引文格式：田婷婷,杜斌,谭美淋,等. 植被指数引导的高光谱影像小麦种植区提取方法研究[J]. 地理空间信息, 2025, 23(4):59-62. doi:10. 3969/j. issn. 1672-4623.2025.04.012

植被指数引导的高光谱影像小麦种植区提取方法研究

田婷婷[1]，杜　斌[1]，谭美淋[1]，岳云峰[1]，黄佐凡[2]，张　帅[3]
（1. 内蒙古自治区测绘地理信息中心，内蒙古 呼和浩特 010000；2. 福建省经纬数字科技有限公司，福建　福州 350000；
3. 武汉星视寰宇科技有限公司，湖北 武汉 430000）

摘　要：农作物对于不同波段的反射和吸收呈现出显著的光谱特征，这使得高光谱图像在农作物分类中具备天然的优势。为了解决高光谱遥感影像农作物提取中的空间信息缺失和光谱响应不一致问题。提出多种植被指数耦合的农作物提取网络，利用植被指数构建光谱特征库，辅助网络进行农作物提取，通过引入尺度间的注意力机制和交叉通道增强模块，弥补空间描述信息和通道相关性信息的不足。以内蒙古典型作物小麦为实验对象进行研究，结果显示该方法在农作物提取方面表现出显著性能

关键词：植被指数；高光谱影像；农作物提取；深度学习
中图分类号：P237　　文献标志码：B　　文章编号：1672-4623（2025）04-0059-04

Research on Wheat Planting Areas Extraction Method from Hyperspectral Images Guided by Vegetation Index

TIAN Tingting[1], DU Bin[1], TAN Meilin[1], YUE Yunfeng[1], HUANG Yifan[2], ZHANG Shuai[3]
(1. Inner Mongolia Autonomous Region Surveying and Mapping Geographic Information Center, Hohhot 010000, China;
2. Fujian Jingwei Digital Technology Co., Ltd., Fuzhou 350000, China;
3. Starvision World Technology Corporation, Wuhan 430000, China)

Abstract: Crops exhibit significant spectral characteristics in different bands, providing a natural advantage for crop classification in hyperspectral images. To address spatial information gaps and inconsistent spectral responses in crop extraction from hyperspectral remote sensing images, we proposed a crop extraction network that coupled multiple vegetation indices. We utilized vegetation indices to construct a spectral feature library, assisting in crop extraction. By introducing a scale-aware attention mechanism and a cross-channel enhancement module, we addressed deficiencies in spatial description and channel correlation information. Taking wheat, a typical crop in Inner Mongolia, as the experimental subject, the result demonstrates the significant performance of this method in crop extraction.

Key words: vegetation index, hyperspectral image, crop extraction, deep learning

获取农作物种植信息对于精准农业的推动至关重要。传统的获取方法主要通过实地调查和抽样验证，但受到对统计数据的依赖、调查主观性的影响、大量人力物力投入以及不可避免的调查误差的制约，难以实现农作物空间分布的可视化[1-2]。在这一背景下，遥感技术因其覆盖面积大、重访周期短、获取成本相对较低、精度较高等特点而成为一种快速、准确获取农作物空间分布和生长状况信息的关键手段。其中，高光谱影像因其“图谱合一”的特性而备受关注[3-4]。高光谱影像提供了丰富的光谱和空间信息，为农业产量估算、有害生物监测以及作物生长状态监测等提供了创新性解决方案[5-7]，这为精准农业的实践奠定了坚实的基础。

本文提出了一种基于先验引导和数据驱动的高光谱遥感影像作物分类深度学习方法，该方法通过引入多个经典植被指数作为先验知识，以丰富网络特征的表达能力，并构建跨尺度增强注意机制和交叉通道增强模块，深度挖掘复杂种植情境下的农作物空间信息和光谱相关性。这一策略旨在强化网络的识别能力和抗干扰性。此外，网络采用全卷积的整体结构，使得该方法具备实际应用的可行性。

1　研究方法

图 1 展示了整体模型架构。首先，基于先验知识，我们选择了响应显著的光谱波段和经典植被指数，并将它们合并为输入数据；接着，采用一组经过预训练的ResNet50的残差块来提取初始特征；最后，通过引入跨尺度增强关注机制和交叉通道增强模块，进一步增强了空间和光谱信息，以获取更具识别性的判别表示。

