepPhy通过将后轴轮胎侧向力模型得到的质心侧偏角先验值与深度网络进行集成, 从而能够学习物理模型未能表达的非线性映射关系, 提升模型面对陌生工况的可靠性。仿真结果表明, 在连续DLC工况下, DeepPhy估计结果的RMSE相较于物理模型方法和纯数据驱动方法分别降低了93%和63%, 并对数据稀缺工况具有鲁棒性。实车验证进一步表明, DeepPhy具有优异的泛化能力, 经过仿真训练的模型可迁移至实车环境中, 并保持高精度的估计结果。

关键词: 质心侧偏角估计; 主动控制系统; 长短时记忆网络; 混合物理-数据驱动

Physics-Data Hybrid Driven Estimation of Vehicle Side Slip Angle

Li Qin¹, Zhang Boyuan¹, Xie Zhihang¹, Wang Yong², Tang Jianming¹ & Chen Yong¹

1. School of Mechanical Engineering, Guangxi University, Nanning 530000;

2. School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100080

[Abstract] In the realm of vehicle dynamics, the sideslip angle is a critical parameter. For the challenges posed by the current model-based methods, which heavily rely on the accuracy of dynamic models, and the poor robustness of data-driven methods in unfamiliar operating conditions, in this paper a sideslip angle estimation method based on a hybrid of physics and data-driven approaches (DeepPhy) is proposed. The aim is to combine the strength of physical modeling and data-driven techniques to achieve reliable and accurate estimation of the sideslip angle. DeepPhy integrates prior values of the sideslip angle obtained from the lateral force model of the rear axle tires with a deep neural network, enabling the learning of nonlinear mapping relationship not captured by the physical model, thereby enhancing the model's reliability in unfamiliar conditions. The simulation results indicate that under continuous DLC conditions, the RMSE of the estimation results from DeepPhy is reduced by 93% compared to the physical model method and by 63% compared to the data-driven method, exhibiting robustness in scenarios with limited data. Real-world validation further confirms DeepPhy's exceptional generalization capabilities, as the models trained through simulation can be transferred to real-world conditions while maintaining high-precision estimation results.

Keywords: sideslip angle estimation; active safety control; long short-term memory; physics-data hybrid driven

* 广西自然科学基金青年基金(2025GXNSFBA069567)和广西科技计划桂科AD基金(23026205)资助。

原稿收到日期为2024年09月10日, 修改稿收到日期为2024年11月05日。

通信作者: 王勇, 博士, E-mail: 17862709675@163.com。

前言

为了提高车辆的操纵稳定性与安全性,大量先进的主动安全控制系统和辅助驾驶系统在汽车领域得到了广泛应用,如直接横摆力矩控制(direct yaw-moment control, DYC)^[1]、四轮转向控制(four wheel steering control, 4WS)^[2]和容错控制(fault-tolerant control, FTC)^[3]等。这些系统的有效性依赖于对车辆状态的精确获取,例如横摆角速度和质心侧偏角等。然而,出于经济性或可靠性的考虑,可直接测量质心侧偏角的传感器难以在量产车辆中应用。一种可行的方法是利用低成本、高可靠性的传感器获取可用的状态信息,如横摆角速度和横向加速度等,然后应用估计算法来获取车辆质心侧偏角^[4]。在车辆动力学控制系统领域,如何精确快速地获取车辆质心侧偏角已成为突出的研究重点^[5]。

现有研究中,车辆质心侧偏角估计方法主要有两种类型:基于模型的方法和数据驱动的方法。基于模型的方法通过结合动力学模型或运动学模型设计相应的观测器来实现,如使用卡尔曼滤波及其改进算法^[6-8]。一般来说,基于动力学模型的方法更适用于高速和高侧滑驾驶条件^[9],而基于运动学模型的算法在侧滑角较小时表现更好^[10]。结合上述两种方法的优势,研究人员开发了两种方案的融合策略^[11-13],在不同场景中实现相对精确的性能。

然而,由于车辆模型非线性程度的增加,基于模型的方法在瞬态和高激励驾驶条件下面临挑战^[14]。因此,数据驱动的质心侧偏角估计方法在近年来受到广泛关注。这些方法旨在仅使用数据捕捉车辆状态之间的非线性关系,而无须依赖详细的模型知识。特别是人工神经网络(artificial neural network, ANN)和深度神经网络(deep neural network, DNN)在这一领域已经得到了广泛研究。早期的研究集中在基于ANN的模型上^[15-16]。随后,循环神经网络(recurrent neural network, RNN)为代表的DNN模型被广泛用于车辆状态估计,其在通过显式建模过去时间步骤间的依赖关系来逼近动态系统方面有显著优势^[17-19]。

数据驱动的估计方法可有效地解决非线性系统的回归问题,通常被描述为黑盒模型。然而,确保这些模型在训练过程中涵盖所有驾驶条件具有挑战性,而且高质量的训练数据集难以获取。因此,虽然这些方法在训练集所涵盖的驾驶操纵范围内提供了

