

基于光谱和纹理信息空间尺度优化的夏玉米冠层 EWT 反演模型

陈洪 王亚昆 姚一飞 代秦 陈子强 刘畅 李高良 胡笑涛

(西北农林科技大学旱区农业水土工程教育部重点实验室, 陕西杨凌 712100)

摘要: 针对空间异质性导致的冠层等效水厚度 (Equivalent water thickness, EWT) 反演误差较大的问题, 以 4 块长势差异较大的玉米田为研究对象, 分别采集 6 个关键生育节点的 EWT 数据, 同时利用无人机多光谱遥感技术获取田间的正射影像。以滑动窗口的方式提取遥感影像不同窗口空间尺寸 (0.1 m × 0.1 m ~ 2.0 m × 2.0 m) 的光谱和纹理信息, 经多重共线性检验后, 应用主成分分析法 (Principal component analysis, PCA) 分别对光谱参数 (Spectral parameters, S)、纹理参数 (Texture parameters, T) 及光谱与纹理组合参数 (Spectral and texture parameters, S + T) 进行降维, 进而分别利用偏最小二乘法 (Partial least squares, PLS)、随机森林 (Random forest, RF) 以及支持向量机 (Support vector machine, SVM) 构建 EWT 反演模型, 而后利用 Kruskal - Wallis 检验模型的精度, 并根据多重检验结果探讨最佳窗口尺寸的选择。结果表明: 随着窗口空间尺度的逐渐增大, EWT 反演模型的精度呈先增大后减小趋势; 以 S + T 作为输入参数构建的模型精度显著优于 S 和 T, 引入纹理特征后, 基于 PLS、RF 和 SVM 的模型最优窗口尺寸校正决定系数 (Adjusted R - square, R_{adj}^2) 分别增加 0.16、0.05 和 0.12, 相对均方根误差 (Relative root mean square error, RRMSE) 分别减小 4.95%、1.17% 和 3.80%, 表明纹理特征可以提高 EWT 模型反演精度; 综合比较不同建模方法构建的 9 组模型, 确定最优采样窗口空间尺寸为 0.7 m × 0.7 m (R_{adj}^2 最高可达 0.82, 对应的 RRMSE 为 16.57%)。该研究可为基于无人机多光谱影像分析的信息挖掘和 EWT 监测提供参考。

关键词: 玉米; 等效水厚度; 多光谱遥感; 纹理特征; 空间尺度; 机器学习

中图分类号: S252; TP79 文献标识码: A 文章编号: 1000-1298(2024)12-0257-11

OSID:



EWT Inversion Model of Summer Maize Based on Spatial Scale Optimization of Spectral and Texture Information

CHEN Hong WANG Yakun YAO Yifei DAI Qin CHEN Ziqiang LIU Chang LI Gaoliang HU Xiaotao

(Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas, Ministry of Education,
Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: In order to solve the problem of large canopy equivalent water thickness (EWT) inversion error caused by spatial heterogeneity, taking four maize fields with large growth differences as the research object, EWT data of six key growth nodes was collected, and UAV multispectral remote sensing technology was used to obtain orthophoto images in the field, and the spectral and texture information of different window space sizes (0.1 m × 0.1 m to 2.0 m × 2.0 m) of remote sensing images in the form of sliding windows was extracted, and after multicollinearity testing, principal component analysis (PCA) was used to reduce the dimensionality of spectral parameters (S), texture parameters (T) and combinatorial parameters (S + T), respectively, and then the EWT inversion model was constructed by partial least squares (PLS), random forest (RF) and support vector machine (SVM), respectively, and then the accuracy of the model was tested by Kruskal - Wallis, and the choice of optimal window size was discussed according to the results of multiple tests. The results showed that with the gradual increase of the window space scale, the accuracy of the EWT inversion model was increased firstly and then decreased. The accuracy of the model constructed with the S + T as the input variable was significantly

收稿日期: 2024-07-04 修回日期: 2024-08-27

基金项目: 国家自然科学基金项目 (U2243235)

作者简介: 陈洪 (2000—), 男, 硕士生, 主要从事智慧水利研究, E-mail: 18784866737@nwfau.edu.cn

通信作者: 胡笑涛 (1972—), 男, 教授, 博士生导师, 主要从事节水灌溉理论与技术研究, E-mail: huxiaotao11@nwsuaf.edu.cn

better than that of the S and the T, and the adjusted R-square (R_{adj}^2) of the optimal window size of the model based on PLS, RF and SVM was increased by 0.16, 0.05 and 0.12, respectively, and the relative root mean square error (RRMSE) was decreased by 4.95%, 1.17% and 3.80%, respectively. The results showed that it was feasible to use texture features to improve the inversion accuracy of EWT model. Comprehensively comparing the nine sets of models constructed by different modeling methods, the optimal sampling window spatial size was finally determined to be 0.7 m × 0.7 m, with R_{adj}^2 up to 0.82 (corresponding RRMSE of 16.57%). The research result can provide a reference for information mining and EWT monitoring based on UAV multi-spectral image analysis.

