

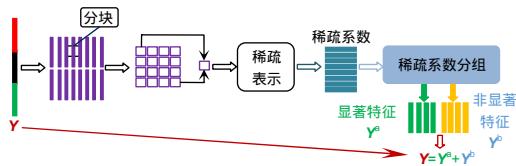


DOI: 10.12086/oee.2019.180627

结合稀疏表示和子空间投影的云图检索

唐彪, 金炜*, 李纲, 尹曹谦

宁波大学信息科学与工程学院, 浙江 宁波 315211



摘要: 卫星云图能从多角度展示各类云系特征及其演变过程, 实现基于内容的云图检索在天气实况监测、气候研究等方面具有重要意义。为了优化云图的组合特征, 增强其组合特征的泛化能力, 本文提出一种结合稀疏表示和子空间投影的特征优化方法。首先分别提取云图的颜色、纹理以及形状三种特征, 并对其组合特征进行转换分块; 然后对每一块的特征进行稀疏表示, 根据不同原子的方差来分组特征, 得到显著特征和非显著特征; 最后由分组特征的能量来计算得到子空间投影矩阵, 将初始的组合特征在投影矩阵上进行投影, 得到优化后的云图特征。实验结果表明, 本文优化云图特征的方法在查准率、查全率上均优于常用的降维方法和云图检索技术, 对组合特征具有较强的优化能力, 在实时检索过程中时间复杂度低, 是一种全新的检索方法。

关键词: 稀疏表示; 特征优化; 子空间学习; 云图检索

中图分类号: TP391.4

文献标志码: A

引用格式: 唐彪, 金炜, 李纲, 等. 结合稀疏表示和子空间投影的云图检索[J]. 光电工程, 2019, 46(10): 180627

The cloud retrieval of combining sparse representation with subspace projection

Tang Biao, Jin Wei*, Li Gang, Yin Caoqian

Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo, Zhejiang 315211, China

Abstract: Satellite cloud imagery can show the features and the evolution processes of all kinds of cloud systems from different aspects. Thus, adopting the content-based cloud image retrieval makes a big difference in supervising present weather conditions and studying the climate change. In order to optimize the combined features of the cloud picture and strengthen the generalization ability of its combined features, this paper presents an optimal method of combining the features of the sparse representation with the subspace projection. At first, we should extract its color, texture and shape, convert all the combined features, and divide them into different blocks. Then, we can make the sparse representation for each block's features, grouping them according to different atom variance and gaining both noticeable and unnoticeable features. Finally, we can count the power of the grouped features to get the subspace projection matrix, projecting the original combined features on it and achieving the optimal cloud picture features. The experiment turns out that the method of optimizing the cloud picture features in this paper is better than common descending dimension method and cloud retrieval technology in precision ratio and recall ratio. It indeed has a stronger optimization in the combined features as well as a lower time complexity in the process of the real-time

收稿日期: 2018-11-30; 收到修改稿日期: 2019-03-21

基金项目: 国家自然科学基金资助项目(61471212); 浙江省自然科学基金资助项目(LY16F010001)

作者简介: 唐彪(1994-), 男, 硕士研究生, 主要从事图像检索的研究。E-mail: 15058466279@163.com

通信作者: 金炜(1969-), 男, 博士, 教授, 主要从事稀疏表示和深度学习在模式识别上的应用研究。E-mail: xyjw1969@126.com

retrieval, which indicates a brand new retrieval method.

Keywords: sparse representation; feature optimization; subspace learning; cloud retrieval

Citation: Tang B, Jin W, Li G, et al. The cloud retrieval of combining sparse representation with subspace projection[J]. *Opto-Electronic Engineering*, 2019, 46(10): 180627

1 引言

包含丰富天气信息的卫星云图被广泛应用于日常天气预报业务，通过云图不仅可追踪云系的形成，监测降水状况，并可对灾难天气进行有效预警。由于不同类型的云对应着不同的天气信息，若两幅云图的视觉特征相似，那么两幅云图所对应的天气发展过程也极有可能相似，因此如果能在历史云图数据库中找到与该云系信息相似的云图，则通过分析历史上某一时刻的天气状况及其发展趋势，就有可能为当前的天气预报提供辅助信息^[1-2]。因此，基于内容的云图检索(content-based cloud image retrieval, CBCIR)技术随之诞生。提取不同类型的特征进行融合，往往产生“维度灾难”，且不同特征所描述云图信息的能力并不相同，简单地将多种特征进行融合，往往并不能实现高效的云图检索。因此，如何实现云图特征的优化具有重要的研究意义。

目前，在机器学习常用的特征降维方法可分为线性和非线性两类，线性最常见的方法有主成分分析(principal component analysis, PCA)和线性判别分析(linear discriminant analysis, LDA)，甘玲等通过PCA方法对梯度方向直方图特征进行降维，实现了快速的行人检测^[3]。吴贤伟等人通过提取胃镜图像的颜色直方图和颜色关联图并运用SPCA(simple principal component analysis)降维方法，不仅保持了检索的性能，还提高了检索的速度^[4]。华顺刚等人利用LDA算法训练生成一个使类间离散度最大，类内离散度最小的最佳分类器在人脸识别中取得了较高的识别率^[5]。然而PCA、LDA面对非线性可分的数据并不能取得满意的效果。在线性降维方法的研究基础上，通过引入核函数的思想，可以很好地弥补线性降维方法在非线性问题上不足。王慧等利用KPCA(kernel principal component analysis)方法对图像进行选择和降维，减少图像特征的数量，消除作用较小的特征，在图像分类的问题上取得了较高的正确率^[6]。赵洪伟等利用局部保持投影(locality preserving projections, LPP)对Gabor小波多尺度多方向的综合特征进行降维，提高了在不同工况下泡沫类别的识别率，有效地指导了实际矿物

的浮选生产过程^[7]。王宝锋等人针对水对光的强烈衰减作用，为了从仅有的水下图像获取更多的图像信息，采用了局部非线性的拉普拉斯(Laplacian)特征映射算法，对水下的彩色图像进行降维处理得到二维嵌入结果，最后通过重投影重建水下图像，提高了图像的对比度^[8]。颜文、李秀馨、上官伟等人通过提取云图的多个特征进行检索或者采用自适应融合的方法将特征进行融合，来实现基于内容的云图检索^[9-11]，虽取得了一定的查准率，但是时间复杂度高，并不利于检索实时化的需求。

本文借鉴稀疏表示所具有的特征保持性和稀疏性，对原始云图特征经过冗余字典稀疏表达，将组合特征分解为显著与非显著两部分，并采用线性子空间学习构造投影算子，在保证显著特征的过程中抑制非显著特征对云图检索的负面影响，使得原始的特征经过投影算子映射后，仍然保持较好的特征表达能力，从而可以有效实现云图综合特征优化。

2 云图多特征提取

卫星云图是一类比较特殊的图像，其表现为形状复杂，不规律，纹理细节信息丰富等，且在相邻时刻变化程度较大^[12]。若要实现准确的云图检索，本文采用常用的图像特征技术提取云图的灰度、纹理和形状三种特征，来较全面表达一幅云图信息。

