

基于核空间 LLE 的彩色图像分割方法

刘 越 彭宏京 钱素静

(南京工业大学电子与信息工程学院 南京 211816)

摘 要 拉普拉斯特征映射近年来被成功地运用到基于聚类的彩色图像分割中,其构成图的结点间权重用高斯函数计算,很难真实反映像素局部几何结构,导致复杂图像边界分割困难。基于此,提出一种基于核空间局部线性嵌入的图像分割方法,其首先利用单个像素间的八邻域关系来构造图,然后将局部线性嵌入算法进行核化,从而实现在高维空间中利用相关拉普拉斯矩阵描述像素间相似度并生成特征向量子空间的过程,最后,利用模糊 C 均值聚类算法对特征向量进行聚类从而为单个像素分配类标签,最终达到了彩色图像分割的目的。实验结果表明,新方法较拉普拉斯特征映射方法的图像分割效果更显著。

关键词 拉普拉斯映射,模糊 C 均值,局部线性嵌入,核空间,彩色图像分割

中图分类号 TP391.4 **文献标识码** A

Color Image Segmentation Approach Based on LLE in Kernel Space

LIU Yue PENG Hong-jing QIAN Su-jing

(College of Electrical and Information Engineering, Nanjing University of Technology, Nanjing 211816, China)

Abstract Recently, Laplacian eigenmaps has been used in the color image segmentation based on cluster algorithm as an improving means. The graph weight matrix which is learned from Gaussian method may not characterize the locally geometric structure of the data points. As a result this method can't tell the fuzzy edges sufficiently. To overcome this problem, the locally linear embedding in kernel space algorithm is proposed. Firstly, the simple pixel's eight-nearest neighbor method is introduced to get weighted graph. Secondly, With the kernel trick, Laplacian reconstruction coefficients used to reflect the similarity between data points in the high dimension space can be achieved, as well as the subspace of feature vector. Finally, Fuzzy C-means clustering algorithm is used in the subspace to distribute labels for each pixel and achieve the segmentation of color images. The result of experiments compared with the results of the Laplacian eigenmaps segmentation method provided shows the encouraging improvements of the new algorithm.

Keywords LE, FCM, LLE, Kernel space, Color image segmentation

图像分割从本质上讲是将具有相似属性(如颜色、灰度、纹理、空间等)的像素进行分类的过程。其作为图像处理到图像分析转变的关键步骤,在图像工程中占据重要的位置,通过图像的分割、目标的分离将原始图像以更抽象、紧凑的形式表现,是图像理解和图像识别的基础。因此,有效的图像分割手段在图像处理过程中起着非常重要的作用。基于聚类的分割方法,由于其直观、易实现的特点,并且可以将 3 个彩色分量作为一个整体考虑,是目前较为流行的彩色图像分割方法。后来,为了解决传统的聚类方法(如 K-means、FCM^[1]算法等)只适合在类簇为凸形的数据集上进行聚类的问题,人们提出了谱聚类算法。谱聚类是建立在谱图理论基础上的的一种点对聚类算法^[2]。其本质是将聚类问题转化为图的最优化问题。该算法主要包括预处理(构造邻接图、建立相似矩阵)、谱映射和聚类 3 个步骤,目前比较经典的谱聚类图像分割算法有 Ncut^[3]、NJW^[4]、MS^[5]算法等。

基于谱图理论的流形学习方法作为一个与谱聚类相关的

工作,也已被广泛地应用于图像分割领域。Tziakos Ioannis 等人^[6]就将流形学习方法中的 Laplacian 特征映射算法与 FCM 聚类算法相结合实现了图像的分割,并取得了不错的分割效果。但由于该方法首先需要将图像分成大小相同的块来构造高维空间,使得聚类后属于同一个块的像素点的类标签相同,导致分割的边界不够平滑,容易产生锯齿,而且算法中使用单相关 Laplacian 矩阵^[7]——图的 Laplacian 矩阵并没有较好地反映像素间的相似性。

