

文章编号: 2095-4980(2018)02-0323-07

基于协方差流形的异常驾驶行为识别方法

李此君^{1,2,3,4}, 刘云鹏^{1,2,3,4}

(1.中国科学院 沈阳自动化研究所, 辽宁 沈阳 110016; 2.中国科学院大学, 北京 100049; 3.中国科学院
光电信息处理重点实验室, 辽宁 沈阳 110016; 4.辽宁省图像理解与视觉计算重点实验室, 辽宁 沈阳 110016)

摘要: 研究一种高效的异常驾驶行为正确识别分类的识别方法, 对预防由于异常驾驶行为导致的交通事故具有重要意义。提出了一种新的基于协方差流形的异常驾驶行为识别方法。首先提取图像的纹理、颜色和梯度方向特征, 以克服基于单一特征识别驾驶行为的不足; 并利用协方差流形进行多特征融合, 以消除特征冗余以及不同特征数值悬殊对图像识别的影响; 最后使用多类 LogitBoost 分类器进行分类识别。针对相同检测目标的正确识别率可达 98% 以上, 对不同检测目标的正确识别率可达 70% 以上。实验结果表明该方法有效提高了驾驶行为识别的效果。

关键词: 异常驾驶行为识别; 协方差描述子; 黎曼流形; 多类 LogitBoost 分类器

中图分类号: TN911.73; TP751.1 **文献标志码:** A **doi:** 10.11805/TKYDA201802.0323

Abnormal driving behavior detection based on covariance manifold

LI Cijun^{1,2,3,4}, LIU Yunpeng^{1,2,3,4}

(1.Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang Liaoning 110016, China; 2.University of Chinese Academy of Sciences, Beijing 100049, China; 3.Key Laboratory of Opto-Electronic Information Processing, Chinese Academy of Sciences, Shenyang Liaoning 110016, China; 4.The Key Lab of Image Understanding and Computer Vision, Shenyang Liaoning 110016, China)

Abstract: Abnormal driving behavior recognition is to find a method to recognize abnormal driving behaviors correctly by analyzing the driver's activities using image processing and pattern recognition technology. This method is composed of a structure of covariance matrices of image features, which is able to extract information from data. The proposed classification framework consists in a new multi-class boosting method, working on the manifold $Sym+d$ of symmetric positive definite $d*d$ (covariance) matrices. The correct recognition rate for the same target can reach 98%, and above 70% for different targets. The result shows that this method effectively improves the accuracy of abnormal driving behavior recognition.

Keywords: abnormal driving behavior recognition; covariance matrices; Riemannian manifolds; LogitBoost

研究表明, 驾驶员人为因素引起的交通事故数占总数的 90% 以上, 其中高达 87% 是由机动车驾驶员的违规操作、经验不足、行为规范性差等原因造成的。因此在人—车—路组成的交通系统中, 驾驶员的异常驾驶行为是造成交通事故的最主要因素^[1]。

随着大规模集成电路和计算机技术的迅速发展, 计算机视觉和机器学习技术在提高汽车驾驶安全性中扮演着越来越重要的角色。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大量研究, 绝大部分研究主要集中在传统的驾驶行为识别方面, 通过对驾驶员的面部特征如注视方向、面部表情等特征进行分析, 但这仅仅是驾驶员驾驶行为的一小部分, 忽略了驾驶员身体其他部位的活动状态, 远不足以监控驾驶员的整体活动情况。因此, 运用图像处理和模式识别技术, 突破传统驾驶行为识别方法的局限, 研究一种高效的异常驾驶行为正确识别分类的识别方法, 对预防由于异常驾驶行为导致的交通事故具有重要意义, 在众多不同的特征中协方差特征已经被证明是强有力的描述子, 可用以提升分类性能^[2]。另一方面, 与该研究内容相关的关键技术和方法研究也是图像处理、模式识别等研究领域的重要研究内容, 因此在理论和实际应用方面都有着很好的研究前景。

