协同自适应巡航控制系统中的驾驶员换道预测新模型

Armin Nejadhossein Qasemabadi[1], Saeed Mozaffari[2], Mahdi Rezaei[3], Majid Ahmadi[1], Shahpour Alirezaee[2]1 温莎大学电气与计算机工程系，加拿大温莎2 温莎大学机械、汽车与材料工程系，加拿大温莎 {nejadho, saeed.mozaffari, m.ahmadi, s.alirezaee } @uwindsor.ca3英国利兹大学交通研究所。 {m.rezaei@leeds.ac.uk}

摘要—准确的换道预测能够减少潜在事故并提高道路安全性。自适应巡航控制（ACC）、车道偏离规避（LDA）和车道保持辅助（LKA）是高级驾驶辅助系统（ADAS）中的一些传统模块。借助车对车通信（V2V），车辆可以与周围车辆共享交通信息，从而实现协同自适应巡航控制（CACC）。ACC 依靠车辆'的传感器获取前车的位置和速度，而 CACC 还可以通过 V2V 通信获取多辆车辆的加速度。本文比较了用于驾驶员换道预测的信息类型（位置、速度、加速度）以及周围车辆的数量。我们在 HighD 数据集上训练了一个长短期记忆网络（LSTM），用于预测换道意图。结果表明，随着周围车辆数量的增加以及从这些车辆接收的信息增多，准确率显著提高。具体而言，所提出的模型在 ACC 和 CACC 场景下分别能够以 59.15% 和 92.43% 的准确率预测自车换道。

I. Introduction

近年来，道路和高速公路上的车辆数量激增，街道上出现了更多交通拥堵和车辆事故。为解决这些问题，汽车制造商一直在开发高级驾驶辅助系统（ADAS）[1]。目前，ADAS 包含多种模块，旨在实现安全、便捷的驾驶，包括碰撞避免系统（CA）、自适应巡航控制（ACC）和车道保持辅助系统（LKA）。下一代 ADAS 和自动驾驶车辆将依靠先进的传感器技术，并利用人工智能预测驾驶员的行为和准备状态，提前采取适当措施以避免事故[2]。

变道是驾驶员最重要的行为之一，因为它是车辆碰撞的主要原因。准确的变道（LC）预测有助于提升车辆安全性和乘客舒适度。变道预测是轨迹预测的一个子类，轨迹预测旨在预测车辆未来时刻的空间坐标。与轨迹预测不同，变道预测旨在判断驾驶员是否会驶离当前车道并汇入相邻车道，还是继续在当前车道行驶。在此语境下，配备高级驾驶辅助系统（ADAS）和自动驾驶功能的车辆称为自车，自车周围的其他车辆称为周围车辆。变道预测可分为两大类：驾驶员变道换道预测 [3] 和周围车辆换道预测 [4]。换言之，驾驶员换道预测旨在预测自车是否会变道，而周围车辆换道预测则试图预测其他车辆何时会从相邻车道切入自车前方。

自动驾驶系统中常用的换道预测方法有几种，包括基于规则的方法 [5], 基于机器学习的方法 [6], 以及基于传感器融合的方法 [7]。基于规则的方法依靠车辆与周围交通之间的速度差和间距来预测变道，而基于机器学习的方法则利用周围车辆的轨迹进行预测。基于传感器融合的方法结合来自多种传感器（如摄像头、激光雷达和雷达）的数据，或通过车车通信（V2V）获取的多辆车辆的信息来预测变道。

基于智能体的方法、博弈论和混合逻辑编程已用于基于规则的换道预测 [8]。基于机器学习的方法包括贝叶斯分类器、支持向量机、隐马尔可夫模型、人工神经网络和深度学习算法 [9]。基于传感器融合的方法将车辆运动参数（如方向盘转角）、驾驶员参数（如眼动和头部转动）以及周围车辆信息（如位置、速度和加速度）结合起来 [10]。

