

doi:10.6041/j.issn.1000-1298.2022.08.025

基于多/高光谱影像的农作物叶片像素自动提取方法

虞佳佳¹ 姬旭升^{2,3} 李晓丽^{2,3}

(1. 浙江机电职业技术学院, 杭州 310053; 2. 浙江大学生物系统工程与食品科学学院, 杭州 310058;
3. 浙江大学数字农业与农村信息化研究中心, 杭州 310058)

摘要: 为了探明作物叶片像素提取的内在机理,设计适用于高光谱和多光谱影像的自动叶片提取方法,以实测高光谱和模拟多光谱影像为基础,通过特征转换、图像分割、边缘检测、基于梯度的断点连接4个步骤,最终实现了作物叶片的快速、准确、自动化提取。结果表明,EVI对作物叶片增强效果最好,NDVI次之,基于红边的植被指数效果最差。在叶片提取过程中,本方法所涉及的5个精度评价指标平均值均在0.94以上,分布于0.9478~0.9896,叶片提取精度极高。该方法相较于大津法(OTSU)、标记分水岭(Marker-watershed)等经典方法具有明显的优势,其提取精度分别提高了29%~98%,与全卷积神经网络(FCN)或随机森林(RF)基本相当。通过运用特征转化,局部自适应阈值分割和边缘检测相结合,可以实现基于高光谱、多光谱影像的叶片像素快速、准确、自动化提取;该方法可避免繁琐的样本标记,且对高光谱和多光谱影像的空间分辨率及尺寸要求较低,其提取结果可直接作为深度学习的标记样本或叶片尺度的表型参数反演的基础数据,具有推广价值。

关键词: 叶片像素; 自动提取; 多/高光谱影像; 复杂背景

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2022)08-0240-10 **OSID:** 

Automatic Extraction Method of Crop Leaves from Complex Background Based on Multi/hyperspectral Imaging

YU Jiajia¹ JI Xusheng^{2,3} LI Xiaoli^{2,3}

(1. Zhejiang Institute of Mechanical and Electrical Engineering, Hangzhou 310053, China
2. College of Biosystems Engineering and Food Science, Zhejiang University, Hangzhou 310058, China
3. Center of Digital Agriculture and Agricultural Information, Zhejiang University, Hangzhou 310058, China)

Abstract: As the primary photosynthetic organ of plants, the leaf is essential for almost all crops. Extracting pure leaf pixels is a prerequisite for estimating leaf physiological parameters or plant disease by using remote sensing images accurately. Therefore, identifying crop leaf pixels accurately, efficiently, and automatically from images are significant for the research of plant phenomics. Unfortunately, previous methods usually were developed from the view of computer vision with the process of having insight into leaf spectral characters abandoned, which is harmful to extract leaf pixels from hyperspectral or multispectral images, so the existing method is poor in these images. An automated method of leaf pixels extraction for hyperspectral or multispectral images was proposed by exploring the internal mechanism of crop leaf pixels identification. After spectral feature compression and conversion for measured hyperspectral and simulated multispectral images, this method performed local adaptive threshold segmentation (ATS) and Canny edge detector (Canny), respectively, so that the advantages of the selected two algorithms were integrated. Following all of this, a novel gradient-based breakpoint connection algorithm was applied. Eventually, an automated crop leaf pixels identification method was developed. The results demonstrated that EVI was superior in enhancing the spectral signatures of the crop leaves. Additionally, NDVI also can strengthen the leaves features, but this ability was slightly worse than EVI. Furthermore, it was highlighted that the ability of vegetation indexes derived from red edges bands was limited in enhancing leaf spectral features. The proposed method can identify crop leaf

收稿日期: 2022-02-12 修回日期: 2022-05-30
基金项目: 浙江省尖兵领雁研发攻关计划项目(2022C02056)
作者简介: 虞佳佳(1983—),女,副教授,主要从事农业信息化与智能信息系统研究,E-mail: yjjxdg@qq.com
通信作者: 李晓丽(1982—),女,教授,博士生导师,主要从事农业信息化和生产加工装备智能化研究,E-mail: xiaolili@zju.edu.cn

pixels effectively, with all accuracy evaluation parameters up to above 0.94. Compared with OTSU, Marker-watershed, and other typical methods, the accuracy was remarkably improved with increases in all evaluation parameters by 29% to 98%, which was similar to the performance of a fully convolutional network (FCN) or random forests (RF) algorithms. However, when ignoring the time-consuming labeling collection activities of FCN and RF, the leaf identification efficiency was improved by about 73% than them. By the combination of feature conversion, ATS, and Canny detector, the crop leaf pixels can be identified accurately, efficiently, and automatically from hyperspectral or multispectral images, without labor-extensive and time-consuming labeling collection activities. The input images were arbitrary for the method so that it's potential for estimating leaf physiological parameters or taking the place of the manual labeling activities in deep learning or supervision algorithms.

Key words: crop leaf pixels; automatic extraction; multi/hyperspectral imaging; complex background

0 引言

叶片是植物体最重要的营养器官之一,它在光合、呼吸、蒸腾以及碳和养分循环等生理过程中发挥着决定性作用。以叶长、叶宽和叶面积为代表的作物表型信息往往与品种和基因型密切相关,此外抗病品种的筛选常以作物叶片感病程度为重要依据^[1-2],以上叶片表型性状的获取又均以叶片形态和面积的准确提取为前提,因此准确、快速地获取叶片形态和面积,对作物养分估测及新品种筛选均具有重要意义^[3-4]。传统叶片表型信息获取均通过手动测量的方式完成,此类方法耗时费力,且易受主观因素的影响,已不能满足现代作物性状调查和表型组学研究的现实需求,因此寻找一种高效、准确、自动化的作物叶片提取方法,对未来大范围的叶片表型信息调查、叶片尺度的养分估测及抗病新品种的筛选都大有裨益。基于 RGB、多光谱或高光谱相机的近地面和低空遥感平台作为一种新型的作物表型信息调查手段,具有灵活性高、可操作性强、探测效果好、成本低廉的特点,现已广泛应用于作物病害早期监测^[5-6]、叶片尺度养分估测^[7-9]等诸多领域,它们的出现为快速、准确、实时地提取作物叶片提供了解决思路。

