用于自适应巡航控制的激进变道期间基于 LSTM 的前车行为预测

Rajmeet Singh[1], Saeed Mozaffari[1], Mahdi Rezaei[2], Shahpour Alirezaee[1]1机械、汽车与材料工程系。温莎大学，温莎，加拿大 {rsbhourji, saeed.mozaffari, s.alirezaee }@uwindsor.ca 2交通研究所，利兹大学，英国 m.rezaei@leeds.ac.uk

摘要—**自适应巡航控制（ACC）系统旨在通过自动调节车辆速度，确保与前车保持安全距离，从而提升车辆的安全性和舒适性。然而，传统的自适应巡航控制系统无法适应不断变化的驾驶条件和驾驶员行为。为解决这一局限性，我们提出了一种基于长短期记忆（LSTM）的自适应巡航控制系统，该系统能够从过去的驾驶经验中学习，并实时适应和预测新情况。该模型基于真实世界的*highD*数据集构建，该数据集借助搭载摄像头的无人机从德国高速公路采集。我们在激进变道情况下评估了该自适应巡航控制系统：侧车道前车突然切入，迫使目标驾驶员减速。为此，我们在模拟驾驶环境中评估了所提出的系统，并将其与前馈人工神经网络（ANN）模型和模型预测控制（MPC）模型进行了比较。结果表明，在预测本车加速度未来值方面，基于LSTM的系统比ANN模型准确率高19.25%，比MPC模型高5.9%。仿真在Matlab/Simulink环境中完成。**

I. 引言

尽管道路上的车辆数量不断增加，但确保道路安全的问题却经常被忽视。道路交通事故最常见的形式是追尾碰撞，即车辆与其前方车辆发生碰撞。这类碰撞占所有碰撞事故的 29%，并导致 7.2% 的死亡事故[1], ，其中大多数事故都归因于人为错误。高级驾驶辅助系统（ADAS）旨在通过在必要时提供提醒、警告、辅助或接管车辆控制来提高安全性和驾驶舒适性 [2]。自适应巡航控制（ACC）是高级驾驶辅助系统（ADAS）的关键组成部分，因为它能够使纵向控制系统自动调节车辆速度，并保持本车与前车之间的安全间距[3]。关于自适应巡航控制（ACC）的研究广泛探讨了多种控制方法，包括基于 PID 的控制[4], 、模糊逻辑控制[5], 、模型预测控制（MPC）[6],和神经网络（NN）[7]。在自适应巡航控制系统中采用模型预测控制（MPC）具有多项优势，包括实现精确且最优的控制、实时多目标最优控制，以及在交通拥堵期间保持较高的响应性[8]。近年来，深度学习已成为众多系统和应用领域的重要研究方向，并已应用于各种交通运输和自动驾驶驾驶应用，例如自适应巡航控制系统[9, 10], 、协同式自适应巡航控制（CACC） [11], 、交通标志识别[12], 和地图融合 [13]。据作者所知，上述文献中尚未使用真实世界数据集来开发相关模型。

本文旨在通过提出一种数据驱动方法来预测前车行为并将其纳入自适应巡航控制，从而推动该领域达到最先进水平。本文的主要贡献是预测侧车道前车（PV）激进变道期间本车（SV）的自适应巡航控制参数（加速度 m/s^2），并调整自适应巡航控制参数，以提升驾驶安全性。为此，本文使用了*highD*数据集中的高精度自然驾驶数据 [14]。该数据集包含超过 45,000 km 的自然驾驶行为数据，这些数据源自搭载摄像头的无人机在德国高速公路上拍摄的 16.5 小时视频。首先，本文采用基于 Matlab 的程序，从数据中识别前车相对于主车激进变道的模式。随后，将所得数据用作实时长短期记忆（LSTM）深度神经网络的输入，该网络预测主车的期望加速度，以适应自适应巡航控制场景。

本文分为几个部分。首先介绍问题陈述，随后介绍本研究所采用的方法。接下来对数据及其预处理进行描述。然后采用长短期记忆网络方法对数据进行训练和测试。最后，将所提出的模型与人工神经网络模型进行比较，以预测激进变道过程中侧车道前车的未来加速度值，并得出结论。

