

基于多隐马尔可夫模型的车辆机动行为识别与预测

曹凯^{1,2}, 于善义¹, 于少伟²

1. 山东理工大学交通与车辆工程学院, 山东 淄博 255049; 2. 山东英才学院, 山东 济南 250104

基金项目: 国家自然科学基金资助项目(61074140); 山东省自然科学基金资助项目(ZR2010FM007)

通信作者: 曹凯, caokailiu@sdu.edu.cn 收稿/录用/修回: 2013-07-01/2013-12-12/2014-06-04

摘要

针对车辆机动行为识别建模中多目标时空依赖关系的不确定性难以表述和刻画的问题, 提出了基于多隐马尔可夫模型(M-HMM)的建模方法, 对多种因素影响下的道路交通微观态势的时空相关性进行建模, 识别和预测交通场景中车辆的机动行为. 为了实现对车辆的机动行为识别, 使用 Baum-Welch 算法和前向算法, 生成了模型训练和模型评价两类输入数据; 采用机动驾驶模拟方法, 建立车辆机动行为数据库, 提高了 HMM 的参数学习效率. 高速公路的超车实验结果表明, 在前方被观察车辆左轮压在车道线这一时刻, 车道变换机动预测正确率已达到 98.3%, 而此前的 0.4 s 内, 正确率约为 75%.

关键词

交通场景理解
隐马尔可夫模型(HMM)
机动行为识别
预测

中图分类号: U471.15, X913.3

文献标识码: A

Maneuver Behavior Identification and Prediction for Vehicles Based on Multi-hidden Markov Model

CAO Kai^{1,2}, YU Shanyi¹, YU Shaowei²

1. School of Traffic & Vehicle Engineering, Shandong University of Technology, Zibo 255049, China;

2. Shandong Yingcai University, Jinan 250104, China

Abstract

The uncertainty of multi-objective temporal dependencies is difficult to be expressed or described in the modeling for recognizing the maneuverability of vehicles. To solve this problem, we propose a modeling method based on the multi-hidden Markov model (M-HMM). We model the spatio-temporal dependencies of traffic micro-situations in the influence of many factors by the method to identify and forecast the maneuvering behavior of vehicles in the traffic scenes. We apply the Baum-Welch algorithm and the forward algorithm to generate two types of input data for model training and evaluation. We also build a database of vehicles' maneuvering behaviors using a driving simulation method to improve the learning efficiency of the parameters of HMM. The experimental results of overtaking on the expressway show that at the point of time when the left tires of a vehicle passing lane the markers. The model's prediction accuracy of lane change is 98.3%, and the accuracy during the 0.4 s before true lane change is about 75%.

Keywords

traffic scene understanding;
hidden Markov model
(HMM);
maneuver behavior identification;
prediction

1 引言

道路场景理解是车辆驾驶辅助系统(advanced driver assistance system, ADAS)的重要组成部分, 同时也是未来车辆自动驾驶的基础要求. 现实的交通环境是一个多交通参与者相互影响、动态变化的复杂系统. 在这个复杂系统中, ADAS 必须具备信息感知和解释其周边环境的能力, 尤其应当具备识别与预测交通参与者机动行为的能力, 才能保证和改善车辆驾驶的舒适性和安全性.

ADAS 的信息感知是基于原始感知数据对目标进行检测和追踪, 但是感知数据具有不确定性. 一般来说, 为了提高感知数据的可靠性, 需要对来自不同数据源的数据进行融合处理, 以便对道路环境中各目标的行为动态进行识别. 尽管在此方面已有大量研究, 但有关交通场景理解方法和技术仍面临大量挑战, 挑战之一就是交通场景中车辆机动的捕捉与识别, 通常需要处理多目标的时空依赖关系.

近年来, 国内外学者在交通场景中车辆机动的识别和

预测领域开展了大量相关研究. 尽管国内学者在此方面的研究起步较晚, 但还是取得了一些可喜的成果. 目前, 国内关于车辆机动识别的研究多集中于车辆机动状态识别和车辆机动意图识别上. 在车辆机动状态识别方面, 如文[1-3]在城市交通环境下采用线性跟驰理论和模糊逻辑方法, 分别建立了速度与车头时距对车辆换道机动的的影响模型、基于局部路径优化搜索的车辆车道变换模型和强制换道机动和自由换道机动两种元胞自动机模型; 此外, 从道路交通饱和和流状态和行为学角度分析入手, 文[4-6]分别建立了饱和和流条件下车辆换道机动仿真模型、车辆换道机动期望运行轨迹模型和换道机动过程中不同职业驾驶员视点转移特性模型. 在车辆机动意图识别方面, 如文[7-8]以操作动作(车速、加速踏板开度及加速踏板开度变化率)和驾驶员心理生理状态(反应时间、听力)为观察参数, 分别提出了识别车辆机动意图的多输入单输出模糊推理模型和具有贝叶斯辨识规则的危险驾驶机动模型; 为了在线辨识驾驶机动意图, 文[9]提出了双层隐马尔可夫模型(hidden Markov model, HMM)的建模方法, 下层 HMM 用于识别驾驶机动, 上层 HMM 用于识别驾驶意图, 并利用驾驶模拟器踏板、方向盘等输出数据对 HMM 进行离线训练, 提高了在线辨识效率; 基于动态贝叶斯网络(dynamic Bayesian network, DBN)和 HMM 理论, 文[10]以驾驶人手和脚的驾驶动作、车速及地理位置作为观测序列, 构建了直线路段和交叉口的车辆驾驶机动意图识别模型.

