

基于 Landsat 时间序列数据和 ATC 滤波算法的高山松碳储量估测

滕晨凯¹, 肖月瑶², 张加龙¹, 和云润¹, 陈朝情¹

1. 西南林业大学 林学院, 昆明 650224;

2. 西南林业大学 会计学院, 昆明 650224

摘要: 借助遥感技术准确估测森林碳储量对于森林生态系统的保护和可持续发展具有重要意义。由于遥感时间序列数据存在大量的噪声, 因此, 为了提高森林碳储量的估测精度, 有必要开发一种滤波算法, 以减少高海拔地区 Landsat 时间序列数据噪声的干扰。基于 1987 年、1992 年、1997 年、2002 年、2007 年、2012 年、2017 年云南省香格里拉市国家森林资源连续清查固定样地的数据以及 1987 年—2017 年的 Landsat 时间序列影像, 本研究利用 Python 开发了自适应地形卷积 ATC (Adaptive Topography Convolution) 算法, 该算法考虑到地形因素对于图像质量的影响, 在尽可能保留图像细节的情况下去除图像的噪声, 并使用 Savitzky-Golay 滤波、中值滤波对 Landsat 时间序列数据进行滤波。应用随机森林回归算法 RFR (Random Forest Regression) 构建香格里拉市高山松碳储量估测模型, 选择最优估测模型对香格里拉市高山松碳储量进行反演制图。结果表明: (1) 从图像的质量评价指标平均绝对误差 MAE (Mean Absolute Error) 来看, 经过 ATC 算法滤波后的图像质量最好; (2) 在使用 RFR 方法的情况下, 滤波后的数据均表现出比原始数据更高的估测精度; (3) 在使用 RFR 方法的情况下, 基于贡献度前 10 的特征因子和累积贡献度达到 70% 的特征因子建模时, 经过 ATC 算法滤波后的时间序列数据均表现出了最优的估测精度; (4) 基于 ATC 算法和贡献度前 10 的特征因子对高山松碳储量的建模效果最优, 其决定系数 R^2 为 0.867、均方根误差 RMSE 为 15.527/(t/hm²)、预测精度 P 为 73.54%、相对均方根误差 rRMSE 为 41.14%; (5) 基于最优估测模型的高山松碳储量反演结果分别为: 677 万 t (1987 年)、716 万 t (1992 年)、722 万 t (1997 年)、436 万 t (2002 年)、720 万 t (2007 年)、711 万 t (2012 年)、753 万 t (2017 年)。综上, 使用 ATC 滤波算法能够有效去除高海拔地区时间序列影像中的噪声, 从而降低时间序列影像的不确定性, 提高了高山松碳储量遥感估测精度。

关键词: Landsat 时间序列, 滤波, 高山松, 碳储量, ATC

中图分类号: S758/S771.8/P2

引用格式: 滕晨凯, 肖月瑶, 张加龙, 和云润, 陈朝情. 2024. 基于 Landsat 时间序列数据和 ATC 滤波算法的高山松碳储量估测. 遥感学报, 28(11): 2927-2942

Teng C K, Xiao Y Y, Zhang J L, He Y R and Chen C Q. 2024. Estimation of *Pinus densata* carbon storage based on Landsat time series data and ATC filtering algorithm. National Remote Sensing Bulletin, 28(11): 2927-2942 [DOI: 10.11834/jrs.20244006]

1 引言

森林作为陆地生态系统的主体, 在改善生态环境方面起着重要作用。碳储量是生态系统碳循环的重要评价指标, 可以用于直接衡量森林的固碳能力 (曹军等, 2023)。精准估算森林碳储量对于生态环境的保护以及林业资源的可持续发展有

着重要意义 (Wang 等, 2022)。

估算碳储量的方法主要包括野外调查法和遥感估测法 (Torre-Tojal 等, 2022)。其中, 野外调查法是最准确的, 但是耗时耗力且难以进行大尺度范围的碳储量测定。随着 Landsat 卫星数据的免费开放 (Woodcock 等, 2008; Wulder 等, 2016), 可使用数据的时间周期长、分辨率较高、覆盖率

收稿日期: 2024-01-04; 预印本: 2024-04-09

基金项目: 国家自然科学基金 (编号: 32260390, 31860207); 2020 年云南省高层次人才培养支持计划“青年拔尖人才”专项 (编号: YNWR-QNBJ-2020-164)

第一作者简介: 滕晨凯, 研究方向为资源环境遥感。E-mail: tckswfu@swfu.edu.cn

通信作者简介: 张加龙, 研究方向为林业遥感。E-mail: jialongzhang@swfu.edu.cn

广,已经获得了科研人员的高度关注和广泛研究,使得利用光学遥感时间序列数据进行大尺度范围的碳储量估测成为可能。然而,由于Landsat卫星时间跨度长,传感器种类多,并且多种传感器的数据在成像时受到各种因素的影响较大(Zhu, 2017),因此,遥感时间序列数据存在噪声和不确定性,限制了其深入应用,需要应用多种方法对时间序列数据进行重构,以获得高质量的数据集。

目前,被广泛应用于遥感影像去噪的滤波算法主要分为以下3类:一是时间域上的处理,包括L-T算法(LandTrendr)(Kennedy等, 2010)、S-G算法(Savitzky-Golay)(Cao等, 2018)、最佳指数斜率提取法BISE(Best Index Slope Extraction)(Viovy等, 1992)等,这些方法通过对时间序列数据的分析,识别和平滑影像中的噪声,从而提高图像质量和信息提取的准确性;二是空间域上的处理,包括中值滤波MF(Median Filter)(Çelik等, 2023)、高斯滤波GF(Gaussian Filter)(何国庆, 2022)等,这些方法主要关注图像中相邻像素之间的空间关系,通过对像素值进行统计和调整,减少图像中的异常值和噪声;三是频率域上的处理,包括小波低通滤波WF(Wavelet Filtering)(李艳等, 2019)、傅里叶低通滤波FF(Fourier Filtering)(Olsson和Eklundh, 1994)等,这些方法通过在频率域进行变换和滤波,实现对不同频率成分的调控,从而有效地去除图像中的高频噪声。目前,以上滤波方法更多应用在对植被指数的处理并用于植被提取与分类上,在碳储量的遥感估测反演研究较少(王书贤等, 2021)。鲍瑞等(2020)使用L-T算法,ARIMA算法以及1×3窗口均值滤波对时间序列数据进行滤波重构,并使用滤波前后的数据对香格里拉高山松地上生物量进行估测,滤波后的数据相较于滤波前的数据在生物量估测方面表现出了更高的精度。时间序列数据重构在提高碳储量估测精度方面已经表现出了可行性。

传统滤波算法常常用于平滑整个图像,以达到去除噪声的目的。然而,这种平滑之后的图像会导致影像中细节的丢失,降低了影像的空间分辨率。尤其是对于需要准确捕捉细节信息的遥感图像分析来说,可能会限制其应用效果。所以,需要根据不同应用选择或者开发适宜该领域的最佳算法(李儒等, 2009)。此外,多数滤波重构方

