

杨珍,郭艳光,鲁晓波. 基于改进 AlexNet 网络的无人机遥感图像分类方法[J].湖南科技大学学报(自然科学版),2023, 38(3):59-69. doi:10.13582/j.cnki.1672-9102.2023.03.008

YANG Z, GUO Y G, LU X B. Classification Method of UAV Remote Sensing Image Based on Improved AlexNet Network [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2023, 38(3):59-69. doi:10.13582/j.cnki.1672-9102.2023.03.008

基于改进 AlexNet 网络的 无人机遥感图像分类方法

杨珍,郭艳光*,鲁晓波

(内蒙古农业大学 计算机技术与信息管理系,内蒙古 包头 014109)

摘要:针对传统卫星遥感难以获取相应的高空间分辨率数据,影响农作物的分类准确度的问题,提出一种基于改进 AlexNet 网络的无人机遥感图像分类方法.首先,为降低方法的复杂度,加快收敛效果,优化改善 AlexNet 网络模型,仅保留 AlexNet 网络模型的前 5 个图像处理卷积层;其次,对试验农作物无人机遥感图像进行光谱特性分析,提取各类作物自身的光谱曲线.在此基础上,考虑到农作物在可见光波段的反射率相近,很难依据反射率曲线进行区分,基于改进 AlexNet 网络的深层卷积结构,依据不同波段内的像素亮度对农作物进行准确分类.最后,利用湖南省长沙市农业科学研究所试验基地实测数据进行算例试验.结果表明:在相同的试验条件下,与 SVM-RFE 和 SVM-SS 相比,所提方法对于农作物的总体分类精度均值提升了 3.91% 以上,Kappa 系数均值至少提升了 2.20%,可适用于实际场景.

关键词:无人机遥感;改进 AlexNet 网络;深度学习;光谱特征;农作物;图像分类

中图分类号:TP391 **文献标志码:**A **文章编号:**1672-9102(2023)03-0059-11

Classification Method of UAV Remote Sensing Image Based on Improved AlexNet Network

YANG Zhen, GUO Yanguang, LU Xiaobo

(Department of Computer Technology and Information Management, Inner Mongolia Agricultural University, Baotou 014109, China)

Abstract: As traditional satellite remote sensing is difficult to obtain the corresponding high spatial resolution data, which affects the accuracy of crop classification, this paper proposes a UAV remote sensing image classification method based on improved AlexNet network. Firstly, in order to reduce the complexity of the algorithm and speed up the convergence effect, the original AlexNet model is improved, that is, the first five convolution layers are retained and all fully connected layers are removed. Secondly, the spectral characteristics of UAV remote sensing images of experimental crops are analyzed, and the spectral curves of various crops are extracted. On this basis, considering that the reflectance of crops in the visible band is similar, it is difficult to distinguish crops according to the reflectance curve. Based on the deep convolution structure of the improved AlexNet network, crops are accurately classified according to the pixel brightness in different bands. Finally, a

收稿日期:2021-04-25

基金项目:内蒙古自治区自然科学基金资助项目(2014MS0616);内蒙古自治区高等学校科学研究项目资助(NJZY20055);内蒙古科技厅科技攻关计划项目资助(2020GG0033);内蒙古哲学社会科学规划项目资助(2020NDC067)

*通信作者,E-mail: 244246020@qq.com

case study is carried out using the experimental data of Changsha Institute of Agricultural Sciences in Hunan Province. Results show that, compared with SVM-RFE method and SVM-SS method, the average classification accuracy of the proposed method is improved by more than 3.91%, and the average kappa coefficient is improved by at least 2.20%, which is suitable for the actual scene.

Keywords: UAV remote sensing; improved AlexNet network; deep learning; spectral features; crops; image classification

精准农业是基于现代科学技术发展起来的新农业生产形式^[1].精准农业可为农作物普查工作提供一定的技术支持,为农业产量预测提供合理依据,为农业生产灾害评估工作提供有力的技术保障,政府相关部门还可根据精准农业制定适合于当前农业快速发展的政策.在精准农业过程中,无人机(Unmanned Aerial Vehicle, UAV)遥感技术具有信息获取精准、多平台便捷控制、提取信息高效、信息覆盖面广等众多优势,得到了广泛使用^[2-3].由于农作物种植范围广、种类繁多,对作物类别的准确辨识造成很大困难.因此,在复杂环境下研究无人机遥感农作物图像的精准识别具有重要意义和实际价值^[4].

传统遥感图像分类技术在面临某些特殊的农业研究区域时,通常不能高效地获取该研究区域内的高空分辨率卫星遥感影像数据信息^[5],导致农业检测受到一定限制.目前,遥感图像分类技术正在迅猛地发展,获取的影像数据信息的空间分辨率不断提升,影像数据中所涵盖的农业信息也增多^[6].传统遥感技术根据成像的像素特征有马氏距离分类法和最近邻传统分类法,在实际使用过程中,这些传统方法提取的特征并不显著,容易产生错分类现象^[7-8].为改善这一现象,出现了基于浅层学习特征提取法,例如,支持向量机^[9](Support Vector Machine, SVM)浅层学习法、反向传播(Back Propagation, BP)浅层学习法等,虽然在一定程度上改善了错分和校验现场,但浅层学习法难以全面描述物体特征,而且,遥感影像的数据量越来越多,利用浅层学习法对特征进行提取也越来越满足不了工程需求^[10-11].由此,深度学习法应运而生,解决了浅层学习法不能解决的一系列问题,深度学习法具有多个隐含层感知器,这些感知器能快速将样本进行特征变换,将原空间影像特征信息变换至新的特征空间中,并通过深度学习的自主学习实现对这些影像信息的多层次化特征表示,由此提升影像信息的准确分类^[12-14].