针对以上问题,本文提出了一种基于核空间局部线性嵌入的彩色图像分割方法,即通过在特征核空间中求取映射权重来代替局部线性嵌入求权重的方法。首先,将各个像素的八邻域点作为其 k 近邻点构造八邻接图,避免因分块导致的分割边缘呈锯齿状的情况;其次,利用核空间的局部线性嵌入算法^[13],实现在高维特征空间中使用重相关 Laplacian^[7] 矩阵尽可能准确地描述像素点间相似性并进行低维嵌入,形成保持数据集局部信息的最优化表示;最后,利用 FCM 算法对特

本文受江苏省自然科学基金项目(BK2011794)资助。

刘 越(1988—),男,硕士生,主要研究方向为图像识别、压缩感知,E-mail:liuyue2046@126.com;彭宏京 男,博士,副教授,主要研究方向为模式识别、压缩感知,E-mail:penghongjing@163.com(通信作者);钱素静(1987—),女,硕士,主要研究方向为图像识别。

征向量进行聚类实现图像的分割。实验结果表明了本文方法的可行性,且较基于 Laplacian 特征映射的彩色图像分割方法取得了更优的结果。

1 基于 Laplacian 特征映射的彩色图像分割方法

1.1 模糊 C 均值聚类(Fuzzy C-Means, FCM)

模糊 C 均值聚类算法^[1]由 Bezdek, J. C 根据硬 C-均值聚类算法(HCM)推广而来,与 HCM、K-means 聚类算法不同之处在于不是将样本分成明子集,而是计算每个样本属于各模糊子集(聚类)的隶属度。其具体描述如下:

令 $X=[x_1, x_2, \dots, x_n]$, $X \in R^D$ 为一训练样本集, c 为预定的聚类类别数,第 i 个聚类的中心为 v_i ($i=1, 2, \dots, c$), u_{ik} ($i=1, 2, \dots, c, k=1, 2, \dots, n$), 是第 k 个样本对第 i 类的隶属度,且 $0 \leq u_{ik} \leq 1$ 及 $0 < \sum_{k=1}^n u_{ik} < n$, FCM 的目标函数为:

$$J_m(U, v) = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m \|x_k - v_i\|^2 \quad (1)$$

式中, m 是一个控制聚类结果模糊程度的常数,一般 $m > 1$, $v = (v_1, v_2, \dots, v_c)$, $U = \{u_{ik}\}$, 约束为:

$$\sum_{i=1}^c u_{ik} = 1, \forall k = 1, 2, \dots, n \quad (2)$$

在约束条件式(2)下优化式(1)可以得到:

$$u_{ik} = \frac{(1/\|x_k - v_i\|^2)^{1/(m-1)}}{\sum_{j=1}^c (1/\|x_k - v_j\|^2)^{1/(m-1)}}, \forall i = 1, 2, \dots, c, k = 1, 2, \dots, n \quad (3)$$

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m}, \forall i = 1, 2, \dots, c \quad (4)$$

通过采用 U, v 交替迭代法来优化目标函数,最终得到聚类中心和各个样本对各类的隶属度值,从而实现数据集的模糊聚类分类。该算法具有很好的收敛性,是聚类方法中最著名、最常用的一种算法,但由于每个样本点对各个类都有影响,同时类与类之间也相互影响,导致 FCM 算法对噪声数据非常敏感^[8,9]。

1.2 拉普拉斯特征映射(Laplacian Eigenmaps, LE)

为了解决 FCM 方法对噪声敏感的问题, Belkin M 和 Niyogi P^[10] 提出了拉普拉斯特征映射算法,引入了流形学习机制。LE 算法是基于邻接图模型的,利用局部性方法,获得了高维数据所在的低维流形嵌入^[11]。其基本思想是在高维空间中离得很近的点投影到低维空间中的像也应该离得很近,通过使用两点间的加权距离作为代价函数,再利用拉普拉斯算子的谱性质进行分析^[12],最终求出保持数据集某种局部信息的最优低维表示。