Key words: maize; equivalent water thickness; multispectral remote sensing; textural features; spatial scale; machine learning

0 引言

冠层等效含水层厚度 (Equivalent water thickness, EWT) 是反映作物水分状况的重要生理指标,大量研究表明其适用于多种空间尺度的植被水分状况遥感监测^[1-3]。无人机遥感技术为 EWT 监测提供了一种更为高效、精准的方式。相较于可见光、热红外和高光谱等遥感技术,无人机多光谱遥感技术由于成本较低、波段连续性较强和影像分辨率高等优点被广泛应用于作物水分监测领域^[4-5]。早期的 EWT 评估大多借助一些线性或简单的非线性拟合方法寻找 EWT 与光谱指数之间的关系^[6-7],然而已有研究中回归模型的估算精度和泛化能力均存在一定限制^[8]。近年来,机器学习 (Machine learning, ML) 方法因其计算的先进性,在利用多光谱和高光谱反射率数据估算作物生物物理参数方面表现出良好的性能^[1,9]。然而,ML 仍存在一些缺点,如其输入数据间可能存在的多重共线性往往会导致 ML 模型复杂度增加、可解释性变差,还可能使得模型发生过拟合现象^[10]。因此,主成分分析 (Principal component analysis, PCA) 等降维方法被用于减少数据冗余和噪声中^[11]。此外,在作物生长的早期阶段,光谱信息容易受到土壤和杂草等背景噪声的干扰,而在后期阶段,密集的冠层可能导致光谱饱和现象^[12-13]。上述因素限制了作物水分状况监测准确性的进一步提高,近年来,有研究发现遥感图像纹理特征能提高农作物表型监测的精度^[2,14-15]。然而,利用高分辨率图像纹理估计作物 EWT 的研究还较少。

由于地表的复杂性和遥感信息多空间分辨率的特点,使得从定量遥感出发的地学描述必然存在多尺度的问题^[16]。目前,利用低空无人机遥感开展的试验研究大部分是有明确边界的小区试验,研究者往往直接将遥感图像上的小区边界作为提取光谱信息的空间窗口^[9]。然而,这种方法未必适用于大区试验,在大区试验中,研究者一般根据地面采样点对

应的遥感影像单像元数据建立相关指标的反演模型^[17]。在一定采样空间内,不同像素之间的光谱信息极易受到地面粗糙度和植被分布等因素的影响^[18],导致邻近像元之间的灰度值产生突变从而使反演模型表现出不稳定的特性。同时,由于无人机多光谱像元往往可达厘米甚至毫米级别,要在包含数十公顷田块的遥感影像中使像元与地面采样点精确匹配显得尤为艰难。为了从无人机遥感影像中提取出更具代表性的像素信息,一些研究人员选择一定尺寸的窗口提取光谱信息,然而在目前的研究中,大部分采样窗口空间尺度的确定主要是根据人为经验,而非基于某种系统的理论或研究^[19]。因此,有必要就光谱信息提取的窗口空间尺度优化问题进行研究。

本文以夏玉米 EWT 作为水分状况指标,基于多种 ML 方法,以不同空间尺度下的纹理特征、光谱特征及其组合作为输入参数构建 EWT 反演模型。主要目的有:研究不同窗口尺寸 EWT 反演模型对 3 种 ML 方法的响应;研究纹理特征的引入对不同窗口尺寸 EWT 反演模型精度的影响;综合多种 ML 方法和模型输入参数,基于 Kruskal - Wallis 检验筛选出 EWT 反演模型的最优采样窗口尺寸,以期对不同 ML 方法和模型输入参数组合条件下夏玉米 EWT 估测的最优采样窗口空间尺度选择提供参考。

1 材料与方法

1.1 研究区概况

试验于陕西省咸阳市武功县海鑫皇嘉农业示范园(34°21'N, 108°03'E)进行,如图 1 所示。该地区属于温带半湿润性季风气候,年平均气温为 12.9℃,多年平均降雨量为 597 mm,无霜期为 210 d,试验地 A、B、C、D 面积各为 1 hm²,土壤类型为壤土,0 ~ 20 cm 土层土壤容重为 1.36 g/cm³^[20]。试验的播种、施肥、灌水、除害、收获等管理均由工人按照农场的耕作管理模式进行。夏玉米播种时间为 2023 年 6 月 20—27 日,品种为延科 288,行距 70 cm,株距 30 cm。




图 1 试验区示意图

Fig. 1 Diagram of study area

1.2 数据采集与处理

1.2.1 田间数据采集

分别于 2023 年 7 月 20 日 (T1)、8 月 2 日 (T2)、8 月 10 日 (T3)、8 月 19 日 (T4)、8 月 30 日 (T5)、9 月 7 日 (T6) 等 6 个关键生育期,在作物长势空间异质性较大的 4 块玉米地 (A, B, C, D) 中以对角线取样法采集 EWT 样品 72 个。采集的参数包括叶片鲜质量 (Fresh weight, F_w)、叶片干质量 (Dry weight, D_w)、对应叶长 (Blade length, B_l) 和叶宽 (Blade width, B_w) 等。EWT 计算公式为^[21]

$$EWT = \frac{10(F_w - D_w)}{0.75d_w B_l B_w} \quad (1)$$

式中 d_w ——水的密度, g/cm^3

1.2.2 无人机多光谱数据采集

试验采用大疆公司研发的 MAVIC 3M 型无人机 (搭载一体式多光谱成像系统) 获取冠层反射率数据及可见光图像。多光谱成像系统集成 1 个 2 000 万像素的可见光相机和 4 个 500 万像素的多光谱相机,可见光相机用于可见光 (RGB) 成像,多光谱相机用于绿 (G, 中心波长: $560 \text{ nm} \pm 16 \text{ nm}$)、红 (R, 中心波长: $650 \text{ nm} \pm 16 \text{ nm}$)、红边 (RE, 中心波长: $730 \text{ nm} \pm 16 \text{ nm}$) 和近红外 (NIR, 中心波长: $860 \text{ nm} \pm 26 \text{ nm}$) 4 个波段的成像。无人机执行航线任务之前先在距离地面 1.0 m 高度附近拍摄一组辐射定标板的正射影像用于辐射校正。采集时间为 2023 年 7 月 20 日、8 月 2 日、8 月 10 日、8 月 19 日、8 月 30 日、9 月 7 日的当地时间 10:00—14:00。遥感影像的采集均在晴朗无风天气进行,无人机飞行高度为 40 m,对应地面分辨率为 1.38 cm/像素,飞行速度为 5 m/s,航向重叠率和旁

