

# 交叉口车辆行为感知在线半监督混合方法\*

张海伦, 王广玮, 孟庆文, 许庆, 王建强, 李克强

(清华大学车辆与运载学院, 智能绿色车辆与交通全国重点实验室, 北京 100084)

**[摘要]** 自动驾驶感知系统须对目标车辆运动进行感知, 以制定合理交互决策。针对行为感知在时间上的滞后性和数据中可能存在的波动和异常值导致感知准确率差的问题, 本文提出一种在线半监督混合方法。首先, 采用自回归积分移动平均和在线梯度下降优化器设计基于数据驱动的车辆运动状态在线预测算法。然后, 构建基于微簇的初始模型, 并以K近邻为基分类器建立集成学习策略, 设计错误驱动代表性学习和指数衰减策略实现对初始模型的迭代更新。最后, 基于驾驶模拟平台采集了验证所提算法有效性的实验数据。结果表明, 所提出的方法对于车辆行为波动具有快速适应性, 在线预测算法可准确预测车辆运动趋势, 行为感知算法对于不同预测时间下的车辆行为均有较强适应能力。

**关键词:** 自动驾驶; 行为预测; 自回归积分移动平均; 集成学习; 半监督学习

## An Online Semi-supervised Hybrid Approach for Vehicle Behavior Perception at Intersections

Zhang Hailun, Wang Guangwei, Meng Qingwen, Xu Qing, Wang Jianqiang & Li Keqiang

School of Vehicle and Mobility, Tsinghua University, State Key Laboratory of Intelligent Green Vehicle and Mobility, Beijing 100084

**[Abstract]** The autonomous driving perception system must perceive the movement of the target vehicle to make reasonable interactive decisions. For the time lag in behavior perception, as well as the problem that possible fluctuations and outliers in the data lead to poor perception accuracy, an online semi-supervised hybrid approach is proposed in this paper. Firstly, a data-driven online prediction algorithm for vehicle motion state is designed using autoregressive integral moving average and online gradient descent optimizer. Then, an initial model based on micro-clusters is constructed, and an ensemble learning strategy is established using K nearest neighbor as the base classifier. Error-driven representative learning and exponential decay strategies are designed to achieve iterative updates of the initial model. Finally, experimental data to verify the effectiveness of the proposed algorithm is collected based on the driving simulation platform. The results show that the proposed method has rapid adaptability to vehicle behavior fluctuations. The online prediction algorithm can accurately predict vehicle motion trends, and the behavior perception algorithm has strong adaptability to vehicle behavior at different prediction times.

**Keywords:** autonomous driving; behavior prediction; autoregressive integral moving average; ensemble learning; semi-supervised learning

\* 北京市自然科学基金 (3244031)、国家资助博士后研究人员计划 (GZB20230355) 和国家自然科学基金 (52131201) 资助。

原稿收到日期为 2024 年 04 月 13 日, 修改稿收到日期为 2024 年 05 月 26 日。

通信作者: 王建强, 教授, 博士, E-mail: wjqlws@tsinghua.edu.cn。

## 前言

人工智能技术使无人驾驶已成为现实<sup>[1]</sup>,然而不同等级的自动驾驶车辆(autonomous vehicles, AV)和传统驾驶人驱动车辆(human-driven vehicles, HV)将共同行驶在交通场景中,形成混行交通环境。面向不同等级的自动驾驶车辆<sup>[2]</sup>,其自动驾驶系统(autonomous driving system, ADS)或高级驾驶辅助系统(advanced driving assistance system, ADAS)为了辅助安全决策、规划安全路径,须具备对周围车辆运动状态进行实时预测和识别的能力。然而,由于复杂的道路交通环境以及千差万别的驾驶风格,导致车辆的运动状态存在较强的随机性<sup>[3-4]</sup>,数据中的噪声和波动也无法避免<sup>[5]</sup>,这使得车辆运动状态预测和行为感知是一项极具挑战性的任务<sup>[6-7]</sup>。车辆行为感知主要评估指标为准确率和时效性,即“更准”和“更快”。

国内外学者针对车辆行为感知进行了全面深入的研究<sup>[8-10]</sup>。张海伦等<sup>[9]</sup>提出一种基于稀疏表示的行为感知字典模型,可实现对多种驾驶行为同时建模。Li等<sup>[5]</sup>提出一种基于长短时记忆(long short-term memory, LSTM)网络的深度学习框架实现换道意图预测,并分析了数据噪声的影响。Zhang等<sup>[11]</sup>结合隐马尔可夫(hidden Markov model, HMM)和贝叶斯滤波(Bayesian filtering, BF),提出一种交叉路口转向行为分类框架。归纳发现,早期研究中以机器学习方法为主,但是该方法无法良好地揭示时序驾驶行为中的隐藏状态,且感知精度逊于近年来快速发展的深度学习方法,尤其以递归神经网络(recurrent neural network, RNN)为代表<sup>[12]</sup>。进一步分析可发现,现有研究以监督学习方法为主要手段。虽然研究表明只要具有大量有效标签数据,就可以训练得到具有良好泛化能力的感知模型,然而此类模型无法实时更新参数以适应多样化的驾驶风格或复杂道路场景,且传感器采集的实际驾驶数据流会存在异常值和波动等影响模型感知精度的问题。因此,现有基于批量学习的通用分类器在面向个体化差异和不同环境时可能不是最优的。

此外,当前感知技术路线为“先采集后识别”,而在行为感知过程中,现有研究往往采用滑动时间窗口技术,即对固定时窗内的数据进行识别<sup>[14]</sup>。此技术避免对整个序列进行识别,提升了计算效率,但是依然存在行为感知时间上的滞后性问题。

车辆行驶状态预测在建模方法上可以分为2类:基于模型进行预测和基于数据驱动进行预测<sup>[13]</sup>。基于模型的预测方法是指基于车辆运动学或动力学模型,考虑一定的规则约束实现车辆运动预测建模<sup>[15]</sup>。Toledo-Moreo等<sup>[16]</sup>提出一种交互式多重模型预测换道机动,整合了扩展卡尔曼滤波器为用户提供定位和机动预测,实验结果表明所提方法可以以较短延迟时间实现换道预测。Wu等<sup>[17]</sup>提出一种结合卡尔曼滤波器和车辆运动模型的方法实现预测目标车辆的短期运动,该方法综合考虑了车辆运动状态、驾驶行为以及道路曲率。然而基于模型和规则的建模方法在现实驾驶环境中(如:周围存在多辆行驶车辆,非标准化道路等)往往无法建立使人满意的预测模型。此外,该建模过程往往较为繁琐,需要考虑较多影响因素<sup>[18]</sup>。

基于数据驱动的车辆运动预测方法近年来受到较多学者的青睐<sup>[19-21]</sup>,该方法的优势在于无须考虑大量约束规则,简化了建模过程。郭景华等<sup>[7]</sup>采用聚类方法获取3类典型危险场景,并通过马尔科夫链蒙特卡洛理论建立预测模型,实现危险场景前车随机运动预测。张涛等<sup>[20]</sup>提出一种非线性自回归神经网络模型,采用转向盘角度、航向角和车辆相对位移等车辆运动参数作为模型的输入,实现车辆横向轨迹建模。Xing等<sup>[22]</sup>提出一种采用LSTM网络个性化联合时间序列的建模方法来预测前车轨迹。但是,需要注意的是,深度学习模型是一个“黑盒子”,缺乏解释性和扩展性,在无法穷尽各种场景和行驶工况的情况下,该方法存在一定应用的限制。另外,模型内部神经元权值无法适应新场景也是该方法的局限性之一。

针对现有研究的局限性,为提升车辆行为感知的准确性和时效性,本文提出一种在线半监督混和方法(OSSHA)实现对车辆运动的短期预测与行为感知,旨在改善简单驾驶行为分类器在处理实际车辆数据流时,由于各种因素(驾驶人个体、道路环境、传感器等)影响可能出现的波动和异常值等问题而导致识别精度下降。

