文章编号:1001-5078(2017)06-0783-06

·图像与信号处理 ·

应用空间金字塔池化 LBP 特征的舰船检测识别

郭少军,陆 斌,娄树理

(海军航空工程学院 控制科学与工程系,山东 烟台 264001)

摘 要:传统 LBP 特征进行目标识别主要依靠局部图像 LBP 特征直方图来实现,通常只能满 足小邻域内小量采样点计算 LBP 特征的情况。当需要计算像素在更大空间邻域更多采样点 的对比纹理特征时,直方图特征的维度将会造成维数灾难。本文提出应用空间金字塔池化方 式对 LBP 特征进行池化,并在 LBP 特征计算过程中采用多种邻域尺度和不同采样点数量,充 分挖掘不同尺度下图像的纹理特征,从而建立完备的图像描述特征。在利用支持向量机或其 他训练网络进行识别模板训练时,需要输入特征集具有相同的维度,传统 LBP 算法首先对图 像按一定尺寸重构/裁切,时常会发生畸变而与现实出现偏离和信息丢失,对识别正确率存在 影响。本文通过空间金字塔尺度对任意大小图像的 LBP 特征进行池化,输出特征维度为固定 长度,有效避免了图像畸变与信息丢失的情况。实验证明,本文方法不仅避免了维度灾难的发 生,同时能够更高效地提高目标检测率和识别正确率。

关键词:空间金字塔;池化;多尺度;LBP 特征;舰船检测;舰船识别

中图分类号:TP391 文献标识码: A DOI: 10.3969/j.issn. 1001-5078.2017.06.025

Ship detection and recognition based on spatial pyramid pooling LBP feature

GUO Shao-jun, LU Bin, LOU Shu-li

(Department of Control Engineering, Navy Aeronautical Engineering University, Yantai 264001, China)

Abstract: The traditional LBP feature for target recognition mainly depends on local LBP histogram, but it is only fit for the calculation of LBP histogram features under the small neighborhoods and small sample points. When calculating the contrast of the pixels with more sampling points in larger scale, the dimension of the histogram will increase exponentially, which will result in the curse of dimensionality. In order to solve this problem, spatial pyramid pooling method is used for pooling LBP features, and LBP features are calculated by several neighborhood scales and different sampling point numbers, so as to establish a complete image feature descriptor. To train recognition template based on support vector machine (SVM) or other training network, the input feature sets need to have the same dimension, and the output characteristic dimension has fixed length, which can effectively avoid image distortion and information loss. The experiments prove that the proposed method can avoid the curse of dimensionality and improve the detection rate and recognition accuracy more efficiently.

Key words: spatial pyramid; pooling; multi-scale; LBP feature; ship detection; ship recognition

1 引 言

利用大量样本数据训练目标检测/识别模板,并

以模板为依据完成目标检测/识别具有较高的检测 率和精确度。训练模板过程中采用的特征描述算子

作者简介:郭少军(1985-),男,在读博士,主要从事计算机视觉,目标检测等方面的研究。E-mail:guoba2000@163.com 收稿日期:2016-09-02;修订日期:2016-10-21

基金项目:国家自然科学基金项目(No. 61303192)资助。

不同,检测率与精确度也会出现差异。因此,优秀的 目标特征描述算子是训练优秀检测/识别模板的基 础。一个优秀的描述算子要满足以下两个条件:

(1) 描述算子要能够完备地表现目标特性;

(2) 描述算子不能太复杂,过度复杂的描述算 子可能包含大量的信息冗余,在计算过程中会造成 资源浪费。

Ojala T^[1]提出的局部二值化特征模式(Local Binary Pattern,LBP)能够满足以上条件。LBP 特征 算子最初应用于人脸识别领域,利用图像像素与周 边邻域像素对比特性来描述局部纹理特征。LBP 算 子邻域的选择,采样点数量,特征值计算起始位置都 影响着特征向量值,为了避免特征值的不稳定, Maenpaa^[2]等人提出了 LBP 的旋转不变模式,消除 了因采样点起始位置不同造成特征值不同的影响。 改进后的 LBP 算子广泛应用于目标检测^[3-5],目标 分类^[6-9]等。为了更广泛的应用,很多学者对 LBP 进行了改进^[10-12]。