本文聚焦于驾驶员换道预测场景，旨在探究自车状态（位置、速度、加速度）以及周围车辆数量（自适应巡航控制和协同式自适应巡航控制系统）对换道预测准确率的影响。我们采用了多个长短期记忆网络（多层LSTM）深度模型，并使用真实交通数据集（HighD）对其进行训练和评估 [11]。

II. 自适应巡航控制和协同式自适应巡航控制系统 YSTEMS

根据美国汽车工程师学会定义的L3级自动驾驶，换道算法是自适应巡航控制系统的基础；在此类系统中，车辆能够在人类驾驶员的监督下变道。

自适应巡航控制系统通常使用一种或多种传感器（如雷达、激光雷达或摄像头）来检测前方车辆的距离和速度。利用这些信息，自车可以与前车保持安全距离。然而，自适应巡航控制系统的性能受限于车载传感器约 150 米的探测范围和约 20 度的视野。因此，协同式自适应巡航控制系统应运而生，旨在以车辆间的

通信来交换车辆之间的信息[12]。与仅依赖距离和速度测量值的自适应巡航控制系统不同，协同式自适应巡航控制系统还可以利用相邻车辆的额外信息，例如其加速度曲线[13]。因此，自适应巡航控制系统和协同式自适应巡航控制系统中的信息类型和周围车辆数量有所不同。本文假设，自适应巡航控制系统能够测量当前车道、左侧车道和右侧车道中的前车（3 辆）的位置信息和速度（两个参数）。另一方面，对于协同式自适应巡航控制系统，我们假设可以获取当前车道、左侧车道和右侧车道中的前车和后车（6 辆），以及左侧车道和右侧车道中的相邻车辆（2 辆）的位置信息、速度和加速度（三个参数）。

III. 数ATASET

本文使用了 HighD 数据集，该数据集包含无人机在德国高速公路上拍摄的高分辨率视频 [11]。该数据集包含在六个不同地点记录的超过 110,000 辆车辆的轨迹。

具体而言，对于换道预测，HighD 数据集包含驾驶员完成的 5,600 次完整变道，以及周围车辆和驾驶环境的数据。与其他用于换道预测的数据集相比，从变道数量的角度来看，该数据集规模更大。例如，HighD 数据集中的变道次数是 NGSIM 的两倍 [14]。这主要是因为其平均交通密度较低，且车道数量较多。该数据集还包含元数据，提供了对换道预测有价值的信息，例如分配给每辆车的标识符、车辆的 (x,y) 位置、横向/纵向速度和加速度、车道标识，以及八辆周围车辆的标识符。图 1 展示了自车的位置、与自车处于同一车道的前车/后车 (PV、FV)、左侧相邻车道上的左侧前车/左侧并行车/左侧后车 (LP、LA、LF)，以及右侧相邻车道上的右侧前车/右侧并行车/右侧后车 (RP、RA、RF)。

