

融合无人机多源传感器的马铃薯叶绿素含量估算

边明博^{1,2} 马彦鹏^{1,2} 樊意广^{1,2} 陈志超³ 杨贵军^{1,2} 冯海宽^{1,4}

(1.北京市农林科学院信息技术研究中心,北京 100097; 2.农业农村部农业遥感机理与定量遥感重点实验室,北京 100097;
3.河南理工大学测绘与国土信息工程学院,焦作 454000; 4.南京农业大学国家信息农业工程技术中心,南京 210095)

摘要: 叶绿素是衡量作物光合作用的重要指标,监测马铃薯关键生育期叶片叶绿素含量(Leaf chlorophyll content, LCC)至关重要。获取马铃薯块茎形成期、块茎增长期和淀粉积累期的无人机 RGB 和多光谱影像,提取无人机多光谱影像的光谱反射率构建植被指数(Vegetation index, VIs),利用 Gabor 滤波器提取 RGB 影像的纹理信息(Texture information, TIs)。然后利用机器学习 SVR-REF 方法进行数据降维获取植被指数和纹理特征重要性排序,并采用迭代的方法在植被指数最佳模型中加入纹理信息,观察每次加入的纹理信息对模型的动态影响。最后使用支持向量机(Support vector machine, SVR)和 K-最近邻算法(K-nearest neighbor, KNN)2 种机器学习方法进行建模。结果表明,马铃薯 3 个关键生育期,加入纹理特征后的 2 种模型精度和稳定性均有提高,且 SVR 模型精度优于 KNN。块茎形成期,SVR 模型建模 R^2 由 0.61 提升至 0.71, RMSE 由 0.20 mg/g 降为 0.17 mg/g,精度提升 14.2%,验证 R^2 由 0.58 提升至 0.66, RMSE 由 0.19 mg/g 降至 0.17 mg/g,精度提升 10.5%。块茎增长期,SVR 建模 R^2 由 0.59 提升至 0.67, RMSE 由 0.16 mg/g 降至 0.14 mg/g,验证 R^2 由 0.71 提升至 0.79, RMSE 由 0.15 mg/g 降至 0.13 mg/g,精度提升 13.3%。淀粉积累期,SVR 建模 R^2 由 0.62 提升至 0.69, RMSE 由 0.17 mg/g 降至 0.14 mg/g,精度提升 17.6%,验证 R^2 由 0.47 提升至 0.63, RMSE 由 0.17 mg/g 降至 0.14 mg/g,精度提升 17.6%。另外,3 个时期参与 SVR 建模的植被指数数量分别为 19、16、3,纹理数量分别为 4、2、9,在植被指数不能充分响应叶绿素含量时,会有更多纹理信息参与建模,并且模型精度提升更高,进一步论证了纹理特征在马铃薯叶绿素含量反演中的重要性。

关键词: 马铃薯; 叶绿素含量; 图谱融合; Gabor 纹理; 机器学习

中图分类号: S25 文献标识码: A 文章编号: 1000-1298(2023)08-0240-09 OSID: 

Estimation of Potato Chlorophyll Content Based on UAV Multi-source Sensor

BIAN Mingbo^{1,2} MA Yanpeng^{1,2} FAN Yiguang^{1,2} CHEN Zhichao³ YANG Guijun^{1,2} FENG Haikuan^{1,4}

(1. Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China
2. Key Laboratory of Quantitative Remote Sensing in Agriculture, Ministry of Agriculture and Rural Affairs, Beijing 100097, China
3. School of Geomatics and Land Information Engineering, Henan Polytechnic University, Jiaozuo 454000, China
4. National Engineering and Technology Center for Information Agriculture, Nanjing Agricultural University, Nanjing 210095, China)

Abstract: Chlorophyll is an important indicator for measuring crop photosynthesis, and monitoring leaf chlorophyll content (LCC) of potatoes during critical growth stages. UAV RGB and multispectral images were obtained during the potato tuber formation, tuber growth, and starch accumulation periods. Vegetation indices (VIs) were extracted from UAV multispectral images, and texture information (TIs) was extracted from RGB images by using Gabor filters. Then, the SVR-REF method was used for data dimensionality reduction to obtain the importance ranking of vegetation indices and texture features, and an iterative approach was used to add texture information to the best vegetation index model and observe the dynamic effect of each added texture information on the model. Finally, support vector machine (SVR) and K-nearest neighbor (KNN) algorithms were used for modeling. The results showed that the accuracy and stability of the two models were improved after adding texture features during the critical growth stages of potatoes, and the SVR model performed better than the KNN model. During the tuber formation period, the SVR modeling R^2 was increased from 0.61 to 0.71, and RMSE was decreased from

收稿日期: 2023-04-06 修回日期: 2023-05-23
基金项目: 黑龙江省揭榜挂帅科技攻关项目(2021ZXJ05A05)和国家自然科学基金项目(41601346)
作者简介: 边明博(1996—),男,实习研究员,主要从事农业定量遥感研究,E-mail: bianmingbo0515@163.com
通信作者: 冯海宽(1982—),男,高级工程师,主要从事农业定量遥感研究,E-mail: fenghaikuan123@163.com

