

DOI:10.16136/j.joel.2022.11.0045

基于约束空间光谱联合的亚像素定位方法

徐文结, 郭宝峰*, 迟昊宇, 许张弛, 吴文豪

(杭州电子科技大学 自动化学院,浙江 杭州 310018)

摘要:针对高光谱遥感图像,提出了一种约束空间光谱的亚像素定位方法。传统的亚像素定位方法以解混的结果作为输入,可能无法充分利用高光谱图像丰富的光谱信息。本文所提出的基于约束空间光谱联合的亚像素定位方法(constraint spatial-spectral subpixel mapping, CSSSM),利用下采样将像素丰度与亚像素丰度显式联系起来,代入线性解混模型得到亚像素丰度求解的新模型。在求解过程中,通过添加稀疏性约束与平滑性约束,以限制亚像素丰度的解空间,亚像素丰度求解更精确。其中,针对亚像素丰度稀疏性先验采用重加权1范数作为新的约束,并自适应地更新权重;针对亚像素丰度空间先验信息则采用全变分(total variational, TV)正则化作为约束,然后使用乘法迭代算法求解亚像素丰度,最后利用赢者通吃的策略进行类别确定。在两个合成数据集上进行了实验,结果表明,本方法能够进一步提高亚像素定位的精度。

关键词:高光谱图像; 亚像素定位; 亚像素丰度; 重加权稀疏; 全变分正则化; 赢者通吃**中图分类号:**TP751.1 **文献标识码:**A **文章编号:**1005-0086(2022)11-1139-09

A joint subpixel mapping method based on a spatial - spectral constraint

XU Wenjie, GUO Baofeng*, CHI Haoyu, XU Zhangchi, WU Wenhao

(School of Automation, Hangzhou Dianzi University, Hangzhou 310018, China)

Abstract: For hyperspectral remotely sensed images, a subpixel mapping method of constrained spatial spectrum is proposed. Traditional subpixel mapping methods may not make full use of the rich spectral information of hyperspectral images due to straightforward using of unmixing results. The method based on constraint spatial-spectral subpixel mapping (CSSSM) is proposed, which explicitly combines the pixel abundance with the subpixel abundance through using subsampling, and derives the new subpixel abundance model by substituting the linear unmixing model. After adding sparsity and smoothness constraints to control the searching space of solutions, the subpixel abundance is obtained quickly. The reweighted 1-norm constraint is applied to the subpixel sparse abundance, and the weight is updated adaptively. Total variational (TV) regularization is used as a new constraint for a spatial priori of the subpixel abundance, and a multiplication iterative algorithm is used to search for the subpixel abundance. Finally, a winner-take-all strategy is used to determine the overall class categories. Experiments on two synthetic data sets show that the proposed method can improve the accuracy of subpixel mapping further.

Key words:hyperspectral image; subpixel mapping; subpixel abundance; re-weighted sparsity; total variational (TV) regularization; winner-take-all strategy

1 引言

在过去几年中,高光谱成像技术的迅速发展

使得光谱信息的来源逐步增加,高光谱图像包含了从可见光到近红外几百个连续波段的信息。但是由于传感器瞬时视场的限制,导致空间分辨率

* E-mail:gfb@hdu.edu.cn

收稿日期:2022-01-18 修订日期:2022-03-08

基金项目:国家自然科学基金(61375011)资助项目

相对较低,因此,混合像元普遍存在。而标准的硬分类算法^[1]并不适合解决混合像元问题。高光谱解混^[2]是通过估计每个混合像元中每个纯材料(端元)的丰度来量化混合像元的有效技术,可以定量探索不同地物类型的亚像素信息。然而,每个地物类别的精确空间定位仍然无法确定,图像的空间特征对位置检测起着极其重要的作用。为此,1997年ATKINSON^[3]首次提出亚像素定位技术,该技术旨在从低空间分辨率图像中以亚像素级重建空间细节,将像素按照一定的比例划分为若干个亚像素,并将亚像素分配给最合适的类标签。亚像素定位本质上是一种亚像素级分类技术,到目前已成功应用在土地覆盖制图^[4]、水流测绘^[5]、地质灾害检测等^[6]方面。

亚像素定位,在多数情况下,可以被视为高光谱解混的后续过程,用于解决混合像元问题。其主要基于空间相关性的假设,即认为空间位置相近的亚像素更可能属于同一类。经过20多年的发展,亚像素定位技术已经开发出了多种模型,例如像素交换模型^[7]、线性优化模型^[8]、Hopfield神经网络^[9](Hopfield neural network, HNN)、空间吸引模型^[10]、插值模型等^[11],除此之外,近些年来ZHONG等^[12]引入空间先验信息,将亚像素定位转化为具有唯一解的逆定问题,提出了一种基于最大后验概率(maximum a posteriori, MAP)亚像素定位模型。GE等^[13]根据不同地理对象的空间分布模式,将对象的几何特征分为面状、线状、点状,并采用分而治之方式进行处理。对于上述从较粗糙的高光谱图像获得较精细分类图的方法,通常采用两步,步骤一是通过高光谱解混技术获得一组丰度图,步骤二是以丰度图作为输入,采用亚像素定位技术获得最终定位结果。因此,亚像素定位结果强烈依赖于解混步骤,解混所带来的误差会传递给亚像素定位的计算。另一方面,高光谱图像最显著的特点是具有丰富的光谱信息,若以丰度图作为亚像素定位的输入,其光谱信息可能无法被充分利用。

基于上述问题,XU等^[14]提出了一种新的亚像素定位模型,即联合空间-光谱亚像素定位模型(spatial-spectral subpixel mapping model, SSSM),并首次提出了亚像素丰度的概念,该模型直接利用原始高光谱图像作为输入,通过亚像素丰度图将高光谱图像与最终的亚像素定位结果联系起来,并且同时考虑了空间信息以及光谱信息,相较于上述基于像素丰度图亚像素定位算法,获得了更加精细的定位结果。然而,该方法存在的不足是仅仅考虑了亚像素丰度的空间先验约束,而没