2.1 灰度特征的提取

灰度作为卫星云图一种重要的视觉特征，直观反映了云顶反照率，是组成云图内容的基本要素。本文所设计的卫星云图检索系统服务于我们的FY2卫星云图接收系统，该系统所获取的云图中每个像素用8位二进制数表示，对应256级灰度。通过计算不同灰度的像素数占像素总数的比例，可较好地描述云图灰度分布的统计特性^[13]。卫星云图灰度直方图计算公式如下：

$$H(i) = \frac{n_i}{N}, i = 0, 1, \dots, L-1 \quad (1)$$

其中： n_i 表示灰度为 i 的像素个数， $H(i)$ 表示灰度为 i 的像素占云图像素总数 N 的比例。灰度直方图具有计

算复杂度低、较好的旋转缩放不变性，但是也存有一些局限，如不同内容的两幅云图，若灰度分布相似，则灰度直方图就可能类似从而导致检索失败，因此需要其它特征的辅助。

2.2 纹理特征的提取

Ojalat 等人对传统 LBP 进行改进，提出一种均匀局部二元模式算子(uniform local binary patterns, ULBP)，ULBP 采用半径为 $R(R>1)$ 的圆形窗口来计算 LBP 算子，如图 1 所示。当 $R=2$ 时，通常选择 8 个采样像素点，此时可产生 $2^8=256$ 种二进制模式；当 $R=3$ 时，通常选择 16 个采样像素点，此时可产生 2^{16} 种二进制模式；实际上，经过 Ojalat 等人的研究，大多数 LBP 模式最多只包含两次从 0 到 1 或者从 1 到 0 的跳变，如在半径 $R=2$ 采样 8 个像素点时的 LBP 模式可以为 00000000、00011111、01111110 等，这种模式称之为

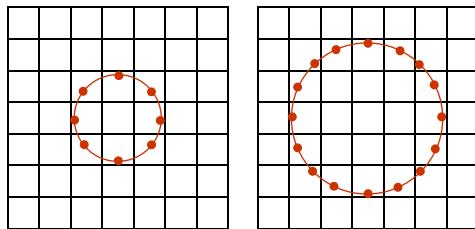


图 1 圆形 LBP 算子示意图

Fig. 1 Schematic diagram of circular LBP operator

均匀模式，另一种 0,1 之间跳变超过两次的称之为非均匀模式。由于 ULBP 只处理均匀模式，从而大大减小了二进制编码的模式，这样在半径 $R=2$ 时的 8 个采样点可组成 $8 \times 7 + 2 + 1 = 59$ 种均匀模式，并且在这种情况下，编码后的图像依然能够反映图像的绝大部分信息^[14]。因此，一幅云图经过 ULBP 编码后，最终可以得到 ULBP 编码图，统计编码图上的 59 种二进制模式直方图，可以将任意一幅高维图像用 59 维的 ULBP 统计直方图特征来描述。

本文选取连续一个月 FY2 卫星在北半球的亚洲区域和部分的太平洋区域上的云图，在一段时间里，除了在某个经纬度上云图有较大的变化外(如台风天气)，其它区域云图变化速度较为平缓，因此采用分块 ULBP 来对云图进行处理，以提取更为鲁棒的纹理特征。这种分块方式首先将图像分为若干小块，然后对每个小块进行 ULBP 变换，统计每个小块的 59 种二进制模式直方图，再将所有小块的直方图特征串联在一起，组成整幅云图的 ULBP 特征，图 2 给出了云图均分成 25 块后的 ULBP 直方图。

由图 2 可知，不同分块上的直方图分布各不相同，这也意味着不同区域有着不同的气象，将整个云图进行均分具有重要的研究意义。如果对整幅云图进行 ULBP 变换，容易忽略某个局部的变化，也就失去了云图检索的意义。

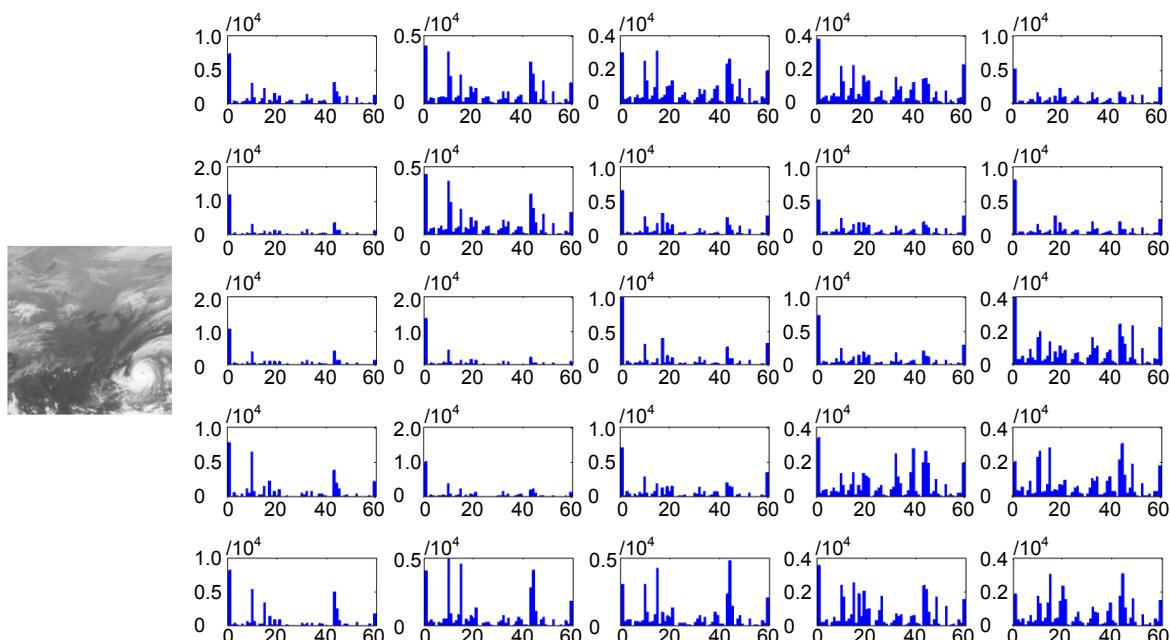


图 2 云图分块 ULBP 统计直方图特征

Fig. 2 Cloud image divided block ULBP statistical histogram features

2.3 形状特征的提取

卫星云图的云系形状多种多样，如高积云常以椭圆形或水波状密集云条存在；卷云一般呈现丝缕状、团簇状；而台风等热带气旋常呈现巨大云团漩涡等^[15]，因此可利用云图形状特征进行相似性检索。目前，对云图形状的描述主要是基于轮廓和基于区域两大类，一般轮廓相对于区域信息较少，且提取云系完整的轮廓比较困难，因此本文通过区域信息来描述云图的形状特征，这不仅能有效利用区域内所有的像素点，更能减少噪声等因素的干扰。云图区域信息的提取首先需要将云系从云中分割出来，本文采用迭代阈值分割法进行云图分割，具体如下：

a) 选择确定的初始阈值 T_0 大小：

$$T_0 = \frac{G_{\max} + G_{\min}}{2}, \quad (2)$$

式中： G_{\max} 为云图最大灰度值， G_{\min} 为云图最小灰度值。

b) 根据初始阈值分割云图，得到目标和背景两个部分，计算目标和背景的平均灰度：

$$Z_0 = \frac{\sum_{f(i,j) < T_0} f(i,j) \cdot N(i,j)}{\sum_{f(i,j) < T_0} N(i,j)}, \quad (3)$$

$$Z_1 = \frac{\sum_{f(i,j) \geq T_0} f(i,j) \cdot N(i,j)}{\sum_{f(i,j) \geq T_0} N(i,j)}, \quad (4)$$

