

BSFCoS: 基于分块与稀疏主特征提取的快速协同显著性检测

周培云 李 静 沈宁敏 庄 毅

(南京航空航天大学计算机科学与技术学院 南京 210016)

摘 要 随着图像采集技术的迅速发展,原始数字图像越来越清晰,已有的协同显著性检测方法在处理这些图像时所需的计算机内存也越来越大,并且伴随着很高的计算复杂性,严重影响了人机交互的实时性。因此,迫切需要一种快速的协同显著性检测方法。提出了一种基于图像分块与稀疏主特征提取的快速协同显著性检测方法(BSFCoS)。该方法在将图像均匀分割成若干个图像块的基础上,从Lab和RGB两种颜色空间上抽取底层特征,再使用截断幂(Truncated Power)的稀疏主成分分析方法进行稀疏主特征提取,以达到在最大程度保留原图像特征的同时减少特征点的数量与属性个数的效果。然后使用K-Means对提取的稀疏主特征进行聚类,并在聚类结果的基础上进行3种基于聚类的显著特征权值的计算。最后,将通过特征融合生成的单幅图像显著图和多幅图像显著图进行组合,以生成协同显著图。在Co-saliency Pairs与CMU Cornell iCoseg两个标准数据集上进行了实验仿真,实验结果表明,与其他协同显著性检测方法相比,BSFCoS在保证检测效果的同时大幅提高了针对多幅图像的协同显著性检测的速度。

关键词 显著性检测,快速,协同显著性,截断幂,K-Means

中图分类号 TP751.1 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.8.062

BSFCoS: Fast Co-saliency Detection Based on Block and Sparse Principal Feature Extraction

ZHOU Pei-yun LI Jing SHEN Ning-min ZHUANG Yi

(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract With the rapid development of image acquisition technology, the original digital images are increasing and becoming more and more clear. When processing these images, the existing co-saliency detection methods need enormous computer memory along with high computational complexity. These limitations make it hard to satisfy the demand of real-time user interaction. This paper proposed a fast co-saliency detection method based on the image block method and sparse principal feature extraction method. Firstly, the image is averagely divided into several uniform blocks, and the low-level features are extracted from Lab and RGB color spaces. Then truncated power and parse principal components method are proposed to extract sparse principal features, which can remain the characteristics of the original image to the maximum extent and reduce the number of feature points and attributes. Furthermore, K-Means method is adopted to cluster the extracted sparse principal features, and calculate the three salient feature weights. Finally, the saliency map of the single image and that of multi images which are generated by feature fusion are combined to generate co-saliency map. The proposed method was tested and simulated on two benchmark datasets: Co-saliency Pairs and CMU Cornell iCoseg datasets. And the experimental results demonstrate that BSFCoS has better effectiveness and efficiency on multiple images compared with the existing co-saliency methods.

Keywords Saliency detection, Fast, Co-saliency, Truncated power, K-Means

1 引言

显著性检测的研究是通过模拟人的视觉注意力机制来预测人的注意力^[1]。在过去的十多年中,研究者们提出了许多针对单幅图像的显著性检测方法,并且将其大量用于显著目标检测与分割、图像检索等应用^[2]。协同显著性检测是从一组图像中发现其间共有的显著性目标,对目标协同分割与协同识别等研究具有重要的作用,是近年来显著性检

测中一个比较新颖的研究领域^[3-7]。与针对单幅图像的显著性检测方法相比,协同显著性检测方法考虑了不同图像间的关联,突出强调在一组图像中同时存在的共有的显著目标。作为协同显著性检测的输出——协同显著图可以被用于目标的协同分割、协同定位和图像检索^[8,9],也是互联网视觉媒体检索的关键^[10,11]。

图1给出了一个协同显著性检测的例子。原图中蝴蝶作为协同显著目标被检测出。

到稿日期:2014-09-28 返修日期:2014-12-08 本文受中央高校基本科研业务费专项资金(NZ2013306)资助。

周培云(1990-),男,硕士生,主要研究领域为数据挖掘、图像处理,E-mail:zhoupeiyun@nuaa.edu.cn;李静(1976-),女,博士,副教授,主要研究领域为数据挖掘、可信软件与并行计算,E-mail:lijing@nuaa.edu.cn;沈宁敏(1991-),男,硕士生,主要研究领域为数据挖掘、图像处理,E-mail:ningminshen@163.com;庄毅(1956-),女,教授,博士生导师,主要研究领域为分布式计算,E-mail:zhuangyi@nuaa.edu.cn。