向重叠率分别设置为 80% 和 70%。

1.2.3 光谱指数与纹理特征提取

首先,通过 DJI Terra 软件对遥感影像进行辐射校正、拼接;之后,通过 Matlab R2021b 对正射影像进行裁剪、波段运算;与此同时,利用灰度共生矩阵 (Gray-level co-occurrence matrix, GLCM) 分别提取 4 种光谱 (G、R、RE、NIR) 图像的对比度 (Contrast, CON)、相关性 (Correlation, COR)、能量 (Energy, ENE) 和同质性 (Homogeneity, HOM) 共计 4×4 组纹理特征,并利用局部平均法提取以采样点为中心的 $0.1 \text{ m} \times 0.1 \text{ m} \sim 2.0 \text{ m} \times 2.0 \text{ m}$ 范围内的像素均值。根据前人经验及多光谱传感器波段范围选择 16 种与作物水分相关的光谱指数参与后续计算与分析,主要包括 NDVI^[22]、NDRE^[23]、GNDVI^[24]、NDGI^[25]、RVI^[26]、SRVI^[26]、DVI^[27]、RDVI^[28]、MSR^[29]、TCARI^[30]、MCARI^[31]、NLI^[32]、TVI^[33]、SAVI^[34]、MSAVI^[35] 和 GCI^[24] 等。

1.3 模型构建及评价

1.3.1 主成分分析

方差膨胀因子 (Variance inflation factor, VIF) 是衡量多重共线性严重程度的一种度量,若 VIF 大于 10,表明回归模型存在严重的多重共线性^[36]。VIF 计算公式为

$$VIF = \frac{1}{1 - R_i^2} \quad (2)$$

式中 R_i ——回归分析中某一自变量对其余自变量的相关系数

主成分分析 (Principal component analysis, PCA) 是一种数据转换技术,用于将多维数据集减少到更

低的维数以进行进一步分析^[37]。采用主成分分析法分别对 20 组光谱参数(Spectral parameters,S)、16 组纹理参数(Texture parameters,T)及 36 组光谱、纹理组合参数(Spectral and texture parameters,S + T)进行降维,并选取累积贡献率占 85% 以上的主成分作为模型的输入参数。上述 S 包括 4 组光谱波段和 16 组光谱指数;T 包括 16 组纹理特征。

1.3.2 建模方法

本文使用偏最小二乘(Partial least squares, PLS)、随机森林(Random forest, RF)和支持向量机(Support vector machines, SVM)3 种不同的 ML 方法构建回归模型。PLS 是一种多元统计数据分析方法,其特点是在进行回归建模的同时进行数据结构简化及典型相关分析^[38]。RF 是一种基于集成学习的算法,通过构建多个决策树并集成它们的预测结果进行回归,其优点在于每棵决策树都是独立的,并且训练过程在随机的子样本上进行,可有效地减少过拟合的风险^[39]。SVM 核心原理是通过最小化预测误差来拟合数据,并且在拟合过程中保持一个边界,使得大部分数据点都落在边界之内^[40]。

为使本文表述更简洁,建模方法特指 3 种 ML 方法(PLS、RF、SVM)和 3 种输入参数(S、T、S + T)所构成的 9 种组合(PLS_S、PLS_T、PLS_S + T、RF_S、RF_T、RF_S + T、SVM_S、SVM_T、SVM_S + T)。

1.3.3 模型评价

为了避免 R^2 随着自变量的个数增加而增加的问题,采用校正决定系数(Adjusted R - square, R^2_{adj})评价回归模型拟合优度^[41];相对均方根误差(Relative root mean square error, RRMSE)评价回归模型拟合值与真实值的差异程度,相较于均方根误差(Root mean square error, RMSE),RRMSE 将该差异相对于真实值的范围进行了归一化,更有利于不同模型之间的比较^[42]。

1.3.4 统计分析方法

Kruskal - Wallis 检验又称 H 检验,是一种非参数检验方法,可用于正态分布条件不满足情况下,多组独立样本方差分析的替代。

利用 Matlab R2021b 软件进行 Kruskal - Wallis 非参数检验,以确定不同窗口空间尺度条件下,基于不同 ML 方法和输入参数构建的 EWT 模型精度是否存在显著性差异($\alpha = 0.05$)。

2 结果与分析

2.1 EWT 动态变化及分析

4 块试验田(A、B、C、D)在不同生育期(T1、T2、

T3、T4、T5、T6)的 EWT 分布情况如图 2 所示,从图 2 可以看出,夏玉米生长的 T1 ~ T6 阶段,EWT 分布呈现显著差异,全生育期内整体呈现递减的趋势,且除 T5 时期外,4 块试验田之间也存在 EWT 分布不均的情况。将 EWT 数据集按比例 2:1 分为训练集样本(48 个)和测试集样本(24 个)并进行统计分析,其中训练集最大值、最小值、中位数、均值和标准差分别为 0.790、0.099、0.219、0.272、0.139 mm;测试集最大值、最小值、中位数、均值和标准差分别为 0.574、0.116、0.220、0.267、0.125 mm,由此可知测试集和训练集统计结果相似,这使得训练集和测试集之间的偏差最小化,为模型强“鲁棒性”提供了基础^[44]。




图 2 EWT 分布的时空差异

Fig.2 Spatial and temporal differences in EWT distribution

2.2 主成分分析

2.2.1 多重共线性检验

在回归分析中,如果 2 个或 2 个以上自变量之间存在相关性,这种自变量之间的相关性称作多重共线性(Multicollinearity),严重的多重共线性会使模型估计失真或难以估计准确^[45]。因此,在模型构建之前利用方差膨胀因子(VIF)评估 36 组光谱及纹理参数之间的多重共线性。计算各自变量间的 VIF,由于存在部分变量之间的 VIF 值过大的问题,将 VIF 计算结果进行对数变换(图 3),普遍认为若 $VIF \geq 10$ 即 $\lg VIF \geq 1$,则表明变量间存在严重多重共线性^[46]。由图 3 可知,不同窗口尺寸下所有变量均满足 $\lg VIF \geq 1$,因此,有必要对光谱及纹理参数进行降维以提高模型的精度和稳定性。

