

文章编号 1004-924X(2024)22-3348-18

用于高光谱图像解混的空谱重加权稀疏多层非负矩阵分解

唐继明¹, 保文星^{1*}, 雷冰冰^{1*}, 冯伟², 屈克文¹

(1. 北方民族大学 计算机科学与工程学院, 宁夏 银川 750021;

2. 西安电子科技大学 电子工程学院, 陕西 西安 710071)

摘要:针对多层非负矩阵分解不能充分利用高光谱遥感图像的空间-光谱特征,以及高光谱图像中普遍存在的噪声问题,本文提出一种新的空间-光谱重加权的稀疏多层非负矩阵分解的解混算法。首先,采用子空间聚类算法构建高光谱图像的空间特征空间权重。其次,使用超像素分割算法对高光谱图像进行超像素分割,并计算超像素之间的相似度,使用KMEANS++算法对超像素进行聚类,接着在超像素内部计算像素级相似度,以此构建出光谱权重。将空间权重和光谱权重融合,融合之后的空间-光谱权重用于表征高光谱图像的空间-光谱信息。然后,使用SUnSAL算法计算稀疏降噪权重,可以有效降低噪声对解混性能的影响。最后,通过 L_1 范数对模型的端元和丰度进行约束,以提升模型的解混性能。与五种解混算法的实验结果进行对比,所提算法在合成数据集上计算所得的平均光谱角距离和均方根误差均为最优,在Jasper Ridge和Cuprite两个真实数据集上也取得良好的解混结果。所提算法在各个数据集上的端元估计误差降低1.49%~4.68%,丰度估计误差降低1.83%~4.18%。

关键词:高光谱图像解混;多层非负矩阵分解;空间-光谱权重;降噪;稀疏约束

中图分类号:TP394.1;TH691.9 **文献标识码:**A **doi:**10.37188/OPE.20243222.3348

Spatial-spectral reweighted sparse multi-layer nonnegative matrix factorization for hyperspectral image unmixing

TANG Jiming¹, BAO Wenxing^{1*}, LEI Bingbing^{1*}, FENG Wei², QU Kewen¹

(1. School of Computer Science and Engineering, North Minzu University, Yinchuan 750021, China;

2. School of Electronic Engineering, Xidian University, Xi'an 710071, China)

* Corresponding author, E-mail: bwx71@163.com; x_generation@126.com

Abstract: Multilayer non-negative matrix factorization (MLNMF) can not fully use the spatial-spectral features of hyperspectral remote sensing images, and the ubiquitous noise in hyperspectral images. To solve the problem, this paper proposed a new spatial-spectral reweighted sparse MNMF unmixing algorithm. Firstly, the subspace clustering algorithm was used to construct spatial weights according to the spatial characteristics of hyperspectral images. Secondly, the superpixel segmentation algorithm was used to segment the hyperspectral image, and the similarity between superpixels was calculated. The

收稿日期:2024-06-11;修订日期:2024-08-08.

基金项目:国家自然科学基金青年基金(No. 62201438);宁夏自然科学基金重点项目(No. 2024AAC02035);国家民委创新团队资助项目

KMEANS++ algorithm was used to cluster the superpixels, and then the pixel-level similarity was calculated in the superpixel to construct the spectral weight. The spatial weight and spectral weight were fused, and the fused spatial-spectral weight was used to characterize the spatial-spectral information of the hyperspectral image. Then, the SUNSAL algorithm was used to calculate the sparse noise reduction weight, which can effectively reduce the influence of noise on the unmixing performance. Finally, the norm was used to constrain the endmembers and abundance of the model to improve the unmixing performance of the model. Compared with the experimental results of five unmixing algorithms, the mean Spectral Angle Distance and Root Mean Square Error of the proposed algorithm on the synthetic dataset were optimal. It also achieves good unmixing results on two real datasets Jasper Ridge and Cuprite. The endmember estimation error of the proposed algorithm is reduced by 1.49% to 4.68%, and the abundance estimation error is reduced by 1.83% to 4.18% on each dataset.

Key words: hyperspectral unmixing; multilevel nonnegative matrix factorization; spatial-spectral weight; noise reduction; sparsity constraint

1 引言

高光谱图像(Hyperspectral Image, HSI)综合反映物质辐射信息的光谱信息和物质在二维空间的图像信息,因而在获取空间地理信息方面具有很大的潜力^[1]。由于其中含有丰富的光谱信息,高光谱图像在众多领域中均有应用,包括农业和军事防御^[2],地表矿物学测绘^[4]以及药品制造工业^[5]。但是由于较低的空间分辨率和复杂多变的成像条件,高光谱图像中会不可避免地出现混合像素^[6],这将在很大程度上增加高光谱图像分析的难度。除了光谱混合效应之外,还有其他干扰因素会显著影响高光谱数据的分析,比如大气干扰和多重散射效应^[8]。为了解决这种问题,通过高光谱图像解混可以将混合像素分解为端元的集合以及与端元对应的丰度。该过程主要包含两个关键步骤:端元提取和丰度估计。

为了处理高光谱图像的解混任务,众多研究者从几何、稀疏回归、深度学习和统计四个方面提出各种解混算法。

几何类算法用于解决线性模型,前提是假设端元是最小体积单纯形的顶点,或者是数据集凸包中最大体积单纯形的顶点。该类算法中的经典方法包括像素纯度指数(Pixel Purity Index, PPI)^[9], N-FINDER^[10]和误差迭代分析(Iterative Error Analysis, IEA)^[11]等方法。基于几何的解混算法寻求一个混合矩阵,最小化由其列定义的单纯形的体积,如最小体积封闭单纯形(Mini-

mum Volume Enclosing Simplex, MVSA)^[12]和通过变量分离和增广拉格朗日(Simplex Identification via Variable Splitting and Augmented Lagrangian, SISAL)^[13]的单纯形识别。然而,由于该类算法都是基于纯像素假设,即假设每个端元都有至少一个纯像素,但是因为纯光谱特征不可用,很难从高度混合的数据中提取端元。因此,该类算法对丰度的估计精度很大程度上取决于端元提取的准确性。除此之外,在处理高度混合的高光谱图像数据时,纯像素假设很难得到保证。

与几何类算法不同,稀疏回归算法中前后求解步骤之间没有依赖关系。同时,随着地物光谱库的可用性不断增加,该类算法被提出并成为主流算法之一。该类算法使用光谱库将混合像素表示为少量纯像素的线性组合,无需从原始高光谱数据中估计和提取端元^[14]。而且,在已知端元的光谱库中包含大量纯端元的光谱信息,从中选择几个端元的光谱来近似混合像素的光谱,这必然导致丰度稀疏。然而,该类算法并不能有效处理不连贯的端元光谱,并且结果的稀疏性和准确性不能得到很好的保障。在这种情况下, Wang等人使用双权重保持丰度在空间域和光谱域中的稀疏性^[15],其中一个权重用于增强光谱库中端元的稀疏性,另一个权重用于促进丰度的稀疏性。为了充分利用高光谱图像中的空间上下文信息,一种新的光谱空间加权稀疏解混(Spectral-Spatial Weighted Sparse Unmixing, SSSU)框

架^[16]被提出。除此之外,空间相关性也被加入该类算法中,用于提升丰度估计的精度。通过使用多视图协同稀疏和光谱空间权重,新的稀疏解混模型中可以充分利用高光谱图像的空间信息和光谱信息。但是,该类算法使用的光谱库是由理想成像条件下获取的地物光谱构成的,实际应用中,由于各种成像条件导致的噪声和大气环境的影响,很难形成理想的成像条件,这也将限制该类方法的适用性。

近期研究表明,深度学习在高光谱图像处理领域具有巨大潜力^[17]。许多研究人员尝试利用深度学习技术来实现更好的高光谱图像解混效果。这类方法利用网络模型的分层结构,自动从大量数据中学习特征和模式,同时具有更强的泛化能力。例如,自编码器(AutoEncoder, AE)可用于无监督的光谱解混,它通过训练过程中最小化重构误差来获得数据的低维表示。Jin 等人提出了一种基于对抗自编码的非监督解混网络(Adversarial Autoencoder Network, AAENet),旨在减少噪声和初始化条件对解混的影响^[18],AAENet 先采用超像素分割将高光谱图像分割成空间均匀区域作为预处理。然后,设计无约束加权自编码器以最小化每组超像素的重建误差。假设具有空间相关性的同一区域中的像元共享相同的统计特性,对丰度进行建模以遵循适当的先验分布。之后在对抗性训练过程中将空间信息传输到网络中,通过将丰度的聚合后验与特定的先验分布相匹配以校正解混权重,大大提高了模型的性能和鲁棒性。受感知机制的启发,Gao 等人提出了一种循环一致性解混网络(Cycle-Consistency Unmixing Network, CyCU-Net),该网络是首个通过放宽原始像素级重建假设并施加循环一致性约束,将高级语义信息转移到基于自编码器的解混网络中的研究,减少了重建过程中的信息损失^[19]。通过所提出的感知损失来实现循环一致性,感知损失由两个光谱重建项和一个丰度重建项组成。该方法具备有效性和稳健性,但没有考虑光谱-空间信息。但是基于深度学习的方法需要大量的训练数据和网络参数才能得到较好的效果,同时还需要具有强大算力的硬件的支持。

为了克服几何类方法的缺点,统计类的算法

将高光谱解混任务作为盲源分离问题,该方法可以根据高光谱图像数据的统计学特性,从无监督线性高光谱解混的角度来看,NMF 过程中使用分解前后的非负矩阵,可以满足高光谱数据端元矩阵和丰度矩阵的非负要求。具体来讲,统计类的算法中最经典的算法有独立成分分析(Independent Component Analysis, ICA)^[11,20]和非负矩阵分解(Nonnegative Matrix Factorization, NMF)^[23]。独立成分分析中假设丰度在统计学角度上是独立的,而经过实验研究发现,这个假设显然是不合理的。而 NMF 的原理就是将目标矩阵分解成两个非负矩阵,这与线性模型(Linear Mixing Model, LMM)是完全吻合的。NMF 作为一种无监督高光谱解混方法,可以在纯像素假设的前提下提取端元并估计与之对应的丰度。这种方法有利于解决高光谱解混任务中遇到的问题,但也存在一些局限性。需要注意的是,统计类算法在处理大规模高光谱数据时,计算复杂度会显著增加,精度也可能会受到影响。因此,选择适当的方法来解决高光谱解混任务需要综合考虑多个因素。

