

利用核方法进行高光谱遥感图像线性解混

林娜^{1,2} 杨武年² 王斌³

1 重庆交通大学土木工程学院测绘系,重庆,400074
2 成都理工大学地学空间信息技术国土资源部重点实验室,四川 成都,610059
3 重庆市地理信息中心,重庆,401121

摘 要:为了提高高光谱遥感图像混合像元分解的精度,提出基于核方法的高光谱线性解混。采用核化正交子空间投影(orthogonal subspace projection,OSP)算子、最小二乘正交子空间投影(least squares OSP,LSOSP)算子、非负约束最小二乘(nonnegative constrained least-squares,NCLS)算子和全约束最小二乘(fully constrained least-squares,FCLS)算子等方法分别构建核正交子空间投影(Kernel OSP,KOSP)、核最小二乘正交子空间投影(Kernel LSOSP,KLSOSP)、核非负约束最小二乘(Kernel NCLS,KNCLS)和核全约束最小二乘(Kernel FCLS,KFCLS)高光谱图像混合像元解混模型。对 CUPRITE 矿区 AVIRIS 数据进行 KLSOSP、KNCLS 和 KFCLS 与 LSOSP、NCLS 和 FCLS 丰度反演对比实验,结果表明,对于混合像元广泛存在的高光谱遥感图像来说,基于核方法的 KLSOSP、KNCLS 和 KFCLS 的解混精度优于 LSOSP、NCLS 和 FCLS;附加约束条件有利于提高丰度反演的精度。

关键词:高光谱遥感;核方法;高光谱解混;OSP

中图法分类号:TP751; P237 **文献标志码:**A

高光谱遥感是遥感技术的重要发展方向之一^[1],其光谱分辨率高达 nm 级,可获得地物的连续光滑的光谱曲线^[2-3]。但因高光谱成像光谱仪侧重于高光谱分辨率,其空间分辨率相对较低;由于地面的复杂多样性,使高光谱遥感图像中广泛存在混合像元^[4],制约了高光谱遥感技术的应用。高光谱解混是解决混合像元问题的一个有效方法,其研究内容主要是提取遥感图像基本组成成分(端元)的特征光谱和有效估计混合像元中各个端元之间的混合比例(丰度)^[5]。

线性光谱混合模型(linear spectral mixture model,LSMM)在混合像元分解中得到了广泛应用,它假定混合像元中各端元之间的相互影响可以忽略不计,每 1 个观测像元矢量都可以表述为端元和它们相应丰度的线性组合^[6]。LSMM 的丰度反演主要应用最小二乘法^[7];为了提高反演的精度,可加入各种约束条件,根据不同约束条件可分为无约束最小二乘法(unconstrained least-squares,ULS)、非负约束最小二乘法(non-negative constrained least-squares,NCLS)和全

约束最小二乘法(fully constrained least-squares,FCLS)。近年来,由于核函数方法具有强大的数据映射能力,可有效地提高混合像元分解的精度,因而在高光谱遥感图像解混中得到广泛应用^[8]。国内外学者利用支持向量机(support vector machine, SVM)及其改进算法进行混合像元的分解^[9-14]。Kwon 等提出核正交子空间投影(Kernel orthogonal subspace projection,KOSP)算法^[15];此后,很多学者将该方法应用于图像分类、目标检测、混合像元分解等领域。Liu 等^[16]在 KOSP 的基础上发展了基于核方法的线性光谱分析。王挺等考虑到局域信息,对 KOSP 方法进行改进,并应用到高光谱图像目标探测领域^[17]。赵春晖等提出了一种基于自适应核方法的正交子空间投影高光谱图像异常检测算法^[18]。国内外学者利用核方法进行高光谱混合像元分解的研究集中在对 SVM 和 KOSP 算法的改进及应用上。关于核方法与 LSMM 模型的丰度反演结合的研究还比较少,尚不成体系。

本文在 KOSP 算法的基础上,将核方法与

LSMM 模型的丰度反演方法结合,采用最小二乘正交子空间投影(least squares orthogonal subspace projection, LSOSP)算子,构建核最小二乘正交子空间投影(Kernel LSOSP, KLSOSP)高光谱混合像元解混方法;然后用 KLSOSP 导出核非负约束最小二乘(Kernel nonnegative constrained least-squares, KNCLS),进一步导出核全约束最小二乘(Kernel fully constrained least-squares, KFCLS);并将 KLSOSP、KNCLS 和 KFCLS 与 LSOSP、NCLS 和 FCLS 的高光谱丰度进行反演对比实验。

