

基于 CBAM-U-HRNet 模型和 Sentinel-2 数据的棉花种植地块提取

靳 宁¹ 孙 林² 张东彦^{2,3} 张 选⁴ 李 毅⁵ 姚 宁⁵

(1. 山西能源学院资源与环境工程系, 晋中 030600;

2. 安徽大学农业生态大数据分析与应用技术国家地方联合工程研究中心, 合肥 230601;

3. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100; 4. 新疆生产建设兵团第三师农业科学研究所, 图木舒克 843900;

5. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100)

摘要: 棉花是我国重要的经济作物和战略储备物资,及时、准确地获取棉花空间分布信息对于棉花产量预测、农业政策的制定与调整具有重要意义。针对高分辨率遥感影像获取难度大以及传统机器学习对特征信息利用不足的问题,本文以新疆南部地区图木舒克市为目标区域,提出一种以 U-HRNet 为基本框架,融合 CBAM 注意力机制的 CBAM-U-HRNet 棉花种植地块提取模型。选择 U-Net、HRNet 和 U-HRNet 作为对比模型,评估 CBAM-U-HRNet 模型在 Sentinel-2 (10 m) 和 GF-2 (1 m) 2 种空间分辨率数据集上的表现以及在棉花地块提取的优势。结果表明,基于 Sentinel-2 遥感影像的 CBAM-U-HRNet 组合模型对棉花地块的提取精度最优,mIoU 和 mPA 分别达到 92.78% 和 95.32%。与 Sentinel-2 数据集相比,空间分辨率更高的 GF-2 数据在 HRNet、U-Net 和 U-HRNet 网络上取得了更高的精度。对于两种不同空间分辨率的数据集,基于 CBAM-U-HRNet 模型的棉花地块提取精度较为接近,表明 CBAM-U-HRNet 模型能够减少由于数据集空间分辨率不同导致的错分。与随机森林算法相比,CBAM-U-HRNet 模型对棉花地块提取的准确率更高。研究结果可以为干旱地区棉花识别与种植地块快速提取提供技术支撑。

关键词: 棉花; 种植地块提取; 注意力机制; CBAM-U-HRNet 模型; Sentinel-2

中图分类号: S127 文献标识码: A 文章编号: 1000-1298(2023)11-0159-10

OSID: 

Classification of Cotton Planting Area Using CBAM-U-HRNet Model and Sentinel-2 Data

JIN Ning¹ SUN Lin² ZHANG Dongyan^{2,3} ZHANG Xuan⁴ LI Yi⁵ YAO Ning⁵

(1. Department of Resources and Environment, Shanxi Institute of Energy, Jinzhong 030600, China

2. National Engineering Research Center of Agro-Ecological Big Data Analysis and Application, Anhui University, Hefei 230601, China

3. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

4. Institute of Agricultural Science and Technology of Third Division, Xinjiang Production and Construction Corps, Tumxuk 843900, China

5. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: Cotton is an important economic crop and strategic reserve material in China, timely and accurate acquisition of cotton spatial distribution information is of great significance for cotton yield prediction and agricultural policy development and adjustment. In order to address the problems of the difficult availability of high-resolution remote sensing data and insufficient usability of feature information by traditional machine learning, a CBAM-U-HRNet classification model was established to extract cotton planted area, where U-HRNet and CBAM attention mechanism were combined, and Tumxuk City in the southern Xinjiang was taken as an study area. Firstly, the Sentinel-2 remote sensing data were pre-processed and annotated. Secondly, the attention mechanism CBAM was introduced into U-HRNet to enhance the important features for cotton classification, suppress the relatively unimportant features, and reduce the interference caused by complex background information. Finally, U-Net, HRNet and

收稿日期: 2023-06-05 修回日期: 2023-08-28

基金项目: 山西省基础研究计划自然科学面上项目(202203021221231)

作者简介: 靳宁(1983—),男,副教授,博士,主要从事生态环境遥感和信息化研究,E-mail: jinn.13b@igsrr.ac.cn

通信作者: 张东彦(1982—),男,教授,主要从事遥感信息处理和大数据挖掘与应用研究,E-mail: zhangdy@ahu.edu.cn

U-HRNet were selected to compare with CBAM-U-HRNet model to test their performance in the classification of cotton planted area. During this process, two different spatial resolution datasets such as Sentinel-2 (10 m) and GF-2 (1 m) were used, and the advantages of CBAM-U-HRNet model were evaluated by using the best feature subset. The results showed the CBAM-U-HRNet model that using Sentinel-2 remote sensing data had the best classification accuracy for cotton planted area, with mIoU and mPA reaching 92.78% and 95.32%, respectively. Comparing with the Sentinel-2 dataset, the GF-2 data had higher spatial resolution and achieved higher accuracy by using HRNet, U-Net and U-HRNet networks. For the two datasets with different spatial resolutions, the classification accuracies of cotton planted area using the CBAM-U-HRNet model was comparable to each other. The CBAM-U-HRNet model can reduce the misclassification induced by the difference in spatial resolution of the two datasets. Comparing with the random forest algorithm, the CBAM-U-HRNet model had higher accuracy in the classification of cotton. The research results can provide technical support for the classification of cotton, and the fast and objective extraction of vegetation planted area in arid regions.

