

文章编号:1006-6993(2023)02-0019-06

基于哨兵2遥感影像的根河林区 森林地上生物量估算

白嘎力¹, 萨如拉^{1*}, 滑永春¹, 明海君², 曹津语², 孟雪², 包蕊², 塔娜¹

(1. 内蒙古农业大学林学院, 呼和浩特 010018; 2. 内蒙古大兴安岭森林调查规划院, 牙克石 022150)

摘要:我国大兴安岭林区在全球碳汇中扮演着重要角色, 测算大兴安岭森林生态系统的碳汇功能具有重要意义。文章以大兴安岭根河林区为研究对象, 对根河林区森林地上生物量(AGB)进行了系统研究。本研究结合2018年哨兵2号数据的植被指数、纹理特征和2018年森林资源连续清查固定样地数据, 利用非参数模型(SVM和RF)来估算并比较高郁闭度的AGB。研究表明:①单波段中, 红边波段的相关性最高, 而植被指数与AGB存在负相关, NDVI的相关性最大, $R=0.752$ 。在所有的纹理特征中, 以B5波段提取的方差纹理特征的相关性最大, $R=0.557$ 。②采用R²和RMSE来评价模型精度, 发现随机森林的拟合精度相对较高。通过随机森林算法, 基于红边波段得到的AGB模型, 高于不加红边的AGB模型。加入纹理特征的模型高于没有纹理特征的AGB模型。说明加入红边波段和纹理特征会提高AGB模型估算精度。

关键词:大兴安岭; 森林地上生物量; 哨兵2号; 随机森林; 支持向量机

中图分类号:P407.8

文献标识码:B

DOI:10.13387/j.cnki.nmld.2023.02.006

Estimation of Forest Above-Ground Biomass in Genhe Forest Area Based on Sentinel 2 Remote Sensing Images

BAI Gali¹, Sarula^{1*}, HUA Yongchun¹, MING Haijun², CAO Jinyu²,
MENG Xue², BAO Rui², Tana¹

(1. Forestry College of Inner Mongolia Agricultural University, Hohhot 010018, Inner Mongolia, China; 2. Inner Mongolia Daxing'anling Forest Survey and Planning Institute, Yakeshi 022150, Inner Mongolia, China)

Abstract: Greater Khingan Mountains forest region in China plays an important role in global carbon sink. It is of great significance to measure the carbon sink function of forest ecosystem in Greater Khingan Mountains. Taking the Genhe forest region of Daxing'anling as the research object, this paper systematically studied the forest above-ground biomass (AGB) in the Genhe forest region. In this study, non-parametric models (SVM and RF) were used to estimate and compare AGB with high canopy density based on the vegetation index and texture features of Sentinel 2 data in 2018 and the fixed plot data of continuous forest inventory in 2018. The results show that: 1 In the single band, the red edge band has the highest correlation, while the vegetation index has a negative correlation with AGB, and NDVI has the highest correlation, $R = 0.752$. Among all the texture features, the variance texture feature extracted by the B5 band has the largest correlation, $R = 0.557$. R² and RMSE were used to evaluate the accuracy of the model, and it was found that the fitting accuracy of random forest was relatively high. Through the random forest algorithm, the AGB model based on the red edge band is higher than the AGB model without red edge. The model with texture features is higher than the AGB model without texture features. It

收稿日期:2023-03-04

基金项目:内蒙古自治区科技计划项目“大兴安岭白桦次生林生态修复关键技术研究”2020GG0067

作者简介:白嘎力(1997-),男(蒙古族),内蒙古自治区通辽市人,硕士研究生。

通讯作者:萨如拉(1976-),女(蒙古族),内蒙古自治区呼和浩特市人,博士,副教授。

shows that adding red edge band and texture features will improve the estimation accuracy of AGB model.