1 线性光谱分解模型

1.1 OSP

线性光谱混合模型假设光谱向量 \mathbf{r} 由 1 组图像端元线性混合而成,即有:

$$\mathbf{r} = \mathbf{M}\mathbf{a} + \mathbf{n} \tag{1}$$

式中, \mathbf{r} 为混合像元光谱, $\mathbf{r} \in \mathbf{R}^l$, \mathbf{R} 为端元, l 为波段数; \mathbf{M} 为端元矩阵, $\mathbf{M} \in \mathbf{R}^{l \times p}$, p 为端元数目; \mathbf{a} 为丰度向量, $\mathbf{a} \in \mathbf{R}^p$; \mathbf{n} 为模型误差。

OSP 方法在进行混合像元分解时,把 \mathbf{M} 分为感兴趣的目标端元 \mathbf{d} 与不感兴趣的背景端元 \mathbf{U} 这两部分^[19-20]。为不失一般性,设 $\mathbf{d} = \mathbf{m}_p$ 为第 p 个端元的光谱信号, $\mathbf{U} = [\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_{p-1}]$ 为其他端元的光谱信号,则式(1)可改写为:

$$\mathbf{r} = \mathbf{d}\alpha_p + \mathbf{U}\boldsymbol{\gamma} + \mathbf{n} \tag{2}$$

式中, α_p 为第 p 个端元的丰度; \mathbf{U} 为背景信号矩阵; $\boldsymbol{\gamma}$ 为 \mathbf{U} 对应的端元丰度。利用最大化信噪比的原则得到未知的丰度 α_p (即 OSP 探测算子)为:

$$\hat{\alpha}_p^{\text{OSP}}(\mathbf{r}) = \mathbf{d}^T \mathbf{P}_U^\perp \mathbf{r} \tag{3}$$

式中, $\mathbf{P}_U^\perp = \mathbf{I} - \mathbf{U}(\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T$ 是背景 \mathbf{U} 的正交补矩阵(亦称“投影阵”),其作用是把信号 \mathbf{d} 投影到由信号 \mathbf{U} 的元素所形成的子空间上; \mathbf{I} 为 $L \times L$ 的单位矩阵。 \mathbf{P} 将 \mathbf{U} 分量消除,从而抑制了图像中不感兴趣目标的特征分量。由此可见,OSP 方法在进行丰度反演时,能消除背景信息的影响,同时也可抑制图像噪声的干扰。

1.2 LSOSP

利用式(3)中的 OSP 探测算子求解端元丰度时,需要已知先验的丰度矩阵,这通常很难获得,可利用最小二乘原理估计未知丰度 α_p :

$$\hat{\alpha}_p^{\text{LS}} = (\mathbf{M}^T \mathbf{M})^{-1} \mathbf{M}^T \mathbf{r} \tag{4}$$

通过引入丰度修正项 $(\mathbf{d}^T \mathbf{P}_U^\perp \mathbf{d})^{-1}$,得到 LSOSP 算子:

$$\hat{\alpha}_p^{\text{LSOSP}}(\mathbf{r}) = (\mathbf{d}^T \mathbf{P}_U^\perp \mathbf{d})^{-1} \mathbf{d}^T \mathbf{P}_U^\perp \mathbf{r} \tag{5}$$

1.3 约束条件

在实际算法中,式(1)中的线性光谱混合模型有以下两个约束条件:①丰度非负约束(abundance non-negativity constraint, ANC),即 $\alpha_j \geq 0$, $1 \leq j \leq p$;②端元丰度总和为 1 约束(abundance sum-to-one constraint, ASC),即 $\sum_{j=1}^p \alpha_j = 1$ 。加入丰度非负约束条件,可构建 NCLS;加入以上两个约束条件,可构建 FCLS。

2 基于核方法的高光谱丰度反演

核方法的应用通常是将所有的训练样本通过核函数映射到高维特征空间,再在特征空间进行线性分析,如核主成分分析^[21]、核最小噪声分离变换^[22]、核 RX 探测^[23]等。这类方法因所有的数据样本都需要核化,计算复杂度较高。本文对核方法的应用是通过核化 OSP、LSOSP、NCLS 和 FCLS 算子来进行丰度反演,不仅可提高线性解混的精度,而且可大大降低计算复杂度。首先核化 OSP 探测算子,构建 KOSP 模型,利用最小二乘法求解导出 KLSOSP;然后加入非负约束条件导出 KNCLS,加入全约束条件导出 KFCLS。