LE 算法首先寻找样本点 x_i 对应连接图的顶点 i , 如果 x_i 和 x_j 距离很“近”, 则顶点 i 和 j 由一条边相连, 有两种方法可以确定 i 和 j 两个顶点间是否存在一条边: (a) ϵ 邻域法 ($\epsilon \in R$)。如果 i 和 j 两顶点间的距离(一般使用欧几里得距离)小于阈值 ϵ , 即 $\|x_i - x_j\|^2 < \epsilon$ 时, 两顶点间存在一条边 E_{ij} 。(b) k 近邻法 ($k \in N$)。如果 x_i 在 x 的 k 近邻内, 则将顶点 i 和 j 用边 E_{ij} 连接。如果 x_i 和 x_j 相邻, 赋予权重 $W_{ij} = \frac{-\|x_i - x_j\|^2}{\rho^2}$ 。

其次, 通过优化目标函数:

$$\sum_{i,j} \|y_i - y_j\|^2 W_{ij} \quad (5)$$

使得近邻点间的距离尽可能小。这样可以转化为求最小化的优化问题:

$$Y^T LY \quad (6)$$

约束条件为: $Y^T LY = 1, Y^T D 1 = 0$, 这里的 $D_{ii} = \sum_j W_{ij}, L = D - W$ 。

最终, 求解 y 即寻找低维嵌入转化为求解式(6)的广义特征值问题:

$$LY = \lambda DY \quad (7)$$

选取式(7)的最小 d 个非零特征值对应的特征向量 y_1, \dots, y_d , 则 $T = [y_1, \dots, y_d]^T$ 即为低维嵌入结果。

以 LE 算法为代表的流形学习方法最终将最优化目标函数问题转化为求解矩阵的特征值和特征向量的问题, 而这正是谱聚类算法的本质所在。LE 算法将高维数据映射到低维空间中使得相邻的数据点尽可能地靠近, 从而得到聚类效果更好的数据集, 加快了运算速度, 而且在出现离群点的情况下, 算法具有良好的鲁棒性, 较好地克服了模糊 C 均值聚类算法对噪声数据比较敏感的问题。

综上所述, 由于 LE 算法可以实现谱聚类算法中的预处理和谱映射过程, 将其与 FCM 算法结合既实现了谱聚类算法的过程, 又较好地解决了 FCM 算法对噪声数据比较敏感的问题。下面给出基于拉普拉斯特征映射的彩色图像分割方法的具体实现步骤:

Step1 分块: 构造高维特征空间 D 。

将彩色图像分成每块由 8×8 个像素组成且与前一个块重叠两个像素的图像块, 那么, 每个图像块即为一个 8×8 的 RGB 矩阵, 则可以将矩阵转换为 $3 \times 8 \times 8$ 大小的向量, 有: $X = [R_1, G_1, B_1, \dots, R_{192}, G_{192}, B_{192}]^T$, 从而形成了一个 192 维的高维空间。

Step2 构造邻接图、计算权值。

选用 k 近邻法构建邻接图 G , 使用高斯核函数 $W_{ij} = \frac{-\|x_i - x_j\|^2}{\rho^2}$ 计算边的权值。

Step3 低维嵌入: 寻找低维特征空间 d 。

求解广义特征系统式(7), 选取前 d 个特征值对应的特征向量, 从而将数据嵌入到一个 d ($d \ll D$) 维特征空间中(一般 d 的取值在 2~15 范围内变化, 通常其值设置为 2 或 3)。

Step4 聚类。

利用 FCM 聚类算法将降维后的特征空间 d 分为 c 类。

Step5 为每个像素指派类标签, 完成分割。

将每个块的类标签指派给该块中的每个像素, 其中, 重叠区域中属于不同类的像素被归类到首先被指派的类中, 不重复进行分类。

2 基于核空间 LLE 的彩色图像分割方法

2.1 局部线性嵌入(LLE)

LLE^[13]认为流形上每一个局部邻域内的任意一点都可以描述为邻域内其他点的线性表示, 各个邻域之间的连接信息也可以通过相互重叠的部分来描述, 而这个线性关系在映射时保持不变, 这样既可以把输入数据映射到统一的一个全局低维坐标系, 并能够保留邻接特性。

