

# 可变类谱聚类遥感影像分割

李 玉, 袁永华, 赵雪梅

(辽宁工程技术大学测绘与地理科学学院遥感科学与应用研究院, 辽宁阜新 123000)

**摘 要:** 为实现遥感影像分割中类别数的准确、自动判别, 提出了一种可变类谱聚类算法. 根据影像的相似图构建权值矩阵和标准 Laplacians 矩阵, 计算 Laplacians 矩阵较小特征值对应的特征向量生成特征向量矩阵, 并视其与像素对应的向量行为像素特征点集; 研究 Laplacians 矩阵处于不同(近似)块对角结构时类属同一目标类像素特征点的聚集性, 定义聚类度指标, 计算不同分割类别数对应聚类度; 选择聚类度将发生最后一次较大跳变时的分割类别数作为算法估计类别数, 并采用 FCM(Fuzzy C-Means)算法划分该类别数对应像素特征点集实现影像分割. 分别采用提出算法和基于特征间隙的算法分割合成及真实遥感影像. 实验结果表明提出算法可准确地判别影像类别数.

**关键词:** 遥感影像; 可变类分割; 相似图; 谱聚类

**中图分类号:** TP181

**文献标识码:** A

**文章编号:** 0372-2112 (2018)12-3021-08

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2018.12.028

## Spectral Clustering of Variable Class for Remote Sensing Image Segmentation

LI Yu, YUAN Yong-hua, ZHAO Xue-mei

(Institute for Remote Sensing Science and Application, School of Geomatics, Liaoning Technical University, Fuxin, Liaoning 123000, China)

**Abstract:** This paper presents a spectral clustering algorithm based image segmentation to correctly and automatically determine the number of classes. Firstly, the weighted matrix and the normalized Laplacians matrix are established with the similarity graph corresponding to a given image. Then, the eigenvectors corresponding to the smaller eigenvalues of the normalized Laplacians matrix are calculated to generate eigenvectors matrix and the pixel feature points set is constructed by means of treating each line of the eigenvectors as a different data point. Secondly, when the Laplacians matrix is in different approximate block diagonal structure, the proposed algorithm exploits the clustering property of the pixel feature points belonging to the same class and calculates the corresponding clustering degree of the different number of segmentation classes by defining the index of clustering degree. Finally, when the clustering degree is the last one to have a greater degree of jumping, the number of the segmentation classes is selected as the number of classes in this paper. The FCM algorithm is used to partition the pixel feature points set corresponding to the number of classes selected to realize the image segmentation. Synthesized and real remote sensing images are used for testing the proposed algorithm. The results show that the proposed algorithm can identify the number of classes in an image correctly.

**Key words:** remote sensing image; Segmentation with unknown number classes; Spectral clustering; Similarity graph

### 1 引言

聚类方法在模式识别和机器学习中有广泛的应用. 作为一种非监督数据解译方法, 该类算法可将相似度较大的数据点划分为同一集群, 进而区分具有不同特征的数据点. 现有聚类方法主要包含以下几类: 基于层次<sup>[1]</sup>、模型<sup>[2-4]</sup>和划分<sup>[5,6]</sup>的聚类等. 其中应用最为广

泛的是 K-means 算法和基于概率混合模型方法. 但对数据模型未知的数据集, 尤其是数据点为非凸分布的数据集, 前述方法的聚类效果均不理想<sup>[7]</sup>. 甚至当各数据点维度不同时, 上述算法无法实现数据聚类<sup>[8]</sup>. 而谱聚类算法无须建立数据模型, 且可将不同维度数据降维至相同维度空间<sup>[9]</sup>.

以图划分为基础的谱聚类算法已被成功用于数据

聚类<sup>[10-12]</sup>. Fiedler<sup>[13]</sup>利用 Laplacians 矩阵中与次最小特征值对应的特征向量聚类数据. 由于仅仅使用单一特征向量,该方法只适用于具有两个数据类的聚类问题. Ng 等<sup>[14]</sup>提出使用 Laplacians 矩阵前  $K$  个最小特征值对应的特征向量构建新数据集,并用 K-means 算法划分新数据集,以实现数据聚类. 然而,上述方法均须预先给定聚类类别数,即只能处理固定类数的谱聚类分割,如何实现类别数的自动确定仍然是谱聚类算法普遍存在的问题. 为了自动确定分割类别数,提出诸如基于信息理论标准<sup>[15]</sup>、基于稳定性<sup>[16,17]</sup>等的谱聚类方法. 其中,确定类别数最为传统的方法是基于特征间隙的谱聚类算法<sup>[18,19]</sup>. 该算法首先按增序排列 Laplacians 矩阵的特征值,其次计算相邻特征值之差作为特征间隙,最后取第一个局部极大特征间隙的位置为聚类类别数. 但该方法用于影像分割时只能用特征值本身确定影像类别数,缺乏有效的理论支撑<sup>[18]</sup>,并且,当异质区域间像素连接权重大时,特征值不存在明显跳变,该算法无法得到正确类别数. 为此,提出一种新的可自动确定类别数的谱聚类分割算法. 提出算法据 Laplacians 矩阵较小特征值对应的特征向量构造不同维度像素特征点集,定义聚类度指标以衡量相应像素特征点集的聚类性,计算不同分割类别数对应的聚类度,最终依据聚类度的明显跳变估计类别数.