本文分别从基础特征提取、特征融合、多类 LogitBoost 分类器及实验对比几方面来介绍本方法。

1 基础特征提取

由于图片信息比较复杂,单独采用物体外观特征或者纹理特征进行图像识别,很难得到令人满意的结果。因此利用外观特征包括颜色特征和纹理特征以及梯度特征,这些特征有助于区别外观特征不同的物体。通过实验,最终选取以下 3 组特征对图像进行基础特征的提取。

1) 颜色特征

颜色特征是彩色图最低层、最直观的外观特征,本次实验使用的图像是 RGB 颜色图像,因此直接采用 RGB 颜色空间。

2) 纹理特征

纹理反映了物体表面周期性重复出现、有规律可循的局部模式及其排列规则,是物体表面固有的内在属性之一。纹理是一种不依赖于图像颜色或亮度的表面特征,而且不受平移、尺度缩放、旋转以及噪声的影响。本文使用与人眼视觉系统相仿的、性能优越的 Gabor 滤波器^[3-4]提取纹理特征。

3) 梯度特征

通过梯度信息可以得到图像显著变化的区域。

2 基于协方差流形的特征融合

由于上述场景的颜色特征和纹理特征以及梯度特征处在不同的值空间,并且这些特征之间存在一定的相关性,因此为了消除特征冗余以及不同特征数值悬殊对场景识别的影响,采用协方差流形进行特征融合。协方差描述子不受平移、旋转、尺度缩放以及光照变化影响^[5]。此外,利用积分图像计算协方差描述子^[6],大大降低了计算复杂性,提高了计算速度,满足场景特征融合的实时性^[7]。

此外,由于细节是区分不同对象类的关键,因此将对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,每个分类器都投票给一个类,最后的分类结果是由大多数分类器投票选出的类。在实验中,选择矩形区域协方差描述子来进行特征融合^[6]。

2.1 协方差描述子的定义

2006 年, Tuzel^[6]等提出了协方差描述子概念,并成功用于物体分类、目标检测与跟踪^[3]。协方差描述子实质上就是一个特征协方差矩阵,用来描述图像区域内各个特征之间的关系(图 1)。



Fig.1 Region division sample

图 1 图像区域划分示例图

对于一帧大小为 $W \times H$ 的图像 I , 通过某种映射可以将其转化为一个 $W \times H \times d$ 维的特征图像 F :

$$F(x,y) = \phi(I,x,y) \quad (1)$$

式中 ϕ 是任意一种映射(变换),如颜色提取、梯度变换或者图像滤波等。假设 R 为特征图像 F 内的一个长方形区域, $\{z_i\}_{i=1,2,\dots,S}$ 表示 R 内的 d 维特征点集合, S 表示 R 中特征点的个数,那么,区域 R 可用公式(2)所示协方差矩阵表示:

$$X_R = \frac{1}{S-1} \sum_{i=1}^S (z_i - \mu_R)(z_i - \mu_R)^T \quad (2)$$

式中: μ_R 表示区域 R 内特征向量的均值; X_R 称为协方差描述子,是一个对称的、半正定矩阵,其对角线上元素是每类特征的方差,非对角线元素为两两特征间的相关系数。采用协方差描述子描述图像区域具有下列优点: 1) 协方差描述子用于多特征融合可以消除特征冗余; 2) 协方差描述子可以从多角度描述图像区域(如颜色、纹理、梯度等); 3) 协方差描述子维数与区域的大小无关,因此协方差描述子还能起到特征降维的作用; 4) 协方差描

述子具有平移、尺度缩放、旋转不变性, 而且不受光照变化影响; 5) 协方差描述子具有较强的抗干扰能力, 不受噪声影响。

但是协方差描述子是一个矩阵而不是特征向量, 因此不能直接用于交通场景识别^[6]。然而, 协方差描述子是一个对称的、半正定矩阵, Fletcher^[8]等已经证明, 这种维的对称、半正定矩阵的集合构成维线性空间中的一个凸锥, 凸锥的内部是一个微分流形, 因此可以利用微分几何学对协方差描述子进行分析和处理, 使之变为可用于分类与识别的向量形式^[9-10]。

