

基于协方差流形和 LogitBoost 的异常驾驶行为识别方法

李此君^{1,2,3,4,5*}, 刘云鹏^{1,2,4,5}

¹中国科学院沈阳自动化研究所, 辽宁 沈阳 110016;

²中国科学院机器人与智能制造创新研究院, 辽宁 沈阳 110016;

³中国科学院大学, 北京 100049;

⁴中国科学院光电信息处理重点实验室, 辽宁 沈阳 110016;

⁵辽宁省图像理解与视觉计算重点实验室, 辽宁 沈阳 110016

摘要 驾驶员因素引发的交通事故比例居高不下,因此,研究基于驾驶员活动状态分析从而对异常驾驶行为进行正确识别分类的识别方法具有重要意义。提出一种基于协方差流形和基于二分类思想的多类 LogitBoost 分类器的异常驾驶行为识别方法。首先,提取图像的纹理、颜色和梯度方向等基础特征,以克服基于单一特征识别驾驶行为的不足;然后,利用协方差流形进行多特征融合,以消除特征冗余,同时降低由于不同特征数值差异过大而可能给图像处理及识别带来的影响;最后,使用基于二分类的多类 LogitBoost 分类器进行分类识别。实验结果表明,相对传统的直接使用 LogitBoost 的多分类方法,本文方法较大幅度地提高了多分类的正确率,针对不同目标的正确识别率可达 81.08%。

关键词 机器视觉; 异常驾驶行为识别; 协方差描述子; 黎曼流形

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/LOP55.111503

Abnormal Driving Behavior Detection Based on Covariance Manifold and LogitBoost

Li Cijun^{1,2,3,4,5*}, Liu Yunpeng^{1,2,4,5}

¹Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang, Liaoning 110016, China;

²Institute for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang, Liaoning 110016, China;

³University of Chinese Academy of Sciences, Beijing 100049, China;

⁴Key Laboratory of Opto-Electronic Information Processing, Chinese Academy of Sciences, Shenyang, Liaoning 110016, China;

⁵Key Laboratory of Image Understanding and Computer Vision, Liaoning Province, Shenyang, Liaoning 110016, China

Abstract The proportion of traffic accidents caused by driver factors is high, therefore, it is of great significance to study a recognition method for the correct identification of abnormal driving behavior by analyzing the driver activity state. We propose a recognition method of abnormal driving behavior based on the covariance manifold and two classification of multi-class LogitBoost classifier. First, we extract the basic features, such as texture, color and gradient direction, to overcome the shortage of recognition of driving behavior based on a single feature. Then, we use the covariance manifolds for the multi-feature fusion to eliminate the feature redundancy and reduce the impact of image processing and recognition due to excessive differences in numerical values of different features. Finally, the classification and identification are performed using a multi-class LogitBoost classifier based on two classification. The experimental results show that compared with the traditional multi-class LogitBoost method, the proposed method greatly improves the correct rate of multi-classification, and the correct recognition rate for different targets can reach 81.08%.

收稿日期: 2018-04-23; 修回日期: 2018-05-14; 录用日期: 2018-05-29

基金项目: 复合信息处理技术(Y6K4250401)

* E-mail: licijun@sia.cn

Key words machine vision; abnormal driving behavior recognition; covariance matrices; Riemannian manifolds

OCIS codes 150.1135; 100.2960; 100.5010

1 引言

研究表明,在车辆驾驶过程中,超过 87% 的道路交通事故是由驾驶员操作失误而造成的。深入了解发现,这部分交通事故原因中出现概率较高的是酒后驾驶、超速行驶、疲劳驾驶,以及急加速、急减速、急刹车和急转弯等不良操作^[1]。