OSSHA包括两个模块,分别为在线预测和在线感知。具体地,首先将车辆运动状态看作为一种连续、时变、动态的过程<sup>[23]</sup>,速度、加速度和轨迹等参数在时间上的表现形式为时间序列,基于自回归积分移动平均模型(autoregressive integrated moving average, ARIMA),提出一种变体的ARIMA建模车辆运动状态,结合在线梯度下降优化器(online gradient descent, OGT)和欧几里得投影使得模型可以在线工

作,基于实时观测序列修正算法参数,实现对算法参数持续迭代,进而实现对车辆运动状态的在线预测。

其次,考虑实际传感器以数据流形式采集数据,传统感知算法和模型必然会因数据波动和异常值出现精度下降问题,将集成学习(ensemble learning, EL)与半监督学习(semi-supervised learning, SSL)相结合,并应用到车辆行为感知领域。基于k-means聚类算法构建以微簇(micro-clusters, MCs)为集合

的初始模型,并采用K近邻(K-nearest neighbor, K-NN)作为基分类器,构建同构集成学习策略,设计基于错误驱动代表性学习和基于时间指数衰减的模型在线更新策略,使得初始模型可以实时适应数据流中可能出现的异常和波动。该方法可以在仅具有少量标记的样本下实现对目标行为样本的高精度分类和适应,具有较强的鲁棒性和适应性。算法架构如图1所示。

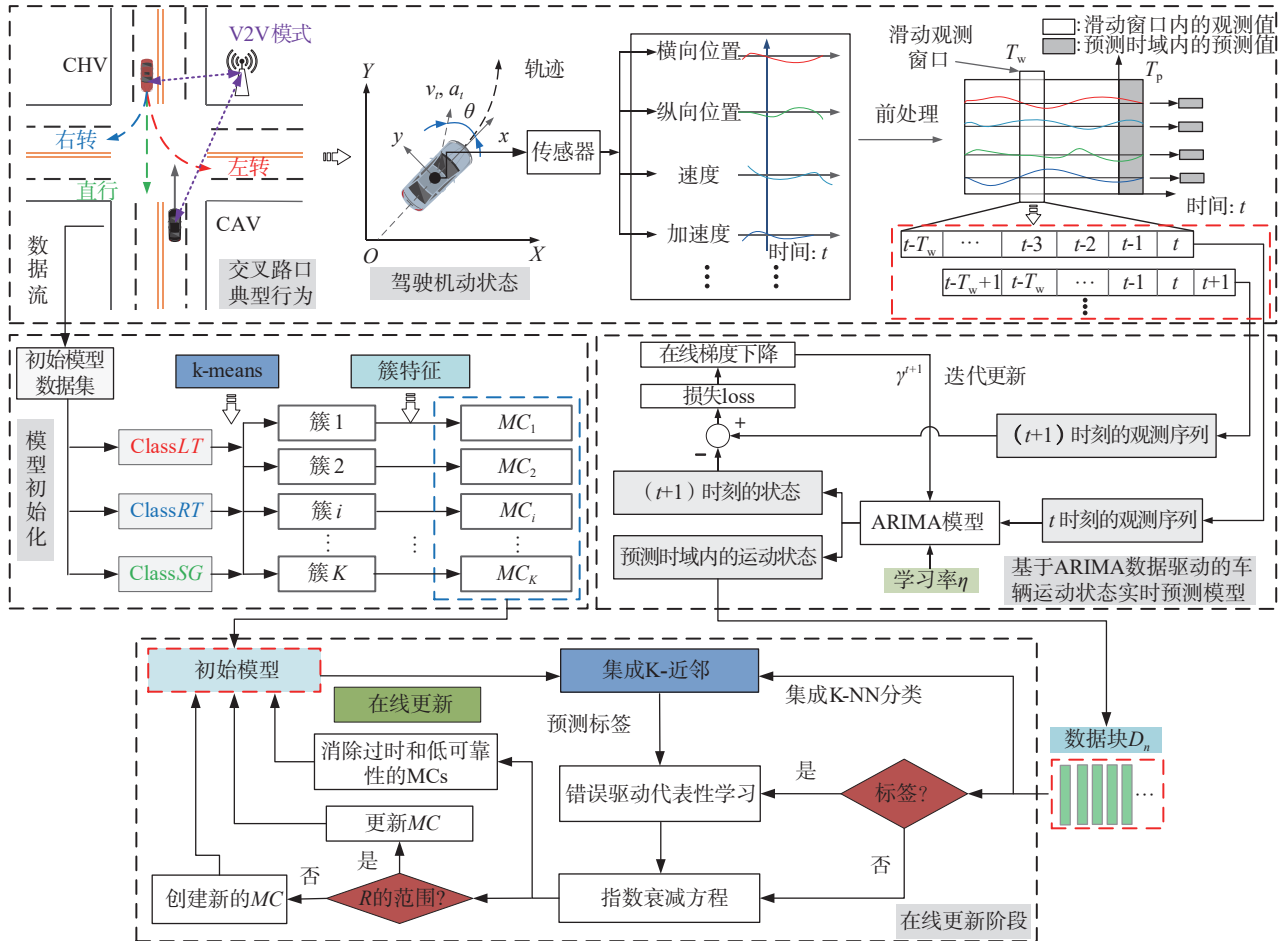


图1 车辆行为短期预测与行为感知框架

# 1 车辆运动在线预测—ARIMA-OGD算法

## 1.1 ARIMA模型

虽然驾驶人的行为意图存在一定的随机性和离散性,但是通过对反映车辆行驶状态的多维时间序列进行建模可以实现对驾驶意图的建模并识别<sup>[24]</sup>。因此,车辆在直行或机动时(换道、转向等),状态参

数在时间序列上的一段时间内将存在一定的趋势,而该趋势则反映出驾驶人在该时间段内的意图。然而传感器连续采集的时间序列可能是平稳的,也可能是非平稳的。ARIMA是非平稳时间序列建模的经典模型<sup>[25]</sup>,可实现对非平稳时间序列的短期离线预测,建模流程如图2所示。

对在时间 $t$ 的观测值 $X_t$ 进行1阶和2阶差分,分别为 $\nabla X_t = X_t - X_{t-1}$ ,  $\nabla^2 X_t = \nabla X_t - \nabla X_{t-1}$ 。当进行 $d$ 阶差分时,ARIMA( $p, d, q$ )模型的结构如式(1)所示:

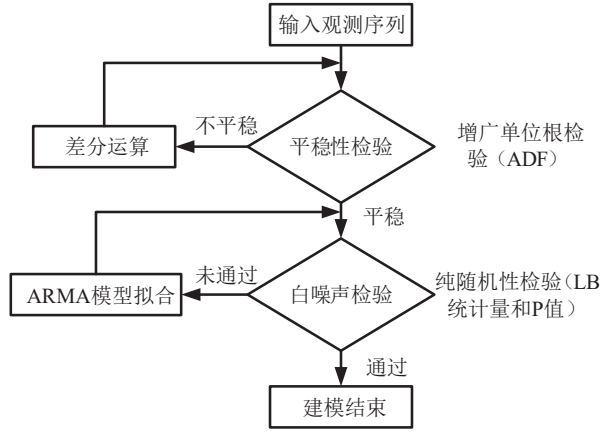


图2 传统ARIMA建模过程

$$\nabla^d X_t = \sum_{i=1}^p \phi_i \nabla^d X_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \epsilon_t \quad (1)$$

该模型的限制条件如下:

- i.  $E(\epsilon_t) = 0, \text{Var}(\epsilon_t) = \sigma_\epsilon^2, E(\epsilon_t \epsilon_s) = 0, s \neq t$
- ii.  $E(x_s \epsilon_t) = 0, \forall s < t$