项目来源：内蒙古自治区测绘地理信息中心自选项目 （NMGZCS-C-F-220342）。
第一作者简介：田婷婷（1989—），本科，高级工程师，从事遥感影像智能解译工作，E-mail：1834252229@qq.com。

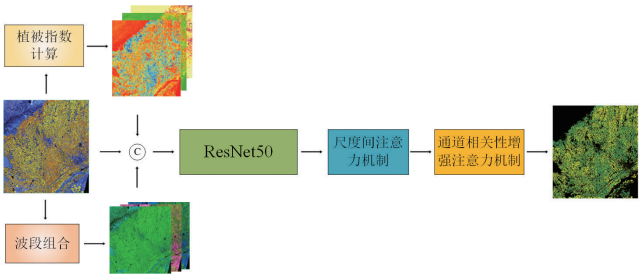


图1 多种植被指数耦合的高光谱遥感影像农作物提取网络

1.1 植被指数选择

根据农作物的生物物理特性以及植被在可见光、近红外和短波红外波段的反射率特性[8]，我们选择了几种经典植被指数来拓展网络特征的表达能力并引导网络对植被区域进行关注。在这其中，2个主要的指数是归一化植被指数（NDVI）[9]和红边叶绿素植被指数（ReCI）[10]。NDVI的计算公式如下：

$$NDVI = (NIR - RED)/(NIR + RED) \quad (1)$$

式中，NDVI一般取值为+1~−1，正值代表有植被覆盖，且覆盖度越大值越大。负值代表云、水、雪等，ReCI的计算公式如下：

$$ReCI = \left(\frac{NIR}{RED}\right) - 1 \quad (2)$$

式中，ReCI一般用于检测植被的叶绿素含量，能够根据植物叶片颜色的不同来区别作物的不同物候期。

1.2 尺度间注意力机制

为了克服高光谱数据在空间信息描述方面的限制，本方法采用了一种自适应调整网络感受野的方法，以获取不同尺度的空间特征，并根据像素之间的依赖性赋予不同的关注。如图2所示，首先使用多尺度卷积核替代池化操作，通过自适应选择合适的卷积核尺寸来提取不同感受野下的图像特征；其次，将不同尺度的特征进行融合，以弥补空间信息的不足。通过引入1D-Conv来建立不同像素之间的内在依赖关系，使得网络更加注重感兴趣区域的空间描述信息，从而筛选出具有较强辨别性的特征。

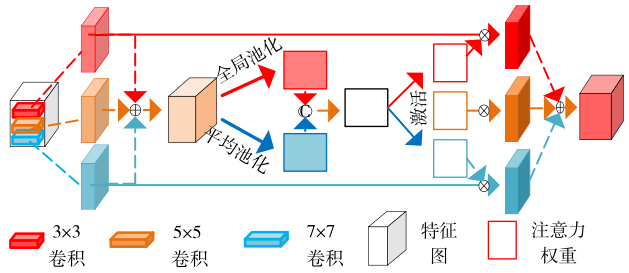


图2 尺度间注意力机制示意图

1.3 交叉通道增强模块

为解决农作物间潜在的光谱混淆问题，本文设计了一个交叉通道相关性增强模块，以深入挖掘通道间的相关性、实现特征映射的跨通道信息交换，并强调关键的光谱波段信息以进行分类重要性划分。具体而言，通过一个1×1卷积和Softmax操作，获得一个全局注意矩阵，通过与输入特征相乘以得到全通道的关注度量。接着，进行瓶颈转换以捕获通道间的依赖性。然而，我们意识到浅层的依赖性建模可能不足以解决农作物之间复杂的光谱混淆问题。为了进一步加强跨信道信息的交互，本文方法引入了一个核大小为3的一维卷积操作，有助于促进通道间的信息传递和整合，以更好地理解不同通道之间的关联性，交叉通道增强模块结构如图3所示。