图1 协同显著性检测示例

Jacobs^[3]对从同一场景中捕获的一对图像中的每个像素点进行特征分析,再利用由显著目标引起的图像局部结构变化来进行协同显著性检测。这个方法需要该对图像具有高度相似的背景。Chen^[4]通过计算 K-L 散度来衡量两幅图像间所有预注意力块的相似程度(这里的预注意力块并不是均匀分块,而是以图像中所有的像素点为中心取块),但该分块方法在增加了样本属性的同时也大幅增加了计算复杂性。Li^[5]提出了使用复杂协同多分子层图像方法将 3 种单一图像的显著性和协同显著性图像进行线性组合,该方法使用超像素块来代替原始像素点进行相似度计算,虽然使用超像素块能够有效减少样本点的个数,但是进行超像素分块处理和 3 种针对单幅图像进行的显著性检测方法使该方法具有较高的时间复杂性。与文献[3-5]的方法只能运用在两幅图像上相比,文献[6,7]的方法可以处理两幅以上的图像。Chang^[6]同样使用了超像素技术,首先为每一幅图像分别生成显著图,然后将大多数图像中频繁出现的显著性部分作为协同显著区域。Fu^[7]对输入图像的所有原始像素点进行聚类,综合了对比特征、空间特征和相似特征来检测聚类级的协同显著性。由于该方法聚类时针对原始图像中的每一个像素点,因此随着输入图像数量的增加,因聚类而带来的耗时也不断增加。

从上述研究中可以看出,从多幅图像中快速检测出共同的显著性目标是当前需要解决的一个问题。针对于此,本文提出了 BSFCoS 方法——快速协同显著性检测方法。本文第 2 节对 BSFCoS 方法进行了介绍;第 3 节将 BSFCoS 与其他协同显著性检测方法在两个标准数据集上进行实验仿真与性能分析;最后对本文的工作做了总结并提出下一步的研究方向。

2 本文方法

图 2 给出了 BSFCoS 方法的结构框架。

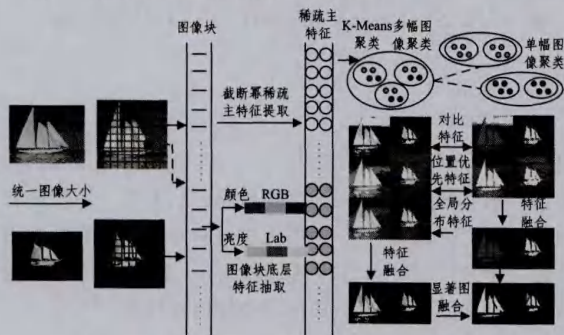


图2 BSFCoS 方法框架

该方法主要包括图像分块与底层特征抽取、稀疏主特征提取、基于聚类的特征计算和协同显著图生成 4 个部分。首先,对已统一大小的图像进行均匀分块,从 Lab 和 RGB 两种颜色空间进行底层特征抽取来构成图像块底层特征矩阵。然后,通过截断幂稀疏主成分分析方法对图像块底层特征矩阵进行稀疏主成分分析,提取图像块的稀疏主特征。使用

K-Means对获得的图像块稀疏特征进行聚类,计算 3 种基于聚类的显著性特征权值。最后,对通过特征融合生成的单幅图像显著图和多幅图像显著图进行组合,以生成协同显著图。

2.1 图像分块与底层特征抽取

如果图像中一个区域为显著区域,那么该图像中该区域至少有一种特征与其周围环境不同。因此提取图像的各种不同底层视觉特征更加有助于显著性区域的检测。BSFCoS 选用 Lab 和 RGB 两种颜色空间,同时考虑亮度和颜色两种底层视觉特征。虽然 Lab 颜色空间可以同时表示亮度和颜色两种特征,但是 Lab 颜色空间侧重于对颜色亮度的表示,而 RGB 颜色空间则擅长于对自然界中各种色彩的表示。