Key words: Greater Khingan Mountains; forest above-ground biomass; sentinel 2; random forest; support vector machines

森林在陆地生态系统的固碳、释放氧气等过程中发挥着重要作用^[1-2]。在全世界的陆地上,森林地上生物量(AGB)占全球固碳的很大一部分^[3-4]。AGB在全球碳排放量的监测和森林碳储量的估算中起到了非常重要的作用^[5-9]。我国北方森林在全球碳汇中扮演着重要角色,但是缺乏针对内蒙古大兴安岭 AGB的系统研究。因此,以根河林区为研究对象,对其进行精确的 AGB 调查和模型建立,对于测算内蒙古大兴安岭的碳汇功能具有不可或缺的作用。

光学遥感可以获得更宽泛、水平方向上连续的、区域范围内的数据。另外,高分辨光学遥感图像中蕴含着丰富的纹理、形状等空间几何信息,对于复杂地形下的森林地上生物量估算具有重要意义^[10-11]。光学遥感数据中,哨兵2号(Sentinel-2)在光学遥感数据的可用性和对森林动态变化的分析上有着明显的优势^[12]。现阶段,AGB预测模型由传统的统计回归模型向非参数化模型扩展,如:神经网络(Artificial Neural network, ANN)^[13]、支持向量机(Support vector machine, SVM)^[14]、K最邻近法(K-nearest neighbor, KNN)^[15]和随机森林(Random forest, RF)^[16]等,该方法不仅可以有效地揭示多源遥感数据与森林地上生物量间的复杂、非线性关系,而且可以有效地减少估算模型中的变量维数^[17-18]。

本研究以内蒙古大兴安岭根河林区为研究区,结合2018年哨兵2号数据的植被指数、纹理特征和2018年森林资源连续清查固定样地数据,利用非参数模型(SVM和RF)来估算并比较高郁闭度的AGB,从而为更大范围的估算森林AGB奠定基础。

1 材料与方 法

1.1 研究区概况

研究区位于内蒙古自治区大兴安岭根河林区,地处东经120°12'~122°55',北纬50°20'~52°30',海拔多集中于700~1300m。研究区森林面积约184万公顷。该地区属于寒温带,具有大陆性季风气候,年降水量为450~500mm,雨季集中在7~8月。根河地区地形由西南至东北逐渐升高,东北区域以坡度小于15°的山地为主。森林资源丰富,森林覆

盖率为91.75%,树种类型以兴安落叶松(*Larix gmelini*)与白桦(*Betula platyphylla*)为主^[19]。

1.2 数据来源与预处理

1.2.1 哨兵2号数据

在遥感探测中,将探测到的电磁信号转化为电子信号并进行存储,从而导致辐射测量结果的偏差。哨兵2号是高分辨率多光谱成像卫星,空间分辨率分别为10,20和60m。文章获取的Sentinel-2A影像成像时间为2018年10月,为L2A(主要包括经过大气校正的大气底层反射率数据)级影像。为了完成哨兵2号卫星的辐射校准和大气修正,必须使用SNAP软件,重新采集各波段的光谱,使其达到10m分辨率;然后,通过镶嵌、裁剪和掩模处理,最终获得研究区资料。

1.2.2 样地数据

样地资料取自2018年内蒙古大兴安岭林区的森林资源普查资料。采用了8km×8km的固定样地间隔,形状采用60m×10m的样地。共得到17块样地,数据以小班为单位划分,其中包含如平均胸径、平均树高、郁闭度、树种结构、地类、优势树种、面积、起源、龄组、蓄积等多个重要调查因子。