利用 LBP 进行特征模板训练需要将图像重构 或裁切成固定大小尺寸(e.g. 128×256),并将图像 分成固定大小的小图块(e.g. 16×16),然后计算小 图区域内 LBP 特征直方图,最后融合形成图像 LBP 特征描述向量。重构图像尺寸容易造成图像的变形 而与现实发生偏离,裁切图像又会丢失目标信息,这 两种方式都影响着目标识别与检测的精确度;同时 LBP 直方图特征的计算严重受到了采样点数量的约 束,采样点过多会造成特征维数灾难(采样点为16 时,直方图维度会高达216位),增加了计算冗余并 给模板训练带来过重负担,对多尺度特征获取极为 不利。为了避免 LBP 模板训练的局限性,本文提出 了对整个图像的 LBP 特征矩阵进行空间金字塔池 化(Spatial Pyramid Pooling, SPP)^[13],避免了图像的 重构或裁切,并且无论采用多少个采样点,都能够有 效地实现特征降维,避免了多尺度多采样点条件下 LBP 特征计算的维度约束与时间约束。为了描述方 便,本文缩写空间金字塔池化 LBP 特征(Spatial Pyramid Pooling LBP, SPP-LBP) 。

2 LBP 特征模板

2.1 LBP 特征模式

原始 LBP 算子是在 3×3 邻域内计算的,以邻 域中心像素值作为阈值,将邻域内 8个像素值与阈 值进行对比,大于阈值则标记为1,小于则标记为0, 从而形成8位二进制数,将二进制数转化成十进制 数值即为中心点位置的 LBP 特征值。特征值计算 公式描述为:

$$LBP(x,y) = \sum_{p=0}^{p-1} 2^p s(\operatorname{gray}(p) - \operatorname{gray}(x,y)) \quad (1)$$

仅仅使用8 邻域内像素进行对比无法获得更大 尺度上图像的特征信息,Ojala T^[1]等人对 LBP 算子 进行了改进,提出了圆形邻域内的 LBP 特征计算模 式(如图1 所示),设置不同的半径 *R* 则能够获得不 同尺度上的 LBP 特征值。尽管在大尺度上能够获 得更多的信息,然而采样点的增加使得二进制数的 长度相应增加,当采样点为 16 时,维数达到 216 位, 虽然采用"等价模式"^[1]能够将模式数量大量减 少,但将多种模式融合为一种表示形式可能会造成 信息丢失。



LBP 圆形模式计算特征值存在多种可能,以 8 个采样点为例,二进制数存在 8 中排列顺序而有 8 种特征值。Maenpaa^[14]等人提出选择多种模式中数 值最小的作为当前特征值,因此也避免了采样点起 始点不同造成的数值变化,这种选择模式成为 LBP 旋转不变模式。原理示意图如图 2 所示。



2.2 LBP 特征模板训练

LBP 特征模板的训练,需要样本特征集和训练 网络,通常使用支持向量机(Support Vector Machine,SVM)。训练过程中要求样本特征向量长度 一致。在传统 LBP 特征模板训练过程中,首先将 样本图像重构或裁切成固定尺寸,然后将重构或 裁切后的图像按照一定尺寸分成小图块,对每个 图块进行 LBP 特征值计算并计算区域 LBP 特征值 直方图,即计算区域图像内各种模式特征值的出 现次数,采样点数量不同特征直方图的维度也会 不同。通常情况下为了避免维度过大采用0~2⁸ 作为直方图范围,也限定了采样点数不宜大于8。 如果采用图1 中第三种模式则直方图取值范围扩 大为0~2¹⁶,维数呈指数增加,必然给计算和训练 带来过重负担。

