

doi:10.6041/j.issn.1000-1298.2021.07.022

基于无人机多光谱遥感的马尾松林叶面积指数估测

姚 雄^{1,2} 余坤勇^{2,3} 刘 健^{2,3}

(1. 福建工程学院建筑与城乡规划学院, 福州 350118;

2.3S 技术与资源优化利用福建省高校重点实验室, 福州 350002; 3. 福建农林大学林学院, 福州 350002)

摘要: 快速、准确、无损估测马尾松林叶面积指数对精准林业管理具有重要意义。以小型低空无人机为平台,搭载 RedEdge 多光谱传感器,获取福建省西部马尾松林多光谱影像,运用重采样的方式获取并计算不同空间分辨率(0.08、0.1、0.2、0.5、1、2、5 m)下的植被指数,结合地面实测 LAI 数据,分析其与植被指数的相关性,进而采用线性模型(LR)、多元逐步回归模型(MSR)、随机森林模型(RF)、支持向量机模型(SVM)和人工神经网络模型(BP)构建不同空间分辨率下的马尾松林 LAI 估测模型,以决定系数(R^2)、均方根误差(RMSE)、相对分析误差(RPD)和总体精度(TA)来评价估测模型精度,从而确定最佳空间分辨率和最佳模型。结果表明,不同空间分辨率下 LAI 与植被指数均呈极显著相关($p < 0.01$);多变量模型(MSR、RF、SVM、BP)的调整 R^2 平均值高于 LR 模型;随着空间分辨率的增加,不同模型的 R^2 整体上呈先增大后减小的趋势;当空间分辨率为 0.5 m 时,利用植被指数建立的 RF 模型为马尾松林 LAI 的最佳估测模型,RF 模型的调整 R^2 为 0.766,模型估测的 R^2 、RMSE、RPD 和 TA 分别为 0.554、0.421、1.523 和 81.95%。本研究可为无人机多光谱遥感反演森林 LAI 表型参数的空间分辨率和模型选择提供理论参考。

关键词: 马尾松; 叶面积指数; 空间分辨率; 无人机; 随机森林模型; 遥感

中图分类号: S127 文献标识码: A 文章编号: 1000-1298(2021)07-0213-09 OSID: 

Leaf Area Index Estimation of Masson Pine (*Pinus massoniana*) Forests Based on Multispectral Remote Sensing of UAV

YAO Xiong^{1,2} YU Kunyong^{2,3} LIU Jian^{2,3}

(1. College of Architecture and Urban Planning, Fujian University of Technology, Fuzhou 350118, China

2. University Key Laboratory for Geomatics Technology and Optimize Resources Utilization in Fujian Province, Fuzhou 350002, China

3. College of Forestry, Fujian Agriculture and Forestry University, Fuzhou 350002, China)

Abstract: Fast, accurate and non-destructive estimation of the leaf area index (LAI) of Masson pine forest is of great significance for precise forestry management. In order to estimate LAI of Masson pine forest, the small low-altitude unmanned aerial vehicle (UAV) platform with the American MicaSense RedEdge multi-spectral sensor was used to obtain the multi-spectral image in western Fujian. Eight different kinds of vegetation indices, green normalized vegetation index (GNDVI), green ratio vegetation index (GRVI), modified soil adjusted vegetation index (MSAVI), normalized difference vegetation index (NDVI), renormalized difference vegetation index (RDVI), ratio vegetation index (RVI), structure insensitive pigment index (SIPI) and visible atmospherically resistant index (VARI) were calculated from imagines with seven spatial resolutions (0.08 m, 0.1 m, 0.2 m, 0.5 m, 1 m, 2 m and 5 m). The correlation between ground-measured LAI and different vegetation indices from different spatial resolutions imagines were analyzed. Five models, linear regression (LR), multiple stepwise (MSR), random forest (RF), support vector machine (SVM) and artificial neural network (BP) were used to construct LAI estimation model, and coefficients of determination (R^2), root mean square errors (RMSE), residual predictive deviation (RPD) and total accuracy (TA) were used to determine the optimal spatial resolution and optimal model for computing Masson pine forest LAI. The results showed that LAI values and vegetation indices from different spatial resolutions imagines were significantly

收稿日期: 2020-11-21 修回日期: 2020-12-08

基金项目: 国家自然科学基金项目(31770760, 41401385)

作者简介: 姚雄(1990—), 男, 讲师, 博士, 主要从事 3S 技术应用研究, E-mail: fyx@fjut.edu.cn

通信作者: 刘健(1963—), 男, 教授, 博士生导师, 主要从事资源环境监测与 3S 技术应用研究, E-mail: fliujian@126.com

correlated ($p < 0.01$)。The adjusted R^2 average values of the multivariate models (MSR, RF, SVM, BP) were higher than that of the LR model. The R^2 of different models was generally increased first and then decreased with the increase of spatial resolution. RF model was the optimal model for Masson pine forest when the spatial resolution was 0.5 m. The highest accuracy for RF model with R^2 of 0.766 for calibration, and with R^2 of 0.554, RMSE of 0.421, RPD of 1.523, and TA of 81.95% for validation. The research result can provide a theoretical reference for the spatial resolution and model selection in the inversion of forest LAI phenotypic parameters by UAV multi-spectral remote sensing image.

Key words: Masson pine; leaf area index; spatial resolution; unmanned aerial vehicle; random forest model; remote sensing

0 引言

叶面积指数(Leaf area index, LAI)指单位水平地面面积上所有绿叶面积总和的一半^[1],是表征森林冠层结构的重要参数,也是描述森林植被的光合作用、蒸腾作用、呼吸作用、降水截留作用和碳氮循环过程的关键参数,经常用于评价森林生产力、森林质量和森林健康状况^[2-4]。马尾松(*Pinus massoniana* Lamb.)是南方红壤区典型的造林树种,具有耐干旱耐贫瘠土壤、适应性强、生长迅速等特点,已成为南方水土流失区域荒山造林的先锋树种^[5],其健康状况和长势对红壤区水土流失监测评价与治理具有重要意义。因此,准确估测马尾松林的LAI,对森林生态系统完整性以及碳氮循环过程研究尤为重要。