## 2 算法描述

### 2.1 建模相似图

给定影像  $Z = \{z_i(x_i, y_i); (x_i, y_i) \in C, i = 1, 2, \dots, n\}$ , 其中,  $C$  为影像域,  $i$  为像素索引,  $n$  为总像素数,  $(x_i, y_i)$  为像素  $i$  的位置坐标,  $z_i$  为像素  $i$  的光谱测度(即灰度值). 给定像素间连接规则,可用加权无向图  $G = (V, E, W)$  表示与影像对应的图模型(称为相似图),其中,  $V = \{v_i; i = 1, 2, \dots, n\}$  为图中顶点集合,  $v_i$  为与像素  $i$  对应的顶点,  $n$  为顶点数(像素数);  $E = [E_{i' i'} \in \{0, 1\}]_{n \times n}$  为连接矩阵,  $E_{i' i'}$ ,  $i, i' = 1, 2, \dots, n$ , 表征顶点  $v_i$  和  $v_{i'}$  的连接关系,  $E_{i' i'} = 1$  表示顶点  $v_i$  和  $v_{i'}$  相连,  $E_{i' i'} = 0$  表示两顶点不相连,无向图中  $E_{i' i'} = E_{i i'}$ ,  $E_{i' i'}$  和  $E_{i i'}$  对应  $G$  中同一条边;  $W = [w_{i' i'}]_{n \times n}$  为权值矩阵,  $w_{i' i'}$  为  $E_{i' i'}$  对应边的连接权重. 采用谱聚类算法分割相似图  $G$ ,可依照标准化划分(Normalized Cut)准则<sup>[20]</sup>将图中顶点集划分成  $K$  个子集  $V = \{F_1, F_2, \dots, F_K\}$ , 满足  $F_j \cap F_{j'} = \emptyset, \forall j, j' \in \{1, 2, \dots, K\}, j \neq j', F_1 \cup \dots \cup F_K = V$ , 其中,  $j, j'$  为子集索引. 从影像分割的角度看,顶点的划分对应影像分割.

#### 2.1.1 连接关系

为了能在影像分割中刻画像素的空间相关性,可用连接边表达像素空间位置关系. 为简单起见,仅考虑邻域像素的连接关系,

$$E_{i' i'} = \begin{cases} 1, & i' \in N_i \\ 0, & i' \notin N_i \end{cases} \quad (1)$$

其中,  $N_i$  为像素  $i$  的邻域像素集合,定义为以  $i$  为中心  $r \times r$  窗口内的像素,  $r$  为指定的窗口尺度. 邻域像素连接关系表达像素的局部连接关系,且使得连接矩阵  $E$  为稀疏矩阵<sup>[21]</sup>.

#### 2.1.2 权值矩阵

权值矩阵  $W$  中连接权重  $w_{i' i'}$  表示像素间空间和光谱测度的相关性,  $w_{i' i'} \neq 0$  表明像素  $i$  与  $i'$  间存在某种程度的相似关系,反之,两者无关. 设  $w_{i' i'} = E_{i' i'} \times s_{i' i'}$ , 当像素  $i$  与  $i'$  不连接 ( $E_{i' i'} = 0$ ) 时,连接权重  $w_{i' i'} = 0$ , 当像素  $i$  与  $i'$  相连 ( $E_{i' i'} = 1$ ) 时,连接权重  $w_{i' i'} = s_{i' i'}$ , 其中,  $s_{i' i'}$  为像素  $i$  与  $i'$  间光谱测度的相似度,满足对称性  $s_{i' i'} = s_{i i'}$ , 并定义为,

$$s_{i' i'} = \exp\left(-\frac{\|z_i - z_{i'}\|^2}{2}\left(\frac{1}{\sigma_i^2} + \frac{1}{\sigma_{i'}^2}\right)\right) \quad (2)$$

其中,  $z_i$  和  $z_{i'}$  分别为像素  $i$  和  $i'$  的光谱测度;  $\|z_i - z_{i'}\|$  用以计算  $z_i$  与  $z_{i'}$  间的欧氏距离;  $\sigma_i$  为像素  $i$  的尺度参数. 令  $\Delta z_i = \{\|z_i - z_{i'}\|, i' \in N_i\}$  且  $\|z_i - z_{i'}\|$  按增序排列,取  $\sigma_i = \Delta z_i(\lfloor \#N_i / M \rfloor)$ ,  $\lfloor \cdot \rfloor$  为取整操作符,  $\#$  为计算集合所含元素总数操作符,  $M \in [2, 6]$  为指定整数<sup>[22]</sup>, 控制  $\sigma_i$  的取值,可根据待分割影像选取不同的  $M$  值.

由上述定义可知,权值矩阵既表达像素的局部连接关系,同时刻画像素间光谱测度的相似度.

### 2.2 图划分

给定影像  $Z$ , 其对应的相似图为  $G = (V, E, W)$ . 假设  $Z$  被分割为  $k$  类. 按像素类属对权值矩阵  $W$  进行行列变换,使其变为由类属索引的块矩阵,可表示为  $W_k = [W_{j' j}]_{k \times k}$ , 其中,  $W_{j' j}$ ,  $j, j' = 1, 2, \dots, k$ , 为块矩阵;  $W_k$  中对角块矩阵  $W_{j' j}$  ( $j = j'$ ) 为类别  $j$  对应区域像素的权值矩阵;非对角块矩阵  $W_{j' j}$  ( $j \neq j'$ ) 为类别  $j$  与  $j'$  对应区域间的权值矩阵,其元素表示分属两区域像素间的连接权重,在理想分割状态下<sup>[23]</sup>,异质区域像素间权重值为零,即当  $j \neq j'$  时,  $W_{j' j} = 0$ . 对应  $W_k$  的标准 Laplacians 矩阵  $L_k$  可计算为  $L_k = I_k - D_k^{-1} W_k$ , 其中,  $I_k$  为  $n$  维单位阵;度矩阵  $D_k = \text{diag}(d_i, i = 1, 2, \dots, n)$  为  $n$  维对角阵,  $d_i = \sum_{i'=1}^n w_{i' i}$ .  $L_k$  可进一步分解为  $L_k = L'_k + H_k$ , 其中,

$$L'_k = \begin{pmatrix} L_{k1} & & & & \\ & \ddots & & & \\ & & L_{kj} & & \\ & & & \ddots & \\ & & & & L_{kk} \end{pmatrix} \quad (3)$$