有考虑亚像素丰度的稀疏性,亚像素相较于像素,因为其空间分辨率更高,稀疏性更强,最终导致定位的精度还有待提高。针对于SSSM存在的问题,在SSSM方法基础上提出一种基于约束空间-光谱联合的亚像素定位方法(constraint spatial-spectral subpixel mapping, CSSSM),其中,亚像素丰度稀疏性采用重加权1范数^[15]作为约束以促进丰度结果的稀疏性,并且自适应更新权重;接着,采用各向异性全变分模型^[16](total variational, TV)作为空间先验项,以促进丰度的分段平滑性;然后,通过乘法迭代^[17]算法求解得到亚像素丰度图;最后采用赢者通吃^[12]的策略进行类别标签的确定。在两个数据集上进行测试,实验结果表明,在增加了稀疏性约束之后,亚像素定位结果精度在SSSM基础上得到了进一步提高。

2 CSSSM

2.1 线性解混模型

高光谱图像线性解混模型^[18]相较于非线性解混模型,有更加广泛的应用,假设 $\mathbf{Y} \in \mathbb{R}^{b \times n}$ 为原始高光谱图像,其中 b 为波段个数, n 为像素个数, $\mathbf{M} \in \mathbb{R}^{b \times p}$ 为端元光谱矩阵, p 为端元个数, $\mathbf{S} \in \mathbb{R}^{p \times n}$ 为像素丰度矩阵, $\mathbf{N} \in \mathbb{R}^{n \times n}$ 为噪声矩阵,高光谱图像线性解混模型定义如式(1):

$$\begin{aligned} \mathbf{Y} &= \mathbf{MS} + \mathbf{N}, \\ \text{s. t. : } &\mathbf{S} \geq 0, \mathbf{1}_p^T \mathbf{S} = \mathbf{1}_n^T, \end{aligned} \quad (1)$$

式中,约束条件为像素丰度非负性以及每个像素内端元丰度之和为1, $\mathbf{1}_p^T$ 表示1行 p 列全1向量, $\mathbf{1}_n^T$ 表示1行 n 列全1向量, $(\cdot)^T$ 表示矩阵转置。

2.2 亚像素丰度模型

文献[14]首次提出了亚像素丰度的概念,通过下采样将像素丰度与亚像素丰度联系起来,假设 $\mathbf{Z} \in \mathbb{R}^{w \times w}$ 为亚像素丰度矩阵,其中 $w = ns^2$ 为亚像素个数, s 为比例因子,表示将一个像素转换为 s^2 个亚像素,下采样矩阵 $\mathbf{D} \in \mathbb{R}^{w \times n}$ 定义如式(2):

$$\mathbf{D} = \frac{(\mathbf{I}_l \otimes \mathbf{1}_s^T)^T \otimes (\mathbf{I}_r \otimes \mathbf{1}_s^T)^T}{s^2}, \quad (2)$$

式中, l 与 r 分别为 \mathbf{Y} 的空间尺寸大小, $\mathbf{I}_l, \mathbf{I}_r$ 分别为维数为 l 和 r 的单位矩阵, \otimes 表示克罗内克积乘子。获得下采样矩阵 \mathbf{D} 后,得到像素丰度和亚像素丰度之间的显式映射关系,如式(3):

$$\mathbf{S} = \mathbf{ZD}. \quad (3)$$

通过将式(3)代入线性混合模型式(1)中,得到亚像素丰度求解模型,如式(4):

$$\begin{aligned} \mathbf{Y} &= \mathbf{MZD} + \mathbf{N} \\ \text{s. t. : } &\mathbf{Z} \geq 0, \mathbf{1}_p^T \mathbf{Z} = \mathbf{1}_w^T, \end{aligned} \quad (4)$$

式中,约束条件为亚像素丰度非负性约束以及和为1

约束, $\mathbf{1}_w^T$ 表示 1 行 w 列全 1 向量。

由于上述求解亚像素丰度目标函数是非凸的, 在求解过程中会出现大量极小值, 导致求解的不稳定性, 因此, 应该在上面模型中加入合理的约束, 从亚像素丰度矩阵列来看, 通常假设单个固定亚像素丰度是稀疏的, 从行来看, 通常假设一个固定端元的丰度是分段平滑的。

2.3 稀疏性约束

丰度的稀疏性指的是在一个混合像素内, 一般不会包含图像中的所有端元, 仅仅包含其中一种或者几种, 因此, 像素的丰度是稀疏的^[18]。相较于像素而言, 由于亚像素的空间分辨率比像素的空间分辨率高, 亚像素丰度的稀疏性表现更加显著, 针对稀疏性, 最佳选择是采用 L_0 范数进行约束, 但是 L_0 范数是 NP 难问题, 不易求解, 采用 L_1 范数替代 L_0 范数是一种常用方案, 但是在丰度和为 1 的约束条件下, L_1 范数不能有效促进稀疏性。文献[15] 提出了重加权 1 范数应用到像素丰度上可以有效解决此问题, 受此启发, 本文将重加权 1 范数应用到亚像素丰度上, 以增强其稀疏性, 从而得到目标函数为式(5):

$$\begin{aligned} & \min_{\mathbf{Z}} \frac{1}{2} \|\mathbf{Y} - \mathbf{M}\mathbf{Z}\mathbf{D}\|_F^2 + \lambda \|\mathbf{W} \cdot * \mathbf{Z}\|_1, \\ & \text{s. t. } \mathbf{Z} \geq 0, \mathbf{1}_p^T \mathbf{Z} = \mathbf{1}_w^T, \end{aligned} \quad (5)$$

式中, $\|\cdot\|_F^2$ 表示 Frobenius 范数的平方, $\|\cdot\|_1$ 表示 1 范数, λ 为控制稀疏度参数, $\cdot *$ 表示点乘, 对应位置元素相乘, \mathbf{W} 为加权系数矩阵, 其自适应更新规则如式(6):

$$\mathbf{W}_{i,j}^{k+1} = 1/(|\mathbf{Z}_{i,j}^k| + eps), \quad (6)$$

式中, $\mathbf{W}_{i,j}^{k+1}$ 表示第 $k+1$ 次迭代中亚像素 (i,j) 处丰度加权矩阵, $\mathbf{Z}_{i,j}^k$ 表示第 k 次迭代在亚像素 (i,j) 处的丰度矩阵, eps 是一个很小的正数, 避免分母为 0。

