

基于二次谱聚类 and HMM-RF 混合模型的车辆行为识别方法研究

范 菁^{1,2} 阮体洪¹ 吴佳敏¹ 董天阳^{1,2}

(浙江工业大学计算机科学与技术学院 杭州 310023)¹

(浙江省可视媒体智能处理技术研究重点实验室 杭州 310012)²

摘 要 从高速交通监控视频中提取的车辆轨迹数据可以用于分析和识别车辆行为。由于从高速监控视频中提取的车辆轨迹中只有少量的变道、超车等类型轨迹,采用经典的最长公共子串(LCSS)相似度和谱聚类算法无法有效地区分轨迹数据中所有类型的轨迹;此外,在车辆行为识别方面,常用的隐马尔科夫(HMM)轨迹模型忽略了负样本的影响,且仅用最大似然值进行分类,存在较高的误识别率。为了解决这些问题,分析和研究了高速监控视频中车辆轨迹数据的特点,提出了一种基于二次谱聚类和 HMM-RF 混合模型的车辆行为识别方法。该方法利用轨迹曲率来识别具有曲线轨迹特征的超车轨迹,利用倾角相似度和谱聚类算法来识别非曲线轨迹中的变道轨迹,并将得到的所有聚类簇用 LCSS 和谱聚类算法进行再聚类,从而有效地区分超车、变道以及直行轨迹等。在进行车辆行为识别时,该方法通过将不同 HMM 模型的多维概率输出作为随机森林 RF 模型的输入来识别多类型轨迹以替代最大似然值分类,提高了行为识别的正确率。为了验证方法的有效性,在不同数据集下进行实验,结果表明轨迹聚类的平均准确率为 96%,而行为识别的平均准确率是 89.3%,算法具有较高的准确率和鲁棒性。

关键词 轨迹聚类,车辆行为识别,二次谱聚类,HMM-RF 混合模型

中图分类号 TP391.4 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.5.055

Vehicle Behavior Recognition Method Based on Quadratic Spectral Clustering and HMM-RF Hybrid Model

FAN Jing^{1,2} RUAN Ti-hong¹ WU Jia-min¹ DONG Tian-yang^{1,2}

(College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China)¹

(Key Laboratory of Visual Media Intelligent Processing Technology of Zhejiang Province, Hangzhou 310012, China)²

Abstract The vehicle trajectory extracted from highway surveillance system can be used to analyze and recognize vehicle behavior. Due to a small amount of abnormal trajectory, such as change lanes and overtaking, the classic spectral clustering with longest common sub-sequence(LCSS) can't effectively distinguish all kinds of trajectory. In addition, the popular HMM trajectory model ignores the negative impact of the samples and only classifies them by maximum likelihood value to cause a higher rate of false recognition in vehicle behavior recognition. In order to address these issues, according to the characteristics of highway vehicle trajectory, we proposed a vehicle trajectory recognition method based on quadratic spectral clustering and HMM-RF hybrid model. Firstly, the trajectory curvature is calculated to distinguish overtaking by curved characteristics, and then lane changes trajectory is distinguished by spectral clustering with inclination similarity in non-curve trajectory. Secondly, all the sub-clusters are clustered by spectral clustering with LCSS again, which can effectively distinguish overtaking, changing lanes and normal trajectory. We made the output of HMM model, the different dimension of probabilities as an input for random forest model to improve the precision of behavior recognition. We did experiments under different data sets to verify the effectiveness of the method. The average accuracy rate of trajectory clustering can achieve 96%, and the average accuracy rate of behavior recognition can reach to 89.3%, so the algorithm has higher accuracy and robustness.

Keywords Trajectory clustering, Vehicle behavior recognition, Quadratic spectral clustering, HMM-RF hybrid model

1 引言

近年来,提取交通监控视频中的有用信息来分析交通行

为已成为研究人员关注的热点问题之一。交通行为的学习关键是学习运动车辆的行为模式,然后识别车辆行为,甚至对交通行为进行预测^[1]。例如,高速公路上的车辆一般都沿着固

到稿日期:2015-03-19 返修日期:2015-06-20 本文受浙江省重大科技专项重大工业项目(2013C01112)资助。

范菁(1969-),女,博士,教授,主要研究方向为虚拟现实和服务计算;阮体洪(1989-),男,硕士生,主要研究方向为视频图像处理;吴佳敏(1989-),女,硕士生,主要研究方向为视频图像处理;董天阳(1977-),男,博士,副教授,主要研究方向为计算机图形学和虚拟现实, E-mail: dty@zjut.edu.cn(通信作者)。

