

## 横向动力学模型对 UKF 轨迹预测精度的影响分析

杜力, 赵均, 杨智宇, 谭晓龙, 刘国言

重庆工商大学制造装备机构设计与控制重点实验室, 重庆 400067

**摘要:**目的 针对基于数据驱动的轨迹预测研究鲜有使用车辆动力学模型, 探讨并解决如何通过动力学模型提高轨迹预测精度和动力学模型对轨迹预测精度影响作用不清晰等一系列问题。方法 使用车辆横向动力学模型和二自由度运动学模型搭建车辆复合模型, 实现对 NGSIM 数据集预处理; 得到包含车辆动力学模型信息的数据后, 通过 UKF 模型预测车辆轨迹; 最后根据实验结果分析车辆横向动力学模型参数对 UKF 模型轨迹预测精度的影响。结果 所有时段复合模型均能明显提高精度, 在 0~1 s 与运动学模型结合时,  $\beta$  与  $\theta$  或  $\gamma$  同时使用能提高精度; 在 1~2 s 和 0~2 s 与运动学模型结合时,  $\gamma$  会降低精度,  $\beta$  与  $\theta$  同时使用能提高精度。结论 与纯运动学模型相比, 车辆横向动力学模型相关参数对 UKF 模型不同时段轨迹预测精度影响情况不同, 完整的横向动力学模型与运动学模型结合在各时段均能明显提高轨迹预测精度, 并使精度具备较好的稳定性。

**关键词:** 轨迹预测; 横向动力学; 数据驱动; 无迹卡尔曼滤波

中图分类号: U463.6 文献标识码: A doi: 10.16055/j.issn.1672-058X.2026.0001.018

### Analysis of the Impact of Lateral Dynamics Model on Trajectory Prediction Accuracy of Unscented Kalman Filter

DU Li, ZHAO Jun, YANG Zhiyu, TAN Xiaolong, LIU Guoyan

Key Laboratory of Mechanism Design and Control of Manufacturing Equipment, Chongqing Technology and Business University, Chongqing 400067, China

**Abstract: Objective** Since vehicle dynamics models are seldom employed in data-driven trajectory prediction research, this study investigates and resolves a series of critical issues, including how such models can improve prediction accuracy and clarifying the unclear mechanisms through which dynamics models influence trajectory prediction precision. **Methods** A composite vehicle model was constructed using the vehicle lateral dynamics model and a two-degree-of-freedom kinematic model to preprocess the NGSIM dataset. After obtaining data incorporating vehicle dynamics model information, the unscented Kalman filter (UKF) model was employed to predict vehicle trajectories. Finally, the impact of vehicle lateral dynamics model parameters on the trajectory prediction accuracy of the UKF model was analyzed based on experimental results. **Results** The composite model significantly improved accuracy across all time periods. When combined with the kinematic model during the 0~1 s interval, simultaneously using  $\beta$  and either  $\theta$  or  $\gamma$  increased accuracy. During the 1~2 s and 0~2 s intervals, using  $\gamma$  decreased accuracy, while simultaneously using  $\beta$  and  $\theta$  improved accuracy. **Conclusion** Compared with the pure kinematic model, the relevant parameters of the vehicle lateral dynamics model exhibit different impacts on the trajectory prediction accuracy of the UKF model at different time periods.

收稿日期: 2024-03-14 修回日期: 2024-06-23 文章编号: 1672-058X(2026)01-0147-08

基金项目: 重庆工商大学研究生科研创新项目资助(YJSCXX2023-211-162); 大学生创新创业训练计划项目资助(S202111799022)。

作者简介: 杜力(1971—), 女, 重庆人, 教授, 从事机构学、机械式无级变速器和车辆轨迹预测等研究。

通信作者: 赵均(1997—), 男, 重庆大足人, 硕士研究生, 从事车辆轨迹预测研究。Email: Zhaojun7710@126.com。

引用格式: 杜力, 赵均, 杨智宇, 等. 横向动力学模型对 UKF 模型轨迹预测精度影响分析[J]. 重庆工商大学学报(自然科学版), 2026, 43(1): 147-154.

DU Li, ZHAO Jun, YANG Zhiyu, et al. Analysis of the impact of lateral dynamics model on trajectory prediction accuracy of unscented Kalman filter[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(1): 147-154.

Integrating the complete lateral dynamics model with the kinematic model significantly enhances trajectory prediction accuracy across all time periods and provides better stability in accuracy.

**Keywords:** trajectory prediction; lateral dynamics; data-driven; unscented Kalman filter

随着智能车辆无人驾驶技术的发展,自动驾驶汽车领域出现了越来越多的智能系统<sup>[1]</sup>,这些系统对于实现安全驾驶至关重要,因此系统感知、理解和预测周边车辆行为的能力也变得越来越重要<sup>[2]</sup>。例如准确预测周边车辆轨迹可以减少交通事故<sup>[3-4]</sup>。只有准确感知环境并预测交通参与者的未来移动轨迹,才能使自动驾驶汽车能够进行稳健且安全的策略规划。然而,由于动态交通环境的复杂性、不确定性,现阶段自动驾驶汽车只能有限地观察到周围环境<sup>[5]</sup>,导致自动驾驶汽车不能有效避免与周围车辆发生碰撞<sup>[6]</sup>,因此如何确保自动驾驶汽车的安全问题是头等大事<sup>[7]</sup>。自动驾驶汽车准确预测周边交通参与者特别是其他车辆的未来运动轨迹是有效避免与周围车辆发生碰撞,实现安全驾驶的重要前提。因此如何准确预测周边车辆未来轨迹成为轨迹预测的核心挑战之一。

早期自动驾驶汽车轨迹预测研究主要分为基于模型的轨迹预测和基于数据驱动的轨迹预测<sup>[8]</sup>。在基于模型的轨迹预测中,主要通过车辆物理模型准确描述车辆的运动状态,得到准确的轨迹预测结果<sup>[9]</sup>。然而,该方法受模型复杂程度影响,难以在基于数据驱动的轨迹预测中使用。基于数据驱动的轨迹预测为了提高预测精度,普遍通过增加数据量<sup>[10]</sup>与算力<sup>[11]</sup>等方式。为减少使用车辆模型的复杂度,在轨迹预测研究中仅使用车辆运动学描述车辆运动状态,并认为车辆动力学模型对提高轨迹预测精度作用不明显<sup>[12]</sup>,导致鲜有使用车辆动力学模型及其相关数据。因此,必须探明车辆动力学模型对轨迹预测的影响,从而进一步提高车辆轨迹预测精度。为此,本文提出在无迹卡尔曼滤波轨迹预测模型中结合车辆横向动力学模型预测车辆轨迹,分析横向动力学模型对预测轨迹的影响。结合了车辆横向动力学的模型有效提高了对车辆运动状态的描述准确性,轨迹预测结果明显优于仅使用车辆运动学模型时的结果,提高了轨迹预测精度。

