

基于 CARS/RFG 优选植被指数的矮林芳樟叶水势反演模型

张海娜 倪程洋 鲁向晖 张跃 罗欣 马璠
(江西水利电力大学江西省樟树繁育与开发利用工程研究中心, 南昌 330099)

摘要: 叶水势(Leaf water potential, LWP)是反映植物水分状态的关键指标,快速准确监测矮林芳樟 LWP 对调控林地水分管理策略具有重要意义。本文以矮林芳樟为对象,利用无人机搭载多光谱相机采集冠层光谱数据,通过皮尔逊相关性分析(PCC)、竞争性自适应重加权采样算法(CARS)和随机蛙跳算法(RFG)筛选出有效反映矮林芳樟水分特征且相互间具有较低冗余度的植被指数组合,结合反向传播神经网络(BPNN)、径向基函数神经网络(RBFNN)、随机森林(RF)和极限梯度提升(XGBoost)构建矮林芳樟 LWP 多光谱反演模型,基于决定系数(R^2)和均方根误差(RMSE)筛选最优模型。结果表明:在快速生长阶段(6—7月)和稳定生长阶段(8—9月),RFG-XGBoost 均为矮林芳樟 LWP 反演的最优模型,其中2阶段训练集 R^2 分别为 0.994 5、0.993 0, RMSE 分别为 0.081 1、0.052 6 MPa;测试集 R^2 分别为 0.806 6、0.822 5, RMSE 分别为 0.348 4、0.119 1 MPa。表明基于无人机多光谱影像的 RFG-XGBoost 模型在反演矮林芳樟 LWP 方面精度较高,在快速获取关键信息方面具有较大应用潜力。研究结果可为芳樟林间水分管理提供重要科学依据和技术支持。

关键词: 矮林芳樟; 叶水势; 无人机多光谱; 特征选择; 机器学习

中图分类号: S758 文献标识码: A 文章编号: 1000-1298(2026)20-0318-10 OSID: 

Inversion Model of Leaf Water Potential of *Cinnamomum camphora* Dwarf Forests Based on Vegetation Index Optimized by CARS/RFG

Zhang Haina Ni Chengyang Lu Xianghui Zhang Yue Luo Xin Ma Fan
(Jiangxi Provincial Engineering Research Center of Seed-breeding and Utilization of Camphor Trees,
Jiangxi University of Water Resources and Electric Power, Nanchang 330099, China)

Abstract: Leaf water potential (LWP) is a key indicator reflecting plant water status, and rapid and accurate monitoring of LWP in *Cinnamomum camphora* dwarf forests is crucial for regulating forestland water management strategies. Canopy spectral data of *Cinnamomum camphora* dwarf forests were collected by using a drone-mounted multispectral camera. Through Pearson correlation analysis (PCC), competitive adaptive reweighted sampling (CARS) algorithm, and random frog (RFG) algorithm, combinations of vegetation indices that effectively reflect the water characteristics of *Cinnamomum camphora* dwarf forests with low mutual redundancy were screened out. Then, multispectral inversion models for LWP of *Cinnamomum camphora* dwarf forests were constructed by combining back propagation neural network (BPNN), radial basis function neural network (RBFNN), random forest (RF), and eXtreme gradient boosting (XGBoost). Finally, the optimal model was selected based on the evaluation criteria of coefficient of determination (R^2) and root mean square error (RMSE). The results showed that the RFG-XGBoost model was the optimal one for LWP inversion. For the training set in these two stages, the R^2 values were 0.994 5 and 0.993 0, with RMSE values of 0.081 1 MPa and 0.052 6 MPa, respectively; for the test set, the R^2 values were 0.806 6 and 0.822 5, with RMSE values of 0.348 4 MPa and 0.119 1 MPa, respectively. It was concluded that the RFG-XGBoost model based on UAV

multispectral images showed high accuracy in inverting LWP of *Cinnamomum camphora* dwarf forests, demonstrating its application potential in quickly obtaining key information. The research results can provide important scientific basis and technical support for water and fertilizer management in *Cinnamomum camphora* forests.

Key words: *Cinnamomum camphora* dwarf forests; leaf water potential; UAV multispectral; feature selection; machine learning

0 引言

芳樟 (*Cinnamomum camphora* ct. linalool) 是一种兼具生态和经济价值的常绿乔木,在我国长江流域及其以南地区广泛种植^[1-2]。近年来,我国南方地区高温伏旱频发^[3],导致矮林芳樟长势偏弱,生物量、出油率 and 水分利用率降低^[4]。叶水势 (Leaf water potential, LWP) 是反映植物水分状态的关键指标,表示叶片内部水分张力或压力状态,对植物生物量累积具有直接影响^[5]。因此,快速准确地监测矮林芳樟 LWP 对调控林地水分管理策略,提高水分利用效率和保障精油产业健康发展具有重要的实践指导作用。

传统 LWP 测定依赖压力室法^[6],费时费力,适用小范围监测,无法快速准确地获取大田监测数据。因此,快速获取植物叶片水分状况、及时调整土壤水分管理策略是规模化农林业经营管理面临的一个难题^[7]。近年来,随着光谱与遥感技术发展,国内外学者纷纷探索光谱特征与机器学习相结合的 LWP 快速反演方法,通过整合无人机影像参数、土壤及气象等多源数据构建模型,并借助算法优化或特征筛选等提升模型反演精度^[8-10]。但目前针对多光谱反演模型的研究大多选取相关性高的植被指数 (Vegetation index, VI) 作为输入变量^[11],然而多个植被指数间可能存在共线性进而影响模型反演精度,只考虑单一植被指数与输出变量的关系可能会忽略不同植被指数间的交互效应,导致所选植被指数组合无法准确反映输出变量特征^[12]。为解决该问题,当前学者开始探究特征选择技术在优化植被指数组合中的应用,已成为农林业实时监测与管理领域的研究热点^[13]。