关于异常驾驶行为识别的研究,按照获取驾驶行为数据的方式,总体上分为两大类:间接法和直接法。间接法的典型应用是在道路交通两侧或上方设置固定检测器,对道路进行监控,获取各项所需参数,通过各参数的变化利用学习算法对异常驾驶行为进行检测;直接法主要是通过传感器或视频图像实时地获取驾驶员或驾驶车辆的数据,对于驾驶员驾驶行为或驾驶车辆的行驶状态进行检测分析。间接法不能精确识别异常驾驶行为的位置和类别,仅起到辅助检测的作用,随着硬件设备的革新和模式识别技术的发展,直接法的应用将逐渐占据主导地位。Bouttefroy 等^[2]通过分析实时获取的车辆数据,将聚类算法与马尔科夫随机场结合,经过视频数据集测试,对以醉酒驾驶为代表的异常驾驶行为具有良好识别效果。Kimachi 等^[3]通过分析车辆数据的图像序列,根据车辆行驶的空间特性,利用模糊理论进行异常驾驶行为识别。研究人员通过对实验视频图像数据进行分析,先后对胎的尺寸、车辆基本运动参数、车辆运行轨迹、车辆时空变化等进行特征分析,设计了具有多项车辆异常驾驶行为识别能力的检测算法,能对车辆异常加减速、异常转向、异常掉头、超载等进行识别,为直接法的发展做了很多前沿的尝试,提供了宝贵经验。随着全球定位系统(GPS)、通用分组无线服务技术(GPRS)实时定位技术日新月异的发展,通过车辆及手机 GPS 数据直接监视车辆行驶状况来评价驾驶员驾驶状态的研究成果也越来越多。Eren 等^[7]通过调用智能终端的定位参数,结合加速度计及陀螺仪等硬件参数来评估驾驶行为。Mohamad 等^[8]通过调用车载 GPS 的定位参数,结合车辆传感器等的硬件参数进行研究,实现对车辆异常加减速和异常变道的检测。Castignani 等^[9]通过调用智能终端的定位数据实现对车辆加减速状态的评估。Amin 等^[10]通过调用定位参数,结合加速度计的硬件参数,成功克服了

GPS 数据可能产生的间断带来的影响。

利用计算机视觉相关技术对异常驾驶行为进行检测识别的方法是基于驾驶行为图像处理完成的,不需要和驾驶员产生任何接触,对于驾驶体验的烦恼最小,是当前异常驾驶行为识别检测方法中研究前景最好、实用价值最大的方法。近年来,国内外众多学者利用图像处理技术对驾驶员驾驶行为监控进行了研究,研究成果在现阶段更多地用于驾驶员面部识别^[11],如用于识别是否存在接打电话的异常驾驶行为等,并未关注驾驶员面部以外的自然状态,在驾驶员的异常驾驶行为识别上还存在一定的局限性。

使用图像处理和模式识别技术,研发一种通过分析驾驶员整体活动状态从而对异常驾驶行为进行正确识别分类的识别方法,对减少由于异常驾驶行为引发的交通事故具有积极意义。同时,该课题涉及的研究技术和算法也是图像处理、机器学习等热门课题的经典研究方向和方法。因此,该课题从方法上讲具有一定的理论意义,从工程上讲,也有很好的应用前景。有鉴于此,本文选取驾驶员的异常驾驶行为作为研究对象,旨在提出一套可以实现正确识别异常驾驶行为的图像识别技术,并开发出与之对应的检测系统。

本文提出一种新的基于协方差流形和 LogitBoost 二分类器的多类异常驾驶行为识别方法。首先,提取图像的纹理、颜色和梯度方向等基础特征,以克服基于单一特征识别驾驶行为的不足;然后,利用协方差流形描述图,并进行多特征融合;最后,使用基于二分类的多类 LogitBoost 分类器对异常驾驶行为进行训练、分类和识别。本文将从基础特征提取、特征融合、多类 LogitBoost 分类器、基于二分类的多分类思想,以及实验对比几个方面介绍本方法。

2 基础特征提取

由于图片所含信息较多,比较冗杂,如果仅使用某一种特征进行图像识别,对图像的表征不够全面,很有可能得不到最优的识别效果,而选取多种外观特征作为基础特征来表征图像有助于区别外观特征不同的物体,更好地描述图像。通过实验,最终选取以下 3 组特征作为从图像提取的基础特征来进行表征。