2.1 KOSP 和 KLSOSP

KOSP 最初由 Kwon 等^[15]在 2005 年提出,采用的是奇异值分解(singular value decomposition, SVD)方法。本文不采用 SVD,而是直接将核方法运用 \mathbf{P}_U^\perp 上,将 $(\mathbf{U}^T \mathbf{U})^{-1}$ 直接映射到特征空间中的核形式 $K(\mathbf{U}^T \mathbf{U})^{-1}$,通过一个核映射 φ 将式(3)映射到特征空间,即有:

$$\alpha_p^{\text{KOSP}}(\mathbf{r}) = \varphi(\mathbf{d})^T \mathbf{P}_{\varphi(\mathbf{U})}^\perp \varphi(\mathbf{r}) \tag{6}$$

其中,

$$\mathbf{P}_{\varphi(\mathbf{U})}^\perp = \mathbf{I}_\varphi - \varphi(\mathbf{U})(\varphi(\mathbf{U}^T)\varphi(\mathbf{U}))^{-1}\varphi(\mathbf{U})^T \tag{7}$$

将式(7)带入式(6),则得 KOSP 关系式:

$$\begin{aligned} \alpha_p^{\text{KOSP}}(\mathbf{r}) = & \varphi(\mathbf{d})^T \varphi(\mathbf{r}) - \varphi(\mathbf{d})^T \varphi(\mathbf{U})(\varphi(\mathbf{U}^T)\varphi(\mathbf{U}))^{-1} \\ & \varphi(\mathbf{U})^T \varphi(\mathbf{r}) \end{aligned} \tag{8}$$

由于 $\langle K(\mathbf{d}, \mathbf{I}_\varphi), K(\mathbf{I}_\varphi, \mathbf{r}) \rangle = K(\mathbf{d}, \mathbf{r})$,利用核方法将式(8)进一步简化为:

$$\alpha_p^{\text{KOSP}}(\mathbf{r}) = K(\mathbf{d}, \mathbf{r}) - K(\mathbf{d}, \mathbf{U})K(\mathbf{U}, \mathbf{U})^{-1}K(\mathbf{U}, \mathbf{r}) \tag{9}$$

相似地,由式(5)可得:

$$\hat{\alpha}_p^{\text{KLSOSP}}(\mathbf{r}) = \frac{\hat{\alpha}_p^{\text{KOSP}}(\mathbf{r})}{\varphi(\mathbf{d})^T \mathbf{P}_{\varphi(\mathbf{U})}^\perp \varphi(\mathbf{d})} \tag{10}$$

再将式(7)带入式(10),得到:

$$\hat{\alpha}_p^{\text{KLSOSP}}(\mathbf{r}) = \frac{\hat{\alpha}_p^{\text{KOSP}}(\mathbf{r})}{\varphi(\mathbf{d})^T \varphi(\mathbf{d}) - \varphi(\mathbf{d})^T \varphi(\mathbf{U}) (\varphi(\mathbf{U})^T \varphi(\mathbf{U}))^{-1} \varphi(\mathbf{U})^T \varphi(\mathbf{r})} = \frac{\hat{\alpha}_p^{\text{KOSP}}(\mathbf{r})}{K(\mathbf{d}, \mathbf{d}) - K(\mathbf{d}, \mathbf{U}) K(\mathbf{U}, \mathbf{U})^{-1} K(\mathbf{U}, \mathbf{d})} \quad (11)$$

2.2 KNCLS

因丰度值不能为负值,所有像元必须满足丰度非负约束条件(ANC),故可得到:

$$\mathbf{r} = \mathbf{M}\boldsymbol{\alpha} + \mathbf{n}, \alpha_j \geq 0, 1 \leq j \leq p \quad (12)$$

对于 ANC 约束下的最小二乘法也就变成了如下最优优化问题:

$$\min(\mathbf{r} - \mathbf{M}\boldsymbol{\alpha})^T (\mathbf{r} - \mathbf{M}\boldsymbol{\alpha}), \alpha_j \geq 0 \quad (13)$$

