

图像显著估计的并行算法研究

沈洪 李晓光

(北京联合大学北京市信息服务工程重点实验室 北京 100101)

摘要 在数字图像处理中,图像显著估计已成为一种重要的工具。然而,在现有的算法中,很难兼顾准确度和实时应用要求。针对自底向上的图像显著估计模型的特点,利用 NVIDIA CUDA 并行计算架构的优势,提出了一种满足实时应用要求的图像显著估计并行算法。结合超像素分割和 Warshall 图论知识对图像进行边缘视觉模糊和背景概率估计,使用基于对比度的图像显著估计模型,突出颜色差异较低的空间紧凑区域,得到优化后的图像显著目标。在保证显著物体检测性能的前提下,提升了算法的效率,满足了实时应用要求。

关键词 显著性,背景概率,CUDA 并行运算,Warshall 图论知识,边缘视觉模糊

中图分类号 TP319 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.12.048

Research on Parallel Algorithm of Image Saliency Estimation

SHEN Hong LI Xiao-guang

(Beijing Key Laboratory of Information Service Engineering, Beijing Union University, Beijing 100101, China)

Abstract Saliency estimation has become an important tool in digital image processing. However, in the existing algorithms, it is difficult to take into account the accuracy and real-time application requirements. In view of the characteristics of the model of the bottom-up image estimation model, a parallel algorithm was proposed to meet the requirement of real-time application, which is based on the advantages of NVIDIA CUDA parallel computing architecture. Super pixel segmentation and Warshall graph theory are combined for edge blurred vision and background probability estimation. Based on the contrast model, the compact area with lower difference of color is high lighted to obtain the optimized saliency map. With the prerequisite of the detection performance, the efficiency was improved, and the requirements of real time application were met.

Keywords Saliency, Background probability, CUDA parallel computing, Warshall graph theory, Fuzzy edge vision

1 引言

数字图像处理中,结合神经生物学^[2,44]和认知心理学^[3,45]的研究成果,图像显著估计算法^[1,4,7-10,15-16,18-19,23-25,28,35-36,39-40]旨在图像中预测人类视觉注意的区域,优先分配图像分析的计算资源,即使在没有先验知识的情况下,也可以对图像进行适当处理。图像显著估计在计算机视觉^[1,36]领域中得到了广泛应用,主要包括感兴趣目标物体图像分割^[21-22,43]、目标识别^[6,46-47]、自适应压缩^[38]、内容感知和图像编辑^[5,48-51]、图像检索^[11,27,52,54,59-57]、图像标签排序^[53,55,58]等。图像显著估计模型可以帮助计算设备模拟生物视觉,获取数字图像中符合语义认知的目标对象,有助于对图像进行语义理解和显著物体定位,从而使计算设备得到更加准确的图像语义目标,提高图像语义检索、图像标签排序和显著目标定位的准确性。

在 Koch 和 Ullman^[20]提出的非常有影响力的生物启发模型的基础上,Itti 等人^[13]定义了图像显著性。Itti 等人提出

的视觉注意理论将图像显著估计算法的研究分为两个方向:快速的、自底向上的、数据驱动的显著性提取和缓慢的、自顶向下的、目标驱动的显著性提取。我们依据图像显著估计的对比度计算模型,进行自底向上的、数据驱动的图像显著性提取。所有自底向上的计算方法都依赖于对象和背景属性间的差异,物体及其周围区域对比度的计算模型在几乎所有自底向上的显著估计算法中被广泛应用。

Perazzi F 等^[8]认为对比度计算模型的所有操作都可以用一个简单高斯滤波框架来解决,实现了一个高效的线性复杂度的显著估计算法。Zhi L 等^[16]提出图像显著树计算模型,利用全局对比度、空间分布特点以及目标先验知识生成的原始区域作为叶子节点,结合动态尺度控制策略进行合并,增强了图像显著估计算法在复杂图像中的应用。联合显著估计模型是利用一组图像寻找共同的显著性目标, Huazhu F 等^[15]提出了基于聚类的快速高效联合显著估计算法,融合单一图像显著性和多张图像显著性的聚类结果,确定图像显著

到稿日期:2016-10-19 返修日期:2017-02-26 本文受国家自然科学基金(61271369,61372148,61571045),北京市自然科学基金(4152016,4152018)资助。

沈洪(1961-),女,硕士,副教授,主要研究方向为可视媒体计算,E-mail:shenhong@buu.edu.cn;李晓光(1988-),男,硕士,主要研究方向为数字图像处理、GPU 并行计算,E-mail:lixiaoguang20@163.com。

目标,在联合图像分割以及视频影像前景检测等应用中获得了较好的实验结果。文献[12]结合图像的深度信息,利用 Prim 最小生成树算法将尽可能多的显著图像块合并到一起,形成信息相对完整的图像显著目标区域。

在文献[9,15-16,19,35]的方法中,利用边界先验^[19],认为图像边界区域有较大概率成为背景区域,可以有效提高显著性计算的准确度,证明了结合边界先验来确定背景的有效性。文献[35]计算图像像素块与边界区域的对比度,将图像显著性估计看作以边界部分为背景先验的基于图的排序问题^[9],文献[19]认为背景区域相比前景区域可以更容易地连接到图像的边界。“中心-边缘准则”认为靠近图像中心的部分具有较高的显著度,靠近图像边界的区域有较大概率成为背景区域。通常情况下,“中心-边缘准则”采用高斯滤波计算模型,可以作为权重来结合其他线索^[24-25,39],也可以作为特征应用到基于学习的计算模型中^[10,35]。

