光电技术及应用

DOI：10.16818/j.issn1001－5868.2023121501

基于高光谱解混的伪装目标识别技术研究

王俊佟，杨华东*

（沈阳理工大学 信息科学与工程学院，沈阳 110159）

摘　要： 高光谱遥感图像识别技术在伪装目标识别方面具有很大的应用前景。针对高光谱遥感图像中的混合像元和光谱变异问题，提出基于高光谱解混技术的伪装目标识别方法。该方法采用扩展线性混合模型表征高光谱图像中的光谱变异问题，利用超像元分割技术将原始高光谱图像转换为粗细多尺度特征图，对超像元丰度矩阵附加8-邻域空间加权与行约束，以降低噪声和奇异点像元的影响。针对伪装目标空间分布稀疏的特点，在模型中增加丰度矩阵的截断加权核范数作为正则化项，以提高算法精度。实验结果表明提出的方法具有良好的抗噪性和较高的解混精度，可以有效提高伪装目标识别精度。

关键词： 伪装目标识别；高光谱图像；光谱解混；扩展线性混合模型

中图分类号： TP751　**文章编号：** 1001－5868(2024)02－0261－08

Camouflaged Target Recognition Technology Based on Hyperspectral Unmixing

WANG Juntong，YANG Huadong

（School of Information Science and Engineering，Shenyang Ligong University，Shenyang 110159，CHN）

Abstract： Endmember extraction is the key step in the mixed pixel decomposition of hyperspectral remote-sensing images. Traditional endmember extraction algorithms ignore the spatial correlation and nonlinear structure of hyperspectral images，which restricts their accuracy. To consider the spatial relationship and nonlinear structure of hyperspectral images，a nonlinear endmember extraction algorithm based on homogeneous region segmentation is proposed. A hyperspectral image was divided into several homogeneous regions using a superpixel segmentation method，and the manifold learning method was used to ensure the nonlinear structure of the hyperspectral images，extracting preferred endmembers within homogeneous regions. Simulation data and real hyperspectral image experiments showed that the algorithm proposed herein can guarantee the nonlinear structure of hyperspectral data，and the endmember extraction results were better than those of other traditional linear endmember extraction methods. Even in the case of a low signal-to-noise ratio，effective endmember extraction results were obtained.

Key words： camouflaged target recognition；hyperspectral image；spectral unmixing；extended linear mixing model

0　引言

随着科学技术的快速发展，应用在武器装备上的颜色、外形等伪装手段在不断地更新变化，使得目标的灰度、纹理等图像特征与背景更相似，能更好地“融入”伪装背景之中，导致在可见光范围内使用传

收稿日期：2023－12－15.

基金项目：辽宁省教育厅科学研究经费项目(LG202024).

* **通信作者：**杨华东

统方法越来越难以识别伪装目标[1]。高光谱图像具有光谱分辨率高且光谱通道连续的特点,图像中每个像元都对应一条完整而连续的光谱曲线,整幅图像呈“图谱合一”的三维立方体结构,常用于地物的精细分类与识别[2]。由于物体的反射光谱具有显著的“光谱指纹”效应,因此利用高光谱图像处理技术可以显著地提高对伪装目标的识别精度并改善检测效果。

徐文斌等[3]使用长波红外成像的高光谱图像,结合红外偏振技术实现伪装目标识别,有效解决相同温度下伪装目标无法识别的难题。程呈等[4]使用偏振干涉成像光谱仪,提出基于光谱探测的战场目标快速识别,有效地提高目标识别的实时性。Zhao等[5]提出基于高光谱图像区域降维分析的伪装目标识别,对高光谱图像进行预处理,确定待测目标区域并进行尺寸缩减,提高对伪装目标的识别能力。但上述方法都没有考虑高光谱图像中普遍存在的混合像元与光谱变异问题。

尽管高光谱图像光谱分辨率高,但其空间分辨率相对较低,且地物在空间分布上具有复杂性和多样性。因此,图像中单个像元中往往包含多种地物,形成混合像元[6]。光谱解混(又称混合像元分解)是解决混合像元问题的关键技术,它将像元观测光谱分解为多种纯端元光谱,并计算出每种端元的丰度[7-8]。在实际场景中,地表受大气、光照及地形等非线性因素的影响,地物光谱会发生不同程度的变异,导致“同物异谱”现象,这阻碍了地物目标的精细识别和有效检测。因此在进行混合像元分解的同时,还要考虑光谱变异的影响。

常用的光谱变异解决方法是在线性光谱混合模型(Linear Mixing Model,LMM)中增加端元光谱变异项。Thouvenin等[9]定义了端元的加性扰动矩阵,提出了扰动线性光谱混合模型(Perturbed Linear Mixing Model,PLMM),扰动矩阵需要与丰度一起估计。虽然扰动矩阵可以模拟任意端元的变化,却缺乏真实物理动机。Drumetz等[10]提出了扩展线性混合模型(Extended Linear Mixing Model,ELMM),对每个端元使用一个缩放因子,可以有效地模拟由于光照导致的观测反射率变化,更符合物理动机。Imbiriba等[11]提出广义线性混合模型(Generalized Linear Mixing Model,GLMM),可以对端元局部进行扰动,以解释测量光谱任意区域的端元变化。与ELMM模型相比,GLMM模型更复杂、求解更难。

