光电技术及应用

DOI：10.16818/j.issn1001－5868.20250219002

结合重叠光谱块嵌入和深度卷积的高光谱解混网络

李诗慧，杨华东*

（沈阳理工大学 信息科学与工程学院，沈阳 110159）

摘 要： 基于Transformer的高光谱解混方法通常将高光谱图像划分为固定大小且不重叠的小块，输入Transformer编码器后再通过解码器进行解混。然而，不重叠的块划分会割裂相邻像素间的相似信息，同时Transformer前馈层中的全连接结构也会丢失部分局部信息，从而影响解混精度。为缓解上述问题，文章提出一种改进的高光谱解混方法：采用重叠光谱块划分策略，并在Transformer前馈层中引入深度卷积。重叠划分保留了相邻块的局部连续性信息，而在前馈层中使用深度卷积则有助于补充局部细节特征。在多个数据集上的实验结果表明，相比原始方法，改进后的方法能够显著提升解混效果。

关键词： 高光谱遥感；混合像元分解；深度卷积；光谱块嵌入

中图分类号： TP317.5 **文章编号：** 1001－5868(2025)03－0508－07

Hyperspectral Unmixing Network Combined with Overlapping Spectral Patch Embedding and Deep Convolution

LI Shihui, YANG Huadong

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

Abstract: The hyperspectral unmixing method, based on Transformer, divides a hyperspectral image into small patches of fixed size without overlapping. The divided patches are then fed as inputs into the Transformer encoder and unmixed by a decoder. However, non-overlapping patch division eliminates similar information between neighboring pixels. Furthermore, some local information is lost in the Transformer feedforward layer, which affects the unmixing effect. In this study, we adopt an improved hyperspectral unmixing method with overlapping spectral patch division and deep convolution in the fully connected layer of Transformer. Hyperspectral imaging experiments show that the unmixing effect achieved by the improved method is more pronounced than that of the original method.

Key words: hyperspectral remote sensing; mixed pixel unmixing; deep convolution; spectral patch embedding

0 引言

高光谱遥感技术能够同时获取地面目标的光谱信息和空间信息[1-3]。然而，受限于成像过程中的空间分辨率，高光谱遥感图像中普遍存在混合像元现象。混合像元包括多种地物类型，严重影响了高光谱图像的精准信息提取。解决此问题的核心是对混合像元进行分解，以获取区域内不同类别地物的端元以及每种类别端元所对应的丰度[4-5]。

近年来，深度学习的快速发展为高光谱解混提供了新思路。凭借出色的数据推测能力，以自动编码器和卷积神经网络为代表的深度学习方法在高光谱解混领域取得了显著成果[4]。Gao等[6]提出采用循环一致性网络来进行高光谱解混的方法

收稿日期：2025－02－19.

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)；2024年度辽宁省教育厅基本科研计划项目(SYLUGXRC202258).

* **通信作者：**杨华东

(Cycle-Consistency Unmixing Network, CyCU-Net)，通过学习级联自编码器实现解混性能的提升。Drumetz等[7]提出利用端元束和组稀疏性诱导混合规范的高光谱图像解混技术(Collaborative Least Absolute Shrinkage and Selection Operator, Collab)，该方法提出了一种新的惩罚机制，但代价是它是非凸的。Heinz等[8]提出受限最小二乘法光谱解混方法(Fully Constrained Least Squares Unmixing, FCLSU)。Zhuang等[9]采用非负矩阵分解-二次最小体积的几何盲解混方法(Nonnegative Matrix Factorization-Quadratic Minimum Volume, NMF-QMV)，所提出的正则化参数选择标准具备一定的竞争力。Rasti等[10]通过提高丰度估计，使非混合问题对噪声具有鲁棒性，但需要使用卷积神经网络进行深度图像先验来估计分数丰度。Qu等[11]采用频谱解混的具有稀疏性的非绑定去噪自动编码器(untied Denoising Autoencoder with Sparsity for Spectral Unmixing, uDAS)，在处理高噪声数据时取得了较好的效果。Palsson等[12]提出第一个基于卷积神经网络(Convolutional Neural Network, CNN)的谱空间解混方法(Convolutional Neural Network Autoencoder Unmixing, CNNAEU)，该方法得到了较为不错的端元提取效果，但其解混得到的丰度为二进制形式。在此之后，Ghosh等[13]提出一种基于Transformer的高光谱解混方法(Deep Transformer Hypersperctal Unmixing, DeepTrans-HSU)，该方法使用CNN和Transformer编码器，采用多头块自注意力机制来捕获编码器中的远程依赖关系，使得高光谱图像的特征提取能力以及解混效果得到一定的提升[4]。但该方法采用的非重叠光谱块划分以及Transformer前馈层中逐点连接的全连接层会丢失部分局部信息。为解决这一问题，受Wang等[14]在目标检测领域的启发，本文基于相邻像素之间的光谱相似性，采用基于重叠光谱块嵌入和深度卷积的高光谱解混方法。通过在划分光谱块时重叠一部分来削弱固定块划分时的连续结构分裂带来的影响，同时在Transformer前馈层中补充必要的局部信息，进而提高解混性能。