式中： $f(i,j)$ 表示图像灰度大小， $N(i,j)$ 表示权重大小，设定为 1。

c) 计算新阈值：

$$T_1 = \frac{Z_0 + Z_1}{2}. \quad (5)$$

d) 迭代求解。如果新阈值与初始阈值的差小于预定值 10，则结束循环，否则以新阈值代替原始阈值，跳转步骤 b) 步继续求解分割。

e) 对原始云图根据阈值大小进行分割，得到二值

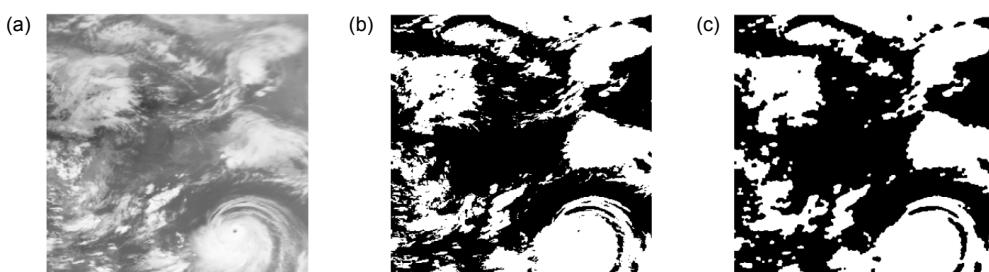


图 3 分割、开闭运算后的效果。(a) 原图；(b) 开运算后效果；(c) 闭运算后效果

Fig. 3 The effect after segmentation, open and close operation. (a) Original; (b) The effect of open operation; (c) The effect of close operation

图像，但是分割所得云系存在着许多毛刺，内部有大量的小孔，因此本文采用经典的开闭运算对云图进一步处理。通过开运算去除边界毛刺，通过闭运算去除内部大部分细小的空洞。最终效果如图 3。

本文分割处理方法能够较完整的保留云图的云系特征，保证了后续的形状特征提取工作。鉴于几何不变矩良好的旋转不变性，本文采用几何不变矩进行云图区域特征的描述。

对于离散的数字图像 $f(x,y)$ 的 $p+q$ 阶矩定义为

$$m_{pq} = \sum_x \sum_y x^p y^q f(x,y), \quad (6)$$

其中： $p+q$ 阶中心矩定义为

$$u_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x,y), \quad (7)$$

式中： $\bar{x} = m_{10} / m_{00}$ ， $\bar{y} = m_{01} / m_{00}$ 表示图像区域的中心，对式(7)进行规范化操作，规范化后的中心矩表示为

$$\eta_{pq} = \frac{u_{pq}}{u_{00}^{\gamma}}, \quad \gamma = \frac{p+q}{2} + 1, \quad p+q = 2, 3, \dots. \quad (8)$$

可以导出 7 个不变矩公式如下：

$$\begin{aligned} \varphi_1 &= \eta_{20} + \eta_{02}, \\ \varphi_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2, \\ \varphi_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2, \\ \varphi_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2, \\ \varphi_5 &= (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03}) \\ &\quad [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ &\quad +(3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \\ &\quad [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2], \\ \varphi_6 &= (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ &\quad + 4\eta_{11}(\eta_{12} + \eta_{30})(\eta_{21} + \eta_{03}), \\ \varphi_7 &= (3\eta_{21} - \eta_{03})(\eta_{12} + \eta_{30}) \\ &\quad [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ &\quad +(3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03}) \\ &\quad [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]. \end{aligned} \quad (9)$$

2.4 云图特征的综合

在提取了卫星云图的灰度、纹理和形状特征后，就可将这三组特征组合成一组特征向量，建立云图检索系统。但是对于云图来说灰度、纹理、形状又分别从不同的角度描述云图信息，其数据范围存在较大的差异，若将不同类型的特征直接排列作为一组综合特征，会造成数量级小的特征几乎无法影响检索结果，尤其综合特征往往都是高维的特征向量，不但影响了检索时间效率，而且不同特征分量间存在互相干扰且冗余度高，特别是某些相关性强而方差较小的特征分量对检索结果的影响并不显著，甚至会对云图检索的准确率产生负面影响，从而难以展现不同类型特征的综合效果。因此做到云图中显著特征的提取、不相关特征影响的消除、特征维数的降低这三方面，对云图检索有着重要作用。

3 基于稀疏编码及子空间投影的云图特征优化

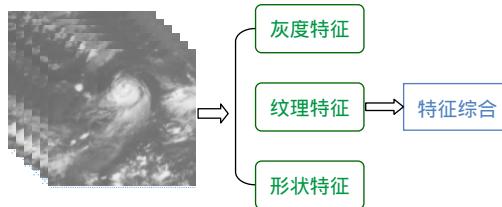
近年来，随着稀疏表示理论的发展及成熟，其在图像处理、模式识别、压缩信号重构等方面得到了广泛的应用，并以其信息表示的高效性及特征保持性为特征优化提供了新的解决思路^[16]。本文通过对原始云图的特征向量进行稀疏编码，将特征分量进行分组，然后结合线性子空间投影，提出一种新颖的特征优化方法，具体步骤如图 4 所示。

3.1 稀疏编码及特征分组

假设云图数据库存在 l 幅云图图像(记为 $1, 2, \dots, l$)， $Y_i \in R^m$ 表示为第 i 幅云图通过提取灰度、纹理和形状特征归一化后堆叠而成的列向量。则整个云图数据库可表示为 $Y \in R^{m \times l}$ ，如下所示：

$$Y = [Y_1, Y_2, \dots, Y_l] \quad (10)$$

设各幅云图特征向量中存在着显著特征 Y^a 和非显著特征 Y^b ，则云图数据库的显著特征可表示为 $Y^a = [Y_1^a, Y_2^a, \dots, Y_l^a]$ ，干扰特征可表示为



$Y^b = [Y_1^b, Y_2^b, \dots, Y_l^b]$ ，即 $Y = f(Y^a, Y^b)$ 成立，原特征 Y 可由 Y^a 和 Y^b 构成。因此若要从云图综合特征中提取显著特征，需要对云图综合特征重新学习，而该过程的关键就是对提取的云图特征进行分解。鉴于稀疏表示理论在信号处理上的优势，本文利用稀疏表示理论分解云图综合特征，根据特征中重要成分重构云图特征。

当某一云图特征向量表示为 Y_i ，为实现特征学习，需重构该特征向量。该向量可重新表示为 $T_i \in R^{t \times s}$ ，($m=t \times s$)，即将原向量以矩阵形式重排，再以 $n \times n$ 的分块方式对 T_i 进行分块处理，则 T_i 可重新表示为

$$H_i = [h_1, h_2, \dots, h_k] \quad (11)$$

其中： $H_i \in R^{z \times k}$ ($z=n^2$ ， $k=(t \times s)/(n^2)$)， $h_j(j=1, 2, \dots, k)$ 表示以 n^2 分块大小展开的列向量，为实现原始特征向量 Y_i 的稀疏表示，可对 H_i 进行稀疏分解。稀疏理论认为，如果存在着一个字典 $\Psi \in R^{z \times d}$ ($z < d$)，并可以用少量系数组合良好地表示 H_i ，则说明 H_i 可以在字典 Ψ 下进行稀疏表示，由压缩感知理论可转化为求解 L_0 最小化问题^[17]，即：

$$\min \|\alpha\|_1, \text{ subject to } \|H_i - \Psi \cdot \alpha\|_2^2 \leq \delta, \quad (12)$$