结合“中心-边缘准则”,利用边界确定背景区域的算法获得了较好的实验结果,但仍然存在一些特殊情况,例如当一个对象只是稍微接触边界,也会被作为图像的背景来进行处理。Zhu W 等^[15]不直接假设图像边界为背景^[9,15-16,19,35],提出了一种新的、稳定可靠的图像背景区域估计算法,该算法具有较强的鲁棒性,得到的背景概率可以有效提高传统的对比度模型的计算精度。

目前的显著估计算法大部分采用 CPU 串行计算模式,处理一张 300×400 像素的图像需要 $100 \sim 400$ ms。虽然通过相对简单的方法可以提高运算速度,但会损失计算精确度。在面对互联网海量图片数据和其他实时性要求较高的应用时,大多数的显著估计算法有较高的计算成本,不能快速高效地计算出图像显著目标,无法满足实时系统的使用要求,从而成为制约图像显著性估计算法应用的瓶颈问题。因此如何提高图像显著估计算法的运算效率以及降低 CPU 负载是需要解决的关键问题。

NVIDIA CUDA 架构充分利用图形显卡的计算资源,达到了较高的计算效率,但其要求每个计算单元处理的数据尽可能地独立,这需要对求解问题进行并行化设计。采用串行自底向上的图像显著估计算法对 CPU 计算资源的依赖较大,且不能完成对图像/视频数据的实时处理。通过分析图像显著计算模型的特点,设计了并行计算方法,采用了 NVIDIA CUDA 架构,旨在提高计算效率并满足实时应用要求。

利用 NVIDIA CUDA 架构实现的显著估计并行算法,首先采用 gSLIC 并行简单聚类算法^[14]对图像进行超像素分割,得到图像超像素邻接矩阵;其次,结合图论 Warshall 传递闭包可达矩阵对颜色相近的区域进行合并,并采用视觉边缘模糊策略增强边界区域的合并效果,进而计算每一个区域的背景概率值;然后采用对比度计算模型,在 CIELab 颜色空间中计算每个超像素块的显著度,突出颜色差异较低的空间紧凑物体的显著度^[8],优化后得到最终显著目标。实验结果对比表明,所提算法获得了较好的加速效果,在普遍应用的基准数据集 MSRA10K^[7]上进行测试,获得了较好的准确性。

2 相关工作

图形处理器(GPU)是一种高度并行的流处理器,其高速

并行化的多核、多线程应用平台在图形和数据运算上表现出了强大的处理能力。图形处理器(GPU)在数字图像处理领域的应用已经日趋广泛,并得到了非常好的加速效果。gDBSCAN 并行密度聚类算法^[33]在原始 DBSCAN 密度聚类算法^[34]的基础上进行并行化设计,采用 BFS 广义优先算法降低了计算复杂度,结合 GPU 计算模型,达到了 100 倍以上的加速效果。Achanta R 等人提出了简单迭代聚类算法(SLIC)^[29],可以得到紧凑和几乎一致的超像素区域。gSLIC 算法^[14]利用图形处理器 GPU 强大的并行处理能力,结合 NVIDIA CUDA 并行计算架构的优势设计了并行简单聚类算法。相比其他串行超像素分割算法如 Normalized cuts 算法^[30]和 QuickShift 算法^[31],gSLIC 算法^[14]在效率和性能上更加优化,有效地减少了图像超像素分割的运算时间,满足了实时应用要求。

文献[8,12-13]采用 SLIC 超像素分割算法对图像进行处理,得到了相对规整且结构清晰的超像素块。文献[14]利用 NVIDIA CUDA 并行框架,将 SLIC 转化为并行计算模式,使用单一的图形显卡达到了较好的加速效果,可以实时完成图像的超像素分割。

2.1 Warshall 传递闭包可达矩阵

在图论知识中,利用邻接矩阵的相乘运算,可以获取任意两点在固定步长下的连通路径个数。如图 1(a)所示,节点之间的连线表示节点之间是可连通的,反之则表示不可连通。得到邻接矩阵 $MatAdj$, $MatAdj[A, B]$ 的值表示节点 A 和节点 B 的连通性,根据式(1), $MatAdj^M[A, B]$ 表示固定步长为 M 时节点 A 和节点 B 的连通路径个数。为简化计算过程并提高运算效率,规定 $M \leq N - 1$ (N 为节点总数),在图 1(a)中, M 的最大值为 3。图 1(a)为邻接图,节点 A 和节点 B 的连线代表节点是可连通的,图 1(b)为采用式(3)计算得出的邻接图可达矩阵。




图 1

$$MatAdj^M = \prod_{i=1}^M MatAdj \quad (1)$$

根据式(2), $MatAdjArr[A, B] > 0$ 表示节点 A 与节点 B 可连通, $MatAdjArr[A, B] = 0$ 表示不连通。

$$MatAdjArr = \sum_{i=1}^{N-1} MatAdj^i \quad (2)$$

结合式(1)和式(2)的计算特点,采用 NVIDIA CUDA 并行计算框架,通过矩阵相乘和相加运算,快速得出每两个节点间的连通性。为进一步提高并行运算效率,采用 Warshall 传递闭包可达矩阵,规定每一个节点都是可自反的,任意节点 p 可以经过以 i 为步长的任意节点 p 可到达自身,即 $MatAdj^i[p, p] = 1, i \in [1, N-1]$ 。 $MatAdj^M[p, q] \geq 1$ 表示在固定步长为 M 的条件下节点 p 和 q 是可连通的,反之则是不可连

