

基于叶冠尺度高光谱的冬小麦叶片含水量估算

陈秀青, 杨琦, 韩景晔, 林琳, 史良胜*

武汉大学水资源与水电工程科学国家重点实验室, 湖北 武汉 430072

摘要 叶片含水量(leaf water content, LWC)的快速监测对于作物的干旱诊断和灌溉决策至关重要。以叶片、冠层两个尺度, 原始、一阶导数两种光谱处理形式的高光谱数据为基础, 采用两波段植被指数如归一化差分(normalized difference spectral index, NDSI)和比值光谱指数(ratio spectral index, RSI), 偏最小二乘回归(partial least squares regression, PLSR)和竞争自适应重加权采样—偏最小二乘回归(competitive adaptive reweighted sampling-partial least squares regression, CARS-PLSR)三种方法对叶片含水量进行建模分析, 以确定最佳冬小麦叶片含水量预测模型。结果表明: 三种方法中, 基于叶片一阶导数光谱的 CARS-PLSR 模型对 LWC 的预测效果最好, LWC 的预测值与实测值高度重合 ($R^2 = 0.969$, $RMSE = 0.164$, $RRMSE = 6.00\%$)。相同条件下, 三种方法的叶片光谱模型对 LWC 的预测效果均优于冠层光谱模型。在两波段指数模型以及 PLSR 模型中, 原始光谱模型对 LWC 的预测效果优于一阶导数光谱模型, 而在 CARS-PLSR 模型中结果相反。在两波段指数模型中, RSI 比 NDSI 具有更高的估算精度。研究表明, 通过竞争自适应重加权采样方法提取敏感波段后所建立的偏最小二乘回归预测模型, 无论是预测精度还是建模精度, 与两波段指数和偏最小二乘回归模型相比都有了显著提高, 该方法可为精准快速地监测冬小麦旱情以及灌溉决策提供参考。

关键词 叶片含水量; 偏最小二乘回归; 竞争性自适应重加权采样; 冬小麦; 高光谱遥感

中图分类号: O657.33 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2020)03-0891-07

引言

叶片含水量是监测植物生理状态, 评估干旱胁迫、火灾风险的重要指标, 快速、准确地获取叶片含水量是进行作物干旱诊断以及灌溉决策的前提。高光谱遥感技术凭借快速、高效和无损的优势, 已被广泛应用于作物生物理化参数的定量监测^[1]。Thomas 等^[2]研究叶片含水量与光谱反射率之间的关系, 结果表明 1 450 和 1 930 nm 波段的反射率与叶片相对含水量显著相关。Curran 等^[3]发现由水和其他分子中 O—H 键的伸缩和弯曲产生分子能级变化会引起目标光谱以 970, 1 200, 1 450, 1 940 和 2 500 nm 为中心的吸收区域的相应变化。田庆久等^[4]、王纪华等^[5]研究发现, 冬小麦叶片含水量与光谱反射率在 1 450 nm 附近的特征吸收峰深度和面积呈良好的线性正相关。根据众多学者研究可知叶片含水量敏感波段主要集中在近红外(NIR, 700~1 300 nm)和短波红外区域(SWIR, 1 300~2 500 nm), 光谱水分吸收带主要

在 970, 1 200, 1 450, 1 940 和 2 500 nm 附近。同时, 导数光谱可以消除背景噪声, 解决重叠光谱现象。Danson 等^[6]发现, 1 450 nm 处的光谱反射率一阶导数曲线与叶片含水量关系密切, 并且对叶片结构不敏感。Kumar^[7]也发现叶片含水量与叶片尺度一阶导数光谱具有统计相关。Clevers 等^[8]发现在 1 015~1 050 nm 内的一阶导数光谱反射率能够很好地估算叶片含水量。

目前利用高光谱遥感数据估算作物水分的方法有两种: 一是基于作物敏感波段反射率的统计法^[9], 二是基于物理过程的辐射传输模型反演法^[10]。相比于机理模型的反演, 统计法更简单方便, 且同样能够获得较好的估算效果。本工作着重探讨统计回归方法对叶片含水量的估算。所有统计回归方法中应用最广泛的是植被指数法, 然而采用植被指数的经验模型通常是基于某一作物在特定条件下建立, 且仅采用两个或几个波段的信息, 不能全面地解释与叶片含水量的相关性, 往往导致模型缺乏通用性和精度。相比之下, 偏最小二乘回归(partial least squares regression, PLSR)作为全波段方