2.2 基于黎曼流形的特征提取

黎曼流形是一种特殊的微分流形^[11], 通过黎曼流形上的每一点 X , 都可以作一个切空间 S_x , 该切空间是由通过该点的所有切向量构成的空间, 该切空间和黎曼流形是微分同胚^[12]。Pennec 等在文献[12]中给出了一种黎曼流形和切空间之间的同胚映射方式: 指数映射和对数映射, 如图 2 所示。

连接流形上 2 点的最短曲线称为测地线, 设 X, Y 分别为黎曼流形和切空间的点, 则 X, Y 之间存在唯一的测地线。

指数映射: 将 y 映射到从点 X 出发的测地线到达的点 Y , 定义如下:

$$Y = X^{\frac{1}{2}} \exp \left(X^{\frac{1}{2}} y X^{\frac{1}{2}} \right) X^{\frac{1}{2}} \quad (3)$$

这条测地线的长度定义为:

$$d_{(X,Y)}^2 = \text{trace} \left(\log^2 \left(X^{-\frac{1}{2}} Y X^{\frac{1}{2}} \right) \right) \quad (4)$$

对数映射:

$$y = X^{\frac{1}{2}} \log \left(X^{\frac{1}{2}} Y X^{\frac{1}{2}} \right) X^{\frac{1}{2}} \quad (5)$$

由式(5)可看到, 经过对数映射, 可以把黎曼流形 M 上的点转换到切空间 S_x 上的点, 即把一个矩阵变换为一个向量。

从图 2 可以看出, 黎曼流形 M 上每一个点 X 都可以作一个切空间 S_x , 因此, 黎曼流形 M 上的一簇点可以作数个不同的切空间。为了把协方差描述子矩阵转化为特征向量, 需要给所有的点建立统一的切空间以此作为映射空间。文献[5]已经证明, 由协方差描述子构建的黎曼流形, 其 Karcher 均值点是唯一的, 因此, 可以选择在 Karcher 均值点作一个切空间。

对于黎曼流形 M 上任意一簇点 (X_1, X_2, \dots, X_n) , 其 Karcher 均值点可以通过下式来确定:

$$\mu = \arg \min_{Y \in m} \sum_{i=1}^N d^2(X_i, Y) \quad (6)$$

式中 $d^2(X_i, Y)$ 为点 X, Y 之间距离(测地线长度)的平方。

从式(6)可看出, 黎曼流形 M 上一簇点的 Karcher 均值点就是该流形上到这些点距离的平方和最小的点。很容易证明, Karcher 均值点就是下列非线性方程的解:

$$\sum_{i=1}^N \log_Y(X_i) = 0 \quad (7)$$

可以利用梯度下降法来求解均值点 μ :

$$\mu^{t+1} = \exp_{\mu^t} \left[\frac{1}{N} \sum_{i=1}^N \log_{\mu^t}(X_i) \right] \quad (8)$$

当 $d(\mu^t, \mu^{t+1}) < \varepsilon$ 时, 循环终止。

通过上述对数映射, 可以把黎曼流形 M 上的点 X (矩阵)映射到均值点的切空间上的点(向量), 但是该向量并不是正交向量, 也就是说, 该向量各个分量之间存在相关性, 为此, 需要将向量正交化处理。

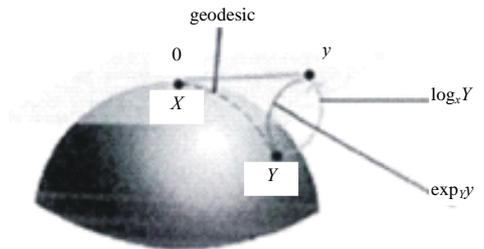


Fig.2 Unified distribution mapping in tangent space
图 2 切空间的同胚映射

根据式(8)把切空间中的向量正交化:

$$\text{vec}_\mu(y) = \text{vec}_1\left(\mu^{-\frac{1}{2}}y\mu^{\frac{1}{2}}\right)w_{1,1} \quad (9)$$