构造一个 Lagrange 乘数,则有:

$$\mathbf{J} = \frac{1}{2} (\mathbf{r} - \mathbf{M}\boldsymbol{\alpha})^T (\mathbf{r} - \mathbf{M}\boldsymbol{\alpha}) + \lambda(\boldsymbol{\alpha} - \mathbf{c}) \quad (14)$$

若 $\boldsymbol{\alpha} = \mathbf{c}$, 由 $\frac{\delta J}{\delta \boldsymbol{\alpha}}$ 可推导出以下两个迭代方程求解 NCLS, 即有:

$$\hat{\boldsymbol{\alpha}}^{\text{NCLS}}(\mathbf{r}) = (\mathbf{M}^T \mathbf{M})^{-1} \mathbf{M}^T \mathbf{r} - (\mathbf{M}^T \mathbf{M})^{-1} \boldsymbol{\lambda} \quad (15)$$

$$\boldsymbol{\lambda} = \mathbf{M}^T \mathbf{r} - \mathbf{M}^T \hat{\boldsymbol{\alpha}}^{\text{NCLS}}(\mathbf{r}) \quad (16)$$

式(15)和式(16)的核形式为:

$$\hat{\boldsymbol{\alpha}}^{\text{KNCLS}}(\mathbf{r}) = (K(\mathbf{M}, \mathbf{M}))^{-1} K(\mathbf{M}, \mathbf{r}) - K(\mathbf{M}, \mathbf{M})^{-1} \boldsymbol{\lambda} \quad (17)$$

$$\boldsymbol{\lambda} = K(\mathbf{M}, \mathbf{r}) - K(\mathbf{M}, \mathbf{M}) \hat{\boldsymbol{\alpha}}^{\text{KNCLS}}(\mathbf{r}) \quad (18)$$

其中, $\boldsymbol{\lambda}$ 为拉格朗日乘向量, 用来实现丰度非负约束; $(K(\mathbf{M}, \mathbf{M}))^{-1} K(\mathbf{M}, \mathbf{r})$ 为式(15)中的 $(\mathbf{M}^T \mathbf{M})^{-1} \mathbf{M}^T \mathbf{r}$ 的核形式。所以, 式(11)中的 $\hat{\alpha}_p^{\text{KLSOSP}}(\mathbf{r})$ 可进一步作为 KNCLS 的式(17)和式(18)这两个迭代方程的初始条件。

2.3 KFCLS

为了推导出 KFCLS, 引入一个新的端元矩阵 $\mathbf{N} = \begin{bmatrix} \delta \mathbf{M} \\ \mathbf{E}^T \end{bmatrix}$ 和一个像元光谱向量 $\mathbf{s} = \begin{bmatrix} \delta \mathbf{r} \\ \mathbf{E} \end{bmatrix}$ 来代替 KNCLS 中的 \mathbf{M} 和 \mathbf{r} [24], 其中 $\mathbf{E} = (1, 1, \dots, 1)^T$ 为 p 维的向量; δ (典型的可取 1×10^{-5}) 用来控制丰度和为 1 的收敛速度, δ 越小, 求解的精度越高, 但需要的收敛时间也更长。用 \mathbf{N} 和 \mathbf{s} 替代 KNCLS 中的 \mathbf{M} 和 \mathbf{r} , 得到 KFCLS 关系式:

$$\hat{\boldsymbol{\alpha}}^{\text{KFCLS}}(\mathbf{r}) = (K(\mathbf{N}, \mathbf{N}))^{-1} K(\mathbf{N}, \mathbf{s}) - (K(\mathbf{N}, \mathbf{N}))^{-1} \boldsymbol{\lambda} \quad (19)$$

$$\boldsymbol{\lambda} = K(\mathbf{N}, \mathbf{s}) - K(\mathbf{N}, \mathbf{N}) \hat{\boldsymbol{\alpha}}^{\text{KFCLS}}(\mathbf{s}) \quad (20)$$