法并未考虑到地学规律的影响。因此,本研究选取云南省迪庆藏族自治州香格里拉市作为研究区,以高山松为研究对象,利用1987年—2017年的国家森林资源连续清查数据和Landsat年度时间序列影像数据,结合谷歌地球引擎GEE(Google Earth Engine),Python等科学运算语言,对时间序列影像使用不同的滤波重构方法。分别从空间域,时间域探究滤波重构方法对于时间序列影像的精度影响并完成时间序列数据的滤波重构,对滤波前后的高山松碳储量估测精度进行对比分析。

2 研究区、数据与方法

2.1 研究区概况

香格里拉市位于云南省西北部(99°20'E—100°19'E, 26°52'N—28°52'N),为青藏高原横断山区腹地,处在云南、四川、西藏三省的交汇地带。香格里拉地处高海拔,低纬度地带,气候随海拔升高而变化,垂直立体气候特征明显。地势西北高、东南低,最高点海拔5545 m,最低点海拔1503 m,海拔高差4042 m,平均海拔3459 m。其优势树种有云杉(*Picea asperata*)、冷杉(*Abies fabri*)和高山松(*Pinus densata*)等。研究区概况详见图1。

2.2 数据来源及处理

2.2.1 样地数据

研究的样地数据以及高山松分布范围均来自于国家森林资源连续清查项目NFI(National Forest Inventory)。抽取了均匀分布在香格里拉全市范围内的38个高山松固定样地,每块样地的面积为0.08 hm²(28.28 m×28.28 m),共产生125份调查记录。高山松分布范围的组织和存储形式为森林斑矢量数据。

NFI固定样地数据主要依据GB/T 38590—2020《森林资源连续清查技术规程》进行规范:(1)按前期样地记录寻找固定样地位置;(2)固定样地复位;(3)样木复位。精度评估方法为:(1)≥8 cm样木株数无误,<8 cm的误差在5%;(2)胸径≥20 cm的树木,测量误差<1.5%,胸径<20 cm的树木,测量误差<0.3 cm;(3)树高<10 m时,测量误差<3%,树高≥10 m,测量误差<5%。并且地类、起源、林种、优势树种等因子不应有错。




图1 研究区概况

Fig. 1 Overview of research area

高山松单木生物量（孙雪莲 等，2016）计算方式如下：

$$AGB = 0.073 \times DBH^{1.739} \times H^{0.880} \quad (1)$$

式中，AGB为单木地上生物量，kg；DBH为胸径，cm； H 为树高，m。

目前针对碳储量的计算方法，通常是采用碳转换系数乘以生物量得到（焦燕和胡海清，2005），参考韩雪莲等（2023）等对于香格里拉地区高山松碳储量的研究，选择0.5作为含碳系数。具体计算方式如下：

$$C = B \times C_c \quad (2)$$

式中， C 为高山松碳储量， B 为森林地上生物量， C_c 为碳转换系数

2.2.2 Landsat 时间序列数据

Landsat 数据为经过大气校正的地表反射率数据。为了使 Landsat 时间序列影像在光谱特征上拥有更好的一致性，参考 Roy 等（2016）等撰写的文档，并通过谷歌地球引擎 GEE（Google Earth Engine）平台对 Landsat 不同传感器进行协调。

由于气候原因，使用年度间隔的时间序列作为香格里拉市研究数据集。冬季初春时节影像质量较好，且植被在冬季生长状态稳定，在时间上选择了当年1月到当年3月的影像（鲍瑞 等，2020）。将各年度筛选出来的高质量影像采用中值合成的方式，对香格里拉市全面覆盖。Landsat 数据的基本信息如表1所示。

表1 Landsat 时间序列数据基本信息

Table 1 Basic information of Landsat time series data

传感器类型	行编号	条带号	起始年份	结束年份	起始日期	结束日期	云量/%	数量
Landsat 5 TM	041	131	1987	2011	01-01	03-31	<10	57
	040	132	1987	2011	01-01	03-31	<10	48
	041	132	1987	2011	01-01	03-31	<10	28
Landsat 7 ETM+	041	131	2012	2013	01-01	03-31	<10	6
	040	132	2012	2013	01-01	03-31	<10	5
	041	132	2012	2013	01-01	03-31	<10	1
Landsat 8 OLI	041	131	2014	2017	01-01	03-31	<10	14
	040	132	2014	2017	01-01	03-31	<10	10
	041	132	2014	2017	01-01	03-31	<10	5

2.2.3 数字高程模型数据

数字高程模型来自于 ASTER GDEM 数据产品，空间分辨率为 30 m。根据 ASTER GDEM 官方帮助文档，数据的水平精度为 30 m，垂直精度为 20 m。

2.2.4 地形位置指数

地形位置指数为单元格高程与预定半径范围内单元格平均高程之间的差异，使用数字高程模型进行计算，具体计算方式如下：

$$TPI = Z_0 - \frac{1}{n} \sum_{i=1}^n Z_i \quad (3)$$

式中， Z_0 为中心点高程， n 为邻域内高程点数量， Z_i 为邻域内高程。

2.3 研究方法

研究的技术路线如图 2 所示。首先，数据的预处理；然后，使用不同滤波方法对时间序列影像进行滤波，并对滤波前后的数据提取遥感特征因子，采用随机森林回归方法构建碳储量估测模型；最后，为了比较使用不同滤波方法滤波后的时间序列数据在碳储量估测精度方面的表现，采用不同的指标来评价碳储量估测模型的准确性。




图 2 技术路线图

Fig. 2 Technology roadmap

2.4 S-G 滤波

S-G 滤波是一种最小平方拟合卷积，通过对信

号的局部区域进行多项式拟合以达到平滑和去除噪声的目的。时域窗口越小，拟合的结果越接近真实值，时域窗口越大，拟合的曲线越平滑。

2.5 中值滤波

中值滤波是一种基于排序统计理论的非线性滤波，通过将一定邻域范围内的像素进行排列，并选择这些像素的中值作为最后的滤波结果。

2.6 自适应地形卷积算法 ATC (Adaptive Topography Convolution)

2.6.1 算法描述

高海拔地区一般指海拔 1500 m 以上的地区（西南林业大学，2022），因其地势复杂、环境恶劣，成为了遥感分析的难点地区。对于在高海拔地区获取的初春季节的时间序列数据，主要的噪声来源来自雪，这些噪声通常在山谷和山脊地区显著存在。相较于其他减少噪声和构建高质量时间序列数据集的方法，ATC 算法的基本假设是：对于高海拔地区的山谷和山脊，将其视为噪声点并进行相应处理。

本研究基于空间卷积理论和反距离权重法（Maleika，2020），采用线性方法，提出了 ATC 算法。ATC 算法考虑到积雪对于图像质量的影响，基于空间自相关性，充分利用相邻像素之间的空间关系，从空间域的角度对图像进行滤波，以更精准的方式调整图像的亮度和对比度，从而提高图像的质量和清晰度。