Key words: cotton; planting area classification; attention mechanism; CBAM-U-HRNet model; Sentinel-2

0 引言

棉花是新疆重要的经济作物,快速准确地获取棉花的空间分布信息有助于新疆地区乡村振兴战略的实施,对棉花产业的可持续发展和种植结构的调整具有重要意义^[1]。目前,大量的农业统计数据例如农作物种植面积等依然是通过实地调查和走访农民等方式获得。这种方式不仅耗费大量的物力和财力,还容易受到人为主观因素的影响,一定程度上降低了统计结果的可靠性和准确性。

近年来随着卫星遥感技术的快速发展,卫星遥感数据在时间分辨率、空间分辨率以及光谱特性等方面有了显著提升^[2],使得区域尺度上棉花种植生产过程的精细化信息获取成为可能。吕绍伦等^[3]基于 GF-1 卫星遥感影像,使用光谱阈值分析和最小距离法识别新疆维吾尔自治区玛纳斯县及周边棉花种植信息,结果显示 9 月是棉花种植面积识别的最佳时相。田野等^[4]基于 HJ-CCD 数据影像,运用支持向量机的分层监督分类法和专家知识决策树分类法提取了新疆维吾尔自治区奎屯市棉花种植面积。AL-SHAMMARI 等^[5]利用 Landsat 8 数据生成 NDVI 时间序列图像,经过傅立叶变换处理后提取相位和振幅,利用随机森林算法建立了棉花分类模型。传统的监督分类方法和非监督分类方法只能提取作物图像的纹理和颜色结构等特征用于作物种植区的分类,不能提取更高层语义特征,鲁棒性较差,分类结果不理想^[6]。

深度学习方法在整体准确性方面通常优于传统(浅层)机器学习技术,能够提取出图像高级语义特征,近年来在农业遥感识别领域成为研究热点^[7]。司凯凯等^[8]借助 DeepLab v3+ 模型基于 Sentinel-2 数据提取新疆维吾尔自治区尉犁县棉花种植地块,

结果表明与 SegNet 相比,DeepLab v3+ 模型的准确率提高 18%。伊尔潘·艾尼瓦尔等^[9]基于 GF-2 卫星数据,利用 Unet 网络模型提取塔里木盆地北部的棉花地块,总体精度达到 84.22%,较支持向量机和随机森林模型分别提高 11.93% 和 11.73%。LI 等^[10]基于 GF-1 卫星图像,利用改进的 DenseNet 网络结构识别棉花地块,并与 ResNet、VGG、SegNet 和 DeepLab v3+ 的分类结果进行了比较。胡航等^[11]通过在 HRNet 网络中添加 CBAM 注意力机制,解决了遥感图像地物分类中各个类别目标之间的像素数量不平衡问题。HRNet 作为近年来提出的先进网络框架,在密集预测中取得了最好的效果^[12],但 HRNet 在区域尺度应用时存在一定的错分现象。为了解决这一问题,WANG 等^[13]提出 U 型高分辨率网络(U-HRNet),并在多个数据集上取得了很好的分类效果。

为了避免卫星遥感影像数据由于像素数量分布不均匀导致的感兴趣区错分漏分现象,以及传统机器学习算法存在的对遥感影像特征信息利用不足、大数量样本运算能力有限等问题,本文选取新疆维吾尔自治区图木舒克市作为目标区域,通过获取 Sentinel-2 卫星遥感数据,提出一种基于卷积注意力机制 CBAM 的 U-HRNet 模型,并将其应用于棉花种植地块提取。基于 Pytorch 平台搭建深度学习网络模型,验证 CBAM-U-HRNet 模型对棉花种植地块提取的精度,以期干旱区作物精细化分类提供思路。

1 研究区概况与数据

1.1 研究区概况

研究区位于新疆生产建设兵团第三师图木舒克市(39°36'~40°04'N,78°38'~79°50'E),该市是新

疆南疆地区重要的优质棉生产基地。图木舒克市位于天山南麓塔里木盆地西部,叶尔羌河、喀什噶尔河流域冲积平原区(图 1)。地势由东南向西北倾斜,属于典型的干旱大陆性气候特征,热量资源丰富,独特的气候条件有利于棉花干物质的生产和积累。




图 1 研究区位置

Fig. 1 Location of study area

图木舒克市的农作物主要为冬小麦、玉米和棉花。冬小麦在 4 月下旬和 5 月上旬进入拔节期,7 月上旬进入成熟期。玉米在 4 月中下旬播种,8 月成熟。棉花在 4 月上旬播种,5 月出苗,6 月进入蕾期,7 月开始进入花铃期,8 月下旬及 9 月处于吐絮期。7 月和 8 月棉花处于全盛生长时期;9 月棉花处于吐絮期,此时其他作物大部分处于收割期。

1.2 数据来源

选取欧空局哨兵 2 卫星 (Sentinel - 2) 数据。Sentinel - 2 地球观测卫星携带多光谱成像系统 (Multi-spectral imaging, MSI) 获取光学图像,覆盖 13 个光谱波段(表 1),光谱波段从可见光到短波红外分别为:4 个 10 m 波段(蓝、红、绿和近红外);6 个 20 m 波段(植被红边波段 4 个窄波段,SWIR 波段 2 个长波段);3 个 60 m 波段用于大气校正和卷云探测。空间分辨率 10 m 使 Sentinel 数据具有对地球表面(例如城市扩张和农业)进行精细探测的潜力。Sentinel - 2A 和 Sentinel - 2B 双星协同观测使得 Sentinel - 2 数据每 5 d 可以更新一次。在光学遥感领域,Sentinel - 2 数据的 3 个红边波段 (B5、B6 和 B7) 有助于提高遥感植被地物分类精度^[14]。Sentinel - 2 的主要优势在于其高空间分辨率、高时间分辨率以及红边波段的可用性。在现有的免费卫星遥感数据源中,Sentinel - 2 的时间分辨率和空间分辨率最高。

棉花处于花铃期时其长势较好,其他作物尚未播种或已成熟,棉花与其他地物之间的差别较大,此时是实现棉花种植区高精度分割提取的最佳时期。因此,选择的卫星遥感影像数据时间为棉花花铃期,即 7 月中下旬。

