光电技术及应用

DOI：10.16818/j.issn1001－5868.20260306002

基于多尺度特征融合与通道校准的高光谱解混网络

满　艺，高　聪，杨华东*

（沈阳理工大学 信息科学与工程学院，沈阳 110159）

摘　要： 在传统的视觉Transformer高光谱解混方法中，固定大小patch划分的局限性和模型对关键信息识别能力的不足，导致多尺度特征难以有效捕捉、通道中的重要信息无法充分利用。基于此，文章提出一种基于多尺度特征融合与通道校准的高光谱解混网络方案。该方案引入多尺度特征融合机制，通过深度可分离卷积和空洞卷积实现多尺度特征的融合，提升空间结构信息的捕捉能力；进而引入动态通道重校准机制，自适应调整通道的权重，增强不同通道间的相互作用，从而突出有用信息并抑制冗余噪声。实验结果表明，所提方法在多个真实数据集上均表现出良好的解混性能，相较于传统方法具有显著的性能提升。

关键词： 高光谱解混；多尺度特征融合；深度可分离卷积；空洞卷积；通道重校准

中图分类号： TP751　**文章编号：** 1001－5868(2026)03－0581－08

Hyperspectral Unmixing Network Based on Multi-Scale Feature Fusion and Channel Calibration

MAN Yi, GAO Cong, YANG Huadong

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

Abstract: Traditional visual Transformer hyperspectral unmixing methods are limited by fixed-size patch division and the insufficient ability of the model to recognize key information. This results in difficulty in effectively capturing multi-scale features and the underutilization of important information in channels. To address these issues, a hyperspectral unmixing network scheme based on multi-scale feature fusion and channel calibration is proposed. This scheme introduces a multi-scale feature fusion mechanism, which fuses multi-scale features through depthwise separable convolution and dilated convolution, enhancing the ability to capture spatial structural information. Additionally, a dynamic channel recalibration mechanism is introduced to adaptively adjust the weights of the channels, strengthen the interaction between different channels, highlight useful information, and suppress redundant noise. Experimental results show that the proposed method exhibits good unmixing performance on multiple real datasets, achieving significant performance improvements compared with traditional methods.

Key words: hyperspectral unmixing; multi-scale features fusion; depthwise separable convolution; dilated convolution; channel recalibration

0　引言

高光谱遥感图像具有波段数目众多的优势[1]，能够同时记录区域内地物的光谱信息和空间信息[2]，实现了图谱合一的数据采集能力[3]，是遥感应用研究的重要数据基础。然而，受传感器空间分辨

收稿日期：2026－03－06.

基金项目：辽宁省博士科研启动基金计划项目(2025-BS-0360).

* **通信作者：**杨华东

率有限的物理约束以及实际地物空间分布复杂性的影响，高光谱图像中普遍存在混合像元现象，即单独一个像元的光谱信号由多种端元光谱信号以不同丰度混合而成[2]。该混合像元问题严重制约了高光谱数据的准确性和应用范围[4]，因此高光谱解混，即从混合光谱中分离出端元光谱和对应丰度的技术[5]，逐渐成为高光谱遥感领域的重要环节[6]。

近年来，深度学习在高光谱解混领域中的应用越来越广泛[7]。其中，基于Transformer的高光谱图像解混是热门研究方向之一。Ghosh等[8]首次将Transformer应用于高光谱解混问题，突破了卷积神经网络（CNN）的局部建模局限，显著提升了解混效果。但是该模型采用固定大小的patch进行特征分割，仅基于单一尺度的patch特征计算长距离依赖，并且没有考虑冗余波段的影响。Mo等[9]提出一种基于转置注意力的轻量化Transformer高光谱解混网络，降低了计算复杂度，但是网络仍然使用固定尺寸的patch，存在一定的局限性。Duan等[10]提出一种面向可解释性光谱重建的解混引导Transformer网络（UGCT），将Transformer与残差块模块嵌入并行残差多头自注意力模块中，借助CNN的局部信息先验与Transformer的非局部信息先验优势，实现特征提取。然而，模型没有考虑高光谱图像中存在的冗余波段问题。Sun等[11]提出一种光谱-通道多尺度Transformer网络（SCMT-Net），并将其应用于高光谱解混任务，依次利用空间多尺度Transformer和通道多尺度Transformer提取不同尺度信息。但是网络的参数与计算开销较大，没有抑制通道中的冗余信息。此外，Xi等[12]提出包含通道校准模块（CCM）的注意力特征嵌入网络，抑制了通道中冗余信息，进而强化了有效信息。