2.2.2 PCA 降维

为消除多重共线性,利用主成分分析(PCA)分别对 S、T 及 S + T 参数进行降维,以提高回归模型的精度和稳定性。分别对不同窗口尺寸的 S、T 以及 S + T 进行主成分分析后,选择累积贡献率大于 85% 的主成分作为模型输入参数。如图 4 所示,经




图 3 光谱及纹理参数间的 lgVIF

Fig. 3 lgVIF between spectral and texture parameters




图 4 PCA 降维后的主成分数量及累积贡献率

Fig. 4 Number of principal components and cumulative contribution rate of PCA after dimensionality reduction

PCA 降维后,不同窗口尺寸下 S 的主成分数量均为 3,T 和 S+T 的主成分数量分别在 3~5 和 5~8 之间,为了消除自变量数量对回归模型的影响,分别选取 S、T 和 S+T 的前 3、前 5 和前 8 个主成分作为回归模型的输入参数。

2.3 模型结果和评价

2.3.1 模型结果

图 5 为根据 3 种 ML 方法 (PLS、RF、SVM) 和 3 种输入参数 (S、T、S+T) 构建的 9 组 EWT 评估模型精度评价指标 (R^2_{adj} 、RRMSE) 与采样窗口尺寸之间的关系。从图 5 中可以看出,在窗口尺寸 0.1 m × 0.1 m ~ 2.0 m × 2.0 m 范围内,随着窗口尺寸的逐渐

增大,模型 R^2_{adj} 整体均呈先增大后减小趋势,RRMSE 则呈先减小后增大的趋势。从不同窗口尺寸的模型整体精度来看,不同 ML 方法构建的模型精度从高到低依次为:SVM、RF、PLS;不同输入参数构建的模型精度从高到低依次为:S+T、S、T。

随着构建模型的 ML 方法或输入参数的变化,对应的最优窗口尺寸也发生变化(表 1)。当输入参数为 S 时,基于 PLS、RF 和 SVM 建模的最优窗口尺寸分别为 0.7 m × 0.7 m、0.6 m × 0.6 m 和 0.4 m × 0.4 m,对应的 R^2_{adj} 分别为 0.61、0.65 和 0.71;对应的 RRMSE 分别为 22.73%、20.98% 和 20.37%。当输入参数为 T 时,基于 PLS、RF 和 SVM 建模的最优窗口尺寸分别为 1.5 m × 1.5 m、1.1 m × 1.1 m 和 0.9 m × 0.9 m,对应的 R^2_{adj} 分别为 0.63、0.61 和 0.60,对应的 RRMSE 分别为 21.99%、22.37% 和 23.70%。当输入参数为 S+T 时,基于 PLS、RF 和 SVM 建模的最优窗口尺寸分别为 0.6 m × 0.6 m、0.5 m × 0.5 m 和 0.7 m × 0.7 m,对应的 R^2_{adj} 分别为 0.77、0.70 和 0.82;对应的 RRMSE 分别为 20.98%、19.81% 和 16.57%。通过对比可以发现,输入参数引入纹理特征后,PLS、RF 和 SVM 最优窗口尺寸相应的模型 R^2_{adj} 分别增加 0.16、0.05 和 0.12,RRMSE 减少 4.95%、1.17% 和 3.8%,表明引入纹理特征后,EWT 反演模型精度具有显著提升。以 S+T 作为模型输入参数,利用 SVM 构建的 EWT




图 5 模型 R^2_{adj} 、RRMSE 与窗口尺寸的关系

Fig. 5 Relationship between R^2_{adj} and RRMSE and sampling window size

表 1 不同建模方法的最优窗口尺寸及精度

Tab. 1 Optimal window size and its accuracy for different models			
建模方法	最优窗口尺寸/(m × m)	R^2_{adj}	RRMSE/%
PLS_S	0.7 × 0.7	0.61	22.73
PLS_T	1.5 × 1.5	0.63	21.99
PLS_S + T	0.8 × 0.8	0.77	17.42
RF_S	0.6 × 0.6	0.65	20.98
RF_T	1.1 × 1.1	0.61	22.37
RF_S + T	0.5 × 0.5	0.70	19.81
SVM_S	0.4 × 0.4	0.71	20.37
SVM_T	0.9 × 0.9	0.60	23.70
SVM_S + T	0.7 × 0.7	0.82	16.57

反演模型在窗口尺寸为 0.7 m × 0.7 m 时取得了不同建模方法条件下的最高精度, R^2_{adj} 和 RRMSE 分别为 0.82 和 16.57%, 表明选择窗口尺寸为 0.7 m × 0.7 m 可有效提高 EWT 反演模型精度。尽管图 5 和表 1 直观地展示了模型精度分布和最优值, 然而它只能用于初步判断模型精度随窗口尺寸的变化, 而不能直接用于确定哪些特定因素影响了分布。为了探讨窗口尺寸对模型精度的影响, 还需要对结果

进行进一步分析。

2.3.2 Kruskal – Wallis 检验结果

为了优选对研究对象有显著影响的因素和各显著因素的最佳水平, 以确定数据集之间的差异, 本研究将模型结果按不同窗口尺寸划分为 20 组样本; 按不同 ML 方法及输入参数将模型结果划分为 9 组样本, 并分别进行非参数 Kruskal – Wallis 检验, 以确定窗口尺寸、ML 方法及输入参数对模型精度的影响, 并综合多种 ML 方法和输入参数组合评选出 EWT 反演的最佳窗口尺寸。

