

结合方向纹理熵的 Haar-like 特征在线 boosting 跟踪算法*

胡松, 孙水发[†], 陈鹏, 但志平, 董方敏

(三峡大学智能视觉与图像信息研究所, 湖北宜昌 443002)

摘要: 针对传统基于 Haar-like 特征的 on-line boosting 跟踪算法(HBT)需要产生大规模随机特征、占用大量计算资源和存储空间的缺点,提出结合方向纹理熵的 Haar-like 特征在线 boosting 跟踪算法(HBTT)。HBTT 算法利用灰度共生矩阵的熵获得目标纹理的方向信息,在此基础上有针对性地产生具有方向纹理信息的 Haar-like 特征,从而可有效避免无效随机特征的产生,减小特征池容量;更进一步,可根据目标纹理的复杂程度自动调整特征数量,使得算法更灵活。在跟踪过程中,在线学习模块可以使错误率较高的特征被结合了目标纹理方向信息的 Haar-like 特征所替换。与 HBT 算法比较,HBTT 算法的跟踪误差降低了 10% 以上;在相同特征池容量下,置信度提高了 2% 以上。实验结果表明,该算法不仅具有较高的鲁棒性,而且在跟踪效率和性能上都有所提高。

关键词: 目标跟踪; 在线 boosting 算法; 类 Haar 特征; 灰度共生矩阵; 方向纹理熵

中图分类号: TP391.41

文献标志码: A

文章编号: 1001-3695(2014)04-1260-04

doi:10.3969/j.issn.1001-3695.2014.04.073

On-line boosting tracking based on direction texture entropy combined Haar-like feature

HU Song, SUN Shui-fa[†], CHEN Peng, DAN Zhi-ping, DONG Fang-min

(Institute of Intelligent Vision & Image Information, China Three Gorges University, Yichang Hubei 443002, China)

Abstract: Large numbers of features are needed for tracking based on the conventional Haar-like feature based on-line boosting (HBT). The vast amount guarantees the existence of useful features. But it leads to expensive computing and memory requirements. To address this problem, this paper proposed a new method named HBTT (Haar-like feature based on-line boosting tracking with texture information). It extracted the texture direction and richness information by the entropy of gray level co-occurrence matrix (GLCM). Then calculated Haar-like features along directions with richest texture. And also governed the employed feature number by the texture richness. In this way, not only the number of useless features was largely reduced, but also the total size of the feature pool. Experiments reveal the higher robustness and performance of this new HBTT method. In general, the tracking error is reduced by more than 10%, and the confidence of the tracking is increased by more than 2%.

Key words: object tracking; on-line boosting algorithm; Haar-like feature; GLCM; direction texture entropy

0 引言

目标跟踪的应用领域很广,如交通控制、医药治疗以及国防中的战地监视和防空系统。长时间跟踪在许多应用系统中有着非常重要的意义,而长时间跟踪中一个非常关键的部分就是对目标状态实时更新的能力^[1,2]。如文献[3]中提到的 on-line boosting 算法采用 Haar-like 特征集,并在每一帧通过集合中各个特征的表现来对特征集的结构进行更新调整,这种方法本文称之为 HBT。HBT 是一种将弱学习提升成为强学习的识别跟踪算法,它使用目标当前的状态进行学习。HBT 主要的局限性是当最能区分背景的特征来自于目标时,识别模型会将主要注意力放在这个部分,从而忽视了目标外观的整体描述,而 MILBoost 可以选出正确的样本来更新模型^[4]。

实时更新一般基于目标的某些特征。基于特征的目标跟踪算法需要提取目标的特征,并在每一帧中寻找该特征,寻找的过程就是特征匹配的过程。因此,特征的选取非常重要。用于跟踪的特征有很多种,如颜色直方图特征,它在粒子滤波和 Mean-Shift 算法中都有用到^[5,6],具有对遮挡、非刚体运动和视角变化相对不太敏感的优点;然而当目标与背景的颜色相似时,颜色直方图特征不能对它们进行很好的区分。Haar-like 特征由于其具有较强的分类能力和较快的计算速度^[7],广泛应用于模式识别和智能视频监控系统中。

