

基于 Landsat 8 影像的乔木林地上生物量估算

任 怡¹, 王海宾², 许等平²

(1. 国家林业和草原局调查规划设计院, 北京 100714; 2. 国家林业和草原局林产工业规划设计院, 北京 100010)

摘要:以浙江省内的一景 Landsat 8 影像和 96 块野外调查数据为数据源, 提取出植被指数、纹理特征、地形因子并进行优选, 对优选后的变量因子进行分组, 生成植被指数、植被指数 + 纹理特征相结合的 2 种自变量集, 采用偏最小二乘回归法构建乔木林地上生物量估算模型, 并对估算结果进行对比分析。结果显示: 在构建的模型中, 植被指数 + 纹理特征集构建的模型精度均要优于植被指数集构建的模型, 说明多光谱波段的纹理特征具有改善模型估算效果的作用。采用的变量筛选方法较好地考虑了变量间的相关性及共线性问题, 可以提高所构建模型的稳定性。

关键词: 乔木林; 生物量模型; 植被指数; 纹理特征; Landsat 8 影像

中图分类号: S718.55; S771.8 **文献标识码:** A **文章编号:** 1002-6622(2018)06-0038-07

DOI: 10.13466/j.cnki.lyzygl.2018.06.007

Estimation of Aboveground Biomass of Arbor Forest Based on Landsat 8 Image

REN Yi¹, WANG Haibin², XU Dengping²

(1. Academy of Forest and Grassland Inventory and Planning, NFGA, Beijing 100714, China; 2. Planning and Design Institute of Forest Products Industry, NFGA, Beijing 100010, China)

Abstract: With the Landsat 8 image and 96 field survey data in Zhejiang Province as the data source, the vegetation indices, texture features, terrain factors were extracted and optimized, and the preferred variables were selected. The factors were grouped into two sets of independent variables: vegetation indices, vegetation indices + texture features. The least squares regression method was used to construct the aboveground biomass estimation model of arbor forest, and the estimation results were compared and analyzed. The results show that in the constructed models, the model accuracy of vegetation indices + texture features set is better than the model constructed by the vegetation indices set. The result indicates that the texture features of the multispectral bands have the effect of improving the model estimation accuracy. In addition, the variable screening method adopted in this paper takes into account the correlation between variables and the collinearity problem, which can improve the stability of the constructed model.

Key words: arbor forest, biomass model, vegetation index, texture feature, Landsat 8 image

收稿日期: 2018-10-10; 修回日期: 2018-12-17

基金项目: 国家林业局 948 项目(2015-4-32); 国家重点林业工程监测技术示范推广项目([2015]02 号)

作者简介: 任怡(1981-), 女, 陕西西安人, 工程师, 硕士, 主要从事森林资源监测及“3S”技术林业应用工作。

Email: 5846758@qq.com

森林生物量作为陆地生态系统的重要组成部分,日益成为人们关注的热点之一。准确地估算森林生物量对开展林业生产活动、生态环境保护建设、探究全球生态系统碳循环具有重要作用和意义^[1-3]。估算森林生物量的方法大致可归为以下两种^[4-5]:一是传统估算方法,大多是采用抽样方法获取野外调查数据估算森林生物量,这种方法往往需要较多的人力物力来完成,并且获取的数据不具有空间连续性特征,无法反映环境因子对估算结果的影响;二是遥感技术估算方法,遥感影像波段具有空间连续性特征,且具有宏观、快速以及可重复等特点,为研究森林生物量及其空间分布提供了必要条件,使得估算结果不仅接近实际,而且可提供直观的森林生物量空间分布信息。诸多学者应用光学遥感技术对不同尺度的森林生物量进行了研究,分别从遥感数据源(如光学遥感数据、微波雷达、激光雷达等)、变量因子选择(如光谱信息、纹理特征、地形因子、气象因子等)、建模方法选择(如参数和非参数方法)等方面进行了大量的研究,取得了较好的估算效果^[6-9]。