定的道路和指定的方向行驶,通过学习这些正常轨迹模型就可以自动检测出逆行、S形行驶等高速公路上的异常行驶行为。

为了给车辆行为识别提供训练样本,首先要利用车辆检测和跟踪算法从高速交通视频中提取车辆轨迹数据,并对车辆轨迹进行聚类。车辆轨迹聚类的一个重要问题就是如何衡量车辆轨迹间的相似度。车辆轨迹聚类的难点在于车辆轨迹的长度是不固定的,而大多数传统的聚类算法的操作数据都建立在固定的维度空间(数据长度是固定且一致的)^[2]。现有的方法通常直接考虑不同轨迹间的长度偏差,尝试找到不同轨迹间对应相似的部分,即 LCSS 轨迹相似度,对跟踪环节中的噪声或者异常值有一定的鲁棒性^[4];然后,在构建的 LCSS 轨迹相似度矩阵上用谱聚类算法进行车辆轨迹聚类。但从高速交通视频中提取的车辆轨迹存在少量的超车、变道等行驶轨迹,单单采用 LCSS 相似度和谱聚类算法会将这些少量轨迹错误地分类到直行轨迹中。因此,本文提出了一种二次谱聚类方法,其在轨迹数量较少的情况下也能对不同类型的轨迹进行有效的聚类。该方法首先计算轨迹曲率来区分具有曲线特征的超车轨迹(超车),接着对非曲线轨迹用倾角相似度和谱聚类算法来区分变道轨迹,最后对得到的所有聚类簇用 LCSS 和谱聚类算法进行再聚类。

完成车辆轨迹聚类之后,在行为识别过程中需要对每个聚类簇进行有效的推理建模和识别。目前车辆行为识别主要包括两类方法:基于轨迹的行为识别和基于主题模型的行为识别。基于轨迹的行为识别结果很大程度依赖于车辆跟踪的鲁棒性,而且轨迹聚类需要两两计算轨迹间的相似度,其计算过程比较耗费时间和内存。基于主题模型的行为识别不太需要特别精确的轨迹信息,但是主要用于描述全景行为,不适用于车辆行为的实时判断。

针对车辆行为的实时检测问题,各国的研究人员一般采用基于轨迹的车辆行为识别方法。如 Morris 等人^[3,5,6]提出了基于轨迹学习的动态场景分析的框架,采用动态的隐马尔可夫模型(Activity HMM)对轨迹建模识别。Hu 等^[7]利用基于 3-D 模型的车辆跟踪来预测交通事件,将等长的轨迹样本用模糊自组织神经网络(FSONN)来学习运动模型,通过匹配每个部分的轨迹运动模式,预测发生交通事故的概率。Piciarelli 等^[8]提出在线轨迹聚类方法对车辆行为进行判断,轨迹聚类簇按树结构组织,新车辆轨迹能不断更新模型,不涉及车辆之间的相互关系。

HMM 车辆轨迹建模方法对车辆轨迹识别率较高,但是它只考虑本类型车辆轨迹的正样本的作用,而未考虑其他类型车辆轨迹负样本的影响,从而很大程度上限制了 HMM 车辆轨迹建模方法的分类能力,在多类别车辆轨迹识别上存在较大的局限性。随机森林(Random Forest, RF)模型^[9]在分类上能获得较高的识别率,但是无法充分利用车辆轨迹过程的动态状态信息,因而存在一定的限制。

因此,为了利用 HMM 方法较好的轨迹建模能力以及 RF 模型具有的较强分类能力,本文提出了一种基于二次谱聚类和 HMM-RF 混合模型的车辆行为识别方法来对车辆行为

进行识别,将不同 HMM 模型的多维概率输出作为 RF 模型的输入来识别多类型轨迹,提高了 HMM 的模型辨别能力,有效降低了错误率。

2 基于二次谱聚类的车辆轨迹自动分类

车辆轨迹通过车辆跟踪算法从交通视频中得到,而在车辆跟踪的过程中不可避免地伴随着跟踪丢失、误跟踪以及遮挡等问题,因此得到的车辆轨迹可能不完整,并且受到噪声的干扰。通过去掉这些不完整的车辆轨迹,降低了后续处理的计算量,同时相应地提高了对有效车辆轨迹的聚类和识别的精度。

在高速公路上,车辆一般按照固定的车道行驶,若在行驶的过程中发生临时变道或者超车,会造成轨迹与原始车道轨迹间有一段公共轨迹部分,同时轨迹的数量较少,且不集中。如果使用 LCSS 相似度来进行谱聚类,会导致变道的轨迹被归类到原始车道轨迹的聚类簇中,局部轨迹数据的误分类可能导致全局聚类效果失衡。