对于每一幅待检测的图像,可将其视为一个矩阵来处理。首先将图像均匀分成若干个图像块,然后对每个图像块进行底层特征的抽取,每个图像块中抽取的所有底层特征用行向量表示,所有图像块存储为列向量,构成一个图像块底层特征矩阵。当抽取多幅图像间的底层特征时,将所有的输入图像构成一个大的矩阵。

假设每一组输入图像有 M 幅,且对于一幅像素大小为 $I_x \times I_y$ 的图像 $I_k, k=1, 2, \dots, M$,将其分成 $p \times q$ 个像素大小为 $m \times n$ 的图像块。即

$$I_k = \begin{pmatrix} (I_k)_{11} & \cdots & (I_k)_{1q} \\ \vdots & \ddots & \vdots \\ (I_k)_{p1} & \cdots & (I_k)_{pq} \end{pmatrix} \quad (1)$$

式中,每个图像块 $(I_k)_{ij} (i=1, 2, \dots, p; j=1, 2, \dots, q)$ 都是 $m \times n$ 大小的图像矩阵,且 $I_x = p \times m, I_y = q \times n$ 。图像均匀分块后,每个图像块像素大小相等,且单独从 Lab 和 RGB 两种颜色空间进行底层特征的抽取,将每个图像块中抽取到的所有底层特征用行向量表示。

$$\text{即对于图像 } I_k \text{ 有 } A_k = \begin{pmatrix} (I_k)_1 \\ (I_k)_2 \\ \vdots \\ (I_k)_K \end{pmatrix} \in R^{K \times N}, \text{ 其中, } N = m \times$$

$n \times f, K = p \times q, f$ 为从每个像素点抽取的底层特征数。当抽取多幅图像底层特征时,将所有图像存在一个大矩阵中,即

$$A = \begin{pmatrix} A_1 \\ A_2 \\ \vdots \\ A_M \end{pmatrix} \in R^{M \times N}.$$

2.2 稀疏主特征提取

通过对输入的原始图像进行图像均匀分块和底层特征抽取的操作后,接着使用截断幂方法在抽取的底层特征上进行稀疏主成分分析,提取稀疏主特征。

2.2.1 截断幂稀疏主成分分析

主成分分析(principal component analysis)是一种经典的数据降维方法,通过数据变换方法将原数据集映射到低维空间,在不损失精度的前提下,使得提取的主成分可以更好地对数据的结构分布进行分析^[12]。因此,主成分分析在降维和数据处理方面得到了广泛的应用,如手写数字的识别、人脸识别和基因表达数据处理等。

可解释方差率(percent explained variance)表示所定义的主成分在整个数据分析中承担的主要意义所占的比重。当取前 r 个主成分来代替原来全部变量时,累计可解释方差率的

大小反映了这种取代的可靠性,累计可解释率越大,可靠性越大;反之,则可靠性越小。一般要求累计可解释率达到70%以上。

但是在主成分分析中,新的主成分是所有原始变量的线性组合,每个变量的权值大小不一且都不为0,使得提取出的主成分的解释能力较差。为了解决这一问题,研究者们在主成分分析中引入“稀疏性”,对所求的负载因子(Loadings)进行稀疏化处理,其目的在于最大化方差的同时保证主成分由个别的变量决定,以增强主成分的可解释性。给定一个数据集 $A \in R^{n \times m}$, n 个样本, m 个属性,稀疏主成分的求解模型如式(2)所示。

$$\begin{aligned} x^* = \arg \max x^T \Sigma x \\ \text{subject to } \|x^T x\| = 1 \text{ and } \|x\|_0 \leq k \end{aligned} \quad (2)$$

式中, x^* 是所求的稀疏负载因子, Σ 为协方差矩阵,负载因子的稀疏程度由参数 k ($k > 0$) 决定, $\|\cdot\|_0$ 为 0-范数,表示向量中非零个数的总和。

