

融合变道意图识别的车辆轨迹预测 GAN 模型^①



王雪阳, 刘 茜

(长安大学 信息工程学院, 西安 710064)
通信作者: 王雪阳, E-mail: w_xymail@163.com

摘 要: 车辆轨迹预测能够有效降低车辆轨迹突变造成的碰撞风险, 是实现安全驾驶的关键技术之一. 针对传统轨迹预测算法缺乏对驾驶员意图分析的问题, 本文提出了一种融合生成对抗网络和驾驶意图识别的车辆轨迹预测模型. 该模型基于生成对抗网络框架预测车辆轨迹, 并引入基于深度神经网络的变道意图识别模块识别驾驶员的变道意图. 通过在公开数据集 NGSIM 上与 LSTM、S-LSTM、CS-LSTM 和 S-GAN 模型进行对比试验, 实验结果表明与其他轨迹预测模型相比, 本文提出的 CS-DNN-GAN 模型具有较好的预测精确度.

关键词: 轨迹预测; 驾驶意图; 生成对抗网络; LSTM

引用格式: 王雪阳, 刘茜. 融合变道意图识别的车辆轨迹预测 GAN 模型. 计算机系统应用, 2023, 32(4): 354-360. <http://www.c-s-a.org.cn/1003-3254/9040.html>

GAN Model of Vehicle Trajectory Prediction Based on Lane Changing Intention Recognition

WANG Xue-Yang, LIU Xi

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

Abstract: Vehicle trajectory prediction can effectively reduce the collision risk caused by the sudden change of a vehicle trajectory, which is one of the key technologies to achieve safe driving. To address the problem that the traditional trajectory prediction algorithm lacks the analysis of the driver's intention, this study proposes a vehicle trajectory prediction model that integrates generative adversarial networks and driving intention recognition. The model predicts vehicle trajectories under a generative adversarial network framework and introduces a deep neural network-based lane change intention recognition module to identify the driver's lane change intention. A comparison test with LSTM, S-LSTM, CS-LSTM and S-GAN models is carried out on the public data set NGSIM. The experimental results show that compared with other trajectory prediction models, the CS-DNN-GAN model proposed in this study has better prediction accuracy.

Key words: trajectory prediction; driving intention; generative adversarial networks (GAN); long short-term memory (LSTM)

1 引言

近年来, 随着智能交通系统、车联网、智慧城市等概念的提出和自动驾驶技术的不断发展, 依赖于车辆轨迹的各种应用的需求不断扩大, 如交通事故预防、交通拥堵缓解、城市交通管理等.

国内外学者对轨迹预测做了广泛研究. 多数轨迹预测算法都是基于 LSTM 的改进. Alahi 等^[1] 提出用于行人轨迹预测的模型 Social-LSTM, 此模型将轨迹预测问题看成序列生成任务, 并引入社交池化层 (social pooling) 在 LSTM 之间共享信息. 郭景华等^[2] 提出了一

^① 基金项目: 国家重点研发计划 (2018YFB1600800)

收稿时间: 2022-08-29; 修改时间: 2022-09-30; 采用时间: 2022-10-27; csa 在线出版时间: 2022-12-23

CNKI 网络首发时间: 2022-12-27

种基于深度学习的改进型 Bi-LSTM 神经网络预测车辆的切入轨迹,在双向长短时记忆网络的基础上引入快捷连接,并考虑了自车对周边车辆切入的影响。秦胜君等^[3]结合强化学习的 Q-learning 算法和深度学习的 LSTM 网络,提出了一个多交互车辆轨迹预测模型 Q-LSTM。Gupta 等^[4]在 S-LSTM 模型基础上提出一种新颖的基于 GAN 的编码-解码器框架 Social-GAN,该模型可以较好地应用于行人轨迹预测领域。

也有众多学者提出识别驾驶意图并进行轨迹预测。季学武等^[5]提出了一种由驾驶意图识别和轨迹预测模块组成的基于深度学习的轨迹预测模型,该模型弥补了传统轨迹预测在预测长时域轨迹方面的不足,使驾驶意图的预判性和准确性得到显著提升。但是该模型适用于高速路段,具有局限性。温惠英等^[6]针对交通场景中的换道轨迹预测,提出了一种基于 GAN 的轨迹预测模型。Pan 等^[7]利用 LSTM 的注意力机制,学习驾驶员的意图和车辆在道路基础设施的位置变化之间的关系来指导预测。刘创等^[8]基于经典的 CS-LSTM 轨迹预测算法,引入横向注意力机制用于轨迹预测。除此之外,由于车辆轨迹可以离散化为序列信息,运动预测可以被视为序列生成任务,因此基于 DNN 的方法因其独特的优势已广泛用于车辆轨迹预测领域,它可以融合更多的信息来预测车辆轨迹,例如周围车辆的历史轨迹、行人信息和场景中的环境信息。也有大量研究使用深度神经网络 (DNN)^[9-12]进行车辆轨迹预测。