0.20 mg/g to 0.17 mg/g, with an accuracy improvement of 14.2%. The validation R^2 was increased from 0.58 to 0.66, and RMSE was decreased from 0.19 mg/g to 0.17 mg/g, with an accuracy improvement of 10.5%. During the tuber growth period, the SVR modeling R^2 was increased from 0.59 to 0.67, and RMSE was decreased from 0.16 mg/g to 0.14 mg/g, with an accuracy improvement of 13.3%. The validation R^2 was increased from 0.71 to 0.79, and RMSE was decreased from 0.15 mg/g to 0.13 mg/g, with an accuracy improvement of 13.3%. During the starch accumulation period, the SVR modeling R^2 was increased from 0.62 to 0.69, and RMSE was decreased from 0.17 mg/g to 0.14 mg/g, with an accuracy improvement of 17.6%. The validation R^2 was increased from 0.47 to 0.63, and RMSE was decreased from 0.17 mg/g to 0.14 mg/g, with an accuracy improvement of 17.6%. In addition, the number of vegetation indices involved in SVR modeling during the three periods were 19, 16, and 3, respectively, and the number of texture features were 4, 2, and 9, respectively. When vegetation indices were unable to respond adequately to chlorophyll content, more texture information was involved in modeling, and the model accuracy was improved significantly, further demonstrating the importance of texture features in chlorophyll content inversion in potatoes.

Key words: potato; chlorophyll content; atlas fusion; Gabor textures; machine learning

0 引言

马铃薯是世界第四大粮食作物^[1], 马铃薯产业的健康发展对保障国家粮食安全和居民生活水平具有重要意义。中国马铃薯种植面积居世界首位, 但单位产量低于世界平均水平^[2]。叶绿素是主导作物光合作用的重要色素, 其含量变化是表征作物胁迫状况、光合作用能力和衰老进程的信息^[3]。叶绿素含量与氮含量高度相关, 叶绿素含量可以直接反映作物的长势情况^[4]。因此, 及时准确地估算具有群体特征的作物冠层叶绿素含量, 对监测作物长势和指导施肥管理具有重要的意义^[5]。

传统的叶绿素含量调查通过人工破坏性取样方式获得, 具有效率低、成本高, 并对作物造成损伤导致减产等局限性^[6]。遥感技术以宏观、无损、快速及便捷等优点广泛应用于农业信息获取方面, 其迅速发展为农作物表型信息提取提供了新的技术手段与方法^[7]。随着遥感监测能力的提升, 超低空无人机(Unmanned aerial vehicle, UAV)遥感系统凭借其低成本、高分辨率、云下获取影像等优点, 成为作物表型信息监测研究的热点, 成为大规模作物长势动态监测的最有力工具^[8]。马铃薯与常规作物(如大豆、玉米和冬小麦)不同, 生长前期主要以营养生长为主, 生长后期会将前期积累的营养物质转移到地下块茎, 这使得作物表型性状和光谱响应的变化会产生剧烈差异。无人机多光谱包含近红外波段信息可以快速响应叶绿素含量, 无人机数码影像分辨率高, 纹理等数据的精度较高。

刘杨等^[9]利用 DSM 提取马铃薯的株高(H_{dsm}), 通过无人机数码影像提取植被指数和 H 、 H_{dsm} 组成新的数据集与马铃薯 AGB 做相关性分析, 结果表明各生育期基于 3 种回归技术均以植被指数融入 H_{dsm}

构建的模型精度最高, 估算能力最强; 陶惠林等^[10]利用无人机数码影像, 从作物表面模型中获取小麦株高信息, 提取株高和实测株高 R^2 达到 0.87, 加入实测株高和估测株高的可见光植被指数估算生物量的 R^2 由 0.72 提升至 0.79 和 0.82; LANG 等^[11]获取了玉米冠层的无人机 RGB 影像并基于 HSV 颜色模型去除土壤背景, 然后使用基于 BP 神经网络建立玉米叶绿素含量检测模型, 结果表明颜色和纹理特征的图像参数组合将叶绿素的确定系数精度由 0.70 提升到 0.72; YUE 等^[12]利用无人机高光谱和 RGB 影像分别将光谱指数、作物株高以及株高和光谱指数进行融合来构建冬小麦地上生物量模型, 结果表明单一变量估测效果不如融合变量效果好; 陈鹏等^[13]结合多光谱光谱和纹理特征进行马铃薯叶片叶绿素含量估算, 光谱和纹理构成的综合指标模型相关系数比指数模型、纹理模型均有提升; SUN 等^[14]从无人机多光谱图像中提取光谱参数和纹理特征, 通过纹理特征的线性计算, 构建归一化差异纹理指数(NDTI)、差异纹理指数和比值纹理指数(RTI)。结果表明, 无人机多光谱特征和纹理特征的结合是提高 LAI 估计精度的有效途径; 目前将植被指数与作物参数或纹理特征结合的研究已有很多, 使用植被指数与不同的作物形态学信息或纹理共同建模是一种提升作物参数反演精度的手段。但以上研究只使用了一种遥感器, 不能将多种遥感器的优势相结合。

樊意广等^[15]利用无人机高光谱和数码影像提取马铃薯地面覆盖度和株高等作物结构信息, 结合绿边参数构建 4 种融合特征参数, 结果表明最优融合参数模型在 5 个生育期 R^2 均提高 0.2 以上; FENG 等^[16]利用 SVR-REF 和 RF-REF 方法对不同压实情况下的苜蓿高光谱进行特征重要性排序,