稀疏主成分的模型求解是一个非凸优化问题,求解方法可以大致分为阈值压缩、近似回归、正定规划、局部优化和幂收缩^[13]。综合考虑求解主成分的可解释能力、负载因子的稀疏度和算法的运行时间3个因素,本文选用截断幂方法^[14]对图像块底层特征矩阵进行稀疏主特征提取。截断幂方法结合幂迭代和矩阵收缩求解稀疏主成分,表1^[15]描述了截断幂方法的计算流程,在每次迭代过程中,应用幂方法求解主成分负载因子,然后根据定义的截断算子(见式(3))对其进行稀疏化处理。

$$\text{Truncate}(x, F) = \begin{cases} [x]_i, & i \in F \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

式中, F 是向量下标的集合,指示每个系数向量的非零位置, $\|F\|_0 \leq n$ 。当一个主成分的求解迭代结束之后,对 x_i 进行单位化,即可得到稀疏主成分对应的负载因子,在每一个主成分确定之后,根据式(4)对协方差矩阵进行收缩操作^[16]。

$$\Sigma' = (I_{p \times p} - x^* x^{*T}) \Sigma (I_{p \times p} - x^* x^{*T}) \quad (4)$$

当所有的负载因子都确定之后,即可得到一个稀疏向量集合 $x = \{x^1, x^2, \dots, x^m\}$, 将其作为稀疏主特征提取的调优参数。

表1 截断幂方法

Input: 一个数据集 $A \in R^{n \times p}$, 包含 n 个样本和 p 个属性, 协方差矩阵 $\Sigma \in R^{p \times p}$, 主成分的个数为 m , 各个主成分的非零个数为 $k \in \{k_1, k_2, \dots, k_m\}$ 。
Output: 稀疏负载因子向量集合 $x = \{x^1, x^2, \dots, x^m\}$ 。
for $i = 1:m$
{
初始化 $x_0^i = 1$, 迭代次数 $t = 1$;
do{
1. 使用幂方法计算 $x_i^t = \Sigma x_{i-1}^t / \ \Sigma x_{i-1}^t\ $;
2. 按大小顺序统计 x_i^t 绝对值最大的前 k 个下标集合 F_i ;
3. 使用截断算子 $x_i^t = \text{truncated}[x_i^t, F_i]$ 对 x_i^t 进行稀疏;
4. 单位化 $x_i^t, x_i^t = x_i^t / \ x_i^t\ , t = t + 1$;
}while (!收敛);
对协方差矩阵 Σ 进行收缩更新, $\Sigma = (I - x_i^t x_i^{tT}) \Sigma (I - x_i^t x_i^{tT}), I \in R^{p \times p}$ 。
}

2.2.2 确定稀疏处理参数方案

图像块数据可描述为一个矩阵 $A(n \times p)$, $a(i, j)$ 表示第 i 个样本的第 j 个属性。稀疏处理参数方案的确定有3个主要步骤:

步骤1 对输入的数据进行标准化。计算样本间的协方差矩阵 $\Sigma(p \times p)$, Σ_{ij} 表示第 i 个样本和第 j 个样本间的相关性。

步骤2 使用PCA计算协方差矩阵的特征值 Σ , 并且按降序进行排序。每个特征值 λ_i 决定了相对应的主成分的贡献度。主成分的个数与它们的累计贡献率有关, 前 k 个主成分的累积贡献率的计算如式(5)所示:

$$\sum_{i=1}^k \lambda_i / \sum_{j=1}^p \lambda_j \geq \epsilon \quad (5)$$

满足条件的最小 k 值就是主成分的个数。

步骤3 在使用截断幂方法的稀疏主成分分析中存在的一个主要问题是每个主成分的非零数值需要事先指定, 因此BSFCoS使用一种局部迭代搜索的方法来平衡方差与稀疏度, 以确定调优参数。首先, 一个方差阈值 δ 被给定, 第 i 个稀疏主成分的方差范围为 $(\text{pev}_i - \delta, \text{pev}_i + \delta)$, pev_i 是第 i 个主成分的方差。然后, 根据对应的负载因子 (l_1, l_2) , 每个主成分的非零个数的上限 ϕ 和下限 φ 能被近似地计算出来, 因为方差 $\text{pev}(i) = R_i^2 / \text{tr}(A^T A)$ 。同时, 稀疏主成分 $Z_i = Q_i R_i$, 所以负载因子可以被计算, $l_i = Z_i A^{-1}, i = 1, 2$ 。最后, 在每个稀疏主成分的非零个数范围 $[\phi, \varphi]$ 内进行局部搜索, 当满足 $|\text{pev}(t) - \text{pev}| < \xi$ 时, 则非零个数的最佳参数值被确定。

