

不同种植设施背景蔬菜作物无人机高光谱精细分类

胡顺石^{1,2}, 杨斌^{1,2}, 黄英¹, 岑奕³, 戚文超³

1. 湖南师范大学 地理科学学院, 长沙 410081;

2. 地理空间大数据挖掘与应用湖南省重点实验室, 长沙 410081;

3. 中国科学院空天信息创新研究院, 北京 100101

摘要: 中国蔬菜产业规模大、产值高, 是促进农民增收和农村农业经济发展的支柱产业。快速准确地获取区域尺度蔬菜种植结构信息对于农业现代化、自动化和精细化等具有重要意义。无人机高光谱遥感技术具有快速机动灵活和“图谱合一”的优势, 在作物精细分类中具有广泛应用前景。然而蔬菜作物种植规模差异大、农业景观破碎度高, 同时还受地膜、大棚和防鸟网覆盖等影响, 无人机高光谱图像易产生严重的混合光谱效应, 给蔬菜作物精细分类带来了极大的挑战。针对此问题, 本研究以湖南省农科院高桥科研基地蔬菜种植区为例, 获取无人机高光谱图像, 探索采用支持向量机和深度学习方法对不同蔬菜作物进行精细分类。研究表明: 基于无人机高光谱遥感数据, 可以实现不同覆盖背景下的蔬菜作物精细分类; 两大分类方法的平均总体精度分别为78.03%和90.75%, 平均Kappa系数分别为0.7359和0.8887, 相较于支持向量机方法, 基于深度学习的分类方法获得的精细分类效果更加理想, 三维卷积神经网络和引入注意力机制的卷积神经网络可以有效提取图像中的光谱-空间特征信息, 在蔬菜作物精细分类中体现出更好的分类效果; 蔬菜作物在大尺度地块上空间纹理特征明显, 而在小地块尺度上差异较大, 宜采用不同深度学习方法对其进行精细分类; 不同覆盖背景与蔬菜作物产生混合光谱效应, 对作物精细分类效果影响显著。

关键词: 精细分类, 蔬菜作物, 无人机, 高光谱, 大棚, 地膜

中图分类号: TP701/P2

引用格式: 胡顺石, 杨斌, 黄英, 岑奕, 戚文超. 2024. 不同种植设施背景蔬菜作物无人机高光谱精细分类. 遥感学报, 28(1): 280-292

Hu S S, Yang B, Huang Y, Cen Y and Qi W C. 2024. Fine classification of vegetable crops covered with different planting facilities using UAV hyperspectral image. National Remote Sensing Bulletin, 28(1): 280-292 [DOI: 10.11834/jrs.20222054]

1 引言

中国是蔬菜第一生产大国, 蔬菜生产种植规模、出口规模稳居世界第一位, 蔬菜产量和质量逐年增长, 年度总产值达到2万亿元(张真和, 2017a; 李斯更和王娟娟, 2018; 李哲敏等, 2018)。蔬菜在中国农作物种植结构中占比高达12.83%, 是仅次于粮食的主要农作物之一, 已成为实现农业增收和促进农村经济发展的主要支柱产业之一, 在丰富老百姓菜品、提高人们生活水平和促进乡村振兴战略实施等方面具有重要作用

(张真和, 2017a; 李斯更和王娟娟, 2018; 李哲敏等, 2018)。准确掌握蔬菜种植类型、面积、空间分布等种植结构信息对准确评估和预测区域蔬菜产量及价格具有重要价值, 对区域蔬菜作物管理现代化、自动化和精细化具有重要意义。

遥感技术具有快速、宏观、无损监测的优势, 已发展成为农作物信息提取的主要手段之一(赵春江, 2014; 陈仲新等, 2016; Weiss等, 2020)。采用多光谱遥感卫星影像对主要粮食作物开展分类研究较多(Weiss等, 2020), 然而基于中低空间分辨率卫星影像的作物分类结果尚不能满足现

收稿日期: 2022-01-29; 预印本: 2022-04-01

基金项目: 国家重点研发计划(编号: 2017YFE0194900); 遥感科学国家重点实验室开放基金(No. OFSLRSS202221); 湖南省教育厅资助科研项目(编号: 21B0046); 2019年湖南省研究生优质课程项目《微波与高光谱遥感》(编号: 130)

第一作者简介: 胡顺石, 研究方向为资源环境遥感、高光谱遥感理论和应用。E-mail: shunshi.hu@hunnu.edu.cn

通信作者简介: 岑奕, 研究方向为高光谱遥感数据处理及应用。E-mail: cenyi@radi.ac.cn

代农业信息化、精准化的需求,并且在提取作物类型信息时,研究者通常需要获取作物生长周期内多时相遥感卫星影像(Asgarian等,2016;Zhong等,2020),这对于多云雨地区而言极为困难。另外,中国耕地地块面积小、景观破碎程度高、异质性严重(Lu等,2013),中低分辨率卫星影像无法实现作物精细分类。与主要粮食作物实行大田种植方式不同,蔬菜多采用地膜覆盖或温室大棚种植方式,用以抵御恶劣天气环境、控制病虫害和提高作物单位面积产量。近年来基于卫星遥感影像开展大棚和地膜覆盖信息提取成为研究热点(Hasituya和Chen,2017;Jiménez-Lao等,2020;朱德海等,2020),同时大棚内部或地膜覆盖作物种植类型识别也正在引起学者的广泛关注,比如,Aguilar(Aguilar等,2015)通过联合Landsat多时相影像和WorldView-2影像,采用决策树和面向对象分类方法探索研究了温室大棚内部秋季蔬菜作物(番茄、胡椒、黄瓜和茄子)的分类问题,总体分类精度最高可达81.3%。这项研究表明通过时序影像可以有效地探测温室大棚内蔬菜作物类型。在此基础上,Nemmaoui等(2018)提出了一种基于多时相多传感器卫星数据的温室大棚内部蔬菜作物识别的技术方法,并指出基于Sentinel-2A时间序列影像的分类结果要高于Landsat 8序列影像的分类结果。Moola(2021)则基于Sentinel-1A SAR图像的时间序列,采用加权的动态时间规整算法和模糊分类方法,实现了蔬菜作物有效分类。

传统通过人工实地调查方式获取蔬菜作物种植信息成本高、效率低,因此迫切需要发展快速准确的蔬菜作物种植结构信息提取方法。无人机遥感具有机动灵活、高空间分辨率、高便捷性、高性价比等特点,在小区域目标信息精细化遥感研究中具有重要作用(李德仁和李明,2014;廖小罕等,2019),可作为卫星农业遥感的重要补充。国内外不同学者采用无人机多光谱相机或数码相机开展了主要粮食作物的精细分类和信息提取研究(Torres-Sánchez等,2014;韩文霆等,2017;李明等,2018)。Feng等(2020)基于多时相无人机获取的数码照片,提出了一种基于注意机制的递归卷积神经网络方法实现了蔬菜作物精细分类。

高光谱技术可以获取可见光至近红外光谱区

间数百个连续光谱曲线,具有“图谱合一”、波段数量多、信息量大等优势(童庆禧等,2016),能够反映不同作物之间光谱特征细微差异,在农作物精细分类中被广泛使用(Lu等,2020)。Xue等(2017)提出一种基于稀疏图正则化的精细作物方法,采用小型机载光谱成像仪CASI获取高光谱数据,对小麦、土豆、韭菜、菜花、甜椒、西瓜等作物进行了精细分类,分类精度为87.43%,该研究指出其方法利用少量地面样本即可达到稳健的分类效果;Wei等(2019)提出了一种基于空间光谱融合的条件随机场的无人机高光谱遥感图像作物的精细分类方法,通过融合光谱和空间特征,减少同质区域内的光谱变化,从而达到准确识别作物的目的,该方法对田块尺度的油菜、小白菜、榨菜等18种蔬菜作物进行了精细分类,精度为94.60%。随着高光谱遥感分类算法研究的深入,越来越多的基于深度学习方法的分类算法也被应用到作物精细分类中(杜培军等,2016;Lu等,2020;Weiss等,2020;Zhong等,2020)。