本研究以南方红壤区矮林芳樟为对象,利用无人机多光谱相机获取芳樟冠层光谱数据,结合 3 种特征选择算法 (皮尔逊相关系数法 (Pearson correlation coefficient, PCC)、竞争性自适应重加权采样法 (Competitive adaptive reweighted sampling, CARS) 和随机蛙跳算法 (Random frog, RFG)) 确定最优植被指数组合,基于反向传播神经网络 (Back propagation neural network, BPNN)、径向基函数神经

网络 (Radial basis function neural network, RBFNN)、随机森林 (Random forest, RF) 和极限梯度提升 (eXtreme gradient boosting, XGBoost) 4 种机器学习算法建立矮林芳樟 LWP 反演模型,探寻矮林芳樟不同生长阶段水分状况的最佳反演模型,以期能全面准确地反映矮林芳樟水分状况。

1 材料与方法

1.1 研究区概况

在江西水利电力大学金溪科教基地 (图 1) 开展研究。基地地理位置坐标为 27°51'N, 116°45'E, 平均海拔 98 m。该区域多年平均降雨量为 1 707.0 mm, 年最大降雨量可达 2 804.0 mm, 年最小降雨量为 1 134.0 mm。多年平均相对湿度 79.8%, 年均蒸发量 1 492.4 mm, 年均气温 17.9℃, 月平均最高气温 29.8℃, 月平均最低气温为 5.5℃, 试验田块耕作层土壤为红壤土。




图 1 研究区地理位置

Fig. 1 Geographical location of study area

供试矮林芳樟为江西省樟树繁育与开发利用工程研究中心选育的优良品种“赣芳 1 号”。试验区采用随机区组设计,设置 3 个林分密度处理: D1 (4 445 株/hm², 1.5 m × 1.5 m)、D2 (6 667 株/hm², 1.0 m × 1.5 m) 和 D3 (10 000 株/hm², 1.0 m × 1.0 m), 共划分 50 个小区,每个小区尺寸为长 10 m、宽 5 m, 试验区与小区分布如图 1 所示。矮林芳樟于 2021 年 4 月栽植,2023 年 9 月对地上部分进行平茬,2024 年重新萌芽后开展试验。在植物整个生长过程,6—7 月为矮林芳樟快速生长阶段,8—9 月植物生长平稳,属于稳定生长阶段。

1.2 数据采集

1.2.1 矮林芳樟多光谱数据获取

使用 DJI M300 RTK 型无人机携带 MS600 Pro 型多光谱相机(长光禹辰信息技术与装备(青岛)有限公司)进行光谱数据采集,多光谱相机参数如表 1 所示。

表 1 多光谱相机参数
Tab.1 Multispectral camera specifications

光谱波段	中心波长/nm	带宽/nm	灰板反射率
蓝(B)	450	35	0.62
绿(G)	555	27	0.61
红(R)	660	22	0.60
红边 1(RE1)	720	10	0.60
红边 2(RE2)	750	10	0.60
近红外(NIR)	840	30	0.58

无人机多光谱数据分别采集于芳樟快速生长期阶段(6 月 14 日、7 月 11 日)、稳定生长阶段(8 月 15 日、9 月 16 日)2 个生长期 4 个时间点。根据试验区轮廓设置飞行航线,飞行时间为 12:00—14:00,飞行时天空晴朗无云,飞行前进行白板校正,飞行高度为 60 m,飞行速度为 2.5 m/s,拍照模式为等时间间隔,航向、旁向重叠度分别为 75%、65%。

利用 Yusesense Map 软件对获取的多光谱影像进行拼接处理。将生成的.tif 文件导入 ENVI 5.3 软件,截取感兴趣区域,通过手动勾画芳樟叶片影像、提取冠层信息、去除阴影和土壤背景等操作,成功获取 6 个波段下植被冠层平均反射率,从而得到试验小区矮林芳樟冠层原始波段反射率数据。

1.2.2 地面实测数据

无人机获取影像的同时,同步测量 50 个小区的矮林芳樟观测植物正午 LWP。每个小区从芳樟中上部随机选取 3 片成熟健康叶片,测定时使用工具刀切割叶柄与枝连接处,留下平整切口,采用压力水势仪(PMS 600D 型)测定 LWP,最后取平均值表示该小区平均 LWP^[14]。

