

基于全局和局部短期稀疏表示的显著性检测

樊强 齐春

(西安交通大学电子与信息工程学院 西安 710049)

摘要 显著性检测是计算机视觉研究的一个重要问题。提出了一种由底向上的基于稀疏表示的显著性检测新算法。一般显著性检测主要包含两个部分,即图像特征提取和显著性度量。对于一幅给定的图像,首先利用独立成分分析(ICA)方法提取图像特征,然后用一个局部和全局模型对图像进行显著性度量。其中,利用一种低秩表示方法提取全局显著性,以及利用一种稀疏编码方法提取局部显著性。最后融合局部和全局显著图得到最终的显著图。在一个眼关注数据库上与目前几种流行的方法进行了对比实验,实验结果显示所提出的方法能够得到更高的视觉关注预测准确率。

关键词 显著性检测,稀疏表示,低秩表示,稀疏编码

中图分类号 TP37 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.10.018

Saliency Detection Based on Global and Local Short-term Sparse Representation

FAN Qiang QI Chun

(School of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract Saliency detection has been considered to be an important issue in many computer vision tasks. We proposed a novel bottom-up saliency detection method based on sparse representation. Saliency detection includes two elements: image representation and saliency measurement. The two elements used in our method are both biological plausible and accurate. For an input image, we first used ICA algorithm to learn a set of basis functions, then the image could be represented by the set of basis functions. Next, we used a global and local saliency framework to measure the saliency respectively, and combined the two results to obtain the final saliency. The global saliency is obtained through Low-Rank Representation(LRR), and the local saliency is obtained through a sparse coding scheme. We compared our method with six state-of-the-art methods on two popular human eye fixation datasets. The experimental results indicate the accuracy of the proposed method to predict the human eye fixations is higher.

Keywords Saliency detection, Sparse representation, Low-rank representation, Sparse coding

1 引言

人眼视觉系统每时每刻都在接收着大量的信息,但并不同时处理所有的这些信息,而是选择一些重要的区域进行关注,称这样的区域为视觉显著性区域。显著性检测对于人类来说是一个简单的问题,但对于计算机来说却是一个困难的问题。然而,显著性检测在很多计算机视觉任务中却有很重要的应用^[1-4]。最近,显著性检测已经成为一个热门的研究方向,很多理论和应用被提了出来。

就检测方法是否需要人类监督,显著性检测方法可以分为两类:由底向上、数据驱动及任务独立的显著性检测方法和由顶向下、目标驱动及任务依赖的显著性检测方法。本文提出的方法属于第一种。在构造显著性检测算法中最重要的两步是图像的和显著性度量。研究者们提出了很多的特征描述子,比如说颜色、强度、朝向^[5,6]等。不同的方法使用这

些特征中的一个或几个来表示图像。然而,只使用一个或几个特征并不能完全地表示图像,会有信息损失。一些研究者发现:人类初级视觉突触细胞的接收域对于所观察到的图像产生一个稀疏表示^[7]。这个观察促使了很多工作使用稀疏特征来表示自然图像^[8-10],这类方法首先收集大量的自然图像块,然后利用独立成分分析(ICA)进行学习,最后得到一组基函数,图像可以用这组基函数进行线性表示,这种方法被称为“长期稀疏表示”^[11]。然而,就像 Sun 等人的工作^[11]中所述,这样做并不能对每一幅输入图像产生一个没有信息损失的表示,这是因为图像中的某些信息可能难以被这些提前定义好的基函数所表示,并且信息损失主要发生在显著性区域上。Sun 等人^[11]提出了一种叫做“短期稀疏表示”的方法,即首先将一幅输入图像分割成块集,然后利用 ICA 算法对块集进行学习,得到一组基函数。这幅图像可以由这组基函数进行线性表示,且这种表示没有信息损失。

到稿日期:2013-03-20 返修日期:2013-08-31 本文受国家自然科学基金(60972124),863项目(2009AA01Z321),973计划子课题(2010CB327902),高等学校博士学科点专项科研基金(20110201110012)资助。

樊强(1988-),男,硕士,主要研究方向为图像的显著性检测,E-mail:dsfxlqq@stu.xjtu.edu.cn;齐春(1955-),男,博士,博士生导师,主要研究方向为图像超分辨率增强、图像检测与跟踪、图像分析与识别。

