中国科学: 地球科学 2025 年 第 55 卷 第 3 期: 860 ~ 873
SCIENTIA SINICA Terrae earthcn.scichina.com
《中国科学》杂志社 SCIENCE CHINA PRESS
论 文

基于遥感解译、野外观测与模型模拟的云南省植被制图

夏侯明健[1†], 彭明春[2†], 沈泽昊[1,2*], 温庆忠[3], 王崇云[2], 刘彦男[2], 张秋媛[2], 彭磊[2], 余昌元[3], 欧晓昆[2], 方精云[1]

1. 北京大学城市与环境学院, 教育部地表过程分析与模拟重点实验室, 北京 100871
2. 云南大学生态与环境学院, 昆明 650504
3. 云南省森林资源调查规划院, 昆明 650051
* 通讯作者, E-mail: shzh@urban.pku.edu.cn
† 同等贡献

收稿日期: 2024-05-27; 收修改稿日期: 2024-11-25; 接受日期: 2025-01-03; 网络版发表日期: 2025-02-14
云南省基础研究重大专项项目(202101BC070002)和第二次青藏高原综合科学考察研究项目(2019QZKK04020101)资助

摘要 植被图为生态学家和决策者提供了直观的植被类型及分布信息, 在复杂生态系统的研究与管理中发挥着关键作用. 近年来, 随着地球观测技术和机器学习算法的快速发展, 绘制大尺度、高精度植被图的数据资源和技术能力得到显著提升. 然而, 在环境异质性强且人为干扰频繁的生物多样性热点地区, 绘制准确详细的植被图仍面临诸多挑战, 地面数据不足和复杂的植被气候关系是制约制图精度的主要因素. 本研究以中国最重要的生物多样性热点地区——云南省为研究区域, 构建了基于多源数据融合的植被制图框架. 框架主要包括以下四个部分: (1) 利用随机森林算法和Landsat影像初步区分植被类型; (2) 建立静态植被气候关系模型以确定植被类型边界; (3) 使用多种独立的森林资源调查数据修正特定类型的植被斑块分布; (4) 结合大量、广泛分布的植物群落调查数据验证植被图的准确性. 基于群落优势种的生长型组成, 绘制了云南省17个植被类型和44个亚型的空间分布图(比例尺1:50000). 经评估, 自然植被型和亚型的总体精度分别为0.747和0.710, 人工植被型和亚型的总体精度分别为0.905和0.891. 此图空间分辨率高、分类系统详细且准确性高, 它不仅深化了我们对生物多样性热点地区植被分布格局和生态复杂性的认识, 也为区域植被保护与可持续管理政策的制定提供了重要的科学参考.

关键词 植被制图, 生物多样性热点地区, 多源数据, 数据融合框架, 生态系统多样性

1 引言

从局地到全球尺度, 植被图提供了关于生态系统和土地利用的空间分布信息(Franklin, 1995; Pedrotti, 2012). 精准的植被图不仅为生态地理学研究奠定了重要基础, 而且为植被保护、生态恢复和可持续管理政策的制定提供了科学依据(van der Maarel和Franklin, 2012; Liu等, 2020). 然而, 大尺度植被制图及更新的

中文引用格式: 夏侯明健, 彭明春, 沈泽昊, 温庆忠, 王崇云, 刘彦男, 张秋媛, 彭磊, 余昌元, 欧晓昆, 方精云. 2025. 基于遥感解译、野外观测与模型模拟的云南省植被制图. 中国科学: 地球科学, 55(3): 860–873, doi: 10.1360/N072024-0156
英文引用格式: Xiahou M, Peng M, Shen Z, Wen Q, Wang C, Liu Y, Zhang Q, Peng L, Yu C, Ou X, Fang J. 2025. Vegetation mapping of Yunnan Province by integrating remote sensing, field observations, and models. Science China Earth Sciences, 68(3): 836–849, https://doi.org/10.1007/s11430-024-1509-3

© 2025 《中国科学》杂志社

时间和资金成本十分高昂. 传统制图方法主要依赖专家知识, 通过在等高线地形图或航空照片上手动绘制植被斑块边界来确定植被类型(Kuchler和Zonneveld, 1967; Roberts和Cooper, 1989). 随着全球气候变化和人类活动影响的加剧, 自然和人工植被的变化速度显著提升, 进一步增加了植被制图的复杂性和不确定性(Gottfried等, 2012; Fagan等, 2018; Chen等, 2019). 在此背景下, 传统植被图不仅难以准确反映植被分布现状, 更无法及时追踪其动态变化.