准确的估计结果,但面临训练不充分的驾驶操作时,它们的准确性会降低甚至得到错误的估计结果^[20]。

考虑到车辆动力学状态数据是典型的时序数据,而长短时记忆网络(long short-term memory, LSTM)作为RNN的一种变种,在解决了RNN梯度消失或梯度爆炸问题的同时,可以实现数据时序关联信息的传递,且具有很强的非线性建模能力,可对多种工况下的车辆动力学行为进行良好的表达。因此本文使用LSTM构建用于估计质心侧偏角的深度神经网络,并在此基础上,提出一种物理-数据混合驱动(DeepPhy)的车辆质心侧偏角估计方法。该方法基于物理模型跟踪质心侧偏角的基本趋势,深度神经网络用于拟合物理模型未表达的非线性映射关系,通过将物理知识嵌入到深度网络中,实现了车辆质心侧偏角的鲁棒估计。模型在多工况组成的数据集上进行了训练与调优,最后在仿真和实车测试中验证了算法的精度与鲁棒性。

1 车辆模型

图1所示为2自由度车辆动力学模型,运动微分方程为




图1 车辆2自由度动力学模型

$$\begin{cases} m(\dot{v}_y + v_x \gamma) = F_{yf} + F_{yr} + g \sin(\varphi) \\ I_z \dot{\gamma} = l_f F_{yf} - l_r F_{yr} \end{cases} \quad (1)$$

式中: v_x 为纵向车速; v_y 为侧向车速; γ 为横摆角速度; β 为质心侧偏角; m 为汽车质量; φ 为路面侧向坡度; I_z 为横摆转动惯量; l_f 和 l_r 分别为质心到前、后轴的距离; F_{yf} 和 F_{yr} 分别为前、后轴的轮胎侧向力。

该模型可用于描述汽车的基本动力学特性。考虑实际传感器测量到的侧向加速度包含由侧向坡度导致的重力加速度的分量,式(1)可以重新表示为

$$\begin{cases} ma_y = F_{yf} + F_{yr} \\ I_z \dot{\gamma} = l_f F_{yf} - l_r F_{yr} \end{cases} \quad (2)$$

式中 a_y 表示侧向加速度的实际测量值。

在轮胎线性工作区域,轮胎的侧向轮胎力与轮胎侧偏角的关系可以表示为

$$\begin{cases} F_{yf} = C_f \alpha_f \\ F_{yr} = C_r \alpha_r \end{cases} \quad (3)$$

式中: C_f 和 C_r 分别为前、后轮胎的轮胎侧偏刚度; α_f 和 α_r 分别为前、后轴轮胎侧偏角。

前后轴轮胎侧偏角与车身状态和前轮转向角的关系可表示为

$$\begin{cases} \alpha_f = \frac{(v_y + l_f \gamma)}{v_x} - \delta_f = \beta + \frac{l_f \gamma}{v_x} - \delta_f \\ \alpha_r = \frac{(v_y - l_r \gamma)}{v_x} = \beta - \frac{l_r \gamma}{v_x} \end{cases} \quad (4)$$

式中 δ_f 为车辆前轮转向角。

2 质心侧偏角估计算法设计

本文提出的物理-数据混合驱动车辆质心侧偏角估计框架如图2所示。首先,引入了一种基于轮胎侧向力的质心侧偏角计算方法,推导出基于物理模型的质心侧偏角结果。然后,通过将物理模型得到的质心侧偏角与 LSTM 网络得到的结果进行结合,使深度网络在训练过程中自动拟合物理模型未表达的非线性特征,从而得到最终的估计结果。最后在训练集和验证集上对影响模型性能的超参数进行调优,得到用于测试分析的质心侧偏角估计模型。

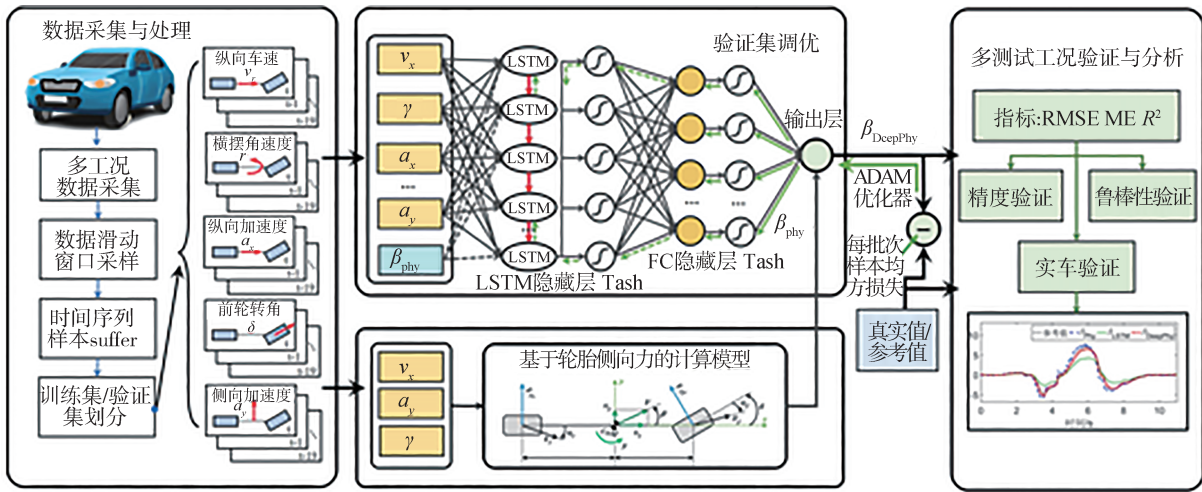


图2 物理-数据混合驱动质心侧偏角估计架构图

2.1 基于轮胎侧向力的质心侧偏角估计方法

由式(2)所示的车辆单轨模型可得到前/后轴轮胎侧向力的近似表示,结合式(3)和式(4)可得到如下描述:

$$\begin{cases} F_f = \frac{ml_f a_y + l_2 \dot{\gamma}}{l_f + l_r} = C_f \left(\delta_f - \beta - \frac{l_f}{v_x} \gamma \right) \\ F_r = \frac{ml_r a_y - l_2 \dot{\gamma}}{l_f + l_r} = C_r \left(-\beta + \frac{l_r}{v_x} \gamma \right) \end{cases} \quad (5)$$

假设 C_f 和 C_r 已知,从前/后轴轮胎侧向力方程中分别推导出质心侧偏角的表达式:

$$\begin{cases} \beta_f = -\frac{ml_f a_y + l_2 \dot{\gamma}}{(l_f + l_r)C_f} + \delta_f - \frac{l_f}{v_x} \gamma \\ \beta_r = -\frac{ml_r a_y - l_2 \dot{\gamma}}{(l_f + l_r)C_r} + \frac{l_r}{v_x} \gamma \end{cases} \quad (6)$$

式中 β_f 和 β_r 分别表示从前/后轴轮胎侧向力方程中推导出的质心侧偏角。

在紧急转向等特殊行驶工况下,考虑到车身稳定控制等主动安全系统会避免车辆侧滑过大和失稳,此时前轮侧偏角变化相对较大,轮胎侧向力与侧偏角、垂直载荷等影响因素间表现出高度非线性,而后轮侧偏角通常变化较小,故侧向力可用线性轮胎模型表示^[21]。因此本文使用后轮胎侧向力方程推导出车辆质心侧偏角作为基于物理模型的计算结果,得到质心侧偏角的基本变化趋势及特性,从而将其与深度网络集成,形成物理-数据混合驱动的估计方法。后文中将该结果用 β_{phy} 表示,即

$$\beta_{phy} = -\frac{ml_r a_y - l_2 \dot{\gamma}}{(l_f + l_r)C_r} + \frac{l_r}{v_x} \gamma \quad (7)$$

2.2 LSTM 神经网络

LSTM的关键是其单元结构,通过细胞状态矢量将信息传输到每个时间步,并且可以添加或减去信息来执行操作,单元结构图如图3所示。单元有3个

门控制状态:遗忘门、输入门和输出门。遗忘门用于选择性地遗忘从前一个节点传入的输入;输入门控制记忆细胞的输入对记忆细胞状态的影响;输出门控制记忆细胞状态对记忆细胞输出的影响。




图3 LSTM单元结构

在图3中, C_{t-1} 和 C_t 分别表示先前的细胞状态和当前的细胞状态,通过遗忘门和输入门来控制。 h_{t-1} 和 h_t 分别表示先前和当前的隐藏状态。 X_t 表示当前的输入。遗忘门、输入门和输出门可以用数学方式表示为

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (8)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (9)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (10)$$

式中: $W(\cdot)$ 和 $b(\cdot)$ 分别表示遗忘门、输入门和输出门的权重矩阵和偏置向量; $\sigma(\cdot)$ 表示 Sigmoid 激活函数。

细胞状态可用数学方式表示为

$$C_t = f_t * C_{t-1} + i_t * \text{Tanh}(W_c \cdot [h_{t-1}, X_t] + b_c) \quad (11)$$

式中: W_c 和 b_c 分别表示可学习的权重矩阵和偏置向量; $\text{Tanh}(\cdot)$ 为双曲正切激活函数。

最后,输出门使用单元状态作为输入并生成 LSTM 单元的输出。

$$h_t = o_t * \text{Tanh}(C_t) \quad (12)$$

Sigmoid 激活函数和 Tanh 激活函数的计算公式如下所示:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (13)$$

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (14)$$

2.3 DeepPhy 算法设计

本文以 LSTM 作为主干网络,在此基础上设计 DeepPhy 估计模型,并将在实验中对二者进行对比分析,以揭示物理模型对估计结果的影响程度。因传感器信号相较于质心侧偏角往往有大约 0.2 s 的

相位超前或滞后^[22],主干网络输入层选取为当前及过去 20 个时间步的传感器数据,时间步长大小为 0.01s,每时刻的输入表示为 $x_t = [v_x, \gamma, \delta, a_x, a_y]_t$ 。隐藏层包括一个 LSTM 隐藏层和一个全连接隐藏层,激活函数为 Tanh。最后输出层对全连接隐藏层状态的加权求和得到质心侧偏角估计结果。