表 1 Sentinel - 2 光谱波段参数

Tab. 1 Spectral wavebands of Sentinel - 2 satellites

波段编号	波段名称	Sentinel - 2A	Sentinel - 2B	空间分辨率/m
		中心波长/nm	中心波长/nm	
Band 1	Coastal aerosol	443.9	442.3	60
Band 2	Blue	496.6	492.1	10
Band 3	Green	560.0	559.0	10
Band 4	Red	664.5	665.0	10
Band 5	Vegetation Red Edge1	703.9	703.8	20
Band 6	Vegetation Red Edge2	740.2	739.1	20
Band 7	Vegetation Red Edge3	782.5	779.7	20
Band 8	NIR	835.1	833.0	10
Band 8A	Narrow-NIR	864.8	864.0	20
Band 9	Water Vapor	945.0	943.2	60
Band 10	SWIR - Cirrus	1 373.5	1 376.9	60
Band 11	SWIR1	1 613.7	1 610.4	20
Band 12	SWIR2	2 202.4	2 185.7	20

1.3 数据预处理

使用 Google Earth Engine (GEE) 平台获取图木舒克市 8 月 22 日的 Sentinel - 2 L2A 级表面反射率产品。这些数据经过辐射定标、大气校正等预处理^[15],为了避免光学数据因雪/云造成的错误检测,使用质量控制带 (QA60) 波段对 Sentinel - 2 L2A 数据进行去云处理。采用空间分辨率分别为 20 m 和 10 m 的 Sentinel - 2 数据(共 10 个光谱波段)进行棉花地块识别。为了使所选用的各波段具有相同空间分辨率,采用最邻近重采样算法将空间分辨率 20 m 的波段重采样至 10 m,最后将 10 个波段合成并裁剪生成感兴趣区。

1.4 候选特征变量

特征变量的选择对棉花地块的准确提取至关重要,直接影响最终的分类精度。为了充分利用遥感影像中不同地物的特征信息,共筛选 33 个卫星遥感数据的特征变量用于棉花种植地块的提取。这些特征变量包括对 Sentinel - 2 数据重采样后生成空间分辨率 10 m 的 10 个波段反射率构建的光谱特征空间,以及通过在 GEE 中计算获得的 23 个扩展特征变量(表 2)。

1.5 数据集构建

深度学习网络训练过程中需要用到图像数据集及其对应的标签。由于缺乏研究区棉花的标签数据,利用空间分辨率为 1 m 的光学遥感影像 (GF - 2) 结

表 2 构建的扩展特征变量

Tab. 2 Extended characteristic variables

扩展特征 类型	特征 编码	表达式	文献 序号
指数特征	NDWI	$(B_3 - B_8) / (B_3 + B_8)$	[1]
	REP	$705 + 35[0.5(B_4 + B_7) - B_5] / (B_6 - B_5)$	[1]
	NDVI _{re5}	$(B_8 - B_5) / (B_8 + B_5)$	[14]
	NDVI _{re6}	$(B_8 - B_6) / (B_8 + B_6)$	[14]
	NDVI _{re7}	$(B_8 - B_7) / (B_8 + B_7)$	[14]
	NDVI	$(B_8 - B_4) / (B_8 + B_4)$	[15]
	WDRVI	$(0.2B_8 - B_4) / (0.2B_8 + B_4)$	[16]
	EVI	$2.5(B_8 - B_4) / (B_8 + 6B_4 - 7.5B_2 + 1)$	[17]
	SAVI	$1.5(B_8 - B_4) / (B_8 + B_4 + 0.5)$	[18]
	MTCI	$(B_6 - B_5) / (B_5 - B_4)$	[19]
纹理特征	GNDVI	$(B_8 - B_3) / (B_8 + B_3)$	[20]
	MNDWI	$(B_3 - B_8) / (B_3 + B_{11})$	[21]
	NDBI	$(B_{11} - B_8) / (B_{11} + B_8)$	[21]
	Angular second momentasm (asm), correlation (corr), contrast, variance (var), inverse differential moment(idm), entropy(ent)		[22]
	地形特征 Elevation, Hillshade, Slop, Aspect		[23]

合野外调查数据进行目视解译,通过手工标记的方式为相应的土地覆盖类型创建标签。数据集通常被分成训练集、验证集与测试集。训练集通过设置分类器的参数来建立分类模型,验证数据集用于筛选模型的最佳参数,测试集用于评估模型的性能[24]。

使用 GIS 软件制作标签数据时,首先创建研究区的掩膜.shp 文件,元素类型为面要素。使用工具箱裁剪原始影像得到训练图像数据.tif 文件。其次创建训练集区域的矢量标签文件,修改标签的 id 字段值并设置标签的空间参考和遥感影像一致。棉花地块的 id 字段值修改为灰度值 255,非棉花地块的 id 字段值修改为 0。利用工具箱将矢量标签.shp 文件转为栅格标签.tif 文件。最后将训练影像数据和标签数据随机裁剪为 5 000 幅 256 像素 × 256 像素的数据集,原始影像数据与标签数据文件名一一对应,得到成品数据集。由于深度学习需要大量的数据进行训练[25],因此本研究采用加噪、对称变换、旋转、改变亮度等数据增强方法对有限的样本数据进行扩充,增加训练集的方差,提升神经网络的概括能力,最终获得 10 000 幅 256 像素 × 256 像素的数据集,并按照 7:2:1 的比例将数据集划分为训练集、验证集和测试集。