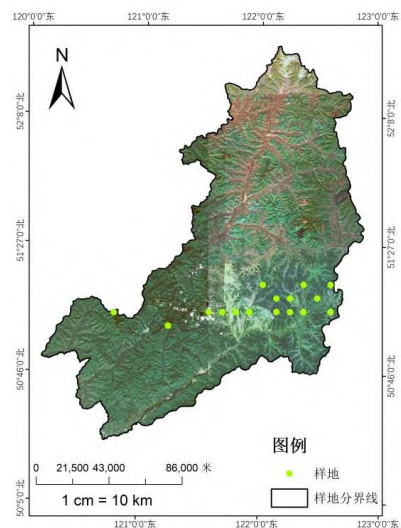


图1 研究区影像及样地分布图

针对AGB的估算方法,本研究采用朱彪、方精云等^[20]学者提出的异速生长方程。根据研究区森林资源一类清查数据,计算出区域AGB。具体计算方

法如表1所示。其中胸径单位为cm,树高单位为m,生物量单位为t/hm²,即吨每公顷。本研究先计算出

每个样地的平均胸径、平均树高,再通过异速生长方程得到样地平均AGB为94.35 t/hm²。

表1 研究区主要树种异速生长方程

树种	异速生长方程
白桦	$0.04939 \times (D^2 \times H)^{0.9011} + 0.01417 \times (D^2 \times H)^{0.7686} + 0.0109 \times (D^2 \times H)^{0.6472}$
落叶松	$0.025 \times (D^2 \times H)^{0.96} + 0.0021 \times (D^2 \times H)^{0.9638} + 0.00126 \times (D^2 \times H)^{0.9675}$

注:D、H分别代表胸径、树高。

1.3 研究方法

1.3.1 遥感特征提取

1.3.1.1 光谱变量提取

哨兵2号具有13个波段,除去检测大气特征的1、9和10波段,提取其余各波段反射率,再用公示计算得出归一化植被指数(NDVI)、比值植被指数(RVI)、差值植被指数(DVI)、增强型植被指数(EVI)、土壤调整植被指数(SAVI)等。

表2 植被指数公式

植被指数	公式
比值植被指数RVI	NIR/R
差值植被指数DVI	NIR-R
归一化植被指数NDVI	$(NIR-R)/(NIR+R)$
增强植被指数EVI	$2.5 \times (NIR-R)/(NIR+C_1NIR-C_2B+C_3)$
土壤调节指数SAVI	$(1+L) \times (NIR-R)/(NIR+R+L)$

注:B、R、NIR分别代表影像蓝、红、近红外波段反射率,EVI中的系数为C₁=6.0,C₂=7.5,C₃=1;SAVI中L值设为0.5。

1.3.1.2 纹理特征提取

纹理是一种以灰度为等效函数的空间变化,对分类、定量等研究具有很大的作用^[21]。在本研究中,采用灰度共生矩阵(GLCM)方法来提取纹理特征,其中包括均值、方差、协同性、对比度、相异性、信息熵、二阶矩和相关性等8种统计量,并使用9×9窗口大小计算。其他参数使用默认值。

表3 纹理特征计算公式

计算方法	纹理因子	计算公式
	均值(ME)	$\sum_{i,j=0}^{N-1} P_{ij}$
	方差(VA)	$\sum_{i,j=0}^{N-1} P_{ij} (i - ME)^2$
	均匀性(HO)	$\sum_{i,j=0}^{N-1} \frac{P_{ij}}{1 + (i-j)^2}$
灰度共生矩阵	对比度(CO)	$\sum_{i,j=0}^{N-1} i P_{ij} (i-j)^2$
	异质性(DI)	$\sum_{i,j=0}^{N-1} i P_{ij} i-j $
	熵(EN)	$\sum_{i,j=0}^{N-1} i P_{ij} (-\ln P_{ij})$
	二阶矩(SM)	$\sum_{i,j=0}^{N-1} i P_{ij}^2$
	相关性(CR)	$\sum_{i,j=0}^{N-1} i P_{ij} \left[\frac{(i - ME)(j - ME)}{\sqrt{VA_i VA_j}} \right]$

注:P_{ij}为归一化共生矩阵,公式中ME为灰度共生矩阵的均值。

1.3.2 构建模型

随机森林(RF)是一种以决策树为基础的整合学习方法。RF在建立决策树时采用了两个随机性的方法。一是随机抽样,即每次从原始数据中随机选取一定数量的样本进行建树;二是随机选取特征,即每次在选取划分特征时,从全部特征中随机选取一定数量的特征。这两个随机性的引入可以有效减少过拟合情况的出现。在文中,使用Python语言实现了RF回归算法,其中n_estimator和max_depth是需要调整的参数。n_estimator是弱学习器的最大迭代次数,一般选择一个适中的数值来避免欠拟合和过拟合的情况,通常默认值为100。max_depth是决策树的最大深度,一般也需要根据具体情况进行调整,以避免过拟合。本研究中对n_estimator和max_depth参数采用默认。