LBP 模板训练特征集计算需要将样本图像重构 或者裁切,从而使输出特征向量达到固定长度,这样 可能造成图像畸变或信息缺失,这两种情况都会导 致目标识别或检测正确的下降,为了避免这种影响, 本文提出了 SPP-LBP 算子,有效解决了 LBP 算子造 成图像畸变或信息丢失的情况,同时"池化"的优秀 表现避免了 LBP 区域特征直方图维数过大带来的 维数灾难。





- 3 SPP-LBP 特征模板
- 3.1 SPP-LBP 特征计算

针对 LBP 小图像块尺寸固定的情况,本文提出 利用空间金字塔结构对图像 LBP 特征矩阵进行 2"×2"分割,分割后动态确定小图块的尺寸。空间 金字塔分割的好处在于对任意尺寸的图像最终分割 得到的图像块数量是相同的。为了使特征更加完备, 通常将 n 设为多个值,计算多尺度特征并进行融合。

SPP-LBP 是基于 LBP 计算模式进行的,不同 于 LBP 特征计算在于:(1) LBP 特征计算是先将图 像进行分割再进行特征计算,而 SPP-LBP 是先在 全图范围内计算每个像素点的 LBP 值,然后进行 分割,再对分割的区域进行特征"池化"处理;(2) LBP 特征计算的区域图块尺寸是固定的,而 SPP-LBP 的区域图块尺寸随输入图像的大小不同而改 变;(3) LBP 特征的局部直方图模式采样点数量因 维度问题受到约束,而 SPP-LBP 没有这方面的 顾虑。

时间复杂度方面,LBP的时间复杂度为 $O(2^n)$,SPP-LBP的时间复杂度为 $O(n^2)$,SPP-LBP的时间复杂度为 $O(n^2)$,SPP-LBP多尺度特征计算具有更高的效率。LBP算子特征计算与SPP-LBP特征计算过程对比如图4所示。



图 4 LBP 特征向量计算流程与 SPP-LBP 特征向量计算流程 Fig. 4 Flow chart of LBP feature computation and Flow chart of SPP-LBP feature computation

从图 4 中不难理解 SPP-LBP 特征的计算过程, 本文在大场景中进行目标检测时,利用 SPP-LBP 特 征的计算特点,首先对整幅场景图进行多模式 LBP 特征计算,再依据 Objectness BING^[16-17]对场景进行 候选目标提取。对于候选目标区域特征,无需再次 计算 LBP 特征,直接从整幅图像的 LBP 特征矩阵中 获得对应矩阵块作为 SPP-LBP 的输入即可。利用 SPP-LBP 的这个特点, m 个候选窗口只需在全图范 围内计算一次 LBP 特征矩阵, 而原始 LBP 特征计算 由于存在重构/裁切等操作,需要 m 次重构/裁切和 m次LBP特征矩阵计算。检测过程中,SPP-LBP采 用LBP⁸₂,LBP⁸₃,LBP¹⁶ 三种模式训练LBP 多尺度特 征模板,平均每个候选窗口检测识别耗时为 0.769 s,LBP 采用 LBP⁸ 模式进行检测,平均每个候 选窗口检测识别耗时为0.71 s。从耗时来看, SPP-LBP 不仅覆盖了更多的特征信息,且运算效率要远 远高于原始 LBP。

3.2 SPP-LBP 多尺度特征

SPP-LBP 的多尺度包括两个方面:(1)在计算 全图像 LBP 特征时,采用多种邻域尺度进行 LBP 特 征计算,并且通过采用不同数量的邻域内采样点获 得不同尺度上的 LBP 特征映射矩阵,这一方面的多 尺度特性主要体现在对图 1 所示的多种圆形 LBP 模式的应用;(2)对计算获得的 LBP 特征映射矩阵 进行空间金字塔池化,空间金字塔尺度采用 2"来进 行图像的尺度划分。空间金字塔池化图像特征如图 5 所示。



图 5 中 d 为采用图 1 中模式的个数, d 越大,获 得的目标特征越多, 使得特征描述子更加完备。在 对 LBP 特征矩阵进行金字塔池化过程中, n 的取值 越大, 划分的区域图像块越细,获得的特征也越细 致, 通常采用的 n 取值范围要尽量满足特征完备性 的要求。