针对传统图像技术在可见光范围内难以识别伪装目标的问题,本文利用高光谱解混技术,同时考虑光谱变异和伪装目标分布稀疏等因素,提出基于高光谱解混的伪装目标识别技术(Camouflage Target Recognition Technology based on Hyperspectral Unmixing,CTRT_HU)。该方法采用ELMM模型表征图像中地物光谱变异性,使用简单线性迭代聚类(Simple Linear Iterative Clustering,SLIC)[12]超像元分割技术,将原始高光谱图像分解转换为粗细多尺度特征图像,对超像元丰度矩阵施加8-邻域空间重加权与行约束,平滑超像元丰度图像,降低图像中奇异点与噪声的影响。由于伪装目标在整个场景内出现概率小,其丰度矩阵往往是稀疏的,因此在模型中引入了截断加权核范数正则化项,保证伪装目标的低秩性,以提高识别的精度。为了验证算法效果,利用便携式地物高光谱仪采集了真实伪装目标的高光谱数据,并建立了典型场景光谱数据库。实验结果表明在模拟数据集和真实数据集上都取得了较好的结果。

1 扩展线性光谱混合模型

LMM假设每个像元的光谱均由端元光谱线性组合而成,第 i 个像元 $\boldsymbol{y}_i \in \mathbb{R}^{L\times 1}$ 表示为:

$$\boldsymbol{y}_i = \boldsymbol{M}_i \boldsymbol{a}_i + \boldsymbol{e}_i, i = 1, \cdots, N \tag{1}$$

式中,$\boldsymbol{M}_i \in \mathbb{R}^{L\times P}$ 是端元矩阵,$\boldsymbol{a}_i \in \mathbb{R}^{P\times 1}$ 是丰度向量,$\boldsymbol{e}_i \in \mathbb{R}^{L\times 1}$ 表示噪声,N 是像元个数,L 是波段数,P 是端元数目。

考虑到端元光谱的变异性,ELMM模型对LMM进行了扩展,引入一个对角矩阵以表征端元光谱的变化,该对角矩阵允许单个端元独立缩放,表示如下:

$$\boldsymbol{y}_i = \boldsymbol{M}_0 \mathrm{diag}(\boldsymbol{\theta}_i) \boldsymbol{a}_i + \boldsymbol{e}_i \tag{2}$$

式中,$\boldsymbol{M}_0 \in \mathbb{R}^{L\times P}$ 为参考端元矩阵,$\boldsymbol{\theta}_i \in \mathbb{R}^{P}$ 是包含每个端元正的缩放因子的向量,$\mathrm{diag}(\boldsymbol{\theta}_i)$ 表示一个对角矩阵,对角元素由向量 $\boldsymbol{\theta}_i$ 的元素给出。

2 基于高光谱解混技术的伪装目标识别方法

为了充分挖掘利用图像空间信息,利用SLIC方法将原始细尺度高光谱图像转换为粗尺度特征图像,并基于ELMM模型构建多尺度特征解混模型。

同时，为了平滑超像元丰度图像，减小高光谱图像中奇异点和噪声的影响，对超像元丰度矩阵施加 8-邻域空间重加权和行约束代价函数。最后，针对伪装目标空间分布稀疏特点，引入丰度矩阵的截断加权核范数作为正则化项，进一步提高光谱分解精度。

2.1　多尺度特征分解

定义变换算子 $\boldsymbol{W}\in\mathbb{R}^{N\times S}$ 用于计算每个超像元内所有像元的平均值[13]，其主要作用是捕获空间相关性并减少噪声的影响。利用 SLIC 分割图像可以实现原始图像到粗尺度图像的空间变换，并应用于 $\boldsymbol{Y}$ 和 $\boldsymbol{A}$ 来实现粗尺度图像。变换矩阵由下式给出：

$$\boldsymbol{Y}_C=\boldsymbol{YW};\boldsymbol{A}_C=\boldsymbol{AW} \tag{3}$$

式中，$\boldsymbol{Y}_C=[\boldsymbol{y}_{C_1},\cdots,\boldsymbol{y}_{C_S}]\in\mathbb{R}^{L\times S}$ 表示粗尺度下的高光谱图像，$\boldsymbol{A}_C=[\boldsymbol{a}_{C_1},\cdots,\boldsymbol{a}_{C_S}]\in\mathbb{R}^{P\times S}$ 表示粗尺度下的丰度矩阵，下标 C 表示粗尺度标记，S 为超像元个数，并且 $S\ll N$。

定义反变换算子 $\boldsymbol{W}^*\in\mathbb{R}^{S\times N}$，其运算结果是将超像元中的每个像元值设置为该超像元的均值[13]，将粗尺度图像转换到细尺度图像，反变换矩阵由下式给出：

$$\boldsymbol{Y}_D=\boldsymbol{Y}(\boldsymbol{I}-\boldsymbol{WW}^*);\boldsymbol{A}_D=\boldsymbol{A}(\boldsymbol{I}-\boldsymbol{WW}^*) \tag{4}$$

式中，$\boldsymbol{Y}_D=[\boldsymbol{y}_{D_1},\cdots,\boldsymbol{y}_{D_N}]\in\mathbb{R}^{L\times N}$ 表示细尺度下的高光谱图像，$\boldsymbol{A}_D=[\boldsymbol{a}_{D_1},\cdots,\boldsymbol{a}_{D_N}]\in\mathbb{R}^{P\times N}$ 是细尺度下的丰度矩阵，下标 D 表示细尺度标记，$\boldsymbol{I}$ 是单位矩阵。