针对上述情况,本文提出二次谱聚类的方法来进行车辆轨迹聚类。首先,该方法采用最小二乘法拟合多项式来求解轨迹曲率,并计算轨迹中前 N 个最大曲率的均值作为该轨迹曲率。若其大于曲率阈值 T ,则为曲线簇;反之,则为非曲线簇。接着对曲线簇构建 LCSS 相似度矩阵,用谱聚类进行聚类,得到曲线簇最终结果;对非曲线簇用最小二乘法拟合轨迹倾角,构建轨迹倾角相似度矩阵,并用谱聚类进行第一次聚类,取得非曲线簇聚类中间结果,然后建立它的轨迹 LCSS 相似度矩阵,再用谱聚类对非曲线簇聚类中间结果进行第二次聚类,获得非曲线簇最终结果;最后整合两个聚类结果,确定最终聚类结果。二次谱聚类算法的过程如图 1 所示。

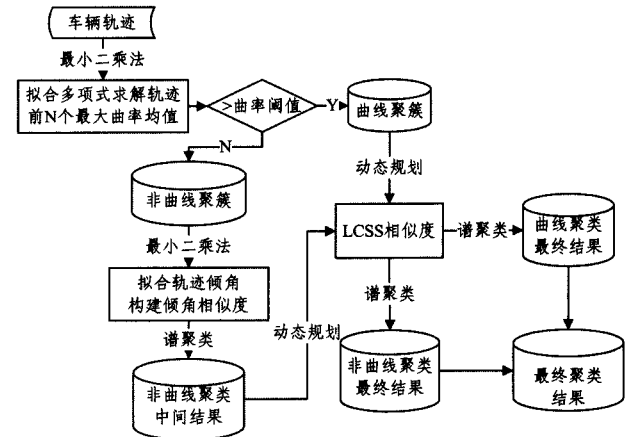


图 1 二次谱聚类算法流程图

轨迹倾角相似度的定义如下:

$$Similar_{\theta}(i, j) = 1 - \frac{|\theta_i - \theta_j|}{d_{\theta \max}}, 0 \leq i \leq n, 0 \leq j \leq n \quad (1)$$

其中, $\theta_i = \frac{\arcsin(-\frac{k}{\sqrt{1+k^2}}) \times 180^\circ}{\pi}$ 为第 i 条轨迹的倾角, $d_{\theta \max} = \max(|\theta_i - \theta_j|)$ 为最大的倾角差值, n 为轨迹数量。而

表 1 车辆轨迹聚类方法的比较

	Hausdorff 谱聚类	LCSS 谱聚类	二次谱聚类方法(两个阶段)	
1				
2				
3				
4				
5				

$k = \frac{l \times \sum_{m=0}^l T_m(x) \times T_m(y) - \sum_{m=0}^l T_m(x) \times \sum_{m=0}^l T_m(y)}{l \times \sum_{m=0}^l T_m(x)^2 - \sum_{m=0}^l T_m(x) \times \sum_{m=0}^l T_m(y)}$ 为轨迹的倾斜率,其中 $T_m(x)$ 、 $T_m(y)$ 表示第 m 个轨迹点的 x 、 y 轴坐标值, l 为轨迹长度。

由于采样频率和运动速度的不同,相同的轨迹行为采样得到的轨迹长度基本上是不一致的。比较轨迹间相似度,要能够处理不同长度的轨迹。LCSS 是对齐处理不等长数据的工具(不需匹配所有的点),且对噪声和异常值有一定的鲁棒性。

LCSS 轨迹相似度由 Vlachos 等提出^[1],定义如下:

$$D_{LCSS}(F_p, F_q) = 1 - \frac{LCSS(F_p, F_q)}{\min(T_p, T_q)} \quad (2)$$

其中, $LCSS(F_p, F_q)$ 描述轨迹 F_p 、 F_q 间的最长公共子串的长度, T_p 、 T_q 分别表示轨迹 F_p 、 F_q 的长度。LCSS 的递归定义如下:

$$LCSS(F_p, F_q) = \begin{cases} 0, & T_p=0 \mid T_q=0 \\ 1+LCSS(F_p^{T_p-1}, F_q^{T_q-1}), & d_E(f_p, \tau_p, f_q, \tau_q) < \epsilon \\ \max(LCSS(F_p^{T_p-1}, F_q^{T_q}), LCSS(F_p^T, F_q^{T_q-1})), & \text{otherwise} \end{cases} \quad (3)$$

