

DOI: 10.13382/j.jemi.B2508729

基于 CPO-LSTM 神经网络的车辆运动状态 分层式估计方法*

唐浩东 潘树国 陶贤露 高 旺 张 驰

(东南大学仪器科学与工程学院综合时空网络与装备技术全国重点实验室 南京 210046)

摘要:准确获取车辆的运动状态对于车辆轨迹位置的推算具有重要意义,尤其是在卫星信号遮蔽严重的环境中(如城市峡谷、树林、隧道等场景),而现有的基于动力学模型驱动的车辆运动估计方法过于依赖建模精度,且在一些极限工况下难以进行准确的估计。故为了更加简洁准确地获取车辆运动状态信息,提出了一种基于冠豪猪算法优化的长短时记忆网络(CPO-LSTM)的分层式车辆状态估计方法。首先,通过分析车辆动力学基本物理特性,设计了纵向速度与侧向速度的分层式估计策略;然后,构建多种行驶工况组成的数据集进行训练,在训练过程中利用冠豪猪优化算法(CPO)对学习率与迭代次数等参数进行寻优;最后,对估计方法进行了多工况及多路面条件下的虚拟仿真试验验证。结果表明,该方法有效地提高了车辆运动状态估计精度,横向速度、纵向速度和横摆角速度的估计精度相比于基于模型驱动的方法精度分别提升92%、73%和52%,整体表现优于传统的基于动力学模型的卡尔曼滤波算法。

关键词:车辆状态估计;动力学模型;机器学习;长短时记忆网络;冠豪猪优化算法

中图分类号: U461.1 **文献标识码:** A **国家标准学科分类代码:** 460.40

Vehicle motion state stratified estimation based on CPO-LSTM

Tang Haodong Pan Shuguo Tao Xianlu Gao Wang Zhang Chi

(State Key Laboratory of comprehensive PNT Network and Equipment Technology, School of Instrument Science and Engineering, Southeast University, Nanjing 210046, China)

Abstract: Accurately obtaining the motion state of a vehicle is of great significance for the estimation of vehicle trajectory and position, especially in environments with severe satellite signal occlusion (such as urban canyons, wooded areas, tunnels, etc.). However, existing vehicle motion estimation methods driven by dynamic models rely too much on modeling accuracy and are difficult to achieve accurate estimation under some extreme working conditions. Therefore, in order to accurately obtain vehicle motion state information without relying on the accuracy of dynamic models, this paper proposes a hierarchical vehicle state estimation method based on the crested porcupine optimization long short-term memory network. Firstly, by analyzing the basic physical characteristics of vehicle dynamics, a hierarchical estimation strategy for longitudinal velocity and lateral velocity is designed. Then, a dataset composed of various driving conditions is constructed for training, and during the training process, the crested porcupine optimization algorithm is used to optimize parameters such as learning rate and number of iterations. Finally, virtual simulation tests are conducted to verify the estimation method under multiple working conditions and multiple road surface conditions. The results show that this method effectively improves the estimation accuracy. Compared with model-driven methods, the estimation accuracy of lateral velocity, longitudinal velocity, and yaw rate is improved by 92%, 73%, and 52% respectively, and the overall performance is better than the traditional Kalman filtering algorithm based on dynamic models.

Keywords: vehicle state estimation; dynamic model; machine learning; long short-term memory (LSTM); crested porcupine optimizer

0 引言

随着汽车智能化的普及,车辆智能驾驶辅助系统正被逐渐应用。而智能驾驶所要实现的自主定位与主动控制的前提则是对汽车行驶状态参数的获取。因此如何准确且低成本的获取汽车运动状态参数已然成为了智能驾驶领域的研究热点^[1-3]。

由于某些关键物理量的获取受制于传感器的测量精度以及成本等因素(如纵向速度、侧向速度、横摆角速度等)。为了解决这个问题,常采用的思路是利用低成本传感器得到一些易获取的状态信息,如纵向加速度、侧向加速度、轮速、前轮转角等等,再通过建立在车辆动力学和运动学模型基础上的估计算法对上述关键物理量进行估计^[4-5]。

从建立模型角度来看,目前常见的方法主要分为汽车运动学模型与汽车动力学模型两种。其中,运动学模型主要有单轨模型、双轨模型、Ackerman 几何模型这几类;动力学模型主要有 2 自由度模型、3 自由度模型和 7 自由度模型这几类。前者主要考虑车辆的几何关系(如位移、速度、航向角),忽略质量、惯性、轮胎力等动力因素,因此具备建模简洁,计算复杂度低等优势,对应的是这类方法的使用场景也有较大的局限性,仅适用于车辆低速和操控不激烈的工况下。而后者同时考虑了质量分布、惯性、轮胎力、空气阻力等物理现象,因而适合高速动态分析和精细控制设计,同时计算上的复杂度也相应增加。