假设 D 维空间中有 N 个样本属于同一流形, 记作: $\{x_i \in R^D, i = 1, 2, 3, \dots, N\}$, 对于每个样本点 x_i 都可以用它的 k 邻

域点 $\{x_j, j \in N_i\}$ 线性重构, 每个样本点与其邻域点间的重构权 w_{ji} 的选取可以通过极小化下面的重构误差来实现:

$$\epsilon(W) = \sum_{i=1}^N \left\| x_i - \sum_{j=1}^k w_{ji} x_j \right\|^2 \quad (8)$$

式中, w_{ji} 表示点 x_j 对样本点 x_i 的重构贡献, 体现数据间内在的几何关系。通过约束条件: $\sum_j w_{ji} = 1$, 将最优权值问题转换为求解最小二乘问题, 则重构误差可以改写为:

$$\left\| x_i - \sum_{j=1}^k w_{ji} x_j \right\|^2 = \left\| \sum_{j=1}^k w_{ji} (x_i - x_j) \right\|^2 \quad (9)$$

经过优化得到的重构权重的表达式为:

$$w_{ij} = \frac{(C_{mm}^{-1})^{-1} \mathbf{1}}{\mathbf{1}^T (C_{mm}^{-1})^{-1} \mathbf{1}} \quad (10)$$

式中, $C_{mm} = (x_i - x_m^i)(x_i - x_m^i)$, 表示关于 x_i 的 k 邻域的相关矩阵。

LLE 要求低维嵌入 $y_i \in R^d$ 与其邻域点能反映出高维空间中样本点间的重构权关系, 即极小化代价函数:

$$\Phi(Y) = \sum_{i=1}^N \left\| y_i - \sum_{j=1}^k w_{ji} y_j \right\|^2 \quad (11)$$

式中, $Y = [y_1, \dots, y_N]$, 为了保证极小化代价函数能够得到唯一的解, LLE 对低维嵌入 Y 加上两个约束条件: (1) Y 被中心化, $\sum_{i=1}^N y_i = 0$; (2) Y 为标准正交阵, 即 $\frac{1}{N} \sum_{i=1}^N y_i y_i^T = I$, 则式(11)又可以写成:

$$\Phi(Y) = \text{Tr}(T(I-W)^T(I-W)) \quad (12)$$

这样, 根据 Rayleitz-Riz 定理, 求解矩阵 $M = (I-W)^T(I-W)$ 的最小 d 个非零特征值对应的特征向量 y_1, \dots, y_d , 即得到低维嵌入 $T = [y_1, \dots, y_d]^T$ 。

LLE 算法通过构造邻接图获得高维空间数据点之间的权重, 得到高维空间中的局部流形几何结构。然后通过优化误差函数保持权值不变, 得到低维空间中的局部线性嵌入新的数据集。该算法通过线性重构的局部对称性质, 把数据由高维空间映射到低维空间。

通过对比 LE 算法和 LLE 算法发现, 尽管两种算法是从不同的角度寻找数据的低维嵌入, 但两者实际上都描述了像素点的特征相似性, 且最终都将目标函数最优化问题归结为求解特征值和特征向量的问题。其中, LE 算法通过求解图的拉普拉斯矩阵 $L = D - W$ 的特征值和特征向量找出保持数据集某种局部信息的最优低维表示, 而 LLE 算法则是求解矩阵 $M = (I - W)^T(I - W)$ 的特征值及其特征向量的过程, 然后将数据映射到统一的一个全局低维空间。文献[7]中分别将这两种矩阵称为单相关的 Laplacian 和重相关的 Laplacian, 并指出: 对于单相关的 Laplacian, 邻点对 (i, j) 无论以 i 还是以 j 为中心的邻域, w_{ij} 只需计算一次, 即 $w_{ij}(i) = w_{ij}(j)$, 而对于重相关的 Laplacian, 当以 i 或 j 为中心的邻域重构权重时, w_{ij} 计算两次, 并且通常 $w_{ij}(i) \neq w_{ij}(j)$ 。所以, LLE 算法较 LE 算法能更好地体现数据间的相似性, 从而能更好地应用于图像分割。