收稿日期: 2018-12-21, 修订日期: 2019-03-12

基金项目: 国家自然科学基金项目(51779180, 51861125202)资助

作者简介: 陈秀青, 女, 1994 年生, 武汉大学水利水电学院硕士研究生 e-mail: chenxiuqing@whu.edu.cn

* 通讯联系人 e-mail: liangshs@whu.edu.cn

法,在利用全波段信息的同时能够有效解决高光谱数据在普通多元回归中的多重相关问题。Cho 等^[11]通过利用 PLSR 进行牧草干物质估算,证明 PLSR 具有估算作物理化参数的可行性。Mirzaie 等^[9]研究表明 PLSR 模型对预测叶片水分有较高的精度, Das 等^[12]研究表明相比于植被指数,逐步回归等统计模型,PLSR 模型对冬小麦叶片含水量的预测效果最好。但 PLSR 并不总能提供最佳预测效果,因为有些波段不能够提供目标变量的信息,甚至可能干扰有用信息^[13]。为了减少冗余波段信息的干扰,敏感波段筛选至关重要。Li 等^[14]根据达尔文进化理论中的“适者生存”原则提出了竞争自适应重加权采样(competitive adaptive reweighted sampling, CARS)特征波段提取方法,研究表明通过 CARS 筛选的波段能够提高 PLSR 模型预测能力和稳健性^[15]。

目前采用 CARS-PLSR 方法进行叶片含水量估算的应用较少,且少有学者同时对基于不同尺度、不同光谱处理形式的多种统计回归模型对叶片含水量的预测效果。本研究以此为切入点,通过设置冬小麦灌溉水平,人为制造不同水分胁迫水平,在冬小麦拔节期至灌浆期获取叶片、冠层尺度的光谱数据,进行原始和一阶导数两种处理,采用两波段植被指数、PLSR 以及 CARS-PLSR 三种方法构建叶片含水量估算模型,同时与传统经典水分植被指数模型作比较,确定叶片含水量最优估算模型,为快速、准确地监测冬小麦叶片含水量及田间灌溉决策提供方法依据。

1 实验部分

1.1 试验设计

本研究共设 2 个冬小麦筒栽试验,于 2016 年—2018 年在武汉大学灌溉排水综合试验场进行(30.5°N, 114.4°E)。冬小麦种植于轨道式称重蒸渗仪测筒内,测筒直径为 0.64 m,深为 1.2 m。测筒回填土为粘土,饱和含水率为 48.19%,田间持水率为 30.81%,容重为 1.36 g·m⁻³。冬小麦品种为郑麦 9023,播种量为 187.5 kg·ha⁻¹,氮施用量为 225 kg N·ha⁻¹。播种时间分别为 2016 年 11 月 16 日以及 2017 年 11 月 18 日,通过人工控制灌水水平,以土壤水分下限为灌水信号,设置不同水分处理。在 2016 年—2017 年试验中,设 CK(control check),LD(light drought),MD(middle drought),SD(severe drought)4 个水分处理(分别为田间持水率的 80%,60%,40%,30%),随机分组,每组 3 个重复;在 2017 年—2018 年试验中,设 CK,LD 和 SD 共 3 个水分处理(分别为田间持水率的 80%,60%,40%),随机分组,每组 4 个重复。各试验于拔节期进行水分差异处理,持续到灌浆期结束。测筒上方配有遮雨棚,下雨时雨棚自动关闭。

1.2 光谱采集与预处理

采用美国 ASD 公司生产的 FieldSpec FR4(350~2 500 nm)地物光谱仪获取冬小麦的叶片和冠层反射率光谱。光谱测量前后用白板进行校正,光谱仪光纤探头视场角为 25°。冠层光谱测量时将探头垂直向下高于冠层顶部约 1 m,每个测筒测定 1 次,每次重复测量 10 次,以其平均值作为该测筒的光谱反射值。光谱测定选择在晴朗无云的天气,测量时间