UAV在实际使用过程中,通常具有使用便捷、维护高效、设备体积精巧、使用成本低廉、使用损耗低、操作风险低、影像数据信息获取效率高、影像信息分辨率高等多种优势,使其广泛应用于某一区域内的遥感监测任务^[15-16].随着高分辨率UAV遥感技术的不断成熟,在进行农作物精细分类时,人们还希望对农作物的观测周期进行缩短,充分使用农作物的纹理形状信息实施监测和分类,因此,高分辨率UAV遥感技术也为实现这些功能打下一定的基础,受到众多农业作物种植领域的研究学者们的青睐^[17-19].

相关研究者对UAV平台进行了深入研究,从信息提取角度看,研究方法可分为以可见光图像像元为基础的物种信息提取方法和以面向农作物对象为基础的信息提取方法^[20].文献[21]以无人机遥感技术为基础,结合液晶可调谐滤波器提取目标农业区域内的高光谱图像,再综合光照光谱反射率和阴影光谱反射率,对目标农业区域内的植被作物、中值土壤、多余杂草作物等进行对比分类;文献[22]从增加图像空间域的角度出发,对所获取的遥感图像进行二次低通滤波处理,从而得出图像中的地物散点图,以散点存在明显分界线为判定标准,实现小麦倒伏信息的有效分类,然而,传统的机器学习法在进行农业影像信息提取时,虽然能有效对农作物的形状特征进行提取,也能高效分辨出农作物的颜色特征,但当这些特征均不明显时,传统方法所提取出来的信息就没有准确率可言;文献[23]采用无人机遥感可见光影像,利用HSV色彩空间转换和纹理滤波,获取不同地物的24项纹理特征与3项色彩特征,提出融合支持向量机的递归特征消除算法(Support Vector Machine-Recursive Feature Elimination, SVM-RFE),建立6种监督分类模型,有效提升农作物分类效果.

深度学习网络模型进行影像数据信息的提取时,能直接提取图像的高层特征,人工干预程度较低.如文献[24]将卷积神经网络与超像素分割方法相结合,对目标图像的高斯金字塔进行多尺度分层特征的精

准提取,实现图像的多层感知相连接的效果,提升识别的准确度与稳定性.

上述方法虽能够对无人机遥感图像进行精准辨识,但对硬件设备的要求很高,在运算过程中需要很大的运行内存,不适用于小型 UAV 设备,并且上述模型的结构制作相对复杂,在处理某些小数据信息或者简单的数据信息时甚至出现过拟合的现象^[25-26].

传统遥感图像分类方法在进行农作物精细分类时,暴露出影像提取周期长、提取的图像分辨率不高等问题,因此,提出改进 AlexNet 网络的无人机遥感图像分类方法.选取湖南省长沙市农业科学研究所试验基地为试验区,以 UAV 遥感技术为基础,利用改进后的 AlexNet 网络模型对提取的农作物数据进行分类,对数据信息的网格参数进行分析调整、对信息的光谱特征进行组合分析,探讨提出的 AlexNet 网络在农作物精细分类中的适用性,为农作物精细分类提供新的思路.论文主要创新点如下:

1) 采用改进的 AlexNet-2 网络,通过保留卷积层和预训练的权重,加速模型的收敛速度,减少网络的训练时间,使得模型更易并行化.

2) 现有大多数方法直接对遥感获得的图像进行分类,忽略了农作物的固有特性,率先对无人机遥感图像的光谱特性进行提取并分析,依据农作物在不同波段的差异关系,利用卷积神经网络(Convolutional Neural Networks, CNN)提取影像中不同农作物包含的复杂特征,有效提升农作物遥感图像的辨识精度.

1 改进的 AlexNet 网络模型搭建

AlexNet 网络模型是由著名学者 KRIZHEVSKY 在该领域内不断研究后首次于 2012 年正式公开提出的,该网络模型是一种经典的 CNN 网络模型,经过众多学者的不断研究与优化,又提出了其升级版本 AlexNet-2 网络模型^[27].在当前社会形势下, AlexNet-2 网络模型已应用在众多领域,尤其在图像识别领域最为突出.

1.1 AlexNet-2 模型结构

AlexNet-2 网络模型的结构原理如图 1 所示.图 1 中,每一层的名称用 Name 表示,模型卷积核的大小用 Size 表示,图像处理的步长用 Stride 表示,某卷积层输出的特征图数量用 Output 表示,处理的图片类型数量用 class 表示.图 1 所示的模型有 8 个图像处理层,前 5 层均为图像处理的卷积层,后 3 层则为图像处理的全连接层,此模型所使用的激活函数为 ReLU 激活函数.图 1 所示的 AlexNet-2 网络模型的标准输入分辨率为 224×224 ,其输出结果为以图片类型数量 class 作为维度的列向量.