从估计方法角度来看,车辆运动状态估计算法以传统的卡尔曼滤波(Kalman filter, KF)及其改进算法为主,如扩展卡尔曼滤波(extended Kalman filter, EKF)和无迹卡尔曼滤波(unscented Kalman filter, UKF), EKF 和 UKF 也是目前最为常用的 KF 改进算法^[6-7]。其中, EKF 算法计算更为简便,更适用于计算资源受限的嵌入式硬件上;而 UKF 则具有更强的处理非线性系统的能力,因此在高精度模型(7 自由度车辆模型、魔术轮胎模型)中常常被使用。

在此基础上,为了进一步提高估计精度。陈龙等^[8]将 EKF 与分级串联的思想相结合,利用了横摆角速度受噪声影响最小,鲁棒性最强的特性,提出了 GS-EKF 算法,提高了估计算法的准确性。周卫琪等^[9]将 UKF 算法与遗传算法相结合,利用遗传算子优化了 UKF 对应的过程噪声协方差矩阵和量测噪声协方差矩阵,得到了一种能有效的自适应优化噪声矩阵的估计算法。陈特等^[10]将强跟踪卡尔曼滤波与岭估计相结合,根据噪声阵的大小在两个模型之中自适应切换,并进行了联合仿真验证。

大部分以 EKF 和 UKF 为基础的改进融合算法都有

较高的估计精度,然而这种方法因为模型的限制,需要获取大量车辆参数才能够建立精准的汽车运动模型来实现对关键物理量的估计,因此这种基于运动学与动力学模型的融合算法具有一定的局限性^[11]。

近年来,机器学习等智能算法逐渐被引入车辆运动状态参数的估计研究中。相较于传统基于物理建模的方法,机器学习技术具有显著优势:其无需依赖预设的车辆动力学模型或固定参数,而是通过对大量训练集数据的学习,结合设计合理的网络结构,实现对车辆状态参数的高效估计与动态预测。这种数据驱动的方法在处理高度非线性、复杂工况或模型不确定性较大的场景中,展现出较强的鲁棒性和泛化能力。

对此,许多国内外学者已经进行了大量深入的研究。尤勇等^[12]提出了用鲸鱼优化算法和支持向量回归算法相结合的方法。Tonoli 等^[13]利用多层神经网络来对质心侧偏角进行了估计。高振海等^[14]设计了混合神经网络(HNN)来对车辆运动状态参数进行估计,并且比较了多个不同的机器学习算法之间的优劣。可以发现,目前的研究热点正从传统的建立动力学模型向机器学习算法进行转变^[15]。

而长短时记忆网络(long short-term memory, LSTM)在车辆估计方法方面的应用仍较少,但 LSTM 算法在许多其他领域进行预测分析以及回归任务时已经取得了较好的结果^[16-18]。LSTM 作为循环神经网络(RNN)的改进形式,因其独特的门控机制而具备建模长期依赖关系的能力。LSTM 可实现信息存储与遗忘之间的动态调节,使模型能够选择性地保留关键特征并抑制冗余或噪声信息,提升了对复杂时序模式的表达能力。得益于此, LSTM 在时间序列预测等任务中展现出优越的性能,并表现出良好的跨领域泛化性与鲁棒性。

因此,本文提出了一种利用冠豪猪优化算法(crested porcupine optimizer, CPO)来对 LSTM 网络进行参数寻优的方法。通过对车辆自身的动力学特性分析,设计了 LSTM 算法网络的结构;然后利用驾驶模拟器采集的多工况数据对 LSTM 模型进行训练,并利用 CPO 算法对网络的关键参数(学习率、迭代次数、隐藏层个数)进行寻优;最后在仿真中验证了算法的可靠性。

1 CPO-LSTM 工作原理

1.1 LSTM 工作原理

本文选用 LSTM 作为主要的时序建模框架。LSTM 属于一种结构改进型循环神经网络,通过引入门控机制,有效缓解了传统 RNN 在建模长期依赖关系时易出现的梯度消失问题,具备更强的序列记忆与时序特征提取能力^[19]。

LSTM 单元内部引入细胞状态以作为长期信息的载体,其状态更新过程由 3 类门控结构协同调节:遗忘门决定细胞状态中需舍弃的信息;输入门引入候选状态并与现有信息融合以更新当前状态;输出门则控制隐藏状态的生成与输出。该门控机制使得网络能够对不同时间步的信息实现动态选择与有效管理,从而提升对复杂时序数据中关键模式的提取能力与建模精度。具体结构如图 1 所示。