令 $\left(\mu^{-\frac{1}{2}}y\mu^{\frac{1}{2}}\right) = x$, 则:

$$\text{vec}_1(x) = [w_{1,1}, \sqrt{2}w_{1,2}, \dots, w_{2,2}, \sqrt{2}w_{2,3}, \dots, w_{n,n}] \quad (10)$$

通过以上变换, 将一个 $d \times d$ 的协方差描述子转化为一个 $d(d+1)/2$ 维的正交特征向量。由于该特征是正交向量, 因此各个特征分量之间是不相关的, 而且该特征维数与图像区域的大小无关, 利用该特征向量便可进行交通场景分割与识别。

总的来说, 为了分割和识别交通场景, 将交通场景图像划分为数个长方形区域。首先, 提取图像区域内每一个像素点的原始特征向量。其次, 根据式(2)计算出每个图像区域的特征协方差描述子; 然后, 分别利用式(3)、式(8)计算切空间向量 y , 以及 Karcher 均值点 μ ; 最后, 根据式(10)得到每个图像小区域的特征向量。

利用协方差描述子进行图像特征融合的步骤具体如下:

- 1) 提取图像区域内各个像素点的原始特征;
- 2) 求得各个图像区域小区域的协方差描述子 X_R ;
- 3) 计算对应的切空间向量 y ;
- 4) 利用梯度下降法求得对应的均值点 μ ;
- 5) 求得每个小区域正交特征向量 $\text{vec}_1(x) = [w_{1,1}, \sqrt{2}w_{1,2}, \dots, w_{2,2}, \sqrt{2}w_{2,3}, \dots, w_{n,n}]$ 。

3 多类 LogitBoost 分类器

本文采用 Boosting 算法对驾驶行为进行识别, 一般的 Boosting 算法, 存在过拟合问题, 而 Logitboost^[10,13] 算法能大大提高弱分类器的性能, 并具有很强的鲁棒性, 因此使用多类 LogitBoost 分类器来实现识别。其基本思想是: 采用负对数似然损失函数, 在一定的样本分布下利用样本数据集对“弱分类器”进行训练, 每一轮循环得到一个“弱分类器”, 并给予错分的样本一个较大的权值, 使得在下一轮训练中弱分类器更关注这些错分的样本, 经过多轮循环训练, 得到一组“弱分类器”, 最后把这组“弱分类器”加权组合成“强分类器”^[14]。

首先介绍多类分类器。

设 $s = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ 为训练样本集, 其中 x_i 为第 i 个训练样本的特征向量, $y_i \in [1, 2, \dots, J]$ 为第 i 个训练样本的类别, J 为类别数, 对于二分类情况, y_i 取值为 0 或 1; 对于多分类情况, 可以将其等效于 J 个二分类问题, 对于每一类采用一个二分类器来判断某个样本是否属于该类, 如果样本属于第 j 类, 则 $y_{ij} = 1$, 否则 $y_{ij} = 0$ 。设 J 个弱二分类器用线性回归模型 g_1, g_2, \dots, g_L 表示, 通过 LogitBoost 算法得到 J 个加权强分类器 F_1, F_2, \dots, F_J , 其中 $F_j = \{g_{1j}, g_{2j}, \dots, g_{Lj}\}$, 学习样本 x_i 属于第 j 类的概率 $Pr_j(X_i)$ 为:

$$Pr_j(X_i) = \frac{e^{F_j(x_i)}}{\sum_{k=1}^J e^{F_k(x_i)}} \quad (11)$$

其中:

$$F_j(x_i) = \sum_{l=1}^L f_{lj}(X_i) \quad (12)$$

式中 $\{f_{ij}\}_{i=1,2,\dots,L}$ 是一组连接 J 个弱分类器的函数, 按式(15)求得。相对于第 j 个弱分类器, 第 i 个样本 x_i 的权值 w_{ij} 为:

$$w_{ij} = Pr_j(X_i)(1 - Pr_j(X_i)) \quad (13)$$

回归目标值 z_{ij} 为:

$$z_{ij} = \frac{y'_{ij} - Pr_j(X_i)}{Pr_j(X_i)(1 - Pr_j(X_i))} \quad (14)$$

式中 $y'_{ij} = (j = y_i)$ 。

通过式(15)可以求得连接 J 个弱分类器的函数 f_{ij} :

$$f_{ij}(x_i) = \frac{J-1}{J} \left[g_{ij}(x_i) - \frac{1}{J} \sum_{k=1}^J g_{ik}(x_i) \right] \quad (15)$$

