

基于长短时记忆网络的高保真遥感影像空谱联合分类方法

翟建丽, 倪伟传, 杨 慧

(广州华商学院 人工智能学院, 广州 511300)

摘要: 在遥感影像中, 单纯依靠光谱信息难以实现准确区分地物; 且高保真遥感影像包含大量的细节和丰富的信息, 往往难以实现高效处理并捕捉地物的细微特征和上下文信息, 导致在分类中易受到噪声和各种干扰因素的影响, 无法突出重要特征, 造成分类精度较差; 因此, 对高保真遥感影像空谱联合分类进行了研究; 利用长短时记忆网络模型, 分析高保真遥感影像特征, 在此基础上, 针对性处理目标影像数据, 实现基于长短时记忆网络的高保真遥感影像压缩、感知与重构, 以在有效减少数据量的同时, 挖掘信息之间的内在联系来捕捉地物的细微特征和上下文信息; 为抑制噪声和干扰信息, 构建超像素小块, 并根据小块内像素数据的降维运算标准, 完善增强处理原则, 突出重要特征, 进而同时利用地物的空间与光谱信息定义空谱分类面, 以有效区分不同类别, 实现遥感影像的空谱联合分类; 经实验测试结果表明, 所提方法在小样本分类任务中平均精度达到 85.12%, 且对目标地物遥感影像的分类精度更高; 同时对遥感影像区域的划分更符合实际应用需求。

关键词: 长短时记忆网络; 高保真遥感影像; 空谱联合分类; 空间信息; 光谱信息; 超像素小块

Spatial Spectral Joint Classification Method for High-Fidelity Remote Sensing Images Based on LSTM Networks

ZHAI Jianli, NI Weichuan, YANG Hui

(School of Computer Engineering, Guangzhou Huashang College, Guangzhou 511300, China)

Abstract: In remote sensing images, relying solely on spectral information makes it difficult to accurately distinguish land features. Moreover, high-fidelity remote sensing images contain a large amount of details and rich information, which often makes it difficult to efficiently process and capture subtle features and contextual information of ground objects, resulting in susceptibility to noise and various interference factors in classification, and inability to highlight important features, leading to a poor classification accuracy. Therefore, research is conducted on the joint classification of spatial spectra in high-fidelity remote sensing images. A long short term memory (LSTM) network model is used to analyze the high fidelity remote sensing image features. Based on this, the target image data is processed in a targeted manner to achieve compression, perception, and reconstruction of high-fidelity remote sensing images based on LSTM networks, effectively reducing the amount of data while mining inherent connections between information to capture subtle features and contextual information of ground objects. To suppress noise and interference information, the superpixel blocks are constructed. Based on the dimensionality reduction operation standards for pixel data within small blocks, it is possible to enhance processing principle to highlight important features, and then simultaneously utilize the spatial and spectral information of land objects to define spatial spectral classification surfaces, effectively distinguishing different categories and achieving spatial-spectral joint classification of remote sensing images. Experimental results show that the proposed method achieves an average accuracy of 85.12% in small sample classification tasks, and has higher classification accuracy for target land remote sensing images; Also, the division of remote sensing image areas is more in line with practical application needs.

Keywords: LSTM network; high-fidelity remote sensing images; spatial-spectral joint classification; spatial information; spectral information; superpixel block

收稿日期:2025-08-06; 修回日期:2025-09-25。

基金项目:广州华商学院 2023 年青年学术科研项目(2023HSQX048)。

作者简介:翟建丽(1981-)女,硕士,副教授。

引用格式:翟建丽,倪伟传,杨 慧. 基于长短时记忆网络的高保真遥感影像空谱联合分类方法[J]. 计算机测量与控制, 2026, 34(7):156-163,179.

0 引言

遥感成像意在完成对地物对象的远距离感知, 通过收集目标物体自身辐射以及其他波源反射的电磁波信号, 获得影像信息。遥感影像分类作为遥感影像处理的重要分支领域, 不但在军事、气象、环境、工业等多个方面表现出了突出应用能力, 还为精细化农业发展提供了重要参考。近年来, 遥感卫星技术的发展, 使得光谱成像逐渐从多光谱发展到高光谱, 再由高光谱发展到超光谱, 随着空间分辨率的不断提升, 光谱通道数量也逐渐增大^[1]。不同于单光谱, 高光谱、超光谱遥感影像的质量更高, 能够获得大量全彩色影像无法获得的信息, 进而完成全彩色图像不能完式的任务。对于遥感影像的分类主要涉及光谱信息分类、场景分类两方面内容, 其中光谱信息分类不但要识别出整幅图像所在场景, 还需要对每个像素点进行准确区分。