目前,获取林分LAI的方法有直接测量法和间接测量法^[6]。直接测量法精度较高,但需要对林木进行破坏性采集,不仅费时、费力,而且选取林木不一定具有代表性,因此这种方法很难应用于大尺度、长时序的研究。间接测量法主要利用遥感技术获取植被光谱信息,进而利用模型对LAI进行估算,具有破坏性小或无破坏性、测量高效等特点。常用的遥感技术主要包括卫星遥感、地面遥感、载人机遥感和无人机遥感^[7-8]。其中,无人机遥感因灵活性高、机动性强、操作简便、成本低等优势而逐渐成为精准农业和精准林业管理的又一重要技术,也是获取植被冠层表型参数的重要手段^[9-11]。现有研究促进了无人机遥感技术在植被LAI估测中的应用,但也存在以下不足:对于无人机影像空间分辨率的选择缺乏统一标准,具有一定的随意性,这给植被LAI估测模型推广带来一定困难;利用经验统计模型、机器学习模型和物理模型反演植被LAI,并通过一种方法或两种方法建模,而采用多种方法进行对比分析的相关研究还比较少。目前,国内外利用无人机遥感技术进行植被LAI的估测研究主要集中在农作物上,而针对森林的研究还鲜见报道^[11],尚未见关于马尾松林LAI无人机遥感估测的相关研究。因此,

探讨不同模型下不同空间分辨率影像对马尾松林LAI估测精度的影响,对精准林业管理和森林冠层表型参数遥感估测技术规范的制定具有重要意义。

本文以无人机搭载的多光谱传感器为平台,获取马尾松林光谱信息,选取相关性高的植被指数,运用多种方法分别构建不同空间分辨率下的LAI估测模型,比较分析各模型的估测精度,从而得到最佳模型和最佳空间分辨率,为无人机影像空间分辨率的选择提供理论依据,以支撑精准林业中森林冠层表型参数无人机遥感估测。

1 材料与方法

1.1 研究区概况

研究区位于福建省西部的长汀县河田镇($25^{\circ}33' \sim 26^{\circ}48'N$ 、 $116^{\circ}18' \sim 116^{\circ}31'E$),如图1所示。该区属于典型的中亚热带季风气候,年平均降雨量为1621 mm,其中一半以上的降雨量集中在4—6月,年平均气温为19℃,年平均无霜期为260 d;土地利用现状以林地为主,森林覆盖率超过70%,优势树种是马尾松,约占森林面积的80%。试验地为马尾松纯林,林龄35 a,林分密度约1800株/ hm^2 ,平均树高小于8 m,平均胸径小于10 cm,较好地代表了南方红壤水土流失区马尾松人工林现状,适合森林LAI无人机遥感估测试验的开展。

1.2 叶面积指数采集

2018年4月在试验地布设了72个10 m × 10 m样方,在每个样方中心点附近测量LAI。借助LAI-2200型植物冠层分析仪(Li-COR Inc., Lincoln, NE,美国)采用1A4B方式测定LAI,即选用90°遮盖帽在离地1.5 m处顺序测量1次样方外空旷处A值和4次样方B值,测量结束后,仪器自动根据朗伯-比尔定律计算并记录LAI;测量同时,利用集思宝手持式GPS定位仪记录该中心点的坐标。为了减少误差,每个样方中心点重复测量3次,取其平均值作为该点的LAI,共获取72组LAI数据。

1.3 无人机影像数据获取及预处理

采用云上晴空公司生产的WG-18型无人机平

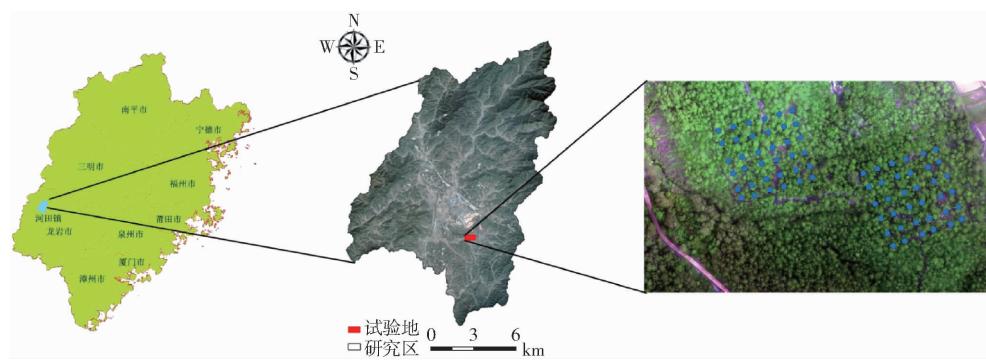


图 1 研究区地理位置图

Fig. 1 Geographic location diagram of study area

台搭载美国 MicaSense 公司生产的 RedEdge 多光谱传感器进行试验地遥感影像的获取, 获取时间为 2018 年 4 月。该传感器包含 5 个通道: 蓝光通道(中心波长 475 nm)、绿光通道(中心波长 560 nm)、红光通道(中心波长 668 nm)、红边通道(中心波长 717 nm)、近红外通道(中心波长 840 nm)。飞行前, 利用传感器配套的白板进行校正。飞行时, 航高设置为 120 m, 航向和旁向重叠率均设置为 80%, 航行速度设置 5 m/s。为降低影像数据受阳光直射效应的影响, 选择无风且阳光充足的时间段(11:00—14:00)进行影像数据采集。采用 Pix4D Mapper 和 ERDAS 软件对无人机获取的数据进行影像拼接和波段融合, 首先将无人机采集的各波段影像数据和标准定标板数据导入 Pix4D Mapper 软件中进行辐射校准并生成单波段拼接影像, 然后利用 ERDAS 对拼接后的单波段影像进行波段融合, 融合后的影像空间分辨率为 0.08 m。