利用 LogitBoost 分类器将图像块进行分类以实现异常驾驶行为的识别。首先, 将图像分割为若干个图像块, 计算每个图像块的特征协方差描述子, 并计算其构造的黎曼流形上的均值点处切空间中正交化的特征向量, 构建样本集 $s = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, 其中 $y_i \in [1, 2, \dots, J]$ 为第 i 个训练样本的类别, 然后以 s 作为训练样本集, 利用 LogitBoost 算法对分类器进行训练, 下列算法描述了基于 LogitBoost 的分类器训练过程。

- 1) 输入学习样本集 $s = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$;
- 2) 初始化权值 $w_{ij} = \frac{1}{N}$, $Pr_j(x_i) = \frac{1}{J}$, $i = 1, 2, \dots, N$, $j = 1, 2, \dots, J$;
- 3) 构建分类器 F_1, F_2, \dots, F_J ;
 - for $l = 1, 2, \dots, L$ do
 - for $j = 1, 2, \dots, L$ do
 - ① 计算回归目标值和权重
 - ② 利用回归树使弱分类器 g_{ij} 拟合目标值为 z_{ij} 、权值为 w_{ij} 的样本 x_i
 - ③ 计算 $f_{ij}(x)$
 - ④ 按公式(12)更新 $F_j(x_i^k)$:
 - ⑤ 按公式(11)更新 $Pr_j(x_i^k)$, 保存 $F_j = \{g_{ij}\}$
 - end for
 - end
- 4) 保存 $\{F_1, F_2, \dots, F_J\}$, 若 $F_j(x) = \max_k \{F_k(x)\}$, 则 $y = j$, 即该图像块属于第 j 类。

4 实验测试

1) 实验数据

本次使用处理的图像来自 Kaggle 的 State Farm Distracted Driver Detection 比赛提供的驾驶员行为数据集。共 102 147 张, 分为 10 类: safe driving; texting-right; talking on the phone-right; texting-left; talking on the phone-left; operating the radio; drinking; reaching behind; hair and makeup; talking to passenger。

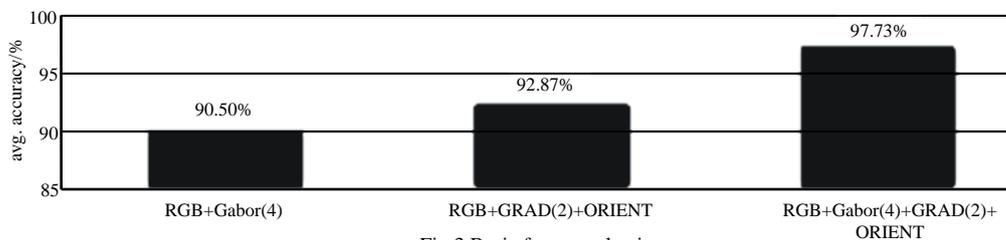


Fig.3 Basic feature selection
图 3 基础特征选取

2) 基础特征选取

在对图像进行基础特征提取的 3 组(图 3)对比试验中, 第 1 组提取了 RGB 和 Gabor 滤波信息, 正确识别率为 90.50%; 第 2 组提取了 RGB、梯度和角度信息, 正确识别率为 92.87%; 第 3 组提取了 RGB、Gabor 滤波、梯度、角度信息, 正确识别率为 97.73%, 由此可见选取 RGB、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。