Haar-like 特征是一种基于灰度信息的局部特征,但在描述目标纹理时显得不足;而灰度共生矩阵可有效对目标纹理信息进行描述^[8],若将两者结合起来,可有效提高特征对目标的描述能力。对 Haar-like 特征模板的研究发现,其模板具有方向

收稿日期: 2013-05-19; **修回日期:** 2013-06-26 **基金项目:** 国家自然科学基金资助项目(61102155,61272236,61272237);湖北省高等学校优秀中青年科技创新团队资助项目(T201002);湖北省教育厅青年科学基金资助项目(Q20111205)

作者简介: 胡松(1988-),男,硕士研究生,主要研究方向为计算机视觉、嵌入式系统;孙水发(1977-),男(通信作者),副教授,博士,主要研究方向为图像处理、计算机视觉(watersun1977@hotmail.com);陈鹏(1972-),男,教授,博士,主要研究方向为计算机视觉;但志平(1976-),男,副教授,硕士,主要研究方向为计算机视觉、图像处理;董方敏(1965-),男,教授,博士,主要研究方向为计算机图像图形处理。

性,且特征模板的方向与目标的纹理正好可以对应起来。若算法产生与目标纹理方向匹配的 Haar-like 特征,便可使特征池中特征的分布更具针对性,减少大量无效冗余特征,使产生的特征分类能力更强。本文在原来基于 Haar-like 特征的 on-line boosting 跟踪算法上作了改进,提出一种通过计算目标灰度共生矩阵的方向熵来驱动 Haar-like 特征池有针对性的建立,且特征池大小可根据目标纹理信息自动伸缩,称这种方法为 HBTT 跟踪算法。

1 现有基础、问题与思路

1.1 On-line boosting 跟踪算法^[3]

On-line boosting 算法由弱分类器、选择器和强分类器组成。弱分类器由识别率大于 50% 的基于 Haar-like 特征的基本分类器组成。每个选择器包含一个弱分类器构成基本分类器,且依次从错误率最低的弱分类器中选取。所有的选择器共用一个特征池,即 Haar-like 特征池,然后对每一个弱分类器进行更新时都选择错误率最低的且未被前面选择器采用的弱分类器作为该选择器所包含的基本分类器。最后通过对每个选择器进行加权求和,从而得到所需的强分类器。选择器的权重由弱分类器的分类错误率决定,分类错误率越高,分类器的权重越低。采用该算法时,弱分类器的个数会直接影响跟踪效率,特征池大可以从中选出更好的特征,但一般算法采用随机生成特征池或穷举产生特征池的方式,因此会产生大量分类能力很弱的特征;而选择器越多,即投票者越多,越能产生更好的分类结果;而且算法中每一个选择器在选择自己最好的特征时都几乎会遍历整个特征池,这也是效率低的另一个方面。如果能在初始化时产生一个精简的特征池,就可以大大提高跟踪效率和跟踪精度。

1.2 灰度共生矩阵的特征——熵^[8]

灰度共生矩阵 (GLCM) 用两个位置像素的联合概率密度来定义,它不仅反映亮度的分布特性,也反映具有同样亮度或接近亮度的像素之间的位置分布特性,是有关图像亮度变化的二阶统计特征。为了更直观地描述纹理状况,从共生矩阵导出一些反映矩阵性质的参数,典型的有角二阶矩、对比度、相关、逆差距、熵等。两个像素点的位置需要确定两个参数 d 和 θ ,若 (x_1, y_1) 与 (x_2, y_2) 是原图像中的两个点, i 和 j 表示这两点的灰度级,则它们之间的距离为 d ,两者与坐标轴的夹角为 θ ,可以得到间距及角度的灰度共生矩阵 $P(i, j, d, \theta)$ 。

通过对目标窗口的扫描,计算得到水平、垂直、45° 和 135° 四个方向的灰度共生矩阵。实验中需要对得到的灰度共生矩阵进行对称化和归一化, $G(i, j)$ 为灰度对 (i, j) 出现的频率,即灰度共生矩阵归一化后的结果。然后分别计算它们的特征——熵。熵的大小一定程度上反映了该方向纹理的无序性,若灰度共生矩阵值分布均匀,也即图像近于随机或噪声很大,熵会有较大值。另外,对于具有规则纹理特性的图像,在纹理方向和垂直于纹理的方向由于像素灰度排列整齐,熵值较小,而在与纹理方向呈 45° 和 135° 的方向上熵值较大。