国外学者相关研究起步较早, 有代表性的方法可以分为两种: 逻辑表达方法和概率建模方法. 在逻辑表达方面, 通常使用常识性知识建立空间和时间模型. 常用的方法有: 命题逻辑^[11]、模态逻辑^[12]或描述逻辑^[13]等逻辑语言表述先验知识, 用以实现对交通状况的逻辑表达. 此外, 文[14]引入了一种概率逻辑的形式化方法, 该方法组合了概率论处理不确定性的能力和演绎逻辑开发结构的能力, 使其形式化表现更加丰富; 文[15]将马尔可夫逻辑用于建模和解释交通场景中的对象关系. 在概率建模方面, 文[16]选择了具有捕捉时-空依存关系能力的动态贝叶斯网络(DBN), 用条件概率表达因果关系, 提出了一种适用于不完整知识条件的时空推理模型, 用以解决机器人控制和决策支持中的相关问题. 与 DBN 相比, HMM 的主要优点是模型具有有效参数学习能力及推理能力. 如文[17]中建立的 HMM 模型试图采用从最简单的概念(离散马尔可夫链)到最复杂的模型(可变时间的连续密度模型)的方式来阐述 HMM 建模理论, 并阐明了该建模理论在语音识别中的应用过程. 此外, 有学者利用 HMM 变异模型, 如耦合 HMM 模型(coupled hidden Markov model, CHMM)和因子 HMM 模型(factorial hidden Markov model, FHMM)成功地对人类活动进行了建模^[18-19].

交通场景中车辆机动的不确定性建模是识别其行为意图的难点, 也是关键所在. 尽管国内外学者为此而付出了巨大的努力, 但建模实践证明, 单一模型在表述和刻画不确定性方面存在局限性. 因为车辆机动的本质特征是动态的、多目标的, 加之道路交通环境不确定变化的影响, 使

得目标之间存在不完整知识, 因此, 因果关系的建立、时间依存关系的表达等变得异常复杂, 单一模型是无法完整表示这种复杂关系的, 这也正是上述多数文献存在的问题. 尽管少数文献考虑到模型组合的优势, 但是参数学习时效性、多模型交互方式等是影响模型组合实时应用的关键因素.

为了克服以上存在的问题, 两项研究成果[20-21]值得关注. 其中, 研究成果[20]组合了支持向量机分类器与贝叶斯滤波的优势, 采用支持向量机对车辆的左车道变换、右车道变换和车道保持行为进行分类; 将多类概率输出作为贝叶斯滤波的输入, 提出了一种在线预测车道变换意图的方法. 该方法的优势在于通过核映射将低维空间的非线性分类问题转换为高维空间的线性分类问题, 并且由于支持向量机是一种最大间隔分类器, 因此对分属于不同类别换道行为轨迹具有较好的分类效果, 再通过贝叶斯滤波来估计车辆的行为, 可以减少系统的误报率和漏检率. 但是, 由于构造支持向量机的高效训练算法是目前广泛面临的难题, 因此, 该方法的训练速度是影响其实时性的一个重要因素. 另外, 该研究的预测框架中没有考虑与前方车辆的相对距离及相对速度, 而这些信息将会影响到驾驶员是否超越前方车辆的判断, 降低了模型对道路环境的适应能力.

此外, 研究成果^[21]提出了将车辆机动变化过程分解成“快照”序列的建模思想, 其中, 每一个“快照”描述在车辆机动状态变化过程中的一个具体状态. 这种分解不仅有利于对车辆动态的细致描述, 而且也有利于提高模型组合应用的计算效率. 但是, 该研究成果存在如下问题: (1) 一个确定模型的观察序列的概率 $P(O|\lambda)$ 并不是最佳决策的数量指标; (2) 将目标机动的长期变化与具体行为建立在一个双层模型框架中, 形成上下交错表达的耦合模型, 增加模型计算复杂度; (3) 在对具体机动行为建立 HMM 模型时, 通过给定的观察序列 O , 计算每个 HMM 模型 λ_i 的概率 $P(O|\lambda_i)$ 来执行机动行为识别, 这对于多个目标之间相互关联以及车辆机动空间的不确定性等构成的复杂交通环境并不适用.