1.4 植被指数选择与提取

植被指数是由遥感数据多种波段经线性和非线性组合而成的遥感产品, 相比于单波段数据, 植被指数可以更有效地度量地表植被长势、生物量和覆盖度等指标。目前常用的植被指数中, 归一化植被指数是应用最广泛、最简单的植被指数, 可用于区域植被覆盖度和植被生理参数的检测, 比值植被指数可用于生物量估算, 修正型土壤调整植被指数降低了土壤背景对植被的影响。此外, 不少研究者利用植被指数进行森林 LAI 估算, 如傅银贞等^[12] 分析了马尾松林 LAI 与 7 种植被指数的相关性, 并进行回归分析, 结果表明, 转换型归一化差值植被指数和归一化植被指数对马尾松林 LAI 具有较好的预测性; 董立新^[13] 基于 7 种常用植被指数和 5 种自定义植被指数对三峡库区阔叶林、针叶林和混交林的 LAI 进行估算, 3 种森林类型的 LAI 估算模型的决定系数 R^2 均达到 0.77 以上。因此, 本文借鉴相关研究者的研究结果, 选择 8 种对 LAI 变化敏感的植被指数: 绿

色归一化植被指数(GNDVI)^[14]、绿色比值植被指数(GRVI)^[15]、修正型土壤调整植被指数(MSAVI)^[16]、归一化植被指数(NDVI)^[17]、再归一化植被指数(RDVI)^[18]、比值植被指数(RVI)^[19]、冠层结构不敏感植被指数(SIPI)^[20]、可见光大气修正植被指数(VARI)^[21]。

为了分析无人机影像空间分辨率对马尾松林 LAI 估算结果的影响, 本文将原始无人机影像数据进行重采样。考虑到试验地的马尾松平均冠幅小于 5 m, 因此设置原始影像重采样为空间分辨率分别为 0.1、0.2、0.5、1、2、5 m, 并借助 ERDAS 软件中的建模工具, 根据植被指数的计算公式分别提取不同空间分辨率下的植被指数。

1.5 模型构建方法

研究采用经验统计模型(一元回归模型和多元逐步回归模型)和机器学习模型(神经网络模型、支持向量机模型和随机森林模型)建立不同空间分辨率的马尾松林 LAI 无人机估测模型。

一元回归模型用于表示预测项目(LAI)与单个预测因子(植被指数)之间的关系。本文利用 Matlab R2014b 建立 LAI 的线性回归(Linear regression, LR)、对数、指数和乘幂模型。

多元逐步回归分析(Multiple stepwise regression, MSR)的基本思路是: 将所有植被指数按照其对 LAI 影响的显著程度, 从小到大依次排序, 每一步选一个最显著的植被指数进入回归方程。首先, 将最显著的植被指数引入回归方程组成一元回归方程。其次, 从剩下的植被指数中选择最显著的植被指数引入回归方程中, 并对回归方程中的所有植被指数进行显著性检验。如果植被指数显著, 则留在回归方程中; 反之则移除, 直至回归方程中的植被指数均对 LAI 的作用显著。如此反复选取, 直至最后再无显著的植被指数可以引入, 同时回归方程中也没有作用不显著的植被指数需要移除^[22]。采用 Matlab R2014b 构建 MSR 模型。

反向传播(Back propagation, BP)神经网络模型是RUMELHART和MCCELLAND^[23]提出的一种基于误差反向传播算法的多层前向型神经网络算法,是目前应用最广泛的神经网络模型。本文BP模型结构采用输入层、单层隐藏层和输出层3层网络结构,通过交叉验证优化得到输入层到隐藏层的传递函数为tansig、隐藏层到输出层的传递函数为purelin、训练方法为LM算法、学习率为0.01、迭代次数为200的误差反向传播模型。本文采用Matlab R2014b构建BP模型。

支持向量机模型(Support vector machine, SVM)是VAPNIK^[24]基于统计学习理论,依据Vapnik-Chervonenkis理论和结构风险最小化理论提出的解决最优解问题的机器学习算法。SVM的基本思想是把训练样本通过非线性变换映射到高维特征空间,然后通过多种算法训练解算高维特征空间中的最优超平面。目前,SVM已被广泛应用于LAI反演研究^[25-26]。SVM预测的核心问题是确定核函数和模型相关参数。研究利用R软件中的e1071软件包进行参数优化并构建SVM,最终选择核函数为高斯核函数,惩罚因子C为7.2,核函数参数 γ 为0.0421。

随机森林(Random forest, RF)模型是BREIMAN^[27]于2001年提出的一种基于分类回归树的集成学习方法。它可以用来处理分类和回归问题。RF回归的主要思想是从n个原始训练集中应用自助法有放回的随机抽取k个样本,并由此生成k个决策树建模结果,根据所有决策树的建模结果,取其平均值得到最终预测结果。RF预测精度依赖于森林中决策树的数量 n_{tree} 和分割节点的随机变量

数 m_{try} 。本文通过误差分析及反复试验,选择模型参数 n_{tree} 为500、 m_{try} 为3构建RF模型。本文采用R软件中的randomForest软件包构建RF模型。

1.6 模型精度评价

为了检验模型的精度,采用保留样本交叉检验方式将72个样本数据按照2:1的比例随机划分为建模集(48个)和检验集(24个)。建模集用来构建LAI估测模型,检验集用来评价估测模型的精度。采用决定系数(R^2)、均方根误差(Root mean square error, RMSE)、相对分析误差(Residual predictive deviation, RPD)、总体精度(Total accuracy, TA)对LAI预测模型的精度进行评价^[1]。 R^2 、RPD和TA越大,RMSE越小,说明模型的预测精度越高。

2 结果与分析

2.1 叶面积指数与植被指数的相关性分析

利用48个建模集实测的LAI,分别与7个不同空间分辨率下计算的遥感植被指数进行相关性分析,结果见表1。由表1可知,不同空间分辨率下LAI与8种植被指数均呈极显著相关($p < 0.01$),且它们的相关系数均大于0.4。从植被指数来看,NDVI与LAI的相关系数在不同空间分辨率中均最大,相关系数均大于0.6,且最大达到0.819。从影像分辨率来看,LAI与植被指数的相关系数整体上呈现先增大后减小的趋势,并在空间分辨率为5 m时,相关系数大幅降低;在0.08 m和0.1 m空间分辨率的尺度下,各植被指数的相关系数由大到小依次为RVI、NDVI、VARI、SIPI、GNDVI、MSAVI、RDVI、GRVI。本文所选8种植被指数均能较好地反映马尾松林LAI的变化情况,可用来建立马尾松林LAI遥感反演模型。