1.3 Haar-like 特征的熵方向

为了将 Haar-like 特征与灰度共生矩阵的熵联系起来,从而通过熵值来指导性地产生 Haar-like 特征,引入 Haar-like 特征的熵方向概念,即对于一类 Haar-like 特征,规定其熵最大的

两个方向为该 Haar-like 特征的熵方向。图 1 为算法中所用到的 15 类 Haar-like 特征,通过实验和推断得到各个 Haar-like 特征的熵方向,如表 1 所示。

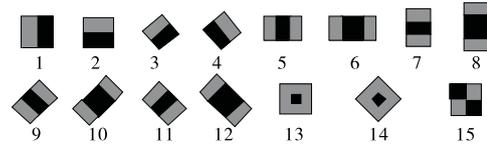


图 1 15 类 Haar-like 特征

表 1 Haar-like 特征的熵方向

熵方向	特征类型编号
0° 90°	3 4 9 10 11 12 14
45° 135°	1 2 5 6 7 8 13 15

表 1 中,编号为 13、14、15 的 Haar-like 特征均为中心对称图形,经计算,它们在四个方向上的熵值差别不大,这里将编号为 13、15 的特征归为熵方向 45° 和 135°,而将编号为 14 的特征归为熵方向 0° 和 90°,这样归类对特征的描述能力影响不大。

2 结合方向纹理熵的目标跟踪算法

传统的基于 Haar-like 特征的 on-line boosting 跟踪算法在初始化特征池时通常采用两种方法:a) 随机生成数量庞大的具有随机大小、随机位置和随机类型的 Haar-like 特征;b) 穷举目标框范围内的所有特征。这两种构建特征池的方式虽然产生了丰富的特征,但同时也产生了大量的冗余特征,使得算法效率低下。在跟踪过程中,分类能力最差的特征被随机产生的特征所替换,只是单纯产生了一个新的特征,并没有对当前目标状态进行特征的有针对性生成,导致算法的鲁棒性不够好。

2.1 初始特征池构建

为了弥补传统算法的不足,通过对目标区域进行灰度共生矩阵的计算,提取出以上四个方向的熵。熵值越大,该方向的细节信息越丰富,需要用更多的特征来表征。而每个方向都有与之对应的 Haar-like 特征,便可通过 Haar-like 特征的熵方向来产生对应灰度共生矩阵方向上的 Haar-like 特征,且产生个数受熵值大小影响。目标越简单,熵值越小,则产生的特征数量就越多;反之,则越少,即简单物体可以由较少的特征所表征,这样便可根据目标复杂度产生动态容量的特征池。在此引入指数分布函数来计算各个方向熵所应产生的特征数量。指数分布的密度函数如式(1)所示。

$$p(x) = \begin{cases} \lambda e^{-\lambda x} & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (1)$$

令 $\lambda = 1$, x 用 $E_i \times ER$ 来表示。其中: E_i 表示某个方向的熵值, $i \in \{0, 45, 90, 135\}$; ER 表示熵倍率,用来扩大熵的数值,产生更多特征。由于 $E_i \times ER$ 一般情况下大于 0,则式(1)可简写为

$$p(E_i) = e^{-E_i \times ER} \quad (2)$$

由式(2)可知,当熵值增大时, $p(E_i)$ 减小。特征数量的确定流程如图 2 所示。由图 2 可知, $p(E_i)$ 越小,则迭代次数越多,所产生的特征数量越多。各个方向所应产生的特征数量确定后就可以产生对应数量类型的特征,如 $\theta = 0^\circ$ 方向上的特征数量 $K_0 = 50$,则应产生类型编号为 3、4、9、10、11、12、14 的特征共 50 个,初始特征池构建完毕。