2.1 颜色特征

颜色特征是彩色图像最底层、最基础的外观特征。实验使用的图像是 RGB 颜色图像,它是一种三基色颜色模型,是目前使用最广泛的颜色表达形式。三基色包括红、绿、蓝三种颜色,将这三种颜色按照一定的比例混合可以得到任意所需彩色信息。然而,由于 RGB 颜色空间的三基色分量中均包含亮度信息^[12],易受到亮度的干扰,是一种不均匀的彩色空间模型,因此,在图像分析领域较少直接使用 RGB 模型。与其他彩色空间模型相比,HSV 彩色模型的自然性、紧凑性、一致性和完整性相对较好,更适宜作为驾驶行为图像的颜色特征,所以,首先将驾驶行为 RGB 彩色图像转换到 HSV 空间,并通过 H 、 S 、 V 分量进行颜色基础特征的提取。

2.2 纹理特征

纹理信息是物体表面固有的内在属性之一,无论获取到的原图像颜色或者亮度如何变化、是否有噪声,无论物体怎样旋转、平移、尺度缩放,其纹理信息不会受到任何影响。利用性能良好的 Gabor 滤波器^[13-14]提取驾驶行为图像的纹理特征。

一般情况下,二维(2D)Gabor 滤波器使用高斯函数 $g(x, y)$ 作为核函数:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right)\right], \quad (1)$$

式中 σ_x 表示沿 x 轴方向的尺度系数, σ_y 表示沿 y 轴方向的尺度系数。

对尺度进行缩放或旋转变换,可以计算获得一组 Gabor 小波。对原图 $I(x, y)$ 使用 Gabor 小波处理后,可以求得小波变换系数及其模的均值和方差。在本文中,通过 4 个方向,得到 4 维的 Gabor 纹理特征向量。

2.3 梯度特征

计算机在存储图像时,是通过数字图像的形式来进行的,相当于将图像模拟成二维离散的数字信号;因此,可以用差分方法代替连续信号中的微分来求解数字图像中的梯度特征。通过梯度信息可以得到图像显著变化的区域,一般地,图形梯度可以通过中值差分获得。

$$\begin{cases} G(x, y) = dx(i, j) + dy(i, j) \\ dx(i, j) = [I(i+1, j) - I(i-1, j)] / 2 \\ dy(i, j) = [I(i, j+1) - I(i, j-1)] / 2, \\ \phi(x, y) = \arctan \left| \frac{dy(i, j)}{dx(i, j)} \right| \end{cases} \quad (2)$$

式中 I 是图像像素的值(如 HSV 值), (i, j) 为像素

的坐标, ϕ 为方向角。

3 基于协方差流形的特征融合

通过前述方法得到的图像颜色特征、纹理特征和梯度特征之间存在一定的相关性,然而其所处的值空间具有较大差异。采用协方差流形对特征进行融合及降维可以有效地消除特征冗余,同时降低不同特征数值差异过大可能对图像表征带来的影响。协方差描述子可以较好地表征高维数据,对于旋转、平移、尺度缩放亦有较强的适应性,同时能有效应对光照变化所带来的影响。在计算协方差描述子时,通过使用快速积分图法求得图像协方差描述子,大幅度减少了原协方差描述子算法的计算复杂度,减少时间成本,对于图像表征及特征融合的实时性有非常积极的作用。

此外,由于细节是区分不同对象类的关键,因此将图像分割成若干个均匀间隔、重叠的矩形区域。对于每个矩形区域的协方差描述子通过黎曼流形进行特征融合。分类时,每个矩形区域对应的分类器都会投票给某一个类别,由大多数分类器投票决定最终的分类结果^[15]。