针对固定大小patch划分导致多尺度特征提取能力有限，以及通道信息利用不充分的不足，本文提出一种基于多尺度特征融合和动态通道重校准的高光谱图像解混网络。该网络采用编码器-解码器基础架构，编码阶段通过CNN提取局部空间-光谱特征。利用空洞卷积提取多尺度空间特征，通过全局注意力、局部相关性分析和自适应门控机制动态的评估波段重要性，再通过数据驱动方式实现最优融合。优化后的特征输入Transformer编码器建模全局依赖关系，最后通过上采样和约束层输出符合物理意义的丰度。

1 工作原理

1.1 CNN编码器

CNN是一种带有卷积结构的深度神经网络，作为深度学习的核心模型之一，在计算机视觉任务中展现出了优越的性能。该编码器能够学习图像的浅层特征，将原始输入数据转换为高阶特征表示。其中，卷积层通过对输入数据进行卷积操作来提取高阶特征；池化层对特征图进行降维和采样，不仅保留了关键信息，还显著降低了计算的复杂度；全连接层则将学习到的信息传入神经网络的输出层[13]。

1.2 Transformer编码器

Transformer模型最开始由Google团队的Vaswani等在2017年针对自然语言任务提出。模型采用编码器-解码器结构，编码器由多头自注意力层、层归一化和前馈网络组成，解码器由多头注意力层和前馈连接层组成。

输入的图像被划分为固定大小的patch，得到Patch Embedding，加入位置编码。位置编码通常以固定的或可学习的方式加到输入序列中，使得每个位置的表示不仅依赖于自身的信息，还包含了该位置在整个序列中的相对或绝对位置，最终输入到编码器进行后续的特征提取等任务。自注意力机制是Transformer中的核心，使每个输入元素在被处理时不仅能关注自身的信息，还能关注到其他位置的信息，从而更好地捕捉长距离依赖。与传统的卷积或递归方法不同，自注意力机制能够在单次计算中直接建模输入序列中任意两个位置之间的关系，极大提升了并行计算的效率和对长距离依赖的建模能力。而多头自注意力机制则通过多个独立的注意力头来并行计算不同的注意力权重，每个注意力头在不同的子空间中学习信息，最终将所有头的输出拼接在一起。这样能够使模型捕捉到不同方面的关系，从而提高模型的表达能力。

2 一种基于多尺度特征融合与通道校准的高光谱解混网络方案

2.1 多尺度特征融合机制

在高光谱图像解混任务中，固定大小的patch划分导致模型很难感知到多尺度的空间信息。为解决这一关键问题，在编码器输出与Transformer输入之间设计并实现了多尺度融合模块。

多尺度融合机制结构如图1所示。该模块采用深度可分离卷积作为基础单元：空洞率$d=1$的3×3卷积捕获局部细节信息；$d=2$的卷积将感受野扩展至5×5，以提取中观尺度空间结构特征，识别地物分布模式，结合自适应全局池化为局部特征提供上下文约束。其中，深度可分离卷积作为基础单元，降低了参数的复杂度；而空洞卷积嵌入在深度可分离卷积内，扩展了特征提取的空间范围。结合深度可分离卷积、空洞卷积和自适应池化技术，实现了高效、轻量化的多尺度特征融合。

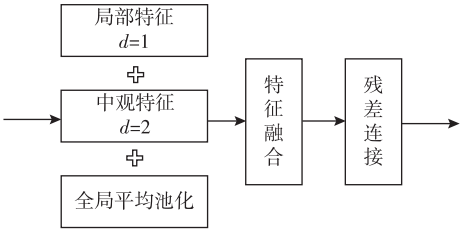


图1　多尺度特征融合机制结构图

2.2　动态通道重校准机制

高光谱图像波段数目多，既包含了丰富的地物光谱特征，也包含了噪声或冗余信息。传统光谱解混技术对所有通道平等处理，不能突出重要信息、抑制冗余信息。针对此问题，本文采用一种动态通道重校准机制，作用于CNN编码器之后，Transformer之前，自动学习每个通道的重要性权重，而不是使用固定的融合权重。

