

基于主动鉴别字典学习的自主导航偏离控制算法

成新田, 唐振民

(南京理工大学 计算机科学与工程学院, 南京 210094)

摘要: 针对传统道路偏离检测算法仅对结构化道路适用的缺陷, 提出一种基于主动鉴别字典学习的偏离控制算法用于非结构化道路的偏离检测与控制. 采用主动学习算法从未标记样本中学习得到主动鉴别字典, 根据其结构化重构误差判断车辆偏离方向, 并以此为依据控制车辆行驶方向; 定义有代价的加权错误率, 作为衡量算法纠偏能力的新准则. 实验结果表明, 所提出的算法对于结构化和非结构化道路偏离检测均有较强的有效性和可靠性.

关键词: 非结构化; 主动学习; 道路偏离; 稀疏表示

中图分类号: TP242.6

文献标志码: A

Lane departure control algorithms based on active discriminant dictionary learning for autonomous navigation

CHENG Xin-tian, TANG Zhen-min

(School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094, China. Correspondent: CHENG Xin-tian, E-mail: chengxintian0304@126.com)

Abstract: For the defect that traditional path deviation detection algorithms apply only to structured roads, a kind of deviation control algorithm for unstructured roads based on active discrimination dictionary learning is proposed. The active discrimination dictionary is obtained from unlabeled samples by using the active learning algorithm. According to its reconstruction error, the deviate direction of vehicles could be clear and as a basis for the next step direction control for vehicles. The definition of price weighted error is used to measure the correcting ability of the proposed algorithm. The experimental results show that the proposed algorithm has strong validity and reliability for structured and unstructured environments.

Keywords: unstructured; active learning; lane departure; sparse representation

0 引言

在复杂的户外环境中, 当自主导航车辆发生道路偏离时, 在视野中仅能检测到极少可通行区域. 因此, 如何准确检测车辆相对道路的偏离及其方向是智能机器人自主导航系统要解决的首要问题.

国内外常用的道路偏离检测方法大致可分为两类: 一类是基于车道线建模的方法^[1-3], 其中文献[1]采用 Hough 变换等方法找到边缘车道线, 再根据两车道线与车辆的夹角判断车辆偏离情况. 此类方法对于无明显车道线的非结构环境并不适用. 另一类是基于立体视觉和摄像机标定的方法^[4]. 此类方法对摄像机的标定有很强的依赖性, 而摄像机的标定很复杂, 且摄像机外部参数也具有不稳定性, 因此鲁棒性较差^[5-6].

本文从主动学习和稀疏表示的角度出发, 提出一种基于主动鉴别字典学习的自主导航偏离控制算法, 通过主动鉴别字典的学习和稀疏表示完成道路偏离的检测, 并以此为依据控制车辆下一步的驱动方向, 而无需提取车道线和标记摄像机的步骤. 该方法通过主动学习选择数量较少的具有鉴别能力的样本, 交由用户标记其偏离方向, 构成带有鉴别信息的结构化字典; 然后对每个测试图像进行稀疏编码, 根据其结构化重构误差判断道路的偏离情况, 从而控制智能车辆从偏离方向纠正到正常行驶方向. 在实车实验图像库上证明了该算法能够正确地检测智能车辆的道路偏离(左偏离, 右偏离, 无偏离), 并纠正其行驶方向, 且不受路况限制, 具有较强自适应性.

收稿日期: 2014-03-19; **修回日期:** 2014-06-03.

基金项目: 国家自然科学基金项目(91220301).

作者简介: 成新田(1985—), 女, 博士生, 从事计算机视觉、智能机器人系统的研究; 唐振民(1961—), 男, 教授, 博士生导师, 从事智能机器人与目标识别、图象处理与模式识别等研究.

1 主动鉴别字典

传统的字典学习通常需要大量的已标注样本,然而实际问题中已标注样本并不易获得. 主动学习以缩小目标空间为目的,能够主动选择有利分类的未标注样例,以降低高性能分类器的复杂度^[7]. 因此,本文提出主动鉴别字典算法通过主动学习从未标记样例集中选择最能代表训练集的少量样例,交由用户标注,构成该数据集的主动鉴别字典,记为 ADD.