II. 问题陈述

我们考虑利用先前观测到的数据，提前调整本车的自适应巡航控制参数（加速度 m/s^2），以避免在高速公路上行驶的前车激进变道。激进变道是指一种强行加塞情形：前车驾驶员在本车前方极近处变道，导致本车驾驶员必须突然减速以避免碰撞。图 1 展示了前车从车道 3 激进变道至车道 2 的情形。形式上，我们考虑一组可观测特征 Ψ 和一组待预测的目标输出 Θ。

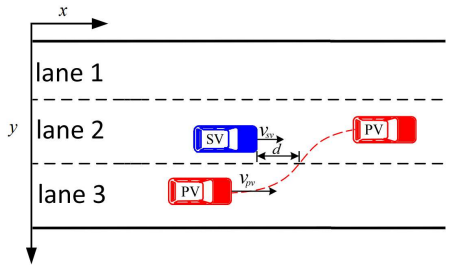

图 1. 激进变道过程中自适应巡航控制参数决策示意图。

本文中，我们的方法是训练一个用于预测主体车辆未来加速度的预测器，并将其纳入自适应巡航控制实施中。因此，我们将可用信息限制为主体车辆正前方的车辆，这些信息可在自适应巡航控制应用中获取。我们使用长短期记忆网络对处理后的 *highD* 数据集[14]数据进行训练和测试。

III. 数据与特征

A. 数据集

highD 数据集 [14] 借助搭载摄像头的无人机采集了德国高速公路的信息。研究人员在六个不同地点记录了交通情况，共涉及 110500 多辆车辆。尽管该数据集主要用于高度自动化车辆的安全验证，但也适用于许多其他任务，例如分析交通模式或对驾驶员模型进行参数化。该数据集包含车辆 ID、位置、速度、加速度等信息，如表 I 所示。

B. 数据筛选本文中，th

统计前车激进变道期间的*highD*数据。根据对影响自适应巡航控制因素的分析，并结合实际驾驶情况下本车加速度的决策行为，选取一个行驶单元中两辆车（本车和前方车辆）的共 5 项数据作为自适应巡航控制决策参数。基于这些信息，我们旨在预测本车加速度，并将其作为自适应巡航控制模型的输出。

1) 主体车辆的位置 $_{sv}$ =

X2) 前车的位置 $_{pv}$ =

X3) 主体车辆的速度

$_{sv}$ =***V***4) 前车的速度 $_{pv}$ =

V5)

车道点与主体车辆之间的距离=***d***前车变道6)

主体车辆的加速度 $_{主体车辆}$ = 自适应巡航控制

当主体车辆遇到侧车道前车变道并切入其前方的情况时，主体车辆驾驶员会降低车速并采取制动措施。前车通过后，主体车辆将恢复遵循自适应巡航控制系统，并与前车保持安全距离。

表 I. HIGHD 数据集提供的主要特征参数

数字	数据名称	Unit
1	当前帧。	编号
2	轨迹 ID	编号
3	X 坐标	m
4	Y 坐标	m
5	车辆宽度	m
6	车辆高度	m
7	X方向速度	m/s
8	Y方向速度	m/s
9	X方向加速度	m/s^2
10	Y方向加速度	m/s^2
11	前车X方向速度	m/s
12	车道编号	数字

通过对 highD 数据集进行预处理和滤波，提取决策参数（加速度），部分样本数据如表 II 所示。

IV. 长短期记忆网络模型

循环神经网络（RNN）是一种独特的神经网络，由多个神经网络以链式结构连接而成，使其能够对序列中的时间依赖关系进行建模 [15]。然而，在实际应用中，RNN 难以有效地建模长期依赖关系 [16]。为克服这一挑战，人们开发了一种称为长短期记忆（LSTM）的专用 RNN [17]。LSTM 保留了 RNN 的链式结构，但对各个单元进行了改进，使其能够更有效地学习长期依赖关系。LSTM 网络除记忆单元外，还采用输入门、遗忘门和输出门层，从而能够调节信息流。这些门层负责丢弃非必要信息，并仅保留完成特定任务所需的关键信息。LSTM 已用于预测高速公路轨迹、确定交叉路口处的驾驶员意图以及识别换道操作 [18]。为构建车辆自适应巡航控制系统的决策模型，本文采用 LSTM 网络。LSTM 模型使用 MATLAB 软件构建。