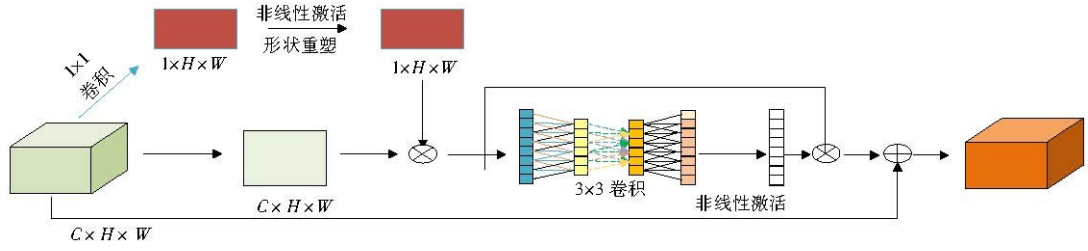


图3 通道相关性增强注意力机制示意图

2 实 验

本节将详细介绍在内蒙古地区小麦和水稻种植区进行实验的结果，并展示模型提取结果与人工提取结果的对比。这些实验结果将进一步验证所提出方法在复杂的农作物种植结构下对农作物的识别性能和分类准确度。

2.1 研究区与数据概况

本研究的调查区域位于巴盟地区的五原县，地理坐标为107°35′10"~108°37′50"E、40°46′30"~41°16′45"N，该地区以其广泛的地理范围、丰富多样的农作物种类、多样化的同种作物类型而著称，因此成为国家农业开发的重要焦点。然而，由于该地农作物的空间分布具有随机性，地块破碎且存在混种现象，这给农作物种植信息的获取带来了极大的困难。

数据集选用Sentinel-2高光谱影像，具体参数如表1所示。为确保数据的质量，实验过程中进行了统一的数据预处理，包括几何校正、辐射校正和大气校正。另外，结合野外调研结果，我们采用了人机交互

的方式对遥感影像进行解译，以获取样本数据，最后以256的步长进行裁剪，得到共5 000对符合研究需求的影像和标签，其中80%的数据用于模型的训练，其余20%用于验证和测试，训练数据如图4所示，标签影像中，白色为小麦区域，黑色为其他区域。

表1　Sentinel-2高光谱卫星参数

技术指标	参数
光谱通道及其星下点地面像元分辨率	海岸区气溶胶 B1：443 nm（60 m） 蓝色 B2：490 nm（10 m） 绿色 B3：560 nm（10 m） 红色 B4：655 nm（10 m） 植被红边 B5：705 nm（20 m） 植被红边 B6：740 nm（20 m） 植被红边 B7：783 nm（20 m） 近红外 B8：842 nm（10 m） 植被红边 B8A：865 nm（20 m） 水气 B9：945 nm（60 m） 短波红外 B10：1 375 nm（60 m） 短波红外 B11：1 610 nm（20 m） 短波红外 B12：2 190 nm（20 m）
幅宽	290 km

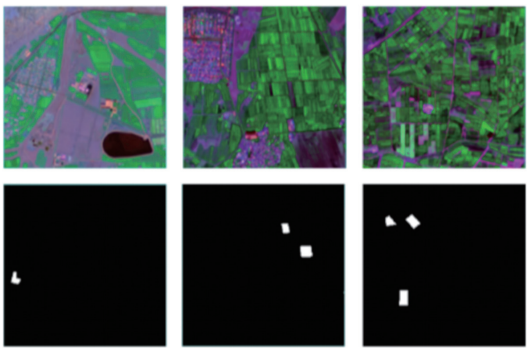


图4　数据集概况

2.2　实验参数与指标设置

为了验证所提出方法的优越性，本文选择了4种先进的方法进行对比，包括SVM[11]、u-Net[12]、CDCNN[13]、HRNet[14]，第一种为传统方法，其余为深度学习方法。所有方法基于PyTorch深度学习框架实现，模型的训练过程在Windows平台的NVIDIA 2080Ti GPU上完成。为了增加训练数据的多样性，在训练时进行了随机裁剪、随机旋转和随机翻转等数据增广操作。模型采用交叉熵损失作为约束，优化器选择Adam，其中 β_1 和 β_2 的值分别为默认值0.9和0.999，学习率为0.001，批次大小设置为8，总训练迭代轮数为300轮。