## 1 相关工作

### 1.1 基于物理模型的轨迹预测

基于模型驱动的车辆轨迹预测理论分为 3 种类型,即基于物理的模型、基于意图的模型以及基于交互的模型<sup>[13]</sup>。基于物理模型的方法主要是基于运动学与动力学原理对目标车辆进行建模直接预测轨迹。对于由运动状态带来的不确定性常被假设为正态分布,由此引入“高斯噪声”的概念<sup>[14]</sup>。有关假设不确定性为正态分布应用最成熟的便是卡尔曼滤波<sup>[15]</sup>,其模式大致为在  $t$  时刻通过对外部事物的运动学以及动力学模

型向前迭代,得到  $t+1$  时刻的初步预测状态,而后在  $t+1$  时刻由车辆自带的传感器如 GPS 获取位置等状态信息,两种状态信息进行融合得到最终的预测状态<sup>[16]</sup>。基于蒙特卡洛方法的粒子滤波原理<sup>[17]</sup>与卡尔曼滤波类似。不同的是此方法不仅可以根据  $t$  时刻的状态来预测未来状态,还可以根据  $t$  时刻之前的某一距离或时间内的状态来预测未来。在基于模型的轨迹预测中,当车辆的运动状态可以通过车辆物理模型准确描述时,能够得到准确的轨迹预测结果。

本文利用车辆二自由度运动学模型与车辆横动力学模型搭建车辆复合模型,以更准确地描述车辆运动状态。

### 1.2 基于数据驱动的轨迹预测

在基于数据驱动的轨迹预测研究中,Lefèvre<sup>[18]</sup>和 Lyu 等<sup>[19]</sup>的研究提到可以不使用车辆动力学模型,但文章并没有明确解释不使用车辆动力学模型的原因。Lin 等<sup>[20]</sup>将穿过车道时间定义为在方向盘角度保持不变的情况下,车辆重心越过车道边缘的剩余时间,在计算预测轨迹不确定性时讨论了涉及车辆动力学模型的对比实验,实验结果表明考虑车辆动力学因素对路径预测的结果与其他结果相近,从而得出在预测车辆轨迹时可以不考虑车辆动力学因素的结论。Lin 等原有的以时间为判定指标的方法在现在的车辆轨迹预测研究领域,作为评价指标并不适用。现有基于数据驱动的车辆轨迹预测研究,鲜有使用车辆动力学模型,如何有效使用车辆动力学模型提升轨迹预测精度并不明确。

本文利用搭建的车辆复合模型处理基于数据驱动轨迹预测中的数据集,进一步提取车辆运动特性信息,将处理后的数据与无迹卡尔曼滤波模型相结合,根据实验结果分析横向动力学模型对预测轨迹精度的影响。

## 2 数据处理

本节描述了使用车辆二自由度运动学模型与横动力学模型相结合,通过运动学模型和动力学模型构成的复合模型对 NGSIM (Next Generation Simulation) 数据集中原有的轿车类数据进行数据处理,提取出后续研究所需的车辆运动特性数据。

### 2.1 车辆二自由度运动学模型

对于车辆运动学模型,选择今天仍然广泛使用的自行车模型,因为其计算复杂度低且简单,运动学自行车模型如图 1 所示<sup>[21-22]</sup>。车辆前轮的转向角用  $\delta$  表示, $\delta$  描述了车辆纵轴和前轮之间的差异。设车辆的重心为  $G$ ,  $a$  和  $b$  分别表示  $G$  到前轮和后轮的距离。在数据处理过程中,本文仅筛选出 NGSIM 数据集中轿车相关

数据。数据集中  $(X, Y)$  表示  $G$  在全局坐标系中的位置,  $v_G$  表示  $G$  的速度,  $\theta$  表示横摆角,  $\beta$  表示车辆侧滑角, 线段  $r_G$  是车辆运动路径的半径,  $\beta + \theta$  是车辆航向角。

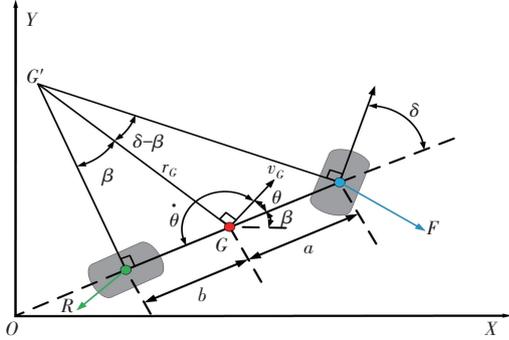


图 1 自行车模型图

Fig. 1 Diagram of the bicycle model

对于运动学建模, 车辆的全局运动定义如下:

$$\dot{X} = v_G \cos(\theta + \beta), \dot{Y} = v_G \sin(\theta + \beta) \quad (1)$$

通过对三角形  $OGF$  和  $OGR$  使用“正弦规则”, 可以容易地获得以下方程:

$$\frac{\sin(\delta - \beta)}{a} = \frac{\sin\left(\frac{\pi}{2} - \delta\right)}{r_G} \quad (2)$$

$$\frac{\sin \beta}{b} = \frac{\sin\left(\frac{\pi}{2}\right)}{r_G}$$

整理式(2)可得:

$$\tan \delta \cos \beta = \frac{(a+b)}{r_G} \quad (3)$$

使用式(2)和式(3), 车辆侧滑角  $\beta$  可计算为

$$\beta = \tan^{-1}\left(\frac{b \tan \delta}{a+b}\right) \quad (4)$$

$v_R$  应等于车辆纵轴上  $v_G$  的分量(即  $v_x$ ), 因此, 式(5)成立:

$$\begin{aligned} v_R &= \dot{X}_R \cos \theta + \dot{Y}_R \sin \theta \\ v_x &= v_G \cos \beta \end{aligned} \quad (5)$$