DeepPhy 在 LSTM 模型基础上,将式(7)所示的物理模型计算结果与深度网络模型进行集成。首先,经物理模型计算得到的质心侧偏角数据将作为数据驱动模型初始的带有物理意义的输入信息,与输入特征向量进行级联合并得到新的 20 个时间步长的数据组合,此时神经网络每时刻的输入重构为 $X_t = [\beta_{\text{phy},t}, x_t]$ 。之后,物理模型的输出 $\beta_{\text{phy},t}$ 与全连接隐藏层的输出单元进行合并,类似于并行使用物理模型和机器学习模型。与纯数据驱动方法直接学习输入和输出之间的潜在映射不同,DeepPhy 模型通过捕捉物理模型输出结果与标签数据之间的偏差来间接地拟合映射关系。由于物理模型已经捕捉到车辆动力学行为的基本特性,因此与纯数据驱动方法相比,DeepPhy 模型面临的数据需求更少,以提升模型面临陌生场景时的鲁棒性。DeepPhy 模型的计算过程如下所示:

$$\begin{cases} x_t = [v_x, \gamma, \delta, a_x, a_y]_t \\ \beta_{\text{phy},t} = f_{\text{phy}}([v_x, \gamma, a_y]_t) \\ X_t = [\beta_{\text{phy},t}, x_t] \\ X = \{X_t, \dots, X_{t-19}\} \\ z_1 = \text{Tanh}(F_{\text{Lstm}}(W_{\text{Lstm}}^T, b_{\text{Lstm}}, X)) \\ z_2 = \text{Tanh}(W_{\text{FC1}}^T z_1 + b_{\text{FC1}}) \\ z_3 = W_{\text{FC2}}^T z_2 + b_{\text{FC2}} \\ \beta_{\text{DeepPhy},t} = z_3 + \beta_{\text{phy},t} \end{cases} \quad (15)$$

式中: x_t 为单个时步的传感器数据; f_{phy} 为物理模型函数; X_t 为级联合并后的传感器数据与模型计算结果组合; X 为多个时步的 X_t 数据; W_{Lstm}^T 、 b_{Lstm} 为可训练参数; F_{Lstm} 为 LSTM 网络的运算函数,具体步骤与 2.2 节中内容一致; z_i 为不同网络层的计算输出。

3 仿真实验与结果分析

为测试验证本文中提出的车辆质心侧偏角估计算法的实际性能,首先在 CarSim-Simulink 仿真平台中采集了数据集并进行相应处理,在此基础上通过训练集和验证集对网络模型超参数进行了调优;然后在仿真环境下的标准工况中对比了本算法与传统

算法的精度,并分析讨论了测试结果;最后验证了算法面对数据稀疏测试环境时相较于纯数据驱动算法的优势。

3.1 数据采集与预处理

本文通过 CarSim 与 Simulink 联合仿真平台来采集了数据样本,车型选用 C 型车辆,车辆参数如表 1 所示。仿真道路环境设置为潮湿水泥路面,路面附着系数为 0.5。

表 1 CarSim C 型车主要参数

参数	数值	单位
车辆整备质量	1 412	kg
质心距前轴长	1. 015	m
质心距后轴长	1. 895	m
前轮侧偏刚度	-52 000	N/rad
后轮侧偏刚度	-34 500	N/rad
轮距	1. 675	m
绕 Z 轴转动惯量	1 536. 7	kg·m ²

训练集/测试集中包含斜坡转向和扫频转向、正弦转向和直线行驶 4 种工况,共 8 组数据,转向工况速度范围集中在 80-100 km/h 范围内,详细介绍如表 2 所示,共包括 20 200 条数据,其中 75% 作为训练集,25% 作为验证集。测试集包含 5 组数据,前 3 组数据将用于测试验证 DeepPhy 算法在训练数据充足情况下的精度,后 2 组数据选用训练集转向工况未涉及的速度范围,用以测试算法在数据稀疏环境下的鲁棒性,详细介绍如表 3 所示。

表 2 训练集/验证集

工况类型	最大转角/(°)	频率/Hz	速度/(km·h ⁻¹)
斜坡转向	130		80/100
扫频转向	±100	1-0. 2	80-100
正弦转向	±40/60	0. 25/0. 5	80-100
直线行驶			5-120

表 3 测试集

测试项目	工况类型	最大转角/(°)	频率/Hz	速度/(km·h ⁻¹)
精度验证	鱼钩转向	-90/120		90
	连续 DLC1			80-90
	正弦转向 1	±90	0. 2	90-100
鲁棒性验证	连续 DLC2			50-60
	正弦转向 2	±90	0. 2	50-60

本文采用滑动时间窗口方法对时间序列数据进行采样,得到若干个训练样本。在使用这些样本进行训练之前,对这些训练样本进行了随机采样,具体

过程如图 4 所示,之后将其分为训练集和验证集。在不进行随机洗牌的情况下,网络学习的是所有数据的时间序列关系^[23],而车辆一次行驶时间往往很长,导致神经网络不能得到全面的训练,因此难以满足质心侧偏角估计的需求。