目前,基于近地面遥感影像的作物叶片提取主要通过阈值分割的方法(Threshold-based)来完成,大津法(OTSU)^[10]、固定阈值(Fixed thresholds)^[11]、直方图熵(Histogram entropy)^[12]等算法先后被应用到此领域;有些学者通过加入归一化植被指数(Normalized difference vegetation index, NDVI)^[13]、过绿指数(Excess green index, ExG)等植被指数^[14]来进一步改进阈值法的性能,取得了较好的应用效果。此类方法操作简便、影像处理效率高、结果较为准确,但是常规阈值往往通过试错法确定,该过程需要大量的人机交互,加之阈值法自身性能的限制,使其在处理较大影像数据集时,呈现出模型稳定性不

高、泛化能力弱、叶片边缘定位不准的劣势。随着计算机视觉技术的发展,基于分水岭(Watershed)、标记分水岭(Marker-watershed)等数学形态学分割算法的叶片提取研究开始出现,这些探索不仅考虑了叶片边缘的梯度变化信息,而且还加入了像素的空间分布特征,从而促进了该领域的进一步发展^[15-16]。尽管此类算法较阈值分割有了明显进步,但该过程依然需要一定的人机交互,且叶片提取精度易受遥感影像光照强度分布不均的影响,这对大规模、自动化、高精度地叶片提取极为不利。考虑到监督或非监督机器学习算法在对象识别方面所表现出的巨大潜力,部分学者开始尝试运用模糊聚类(Fuzzy cluster)、均值漂移(Mean shift)、支持向量机(Support vector machine, SVM)等算法进行作物叶片的提取,为作物叶片的快速提取提供了解决方案^[17]。研究表明监督学习算法的对象识别性能明显优于非监督算法,但前者的实现必须依赖一定数量的训练样本,使得此类算法的自动化性能受到了严重制约。近年来,伴随着大数据和人工智能技术的快速发展,相关学者开始探索深度学习算法在作物叶片自动化提取方面的应用潜力,以 LeafMASK 为代表的植物叶片自动化提取算法将该领域的相关研究提升到了一个新的高度^[18]。深度学习算法的实现需立足于大量的影像数据和繁琐人工标记,还需占用大量的计算资源,使其在处理高维度叶片影像时常常具有较低的性价比。

长期以来,作物叶片提取的相关研究均将此类问题纳入到计算机视觉的范畴,其目的只针对叶片提取和计数本身,但是作物叶片提取之后的养分、色素等生理生化指标反演以及感病程度估算等植物和育种学家最为关注的核心问题几乎被选择性忽略,致使现存的大多数植物叶片提取方法均以 RGB 影像为基本数据源^[19]。因为 RGB 影像自身具有较低的特征维度,所以针对此类影像的叶片提取算法在处理高光谱等具有较高特征维度的影像时,时常被

“信息爆炸”的问题所困扰,拖慢了影像处理速度,降低了方法的效率,这种问题在基于深度学习的高光谱影像作物叶片提取研究中表现尤为明显^[13]。除此之外,先前的研究大多仅聚焦于算法的性能,缺乏对输入特征的探究和深入分析,这对摸清植物叶片提取的内部机理,进一步提高作物叶片提取的效果和效率都极为不利^[20]。从植物和育种学家的角度出发,基于遥感影像的作物叶片提取是为后续叶片尺度的生理生化指标反演和感病程度定量评估服务。作为一个影像处理的初始步骤,不应投入过多的人力和计算资源,输入少量的相关特征,在无人机交互的前提下,快速、准确地提取出作物叶片才是该问题的最优解^[21]。因此,开发一种简单、快速、准确、自动化的作物叶片提取方法,对该问题的本身及后续叶片尺度的生理生化指标反演和感病程度精确评估均具有重要的意义。

本文立足于农作物叶片提取算法现有的研究进展,针对农作物叶片提取的现实需求,以室内高光谱影像以及其模拟的多光谱影像为基础数据源,深入探究常用植被指数在叶片提取中的作用;并以此为基础,通过融合图像分割、边缘检测、基于梯度的断点连接等算法的优势,以期提出一种快速、准确、不需人机交互的作物叶片自动提取方法。

1 材料

1.1 高光谱及模拟多光谱影像采集

在野外试验小区采集大量被病菌侵染的番茄叶片和茶叶叶片,然后立即转运至实验室内,通过室内高光谱植物表型平台(图 1)采集所需高光谱影像。该平台由控制终端、交互式操作界面、光谱仪、暗箱、线光源、高度调整轴、移动平台等部分构成,其中可见近红外高光谱成像仪的型号为 V10E (Specim, 芬兰)。该仪器光谱分辨率 2.8 nm,光谱采样间隔为

0.65 nm,可一次性采集波长 400 ~ 1 000 nm 之间 512 个通道的光谱影像,其高光谱影像的成像模式为推扫式。




图 1 室内高光谱植物表型平台

Fig. 1 Indoor hyperspectral plant phenotyping platform

1. 光谱仪 2. 样品 3. 电源

在采集影像时,分别将获取到的样品平放于移动平台之上,随后设置合适的曝光时间和线扫描速度,在进行标准白场校正和暗场校正之后即可采集波长范围为 400 ~ 1 000 nm 的高质量光谱影像。高光谱图像采集软件为 Spectral Image - V10E (ISUZU OPTICS)^[22]。考虑到多光谱相机具有更大的应用潜力及更高的性价比,且着眼于进一步增加本文算法普适性,利用所采集到的高光谱影像对广泛应用的 Airphen (Hiphen, 法国)^[23]、Sequoia (Parrot, 法国)^[24]、RedEdge - MX (Micasense, 美国)^[25] 多光谱影像进行模拟,以进一步明确本文算法对多种数据源的适用性。该模拟过程通过软件 ENVI 5.3 (Exelis Visual Information Solutions, Boulder, 美国)实现,运用 ENVI 软件对原始高光谱影像进行重采样,保持其他参数不变,仅保留各多光谱相机所对应波段信息,最终获得高质量的多光谱影像数据集。共获得 4 组共 320 个(80 × 4) 叶片及叶片分支影像集,每组包括 729 个叶片。本研究所涉及的高光谱及模拟多光谱影像的基本情况如表 1 所示。