2 CBAM - U - HRNet 模型构建和特征变量筛选

2.1 U - HRNet 模型改进

U - HRNet 融合 HRNet 和 U - Net 模型的优势,

延续 U - Net 网络的编码器-解码器结构,使网络能够同时利用高低层次的特征,有利于低分辨率的较强语义特征向上与高分辨率的特征融合;保留 HRNet 的多个分辨率卷积流并联模式,通过在低分辨率增加模块以及在高分辨率减少模块,使低分辨率获得更多的计算资源以改善语义表示[13]。U - HRNet 的主体包含 9 个阶段和 5 个分辨率流,分辨率分别为 1/4、1/8、1/16、1/32 和 1/64。第 1 阶段包含 1 个由 4 个瓶颈残差块组成的单分支 hr 模块,每个块的宽度为 64;然后是一个 3 × 3 卷积,将特征图的宽度改为 C,表示为 1/4 分辨率流的宽度。第 2 至第 8 阶段分别包含 1、5、2、2、1、1、1hr - modules。所有这些模块都由 2 个分支组成,这些模块中的每个分支由 4 个基本剩余块组成。最后,5 个解析流的卷积宽度分别为 C、2C、4C、8C 和 16C。由于研究区耕地破碎,地物信息复杂,目标尺度大小不一,为了更好地突出图像中棉花的特征信息,减少图像中噪点和不相干背景的干扰,引入了 CBAM 模块。

CBAM 包含通道注意力模块(Channel attention, CA)和空间注意力模块空间注意力(Spatial attention, SA)(图 2)。CA 模块通过通道之间的特征关系创建通道注意力特征图[26]。在 CA 模块中,首先输入特征图 F 经过 2 个并行的平均池化(Avg pool, AP)和最大池化(Max pool, MP)层,即 AP(F)和 MP(F),分别表示聚合遥感图像的平均池化和最大池化特征;然后将这些特征通过一个权重共享具有隐藏层的多层感知网络(MLP),将这些特征逐元素相加,再使用 Sigmoid 激活函数处理后得到每个通道使用的权重,最终得到通道注意力特征图。通道注意力 M_c 表达式为

$$M_c(F) = \sigma(MLP(AP(F)) + MLP(MP(F))) \quad (1)$$

式中 σ ——Sigmoid 激活函数

SA 模块利用空间之间的属性关系创建空间注意力特征图[27]。与 CA 模块不同,SA 模块侧重于输入特征图中有意义信息的位置。对输入特征沿着通道维度进行 AP 和 MP 操作,拼接得到突出位置区域的有效特征,再通过一个 7 × 7 的卷积运算后经 Sigmoid 激活函数处理得到空间注意力 M_s 为

$$M_s(F') = \sigma(f^{7 \times 7}([AP(F'), MP(F')])) \quad (2)$$

式中 $f^{7 \times 7}$ ——7 × 7 的卷积运算

CBAM 注意力机制首先应用于遥感图像的通道,再应用于空间维度。即输入特征图 F 首先与通道注意力特征图 M_c 点乘得到特征 F',特征 F'再与空间注意力特征图 M_s 逐元素相乘,最后输出特征 F''为




图 2 CBAM 模块示意图

Fig.2 Schematic of CBAM

$$F'' = M_s(F') \otimes F' \quad (3)$$

$$F' = M_c(F) \otimes F \quad (4)$$

其中

式中 $\otimes$ ——逐元素相乘操作

基于 U - HRNet 网络和 CBAM 卷积注意力模块得到改进后的 U - HRNet 网络模型 (图 3)。在

CBAM - U - HRNet 中, Stage 2、Stage 3 和 Stage 4 分支输出的特征首先通过 CBAM 模块, 再与 Stage 8、Stage 7 和 Stage 6 的特征融合, 放大棉花识别的重要特征, 抑制相对不重要的特征, 提高网络对棉花地块的提取精度。




图 3 CBAM - U - HRNet 网络结构

Fig.3 Structure diagram of CBAM - U - HRNet

2.2 评价指标

采用平均像素精度 (Mean pixel accuracy, mPA)、平均交并比 (Mean intersection over union, mIoU)、F1 值和准确率 (Accuracy) 等评价指标对网络模型进行定量评估, 指标越大表示模型分割效果越好^[28]。其中, 平均像素精度表示所有类型正确分类像素的平均值; 平均交并比表示所有类别的预测像素与真实值相似程度的平均值; F1 值能够平衡精度和召回率, 在不均匀分布的情况下表现较好; 准确率表示被正确分类的样本占总样本的比例。利用混淆矩阵评估棉花实际种植地块和提取结果之间的一致性程度, 即总体精度 OA、生产者精度 PA、用户精度 UA 和 Kappa 系数。以上指标能够从不同角度反映作物分类的精度^[29]。

2.3 特征变量筛选

使用随机森林特征重要性选择 (Random forest features importance, RF - FI) 算法结合顺序向前选择 (Sequential forward selection, SFS) 算法从多个候选特征变量中筛选特征变量作为 CBAM - U - HRNet 模型的输入。随机森林算法本质上是对决策树算法的一种改进, 通过随机选择样本集和特征集合进行训练, 其结果由多棵决策树构成并进一步由多棵树投票表决得出最终的分类结果。重要特征的选择过程: ①随机森林中每一棵决策树的袋外数据误差, 由相应的袋外数据计算得到。②随机对袋外数据所有样本的特征 X 加入噪声干扰, 计算得到袋外数据误差。根据这两次误差结果计算特征的重要性, 对于某个特征随机加入噪声之后, 其袋外的准确率大幅度下降, 表明样本的分类结果在很大程度上

受这个特征的影响,即该特征的重要程度比较高。③对得到的特征重要性进行降序排序,确定阈值并删除不重要的特征,得到新的特征集合。顺序向前选择算法是一种从下向上的方法,其流程为:特征子集 X 从空集开始,每次将一个特征 x 加入到特征子集 X ,使得特征函数 $J(X)$ 最优。对第 1 个特征选择单独最优的特征,第 2 个特征从其余特征中选择能够与第 1 个特征组合后表现最优的特征,后面的每一个特征都与已经入选的特征组合成最优的特征。顺序向前选择算法的缺陷在于,虽然考虑了一定的特征间组合因素,但对于第 1 个特征的选择仍然是仅依赖于单个特征准则,即使它与后面选择的特征并不是最优的组合,也无法再去去除已入选的特征。