支持向量机(SVR)将低维数据的非线性可分性和泛化能力通过线性核函数将其映射到高维数据,从而保证其良好的泛化能力^[22]。本研究基于Python语言实现随机森林回归算法和支持向量回归算法。研究中,加入了与AGB相关的特征来构建不同组合的AGB估测模型,具体如表4所示,探究不同特征组合对AGB估算的影响,并得到最优的AGB预测模型方法。

表4 不同特征组合构建模型

组别	特征组合
A	光谱变量(无红边)+模型
B	光谱变量(有红边)+模型
C	光谱变量(有红边)+纹理特征+模型

注:A:光谱变量(无红边)+模型(RF和SVR);B:光谱变量(有红边)+模型(RF和SVR的优选);C:光谱变量(含红边)+纹理特征+模型(RF和SVR的优选)。

1.3.3 地上生物量构建模型精度评价

采用决策因子(R²)和均方根偏差(RMSE)等参数对建模结果进行评估。R²对回归直线拟合程度的检验,反映了因变量与自变量之间的相关性,其取值范围为0~1,数值越接近1,说明相关性越高,自变量对因变量的解释能力更强;模型也更符合实

际。RMSE代表的是估计值与实测值之间误差的平方和与样本个数n的比值的平方根, RMSE的数值越小, 表示模型预测效果越好, 估计值与实测值越接近^[23], 本研究的训练集与测试集样本比例为7:3。可按公式①②计算:

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

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

式中:n表示样本数量; y_i表示第i个样本地上生物量的实测值; \bar{y} 表示实测结果算数平均值; \hat{y}_i 表示第i个样本地上生物量的估测值。

2 结果与分析

2.1 不同变量特征与AGB的相关性

经相关分析, 得出了各因素与AGB之间的显著相关系数, 如表5所示。选取与地上生物量有显著相关性且P=0.01和0.05的遥感因子, 作为模型中的自变量。

从表5中可以看出, 一共19个变量的特性都与AGB的测量值达到了0.05的显著性, 可以发现在植被指数中, NDVI的相关性最大, R=0.752, 对其相关性排序为NDVI>RVI>SAVI>DVI>EVI。在光谱变量中红边波段(B5)的相关性最大, R=0.605。纹理特征中由波段B5计算的方差纹理特征的相关性最高, R=0.557。按照大小, 前五个特征排序为B5_VA>B5_ME>B3_ME>B4_ME>B5_CO。

表5 自变量与地上生物量间显著相关系数

特 征	SAVI	NDVI	RVI	DVI	EVI
相关性	-0.671**	-0.752**	-0.751**	-0.568*	-0.554*
特 征	B2_CR	B3_ME	B4_ME	B4_VA	B5_CO
相关性	-0.499*	0.550*	0.543*	0.515*	0.538*
特 征	B5_ME	B5_VA	B6_CO	B6_VA	B7_HO
相关性	0.552*	0.557*	0.498*	0.514*	-0.484*
特 征	B2	B3	B4	B5	-
相关性	0.576*	0.579*	0.589*	0.605*	-

注:**为0.01水平显著相关;*为0.05水平显著相关。

2.2 不同算法和特征变量的AGB模型对比分析

2.2.1 不同算法对AGB模型的影响

采用随机森林和支持向量机两种机器学习方法构建了AGB模型。如表6所示, 在此基础上, 比较两种机器学习算法, 建立并检验AGB估计模型的精度。

表6 两种算法的模型精度比较

组合	随 机 森 林		支持向量机	
	R ²	RMSE	R ²	RMSE
A	0.23	67.33	0.18	69.34

注:A光谱变量(无红边)。

从表6中可以看到, 通过使用光谱变量(无红边)来建立AGB估计模型, 随机森林和支持向量机回归预测模型的R²分别是0.23, 0.18, RMSE分别为67.33 t/hm², 69.34 t/hm²。通过对比不同特征变量的AGB模型, 可以发现, 随机森林模型的RMSE较小, 而支持向量机的RMSE范围较大。结果表明, 与SVR相比, 随机森林模型更适用于本研究区。