2.2.3 特征提取

稀疏主特征提取后, 使用截断幂方法的稀疏主成分分析对抽取的图像底层特征进行降维并求取主成分。利用稀疏主成分分析获取稀疏负载因子 X , 稀疏主特征 $Z = A \times X, Z \in R^{n \times m}$ 。

2.3 基于聚类的显著性特征计算

对于显著性特征的计算, 本文在Fu^[7]的基于聚类的显著性特征计算方法的基础上进行了改进。利用图像的稀疏主特征, 分别进行单幅图像与多幅图像两层聚类, 并在聚类的结果上进行显著性特征计算。

当获得单幅图像与多幅图像的 m -D 稀疏主特征 $Z =$

$$\begin{cases} z_1 \\ z_2 \\ \vdots \\ z_n \end{cases} \in R^{n \times m} \text{ 后, 利用经典的 K-Means 算法将所有的块聚成 } k$$

个聚类(cluster), 稀疏特征相似的块被聚到一个聚类中, 并计算得到 k 个聚类中心 $C = \{c_1, c_2, \dots, c_k\}$ 。

2.3.1 对比特征

对比特征是在单幅图像显著性检测算法中检测显著性最常用的特征之一。与Fu的工作相同, 为每个聚类 C^k 计算其对应的对比特征权值 $w^c(k)$ 。

2.3.2 位置优先特征

在人类的视觉系统里, 越靠近图像中心的区域往往比其他区域更能够吸引我们的注意力; 越到图像的边缘, 其吸引力越低。因此基于各个像素点到图像中心的距离, 可以使用高斯分布函数(见式(6))生成位置优先图, 如图3所示。

$$p(x) = e^{-\frac{d(x, \omega)}{\sigma^2}} \quad (6)$$

将这个概念运用到聚类级的位置优先特征的计算中。聚类 C^k 的位置优先特征 $w^l(k)$ 的求解如式(7)所示:

$$w^l(k) = \frac{1}{n^k} \sum_{j=1}^M \sum_{i=1}^{N_j} [N(\|z_i^j - \omega^k\|_2 | 0, \sigma^2)] \quad (7)$$

其中, o^j 表示图像 I^j 的中心, 变量 σ^2 是图像的标准半径, n^k 表示类 C^k 中图像块的个数。根据图像块 z_i^k 到图像 I^j 中心 o^j 的空间距离, 利用高斯函数 $N(\cdot)$ 计算位置优先特征权值。包含图像块数越多且距离图像中心越近的聚类将得到越大的位置优先特征权值。




图3 位置优先图

2.3.3 全局分布特征

与对比特征和位置优先特征不同, 全局分布特征用来衡量各个聚类在多幅图像中是如何分布的。它是协同显著性一个重要的全局指标。实际上, 在图像间的聚类基本上保持着在多幅图像上的全局一致性。因此, 本文使用各个聚类的全局分布的变化描述各个聚类在多幅图像中的分布情况。