动态通道重校准机制结构如图2所示。第一支路通过全局平均池化与全连接层学习各波段的全局重要性，第二支路采用一维卷积捕获相邻波段间的局部相关性，最后根据均值与方差动态地调节重校准强度，避免了固定的融合参数的局限性。两个支路的输出通过特征拼接与非线性变换进行融合，生成最终波段权重矩阵。该矩阵与原始特征进行逐通道相乘来实现波段重校准，再通过自适应门控系数与原始特征进行加权融合，确保在增强重要波段的同时保留原始信息的完整性，突出有用信息，抑制冗余噪声。

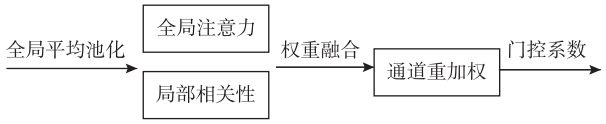


图2　动态通道重校准机制结构图

2.3　高光谱图像解混网络

所提出的高光谱解混网络结构如图3所示。将原始高光谱图像输入CNN编码器进行特征提取与降维处理，设输入特征为$X\in R^{B\times C\times H\times W}$，其中$B$为批大小，$C$为通道数，$H\times W$为空间尺寸。

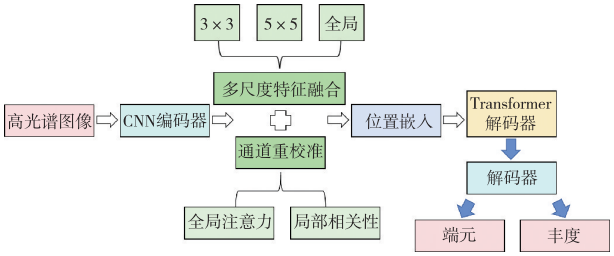


图3　基于多尺度特征融合与通道校准的高光谱解混网络结构图

编码器采用三层1×1卷积结构，输出$(dim\times P)/patch^2$个波段，其中dim为预设的特征维度，P为端元数，$patch$为图像块的固定尺寸。经过CNN编码器后输入多尺度特征融合与动态通道重校准模块。

对于标准卷积操作，输出特征位置(i,j)处第k个通道的值为：

$$y_{i,j,k}=\sum_{c=1}^{C}\sum_{m,n}w_{m,n,c,k}\cdot x_{i+m,j+n,c} \tag{1}$$

引入空洞率d后，输出特征位置(i,j)处第k个通道的值为：

$$y_{i,j,k}^{(d)}=\sum_{c=1}^{C}\sum_{m,n}w_{m,n,c,k}\cdot x_{i+d\cdot m,j+d\cdot n,c} \tag{2}$$

多尺度融合机制采用空洞率$d=1$的3×3深度可分离卷积捕获像素级的局部细节特征，感受野为3×3像素：

$$F_1=DWConv_{3\times 3}^{(d=1)}(X) \tag{3}$$

采用$d=2$的空洞卷积扩展感受野至5×5像素，提取相邻像素和小区域内的特征：

$$F_2=DWConv_{3\times 3}^{(d=2)}(X) \tag{4}$$

结合自适应全局池化获取通道级的特征：

$$F_3=Upsample\left\{Conv_{1\times 1}\left[GAP(X)\right]\right\} \tag{5}$$

三路空间特征经平均融合与1×1卷积调整，残差连接输出得到最终结果。设输入特征为X_1，输出特征为Y_1，多尺度融合机制的公式为：

$$Y_1=X_1+\beta\cdot fusion\left(\frac{F_1+F_2+F_3}{3}\right) \tag{6}$$

式中，β是残差权重，F_1，F_2和F_3分别是三个分支的输出。

通道重校准模块采用双分支并行结构，包括全局注意力分支和局部相关性分支，两个分支的输出通过自适应门控机制进行融合。全局注意力分支负责捕获每个通道的全局重要性信息，经两层全连

接网络学习全局权重分布：

$$z_c=\frac{1}{H\times W}\sum_{i=1}^{H}\sum_{j=1}^{W}x_c(i,j) \tag{7}$$

$$s=\sigma\left[W_2\delta(W_1z)\right] \tag{8}$$

式中，z为全局平均池化输出，W_1和W_2为全连接层权重，δ为ReLU激活函数，σ为Sigmoid函数，s为各通道的全局重要性权重。

局部相关性分支对通道均值序列进行一维卷积操作，捕获相邻波段间的依赖关系：

$$y=Conv1D(z,K,p) \tag{9}$$

$$w_{\text{local}}=\sigma\left(\frac{1}{C}\sum_{k=1}^{C}y_k\right) \tag{10}$$

式中，K为卷积核尺寸，设置为5；填充p为2保持维度不变，通过对卷积输出在通道维度求平均后经Sigmoid激活得到局部相关性权重w_{local}。

自适应门控根据通道的均值与方差，动态生成融合系数。设输入特征为X_2，输出特征为Y_2。通道重校准的公式为：

$$Y_2=\alpha\cdot\left(X_2\odot W_{\text{fused}}\right)+(1-\alpha)\cdot X_2 \tag{11}$$