Landsat 8 卫星提供了空间分辨率为 30m 的多光谱和 15m 的全色波段数据,为区域和大尺度范围的森林生物量估算提供了新的遥感数据源,而针对 Landsat 8 影像估算乔木林地上生物量的研究则较少。本研究选取浙江省内一景 Landsat 8 影像覆盖的范围为研究区,基于获取的乔木林地上生物量以及 Landsat 8 多光谱影像信息,构建乔木林地上生物量估测模型,以期应用 Landsat 8 多光谱影像估算区域及大尺度的森林参数提供参考。

1 研究区概况

浙江省地处中国东南沿海,地理范围为 27°06' ~ 31°11'N, 180°01' ~ 123°10'E。浙江省东西和南北的直线距离接近,均在 450km 左右,土地面积为 10.55 万 km²,占全国的 1.1%。浙江省海域面积广阔,总面积达 26 万 km²,大海岸线长度居全国首位。同时,其沿海有 2 100 多个岛屿,是我国岛屿最多的省。浙江省下辖 11 个地级市,89 个县级行政区。本研究的研究区范围如图 1 所示,为一景 Landsat 8 覆盖的范围,面积大小为 185km × 185km。




图 1 研究区边界及调查样地分布

Fig. 1 The border of the study area and distribution of survey samples

2 研究方法

2.1 数据获取

地面数据通过外业调查获取,在数据采集的过程中,依据研究区内的林分年龄(分为幼龄林、中龄

林、近成过熟林)和优势树种的实际情况设置调查样地,使调查样地具有代表性。共设置和调查了96个样点,数据采集时间为2017年,样地形状为正方形,面积大小为 0.067hm^2 。样地的森林类型主要包括针叶林、阔叶林、混交林,属性因子包括树种、胸径(起测胸径为 5cm)、平均高、郁闭度、株数、年龄、蓄积量、坡向、坡度、海拔等因子。样地调查数据的分布如图1所示。

乔木林地上生物量采用样地蓄积量乘以生物量换算因子(Biomass Expansion Factor, BEF)计算获取,生物量换算因子采用沈楚楚^[10]提供的浙江省四大树种(组)的BEF,分别为杉木林(0.745 t/m^3)、马尾松林(0.883 t/m^3)、软阔类(1.657 t/m^3)、硬阔类(1.070 t/m^3)。将其他树种分别归并到软阔类和硬阔类树种(组),并采用相应的BEF计算生物量,最后将乔木林地上生物量转换为每公顷生物量(t/hm^2)。

2.2 Landsat 8 影像及预处理

Landsat 8 卫星于2013年2月11日成功发射,它搭载了陆地成像仪传感器(OLI传感器,全称为:Operational Land Image)和热红外传感器(TIRS传感器全称为:Thermal Infrared Sensor)2个传感器。OLI传感器可获取多光谱波段和全色波段共计9个波段,其中多光谱波段为1—7和9波段,空间分辨率为 30m ,全色波段为第8波段,空间分辨率为 15m 。TIRS传感器包括2个波段,分别为波段10—TIRS热红外传感器1和波段11—TIRS热红外传感器2,空间分辨率为 30m 。Landsat 8 卫星重访周期为16d,成像宽幅为 $185\text{km} \times 185\text{km}$ ^[11]。

本研究选用一景Landsat 8影像的多光谱影像为遥感数据源,覆盖整个研究区,影像轨道号为119/040,采集时间为2017年10月26日。Landsat 8 OLI的技术参数如表1所示。应用ENVI5.3软件对Landsat 8影像进行预处理,具体过程包括辐射定标和大气校正2个过程。

2.3 建模变量设置及优选

在建模变量的设置上,应用较多的包括植被指数^[4-7,12]、纹理特征^[13-15]等因子。通过计算获取了9种植被指数、8种纹理特征以及DEM数据提取的

表1 Landsat 8 OLI 技术参数表

Tab. 1 Technical parameters for Landsat 8 OLI

波段序号	波长范围/ μm	波段名称	分辨率/ m
1	0.433 ~ 0.453	气溶胶	30
2	0.450 ~ 0.515	蓝	30
3	0.525 ~ 0.600	绿	30
4	0.630 ~ 0.680	红	30
5	0.845 ~ 0.885	近红外	30
6	1.560 ~ 1.660	短波红外	30
7	2.100 ~ 2.300	短波红外	30
8	0.500 ~ 0.680	全色	15
9	1.136 ~ 1.390	卷云	30