TPI 作为 DEM 的衍生产品（Weiss，2001），能够更准确地反映一个点与其邻域内其他点在地形上的相对位置关系。常被用作地表的形态分类，如山脊山谷、上中下坡位以及平坡等（马伟波等，2020）。ATC 算法按照先检测后滤波的模式，根据重分类后的 TPI 数值，将图像分成疑似噪声点区域和非噪声点区域。

当 TPI 属于山谷山脊地区时，将其视作疑似噪声点区域，考虑到部分山谷和山脊区域可能不存在噪声污染，为了更细致地处理这些区域，结合三倍标准差法（黄二辉等，2006）来对疑似噪声点区域进行二次判断并选择适宜的卷积核来进行运算；当 TPI 属于山谷山脊外的其他区域时，将其视作优质像元，ATC 算法对这些中心点赋予较高的权重值，以确保图像的整体质量。

2.6.2 算法具体步骤

步骤 1: 由于影像的时间跨度较长, 部分数据会出现像元值缺失的情况, 为了保证图像的完整性, 通过利用周围相邻像素的信息, 使用空间插值的方式在一定程度上还原缺失的数据, 减轻数据缺失对图像解译和分析的影响。

步骤 2: 使用 3×3 的矩形邻域窗口来计算 TPI, 并按照一定的分类规则将 TPI 重分类成 3 类。根据香格里拉的地形地貌情况, 研究将 TPI 重分类的阈值设定为 -1 和 1, 即当 $TPI < -1$ 时, 这部分区域为山谷, 赋值为 1, 当 $-1 \leq TPI \leq 1$, 这部分区域为平缓区域, 赋值为 2, $TPI > 1$ 时, 这部分区域为山脊, 赋值为 3。

步骤 3: 将重分类后的 TPI 值与 Landsat 影像按照空间位置进行匹配。

步骤 4: 根据 TPI 判断使用不同的 3×3 卷积核对图像进行卷积运算。

(1) 当 $TPI=2$ 时, 这部分区域属于较为平缓的区域, 像元质量相对较好, 此时对中心点赋予更高的权重值能够尽可能的保留图像的细节。具体计算方式如下:

$$y = \frac{1}{10}x_2 + \frac{1}{10}x_3 + \frac{3}{5}x_5 + \frac{1}{10}x_6 + \frac{1}{10}x_8 \quad (4)$$

式中, y 为新中心点像元值, x 为原始像元值。

(2) 当 $TPI=1, 3$ 时, 这部分区域属于山谷山

脊地区, 像元可能存在噪声污染的情况。首先对整幅影像计算标准差, 并结合 3 倍标准差法对这些疑似噪声的区域进行 2 次判断, 当像元属于异常的离群值时, 中心点像元的权重值降为零, 为了能反应受到噪声污染前像元的真实情况, 通过反距离权重法来确定 3×3 卷积核中除中心点外像元的权重值, 距离越远, 权重越低, 并依据式 (5) 计算出了剩余像元值所占的权重。

$$W_i = \frac{1}{\sum_{i=1}^n \frac{1}{d_i}} \quad (5)$$

式中: W_i 为权重值, d_i 为像元点至中心点像元的距离。

采用通过反距离权重法计算出来的权重值, 使用式 (6) 计算得到新的像元值。

$$y = \frac{1}{10}x_1 + \frac{3}{20}x_2 + \frac{1}{10}x_3 + \frac{3}{20}x_4 + \frac{3}{20}x_6 + \frac{1}{10}x_7 + \frac{3}{20}x_8 + \frac{1}{10}x_9 \quad (6)$$

式中, y 为新中心点像元值, x 为原始像元值。

(3) 当 $TPI=1, 3$ 时, 但又不属于异常的离群值时, 将其看作是优质像元, 采用第一种情况下的卷积核, 依据式 (4) 计算得到新的像元值。

步骤 5: 完成整幅图像的滤波。

ATC 算法具体计算步骤如图 3 所示。




图 3 ATC 算法示意图

Fig. 3 ATC algorithm schematic

2.7 滤波后图像质量评价指标

2.7.1 平均绝对误差

平均绝对误差是一种衡量预测结果与实际观测值之间差异的指标 (Cao 等, 2018), 其数值越小, 滤波的效果越好。计算方式如下:

$$MAE = \frac{\sum_{i=1}^n |y_i - y_j|}{n} \quad (7)$$

式中, y_i 为滤波后图像的值, y_j 为滤波前图像的值, n 为样本个数。

研究使用了均匀分布在香格里拉全境的样地

点来提取基于像素的数据并计算使用不同滤波方法滤波后的数据与原始数据之间的偏差。

2.7.2 峰值信噪比

峰值信噪比通常用于评估滤波后图像与原始图像之间的差异（许黎等，2022），但它不能完全反映人眼的主观感受。在计算PSNR时，会分别取滤波前后一定大小的图像，并通过比较原始图像和滤波后图像的峰值信号和均方误差来得出评估结果。PSNR值越大，表示滤波后图像的失真越少，滤波效果越好。PSNR如式（8）所示，用均方误差MSE（Mean Square Error）值来计算PSNR值。MSE可以用式（9）来定义， MAX_f 为图像中像素的最大值，可以用式（10）来定义。

$$PSNR = 10 \log_{10} \left(\frac{MAX_f^2}{MSE} \right) \quad (8)$$

式中：

$$MSE = \frac{1}{W \times H} \sum_{x=0}^{W-1} \sum_{y=0}^{H-1} (f(x,y) - o(x,y))^2 \quad (9)$$

$$MAX_f = (f(0,0):f(W-1,H-1)) \quad (10)$$

式中， f 为滤波后图像， o 为滤波前图像， (x, y) 为像元位置， W 为图像宽度， H 为图像高度。

2.8 随机森林回归算法

随机森林回归算法是一种通过构建多个决策树提高回归模型准确性的方法。每颗决策树都在随机抽样的数据子集上建立，随机选择特征，最后通过投票机制综合多棵树的结果（Xu等，2023）。是当前碳储量遥感估测中应用较多的一种非参数模型。

随机森林回归算法在训练过程中伴随着一定数量运行参数的调整。建模过程中的调整的参数主要有4个，分别为

$n_estimators$ ：参与运算的弱学习器的最大迭代次数。

max_depth ：决策树最大深度，默认为10。

$min_samples_leaf$ ：叶节点最少样本数。

$min_samples_split$ ：内部节点再划分所需最小样本数，默认为2。

本研究限定了部分模型运行参数： $max_depth=10$ ， $min_samples_leaf=1$ ， $min_samples_split=2$ ，在此情况下，弱学习器允许迭代的最大次数范围为20—200。