通,其中 $M \leq N-1$, N 为节点总数。通过 Warshall 传递闭包可达矩阵的并行计算,利用式(3)可以快速得出可达矩阵 $MatAdjArr$,其中 $V()$ 为所有节点的集合。

$$MatAdjArr = \prod_{i=1}^{N-1} MatAdj^i \tag{3}$$

$$MatAdj[j, j] = 1, j \in V()$$

对于一个 200×200 的矩阵,分别在 CPU 和 CUDA 两种编程环境下进行矩阵相乘运算,得出时间效率对比图,如图 2 所示。CPU 和 GPU 的时间效率对比如表 1 所列。




图 2 算法的时间效率对比图

表 1 CPU 和 GPU 的时间效率对比

名称	CPU_Mat	GPU_Mat	CPU_MatArr	GPU_MatArr
时间/ms	46	0.253	421	2.449
类型	CPU	CUDA	CPU	CUDA

图 2 中,CPU_Mat 和 GPU_Mat 运算分别表示在 CPU 和 CUDA 两种编程环境下进行 1 次矩阵相乘操作;CPU_MatArr 和 GPU_MatArr 运算是采用最大步长为 10 的 Warshall 传递闭包可达矩阵算法,在 CPU 和 CUDA 两种编程环境下进行的操作。通过实验可以观察到,GPU 具有非常高的计算效率,可以快速完成矩阵相乘操作。实验中,CPU 型号为 Inter Xeon E5-2609 v2 2.5GHZ,CUDA 的计算设备为一个单一的 GTX980 图形显卡。

2.2 图像边缘视觉模糊

文献[9,13,15-16,19,35]利用边界先验有效提高了图像显著计算的准确度。文献[13]提出了一个边界连接性算法模型,可以得出每一个超像素块的背景概率,算法具有较强的鲁棒性,需要计算每个区域与其他区域的 CIELab 颜色距离,计算量相对较大。本文直接从图像边界区域的超像素块出发,结合 Warshall 传递闭包可达矩阵算法合并超像素块,采用图像边缘视觉模糊策略,使边界区域图像块更容易与颜色相近的相邻图像块合并,将图像边界区域向图像内部延伸,并将计算资源集中到图像的中心区域,从而计算图像各个超像素区域的背景概率值,在满足 NVIDIA CUDA 的并行计算框架的同时,减少了图像处理的计算量。

2.3 优化策略

大多数显著估计算法^[4,8,24-25]结合多种底层特征,采用权重相乘或相加的方法,得到最终显著度图。文献[13]提出了一个线性复杂度的全局优化框架,采用高效的最小二乘法得到最终的显著度图像,该方法可以获得相对完整的目标对象,但在优化过程中增加了时间消耗。

文献[24-25,42]采用条件随机场 CRF/MRF 优化算法,获得了较好的实验结果,但计算复杂度较高。文献[40]提出了最大化子模块目标优化函数。文献[16]结合中心边缘策

略,采用了动态尺度控制优化显著树模型。文献[17,26]认为图像显著目标是一个稀疏的噪声部分,其采用低秩矩阵的方法计算图像显著度。

不同于以上提到的优化策略,文献[8]认为颜色差异较低的空间紧凑物体具有较高的显著性,采用简单高斯滤波框架计算模型,实现了一个高效的线性复杂度的显著估计算法,得到了较好的效果。为保证算法的运算效率,突出颜色差异较低的空间紧凑物体的显著性,使用 NVIDIA CUDA 架构,结合文献[8]设计并行图像显著区域优化算法。

3 图像显著估计并行方法

图形处理器(GPU)是一种高度并行的流处理器,其高速并行化的多核、多线程通用应用平台在图形和数据运算上表现出了强大的处理能力。利用图形处理器 GPU 强大的并行处理能力,针对自底向上的图像显著估计模型的特点,提出了一种满足实时应用要求的图像显著估计并行算法。结合超像素分割结果和图论相关知识对图像进行视觉边缘模糊和背景估计,突出颜色差异较低的空间紧凑区域,得到优化后的图像显著目标。通过并行化处理技术有效地减少了图像显著估计算法的运算时间,从而降低了 CPU 负载,满足实时应用需求。

3.1 对比度方法计算图像显著度

Liu T 等^[24]通过图像高斯金字塔模型,提出了多尺度对比度显著估计算法。Goferman S 等^[26]结合全局特征,同时对局部底层线索、视觉组织规则和表层特征进行建模,突出图像显著物体。以上利用局部对比度的方法倾向于在边缘部分产生高显著性值,而不是均匀地突出显著目标物体。Cheng M 等^[7]提出了基于空间信息增强的区域对比度算法,认为图像中和周围物体对比度较大的区域容易引起视觉注意,且相邻区域的高对比度比较远区域的高对比度更容易引起视觉注意。基于空间信息增强的区域对比度计算方法具有较高的实验准确性。

文献[7]没有考虑边界先验对计算精度的影响,具有相对较低的计算效率。在我们的实验中,结合 CUDA 并行计算框架对图像超像素进行分割后,得到超像素块邻接矩阵 $MatAdj$,利用式(3)计算得出 $MatAdjArr$ 可达矩阵,可以有效合并颜色一致的空间邻近区域。同时,考虑到图像边界先验,结合边缘视觉模糊计算模型,去除靠近图像边界的孤立噪声点和颜色差异较小的区域,将图像边界向图像内部延伸,计算资源集中到图像的中心区域,在有效保证计算效率的同时提升了显著估计的准确性。

3.2 边缘视觉模糊

在视觉注意力机制中,往往会注意图像的中心区域,而忽视图像的边缘部分。结合中心-边缘先验在显著计算中的有效性,提出了边缘视觉模糊计算模型,如式(4)所示,其可以加强边界区域对相邻区域的合并效果。式(4)中, p 和 q 为邻接超像素区域, p 为待处理区域,当 p 属于图像边界区域时, $F() \in (0, 1)$ 。模拟视觉注意力特性,模糊区域 p 和 q 在 CIELab 空间内的颜色差异的度量,增强边界区域的融合效果,将边缘区域视觉模糊化。当 p 不属于边界区域时, $F() = 1$,参数 σ_p 为强化系数,用于控制边界区域对相邻区域的合并