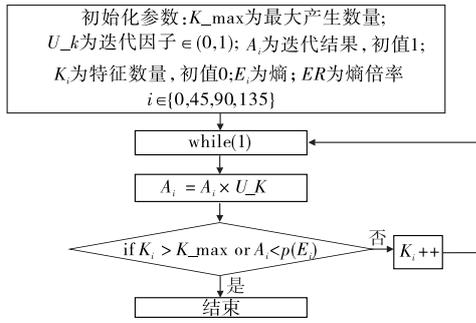


图 2 各个方向上特征数量确定流程

2.2 特征池自适应更新

在跟踪过程中,由于目标的状态在不断发生改变,为了适应这种改变,得到更好的跟踪效果,可以对特征池进行部分更新。这种更新旨在剔除特征池中的最差特征,加入比它分类能力更强的特征。为此,算法引入基于目标纹理信息的特征更新策略,该策略根据目标灰度共生矩阵的熵的最大值方向来选择特征类型进行更新。下面的纹理旋转实验说明了纹理与特征更新之间的对应关系:实验视频图 3(a)中的目标在缓慢旋转,目标的纹理方向也在不断发生变化,更新产生的特征类型也在缓慢发生变化,如图 3(b)所示。

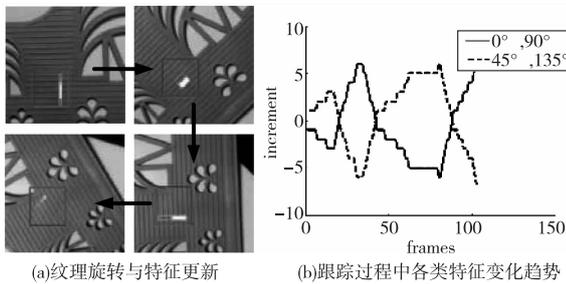


图 3 纹理方向与特征更新之间的关系

从图 3 中可看出,开始时目标纹理处于水平方向,更新所产生的熵方向为 45° 与 135° 的特征增多;当纹理方向由水平逐步偏转到 45° 方向时,更新产生的熵方向为 0° 与 90° 的特征不断增加,如图中实线部分所示;而当纹理方向由 45° 偏转到垂直方向时,更新产生的熵方向为 45° 与 135° 的特征增多,如图中虚线部分所示;当纹理方向由垂直方向偏转到 135° 方向时,更新所产生的熵方向为 0° 与 90° 的特征不断增加。实验结果表明,当纹理方向发生角度变化时,算法更新策略可产生与纹理方向一致的新特征,从而保证特征池的特征分类能力及跟踪的自适应性。

2.3 算法流程

算法分初始化和跟踪两个模块。具体流程如下:

a) 初始化模块

(a) 选择目标,求取目标的灰度共生矩阵,得到纹理信息,并计算四个方向共生矩阵的熵值。

(b) 根据图 2 计算各方向应产生的特征数量,生成特征池,其中 20 个留做备用替换特征,剩下特征作为选择器共享特征池。

(c) 构建强分类器,对组成强分类器的选择器中的弱分类器进行训练。若特征池中构成弱分类器的 Haar-like 特征的最大错误率大于备用特征的错误率,则通过前面的更新策略产生新特征并加入到备用特征中,从备用特征中选出最好的特征替换特征池中最差的特征。

(d) 构建检测器并初始化扫描窗口和置信度图。

b) 跟踪模块

(a) 传入下一帧图像,在上一帧目标位置周围两倍范围内进行目标搜索,计算搜索窗口的置信度,选出置信度最大的作为新目标位置。

(b) 在新目标位置处对强、弱分类器进行训练更新。若特征池中构成弱分类器的 Haar-like 特征的最大错误率大于备用特征的错误率,则通过前面的更新策略产生新特征并加入到备用特征中,从备用特征中选出最好的特征替换特征池中最差的特征。

(c) 转步骤 (a) 继续执行,直到视频结束。

3 实验结果及分析

3.1 实验视频及说明

本实验所用视频来自于 Benchmark 数据集^[9],该数据集共包含 12 组不同场景下的视频序列,其中,seqF 由于目标被其他物体长时间完全遮挡,超出本算法的适用范围,故实验视频序列中不包含该序列;seqJ 中有两个被标记的人物目标,选择 Ja 为跟踪目标;视频序列涵盖了移动摄像头(A、B、C、D、E、G、I、Ja、K、L)、移动目标(A、B、D、I、Ja)、旋转(A、D、I)、快速方向变化(A、C)、背景变化(B)、尺度变化(B、C、K、L)、非刚性目标(D、I、Ja)、户外(D、I)、局部遮挡(E)、视角变化(G、K、L)、光照变化(H)、相似干扰(I、K)、短暂完全遮挡(I、Ja)等各种场景。

