

SAR 图像局部非线性分布特征及提取算法

管 涛 于浩杰

(郑州航空工业管理学院计算机科学与技术系 郑州 450015)

摘 要 谱聚类是当今机器学习领域的研究热点,大多数算法用于图像分割。由于谱聚类能够刻画数据在低维空间内的主要特性,因此分析了谱聚类表示特征的原理,构造了一种面向图像子块的非线性局部特征,提出了相应的特征提取算法,用于刻画 SAR 图像分块的性质。这些特征由谱聚类产生的若干特征值构成的向量组成,然后经过傅里叶变换得到,因而具有平移不变性。在计算的过程中,可以采用 Nyström 等方法解决谱聚类中矩阵不可逆问题。为了避免减弱局部特性差异,在子块相似性计算中采用了明氏距离。实验验证了所提特征的有效性。

关键词 谱聚类, 平移不变特征, 图像特征, SAR 图像, 图像块

中图法分类号 TP391.41 文献标识码 A

Local Nonlinear Distribution Feature and Extraction Algorithm for SAR Images

GUAN Tao YU Hao-jie

(Department of Computer Science and Application Zhengzhou Institute of Aeronautical Industry Management, Zhengzhou 450015, China)

Abstract Spectral clustering is a current research focus and most algorithms are applied to image segmentation. With the capacity of finding low dimension space of spectral clustering, this paper analyzed the principle of feature representation of spectral clustering, proposed a new local nonlinear distribution feature extracted from sub-blocks of SAR images and used to describe the properties of sub-blocks. These feature vectors are rotationally invariant and they are obtained via several steps. First, the initial feature vectors are obtained via spectral clustering and then they are transformed by discrete Fourier transform. We used Nyström approach to compute the eigenvalues of spectral clustering. In order to avoid weakening the difference of local characteristics in sub-graphs, we adopted Minkowski distance to compute similarity among sub-graphs. The efficiency of our features is validated by experiments.

Keywords Spectral clustering, Shift invariant feature, Image feature, SAR image, Image patch

1 引言

图像特征的定义和设计是图像描述、目标识别的重要步骤,在图像和视频工程应用中起着关键性的作用。图像的描述特征很多,如点、线、面、颜色、形状、灰度等,但是,不同特征的提取方法、作用和描述能力不一样。Harris 角点是一种典型的点特征;SUSAN 算子能够发现图像中对象的边缘特征;MSERs 可用于检测图像稳定区域特征^[1]。统计量如均值、方差、斜度、峰度、分布、拖尾性质也可以作为图像的特征。除了以上特征外,变换后得到的特征在图像描述中普遍存在。王国力等人构造了一种单演函数,并用它提取了一种 SAR 图像特征用于图像配准^[2]。正交变换是提取图像特征的方法之一^[3-5],不同的正交基在特征提取的效果、类型上存在差异。小波变换可以较好地获取图像中对象的横向、竖向边缘,曲波变换可以发现小波变换不能提取的斜向边缘。对于纹理图像,小波变换不能达到最佳的逼近,脊波变换实现了这一功能。方向波变换能够提取图像的各向异性特征。可见,不同

的正交基会产生不同性质的图像特征,所反映的图像信息也不一样。

谱聚类算法是近些年来图像处理领域较为流行的算法之一,在降维、聚类、图分割等方面具有优异的性能。在原理上,谱聚类利用了图上节点之间的相似矩阵的 Laplace 变换的特征值构造数据的低维空间表示,有效地发现了数据的非线性低维嵌入结构。从物理学角度来看,谱聚类与 Laplace 特征映射是等价的,都是连续积分算子特征函数学习问题的特例^[6-8]。谱聚类也与核 PCA、核判别分析、流形映射等模型存在着紧密的联系,因而,基于 PCA 的特征提取方法自然地可以发展到基于谱聚类的特征分析。在计算实践中,通常的谱聚类算法在特征值分解阶段往往耗费大量的时间,不适用于大数据分析。而基于 Nyström 方法的插值技术可以有效提高谱聚类的效率^[9]。

在图像识别领域,设定不同的优化目标将产生不同的算法模型,典型的有 NJW 算法^[10]、Ncut、Ratio-cut、Ratio Association Criteria。这些方法采用广义 Laplacian 等矩阵的特

本文受国家自然科学基金项目(41171341),河南省基础与前沿技术研究计划项目(132300410186),河南省教育厅科学技术研究重点项目资助计划(14A520060),河南省教育厅项目(2010B520032),河南省教育厅高等学校骨干教师资助计划(2010GGJS-148),郑州市科技局项目(20130783)资助。