地球观测技术与机器学习算法的快速发展使大尺度植被制图和植被动态监测成为可能(Xie等, 2008; Adam等, 2010; Gašparović和Dobrinić, 2020; Del Valle和Jiang, 2022). 遥感数据能全球覆盖且免费获取, 显著降低了制图的时间和资金成本(Tong等, 2023). 其中, 光学卫星提供了植物反射率、纹理和物候特征等光谱信息, 为精确的植被分类奠定了坚实基础(Tuanmu等, 2010; Verrelst等, 2015; Madonsela等, 2017). 合成孔径雷达(SAR)(Grimaldi等, 2020)、激光雷达(LiDAR)(Liang等, 2020)和无人机(de Castro等, 2021)等数据也在植被分类中得到了广泛的应用. 机器学习算法通过深入挖掘地表反射率与土地覆盖类型之间的关系, 为现代植被制图提供了强有力的技术支持. 目前常用的算法包括深度学习(Ienco等, 2019)、神经网络(Flood等, 2019)、决策树(Tsai等, 2018)、支持向量机和随机森林等. 其中, 随机森林算法在处理高维数据和多重共线性方面表现优异, 被广泛应用到植被分类工作中(van Beijma等, 2014; Belgiu和Drăguţ, 2016). 支持向量机则在样本量有限的情况下表现出色, 这对于野外数据获取困难的地区尤为重要(Mountrakis等, 2011; Shao和Lunetta, 2012). 相比之下, 深度学习算法对高分辨率遥感影像和充足地面观测样本的依赖性较强, 在一定程度上限制了其在大尺度植被制图中的应用(Kattenborn等, 2021).

土地利用和土地覆被(LULC)图是精细植被制图的基础(Hansen和Loveland, 2012). 然而, 现有的LULC图分类系统往往过于简化, 难以提供植被型及亚型层级的详细信息(Homer等, 2015). 目前, 不同尺度和区域的植被图已取得显著进展. 在大陆或国家尺度上, Su等(2020)利用MODIS影像更新了中国植被图; Roy等(2015)基于IRS LISS-III数据绘制了印度植被类型图; Raynolds等(2019)则结合遥感影像与传统植被图(Walker等, 2005)更新了环北极地区植被分布图. 在区域尺度上, Preidl等(2020)基于Sentinel-2数据将德国农业区划分为19种土地覆盖类型; Erinjery等(2018)在热带雨林地区采用最大似然法和随机森林方法实现了不同植被类型的精细制图.

尽管遥感技术和机器学习方法不断进步, 但在环境异质性强、生物多样性高且人为干扰频繁的地区, 绘制分类详细、空间分辨率高且准确度高的植被图仍面临诸多挑战(Erinjery等, 2018; Räsänen和Virtanen, 2019; Wagner等, 2019). 具体而言, 植被制图的难点主要包括: 地面数据不足、数据源单一、复杂的植被气候关系、次生植被的识别以及动态的农业生态系统. 首先, 数量有限且分布不均的野外采样点常常制约机器学习算法在植被分类中的准确性和稳健性(Treitz等, 1992). 其次, 由于多种植被类型常具有相似的外貌和物候特征, 单一数据源难以支持生物多样性热点区域的详细分类(Bioucas-Dias等, 2013; Tsai等, 2018). 再次, 干扰或造林后的次生植被类型往往复杂多变, 难以准确辨别(Carreiras等, 2017; Chen等, 2020). 此外, 农业生态系统的分布对生态管理至关重要, 但当前的植被图往往未能充分体现(Senf等, 2013).

云南省地处中国西南部, 是全球36个生物多样性热点中的两个——东喜马拉雅和中国西南山地——的交汇区域(Myers等, 2000). 精准的植被图对该地区的生物多样性保护和生态系统管理具有重要价值(Li等, 2015). 然而, 复杂的地形、多样的生态系统和日益增加的人为干扰使该地区的植被制图面临诸多挑战(Ye等, 2020). 云南省现有植被图绘制于20世纪80年代, 是基于等高线地形图、专家知识和广泛野外调查的传统植被图(吴征镒和朱彦丞, 1987); 但其空间分辨率较低, 难以展现植被分布的细节, 且精度尚未经过系统评估. 同时, 近年来云南省的植被分布已发生显著变化(Zomer等, 2015; Shi和Chen, 2018; Sun等, 2021). 因此, 迫切需要绘制分辨率更高、分类更细致、精度更高的新一代云南植被图, 以准确反映当前植被状况.