由于运动速度较低, 车轮仅在切线方向滚动而不滑动, 如式(6)所示:

$$\begin{aligned} \dot{X}_F \sin(\theta + \delta) &= \dot{Y}_F \sin(\theta + \delta) \\ \dot{X}_R \sin \theta &= \dot{Y}_R \sin \theta \end{aligned} \quad (6)$$

式(6)中,  $(X_F, Y_F)$  和  $(X_R, Y_R)$  分别是点  $F$  和  $R$  处的坐标。基于前轮和后轮之间的几何关系, 式(7)成立:

$$\begin{aligned} X_F &= X_R + (a+b) \cos \theta \\ Y_F &= Y_R + (a+b) \sin \theta \end{aligned} \quad (7)$$

随后,  $\gamma$  中定义的偏航角变化率可推导出:

$$\gamma = \dot{\theta} = \frac{v_G}{a+b} \cos \beta \tan \delta \quad (8)$$

## 2.2 车辆横向动力学模型

为了更好地适应实际情况, 在现有自行车模型的基础

上, 进一步考虑动力学车辆模型。轮胎是负责将驱动力传递到地面并向车辆提供不可或缺的侧向力的关键部件, 如图 2 所示<sup>[23-25]</sup>。本文使用横向动力学车辆模型, 其中变量  $\theta$  表示路径角, 即车身与  $X$  轴之间的角度。

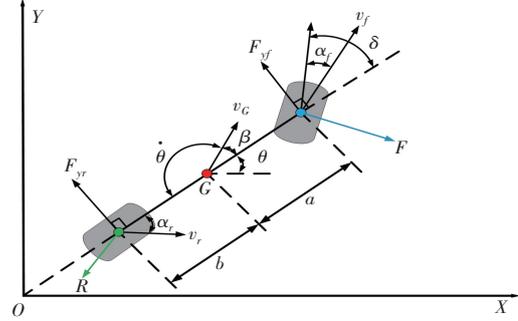


图 2 横向车辆动力学模型图

Fig. 2 Diagram of the lateral vehicle dynamics model

基于牛顿定律, 基本方程表示自行车横向动力学, 并通过对横向力和横摆力矩和表示如下:

$$\begin{cases} \sum F_y = 2F_{yf} + 2F_{yr} = m(v_x \gamma + \dot{v}_y) \\ \sum M_z = 2aF_{yf} - 2bF_{yr} = I_z \dot{\gamma} \end{cases} \quad (9)$$

式(9)中,  $F_{yf}$  和  $F_{yr}$  分别表示前、后轮胎在  $y$  轴方向上的力,  $I_z$ 、 $v_x$  和  $v_y$  分别表示绕车身重心方向的偏航惯量, 以及  $v_G$  在横向轴和纵向轴上的分量,  $\gamma$  为角速度, 即  $\theta$  的导数。

本文基于一个简单的线性轮胎模型, 作用在轮胎上的横向力与轮胎滑移角成正比:

$$F_{yf} = -C_{af} \alpha_f, F_{yr} = -C_{ar} \alpha_r \quad (10)$$

式(10)中,  $C_{af}$  和  $C_{ar}$  分别表示前后轮的过弯刚度系数,  $\alpha_f$  和  $\alpha_r$  分别表示前后轮的滑移角。另外, 滑移角<sup>[26]</sup>可表示为

$$\alpha_f = \beta + \frac{a\gamma}{v_x} - \delta, \alpha_r = \beta - \frac{b\gamma}{v_x} \quad (11)$$

综上所述, 整车模型的表达式为

$$\begin{cases} \dot{X} = v_G \cos(\theta + \beta) \\ \dot{Y} = v_G \sin(\theta + \beta) \\ \dot{\theta} = \gamma \\ \dot{\gamma} = -\frac{2aC_{af}}{I_z} \left( \beta + \frac{a\gamma}{v_x} - \delta \right) + \frac{2bC_{ar}}{I_z} \left( \beta - \frac{b\gamma}{v_x} \right) \\ \dot{\beta} = -\gamma - \frac{2aC_{af}}{mv_x} \left( \beta + \frac{a\gamma}{v_x} - \delta \right) + \frac{2bC_{ar}}{mv_x} \left( \beta - \frac{b\gamma}{v_x} \right) \end{cases} \quad (12)$$

式(12)中,  $\dot{X}$  表示车辆  $X$  方向的速度,  $\dot{Y}$  表示车辆  $Y$  方向的速度,  $\dot{\theta}$  表示车辆的偏航角速度,  $\dot{\gamma}$  表示车辆的路径角加速度,  $\dot{\beta}$  表示车辆的横摆角速度。

## 2.3 基于车辆物理模型的非结构场景数据处理

数据集采用的是名为 NGSIM 的非结构场景数据集, 该数据集采集于加州 US 101 号公路、洛杉矶 Lankershim Boulevard、埃默里维尔 I-80 号公路和佐治亚州 Peachtree

Street。数据集中包含车辆 ID、时间、速度、坐标、车道等信息。由于原始数据集中所含车辆运动特性数据不足以支撑后续研究,因此为获得后续研究所需包含车辆运动特性数据的数据集,利用搭建的车辆复合模型对 NGSIM 数据集进行进一步处理。处理后得到的数据集与原始数据集相比,变化如表 1、图 3 和图 4 所示。

表 1 NGSIM 数据集处理前后比较

Table 1 Comparison of NGSIM dataset before and after processing

场 景	处理状态	车辆数	数据量	每辆车包含数据量
I-80	处理前	1 723	18 874 368	10 954
	处理后	1 723	41 835 480	24 281
	变化率	—	121. 65%	121. 65%
Lankershim	处理前	1 437	27 262 975	18 972
	处理后	1 437	58 717 627	40 861
	变化率	—	115. 37%	115. 37%
Peachtree	处理前	1 809	21 339 750	11 796
	处理后	1 809	47 797 979	26 422
	变化率	—	123. 99%	123. 99%
US-101	处理前	2 782	18 186 102	6 537
	处理后	2 782	55 564 775	19 973
	变化率	—	205. 53%	205. 53%