式中, $\boldsymbol{\lambda}$ 和 δ 这两个参数可分别实现“丰度非负”和“丰度总和为 1”这两个约束条件。

3 实验与分析

3.1 实验数据

本文选择机载可见/近红外成像光谱仪 (airborne visible/infrared imaging spectrometer, AVIRIS) 1997-06-19 获取的国内华达州 CU-PRITE 矿区的成像光谱数据为实验数据。AVIRIS 数据是典型的高光谱数据, 它覆盖全反射光谱区域 ($0.4 \sim 2.5 \mu\text{m}$), 共有 224 个波段, 平均光谱分辨率为 10 nm, 地面分辨率约为 20 m。从所获取的高光谱遥感图像数据中截取 548 像素 \times 511 像素的子区作为研究区数据, 该地区矿物类型主要有明矾石、高岭石、方解石、云母、玉髓和水铵长石等 [25]。图 1 为研究区高光谱图像立方体及矿物蚀变分布图。

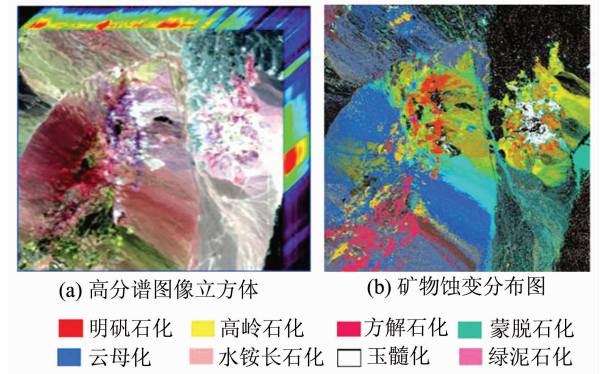


图 1 研究区高光谱图像立方体及矿物蚀变分布图

Fig. 1 Hyperspectral Image Cube and Mineral Maps

由于数据的空间分辨率较低, 且地面矿物复杂多样, 故图像中混合像元较多, 适合高光谱解混实验。实验前先对其进行了大气校正, 选用短波红外的 50 个连续波段 (波段 172 ($1.9908 \mu\text{m}$) ~ 波段 221 ($2.4790 \mu\text{m}$)) 进行实验。

3.2 实验方法及结果分析

实验中的端元采用 USGS 权威网站公布的该地区的参考端元光谱 [26], 如 2 图所示 (为了清晰表示反射率变化, 对纵坐标进行了平移), 此端元比较准确, 有利于后续丰度反演方法的分析。

用 MATLAB 编程实现 KLSOSP、KNCLS 和 KFCLS 丰度反演算法, 其中的核函数都选择




图 2 参考端元光谱曲线

Fig. 2 Reference Endmember Spectral

使用广泛的径向基函数(radial basis function, RBF),其计算公式为:

$$k(x_i, x_j) = \exp(-\frac{1}{2}(\|x_i - x_j\|/\sigma^2)) \quad (21)$$

式中, x_i 和 x_j 分别为不同的样本; σ 为函数的宽度。核函数中对参数 σ 的选择需要经过多次实验才能确定较好的值,因 KFCLS 算法中通过 λ 和 δ 两个参数实现 ASC 和 ANC 约束条件, δ 是固定值(本文中取 1×10^{-5}),导致 KFCLS 中的参数 σ 与 KLSOSP 和 KNCLS 中的参数 σ 相比要小得多。最终,确定 KLSOSP、KNCLS 和 KFCLS 中的参数 σ 分别为 2 000、2 000 和 0.5。

对 KLSOSP、KNCLS 和 KFCLS 与 LSOSP、NCLS 和 FCLS 进行丰度反演对比实验。对实验结果从解混矿物丰度图和解混均方根误差图像两个方面进行分析。

1) KLSOSP、KNLS、KFCLS 与 LSOSP、NLS、FCLS 解混矿物丰度图分析。限于篇幅,本文仅列出明矾石和高岭石两种矿物的丰度图。图 3~图 5 分别是用 LSOSP 和 KLSOSP、NCLS 和 KNCLS、FCLS 和 KFCLS 解混得到的明矾石和高岭石丰度图。丰度图中色调越亮的部分,表明矿物在该位置的比例越大。

从图 3~图 5 可以清楚地看出,用 KLSOSP、KNCLS 和 KFCLS 方法解混得到的明矾石和高岭石丰度图较清晰,与矿物分布图的吻合度也更好。这 3 种核化方法解混的效果明显优于其对应的 LSOSP、NCLS 和 FCLS 方法。

对丰度图进行统计分析的结果表明,LSOSP 和 KLSOSP 解混得到的矿物丰度有小于 0 或大于 1 的情况,这与实际情况不符;附加丰度非负约束条件之后,NCLS 和 KNCLS 解混得到的矿物丰度都大于等于 0;附加全约束条件之后,




