光电技术及应用

DOI：10.16818/j.issn1001－5868.2024052601

基于自编码器与多尺度空-谱特征编码的高光谱图像解混算法

张承弼，杨华东*，李诗慧，陈丽媛

（沈阳理工大学 信息科学与工程学院，沈阳 110159）

摘　要： 基于自编码器的高光谱解混方法过度关注高光谱图像中的空间信息或光谱信息，而忽略了空间信息、光谱信息的均衡提取。文章提出一种基于自编码器与多尺度空-谱特征编码的高光谱图像解混方法。该方法利用 CNN 编码器进行多尺度解混特征提取，Transformer 编码器接收多尺度解混特征，利用子 Transformer 编码器和全局 Transformer 编码器解耦空间和光谱之间的依赖性。为验证所提出方法的性能，在两个真实数据集上进行实验和对比。研究结果表明，所提出的解混算法可以提高高光谱图像解混精度。

关键词： 高光谱图像；光谱解混；自编码器；CNN；Transformer

中图分类号： TN762；TP751　**文章编号：** 1001－5868(2024)06－0925－06

Hyperspectral Image Unmixing Algorithm Based on Autoencoder and Multi-scale Spatial-Spectral Feature Encoding

ZHANG Chengbi，YANG Huadong，LI Shihui，CHEN Liyuan

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

Abstract： Most hyperspectral unmixing methods based on autoencoders mainly focus either on the spatial information or on the spectral information，while ignoring the balance extraction of them. To address this issue，we propose a hyperspectral image unmixing method based on autoencoders and multi-scale spatial-spectral feature encoding. This method utilizes a CNN encoder for multi-scale unmixing feature extraction. The Transformer encoder receives the multi-scale unmixing features. It further utilizes sub-Transformer encoders and a global Transformer encoder to decouple the dependence between spatial and spectral information. Experimental analysis is conducted on two real datasets to validate the performance of the proposed method. The results demonstrate that the proposed unmixing algorithm can improve the accuracy of hyperspectral image unmixing.

Key words： hyperspectral images；spectral unmixing；autoencoder；CNN；Transformer

0　引言

近年来，高光谱遥感技术广泛应用于精准农业、地质勘矿、环境监测和文物保护等领域，并产生了显著的社会经济效益[1]。然而，受自然界地物多样性影响和成像光谱仪空间分辨率的制约，混合像元问题在高光谱遥感图像中普遍存在，已经成为影响高光谱图像解译的重要因素。

光谱解混也称为混合像元分解，旨在将混合像元的光谱分解为各类地物光谱组分以及相对应的丰

收稿日期：2024－05－26.

基金项目：辽宁省属本科高校基本科研业务费专项资金项目(LJ212410144018，SYLUGXRC202258).

* **通信作者：**杨华东

度占比[2]。前者称为端元提取，后者称为丰度估计。光谱解混前需要确定光谱的混合模型，通常将其分为线性混合模型(Linear Mixed Model，LMM)和非线性混合模型。LMM 简单、高效，广泛应用于光谱解混领域[3]。基于 LMM 的传统解混算法根据设计思路可分为两类：几何学方法和统计学方法。典型几何学方法主要包括 PPI[4]，N-FINDR[5]和 VCA[6]等；统计学方法采用统计推理方式处理解混问题，主要包括独立成分分析、依赖成分分析和贝叶斯分析等。上述方法通常先提取端元，后进行丰度反演。因此，端元提取过程中产生的误差会传递累积至丰度反演过程中，从而导致解混精度降低。对此，研究者们提出盲解混方法，将端元提取和丰度反演同时进行以降低累积误差[7]。

随着深度学习的发展，自编码神经网络在高光谱解混领域得到了广泛关注。Su 等[8]引入非负稀疏自编码网络以减弱异常值对端元提取和丰度估计的影响。Palsson 等[9]验证了不同自编码网络结构对解混精度的影响。Jin 等[3]将生成器的隐藏层与初始化的丰度进行对抗训练，在重构误差与对抗误差的同步优化中提升解混性能。为充分利用高光谱图像的空间信息，Palsson 等[10]采用卷积自编码网络对高光谱图像块进行空间解混。Gao 等[11]通过端到端训练两个卷积神经网络(Convolutional Neural Networks，CNN)级联自动编码器，提出了循环一致性解混网络。