将 3 种广泛使用的机器学习器(包括随机森林(RF)、支持向量回归(SVR)和 K 最近邻(KNN))相结合,开发了一个集成机器学习模型。结果表明,集成模型的性能优于所有基础学习者,决定系数 R^2 达到 0.874。将选择不同类型特征融合的方法一般是根据相关性排序简单筛选,参数与因变量的相关性 R^2 可评价单个参数与因变量的相关性,而对模型的贡献不能体现出来,按相关性添加参数会因为共线性影响使模型 R^2 虚假升高,也无法清楚得知每个添加的纹理特征对反演模型的影响。本文首先通过多光谱影像提取光谱信息构建植被指数,无人机 RGB 影像提取纹理信息,然后采用 SVR-REF 特征筛选方法进行重要性排序,最后采取迭代的方法使用 SVR 和 KNN 两种机器学习方法构建马铃薯冠层叶绿素含量反演模型。旨在构建一个可动态观测模型精度变化的模型,并通过添加不同个数纹理特征时模型 R^2 变化,了解纹理特征对马铃薯叶绿素含量反演精度的影响,最后选取最佳 LCC 反演模型,以监督作物的营养状况和长势。

1 材料与方法

1.1 研究区域与实验设计

本研究于北京市昌平区小汤山镇国家精准农业研究示范基地开展。实验区域位于小汤山镇东部(40°10'34"N,116°26'39"E)。该实验区属暖温带大陆半湿润半干旱季风气候,平均海拔 34 m,多年平均气温 11.8℃,年平均降水 584 mm,年平均无霜期 203 d。

实验区域采取图 1 中小区梯度施肥设计,共划分 48 个小区(5 m×6.5 m),选用早熟马铃薯品种中薯 5(Z5)和中薯 3(Z3)作为实验品种。设置 3 种密度(T0:60 000 株/hm²,T1:72 000 株/hm²,T2:84 000 株/hm²),每组处理 6 个小区,重复 3 次。设 4 种氮素水平(N0:0 kg/hm²,N1:244.65 kg/hm²,N2:489.15 kg/hm²,N3:733.5 kg/hm²),每组处理 8 个小区,重复 3 次。设 3 种钾肥水平(K0:0 kg/hm²,K1:970.5 kg/hm²(T 区和 N 区均为 K1 处理),K2:1 941 kg/hm²)。为保证影像拼接精度,在实验小区均匀设置 11 个控制点(G1~G11),并以高精度差分定位系统(GPS)进行毫米级定位。

1.2 无人机影像获取及处理

无人机光谱影像是以红杉多光谱镜头为遥感平台,分别获取马铃薯块茎形成期、块茎增长期、淀粉积累期的多光谱影像。飞行高度 20 m,航线重叠率 85%,均在无风无云晴朗天气进行数据采集,并根据太阳高度角调节航线。每次飞行后检查图像是否缺




图 1 马铃薯实验小区概况

Fig. 1 Overview of potato experimental community

失。并使用 Photoscan 软件对图像进行拼接得到正射影像。并对正射影像进行几何校正和辐射校正。最后使用 ArcGIS 软件绘出矢量小区,并使用 ENVI 软件提取小区平均光谱。得到每个小区的冠层光谱反射率。RGB 影像是以大疆精灵 4 型数码相机为遥感平台,和多光谱影像在相同时间采集数据并做相同预处理。

1.3 地面数据获取及处理

在 2019 年 5 月 28 日、6 月 10 日、6 月 20 日进行 3 次叶绿素样品测定,地面数据的获取和无人机数据获取同步进行。为避免因水分散失引起误差采样后立即用保鲜袋将样品密封带回实验室,将每个小区选取的植株样品筛选出 6 片典型马铃薯叶片,用直径为 0.8 cm 的打孔器获取 12 片小样品,用精度为 0.001 g 的天平称取样品质量,样品质量 0.2 g 左右。样品称量后放入装有 80 mL、质量分数为 95% 乙醇浸提液的刻度试管中,然后将试管置于黑暗中,每天摇动一次,直至叶片完全变白(3~7 d)后用分光光度计测定乙醇溶液在可见光 440、649、665 nm 处的吸光度值并利用 LICHTENTHALER^[17]的方法计算叶绿素的含量(mg/g)。

1.4 植被指数与纹理信息获取

1.4.1 特征筛选

根据相关研究,本研究选取 18 个与叶绿素反演相关性较好的植被指数:叶绿素指数-绿光^[12](Chlorophyll index-green light, CIG)、归一化植被指数^[13](Normalized difference vegetation index, NDVI)、绿色归一化差值植被指数(Green normalized difference vegetation index, GNDVI)、叶绿素指数-红边^[13](Chlorophyll index-red edge, CIRE)、归一化差异红边植被指数^[13](Normalized difference red-edged vegetation index, NDRE)、归一化差值植被指数^[13](Normalized difference vegetation index, RDVI)、优化

土壤调整植被指数^[13] (Optimize the soil and adjust the vegetation index, OSAVI)、比值植被指数^[13] (Ratio vegetation index, RVI)、土壤调节植被指数^[13] (Soil regulated vegetation index, SAVI)、叶面叶绿素指数^[18] (Leaf chlorophyll index, LCI)、差值环境植被指数^[18] (Differential environmental vegetation index, DVI)、绿色差值环境植被指数^[18] (Green difference environmental vegetation index, GDVI)、二次改进土壤调整植被指数^[19] (Secondary of adjustment soil vegetation index, MASVI2)、改进红边比值植被指数 (Modified red edge simple ratio index, MSR)^[18]、改进非线性植被指数^[19] (Modify nonlinear vegetation index, MNLI)、非线性植被指数^[19] (Nonlinear vegetation index, NLI)、温度归一化植被指数^[20] (Temperature normalized vegetation index, TNDVI)、三角植被指数^[20] (Triangular vegetation index, TVI) 用于构建叶绿素反演模型。