随着无人机有效载荷和续航时间的不断提高,以及轻型高光谱成像传感器的快速发展,无人机高光谱遥感技术作为一种新型遥感对地观测技术应运而生,它可以获取高空间分辨率、高光谱分辨率影像(H²影像),并且无人机高光谱遥感具有灵活、成本低、实时数据采集能力强等优势特点,被广泛应用于作物精细分类(Zhong等,2020)。针对H²影像的优势与特点,Zhong等(2020)提出了一种基于条件随机场的深度卷积神经网络方法,用于农作物的精细分类,并构建了一套公开共享的高光谱高空间(双高)遥感影像地物精细分类数据集。

无人机高光谱由于其便捷性和高光谱高空间分辨率特征,使得其在区域性作物精细分类上具有较为明显的优势(Zhong等,2020)。然而基于无人机高光谱的蔬菜作物的精细分类仍然面临着一些挑战。首先,蔬菜作物类型繁多,栽培茬口多样,种植方式与技术复杂多变,存在塑料地膜、大棚、防鸟网、防虫网等复杂背景覆盖情形(张真和,2017a,2017b),这影响着蔬菜作物的光谱特征。其次,无人机高光谱影像极高空间分辨率特征将导致作物光谱差异性和空间异质性,存在“同物异谱,异物同谱”现象,给作物精细分类带来了困难(Zhong等,2020)。最后,蔬菜种植地

块尺寸较小, 多种蔬菜类型混合种植情形多, 农业景观破碎, 地块形状和规模差异较大, 地块尺度影响分类模型中参数的设置与选择。在此复杂背景下, 作物的光谱和纹理特征会发生较大的变化, 为蔬菜作物精细分类带来极大挑战, 当前高光谱图像精细分类方法能否适用于复杂背景下的蔬菜作物精细分类尚需要进一步深入研究。

为解决上述现实问题, 探索在局部小区域尺度上蔬菜作物信息提取方法, 本研究以湖南省农业科学院高桥科研试验基地为研究区, 采用无人机高光谱数据, 探索基地内不同蔬菜作物精细分类方法, 以期开展复杂背景下的基于无人机高光谱遥感技术的蔬菜作物精细分类方法研究和蔬菜种植精细管理提供技术支撑。

2 研究区概况和数据处理

2.1 研究区概况

湖南省农业科学院高桥科研试验基地 ($113^{\circ}21'39.5928''E$, $28^{\circ}28'54.3756''N$) 位于湖南

省长沙县高桥镇, 占地面积 3246 亩, 地势平坦; 该基地包含湖南省作物所、蔬菜所等 11 个研究所作物新品种选育、栽培、筛选试验核心区和成果展示区, 是一个综合性的试验示范基地。本次研究区域位于该试验基地南部区域, 如图 1 (a) 所示。通过实地踏勘和统计, 研究区域内包含有番茄、辣椒、水稻等 9 种农作物, 不同农作物的种植结构、植株大小、间隙等并不一致; 作物背景信息十分复杂。试验时间正值该区域不同蔬菜作物培育、生长关键期, 实验区蔬菜作物类型较多, 不同蔬菜作物的覆盖背景十分复杂, 包括地膜、防鸟网、防虫网以及大棚覆盖等, 如图 1 (b) 所示, 比较适合复杂背景下作物分类研究。部分作物底部覆有地膜, 如辣椒、丝瓜种植区; 部分作物是种植在大棚内部, 如辣椒种植区; 甚至还有部分作物底部覆盖地膜, 顶部有防鸟网或纱网, 如番茄、南瓜种植区。而水稻种植区顶部没有防鸟网, 属于大面积密集覆盖, 且长势良好, 实景照片如图 2 所示。

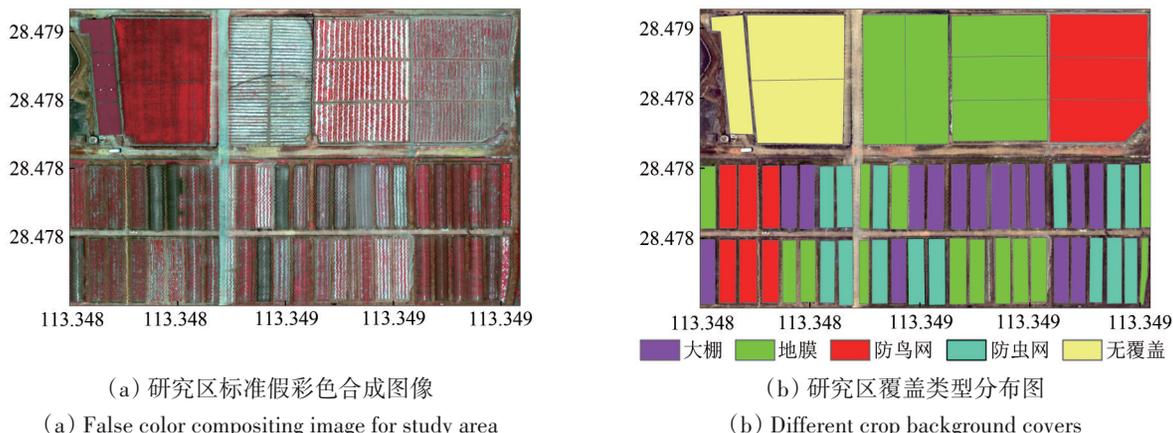


图1 研究区域、作物覆盖背景分布图

Fig. 1 Study area, crop background covers distributions

2.2 数据获取与预处理

本次试验选择的无人机平台为大疆经纬 M600 PRO, 飞行时间是 2021 年 6 月 8 日上午 11:00, 天气晴朗, 微风, 比较适合利用无人机平台获取遥感数据。无人机上搭载了 Headwall 微型高光谱成像仪 Micro-Hyperspec, 其光谱范围是 400—1000 nm, 270 个光谱波段, 光谱分辨率为 2 nm。作业时飞行高度为 200 m, 地面分辨率为 12.33 cm。飞行前, 在飞行区域平整地面上铺设定标白布, 用于获取

地表反射率数据; 同时获取传感器相应的暗电流用于消除噪声, 提高数据信噪比。此次实验共获取 4 个条带, 分别将每个条带转换成辐射亮度数据, 然后对其进行正射校正并镶嵌成一幅图像; 最后采用基于平场域方法 (童庆禧等, 2006) 获取研究区域的地表反射率数据。由于图像空间分辨率较高、范围较大, 在分类时需要较大的计算机内存, 为此我们将原始图像以 4:1 的方式进行空间采样, 同时训练样本与测试样本执行同样的操作。



(a) 地膜覆盖
(a) Mulch film



(b) 防鸟网/防虫网覆盖
(b) Bird or insect-proof screen



(c) 大棚覆盖
(c) Greenhouse

图2 不同覆盖背景

Fig. 2 Different cover backgrounds for vegetable crops

2.3 训练与测试样本选择

为了准确提取研究区作物类别，根据现场踏勘结果将研究区的地物类型划分14个类别，如图3所示，包括茄子、丝瓜、水稻、辣椒、番茄、铁皮厂房、西瓜、南瓜、黄瓜、番薯、无种植、水泥路面、裸土和其他。不同于众多高光谱分类验证实验采用随机抽取训练集的做法，本研究采取更贴合实际应用的方式，根据实地踏勘结果，通过人工选取小块作物作为带标记的训练样本(图3(a))，再选择剩下的作物作为测试样本

(图3(b))，以此减少训练集与测试集的空间相关性，同时增加样本测试的难度。具体样本划分如表1所示。

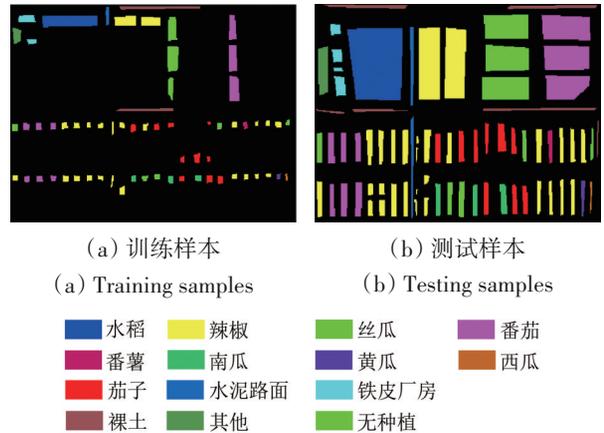


图3 14类地物训练样本和测试样本分布图

Fig. 3 Distribution map of 14 kinds of ground object training samples and testing samples