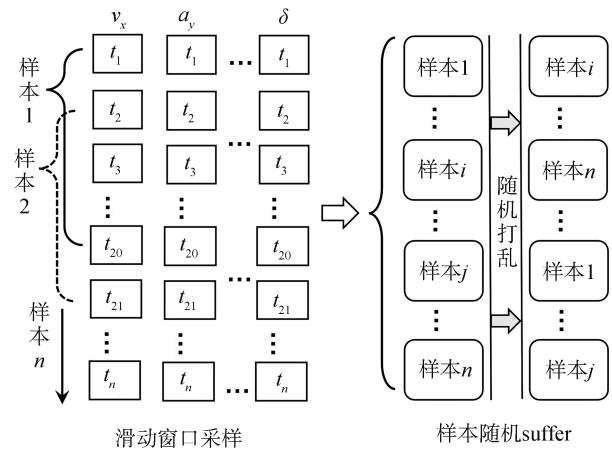


图 4 样本处理过程

此外,本文在进行训练之前对神经网络的输入数据进行了标准归一化处理,用于增强不同传感器数据之间的比较性。

3.2 网络模型训练与超参数配置

模型结构中影响模型性能的超参数主要有隐藏层数量、隐藏层单元数和激活函数等。本文在验证集上对超参数进行了调优,最后在训练集与验证集上重新训练模型。表 4 展示了经过调优后的超参数设置,图 5 所示为最后的训练过程。本文采用均方误差函数作为模型的损失函数,如式(16)所示,损失变化在 200 个 Epoch 后趋近稳定,此时 DeepPhy 算法在训练集和验证集上的损失相较于 LSTM 模型均大幅降低。

$$L = \frac{\|Y - \hat{Y}\|^2}{2n} \quad (16)$$

3.3 数据充足测试工况下算法精度验证

本文首先在鱼钩工况下验证了剧烈转向时物理模型算法与 DeepPhy 算法的可靠性,之后进一步在双移线(the dual-lane change, DLC)工况和正弦转向工况下验证了算法的精度优势。

图 6 展示了鱼钩工况的输入设置与测试结果,该测试验证了高速运行时转向盘转角发生剧烈变化期间的估计性能,为区别于训练集的斜坡转向工况,前后斜坡斜率分别为 120 和 60 (°)/s。从测试结果

表4 状态估计网络超参数设置

项目	超参数	设置
网络架构	时间序列长度	20
	LSTM 隐层数	1
	全连接隐层数	1
	LSTM 隐层单元数	128
	全连接隐层单元数	128
	激活函数	Tanh
	参数个数	86 273
训练过程	优化器	Adam
	学习率初值	0.000 4
	批大小	512
	Epochs	250
	提前停止耐心	30
	梯度剪切值	1




图6 鱼钩转向工况设置与测试结果

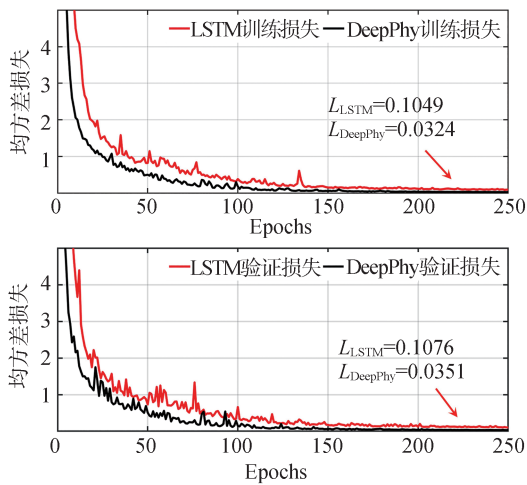


图5 估计网络最终训练过程

可以看出该工况下基于后轴侧向力的质心侧偏角计算模型仍然可以跟踪质心侧偏角的趋势,体现出DeepPhy方法引入的物理模型的合理性。由于该速度条件下训练集较为充分,DeepPhy模型与LSTM模型均展现出较为理想的效果,其中DeepPhy模型在转向趋近稳态时精度有所提高。同时也证明两种模型均有一定的泛化能力。

图7展示了DLC工况1的设置与测试结果,该测试验证了算法在高速变道期间的性能。 β_{phy} 相较于参考值表现有相位滞后,幅值则接近参考值;得益于LSTM对过去信息的利用,其估计结果消除了相位滞后,但是在2-4 s和9-11 s的超车换道期间,估计结果误差较大;所提的DeepPhy方法作为一种误差补偿模型,旨在学习物理模型未表达的非线性映射关系,考虑到此工况下物理模型估计值结果较好,

因而估计误差相较于LSTM明显降低。




图7 连续DLC工况1设置与测试结果

图8展示了正弦转向工况1的设置与测试结果,该测试验证了高速运行时避障操作期间的算法性能。在转向峰值时车辆的非线性增加导致侧滑角度曲线与前轮转向角度曲线之间的一致性相应降低,此时 β_{phy} 相较于参考值误差较大,但是其仍可跟踪质心侧偏角变化趋势;LSTM在一定程度上改善了估计结果,但是在11-13 s期间执行加速操作后,由于车辆非线性程度进一步增加,LSTM网络表现不佳;所提DeepPhy模型的估计误差相较于LSTM明显减少,表明其具有更强的非线性特征学习能力。

为定量对比估计模型之间的误差,表5展示了各算法的均方根误差(RMSE)、最大误差(ME)与 R^2 的统计结果,相较于另外两种算法,DeepPhy算法的精度明显提高。