由于现有的基于 NMF 的方法大部分都只是单层结构,这并不能充分表征高光谱图像数据中的复杂结构信息,进而会忽略具有隐藏信息的层次特征^[22]。本文提出的方法是一种结合基于深度学习方法的具备提取分层特征能力的多层非负矩阵分解模型,即空间光谱重加权多层稀疏非负矩阵分解模型(Spatial-spectral Reweighted Sparse Multilayer NMF, SSRS-MLNMF)可以进一步提取高光谱图像中的隐藏信息,并利用包含高光谱图像的空间和光谱特征的权重矩阵以及去噪矩阵提升模型的解混精度。

本文所提方法的主要优势总结如下:

(1) 基于高光谱图像中混合像素中端元比例不均衡的特性,以及像素局部和全局相似性,使用 KMEANS++ 算法在全局范围内进行像素聚类,构建空间权重矩阵,以中和不均衡像素在解混过程中的影响;

(2) 由于高光谱数据中相似的像素在光谱维度也具有相似性,使用 SLIC 超像素分割算法将高光谱图像分割成大小自适应的超像素。然后计算超像素之间的相似度,并逐个计算超像素内

部像素级光谱角距离和欧氏距离,以此作为相似度量来构建光谱权重。最后,将空间、光谱权重矩阵进行融合以保留高光谱图像中的空间和光谱信息;

(3) 由于在真实的高光谱图像中噪声和异常值的存在是不可避免的,因此根据超像素分割的结果,使用 SUNSAL 算法构建降噪权重矩阵,以降低噪声和异常值对解混精度的影响;

(4) 在多层结构的 NMF 框架中,端元在单一的层次结构中会具备稀疏性。同时,加上丰度矩阵本身具有的稀疏性,模型中使用 L_1 范数保持端元和丰度的稀疏性。此外,设计了基于交替方向乘法(Alternative Direction Method of Multipliers, ADMM)的解混算法以求解端元矩阵与丰度矩阵,并在一组合成数据集和两个真实数据集上进行实验以验证算法的有效性。

2 高光谱解混方法

2.1 线性混合模型

在高光谱图像解混研究中,LMM 由于其明确的可解释性和简单高效的特性一直受到广泛关注。在该模型中,高光谱图像中每个像素的光谱可以被视为一组端元经过与之对应的丰度加权之后的线性组合。从数学角度上看,LMM 模型如公式(1)所示:

$$x = As + e \quad (1)$$

其中: $x \in R^{L \times 1}$ 表示高光谱观测数据中的一个像素的光谱信息, $A = [a_1, a_2, a_3, \dots, a_p] \in R^{L \times P}$ 表示端元矩阵, L 表示波段数量, P 表示端元数量。该矩阵的每一列即为一个端元,向量 $s \in R^{P \times 1}$ 表示与端元 x 对应的丰度, $e \in R^{L \times 1}$ 表示一个加性噪声向量。此外,为了使得模型在物理上更加具有可解释性,丰度矩阵中的每个丰度向量都要满足非负约束(Abundance Nonnegativity Constrained, ANC)以及和为一约束(Abundance Sum-to-one Constrained, ASC),如式(2)和式(3)所示:

$$ANC: s_j \geq 0, j = 1, \dots, P, \quad (2)$$

$$ASC: \sum_{j=1}^P s_j = 1. \quad (3)$$

将式(1)进行矩阵化之后,LMM 可以重写成如式(4)的形式。

$$X = AS + E, \quad (4)$$

其中: $S = [s_1, s_2, s_3, \dots, s_N] \in R^{P \times N}$ 是由 N 个丰度向量构成的丰度矩阵,同时 N 也表示像素数量, $E \in R^{L \times N}$ 表示加性噪声矩阵。在高光谱图像解混任务中,该模型对已知的高光谱图像数据在 ANC 和 ASC 约束下对端元矩阵和丰度矩阵进行估计。

2.2 多层非负矩阵分解

和 LMM 类似,NMF 也是将目标矩阵分解成两个非负低秩的因子矩阵,以最小化这两个因子矩阵的乘积与目标矩阵之间的重构误差^[23]。所以在标准 NMF 中,计算重构误差的数学表达式如式(5)所示:

$$\min_{A, S} \|X - AS\|_F^2, s. t. A, S \geq 0, \quad (5)$$

其中: $X \in R^{L \times N}$ 表示目标矩阵, A 和 S 表示两个非负因子矩阵, $\|\cdot\|_F$ 表示矩阵的 Frobenius 范数,其中两个因子矩阵中每个元素都满足非负约束。

但是,由于非负矩阵分解的非凸性,即公式(5)中,需要将目标矩阵同时分解成两个非凸的因子矩阵 A 和 S ,所以基于交替优化技术的乘法更新规则(Multiplication Update Rule, MUR)^[24] 可以被用来最小化 A 和 S ,进而使得它们的乘积与目标矩阵之间的偏差最小化。

在这里需要注意的是,标准的 NMF 模型在迭代求解的过程中容易出现陷入局部最优或求解不唯一的问题。为了处理这种问题,常用的方法就是在模型中引入额外的约束,缩小解空间,使得模型在迭代计算之后得到的解更接近最优解。此外,考虑到在真实 HSI 数据中的丰度具有稀疏性,需要对丰度施加稀疏约束。比如, $L_{1/2}$ -NMF 作为一种基于稀疏约束的 NMF 方法^[25],将丰度的稀疏约束加入标准 NMF 方法中,其目标函数如式(6)所示:

$$f(A, S) = \frac{1}{2} \|X - AS\|_F^2 + \lambda \|S\|_{1/2}, \quad (6)$$

其中: λ 作为正则化参数,控制丰度上稀疏程度, $\|S\|_{1/2}$ 的表达式如式(7)所示:

$$\|S\|_{1/2} = \sum_{p=1}^P \sum_{n=1}^N (s_{pn})^{\frac{1}{2}}, \quad (7)$$

其中, s_{pn} 表示丰度矩阵中坐标为 (p, n) 的元素 s 。然而, $L_{1/2}$ -NMF 的求解结果很大程度上会受到不同初始值的影响,同时该方法无法挖掘高光谱

图像的隐藏的层次信息,尤其是在未知的非负分量被严重缩放(病态数据),或者不够稀疏的情况下,很多 NMF 方法并不能够得到理想的解混效果。

为了使得 NMF 模型克服上述缺陷,一种多层结构的 NMF 模型被提出^[26],利用多层结构,在每一层中对端元矩阵和丰度矩阵进行稀疏约束,在经过多次迭代之后,会进一步提升丰度稀疏性。在第一层中,目标矩阵被分解成 A_1 和 S_1 。第二层中会将经过第一层分解得到的 S_1 进一步分解,得到 A_2 和 S_2 。这个过程会不断重复,直到每一层都完成对上一层中矩阵 S 的分解,该过程的数学表达式如式(8)所示:

$$\begin{aligned} X &= A_1 S_1, \\ S_1 &= A_2 S_2, \\ &\dots \\ S_{l-1} &= A_l S_l \\ \Rightarrow A &= A_1 A_2 \dots A_l, S = S_l \end{aligned} \quad (8)$$

该模型在分解过程中,对端元和丰度同时施加稀疏约束。众所周知,高光谱图像中的混合像素通常只是包含少数端元,并不是大多数端元的叠加,所以其对应的丰度具有稀疏性^[25]。然而,在标准 NMF 模型中,端元矩阵不是稀疏的,但是在多层 NMF 模型中,端元矩阵在每一层中的分解结果可以是稀疏的,因此在多层 NMF 模型的每一层都在端元上也施加了稀疏约束。高光谱图像数据 X 在第一层中会被部分分解,此后会在之后的层次结构中被完全分解^[27]。综上所述,多层 NMF 的第 l 层的数学表达式如式(9)所示:

$$F_{\text{MLNMF}} = \frac{1}{2} \|X_l - A_l S_l\|_F^2 + \alpha_A \|A_l\|_{\frac{1}{2}} + \alpha_S \|S_l\|_{\frac{1}{2}}, \quad (9)$$

其中, α_A 和 α_S 分别是控制端元和丰度稀疏约束的参数。由于 $L_{\frac{1}{2}}$ 范数更具稀疏性^[25],同时当对丰度矩阵施加完全可加性约束时, L_1 范数无法进一步提升稀疏性,故而利用 $L_{\frac{1}{2}}$ 范数代替 L_1 范数,以使得丰度更加稀疏。

由于高光谱图像中的特征之间具有高度空间相关性^[16],同时由于相似的像素其各自的丰度之间也具有相似性^[28]。Wang 等人提出使用空间权重和光谱权重的方式,增强丰度在空间域和光谱域中的稀疏性^[29]。由于高光谱图像中像素之间具有局部相似性和非局部相似性的特性,Yang

等人提出一种将非局部空间信息和空间组稀疏性相结合的非负矩阵分解的方法^[30],以提升解混的精度。

3 空谱重加权稀疏多层非负矩阵分解算法

由于多层非负矩阵分解的过程中并没有考虑到利用高光谱图像的空间和光谱信息,以及噪声对模型性能的影响。本文中根据高光谱图像的空间和光谱特征计算与之对应的空间和光谱权重矩阵。将这两种权重矩阵融合之后用于表征高光谱图像的空间-光谱特征。融合之后的空间-光谱权重矩阵和丰度矩阵具有相同的维度,在模型的各层中使用该空间-光谱权重矩阵对丰度进行加权操作,可以使得每个像素都可以利用其本身在高光谱图像中所具有的空间-光谱特征。同时,出于尽可能降低噪声影响的目的,模型中利用 SLIC 超像素分割算法,构建粗略的高光谱图像,利用 SUnSAL 算法计算粗略的丰度权重矩阵,以提升模型性能。

