

中图法分类号: TP242.6+2 文献标志码: A 文章编号: 1006-8961(2011)05-0792-08

论文索引信息: 叶伟龙, 刘华平, 孙富春, 何克忠. 非结构化道路区域检测的协同学习方法 [J]. 中国图象图形学报, 2011, 16(5): 792-799

非结构化道路区域检测的协同学习方法

叶伟龙, 刘华平, 孙富春, 何克忠

(清华大学计算机科学与技术系, 北京 100084) (智能技术与系统国家重点实验室, 北京 100084)

摘要: 非结构化道路区域检测是智能车环境感知的重要问题。提出基于多方向 Gabor 纹理直方图的 SVM 分类器, 并将其与直方图反向投影器组合, 建立了协同学习框架。在实际运行中, 两个学习器可以相互为对方提供标注样本进行更新, 既提高了在线学习能力, 又回避了自学习过程经常导致的模型漂移问题。经实验测试, 协同学习机制显著改善了道路检测性能。

关键词: 协同学习; 道路检测; 支持向量机

Unstructured road detection using co-learning

Ye Weilong, Liu Huaping, Sun Fuchun, He Kezhong

(Department of Computer Science and Technology, Tsinghua University, Beijing 100084 China)

(State Key Lab. of Intelligent Technology and Systems, Beijing 100084 China)

Abstract: Unstructured road region detection forms a main problem of environment sensing for intelligent vehicle. In this paper, two learners are proposed to solve this problem. One is a support vector machine (SVM) classifier which utilizes multi-orientation Gabor texture histogram, and the other is a color histogram back-projection model. Both learners are combined in a co-learning framework. In practical running, the two learners can provide "labeled" samples for each other. This approach can improve the online learning capability and avoid the model drifting problem which often occurs in self-learning approach. Experimental results show the advantages of the proposed co-learning approach.

Keywords: co-learning; road detection; support vector machine

0 引言

非结构化环境下的视觉导航是室外移动机器人的重要问题, 由于该问题的重要性和挑战性, 近年来得到了越来越多的关注。当前有不少研究工作是基于激光雷达传感器的^[1], 但一般来说对成本要求较高。因而, 基于光学的摄像机也吸引了人们的注意。该问题的核心技术在于利用视频图像自动地识别出

机器人前方的可行区域和不可行区域。对于有明显车道线的环境(如高速公路), 该问题可转化为对车道线和道路边界的识别^[2-3]。但对于野外环境、乡村道路之类的非结构化道路, 这些技术难以应用。早期研究提出利用颜色信息来分割可行区域^[4], 但这类方法对于光照改变等影响非常敏感。随着机器学习的进展, 很多研究工作将分类器设计的思想引入了视觉导航领域。例如, 文献[5]利用 Adaboost 技术设计了基于纹理特征的分类器; 文献[6]研究

收稿日期: 2010-02-05; 修回日期: 2010-06-11

基金项目: 国家自然科学基金项目(90820304, 60909055, 60625304, 61075027); 国家高技术研究与发展计划项目(2007AA04Z232); 国家重点基础研究计划项目(G2007CB311003)。

第一作者简介: 叶伟龙(1981—), 男。现为清华大学计算机科学与技术系硕士研究生, 主要研究方向为智能移动机器人环境建模与自主导航。E-mail: dragon2007_mail@163.com。