4 实验与分析

实验使用 CPU Intel(R) Core(TM) i5 - 3317U CPU 的计算机和 VS2012 Pro 进行编程计算,训练和 实验图像采用互联网下载各种舰船图片作为正样 本,场景中非舰船区域作为负样本进行样本特征集 计算,并利用支持向量机对特征集进行训练获得舰 船检测/识别模板。实验中以检测率,虚警率,正确 率和错误率为指标对算法进行评测,等式(2)是几 个评价指标的计算方法。

$$Dr = \frac{\text{target}_{\text{detect}}}{\text{target}_{\text{sum}}} \times 100\%$$

$$False_alarm = \frac{F_{\text{detect}}}{Test_{\text{sum}}} \times 100\%$$

$$Rr = \frac{R_{\text{reg}}}{\text{sum}_{\text{reg}}} \times 100\%$$

$$Er = \frac{E_{\text{reg}}}{\text{sum}_{\text{reg}}} \times 100\%$$
(2)

其中,Dr 为舰船目标检测率;target_{detect}为正确检 测的目标数;target_{sum}为目标总数;False_alarm 为虚 警率;F_{detect}为错误检测为目标的数量;test_{sum}为测试 图像总数;Rr 为识别正确率;R_{reg}为正确识别的数 量;sum_{reg}为识别图像总数;Er 为错误率;E_{reg}为错误 识别数量。

实验中,参数设置为 n =1~5,LBP 特征计算采 用旋转不变圆形模式,采用图 1 所示集中模式算子 进行 LBP 特征计算,对获得特征集采用 SVM 进行 训练,为了保证训练获得模板的推广实用性,采用了 交叉验证^[15]的方法对 SVM 训练参数进行优化。在 舰船目标检测过程中,采用 Objectness BING^[16-17]进 行候选目标提取。

图 6 是 SPP-LBP 与 LBP 特征在数据集中进行 检测识别的评测参数曲线。从曲线对比中发现, SPP-LBP 特征模板的正确率要远远高于 LBP;在舰 船目标检测率方面,SPP-LBP 要略优于 LBP;LBP 的 虚警率和错误率较高,SPP-LBP 虚警率和错误率则 控制在较低的范围内。四个指标曲线一致表明,在 LBP 的基础上改进的 SPP-LBP 特征在目标检测与 识别方面具有了更强大的能力。



利用 SPP-LBP 训练舰船模板进行的目标检测 部分结果如图 7 所示。从图中发现,在 Objectness BING 候选窗口中,具有一定成像面积的舰船目 标,SP-LBP 能够准确地识别,如图中方框标记区 域,对于成像面积较小,纹理特征不够丰富的图像 目标,SPP-LBP 模板存在漏检的情况,如图 7 中第 三行最后一列图像中存在舰船目标漏检,同时,由 于浪花等背景干扰因素的存在,SPP-LBP 受到了一 定的干扰,检测目标标记方框位置存在一定程度 的偏差。



图 7 结合 Objectness BING 候选窗口 SPP-LBP 的舰船检测部分结果图像

Fig. 7 The bonding results of ship target associate with SPP-LBP and Objectness BING

在目标检测过程中,SPP-LBP 特征的计算模式 使得输入场景图像只需要进行单次 LBP 模式特征 计算,对于场景中候选目标区域 LBP 特征则只需 要在场景 LBP 特征中找到对应坐标位置即可获 取,极大限度减少了候选图像区域 LBP 特征计算 次数,有效提高了计算效率,在采用三尺度 SPP-LBP 特征进行目标检测过程中,单窗口检测耗时 为 0.769 s,LBP 单尺度特征模板单窗口检测耗 时为 0.71 s,充分显示了 SPP-LBP 特征的高 效性。