除了丰度矩阵本身具有的稀疏性之外,由于端元矩阵在多层非负矩阵分解模型的各层中会具有稀疏性,因此模型中通过利用 $L_{\frac{1}{2}}$ 范数对端元和丰度施加稀疏约束,以提升解混效果。

3.1 空间权重

由于高光谱图像中的像素具有局部和非局部相似性,以及混合像素中端元所占的比例的不均衡性^[31],这些因素将会影响解混性能。由于高光谱图像中像素的局部和非局部相似性以及包含端元的像素也会具有明显差异,同时相比于 KMEANS 算法需要通过多次随机初始化聚类中心,KMEANS++ 算法更适合用于像素的聚类操作,因此本文中采用 KMEANS++ 算法计算空间权重。根据聚类结果计算的空间权重的表达式如式(10)所示:

$$W_{i,j}^{\text{spa}} = \frac{\log\left(\frac{N}{n_k}\right)}{\max\left(\log\left(\frac{N}{v}\right)\right)}, \text{ if } x_{i,j} \in C_k, \quad (10)$$

其中: N 表示高光谱图像中的像素个数; n_k 表示第 k 个聚类 C_k 中像素的个数; 向量 $v =$

$[n_1, n_2, n_3, \dots, n_k] \in \mathbf{R}^{1 \times k}$ 中每个元素均表示相应聚类中的像素个数; $x_{i,j}$ 表示高光谱图像空间维度坐标为 (i, j) 的像素; C_k 表示第 k 个聚类。

使用 KMEANS++ 聚类算法, 对空间维度中相邻或不相邻的相似像素进行聚类操作, 将每个像素划分到相应的聚类中, 得到一个全局空间聚类结果。通过式(10)定义的空间权重可以为不同的聚类进行加权并避免不同聚类的权重差异过大, 可以中和不同混合像素中明显特征和细微特征对解混效果的影响。

3.2 光谱权重

根据光谱自相似度分析^[28], 假设高光谱图像中, 局部区域的像素具有相似的特征和光谱值, 则在多维空间中表示这些像素的向量在该局部区域中是相似的。如图 1 中所示的光谱权重的构造过程, 利用 SLIC 超像素分割算法将三维高光谱图像分割成若干个自适应形状的超像素。计算超像素之间的相似度, 并根据超像素中心构建超像素两两之间的相似度, 构造出相似度矩阵, 如式(11)所示:

$$D_{i,j}^{sp} = \frac{1}{d_{\text{enc}}}, \text{ s. t. } i = 1, \dots, k; j = 1, \dots, d \text{ and } i \neq j, \quad (11)$$

其中: d_{enc} 表示根据超像素的中心坐标计算得到的欧几里得距离。得到的超像素相似度矩阵 $D^{sp} \in \mathbf{R}^{d \times d}$, d 表示超像素数量。

利用 KMEANS++ 算法, 根据超像素相似度矩阵 D^{sp} 对超像素进行聚类, 取代逐像素进行聚类, 以提高计算效率。根据每个聚类中的超像素个数计算每个聚类中的权重, 同一个聚类中的超像素具有相同的权重。

通过公式(10)可以计算出中心坐标为 (i, j) 的超像素的权重 $W_{i,j}^{sp}$, 可以为不同的聚类进行加权并避免不同聚类的权重差异过大, 可以中和不同混合像素中明显特征和细微特征对解混效果的影响。随后, 在超像素内部计算各个像素与超像素中心的相似度, 若空间坐标为 (i, j) 的像素 $p_{i,j}$ 在中心坐标为 (m, n) 的超像素 $P_{m,n}$ 中, 则计算像素 $p_{i,j}$ 到超像素中心像素 $p_{m,n}$ 的光谱角距离 d_{spe} 和欧几里得距离 d_{spa} 。像素 $p_{i,j}$ 所对应的权重计算方式如式(12)所示:

$$W_{i,j}^p = \sqrt{d_{\text{spe}}^2 + d_{\text{spa}}^2}, \text{ if } p_{i,j} \in P_{m,n}. \quad (12)$$

然后将各个像素的权重与其所在超像素的权重进行融合, 得到光谱权重 W^{spc} , 如式(13)所示:

$$W_{i,j}^{spc} = W_{i,j}^p * W_{m,n}^{sp}, \text{ if } p_{i,j} \in P_{m,n}. \quad (13)$$

因此该权重矩阵可以在保留超像素之间相似度的同时也能充分表示超像素内部各个像素之间的微小差异。

3.3 去噪权重

由于高光图像在成像过程中会不可避免地受到噪声的影响, 使得地物特征的可分离性降低^[32], 这将在极大程度上影响模型的性能。针对高光谱图像中噪声的存在, 本文在构建光谱权重的过程中, 利用超像素分割算法结果, 构建粗略的高光谱图像, 使用 SUnSAL 算法^[33] 计算粗略的丰度矩阵, 并以此作为去噪权重, 降低噪声对模型性能的影响。

根据 SLIC 超像素分割结果, 将高光谱图像 $X \in \mathbf{R}^{L \times N}$ 自适应分割成 k 个超像素块, 通过将每个超像素进行均值化, 可以得到粗略的高光谱图像 $\tilde{X} \in \mathbf{R}^{L \times N}$, 构建方法如式(14)所示:

$$\tilde{x}_k = \frac{1}{n_k} \sum_{t=1}^{n_k} x_t, \quad (14)$$

其中: \tilde{x}_k 表示第 k 个超像素中进行均值化之后的像素, x_t 表示第 k 个超像素中的像素, n_k 表示第 k 个超像素中像素的数量。

使用 SUnSAL 算法构建粗略的丰度矩阵 \tilde{S} , 对应表达式如式(15)所示:

$$\min_{\tilde{S}} \frac{1}{2} \left\| \tilde{X} - A\tilde{S} \right\|_F^2 + \lambda \left\| \tilde{X} \right\|_{1,1}, \text{ s. t. } \tilde{X} \geq 0. \quad (15)$$

粗略的丰度矩阵 \tilde{S} 可以保留像素之间的空间信息, 然后以此计算基于超像素的去噪权重因子 D , 如式(16)所示:

$$D_{ij} = \frac{1}{\left\| \tilde{S}(i, :) \right\|_2 + \epsilon}, \text{ } i = 1, \dots, P; j = 1, \dots, N, \quad (16)$$

其中: ϵ 是一个极小的正数, 去噪权重因子 D 受粗略丰度矩阵 \tilde{S} 的影响, 会保持在其行向量的稀疏性。此外, 由于高光谱图像中每个均质区域由粗略高光谱图像进行均值化, 可以有效降低噪声的影响。因此, 由此得到的基于超像素的去噪权重因子 D 对噪声不敏感。

在文献^[34]中已经详细阐述过在高光谱图像中丰度具有的稀疏性。同时,由于在多层非负矩阵分解过程中,在单一的层次结构中,端元也会具有稀疏性。与 $L_{\frac{1}{2}}$ 范数相比, $L_{\frac{1}{4}}$ 范数具有更好的稀疏效果。因此,在本文所提出的 SSRS-MLNMF 模型的每一层中,均对端元和丰度施加 $L_{\frac{1}{4}}$ 稀疏约束。

3.4 SSRS-MLNMF

因此,本文提出基于全局空间信息和局部光谱信息的加权多层 NMF,利用包含高光谱图像的空间特征和光谱特征的权重,使得模型在挖掘高光谱图像的深层次信息的同时,具备利用空间-光谱特征的能力。融合之后的空间-光谱权重 $W^{spa-spe}$ 的计算公式如公式(17)所示。

$$W^{spa-spe} = \alpha W^{spa} \odot \left((1 - \alpha)^2 \sqrt{(W^{spe})^2} \right), \quad (17)$$

其中: α 为常数系数,用于控制空间权重 W^{spa} 和光谱权重 W^{spe} 在权重矩阵中的影响。

为了降低噪声对高光谱图像的负面影响,利用超像素分割算法将高光谱图像分割成大小自适应的构建粗略的高光谱图像,在各个超像素中将对所有像素进行平滑处理降低噪声的影响,并

使用 SUnSAL 算法构建使用融合之后的权重约束丰度以及利用 $L_{\frac{1}{4}}$ 范数约束端元和丰度,使得解混模型更具有物理意义。模型中第 l 层的数学表达式如式(18)所示:

$$\min_{A_l, S_l} f(A_l, S_l) = \frac{1}{2} \|X_l - A_l S_l\|_F^2 + \alpha_A \|A_l\|_{\frac{1}{4}} + \alpha_S \|W^{spa-spe} \odot D \odot S_l\|_{\frac{1}{4}} \quad s.t. \quad A, S \geq 0, \quad (18)$$

其中: $X \in R^{L \times N}$, $A = [a_1, a_2, a_3, \dots, a_p] \in R^{L \times P}$, $S = [s_1, s_2, s_3, \dots, s_N] \in R^{P \times N}$,分别表示高光谱图像数据,端元矩阵和丰度矩阵; L 表示波段数量, N 表示像素数量, P 表示端元数量, l 表示模型中的第 l 层, α_A 和 α_S 分别表示约束端元和丰度的系数。 $W^{spa-spe}$ 表示融合了空间权重 W^{spa} 和光谱权重 W^{spe} 的空间-光谱权重。除此之外,与直接计算像素级相似的方法相比,该计算方式没有过高的计算复杂度也无需大量计算资源。在解混过程中通过融合空间权重和光谱权重可以使高光谱图像的空间和光谱信息通过加权的方式作用到每一个像素上, D 表示去噪权重,根据 SLIC 超像素分割算法构建的粗略高光谱图像,降低噪声对模型性能的影响。