在使用 Fu 的方法计算聚类 C^k 的全局分布特征权值 $w^d(k)$ 的基础上进一步增强全局分布特征的重要性(见式(8))。

$$w^d(i) = 2 * w^d(i), w^d(i) = \max\{w^d(j)\}_{j=1}^K \quad (8)$$

当一个聚类中的图像块在每一幅图像中的分布越均匀时, 这个聚类将得到越大的全局分布特征权值。

2.4 协同显著图生成

上面介绍了3种自底向上的显著性特征。每个特征单独使用, 既有优势也有不足。这里使用与 Fu 相似的特征融合方法完成协同显著图的生成。

表2 BSFCoS 方法

Input:	一组输入图像 $\{I_k\}_{k=1}^M$, 稀疏处理参数, 单幅图像聚类数 k_1 以及多幅图像聚类数 k_2 。
Output:	一组协同显著图。
1. 单幅图像显著性检测	
for $i=1:M$	
{	
(1) 对图像 I_k 进行均匀分块, 并对每个图像块从 Lab 和 RGB 两种颜色空间进行底层特征的抽取, 以此构成图像块的底层特征矩阵 A_k ;	
(2) 使用截断幂方法对 A_k 进行稀疏主成分分析, 提取稀疏主特征 Z_k ;	
(3) 使用 K-Means 算法将 Z_k 聚成 k_1 个聚类 $\{C^k\}_{k=1}^{k_1}$;	
(4) 为每个聚类 C^k 计算对比特征权值 $w^c(k)$ 与位置优先特征权值 $w^l(k)$;	
(5) 融合对比特征权值与位置优先特征权值生成单幅图像显著图。	
}	
2. 多幅图像显著性检测	
(1) 构成所有输入图像块的底层特征矩阵 A ;	
(2) 使用截断幂方法对 A 进行稀疏主成分分析, 提取稀疏主特征 Z ;	
(3) 使用 K-Means 算法将 Z 聚成 k_2 个聚类 $\{C^k\}_{k=1}^{k_2}$;	
(4) 为每个聚类 C^k 计算对比特征权值 $w^c(k)$ 、位置优先特征权值 $w^l(k)$ 与全局分布特征权值 $w^d(k)$;	
(5) 融合对比特征权值、位置优先特征权值与全局分布特征权值生成多幅图像显著图;	
(6) 组合单幅图像显著图与多幅图像显著图生成协同显著图。	

在融合这个特征之前, 利用标准的高斯归一化函数让每个特征的值分布到每个类中。然后一个聚类级的类 k 的协同显著概率 $p(k)$ 定义为:

$$p(C^k) = w^c(k) * w^l(k) * w^d(k) \quad (9)$$

到此, 离散分布的聚类级协同显著值已经计算完成。然后将协同显著特征权值赋予每个图像块, 再通过图像块还原

出每个像素点的显著特征权值, 获得最终像素级的协同显著图。算法框架如图2所示。表2对本文提出的 BSFCoS 方法进行了总结。

3 实验仿真与分析

实验在 Intel Core™ i3-3220 处理器、4GB 内存的硬件环境下进行。操作系统为 Microsoft Windows 7, 实验仿真环境是 Matlab 2008a。为了验证上述方法的有效性, 在 Co-saliency Pairs^[5] 与 CMU Cornell iCoseg^[17] 这两个标准数据集上进行实验验证, 通过考察显著图与基于显著图的分割图显示目标的效率来评价方法的性能, 与已公开实验代码的 Li^[5] (只比较处理两幅图像) 和 Fu^[7] 的方法进行分析比较。其中 Co-saliency Pairs 数据集包含 105 组共 210 幅图像, CMU Cornell iCoseg 数据集包含 38 组共 643 幅图像(每个目标类包含有 5 至 41 幅不等的图像)。为了便于计算与处理, 将所有输入的图像统一为 200×200 的大小, 图像块大小取 4×4 。

3.1 确定稀疏处理参数

首先, 在两个标准数据集中随机选取 100 幅图像, 使用 2.2.2 节描述的方法分别对这些图像生成的图像底层特征矩阵进行分析, 确定稀疏化参数。

对 100 幅图像处理的结果如图4、图5所示, 随着主成分个数的增加, 主成分的可解释率也越来越低, 当主成分个数超过 3 时, 可解释率的值几乎为 0。因此, 在后续应用稀疏主成分分析时, 提取的主成分个数为 3, 其累计可解释率为 0.9894。当提取的主成分个数确定后, 再调节负载因子的非零个数。前 3 个主成分的非零个数调节基本呈上升趋势, 当达到一定的数量时可解释力的值基本不变, 因此, 将各个主成分负载因子中的非零个数确定为 16。




图4 主成分个数与可解释率的关系




图5 非零个数与可解释率的关系

此外, 对于单幅图像内的聚类, 使用一个固定值 $k_1 = 6$, 对于一组图像间的聚类, 令 $k_2 = \min\{\max\{2 * M, 10\}, 30\}$, 其中 M 表示这组图像中图像的数量。