式中，α为自适应门控系数，W_{fused}为融合后的通道权重。

通过自适应门控机制进行智能加权融合，得到融合后的特征F_{fused}，将融合后的特征图F_{fused}输入Transformer以捕获长距离全局依赖。X_{study}和X_{pos}被添加到每个patch中构成输入序列，其中X_{study}保存来自各个patch的全局信息，帮助模型理解图像的整体语义，X_{pos}提供空间信息，帮助模型理解patch在图像中的相对位置。Transformer编码器由多层堆叠而成，每一层都能捕获patch之间更深层次和更复杂的关系。处理后，提取类别标记对应的输出向量作为全局特征表示。

模型首先采用上采样映射与平滑处理从全局特征中恢复空间的丰度分布。再通过softmax激活函数来保证丰度的非负性以及丰度和为1的约束。最后，利用解码器对图像进行重构得到端元与丰度。

3 实验结果与分析

3.1 数据集

为验证所提方法的适用性和有效性，选取认可度高的Samson，Apex和Washington DC Mall数据集进行对比实验。

Samson数据集共有95×95个像元，波段数为156个，光谱范围为401～889 nm，采集自美国加州萨姆森岛的沿海区域，由树木、水、土壤三个端元组成。Apex数据集共有110×110个像元，波段数为285个，光谱范围为372～2 540 nm，由树木、水、道路、屋顶四个端元组成。Washington DC Mall数据集共有290×290个像元，波段数为191个，光谱范围为372～2 540 nm，由树木、水、道路、屋顶、草、小径六个端元组成。

3.2 评价指标

选用均方根误差（RMSE）以及光谱角距离（SAD）评估解混效果。

RMSE计算公式为：

$$RMSE(\hat{Y},Y)=\sqrt{\frac{1}{H\times W}\sum_{j=1}^{H\times W}\|\hat{y}_j-y_j\|_2^2} \tag{12}$$

SAD计算公式为：

$$SAD(\hat{m}_i,m_i)=\frac{1}{P}\sum_{i=1}^{P}\arccos\left(\frac{m_i^{\top}\hat{m}_i}{\|m_i\|\cdot\|\hat{m}_i\|}\right) \tag{13}$$

3.3 对比方法

选取两大类共五种典型方法进行实验对比。第一类是传统解混方法，包括FCLSU[14]，NMF[15]和Collab[16]三种解混方法。FCLSU方法即完全约束最小二乘线性光谱混合分析方法；NMF方法即几何和盲解混方法非负矩阵分解-二次最小体积方法，是高光谱解混的核心基础方法之一；Collab[16]方法通过把端元束的分组光谱结构与诱导组稀疏性的混合范数约束融合，实现性能的提升。第二类是深度学习解混方法。具体而言，CyCU[17]方法是一种循环一致性解混网络，通过串联两个自动编码器，提升解混性能；DeepTrans[8]方法充分利用卷积神经网络和Transformer编码器，解混效果得到显著提升。

3.4 实验结果

3.4.1 Samson数据集

表1和表2分别是Samson数据集上不同方法的RMSE和SAD结果，其中每一端元的解混最优结果均用黑色加粗字体表示。图4是本方法在Samson数据集上的丰度图可视化结果。图5是本方法在Samson数据集上的端元光谱可视化结果。

实验结果表明，所提方法在SAD均值解混精度上表现最优。土壤端元的RMSE结果为六种方法中最优，并且效果显著。树木端元和水端元均值的

表 1　Samson 数据集上不同方法的 RMSE 结果

端元	解混方法					
	FCLSU	NMF	Collab	CyCU	DeepTrans	本文
土壤	0.176 6	0.201 1	0.150 6	0.241 7	0.097 3	**0.077 0**
树木	0.065 3	0.146 6	**0.060 7**	0.138 6	0.062 2	0.078 1
水	0.149 2	0.206 3	0.118 1	0.265 4	**0.0604**	0.103 8
均值	0.138 7	0.186 6	0.115 9	0.222 2	**0.075 2**	0.087 2