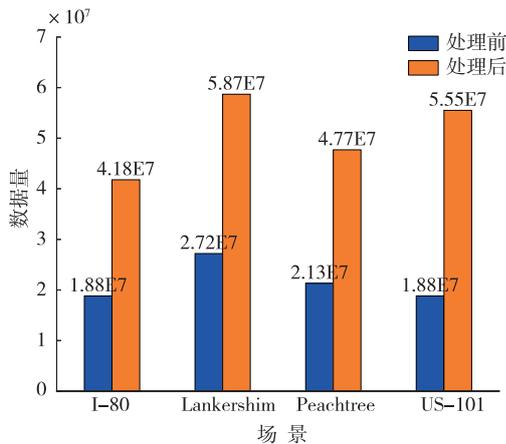


图 3 数据集处理前后数据量对比

Fig. 3 Comparison of the amount of data before and after processing of the dataset

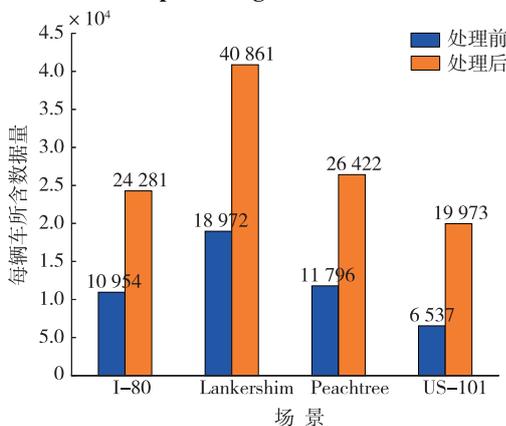


图 4 数据集处理前后每辆车包含数据量对比

Fig. 4 Comparison of the amount of data contained in each vehicle before and after dataset processing

NGSIM 数据集中 4 个场景包含的 7 751 辆轿车的 数据总量由 85 663 195 增加到 203 915 861,每辆车包含数据总量由 48 259 增加到 11 537,整个数据集数据量增加了 131. 12%。新增加的数据中包含大量车辆复合模型中涉及的中间车辆物理数据,例如车辆所受横向力、横向加速度和转动惯量等。

### 3 本文方法的提出

本节描述了基于数据驱动的 UKF 轨迹预测模型和模型轨迹预测精度的评价指标。

#### 3.1 UKF 轨迹预测模型

无迹卡尔曼滤波通过去除点来逼近非线性模型,因为没有使用雅可比和偏导数,这使得计算更容易,并且没有忽略高阶导数。基于 Marina 等<sup>[24]</sup>在车辆超级电容器能量状态和健康状态测定研究和 Chen 等<sup>[25]</sup>使用无迹卡尔曼滤波估计共模噪声寄生电容研究的实验结果,可以明显看出无迹卡尔曼滤波是一种高效的方法,并且优于传统卡尔曼滤波算法和扩展卡尔曼滤波算法。

在本节基于数据驱动的 UKF 轨迹预测模型中,假设在数据集 NGSIM 中获得了周边车辆在  $T$  时间步中的历史轨迹,将相应的坐标作为标准坐标系。首先对每辆车所在场景进行预处理,得到每辆车在不同时间的坐标, $i \in \{1, 2, \dots, N\}$  表示车辆编号。定义第  $i$  个观察到的车辆位置坐标为  $C_i^t = (x_i^t, y_i^t)$ ,在时间步长  $t$  中观测到车辆  $i$  的历史轨迹  $C_{si}^t = (C_{si}^{t-T+1}, C_{si}^{t-T+2}, \dots, C_{si}^t)$ 。通过前文搭建的车辆复合模型定义车辆状态向量如下所示:

$$\boldsymbol{\chi} = [X(t), Y(t), \theta(t), \gamma(t), \beta(t)]^T = \int_t^{t+T} [\dot{X}(t), \dot{Y}(t), \dot{\theta}(t), \dot{\gamma}(t), \dot{\beta}(t)]^T dt \quad (13)$$

式(13)中, $X$  表示车辆的  $X$  坐标, $Y$  表示车辆的  $Y$  坐标, $\theta$  表示车辆的偏航角, $\gamma$  表示车辆的路径角速度, $\beta$  表示车辆的横摆角, $t$  表示时间指数。

将车辆状态转移函数,即车辆模型定义为  $f(\boldsymbol{\chi}(t), T)$ ,如式(14)所示:

$$\boldsymbol{\chi}(t+T) = \boldsymbol{\chi}(t) + f(\boldsymbol{\chi}(t), T) \quad (14)$$

在计算过程中,车辆初始状态量可由处理后的非机构场景 NGSIM 数据集中的数据获得。输出车辆  $i$  未来  $n$  个时间步长的轨迹  $C_p^t = (C_i^{t+1}, C_i^{t+2}, \dots, C_i^{t+n})$ ,无迹卡尔曼滤波通过 4 个部分实现车辆轨迹预测,如算法 1 所述<sup>[22]</sup>。

---

算法 1:UKF 轨迹预测算法

---

初始化:

- (1) 预测平均值  $\hat{x}_0$ ;
- (2) 预测协方差  $P_0$ 。

从  $episode = 1, \dots, N$  进行预测:

- (1) 预测状态向量  $\boldsymbol{\chi}_i(t|t-T)$ ;
- (2) 预测协方差矩阵  $\boldsymbol{P}_{xx}(t|t-T)$ 。

---

算法 1:UKF 轨迹预测算法

确认:

- (1) 计算观测向量  $\hat{z}(t|t-T)$ ;
- (2) 计算验证区域值  $\Phi_i(t, \varepsilon^2)$ 。

更新:

- (1) 计算无迹卡尔曼滤波器增益  $K(t|t-T)$ ;
- (2) 使用位置信息更新估计值  $\hat{x}(t+T|t)$ ;
- (3) 更新协方差矩阵  $P_{xx}(t+T|t)$ 。

结束

3.2 实验实施细则

通过将不同数量的横向动力学模型因素与运动学模型结合形成 9 个 UKF 轨迹预测模型,根据 9 个模型轨迹预测结果分析横向动力学模型对预测轨迹精度的影响,9 个模型具体信息如表 2 所示。实验环境为 Ubuntu18.04 操作系统,UKF 模型在 Nvidia GTX2070Ti GPU 上训练,数据集采用结合车辆物理模型处理后的 NGSIM 数据集,并按照 7:2:1 的比例划分为训练集、验证集和测试集。每个模型进行 10 次以上的训练进行消融实验,保证模型预测结果的有效性。利用每个模型通过测试集前 3 s 的历史数据预测目标车辆未来 2 s 的车辆轨迹。