本文借鉴了文[20-21]的有益建模思想, 特别是采用了分解车辆机动变化过程的理念, 同时针对文[20-21]存在的问题, 本文提出: (1) 为了提高对道路环境的适应能力, 建模时增加目标车辆的动态信息量(车辆之间的相对位置、速度和加速度信息); (2) 以一个确定观测序列模型的概率 $P(\lambda|O)$ 作为最佳决策数量指标, 并为此提出一个可行的快速解法; (3) 通过计算每个机动 λ_i 的概率 $p(\lambda_i|O)$, 对车辆机动行为进行预测, 同时重新观察或确定新的目标车辆, 以便于重新计算 $p(\lambda_i|O)$ 或识别目标车辆, 从而可以避免研究成果[21]上下层交错表达增加模型耦合复杂度的问题, 提高计算效率; (4) 提出了一种非笛卡儿的道路联合坐标系(road-aligned coordinate system, RACA), 以便于获取更多的道路行驶信息.

2 HMM 基本模型

HMM 模型是时序数据概率建模最常用的方法, 它包

括一个双重随机过程,即马尔可夫链和状态与观察值之间的统计对应关系. HMM 可以用 5 个基本参数描述,其组成如图 1 所示,其中, N 为 HMM 模型的状态数目; T 为每个状态的不同观测值的数目; \mathbf{A} 为状态转移概率矩阵,它描述了 HMM 模型中各个状态之间的概率转移. 本文假设状态集合 $S = \{s_1, s_2, \dots, s_N\}$ 为模型的离散状态, HMM 中的一个马尔可夫链为 $Q = (q_1, q_2, \dots, q_T)$, 则 $t+1$ 时刻状态为 s_j 的概率为 $a_{ij} = P(q_{t+1} = s_j | q_t = s_i)$, 其中, a_{ij} 为矩阵 \mathbf{A} 中的元素; \mathbf{B} 为观察值输出概率矩阵, $b_i(o)$ 为 \mathbf{B} 中元素,处在状态 s_i 时观察 o 的概率为 $b_i(o) = p(o | s_i)$. 在实际观察中,观察分布是连续的,通常使用混合高斯(mixtures of Gaussian, MoG)模型进行参数化; $\boldsymbol{\pi}$ 为初始状态分布矩阵, $\boldsymbol{\pi} = [\pi_i]$, $\pi_i = P(q_1 = s_i)$ ($1 \leq i \leq N$) 表示在 t 时刻状态 s_i 的概率.




图 1 HMM 示意图

Fig.1 The schematic diagram for HMM

一个 HMM 的一般形式可简洁表示为 $\lambda = (\mathbf{A}, \mathbf{B}, \boldsymbol{\pi})$. 确定了参数 $N, M, \mathbf{A}, \mathbf{B}$ 和 $\boldsymbol{\pi}$ 后, HMM 就可以生成一个观察序列 $O = (o_1, o_2, \dots, o_T)$. 然而,利用 HMM 对道路交通微观态势进行识别建模时涉及两个问题:一个是与 HMM 有关的观察序列的概率求解,另一个是 HMM 参数学习. 以下将针对这两个问题阐述有效的解决办法.

2.1 HMM 的概率求解

首先,给定一个新的观察序列 $O = (o_1, o_2, \dots, o_T)$ 和对观察序列给予最佳解释的一组模型 $\{\lambda_1, \lambda_2, \dots, \lambda_k\}$. 当选定一个模型 λ_i 时,需要计算观察序列 O 的概率. 这种概率可以扩展为

$$p(O | \lambda_i) = \sum_{\text{all possible } Q} p(O, Q | \lambda_i) \quad (1)$$

由于 q_t 在每个时间步取 N 个可能值之一,因此,式(1)的求解需要进行 $O(N^T)$ 次操作. 实际上, $P(O | \lambda)$ 可以通过所谓前向算法(forward algorithm)的动态规划进行计算. 在前向算法中的每个时间步长,以状态 j 结尾的部分观察序列的概率可以递归地计算:

●初始化:

$$\alpha_1(i) = a_{1,i} b_i(o_1), i = 1, \dots, N \quad (2)$$

●递归:

$$\alpha_{t+1}(j) = \left(\sum_{i=1}^N \alpha_t(i) \cdot a_{ij} \right) b_j(o_{t+1}) \quad (3)$$

最后,通过式(4)可以计算出整个序列的概率:

$$p(O | \lambda) = \sum_{i=1}^N \alpha_T(i) \quad (4)$$

这样,该算法可以有效地计算出 $\alpha_t(i)$, 而且在每一个时间步长中,只需要 $O(N)$ 次操作即可. 因此,计算具有长度为 T 的观测总概率的复杂度为 $O(N \cdot T)$.