2.4 空间先验约束

在空间先验方面, 由于 TV 能够有效保留边缘信息并促进分段平滑, RUDIN 等^[19]首先提出了 TV 模型来解决灰度图像去噪问题, 例如相对于尺寸为 $m \times g$ 的灰度图像 \mathbf{z} , 各向异性 TV 定义如式(7):

$$\begin{aligned} \|\mathbf{z}\|_{TV} = & \sum_{i=1}^{m-1} \sum_{j=1}^{g-1} \{ |\mathbf{z}_{i,j} - \mathbf{z}_{i+1,j}| + \\ & |\mathbf{z}_{i,j} - \mathbf{z}_{1,j+1}| \} + \sum_{i=1}^{m-1} |\mathbf{z}_{i,n} - \mathbf{z}_{i+1,n}| + \\ & \sum_{j=1}^{g-1} |\mathbf{z}_{m,j} - \mathbf{z}_{m,j+1}|, \end{aligned} \quad (7)$$

式中, $\mathbf{z}_{i,j}$ 表示像素 (i,j) 处的灰度值, 定义完全变分正则化之后, 将其应用到亚像素丰度之中, 将每个类别的亚像素丰度图都视为一个单独的灰度图像, 然后, 逐类别计算 TV 然后再全变分进行叠加, 得到式(8):

$$\|\mathbf{Z}\|_{TV} = \sum_{t=1}^p \|\Psi \mathbf{Z}^t\|_{TV}, \quad (8)$$

式中, \mathbf{Z}^t 表示亚像素丰度矩阵第 t 行元素, Ψ 是将 \mathbf{Z} 第 t 行元素 \mathbf{Z}^t 重塑成 $ls \times rs$ 大小算子, ls, rs 分别为高空间分辨率图像空间尺寸大小。

2.5 优化求解

通过对上述的总结, 得到本文提出方法目标函数, 如式(9):

$$\begin{aligned} J(\mathbf{Z}) = & \min_{\mathbf{Z}} \frac{1}{2} \|\mathbf{Y} - \mathbf{M}\mathbf{Z}\mathbf{D}\|_F^2 + \\ & \lambda \|\mathbf{W} \cdot * \mathbf{Z}\|_1 + \sigma \|\mathbf{Z}\|_{TV}, \\ & \text{s. t. } \mathbf{Z} \geq 0, \mathbf{1}_p^T \mathbf{Z} = \mathbf{1}_w^T, \end{aligned} \quad (9)$$

式中, σ 是 TV 正则化参数, 控制分段平滑性, 显然上述模型针对于 \mathbf{Z} 是非凸的。为了有效解决这个问题, 引入辅助变量 \mathbf{L} , 将 \mathbf{Z} 作为 \mathbf{L} 的噪声版本, 将上述模型转换成以下等价问题, 得到优化目标函数为式(10):

$$\begin{aligned} J(\mathbf{Z}, \mathbf{L}) = & \min_{\mathbf{Z}} \frac{1}{2} \|\mathbf{Y} - \mathbf{M}\mathbf{Z}\mathbf{D}\|_F^2 + \\ & \lambda \|\mathbf{W} \cdot * \mathbf{Z}\|_1 + \sigma \|\mathbf{Z}\|_{TV}, \\ & \text{s. t. } \mathbf{Z} \geq 0, \mathbf{1}_p^T \mathbf{Z} = \mathbf{1}_w^T, \mathbf{L} = \mathbf{Z}. \end{aligned} \quad (10)$$

然后将约束 $\mathbf{L} = \mathbf{Z}$ 吸收到式(10), 得到下面替代松弛问题, 即最终的目标函数式(11):

$$\begin{aligned} J(\mathbf{Z}, \mathbf{L}) = & \min_{\mathbf{Z}, \mathbf{L}} \frac{1}{2} \|\mathbf{Y} - \mathbf{M}\mathbf{Z}\mathbf{D}\|_F^2 + \\ & \lambda \|\mathbf{W} \cdot * \mathbf{Z}\|_1 + \frac{\mu}{2} \|\mathbf{L} - \mathbf{Z}\|_F^2 + \\ & \sigma \|\mathbf{L}\|_{TV}, \\ & \text{s. t. } \mathbf{Z} \geq 0, \mathbf{1}_p^T \mathbf{Z} = \mathbf{1}_w^T, \end{aligned} \quad (11)$$

式中, 参数 μ 是惩罚系数, 控制 \mathbf{L} 与 \mathbf{Z} 的相似性, 采用乘法迭代方式解决问题式(11), 将目标函数式(11)的优化分为以下两个子问题, 如式(12):

$$\begin{aligned} \mathbf{Z} = & \arg \min_{\mathbf{Z}} J(\mathbf{Z}, \mathbf{L}), \\ \mathbf{L} = & \arg \min_{\mathbf{L}} J(\mathbf{Z}, \mathbf{L}). \end{aligned} \quad (12)$$

根据式(12), 求解可以分为两个步骤, 步骤一, 更新亚像素丰度 \mathbf{Z} , 步骤二, 丰度的去噪即更新 \mathbf{L} , 在每个步骤中, 根据其他变量的当前值有条件地更新另一个变量, 以便目标函数的值迭代减小, 以下推导更新规则。

对 \mathbf{Z} 的更新, 将亚像素丰度非负性约束以及亚像素丰度和为 1 约束添加到式(12), 得到 \mathbf{Z} 的目标函数为式(13):

$$\begin{aligned} J(\mathbf{Z}, \mathbf{L}) = & \min_{\mathbf{Z}} \frac{1}{2} \|\mathbf{Y} - \mathbf{M}\mathbf{Z}\mathbf{D}\|_F^2 + \\ & \lambda \|\mathbf{W} \cdot * \mathbf{Z}\|_1 + \frac{\mu}{2} \|\mathbf{L} - \mathbf{Z}\|_F^2 + \\ & \frac{\tau}{2} \|\mathbf{1}_p^T \mathbf{Z} - \mathbf{1}_w^T\|_2^2 + \text{Tr}(\mathbf{I}\mathbf{Z}), \end{aligned} \quad (13)$$