本研究旨在绘制云南省植被类型空间分布图, 并揭示该地区生态系统的复杂性和多样性. 研究将整合遥感数据、野外观测数据、森林资源调查数据、环境因子和专家知识, 开展以下工作: (1) 构建基于数据融合的制图框架, 利用多源数据在生物多样性热点地区绘制植被分布图并验证; (2) 提供一张准确、详细、

高分辨率的云南植被图; (3) 分析云南植被的空间分布格局, 为植被保护、生态恢复和可持续管理政策的制定提供科学依据.

2 方法

2.1 研究区

云南省是东亚、东南亚和青藏高原三大地理区域的过渡地带, 其独特的地理位置造就了丰富多样的生态系统(图1). 从寒冷潮湿的高山到炎热干燥的河谷, 显著的区域气候差异为动植物提供了丰富多样的栖息环境(Wang等, 2018). 具体而言, 云南南部受湿润季风影响, 发育有热带雨林和常绿阔叶林, 为众多热带物种提供了理想的栖息地; 中部地区受人类活动影响较大, 以次生植被和人工植被为主; 东部喀斯特地貌则形成了独具特色的丘陵植被分布格局.

2.2 分类系统

本研究基于《云南省生态系统名录》(高正文等, 2021)和《云南植被》(吴征镒和朱彦丞, 1987)的分类体系, 结合实地观测结果优化调整了植被分类系统. 最终构建的分类系统包含17个植被型和44个亚型, 其中自然植被亚型32个、人工植被亚型9个、非植被亚型3个(网络版附表S1, https://earthcn.scichina.com/).

2.3 数据来源

2.3.1 遥感数据

从USGS Earth Explorer(https://earthexplorer.usgs.gov/)获取了2018~2020年Landsat 8 OLI collection-2 Tier-1 level-2地表反射影像(空间分辨率30m). 在去除云层和阴影干扰后, 将影像按春季(3~5月)、夏季(6~8月)和秋季(9~11月)划分. 采用中值法生成6个波段(2-蓝、3-绿、4-红、5-近红外、6-短波红外1和7-短波红外2)的季节性合成影像, 并计算了各季节的NDVI和EVI植被指数. 此外, 还利用分辨率小于1m的Google Earth 19级影像进行植被类型的目视解译, 并基于ASTER全球数字高程模型(分辨率30m)提取了海拔、坡度、坡向和粗糙度四个地形因子.