3) 矩形区域尺寸确定

在计算图像的协方差描述子时，由于细节是区分不同对象类的关键，因此将对图像分割成若干个均匀间隔、重叠的矩形区域，而矩形区域的大小会影响图像的分类效果，为此，通过实验来确定最佳矩形区域大小。在 5 组对比实验中(图 4)，分别令划分的矩形占图片比例的 0.1,0.15,0.3,0.4,0.6。图 5 给出了图像正确识别率和矩形区域块大小的关系曲线，在其他条件相同的情况下，正确识别率分别为 82.62%,90.50%,98.51%,95.21%,90.03%，由此可见当划分的矩形区域大小占图片比例 0.3 左右时，识别分类的正确率更高。

4) LogitBoost 回归树参数

对于 LogitBoost 分类器的回归树参数最小叶子结点 minleaf，依次取值 0,25,50,100,150,200,400。如图 6 所示，在其他条件相同的情况下，正确识别率依次为 90.50%,91.61%,92.33%,92.95%,93.50%,92.87%,92.66%，由此可见，当 minleaf 取 150 左右时，识别分类的正确率更高。

5) 交叉验证

在对各项参数分析调整结束后，将数据集随机平均分为 5 份，每次选取其中 4 份作为训练数据集，另外一份作为测试数据集，进行五重交叉验证。结果如图 6 所示，正确识别率分别为 97.96%,96.89%,96.67%,98.73%,97.75%。

6) 对比实验(表 1~2)

本文对所提算法涉及的主要参数进行了测试，实验结果表明选取 RGB、Gabor 滤波、梯度、角度作为基础特征，划分图片矩形区域大小占图片比例 0.3 左右、多类 LogitBoost 分类器的回归树参数 minleaf 取 150 左右时的正确率更高。

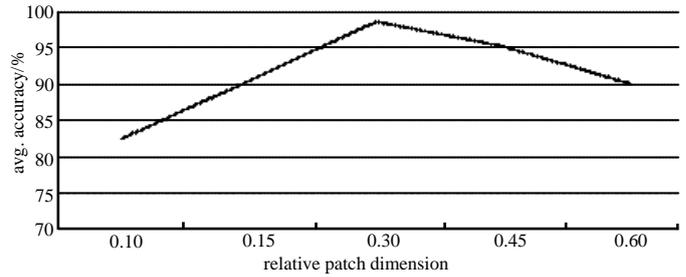


Fig.4 Region division
图 4 矩形框划分

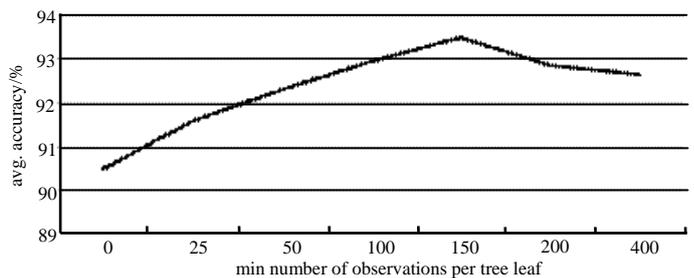


Fig.5 Regression tree parameter minleaf
图 5 回归树参数 minleaf

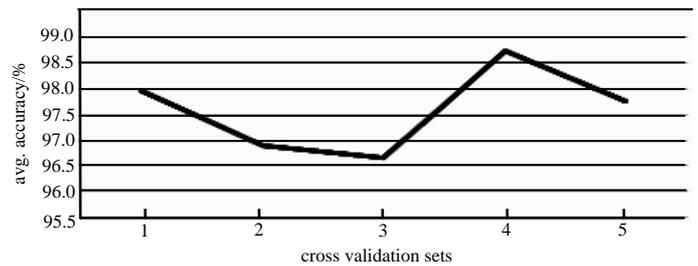


Fig.6 Result of cross validation
图 6 交叉验证结果

表 1 不同目标各方法识别正确率对比

method	accuracy
SVC+Bbox+PCA	0.407
scratched CNN	0.633
AlexNet	0.669
this method	0.728

表 2 相同目标各方法识别正确率对比

method	accuracy
SVC+Bbox+PCA	0.750
scratched CNN	0.883
AlexNet	0.927
this method	0.983