Gabor 变换也称加窗傅里叶变换(高斯函数作为窗函数),是一种从时间域到频率域的转换,它在提取目标的局部空间和频率域信息方面具有良好的特性。Gabor 滤波器与人类视觉系统中简单细胞的视觉刺激响应非常相似,它对于图像的边缘敏感,能够提供良好的方向选择和尺度选择特性对。本研究首先使用 Gabor 滤波器对经过预处理的 RGB 正射影像进行处理,然后选取 5 个不同尺度对 3 个生育期 RGB 正射影像滤波,最后统计 3 个波段通道的 4 个特征值(Mean、Ent、Sec、Var)共 60 个纹理特征作为建模参数。

1.4.2 建模方法

SVR-REF 是一种支持向量机回归算法,它是在 SVM 分类算法基础上发展而来的。与 SVM 算法不同的是,SVR-REF 算法用于解决回归问题,而不是分类问题。其基本思想是将回归问题转换为多个二分类问题,并使用支持向量机进行回归。SVR-REF 算法的优点是可以处理回归问题,且在训练过程中只需要使用一部分数据,具有较好的计算效率和内存效率。其缺点是参考向量的选择可能对预测结果产生影响,本研究通过 SVR-REF 特征筛选方法,对植被指数和纹理分别进行特征筛选,得到重要性排序。

SVR 是一种监督学习模型,其特征是使用内核。在 SVR 中变量首先通过核函数从原始空间转换为另一个空间。然后确定线性函数以最小化训练数据和不敏感损失函数之间的误差。KNN 回归模型是一种基于邻近算法的非参数回归模型,可以用于预测一个样本的输出值。该模型的基本思想是通

过找到最接近待预测样本的 K 个邻居,并使用这些邻居的输出值的加权平均值来估计待预测样本的输出值。在本研究中,使用了随机抽样法划分样本,选取 70% 的变量作为建模,剩余 30% 作为验证。并使用决定系数 (Coefficient of determination, R^2),均方根误差 (Root mean squared error, RMSE) 和标准均方根误差 (Normalized root mean squared error, NRMSE) 作为模型精度评价指标。

2 实验结果与分析

2.1 叶绿素分布

本研究利用分光光度计法获取每个小区的马铃薯叶绿素含量,由图 2 马铃薯叶绿素含量的箱线图可知其分布,需要持续光合的马铃薯生长分为 3 个主要阶段:块茎形成期、块茎增长期和淀粉积累期。块茎形成期叶绿素含量范围 0.94 ~ 2.23 mg/g,平均叶绿素含量 1.39 mg/g;块茎增长期叶绿素含量范围 0.66 ~ 1.79 mg/g,平均叶绿素含量 1.15 mg/g;淀粉积累期叶绿素范围 0.40 ~ 1.51 mg/g,平均叶绿素含量 0.91 mg/g。




图 2 叶绿素含量分布箱线图

Fig. 2 Boxplot of chlorophyll content distribution

2.2 特征重要性排序

本研究使用 SVR-REF 方法对指数进行排序,由于 SVR-REF 特征筛选方法为依次建模删除最不相关的自变量,将 22 个光谱植被指数和 60 个纹理参数分别进行筛选排序,排序结果如表 1、2 所示。由表 1 可知,在 3 期实验中,CIG、GDVI、GNDVI 的波段重要性排名比较靠前。

由表 2 可知,B-Var-1、G-Ent-4、G-Ent-2、G-Mean-1、B-Sec-2、G-Ent-3、B-Mean-1、G-Ent-1、B-Mean-3、G-Mean-2 在纹理指数重要性排序中较为靠前。

2.3 模型特征选择

为了探索高性能的特征变量,使用迭代的方法将变量逐次加入机器学习模型中。并采取随机抽样的方法划分模型训练集和测试集,随机选取70%的

表 1 植被指数特征重要性排序

Tab. 1 Vegetation index feature importance ranking			
排序	块茎形成期	块茎增长期	淀粉积累期
1	CIG	CIG	CIG
2	TVI	RVI	GNDVI
3	MSR	GNDVI	MASVI2
4	NIR	TVI	GDVI
5	DVI	MASVI2	SAVI
6	REDEDGE	GDVI	MNLI
7	GDVI	NDVI	MSR
8	MASVI2	R	G
9	GNDVI	OSAVI	RDVI
10	MNLI	TNDVI	CIRE
11	SAVI	G	REDEDGE
12	CIRE	NLI	LCI
13	G	MNLI	RVI
14	R	SAVI	NDRE
15	NDRE	LCI	NLI
16	OSAVI	RDVI	TVI
17	LCI	DVI	NDVI
18	RDVI	CIRE	OSAVI
19	NLI	NDRE	TNDVI
20	NDVI	NIR	NIR
21	TNDVI	MSR	DVI
22	RVI	REDEDGE	R