2.2 参数学习

给定一组观测序列 $\{O_{\text{training}}\}$, 需要调整模型 $\lambda = (\mathbf{A},$

$\mathbf{B}, \boldsymbol{\pi})$ 的参数,为此,求解如下优化问题:

$$\hat{\lambda} = \underset{\lambda}{\operatorname{argmax}} P(O_{\text{training}} | \lambda) \quad (5)$$

为了求解式(5),本文采用 Baum-Welch 迭代数值算法实现概率函数最大化,即对于每种微观态势的 HMM 模型 λ_i , 利用 Baum-Welch 算法学习模型的初始分布 $\boldsymbol{\pi}_i$ 、转移矩阵 \mathbf{A}_i 及由高斯混合建模得到的转移概率密度函数向量 \mathbf{B}_i . Baum-Welch 算法是由 HMM 模型的期望最大化算法推导出来的,因此可以使用迭代数值技术实现概率函数最大化. 由于 HMM 模型参数学习是一个具有多局部极大值的非凸问题,因此依据它的初始参数, Baum-Welch 算法可以收敛到一个最大值.

3 系统建模

为了体现交通场景中的目标机动性具有动态和不确定性,本文针对高速公路最常出现的跟驰、超车和并线的三种机动行为,通过获取每两个目标车辆之间的相对位置、速度和加速度信息,采用 HMM 建模技术进行系统机动行为识别和预测建模. 由于存在对连续变化的道路交通微观态势描述和刻画约束,目前较为有效的方法就是把车辆的机动行为分解成容易识别的随机事件序列,从而在机动变化中获得事件之间的转移概率. 为此,在建立“低解像度”模型即态势模型时,将道路交通最常出现的跟驰、超车和并线连续机动行为分解成 3 种独立的机动行为,采用 HMM 建模方法,分别建立描述和刻画不同机动行为的 HMM 模型. 为此,每一个机动行为就由一个独立 HMM 模型描述,这样交通场景中目标车辆机动性的动态和不确定性就可以由若干个独立机动行为模型并行地刻画并识别.

具体地说,对 3 种机动行为分别建立一个 HMM 模型,以便使模型的系统状态与机动行为的物理状态相对应,而且每一个模型设置 5 个状态. 于是,对于给定的观察序列 O , 通过前向计算每个 HMM 模型 λ_i 的概率 $P(O | \lambda_i)$ 来执行机动行为识别. 由于第 2 节中提到的混合高斯(MoG)观测模型对任意概率分布都具有良好的逼近能力,因此,利用这一模型表现连续观测. 然而,混合模型数目过高会导致模型参数急剧增加,影响计算的实时性,因此模型数目设置为 3.

这种方法对简单的交通环境具有很好的适用性,但对于车道数目不同的各类道路、多个目标之间相互关联及车辆机动空间的不确定性等构成的复杂交通环境却不适用. 此外,一个确定模型的观察序列的概率 $P(O | \lambda)$ 并不是最佳决策的数量指标,而最佳决策数量指标是一个确定观测序列模型的概率 $P(\lambda | O)$. 为此,本研究提出一个更可行的方法.

利用贝叶斯理论的基本方程,改写概率 $P(O | \lambda)$, 并假设一个不变的观测概率 $P(O)$, 于是:

$$P(\lambda_i | O) = \frac{P(O | \lambda_i) \cdot P(\lambda_i)}{P(O)} \propto P(O | \lambda_i) \cdot P(\lambda_i) \quad (6)$$

式(6)中的先验概率 $p(\lambda_i)$ 不仅对生成的概率有影响,而且取决于如下因素:(1) 机动行为的先验概率受制于道路

类型, 如高速公路比城市道路超车机动更频繁; (2) 驾驶员的驾驶风格; (3) 其它车辆的影响; (4) 道路表面信息, 如车道线、道路边界或对向车道等信息。

系统机动行为识别与预测如图 2 所示, 每当一个新的车辆进入感应区域时, 系统启动初始化程序, 同时确定观察车辆前方的目标车辆, 并获得感应车辆的实际参数, 然后计算每个机动 λ_i 的概率 $p(\lambda_i | O)$. 在对车辆机动行为进行预测的同时, 重新观察感应车辆的机动变化或确定前方新目标, 以便于重新计算每个机动 λ_i 的概率 $p(\lambda_i | O)$ 或识别目标. 因此, 通过确定:

$$\operatorname{argmax}_i P(\lambda_i | O) \quad (7)$$

来识别主导机动模型.