综上所述,虽然许多文献都采用了适合序列数据的 LSTM 网络,但是该网络并不适合复杂场景下多个车辆之间的交互。同时,由于缺少对驾驶员行为的考虑与分析,因此并不能很好地模拟真实社会中的驾驶环境,从而导致预测的轨迹与真实的车辆轨迹存在一定的偏差。因此本文提出基于 GAN 的轨迹预测模型 CS-GAN,并融入基于 DNN 的驾驶意图模块,以此来增强轨迹预测模型的准确性。

2 问题定义

车辆轨迹预测问题可以定义为,在一个给定场景中,给出车辆的历史轨迹信息,模型根据历史轨迹预测车辆的未来轨迹。本文的目标是预测该场景下所有车辆的未来轨迹。假设在一个数据集中,所有车辆的历史轨迹为 $X = X_1, X_2, \dots, X_n$, 预测所有车辆的未来轨迹为

$\hat{Y} = \hat{Y}_1, \hat{Y}_2, \dots, \hat{Y}_n$ 。在时间范围 $t = 1, \dots, t_{obs}$, 将车辆 i 的输入轨迹定义为 $X_i = (x_i^t, y_i^t)$, 而在时间范围 $t = t_{obs}+1, \dots, t_{pred}$, 真值的未来轨迹定义为 $Y_i = (x_i^t, y_i^t)$ 。本文的目标是训练一个可以预测车辆轨迹的模型,即通过输入 X_i , 可以预测车辆的未来轨迹 Y_i 。

3 车辆轨迹预测模型

本文的车辆轨迹预测模型基于 GAN 网络框架搭建,并引入 DNN 来识别驾驶意图,形成了一种具有驾驶意图分析的车辆轨迹预测模型。包括轨迹生成模块、轨迹判别模块和驾驶意图识别模块 3 部分。生成器和判别器基于 GAN 网络搭建。其中生成器用于生成轨迹数据,而判别器用于评估由生成模块产生的轨迹与真实轨迹间的差异,进而不断优化生成器的输出。驾驶意图识别模块基于 DNN 深度神经网络,将换道轨迹数据作为输入,得到驾驶员的意图类别预测结果。如图 1 所示,轨迹生成模型由编码-解码器框架组成,编码器对各个车辆信息进行编码,编码-解码器中间嵌入了一个卷积社交池化模块,用于将编码器和解码器的隐藏状态进行连接,解码器以驾驶意图识别模块生成的编码向量 x 、池化模块的输出编码和高斯噪声为输入,生成车辆的预测轨迹,输入到轨迹判别器中。在轨迹判别器中对轨迹生成模型生成的预测轨迹与实际输入的真实轨迹进行编码,辨别真实车辆轨迹与生成的车辆轨迹之间的差异。

3.1 轨迹生成模型

轨迹生成模型包括编码器、卷积社交池化和解码器 3 个模块。编码器对各个车辆轨迹信息进行编码,存储历史信息。卷积池化模块位于编码器和解码器中间。解码器将信息解码,得到预测的轨迹。

3.1.1 编码器模块

本文使用 LSTM 网络作为生成模型。首先使用多层感知机 MLP 来编码每辆车的位置 (x, y) , 这里的 (x, y) 是相对于上一个时间步的相对位置,以此来获取固定长度的特征 e^t 。这些特征 e^t 作为编码器 LSTM 的输入,计算公式如式 (1) 和式 (2):

$$e_i^t = \phi(x_i^t, y_i^t; W_\phi) \quad (1)$$

$$h_{ei}^t = LSTM(h_{ei}^{t-1}, e_i^t; W_e) \quad (2)$$

其中, ϕ 是带有 ReLU 函数的嵌入函数, $LSTM$ 是网络映射函数, W_ϕ 是嵌入函数的权重, h_{ei}^{t-1} 是上一时间步的隐

隐藏向量, W_e 是 LSTM 权重, h'_{ei} 是当前的隐藏向量. 编码器学习一辆车的状态并存储历史信息, 网络结构抽象图如图 2 所示.