式中, τ 参数控制亚像素丰度和为 1 约束, $\|\cdot\|_2^2$ 为 2 范数平方, $\text{Tr}(\mathbf{I}\mathbf{Z})$ 为非负性约束项, $\boldsymbol{\Gamma} \in \mathcal{R}^{w \times p}$ 为拉格朗日乘子。通过上式(13)对 \mathbf{Z} 求偏导, 然后根据 KKT 条件, 可以得到方程如式(14)、(15):

$$\nabla_{\mathbf{Z}} J(\mathbf{Z}) = \mathbf{M}^T (\mathbf{M}\mathbf{Z}\mathbf{D} - \mathbf{Y})\mathbf{D}^T + \lambda \mathbf{W} +$$

$$\mu(\mathbf{Z} - \mathbf{L}) + \tau \mathbf{1}_p (\mathbf{1}_p^T \mathbf{Z} - \mathbf{1}_w^T) + \boldsymbol{\Gamma} = 0, \quad (14)$$

$$\mathbf{Z} \cdot * \boldsymbol{\Gamma} = 0, \quad (15)$$

由 \mathbf{Z} 点乘式(14), 然后将式(15)代入, 得到 \mathbf{Z} 的更新方程, 如式(16):

$$\begin{aligned} \mathbf{Z}^{k+1} = & \mathbf{Z}^k \cdot * (\mathbf{M}^T \mathbf{Y} \mathbf{D}^T + \mu \mathbf{L}^k + \\ & \tau \mathbf{1}_p \mathbf{1}_w^T / (\mathbf{M}^T \mathbf{M} \mathbf{Z}^k \mathbf{D} \mathbf{D}^T + \lambda \mathbf{W}^{k+1} + \\ & \mu \mathbf{Z}^k + \tau \mathbf{1}_p \mathbf{1}_p^T \mathbf{Z}^k), \end{aligned} \quad (16)$$

式中, $\cdot /$ 表示点除, 对应位置元素相除, \mathbf{Z}^k 表示第 k 次迭代得到的亚像素丰度矩阵, \mathbf{Z}^{k+1} 表示第 $k+1$ 次迭代得到的亚像素丰度矩阵, \mathbf{W}^{k+1} 更新规则为式(6)所示。

对 \mathbf{L} 的更新, 采用 TV 正则化对式(16)得到的丰度图进行去噪, 同时促进分段平滑, 得到的目标子函数为:

$$J(\mathbf{L}) = \frac{\mu}{2} \|\mathbf{L} - \mathbf{Z}\|_F^2 + \sigma \|\mathbf{L}\|_{\text{TV}}. \quad (17)$$

上式等价于求所有端元的亚像素丰度去噪之和, 设端元个数为 p , 即得到式(18):

$$J(\mathbf{L}) = \min_{\mathbf{L}} \sum_{t=1}^p \left(\frac{\mu}{2} (\Psi \mathbf{L}^t - \Psi \mathbf{Z}^t)^2 + \right. \\ \left. \sigma \|\Psi \mathbf{L}^t\|_{\text{TV}} \right), \quad (18)$$

式中, \mathbf{L}^t 、 \mathbf{Z}^t 表示矩阵 \mathbf{L} 与矩阵 \mathbf{Z} 的第 t 行元素, 采用文献[16]中提出的快速梯度投影算法(fast gradient projection, FGP)进行更新求解。

2.6 类别确定

通过上述迭代更新之后, 得到亚像素丰度图, 最终进行类别的确定, 因为没有经过像素解混这一步骤, 因此每个类别亚像素个数并不确定, 采用赢者通吃策略, 对每个亚像素进行丰度的比较, 将亚像素类别设定为丰度值最大的, 即:

$$O_i = q \text{ if } \mathbf{Z}_{q,i} = \max\{\mathbf{Z}_{h,i} \mid h \in (1, p)\}, \quad (19)$$

式中, O_i 表示亚像素 i 所属于类别, $\mathbf{Z}_{h,i}$ 表示属于类别 h 在亚像素 i 处的丰度值, $\mathbf{Z}_{q,i}$ 表示在亚像素 i 处最大的亚像素丰度值, 将此类别信息赋值给 q 。

2.7 算法框架

本文提出的亚像素定位算法整体框架如图 1 所示, 主要策略是分别迭代 \mathbf{Z} 、 \mathbf{L} 以及权重矩阵 \mathbf{W} 的自适应更新, 达到迭代次数停止迭代。 \mathbf{Z} 、 \mathbf{L} 、 \mathbf{W} 初始设置以及参数 λ 、 σ 、 μ 、 τ 设置至关重要, 首先将原始高光谱矩阵进行归一化, 以便应用到不同灰度级。针对于 \mathbf{Z} 的初始化, 采用的是保证每个类别亚像素丰度在 0—1 之间且和为 1 条件下进行随机初始化; \mathbf{W}

初始化为 $\mathbf{W}_{i,j}^k = 1/(|\mathbf{Z}_{i,j}^k| + eps)$, 辅助变量 \mathbf{L} 的初始设置为 $\mathbf{L} = \mathbf{Z}$; 参数 λ 是控制稀疏性, σ 控制亚像素丰度图分段平滑, 文中采用文献[20]中策略将 λ 、 σ 分别从 10^{-6} — 10^{-1} 以 5 倍的速率进行取值, 参数 μ 是控制 $\mathbf{L} = \mathbf{Z}$ 的惩罚系数, τ 是为了控制亚像素丰度和为 1, 将 μ 、 τ 分别从 10^{-3} — 10^2 之间以 5 倍速率增加遍历取值, 将在后续实验中确定最佳参数。

迭代终止准则一般情况下有两个, 第一个标准是设置预定义的错误容限, 一旦错误连续 10 次在公差范围内, 迭代就会停止; 另一个标准是达到 3 000 的最大迭代次数设置, 在本次实验中采用的是最大迭代次数来停止迭代。

