

无人机成像高光谱的马铃薯地上生物量估算

刘 杨^{1, 4, 5}, 张 涵², 冯海宽^{1, 3, 5*}, 孙 乾^{1, 5}, 黄 珏⁴, 王娇娇^{1, 5}, 杨贵军^{1, 5}

1. 农业部农业遥感机理与定量遥感重点实验室, 北京农业信息技术研究中心, 北京 100097
2. University of New South Wales, Sydney NSW 2052, Australia
3. 南京农业大学国家信息农业工程技术中心, 江苏 南京 210095
4. 山东科技大学测绘科学与工程学院, 山东 青岛 266590
5. 国家农业信息化工程技术研究中心, 北京 100097

摘 要 地上生物量(AGB)的精准监测是农田生产管理的重要环节,因此快速准确地估算 AGB,对于精准农业的发展十分重要。传统上,获取 AGB的方法是采用破坏性取样法,这使得大面积、长期的测量变得困难。无人机高光谱遥感因具有机动性强、光谱分辨率高和图谱合一的优势,成为当前估算大面积作物 AGB最有效的技术手段。该研究通过无人机平台搭载成像高光谱传感器分别获取马铃薯块茎形成期、块茎增长期、淀粉积累期的冠层高光谱影像以及利用烘干称重法获取相应生育期实测 AGB数据。然后,采用相关性分析法(CAM)、随机蛙跳算法(RFM)和高斯过程回归波长分析工具(GPR-BAT)分别筛选冠层原始光谱(COS)和一阶导数光谱(FDS)的敏感波长,结合偏最小二乘回归(PLSR)和高斯过程回归(GPR)构建各生育期的 AGB估算模型,并对比不同模型的估测效果。结果显示:(1)基于同种方法分别筛选 COS和FDS的特征波长,结合2种回归技术估算 AGB的效果均从块茎形成期到淀粉积累期由好变差。(2)基于FDS分别通过3种方法筛选的特征波长,通过同种回归技术构建的模型效果要优于基于COS的相应效果。(3)基于COS和FDS使用CAM,RFM和GPR-BAT方法筛选的特征波长个数在块茎形成期分别为28,12,6个和12,23,10个,在块茎增长期分别为32,8,2个和18,28,4个,在淀粉积累期分别为30,15,3个和21,33,5个。(4)各生育期基于COS和FDS通过3种方法筛选的敏感波长估算 AGB效果由高到低依次均为GPR-BAT,RFM和CAM。(5)各生育期基于FDS通过GPR-BAT方法筛选的敏感波长,结合PLSR建立的模型精度更高、稳定性更强, R^2 分别为0.67,0.73和0.65,NRMSE分别为16.63%,15.84%和20.81%。研究表明利用无人机高光谱成像技术可以准确地估算 AGB,这为实现马铃薯作物长势动态监测,提供科学指导和参考。

关键词 马铃薯;无人机;成像高光谱;随机蛙跳;高斯过程回归;地上生物量

中图分类号: S25 **文献标识码:** R **DOI:** 10.3964/j.issn.1000-0593(2021)09-2657-08

引 言

地上生物量(above ground biomass, AGB)是评估作物营养状况和长势情况的重要理化参数,与品质和产量有着密切联系,及时准确地估算 AGB有助于提高农田生产管理和作物监测水平^[1]。传统的 AGB测量方法需要人工破坏性取样,虽能达到较高精度,但过程复杂,费时费力,无法满足大面积应用需求。然而,遥感技术通过远距离、非接触式探测目

标的电磁波特性,为无损高通量估算作物 AGB提供了有效途径。无人机高光谱遥感虽传感器价格昂贵,数据后续处理复杂,但因具有操作灵活、图谱合一和光谱分辨率高等优势,在农情监测和产量预测等方面得到广泛关注^[2]。

近年来国内外学者应用高光谱成像技术监测作物 AGB,取得了一定的研究进展。如 Yue等^[3]基于冬小麦冠层光谱数据构建多种植被指数,结合不同的回归技术有效地估算作物多生育 AGB。Tao等^[4]利用相关性分析法(correlation analysis method, CAM)筛选出与冬小麦 AGB敏感的光亲指数和

收稿日期:2021-04-08,修订日期:2021-06-28

基金项目:广东省重点领域研发计划项目(2019B020216001),国家自然科学基金项目(41601346)资助

作者简介:刘 杨,1994年生,北京农业信息技术研究中心实习研究员 e-mail:liuyanghe810@163.com

* 通讯作者 e-mail:fenghaikuan123@163.com

红边参数,使用 2 种回归方法准确地评价作物长势情况。Kanke 等^[5]分析了红和红边波段组成的植被指数与水稻 AGB 的定量关系,最终确定了较好估算 AGB 的敏感光谱波段。刘斌等^[6]研究高光谱数据任意两波段构建的 NDVI 与冬小麦 AGB 的相关关系,通过比较模型间的精度,得出估算 AGB 最优中心波段和波段宽度。陶惠林等^[7]基于无人机高光谱数据构建的多种植被指数和提取的红边参数,采用多元线性回归方法估算冬小麦多生育期 AGB,结果表明加入红边参数信息能够较好地改善模型精度。石雅娇等^[8]基于玉米冠层高光谱数据构建敏感植被指数,结合 BP 神经网络估算玉米 AGB,建模的决定系数达到 0.99,估测效果极好。这些研究成果表明,通过光谱分析技术能够很好地估测冬小麦、水稻和玉米等作物 AGB,然而马铃薯植株形态结构与上述作物存在显著差异,且在作物养分吸收、输送和转移等方面表现也明显不同。前期地下营养物质往地上供应,促进植株茎叶生长,而后期地上生殖器官光合作用积累的有机物向地下块茎转移,促进果实膨大,整个生育期 AGB 值呈现先升高后降低的变化趋势,故已有的其他作物 AGB 监测成果无法在马铃薯作物上直接应用。