表 2　Samson 数据集上不同方法的 SAD 结果

端元	解混方法					
	FCLSU	NMF	Collab	CyCU	DeepTrans	本文
土壤	0.025 9	0.039 1	0.015 5	0.114 4	0.032 7	**0.013 9**
树木	0.096 1	0.123 9	0.083 2	0.151 7	0.091 4	**0.070 9**
水	0.155 4	1.520 1	0.140 2	0.208 1	0.126 1	**0.102 2**
均值	0.092 5	0.561 0	0.079 6	0.158 1	0.083 4	**0.062 3**

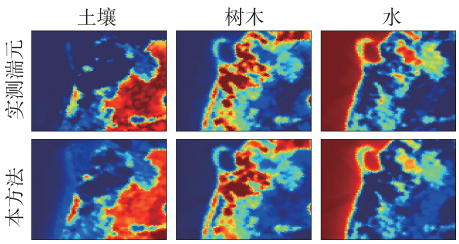
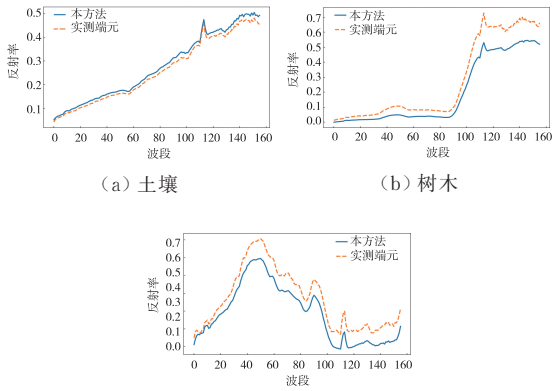


图 4　Samson 数据集丰度图可视化结果



（a）土壤　（b）树木

（c）水

图 5　Samson 数据集上的端元光谱可视化结果

结果虽然不是最优，但与其他方法相比，效果仍然稳定可观，与优秀方法差距较小。均值的 RMSE 结果为次优，相比于最优结果差距较小；土壤、树木和水端元和均值的 SAD 结果显著优于其他方法。

3.4.2　Apex 数据集

表 3 和表 4 分别是 Apex 数据集上不同方法的 RMSE 和 SAD 结果，其中每一端元的解混最优结果均用黑色加粗字体表示。图 6 是本方法在 Apex 数据集上的丰度图可视化结果。图 7 是本方法在 Apex 数据集上的端元光谱可视化结果。

实验结果表明，所提方法的综合解混性能最好。均值、路面端元和树木端元的 RMSE 结果均为六种方法中最优。屋顶、水端元的 RMSE 结果虽然不是最优，但是与最优方法的结果差距较小，整体处于中等偏上水平。均值的 SAD 结果优于所有对比方法，比次优方法 FCLSU 降低了 70.3%。路面、水端元的 SAD 结果均取得最优；树木端元的 SAD 结果中 CyCU 方法取得最优，虽略逊于最优方法，但是均值仍处于较高水平。

表 3　在 Apex 数据集上对比不同方法下的 RMSE 结果

端元	解混方法					
	FCLSU	NMF	Collab	CyCU	DeepTrans	本文
路面	0.233 1	0.180 6	0.307 8	0.292 1	0.476 3	**0.174 3**
树木	0.094 4	0.246 8	0.190 7	0.202 0	0.097 8	**0.095 7**
屋顶	**0.120 1**	0.235 9	0.148 3	0.163 0	0.120 8	0.127 6
水	0.132 7	0.375 1	**0.079 7**	0.121 3	0.525 3	0.081 2
均值	0.154 3	0.269 2	0.199 7	0.204 6	0.362 9	**0.124 9**

表 4　在 Apex 数据集上对比不同方法下的 SAD 结果

端元	解混方法					
	FCLSU	NMF	Collab	CyCU	DeepTrans	本文
路面	0.691 5	0.400 3	0.677 2	0.454 3	0.908 2	**0.065 7**
树木	0.264 4	0.271 0	0.206 3	**0.085 0**	0.129 8	0.131 4
屋顶	0.147 1	0.175 3	0.100 2	0.129 8	**0.083 2**	0.089 5
水	0.517 6	1.8417	0.513 7	0.622 3	0.895 5	**0.044 9**
均值	0.405 2	0.672 1	0.374 4	0.322 8	0.504 2	**0.082 9**