3 实验

3.1 实验环境与模型训练

深度学习模型的实验环境为 Windows 10 搭载的 Pytorch, CPU 处理器为 Intel Xeon E5-2630 v4, GPU 处理器为 NVIDIA GeForce RTX 3080。在实际实验中,统一设置网络模型的参数,各个模型均采用 Adam 优化器。初始学习率设置为 0.000 1。为了防止过拟合问题,学习率下降方式采用余弦退火法,批量大小(batch_size)设为 16,训练模型的迭代次数设为 100。

3.2 实验结果

3.2.1 图木舒克市棉花地块提取结果

图木舒克市棉花地块提取结果如图 4 所示,图中绿色部分为研究区棉花种植地块,白色部分为非棉花。CBAM-U-HRNet 模型在复杂区域提取的棉花种植地块效果较好,提取的棉花图斑较为完整,建筑物、水体边界也较为清晰,大部分线状道路较为完整且不存在间断现象。




图 4 基于 CBAM-U-HRNet 模型的棉花种植地块空间分布

Fig. 4 Spatial distribution of cotton planted area derived by using structure of CBAM-U-HRNet model

3.2.2 不同模型下棉花提取结果对比

为了验证本研究提出的基于 CBAM-U-

HRNet 模型的棉花地块提取方法的可行性,选取 U-Net、HRNet 和 U-HRNet 作为对比模型。这 3 个对比模型与 CBAM-U-HRNet 均使用相同的训练数据和测试数据,采样平均像素精度、平均交并比、F1 值和准确率作为网络模型评价的指标。

使用添加注意力机制 CBAM 的 U-HRNet 模型的 F1 值和准确率分别达到 95.08% 和 95.26%,对棉花地块的分类效果最好(表 3)。深度学习具备像素级的分析能力,不仅能识别简单的地物信息,对稀疏的特征目标具有更好的分类效果。添加了注意力机制的 U-HRNet 模型的 mIoU 和 mPA 分别达到 92.78%、95.32%,分别比 U-Net 和 HRNet 提高 4.09、4.65 个百分点和 5.22、3.44 个百分点;F1 值为 95.08%,分别比 U-Net 和 HRNet 高 4.52、4.63 个百分点。总体上,HRNet 的各项指标最差,添加注意力机制的 U-HRNet 各项指标均最好,误分区域相对较少。

表 3 基于 Sentinel-2 影像的不同模型分类精度对比
Tab. 3 Comparison of accuracy for different classification models using Sentinel-2 data

网络模型	mIoU	mPA	F1 值	准确率
CBAM-U-HRNet	92.78	95.32	95.08	95.26
U-HRNet	90.85	93.27	93.23	93.68
U-Net	88.69	90.67	90.56	91.73
HRNet	87.56	91.88	90.45	91.29

选取 3 景具有不同空间特征的图像,比较不同深度学习方法提取棉花地块的准确性。图 5 中白色区域为棉花,黑色区域为非棉花。区域 I 是乡镇周边的棉田,该区域地势平坦,棉花种植较为密集,长势良好。区域 II 中存在多种土地覆盖类型,除棉花外,还有杂草、建筑物、道路、河流和荒地,棉花种植地块相对破碎。区域 III 的棉花种植较为稀疏分散,有大面积荒地和丘陵。

由图 5 可得,区域 I 的分类效果最好。原因是 8 月棉花处于花铃期,此时棉花生长旺盛,光谱特征与其他地物类型之间的差异明显。此区域棉花种植较为密集,相较于区域 II 和 III 的种植面积较大,分类结果较好。区域 I 的 4 种网络分类结果之间的差异不大,道路、建筑物等边缘信息均被较好地分割出来。区域 II 的棉花种植地块相对破碎且分散,有 1 块非棉田地块被 HRNet 和 U-Net 模型错分为棉田。U-HRNet 和 CBAM-U-HRNet 模型能够实现正确的分类,表明这 2 种模型对于复杂地块的提取效果较好。区域 III 主要为丘陵和荒地,HRNet 模型明显存在错分、漏分等问题,提取的棉花地块连片分布,边缘信息缺失严重,分割结果不太理想。U-




图 5 基于 Sentinel - 2 数据不同模型对研究区 3 个代表性区域的棉花提取结果

Fig. 5 Cotton planted area derived in three representative regions in study area using Sentinel - 2 data

Net 的分割结果相较于 HRNet 明显较为圆滑,但存在密集种植区域内漏分现象。

总体上,U - HRNet 的表现较好,但仍然存在边缘信息缺失的问题,尤其是在棉花种植地块破碎,其他地物类型相对较多的情况。为了使模型能够充分反映棉花地块的特征信息,同时减少复杂背景信息带来的干扰,通过在 U - HRNet 中引入卷积注意力模块 CBAM 突出棉花识别的重要特征,降低田间复杂种植环境对棉花地块提取精度的影响。

3. 2. 3 不同空间分辨率遥感数据对棉花地块提取结果的影响

适宜时间分辨率和空间分辨率的卫星遥感数据有助于提高农作物的识别精度。为了同中高分辨率的 Sentinel - 2 (10 m) 遥感影像数据进行对比,采用成本较高且获取难度较大的高分辨率 GF - 2 (1 m) 遥感影像作为训练数据,评估不同空间分辨率卫星遥感数据对 CBAM - U - HRNet 模型提取棉花种植地块准确率的影响,并同 U - Net、HRNet 和 U - HRNet 模型的提取结果进行对比(表 4)。