目前,马铃薯作物多生育期的长势动态监测,主要集中在冠层氮素含量、叶面积指数、叶绿素和叶片含水量的估测研究。如 Liu 等^[9]基于马铃薯冠层高光谱影像,使用偏最小二乘回归(partial leastsquares regression, PLSR)分别结合全谱、可见光—近红外和短波红外的光谱反射率估算氮素含量,结果表明利用全谱波段信息构建的模型效果较好。Luo 等^[10]从马铃薯冠层高光谱数据中提取不同类型的光谱参数,分别结合一元回归技术估算不同水分条件的叶面积指数,结果表明水分饱和条件下使用深度面积比指数估算精度最高。孙红等^[11-12]基于马铃薯冠层高光谱影像,通过 CAM 和随机蛙跳算法(random frog algorithm, RFM)分别挑选出与叶绿

素和叶片含水量相关的特征波长,结合 PLSR 方法有效地实现马铃薯理化参数的反演。

这些研究成果对马铃薯作物监测有一定的参考和应用价值,但是,针对马铃薯多生育期 AGB 的估测研究,鲜有报道。因此,为了探究生长过程中 AGB 的动态光谱响应机制,本研究采用无人机成像高光谱技术获取不同生育期的马铃薯冠层影像,同时为了减少全谱数据的冗余度和增强模型的稳定性,通过 CAM,RFM 和高斯过程回归波长分析工具(Gaussian process regression-band analysis tool, GPR-BAT)分别对冠层原始光谱(canopy original spectra, COS)和一阶导数光谱(first derivative spectra, FDS)筛选敏感波长,结合使用 PLSR 和 GPR 方法建立 AGB 估算模型,从而确定估算 AGB 的最佳波长和最优反演模型,以期通过无人机高光谱遥感快速无损地监测马铃薯长势情况以及分析 AGB 含量提供方法依据。

1 实验部分

1.1 试验设计

试验地点位于北京市昌平区小汤山镇国家精准农业研究示范基地,地处北纬 $40^{\circ}10'35''$,东经 $116^{\circ}26'40''$ 。马铃薯种植试验为小区完全随机试验设计,共设计密度试验(N区)、氮素试验(S区)、钾肥试验(K区)3个试验区。试验品种采用早熟的中薯5(Z5)和中薯3(Z3),每个品种进行相同的控制试验,每种试验重复3次,每种重复进行不同程度的密度(T1, T2 和 T3)、氮素和钾肥处理,其中密度、氮素和钾肥具体处理详情见文献[1]。小区总计 48 个,每个小区面积为 32.5 m^2 。为了更精准地获取试验田的位置,在试验小区周围均匀布控 11 个地面控制点(G1—G11),并用差分 GPS 测定其三维空间位置,详细的试验设计见图 1 所示。

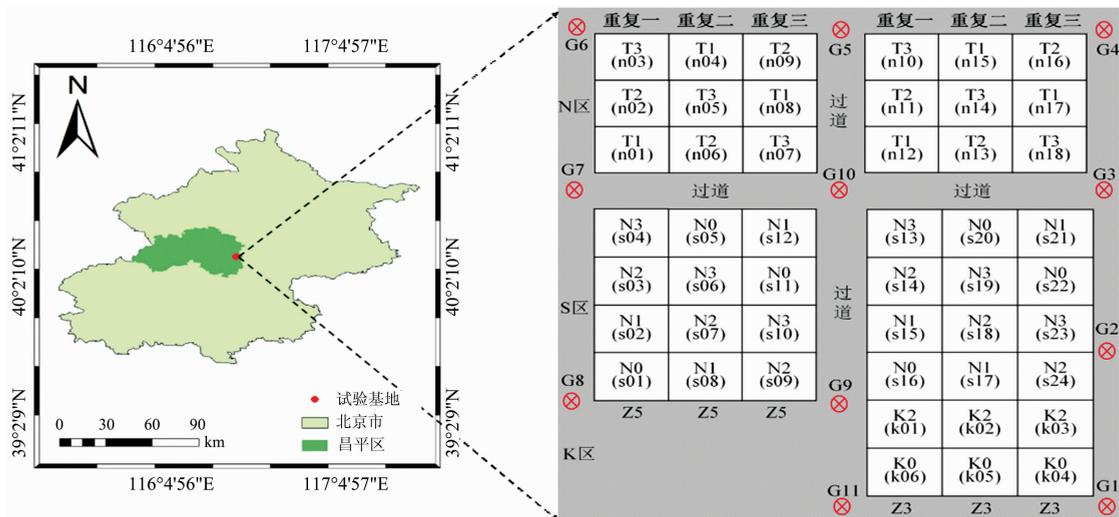


图 1 试验区域和试验设计

Fig. 1 Experimental area and experimental design

1.2 无人机高光谱影像采集及处理

采用八旋翼电动无人机搭载德国 Cubert 公司生产的

UHD185 成像光谱仪(波长范围为 $450\sim 950\text{ nm}$,光谱分辨率 4 nm ,共有 125 个光谱通道,光谱采集时保证仪器垂直向

下),分别在 2019 年 5 月 28 日(块茎形成期)、2019 年 6 月 10 日(块茎生长期)和 2019 年 6 月 20 日(淀粉积累期)进行高光谱遥感作业。各时期飞行时间为 12:00—13:00,此时天空晴朗,无风无云,飞行高度为 50 m,获得的影像空间分辨率为 13 cm。每次无人机采集数据前,需要在地面利用黑板进行高光谱影像辐射校正。