表1 训练样本及测试样本统计

Table 1 Statistics for training and test samples

序号	类别名称	训练样本(像元数)	测试样本(像元数)
1	茄子	554	2272
2	丝瓜	1199	6556
3	水稻	1018	6307
4	辣椒	1698	10467
5	番茄	1413	7380
6	铁皮厂房	256	761
7	西瓜	25	79
8	南瓜	183	825
9	黄瓜	36	198
10	番薯	50	227
11	无种植	55	235
12	水泥路面	100	783
13	裸土	630	1733
14	其他	189	785

3 作物精细分类方法

近年来，国内外学者发展了一系列针对作物精细分类的不同算法模型(陈仲新等, 2016)，其难点在于设计合适的分类算法从影像中挖掘有用的特征信息。在众多的分类算法模型中，经典机器学习方法和深度学习方法在作物精细分类中扮演重要角色。鉴于此，本文探索采用经典的支持向量机SVM方法和深度学习方法开展高桥实验田蔬菜作物精细分类研究。

3.1 基于SVM的分类方法

在机器学习领域中，SVM方法利用结构风险最小化原理，能够在少量样本情况下完成多维特征分类，取得良好分类效果并可以避免过拟合现象，SVM优良的泛化能力使得其被广泛应用于遥感图像分类领域（吴锦玉等，2019；叶珍等，2021）。尤其是基于核变换的SVM方法性能较好，它利用内积核函数实现特征向高维空间映射，解决了特征类别线性不可分问题。其中，高斯径向基函数RBF（Radial Basis Function）能够在使用较少参数的情况下得到与其他核函数相似的性能，是SVM方法最常用的核函数之一（Camps-Valls和Bruzzone，2005；叶珍等，2021）。此外，对于高光谱图像而言，其丰富的光谱信息有利于地物光谱特征表达，但是也带来了信息冗余和维度过高的问题。主成分分析PCA（Principal Component Analysis）（Jolliffe和Cadima，2016）是一种经典且应用十分广泛的数据降维方法，其核心思想是降低数据维度的同时尽可能多地保留原始数据信息，它通过正交变换寻找一组新的变量，依次使各个变量方差最大化，并且各变量之间彼此不相关。主成分分析法可以在一定程度上解决高光谱数据信息冗余和维度过高的问题。

本研究设计了传统SVM分类方法（SVM-Linear）、基于核变换的SVM分类方法（SVM-RBF）、基于主成分变换和核变换的SVM分类方法（SVM-RBF-PCA）对高桥实验田的不同作物分类。其中，SVM-RBF径向基函数gamma值设定为0.125，惩罚系数C=40；PCA主成分数目尝试了从5—50的所有设置。另外，将空间纹理结构特征加入到SVM-RBF-PCA模型中形成SVM-RBF-PCA-GLCM模型。空间纹理结构特征通过计算灰度共生矩阵（吴锦玉等，2019）获得表征图像纹理结构特征指标，包括均值、方差、同质性、对比度、熵、差异性、二阶矩和相关性共8项指标。另外，我们还选择了一种基于扩展随机游走ERW（Extended Random Walkers）分类方法（Kang等，2015）来提高分类精度。该方法是一种典型的空

间信息后处理技术（叶珍等，2021），首先采用支持向量机分类器获得高光谱图像的分类概率图，然后使用ERW算法对获得的像素概率图进行优化，将高光谱图像的空间信息编码为加权图，通

3.2 基于深度卷积神经网络的分类方法

随着深度学习在计算机视觉领域取得巨大成功，国内外不同学者也尝试将深度卷积神经网络引入高光谱图像分类（Zhong等，2018；Mdrafai等，2020）。深度卷积神经网络结构可以自动学习图像的抽象特征，获得样本更高层次和更丰富的语义信息，从而更好地完成分类任务，避免了传统方法中使用特征工程选择和构建特征集的繁琐流程。卷积神经网络CNN（Convolutional Neural Network）可以很好的抽取图像高维特征，在图像分类与识别中应用较多。本文采用一维CNN卷积神经网络（1D-CNN）、三维卷积神经网络（3D-CNN）（Li等，2017）以及引入注意力机制的Attention-CNN模型（Mdrafai等，2020），以上模型参数均按照原文设置。详细介绍CNN模型超出了本文探讨的内容且需要占用较大的篇幅，读者可查阅参考文献进行详细了解。值得注意的是3D-CNN模型和Attention-CNN模型都是基于三维CNN模型的，能够较好地融合光谱—空间特征信息。3D-CNN模型主要通过三维空间滤波方式提取这些图像中的光谱—空间特征，从而能较好地提取图像高阶特征。Attention-CNN模型基于三维卷积神经网络，通过加入注意力机制，能让网络更好地专注于学习通用特征，且能够较好地用于迁移学习（Ji等，2013）。

3.3 分类结果精度评价

将分类结果与测试样本进行比较，构建混淆矩阵，提取相关指标评价不同分类方法的分类精度，包括总体分类精度OA（Overall Accuracy）、Kappa系数（Kappa）、用户精度UA（User's Accuracy）、平均分类精度AA（Average Accuracy），不同精度计算方式（Congalton，1991）为式（1）—（4）。

$$OA = \frac{\sum_{i=1}^c x_{ii}}{N} \times 100\% \quad (1)$$

$$Kappa = \frac{N \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i+} \cdot x_{+i}}{N^2 - \sum_{i=1}^c x_{i+} \cdot x_{+i}} \quad (2)$$

$$UA = \frac{x_{ii}}{x_{i+}} \times 100\% \quad (3)$$

$$AA = \frac{\sum_{i=1}^C UA_i}{C} \quad (4)$$

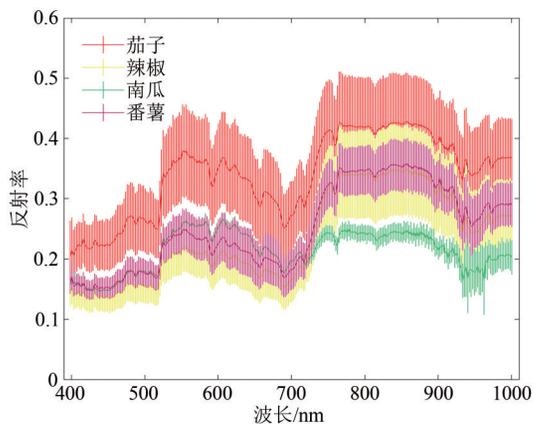
式中, N 为验证样本总数量, C 为类别数量; x_{ii} 为混淆矩阵主对角线上的元素, 表示第 i 类被正确分类的样本数量; x_{i+} , x_{+i} 分别为混淆矩阵第 i 行和第 i 列的和, 分别表示第 i 类分类的结果和地面真实值。

4 结果分析

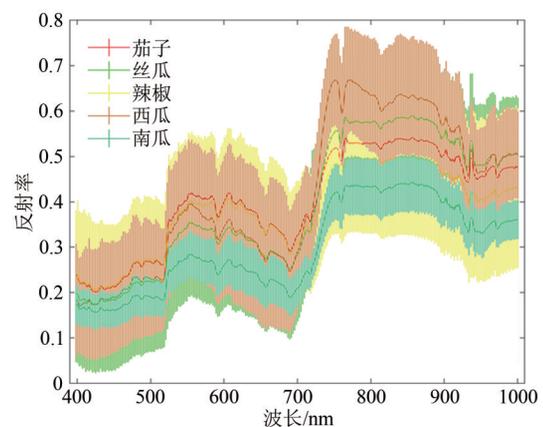
4.1 训练样本的光谱特征

高光谱技术能够以较高的光谱分辨率获得地物的诊断光谱, 从而区分具有不同性质的地物, 但是当物受到土壤、地膜、大棚覆盖背景物体

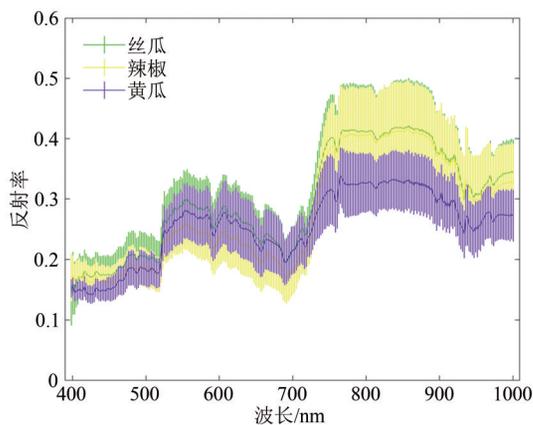
等强烈影响时, 地物诊断光谱特征会发生变化。图 4 (a)、(b)、(c) 分别显示了在大棚、地膜和防虫网覆盖背景下, 不同作物平均光谱与标准差。可以看出, 作物在不同覆盖背景下, 同类作物的光谱变化范围较大, 不同作物之间会存在交叠区域, 这意味着仅采用光谱特征对作物精细分类存在较大挑战。另外, 研究区 14 类不同地物训练样本的平均光谱相关系数矩阵如图 4 (d) 所示, 此相关系数矩阵图也表明, 铁皮厂房与其他地物光谱呈负相关特征, 受地面背景影响, 水泥路面和无种植区与其他作物的光谱相似程度有较大差异; 而从整体上来看, 不同蔬菜作物之间的光谱相似程度较高, 这也表明仅利用光谱特征较难区分这些不同蔬菜作物。