假设检验分为参数检验和非参数检验, 参数检验需要满足样本数据为正态分布和方差齐性的条件, 因此先对各组数据进行正态性检验, 其中 $h = 0$ 表示假设符合正态分布, $p > 0.05$ 表示接受 $h = 0$, 即接受符合正态分布这个假设, 表明该组数据符合正态分布, 反之则不符合。计算结果见表 2, 由表 2 可知: 20 组不同窗口尺寸的模型精度样本和 9 组不同建模方法构建的模型精度样本中, 多组数据不满足正态分布检验, 且由于样本量较小, 对总体分布情况不了解, 于是利用 Kruskal – Wallis 方法对样本进行

表 2 不同窗口尺寸/建模方法的模型精度正态性检验

Tab.2 Normal test of model accuracy for different window sizes/modeling methods														
尺寸/ (m × m)	R^2_{adj}		RRMSE		尺寸/ (m × m)	R^2_{adj}		RRMSE		建模 方法	R^2_{adj}		RRMSE	
	h	p	h	p		h	p	h	p		h	p	h	p
0.1 × 0.1	1	0	1	0.03	1.1 × 1.1	0	0.50	0	0.43	PLS_S	1	0	1	0
0.2 × 0.2	0	0.19	0	0.29	1.2 × 1.2	0	0.50	0	0.10	PLS_T	1	0.01	0	0.09
0.3 × 0.3	0	0.06	0	0.09	1.3 × 1.3	0	0.26	0	0.23	PLS_S + T	0	0.34	0	0.10
0.4 × 0.4	0	0.21	0	0.50	1.4 × 1.4	0	0.50	0	0.50	RF_S	0	0.06	0	0.08
0.5 × 0.5	1	0.02	0	0.06	1.5 × 1.5	0	0.50	0	0.50	RF_T	1	0	1	0.04
0.6 × 0.6	1	0	0	0.11	1.6 × 1.6	1	0.03	0	0.09	RF_S + T	0	0.21	0	0.23
0.7 × 0.7	1	0.01	0	0.18	1.7 × 1.7	0	0.14	0	0.18	SVM_S	1	0	1	0
0.8 × 0.8	0	0.50	0	0.50	1.8 × 1.8	0	0.50	0	0.50	SVM_T	1	0.03	1	0.02
0.9 × 0.9	0	0.19	0	0.08	1.9 × 1.9	0	0.50	0	0.50	SVM_S + T	0	0.29	0	0.37
1.0 × 1.0	0	0.50	0	0.50	2.0 × 2.0	0	0.50	0	0.50					

注：如显著性水平 $p > 0.05$, $h = 0$, 则接受原假设。

非参数检验。

Kruskal – Wallis 检验结果如表 3 所示,若 $p \leq 0.05$,则表示各变量间存在显著差异,不同窗口尺寸条件下模型 R^2_{adj} 和 RRMSE 的 p 值均小于 0.05,因此可认为各变量间整体存在显著差异,表明基于不同窗口尺寸提取的光谱及纹理信息对模型精度具有显

著影响;不同建模方法模型 R^2_{adj} 和 RRMSE 的 p 值均小于 0.05,表明建模方法对模型精度具有显著影响。然而,Kruskal – Wallis 结果并没有表明哪些组间的均值具有显著差异,因此可进行多重比较,以确定组间差异的显著性,进一步解释 Kruskal – Wallis 检验的结果。

表 3 不同窗口尺寸/建模方法的模型精度 Kruskal – Wallis 检验

Tab. 3 Kruskal – Wallisd test for model accuracy for different window sizes/modeling methods								
项目	R^2_{adj}				RRMSE			
	来源	组	误差	合计	来源	组	误差	合计
窗口尺寸	平方和	123 495. 9	362 487. 6	485 983. 5	平方和	115 282. 1	370 692. 9	485 975
	自由度	19	160	179	自由度	19	160	179
	均方	6 499. 79	2 265. 55		均方	6 067. 48	2 316. 83	
	F	45. 49			F	42. 46		
	p	0. 000 6			p	0. 001 5		
建模方法	平方和	206 775. 3	279 208. 2	485 983. 5	平方和	193 603. 1	292 371. 9	485 975
	自由度	8	171	179	自由度	8	171	179
	均方	25 846. 9	1 632. 8		均方	24 200. 4	1 709. 8	
	F	76. 16			F	71. 31		
	p	$2. 89 \times 10^{-13}$			p	$2. 69 \times 10^{-12}$		

2.3.3 多重比较

多重比较结果如图 6 所示,其中图 6a 为 20 组不同窗口尺寸模型 R^2_{adj} 和 RRMSE 均值秩,由图 6a 可知, R^2_{adj} 均值秩随着窗口尺寸增加呈先增大后减小趋势,最大值 (132.0) 出现在窗口尺寸 0.9 m × 0.9 m;RRMSE 的均值秩随着窗口尺寸的增加呈先减小后增大趋势,最小值 (53.44) 出现在窗口尺寸 0.7 m × 0.7 m。由于本研究的目的侧重于模型的预测准确性,因此最终选择以 RRMSE 为准,选取 0.7 m × 0.7 m 作为夏玉米无人机多光谱遥感信息的最优采样窗口尺寸。

图 6b 为不同建模方法的模型 R^2_{adj} 和 RRMSE 的均值秩。由图 6b 可知,基于 PLS、RF、SVM 3 种方法构建的模型中, R^2_{adj} 均值秩逐渐减小,RRMSE 均值秩

逐渐增大,表明基于 3 种 ML 方法构建的模型中反演精度从高到低依次为:SVM、RF、PLS;基于 S、T、S + T 3 种参数构建的模型中, R^2_{adj} 均值秩先减后增且 S + T 均值秩最大、RRMSE 均值秩先增后减且 S + T 均值秩最小,表明基于 3 种参数构建的模型中反演精度从高到低依次为:S + T、S、T。