因为子空间相同的样本是线性相关的,所以同类样本间有多种线性表达. 这里要选择的样本是表达能力最强的样本. 将未标记样本集 \mathbf{T} 作为自表达字典,系数 \mathbf{M} (即重构系数矩阵) 由以下优化问题求得:

$$\begin{aligned} \min & \|\mathbf{T} - \mathbf{TM}\|_{\text{F}}^2; \\ \text{s.t.} & \|\mathbf{M}\|_{1,q} \leq \tau, \mathbf{1}^{\text{T}}\mathbf{M} = \mathbf{1}^{\text{T}}. \end{aligned} \quad (1)$$

为了保证 \mathbf{M} 的稀疏性,即保证用来重构整个样本空间的样本数是稀疏的,加入正则项 $\|\mathbf{M}\|_{1,q} \leq \tau$,从而保证选出的待标注样例可重构整个样本空间. 此外,加入约束 $\mathbf{1}^{\text{T}}\mathbf{M} = \mathbf{1}^{\text{T}}$,使数据集 \mathbf{T} 具有仿射不变性.

引入重构误差 ε 后,式(1)可转化为

$$\begin{aligned} \min & \|\mathbf{M}\|_{1,q}; \\ \text{s.t.} & \|\mathbf{T} - \mathbf{TM}\|_{\text{F}} \leq \varepsilon, \mathbf{1}^{\text{T}}\mathbf{M} = \mathbf{1}^{\text{T}}. \end{aligned} \quad (2)$$

用拉格朗日乘子法可将式(2)转化为以下目标函数:

$$\begin{aligned} \min & \lambda \|\mathbf{M}\|_{1,q} + \frac{1}{2} \|\mathbf{T} - \mathbf{TM}\|_{\text{F}}^2; \\ \text{s.t.} & \mathbf{1}^{\text{T}}\mathbf{M} = \mathbf{1}^{\text{T}}. \end{aligned} \quad (3)$$

其中: $\lambda = \frac{1}{\alpha} \max \|t_i^{\text{T}} * \mathbf{T}\|$, $\alpha > 1$ 为尺度因子.

至此, \mathbf{T} 的重构系数矩阵 \mathbf{M} 求得. 进一步,由于矩阵 \mathbf{M} 体现了样本间的相关性,可根据矩阵 \mathbf{M} 选出重构整个样本空间的样本点. $\|m^l\|_q$ (m^l 表示 \mathbf{M} 的第 l 行, $l = 1, 2, \dots, n$) 的稀疏性对应第 l 个待标注样本 t_l 对于重构整个样本空间的贡献大小^[8],这里定义为

$$\Delta(l) = \frac{N \|m^l\|_{\infty} - \|m^l\|_1}{(N-1) \|m^l\|_1} \in [0, 1]. \quad (4)$$

设定阈值 θ , 当 $\Delta(l) < \theta$ 时, t_l 为待标注样本. 将所构建的主动鉴别字典记为 $\mathbf{S} = [(s_1, l_1), (s_2, l_2), \dots, (s_r, l_r)]$. 其中: s_i 为样本点, l_i ($i = 1, 2, \dots, r$) 为其标签.



图 1 当 $\alpha = 10$ 时, 所选择的待标注样例

当 $\alpha = 10$ 时, 所选样本集中共有 18 个样例, 其中包括 4 幅左偏离样例, 8 幅右偏离样例, 6 幅不偏离样例, 如图 1 所示.

2 基于主动鉴别字典学习的偏离控制算法

在野外非结构化环境下, 智能自主车辆无法凭借车道线识别车辆是否偏离道路, 因此基于车道线的偏离检测方法均不再适用. 受文献[9]的启发, 将结构化稀疏表示分类器 (SSRC)^[10-11] 引入道路偏离的检测, 以提高算法对复杂道路环境的适用性和鲁棒性.