了从驾驶员遥操作过程中学习的方法。然而,这些方法都是事先在相应环境中采集样本数据,利用这些数据设计分类器,再将分类器用于机器人的在线分类。显然,由于机器人面临的是动态环境,很难利用固定的数据集来获得满意的在线分类效果。因此,引入分类器在线训练的机制成为视觉导航的关键问题。文献[7]引入了在线监督式更新机制。文献[8]研究了利用双目立体视觉的方法来在线更新颜色模型。文献[9]用雷达和姿态传感器测量近距离可行区域,然后从中提取颜色信息来构建外观模型,在此基础上构建远距离的可行区域。这些方法都需要额外的传感器来提供在线监督信息。最近,文献[10]提出一类半监督学习方法来识别可行区域。相比于监督式学习方法,半监督学习方法仅在初始时刻需要监督信息(可以由人或其他传感器提供),在运行过程中不再需要监督信息,而仅仅依靠在实时运行过程中采集到的未标注样本进行分类器在线更新。由于未标注样本的采集非常方便,而且可以实时反映道路环境的变化,因此,半监督学习方法在道路区域检测方面具有天然的优势。然而,文献[10]的方法假设道路区域像素存在一低维流形上,并利用 Markov 随机游走技术设计了在线更新机制。这类半监督技术本质上是基于图(graph)的方法,其性能对相似度关系以及邻域图的选择非常敏感,且运算效率也很低,对于大数据量引发的高维矩阵的求逆计算也很困难。为此,文献[10]将 320×240 的图像分辨率降到 80×60 进行处理,虽然能保证一定的实时性,但是损失了大量图像细节。在在线更新的过程中,需要用到被分错的像素点,在确定分错像素点的过程中,采用了考察周围像素点分类情况的办法,此方法存在一定的局限性,分错像素点的选取正确与否对算法的性能会产生不小的影响。本文针对野外环境,研究将协同学习机制引入非结构化道路识别中。协同学习机制本质上也属于半监督学习机制,但与文献[10]不同的是,此方法并不需要计算各样本之间的相似度关系,而是通过两个学习器互相学习,相互提高的方法来改进学习性能。其实时性相比基于图的方法有明显提高。此外,在提出的协同学习机制框架下,针对道路特点深入研究了特征提取和学习器设计等问题,提出了多方向 Gabor 纹理直方图以更好地刻画纹理信息,利用直方图反向投影技术改善了道路识别性能。

1 多方向 Gabor 纹理直方图特征

Gabor 函数在频率域和空间域同时具有很好的局部性,它和哺乳动物视网膜神经细胞的感受野非常相似,从而被用于图像处理、理解、识别等领域。在非结构化道路环境中,路面的形状、边缘、质地、颜色等都不固定,传统的处理方法(如车道线检测、路面边缘检测、图像阈值分割)都不太适用。文献[11]对多种特征做了实验对比,并指出 Gabor 纹理特征的优越性。但文献[11]仅利用 Gabor 特征寻找消失点。本文提出一种多方向 Gabor 纹理直方图的特征提取方法,实质上是描述图像局部小范围内多个方向的纹理统计信息,对于没有明显结构信息和颜色信息,形状又多变的复杂情况,该特征能建立起稳定的模型,针对类似于乡村公路的非结构化路面,有较好的分类特性。

2 维 Gabor 函数具有方向性和带通性,能比较精确地提取图像的局部纹理特征。Gabor 滤波运算本质上是通过不同的卷积核(由方向角 θ 、波长 λ 和奇偶相位决定)对图像进行高斯窗傅里叶变换。通过 Gabor 函数计算出奇偶两个 $k \times k$ 的卷积核,其函数原型为^[11]

$$g_{\text{odd}}(x, y, \theta, \lambda) = \exp\left[-\frac{1}{8\sigma^2}(4a^2 + b^2)\right] \sin(2\pi a/\lambda) \quad (1)$$

$$g_{\text{even}}(x, y, \theta, \lambda) = \exp\left[-\frac{1}{8\sigma^2}(4a^2 + b^2)\right] \cos(2\pi a/\lambda) \quad (2)$$

式中, g_{odd} 为奇部, g_{even} 为偶部, $a = x \cos \theta + y \sin \theta$, $b = -x \sin \theta + y \cos \theta$, $k = \lfloor 10\lambda/\pi \rfloor$ ($\lfloor \cdot \rfloor$ 代表向下取整函数,若 k 为偶数,则加 1 奇数化), $\sigma = k/9$ 。为了较好地描述局部纹理特征,对像素点 $I(x, y)$, 计算 $I_{\text{complex}}(x, y) = (g_{\text{odd}} * I)(x, y)^2 + (g_{\text{even}} * I)(x, y)^2$ 作为最终滤波结果。