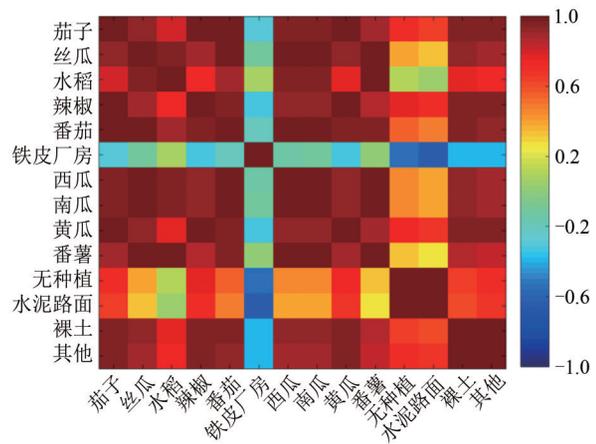
(a) Mean spectra ± standard deviation for crops under greenhouse cover backgrounds



(b) Mean spectra ± standard deviation for crops under mulch film cover backgrounds



(c) Mean spectra ± standard deviation for crops under insect-proof screen cover backgrounds



(d) Average spectral correlation coefficient matrix for training samples

图 4 不同覆盖背景作物平均光谱与标准差, 训练样本平均光谱相关系数矩阵

Fig. 4 Mean spectra ± standard deviation for different covers, mean spectra correlation matrix for each crop

4.2 不同分类方法的结果与精度

实验所用训练集、测试集及不同分类方法得到的结果如图5所示，精度评价见表2。从图5中可以看出，采用基于SVM的分类方法结果整体上要劣于深度学习的方法，其分类结果图像中椒盐噪声更加突出。这是由于图像整体空间分辨率较高、地物的光谱变化较大所造成的，同时还受到土壤、地膜等复杂背景的影响，采用逐像素分类的SVM类方法效果不太理想。1D-CNN模型尽管

采用了深度学习网络架构，但是由于其仅利用单个像素的光谱信息，没有融合邻域信息，所以其分类结果仍然存在较多的椒盐噪声。其他基于深度学习的模型由于能够更好地结合光谱与空间信息，分类效果能够得到显著提高，并极大程度地消除了椒盐噪声现象。另外，对于小块田间作物以及受地膜、大棚以及防鸟网覆盖影响的作物分类结果，由于其混合光谱现象严重，传统基于SVM的方法和1D-CNN方法非常容易产生错分现象。