利用动态规划高效地计算 LCSS 相似度, ϵ 表示两点间欧氏距离的阈值, $F^t = \{f_1, \dots, f_t\}$ 代表 t 时刻的所有样本点。

根据轨迹相似度度量方法,计算两两轨迹间的相似度,进而构成的轨迹相似度矩阵 S 是全联通图的邻接矩阵: $S = \{s_{xy}\}, 1 \leq x, y \leq n, n$ 为轨迹数量,即矩阵大小。谱聚类算法^[10]根据轨迹相似度矩阵计算特征向量以找出数据间的内在联系,将轨迹划分为不同的类簇。

3 车辆轨迹聚类结果分析

针对交通应用场景,本文采用 Hausdorff 距离^[11]和 LCSS 相似度来构建车辆轨迹的相似度矩阵,与谱聚类算法组合,然后在 5 个不同的实验数据集上进行车辆轨迹聚类,并将两种组合对车辆轨迹聚类的效果与本文方法提出的二次谱聚类方法的效果进行比较。

实验数据 1:采用固定摄像头采集的视频作为实验对象,视频的帧率为 25pfs,视频分辨率为 320 * 240,利用 Vibe 背景建模和团块跟踪算法得到轨迹数据,总共 43 条轨迹,共 3 类。

实验数据 2:在实验数据 1 的基础上增加新一类的从左到右的变道轨迹(3 条),共 4 类。

实验数据 3:在实验数据 2 的基础上增加新一类的从右到左的变道轨迹(3 条),共 5 类。

实验数据 4:在实验数据 3 的基础上增加新一类的小转弯超车轨迹(3 条),共 6 类。

实验数据 5:在实验数据 4 的基础上增加新一类的大转弯超车轨迹(3 条),共 7 类。

由表 1 可以看出, Hausdorff 谱聚类方法虽能将变道、超车等大致区分开来,但是会产生过多错误的聚类簇;在变道和超车轨迹数量较少的情况下, LCSS 谱聚类组合方法会将变道轨迹与变道前的轨迹错划分为一类。因此,本文的二次谱聚类方法比其他方法组合更优,能够有效地将变道、超车、直行等轨迹区分开来。

为了更加准确地对比实验结果,将 LCSS 谱聚类组合方法与本文提出的二次谱聚类方法进行详细分析,并采用表 2 中的性能指标进行衡量;表 3 为分别在实验数据 1—5 上采用两种方法的实验结果。

表 2 性能指标

名称	说明
True Positive(TP)	正样本被分类成正样本
False Positive(FP)	负样本被分类成正样本
False Negative(FN)	正样本被分类成负样本
True Negative(TN)	负样本被分类成负样本
TPR(真正元比率)	TP/(TP+FN)
FPR(假正元比率)	FP/(FP+TN)
Precision(准确率)	TP/(TP+FP)
Recall(召回率)	TP/(TP+FN)
F-Measure(F 值)	(2 * Precision * Recall)/(Precision+Recall)
PWC(错误分类率)	FN+FP/(TP+FN+FP+TN)

表 3 在不同实验数据下不同聚类方法的性能分析

方法	TPR	FPR	Pre	Recall	F 值	PWC	
1	LCSS 谱聚类	0.930	0.030	0.874	0.930	0.899	0.026
	二次谱聚类	1.000	0.000	1.000	1.000	1.000	0.000
2	LCSS 谱聚类	0.870	0.138	0.758	0.870	0.809	0.070
	二次谱聚类	0.957	0.080	0.937	0.957	0.947	0.060
3	LCSS 谱聚类	0.816	0.201	0.666	0.816	0.734	0.103
	二次谱聚类	0.939	0.066	0.939	0.939	0.939	0.064
4	LCSS 谱聚类	0.769	0.209	0.596	0.769	0.670	0.116
	二次谱聚类	0.923	0.040	0.960	0.923	0.941	0.054
5	LCSS 谱聚类	0.727	0.244	0.530	0.727	0.613	0.140
	二次谱聚类	0.909	0.035	0.962	0.909	0.934	0.054

从表 3 中可以得出,随着聚类类别的增加, LCSS 谱聚类方法在处理存在少量变道、超车轨迹数据时的聚类准确率、F-Measure 值等性能明显下降,而本文提出的二次分类谱聚类方法依然表现出较好的性能。但在高速公路上变道轨迹的倾角有可能与直行轨迹相近的情况下,本文方法的聚类效果会变差,其甚至退化为与 LCSS 谱聚类算法一样,无法区分变道。