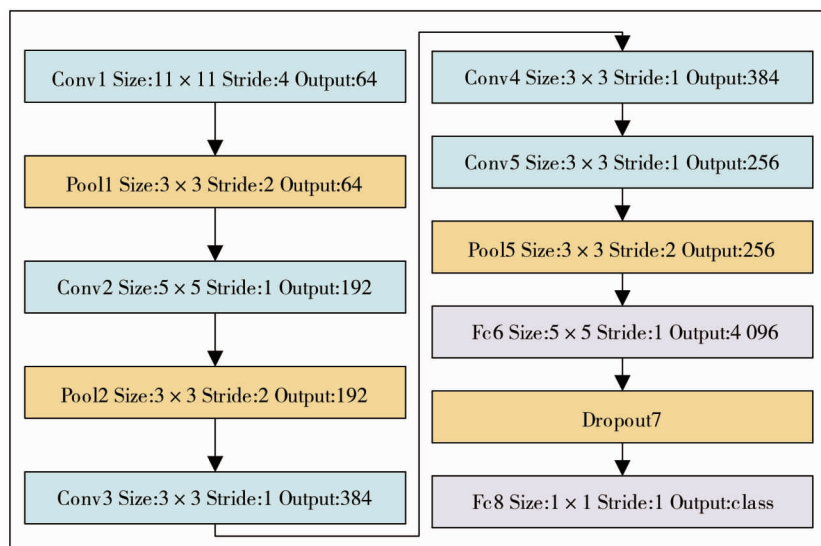


图 1 Alexnet-2 体系结构

AlexNet-2 网络模型的结构可细化为前 5 层为模型卷积层,第一层、第二层、第五层图像处理卷积层后都分别接入图像处理池化层,图像处理池化层的池化规则为最大池化,第三层、第四层均只有图像处理卷

积层,之后没有接入池化层;后3层为模型全连接层,这3层的目的是将图像处理后的二维特征转化成一维列向量进行输出,在第六层和第七层中分别加入 Dropout 层,以防止过拟合现象.在激活函数方面,第六层和第七层卷积层仍采用 ReLU 函数,第八层的神经元与上一层的数据进行全连接,经过训练后输出 float 型的值,即预测结果.

AlexNet-2 模型保留了原 AlexNet 模型的 Dropout 层和 ReLU 激活函数,Dropout 层能够有效降低过拟合现象;ReLU 函数是非饱和非线性函数,相较于传统的双曲正切函数和 Sigmoid 函数等饱和非线性函数而言,ReLU 函数能够加速模型收敛,减少网络训练时间.AlexNet-2 模型在原 AlexNet 模型全连接层的位置使用卷积层替代,相比于全连接层,卷积层参数较少,有利于减少模型的收敛时间;去除 LRN 层,使得模型更易并行化.但 AlexNet-2 的训练时间依然不适合 UAV 遥感图像自动分类的要求.

1.2 改进的 AlexNet-2 模型

AlexNet-2 网络模型中的卷积核尺寸大小、卷积核的数量以及图像处理的步长对模型识别精度有很大影响,为了减少过拟合现象的发生,对 AlexNet-2 网络模型进一步优化:保留前 5 个图像处理卷积层,模型中卷积层的功能是对图像进行特征的提取,其中,浅层卷积层的功能是对图像的边缘以及图像的颜色等底层图像特征进行提取,深层卷积层的功能是对图像的高级特征进行提取,在对图像提取完后保留各卷积层,保留模型预训练的权重,以及保留各卷积层的原始参数,加速网络收敛同时易于提取目标特征.其中,第一层卷积层的卷积核尺寸为 $11 \times 11 \times 3$;第二层卷积层的卷积核尺寸为 $5 \times 5 \times 48$,2 层卷积层的参数与原网络的参数相同^[27-28].

由于无人机遥感图像辨识属于二分类问题,将最后的全连接层参数设置为 2,从而提出了用于无人机遥感图像分类的改进 AlexNet-2 模型,具体的网络参数配置如表 1 所示.网络结构一共包括了 5 个卷积层、2 个全连接层和 1 个输出层.

表 1 Im-AlexNet-2 网络结构的参数设置

网络层	卷积核	步长	卷积核数量
Conv1	$11 \times 11 \times 3$	4	96
Pool1	$1 \times 3 \times 3 \times 1$	2	/
Conv2	$5 \times 5 \times 48$	1	256
Pool2	$1 \times 3 \times 3 \times 1$	2	/
Conv3	$3 \times 3 \times 384$	1	256
Conv4	$3 \times 3 \times 384$	1	384
Conv5	$3 \times 3 \times 256$	1	384
Pool5	$1 \times 3 \times 3 \times 1$	2	/
Fc6	32×256	/	256
ReLU6	/	/	384
Dropout	/	/	/
Fc7	32×256	/	256
ReLU7	/	/	256
Dropout	/	/	/
Fc8	256×2	/	2
Prob	Softmax	/	/
Output	/	/	/

2 无人机遥感农作物的识别

2.1 无人机遥感农作物光谱特性分析

试验数据采集时间为 5 月下旬,目标区域内所种植的 3 种农作物的叶片生长均已完成,其叶片所呈现出的绿色光谱特征较为明显,由此利用相关技术手段得出 3 种农作物的光谱反射曲线图,如图 2 所示.




图 2 典型农作物光谱曲线

综合分析 3 种农作物的光谱反射曲线图,3 种目标检测农作物的曲线在可见光波段都统一呈现出从低到高再到低的变化趋势,出现这种现象的原因是因为农作物叶片中不同色素对可见光的吸收程度不一致.从可见光波段与接近红外波段的曲线来看,叶片曲线陡然升高,此现象称为“红边”现象.通过波长增加至波长为 0.89 μm 这一阶段曲线分析得出:农作物的光谱特性曲线还与叶片的内部结构相关,反射率达到峰值附近,此时南瓜反射率为 0.80,茄子反射率为 0.81,而青菜的反射率则高达 0.86.

