

利用无人机多源传感器估算马铃薯植株氮含量

樊意广^{1, 3, 5}, 冯海宽^{1, 2, 3*}, 刘杨^{1, 3, 4}, 边明博^{1, 3},
赵钰^{1, 3}, 杨贵军^{1, 3}, 钱建国⁵

1. 农业农村部农业遥感机理与定量遥感重点实验室, 北京市农林科学院信息技术研究中心, 北京 100097
2. 南京农业大学国家信息农业工程技术中心, 江苏 南京 210095
3. 国家农业信息化工程技术研究中心, 北京 100097
4. 中国农业大学现代精细农业系统集成研究教育部重点实验室, 北京 100083
5. 辽宁工程技术大学测绘与地理科学学院, 辽宁 阜新 123000

摘要 快速准确地获取作物的植株氮含量(PNC)信息, 是农业精细化管理的关键和数字农业发展的研究热点。近年来, 随着无人机和传感器技术的发展, 利用多种传感器信息监测作物理化参数逐渐引起国内外学者的关注。以马铃薯为研究对象, 首先, 基于无人机获取了马铃薯现蕾期、块茎形成期、块茎增长期、淀粉积累期和成熟期的高光谱影像和数码影像, 同时采集各生育期的地面数码影像, 并实测了株高(H)、PNC和11个地面控制点(GCPs)的三维空间坐标。其次, 利用无人机数码影像结合GCPs生成试验区域的数字表面模型(DSM), 分别从无人机数码影像和DSM中提取马铃薯的地面覆盖度(VC_{uv})和株高(H_{dsm}), 并利用地面数码影像计算的覆盖度(VC)和实测 H 验证提取的 VC_{uv} 和 H_{dsm} 的精度。然后, 根据高光谱反射率数据计算绿边参数(GEPs), 构造 $GEPs \times H_{dsm} \times VC_{uv}$, $GEPs / (1 + VC_{uv})$, $(GEPs + VC_{uv}) \times H_{dsm}$ 和 $GEPs / (1 + H_{dsm})$ 4种融合特征参数(FFPs), 对高光谱影像信息和数码影像信息进行融合。最后, 将各生育期提取的GEPs和构造的FFPs分别与PNC作相关性分析, 筛选最优绿边参数(OGEP)和最优融合特征参数(OFFP)构建5个生育期的PNC线性估算模型, 并根据相关性较高的GEPs和FFPs利用偏最小二乘(PLSR)和人工神经网络(ANN)2种回归方法构建PNC的多参数估算模型, 结果表明: (1)基于无人机数码影像提取的 H_{dsm} 和 VC_{uv} 具有较高的精度, 可以代替实测 H 和 VC 估算作物理化参数。(2)与GEPs相比, 前4个生育期, 构造的大部分FFPs与PNC的相关性更高, 能更好地反映马铃薯的氮营养状况。(3)马铃薯5个生育期, OFFP估算PNC的效果优于OGEP。(4)与单参数模型相比, 基于GEPs和FFPs利用PLSR和ANN2种方法构建的模型精度和稳定性均明显提高, 其中, 以FFPs为模型因子利用ANN方法构建的模型效果最好。该研究表明融合高光谱绿边参数和高清数码相机传感器提取的株高和覆盖度信息能显著提升PNC的估算精度, 可为马铃薯氮营养状况的动态无损监测和多源传感器信息的应用提供参考。

关键词 植株氮含量; 无人机; 多源传感器; 绿边; 株高; 覆盖度

中图分类号: S25 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2022)10-3217-09

引言

氮素是作物生长过程中不可或缺的营养元素, 合理的氮肥供应是保证作物正常生命活动的物质基础。植株氮含量(plant nitrogen content, PNC)是表征作物氮素营养状况的重

要指示因子; 快速准确地获取作物的PNC信息有助于科学、高效地制定氮肥管理策略, 提高氮肥利用效率及降低环境污染^[1]。传统的PNC测量方法主要是田间取样与实验室测试相结合, 虽然结果准确, 但具有一定的破坏性, 且耗时费力, 无法满足数字农业快速、高效和大范围监测的要求。近年来, 遥感技术的迅速发展, 为作物氮营养状况的高效无损监

收稿日期: 2022-03-02, 修订日期: 2022-06-09

基金项目: 黑龙江省揭榜挂帅科技攻关项目(2021ZXJ05A05), 国家自然科学基金项目(41601346), 2022年度农业农村部农业遥感机理与定量遥感重点实验室建设项目(PT2022 24)资助

作者简介: 樊意广, 1993年生, 北京市农林科学院信息技术研究中心硕士研究生 e-mail: fyglngd@163.com

* 通讯作者 e-mail: fenghaikuan123@163.com

测提供了一种新的技术手段^[2]。

与卫星和地面遥感技术相比,无人机成像技术具有操作简单、分辨率高和成本低等优点,已成为数字农业的重要技术支撑^[3]。目前,以无人机为遥感平台监测作物理化参数常用的传感器主要有高光谱、多光谱和数码相机等,国内外学者就不同传感器监测作物理化参数的性能做了大量研究。结果表明,不同类型传感器监测作物理化参数的性能不同,仅利用单一传感器监测作物理化参数具有一定的局限性^[4-6]。例如高光谱传感器虽然波段数目众多,可获得大量与作物理化性质密切相关的特征参数,如红边和绿边等,但存在空间分辨率低,无法获取作物详细的空间结构特征等不足,无法避免单一光谱特征在作物高覆盖度条件下估算理化参数可能出现的饱和现象^[7]。而多光谱和数码相机传感器虽然空间分辨率高,可以高精度地获取作物的空间结构特征,如株高和纹理等,但受波段数目的制约,无法提供足够的与作物理化性质密切相关的光谱信息。