1.3 反演模型构建

1.3.1 植被指数选取

植被指数主要用于反映植物的生长状况和生理特征^[15]。植物 LWP 受光照、土壤水分、空气湿度等多种因素影响,从多个角度通过植被指数反演植物水分状况具有重要意义。参照文献[15–28],从现有的多光谱植被指数中选取 36 种常见植被指数,用于叶水势反演模型构建。包括直接反映植被含水率的植被指数:归一化差值水指数(Normalized difference water index,NDWI);与叶绿素相关的植被指数:叶绿素指数(Green chlorophyll vegetation

index,GCVI)、红边叶绿素指数 1(Chlorophyll index red-edge 1,Cirededge1)、红边叶绿素指数 2(Chlorophyll index red-edge 2,Cirededge2)、绿色叶绿素指数(Chlorophyll index green,CIgreen)、中尺度叶绿素指数(MERIS terrestrial chlorophyll index,MTCI)、叶绿素含量指数 1(Leaf chlorophyll index 1,LCI1)、叶绿素含量指数 2(Leaf chlorophyll index 2,LCI2)、转换型叶绿素吸收反射率指数(Transformed chlorophyll absorption in reflectance,TCART)、绿度指数(Greenness index,GI)、归一化绿红差值指数(Normalized green-red difference index,NGRDI)、过绿指数(Excess green index,EXG)、过红指数(Excess red index,EXR)、超绿红蓝差分指数(Excess green red blue difference index,EGRBDI)、结构不敏感色素指数(Structure insensitive pigment index,SIPI)、植被色素比值指数(Plant pigment ratio,PPR);与植被生长状况相关的植被指数:归一化植被指数(Normalized difference vegetation index,NDVI)、红边归一化差值植被指数 1(Red-edge normalized difference vegetation index 1,RNDVI1)、红边归一化差值植被指数 2(Red-edge normalized difference vegetation index 2,RNDVI2)、绿色归一化差值植被指数(Green normalized difference vegetation index,GNDVI)、重归一化差值植被指数(Renormalized difference vegetation index,RDVI)、修改的归一化植被指数(Modified normalized difference vegetation index,MNVI)、可见光差异植被指数(Visible-band difference vegetation index,VDVI)、非线性植被指数(Non-linear vegetation index,NLI)、增强植被指数(Enhanced vegetation index,EVI)、改进的简单比值植被指数(Modified simple ratio,MSR)、差值植被指数(Difference vegetation index,DVI)、修正植被指数(Modified vegetation index,MVI)、比值植被指数(Ratio vegetation index,RVI)、变换植被指数(Transformed vegetation index,TVI)、叶绿素植被指数(Chlorophyll vegetation index,CVI)、修改的三角形植被指数(Modified triangular vegetation index,MTVI);与环境相关的植被指数:土壤调整植被指数(Soil-adjusted vegetation index,SAVI)、修改的土壤调整植被指数(Modified soil-adjusted vegetation index,MSAVI)、优化土壤调整植被指数(Optimized soil-adjusted vegetation index,OSAVI)、大气校正植被指数(Atmospherically resistant vegetation index,ARVI)。其中 NDWI 通过对植物叶片中水分敏感的近红外和短波红外波段反射率计算,直接反映叶片含水率^[22];植物缺水会导致叶片萎蔫、叶绿素合成

受影响,进而改变叶片在可见光波段的反射率。GCVI、GI、EGRBDI 等指标能通过绿、红、蓝等波段的组合变化,间接体现因水分不足引发的叶片状态改变^[24];与植物生长状况相关的植被指数 NDVI、EVI 等^[15]间接反映因水分不足引发的植物生长状况改变;土壤调整类指数(SAVI、OSAVI、MSAVI)通过引入土壤调整系数,减少土壤背景反射对信号的干扰,更准确地提取植物自身因水分变化产生的差异^[28]。综上,36 种植被指数从植物含水率、叶绿素特征、生长状况、环境适应性等多个生理和环境因素反映不同条件下植物水分监测需求。

1.3.2 特征选择

PCC 是一种度量 2 个变量间线性相关程度的方法,常用于特征选择^[29],对于光谱数据中每一对特征,计算特征间的皮尔逊相关系数,以筛选出与目标变量相关性强的特征组合。

CARS 是一种用于变量选择的方法,在光谱分析、田间水分管理等领域应用广泛^[30],可从众多变量中筛选出与目标变量最为相关的重要变量子集,从而提高模型性能^[31]。基于筛选的特征子集重新构建偏最小二乘回归(PLS)模型,并通过计算模型均方根误差(RMSE);重复上述采样和建模过程,最终选择 RMSE 最小的特征子集作为最优结果。

RFG 是一种用于求解优化问题的算法^[32-33],在波段范围内随机选取 1 个初始变量子集 V_0 ,包含变量数为 n ,同时设置所需要的迭代次数 M 。基于原始的变量子集 V_0 ,提出 1 个候选变量子集 V^* ,选择 V^* 作为 V_i 代替原始的变量子集 V_0 ,直到 M 次迭代终止。统计每次迭代过程变量子集,代入 PLS 模型计算决定系数(R^2)和 RMSE,在整个迭代过程计算每个光谱波段被选择的概率,概率越高则光谱变量越重要。

1.3.3 机器学习模型

根据课题组前期樟树叶水势反演结果^[11],采用 Matlab 2021a 软件平台分别建立基于神经网络模型(BPNN、RBFNN)和决策树模型(RF、XGBoost)^[34-35]的矮林芳樟 LWP 反演模型,采用 Origin 2022 软件绘制各反演模型拟合图。其中神经网络模型对强非线性数据拟合能力极强,在数据分布有波动时仍可保持稳定预测,具有一定泛化能力和鲁棒性;决策树模型在处理低纬度数据时预测稳定,能有效捕捉特征间交互作用,通过集成学习降低拟合风险。