表 1 获取或模拟的高/多光谱影像

Tab. 1 Acquired or simulated multispectral and hyperspectral images of crop leaves				
影像类型	相机名称	波长/nm	应用场景	可搭载平台
高光谱	ImSpector V10E	400 ~ 1 000	作物氮素、色素估测	近地面
	Airphen	450/570/675/710/730/850	作物养分、长势及产量估测	近地面/低空平台
多光谱	Sequoia	RGB/550/660/735/790	作物胁迫、养分、长势监测及产量评估	近地面/低空平台
	RedEdge - MX	475/560/668/717/840	作物病害、养分及长势监测	近地面/低空平台

1.2 作物叶片实测数据获取

本研究作物叶片实测数据通过目视解译的方式获取。将获取到的高光谱影像分别导入到 ENVI 软件之中,在遥感专家的协助下,运用 Vector 模块,沿

叶片边缘分别对各叶片进行矢量化转换,得到每幅影像所对应的叶片多边形,即 Shapefile 文件。此类文件可以精确地记录叶片边缘位置,并计算叶片面积。在获取到 Shapefile 文件之后,利用 ENVI ROI

工具将实测叶片数据转换为 ENVI classification 格式,并以 TIF 影像的格式保存,备用。最终获取到叶片边缘定位误差不超过一个像素的高质量真实叶片影像集。

2 自动提取方法

图 2 为技术路线图,该作物叶片提取方法主要包括以下步骤:①光谱特征转换及筛选。选用代表性植被指数进行特征转换和压缩,筛选出合适的光谱指数特征层。②特征影像分割及边缘检测。分割特征影像,并对特征影像进行边缘检测,综合以上两种结果,得到作物叶片边缘特征。③叶片边缘断点连接。通过边缘强度图对作物叶片边缘进行重连,得到完全闭合的作物叶片边缘。④边缘填充及形态学后处理。对得到的作物叶片闭合边缘进行填充,运用形态学方法去除噪声,最终获得精确的作物叶片前景影像。




图 2 作物叶片像素提取流程图

Fig. 2 Flowchart of crop leaves pixels extraction

2.1 光谱特征转换及筛选

光谱指数是目前最常用的高光谱或多光谱数据转换方法。光谱指数包括单波段及其变换形式、归一化光谱指数及其变换形式、比值光谱指数及其变换形式、多波段光谱指数 4 种类型。为了大幅度压缩高光谱和多光谱影像的特征维度,提高所构建算法的运算效率,且最大程度地增强叶片光谱信号,抑制各类背景特征,选用 NDVI、GNDVI (Green normalized difference vegetation index)^[26]、EVI (Enhance vegetation index)^[27]、NDRE (Normalized difference red edge index)^[28] 和 CI_{red-edge} (Red edge chlorophyll index)^[29] 这 5 种较具代表性的植被指数对原始光谱影像进行特征转换,在提高数据一致性的同时深入分析各个特征波段对作物叶片像素提取的影响。该特征转换过程均以原始高光谱影像为输

入层。需要强调的是,因为该部分的目的是通过光谱指数比较各常用波段在叶片提取中的作用,单一类型的光谱指数即可满足此类需求,所以本部分仅选用归一化光谱指数及其变换形式作为光谱特征转换的主要依据。

NDVI 是植被遥感领域应用最为广泛的植被指数,它可以有效地整合近红外和红光波段的光谱信息,增强图像中植被特征,抑制非植被特征;并且它还可以很好地反映植被覆盖度及植被的生长状态^[30]。与 NDVI 作用类似,GNDVI 可以较好地反映植被信息,但因该指数中加入了绿波段的光谱特征,使得该指数可以更好地捕获光合作用,从而对叶绿素更敏感^[26]。EVI 为 NDVI 的优化指数,它可以稳定植被特征,减弱土壤和大气因素的影响^[27]。红边波段为植被所特有,它与植被生长状态、叶片结构和生理生化参量息息相关,使得 NDRE 和 CI_{red-edge} 可以精确地反映植物叶片色素等成分的空间分布情况^[28-29]。在系统性分析各指数在植物叶片提取中的作用之后,选取两个最优的指数作为后续算法的输入变量。

2.2 特征影像分割及边缘检测

在进行光谱特征转换之后,选取叶片与背景分离度最大的特征层作为局部自适应阈值分割 (Local adaptive thresholding segmentation, ATS) 算法的输入层来进行叶片前景特征和非植被背景特征的分离。ATS 是进行图像分割的一种有效算法^[31-32],它可以将所输入的特征影像分为若干个区块,仅从局部像素确定最优分割阈值。该算法的最大优势在于图像分割过程中产生的二值化阈值不是固定不变的,不同区块内的最适阈值随着区块内灰度的分布情况也会发生一定改变,使得该算法对光照不均匀的影像有着极佳的分割效果。由于大部分分割算法均存在边缘定位不准的弊端,所以在进行阈值分割的同时,通过 Canny 算子对选定的 2 个特征层中叶片边缘较为清晰的特征层进行边缘检测,获取影像中各对象的边缘信息。在此基础上,将叶片前景特征和对象的边缘信息融合,以最大限度地消除非叶片边缘特征对后续步骤的影响,最终仅获取到准确的作物叶片边缘特征。

2.3 基于边缘强度图的断点连接

由于边缘检测算法自身性能的限制,植物叶片边缘提取易受噪声的干扰,使得所获得的叶片边缘往往不能闭合。本研究选用基于边缘强度图^[33]的断点连接策略,对叶片的真实边界进行还原,从而获取到完全闭合的作物叶片边界。从本质上讲叶片边缘即为叶片像元与背景像元之间的光谱跃变区,即

边缘强度图在跃变区的局部最大值,通过开发自动化算法对边缘断点进行捕获,并以此为基础获取边缘强度图在跃变区的局部最大值,使边缘断点沿叶片边缘真实的延伸方向增长,直至叶片边缘断点完全闭合为止。该策略可以克服腐蚀、膨胀等常规断点延伸方法边缘定位不准的弊端,使最终所得到的作物叶片闭合边缘可以最大程度地接近其实际像素。此后对植物叶片闭合边缘进行填充,再经过数学形态学后处理,即可得到精确的作物叶片前景影像。