CNN 能够有效地捕捉图像中的局部特征，但其存在感受野受限的问题。Transformer 使用了自注意力机制，能够更好地捕捉长距离依赖关系[12]。Ghosh 等[13]提出 Self-Patch 注意力机制并将 Transformer 应用于自编码高光谱解混网络。Yang 等[14]将 Swin-Transformer 引入高光谱解混领域并提出 UST 网络。这些方法虽然展现出良好的解混能力，但它们只关注高光谱图像中的空间信息，或仅关注高光谱图像中的光谱信息，而忽略了空间特征信息和光谱特征信息的均衡提取。

为充分利用高光谱遥感图像“图谱合一”的显著特征，提出了基于自编码器与多尺度的空-谱特征编码的高光谱图像解混算法。该算法利用 CNN 编码器建立多尺度空间波段组特征，并输出到 Transformer 编码器中，进行多尺度光谱空间特征融合。综合利用 CNN 和 Transformer 两种网络的特性，使得解码器可解译出更精确的端元和丰度信息，从而提升高光谱图像解混精度。

1 线性混合模型

线性混合模型的数学表达式为：

$$\boldsymbol{Y}=\boldsymbol{E}\boldsymbol{A}+\boldsymbol{N} \tag{1}$$

$$\text{st.}\begin{cases}\boldsymbol{A}\geqslant 0\\ 1_P^{\mathrm{T}}\boldsymbol{A}=1_S^{\mathrm{T}}\end{cases} \tag{2}$$

式中，$\boldsymbol{Y}\in R^{B\times S}$ 是高光谱图像 $\boldsymbol{I}\in R^{B\times H\times W}$ 的二维矩阵形式，B 是高光谱图像波段数，H 是图像的行数，W 是图像的列数，$S=H\cdot W$ 是图像的像元个数。$\boldsymbol{E}\in R^{B\times P}$ 是 P 个端元向量按列排列而成的端元矩阵，$\boldsymbol{A}\in R^{P\times S}$ 是丰度矩阵，且满足“非负性”与“和为一”约束，$\boldsymbol{N}\in R^{B\times S}$ 代表可能的噪声。

2 基于自编码器与多尺度的空-谱特征编码的高光谱图像解混算法

2.1 高光谱解混网络框架

所提出的高光谱图像解混网络包括编码器和解码器两个部分，具体解混网络结构如图 1 所示。编码器部分包括 CNN 编码器和 Transformer 编码器。其中，CNN 编码器从输入的原始高光谱图像提取出空间-光谱波段组特征，Transformer 编码器将 CNN 编码器提取的特征进行融合并输入到解码器中，解译出端元信息和丰度信息，从而实现融合空间-光谱特征信息的高光谱解混。

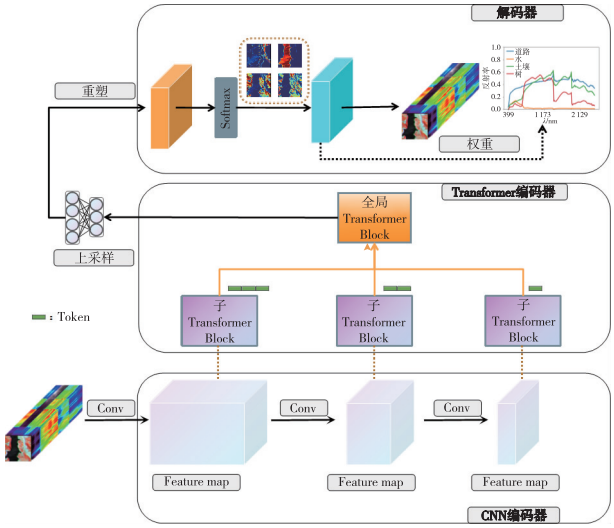


图 1 高光谱解混网络框架

2.2 CNN 编码器

在 CNN 编码器中，采用 1×1 的卷积对原始高光谱图像在波段维度进行多次下采样操作，但不改

变空间维度信息。为了网络稳定，防止过拟合和增强网络非线性拟合能力，在采样中添加了 Batch Normalization（BN），Dropout 和 Leaky ReLU 操作。选择最后三次下采样 Feature map 作为 CNN 编码器提取的多尺度空间波段组解混特征。第一级下采样输出的 Feature map 为 $\boldsymbol{F}_1 \in R^{72\times H\times W}$，第二级下采样输出的 Feature map 为 $\boldsymbol{F}_2 \in R^{48\times H\times W}$，第三级下采样输出的 Feature map 为 $\boldsymbol{F}_3 \in R^{24\times H\times W}$。多级下采样 CNN 编码器的网络结构参数见表 1。在 CNN 编码器中，卷积操作可以有效提取判别性的高光谱图像特征信息，而多级波段下采样处理则赋予了 CNN 编码器提取光谱特征信息的能力，为后续 Transformer 编码器提供解混特征基础。