1.3.4 模型精度评价

分别获取矮林芳樟快速生长阶段、稳定生长阶段样本数据 100 组,将数据随机分成 80 组作为模型

训练集,其余 20 组作为测试集。选取 R^2 和 RMSE 对模型可靠性和预测结果精准性进行检验, R^2 越高、RMSE 越低,表明模型反演性能越好。

2 结果与分析

2.1 矮林芳樟 LWP 数据分析

矮林芳樟不同生长阶段实测 LWP 样本数为 100,其中快速生长阶段 LWP 为 $-3.3 \sim -1.0$ MPa,均值为 -2.1 MPa,稳定生长阶段为 $-4.3 \sim -1.1$ MPa,均值为 -2.6 MPa,低于快速生长阶段;变异系数分别为 23.8% 和 30.8%。分析结果表明,矮林芳樟 LWP 样本集数据变异系数大于 20%,离散程度较大,作为模型训练样本能确保模型预测准确性。

2.2 矮林芳樟植被指数特征选择

基于皮尔逊相关性分析分别在快速生长阶段和稳定生长阶段选择与 LWP 相关性最高的 5 种植被指数,其中快速生长阶段相关系数均超过 0.55,t1 特征组合为 GI、NGRDI、VDVI、EGRBDI 和 RNDVI1,稳定生长阶段相关系数均超过 0.50,t2 特征组合为 Clrededge2、TVI、CIgreen、RDVI 和 EVI(图 2)。




图 2 不同生长阶段植被指数与 LWP 相关系数
Fig.2 Correlation coefficient between vegetation index and LWP in different growth stages

基于 CARS 算法对植物 LWP 筛选植被指数,在快速生长阶段得到最佳特征变量组合 t3 为 GCVI、GI 和 RVI,在稳定生长阶段得到最佳特征变量组合 t4 为 GCVI、GI、CIrededge2、RVI 和 TVI。

基于 RFG 算法对植物 LWP 进行植被指数筛选,在快速生长阶段得到 t5 特征组合为 NGRDI、PPR、ARVI、GI 和 DVI,在稳定生长阶段得到 t6 特征组合为 NGRDI、ARVI、DVI、NDWI 和 TCART。

2.3 矮林芳樟 LWP 反演

2.3.1 基于神经网络的矮林芳樟 LWP 反演模型构建

以皮尔逊相关性分析、CARS 和 RFG 算法分别筛选出矮林芳樟快速生长阶段植被指数组合 t1、t3、t5 以及稳定生长阶段植被指数组合 t2、t4、t6 作为模型自变量,LWP 作为模型因变量,构建基于 RBFNN 和 BPNN 的矮林芳樟反演模型,模型运行结果见图 3、4。




图 3 基于神经网络的矮林芳樟快速生长阶段 LWP 反演

Fig.3 Neural network based inversion model of LWP of dwarf forest of *Cinnamomum camphora* ct. linalool in quick growth stage

由图 3 可知,在快速生长阶段,经皮尔逊相关性分析、CARS 和 RFG 算法特征选择后 BPNN 模型性能均优于 RBFNN,BPNN 在反演 LWP 方面具有更强的性能。基于 RFG 算法和 CARS 算法筛选的植被指数所构建的 BPNN 模型,精度均显著高于基于皮尔逊相关性筛选出的模型。其中,使用 RFG 算法筛选的植被指数在 BPNN 模型中表现最优:RFG - BPNN 模型训练集和测试集 R^2 分别为 0.751 0 和 0.746 8, RMSE 分别为 0.403 6、0.391 6 MPa。

由图 4 可知,在稳定生长阶段,经皮尔逊相关性分析、CARS 和 RFG 算法特征选择后 BPNN 模型性能均优于 RBFNN,相较于快速生长阶段,2 种神经网络模型在稳定生长阶段预测精度均有所提升,其中 BPNN 模型表现尤为突出。另外,基于 RFG 算法和 CARS 算法筛选的植被指数所构建的 RBFNN 和 BPNN 模型精度均显著高于皮尔逊相关性分析筛选的模型。CARS 算法筛选的植被指数在 RBFNN 模型预测性能最优,CARS - RBFNN 模型训练集 R^2 为 0.609 5, RMSE 为 0.335 9 MPa,测试集 R^2 为 0.558 6,

RMSE 为 0.342 2 MPa。RFG 算法筛选的植被指数在 BPNN 模型中预测性能最优,RFG - BPNN 模型训练集 R^2 为 0.846 3, RMSE 为 0.199 0 MPa,测试集 R^2 为 0.771 8, RMSE 为 0.295 1 MPa。

2.3.2 基于决策树的芳樟叶 LWP 反演模型构建

以皮尔逊相关性分析、CARS 和 RFG 算法分别筛选出快速生长阶段的植被指数组合 t1、t3、t5 和稳定生长阶段植被指数组合 t2、t4、t6 作为模型自变量,矮林芳樟 LWP 作为模型因变量,构建基于 RF 和 XGBoost 的矮林芳樟反演模型。快速生长阶段和稳定生长阶段矮林芳樟 LWP 反演模型运行结果见图 5、6。

由图 5 可知,在快速生长阶段,经皮尔逊相关性分析、CARS 和 RFG 算法特征选择后 RF 模型性能均劣于 XGBoost,但优于 BPNN 和 RBFNN 模型。进一步分析发现,基于 RFG 算法和 CARS 算法筛选的植被指数所构建的 RF 和 XGBoost 模型精度均显著高于基于皮尔逊相关系数筛选的模型。RF 模型中 RFG - RF 模型最优,性能优于 PCC - RF 和 CARS -




图 4 基于神经网络的矮林芳樟稳定生长阶段 LWP 反演

Fig.4 Neural network-based inversion model of LWP for dwarf forest of *Cinnamomum camphora* ct. linalool in stable growth stage