1　工作原理

1.1　CNN编码器

CNN作为一种深度学习模型，已经在多个领域取得显著成功，尤其是在计算机视觉领域。CNN编码器主要由多个卷积层和池化层组成，用于将输入数据转化为高层次的特征表示。CNN通过卷积层提取输入数据中的局部特征，并通过池化层减少数据维度，从而实现高效的信息编码和特征提取。这些特征经过编码后，可以被进一步用于下游任务，如图像生成、分类或与解码器结合，完成更复杂的任务。

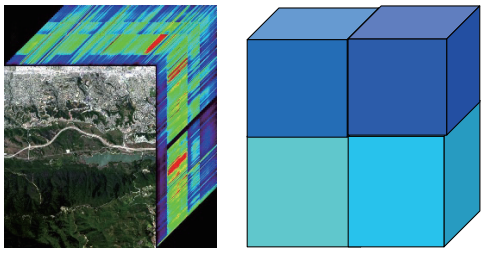
1.2　Transformer编码器

Transformer编码器由多头自注意力层、层归一化和前馈网络组成，并通过残差连接将多个编码器层堆叠在一起。Transformer编码器能捕获长距离之间的远程依赖关系，其中的多头注意力机制通过使用多个头对输入进行不同的变换将注意力机制进行多次并行化，每个头都有独立的查询(Query)、键(Key)和值(Value)矩阵，通过这些矩阵学习不同的表示方式。通过不同头的多角度信息，模型能够捕捉到更丰富的上下文信息。前馈层位于每个编码器层的自注意力模块后，通常由两层全连接神经网络组成，并应用ReLU激活函数来引入非线性变换。前馈层能进一步增强输入表示的能力，帮助每个位置的特征在不同维度上得到更丰富的表达，从而提高模型的表示能力。

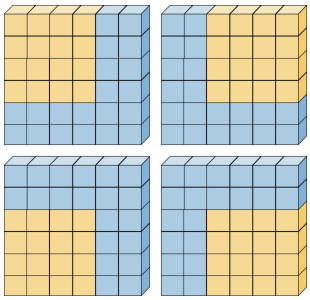
2　结合重叠光谱块嵌入和深度卷积的高光谱解混网络

2.1　重叠光谱块划分

为减弱固定大小光谱块划分带来的连续结构相似信息割裂的影响，实验采用重叠划分光谱块的方式，在将数据输入给Transformer编码器之前，通过将图像分割成若干个大小相同且有部分重叠的光谱块，进而保留相邻光谱块的局部信息，使得相邻像素之间的相似信息可以相互补充。如图1所示，卷积核大小设置为块大小，采用无填充的方式。



(a) 高光谱图像　　(b) 传统切块方式



（c）重叠切块方式

图1 重叠光谱块划分

2.2 采用深度卷积的前馈层

Transformer编码器前馈层由全连接层和激活函数构成，然而逐点连接的全连接层会丢失一部分局部信息。为解决这一问题，采用在前馈层的全连接层中添加深度可分离卷积的方法，补充前馈层中的细节信息。深度可分离卷积使得每个输入通道和卷积核一一对应进行卷积操作，每个输入通道都会有一个独立的卷积核。深度可分离卷积的卷积核大小设置为3，步长和填充均设置为1，采用深度卷积的前馈层如图2所示。