对于显著性度量,目前的方法可以分为两类:全局性模型和局部性模型。全局性模型通过在整个图像上计算特征的稀有性来找到显著性区域,例如 AIM^[8]、ICM^[9]等方法。局部性方法通过在一个小的局部范围内计算特征的稀有性来找到显著性区域,例如 Itti^[5]、GBVS^[12]等方法。局部性方法能够发现局部强烈的对比,但这些局部强烈的对比可能在全局上并不显著。全局方法能够发现全局稀有特征,但局部强烈的对比可能会被忽视掉。已有研究^[13]表明,人眼视觉突触遵守一个中心-四周的方法,视觉系统对局部强烈的对比非常敏感,因此只使用局部或全局的方法并不合理。本文采用全局和局部显著性度量融合的方法进行显著性检测,具体来说,首先计算局部和全局显著图,然后融合得到最终的显著图。

本文使用“短期稀疏表示”作为图像的表达方法,在全局模型部分,先将图像从颜色空间转换到特征空间,用低秩表示(LRR)方法将系数矩阵分解为一个低阶矩阵和一个稀疏矩阵,它们分别代表图像的规则信息和不规则信息,然后通过分析稀疏部分来获得全局显著性。在局部模型部分,利用一种稀疏编码的方法来度量局部显著性,稀疏编码的目标是找到信息损失和稀疏性之间的最优平衡。本文利用四周块来表示中央块,通过解一个 Lasso 问题,得到每一个块的表示系数。然后将一个块的局部显著性定义为稀疏编码长度和表示残差之间的乘积。最后,融合全局显著图和局部显著图得到最终的显著图。算法的流程如图 1 所示。

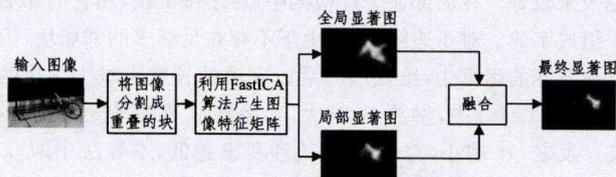


图 1 模板及其 ROI 区域

所提出的方法的贡献主要在于,提出的算法结合了更好的图像表示和更好的显著性度量方法,具体就是:引入了“短期稀疏表示”方法,能够更好地对图像进行表示。构建的全局和局部相结合的框架对于显著性检测来说更加准确,且从生物角度来说更加合理。

本文第 2 节介绍所提出的算法;第 3 节分为实验和对比分析;最后总结全文。

2 算法步骤

本节详细介绍所提算法的细节,算法主要有 4 个步骤:图像块的表示、全局显著性度量、局部显著性度量、融合。

2.1 图像块的表示

为了提高效率,本文使用块而不是像素作为基本的处理单元。其次如引言中所述,使用“短期稀疏表示”^[11]来提取图像特征,具体就是使用 ICA 算法对图像块进行学习来得到一组基函数。这里由 ICA 学习得到的基函数是相互独立的,并且是非高斯的。区别于之前的长期稀疏表示,这种对每一幅输入图像进行学习得到基函数的图像表示方法称为短期稀疏表示。

一个向量化的图像块 $x_k \in \mathcal{R}^{m \times 1}$ 可以被表示成基 $a_i \in \mathcal{R}^{m \times 1}$ 的线性叠加,表达式如下:

$$x_k = \sum_{i=1}^n r_i a_i = A s_k \quad (1)$$

式中, $A \in \mathcal{R}^{m \times n}$ 代表基字典,有 n 列基。 $s_k \in \mathcal{R}^{n \times 1}$ 是块 x_k 在基函数上的反应,其中 $s_k = [r_1, r_2, \dots, r_n]^T$ 。式(1)中, A 是通过从输入图像采样的块学习而来的。本文取块的大小为 4×4 , ICA 学习得到 $4 \times 4 \times 3 = 48$ 个基函数。如图 2 所示,一幅输入图像经过 FastICA 算法学习得到一组基函数。令 $W = A^{-1}$ 为滤波函数的集合,则一个块的系数可以表示为:

$$s_k = W x_k \quad (2)$$

对图像中所有的块按式(2)获得系数后,就把图像从颜色空间转换到了系数空间。

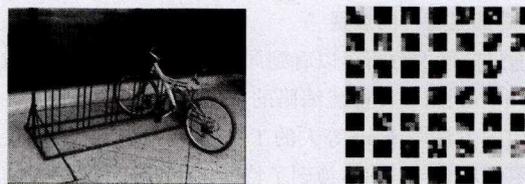


图 2 一幅输入图像和对应的基函数

2.2 全局显著性的度量

在显著性检测算法建模过程中,一个基本原则是压缩出现频率高的特征,而对异常的特征保持敏感。从显著性的角度来说,出现频率高的特征应该获得低的显著值,而出现频率低的特征应该获得较高的显著值。在 2.1 节已经获得了系数矩阵 $S = [s_1, s_2, \dots, s_n]$,其中 n 是图像块的个数。一幅图像中往往存在着显著性区域和背景区域,背景块的特征往往是相关联的,而显著块的特征明显区别于背景块的特征。本文利用 LRR^[14]来解决显著性检测问题,将系数矩阵按下式分解:

$$S = SZ + E \quad (3)$$

式中, Z 代表重建系数; SZ 代表背景部分,可以由 S 进行重建; E 代表显著性部分。如果不加约束,此式有无穷多解(针对 Z, E)。但在显著性检测问题中,可以认为显著性物体占少数,因此 E 是稀疏的。由于背景块是很相似的,它们之间可以相互表示,因此 Z 是低秩的。可以通过求解下面的模型解决显著性检测问题:

$$\begin{aligned} \min \|Z\|_* + \lambda_1 \|E\|_{2,1} \\ \text{s. t. } S = SZ + E \end{aligned} \quad (4)$$

式中, $\|\cdot\|_*$ 为核范数^[42],也即一个矩阵的奇异值的和; $\|\cdot\|_{2,1}$ 为 $\ell_{2,1}$ 范数, $\|E\|_{2,1} = \sum_{j=1}^n \sqrt{\sum_{i=1}^m (E(i,j))^2}$ 。参数 $\lambda_1 > 0$ 是一个平衡参数,用来平衡两部分的影响,可以根据两个范数的性质来选择,或者根据经验来调整。 $\ell_{2,1}$ 范数使 E 的列为零,这样 E 就趋近于稀疏。

将式(4)的最优解表示为 E^* ,对于每个块,全局显著性定义为:

$$S_{global}^i = \|E^*(:,i)\|_1 = \sum_{j=1}^n \|E^*(j,i)\| \quad (5)$$

式中, $\|E^*(:,i)\|_1$ 定义为 E^* 中第 i 列的 ℓ_1 范数。在本算法中,因为会用到块重叠,所以一个像素的全局显著性是叠加在这个像素上的所有块的显著性的累加。当每一个像素得到显著值后,进行标准化便得到像素级别的全局显著图。

下面来解式(4),首先将它转换为下面的等式:

$$\begin{aligned} \min & \|J\|_* + \lambda_1 \|E\|_{2,1} \\ \text{s. t. } & X = XZ + E, \\ & Z = J \end{aligned} \quad (6)$$

式(6)可以通过下面的增广拉格朗日乘子来求解:

$$\begin{aligned} \min_{Z, E, Y_1, Y_2} & \|J\|_* + \lambda_1 \|E\|_{2,1} + \text{tr}[Y_1^T(X - XZ - E)] + \\ & \text{tr}[Y_2^T(Z - J)] + \frac{\mu}{2} (\|X - XZ - E\|_F^2 + \\ & \|Z - J\|_F^2) \end{aligned} \quad (7)$$

式中, Y_1, Y_2 分别是拉格朗日乘子; $\mu > 0$ 是一个惩罚参数。式(7)可以通过 exact 或者 inexact ALM 算法来求解^[15], 本文用 inexact ALM 算法来进行模型求解。

2.3 局部显著性的度量

通过前面的分析可以看到局部显著性对于显著性检测很重要, 本节利用一种稀疏编码的方法来得到局部显著性。这里使用的方法与 Han 等人的工作^[16]相似, 不同的是我们首先将图像从颜色空间转换到了特征空间, 而 Han 等人的工作直接在颜色空间对图像进行显著性度量。在 2.1 节, 将图像从颜色空间转换到了系数空间, $S = [s_1, s_2, \dots, s_n]$, s_i 代表第 i 个块经过稀疏表示后得到的系数, n 是图像块的系数。每个块 i 可以表示为如下形式:

$$s_i = D\alpha_i + r_i \quad (8)$$

式中, D 是一个字典, 由块 i 的邻居块的系数组成; r_i 是稀疏编码的残差; α_i 是块 i 的稀疏编码系数。 $A = \{\alpha_1, \alpha_2, \dots, \alpha_n\}$ 是稀疏编码系数的集合, $R = \{r_1, r_2, \dots, r_n\}$ 是稀疏编码的残差的集合。稀疏编码其实就是找到信息损失和稀疏性的一个最优平衡, 信息损失表示为 L , A 的稀疏性表示为 S 。稀疏编码问题可以表示为最小化如下代价函数:

$$E = L + \lambda_2 S \quad (9)$$

式中, L 是稀疏表示后的信息损失; S 是 A 的稀疏性; λ_2 是平衡信息损失和稀疏性的平衡系数。上面这个等式可以通过解下面这个最优化问题来得到解决:

$$\min \lambda_2 \|\alpha_i\|_0 + \|s_i - D\alpha_i\|_2^2 \quad (10)$$

但是这个问题不易求解, 幸运的是, 根据最新的研究^[17], 对于大多数系统, 最稀疏的近似解可以通过最小化 ℓ_1 范数来近似求解, 因此, 式(10)可以通过如下模型来得到近似解:

$$\min \lambda_2 \|\alpha_i\|_1 + \|s_i - D\alpha_i\|_2^2 \quad (11)$$

式(11)是著名的线性退化 Lasso 问题^[18], 可以通过 LARS 算法来求解, 本文使用 SPAMS 工具包^[19]来实现 LARS 算法, SPAMS 工具包是 LARS 算法的快速实现。

在计算求解 Lasso 问题之后, 可以得到稀疏性表示 $A = \{\alpha_1, \alpha_2, \dots, \alpha_n\}$, 对于块 i , 局部显著值的计算如下:

$$S_{local} = \|\alpha_i\|_0 \cdot \|x_i - D\alpha_i\|_1 \quad (12)$$

同全局显著性一样, 一个像素的局部显著性是这个像素上各个相关块显著性的累加。在得到像素级别的显著值后, 进行标准化就可获得像素级别的显著图。

2.4 融合

得到了像素级别的全局显著图 S_{global} 和局部显著图 S_{local} 之后, 将它们融合成为一个整体显著图。类似于 Borji 等人的工作^[20], 可以采用许多不同的融合策略(比如 +, *, max, min), 在做了许多对比实验后发现乘法(*)能够获得较好的

检测结果, 故本文使用乘法作为融合方法, 融合的显著图可以按下式得到:

$$S_{gl} = S_{global} \cdot S_{local} \quad (13)$$

当得到 S_{gl} 后, 对显著图进行标准化便可得到最终结果。为了更好的视觉效果, 可以用一个 2D 高斯滤波器($\sigma=4$)进行滤波处理。

3 实验

本文的实验主要是人眼关注点预测, 人眼关注点预测实验可以通过检测显著图来预测人眼关注点的准确性。通过比较显著图和人眼关注点, 画出 ROC 曲线, 得到 AUC 值, 并与目前几种典型方法在一个流行的数据库上进行了定性和定量的比较。

3.1 参数设置

本文所提方法简称 SSR, 为了提高运算效率, 将图像下采样到原图像大小的 0.1。图像被分割成大小为 4×4 像素的块, 分块的时候 4 个方向和其相邻块各有 2 个像素的重叠, 使用重叠主要是为了减小图像分块造成的影响。全局显著性检测中, 式(4)中的参数 λ_1 是为了平衡低秩和稀疏的影响, 较大的 λ_1 意味着式(4)中对于稀疏性的要求较高, 因此得到的 E 较稀疏。相反, 较小的 λ_1 意味着式(4)中对于稀疏性的要求较低, 因此 E 更不稀疏。我们按文献^[14]中 LRR 算法工具包中的建议, 将 λ_1 从 0.0001 变化到 0.1, 发现 0.0005 能使检测效果较好。在局部显著性检测中, 对于每个块, 用它的邻居块组成字典。对于边缘的块, 由于不存在足够多的邻居块, 因此在实际的运算中, 给式(12)乘以字典的长度来减小边缘的影响, 在 Lasso 中, 参数 λ_2 越大, 对系数 α_i 的稀疏性要求越高。反之, λ_2 越小, 对 α_i 的稀疏性要求越低, 本算法中取 0.15, 在这个值附近能够取得较好的检测效果。