图 5 基于决策树的矮林芳樟快速生长阶段 LWP 反演

Fig.5 Decision tree based inversion model of LWP of dwarf forest of *Cinnamomum camphora* ct. linalool in quick growth stage

RF 模型,训练集 R^2 为 0.833 4, RMSE 为 0.344 0 MPa, 测试集 R^2 为 0.771 5, RMSE 为 0.338 9 MPa; XGBoost 模型中 RFG - XGBoost 模型最优 (训练集 R^2 为 0.994 5, RMSE 为 0.081 1 MPa, 测试集 R^2 为 0.806 6, RMSE 为 0.348 4 MPa), 性能优于 PCC - XGBoost 和 CARS - XGBoost 模型。RFG - XGBoost 模型性能优于 PCC - XGBoost。

由图 6 可知,在稳定生长阶段,经皮尔逊相关性分析、CARS 和 RFG 算法特征选择后 RF 和 XGBoost 模型均取得了较好的预测精度,其中 XGBoost 优于 RF 模型。进一步分析发现,基于 RFG 和 CARS 算法筛选的植被指数所构建的模型精度均显著高于基于 PCC 筛选的模型。RF 模型中最优的为 RFG - RF 模型,性能优于 PCC - RF 和 CARS - RF 模型,训练




图 6 基于决策树的矮林芳樟稳定生长阶段 LWP 反演

Fig. 6 Decision tree based inversion model for LWP of dwarf forest of *Cinnamomum camphora* ct. linalool in stable growth stage

集 R^2 为 0.858 4, RMSE 为 0.208 3 MPa, 测试集 R^2 为 0.727 0, RMSE 为 0.314 3 MPa; XGBoost 模型中最优的为 RFG - XGBoost 模型 (训练集 R^2 为 0.993 0, RMSE 为 0.052 6 MPa, 测试集 R^2 为 0.822 5, RMSE 为 0.119 1 MPa), 性能优于 PCC - XGBoost 和 CARS - XGBoost 模型。

3 讨论

水分是植物进行光合作用和维持生长的基本要素, 作为反映叶片水分状态的核心生理指标, 植物 LWP 变化与叶片内部结构、叶绿素及水分含量密切相关, 使得叶片对不同波段光谱的吸收、反射与透射特性发生变化, 进而形成多光谱的差异化响应, 其中短波红外与近红外波段的响应最为敏感^[35]。本研究通过不同特征选择方法均筛选出大多数与叶绿素和植被生长状况相关的植被指数, 如 GCVI、CIrededge2、NGRDI、GI 等, 说明 LWP 变化主要通过影响叶绿素合成改变叶片光谱特性。其中 CARS 算法和 RFG 算法分别在矮林芳樟的 2 个生长阶段均筛选出 GCVI 和 NGRDI, 可能是由于 GCVI 通过绿光与近红外波段反射率计算得到, 2 个波段对叶片叶绿素含量变化敏感, 不同水分条件下叶绿素含量改变直接影响了 2 个波段反射率, 进而使 GCVI 发生变化, 而 NGRDI 通过绿光波段进行计算, 直接关联叶片绿色度和光合作用活性, 水分充足时, 矮林芳樟叶片光合作用强, 绿光反射低, NGRDI 较高; 当 LWP 降低, 气孔关闭导致光合效率下降, 绿光反射

升高, NGRDI 降低, 使得 NGRDI 能快速响应矮林芳樟叶片水分状态改变, 同时还可以消除不同辐照度对植被光谱特征的影响^[36]。

植物 LWP 还受光照、土壤湿度、空气温度等多因素影响^[11], 综合反映多种因素的植被指数可以全面获取信息维度, 抗干扰能力增强, 突破单一因子敏感型指数的局限性。已有研究表明, 利用多植被指数组合的非线性 BP 神经网络算法建模对土壤含水率反演的精度更高^[37], 综合考虑多种因素的植被指数在反演精度上更具优势。本研究中, 矮林芳樟不管是处于快速生长还是稳定生长阶段, RFG 方法筛选的植被指数包含了 3 ~ 4 种反映植物不同特征的植被指数, 皮尔逊相关系数法和 CARS 算法只筛选了与植物叶绿素和生长状况相关的 2 种植被指数, 说明 RFG 算法可同步捕捉植物叶片水分状态、叶绿素含量及环境等多重指标的综合信号, 更贴合植物生长过程多因子协同作用的生理机制, 对复杂环境噪声等外部因素通过波段间差值、比值或归一化运算, 能抵消部分非目标因素的影响。另外, 在矮林芳樟快速生长阶段和稳定生长阶段, RFG - XGBoost 模型均被证明是反演 LWP 的最佳模型, 性能优于 CARS - XGBoost 模型。这一现象主要归因于 2 种特征选择算法在处理数据特性和变量关系方面的差异。RFG 算法具有较强的全局搜索能力, 可充分挖掘潜在关键变量, 捕捉变量间的复杂非线性关系, 这些特性不仅有助于简化模型结构, 更能显著降低过拟合风险, 对 LWP (负