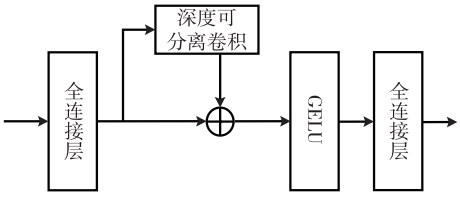


图2 采用深度卷积的前馈层

2.3 基于深度神经网络的高光谱图像解混

输入的高光谱图像大小为$H\times W\times B$，其中H为图像的高度，W为图像的宽度，B为图像的波段数。将高光谱图像输入CNN编码器，原始输入波段为B，CNN编码器卷积核大小为1×1，经过CNN编码器后输出的波段数为$(dim\times P)/patch^2$，其中dim代表维度，P是端元数，$patch$代表划分光谱块的大小。

将经过CNN编码器后的图像进行重叠光谱块划分，N为块总数，D为重叠光谱块划分后每个块的维度。划分后的光谱块与可学习类标记X_{learn}进行拼接，将拼接后的结果与位置标记X_{pos}进行加和操作，得到的结果输入给Transformer编码器，此部分的计算公式为：

$$Z=\left[X_{\text{learn}},X_1,X_2,\cdots,X_N\right]+X_{\text{pos}} \tag{1}$$

式中，Z代表输入给Transformer编码器的序列，X_1，X_2，$\cdots$，X_N代表进行重叠光谱划分后得到的N个块。

Transformer编码器由多头块自注意力机制和采用深度卷积的前馈层构成，此部分的公式化过程如下：

$$Z_L'=\text{MSA}\left(\text{LN}\left(Z_{L-1}\right)\right)+Z_{L-1} \tag{2}$$

$$Z_L=\text{DeepConv}\left(\text{LN}\left(Z_L'\right)\right)+Z_L' \tag{3}$$

式中，MSA代表多头自注意力，LN代表层归一化，DeepConv代表采用深度卷积的前馈层。

在经过两个Transformer编码器进行编码后，对结果进行上采样重塑操作后，使用Softmax函数保证解混结果满足丰度非负约束以及丰度和为一约束，关于约束的数学表达式为：

$$\begin{aligned}&\boldsymbol{Y}=\boldsymbol{EA}+\boldsymbol{N}\\&\begin{cases}\boldsymbol{A}\geqslant 0\\ 1_e^T\boldsymbol{A}=1_n^T\end{cases}\end{aligned} \tag{4}$$

式中，$\boldsymbol{Y}$代表矩阵形式的高光谱图像，$\boldsymbol{A}$代表丰度矩阵，$\boldsymbol{E}$代表端元矩阵，$\boldsymbol{N}$代表噪声，1_e代表端元向量，1_n代表1的n分量列向量。

最后，解混得到端元和丰度图。解混过程的框架图如图3所示。

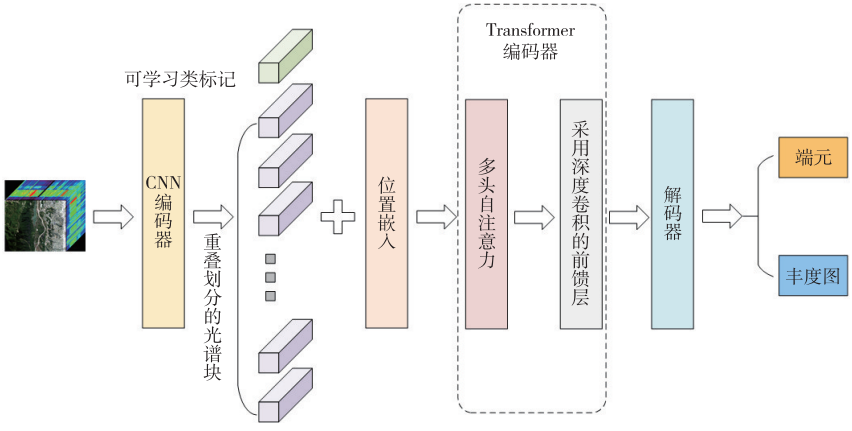


图3 结合重叠光谱块嵌入和深度卷积的高光谱解混网络框架图

3　实验结果与分析

为验证解混算法的有效性，使用三个数据集进行对比实验。为评价解混算法的优劣，利用估计丰度与地物真实丰度之间的均方根误差（RMSE）以及估计端元与真实端元之间的光谱角距离（SAD）评估解混效果。