管涛(1974—),男,博士,副教授,CCF 会员,主要研究方向为统计机器学习、数据挖掘、图像分析与处理,E-mail: easyguan@126.com。

征值,注重从整体上分割图像。由于受到了度量尺度的影响,同时在优化目标模型中仅具有基于距离的相似性,因而统一的优化目标无法较全面地表达图像的局部特性。目前,在局部精度上有一些提高的方法。Mahoney 等人给出了具有局部偏差的 Laplace 矩阵的第二个特征向量,在半监督图分割中提高了质量^[11]。Maji 等人提出了包含偏置信息的 Biased-Ncut 算法,其解决了图像指定区域的分割问题^[12]。Belkin 等人通过优化球面上的对比函数提出了一种多路谱聚类算法,算法的优点是不依赖于初始条件^[13]。Arias-Castro 等人将数据分为若干邻域,在邻域中心计算协方差矩阵得到前 d 个特征向量,然后利用数据在这些方向上的投影距离计算相似性权重^[14]。面对动态变化的矩阵,Dhanjal 等人提出了一种增量式近似特征向量学习方法^[15],Smith 等人提出了基于扩散模型的谱聚类算法^[16]。最近的工作集中在改进模型本身或者学习方式方面。谱聚类及相关的流形嵌入学习已经在图像分段、人脸识别、基因表达数据分析、社会关系^[17]、文本挖掘等领域有许多研究成果。

鉴于谱聚类能够在低维空间描述数据的主要结构,本文提出了一种新型的 SAR 图像非线性分布描述特征。该特征揭示了子图像素点在低维空间的分布状况,具有平移不变性,在一些场景中能够刻画子图之间的相似性。较之前的工作,本文焦点不在于图像分割或者目标识别,而是着重于如何构造区分图像子块的非线性分布特征。此外,文中构造的特征反映了子图的像素分布的特性,并不体现所有的信息(如图像子块的像素位置和结构信息),因此,在复杂场景目标识别问题中还需要融合其他特征信息。

2 谱聚类特征表示原理

一般情况下谱聚类用来聚类数据,尚未见到用于图像特征提取。谱聚类本质上是一种非线性降维方法,可以发现数据蕴含的非线性结构。据此,分析了利用谱聚类构造特征的原理。给定测度 μ 下 iid 样本 $X = \{x_1, x_2, \dots, x_n\}$,谱聚类可以表达为求解经验积分算子 T_n 的特征函数学习问题:

$$T_n(f_k)(x) \simeq \frac{1}{n} \sum_{j=1}^n K(x, x_j) f_k(x_j) = \lambda_k f_k(x) \quad (1)$$

其中, $K(\cdot, \cdot)$ 为某种核函数; λ_k 为第 k 个特征值; f_k 为 T_n 的第 k 个特征函数,即:

$$f_k(x) = \frac{1}{n\lambda_k} \sum_{j=1}^n K(x, x_j) f_k(x_j) \quad (2)$$

式(2)给出了数据经过谱聚类得到的非线性特征表示形式。通过这种形式可以定义样本在低维空间中的表示。实际中,谱聚类求解了 Gram 矩阵 $K(\cdot, \cdot)$ 的特征向量,并截取了适当长度的分量组成低维特征向量^[18]。

3 图像局部非线性分布特征

本文利用谱聚类算法的低维空间发现能力,提取了图像子块的一种具有平移不变性的近似局部非线性特征,为将来的 SAR 图像目标识别提供工具。该特征向量包含了图像子块的大部分像素分布信息,有效表达了子块之间的分布差异性。选择适当的低维空间维度,即可表达子块的大部分描述信息。当空间维度增加时,特征值构成的向量的描述能力就会得到增强。为了避免特征值向量的旋转问题,对该向量序列进行了傅里叶变换,构造了子图的平移不变特征,如图 1 所

示。图 2 给出了特征提取的过程。



图 1 特征方向在高维空间中的分布可能不同,形成的序列在位置上存在偏差




图 2 基于谱聚类算法的特征提取过程


非线性特征提取及子块相似性计算算法如下:

1. 将图像分成 l 个 $m \times m$ 大小的子图;
 - (1) 对第 $i(0 \leq i \leq l)$ 个子图进行特征变换,得到其特征子空间 F_i ;
 - (2) 谱聚类 F_i 中数据,得到前 k 个非线性特征值,形成特征值向量 V_i ;
 - (3) 对 V_i 进行傅里叶变换,得到平移不变特征 U_i ; 转(1);
2. 利用 U_i 计算 U 之间的明氏距离,输出子图之间的相似性度量。

算法中采用谱聚类发现子图的低维空间特征。由于用于提取特征子块并不大,因此谱聚类的复杂度并不影响算法的效率。给定 $n \times n$ 大小的图像,如果将其划分为 k 个 $m \times m$ 的子图,则算法计算复杂度为 $O(km^3)$ 。一般情况下 $m \ll n$,所以当 n 足够大时, $O(km^3) \ll O(n^3)$ 。如果子图亦较大或者矩阵不可逆,则采用 Nyström 方法解决。默认情况下,谱聚类的尺度参数设置为 0.5。

4 实验分析

为了测试本文特征的有效性,下面在一幅 256×256 大小的 SAR 图像上进行实验,如图 3(b) 所示。为方便起见,这里展示了前 6 个 32×32 图像子块,根据图像内容可以确定子图在原图中的位置。根据本文算法提取了子图在低维空间的 8 维特征,将其组成向量,并采用明氏距离计算了子图的相似性。