式中:  $p, d, q \in \mathbb{R}$ ,  $p$  为自回归模型 AR 的阶数,  $q$  为移动平均模型 MA 的最高阶数; 系数向量  $\theta \in \mathbb{R}^q$ ;  $\phi \in \mathbb{R}^p$ ;  $E$  表示期望;  $\text{Var}$  为方差符号;  $\sigma_\epsilon^2$  为随机波动方差;  $\epsilon_t$  为零均值白噪声;  $t, s \in K, K$  为时间序列宽度。可以注意到, 当  $d = 0$  时, ARIMA( $p, d, q$ ) 模型就是 ARMA( $p, q$ ) 模型。

当车辆运动状态参数时间序列  $X_t$  满足 ARIMA( $p, d, q$ ) 模型并基于该模型进行预测时, 将在  $t+1$  时刻处观测值的  $d$  阶差分预测为  $\nabla^d \tilde{X}_{t+1}$ , 将在  $t+1$  处观测值预测为  $\tilde{X}_t$ , 预测值的表达式如下:

$$\tilde{X}_t = \nabla^d \tilde{X}_t + \sum_{i=0}^{d-1} \nabla^i X_{t-1} \quad (2)$$

结合式(1)可得

$$\tilde{X}_t = \sum_{i=1}^p \phi_i \nabla^d \tilde{X}_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \epsilon_t + \sum_{i=0}^{d-1} \nabla^i X_{t-1} \quad (3)$$

## 1.2 变体 ARIMA

由于所构建的模型并非完全准确, 因此当获取到在  $t$  时刻的 ARIMA( $p, d, q|t$ ) 模型后, 基于该模型获取  $t+1$  时刻的预测值  $\tilde{X}_t$ , 结合真实值  $X_t$ , 将容易得到一个损失值  $\ell_t(X_t, \tilde{X}_t)$ :

$$f(\phi, \theta) = \ell_t(X_t, \tilde{X}_t(\phi, \theta)) = \ell_t\left(X_t, \left(\sum_{i=1}^q \theta_i \epsilon_{t-i} + \sum_{i=1}^p \phi_i \nabla^d X_{t-i} + \sum_{i=0}^{d-1} \nabla^i X_{t-1} + \epsilon_t\right)\right) \quad (4)$$

所设计的在线 ARIMA 算法需要在  $T$  次迭代计

算后将损失的总和最小化。进一步, 将在  $T$  次迭代计算后的后悔值定义为

$$R_T = \sum_{i=1}^T \ell_i(X_i, \tilde{X}_i) - \min_{\phi, \theta} \sum_{i=1}^T \ell_i(X_i, \tilde{X}_i(\phi, \theta)) \quad (5)$$

因此, 在线 ARIMA 算法的后悔值应以次线性增长, 每一次迭代计算的后悔值随着  $T$  的增加最终会消失, 表示为  $\lim_{T \rightarrow \infty} (R_T/T) = 0$ 。

尽管在线凸优化技术可以实现参数估计<sup>[26-27]</sup>, 但是由于 ARIMA( $p, d, q$ ) 中的限制条件(i), 使得零均值噪声项  $\epsilon_t$  无法确定, 因此, 导致无法估计式(4)中的系数向量  $(\phi, \theta)$ <sup>[28]</sup>。为此, 以 ARIMA( $p, d, q$ ) 模型为基础, 定义变体模型 ARIMA( $p+n, d, 0$ ) 如下:

$$\nabla^d X_t = \sum_{i=1}^{p+n} \gamma_i \nabla^d X_{t-i} \quad (6)$$

式中:  $\gamma \in \mathbb{R}^{p+n}$ ;  $n$  为所定义的常数。

式(6)模型只有一个限制条件, 即  $\gamma_{p+n} \neq 0$ , 表示模型的最高阶数为  $p+n$ , 相较于式(1)其不含随机噪声项  $\epsilon_t$ , 因此, 为了使基于变体模型 ARIMA( $p+n, d, 0$ ) 获得的预测值尽可能有效接近原 ARIMA( $p, d, q$ ) 模型获得的预测值,  $n$  的选择至关重要。基于 ARIMA( $p+n, d, 0$ ) 模型得到预测值如下:

$$\tilde{X}_t(\gamma^t) = \sum_{i=1}^{p+n} \gamma_i \nabla^d X_{t-i} + \sum_{i=0}^{d-1} \nabla^i X_{t-1} \quad (7)$$

损失函数为

$$f(\gamma) = \ell_t(X_t, \tilde{X}_t(\gamma^t)) = \ell_t\left(X_t, \left(\sum_{i=1}^{p+n} \gamma_i \nabla^d X_{t-i} + \sum_{i=0}^{d-1} \nabla^i X_{t-1}\right)\right) \quad (8)$$

上式为凸损失函数, 因此, ARIMA( $p, d, q$ ) 模型在形式上被转化为无噪声项的在线凸优化问题, 主要实现对参数向量  $\gamma$  的估计。

## 1.3 在线梯度下降优化

在线梯度下降的凸优化求解器, 可实用于任意凸损失函数<sup>[27]</sup>。定义在线学习策略集为  $\mathcal{H}$  (凸集), 对于向量  $\gamma$  在  $t$  时刻进行如下两次计算操作。

(1) 采用当前数据对  $\gamma_t$  进行梯度下降计算, 获得  $\gamma_{t+1}$ 。

(2) 判断  $\gamma_{t+1}$  是否属于  $\mathcal{H}$ , 如果不属于, 则进行欧几里得投影, 如下:

$$\gamma_{t+1} = \prod_{\mathcal{H}}(\gamma_t - \eta_t \nabla \ell_t(\gamma_t)) \quad (9)$$

式中:  $\eta_t$  为学习率;  $\nabla \ell_t(\gamma_t)$  为对  $\ell_t$  求关于  $\gamma_t$  的导数;  $\prod_{\mathcal{H}}$  为投影算子, 即将不在  $\mathcal{H}$  中的向量  $\gamma$  投影成一

个与 $\gamma$ 最近且包含在 $\mathcal{H}$ 的向量。须注意的是,如果 $\gamma$ 已经包含于 $\mathcal{H}$ 中,则无须进行第2步投影计算,即

$$\prod_{\mathcal{H}}(\gamma) = \operatorname{argmin}_{u \in \mathcal{H}} \|\gamma - u\| \quad (10)$$

式中 $u$ 为属于 $\mathcal{H}$ 的向量。

可以通过调制学习率 $\eta_t$ ,实现对式(5)后悔值界的控制。

具体如图1所示,定义时间序列上的滑动观测窗口为 $T_w$ ,设 $I$ 为模型的输入量, $T_p$ 为预测时域, $O$ 为模型的输出量, $\gamma$ 为变体ARIMA的参数向量,则在线预测模型输出表示为

$$O^\tau = V\_ARIMA(\gamma^\tau, I^\tau) \quad (11)$$

$$\gamma^{\tau+1} = OGT(\gamma^\tau, O^{\tau+1}, \eta, \ell^\tau) \quad (12)$$

式中: $V\_ARIMA$ 表示ARIMA的变体结构; $OGT$ 表示在线梯度下降法; $O^\tau$ 为在 $\tau$ 时刻的预测输出,其中 $\tau = (t+1, t+2, \dots, t+T_p)$ ;  $I^\tau$ 为在 $\tau$ 时刻的输入,其中 $\tau = (t-T_w, \dots, t-2, t-1)$ ;  $\gamma^{\tau+1}$ 为 $\tau+1$ 时刻的模型参数向量; $O^{\tau+1}$ 为在下一时刻的观测量; $\eta$ 为学习率; $\ell^\tau$ 为 $\tau$ 时刻的损失。随着观测数据的输入实时更新模型参数,使得模型具有快速适应能力,并可较为真实地反映未来一段时间内车辆的运动趋势,此种处理方式克服了传统预测模型对系统算力和存储有较高需求的局限。