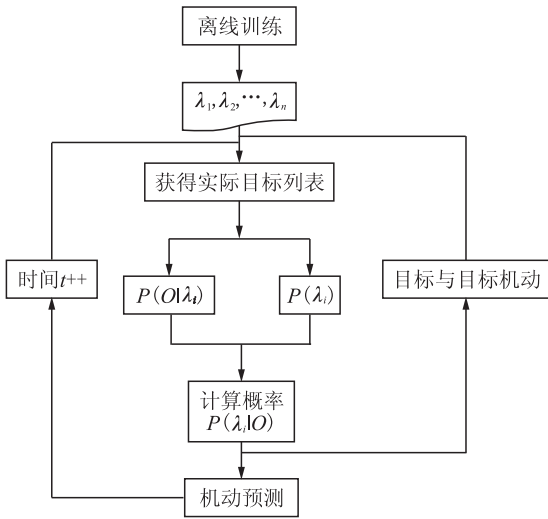


图 2 基于 HMM 模型的机动识别

Fig.2 Maneuver identification based on HMM model

4 模型检验

本节将描述以上构建的机动行为识别与预测模型的检验过程, 并给出基于真实数据的交通机动行为识别与预测结果.

4.1 系统设置

为了采集车辆机动行为数据, 实验车辆平台上安装了雷达和相机构成的多传感器组, 对前方车辆探测、分类与追踪, 传感器张角如图 3 所示设置.

由于相关研究广泛采用的是车辆或传感器固定坐标, 这种坐标建立方法只适用于直线道路. 为了获取更多的信息, 弯道行驶信息也必须加以考虑. 因此, 本研究建立一种非笛卡儿的道路联合坐标系统 (road-aligned coordinate system, RACA) (X, Y) , 即 x 坐标轴沿道路中心线, y 坐标轴与 x 坐标轴的切线正交, 相关参数如图 3 所示. 然而, 将传感器固定坐标 (sensor fixed coordinate system, SFCS) (X_s, Y_s) 转换成道路联合坐标 (X, Y) , 必须获得道路的几何信息, 为此本文参考文[23]的方法, 采用回旋曲线模型 (clothoid model). 该模型参数从传感器感知车道标志线和道路边界的信息中提取. 于是, 对目标车辆的观测向量可定义为

$$o = (\Delta_x, \Delta_y, \tilde{v}, \tilde{a}) \quad (8)$$

其中, 分量 Δ_x 与 Δ_y 表示目标车辆在 X 与 Y 方向 (道路联合坐标系) 的相对距离, 即 $\Delta_x = X_1 - X_2, \Delta_y = Y_1 - Y_2$; \tilde{v} 和 \tilde{a} 是目标车辆的相对速度和相对加速度的绝对值. 为了实现对目标车辆的机动行为识别, 需要生成 2 类输入数据: 一类是训练数据, 即使用 Baum-Welch 算法获得的模型参数估计数据; 另一类是测评数据, 即利用前向算法获得的机动行为识别数据.

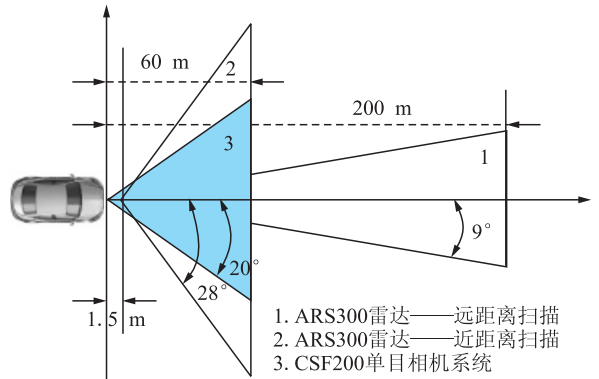


图 3 远、近距离扫描的传感器开角设置
Fig.3 Opening angles set-up of the sensor performing a far and a short range scan




图 4 道路联合坐标系统 (X, Y) 和车辆传感器固定坐标系 (X_s, Y_s)
Fig.4 RACA (X, Y) and SFCS (X_s, Y_s) of the vehicle

由于确定 HMM 模型的参数需要大量的训练数据, 而利用车载传感器进行实际数据采集耗费大量时间, 因此, 在模型训练阶段使用 CarSim 和 Matlab/Simulink 联合的车辆虚拟驾驶机动行为模拟. 通过对交通场景的参数化定义, 建立车辆驾驶机动行为数据库 (大约由 500 个机动行为数据构成). 为了评价被训练的模型, 执行对目标车辆机动行为的预测, 设置了如图 5 所示的测试方案. 在这个测试方案中, 为了评价模型的机动行为识别能力和展示车道变换预测效果, 总共记录了 60 个超车机动行为数据.

4.2 测试分析

数据采集完成后, 可以根据式 (8) 提取影响车辆之间的相对动态信息. 通过图 2 中所示的机动行为识别程序,




图5 采用实际数据的不同阶段超车机动模型评价截图

Fig.5 Screenshots of scenario setup for model evaluation with real data during different stages of the overtaking maneuver

对约 80 套完整的跟驰、超车及并线机动记录序列进行分类,从而实现机动行为识别. 由于前向算法的复杂度为 $O(N \cdot T)$, 因此运用该算法可以提高计算概率 $P(O|\lambda_i)$ 的效率. 然而, 算法中存在大量乘积计算, 计算前向变量的一个主要问题是下溢. 为此, 本研究使用文[23]提出的在每个时间步正规化前向变量的推算方法. 概率函数不再单调递减.