2.4 结果评价指标与验证

2.4.1 叶片提取精度评价

目前,图像分割的评价方法可分为:目视解译、系统性评估、实例检验、差异化验证4种^[34]。其中,目视解译最为常用,该方法虽可对分割结果进行定性评价,但也存在易受主观因素干扰的弊端^[35];相较而言,差异化验证对分割结果的验证最有效,它可以对分割结果的误差进行量化描述^[36]。为了客观、准确地评价叶片提取精度,选用目视解译和差异化验证相结合的方法对叶片提取的结果进行系统化分析,其中选定的差异化验证的指标包括准确度(Precision)、召回率(Recall)、Dice系数、杰卡德相似系数(Jaccard)、曼哈顿距离(Manhattan)5种,以便与现有研究进行横向对比。

2.4.2 与现有经典叶片提取方法对比

选取大津法(OTSU)、标记分水岭(Marked-watershed)和随机森林(Random forests, RF)3种经典算法作为对照,以5种指标为依托,深入分析所涉及的4种算法在提取精度等方面的差异,明确本算法的优缺点,为该算法的进一步完善提供理论依据。

3 提取结果分析

3.1 选定特征维度下的叶片信息增强及背景抑制

为了对选定植被指数的叶片光谱特征增强效果进行客观比较,对所获取的5种指数分别进行线性拉伸,将它们量纲统一转换为1,以提高所涉及数据的一致性。图3展示了任意5组作物叶片(其中番茄叶片2组,茶叶叶片3组)在5种不同植被指数(NDVI、GNDVI、EVI、NDRE、CI_{red-edge})空间中的特征强度分布状况。通过目视解译可知,NDVI对叶片信息有非常显著的增强效果,但该指数对背景的抑制能力相对较弱,这种弱化的能力在叶片边缘和阴影像素处较为显著。GNDVI也可以突出叶片特征,但该指数对各类背景信息也较为敏感,在增强叶片光谱特征的同时也会对所有非植被背景信息的细节进行有效地刻画;虽然该指数的能力有限,但对阴影

和光晕的敏感性却相对较低,使得基于该指数的叶片边缘特征较为突出。EVI可对叶片光谱特征进行大幅度增强,同时还可对背景信息进行有效地抑制,这种特征增强的有效性在处理叶片边缘混合像素和阴影处像素时体现的尤为突出;该指数可以在增强叶片光谱特征和抑制背景信息之间达到有效的平衡。相较于基于近红外波段的植被指数,所选定的2种基于红边波段的植被指数NDRE和CI_{red-edge}不能对叶片光谱特征进行增强,也不能对非植被背景特征进行抑制,但此类指数可以有效地捕获叶片内部的光谱变异(如作物病斑)。以上特征在不同作物(番茄和茶叶)及不同叶片组间所呈现出的规律基本一致,所以最终选取EVI(拥有蓝波段)或NDVI(缺失蓝波段)作为后续步骤的输入层。




图3 特定影像中5种植被指数的空间分布图

Fig.3 Spatial distributions of different vegetation indexes in selected hyperspectral or multispectral image

3.2 不同算法提取叶片结果对比

表2为本文方法、大津法(OTSU)、标记分水岭(Marker-watershed)、随机森林(RF)这4种方法对2类作物叶片数据集的平均提取精度。从所涉及算法的提取精度来看,除准确度外,本文方法的各项评价指标均有最优的表现,召回率、Dice系数、曼哈顿距离、杰卡德相似系数分别高达0.9649~0.9667、0.9721~0.9820、0.9828~0.9924、0.9458~0.9647,且包括准确率(0.9799~0.9978)在内的叶片像素提取精度均在0.95以上;以上评价指标较其它3种方法分别提高了2%~700%,叶片像素提取效果得到了显著改善。本文算法对不同的作物叶片和叶片背景均有较强的适应性,番茄叶片和茶叶叶片所对应的5个评价指标均保持在较高的水平,且2组数据(番茄叶片提取平均精度和茶叶叶片提取平均精度)之间不存在显著性差异。在另外3种叶片提取方法中,RF这种监督算法也有较好的表现,其各项指标较经典的无监督OTSU方法分别提

高了 50% ~ 600% , 部分数据集的各项指标可稳定在 0.91 以上; 然而此种算法对番茄和茶叶叶片这 2 种不同数据集的提取精度呈现出一定差异, 算法的迁移性相对较弱。在以上 4 种算法中, 经典的 OTSU 算法性能最差, 茶叶叶片的各项评价指标仅为 0.09 ~ 0.39; 且该方法对不同的数据集的适应能力极弱, 番

茄叶片(准确度、召回率、Dice 系数、曼哈顿距离、杰卡德相似系数分别为 0.981 0、0.630 6、0.766 2、0.825 1、0.623 0) 和茶叶叶片(准确度、召回率、Dice 系数、曼哈顿距离、杰卡德相似系数分别为 0.271 2、0.120 3、0.166 8、0.384 6、0.091 5) 的识别效果之间差异巨大。

表 2 不同方法的叶片提取平均精度及运算效率

Tab.2 Comparison of proposed method with typical methods in all hyperspectral image

方法	准确度		召回率		Dice 系数		曼哈顿距离		杰卡德相似系数	
	番茄	茶叶	番茄	茶叶	番茄	茶叶	番茄	茶叶	番茄	茶叶
本文方法	0.979 9	0.997 8	0.964 9	0.966 7	0.972 1	0.982 0	0.982 8	0.992 4	0.945 8	0.964 7
OTSU	0.981 0	0.271 2	0.630 6	0.120 3	0.766 2	0.166 8	0.825 1	0.384 6	0.623 0	0.091 5
Marker-watershed	0.728 9	0.861 9	0.796 2	0.754 4	0.759 0	0.802 2	0.858 5	0.908 4	0.612 7	0.669 8
RF	0.939 4	0.960 9	0.990 1	0.952 8	0.964 2	0.955 9	0.978 0	0.978 0	0.931 0	0.916 3