IV. PROPOSED 方法

在所提出的换道预测方法中，当车辆的车道标识发生变化时，即视为开始换道。找到具有换道行为的车辆并提取所需信息后，我们训练长短期记忆网络来预测换道和车道保持行为。

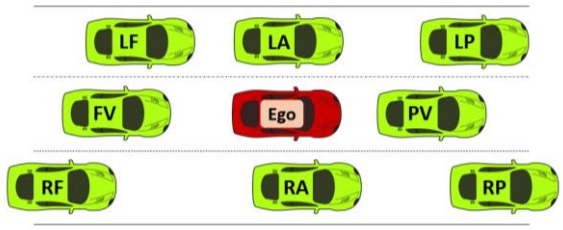


图 1. 自车及其周围车辆。

A. 变量

为训练和测试长短期记忆网络，我们首先选取发生换道的车辆，然后检测相应的换道帧。找到换道帧（f_{lc}）后，我们选取事件发生前的 n 帧，并将 $[f_{lc} - n, f_{lc}]$ 帧用作训练集。换言之，参数 n 表示数据集的时间长度。同样，我们将使用 n 帧来训练长短期记忆网络，使其预测车道保持行为。最后，从 HighD 数据集中提取周围车辆的参数，包括周围车辆与自车之间的相对距离、相对速度和相对加速度。我们将研究这些参数以及周围车辆数量对换道行为的影响。表 1 展示了编号为 48 的车辆的行为：该车从第 1137 帧到第 1147 帧位于 3rd 车道，并在第 1148 帧驶入 2nd 车道。自车周围有编号为 45、46 和 49 的车辆。如果相应位置不存在车辆，则将标识符值设为 0。

长短期记忆网络模型的输入向量取决于车辆信息以及周围车辆的类型：

$$x_t = [dp(i), dv(i), da(i)] \quad (1)$$

其中，i 表示车辆类型，其遍历集合 {LA, LP, PV, RP, RA, RF, FV, LF}。参数 dp(i)、dv(i) 和 da(i) 分别表示自车与第 i^{th} 辆车辆之间的位置、速度和加速度的曼哈顿距离。输入向量的长度还取决于换道前的帧数。

$$X_t = [x_{t-n}, \ldots, x_{t-1}, x_t] \quad (2)$$

其中，t 等于发生换道的车辆的 f_{lc}，n 为时间长度。

B. 长短期记忆网络模型

LSTM是长短期记忆（Long Short-Term Memory）的缩写，是循环神经网络（RNN）的一种变体。如图2所示，我们提出的多层LSTM网络由两个长短期记忆网络层组成，每层包含若干LSTM单元。第二层的输出经过一个包含32个神经元的全连接层（FC），以预测二进制值0或1，分别代表车道保持（LK）和换道（LC）动作。表2展示了LSTM模型的其他参数。

表 I. 发生变道的单辆样本车辆的时变值。

frame	id	x	y	xVel	yVel	xAcc	yAcc	PVId	FVId	LPId	LAId	LFId	RPId	RAId	RFId	laneId
1137	48	166.64	12.11	-33.64	-1.17	0.44	-0.21	46	49	0	0	0	0	0	45	3
1138	48	165.3	12.06	-33.62	-1.18	0.44	-0.19	46	49	0	0	0	0	0	45	3
1139	48	163.96	12.01	-33.6	-1.19	0.44	-0.17	46	49	0	0	0	0	0	45	3
1140	48	162.61	11.96	-33.58	-1.2	0.45	-0.15	46	49	0	0	0	0	0	45	3
1141	48	161.26	11.91	-33.57	-1.21	0.45	-0.13	46	49	0	0	0	0	0	45	3
1142	48	159.91	11.86	-33.55	-1.22	0.45	-0.11	46	49	0	0	0	0	0	45	3
1143	48	158.57	11.81	-33.53	-1.22	0.45	-0.08	46	49	0	0	0	0	0	45	3
1144	48	157.23	11.76	-33.51	-1.23	0.46	-0.06	46	49	0	0	0	0	0	45	3
1145	48	155.89	11.71	-33.49	-1.23	0.46	-0.04	46	49	0	0	0	0	0	45	3
1146	48	154.54	11.65	-33.48	-1.23	0.46	-0.02	46	49	0	0	0	0	0	45	3
1147	48	153.19	11.6	-33.46	-1.23	0.46	0	46	49	0	0	0	0	0	45	3
1148	48	151.85	11.55	-33.44	-1.23	0.46	0.02	0	45	46	0	49	0	0	0	2
1149	48	150.51	11.5	-33.42	-1.23	0.47	0.04	0	45	46	0	49	0	0	0	2
1150	48	149.18	11.45	-33.4	-1.22	0.47	0.06	0	45	46	0	49	0	0	0	2
1151	48	147.85	11.4	-33.38	-1.22	0.47	0.08	0	45	46	0	49	0	0	0	2
1152	48	146.53	11.35	-33.36	-1.21	0.47	0.1	0	45	46	0	49	0	0	0	2
1153	48	145.2	11.3	-33.34	-1.21	0.47	0.12	0	45	46	0	49	0	0	0	2