2.2.2 红边波段对AGB模型的影响

已知在建立AGB估计模型时, 随机森林是最准确的, 所以, 在对光谱变量进行组合的基础上, 添加了哨兵2号的红边波段, 利用随机森林算法, 建立了AGB估计模型。分析红边波段对AGB估算模型的影响。详见表7。

表7 有无红边波段的模型精度比较

组合	随 机 森 林	
	R ²	RMSE
A	0.23	67.33
B	0.37	32.01

注:A光谱变量(无红边); B光谱变量(红边)。

通过表7测试集样本对2种AGB估算模型进行精度评价, 得到两种模型的R²分别为0.23, 0.37, RMSE为67.33 t/hm², 32.01 t/hm²。从二者的模型精度结果中可以发现, 在光谱变量组合的基础之上, 加入红边波段, 使其模型RMSE减小, 模型精度有所提高。




图2 有无红边波段地上生物量估测模型精度

从图2中可以看出,在测试集样本中,实测AGB集中于 100 t/hm^2 左右,由样地调查数据通过异速生长方程得到森林样地平均AGB为 94.354 t/hm^2 ,两者相近。加入红边的模型对AGB位于 $75 \sim 120 \text{ t/hm}^2$ 之间的样本预测呈现线性相关,精度较高,而对于 $\text{AGB} < 75 \text{ t/hm}^2$ 或 $> 120 \text{ t/hm}^2$ 的样本,其离散程度较大,精度较低。

2.2.3 纹理特征对AGB模型的影响

已知在构建AGB估算模型时,有红边波段的模型精度较高,因此,在有红边波段组合的基础之上,加入纹理特征,通过随机森林算法构建AGB估测模型,分析纹理特征对AGB估算模型的影响。详见表8。

表8 有无纹理特征的模型精度比较

组合	随 机 森 林	
	R^2	RMSE
B	0.37	32.01
C	0.40	29.61

注:B光谱变量(红边);C光谱变量(含红边)+纹理特征。

由表8可知,通过测试集样本对两种AGB估算模型进行精度评价,得到两种模型的 R^2 分别为0.37,0.40, RMSE为 32.01 t/hm^2 、 29.61 t/hm^2 。根据两者的模型精度结果可以看出,在光谱变量组合的基础之上,加入纹理特征,使其模型RMSE减小,模型精度有所提高。这说明加入纹理特征对模型估测AGB有明显的提高。




图3 有无纹理特征地上生物量估测模型精度

从图3中可以看出,AGB估测模型发现预测AGB在高于 120 t/hm^2 和低于 50 t/hm^2 范围出现异常,

对于AGB较低的样本,其预测值偏高,对于AGB较高的样本,其预测值较低。加入纹理特征的模型对AGB位于 $50 \sim 120 \text{ t/hm}^2$ 之间的样本预测呈现线性相关,精度较高,而对于 $\text{AGB} < 50 \text{ t/hm}^2$ 或 $> 120 \text{ t/hm}^2$ 的样本,其离散程度较大,精度较低。

3 讨论与结论

3.1 讨论

3.1.1 特征变量与AGB的相关性分析

在建立AGB模型的时候,可以将各种遥感参数用作模拟因素,这些参数包含了光谱波段反射率、纹理特征和植被指数等^[24]。在本研究中,纹理特征与地上生物量具有显著相关性,因为纹理特征可以帮助减少异物同谱或同物异谱的影响。因此,在建立AGB模型时,需要综合考虑多种遥感变量,并进行相关性分析,以提高模型的预测精度。

