

基于深度学习的复杂光谱识别方法及性能评价研究

林浩辰

辽宁师范大学, 辽宁 大连 116029

[摘要] 复杂光谱数据具有波段数量多、相邻波段相关性强、类别边界模糊和空间结构差异明显等特点, 传统分类方法难以充分提取深层判别信息。深度学习能够通过分层网络自动学习光谱、空间及空谱联合特征, 已成为高光谱识别的重要方法。文章分析一维卷积、二维卷积、三维卷积、混合卷积和注意力机制的基本特点, 并结合 Indian Pines、Pavia University 等公开数据集的实验结果评价不同方法的分类性能。结果表明, 空谱联合网络整体精度较高, 但小样本、类别不平衡和跨场景泛化仍是制约实际应用的重要因素。

[关键词] 深度学习; 复杂光谱; 光谱识别; 卷积神经网络; 性能评价

DOI: 10.64635/ja.2026.1472

中图分类号: TP391.4

文献标识码: A

Research on Complex Spectral Recognition Methods and Performance Evaluation Based on Deep Learning

Lin Haochen

Liaoning Normal University, Dalian, Liaoning 116029, China

Abstract: Complex spectral data are characterized by a large number of bands, strong correlations between adjacent bands, ambiguous class boundaries, and significant differences in spatial structures, making it difficult for traditional classification methods to fully extract deep discriminative information. Deep learning can automatically learn spectral, spatial, and joint spectral-spatial features through hierarchical networks, and has become an important method for hyperspectral recognition. This paper analyzes the basic characteristics of one-dimensional convolution, two-dimensional convolution, three-dimensional convolution, hybrid convolution, and attention mechanisms, and evaluates the classification performance of different methods in combination with experimental results on public datasets such as Indian Pines and Pavia University. The results show that spectral-spatial joint networks achieve relatively high overall accuracy, but small samples, class imbalance, and cross-scene generalization remain important factors restricting practical applications.

Keywords: deep learning; complex spectrum; spectral recognition; convolutional neural network; performance evaluation

引言

复杂光谱识别是利用不同物质在连续波段上的反射、吸收或辐射差异完成类别判断的技术过程。高光谱遥感影像能够同时记录地物空间分布和连续光谱信息, 通常包含数十至数百个窄波段, 在农作物识别、矿物调查、生态监测、环境评价和城市地物分类中具有较强应用能力。

复杂光谱数据虽然信息丰富, 也具有明显的高维特征。相邻波段之间具有较强相关性, 大量冗余信息增加模型计算负担。不同地物可能表现出相似光谱, 同一地物又会受到光照、含水量、空间位置和生长状态影响产生明显差异, 由此形成“同谱异物”和“异谱同物”现象。传统支持向量机、随机森林等方法能够处理一定程度的非线性分类问题, 但其性能较大程

度依赖人工选择特征。

深度学习为复杂光谱识别提供了新的特征表达方式。卷积神经网络能够利用局部连接和权值共享提取光谱或空间结构, 三维卷积则可以同时处理光谱维和空间维信息。相关研究提出基于变异系数降维和卷积神经网络的高光谱分类方法, 在 Indian Pines 和 Pavia University 数据集上的总体精度分别达到 98.69% 和 99.66%^[1]。另有研究将局部二值模式与双通道卷积网络结合, 在 Indian Pines、Pavia University 和 Salinas 数据集上的分类精度分别达到 98.54%、99.73% 和 99.56%^[2]。

结果表明, 深度网络已经具有较强复杂光谱特征提取能力。模型性能仍受到训练样本、网络结构、波段选择和场景差异影响, 需要从识别精度、稳定程度

和计算成本等多个方面开展综合评价。

1 复杂光谱识别的数据特征与深度学习基础

1.1 复杂光谱数据的高维特征

高光谱数据可以表示为空间维和光谱维共同组成的三维数据立方体。每个像元均对应一条连续光谱曲线，同一空间区域同时具有纹理、边缘和邻域结构信息。相较普通多光谱影像，高光谱数据能够表达更细微的物质光谱差异，但高维性也增加了识别难度。

光谱波段之间存在明显相关性。连续波段通常记录相近的物理信息，全部直接输入分类器容易产生冗余，并增加网络参数。相关研究通过类内与类间变异系数筛选低效波段，再进行卷积特征提取，说明合理降维能够在保留判别信息的同时提高分类效率^[1]。

复杂光谱还具有明显的类别内部变化。例如同一种植被类型受到生长阶段、土壤背景和水分条件影响后，其反射曲线会发生变化。不同材料也可能在部分波段产生相近响应，因此仅使用单个像元的光谱曲线容易出现误分。

1.2 深度网络的特征表达优势

深度学习与传统人工特征方法的主要区别在于特征能够通过训练自动形成。网络浅层通常提取局部变化、波段组合或边缘信息，随着层数增加，模型逐渐形成具有类别判别能力的高层特征。