图 4 展示了 4 种不同方法对随机选取的 5 组作物叶片(其中番茄叶片 2 组, 茶叶叶片 3 组) 的提取效果。从图 4 可以看出, 基于不同方法和不同作物/数据集的叶片提取效果呈现出较大的差异。通过目视解译可知, 本文方法所提取的作物叶片边缘准确、清晰, 形态完整, 其与背景像素分离准确。此算法对番茄和茶叶两类作物叶片数据集均有较强的适应性, 叶片像素提取效果较好。相较而言, RF 算法的表现虽优于 Marker-watershed 和 OTSU 算法, 且可对部分数据(番茄叶片数据集) 中的叶片像素及其边缘进行准确捕获, 但这种能力在不同数据集(番茄和茶叶) 之间差异较大, 方法迁移性稍差, 在处理光照不均匀和背景复杂的叶片时尤为突出。Marker-watershed 算法虽可对叶片边缘进行准确地刻画, 但此类算法对叶片和背景像素的分离能力相对有限。OTSU 对叶片和背景的识别能力较弱, 在复杂的背景下该方法基本丧失了对叶片和背景的区分能力。




图 4 基于不同方法的选定叶片提取效果

3.3 自动提取算法对不同影像的叶片提取效果

图 5 为基于本文算法的 4 种不同影像集(ImSpector - V10E、Sequoia、Airphen、RedEdge - MX) 的作物叶片提取平均精度。虽然以上 4 种影像集的近红外波段(NIR)、红波段(Red) 和蓝波段(Blue) 的波长范围存在一定差异, 但从图 5 可以看出, 除 Sequoia 影像外, 基于其他 3 类影像的叶片提取平均精度之间不存在明显差异, 每类影像的准确度、召回率、Dice 系数、曼哈顿距离、杰卡德相似系数数值跨度较小, 且均保持在极高的水平(0.947 8 ~ 0.989 6), 本文算法对 ImSpector - V10E、Airphen、RedEdge - MX 这 3 种影像数据集中的叶片和背景像素实现了准确分离, 叶片像素提取效果良好。基于 Sequoia 影像的作物叶片像素提取虽精确度较高, 5 个评价指标稳定在 0.92 以上(0.922 9 ~ 0.975 4), 但此类影像相较于其他 3 类影像, 这 5 种评价指标的平均数值均呈现出一定的下降趋势, 其数值分别下降了 0.85% ~ 3.54%, 叶片像素提取效果变差, 这种现象在召回率指标上体现的尤为明显。该类影像的精确度和召回率之间的跨度较大, 其跨度为 0.038 7, 且曼哈顿距离与杰卡德相似系数之间的差




图 5 基于不同影像集的叶片提取平均精度

Fig.5 Performance of proposed method in different images acquired from different cameras

Fig.4 Segmented leaf of several methods in selected hyperspectral image

异呈现出逐渐增大的趋势,进一步说明本文算法对 Sequoia 影像中的叶片和背景像素的分离能力相较于其它 3 类影像开始逐渐减弱,叶片像素提取效果变差。

4 讨论

4.1 光谱特征对植被和背景信息的响应机理

由于植物叶片内部叶绿素、类胡萝卜素等光合色素的存在,使得高光谱或多光谱影像的红光波段和蓝光波段处呈现出明显的吸收特征,从而形成反射率波谷;与此同时,由于植物色素对绿光的低敏感性,使得该波段表现出较为明显的反射特征,进而形成反射峰^[37]。植物近红外波段的光谱特性与植物叶片的内部结构息息相关,此处叶片反射率高(45%~50%),透射率高(45%~50%),吸收率低(0~5%)^[38]。在可见光和近红外之间,即“红边”波段,植物叶片的反射率会急剧上升,形成植物最标志性的光谱特征,该波段对叶片内部的生理变化极为敏感^[39-40]。

本研究所选取的番茄和茶叶 2 类作物叶片性质差异较大,具有很强的代表性,尤其是数据集中的茶叶叶片具有较厚的角质层(蜡质层),部分区域镜面反射强烈^[41],可以在一定程度上模拟光照不均匀的情况。NDVI 指数可以综合近红外(NIR)和红波段(Red)的反射特征,其大小主要取决于两者之间反射率强度的相对差异,两者差异越大 NDVI 也越大,即使是叶片镜面反射或光照不均匀区域也遵循此规律;考虑到植物叶片红波段吸收峰的存在,叶片背景与叶片之间的光谱差异在 NDVI 特征空间中被进一步放大,且叶片 NDVI 显著高于背景,叶片特征被大幅度增强的同时,非植被背景也被大幅度抑制,并在一定程度上缓解叶片光照的不均匀,降低镜面反射对叶片像素的影响,使得该指数可以适应不同类型的作物叶片。受散射光的影响,阴影背景处的近红外反射率显著降低,致使阴影背景处的 NDVI 与叶片之间的差异减小,这也是 NDVI 对阴影像素较为敏感的一个重要原因^[42]。与前者类似,GNDVI 也受近红外波段反射率和绿光波段反射率之间相对差异的影响,尽管植物叶片绿波段存在反射峰,但其与特定色彩空间中的背景光谱差异较小,使得 GNDVI 虽可对作物叶片像素的光谱特征进行一定增强,但其对背景光谱的抑制能力相对有限。EVI 在 NDVI 的基础之上整合进了蓝波段光谱特征,增大了叶片光谱和背景光谱之间的差异,使得前者的信号更加突出。由于 EVI 衡量的近红外、红、蓝 3 个波段反射率的相对差异,受这 3 个波段反射率绝对数值的影响

不大,使得这种信号的增强对不同的作物均有很强的适应性。随着蓝波段的加入,该指数对阴影像素的敏感性也进一步降低,植物叶片边缘更加清晰和明显。与基于近红外波段的植被指数不同,基于红边的指数(NDRE、CI_{red-edge})虽对叶片内部生理变化较为敏感,然而受制于红边波段和近红外波段反射率的相对差异,加上背景噪声的影响,使得该指数对叶片的增强、背景的抑制效果极差^[43]。