图 1 LSTM 原理

Fig. 1 LSTM schematic

设在时间步 t 的输入为 x_t , 在此时间步的 LSTM 输出为 h_t , 细胞状态为 c_t 。LSTM 通过门控机制对信息的保留与更新进行动态控制,具体包括如下 4 个步骤。

1) 遗忘门主要负责判断前一时刻细胞状态中各类信息的保留与舍弃程度,从而在历史记忆与当前输入之间实现动态权衡。该门控结构输出的权值介于 0~1 之间,其中接近 0 表示相应信息将被显著遗忘,接近 1 则表示信息得以完全保留。该机制赋予 LSTM 网络对长期记忆内容的细粒度调控能力,有效缓解传统 RNN 在处理长时依赖关系时所面临的梯度衰减问题,增强了模型在时序建模任务中的稳定性与表达能力,具体公式如下:

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

式中: W_f 是权重矩阵; b_f 是偏置项; x_t 为时间步 t 的输入向量; σ 是激活函数。

2) 输入门负责接收当前输入 x_t 与前一时刻输出的隐藏状态 h_{t-1} , 并决定哪些新的信息需要写入当前细胞状态。首先,利用 Sigmoid 函数生成输入门激活值,以调控信息更新的权重;其次,产生候选状态向量以确定拟更新的内容;最终,通过将输入门激活值与候选状态进行逐元素乘积,实现对细胞状态的有效更新,从而动态调节细胞记忆的增量部分。输入门用于确定当前时间步的新信息中需写入细胞状态的部分,候选细胞状态则生成待更新的新信息,具体公式如下:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

式中: W_i 和 W_c 分别是输入门控制和候选细胞状态的权重矩阵; b_i 和 b_c 分别是对应的偏置项。

3) 结合遗忘门筛选后的历史信息与输入门调控的新信息,对细胞状态进行更新,公式如下:

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (4)$$

4) 输出门控制细胞状态 c_t 中需传递至隐藏层输出 h_t 的信息, h_t 既作为当前时间步的模型输出,也作为下一时间步的历史特征输入,公式如下:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

式中: W_o 和 b_o 是输出门的权重矩阵和偏置项。

1.2 CPO 优化算法

CPO 优化算法由 Abdel-Basset 等^[20]提出,基于冠豪猪在自然环境中的典型防御行为所构建,是一种新颖的元启发式优化方法。该算法在传统粒子群优化 (particle swarm optimization, PSO) 框架的基础上,引入 4 种模拟冠豪猪防御策略的机制,通过分阶段协同搜索实现全局探索与局部开发的动态平衡,相比 PSO 具有更优的寻优性能与收敛特性。

相较于传统粒子群优化算法, CPO 算法优势显著,搜索机制更全面, PSO 仅依赖粒子速度与位置迭代的单一策略,而 CPO 可通过 4 种模式切换,兼顾全局多样化探索与局部精细化开发,有效规避过早收敛;收敛性能更优异, PSO 收敛速度易受参数设置影响且后期寻优效率低, CPO 则借由阶段化策略切换与适应度权重因子实现迭代初期扩范围、后期聚优质区域的高效收敛。 PSO 对高维复杂问题适配性差且易受初始条件影响, CPO 依托个体距离感知与适应度反馈调节,在 LSTM 多参数寻优这类复杂任务中适应性及稳定性更优。

CPO 的种群初始化过程遵循多数群体智能优化方法的通用策略,通过在搜索空间内基于一定规则分布生成初始解,构成初始种群,为后续的迭代优化提供基础。

$$\vec{x}_i = \vec{L} + r \times (\vec{U} - \vec{L}) \quad i = 1, 2, \dots, N \quad (7)$$

式中: N 代表个体数量; x_i 为搜索空间中的第 i 个候选解; L 和 U 分别代表搜索范围的上下限, r 是 0~1 的随机数。

冠豪猪使用的 4 种防御策略可以分为两个阶段,探索阶段 (视觉和声音) 和开发阶段 (气味和身体) 以实现从全局搜索到局部精细搜索的平滑过渡。

搜索阶段针对 LSTM 网络参数 (隐藏层单元数、学习率、训练周期) 的搜索空间进行全局遍历,避免遗漏最优参数组合,为后续精细化寻优提供基础。

1) 视觉恐吓阶段

当冠豪猪感知到远处威胁时,会竖起背部的刺形成威慑。在 CPO 中,该机制用于扩大搜索范围,引导个体向当前最优解与其他个体的中点靠近,实现全局探索,如式 (8) 所示:

$$\vec{x}_i^{t+1} = \vec{x}_i^t + \tau_1 \times |2 \times \tau_2 \times \vec{x}_{CP}^t - \vec{y}_i^t| \quad (8)$$