## 2 整合集成学习的在线半监督方法

在线半监督算法架构如图1中模型初始化和在线更新模块所示。通过动态更新一组表征驾驶行为的微簇(micro-clusters, MCs),不断学习变化的数据流趋势,可使模型在线工作。MC是聚类数据的一种统计总结<sup>[29]</sup>,与传统聚类的区别在于,后者是指将具有相似特征的数据点聚类形成一个类别,而MC将传统聚类中的数据点计算为聚类特征向量。算法包含3个部分,分别为初始模型训练、在线分类和在线模型更新。定义 $D = \left\{ (x_i, y_i) \right\}_1^\infty$ 为数据流,其中 $x_i$ 为在时间 $t_i$ 进入模型的实例, $x_i \in \mathcal{X} \in \mathbb{R}^n$ 为 $n$ 维的向量, $y_i \in \mathcal{Y}$ 表示实例的标签。

### 2.1 初始模型训练

首先将初始训练数据手动划分为不同类别,然后使用k-means将每一类数据划分为 $k$ 个簇,计算每个簇的摘要信息,并存储在MC中,其包含以下7个特征:

$$MC = (L_s, S_s, N, Z, T, M_L, R) \quad (13)$$

式中: $L_s$ 和 $S_s$ 分别为MC中全部数据点的线性和以及平方和,并分别表示为 $\sum_1^N x_i$ 和 $\sum_1^N (x_i)^2$ ;  $N$ 为数据点的数量; $Z$ 为MC随时间的可靠性,其初始值设置为1; $T$ 为MC每次更新所记录的时间,初始值为0; $M_L$ 为MC的标签; $R$ 为MC的空间半径,被定义为MC中数据点与中心之间距离的标准差;MC的中心为所有数据的均值,表示为 $\rho$ ,计算如下:

$$\begin{cases} R = \sqrt{\frac{N \times S_s - L_s^2}{N^2}} \\ \rho = \frac{L_s}{N} \end{cases} \quad (14)$$

须注意的是,不同的驾驶人可能会以不同的方式执行相同的操作,相同的机动行为数据可能会落入不同的簇集群。因此,对每个机动行为都设一个确定簇数,以防止某个机动行为特性未被涵盖。

### 2.2 基于K-NN的同构集成学习分类策略

为了获得稳定可靠的分类性能,将多个K-NN进行集成,即 $\vartheta \times K$ -NN,其中 $(K \in \{1, 3, 5, \dots\})$ 。如,当 $\vartheta = 1$ 时,表示只有一个K-NN分类(1-NN或3-NN);当 $\vartheta = 2$ 表示2×K-NN分类器(1-NN和3-NN)。以此类推,当 $\vartheta = 4$ 时,表示4×K-NN分类器 $(K \in \{1, 3, 5, 7\})$ 。在每个时间步上,对新输入的实例 $x_i$ 在各分类器中选择一个分类性能最好的K-NN分类器来预测 $x_i$ 的标签。最佳分类器选择规则为,对每个分类器设置相应的权重,来表示对应分类器对当前样本的平均准确率,每个分类器在时间 $t_i$ 权重计算如下:

$$\zeta_{K-NN} = \frac{1}{c} \sum_{i=t_i-c+1}^{t_i} (K-NN(x_i) = y_i) \quad (15)$$

式中: $\zeta$ 为表示每个分类器权重的矩阵; $c$ 为最近具有标签样本的数量; $t_i$ 为时间步; $K-NN(x_i)$ 则用于预测 $x_i$ ;  $y_i$ 为真实的类标签。 $K-NN(x_i) = y_i$ 为在时间 $t_i$ 之前预测最近 $c$ 个数量具有标签的样本的逻辑函数。如果预测结果与真实结果相同,则总和值累加1,否则累加0。获得的结果除 $c$ 得到分类器的平均权重。

最后,权重最大的分类器为最佳,并用于测试实例的类标签。集成K-NN的策略如下:

$$\begin{cases} \text{best}_K = \operatorname{argmax}_K (\zeta_{K-NN}) \\ \text{label}(x_i) = \text{best}_K(K-NN(x_i)) \end{cases} \quad (16)$$

其中 $K$ 是K-NN分类算法中的一个重要参数,与集成策略中 $\vartheta$ 值的选择有关。

### 2.3 在线更新策略

在线更新阶段包含基于错误驱动的代表性学习方法和指数衰减方程。具体地说,在获得初始模型后,传入的实例数据流首先通过集成K-NN进行分类。然后,每个标记或未标记的实例用于在线更新初始模型。如果传入实例被标记,则用于学习MC的代表性;否则,算法会根据实例的具体特征更新MC或创建一个新的MC。对传入实例进行分类的主要目的是推断相邻MCs的可靠性,并以错误驱动的方式动态选择最具代表性的MC来表示各种机动行为。如果相邻MC的类标签与传入实例的类标签一致,则MC的可靠性增加,同时更新 $T$ 。否则,可靠性会降低。

随着时间的推移,传入数据流的概念漂移可能会降低模型的鲁棒性。模型必须实时消除过时的MC。例如,意外误操作和短时操纵波动对当前车辆机动行为表征的影响可以忽略不计,也不能代表当前正在机动过程的趋势。因此,采用一种指数衰减函数计算MC权重随时间的变化:

$$Z_i = Z_i \times 2^{-\lambda \times E} \quad (17)$$

式中: $\lambda$ 为衰减率; $E$ 是自上次更新MC所经过的时间。尽管MC的可靠性会随着时间的推移而逐渐降低,但是如果一个MC被选择作为K-NNs的基准,用于测试实例并做出正确的预测,则MC的可靠性增加1。此外,从模型中消除了具有负可靠性的局部概念漂移MC或具有接近零可靠性的MC。通过这种方式,算法可以快速适应数据中的局部波动。

剔除过时的MC后,实时传入的实例 $\mathbf{x}$ 则增量式地添加到最近的MC,或创建一个新的MC以使模型能够应对不同机动或同一机动行为的不同数据趋势。为此,计算 $\mathbf{x}$ 和最近MC之间的欧几里得距离。然而必须满足两个条件才能创建新的MC,即 $\mathbf{x}$ 不在最近MC的半径之内( $R_{MC}$ ),或者 $\mathbf{x}$ 和最近MC都已经具有标签,但是标签不同。除此之外, $\mathbf{x}$ 则增量式地被融合到最近地MC中,更新方式如下:

$$\begin{cases} L_s = L_s + L_s(\mathbf{x}) \\ S_s = S_s + S_s(\mathbf{x}^2) \\ N = N + 1 \\ T = cur\_T \end{cases} \quad (18)$$

式中 $cur\_T$ 为当前时间。如果新的MC没有标签,而 $\mathbf{x}$ 具有标签,则将 $\mathbf{x}$ 的标签分配给新的MC。从而创建一个新的MC,模型也获得更新。

由于计算机内存的限制,可以添加的新MC数

量并非是有限的。因此,须设置MC的最大边界(maxMC),即模型可以存储的最大MC数量。由于机动过程的差异,一些现有的MC须合并为新的MC来创造空间,即算法会搜索两个最近的MC(未标记和标记)合并。如果没有未标记的MC,则搜索具有最多MC的类,并合并该类中最接近的两个MC。采用欧几里得距离计算MC之间的距离。MC的合并规则定义如下:

$$[MC_i, MC_j] = \begin{cases} \underset{\substack{MC_i \in MC_{in} \\ MC_j \in MC_{un}}}]{\operatorname{argmin}} ED(MC_i, MC_j), MC_{un} \neq \phi \\ \underset{\substack{MC_{i,j} \in MC_{in} \\ i \neq j}}{\operatorname{argmin}} ED(MC_i, MC_j), \text{其他} \end{cases} \quad (19)$$