图 3 利用 LSOSP、KLSOSP 解混得到的明矾石、高岭石丰度图

Fig. 3 Alunite, Kaolinite Abundance Maps Produced by LSOSP and KLSOSP




图 4 利用 NCLS、KNCLS 解混得到的明矾石、高岭石丰度图

Fig. 4 Alunite, Kaolinite Abundance Maps Produced by NCLS and KNCLS

FCLS 和 KFCLS 的丰度都在 0~1 之间。由此可见,附加约束条件有利于提高矿物丰度反演的精度。

2) KLSOSP、KNLS、KFCLS 与 LSOSP、NLS、FCLS 解混均方根误差分析。均方根误差(root mean square error, RMSE)计算公式为:

$$RMSE = | \sum (n^2 / N) |^{1/2} \tag{22}$$

式中, n 为式(1)中的模型误差; N 为像素总数。

图 6 是用 KLSOSP、KNCLS 和 KFCLS 解混

之后的均方根误差图像。误差图像中的色调越亮,误差就越大;色调暗并且均匀分布时,便达到了 RMSE 尽可能小的要求。




图 5 利用 FCLS、KFCLS 解混得到的明矾石、高岭石丰度图

Fig. 5 Alunite, Kaolinite Abundance Maps Produced by FCLS and KFCLS




图 6 KLSOSP、KNCLS、KFCLS 解混之后的均方根误差图像

Fig. 6 RMSE Images Produced by KLSOSP,KNCLS,KFCLS

从图 6 可以很明显地看出,KFCLS 的误差图像中亮像素最少,灰度分布最均匀;KLSOSP 的误差图像中亮像素最多;KNCLS 的误差图像中亮像素的数量介于 KLSOSP 和 KFCLS 之间。由此可以看出,KFCLS 解混的精度最高,其次是 KNCLS,而 KLSOSP 解混的精度最低。表 1 列出 KLSOSP、KNCLS 和 KFCLS 与 LSOSP、NCLS 和 FCLS 解混的均方根误差对比情况。

由表 1 可以看出,KLSOSP、KNCLS 和 KFCLS 解混的 RMSE 的最大值与均值分别小于对应的 LSOSP、NCLS 和 FCLS。这进一步说明了 KLSOSP、KNCLS 和 KFCLS 方法分别优于其对应的 LSOSP、NCLS 和 FCLS 方法,且附加约束条件有利于提高丰度反演的精度。

4 结 语

本文利用核方法,分别核化 OSP、LSOSP、NCLS 和 FCLS 算子,构建 KOSP、KLSOSP、KNCLS 和 KFCLS 高光谱图像混合像元分解模型。KLSOSP、KNCLS 和 KFCLS 与 LSOSP、NCLS 和 FCLS 高光谱遥感图像解混对比实验的结果表明:对于混合像元广泛存在的高光谱遥感图像来说,利用 KLSOSP、KNCLS 和 KFCLS 进行丰度反演的效果要优于对应的 LSOSP、NCLS 和

表 1 KLSOSP、KNCLS、KFCLS 与 LSOSP、NCLS、FCLS 解混均方根误差对比

Tab. 1 Comparing RMSE of KLSOSP,KNCLS, KFCLS and LSOSP,NLS,FCLS

RMSE	KLSOSP/ LSOSP	KNCLS/ NCLS	KFCLS/ FCLS
最大值	0.014 7/	0.006 6/	0.003 4/
	0.065 3	0.021 4	0.007 3
	0.006 1/	0.003 1/	0.001 7/
均值	0.027 1	0.009 2	0.003 0