如果将高光谱数据视为独立的数据立方体, 在分类过程中, 只有同时掌握像素规模、光谱维度等空间信息才能够获得较为理想的分类结果。过往研究中, 赵全意等人提出了基于深度流形蒸馏网络的分类方法, 深度流形蒸馏网络基于移位窗口的层次化视觉标准, 挖掘遥感影像中的长距离依赖信息, 以捕捉不同像素波段之间的关系, 再通过对中间层输出特征与光谱像素的匹配, 定义具体的信息分类标准^[2]。移位窗口中包含大量的影像信息, 分类过程中, 如果不能准确区分样本相似性则会导致像素波段混乱的问题。王丽英等人提出了基于多元高斯混合模型 (GMM, global multimedia mobility) 的分类方法, 提取多光谱、高程等点云数据构建空谱特征矢量, 通过离散化处理的方式消除特征矢量之间的尺度差异, 进而根据各类目标的响应度确定其类属^[3]。但该方法易受到噪声和各种干扰因素的影响, 无法突出重要特征, 使得不同类别区分效果不佳。何光等人提出了三维卷积联合空谱特征的分类方法, 基于主成分分析法沿垂直方向对遥感影像进行降维运算, 再通过非负矩阵提取影像信息空间特征, 将降维后的数据与空间特征信息拼接起来, 构建长序列矩阵, 以便于通过多层感知机制完成分类^[4]。但该方法难以挖掘信息之间的内在联系来捕捉地物的细微特征和上下文信息, 导致分类精度较差。虞瑶等人提出了联合空间信息的分类算法, 综合自适应相似度与分类器精度确定测试样本的 K 邻域, 再设计自适应窗口协调局部空间内的地物近邻关系, 以利用高光谱遥感影像描述目标地物的空间形态结构^[5]。然而该方法未考虑噪声和各种干扰因素的影响, 遥感影像包含大量的细节和丰富的信息, 使得不同类别区分效果不佳。

长短时记忆网络 (LSTM, long short-term memo-

ry) 在图像处理中, 利用其独特的门控机制和长短期记忆能力, 能够深入分析图像复杂的时空特征, 捕捉图像中像素在不同时间和空间维度上的关联信息^[6]。因此, 为提高高保真遥感影像空谱联合分类效果, 针对基于长短时记忆网络的高保真遥感影像空谱联合分类方法展开研究。

1 基于长短时记忆网络的高保真遥感影像压缩感知与重构

基于长短时记忆网络的高保真遥感影像压缩感知与重构旨在利用网络算法模型^[7-9], 分析高保真遥感影像特征, 进而实施针对性处理。不同于传统方法可能仅关注影像的局部或简单特征, LSTM 可以捕捉影像中像素在不同时间和空间维度上的关联信息, 为后续的压缩、感知、重构以及分类提供更丰富、准确的特征依据。

1.1 长短时记忆网络构建及算法模型求解

长短时记忆网络包含多个输入、输出部分, 可以用于提取目标图像的空间特征, 其结构模型如图 1 所示。




图 1 长短时记忆网络模型

其中, 采用 3 层 LSTM, 每层 128 个隐藏单元, dropout 率 0.2, 通过网格搜索确定最优参数。

记忆输入与隐状态输入以两层全连接层作为分类器, 在数据量较大的情况下, 往往比一层全连接层的稳定性更高。设 a 表示输入数据, S 表示隐状态权重, δ 表示激活函数, d 表示针对激活函数所定义的输入样本全连接参数, χ 表示元素运算的偏置向量, 联立上述物理量, 可将长短时记忆网络算法的表达式定义为:

$$A = \delta(Sa + d)^{-\chi} \quad (1)$$

长短时记忆网络为了避免运算过程中出现过拟合现象, 在训练输入数据时, 全连接层可以直接参与运算, 即让带有激活函数的全连接层按照一定概率置 0。

1.2 长短时记忆网络下的高保真遥感影像特征分析

高保真遥感影像中通常包含大量的高分辨率光谱信息, 可以提供与地物景观特征相关的详细数据信息。然而, 针对遥感影像的分析必须考虑数据信息在时间序列上的变化特性, 才能准确捕捉地物景观的动态演变规律。长短时记忆网络的门控机制直接以遥感影像特征作为输入, 根据细胞状态完成对长序列数据的分类, 从而为影

像压缩感知与重构提供针对性的数据样本, 实现高保真的遥感影像处理。在公式 (1) 的基础上, 推导基于长短时记忆网络的高保真遥感影像特征分析表达式如下:

$$D = \operatorname{argmin}_{g \rightarrow \infty} \beta \|sA\| + \frac{1}{2} \|g_s - \gamma g_o\|^2 \quad (2)$$

α 表示长短时记忆网络的细胞状态定义值, β 表示门控机制下的样本输入项, s 表示遥感影像的长序列特征参量, g_s 表示细胞状态为 α 时的遥感影像长序列数据, γ 表示输入信息的时间性依赖度, g_o 表示样本输入时刻长短时记忆网络中的遥感影像长序列数据。根据高保真遥感影像的复杂程度增加或减少长短时记忆网络的层数量, 或在激活函数中调整层结构的单元数, 以控制网络运算的复杂度, 防止在提取高保真遥感影像特征时陷入样本过拟合之中。