均方根误差计算公式为：

$$RMSE\left(M,\hat{M}\right)=\sqrt{\frac{1}{RHW}\sum_{k=1}^{R}\sum_{i=1}^{H}\sum_{j=1}^{W}\left(\hat{\boldsymbol{M}}_{kij}-\boldsymbol{M}_{kij}\right)^2} \tag{5}$$

光谱角距离计算公式为：

$$SAD\left(\boldsymbol{S},\hat{\boldsymbol{S}}\right)=\frac{1}{R}\sum_{i=1}^{R}\arccos\left(\frac{\left\langle \boldsymbol{s}_{(i)},\hat{\boldsymbol{s}}_{(i)}\right\rangle}{\left\| \boldsymbol{s}_{(i)}\right\|_2\left\|\hat{\boldsymbol{s}}_{(i)}\right\|_2}\right) \tag{6}$$

式中，$\langle\cdot\rangle$代表内积，$\boldsymbol{s}_{(i)}$代表真实地物端元矩阵$\boldsymbol{S}$的第i列。

表 1 为本方法在训练模型时所设置的参数。

表 1　模型参数设置

参数	数据集		
	Samson	Apex	DC
学习率	6×10^{-3}	9×10^{-3}	6×10^{-3}
epoch	200	200	150
块大小	5	5	10
权重衰减	4×10^{-5}	4×10^{-5}	3×10^{-5}

3.1　Samson 数据集

Samson 数据集[15]是高光谱解混领域常见的公开数据集，具有 156 个波段，包含 95×95 个像元，波长范围为 401～889 nm，包含三个端元，分别是土壤、树木和水。在 Samson 数据集上解混得到丰度图如图 4 所示。图 5 是得到的端元光谱，可以看出在土壤、水这两个端元上提取效果贴合真实地物曲线。

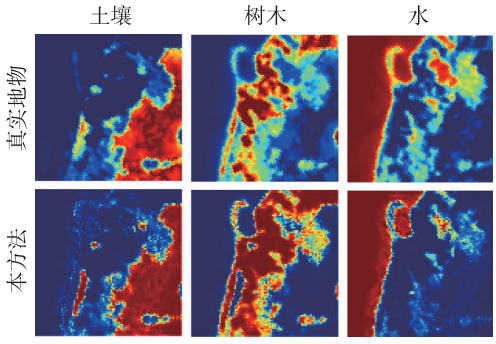
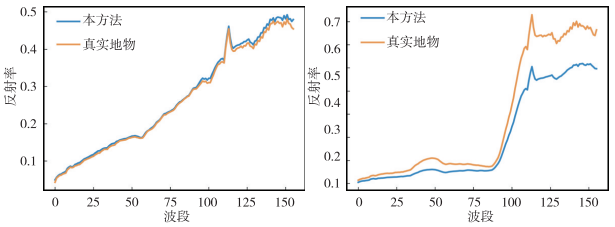
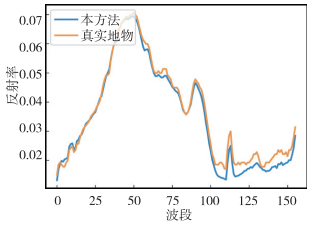