为解决上述问题,充分利用多种传感器的优势,一些学者尝试利用多种传感器信息监测作物的理化参数。如 Kefauver 等^[8]利用数码影像数据和多光谱影像数据探究了不同施氮水平对大麦品质的影响,结果表明多光谱影像指数对多元模型的贡献大于数码影像指数。Yue 等^[9]探究了地面高光谱数据、无人机数码影像数据和无人机高光谱数据与株高结合估算作物长势参数的性能,结果显示,株高的加入能明显提高光谱指数估算冬小麦地上生物量的能力。Xu 等^[10]利用无人机搭载数码相机传感器和多光谱传感器分别获取了冬小麦的覆盖度信息和多光谱影像指数,并构建了覆盖度调整光谱指数,用于估算冬小麦的叶片氮含量,结果显示,无人机多光谱指数结合数码相机提取的覆盖度信息能有效提高估算模型的精度和稳定性。

以上研究表明,株高和覆盖度的加入可以提高作物理化

参数的估算精度,但现有的大多数研究都是将二者与不同传感器获取的光谱指数作为单独变量直接输入到理化参数的估算模型中,尝试融合不同传感器获取的信息的较少,将无人机高光谱获取的红边和绿边等特征参数,与无人机数码相机获取的株高和覆盖度信息融合监测作物的氮营养状况的研究更是鲜有报道。

已有的研究表明,相较于红边区域,绿边与作物的理化性质联系更加紧密,在监测作物理化参数方面的应用更广泛^[11-12]。因此,以马铃薯为研究对象,基于无人机高光谱反射率数据,提取了 8 个绿边参数(green edge parameters, GEPs),分别与无人机数码影像提取的株高和覆盖度信息融合,构造了 $GEPs \times H_{dsm} \times VC_{uav}$, $GEPs / (1 + VC_{uav})$, $(GEPs + VC_{uav}) \times H_{dsm}$ 和 $GEPs / (1 + H_{dsm})$ 4 种融合特征参数(fusion feature parameters, FFPs),并利用偏最小二乘(partial least squares regression, PLSR)和人工神经网络(artificial neural networks, ANN)2 种算法,着重探讨了绿边参数融合株高和覆盖度估算马铃薯植株氮含量的潜力,以为马铃薯营养状况的高效无损监测提供一种新的技术支撑。

1 实验部分

1.1 实验设计

马铃薯试验田位于北京市昌平区小汤山镇国家精准农业研究示范基地(40°10'34"N, 116°26'39"E),该地平均海拔为 36 m,属暖温带半湿润大陆性气候。马铃薯试验采用正交试验设计,试验方案详情见文献[12]。为避免不同生育期试验田位置偏差对试验结果的影响,于试验小区周围埋设了 11 个地面控制点(ground control point, GCPs),并利用高精度的 GPS 测定各 GCP 的三维坐标。具体的试验设计如图 1 所示。




图 1 马铃薯田间位置及试验设计

Fig. 1 Potato field location and experiment design

1.2 无人机影像的获取与预处理

以无人机为遥感平台,搭载高清数码相机传感器和高光谱传感器分别于 2019 年 5 月 13 日、5 月 28 日、6 月 10 日、6 月 20 日和 7 月 3 日开展飞行作业,获取马铃薯现蕾期至成

熟期 5 个生育期的数码影像和高光谱影像数据。2 种传感器的具体参数如表 1 所示。为避免光照对试验结果的影响,选择正午 12:00—14:00 开展飞行作业,无人机的飞行高度设置为 20 m,且配备高精度的位置与姿态测量系统,以获得试

验区域的精确位置。

高光谱影像的预处理在 Cubert-Pilot 和 PhotoScan 软件中完成, 主要包括影像的校正、拼接和融合等。数码影像的预处理在 PhotoScan 中完成, 主要包括影像的对齐与校正、

生成点云、构建网格和纹理, 最终生成试验区域的数字表面模型(digital surface model, DSM)和数字正射影像(digital orthophoto map, DOM)。

表 1 传感器参数
Table 1 Sensor parameters

数码相机传感器	参数值	高光谱传感器	参数值
类型	CMOS	型号	UHD185
镜头	FOV 84°	尺寸/(mm×mm×mm)	195×67×60
快门速度/s	8~1/8 000	相机质量/g	470
有效像素/万	2 000	波谱范围/nm	450~950
对焦距离/自动	1 m~无穷远	采样间隔/nm	4
照片尺寸	4 864×3 648	光谱分辨率/nm	8

1.3 地面数据获取

地面数据的采集与无人机飞行作业同步开展。采集内容包括各生育期的实测株高(height, H)、实测覆盖度(vegetation coverage, VC)和 PNC 数据。其中 H 的测量方法为: 在每个小区选取 4 株能代表整体长势的马铃薯植株, 量取自然状态下叶顶端到茎基的距离, 取其平均值作为该小区马铃薯植株的 H 值。 VC 的测量方法借鉴了吴智超等^[13]的思路, 首先基于型号为 G16 的数码相机(有效像素为 1 200 万), 分别获取马铃薯 5 个生育期冠层上方约 1.5 m 处的数码影像。其次利用“色度-饱和度-亮度”(hue-saturation-intensity, HSI)颜色空间对研究区进行转换处理, 再利用过绿植被指数(excess green vegetation index, EXG)对 HSI 处理的结果进行绿色植被处理。然后采用最大类间方差阈值和形态学阈值的方法剔除土壤背景和杂草噪声。最后每个研究小区内植被的像素数与小区内总像素数的比值即该小区的 VC 值。PNC 通过实验室测量获取; 每个试验小区选取能代表整体长势的植株 3 株, 将其茎叶分离后 105 °C 杀青 0.5 h, 之后在 80 °C 条件下干燥至恒质量得到样本的干质量, 然后利用凯氏定氮仪测定叶和茎部分的全氮含量, 最后根据样本的干质量计算各个小区的 PNC 值^[14]。

1.4 绿边参数及融合特征参数选取

在 502~554 nm 范围内, 由于植被叶片自身特性和内部结构的影响, 光谱反射率由低谷区缓慢增加到峰值区, 形成绿色植物特有的绿边特征, 常用于作物理化参数的监测。选取了绿边最大反射率(R_{max})、绿边反射率总和(R_{sum})、绿边面积(SD_g)、绿边位置(GEP)、绿边振幅(D_g)、最小振幅(D_{gmin})、绿边振幅/最小振幅(D_g/D_{gmin})和绿边一阶导数总和(D_{sum})8 个 GEPs。其中, SD_g 表示绿边区域内光谱曲线包围的面积, GEP 表示绿边区域一阶导数最大处对应的波长, D_g 和 D_{gmin} 分别表示绿边区域一阶导数的最大值和最小值。为充分利用高光谱传感器波段信息丰富和数码相机传感器高分辨率的优点, 基于选取的无人机高光谱 GEPs 和无人机数码影像提取的 H_{dsm} 和 VC_{uav} 构造 $GEPs * H_{dsm} * VC_{uav}$, $GEPs/(1 + VC_{uav})$, $(GEPs + VC_{uav}) * H_{dsm}$ 和 $GEPs/(1 + H_{dsm})$ 4 种共 32 个融合特征参数进行马铃薯 PNC 的监测。