4 基于 HMM-RF 混合模型的车辆行为识别

进行车辆行为识别时,主要根据车辆轨迹的聚类结果进行分类识别。利用车辆的运动轨迹进行车辆行为识别时,首

先需要进行车辆轨迹聚类,将相似的车辆运动轨迹分作一类;然后,进行车辆轨迹特征提取和车辆轨迹建模,给同一类别中的车辆运动行为建立统一的行为模型;最后,利用行为模型,使用新车辆轨迹对车辆行为进行识别。为了简化车辆行为模型的训练和识别,本文采用线性插值的方式将轨迹重采样到统一的维度。

4.1 车辆轨迹特征的提取

车辆轨迹特征是车辆轨迹中最重要的信息,用于区分不同种类的车辆轨迹。在车辆轨迹识别中,特征的选择直接决定最终结果的好坏。有很多特征可以选择,如车辆轨迹的位置坐标、车辆轨迹点的速度等。因为相同车辆轨迹的速度可能不同,位置坐标变化范围很大,最合适的特征是车辆运行轨迹序列中相邻的轨迹点所形成的方向角,其具有较好的鲁棒性。

假设车辆轨迹序列上 t 时刻的坐标为 (x_t, y_t) , $t+1$ 时刻的坐标为 (x_{t+1}, y_{t+1}) , 则形成的方向角 $\theta = \arctan((y_{t+1} - y_t)/(x_{t+1} - x_t))$ 。对方向角在 16 个方向进行均衡量化编码,每 $\pi/8$ 量化到一个方向,如图 2(a)所示。

最后利用依次获得的所有方向角序列 $\theta_1, \theta_2, \dots, \theta_{n-1}$ 构成了轨迹的新特征值序列 $L_\theta = \{\theta_1, \theta_2, \dots, \theta_{n-1}\}$ 。图 2(b)中直行转弯轨迹的车辆轨迹特征表示为“3-3-3-3-3-3-3-3-3-3-2-2-2”,图 2(c)中的转弯直行的车辆轨迹特征值序列表示为“3-3-7-7-3-3-7-3-7-3-7-7-7-7-15-7”。




图 2

4.2 基于 HMM-RF 混合模型的车辆行为识别方法

隐马尔科夫模型 (Hidden Markov Model, HMM) 是一种基于参数描述,具有随机过程统计特性的概率模型^[12,13]。它是一种双重随机过程,由马尔可夫链和一般随机过程两部分组成。马尔可夫链用于描述状态的转移,一般随机过程用于描述状态与观察序列的关系。

HMM 模型尽管对车辆轨迹有很强的建模能力,但只考虑了车辆轨迹正训练样本的作用,而忽略了其他类型负样本的影响;而且若单纯计算车辆轨迹序列与车辆轨迹模型的最大似然值来确定轨迹类型,在识别精度上会存在较大的局限性。

为了解决这个问题,提高车辆轨迹模型分类的性能,同时随机森林模型是目前最优的分类算法,我们考虑结合随机森林模型的强分类,将计算最大似然值的多维概率输出作为随机森林模型的输入来识别车辆轨迹类型,以提高车辆轨迹模型分类的准确率。

随机森林 (Random Forest, RF) 分类算法是由 Leo Breiman^[9] 提出的,是用许多分类树以随机的方式建立一个森林,每棵树之间是没有关联的。每一个分类树使用引入样本的数据时,就让森林中的每一棵分类树分别判断,依据哪一类分类树被选择得最多,就预测这个样本为哪一类。

随机森林具有以下特点以满足车辆行为识别的要求:

a) 能够处理高维度数据,且无须做特征选择,较好地处理

了提取车辆轨迹特征维度较高的问题;

b) 训练速度较快,而且可用于两类或者多类分类问题,能够支持多类型车辆行为的识别;

c) 对异常值有较好的鲁棒性,可以克服车辆轨迹存在一定噪声的问题。

综合 HMM 模型良好的车辆轨迹建模能力和 RF 模型的强分类能力,提出了一种基于 HMM-RF 混合模型的车辆行为识别方法。该方法将 HMM 作为车辆轨迹模型的一部分和 RF 模型共同组成车辆轨迹模型,以 HMM 模型作为车辆轨迹模型的前缀,以此来对用于 RF 模型的多类车辆轨迹数据有区分性地特征变换,即用 HMM 的多维概率输出作为后级 RF 模型的输入矢量,最后由 RF 模型来判断所属车辆轨迹类型。首先,将聚类好的车辆轨迹数据重采样到统一长度 N ,接着对车辆轨迹按照方向角编码(0-15),提取车辆轨迹特征到 $N-1$ 维特征;这样,每条车辆轨迹样本经过 HMM 模型之后就变成了一个 $N-1$ 维的概率特征矢量,将此作为 RF 模型的输入矢量,进行二次分类识别。