综合分析 3 种农作物的光谱反射曲线图,可得出 3 种农作物的光谱反射趋势一致,其光谱反射率的大致相同,3 种农作物均在蓝光波段出现了光谱最低值,最低值低至 0.26,在绿光波段均出现了光谱最高值,最高值达到 0.34.结合光谱反射率曲线图和遥感图像数据进行分析,再合理考虑 3 种农作物的光谱值在靠近红外波段的不同,对 3 种农作物的归一化植被指数(Normalized Differential Vegetation Index, NDVI)进行计算,并通过计算结果进行对比分析,计算公式为

$$\text{NDVI} = \frac{\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}}} \quad (1)$$

式中:NDVI 为农作物的归一化植被指数; ρ_{nir} 为近红外波段的农作物光谱反射率; ρ_{red} 为红光波段的农作物光谱反射率.

归一化植被指数 NDVI 能在一定程度上增强遥感技术进行植被特征提取时的响应能力,也是目前农作物领域中植被指数最常用的方法.定义归一化植被指数的计算结果中没有异常值,即其置信度值为 2,在此基础上对 3 种目标农作物的归一化植被指数进行统计,并综合分析其对应的像素百分比,统计结果见表 2,对比分析图像如图 3 所示.

表 2 NDVI 统计特征值

作物	最小值	最大值	均值	标准差
青菜	0.671	0.984	0.875	0.048
茄子	0.711	0.991	0.887	0.042
南瓜	0.692	0.979	0.869	0.051




图 3 典型农作物 NDVI 统计分布

综合分析表2和图3:3种农作物青菜、茄子、南瓜的归一化植被指数普遍都高,青菜的归一化植被指数均值为0.875,茄子的归一化植被指数均值为0.887,南瓜的归一化植被指数均值为0.869;3种农作物的归一化植被指数均集中分布,青菜的归一化植被指数标准差为0.048,茄子的归一化植被指数标准差为0.042,南瓜的归一化植被指数标准差为0.051;归一化植被指数特征统计曲线既相互重叠又相互交错.使用主成分分析(Principal Component Analysis,PCA)方法对3种农作物的特征维度进行降低,降至三维再进行3种农作物的区分,但依旧难以区分开.主成分分析法得出的3种农作物散点图如图4所示.因此,为了更好地区别3种农作物,引入了深度学习的方法,利用深度学习方法的卷积层神经网络结构实现对3种农作物的复杂特征进行提取,再利用遥感图像分类技术实现对3种农作物特征的区分.




图4 PCA特征下典型农作物散点

2.2 光谱特征及其分类

综合上述分析结果可知:3种农作物在可见光波段的光谱反射率基本一致,难以通过此方法实现对3种农作物的区分;以归一化植被指数为基础,综合使用波谱工具,3种农作物的曲线在经过波谱工具作用后的像素亮度曲线在不同波段均出现了些许差异,如图5所示.




图5 典型农作物波段差异

综合分析图5可知:反射率曲线呈现出的像素亮度最大的农作物为南瓜,其次是青菜,像素亮度最小的农作物是茄子;3种农作物在蓝光波段所呈现出的像素亮度差异最为显著,三者像素亮度的差值随着波长的增加呈现出差值减小的变化趋势.以3种农作物的原训练数据为基础,综合考虑3种农作物在不同波段作用下的像素亮度差异相关关系,将不同波段的像素亮度值进行重新组合,构成新的训练数据样本,再对波长变化与农作物的区分效果进行综合分析.新的训练数据波段组合信息如表3所示,包括3种不同的组合方式.

表3 波段组合信息

波段	组合方式
单波段	蓝光波段
双波段	红光波段、绿光波段
三波段	红光波段、绿光波段、蓝光波段

利用CNN网络模型对影像数据中的复杂特征进行提取,能高效地找出不同农作物的差异,实现对农作物的分类.结合当前领域内的实践经验,以及使用UAV遥感图像所获取的图像光谱信息不多,提取出的农作物形状特性明显,提取到的农作物纹理信息也较为突出等特点,综合深层神经网络的卷积结构,开发出专用于农作物分类识别的网络模型,结构如图6所示.

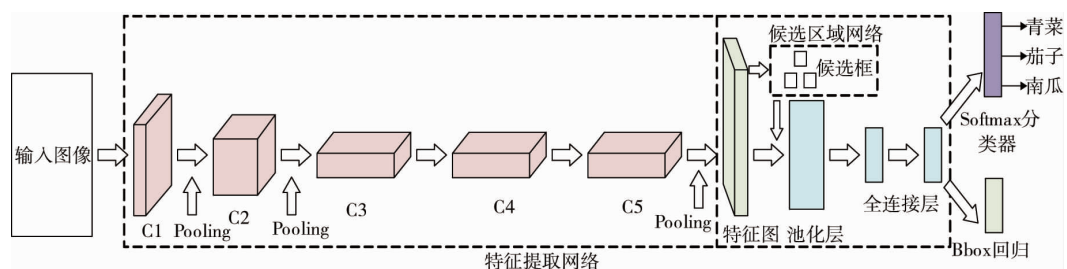


图6 利用改进的 AlexNet-2 网络进行农作物分类

模型各部分参数设置(如表4所示):

1)输入部分.输入数据为各个农作物的可见光样本数据,分辨率为 224×224 ,各样本数据与其农作物相互对应,有利于模型对农作物的训练识别.

2)卷积层部分.模型卷积层结构与 ReLU 激活函数的综合能达到去除影像线性化的目的,在某些卷积层结构后还有池化层结构,池化层结构的增加减少了模型中的全连接层结构的参数,避免了影像处理过程中的过拟合现象的发生.