2.2 八邻接图的构造

数字图像像素间的关系是图像处理中一个重要的概念, 位于坐标 (x, y) 的一个像素 p 有 4 个水平或垂直的相邻像素, 其坐标为 $(x+1, y), (x-1, y), (x, y+1), (x, y-1)$, 将这个像素集称为 p 的 4 邻域; p 的 4 个对角的像素坐标为 $(x+1, y), (x+1, y-1), (x-1, y+1), (x-1, y-1)$, 其与四邻域

点一起组成的像素集称为 p 的八邻域^[12]。

从 LLE 算法的步骤中可以看出, 局部线性嵌入算法的首要步骤是构造 ϵ 邻域图或 k 近邻图, 但在处理大规模的图像时, 这两种构造方式的计算复杂度会大大增加, 例如, 使用 k 近邻构造邻接图时, 我们需要花大量的时间来计算和排序找出各个像素点的 k 个近邻点, 所以在实际的图像分割中常按照像素的四邻接或八邻接来构造邻接图, 即当像素 i 和像素 j 的位置满足四邻接或八邻接的关系时, 顶点 i 与 j 之间才存在一条边, 这样, 由图像生成的相似矩阵的元素大多为零, 使得求解特征值和特征向量时相对比较简单。

2.3 核空间局部线性嵌入(KLLE)

根据 Mercer Kernel 理论, 核方法可以把实际输入空间中难以分割的样本映射到高维特征空间中进行聚类, 核聚类方法通过非线性映射能够较好地分辨、提取并放大有用的特征, 进而可以得到更为准确的聚类效果, 使得算法有更快的收敛效果。于是出现了如 KPCA 等核方法的成功应用。

本文图像分割中采用核空间局部线性嵌入算法^[13], 在核空间中对每个数据点在其邻域内计算重构权重, 以反映数据点之间的几何结构, 然后用正规化方法对未分类的数据点进行标示。

对图的拉普拉斯矩阵进行正则化处理有:

$$P = \tau(\tilde{L}) = \tilde{L} + \epsilon \cdot I$$

这样, 图 G 上的一个希尔伯特空间 H 可以定义为 $\langle f, f \rangle_H = \langle f, Pf \rangle$, 同时, 文献[14]已经证明了矩阵 P 的逆即为希尔伯特空间 $H(G)$ 的再生核, 有: $k(i, j) = [P^{-1}]_{ij}$ 。

可见, 从输入空间到高维特征空间 F 中, 图的 Laplacian 矩阵的核 K 隐含了一个映射 ϕ , 通过 $k(x, x') = \langle \phi(x), \phi(x') \rangle$ 使得 K 对应特征空间 F 中的一点, 从而, 我们可以描述数据点 x_i 在核诱导特征空间 F 中的几何结构。对于每个特征点 $\phi(x_i)$, 定义其在特征空间 F 中的 k 个近邻为 $N(\phi(x_i))$, 那么, 有关 $\phi(x_i)$ 的重构误差即为:

$$\epsilon(W_i) = \left\| \phi(x_i) - \sum_{\phi(x_j) \in N(\phi(x_i))} w_{ji} \phi(x_j) \right\|^2 \quad (13)$$

在约束条件 $\sum_j w_{ji} = 1$ 下, 式(13)可以改写为:

$$\left\| \sum_{\phi(x_j) \in N(\phi(x_i))} w_{ji} (\phi(x_i) - \phi(x_j)) \right\|^2 = W_i^T G_i W_i \quad (14)$$

其中, G_i 是特征点 $\phi(x_i)$ 在特征空间 F 中的局部 Gram 矩阵:

$$G_i(j, k) = (\phi(x_i) - \phi(x_j))^T (\phi(x_i) - \phi(x_k)) \quad (15)$$

用核函数来代替点积, 有:

$$\left\| \phi(x_i) - \phi(x_j) \right\|^2 = K(i, i) + K(j, j) - 2K(i, j) \quad (16)$$