3.2 Bruce 数据库上的结果

将 Bruce 等人收集的的关注点数据^[8]作为比较的基准, 这个数据包含了 11999 个人眼关注点, 这些关注点是从 20 个人观看 120 幅自然图像而得来的。这些关注点是通过下面的实验得到: 图像按随机的顺序播放, 每幅图片播放 4 秒钟, 两幅图片中会有遮挡物遮挡, 受试者被置于一个 21 英寸的显示器前 0.75 米, 观看图像的时候没有给予任何的指示或提醒。这 120 幅自然图像包含大量的室内和室外的场景, 有些图像有很显著的物体, 有些没有很显著的物体。这个数据库也是目前最经典且使用得最多的数据库之一。

为了比较 SSR 的显著图和人眼关注点, 使用 Bruce 等人介绍的著名的验证方法^[8], 具体来说, 将接受者工作特性曲线(ROC)和曲线下方的面积(AUC)作为检测方法。ROC 曲线是一个二维曲线, 曲线中, Y 轴是真阳性率(TPR), X 轴是假阳性率(FPR)。TPR 也叫命中率, FPR 也叫误报率, 可以按下式进行计算:

$$TPR = \frac{TP}{TP + FN} \quad (14)$$

$$FPR = \frac{FP}{FP + TN} \quad (15)$$

式中, TP 是真阳性的个数; TN 是真阴性的个数; FP 是假阳性的个数; FN 是假阴性的个数。ROC 曲线是 TPR 和 FPR 的权衡。AUC 是 ROC 曲线下的面积, 它的值是 0 到 1。如果

是理想的分类器, AUC 的值是 1, 如果是随机猜测, AUC 的值是 $0.5^{[21]}$ 。显著图在门限 $[0, 255]$ 中每一点被二值化, 在这点上利用二值化的显著图和关注点图来计算 TPR 和 FPR 。当得到 256 对 TPR 和 FPR 之后, 就可以画出 ROC 曲线(对数据库中所有图像取平均), 并可以计算得到 AUC 值。本文使用 Harel 等人的工作^[12]的算法代码来产生 ROC 曲线和 AUC 值。但是这里面做了一些修改, 在文献^[12]的代码中, 对于每幅显著图, 门限的值是那些在显著图中存在的值。而本文使用在 $[0, 255]$ 中的每个值。

首先, 利用一个实验来验证加入块重叠、短期稀疏表示及局部显著性度量的必要性。假设 A 为局部显著性度量, B 为短期图像表示, C 为块重叠。从表 1 可以看出, 当加入局部显著性后, AUC 值从 0.7852 提升到 0.8014, 这就证明当加入局部显著性后, 显著性检测效果得到提升。如果图像块不用短期稀疏表示, 效果更差, 这就证明了短期稀疏表示在图像特征提取中的优势。当没有块重叠时, AUC 值下降了不少, 这是因为块重叠可以保证 SSR 能够获得更多的图像信息。

表 1 SSR 和不同参数设置下的方法的比较

方法	AUC
SSR	0.8014
去掉 A 的 SSR	0.7852
去掉 A, B 的 SSR	0.7101
去掉 A, B, C 的 SSR	0.6375

为了检验所提 SSR 方法的效果, 将 SSR 和目前流行的 6 种方法进行比较: 4 种经典的方法 $AIM^{[8]}$ 、 $itti's^{[5]}$ 、 $ICM^{[9]}$ 、 $SR^{[22]}$, 还有与 SSR 比较近似的 $ST^{[11]}$ 、 $SCR^{[16]}$ 。 ST 方法是基于神经科学理论提出的。对于每一幅输入图像, 首先用 ICA 方法学习, 得到一组基函数, 然后图像中的每一个块可以用这组基函数进行线性表示, 这样就把图像从颜色空间转换到特征空间。对于每一个稀疏特征, 作者定义了一个背景入射率, 也即所有块中该特征的均值。对于一个特定的要计算的块, 作者定义了一个特征激活率, 并且认为当一个区别于背景入射率的特征出现的时候, 这个特征能刺激神经, 也即代表高的显著值。一个块的特征激活率被定义为这个块中所有特征与相应的背景入射率之间的差异的绝对值之和。这个块的显著性被认为是特征激活率。 SCR 方法没有进行任何特征转换, 而是直接用图像的颜色作为特征, 然后用 SSR 的局部显著性度量进行计算得到显著图。对于方法 AIM 、 $itti's$ 、 ICM 、 SR , 直接使用作者的原来代码实现。而对于 ST 和 SCR 方法, 进行了 matlab 编程实现。为了与 SSR 进行对比, 上述两种方法和 SSR 使用同样的参数。为了对比说明结合全局与局部特性的优势, 同时还加入了 $GSSR$ 方法, 也即 SSR 方法忽略掉局部显著性, 只使用全局显著性度量的方法。定性的对比如图 3 所示。由图可见, SSR 与人眼关注点图更加接近, 能够更加准确地预测人眼关注点。为了更加直观地对比, 没有使用人眼关注点, 而是使用人眼关注点图, 人眼关注点图是在人眼视觉关注点上加高斯滤波而来的图。定量的实验如表 2 所列, 由表可见, SSR 的 AUC 值高于其他 6 种方法, 即使是 SSR 的全局方法 $GSSR$ 的 AUC 值也要明显高于其他方法, 因此提出的方法在预测人眼视觉关注点方面具有更高的准确率。