FCLS方法;附加约束条件有利于提高丰度反演的精度。

参 考 文 献

- [1] Li Deren, Tong Qinxi, Li Rongxing, et al. Current Issues in High-resolution Earth Observation Technology[J]. *Sci China (Earth Sci)*, 2012, 42(6): 805-813(李德仁, 童庆禧, 李荣兴, 等. 高分辨率对地观测的若干前沿科学问题[J]. 中国科学(地球科学), 2012, 42(6): 805-813)
- [2] Chang C I. Hyperspectral Data Processing: Algorithm Design and Analysis[M]. New York: John Wiley and Sons Inc, 2013
- [3] Zhang Liangpei, Huang Xin. Advanced Processing Techniques for Remotely Sensed Imagery[J]. *Journal of Remote Sensing*, 2009, 13(4): 559-569
- [4] Rosin P L. Robust Pixel Unmixing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, 39(9): 1 978-1 983
- [5] Pu Hanye, Wang Bin, Zhang Liming. Simplex Geometry-based Abundance Estimation Algorithm for Hyperspectral Unmixing [J]. *Sci China (Info Sci)*, 2012, 42(8): 1 019-1 033(普晗晔, 王斌, 张立明. 基于单形体几何的高光谱遥感图像解混算法[J]. 中国科学(信息科学), 2012, 42(8): 1 019-1 033)
- [6] Wirasakti S, Zein R A, Mafazi F. Comparative Study of Land Cover Linear Spectral Mixture Analysis (LSMA) Model on Multispectral and Hyperspectral Imagery[C]. The 34th Asian Conference on Remote Sensing, Bali, Indonesia, 2013
- [7] Zhao Chunhui, Xiao Jianyu. An Abundance Inversion Algorithm Based on Mutual Information Weighted Least Square Error[J]. *Journal of Shenyang University Natural Science*, 2014, 26(1): 45-49(赵春晖, 肖健钰. 一种利用互信息加权的最小二乘法丰度反演算法[J]. 沈阳大学学报(自然科学), 2014, 26(1): 45-49)
- [8] Tang Xiaoyan, Gao Kun, Ni Guoqiang. Nonlinear Spectral Unmixing of Hyperspectral Images[J]. *Remote Sensing Technology and Application*, 2013, 28(4): 731-738(唐晓燕, 高昆, 倪国强. 高光谱图像非线性解混方法的研究进展[J]. 遥感技术与应用, 2013, 28(4): 731-738)
- [9] Camps-Valls G, Bruzzone L. Kernel Methods for Remote Sensing Data Analysis [M]. New York: John Wiley & Sons Ltd, 2009
- [10] Hosseini S A, Ghassemian H. A New Fast Algorithm for Multiclass Hyperspectral Image Classification with SVM[J]. *International Journal of Remote Sensing*, 2011, 32(23): 8 657-8 683
- [11] Broadwater J, Banerjee A. Mapping Intimate Mixtures Using an Adaptive Kernel-based Technique [C]. The 3rd Workshop on Hyperspectral Signal Processing: Evolution in Remote Sensing, Wuhan, 2011
- [12] Liu Tingting, Lin Hui, Zhang Liangpei, et al. SVM-relevance-feedback and Semantic-extraction-based RS Image Retrieval[J]. *Geomatics and Information Science of Wuhan University*, 2012, 37(4): 415-418(刘婷婷, 林珏, 张良培, 等. 利用 SVM 相关反馈和语义挖掘的遥感影像检索[J]. 武汉大学学报·信息科学版, 2012, 37(4): 415-418)
- [13] Wang Xiaofei, Zhang Junping, Zhang Ye. Unmixing Algorithm of Hyperspectral Images[J]. *Journal of Infrared Millim Waves*, 2010, 29(3): 210-216(王晓飞, 张钧萍, 张晔. 高光谱图像混合像元分解算法[J]. 红外与毫米波学报, 2010, 29(3): 210-216)
- [14] Tan Xiong, Yu Huchu, Zhang Liangpei, et al. Nonlinear Mixed Pixel Decomposition of Hyperspectral Imagery Based on Kernel SVM[J]. *Optics and Precision Engineering*, 2014, 22(7): 1 912-1 920(谭熊, 余旭初, 张鹏强, 等. 基于多核支持向量机的高光谱影像非线性混合像元分解[J]. 光学精密工程, 2014, 22(7): 1 912-1 920)
- [15] Kwon H, Nasrabadi N M. Kernel Orthogonal Subspace Projection for Hyperspectral Signal Classification [J]. *IEEE Geoscience and Remote Sensing*, 2005, 43(12): 2 952-2 962
- [16] Liu K H, Wong E, Du E Y, et al. Kernel-based Linear Spectral Mixture Analysis[J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(1): 129-133
- [17] Wang Ting, Du Bo, Zhang Liangpei. A Local Information-based Kernelized OSP Method for Target Detection[J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(2): 200-204(王挺, 杜博, 张良培. 顾及局域信息的核化正交子空间投影目标探测方法[J]. 武汉大学学报·信息科学版, 2013, 38(2): 200-204)
- [18] Zhao Chunhui, You Jia, Li Xiaohui. An Orthogonal Subspace Projection Anomaly Detection Algorithm Based on Adaptive Kernel Method[J]. *Journal of Natural Science of Heilongjiang University*, 2012, 29(2): 254-259(赵春晖, 尤佳, 李晓慧. 基于自适应核方法的正交子空间投影异常检测算法[J]. 黑龙江大学(自然科学学报), 2012, 29(2): 254-259)
- [19] Bajorski P. Analytical Comparison of the Matched Filter and Orthogonal Subspace Projection Detectors for Hyperspectral Images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(7): 2 394-2 402
- [20] Capobianco L, Garzelli A, Camps-Valls G. Target