变换算子 $\boldsymbol{W}$ 捕获粗尺度高光谱图像的空间相关性，而它的补变换 $(\boldsymbol{I}-\boldsymbol{WW}^*)$ 捕获细尺度高光谱图像的空间可变性。为计算方便，将变换 $\boldsymbol{W}$ 和 $(\boldsymbol{I}-\boldsymbol{WW}^*)$ 定义为一个复合转换：

$$\boldsymbol{W}=[\boldsymbol{W}\quad\boldsymbol{I}-\boldsymbol{WW}^*] \tag{5}$$

它将输入高光谱图像分解为粗尺度和它的补集细尺度，并且这个变换是可逆的：

$$\boldsymbol{W}^\dagger=[\boldsymbol{W}^*\quad\boldsymbol{I}]^{\mathrm{T}} \tag{6}$$

将高光谱图像 $\boldsymbol{Y}$ 从右侧乘以复合变换 $\boldsymbol{W}$，可以分别得到粗细尺度下的混合模型：

$$\begin{aligned}\boldsymbol{Y}_C&=[\boldsymbol{M}_1\boldsymbol{a}_1,\cdots,\boldsymbol{M}_N\boldsymbol{a}_N]\boldsymbol{W}+\boldsymbol{E}_C\\ \boldsymbol{Y}_D&=[\boldsymbol{M}_1\boldsymbol{a}_1,\cdots,\boldsymbol{M}_N\boldsymbol{a}_N](\boldsymbol{I}-\boldsymbol{WW}^*)+\boldsymbol{E}_D\end{aligned} \tag{7}$$

式中，$\boldsymbol{E}_C=\boldsymbol{EW}$ 和 $\boldsymbol{E}_{\mathrm{D}}=\boldsymbol{E}(\boldsymbol{I}-\boldsymbol{WW}^*)$ 分别表示粗细尺度上的噪声。

2.2　基于 ELMM 的多尺度特征解混模型

解混模型表示如下：

$$\begin{aligned}J(\boldsymbol{M},\boldsymbol{\Psi},\boldsymbol{A})=&\frac{1}{2}\|\boldsymbol{Y}-[\boldsymbol{M}_1\boldsymbol{a}_1,\cdots,\boldsymbol{M}_N\boldsymbol{a}_N]\|_F^2+\\ &\frac{\lambda_M}{2}\sum_{i=1}^{N}\|\boldsymbol{M}_i-\boldsymbol{M}_0\mathrm{diag}(\boldsymbol{\theta}_i)\|_F^2+\\ &\lambda_w\|\boldsymbol{W}_H(\boldsymbol{W}_K\odot\boldsymbol{A})\|_{1,1}+\\ &\lambda_R\|\boldsymbol{A}\|_{b,r,*}+\lambda_AR(\boldsymbol{A})+\\ &\lambda_\Psi R(\boldsymbol{\Theta})\\ \text{s.t.}\ &\boldsymbol{A}\geqslant 0,\boldsymbol{1}^{\mathrm{T}}\boldsymbol{A}=\boldsymbol{1},\boldsymbol{M}_n\geqslant 0,i=1,\cdots,N\end{aligned} \tag{8}$$

式中，$\boldsymbol{M}$ 是一个 $L\times P\times N$ 张量，包含端元矩阵，其元素为 $[\boldsymbol{M}]_{:,:,n}=\boldsymbol{M}_n$，$\boldsymbol{\Theta}=[\boldsymbol{\theta}_1,\cdots,\boldsymbol{\theta}_N]$ 是各像元光谱变异参数的矩阵；$\|\boldsymbol{W}_H(\boldsymbol{W}_K\odot\boldsymbol{A})\|_{1,1}$ 是超像元丰度矩阵 $\boldsymbol{A}$ 的 8-邻域空间重加权与行约束正则化项；$\|\boldsymbol{A}\|_{b,r,*}$ 为截断加权核范数正则化项；$R(\boldsymbol{A})$ 为丰度粗细尺度变换正则化项；$R(\boldsymbol{\Theta})$ 为端元光谱缩放因子正则化项，λ_M，λ_W，λ_R，λ_A 和 λ_Θ 都为正则化参数。

2.2.1　8-邻域空间重加权与行约束

对超像元丰度矩阵施加 8-邻域空间重加权[14-16]与行约束[17]，用来重加权空间关系实现超像元丰度图像的平滑，其表示为：$\|\boldsymbol{W}_H(\boldsymbol{W}_K\odot\boldsymbol{A})\|_{1,1}$，其中⊙表示哈达玛积[18]，$\boldsymbol{W}_K\in R^{P\times N}$ 表示 $\boldsymbol{A}$ 的 8-邻域空间矩阵，每个超像元的值取其区域内所有像素的平均值。$\boldsymbol{W}_H$ 表示 $\boldsymbol{A}$ 的行向量权值，其构造如下：

$$\boldsymbol{W}_H=\mathrm{diag}\left[\frac{1}{\|\boldsymbol{A}(1,:)\|_1+\varepsilon},\cdots,\frac{1}{\|\boldsymbol{A}(S,:)\|_1+\varepsilon}\right] \tag{9}$$

式中，$\|\boldsymbol{A}(\mathrm{S},:)\|_1$ 为丰度矩阵 $\boldsymbol{A}$ 第 S 行的 l_1 范数，常数 $\varepsilon>0$。

2.2.2　截断加权核范数正则化

超像元丰度矩阵 $\boldsymbol{A}$ 的截断加权核范数[19]表示为 $\|\boldsymbol{A}\|_{b,r,*}=\sum\sigma_i^*(\boldsymbol{A})$，$\sigma_i^*(\boldsymbol{A})$ 计算公式如下：

$$\sigma_i^*(\boldsymbol{A})=\begin{cases}\sigma_i(\boldsymbol{A}),1\leqslant i\leqslant r\\ SHR_{b_i}(\sigma_i(\boldsymbol{A})),i>r\end{cases} \tag{10}$$