表 2 UKF 轨迹预测子模型详情

Table 2 Details of the UKF trajectory prediction submodel

模 型	所含运动学因素	所含动力学因素
复合模型	横向速度,纵向速度	侧滑角 $\theta$ , 路径角速度 $\gamma$ , 横摆角 $\beta$
纯运动学模型	横向速度,纵向速度	—
纯动力学模型	—	侧滑角 $\theta$ , 路径角速度 $\gamma$ , 横摆角 $\beta$
运动学模型 & $\theta$	横向速度,纵向速度	侧滑角 $\theta$
运动学模型 & $\gamma$	横向速度,纵向速度	路径角速度 $\gamma$
运动学模型 & $\beta$	横向速度,纵向速度	横摆角 $\beta$
运动学模型 & $\theta$ & $\gamma$	横向速度,纵向速度	侧滑角 $\theta$ , 路径角速度 $\gamma$
运动学模型 & $\theta$ & $\beta$	横向速度,纵向速度	侧滑角 $\theta$ , 横摆角 $\beta$
运动学模型 & $\gamma$ & $\beta$	横向速度,纵向速度	路径角速度 $\gamma$ , 横摆角 $\beta$

3.3 评价指标

为了整体分析车辆横向动力学模型轨迹预测的影响,本研究选取在轨迹预测中常用的平均位移误差指标 ADE(Average Displacement Error)评估上述模型对于轨迹预测的准确性。平均位移误差(ADE)计算公式如下:

$$F_{ADE}(\hat{Y}, Y) = \frac{\sum_{i=1}^N \sum_{t=i+1}^{i+T} \|C_p^t - C_o^t\|_2}{N * T} \quad (16)$$

式(16)中, $\hat{Y}, Y$  分别表示预测轨迹和真实轨迹,  $C_o^t, C_p^t$  分别表示所有预测时间步长的实际轨迹坐标和预测轨迹坐标,  $T$  表示时间步长,  $N$  表示轨迹数量。

4 仿真实验与结果分析

将提出的基于数据驱动与车辆物理模型的 UKF 轨迹预测模型与使用不同数量的车辆动力学参数得到的 ADE 指标进行对比。实验结果分为 0~1 s 的短期轨迹预测结果、1~2 s 的中长期轨迹预测结果和 0~2 s 长短期整体轨迹预测结果。

4.1 0~1 s 实验结果

UKF 轨迹预测模型 0~1 s 短期轨迹预测 ADE 指标结果见表 3。

表 3 UKF 轨迹预测模型 0~1 s ADE 结果

Table 3 ADE results of the UKF trajectory prediction model from 0 s to 1 s

模 型	ADE/m	性能变化/%
复合模型	0.214 7	8.37
纯运动学模型	0.234 3	—
纯动力学模型	0.324 1	-38.33
运动学模型 & $\theta$	0.246 9	-5.38
运动学模型 & $\gamma$	0.253 0	-7.98
运动学模型 & $\beta$	0.242 0	-3.29
运动学模型 & $\theta$ & $\gamma$	0.251 1	-7.17
运动学模型 & $\theta$ & $\beta$	0.218 8	6.62
运动学模型 & $\gamma$ & $\beta$	0.198 1	15.45

表 3 结果表明:在 UKF 轨迹预测模型的短期轨迹预测中,使用车辆复合模型、纯运动学模型和纯动力学模型时,精度分别为 0.214 7 m、0.234 3 m 和 0.324 1 m,使用复合模型提高 8.37%,使用纯动力学模型下降 38.33%;使用运动学模型 & $\theta$ 、& $\gamma$  和 & $\beta$  时,精度分别为 0.246 9 m、0.253 0 m 和 0.242 0 m,分别下降 5.38%、7.98% 和 3.29%;使用运动学模型 & $\theta$ & $\gamma$ 、& $\theta$ & $\beta$  和 & $\gamma$ & $\beta$  时,精度分别为 0.251 1 m、0.218 8 m 和 0.198 1 m,分别下降 7.17%,提高 6.62% 和 15.45%。

4.2 1~2 s 实验结果

UKF 轨迹预测模型 1~2 s 长期轨迹预测 ADE 指标结果见表 4。

表 4 UKF 轨迹预测模型 1~2 s ADE 结果

Table 4 ADE results of the UKF trajectory prediction model from 1 s to 2 s

模 型	ADE/m	性能变化/%
复合模型	0.230 9	32.74
纯运动学模型	0.343 3	—
纯动力学模型	0.376 7	-9.73
运动学模型 & $\theta$	0.327 7	4.54
运动学模型 & $\gamma$	0.346 4	-0.90
运动学模型 & $\beta$	0.259 8	24.32
运动学模型 & $\theta$ & $\gamma$	0.348 9	-1.63
运动学模型 & $\theta$ & $\beta$	0.281 6	17.97
运动学模型 & $\gamma$ & $\beta$	0.308 9	10.02

表 4 结果表明:在 UKF 轨迹预测模型的长期轨迹预测中,使用车辆复合模型、纯运动学模型和纯动力学模型精度分别为 0.230 9 m、0.343 3 m 和 0.376 7 m,使用复合模型提高 32.74%,使用纯动力学模型下降 9.73%;使用运动学模型  $\theta$ 、 $\gamma$  和  $\beta$  时,精度分别为 0.327 7 m、0.346 4 m 和 0.259 8 m,分别提高 4.54% 和 24.32%,下降 0.90%;使用运动学模型  $\theta$ 、 $\gamma$  和  $\beta$  时,精度分别为 0.348 9 m、0.281 6 m 和 0.308 9 m,分别下降 1.63%,提高 17.97% 和 10.02%。

4.3 0~2 s 实验结果

UKF 轨迹预测模型 0~2 s 长短期轨迹预测 ADE 指标结果见表 5,UKF 轨迹预测模型 0~1 s 和 1~2 s 预测轨迹 ADE 指标比较结果见表 6。

表 5 UKF 轨迹预测模型 0~2 s ADE 结果  
Table 5 ADE results of the UKF trajectory prediction model from 0 s to 2 s