效果。 $S(p)$ 表示超像素区域 p 包含的像素个数。采用 gSLIC^[14] 分割图像后,图像超像素块大小呈现出相对均匀的特点,当区域 q 较小且临近图像边界区域时,会有较大概率属于噪声部分,式(4)可以将这些靠近边界的噪声部分模糊化。实验表明,增强此类型区域的合并效果可有效提高显著计算的准确性。实验中 $\sigma_p=0.4$ 。

$$F(p, q, \sigma_p) = 1 - (1 - \sigma_p) \exp(-\sqrt{S(q)}/S(p)) \quad (4)$$

采用并行 gSLIC^[14] 超像素分割算法,得到图像的超像素块邻接矩阵 $MAdj$,在超像素矩阵的基础上计算图像显著度。如式(5)所示, T_{lab} 为阈值,当相邻区域 p 和 q 的颜色值比较接近时,认为区域 p 和 q 在同一颜色紧凑区域是可连通的;当 p 属于边界区域时,结合边缘视觉模糊公式,有效提高边界区域同周围区域的合并效果,使得图像的显著性区域更趋向于图像的中心,如图 3 所示。

$$MAdj(p, q) = \begin{cases} 1, & isAdj(p, q) * d_{app}(p, q) * F(p, q, \sigma_p) < T_{lab} \\ 0, & else \end{cases} \quad (5)$$

其中, $d_{app}(p, q)$ 表示在 CIELab 颜色空间,区域 p 和 q 的颜色值的欧氏距离; $isAdj(p, q)$ 表示区域 p 和 q 的邻接关系,当 $isAdj(p, q)=1$ 时表示区域 p 和 q 相邻接。



图 3 原始图像和边缘视觉模糊后的图像

3.3 图像背景概率估计

中心-边缘理论的有效性得到了广泛认可^[9,15-16,19,35],但当图像中的显著目标区域只有一小部分连接到图像的边界上时,也会认为此区域为图像的背景区域,从而容易产生误判,降低整个算法的计算准确性。文献[13]提出一种背景概率计算模型,得到每一个区域的背景概率值,结合对比度算法模型,有效提高了显著估计的准确性。背景概率计算模型需要计算每个区域与其他区域的 CIELab 颜色距离,计算量相对较大。结合 NVIDIA CUDA 的并行计算框架和背景概率计算模型^[13]的运算原理,设计并行背景概率计算模型,如式(6)所示,直接从图像边界区域的超像素块出发,计算图像各个超像素区域的背景概率值。

$$w_i^{bg} = 1 - \exp\left(-\frac{BndCon^2(p_i)}{2\sigma_{bndCon}^2}\right) \quad (6)$$

$$BndCon(p) = \frac{Len_{bnd}(p)}{\sqrt{Area(p)}}$$

$Area(p)$ 为在 CIELab 颜色空间内,包含 p 超像素区域在内的合并后的图像区域 PM 中超像素块的个数, $Len_{bnd}(p)$ 为 PM 中连接边界的超像素个数。当 $p_i(p_i \in PM)$ 属于边界区域时, $p_i \in Len_{bnd}(p)$,否则 $p_i \notin Len_{bnd}(p)$ 。 w_i^{bg} 为区域 p_i 的背景概率值。

$$wSal(p) = \sum_{i=1}^N d_{app}(p, p_i) w_{spc}(p, p_i) w_i^{bg} \quad (7)$$

空间信息增强的区域对比度方法^[7]没有考虑边界先验对计算精度的影响,具有相对较低的计算效率。文献[13]将

w_i^{bg} 作为权重因子参与到对比度计算模型中,如式(7)所示,得到了较好的效果。该算法计算简单,但计算量相对较大。其中, $d_{app}(p, p_i)$ 表示在 CIELab 颜色空间中超像素区域 p 与 p_i 的欧氏距离, $d_{spc}(p, p_i)$ 表示在坐标空间中超像素区域 p 与 p_i 中心点的坐标距离。

本文方法结合 CUDA 并行计算框架,对图像进行超像素分割后,得到超像素块邻接矩阵 $MatAdj$,结合式(3)计算得出 $MatAdjArr$ 可达矩阵,可以有效合并颜色一致的空间邻近区域。同时,考虑到图像边界先验,结合边缘视觉模糊计算模型,去除靠近图像边界的孤立噪声点,将图像边界向图像内部延伸,显著计算集中到图像的中心区域,在有效保证计算效率的同时提升了显著性计算的准确性。

3.4 显著区域优化

针对背景噪声较多的复杂图像,Zhang Y 等人^[32]认为显著目标区域在空间的分布是较集中的,提出了一个简单快速的显著目标定位算法,该算法将显著性区域尽可能用一个小的圆圈包裹,该圆圈区域用于确定显著区域的位置和范围大小,作为显著性区域空间分布计算的权重,结合对比度模型算法确定复杂图像的显著目标对象。