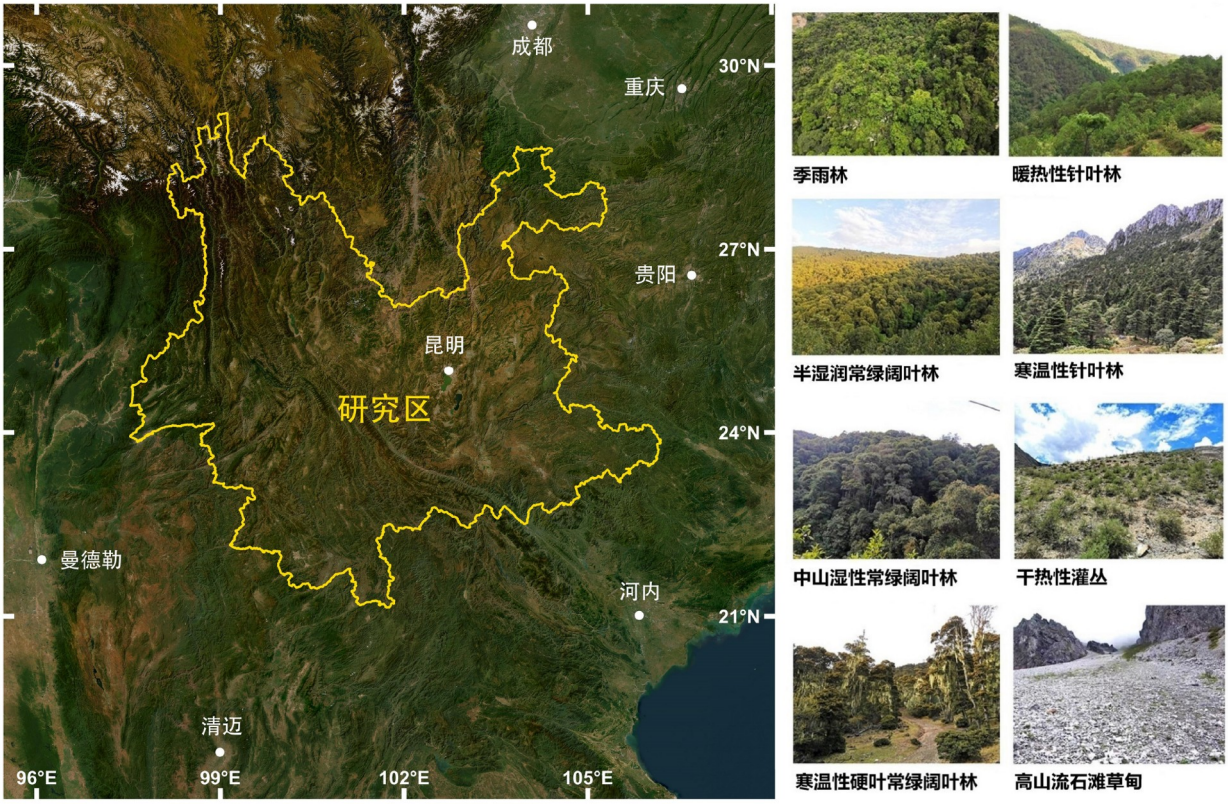

图 1 研究区域及云南主要植被类型外貌

2.3.2　野外数据

2018~2020年间, 研究团队在云南省范围内系统采集了超过20000个野外样点和5000个样方数据. 经过严格筛选, 最终确定15066个样点、2052个自然植被样方和588个人工植被样方用于研究(图2). 15066个样点均匀分布于云南全境, 覆盖了分类系统中的全部44个植被类型, 样方则涵盖了28个自然植被类型和9个人工植被类型, 为植被图的验证提供了可靠依据. 此外, 研究还整合了2010~2020年间云南省森林资源调查规划院的调查数据, 包括原始森林和人工林的分布信息(图2). 其中, 原始植被斑块是指保持自然结构和功能、未受显著人类活动干扰的古老植被, 其识别和调查方法详见陶晶等(2016); 人工植被斑块则包括持续管理的种植园(如橡胶、桉树种植园)和果园(如茶园、果园), 这些数据均来自云南省造林计划, 记录了植被分布范围及主要物种信息.

2.3.3　环境因子和潜在自然植被图(PNV)

基于月度气候数据和综合序列分类系统(CSCS)(任继周等, 1980; Liang等, 2012), 研究构建了云南省潜在自然植被(PNV)分布图. 利用云南及周边184个气象站的数据, 以数字高程模型数据作为协变量, 通过ANUSPLIN 4.4的薄板光滑样条插值方法, 获得了月均温(MAT, ℃)和月降水(MAP, cm)数据(Hutchinson, 1995). 根据0℃以上的累积温度(GDD0)和湿润度(K), CSCS模型将云南划分为17个潜在自然植被类型, 为确定植被类型及亚型的气候边界提供了科学依据. 研究还结合文献中1930个野外样点数据, 总结了云南23座山脉