表 1　CNN 编码器网络参数

层	操作	核	输入通道数	输出通道数
Layer1	Conv 2D	1×1	B	128
	BN			
	Dropout			
	Leaky ReLU			
Layer2	Conv 2D		128	108
	BN			
	Leaky ReLU			
Layer3	Conv 2D		108	72
	BN			
	Leaky ReLU			
Layer4	Conv 2D		72	48
	BN			
	Leaky ReLU			
Layer5	Conv 2D		48	24
	BN			

2.3　Transformer 编码器

Transformer 编码器包含三个子 Transformer Block 和一个全局 Transformer Block。CNN 编码器输出的三级下采样 Feature map 分别输入到三个子 Transformer Block，全局 Transformer Block 整合三个子 Transformer Block 进行最后的解混特征解耦。四个 Transformer Block 均采用和文献[15]一致的特征编码方式和多头自注意机制（Multiheaded Self-Attention，MSA）。首先，将高光谱图像的 Feature map 分割成 $Q=h\cdot w$ 个不重叠的 $Patch(x_i, i=1,2,\cdots,Q)$，每个 *Patch* 被映射成一个 *Token*。这些 *Token* 添加一个可学习的 *Clstoken* 后构成一个 *Patches* 序列 $\boldsymbol{z}_0$。最后，添加位置编码完成 Tokenization。其表达形式为：

$$\boldsymbol{z}_0=[z_{\text{cls}}, Vx_1, Vx_2, \cdots, Vx_Q]+Pos \tag{3}$$

式中，z_{cls} 代表 *Clstoken*，V 代表映射操作，*Pos* 代表位置编码。

Transformer Block 含有 MSA Block 和多层感知机（Multilayer Perceptron，MLP）Block。层归一化（Layernorm，LN）放置在每一个 Block 之前，残差连接放置在每一个 Block 之后。MLP 具有 GELU 激活函数的非线性层。Tokens 经过 L 层的 Transformer 编码器的公式化过程如下：

$$\boldsymbol{z}'_L=\text{MSA}(\text{LN}(\boldsymbol{z}_{L-1}))+\boldsymbol{z}_{L-1} \tag{4}$$

$$\boldsymbol{z}_L=\text{MLP}(\text{LN}(\boldsymbol{z}'_L))+\boldsymbol{z}'_L \tag{5}$$

在 *Token* 数目相同的情况下，每个子 Transformer Block 接收的 CNN Feature 的尺度不同，每个子 Transformer Block 的 *Token* 尺度也不同。大尺度 CNN Feature map 对应大的 Token，小尺度 CNN Feature map 对应小的 *Token*。因此，三个不同规格的子 Transformer Block 输出的 *Token* 的维度分别为：$Token_1 \in R^{1\times(72\cdot\frac{H}{h}\cdot\frac{W}{w})}$，$Token_2 \in R^{1\times(48\cdot\frac{H}{h}\cdot\frac{W}{w})}$ 和 $Token_3 \in R^{1\times(24\cdot\frac{H}{h}\cdot\frac{W}{w})}$。全局 Transformer Block 接收三种尺度的 *Tokens*，但 Transformer Block 内部的多头注意力需要具有相同维度的 *Token* 才能进行矩阵乘法。

Token 维度不一致问题可以通过 *Token* 尺度最大化或 *Token* 尺度最小化解决。*Token* 尺度最大化将三种 Token 拼接在一起，其特点是 *Token* 的数目保持不变，但 *Token* 的尺度变大为 $Token_L \in R^{1\times((72+48+24)\cdot\frac{H}{h}\cdot\frac{W}{w})}$，因此，进行矩阵乘法时需要更多的计算资源。最小化 *Token* 尺度以最小的 *Token* 尺度为基准规格，将其他规格的 *Token* 分割成多个基准规格的 $Token_s \in R^{1\times(24\cdot\frac{H}{h}\cdot\frac{W}{w})}$。