1.5 株高及覆盖度的提取

为提取马铃薯的株高, 于 2019 年 4 月 20 号采集了马铃薯试验田裸土状态下的数码影像, 并结合 GCPs 生成该时期的 DSM, 在 ArcGIS 软件中将不同生育期的 DSM 与裸土期的 DSM 进行差值运算, 最后利用感兴趣区工具提取每个小区的株高, 将其平均值作为该小区的 H_{dsm} 。马铃薯覆盖度的提取在 ENVI 软件中完成, 首先利用 EXG 指数通过双峰法求取植被与土壤背景的阈值, 然后对影像进行二值化处理, 最终以植被像素点个数与总像素点个数的比值作为该小区的 VC_{uav} 。

1.6 数据分析方法

采用偏 PLSR 和 ANN 两种方法构建马铃薯 PNC 估算模型。PLSR 是一种可以提供多对多的回归模型。特别是当自变量个数较多并存在一定的自相关性, 而因变量个数较少时, 通过 PLSR 构建的模型效果要优于传统回归分析。ANN 能够模拟动物脑神经元的行为特征, 根据输出值与期望值之间的误差对各神经元间的权值进行不断修正, 从而达到非线性映射的目的。

1.7 精度评价

每个生育期获取 48 组数据, 在回归分析中, 采用 32 组数据(重复 1 和重复 3)作为建模集, 16 组数据(重复 2)作为验证集, 构建马铃薯 PNC 的估算模型。选用决定系数(R^2)、均方根误差(RMSE)和标准均方根误差(NRMSE)评价模型的性能。

2 结果与讨论

2.1 马铃薯冠层高光谱反射率提取

采用卷积平滑滤波(Savitzky-Golag, SG)对原始高光谱反射率进行平滑校正, 以减少环境噪声、传感器随机误差等对马铃薯冠层高光谱反射率的影响。以块茎形成期为例, 不同处理小区校正后的光谱反射率曲线如图 2 所示。由图 2 可知, 马铃薯冠层反射率具有典型的绿色植被光谱特征。在选取的绿边区域内, 光谱反射率缓慢上升, 在 550 nm 附近出现“绿峰”特征, 可以较好地地区分环境背景和植被特征。




图 2 马铃薯块茎形成期光谱反射率曲线

Fig. 2 Spectral reflectance curves of potato in tuber formation period




图 4 马铃薯提取覆盖度与实测覆盖度对比分析

Fig. 4 Comparative analysis of potato extraction coverage and measured coverage

2.2 株高提取

通过马铃薯各生育期 DSM 与裸土期 DSM 之间的差值运算,得到 5 个生育期共 240 组 H_{dsm} 数据,将其与实测的 H 进行线性拟合,结果如图 3 所示。由图 3 可知,提取的 H_{dsm} 与实测 H 拟合的决定系数为 0.86, RMSE 为 2.66 cm, NRMSE 为 10.23%,表明基于 DSM 提取的 H_{dsm} 具有可靠的精度,可以代替实测 H 估算作物的理化参数。

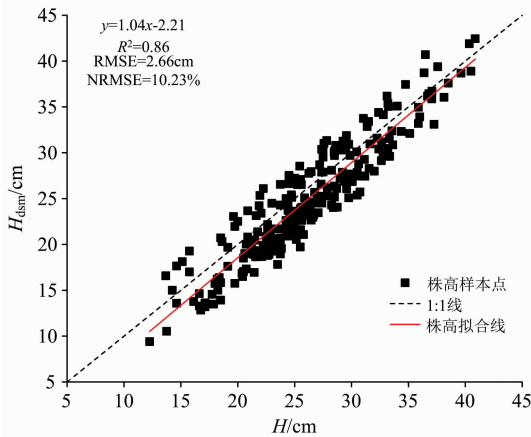


图 3 马铃薯提取株高与实测株高对比分析

Fig. 3 Comparative analysis of extracted plant height and measured plant height of potato

2.3 覆盖度提取

基于马铃薯 5 个生育期的无人机数码影像和地面数码影像,分别获取 240 组提取 VC_{uav} 数据和实测 VC 数据,将二者进行线性拟合得到如图 4 所示的结果。由图 4 可知,5 个生育期 VC_{uav} 和 VC 的拟合决定系数为 0.84, RMSE 为 0.08, NRMSE 为 15.38%,表明基于无人机数码影像提取的 VC_{uav} 具有较高的精度,可以代替实测 VC 估算作物的理化参数。