其中：字典 $\Psi = [\Psi_1, \Psi_2, \dots, \Psi_d]$ ，系数 $\alpha \in R^{d \times k}$ ，本文通过 K-SVD 字典学习算法进行逼近。

为提取综合特征中的重要信息成分，可通过计算 H_i 各块对应系数特征方差大小来区分。通过计算 H_i 各块对应序列方差进行大小排序，选取其中方差大的系数重构原始云图特征向量 $Y_i^a \in R^m$ ，同时利用方差小的对应系数重构原始云图特征向量 $Y_i^b \in R^m$ ，由此云图数据库的显著特征可表示为 $Y^a = [Y_1^a, Y_2^a, \dots, Y_l^a]$ ，非显著特征可表示为 $Y^b = [Y_1^b, Y_2^b, \dots, Y_l^b]$ 。

3.2 子空间学习

经过特征分组，原始的云图特征可以写成 $Y_i = Y_i^a + Y_i^b$ 的形式，对于整个云图特征 $Y = Y^a + Y^b$ 。基于子空间投影在降维的理论之上，我们将寻找一个子空间，其中显著部分被保留，而非显著部分将被抑制，可通过学习训练获取一个投影矩阵 P 来实现特征

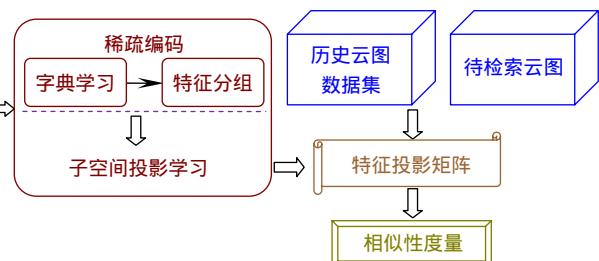


图 4 稀疏编码及子空间学习
Fig. 4 Sparse coding and subspace learning

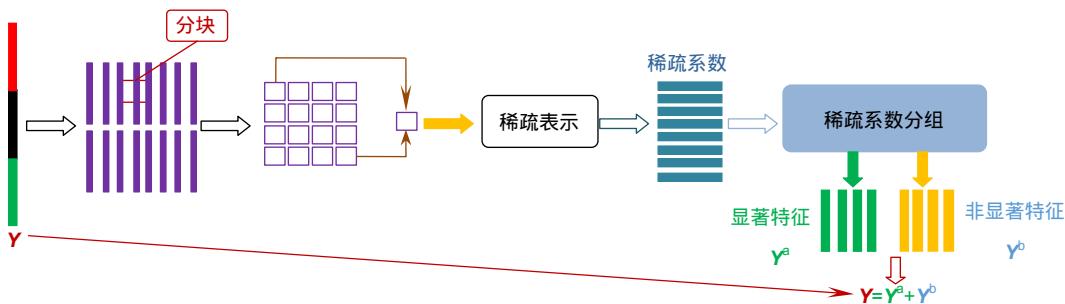


图 5 稀疏表示和特征分组流程

Fig. 5 Sparse representation and feature grouping processes

优化，即满足 $P \cdot Y = P \cdot Y^a + P \cdot Y^b$ ，因此如何计算得到该投影矩阵是关键所在。可通过最大化下列目标函数进行求解：

$$J = \arg \max_p (E_a / E_b) , \quad (13)$$

其中： E_a 表示显著特征能量， E_b 为非显著特征能量，即通过两类特征能量比最大化进行求解，以有效分离两类特征。 E_a 与 E_b 求解如下所示：

$$\begin{aligned} E_a &= \frac{1}{l} \sum_{i=1}^l \|PY_i^a\|_2^2 = \frac{1}{l} \sum_{i=1}^l (PY_i^a)^T (PY_i^a) \\ &= \text{tr}\{P(\frac{1}{l} Y_a Y_a^T) P^T\} = \text{tr}\{P(S_a) P^T\} , \end{aligned} \quad (14)$$

$$\begin{aligned} E_b &= \frac{1}{l} \sum_{i=1}^l \|PY_i^b\|_2^2 = \frac{1}{l} \sum_{i=1}^l (PY_i^b)^T (PY_i^b) \\ &= \text{tr}\{P(\frac{1}{l} Y_b Y_b^T) P^T\} = \text{tr}\{P(S_b) P^T\} , \end{aligned} \quad (15)$$

式中： tr 表示矩阵的迹， $S_a = \frac{1}{l} Y_a Y_a^T$ ， $S_b = \frac{1}{l} Y_b Y_b^T$ 分别表示两类特征的协方差矩阵，描述了两类特征的散布度，为使较小样本也能更好逼近总体方差，对其适当修改， $S_a = Y_a Y_a^T / (l-1)$ ， $S_b = Y_b Y_b^T / (l-1)$ ，由此式可转化为如下求解：

$$P_{\text{opt}} = \arg \max_p \frac{E_a}{E_b} = \arg \max_p \frac{\text{tr}\{P(S_a) P^T\}}{\text{tr}\{P(S_b) P^T\}} . \quad (16)$$

根据如上所述，由线性判别分析子空间，转化为广义特征方程进行特征值求解，如下：

$$S_a P = \lambda S_b P , \quad (17)$$

式中： P 的闭式解则是 $S_b^{-1} S_a$ 的最大非零广义特征值所对应的特征向量组成的矩阵， λ 表示对应的特征值。首先对协方差矩阵 S_a 与 S_b 之和进行特征分解得到矩阵 $P_1 \in \mathbb{R}^{m \times v}$ ，其中 $v (v < m)$ 为降维维度；根据特征能量 $P(S_a)P^T$ ， $P(S_b)P^T$ 及所降维度 v 求取广义特征值及特征向量 $P_2 \in \mathbb{R}^{v \times v'}$ ，则所求解的投影矩阵为

$$P = P_1 \cdot P_2, (P \in \mathbb{R}^{m \times v'}) . \quad (18)$$

根据求取的投影矩阵 P ，云图检索样本特征数据库 $Y \in \mathbb{R}^{m \times l}$ 可在样本空间投影获取优化特征，新的云图数据库可表示为 $W \in \mathbb{R}^{v' \times l}$ ，如下所示：

$$W = P^T \cdot Y . \quad (19)$$

由上式可知，通过投影变换处理由于 $v < m$ 可有效降低云图数据维数，降低云图检索运算复杂度，同时最大化地降低云图样本特征值中非显著特征的干扰，使得降维后的特征仍保持较强的表现力。对于查询云图，投影是唯一的附加操作，稀疏编码只需要在学习阶段，因此检索系统可以保持较高的时间效率。

4 实验结果与分析

4.1 云图数据集说明

本文气象云图数据均下载于国家卫星气象中心，选取 FY-2D 卫星分区图的数据，FY-2D 是我国自主研制的静止气象卫星系列，每隔一小时接收一张卫星云图。共收集了 1200 张，部分实验样本如图 6 所示。