式中: $MC_{in}$ 和 $MC_{un}$ 分别表示模型中标记和未被标记的集; $MC_{in}$ 是一组属于特定类别的具有标签的MC; $ED(MC_i, MC_j)$ 表示 $MC_i$ 和 $MC_j$ 之间的欧式距离。合并后的MC特征表示如下:

$$MC_{merge} = \begin{cases} L_{S_{merge}} = L_{S_i} + L_{S_j} \\ S_{S_{merge}} = S_{S_i} + S_{S_j} \\ N_{merge} = N_i + N_j \\ Z_{merge} = \max(Z_i, Z_j) \\ T_{merge} = \max(T_i, T_j) \\ M_{L_{merge}} = CL_i \end{cases} \quad (20)$$

新合并得到的MC半径 $R$ 根据式(14)计算。新空间获取之后,则创建一个新的MC并将其添加到模型中。采用交叉测试训练方法确定在线半监督算法5个关键参数优选值,使用单个实例测试和更新分类器,并以准确率为测试指标。最终,maxMC选择45, $c$ 为100, $k$ 为40, $\vartheta$ 选择5。 $\lambda$ 设置规则为:如果一个MC在接收到两倍的maxMCs样本后没有更新,则该MC从模型中删除。

## 3 实验与数据

### 3.1 驾驶模拟平台

基于驾驶模拟平台设计了网联交叉路口交通环境,采集所需的驾驶行为数据(左转TL、右转TR和直行GS)。如图3所示,驾驶模拟平台由真实轿车、三通道前显示系统、双通道后显系统、6自由度平台、工控主机和控制系统组成。平台可提供与驾驶真实汽车相近的体验,如加速、转向和制动等机动。系统以60 Hz频率记录驾驶行为数据(速度、加速度和行驶轨迹等)。



图3 驾驶模拟平台及其组件

### 3.2 实验人员

招募身体健康且视力良好的驾驶人35名(其中26名男性和9名女性)进行实验。每位驾驶人在实验前都接受10-15 min的培训和试驾,并填写一份包含驾驶人基本信息(年龄、驾驶经验、职业背景、交通违规和事故情况)的问卷和一份知晓本研究的同意书。在试验期间感受任何不适(如晕动症)可随时退出实验。一名驾驶人在实验过程中因晕动症退出,共分析了34名驾驶人的实验数据,年龄范围为23至56岁,平均38.4岁(标准差10.9),平均驾龄为16.3年(标准差10.6)。

### 3.3 实验场景

在驾驶模拟平台中建立了城市场景,并设计双向四车道信号交叉路口,驾驶环境为晴朗的白天。图4显示了驾驶模拟平台中所设计的场景,其中图4(a)为场景俯视图且包含了每个路口的编号,图4(b)为进入路口时的驾驶人视觉角度。

### 3.4 行为序列提取与参数

模型应能够实时并可在周围车辆机动开始的早

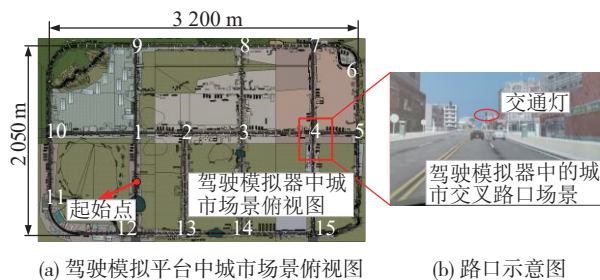


图4 驾驶模拟平台场景

期阶段实现行为感知,如图5(a)显示了从AV的视角对交叉路口HV机动行为进行识别的示意图。因此,为构建鲁棒的行为感知模型,机动行为序列的有效提取是初始的关键步骤,图5(b)为交叉路口驾驶行为时间序列样本提取示意图。

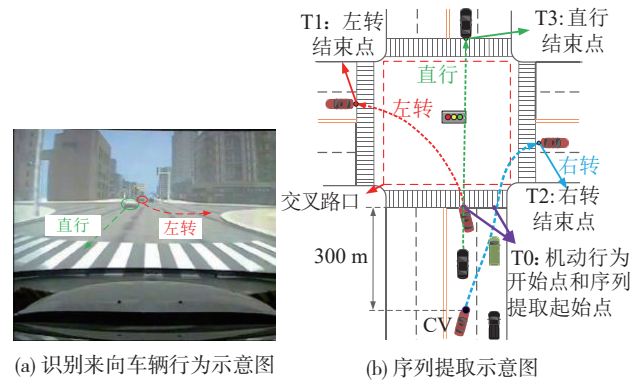


图5 案例演示与序列提取示意

本文提取的序列开始位置为T0点,即车辆开始跨过路口的斑马线,时间序列的终点对于TL为T1、TR为T2和GS为T3,即车辆完全越过路口斑马线,最终获取了交叉路口驾驶行为样本1 212个,包括404个TL,404个TR以及404个GS样本。构建鲁棒的行为感知模型,需要选择合适的车辆行为参数,本文选择的模型输入参数为速度、加速度、车辆横向位置和纵向位置。

## 4 算法验证与结果分析

### 4.1 ARIMA-OGD算法验证

分别设置预测时间0.1、0.5、1和1.5 s以验证算法有效性,如图6和图7所示,分别为对左转和右转的横向位置、纵向位置、速度以及加速度的预测结果。

由图6(a)和图7(a)中的横向位置预测结果可知,当预测时间较短时,ARIMA-OGD可以以较高的准确率实现对车辆横向位置的预测,随着预测时间增加,尽管算法在初始0-1 s阶段具有一定的波动,但是在2-4 s位置时则趋于稳定,并且与实际轨迹保持相对一致的趋势。由图6(b)和图7(b)的纵向位置预测结果可知,所提出的预测算法对于纵向运动可实现更为准确的预测,这与纵向位置始终保持相对稳定有关。