2.8.1 精度评价

本研究使用125个样地调查数据；其中80%

（100个）的数据进行模型的拟合，20%（25个）用作模型的预测，并在模型拟合时进行交叉验证，为了使模型结果尽可能客观，对每个模型进行了20次拟合。

评价模型准确性的指标为相关系数（ R^2 ）、均方根误差（RMSE）、预测精度（ P ）、相对均方根误差（rRMSE），具体计算方式如下所示：

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (11)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{n}} \quad (12)$$

$$P = \frac{1}{n} \sum_{i=1}^n \left(1 - \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \right) \times 100\% \quad (13)$$

$$rRMSE = \frac{RMSE}{\bar{y}} \times 100\% \quad (14)$$

式中， y_i 为实测样地数据碳储量， $\hat{y}_i$ 为模型预测值， $\bar{y}$ 为真实值均值， n 为样本个数。

这125个样地点在DEM以及TPI中的分布情况如表2所示。

表2 样地点分布情况

Table 2 Distribution of sampling plots

高程/m	样地点数量	地形位置指数	样地点个数
1500—3000	9	$TPI < -1$	60
3000—3200	36	$-1 \leq TPI \leq 1$	38
3200—3600	60	$TPI > 1$	37
3600—3800	9	—	—
3800—4000	11	—	—
4000—5520	0	—	—

3 结果与分析

3.1 ATC算法滤波后影像质量评价

本研究选取了部分年份使用ATC算法滤波前后的图像进行展示，如图4、图5所示。由图4、图5可见，经过ATC算法滤波后的图像质量有所提高。由图6可见，S-G滤波方法对像元值的调整较为显著，而ATC和MF方法对像元值的调整较为微小。这表明采用ATC算法对影像进行滤波可以有效地保留图像细节，同时消除原始时间序列数据中存在的 uncertainty。




图 4 7 个不同年份香格里拉市使用 ATC 算法滤波前后图像
Fig. 4 Seven different years of Shangri La City using ATC algorithm to filter before and after images




图 5 7 个不同年份香格里拉市使用 ATC 算法滤波前后影像细节对比图

Fig. 5 Comparison of image details before and after using ATC algorithm filtering in Shangri La City in seven different years

MAE 具体计算结果如表 3 所示，可见滤波前后的数据偏差较大，其中 ATC 算法的滤波效果最好。

此外，研究还使用 PSNR 来对 ATC 算法滤波后

的图像可靠性进行检验。对于滤波前后的数据，分别裁剪长度为 1403 像素，宽度为 1340 像素的图像用于计算 PSNR。由表 4 的计算结果可见，除了

1987年的B1波段, 1997年的B4波段和2017年的B5波段, 其余年份所有波段的PSNR均>40 dB, 说明使用ATC算法滤波后的图像质量相对较好。




图6 1987年—2017年Landsat时间序列影像使用不同滤波方法滤波后像元值变化曲线(以图5中1号样点为例)
Fig. 6 Pixel value variation curves of Landsat time series images filtered using different filtering methods from 1987 to 2017

表3 不同滤波方法滤波后与原始影像之间的平均绝对误差

Table 3 The mean absolute error between the filtered image and original image using different filtering methods						
滤波方法	B1	B2	B3	B4	B5	B7
S-G	57.66	73.97	83.57	259.20	244.81	153.71
MF	42.57	56.77	70.77	102.43	121.01	96.98
ATC	5.92	7.75	8.58	29.45	26.35	16.24

表 4 ATC 算法滤波后峰值信噪比
Table 4 Peak signal-to-noise ratio after ATC algorithm filtering

							/dB
年份	B1	B2	B3	B4	B5	B7	
2017	50.95	49.56	48.56	44.39	27.85	45.12	
2012	49.71	48.35	51.50	47.09	50.82	47.72	
2007	53.57	47.84	46.78	42.12	44.88	47.80	
2002	61.58	60.66	59.86	56.70	52.63	50.17	
1997	54.35	52.95	52.13	27.74	51.49	48.91	
1992	58.04	53.19	56.45	53.80	49.59	46.70	
1987	28.25	58.23	57.09	50.14	54.30	47.47	

3.2 使用不同滤波方法的时间序列遥感数据建模精度对比

3.2.1 建模特征因子提取

Landsat 时间序列合集中，每幅影像都保留了 6 个波段，分别是 B1 (BLUE)、B2 (GREEN)、B3 (RED)、B4 (NIR)、B5 (SWIR1)、B7 (SWIR2)。研究参考了岳彩荣 (2012) 对于香格里拉地区生物量/碳储量的研究，对滤波前后的 Landsat 时间序列数据提取如表 5 所示的遥感因子。

其中，土壤调节植被指数 SAVI 引入了一个土壤调节系数 L ，通常在植被覆盖度较高的地区取 0.25，中等地区取 0.5，低的地区取 1，由于香格里拉地区的植被覆盖度较高 (岳彩荣, 2012)，所以在本研究中 L 取 0.25。

3.2.2 建模精度对比

模型的效率会受到特征数量的影响，因为过多的特征会降低模型拟合的速度。此外，原始特征中含有一些冗余信息，这对模型精度有负面影响 (Liao 等, 2022)。因此，本研究利用随机森林特征重要性评估方法，在数据标准化的前提下，对提取出的遥感因子进行了特征筛选，按照特征在随机森林回归模型中的贡献度，选择了贡献度前 10 的特征用于碳储量估测模型的构建 (周蓉等, 2022)，结果如表 6 所示。此外，研究还对比了基于不同滤波方法的遥感特征因子在随机森林建模时累积贡献度达到 70% 的表现，结果见表 7。

研究比较了未滤波的遥感数据、基于 S-G 滤波的遥感数据、基于 MF 滤波的遥感数据，基于 ATC 滤波的遥感数据在香格里拉高山松碳储量估测方面的表现。由图 6 可以看到，基于贡献度前

10 的遥感特征建立的随机森林模型中，ATC 滤波方法在模型拟合和预测精度方面有着最佳的表现。由图 7 可以看到，在使用累积贡献度达到 70% 的遥感特征建立随机森林估测模型时，ATC 滤波方法依旧有着最优的表现。

3.3 高山松地上碳储量估测结果并与已有研究成果的对比

基于 ATC 算法滤波后的数据，使用遥感特征 (10 个) 训练的最优随机森林估测模型用于 1987 年—2017 年香格里拉高山松碳储量的估测。由此，得到对应年份的高山松碳储量反演数据，如表 8 所示。1987 年、1992 年、1997 年、2002 年、2007 年、2012 年、2017 年的高山松平均碳储量分别为 35.02 t/hm²、36.75 t/hm²、37.23 t/hm²、22.53 t/hm²、36.40 t/hm²、35.93 t/hm²、35.87 t/hm²。