考虑到字典 \mathbf{S} 包含每个原子的类别信息, 这里将同类的原子作为一个结构化的子字典 $s[i]$, $i = 1, 2, \dots, k$. 其中: $s[i]$ 为字典 \mathbf{S} 中标签为 i 的所有原子所构成的子字典, k 为类别数. 结构化稀疏表示的目标函数为^[12]

$$\begin{aligned} \min & \sum_{i=1}^k I(\|c[i]\|_q > 0); \\ \text{s.t.} & \mathbf{y} = \mathbf{S}'\mathbf{c}. \end{aligned} \quad (5)$$

其中: $I(\cdot)$ 为指示函数; $c[i]$ 为向量 \mathbf{c} 中子字典 $s[i]$ 对应的稀疏系数 $i = 1, 2, \dots, k$; 同时, 为了保证目标函数是凸的, 要求 $q \geq 1$. 由于优化问题(5)是 NP 难的, 将其松弛到如下 $L1$ 范数:

$$\begin{aligned} \min & \sum_{i=1}^k \|c[i]\|_q; \\ \text{s.t.} & \mathbf{y} = \mathbf{S}'\mathbf{c}. \end{aligned} \quad (6)$$

其解为 $\mathbf{c}^* = [c^*[1], c^*[2], \dots, c^*[k]]^{\text{T}}$. 分类准则函数为

$$\text{class}(\mathbf{y}) = \arg \min_i \|\mathbf{y} - s[i]c^*[i]\|_2. \quad (7)$$

基于主动鉴别字典学习的偏离控制算法的具体步骤如下.

Step 1: 设由图像序列所构成的数据集为 $\mathbf{U} = [u_1, u_2, \dots, u_N]$, 初始化 \mathbf{T} 为 \mathbf{U} . 根据目标函数(3), 求待标注样本相关矩阵 \mathbf{M} .

Step 2: 对于 \mathbf{M} 的每行求各个样本对重构样本空间的贡献 $\Delta(l)$, 根据阈值 θ (这里取 0.90) 选择可重构整个样本空间的子集 \mathbf{S} .

Step 3: 将样本集 \mathbf{S} 交由用户标注, 同时对 \mathbf{S} 进行 PCA 降维 (13 维), 再将其构成结构化主动鉴别字典 \mathbf{S}' .

Step 4: 对所有样本 \mathbf{U} 进行 PCA 降维为 \mathbf{U}' (13 维), 由 SSRC 算法得到所有样本在字典 \mathbf{S}' 上的稀疏表示系数 c_i , 并根据分类准则函数(4)对图像序列的每幅图像判断是否偏离及其偏离方向.

将上述算法用于行驶车辆的方向控制的流程图如图 2 所示. 根据当前图像在主动鉴别字典上的结构化重构误差, 确定其偏离情况. 当无偏离时, 正常前行;

当检测到偏离时, 首先停止前行, 再根据确定的偏离方向, 选择方向盘的旋转方向, 每次调整 15° , 再进行判断, 直到将车辆方向回正, 再继续前行。

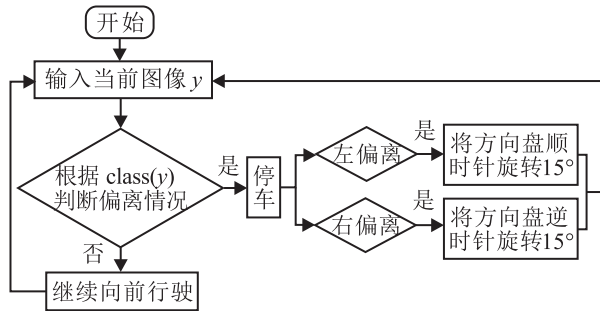


图2 车辆方向控制流程

3 实验及分析

3.1 数据集介绍

本文实验在 Microsoft Windows XP 系统下通过 Matlab 7.10 编程实现, CPU 主频 2.93 GHz, 内存 1.98 GB. 实验采用 NUST_Robot 数据库中 1031 号数据集, 均匀选取数据集中 111 幅分辨率为 352×288 的彩色图像序列, 包含 7 次道路偏离 (3 次左偏离, 4 次右偏离). 本文将该数据集标注为 3 种偏离状态 (左偏离、右偏离、不偏离), 分别为 24 幅、43 幅和 44 幅。

3.2 实验结果

为了证明主动鉴别字典的有效性, 在具有相同大小字典的前提下将所提出的主动鉴别字典学习算法、随机挑选字典学习算法和等间隔挑选字典学习算法分别与 4 种基于子空间学习的分类算法相结合进行分类结果的对比, 结果如图 3 所示. 其中: 将最近邻分类法记为 NN, 最近邻子空间分类法记为 NS, 基于 L_1 范数的 SSRC 算法记为 Q-Norm1, 基于 L_2 范数的 SSRC 算法记为 Q-Norm2. 由图 3 可见, 当主动鉴别字典算法与基于 L_1 范数的 SSRC 算法结合时性能最优, 将该偏离检测算法记为 ADD+Q-Norm1.