为 10:00—14:00。所有光谱反射率数据通过配套软件 ViewSpecPro 处理得到。冠层光谱剔除 350~400,1 350~1 400,1 800~1 950 以及 2 400~2 500 nm 的水分吸收带,并采用 S-G 滤波平滑,其中每个窗口用 21 个数据点进行二项式拟合。叶片光谱测量采用地物光谱仪配套的叶片夹,每个测筒随机选取三片长势良好、伸展充分的旗叶进行测量,每片叶片重复测量 5 次,以其平均值作为该测筒的光谱反射值。数据采集的日期及其对应的生育期如表 1 所示。分别采集叶片、冠层光谱各 120 份,随机选取 84 份用于建立模型(建模集),剩下的 36 份用于验证模型(验证集)。

表 1 光谱数据采集日期及对应的冬小麦生育

Table 1 Date of hyperspectral data acquisition and growth stage of winter wheat

生育期	时间	
	2017	2018
拔节期	3 月 7 日	3 月 9 日
孕穗抽穗期	3 月 16 日	3 月 21 日、3 月 26 日
扬花期	3 月 27 日	4 月 2 日
灌浆期	4 月 1 日、4 月 12 日、4 月 23 日	4 月 9 日、4 月 18 日
总计	6 次观测	6 次观测

1.3 叶片含水量测定

待叶片光谱测定完成后,立即将上述叶片取下,放入自封袋中(放置阴凉处)。将叶片放入铝盒中称取鲜重后,置于烘箱以 65 °C 烘至恒重,测定其干重。叶片含水量按照式(1)进行测定,其统计特征见表 2。其中 FW(fresh weight)为叶片鲜重,DW(drought weight)为干重。

$$LWC = (FW - DW)/DW \quad (1)$$

1.4 数据分析方法

植被指数是被广泛用于获取作物生物物理变量。不同形式的植被指数对与植被特征相关的光谱信号增强效果不同,其中最常见的形式是比值型指数。因此通过在 350~2 500 nm 波段范围内,将任意两个波段进行组合分别构造两波段指数:归一化差值(NDSI)和比值(RSI)光谱指数[式(2)和式(3)],分析其与冬小麦叶片含水量的关系,建立估算模型。

$$NDSI = (R_{\lambda_1} - R_{\lambda_2}) / (R_{\lambda_1} + R_{\lambda_2}) \quad (2)$$

$$RSI = R_{\lambda_1} / R_{\lambda_2} \quad (3)$$

其中 R_{λ_1} 和 R_{λ_2} 分别为 350~2 500 nm 波段范围内的任意波段光谱反射率。

PLSR 方法由 Wold 等^[16]在 1983 年提出,其最大优势就是能够在自变量存在严重多重相关性的条件下进行有效回归建模。与 PCA 不同的是,PCA 的主成分仅取决于自变量的方差,而 PLSR 的潜变量通过考虑自变量以及目标变量之间的协方差,增加了预测准确性。但全波段 PLSR 模型包含大量冗余波段信息,为提高 PLSR 模型的预测性,采用竞争自适应重加权采样(competitive adaptive reweighted sampling, CARS)方法进行敏感波段提取,主要步骤:(1)蒙特卡洛模型抽样 N 次,分别建立 PLS 回归模型;(2)采用指数递减函

数(EDF)强制选择波段, 去除回归系数绝对值相对较小的波长; (3)采用自适应重采样进行波长竞争性选择, 选出回归系数绝对值较大的波长; (4)交叉验证, 选择最小 RMSE 对应的变量子集。本文将比较 CARS-PLSR 与 PLSR 的预测效果, 验证波段选取的有效性。

表 2 冬小麦叶片含水量的统计特征

Table 2 LWC of winter wheat during different growth stages

生育期	均值/ (g · g ⁻¹)	最大值/ (g · g ⁻¹)	最小值/ (g · g ⁻¹)	标准差/ (g · g ⁻¹)
拔节期	3.91	5.64	2.18	1.24
孕穗抽穗期	3.06	3.94	1.98	0.62
扬花期	2.54	3.32	1.79	0.46
灌浆期	2.02	2.75	1.13	0.47

模型构建与验证分析在 Matlab R2014a 中完成。模型预测精度选取建模集和验证集的决定系数 R², 均方根误差 RMSE 以及相对均方根误差 RRMSE 三个参数作为检测指标, 其计算公式见式(4)一式(6)。