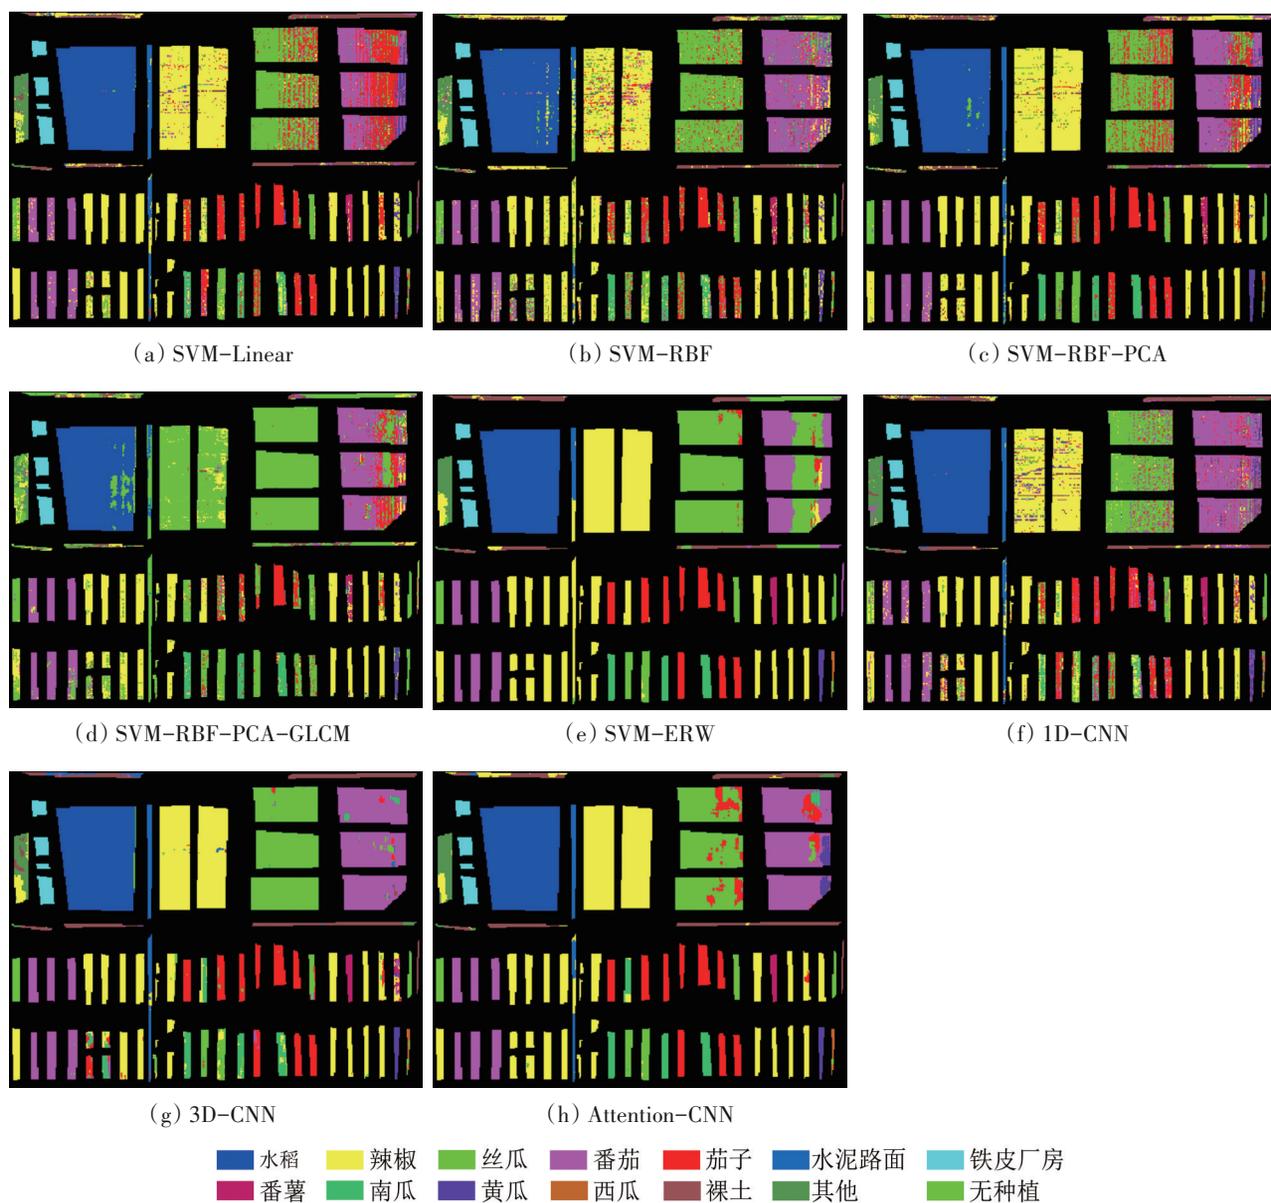


图5 基于不同方法的作物分类结果

Fig. 5 Classification results by different methods

表2 测试样本的分类精度
Table 2 Classification accuracies of test samples

序号	类别名称	SVM-Linear	SVM-RBF	SVM-RBF-PCA	SVM-RBF-PCA-GLCM	SVM-EWR	1D-CNN	3D-CNN	Attention-CNN
1	茄子	87.81	78.65	91.33	40.27	99.82	71.79	97.62	100.00
2	丝瓜	68.12	82.84	72.27	98.12	97.50	74.31	97.79	88.00
3	水稻	99.79	97.62	98.43	93.18	100.00	99.94	98.89	100.00
4	辣椒	92.49	82.48	94.20	47.84	99.98	88.09	91.24	97.66
5	番茄	57.03	79.35	69.39	68.36	68.04	83.64	96.08	87.76
6	铁皮厂房	100.00	99.87	100.00	99.34	100.00	100.00	100.00	100.00
7	西瓜	56.96	27.85	67.09	0.00	79.75	63.29	65.82	87.34
8	南瓜	69.82	78.55	94.79	91.03	100.00	48.00	84.24	100.00
9	黄瓜	86.36	63.13	98.48	80.81	100.00	72.22	100.00	100.00
10	番薯	87.22	82.82	87.67	55.51	100.00	95.15	100.00	100.00
11	无种植	89.79	81.70	86.81	6.81	100.00	80.00	81.70	100.00
12	水泥路面	82.63	30.14	83.91	18.26	37.29	86.97	95.40	85.19
13	裸土	74.09	44.43	43.16	22.33	55.34	79.00	85.92	81.65
14	其他	72.74	61.40	76.56	36.56	72.23	87.90	60.76	79.87
	OA	80.58	81.04	83.41	67.09	89.57	84.68	94.14	93.43
	AA	80.35	70.77	83.15	54.17	86.42	80.74	89.68	93.39
	Kappa	76.85	77.04	80.09	60.39	87.30	81.56	92.94	92.10

注：加粗数字表示同类最高精度。

从分类精度评价结果来看，基于SVM方法的总体分类精度、用户平均精度和Kappa系数均要低于深度学习方法得到的结果。而当训练样本数量较少时，基于SVM方法难以挖掘总体特征，分类模型的泛化能力不足，从而导致分类结果不稳定，在有些模型中分类精度偏低，比如西瓜、黄瓜、番薯、水泥路面等地物。然而，基于深度学习的分类方法能够容纳更多的特征信息，学习到更多抽象特征，对噪声及模型的容错能力也更强，所以在3D-CNN模型和Attention-CNN模型中，所有类别的分类精度均比较稳定且都较高。另外，受背景因素影响小且属于大面积密集分布的地物在所有分类方法中均能有效地区分开来，比如铁皮厂房、水稻，这从训练样本的平均光谱特征也能反映出来。而不同蔬菜种类的混合光谱较为严重，且种植面积小、植株间隔与生长发育阶段差异大，从而导致难以区分，这在不同的分类方法体现较为明显，比如番茄、番薯、黄瓜和辣椒等，在3D-CNN和Attention-CNN模型中得到了极好的区分，而其他分类方法的结果差异较大。

4.3 不同分类方法比较与分析

4.3.1 基于SVM方法的分类结果比较

在不同SVM分类方法中，由于其所采用的分类模型和输入特征差异影响，分类结果也存在较大差异。相较于SVM-Linear方法，SVM-RBF模型采用RBF核函数将原始特征光谱空间投影到更高维空间，以解决线性不可分问题，理论上应该可以得到更好的分类结果（CampsValls和Bruzzone, 2005）。然而在本实验中，SVM-RBF模型并没有体现出更加强大的优势，反而在西瓜、水泥路面、裸土这些地物分类中表现出更差的分类结果。这有可能与训练样本的数量和可分性密切相关，这些地物的样本数量偏少，样本空间即使投影到高维空间，也难以被区分开来。高光谱不同波段之间的强相关性以及信息冗余容易引发“Hughes现象”，主成分变换方法可以对原始光谱数据进行降维，通过提取部分主成分分量进行地物分类有可能在一定程度上提高分类模型的鲁棒性。提取前 k 个主分量输入到基于RBF核变换的SVM分类模型中，得到的分类结果精度与主成分分量个数之间

的关系如图5所示。可以发现,当主分量数量过少,会影响到分类精度,而随着主分量数量的增加,分类精度会有所提升直到稳定状态,此时如果再增加主分量数量,分类精度反而会下降。从图6可以看出,取前15个主成分分量能够达到较好的分类结果,此15个主成分占原图像信息含量为99.92%,所有地物的平均分类精度为83.15%,仅裸土的分类精度较低。如果在此基础上再加入灰度共生矩阵的纹理特征,即SVM-RBF-PCA-GLCM模型。一般来说,将高空间分辨率图像的空间纹理特征输入到分类器中有助于提高图像分类精度。但对于本研究而言,它并没有获得理想效果,这是因为本研究区地表覆盖类型十分复杂、作物的生长阶段也不一致,多数地物并没有体现出有规律的空间纹理特征所致。但是从表2也可以看出,对于大面积分布、有一定空间纹理规律的地物,SVM-RBF-PCA-GLCM模型能够得到较好的效果,如丝瓜、水稻、铁皮厂房、南瓜、黄瓜。相较于本文其他SVM方法,采用空间后处理技术的SVM-ERW方法考虑了相邻像素之间的空间相关性以及训练样本和测试样本之间的连通性,在消除“椒盐”噪声方面表现良好,同时在整体精度上展示出较好的性能,但是该方法容易将作物间的其他地物类型划分为相同作物,比如其中的水泥路面、裸土和其他,多被错误划分成邻近作物类型。

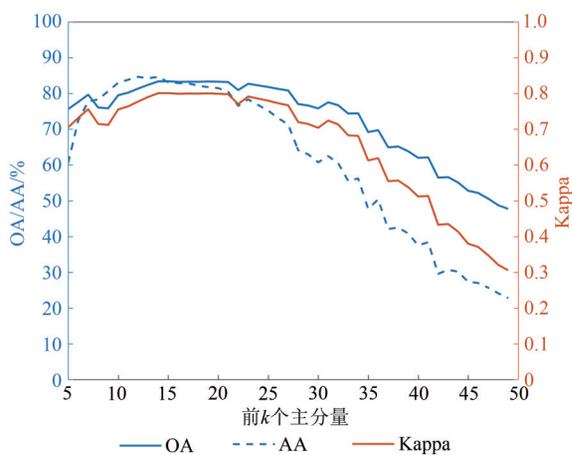


图6 不同数量的主成分分类精度变化

Fig. 6 Classification accuracy variations with different number of PCA components

4.3.2 基于深度学习方法的分类结果比较

针对高光谱遥感图像高维非线性问题,深度

学习方法具有较强的自主学习能力的优势,并且能够解决复杂的多维非线性问题,可以从原始图像中提取各层次特征,从而在高光谱图像分类中表现出更强的鲁棒性。从分类结果上看出,3D-CNN模型与Attention-CNN模型由于融合了图像光谱-空间信息,极大地提升了高光谱图像分类精度,同时分类结果也剔除了大部分椒盐噪声;基于深度学习方法的分类结果总体分类精度整体上比SVM方法提升了12.7%。3D-CNN模型基于整个高光谱立方体数据集,有效地提取了光谱-空间特征,并且不依赖于数据预处理方式或后期处理,能够取得较好的效果,所有地物类型的分类精度均有很大的提升。引入注意力机制的Attention-CNN模型,可以让模型忽略无关信息而更多地关注图像中的高阶光谱特征,从而提升图像分类效果。从分类结果上来看,Attention-CNN模型与3D-CNN模型在总体分类精度OA、Kappa系数上并没有体现出太多的差异,但是它的平均分类精度却提升了3.7%,对于西瓜这类小样本数量地物而言,其分类精度远超过其他方法。