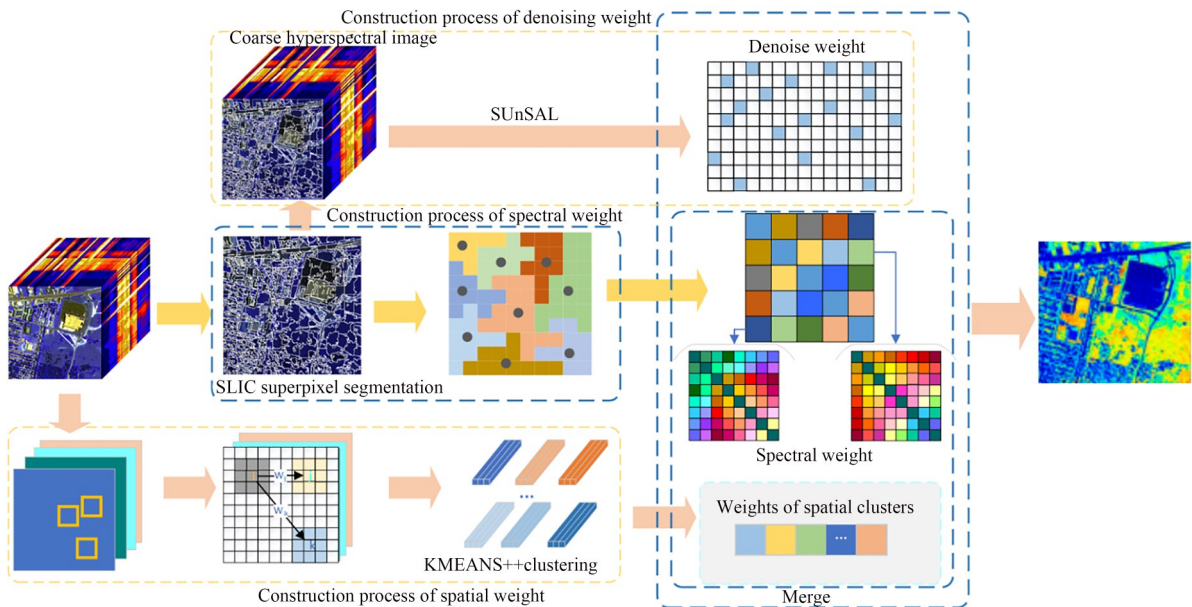


图1 SSRS-MLNMF 技术流程图
Fig. 1 Flowchart of the SSRS-MLNMF

与文献[26]类似,为了保证丰度上的 ASC,使用全约束最小二乘(Constrained Least Squares,

FCLS)进行求解。在模型的每一层中,高光谱数据矩阵和端元矩阵会被改写,如式(19)所示:

$$\tilde{X}_l = \begin{bmatrix} X_l \\ \delta \mathbf{1} \end{bmatrix}, \tilde{A}_l = \begin{bmatrix} A_l \\ \delta \mathbf{1} \end{bmatrix}, \quad (19)$$

其中, δ 是一个控制 ASC 程度的参数以及 $\mathbf{1}$ 是一个元素值都等于“1”的行向量^[35]。

3.5 算法求解

利用拉格朗日乘子法可以将式(18)进行求解,如式(20)所示:

$$L = \frac{1}{2} \|X_l - A_l S_l\|_F^2 + \alpha_A \|A_l\|_{\frac{1}{4}} + \alpha_S \|W^{\text{spa-spe}} \odot D \odot S_l\|_{\frac{1}{4}} + \text{Tr}(\Psi A_l^T) + \text{Tr}(\Phi S_l^T), \quad (20)$$

其中, Ψ 和 Φ 分别是拉格朗日乘子。此时,令:

$$V = W^{\text{spa-spe}} \odot D. \quad (21)$$

由于需要交替更新 A 和 S , 可以将 L 分解成两个子问题分别求解。

3.5.1 求解端元

关于 A 的子问题,表达式如式(22)所示:

$$L_1 = \frac{1}{2} \|X_l - A_l S_l\|_F^2 + \alpha_A \|A_l\|_{\frac{1}{4}} + \text{Tr}(\Psi A_l^T). \quad (22)$$

对公式(22)关于 A 求偏导并令其为零,得到的偏导数如公式(23)所示:

$$\frac{\partial L_1}{\partial A_l} = -X_l S_l^T + A_l S_l S_l^T + \frac{1}{4} \alpha_A (A_l)^{-\frac{3}{4}} + \Psi = 0. \quad (23)$$

根据 Karush-Kuhn-Tucker (KKT) 条件,令 $\Psi A_l = 0$, 同时令偏导为 0, 可以得到 A_l 的迭代更新公式,如公式(24)所示:

$$A_{l+1} \leftarrow A_l \cdot * (X_l S_l^T) \cdot / \left(A_l S_l S_l^T + \frac{1}{4} \alpha_A (A_l)^{-\frac{3}{4}} \right). \quad (24)$$

3.5.2 求解丰度

关于 S 的子问题,表达式如公式(25)所示:

$$L_2 = \frac{1}{2} \|X_l - A_l S_l\|_F^2 + \alpha_S \|V \odot S_l\|_{\frac{1}{4}} + \text{Tr}(\Phi S_l^T). \quad (25)$$

对式(25)关于 S 求偏导并令其为零,得到的偏导数如式(26)所示:

$$\frac{\partial L_2}{\partial S_l} = -A_l^T X_l + A_l^T A_l S_l + \frac{1}{4} \alpha_S V \odot (V \odot S_l)^{-\frac{3}{4}} + \Phi = 0. \quad (26)$$

根据 KKT 条件,令 $\Phi S_l = 0$, 同时令偏导为

零,可以得到 S_l 的迭代更新公式,如式(27):

$$S_{l+1} \leftarrow S_l \cdot * (A_l^T X_l) \cdot / \left(A_l^T A_l S_l + \frac{1}{4} \alpha_S V \odot (V \odot S_l)^{-\frac{3}{4}} \right). \quad (27)$$

此外,需要注意的是,在模型计算过程中,在每层的迭代计算完成之后,需要更新权重矩阵 V , 权重更新策略如式(28)所示:

$$V^{t+1} = \frac{1}{\|S^t\|_{2,1} + \xi}, \quad (28)$$

其中: V^{t+1} 表示参与第 $t+1$ 层迭代计算的权重因子, S^t 表示第 t 层中计算得到的丰度矩阵, $\|\cdot\|_{2,1}$ 为 $l_{2,1}$ 范数,该范数相比于 l_1 范数可以进一步增强丰度的稀疏特性。 ξ 表示一个较小的正数。

3.5.3 算法流程

算法 1: SSRS-MLNMF 算法

输入: 高光谱图像数据 $X \in R^{L \times N}$, 端元数量 P , 参数 $\alpha_0, \tau, L_{\max}, T_{\max}$

输出: 端元矩阵 $E \in R^{L \times P}$ 和丰度矩阵 $S \in R^{P \times N}$

初始化: A, S , 计算空间权重和光谱权重并融合得到 $W^{\text{spa-spe}}$, 计算高光谱粗略图, 并构建去噪权重 V

Repeat:

1. $A_{l+1} \leftarrow A_l \cdot * (X_l S_l^T) \cdot / \left(A_l S_l S_l^T + \frac{1}{4} \alpha_A (A_l)^{-\frac{3}{4}} \right)$

2. $S_{l+1} \leftarrow S_l \cdot * (A_l^T X_l) \cdot / \left(A_l^T A_l S_l + \frac{1}{4} \alpha_S V \odot (V \odot S_l)^{-\frac{3}{4}} \right)$

3. 更新权重因子: $V^{t+1} = \frac{1}{\|S^t\|_{2,1} + \xi}$

4. 更新条件: $k+1 \leftarrow k$

停止条件: 直到满足停止条件。

结束: 返回结果: $A = \prod_{l=1}^L A_l, S = S_L$

在算法初始化方面,由于算法使用顶点成分分析(Vertex Component Analysis, VCA)^[36]进行初始化可以得到更加鲁棒性的结果,因此实验中使用 VCA 的结果作为算法的初始化。本文所提算法由内循环和外循环组成,在内循环中,端元矩阵和丰度矩阵被交替更新,权重矩阵在外循环中更新。另一个重要设置是算法终止迭代的条件,即在每一层中,当算法达到最大迭代次数或者连续 10 次达到最小计算误差之后,就会终止迭代计算。

4 实验结果与分析

4.1 实验设计与评价指标

实验中使用了从文献[37]中获得的包含实际端元和丰度的合成数据集。除此之外,还使用两组真实数据集(Samson和Cuprite)进行实验。使用顶点成分分析(VCA)^[36],L1非负矩阵分解^[38],多层非负矩阵分解(MLNMF)^[26],深度矩阵分解(DMF)^[39],和基于即插即用先验的高光谱解混(Pro-BM3D)^[40]五种不同的解混模型,将各自的结果与本文中所提算法的实验结果进行对比。为了保证实验公平性,所有实验均使用VCA进行端元初始化,并对各个对比算法的参数进行调优处理。在实验中,高光谱图像中的端元数量为已知,在所有的实验结果中,最佳结果以粗体突出显示。

为了评估解混效果,实验中使用光谱角距离SAD作为评估测度衡量估计出的端元矩阵和标准参考端元矩阵之间的差别。SAD的计算公式如公式(29)所示:

$$SAD = \sum_{i=1}^M \arccos \left(\frac{A_i^T \tilde{A}_i}{\|A_i\| \|\tilde{A}_i\|} \right), \quad (29)$$

其中: A_i 表示参考端元, \tilde{A}_i 表示估计的端元。同样为了验证模型得到的丰度的精度,实验中使用

均方根误差RMSE作为衡量估计出的丰度矩阵和标准参考丰度矩阵之间差距的度量。RMSE的计算公式如公式(30)所示:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N \|S_i - \tilde{S}_i\|_2^2}, \quad (30)$$