表 2 纹理特征重要性排序

Tab. 2 Texture index feature importance ranking			
排序	块茎形成期	块茎增长期	淀粉积累期
1	R-SEC-1	G-ENT-1	G-MEAN-1
2	R-VAR-5	B-MEAN-1	B-MEAN-1
3	G-VAR-1	G-MEAN-2	G-VAR-1
4	B-VAR-1	G-MEAN-1	G-ENT-1
5	R-VAR-3	G-VAR-5	B-VAR-1
6	R-VAR-4	R-SEC-5	B-VAR-5
7	G-ENT-4	R-SEC-2	R-SEC-5
8	G-ENT-2	B-SEC-3	R-MEAN-1
9	R-MEAN-1	B-MEAN-4	B-MEAN-4
10	G-MEAN-1	G-ENT-4	B-SEC-2
11	B-SEC-2	G-ENT-5	B-MEAN-3
12	B-MEAN-1	R-ENT-3	G-VAR-2
13	G-MEAN-5	B-VAR-4	G-MEAN-2
14	G-ENT-3	R-VAR-3	R-SEC-1
15	G-VAR-3	R-SEC-4	G-ENT-4
	⋮	⋮	⋮
50	G-SEC-3	B-SEC-1	B-ENT-5
51	R-ENT-1	G-SEC-2	G-SEC-4
52	B-VAR-3	G-SEC-4	R-VAR-2
53	B-VAR-2	R-MEAN-4	G-MEAN-3
54	G-MEAN-4	B-SEC-5	B-VAR-4
55	R-SEC-2	B-ENT-4	R-SEC-3
56	B-ENT-5	B-VAR-5	G-SEC-3
57	B-MEAN-2	B-ENT-3	R-VAR-1
58	G-ENT-5	B-ENT-5	R-ENT-1
59	B-SEC-1	R-MEAN-5	R-ENT-4
60	R-VAR-2	R-ENT-5	G-SEC-2

样本用来建模,30%的样本用来验证,并寻找最佳植被指数模型,在植被指数模型 R^2 达到最高时,把纹理特征加入植被指数构建的反演模型,观察模型的 R^2 精度变化。通过观察加入纹理特征后的模型精度变化,由图 3 可以看出,在添加了纹理特征后,3 个马铃薯主要生育期的模型稳定性均有提升。块茎形成期的 SVR 模型,前 19 个植被指数参与建模模型 R^2 精度达到最高值 0.58,加入前 4 个纹理特征模型 R^2 精度达到最高 0.65,精度提升 13.7%。块茎形成期 KNN 模型,在前 7 个植被指数参与建模时模型 R^2 精度达到最高值 0.55,加入前 3 个纹理特征模型 R^2 精度达到最高 0.58,精度提升 6.8%。块茎增长期 SVR 模型,加入前 16 个植被指数参与建模模型 R^2 精度达到最高值 0.68,加入前 2 个纹理特征模型 R^2 精度达到最高 0.72,精度提升 4.8%。块茎增长期的 KNN 模型,加入前 11 个植被指数参与建模时模型 R^2 精度达到最高值 0.56,加入前 4 个纹理特征模型 R^2 精度达到最高 0.60,精度提升 4.3%。淀粉积累期 SVR 模型中,前 3 个植被指数参与建模时模型 R^2 精度达到最高值 0.51,加入前 9 个纹理特征模型 R^2 精度达到最高 0.65,精度提升 27.3%。淀粉积累期 KNN 模型中,前 5 个植被指数参与建模时模型 R^2 精度达到最高值 0.52,加入前 7 个纹理特征模型 R^2 精度达到最高 0.63,精度提升 22.6%。

2.4 马铃薯叶绿素含量建模

本研究使用支持向量回归(SVR)和最近邻算法(KNN)分别采用 VIs 和 VIs 与纹理特征相结合的数据模型,对马铃薯的 3 个生长阶段(块茎形成期、块茎生长期和淀粉积累期)进行预测。模型参数选择:SVR 模型 Kernel 为 rbf, gamma 为 auto, tol 为 0.001,其余参数为默认参数;KNN 模型 n_neighbors 为 5, weight 为 uniform,其余参数为默认参数。不同生育期下马铃薯叶绿素反演结果如表 3 所示。研究评估了模型的表现,并使用 R^2 、RMSE 和 NRMSE 来评估模型的准确性。植被指数与融合数据模型验证见图 4。

(1)块茎形成期,SVR 模型建模集 VIs 的 R^2 为 0.58, RMSE 为 0.19 mg/g, NRMSE 为 18.2%, VIs 和纹理特征相结合的 R^2 为 0.65, RMSE 为 0.17 mg/g, NRMSE 为 16.8%, 模型精度提升 8.9%。验证集 VIs 的 R^2 为 0.61, RMSE 为 0.2 mg/g, NRMSE 为 17.8%, VIs 和纹理特征相结合的 R^2 为 0.71, RMSE 为 0.17 mg/g, NRMSE 为 15.3%, 模型精度提升 14.2%。KNN 模型建模数据集中 VIs 参与建模的 R^2 为 0.55, RMSE 为 0.20 mg/g, NRMSE 为 19.2%, 使用 VIs 和纹理特征相结合的 R^2 为 0.58, RMSE 为




图 3 不同生育期迭代特征模型精度变化

Fig. 3 Variation in accuracy of iterative feature models at different growth stages

表 3 各生育期基于机器学习模型精度评定

Tab.3 Each fertility period evaluated based on accuracy of machine learning model								
生育期	模型	特征	建模			验证		
			R^2	RMSE/($\text{mg}\cdot\text{g}^{-1}$)	NRMSE/%	R^2	RMSE/($\text{mg}\cdot\text{g}^{-1}$)	NRMSE/%
块茎形成期	SVR	VI _s	0.58	0.19	18.2	0.61	0.20	17.8
		VI _s + Texture	0.65	0.17	16.8	0.71	0.17	15.3
	KNN	VI _s	0.55	0.20	19.2	0.64	0.16	17.7
		VI _s + Texture	0.58	0.19	18.3	0.65	0.16	17.3
块茎增长期	SVR	VI _s	0.71	0.15	13.6	0.59	0.16	16.4
		VI _s + Texture	0.79	0.13	11.6	0.67	0.14	15.0
	KNN	VI _s	0.48	0.20	18.4	0.73	0.16	15.2
		VI _s + Texture	0.55	0.18	17.3	0.74	0.17	15.9
淀粉积累期	SVR	VI _s	0.47	0.17	15.6	0.62	0.17	17.6
		VI _s + Texture	0.63	0.14	13.0	0.69	0.14	14.7
	KNN	VI _s	0.48	0.18	16.5	0.63	0.14	18.3
		VI _s + Texture	0.63	0.16	14.6	0.66	0.13	17.0