式中，$\sigma_i(\boldsymbol{A})$ 是 $\boldsymbol{A}$ 的奇异值从大到小排序的第 i 个奇异值，r 为 $\boldsymbol{A}$ 的秩，b_i 为 $\boldsymbol{A}$ 的奇异值权重向量 $\boldsymbol{b}$ 的第 i 个元素，$b_i=\dfrac{1}{\sigma_i(\boldsymbol{A})+\varepsilon}$；$SHR_{b_i}(\sigma_i(\boldsymbol{A}))$ 表示 $\sigma_i(\boldsymbol{A})$ 上的软阈值算子[20]。

2.2.3　丰度粗细尺度变换正则化

$R(\boldsymbol{A})$ 包含了关于丰度空间平滑性的先验信息。丰度映射约束通过变换 $\boldsymbol{W}$ 间接引入空间正则性，表示如下：

$$R(\boldsymbol{A})=\frac{\rho}{2}\|\boldsymbol{AW}\|_F^2+\frac{1}{2}\|\boldsymbol{A}(\boldsymbol{I}-\boldsymbol{WW}^*)\|_F^2=$$

$$\frac{\rho}{2}\|\boldsymbol{A}_C\|_F^2+\frac{1}{2}\|\boldsymbol{A}_D\|_F^2 \tag{11}$$

式中，ρ 为丰度惩罚中粗细尺度的相对权重。

2.2.4 光谱变异缩放因子正则化

$R(\boldsymbol{\Theta})$包含了光谱变异模型参数的先验信息：$R(\boldsymbol{\Theta})=\|H_{\mathrm{h}}(\boldsymbol{\Theta})\|_F^2+\|H_{\mathrm{v}}(\boldsymbol{\Theta})\|_F^2$，其中，$H_{\mathrm{h}}$ 和 H_{v} 分别表示水平和垂直梯度的线性算子。

对于式(8)中的目标函数，使用交替非负最小二乘法[21]求解，算法主要步骤如下表所示。

表 1 算法步骤

算法主要步骤：
输入：$\boldsymbol{Y}$，参数 λ_M，λ_W，λ_R，λ_A，λ_Θ 和 ρ，矩阵 $\boldsymbol{A}^{(0)}$，$\boldsymbol{\Theta}^{(0)}$ 和 $\boldsymbol{M}_0$，算法终止条件 $\varepsilon_{\boldsymbol{A}}$，$\varepsilon_{\boldsymbol{M}}$ 和 $\varepsilon_{\boldsymbol{\Theta}}$，最大迭代次数 $maxiter$；
输出：估计矩阵 $\hat{\boldsymbol{A}}$，$\hat{\boldsymbol{\Theta}}$ 和 $\hat{\boldsymbol{M}}$；
①：使用 SLIC 对高光谱图像 $\boldsymbol{Y}$ 进行分割，得到尺度变换矩阵 $\boldsymbol{W}$、$\boldsymbol{W}^*$；
②：根据分割结果将高光谱图像 $\boldsymbol{Y}$，分解计算为粗尺度 $\boldsymbol{Y}_{\mathrm{C}}$ 和细尺度 $\boldsymbol{Y}_{\mathrm{D}}$；
③：令迭代次数 $i=1$；
④：循环迭代，当不满足算法迭代终止条件 $\varepsilon_{\boldsymbol{A}}$，$\varepsilon_{\boldsymbol{M}}$，$\varepsilon_{\boldsymbol{\Theta}}$ 或最大迭代次数 $maxiter$ 时，交替非负最小二乘求解，$i=i+1$；
⑤：结束迭代，返回 $\hat{\boldsymbol{A}}=\boldsymbol{A}^{(i-1)}$，$\hat{\boldsymbol{M}}=\boldsymbol{M}^{(i-1)}$，$\hat{\boldsymbol{\Theta}}=\boldsymbol{\Theta}^{(i-1)}$，结束。

3 实验结果与分析

3.1 实验条件与算法评价方法

本文实验均在 MATLAB R2021a 软件平台上完成，计算机硬件配置为 Intel CORE I7-11800H CPU@2.3 GHz，8 核 16 线程，内存 16 GB，操作系统为 64 位 Microsoft Windows 10 家庭中文版。

为了评价算法有效性，分别从丰度图、算法执行时间和均方根误差（Root Mean Square Error，RMSE）[22]三个方面进行对比评价。RMSE 定义式如下：

$$RMSE=\sqrt{\sum_{i=1}^{N}((\boldsymbol{M}_0\hat{\boldsymbol{A}})_i-\boldsymbol{Y}_i)^2/N} \tag{12}$$

算法执行时间越短，算法的性能越好。RMSE 值越小，表示端元与丰度重建后的高光谱图像与原图像相比误差越小，算法性能越好。

3.2 模拟数据实验

从高光谱解混研究基准图像 Cuprite 中提取 Alunite、Pyrope 和 Sphene 共 3 种矿物光谱作为合成图像的端元光谱，分别记为 A，B 和 C。以 Cuprite 图像样本均值作为合成图像的背景 b，端元光谱曲线如图 1 所示。