图 4　Samson 数据集解混丰度图



（a）土壤　　（b）树木



（c）水

图 5　Samson 数据集解混端元光谱

与 CyCU[6]，Collab[7]，FCLSU[8]，NMF-QMV[9]，UnDIP[10]，uDAS[11]，DeepTrans[13]七种方法对比，在 Samson 数据集上对比 RMSE 与 SAD 分别如表 2 和 3 所示。其中，每一类别的最优结果均通过黑色加粗显示，可以看出本方法在土壤上的 RMSE 结果最优，在其他地物对应的 RMSE 上均能达到平均水平。本方法的 SAD 无论是在各类地物上还是平均 SAD 均相比其他几种对比方法达到最优，本方法的平均 SAD 值为 0.04。

表 2　在 Samson 数据集上对比不同方法下的 RMSE

端元	CyCU	Collab	FCLSU	NMF-QMV	UnDIP	uDAS	DeepTrans	本方法
土壤	0.241 7	0.150 6	0.176 6	0.201 1	0.177 8	0.179 9	0.079 3	**0.068 7**
树木	0.138 6	**0.060 7**	0.065 3	0.146 6	0.133 0	0.138 3	0.066 1	0.106 8
水	0.265 4	0.118 1	0.149 2	0.206 3	0.209 6	0.230 3	**0.085 1**	0.130 0

表 3　在 Samson 数据集上对比不同方法下的 SAD

端元	CyCU	Collab	FCLSU	NMF-QMV	UnDIP	uDAS	DeepTrans	本方法
土壤	0.114 4	0.015 5	0.025 9	0.039 1	0.025 9	0.035 8	0.021 6	**0.009 7**
树木	0.151 7	0.083 2	0.096 1	0.123 9	0.074 8	0.096 0	0.075 3	**0.046 6**
水	0.208 1	0.140 2	0.155 4	1.520 1	0.155 4	0.152 7	0.105 7	**0.063 8**

3.2　Apex 数据集

Apex 数据集[16]具有 285 个波段，包含 110×110 个像元，波长范围为 413～2 420 nm，包含 4 个端元，分别是水、树木、道路和屋顶。在 Apex 数据集上解混得到的丰度图如图 6，图 7 是得到的端元光谱。

表 4 与 5 分别展示了在 Apex 数据集上与其他 7 种方法对比的 RMSE 与 SAD，表中黑色加粗数值代表每一类别的最优结果。本方法在 Apex 数据集上

平均RMSE值最优为0.142 5,反映出本方法能在Apex数据集上获得整体较好的丰度。在SAD方面,本方法能在绝大多数地物的光谱角距离中获得最优的结果,体现出本方法在解混得到的端元图方面相比其他几种方法获得不错的结果。

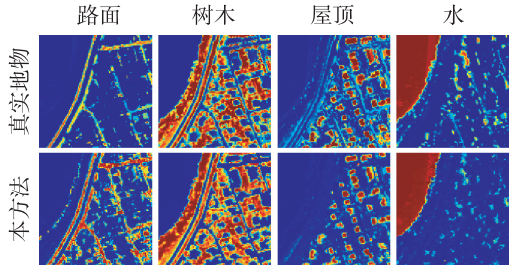
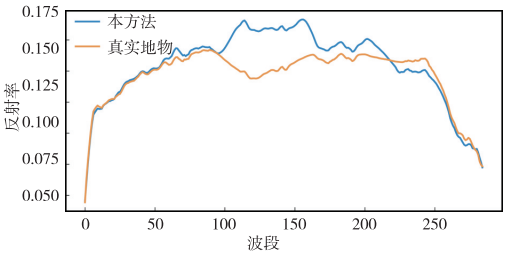
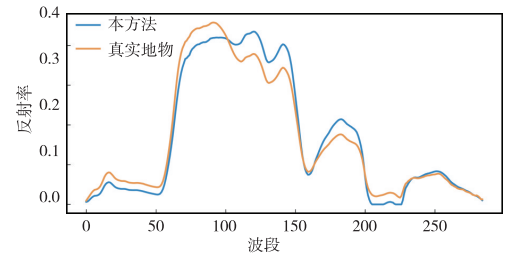