0.19 mg/g,NRMSE 为 18.3% ,模型精度提升 5%。验证数据集 VI_s 的 R^2 为 0.64, RMSE 为 0.16 mg/g, NRMSE 为 17.7% ,VI_s 和纹理特征相结合的 R^2 为 0.65, RMSE 为 0.16 mg/g, NRMSE 为 17.3% ,模型精度提升 1.9%。

(2)块茎增长期, SVR 模型建模数据集中 VI_s 的 R^2 为 0.71, RMSE 为 0.15 mg/g, NRMSE 为 13.6% ,VI_s 和纹理特征相结合的 R^2 为 0.79, RMSE 为 0.13 mg/g, NRMSE 为 11.6% ,模型精度提升 13.3%。验证数据集 VI_s 的 R^2 为 0.59, RMSE 为 0.16 mg/g, NRMSE 为 16.4% ,VI_s 和纹理特征相结合的 R^2 为 0.67, RMSE 为 0.14 mg/g, NRMSE 为 14.97% ,模型精度提升 8.9%。在 KNN 模型建模数据集中 VI_s 的 R^2 为 0.48, RMSE 为 0.2 mg/g,

NRMSE 为 18.4% ,VI_s 和纹理特征相结合的 R^2 为 0.55, RMSE 为 0.18 mg/g, NRMSE 为 17.3% ,模型精度提升 10%。验证数据集 VI_s 的 R^2 为 0.73, RMSE 为 0.16 mg/g, NRMSE 为 15.2% ,VI_s 和纹理特征相结合的 R^2 为 0.74, RMSE 为 0.17, NRMSE 为 15.9% ,模型精度下降 4.3%。

(3)淀粉积累期, SVR 模型中建模数据集 VI_s 的 R^2 为 0.47, RMSE 为 0.17 mg/g, NRMSE 为 15.6% ,VI_s 和纹理特征相结合的 R^2 为 0.63, RMSE 为 0.14 mg/g, NRMSE 为 13.0% ,模型精度提升 17.6%。验证数据集 VI_s 的 R^2 为 0.62, RMSE 为 0.17 mg/g, NRMSE 为 17.6% ,VI_s 和纹理特征相结合的 R^2 为 0.70, RMSE 为 0.14 mg/g, NRMSE 为 14.7% ,模型精度提升 16.7%。KNN 模型中建模数




图4 植被指数与融合数据模型验证

Fig. 4 Vegetation index and fusion data model validation

据集 VIs 的 R^2 为 0.48, RMSE 为 0.18 $\text{mg} \cdot \text{g}^{-1}$, NRMSE 为 16.5%, VIs 和纹理特征相结合的 R^2 为 0.63, RMSE 为 0.16 $\text{mg} \cdot \text{g}^{-1}$, NRMSE 为 14.6%, 模型精度提升 11.1%。验证数据集 VIs 的 R^2 为 0.63, RMSE 为 0.14 $\text{mg} \cdot \text{g}^{-1}$, NRMSE 为 18.3%, VIs 和纹理特征相结合的 R^2 为 0.66, RMSE 为 0.13 $\text{mg} \cdot \text{g}^{-1}$, NRMSE 为 17.0%, 模型精度提升 6.4%。

3 讨论

本研究通过测量植被绿色光谱反射率和近红外光谱反射率来计算的 CIG、GDVI、GNDVI 植被指数

在 3 个时期中重要性排序都为前 10, 绿光波段对健康茂盛的植物反射敏感, 近红外波段透过率强, 估算叶片叶绿素含量效果更好^[21]。在加入的纹理特征中, 方差和均值参与建模的数量最多。使用迭代添加特征的方法, 可以观察特征加入模型精度的变化, 植被指数和纹理参数在最优叶绿素反演模型中所占比例。在 SVR 模型中, 3 个时期参与建模的植被指数数量分别为 19、16、3, 纹理数量分别为 4、2、9, R^2 由 0.58、0.68、0.51 提升至 0.65、0.72、0.65, 分别提升 13.7%、4.8%、27.3%, 在 KNN 模型中, 3 个时期参与建模的植被指数数量分别为 7、11、5, 纹理数量

分别为 3、4、7,模型 R^2 由 0.55、0.48、0.48 提升至 0.58、0.55、0.63,分别提升 6.8%、4.3%、22.6%,当植被指数模型精度低时,加入的纹理信息可以更好地提升叶绿素含量估算模型的精度。由图 3 和表 3 可知,SVR 方法构建的模型精度优于 KNN,主要原因是 SVR 利用复杂的核函数将数据映射到高维空间中,能够更好地处理数据噪声和异常值。