图8 正弦转向工况1设置与测试结果

表5 精度验证误差分析

场景	对比算法	RMSE/(°)	ME/(°)	R^2
鱼钩工况	模型方法	0.449 2	1.170 6	0.828 5
	LSTM	0.077 7	0.223 4	0.994 9
	DeepPhy	0.023 5	0.068 4	0.999 3
连续DLC1	模型方法	0.278 4	0.682 8	0.820 7
	LSTM	0.053 3	0.150 2	0.993 4
	DeepPhy	0.019 7	0.081 1	0.999 1
正弦工况1	模型方法	0.510 4	1.085 6	0.807 9
	LSTM	0.088 5	0.440 6	0.994 2
	DeepPhy	0.039 3	0.192 7	0.998 9

3.4 数据稀缺测试工况下算法鲁棒性验证

车辆质心侧偏角估计算法不仅要求高精度的估计性能,而且在测试阶段需要对训练数据没有覆盖的场景具有鲁棒性。因此,本文在速度为50–60 km/h的连续DLC工况2和正弦转向工况2上进行了数据稀缺时算法的鲁棒性验证。图9展示了连续DLC工况2的设置与测试结果。在50 km/h速度期间,物理模型表现为相位超前,但是误差较小,且可以很好地反映质心侧偏角的变化趋势。由于循环网络具有一定的预测能力,LSTM模型没有表现出相位超前,但是误差较大,原因是训练集没有涵盖该速度条件下的转向操作,模型不了解该速度下的车辆动力学行为。DeepPhy集成了物理模型与数据驱动模型的优势,不仅消除了相位超前,而且取得了更高精度的估计结果,表明在数据驱动模型中嵌入合理的物理模型,可以学习和补偿物理模型未表达的车辆动力学特性。在11 s之后,车辆加速到60 km/h,此时车辆处于转向不足与转向过度的临界状态,动力学行为

更加复杂,物理模型难以捕捉到质心侧偏角的变化趋势,但是DeepPhy仍然最大仅有0.04°的误差。该结果表明,尽管物理模型在某些情况下不能完全表达车辆动力学行为,但是整体而言其仍然对数据模型起到有益的引导作用。




图9 连续DLC工况2设置与测试结果

图10展示了正弦转向工况2的设置与测试结果。与DLC工况2一致,在50 km/h速度期间,物理模型表现为相位超前,但是在转向达到峰值时,估计结果出现较大误差。LSTM模型的估计误差在13 s之前大于物理模型估计结果的误差,之后在更接近得到充分训练的转向操作速度范围时,估计效果有较大提升,物理模型由于车辆非线性的增加表现逐渐变差。而结合了物理模型和数据驱动模型的DeepPhy算法误差仍然在0.21°以内,精度接近得到充分训练时的转向测试工况的结果。




图10 正弦转向工况2设置与测试结果

表6展示了数据稀缺环境下两种测试工况各算法的RMSE、ME与 R^2 统计结果。本文提出的DeepPhy模型精度大幅度高于物理模型与纯数据驱动模型,例如在DLC工况2下,DeepPhy相比物理模型和LSTM模型, RMSE误差分别降低了72%和80%。

为直观比较在不同测试场景下各算法误差的分布结果,5个工况的误差箱型图如图11所示。物理模型的估计结果不受训练数据条件的影响,而与车辆行为的非线性程度有关,在相同速度条件下,转向角越大其估计误差越大。LSTM模型在训练数据充足的测试环境下误差分布相较于物理模型结果得到改善,但是在数据稀缺环境下精度提高有限甚至劣

表6 鲁棒性验证误差分析

场景	对比算法	RMSE/(°)	ME/(°)	R^2
连续DLC2	模型方法	0.087 0	0.288 6	0.843 3
	LSTM	0.125 3	0.371 6	0.675 1
	DeepPhy	0.023 9	0.080 3	0.988 2
正弦工况2	模型方法	0.308 0	0.750 3	0.445 7
	LSTM	0.270 4	0.620 5	0.572 7
	DeepPhy	0.054 8	0.208 4	0.982 5

于物理模型的结果,表明纯数据驱动方法在面临数据稀缺情况时的不足。本文所提的DeepPhy算法在5组工况下误差分布均集中于 0.1° 以内,进一步体现了其精度优势与对训练数据的鲁棒性。