表 4 基于 GF - 2 数据不同模型分类精度对比

models using GF - 2 data				%
网络模型	mIoU	mPA	F1 值	准确率
CBAM - U - HRNet	93. 86	96. 25	96. 63	96. 86
U - HRNet	92. 73	95. 84	95. 76	95. 21
U - Net	91. 53	93. 46	93. 84	94. 76
HRNet	91. 86	95. 28	94. 64	95. 88

对于 HRNet 模型,以 GF - 2 数据进行模型训练得到的网络精度较 Sentinel - 2 数据有较大提升,二者之间的准确率差值达到 4. 59% ,U - Net 模型次之。两种空间分辨率的遥感数据集在 CBAM - U - HRNet 网络模型上取得的精度最为接近(图 6) ,表

明加入注意力机制的 U - HRNet 网络能够充分挖掘棉花在遥感影像上的深层次信息,抑制次要信息,提高棉花地块提取的精度,减少因卫星遥感影像空间分辨率的不同造成的错分现象。




图 6 基于 GF - 2 数据和 Sentinel - 2 数据不同空间分辨率数据源的模型精度对比

Fig. 6 Comparison of accuracy for different classification models using GF - 2 data and Sentinel - 2 data at different spatial resolutions

3. 2. 4 优选特征子集下棉花提取结果对比

使用随机森林特征重要性选择算法结合顺序向前选择算法从 33 个候选特征变量中筛选出 6 个特征变量 (B_8 、REP、 B_6 、 B_8 - contrast、NDVI_{re5} 和 Elevation)。将这些特征变量作为 CBAM - U - HRNet 模型的输入,探究植被指数、高程及纹理特征的引入对于 CBAM - U - HRNet 模型的影响,模型的 mIoU、mPA、F1 值和准确率分别为 93. 06%、95. 38%、94. 06% 和 95. 38%。

为了对比分析 CBAM - U - HRNet 模型得到的分类结果和传统机器学习算法如随机森林的分类结果,从研究区中裁减一块矩形区域作为网络的输入。在 GF - 2 影像上均匀地设置 4 个 3 km × 3 km 的验证样方(图 7),评估 2 种算法对棉花地块的提取精度。




图7 基于GF-2影像规划的空间验证样方分布

Fig.7 Spatial distribution of verification quadrat using GF-2 data




图8 基于两种分类器的棉花种植区分布

Fig.8 Spatial distribution of cotton planted area for two classification models

评估CBAM-U-HRNet网络和随机森林两种算法的效果。棉花提取结果分类评价指标如表5所示。

表5 棉花地块分类结果提取评价指标

Tab.5 Evaluation indices for classification of cotton planted area

网络模型	样方编号	OA/%	PA/%	UA/%	Kappa 系数
CBAM-U-HRNet	样方1	95.8	96.3	97.0	0.88
	样方2	92.9	89.9	94.3	0.86
	样方3	95.1	94.2	91.6	0.87
	样方4	92.5	92.3	93.4	0.86
	平均值	94.1	93.2	94.1	0.87
随机森林	样方1	92.8	94.5	91.3	0.85
	样方2	91.0	88.7	91.0	0.83
	样方3	91.9	92.4	94.4	0.85
	样方4	93.1	95.3	87.9	0.86
	平均值	92.2	92.7	91.1	0.85

由表5可知,基于CBAM-U-HRNet模型的4个验证样方OA的平均值为94.1%,Kappa系数为0.87,与RF相比分别提高1.9个百分点和0.02。基于CBAM-U-HRNet模型的棉花分类结果中,4个验证样方的OA在92.5%~95.8%之间,Kappa系数在0.86~0.88之间。基于随机森林算法的棉

整体上,2种分类器提取的棉花地块的空间分布信息存在较小的差异(图8)。基于CBAM-U-HRNet网络提取的结果中农田较为破碎,对稀疏棉花地块的提取效果较好。基于随机森林分类器得到的棉花地块结果整体上较为完整,但对于城镇周边耕地、建筑用地和道路边界的处理不够清晰,存在一定的破碎图斑。

为了定量评估基于优选特征变量的RF和CBAM-U-HRNet模型的棉花地块提取结果,采用图8中的样方验证方案,使用GF-2影像获得的棉花分布数据作为验证数据,利用均匀分布的4个验证样方对比分析矩形研究区棉花地块的提取结果,

花分类结果中,有2个样方的OA低于92%,仅有一个样方的Kappa高于0.85,表明CBAM-U-HRNet模型对于棉花地块提取的精度优于随机森林分类器。

4 讨论

基于Sentinel-2影像数据,通过将注意力机制融入U-HRNet并建立CBAM-U-HRNet模型,较好地实现了棉花地块的提取。现有棉花种植地块提取的研究较少涉及注意力机制和U-HRNet的应用^[30-31]。图木舒克市作为南疆地区重要的优质棉产区,该区域的研究结果可以为南疆地区及“一带一路”干旱区棉花地块的提取提供一定参考。

通过比较CBAM-U-HRNet模型与HRNet、UNet、U-HRNet模型对棉花地块的提取结果,发现添加注意力机制的U-HRNet模型取得了更好的分割效果,这与胡航等^[11]的研究结果一致。CBAM可以有效提高模型的特征提取能力,提升模型对棉花目标特征信息的反映能力,减少由复杂背景信息带来的干扰。

以Sentinel-2和GF-2数据为例,对比分析不

同空间分辨率的遥感数据对棉花地块提取准确率的影响。结果表明,GF-2 数据在 HRNet、U-Net 和 U-HRNet 网络上取得了更好的效果,高分辨率影像数据有助于提升对复杂背景地物识别的准确率^[32]。同 GF-2 卫星遥感影像较高的使用成本相比,Sentinel-2 数据免费且具有较高的空间分辨率和时间分辨率。对于 CBAM-U-HRNet 模型而言,两种空间分辨率的卫星遥感数据集在棉花地块提取的精度上差别较小。CBAM 注意力机制可以有效提高模型的特征提取能力,减少因数据空间分辨率的不同造成的误差,提高棉花地块的遥感提取精度。