为据  $\mathbf{W}_k$  中对角阵  $\mathbf{W}_{jj}$  计算得到的块对角阵,称为理想分割状态的 Laplacians 矩阵,  $\mathbf{L}_{kj} = \mathbf{I}_j - \mathbf{D}_j^{-1} \mathbf{W}_{jj}$  为  $\mathbf{W}_{jj}$  的 Laplacians 矩阵,  $\mathbf{I}_j$  为  $n_j$  阶单位阵,  $n_j$  为类别  $j$  对应区域内像素数,  $\mathbf{D}_j = \text{diag}(d_i, i = 1, 2, \dots, n_j)$  且  $d_i = \sum_{(v_i, v_j) \in F_j} w_{ij}$ ;  $\mathbf{H}_k$  为  $\mathbf{W}_k$  中非对角块  $\mathbf{W}_{jj}$  影响产生的扰动项<sup>[18]</sup>.

$\mathbf{L}_k$  的  $k$  个最小特征值对应的  $k$  个特征向量依特征值的增序按列排成的矩阵  $\mathbf{U}_k \in \mathbb{R}^{n \times k}$  可表示如下,

$$\mathbf{U}_k = (\mathbf{u}_{\cdot 1}, \dots, \mathbf{u}_{\cdot j}, \dots, \mathbf{u}_{\cdot k})$$

$$= \begin{pmatrix} r_{11}\mathbf{x}_1 + \boldsymbol{\alpha}_{11} & \dots & r_{1j}\mathbf{x}_1 + \boldsymbol{\alpha}_{1j} & \dots & r_{1k}\mathbf{x}_1 + \boldsymbol{\alpha}_{1k} \\ \vdots & & \vdots & & \vdots \\ r_{j1}\mathbf{x}_{j'} + \boldsymbol{\alpha}_{j1} & \dots & r_{jj}\mathbf{x}_{j'} + \boldsymbol{\alpha}_{jj} & \dots & \vdots \\ \vdots & & \vdots & & \vdots \\ r_{k1}\mathbf{x}_k + \boldsymbol{\alpha}_{k1} & \dots & \dots & \dots & r_{kk}\mathbf{x}_k + \boldsymbol{\alpha}_{kk} \end{pmatrix} \quad (4)$$

其中,  $r_{jj}, j, j' = 1, 2, \dots, k$ , 为实数;  $\mathbf{x}_{j'} = a_j \mathbf{e}_{j'}$  为与类别  $j'$  对应的常数向量,  $a_j$  为非零常数,  $\mathbf{e}_{j'}$  为  $n_j$  维全 1 向量; 特征向量  $\mathbf{u}_{\cdot j} = ((r_{1j}\mathbf{x}_1 + \boldsymbol{\alpha}_{1j})^T, \dots, (r_{jj}\mathbf{x}_{j'} + \boldsymbol{\alpha}_{jj})^T, \dots, (r_{kj}\mathbf{x}_k + \boldsymbol{\alpha}_{kj})^T)$ ;  $\boldsymbol{\alpha}_{ij} = (\boldsymbol{\alpha}_{ij}^T, i = 1, 2, \dots, n_j)^T$ , 为受  $\mathbf{H}_k$  影响产生的扰动项<sup>[24]</sup>.  $\mathbf{U}_k$  中全部行向量  $\{\mathbf{u}_{\cdot 1}, \dots, \mathbf{u}_{\cdot j}, \dots, \mathbf{u}_{\cdot k}\}$  对应  $k$  维空间中的  $n$  个点, 由于其中每个点均与像素一一对应, 因此称为像素特征点. 在不至混淆的情况下, 使用  $\mathbf{U}_k$  作为特征向量矩阵和像素特征点集.

分割类属数  $k$  等于影像固有类属数  $K$ , 由于具有不同类属性的邻域像素仍存在连接关系, 则  $\mathbf{W}_{jj} \neq \mathbf{0}, \mathbf{H}_k \neq \mathbf{0}$ ; 但当  $k = K$  时, 不同类别像素间相似度较小,  $\mathbf{W}_{jj}$  中元素取值小, 则  $\mathbf{H}_k$  中各元素取值极小<sup>[18]</sup>. 当扰动项较小时,  $\mathbf{L}_k$  为近似块对角阵, 其对角块矩阵个数即为类别数  $k$ <sup>[24]</sup>. 而对于由  $\mathbf{L}_k$  诱导的特征矩阵  $\mathbf{U}_k$ , 由于  $\boldsymbol{\alpha}_{ij}$  取值很小, 则  $r_{jj}\mathbf{x}_{j'} + \boldsymbol{\alpha}_{jj}$  近似为常数向量,  $\mathbf{u}_{\cdot j}$  近似为分段常量, 进而类属同一目标类的像素特征点相互接近, 表现极强的聚集性.

当取  $k < K$  时,  $\mathbf{U}_k$  各列应分别对应  $\mathbf{U}_K$  中前  $k$  列近似分段常量. 更可能的图划分是将若干真实聚类合并为单一聚类, 但仍满足  $\mathbf{W}_{jj}$  和  $\mathbf{H}_k$  中元素取值小,  $\mathbf{L}_k$  可视为包含  $k$  个对角块的近似块对角阵. 尽管像素特征点的维度减少(从  $K$  维降低到  $k$  维), 但类属同一目标类的像素特征点仍表现聚集性.