式中: $\vec{x}_i^t$ 和 $\vec{x}_i^{t+1}$ 分别代表第 i 个个体在当前和下一个时刻的位置; $\vec{x}_{CP}^t$ 为最佳 CPO 位置; $\vec{y}_i^t$ 是当前冠豪猪与随机冠豪猪之间的距离; τ_1 是基于正态分布的随机数; τ_2 是 0~1 的随机数。

$\vec{y}_i^t$ 表达式如下:

$$\vec{y}_i^t = \frac{\vec{x}_i^t + \vec{x}_r^t}{2} \quad (9)$$

式中: r 为 1~ N 的随机数。

2) 声音恐吓阶段

当视觉恐吓无法奏效时,冠豪猪会发出响亮的咆哮声来驱赶捕食者。该策略通过个体之间的差异引导更新,增强搜索空间中的多样性,避免过早收敛,公式如下:

$$\vec{x}_i^{t+1} = (1 - \vec{U}_1) \times \vec{x}_i^t + \vec{U}_1 \times (\vec{y} + \tau_3 \times (\vec{x}_{r_1}^t - \vec{x}_{r_2}^t)) \quad (10)$$

式中: r_1 和 r_2 同样是在 1~ N 的两个随机整数; τ_3 为 0~1 的某一个随机值。

而当捕食者较近时,冠豪猪会采取第 2 个阶段的防御策略。

该阶段基于探索阶段筛选出的优质参数区域,进行精细化搜索,优化参数组合以最小化 LSTM 模型的均方根误差(适应度函数)。

3) 气味攻击阶段

在威胁临近时,冠豪猪会释放刺鼻气味扰乱对方。此机制引入了适应度的权重因子,使个体在向目标靠近时结合当前解的质量,实现有偏的局部开发,公式如下:

$$\vec{x}_i^{t+1} = (1 - \vec{U}_1) \vec{x}_i^t + \vec{U}_1 (\vec{x}_{r_1}^t + S_i^t (\vec{x}_{r_2}^t - \vec{x}_{r_3}^t) - \tau_3 \delta \gamma_i S_i^t) \quad (11)$$

式中: r_3 是 1~ N 的随机数; S_i^t 为所定义的气味扩散因子; δ 是用于控制搜索方向的参数; γ_i 为所定义的防御因子; τ_3 是 0~1 的随机数。

4) 身体攻击阶段

若上述策略均无效,冠豪猪将主动发起身体攻击。该策略模拟个体快速向当前最优解靠拢,加强收敛能力,公式如下:

$$\vec{x}_i^{t+1} = \vec{x}_{CP}^t + (\alpha(1 - \tau_4) + \tau_4) (\delta \vec{x}_{CP}^t - \vec{x}_i^t) - \tau_5 \delta \gamma_i \vec{F}_i^t \quad (12)$$

式中: $\vec{x}_{CP}^t$ 是 CPO 最优解; α 是收敛速度因子; τ_4 是 0~1 之间的随机数; $\vec{F}_i^t$ 是影响第 i 个捕食者的冠豪猪的平均力。

$$\vec{F}_i^t = \vec{\tau}_6 \times m_i \times (\vec{v}_i^{t+1} - \vec{v}_i^t) \quad (13)$$

式中: m_i 是迭代到 t 轮时第 i 个个体的质量; $\vec{v}_i^{t+1}$ 表示的是第 i 个个体在迭代到 $t+1$ 代时的最终速度; $\vec{v}_i^t$ 是迭代到 t 代时第 i 个个体的初始速度; τ_6 是 0~1 的随机数。

1.3 适应度函数的选取与 CPO 参数设置

本文以 LSTM 训练结果的均方根误差的最小值作为适应度函数,通过 CPO 优化算法对网络的隐藏层节点数、训练周期和学习率进行参数化寻优。

$$loss = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

式中: n 为样例个数; y^i 为模型输出; $\hat{y}^i$ 为真实值。

由于 LSTM 模型中的参数会严重影响最终的预测结果,因此需要通过 CPO 优化算法得到合适的参数组合。本文主要针对隐藏层单元数量、学习率以及训练周期这 3 个主要参数进行寻优。具体参数设置如表 1 所示, CPO-LSTM 流程如图 2 所示。

表 1 LSTM-CPO 参数设置

Table 1 LSTM-CPO parameter settings

参数	候选值
LSTM 隐藏层单元数	{32, 64, 128, 256}
LSTM 学习率	{0.001, 0.005, 0.01, 0.05}
LSTM 训练周期	{20, 50, 100, 150, 200}
CPO 种群规模	20
CPO 最大迭代次数	50
CPO 收敛阈值	1^{-6}