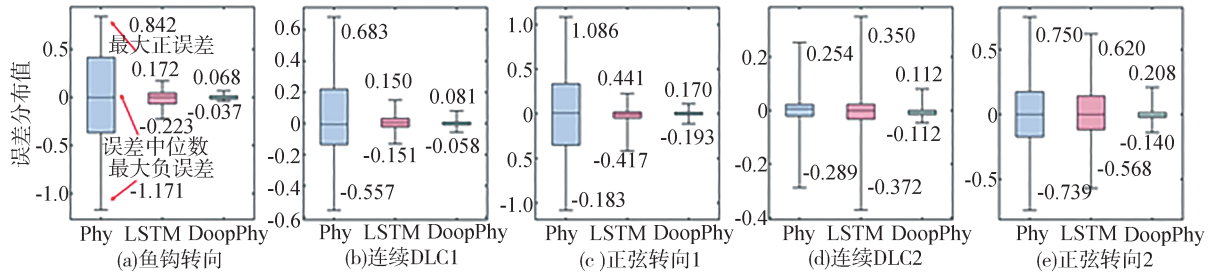


图11 5组工况估计误差箱型图对比

4 实车验证与结果分析

为了验证算法在实际运行环境中的效果以及迁移到其他车辆的能力,本文进行了实车验证,实验车辆是一辆自动驾驶分布式驱动汽车,该车辆主要参数见表7。整个车辆控制系统使用Speedgoat快速原型开发平台实现。前轮转角由角度传感器测量,并通过CAN线连接到Speedgoat平台。此外,测试车辆配备了华测CG-410高精度组合导航系统,包括实时动态定位(real-time kinematic, RTK)功能,通过测量偏航角与航向角,进而获取车辆的质心侧偏角,相关信息通过另一个CAN线连接到Speedgoat平台。数据采集过程中的传感器与平台配置如图12所示,从组合导航系统获得的质心侧偏角被视为本次实验中的参考值。同时为了研究算法的迁移能力,本文没有使用实车数据对模型重新训练或调整,而是采用仿真数据训练好的模型。

图13为实车环境的双移线工况下前轮转角和速度曲线与估计结果。 β_{phy} 为实车参数的物理模型估计结果,与仿真实验一致,其估计误差相对参考值

表7 测试车辆主要参数

参数	数值	单位
车辆整备质量	1 890	kg
质心距前轴长	1.504	m
质心距后轴长	1.506	m
前轮侧偏刚度	-84 500	N/rad
后轮侧偏刚度	-52 500	N/rad
轮距	1.620	m
绕Z轴转动惯量	2 150	kg·m ²




图12 实车数据采集平台与传感器配置

较大且有一定的相位超前,但是可跟踪质心侧偏角的基本特性,表明其在实际噪声环境下的有效性。由于实验车辆速度较低,且仿真车辆参数和实车参数具有差异,纯数据驱动的LSTM模型表现出最差

的估计结果。与之相比,本文所提出的DeepPhy模型在实车工况中仍然有最高的估计精度,模型表现出很强的泛化性能,在经过仿真数据训练后,可有效迁移至实车上对质心侧偏角进行估计,进一步验证了所提算法的优越性,误差统计结果见表8。




图13 实车环境双移线工况设置与结果对比

表8 实车双移线工况误差统计结果

对比算法	RMSE/(°)	ME/(°)	R^2
模型方法	0.802 1	2.902 4	0.907 6
LSTM	1.005 1	2.837 3	0.854 9
DeepPhy	0.267 9	1.264 0	0.989 7

5 结论

本文提出了一种结合物理模型与数据驱动模型优势的车辆质心侧偏角鲁棒估计方法(DeepPhy)。该方法基于物理模型跟踪质心侧偏角的基本特性,然后构建数据驱动模型拟合物理模型未表达的非线性特征,捕捉物理模型输出结果与数据之间的偏差,使其能够在具有高精度的同时具有对数据稀缺环境的鲁棒性。

(1)本文提出的DeepPhy方法与基于模型的方法和纯数据驱动的LSTM方法结果对比表明,本方法对质心侧偏角的估计结果具有更高的精度,其中在正弦工况下,DeepPhy相比LSTM的估计误差降低了55.6%。

(2)鲁棒性测试表明,DeepPhy对未知工况具有很强的鲁棒性,面对数据稀缺的测试工况时,LSTM误差增大甚至难以对质心侧偏角进行估计,而DeepPhy仍然有很高的精度。

(3)实车测试结果表明,相比于纯数据驱动方法,DeepPhy表现出可迁移性。经仿真数据训练的模型可迁移到实车环境中,对质心侧偏角进行估计。这体现出所提方法具有可扩展性,不依赖于完善的训练数据,通过改变其中的物理模型参数,可以应用于不同的车辆。

参考文献

- [1] MAZZILLI V, DE PINTO S, PASCALI L, et al. Integrated chassis control: classification, analysis and future trends[J]. Annual Reviews in Control, 2021, 51: 172-205.
- [2] TAN Q, SHI L, KATUPITIYA J. A novel control approach for path tracking of a force-controlled two-wheel-steer four wheel-drive vehicle[J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2019, 233(6): 1480-1494.
- [3] 李琴,汤建明,张博远,等.分布式驱动电动汽车多执行器容错控制研究[J].汽车工程,2023,45(12):2251-2259.
LI Q, TANG J M, ZHANG B Y, et al. Research on fault-tolerant control of multi-actuator for distributed drive electric vehicles[J]. Automotive Engineering, 2023, 45(12): 2251-2259.
- [4] WANG Y, XU L, ZHANG F, et al. An adaptive fault-tolerant EKF for vehicle state estimation with partial missing measurements[J]. IEEE/ASME Transactions on Mechatronics, 2021, 26(3): 1318-1327.
- [5] CHENG S, LI L, YAN B, et al. Simultaneous estimation of tire side-slip angle and lateral tire force for vehicle lateral stability control[J]. Mechanical Systems and Signal Processing, 2019, 132: 168-182.
- [6] XIONG L, XIA X, LU Y, et al. IMU-based automated vehicle body sideslip angle and attitude estimation aided by GNSS using parallel adaptive Kalman filters[J]. IEEE Transactions on Vehicular Technology, 2020, 69(10): 10668-10680.
- [7] RUGGABER J, BREMBECK J. A novel Kalman filter design and analysis method considering observability and dominance properties of measurands applied to vehicle state estimation[J]. Sensors, 2021, 21(14): 4750.
- [8] WANG Y, GENG K, XU L, et al. Estimation of sideslip angle and tire cornering stiffness using fuzzy adaptive robust cubature Kalman filter[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 52(3): 1451-1462.
- [9] JEON W, CHAKRABARTY A, ZEMOUCHE A, et al. Simultaneous state estimation and tire model learning for autonomous vehicle applications[J]. IEEE/ASME Transactions on Mechatronics, 2021, 26(4): 1941-1950.
- [10] NGUYEN A T, DINH T Q, GUERRA T M, et al. Takagi-Sugeno fuzzy unknown input observers to estimate nonlinear dynamics of autonomous ground vehicles: theory and real-time verification[J]. IEEE/ASME Transactions on Mechatronics, 2021, 26(3): 1328-1338.