表1 不同空间分辨率影像植被指数与LAI的相关系数

Tab. 1 Correlation coefficients of LAI and vegetation indices at different spatial resolutions

| 植被指数 | 0.08 m | 0.1 m | 0.2 m | 0.5 m | 1 m | 2 m | 5 m |
|-------|----------|----------|----------|----------|----------|----------|----------|
| GNDVI | 0.682 ** | 0.682 ** | 0.682 ** | 0.680 ** | 0.691 ** | 0.606 ** | 0.476 ** |
| GRVI | 0.658 ** | 0.659 ** | 0.671 ** | 0.663 ** | 0.686 ** | 0.625 ** | 0.460 ** |
| MSAVI | 0.674 ** | 0.674 ** | 0.667 ** | 0.672 ** | 0.666 ** | 0.641 ** | 0.530 ** |
| NDVI | 0.789 ** | 0.793 ** | 0.795 ** | 0.794 ** | 0.789 ** | 0.748 ** | 0.626 ** |
| RDVI | 0.660 ** | 0.663 ** | 0.655 ** | 0.660 ** | 0.638 ** | 0.624 ** | 0.520 ** |
| RVI | 0.816 ** | 0.818 ** | 0.815 ** | 0.819 ** | 0.817 ** | 0.769 ** | 0.643 ** |
| SIPI | 0.724 ** | 0.724 ** | 0.730 ** | 0.729 ** | 0.717 ** | 0.683 ** | 0.624 ** |
| VARI | 0.777 ** | 0.781 ** | 0.766 ** | 0.782 ** | 0.796 ** | 0.728 ** | 0.524 ** |

注: ** 表示在 $p < 0.01$ 水平(双侧)极显著相关。

2.2 叶面积指数单变量模型分析

基于48组建模集数据,共建立了不同空间分辨率尺度下的224种单变量模型,各模型的 R^2 见表2。从表2中可知,在空间分辨率为0.5 m时,基于RVI

构建的LAI线性模型的 R^2 最高(0.671);在空间分辨率为5 m时,基于VARI构建的LAI乘幂模型的 R^2 最低(0.157)。从模型类型来看,LAI单变量模型的 R^2 平均值由大到小依次为线性(0.487)、对数

(0.457)、指数(0.455)、乘幂(0.432)。从植被指数来看,LAI单变量模型的 R^2 平均值由大到小依次为RVI(0.587)、NDVI(0.540)、VARI(0.507)、SIP(0.463)、GNDVI(0.397)、RDVI(0.384)、GRVI(0.382)。从空间分辨率尺度来看,LAI单变量模型

的 R^2 平均值由大到小依次为0.5 m(0.501)、0.1 m(0.500)、1 m(0.499)、0.2 m(0.498)、0.08 m(0.497)、2 m(0.437)、5 m(0.270)。此外,在同一空间分辨率尺度下,基于RVI构建的LAI线性估测模型均比其他模型的 R^2 高。

表2 不同空间分辨率下单变量LAI估测模型的 R^2 Tab. 2 R^2 of single variable models estimating LAI at different spatial resolutions

| 空间分辨率/m | 估测模型 | GNDVI | GRVI | MSAVI | NDVI | RDVI | RVI | SIP | VARI |
|---------|------|-------|-------|-------|-------|-------|-------|-------|-------|
| 0.08 | 线性 | 0.464 | 0.433 | 0.454 | 0.623 | 0.436 | 0.666 | 0.525 | 0.604 |
| | 对数 | 0.440 | 0.399 | 0.443 | 0.578 | 0.431 | 0.643 | 0.489 | 0.564 |
| | 乘幂 | 0.432 | 0.384 | 0.421 | 0.544 | 0.407 | 0.601 | 0.464 | 0.526 |
| | 指数 | 0.446 | 0.408 | 0.429 | 0.578 | 0.412 | 0.617 | 0.492 | 0.556 |
| 0.1 | 线性 | 0.464 | 0.435 | 0.454 | 0.630 | 0.439 | 0.669 | 0.525 | 0.610 |
| | 对数 | 0.440 | 0.412 | 0.443 | 0.584 | 0.434 | 0.647 | 0.489 | 0.570 |
| | 乘幂 | 0.432 | 0.396 | 0.421 | 0.550 | 0.410 | 0.603 | 0.464 | 0.533 |
| | 指数 | 0.446 | 0.409 | 0.429 | 0.584 | 0.414 | 0.619 | 0.492 | 0.564 |
| 0.2 | 线性 | 0.464 | 0.450 | 0.445 | 0.632 | 0.429 | 0.664 | 0.533 | 0.586 |
| | 对数 | 0.440 | 0.430 | 0.431 | 0.585 | 0.422 | 0.641 | 0.496 | 0.548 |
| | 乘幂 | 0.432 | 0.417 | 0.411 | 0.554 | 0.400 | 0.599 | 0.467 | 0.511 |
| | 指数 | 0.446 | 0.426 | 0.422 | 0.589 | 0.406 | 0.615 | 0.496 | 0.540 |
| 0.5 | 线性 | 0.463 | 0.440 | 0.452 | 0.630 | 0.436 | 0.671 | 0.532 | 0.611 |
| | 对数 | 0.433 | 0.407 | 0.443 | 0.584 | 0.432 | 0.648 | 0.495 | 0.569 |
| | 乘幂 | 0.422 | 0.395 | 0.424 | 0.551 | 0.410 | 0.606 | 0.470 | 0.533 |
| | 指数 | 0.441 | 0.417 | 0.431 | 0.585 | 0.414 | 0.622 | 0.499 | 0.565 |
| 1 | 线性 | 0.478 | 0.471 | 0.444 | 0.623 | 0.406 | 0.668 | 0.514 | 0.633 |
| | 对数 | 0.444 | 0.434 | 0.435 | 0.574 | 0.405 | 0.642 | 0.476 | 0.597 |
| | 乘幂 | 0.417 | 0.416 | 0.415 | 0.541 | 0.386 | 0.600 | 0.448 | 0.562 |
| | 指数 | 0.442 | 0.440 | 0.422 | 0.579 | 0.388 | 0.619 | 0.478 | 0.588 |
| 2 | 线性 | 0.367 | 0.390 | 0.411 | 0.560 | 0.389 | 0.591 | 0.467 | 0.530 |
| | 对数 | 0.356 | 0.388 | 0.386 | 0.499 | 0.373 | 0.567 | 0.425 | 0.478 |
| | 乘幂 | 0.346 | 0.374 | 0.374 | 0.478 | 0.357 | 0.536 | 0.406 | 0.457 |
| | 指数 | 0.347 | 0.365 | 0.395 | 0.525 | 0.370 | 0.553 | 0.440 | 0.497 |
| 5 | 线性 | 0.226 | 0.190 | 0.281 | 0.392 | 0.271 | 0.413 | 0.385 | 0.275 |
| | 对数 | 0.175 | 0.177 | 0.248 | 0.336 | 0.241 | 0.402 | 0.344 | 0.197 |
| | 乘幂 | 0.182 | 0.186 | 0.210 | 0.291 | 0.204 | 0.355 | 0.313 | 0.157 |
| | 指数 | 0.234 | 0.196 | 0.246 | 0.344 | 0.236 | 0.368 | 0.352 | 0.227 |