尽管 SPP-LBP 特征在原 LBP 基础上有了很大

的改进,但对场景中目标区域检测还存在一定的偏差和漏检,需要进一步完善特征算子对浪花等干扰因素的免疫能力,提高弱小成像目标的检测能力。

5 总结与展望

文章针对 LBP 特征的不足进行改进,引入了 空间金字塔池化的思想,将传统固定尺寸图像的 LBP 特征计算模式改进为动态尺寸计算模式。避 免了特征计算前图像重构或裁切带来的目标畸变 或信息丢失,通过池化特征避免了传统 LBP 多尺 度特征可能带来的维数灾难,在复杂度可控范围 内,极大可能地挖掘了目标图像特征,使特征更加 完备。

参考文献:

- [1] Ojala T, Pietikainen M, Harwood D. Performance evaluation of texture measures with classification based on Kullback discrimination of distributions [C]// Iapr International Conference on Pattern Recognition, 1994. Vol. 1 Conference A: Computer Vision & Image Processing. IEEE, 1994, 1:582 585.
- [2] Maenpaa T, Pietikainen M, Viertola J. Separating color and pattern information for color texture discrimination [C]// 16 Th International Conference on Pattern Recognition, IEEE, 2002:668-671.
- [3] Heng C K, Yokomitsu S, Matsumoto Y, et al. Shrink boost for selecting multi-LBP histogram features in object detection [C]// IEEE Conference on Computer Vision and Pattern Recognition, 2012:3250 - 3257.
- [4] Tran Nguyen Ngoc. An efficient LBP-based descriptor for real-time object detection [C]// Computational Intelligence for Security and Defense Applications (CISDA), 2014 Seventh IEEE Symposium on, IEEE, 2014:1-5.
- [5] Shen J, Sun C, Yang W, et al. A novel distribution-based feature for rapid object detection [J]. Neurocomputing, 2011,74(17):2767-2779.
- [6] Murty G S, Kumar V V, Obulesu A. Age classification based on simple IBP transitions [J]. International Journal on Computer Science & Engineering, 2013, 5 (10): 885-893.
- [7] Gunay A, Nabiyev V V. Automatic age classification with LBP[C]// International Symposium on Computer and Information Sciences, 2008:1-4.

- [8] Le H T, Ha D T T. Facial expression representation and classification using 2DPCA [C]// International Conference on Control, Automation and Information Sciences. 2012;42-47.
- [9] Yu W, Gan L, Yang S, et al. An improved LBP algorithm for texture and face classification [J]. Signal Image & Video Processing, 2014, 8(S1):155 - 161.
- [10] X Wang, T X Han, S Yan. An HOG-LBP human detector with partial occlusion handling[J]. Proceedings, 2009, 30 (2):32-39.
- [11] Lambert J C, Goumidi L, Vrièze W D, et al. The transcriptional factor LBP-1c/CP2/LSF gene on chromosome 12 is a genetic determinant of Alzheimer's disease. [J]. Human Molecular Genetics, 2000, 9(15):2275 2280.
- [12] Bingle C D, Craven C J. Meet the relatives: a family of BPI-and LBP-related proteins[J]. Trends in Immunology, 2004,25(2):53-55.
- [13] He K, Zhang X, Ren S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J].
 IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 37(9):1904 - 16.

- [14] Maenpaa T, Pietikainen M, Viertola J. Separating color and pattern information for color texture discrimination [C]// 16 Th International Conference on Pattern Recognition, IEEE, 2002:668 - 671.
- [15] Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection [C]// International Joint Conference on Artificial Intelligence, 2001: 1137-1143.
- [16] GUO Shaojun, SHEN Tongsheng, XU Jian, et al. Detection of multi-ship targets at sea based on ObjectNess BING
 [J]. Systems Engineering and Electronics, 2016, 38(1): 14-20. (in Chinese)
 郭少军,沈同圣,徐健,等. 基于 ObjectNess BING 的海 面多舰船目标检测[J]. 系统工程与电子技术, 2016, 38(1):14-20.
- [17] Cheng M M, Zhang Z, Lin W Y, et al. BING: Binarized normed gradients for objectness estimation at 300 fps
 [C]// Computer Vision and Pattern Recognition (CVPR), 2014 IEEE Conference on IEEE, 2014: 3286-3293.