Transformer Block 中 MSA Block 的时间复杂度为[16]：

$$\Omega(\text{MSA})=4hwC^2+2(hw)^2C \tag{6}$$

式中，C 是 *Token* 的维度。为了便于比较两种方案的 MSA 时间复杂度，以最后一个子 Transformer Block 为例进行说明，最后一个子 Transformer Block 的 *Token*，$Token_3 \in R^{1\times(24\cdot\frac{H}{h}\cdot\frac{W}{w})}$，个数为 hw，维度是 C_0。采用最大化方案，输入到全局 Transformer Block 的 *Token*，$Token_L \in R^{1\times((72+48+24)\cdot\frac{H}{h}\cdot\frac{W}{w})}$，个数为 hw，维度是 $6C_0$。

$$\Omega_L(\text{MSA})=(12\times 12)hwC_0^2+12(hw)^2C_0 \tag{7}$$

采用最小化方案，输入到全局 Transformer Block 的 *Token*，$Token_s \in R^{1\times(24\cdot\frac{H}{h}\cdot\frac{W}{w})}$，个数为

$6hw$，维度是 C_0。

$$\Omega_s(\mathrm{MSA}) = (12\times 2)hwC_0^2 + (12\times 6)(hw)^2C_0 \quad (8)$$

实验中，$2C_0 > hw$，最小化 Token 方案的 MSA 时间复杂度较低。因此，本文采用最小化 Token 尺度方案，基准规格为 $Token_s$。该方案下全局 Transformer Block 输出 $Clstoken$ 的尺度为 $Clstoken_g \in R^{1\times(24\cdot\frac{H}{h}\cdot\frac{W}{w})}$。

在 Transformer 编码器中，Transformer 技术增强了解混网络空间解耦能力，提高了解混网络长距离的特征建模能力。多个子 Transformer Block 和全局 Transformer Block 的组合赋予了解混网络跨尺度的空间光谱解耦能力。因此，Transformer 编码器实现了平衡空间特征信息和多级光谱特征的信息提取。

2.4 解码器与损失函数

在解码器中，由全局 Transformer Block 输出的 $Clstoken$ 被上采样并重塑为丰度维度大小的矩阵，如图 1 中黄色立方体所示。然后，应用 Softmax 来确保非负性与和为一约束并输出丰度信息。最后，通过如图 1 中蓝色立方体所示的无偏置卷积层输出重建的高光谱图像 $\hat{\boldsymbol{I}}$。其中，卷积层的最终权重为高光谱解混的端元信息。实验使用 VCA[6] 提取到的端元初始化卷积层的权值，以加快网络收敛。所提算法的损失函数由重构误差（Reconstruction Error，RE）损失函数和光谱角距离（Spectral Angle Distance，SAD）损失函数组成，公式为：

$$\boldsymbol{Loss}_{\mathrm{RE}}(\boldsymbol{I},\hat{\boldsymbol{I}}) = \frac{1}{H\cdot W}\sum_{i=1}^{H}\sum_{j=1}^{W}(\hat{\boldsymbol{I}}_{ij} - \boldsymbol{I}_{ij})^2 \quad (9)$$

$$\boldsymbol{Loss}_{\mathrm{SAD}} = \sum_{i=1}^{S}\arccos\left(\frac{\langle \boldsymbol{I}_i, \hat{\boldsymbol{I}}_i\rangle}{\|\boldsymbol{I}_i\|_2\|\hat{\boldsymbol{I}}_i\|_2}\right) \quad (10)$$

$$\boldsymbol{Loss} = \alpha\boldsymbol{Loss}_{\mathrm{RE}} + \beta\boldsymbol{Loss}_{\mathrm{SAD}} \quad (11)$$

式中，α 和 β 为正则化参数。

3 实验结果与分析

为评估本文解混算法性能，在两个真实高光谱数据集上进行实验，并将其实验结果与 CNNAEU[10]，DAEU[9]，CyCU[11]，DeepTrans[12] 四种解混算法进行对比。