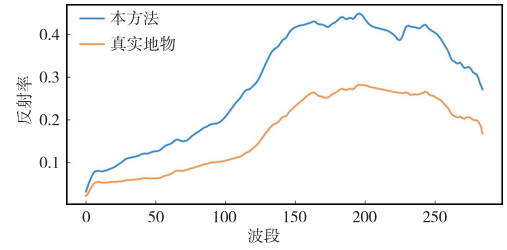
图6 Apex数据集解混丰度图



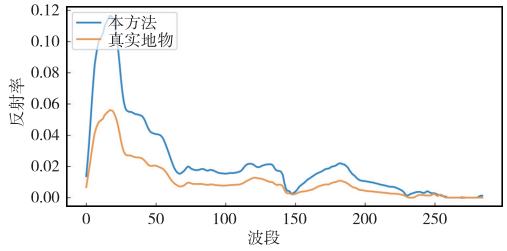
(a) 路面



(b) 树木



(c) 屋顶



(d) 水

图7 Apex数据集解混端元光谱

表4 在Apex数据集上对比不同方法下的RMSE

端元	CyCU	Collab	FCLSU	NMF-QMV	UnDIP	uDAS	DeepTrans	本方法
路面	0.292 1	0.307 8	0.233 1	0.180 6	**0.173 7**	0.197 3	0.478 0	0.198 3
树木	0.202 0	0.190 7	**0.094 4**	0.246 8	0.215 4	0.141 9	0.101 1	0.107 5
屋顶	0.163 0	0.148 3	**0.120 1**	0.235 9	0.255 4	0.230 3	0.129 6	0.130 1
水	0.121 3	**0.079 7**	0.132 7	0.375 1	0.417 0	0.288 7	0.531 9	0.115 8

表5 在Apex数据集上对比不同方法下的SAD

端元	CyCU	Collab	FCLSU	NMF-QMV	UnDIP	uDAS	DeepTrans	本方法
路面	0.454 3	0.677 2	0.691 5	0.400 3	0.090 7	0.455 1	0.909 9	**0.087 4**
树木	**0.085 0**	0.206 3	0.264 4	0.271 0	0.133 9	0.140 5	0.129 7	0.130 6
屋顶	0.129 8	0.100 2	0.147 1	0.175 3	**0.068 9**	0.086 0	0.090 2	0.088 8
水	0.622 3	0.513 7	0.517 6	1.841 7	0.504 0	0.225 1	0.899 8	**0.041 6**

3.3 Washington DC Mall数据集

Washington DC Mall数据集有191个波段,包含290×290个像元,波长范围为400~2 400 nm,包含6个端元,分别是草、树木、屋顶、道路、水以及小径。在Washington DC Mall数据集上解混得到的丰度图如图8所示,重叠光谱块列数设置为两列。图9为这6个端元的对应解混得到的端元光谱,在第2,3,4,5,6个子图上均能看出较好效果。

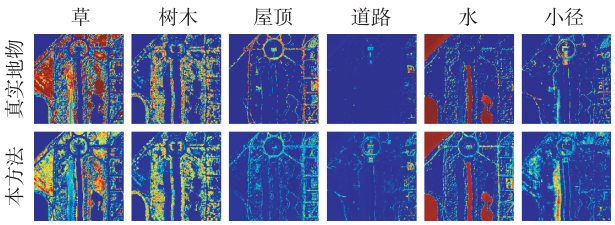
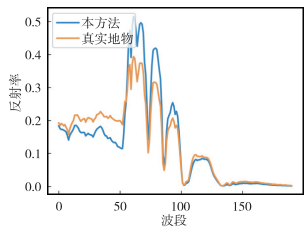
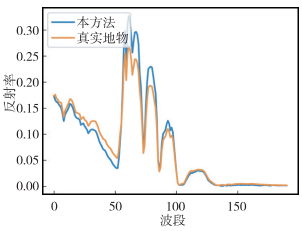