2.3 叶面积指数多变量模型分析

表3为不同空间分辨率尺度下LAI多变量估测模型的调整 R^2 。由表3可知,在空间分辨率为0.5 m时,基于RF算法建立的LAI估测模型的调整 R^2 最高(0.766),比单变量 R^2 最高值(0.671)提高了14%;在空间分辨率为5 m时,基于MSR模型构建

的LAI估测模型的调整 R^2 最低(0.401),但比单变量 R^2 最低值(0.157)增加了0.244。从模型类型看,LAI多变量模型的调整 R^2 平均值由大到小依次为RF(0.695)、SVM(0.683)、BP(0.670)、MSR(0.668)。从空间分辨率尺度来看,LAI多变量模型的调整 R^2 平均值均比单变量模型高,说明LAI多变

表3 不同空间分辨率下多变量LAI估测模型的调整 R^2 Tab. 3 Adjusted R^2 of multivariable variable models estimating LAI at different spatial resolutions

| 估测模型 | 0.08 m | 0.1 m | 0.2 m | 0.5 m | 1 m | 2 m | 5 m |
|------|--------|-------|-------|-------|-------|-------|-------|
| MSR | 0.728 | 0.732 | 0.718 | 0.737 | 0.744 | 0.615 | 0.401 |
| BP | 0.743 | 0.711 | 0.736 | 0.731 | 0.705 | 0.627 | 0.436 |
| SVM | 0.736 | 0.727 | 0.729 | 0.743 | 0.715 | 0.649 | 0.485 |
| RF | 0.747 | 0.729 | 0.734 | 0.766 | 0.741 | 0.633 | 0.512 |

量模型比单变量模型的建模精度高,对应的调整 R^2 平均值由大到小依次为 0.5 m (0.744)、0.08 m (0.739)、0.2 m (0.729)、1 m (0.726)、0.1 m (0.725)、2 m (0.631)、5 m (0.459)。

2.4 马尾松林叶面积指数遥感反演模型比较分析

基于 24 组检验集数据,利用单变量最优模型(即线性模型)和 4 个多变量模型,得到不同空间分辨率尺度下 5 个模型的 LAI 估测数据,通过与野外实测 LAI 数据比较分析,评价不同空间分辨率尺度下不同模型的预测性能,结果见图 2。由图 2 可知,除 BP 算法外,其余模型整体上在空间分辨率尺度为 0.08~0.5 m 内变化幅度不大,而在空间分辨率尺度为 1~5 m 范围内整体上呈急剧下降的趋势;当空间分辨率尺度为 0.5 m 时,RF 算法的 R^2 最高,达到 0.554。均方根误差 RMSE 的变化趋势与 R^2 相反,即模型 RMSE 在空间分辨率尺度为 0.08~0.5 m 内随着分辨率的增大其值变化幅度较小,随着空间分辨率尺度的进一步增大,其值整体上呈增加的趋势;当空间分辨率尺度为 0.5 m 时,RF 算法的 RMSE 最低,仅为 0.421。模型相对分析误差和总体精度的变化规律与 R^2 较为一致,即在空间分辨率尺度为 0.5 m 时,RF 算法的模型相对分析误差最高(1.523),总体精度达到最大,最大值为 81.95%。由此可知,空间分辨率尺度为 0.5 m 时 RF 模型得到的反演结果较为理想。

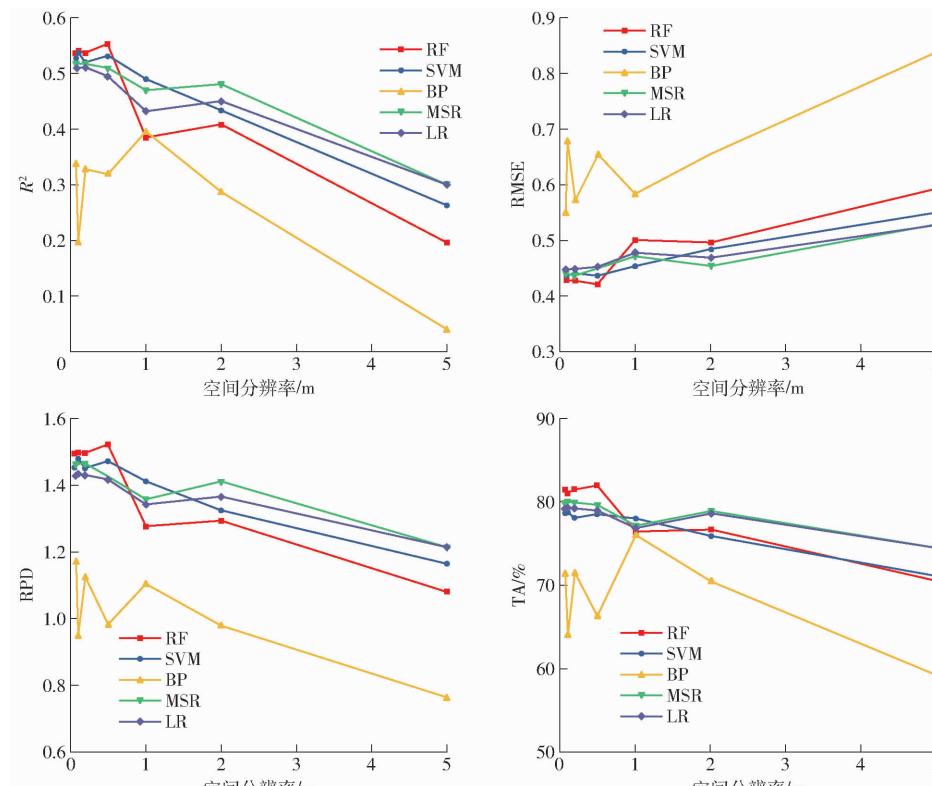


图 2 LAI 估算模型在不同空间分辨率下的性能比较

Fig. 2 Performance comparison of LAI estimation models at different spatial resolutions