高光谱数据预处理过程主要包括两个部分:(1)影像拼接和几何地形纠正,首先使用 Cuber 公司生产的 Cuber-Pilot 软件融合航带内的灰度影像和高光谱影像,进而形成新的融合后的高光谱影像;其次通过 PhotoScan 软件利用地面控制点的位置信息进行影像地形校正,各时期的校正误差均小于 2 cm;最后基于高密度点云数据完成影像拼接,生成马铃薯 3 个生育期的数字正射影像(DOM)和数字表面模型(DSM)。(2)提取冠层光谱反射率,在 ArcGIS 软件中根据各小区的最大面积矢量数据,通过 IDL 语言提取出各小区平均光谱,将平均光谱反射率作为不同小区冠层光谱反射率。

1.3 地面数据采集及处理

地面数据采集与无人机高光谱遥感作业同步进行,每个生育期共获取 48 组实测 AGB 数据,具体采集过程见文献[2]。

1.4 特征波段筛选方法

为了降低光谱数据的冗余度,提高模型的稳定性和预测能力,使用相关性分析法(CAM)、随机蛙跳算法(RFM)和高斯过程回归波长分析工具(GPR-BAT)分别对马铃薯 3 个生育期的冠层原始光谱(COS)和一阶导数光谱(FDS)进行特征波长筛选。CAM 是数据分析过程中最为常用的敏感波长筛选方法,根据相关系数的大小决定建模的个数和最优模型参数。RFM 是一种类似于可逆跳转马尔科夫链蒙特卡洛的变量选择方法,通过迭代的方式计算变量在每次迭代过程中被选择的概率,根据概率值的高低来评价变量的重要性[12]。GPR-BAT 通过光谱数据依次迭代,去除对模型贡献最小的波长,采用 10 折交叉验证法进行模型内部验证,基于交叉验证均方根误差 RMSECV 的最小值来确定最优特征波长数。CAM 在 Excel2019 软件中进行,RFM 和 GPR-BAT 在 Matlab R2020b 软件中进行。

1.5 建模方法

PLSR 是解决模型参数共线性问题最为常用的方法,在数据拟合过程中通过对光谱反射率矩阵和 AGB 含量矩阵同时分解,提取最佳主成分后,将二者进行关联,建立线性的回归模型,从而达到估算 AGB 的目的[12]。GPR 是一种非参数概率统计模型,基于贝叶斯定理来学习自变量和因变量之间的关系,利用均值和协方差函数根据最大似然估计法来训练样本,可以提供预测及其相关的置信区间,这能够评估预测结果的可靠性。与常规机器学习法相比,参数优化更简单,更适合训练小样本数据,最大的优势在于能够通过 GPR-BAT 工具箱自动识别最佳光谱特征[13]。

1.6 精度评价

选取 67% 样本数据(32 个,重复一和重复二)作为建模集,33% 样本数据(16 个,重复三)作为验证集,利用 PLSR 和 GPR 方法构建各生育期马铃薯 AGB 估算模型。为了评估

不同模型的拟合效果和稳定性,采用决定系数 R^2 、均方根误差 RMSE 和标准均方根误差 NRMSE 作为精度评价指标。 R^2 越高, RMSE 和 NRMSE 越低,构建的模型精度就越高。

2 结果与讨论

2.1 马铃薯冠层高光谱反射率曲线

通过标准正态变量(standard normal variable, SNV)校正方法对马铃薯各生育期获取的冠层高光谱数据进行修正,以此减少背景噪声、地物纹理等多种因素对光谱反射率的影响[11]。以块茎生长期为例, n13—n15, s17—s20, k02 和 k05 小区经过 SNV 处理后的冠层原始光谱曲线如图 2 所示。由图可知,马铃薯冠层反射率曲线符合绿色植被特征,在 450 和 650 nm 附近存在吸收谷,而在 550 nm 附近存在小的反射峰。由于叶肉细胞结构的影响,在 680~750 nm 范围内,光谱反射率急剧增加,形成植物特有的红边特征。对处理后的光谱反射率进行一阶微分,以及利用 CAM, RFM 和 GPR-BAT 筛选与 AGB 相关的敏感波长。

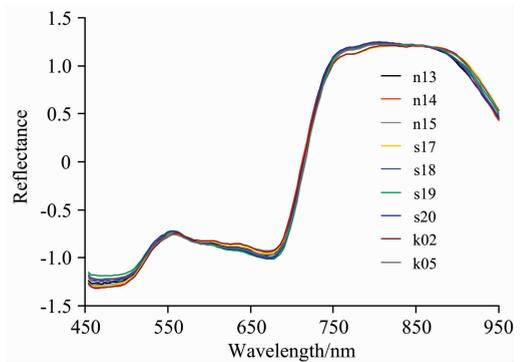


图 2 马铃薯块茎生长期经 SNV 处理后的光谱反射率曲线
Fig. 2 Spectral reflectance curves treated with SNV during potato tubergrow period

2.2 CAM 筛选特征波长

将马铃薯 3 个生育期的 COS 和 FDS 分别与 AGB 作相关性分析,得到结果如图 3 所示。为了避免边界波长震荡效应的影响,只对 458~946 nm 波段范围作进一步研究。以各生育期的相关系数绝对值由大到小依次排列,基于 COS 和 FDS 块茎形成期分别筛选出相关系数大于 0.7 的特征波长总数为 28 个和 12 个,块茎生长期分别筛选出相关系数大于 0.7 的特征波长总数为 32 个和 18 个,淀粉积累期基于 COS 筛选出相关系数大于 0.7 的特征波长总数为 30 个,基于 FDS 筛选出相关系数大于 0.6 的特征波长总数为 21 个。各生育期使用 CAM 得到的具体模型参数见表 1 所示。