由于高斯核函数是比较常用的核函数, 更具有代表性, 这

里将高斯核函数 $W_{ij} = e^{-\frac{\|x_i - x_j\|^2}{\sigma^2}}$ 代入式(16)中, 从而得到特征空间中的局部 Gram 矩阵, 再根据式(10)计算出特征点 $\phi(x_i)$ 的权值矩阵 w_i , 最后计算 $M = (I - W)^T(I - W)$ 的最小 d 个非零特征值对应的特征向量, 相应地嵌入到 d 维的空间中, 从而实现核空间局部线性嵌入。

核空间局部线性嵌入算法的中心思想就是通过一个非线性映射将原始特征空间映射到希尔伯特空间 H 中, 在新生成特征空间 H 中再用局部线性嵌入方法将数据点嵌入到低维空间。由于核方法可以将实际空间中难分的数据映射到更高维的空间, 再在新空间进行高效学习, 因此核空间局部线性嵌入将重构权重的计算以及低维嵌入过程映射到高维空间中

进行,较局部线性嵌入算法更好地实现了样本点 x_i 的邻域点对 x_i 的线性重构,即更精确地描述了样本点 x_i 与其邻域点的相似性。

综上所述,可以得到如下基于核空间局部线性嵌入的彩色图像分割方法的具体步骤:

输入:一幅具有 n 个像素点的彩色图像 X ;

输出:分割结果图;

Step1 构造八邻接图 G 。

将彩色图像中每个像素八邻域内的像素作为其近邻点来构造邻接图,即当像素 x_i 和像素 x_j 的位置满足八邻接的关系时,顶点 i 与 j 之间存在一条边 E_{ij} 。

Step2 计算重构权。

利用高斯核函数 $W_{ij} = e^{-\frac{\|x_i - x_j\|^2}{\sigma^2}}$ 代替点积,根据式(15)计算每个特征点在特征空间的局部 Gram 矩阵,并求解正则化线性系统式

$$(10), \text{从而得到 } w_i = \frac{G_i^{-1} \mathbf{1}}{\mathbf{1}^T G_i^{-1} \mathbf{1}}。$$

Step3 低维嵌入。

计算 $M = (I - W)^T (I - W)$ 的最小 d 个非零特征值对应的特征向量 y_1, \dots, y_d , 则 $T = [y_1, \dots, y_d]^T$ 为低维嵌入结果。

Step4 聚类。

利用 FCM 算法将特征向量 T 分为 c 类。

Step5 标记。

为每个像素点分配类标签,完成分割。

3 实验结果及分析

从 BSD3 标准测试图像数据库^[4]中随机选取一组图像,在 Matlab 2010a 环境下实现了本文提出的分割方法,并将其与利用 FCM 算法以及基于拉普拉斯特征映射的谱聚类算法进行了比较,结果如图 1 所示。实验中,高斯核参数 σ 取 1,低维特征空间 d 取 3,图 1 中由上至下 7 幅彩色图像聚类数目的取值依次为 2, 2, 2, 6, 5, 4, 5。



图 1 本文方法与其他方法的结果比较

如图 1 所示,不管是将图像分为两类还是分为多类,无论是背景比较复杂还是简单的图像,目标与背景颜色相近还是

相差较大的图像,本文的方法较基于 LE 的图像分割方法以及 FCM 算法都取得了更优的分割结果,较好地实现了类的划分。其中,利用 FCM 算法对图像进行分割则较多地出现了过分割的现象,而 LE 的图像分割方法由于利用特征块来构造高维空间,使得最终属于同一个块的像素被分配了相同的类标签,从图 1 中拉普拉斯特征映射的图像方法下的第 2 幅和第 4 幅的分割结果图可以看出,其分割的边界出现了较明显的锯齿状,而本文中则通过构造单个像素的八邻接图避免了该情况的发生。