3.1.2 卷积社交池化模块

LSTM 网络虽然可以学习车辆的运动状态, 但无法

学习车辆之间的交互. Alahi 等^[1] 针对车辆之间缺乏交互的问题, 提出用社交池化将被预测车辆周围的所有车辆状态都汇集到一个社交张量中. 但是该类方法会破坏社交张量的内部空间结构, 空间中相邻的单元格在全连接层中可能会彼此远离.

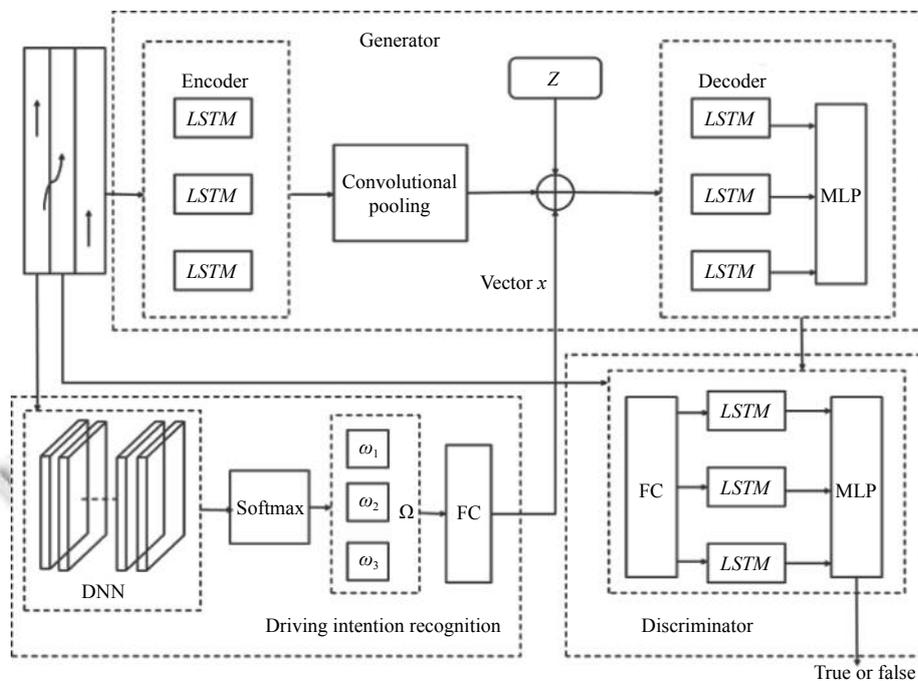


图 1 车辆轨迹预测模型框架图

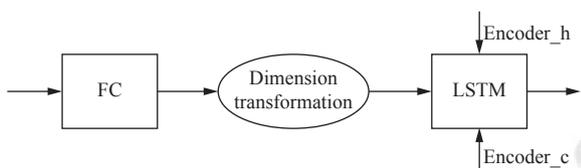


图 2 编码器的网络结构抽象

为了解决该问题, 本文采取 Deo 等^[13] 提出的方法, 在社交张量上采用由卷积层和池化层组成的卷积社交池化层, 用卷积层抓取局部车辆相对位置, 以此来弥补 LSTM 不能感知相对位置的缺点, 从而更稳健地学习车辆之间的交互. 结构如图 3 所示, 在被预测车辆周围定义一个 13×3 的空间网格, 其中, 行与行之间约为一辆车的距离, 每列对应一个车道, 通过周围车辆的位置填充这个空间网格, 进而形成社交张量. 图 3 中分别有 5 辆车, 位于目标车辆的四围, 然后分别将两个大小为 3×3 和 1×1 的卷积核和一个最大池化层应用于社交张量中, 以此来获取社交上下文编码. 目标车辆通过全连

接层获取车辆编码, 之后将两个编码组合起来形成完整的轨迹编码, 然后再加入防止模型泛化的随机噪声 z 向量, 和驾驶意图识别的模块的输出概率向量一起作为解码器的输入.