值)与输入特征间的复杂关联(含非线性、高阶交互作用)具有较好的适配性。相比之下,CARS 算法侧重线性相关性,可能忽略非线性特征,难以应对 LWP 受多因素影响的复杂光谱关系。RFG - XGBoost 结合 RFG 筛选的高质量特征与 XGBoost 非线性拟合能力,提升了模型预测精度与稳定性。而且本研究发现 RFG - XGBoost 模型在快速生长阶段测试集 R^2 稍低于稳定生长阶段,可能是因为快速生长阶段矮林芳樟冠层结构动态变化加快导致光谱混合效应增强,导致在处理数据时 XGBoost 仍存在一定局限性。未来可引入注意力机制或三维卷积神经网络,结合冠层结构参数(如叶倾角、叶面积指数)进一步提升模型鲁棒性。

本研究构建基于神经网络(BPNN、RBFNN)以及决策树模型(RF、XGBoost)的矮林芳樟 LWP 反演模型,得出的结论与前人类似^[11]。不同模型在反演精度和适用场景上存在显著差异:XGBoost 模型最优,RF 和 BPNN 模型其次,RBFNN 无法有效反演矮林芳樟 LWP,该性能差异源于目标变量的固有特性以及模型对数据特征的适应性。RF 模型能有效捕捉特征间的交互作用以及主要的非线性关系,然而 LWP 数据均为负值,与光谱特征间可能存在更为复杂的非线性关系。高 LWP 时叶绿素合成与稳定性良好,在可见光红光波段吸收能力强,GCVI、NGRDI 等指数与 LWP 呈线性相关,而低 LWP 时,可见光波段反射率无显著波动,当 LWP 极低时叶绿素合成受阻且降解加速,红光反射率明显上升,植被指数与 LWP 呈非线性关系。XGBoost 模型采用梯度提升策略,通过集成多个学习器并逐步优化损失函数,展现

了更强的非线性拟合能力和对复杂模式的捕捉能力,在 LWP 反演中表现出最优性能。作为神经网络模型,BPNN 具有多层次的神经元结构和非线性激活函数,强大的非线性拟合能力能有效捕捉植被指数与 LWP 间的非线性关系,使得 BPNN 同样能有效反演矮林芳樟 LWP;而 RBFNN 通常由输入层、仅有 1 个隐藏层的径向基函数层和输出层组成,在处理高非线性和存在噪声的数据时,可能无法充分捕捉数据中复杂模式。

本研究构建了基于机器学习算法的矮林芳樟 LWP 反演模型。该模型在很大程度上依赖于数据集(包括光谱指数和水分参数实测值),且不同数据在不同模型中表现存在显著差异。后续研究需采集不同条件和年份的多年数据,以进行模型修正和验证。将研究范围扩大至江西省其他矮林樟树种植区,验证模型的地区适用性。

4 结论

(1)CARS 算法筛选出快速生长阶段最优植被指数组合为 GCVI、GI、RVI,稳定生长阶段最优植被指数组合为 GCVI、GI、CIrededge2、RVI、TVI;RFG 算法筛选出快速生长阶段最优植被指数组合为 NGRDI、PPR、ARVI、IG、DVI,稳定生长阶段最优植被指数组合为 NGRDI、ARVI、DVI、NDWI、TCART。

(2)在矮林芳樟快速生长与稳定生长阶段,基于 RFG 算法筛选植被指数组合的 XGBoost 模型均最优:快速生长阶段测试集 R^2 为 0.806 6、RMSE 为 0.348 4 MPa;稳定生长阶段测试集 R^2 为 0.822 5、RMSE 为 0.119 1 MPa。

参 考 文 献

[1] 金志农,张北红,艾卿,等. 香料樟树研究的必要性与可行性分析[J]. 南昌工程学院学报, 2020, 39(6):1-13.
Jin Zhinong, Zhang Beihong, Ai Qing, et al. Necessity and feasibility of research on *Cinnamomum* spp. and *Litsea* spp. used in spice[J]. Journal of Nanchang Institute of Technology, 2020, 39(6):1-13. (in Chinese)

[2] Liu Z, Li H, Zhu Z, et al. *Cinnamomum camphora* fruit peel as a source of essential oil extracted using the solvent-free microwave-assisted method compared with conventional hydrodistillation[J]. LWT, 2022, 153:112549.

[3] 张蕾,钱拴,曹云,等. 2022 年南方高温干旱特点及其对植被净初级生产力的影响[J]. 生态学杂志, 2024, 43(7): 2182-2188.
Zhang Lei, Qian Shuan, Cao Yun, et al. Characteristics of heat and drought events across southern China in 2022 and their impacts on vegetation net primary productivity[J]. Chinese Journal of Ecology, 2024, 43(7):2182-2188. (in Chinese)

[4] Cai Y, Xu H, Xu C, et al. Adjusting function of camphor on primary metabolism in *Cinnamomum camphora* stressed by high temperature[J]. Plant Science, 2024, 339:111956.

[5] Mullan D, Pietragalla J. Leaf relative water content[M]//Pask A, Pietragalla J, Mullan D, et al. Physiological breeding II: a field guide to wheat phenotyping. Mexico: Cimmyt, 2012:25-35.

[6] 柏新富,卜庆梅,谭永芹,等. 植物 4 种水势测定方法的比较及可靠性分析[J]. 林业科学, 2012, 48(12):128-133.
Bai Xinfu, Bu Qingmei, Tan Yongqin, et al. Comparison and analysis of four methods used in measuring the plant water potential[J]. Scientia Silvae Sinicae, 2012, 48(12):128-133. (in Chinese)

[7] Zang Z, Li Z, Wang J, et al. Terahertz spectroscopic monitoring and analysis of citrus leaf water status under low temperature stress[J]. Plant Physiology and Biochemistry, 2023, 194:52-59.