3.1 评估指标

实验使用均方根误差（Root Mean Square Error，RMSE）计算估计丰度与参考丰度之间的误差，使用光谱角距离衡量提取端元与真实端元之间的相似性。两个评估指标的计算公式为：

$$RMSE(\boldsymbol{A},\hat{\boldsymbol{A}}) = \sqrt{\frac{1}{P\cdot S}\sum_{i=1}^{P}\sum_{j=1}^{S}(\boldsymbol{A}_{ij} - \hat{\boldsymbol{A}}_{ij})^2} \quad (12)$$

$$SAD(\boldsymbol{E},\hat{\boldsymbol{E}}) = \frac{1}{P}\sum_{i=1}^{P}\arccos\left(\frac{\langle \boldsymbol{E}_{(i)}, \hat{\boldsymbol{E}}_{(i)}\rangle}{\|\boldsymbol{E}_{(i)}\|_2\|\hat{\boldsymbol{E}}\|_2}\right) \quad (13)$$

式中，$\boldsymbol{A}$，$\hat{\boldsymbol{A}}$ 分别代表真实（参考）丰度和算法估计的丰度。$\boldsymbol{E}$，$\hat{\boldsymbol{E}}$ 分别代表真实（参考）端元和算法提取的端元。

3.2 真实数据集

Samson 数据集：该数据集有 952×952 个像元，156 个波段，波长覆盖范围为 401～889 nm。光谱分辨率高达 3.13 nm。原始图像太大，计算成本非常高，实验使用 95×95 像素子区域进行实验，该区域包含三种端元：土壤、树和水。

Jasper 数据集：该数据集有 512×614 个像元，224 个波段，波长覆盖范围为 380～2 500 nm。光谱分辨率高达 9.46 nm。实验中使用 100×100 像素的子图像。在移除波段 1～3，108～112，154～166 和 220～224 后，保留 198 个波段。该数据集包含四种端元：道路、土壤、水和树。

3.3 实验结果与分析

3.3.1 Samson 数据集实验

Samson 数据集的端元提取和丰度估计量化实验结果如表 2 所示，丰度信息可视化实验结果如图 2 所示。正如表中数据所示，所提出的方法获得的平均 SAD 值和 RMSE 值均小于其他方法。对比次优结果，本文方法在平均 SAD 评价指标上提升 3.2%，在 RMSE 评价指标上提升 6.3%。在单个端元提取评价结果中，对于土壤端元和水端元，本文方法提取的结果最接近真实端元。对于树端元，CyCU 提取结果最优。在丰度信息可视化实验结果中，DeepTrans 和本文方法具有 Transformer 长距离特征建模优势，呈现出更好的色彩饱和度。对比 GroudTruth（GT），所提出的基于自编码器与多尺度空-谱特征编码的高光谱解混算法的结果更接近真实分布。验证了 Transformer 编码器利用多尺度的 CNN 特征能够解译出更精准的丰度信息。

表 2 Samson 数据集的端元提取和丰度估计量化实验结果

评估指标		CNNAEU	CyCU	DAEU	DeepTrans	本文算法
SAD	土壤	0.060 6	0.012 7	0.060 6	0.038 3	0.009 8
	树	0.039 9	0.025 3	0.039 9	0.056 1	0.042 3
	水	0.127 9	0.063 7	0.127 9	0.077 4	0.046 3
平均 SAD		0.076 1	0.033 9	0.036 0	0.057 3	0.032 8
RMSE		0.193 7	0.174 2	0.211 6	0.421 3	0.163 3