当取  $k > K$  时, 对应的图划分将使某些真实聚类划归为不同类属, 使得  $\mathbf{W}_{jj}$  中各元素取值增大,  $\mathbf{L}_k$  的块对角性减弱, 相应的  $\mathbf{U}_k$  后  $(k - K)$  列不为近似分段常量. 由此导致类属同一目标类的像素特征点呈现弱聚集性.

由上述分析可知, 类属同一目标类的像素特征点相互接近, 表现出一定程度的聚集性, 因此可用于实现后续的分割任务.

### 2.3 类别数估计

给定分割类别数  $k$ , 像素特征点集  $\mathbf{U}_k = \{\mathbf{u}_{\cdot 1}, \dots, \mathbf{u}_{\cdot i}, \dots, \mathbf{u}_{\cdot n}\}$ , 将  $\mathbf{U}_k$  划分为  $k$  个集群  $F_k = \{F_{k1}, \dots, F_{kj}, \dots, F_{kk}\}$ . 将像素特征点由  $k$  维降维到  $m \in \{2, 3, \dots, k-1\}$  维, 依据维度组合共有  $C_k^m$  种降维方式, 记为  $\mathbf{U}_{k \rightarrow m} = \{\mathbf{U}_{k \rightarrow m, q}, q = 1, 2, \dots, C_k^m\}$ , 其中,  $\mathbf{U}_{k \rightarrow m, q}$  为  $m$  维像素特征点集,  $q$  为降维方式索引. 对  $\mathbf{U}_{k \rightarrow m}$  中每种降维像素特征点集均划分为  $m$  个集群, 结果记为  $F_{k \rightarrow m} = \{F_{k \rightarrow m, q}, q = 1, 2, \dots, C_k^m\}$ , 其中,  $F_{k \rightarrow m, q} = \{F_{k \rightarrow m, q, j'}, j' = 1, 2, \dots, m\}$  为  $\mathbf{U}_{k \rightarrow m, q}$  的分割结果. 为了判别正确类别数, 定义聚类度指标  $t_k$ ,

$$t_k = \min_{m \in \{2, 3, \dots, k-1\}} \{t_{k \rightarrow m}\} \quad (5)$$

其中,

$$t_{k \rightarrow m} = \min_{q=1, 2, \dots, C_k^m} \left\{ \min_{j=1, 2, \dots, k} \left( \frac{\max_{j'=1, 2, \dots, m} (\#(F_{kj} \cap F_{k \rightarrow m, q, j'}))}{n_{kj}} \right) \right\} \quad (6)$$

其中,  $n_{kj} = \#F_{kj}$ .

当  $k = K$  时, 由于类属同一目标类的像素特征点聚集性极强, 则  $F_k$  中各集群分别对应真实聚类. 取  $m < k$ , 降维后类属不同目标类的像素特征点间差异性减弱, 若干真实聚类合并为单一聚类, 则各真实聚类  $F_{kj}$  应(近似)完全包含于某一集群  $F_{k \rightarrow m, q, j'}$ , 即满足  $\#(F_{kj} \cap F_{k \rightarrow m, q, j'}) \approx n_{kj}$ , 使得  $t_k$  取值较大; 当  $k > K$  时, 同一目标类像素特征点聚集性较弱, 某些真实聚类划归为不同类属. 取  $m < k$ , 特别地, 当矩阵  $\mathbf{U}_{k \rightarrow m, q}$  包含非近似分段常量时, 同一目标类像素特征点聚集性更弱, 真实聚类被划分开, 存在  $\#(F_{kj} \cap F_{k \rightarrow m, q, j'})$  取值很小的情况, 使得  $t_k$  极小; 当  $k < K$  时, 取  $m < k$ , 显然,  $F_k$  和  $F_{k \rightarrow m, q}$  均对应  $\mathbf{U}_k$  降维后的分割结果, 各真实聚类满足(近似)完全包含于某一集群  $F_{kj}$  或  $F_{k \rightarrow m, q, j'}$ , 然而, 两分割结果间不一定满足  $\#(F_{kj} \cap F_{k \rightarrow m, q, j'}) \approx n_j$ , 则  $t_k$  或为较大值, 或取较小值. 上述可知,  $t_{K+1}$  远小于  $t_K$ , 且  $k > K$  后  $t_k$  值均取值很小, 可以说,  $t_k$  在  $K$  和  $K+1$  间发生较大跳变, 据此, 可通过设置合适的阈值  $\zeta$ , 并选择满足  $t_k > \zeta$  的  $t_k$  值对应的最大  $k$  值作为算法估计的类别数  $K$ , 即,

$$K = \max \{ \arg \{ t_k > \zeta, k = 2, 3, \dots, K_{\max} \} \} \quad (7)$$

其中,  $\zeta$  为给定的阈值,  $K_{\max}$  为最大可能的类别数.