文献[32]首先对原图像进行多阈值 canny 算法处理,然后利用高斯函数模型,通过一系列取值运算,确定复杂图像显著目标分布的位置和窗口大小。

通过高斯函数模型优化,可以有效提升显著性估计的计算准确度,但计算相对复杂。Perazzi F 等^[8]认为图像颜色差异较低的空间紧凑物体具有较高的显著性,运用对比度算法模型,获得了较好的效果。结合文献[8]设计显著区域并行优化算法,以突出颜色差异较低的空间紧凑区域的显著度,如式(8)一式(11)所示。

$$CenPos = w_{app} * meanPos \quad (8)$$

其中, $meanPos[p]$ 为超像素区 p 的坐标,其中 $w_{app}(p, p_i) = \exp(-d_{app}^2(p, p_i)/2\sigma_{app}^2)$ 需要对矩阵 w_{app} 的每一行进行标准化处理,即 $\sum_{i=1}^N w_{app}(p, p_i) = 1$, N 为超像素区域的个数。利用式(9)得到每一个超像素区域的空间分布向量,其中矩阵 $PosDis[p, q]$ 为超像素区域 p 和 q 的带颜色权重的距离量度。为了满足 CUDA 并行计算框架,规定 $PosDis[p, q] = \|meanPos[p, :] - CenPos[:, q]\|$ 。

$$Distribution = Diag(w_{app} * PosDis) \quad (9)$$

其中, $Diag(Mat)$ 表示将方阵 Mat 中的主对角线上的元素组成的一个列向量。得到图像超像素分割后的空间分布向量后,根据式(10)计算得到优化后的显著图,其中 k 为控制空间分布的权重因子,本文实验中,参数设置与文献[8]相同, $k=6$ 。

$$res = wSal * \exp(-Distribution * k) \quad (10)$$

3.5 算法的并行化设计

如图 4 所示,本文算法可分为 CPU 和 GPU 两个计算部分,图像数据的获取操作借助于 CPU 运算设备,然后由计算机主存传输到图形卡的显存,图像的超像素分割、图像边缘视觉模糊、背景概率估计、显著目标区域的计算与优化等操作全部利用 GPU 图形显卡计算资源。工程实验的设计过程只在图像数据读取和显示过程涉及主存与显存之间的数据传输。

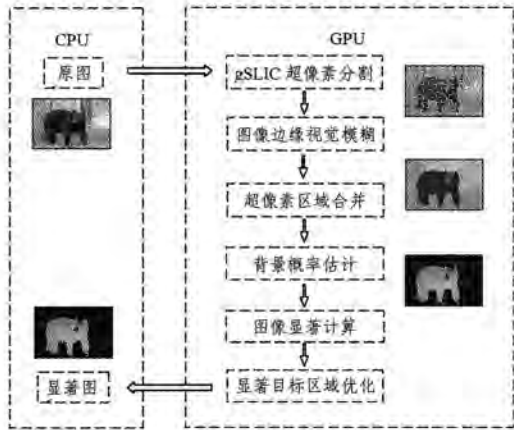


图4 算法并行设计流程图

图像显著估计整体算法的并行化设计要尽可能保证数据读取和运算的高效性,减少计算数据之间的关联程度,在满足NVIDIA CUDA并行计算架构的同时,提升并行算法的运算效率。为保证对CUDA计算设备的兼容性,在所有计算步骤中,每一个线程块的最大线程数不超过512。在对超像素矩阵进行对比度运算的过程中,线程块中的每一个线程的计算步骤涉及其他线程块中的数据,这在一定程度上降低了GPU的运算效率,同时也避免了严重降低运算效率的原子操作。算法并行设计的主要步骤如下。

3.5.1 图像边缘视觉模糊

首先需要检测图像边界区域的超像素块,在 16×16 固定大小的线程块中,为每一个像素分配一个线程,每一个线程查找当前像素的四邻域,当四邻域中有一个超出图像边界,即可确定该像素为图像的边界像素点。当一个超像素块中存在一个边界像素点,则确定该超像素块为图像的边界区域。

考虑到视觉注意力机制会更多关注图像的中心区域,而忽略图像边界部分,在实验过程中,为了降低边界颜色差异较大且孤立的超像素区域的显著度,对图像边界区域进行边缘视觉模糊处理,为每一个超像素区域分配一个线程,构造邻接矩阵,每一个线程的运算过程如式(4)、式(5)所示。

然后通过Warshall传递闭包可达矩阵(如式(3)所示)合并图像中颜色差异较低的临近区域。矩阵 $MatAdjArr[i,j]=1$,表示超像素区域*i*和*j*在CIELab颜色空间内的颜色值比较接近,将它们合并为一个更大的超像素区域。结合NVIDIA CUDA SDK中的reduce归约方法和式(6)计算每一个超像素区域的背景概率值。

3.5.2 基于对比度的并行显著运算

在 16×16 固定大小的线程块中,为每一个超像素区域分配一个线程,每一个线程都要计算当前超像素区域与其他所有超像素区域的颜色空间距离和坐标空间距离,获取超像素节点颜色空间距离矩阵 d_{app} 和坐标空间距离矩阵 w_{spa} 。结合NVIDIA CUDA SDK中的multiple方法、背景概率权重 w_i^{bg} 和式(7),通过矩阵相乘并行运算,完成图像显著估计运算。

3.5.3 显著区域优化

图像的显著区域优化旨在明确图像显著目标的具体位置和轮廓信息。结合NVIDIA CUDA SDK中的multiple方法和式(8)~式(10),完成对图像显著区域的优化。式(9)中,只

需要Distribution矩阵主对角线元素组成的一个列向量,在计算过程中,为了保持与基于对比度的并行显著运算的计算架构的一致,未对算法做进一步调整,因此产生了较多的冗余计算。

在NVIDIA CUDA框架下,利用GPU计算资源,完成图像颜色空间变换、超像素分割、图像边缘视觉模糊、超像素区域合并、背景概率计算、图像显著估计、显著目标区域优化等运算过程,再将优化后的显著图回传到计算机主存。借助于单一的图形显卡,所提算法获得了较好的加速效果,可以完成对视频/图像数据的实时处理。