4.4 不同尺度地块的分类结果

不同尺度地块上的蔬菜作物精细分类主要依赖于蔬菜作物本征光谱特征和空间纹理结构特征。大尺度地块上的蔬菜作物空间纹理结构更加显著,如辣椒、番茄和丝瓜,而小尺度地块上蔬菜作物因种植数量有限,无法形成大规模空间覆盖,空间纹理结构特征不能很好地体现作物空间分布特征。相较于SVM机器学习方法,深度学习方法在蔬菜作物精细分类结果上体现出更加优越的性能,但是对于不同地块尺度上的蔬菜作物精细分类,不同深度学习方法依存在一定的差异性。三维卷积网络3D-CNN深度学习方法可以深度融合图像中的光谱、空间纹理结构信息,能对大尺度地块的蔬菜作物进行更好的精细分类,比如对于大尺度地块的辣椒、丝瓜和番茄,其错误分类明显要少于Attention-CNN模型,但对小地块尺度上辣椒、南瓜和丝瓜而言,其分类结果要劣于Attention-CNN模型。引入注意力机制的卷积神经网络模型Attention-CNN对小地块有更好的分类结果,这是由于Attention-CNN模型能够较好地融入邻域范围内的光谱特征,从而能够更好地捕捉局部区域的光谱-空间信息,比如小地块尺度的茄子、

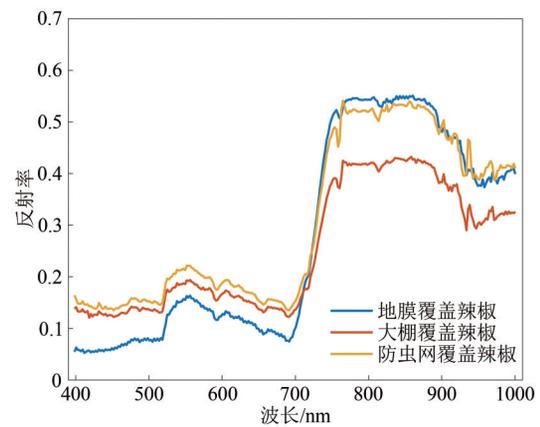
南瓜、黄瓜、丝瓜都能得到更佳分类效果。因此, 地块尺度大小及作物呈现的空间纹理结构特征对于蔬菜作物精细分类有较大影响, 在蔬菜作物精细分类中应予以考虑。

4.5 不同覆盖背景下蔬菜作物的分类结果

不同覆盖背景会与作物产生光谱混合现象, 特别是作物处于不同生长发育阶段、叶面积覆盖较小时, 作物混合光谱效应越明显, 混合光谱差异越大, 从而影响作物的精细分类结果。水稻作物由于没有覆盖背景影响且叶面积覆盖较大, 其光谱特征明显、作物内部同质性高, 因此在所有分类方法中水稻作物能够很好地与蔬菜其他作物区分开来。辣椒包含地膜、大棚和防虫网3种覆盖背景, 尽管总体上深度学习获得了较好的分类结果, 但是在不同覆盖背景上的分类效果还是存在一定的差异。在3D-CNN模型的分类结果中, 均会出现部分区域由于混合光谱影响而错分为其他类型的现象, 特别是在小尺度地块分类结果中, 3种覆盖类型的部分地块均出现了极端错误分类情形。例如第二排小尺度地块中的左起第12块大棚覆盖辣椒、第23块防虫网覆盖辣椒以及第三排第5、6块地膜覆盖辣椒均出现了极端错误分类情况; 而在Attention-CNN模型辣椒分类结果中, 仅第二排第12块大棚覆盖辣椒出现了极端错误现象, 其他覆盖背景的辣椒作物得到了较好的分类效果, 但是大尺度地块上地膜覆盖辣椒除外。地膜覆盖的丝瓜在3D-CNN模型中分类效果较好, 但防虫网覆盖的丝瓜欠佳; Attention-CNN模型的分类效果与之相反。在小尺度地块上, 地膜和大棚覆盖的茄子在Attention-CNN模型中均得到了较好的分类效果。

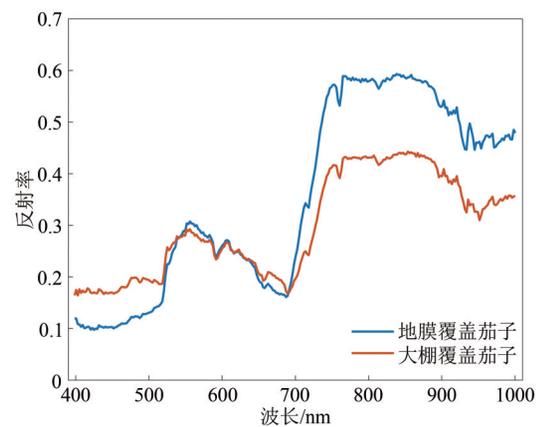
产生上述现象的原因在于不同覆盖背景对训练集混合光谱的影响。在实验区中, 辣椒、茄子和丝瓜3种作物最为典型, 均受了地膜、大棚及防虫网覆盖背景的影响。它们处在不同生长发育阶段, 其中辣椒处于初花期生长阶段, 叶片较为茂盛, 植株长势较好; 茄子处于移栽期, 叶片较小, 植株整体偏小; 丝瓜处于盛果期, 叶片茂密, 整体植株覆盖面积大。这3种作物在不同覆盖背景下的作物光谱如图7所示。从图7中可以看出, 不同覆盖背景下的作物光谱有显著差异, 这也给同种作物精细分类带来较大挑战。不同蔬菜作物受覆盖物材质、颜色以及作物生长物候等因素影响,

其光谱曲线的变化会存在一定的不确定性。在未来的研究中, 我们将围绕不同地区常用地膜、大棚材质、颜色开展更进一步的高光谱成像实验, 深入分析其光谱、空间特征变化机理, 阐明蔬菜作物设施覆盖对其光谱的影响性。



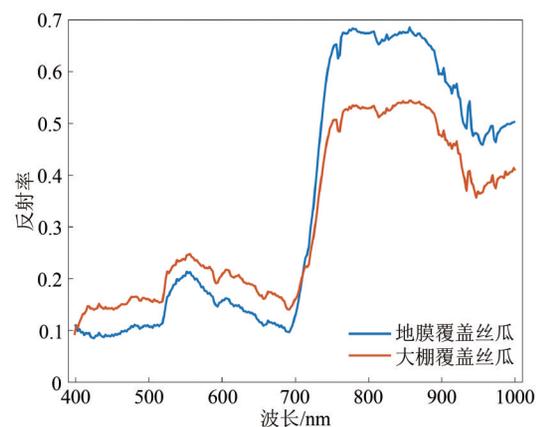
(a) 辣椒

(a) Pepper



(b) 茄子

(b) Aubergine



(c) 丝瓜

(c) Luffa

图7 不同覆盖背景下蔬菜作物光谱

Fig.7 Spectra of vegetable crops under different background covers

5 结 论

本研究以湖南省农业科学研究院高桥科研基地为研究区, 通过利用无人搭载高光谱传感器获取研究区的高光谱数据, 采用当前流行SVM机器学习方法和深度学习方法对研究区的蔬菜作物进行了精细分类, 经过对分类结果比较和精度评价分析, 不同的方法均能得到较好的效果, 可为复杂背景下田间蔬菜作物无人机高光谱精细分类提供一定的技术支持。通过本次研究, 可以得到以下结论:

(1) 无人机高光谱遥感数据兼具高空间分辨率和高光谱分辨率的特点, 在受到地膜、防鸟网、大棚覆盖等复杂背景影响情况下, 仍可有效地实现蔬菜作物高精度精细分类, 可对区域蔬菜作物管理现代化、自动化和精细化提供有力支撑。

(2) 基于SVM的不同分类方法可以得到较好的分类效果, 但难以克服分类中的椒盐噪声影响; 由于高光谱数据的高维度、信息冗余、非线性等特点, 直接将原始高光谱特征输入SVM分类器以及核变换分类器, 效果不甚理想, 但是通过选择主成分降维后可以有效地提升分类效果, 但是效果有限; 鉴于本研究不同蔬菜作物的种植背景较为复杂、作物生长阶段差异较大, 空间纹理结构特征的输入并没有取得理想的分类精度提升效果。

(3) 基于深度学习的方法(1D-CNN除外)可以有效实现对复杂背景下的蔬菜作物分类; 三维卷积神经网络(3D-CNN)能够有效地提取高光谱图像中的光谱-空间特征, 并从中挖掘深层次的高级语义信息, 分类结果中能有效地消除椒盐噪声, 在蔬菜作物精细分类中表现出强大的优势; 基于注意力机制的卷积神经网络(Attention-CNN)通过关注图像中的光谱-空间特征信息, 在分类精度上表现得更加平衡, 对于西瓜这类小样本数量地物而言, 其分类精度远超过其他方法。

(4) 蔬菜作物在大尺度地块上空间纹理特征明显, 而在小地块尺度上差异较大, 宜采用不同深度学习方法对其进行精细分类。基于3D-CNN模型有效地融合了光谱-空间结构特征, 更加适合提取大地块尺度上的蔬菜作物; Attention-CNN模型引入注意力机制, 聚焦高阶光谱特征和局部邻域信息, 更加适合小尺度地块作物的精细分类。

由于蔬菜作物种植的特殊性和实验基地的局

限性, 本研究获取的数据较为有限, 后续将通过深入研究不同覆盖背景对蔬菜作物光谱信号的透过规律和影响机制, 收集多个区域的高光谱航飞数据, 进一步分析研究蔬菜复杂覆盖背景下的蔬菜作物种植结构信息高光谱遥感探测能力及精度。

志 谢 此次野外实验得到了湖南省农业科学研究院蔬菜研究所番茄课题组张战泓、白占兵、欧阳娴的大力支持, 在此表示衷心的感谢!