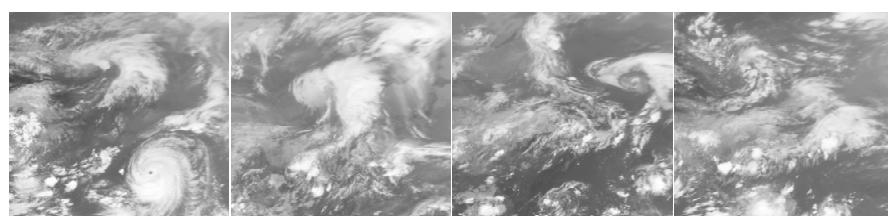


图 6 本文使用 FY-2D 部分云图样本

Fig. 6 FY-2D cloud image samples are used in this paper

4.2 评价准则

在本文的云图检索中，将从查准率、查全率两个角度来衡量本文算法的有效性。查准率是指检索所得的图像中与检索图像相关的图像数占返回图像数目的比例。

$$P_{\text{precision}} = \frac{m_1}{m_1 + m_3} \quad (20)$$

查全率是指检索所得的图像中与检索图像相关的图像数占整个数据库中相关图像数的比例。

$$P_{\text{recall}} = \frac{m_1}{m_1 + m_2} \quad (21)$$

其中： m_1 代表查询结果中与待检索图像相关的图像个数， m_2 代表相关但并未检索到的图像个数， m_3 代表检

索返回的图像中不相关的图像个数。

4.3 实验的相关参数说明

此处将给出第三章 3.1 节和 3.2 节出现的具体参数设置以及文中出现的矩阵维数，相关的参数设置见表 1，相关的矩阵维数见表 2。

4.4 对比实验设计及结果分析

为了检验本文算法的检索性能，将分别从特征优化和方法性能两个角度来设计对比实验，在 Intel Core i7-7700 CPU@3.6 GHz，64 G 内存，Matlab 2014 b 环境下使用 24 张云图数据作为待检索数据，依据时间上的连续性和相关气象专家的建议，确定每一张查询云图约有对应的 50 张云图是相似的，其中部分相似样本如图 7 所示。

表 1 文中相关的参数设置

Table 1 Related parameter settings in paper

Parameter	l	m	t	s	n	z	k	d	v	v'
Size	1200	1600	40	40	4	16	100	128	800	500

表 2 文中相关的矩阵维数

Table 2 Related matrix dimensions in paper

Dimension of matrix	P_1	P_2	P	W	Y	$Y_a=Y_b$	H_i	H
Size	1600×800	800×500	1600×500	500×1200	1600×1200	1600×1200	16×100	16×433200

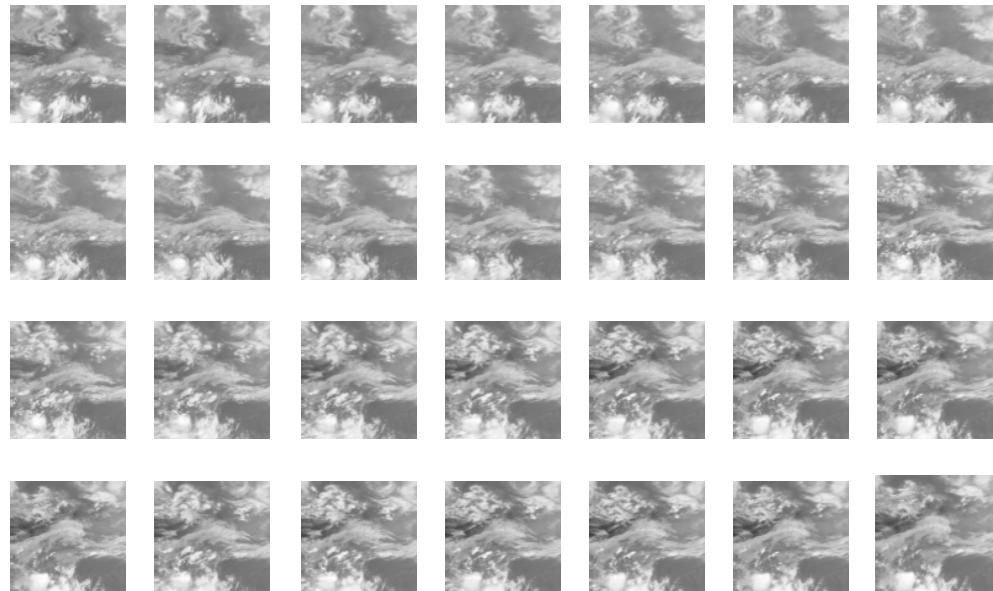


图 7 相似云图样本实例

Fig. 7 Sample examples of similar cloud image

4.4.1 降维性能对比

分别选择 PCA、SPCA、LDA、Laplacian 和 AutoEncoder 进行比较，通过不同的降维方法将原始特征大小优化到相同的维度，维度大小设置为 500，最后由欧氏距离来度量云图间的相似性，根据 24 次查询的平均查准率和查全率来衡量不同降维方法的性能。图 8 是本文方法在返回 20 幅云图下的查询结果。

如图 8 所示，待检索云图是一个正在运动的台风，根据返回的结果可知，本文可以返回 20 幅相似的台风云图，相当于在时间跨度上将该台风天气当天的云图均检索出来。因此本文方法能够较好地检索出该台风

的运动轨迹，以及台风天气前后大陆上空的云图变化，为气象部门做出相应的决策，提供较可靠的信息支撑。不同降维方法在返回不同云图数目下，产生的平均查准率和查全率如表 3 和表 4 所示。

由上表 3 和表 4 可知，在返回 5 张相似云图的情况下，其 PCA、SPCA 和 LDA 均取得非常好的效果，由此可见，在返回少量相似云图的情况下，其上三种降维方式均可取得满意的效果，而自动编码机（AutoEncoder）作为新一代降维算法，可能缺少足量的训练数据导致在小数据量的样本中并不能发挥出其优秀的降维性能。随着返回云图数目的增加，SPCA、