A. 训练和测试数据

该数据集涵盖四车道（每个方向两条车道）和六车道（每个方向三条车道）的高速公路，设有中央分隔带和外侧硬路肩。记录工作均在高速公路上进行。数据集包含 110,000 辆车辆的数据（81% 为轿车，19% 为卡车），总行驶距离为 45,000 km，观测到 5,600 次变道。我们考察了激进变道前后各 40 帧。本研究仅使用数据集中的纵向速度和纵向加速度时间序列。仅使用记录编号 9 至 60 的轨迹数据来训练和构建预测模型。所选数据包含记录在案的 2,449 辆车辆（2,034 辆轿车和 415 辆卡车），其中 259 辆车辆进行了激进变道。数据集同时包含轿车和卡车，因此能够捕捉混合交通场景中的驾驶员行为。数据按 80/20 的比例划分为训练集和验证集，如表III所示。测试数据集包含 15,432 条轨迹。

表 II.　　自适应巡航控制模型决策因素数据

)(sv *mX*	)(pv *mX*	)/(sv *smV*	)/(pv *smV*	***d*(*m*)**	)/(　　2主体车辆 ***sm*自适应巡航控制
154	189.16	24.93	30.78	18.08	0.03
78.71	115	24.98	32.89	23.79	0.035
122.58	162.9	23.41	26.37	20.51	0.05
209.92	252.89	30.61	34.24	35.17	0.06
213.58	256.64	30.62	34.24	35.78	0.07
222.12	266.22	30.64	34.23	36.82	0.08
224.56	268.96	30.65	34.24	37.12	0.09

表III.　　训练样本和测试样本

数据集	**激进变道 随后是本车**
训练数据	12345
测试数据	3087
总计	15432

B. 长短期记忆网络预测器的确定

为了确定 LSTM 预测器的最佳配置，我们评估其在验证数据集上的性能以及训练时间 。所提出网络各层的流程图如图 2 所示。该网络由八层组成，每层包含 200 个神经元。序列输入层将序列数据输入网络。全连接层将输入与权重矩阵相乘，然后加上偏置向量。ReLU 层对 输入的每个元素执行阈值运算，将任何小于零的值设为零。LSTM 层学习时间序列和序列数据中不同时间步之间的长期依赖关系。该层执行加性交互，有助于改善训练期间长序列上的梯度流；回归层则计算回归任务的半均方误差损失。采用 Adam 优化器调整学习率 [19]。学习率设为 0.0001。为防止过拟合，当验证准确率连续五次迭代/训练轮次未见提升时，训练过程将停止。

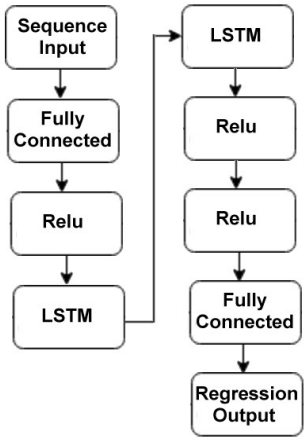

图 2.　所提出的网络层

V.　结果

本节采用均方根误差（RMSE）作为模型预测准确度的指标，对车辆加速度预测性能进行评估，其定义见以下公式（1）和（2）[18]:

$$\bar{y} = \frac{1}{N}\sum_{t=1}^{N} y_t \tag{1}$$

$$\mathrm{RMSE} = \sqrt{\frac{\sum_{t=1}^{N}\left(y_t - \hat{y}_t\right)^2}{N}} \tag{2}$$