3.1 协方差描述子

图像的协方差描述子最初是于 2006 年由 Tuzel 等^[15]提出的一个定义,在目标分类、目标检测与目标跟踪方面展现出良好的可适用性^[16]。这里,图像的协方差描述子是一个能够表征出图像区域内每个不同特征之间关系的特征协方差矩阵^[17]。

若 I 为一幅大小为 $W \times H$ 的图像,那么从图像 I 中提取到的 $W \times H \times d$ 维的特征图像 F 可以表示为

$$F(x, y) = \Phi(I, x, y), \quad (3)$$

式中函数 Φ 可以为任意一种变换,包括灰度变换、获取坐标信息等。如图 1 所示,在 F 中选取任意的一个矩形区域用 R 来表示,则 R 内的协方差描述子 \mathbf{X}_R 可表示为

$$\mathbf{X}_R = \frac{1}{s-1} \sum_{i=1}^s (z_i - \boldsymbol{\mu}_R) (z_i - \boldsymbol{\mu}_R)^T, \quad (4)$$

式中 $\boldsymbol{\mu}_R$ 为 R 中特征向量的均值, $\{z_i\}_{i=1, \dots, s}$ 为 R 中 d 维所有特征点的集合, s 为 R 内所有特征点的个数。由(4)式可知,协方差描述子的大小取决于特征维数,与 R 的大小无关,因此对高维特征有降低维度的作用。这里得到的协方差描述子 \mathbf{X}_R 中对角线表示每个特征的方差,非对角线表示特征间的相关。

可以看出,通过协方差描述子对图像区域进行描述,具有如下优点:1)大小与区域的大小无关,能




图1 图像区域划分示例图

Fig. 1 Region division sample

起到特征降维的作用; 2) 对于旋转、平移、尺度缩放有较强的适应性; 3) 用于多特征融合时可消除特征冗余; 4) 对高维数据的表征具有良好的效果; 5) 能有效应对光照变化带来的影响, 抗干扰能力强, 不易受噪声影响^[18]。

3.2 基于黎曼流形的特征融合

Fletcher 等^[19]论证并指出, $d \times d$ 维的协方差描述子具有对称和半正定的特性, 具有这种特性的矩阵可以在 $d(d+1)/2$ 维的线性空间中形成一个内部是一个微分流形的凸锥, 此时就能够通过微分几何学对不能直接用于分类训练的协方差描述子进行操作和运算, 从而得到能够用于分类训练的向量。

黎曼流形属于微分流形中的一类^[19], 在黎曼流形 M 上任选一个点 X , 过点 X 能够做出无数个切向量, 这些切向量组成了点 X 对应的切空间 S_X , 黎曼流形与这个切空间 S_X 互为可逆映射^[20]。如图2所示, Penneec 等^[20]用指数和对数的互逆形式给出了一种切空间 S_X 与黎曼流形 M 之间的映射函数式。




图2 切空间的同胚映射

Fig. 2 Unified distribution mapping in tangent space

任取黎曼流形 M 上的点 X 及其所对应切空间上的点 y , 那么显然 X 、 y 之间存在唯一的最短曲线。将把 y 映射到在黎曼流形上从点 X 出发以最短曲线为距离到达的点 Y 定义为其指数映射, 可用下式表示:

$$Y = X^{1/2} \exp(X^{1/2} y X^{1/2}) X^{1/2}. \quad (5)$$

则可以求出这条最短曲线的长度为

$$d_{(X,Y)}^2 = \text{trace} [\ln(X^{-1/2} Y X^{1/2})]. \quad (6)$$

并可以推导出其对数映射:

$$y = X^{1/2} \ln(X^{1/2} Y X^{1/2}) X^{1/2}. \quad (7)$$

通过(7)式能够实现从黎曼流形 M 上的点与其切空间 S_X 上的点的对应转换过程, 也就是由矩阵得到其对应向量的一种映射方式。由图2可知, 通过 M 上的所有的点 X 均能够做出其对应的切空间 S_X , 此时, 对于一个黎曼流形需要在所有的切空间中选取一个统一的映射标准, 在这个映射标准下选取其对应的切空间 S_X , 最终能够由原协方差矩阵得到统一映射标准的可用于分类训练的特征向量。由这种对称、半正定矩阵对应的黎曼流形具有唯一的 Karcher 均值点 μ , 所以可以选取 μ 作为统一的点 X , 并通过该点 X 得到对应的切空间 S_X 。