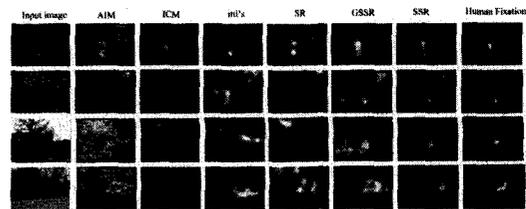


图 3 几种方法的定性比较

表 2 几种方法的定量比较

方法	AUC
AIM	0.7243
SR	0.7311
ST	0.7441
SCR	0.7534
Itti's	0.7602
ICM	0.7645
GSSR	0.7852
SSR	0.8014

结束语 本文提出一种基于全局和局部短期稀疏表示的显著性检测算法, 首先使用基于 ICA 的短期稀疏表示方法将输入图像从颜色空间转换到特征空间。在全局显著性检测中, 利用低秩分解(LRR)将图像特征分解为一个低秩矩阵和一个稀疏矩阵, 低秩矩阵代表重复性高的背景区域特征, 稀疏矩阵代表图像中区别于背景区域的显著性特征, 通过分析稀疏矩阵得到全局显著性。对于局部显著性, 如果一个块不能被它的邻居块稀疏、低误差地表示, 那么这个块被认为是显著块。采用稀疏编码方法建立一种局部稀疏性和信息损失模型, 进而通过求解模型来提取局部显著性。最后融合全局显著性和局部显著性构建一种人眼显著性检测 SSR 方法。与其它 6 种方法在一个流行数据库上进行了定性和定量实验比较, 结果显示本文所提 SSR 方法在预测人眼关注点方面具有更好的准确性。本文只讨论了静止图像 SSR 方法显著性检测, 可以在 SSR 方法框架中加入一些运动特征来将其扩展到视频显著性检测。

参考文献

- [1] Avidan S, Shamir A. Seam carving for content-aware image re-sizing[J]. *ACM Transactions on Graphics*, 2007, 26(3): 10
- [2] Han J, Ngan K, 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
- [3] Ko B, Nam J. Object-of-interest image segmentation based on human attention and semantic region clustering[J]. *JOSA. A*, 2006, 23(10): 2462-2470
- [4] 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*. 2004, 2: 37-44
- [5] Itti U, Koch C, Niebur E. A model of saliency-based visual attention for rapid scene analysis[J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 1998, 20(11): 1254-1259
- [6] Judd T, Ehinger K, Durand F, et al. Learning to predict where humans look[C] // *IEEE International Conference on Computer Vision*. 2009: 2106-2113

法,并且在本文字典基础上,加入空间信息约束的分类效果也优于单独使用光谱信息的分类效果。

本文算法提高了分类效果,但也有许多值得进一步改进的地方,如在高光谱图像的分类方法中的邻域约束仅采用了固定的8邻域信息,若能根据像元的分布采用随机窗口约束或是空间金字塔进行约束,则可以提高分类精度。

参考文献

[1] Plaza A, Benediktsson J A, Boardman J W, et al. Recent advances in techniques for hyperspectral image processing [J]. *Remote Sensing of Environment*, 2009, 113(1): 110-122

[2] Geng Xiu-ru, Zhang Xia, Chen Zheng-chao, et al. Classification algorithm based on spatial continuity for hyperspectral image [J]. *Journal of Infrared Millimeter Waves*, 2004, 23(4): 209-302

[3] Mathieu F, Jón A B, Jocelyn C, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(11): 3804-3814