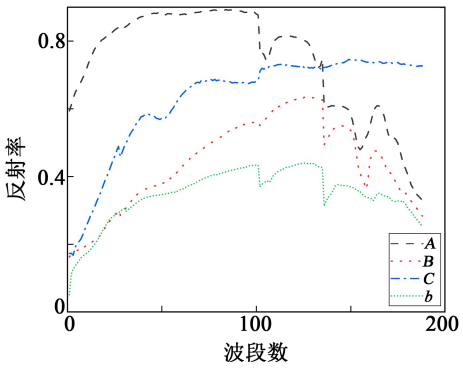


图 1 端元光谱

利用上述 3 种矿物光谱及背景光谱合成一幅空间大小为 120×200 的高光谱图像。整幅图像平均分割为 3 行 5 列，共 15 个 40×40 的图块，每个图块的中心位置放置一个面板。具体地，第 1 列和第 2 列分别放置 3 个 4×4 和 3 个 2×2 纯像元面板。前两列从上至下 3 个面板行分别设置为 A，B 和 C 端元。第 3 列至第 5 列分别放置 3 个 2×2，3 个 1×1 和 3 个 1×1 混合像元面板。后三列混合像元面板的端元光谱构成如表 2 所示。其中，在第 3 列面板中，分别对端元光谱 A，B 和 C 进行缩放以模拟光谱变异现象。以均值光谱 b 作为背景光谱填充除 15 个面板以外的区域。最后在合成图像中添加不同信噪比(SNR)的高斯白噪声以模拟实际图像中存在的噪声。

表 2 混合像元面板光谱组成

行数	第 3 列		第 4 列	第 5 列
第 1 行	$0.5A+0.5B$	$1.1A$	$0.5A+0.5b$	$0.25A+0.75b$
	$0.5A+0.5C$	$0.9A$		
第 2 行	$0.5B+0.5A$	$1.1B$	$0.5B+0.5b$	$0.25B+0.75b$
	$0.5B+0.5C$	$0.9B$		
第 3 行	$0.5C+0.5A$	$1.1C$	$0.5C+0.5b$	$0.25C+0.75b$
	$0.5C+0.5B$	$0.9C$		
	$0.5C+0.5B$	$0.9C$		

本节实验选用完全约束最小二乘解混(FCLS)[23]、比例约束最小二乘解混(SCLS)[24]、ELMM、GLMM 和 PLMM 作为对比方法。每种方法的参数设置与原始参考文献相同。本文所提方法中，设置算法迭代终止条件 $\varepsilon_{\boldsymbol{A}}$，$\varepsilon_{\boldsymbol{M}}$ 和 $\varepsilon_{\boldsymbol{\Theta}}$ 为 2×10^{-3}，最大迭代次数 $maxiter$ 为 100 次。表 3 是 6 种算法运行时间。表 4 所示为高斯白噪声强度分别为 15，20，25，30，35，40，45 和 50 dB 时，6 种算法的均方根误差结果。图 2 是 $SNR=30$ dB 时的解混丰度图。图 3 是合成图像中位于第 2 行第 3 列的面板(四个像元)，使用上述 6 种方法得到的解混丰度图。

由表 3 可以看出线性解混方法 FCLS 所需运算

时间最少，SCLS 次之，且都不受噪声水平影响。非线性解混方法所需运算时间显著多于线性解混方法，其中 PLMM 算法耗时最多。CTRT_HU、ELMM 和 GLMM 算法耗时随着噪声水平的降低而减少。当噪声水平较低时，CTRT_HU、ELMM 和 GLMM 算法耗时相近。当噪声水平较高时（$SNR<30$ dB），CTRT_HU 耗时最少，ELMM、PLMM 与 GLMM 耗时过高，总体上，CTRT_HU 耗时少于 GLMM。但在真实高光谱图像应用中，GLMM 和 PLMM 过于耗时，不宜采用。

如表 4 所示，随着噪声水平的增加（信噪比降低），所有算法的均方根误差值都在不断增加，即算法性能随噪声强度增加而降低。总体上，非线性解混方法效果优于线性解混方法，其中，CTRT_HU 和 ELMM 性能基本相同，都优于 PLMM。需要说明的是从表 4 数据可以看出 GLMM 的重构解混误差在不同噪声水平下都接近于零，性能最优。但结合 3 种端元的解混丰度图（图 2）和局部像元解混情况（图 3），可以发现造成这种结果很可能是因为解混过程中发生了过拟合现象。综合考虑表 4、图 2 和图 3，CTRT_HU 解混丰度更接近端元的真实丰度，这也验证了模型中添加丰度矩阵的截断加权核范数作为正则化项的有效性。

综上，本文提出的 CTRT_HU 算法分别在算法执行时间、重构误差和解混丰度图三个方面相对于其他算法在合成图像上都有较好的结果，验证了本文算法的可行性和有效性。

表 3　各算法在不同信噪比下的执行时间　　单位：s

算法	15 dB	20 dB	25 dB	30 dB	35 dB	40 dB	45 dB	50 dB
FCLS	0.72	0.76	0.70	0.60	0.59	0.60	0.53	0.51
SCLS	1.28	1.42	1.22	1.31	1.22	1.34	1.32	1.23
ELMM	275.86	213.59	9.96	3.22	2.89	3.04	2.72	1.42
GLMM	47.92	22.01	17.07	39.44	13.19	10.05	6.84	3.35
PLMM	279.70	268.14	263.74	373.26	1 194.03	1 175.12	307.42	311.67
CTRT_HU	20.98	8.96	6.70	4.60	3.40	3.58	3.54	3.56

表 4　各算法在不同信噪比下的均方根误差　　单位：10^{-5}

算法	15 dB	20 dB	25 dB	30 dB	35 dB	40 dB	45 dB	50 dB
FCLS	399.38	126.41	39.99	12.69	4.05	1.31	0.45	0.17
SCLS	395.44	125.13	39.55	12.52	3.96	1.25	0.40	0.13
ELMM	30.76	10.08	3.42	1.06	0.33	0.10	0.03	0.01
GLMM	0.05	0.05	0.05	0.01	0.02	0.02	0.03	0.04
PLMM	93.57	29.46	9.26	2.92	1.07	0.34	0.11	0.04
CTRT_HU	44.67	14.58	4.56	1.43	0.45	0.14	0.05	0.01