其中, S_i 和 \tilde{S}_i 分别表示参考丰度和估计的丰度。

4.2 合成数据集实验

对合成数据进行实验可以对所有方法进行客观评估,因为在数据生成过程中地面实况数据是已知的。利用USGS数字光谱库,并从中选择了六个端元来生成合成数据。该库中的光谱特征包含224个光谱带,光谱分辨率为10nm,涵盖380~2500nm的波长范围。

4.2.1 鲁棒性实验

为了验证算法的鲁棒性,该实验在不同噪声水平(10~40dB)下将所有算法进行对比。根据表1和表2所示的实验数据可以看出,SSRS-MLNMF算法在mSAD和RMSE两个评价指标上均取得较好的效果。由于考虑过降低噪声影响,SSRS-MLNMF和其余五种对比算法相比,性能均有明显提升。随着信噪比的提升,所有算法的性能均呈现逐渐增强的趋势,由于使用超像素构建降噪权重矩阵,SSRS-MLNMF算法在低信噪比的实验场景中具有更加优良的解混性能。

表1 不同噪声水平下各个算法的mSAD值比较(合成数据集)

Tab. 1 mSAD comparison of different algorithms under different noise levels (synthetic dataset)

SNR/算法	VCA	L1-NMF	MLNMF	DMF	Pro-BM3D	Proposed
SNR=10 dB	0.251 2	0.118 5	0.105 4	0.226 9	0.036 5	0.041 3
SNR=20 dB	0.207 6	0.070 1	0.068 5	0.207 3	0.041 4	0.039 9
SNR=30 dB	0.183 9	0.064 8	0.064 3	0.126 4	0.040 5	0.038 7
SNR=40 dB	0.119 3	0.050 5	0.059 3	0.106 6	0.036 1	0.035 8

表2 不同噪声水平下各个算法的RMSE值比较(合成数据集)

Tab. 2 RMSE comparison of different algorithms under different noise levels (synthetic dataset)

SNR/算法	VCA	L1-NMF	MLNMF	DMF	Pro-BM3D	Proposed
SNR=10 dB	0.137 9	0.142 1	0.057 9	0.142 1	0.060 2	0.053 9
SNR=20 dB	0.093 8	0.107 4	0.055 9	0.121 9	0.049 8	0.047 2
SNR=30 dB	0.105 8	0.096 5	0.048 2	0.101 5	0.046 4	0.045 1
SNR=40 dB	0.102 8	0.082 4	0.046 4	0.081 5	0.047 2	0.043 7

4.2.2 有效性实验

本实验通过在传统多层非负矩阵分解模

型中加入不同的权重,分析不同权重的有效性。式(31)为传统多层非负矩阵分解(MLN-

MF)模型;公式(32)为加入空间-光谱矩阵的多层非负矩阵分解(SSWS-MLNMF)模型;公式(33)为加入空间-光谱矩阵和降噪矩阵的多

层非负矩阵分解(SSRS-MLNMF)模型。实验在SNR=20 dB的条件下进行,实验结果如图2所示。

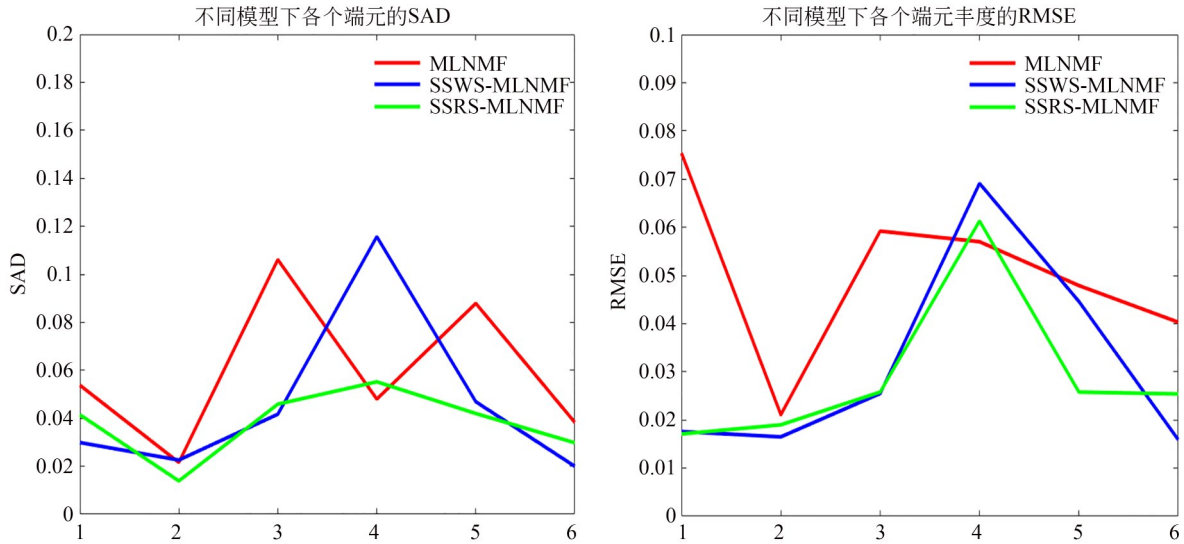


图2 不同模型处理合成数据集的实验结果

Fig. 2 Experimental results of different models dealing with synthetic datasets

$$F_{MLNMF} = \frac{1}{2} \|X_l - A_l S_l\|_F^2 + \alpha_A \|A_l\|_{\frac{1}{2}} + \alpha_S \|S_l\|_{\frac{1}{2}}, \quad (31)$$

$$F_{SSWS-MLNMF} = \frac{1}{2} \|X_l - A_l S_l\|_F^2 + \alpha_A \|A_l\|_{\frac{1}{4}} + \alpha_S \|W_{spa-spe} \odot S_l\|_{\frac{1}{4}}, \quad (32)$$

$$F_{SSRS-MLNMF} = \frac{1}{2} \|X_l - A_l S_l\|_F^2 + \alpha_A \|A_l\|_{\frac{1}{4}} + \alpha_S \|W_{spa-spe} \odot D \odot S_l\|_{\frac{1}{4}}. \quad (33)$$

从图2中可以看到所提方法在解混性能上有一定提升。MLNMF和SSWS-MLNMF的实验结果对比了在加入空间-光谱权重矩阵前后的解混性能,说明加入空间-光谱权重矩阵之后,可以有效提升模型的解混精度。SSWS-MLNMF和SSRS-MLNMF的实验结果对比了加入降噪权重矩阵前后的解混性能,说明在加入空间-光谱权重矩阵的模型中再加入降噪权重矩阵之后,模型的解混性能有了进一步的提升。最终,可以清晰地看到,通过同时增加空间-光谱权重和降噪权重,可以使模型在处理含有噪声的高光谱图像数据的过程中可以保持良好的解混精度。

4. 2. 3 合成数据集实验

在经过多次实验对比之后,确定该模型的最

佳层数和每层迭代次数,以达到最佳解混性能,如表3所示。表4为各个算法在合成数据集上的实验结果(SNR=20 dB)。图3为SSRS-MLNMF所得估计的丰度图与真实丰度的对比图。图4为SSRS-MLNMF所得估计端元曲线与真实端元曲线的对比图。

表3 模型最佳结构参数(合成数据集)

Tab. 3 Optimal structural parameters of the model (synthetic dataset)

层数	每层迭代次数	mSAD
5	1 000	0.076 9
5	800	0.060 2
10	1 000	0.029 1
10	800	0.051 2
15	800	0.048 7
15	500	0.057 1

在与其他对比算法的实验结果对比中可以发现,所提方法几乎在每个端元上均具有一定优势。

表 4 在合成数据集上不同算法的性能

Tab. 4 Performance of different algorithms on synthetic dataset

	VCA	L1-NMF	MLNMF	DMF	Pro-BM3D	Proposed
Almandine	0.253 4	0.264 9	0.034 4	0.170 4	0.032 0	0.017 1
Ammonio	0.583 7	0.333 6	0.037 3	0.051 8	0.016 3	0.019 0
Antigorite	0.153 7	0.130 8	0.104 8	0.200 2	0.038 3	0.025 8
Axinite	0.639 1	0.122 9	0.123 7	0.176 9	0.046 0	0.061 3
Biotite	0.191 9	0.275 9	0.113 2	0.289 8	0.060 4	0.025 8
Carnallite	0.349 3	0.397 6	0.027 8	0.139 3	0.023 3	0.025 4
mSAD	0.361 9	0.254 2	0.073 5	0.171 4	0.036 1	0.029 1
mRMSE	0.087 8	0.086 7	0.064 1	0.041 5	0.059 6	0.038 1




图 3 第一行(a)为参考丰度 第二行(b)为模型所得丰度

Fig. 3 First row (a) shows the true abundance and the second row (b) shows the abundance obtained by the model