本文采用2种公认的定量指标评估分类性能，包括总体精度和 F_1 分数，总体精度（overall accuracy, OA）是指被正确分类的像元总数和与像元总数的比值，计算公式为：

$$OA=\frac{\sum_{i=1}^{n}X_{ij}}{N} \tag{3}$$

式中，n 为行列数；X_{ij} 为第 i 行、第 j 列的元素；N 为所有元素的和。F_1 分数（F_1-score），是统计学中用来衡量二分类模型精确度的一种指标，可以看作是模型精确率和召回率的一种调和平均，其计算公式为：

$$F_1=2\times\frac{\text{precision}\times\text{recall}}{\text{precision}+\text{recall}} \tag{4}$$

式中，precision为查准率；recall为召回率。

2.3　实验结果

我们对所提出的方法在内蒙古自治区相应农作物种植区的影像上的提取效果进行了评估，以人工判读绘制的图斑作为真值进行对比。为确保实验结果的可靠性，我们在影像范围内随机选取了多个地面尺寸为1 km × 1 km的地块进行了精度验证。

图5给出了所有方法在数据集上的定性结果。可以看出，由于内蒙地区存在复杂的农田种植结构，只依靠光谱信息进行分类的SVM效果较差，分类图存在大量错分区域，这点在地块三和地块五上更为明显。基于深度学习的方法由于其强大的特征提取能力以及加入了空间信息，普遍取得了比SVM优越的分类效果，但CDCNN与Unet的分类结果仍然存在误分区域，证明二者不能很好地应对农作物由于物候等原因引起的光谱混淆问题。HRNet由于加入了多尺度思想，取得了具有竞争力的分类效果，但是从地块三与地块六可以看出，对于光谱易混淆区域效果不够理想。相比之下，本文方法展现出了优越的分类性能，通过尺度间注意力机制的特征增强，多尺度信息得到重用，网络能够捕捉到细小区域与大面积区域的相关信息，即使在复杂的农田结构情况下，模型在哨兵影像上仍然准确提取出作物区域。另外交叉通道增强模块能够很好的筛选出显著波段，屏蔽噪声波段，有效解决光谱混淆问题。然而，在本文方法的分类结果中，仍然存在明显的误分区域。这种误分可能是由于同一种植物在不同的生长阶段呈现出显著的物候差异所致。物种的生长周期导致了不同阶段的植被覆盖率和土壤裸露率的变化，这反映在遥感影像中的光谱特征上，增加了分类器面临的挑战。具体而言，不同物种在不同的生长阶段具有不同的光谱特征，例如，在生长初期，植被可能呈现出较浅的颜色和纹理，而在成熟阶段，植被可能更加繁茂，颜色更加深绿。相比之下，裸土的光谱特征则可能更加单一和稳定。这种物种在不同时期的光谱差异会导致分类器在影像中误判

裸土为植被，或者将植被误判为裸土，进而产生误分区域。表2展示了不同方法的定量结果，本文方法在所有地块上表现出了分类优越性，分类总体精度均超过0.87，F_1分数平均超过0.86。这表明，所提方法在实际应用中具备一定的可行性与有效性