图 2 CPO-LSTM 流程

Fig. 2 CPO-LSTM flow

隐藏层单元决定了 LSTM 层的“记忆容量”和表达能力,单元数越多,模型能捕捉的特征和模式越丰富^[21]。较少的隐藏单元数量限制了模型的表达能力,导致其难以充分捕捉序列数据中的复杂时序特征,进而引发欠拟合问题,表现为模型在训练集和测试集上均难以达到理想的预测精度。相反,增加隐藏单元数量能够提升模型的容量,使其具备学习更加复杂和丰富的序列模式的能力,从而增强拟合效果。然而,隐藏单元过多则可能导致模型过度拟合训练数据,记忆训练样本中的噪声和偶然性特征,降低其对未知数据的泛化能。

学习率是深度学习中控制模型参数更新步伐的超参

数,决定了每次梯度下降时,参数沿负梯度方向调整的幅度。较小的学习率会导致模型参数更新步伐过于缓慢,从而延长训练收敛时间,并增加陷入局部最优解或鞍点的风险,限制模型达到全局最优的能力。相反,较大的学习率虽然能够加快训练速度,但若设置过高,则可能引起参数更新过程中的震荡甚至发散,导致模型难以稳定收敛,影响最终性能表现。

训练周期(Epoch)指的是整个训练数据集被完整地输入模型进行一次前向传播和反向传播的过程。一个训练周期意味着模型已经“看过”了全部训练样本一次。较少的训练周期会导致模型欠拟合,而较多的训练周期则可能会导致过拟合。

2 车辆状态估计算法设计

运动状态估计网络的架构设计基于对传统车辆动力学模型的系统性解析,围绕传感器观测量与待估状态变量之间的关键依赖关系展开建模。针对该隐含映射关系,构建了具有强表达能力的深度神经网络结构,以实现车辆状态的高精度估计,并增强模型在复杂工况下的泛化能力与鲁棒性。

2.1 3 自由度车辆模型

选择合适的车辆动力学模型对车辆的运动状态进行分析,是构建深度神经网络结果的前提。3 自由度车辆模型具有较高建模精度的同时,不必对轮胎等过于复杂的物理模型进行分析,因而适合作为本文的研究对象。图3所示为3 自由度车辆动力学模型。




图3 3 自由度车辆模型

Fig. 3 Three degrees of freedom vehicle model

根据车辆动力学模型建立的动力学方程为:

$$\begin{aligned}\dot{\omega} &= \frac{a^2 k_1 + b^2 k_2}{I_z v_x} \omega + \frac{a k_1 - b k_2}{I_z} \beta - \frac{a k_1}{I_z} \delta \\ \dot{\beta} &= \frac{a k_1 - b k_2 - m v_x^2}{m v_x^2} \omega + \frac{k_1 + k_2}{m v_x} \beta - \frac{k_1}{m v_x} \delta \\ \dot{v}_x &= a_x + \beta v_{y1}\end{aligned}\quad (15)$$

式中: a 、 b 分别为前后轴到质心距离; k_1 、 k_2 分别为前后轮等效侧偏刚度; v_x 为纵向车速; a_x 和 a_y 分别为车辆纵

向和侧向加速度; ω 为横摆角速度; β 为质心侧偏角; m 为整车质量; I_z 为车辆绕 z 轴的转动惯量; δ 为前轮转角。

这里车辆在建模时忽略悬架系统的影响,只考虑3个方向的自由度,即纵向、侧向以及绕 z 轴的横摆运动。

2.2 网络结构设计

由上述动力学方程可见,车辆行驶过程中侧向运动的强度与车辆的纵向速度密切相关。此外,当前时刻的侧向运动状态与前一时刻存在显著的时序相关性。相比之下,纵向运动主要受轮速影响,在车辆未发生显著滑移的条件下,轮速与纵向速度之间表现出非线性的耦合关系。不同于侧向速度和横摆角速度,纵向速度在时间序列上缺乏明显的依赖特性。

故由此特性,本文选择将纵向速度与侧向速度和横摆角速度进行分层式估计;即先对纵向速度进行单独估计,再对侧向速度和横摆角速度进行估计。在纵向速度估计模块中,考虑成本和传感器精度等因素,选择四轮轮速、前轮转角以及纵向加速度作为输入量,纵向速度为输出量;而在侧向运动估计模块中,选择前轮转角、纵向、侧向加速度以及上一模块中输出的纵向速度作为输入量,侧向速度和横摆角速度作为输出量。具体结构如图4所示。




图4 网络结构设计

Fig. 4 Network structure design

3 仿真结果验证

3.1 数据采集

本文的数据采集采用的是驾驶模拟器,车辆模型选用的是某国产乘用车车型。在数据采集过程中,为了避免数据的单一性和重复性,选取了5名具有一定驾驶经验的青年担任驾驶员。采集过程如图5所示。