由结果可知,3 个生育期模型加入了纹理特征后精度均有提升,这和文献[22]的研究一致,主要原因是叶片表面的纹理结构可以改变光的入射角度和方向,从而改变叶绿素吸收光的效率,可以提高叶绿素反演的精度。在块茎形成和块茎增长期,马铃薯植株为封垄状态,植被指数可以较好地预测马铃薯冠层叶绿素含量,纹理信息的添加对模型精度提升不太明显,并且只有少数纹理信息对精度提升有积极作用。在淀粉积累期,由于干物质转移,叶片开始枯萎发黄,此时植被指数不足以很好地响应叶绿素的变化时,纹理信息作为叶绿素反演的信息补充,更多的纹理指数参与建模,并且大幅提升马铃薯叶绿素含量反演模型精度。

本研究以植被指数结合纹理特征作为模型变量,利用 SVR-REF 方法进行特征降维,分别利用 2 种机器学习方法构建马铃薯 3 个生育期的叶绿素含量估算模型,结果显示,马铃薯植被指数结合纹理在两种建模方法中精度都有所提升。这可为作物叶绿素含量状况快速检测装置的开发与集成提供参考。本研究使用无人机多光谱和 RGB 影像对马铃薯叶片叶绿素含量进行估算。旨在快速无损监测马铃薯叶片叶绿素含量。对于未来的工作,将采用高光谱

数据进行更深入地植被指数的分析,提升模型的精度。此外,后续研究中将添加更多不同类型的纹理和物候土壤等信息,以达到模型的异地迁移。

4 结论

(1)相较于单一的植被指数特征,各生育期加入纹理特征均能提升马铃薯叶片叶绿素含量的估算精度。

(2)在 SVR 模型中,3 个时期参与建模的植被指数数量分别为 19、16、3,纹理数量分别为 4、2、9, R^2 由 0.58、0.68、0.51 提升至 0.65、0.72、0.65,分别提升 13.7%、4.8%、27.3%;在 KNN 模型中,3 个时期参与建模的植被指数数量分别为 7、11、5,纹理数量分别为 3、4、7,模型 R^2 精度分别提升 6.8%、4.3%、22.6%。当植被指数模型精度低时,加入的纹理信息可以更好地提升叶绿素含量估算模型的精度。

(3)SVR 和 KNN 回归构建的马铃薯叶绿素含量估算模型中,以植被指数结合纹理特征的 SVR 模型效果最好。3 个生育期的建模 R^2 由 0.58、0.71、0.47 提升至 0.65、0.79、0.63, RMSE 由 0.2、0.16、0.17 mg/g 降低至 0.17、0.14、0.14 mg/g, NRMSE 由 17.8%、16.4%、17.6% 降至 15.3%、15.0%、14.7%。验证 R^2 由 0.60、0.59、0.62 提升至 0.70、0.67、0.69, RMSE 由 0.19、0.15、0.17 mg/g 降低至 0.17、0.13、0.14 mg/g, NRMSE 由 18.2%、13.6%、15.6% 降至 16.8%、13.3%、13.0%,表明纹理参与建模可以提升马铃薯叶绿素含量的估算。该研究为马铃薯叶绿素估算提供了种新的方法。

参 考 文 献

- [1] ZHANG H, XU F, WU Y, et al. Progress of potato staple food research and industry development in China[J]. Journal of Integrative Agriculture, 2017, 16(12): 2924-2932.
- [2] JIA J, YANG D, LI J, et al. Research and comparative analysis about potato production situation between China and continents in the world[J]. Agric. Eng., 2011, 1: 84-86.
- [3] WIJESINGHA J, DAYANANDA S, WACHENDORF M, et al. Comparison of spaceborne and UAV-borne remote sensing spectral data for estimating monsoon crop vegetation parameters[J]. Sensors, 2021, 21(8):2886.
- [4] BOHMAN B J, ROSEN C J, MULLA D J. Evaluation of variable rate nitrogen and reduced irrigation management for potato production[J]. Agronomy Journal, 2019, 111(4): 2005-2017.
- [5] LI X, LI L, LIU X. Collaborative inversion heavy metal stress in rice by using two-dimensional spectral feature space based on HJ-1 A HSI and radarsat-2 SAR remote sensing data[J]. International Journal of Applied Earth Observation and Geoinformation, 2019, 78: 39-52.
- [6] PUTRA B T W. New low-cost portable sensing system integrated with on-the-go fertilizer application system for plantation crops[J]. Measurement, 2020, 155:107562.
- [7] YANG M D, HUANG K S, KUO Y H, et al. Spatial and spectral hybrid image classification for rice lodging assessment through UAV imagery[J]. Remote Sensing, 2017, 9(6):583.
- [8] ZHUO W, WU N, SHI R, et al. UAV mapping of the chlorophyll content in a tidal flat wetland using a combination of spectral and frequency indices[J]. Remote Sensing, 2022, 14(4):827.
- [9] 刘杨, 黄珏, 孙乾, 等. 利用无人机数码影像估算马铃薯地上生物量[J]. 遥感学报, 2021, 25(9): 2004-2014.
LIU Yang, HUANG Jue, SUN Qian, et al. Estimation of potato aboveground biomass using UAV digital images[J]. Journal of