2.4 相关性分析

根据马铃薯高光谱反射率数据,提取各生育期的 GEPs,并基于 GEPs 和无人机数码影像提取的 H_{dsm} 及 VC_{uav} 构造

$GEPs \times H_{dsm} \times VC_{uav}$, $GEPs / (1 + VC_{uav})$, $(GEPs + VC_{uav}) \times H_{dsm}$ 和 $GEPs / (1 + H_{dsm})$ 4 种 FFPs,将各生育期获取的 GEPs 和 FFPs 分别与对应生育期的 PNC 进行相关性分析,结果如图 5 所示。由图 5 可知,马铃薯 5 个生育期,大部分 GEPs 和 FFPs 与 PNC 均达到 0.01 相关水平,相关性表现较好。其中,现蕾期共有 6 个 GEPs 与 PNC 的相关性达到 0.01 相关水平,相关性从小到大依次为 D_{gmin} , D_g , R_{sum} , SD_g , R_{max} 和 D_{sum} , 相关系数绝对值介于 0.60~0.79 之间,而相关性位于前 6 的 FFPs 分别为 $D_g / 1 + H_{dsm}$, $D_{sum} / 1 + H_{dsm}$, $SD_g / 1 + H_{dsm}$, $R_{max} / 1 + VC_{uav}$, $D_{sum} / 1 + VC_{uav}$ 和 $SD_g / 1 + VC_{uav}$, 相关系数绝对值介于 0.71~0.84 之间。块茎形成期共有 R_{max} , D_g , D_{gmin} , SD_g 和 D_{sum} 5 个 GEPs 与 PNC 的相关性达到 0.01 相关水平,相关系数绝对值介于 0.37~0.72 之间,而相关性位于前 5 的 FFPs 分别为 $(R_{max} + VC_{uav}) \times H_{dsm}$, $D_{sum} / 1 + H_{dsm}$, $SD_g / 1 + H_{dsm}$, $D_{sum} / 1 + VC_{uav}$ 和 $SD_g / 1 + VC_{uav}$, 相关系数绝对值位于 0.75~0.85 之间。块茎增长长期共有 D_{gmin} , R_{sum} , R_{max} 和 D_g / D_{gmin} 4 个 GEPs 与 PNC 达到 0.01 相关水平,相关系数绝对值介于 0.63~0.68 之间,而相关性位于前 4 的 FFPs 分别是 $D_g / D_{gmin} \times VC_{uav} \times H_{dsm}$, $R_{max} / 1 + VC_{uav}$, $SD_g / 1 + VC_{uav}$ 和 $D_{sum} / 1 + VC_{uav}$, 相关系数绝对值介于 0.70~0.88 之间。淀粉积累期共有 D_{gmin} , R_{sum} 和 R_{max} 3 个 GEPs 与 PNC 达到 0.01 相关水平,相关系数绝对值介于 0.39~0.69 之间,而相关性位于前 3 的 FFPs 分别为 $D_g / 1 + VC_{uav}$, $SD_g / 1 + VC_{uav}$ 和 $D_{sum} / 1 + VC_{uav}$, 相关系数绝对值介于 0.66~0.74 之间。成熟期共有 R_{sum} , D_g , R_{max} , SD_g 和 D_{sum} 5 个 GEPs 与 PNC 达到 0.01 相关水平,相关系数绝对值介于 0.52~0.68 之间,而相关性位于前 5 的 FFPs 分别为 $D_{sum} \times VC_{uav} \times H_{dsm}$, $SD_g \times VC_{uav} \times H_{dsm}$, $D_g / 1 + VC_{uav}$, $D_{sum} / 1 + VC_{uav}$ 和 $D_g / 1 + VC_{uav}$, 相关系数介于 0.49~0.56 之间。由以上分析可知,马铃薯前 4 个生育期,构造的大部分 FFPs 与 PNC 的相关性明显高于 GEPs,表明 FFPs 与作物 PNC 联系更紧密,能更好地反映作物氮素营养的动态变化。

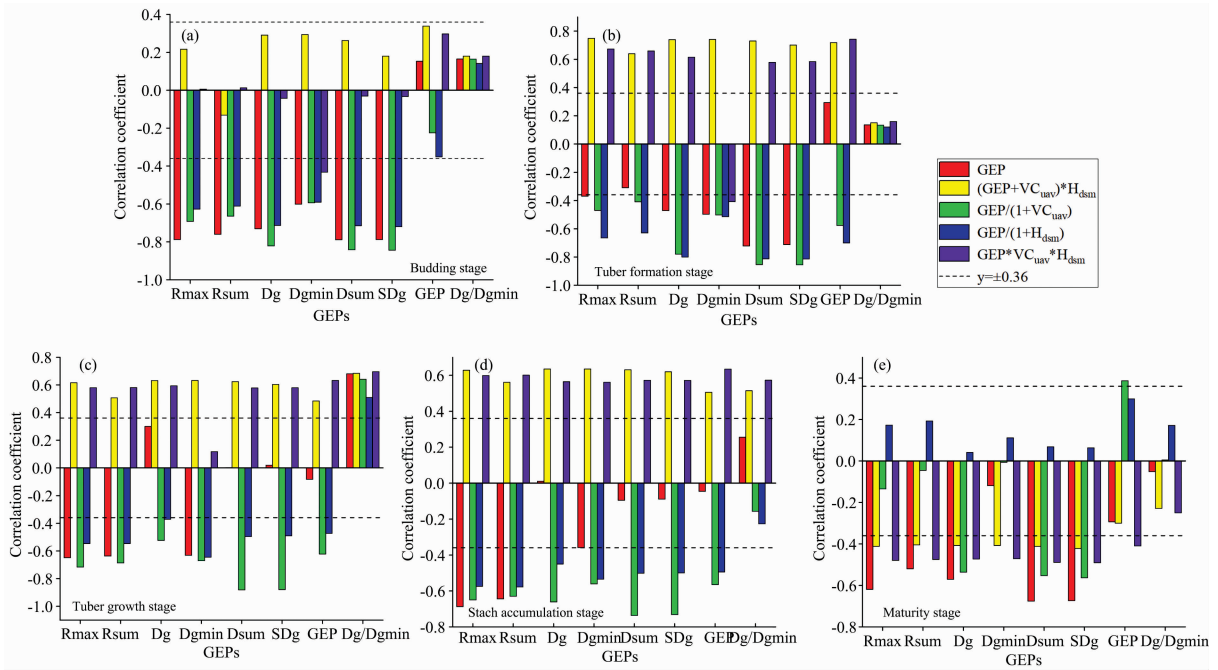


图 5 不同生育期植株氮含量与提取参数相关性分析结果

注：虚线为 0.01 相关水平线

Fig. 5 Correlation analysis results of extraction parameters and plant nitrogen content at different growth stages

Note: dotted line represents the correlation significant at 0.01 level

2.5 马铃薯植株氮含量估算

2.5.1 单参数估算马铃薯植株氮含量

基于各生育期挑选的最优绿边参数 (optimal GEP, OGEP) 和最优融合特征参数 (optimal FFP, OFFP), 利用一元线性回归建立 5 个生育期的 PNC 估算模型, 以探究 OGEP 和 OFFP 估算马铃薯 PNC 的能力。通过建模集和验证集数据得到各生育期模型的精度指标如表 2 和表 3 所示。