通过已发表研究中的高山松生物量估测结果乘以碳转换系数 (岳彩荣, 2012) 并与本研究进行对比。表 8 总结了历年来各研究者对于香格里拉高山松生物量的反演结果。岳彩荣 (2012) 和王金亮等 (2013) 的研究对象为森林生物量，无法直接比较。根据相关研究 (Chen 等, 2023)，地上生物量占森林生物量的 70%—90%，由此推算岳彩荣 (2012) 研究中的 2008 年香格里拉高山松地上生物量大致在 1523 万—1968 万 t，王金亮等 (2013) 研究的 2009 年香格里拉高山地上生物量大致在 1400 万—1800 万 t。除此之外，研究还使用 2016 年的香格里拉市森林资源二类调查数据，得到 2016 年高山松地上碳储量大致为 745 万 t，与本研究相近年份 (2017 年) 反演结果相差 8 万 t。

由图 8 可见：在 1987 年—1997 年，碳储量呈现逐渐增加的趋势。而从 2002 年—2017 年，碳储

量则表现出明显的波动趋势。这种波动的一个主要原因是香格里拉地区实施了森林抚育措施，当高山松生长到一定阶段时，成熟的天然林被幼小的人工林所替代，间接导致了高山松碳储量的减少；每个研究者对于香格里拉高山松碳储量的估测结果差异都很大，在进行遥感估测碳储量的过程中，误差涉及多个来源，这些主客观因素的差异导致了较大的研究结果差异。

表 5 用于随机森林回归方法建模的遥感特征因子

Table 5 Remote sensing feature factors used for modeling random forest regression methods		
因子类型	因子	计算方式
单波段因子	B1	—
	B2	—
	B3	—
	B4	—
	B5	—
	B7	—
比值因子	B4/B2	—
	B5/B3	—
	B5/B4	—
	B5/B7	—
	B7/B3	—
	B3/Albedo	Albedo=B1+B2+B3+B4+B5+B7
植被指数	B4×B3/B7	—
	Albedo	Albedo=B1+B2+B3+B4+B5+B7
	归一化植被指数 NDVI	$NDVI = \frac{B4 - B3}{B4 + B3}$
	比值植被指数 RVI	$RVI = \frac{B4}{B3}$
	差值植被指数 DVI	$DVI = B4 - B3$
	增强型植被指数 EVI	$EVI = \frac{2.5(B4 - B3)}{B4 + 6B3 - 7.5B1 + 1}$
	大气阻抗植被指数 ARVI	$ARVI = \frac{B4 - 2B3 + B1}{B4 + 2B3 - 1}$
	叶面积指数 LAI	$LAI = 3.618 \times EVI - 0.118$
	归一化燃烧指数 NBR	$NBR = \frac{B4 - B7}{B4 + B7}$
	ND32	$ND32 = \frac{B3 - B2}{B3 + B2}$
	ND57	$ND57 = \frac{B5 - B7}{B5 + B7}$
	ND452	$ND452 = \frac{B4 + B5 - B2}{B4 + B5 + B2}$
	ND53	$ND53 = \frac{B5 - B3}{B5 + B3}$
	ND54	$ND54 = \frac{B5 - B4}{B5 + B4}$
	土壤调节植被指数 SAVI	$SAVI = \frac{1.25 \times (B4 - B3)}{B4 + B3 + 0.25}$
	优化土壤调节植被指数 OSAVI	$OSAVI = \frac{B4 - B3}{B4 + B3 + 0.16}$
	EVI2	$EVI2 = \frac{2.5 \times (B4 - B3)}{B4 + 2.4B3 + 1}$

表 6 用于随机森林建模的贡献度前 10 遥感特征因子

Table 6 Top 10 Contributing remote sensing feature factors for random forest modeling

数据类型	遥感因子	累计贡献度/%
未滤波	LAI、B4×B3/B7、ND53、ND32、ARVI、B4/B2、EVI、B1、ND54、B5/B7	59
基于 S-G 滤波	B3/Albedo、EVI、ND452、ND54、B5/B3、LAI、ND32、B5/B4、ND53、ARVI	64
基于 MF 滤波	B1、ND57、EVI、LAI、B4×B3/B7、ND32、B5/B7、ND54、B5/B3、B5/B4	67
基于 ATC 滤波	EVI、LAI、B7、B5/B7、ND32、B4×B3/B7、B3/Albedo、B4/B2、B4、B7/B3	62

表 7 用于随机森林建模的累积贡献 70% 的遥感特征因子

Table 7 Remote sensing feature factors contributing to 70% cumulative contribution for random forest modeling

数据类型	遥感因子	累计贡献度/%
未滤波	LAI、B4×B3/B7、ND53、ND32、ARVI、B4/B2、EVI、B1、ND54、SWIR1/SWIR2、ND452、B3/Albedo、B5/B4	70
基于 S-G 滤波	B3/Albedo、EVI、ND452、ND54、B5/B3、LAI、ND32、B5/B4、ND53、ARVI、ND57、B4×B3/B7、B4/B3	70
基于 MF 滤波	B1、ND57、EVI、LAI、B4×B3/B7、ND32、B5/B7、ND54、B5/B3、B5/B4、ND452	70
基于 ATC 滤波	EVI、LAI、B7、B5/B7、ND32、B4×B3/B7、B3/Albedo、B4/B2、B4、B7/B3、B5/B4、ND53、ARVI	70




图 7 累积贡献度为前 10 的高山松碳储量估测模型散点图

Fig. 7 Scatter plot of carbon storage estimation model for *Pinus Densata* with the cumulative contribution of the top 10

表 8 不同研究者对于香格里拉地区高山松碳储量估测结果

Table 8 Results of carbon storage estimation of *Pinus Densata* in Shangri-La by different researchers

研究者	研究发表年份	高山松生物量类型	反演数据年份	生物量反演结果/ 10 ² 万 t	碳储量结果/ 10 ² 万 t	碳储量反演结果差异/ 10 ² 万 t
岳彩荣(2012)	2012	森林生物量	2008	21.86	7.65—9.84	0.45—2.64(2007年)
王金亮等(2013)	2013	森林生物量	2009	20.00	7.00—9.00	0.20—1.80(2007年)
孙雪莲(2016)	2016	地上生物量	2014	11.71	5.86	1.25(2012年)
谢福明(2019)	2019	地上生物量	2015	12.11	6.05	1.06(2012年)
廖易等(2023)	2023	地上生物量	1987	8.76	4.38	2.39
			1992	8.96	4.48	2.68
			1997	9.29	4.64	2.58
			2002	9.01	4.51	0.15
			2007	8.88	4.44	2.76
			2012	8.79	4.40	2.71
			2017	8.72	4.36	3.17
本研究	—	—	1987	—	6.77	—
			1992	—	7.16	—
			1997	—	7.22	—
			2002	—	4.36	—
			2007	—	7.20	—
			2012	—	7.11	—
			2017	—	7.53	—




图 8 累积贡献度为 70% 的高山松碳储量估测模型散点图

Fig. 8 Scatter plot of carbon storage estimation model for *Pinus Densata* with a cumulative contribution of 70%




图9 1987年—2017年香格里拉高山松地上碳储量分布图

Fig. 9 Distribution of *Pinus Densata* aboveground carbon storage in Shangri-La from 1987 to 2017