表4 网络初始卷积核参数设置

层级	输入	卷积核/步长	填充像素数	池化/步长	输出
1	$224 \times 224 \times 3$	$7 \times 7 \times 3/2$	2	$3 \times 3/2$	$63 \times 63 \times 96$
2	$63 \times 63 \times 96$	$5 \times 5 \times 96/2$	1	$3 \times 3/2$	$15 \times 15 \times 256$
3	$15 \times 15 \times 256$	$3 \times 3 \times 256/1$	1	0	$15 \times 15 \times 384$
4	$15 \times 15 \times 384$	$3 \times 3 \times 384/1$	1	0	$15 \times 15 \times 384$
5	$15 \times 15 \times 384$	$3 \times 3 \times 384/1$	1	$3 \times 3/2$	$6 \times 6 \times 224$

模型卷积层结构进行卷积层运算时,输入卷积层的数据与卷积处理后输出的数据之间的关系为

$$y = \begin{cases} \frac{x - n_j + 2p}{s_j} + 1, & (n_c = 0); \\ \frac{x - n_j + 2p + s_j - n_c s_j}{s_j s_c} + 1, & (n_c > 0). \end{cases} \quad (2)$$

式中: y 为卷积处理后输出的数据大小; x 为卷积处理前输入的数据大小; n_j 为卷积层结构的卷积核大小; s_j 为卷积层进行影像处理的步长; n_c 为池化层进行池化处理的大小; s_c 为池化层进行池化处理的步长; p 为对卷积处理前输入的数据进行4边填充的规模大小.

3)全连接层部分.全连接层部分与上层卷积层或池化层相连,其滤波器的规模与上层输出滤波器的规模相同,大小为 $6 \times 6 \times 224$,全连接层部分中每个滤波器在进行影像处理时都会生成唯一的运算结果,再经过 Dropout 运算后进行影像数据的输出.

4)其他参数部分.模型中的其他参数均使用随机梯度下降法训练网络进行参数的定义,定义高斯分布的均值为0、标准差为0.01,用此参数的高斯分布对模型其他参数的权重进行初始化.将第二层卷积层、第四层卷积层、第五层卷积层以及模型中所有的全连接层的神经元偏差初始化定义为1,其余层的初始化定义为0,由此初始化可实现带正输入的 ReLU 激励函数对整个模型初级阶段的学习效率的提升.

3 实验结果与分析

3.1 数据获取

研究区域分为试验区和验证区,位于湖南省长沙市农业科学研究所试验基地.试验区测区面积为 $5 \text{ km} \times 5 \text{ km}$,验证区测区面积为 $1.0 \text{ km} \times 0.8 \text{ km}$.试验数据来源于2019年5月在试验区和2019年6月在验证区利用无人机遥感获得的图像.无人机平台所采用的无人机为著名无人机研发公司星索尔航空科技有限公司研发生产的六旋翼无人机,该无人机的最大飞行速度可达 7 m/s ,轴距为 $1\ 300 \text{ mm}$,无人机飞行的起重限制重量为 8 kg ,与之相匹配的相机影像传感器为 CMOS 传感器,相机影像的镜头搭载型号为 FOV94,此镜头具有对焦点无穷远的特点,所拍摄的单幅照片最大像素可达到 $4\ 000 \times 3\ 000$.无人机平台试验区设定的最高飞行高度为 100 m ,包含的飞行航线有15条,航线总长度为 20 km ,通过无人机平台对试验区的田地及周边区域进行航拍,总计获得的航片数量为580张.无人机平台验证区设定的最高飞行高度为 80 m ,包含的飞行航线有10条,航线总长度为 10 km ,通过无人机平台对验证区的田地及周边区域进行航拍,总计获得的航片数量为160张.

3.2 平台与网络训练

试验过程选用的训练处理平台为良泰 SP16HDIET 深度学习计算模拟机,处理器型号为 Intel Xeon E5

1650 v4,主频参数为 7.2 GHz 内存大小为 64 GB;显卡型号为 Nvidia TITAN XP(GPU);硬盘型号选取 2 TB, 7 200 rpm SATA.

根据表 4 所示网络结构进行参数设置后,对候选区域网络进行反复多次的训练,并对训练的结果进行多次的测试试验.在对网络进行训练的过程中,定义网络训练的起始学习率为 0.001,单次网络训练所处理的图像数量为 64,网络处理的动量值为 0.8,网络处理的权值衰减值为 0.000 4,网络训练的迭代次数最多为 100 次;在 L6 全连接层结构引入 Dropout 层,并在 L7 全连接层也同时引入 Dropout 层,以保证在进行图像处理过程中,每一层对图像特征的提取过程能相互独立,为避免图像处理过程中过拟合现象的发生,定义过拟合 Dropout 值为 0.5,经过以上参数定义后的网络结构具有最高的图像识别精度.改进后的 AlexNet-2 网络模型在进行图像处理,输出的结果为对遥感图像农作物进行的分类之后的结果,本次研究过程中为了提高对猕猴桃农作物的识别,定义网络结构的置信度>0.85.为了进一步检验本文所使用的图像提取辨识方法的有效性,将以上定义参数值保持不变,对本文方法、SVM-RFE^[23]方法和 SVM-SS^[24]方法进行识别测试验证,并对识别结果进行数据统计.

3.3 分类结果分析

在卷积神经网络模型中使用样本输入数据信息进行训练,由此得出不同样本参数情况下,卷积神经网络模型对于不同对象的分类精度的变化曲线,如图 7 所示.