通过(8)式能够得到某黎曼流形 M 对应的唯一 Karcher 均值点 μ :

$$\mu = \arg \min_{Y \in M} \sum_{i=1}^N d^2(X_i, Y), \quad (8)$$

式中 (X_1, X_2, \dots, X_n) 表示 M 上点的集合, 黎曼流形 M 上的两点 X 、 Y 之间距离用 $d(X_i, Y)$ 来表示, 该距离也可以被称为测地线。

由 μ 的推导公式可知, 其物理意义为在黎曼流形 M 上存在这样一个点, 使得 M 上所有的点到该点的测地线的平方和最小, 那么这个点即为所需寻找的 μ 。可以通过求解下式得到 μ :

$$\sum_{i=1}^N \log_Y(X_i) = 0. \quad (9)$$

使用梯度下降法对均值点 μ 进行求解, 同时, 需要对 μ 进行正交化处理, 以消除所得向量 μ 中每个分量与其他分量的关联。

至此, 已经将黎曼流形 M 上的点 X 利用对数映射得到其 Karcher 均值点对应的切空间 S_μ 上的正交向量。

总结来说, 为了描述和识别驾驶行为图像, 将驾驶行为图像划分为若干个矩形区域。第一步, 对所有矩形区域中的所有点进行基础特征提取, 其中包含二维的坐标信息、三维的 HSV 颜色信息、四维的

Gabor 滤波信息、三维的梯度及方向信息,共计 12 维与矩形区域大小相同的基础特征;第二步,求得所有矩形区域的特征协方差矩阵,该协方差矩阵大小为 12×12 ;第三步,求得每个协方差矩阵的切空间向量 y ,并通过梯度下降法求出其 Karcher 均值点 μ ;第四步,对所得向量进行正交化处理,得到每个矩形区域可以用来分类训练的特征向量,每个特征向量大小为 12×1 。

4 分类算法

4.1 多类 LogitBoost 分类器算法

采用 Boosting 算法中的 LogitBoost 算法对驾驶行为进行识别。Boosting 算法的基本思想是,在现有的样本分布下构建一个基础的弱分类器,每一轮循环使用样本集来训练这个弱分类器,每次循环后能够得到一个新的弱分类器,并在接下来的循环时赋予被错误分类的数据更大的权值,让新的弱分类器更注重被错误分类的数据,在反复多次之后,得到若干个弱分类器,最终的强分类器将由这些弱分类器通过不同的权值结合而成^[21]。

一般的 Boosting 算法存在过拟合问题,而 LogitBoost 算法采用负对数似然损失函数,能大大提高弱分类器的性能,同时减少过拟合情况的出现,并且有较好的稳健性;因此,使用多类 LogitBoost 分类器来实现对异常驾驶行为的分类。

4.2 基于二分类的多分类思想

1) 一对二的二分类思想。对于一个需要 n 分类的样本数据集,每两类间构建一个二分类的分类器 $F(n_a, n_b)$,这样的二分类器共可构建 $n(n-1)/2$ 个如表 1 所示。

表 1 一对二的二分类器

Table 1 One-against-one binary classifiers

Item	2	3	$n-1$	n
1	$F(1,2)$	$F(1,3)$	$F(1,n-1)$	$F(1,n)$
2		$F(2,3)$	$F(2,n-1)$	$F(2,n)$
$n-1$				$F(n-1,n)$
n				

对于一个待处理的数据,将其遍历这 $n(n-1)/2$ 个二分类器,含有其应从属类别的二分类器能够对其正确分类,不含有其应从属类别的二分类器则是随机投票,最终选取得票多的类别为其最终类别。