### 2.4 影像分割

依据上述理论, 可实现类别数的自动判别, 确定  $K$  后, 结合 FCM 算法可实现像素类别的归属完成影像分割. 具体的操作流程总结如下:

Step1: 设置常数  $K_{\max}$  及阈值  $\zeta$  的取值;

Step2: 据待分割影像  $Z$  建立相似图  $G = (V, E, W)$ , 并计算标准 Laplacians 矩阵  $\mathbf{L} = \mathbf{I} - \mathbf{D}^{-1} \mathbf{W}$ ;

Step3: 顺次取  $k = 2, 3, \dots, K_{\max}$ , 对每个  $k$  依次执行

Step4 ~ Step10;

Step4: 计算  $L$  的  $k$  个最小特征值对应的  $k$  个特征向量, 并令向量依特征值的增序按列排成矩阵  $U_k$ , 视  $U_k$  各行分别对应不同像素构成像素特征点集  $U_k = \{u_{1.}, \dots, u_{i.}, \dots, u_{n.}\}$ ;

Step5: 采用 FCM 算法划分点集  $U_k$  为  $k$  类集群  $F_k = \{F_{k1}, \dots, F_{kj}, \dots, F_{kk}\}$ ;

Step6: 依次取  $m = 2, 3, \dots, (k-1)$ , 对  $m$  的不同取值重复执行 Step7 ~ Step9;

Step7: 计算  $C_k^m$ , 遍历矩阵  $U_k$  中不同的  $m$  个列向量按列排成矩阵并构造像素特征点集  $U_{k \rightarrow m} = \{U_{k \rightarrow m, q}, q = 1, 2, \dots, C_k^m\}$ , 对该集合中各特征点集分别执行 Step8;

Step8: FCM 划分  $U_{k \rightarrow m, q}$  为  $m$  个集群  $F_{k \rightarrow m, q} = \{F_{k \rightarrow m, q, j'}, j' = 1, 2, \dots, m\}$ ;

Step9: 利用 Step8 结果  $F_{k \rightarrow m} = \{F_{k \rightarrow m, q}, q = 1, 2, \dots, C_k^m\}$ , 据式(6)计算  $t_{k \rightarrow m}$ ;

Step10: 分别计算  $m$  取不同值时相应的  $t_{k \rightarrow m}$ , 并由式(5)计算  $t_k$ ;

Step11: 执行 Step4 ~ Step10 后, 据式(7)确定  $K$  值并将  $t_k$  对应的像素特征点集表示为  $U_K$ ;

Step12: 采用 FCM 算法划分特征点集  $U_K$  为  $K$  类集群完成影像分割;

### 3 实验与讨论

#### 3.1 合成影像分割

根据模板影像图 1(a)、(c) 生成尺寸均为  $128 \times 128$  像素的合成影像, 如图 1(b)、(d) 所示. 合成影像包含同质区域个数  $K$  分别为 4、5. 图 1(b) 中区域 I、II、III、IV 分别对应灌木、森林、稀疏草地及河岸, 各地物均为 Worldview-2 的 0.5m 分辨率全色影像. 其中, 区域 I、II 和 III 灰度特征较为接近, 计算相似度时, 导致不同区域间像素相似度较大. 图 1(d) 中区域 I 和 III 分别对应森林和裸地, 区域 II、IV、V 为不同类型植被用地, 各地物均为 Ikonos 的 1m 分辨率全色影像. 其中, 区域 I 和区域 V 灰度特征较为接近, 区域 II 和区域 IV 灰度特征接近. 因此, 区域 I 和 V 及区域 II 和 IV 间像素相似程度远高于与其它区域像素间的相似程度.

采用基于特征间隙的谱聚类算法<sup>[19]</sup> 为对比算法估计类别数, 增序排列 Laplacians 矩阵的特征值, 并对排列后特征值顺次编号. 当 Laplacians 矩阵的扰动项取值为零或极小时, 编号为固有类别数的特征值将发生第一次局部极大跳变<sup>[18]</sup>, 因此, 对比算法可通过选取第一个局部极大特征间隙的索引位置确定类别数  $K$ . 然而, 由于合成影像中存在不同地物像素间相似度较大的情况, 使得不同地物像素间连接权重较大, 进而导致 Laplacians 矩阵扰动项增大. 较大的扰动项使得增序排列的

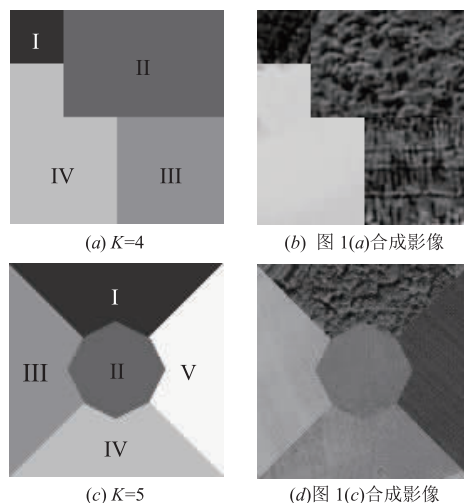


图1 模板影像及其对应的合成影像

特征值没有明显跳变<sup>[18]</sup>, 因此, 对比算法无法准确确定类别数. 图 2(a)、(c) 分别为该算法分割各合成影像的类别数折线图, 表征特征值随特征值序号的变化, 其横坐标为特征值增序排列后的序号, 用  $k$  索引, 纵坐标为第  $k$  个特征值, 红色三角对应的横坐标为该算法估计的类别数. 图 2(a)、(c) 表明, 对比算法估计各影像类别数分别为 2 类和 3 类, 其值与合成影像时截取地物类别不符, 类别数估计错误. 而采用本文算法估计类别数, 当分割类别数  $k$  遍历其可能取值时, 分别构建具有类别数  $k$  个块结构的对角块 Laplacians 矩阵, 各地物 (异质区域) 分别对应 Laplacians 矩阵对角位置的块矩阵, 并计算不同  $k$  对应的聚类度  $t_k$ . 由于  $k$  取固有类别数时,  $t_k$  将发生最后一次较大跳变, 因此, 本文算法通过选择即将发生最后一次跳变的  $t_k$  对应的  $k$  作为估计类别数, 可得到正确的类别数 (即固有类别数). 图 2(b)、(d) 分别为本文算法分割各合成影像的类别数折线图, 表征聚类度随分割类别数的变化, 其横坐标为分割类别数  $k$ , 纵坐标为聚类度  $t_k$ , 红色虚线为  $\zeta$  的位置, 大于  $\zeta$  的  $t_k$  值对应的最大  $k$  值 (红色三角对应的横坐标) 为估计的类别数. 且图 2(b)、(d) 显示, 本文算法估计类别数分别为 4 类和 5 类, 等于合成影像时裁剪的目标个数.