一维卷积主要沿光谱维滑动，可以识别吸收峰、反射变化和局部波段组合。二维卷积主要作用于空间邻域，能够获取纹理、形状及局部结构。三维卷积同时在两个空间维和一个光谱维进行运算，可以直接学习空谱联合特征。

深层网络也具有一定风险。高光谱标注样本通常远少于普通自然图像，模型参数过多时容易记忆训练样本而降低测试性能。因此，复杂光谱识别并不是简单增加网络深度，而需要依据样本规模选择合理网络复杂程度。

2 基于深度学习的复杂光谱识别方法

2.1 一维与二维卷积特征提取

一维卷积网络结构较简单，重点提取单像元光谱序列特征。其输入数据规模相对较小，计算量较低，在标记样本有限时具有一定优势。缺点是空间上下文利用不足，当不同类别光谱相近时，仅依靠光谱特征难以形成稳定边界。

二维卷积通常先对高维光谱数据进行主成分分析或波段选择，再将降维后的空间邻域作为输入。这种方法能够利用相邻像元之间的空间相关性，对大片连

续地物具有较强识别能力。

单独依靠二维空间特征也存在信息损失风险。复杂材料或植被类型之间的重要差异可能集中在少量窄波段，过度压缩光谱维后会丢失有效信息。因此，一维光谱网络和二维空间网络常采用双分支或特征融合方式联合使用。

相关研究构建两个一维 CNN 通道，分别处理原始光谱数据和局部二值模式特征，再将深层光谱与空间特征融合。该方法在 3 个公开数据集上均取得 98% 以上总体分类精度，说明人工纹理信息与深层光谱特征之间具有一定互补作用^[2]。

2.2 三维卷积及空谱联合识别

三维卷积可以直接在光谱—空间立方体上提取特征，避免光谱和空间信息完全分离。卷积核同时沿行、列和波段方向移动，能够捕捉地物局部空间分布及相邻波段之间的响应关系。

三维网络的主要优势是联合建模，但计算量和参数数量明显高于一维、二维卷积。相关研究提出 HybridSN 模型，先利用三维卷积提取空谱联合特征，再通过二维卷积提取更高层空间信息，以降低纯三维网络的复杂度^[4]。该方法在 Indian Pines、Pavia University 和 Salinas 等公开数据集上表现出较高分类性能。

后续研究进一步验证了混合三维—二维结构的有效性。有研究在 Indian Pines 数据集 20% 训练样本条件下得到 HybridSN 总体精度 99.30%，改进的残差混合网络达到 99.52%；当训练比例下降至 2% 时，两者分别降至 83.14% 和 86.67%，反映出深度模型对训练样本数量具有明显敏感性^[5]。

2.3 注意力与多尺度特征增强

复杂光谱的不同波段并非具有相同判别价值。注意力机制通过学习权重突出关键波段或重要空间位置，使网络能够减少无效信息干扰。

多尺度结构则解决空间窗口单一的问题。小窗口有利于保持像元局部细节，大窗口能够获取更丰富的邻域环境。将不同尺度特征融合，可以提高边缘区域和复杂类别的识别能力。

相关研究提出多方向自适应感知网络，通过多方向特征提取增强高光谱空间结构表达。另有研究采用协方差池化与跨尺度特征提取，在 Indian Pines、Houston 和 Pavia University 数据集分别使用 5%、5% 和 1% 标记样本训练时，总体精度达到 97.63%、98.48% 和 98.21%^[3]。这一结果表明，多尺度和高阶

统计信息在较少训练样本条件下仍具有较好的判别能力。

3 深度学习光谱识别性能评价

3.1 评价指标及实验条件

复杂光谱分类通常采用总体精度、平均精度和 Kappa 系数作为主要评价指标。总体精度表示全部测试样本中正确分类样本所占比例，能够反映整体识别效果。平均精度先计算各类别准确率，再求平均值，可以降低大类别样本对最终结果的主导作用。Kappa 系数则用于评价分类结果相对随机分类的一致程度。

评价深度模型时还应记录训练样本比例、随机划分方式和运行时间。高光谱数据集内部类别数量差异较大，仅报告总体精度容易掩盖小样本类别的识别问题。

不同文献的准确率不能脱离实验条件直接横向比较。训练样本比例越高，模型通常越容易获得较高结果。采用随机像元划分时，训练与测试样本还可能空间距离较近，造成邻域信息泄漏。因此，性能评价应同时说明数据集、训练比例和模型输入方式。

3.2 不同网络结构的识别性能

表 1 典型深度学习方法在公开高光谱数据集上的分类结果

方法	数据集	训练条件	总体精度
CV-CNN	Indian Pines	实验设置	98.69%
CV-CNN	Pavia University	实验设置	99.66%
CNN+LBP	Indian Pines	实验设置	98.54%
CNN+LBP	Pavia University	实验设置	99.73%
SDCNN	Indian Pines	每类 10% 样本	98.86%
SDCNN	Pavia University	每类 5% 样本	99.81%
SDCNN	Houston	每类 50 个样本	97.41%