1.3 遥感影像压缩感知重构

1.3.1 高保真影像压缩

长短时记忆网络对于遥感影像所提出的高保真压缩标准意在尽可能减少数据存储和传输成本, 并在处理过程中最大程度保留原始影像信息。基于高保真遥感影像特征所设置的压缩标准应融合无损压缩和有损压缩优点, 先通过有损压缩去除遥感影像中大部分的冗余信息, 再对有损压缩后的影像残差进行无损压缩, 以实现对关键信息的高集真保留^[10]。在长短时记忆网络中, 高保真遥感影像的压缩主要以小波变换作为分析标准, 将目标影像分解为不同频率的子带对象, 进而在不同子带区域内完成针对性的压缩处理。其中, 采用 db4 小波基, 分解 3 层, 高频子带采用阈值量化 (阈值 0.02)。基于长短时记忆网络模型所定义的小波变换算法原则如公式 (3) 所示:

$$G_\epsilon = \frac{1}{\omega_\epsilon} \sum_{\epsilon \neq 0} \varphi \cdot h_\epsilon^2 \quad (3)$$

ϵ 表示小波系数, φ_ϵ 表示目标对象的时频局部化特性, φ 表示小波基取样参数, h_ϵ 表示目标对象的有效压缩比。由于小波变换原则提出了明确的时频局部化标准, 能够准确捕捉遥感影像中的局部特征, 所以基于该方法进行压缩能够适应多种不同的影像处理需求^[11]。联立公式 (2)、公式 (3), 可将高保真遥感影像压缩表达式定义为:

$$F = fG_\epsilon + \sqrt{(\epsilon - 1)} \hat{H}^{-1} D \quad (4)$$

f 表示影像数据内在规律, ϵ 表示遥感影像压缩尺度, $\hat{H}$ 表示目标压缩部分的影像数据样本。高保真压缩解决了影像样本兼容性较差的问题, 在空谱联合分类过程中, 该处理充分保障了长短时记忆网络所输入影像信息的真实性与完整性。

1.3.2 高保真影像感知

高保真遥感影像同时通过高空间分辨率、高光谱分

辨率与高时间分辨率精准捕捉地表信息的动态与细节变化。基于长短时记忆网络感知高保真遥感影像, 就是利用丰富的光谱信息, 还原空间细节, 从而根据影像特征, 完成对目标遥感区域的动态监测^[12]。长短时记忆网络融合对抗学习机制对影像信息进行增强处理, 不但解决了遥感影像融合中可能出现的光谱畸变问题, 也提升了影像信息的跨尺度泛化能力。遥感测量过程中, 影像信息在感受野中所对应的数据样本并不能保持固定取值状态, 所以为获得较为准确的影像感知结果, 应通过对抗学习算法进行动态耦合运算^[13]。利用公式 (2), 推导高保真遥感影像的感知表达式为:

$$J = l_\kappa \sqrt{\kappa D} \cdot \frac{|j_\kappa - \bar{j}|^2}{\Delta K} \quad (5)$$

κ 表示对抗学习系数, l_κ 表示基于系数 κ 的遥感影像光谱畸变参量, ΔK 表示影像信息的单位感知量, j_κ 表示基于系数 κ 所定义影像信息跨尺度泛化样本, $\bar{j}$ 表示影像信息跨尺度泛化的样本量均值。结合对抗学习机制进行高保真遥感影像感知, 不但增强了长短时记忆网络对目标遥感的跟踪能力, 也能够更好合并相邻超像素样点, 以优化目标遥感对象的分类标准。

1.3.3 高保真影像重构

通过对高保真遥感影像的重构可以突破图像压缩感知的约束等距特性, 从而在全图范围内实现对目标信息的联合采样。长短时记忆网络针对影像的重构处理主要基于平滑绝对误差函数 (Huber Loss Function, Huber 函数), 采用平衡计算的方式, 规定 L1 与 L2 范数, 从而在去除高频噪声参量的同时, 大量保留遥感影像的边缘信息^[14]。对于 Huber 函数的定义参考如下表达式:

$$I[p(O)] = \begin{cases} \frac{1}{2} O^2 p |L_1 - L_2|, & |O| \leq |p| \\ p \left(O - \frac{1}{2} |L_1 - L_2| \right), & |O| > |p| \end{cases} \quad (6)$$

O 表示绝对误差参数, p 表示平滑性超参数, L_1 表示 L1 范数, L_2 表示 L2 范数, 且 $L_1 \neq L_2$ 的不等式取值条件恒成立。