由表 2 可知, 基于 OGEP 构建的马铃薯 PNC 估算模型现蕾期精度最好, 建模和验证的 R^2 分别为 0.54 和 0.77, RMSE 分别为 0.55 和 0.37, NRMSE 分别为 14.97% 和 14.21%, 成熟期模型精度最差, 建模和验证的 R^2 分别为 0.49 和 0.31, RMSE 分别为 0.37 和 0.37, NRMSE 分别为 14.02% 和 14.33%。总的来说, 各生育期的 OGEP 具有一定估算马铃薯 PNC 的能力, 但构建的模型精度普遍不高。

表 2 最优绿边参数估算马铃薯 PNC 结果

Table 2 PNC of potato estimated by using optimal green edge parameter

生育期	OGEP	建模			验证		
		R^2	RMSE/%	NRMSE/%	R^2	RMSE/%	NRMSE/%
现蕾期	D_{sum}	0.54	0.55	14.97	0.77	0.37	14.21
块茎形成期	D_{sum}	0.44	0.46	14.53	0.80	0.37	14.32
块茎增长期	D_g/D_{gmin}	0.47	0.44	16.46	0.48	0.39	16.63
淀粉积累期	R_{max}	0.47	0.34	11.92	0.45	0.36	11.54
成熟期	D_{sum}	0.49	0.37	14.02	0.31	0.37	13.33

由表 3 可知, 基于 OFFP 构建的马铃薯 5 个生育期的 PNC 估算模型块茎增长期精度最好, 建模和验证的 R^2 分别为 0.78 和 0.76, RMSE 分别为 0.28 和 0.25, NRMSE 分别为 10.52% 和 11.14%, 成熟期精度最差, 建模和验证的 R^2 分别为 0.30 和 0.47, RMSE 分别为 0.43 和 0.38, NRMSE 分别为 16.47% 和 16.43%。总的来说, 基于 OFFP 构建的马铃薯 PNC 估算模型前 4 个生育期估算效果良好, 精度和稳定性较高, 但成熟期模型的精度较低。

2.5.2 多参数估算马铃薯植株氮含量

为评估多个绿边参数和融合特征参数估算马铃薯 PNC 的能力, 分别基于各生育期与 PNC 达到 0.01 相关水平的 GEPs 及相同个数的 FFPs, 采用 PLSR 和 ANN 两种方法构建马铃薯 5 个生育期的 PNC 估算模型, 结果如表 4 所示。由表 4 可知, 以 GEPs 为模型变量, 利用 PLSR 和 ANN 2 种方法建立的马铃薯 PNC 估算模型前 3 个生育期的精度较高, 而淀粉积累期和成熟期的模型精度有所下降。而以 FFPs 为模型变量构建的模型前 4 个生育期的模型精度较高, 成熟期的模型精度较低。与单个模型参数构建的 PNC 估算模型相

比,多参数构建的模型的精度和稳定性更高,且以 FFPs 为模型变量,构建的模型精度优于 GEPs。为进一步确定马铃薯 PNC 的最佳估算模型,以 FFPs 为模型变量,分别绘制基于 PLSR 和 ANN 两种方法的马铃薯 5 个生育期 PNC 实测值与预测值的散点图,如图 6 和图 7 所示。

综合表 4、图 6 和图 7 可知,各生育期以同种模型变量基于 ANN 构建的 PNC 估算模型的建模 R^2 均高于 PLSR 方法, RMSE 和 NRMSE 均低于 PLSR 方法,且以 FFPs 为模型变量,基于 ANN 方法的 5 个生育期的预测值与实测值分布更接近 1:1 线,模型的精度和稳定性最好。

表 3 最优融合特征参数估算马铃薯 PNC 结果

Table 3 Estimated values of potato PNC with optimal fusion feature parameters

生育期	OFFP	建模			验证		
		R^2	RMSE/%	NRMSE/%	R^2	RMSE/%	NRMSE/%
现蕾期	$SD_g/1+VC_{uav}$	0.68	0.46	12.50	0.77	0.38	11.29
块茎形成期	$SD_g/1+VC_{uav}$	0.67	0.35	11.07	0.86	0.25	10.41
块茎增长期	$D_{sum}/1+VC_{uav}$	0.78	0.281	0.52	0.76	0.25	10.14
淀粉积累期	$D_{sum}/1+VC_{uav}$	0.53	0.34	11.35	0.72	0.30	10.82
成熟期	$D_g/1+VC_{uav}$	0.30	0.43	16.47	0.47	0.38	16.43

表 4 基于 PLSR 和 ANN 方法估算马铃薯不同生育期 PNC

Table 4 PNC estimations of potato at different growth stages by using PLSR and ANN

生育期	模型变量	PLSR						ANN					
		建模			验证			建模			验证		
		R^2	RMSE/%	NRMSE/%	R^2	RMSE/%	NRMSE/%	R^2	RMSE/%	NRMSE/%	R^2	RMSE/%	NRMSE/%
P1	GEPs	0.73	0.42	11.61	0.77	0.41	10.47	0.77	0.43	11.89	0.81	0.39	10.09
	FFPs	0.74	0.41	11.35	0.78	0.41	10.48	0.84	0.34	9.30	0.86	0.32	8.08
P2	GEPs	0.72	0.32	10.30	0.68	0.35	10.38	0.74	0.33	10.47	0.72	0.40	12.03
	FFPs	0.77	0.29	9.32	0.85	0.28	8.55	0.80	0.27	8.70	0.84	0.30	8.96
P3	GEPs	0.50	0.42	15.94	0.62	0.34	12.25	0.57	0.39	14.72	0.67	0.30	10.93
	FFPs	0.79	0.28	10.38	0.77	0.25	9.22	0.83	0.25	9.51	0.79	0.25	9.09
P4	GEPs	0.47	0.34	11.9	0.47	0.36	11.50	0.55	0.33	11.56	0.50	0.36	11.36
	FFPs	0.67	0.29	9.71	0.73	0.29	10.53	0.71	0.27	9.05	0.74	0.29	10.44
P5	GEPs	0.53	0.35	13.5	0.47	0.34	12.18	0.64	0.32	12.22	0.46	0.33	11.88
	FFPs	0.37	0.41	15.57	0.51	0.33	11.98	0.53	0.36	13.66	0.42	0.34	12.16