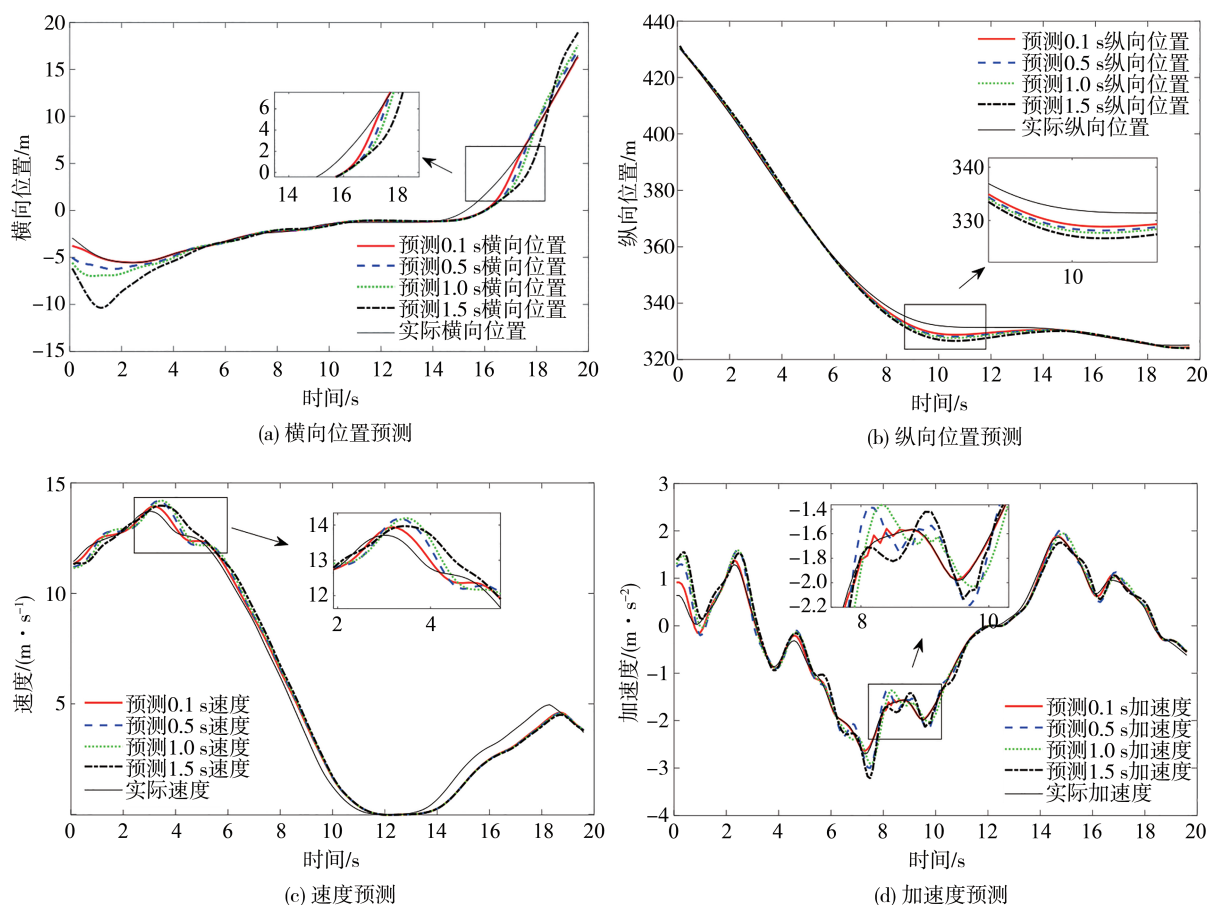


图6 左转参数预测

相比于车辆轨迹,车辆的速度和加速度波动性更大。如图6(c)和图7(c)中预测的结果所示,算法也可以实现对速度的准确预测,如图中的放大图所示,当速度突然下降或者提升时,算法可以在短时间内适应,并可在1 s内恢复准确预测,表明所提算法具有较强的适应性。由图6(d)和图7(d)的加速度预测结果可知,预测值与实际加速度存在一定偏差,这是由于加速度的非稳定性和随机性大,当加速度出现显著波动时,预测值也存在一定波动,但是从预测结果也可以看出预测算法可以跟随实际加速度快速调整参数,并在随后的预测中反映出实际加速度的变化趋势。

总体可知,所提出的ARIMA-OGD算法可以对短时内的车辆运动状态实现较好的预测效果,算法在运行的早期阶段存在一定预测波动,这是由于模型在初始化后,未接收到足够多的观测数据而无法依据历史状态对车辆未来运动做出准确判断,随着充足观测数据的输入,模型预测精度随之提升。因此,本文算法可以准确地预测车辆运动状态和轨迹。

#### 4.2 EL-SSL算法验证

如前所述,对所提出的EL-SSL算法进行测试评估首先需要构建初始模型。从3种交叉路口行为样本中随机选择10%的数据量作为初始模型训练集,即40个TL、40个TR和40个GS样本。随后,剩余样本以数据流的形式依次随机进入模型,其中部分样本具有标注。算法的具体运行方式为,预测的样本实例进入后即进行测试,并根据测试结果更新MC,随之更新初始模型,之后输入的样本则使用更新后的模型进行测试,重复此过程,直至数据流结束。

比较了不同预测时间下EL-SSL算法与其他机器学习方法的性能表现,包括HMM、朴素贝叶斯(NB)、支持向量机(SVM)、K-NN和LSTM。LSTM-50表示50%的样本被标记并用于测试模型,LSTM-int表示考虑了车车交互信息(即AV和HV的相对速度和相对距离);其中SSL-K-NN表示仅使用了一个K-NN分类器,并有10%的测试样本具有标记,用于测试集成策略有效性;EL-SSL-10、EL-SSL-30和EL-SSL-50分别表示有10%、30%和50%的剩余样

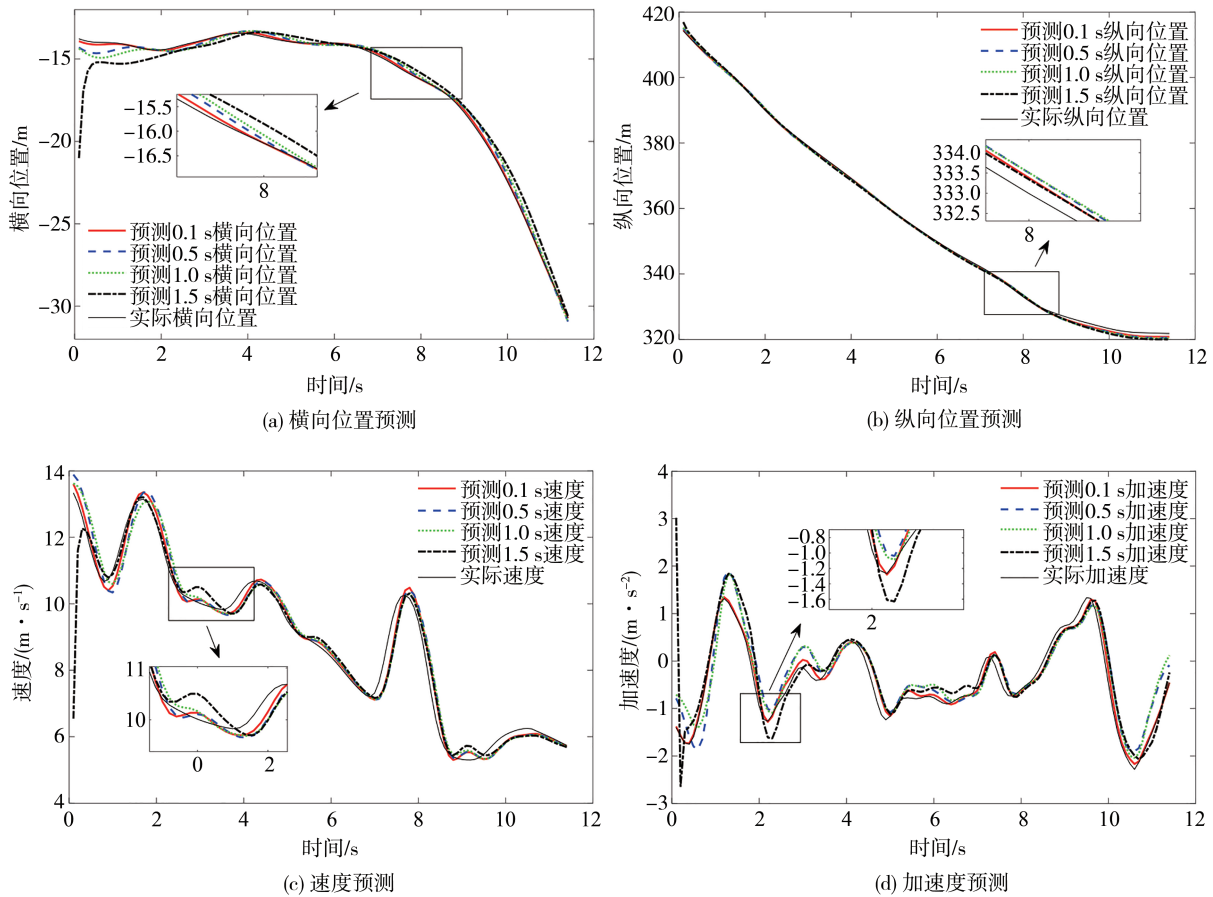


图7 右转参数预测

本具有标记,通过与这3个基准算法对比可反映出半监督学习方法对于少量标记数据所能达到的识别性能。测试结果如表1~表3所示。

表1 预测时间0.1s时准确率对比

算法	TL/%	TR/%	GS/%	平均准确率/%
SVM	76.2±3.5	73.1±2.7	74.6±3.2	74.8±3.5
HMM	72.5±2.9	69.7±2.7	70.1±2.4	71.7±3.8
HMM-BF	80.4±4.5	78.6±3.7	78.4±2.4	79.2±5.7
NB	78.2±3.3	77.2±3.5	76.4±4.1	77.5±4.5
K-NN	76.6±2.5	72.5±3.2	73.4±6.2	75.0±1.5
LSTM-50	62.0±1.9	59.2±2.9	58.4±2.1	59.5±3.5
LSTM-int	83.5±4.3	81.4±3.1	81.9±2.8	82.4±4.3
SSL-K-NN	78.6±4.2	76.1±3.7	76.9±3.5	77.5±4.4
EL-SSL-10	84.1±4.2	79.4±5.7	82.1±4.6	81.2±5.7
EL-SSL-30	85.8±3.4	81.4±5.2	82.9±4.3	83.8±1.4
EL-SSL-50	86.8±5.3	84.5±2.8	85.1±2.7	85.9±3.4