不同的特征变量对于遥感识别作物精度有一定影响,MAO 等^[33]基于 Sentinel-2 遥感数据,采用随机森林算法讨论了棉花提取的最佳特征组合,结果表明优选特征能够在简化工作量的基础上获得较高的棉花制图精度。本研究使用优选特征子集作为 CBAM-U-HRNet 模型的输入,4 个验证样方的总体精度和 Kappa 系数的平均值分别为 94.1% 和 0.87。基于 RF 分类器的总体精度和 Kappa 系数的平均值分别为 92.2% 和 0.85,样方 2 和样方 3 的总体精度低于 92%,可能是由于干旱等原因导致棉花出现查苗补种现象,造成研究区内棉花长势不均一。浅层机器学习算法(RF)不能够很好地利用特征变量^[9],深度学习模型的结果证明深度学习在干旱地

区棉花地块遥感识别应用中的潜力。

5 结论

(1)由于研究区的地物类型较为复杂,将注意力机制融入 U-HRNet 网络构建棉花种植地块识别模型 CBAM-U-HRNet,并与 U-Net、HRNet、U-HRNet 模型进行了比较。结果表明,基于 Sentinel-2 遥感影像 CBAM-U-HRNet 组合模型的 mIoU 为 92.78%,分别比 U-Net 和 HRNet 提高 4.09、5.22 个百分点;F1 值为 95.08%,较 U-Net、HRNet 和 U-HRNet 分别提高 4.52、4.63、1.85 个百分点。

(2)基于 Sentinel-2 和 GF-2 卫星遥感数据评估了不同空间分辨率对深度学习网络模型提取棉花地块的影响。结果表明,高分辨率的 GF-2 数据在 HRNet、U-Net 和 U-HRNet 网络上取得了更好的效果,CBAM-U-HRNet 模型能够减少因空间分辨率的不同导致的错分。为了消除特征选择不完全对随机森林算法的影响,以最佳特征子集作为 CBAM-U-HRNet 模型的输入。结果表明 CBAM-U-HRNet 模型的平均总体精度为 94.1%,Kappa 系数为 0.87,与随机森林算法相比,其总体精度和 Kappa 系数分别提高 1.9 个百分点和 0.02。CBAM-U-HRNet 模型较随机森林算法实现了更高的棉花地块提取精度。

参 考 文 献

- [1] HU T, HU Y, DONG J, et al. Integrating Sentinel-1/2 data and machine learning to map cotton fields in Northern Xinjiang, China[J]. Remote Sensing, 2021, 13(23): 4819.
- [2] MURA M, BOTTALICO F, GIANNETTI F, et al. Exploiting the capabilities of the Sentinel-2 multi spectral instrument for predicting growing stock volume in forest ecosystems[J]. International Journal of Applied Earth Observation and Geoinformation, 2018, 66: 126-134.
- [3] 吕绍伦, 赵阳, 陈万基, 等. 基于遥感云计算的阿拉尔市棉花种植面积提取[J]. 棉花科学, 2022, 44(4): 19-25.
LÜ Shaolun, ZHAO Yang, CHEN Wanji, et al. Extraction of cotton planting area in Alaer based on remote sensing cloud computing[J]. Cotton Sciences, 2022, 44(4): 19-25. (in Chinese)
- [4] 田野, 张清, 李希灿, 等. 基于多时相影像的棉花种植信息提取方法研究[J]. 干旱区研究, 2017, 34(2): 423-430.
TIAN Ye, ZHANG Qing, LI Xican, et al. Extraction method of cotton plantation information based on multi-temporal images[J]. Arid Zone Research, 2017, 34(2): 423-430. (in Chinese)
- [5] AL-SHAMMARI D, FUENTES I, WHELAN B M, et al. Mapping of cotton fields within-season using phenology-based metrics derived from a time series of Landsat imagery[J]. Remote Sensing, 2020, 12(18): 3038.
- [6] 赵晋陵, 詹媛媛, 王娟, 等. 基于 SE-UNet 的冬小麦种植区域提取方法[J]. 农业机械学报, 2022, 53(9): 189-196.
ZHAO Jinling, ZHAN Yuanyuan, WANG Juan, et al. SE-UNet-based extraction of winter wheat planting areas[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 189-196. (in Chinese)
- [7] 董金玮, 吴文斌, 黄健熙, 等. 农业土地利用遥感信息提取的研究进展与展望[J]. 地球信息科学学报, 2020, 22(4): 772-783.
DONG Jinwei, WU Wenbin, HUANG Jianxi, et al. State of the art and perspective of agricultural land use remote sensing information extraction[J]. Journal of Geo-information Science, 2020, 22(4): 772-783. (in Chinese)
- [8] 司凯凯, 汪传建, 赵庆展, 等. 基于哨兵 2 号遥感影像最优时相组合的棉花提取方法[J]. 石河子大学学报, 2022, 40(5): 639-647.
SI Kaikai, WANG Chuanjian, ZHAO Qingzhan, et al. Cotton extraction method based on optimal time phase combination of Sentinel-2 remote sensing images[J]. Journal of Shihezi University (Natural Science), 2022, 40(5): 639-647. (in Chinese)
- [9] 伊尔潘·艾尼瓦尔, 买买提·沙吾提, 买合木提·巴拉提. 基于 GF-2 影像和 Unet 模型的棉花分布识别[J]. 自然资源遥