参考文献(References)

- Aguilar M A, Vallario A, Aguilar F J, Lorca A G and Parente C. 2015. Object-based greenhouse horticultural crop identification from multi-temporal satellite imagery: a case study in Almeria, Spain. *Remote Sensing*, 7(6): 7378-7401 [DOI: 10.3390/rs70607378]
- Asgarian A, Soffianian A and Pourmanafi S. 2016. Crop type mapping in a highly fragmented and heterogeneous agricultural landscape: a case of central Iran using multi-temporal landsat 8 imagery. *Computers and Electronics in Agriculture*, 127: 531-540 [DOI: 10.1016/j.compag.2016.07.019]
- Camps-Valls G and Bruzzone L. 2005. Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(6): 1351-1362 [DOI: 10.1109/TGRS.2005.846154]
- Chen Z X, Ren J Q, Tang H J, Shi Y, Leng P, Liu J, Wang L M, Wu W B, Yao Y M and Hasiyuya. 2016. Progress and perspectives on agricultural remote sensing research and applications in China. *Journal of Remote Sensing*, 20(5): 748-767 (陈仲新, 任建强, 唐华俊, 史云, 冷佩, 刘佳, 王利民, 吴文斌, 姚艳敏, 哈斯图亚. 2016. 农业遥感研究应用进展与展望. *遥感学报*, 20(5): 748-767) [DOI: 10.11834/jrs.20166214]
- Congalton R G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1): 35-46 [DOI: 10.1016/0034-4257(91)90048-B]
- Du P J, Xia J S, Xue Z H, Tan K, Su H J and Bao R. 2016. Review of hyperspectral remote sensing image classification. *Journal of Remote Sensing*, 20(2): 236-256 (杜培军, 夏俊士, 薛朝辉, 谭琨, 苏红军, 鲍蕊. 2016. 高光谱遥感影像分类研究进展. *遥感学报*, 20(2): 236-256) [DOI: 10.11834/jrs.20165022]
- Feng Q L, Yang J Y, Liu Y M, Ou C, Zhu D H, Niu B W, Liu J T and Li B G. 2020. Multi-temporal unmanned aerial vehicle remote sensing for vegetable mapping using an attention-based recurrent convolutional neural network. *Remote Sensing*, 12(10): 1668 [DOI: 10.3390/rs12101668]
- Han W T, Li G, Yuan M C, Zhang L Y and Shi Z Q. 2017. Extraction method of maize planting information based on UAV remote sensing technology. *Transactions of the Chinese Society for Agricultural Machinery*, 48(1): 139-147 (韩文霆, 李广, 苑梦婵, 张立元, 师志强. 2017. 基于无人机遥感技术的玉米种植信息提取方法研究. *农业机械学报*, 48(1): 139-147) [DOI: 10.6041/j.issn.1000-1298.2017.01.018]
- Hasiyuya and Chen Z X. 2017. Mapping plastic-mulched farmland

- with multi-temporal landsat-8 data. *Remote Sensing*, 9(6): 557 [DOI: 10.3390/rs9060557]
- Ji S W, Xu W, Yang M and Yu K. 2013. 3D convolutional neural networks for human action recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(1): 221-231 [DOI: 10.1109/TPAMI.2012.59]
- Jiménez-Lao R, Aguilar F J, Nemmaoui A and Aguilar M A. 2020. Remote sensing of agricultural greenhouses and plastic-mulched farmland: an analysis of worldwide research. *Remote Sensing*, 12(16): 2649 [DOI: 10.3390/rs12162649]
- Jolliffe I T and Cadima J. 2016. Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065): 20150202 [DOI: 10.1098/rsta.2015.0202]
- Kang X D, Li S T, Fang L Y, Li M X and Benediktsson J A. 2015. Extended random walker-based classification of hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 53(1): 144-153 [DOI: 10.1109/TGRS.2014.2319373]
- Li D R and Li M. 2014. Research advance and application prospect of unmanned aerial vehicle remote sensing system. *Geomatics and Information Science of Wuhan University*, 39(5): 505-513, 540 (李德仁, 李明. 2014. 无人机遥感系统的研究进展与应用前景. 武汉大学学报(信息科学版), 39(5): 505-513, 540) [DOI: 10.13203/j.whugis20140045]
- Li M, Huang Y Q, Li X M, Peng D X and Xie J X. 2018. Extraction of rice planting information based on remote sensing image from UAV. *Transactions of the Chinese Society of Agricultural Engineering*, 34(4): 108-114 (李明, 黄榆淇, 李绪孟, 彭冬星, 谢景鑫. 2018. 基于无人机遥感影像的水稻种植信息提取. 农业工程学报, 34(4): 108-114) [DOI: 10.11975/j.issn.1002-6819.2018.04.013]
- Li S G and Wang J J. 2018. Current situation and countermeasures of vegetable industry development in China. *China Vegetables*, (6): 1-4 (李斯更, 王娟娟. 2018. 中国蔬菜产业发展现状及对策措施. 中国蔬菜, (6): 1-4)
- Li Y, Zhang H K and Shen Q. 2017. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network. *Remote Sensing*, 9(1): 67 [DOI: 10.3390/rs9010067]
- Li Z M, Ren Y F and Zhang X Y. 2018. Development and trend of vegetable industry in China since reform and opening-up. *Chinese Journal of Agricultural Resources and Regional Planning*, 39(12): 13-20 (李哲敏, 任育锋, 张小允. 2018. 改革开放以来中国蔬菜产业发展及趋势. 中国农业资源与区划, 39(12): 13-20) [DOI: 10.7621/cjarrp.1005-9121.20181203]
- Liao X H, Xiao Q and Zhang H. 2019. UAV remote sensing: popularization and expand application development trend. *National Remote Sensing Bulletin*, 23(6): 1046-1052 (廖小罕, 肖青, 张颢. 2019. 无人机遥感: 大众化与拓展应用发展趋势. 遥感学报, 23(6): 1046-1052) [DOI: 10.11834/jrs.20199422]
- Lu B, Dao P D, Liu J G, He Y H and Shang J L. 2020. Recent advances of hyperspectral imaging technology and applications in agriculture. *Remote Sensing*, 12(16): 2659 [DOI: 10.3390/rs12162659]
- Lu X, Huang X J, Zhong T Y, Zhao Y T and Li Y. 2013. A review of farmland fragmentation in China. *Journal of Resources and Ecology*, 4(4): 344-352 [DOI: 10.5814/j.issn.1674-764x.2013.04.007]
- Mdrafi R, Du Q, Gurbuz A C, Tang B, Ma L and Younan N H. 2020. Attention-based domain adaptation using residual network for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 6424-6433 [DOI: 10.1109/JSTARS.2020.3035382]
- Moola W S, Bijker W, Belgiu M and Li M M. 2021. Vegetable mapping using fuzzy classification of dynamic time warping distances from time series of sentinel-1A images. *International Journal of Applied Earth Observation and Geoinformation*, 102: 102405 [DOI: 10.1016/j.jag.2021.102405]
- Nemmaoui A, Aguilar M A, Aguilar F J, Novelli A and García Lorca A. 2018. Greenhouse crop identification from multi-temporal multi-sensor satellite imagery using object-based approach: a case study from Almería (Spain). *Remote Sensing*, 10(11): 1751
- Tong Q X, Zhang B and Zheng L F. 2006. *Hyperspectral Remote Sensing—Principle, Technology and Application*. Beijing: Higher Education Press: 83-86 (童庆禧, 张兵, 郑兰芬. 2006. 高光谱遥感——原理、技术与应用. 北京: 高等教育出版社: 83-86)
- Tong Q X, Zhang B and Zhang L F. 2016. Current progress of hyperspectral remote sensing in China. *Journal of Remote Sensing*, 20(5): 689-707 (童庆禧, 张兵, 张立福. 2016. 中国高光谱遥感的前沿进展. 遥感学报, 20(5): 689-707) [DOI: 10.11834/jrs.20166264]
- Torres-Sánchez J, Peña J M, De Castro A I and López-Granados F. 2014. Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103: 104-113 [DOI: 10.1016/j.compag.2014.02.009]
- Wei L F, Yu M, Zhong Y F, Zhao J, Liang Y J and Hu X. 2019. Spatial-spectral fusion based on conditional random fields for the fine classification of crops in UAV-borne hyperspectral remote sensing imagery. *Remote Sensing*, 11(7): 780 [DOI: 10.3390/rs11070780]
- Weiss M, Jacob F and Duveiller G. 2020. Remote sensing for agricultural applications: a meta-review. *Remote Sensing of Environment*, 236: 111402 [DOI: 10.1016/j.rse.2019.111402]
- Wu J Y, Liu X L, Bo Y C, Shi Z T and Fu Z. 2019. Plastic greenhouse recognition based on GF-2 data and multi-texture features. *Transactions of the Chinese Society of Agricultural Engineering*, 35(12): 173-183 (吴锦玉, 刘晓龙, 柏廷臣, 史正涛, 付卓. 2019. 基于GF-2数据结合多纹理特征的塑料大棚识别. 农业工程学报, 35(12): 173-183) [DOI: 10.11975/j.issn.1002-6819.2019.12.021]
- Xue Z H, Du P J, Li J and Su H J. 2017. Sparse graph regularization for robust crop mapping using hyperspectral remotely sensed imagery with very few *in situ* data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 124: 1-15 [DOI: 10.1016/j.isprsjprs.2016.12.003]
- Ye Z, Bai L and He M Y. 2021. Review of spatial-spectral feature extraction for hyperspectral image. *Journal of Image and Graphics*, 26(8): 1737-1763 (叶珍, 白璘, 何明一. 2021. 高光谱图像空谱特征提取综述. 中国图象图形学报, 26(8): 1737-1763) [DOI: 10.11834/jig.210198]
- Zhang Z H. 2017a. Countermeasures for transformation and upgrading of vegetable industry in China (I). *Journal of Chinese Agricultural Mechanization*, 38(8): 96-106 (张真和. 2017a. 中国蔬菜产业转型升级对策探讨(上). 中国农机化学报, 38(8): 96-106) [DOI: 10.13733/j.jcam.issn.2095-5553.2017.08.019]
- Zhang Z H. 2017b. Countermeasures for transformation and upgrading of vegetable industry in China (II). *Journal of Chinese Agricultural Mechanization*, 38(9): 88-94 (张真和. 2017b. 中国蔬菜产业转型升级对策探讨(下). 中国农机化学报, 38(9): 88-94) [DOI: 10.