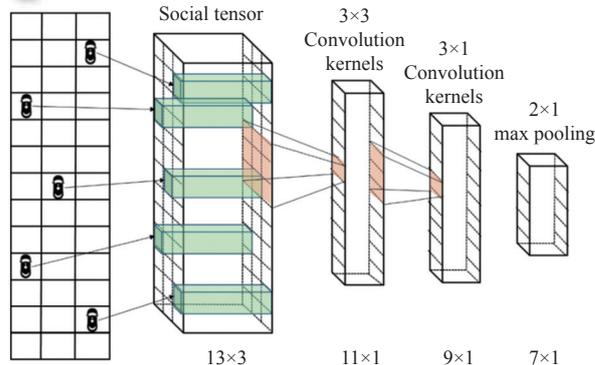


图 3 卷积社会池化模块具体结构

3.1.3 解码器模块

轨迹解码器 Decoder 由 LSTM 网络组成, 网络结构抽象图如图 4 所示. 在运行解码器之前, 先对 LSTM

网络进行初始化. 将经过编码器上一层的隐藏状态向量和经过卷积池化模块得到的向量, 以及驾驶意图识别模块生成的输出概率编码、与随机噪声向量 z 一起输入到解码器中得到生成器生成的预测轨迹, 将其作为全新的特征编码. 为了产生与过去一致的未来场景, 要初始化解码器的隐藏状态, 解码器的相关公式如式(3)–式(6)所示:

$$c_i^{(t-1)} = \gamma(P_i, h_{ei}^{t-1}, W_c) \quad (3)$$

$$h_{di}^{t-1} = [c_i^{(t-1)}, z] \quad (4)$$

$$h_{di}^t = LSTM(\gamma(\hat{Y}_i^{(t-1)}; W_{(y_d)}), h_{di}^{t-1}; W_d) \quad (5)$$

$$\hat{Y}_i^t = \gamma(h_{di}^t) \quad (6)$$

其中, c_i^{t-1} 是生成的轨迹, γ 是一个带 ReLU 函数的多层感知机 MLP, P_i 是经过卷积池化模块后车辆的张量, h_{ei}^{t-1} 是隐藏向量, W_c 是嵌入权重. W_d 是 LSTM 的权重, c_i^{t-1} 和随机噪声 z 组成得到 h_{di}^{t-1} , 作为解码器的输入向量, 将其输入到多层感知机 MLP 最终得到预测轨迹 \hat{Y}_i^t .

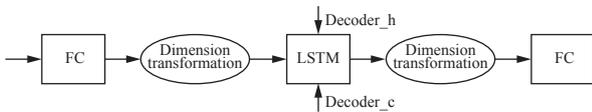


图4 解码器的网络结构抽象图

3.2 轨迹判别模型

判别模型是由一个单独的编码器构成的, 本质上属于分类模型, 它的输入是真实的车辆轨迹 $T_{\text{real}} = X_i$ 和生成器生成的虚假轨迹 $T_{\text{fake}} = \hat{Y}_i$. 判别器的作用是对生成器所生成的轨迹序列进行判断, 判断其是否为车辆真实轨迹序列. 通过将多层感知机应用在编码器的最后一个隐藏状态上来获取得分, 当生成的轨迹与真实轨迹越接近时, 判别器的得分越接近 1, 反之则判别器的分数越接近 0. 当判别器不再能分辨出预测轨迹与真实轨迹时, 训练达到平衡, 此时生成模型生成的轨迹最符合真实的轨迹分布.

3.3 驾驶意图识别模型

提出驾驶意图识别模型的目的是为了从数据中识别驾驶员的意图. 利用这种深度架构来从时间序列车辆数据中提取重要的信息. 重新制定时间序列预测问题, 便可以学习特征和标签之间的时间关系. 如图5所示. 驾驶意图识别模型主要是将驾驶员的换道意图转变为特征向量 x , 具体的做法是先将处理好的换道数据

集输入到一个由 1 个输入层、4 个隐藏层和 1 个输出层构成的深度神经网络 DNN 中. 其中, 隐藏层的激活函数为 \tanh , 输出层的激活函数为 Softmax , 用于识别驾驶员的意图并计算向左转弯、向右转弯、保持直行的概率, 生成驾驶意图概率向量 $\Omega = (\Omega_1, \Omega_2, \Omega_3)$. 将驾驶意图模块得到的编码向量与随机噪声 z 以及卷积池化模块的输出一起输入到编码器中, 实现驾驶意图识别模块与基于 GAN 网络的轨迹预测模型的融合, 形成本文的车辆轨迹预测方法.