本文主要针对协同显著性检测的检测效果与计算处理时间两个方面设计实验。实验包括主观上对协同显著图的观察、客观上 PR 曲线 (Precision-Recall Curve) 与 F_β 值的计算, 以及各方法在处理时间上的比较。

这里给出查准率(Precision, P)与查全率(Recall, R)的计算,如式(10)所示。

$$P = \frac{\text{sum}(S, A)}{\text{sum}(S)}, R = \frac{\text{sum}(S, A)}{\text{sum}(A)} \quad (10)$$

其中, $\text{sum}(S, A)$ 表示显著图 S 和人工分割图 A 对应像素点的值相乘后的和, $\text{sum}(S)$ 、 $\text{sum}(A)$ 分别表示显著图 S 和人工分割图 A 所有像素点的值之和。查全率与查准率有互逆的关系。 P 、 R 值越大,显著图显示目标的绝对效率越高。

3.2 协同检测性能对比

对于主观上的比较,图6、图7分别为一些从两个数据集中生成的协同显著图。为了公平起见,这些显著图都已经被规范化到 $[0, 255]$ 。从图中可以看出,本文的协同显著图能够完整地地标出协同显著目标,边界清晰并且抑制了背景区域,相比 L_i 和 F_u 的协同显著图依然保持着良好的检测效果。




图6 针对 CP 数据集的协同显著性检测实验

对于客观上的比较,对给定的灰度值在 $[0, 255]$ 范围内的显著图进行固定阈值分割,阈值范围为 $[0, 255]$ 。当阈值从0变化到255时,可以得到多组不同的查准率和查全率,并且能够画出一条PR曲线。最终的PR曲线通过平均所有的测试图像的结果得到。

在另一个实验中,使用每个显著图的自适应阈值来进行阈值分割。一幅图像的自适应阈值 T_a 通常按下式取值。

$$T_a = \frac{2}{W \times H} \sum_{x=1}^W \sum_{y=1}^H S(x, y) \quad (11)$$

其中, W 和 H 是一幅图像的宽和高, $S(x, y)$ 是位置 (x, y) 处像素点的显著值。使用这个自适应阈值,获得基于显著图的自适应阈值分割图。然后为每幅图像计算 F_β 值:

$$F_\beta = \frac{(\beta^2 + 1)PR}{\beta^2 P + R} \quad (12)$$

一般在实验中取 $\beta^2 = 0.3$ 。 F_β 是查准率与查全率加权调和平均,它是一个要求两者同时提高的值,可以反映算法的整体预测精度。




图7 针对 iCoseg 数据集的协同显著性检测实验




图8 不同协同显著性检测方法的PR曲线

(下转第313页)

Li Chuan-long, Li Ying, Yu Shui-ming. New fractal model of grid overlapping differential box-counting [J]. Computer Science, 2011, 38(1): 282-285

[8] Tsompanaki I, Manousaki G, Manios G, et al. Use of color texture in determining the nature of melanocytic skin lesions—A qualitative and quantitative approach [J]. Comput. Biol. Med., 2006, 36: 416-427

(上接第 309 页)

图 8 分别显示了对两个数据集进行实验分析得到的 PR 曲线和 F_{β} 值。

3.3 协同检测处理效率对比

从上面的实验结果可以看出,本文的方法虽然只使用了图像块的稀疏主特征,但是在检测的性能上并无劣势,并且略优于目前已经提出的较好的协同显著性检测方法。然而,本文的方法在处理时间上的优势远优于它们。表 3 给出了在分别包括 210 幅图像和 643 幅图像的标准数据集下,各种方法处理每一幅图像所需的平均时间,可以看出 BSFCoS 的计算处理效率是最高的。

表 3 平均检测时间(/幅)

模型	$L_i^{[5]}$	$F_u^{[7]}$	BSFCoS
CP	450.4	1.81	0.451
iCoseg	N/A	4.93	0.702

图 9 示出了在 iCoseg 标准数据集下,通过控制输入图像的数量,分别记录当输入图像数量从 2 变化到 41 时, F_u 和本文方法处理每幅图像所需的平均时间,可以看出 BSFCoS 的计算处理效率一直保持在一个较低的水平。