13733/j.jcam.issn.2095-5553.2017.09.018]

Zhao C J. 2014. Advances of research and application in remote sensing for agriculture. Transactions of the Chinese Society for Agricultural Machinery, 45(12): 277-293 (赵春江. 2014. 农业遥感研究与应用进展. 农业机械学报, 45(12): 277-293) [DOI: 10.6041/j.issn.1000-1298.2014.12.041]

Zhong Y F, Hu X, Luo C, Wang X Y, Zhao J and Zhang L P. 2020. WHU-Hi: UAV-borne hyperspectral with high spatial resolution (H^2) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF. Remote Sensing of Environment, 250: 112012 [DOI: 10.1016/j.rse.2020.112012]

Zhong Z L, Li J, Luo Z M and Chapman M. 2018. Spectral - spatial residual network for hyperspectral image classification: a 3-D deep learning framework. IEEE Transactions on Geoscience and Remote Sensing, 56(2): 847-858 [DOI: 10.1109/TGRS.2017.2755542]

Zhu D H, Liu Y M, Feng Q L, Ou C, Guo H and Liu J T. 2020. Spatial-temporal dynamic changes of agricultural greenhouses in shandong province in recent 30 years based on google earth engine. Transactions of the Chinese Society for Agricultural Machinery, 51(1): 168-175 (朱德海, 刘逸铭, 冯权泷, 欧聪, 郭浩, 刘建涛. 2020. 基于GEE的山东省近30年农业大棚时空动态变化研究. 农业机械学报, 51(1): 168-175) [DOI: 10.6041/j.issn.1000-1298.2020.01.018]

Fine classification of vegetable crops covered with different planting facilities using UAV hyperspectral image

HU Shunshi^{1,2}, YANG Bin^{1,2}, HUANG Ying¹, CEN Yi³, QI Wenchao³

1.School of Geographic Sciences, Hunan Normal University, Changsha 410081, China;

2.Key Laboratory of Geospatial Big Data Mining and Application, Hunan Province, Changsha 410081, China;

3.Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100101, China

Abstract: With large-scale and high-output values, the vegetable industry of China is a pillar industry to promote the income increase of farmers and the development of rural agricultural economy. Rapidly and accurately obtaining the structural information of vegetable crop planting is of considerable importance for agricultural modernization, automation, and precision. With the advantages of fast mobility, flexibility, and image-spectrum merging, Unarmed Aerial Vehicle (UAV) hyperspectral remote sensing has wide prospects in fine classification of crops. However, vegetable crop planting scales and modes have considerable variations, and the fragmentation of agricultural landscape is high in China. The vegetable crops are also affected by the coverage of plastic film, greenhouse, and bird proof net, which easily produced the mixed spectral effect in UAV hyperspectral images and also introduced considerable challenges to the fine classification of vegetable crops.

Hyperspectral images of Gaoqiao scientific research base of Hunan Academy of Agricultural Sciences were obtained by UAV. The field survey revealed that the area contains 14 ground feature categories, including eggplant, towel gourd, rice, pepper, and tomato. Support Vector Machine (SVM) is widely used in crop classification due to low requirements for data and excellent generalization capability. Meanwhile, deep convolution neural network structures can automatically learn the abstract features of images and obtain high-level and rich semantic information of samples to successfully complete the classification task. Therefore, SVM and Deep Learning (DL) methods were applied to the classification of vegetable crops in this study. Unlike other hyperspectral classification verification experiments that randomly select training sets, training and test samples were manually selected in this study to reduce the spatial correlation between training and test sets, and the performance of different classification methods was evaluated using confusion matrix.

The results showed that based on hyperspectral images obtained by UAVs, the average overall accuracy of vegetable crop classification using SVM and DL methods is 78.03% and 90.75%, respectively, and the average Kappa coefficients are 0.7359 and 0.8887, respectively. Compared with the SVM methods, the fine classification effects obtained by the DL methods are more ideal. This finding is attributed to the effective extraction of spectral and spatial feature information from the image using the three-dimensional convolutional neural network and the convolutional neural network with attention mechanism, thus demonstrating a superior performance in the classification of vegetable crops. The spatial texture characteristics of vegetable crops are observed on large-scale plots, while they are various on small-scale plots. Thus, using different DL methods for the classification of vegetable crops on different scale plots is appropriate.

Vegetable crops under different planting facilities were classified in this study using UAV hyperspectral images. Under the influence of complex backgrounds such as plastic films, bird nets, and greenhouses, satisfactory performance was still achieved using SVM and DL methods, which can provide technological support for the modernization, automation, and refinement of regional vegetable crop management.

Key words: fine classification, vegetable crops, Unmanned Aerial Vehicle (UAV), hyperspectral, greenhouses, mulch film

Supported by National Key Research and Development Program of China (No. 2017YFE0194900); Open Fund of State Key Laboratory of Remote Sensing Science (No. OFSLRSS202221); Scientific Research Project Supported by Hunan Provincial Department of Education (No. 21B0046); 2019 Hunan Postgraduate High Quality Course Project "Microwave and Hyperspectral Remote Sensing" (No. 130)