由表1~表3可知,EL-SSL算法对不同预测时间样本实例的识别准确率均优于大多数基准算法。即使只有10%的样本被标记(即无标记的测试样本占

表2 预测时间0.5s时准确率对比

算法	TL/%	TR/%	GS/%	平均准确率/%
SVM	85.7±2.4	79.3±2.1	80.9±3.2	82.1±3.6
HMM	78.8±3.1	76.0±3.2	75.4±3.2	76.8±4.8
HMM-BF	85.5±4.7	83.2±4.3	82.4±2.4	84.1±3.6
NB	85.1±3.1	84.4±3.0	84.0±3.2	84.9±4.0
K-NN	86.0±3.3	85.7±3.5	84.2±2.1	84.9±1.8
LSTM-50	63.4±5.2	61.4±2.7	64.1±4.1	63.2±2.9
LSTM-int	89.9±2.9	87.4±2.7	88.0±3.0	88.9±2.4
SSL-K-NN	87.3±1.5	83.5±1.7	83.4±3.6	84.9±2.8
EL-SSL-10	91.2±4.6	86.3±3.2	86.9±2.2	88.6±2.1
EL-SSL-30	93.2±3.5	88.9±4.5	89.1±3.6	91.2±2.5
EL-OSS-50	93.9±1.2	91.0±2.5	90.1±1.1	92.1±2.9

80%),所提出的EL-SSL算法在不同的预测时间下也能达到较高的准确率。而随着测试样本中的标记率越高,准确率则越高。LSTM模型在之前的研究中显现出优异的识别性能,然而在行为样本标签较少情况下,其泛化性能表现较差,因为其不能使用未标记的样本进行自我更新,不具有适应性;在考虑车车交互信息后,LSTM-int模型在不同预测时间下的准

表3 预测时间1 s时准确率对比

算法	TL/%	TR/%	GS/%	平均准确率/%
SVM	88.2±2.1	86.2±1.9	86.0±1.8	87.1±4.2
HMM	84.3±2.2	82.5±4.1	81.3±4.4	83.8±3.5
HMM-BF	88.3±2.5	86.7±3.2	87.4±3.4	87.8±3.1
NB	88.1±4.3	87.6±4.5	86.9±1.5	87.5±2.3
K-NN	88.9±2.5	87.6±1.7	87.7±1.9	88.5±3.9
LSTM-50	71.5±6.1	70.2±3.5	69.8±4.7	69.8±4.5
LSTM-int	94.9±3.2	93.4±1.5	93.0±3.2	94.3±5.1
SSL-K-NN	93.4±2.0	90.9±3.8	92.7±5.2	92.3±3.2
EL-SSL-10	94.0±2.0	92.2±2.5	93.1±2.5	93.6±2.5
EL-SSL-30	96.2±2.4	93.5±1.9	95.1±1.5	94.9±1.1
EL-SSL-50	97.0±2.2	94.1±3.5	94.8±1.6	95.6±2.1

准确率均超越大多数算法,但是低于EL-SSL-30和EL-SSL-50,这表明所提出的集成半监督学习算法在转向行为感知任务下具有优越性。

其他基准算法均采用5折交叉验证进行测试。结果表明,当预测时间为0.1 s时,各基准算法均表现不佳,这是由于较短时间内的行为样本可识别特征不足,但是本文算法识别准确率依然超过80%,这表明该算法对新特征的学习适应性。随着预测时间提升,行为样本表现出更多可区分机动特征,各算法的准确率均有所提升。此外,对比表1~表3中的SSL-K-NN和EL-SSL也可知,SSL中的集成学习策略对于提升准确率也具有显著效果。结果表明所提出的EL-SSL算法相比于传统机器学习方法在缺少样本标记时,对于车辆行为识别任务更具鲁棒性,即使是标记样本数量较少时,随着可区分样本进入模型越多,算法性能越佳。

图8显示的是所提算法在对预测时间为1.5 s时车辆行为数据流进行测试获得的识别精度,图中的EL-OSS 10%(30%、50%)表示剩余样本的10%(30%、50%)被随机标记并用于测试。可以看出,SSL框架的识别准确率随着数据流的增加而迅速增加,这是因为随着更多数据进入模型,初始模型不断更新,识别性能逐渐提升。随后曲线开始变平,表明额外的样本不再使识别模型发生显著变化。SSL-K-NN识别性能相对较低,表明单个K-NN的感知能力弱于集成学习策略。

进一步对算法的实时识别性能进行测试,数据块中样本实例以数据流形式进入模型并获得实时识别结果,如图9(a)和图9(c)所示,分别显示了实时识别TL和TR两个样例的示意图。图中第1行显示车辆的轨迹图(倒三角形表示转向开始点,其计算方




图8 不同标记比例下的识别率

式参考文献[11]),第2行是航向角的轨迹图,第3行是识别的结果图(序列在转向点之前始终被标记为GS)。可以直观地看出,当车辆进入路口并开始转向时,算法可以快速识别出车辆的机动状态。此外,对算法的时效性进行了统计,如图9(b)和图9(d)所示。超过80%的TL和TR可以在0.1和0.15 s内获得准确检测,由此可知算法可在转向机动行为的早期阶段实现实时快速感知。

综上所述,本文算法相比其他基准算法更具适应性,并具有较高的准确率,算法也具备实时识别能力。

## 5 结论

本文提出了一种在线半监督混合方法,实现对车辆行驶状态的实时预测和在线感知。设计了一种ARIMA变体模型,在未考虑时间序列零均值噪声项的前提下,通过选择合适的参数实现对非平稳时间序列的建模。引入在线梯度下降方法,并通过欧几里得投影计算获得下一时刻的向量参数,实现预测模型的在线参数更新。此外,针对实时数据中可能存在的波动或异常,训练了基于微簇的初始模型,设计了以K-NN为基准模型的同构集成学习策略,结合半监督学习算法构建了车辆行为感知半监督学习方法,其可对以数据流形式为表征的车辆行为进行实时感知识别。模型更新策略包含错误驱动代表性学习方法和指数衰减方程,随着输入模型中的样本实例增多,模型的鲁棒性可逐渐加强。

基于驾驶模拟平台设计了交叉路口场景,并采集了驾驶人行为样本数据,测试所提出的混合算法,结果表明所提预测算法可实现对车辆机动行为的准







图9 实时识别结果

确预测,半监督行为感知算法相比于基准算法具有显著优越性,尤其在具有少量标记数据下依然可获得令人满意的性能表现。

本文算法还需要考虑以下局限性。不同的车辆运动参数在数值量纲上存在差异,如纵向位置和加速度的数量级不同,预测算法需要根据不同参数选择不同学习率用以保证预测精度。下一步将对学习率的自适应选择进行研究。此外,所提半监督感知算法主要考虑数据中的异常和波动等问题,下一步考虑更加复杂的数据情况,如数据演化特征的适应性计算,进一步提升算法鲁棒性。