在高速公路上的实际交通情形中, 跟驰、超车和并线机动行为是时常发生的, 因此在高速公路测试场景中, 所有机动行为的先验概率事先设置好. 本文设定跟驰概率为 0.9, 超车概率等于并线概率为 0.05. 这意味着, 在先验概率中只考虑道路类型的依存关系. 实际测试过程中, 在目标车辆执行第一次车道变换时, 系统从所有机动记录序列中正确地检测到超车机动. 起初(如图 5 的第 1 阶段), 超车机动与跟驰机动之间的清晰差别是很难区分的, 有时甚至不可能实现, 这与现实交通场景中此时对机动行为判断的模糊性一致.

图 6 展现了图 5 所示的检测例证结果之一, 其中 3 条对数值曲线对应于 3 个 HMM 模型的概率 $P(\lambda_i|O)$. 曲线的起始位置对应图 5(a), 车辆 1 跟随车辆 2, 此时车辆 1 的跟驰机动概率略高于超车机动概率; 在第 250 帧, 车辆 1 离开第 1 车道开始超车(如图 5(b)), 跟驰机动概率开始降低(坐标原点开始的最上方曲线), 侧向机动概率突然增加(坐标原点开始的最下方曲线); 在第 520 帧, 车辆 1 离开第 2 车道(如图 5(c)) 开始并道, 侧向移动概率(坐标原点开始的最下方曲线)开始降低.




图6 3个不同模型的机动识别结果

Fig.6 Results of maneuver behaviour identification for three different models

4.3 车道变换预测

以下将针对车道变换这种单一驾驶机动行为进行预测测试, 即通过识别车辆 1 的超车机动来预测车辆 1 的车道变换机动. 为此, 有必要考察比率:

$$\beta = \frac{p(O|\tilde{f})}{p(O|\hat{o})} \quad (9)$$

其中, \tilde{f} 表示车辆跟驰, \hat{o} 表示车辆超车. 通过以上分析可知, 车辆相对速度 \tilde{v} 的增加将会导致 $p(O|\tilde{f})$ 快速降低, 发生车道变换的概率增高; 如果将 $\beta=1$ 设为临界比值, 那么当跟驰机动的概率低于超车机动的概率时, 可以预测被观察车辆的车道变换行为. 要降低错误检测率, 可以调整临界比率, 但目前尚无比率标准可以参照.

表1 超车机动识别的车道变换预测结果

Tab.1 Lane change prediction results based on overtaking manoeuvre recognition

变道前的时间 /s	预测正确率 /%	变道前的时间 /s	预测正确率 /%
2	6.7	0.8	55
1.8	10	0.6	65
1.6	18.3	0.4	76.7
1.4	28.3	0.2	85
1.2	33.3	0	98.3
1	40	-0.2	100

表 1 为以上采集的 60 个机动记录的车道变换预测结果, 即当车辆开始向左换道(车辆左轮通过车道线)时, 车辆在不同时间点车道变换的预测情况. 从表 1 可以得知, 在被观察车辆左轮压在车道线这一时刻, 车道变换机动预测正确率达到 98.3%, 而在 0.4 s 前, 正确率约为 75%.

4.4 模型评价

由于式(6)中的先验概率 $p(\lambda_i)$ 不仅对生成的概率有影响, 而且取决于驾驶员的驾驶风格, 因此, 为了评价本文提出的方法在车道变换时的稳定性, 采用两名不同驾驶风格的驾驶员(稳重型和冒险型)轮流驾驶测试该方法. 尽管驾驶员的驾驶风格不同(不同驾驶风格的驾驶员换道时与目标车辆之间的相对距离、速度和加速度会有不同), 使得模型(模型数目为 3, 每一个模型状态为 5)对超车机动的识别精度略有变化, 但整体变化不大, 参阅表 2.

表2 不同驾驶风格车道变换预测对比

Tab.2 Prediction comparison results of different styles for drivers' lane changing

换道前的时间 /s	稳重型预测正确率 /%	冒险型预测正确率 /%	换道前的时间 /s	稳重型预测正确率 /%	冒险型预测正确率 /%
2	4.7	2.3	0.8	51.3	50
1.8	8.4	5.2	0.6	59.8	57.7
1.6	17	14	0.4	77.7	76.5
1.4	29.2	27.7	0.2	85	84.2
1.2	31	32.8	0	98.3	95.9
1	39.1	38.3	-0.2	100	100

此外, 为了测试模型的实时性, 模型数目为 3, 每一个模型状态为 5、6 和 7 个进行比较. 由于确定 HMM 模型的参数需要大量的训练数据, 而利用车载传感器进行实际数