4 实验比较

本文提出了一种快速的并行图像显著估计算法,在数据集MSRA10K^[7]上同其他几种优秀的算法进行了比较,图5和图6给出了同其他方法的比较结果。所使用图像库的显著图人工标记数据来自文献[7]。

4.1 正确率和召回率

同文献[7-8,36]一致,使用正确率、召回率、 F_β 值作为图像显著估计算法的评价标准,固定阈值分割是一个简单有效的方法,需要设定一个 $T_f \in [0, 255]$,因此为了可靠地比较多种显著估计算法的效果,将阈值 T_f 设定在0到255之间变化,用 $\beta^2=0.3$ 来使正确率的权重大于召回率,其中 F_β 定义为:

$$F_\beta = \frac{(1+\beta^2)Precision * Recall}{\beta^2 * Precision + Recall} \quad (11)$$

图5是在包含10000幅图像的公开测试集MSRA10K^[7]上采用各种方法得到的显著图,经过简单阈值分割得到结果的正确率召回率曲线,并将本文方法与wCtr^[13],SE^[8],RC^[7],HC^[7],MR^[9],GS^[10]方法进行了比较。图6是显著区域分割方法以不同的显著图作为初始值得到的正确率、召回率柱状图。将本文的并行显著性估计算法在10000幅图像数据集上与其他优秀算法进行了比较,从图5和图6中可以看出,所提方法在提高运算效率的同时,取得了较好的实验结果。




图5 算法正确率、召回率的曲线对比图




图6 不同 F_β 值的测试结果对比

图 7 和图 8 是在包含 1000 幅图像的公开测试集 MSRA1000 上采用各种方法得到的测试结果。MSRA1000 公开测试集公布得比较早,相比其他针对图像显著估计的公开测试集比较简单,各个算法在 MSRA1000 测试集上的准确率和召回率都比较高,本文的并行显著性估计方法在 1000 幅图像的数据集上具有较高的精度、召回率和 F_{β} 值。




图 7 MSRA1000 测试集中不同 F_{β} 值的测试结果




图 8 MSRA1000 测试集中各算法的正确率、召回率

图 9 给出了显著度图视觉效果对比。




图 9 显著度图视觉效果对比图

由图 9 可知,本文方法的分割结果均匀地突出了整个显著性区域,达到了较好的实验结果。

4.2 时间效率

图 10 给出了不同算法在公开测试集中处理一张图像的

平均用时,该数据集中大部分图像的分辨率为 300×400 。此处所有方法的时间消耗是在一个拥有 Inter Xeon E5-2609 v2 2.5GHz 的 CPU、4GB 内存和一个单一的 GTX980 图形显卡作为 CUDA 计算设备的机器上测试得到的。图 10 比较了每个方法的平均用时,本文方法 CUDA_Sal 使用 CUDA C/C++ 实现,对于算法 wCtr*, SF, RC, MR, GS, 我们引用了作者的实现。算法 wCtr*, MR, GS 达到了较高的正确率、召回率水平,但时间消耗相对较高,不能完成对图像数据的实时处理,不能满足实时性要求较高的应用需求。表 2 列出了时间效率对比。




图 10 算法时间效率对比图

表 2 时间效率对比

方法	wCtr*	SF	RC	MR	GS	CUDA_Sal
时间/ms	155	215	192	210	190	16.5
类型	Matlab	C++	C++	Matlab	Matlab	CUDA C/C++

通过图 5—图 10 可以看出,本文并行显著估计算法不是目前最好的,但是同其他正确率、召回率、 F_{β} 值相当以及更好的方法相比,所提方法在时间效率上具有明显的优势,在降低 CPU 负载的同时,可以有效提高计算效率,达到了较好的加速效果,可以达到对图像/视频数据的实时处理要求。

4.3 应用与局限

结合 NVIDIA CUDA 并行计算架构的优势,利用图形处理器 GPU 强大的并行处理能力,设计并行的图像显著估计模型。通过并行化处理技术有效地减少了图像显著性提取的运算时间,降低了 CPU 负载,满足了实时应用需求。并行的图像显著估计模型可以广泛适用于兴趣目标物体图像分割^[21-22,43]、目标识别^[6,46-47]、自适应压缩^[38]、内容感知和图像编辑^[5,48-51]、图像检索^[11,27,52,54,56-57]、图像标签排序^[53,55,58]等。

基于对比度的图像显著估计算法不是总是可行的,当场景的光线不断变化或图像前景物体和图像背景很接近时,通过对比度的方法不能获得很好的检测效果。在本文的方法中,首先采用了 gSLIC 图像超像素分割算法,当图像中有较多比较孤立且高对比度的噪声区域时,虽然可以采用不同的阈值来加强区域合并的效果,但是很难有普遍适用性,很难得到精准的图像显著目标区域。通过突出颜色差异较低的空间紧凑区域,尽量忽略孤立的噪声点,来尽可能获取较精确和稳定的图像显著目标。

结束语 图形处理器(GPU)高速并行化的多核、多线程通用应用平台在图像和数据运算上表现出强大的处理能力,在数字图像处理领域的应用已经日趋广泛。利用 NVIDIA CUDA 并行计算架构的优势,结合自底向上计算模型的特点,设计基于对比度和背景概率的图像显著估计并行算法,通过并行算法处理有效地减少了计算时间,同时降低了 CPU 负