4.2 自动提取算法的可靠性和可迁移性

叶片像素提取算法的可靠性和可迁移性是衡量其性能的重要指标^[44],两者可从叶片的提取精度、算法对输入层的要求、超参数的适应性等方面综合评判。在本研究中利用 4 种不同波段、不同波长、不同长宽的 320 组番茄和茶叶叶片(其中番茄 120 组,茶叶 200 组)高光谱实测和多光谱模拟影像对本文算法进行了系统性测试,均取得了较好的叶片像素提取效果,这 5 类评价指标的平均值均在 0.92 以上,其表现接近或超越最新的监督分类(Meanshift、Graphcut)、深度学习(FCN、GCA)叶片提取算法(表 3)^[45]。该算法对于不同类型的数据集均有较好的适应性,叶片像素提取精度较高,究其原因,是因为本方法对原始的光谱特征进行了转换和筛选,该过程不仅大幅度降低了原始影像的特征维度,而且还通过 EVI 或 NDVI 指数对叶片光谱特征进行了大幅度增强,由于这 2 种植被指数的分布受波段类型影响极大,对具体波长敏感性较低^[46],加之植被指数受特定波段反射特征的相对差异影响极大,与相应波段反射率的绝对数值关系较小,因此,该类特征具有较高的稳定性和可靠性。局部自适应阈值分割算法的应用也是保证叶片自动提取算法可靠、稳定的重要原因。此算法对输入影像的尺寸无任何限制,且可适应输入影像光照不均匀的情况;该算法几乎不存在输入参数^[31,47],使得本文叶片提取算法的有效性和稳定性进一步增强。尽管该算法在高光谱实测和多光谱模拟影像中取得了较好的叶片提取效果,但因本研究是为了方便开展后续叶片尺度的生理生化指标反演和感病程度精确评估,所以该算法

表 3 本文方法与最新叶片提取方法的性能对比
Tab.3 Comparison of proposed method with the latest methods

算法	准确 度	召回 率	Dice 系数	曼哈顿 距离	杰卡德相 似系数	算法 来源
本文方法	0.983 7	0.969 9	0.977	0.988 7	0.954 6	
Meanshift	0.781 9	0.891 4	0.816	0.863 5	0.715 6	文献[48]
Graphcut	0.758 9	0.872 0	0.790	0.854 6	0.682 34	文献[49]
FCN	0.912 0	0.982 9	0.945	0.955 7	0.896 5	文献[45]
GCA	0.945 6	0.874 7	0.903	0.940 6	0.833 9	文献[50]

在 RGB 影像上的通用性目前还未加以考虑,使得该方法仍存在较大的改进空间。

4.3 自动提取算法的技术创新及未来应用

作物叶片像素提取是开展叶片尺度生理生化指标反演、感病程度精确评估等研究的先决条件和决定性步骤^[51]。在相当长的一段时间内,叶片像素提取的相关研究都被纳入到计算机视觉的范畴^[52],标记分水岭 (Marker-watershed)、全卷积神经网络 (FCN)、LeafMask 等算法先后被应用于这一领域,取得了较好的应用效果^[18]。以上算法的实现均需适当的人机交互和实测样本输入,由于机器学习或深度学习过程中的样本标记需要耗费大量的人力和时间成本^[53],且 FCN、LeafMask 等深度学习算法需要占用较多的计算资源,所以此类算法均不能满足植物表型研究中准确、快速、高效提取作物叶片的现实需求,这也使得自动化提取叶片像素的相关研究应运而生。具体而言,大幅度提高叶片像素提取的精度及效率是此类算法出现的根本原因^[54-55]。对于本文方法而言,它省去了大量复杂且耗时的样本标记活动,降低了大量的人工成本,可在无实测样本参与的情况下实现叶片的快速、准确提取,这种优势在未来高通量、实时植物表型平台的搭建中显得尤为重要。除此之外,还通过特征转换的方法,对叶片和背景的光谱响应机理进行了深入地分析,对深入了解叶片提取的内在机理,进一步提高作物叶片像素

提取的效率都大有裨益。

随着影像采集终端的普及,海量的叶片影像数据集在短时间内被迅速释放,以卷积神经网络为代表的人工智能算法在处理大数据集时具有独特的优势。本研究的叶片自动提取方法可与这些人工智能算法优势互补,其运算结果可以直接作为人工智能算法的标记集,从而节省大量的人力和时间成本,这对进一步提高叶片自动提取算法的效率、精度和普适性都具有重要意义。尽管本方法以基于高光谱和多光谱影像中叶片的提取为目的,但该算法运算简单、操作方便,在经过一定改进之后可以适应 RGB 影像的处理,具有转化为计算机软件或手机 APP 的潜力,使农户、专家等在田间地头即可完成叶片的提取,应用前景广阔。

5 结论

- (1) EVI 指数在叶片特征增强和背景抑制方面表现最好,NDVI 次之,CI_{red-edge} 和 NDRE 效果最差。
- (2) 本文方法在叶片提取方面表现优异,其各项精度评价指标均在 0.94 以上,显著高于 OTSU、标记分水岭等算法,且该方法可适应不同的相机。
- (3) 通过整合特征转换、局部自适应阈值、边缘检测等方法,可以实现对叶片的快速、准确、自动提取。该方法的运算效率相较于 RF 算法可提高 80% 以上。