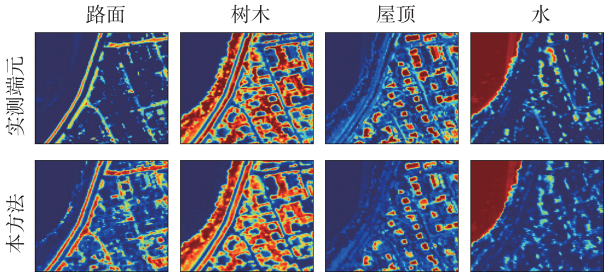
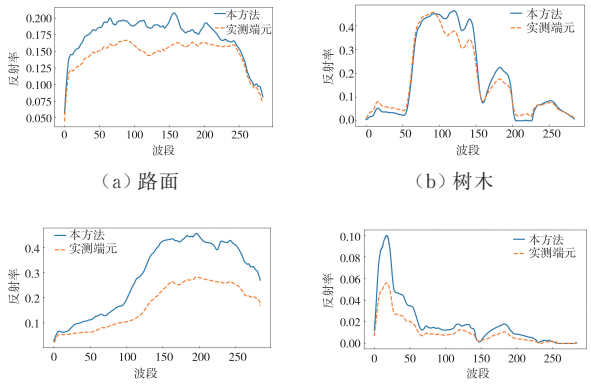


图 6　Apex 数据集丰度图可视化结果



（a）路面　（b）树木

（c）屋顶　（d）水

图 7　Apex 数据集上的端元光谱可视化结果

3.4.3 DC数据集

表5和表6分别是DC数据集上不同方法的RMSE和SAD结果，其中最优结果均用黑色加粗字体表示。图8是本方法在DC数据集上的丰度图可视化结果。图9是本方法在DC数据集上的端元光谱可视化结果。

实验结果表明，所提方法获得的草端元的RMSE优于各对比方法。对于屋顶端元的RMSE，FCLSU方法最优，本文方法处于中等水平，优于CyCU方法。对于水端元的RMSE，DeepTrans方法最优，本文方法次优，但优于传统解混方法。对于小径端元的RMSE，NMF方法最优，本文方法处于中等水平，优于CyCU，DeepTrans和Collab三种方法，略逊于FCLSU方法。草、树木、屋顶、道路、水、小径端元和均值的SAD结果处于中等水平，虽未达到最优，但是保持稳定。

表5 在DC数据集上对比不同方法下的RMSE结果

端元	解混方法					
	FCLSU	NMF	Collab	CyCU	DeepTrans	本文
草	0.309 0	0.362 4	0.290 1	0.410 4	0.172 6	**0.157 9**
树木	0.402 5	0.276 1	0.416 7	0.282 4	**0.096 5**	0.128 0
屋顶	**0.038 0**	0.086 2	0.043 7	0.415 7	0.087 3	0.094 0
道路	0.175 7	0.235 1	0.226 3	0.254 5	**0.156 2**	0.223 8
水	0.292 1	0.270 6	0.310 2	0.395 7	**0.151 6**	0.175 1
小径	0.123 0	**0.101 1**	0.187 5	0.207 2	0.158 5	0.128 0
均值	0.255 0	0.232 2	0.271 5	0.337 9	**0.141 0**	0.156 7

表6 在DC数据集上对比不同方法下的SAD结果

端元	解混方法					
	FCLSU	NMF	Collab	CyCU	DeepTrans	本文
草	0.317 0	0.195 2	0.317 1	**0.089 5**	0.241 8	0.259 7
树木	0.288 3	0.450 7	0.333 5	0.270 4	**0.138 5**	0.183 9
屋顶	0.034 3	0.207 8	**0.033 1**	0.950 0	0.332 1	0.322 9
道路	0.231 6	0.224 3	0.343 9	0.464 2	**0.069 2**	0.290 1
水	0.776 6	0.673 6	**0.030 5**	0.420 5	0.071 0	0.082 1
小径	0.647 2	**0.061 5**	0.346 6	0.790 6	0.113 0	0.170 3
均值	0.382 5	0.302 2	0.233 8	0.497 5	**0.160 9**	0.218 2