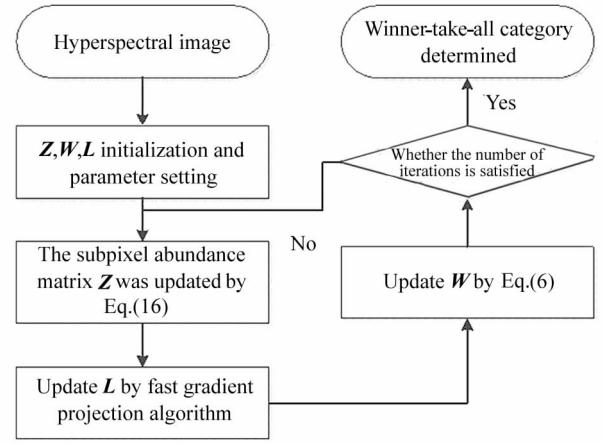


图 1 算法框架

Fig. 1 Algorithm diagram of the proposed method

3 实验与分析

为了测试本文提出方法的性能效果, 选取了径向基插值(radial basis function, RBF)^[10]、HNN、以及 SSSM 3 种方法进行对比, 其中, RBF 仅基于丰度图, 并且混合像素中不同类别的亚像素数量与丰度成正比, 严格满足丰度约束; HNN 通过丰度图获得亚像素结果的最小能量函数, 最终亚像素定位结果不需要严格满足丰度约束; SSSM 直接以原始高光谱图像作为输入, 并且采用 TV 作为空间先验约束。为了避免由于传感器点扩散函数、大气和几何效应等引起的真实图像固有的不确定性, 而且合成图像可以有效避免低分辨率图像和高分辨率图像之间的配准误差, 本次实验选用两个合成数据集来验证所提方法的有效性, 分别为 Jasper Ridge 高光谱数据集与 Washington 高光谱数据集。对于数据集的处理, 首先采用均值滤波器对原始高分辨率图像进行降质获得低分辨率图像, 然后利用解混以及亚像素定位技术对低分辨率图像进行亚像素定位。RBF 与

HNN 两种亚像素定位方法以丰度图作为其算法输入,本次实验采用全约束最小二乘法(fully constrained least squares, FCLS)^[21]获得丰度图,因为该方法满足丰度和为 1 和非负性约束。对高空间分辨率图像,通过遥感图像分类算法得到的结果作为参考图像,用于评估不同的亚像素定位方法性能。最终,使用平均精度(average accuracy, AA)、总体精度(overall accuracy, OA)、生产者精度(producer accuracy),以及 Kappa 系数(Kappa coefficient, KC)对其结果进行评估比较,其中,AA 表示每个类别定位准确度的均值,OA 表示正确定位亚像素个数与亚像素

总数的比值,生产者精度表示每个类别的分类准确度,KC 用于定位一致性检验。

本文所提的亚像素定位算法中,4 个参数需要被考虑,分别为惩罚系数 μ 、亚像素丰度和为 1 约束参数 τ 、稀疏性约束参数 λ 、空间约束参数 σ ,以上参数对结果的优化有很大影响,或者说不同数据集敏感,参数的选择对结果验证至关重要。为了评估本文所提算法中不同参数对最终亚像素定位结果精度的影响,利用所有的实验数据集获得了不同参数所对应的精度,如图 2、图 3 所示。

从图中可知,不同数据集参数的选择对精度的

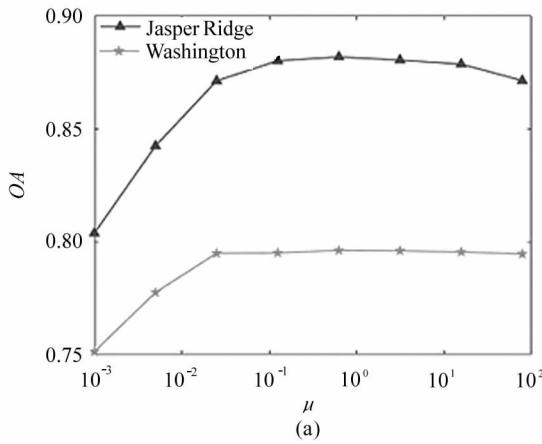


图 2 不同数据参数集中(a) μ 和(b) τ 对亚像素定位精度的影响

Fig. 2 Effects on subpixel mapping accuracy with parameter (a) μ and (b) τ in different datasets

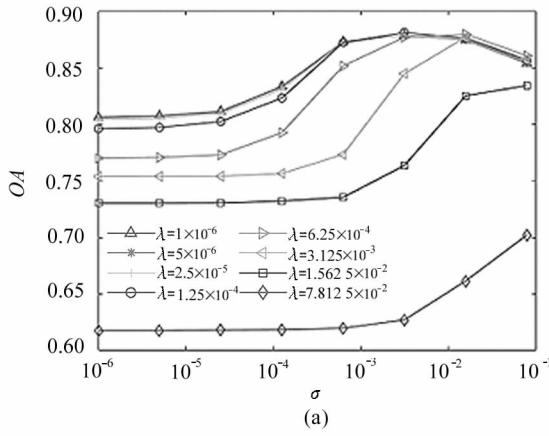
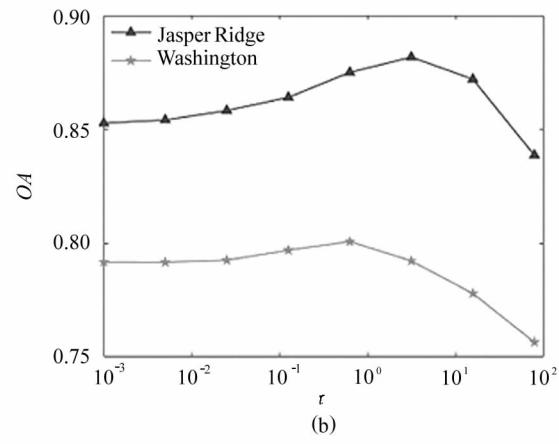
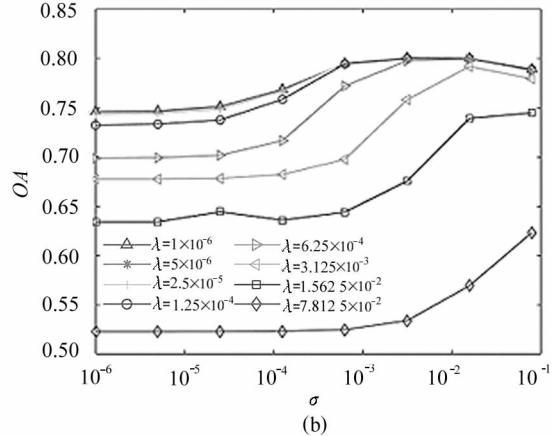