模型	ADE/m	性能变化/%
复合模型	0.222 8	22.85
纯运动学模型	0.288 8	—
纯动力学模型	0.350 4	-21.33
运动学模型 $\theta$	0.287 3	0.52
运动学模型 $\gamma$	0.299 7	-3.77
运动学模型 $\beta$	0.250 9	13.12
运动学模型 $\theta$ & $\gamma$	0.300 0	-3.88
运动学模型 $\theta$ & $\beta$	0.250 2	13.37
运动学模型 $\gamma$ & $\beta$	0.253 5	12.22

表 6 UKF 轨迹预测模型 0~1 s 和 1~2 s 的结果比较  
Table 6 Comparison results of the UKF trajectory prediction model from 0 s to 1 s and from 1 s to 2 s

模型	ADE/m		变化幅度
	0~1 s	1~2 s	
复合模型	0.214 7	0.230 9	-0.016 2
纯运动学模型	0.234 3	0.343 3	-0.109 0
纯动力学模型	0.324 1	0.376 7	-0.052 6
运动学模型 $\theta$	0.246 9	0.327 7	-0.080 8
运动学模型 $\gamma$	0.253 0	0.346 4	-0.093 4
运动学模型 $\beta$	0.242 0	0.259 8	-0.017 8
运动学模型 $\theta$ & $\gamma$	0.251 1	0.348 9	-0.097 8
运动学模型 $\theta$ & $\beta$	0.218 8	0.281 6	-0.062 8
运动学模型 $\gamma$ & $\beta$	0.198 1	0.308 9	-0.110 8

表 5 表明:在 UKF 轨迹预测模型的长短期整体轨迹预测中,使用车辆复合模型、纯运动学模型和纯动力学模型精度分别为 0.222 8 m、0.288 8 m 和 0.350 4 m,使用复合模型提高 22.85%,使用纯动力学模型下降 21.33%;使用运动学模型  $\theta$ 、 $\gamma$  和  $\beta$  时,精度分别为 0.287 3 m、0.299 7 m 和 0.250 9 m,分别提高 0.52% 和 13.12%,下降 3.77%;使用运动学模型  $\theta$ 、 $\gamma$  和  $\beta$  时,精度分别为 0.300 0 m、0.250 2 m 和 0.253 5 m,分别下降 3.88%,提高 13.37% 和 12.22%。

根据表 6 表明:在 UKF 轨迹预测模型的长短期整体轨迹预测中,使用复合模型、运动学模型和动力学模型时

0~1 s 到 1~2 s 精度下降幅度分别为 0.016 2 m、0.109 0 m 和 0.052 6 m;使用运动学模型  $\theta$ 、 $\gamma$  和  $\beta$  时,0~1 s 到 1~2 s 精度下降幅度分别为 0.080 8 m、0.093 4 m 和 0.017 8 m;使用运动学模型  $\theta$  &  $\gamma$ 、 $\theta$  &  $\beta$  和  $\gamma$  &  $\beta$  时,0~1 s 到 1~2 s 精度下降幅度分别为 0.097 8 m、0.062 8 m 和 0.110 8 m。

4.4 0~1 s 结果分析

根据实验结果绘制 UKF 模型 0~1 s 轨迹预测 ADE 结果分析图,如图 5 所示。

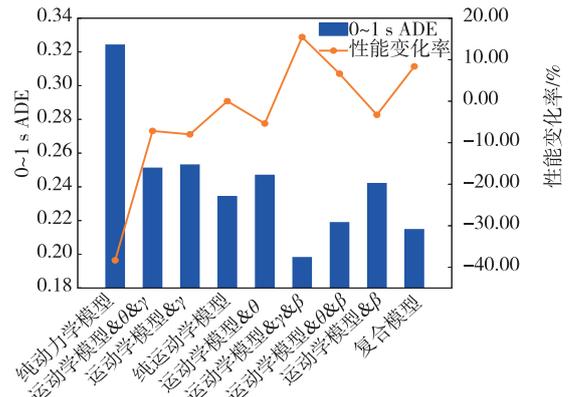


图 5 UKF 模型 0~1 s 轨迹预测 ADE 结果分析

Fig. 5 Analysis of ADE results for UKF model trajectory prediction from 0 s to 1 s

图 5 表明:复合模型精度明显优于纯运动学模型,纯动力学模型精度最低;运动学模型  $\theta$ 、 $\gamma$  和  $\beta$  都比纯运动学模型精度低;运动学模型  $\theta$  &  $\gamma$  比纯运动学模型精度低, $\theta$  &  $\beta$  和  $\gamma$  &  $\beta$  精度明显优于纯运动学模型。因此在短期轨迹预测中,横向动力学模型中的  $\beta$  参数与  $\theta$  或  $\gamma$  参数共同与车辆运动学模型结合使用能获得比纯运动学模型更好的预测结果。

4.5 1~2 s 结果分析

根据实验结果绘制 UKF 模型 1~2 s 轨迹预测 ADE 结果分析图,如图 6 所示。

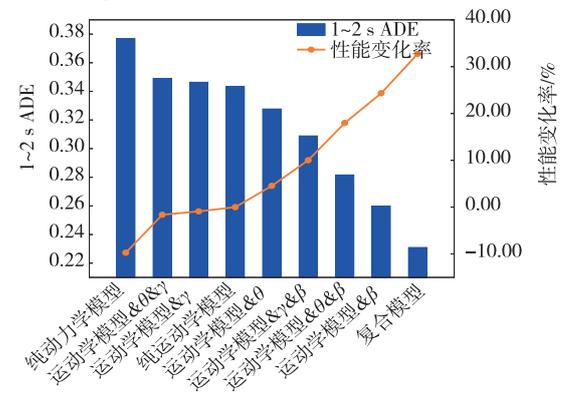


图 6 UKF 模型 1~2 s 轨迹预测 ADE 结果分析

Fig. 6 Analysis of ADE results for UKF model trajectory prediction from 1 s to 2 s

图 6 表明:复合模型精度最高,纯动力学模型精度最低;运动学模型  $\theta$  和  $\beta$  比纯运动学模型精度高,运动学模型  $\gamma$  比纯运动学模型精度低;运动学模型  $\theta$  &  $\gamma$  比纯运动学模型精度低,但运动学模型  $\theta$  &  $\beta$  和