2.3 RFM 筛选特征波长

在 MatlabR2020b 软件中,设置 RFM 初始变量个数为 2 个,迭代次数 10 000 次,运行结果如图 4 所示。马铃薯 3 个生育期基于 COS 和 FDS 选择概率值大于 0.2 的变量为特征波长,块茎形成期选择的特征波长数分别为 12 个和 23 个,块茎生长期对应为 8 个和 28 个,淀粉积累期对应为 15 个和 33 个。各生育期使用 RFM 得到的具体模型参数见表 2 所示。

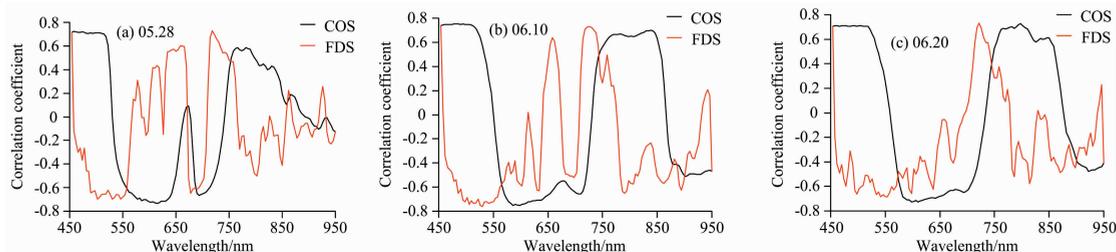


图 3 马铃薯各生育期 COS 和 FDS 与 AGB 的相关系数图

Fig. 3 Correlation coefficient diagrams of COS and FDS with AGB during each growth period of potato

表 1 各生育期基于 FDS 和 COS 使用 CAM 筛选的敏感波长

Table 1 The sensitive wavelengths selected by CAM based on FDS and COS during each growth period

生育期	COS/nm	FDS/nm
块茎形成期	458~514, 586~634	502, 506, 530~538, 542~554, 714~722
块茎增长期	458~518, 578~638	494~498, 506~518, 526~550, 718~730
淀粉积累期	458~518, 590~626, 790~802	494~506, 530~566, 594~598, 638, 718~730

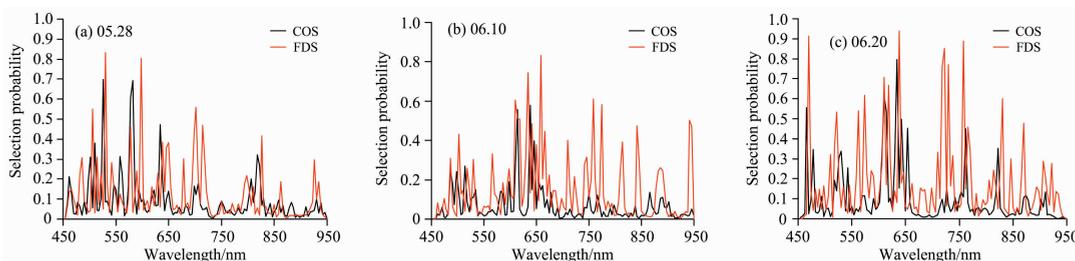


图 4 马铃薯各生育期 COS 和 FDS 的变量选择概率

Fig. 4 Variable selection probabilities of COS and FDS during each growth period of potato

表 2 各生育期基于 FDS 和 COS 使用 RFM 筛选的敏感波长

Table 3 The sensitive wavelengths were selected by RFM based on FDS and COS during each growth period

生育期	COS/nm	FDS/nm
块茎形成期	462, 502, 510, 526, 558, 562, 578, 582, 634, 806, 818, 822	482~486, 506, 514, 522, 530, 542, 578, 590, 598, 630, 638, 646~650, 678, 698, 702~706, 714~718, 798, 826, 926
块茎增长期	486, 498, 514, 610~614, 648, 646, 654	486, 502, 518, 598, 610~618, 630~634, 642, 658, 666, 710, 722, 742~746, 758~762, 774, 810~814, 842~846, 882~890, 942~946
淀粉积累期	466, 478, 526~530, 542, 606~614, 630~634, 642~646, 654, 762, 822	470, 510, 518, 522~526, 558~562, 574~578, 586~590, 606~610, 618~622, 638, 646, 710, 718~722, 738, 758, 766~770, 814, 826~830, 846, 866~870, 906, 910, 922

2.4 GPR-BAT 筛选特征波长

通过 ARTMO 软件中 MLRA 模块的 GPR-BAT 对马铃薯 3 个生育期的 COS 和 FDS 作敏感性分析, 各生育期进行内部交叉验证的平均 RMSECV、标准差 SD 以及 min-max 极值范围见图 5 所示。根据 RMSECV 的最小值确定估算 AGB 的特征波长, 块茎形成期, 基于 COS 和 FDS 筛选的敏感波长个数分别为 6 个和 10 个, 块茎增长期分别为 2 个和 4 个, 淀粉积累期分别为 3 个和 5 个。各生育期使用 GPR-BAT 得到的具体模型参数见表 3 所示。