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (5)$$

$$RRMSE = RMSE/\bar{y} \times 100\% \quad (6)$$

式中, \hat{y}_i 为叶片含水量的预测值, y_i 为叶片含水量的观测

值, \bar{y} 为叶片含水量的平均值; i 为样本序数, $i=1, 2, \dots, n$ 。 n 为样本数, 建模集 $n=84$, 验证集 $n=36$ 。

2 结果与讨论

2.1 原始光谱与一阶导数光谱经验植被指数相关性分析

将所有获取的叶片含水量与对应的高光谱反射率(R)及一阶导数光谱反射率(FDR)进行相关分析[图 1(a,b)]。结果显示, 在叶片尺度, 原始光谱在 1 520~1 550 nm 范围内呈现显著负相关(取 |R| 最大值的前 1%, 下同), 最大相关系数波长为 1 533 nm($r=-0.81$)。一阶导数光谱在 1 880~1 900 nm 范围内呈现显著负相关, 在 1 960~1 980 nm 范围内呈现显著正相关, 最大相关系数波长为 1 973 nm($r=0.86$)。在冠层尺度, 原始光谱在 1 950~1 965 和 1 995~2 010 nm 范围内呈现显著负相关, 最大相关系数波长为 1 959 nm($r=-0.60$)。一阶导数光谱在 555~580 nm 范围内和 1 738 nm 附近呈现显著负相关, 在 1 580 nm 附近呈现显著正相关, 最大相关系数波长为 563 nm($r=-0.63$)。结果表明, 在叶片尺度, 原始光谱和一阶导数光谱的水分敏感波段都位于短波红外区域(1 300~2 500 nm); 在冠层尺度, 原始光谱的水分敏感波段均位于短波红外区域, 而一阶导数光谱的水分敏感波段则分布在绿光区域以及短波红外区域, 与前人研究结果相似^[17]。




图 1 冬小麦叶片含水量与原始光谱及一阶导数光谱反射率的相关性

(a): 叶片尺度光谱; (b): 冠层尺度光谱

Fig. 1 The correlation between LWC and reflectance of original reflectance and its first derivative reflectance

(a): Leaf scale reflectance; (b): Canopy scale reflectance

2.2 叶片、冠层尺度下冬小麦 LWC 模型构建与分析

2.2.1 两波段植被指数回归建模

基于原始光谱, 一阶导数光谱分别构建叶片、冠层尺度的两波段植被指数(NDSI, RSI), 通过植被指数与叶片含水量的 R² 等值线图进行敏感波段组合筛选(图 2), 模型预测效果汇总于表 3。

由图 2 可以看出, 对比不同指数类型, NDSI 与 RSI 对 LWC 的敏感波段组合类似, 相同的敏感波段组合下, RSI 比 NDSI 与 LWC 有更高的 R²; 对比不同尺度光谱可知, 构建的

叶片光谱指数与冠层光谱指数与 LWC 具有类似的敏感区域, 不同波段组合下, 叶片光谱指数与 LWC 的相关性大于冠层光谱指数; 对比不同光谱处理类型可知, 原始光谱指数的敏感波段组合主要分布在近红外(750~1 300 nm)和短波红外波段(1 300~1 900 nm)范围内, 而一阶导数光谱指数的敏感波段组合主要分布在短波红外波段范围(1 300~2 100 nm)内, 对比原始光谱指数, 一阶导数光谱 R² 等值线图中峰带宽较小。

由表 3 可知, 对于叶片尺度, NDSI($R_{1\ 162}, R_{1\ 321}$), RSI

($R_{1\ 162}, R_{1\ 321}$)与叶片含水量相关性最高(验证集 R^2 为 0.871 和 0.872, RMSE 为 0.354 和 0.352), 在冠层尺度, NDSI ($R_{1\ 653}, R_{1\ 683}$), RSI($R_{1\ 684}, R_{1\ 652}$)与叶片含水量相关性最高(验证集 R^2 为 0.811 和 0.817, RMSE 分别为 0.482 和 0.474)。同样利用一阶导数光谱进行指数构建, 在叶片尺度,