图 3 不同数据集(a) Jasper Ridge 和(b) Washington 中不同正则化参数 λ 、 σ 对亚像素定位精度的影响

Fig. 3 Effects on subpixel mapping accuracy with different regularization parameter λ and σ in different datasets of (a) Jasper Ridge and (b) Washington



影响整体趋势保持一致,由图 2(a)可得,随着 μ 的增加,精度显著提升,超过某个阈值后,逐渐平缓,最后再缓慢降低;由图 2(b)可得,随着 τ 增加,精度缓慢增加,当超过某个阈值之后,再急剧下降;一般而言,针对不同的数据集,可以选择 μ 与 τ 在 1 附近取值,

可以得到较好的效果。对于两个正则化参数 λ 、 σ ,图 3 显示了不同数据集在不同正则化参数下的精度,可以得知,本文中正则化参数对不同的数据集影响的趋势是一致的,并且从图中可以得知,随着 λ 增加,精度逐渐降低,随着 σ 增加,精度先增加,然后再慢慢降

低,为了不失一般性,可以选择 λ, σ 分别在 10^{-4} 与 10^{-2} 附近取值。

使用的第一个高光谱数据集是 Jasper Ridge, Jasper Ridge 是一个流行的高光谱数据集。原始数据有 512×614 个像素,包含 224 个波段,光谱分辨率达到 9.46 nm 。由于这类高光谱图像过于复杂,无法得到地面真实情况,因此截取局部区域,大小为 99×99 个像素,并且去除噪声波段后留下 198 个波段信息,高分辨率灰度图如图 4(a)所示,其中所含地物类型主要分为 4 类,分别为道路、土壤、水和树,使用 3×3 均值滤波器对高分辨率图像进行降质,得到低分辨率输入图像,如图 4(b)所示。对高空间分辨率图像在 ENVI 软件上借助支持向量机(support vector machine, SVM)分类算法得到参考分类图,如图 5(a)所示。

RBF、HNN、SSSM 以及本文所提亚像素定位方法得到定位结果分别为图 5(b)—(e)所示,从图 5(a)与 5(b)—(e)比较可知,RBF 不能提供令人满意的视觉效果,因为存在大量噪声点,并且图像的很多亚像素被分配到错误的位置;HNN 取得了相对较好的结果,但是道路错分较多;SSSM 与 CSSSM 相较于 HNN 取得更平滑、更好的视觉效果,而 CSSSM 与 SSSM 相比,在细节方面有一定的改善,例如图像中的道路以及土壤。

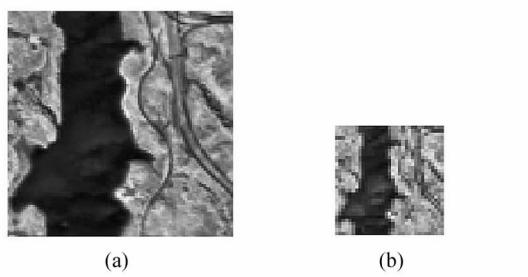


图 4 Jasper Ridge 数据集中(a)高分辨率与
(b)低分辨率灰度图

Fig. 4 (a) High and (b) low resolution grayscale images in Jasper Ridge dataset

为了更详细验证结果,得到表 1 的混淆矩阵,上述算法的定量比较如表 2 所示,在每种评判标准中,最好的结果用加粗黑体表示。从表 2 可以得出结论,本文提出的 CSSSM 方法比其他方法有更好的性

能,提高了精度,例如 RBF、HNN、SSSM 的 OA 分别为 82.32%、86.60%、87.38%,而本文提出方法精度是 88.32%。对于 KC, RBF、HNN、SSSM 精度分别为 0.7496、0.8095、0.8231,而本文提出方法为 0.8332。除此之外,就每个类别的分类准确度以及平均分类准确度而言,本文所提算法对土壤和道路的分类准确度显著提高,相较于 SSSM,除了树的精度有所下降,其余类别精度均有不同程度的提高。因此可以得出结论,虽然 SSSM 相较于 CSSSM 具有可比性的视觉效果,但是本文所提的方法有明显的定量改进,对于该数据集,该方法明显优于其他方法。

第二个图像是 Washington 高光谱数据集,原始图像数据大小是 1208×307 ,包含 191 个光谱波段,截取其中 300×195 个像素用于此次实验。原始高分辨率图像灰度图如图 6(a)所示,针对此图像首先使用 3×3 均值滤波器进行下采样,得到低分辨率图像,其灰度图如图 6(b)所示。针对高分辨率图像,采用 SVM 分类算法得到参考分类图,如图 7(a)所示,将其作为地面真值,该图像地物主要分为 4 个类别,分别为草、水、道路以及树,图 7(b)—(e)所示分别为 RBF、HNN、SSSM 以及本文中所提方法 CSSSM 的亚像素定位结果图,实验中,比例因子设置为 3。

如图 7 所示,与 RBF、HNN 结果相比,所提出的方法由于成功利用了原始高光谱图像的光谱和空间信息,得到了比 RBF、HNN 更好的结果,而相较于 SSSM,因为在其基础上考虑了亚像素丰度稀疏性约束,在细节方面得到的结果比 SSSM 好,例如左上角关于道路(白色)的定位。

表 3 显示了本文所提方法得到的混淆矩阵,表 4 显示了 RBF、HNN、SSSM 以及 CSSSM 方法定量比较。从表 4 可知,除了水在单个类别精度上有所下降,其余定量指标均有一定的提升,道路的生产者精度提升最大,相较于 SSSM,提升了 0.083 而在 OA 指标上,RBF、HNN 以及 SSSM 分别为 71.44%、77.50%、78.50%,而 CSSSM 为 79.95%,相较于 SSSM,提升了 1.45%;在 KC 上,RBF、HNN、SSSM 分别为 0.5967、0.6789、0.6938,而 CSSSM 为 0.7106,相较于 SSSM,提升了 0.0168。因此可以得出结论,CSSSM 在性能上能够获得更好的结果,其原因为:相较于传统的方法,RBF 与 CNN, CSSSM 成功应用了图像的光谱信息,并且减少了光谱分解