例如,对于一个需要 n 分类的样本数据集,若有一待分类处理的 M 类数据 D ,将 D 遍历这 $n(n-1)/2$ 个二分类器。对于 $F(M,1), F(M,2), \dots,$

$F(M,n)$ 这 $n-1$ 个分类器,可以将其正确分类,投票给 M ;对于其余的二分类器,由于无法正确分类,会等概率随机投票给其他类。最终 M 类得票最多,从而将数据 D 确定为 M 类。

2) 一对多的二分类思想。对于一个需要 n 分类的样本数据集,选取其中 $n-1$ 类作为一个整体,与剩余的一类间构建一个二分类的分类器 $F(n)$,这样的二分类器共可构建 n 个。如表 2 所示。

表 2 一对多的二分类器

Table 2 One-against-all binary classifiers

Item	1	2	\dots	$n-1$	n
Classifier	$F(1)$	$F(2)$	\dots	$F(n-1)$	$F(n)$

对于一个待处理数据,将其遍历这 n 个分类器,最终选取得票多的类别为其最终类别。

例如,对于一个需要 n 分类的样本数据集,若有一待分类处理的 M 类数据 D ,将 D 遍历这 n 个二分类器。对于二分类器 $F(M)$,可正确分类,使 M 类得到 1 票,其余类票数均为 0;对于其余的二分类器,由于作为整体的 $n-1$ 类中均含有 M 类,所以这 $n-1$ 类每次各得到 1 票。若所有二分类器均可正确分类,则最终 M 类票数为 n ,其余类票数为 $n-2$,从而将数据 D 确定为 M 类。

5 实验及结果分析

处理图像来自 Kaggle 的 State Farm Distracted Driver Detection 比赛用驾驶员行为数据集,共 102147 张,分为 10 类:2489 张训练数据、8726 张测试数据的 safe driving,2267 张训练数据、8353 张测试数据的 texting-right,2317 张训练数据、8293 张测试数据的 talking on the phone-right,2346 张训练数据、8264 张测试数据的 texting-left,2326 张训练数据、8344 张测试数据的 talking on the phone-left,2312 张训练数据、8435 张测试数据的 operating the radio,2325 张训练数据、8052 张测试数据的 drinking,2002 张训练数据、7261 张测试数据的 reaching behind,1911 张训练数据、6984 张测试数据的 hair and makeup,2129 张训练数据、7011 张测试数据的 talking to passenger。

5.1 算法参数

对图像进行基础特征提取对比实验,如图 3 所示。第 1 组提取了 HSV 和 Gabor 滤波信息,正确识别率为 58.26%;第 2 组提取了 RGB、梯度和角度信息,正确识别率为 64.74%;第 3 组提取了 HSV、Gabor 滤波、梯度、角度信息,正确识别率为 67.35%。




图3 基础特征选取对识别率的影响

Fig. 3 Effect of basic feature selection on recognition rate

由此可见,选取 HSV、Gabor 滤波、梯度、角度信息作为基础特征时识别分类的正确率更高。

在计算图像的协方差描述子时,由于矩形区域占整体图像的比例会影响最终对图像的识别分类效果,所以通过 5 组对比实验来比较不同矩形区域比例时的正确识别率。分别令划分的矩形占图片比例的 0.1、0.15、0.3、0.4、0.6,在其他条件相同的情况下结果如图 4 所示,正确识别率分别为 65.83%、67.35%、72.80%、

70.71%、64.27%。由此可见,当划分的矩形区域大小占图片比例为 0.3 时,识别分类的正确率更高。

对于 LogitBoost 分类器的回归树参数最小叶子结点,依次取值 0、25、50、100、150、200、400。如图 5 所示,在其他条件相同的情况下,正确识别率依次为 79.08%、79.19%、79.91%、80.53%、81.08%、80.45%、80.24%。由此可见,当 minleaf 取 150 左右时,识别分类的正确率更高。