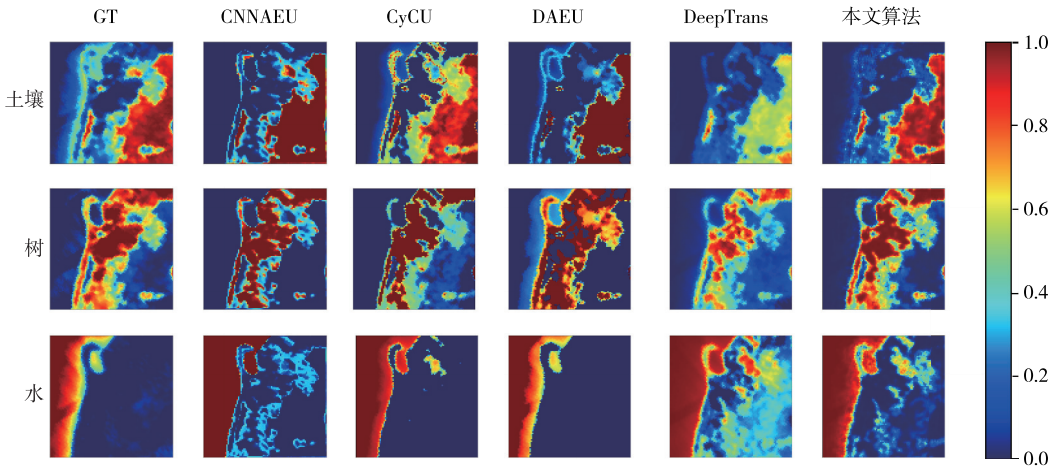


图 2　Samson 数据集的丰度估计可视化实验结果

3.3.2　Jasper 数据集实验

Jasper 数据集的端元提取和丰度估计量化实验结果如表 3 所示，丰度估计可视化实验结果如图 3 所示，其中图中右侧刻度条中的颜色代表端元所占的比例的大小。所提出的方法在端元提取的平均 SAD 值和丰度估计的 RMSE 值小于其他方法。道路端元的提取在 Jasper 数据集中是一个挑战任务。本文方法在道路端元提取时实验效果优于其他方法。对比次优结果，本文方法在平均 SAD 评价指标上提升 24.0%，在 RMSE 评价指标上提升 14.2%。对比丰度信息可视化实验结果，CNNAEU，CyCU 和 DAEU 在道路边缘细节上的丰度信息良好，但其他区域与 GT 差别较大。本文方法提取的土壤和树端元的丰度信息更加接近真实分布，如图 3 中红色方框区域所示。对于水端元，DAEU 蓝色区域是较为纯净的，但红色区域过于嘈杂。量化和可视化的实验结果均证明所提出的方法可以捕捉多级解混特征，并且解译出空间维度和光谱的耦合性，有效地实现了解混精度的提升。

表 3　Jasper 数据集的端元提取和丰度估计量化实验结果

评估指标		CNNAEU	CyCU	DAEU	DeepTrans	本文算法
SAD	道路	0.144 2	0.049 4	0.130 2	0.052 1	0.047 2
	土壤	0.124 6	0.028 4	0.076 9	0.093 7	0.065 1
	树	0.073 4	0.037 4	0.025 1	0.025 5	0.039 4
	水	0.060 7	0.145 9	0.028 5	0.045 5	0.046 4
平均 SAD		0.100 7	0.065 3	0.065 1	0.054 2	0.049 5
RMSE		0.607 5	0.115 4	0.545 8	0.102 8	0.088 2