带来的误差,相较于 SSSM 提升的原因是添加了本文所提的稀疏性约束。

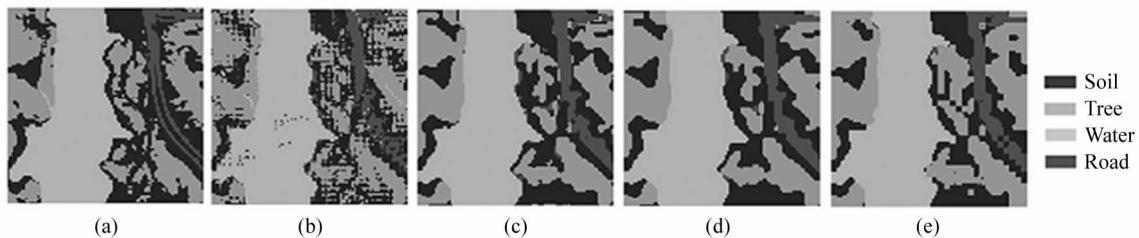


图 5 Jasper Ridge 数据集亚像素定位结果:(a) 参考分类图; (b) RBF; (c) HNN; (d) SSSM; (e) CSSSM

Fig. 5 Subpixelmapping results of the Jasper Ridge dataset;(a)Reference classification map;
(b) RBF; (c) HNN; (d) SSSM; (e) CSSSM

表 1 Jasper Ridge 数据集混淆矩阵

Tab. 1 Confusion matrix of Jasper Ridge dataset

	Predicted classes			
	Water	Soil	Tree	Road
Water	12	171	2 718	0
Soil	3 353	12	321	1
Tree	46	2 162	46	242
Road	18	45	18	423

表 2 不同算法对于 Jasper Ridge 数据集亚像素定位精度

Tab. 2 Subpixel mapping accuracies of Jasper Ridge dataset with different methods

Method	Producer accuracy				AA/%	OA/%	KC
	Water	Soil	Tree	Road			
RBF	0.970 4	0.814 7	0.774 1	0.427 6	74.67	82.32	0.749 6
HNN	0.982 2	0.824 5	0.856 1	0.539 5	80.06	86.60	0.809 5
SSSM	0.974 7	0.858 5	0.834 5	0.605 5	81.83	87.38	0.820 1
CSSSM	0.977 8	0.904 6	0.819 7	0.635 1	83.43	88.32	0.833 2

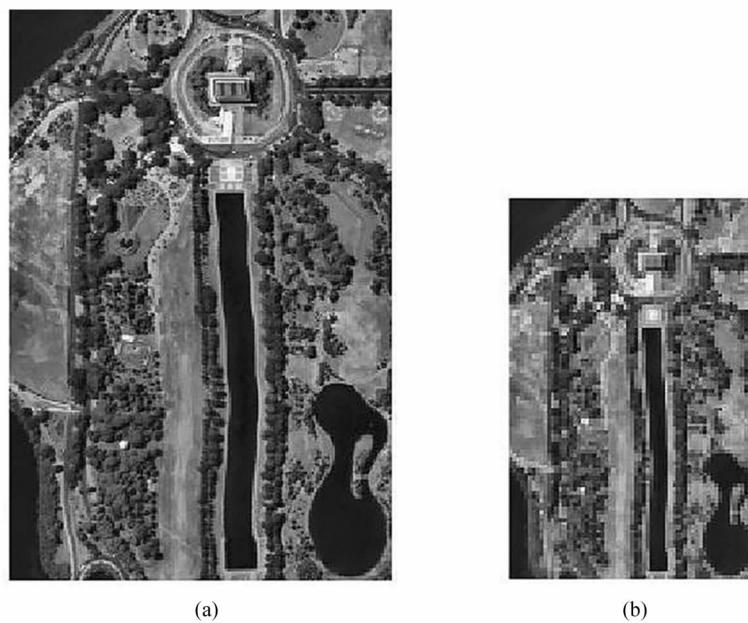


图 6 Washington 数据集中(a)高分辨率与(b)低分辨率灰度图

Fig. 6 (a) High and (b) low resolution grayscale images in Washington dataset

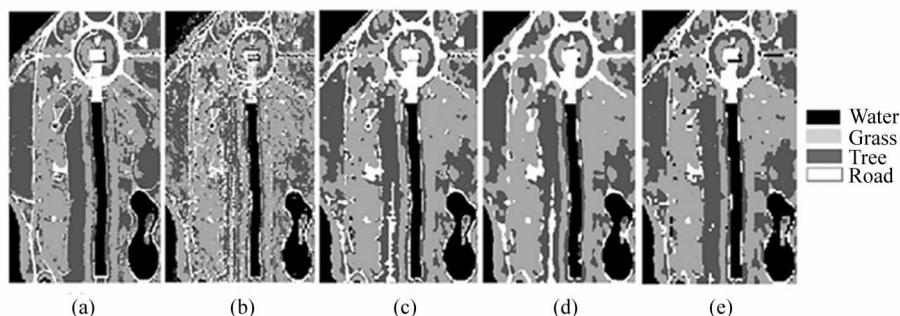


图 7 Washington 数据集亚像素定位结果:(a) 参考分类图; (b) RBF; (c) HNN; (d) SSSM; (e) CSSSM

Fig. 7 Subpixel mapping results for the Washington dataset: (a) Reference classification map; (c) HNN; (d) SSSM; (e) CSSSM

表 3 Washington 数据集混淆矩阵

Tab. 3 Confusion matrix of Washington dataset

	Predicted classes			
	Water	Grass	Tree	Road
Water	7 662	121	239	243
Grass	85	15 824	4 077	1 134
Tree	314	2 256	18 727	491
Road	620	1 356	795	4 556