- 感, 2022, 34(2): 242–250.
- ERPAN A, MAMAT S, MAIHEMUTI B, et al. Cotton distribution recognition based on GF-2 image and Unet model[J]. Remote Sensing for Natural Resources, 2022, 34(2): 242–250. (in Chinese)
- [10] LI H, WANG G, DONG Z, et al. Identifying cotton fields from remote sensing images using multiple deep learning networks[J]. Agronomy, 2021, 11(1): 174.
- [11] 胡航, 牛晓伟, 左昊, 等. 基于改进 HRNet 架构的图像语义分割算法应用研究[J]. 现代计算机, 2022, 28(18): 23–29.
- HU Hang, NIU Xiaowei, ZUO Hao, et al. Application study of image semantic segmentation algorithm based on improved HRNet architecture[J]. Modern Computer, 2022, 28(18): 23–29. (in Chinese)
- [12] SUN K, ZHAO Y, JIANG B, et al. High-resolution representations for labeling pixels and regions[J]. arXiv, 2019, 1:13.
- [13] WANG J, LONG X, CHEN G, et al. U-HRNet: delving into improving semantic representation of high resolution network for dense prediction[J]. arXiv, 2022, 1:13.
- [14] DELEGIDO J, VERRELST J, ALONSO L, et al. Evaluation of Sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content[J]. Sensors, 2011, 11(7): 7063–7081.
- [15] 黄双燕, 杨辽, 陈曦, 等. 机器学习法的干旱区典型农作物分类[J]. 光谱学与光谱分析, 2018, 38(10): 3169–3176.
- HUANG Shuangyan, YANG Liao, CHEN Xi, et al. Study of typical arid crops classification based on machine learning[J]. Spectroscopy and Spectral Analysis, 2018, 38(10): 3169–3176. (in Chinese)
- [16] SUN Y, QIN Q, REN H, et al. Red-edge band vegetation indices for leaf area index estimation from Sentinel-2/MSI imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 58(2): 826–840.
- [17] 刘传迹, 金晓斌, 徐伟义, 等. 2000—2020 年南疆地区棉花种植空间格局及其变化特征分析[J]. 农业工程学报, 2021, 37(16): 223–232.
- LIU Chuanji, JIN Xiaobin, XU Weiyi, et al. Analysis of the spatial distribution and variation characteristics of cotton planting in southern Xinjiang from 2000 to 2020[J]. Transactions of the CSAE, 2021, 37(16): 223–232. (in Chinese)
- [18] FEI H, FAN Z, WANG C, et al. Cotton classification method at the county scale based on multi-features and random forest feature selection algorithm and classifier[J]. Remote Sensing, 2022, 14(4): 829.
- [19] 王汇涵, 张泽, 康孝岩, 等. 基于 Sentinel-2A 的棉花种植面积提取及产量预测[J]. 农业工程学报, 2022, 38(9): 205–214.
- WANG Huihan, ZHANG Ze, KANG Xiaoyan, et al. Cotton planting area extraction and yield prediction based on Sentinel-2A[J]. Transactions of the CSAE, 2022, 38(9): 205–214. (in Chinese)
- [20] ZHU M, SHE B, HUANG L, et al. Identification of soybean based on Sentinel-1/2 SAR and MSI imagery under a complex planting structure[J]. Ecological Informatics, 2022, 72: 101825.
- [21] LIU J, FENG Q, GONG J, et al. Winter wheat mapping using a random forest classifier combined with multi-temporal and multi-sensor data[J]. International Journal of Digital Earth, 2018, 11(8): 783–802.
- [22] LIU S, PENG D, ZHANG B, et al. The accuracy of winter wheat identification at different growth stages using remote sensing[J]. Remote Sensing, 2022, 14(4): 893.
- [23] LUO K, LU L, XIE Y, et al. Crop type mapping in the central part of the North China Plain using Sentinel-2 time series and machine learning[J]. Computers and Electronics in Agriculture, 2023, 205: 107577.
- [24] YANG S, GU L, LI X, et al. Crop classification method based on optimal feature selection and hybrid CNN-RF networks for multi-temporal remote sensing imagery[J]. Remote Sensing, 2020, 12(19): 3119.
- [25] 樊湘鹏, 周建平, 许燕, 等. 基于优化 Faster R-CNN 的棉花苗期杂草识别与定位[J]. 农业机械学报, 2021, 52(5): 26–34.
- FAN Xiangpeng, ZHOU Jianping, XU Yan, et al. Identification and localization of weeds based on optimized Faster R-CNN in cotton seedling stage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5): 26–34. (in Chinese)
- [26] GUL M S K, MUKATI M U, BÄTZ M, et al. Light-field view synthesis using a convolutional block attention module[C]// 2021 IEEE International Conference on Image Processing (ICIP). IEEE, 2021: 3398–3402.
- [27] CHANG R, HOU D, CHEN Z, et al. Automatic extraction of urban impervious surface based on SAH-Unet[J]. Remote Sensing, 2023, 15(4): 1042.
- [28] SYRRIS V, HASENOHR P, DELIPETREV B, et al. Fully convolutional networks for semantic segmentation[J]. Remote Sensing, 2019, 11(8): 907.
- [29] ZHANG S, GUO J, LUO N, et al. Improving Wi-Fi fingerprint positioning with a pose recognition-assisted SVM algorithm[J]. Remote Sensing, 2019, 11(6): 652.
- [30] WANG N, ZHAI Y, ZHANG L. Automatic cotton mapping using time series of Sentinel-2 images[J]. Remote Sensing, 2021, 13(7): 1355.
- [31] REN B, ZHOU H, SHEN H, et al. Research on cotton information extraction based on Sentinel-2 time series analysis[C]// 2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics). IEEE, 2019: 1–6.
- [32] TAMIMINIA H, SALEHI B, MAHDIANPARI M, et al. Google Earth Engine for geo-big data applications: a meta-analysis and systematic review[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 164: 152–170.
- [33] MAO H, MENG J, JI F, et al. Comparison of machine learning regression algorithms for cotton leaf area index retrieval using Sentinel-2 spectral bands[J]. Applied Sciences, 2019, 9(7): 1459.