2.5 构建 AGB 估算模型

将通过 CAM, RFM 和 GPR-BAT 基于 COS 和 FDS 筛选的敏感波长作为自变量, 马铃薯 AGB 作为因变量, 分别

使用 PLSR 和 GPR 方法构建各生育期的 AGB 估算模型, 各模型的精度评价指标见表 4 和表 5 所示。由表可知, 基于不同冠层光谱数据, 各生育期通过 3 种方法筛选的敏感波长, 利用 PLSR 和 GPR 建立的模型效果表现一致, 均从块茎形成期到淀粉积累期由好变差, 其中各生育期基于 FDS 得到的模型变量估算 AGB 精度更高, 模型较为稳定。基于同种冠层光谱数据, 通过 GPR-BAT 筛选的敏感波长使用 2 种方法估算 AGB 的效果最优, 其次为 RFM, 而通过 CAM 筛选的特征波长估算效果最差。基于不同方法对 COS 和 FDS 筛选的敏感波长, 各生育期以相同变量使用 PLSR 构建的 AGB 估算模型效果优于相应地 GPR-AGB 估算模型。基于 COS 通过 GPR-BAT 筛选的特征波长, 使用 PLSR 方法估算 AGB,

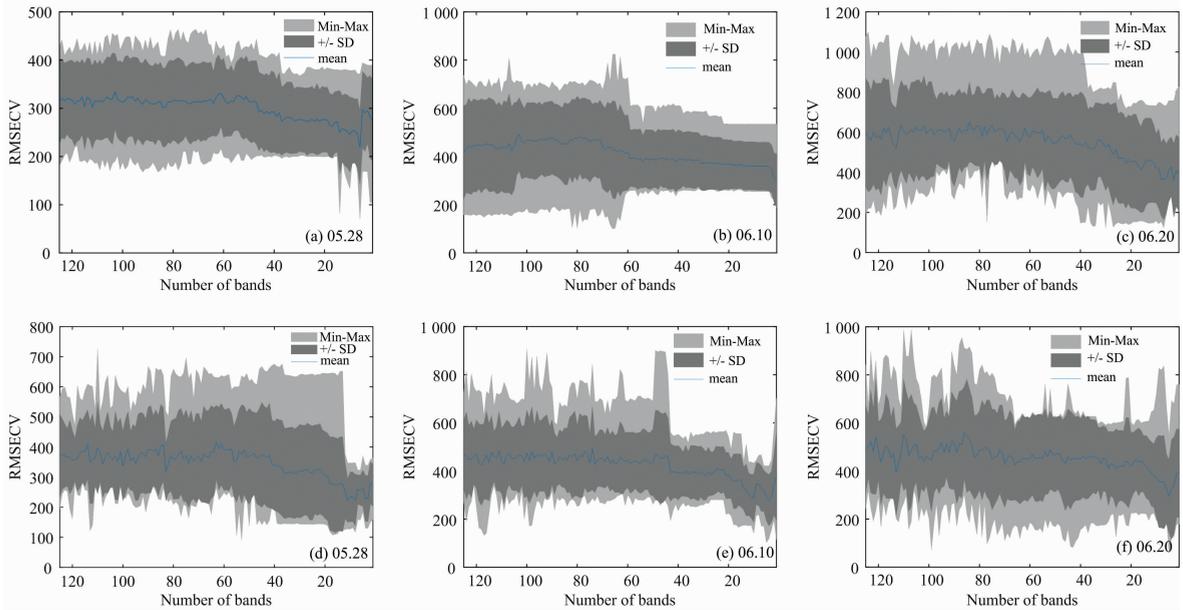


图 5 马铃薯各生育期使用 COS(上)和 FDS(下)的交叉验证图

Fig. 5 Cross validation maps of using COS (upper) and FDS (lower) during each growth period of potato

表 3 各生育期基于 FDS 和 COS 使用 GPR-BAT 筛选的敏感波长

Table 3 The sensitive wavelengths were selected by GPR-BAT based on FDS and COS during each growth period

生育期	COS/nm	FDS/nm
块茎形成期	626, 642, 778, 822, 846, 938	482, 494, 526, 530, 534, 586, 602, 686, 702, 914
块茎增长期	598, 710	658, 666, 774, 782
淀粉积累期	582, 798, 822	550, 722, 726, 734, 866

建模 R^2 从块茎形成期到淀粉积累期的变化范围为 0.62~0.71, RMSE 变化范围为 211.03~307.31 $\text{kg} \cdot \text{hm}^{-2}$, NRMSE 变化范围为 16.37%~21.18%, 验证结果与建模结果保持一致, R^2 越大, RMSE 和 NRMSE 值越小; 而使用 GPR 方法建模 R^2 相对较小, 变化范围为 0.61~0.67, RMSE 和 NRMSE 值相对较大, 变化范围分别为 228.30~321.82 $\text{kg} \cdot \text{hm}^{-2}$ 和 17.71%~22.18%, 验证效果与建模结果一致, R^2 越小, RMSE 和 NRMSE 值越大。基于 FDS 通过 GPR-BAT 筛选的特征波长, 使用 PLSR 方法估算 AGB 效果最佳, 块茎形成期到淀粉积累期建模 R^2 从 0.65 变化到 0.73, RMSE 从 203.07 $\text{kg} \cdot \text{hm}^{-2}$ 变化到 301.95 $\text{kg} \cdot \text{hm}^{-2}$, NRMSE 从 15.84%~20.81%, 验证 R^2 也是先增大后减小, RMSE 和 NRMSE 值都是先减小后增大; 使用 GPR 方法估算 AGB 的建模 R^2 相应地从 0.62 变化到 0.69, RMSE 从 216.95 $\text{kg} \cdot \text{hm}^{-2}$ 变化到 306.30 $\text{kg} \cdot \text{hm}^{-2}$, NRMSE 从 16.83% 变化到 21.11%, 验证 R^2 , RMSE 和 NRMSE 的变化趋势与建模结果相同, R^2 先增大后减小, RMSE 和 NRMSE 先减小后增大。