$\gamma$ 与 $\beta$ 精度明显优于纯运动学模型。因此在长期轨迹预测中,横向动力学模型中的  $\gamma$  参数与车辆运动学模型结合使用会导致预测精度降低;横向动力学模型中的  $\beta$  与  $\theta$  参数与车辆运动学模型结合使用能提高精度,但  $\theta$  参数对预测精度提升的程度没有  $\beta$  参数明显。

#### 4.6 0~2 s 结果分析

根据实验结果绘制 UKF 模型 1~2 s 轨迹预测 ADE 结果分析图,如图 7 所示。

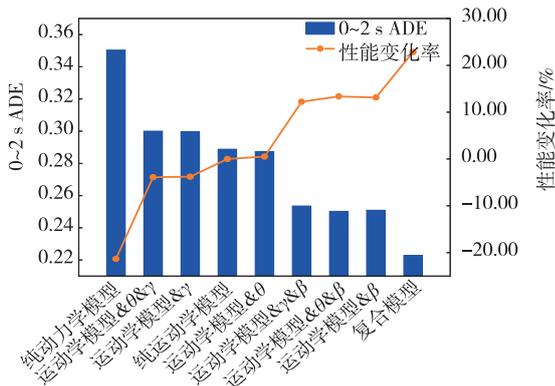


图 7 UKF 模型 0~2 s 轨迹预测 ADE 结果分析

Fig. 7 Analysis of ADE results for UKF model trajectory prediction from 0 s to 2 s

图 7 表明:复合模型精度最高,纯动力学模型精度最低;运动学模型  $\theta$  和纯运动学模型精度接近,运动学模型  $\beta$  比纯运动学模型精度高,但运动学模型  $\gamma$  比纯运动学模型精度低;运动学模型  $\theta$  与  $\gamma$  比纯运动学模型精度低,但  $\theta$  与  $\beta$  和  $\gamma$  与  $\beta$  精度明显优于纯运动学模型。因此在 0~2 s 整体轨迹预测中,横向动力学模型中的  $\gamma$  参数与车辆运动学模型结合使用会导致预测精度下降;横向动力学模型中的  $\beta$  与  $\theta$  参数与车辆运动学模型结合使用能提高精度,但  $\theta$  参数对预测精度提升的程度没有  $\beta$  参数明显。

进一步分析车辆横向动力学模型对 UKF 轨迹预测模型在 0~2 s 内的影响。UKF 轨迹预测模型 0~1 s 和 1~2 s 内的 ADE 指标变化趋势,0~2 s 内的 ADE 指标变化趋势分别如图 8 所示和图 9 所示。

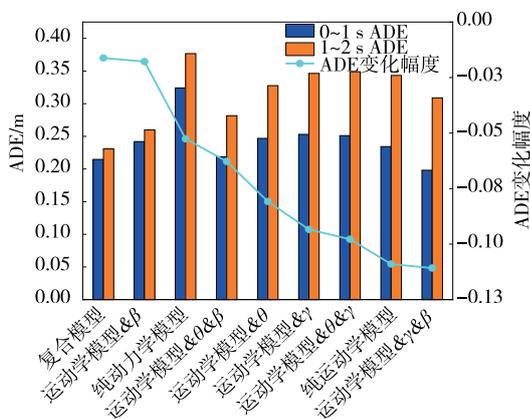


图 8 UKF 模型 0~1 s 和 1~2 s 轨迹预测 ADE 变化分析

Fig. 8 Analysis of ADE variation in trajectory prediction for UKF model from 0 s to 1 s and 1 s to 2 s

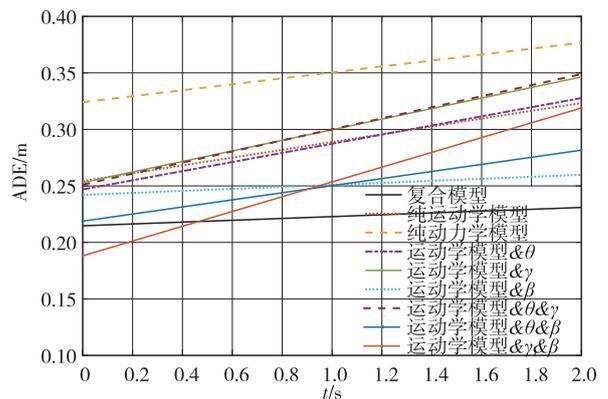


图 9 UKF 模型 0~2 s 轨迹预测 ADE 变化趋势

Fig. 9 Trend of ADE variation in trajectory prediction for UKF model from 0 s to 2 s

图 8 和图 9 表明:使用复合模型进行轨迹预测时, ADE 指标下降幅度最小,使用运动学模型  $\beta$  进行轨迹预测时, ADE 指标下降幅度与使用复合模型时接近。因此,在 UKF 轨迹预测模型中,复合模型和运动学模型  $\beta$  能使轨迹预测精度有较好的稳定性。

## 5 结论与展望

为分析横向动力学模型对车辆轨迹预测的影响,通过车辆二自由度运动学模型与横向动力学模型构建的复合模型对 NGSIM 数据集进行进一步处理。UKF 轨迹预测模型使用处理后的数据集进行轨迹预测,分别分析横向动力学模型对 UKF 轨迹预测模型 0~1 s、1~2 s 和 0~2 s 时段车辆轨迹预测的影响。实验结果表明:在短期轨迹预测中,横向动力学模型中的  $\beta$  参数与  $\theta$  或  $\gamma$  参数共同与车辆运动学模型结合使用,能获得比使用纯运动学模型更好的预测结果;在长期轨迹预测中,横向动力学模型中的  $\gamma$  参数与车辆运动学模型结合使用会导致预测精度降低,横向动力学模型中的  $\beta$  与  $\theta$  参数与车辆运动学模型结合使用能提高精度;在整体轨迹预测中,横向动力学模型中的  $\gamma$  参数与车辆运动学模型结合使用会导致预测精度下降,横向动力学模型中的  $\beta$  与  $\theta$  参数与车辆运动学模型结合使用能提高精度,复合模型和横向动力学模型中的  $\beta$  参数能使轨迹预测精度有较好的稳定性。