(a) 放大的子图



(b) SAR 图像


图 3 本文特征在 SAR 图像上的演示

表 1 为图 3(a) 所示子图之间的不相似性。从表 1 可知, 本文特征可以有效地反映 SAR 图像 32×32 子块之间的分布特征差异。比如, 子块 6 与子块 2、3、4 非常相似, 而与子块 1 差别较大。在交互式 SAR 目标识别问题中, 当用户指定某均匀区域为背景时, 则与之不相似区域可能包含了更多的信息; 反之, 类似于背景区域。

表 1 图 3(a) 所示子图之间的不相似性

	1	2	3	4	5	6
1	0	1.1861	1.1569	1.1669	1.0520	1.1861
2		0	0.0344	0.0278	0.9699	0.0314
3			0	0.0184	0.9548	0.0445
4				0	0.9596	0.0276
5					0	0.9579
6						0

下面选择了另一幅 SAR 图像开展实验, 图 4(a) 是部分 32×32 大小子图, 图 4(b) 图大小为 256×256 。在子图上采用基于 Nyström 方法的谱聚类算法实现了近似的特征提取。子图 3 和 19 的不相似度为 0.32, 但子图 3 与子图 4 和 10 的相似度较高。



(a) 子图相似性



(b) SAR 图像

图 4 SAR 图像及子块比较

结束语 本文提出了一种描述 SAR 图像子块的非线性分布特征, 用于鉴别子块之间的差异; 利用谱聚类的低维空间发现能力提取了这些特征。实验证明, 特征能有效区分 SAR 图像子块之间的差异。该特征不同于拓扑结构、几何特征, 只是反映了图像子块的一种低维嵌入结构。但是, 该特征尚不能解决图像中所有识别问题, 而是提供了一种辨别相似子块的方法。在今后的研究中, 将结合该特征和其他特征开展 SAR 图像滤噪、SAR 图像目标识别方面的研究。

参考文献

[1] Matas J, Churn O, et al. Robust wide baseline stereo from maxi-

mally stable external regions[J]. Image and Vision Computing, 2004, 22(10): 761-767

[2] 王国力, 周伟, 等. 基于单演信号理论的 SAR 图像配准[J]. 电子与信息学报, 2013, 35(8): 1779-1785

[3] 王永明, 王贵锦. 图像局部不变形特征与描述[M]. 北京: 国防工业出版社, 2010

[4] Candès E J, Demanet L, Donoho D L, et al. Fast discrete curvelet transforms[J]. Applied and Computational Mathematics, California Institute of Technology, 2005, 5(3): 861-899

[5] Candès E J, Donoho D L. Ridgelets: A key to higher-dimensional intermittency? [J]. Phil. Trans. R. Soc. A, 1999 (357): 2495-2509

[6] Rosasco L, Belkin M, De Vito E. On learning with integral operators[J]. Journal of Machine Learning Research, 2010(11): 905-934

[7] von Luxberg U, Belkin M, Bousquet O. Consistency of spectral clustering[J]. The Annals of Statistics, 2008(36): 555-586

[8] 韩彦彬. 正定积分算子的本征值[J]. 科学通报, 1986, 30(17): 1357-1357

[9] Fowlkes C, Belongie S, Chung F, et al. Spectral grouping using the Nyström method[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(2): 214-225

[10] Ng A Y, Jordan M I, Weiss Y. On spectral clustering: analysis and an algorithm[J]. Advances in Neural Information Processing Systems, MIT Press, 2001(14): 849-856

[11] Mahoney M W, Orecchia L, Vishnoi N K. A local spectral method for graphs: with applications to improving graph partitions and exploring data graphs locally[J]. Journal of Machine Learning Research, 2012(13): 2339-2365

[12] Maji S, Vishnoi N K, Malik J. Biased normalized cuts[C] // Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition. 2011: 2057-2064

[13] Belkin M, Rademacher L, Voss J R. The hidden convexity of spectral clustering[OL]. <http://arxiv.org/abs/1403.0667>

[14] Arias-Castro E, Lerman G, Zhang T. Spectral clustering based on local PCA[OL]. <http://arxiv.org/abs/1301.2007>

[15] Dhanjal C, Gaudelb R, Cléménçon R. Efficient eigen-updating for spectral graph clustering[J]. Neurocomputing, 2014, 131: 440-452

[16] Smith L M, Lerman K, Garcia-Cardona C, et al. Spectral clustering with epidemic diffusion[J]. Physical Review E, 2013, 88(4): 042813

[17] Mall R, Langone R, Suykens J A K. Kernel spectral clustering for big data networks[J]. Entropy, 2013(15): 1567-1586

[18] 管涛, 杨婷. 谱聚类广义模型与典型算法分析[J]. 模式识别与人工智能, 2014, 27(11): 1-11