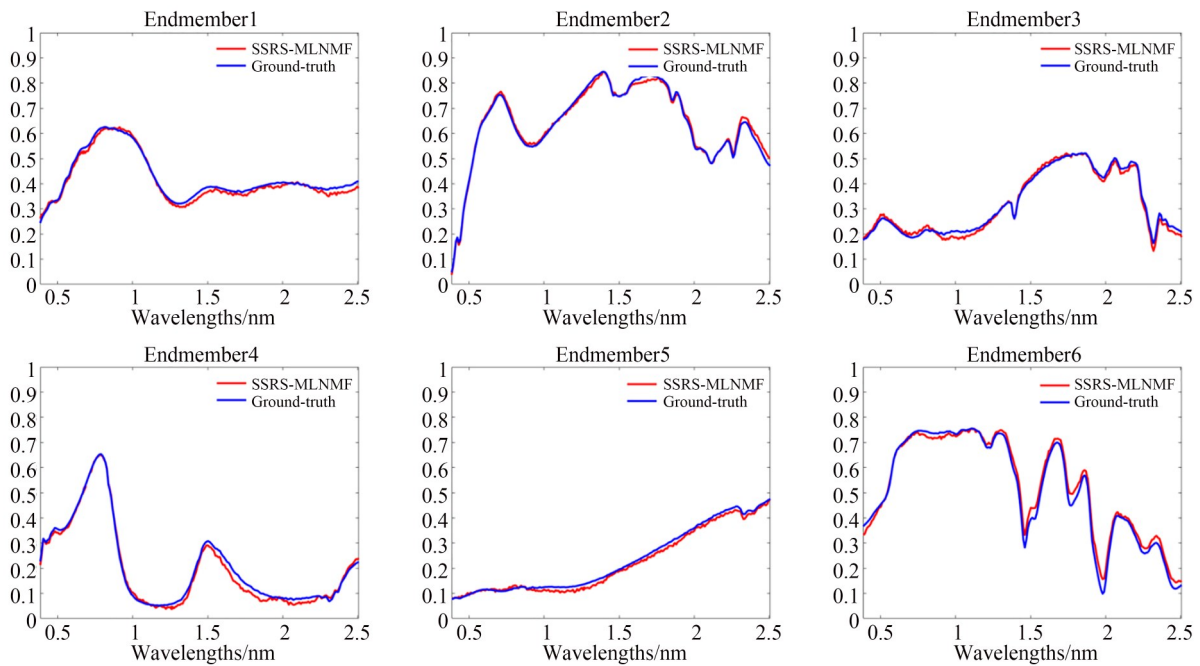


图 4 合成数据集估计的端元曲线与真实端元曲线的对比

Fig. 4 Comparison of the estimated endmember curves with the true endmember curves for the synthetic dataset

4.3 真实数据集实验

4.3.1 Jasper Ridge 数据集

该数据集位于美国加州的 Jasper Ridge 生态保护区,最原始数据的空间维度为 512×614 ,共有 314 368 pixel,光谱波段数目为 224,光谱分辨率为 9.46 nm。每个像素的光谱范围从 380 nm 到 2 500 nm。由于密集水蒸气和大气效应,去除 26 个波段,保留 198 个波段用于实验。

表 5 为模型处理该数据集的最佳层数和每层迭代次数。表 6 为各个算法在该数据集上的实验结果。图 5 为所提算法在该数据集上得到的丰度图与真实丰度的对比。图 6 为 SSRS-MLNMF 在该数据集上得到的端元曲线与真实端元曲线的对比。

表 5 模型最佳结构参数(Jasper Ridge 数据集)

Tab. 5 Optimal structural parameters of the model (Jasper Ridge dataset)

层数	每层迭代次数	mSAD
40	600	0.083 1
40	800	0.088 2
50	600	0.051 6
50	800	0.056 4
60	600	0.066 9
60	800	0.087 3

从表 6 中可以清晰地看到,所提出的方法在平均 SAD 和 RMSE 上都表现最优。图 6 展示了所提出的方法估计的端元与相对应的参考端元,可以清晰地看到,除了个别端元,所提出方法估计的端元与相对应的参考端元基本吻合。

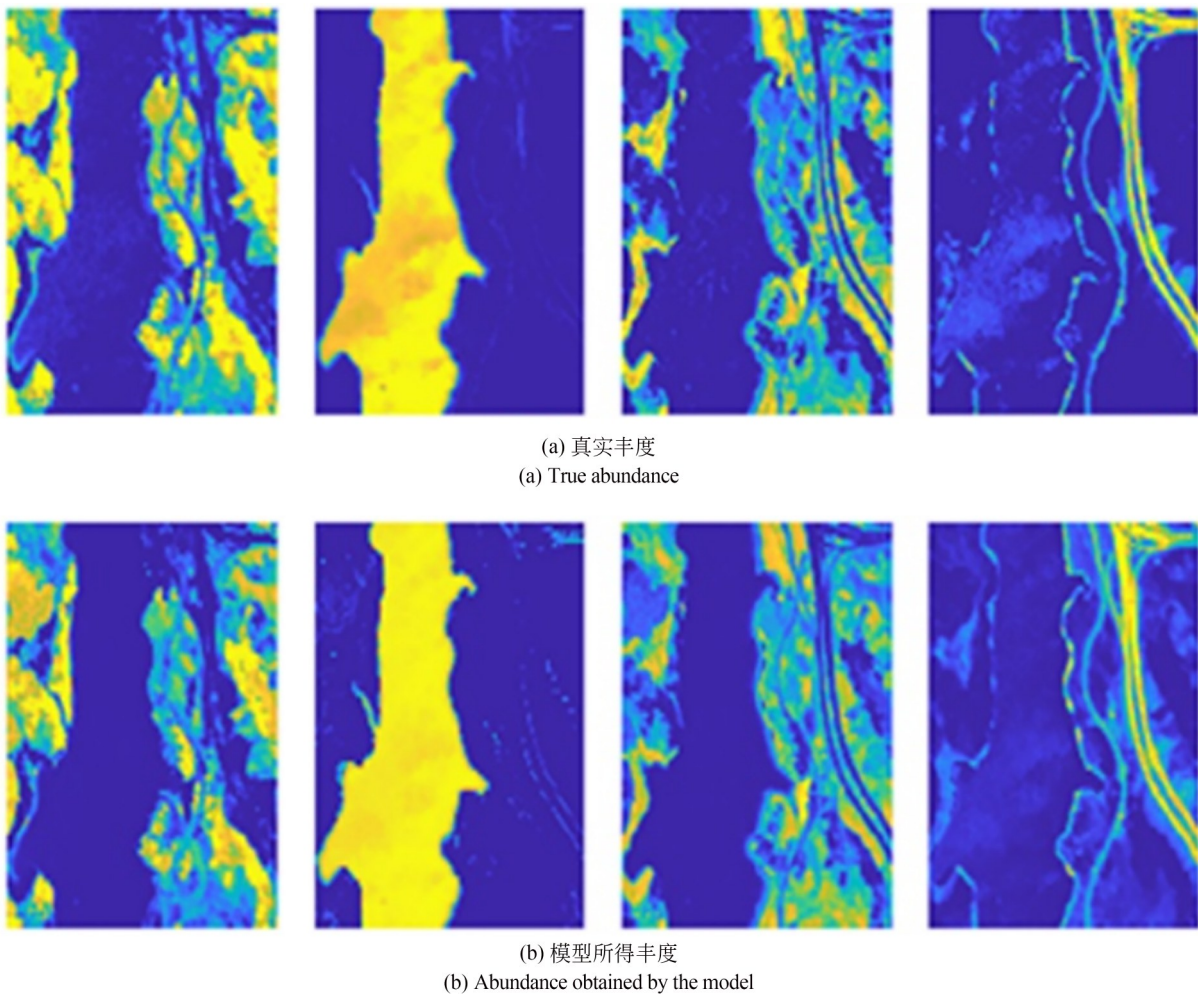


图 5 所提算法在该数据集上得到的丰度图与真实丰度的对比

Fig. 5 Comparison between the abundance obtained by the model and the true abundance

表 6 在 Jasper Ridge 数据集上不同算法的性能

Tab. 6 Performance of different algorithms on the Jasper Ridge dataset

	VCA	L1-NMF	MLNMF	DMF	Pro-BM3D	Proposed
Tree	0.197 9	0.105 6	0.190 3	0.050 7	0.053 2	0.047 1
Water	0.445 5	0.196 4	0.150 0	0.139 1	0.103 5	0.106 8
Dirt	0.279 1	0.362 1	0.238 7	0.206 0	0.025 6	0.030 2
Road	0.265 6	0.402 9	0.196 6	0.116 5	0.031 1	0.022 4
mSAD	0.297 0	0.266 7	0.193 9	0.128 1	0.053 4	0.051 6
mRMSE	0.197 9	0.105 6	0.090 3	0.050 7	0.053 2	0.046 3