根据本文的训练目标,训练集中包含的工况应符合如下3个要求。

1) 应包含纵向、侧向两种车辆运动典型的工况。能充分体现两种运动各自的特征。

2) 能够体现车辆在不同速度下的运动情况。

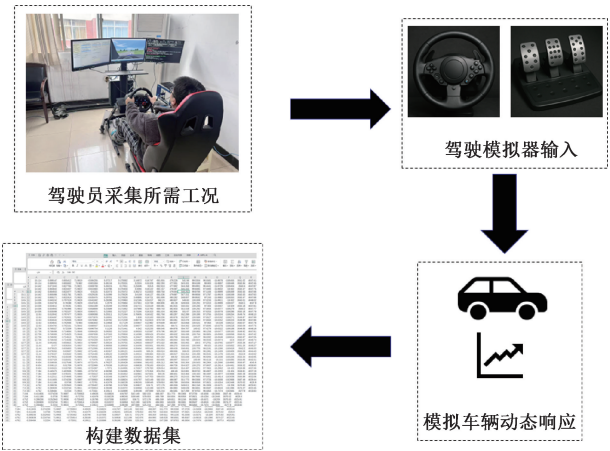


图5 数据采集流程

Fig. 5 Data collection process

3)能够体现车辆在不同路面附着系数下的运动情况。

根据上述要求,采集工况可分为两部分:其中纵向工况包括两种路面附着系数下的直线加速、制动工况,加速工况中加速度为固定值,制动工况中为全力制动,速度范围72~108 km/h,间隔为9 km/h;侧向工况包括两种路面附着系数下的单移线工况和正弦转向工况,速度范围及间隔与上述纵向工况部分相同。训练集总计样本为142 809个,具体情况如表2所示。

表2 训练集采集工况

Table 2 Training set acquisition conditions			
工况	路面附着系数	车速/(km·h ⁻¹)	加速度/g
加速	0.2、0.85	—	0.1、0.2
制动	0.2、0.85	72~108	—
单移线	0.2、0.85	72~108	—
正弦转向	0.2、0.85	72~108	—

3.2 仿真结果验证

为了保证测试结果的可靠性,分别采用相同路面附着系数下72 km/h的中速情况和108 km/h的高速情况来对模型的估计精度进行验证。测试工况为双移线工况和蛇形工况,分别为GB/T 40521.1-2021以及GB/T 6323-2014。这两种工况均覆盖了直线工况和大侧向加速度工况。另外也对相同车速下不同路面附着系数的情况进行了验证。与训练集工况相同,模型的输入参数为四轮轮速、纵向加速度、侧向加速度以及前轮转角。输出参数为纵向车速、侧向车速以及横摆角速度。最后,将本模型的结果与传统的AUKF(噪声自适应无迹卡尔曼滤波)算法进行比较。

1)不同车速下的结果分析

图6、7所示分别为双移线工况下72、108 km/h的估

计结果,图8、9所示分别为蛇形工况下72、108 km/h的估计结果,路面附着系数均为0.2。两种算法估计结果的均方根误差(RMSE)如表3所示。




图6 车速72 km/h下的双移线工况估计结果

Fig. 6 Estimation results of double shifting condition at vehicle speed of 72 km/h




图7 车速108 km/h下的双移线工况估计结果

Fig. 7 Estimation results of double shifting condition at vehicle speed of 108 km/h

由图6、8可知,当车速为72 km/h时传统AUKF算法对纵向车速的估计结果存在较明显的误差,尤其在初始时刻更加明显。这是因为基于车辆动力学的估计模型十分依赖初值设定,即对车辆初始状态的获取。而CPO-LSTM模型则很好的避免了这一点。而对于侧向车速和横摆角速度,AUKF的估计结果则出现了明显的滞后性。CPO-LSTM算法估计结果与真值变化趋于一致。由图7、9可知,当车速为108 km/h时,车辆运动的非线性特性




图 8 车速 72 km/h 下的蛇形工况估计结果
Fig. 8 Estimation results of serpentine maneuver condition at vehicle speed of 72 km/h




图 9 车速 108 km/h 下的蛇形工况估计结果
Fig. 9 Estimation results of serpentine maneuver condition at vehicle speed of 108 km/h

被进一步放大。在这种情况下,AUKF 的估计结果不能很好的反应车辆出现转向等姿态变化,而随着速度的升高 CPO-LSTM 算法的估计精度下降并不明显的同时仍能很好的反应车辆侧向运动的变化情况。可见,CPO-LSTM 算法在不同车速及多样工况下均展现出较优的估计精度,体现出其在复杂动态环境中的稳定性与适应能力。

2) 不同路面附着系数下的结果分析

图 10、11 分别为路面附着系数为 0.2 和 0.85 的估计结果,测试车速为 81 km/h。仍采用双移线工况进行验证,两种算法估计结果的均方根误差如表 4 所示。