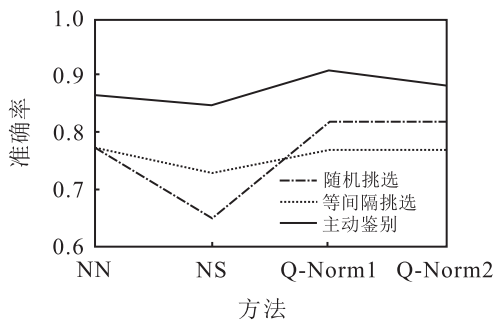


图3 不同训练样例选择方法的识别率比较

为了将所提出的算法与基于 Hough 变换^[1]的偏离检测方法进行比较, 将两种方法分别在结构化道路上进行偏离检测实验, 并对其检测准确率和实时性, 如表 1 所示. 由表 1 可知: 在总识别率上, 本文

算法具有较高的识别率, 达到 96.18%; 在运行效率上, Hough 变换法优于本文算法, 每帧图像的处理时间为 0.41 s. 其原因在于, 本文算法根据图像在每个子字典上的重构误差进行分类, 其迭代求解过程较复杂, 增加了运行时间. 实验表明, 本文算法在结构化和非结构化道路上均适用, 且其实时性可以满足实际需要, 但仍需对其算法代码进一步优化, 以提高算法的实时性。

表1 算法性能对比

方法	总识别率/%	平均时间/s
Hough 变换	94.26	0.41
ADD+Q-Norm1	96.18	0.73

3.3 评估参数对实验结果的影响

在构建主动鉴别字典时, 尺度因子 α 在一定程度上影响样本集的选择. 因此, 通过实验分析了 α 的取值与识别率的关系, 结果如图 4 所示. 由图 4 可以看出: 1) 当 $\alpha = 20$ 时, ADD 分别与 Q-Norm1 和 NN 分类法相结合均达到最高识别率; 2) 当 ADD 与 Q-Norm2 相结合时, 在 α 的所有取值中均为识别最高的方法; 3) 除采用 Q-Norm2 分类法时识别率随 α 取值波动较大外, 其他方法均波动较小. 由此可知, ADD 与 Q-Norm1 相结合对参数 α 的敏感度较低, 具有较强的适应能力, 同时这一特性增强了该控制算法的鲁棒性。




图4 识别率与 α 取值变化的关系

定义 1 若系统含有 k 个类别, 则该系统的混淆矩阵为 $E_{\text{confusion}} \in R^{k \times k}$, 其中 $E_{i,j}$ 表示第 j 类样本被识别为第 i 类的样例数。

由于在实际行驶过程中, 将类 1 或类 2 误分为类 3 (即 $E_{3,1}$ 和 $E_{3,2}$) 的后果远比将其他错分情况严重, 这里对 $E_{3,1}$ 和 $E_{3,2}$ 增加其代价权重, 定义 $P_{w\text{-err}}$ 以便对算法检测能力及其安全可靠描述更准确. 设 $E_{i,j}$ 的代价权重为 $w_{i,j}$, $P_{w\text{-err}}$ 可表达为

$$P_{w\text{-err}} = \frac{1}{N} \sum_{i=1}^k \sum_{j=1}^k w_{i,j} E_{i,j}. \quad (8)$$

当系统的错误代价有显著差别时, 可通过调整 W 来衡量算法的检测或识别性能. 若系统无显著错误代价的差别, 则令 $W = I$, 即为无代价权重的错误

率. 这里, 将 $w_{3,1}$ 和 $w_{3,2}$ 均设为 3, 其他仍为 1. 表 2 为当 $\alpha = 20$ 时, 对各个类别的识别正确率和代价加权错误率.