3.2 基本跟踪测试

实验发现,HBT 和 HBTT 算法对视频序列 C、D、E、G、H、Ja、K 及 L 都进行了较好的跟踪,但在对视频序列 A、B 及 I 的跟踪过程中,HBT 算法均出现了跟踪丢失的现象,而 HBTT 算法却对这些视频进行了较好的跟踪。在 HBT 算法下,视频序列 A 在第 189 帧时即跟踪丢失;视频序列 B 在第 221 帧时开始将背景作为目标的一部分进行跟踪,后面逐渐将整个背景图案当做目标,发生错跟现象,最后导致跟踪丢失。图 4(a) 为视频序列 B 在两种算法下三帧图像的跟踪结果对比(左:HBT;右:HBTT),视频序列 I 在出现第一个人从目标背后穿过时,便将另一个人作为目标,发生错跟现象,最后当那个人消失时导致跟踪丢失;(b) 为视频序列 I 在两种算法下三帧图像的跟踪结果对比。

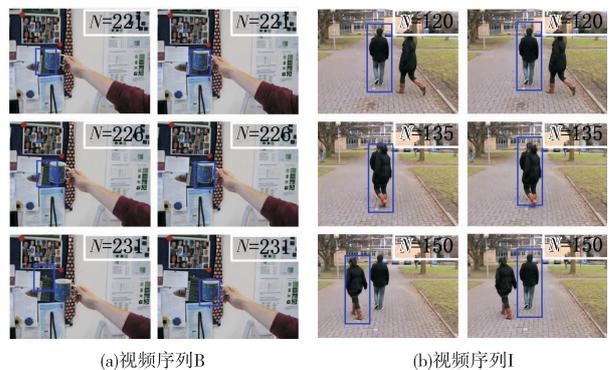


图 4 视频序列 B、I 在两种算法下三帧图像的跟踪结果对比

可以看出,当背景发生变化、明暗程度与前景相似时,HBT 算法容易将背景当做目标发生错跟,如视频序列 B;而当有类似物体与目标本身发生重合、干扰跟踪时,HBT 算法也容易发生错跟,从而丢失原目标,如视频序列 I。HBTT 算法通过目标的纹理信息作指导产生对应方向的 Haar-like 特征,形成的强分类器对目标纹理更敏感,背景与目标相似的明暗度不会太大

影响到算法对目标的准确跟踪。

3.3 跟踪准确度测试

为了更进一步地分析两种跟踪算法的性能,引入评判标准 DER(displacement error rate)^[6]。其计算公式如式(3)所示。

$$DER = \frac{DE}{S} \quad (3)$$

其中:DE 为目标中心位置与 GT(ground truth)之间的欧式距离,S 为目标尺寸。DER 越小,则跟踪性能越好。图 5 为视频序列 C、D、E、G、H、Ja、K、L 在两种算法中的 DER 之差(HBT 算法的 DER 减去 HBTT 算法的 DER)。