综上所述,车辆横向动力学模型相关参数与车辆运动学模型结合对 UKF 轨迹预测模型不同时段的轨迹预测精度影响程度不同,但完整的车辆横向动力学模型与车辆运动学模型结合在 UKF 轨迹预测模型各时段均能明显提高预测精度,并使其具备较好的稳定性。

本文选用的动力学模型为简单的二自由度横向动力学模型,一定程度上忽略了高自由度动力学模型的全面性。如何进一步分析更多动力学参数对轨迹预测精度的影响,将是未来的工作方向。

## 参考文献(References):

- [1] RAJU V M, GUPTA V, LOMATE S. Performance of open autonomous vehicle platforms: autoware and Apollo [C]// Proceedings of the IEEE 5th International Conference for Convergence in Technology (I2CT). Piscataway: IEEE Press, 2020: 1–5.
- [2] SADAT A, CASAS S, REN M, et al. Perceive, predict, and plan: Safe motion planning through interpretable semantic representations[C]//Proceedings of the Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 414–430.
- [3] ZHANG T, ZHAN J, SHI J, et al. Human-like decision-making of autonomous vehicles in dynamic traffic scenarios [J]. CAA Journal of Automatica Sinica, 2023, 10(10): 1905–1917.
- [4] ZHANG Y, HAO R, ZHANG T, et al. A trajectory optimization-based intersection coordination framework for cooperative autonomous vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 14674–14688.
- [5] HELBIG M, HOEDT J, KONIGORSKI U. Model learning and tactical maneuver planning for automatic driving[J]. 2023, 488: 703–718.
- [6] SONG Z, DING H. Modeling car-following behavior in heterogeneous traffic mixing human-driven, automated and connected vehicles: Considering multitype vehicle interactions[J]. Nonlinear Dynamics, 2023, 111(12): 11115–11134.
- [7] ZHENG Y, HAN L, YU J, et al. Driving risk assessment under the connected vehicle environment: A CNN-LSTM modeling approach[J]. Digital Transportation and Safety, 2023, 2(3): 211–219.
- [8] ZHAO S, LI M, HUANG T, et al. Trajectory prediction for heterogeneous road-agents using dual attention model[J]. Measurement, 2023, 212(1): 1–10.
- [9] LEE C, HAN D S. Sequential rasterized image-based trajectory prediction deep-learning model[C]//Proceedings of the International Conference on Artificial Intelligence in Information and Communication. Piscataway: IEEE Press, 2023.
- [10] HOU L, LI S E, YANG B, et al. Integrated graphical representation of highway scenarios to improve trajectory prediction of surrounding vehicles[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(2): 1638–1651.
- [11] XU D, SHANG X, LIU Y, et al. Group vehicle trajectory prediction with global spatio-temporal graph[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(2): 1219–1229.
- [12] ZHOU D, MA Z, ZHANG X, et al. Autonomous vehicles' intended cooperative motion planning for unprotected turning at intersections[J]. IET Intelligent Transport Systems, 2022, 16(8): 1058–1073.
- [13] 邱润, 黎敬涛, 李孝疆, 等. 基于卡尔曼滤波算法的轨迹预测[J]. 电视技术, 2022, 46(6): 24–28.  
QIU Run, LI Jing-tao, LI Xiao-jiang, et al. Trajectory prediction based on Kalman filtering algorithm [J]. Video Engineering, 2022, 46(6): 24–28.
- [14] 赵高士, 陈龙, 蔡英凤, 等. 融合复杂网络和记忆增强网络的轨迹预测技术 [J]. 汽车工程, 2023, 45(9): 1608–1616, 1636.  
ZHAO Gao-shi, CHEN Long, CAI Ying-feng, et al. Trajectory prediction technology integrating complex network and memory-augmented network[J]. Automotive Engineering, 2023, 45(9): 1608–1616, 1636.
- [15] BARRIOS C, MOTAI Y. Improving estimation of vehicle's trajectory using the latest global positioning system with Kalman filtering [J]. IEEE Transactions on Instrumentation and Measurement, 2011, 60(12): 3747–3755.
- [16] SINGH A K. Major development under Gaussian filtering since unscented Kalman filter[J]. CAA Journal of Automatica Sinica, 2020, 7(5): 1308–1325.
- [17] LI J, ZHAN W, HU Y, et al. Generic tracking and probabilistic prediction framework and its application in autonomous driving[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3634–3649.
- [18] LEFÈVRE S, VASQUEZ D, LAUGIER C. A survey on motion prediction and risk assessment for intelligent vehicles[J]. ROBOMECH Journal, 2014, 1(1): 1–12.
- [19] LYU Q F, ZHU W Q, DENG M L. Response of quasi-integrable and resonant Hamiltonian systems to fractional Gaussian noise[J]. Journal of Vibration and Acoustics, 2022, 144(1): 10–19.
- [20] LIN C F, ULISOY A G, LEBLANC D J. Vehicle dynamics and external disturbance estimation for vehicle path prediction [J]. IEEE Transactions on Control Systems Technology, 2000, 8(3): 508–518.
- [21] GAO H, ZHU J, ZHANG T, et al. Situational assessment for intelligent vehicles based on stochastic model and Gaussian distributions in typical traffic scenarios[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2022, 52(3): 1426–1436.
- [22] GAO H, QIN Y, HU C, et al. An interacting multiple model for trajectory prediction of intelligent vehicles in typical road traffic scenario [J]. IEEE Trans Neural Netw Learn Syst, 2023, 34(9): 6468–6479.
- [23] VELUCHAMY S, MAHESH K M, A P B, et al. Deep Drive: A braking decision making approach using optimized GAN and Deep CNN for advanced driver assistance systems[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106111.
- [24] MARINA M C, HEUCKE M, WANG F Y, et al. Driving style recognition for intelligent vehicle control and advanced driver assistance: A survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(3): 666–676.
- [25] CHEN Y, SONG Y, SHI L, et al. Stochastic model predictive control for driver assistance control of intelligent vehicles considering uncertain driving environment[J]. Journal of Vibration and Control, 2023, 29(3–4): 758–771.
- [26] KARIMI S, FARJAH E, GHANBARI T, et al. Estimation of parasitic capacitance of common mode noise in vehicular applications: An unscented Kalman filter-based approach[J]. IEEE Transactions on Industrial Electronics, 2021, 68(8): 7526–7534.

责任编辑:李翠薇