NDSI($R_{1\ 381}, R_{1\ 977}$), RSI($R_{1\ 977}, R_{1\ 380}$)与叶片含水量相关性最高(验证集 R^2 为 0.764 和 0.753, RMSE 为 0.498 和 0.508), 在冠层尺度, NDSI($R_{563}, R_{1\ 509}$), RSI($R_{1\ 288}, R_{766}$)与叶片含水量相关性最高(验证集 R^2 为 0.490 和 0.669, RMSE 为 0.935 和 0.764)。




图 2 NDSI, RSI 与 LWC 的决定系数 R^2 等值线图

(a): NDSI-叶片原始光谱; (b): NDSI-叶片一阶导数光谱; (c): NDSI-冠层原始光谱; (d): NDSI-冠层一阶导数光谱;
(e): RSI-叶片原始光谱; (f): RSI-叶片一阶导数光谱; (g): RSI-冠层原始光谱; (h): RSI-冠层一阶导数光谱

Fig. 2 R^2 contour map for NDSI and LWC (a, b, c, d); R^2 contour map for RSI and LWC (e, f, g, h)

(a): NDIS-leaf-R; (b): NDIS-leaf-FDR; (c): NDSI-canopy-R; (d): NDSI-canopy-FDR;
(e): RSI-leaf-R; (f): RSI-leaf-FDR; (g): RSI-canopy-R; (h): RSI-canopy-FDR

表 3 新构建的植被指数对冬小麦叶片含水量估算效果分析

Table 3 Results of model performance analysis by calibration and validation data sets

光谱 尺度	光谱 类型	指数 类型	建模集($n=84$)				验证集($n=36$)				
			λ_1	λ_2	方程式	R^2	RMSE	RRMSE/%	R^2	RMSE	RRMSE/%
叶片光谱	原始	NDSI	1 162	1 321	$y=267.25x-1.396\ 3$	0.855	0.376	13.80	0.871	0.354	13.14
		RSI	1 162	1 321	$y=129.3x-130.63$	0.856	0.375	13.75	0.872	0.352	13.09
	导数	NDSIst	1 381	1 977	$y=-3.571\ 5x+8.331\ 9$	0.854	0.372	13.47	0.764	0.498	19.13
		RSIst	1 977	1 380	$y=9.61x+4.891\ 9$	0.864	0.360	13.01	0.753	0.508	19.52
冠层光谱	原始	NDSI	1 653	1 683	$y=-208.46x+2.863\ 8$	0.730	0.488	18.20	0.811	0.482	17.22
		RSI	1 684	1 652	$y=99.189x-96.305$	0.731	0.486	18.15	0.817	0.474	16.94
	导数	NDSIst	563	1 509	$y=-0.128\ 5x+1.968\ 4$	0.610	0.548	20.23	0.490	0.935	34.22
		RSIst	1 288	766	$y=-1.338\ 7x+1.804$	0.649	0.520	19.21	0.669	0.764	27.95

2.2.2 PLSR/CARS-PLSR 回归建模

PLSR 采用留一法(leave-one-out)进行交叉验证, 通过使交叉验证集的 RMSE 最小确定最优潜在变量个数。将所有数据随机分成建模集(70%)和验证集(30%), 考虑到抽样本身具有随机性, 故为提高模型预测效果的稳健性, 研究中进行了 10 000 次重复抽样, 取验证集 R^2 出现频率最高时对应的建模与验证子集作为模型运行数据集。其中 CARS 波段筛选结果见图 3, PLSR 与 CARS-PLSR 回归模型的预测效果汇总于表 4。

由图 3 可知, CARS-PLSR 筛选出的波段大致分为两部分, 一部分在 1 200, 1 450, 1 950, 2 100 以及 2 350 nm 等水

敏感波段附近, 另一部分在可见光及红边等与色素、胁迫强度相关的波段范围内, 与 Cater 等^[17]的研究结果一致。

根据表 4, PLSR 与 CARS-PLSR 回归模型无论在叶片还是冠层尺度的预测效果都较好($R^2 > 0.66$, RRMSE < 14%)。对比不同方法可知, 无论是基于不同尺度还是不同光谱处理形式, CARS-PLSR 仅利用不足全波段 2% 的波段数信息, 就获得优于 PLSR 的预测效果, 表明 CARS 方法能够筛选出对叶片含水量较敏感的波段。通过分析两种方法验证集 R^2 分布[图 4(a-h)]可以看出, 在 10 000 次随机抽样中, CARS-PLSR 方法验证集的 R^2 分布比 PLSR 更集中且更靠近 1, 且频率最高点对应的被选次数更高, 这表明全波段