滤波器卷积核是由方向角 θ 和波长 λ 两个参数来决定的。不同方向角的滤波结果反映了纹理特征在不同方向上的响应。选取的方向角 θ 越多,特征的描述越精确,但同时也会带来更大的时间开销。经实验证明,选取 $\{0, \pi/9, 2\pi/9, 3\pi/9, 4\pi/9, 5\pi/9, 6\pi/9, 7\pi/9, 8\pi/9\}$ 这 9 个方向能获得较好的实验结果。在文献[11]中,选取 $\lambda = 2^{\lfloor \log_2(W) \rfloor - 5}$ (W 为图像宽度),该波长相对较长。因为文献[11]的目

的是希望通过 Gabor 特征利用路面上的车辙寻找消失点,车辙信息表现的局部范围相对较广,适当长一些的波长能更好地描述。而在本文的道路检测中,需要描述的是局部小范围区域内的纹理统计信息,因此相对短一些的波长更合适,经过实验,本文选取 $\lambda = 2^{\lfloor \log_2(H/2) \rfloor - 5}$ (H 为图像高度),对 320×240 分辨率的图像,可得 $\lambda = 2$ 时核的大小为 $k = 7$ 。通过不同参数的选取,可形成 9 个不同方向的滤波器组成的滤波器组。由于路面结构的不稳定性,直接用滤波器响应作为特征很难取得满意的分类特性,因而对滤波器响应进行了直方图统计,形成多方向 Gabor 纹理直方图特征,能取得相对较好的分类特性。




图 1 多方向 Gabor 纹理直方图

Fig. 1 Multi-orientation Gabor texture histogram

值得说明的是,在传统的利用 Gabor 特征进行目标识别(如笔迹识别)的问题中,一般对 Gabor 纹理特征进一步做均值和方差的统计,本文也尝试用均值方差作为特征输入,效果并不理想,图 2 为一代表性比较结果。对于有一定固定结构的目标识别问题,均值方差特征比较适用,而在本文的非结构化道路检测问题中,基于路面的多样性,多方向纹理直方图特征能达到更好的效果。




图 2 不同 Gabor 特征实验对比

Fig. 2 Experimental comparison of different Gabor features

在分类器方面,支持向量机的分类目标是通过构造最优分类面来获得最大的分类间隔,从而增强分类器的泛化能力。关于支持向量机的求解目前已

多方向 Gabor 纹理直方图定义为:对一幅灰度图像,分别统计其在每个方向上的 Gabor 滤波结果分布。即对每一个方向,将滤波结果空间(归一化到 $[0, 255]$ 区间)等分为 8 个区间,统计属于每个区间的像素个数,并组成一个 8 维向量。将 9 个方向上的 8 维向量连接起来即形成一个 72 维向量,最后将向量进行范数归一化后作为 SVM 的特征输入。

本文采用 20×20 的图像样本提取 Gabor 纹理直方图特征,如图 1 所示,对从原始图像中分割出的图像样本,首先灰度化,然后提取 9 个方向的纹理特征,归一化到 $[0, 255]$ 区间,最后分别对 9 个灰度图进行直方图统计。

有很多研究,在此不再赘述。为达到在线学习目的,本文利用文献[12]中提出的增量式 SVM(LASVM)实现分类器在线更新。LASVM 包括 PROCESS 和 REPROCESS 两个步骤。通过 PROCESS,一个新的样本可能成为一个支持向量;而通过 REPROCESS,一个支持向量可能被排除出支持向量集,具体细节可参见文献[12]。

2 直方图反向投影器

直方图反向投影是将图像的像素值与相应的图像直方图相联系的一种方法,其本质是将原始图像通过颜色直方图转换到颜色概率分布的过程。原始图像中的像素值用于描述光强度,而直方图反向投影概率图中的像素用来度量某种“可能性”,例如在目标跟踪方法中,概率图中每一个像素点的值表示跟踪目标出现在此像素位置的可能性^[13]。本文构造直方图反向投影以衡量原始图像中的像素点属于路面区域的可能性。在颜色模型的选取中,基于路面上阴影较多、光照强度变化大等环境因素的考虑,本文采用了对此类环境因素相对不太敏感的 $c_1 c_2 c_3$