研究表明,利用无人机影像数据进行林地 LAI 遥感反演时,影像空间分辨率尺度并非越高越好,在选择合适的预测因子和模型前提下,空间分辨率尺度的选择对保证 LAI 的反演精度至关重要,因而在进行林地 LAI 无人机遥感反演时,需根据树种类型以及叶片和冠幅大小选择合适的空间分辨率影像。

2.5 马尾松林叶面积指数空间分布

根据前文分析结果,研究采用 0.5 m 空间分辨率尺度下的 RF 模型进行马尾松林 LAI 的空间反演(图 3)。从图 3 中可以看出,试验地 LAI 在 0~4.35 之间,平均值为 1.46,且大部分区域的 LAI 在 0~2 之间;中部区域的 LAI 普遍低于西南部区域的 LAI,可能原因是 2017 年 7 月课题组在中部区域进行了一次马尾松目标树采伐作业,加上多次的外业工作,破坏了林下植被覆盖状况,导致植被较为稀疏,从而使该区域的 LAI 低于西南部的 LAI。由此可知,基于 0.5 m 空间分辨率下的 RF 模型能够较好地还原马尾松林 LAI 的分布格局。

3 讨论

目前,利用无人机多光谱成像仪进行植被参数的反演研究,主要通过提取植被指数建立经验统计模型或机器学习模型进行植被参数的估测,不同研究区、植被类型和估算方法得到的研究结果基本一致^[28~31],但精度有一定差异。本文利用 LR、MSR、

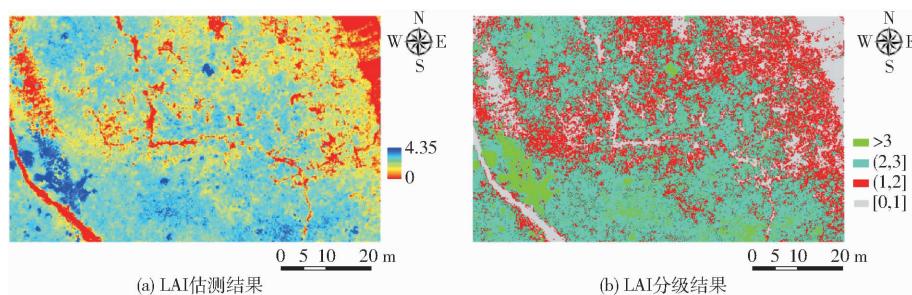


图3 马尾松林 LAI 空间分布图

Fig. 3 Spatial distributions of LAI for Massion pine forest

RF、SVM、BP 共 5 种方法构建了马尾松林 LAI 无人机估测模型, 通过对比回分析发现, 基于多变量模型 (MSR、RF、SVM、BP) 的 LAI 估测精度普遍优于单变量 (LR) 模型, 这与多变量模型中多种自变量比单变量模型能更全面挖掘遥感数据信息有关。这与文献[32]利用单变量模型和多变量模型进行阔叶林、针叶林、针阔混交林等林地 LAI 的研究结果一致。除 BP 模型外, 其他 4 种模型的决定系数 R^2 均在空间分辨率为 0.5 m 时达到最高, 且随着空间分辨率的变化, 对应的 R^2 均降低, 并在空间分辨率为 5 m 时降至 0.4 以下。其原因主要是 LAI 反映了单位水平面积上绿叶总叶面积的一半, 在影像空间分辨率较高 (0.08 ~ 0.2 m) 的情况下, 可能会出现马尾松叶簇完全包含整个像元的现象, 此时基于间隙率计算的 LAI 较易失真, 从而降低模型的 R^2 ; 而在空间分辨率越来越低 (1 ~ 5 m) 的情况下, 可能由于像元中存在的混合信息越来越复杂, 导致模型的估测性能下降。这与文献[33]利用无人机影像进行玉米冠层的 LAI、叶绿素含量的研究结果基本一致。

在空间分辨率较高时, RF 模型的检验精度均最高, 主要原因是 RF 模型对自变量共线性问题不敏感, 且不需要检验变量的正态性和独立性, 加上该模型在回归分析过程中进行了两次随机抽样, 其预测结果不是某一个回归方程的预测结果, 而是多个预测值的平均值, 可有效提高模型的精度。尽管 BP 模型在建模集中的调整 R^2 均高于 LR 模型, 甚至在空间分辨率为 0.2 m 时的调整 R^2 高于 SVM 和 RF 模型, 但 BP 模型在检验集中的预测精度普遍低于其他 4 种模型。造成 BP 模型预测精度较低的原因可能是该模型在建模集训练过程中学习能力过强或模型陷入局部最优解, 导致学习模型未能有效包含建模集的内在规律, 从而造成模型在检验集中的泛化能力较弱^[1]。在空间分辨率较低时, 可能由于单个像素中含有的混合信息较复杂, 导致 5 种模型的估测精度均较低。