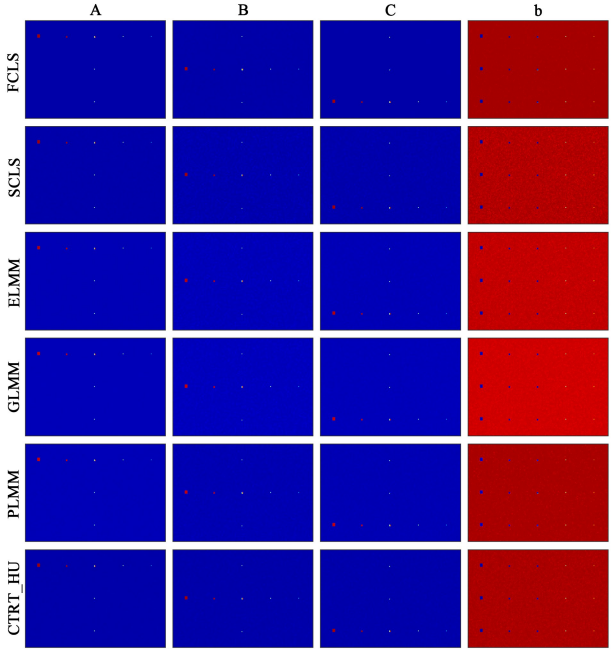


图 2　各算法在 $SNR=30$ dB 时的丰度图

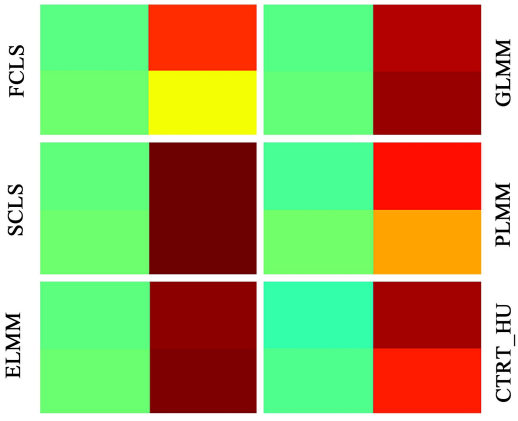


图 3　$SNR=30$ dB 时第 2 行第 3 列面板端元 B 丰度图

3.3　真实数据实验

真实数据由四川双利合谱科技有限公司提供的 GaiaField-V10 便携式地物高光谱仪于 2022 年 11 月采集获得。真实图像场景非常复杂包含多种地物，其中在可见光波段颜色相近的地物包括：坦克绿

色涂装与树叶等，坦克黄色涂装与地面地砖、树枝、树干、石头等，牵引火炮与沥青地面等。

本文使用的真实图像大小为 623×600，由 176 个波段组成，波段范围为 381.60～986.10 nm，去除 1～5 和 126～176 噪声波段，剩余 120 个波段，由 120，90 和 30 波段合成的假彩色图像如图 4 所示。该图像中包含的伪装目标主要有黄绿涂装的苏制 T-34 坦克与墨绿色的牵引火炮。



图 4 真实高光谱图像

由于 CTRT_HU 是丰度估计方法，地物端元信息需要提前获取。为降低端元提取对丰度反演的影响，利用光谱仪采集场景中典型地物的光谱数据建立端元光谱库，共包含 17 种地物光谱信号。具体行列数与对应端元为：黄色涂装坦克(564，446)，绿色涂装坦克(570，351)，牵引火炮(431，302)，树干蓝色保温层(507，562)，树干白色保护层(306，59)，石墩(470，516)，刻字石(292，349)，路灯罩(512，107)，路灯杆(554，169)，树叶(82，103)，树枝(296，240)，红色宣传牌(167，480)，沥青路(246，447)，白色地砖(444，77)，红色地砖(450，55)，黑色树干(173，499)，警示牌(463，202)，端元曲线如图 5 所示。

GLMM 和 PLMM 算法计算量大且计算过程复杂，运行时导致内存溢出或算法运行时间过长，因此文中在真实数据集上不采用。经过试验所得，使用 SLIC 分割真实高光谱图像，在分割尺度为 20 像素时，图像分割效果最好，可以使超像元块尽可能为同质区，即每一块超像元区域只包含一种地物。经超像元分割后的真实高光谱假彩色图像如图 6 所示。

各算法在真实高光谱图像上的算法执行时间与均方根误差如表 5 所示，真实高光谱图像各端元丰度图如图 7 所示。由表 5 可知，CTRT_HU 算法执行后的均方根误差最小，由于所使用的是近景高光谱图像，且地物覆盖区域较小，经 SLIC 分割后的同质区过多，导致算法执行时间长。