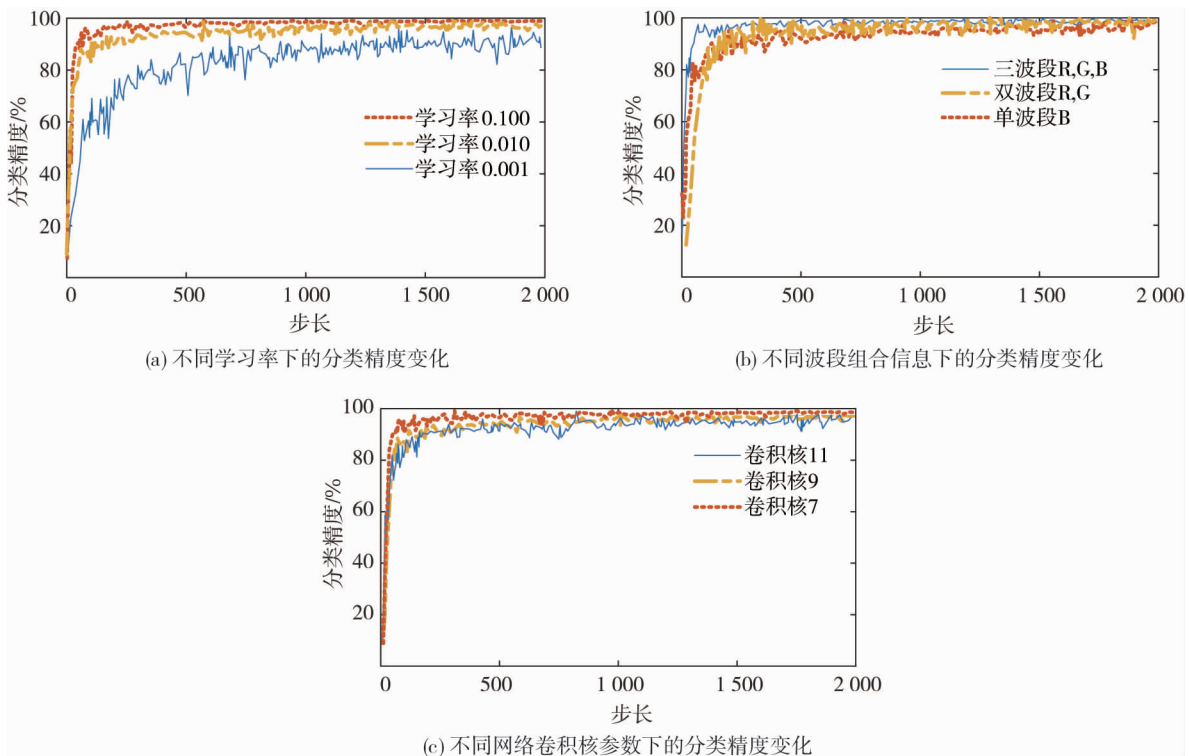


图 7 不同参数下模型分类精度变化曲线

综合分析图 7 可知:样本数据的参数不同,对卷积神经网络模型的识别结果的作用效果也不同.

1) 卷积神经网络的学习率受到农作物分类模型收敛速度大小的影响程度最大.在利用卷积神经网络模型对某些常见的农作物进行训练识别的过程中,高学习率下的收敛效果以及收敛后的识别精度均优于低学习率.出现以上现象的原因是低学习率样本训练时的步长较短,导致识别精度只在某一局部实现了最优,而使用高学习率进行样本训练时,只要在训练过程中杜绝卷积神经网络出现训练振荡的现象,就能实现农作物分类模型的快速收敛,还能防止局部最优状况的发生.

2) 模型分类精度和稳定性受样本包含波段信息影响.样本数据中的波段信息对卷积神经网络模型的分类精度具有很大的影响,也对卷积神经网络模型的稳定性有很大的作用效果.样本数据不同波段间的差异程度,以及增加样本数据的波段信息都能在一定程度上提升卷积神经网络对农作物的分类精度.综合农

作物的光谱图进行分析,在光谱图的可见光波段中,3种农作物的光谱图显示出:在蓝光波段内,3种农作物的像素亮度差异最大,然后是红光波段,最后是绿光波段;当样本数据中的波段信息只有蓝光波段时,样本训练的卷积神经网络模型对农作物具有分类精度,但总体来说其分类识别的效果具有变动性;在样本数据的波段信息中除了蓝光波段还有红光波段和绿光波段时,卷积神经网络模型进行农作物分类识别的稳定性在一定范围内得到了提升,但其整体分类精度又不如波段信息仅包含蓝光波段的情况,综合而言,使用蓝光、红光、绿光这3个波段信息的样本数据进行训练,可有效提升卷积神经网络对农作物的识别能力,也能提升整个网络系统的识别稳定性。

3)当第一层卷积层中的卷积核尺寸较小时,更能高效识别农作物的特征并进行提取,但对于某些特征不明显的农作物而言,卷积层的卷积核尺寸较大时仅需要进行一次卷积运算就能实现大范围的特征覆盖,表示效果较好。卷积核进行农作物特征提取时,无人机遥感图像中农作物的特征信息呈现出密集分布的效果。在卷积神经网络模型中,使用尺寸相对较大,值为 11×11 的卷积核对农作物进行特征的识别和提取,由试验可知:在此卷积核尺寸下进行2000次的样本数据训练后,卷积神经网络模型能保持稳定且精准的农作物特征识别和分类;当使用尺寸相对较小,值为 7×7 的卷积核进行农作物特征识别和提取时,只进行了1200次的样本数据训练,就实现了卷积神经网络模型的稳定和精准的农作物特征识别和分类,且尺寸较小的卷积核的分类精度更高。