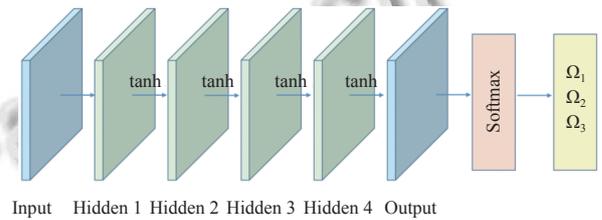


图5 驾驶意图识别模型流程示意图

3.4 损失函数

本文采用的损失函数除对抗性损失 $L_{\text{GAN}}(G, D)$ 以外, 还有轨迹预测上的损失 $L_{L2}(G)$, $L_{\text{GAN}}(G, D)$ 为生成对抗网络在对抗训练时的损失值, $L_{L2}(G)$ 计算生成的轨迹数据与真实的轨迹数据之间的差值. 加入损失函数的目的是为了不断缩小虚假轨迹数据与真实轨迹数据之间的差距. 通过 loss 反向传播, 不断地优化网络模型中各层网络的权重和参数, 使得生成模型生成的轨迹更加符合真实的轨迹分布. 损失函数的计算公式如式(7)–式(9)所示:

$$L = L_{\text{GAN}}(G, D) + \alpha L_{L2}(G) \quad (7)$$

$$L_{\text{GAN}}(G, D) = \min_G \max_D E_{T_{\text{real}} \sim P_{\text{data}}(X_i, Y_i)} [\log D(T_i)] + E_{z \sim p(z)} [\log(1 - D(G(X_i, z)))] \quad (8)$$

$$L_{L2}(G) = \min_k Y_i - G(X, z)_2^{(k)} \quad (9)$$

其中, E 代表着期望值; k 是超参数, 表示生成器的采样次数; α 是权重.

4 实验

4.1 数据集选取

本文选取的数据集是网上的开源数据集 NGSIM, 该数据集由 I-80、US-101、Lankershim 和 Peachtree 这 4 个不同路段的车辆轨迹组成. NGSIM 数据集是用同步数字摄像机网络收集, 并通过 NGVIDEO 软件, 以每秒 10 帧或者 15 帧的频率加工成一条一条的轨迹点

记录, 以此来得到详细的轨迹数据和车道信息. 本文选取 US-101 路段的数据进行研究. 如图 6 所示.

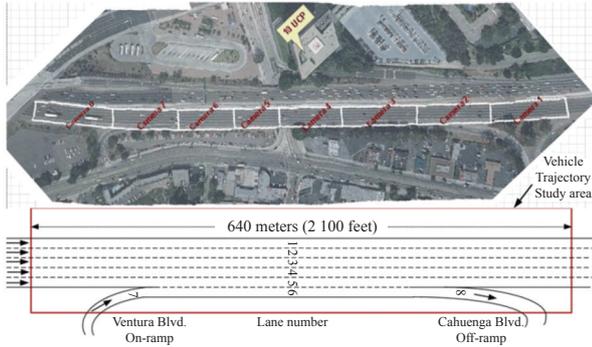


图 6 US-101 高速公路匝道口示意图

定义两种数据如下: 如果行驶轨迹的横向位置不包括与车道线横向位置重合的点, 则可以判断车辆沿当前车道行驶, 没有变道行为, 判定为直线行驶轨迹; 如果车头通过车道线并且在一定时间内没有回到当前车道, 则被判定为变道数据.

进一步地, 在数据清理的基础上, 增加驾驶过程中变道行为的重要特征. 计算方法如式 (10)–式 (16) 所示:

$$\Delta x = x_{t+1} - x_t \quad (10)$$

其中, x_t 为当前时刻车辆的横向位置, x_{t+1} 为 0.1 s 后车辆的横向位置, Δx 为横向位移差值.

$$\Delta y = y_{t+1} - y_t \quad (11)$$

其中, y_t 为当前时刻车辆的纵向位置, y_{t+1} 为 0.1 s 后车辆的纵向位置, Δy 为纵向位移差.

$$V_x^{t+1} = \frac{\Delta x}{t} \quad (12)$$

其中, t 为横向位移变化期间的总时间, V_x^{t+1} 为横向位移从 t 变化到 $t+1$ 后车辆的瞬时速度.

$$V_y^{t+1} = \frac{\Delta y}{t} \quad (13)$$

其中, t 为纵向位移变化期间的总时间, V_y^{t+1} 为纵向位移从 t 变化到 $t+1$ 后车辆的瞬时速度.

$$a_x^{t+1} = \frac{V_x^{t+1} - V_x^t}{t} \quad (14)$$

其中, a_x^{t+1} 为 $t+1$ 时车辆的瞬时加速度.

$$\theta = \tan^{-1} \left(\frac{\Delta y}{\Delta x} \right) \quad (15)$$

其中, θ 为车辆的航向角.