- Remote Sensing, 2021, 25(9): 2004 – 2014. (in Chinese)
- [10] 陶惠林, 徐良骥, 冯海宽, 等. 基于无人机数码影像的冬小麦株高和生物量估算[J]. 农业工程学报, 2019, 35(19): 107 – 116.
TAO Huilin, XU Liangji, FENG Haikuan, et al. Plant height and biomass estimation of winter wheat based on UAV digital image[J]. Transactions of the CSAE, 2019, 35(19): 107 – 116. (in Chinese)
- [11] LANG Q, ZHIYONG Z, LONGSHENG C, et al. Detection of chlorophyll content in maize canopy from UAV imagery[J]. IFAC-PapersOnLine, 2019, 52(30): 330 – 335.
- [12] YUE J, YANG G, TIAN Q, et al. Estimate of winter-wheat above-ground biomass based on UAV ultrahigh-ground-resolution image textures and vegetation indices[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 150: 226 – 244.
- [13] 陈鹏, 冯海宽, 李长春, 等. 无人机影像光谱和纹理融合信息估算马铃薯叶片叶绿素含量[J]. 农业工程学报, 2019, 35(11): 63 – 74.
CHEN Peng, FENG Haikuan, LI Changchun, et al. UAV image spectral and texture fusion information to estimate the chlorophyll content of potato leaves[J]. Transactions of the CSAE, 2019, 35(11): 63 – 74. (in Chinese)
- [14] SUN X, YANG Z, SU P, et al. Non-destructive monitoring of maize LAI by fusing UAV spectral and textural features[J]. Frontiers in Plant Science, 2023, 14: 1158837.
- [15] 樊意广, 冯海宽, 刘杨, 等. 利用无人机多源传感器估算马铃薯植株氮含量[J]. 光谱学与光谱分析, 2022, 42(10): 3217 – 3225.
FAN Yiguang, FENG Haikuan, LIU Yang, et al. Estimation of nitrogen content of potato plants using UAV multi-source sensors[J]. Spectroscopy and Spectral Analysis, 2022, 42(10): 3217 – 3225. (in Chinese)
- [16] FENG L, ZHANG Z, MA Y, et al. Alfalfa yield prediction using uav-based hyperspectral imagery and ensemble learning[J]. Remote Sensing, 2020, 12(12): 2080.
- [17] LICHTENTHALER H K. Chlorophylls and carotenoids: pigments of photosynthetic biomembranes [M] // Methods in Enzymology. Academic Press, 1987: 350 – 382.
- [18] QI H, WU Z, ZHANG L, et al. Monitoring of peanut leaves chlorophyll content based on drone-based multispectral image feature extraction[J]. Computers and Electronics in Agriculture, 2021, 187: 106292.
- [19] 魏鹏飞, 徐新刚, 李中元, 等. 基于无人机多光谱影像的夏玉米叶片氮含量遥感估测[J]. 农业工程学报, 2019, 35(8): 126 – 133, 335.
WEI Pengfei, XU Xingang, LI Zhongyuan, et al. Remote sensing estimation of leaf nitrogen content of summer maize based on UAV multispectral imagery[J]. Transactions of the CSAE, 2019, 35(8): 126 – 133, 335. (in Chinese)
- [20] 孙诗睿, 赵艳玲, 王亚娟, 等. 基于无人机多光谱遥感的冬小麦叶面积指数反演[J]. 中国农业大学学报, 2019, 24(11): 51 – 58.
SUN Shirui, ZHAO Yanling, WANG Yajuan, et al. Inversion of leaf area index of winter wheat based on UAV multispectral remote sensing[J]. Journal of China Agricultural University, 2019, 24(11): 51 – 58. (in Chinese)
- [21] SHEN L, GAO M, YAN J, et al. Winter wheat SPAD value inversion based on multiple pretreatment methods[J]. Remote Sensing, 2022, 14(18): 466.
- [22] ZHENG H, CHENG T, ZHOU M, et al. Improved estimation of rice aboveground biomass combining textural and spectral analysis of UAV imagery[J]. Precision Agriculture, 2018, 20(3): 611 – 629.

(上接第 170 页)

- [21] 王予琪, 宿向辉, 朱祖超. 深海采矿混输泵内流场及粗颗粒运动特性[J]. 排灌机械工程学报, 2022, 40(8): 800 – 806.
WANG Yuqi, SU Xianghui, ZHU Zuchao. Characteristics of flow field and coarse particle motion in multiphase pump for deep-sea mining[J]. Journal of Drainage and Irrigation Machinery Engineering, 2022, 40(8): 800 – 806. (in Chinese)
- [22] MAO W Y, SONG P Y, DENG Q G, et al. Numerical simulation on the performance of the vortex pump for transporting solid-liquid two-phase with light particles[J]. IOP Conference Series: Materials Science and Engineering, 2016, 129(1): 012018.
- [23] 张胜伟, 张瑞雨, 陈天佑, 等. 绿豆种子离散元仿真参数标定与排种试验[J]. 农业机械学报, 2022, 53(3): 71 – 79.
ZHANG Shengwei, ZHANG Ruiyu, CHEN Tianyou, et al. Calibration of simulation parameters of mung bean seeds using discrete element method and verification of seed-metering test[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 71 – 79. (in Chinese)
- [24] 李伟, 季磊磊, 张扬, 等. 混流泵启动过程瞬态流场的涡动力学分析[J]. 中南大学学报(自然科学版), 2018, 49(10): 2480 – 2489.
LI Wei, JI Leilei, ZHANG Yang, et al. Vortex dynamics analysis of transient flow field at starting process of mixed-flow pump[J]. Journal of Central South University (Science and Technology), 2018, 49(10): 2480 – 2489. (in Chinese)
- [25] 彭笙洋, 李正贵, 李新锐, 等. 基于涡分析的贯流式水轮机尾水管流动分析[J]. 武汉大学学报(工学版), 2020, 53(8): 679 – 685.
PENG Shengyang, LI Zhenggui, LI Xinrui, et al. Flow analysis of tubular turbine draft tube based on vortex analysis[J]. Engineering Journal of Wuhan University, 2020, 53(8): 679 – 685. (in Chinese)