为了直观展示引入 T 对模型准确性的影响,以 0.7 m × 0.7 m 作为最优采样窗口尺寸绘制了 EWT 预测值和真实值的散点图,见图 7 (图中仅展示测试集)。图 7 表明,除参数 T 外,基于参数 S 和 S + T 构建的模型拟合效果良好,真实值和预测值分布的 R^2_{adj} 均在 0.60 以上,RRMSE 均在 23% 以下,表明上述模型可用于监测 EWT。且相较于 S,参数 S + T 利用 PLS、RF、SVM 构建的模型精度均有所提升,表明




图 6 不同窗口尺寸/建模方法的模型精度多重比较
Fig.6 Multiple comparisons of model accuracy for different window sizes/modeling methods




图 7 最优窗口尺寸的 EWT 真实值与预测值比较
Fig.7 Comparison of true and predicted values of EWT for optimal window size

引入 T 后可有效提高 EWT 模型的反演精度。

3 讨论

基于 PLS、RF、SVM 3 种 ML 方法,构建了不同输入参数(S、T、S + T)的采样窗口尺度优选 EWT 估计模型。经比较发现,随着采样窗口尺寸的逐渐增大,利用 PLS、RF 和 SVM 方法构建的 3 类 EWT 模型精度均呈现先增大后减小的趋势,与 BAI 等^[19]和 DENG 等^[46]研究结果一致,主要原因在于无人机遥感空间分辨率较高,单一像元覆盖面积远小于玉米植株,导致其难以有效表达玉米冠层 EWT 的实际情

况。采样窗口空间尺度过小时,不能有效地涵盖玉米冠层的光谱和纹理信息,进而给模型带来较大的随机误差;而当采样窗口空间尺度过大时,玉米冠层边界像元会大幅度增加光谱和纹理信息的冗余性,这同样会使得反演模型的精度降低。与 PLS 方法构建的模型相比,RF 和 SVM 方法构建的模型精度有显著提升,主要原因在于 PLS 回归更擅于处理线性问题,而 RF、SVM 回归在非线性问题中同样具有较强的解析能力^[47]。SVM 构建的模型精度整体上较 RF 有所提高,主要原因在于 SVM 是一种理论基础坚实的小样本学习方法,使得最终决策函数由少

数支持向量确定,即少数支持向量决定了最终结果,这可以帮助剔除大量冗余、抓住关键样本,同时注定了 SVM 具有较好的“鲁棒性”,这与 TRAORE 等^[1]和 LEI 等^[48]研究结果一致。

图像纹理技术在水分胁迫诊断中的应用为作物水分状况的监测提供了一种潜在的方法^[49]。许多研究指出,图像纹理的利用不应局限在植被分类或生物量估计上^[18-19]。由于玉米田间包含了茎、叶、穗、土壤和阴影等多种成分,其高分辨率数字图像具有丰富高频的纹理信息,提高了对复杂植被结构的检测能力。虽然图像纹理和植被指数的获取方式不同,但它们的互补信息有助于提高作物水分监测指标的估计能力^[50],这与本研究基于 S + T 的模型精度显著高于 S 和 T 的结果一致。此外,类似的研究并不局限于关中地区的玉米作物,LIU 等^[50]和 FU 等^[51]分别就华东地区的水稻、华北地区的小麦等作物的多尺度纹理与光谱信息的地上生物量估算开展研究,结果表明在不同作物和环境条件下纹理参数的引入均有助于模型准确性的提高。

本研究探讨了采样窗口空间尺寸对夏玉米 EWT 监测模型精度的影响,为提取光谱、纹理信息的最优窗口尺寸提供了解决方案。然而,本研究仍然存在诸多不足之处。在数据提取方面,本研究提取采样窗口光谱和纹理信息仅用了简单平均法,并未考虑其它转换方法进行对比,且在提取的过程中未对剔除土壤背景后的信息作进一步探讨,后续的研究可进一步引入更精准的尺度转换方法和土壤背景剔除方法以提高模型的精度;本研究提取图像纹理特征所采用的灰度共生矩阵已被证明是有效的,但是否有其他更有效的算法仍有待研究。在模型的

构建方面,本文所用的建模方法均为适用于多维、小样本数据集的传统 ML 方法(如 SVM、RF、PLS);更为先进的 ML 方法(如深度学习等)已经被众多学者用于作物长势和土壤含水率的监测并取得了更好的效果,受本研究数据量限制未被采用,后续研究将考虑利用深度学习方法建模。

4 结论

(1)对比构建 EWT 反演模型的 3 种 ML 方法(PLS、RF、SVM)可以发现,不同空间尺度条件下的模型反演精度从高到低依次为:SVM、RF、PLS,对应的最优反演精度 R^2_{adj} (RRMSE) 分别为 0.82 (16.57%)、0.70 (19.81%)、0.77 (17.2%),表明利用 PLS、RF、SVM 3 种方法监测 EWT 有可行性。

(2)对比构建 EWT 反演模型的 3 种输入参数(S、T、S + T)可以发现,基于 S + T 的模型精度显著优于 S 或 T,引入 T 后,PLS、RF 和 SVM 模型最优窗口尺寸相应的 R^2_{adj} 分别增加 0.16、0.05 和 0.12,RRMSE 减少 4.95%、1.17% 和 3.8%。因此,结合无人机多光谱图像纹理特征与光谱指数估算 EWT,为夏玉米水分状况评估提供了一种可行且准确的方法。

(3)通过 Kruskal - Wallis 检验方法对模型精度进行分析,发现在窗口尺寸 0.1 m × 0.1 m ~ 2.0 m × 2.0 m 内,随着窗口尺寸逐渐增大,EWT 反演模型精度呈先增大后减小趋势,最优采样窗口空间尺寸为 0.7 m × 0.7 m, R^2_{adj} 最高可达 0.82 (对应 RRMSE 为 16.57%)。在此范围内提取的光谱信息能够代表取样区域的玉米冠层光谱,从而更为有效地解析玉米试验材料差异和提高模型反演精度。

参 考 文 献

[1] TRAORE A, ATA-UL-KARIM S T, DUAN A, et al. Predicting equivalent water thickness in wheat using UAV mounted multispectral sensor through deep learning techniques[J]. Remote Sensing, 2021, 13(21): 4476.