在 Huber 函数的基础上, 利用长短时记忆网络模型, 根据样本信息所对应的分辨率标准进行数值运算, 就可以实现对高保真遥感影像的重构^[15]。联立公式 (2)、公式 (6), 推导高保真遥感影像的重构定义式如下:

$$P = \lambda \times \left[1 + \left(\frac{o^2 D}{I[p(O)]} \right) \right] + \hat{u} \quad (7)$$

λ 表示遥感影像的重构分辨率, o 表示边缘区域内的遥感信息全局残差, i 表示目标遥感信息的等距约束参数, $\hat{u}$ 表示遥感影像中的高频噪声参量。长短时记忆网络通过对高保真遥感影像的压缩感知与重构处理, 协

调目标影像中的遥感信息,一方面抑制噪声、变化纹理等干扰因素对影像识别结果造成的影响,另一方面定义更精确的信息分级标准,以保障高保真遥感影像空谱联合分类的准确性。

2 高保真遥感影像空谱联合分类方法设计

遥感影像在获取过程中不可避免地会受到噪声和各种干扰因素的影响,这些因素会降低影像的质量,影响分类结果。通过完善超像素小块的增强处理原则,能够对影像进行预处理,突出重要特征,抑制噪声和干扰信息。因此,结合长短时记忆网络所定义的遥感影像压缩感知与重构标准,构建超像素小块,并通过对目标像素信息的降维与增强处理,定义空谱分类面,实现对高保真遥感影像的空谱联合分类。

2.1 遥感影像超像素小块构建

构建超像素小块是超像素分割的核心处理步骤,旨在将一幅遥感影像从像素级降维至区块级。在高保真遥感影像中,超像素分割能够将完整的图像分割成多个光谱特性较为接近的同性质小块,且同一小块的像素水平也较为近似^[16]。构建超像素小块能够大幅降低遥感影像处理的计算量,且通过这种方法可以有效剔除图像中具有明显异常表现像素点。长短时记忆网络在压缩感知与重构处理高保真遥感影像后,通常将目标像素所对应的波段作为构建超像素小块的输入,以减少将整幅遥感影像输入所带来的计算量^[17]。对于高保真遥感影像而言,实现超像素分割还应避免小块结构之间发生重叠,才能避免目标遥感对象的结构信息或纹理特征被其他像素所掩盖。对于遥感影像超像素小块的构建如图2所示。




图2 遥感影像及其超像素小块图像

以遥感影像中的红绿蓝波形为例,求解超像素小块建模标准如公式(8)所示:

$$U = \sqrt{\left(\frac{y_1 + y_2 + y_3}{t_1 t_2 t_3}\right)^2 + \frac{er}{FJP}} \quad (8)$$

式中, y_1 、 y_2 、 y_3 分别表示红绿蓝波形在遥感影像中所对应的光谱长度, t_1 、 t_2 、 t_3 分别表示红、绿、蓝颜色距离的权重参数,分别取值 0.4、0.3、0.3,基于 RGB 波段重要性分配, $\bar{e}$ 表示颜色距离均值, $\bar{r}$ 表示空间距离均值。将超像素小块作为遥感影像空谱联合分类的基本单元,可以合并相似的超像素对象提取地物信息,

避免了差异性分类的问题,而超像素尺寸平均大小 30×30 像素。

2.2 影像超像素数据的降维运算

随着高保真遥感影像光谱范围的增大以及光谱分辨率水平的提高,长短时记忆网络对超像素小块的分类准确率必然出现不断下降的情况,因此对影像超像素数据进行降维运算极为必要。关于光谱分辨率升高的描述主要基于休斯现象,可以理解为遥感影像各个谱段相关性所造成的超像素小块冗余度增加的情况,在各个像素波段间造成了相互干扰^[18]。而通过降维运算则可以消除各波段间的冗余性关系,达到抑制超像素小块分类准确率下降的目的。对于遥感影像超像素数据的降维运算主要遵循线性判别原则,其基本思想是通过线性变换超像素小块使得各波段内光谱数据的差异度尽可能小,而波段间的差异度尽可能大^[19]。基于线性变换原则可将遥感影像超像素数据的降维运算表示为:

$$Q = \mu \cdot \left| \frac{\hat{R}}{\hat{U}} \right| \cdot \sum_{\nu \rightarrow \infty} q_{\nu}^2 \quad (9)$$

μ 表示超像素小块波段间的冗余性, $\hat{R}$ 表示光谱数据的线性差异度, ν 表示光谱波段内的分辨率基准值, q_{ν} 表示超像素数据的线性降维参数。降维运算是建立在超像素数据线性假设基础上的,通过线性变换的方式将高维光谱分辨率映射至低维空间,从而避免在空谱联合分类高保真遥感影像时发生超像素小块分类准确率下降的问题。