图 3 所示为面向车辆轨迹的 HMM-RF 混合模型训练流程,具体过程如下:

(1) 利用聚类好的不同类轨迹数据,通过前向后向 (Baum-Welch) 算法来分别训练与目标轨迹对应的 HMM 模型。

(2) 轨迹经过训练得到的对应类型的 HMM 模型后,将原本计算最大似然值的多维概率输出作为 RF 模型的输入矢量进行模型训练。显然,属于此类 HMM 模型的轨迹经过该模型后的多维概率输出值较大,而不属于此类 HMM 模型的轨迹经过该模型后的多维概率输出值则较小,因此可以提高分类能力。




图 3 HMM-RF 混合模型训练流程

车辆轨迹混合模型识别流程如图 4 所示,具体过程如下:

(1) 新的车辆轨迹经过各个不同的 HMM 模型后,得到 N 个不同的多维概率输出矢量;

(2) 将 N 个多维概率矢量输入到随机森林模型中,比较所有树中预测概率,将预测概率总和最大的树确定为车辆轨迹类型。




图 4 HMM-RF 混合模型识别流程

5 车辆行为识别结果的分析与比较

为了验证本文提出的基于 HMM-RF 混合模型的车辆行为识别方法的有效性,设计并实现了车辆行为识别系统,如图 5 所示。该系统分为两个部分:

(1) 车辆轨迹模型离线训练。将历史采集的车辆轨迹数据进行预处理、轨迹车辆聚类、量化编码、车辆轨迹建模;

(2) 车辆行为类型识别。将交通视频作为输入,通过车辆检测和跟踪算法,采集车辆轨迹序列,并对轨迹进行预处理和量化编码后,进行车辆轨迹类型的识别。

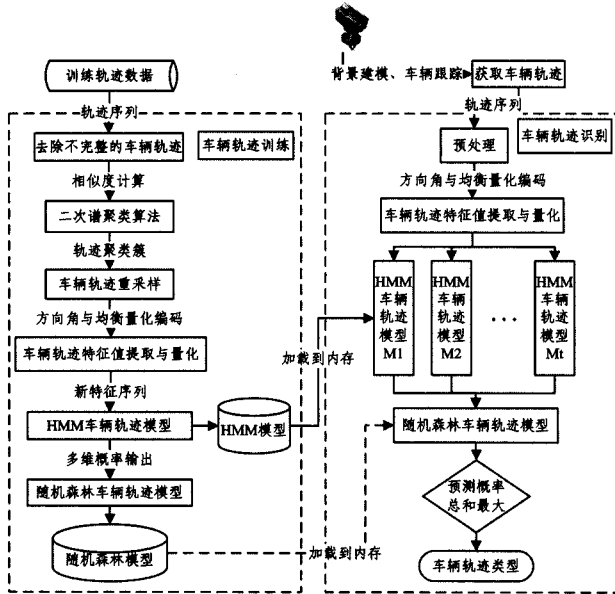


图 5 车辆轨迹识别系统框架

本文采用了表 4 所列的 3 个高速公路车辆行为识别数据集,分别对 HMM 模型^[11]、HMM-SVM(支持向量机)模型、HMM-RBFNetwork(径向基神经网络)模型以及本文提出的 HMM-RF 模型进行十折交叉验证实验,并引用 Activity HMM^[3]在 I5_All 数据集上的实验结果,分析和比较了 5 种方法在不同数据集上识别结果的准确率,如表 5 所列。

表 4 高速公路车辆行为识别数据集

数据集	说明	样本数量	类别数量
D_40	由聚类实验中的数据 1 聚类得到	40	3
I5_Part	从 CVRR 数据(http://cvrr.ucsd.edu/datasets)的 i5 数据集的每类选取 10 条	80	8
I5_All	CVRR 的 i5 数据集	806	8

表 5 高速公路场景下不同模型实验的准确率

Precision	3 classes			average
	D_40	I5_Part	I5_All	
HMM ^[11]	0.929	0.322	0.343	0.531
HMM-RF	0.952	0.729	0.998	0.893
HMM-SVM	0.444	0.439	0.295	0.393
HMM-RBFNetwork	0.736	0.555	0.822	0.704
Activity HMM ^[3]	—	—	0.950	—