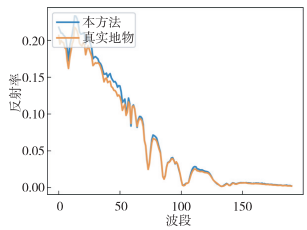
图8 DC数据集解混丰度图



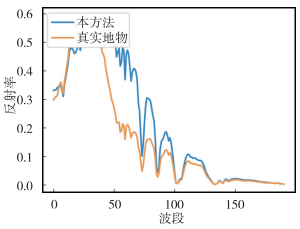
(a) 草



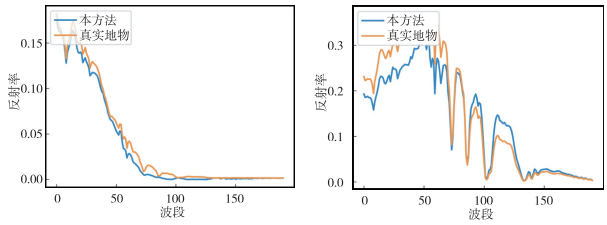
(b) 树木



(c) 屋顶



(d) 道路



（e）水　　（f）小径

图 9　DC 数据集解混端元光谱

在 Washington DC Mall 数据集上进行解混得到的 RMSE 以及 SAD 与其他七种方法对比如表 6 和 7 所示，表中每一类别的最优结果均通过黑色加粗显示。通过对比可以得出，本方法在 Washington DC Mall 数据集上得到的 RMSE 值在草、水这两种地物上结果最优，平均 RMSE 达到 0.144，在其他地物类别中虽然不是最优但仍能达到第二或第三的水平。在 SAD 中，本方法的平均 SAD 达到 0.176 2，为几种对比方法中最优水平。

表 6　在 Washington DC Mall 数据集上对比不同方法下的 RMSE

端元	CyCU	Collab	FCLSU	NMF-QMV	UnDIP	uDAS	DeepTrans	本方法
草	0.410 4	0.290 1	0.309 0	0.362 4	0.297 8	0.378 0	0.195 0	**0.188 9**
树木	0.282 4	0.416 7	0.402 5	0.276 1	0.351 4	0.335 1	**0.107 8**	0.114 1
路面	0.254 5	0.226 3	0.175 7	0.235 1	0.243 6	0.249 7	**0.149 1**	0.155 2
屋顶	0.415 7	0.043 7	**0.038 0**	0.086 2	0.049 3	0.046 3	0.078 4	0.096 1
水	0.395 7	0.310 2	0.292 1	0.207 6	0.381 2	0.515 6	0.146 7	**0.133 4**
小径	0.207 2	0.187 5	0.123 0	**0.101 1**	0.236 0	0.176 9	0.168 9	0.159 2

表 7　在 Washington DC Mall 数据集上对比不同方法下的 SAD

端元	CyCU	Collab	FCLSU	NMF-QMV	UnDIP	uDAS	DeepTrans	本方法
草	**0.089 5**	0.317 1	0.317 0	0.195 2	0.185 1	0.189 7	0.280 4	0.238 3
树木	0.270 4	0.333 5	0.288 3	0.450 7	0.725 8	0.425 1	**0.155 7**	0.193 5
路面	0.464 2	0.343 9	0.231 6	0.224 3	0.860 8	0.658 5	**0.034 0**	0.104 2
屋顶	0.950 0	**0.033 1**	0.034 3	0.207 8	0.282 6	0.199 2	0.325 3	0.314 1
水	0.420 5	**0.030 5**	0.776 6	0.673 6	0.949 5	0.232 8	0.096 5	0.063 8
小径	0.790 6	0.344 6	0.647 2	**0.061 5**	0.175 4	0.094 1	0.165 8	0.143 2

3.4　消融实验

为验证不同模块对模型效果的影响，进行了消融实验，在 RMSE 与 SAD 两个评价指标下的对比结果如表 8 和 9 所示。

表 8　不同模块在三个数据集上的 RMSE 对比

模块	Samson	Apex	DC
只进行重叠光谱块划分	0.120 5	0.364 1	0.189 5
只采用深度卷积的前馈层	0.097 2	0.132 4	0.166 2
重叠光谱块划分＋采用深度卷积的前馈层	0.104 9	0.142 5	0.144 4

表 9　不同模块在三个数据集上的 SAD 对比

模块	Samson	Apex	DC
只进行重叠光谱块划分	0.034 3	0.521 6	0.256 3
只采用深度卷积的前馈层	0.043 5	0.085 0	0.257 0
重叠光谱块划分＋采用深度卷积的前馈层	0.040 0	0.087 1	0.176 2