颜色模型^[14]

$$\begin{cases} c_1(R, G, B) = \arctan(R/\max(G, B)) \\ c_2(R, G, B) = \arctan(G/\max(R, B)) \\ c_3(R, G, B) = \arctan(B/\max(R, G)) \end{cases} \quad (3)$$

式中, R, G, B 分别为像素点的 RGB 值。

直方图反向投影器构造步骤如图 3 所示, (a) 中白色区域为路面区域, 对此区域建立 c_1, c_2, c_3 直方图(图 3(b)), 经反向投影得到图 3(c)。注意, 在此过程中要求分类出路面区域和非路面区域。本文正是通过协同学习机制来实现这一点的, 即用于直方图反向投影器的标注信息由前一部分介绍的 SVM 分类器输出给出。具体细节将在下一部分详细介绍。




图 3 直方图反向投影图

Fig. 3 Histogram back-projection map

经大量实验测试, 相比于 RGB 模型, c_1, c_2, c_3 模型确实有更好的效果。图 4 为一代表性结果, (a) 为两幅原始图像, 对其中框定的区域建立直方图; (b) 为 RGB 直方图反向投影得到的概率图; (c) 为 c_1, c_2, c_3 直方图反向投影得到的概率图。从图中可以看出, c_1, c_2, c_3 模型明显优于 RGB 模型。




图 4 反向投影比较

Fig. 4 Comparison between different back-projections

3 在线协同学习

在半监督学习中, 协同训练是一类重要的学习方法。Blum 和 Mitchell 第一次给出了此方法的形

式化定义, 并成功应用于网页分类中^[15]。协同训练的基本思想是从两个角度看一个分类问题, 根据不同的角度分别建立一个模型, 利用小规模标注样本标注大量未标注样本。文献[15]是在“条件独立”的假设前提下提出的可能近似正确框架支撑模型, 且把在网页分类中获得的优越性能归功于条件独立的假设。“条件独立”的约束过于局限, 在实际问题中要保证两个角度的完美独立也是不现实的。文献[16]指出, 两个并不独立的分类器也可能得到有效的相互训练。近年来, 协同学习的方法在目标跟踪^[17]、阴影检测^[18]等领域获得了成功应用, 但在道路检测方面还没有相关报道。基于协同训练的思想, 本文分别采用 SVM 分类器和直方图反向投影器作为两个学习器, 利用协同学习机制建立道路区域检测的协同学习框架, 如图 5 所示。

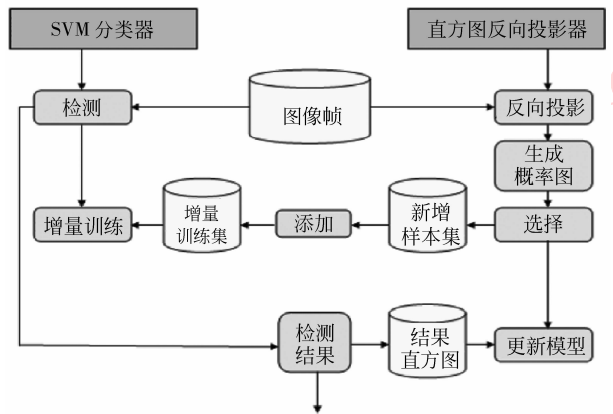


图 5 协同学习算法框架

Fig. 5 Framework for co-learning algorithm

该算法流程如下:

- 1) 利用当前 SVM 分类器对新输入的图像帧进行检测, 得到当前帧的路面检测结果。
- 2) 利用当前直方图反向投影器对新输入的图像帧进行反向投影, 生成反向投影概率图。
- 3) 在投影概率图上按照一定的规则选择正负样本, 提取样本特征, 对加入 SVM 分类器的增量训练集进行增量训练, 得到更新的 SVM 分类器, 作为下一帧图像的分类器。
- 4) 利用当前帧的路面检测结果, 计算路面结果的直方图, 对当前直方图反向投影器进行更新, 作为下一帧图像的直方图反向投影器。