Detection with Semisupervised Kernel Orthogonal Subspace Projection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(11): 3 822-3 833

[21] Fauvel M, Chanussot J, Benediktsson J A. Kernel Principal Component Analysis for the Classification of Hyperspectral Remote Sensing Data over Urban Areas[J]. *EURASIP Journal on Advances in Signal Processing*, 2009, 5(1): 1-14

[22] Lin Na, Yang Wunian, Wang Bin. Hyperspectral Image Feature Extraction via Kernel Minimum Noise Fraction Transform[J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(8): 988-992 (林娜, 杨武年, 王斌. 高光谱遥感影像核最小噪声分离变换特征提取[J]. 武汉大学学报·信息科学版, 2013, 38(8): 988-992)

[23] Molero J M, Garzón E M, García I. Anomaly Detection Based on a Parallel Kernel RX Algorithm for Multicore Platforms[J]. *Journal of Applied Remote Sensing*, 2012, 6(1): 3 542-3 552

[24] Broadwater J, Chellappa R, Banerjee A, et al. Kernel Fully Constrained Least Squares Abundance Estimates[C]. *Geoscience and Remote Sensing Symposium, IGARSS, United States*, 2007

[25] Swayze G A, Clark R N, Goetz A F H, et al. Mapping Advanced Argillic Alteration at Cuprite, Nevada, Using Imaging Spectroscopy[J]. *Economic Geology*, 2014, 109(5): 1 179-1 221

[26] Nevada. Ground-truthing AVIRIS Mineral Mapping at Cuprite[OL]. <http://speclab.cr.usgs.gov>, 2015

Using Kernel Method to Linearly Un-mixing Hyperspectral Pixel

LIN Na^{1,2} YANG Wunian² WANG Bin³

- 1 School of Civil Engineering, Chongqing Jiaotong University, Chongqing 400074, China
- 2 Key Laboratory of Geoscience Spatial Information Technology, Ministry of Land and Resources, Chengdu University of Technology, Chengdu 610059, China
- 3 Chongqing Geomatics Center, Chongqing 401121, China

Abstract: In order to improve the accuracy of hyperspectral pixel un-mixing, a Kernel based pixel un-mixing method was proposed in this paper. By kernelizing orthogonal subspace projection(OSP)operator, least squares OSP(LSOSP)operator, nonnegative constrained least squares(NCLS)operator and fully constrained least squares(FCLS)operator respectively, the authors established Kernel OSP(KOSP), Kernel LSOSP(KLSOSP), Kernel NCLS(KNCLS)and Kernel FCLS(KFCLS)to hyperspectral imagery pixel un-mixing. The comparison experiments of abundance inversion by using KLSOSP, KNCLS, KFCLS and LSOSP, NCLS, FCLS to CUPRITE AVIRIS data were carried out. The results show that for heavily mixed hyperspectral images, the pixel un-mixing accuracy of Kernels based KLSOSP, KNCLS and KFCLS is higher than that of LSOSP, NCLS and FCLS. Meanwhile, the constraint conditions can improve the accuracy of abundance estimates.

Key words: hyperspectral remote sensing; Kernel trick; pixel un-mixing; OSP

First author: LIN Na, PhD, associate professor, specializes in hyperspectral remote sensing. E-mail:linnawb@126.com

Foundation support: The National Natural Science Foundation of China, No. 41071265; the Science & Technology Research Project of Chongqing Municipal Education Commission, No. KJ1400325; the Open Fund of State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, No. 13R03; the Doctoral Foundation of Chongqing Jiaotong University, No. 2012kjc2-011; the Chongqing Research Program of Basic Research and Frontier Technology, No. cstc2015jcyjBX0023.