2.3 降维像素数据的增强处理

数据增强是通过降维影像超像素数据产生更多像素数据样本集的过程。不同于单纯基于降维数据进行空谱联合分类,通过增强处理可以添加一定的高斯噪声。利用含有高斯噪声的超像素数据进行分类,可以增强遥感影像的色彩空间,避免旋转、平移等处理对分类准确性造成影响^[20]。利用高斯噪声对降维后的影像超像素数据实施增强处理,应根据高保真遥感影像中的边缘色彩变换需求,进行对比度变换处理。对于超像素小块对比度的变换可以调整整幅遥感影像中的亮度分布情况,以增强原影像的对比度^[21]。在空谱联合分类中,利用高对比度影像定义具体的分类标准,可以在区分超像素数据的同时,保障图像边缘的完整性。在公式(9)的基础上,可将降维像素数据的增强处理运算式表示为:

$$W = - \sum_{o=1}^{+\infty} [E(z_o) \times \log Q(x_o)] \quad (10)$$

o 表示高斯噪声, z_o 表示基于噪声 o 所定义的超像素数据色彩空间, E 表示边缘色彩变换参数, x_o 表示包含噪声的原遥感影像对比度增强参量。在降维运算的基础上,通过添加高斯噪声的方式对像素数据进行增强处

理,不但最大限度保留了原始影像信息,也为空谱分类面的定义提供了数据参考。其中,高斯噪声均值 0,方差 0.01。

2.4 空谱分类面定义

接下来,根据上述增强后的像素数据,定义空谱分类面,以用于后续分类。空谱分类面就是能够实现遥感影像正确空谱联合分类且能够保证超像素数据间隔最大的分类面。图 3 是在包含增强像素数据情况下所定义的空谱分类面。空谱分类面两侧为两条分类基线,它们之间的距离为分类间隔,且始终与分类面保持等距关系,超像素数据则分布在分类基线两侧^[22]。




图 3 高保真遥感影像的空谱分类面

在空谱联合分类中,分类面具有均分遥感影像超像素数据的能力,无论在空间谱还是光谱环境下,其分类准确性都不会受到影响^[23]。 ϑ 表示分类间隔,其计算式如下:

$$\vartheta = \frac{2}{\|b\|^2} \quad (11)$$

b 表示两条分类基线到空谱分类面的距离之和。

联立公式 (10)、公式 (11),可将遥感影像空谱分类面的定义式表示为:

$$Z = \frac{1}{2}(k_1 + k_2) - \sum W[(\bar{\rho} \cdot N) + \vartheta] - 1 \quad (12)$$

k_1 、 k_2 分别表示两条分类基线的斜率, $\bar{\rho}$ 表示遥感影像超像素数据的分布密度均值, N 表示分类基线之间像素区域的面积。将空间特征与光谱特征直接拼接为高维特征向量,再利用光谱的“点”像素数据与空间的“面”像素数据,实现优势互补,以保证空谱分类面的定义准确性,进而实现高保真遥感影像的空谱联合分类。

2.5 空谱联合分类的实现

高保真遥感影像空谱联合分类的实现包含光谱信息分类、空间信息分类两方面内容。基于空谱分类面可将光谱信息定义为每个像素在连续遥感波段上的反射值,反映了地物对象的物理特性;空间信息则描述了像素在影像空间上的相关性^[24]。联合分类在空谱分类面的基

础上设计核函数,通过线性组合的方式融合光谱信息与空间信息。由于分类核函数的选择与优化依赖“点”像素数据与“面”像素数据,所以空谱分类面的输入必须同时支持光谱向量与空间向量^[25]。设 ω 表示光谱“点”数据, σ 表示空间“面”数据, b_ω 表示光谱像素数据在遥感波段上的反射值, ζ 表示光谱信息拼接特征, v_ω 表示光谱波段差, c_ω 表示光谱似然值, c_σ 表示空间先验值,联立公式 (12),推导高保真遥感影像空谱联合分类运算式表示为:

$$B = \sum_{\omega} \|b_\omega - \zeta(v_\omega)\|^2 + Z \sum_{\omega, \sigma} (c_\omega + c_\sigma)^2 \quad (13)$$

综上,有效利用了长短时记忆网络的时序建模能力,将超像素数据的光谱序列特性与空间上下文信息相结合,实现高保真遥感影像空谱联合分类,以提升遥感影像的鲁棒性与分类精度。

3 实验分析与研究

3.1 实验设置

验证所提长短时记忆网络(方法 1)、文献 [2] 中深度流形蒸馏网络(方法 2)、文献 [3] 中多元高斯混合模型(方法 3)在高保真遥感影像空谱联合分类方面的有效性,结合光谱信息、空间信息两方面内容对分类准确性进行研究。数据集方面采用 Indian Pines 高光谱遥感数据集,使用 145×145 像素、包含 16 类地物和 220 波段的公开高光谱数据集作为影像信息来源,去除水汽吸收波段,以避免对原遥感影像的清晰度造成影响,将光谱值缩放至 $[0, 1]$ 的数值范围内,以促进不同实验模型的快速收敛,从而获得有效的分类结果。其中,16 类地物样本分布,如表 1 所示。