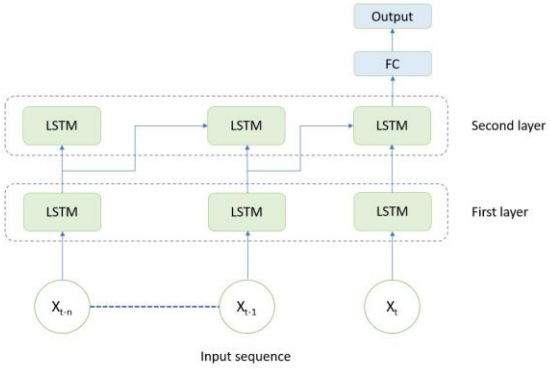


图2. 所提出的LSTM网络架构。

每个单元都会接收同一层中前序单元以及前一层的输入。处理输入后，该单元会生成输出并将其传递给后续单元。图3展示了一个由四个组件组成的LSTM单元。单元状态用于存储随时间变化的信息。输入门决定应将多少数据输入记忆单元。遗忘门表示应舍弃哪些数据，防止其进入记忆单元。最后，输出门控制记忆单元的输出，决定应保留或遗忘前一时间步的哪些信息。这使网络能够随时间选择性地记忆或遗忘信息。LSTM单元各组件之间的关系如下：

$$f_t=\sigma(W_{xf}xt+W_{hf}h_{t-1}+b_f) \quad (3)$$

$$i_t=\sigma(W_{xi}x_t+W_{hi}h_{t-1}+b_i) \quad (4)$$

$$o_t=\sigma(W_{xo}x_t+W_{ho}h_{t-1}+b_o) \quad (5)$$

$$c_t=f_t\odot c_{t-1}+i_t\odot\tanh(W_{xc}x_t+W_{hc}h_{t-1}+b_c) \quad (6)$$

$$h_t=o_t\odot\tanh(c_t) \quad (7)$$

其中 是Sigmoid函数，且是逐元素乘积，， 而是门控向量。

f_t i_t o_t

I. Experimental Results

本节研究LSTM架构、信息类型、帧数和周围车辆数量对换道预测的影响。

A. 评估指标

换道预测模型的性能可以根据准确率、精确率和召回率指标进行评估。这些指标通过使用假阳性（FP）、假阴性（FN）、真阴性（TN）和真正例（TP）的计数进行计算。

$$Accuracy=\frac{TP+TN}{TP+TN+FP+FN} \quad (8)$$

$$Precision=\frac{TP}{TP+FP} \quad (9)$$

$$Recall=\frac{TP}{TP+FN} \quad (10)$$

表II. LSTM参数。

Parameter	Description	Value
Input Dimension	CACC(8 surrounding cars, 5 frames, dp, dv, da)	120
	ACC(3 preceding cars, 5 frames, dp, dv)	30
Output Dimension	Dimension of output layer	1
Batch Size	Number of training cases over each optimizer update	32
Hidden Layer Number	Number of LSTM layers	2
Dropout rate	The rate used in dropout layers	0.2
Number of epochs	Number of training update	100
Loss function	Function to calculate loss	Binary cross entropy
Activation Function	Function to activate output of LSTM layers	Relu
Optimizer	The fuction to minimize loss	RMSprop