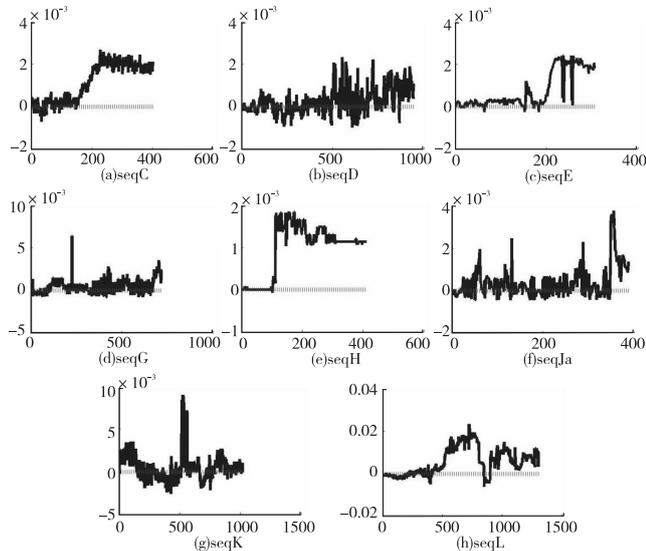


图 5 跟踪结果 DER 对照

图 5 中纵坐标 0 以上说明 HBT 算法的误差大于 HBTT 算法的误差,0 以下则相反。从图 5 中可以直观地看出 DER 在 HBTT 算法中的表现明显比 HBT 算法好。下面从数据上加以说明,将 DE 的均值用 D_m 表示,DE 的中值用 D_{md} 表示。它们越小,则算法性能越好。表 2 列出了以上视频序列在两种算法下的 DE 统计结果(PI-percentage improved)。

表 2 DE 统计结果

video	method	D_m	PI/%	D_{md}	PI/%
seqC	HBT	7.20		10.30	
	HBTT	3.43	52.36	4.12	60.00
seqD	HBT	5.45		4.47	
	HBTT	4.40	19.27	3.61	19.24
seqE	HBT	9.89		5.00	
	HBTT	2.94	70.27	2.00	60.00
seqG	HBT	7.38		6.08	
	HBTT	6.00	18.70	5.39	11.35
seqH	HBT	6.39		7.28	
	HBTT	1.04	83.72	1.00	86.26
seqJa	HBT	10.52		6.40	
	HBTT	9.43	10.36	5.66	11.56
seqK	HBT	3.41		3.32	
	HBTT	2.84	16.72	2.88	13.25
seqL	HBT	18.59		19.92	
	HBTT	11.92	35.88	11.40	42.77

从表 2 中可以看出,HBTT 算法的跟踪效果优于 HBT 算法,说明新的特征产生和更新策略确实起到了选出更好特征的能力。实际上算法在初始训练第一帧图像中的目标时,根据目标各方向上的纹理信息针对性地产生了对应方向上的 Haar-like 特征,使得特征的分布并不完全随机,而是与纹理的分布一致,这样既保证了各个方向上的特征都存在,又进一步减少

了不对应方向上特征的冗余,在保证选择器能够选出较好区分能力特征的同时降低了特征的冗余。

3.4 跟踪可信度测试

通过调整熵倍率 ER 使得 HBTT 算法的初始特征池大小同 HBT 算法,均为 500,然后比较两种算法的平均置信度(Mean-Conf),结果数据如表 3 所示。可以看出,HBTT 算法的平均置信度明显高于 HBT 算法,说明在相同特征池容量下,HBTT 算法特征池中特征的分类能力比 HBT 算法好。

表 3 特征池容量相同条件下的平均置信度比较

video	method	meanconf	PI/%
seqC	HBT	0.839 1	
	HBTT	0.873 9	4.15
seqD	HBT	0.880 2	
	HBTT	0.933 5	6.06
seqE	HBT	0.945 5	
	HBTT	0.967 8	2.36
seqG	HBT	0.835 8	
	HBTT	0.880 5	5.35
seqH	HBT	0.937 4	
	HBTT	0.978 6	4.40
seqJa	HBT	0.818 0	
	HBTT	0.926 1	13.22
seqK	HBT	0.887 1	
	HBTT	0.942 9	6.29
seqL	HBT	0.681 1	
	HBTT	0.784 0	15.11

3.5 跟踪速度测试

以上从跟踪准确性上作了分析,下面从跟踪效率和有效性上对算法作进一步分析。表 4 列出了图 5 中视频序列在两种算法下所产生的特征池大小(FPSize)以及平均处理速度(MeanFPS)的情况。其中,FPSize 为初始化时算法所产生的特征的总个数,MeanFPS 为单位时间内处理帧数的平均值。

表 4 算法效率及有效性分析

video	method	FPSize	MeanFPS	PI/%
seqC	HBT	500	7.70	
	HBTT	223	13.30	72.73
seqD	HBT	500	6.43	
	HBTT	255	8.92	38.72
seqE	HBT	500	11.79	
	HBTT	216	15.51	31.55
seqG	HBT	500	12.80	
	HBTT	221	25.65	100.39
seqH	HBT	500	6.37	
	HBTT	219	9.90	55.42
seqJa	HBT	500	4.82	
	HBTT	239	7.48	55.19
seqK	HBT	500	18.20	
	HBTT	254	33.34	83.19
seqL	HBT	500	17.12	
	HBTT	242	35.75	108.82