参 考 文 献

- [1] PAL M S, ZHANG Guoping, CHEN Jinxin. Influence of genotypes and nitrogen fertilization on leaf morphogenesis and tillering behaviors in winter wheat[J]. Journal of Triticeae Crops, 2000, 20(1): 28-33.
- [2] YANG W, FENG H, ZHANG X, et al. Crop phenomics and high-throughput phenotyping: past decades, current challenges, and future perspectives[J]. Molecular Plant, 2020, 13(2): 187-214.
- [3] CASTILLO-MARTÍNEZ M, GALLEGOS-FUNES F, CARVAJAL-GÁMEZ B, et al. Color index-based thresholding method for background and foreground segmentation of plant images[J]. Computers and Electronics in Agriculture, 2020, 178: 105783.
- [4] 张慧春,杨琨琪,李杨先,等. 面向植物抗旱性研究的多源表型信息采集和分析技术[J]. 农业机械学报, 2022, 53(2): 203-211.
ZHANG Huichun, YANG Kunqi, LI Yangxian, et al. Multi-source phenotypic information collection and analysis techniques for drought resistance of plants[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 203-211. (in Chinese)
- [5] ZHAO Y, YU K, LI X, et al. Detection of fungus infection on petals of rapeseed (*Brassica napus* L.) using NIR hyperspectral imaging[J]. Scientific Reports, 2016, 6(1): 38878.
- [6] 张德荣,方慧,何勇. 可见/近红外光谱图像在作物病害检测中的应用[J]. 光谱学与光谱分析, 2019, 39(6): 1748-1756.
ZHANG Derong, FANG Hui, HE Yong. Research of crop disease based on visible/near-infrared spectral image technology: a review[J]. Spectroscopy and Spectral Analysis, 2019, 39(6): 1748-1756. (in Chinese)
- [7] ELSHERBINY O, FAN Y, ZHOU L, et al. Fusion of feature selection methods and regression algorithms for predicting the canopy water content of rice based on hyperspectral data[J]. Agriculture, 2021, 11(1): 51.
- [8] 张筱蕾,刘飞,聂鹏程,等. 高光谱成像技术的油菜叶片氮含量及分布快速检测[J]. 光谱学与光谱分析, 2014, 34(9): 2513-2518.
ZHANG Xiaolei, LIU Fei, NIE Pengcheng, et al. Rapid detection of nitrogen content and distribution in oilseed rape leaves based on hyperspectral imaging[J]. Spectroscopy and Spectral Analysis, 2014, 34(9): 2513-2518. (in Chinese)
- [9] 程曼,袁洪波,蔡振江,等. 田间作物高通量表型信息获取与分析技术研究进展[J]. 农业机械学报, 2020, 51(增刊1):

314 – 324.

- CHENG Man, YUAN Hong, CAI Zhenjiang, et al. Review of field-based information acquisition and analysis of high-throughput phenotyping[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51 (Supp. 1) : 314 – 324. (in Chinese)
- [10] 孙俊,宋佳,武小红,等. 基于改进 Otsu 算法的生菜叶片图像分割方法[J]. 江苏大学学报(自然科学版),2018,39(2): 179 – 184.
- SUN Jun, SONG Jia, WU Xiaohong, et al. Image segmentation method of lettuce leaf based on improved Otsu algorithm[J]. Journal of Jiangsu University (Natural Science Edition), 2018, 39(2) : 179 – 184. (in Chinese)
- [11] WANG Y, WANG D, ZHANG G, et al. Estimating nitrogen status of rice using the image segmentation of G – R thresholding method[J]. Field Crop Research, 2013, 149(3) : 33 – 39.
- [12] ZHENG L, ZHANG J, WANG Q. Mean-shift-based color segmentation of images containing green vegetation[J]. Computers and Electronics in Agriculture, 2009, 65 : 93 – 98.
- [13] HAUG S, MICHAELS A, BIBER P, et al. Plant classification system for crop/weed discrimination without segmentation[C]//IEEE Winter Conference on Applications of Computer Vision, 2014:1142 – 1149.
- [14] HAMUDA E, GLAVIN M, JONES E. A survey of image processing techniques for plant extraction and segmentation in the field[J]. Computers and Electronics in Agriculture, 2016, 125 : 184 – 199.
- [15] GAO L, LIN X. Fully automatic segmentation method for medicinal plant leaf images in complex background[J]. Computers and Electronics in Agriculture, 2019, 164 : 104924.
- [16] 丁永军,张晶晶,LEE Won Suk,等. 小波变换与分水岭算法融合的番茄冠层叶片图像分割[J]. 农业机械学报,2017,48(9):32 – 37.
- DING Yongjun, ZHANG Jingjing, LEE Won Suk, et al. Segmentation of tomato leaves from canopy images by combination of wavelet transform and watershed algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(9) : 32 – 37. (in Chinese)
- [17] GUIJARRO M, RIOMOROS I, PAJARES G, et al. Discrete wavelets transform for improving greenness image segmentation in agricultural images[J]. Computers and Electronics in Agriculture, 2015, 118 : 396 – 407.
- [18] GUO R, QU L, NIU D, et al. LeafMask: towards greater accuracy on leaf segmentation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021:1249 – 1258.
- [19] 王琢,汪雅婷,宋文龙,等. 基于深度学习的叶片图像分割算法[J]. 森林工程, 2019, 35(1) : 42 – 46.
- WANG Zhuo, WANG Yating, SONG Wenlong, et al. The leaf image segmentation algorithm based on deep learning[J]. Forest Engineering, 2019, 35(1) : 42 – 46. (in Chinese)
- [20] GUILLAUME C, LAURE T, JULIEN M, et al. A model-based approach for compound leaves understanding and identification [C]//2013 IEEE International Conference on Image Processing. ICIP2013 – Proceedings, 2013:1471 – 1475.
- [21] SAKAMOTO T, GITELSON A, NGUY-ROBERTSON A, et al. An alternative method using digital cameras for continuous monitoring of crop status[J]. Agricultural and Forest Meteorology, 2012, 154 – 155 : 113 – 126.
- [22] WANG Y, HU X, HOU Z, et al. Discrimination of nitrogen fertilizer levels of tea plant (*Camellia sinensis*) based on hyperspectral imaging[J]. Journal of the Science Food and Agriculture, 2018, 98(12) : 4659 – 4664.
- [23] JAY S, BARET F, DUTARTRE D, et al. Exploiting the centimeter resolution of UAV multispectral imagery to improve remote-sensing estimates of canopy structure and biochemistry in sugar beet crops[J]. Remote Sensing of Environment, 2019, 231 : 110898.
- [24] OSCO L, RAMOS A, MORIYA É, et al. Improvement of leaf nitrogen content inference in Valencia-orange trees applying spectral analysis algorithms in UAV mounted-sensor images [J]. International Journal of Applied Earth Observation and Geoinformation, 2019, 83 : 101907.
- [25] XAVIER T, SOUTO R, STATELLA T, et al. Identification of ramularia leaf blight cotton disease infection levels by multispectral, multiscale UAV imagery[J]. Drones, 2019, 3(2) : 33.
- [26] GITELSON A, KAUFMAN Y, MERZLYAK M. Use of a green channel in remote sensing of global vegetation from EOS – MODIS[J]. Remote Sensing of Environment, 1996, 8(3) : 289 – 298.
- [27] HUETE A, LIU H, BATCHILY K, et al. A comparison of vegetation indices over a global set of TM images for EOS – MODIS [J]. Remote Sensing of Environment, 1997, 59(3) : 440 – 451.
- [28] BARNES E M, CLARKE T R, RICHARDS S E, et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data[C]// Proceedings of the Fifth International Conference on Precision Agriculture, Bloomington, MN, USA, 2000,
- [29] GITELSON A A, KAUFMAN Y J, STARK R, et al. Novel algorithms for remote estimation of vegetation fraction[J]. Remote Sensing of Environment, 2002, 80(1) : 76 – 87.
- [30] ROUSE J W, HAAS R H, SCHELL J A, et al. Monitoring vegetation systems in the Great Plains with ERTS[C]//FREDEN S C, MERCANTI E P, BECKER M. Third earth resources technology satellite – 1 symposium. Volume I: Technical Presentations. NASA SP – 351, NASA, Washington, D. C. , 1974:309 – 317.
- [31] BLAYVAS I, BRUCKSTEIN A, KIMMEL R. Efficient computation of adaptive threshold surfaces for image binarization[J].