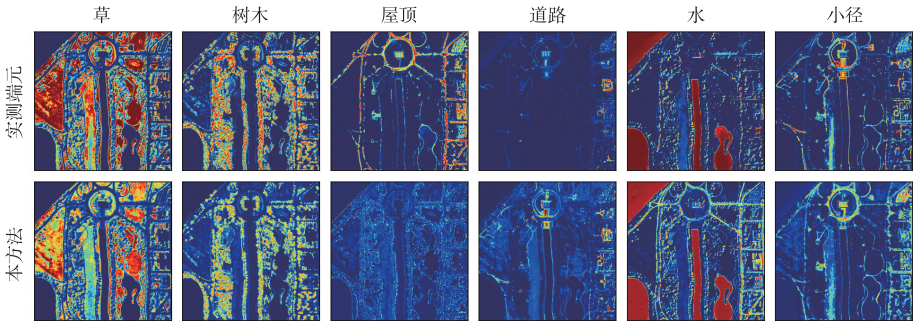


图8 DC数据集丰度图可视化结果

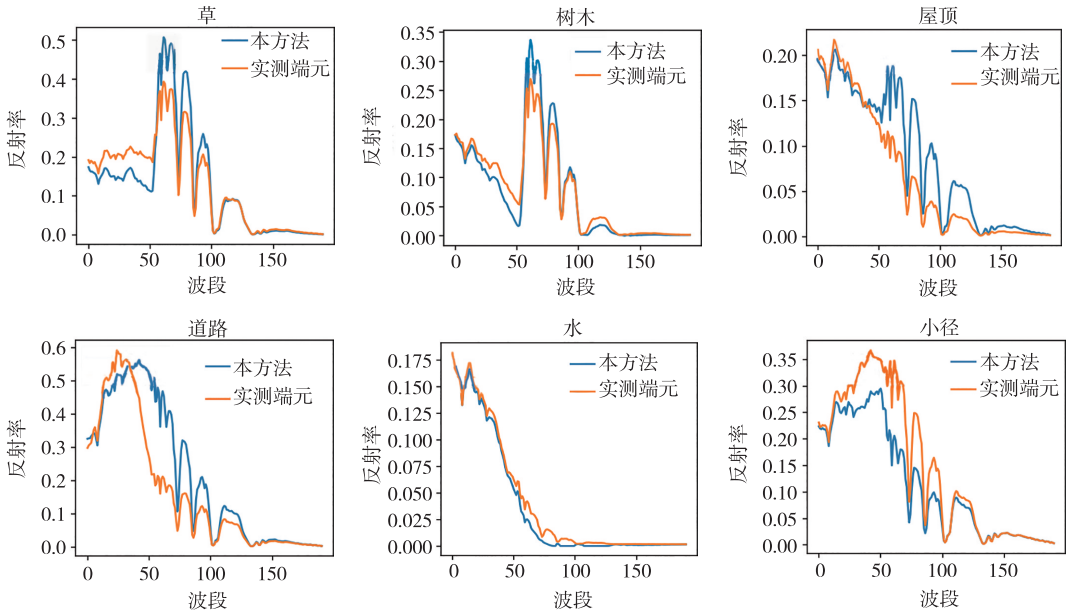


图9 DC数据集端元光谱可视化结果

3.5　消融实验

为验证不同模块对模型效果的影响，对本方法提出的多尺度特征融合模块与动态通道重校准模块行消融实验，在 RMSE 与 SAD 两个评价指标下的对比结果如表 7 所示。

表 7　不同模块在三个数据集上的 RMSE 和 SAD 对比

数据集	参数	多尺度特征融合	通道重校准	多尺度特征融合＋通道重校准
Samson	*RMSE*	0.074 9	**0.071 8**	0.087 2
	SAD	0.089 7	0.068 7	**0.062 3**
Apex	*RMSE*	0.130 5	0.125 7	**0.124 9**
	SAD	0.085 0	0.084 8	**0.082 9**
DC	*RMSE*	**0.121 1**	0.127 2	0.156 7
	SAD	0.165 0	**0.153 7**	0.218 2

实验结果表明，当单独采用多尺度特征融合模块时，DC 数据集的 RMSE 值结果最优。当单独使用通道重校准模块时，Samson 数据集的 RMSE 值和 DC 数据集的 SAD 值结果最优。其他指标均为同时使用两模块取得最优。总体来说，同时使用两模块解混结果较稳定，效果更好。