表 1 显示，深度学习方法在典型公开高光谱数据集上已经能够取得较高总体精度，部分模型超过 99%。这一结果体现了卷积网络对复杂空谱特征的表达能力，也说明性能评价不能只关注最高精度。

小样本条件下的性能下降更值得关注。残差三维—二维网络实验中，Indian Pines 训练比例由 20% 降至 2% 时，总体精度由 99.52% 下降至 86.67%^[5]。这一变化说明模型在充足训练数据下形成的优势，并不一定能够完全迁移到实际少样本场景。

因此，评价复杂光谱识别方法应同时考察精度、样本效率、类别均衡性和重复实验稳定性。对于工程应用，还需要加入推理时间、显存占用和跨区域适应能力等指标。

4 复杂光谱识别的限制因素与优化方向

4.1 小样本与类别不平衡

标注成本高是复杂光谱识别长期存在的问题。高光谱像元虽然数量庞大，但可靠类别标签通常需要现场调查或人工判读，难以获得大规模均衡样本。部分公开数据集中，不同类别样本数量差异达到数十倍，网络容易偏向大样本类别。

数据增强、迁移学习、半监督学习和对比学习可以缓解该问题。相关综述指出，利用少量标记样本与大量未标记数据共同训练，是解决监督方法样本依赖的重要方向^[6]。

类别不平衡还可以通过加权损失、重采样和难样本挖掘改善。评价时应增加各类别精度分析，避免总体精度较高而少数类别持续误判。

4.2 光谱冗余及空间尺度差异

高光谱数据中大量相邻波段高度相关，全部输入网络会增加计算量。波段选择、主成分分析和可学习光谱注意力可以压缩信息，提高模型效率。

相关研究提出光谱可形变卷积网络，通过在光谱维学习偏移位置，为不同类别自动选择更适合的特征波段。在 Indian Pines、Pavia University 和 Houston 数据集上的总体精度分别达到 98.86%、99.81% 和 97.41%^[3]，表明针对光谱维进行自适应特征选择具有较好的应用潜力。

空间尺度选择也需要结合地物尺寸。过小窗口缺少上下文信息，过大窗口可能引入其他类别像元，尤其在道路、建筑边缘和零散植被区域容易产生混合特征。多尺度卷积和自适应感受野能够在一定程度上降低固定窗口带来的影响。

4.3 模型泛化与计算效率优化

公开数据集上的高精度并不能直接代表实际应用性能。不同地区在传感器、太阳高度、地表条件和大气状态方面存在差异，同一网络跨区域应用时可能出现明显精度下降。

提高泛化能力需要加强模型对稳定物理特征的学习。域适应、迁移学习和多区域联合训练能够降低数据分布差异。训练样本还应尽量覆盖不同时间、光照和地物状态，避免模型依赖某个特定场景。

计算效率也是深度光谱识别走向实际应用的重要

条件。三维卷积具有较强空谱建模能力, 却消耗较多计算资源。HybridSN 采用三维卷积与二维卷积组合, 就是在联合特征表达和模型复杂程度之间进行折中^[4]。进一步采用深度可分离卷积、网络剪枝、知识蒸馏和低维特征输入, 可以降低参数量, 并为机载、星载或边缘设备实时处理创造条件。

5 结语

深度学习提高了复杂光谱数据的自动特征提取和非线性分类能力。一维卷积适合学习连续光谱响应, 二维卷积能够利用空间结构, 三维及混合卷积则进一步建立空谱联合表达。公开数据集实验表明, 多种深度模型在 Indian Pines、Pavia University 等典型数据上能够取得较高总体精度, 其中部分方法超过 99%。

较高实验精度不能完全替代对模型实际性能的评价。训练样本比例、类别分布、空间窗口和数据划分方式都会改变最终结果。小样本条件下, 部分网络性能仍会明显下降, 跨传感器和跨区域泛化也存在不足。复杂光谱识别的发展重点应放在空谱联合特征、多尺度自适应表达、半监督与对比学习以及轻量化模型等方面。同时建立更加统一的实验划分和性能评价体系,

综合考察总体精度、平均精度、类别稳定性、运行效率和跨场景适应能力, 才能更准确判断深度学习方法的实际应用价值。

【参考文献】

- [1] 张康, 黑保琴, 周壮, 李盛阳. 变异系数降维的 CNN 高光谱遥感图像分类 [J]. 遥感学报, 2018, 22(1): 87-96.
- [2] 魏祥坡, 余旭初, 张鹏强, 等. 联合局部二值模式的 CNN 高光谱图像分类 [J]. 遥感学报, 2020, 24(8): 1000-1009.
- [3] 薛朝辉, 李博. 光谱可形变卷积驱动的高光谱图像分类 [J]. 遥感学报, 2022, 26(10): 2014-2028.
- [4] Roy S K, Krishna G, Dubey S R, Chaudhuri B. HybridSN: Exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(2): 277-281.
- [5] Meng Z, Li L, Tang X, et al. Learning deep hierarchical spatial-spectral features for hyperspectral image classification based on residual 3D-2D CNN[J]. Sensors, 2019, 19(23): 5276.