需要指出的是, 本文建模集和检验集中 LAI 估算模型的 R^2 最高值均低于 0.800, 精度相对比较低,

造成此现象的原因可能是试验地地形因素的限制, 加上地面实测点不足且比较集中, 弱化了实测点之间的空间异质性。此外, 研究采用的是 LAI-2200 型植物冠层分析仪以自下向上测定 LAI, 即通过 5 个天顶角方位 ($7^\circ, 22^\circ, 38^\circ, 52^\circ, 68^\circ$) 综合观测冠层空隙率结合朗伯-比尔定律获取 LAI, 而无人机采样角度(本次是垂直拍摄)以自上向下观测方式仅能获取顶部冠层光谱信息, 两者之间必然存在误差。再者, 基于光谱信息构建的植被指数在反演 LAI 时容易出现光谱信息“饱和”现象, 从而影响模型估测精度。有研究表明, 在光谱信息的基础上引入纹理特征信息可以显著提高 LAI 或其他植被参数的估算精度^[8,34]。后期将改进这些问题, 引入多角度信息、纹理特征和地形变量等, 以获取更加精确的估算结果。研究仅对试验地的马尾松林进行了 LAI 估测研究, 最佳分辨率为 0.5 m, 接近于试验地马尾松林平均冠幅半径的一半, 因此利用无人机影像反演林分 LAI 的最佳分辨率可能与林分冠幅大小或叶片大小存在相关性。后续工作将进一步确定利用无人机影像估算其他林分植被 LAI 的合适空间分辨率, 以验证本文研究结果的普适性程度。

4 结论

(1) 在不同空间分辨率尺度下选取的植被指数与马尾松林 LAI 均呈极显著相关, 相关系数均大于 0.4, 且 7 个空间分辨率尺度中 RVI 与 LAI 的相关性最高。

(2) 构建 LAI 和植被指数之间的单变量模型 (线性、对数、乘幂、指数模型) 和多变量模型 (MSR、BP、SVM、RF 模型), 对建模样本的 R^2 进行对比分析, 结果表明, 4 种多变量模型的调整 R^2 平均值均比单变量模型高, 其中基于 RF 模型建立的 LAI 估测模型在空间分辨率为 0.5 m 时调整 R^2 最高, 达 0.766。

(3) 用 LR、MSR、RF、SVM、BP 共 5 种模型估算不同空间分辨率下的马尾松林 LAI, 研究无人机影像空间分辨率对 LAI 估测精度的影响, 研究表明, 选

择最优的估算模型和空间分辨率才能得到高精度的估测结果,空间分辨率为0.5 m时RF模型的估测效

果最佳,可作为水土流失区域马尾松林LAI监测的主要模型。

参考文献

- [1] 姚雄,余坤勇,杨玉洁,等.基于随机森林模型的林地叶面积指数遥感估算[J/OL].农业机械学报,2017,48(5):159–166.
YAO Xiong, YU Kunyong, YANG Yujie, et al. Estimation of forest leaf area index based on random forest model and remote sensing data [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(5):159–166. http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170519&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2017.05.019. (in Chinese)
- [2] 张国祯,甘敬,朱建刚.北京山区森林健康的多尺度评价[J].林业科学,2011,47(6):143–151.
ZHANG Guozhen, GAN Jing, ZHU Jian'gang. Multi-scale health assessment of forests in mountainous regions of Beijing [J]. Scientia Silvae Sinicae, 2011, 47(6):143–151. (in Chinese)
- [3] 柳艺博,王怀清,居为民.干旱对江西省森林生产力的影响特征[J].自然灾害学报,2016,25(3):67–77.
LIU Yibo, WANG Huaiqing, JU Weimin. Characteristics of drought effects on forest productivity in Jiangxi Province [J]. Journal of Natural Disasters, 2016, 25(3):67–77. (in Chinese)
- [4] 陶惠林,冯海宽,杨贵军,等.基于无人机成像高光谱影像的冬小麦LAI估测[J/OL].农业机械学报,2020,51(1):176–187.
TAO Huilin, FENG Haikuan, YANG Guijun, et al. Leaf area index estimation of winter wheat based on UAV imaging hyperspectral imagery [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1):176–187. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200119&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2020.01.019. (in Chinese)
- [5] YAO X, YU K, DENG Y, et al. Spatial distribution of soil organic carbon stocks in Masson pine (*Pinus massoniana*) forests in subtropical China[J]. Catena, 2019, 178(2):189–198.
- [6] 孙诗睿,赵艳玲,王亚娟,等.基于无人机多光谱遥感的冬小麦叶面积指数反演[J].中国农业大学学报,2019,24(11):51–58.
SUN Shirui, ZHAO Yanling, WANG Yajuan, et al. Leaf area index inversion of winter wheat based on multispectral remote sensing of UAV [J]. Journal of China Agricultural University, 2019, 24(11):51–58. (in Chinese)
- [7] 陈仲新,任建强,唐华俊,等.农业遥感研究应用进展与展望[J].遥感学报,2016,20(5):748–767.
CHEN Zhongxin, REN Jianqiang, TANG Huajun, et al. Progress and perspectives on agricultural remote sensing research and applications in China [J]. Journal of Remote Sensing, 2016, 20(5):748–767. (in Chinese)
- [8] 贾丹,陈鹏飞.低空无人机影像分辨率对冬小麦氮浓度反演的影响[J/OL].农业机械学报,2020,51(7):164–169.
JIA Dan, CHEN Pengfei. Effect of low-altitude UAV image resolution on inversion of winter wheat nitrogen concentration [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7):164–169. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200719&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2020.07.019. (in Chinese)
- [9] 孙刚,黄文江,陈鹏飞,等.轻小型无人机多光谱遥感技术应用进展[J/OL].农业机械学报,2018,49(3):1–17.
SUN Gang, HUANG Wenjiang, CHEN Pengfei, et al. Advances in UAV-based multispectral remote sensing applications [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(3):1–17. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180301&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.03.001. (in Chinese)
- [10] ROOSJEN P P J, BREDE B, SUOMALAINEN J M, et al. Improved estimation of leaf area index and leaf chlorophyll content of a potato crop using multi-angle spectral data-potential of unmanned aerial vehicle imagery [J]. International Journal of Applied Earth Observation & Geoinformation, 2018, 66:14–26.
- [11] 吴项乾,曹林,申鑫,等.基于无人机激光雷达的银杏人工林有效叶面积指数估测[J].林业科学,2020,56(1):74–86.
WU Xiangqian, CAO Lin, SHEN Xin, et al. Estimation of effective leaf area index using UAV-based LiDAR in Ginkgo plantation [J]. Scientia Silvae Sinicae, 2020, 56(1):74–86. (in Chinese)
- [12] 傅银贞,汪小钦,江洪.马尾松LAI与植被指数的相关性研究[J].国土资源遥感,2010,22(3):44–49.
FU Yinzen, WANG Xiaoqin, JIANG Hong. The correlation between LAI and vegetation index of masson pine [J]. Remote Sensing for Land and Resources, 2010, 22(3):44–49. (in Chinese)
- [13] 董立新.三峡库区森林叶面积指数多模型遥感估算[J].国土资源遥感,2019,31(2):73–81.
DONG Lixin. Multi-model estimation of forest leaf area index in the Three Gorges Reservoir area [J]. Remote Sensing for Land and Resources, 2019, 31(2):73–81. (in Chinese)
- [14] GITELSON A A, KAUFMAN Y J, MERZLYAK M N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS[J]. Remote Sensing of Environment, 1996, 58(3):289–298.
- [15] TUCKER C J. Red and photographic infrared linear combinations for monitoring vegetation [J]. Remote Sensing and Environment, 1979, 8(2):127–150.
- [16] QI J, CHEHBOUNI A R, HUETE A R, et al. A modified soil adjusted vegetation index[J]. Remote Sensing of Environment, 1994, 48(2):119–126.
- [17] ROUSE J W, HAAS R H, SCHELL J A, et al. Monitoring the vernal advancement of retrogradation of natural vegetation [R]. NASA/GSFC, Type III, Final Report, Greenbelt, MD, USA, 1974, 1–371.