为了更进一步地对所使用的农作物特征提取方法进行分类适用性的验证和研究,将目前使用广泛的3种方法(改进后的 AlexNet-2 特征提取法、SVM-RFE 网络数据提取分类法、SVM-SS 网络数据提取分类法)进行对比试验分析,SVM 网络法进行特征提取时,使用径向基函数作为 SVM 网络的核函数,再以交叉验证的网格搜索法为 SVM 网络运算的基础,确定惩罚因子 C ,以及对核函数中参数 γ 的确定。以3种不同方法的整体分类精度值作为评价指标,再综合 Kappa 系数对其进行辅助评价。经过多次反复的试验,得出3种方法进行农作物特征提取的分类精度(见表5),从而验证了整个卷积神经网络模型的稳定性特征。

对表5中的数据进行分析,改进后的 AlexNet-2 特征提取法的总体分类精度优于其他2种方法,均值至少提升了3.91%,经过 Kappa 系数对3种方法进行评价后,也是 AlexNet 特征提取法的效果最佳,Kappa 系数的均值至少提升了2.2%。分析此现象出现的原因,SVM-RFE 网络法进行农作物特征提取的过程是利用了径向基函数作为核函数对农作物进行的非线性分类,此方法特别适用于样本数据规模较小的情况,在遥感影像数据规模较大时,此方法进行提取的效果相对较差,特别是在不同种类农作物之间的特征差异比较小的情况下,核函数进行特征提取时更加捉襟见肘。改进后的 AlexNet-2 特征提取法的实质是深层网络机构,在对农作物进行特征提取时更能提取出农作物更深层的特征,在农作物之间的差异较小时,提取效果更佳,使用此方法进行农作物特征提取,能高效地提取出不同农作物之间的区别和差异规律,提升模型的农作物分类精度。

表5 不同农作物识别方法对比试验结果

实验序号	总体分类精度/%			Kappa 系数		
	本文方法	SVM-RFE	SVM-SS	本文方法	SVM-RFE	SVM-SS
1	97.85	94.32	93.24	0.948	0.931	0.927
2	97.54	94.12	94.12	0.958	0.928	0.922
3	98.63	93.87	92.76	0.952	0.935	0.912
均值	98.01	94.10	93.37	0.953	0.931	0.920

3.4 与卫星遥感的优势

传统的农作物特征提取过程中,所使用的特征提取方法的基础是高空间分辨率卫星影像,特别是以三维角度为出发点进行农作物的特征提取辨别时具有显著的效果。原因在于不同的农作物对于光照强度的敏感程度不一样,所产生的农作物不同反应效果也不同。因此,通过图像像素的亮度值就能完成对农作物种类的识别。本文 UAV 遥感分类法的空间分辨率相较于传统分类法更高,由此,无人机遥感影像处理方法对农作物的细节纹理等特征进行提取时更加高效,更加精准,可以更好地通过光谱空间对作物的类别进行

精确的辨识.

3.5 实时性能测试

系统的实时评估指标是单帧图像处理时间,包括平均处理时间和最快处理时间.选取无人机遥感图像中的6张图像进行测试,每个步骤的运行时间和总时间随图像分辨率而变化,如表6所示.

表6 不同图像分辨率下的总时间测试结果

分辨率	遥感图像	灰度	图像二值化	孔过滤填充	粒子滤波	边界提取	边界填充	耗时/ms
1 920×1 080	图像 1	72.37	3.245	6.572	7.242	1.376	0.801	95.2
	图像 2	73.24	3.761	6.313	6.234	1.986	0.672	93.2
	图像 3	75.45	3.563	6.471	7.215	1.638	0.472	90.8
960×540	图像 1	16.34	0.923	1.283	1.987	0.287	0.386	22.8
	图像 2	14.92	0.912	1.317	2.032	0.286	0.218	23.2
	图像 3	18.34	0.936	1.275	1.866	0.275	0.278	22.2

从表6的数据可以得出:当分辨率相同时,图像的总耗时差别不大.即平均处理时间与单帧图像的最快处理时间之间几乎没有差异.如表7所示,单帧图像的平均处理时间为系统实时评估的指标,可以发现随着分辨率降低,平均处理时间减少.因此,这是一种通过降低图像分辨率来减少平均处理时间的方法,但是边界精度会相应降低.因此,根据实际情况选择合适的图像分辨率,可以满足不同场合的精度和实时性要求.

表7 单帧图像的平均处理时间

分辨率	单帧图像的平均耗时/ms
1 920×1 080	93.8
960×540	22.4

4 结论

1) 提出一种基于改进 AlexNet 网络的无人机遥感图像分类方法.对原始 AlexNet 网络进行优化,并基于改进 AlexNet 网络的深层卷积结构,依据不同波段内的像素亮度对农作物进行准确分类.

2) 所提方法率先对无人机遥感图像的光谱特性进行提取并分析,采用优化的深度神经网络进行图像分类,取得了良好的效果,具有实际应用价值.所提方法的主要不足是图像必须预处理为 224×224 尺寸,且不能对遥感农作物进行实时边界区分.

3) 未来将探讨所提方法对于其他各类农作物的适用性,努力实现所提方法的泛化能力.为了提高处理效率,将采用空间金字塔池化(SPP)模式,实现对分辨率的自动化处理.未来的另一个研究方向是将农作物的边界检测问题添加到所提方法中,这样在 GPS 系统的帮助下,就可实现对野外作业区域的自动分类与测绘试验.