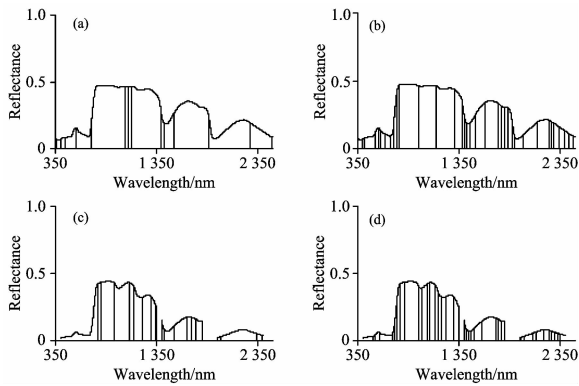


图 3 平均光谱以及 CARS 方法筛选出的波段

(a): 叶片-原始光谱; (b): 叶片—一阶导数光谱;
(c): 冠层-原始光谱; (d): 冠层—一阶导数光谱

Fig. 3 The average reflectance spectra with the selected wavebands via CARS

(a): Leaf-R; (b): Leaf-FDR; (c): Canopy-R; (d): Canopy-FDR

表 4 PLSR, CARS-PLSR 对冬小麦叶片含水量估算效果分析

Table 4 Results of model performance analysis by calibration and validation data sets

光谱尺度	方法	光谱类型	潜变量 个数	建模集 (n=84)			验证集 (n=36)		
				R ²	RMSE	RRMSE/%	R ²	RMSE	RRMSE/%
叶片	PLSR	原始	22	0.995	0.072	2.62	0.953	0.196	7.55
		导数	8	0.993	0.071	2.71	0.947	0.245	8.40
	CARS-PLSR	原始	17	0.976	0.140	5.15	0.955	0.209	7.71
		导数	35	0.986	0.121	4.46	0.969	0.164	6.00
冠层	PLSR	原始	17	0.974	0.140	5.42	0.835	0.402	13.38
		导数	18	0.995	0.070	2.52	0.662	0.563	21.74
	CARS-PLSR	原始	17	0.918	0.272	9.86	0.877	0.289	11.06
		导数	36	0.944	0.236	8.76	0.881	0.372	13.41

作物中叶片含水量的及时评估对于作物的干旱诊断和精确水分管理至关重要。分别比较了三种不同统计方法对冬小麦叶片含水量的预测效果。结果表明：三种方法中，基于叶片一阶导数光谱的 CARS-PLSR 模型对 LWC 的预测效果最好，CARS 方法能提取与叶片含水量密切相关的敏感波段，从而提高模型预测效果。相比之下，两波段指数方法会“丢失”一些有效波段信息，而 PLSR 方法可能会包含一些具有干扰性的无效波段信息。

在三种方法中，叶片尺度的 LWC 估算效果均优于冠层尺度。但是，叶片尺度下的光谱监测难以向大区域推广。结果表明，在没有叶片光谱观测的条件下，基于冠层原始光谱的三种方法也可以达到较好的 LWC 预测效果 ($R^2 > 0.81$)，其中基于冠层一阶导数光谱的模型在 CARS-PLSR 方法下取得较好的预测效果 ($R^2 = 0.881$)。从光谱特性可知，叶片含水量敏感波段处于近红外与短波红外范围，考虑到叶片结构以及叶面积指数影响的波段也主要处于短波红外范围，因此两波段指数以及 CARS 所筛选出的波段可能不仅仅对 LWC 敏感，同时所选波段的内在机理仍有待进一步研究，以期选出普适的波段组合。

的 PLSR 方法包含与 LWC 无关的波段信息，一定程度上影响 PLSR 对 LWC 的预测效果。相比之下，通过 CARS 提取特征波段可以保留有效波段信息，剔除无效波段信息，降低模型的复杂程度，获得较高的预测能力。因此 CARS-PLSR 模型对 LWC 的预测效果比 PLSR 模型好且具有更强的稳健性。对比基于叶片、冠层光谱的模型可以发现，基于叶片光谱的模型验证集 R^2 分布均比基于冠层光谱的更集中且更接近 1，可以说明基于叶片光谱建模的预测效果优于基于冠层光谱的建模且更具有稳健性。对比基于原始光谱和一阶导数光谱模型可以发现，在 CARS-PLSR 方法中，基于一阶导数光谱的模型预测效果优于基于原始光谱模型。