从表 5 中的识别实验的准确率统计分析可以看出,在高速公路场景下,基于 HMM-RF 混合模型的车辆行为的准确率明显高于 HMM 模型、HMM-SVM 混合模型和 HMM-RBFNetwork 混合模型,且平均达到 89.3%;尤其在 I5_All 数据集上的准确率高达 99.8%,高于 Activity HMM^[3]中的 95%。

数据集的样本数量和类别数量呈不递减趋势(样本数量

和类别都增加)。分析图 6、图 7 的 F 值(F-Measure)和召回率(Recall)可以得出:随着样本数量和样本类别的增加,HMM-RF 混合模型的性能比其他 3 种方法好,特别是单 HMM 模型的性能下降最为明显。从不同数据集上的表现看出,HMM-RF 混合模型、HMM-RBFNetwork 模型都有较强的鲁棒性,但是 HMM-RF 混合模型的 F 值和召回率性能更好。




图 6 高速公路场景下不同模型的 F 值(F-Measure)




图 7 高速公路场景下不同模型的召回率(Recall)

本文将 HMM-RF 混合模型也用于表 6 所列的 CVRR 数据库中十字路口的 Cross 数据集,实验的准确率如表 7 所列,结果说明 HMM-RF 混合模型也适用于十字路口的车辆行为识别。其中 Cross_All 的识别准确率达到 94.4%,但低于 Activity HMM^[3]在 Cross 数据集上 96.8%的准确率,这是由于 Cross 数据集中有两类轨迹很相似,如图 8 所示,深色和浅色的原始轨迹邻近且方向相同,而本文对这两类轨迹进行特征值量化编码获得的轨迹特征序列几乎相同,导致准确率降低。Cross_Part2 是去除量化特征相同的一类的数据集,实验结果的准确率高达 99.8%。

表 6 十字路口车辆行为识别数据集

数据集	说明	样本数量	类别数量
Cross_Part	从 CVRR 数据库中的 cross 数据集中选取 8 类轨迹数据,每类选取 10 条	80	8
Cross_Part2	CVRR 的 cross 数据集(除去量化后特征相同的一类)	1800	18
Cross_All	CVRR 的 cross 数据集	1900	19

表 7 十字路口场景下不同模型实验的准确率

Precision	8 classes	18 classes	19 classes	average
	Cross_Part	Cross_Part2	Cross_All	
HMM ^[11]	0.825	0.702	0.641	0.733
HMM-RF	0.977	0.998	0.944	0.961
HMM-SVM	0.752	0.635	0.597	0.675
HMM-RBFNetwork	0.945	0.793	0.742	0.844
Activity HMM ^[3]	—	—	0.968	—



图 8 邻近同向轨迹

结束语 提出了一种基于二次谱聚类和 HMM-RF 混合

模型的车辆行为识别方法。该方法可以在高速公路监控视频中变道、超车等轨迹数据较少的情况下,通过采用二次谱聚类算法实现对变道、超车、直行等车辆轨迹的有效聚类;此外,该方法还可以将聚类得到的不同类型轨迹数据通过 Baum-Welch 算法来训练与目标轨迹对应的 HMM 模型,并将 HMM 模型的多维概率输出作为随机森林(RF)模型的训练样本输入进行分类识别。实验表明,该 HMM-RF 混合模型方法具有更高的准确率。虽然 HMM-RF 混合模型在一定情况下提高了准确率,但在未来研究工作中可以寻求和引入更多的车辆轨迹特征以进一步提高准确率。另外,谱聚类的计算复杂度为 $O(n^3)$,其中 n 是数据点的个数,其计算过程十分耗时,这限制了它在实际中的应用。我们在未来的研究工作中考虑将 MapReduce 和谱聚类算法结合,以加速谱聚类的计算过程。