从表 4 可以看出,HBTT 算法产生的特征池更小,但并没有影响到算法的跟踪性能,相反提高了跟踪效率,这说明本文提出的算法在算法效率上优于 HBT 算法。比如本实验两种算法均采用 30 个选择器,每一次强分类器更新都要调用更新函数八次,分别对正负样本进行交错更新,更新函数首先需要根据样本重要性对每个弱分类器进行训练,弱分类器个数即为 FPSize,训练轮数由重要性决定,接着选出每个选择器所包含的最好弱分类器,可见 FPSize 的减小可以大大降低算法中循环遍历的次数,从而提高跟踪速度。(下转第 1269 页)

可以看出,VisuShink 方法降噪之后的图像比较模糊,过于平滑,丢失了过多的细节。NeighShink 方法相对于 VisuShink 方法图像较为清晰,但在一些细节方面也比较模糊。本文方法去噪之后图像的视觉效果明显优于其他方法,不仅清晰,而且较好地保留了更多细节。

5 结束语

本文主要是将 Contourlet 变换和改进 NeighShink 相结合进行图像去噪,主要有以下特点:a) 在每个方向子带上基于 SURE 进行启发式阈值选择来减小误差;b) 根据邻域窗能量大小将系数进一步细分,并进行不同的收缩处理;c) 对大能量系数利用最大似然估计和最小均方误差得到系数更准确的估计。实验表明,本文方法提高了去噪效果,且视觉效果较好。

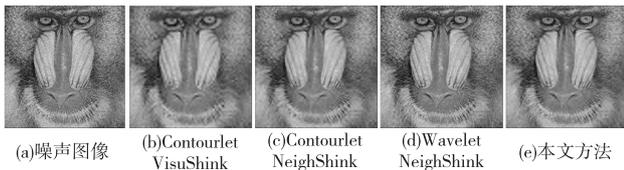


图4 图像 baboon 在 PSNR = 18.641 时去噪结果比较

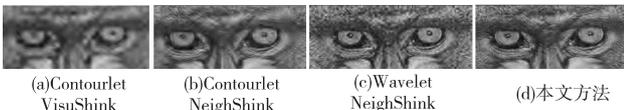


图5 眼睛局部图像

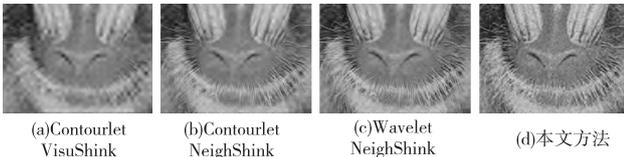


图6 嘴巴局部图像

参考文献:

[1] DONOHO D L, JOHNSTONE I M. Ideal spatial adaptation via wavelet shrinkage[J]. *Biometrika*, 1994, 81(3):425-455.

[2] DONOHO D L, JOHNSTONE I M. Adapting to unknown smoothness via wavelet shrinkage[J]. *Journal of the American Statistical Association*, 1995, 90(432):1200-1224.

[3] CHEN G Y, BUI T D, KRZYSAK A. Image denoising with neighbour dependency and customized wavelet and threshold[J]. *Pattern Recognition*, 2005, 38(1):115-124.

[4] DO M N, VETTERLI M. The contourlet transform: an efficient directional multiresolution image representation [J]. *IEEE Trans on Image Processing*, 2005, 14(12):2091-2106.

[5] DO M N, VETTERLI M. Contourlets: a directional multi-resolution image representation[C]//Proc of IEEE International Conference on Image Processing. Piscataway, NJ: IEEE Press, 2002:357-360.

[6] PO D D, DO M N. Directional multiscale modeling of images using the Contourlet transform[J]. *IEEE Trans on Image Processing*, 2006, 15(6):1610-1620.

[7] 何雅丽,杨波先,李利,等. 邻域窗能量平均的 Contourlet 变换自适应阈值去噪算法[J]. *计算机应用*, 2012, 32(5):1286-1288.

[8] BURT P J, ADELSON E H. The Laplacian pyramid as a compact image code[J]. *IEEE Trans on Communications*, 1983, 31(4):532-540.