其中，$\bar{y}$为测得加速度的平均值，y_t是 the 测得的加速度，$\hat{y}_t$是预测的加速度，N 是输出中的元素数量。图 3 显示了 LSTM 训练过程中的均方根误差值。如图 3 所示，均方根误差值收敛得非常快，并在 2000 次迭代后降至 0.025 以下。

为了比较预测准确度，将所提出的模型与具有五个隐藏层（每层含 200 个神经元）的前馈人工神经网络（人工神经网络）以及模型预测控制（模型预测控制） [6]方法进行比较。结果如图 4 所示，表明所提出模型对未来值的预测比人工神经网络和模型预测控制模型更准确。所提出模型的整体预测准确率为 98.5%，显著高于人工神经网络模型（79.25%）和模型预测控制模型（92.6%）的准确率。因此，对于所述场景，所提出的模型表现更佳。

VI. 致谢

我们感谢加拿大自然科学与工程研究委员会（NSERC）催化剂资助项目提供的资金支持。 此外，作者感谢 Manveen Kaur 女士（温莎大学）在使用 MATLAB 程序完善原始数据方面提供的协助。

VII. 结论

本研究提出了一种长短期记忆网络模型，用于预测侧车道前车引发激进变道期间本车加速度在自适应巡航控制中的未来值。所提出的系统利用从德国高速公路获取的综合数据集，能够从以往的驾驶经验中学习，并实时适应和预测新情况。

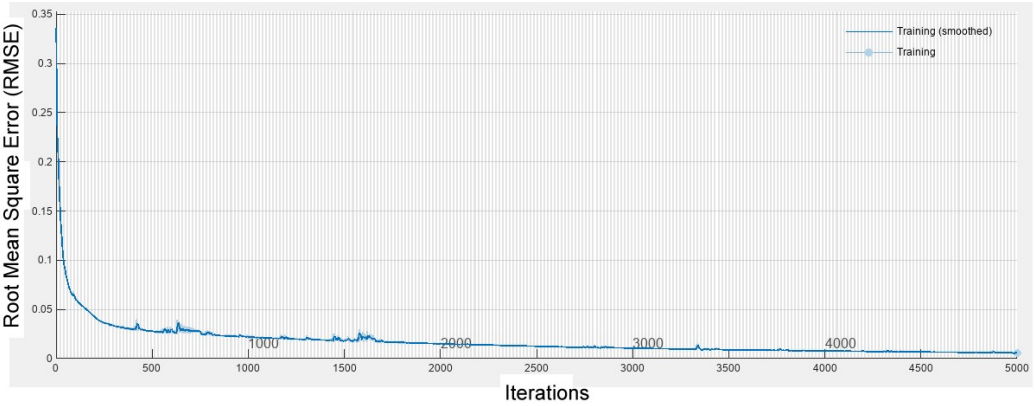

图 3. 均方根误差结果。

我们将所提出的基于长短期记忆网络的系统与其他方法进行了比较，结果表明，该系统在预测本车加速度的未来值方面优于最先进的方法。因此，可以得出结论，所提出的模型在预测侧车道前车引发激进变道期间的本车加速度方面更加有效、准确。未来，作者将针对车道合流、环岛等不同场景验证所提出的模型。