以下分别介绍算法初始化和各部分的实现过程。

3.1 初始化

SVM 分类器和直方图反向投影器的初始化都可以在第 1 帧视频图像上完成,前提是开始检测的第 1 帧图像里包含路面和背景两种元素。检测开始时,在第 1 帧图像上手工选取少量的正负样本构成 SVM 分类器的初始训练样本。对选取的正样本统计 $c_1c_2c_3$ 颜色直方图,作为直方图反向投影器的初始投影直方图。图 6(a)为随机手工选取的实例,其中每个方框的大小为 20×20 像素,图 6(b)为所有黑色框内像素点的初始 $c_1c_2c_3$ 反向投影直方图。




图 6 初始 $c_1c_2c_3$ 反向投影直方图

Fig. 6 Initial $c_1c_2c_3$ back-projection histogram

3.2 LASVM 分类器的更新

基于协同学习框架,分类器的更新样本来自于直方图反向投影器的投影结果。根据直方图反向投影得到的概率图,在其中选取合适的正负样本作为分类器更新的增量样本,通过 LASVM 的增量训练更新分类器。利用路面区域的连续性特质,以 20×20 大小的方框栅格扫描直方图反向投影图,在 20×20 的区域内计算所有像素点的灰度值总和 P ,设此区域像素点全部为路面时的灰度值总和 $P_{\max} = 255 \times 20 \times 20$ 。当 $P > \alpha P_{\max}$ 时,认为此方框为路面区域;当 $P < (1 - \alpha) P_{\max}$ 时,认为此方框为非路面区域。 α 的取值反映了如何刻画数据的“置信程度”,一般可取 $\alpha = 0.9$ 。样本的选取如图 7 所示,黑框为正样本,白框为负样本,(a)为在直方图反向投影概率图上选取增量样本,(b)为所选取增量样本对应的原始图选取。具体的算法流程如下:

1) 栅格扫描直方图反向投影概率图,设扫描得到的方框集合为 $\{S_i\}$,正样本集合 S_{pos} ,负样本集合 S_{neg} 。

2) 累积方框里每一个像素点的灰度值,得到累积和 $P = \sum_{j=1}^{20 \times 20} S_i^{(j)}$,其中 $S_i^{(j)}$ 表示方框 S_i 内第 j 个像素点的灰度值。

3) 如果 $P > \alpha P_{\max}$,则 $S_{\text{pos}} = S_{\text{pos}} \cup S_i$;如果 $P <$

$(1 - \alpha) P_{\max}$,则 $S_{\text{neg}} = S_{\text{neg}} \cup S_i$ 。

4) 从 S_{pos} 和 S_{neg} 中各随机选取 5 个样本,作为 LASVM 分类器的增量训练集。




图 7 无标注样本的增量式选取

Fig. 7 Incremental selection of unlabelled samples

3.3 直方图反向投影器的更新

反向投影直方图的更新由最后的检测结果决定。统计检测结果路面区域所有像素点的 $c_1c_2c_3$ 直方图,记为 H_{new} 。如图 8 所示,统计图 8(a)白色区域所有像素点的 $c_1c_2c_3$ 直方图,得到图 8(b)。设当前直方图为 H_{old} ,则更新后的直方图为

$$H = (1 - \gamma) H_{\text{old}} + \gamma H_{\text{new}} \quad (4)$$

式中, γ 为更新系数,可用于控制更新速度,本文分别选取 0.2,0.5,0.7 几个参数进行实验,效果差别并不明显,本文中固定选取 $\gamma = 0.5$ 。