- [11] 夏秋,陈特,陈龙,等.基于冗余信息融合的车辆质心侧偏角估计方法[J].汽车工程,2022,44(2):280-289.
XIA Q, CHEN T, CHEN L, et al. Vehicle sideslip angle estimation method based on redundant information fusion [J]. *Automotive Engineering*, 2022, 44(2): 280-289.
- [12] CHEN T, CAI Y, CHEN L, et al. Sideslip angle fusion estimation method of three-axis autonomous vehicle based on composite model and adaptive cubature Kalman filter [J]. *IEEE Transactions on Transportation Electrification*, 2023.
- [13] 陈建锋,吴强,葛新元,等.基于切换策略的车辆质心侧偏角高性能获取[J].汽车工程,2024,46(2):346-355.
CHEN J F, WU Q, GE X Y, et al. High-performance acquisition for vehicle sideslip angle based on switch strategy [J]. *Automotive Engineering*, 2024, 46(2): 346-355.
- [14] BERTIPAGLIA A, DE MOL D, ALIREZAEI M, et al. Model-based vs data-driven estimation of vehicle sideslip angle and benefits of tyre force measurements [J]. *arXiv preprint arXiv: 2206.15119*, 2022.
- [15] BONFITTO A, FERACO S, TONOLI A, et al. Combined regression and classification artificial neural networks for sideslip angle estimation and road condition identification [J]. *Vehicle System Dynamics*, 2020, 58(11): 1766-1787.
- [16] BOADA B L, BOADA M J L, GAUCHÍA A, et al. Sideslip angle estimator based on ANFIS for vehicle handling and stability [J]. *Journal of Mechanical Science and Technology*, 2015, 29: 1473-1481.
- [17] GIULIACCI T A, BALLESEO S, FAINELLO M, et al. Recurrent neural network model for on-board estimation of the side-slip angle in a four-wheel drive and steering vehicle [J]. *SAE International Journal of Passenger Vehicle Systems*, 2023, 17(15-17-01-0003).
- [18] SRINIVASAN S, SA I, ZYNER A, et al. End-to-end velocity estimation for autonomous racing [J]. *IEEE Robotics and Automation Letters*, 2020, 5(4): 6869-6875.
- [19] ZHANG B, ZHAO W, ZOU S, et al. A reliable vehicle lateral velocity estimation methodology based on SBI-LSTM during GPS-outage [J]. *IEEE Sensors Journal*, 2020, 21(14): 15485-15495.
- [20] LIU J, WANG Z, ZHANG L, et al. Sideslip angle estimation of ground vehicles: a comparative study [J]. *IET Control Theory & Applications*, 2020, 14(20): 3490-3505.
- [21] 孙晓强,王玉麟,胡伟伟,等.基于轮胎分段仿射辨识模型的车辆行驶状态估计策略研究[J].汽车工程,2023,45(7):1212-1221.
SUN X Q, WANG Y L, HU W W, et al. Research on estimation strategy of vehicle driving state based on tire piecewise affine identification model [J]. *Automotive Engineering*, 2023, 45(7): 1212-1221.
- [22] LI X, XU N, LI Q, et al. A fusion methodology for sideslip angle estimation on the basis of kinematics-based and model-based approaches [J]. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 2020, 234(7): 1930-1943.
- [23] HERMANDSORFER L, TRAUTH R, BETZ J, et al. End-to-end neural network for vehicle dynamics modeling [C]. 2020 6th IEEE Congress on Information Science and Technology (CiSt). IEEE, 2021: 407-412.

(上接第763页)

- [18] GOGO K O, NDERU L, MUTUA M. Variances in knowledge-based interval type 2 Gaussian fuzzy on linear regression models [J]. *Journal of Intelligent & Fuzzy Systems*, 2021, 41(1): 1807-1820.
- [19] CHEN Y, LI C, YANG J. Design of discrete noniterative algorithms for center-of-sets type reduction of general type-2 fuzzy logic systems [J]. *International Journal of Fuzzy Systems*, 2022, 24(4): 2024-2035.
- [20] ZHANG X, KIM D, BANG J, et al. Time delay compensation of a robotic arm based on multiple sensors for indirect teaching [J]. *International Journal of Precision Engineering and Manufacturing*, 2021, 22: 1841-1851.
- [21] YAN G, FANG M, XU J. Analysis and experiment of time-delayed optimal control for vehicle suspension system [J]. *Journal of Sound and Vibration*, 2019, 446: 144-158.