- [8] Wang Z, Tan X, Ma Y, et al. Combining canopy spectral reflectance and RGB images to estimate leaf chlorophyll content and grain yield in rice[J]. Computers and Electronics in Agriculture, 2024, 221:108975.
- [9] Gao Y, Zhao T, Zheng Z, et al. Cotton leaf water potential prediction based on UAV visible light images and multi-source data[J]. Irrigation Science, 2025, 43(1):121–134.
- [10] Li W, Wang J, Zhang Y, et al. Combining texture, color, and vegetation index from unmanned aerial vehicle multispectral images to estimate winter wheat leaf area index during the vegetative growth stage[J]. Remote Sensing, 2023, 15:5715.
- [11] 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)
- [12] Zu J, Yang H, Wang J, et al. Inversion of winter wheat leaf area index from UAV multispectral images: classical *vs* deep learning approaches[J]. Frontiers in Plant Science, 2024, 15:1367828.
- [13] 鲁向晖, 龚荣新, 张海娜, 等. 基于无人机多光谱遥感的矮林芳樟光合参数估测[J]. 农业机械学报, 2023, 54(10):179–187.
Lu Xianghui, Gong Rongxin, Zhang Haina, et al. Estimation of photosynthetic parameters of *Cinnamomum camphora* in dwarf forest based on UAV multi-spectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10):179–187. (in Chinese)
- [14] 杨朝选, 焦国利, 郑先波. 重水分胁迫下苹果树茎、叶水势的变化[J]. 果树学报, 2002, 19(2):71–74.
Yang Chaoxuan, Jiao Guoli, Zheng Xianbo. Variations of leaf and stem water potentials in field grown apple trees under severe water stress[J]. Journal of Fruit Science, 2002, 19(2):71–74. (in Chinese)
- [15] Bannari A, Morin D, Bonn F, et al. A review of vegetation indices[J]. Remote Sensing Reviews, 1995, 13(1–2):95–120.
- [16] Punalekar S M, Thomson A, Verhoef A, et al. Assessing suitability of Sentinel-2 bands for monitoring of nutrient concentration of pastures with a range of species compositions[J]. Agronomy, 2021, 11(8):1661.
- [17] Upendar K, Agrawal K N, Chandel N S, et al. Greenness identification using visible spectral colour indices for site specific weed management[J]. Plant Physiology Reports, 2021, 26(1):179–187.
- [18] Huang X, Lin D, Mao X, et al. Multi-source data fusion for estimating maize leaf area index over the whole growing season under different mulching and irrigation conditions[J]. Field Crops Research, 2023, 303:109111.
- [19] Xue J, Su B. Significant remote sensing vegetation indices: a review of developments and applications[J]. Journal of Sensors, 2017, 2017:1–17.
- [20] Xu X, Liu L, Han P, et al. Accuracy of vegetation indices in assessing different grades of grassland desertification from UAV[J]. International Journal of Environmental Research and Public Health, 2022, 19(24):16793.
- [21] Shuai G, Fowler A, Basso B. Within-season vegetation indices and yield stability as a predictor of spatial patterns of maize (*Zea mays* L.) yields[J]. Precision Agriculture, 2024, 25(2):963–982.
- [22] Gao B. NDWI: a normalized difference water index for remote sensing of vegetation liquid water from space[J]. Remote Sensing of Environment, 1996, 58(3):257–266.
- [23] Gupta K, Kumar P, Pathan S K, et al. Urban neighborhood green index: a measure of green spaces in urban areas[J]. Landscape and Urban Planning, 2012, 105(3):325–335.
- [24] Cao X, Liu Y, Yu R, et al. A comparison of UAV RGB and multispectral imaging in phenotyping for stay green of wheat population[J]. Remote Sensing, 2021, 13(24):5173.
- [25] 王蕾, 王鹏新, 李俐, 等. 河北省中部平原玉米长势遥感综合监测[J]. 资源科学, 2018, 40(10):2099–2109.
Wang Lei, Wang Pengxin, Li Li, et al. Integrated maize growth monitoring based on gray correlation analysis and remote sense data in the central plain of Hebei Province[J]. Resources Science, 2018, 40(10):2099–2109. (in Chinese)
- [26] 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.
- [27] 徐云飞, 程琦, 魏祥平, 等. 变异系数法结合优化神经网络的无人机冬小麦长势监测[J]. 农业工程学报, 2021, 37(20):71–80.
Xu Yunfei, Cheng Qi, Wei Xiangping, et al. Monitoring of winter wheat growth under UAV using variation coefficient method and optimized neural network[J]. Transactions of the CSAE, 2021, 37(20):71–80. (in Chinese)
- [28] 谭丞轩. 基于无人机多光谱遥感的大田玉米土壤含水率估算模型研究[D]. 杨凌: 西北农林科技大学, 2020.
Tan Chengxuan. Research on the estimation model of field maize soil moisture content based on UAV multispectral remote sensing[D]. Yangling: Northwest A&F University, 2020. (in Chinese)
- [29] Benesty J, Chen J, Huang Y, et al. Pearson correlation coefficient[M]//Cohen I, Huang Y, Chen J, et al. Noise reduction in speech processing. Berlin Heidelberg: Springer, 2009:1–4.
- [30] 夏媛媛, 冯全, 杨森, 等. 基于高光谱遥感的苹果园土壤水分估测研究[J]. 林业机械与木工设备, 2023, 51(4):24–32.
Xia Yuanyuan, Feng Quan, Yang Sen, et al. Estimation of apple orchard soil moisture based on hyperspectral remote sensing