图 8 H_{new} 的计算

Fig. 8 Calculation of H_{new}

4 实验结果

当前道路检测方面的文献很多,但很多研究都依赖于额外的硬件实现,如激光雷达^[1,9]、立体视觉^[8]等。因此,本文算法与这些方法难以比较。与本文关系最为密切的是文献[10],该文中也引入了半监督学习方法。但正如引言中指出,该方法本质上基于低维流形假设,需要在线比较样本之间的相似度,其运算复杂度很高。由于文献[10]中没有提供完整的实现细节,我们对其进行了粗略复现,其结

果较我们提出的算法差距较大。这可能有两方面原因:1)文献[10]中采用的特征与我们采用的特征不同;2)我们对文献[10]中的算法实现不够精准。因而此处并未列出与文献[10]之间的性能比较。在实验结果对比中,重点考察协同学习机制的引入对算法性能的改进。事实上,这一协同学习框架也可与其他特征和算法结合以改进性能。

为测试本算法性能,采集了类似乡村公路的视频(分辨率为 320×240 ,称为 THMR 数据)以及 DARPA LAGR 数据(<http://ml.cs.colorado.edu/~procopio/labeledlagrdata/>)作为测试数据,在一台 Core2 2 GHz,2 GB RAM 的 PC 上完成测试,算法未经特殊优化,其处理速度在 5 帧/s 左右,其中分类器检测的平均时间为 128 ms,反向投影的平均时间为 20 ms,分类器和直方图反向投影器的在线更新时间为 19 ms。为了验证算法的在线学习能力,我们实现了 3 个不同算法的比较,具体算法如下:

- 1) UN 不更新 SVM 分类器。
- 2) UD 仅更新 SVM 分类器,不更新反向投影直方图。
- 3) UDH 既更新 SVM 分类器,又更新反向投影直方图。

LAGR 数据提供了路面标注信息。此外,我们也对采集的 THMR 数据中的 50 帧进行了手工标注(手工标注采用 PhotoShop 作为辅助工具,先框定路面区域选区,然后在选区内着上单色),并计算出每种算法的检测错误率。本文中检测错误率定义为检测结果与手工标注信息不一致的像素点数占像素点总数的百分比。由于算法需要随机初始化样本选择,故将以上算法各运行 10 次,取平均检测误差显示于图 9 和图 10。




图 9 检测误差率 (LAGR 数据)

Fig. 9 Detection error rate (LAGR dataset)




图 10 检测误差率 (THMR 数据)

Fig. 10 Detection error rate (THMR dataset)

从图 9 中可以看出,UDH 和 UD 两种方法明显优于 UN 方法,3 种方法的平均错误率分别为 0.111 031 (UDH)、0.110 098 (UD)、0.158 801 (UN)。UDH 和 UD 之所以比较接近,是因为在 LAGR 数据的这 100 帧图像中,路面区域的 $c_1c_2c_3$ 直方图变化很小(如图 11 所示),所以直方图的更新并没有带来什么影响。同样从图 10 中可以看出,在采集的 THMR 数据集上,UDH 和 UD 两种方法也明显优于 UN 方法,平均错误率分别为 0.046 650 9 (UDH)、0.172 833 (UD)、0.190 988 (UN)。与标准数据集不同的是,UD 在 THMR 数据中的表现很不理想,这是因为在此数据中,由于阴影和坑洼影响, $c_1c_2c_3$ 直方图的变化比较大(如图 12 所示),所以直方图的更新变得非常重要。

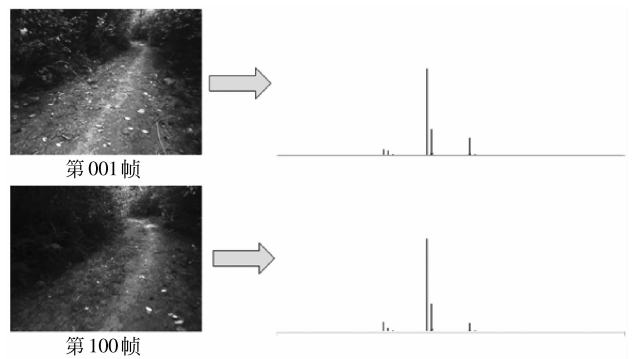


图 11 $c_1c_2c_3$ 直方图比较 (LAGR 数据)