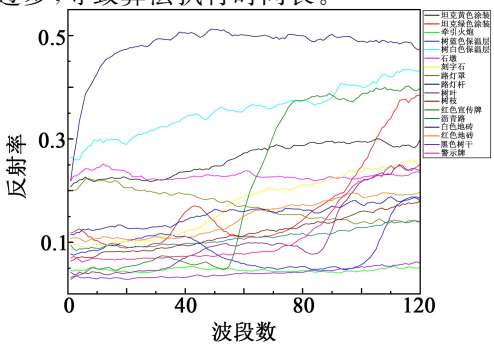


图 5 端元光谱曲线

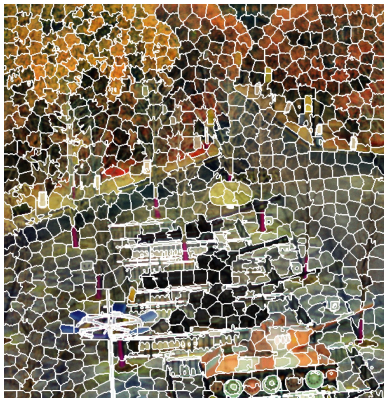


图 6 超像元分割结果

表 5 算法执行时间与均方根误差

算法	时间/s	RMSE
FCLS	19.54	5.11×10^{-5}
SCLS	51.67	2.38×10^{-5}
ELMM	1 921.50	8.32×10^{-6}
CTRT_HU	1 758.78	7.82×10^{-6}

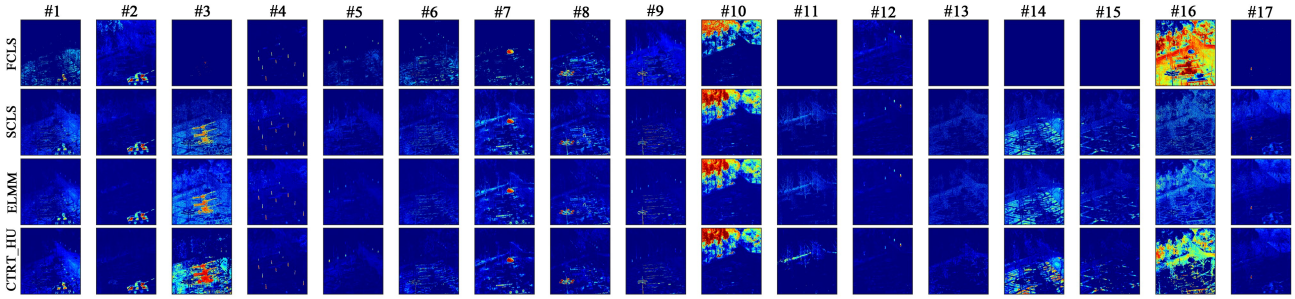
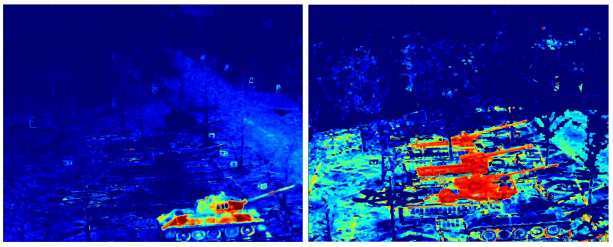


图 7 真实高光谱图像各端元丰度图

结合图 7 与表 5 可以看出 CTRT_HU 的均方根误差最小，解混丰度图效果最好。与 ELMM 相比，CTRT_HU 执行时间少且误差小。结合先验光谱库，可以准确地识别出具有涂色伪装的苏制 T-34 坦克的位置与牵引火炮的位置。伪装坦克的位置如图 8(a)所示，牵引火炮的位置如图 8(b)所示。采用基于阈值的分割方法可以将伪装目标与伪装背景分离，准确地识别出伪装目标。伪装坦克的位置如图 9(a)所示，牵引火炮的位置如图 9(b)所示。



(a) 伪装坦克位置　　(b) 牵引火炮位置

图 8　伪装坦克与牵引火炮位置



(a) 伪装坦克　　(b) 牵引火炮

图 9　阈值分割结果

4　结论

本文提出一种顾及光谱变异的非线性高光谱解混方法，该方法采用超像元分割技术提取高光谱图像的多尺度特征图像，增强高光谱图像的空间联系，基于 ELMM 模型构建多尺度非线性光谱解混模型。针对伪装目标空间分布稀疏特点，引入丰度矩阵的截断加权核范数作为正则化项。模拟数据和真实数据集实验结果都验证了方法的可行性和有效性。该方法既可以为伪装目标识别提供高光谱技术解决途径，也可用于解决高光谱遥感应用中的混合像元问题与光谱变异性问题。

参考文献：

[1] 刘　珩，冉建国，杨　鑫，等. 基于 DETR 的迷彩伪装目标检测[J]. 现代电子技术，2022，45(17)：41-46.
Liu Heng，Ran Jianguo，Yang Xin，et al. Camouflage target detection based on detection transformer [J]. Modern Electronics Technique，2022，45(17)：41-46.

[2] 李树涛，李聪好，康旭东. 多源遥感图像融合发展现状与未来展望[J]. 遥感学报，2021，25(1)：148-166.
Li Shutao，Li Congyu，Kang Xudong. Development status and future prospects of multi-source remote sensing image fusion [J]. National Remote Sensing Bulletin，2021，25(1)：148-166.

[3] 徐文斌，陈伟力，李军伟. 长波红外高光谱偏振特性的伪装目标识别方法[J]. 光谱学与光谱分析，2019，39(1)：235-240.
Xu Wenbin，Chen Weili，Li Junwei. Identification method of camouflaged objects based on long-wave infrared hyperspectral polarization characteristic [J]. Spectroscopy and Spectral Analysis，2019，39(1)：235-240.

[4] 程　呈，高　敏，程旭德，等. 基于光谱探测的战场目标快速识别[J]. 光谱学与光谱分析，2018，38(1)：161-165.
Cheng Cheng，Gao Min，Cheng Xude，et al. Research on fast target recognition method based on spectrum detection in battlefield[J]. Spectroscopy and Spectral Analysis，2018，38(1)：161-165.