注: P1—P5 分别表示现蕾期、块茎形成期、块茎增长期、淀粉积累期和成熟期

Note: P1—P5 represent budding stage, tuber formation stage, tuber growth stage, starch accumulation stage and maturity stage respectively

2.6 基于绿边参数估算马铃薯植株氮含量

由相关性分析结果(图 5)可知,马铃薯 5 个生育期,构建的大部分 GEPs 均与 PNC 达到 0.01 相关水平,且前 3 个生育期的相关性明显高于后 2 个生育期,表明绿边区域与 PNC 的联系较为紧密,且生长前期相关性高于生长后期。分别基于 OGEP 和 GEPs 构建马铃薯 PNC 的估算模型,结果(表 2、表 4)也表明,前 3 个生育期的模型精度高于后 2 个生育期,其原因是随着马铃薯生长进程的推进,由淀粉积累期到成熟期马铃薯植株逐渐凋零枯萎,马铃薯叶片内叶绿素浓度不断降低,对绿光的反射能力变弱,绿边区域与 PNC 的敏感性降低,以 GEPs 构建的马铃薯 PNC 估算模型的精度也因此降低。

2.7 基于融合特征估算马铃薯植株氮含量

为探究融合特征参数估算马铃薯植株氮含量的性能,首先基于无人机数码影像提取了作物的株高和覆盖度,由图 3 和图 4 可知,基于无人机数码影像提取的 H_{dsm} 和 VC_{uav} 精度

可靠,可以用于作物理化参数的估算。由各生育期的 FFPs 与 PNC 的相关性分析结果(图 5)可知,前 4 个生育期,构造的大部分 FFPs 与 PNC 的相关性明显高于 GEPs。由表 3 和表 4 可知,前 4 个生育期的 OFFP 与 PNC 的相关性显著高于 OGEP,且基于 OFFP 和 FFPs 构建的 PNC 估算模型的精度和稳定性均显著优于 OGEP 和 GEPs,而在成熟期,模型的精度没有提升。这表明,前 4 个生育期 FFPs 与 PNC 的联系更紧密,其原因是,相较于 GEPs,FFPs 融合了高光谱绿边参数、高清数码相机获取株高和覆盖度,包含了作物冠层和垂直结构 2 个层次的变化信息,而 PNC 由茎和叶 2 部分的氮含量组成,因此,FFPs 与作物 PNC 的联系更紧密,能更好地反映 PNC 的动态变化,且覆盖度的加入,在一定程度上能消除土壤背景等的影响^[15],因此马铃薯前 4 个生育期基于 FFPs 估算 PNC 的效果优于 GEPs,而成熟期,由于连天大雨的影响,大部分马铃薯植株迅速凋零枯死,此时提取的株高和覆盖度信息不能反映真实的 PNC 状况,因此这一时期