Fig. 11 Comparison of $c_1c_2c_3$ histogram (LAGR dataset)

图 13—15 为一些代表性实验结果,其中布局说明如下:图(a)中上图为增量样本选取,其中黑框为正样本,白框为负样本;图(b)中上图为 $c_1c_2c_3$ 反向投影概率图;图(a)中下图为手工标注图;图(b)中下图为 SVM 分类器检测结果图。

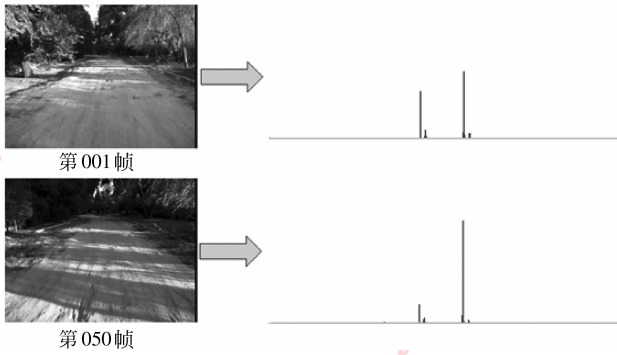


图 12 c_1, c_2, c_3 直方图比较 (THMR 数据)

Fig. 12 Comparison of c_1, c_2, c_3 histogram (THMR dataset)




图 13 THMR 数据, 第 5 帧

Fig. 13 THMR dataset, frame 5




图 14 采集数据, 第 36 帧

Fig. 14 THMR dataset, frame 36




图 15 LAGR 数据, 第 73 帧

Fig. 15 LAGR dataset, frame 73

从实验结果可以看出,在初始训练样本很少的情况下,通过 SVM 分类器和直方图反向投影器的学习更新,算法能明显地适应路面环境(阴影、光照、坑洼等)的变化,检测效果得到提高。具体比较如下:

1)图 13 为采集的 THMR 数据第 5 帧在 UD 和 UDH 两种方法下的检测结果。图(a)由于没有更新直方图,反向投影概率图出现较大误差,导致增量样本的选取也出现误差(有两个增量负样本选到路面上),从而也会影响到分类器的更新,得到的检测结果自然不会理想。图(b)对分类器和反向投影直方图都进行了更新,没有出现类似的情况,结果较为理想。从这两幅图像的比较可以看出,直方图反向投影器更新学习的重要性。

2)图 14 为采集的 THMR 数据第 36 帧在 UN 和 UDH 两种方法下的检测结果。图(a)没有更新 SVM 分类器和直方图,从分类器结果可以看出,光照和坑洼给分类器带来了很大的影响,因为初始的分类器只有少量的训练样本,分类器的分类能力并不强。图(b)进行了分类器的更新,分类结果明显改善,从图(b)左上角的增量样本选取情况可以看出,光照强度变化大的路面区域被学习到了。从这两幅图像的比较可以看出,分类器更新学习的重要性。

3)图 15 为 LAGR 数据第 73 帧在 UN 和 UDH 两种方法下的检测结果。图(b)由于在线更新,检测效果要优于图(a)。

由实验结果可以看出,引入协同学习机制确实明显改善了分类性能。

5 结 论

针对非结构化道路区域检测提出增量式协同学习方法,利用多方向 Gabor 纹理直方图和直方图反向投影器相互学习,可以很好地适应环境的变化。协同学习机制本质上属于半监督学习。与基于图的半监督学习方法相比,该方法不需要计算所有样本之间的相似度关系,无需低维流形假设,算法直观且具有开放性,可以很容易融入其他学习机制。另外,协同学习本质上关注两个学习器之间的相互学习,而并不限定学习器的融合应用。本文的重心也在于学习器之间的相互改进。下一步工作中可引入不同学习器的置信程度以构建自适应融合方法。

参考文献 (References)