- Pattern Recognition, 2006, 39(1): 89 – 101.
- [32] 马保国, 乔玲玲, 贾寅波. 基于局部自适应阈值的细胞图像分割方法[J]. 计算机应用研究, 2009, 26(2): 755 – 756.
- [33] CHENG T, JI X, YANG G, et al. DESTIN: a new method for delineating the boundaries of crop fields by fusing spatial and temporal information from WorldView and Planet satellite imagery[J]. Computers and Electronics in Agriculture, 2020, 178: 105787.
- [34] LI P, GUO J, SONG B, et al. A multilevel hierarchical image segmentation method for urban impervious surface mapping using very high resolution imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2011, 4(1): 103 – 116.
- [35] ZHANG H, FRITTS J E, GOLDMAN S A. Image segmentation evaluation: a survey of unsupervised methods[J]. Computer Vision and Image Understanding, 2008, 110(2): 260 – 280.
- [36] ZHANG Y. A survey on evaluation methods for image segmentation[J]. Pattern Recognition, 1996, 29(8): 1335 – 1346.
- [37] SIMS D, GAMON J. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages[J]. Remote Sensing of Environment, 2002, 81(2–3): 337 – 354.
- [38] KNIPLING E. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation[J]. Remote Sensing of Environment, 1970, 1(3): 155 – 159.
- [39] MILLER J, WU J, BOYER M, et al. Seasonal patterns in leaf reflectance red-edge characteristics[J]. International Journal of Remote Sensing, 1991, 12(7): 1509 – 1523.
- [40] 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, 37(1): 29 – 35.
TANG Yanlin, HUANG Jingfeng, WANG Xiuzhen, et al. Comparison of the characteristics of hyperspectral and the red edge in rice, corn and cotton[J]. Scientia Agricultura Sinica, 2004, 37(1): 29 – 35. (in Chinese)
- [41] CHEN M. The tea plant leaf cuticle: from plant protection to tea quality[J]. Frontiers in Plant Science, 2021, 12: 75154.
- [42] HUANG S, TANG L, HUPY J, et al. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing[J]. Journal of Forestry Research, 2021, 32(1): 1 – 6.
- [43] XUE J, SU B. Significant remote sensing vegetation indices: a review of developments and applications[J]. Journal of Sensors, 2017(2017–5–23): 1 – 17.
- [44] BRINDHA G J, GOPI E S. An hierarchical approach for automatic segmentation of leaf images with similar background using kernel smoothing based Gaussian process regression[J]. Ecological Informatics, 2021, 63: 101323.
- [45] SAKURAI S, UCHIYAMA H, SHIMADA A, et al. Two-step transfer learning for semantic plant segmentation[C] // ICPRAM, 2018: 332 – 339.
- [46] 刘洋, 刘荣高, 陈镜明, 等. 叶面积指数遥感反演研究进展与展望[J]. 地球信息科学学报, 2013, 15(5): 734 – 743.
LIU Yang, LIU Ronggao, CHEN Jingming, et al. Current status and perspectives of leaf area index retrieval from optical remote sensing data[J]. Journal of Geo-Information Science, 2013, 15(5): 734 – 743. (in Chinese)
- [47] GRAESSER J, RAMANKUTTY N. Detection of cropland field parcels from Landsat imagery[J]. Remote Sensing of Environment, 2017, 201(19): 165 – 180.
- [48] COMANICIU D, MEER P. Mean shift: a robust approach toward feature space analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(5): 603 – 619.
- [49] BOYKOV Y, JOLLY M. Interactive graph cuts for optimal boundary & region segmentation of objects in N – D images[C] // Proc. ICCV, Vancouver, Canada, 2001: 105 – 112.
- [50] GRAND-BROCHIER M, VACAVANT A, CERUTTI G, et al. Tree leaves extraction in natural images: comparative study of preprocessing tools and segmentation methods[J]. IEEE Transactions on Image Processing, 2015, 24(5): 1549 – 1560.
- [51] LOWE A, HARRISON N, FRENCH A P. Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress[J]. Plant Methods, 2017, 13(1): 80.
- [52] KUZNICHOV D, ZVIRIN A, HONEN Y, et al. Data augmentation for leaf segmentation and counting tasks in rosette plants[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2019: 2580 – 2589.
- [53] WANG D, SHANG Y. A new active labeling method for deep learning[C] // 2014 International Joint Conference on Neural Networks (IJCNN), 2014: 112 – 119.
- [54] SCHARR H, MINERVINI M, FRENCH A P, et al. Leaf segmentation in plant phenotyping: a collation study[J]. Machine Vision and Applications, 2016, 27(4): 585 – 606.
- [55] 宁姗, 陈海涛, 赵秋多, 等. 基于 IM SSD + ACO 算法的整株大豆表型信息提取[J]. 农业机械学报, 2021, 52(12): 182 – 190.
NING Shan, CHEN Haitao, ZHAO Qiuduo, et al. Detection of pods and stems in soybean based on IM SSD + ACO algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12): 182 – 190. (in Chinese)