表 2 当 $\alpha = 20$ 时, 各类别识别正确率和代价加权错误率

方法	识别率/%			总识别率/%	$E_{3,1}$	$E_{3,2}$	$P_{w-err}/\%$
	类1	类2	类3				
ADD+NN	87.50	88.37	90.91	89.19	4	10	25.97
ADD+NS	83.33	69.77	93.18	81.98	3	18	45.45
ADD+Q-Norm1	87.50	93.02	95.45	92.79	2	6	14.61
ADD+Q-Norm2	79.17	95.35	90.91	90.09	4	4	12.99

由表 2 可知: 结合 ADD 的 Q-Norm1 算法具有最高总识别率, 达到 92.79%; 结合 ADD 的 Q-Norm2 算法具有最低的代价加权错误率 P_{w-err} . 这表明主动鉴别字典与稀疏分类器的结合能使道路偏离检测算法在识别率和可靠性两方面性能达到平衡, 满足非结构化环境下的自主导航控制系统中道路偏离检测和纠偏要求.

4 结 论

本文提出了一种基于主动鉴别字典学习的自主导航偏离控制算法, 实现了对智能车辆偏离道路情况的准确判断. 通过实车实验验证了所提出的方法不受路况限制, 具有较强自适应性. 一方面, 该算法在一定程度上解决了以较少标注数据获得较高识别率的问题; 另一方面, 解决了当自主导航车辆偏离道路时, 控制系统如何驱动车辆以纠正偏离方向, 回归正常行驶方向的问题, 为智能车辆的安全行驶提供了保障.

参考文献(References)

- [1] 孙伟, 张小瑞, 唐慧强, 等. Hough 变换和最小二乘拟合的车道线协调检测[J]. 光电工程, 2011, 38(10): 13-19.
(Sun W, Zhang X R, Tang H Q, et al. Lane coordination detection based on hough transformation and least square fitting[J]. Opto-Electronic Engineering, 2011, 38(10): 13-19.)
- [2] 刘富强, 张姗姗, 朱文红, 等. 一种基于视觉的车道线检测与跟踪算法[J]. 同济大学学报: 自然科学版, 2010, 38(2): 223-229.
(Liu F Q, Zhang S S, Zhu W H, et al. A vision-based lane detection and tracking algorithm[J]. J of Tongji University: Natural Science Edition, 2010, 38(2): 223-229.)
- [3] 于兵, 张为公, 龚宗洋. 基于机器视觉的车道偏离报警系统[J]. 东南大学学报: 自然科学版, 2009, 39(5): 930-931.

- (Yu B, Zhang W G, Gong Z Y. Lane departure warning system based on machinevision[J]. J of Southeast University: Natural Science Edition, 2009, 39(5): 930-931.)
- [4] Bertozzi M, Broggi A. GOLD: A parallel real-time stereovision system for generic obstacle and lane detection[J]. IEEE Trans on Image Processing, 1998, 7(1): 62-81.
- [5] Jung C R, Kelber C R. An improved linear-parabolic model for lane following and curve detection[C]. The 18th Brazilian Symposium on Computer Graphics and Image Processing. Rio Grande do Norte: IEEE, 2005: 131-138.
- [6] 龙军, 殷建平, 祝恩, 等. 主动学习研究综述[J]. 计算机研究与发展, 2008, 45(增1): 300-304.
(Long J, Yin J P, Zhu E, et al. An survey of active[J]. J of Computer Research and Development, 2008, 45(S1): 300-304.)
- [7] Zhang L J, Chen C, Bu J J. Active learning based on locally linear reconstruction[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2011, 33(10): 2026-2038.
- [8] Elhamifar E, Sapiro G, Vidal R. See all by looking at a few: Sparse modeling for finding representative objects[C]. 2012 IEEE Conf on Computer Vision and Pattern Recognition. RI: IEEE, 2012: 1600-1607.
- [9] 肖良, 戴斌, 吴涛, 等. 基于字典学习与稀疏表示的非结构化道路分割方法[J]. 吉林大学学报: 工学版, 2013, 43(增): 384-388.
(Xiao L, Dai B, Wu T, et al. Unstructured road segmentation method based on dictionary llearning and sparse representation[J]. J of Jilin University: Engineering and Technology Edition, 2013, 43(S): 384-388.)
- [10] Wright J, Yang A, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.
- [11] Eldar Y C, Mishali M. Robust recovery of signals from a structured union of subspaces[J]. IEEE Trans on Information Theory, 2009, 55(11): 5302-5316.
- [12] Eldar Y C, Kuppinger P, Bolcskei H. Compressed sensing of block-sparse signals: Uncertainty relations and efficient recovery[J]. IEEE Trans on Signal Processing, 2010, 58(6): 3042-3054.

(责任编辑: 滕 蓉)