再对比 2.2.1 中构建的两波段指数，PLSR 以及 CARS-PLSR 模型的预测能力优于两波段指数模型，究其原因 PLSR 以及 CARS-PLSR 利用了更多与 LWC 相关波段信息，避免了两波段指数模型存在的有效信息“丢失”问题，因此具有更佳的预测效果。

本试验的水分差异处理从拔节后期开始一直持续至冬小麦成熟。通过人为设置不同水分差异处理，在不同生育期获取叶片含水量数据。由于不同生育期造成叶片含水量变化的原因不同，在作物生长期，叶片含水量降低主要受水分胁迫影响，而在作物生殖期，叶片开始衰老，叶片含水量自然降低，叶片含水量的变化并非单纯受到水分胁迫的影响。因此，未来的研究应考虑划分生育期构建叶片含水量估算模型。另外，试验设计目前缺乏不同作物品种间的对比，且研究结论是否适合小区试验或大田试验，在今后也需要深入研究。

3 结 论

(1) 对比三种不同统计回归的方法，发现基于叶片一阶导数光谱的 CARS-PLSR 模型对 LWC 的预测效果最好 ($R^2 = 0.969$, $RMSE = 0.164$, $RRMSE = 6.00\%$)。

(2) 在两波段植被指数法中，NDSI 与 RSI 具有相似的水分敏感区域，其中基于叶片原始光谱的 $NDVI(R_{162}, R_{1321})$ 和 $RSI(R_{162}, R_{1321})$ 模型对叶片含水量预测效果最好。在相




图 4 PLSR 模型验证集 R^2 分布图(a, b, c, d); CARS-PLSR 模型验证集 R^2 分布图(e, f, g, h)

(a): PLSR-叶片原始光谱; (b): PLSR-叶片一阶导数光谱; (c): PLSR-冠层原始光谱;
(d): PLSR-冠层一阶导数光谱; (e): CARS-PLSR-叶片原始光谱; (f): CARS-PLSR-叶片一阶导数光谱;
(g): CARS-PLSR-冠层原始光谱; (h): CARS-PLSR-冠层一阶导数光谱

Fig. 4 R^2 histograms of validation set of the PLSR model (a, b, c, d); R^2 histograms of validation set of the CARS-PLSR model (e, f, g, h)

(a): PLSR-leaf-R; (b): PLSR-leaf-FDR; (c): PLSR-canopy-R; (d): PLSR-canopy-FDR;
(e): CARS-PLSR-leaf-R; (f): CARS-PLSR-leaf-FDR; (g): CARS-PLSR-canopy-R; (h): CARS-PLSR-canopy-FDR