[J]. Forestry Machinery & Woodworking Equipment, 2023, 51(4):24–32. (in Chinese)

[31] 曾小松, 宦克为, 曹献文, 等. 基于竞争性自适应重加权采样和二维卷积神经网络的小麦水分含量的定量测定[J]. 长春理工大学学报(自然科学版), 2024, 47(6):36–44.
Zeng Xiaosong, Huan Kewei, Cao Xianwen, et al. Determination of moisture content in wheat using competitive adaptive reweighted sampling and two-dimensional convolutional neural networks[J]. Journal of Changchun University of Science and Technology (Natural Science Edition), 2024, 47(6):36–44. (in Chinese)

[32] 陈立旦, 赵艳茹. 可见-近红外光谱联合随机蛙跳算法检测生物柴油含水量[J]. 农业工程学报, 2014, 30(8):168–173.
Chen Lidan, Zhao Yanru. Measurement of water content in biodiesel using visible and near infrared spectroscopy combined with random-frog algorithm[J]. Transactions of the CSAE, 2014, 30(8):168–173. (in Chinese)

[33] 龙燕, 连雅茹, 马敏娟, 等. 基于高光谱技术和改进型区间随机蛙跳算法的番茄硬度检测[J]. 农业工程学报, 2019, 35(13):270–276.
Long Yan, Lian Yaru, Ma Minjuan, et al. Detection of tomato hardness based on hyperspectral technology and modified interval random frog algorithm[J]. Transactions of the CSAE, 2019, 35(13):270–276. (in Chinese)

[34] 焦李成, 杨淑媛, 刘芳, 等. 神经网络七十年: 回顾与展望[J]. 计算机学报, 2016, 39(8):1697–1716.
Jiao Licheng, Yang Shuyuan, Liu Fang, et al. Seventy years of neural networks: review and prospect[J]. Chinese Journal of Computers, 2016, 39(8):1697–1716. (in Chinese)

[35] 高凯, 杨海波, 尹航, 等. 基于波段优化光谱指数的马铃薯叶水势估测[J]. 灌溉排水学报, 2025, 44(3):1–11.
Gao Kai, Yang Haibo, Yin Hang, et al. Estimating leaf water potential of potato using band-optimized spectral indices[J]. Journal of Irrigation and Drainage, 2025, 44(3):1–11. (in Chinese)

[36] 蒋鹏艳, 高晓东, 何娜娜, 等. 基于多光谱遥感的刺槐正午叶水势反演[J]. 西南林业大学学报(自然科学), 2025, 45(4):142–149.
Jiang Pengyan, Gao Xiaodong, He Nana, et al. Inversion of *Robinia pseudoacacia* midday leaf water potential based on UAV multispectral images[J]. Journal of Southwest Forestry University (Natural Sciences), 2025, 45(4):142–149. (in Chinese)

[37] 李虎, 钟韵, 冯雅婷, 等. 无人机遥感的多植被指数土壤水分反演模型[J]. 光谱学与光谱分析, 2024, 44(1):207–214.
Li Hu, Zhong Yun, Feng Yating, et al. Multi-vegetation index soil moisture inversion model based on UAV remote sensing[J]. Spectroscopy and Spectral Analysis, 2024, 44(1):207–214. (in Chinese)

(上接第 307 页)

[20] Huo P, Ma S, Su C, et al. Emergency obstacle avoidance system of sugarcane basecutter based on improved YOLO v5s[J]. Computers and Electronics in Agriculture, 2024, 216: 108468.

[21] Xu W, Liu L. PCNN orchard heterologous image fusion with semantic segmentation of significance regions[J]. Computers and Electronics in Agriculture, 2024, 216: 108454.

[22] Cui J S, Zhang F R, Feng D Z, et al. An improved SLAM based on RK-VIF: vision and inertial information fusion via Runge-Kutta method[J]. Defence Technology, 2023, 21: 133–146.

[23] Rochefort-Beaudoin T, Vadean A, Achiche S, et al. From density to geometry: YOLO v8 instance segmentation for reverse engineering of optimized structures[PP/OL]. V1. arXiv (2024-04-29) [2026-03-15]. <https://doi.org/10.48550/arXiv.2404.18763>.

[24] Miki T, Wellhausen L, Grandia R, et al. Elevation mapping for locomotion and navigation using GPU[J]. IEEE Robotics and Automation Letters, 2022, 7(3): 7412–7419.

[25] GB/T 37164—2018 自走式农业机械导航系统作业性能要求及评价方法[S].

[26] Zheng C, Zhang P, Li Y. Semantic SLAM system for mobile robots based on large visual model in complex environments[J]. Scientific Reports, 2025, 15: 8450.

[27] Wang H, Jiang B, Xu H. Semantic SLAM based on ORB-SLAM3 combined with YOLO v5 in dynamic environment[C]//Proceedings of the IEEE 7th International Conference on Communications, Information System and Computer Engineering. IEEE, 2025: 535–539.

[28] Qin T, Li P, Shen S. VINS-Mono: a robust and versatile monocular visual-inertial state estimator[J]. IEEE Transactions on Robotics, 2018, 34(4): 1004–1020.

[29] He K. Mask R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. IEEE, 2017: 2961–2969.

[30] Bolya D. YOLACT: real-time instance segmentation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. IEEE, 2019: 9157–9166.