3种地形因子作为自变量,参与生物量模型构建,其中纹理特征设置步长和纹理方向为1和 135° ,提取了 3×3 窗口下的8种影像纹理特征。建模变量设置结果如表2所示。

采用皮尔森相关系数法结合方差膨胀因子法提取自变量因子。首先,采用皮尔森相关系数法提取出与乔木林地上生物量极显著相关($P < 0.01$)的自变量因子,然后采用方差膨胀因子法对自变量因子做进一步筛选,提取出自变量因子用于模型构建。

方差膨胀因子(Variance Inflation Factor, VIF)是指解释变量之间存在多重共线性时的方差与不存在多重共线性时的方差之比,为容忍度的倒数,VIF越大,显示共线性越严重^[16]。经验判断方法表明:当 $0 < VIF < 10$,不存在多重共线性;当 $10 \leq VIF < 100$,存在较强的多重共线性;当 $VIF \geq 100$,存在严重多重共线性。依据相关的文献资料^[17-18],本研究设置 $0 < VIF < 10$,容忍度 >0.1 来进行控制,对自变量进行优选。

基于自变量优选结果,分别生成植被指数、植被指数+纹理特征的2种自变量集,参与模型构建,对比分析纹理特征能够改善模型的估算效果。

2.4 偏最小二乘回归法

采用偏最小二乘回归法建立乔木林地上生物

量估算模型。偏最小二乘回归法(Partial Least-Squares Regression, PLSR)集多元回归分析、典型相关分析和主成分分析的优点于一体,可以有效地解

决多元回归分析中的变量多重相关性及噪声问题^[19-20],近年来被逐渐的应用到森林参数的估计上^[21-23],取得了较好的估算效果。

表2 建模变量因子
Tab. 2 Modeling variable factors

变量类型	变量名称	计算公式
植被指数	归一化植被指数 NDVI	$NDVI = \frac{NIR - RED}{NIR + RED}$
	比值植被指数 RVI	$RVI = NIR/RED$
	差值植被指数 DVI	$DVI = NIR - RED$
	比值植被指数 1 RVI54	$RVI54 = SWIR1/NIR$
	比值植被指数 2 RVI64	$RVI64 = SWIR2/NIR$
	土壤植被指数 SAVI	$SAVI = \frac{(1 + L)(NIR - RED)}{(NIR + RED + L)}$
	优化土壤调整指数 NLI	$NLI = \frac{NIR^2 - RED}{NIR^2 + RED}$
	大气抗阻植被指数 ARVI	$ARVI = \frac{(NIR - RED + r(BLUE - RED))}{(NIR + RED - r(BLUE - RED))}$
	增强植被指数 EVI	$EVI = G \times \frac{NIR - RED}{NIR + C1 \times RED - C2 \times BLUE + L}$
纹理特征	平均值	$Mean = \sum_{i,j=0}^{N-1} i(P_{i,j})$
	方差	$Variance = \sum_{i,j=0}^{N-1} iP_{i,j}(i - Mean)^2$
	均一性	$Homogeneity = \sum_{i,j=0}^{N-1} i \frac{P_{i,j}}{1 + (i - j)^2}$
	对比度	$Contrast = \sum_{i,j=0}^{N-1} iP_{i,j}(i - j)^2$
	相异性	$Dissimilarity = \sum_{i,j=0}^{N-1} iP_{i,j} i - j $
	熵	$Entropy = \sum_{i,j=0}^{N-1} iP_{i,j}(-\ln P_{i,j})$
	角二阶矩	$SecondMoment = \sum_{i,j=0}^{N-1} iP_{i,j}^2$
	相关性	$Correlation = \sum_{i,j=0}^{N-1} iP_{i,j} \left[\frac{(i - Mean)(j - Mean)}{\sqrt{Variance_i} \sqrt{Variance_j}} \right]$
地形因子	海拔	
	坡度	
	坡向	

注:BLUE,RED,NIR,SWIR1,SWIR2 分别为蓝、红、近红、短波红外 1、短波红外 2 波段;SAVI 指数中,L 值为 0.5;EVI 指数中,增益系数 G、土壤调整因子 L 的 2 个修正系数 c1 和 c2 的值分别为 2.5、0.10、6.0 和 7.5;ARVI 指数中,r 设置为 1.0; $P_{i,j} = V_{i,j} / \sum_{i,j=0}^{N-1} V_{ij}$,其中 V_{ij} 表示第 i 行第 j 列位置上的像元值,N 表示移动窗口的大小和尺寸。