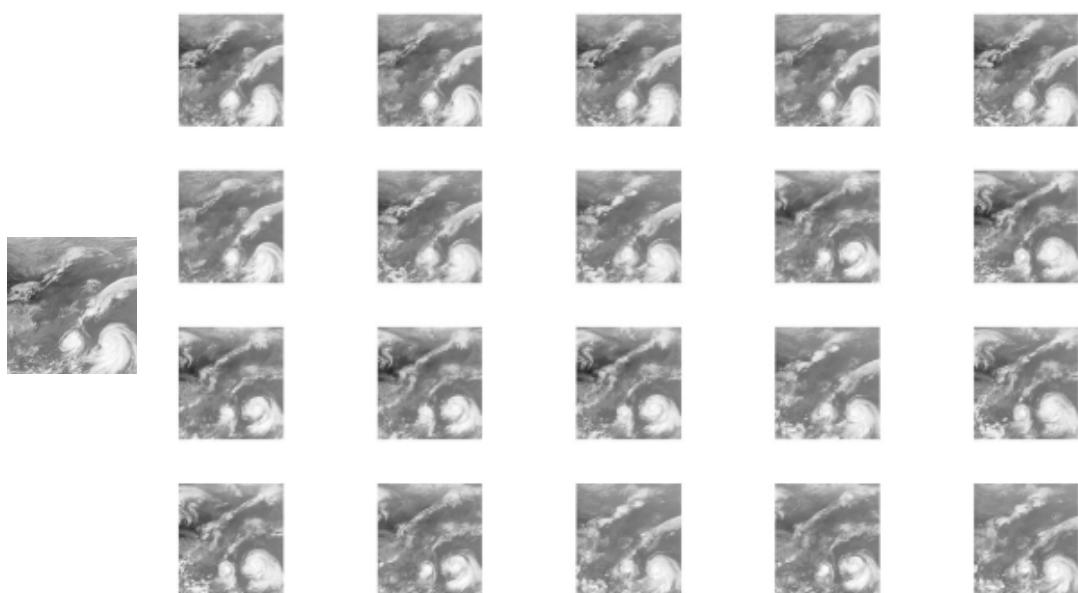


图 8 一次检索实验结果

Fig. 8 A retrieval of experimental results

表 3 六种降维方法的查准率对比

Table 3 Comparison of precision of six dimensionality reduction methods

Number of cloud image return	Proposed	PCA	SPCA	LDA	Laplacian	AutoEncoder
5	1.000	1.000	0.967	1.000	0.475	0.467
10	0.987	0.983	0.838	0.987	0.288	0.425
15	0.964	0.953	0.717	0.961	0.225	0.372
20	0.931	0.927	0.619	0.938	0.179	0.354
25	0.897	0.888	0.545	0.885	0.153	0.348
30	0.843	0.838	0.499	0.838	0.131	0.328
35	0.794	0.787	0.443	0.777	0.117	0.315
40	0.754	0.734	0.401	0.717	0.113	0.303
45	0.716	0.688	0.369	0.648	0.107	0.294

表 4 六种降维方法的查全率对比

Table 4 Comparison of recall of six dimensionality reduction methods

Number of cloud image return	Proposed	PCA	SPCA	LDA	Laplacian	AutoEncoder
5	0.100	0.100	0.097	0.100	0.048	0.047
10	0.198	0.197	0.168	0.198	0.058	0.085
15	0.289	0.286	0.215	0.288	0.068	0.112
20	0.373	0.371	0.248	0.375	0.072	0.142
25	0.448	0.444	0.273	0.443	0.077	0.174
30	0.506	0.503	0.299	0.503	0.078	0.197
35	0.556	0.551	0.310	0.544	0.082	0.221
40	0.603	0.588	0.321	0.573	0.090	0.243
45	0.644	0.619	0.332	0.583	0.097	0.265

Laplacian 以及 AutoEncoder 均不能保持较好的检索性能，即经该三种降维算法降维后，其降维后的特征并不能较好地保持原特征值的特征。反而是本文的方法，PCA 以及 LDA 算法能够保持稳定的检索性能，但是本文的算法仍然强于 PCA 和 LDA，特别是在返回 40 张相似云图的时候取得了 0.754 的查准率，其性能远远领先于其它五种降维方式。综上所述，本文的降维方法是可靠的。

图 9 中六条曲线为表 3、表 4 所示变化曲线，本文提出的降维算法在返回相同数量云图的情况下，均取得了较高的查准率和查全率，其 PCA 和 LDA 在云图检索上性能表现相当，而 SPCA 不能够较好地保持返回少量相似云图下的优势，而 AutoEncoder 和 Laplacian 在云图的降维性能上取得了较差的检索结果。总之本文的方法在性能上取得了最好的检索结果。

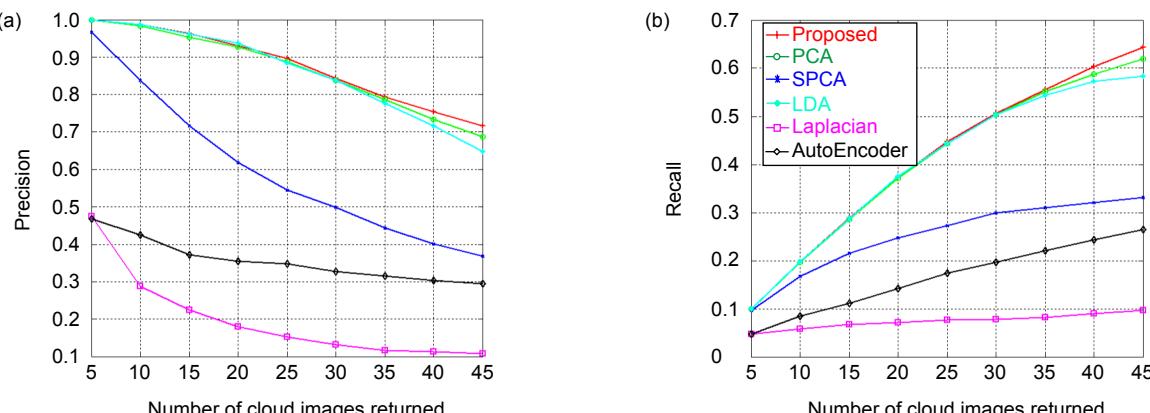


图 9 不同返回数目下的查准率(a)和查全率(b)变化曲线图

Fig. 9 Curves of precision (a) and recall (b) under different number of returns

表 5 7 种检索方法的特征维度大小
Table 5 Feature dimension size of seven retrieval methods

Retrieval methods	Propose	Methods 1	Methods 2	Methods 3	Methods 4	Methods 5	Methods 6
Size of feature	500	256	1475	8	1012036	1738	4096

表 6 7 种检索方法的查准率对比
Table 6 Comparisons of the precision of the seven retrieval methods

Number of cloud image return	Propose	Methods 1	Methods 2	Methods 3	Methods 4	Methods 5	Methods 6
5	1.000	0.958	1.000	0.408	1.000	1.000	1.000
10	0.987	0.896	0.996	0.337	1.000	0.983	0.992
15	0.964	0.817	0.964	0.294	0.981	0.953	0.944
20	0.931	0.750	0.931	0.265	0.944	0.927	0.890
25	0.897	0.685	0.883	0.242	0.917	0.888	0.827
30	0.843	0.636	0.824	0.222	0.890	0.843	0.775
35	0.794	0.586	0.775	0.213	0.864	0.794	0.731
40	0.754	0.546	0.733	0.203	0.833	0.754	0.693
45	0.716	0.510	0.689	0.193	0.803	0.716	0.660

表 7 七种检索方法的查全率对比
Table 7 Comparisons of the recall of the seven retrieval methods

Number of cloud image return	Propose	Methods 1	Methods 2	Methods 3	Methods 4	Methods 5	Methods 6
5	0.100	0.096	0.100	0.041	0.100	0.100	0.100
10	0.198	0.179	0.199	0.068	0.200	0.197	0.198
15	0.289	0.245	0.289	0.088	0.294	0.286	0.283
20	0.373	0.300	0.373	0.106	0.378	0.371	0.356
25	0.448	0.343	0.442	0.121	0.458	0.444	0.413
30	0.506	0.382	0.494	0.133	0.534	0.506	0.465
35	0.556	0.410	0.542	0.149	0.605	0.556	0.512
40	0.603	0.437	0.587	0.163	0.667	0.603	0.554
45	0.644	0.459	0.620	0.173	0.723	0.644	0.594