- [1] Yuan Xia, Zhao Chunxia, Chen Debao, et al. Road-surface detection based on lidar sensing [J]. *Journal of Image and Graphics*, 2009, 14(10): 2035-2041. [袁夏,赵春霞,陈得宝,等.一种基于激光雷达的路面提取算法[J].中国图象图形学报,2009,14(10):2035-2041.]
- [2] Danescu R, Nedeveschi S. Probabilistic lane tracking in difficult road scenarios using stereovision [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2009, 10(2): 272-282.
- [3] Cheng H Y, Jeng B S, Tseng P T, et al. Lane detection with moving vehicles in the traffic scenes [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2006, 7(4): 571-582.
- [4] Crisman J, Thorpe C. Unscarf—A color vision system for the detection of unstructured roads [C] // *Proceedings of International Conference on Robotics and Automation*. Piscataway, USA: IEEE Press, 1991: 2496-2501.
- [5] Alon Y, Ferencz A, Shashua A. Off-road path following using region classification and geometric projection constraints [C] // *Proceedings of Computer Vision and Pattern Recognition*. Piscataway, USA: IEEE Press, 2006: 689-696.
- [6] Ollis M, Huang W H, Happold M. A Bayesian approach to imitation learning for robot navigation [C] // *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems*. Piscataway, USA: IEEE Press, 2007: 709-714.
- [7] Lookingbill A, Rogers J, Lieb D, et al. Reverse optical flow for self-supervised adaptive autonomous robot navigation [J]. *International Journal of Computer Vision*, 2007, 74(3): 287-302.
- [8] Tue D S, Guo D, Yan C H, et al. Robust extraction of shady roads for vision-based UGV navigation [C] // *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems*. Piscataway, USA: IEEE Press, 2008: 3140-3145.
- [9] Dahlkamp H, Kaehler A, Stavens D, et al. Self-supervised monocular road detection in desert terrain [C] // *Proceedings of the Robotics Science and Systems Conference*. Philadelphia, USA: IEEE Press, 2006: 1-7.
- [10] Bates A R, Bijral A S, Mulligan J, et al. Traversable path identification in unstructured terrains: a Markov random walk approach [C] // *Proceedings of IEEE International Conference on Robotics and Automation*. Piscataway, USA: IEEE Press, 2009: 3423-3430.
- [11] Rasmussen C. Grouping dominant orientations for ill-structured road following [C] // *Proceedings of Computer Vision and Pattern Recognition*. Piscataway, USA: IEEE Press, 2004: 470-477.
- [12] Bordes A, Ertekin S, Weston J, et al. Fast kernel classifiers with online and active learning [J]. *Journal of Machine Learning Research*, 2005, 6: 1579-1619.
- [13] Collins R T, Liu Y, Leordeanu M. Online selection of discriminative tracking features [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(10): 1631-1643.
- [14] Villamizar M, Scandaliaris J, Sanfeliu A, et al. Combining color-based invariant gradient detector with HoG descriptors for robust image detection in scenes under cast shadows [C] // *Proceedings of IEEE International Conference on Robotics and Automation*. Piscataway, USA: IEEE Press, 2009: 1997-2002.
- [15] Blum A, Mitchell T. Combining labeled and unlabeled data with co-training [C] // *Proceedings of the Eleventh Annual Conference on Computational Learning Theory*. New York, USA: ACM Press, 1998: 92-100.
- [16] Levin A, Viola P, Freund Y. Unsupervised improvement of visual detectors using co-training [C] // *Proceedings of International Conference on Computer Vision*. Piscataway, USA: IEEE Press, 2003: 626-633.
- [17] Yu Q, Thang B D, Medioni G. Online tracking and reacquisition using co-trained generative and discriminative trackers [C] // *Proceedings of European Conference on Computer Vision, Heidelberg, Germany*: Springer Verlag, 2008: 678-691.
- [18] Joshi A J, Papanikolopoulos N. Learning of moving cast shadows for dynamic environments [C] // *Proceedings of International Conference on Robotics and Automation*. Piscataway, USA: IEEE Press, 2008: 987-992.