以往研究通过无人机成像高光谱技术估算作物 AGB, 大多利用全谱数据构建光谱指数并结合不同的回归技术实现

AGB 含量监测, 但是这样会增加模型的复杂性和降低运算效率。为解决这一问题, 本研究通过 CAM, RFM 和 GPR-BAT3 种方法对马铃薯各生育期的 COS 和 FDS 分别作敏感性分析, 从而筛选特征波长结合 PLSR 和 GPR 构建 AGB 反演模型。结果显示, 3 个生育期构建的模型中, 块茎增长期以不同变量使用同种方法建立的估算模型精度均高于其他生育期, 这是因为马铃薯植株从块茎形成期开始, 由原来的营养生长转变为生殖生长和物质积累, 地上茎叶逐渐发育完善, 到了块茎增长期, 茎叶生长速度、叶面积指数和茎叶鲜重达到峰值, 此时植被覆盖度最大, 提取冠层光谱反射率时不易受到地面土壤的干扰, 随后由于地上同化的有机物向地下块茎输送, 造成地上茎叶因营养匮乏而枯黄脱落, 此时马铃薯作物长势变差, 间接提取的光谱反射率包括大量的裸土像元, 因此参与建模的变量不能真实反映 AGB 的实际情况。

各生育期分别用基于 COS 和 FDS 通过 RFM 方法筛选的特征波长来估算 AGB 的效果要优于相应地 CAM 方法, 这是因为 RFM 方法筛选的特征波长间隔大, 跨度广, 包含信息量丰富, 模型变量自相关性较弱, 因此构建的模型精度较高、稳健性较强, 这与孙红等^[11-12]估算马铃薯叶片叶绿素和含水量结论一致, 但本研究利用 RFM 和 CAM 方法筛选的敏感波长来估算 AGB 的精度较低, 主要原因其一可能是估算的理化参数不同, 其二是传感器类型和数据获取场景不同, 本研究通过无人机平台搭载 UHD185 成像光谱仪在田间获取数据, 而孙红等研究在封闭实验室载物台通过 Gaia 高光谱成像系统获取数据, 其三是本研究对马铃薯冠层群体植株进行 AGB 监测, 而孙红等仅以单个叶片为目标实现作物参数估算。为了验证通过利用 GPR-BAT 筛选敏感波长来估算 AGB 的效果, 同样对 COS 和 FDS 作敏感性分析, 结果发现, 各生育期基于 GPR-BAT 筛选波长运行效率较低, 但得到的特征波长个数少, 使用 PLSR 和 GPR 建模方法估算

AGB 效果更优, 这一结论与 Fu 等^[13] 研究冬小麦氮素情况相一致, 也表明 GPR-BAT 筛选的敏感波长与作物理化参数联系更紧密。基于同种变量, 各生育期利用 PLSR 方法构建的模型精度更高, 这与 Tao 等^[4] 估算冬小麦多生育期 AGB 结果一致, 这主要与其自身处理光谱数据能力相关, 可以较好地解决变量间的多重共线性问题, 使得能够准确地估算作物

理化参数^[1-2]。综上所述, GPR-BAT 筛选的敏感波长在符合 AGB 含量与光谱反射率变化的规律前提下, 可结合 PLSR 方法使用较少波长来预测各生育期 AGB, 以达到准确监测的目的。但是, 本研究并未考虑不同水分灌溉下, 基于马铃薯冠层光谱筛选的敏感波长对 AGB 监测结果的影响, 需要在未来的研究中进行深入探究。

表 4 基于 COS 使用 PLSR 和 GPR 估算 AGB 的建模和验证精度

Table 4 Modeling and verification accuracies of estimating AGB based on COS by PLSR and GPR

生育期	模型变量	PLSR						GPR					
		建模			验证			建模			验证		
		R^2	RMSE/ ($\text{kg} \cdot \text{hm}^{-2}$)	NRMSE/ %	R^2	RMSE/ ($\text{kg} \cdot \text{hm}^{-2}$)	NRMSE/ %	R^2	RMSE/ ($\text{kg} \cdot \text{hm}^{-2}$)	NRMSE/ %	R^2	RMSE/ ($\text{kg} \cdot \text{hm}^{-2}$)	NRMSE/ %
块茎形成期	CAM	0.61	240.68	19.71	0.64	191.49	18.81	0.58	259.24	21.23	0.59	209.62	20.59
	RFM	0.63	223.22	18.28	0.65	179.89	17.67	0.60	247.27	20.25	0.61	202.39	19.88
	GPR-BAT	0.64	215.16	17.62	0.67	172.46	16.94	0.62	237.87	19.48	0.64	190.98	18.76
块茎增长期	CAM	0.65	236.16	18.32	0.66	165.17	18.19	0.62	253.44	19.66	0.63	172.98	19.05
	RFM	0.68	221.21	17.16	0.70	152.82	16.83	0.64	239.38	18.57	0.66	161.27	17.76
	GPR-BAT	0.71	211.03	16.37	0.72	144.47	15.91	0.67	228.30	17.71	0.68	150.65	16.59
淀粉积累期	CAM	0.58	338.80	23.35	0.60	195.14	22.62	0.55	348.96	24.05	0.57	203.68	23.61
	RFM	0.61	319.65	22.03	0.63	187.55	21.74	0.59	338.22	23.31	0.60	194.19	22.51
	GPR-BAT	0.62	307.31	21.18	0.64	176.51	20.46	0.61	321.82	22.18	0.62	182.55	21.16