4　结论

为解决固定尺寸 patch 划分导致的局限性和通道中重要信息未被充分利用、冗余波段造成干扰的问题，本文提出一种基于多尺度特征融合与通道重校准的视觉 Transformer 的高光谱解混方法。该方法通过引入多尺度特征融合机制，有效捕获不同尺寸大小的空间信息；同时结合通道重校准机制，为波段划分重要性，从而构建了一个能够提取局部细节与全局结构特征、突出重要波段并抑制冗余噪声的高光谱解混网络。在此基础上，借助 Transformer 模型进行端元与丰度的联合估计，以数据驱动的方式自适应提取图像深层特征，进一步增强模型的表达能力与灵活性。

在 Samson，Apex 和 Washington DC Mall 三个公开数据集上与五种主流方法的对比实验结果表明，所提方法在 SAD 与 RMSE 两项关键评价指标上均取得显著提升，验证了其在端元提取与丰度估计方面的优势。结合消融实验的结果可知，所提出的多尺度特征融合与通道重校准机制，能够增强特征表达能力，为高光谱解混中的空间-光谱信息协同运用提供了新的可行性。

参考文献：

[1] 张　兵. 高光谱图像混合像元分解[J]. 遥感学报，2023，27(12)：2882-2883.
Zhang Bing. Hyperspectral image pixel unmixing[J]. National Remote Sensing Bulletin，2023，27(12)：2882-2883.

[2] 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.

[3] 游雪儿，苏远超，蒋梦莹，等. 深度嵌套式 Transformer 网络的高光谱图像空谱解混方法[J]. 中国图象图形学报，2024，29(8)：2220-2235.
You Xue’er，Su Yuanchao，Jiang Mengying，et al. Deep embedded Transformer network with spatial-spectral information for unmixing of hyperspectral remote sensing images[J]. Journal of Image and Graphics，2024，29(8)：2220-2235.

[4] 朱治青，苏远超，李朋飞，等. 双约束深度卷积网络的高光谱图像空谱解混方法[J]. 信号处理，2023，39(1)：128-142.
Zhu Zhiqing，Su Yuanchao，Li Pengfei，et al. Spectral-spatial hyperspectral unmixing using deep double-constraints convolutional network[J]. Journal of Signal Processing，2023，39(1)：128-142.

[5] 秦　凯，郝予希，赵英俊，等. 基于自编码的高光谱遥感解混技术研究综述(内封面文章·特邀)[J]. 红外与激光工程，2025，54(5)：20-37.
Qin Kai，Hao Yuxi，Zhao Yingjun，et al. A survey on hyperspectral remote sensing unmixing techniques based on autoencoders (inner cover paper·invited) [J]. Infrared and Laser Engineering，2025，54(5)：20-37.

[6] 袁　静，章毓晋，高方平. 线性高光谱解混模型综述[J]. 红外与毫米波学报，2018，37(5)：553-571.
Yuan Jing，Zhang Yujin，Gao Fangping. An overview on linear hyperspectral unmixing [J]. Journal of Infrared and Millimeter Waves，2018，37(5)：553-571.

[7] 万亚玲，钟锡武，刘　慧，等. 卷积神经网络在高光谱图像分类中的应用综述[J]. 计算机工程与应用，2021，57(4)：1-10.
Wan Yaling，Zhong Xiwu，Liu Hui，et al. Survey of application of convolutional neural network in classification of hyperspectral images [J]. Computer Engineering and Applications，2021，57(4)：1-10.

[8] 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.

[9] Mo Y，Sun H，Meng F. Lightweight transformer with transposed-attention for hyperspectral unmixing[J]. Journal of Physics：Conference Series，2023，2640(1)：012006.

[10] Duan S, Li J, Song R, et al. Unmixing-guided convolutional transformer for spectral reconstruction[J]. Remote Sensing, 2023, 15(10): 2619.

[11] Sun H, Cao Q, Meng F, et al. Spatial-channel multiscale transformer network for hyperspectral unmixing[J]. Sensors, 2025, 25(14): 4493.

[12] Xi B, Zhang Y, Li J, et al. Transductive few-shot learning with enhanced spectral-spatial embedding for hyperspectral image classification [J]. IEEE Transactions on Image Processing, 2025, 34: 854-868.

[13] 周飞燕, 金林鹏, 董 军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
Zhou Feiyan, Jin Linpeng, Dong Jun. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.

[14] 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.

[15] 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.

[16] 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.

[17] 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, 2022, 60: 5503914.

作者简介：

满 艺(2002—),女,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,主要从事遥感图像智能解译、智能信息处理方面的研究。