最后, 对数据进行归一化操作. 采用最大-最小标准化方法, 将数据变为 $[0, 1]$ 区间内的小数. 转换函数如式 (16) 所示:

$$x = \frac{x - \min}{\max - \min} \quad (16)$$

其中, \max 是样本数据中的最大值, \min 是样本数据中的最小值.

4.2 评价指标

为了评估车辆轨迹预测模型的准确性, 本文使用平均位移误差 ADE 和最终位移误差 FDE 作为模型的评价指标.

平均位移误差 ADE 是衡量对象预测位置与预测时间段内, 每个实际位置与每个预测位置之间的平均欧式距离偏差的指标. 公式如式 (17) 所示:

$$ADE = \frac{\sum_{i \in N} \sum_{t \in T} \|\hat{x}_i^t - x_i^t\|_2}{NT} \quad (17)$$

最终位移误差 FDE 是预测一段时间内预测车辆最终位置点和真实最终位置点之间的平均欧式距离差值. 公式如式 (18) 所示:

$$FDE = \frac{\sum_{i \in N} \|\hat{x}_i^T - x_i^T\|_2}{N}, t = T \quad (18)$$

其中, N 代表轨迹样本的总数, T 代表最后时刻, x_i^t 代表真实轨迹, \hat{x}_i^t 代表预测轨迹.

5 实验结果与分析

5.1 模型训练细节

本文使用 LSTM 作为模型的主干网络. 生成器中编码器隐藏层的维度为 32, 解码器隐藏层的维度为 32, 判别器中编码器隐藏层的维度为 64. 采用的优化器为 Adam. Batch_size 为 64, epoch 为 1000, 初始学习率为 0.001. 实验使用 Python 3.6 和 PyTorch 1.8.0 开发神经网络轨迹预测模型, 硬件环境为 Window 10 下具有 Intel(R) Xeon(R) CPU E5620@2.40 GHz 和 NVIDIA GeForce RTX 3060 的 PC.

5.2 实验结果对比

为了验证本文提出的轨迹预测模型的有效性, 选用 LSTM^[14]、Social-LSTM^[1]、CS-LSTM^[13]、Social-GAN^[2] 与本文提出的 CS-DNN-GAN 进行对比.

表 1 给出了在 5 s 预测时长下, 各个模型在 NGSIM 数据集上的 ADE 和 FDE .

观察表 1 中的数据, 可以看出本文提出的 CS-DNN-GAN 模型在 NGSIM 数据集上的误差要小于其他模型. S-LSTM 模型只在特定密度的交通数据集中才会有较好的效果, 具有局限性, 并且采用的池化模块只

有最大池化,与 S-LSTM 模型相比,CS-LSTM 中的卷积社交池化层能够更稳健地学习车辆之间的交互。S-GAN 模型较优于 CS-LSTM 模型,这是因为 S-GAN 提出的模型中加入了生成对抗网络 GAN。但它只考虑了车辆之间的位置关系,缺乏考虑车辆的运动方向会对轨迹产生影响,并且在现实生活中的交通情况往往较为复杂,驾驶员的变道意图也会影响车辆的轨迹预测。由于本文提出使用卷积社交池化模块替换了 S-GAN 中的最大池化模块,使得轨迹生成器能够稳健地对车辆之间的交互进行建模,引入了基于 DNN 的驾驶意图识别模块,因此本文提出的 CS-DNN-GAN 模型的精确度要优于 S-GAN 模型。由此可见,融入驾驶意图之后,轨迹预测模型的准确率会有所提升。

表1 各模型在 NGSIM 数据集上的 ADE 和 FDE

评价指标	LSTM	S-LSTM	CS-LSTM	S-GAN	CS-DNN-GAN
ADE	6.96	5.87	4.95	3.64	2.85
FDE	6.98	7.42	5.78	4.58	3.48

此外,预测的时间长短也会对轨迹预测模型的训练效果产生不同程度的影响,表2和表3分别展示了在 1-5 s 的预测时长下,各模型的平均位移误差 ADE 和最终位移误差 FDE。图7展示了在不同预测时长下的误差曲线图。