参考文献:

- [1] 王来刚,徐建华,贺佳,等.基于无人机遥感的玉米叶面积指数与产量估算[J].玉米科学,2020,28(6):88-93.
- [2] 韩文霆,张立元,张海鑫,等.基于无人机遥感与面向对象法的田间渠系分布信息提取[J].农业机械学报,2017,48(3):205-214.
- [3] 戴建国,张国顺,郭鹏,等.基于无人机遥感可见光影像的北疆主要农作物分类方法[J].农业工程学报,2018,34(18):122-129.
- [4] 杨勇强,王振锡,师玉霞,等.基于无人机影像的天山云杉林更新类别划分及提取[J].西北林学院学报,2020,35(6):185-193.
- [5] 张超,乔敏,刘哲,等.基于无人机和卫星遥感影像的制种玉米田识别纹理特征尺度优选[J].农业工程学报,2017,33(17):98-104.
- [6] LIU H, YUAN Z, ZHANG J, et al. Highly efficient paddy classification using UAV-based orthorectified image[C]//2017

- IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Fort Worth, TX, 2017: 3230–3233.
- [7] HONKAVAARA E, ESKELINEN M A, PÖLÖNEN I, et al. Remote Sensing of 3-D Geometry and Surface Moisture of a Peat Production Area Using Hyperspectral Frame Cameras in Visible to Short-Wave Infrared Spectral Ranges Onboard a Small Unmanned Airborne Vehicle (UAV)[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(9): 5440–5454.
- [8] 杨红艳,杜健民,王圆,等.基于无人机遥感与卷积神经网络的草原物种分类方法[J].农业机械学报,2019,50(4):188–195.
- [9] BAZI Y, MELGANI F. Convolutional SVM Networks for Object Detection in UAV Imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(6): 3107–3118.
- [10] HU X, ZHONG Y, LUO C, et al. Fine Classification of Typical Farms in Southern China Based on Airborne Hyperspectral Remote Sensing Images[C]//2018 7th International Conference on Agro-geoinformatics (Agro-geoinformatics), Hangzhou, China, 2018: 1–4.
- [11] ZEGGADA A, MELGANI F. Multilabel classification of UAV images with Convolutional Neural Networks[C]//2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China, 2016: 5083–5086.
- [12] 王生生,王顺,张航,等.基于轻量级卷积神经网络及无人机遥感图像的大豆田杂草识别[J].农业工程学报,2019,35(6):81–89.
- [13] 徐信罗,陶欢,李存军,等.基于 Faster R-CNN 的松材线虫病受害木识别与定位[J].农业机械学报,2020,51(7): 228–236.
- [14] SU L, HUANG Y, HU Z. AN EMPIRICAL STUDY ON FULLY CONVOLUTIONAL NETWORK AND HYPERCOLUMN METHODS FOR UAV REMOTE SENSING IMAGERY CLASSIFICATION [C]//IGARSS 2020 – 2020 IEEE International Geoscience and Remote Sensing Symposium, Waikoloa, HI, USA, 2020: 2567–2570.
- [15] YANCHO J, COOPS N C, TOMPALSKI P, et al. Fine-Scale Spatial and Spectral Clustering of UAV-Acquired Digital Aerial Photogrammetric (DAP) Point Clouds for Individual Tree Crown Detection and Segmentation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(10): 4131–4148.
- [16] 张仓皓,杨樟平,谢巧雅,等.毛竹立竹度无人机遥感识别有效高度的研究[J].遥感技术与应用,2020,35(6): 1436–1446.
- [17] 祁媛,徐伟诚,王林琳,等.基于无人机遥感影像的砂糖橘果树提取方法研究[J].华南农业大学学报,2020,41(6): 126–133.
- [18] 赵静,李志铭,鲁力群,等.基于无人机多光谱遥感图像的玉米田间杂草识别[J].中国农业科学,2020,53(8): 1545–1555.
- [19] WU M Y, CHENG S, QIN L, et al. Ground Object Classification Based on UAV Multispectral Images[C]// 2019 Chinese Automation Congress (CAC), Hangzhou, China, 2019: 4629–4634.
- [20] KYRKOUC, THEOCHARIDES T. EmergencyNet: Efficient Aerial Image Classification for Drone-Based Emergency Monitoring Using Atrous Convolutional Feature Fusion[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 1687–1699.
- [21] ISHIDA T, KURIHARA J, VIRAY F A, et al. A novel approach for vegetation classification using UAV-based hyperspectral imaging[J]. Computers & Electronics in Agriculture, 2018, 144: 80–85.
- [22] 李广,张立元,宋朝阳,等.小麦倒伏信息无人机多时相遥感提取方法[J].农业机械学报,2019,50(4):211–220.
- [23] 李志铭,赵静,兰玉彬,等.基于无人机可见光图像的作物分类研究[J].西北农林科技大学学报(自然科学版),2020,48(6):137–144.
- [24] 王璨,武新慧,李志伟.基于卷积神经网络提取多尺度分层特征识别玉米杂草[J].农业工程学报,2018,34(5): 144–151.
- [25] 胡根生,张学敏,梁栋.基于 WWSVDD 多分类的遥感图像病害松树识别[J].北京邮电大学学报,2014,37(2):23–27.
- [26] CAVALLARO G, BAZI Y, MELGANI F, et al. Multi-Scale Convolutional SVM Networks for Multi-Class Classification Problems of Remote Sensing Images [C]//IGARSS 2019 – 2019 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2019: 875–878.
- [27] KRIZHEVSKY A, SUTSKEVER I, GEOFFREY E. ImageNet Classification with Deep Convolutional Neural Networks[J]. Communications of the ACM, 2017, 60(6): 84–90.
- [28] HAO X, ZHANG G, MA S. Deep Learning[J]. International Journal of Semantic Computing, 2016, 10(3):417–439.