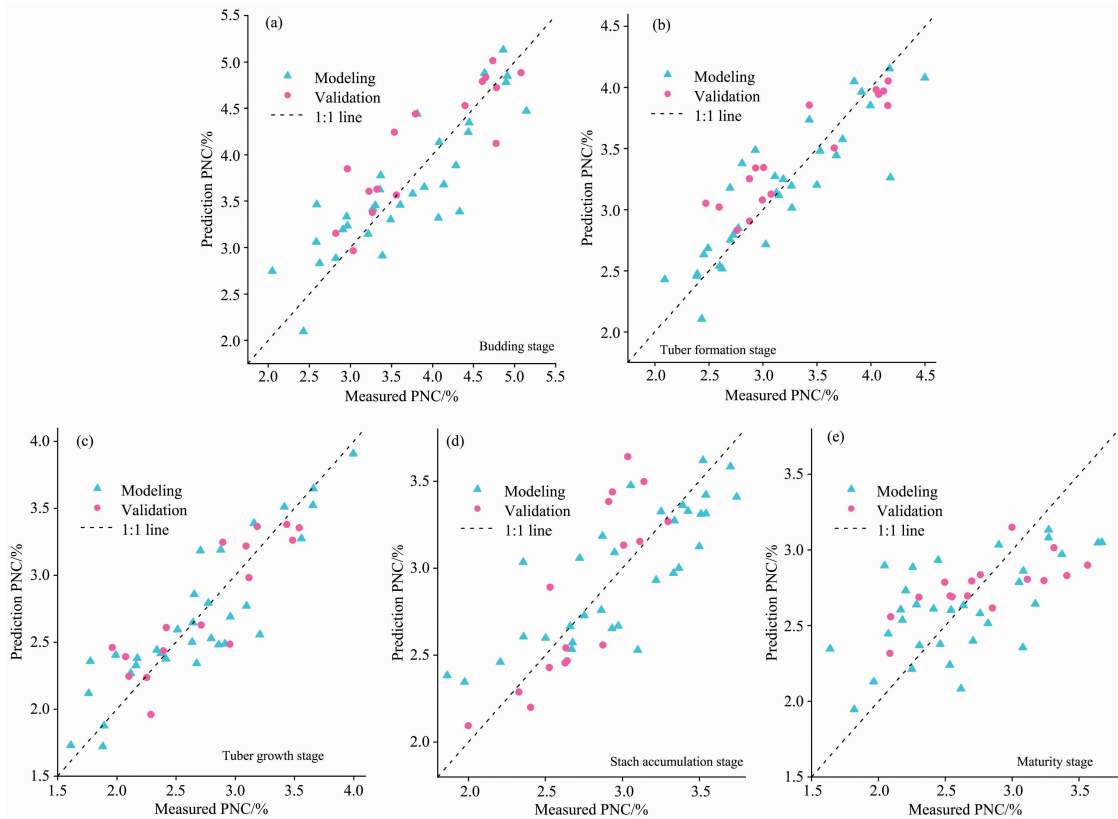


图 6 基于 FFPs 利用 PLSR 估算马铃薯 PNC 效果

Fig. 6 PNC estimation of potato based on FFPs using PLSR

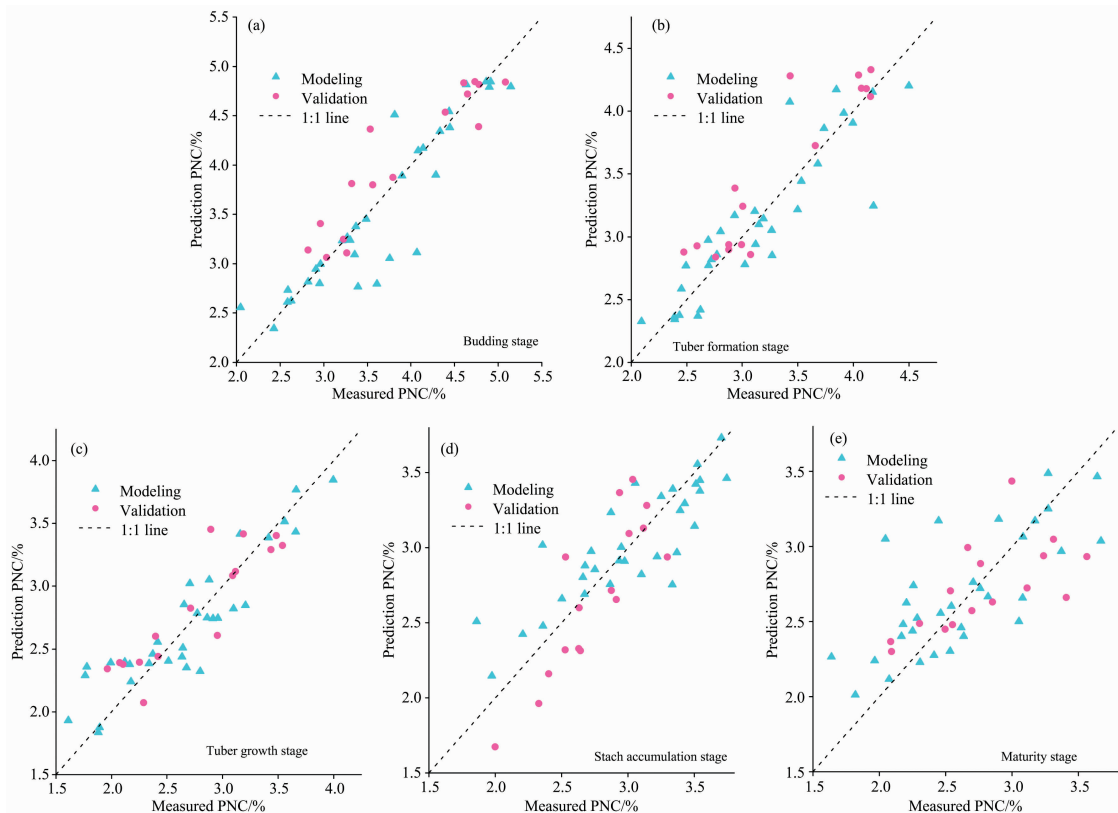


图 7 基于 FFPs 利用 ANN 估算马铃薯 PNC 效果

Fig. 7 PNC estimation of potato based on FFPs using ANN

构建的 FFPs 与 PNC 的相关性明显降低, 构建的 PNC 估算模型的精度也明显降低。此外, 由 5 个生育期的 OFFP 和参与建模的 FFPs 可知, 由 $GEPs/(1+VC_{uv})$ 构建的 FFPs 与 PNC 的相关性更强, 对马铃薯 PNC 估算模型的贡献最大, 这与 Yao 等^[14]利用高光谱植被指数与地面数码相机获取的覆盖度估算冬小麦叶片氮含量得到的结论一致, 其原因是植被覆盖度的加入能很大程度上消除土壤背景的影响, 增强了 GEPs 与作物氮状况的敏感性。

2.8 基于不同回归方法估算马铃薯植株氮含量

为探究 OGEP 和 OFFP 估算马铃薯 PNC 的效果, 首先利用一元线性回归构建马铃薯 5 个生育期的 PNC 估算模型, 由表 2 和表 3 可知, 与基于 GEPs 和 FFPs 构建的模型相比, 基于最优模型参数构建的模型的精度和稳定性较差, 说明多参数估算作物理化参数的能力高于单个模型参数, 这与 Han 等^[16]估算玉米地上生物量得到的结论一致。其原因是多参数能够提供更丰富的与氮相关的信息, 从而能够更好地反映 PNC 的变化。基于 GEPs 和 FFPs, 分别采用 PLSR 和 ANN 2 种方法构建马铃薯的 PNC 估算模型, 由表 4 可知, 基于 2 种方法构建的模型均表现为 FFPs 明显优于 GEPs, 说明融合绿边参数和株高、覆盖度构建的 FFPs 与 PNC 的联系更紧密, 能明显提高估算作物 PNC 的精度, 可为作物氮营养状况

的监测和多源传感器信息的应用提供参考; 而基于同种模型因子时, ANN 方法显示出更好的估算性能, 其原因是神经网络算法在处理非线性问题方面具有明显的优势和强大的容错能力, 提高了估算模型的精度。

3 结 论

利用无人机搭载高光谱和数码相机 2 种传感器, 探究了高光谱绿边参数融合株高及覆盖度信息估算马铃薯植株氮含量的能力, 结果表明: (1) 基于无人机数码影像提取的 H_{dsm} 和 VC_{uv} 与实测 H 和 VC 的拟合 R^2 分别是 0.86 和 0.84, 表明提取的 H_{dsm} 和 VC_{uv} 精度可靠, 可以用于估算作物的理化参数。(2) 与原始无人机高光谱 GEPs 相比, 利用 GEPs 与无人机数码影像提取的 H_{dsm} 和 VC_{uv} 构造的大部分 FFPs 与马铃薯 PNC 的相关性更高, 能更好地反映马铃薯的氮营养状况。(3) 在马铃薯前 4 个生育期, 基于 OFFP 和 FFPs 构建的模型明显优于 OGEP 和 GEPs, 其中, 以 FFPs 为模型因子构建的模型效果最好。(4) 利用 ANN 方法估算各生育期 PNC 的效果优于 PLSR 方法。该研究可为马铃薯氮营养状况的无损动态监测和多源传感器信息的应用提供参考。