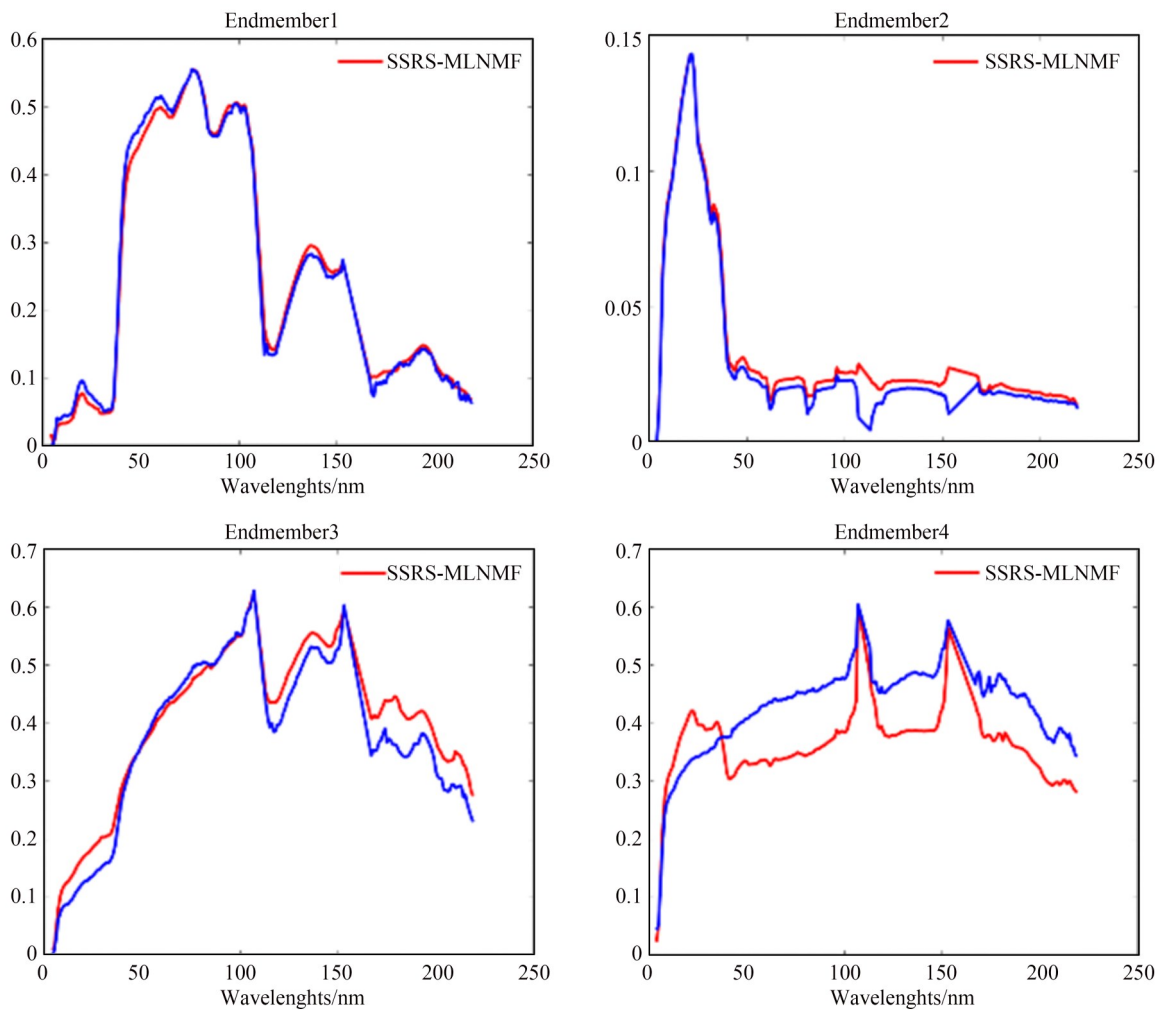


图 6 实端元曲线与参考端元曲线对比

Fig. 6 Comparison of the true endmember curves with the reference endmember curve

4.3.2 Cuprite 数据集

该数据集是高光谱解混研究的最基准数据集,涵盖美国内华达州拉斯维加斯的 Cuprite 矿区。由于图像太大,选取一个 250×191 尺寸大小的图像作为实验数据集。并且,去除被水蒸

气、大气效用影响以及噪声侵蚀的波段(1-2, 104-113, 148-167, 221-224),最后剩余 188 个波段。

表 7 为模型处理该数据集的最佳层数和每层迭代次数。表 8 为各个算法在该数据集上的性能。由于该数据集没有提供真实丰度,因此图 7

表 7 模型最佳结构参数(Cuprite数据集)

Tab. 7 Optimal structural parameters of the model (Cuprite dataset)

层数	每层迭代次数	mSAD
15	1 000	0.142 8
15	1 500	0.153 7
20	1 000	0.144 0
20	1 500	0.145 5
25	1 000	0.138 6
25	1 500	0.110 9


为 SSRS-MLNMF 在该数据集上得到的丰度图。图 8 为 SSRS-MLNMF 在该数据集上得到的端元曲线与真实端元曲线的对比。

从表 8 可以看出本章所提出的算法在 Kaolinite_1, Muscovite, Pyrope, Sphene 和 Chalcodony 的解混性能上表现最佳。通过对比 SAD 和 RMSE 的平均值,可见所提算法具有更高的准确性。总的来说,空间-光谱权重矩阵与降噪权重矩阵对解混有着积极的影响,使得所提算法表现出较好的解混性能。

表 8 在 Cuprite 数据集上不同算法的性能

Tab. 8 Performance of different algorithms on the Cuprite dataset

	VCA	L1NMF	MLNMF	DMF	Pro-BM3D	Proposed
#1 Alunite	1.141 0	0.052 5	0.112 6	1.078	0.1865	0.177 4
#2 Andradite	0.126 7	0.075 8	0.087 6	0.086 6	0.154 3	0.081 1
#3 Buddingtonite	0.199 8	0.078 1	0.134 5	0.143 7	0.107 6	0.175 5
#4 Dumortierite	0.277 9	0.083 4	0.115 7	0.951 1	0.117 1	0.133 3
#5 Kaolinite_1	0.158 5	0.083 7	0.085 3	0.115 7	0.091 4	0.082 0
#6 Kaolinite_2	0.101 1	0.094 3	0.058 1	0.068 9	0.224 8	0.149 5
#7 Muscovite	0.174 8	0.102 1	1.363 6	1.003 5	0.094 0	0.024 6
#8 Montmorillonite	0.108 5	0.102 3	0.072 4	0.057 9	0.080 0	0.130 2
#9 Nontronite	0.131 2	0.112 1	0.190 6	0.092 8	0.169 8	0.111 4
#10 Pyrope	0.141 2	0.146 2	0.089 6	0.112 9	0.110 8	0.089 3
#11 Sphene	0.264 2	0.146 9	0.164 7	0.101 4	0.157 8	0.075 6
#12 Chalcodony	0.133 9	0.174 0	0.136	1.017 6	0.161 5	0.101 7
mSAD	0.246 6	0.116 4	0.217 6	0.402 5	0.138 0	0.110 9






图7 模型所得丰度图(自上而下 第一行:Alunite、Pyrope、Muscovite、Andradite 第二行:Dumortierite、Montmorillonite、Sphe-ne、Kaolinite_2 第三行:Nontronite、Chalcedony、Buddingtonite、Kaolinite_1)

Fig. 7 Abundance map obtained by the model (From top to bottom, the first row: Alunite, Pyrope, Muscovite, Andradite. The second row: Dumortierite, Montmorillonite, Sphe-ne, Kaolinite_2. The third row: Nontronite, Chalcedony, Buddingtonite, Kaolinite_1)

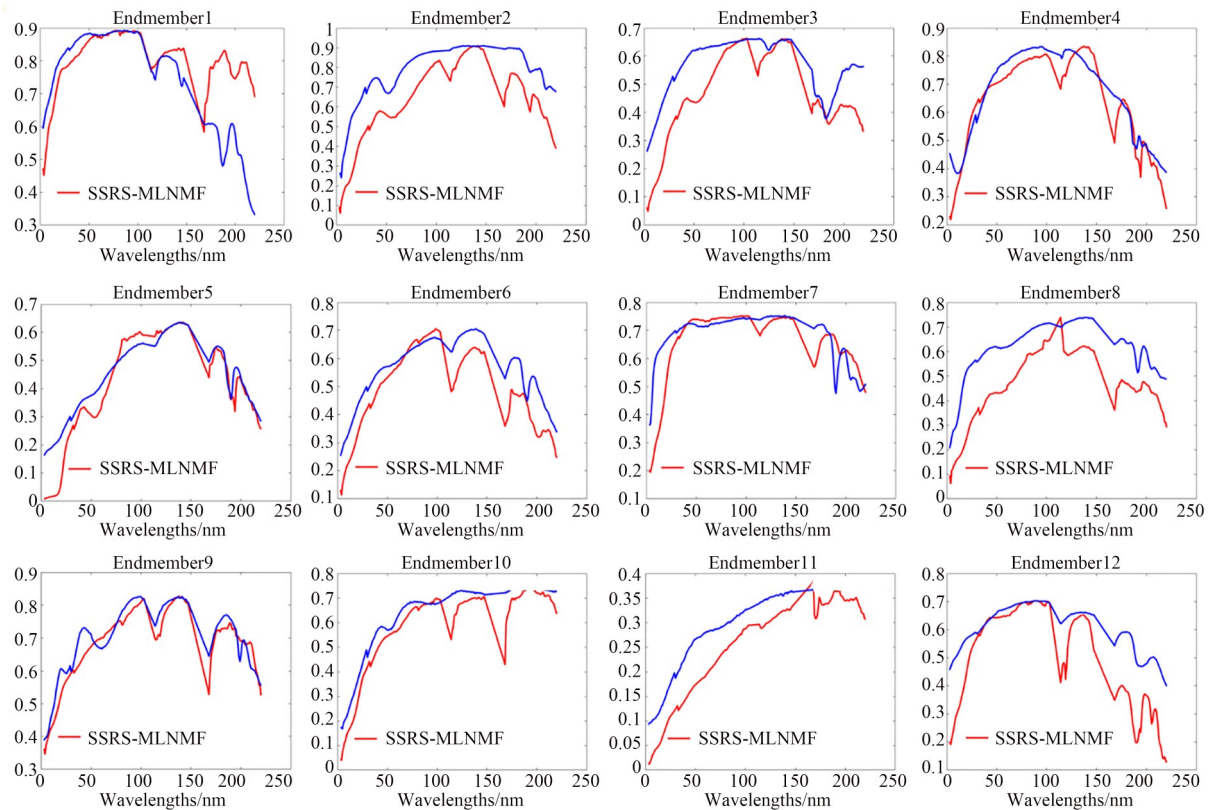


图8 真实端元曲线与参考端元曲线对比(从左往右,从上到下,子图第一行分别为:Alunite、Andradite、Buddingtonite、Dumortierite。子图第二行分别为:Kaolinite_1、Kaolinite_2、Muscovite、Montmorillonite。子图第三行分别为:Nontronite、Pyrope、Sphe-ne、Chalcedony。)

Fig. 8 Comparison of the true endmember curves with the reference endmember curve (From left to right, from top to bottom, the first row of subgraphs are: Alunite, Andradite, Buddingtonite, Dumortierite. The second row of subgraphs are: Kaolinite_1, Kaolinite_2, Muscovite, Montmorillonite. The third row of subgraphs are: Nontronite, Pyrope, Sphe-ne, Chalcedony.)