4 讨论与结论

本研究基于空间卷积理论和反距离权重法开发了 ATC 算法，并使用 MAE 和 PSNR 对滤波后影像质量的可靠性进行了检验。使用 RFR 算法对香格里拉高山松碳储量进行估测建模并比较了不同方法滤波后的时间序列数据在高山松碳储量估测上的表现。选择最优估测模型对香格里拉高山松碳储量进行反演制图。得出了以下结论：

(1) 通过图像的质量评价指标 MAE 和 PSNR 以及目视效果来看，ATC 算法对于遥感图像的保真度较高，同时对于噪声有着一定的去除能力；

(2) 通过随机森林回归算法，基于不同滤波

方法滤波后的时间序列遥感数据对于高山松碳储量估测精度均有一定的提升。同时，ATC 算法滤波后的时间序列数据表现出了最优的估测精度，其 R^2 为 0.867、RMSE 为 15.527/(t/hm²)、 P 为 73.54%、rRMSE 为 41.14%。

(3) 在使用 RFR 和 ATC 滤波方法的情况下，香格里拉高山松碳储量估测结果分别为：677 万 t (1987 年)、716 万 t (1992 年)、722 万 t (1997 年)、436 万 t (2002 年)、720 万 t (2007 年)、711 万 t (2012 年)、753 万 t (2017 年)。

ATC 算法也存在一些不确定性，在提取 TPI 时，为了与卷积核的大小匹配，选择了较小的矩形邻域窗口，尽管这样能够获得较为精确的地形

变化趋势,但导致在一些情况下失去对整体地形特征的全面捕捉,因而影响算法在大尺度上的准确性。为了更好的保护影像的细节,ATC算法选择了较小的卷积核进行卷积运算,虽然使用较大的卷积核窗口能够有效去除大范围区域的噪声,但同时也会导致图像细节的丢失,使图像变得模糊。这些问题都有待在后续的研究中进一步探讨,以找到更合适的卷积核大小来平衡图像细节和噪声去除。

时间序列遥感数据的优势在于能够降低单期数据建模时不确定性因素的影响,提高建模的准确性和可靠性(张加龙和胥辉,2020)。并且通过滤波的方法对时间序列影像数据进行去噪,可以协调多年期遥感影像,把多年积累的森林调查数据联系起来使用(鲍瑞等,2020),为碳储量估测提供更准确和更为丰富的数据支持。在使用RFR构建碳储量估测模型时,仅使用了遥感因子作为特征变量,在未来的研究中,可以加入地形因子、纹理因子等其他对模型精度产生影响的特征变量,以提高估测模型的全面性和准确性。但是,由于空间异质性的存在(黄雅君等,2023),碳储量估测结果空间分布的不确定性仍无法完全消除。首先,碳储量在不同的空间特征上具有显著的变化(岳彩荣,2012),虽然选择的高山松固定样地均匀分布在香格里拉全境,但是仍然存在一定的限制。其次,空间分布属性会随时间变化(蔡晓斌,2010),这种动态性导致了不确定性的存在,特别是在长时间跨度内的研究中。此外,所使用的数据质量和精度也会影响空间分布预测的精确性。在未来的研究中,需要综合考虑这些因素影响,以提高估测结果空间分布的准确性。

参考文献(References)

- Bao R, Zhang J L and Chen P G. 2020. Research on improving the accuracy of estimating aboveground biomass for *Pinus densata* based on remote sensing using filtering algorithm. *Journal of Southwest Forestry University*, 40(5): 126-134 (鲍瑞, 张加龙, 陈培高. 2020. 应用滤波方法提高高山松地上生物量遥感估测精度的研究. *西南林业大学学报(自然科学)*, 40(5): 126-134) [DOI: 10.11929/j.swfu.201912065]
- Cai X B. 2010. The Change Analysis of Water Stage and Beach Wetland in Poyang Lake with the Aid of Multi-temporal Active and Passive Remote Sensing Data. Wuhan: Wuhan University (蔡晓斌. 2010. 主被动遥感辅助下的鄱阳湖水位时空动态及洲滩变化研究. 武汉: 武汉大学)
- Cao J, Zhang J L, Xiao Q L, Wang F P, Han X L and Huang Y J. 2023. Estimation and uncertainty analysis of aboveground carbon storage of *Pinus densata* based on Random Forests and Monte Carlo. *Forest Research*, 36(5): 131-139 (曹军, 张加龙, 肖庆琳, 王飞平, 韩雪莲, 黄屹杰. 2023. 基于随机森林和蒙特卡洛的高山松地上碳储量估测及不确定性分析. *林业科学研究*, 36(5): 131-139) [DOI: 10.12403/j.1001-1498.20220603]
- Cao R Y, Chen Y, Shen M G, Chen J, Zhou J, Wang C and Yang W. 2018. A simple method to improve the quality of NDVI time-series data by integrating spatiotemporal information with the Savitzky-Golay filter. *Remote Sensing of Environment*, 217: 244-257 [DOI: 10.1016/j.rse.2018.08.022]
- Çelik O İ, Büyüksalih G and Gazioğlu C. 2023. Improving the accuracy of satellite-derived bathymetry using multi-layer perceptron and random forest regression methods: a case study of Tavşan Island. *Journal of Marine Science and Engineering*, 11(11): 2090 [DOI: 10.3390/jmse11112090]
- Chen C Q, He Y R, Zhang J L, Xu D F, Han D Y, Liao Y, Luo L B, Teng C K and Yin T Y. 2023. Estimation of above-ground biomass for *Pinus densata* using multi-source time series in shangri-la considering seasonal effects. *Forests*, 14(9): 1747 [DOI: 10.3390/f14091747]
- Han X L, Zhang J L, Liu L, Liao Y, Tang J H and Han D Y. 2023. Sampling estimation of *Pinus densata* carbon storage based on remote sensing feature variables. *Journal of Southwest Forestry University*, 43(6): 117-124 (韩雪莲, 张加龙, 刘灵, 廖易, 唐金灏, 韩东阳. 2023. 基于遥感特征变量的高山松碳储量抽样估算. *西南林业大学学报(自然科学)*, 43(6): 117-124) [DOI: 10.11929/j.swfu.202208047]
- He G Q. 2022. Study on filtering methods of error processing in GRACE time variable gravity data. *Progress in Geophysics*, 37(1): 19-29 (何国庆. 2022. GRACE时变重力位系数误差处理滤波方法研究. *地球物理学进展*, 37(1): 19-29) [DOI: 10.6038/pg2022EE0510]
- Huang E H, Pan D L, Li S Q and He X Q. 2006. Comparing methods for identifying the outliers in the in-water profile spectral data. *Journal of Marine Sciences*, 24(1): 91-96 (黄二辉, 潘德炉, 李淑菁, 何贤强. 2006. 水下剖面光谱原始数据异常值的判断方法. *海洋学研究*, 24(1): 91-96)
- Huang Y J, Zhou W and Ma M G. 2023. Characterize the spatial heterogeneity of fragmented land-surface and its relationship with spatial scale in southwest China. *National Remote Sensing Bulletin*, 27(3): 802-809 (黄雅君, 周伟, 马明国. 2023. 西南地区破碎地表空间异质性刻画与空间尺度关系初探. *遥感学报*, 27(3): 802-809) [DOI: 10.11834/jrs.20232134]
- Jiao Y and Hu H Q. 2005. Carbon storage and its dynamics of forest vegetations in Heilongjiang Province. *Chinese Journal of Applied Ecology*, 16(12): 2248-2252 (焦燕, 胡海清. 2005. 黑龙江省森林植被碳储量及其动态变化. *应用生态学报*, 16(12): 2248-2252)
- Kennedy R E, Yang Z Q and Cohen W B. 2010. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr—Temporal segmentation algorithms. *Remote Sens-*