References

- [1] Corti M, Cavalli D, Cabassi G, et al. Precision Agriculture, 2019, 20(4): 675.
- [2] Zhang Y, Hui J, Qin Q, et al. Remote Sensing of Environment, 2021, 267: 112724.
- [3] Suomalainen J, de Oliveira R A, Hakala T, et al. Remote Sensing of Environment, 2021, 266: 112691.
- [4] NIJIAT Kasim, SHI Qing-dong, WANG Jing-zhe, et al(尼加提·卡斯木, 师庆东, 王敬哲, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2017, 33(22): 208.
- [5] Zheng H, Cheng T, Zhou M, et al. Precision Agriculture, 2019, 20(3): 611.
- [6] NIU Qing-lin, FENG Hai-kuan, YANG Gui-jun, et al(牛庆林, 冯海宽, 杨贵军, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2018, 34(5): 73.
- [7] Yue J, Yang G, Li C, et al. Remote Sensing, 2017, 9(7): 708.
- [8] Kefauver S C, Vicente R, Vergara-Diaz O, et al. Frontiers in Plant Science, 2017, 8: 1733.
- [9] Yue J, Feng H, Jin X, et al. Remote Sensing, 2018, 10(7): 1138.
- [10] Xu X, Fan L, Li Z, et al. Remote Sensing, 2021, 13(3): 340.
- [11] WANG Yu-na, LI Fen-ling, WANG Wei-dong, et al(王玉娜, 李粉玲, 王伟东, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2020, 36(22): 9.
- [12] LIU Yang, FENG Hai-kuan, HUANG Jue, et al(刘 杨, 冯海宽, 黄 珏, 等). Spectroscopy and Spectral Analysis(光谱学与光谱分析), 2021, 41(3): 903.
- [13] WU Zhi-chao, LI Chang-chun, FENG Hai-kuan, et al(吴智超, 李长春, 冯海宽, 等). Transactions of the Chinese Society for Agricultural Machinery(农业机械学报), 2020, 51(3): 7.
- [14] Fu Y, Yang G, Li Z, et al. Remote Sensing, 2020, 12(22): 3778.
- [15] Yao X, Ren H J, Cao Z S, et al. International Journal of Applied Earth Observation and Geoinformation, 2014, 32: 114.
- [16] Han L, Yang G, Dai H, et al. Plant Methods, 2019, 15(1): 10.

Estimation of Potato Plant Nitrogen Content Using UAV Multi-Source Sensor Information

FAN Yi-guang^{1, 3, 5}, FENG Hai-kuan^{1, 2, 3*}, LIU Yang^{1, 3, 4}, BIAN Ming-bo^{1, 3}, ZHAO Yu^{1, 3}, YANG Gui-jun^{1, 3}, QIAN Jian-guo⁵

1. Key Laboratory of Quantitative Remote Sensing in Agriculture of Ministry of Agriculture and Rural Affairs, Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China
2. Nanjing Agricultural University, Nanjing 210095, China
3. National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China
4. Key Laboratory of Modern Precision Agriculture System Integration Research, Ministry of Education, China Agricultural University, Beijing 100083, China
5. School of Geomatics, Liaoning Technical University, Fuxin 123000, China

Abstract Acquiring the plant nitrogen content (PNC) information of crops quickly and accurately is the key to agricultural meticulous management and a research hotspot in the development of digital agriculture. In recent years, with the development of UAV and sensor technology, the use of various sensor information to monitor the physical and chemical parameters of crops has gradually attracted the attention of scholars at home and abroad. This study takes potato as the research object. Firstly, based on the UAV, the hyperspectral images and digital images of the potato budding stage, tuber formation stage, tuber growth stage, starch accumulation stage and maturity stage were obtained. At the same time, the digital camera was used to synchronously obtain the ground digital images of five growth periods, and the three-dimensional spatial coordinates of eleven ground control points (GCPs) and plant height (H), PNC were measured. Secondly, the digital surface model (DSM) of the test area was generated by using UAV digital images combined with GCPs. The accuracy of the extracted VC_{uav} and H_{dsm} is verified by the calculated coverage (VC) of the digital image and the measured H . Then, the green edge parameters (GEPs) were calculated according to the hyperspectral images, and four fusion feature parameters (FFPs) of $GEPs \times H_{dsm} * VC_{uav}$, $GEPs/(1+VC_{uav})$, $(GEPs+VC_{uav}) \times H_{dsm}$ and $GEPs/(1+H_{dsm})$ were constructed, fusion of hyperspectral image information and digital image information. Finally, the correlation between GEPs extracted and FFPs constructed in each growth period with PNC were analyzed, and the PNC linear estimation models of five growth periods were constructed based on the optimal GEP and optimal FFP respectively. According to the GEPs and FFPs with high correlation, the multiple parameters estimation models of PNC were constructed by using partial least squares (PLSR) and artificial neural network (ANN). The results show that: (1) H_{dsm} and VC_{uav} extracted from UAV digital images have high accuracy, which can replace the measured H and VC to estimation physical and chemical parameters (2) Compared with GEPs, most of the constructed FFPs have stronger correlation with PNC in the first four growth stages, and could better reflect the nitrogen nutrition status of potato. (3) Linear estimation models of potato PNC were constructed based on the optimal green edge parameter (OGEP) and the optimal fusion feature parameter (OFFP), respectively. The results showed that the effect of OFFP in estimating PNC was better than that of OGEP. (4) Compared with the single-parameter model, the accuracy and stability of the model constructed by using PLSR and ANN based on GEPs and FFPs are significantly improved. Among them, the models constructed with FFPs as the model factor have the best effect. (5) The ANN method is better than the PLSR method in estimating PNC in each growth period. Therefore, the fusion of the hyperspectral green edge parameters and the plant height and coverage information extracted by the high-definition digital camera sensor can improve the estimation accuracy of PNC, which provide a reference for the non-destructive dynamic monitoring of potato nitrogen nutrition status and the application of multi-source sensors information.

Keywords Plant nitrogen content; UAV; Multi-source sensor; Green edge; Plant height; Coverage

(Received Mar. 2, 2022; accepted Jun. 9, 2022)

* Corresponding author