载,提升了显著估计算法的实时应用性能。

在面对互联网海量图片/视频数据显著性检索和其他实时性能要求较高的应用时,大多数显著估计算法具有较高的计算成本,不能快速高效地计算出图像显著目标,无法满足实时系统的使用要求,从而成为制约图像显著估计算法应用的瓶颈问题。在未来的工作中,我们将进一步结合生物视觉的最新研究成果,获取更加精细的图像显著目标,以用于可靠的图像分析^[37],提升图像检索^[11,27,52,54,56-57]和图像标签排序^[53,55,58]的准确度,结合本文并行显著估计算法,可以满足如图像检索、机器人辅助视觉、汽车无人驾驶视觉系统等对实时处理要求较高的应用需求。

参 考 文 献

- [1] ITTI L, KOCH C, NIEBUR E. A model of saliency-based visual attention for rapid scene analysis[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 1998, 20(11): 1254-1259.
- [2] DESIMONE R, DUNCAN J. Neural mechanisms of selective visual attention [J]. *Annual Review of Neuroscience*, 1995, 18(1): 193-222.
- [3] TEUBER H. Physiological psychology[J]. *Annual Review of Psychology*, 1955, 6(1): 267-296.
- [4] BORJI A, SIHITE D N, ITTI L. Salient Object Detection: A Benchmark[M]//*Computer Vision-ECCV 2012*. Springer Berlin Heidelberg, 2012: 414-429.
- [5] DING M, TONG R F. Content-aware copying and pasting in images[J]. *The Visual Computer*, 2010, 26(6-8): 721-729.
- [6] DING Y, XIAO J, YU J. Importance filtering for image retargeting[C]//*IEEE Conference on Computer Vision & Pattern Recognition*. IEEE Computer Society, 2011: 89-96.
- [7] CHENG M, MITRA N J, HUANG X, et al. Global Contrast Based Salient Region Detection[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2015, 37(3): 569-582.
- [8] PERAZZI F, KRÄHENBÜHL P, PRITICH Y, et al. Saliency filters; Contrast based filtering for salient region detection[C]//*2013 IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, 2012: 733-740.
- [9] YANG C, ZHANG L, LU H, et al. Saliency Detection via Graph-Based Manifold Ranking[C]//*2013 IEEE Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society, 2013: 3166-3173.
- [10] JUDD T, EHINGER K, DURAND F, et al. Learning to predict where humans look[C]//*International Conference on Computer Vision*. 2010: 2106-2113.
- [11] CHEN T, CHENG M M, TAN P, et al. Sketch Photo: internet image montage[J]. *ACM Transactions on Graphics (TOG)*, 2009, 28(5): 124.
- [12] PENG H, LI B, XIONG W. RGBD Salient Object Detection: A Benchmark and Algorithms [M]//*Computer Vision - ECCV 2014*. Springer International Publishing, 2014: 92-109.
- [13] ZHU W, LIANG S, WEI Y, et al. Saliency Optimization from Robust Background Detection[C]//*2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2014: 2814-2821.
- [14] REN C Y, REID I. gSLIC: a real-time implementation of SLIC superpixel segmentation[J]. University of Oxford, 2011.
- [15] HUAZHU F, XIAOCHU C, ZHUOWEN T. Cluster-based co-saliency detection[J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2013, 22(10): 3766.
- [16] ZHI L, ZOU W, MEUR O L. Saliency Tree: A Novel Saliency Detection Framework[J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2014, 23(5): 1937-1952.
- [17] PENG H W, LI B, JI R, et al. Salient Object Detection via Low-Rank and Structured Sparse Matrix Decomposition[C]//*AAAI Conference on Artificial Intelligence*. 2013: 796-802.
- [18] WANG L, XUE J, HENG N, et al. Automatic salient object extraction with contextual cue[C]//*2011 IEEE International Conference on Computer Vision (ICCV)*. IEEE, 2011: 105-112.
- [19] WEI Y, WEI F, ZHU W, et al. Geodesic saliency using background priors [M]//*Computer Vision-ECCV 2012*. Springer Berlin Heidelberg, 2012: 29-42.
- [20] KOCH C, ULLMAN S. Shifts in selective visual attention: towards the underlying neural circuitry[M]//*Matters of Intelligence*. Springer Netherlands, 1987: 115-141.
- [21] KO B C, NAM J Y. Object-of-interest image segmentation based on human attention and semantic region clustering[J]. *Journal of the Optical Society of America A Optics Image Science & Vision*, 2006, 23(10): 2462-2470.
- [22] HAN J, NGAN K N, LI M, et al. Unsupervised extraction of visual attention objects in color images[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2006, 16(1): 141-145.
- [23] GAO D, MAHADEVAN V, VASCONCELOS N. The discriminant center-surround hypothesis for bottom-up saliency[C]//*International Conference on Information Processing Systems*. 2007: 497-504.
- [24] LIU T, YUAN Z, SUN J, et al. Learning to Detect a Salient Object[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2010, 33(3): 353-367.
- [25] YAN Q, XU L, SHI J, et al. Hierarchical saliency detection [C]//*2013 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2013: 1155-1162.
- [26] SHEN X, WU Y. A unified approach to salient object detection via low rank matrix recovery[C]//*2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2012: 853-860.
- [27] ZHENG L, WANG S, LIU Z, et al. Fast Image Retrieval; Query Pruning and Early Termination[J]. *IEEE Transactions on Multimedia*, 2015, 17(5): 648-659.
- [28] GOFERMAN S, ZELNIK-MANOR L, TAL A. Context-aware saliency detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(10): 1915-1926.
- [29] ACHANTA R, SHAJI A, SMITH K, et al. SLIC Superpixels [J]. *Epl*, 2010.
- [30] MORI G. Guiding Model Search Using Segmentation[C]//