- ing of Environment, 114(12): 2897-2910 [DOI: 10.1016/j.rse.2010.07.008]
- Li R, Zhang X, Liu B and Zhang B. 2009. Review on methods of remote sensing time-series data reconstruction. Journal of Remote Sensing (in Chinese), 13(2): 335-341 (李儒, 张霞, 刘波, 张兵. 2009. 遥感时间序列数据滤波重建算法发展综述. 遥感学报, 13(2): 335-341) [DOI: 10.11834/jrs.20090257]
- Li Y, Zhang C C, Luo W R and Gao W J. 2019. Summer maize phenology monitoring based on normalized difference vegetation index reconstructed with improved maximum value composite. Transactions of the Chinese Society of Agricultural Engineering, 35(14): 159-165 (李艳, 张成才, 罗蔚然, 郜文江. 2019. 基于改进最大值法合成 NDVI 的夏玉米物候期遥感监测. 农业工程学报, 35(14): 159-165) [DOI: 10.11975/j.issn.1002-6819.2019.14.020]
- Liao Y, Zhang J L, Bao R and Xu D F. 2023. Estimating the dynamic changes of aboveground biomass of *Pinus densata* based on Landsat. Journal of Southwest Forestry University, 43(1): 117-125 (廖易, 张加龙, 鲍瑞, 许冬凡. 2023. 基于 Landsat 的高山松地上生物量动态变化估测模型构建. 西南林业大学学报(自然科学), 43(1): 117-125) [DOI: 10.11929/j.swfu.202111058]
- Liao Y, Zhang J L, Bao R, Xu D F and Han D Y. 2022. Modelling the dynamics of carbon storages for *Pinus densata* using landsat images in Shangri-La considering topographic factors. Remote Sensing, 14(24): 6244 [DOI: 10.3390/rs14246244]
- Ma W B, Zhao L J, Tian J R, Wang N, Gao Y Y and Li H D. 2020. Spatiotemporal changes of vegetation in Chishui River Basin based on topographic position index. Research of Environmental Sciences, 33(12): 2705-2712 (马伟波, 赵立君, 田佳榕, 王楠, 高媛赞, 李海东. 2020. 基于地形位置指数的赤水河流域植被时空变化研究. 环境科学研究, 33(12): 2705-2712) [DOI: 10.13198/j.issn.1001-6929.2020.10.19]
- Maleika W. 2020. Inverse distance weighting method optimization in the process of digital terrain model creation based on data collected from a multibeam echosounder. Applied Geomatics, 12(4): 397-407 [DOI: 10.1007/s12518-020-00307-6]
- Olsson L and Eklundh L. 1994. Fourier series for analysis of temporal sequences of satellite sensor imagery. International Journal of Remote Sensing, 15(18): 3735-3741 [DOI: 10.1080/01431169408954355]
- Roy D P, Kovalsky V, Zhang H K, Vermote E F, Yan L, Kumar S S and Egorov A. 2016. Characterization of Landsat-7 to Landsat-8 reflective wavelength and normalized difference vegetation index continuity. Remote sensing of Environment, 185: 57-70 [DOI: 10.1016/j.rse.2015.12.024]
- Southwest Forestry University. 2022. Forest dominant tree species identification method, device and equipment and storage medium. CN, 202211007458.0 (西南林业大学. 2022. 森林优势树种识别方法、装置、设备及存储介质. 中国, 202211007458.0)
- Sun X L. 2016. Biomass Estimation Model of *Pinus Densata* Forests in Shangri-La City Based on Landsat 8-OLI By Remote Sensing. Kunming: Southwest Forestry University (孙雪莲. 2016. 基于 Landsat8-OLI 的香格里拉高山松林生物量遥感估测模型研究. 昆明: 西南林业大学)
- Sun X L, Xiong H X, Xu H, Wei A C, Li C, Lü Y Y, Zhang B and Ou G L. 2016. Modelling of individual tree biomass factors for natural *Pinus densata* forest. Forest Resources Management, 3: 49-53, 60 (孙雪莲, 熊河先, 胥辉, 魏安超, 李超, 闫妍宇, 张博, 欧光龙. 2016. 高山松天然林单木生物量因子模型构建. 林业资源管理, (3): 49-53, 60) [DOI: 10.13466/j.cnki.lyzygl.2016.03.010]
- Torre-Tojal L, Bastarrika A, Boyano A, Lopez-Guede J M and Graña M. 2022. Above-ground biomass estimation from LiDAR data using random forest algorithms. Journal of Computational Science, 58: 101517 [DOI: 10.1016/j.jocs.2021.101517]
- Viovy N, Arino O and Belward A S. 1992. The Best Index Slope Extraction (BISE): a method for reducing noise in NDVI time-series. International Journal of Remote Sensing, 13(8): 1585-1590 [DOI: 10.1080/01431169208904212]
- Wang J L, Cheng P F, Xu S, Wang X H and Cheng F. 2013. Forest biomass estimation in Shangri-La based on the remote sensing. Journal of Zhejiang A and F University, 30(3): 325-329 (王金亮, 程鹏飞, 徐申, 王小花, 程峰. 2013. 基于遥感信息模型的香格里拉森林生物量估算. 浙江农林大学学报, 30(3): 325-329) [DOI: 10.11833/j.issn.2095-0756.2013.03.003]
- Wang S X, Zhang J L and Liao Y. 2021. Research progress in above-ground forest biomass estimation based on Landsat time series data. World Forestry Research, 34(6): 20-26 (王书贤, 张加龙, 廖易. 2021. 基于 Landsat 时间序列数据的森林地上生物量估测研究进展. 世界林业研究, 34(6): 20-26) [DOI: 10.13348/j.cnki.sjlyyj.2021.0046.y]
- Wang Z Y, Li X, Mao Y T, Li L, Wang X R and Lin Q. 2022. Dynamic simulation of land use change and assessment of carbon storage based on climate change scenarios at the city level: a case study of Bortala, China. Ecological Indicators, 134: 108499 [DOI: 10.1016/j.ecolind.2021.108499]
- WEISS A. Topographic position and landforms analysis. San Diego, CA: ESRI User Conference, 2001: 227-245.
- Woodcock C E, Allen R, Anderson M, Belward A, Bindschadler R, Cohen W, Gao F, Goward S N, Helder D, Helmer E, Nemani R, Oreopoulos L, Schott J, Thenkabail P S, Vermote E F, Vogelmann J, Wulder M A and Wynne R. 2008. Free access to Landsat imagery. Science, 320(5879): 1011 [DOI: 10.1126/science.320.5879.1011a]
- Wulder M A, White J C, Loveland T R, Woodcock C E, Belward A S, Cohen W B, Fosnight E A, Shaw J, Masek J G and Roy D P. 2016. The global Landsat archive: status, consolidation, and direction. Remote Sensing of Environment, 185: 271-283 [DOI: 10.1016/j.rse.2015.11.032]
- Xie F M. 2019. Estimating and Mapping Forest Aboveground Biomass Using a k-NN Model and Remote Sensing. Kunming: Southwest Forestry University (谢福明. 2019. 基于优化 k-NN 模型的森林地上生物量遥感估测反演. 昆明: 西南林业大学) [DOI: 10.27416/d.cnki.gxnlc.2019.000003]
- Xu L, Hou J, Chen Q L, Qin Y Q, Peng Y C and Huang G. 2022. A new adaptive median denoising model combined with cyclic iterative method. Journal of Sichuan University (Natural Science Edition), 59(4): 042002 (许黎, 侯杰, 陈庆利, 秦亚琦, 彭乙翠, 黄果. 2022. 结合循环迭代方法的自适应中值去噪新模型. 四川大学学报(自然科学版), 59(4): 042002) [DOI: 10.19907/j.0490-6756.