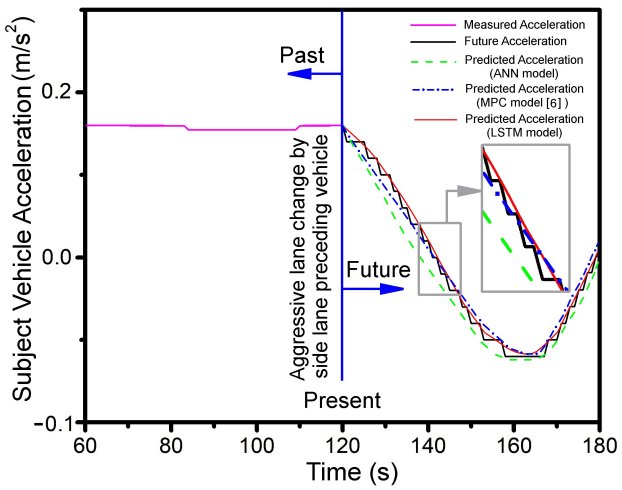

图 4. 所提出模型的预测结果。

参考文献

[1] 驾驶统计数据，elegant E-Learning, Inc.， [在线]。可访问：https://~~driving-tests.org/driving-statistics/。~~ [2] 高级驾驶辅助系统，维基媒体基金会，2021年5月13日。[在线]。可访问：https://en.wikipedia.org/wiki/Advanced_driver-assistance_systems。[3] R. Rajamani，《车辆动力学与控制》中的自适应巡航控制，Springer，2012年，第141–170页。[4] H. Balaska、S. Ladaci、H. Schulte 和 A. Djouambi，“采用分数阶模型参考自适应策略的电动汽车自适应巡航控制系统”， 9thIFAC制造建模、管理与控制会议，第52卷，第13期，第194–199页，2019年8月。

[5] G. Prabhakar、S. Selvaperumal 和 P. Nedumal Pugazhenthi，“基于模糊PD加I控制的自适应巡航控制系统：仿真与实时环境”，IETE研究期刊，第65卷，第1期，2019年。[6] R. C. Zhao、P. K. Wong、Z. C. Xie 和 J. Zhao，“用于自适应巡航控制系统的实时加权多目标模型预测控制器”，《国际汽车技术杂志》，第18卷，2017年，第279–292页。[7] M. Wang、H. Yu、G. Dong 和 M. Huang，“基于模型预测控制和神经网络的纯电动汽车双模式自适应巡航控制策略”，载于国际交通信息与安全会议，英国利物浦，2019年。[8] T. Takahama 和 D. Akasaka，“面向交通拥堵的实用自适应巡航控制设计：模型预测控制方法”，《国际汽车工程杂志》，第9卷，第3期，2018年，第99–104页。[9] D. Zhao、B. Wang 和 D. Liu，“用于自适应巡航控制的监督式Actor–Critic方法”，《软计算》，第17卷，2013年，第2089–2099页。[10] X. Chen、Y. Zhai、C. Lu、J. Gong 和 G. Wang，“个性化自适应巡航控制的学习模型”，载于IEEE智能车辆研讨会（IV），美国加利福尼亚州洛杉矶，2017年。[11] H. Ke、S. Mozaffari 和 S. Alirezaee，“利用车车通信和深度学习的协同式自适应巡航控制”。载于IEEE智能车辆研讨会论文集，第435–440页。[12] A. S. Hashemi、S. Mozaffari 和 S. Alirezaee，“提升交通标志图像识别网络的对抗鲁棒性”。《显示器》，第74卷，2022年，第102277–102282页。[13] S. Sunil、S. Mozaffari、R. Singh、B. Shahrrava 和 S. Alirezaee，“用于协同式同步定位与地图构建的基于特征的占用地图合并”。《传感器》，第23卷（6），2023年，第3114–3124页。[14] R. Krajewski、J. Bock、L. Kloeker 和 L. Eckstein，“highD 数据集：用于高度自动化驾驶系统验证的德国高速公路自然驾驶车辆轨迹无人机数据集”。载于21st国际智能交通系统会议，毛伊岛，夏威夷州，2018年。[15] D. Rumelhart、G. E. Hinton 和 R. J. Williams，“通过误差反向传播学习表征”。《自然》，第323卷，1986年，第533–536页。[16] Y. Bengio、P. Simard 和 P. Frasconi，“通过梯度下降学习长期依赖关系十分困难”。《IEEE神经网络汇刊》，第5卷，第2期，1994年，第157–166页。[17] S. Hochreiter 和 J. Schmidhuber，“长短期记忆网络”。《神经计算》，第9卷，1997年，第1735–1780页。[18] V. Mahajan、C. Katrakazas 和 C. Antoniou，“利用自动标注和深度学习预测变道动作”。《交通研究记录》，第2674卷，2020年，第336–347页。[19] D. P. Kingma 和 J. Ba，“Adam：一种随机优化方法”。arXiv预印本 arXiv:1412.6980，2014年，第1–15页。