同情况下 RSI 对叶片含水量的预测效果优于 NDSI。

(3)对比原始、一阶导数光谱两种光谱处理形式,在两波段指数和 PLSR 方法中,基于原始光谱的模型对叶片含水

量的预测效果优于基于一阶导数光谱的模型,在 CARS-PLSR 方法中,结果相反。

References

- [1] Verrelst J, Camps-Valls G, Muñoz-Mari J, et al. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 108: 273.
- [2] Thomas J R, Namken L N, Oerther G F, et al. Agronomy Journal, 1971, 63(6): 845.
- [3] Curran P J. Remote Sensing of Environment, 1989, 30(3): 271.
- [4] TIAN Qing-jiu, GONG Peng, ZHAO Chun-jiang, et al(田庆久, 宫 鹏, 赵春江, 等). Chinese Science Bulletin(科学通报), 2000, 45(24): 2645.
- [5] WANG Ji-hua, ZHAO Chun-jiang, GUO Xiao-wei, et al(王纪华, 赵春江, 郭晓维, 等). Scientia Agricultura Sinica(中国农业科学), 2001, 34(1): 104.
- [6] Danson F M, Steven M D, Malthus T J, et al. International Journal of Remote Sensing, 1992, 13(3): 461.
- [7] Kumar L. Geocarto International, 2007, 22(1): 3.
- [8] Clevers J G P W, Kooistra L, Schaepman M E. International Journal of Applied Earth Observation and Geoinformation, 2010, 12: 119.
- [9] Mirzaie M, Darvishzadeh R, Shakiba A, et al. International Journal of Applied Earth Observation and Geoinformation, 2014, 26: 1.
- [10] Jacquemoud S. Remote Sensing of Environment, 1993, 44(2-3): 281.
- [11] Cho M A, Skidmore A, Corsi F, et al. International Journal of Applied Earth Observation and Geoinformation, 2007, 9(4): 414.
- [12] Das B, Sahoo R N, Pargal S, et al. Biosystems Engineering, 2017, 160: 69.
- [13] Inoue Y, Miah G, Sakaiya E, et al. Journal of the Remote Sensing Society of Japan, 2008, 28(4): 317.
- [14] Li H, Liang Y, Xu Q, et al. Analytica Chimica Acta, 2009, 648(1): 77.
- [15] YANG Bao-hua, CHEN Jian-lin, CHEN Lin-hai, et al(杨宝华, 陈建林, 陈林海, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2015, 31(22): 176.
- [16] Wold S, Martens H, Wold H. The Multivariate Calibration Problem in Chemistry Solved by the PLS Method: Springer, Berlin, Heidelberg, 1983. 286.
- [17] Cater G A. American Journal of Botany, 1991, 78(7): 916.

Estimation of Winter Wheat Leaf Water Content Based on Leaf and Canopy Hyperspectral Data

CHEN Xiu-qing, YANG Qi, HAN Jing-ye, LIN Lin, SHI Liang-sheng*

State Key Laboratory of Water Resources and Hydropower Engineering Science, Wuhan University, Wuhan 430072, China

Abstract Fast and nondestructive monitoring of leaf water content (LWC) is critical to crop drought diagnosis and irrigation decision. In order to quantify and predict the LWC with hyperspectral remote sensing data, field experiments of winter wheat with different water-deficit stress levels were conducted for two consecutive years (2016—2017 and 2017—2018). Hyperspectral reflectance was recorded at four growth stages. Then, normalized difference spectral index (NDSI) and ratio spectral index (RSI) were calculated in all possible combinations within 350–2500 nm, and their correlations with LWC were quantified to identify the best indices. Spectral data were also used to build partial least squares regression (PLSR) and competitive adaptive reweighted sampling- partial least squares regression (CARS-PLSR) model to calculate LWC. Two different data forms (original and first derivative reflectance) and two different observation scales (leaf and canopy) were used to explore the suitability of these three algorithms on estimating LWC for winter wheat. Additionally, in order to avoid sampling uncertainty when constructing calibration and validation datasets, a method of increasing the number of sampling times was proposed to improve the robustness of prediction models. The results showed that the best spectral indices for estimating LWC of winter wheat were NDSI ($R_{1\ 162}, R_{1\ 321}$) and RSI($R_{1\ 162}, R_{1\ 321}$) with R^2 of 0.871 and 0.872 respectively, which were both based on original leaf reflectance. RSI models had higher estimation accuracy than NDSI models under the same situation. The PLSR model based on original leaf reflectance obtained the best performance for predicting LWC with R^2 of 0.953. CARS-PLSR based on the first derivative leaf reflectance was the most accurate model ($R^2=0.969$; RMSE=0.164; RRMSE=6%). It was indicated that in terms of different forms of hyperspectral data, the original spectral-based models were better than the first derivative spectral-based models in two-band vegetation index and PLSR models, but the results were reversed for the CARS-PLSR model. While for different observation scales, LWC had stronger correlations with leaf reflectance-based models than that of the canopy based models. Overall, CARS-PLSR delivered better performance than the other two methods. In light of this, CARS was a feasible band selection algorithm and the prediction accuracy of CARS-PLSR model for LWC estimation of winter wheat was better than that of the other two models. CARS-PLSR method provides a promising approach for accurate and rapid monitoring of winter wheat drought.

Keywords Leaf water content; Partial least squares regression; Competitive adaptive reweighted sampling; Winter wheat; Hyperspectral remote sensing

(Received Dec. 21, 2018; accepted Mar. 12, 2019)

* Corresponding author