据采集需耗费大量时间, 为此, 在模型训练阶段使用 CarSim 和 Matlab/Simulink 联合的车辆虚拟驾驶机动行为模拟, 建立车辆驾驶机动行为数据库(大约由 500 个机动行为数据构成)。因此, 模型训练阶段是离线计算完成, 节省了大部分运算时间。模型测评阶段在 2.80GHz 奔腾处理器和 E6300CPU 计算平台上进行计算, 不同状态下的对比计算时间如表 3 所示。

表 3 不同数量状态的模型测评时间对比

Tab. 3 Evaluation time comparison of models with different number of states

模型状态数	5	6	7
模型测试时间 /s	0.23	3.64	8.20

5 结论

针对交通场景理解中车辆的机动行为识别和预测所面临的问题, 本文提出了真实交通场景车辆机动识别和预测的概率模型框架, 研究结论如下:

(1) 在建模过程中, 充分考虑到目标车辆的相对位置、相对速度和相对加速度对模型识别和预测的影响, 从而提高了模型对道路环境的估计精度。

(2) 修正了最佳决策数量指标, 给出了一种可行的解法。

(3) 通过计算每个机动 λ_i 的概率 $p(\lambda_i | O)$, 对车辆机动行为进行预测, 同时重新观察或确定新目标, 以便于重新计算 $p(\lambda_i | O)$ 或识别目标, 降低了模型计算的复杂度。

(4) 在模型训练阶段采用离线模拟的方法, 建立车辆驾驶机动行为数据库, 节省了模型运算时间。

(5) 拓宽了模型只适用于直线道路的假设, 提出了一种非笛卡儿的道路联合坐标系, 获取了更多的道路行驶信息。

在下一步工作中, 将对先验信息进行更为详细的划分建模。本文认为, 如果先验信息建模更为准确, 将会改善识别结果, 能够更好地处理更多不同的、更为复杂的场景, 同时也可以路径预测阶段使用识别阶段的结果。

参考文献

- [1] 魏丽英, 隽志才, 田春林. 驾驶员车道变换行为模拟分析[J]. 中国公路学报, 2001, 14(1): 77-80.
Wei L Y, Jun Z C, Tian C L. Simulation analysis of driver's lane changing behavior[J]. China Journal of Highway and Transport, 2001, 14(1): 77-80.
- [2] 韩珍. 驾驶员-车辆 Agent 微观换道行为的建模[D]. 北京: 中国科技大学, 2011.
Han Z. A microscopic lane-changing model for driver-vehicle agent[D]. Beijing: University of Science and Technology of China, 2011.
- [3] 曹珊. 城市道路车辆换道模型及换道影响研究[D]. 武汉: 华中科技大学, 2009.
Cao S. Study on the model and impact of lane-changing vehicles for city road[D]. Wuhan: Huazhong University of Science and Technology, 2009.
- [4] 杨小宝, 张宁, 黄留兵. 通行能力仿真中的换道模型研究[J]. 公路交通科技, 2007, 24(5): 109-113.
Yang X B, Zhang N, Huang L B. Study on lane changing model in the simulation of traffic capacity[J]. Highway Traffic Science and Technology, 2007, 24(5): 109-113.
- [5] 徐慧智, 裴玉龙, 于涛, 等. 驾驶员车道变换行为视点转移特性研究[J]. 哈尔滨理工大学学报, 2010, 15(5): 57-60.
Xu H Z, Pei Y L, Yu T, et al. The study on the eye's characteristics of lane-changing[J]. Journal of Harbin University of Science and Technology, 2010, 15(5): 57-60.
- [6] 裴玉龙, 张银. 车道变换期望运行轨迹仿真[J]. 交通与计算机, 2008, 26(4): 68-71.
Pei Y L, Zhang Y. Lane-changing virtual desire trajectory simulation[J]. Computer and Communications, 2008, 26(4): 68-71.
- [7] 王玉海, 宋健, 李兴坤. 驾驶员意图与行驶环境的统一识别及实时算法[J]. 机械工程学报, 2006, 42(4): 206-212.
Wang Y H, Song J, Li X K. Integrated inference of driver's intentions and driving environment and real-time algorithm[J]. Chinese Journal of Mechanical Engineering, 2006, 42(4): 206-212.
- [8] 郭夜政, 陈崇双, 王欣. 基于贝叶斯判别的驾驶行为危险状态辨识[J]. 西南交通大学学报, 2009, 44(5): 771-775.
Guo Z Z, Chen C S, Wang X. Risk identification for driving behaviors based on Bayesian discrimination[J]. Journal of Southwest Jiao Tong University, 2009, 44(5): 771-775.
- [9] 宗长富, 王畅, 何磊, 等. 基于双层隐式马尔可夫模型的驾驶意图辨识[J]. 汽车工程, 2011, 33(8): 701-706.
Zong C F, Wang C, He L, et al. Driving intention recognition based on double-layer HMM[J]. Automotive Engineering, 2011, 33(8): 701-706.
- [10] 张良力. 面向安全预警的机动车驾驶意图识别方法研究[D]. 武汉: 武汉理工大学, 2011.
Zhang L L. Research on motorist's intention recognition for traffic safety precaution[D]. Wuhan: Wuhan University of Technology, 2011.
- [11] Manna Z, Pnueli A. The temporal logic of reactive and concurrent systems[M]. 1st ed. New York, USA: Springer Science Business Media Press, 1992: 1171-1184.
- [12] Bennett B, Cohn A G, Wolter F, et al. Multi-dimensional modal logic as a framework for spatio-temporal reasoning[J]. Applied Intelligence, 2002, 17(3): 239-251.
- [13] Dams M, Komar M, Lueke S. Map based road boundary estimation[C]//Proceedings of the Intelligent Vehicles Symposium (IV). Piscataway, NJ, USA: IEEE, 2010: 609-614.