表 4 不同算法针对 Washington 数据集的亚像素定位精度

Tab. 4 Subpixel mapping accuracies of Washington dataset with different methods

Method	Producer accuracy				AA/%	OA/%	KC
	Water	Grass	Tree	Road			
RBF	0.8797	0.7497	0.7507	0.4424	70.56	71.44	0.5967
HNN	0.9181	0.7995	0.7755	0.5884	77.04	77.50	0.6789
SSSM	0.9466	0.8011	0.7770	0.6260	78.77	78.63	0.6938
CSSSM	0.8826	0.8091	0.7856	0.7092	79.66	79.95	0.7106

4 结 论

文中针对高光谱图像空间分辨率低,混合像元普遍存在问题,提出了一种基于 CSSSM 方法,该方法同时结合了原始图像的光谱信息和空间相关性,以提供精确的亚像素映射结果。因为传统的 1 范数在满足像素丰度和为 1 的基础上无法进一步促进稀疏性,本文所提方法的一个主要贡献是在对亚像素丰度稀疏性引入重加权 1 范数到亚像素丰度求解模型中,约束其稀疏性,并且根据丰度自适应更新权重,在此基础上,采用迭代方式求解亚像素丰度,最后再使用赢家通吃的策略进行类别确定。在两个经典的数据集上进行结果的验证,实验结果表明,与传统的亚像素定位方法以及改进的方法相比,本方法不仅在可视化方面得到更加可观的结果,而且在定量比较中也能够进一步提高亚像素定位的准确度,因此本方法是一种有效的亚像素定位方法。但是,

参数选择仍然是一个问题,在接下来的工作将把重心放在参数的自适应选择上。

参 考 文 献:

- [1] DING F C, GUO B F, JIA X X, et al. Feature extraction of hyperspectral image based on generation countermeasure networks[J]. Journal of Optoelectronics · Laser 2021, 32(8): 852-861.
丁繁昌, 郭宝峰, 贾响响, 等. 基于生成对抗网络的高光谱图像特征提取[J]. 光电子·激光, 2021, 32(8): 852-861.
- [2] PLAZA A, DU Q, BIOUCAS-DIAS J M, et al. Foreword to the special issue on spectral unmixing of remotely sensed data[J]. IEEE Transactions on Geoscience & Remote Sensing, 2011, 49(11): 4103-4110.
- [3] ATKINSON P M. Mapping subpixel boundaries from remotely sensed images[M]//KEMP Z. Innovations in GIS IV. London: CRC Press, 1997, 12: 166-180.

- [4] THORNTON M W, ATKINSON P M, HOLLAND D A. A linearised pixel-swapping method for mapping rural linear land cover features from fine spatial resolution remotely sensed imagery[J]. *Computers & Geosciences*, 2007, 33(10):1261-1272.
- [5] LV Y, GAO W, YANG C, et al. A novel spatial-spectral extraction method for subpixel surface water[J]. *International Journal of Remote Sensing*, 2020, 41(7): 2477-2499.
- [6] LING F, DU Y, ZHANG Y, et al. Burned-area mapping at the subpixel scale with modis images [J]. *IEEE Geoscience & Remote Sensing Letters*, 2015, 12(9): 1963-1967.
- [7] WU S, CHEN Z, REN J, et al. An improved subpixel mapping algorithm based on a combination of the spatial attraction and pixel swapping models for multispectral remote sensing imagery [J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(7):1070-1074.
- [8] CHEN Y, GE Y, CHEN Y, et al. Subpixel land cover mapping using multiscale spatial dependence[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2018, 56(9): 5097-5106.
- [9] WANG Q, SHI W, ATKINSON P M, et al. Land cover change detection at subpixel resolution with a Hopfield neural network[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(3):1339-1352.
- [10] WANG P, WU Y, LEUNG H. Subpixel land cover mapping based on a new spatial attraction model with spatial-spectral information[J]. *International Journal of Remote Sensing*, 2019, 40(15-16):6444-6463.
- [11] WANG Q, SHI W, ATKINSON P M. Sub-pixel mapping of remote sensing images based on radial basis function interpolation [J]. *ISPRS Journal of Photogrammetry & Remote Sensing*, 2014, 92(92):1-15.
- [12] ZHONG Y, WU Y, XU X, et al. An adaptive subpixel mapping method based on map model and class determination strategy for hyperspectral remote sensing imagery [J]. *IEEE Transactionson Geoscience and Remote Sensing*, 2015, 53(3):1411-1426.
- [13] GE Y, CHEN Y H, STEI N A, et al. Enhanced subpixel mapping with spatial distribution patterns of geographical objects[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2016, 54(4):2356-2370.
- [14] XU X, TONG X H, ANTONIO P, et al. A new spectral-spatial sub-pixel mapping model for remotely sensed hyperspectral imagery[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2018, 56(11):6763-6778.
- [15] CANDÈS E, WAKIN M B, BOYD S P. Enhancing sparsity by reweighted L1 minimization[J]. *Journal of Fourier Analysis & Applications*, 2007, 14(5):877-905.
- [16] BECK A, TEBOULLE M. Fast gradient-based algorithms for constrained total variation image denoisingand deblurring problems[J]. *IEEE Transactions on Image Processing*, 2009, 18(11):2419-2434.
- [17] HE W, ZHANG H Y, ZHANG L P. Total variation regularized reweighted sparse nonnegative matrix factorization for hyperspectral unmixing[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2017, 55(7):3909-3921.
- [18] HUANG R S. Research on unmixing methods based on nonnegative matrix factorization for hyperspectral remote sensing[D]. Hangzhou: Zhejiang University, 2020:14-28.
黄日胜. 基于非负矩阵分解的高光谱遥感图像解混方法研究[D]. 杭州:浙江大学, 2020:14-28.
- [19] RUDIN L. Nonlinear total variation based noise removal algorithms[J]. *Physica D: Nonlinear Phenomena*, 1992, 60(1-4):259-268.
- [20] XU X, TONG X H, ANTONIO P, et al. Joint sparse sub-pixel mapping model with endmember variability for remotely sensed imagery[J]. *Remote Sensing*, 2016, 9(1): 1-20.
- [21] HEYLEN R, BURAZEROVIC D, SCHEUNDERS P. Fully constrained least squares spectral unmixing by simplex projection[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2011, 49(11):4112-4122.

作者简介:

郭宝峰 (1973—),男,教授,博士,博士生导师,主要从事高光谱图像处理、模式识别信号处理方面的研究。