由表 6 和表 7 可知，相比较单一的 HIST 特征、ULBP 特征以及灰度共生矩阵特征，本文方法的检索性能确实要优于单一特征，即使本文的方法维度只有 500 远不及 ULBP 特征的 1475，但是综合特征降维后的小维度也强于单一特征的高维度。方法 6 是基于 AlexNet 卷积神经网络提取其全连接层的第 7 层特征，

其维度高达 4096，然而从检索的性能上看，其性能远不及人工设计的 ULBP 特征以及小波特征，究其原因可能是训练的样本过少，模型没有收敛，或者是云图的语义信息较为模糊，对神经网络来说都是一团云，很难捕捉到真正的语义信息，即使捕捉到语义信息在视觉上也不一定相似。对比其本文的方法和方法 5 就

可看出，本文提出的方法性能和方法 5 的性能几乎是保持一致的变化，由此可见本文的降维方法鲁棒性很好，而对比的小波的高维特征，不仅是本文方法的性能差于小波，其方法 5 的特征级联也不及小波，但是在返回 25 张云图的时候，其三个方法的性能可以说是发挥出比较一致的性能，即在时间跨度上在当天的云图的运动轨迹大致趋势都可以检索得到。总之，本文的方法可以保持降维后的特征性能，具有较强的鲁棒性。

图 10 为上面七个方法的变化曲线，基于灰度共生矩阵的方法在本文的数据库下，取得了较差的检索结果，由此基本可以断定，该方法不适合大规模的云图检索，在较为离散的时间下，该方法的鲁棒性差；单一特征的检索性能差于综合特征的检索性能，甚至是在一定特征维度范围内，单一的高维度特征不如综合特征降维后的小维度特征，在与深度特征比较中可知，

深度学习的优越性能需要大样本的支撑，在小规模的样本中，卷积神经网络很难较好地学习到其中的语义信息，即不能在小规模的云图检索中发挥出良好的性能。

5 结 论

本文提出一种结合稀疏表示和子空间投影的特征优化方法，在训练阶段对云图数据集分别提取颜色，纹理以及形状特征，对其综合特征进行稀疏表示并计算不同原子的方差来分组特征，最后根据分组特征的能量来计算投影矩阵，由计算得到的特征矩阵对原来的综合特征进行降维。由两组实验结果可知，本文的方法无论是降维性能上还是实际应用上，本文的方法都能够减少综合特征间的冗余，使得降维后特征的表现力更强，具有一定的应用前景。

参 考 文 献

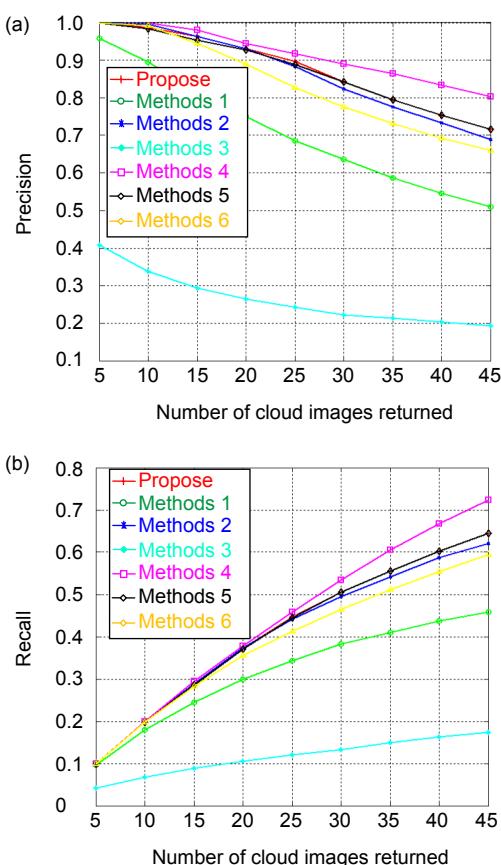


图 10 不同返回数目下的查准率(a)和查全率(b)曲线图

Fig. 10 Curves of precision (a) and recall (b) under different number of returns

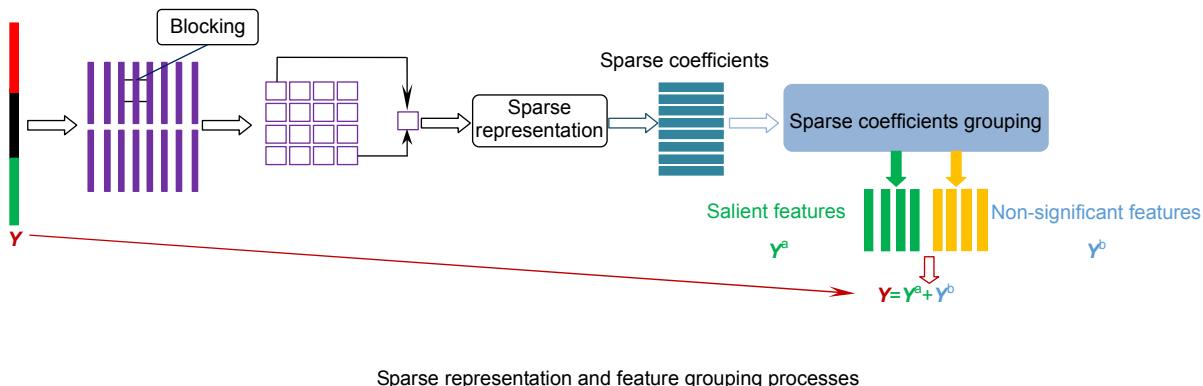
- [1] Gurve M K, Sarup J. Satellite cloud image processing and information retrieval system[C]//2012 World Congress on Information and Communication Technologies, 2012: 292–296.
- [2] Ou S S C, Kahn B H, Liou K N, et al. Retrieval of cirrus cloud properties from the atmospheric infrared sounder: the k-coefficient approach using cloud-cleared radiances as input[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **51**(2): 1010–1024.
- [3] Gan L, Zou K Z, Liu X. Pedestrian detection based on PCA dimension reduction of multi-feature cascade[J]. *Computer Science*, 2016, **43**(6): 308–311.
甘玲, 邹宽中, 刘肖. 基于PCA降维的多特征级联的行人检测[J]. 计算机科学, 2016, **43**(6): 308–311.
- [4] Wu X W, Tai X Y, Ba T E. Content based color gastroscopy image retrieval[J]. *Computer Applications*, 2005, **25**(S1): 248–250.
吴贤伟, 邱晓英, 巴特尔. 基于内容的彩色胃镜图像检索[J]. 计算机应用, 2005, **25**(S1): 248–250.
- [5] Hua S G, Zhou Y, Liu T. Thermal infrared face image recognition based on PCA and LDA[J]. *Pattern Recognition and Artificial Intelligence*, 2008, **21**(2): 160–164.
华顺刚, 周羽, 刘婷. 基于 PCA+LDA 的热红外成像人脸识别[J]. 模式识别与人工智能, 2008, **21**(2): 160–164.
- [6] Wang H, Song S Y. Image classification based on KCPA feature extraction and RVM[J]. *Journal of Jilin University (Science Edition)*, 2017, **55**(2): 357–362.
王慧, 宋淑蕴. 基于 KCPA 提取特征和 RVM 的图像分类[J]. 吉林大学学报(理学版), 2017, **55**(2): 357–362.
- [7] Zhao H W, Xie Y F, Cao B F, et al. Extraction and application of froth texture feature based on Gabor wavelets and LPP in flotation process[J]. *Journal of Shanghai Jiaotong University*, 2014, **48**(7): 942–947.
赵洪伟, 谢永芳, 曹斌芳, 等. 基于 Gabor 小波和 LPP 的浮选过程泡沫纹理特征提取及应用[J]. 上海交通大学学报, 2014, **48**(7): 942–947.
- [8] Wang B F, Liu J, Wang G H, et al. Research on underwater image dimensionality reduction based on Laplacian Eigen-