表2 不同时长下各模型的平均位移误差 ADE

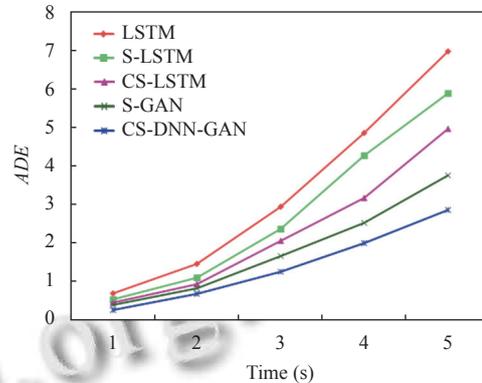
时长 (s)	LSTM	S-LSTM	CS-LSTM	S-GAN	CS-DNN-GAN
1	0.68	0.53	0.44	0.39	0.25
2	1.45	1.09	0.92	0.81	0.67
3	2.93	2.36	2.05	1.65	1.24
4	4.84	4.25	3.16	2.51	1.98
5	6.96	5.87	4.95	3.74	2.85

表3 不同时长下各模型的最终位移误差 FDE

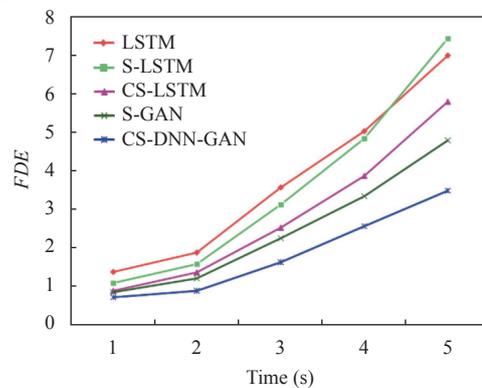
时长 (s)	LSTM	S-LSTM	CS-LSTM	S-GAN	CS-DNN-GAN
1	1.37	1.09	0.89	0.85	0.72
2	1.88	1.58	1.36	1.21	0.89
3	3.56	3.12	2.52	2.25	1.63
4	5.02	4.83	3.86	3.34	2.56
5	6.98	7.42	5.78	4.78	3.48

由表2和表3可知,随着预测时长的增加,各个模型的准确率也在随之下降。由图7可明显看出,CS-DNN-GAN 模型的预测误差是最低的,对比 LSTM 和 S-LSTM 曲线,可以看出在加入预测车辆周围车辆信息后,模型的预测精度明显有所提升,这也验证了本文提出的模型将车辆之间的交互信息作为输入的有效性。对比图7中 S-GAN 和 CS-DNN-GAN 模型的误差曲线图,可明显得知加入驾驶意图模块使得长时间预测的准确性得以

提高。此外,随着预测时间的增加,CS-DNN-GAN 模型的误差并没有像其他模型一样陡然上升,这反映了加入驾驶意图识别模块可以提高预测的稳定性。



(a) 不同预测时长下各模型的 ADE 值



(b) 不同预测时长下各模型的 FDE 值

图7 不同预测时长下各模型的 ADE 和 FDE 值

图8可视化了5组对比实验的换道轨迹预测效果。从图8可以看出,本文提出的 CS-DNN-GAN 模型的轨迹预测效果与真实轨迹是最接近的。进一步观察,在轨迹较平滑时,5种模型都有不错的预测轨迹,这证明普通的 LSTM 网络可以预测简单的换道行为,但是随着预测时长增加,LSTM 的预测效果较差,说明普通的 LSTM 模型不具有稳定性。S-LSTM 的预测效果要明显优于 LSTM 模型,这可以证明加入社交池 (social pooling),即车辆之间的交互关系,能够提高模型预测的准确性。再观察 S-LSTM 和 CS-LSTM 的预测轨迹图,发现 CS-LSTM 的预测效果要略优于 S-LSTM,这是因为与社交池相比,加入卷积层与社交层的组合更能接近真实轨迹。再对比 S-GAN 模型和本文提出的 CS-DNN-GAN 模型,不难发现两者的可视化轨迹图都要优于其他模型,这说明了本文选择 GAN 基本框架的可靠性,因为 GAN 的对抗训练特点能够提高模型对概率分布的模拟近似能力。然而,在加入基于 DNN 的驾驶意图识别