图4 矩形框划分对识别率的影响

Fig. 4 Effect of region division on recognition rate




图5 回归树参数最小叶子结点对识别率的影响

Fig. 5 Effect of regression tree parameter minleaf on recognition rate

5.2 对比实验

针对复杂环境多类间存在干扰的多类分类数据集,对所提算法进行了多组实验。实验结果如表 3 所示。相对传统的直接使用 LogitBoost 多分类方法,基于 LogitBoost 二分类器的多类分类方法均较大幅度地提高了多分类的正确率,其中,基于一对一二分类器的方法消耗时间最多,正确率也最高,基于一对多二分类器的分类方法消耗时间较传统方法略长,但正确率也有显著提高。

针对该异常驾驶行为数据集,不同算法的正确识别率如表 4 所示。实验结果表明,相对传统的机器学习算法和直接使用 LogitBoost 多分类方法,该

表 3 传统 LogitBoost 分类器与基于遍历二分类器 LogitBoost 分类器的效果对比

Table 3 Performance comparison among traditional LogitBoost classifier and LogitBoost classifier based on binary classifiers

Method	Accuracy / %	Time consuming / h
LogitBoost	0.728	6.5
One-against-one binary	0.811	23.2
One-against-all binary	0.785	12.3

方法较大幅度地提高了多分类的正确率,是一种应用性较强的 LogitBoost 多类分类方法。

值得注意的是,在该数据集中,训练数据集与测

试数据集中的驾驶员完全不同。在数据集之间进行识别分类时,也就是使用本文方法在训练之后对不同目标进行识别,其正确识别率与支持向量机+人体边界框+主元分析法(SVC+Bbox+PCA)对比,如表4所示;在训练数据集或测试数据集内部进行交叉验证识别分类时,也就是使用本文方法在训练之后对相同目标进行识别,其正确识别率如表5所示。可以看出,本文方法对相同目标的正确识别率要远远高于对不同目标的正确识别率,但对该数据集进行检测时,无论是对不同目标还是对相同目标,本文方法的正确识别率均更高。

表4 不同方法的正确识别率

Table 4 Recognition accuracy of different methods

Method	Accuracy /%
SVC+Bbox+PCA	0.407
Proposed method	0.811

表5 不同方法对相同目标的正确识别率

Table 5 Recognition accuracy of different methods for the same targets

Method	Accuracy /%
SVC+Bbox+PCA	0.750
Proposed method	0.983

6 结 论

提出一种基于协方差流形和基于二分类的多类LogitBoost分类器的异常驾驶行为识别方法。该方法首先利用协方差描述子来描述图像各矩形区域,然后利用流形进行多特征融合,提取可用于分类识别的特征向量,最后利用基于二分类的多类LogitBoost分类器进行分类识别。相对传统的直接使用LogitBoost多分类方法,本文方法较大幅度地提高了多分类的正确率。本文方法针对相同目标检测时正确率非常高,但对不同目标进行检测时的正确率与其还有一定差距,如果能够继续提高本文方法对不同目标检测的正确识别率至对相同目标检测的识别率水平,那么本文方法就能够推广到实际应用中去。

参 考 文 献

- [1] Miyaji M, Danno M, Oguri K. Analysis of driver behavior based on traffic incidents for driver monitor systems[C]//IEEE Intelligent Vehicles Symposium, 2008: 930-935.
- [2] Bouttefroy P L, Beghdadi A, Bouzerdoum A, *et al.* Markov random fields for abnormal behavior

detection on highways [C] // European Workshop on Visual Information Processing, 2010: 149-154.