4.3.3 算法运行时间

本文改进 MLNMF 解混模型,在构建空间-光谱权重方面,通过超像素分割算法将高光谱图

像分割成多个超像素块,先计算超像素级相似度,然后在各个超像素内部计算像素级相似度。通过这种方式取代直接计算像素级相似度的方

式,以降低构建空间-光谱权重的计算复杂度。此外,在构建降噪权重矩阵方面,直接利用超像素分割算法的计算结果,无需重新构建粗略高光谱图像,进而节省计算降噪权重矩阵所消耗的时间。从表 9 可以看出,SSRS-MLNMF 算法在提

升模型解混精度的同时,其运行时间在处理较为复杂的高光谱图像的场景中具有一定优势,而实际应用场景中高光谱图像往往较为庞大且复杂。进而说明 SSRS-MLNMF 算法在实际应用场景中的可行性。

表 9 各个算法处理不同数据集所用时间

Tab. 9 Sum the time taken by each algorithm to process different datasets

(s)

	VCA	L1NMF	MLNMF	DMF	Pro-BM3D	Proposed
Synthetic dataset	0.8	4.2	13.6	8.6	20.3	13.6
Samson	1.2	20.4	51.3	10.4	140.7	102.6
Jasper Ridge	1.9	18.3	55.4	15.2	162.7	143.6
Urban	2.3	23.8	67.2	18.9	1 258.8	984.6
Cuprite	4.9	28.2	77.3	25.8	2 189.2	1 612.4

5 结 论

本文所提出的 SSRS-MLNMF 模型,在加入空间-光谱权重矩阵以充分利用高光谱图像的空间-光谱特征。此外,利用超像素分割算法划分高光谱的同质区域,构建粗略高光谱图像,并以此计算降噪权重矩阵,以提升模型的解混性能。

在合成数据集真实数据集上进行一系列实验,相较于对比算法,SSRS-MLNMF 算法在各个数据集上的端元误差降低 1.49%~4.68%,丰度误差降低 1.83%~4.18%,而且在多数场景中 SSRS-MLNMF 算法的解混精度均优于其他对比算法,实验结果也可以验证 SSRS-MLNMF 算法的有效性和可行性。


参考文献:

- [1] WEI J J, WANG X F. An overview on linear unmixing of hyperspectral data [J]. *Mathematical Problems in Engineering*, 2020, 2020: 3735403.
- [2] KHAN M J, KHAN H S, YOUSAF A, et al. Modern trends in hyperspectral image analysis: a review[J]. *IEEE Access*, 2018, 6: 14118-14129.
- [3] PU R L. Mapping tree species using advanced remote sensing technologies: a state-of-the-art review and perspective [J]. *Journal of Remote Sensing*, 2021, 2021: 9812624.
- [4] HUETE A R, MIURA T, GAO X. Land cover conversion and degradation analyses through coupled soil-plant biophysical parameters derived from hyperspectral EO-1 Hyperion [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41 (6) : 1268-1276.
- [5] GENDRIN C, ROGGO Y, COLLET C. Pharmaceutical applications of vibrational chemical imaging and chemometrics: a review[J]. *Journal of Pharmaceutical and Biomedical Analysis*, 2008, 48 (3) : 533-553.
- [6] HE W, ZHANG H Y, ZHANG L P. Sparsity-regularized robust non-negative matrix factorization for hyperspectral unmixing[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(9): 4267-4279.
- [7] GOETZ A F, VANE G, SOLOMON J E, et al. Imaging spectrometry for Earth remote sensing[J]. *Science*, 1985, 228(4704): 1147-1153.
- [8] GHAMISI P, YOKOYA N, LI J, et al. Advances in hyperspectral image and signal processing: a comprehensive overview of the state of the art[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2017, 5 (4): 37-78.
- [9] BIOCAS-DIAS J M, PLAZA A. An overview on hyperspectral unmixing: geometrical, statistical, and sparse regression based approaches [C]. 2011 *IEEE International Geoscience and Remote Sensing Symposium. Vancouver, BC, Canada*. IEEE, 2011: 1135-1138.

- [10] BEKIT A, CHANG C I, LAMPE B, *et al.* N-FINDER for finding endmembers in compressively sensed band domain [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(2): 1087-1101.
- [11] WINTER M E. Comparison of approaches for determining end-members in hyperspectral data [C]. 2000 *IEEE Aerospace Conference. Proceedings (Cat. No. 00TH8484)*. Big Sky, MT, USA. IEEE, 2000: 305-313.
- [12] LI J, AGATHOS A, ZAHARIE D, *et al.* Minimum volume simplex analysis: a fast algorithm for linear hyperspectral unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(9): 5067-5082.
- [13] BIOCAS-DIAS J M. A variable splitting augmented lagrangian approach to linear spectral unmixing [C]. 2009 *First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing. Grenoble, France*. IEEE, 2009: 1-4.
- [14] SHI Z W, TANG W, DUREN Z N, *et al.* Subspace matching pursuit for sparse unmixing of hyperspectral data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(6): 3256-3274.
- [15] WANG R, LI H C, PIZURICA A, *et al.* Hyperspectral unmixing using double reweighted sparse regression and total variation [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(7): 1146-1150.
- [16] ZHANG S Q, LI J, LI H C, *et al.* Spectral-spatial weighted sparse regression for hyperspectral image unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(6): 3265-3276.
- [17] BHATT J S, JOSHI M V. Deep learning in hyperspectral unmixing: a review [C]. *IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium. Waikoloa, HI, USA*. IEEE, 2020: 2189-2192.
- [18] JIN Q W, MA Y, FAN F, *et al.* Adversarial autoencoder network for hyperspectral unmixing [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(8): 4555-4569.
- [19] GAO L R, HAN Z, HONG D F, *et al.* CyCUnet: cycle-consistency unmixing network by learning cascaded autoencoders [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5503914.
- [20] JIA S, QIAN Y T. Spectral and spatial complexity-based hyperspectral unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(12): 3867-3879.
- [21] WANG W H, QIAN Y T, TANG Y Y. Hypergraph-regularized sparse NMF for hyperspectral unmixing [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(2): 681-694.
- [22] FENG X R, LI H C, LI J, *et al.* Hyperspectral unmixing using sparsity-constrained deep nonnegative matrix factorization with total variation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(10): 6245-6257.
- [23] CHANG C I, DU Q. Estimation of number of spectrally distinct signal sources in hyperspectral imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(3): 608-619.
- [24] LEE D D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization [J]. *Nature*, 1999, 401: 788-791.
- [25] QIAN Y T, JIA S, ZHOU J, *et al.* Hyperspectral unmixing via $L_{1/2}$ sparsity-constrained nonnegative matrix factorization [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(11): 4282-4297.
- [26] RAJABI R, GHASSEMIAN H. Spectral unmixing of hyperspectral imagery using multilayer NMF [J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(1): 38-42.
- [27] RAJABI R, GHASSEMIAN H. Multilayer structured nmf for spectral unmixing of hyperspectral images [C]. 2014 *6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*. Lausanne, Switzerland. IEEE, 2014: 1-4.
- [28] DONG L, YUAN Y, LUXS X. Spectral-spatial joint sparse NMF for hyperspectral unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(3): 2391-2402.
- [29] WANG R, LI H C, LIAO W Z, *et al.* Double Reweighted Sparse Regression for Hyperspectral Unmixing [C]. 2016 *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*.

- Beijing, China. IEEE, 2016: 6986-6989.
- [30] YANG L S, PENG J H, SU H W, *et al.* Combined nonlocal spatial information and spatial group sparsity in NMF for hyperspectral unmixing [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(10): 1767-1771.
- [31] LV X C, WANG W H, LIU H F. Cluster-wise weighted NMF for hyperspectral images unmixing with imbalanced data[J]. *Remote Sensing*, 2021, 13(2): 268.
- [32] DENG C Z, CHEN Y G, ZHANG S Q, *et al.* Robust dual spatial weighted sparse unmixing for remotely sensed hyperspectral imagery[J]. *Remote Sensing*, 2023, 15(16): 4056.
- [33] IORDACHE M D, BIOUCAS-DIAS J M, PLAZA A. Sparse unmixing of hyperspectral data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(6): 2014-2039.
- [34] PENG J T, SUN W W, LI H C, *et al.* Low-Rank and Sparse Representation for Hyperspectral Image Processing: a review[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2022, 10(1): 10-43.
- [35] HEINZ D C, CHEIN-I-CHANG. Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, 39(3): 529-545.
- [36] NASCIMENTO J M P, DIAS J M B. Vertex component analysis: a fast algorithm to unmix hyperspectral data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(4): 898-910.
- [37] ZHU F. Spectral unmixing datasets with ground truths[EB/OL]. 2017: arXiv:1708.05125.
- [38] GUO Z H, WITTMAN T, OSHER S. L1 unmixing and its application to hyperspectral image enhancement [C]. *SPIE Proceedings*, "Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XV. Orlando, Florida, USA. SPIE, 2009.
- [39] DE HANDSCHUTTER P, GILLIS N, SIEBERT X. Deep matrix factorizations [EB/OL]. 2020: arXiv: 2010.00380. <http://arxiv.org/abs/2010.00380>
- [40] WANG X H, ZHAO M, CHEN J. Hyperspectral unmixing via plug-and-play priors[C]. 2020 *IEEE International Conference on Image Processing (ICIP)*. Abu Dhabi, United Arab Emirates. IEEE, 2020: 1063-1067.

作者简介:



唐继明(1996—),男,江苏南通人,硕士研究生,2020年毕业于南京工程学院软件工程专业,获得工学学士学位,主要从事高光谱混合像元分解方面的研究。E-mail: tangjm_lt@163.com

通讯作者:



保文星(1971—),男,宁夏银川人,教授,博士生导师,1993年获西安电子科技大学工业自动化专业学士学位,2001年获西安交通大学电气工程专业硕士学位,2006年获西安交通大学电子科学与技术专业博士学位,主要从事遥感影像处理和模式识别方面的研究。E-mail:bw71@163.com

通讯作者:



雷冰冰(1985—),男,河南洛阳人,讲师,研究生导师,2008年获北方民族大学通信工程专业学士学位,2011年获北方民族大学计算机应用技术专业硕士学位,2015年获东华大学控制理论与控制工程专业博士学位,主要从事嵌入式系统及应用和算法分析与设计的研究。E-mail: x_generation@126.com