- [14] Richardson M, Domingos P. Markov logic networks[J]. *Machine Learning*, 2006, 62(1): 107–136.
- [15] Hensel I, Bachmann A, Hummel B, et al. Understanding object relations in traffic scenes[C]//*Proceedings of the Fifth International Conference on Computer Vision Theory and Applications (VISAPP)*. 2010: 389–395.
- [16] Dean T, Kanazawa K. A model for reasoning about persistence and causation[J]. *Computational Intelligence*, 1989, 5(2): 142–150.
- [17] Rabiner L R. A tutorial on hidden Markov models and selected applications in speech recognition[J]. *Proceedings of the IEEE*, 1989, 77(2): 257–286.
- [18] Brand M, Oliver N, Pentland A. Coupled hidden Markov models for complex action recognition[C]//*Proceedings of the Conference on Computer Vision and Pattern Recognition*. Piscataway, NJ, USA: IEEE, 1997: 994–999.
- [19] Landwehr N. Modeling interleaved hidden processes[C]//*Proceedings of the 25th International Conference on Machine Learning*. 2008: 520–527.
- [20] Kumar P, Perrollaz M, Lefèvre S, et al. Learning-based approach for online lane change intention prediction[C]//*Proceedings of the Intelligent Vehicles Symposium (IV)*. Piscataway, NJ, USA: IEEE, 2013: 797–802.
- [21] Meyer-Delius D, Plagemann C, Burgard W. Probabilistic situation recognition for vehicular traffic scenarios[C]//*Proceedings of the IEEE International Conference on Robotics and Automation*. Piscataway, NJ, USA: IEEE, 2009: 459–464.
- [22] Gerber R, Nagel H H. Representation of occurrences for road vehicle traffic[J]. *Artificial Intelligence*. 2008, 172(4/5): 351–391.
- [23] Luke S, Rieth P, Darms M. From brake assist to autonomous collision avoidance[C]//*Proceedings of the FISITA 2008 World Automotive Congress*. 2008: 553–562.

作者简介

曹 凯(1959–), 男, 博士, 副教授. 研究领域为智能交通控制, 复杂系统建模.
 于善义(1986–), 男, 硕士生. 研究领域为智能交通预测.
 于少伟(1986–), 男, 博士生. 研究领域为交通智能数据采集及挖掘.

(上接第 505 页)

- [11] 姜殿民, 郑鹏鹏. 导弹靶试数据弹道重建方法[J]. *四川兵工学报*, 2012, 33(7): 34–36.
 Zhang D M, Zheng K P. Reconstruction method of missile flight-test data[J]. *Journal of Sichuan Ordnance*, 2012, 33(7): 34–36.
- [12] 于雪梅, 程伟, 谷伟岩. 极大似然法在飞机起飞性能参数辨识中的应用[J]. *飞行力学*, 2012, 30(3): 201–205.
 Yu X M, Cheng W, Gu W Y. Application of maximum likelihood estimation to the parameter identification of airplane take-off performance [J]. *Flight Dynamics*, 2012, 30(3): 201–205.
- [13] Eurocontrol Experimental Centre. User manual for the base of aircraft data (BADA) REVISION 3.8 [R]. Bruxelles, Belgium: Eurocontrol, 2010: 1–83.
- [14] Hsu L Y, Chen T L. Vehicle dynamic prediction systems with on-line identification of vehicle parameters and road conditions[J]. *Sensors*, 2012, 12(11): 15778–15800.

作者简介

徐 琴(1988–), 女, 硕士生. 研究领域为新一代空中交通管制自动化系统等.
 汤新民(1979–), 男, 博士, 副教授. 研究领域为新一代空中交通管理系统, 先进场面引导与控制系统等.
 韩松臣(1968–), 男, 博士, 教授. 研究领域为新一代空中交通管理系统, 先进场面引导与控制系统, 空域与机场容量与安全性, 智能交通与新航行系统技术等.