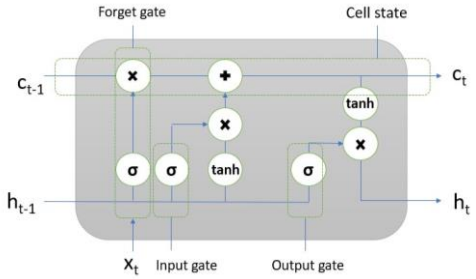


图3。一个LSTM单元。

B. LSTM架构

在本实验中，我们研究了LSTM单元数量对换道预测的影响。表3显示，将单元数量从8增加到128可提升LSTM的性能，在所有测试数据集上的准确率平均提高了2%。然而，当使用256个单元时，由于过拟合问题，准确率下降至91.97，此时多层LSTM开始记忆数据。因此，在后续实验中选择了128个单元。

C. 车辆'信息

为评估纳入有关周围车辆的多种信息对各项指标的影响，我们分析了三种不同情形：仅使用 dp、同时使用 dp 和 dv，以及使用包括 dp、dv 和 da 在内的全部可用信息。如表 4 所示，增加

表III. LSTM单元数量的影响。

LSTM Units	Accuracy	Precision	Recall
8	90.47	95.33	85.43
16	91.49	96.33	86.03
32	91.74	96.11	87.23
64	91.15	95.98	85.79
128	92.43	96.87	87.96
256	91.97	96.21	87.14

表IV. 车辆'信息的影响。

Vehicle's Information	Accuracy	Precision	Recall
dp	89.45	96.12	82.67
dp, dv	90.94	93.57	87.92
dp, dv, da	92.43	96.87	87.96

信息量 能够提高换道准确率。然而，纳入更多数据会显著增加执行时间：仅使用 *dp* 时耗时 540 秒，而使用 *dp*、*dv* 和 *dp*、*dv*、*da* 时则分别耗时 986 秒和 1624 秒。

D. 帧集大小

换道前的时间长度（帧集大小）决定了输入序列长度，对 LSTM网络所做预测的准确率有显著影响。如果帧集大小过小，网络可能没有足够的信息来做出准确预测。另一方面，如果帧集大小过大，网络可能会受到无关信息、计算量过大以及梯度消失问题的影响。图 4 显示，帧集大小为 5 时，换道预测效果最佳。

E. 自适应巡航控制（ACC）与协同式自适应巡航控制（CACC）系统

车辆相对于自车的数量和位置，是我们系统设计中的关键因素。对此，我们对表 5 所示的四种不同场景的性能指标进行了全面分析。实验表明，纳入有关并行车辆的信息并未提高网络的准确率，因为该区域存在车辆通常会导致车道保持（LK）。此外，比较表 5 的第一行和最后一行可以发现，与仅使用三辆前方车辆的场景相比，使用所有周围车辆时，各项指标均有显著提升。

VI. 结论

本研究探讨了车对车通信以及车辆信息类型对变道预测准确率的影响。结果表明，所提出的模型采用在 HighD 数据集上训练的长短期记忆网络；随着周围车辆数量及其信息的增加，该模型的准确率显著提高。将场景从自适应巡航控制改为协同式自适应巡航控制后，准确率提高了 33.28%。将长短期记忆网络单元数量增加至 128，并将帧集大小设为 5，可获得最高准确率。此外，使用更多其他车辆的信息可提高换道预测准确率，但会增加计算负担。

致谢

我们感谢加拿大自然科学与工程研究委员会（NSERC）催化剂基金的资助。

表 V. 车辆类型的影响

Type of Vehicles	Accuracy	Precision	Recall
LP, PV, RP	59.15	78.54	28.43
LF, FV, RF	92.26	96.18	87.65
LP, PV, RP, LA, RA	62.89	75.29	34.8
LP, PV, RP, LA, RA, LF, FV, RF	92.43	96.87	87.96