5 结论

本文提出了一种基于协方差流形的异常驾驶行为识别方法。该算法利用协方差描述子描述图像各个矩形区域进行特征融合，利用黎曼流形在 $d * d$ 维空间上提取协方差描述子的特征向量，最后利用多类 LogitBoost 分类器分类识别。通过实验结果可以看出，本文算法针对相同目标检测时正确率非常高，但对不同目标检测时距离理想正确率还有差距，今后将采用改进基础特征提取、调整分类器权重等方法进行改进。

参考文献:

[1] 黄思博. 基于计算机视觉的异常驾驶行为检测方法研究[D]. 广州:华南理工大学, 2011. (HUANG Sib0. Abnormal driving behavior analysis using computer vision[D]. Guangzhou,China:South China University of Technology, 2011.)

- [2] 谭论正,夏利民. 基于视觉的驾驶行为建模[D]. 长沙:中南大学, 2014. (TAN Lunzheng,XIA Limin. Vision-based driving behavior modeling[D]. Changsha,China:Central South University, 2014.)
- [3] AMIR R,LALITHA R. Medical image segmentation using linear combination of Gabor[J]. International Journal of Machine Intelligence, 2011(3940):212-216.
- [4] 陈力,王俊凯,张玉玺. 基于深度信息的人体运动识别方法[J]. 太赫兹科学与电子信息学报, 2016,14(3):443-448. (CHEN Li,WANG Junkai,ZHANG Yuxi. Human motion recognition method based on depth information[J]. Journal of Terahertz Science and Electronic Information Technology, 2016,14(3):443-448.)
- [5] 于黎明,王占林. 人机系统最优预见补偿跟踪控制研究[J]. 自动化学报, 2001,27(3):421-423.(YU Liming,WANG Zhanlin. Optimal preview compensative tracking control for pilot-vehicle systems[J]. Acta Automatica Sinica, 2001,27(3):421-423.)
- [6] TUZEL O,PORIKLI F,MEER P. Region covariance:a fast descriptor for detection and classification[C]// Proc. 9th European Conf. on Computer Vision. Graz,Austria:[s.n.], 2006(2):589-600.
- [7] FAULKNER H,SHEHU E,SZPAK ZL. A study of the region covariance descriptor: impact of feature selection and image transformations[C]// Digit.Image Comput.Techn.Appl.(DICTA). Australia:[s.n.], 2016:1-8.
- [8] TUZEL O,PORIKLI F,MEER P. Pedestrian detection via classification on Riemannian manifolds[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008,30(10):1713.
- [9] QIN L,SNOUSSI H,ABDALLAH F. Adaptive covariance matrix for object region representation[J]. Proc. SPIE, 2013,8878(4):48.
- [10] HU X,LI S,YANG Y. Advanced machine learning approach for lithium-ion battery state estimation in electric vehicles[J]. IEEE Transactions on Transportation Electrification, 2016,2(2):140-149.
- [11] JAYASUMANA S,HARTLEY R,SALZMANN M,et al. Kernel methods on the Riemannian manifold of symmetric positive definite matrices[C]// Conference on CVPR. [S.l.]:IEEE, 2013:73-80.
- [12] FLETCHER P T,JOSHI S. Riemannian geometry for the statistical analysis of diffusion tensor data[J]. Signal Processing, 2007,87(2):250-262.
- [13] WILLIAMS D,LIAO X,XUE Y,et al. Incomplete data classification using logistic regression[C]// 2005 Proceedings of the 22nd International Conference on Machine Learning(ICML). Bonn,Germany,ACM:2005:972-979.
- [14] TOSATO D,FARENZENA M,SPERA M,et al. Multi-class classification on Riemannian manifolds for video surveillance[C]// European Conference on Computer Vision(ECCV). Vision European:[s.n.], 2010:378-391.

作者简介:



李此君(1989-),男,沈阳市人,在读硕士研究生,主要研究方向为图像处理与目标识别,email:licijun@sia.cn.

刘云鹏(1980-),男,河南省汝南县人,研究员,主要研究方向为图像目标识别、跟踪.