表 3 两种车速下各算法估计均方根误差
Table 3 The root mean square error of each algorithm is estimated at two vehicle speeds

	估计量	车速	AUKF	CPO-LSTM
双移线工况	v_x	72	0.214 89	0.017 72
		108	1.513 82	0.037 67
	v_y	72	0.834 45	0.236 96
		108	2.938 64	1.093 22
	ω	72	0.667 28	0.326 34
		108	2.741 33	1.376 21
蛇形工况	v_x	72	0.136 97	0.023 32
		108	1.436 42	0.040 12
	v_y	72	1.098 27	0.409 21
		108	3.014 24	1.213 32
	ω	72	0.772 81	0.398 33
		108	2.967 95	1.503 77




图 10 路面附着系数 0.2 估计结果
Fig. 10 Estimate results of the pavement adhesion coefficient 0.2




图 11 路面附着系数 0.85 估计结果
Fig. 11 Estimate results of the pavement adhesion coefficient 0.85

由图 10、11 可知,路面附着系数的变化显著影响车辆的侧向运动特性。低附着条件下,车辆更易发生滑移现象,这导致侧向车速的变化更加激烈,进而对侧向车速的准确估计提出更高的挑战。而根据估计结果,可以看到 CPO-LSTM 算法在不同路面下的估计结果均好于 AUKF 算法,这表明该方法在面对复杂多变的行驶环境时,具备更强的鲁棒性,以及更优的状态估计性能。

表 4 两种路面下各算法估计均方根误差

Table 4 The root mean square error of each algorithm is estimated under two types of pavement

估计量	路面附着系数	AUKF	CPO-LSTM
v_x	0.2	0.253 84	0.021 67
	0.85	0.324 33	0.030 54
v_y	0.2	1.168 52	0.336 96
	0.85	1.189 65	0.403 73
ω	0.2	0.863 47	0.405 83
	0.85	0.904 22	0.453 99

4 结 论

本文从不依赖动力学模型进行车辆运动状态参数估计的角度出发,提出了基于深度学习的 CPO-LSTM 估计算法。

首先,根据 3 自由度车辆动力学模型总结了车辆运动的特性,并依此设计了纵向运动与侧向运动分离估计的 LSTM 网络。

接下来通过驾驶模拟器采集训练集以及测试集数据。数据包括了纵向车速及加速度、侧向车速及加速度、前轮转角、四轮轮速、横摆角速度。工况包括单移线工况、双移线工况、正弦转向工况等等。训练过程中利用 CPO 算法对 LSTM 网络中的隐藏层节点数、训练周期和学习率进行寻优,得到最优参数组合。

最后利用双移线工况及蛇形工况对模型进行了仿真验证,并与传统 AUKF 算法进行了比较,结果表明了在不同车速和不同路面下,CPO-LSTM 算法估计结果均优于 AUKF 算法,且对车速变化和路面附着系数变化都具备鲁棒性。

当前研究通过虚拟仿真验证了 CPO-LSTM 方法的有效性,对于实车测试方面,本文由于实验条件限制并未进行。因此实验结论具有一定的局限性,且在复杂场景适应性与模型泛化能力上仍有拓展空间。后续将搭建实车试验平台,选取不同车型与典型真实场景,采集轮速、加速度、转向角等传感器的实测数据,验证 CPO-LSTM 算法在物理环境中的鲁棒性。

基于本文探索,未来可以针对车辆的纵向运动与侧

向运动的差异性分别设计不同的神经网络模型,或是引入注意力机制,以达到更好的估计结果。

参考文献

[1] 李亮. 汽车动力学与控制 [M]. 北京:清华大学出版, 2022:130-147.
LI L. Vehicle Dynamics and Control [M]. Beijing: Tsinghua University Press, 2022:130-147.

[2] GUO H Y, CAO D P, CHEN H, et al. Vehicle dynamic state estimation: State of the art schemes and perspectives [J]. IEEE/CAA Journal of Automatica Sinica, 2018, 5 (2) : 418-431.

[3] PENDLETON S D, ANDERSEN H, DU X X, et al. Perception, planning, control, and coordination for autonomous vehicles [J]. Machines, 2017, 5 (1) : 6.

[4] 章仁燮,熊璐,余卓平. 智能汽车转向轮转角主动控制 [J]. 机械工程学报, 2017, 53 (14) : 106-113.
ZHANG R Y, XIONG L, YU ZH P. Active control of steering wheel angle of smart car [J]. Journal of Mechanical Engineering, 2017, 53 (14) : 106-113.

[5] KUUTTI S, BOWDEN R, JIN Y, et al. A survey of deep learning applications to autonomous vehicle control [J]. IEEE Transactions on ITS, 2021, 22 (2) : 712-733.