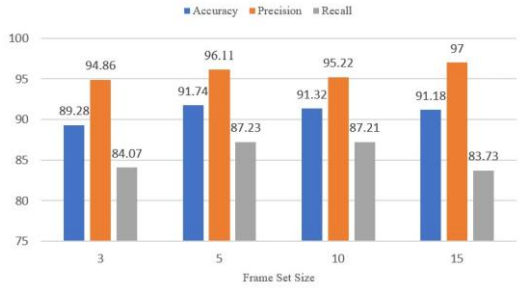


图 4. 帧集大小的影响。

REFERENCES

[1] V. K. Kukkala、J. Tunnell、S. Pasricha 和 T. Bradley，“高级驾驶辅助系统：迈向自动驾驶汽车的道路”，载于《IEEE消费电子杂志》，第 7 卷第 5 期，第 18–25 页，2018 年 9 月。

[2] Brenna D. Argall、Sonia Chernova、Manuela Veloso、Brett Browning，“机器人示范学习综述，”《机器人与自主系统》，第57卷，第5期，2009年，第469-483页。[3] Y. Xing 等，“智能车辆驾驶员变道意图推断：框架、综述与挑战”，载于《IEEE车辆技术汇刊》，第68卷，第5期，第4377-4390页，2019年5月。[4] R. Song 和 B. Li，“智能车辆周边车辆变道操作预测与检测：全面综述”，载于《IEEE智能交通系统汇刊》，第23卷，第7期，第6046-6062页，2022年7月。[5] B. Khelfa 和 A. Tordeux，“高速公路变道预测：基于经验比较规则的 MOBIL 模型与朴素贝叶斯算法”，2021年 IEEE智能交通系统国际会议（ITSC），美国印第安纳州印第安纳波利斯，2021年，第1598-1603页。[6] C. Ou 和 F. Karray，“基于深度学习的驾驶操作预测系统”，载于《IEEE车辆技术汇刊》，第69卷，第2期，第1328-1340页，2020年2月。[7] Yingshi Guo、Hongjia Zhang、Chang Wang、Qinyu Sun、Wanmin Li，“联网环境中的驾驶员变道意图识别”，《物理学A：统计力学及其应用》，第575卷，2021年。[8] B. Khelfa 和 A. Tordeux，“高速公路变道预测：基于经验比较规则的 MOBIL 模型与朴素贝叶斯算法”，2021年 IEEE智能交通系统国际会议（ITSC），美国印第安纳州印第安纳波利斯，2021年，第1598-1603页。[9] S. Mozaffari、O. Y. Al-Jarrah、M. Dianati、P. Jennings 和 A. Mouzakitis，“面向自动驾驶应用的基于深度学习的车辆行为预测：综述”，载于《IEEE智能交通系统汇刊》，第23卷，第1期，第33-47页，2022年1月。[10] Hongyu Guo、Mehdi Keyvan-Ekbatani、Kun Xie，“利用真实世界联网车辆数据进行变道检测与预测”，《交通研究C辑：新兴技术》，第142卷，2022年，103785，ISSN 0968-090X。[11] R. Krajewski、J. Bock、L. Kloeker 和 L. Eckstein，“HighD 数据集：用于验证高度自动化驾驶系统的德国高速公路自然驾驶车辆轨迹无人机数据集”，2018年第21届智能交通系统国际会议（ITSC），美国夏威夷州毛伊岛，2018年，第2118-2125页。[12] H. Ke、S. Mozaffari、S. Alirezaee 和 M. Saif，“利用车对车通信和深度学习实现协同自适应巡航控制”，2022年 IEEE智能车辆研讨会（IV），德国亚琛，2022年，第435-440页，doi: 10.1109/IV51971.2022.9827148。[13] Z. Mu 等，“干道混合交通中协同自适应巡航控制的评估”，2021年 IEEE智能交通系统国际会议（ITSC），美国印第安纳州印第安纳波利斯，2021年，第3851-3856页。[14] J. Colyar 和 J. Halkias，NGSIM - 美国101号公路数据集。
h
ttps://www.fhwa.dot.gov/publications/research/operations/07030/07030.pdf