- 2022.042002]
- Xu Z Y, Sun B, Zhang W F, Gao Z H, Yue W, Wang H, Wu Z T and Teng S H. 2023. Is spectral unmixing model or nonlinear statistical model more suitable for shrub coverage estimation in shrub-encroached grasslands based on earth observation data? A case study in Xilingol Grassland, China. *Remote Sensing*, 15(23): 5488 [DOI: 10.3390/rs15235488]
- Yue C R. 2012. Forset Biomass Estimation in Shangri-La County Based on Remote Sensing. Beijing: Beijing Forestry University (岳彩荣. 2012. 香格里拉县森林生物量遥感估测研究. 北京: 北京林业大学)
- Zhang J L and Xu H. 2020. Establishment of remote sensing based model to estimate the aboveground biomass of *Pinus densata* for permanent sample plots from national forestry inventory. *Journal of Beijing Forestry University*, 42(7): 1-11 (张加龙, 胥辉. 2020. 基于遥感的高山松连清固定样地地上生物量估测模型构建. 北京林业大学学报, 42(7): 1-11) [DOI: 10.12171/j.1000-1522.20190394]
- Zhou R, Zhao T Z and Wu F Y. 2022. Aboveground biomass model based on Landsat 8 remote sensing images. *Journal of Northwest Forestry University*, 37(2): 186-192 (周蓉, 赵天忠, 吴发云. 2022. 基于 Landsat 8 遥感影像的地上生物量模型反演研究. 西北林学院学报, 37(2): 186-192) [DOI: 10.3969/j.issn.1001-7461.2022.02.26]
- Zhu Z. 2017. Change detection using landsat time series: a review of frequencies, preprocessing, algorithms, and applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130: 370-384 [DOI: 10.1016/j.isprsjprs.2017.06.013]

Estimation of *Pinus densata* carbon storage based on Landsat time series data and ATC filtering algorithm

TENG Chenkai¹, XIAO Yueyao², ZHANG Jialong¹, HE Yunrun¹, CHEN Chaoqing¹

1. College of Forestry, Southwest Forestry University, Kunming 650224, China;

2. College of Accounting, Southwest Forestry University, Kunming 650224, China

Abstract: Time-series remote sensing data have applications in the accurate estimation of forest carbon storage, providing data support for a deeper understanding of the carbon cycle process of forest ecosystems, scientific management, and protection of forest resources. However, considerable noise is present in remote sensing time-series data. To enhance the accuracy of estimating carbon storage, a filtering algorithm was developed to reduce the interference of noise in Landsat time-series data from high-altitude areas. The algorithm was developed based on the continuous inventory fixed plot data of the National Forest Inventory in the Shangri-La area for the years 1987, 1992, 1997, 2002, 2007, 2012, and 2017, and Landsat time-series images from 1987 to 2017. In this study, the Adaptive Topography Convolution (ATC) algorithm was developed using Python. This algorithm considers the effects of terrain factors on image quality, removes noise from the image while retaining as much details as possible, and uses Savitzky - Golay filtering and median filtering to filter Landsat time-series data. By using the random forest regression (RFR) algorithm, a carbon storage estimation model for *Pinus densata* in Shangri La City was constructed. The optimal estimation model was selected to invert and map the carbon storage of *P. densata* in 1987, 1992, 1997, 2002, 2007, 2012, and 2017. The results showed the following. (1) In accordance with the mean absolute error of the image quality evaluation index, image quality is best after filtering with the ATC algorithm. In addition, the peak signal-to-noise ratio value of the time-series data filtered by the ATC algorithm is relatively high, indicating an improvement in data quality. (2) When using the RFR algorithm, the filtered data showed higher fitting and prediction accuracy than the original data. (3) When using the RFR algorithm, the time-series data filtered based on the ATC algorithm exhibit the best estimation accuracy when selecting the top 10 feature factors with contribution and the feature factors with cumulative contribution reaching 70% for modeling. (4) The estimation model constructed based on the ATC-filtered time series and remote sensing features (number of features 10) and the random forest algorithm exhibits the best performance in research, with a determination coefficient (R^2) of 0.867, a root mean square error (RMSE) of 15.527/(t/hm²), a prediction accuracy (P) of 73.54%, and a relative RMSE (rRMSE) of 41.14%. 5) The carbon storage inversion results of Shangri La *Pinus densata* based on the optimal estimation model are as follows: 6.77 million tons (1987), 7.16 million tons (1992), 7.22 million tons (1997), 4.36 million tons (2002), 7.20 million tons (2007), 7.11 million tons (2012), and 7.53 million tons (2017). From the inversion results, the carbon storage of Shangri-La *P. densata* exhibited a gradually increasing trend during the period of 1987—1997. However, carbon storage exhibited a significant fluctuating trend from 2002 to 2017. The use of the ATC filtering method can effectively remove noise in the time-series images of high-altitude areas, reducing the uncertainty of time-series images and improving the accuracy of the remote sensing estimation of *P. densata* carbon storage.

Key words: Landsat time series, filter, *Pinus densata*, carbon storage, ATC

Supported by National Natural Science Foundation of China (No. 32260390, 31860207); 2020 Yunnan Provincial High-level Talent Cultivation Support Programme “Young Top Talents” Special Programme (No. YNWR-QNBJ-2020-164)