### 参考文献

- [1] FENG S, SUN H, YAN X, et al. Dense reinforcement learning for safety validation of autonomous vehicles [J]. *Nature*, 2023, 615(7953): 620-627.
- [2] SCHNEIDER J, MEADOWS G, MATHISON S R, et al. Validation and sensitivity studies for SAE J2601, the light duty vehicle hydrogen fueling standard [J]. *SAE International Journal of Alternative Powertrains*, 2014, 3(2): 257-309.
- [3] 田彦涛, 赵凤凯, 聂光明. 考虑驾驶习惯的驾驶员换道意图识别 [J/OL]. *吉林大学学报(工学版)*, 2020: 1-9.  
TIAN Y T, ZHAO F K, NIE G M. Driver's lane change intention recognition considering driving habits [J/OL]. *Journal of Jilin University (Engineering and Technology Edition)*, 2020: 1-9.
- [4] 刘通, 付锐, 马勇, 等. 考虑驾驶人风格的跟车预警规则研究 [J]. *中国公路学报*, 2020, 33(2): 170-180.  
LIU T, FU R, MA Y, et al. Car-following warning rules considering driving styles [J]. *China Journal of Highway and Transport*, 2020, 33(2): 170-180.
- [5] LI Y, LIU F, XING L, et al. A deep learning framework to explore influences of data noises on lane-changing intention prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024.
- [6] 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 [J]. *中国公路学报*, 2019, 32(6): 34-42.  
JI X W, FEI C, HE X K, et al. Intention recognition and trajectory prediction for vehicles using LSTM network [J]. *China Journal of Highway and Transport*, 2019, 32(6): 34-42.
- [7] 郭景华, 李志强, 王进, 等. 基于危险场景聚类分析的前车随机运动状态预测研究 [J]. *汽车工程*, 2020, 42(7): 847-853, 859.  
GUO J H, LI K Q, WANG J, et al. Study on prediction of preceding vehicle's stochastic motion based on risk scenarios clustering analysis [J]. *Automotive Engineering*, 2020, 42(7): 847-853, 859.
- [8] 付锐, 张海伦, 刘文晓, 等. 驾驶人意图识别综述 [J]. *长安大学学报(自然科学版)*, 2022, 42(1): 33-60.  
FU R, ZHANG H L, LIU W X, et al. Review on driver intention recognition [J]. *Journal of Chang'an University (Natural Science*

- Edition), 2022, 42(1): 33–60.
- [9] 张海伦, 付锐, 袁伟, 等. 面向前车的驾驶行为感知与意图识别算法研究 [J]. 中国公路学报, 2022, 35 (6): 299–311.  
ZHANG H L, FU R, YUAN W, et al. Research on algorithms of driving behavior perception and intention recognition oriented to the vehicle front [J]. China Journal of Highway and Transport, 2022, 35 (6): 299–311.
- [10] BOCKLISCH F, BOCKLISCH S F, BEGGIATO M, et al. Adaptive fuzzy pattern classification for the online detection of driver lane change intention [J]. Neurocomputing, 2017, 262: 148–158.
- [11] ZHANG M, FU R, MORRIS D D, et al. A framework for turning behavior classification at intersections using 3D LIDAR [J]. IEEE Transactions on Vehicular Technology, 2019, 68 (8): 7431–7442.
- [12] ZYNER A, WORRALL S, NEBOT E. Naturalistic driver intention and path prediction using recurrent neural networks [J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21(4): 1584–1594.
- [13] LEFÈVRE S, VASQUEZ D, LAUGIER C. A survey on motion prediction and risk assessment for intelligent vehicles [J]. ROBO-MECH Journal, 2014, 1(1): 1–14.
- [14] ZHANG H, FU R, WANG C, et al. Turning maneuver prediction of connected vehicles at signalized intersections: a dictionary learning-based approach [J]. IEEE Internet of Things Journal, 2022, 9(22): 23142–23159.
- [15] 张一鸣, 周兵, 吴晓建, 等. 基于前车轨迹预测的高速智能车运动规划 [J]. 汽车工程, 2020, 42(5): 574–580, 587.  
ZHANG Y M, ZHOU B, WU X J, et al. Motion planning of high-speed intelligent vehicle based on front vehicle trajectory prediction [J]. Automotive Engineering, 2020, 42(5): 574–580, 587.
- [16] TOLEDO-MOREO R, ZAMORA-IZQUIERDO M A. IMM-based lane-change prediction in highways with low-cost GPS/INS [J]. IEEE Transactions on Intelligent Transportation Systems, 2009, 10(1): 180–185.
- [17] WU C, PENG L, HUANG Z, et al. A method of vehicle motion prediction and collision risk assessment with a simulated vehicular cyber physical system [J]. Transportation Research Part C: Emerging Technologies, 2014, 47: 179–191.
- [18] 谢枫, 娄静涛, 赵凯, 等. 基于行为识别和曲率约束的车辆轨迹预测方法研究 [J]. 汽车工程, 2019, 41(9): 1036–1042.  
XIE L, LOU J T, ZHAO K, et al. A research on vehicle trajectory prediction method based on behavior recognition and curvature constraints [J]. Automotive Engineering, 2019, 41(9): 1036–1042.
- [19] 刘创, 梁军. 基于注意力机制的车辆运动轨迹预测 [J]. 浙江大学学报(工学版), 2020, 54(6): 1156–1163.  
LIU C, LIANG J. Vehicle motion trajectory prediction based on attention mechanism [J]. Journal of Zhejiang University (Engineering Science), 2020, 54(6): 1156–1163.
- [20] 张涛, 邹渊, 张旭东, 等. 网联车辆并线预测与巡航控制的研究 [J]. 汽车工程, 2020, 42(2): 250–256.  
ZHANG T, ZHOU Y, ZHANG X D, et al. Research on merging prediction and cruise control for connected vehicles [J]. Automotive Engineering, 2020, 42(2): 250–256.
- [21] SUN J, QI X, XU Y, et al. Vehicle turning behavior modeling at conflicting areas of mixed-flow intersections based on deep learning [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3674–3685.
- [22] XING Y, LV C, CAO D. Personalized vehicle trajectory prediction based on joint time-series modeling for connected vehicles [J]. IEEE Transactions on Vehicular Technology, 2020, 69(2): 1341–1352.
- [23] ZHANG M, FU R, MORRIS D D, et al. A framework for turning behavior classification at intersections using 3D LIDAR [J]. IEEE Transactions on Vehicular Technology, 2019, 68 (8): 7431–7442.
- [24] GADEPALLY V, KRISHNAMURTHY A, OZGUNER U. A framework for estimating driver decisions near intersections [J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(2): 637–646.
- [25] 易丹辉, 王燕. 应用时间序列分析 [M]. 5版. 北京: 中国人民大学出版社, 2019.  
YI D H, WANG Y. Applied time series analysis [M]. 5th ed. Beijing: China Renmin University Press, 2019.
- [26] HAZAN E, AGARWAL A, KALE S. Logarithmic regret algorithms for online convex optimization [J]. Machine Learning, 2007, 69(2–3): 169–192.
- [27] ZINKEVICH M. Online convex programming and generalized infinitesimal gradient ascent [C]. Proceedings of the 20th International Conference on Machine Learning (ICML-03), 2003: 928–936.
- [28] ANAVA O, HAZAN E, MANNOR S, et al. Online learning for time series prediction [C]. Conference on Learning Theory, 2013: 172–184.
- [29] SHAO J, TAN Y, GAO L, et al. Synchronization-based clustering on evolving data stream [J]. Information Sciences, 2019, 501: 573–587.