对比算法在类别数估计错误的情况下分割各合成影像, 其分割结果图 3(a)、(c) 显示, 图 1(b) 的区域 I、II 和 III 被划分为一类, 图 1(d) 的区域 I 和 V 及区域 II 和 IV 均被归为相同类别. 本文算法依据估计的类别数分割各合成影像, 分割结果见图 3(b)、(d), 各区域对应地物均被准确划分开来. 由于对比算法类别数估计错误, 其分割结果无法与模板图像对比计算混淆矩阵, 因此表 1 仅列出了本文算法分割结果的各项精度指标, 即用户精度、产品精度、总精度及 Kappa 值. 不难看出, 两合成影像各区域用户精度和产品精度均达到 90% 以




图2 对比算法和本文算法分割图1(b)、(d)的类别数折线图

上,总精度均大于 97%, Kappa 值亦不小于 0.96. 综上所述,本文算法不但可准确地估计类别数,还能有效划分异质区域.

实验过程中,为建模影像相似图,本文算法需预先指定构建邻域像素连接关系的窗口尺度  $r$  及辅助计算尺度参数的邻域窗口尺度. 为了更加完善的刻画像素与其它像素的连接关系,窗口尺度  $r$  取值应尽可能大,但为保证连接矩阵的稀疏性, $r$  取值不能过大,因此,结合实验验证,本文取  $r$  为 [11, 19] 范围内的奇数. 尺度参数定义中涉及的窗口尺度取固定值 5 时,像素尺度计算合理,分割结果较好. 本文算法在执行类别数估计的

步骤中,需预先给定预计的最大可能类别数  $K_{max}$  和阈值  $\zeta$ . 一般地,遥感影像分割最大可能的类别数不超过 15 类;实验表明,不恰当的  $\zeta$  值会导致类别数估计错误,由于  $k$  取固有类别数时  $t_k$  (即  $t_k$ ) 取值较大使得  $\zeta$  可取较大值,经大量实验验证, $\zeta$  可取 [0.7, 1] 间实数,且结合验证结果,本文可取  $\zeta = 0.762$ . 当取  $m = 2, 3, \dots, (k - 1)$  时, $k$  的增大使得计算各  $m$  对应的  $t_{k \rightarrow m}$  均需重复执行步骤 Step7 ~ Step9,大量实验结果分析,当令  $\zeta = 0.762$ ,取  $m = 2$  时,执行类别数估计步骤可确定类别数  $K$ ,可减少循环次数,即当  $\zeta$  选择恰当时, $m$  取 2 即可.




图3 对比算法和本文算法分割图1(b)、(d)的分割结果图

表 1 用户精度、产品精度、总精度 (%) 及 Kappa 值

| 合成影像   | 精度指标                      | 同质区域  |       |        |        |       |
|--------|---------------------------|-------|-------|--------|--------|-------|
|        |                           | I     | II    | III    | IV     | V     |
| 图 1(b) | 用户精度                      | 96.34 | 95.00 | 98.83  | 100.00 |       |
|        | 产品精度                      | 97.56 | 98.65 | 92.82  | 100.00 |       |
|        | 总精度 = 97.55, Kappa = 0.96 |       |       |        |        |       |
| 图 1(d) | 用户精度                      | 98.73 | 97.50 | 99.94  | 99.60  | 92.58 |
|        | 产品精度                      | 90.67 | 99.30 | 100.00 | 98.67  | 99.86 |
|        | 总精度 = 97.58, Kappa = 0.97 |       |       |        |        |       |

### 3.2 真实遥感影像分割

为进一步验证本文算法能较为准确地估计类别数,采用本文算法对图 4 的真实遥感影像进行了分割实验,并与对比算法的结果比较. 图 4 中各影像尺寸均为 128 × 128 像素,图 4(a) ~ (d) 类别数分别为 2、3、4 和 6 类. 其中,图 4(a)、(c) 均为 0.7m 分辨率的 EROS-B 全色影像,前者影像上半部分为耕地、下半部分为树林,后者影像左上角为静止水域、右上角为城区、下半

部分为海波、中间部分为沿海工业区;图 4(b) 为 Pleiades-1 的 0.5m 分辨率的全色影像,其左边部分为公路、中间为草地、右边为树林;图 4(d) 为 Worldview-2 的 0.5m 分辨率影像,其左上角为树林、白色部分包含两种不同类型的裸地并用④和⑤标注、其余部分为不同类型植被用地且以①、②、③标记.