表 1 16 类地物样本分布

类别名称	样本量
道路	500
小麦	450
玉米	400
森林	380
水体	350
建筑	320
裸土	290
草地	260
灌木	220
农田	200
湿地	180
果园	160
铁路	135
桥梁	120
机场跑道	125
光伏板	130

表 1 中，类别样本量范围 120~500，其中“道路”（500 样本）、“小麦”（450 样本）、“玉米”（400 样本）为多数类，“桥梁”（120 样本）、“铁路”（135 样本）为少数类。

实验所需软、硬件环境的参数设置如表 2 所示。

表 2 环境参数

分类	名称/参数	型号/数值
硬件	处理器	AMD Ryzen 9 5900HX with Radeon Graphics
	核数量	八核
	内存	DDR4 3 200 MHz
	存储量	16 GB
	显卡	NVIDIA GeForce RTX 3080 Laptop GPU
	显存	16 G
软件	操作系统	Windows 11
	编程语言	Python 3.8+pytorch1.12+numpy 1.23.5

获取 64 维像素空间内的遥感影像作为实验图像，由于其像素维度较低，故图像中必然存在大量的噪声点与像素曝光问题，如图 4（左）所示。高保真遥感影像空谱联合分类实验对图像清晰度的要求较高，所以出于对实验结果准确性的保障，在 128 维像素空间内将光谱与空间特征拼接起来，再针对性建立包含 128 个像素单元的全连接层，以确保 Softmax 分类器能够输出满足清晰度要求的遥感实验图像，如图 4（右）所示。




图 4 原遥感图像与 Softmax 分类器输出的图像

空谱联合分类意在区分遥感影像全像素区域内的光谱信息与空间信息对象，所以其色度区域内必须同时包含完整的太阳光谱信号波形。而 Softmax 分类器所输出遥感图像中同时可见红、橙、黄、绿、蓝、靛、紫 7 类不同的太阳光谱信号，且信号之间的过渡关系稳定且清晰，表示 Softmax 分类器所输出遥感图像符合空谱联合分类的实验需求。

3.2 参数设置对网络性能的影响分析

根据前文可知，采用 3 层 LSTM，每层 128 个隐藏单元，dropout 率 0.2，通过网格搜索确定最优参数。针对于此，利用图像重构精度及训练时间增加率进行衡量，说明参数设置对模型性能的影响，如表 3 所示。

表 3 参数设置对模型性能的影响变化

隐藏单元数量	dropout 率	图像重构精度 (PSNR/dB)	训练时间增加率/%
128	0.2	32.5	5
	0.3	32.0	8
	0.4	31.5	10
256	0.2	33.0	20
	0.3	32.7	25
	0.4	32.2	30
512	0.2	33.2	35
	0.3	32.9	40
	0.4	32.4	45

基于表 3 的实验数据，隐藏单元数量的增加显著提升了图像重构精度，但边际效益递减明显。当单元数从 128 增加到 256 时，PSNR 提升了 0.5 dB（32.5→33.0），而继续增加到 512 仅带来 0.2 dB 增益（33.0→33.2）。这表明在 3 层 LSTM 架构下，256 单元可能已接近该结构的表达能力上限。dropout 率对模型性能呈现非线性影响。在所有单元配置下，0.2 的 dropout 率均取得最佳 PSNR 值，且随着 dropout 率增大，模型精度持续下降。例如在 256 单元时，dropout 从 0.2 提升到 0.4 导致 PSNR 降低 0.8 dB（33.0→32.2）。这说明当前任务的过拟合风险较低，过强的正则化反而损害了特征提取能力。

在计算效率方面，模型复杂度的提升导致训练时间非线性增长。单元数每增加一倍，时间成本增长约 15%~20%。值得注意的是，512 单元配置下即便采用最小 dropout（0.2），其 35% 的时间增加率仅换来比 256 单元高 0.2dB 的精度提升，性价比显著降低。

综合来看，256 隐藏单元配合 0.2dropout 率展现出最优的平衡性，其 33.0 dB 的 PSNR 比 128 单元基线提升 0.5 dB，而时间成本仅增加 20%。该配置在计算资源和模型性能之间实现了帕累托最优。

3.3 不同参数对压缩比与精度的影响分析

根据前文可知，采用 db4 小波基，分解 3 层，高频子带采用阈值量化（阈值 0.02）。针对于此，利用压缩比与精度损失进行衡量，说明不同参数对压缩比与精度的影响，如表 4 所示。