可以看出，当只进行重叠光谱块划分时，两个评价指标在三个数据集上几乎都不如两个模块叠加在一起效果好。只采用深度卷积的前馈层在 DC 数据集上 RMSE 不如两个模块叠加在一起效果好，在 SAD 上则普遍不如两个模块叠加后的效果。

4　结论

针对高光谱图像解混过程中传统分块方法导致的相邻像素之间的连续结构割裂问题，文章提出一种改进的高光谱解混方法：采用重叠光谱块划分策略，有效保留了相邻像素之间的光谱-空间相似性信息，实现了局部细节特征与全局结构特征的协同利用。具体而言，文章设计了基于重叠光谱块嵌入的特征提取模块，结合深度可分离卷积的轻量化架构，构建了一个新的高光谱解混网络。在 Samson，Apex 和 Washington DC Mall 三个数据集上对比 7 种方法，定量评估结果显示，在光谱角距离和均方根误差两项关键指标上，本方法呈现出了在提升端元解混精度方面的显著优势。这些实验结果充分验证了重叠分块策略和深度可分离卷积设计在保持光谱连续性和特征提取方面的有效性，为高光谱解混中的空间-光谱信息协同利用提供了新的技术思路。

参考文献：

[1] 智通祥，王　斌．一种考虑光谱变异性的高光谱图像非线性解混方法．中国，CN201810579080.9[P]．2018-12-18.
Zhi Tongxiang，Wang Bin．A Nonlinear Unmixing Method for Hyperspectral Images Considering Spectral Variability．China，CN201810579080.9[P]．2018-12-18.

[2] 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.

[3] 杨　星．基于压缩感知的高光谱图像重构[D]．西安：西安电子科技大学，2015.
Yang Xing．Hyperspectral image reconstruction based on compressive sensing[D]．Xi'an：Xidian University，2015.

[4] 苏远超，许若晴，高连如，等．基于深度学习的高光谱遥感图像混合像元分解研究综述[J]．遥感学报，2024，28(1)：1-19.
Su Yuanchao，Xu Ruoqing，Gao Lianru，et al．Development of

deep learning-based hyperspectral remote sensing image unmixing [J]. National Remote Sensing Bulletin, 2024, 28(1): 1-19.

[5] Bioucas-Dias J M, Plaza A, Camps-Valls G, et al. Hyperspectral remote sensing data analysis and future challenges [J]. IEEE Geoscience and Remote Sensing Magazine, 2013, 1(2): 6-36.

[6] 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: 5503914.

[7] Drumetz L, Meyer T R, Chanussot J, et al. Hyperspectral image unmixing with endmember bundles and group sparsity inducing mixed norms[J]. IEEE Transactions on Image Processing, 2019, 28(7): 3435-3450.

[8] 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.

[9] Zhuang L, Lin C H, Figueiredo M A T, et al. Regularization parameter selection in minimum volume hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(12): 9858-9877.

[10] Rasti B, Koirala B, Scheunders P, et al. UnDIP: hyperspectral unmixing using deep image prior [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 5504615.

[11] Qu Y, Qi H. uDAS: an untied denoising autoencoder with sparsity for spectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(3): 1698-1712.

[12] Palsson B, Ulfarsson M O, Sveinsson J R. Convolutional autoencoder for spectral-spatial hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(1): 535-549.

[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: 5535116.

[14] Wang Y, Chen X, Zhao E, et al. An unsupervised momentum contrastive learning based transformer network for hyperspectral target detection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024, 17: 9053-9068.

[15] Zhu F, Wang Y, Fan B, et al. Spectral unmixing via data-guided sparsity [J]. IEEE Transactions on Image Processing, 2014, 23(12): 5412-5427.

[16] Schaepman M E, Jehle M, Hueni A, et al. Advanced radiometry measurements and Earth science applications with the Airborne Prism Experiment (APEX) [J]. Remote Sensing of Environment, 2015, 158: 207-219.

作者简介：

李诗慧(1999—),女,硕士研究生,主要从事高光谱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。