- Tenth IEEE International Conference on Computer Vision, IEEE Computer Society, 2005; 1417-1423.
- [31] VEDALDI A, SOATTO S. Quick Shift and Kernel Methods for Mode Seeking [M] // Computer Vision-ECCV 2008. Springer Berlin Heidelberg, 2008; 705-718.
- [32] ZHANG Y, MAO Z, LI J, et al. Salient region detection for complex background images using integrated features[J]. Information Sciences, 2014, 281; 586-600.
- [33] ANDRADE G, RAMOS G, MADEIRA D, et al. G-DBSCAN: A GPU Accelerated Algorithm for Density-based Clustering[J]. Procedia Computer Science, 2013, 18(1); 369-378.
- [34] ESTER M, JORG S, XU X. A density-based algorithm for discovering clusters in large spatial databases with noise[C] // International Conference on Knowledge Discovery and Data Mining, AAAI Press, 1996; 226-231.
- [35] JIANG H, WANG J, YUAN Z, et al. Salient Object Detection: A Discriminative Regional Feature Integration Approach [C] // Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2013; 2083-2090.
- [36] ACHANTA R, HEMAMI S, ESTRADA F, et al. Frequency-tuned Salient Region Detection[C] // IEEE International Conference on Computer Vision and Pattern Recognition (CVPR 2009). 2009; 1597-1604.
- [37] CHENG M M, ZHANG F L, MITRA N J, et al. RepFinder: finding approximately repeated scene elements for image editing [J]. ACM Transactions on Graphics (TOG). ACM, 2010, 29(4); 83.
- [38] CHRISTOPOULOS C, SKODRAS A, EBRAHIMI T. The JPEG 2000 still image coding system; an overview[J]. IEEE Transactions on Consumer Electronics, 2000, 46(4); 1103-1127.
- [39] CHENG M M, WARRELL J, LIN W Y, et al. Efficient Salient Region Detection with Soft Image Abstraction[C] // 2013 IEEE International Conference on Computer Vision (ICCV). IEEE, 2013; 1529-1536.
- [40] JIANG Z, DAVIS L. Submodular Salient Region Detection[C] // Conference on Computer Vision and Pattern Recognition. IEEE, 2013; 2043-2050.
- [41] KLEIN D A, FRINTROP S. Center-surround divergence of feature statistics for salient object detection[C] // IEEE International Conference on Computer Vision, 2011; 2214-2219.
- [42] MAI L, NIU Y, LIU F. Saliency Aggregation: A Data-Driven Approach[C] // Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2013; 1131-1138.
- [43] ROTHER C, KOLMOGOROV V, BLAKE A. GrabCut: interactive foreground extraction using iterated graph cuts[J]. ACM Transactions on Graphics, 2004, 23(3); 309-314.
- [44] MANNAN S K, CHRISTOPHER K, MASUD H. The role of visual salience in directing eye movements in visual object agnosia[J]. Current Biology Cb, 2009, 19(6); 247-248.
- [45] WOLFE J M, HOROWITZ T S. What Attributes Guide the Deployment of Visual Attention and How do They Do it?[J]. Nature Review Neuroscience, 2004, 5(6); 495-501.
- [46] RUTISHAUSER U, WALTHER D, KOCH C, et al. Is bottom-up attention useful for object recognition?[C] // Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2004; 37-44.
- [47] SUN J, LING H. Scale and object aware image retargeting for thumbnail browsing[C] // 2011 IEEE International Conference on Computer Vision (ICCV). IEEE, 2011; 1511-1518.
- [48] MARCHESOTTI L, CIFARELLI C, CSURKA G. A framework for visual saliency detection with applications to image thumbnailing[C] // IEEE International Conference on Computer Vision. IEEE International Conference on Computer Vision, 2009; 2232-2239.
- [49] WANG Y S, TAI C L, SORKINE O, et al. Optimized scale-and-stretch for image resizing[J]. ACM Transactions on Graphics, 2008, 27(5); 32-39.
- [50] ZHANG G X, CHENG M M, HU S M, et al. A Shape-Preserving Approach to Image Resizing[J]. Computer Graphics Forum, 2009, 28(7); 1897-1906.
- [51] WU H, WANG Y S, FENG K C, et al. Resizing by symmetry-summarization [J]. ACM Transactions on Graphics, 2010, 29(6); 81-95.
- [52] HUANG S, WANG W, ZHANG H. Retrieving images using saliency detection and graph matching[C] // 2014 IEEE International Conference on Image Processing (ICIP). IEEE, 2014; 3087-3091.
- [53] FENG S, LANG C, LIU H, et al. Adaptive all-season image tag ranking by saliency-driven image pre-classification[J]. Journal of Visual Communication & Image Representation, 2013, 24(7); 1031-1039.
- [54] PAPUSHOY A, BORS A G. Image retrieval based on query by saliency content [J]. Digital Signal Processing, 2015, 36; 156-173.
- [55] HUANG J, YANG X, ZHANG R, et al. Re-ranking image search results by multiscale visual saliency model[C] // IEEE International Symposium on Broadband Multimedia Systems and Broadcasting. IEEE, 2010; 1-4.
- [56] WANG B, ZHANG X, WANG M, et al. Saliency distinguishing and applications to semantics extraction and retrieval of natural image[C] // 2010 International Conference on Machine Learning and Cybernetics (ICMLC). IEEE, 2010; 802-807.
- [57] GIOUVANAKIS E, KOTROPOULOS C. Saliency map driven image retrieval combining the bag-of-words model and PLSA[C] // 2014 19th International Conference on Digital Signal Processing (DSP). IEEE, 2014; 280-285.
- [58] HUANG J, YANG X, ZHANG R, et al. Integrating Visual Saliency and Consistency for Re-Ranking Image Search Results[C] // 2010 17th IEEE International Conference on Image Processing (ICIP). 2010; 653-661.