[2] PEI S, DAI Y, BAI Z, et al. Improved estimation of canopy water status in cotton using vegetation indices along with textural information from UAV-based multispectral images[J]. Computers and Electronics in Agriculture, 2024, 224: 109176.

[3] MIAO J, WANG J, ZHAO D, et al. Modeling strategies and influencing factors in retrieving canopy equivalent water thickness of mangrove forest with Sentinel-2 image[J]. Ecological Indicators, 2024, 158: 111497.

[4] 杨宝城, 鲁向晖, 张海娜, 等. 基于无人机多光谱影像的矮林芳樟叶片含水率与叶水势反演[J]. 农业机械学报, 2024, 55(2): 220 - 230, 267.

YANG Baocheng, LU Xianghui, ZHANG Haina, et al. Inversion of leaf water content and leaf water potential of *Cinnamomum camphora* based on UAV multispectral images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 220 - 230, 267. (in Chinese)

[5] 赵文举, 段威成, 王银凤, 等. 基于敏感变量筛选的多光谱植被含水率反演模型研究[J]. 农业机械学报, 2023, 54(9): 343 - 351, 385.

ZHAO Wenju, DUAN Weicheng, WANG Yinfeng, et al. Multispectral vegetation water content inversion model based on sensitive variable filtering[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(9): 343 - 351, 385. (in Chinese)

[6] CECCATO P, FLASSE S, TARANTOLA S, et al. Detecting vegetation leaf water content using reflectance in the optical domain

- [J]. Remote Sensing of Environment, 2001, 77(1): 22–33.
- [7] 韩晓勇. 基于 MODIS 和地物光谱的植被水分定量遥感研究[D]. 西安:长安大学, 2010.
HAN Xiaoyong. Quantitative study on estimation of vegetation water based on MODIS data and canopy spectra of vegetation—a case study in the greater Hinggan mountains forested areas[D]. Xi'an: Chang'an University, 2010. (in Chinese)
- [8] 贺宇豪. 基于机器学习和植被指数的植被生化参量反演[D]. 长沙:湖南大学, 2022.
HE Yuhao. Inversion of vegetation biochemical parameters based on machine learning and vegetation index[D]. Changsha: Hunan University, 2022. (in Chinese)
- [9] 贾方方, 滕世华, 何琳, 等. 基于水分光谱指数的烟草叶片等效水厚度估测[J]. 中国农学通报, 2024, 40(1): 151–156.
JIA Fangfang, TENG Shihua, HE Lin, et al. Estimating equivalent water thickness of tobacco leaves based on water hyperspectral indices[J]. Chinese Agricultural Science Bulletin, 2024, 40(1): 151–156. (in Chinese)
- [10] 董一凡. 基于多源数据的城市公园活力影响机制研究[D]. 南京:南京林业大学, 2023.
DONG Yifan. Study on the vibrancy of urban parks and surrounding areas: analyzing the impact mechanism using multi-source data[D]. Nanjing: Nanjing Forestry University, 2023. (in Chinese)
- [11] FENG L, CHEN S, ZHANG C, et al. A comprehensive review on recent applications of unmanned aerial vehicle remote sensing with various sensors for high-throughput plant phenoty[J]. Computers and Electronics in Agriculture, 2021, 182: 106033.
- [12] WANG F, YANG M, MA L, et al. Estimation of above-ground biomass of winter wheat based on consumer-grade multi-spectral UAV[J]. Remote Sensing, 2022, 14(5): 1251.
- [13] ZHU Y, LIU J, TAO X, et al. A three-dimensional conceptual model for estimating the above-ground biomass of winter wheat using digital and multispectral unmanned aerial vehicle images at various growth stages[J]. Remote Sensing, 2023, 15(13): 3332.
- [14] XU T, WANG F, XIE L, et al. Integrating the textural and spectral information of UAV hyperspectral images for the improved estimation of rice aboveground biomass[J]. Remote Sensing, 2022, 14(11): 2534.
- [15] CHEN M, YIN C, LIN T, et al. Integration of unmanned aerial vehicle spectral and textural features for accurate above-ground biomass estimation in cotton[J]. Agronomy, 2024, 14(6): 1313.
- [16] 靳亚红, 吴鑫淼, 甄文超, 等. 基于采样点光谱信息窗口尺度优化的土壤含水率无人机多光谱遥感反演[J]. 农业机械学报, 2024, 55(1): 316–327.
JIN Yahong, WU Xinmiao, ZHEN Wenchao, et al. UAV multispectral remote sensing inversion of soil moisture content based on window size optimization of spectral information at sampling points[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 316–327. (in Chinese)
- [17] CHAN C, NELSON P R, HAYES D J, et al. Predicting water stress in wild blueberry fields using airborne visible and near infrared imaging spectroscopy[J]. Remote Sensing, 2021, 13(8): 1425.
- [18] ZHANG J, ZHANG Z, CHEN J, et al. Estimating soil salinity with different fractional vegetation cover using remote sensing [J]. Land Degradation & Development, 2021, 32(2): 597–612.
- [19] BAI X, CHEN Y, CHEN J, et al. Optimal window size selection for spectral information extraction of sampling points from UAV multispectral images for soil moisture content inversion[J]. Computers and Electronics in Agriculture, 2021, 190: 106456.
- [20] 胡田田, 崔晓路, 李梦月, 等. 不同氮肥增效剂和水氮用量对冬小麦产量的影响[J]. 农业机械学报, 2021, 52(4): 302–310.
HU Tiantian, CUI Xiaolu, LI Mengyue, et al. Effect of different nitrogen fertilizer synergists, water and nitrogen amount on winter wheat yield[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(4): 302–310. (in Chinese)
- [21] SHU Meiyan, DONG Qizhou, FENG Shuaipeng, et al. Improved estimation of canopy water status in maize using UAV-based digital and hyperspectral images[J]. Computers and Electronics in Agriculture, 2022, 197: 106982.
- [22] ROUSE JR J W, HAAS R H, DEERING D W, et al. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation[R]. 1974.
- [23] FITZGERALD G J, RODRIGUEZ D, CHRISTENSEN L K, et al. Spectral and thermal sensing for nitrogen and water status in rainfed and irrigated wheat environments[J]. Precision Agriculture, 2006, 7: 233–248.
- [24] GITELSON A A, VIÑA A, CIGANDA V, et al. Remote estimation of canopy chlorophyll content in crops[J]. Geophysical Research Letters, 2005, 32(8): L08403.
- [25] GAMON J A, PENUELAS J, FIELD C B. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency[J]. Remote Sensing of Environment, 1992, 41(1): 35–44.
- [26] SCHUERGER A C, CAPELLE G A, DI BENEDETTO J A, et al. Comparison of two hyperspectral imaging and two laser-induced fluorescence instruments for the detection of zinc stress and chlorophyll concentration in bahia grass (*Paspalum notatum* Flugge.) [J]. Remote Sensing of Environment, 2003, 84(4): 572–588.
- [27] JORDAN C F. Derivation of leaf-area index from quality of light on the forest floor[J]. Ecology, 1969, 50(4): 663–666.
- [28] ROUJEAN J L, BREON F M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements[J].