[4] 高恒振,万建伟,粘永健,等.一种基于谱域-空域组合特征支持向量机的高光谱图像分类算法[J]. *宇航学报*, 2011, 32(4): 917-921

[5] Fauvel M, Chanussot J, et al. A spatial-spectral kernel-based approach for the classification of remote-sensing images [J]. *Pattern Recognition*, 2012, 45(1): 381-392

[6] Fu Z, Antonio R. Discriminant Absorption-Feature Learning for Material Classification [J]. *IEEE Transaction of Geoscience and Remote Sensing*, 2011, 49(5): 1536-1556

[7] Haq Q S, Shi Li-xin, Tao Lin-mi, et al. A L1-minimization based approach for hyperspectral data classification[C]//*Proceedings of 2010 International Conference on Remote Sensing (ICRS)*. 2010, 2: 139-142

[8] Yi Chen, Nasrabadi N M, Tran T D. Hyperspectral image classification using dictionary-based sparse representation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(10): 3973-3985

[9] 宋相法, 焦李成. 基于稀疏表示及光谱信息的高光谱遥感图像分类[J]. *电子与信息学报*, 2012, 34(2): 268-272

[10] Haq S, Tao Q L, et al. A Fast and Robust Sparse Approach for Hyperspectral Data Classification Using a Few Labeled Samples [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 99: 1-16

[11] Iordache M D, Dias J M B, Plaza A. Sparse unmixing of hyperspectral data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(6): 2014-2039

[12] Wright J, Yang A, Ganesh A, et al. Robust face recognition via sparse representation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(2): 201-227

[13] Elhamifar E, Vidal R. Robust classification using structured sparse representation[C]//*IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2011: 1873-1879

[14] Weizman L, Goldberger J. Urban-Area Segmentation Using Visual Words[J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(3): 388-392

[15] <https://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html>

(上接第83页)

[7] Olshausen B, Field D. Emergence of simple-cell receptive field properties by learning a sparse code for natural images[J]. *Natural*, 1996, 381(6583): 607-609

[8] Bruce N, Tsotsos J. Saliency based on information maximization [C]//*Advances in neural information processing systems*. 2006, 18: 155-162

[9] Hou X, Zhang L. Dynamic visual attention: Searching for coding length increments[C]//*Advances in Neural Information Processing Systems*. 2008, 21: 681-688

[10] Yan J, Zhu M, Liu H. Visual saliency detection via sparsity pursuit[J]. *IEEE Signal Processing Letters*, 2010, 17(8): 739-742

[11] Sun X, Yao H, Ji R. Saliency detection based on short-term sparse representation[C]//*Proceedings of 2010 IEEE 17th International Conference on Image Processing*. 2010: 1101-1104

[12] Harel J, Koch C, Perona P. Graph-based visual saliency[C]//*Advances in Neural Information Processing System*. 2006: 545-552

[13] Vinje W, Gallant J. Receptive fields and functional architecture in two nonstriate visual areas[J]. *Journal of Neurophysiol*, 1965, 28: 229-289

[14] Liu G, Lin Z, Yu Y. Robust subspace segmentation by low-rank representation[C]//*International Conference on machine learning*. 2010

[15] Liu G, Chen M, Ma Y. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrix[R]. *UTUC Technical Report UILU-ENG-09-2215*. 2009

[16] Han B, Zhu H, Ding Y. Bottom up saliency based on weighted sparse coding residual[C]//*Proceedings of the 19th Annual ACM International Conference on Multimedia*. 2011: 1117-1120

[17] Donoho D L. For most large underdetermined systems of linear equations the minimal[J]. *Communications on pure and applied mathematics*, 2006, 59(6): 797-829

[18] Tibshirani R. Regression shrinkage and selection via the lasso [J]. *Journal of the Royal Statistical Society Series B (Methodological)*, 1996, 58(1): 267-288

[19] Mairal J, Bach F, Ponce J, et al. Online learning for matrix factorization and sparse coding[J]. *The Journal of Machine Learning Research*, 2010, 11: 19-60

[20] Borji A, Itti L. Exploiting local and global patch rarities for saliency detection[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. 2012: 478-485

[21] Davis J, Goadrich M. The relationship between Precision-Recall and ROC curves[C]//*Proceedings of the 23th International Conference on Machine Learning*. 2006: 233-240

[22] Hou X, Zhang L. Saliency detection: A spectral residual approach[C]//*IEEE International conference on Computer Vision and Pattern Recognition*. 2007: 1-8