[6] ZHA Y, QUAN X, MA F, et al. Stability control for a four wheel-independent-drive electric vehicle based on model predictive control [J]. SAE International Journal of Vehicle Dynamics, Stability, and NVH, 2021, 5 (2) : 191-204.

[7] ROKONUZZAMAN M, MOHAJER N, NAHAVANDI S, et al. Model predictive control with learned vehicle dynamics for autonomous vehicle path tracking [J]. IEEE Access, 2021, 9: 128233-128249.

[8] 陈龙,刘巧斌,陶磊. 基于 GS-EKF 滤波方法的车辆状态参数估计 [J]. 东北大学学报 (自然科学版), 2023, 44 (8) : 1144-1151.
CHEN L, LIU Q B, TAO L. Vehicle state parameter estimation based on graded series extended Kalman filter method [J]. Journal of Northeastern University (Natural Science), 2023, 44 (8) : 1144-1151.

[9] 周卫琪,齐翔,陈龙,等. 基于无迹卡尔曼滤波与遗传算法相结合的车辆状态估计 [J]. 汽车工程, 2019, 41 (2) : 198-205.
ZHOU W Q, QI X, CHEN L, et al. Vehicle state estimation based on the combination of unscented Kalman filtering and genetic algorithm [J]. Automotive Engineering, 2019, 41 (2) : 198-205.

[10] 陈特,陈龙,蔡英凤,等. 基于多模型迭代的车辆状态融合估计方法 [J]. 农业机械学报, 2018, 49 (6) : 385-392.

- CHEN T, CHEN L, CAI Y F, et al. Vehicle state fusion estimation method based on multi-model iteration [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(6): 385-392.
- [11] 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): 3490-350.
- [12] 尤勇, 孟云龙, 吴景涛, 等. 基于鲸鱼优化算法-支持向量回归的汽车运动状态估计 [J]. 中国机械工程, 2024, 35(6): 973-981, 992.
- YOU Y, MENG Y L, WU J T, et al. Vehicle motion state estimation based on WOA-SVR [J]. China Mechanical Engineering, 2024, 35(6): 973-981, 992.
- [13] TONOLI A, AMATI N, GHOSH J. A deep learning based virtual sensor for vehicle sideslip angle estimation: Experimental results [C]. WCX World Congress Experience, 2018.
- [14] 高振海, 温文昊, 唐明弘, 等. 基于混合神经网络的汽车运动状态估计 [J]. 汽车工程, 2022, 44(10): 1527-1536.
- GAO Z H, WEN W H, TANG M H, et al. Estimation of vehicle motion state based on hybrid neural network [J]. Automotive Engineering, 2022, 44(10): 1527-1536.
- [15] LIU Y J, SUN Q Y, CUI D W. Vehicle state estimation based on PSO-RBF neural network [J]. International Journal of Vehicle Safety, 2019, 11(1): 93-106.
- [16] 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.
- [17] GONZALEZ L P, SANCHEZ S S, GARCIA-GUZMAN J, et al. Simultaneous estimation of vehicle roll and sideslip angles through a deep learning approach [J]. Sensors, 2020, 20(13): 18.
- [18] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [19] PAN G L, LI J, LI M L. Multi-channel multi-step spectrum prediction using transformer and stacked Bi-LSTM [J]. China Communications, 2025, 22(5): 1-13.
- [20] ABDEL-BASSET M, MOHAMED R, ABOUHAWWASH M. Crested porcupine optimizer: A new nature-inspired metaheuristic [J]. Knowledge-Based Systems, 2024, 284: 111257.
- [21] 惠永永, 孙凯文, 脱奔奔, 等. 基于 CNN-STA-DLSTM 模型的间歇过程质量预测 [J]. 电子测量与仪器学报, 2024, 38(11): 168-181.
- HUI Y Y, SUN K W, TUO B B, et al. Batch process quality prediction based on CNN-STA-DLSTM model [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(11): 168-181.

作者简介



唐浩东, 2023 年于江苏大学获得学士学位, 现为东南大学硕士研究生, 主要研究方向为组合导航。

E-mail: 1615846958@qq.com

Tang Haodong received his B. Sc. degree from Jiangsu University in 2023. Now he is a M. Sc. candidate in Southeast University. His main research interest includes combined navigation.



潘树国 (通信作者), 2007 年于东南大学获得博士学位, 现为东南大学教授, 博士生导师, 主要研究方向为 GNSS 高精度定位与环境智能感知。

E-mail: psg@seu.edu.cn

Pan Shuguo (Corresponding author) received his Ph. D. degree from Southeast University in 2007. Now he is a professor in Southeast University. His main research interests include GNSS high-precision positioning and intelligent perception of the environment.