3.1.2 基于不同算法和特征变量估测AGB

3.1.2.1 AGB建模算法的选择

AGB建模算法的选择对于精度提高具有重要意义。在本研究中,随机森林和支持向量机两种算法用于构建AGB模型。结果显示,两种算法的AGB模型RMSE分别为 67.33 t/hm^2 和 69.34 t/hm^2 ,随机森林估测结果优于支持向量机。但是,该研究无法说明机器学习算法与传统回归估测结果的优劣。在另一项研究中,利用相同的数据源来建立AGB模型,随机森林的RMSE为 30.3 Mg/hm^2 , R^2 为0.15,而支持向量机的RMSE为 27.7 Mg/hm^2 , R^2 为0.35^[25]。这表明选择最适合特定区域的AGB估测模型算法对模型精度的提高具有重要意义。对于根河AGB估测,随机森林估测结果优于支持向量机。

3.1.2.2 基于红边波段AGB的估测模型

Sibanda等人通过比较哨兵2号MSI和Landsat8OLI对AGB的估算模型发现,哨兵2号的性能更好^[24]。Muukkonen和Heiskanen等人的研究表明,当AGB增大时,阴影与光谱带的反射率成反比。随着高分辨率卫星传感器的研制成功,红边波段加入传感器,为在森林结构复杂地区开展地上生物量研究提供了一种可靠的遥感数据源^[26]。本研究的结果表明,在模型中加入红边波段可以提高AGB估算模型的精度,这与前人得到的结论相符合。但是,在像根河这样地区,由于树种类型和冠层的影响,树种的光谱信息获取较少或出现光谱重叠的现象,可能限制了模型精度的提高。

3.1.2.3 基于纹理特征 AGB 的估测模型

与光谱信息相比,遥感数据的纹理特征可以扩大基于原始影像空间信息的识别度,并且基于纹理信息的地表参数反演精度有很大的提升空间^[27]。一些研究表明,利用K—NN模型,在生物物理梯度显著变化的区域,辅以地表观测资料,能够有效地提升K—NN模型对植被参数的预报精度^[28]。另外,应用纹理特征结合光谱信息和植被指数可以有效提高森林地上生物量估测的精度^[29]。在本研究中,为了解纹理特征对AGB模型的影响,在有红边波段的光谱变量的基础上加入纹理特征,构建了AGB估算模型,并得到预测结果。研究表明,加入纹理特征后,AGB估测模型精度有所提高,这说明,在根河林区,由于其结构比较复杂,光谱信息很难对其上部结构中的生物量进行有效的监测,从而导致了植物的地上生物量的饱和。

3.2 结论

本研究选取根河林区为研究区,研究了基于高分多光谱Sentinel-2影像的随机森林和支持向量机的遥感估测方法以及构建了AGB估测模型。研究发现,红边波段、纹理特征对AGB的估算精度有显著影响。在变量之间存在明显的共线性问题,植被指数的相关性最高,纹理特征的相关性次之。支持向量机与随机森林相比,随机森林算法的拟合精度相对较高,加入红边波段、纹理特征会提高AGB模型估算精度。

参考文献:

- [1] 梁燕,葛忠强,马安宝,等.森林生态系统稳定性研究进展[J].山西林业科技,2018,47(4):32-34.
- [2] Dixon RK, Brown S, Houghton RA, et al. Carbon pools and flux of global forest ecosystems[J]. Science, 1994,263(5 144):185-190.
- [3] Lieth H, Whittaker RPL. Primary Productivity of the Biosphere[M]. New York:Springer-Verlag, 1975.
- [4] 杨洪晓,吴波,张金屯,等.森林生态系统的固碳功能和碳储量研究进展[J].北京师范大学学报(自然科学版),2005(2):172-177.
- [5] 张茂震,王广兴.浙江省森林地上生物量动态[J].生态学报,2008,28(11):469-478.
- [6] Li DR, Wang CW, Hu Y M, et al. General review on remote sensing-based biomass estimation[J]. Geomatics and Information Science of Wuhan University, 2012, 37(6):631-635.
- [7] Yu G, Chen Z, Piao S, et al. High carbon dioxide uptake by subtropical forest ecosystems in the East Asian monsoon region[J]. Proceedings of the National Academy of Sciences of the United States of America, 2014, 111(13):4 910-4 915.
- [8] Chen J, John R, Ge S, et al. Carbon fluxes and storage in forests and landscapes[J]. Springer New York, Forest Landscapes and Global Change, 2014,139-166.
- [9] Baccini A, Walker W, Carvalho L, et al. Tropical forests are a net car-

bon source based on aboveground measurements of gain and loss[J]. Science, 2017, 358(6360):230-234.