[5] Zhao J，Zhou B，Wang G，et al. Camouflage target recognition based on dimension reduction analysis of hyperspectral image regions [J]. Photonics，2022，9(9)：9090640.

[6] 杨　斌，王　斌. 光谱解混技术及其应用研究进展[J]. 激光与光电子学进展，2021，58(16)：76-103.
Yang Bin，Wang Bin. Research advances of spectral unmixing technology and its applications[J]. Laser and Optoelectronics Progress，2021，58(16)：76-103.

[7] 蓝金辉，邹金霖，郝彦爽，等. 高光谱遥感影像混合像元分解研究进展[J]. 遥感学报，2018，22(1)：13-27.
Lan Jinhui，Zou Jinlin，Hao Yanshuang，et al. Research progress on unmixing of hyperspectral remote sensing imagery [J]. J. of Remote Sensing，2018，22(1)：13-27.

[8] Keshava N，Mustard J F. Spectral unmixing[J]. IEEE Signal Process Mag.，2002，19(1)：44-57.

[9] Thouvenin P A，Dobigeon N，Tourneret J Y. Hyperspectral unmixing with spectral variability using a perturbed linear mixing model[J]. IEEE Trans. Signal Process.，2015，64(2)：525-538.

[10] Drumetz L，Veganzones M A，Henrot S，et al. Blind hyperspectral unmixing using an Extended Linear Mixing Model to address spectral variability[J]. IEEE Trans. Image Process.，2016，25(8)：3890-3905.

[11] Imbiriba T，Borsoi R A，Bermudez J. Generalized linear mixing model accounting for endmember variability [C]// 2018 IEEE Inter. Conf. on Acoustics，Speech and Signal Processing (ICASSP)，2018：1862-1866.

[12] Achanta R，Shaji A，Smith K，et al. SLIC superpixels compared to state-of-the-art superpixel methods [J]. IEEE Trans. Pattern Anal. Mach. Intell.，2012，34(11)：2274-2282.

[13] Borsoi R A，Imbiriba T，Bermudez J. A data dependent multiscale model for hyperspectral unmixing with spectral

variability[J]. IEEE Trans. Image Process., 2020, 29: 3638-3651.

[14] 朱昌宇, 张绍泉, 李 军, 等. 基于空间加权协同稀疏的高光谱解混算法研究[J]. 南京信息工程大学学报(自然科学版), 2018, 10(1): 92-101.
Zhu Changyu, Zhang Shaoquan, Li Jun, et al. Spatially weighted collaborative sparse unmixing for hyperspectral images [J]. J. of Nanjing University of Information Science and Technology(Natural Science Edition), 2018, 10(1): 92-101.

[15] Zhang S, Li J, Li H, et al. Spectral-spatial weighted sparse regression for hyperspectral image unmixing [J]. IEEE Trans. Geosci. Remote Sens., 2018, 56(6): 1-12.

[16] Zhang S, Li J, Plaza J A, et al. Spatial weighted sparse regression for hyperspectral image unmixing [C]// 2017 IEEE Inter. Geoscience and Remote Sensing Symposium, 2017: 225-228.

[17] Ma Y, Fan G, Jin Q, et al. Hyperspectral anomaly detection via integration of feature extraction and background purification[J]. IEEE Geosci. Remote Sens. Lett., 2021, 18(8): 1436-1440.

[18] 董桓宇, 陈善学, 陈雯雯. 基于再权重稀疏和正交约束非负矩阵分解的高光谱图像解混[J]. 计算机应用与软件, 2022, 39(7): 222-226.
Dong Huanyu, Chen Shanxue, Chen Wenwen. Reweight sparse and orthogonal nonnegative matrix factorization for hyperspectral unmixing [J]. Computer Applications and Software, 2022, 39(7): 222-226.

[19] 李 璠, 张绍泉, 曹晶晶, 等. 高光谱数据截断加权核范数稀疏解混[J]. 遥感学报, 2022, 26(6): 1067-1082.
Li Fan, Zhang Shaoquan, Cao Jingjing, et al. Sparse unmixing with truncated weighted nuclear norm for hyperspectral data [J]. National Remote Sensing Bulletin, 2022, 26(6): 1067-1082.

[20] Giampouras P V, Themelis K E, Rontogiannis A A, et al. Simultaneously sparse and low-rank abundance matrix estimation for hyperspectral image unmixing [J]. IEEE Trans. on Geosci. Remote Sens., 2016, 54(8): 4775-4789.

[21] Paatero P, Tapper U. Positive matrix factorization: A non-negative factor model with optimal utilization of error estimates of data values[J]. Environmetrics, 1994, 5(2): 111-126.

[22] 韩红伟, 陈 聆, 苗加庆. 一种低秩和图正则化的协同稀疏高光谱解混方法[J]. 无线电工程, 2023, 53(4): 868-876.
Han Hongwei, Chen Ling, Miao Jjiaqing. A low-rank and graph regularization collaborative sparse hyperspectral unmixing method[J]. Radio Engineering, 2023, 53(4): 868-876.

[23] Heinz D C, Chang C I. Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery [J]. IEEE Trans. Geosci. Remote Sens., 2001, 39(3): 529-545.

[24] Veganzones M A, Drumetz L, Tochon G, et al. A new extended linear mixing model to address spectral variability [C]// 2014 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), 2014: 1-4.

作者简介:

王俊佟(1998—),男,硕士研究生,主要从事高光谱图像混合像元分解方面的研究;

杨华东(1986—),男,博士,副教授,主要从事高光谱图像解译及智能信息处理方面的研究。