其次,根据文献[14]提供的人工分割基准(ground-truth)图,本文进一步计算了利用这几种方法对图 1 中 7 幅图像进行分割后的概率兰德指数(Probabilistic Rand Index, PRI)^[16],PRI 是用来计算图像分割结果与其所有人工分割基准图的一致性,PRI 值越大表示图像的分割结果与其基准图越一致,即分割效果越好。图 2 为各个方法下每幅图像的 PRI 比较。




图 2 概率兰德指数比

由图 2 可以看出,利用本文的方法进行图像分割后的概率兰德指数明显高于其他两种分割方法下的概率兰德指数。这充分说明了,本文这种核空间局部线性嵌入的方法通过将原始特征空间映射到希尔伯特空间,并在该高维空间中实现重构权的计算和谱映射的过程,较其他两种方法更准确地反映了相似点之间的相似性,从而降低了错分的可能性。综上所述,本文这种基于核空间 LLE 的图像分割方法有效、可行,较 FCM 算法和基于 LE 的图像分割方法能够更好地进行彩色图像的分割。

结束语 本文通过构造单个像素的八邻接图,有针对地解决了拉普拉斯特征映射彩色图像分割方法下分割结果不够平滑的问题,并利用核空间局部线性嵌入的方法将图像映射到高维空间中完成像素间相似度的计算以及特征向量空间的形成,最后通过 FCM 算法对特征向量进行聚类完成了彩色图像的分割。实验结果表明,本文的方法能够提高图像分割的效果,较 FCM 算法下进行的图像分割以及基于拉普拉斯特征映射的彩色图像分割方法具有明显的优势。本文的方法中没有对彩色空间进行变换,即直接在 RGB 彩色空间中实现图像分割,下一步的研究工作将尝试在其他彩色空间(如 HSV、CIE、 $L^*a^*b^*$)中进行彩色图像分割。

参考文献

- [1] 章毓晋. 图像工程(中册:图像分析)[M]. 北京:清华大学出版社,2005
- [2] Fiedler M. Algebraic connectivity of graphs [J]. Czechoslovak Mathematical Journal, 1973, 23: 298-305
- [3] Shi J, Malik J. Normalized cuts and image segmentation. IEEE Trans. Pattern Analysis and Machine Intelligence, 2000, 22(8): 888-905

(下转第 219 页)

1200nm, 船只为 2500 时, AIS 系统的监测概率在 15%, 使用盲分离技术以后, 监测概率达到 97%; 管理区域列宽为 1900nm, 船只为 2500 时, AIS 系统的监测概率在 24%, 使用盲分离技术以后, 监测概率达到 100%; 管理区域列宽为 2880nm, 船只为 3000 时, AIS 系统的监测概率在 12%, 使用盲分离技术以后, 监测概率达到 98%。因此, 明显地可以看到, 将盲分离技术应用于基于星载的 AIS 系统中, 可以大大地提高船只的检测概率, 一定程度上改进了 AIS 系统的性能。




图 1 使用盲分离技术前后船只的监测概率(同颜色的曲线中, 细的为文献中的, 粗线条的为加入盲分离技术后的)




图 2 使用盲分离技术前后船只的监测概率(同颜色的曲线中, 细的为文献中的, 粗线条的为加入盲分离技术后的)

结束语 AIS 系统由岸基(基站)设施和船载设备共同组成, 是一种新型的集网络技术、现代通讯技术、计算机技术、电子信息显示技术为一体的数字助航系统和设备。文中针对 AIS 系统在船只数目增多时, 汇报信息时隙冲突增多, 从而导致 AIS 性能急剧下降的问题, 提出了将盲源分离技术应用