图 5 为分别采用对比算法和本文算法分割图 4(a) ~ (d) 的类别数折线图,其中,图 5(a) ~ (d) 为对比算




图4 真实遥感影像

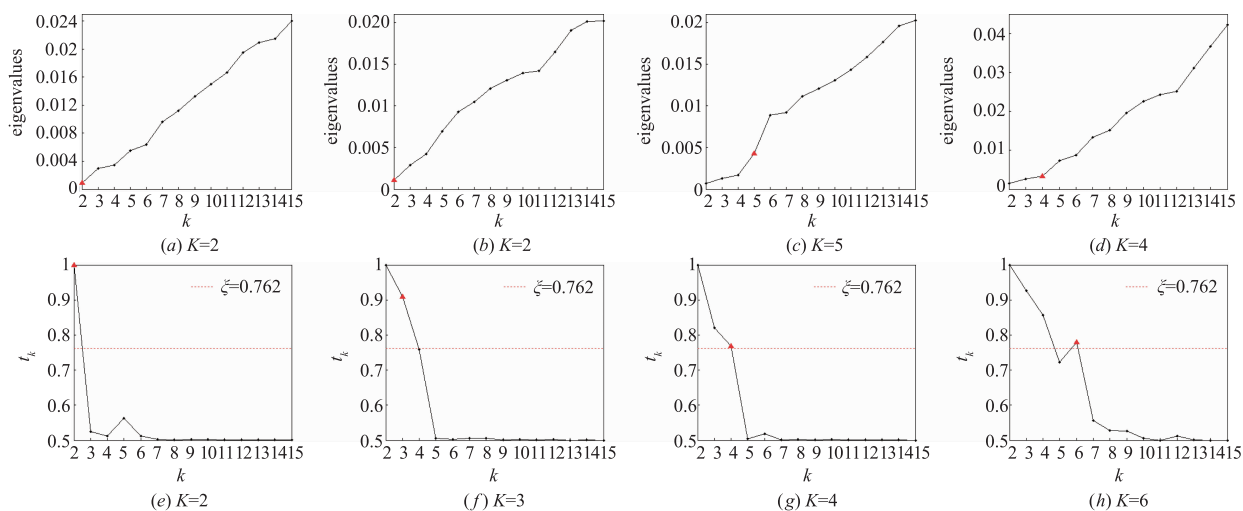


图5 对比算法和本算法分割图4(b)~(d)的类别数折线图

法的类别数折线图,图5(e)~(h)为本文算法的类别数折线图;图6为两种算法分割图4各影像的分割结果图,其中图6(a)~(d)为对比算法的分割结果图,图6(e)~(h)为本文算法的分割结果图.采用对比算法和本算法分割图4(a),由于两算法能判别的最小类别数均为2类,则各算法均至少将图4(a)划分为2类.由类别数折线图5(a)、(e)知,各算法判别类别数均为2类,判别正确.分割结果图6(a)、(e)表明各算法分割结果均很好.且通过大量实验表明,当待分割影像类别

数为2时,本文算法和对比算法均能正确地实现类别数的自动确定,较好地分割影像.然而,当待分割影像类别数大于2时,采用对比算法分割图4(b)~(d),图4(b)中草地与树林、图4(d)中植被用地②与③、裸地④与⑤灰度特征较为接近,图5(b)、(d)显示该算法确定的类别数分别为2和4类,类别数判别错误,且上述灰度相近地物被划分为相同类别,如图6(b)、(d)所示;图4(c)的沿海工业区灰度方差较大,图5(c)显示对比算法判别的类别数为5类,类别数判别错误,且分




图6 对比算法和本算法分割图4(a)~(d)的分割结果图

割结果图 6(c) 表明, 该算法将沿海工业区与部分海波区域归为一类, 海波区域被划分为两类, 区域分割错误. 而采用本文算法分割图 4(b) ~ (d), 据类别数折线图 5(f) ~ (h) 知, 各影像类别数判别正确; 由分割结果图 6(f) ~ (h) 得, 图 4(b)、(d) 中灰度特征较近地物可被划分开来, 图 4(c) 中灰度方差较大地物可得到正确的分割结果. 相较于对比算法, 本文算法的实验结果进一步验证了提出算法可较为准确地确定影像类别数, 有效地分割影像.

#### 4 结论

遥感影像中普遍存在不同地物间灰度特征较为接近的现象. 在基于图划分的分割算法中, 这种现象将导致不同地物像素间连接权重增大, 使得基于 Laplacians 矩阵特征值间隙的谱聚类策略无法正确判别类别数. 本文提出的可变类的谱聚类遥感影像分割算法, 遍历给定区间中各不同类别数并计算其对应聚类度, 进而得到类别数-聚类度变化曲线; 通过判断聚类度发生明显跳变的跳变点即可得到固有类别数; 在此类别数基础上, 分割特征向量矩阵对应的像素特征点获得影像分割结果. 研究表明, 通过逐次降维特征向量矩阵而定义的聚类度具有在固有类别数处的跳变特性, 可以作为固有类别数的判据; 此外, 由特征向量矩阵得到的像素特征点集较之遥感影像灰度值本身更具聚类性, 因此, 以前者为数据的分割结果将更为精准. 然而, 实验表明提出算法在计算类别数过程中阈值  $\zeta$  的取值至关重要; 且由于谱聚类算法需解算极大矩阵的特征解, 很难对大图幅影像数据进行处理. 所以, 在未来的工作中, 将研究自适应确定阈值  $\zeta$  的方法; 并探索提高效率的解决办法, 以使算法更好地适用于大图幅遥感影像.