- [10] 营永峰,韩泽民,黄光体,等.基于高分辨率遥感影像的北亚热带森林地上生物量反演[J].生态学报,2021,41(6):2161-2169.
- [11] 李德仁,王长委,胡月明,等.遥感技术估算森林地上生物量的研究进展[J].武汉大学学报(信息科学版),2012,37(6):631-635.
- [12] 王熙媛,张王菲,李云,等.依据光学遥感特征优选的森林地上地上生物量反演[J].东北林业大学学报,2022,50(4):47-54.
- [13] SHERIDAN R, POPESCU S C, GATZIOLIS D, et al. Modeling forest aboveground biomass and volume using airborne LiDAR metrics and forest inventory and analysis data in the Pacific northwest[J]. Remote Sensing, 2015,7(1):229-255.
- [14] CORTES C, VAPNIK V. Support-vector networks[J]. Mach Learning, 1995,20:273-297.
- [15] 韩宗涛,江洪,王威,等.基于多源遥感的森林地上地上生物量KNN-FIFS估测[J].林业科学,2018,54(9):70-79.
- [16] 刘茜,杨乐,柳钦火,等.森林地上地上生物量遥感反演方法综述[J].遥感学报,2015,19(1):62-74.
- [17] YUAN H H, YANG G J, WANG Y J, 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.
- [18] BERIE H T, KUTIE Z A, GOBAKKEN T, et al. Use of remotely sensed data to enhance estimation of aboveground biomass for the dry afro-montane forest in south-central Ethiopia[J]. Remote Sensing, 2020,12(20):23.
- [19] 饶月明,刘凯军,黄华国,等.基于INFORM模型与GEE的根河火烧迹地冠层含水量反演研究[J].中南林业科技大学学报,2021,41(1):80-91.
- [20] Zhu B, Wang X, Fang J, et al. Altitudinal changes in carbon storage of temperate forests on Mt Changbai, Northeast China[J]. Journal of Plant Research, 2010, 123(4):439-452.
- [21] 朱妍.基于Landsat 8 OLI和ALOS-2 PALSAR-2数据的北京市森林地上生物量估测研究[D].北京:北京林业大学,2020.
- [22] 尚珂.基于支持向量机回归的草地上生物量遥感估测研究[D].昆明:西南林业大学,2015.
- [23] Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection[C]//International joint conference on Artificial intelligence. Morgan Kaufmann Publishers Inc, 1995.
- [24] 陈瑶,青晓,张德然,等.四川龙门山西北部植被分布与地形因子的相关性[J].生态学杂志,2006,25(9):1 052-1 055.
- [25] 高煌堃.基于机器学习及多源数据的亚热带典型区域森林地上地上生物量估测研究[D].杭州:浙江农林大学,2018.
- [26] Muukkonen P, Heiskanen J. Biomass estimation over a large area based on standwise forest inventory data and ASTER and MODIS satellite data: A possibility to verify carbon inventories[J]. Remote Sensing of Environment, 2007,107(4):617-624.
- [27] Kuplich T M, Curran P J, Atkinson P M. Relating SAR image texture to the biomass of regenerating tropical forest[J]. International Journal of Remote Sensing, 2005,26(21):4 829-4 854.
- [28] Ohmann J L, GREGORY M J. Predictive mapping of forest composition and structure with direct gradient analysis and nearest-neighbor imputation in coastal Oregon, USA[J]. Canadian Journal of Forest Research, 2002, 32(4): 725-741.
- [29] 韩宗涛.基于特征优选的森林地上地上生物量遥感估测[D].福州:福州大学,2017.