- [3] Kimachi M, Kanayama K, Teramoto K. Incident prediction by fuzzy image sequence analysis [C] // Vehicle Navigation and Information Systems Conference, 1994: 51-56.
- [4] Srivastava S, Delp E J. Standoff video analysis for the detection of security anomalies in vehicles [C] // IEEE Applied Imagery Pattern Recognition Workshop, 2010: 1-8.
- [5] Srivastava S, Ng K K, Delp E J. Co-ordinate mapping and analysis of vehicle trajectory for anomaly detection [C] // IEEE International Conference on Multimedia and Expo, 2011: 1-6.
- [6] Saruwatari K, Sakaue F, Sato J. Detection of abnormal driving using multiple view geometry in space-time [C] // IEEE Intelligent Vehicles Symposium, 2012: 1102-1107.
- [7] Eren H, Makinist S, Akin E, *et al.* Estimating driving behavior by a smartphone [C] // IEEE Intelligent Vehicles Symposium, 2012: 234-239.
- [8] Mohamad I, Ali M A M, Ismail M. Abnormal driving detection using real time global positioning system data [C] // Proceeding of the 2011 IEEE International Conference on Space Science and Communication (IconSpace), 2011: 1-6.
- [9] Castignani G, Derrmann T, Frank R, *et al.* Driver behavior profiling using smartphones: a low-cost platform for driver monitoring [J]. IEEE Intelligent Transportation Systems Magazine, 2015, 7(1): 91-102.
- [10] Amin M S, Reaz M B I, Nasir S S. Integrated vehicle accident detection and location system [J]. TELKOMNIKA (Telecommunication Computing Electronics and Control), 2014, 12(1): 73-78.
- [11] Zhu Z, Ji Q. Real time and non-intrusive driver fatigue monitoring [C] // 7th International IEEE Conference on Intelligent Transportation Systems, 2004: 657-662.
- [12] Huang H, Jin Y Y, Li Z Y, *et al.* Fluorescent microsphere segmentation and classification based on watershed and semi-supervised minor reconstruction error [J]. Chinese Journal of Lasers, 2018, 45(3): 0307013.
- 黄鸿, 金莹莹, 李政英, 等. 基于分水岭及半监督最小误差重构的荧光微球分割及分类方法 [J]. 中国激光, 2018, 45(3): 0307013.
- [13] Lin S, Xu T Y, Wang Y. Palm vein recognition

- based on Gabor wavelet and NBP algorithm [J]. *Laser & Optoelectronics Progress*, 2017, 54(5): 051002.
- 林森, 徐天扬, 王颖. 基于 Gabor 小波和 NBP 算法的手掌静脉识别 [J]. *激光与光电子学进展*, 2017, 54(5): 051002.
- [14] Ye Z, Bai L, Nian Y J. Hyperspectral image classification algorithm based on Gabor feature and locality-preserving dimensionality reduction[J]. *Acta Optica Sinica*, 2016, 36(10): 1028003.
- 叶珍, 白璘, 粘永健. 基于 Gabor 特征与局部保护降维的高光谱图像分类算法 [J]. *光学学报*, 2016, 36(10): 1028003.
- [15] Tuzel O, Porikli F, Meer P. Region covariance: a fast descriptor for detection and classification [C] // *European Conference on Computer Vision*, 2006: 589-600.
- [16] Qin L, Snoussi H, Abdallah F. Adaptive covariance matrix for object region representation [C] // *Fifth International Conference on Digital Image Processing (ICDIP 2013)*, 2013, 8878: 887848.
- [17] Hu X S, Li S E, Yang Y L. Advanced machine learning approach for lithium-ion battery state estimation in electric vehicles [J]. *IEEE Transactions on Transportation Electrification*, 2016, 2(2): 140-149.
- [18] Jayasumana S, Hartley R, Salzmann M, *et al.* Kernel methods on the Riemannian manifold of symmetric positive definite matrices [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2013: 73-80.
- [19] Fletcher P T, Joshi S. Riemannian geometry for the statistical analysis of diffusion tensor data [J]. *Signal Processing*, 2007, 87(2): 250-262.
- [20] Pennec X, Fillard P, Ayache N. A Riemannian framework for tensor computing [J]. *International Journal of Computer Vision*, 2006, 66(1): 41-66.
- [21] Williams D, Liao X, Xue Y, *et al.* Incomplete-data classification using logistic regression [C] // *Proceedings of the 22nd International Conference on Machine learning*, 2005: 972-979.