表 4 不同参数对压缩比与精度的影响分析

分解层数	压缩比	精度损失/%
1	3 : 1	1.0
2	4 : 1	1.2
3	5 : 1	1.5
4	6 : 1	2.0

基于表 4 的实验数据，提升小波分解层数能显著提

高压缩比, 但会带来轻微的精度损失。当分解层数从 1 层增加到 3 层时, 压缩比从 3 : 1 提高到 5 : 1, 而精度损失仅从 1.0% 增加到 1.5% (增加 0.5 个百分点)。这表明增加分解层数可在压缩效率上获得较大收益, 同时对精度的影响相对有限。分解层数的增加使高频子带得到更精细的划分, 从而在阈值量化过程中保留更多有效低频信息并稀疏化高频噪声。例如, 3 层分解相比 1 层分解能更有效地分离不同尺度的细节特征, 使压缩算法在相同阈值 (0.02) 下舍弃更多非关键高频分量, 进而提升压缩比。然而, 精度损失随分解层数增加而缓慢上升, 说明高频信息的过度稀疏化会导致部分有用细节丢失。例如, 3 层分解的精度损失 (1.5%) 虽仍处于可接受范围, 但若继续增加至 4 层, 精度损失提升到 2%, 可能引发明显失真 (如边缘模糊或纹理退化)。综合考虑, 3 层分解在压缩比 (5 : 1) 和精度损失 (1.5%) 之间达到了较优平衡。

3.4 噪声强度对分类结果的影响分析

根据前文可知, 高斯噪声均值 0, 方差 0.01。针对于此, 利用分类精度变化率进行衡量, 说明噪声强度对分类结果的影响, 如表 5 所示。

表 5 不同噪声强度对分类精度的影响分析

噪声方差	分类精度变化率/%
0.01	+2.1
0.02	-1.3
0.03	-2.4
0.04	-4.2
0.05	-5.8

根据表 5 的实验数据, 低强度噪声显著提升分类精度, 当噪声方差为 0.01 时, 分类精度提高 2.1%, 说明适度的噪声注入能够增强模型的泛化能力。噪声强度增加 ($\sigma^2 \geq 0.02$) 导致分类精度下降, 当噪声方差从 0.02 提升至 0.05 时, 分类精度呈现单调递减趋势, 噪声开始掩盖有效信号, 部分关键特征受到干扰, 分类性能大幅退化。

3.5 小样本类别分类性能分析

为验证所提方法的对小样本类别 (以桥梁为例) 的分类精度, 展开方法 1、方法 2、方法 3 的对比分析, 统计各方法对桥梁样本的分类精度, 如表 6 所示。

根据表 6 结果, 方法 1 在桥梁样本分类任务中展现出显著优势。具体而言, 方法 1 在所有实验轮次中的分类精度均稳定在 84.8% 至 85.3% 之间, 平均精度达到 85.12%, 且各次实验结果波动幅度极小, 体现出极强的稳定性。相比之下, 方法 2 的分类精度波动范围为 67.4% 至 73.1%, 平均精度为 70.73%, 整体表现明显低于方法 1, 且存在多次实验精度低于 70% 的情况; 方

表 6 分类精度结果

实验次数	分类精度/%		
	方法 1	方法 2	方法 3
1	85.3	71.3	68.5
2	85.1	69.8	67.2
3	84.9	72.6	70.1
4	85.2	68.9	65.4
5	85.3	70.5	69.8
6	84.8	73.1	71.3
7	85.0	67.4	66.7
8	85.3	71.9	68.9
9	85.2	72.0	69.5
10	85.1	70.2	67.8

法 3 的分类精度则进一步下降至 65.4% 至 71.3%, 平均精度仅为 68.92%, 是 3 种方法中精度最低且波动最大的。这一结果充分说明, 所提方法 (方法 1) 在小样本场景下具有较好的分类性能, 而方法 2 和方法 3 可能因对小样本数据的适应性不足或特征提取能力有限, 导致分类精度出现较大波动且整体偏低。

3.6 高保真遥感影像空谱联合分类结果分析

光谱信息方面对于分类精度的验证可以基于光波信号组成, 即在色度分布图像中同时包含红、橙、黄、绿、蓝、靛、紫外光谱信号波形时, 各类光信号的组成情况与原遥感影像中光信号的组成情况越接近, 就表示空谱联合分类的精度越高。基于方法 1、方法 2、方法 3 进行实验, 并基于光谱组成情况分析空谱联合分类的准确性, 详情如图 5 所示。




图 5 基于光谱信息的遥感影像空谱联合分类

分析图 5 可知, 按照光谱信号占比由大致小的顺序进行排列, 原遥感影像中光谱信号的顺序依次为: 绿色、靛色、黄色、橙色、红色、紫色、蓝色, 与图 5 所示的色度分布情况相符合。基于方法 1 进行分类, 光谱