图 9 当输入图像数量改变时, F_u 和 BSFCoS 方法处理每幅图像所需的平均时间

结束语 提出了一种基于图像分块与稀疏主特征提取的协同显著性检测方法。从 Lab 和 RGB 两种颜色空间对输入图像进行底层特征的抽取,使用截断幂方法在分块的基础上进行稀疏主成分分析并提取稀疏主特征。在使用 K-Means 对稀疏主特征进行聚类的结果上进行 3 种显著特征权值的度量,并从单幅图像和多幅图像两个角度进行特征融合,以生成最终的协同显著图。实验结果表明,该方法在保证具有协同显著性检测效果的同时,大幅缩短了处理图像所需的时间,具有更好的协同显著性检测性能。

但是,目前 BSFCoS 使用的基于聚类的显著性特征计算方法只对单一协同显著目标的检测表现出良好的性能,当多幅图像中同时包含多个协同目标时,它则表现出明显的不足。下一步工作的重心将放在能够同时检测出多幅图像中的多个协同显著目标。

参 考 文 献

[1] Itti L, Koch C, Niebur E. A model of saliency-based visual atten-

[9] <http://vismod.media.mit.edu/vismod/imagery/VisionTexture/vistex.html>

[10] Ivanovici M, Richard N. Fractal Dimension of Color Fractal Images [J]. IEEE Transactions on images processing, 2011, 20(1): 227-235

[11] Zhang H, Hu Y, Lan X, et al. Fuzzy fractal dimension of complex networks [J]. Applied Soft Computing, 2014, 25(11): 514-518

tion for rapid scene analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(11): 1254-1259

[2] Toet A. Computational versus psychophysical bottom-up image saliency: A comparative evaluation study [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(11): 2131-2146

[3] Jacobs D E, Goldman D B, Shechtman E. Cosaliency: Where people look when comparing images [C] // Proceedings of 23rd Annual ACM Symposium on User Interface Software and Technology. ACM, 2010: 219-228

[4] Chen H T. Preattentive co-saliency detection [C] // 2010 17th IEEE International Conference on Image Processing (ICIP). IEEE, 2010: 1117-1120

[5] Li H, Ngan K N. A co-saliency model of image pairs [J]. IEEE Transactions on Image Processing, 2011, 20(12): 3365-3375

[6] Chang K Y, Liu T L, Lai S H. From co-saliency to co-segmentation: An efficient and fully unsupervised energy minimization model [C] // 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2011: 2129-2136

[7] Fu H, Cao X, Tu Z. Cluster-based co-saliency detection [J]. IEEE Transactions on Image Processing, 2013, 22(10): 3766-3778

[8] Wang F, Huang Q, Guibas L J. Image co-segmentation via consistent functional maps [C] // 2013 IEEE International Conference on Computer Vision (ICCV). IEEE, 2013: 849-856

[9] Tang K, Joulin A, Li L J, et al. Co-localization in real-world images [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2014: 1464-1471

[10] Hu S M, Chen T, Xu K, et al. Internet visual media processing: a survey with graphics and vision applications [J]. The Visual Computer, 2013, 29(5): 393-405

[11] Kim G, Xing E P. Visualizing brand associations from web community photos [C] // Proceedings of 7th ACM International Conference on Web Search and Data Mining. ACM, 2014: 623-632

[12] Jolliffe I. Principal component analysis [M]. John Wiley & Sons, Ltd, 2005

[13] Hu Z F, Pan G, Wang Y M, et al. Sparse Principal Component Analysis via Rotation and Truncation [J]. arXiv preprint arXiv: 1403.1430, 2014

[14] Yuan X T, Zhang T. Truncated power method for sparse eigenvalue problems [J]. The Journal of Machine Learning Research, 2013, 14(1): 899-925

[15] Saad Y. Numerical methods for large eigenvalue problems [M]. Manchester: Manchester University Press, 1992

[16] Mackey L W. Deflation methods for sparse pca [C] // Advances in Neural Information Processing Systems. 2009: 1017-1024

[17] Batra D, Kowdle A, Parikh D, et al. icoseg: Interactive co-segmentation with intelligent scribble guidance [C] // 2010 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2010: 3169-3176