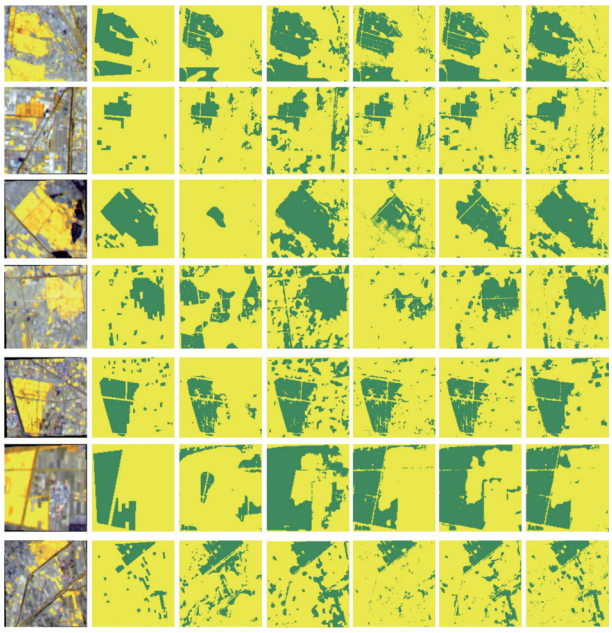


图5 模型结果

表2 定量结果

地块编号	SVM		CDCNN		U-Net		HRNet		Ours	
	OA	F_1	*OA*	F_1	*OA*	F_1	*OA*	F_1	*OA*	F_1
1	85.53	71.63	82.71	75.58	85.87	75.91	87.37	79.53	89.35	85.53
2	90.83	57.40	83.09	49.93	93.22	67.39	91.70	65.29	93.13	90.83
3	70.94	18.32	83.08	78.66	78.83	56.58	87.02	77.12	89.94	70.94
4	64.87	25.56	77.03	61.99	84.90	47.37	88.00	72.00	90.35	64.87
5	89.71	75.16	86.48	76.59	91.19	80.65	92.16	82.57	92.34	89.71
6	61.60	8.05	81.74	74.48	88.37	81.31	85.96	78.59	85.72	61.60
7	82.73	48.94	85.92	61.28	91.62	62.34	89.62	66.23	92.68	82.73

3 结 语

本研究充分考虑了高光谱影像的数据特征及农作物生理物候特性。面对农作物分类中常见的空间信息缺失和光谱混淆等问题，本文提出了一种基于多植被指数耦合的高光谱遥感影像农作物提取网络。在内蒙古地区的实验中，该方法成功应对了复杂的种植结构，实现了对小麦的高精度识别，分类准确度达到了0.86以上，彰显了其显著的有效性。未来的研究方向将侧重于通过利用时间序列数据来增强模型的泛化能力，以解决由于物候差异引起的准确率下降问题。这一方法涉及引入多时相的高光谱数据，结合时序特征进行建模和分类，旨在更全面地捕获农作物生长变化，提高模型对不同生育阶段的适应性，从而进一步提升农作物分类的鲁棒性和准确性。

参考文献

[1] 周淑芳,陈雨竹,夏建锋,等. 多源遥感数据协同的地块级农作物精细提取[J]. 中国农业信息,2022,34(4):20-29

[2] 冯海宽,岳继博,樊意广,等. 利用VGC-AGB模型和高光谱遥感的马铃薯地上生物量估算[J]. 光谱学与光谱分析,2023,43(9):2 876-2 884

[3] 费帅鹏,禹小龙,兰铭,等. 基于高光谱遥感和集成学习方法的冬小麦产量估测研究[J]. 中国农业科学,2021,54(16):3 417-3 427

[4] Peng X, Han W, Ao J, et al. Assimilation of LAI Derived from UAV Multispectral Data into the SAFY Model to Estimate Maize Yield[J]. Remote Sensing,2021(13):1 094

[5] Lianze T, Yong L, Hong J Z, et al, Summary of UAV Remote Sensing Application Research in Agricultural Monitoring[J]. Sci Technol Inf,2018(16):122-124

[6] 韩彦岭,刘业锟,杨树瑚,等. 利用深度特征融合进行高光谱遥感影像分类[J]. 遥感信息,2021,36(2):13-23

[7] Xiao Z, Gong Y, Long Y, et al. Airport Detection Based on a Multiscale Fusion Feature for Optical Remote Sensing Images[J]. IEEE Geoscience and Remote Sensing Letters, 2017,14(9):1 469-1 473

[8] 唐延林,黄敬峰,王秀珍,等. 水稻、玉米、棉花的高光谱及其红边特征比较[J]. 中国农业科学,2004,44(1):29-35

[9] 余琦殷,宋超. 基于MODIS数据的白茭滩自然保护区人工植被恢复区植被指数研究[J]. 福建农林大学学报(自然科学版),2023,52(6):837-845

[10] 许嘉桐,陈书涛,张苗苗,等. 不同作物叶片和茎全磷含量与高光谱植被指数的关系[J]. 河南农业科学,2022,51(9):141-150

[11] Melgani F, Bruzzone L. Classification of Hyperspectral Remote Sensing Images with Support Vector Machines[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004,42(8):1 778-1 790

[12] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation[C]//Medical Image Computing and Computer-assisted Intervention-MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18. Springer International Publishing, 2015: 234-241

[13] Lee H, Kwon H. Going Deeper with Contextual CNN for Hyperspectral Image Classification[J]. IEEE Transactions on Image Processing, 2017, 26(10): 4 843-4 855

[14] Wang J, Sun K, Cheng T, et al. Deep High-resolution Representation Learning for Visual Recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020,43(10):349-336