2.5 模型评价

采用留一交叉验证法来对模型进行验证。采用的评价指标有:决定系数(R^2)、均方根误差(Root Mean Square Error, RMSE)、平均绝对偏差(Mean Absolute Error, MAE)和总预报偏差的相对误差(RE)。 R^2 越大,模型的拟合精度越好, RMSE, MAE 和 RE 值越小,表示模型预测精度越高。

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

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

$$MAE = \frac{\left| \sum_{i=1}^n (\hat{y}_i - y_i) \right|}{n} \quad (3)$$

$$RE = \left| \sum_{i=1}^n (\hat{y}_i - y_i) \right| / \sum_{i=1}^n y_i \times 100\% \quad (4)$$

式中: y_i 为碳储量实测值; $\hat{y}_i$ 为碳储量预测值; $\bar{y}_i$ 为碳储量实测值平均值; n 为样本个数。

3 结果与分析

3.1 自变量筛选

采用 SPSS 20.0 软件,对乔木林地上生物量和

提取的 60 个自变量因子进行皮尔森相关性分析,提取出与生物量极显著相关($P < 0.01$)的因子,共计有 22 个,提取结果如表 3 所示。

对提取出的 22 个自变量因子进一步优选,生成基于 VIF 法筛选的自变量因子(表 4)。经筛选后, RVI , NLI , 海拔, $B1_Mean$, $B3_Correlation$, $B6_Mean$, $B6_Variance$ 共计 7 个自变量因子被提取出来。基于筛选的 7 个变量因子,分别构建基于植被指数、植被指数 + 纹理特征的自变量集。本文将海拔因子划归植被指数集(表 5)。

3.2 生物量估测模型构建

3.2.1 基于 2 种自变量集构建的 PLSR 模型

基于建立的植被指数集、植被指数 + 纹理特征集,采用 PLSR 法构建乔木林地上生物量估算模型。应用 MATLAB2014a 计算各个模型的参数,得到基于植被指数集、植被指数 + 纹理特征集的 PLSR 模型(表 6),模型精度评价结果如表 7 所示。基于植被指数构建的模型中, R^2 为 0.406 9, RMSE 为 20.53 t/hm², AE 和 RE 分别为 0.17 t/hm², 0.43%; 基于植被指数 + 纹理特征集构建的模型中, R^2 为 0.421 2, RMSE 为 20.30 t/hm², AE 和 RE 分别为 0.10 t/hm², 0.27%。

表 3 自变量因子与乔木林地上生物量的皮尔森相关系数

Tab. 3 Pearson correlation coefficients between independent variables and arbor forest above ground biomass

变量	相关系数	变量	相关系数	变量	相关系数
$NDVI$	0.644 **	$Greenness$	0.306 **	$B6_Mean$	-0.320 **
RVI	0.678 **	海拔	0.321 **	$B6_Variance$	-0.345 **
$RVI54$	-0.400 **	$B1_Mean$	-0.336 **	$B6_Contrast$	-0.295 **
$RVI64$	-0.398 **	$B2_Mean$	-0.342 **	$B6_Diss$	-0.277 **
$SAVI$	0.644 **	$B3_Mean$	-0.407 **	$B6_Entropy$	-0.318 **
NLI	0.387 **	$B3_Entropy$	-0.321 **	$B6_Second$	0.285 **
$ARVI$	0.646 **	$B3_Second$	0.316 **		
$PCA2$	-0.500 **	$B3_Correlation$	0.282 **		

注: “**”表示在 0.01 水平(双侧)上显著相关; $B1$, $B2$, $B3$, $B6$ 分别代表 Landsat 8 影像的第 2, 3, 4, 7 波段; $Mean$ 代表平均值纹理, $Entropy$ 代表熵纹理, $Second$ 代表角二阶矩纹理, $correlation$ 代表相关性纹理, $Variance$ 代表方差纹理, $Contrast$ 代表对比度纹理, $Diss$ 代表相异性纹理。