- [18] 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.
- [19] PEARSON R L, MILLER L D. Proceedings of the 8th international symposium on remote sensing of the environment [C] // Ann Arbor, MI, USA, 1972;1357–1381.
- [20] PUNELAS J, BARET F, FILELLA I. Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance [J]. *Photosynthetica*, 1995, 31(2): 221–230.
- [21] GITELSON A A, KAUFMAN Y J, STARK R, et al. Novel algorithms for remote estimation of vegetation fraction [J]. *Remote Sensing of Environment*, 2002, 80(1):76–87.
- [22] 咸云浩,张恒德,谢永华,等.多元逐步回归与卡尔曼滤波法在霾预报中应用[J].*系统仿真学报*,2018,30(4):1482–1489.
XIAN Yunhao, ZHANG Hengde, XIE Yonghua, et al. Application of multiple-stepwise and Kalman filtering in haze forecast [J]. *Journal of System Simulation*, 2018, 30(4):1482–1489. (in Chinese)
- [23] RUMELHART D E, MCCELLAND J L. Parallel distributed processing: explorations in the microstructures of cognition [M]. Cambridge, MA: MIT Press, 1986.
- [24] VAPNIK V N. The nature of statistical learning theory [M]. New York: Springer-Verlag, 1995: 52–320.
- [25] 王丽爱,谭昌伟,杨昕,等.基于MK-SVR模型的小麦叶面积指数遥感反演[J/OL].*农业机械学报*,2015,46(5):245–251.
WANG Lai, TAN Changwei, YANG Xin, et al. Monitoring wheat leaf area index using MK-SVR algorithmic model and remote sensing data [J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2015, 46(5): 245–251. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20150535&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2015.05.035. (in Chinese)
- [26] YUAN H, YANG G, LI C, et al. Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: analysis of RF, ANN, and SVM regression models [J]. *Remote Sensing*, 2017, 9(4):309.
- [27] BREIMAN L. Random forest [J]. *Machine Learning*, 2001, 45(1): 5–32.
- [28] FANG S, TANG W, PENG Y, et al. Remote estimation of vegetation fraction and flower fraction in oilseed rape with unmanned aerial vehicle data [J]. *Remote Sensing*, 2016, 8(5): 416.
- [29] 刘昌华,王哲,陈志超,等.基于无人机遥感影像的冬小麦氮素监测[J/OL].*农业机械学报*,2018,49(6):207–214.
LIU Changhua, WANG Zhe, CHEN Zhichao, et al. Nitrogen monitoring of winter wheat based on unmanned aerial vehicle remote sensing image [J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(6): 207–214. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180624&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.06.024. (in Chinese)
- [30] 魏鹏飞,徐新刚,李中元,等.基于无人机多光谱影像的夏玉米叶片氮含量遥感估测[J].*农业工程学报*,2019,35(8):126–133,335.
WEI Pengfei, XU Xin'gang, LI Zhongyuan, et al. Remote sensing estimation of nitrogen content in summer maize leaves based on multispectral images of UAV [J]. *Transactions of the CSAE*, 2019, 35(8):126–133,335. (in Chinese)
- [31] 田军仓,杨振峰,冯克鹏,等.基于无人机多光谱影像的番茄冠层SPAD预测研究[J/OL].*农业机械学报*,2020,51(8):178–188.
TIAN Juncang, YANG Zhenfeng, FENG Kepeng, et al. Prediction of tomato canopy SPAD based on UAV multispectral image [J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(8): 178–188. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200820&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2020.08.020. (in Chinese)
- [32] GU Z, SHP X, LIN L, et al. Using multiple radiometric correction images to estimate leaf area index [J]. *International Journal of Remote Sensing*, 2011, 32(24):9441–9454.
- [33] 苏伟,王伟,刘哲,等.无人机影像反演玉米冠层LAI和叶绿素含量的参数确定[J].*农业工程学报*,2020,36(19):58–65.
SU Wei, WANG Wei, LIU Zhe, et al. Determining the retrieving parameters of corn canopy LAI and chlorophyll content computed using UAV image [J]. *Transactions of the CSAE*, 2020, 36(19): 58–65. (in Chinese)
- [34] 周靖婧,赵忠,刘金良,等.不同方法提取的快鸟影像信息估算刺槐林有效叶面积指数精度比较[J].*林业科学*,2015,51(9):24–34.
ZHOU Jingjing, ZHAO Zhong, LIU Jinliang, et al. A comparison of different Quickbird image information for estimating the effective leaf area index of *Robinia pseudoacacia* plantations [J]. *Scientia Silvae Sinicae*, 2015, 51(9):24–34. (in Chinese)