表 5 基于 FDS 使用 PLSR 和 GPR 估算 AGB 的建模和验证精度

Table 5 Modeling and verification accuracies of estimating AGB based on FDS by PLSR and GPR

生育期	模型变量	PLSR						GPR					
		建模			验证			建模			验证		
		R^2	RMSE/ ($\text{kg} \cdot \text{hm}^{-2}$)	NRMSE/ %	R^2	RMSE/ ($\text{kg} \cdot \text{hm}^{-2}$)	NRMSE/ %	R^2	RMSE/ ($\text{kg} \cdot \text{hm}^{-2}$)	NRMSE/ %	R^2	RMSE/ ($\text{kg} \cdot \text{hm}^{-2}$)	NRMSE/ %
块茎形成期	CAM	0.64	233.11	19.09	0.66	182.03	17.88	0.60	250.57	20.52	0.62	200.96	19.74
	RFM	0.65	214.42	17.56	0.68	177.44	17.43	0.63	235.43	19.28	0.64	189.25	18.59
	GPR-BAT	0.67	203.07	16.63	0.70	161.05	15.82	0.65	231.89	18.99	0.68	179.99	17.68
块茎增长期	CAM	0.69	232.17	18.01	0.71	162.18	17.86	0.65	250.47	19.43	0.67	167.90	18.49
	RFM	0.71	214.89	16.67	0.72	140.47	15.47	0.68	235.26	18.25	0.69	159.18	17.53
	GPR-BAT	0.73	204.19	15.84	0.75	134.66	14.83	0.69	216.95	16.83	0.72	153.55	16.91
淀粉积累期	CAM	0.61	331.55	22.85	0.63	185.74	21.53	0.57	342.14	23.58	0.59	196.52	22.78
	RFM	0.64	305.72	21.07	0.66	180.48	20.92	0.61	329.66	22.72	0.63	184.96	21.44
	GPR-BAT	0.65	301.95	20.81	0.67	166.15	19.26	0.62	306.30	21.11	0.64	175.56	20.35

3 结 论

(1) 基于 COS 和 FDS 使用 CAM, RFM 和 GPR-BAT 方法筛选的特征波长个数在块茎形成期分别为 28, 12, 6 个和 12, 23, 10 个, 在块茎增长期分别为 32, 8, 2 个和 18, 28, 4 个, 在淀粉积累期分别为 30, 15, 3 个和 21, 33, 5 个。

(2) 在相同条件下, 各生育期基于 FDS 筛选的敏感波长相比于基于 COS 筛选的敏感波长更能准确估算 AGB。

(3) 各生育期通过 GPR-BAT 筛选的特征波长估算 AGB

效果最优, 其次为 RFM 方法, 而 CAM 方法筛选的特征波长估算效果最差。

(4) 各生育期基于 FDS 通过 GPR-BAT 筛选敏感波长, 并结合 PLSR 方法建立的模型精度更高, 块茎形成期建模 R^2 , RMSE 和 NRMSE 分别为 0.67, 203.07 $\text{kg} \cdot \text{hm}^{-2}$ 和 16.63%, 块茎增长期建模 R^2 , RMSE 和 NRMSE 分别为 0.73, 204.19 $\text{kg} \cdot \text{hm}^{-2}$ 和 15.84%, 淀粉积累期建模 R^2 , RMSE 和 NRMSE 分别为 0.65, 301.95 $\text{kg} \cdot \text{hm}^{-2}$ 和 20.81%。

References

- [1] LIU Yang, FENG Hai-kuan, HUANG Jue, et al(刘 杨, 冯海宽, 黄 珏, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2020, 36(23): 181.
- [2] LIU Yang, FENG Hai-kuan, HUANG Jue, et al(刘 杨, 冯海宽, 黄 珏, 等). Transactions of the Chinese Society for Agricultural Machinery(农业机械学报), 2021, 52(2): 188.
- [3] Yue J B, Feng H K, Yang G J, et al. Remote Sensing, 2018, 10(2): 66.
- [4] Tao H L, Feng H K, Xu L J, et al. Sensors, 2020, 20(5): 1296.
- [5] Kanke Y, Tubana B, Dalen M, et al. Precision Agriculture, 2016, 17(5): 507.
- [6] LIU Bin, REN Jian-qiang, CHEN Zhong-xin, et al(刘 斌, 任建强, 陈仲新, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2016, 32(16): 125.
- [7] TAO Hui-lin, FENG Hai-kuan, XU Liang-ji, et al(陶惠林, 冯海宽, 徐良骥, 等). Jiangsu Journal of Agricultural Sciences(江苏农业学报), 2020, 36(5): 1154.
- [8] SHI Ya-jiao, CHEN Peng-fei(石雅娇, 陈鹏飞). Chinese Agricultural Science Bulletin(中国农学通报), 2019, 35(17): 117.
- [9] Liu N F, Townsend P A, Naber M R, et al. Remote Sensing of Environment, 2021, 255(3): 112303.
- [10] Luo S J, He Y B, Li Q, et al. Journal of Applied Remote Sensing, 2020, 14(1): 1.
- [11] SUN Hong, ZHENG Tao, LIU Ning, et al(孙 红, 郑 涛, 刘 宁, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2018, 34(1): 149.
- [12] SUN Hong, LIU Ning, WU Li, et al(孙 红, 刘 宁, 吴 莉, 等). Spectroscopy and Spectral Analysis(光谱学与光谱分析), 2019, 39(3): 910.
- [13] Fu Y Y, Yang G J, Li Z H, et al. Remote Sensing, 2020, 12(22): 3778.