表 4 基于 VIF 法筛选的自变量因子

Tab. 4 Independent factors filter based on the VIF method

变量	相关系数	变量	相关系数	变量	相关系数
RVI	0.678 **	$B1_Mean$	-0.336 **	$B6_Variance$	-0.345 **
NLI	0.387 **	$B3_Correlation$	0.282 **		
海拔	0.321 **	$B6_Mean$	-0.320 **		

注: “**”表示在 0.01 水平(双侧)上显著相关; $B1$, $B3$, $B6$ 分别代表 Landsat 8 影像的第 2, 4, 7 波段; $Mean$ 代表平均值纹理, $Correlation$ 代表相关性纹理, $Variance$ 代表方差纹理。

表 5 基于 VIF 法筛选的自变量构建的 2 种自变量集

Tab. 5 Two independent variable sets constructed based on independent variables selected by VIF method

自变量集	碳储量模型
植被指数	$RVI, NLI, \text{海拔}$
植被指数 + 纹理特征	$RVI, NLI, \text{海拔}, B1_Mean, B3_Correlation, B6_Mean, B6_Variance$

表 6 基于不同自变量集和 PLSR 法构建的生物量估算模型

Tab. 6 Biomass estimation models based on different independent variable sets and PLSR method

自变量集	碳储量模型
植被指数	$5.8452 \times RVI + 1.6765 \times 10^4 \times NLI - 0.0122 \times \text{海拔} - 1.6763 \times 10^4$
植被指数 + 纹理特征	$2.9581 \times RVI + 4.2002 \times 10^4 \times NLI + 0.0030 \times \text{海拔} - 4.5295 \times B1_Mean + 10.0608 \times B3_Correlation - 7.7782 \times B6_Mean - 9.8515 \times B6_Variance - 4.1966 \times 10^4$

表 7 不同自变量集的 PLSR 模型预测精度比较

Tab. 7 Comparison of prediction accuracy of PLSR models with different sets of independent variables

自变量集	R^2	$RMSE/(t/hm^2)$	$MAE/(t/hm^2)$	$RE/\%$
植被指数	0.4069	20.53	0.17	0.43
植被指数 + 纹理特征	0.4212	20.30	0.10	0.27

3.2.2 模型比较分析

由表 6 和图 2 可知,基于植被指数 + 纹理特征构建的模型 R^2 (0.421 2) 大于基于植被指数构建的模型 (R^2 为 0.406 9),相应的 $RMSE, MAE, RE$ (分别为 $20.30t/hm^2, 0.10t/hm^2, 0.27\%$) 均要小于植被指

数集构建的模型 ($RMSE = 20.53 t/hm^2, MAE = 0.17 t/hm^2, RE = 0.43\%$)。基于植被指数构建的模型精度最低,而结合植被指数和纹理特征所构建的模型精度有所提高,说明多光谱波段纹理特征对提高生物量模型的预测精度具有贡献作用。由此可知,在构建 PLSR 生物量模型时,Landsat 8 影像多光谱波段的纹理特征可以改善乔木林地上生物量模型的预测精度。

4 结论与讨论

1) 在采用 2 种自变量集构建的模型中,基于植被指数 + 纹理特征构建的乔木林生物量估算模型最好,基于植被指数构建的模型精度最低。在加入 Landsat 8 多光谱影像的纹理特征后,生物量估算模型精度提高,这说明多光谱影像的纹理特征具有改善估测模型的作用,由此可知在估算其他森林参数方面,可考虑多光谱波段的纹理特征用于模型构建。




图 2 2 种模型的评价指标对比

Fig. 2 Comparison of two model evaluation indexes

2) 本研究在应用较多的皮尔森相关系数法筛选自变量因子的基础上,进一步采用 VIF 法提取自变量因子,兼顾了变量间的相关性以及共线性问题,与只基于皮尔森相关系数法筛选自变量因子构建的模型相比,所构建的模型具有较好的稳定性。

3) Landsat 8 影像全色波段具有较高的空间分辨率,采用多光谱影像的纹理特征可提高生物量估算模型的估算精度,本研究未采用 Landsat 8 影像全色波段进一步提取纹理特征作为自变量来参与模型构建,在后续的研究中可考虑全色波段纹理特征来构建乔木林地上生物量模型,并验证其是否适用。