[9] 白璘,刘盼芝,李光. 一种基于 Contourlet 变换的高光谱图像压缩算法[J]. *计算机科学*, 2012, 39(11A):395-397.

[10] 杨家红,许灿辉,王耀南. 基于 Contourlet 广义高斯模型的纹理图像检索[J]. *中国图象图形学报*, 2007, 12(4):691-694.

[11] 王佳奕,葛玉荣. 基于 Contourlet 变换和支持向量机的纹理识别方法[J]. *计算机应用*, 2013, 33(3):677-679.

[12] 蒋玉峰,陈杰,王彦杰,等. 一种基于 Contourlet 变换的气象图像增强算法[J]. *计算机工程与应用*, 2012, 48(30):187-192.

[13] CAI T T, SILVERMAN B W. Incorporating information on neighbouring coefficients into wavelet estimation[J]. *The Indian Journal of Statistics, Series B*, 2001, 63(2):127-148.

[14] DONOHO D L. De-nosing by soft-thresholding[J]. *IEEE Trans Theory*, 1995, 41(3):613-627.

[15] 周登文,申晓留. 邻域小波系数自适应的图像降噪[J]. *中国图象图形学报*, 2008, 13(11):2112-2116.

[16] 李柯材,张曦煌. 先优化后分类改进的小波域图像去噪方法[J]. *计算机工程与应用*, 2011, 47(8):186-189.

(上接第 1263 页)

4 结束语

本文针对传统基于 Haar-like 特征的 on-line boosting 跟踪算法在特征池构建与更新时的随机性及跟踪效率较低的问题,提出了结合目标纹理信息产生更精简特征池的算法。该算法汲取了用于纹理分析的灰度共生矩阵的特点,将方向纹理熵与 Haar-like 特征类型对应起来,提出了结合方向纹理熵的 Haar-like 特征在线 boosting 跟踪算法。经实验验证,本算法具有较强的有效性和实时性,相比传统方法,本算法的鲁棒性更好,而且更具灵活性和适应性。但算法对目标遮挡问题的鲁棒性还有待提高,主要是由于算法在有遮挡时会将背景当做正样本参与训练,导致错误累积,最终跟踪丢失,半监督的学习可以有效改善这一问题^[10];另外,可以同时考虑背景和目标的纹理信息共同指导特征池的构建和更新。

参考文献:

[1] KALAL Z, MIKOLAJCZYK K, MATAS J. Tracking-learning-detection[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2012, 34(7):1409-1422.

[2] BABENKO B, MING-HSUAN Y, BELONGIE S. Robust object tracking with online multiple instance learning[J]. *IEEE Trans on*

Pattern Analysis and Machine Intelligence, 2011, 33(8):1619-1632.

[3] GRABNER H, BISCHOF H. On-line boosting and vision[C]//Proc of IEEE International Conference on Computer Vision and Pattern Recognition. 2006:260-267.

[4] SALT I S, CAVALLARO A, Di STEFANO L. Adaptive appearance modeling for video tracking: survey and evaluation[J]. *IEEE Trans on Image Processing*, 2012, 21(10):4334-4348.

[5] COMANICIU D, RAMESH V, MEER P. Real-time tracking of non-rigid objects using mean shift[C]//Proc of IEEE International Conference on Computer Vision and Pattern Recognition. 2000:142-149.

[6] SHEN Hong-ying, SUN Shui-fa. Comparative study of color feature for particle filter based object tracking[C]//Proc of IEEE International Conference on Machine Learning and Computing. 2012:1104-1110.

[7] VIOLA P, JONES M. Robust real-time object detection[J]. *International Journal of Computer Vision*, 2004, 57(2):137-154.

[8] HEIKKILA M, PIETIKAINEN M. A texturebased method for modeling the background and detecting moving objects[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2006, 28(4):657-662.

[9] BoBoT-bonn benchmark on tracking Web site [EB/OL]. <http://www.iai.uni-bonn.de/~kleind/tracking/index.html>.

[10] GRABNER H, LEISTNER C, BISCHOF H. Semi-supervised on-line boosting for robust tracking[C]//Proc of the 10th European Conference on Computer Vision. 2008:234-247.