Remote Sensing of Environment, 1995, 51(3) : 375 – 384.

[29] CHEN J M. Evaluation of vegetation indices and a modified simple ratio for boreal applications [J]. Canadian Journal of Remote Sensing, 1996, 22(3) : 229 – 242.

[30] HABOUDANE D, MILLER J R, TREMBLAY N, et al. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture[J]. Remote Sensing of Environment, 2002, 81(2 – 3) : 416 – 426.

[31] DAUGHTRY C S T, WALTHALL C L, KIM M S, et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance[J]. Remote Sensing of Environment, 2000, 74(2) : 229 – 239.

[32] GOEL N S, QIN W. Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: a computer simulation[J]. Remote Sensing Reviews, 1994, 10(4) : 309 – 347.

[33] BROGE N H, LEBLANC E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density[J]. Remote Sensing of Environment, 2001, 76(2) : 156 – 172.

[34] AR H. A soil adjusted vegetation index (SAVI)[J]. Remote Sensing of Environment, 1988, 25: 295 – 300.

[35] QI J, CHEHBOUNI A, HUETE A R, et al. A modified soil adjusted vegetation index[J]. Remote Sensing of Environment, 1994, 48(2) : 119 – 126.

[36] 郑家亨. 统计大辞典[M]. 北京:中国统计出版社,1995.

[37] WANG J, LOU Y, WANG W, et al. A robust model for diagnosing water stress of winter wheat by combining UAV multispectral and thermal remote sensing[J]. Agricultural Water Management, 2024, 291: 108616.

[38] ABDI H. Partial least squares regression and projection on latent structure regression (PLS regression) [J]. Wiley Interdisciplinary Reviews: Computational Statistics, 2010, 2(1) : 97 – 106.

[39] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45: 5 – 32.

[40] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20: 273 – 297.

[41] 薛琛昊, 邹滨, 徐勇, 等. 全国不同城市化水平与大气污染的时空关系[J/OL]. 环境科学. [2024 – 06 – 11]. <https://doi.org/10.13227/j.hjxx.202402046>.

XUE Chenhao, ZOU Bin, XU Yong, et al. Spatial-temporal relationships between urbanization levels and air pollution across various stages of urbanization nationwide[J/OL]. Environmental Science. [2024 – 06 – 11]. <https://doi.org/10.13227/j.hjxx.202402046>. (in Chinese)

[42] CHENG M, JIAO X, LIU Y, et al. Estimation of soil moisture content under high maize canopy coverage from UAV multimodal data and machine learning[J]. Agricultural Water Management, 2022, 264: 107530.

[43] 周概容. 应用统计方法辞典[M]. 北京:中国统计出版社,1993: 213 – 462.

[44] YANG N, ZHANG Z, DING B, et al. Evaluation of winter-wheat water stress with UAV-based multispectral data and ensemble learning method[J]. Plant and Soil, 2024, 497(1) : 647 – 668.

[45] 王元, 文兰, 陈木法. 数学大辞典[M]. 北京:科学出版社, 2010.

[46] DENG J, PAN S, ZHOU M, et al. Optimum sampling window size and vegetation index selection for low-altitude multispectral estimation of root soil moisture content for Xuxiang kiwifruit[J]. Agricultural Water Management, 2023, 282: 108297.

[47] PENG X, MA Y, SUN J, et al. Grape leaf moisture prediction from UAVs using multimodal data fusion and machine learning [J]. Precision Agriculture, 2024, 25(3) : 1609 – 1635.

[48] LEI J J, YANG W N, LI H, et al. Leaf equivalent water thickness assessment by means of spectral analysis and a new vegetation index[J]. Journal of Applied Remote Sensing, 2019, 13(3) : 034517.

[49] ZHOU Y, LAO C, YANG Y, et al. Diagnosis of winter-wheat water stress based on UAV-borne multispectral image texture and vegetation indices[J]. Agricultural Water Management, 2021, 256: 107076.

[50] LIU J, ZHU Y, SONG L, et al. Optimizing window size and directional parameters of GLCM texture features for estimating rice AGB based on UAVs multispectral imagery[J]. Frontiers in Plant Science, 2023, 14: 1284235.

[51] FU Y, YANG G, SONG X, et al. Improved estimation of winter wheat aboveground biomass using multiscale textures extracted from UAV-based digital images and hyperspectral feature analysis[J]. Remote Sensing, 2021, 13(4) : 581.