#### 参考文献

- [1] Xu R, Wunsch D. Survey of clustering algorithms [J]. IEEE Transaction on Neural Networks, 2015, 16(3): 645 - 678.
- [2] Geoffrey M, Peel D. Finite Mixture Models [M]. The Netherlands: John Wiley & Sons, 2004.
- [3] Duda R O, Hart P E, Stork D G. Pattern Classification [M]. New York: John Wiley & Sons, 2012.
- [4] 陈海鹏, 申铨京, 龙建武, 等. 自动确定聚类个数的模糊聚类算法 [J]. 电子学报, 2017, 45(3): 687 - 694.  
Chen H, Shen X, Long J, et al. Fuzzy clustering algorithm for automatic identification of clusters [J]. Acta Electronica Sinica, 2017, 45(3): 687 - 694. (in Chinese)
- [5] Pal N R, Bezdek J C. On cluster validity for the fuzzy c-means model [J]. IEEE Transactions on Fuzzy Systems, 1995, 3(3): 370 - 379.
- [6] Chuang K S, Tzeng H L, Chen S, et al. Fuzzy c-means clustering with spatial information for image segmentation [J]. Computerized Medical Imaging and Graphics, 2006, 30(1): 9 - 15.
- [7] Hong X, Wang J, Qi G. Comparison of spectral clustering, K-clustering and hierarchical clustering on e-nose datasets: application to the recognition of material freshness, adulteration levels and pretreatment approaches for tomato juices [J]. Chemometrics and Intelligent Laboratory Systems, 2014, 133: 17 - 24.
- [8] Zhao F, Jiao L, Liu H, et al. Spectral clustering with eigenvector selection based on entropy ranking [J]. Neurocomputing, 2010, 73(10): 1704 - 1717.
- [9] Zeng S, Huang R, Kang Z, et al. Image segmentation using spectral clustering of Gaussian mixture models [J]. Neurocomputing, 2014, 144: 346 - 356.
- [10] Chan P K, Schlag M D F, Zien J Y. Spectral K-way ratio-cut partitioning and clustering [J]. IEEE Transaction on Computer-Aided Design of Integrated Circuits and Systems, 1994, 13(9): 1088 - 1096.
- [11] Zhang X, You Q. An improved spectral clustering algorithm based on random walk [J]. Frontiers of Computer Science in China, 2011, 5(3): 268 - 278.
- [12] Liu H, Zhao F, Jiao L. Fuzzy spectral clustering with robust spatial information for image segmentation [J]. Applied Soft Computing, 2012, 12(11): 3636 - 3647.
- [13] Fiedler M. Algebraic connectivity of graphs [J]. Czechoslovak Mathematical Journal, 1973, 23(2): 298 - 305.
- [14] Ng A Y, Jordan M I, Weiss Y. On spectral clustering: analysis and an algorithm [A]. Advances in Neural Information Processing Systems, 2001 [C]. British Columbia, Canada: NIPS, 2001. 849 - 856.
- [15] Still S, Bialek W. How many clusters? an information-theoretic perspective [J]. Neural Computation, 2004, 16(12): 2483 - 2506.
- [16] Ben-David S, Von Luxburg U, Pal D. A Sober Look at Clustering Stability [M]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006. 5 - 19.
- [17] Borjigin S, Guo Chonghui. Non-unique cluster numbers determination methods based on stability in spectral clustering [J]. Knowledge and Information Systems, 2013, 36(2): 439 - 458.
- [18] VonLuxburg U. A tutorial on spectral clustering [J]. Statistics and Computing, 2007, 17(4): 395 - 416.
- [19] 孔万增, 孙志海, 杨灿, 戴国骏, 孙昌思核. 基于本征间隙与正交特征向量的自动谱聚类 [J]. 电子学报, 2010, 38(8): 1880 - 1891.  
KongWanzeng, Sun Zhihai, Yang Can, et al. Automatic spectral clustering based on eigengap and orthogonal eig-

- envector[J]. Acta Electronica Sinica, 2010, 38(8): 1880 - 1891 (in Chinese).
- [20] Shi J, Malik J. Normalized cuts and image segmentation [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2000, 22(8): 888 - 905.
- [21] Wu S, Feng X, Zhou W. Spectral clustering of high-dimensional data exploiting sparse representation vectors [J]. Neurocomputing, 2014, 135: 229 - 239.
- [22] 袁永华, 李玉, 赵雪梅. 基于谱聚类的高分辨率全色遥感影像分割 [J]. 仪器仪表学报, 2016, 37(7): 1201 - 1209.  
Yuan Y, Li Y, Zhao X. High-resolution panchromatic remote sensing image segmentation based on spectral clustering [J]. Chinese Journal of Scientific Instrument, 2016, 37(7): 1201 - 1209 (in Chinese).
- [23] Liu A H, Poon L K M, Liu Tengfei, et al. Latent tree models for rounding in spectral clustering [J]. Neurocomputing, 2014, 144: 448 - 462.
- [24] Roblitz S, Weber M. Fuzzy spectral clustering by PCCA + : application to Markov state models and data classification [J]. Advances in Data Analysis and Classification, 2013, 7(2): 147 - 179.

## 作者简介



**李玉 (通讯作者)** 男, 1963 年 3 月出生于吉林省长春市, 1984 年于西北电讯工程学院获得学士学位, 1991 年于东南大学获得硕士学位, 2006 年于瑞尔森大学获得博士学位, 2010 年于滑铁卢大学获得博士学位, 现为辽宁工程技术大学教授, 主要研究方向为遥感数据处理理论与应用基础研究。

E-mail: liyu@lntu.edu.cn



**袁永华** 女, 1991 年 5 月出生于河南省商丘市, 2014 年于河南城建学院获得学士学位, 现为辽宁工程技术大学在读硕士生, 主要研究方向为图像分割。

E-mail: 790599549@qq.com



**赵雪梅** 女, 1989 年 9 月出生于辽宁省阜新市, 2012 年于辽宁工程技术大学获得学士学位, 2017 年于辽宁工程技术大学获得博士学位, 现于中国科学院遥感与数字地球研究所做博士后研究工作, 主要研究方向为遥感图像分割及基于深度学习的 Landsat 图像分类。

E-mail: 374010101@qq.com