于其中的设想, 在时隙发生冲突时, 将重叠的汇报信息分开, 从而提高了信号的监测概率, 避免了反复选择时隙、发送汇报信息的过程, 提高了 AIS 系统的效率。

参考文献

- [1] 刘彤, 吴建华, 雷金平. AIS 通信系统性能分析[J]. 交通科技, 2004(4):134-136
- [2] 常青. 通用船载自动识别系统 AIS 的研究与实现[D]. 北京: 清华大学, 2004
- [3] 张京娟, 郝燕玲. AIS 系统时隙预约选择算法的分析[J]. 哈尔滨工程大学学报, 2002(5):52-56
- [4] Høye G, Narheim B, Eriksen T, et al. EUCLID JP9. 16: Space-Based AIS Reception for Ship Identification[M]. FFI/RAP-PORT-2004/01328(Restricted distribution, EUCLID PMOU), 2004
- [5] Eriksen T, Høye G, Narheim B, et al. Maritime traffic monitoring using a space-based AIS receiver[J]. Acta Astronautica, 2006(58):537-549
- [6] Jutten C, Herault J. Blind separation of sources, Part 1: An adaptive algorithm based on neuromimetic architecture [J]. Signal Processing, 1991, 24(1):1-10
- [7] Hyvarinen A. Fast and robust fixed-point algorithms for independent component analysis [J]. IEEE Transactions on Neural Networks, 1999, 10(3):626-634
- [8] Hyvarinen A. The FastICA Matlab package. V2. 5 [CP/OL]. <http://www.Arocmag.com>, 2005
- [9] Yang H H, Amari S. Adaptive On-Line Learning Algorithms for Blind Separation-Maximum Entropy and Minimum Mutual Information[J]. Neural Computation, 1997, 9(7):1457-1482
- [10] Cardoso J F. Infomax and maximum likelihood for blind source separation [J]. IEEE Signal Processing, 1997, 45(2):434-444
- [11] Hyvarinen A. The fixed-point algorithm and maximum likelihood estimation for independent component analysis[J]. Neural Processing Letters, 1999, 10(1):1-5
- [12] Lee T, Girolami M, Bell A J, et al. A unifying information theoretic framework for independent component analysis[J]. Computers & Mathematics with Applications, 2003, 31(11):1-21
- [13] Eriksen T, Høye G, Narheim B, et al. Maritime traffic monitoring using a space-based AIS receiver[J]. Acta Astronautica, 2006, 58(10):537-549

(上接第 183 页)

- [4] Ng A Y, Jordan M I, Weiss Y. On spectral clustering: Analysis and an algorithm [C]//Neural Information Processing Systems, Cambridge, MA, MIT Press, 2002:857-864
- [5] Meila M, Shi J. Learning segmentation by random walks[C]// Neural Information Processing Systems. 2000:873-879
- [6] Tziakos I, Theoharatos C, Laskaris N A, et al. Color image segmentation using Laplacian eigenmaps [J]. Journal of Electronic Imaging, 2009, 18(2):1-10
- [7] 彭宏京, 陈松灿, 张道强. 一种基于局部学习的自然图像景物提取方法[J]. 软件学报, 2009, 20(4):834-844
- [8] Cai W L, Chen S C, Zhang D Q. Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation[J]. Pattern Recognition, 2007, 40(3):825-838
- [9] 田军委, 黄永宣, 于亚琳. 基于直方图偏差约束的快速模糊 C 均值图像分割法[J]. 西安交通大学学报, 2007, 41(4):430-434
- [10] Belk M, Niyogi P. Laplacian eigenmaps and spectral techniques

for embedding and clustering[C]//Advanced in Neural Information Processing Systems 14. Cambridge, MA:MIT Press, 2002

- [11] Saul L K, Rowels S T. Think globally, fit locally: Unsupervised learning of low dimensional manifolds [J]. Journal of Machine Learning Research, 2003, 4(6):119-155
- [12] 阮秋琦, 阮宇智. 数字图像处理(第二版)[M]. 北京: 电子工业出版社, 2009
- [13] Liu Ru-jie, Wang Yue-hong, Baba T, et al. Semi-supervised learning by locally linear embedding in kernel space[C]//International Conference on Pattern Recognition, 2008
- [14] Fowlkes C, Martin D, Malik J. The Berkeley Segmentation Dataset and Benchmark(BSDB) [OL]. <http://www.eecs.berkeley.edu/Research/Projects/CS/vision/grouping/segbench/>
- [15] Unnikrishnan R, Pantofaru C, Hebert H. Toward objective evaluation of image segmentation algorithms [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(6):929-944