参考文献:

- [1] Cao Lin, Coops Nicholas C, Innes John L, et al. Estimation of forest biomass dynamics in subtropical forests using multi-temporal airborne LiDAR data [J]. Remote Sensing of Environment, 2016, 178: 151 - 171.
- [2] 范文义, 张海玉, 于颖, 等. 三种森林生物量估测模型的分析[J]. 植物生态学报, 2016, 35(4): 402 - 410.
- [3] 王海滨, 侯瑞萍, 郑冬梅, 等. 基于地理加权回归模型的亚热带地区乔木林生物量估算[J]. 农业机械学报, 2018(6): 184 - 190.
- [4] 刘茜, 杨乐, 柳钦火, 等. 森林地上生物量遥感反演方法综述[J]. 遥感学报, 2015, 19(1): 62 - 74.
- [5] Lu D, Chen Q, Wang G, et al. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems[J]. International Journal of Digital Earth, 2014, 9(1): 63 - 105.
- [6] 戚玉娇. 大兴安岭森林地上碳储量遥感估算与分析[D]. 哈尔滨: 东北林业大学, 2014.
- [7] Lu, D., Chen, Q., Wang, G., et al. Aboveground forest biomass estimation with Landsat and LiDAR data and uncertainty analysis of the estimates[J]. International Journal of Forestry Research, 2012, 2012(2): 1 - 16.
- [8] 杜华强. 竹林生物量碳储量遥感定量估算[M]. 北京: 科学出版社, 2012.
- [9] 韩爱惠. 森林生物量及碳储量遥感监测方法研究[D]. 北京: 北京林业大学, 2009.
- [10] 沈楚楚. 浙江省主要树种(组)生物量转换系数研究[D]. 杭州: 浙江农林大学, 2013.
- [11] 陶立超. 白马林场森林碳储量遥感估测[D]. 北京: 北京林业大学, 2014.
- [12] 许等平, 李晖, 智长贵, 等. 基于 CEBERS-WFI 遥感数据的森林生物量估测方法研究[J]. 林业资源管理, 2010(3): 104 - 109.
- [13] Sarker L R, Nichol J E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices[J]. Remote Sensing of Environment, 2011, 115(4): 968 - 977.
- [14] Nichol J E, Sarker M L R. Improved biomass estimation using the texture parameters of two high-resolution optical sensors[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49: 930 - 948.
- [15] 王月婷, 张晓丽, 杨慧乔, 等. 基于 Landsat 8 卫星光谱与纹理信息的森林蓄积量估算[J]. 浙江农林大学学报, 2015, 32(3): 384 - 391.
- [16] Eckert S. Improved forest biomass and carbon estimations using texture measures from worldView-2 satellite data[J]. Remote Sensing, 2012, 4(4): 810 - 829.
- [17] Meng J H, Li S M, Wang W, et al. Estimation of forest structural diversity using the spectral and textural information derived from SPOT-5 satellite images[J]. Remote Sensing, 2016, 8(2): 125.
- [18] Sarker L R, Nichol J E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices[J]. Remote Sensing of Environment, 2011, 115(4): 968 - 977.
- [19] 王惠文, 吴载斌, 孟洁. 偏最小二成回归的线性与非线性方法[M]. 北京: 国防工业出版社, 2006.
- [20] 张超, 彭道黎, 涂云燕, 等. 利用 TM 影像和偏最小二乘回归方法估测三峡库区森林蓄积量[J]. 北京林业大学学报, 2013, 35(3): 11 - 17.
- [21] Li X C, Zhang Y J, Bao Y S, et al. Exploring the best hyperspectral Features for LAI estimation using partial least squares regression[J]. Remote Sensing, 2014, 6(7): 6221 - 6241.
- [22] Kelsey K C, Neff J C. Estimates of aboveground biomass from texture analysis of Landsat imagery[J]. Remote Sensing, 2014, 6(7): 6407 - 6422.
- [23] 徐小军, 周国模, 杜华强, 等. 基于 Landsat TM 数据估算雷竹林地上生物量[J]. 林业科学, 2011, 47(9): 1 - 6.