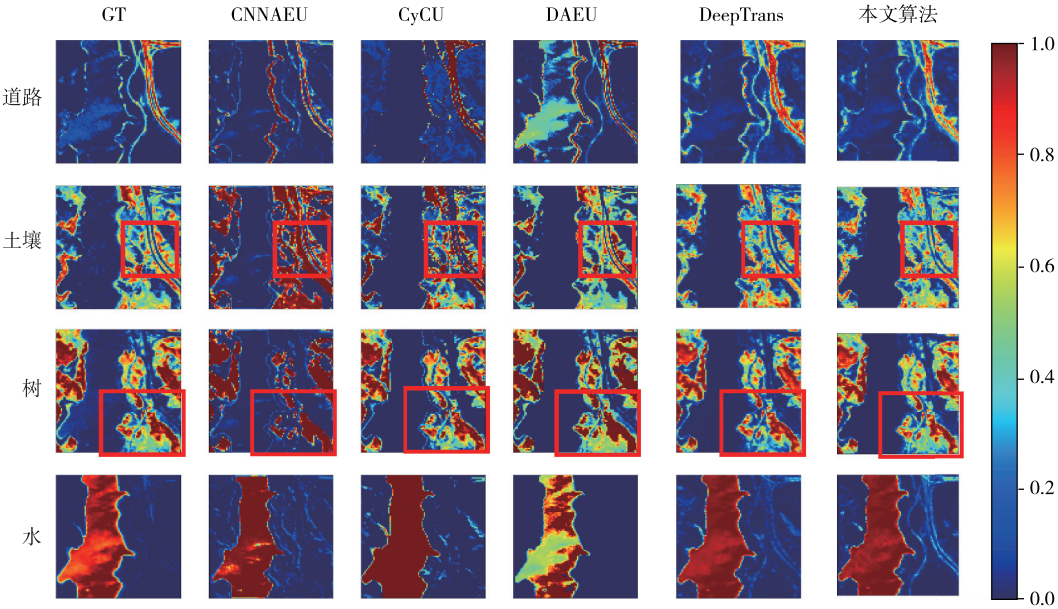


图 3　Jasper 数据集的丰度估计可视化实验结果

4 结论

针对高光谱数据立方体的空间和波段特征信息相关性，提出基于自编码与多尺度空-谱特征编码的高光谱图像解混算法。该方法使用CNN编码器建立高光谱图像多级金字塔波段组特征，使用Transformer编码器对多尺度的解混特征进行有效融合，使得网络能够解耦空间和光谱之间的依赖性，实现更精准的解混效果。在两个真实的数据集上进行实验数据对比，结果验证了本文算法可以提升高光谱图像的光谱分解精度。

参考文献：

[1] 童庆禧，张 兵，张立福. 中国高光谱遥感的前沿进展[J]. 遥感学报，2016，20(5)：689-707.
Tong Qingxi，Zhang Bing，Zhang Lifu. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing，2016，20(5)：689-707.

[2] Keshava N，Mustard J F. Spectral unmixing[J]. IEEE Signal Processing Magazine，2002，19(1)：44-57.

[3] 靳淇文，马 泳，樊 凡，等. 生成对抗网络的无监督高光谱解混[J]. 遥感学报，2023，27(8)：1964-1974.
Jin Qiwen，Ma Yong，Fan Fan，et al. Hyperspectral unmixing based on adversarial autoencoder network[J]. National Remote Sensing Bulletin，2023，27(8)：1964-1974.

[4] Boardman J W，Kruse F A，Green R O. Mapping target signatures via partial unmixing of AVIRIS data [C]// Summaries of the Fifth Annual JPL Airborne Earth Science Workshop，1995：127556070.

[5] Winter M E. N-FINDR：An algorithm for fast autonomous spectral end-member determination in hyperspectral data[J]. Proc. SPIE，1999，3753：266-275.

[6] 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.

[7] Palsson B，Sveinsson J R，Ulfarsson M O. Blind hyperspectral unmixing using autoencoders：A critical comparison[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing，2022，15：1340-1372.

[8] Su Y，Marinoni A，Li J，et al. Stacked nonnegative sparse autoencoders for robust hyperspectral unmixing [J]. IEEE Geoscience and Remote Sensing Letters，2018，15(9)：1427-1431.

[9] Palsson B，Sigurdsson J，Sveinsson J R，et al. Hyperspectral unmixing using a neural network autoencoder [J]. IEEE Access，2018，6：25646-25656.

[10] Palsson B，Ulfarsson M O，Sveinsson J R. Convolutional autoencoder for spatial-spectral hyperspectral unmixing[C]// IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium. IEEE，2019：357-360.

[11] Gao L，Han Z，Hong D，et al. CyCU-Net：Cycle-consistency unmixing network by learning cascaded autoencoders [J]. IEEE Transactions on Geoscience and Remote Sensing，2021，60：1-14.

[12] Vaswani A，Shazeer N，Parmar N，et al. Attention is all you need [J]. Advances in Neural Information Processing Systems，2017，30：6000-6010.

[13] Ghosh P，Roy S K，Koirala B，et al. Hyperspectral unmixing using transformer network[J]. IEEE Transactions on Geoscience and Remote Sensing，2022，60：1-16.

[14] Yang Z，Xu M，Liu S，et al. UST-Net：A U-shaped transformer network using shifted windows for hyperspectral unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing，2023，61：1-15.

[15] Dosovitskiy A，Beyer L，Kolesnikov A，et al. An image is worth 16×16 words：Transformers for image recognition at scale[J]. arXiv preprint arXiv：2010.11929，2020.

[16] Liu Z，Lin Y，Cao Y，et al. Swin transformer：Hierarchical vision transformer using shifted windows[C]// Proc. of the IEEE/CVF International Conf. on Computer Vision，2021：10012-10022.

作者简介：

张承弼(1992—)，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，硕士生导师，主要从事高光谱图像解译及智能信息处理方面的研究。