模块之后, CS-DNN-GAN 模型的预测效果要略优于 S-GAN 模型, 这是因为在现实的交通环境中, 驾驶员行为对轨迹预测的影响也十分重大。

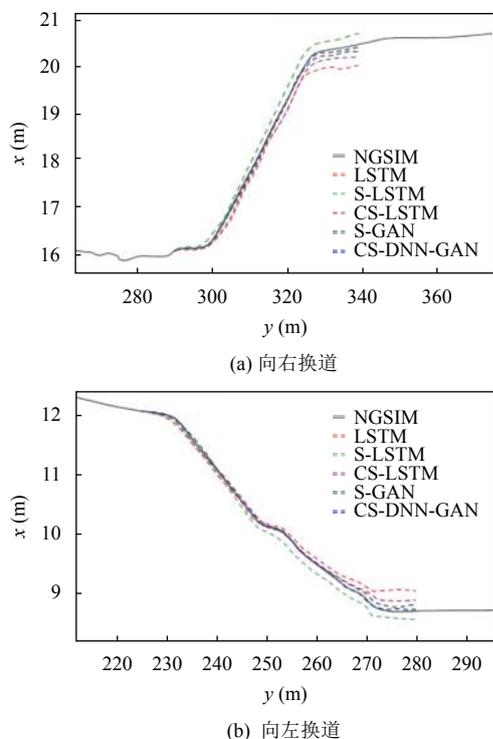


图8 各模型的换道轨迹可视化图

综合以上对比实验, 可以看出 CS-DNN-GAN 模型预测的轨迹最接近真实的车辆轨迹, 该模型的性能要优于同类型的其他网络模型。

6 总结

本文提出了一种融合变道意图识别的 CS-DNN-GAN 车辆轨迹预测模型. 该模型基于 GAN 网络, 并结合 DNN 融入了驾驶意图识别. 经过在公开数据集 NGSIM 上的验证, CS-DNN-GAN 轨迹预测模型表现出了较好的预测效果. 通过与其他轨迹预测模型进行对比, 实验结果显示本文提出的轨迹预测模型的预测准确性更好。

参考文献

- Alahi A, Goel K, Ramanathan V, *et al.* Social LSTM: Human trajectory prediction in crowded spaces. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 961–971. [doi: 10.1109/CVPR.2016.110]
- 郭景华, 何智飞, 罗禹贡, 等. 人机混驾环境下基于深度学

- 习的车辆切入轨迹预测. 汽车工程, 2022, 44(2): 153–160, 214. [doi: 10.19562/j.chinasae.qcgc.2022.02.001]
- 秦胜君, 李婷. 多交互车辆轨迹预测研究. 计算机工程与应用, 2021, 57(11): 232–238. [doi: 10.3778/j.issn.1002-8331.2005-0154]
- Gupta A, Johnson J, Li FF, *et al.* Social GAN: Socially acceptable trajectories with generative adversarial networks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 2255–2264. [doi: 10.1109/CVPR.2018.00240]
- 季学武, 费聪, 何祥坤, 等. 基于 LSTM 网络的驾驶意图识别及车辆轨迹预测. 中国公路学报, 2019, 32(6): 34–42. [doi: 10.19721/j.cnki.1001-7372.2019.06.003]
- 温惠英, 张伟罡, 赵胜. 基于生成对抗网络的车辆换道轨迹预测模型. 华南理工大学学报(自然科学版), 2020, 48(5): 32–40. [doi: 10.12141/j.issn.1000-565X.190182]
- Pan JC, Sun HY, Xu KC, *et al.* Lane-attention: Predicting vehicles' moving trajectories by learning their attention over lanes. Proceedings of the 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems. Las Vegas: IEEE, 2020. 7949–7956. [doi: 10.1109/IROS45743.2020.9341233]
- 刘创, 梁军. 基于注意力机制的车辆运动轨迹预测. 浙江大学学报(工学版), 2020, 54(6): 1156–1163. [doi: 10.3785/j.issn.1008-973X.2020.06.012]
- Lenz D, Diehl F, Le M T, *et al.* Deep neural networks for Markovian interactive scene prediction in highway scenarios. Proceedings of the 2017 IEEE Intelligent Vehicles Symposium. Los Angeles: IEEE, 2017. 685–692.
- Hu YP, Zhan W, Tomizuka M. Probabilistic prediction of vehicle semantic intention and motion. Proceedings of the 2018 IEEE Intelligent Vehicles Symposium. Changshu: IEEE, 2018. 307–313.
- Zhao TY, Xu YF, Monfort M, *et al.* Multi-agent tensor fusion for contextual trajectory prediction. Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 12118–12126.
- Lee N, Choi W, Vernaza P, *et al.* Desire: Distant future prediction in dynamic scenes with interacting agents. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 2156–2174.
- Deo N, Trivedi MM. Convolutional social pooling for vehicle trajectory prediction. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Salt Lake City: IEEE, 2018. 1468–1476. [doi: 10.1109/CVPRW.2018.00196]
- Hochreiter S, Schmidhuber J. Long short-term memory. Neural Computation, 1997, 9(8): 1735–1780. [doi: 10.1162/neco.1997.9.8.1735]

(校对责编: 牛欣悦)