- map[J]. *Modern Electronics Technique*, 2013, **36**(2): 29–31.
王宝锋, 刘俊, 王国宇, 等. 基于拉普拉斯特征映射法的水下图像降维研究[J]. 现代电子技术, 2013, **36**(2): 29–31.
- [9] Yan W. Study on content-based cloud image retrieval technology[D]. Ningbo: Ningbo University, 2017.
颜文. 基于内容的云图检索技术研究[D]. 宁波: 宁波大学, 2017.
- [10] Li X X. Research on the technology of content-based satellite cloud image retrieval[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2013.
李秀馨. 基于内容的卫星云图检索技术研究[D]. 南京: 南京航空航天大学, 2013.
- [11] Shangguan W. Research of content-based satellite cloud image processing and information retrieval technology[D]. Harbin: Harbin Engineering University, 2008.
上官伟. 基于内容的卫星云图处理与信息检索技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2008.
- [12] Liu Y C. Application of satellite cloud image in weather analysis and forecast[J]. *Agriculture & Technology*, 2016, **36**(22): 207.
刘英春. 卫星云图在天气分析及预报中的应用[J]. 农业与技术, 2016, **36**(22): 207.
- [13] Song X Y, Bai F Z, Wu J X, et al. Wood knot defects recognition with gray-scale histogram features[J]. *Laser & Optoelectronics Progress*, 2015, **52**(3): 031501.
宋小燕, 白福忠, 武建新, 等. 应用灰度直方图特征识别木材表面节子缺陷[J]. 激光与光电子学进展, 2015, **52**(3): 031501.
- [14] Wu H P, Dai S K. Face recognition of 2DLDA based on ULBP eigensubspace[J]. *Pattern Recognition and Artificial Intelligence*, 2014, **27**(10): 894–899.
吴煌鹏, 戴声奎. 基于ULBP特征子空间的2DLDA人脸识别方法[J]. 模式识别与人工智能, 2014, **27**(10): 894–899.
- [15] Tian W Z, Fu R D, Jin W, et al. Adaptive fuzzy support vector machine for classification of clouds in satellite imagery[J]. *Geomatics and Information Science of Wuhan University*, 2017, **42**(4): 488–495.
田文哲, 符冉迪, 金炜, 等. 面向卫星云图云分类的自适应模糊支持向量机[J]. 武汉大学学报·信息科学版, 2017, **42**(4): 488–495.
- [16] Gao S B, Cheng Y M, Xiao L P, et al. Recent advances of sparse representation for object detection[J]. *Acta Electronica Sinica*, 2015, **43**(2): 320–332.
高仕博, 程咏梅, 肖利平, 等. 面向目标检测的稀疏表示方法研究进展[J]. 电子学报, 2015, **43**(2): 320–332.
- [17] Zhou Y, Fu R D, Yan W, et al. A method of infrared nephogram super-resolution based on structural group sparse representation[J]. *Opto-Electronic Engineering*, 2016, **43**(12): 126–132.
周颖, 符冉迪, 颜文, 等. 基于结构组稀疏表示的红外云图超分辨率方法[J]. 光电工程, 2016, **43**(12): 126–132.
- [18] Xia S M, Li Q, Zhang J, et al. Satellite cloud image retrieval based on gray level co-occurrence matrix[J]. *Modern Computer*, 2013(25): 34–38.
夏士明, 李骞, 张璟, 等. 一种基于灰度共生矩阵的云图检索方法[J]. 现代计算机, 2013(25): 34–38.
- [19] Li Y B, Li Y X, Sun L X, et al. Satellite cloud image retrieval based on wavelet texture[C]//*Proceedings of the 12th National Conference on Image and Graphics*, 2005: 5.
李艳兵, 李元祥, 孙龙祥, 等. 基于小波纹理特征的卫星云图检索[C]//第十二届全国图象图形学学术会议论文集, 2005: 5.
- [20] Ji N, Zuo D, Cao Y, et al. Image classification with deep dictionary and sparse representation[J]. *Wireless Communication Technology*, 2017, **26**(4): 56–60.
纪念, 左登, 曹燕, 等. 基于深度字典和稀疏表示的图像分类[J]. 无线通信技术, 2017, **26**(4): 56–60.

The cloud retrieval of combining sparse representation with subspace projection

Tang Biao, Jin Wei*, Li Gang, Yin Caoqian

Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo, Zhejiang 315211, China



Overview: The satellite cloud image can show the characteristics of the cloud system and its evolution process from multiple angles. The research of cloud image retrieval is of great significance for weather monitoring and climate research. In the design and implementation of cloud image retrieval system, feature extraction is the key link. Since different types of cloud image features have their own advantages when portraying cloud images, combining different types of features will help improve the performance of cloud image retrieval system. However, since the combined cloud image features tend to be too high in dimension, the time cost is often high in the similarity measurement phase, and there is redundancy between the feature vectors. In view of the above problems, this paper combines sparse representation and subspace projection technology to propose a dimension reduction method for cloud image combination features. Firstly, the content information of the cloud image is drawn from different angles, that is, the three features of the cloud image color, texture and shape are extracted. After that, the three features are normalized and cascaded into a combined feature vector, and then the combined feature vector is matrixed. The form is arranged, and the matrix is subsequently subjected to block processing. Then, each block is sparsely represented, the variance of each feature block sparse representation coefficient is calculated, and the feature blocks are grouped according to the variance obtained by different blocks and grouped by grouping. It is then possible to separate the initial combined features into salient features and non-significant features. At this point, a subspace will be searched, in which the significant part is preserved, and the non-significant part will be suppressed. A projection matrix can be obtained by learning training to achieve the combined feature dimension reduction. In the retrieval stage, the initial cloud image combination feature vector is projected on the projection matrix, and the dimensionality reduction cloud image feature can be obtained, so that the cloud image retrieval can be realized quickly and accurately. The experimental results show that the cloud image retrieval system achieved by this method is superior to the traditional dimensionality reduction method in the accuracy and recall rate of the cloud image retrieval system, and the time complexity of the retrieval process is low. This indicates that the proposed method has strong dimensionality reduction ability for cloud image combination features, and provides a new idea for cloud image feature dimension reduction and efficient cloud image retrieval system.

Citation: Tang B, Jin W, Li G, et al. The cloud retrieval of combining sparse representation with subspace projection[J]. *Opto-Electronic Engineering*, 2019, **46**(10): 180627

Supported by National Natural Science Foundation of China (61471212) and the Natural Science Foundation of Zhejiang Province of China (LY16F010001)

* E-mail: xyjw1969@126.com