信号的排列顺序依次为: 绿色、靛色、黄色、橙色、红色、紫色、蓝色, 虽然各个光谱信号的实际占比不能与原遥感影像完全相同, 但二者排列顺序保持一致。基于方法 2 进行分类, 光谱信号的排列顺序依次为: 黄色、红色、绿色、靛色、紫色、蓝色、橙色, 与原遥感影像中光谱信号的排列顺序具有明显差异性, 故该方法在光谱信息方面的分类精度不及方法 1。基于方法 3 进行分类, 光谱信号的排列顺序依次为: 绿色、紫色、橙色、红色、黄色、靛色、蓝色, 也与原遥感影像中光谱信号的排列顺序具有明显差异性, 表示该方法在光谱信息方面的分类精度也不及方法 1。

空间信息方面对于分类精度的验证可以基于横轴与纵轴方向上的目标影像长度, 在光谱输入稳定的前提下, 目标影像长度分类越接近原遥感图像中的影像长度, 就表示划分越准确。基于方法 1、方法 2、方法 3 进行实验, 并基于空间信息的长度组成情况分析空谱联合分类的准确性, 详情如图 6 所示。




图 6 基于空间信息的遥感影像空谱联合分类

分析图 6 可知, 原遥感图像中基于空间信息所定义影像分类标准的横轴长度始终略大于纵轴长度, 但二者差值极小。基于方法 1 进行分类, 个别样点处出现了纵轴长度大于横轴长度的实验情况, 但超限部分的数值水平极低, 故该方法在空间信息方面对于遥感影像的分类较为接近真实遥感情况。基于方法 2、方法 3 进行分类, 所得实验曲线与原遥感图像影像分类长度曲线的数值差较为明显, 特别是方法 3 的实验结果, 纵轴长度始终大于横轴长度, 因此相较于方法 1, 这两种方法在遥感影像空间信息分类方面的准确性不足以满足实际需求。

4 结束语

通过长短时记忆网络所构建的高保真遥感影像空谱联合分类方法, 充分融合了遥感影像的光谱特征与空间特征, 不但拓展了记忆网络模型在遥感领域中的应用, 也为空谱联合特征分类提供了新的视角。空间特征提取方面, 所提出方法能够更有效地捕捉遥感影像中的地物

分布规律、空间纹理结构等信息; 光谱特征处理方面, 长短时记忆网络所特有的记忆机制, 不但深入挖掘了光谱数据的时序相关性, 也通过关联类比的方式, 提取出更具有判别性的光谱参量。结合空间特征与光谱处理原则, 既实现了对遥感影像中不同地物景观的有效区分, 也大幅提升了影像数据空谱联合分类的精度水平。随着遥感技术的不断发展, 影像分辨率也在不断提高, 这就使得长短时记忆网络所需处理的数据量越来越大。因此, 如何增强模型计算效率, 使其能够更好、更快速的处理大规模遥感影像数据, 成为了空谱联合分类技术的未来发展方向。

参考文献:

[1] 董宝鑫, 王江涛. 基于重参数化广义金字塔与扩张残差的遥感图像旋转框算法 [J]. 电子测量与仪器学报, 2024, 38 (12): 54-61.

[2] 赵全意, 郑福建, 夏 波, 等. 基于深度流形蒸馏网络的高光谱遥感图像场景分类方法 [J]. 测绘学报, 2024, 53 (12): 2404-2415.

[3] 王丽英, 马旭伟, 有 泽, 等. 基于多元 GMM 的机载多光谱 LiDAR 点云空谱联合分类 [J]. 自然资源遥感, 2023, 35 (3): 88-96.

[4] 何 光, 吴田军. 三维卷积与 Transformer 支持下联合空谱特征的高光谱影像分类 [J]. 计算机工程与应用, 2025, 61 (2): 259-272.

[5] 虞 瑶, 苏红军, 陶 畅. 联合空间信息的高光谱遥感协同表示动态集成分类算法 [J]. 遥感学报, 2024, 28 (1): 187-202.

[6] 阳治民, 宋 威. 结合金字塔和长短期记忆网络的细粒度图像分类 [J]. 小型微型计算机系统, 2023, 44 (8): 1771-1776.

[7] 王继东, 于俊源, 孔祥玉. 基于双重分解和双向长短时记忆网络的中长期负荷预测模型 [J]. 电网技术, 2024, 48 (8): 3418-3426.

[8] 杜晓庆, 鲁 羿, 董浩天, 等. 基于长短期记忆神经网络的方柱表面风压时程预测 [J]. 工程力学, 2025, 42 (4): 130-138+186.

[9] 庞兆峻, 胡荣明, 竞 霞, 等. 融合多重多尺度特征的高分辨率遥感影像建筑物提取网络 [J]. 遥感信息, 2024, 39 (5): 162-170.

[10] 吴盛葳, 方娇莉, 朱大明. 基于改进压缩与激活块的遥感影像语义分割方法 [J]. 激光与光电子学进展, 2024, 61 (12): 287-296.

[11] 齐保贵, 赵鹏赫, 陈 禾, 等. 基于 YOLOv3-SPP 的遥感图像目标检测压缩模型 [J]. 信号处理, 2023, 39 (9): 1621-1632.

(下转第 179 页)