Estimation of Potato Above Ground Biomass Based on Hyperspectral Images of UAV

LIU Yang^{1,4,5}, ZHANG Han², FENG Hai-kuan^{1,3,5*}, SUN Qian^{1,5}, HUANG Jue⁴, WANG Jiao-jiao^{1,5}, YANG Gui-jun^{1,5}

1. Key Laboratory of Quantitative Remote Sensing in Agriculture, Ministry of Agriculture, Beijing Research Center for Information Technology in Agriculture, Beijing 100097, China
2. University of New South Wales, Sydney NSW 2052, Australia
3. National Information Agriculture Engineering Technology Center of Nanjing Agricultural University, Nanjing 210095, China
4. College of Surveying Science and Engineering, Shandong University of Science and Technology, Qingdao 266590, China
5. National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China

Abstract Accurate monitoring of above-ground biomass (AGB) is an important part of farm production management, so rapid and accurate estimation of AGB is important for the development of precision agriculture. Traditionally, AGB has been obtained using destructive sampling methods, which makes large-area, long-term measurements difficult. However, with the advancement of science and technology, UAV hyperspectral remote sensing has become the most effective technical means to estimate AGB of large crops because of its advantages of high mobility, high spectral resolution and map integration. In this study, the canopy hyperspectral images and actual AGB data of potato tuber formation, tuber growth and starch accumulation stages were obtained by carrying imaging spectrometer sensors on the UAV platform and drying and weighing method, respectively. Correlation analysis method (CAM), random frog method (RFM) and Gaussian process regression bands analysis tool (GPR-BAT) were used to screen canopy original spectra (COS) and first-order derivative spectra (FDS) for sensitive wavelengths, respectively, combined with partial least squares regression (PLSR) and Gaussian process regression (GPR) techniques to establish AGB estimation models for each fertility period and the estimation effects of different models were compared. The results showed that (1) the effect of combining the two regression techniques based on the characteristic wavelengths screened by the same method for COS and FDS to estimate AGB all changed from good to bad from the tuber formation stage to the starch accumulation stage. (2) Based on the characteristic wavelengths screened by the three methods of FDS respectively, the models constructed by homogeneous regression techniques are more effective than those based on COS accordingly. (3) The number of characteristic wavelengths screened based on COS and FDS using CAM, RFM and GPR-BAT

methods were 28, 12, 6 and 12, 23, 10 at the tuber formation stage, 32, 8, 2 and 18, 28, 4 at the tuber growth stage, and 30, 15, 3 and 21, 33, 5 at the starch accumulation stage, respectively. (4) The effect of sensitive wavelengths for AGB estimation based on COS and FDS screened by three methods at each reproductive stage were GPR-BAT, RFM and CAM in descending order. (5) The models based on sensitive wavelengths screened by FDS through the GPR-BAT method at each fertility stage combined with PLSR were more accurate and stable with R^2 of 0.67, 0.73 and 0.65, NRMSE of 16.63%, 15.84% and 20.81%, respectively. This study shows that AGB can be accurately estimated using UAV hyperspectral imaging technology, which provides scientific guidance and reference for achieving dynamic monitoring of potato crop growth.

Keywords Potato; UAV; Imaging hyperspectral; Random frog; Gaussian process regression; Above-ground biomass

* Corresponding author

(Received Apr. 8, 2021; accepted Jun. 28, 2021)

欢迎投稿

欢迎订阅

欢迎刊登广告

《光谱学与光谱分析》2022年征订启事

国内邮发代码：82-68

国外发行代码：M905

《光谱学与光谱分析》1981年创刊，国内统一刊号：CN 11-2200/O4，国际标准刊号：ISSN 1000-0593，CODEN码：GYGFED，国内外公开发行，大16开本，332页，月刊；是中国科协主管，中国光学学会主办，钢铁研究总院、中国科学院物理研究所、北京大学、清华大学共同承办的学术性刊物。北京大学出版社出版，每期售价95元，全年1140元。刊登主要内容：激光光谱测量、红外、拉曼、紫外、可见光谱、发射光谱、吸收光谱、X射线荧光光谱、激光显微光谱、光谱化学分析、国内外光谱化学分析领域内的最新研究成果、开创性研究论文、学科发展前沿和最新进展、综合评述、研究简报、问题讨论、书刊评述。

《光谱学与光谱分析》适用于冶金、地质、机械、环境保护、国防、天文、医药、农林、化学化工、商检等各领域的科学研究单位、高等院校、制造厂家、从事光谱学与光谱分析的研究人员、高校有关专业的师生、管理干部。

《光谱学与光谱分析》为我国首批自然科学核心期刊，中国科协优秀科技期刊，中国科协择优支持基础性、高科技学术期刊，中国科技论文统计源刊，“中国科学引文数据库”，“中国物理文摘”，“中国学术期刊文摘”，同时被国内外的CJCR, CNKI, CSCD, SCI, AA, CA, Ei, AJ, PJK, MEDLINE, Scopus等文献机构收录。根据中国科学技术信息研究所发布信息，中国科技期刊物理类影响因子、引文量及综合评价总分《光谱学与光谱分析》都居前几位。欢迎国内外厂商在《光谱学与光谱分析》发布广告（广告经营许可证：京海市监广登字20170260号）。

《光谱学与光谱分析》的主编为高松院士。

欢迎新老客户到全国各地邮局订阅，若有漏订者可直接与《光谱学与光谱分析》期刊社联系。

联系地址：北京市海淀区学院南路76号（南院），

《光谱学与光谱分析》期刊社

邮政编码：100081

联系电话：010-62181070, 62182998

电子信箱：chnghpxygpfx@vip.sina.com

修改稿专用邮箱：gp2008@vip.sina.com

网 址：<http://www.gpxygpfx.com>