参 考 文 献

- [1] Atev S, Miller G, Papanikolopoulos N P. Clustering of vehicle trajectories [J]. IEEE Transactions on Intelligent Transportation Systems, 2010, 11(3): 647-657
- [2] Morris B T, Trivedi M M. Understanding vehicular traffic behavior from video; a survey of unsupervised approaches [J]. Journal of Electronic Imaging, 2013, 22(4): 6931-6946
- [3] Morris B T, Trivedi M M. Trajectory learning for activity understanding; Unsupervised, multilevel, and long-term adaptive approach[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(11): 2287-2301
- [4] Morris B, Trivedi M. Learning trajectory patterns by clustering; Experimental studies and comparative evaluation [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2009 (CVPR 2009). IEEE, 2009; 312-319
- [5] Morris B, Trivedi M. An adaptive scene description for activity analysis in surveillance video [C] // 19th International Conference on Pattern Recognition, 2008 (ICPR 2008). IEEE, 2008; 1-4
- [6] Morris B T, Trivedi M M. Learning and classification of trajectories in dynamic scenes; A general framework for live video analysis [C] // IEEE Fifth International Conference on Advanced Video and Signal Based Surveillance, 2008 (AVSS'08). IEEE, 2008; 154-161
- [7] Hu W, Xiao X, Fu Z, et al. A system for learning statistical motion patterns [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(9): 1450-1464
- [8] Piciarelli C, Micheloni C, Foresti G L. Trajectory-based anomalous event detection [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2008, 18(11): 1544-1554
- [9] Breiman L. Random forests [J]. Machine Learning, 2001, 45(1): 5-32
- [10] Zelnik-Manor L, Perona P. Self-tuning spectral clustering [C] // Advances in Neural Information Processing Systems, 2004; 1601-1608
- [11] Chen J, Wang R, Liu L, et al. Clustering of trajectories based on Hausdorff distance [C] // 2011 International Conference on Electronics, Communications and Control (ICECC). IEEE, 2011; 1940-1944
- [12] Hervieu A, Bouthemy P, Le Cadre J P. A HMM-based method for recognizing dynamic video contents from trajectories [C] // IEEE International Conference on Image Processing, 2007 (ICIP 2007). IEEE, 2007, 4: 533-536
- [13] Wang Y, Yang C, Wu X, et al. Kinect based dynamic hand gesture recognition algorithm research [C] // 2012 4th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC). IEEE, 2012; 274-279
- [5] Lines J, Bagnall A, Caiger-Smith P, et al. Classification of house hold devices by electricity usage profiles [C] // Proceedings of the 12th International Conference on Intelligent Data Engineering and Automated Learning (IDEAL 2011). 2011; 403-412
- [6] Hartmann B, Link N. Gesture recognition with inertial sensors and optimized dtw prototypes [C] // Proceedings of IEEE International Conference on Systems Man and Cybernetics (SMC). 2010; 2102-2109
- [7] Mueen A, Keogh E, Young N. Logical-shapelets; an expressive primitive for time series classification [C] // Proceedings of the 17th International Conference on Knowledge Discovery and Data Mining. 2011; 1154-1162
- [8] Bakshi B R, Stephanopoulos G. Induction of real-time patterns from operating data for diagnosis and supervisory control [J]. Computers & Chemical Engineering, 1994, 18(4): 303-332
- [9] Jeng S L, Huang Y T. Time series classification based on spectral analysis [J]. Communications in Statistics-Simulation and Computation, 2007, 37(1): 132-142
- [10] Chen Y, Hu B, Keogh E, et al. DTW-D; time series semi-supervised learning from a single example [C] // Proceedings of the 19th International Conference on Knowledge Discovery and Data Mining. 2013; 383-391
- [11] Kalpakis K, Gada D, Andputtagunta V. Distance measures for effective clustering of ARIMA time series [C] // Proceedings of the IEEE International Conference on Data Mining. 2001; 273-280
- [12] Azzouzi M, Nabney I T. Analyzing time series structure with Hidden Markov Models [C] // Proceedings of the International Conference on Neural Networks and Signal Processing. 1998; 402-40
- [13] Ding H, Trajcevski G, Scheuermann P, et al. Querying and mining of time series data; experimental comparison of representations and distance measures [J]. Proceedings of the International Conference on Very Large Data Bases, 2008, 1(2): 1542-1552
- [14] Keogh E, Kasetty S. On the need for time series data mining benchmarks; a survey and empirical demonstration [J]. Data Mining and Knowledge Discovery, 2003, 7(4): 349-371
- [15] Buza K. Fusion methods for time series classification [D]. Germany; University of Hildesheim, 2011
- [16] Ye L, Keogh E. Time series shapelets; a new primitive for data mining [C] // Proceedings of the 15th International Conference on Knowledge Discovery and Data Mining. 2009; 947-956
- [17] Ye L, Keogh E. Time series shapelets; a novel technique that allows accurate, interpretable and fast classification [J]. Data Mining and Knowledge Discovery, 2011, 22(1/2): 149-182
- [18] Lin J, Keogh E J, Wei L, et al. Experiencing SAX; a novel symbolic representation of time series [J]. Data Mining Knowledge Discovery, 2007, 15(2): 107-144
- [19] Keogh E, Wei L, Xi X, et al. LB_Keogh supports exact indexing of shapes under rotation invariance with arbitrary representations and distance measures [C] // Proceedings of the 32nd International Conference on Very Large Data Bases. 2006; 882-893

(上接第 260 页)