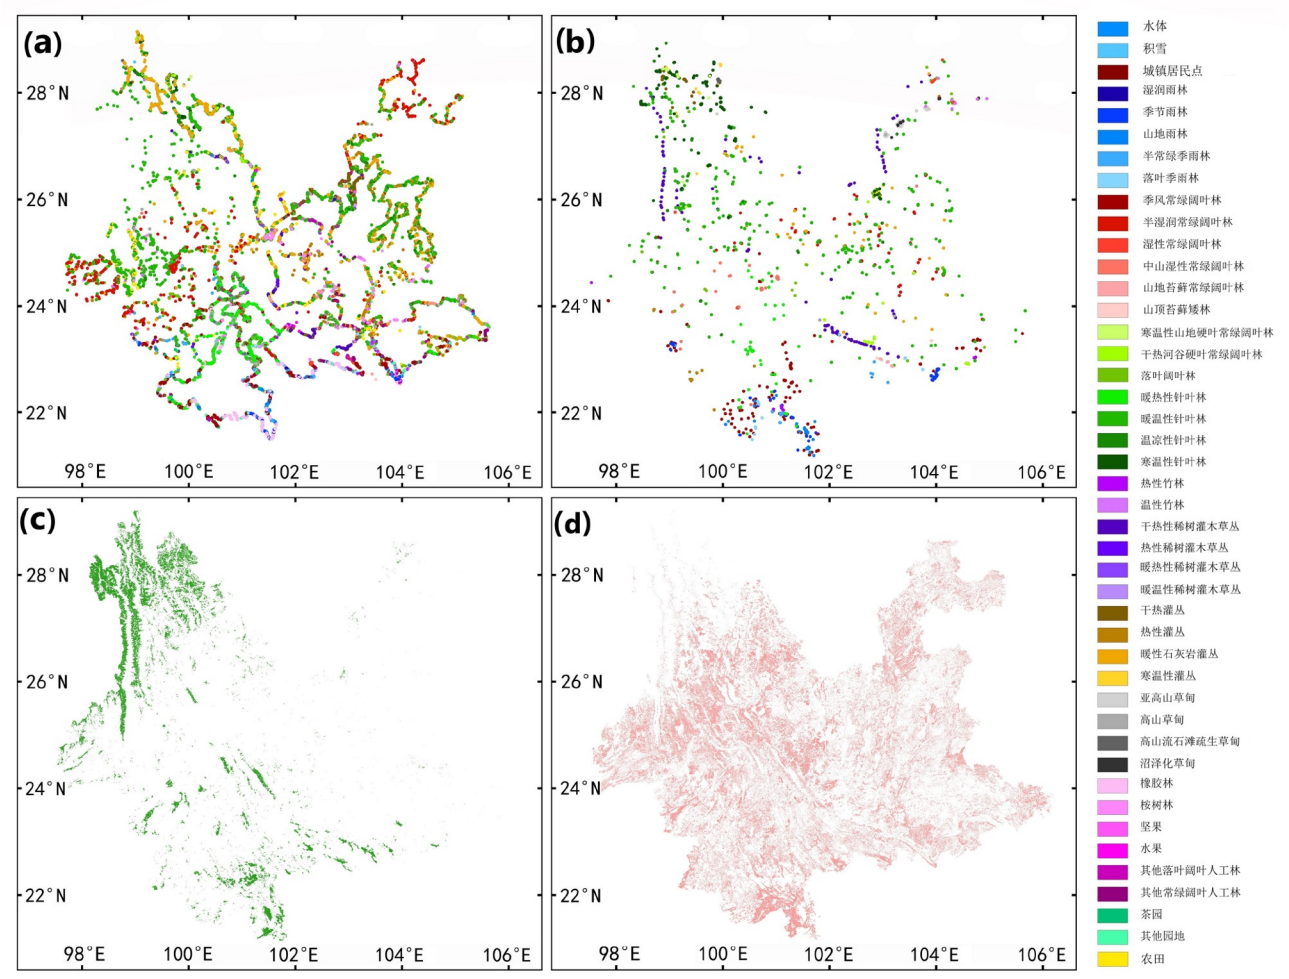

图 2　**15066个野外样点(a)、2052个自然植被样方(b)、原始植被斑块(c)和人工植被斑块(d)的空间分布**

上16种PNV类型的海拔和气候边界，进一步细化了每种PNV类型的热量(GDD0)和湿润度(K)阈值．有关CSCS模型和潜在自然植被图的详细信息，可参见Xiahou等(2024).

2.4 数据处理和验证

基于数据融合制图框架，研究利用多源数据绘制并验证了云南省植被类型的空间分布(图3)．制图框架包括以下四个主要步骤：(1) 基于Landsat影像和随机森林算法初步区分植被类型；(2) 基于静态植被气候模型校正边界；(3) 使用森林资源调查数据修正斑块；(4) 利用野外调查数据验证准确性.

2.4.1 植被分类

为优化分类方法，研究比较了随机森林、支持向量机和深度学习三种常用算法．将15066个样点随机分为训练集(70%)和测试集(30%)，通过评估模型性能发现，随机森林算法具有最高的分类精度，因此被选为云南植被分类的最终方法，训练数据为经过筛选的15066个野外样点.

2.4.2 边界校准

本研究通过潜在植被图调整了地带性植被类型的气候边界．潜在植被图结合了气候因子和地带性植被的环境范围，是理想的参考依据．通过对比每种植被类型的潜在分布和实际分布，将超出潜在分布区域的斑块调整为对应的潜在植被类型，从而更精准地区分外观和光谱特征相似但分布不同的植被类型．这一方法对于区分分布在不同气候和地理区域但具有相似特征的植被类型具有重要意义.

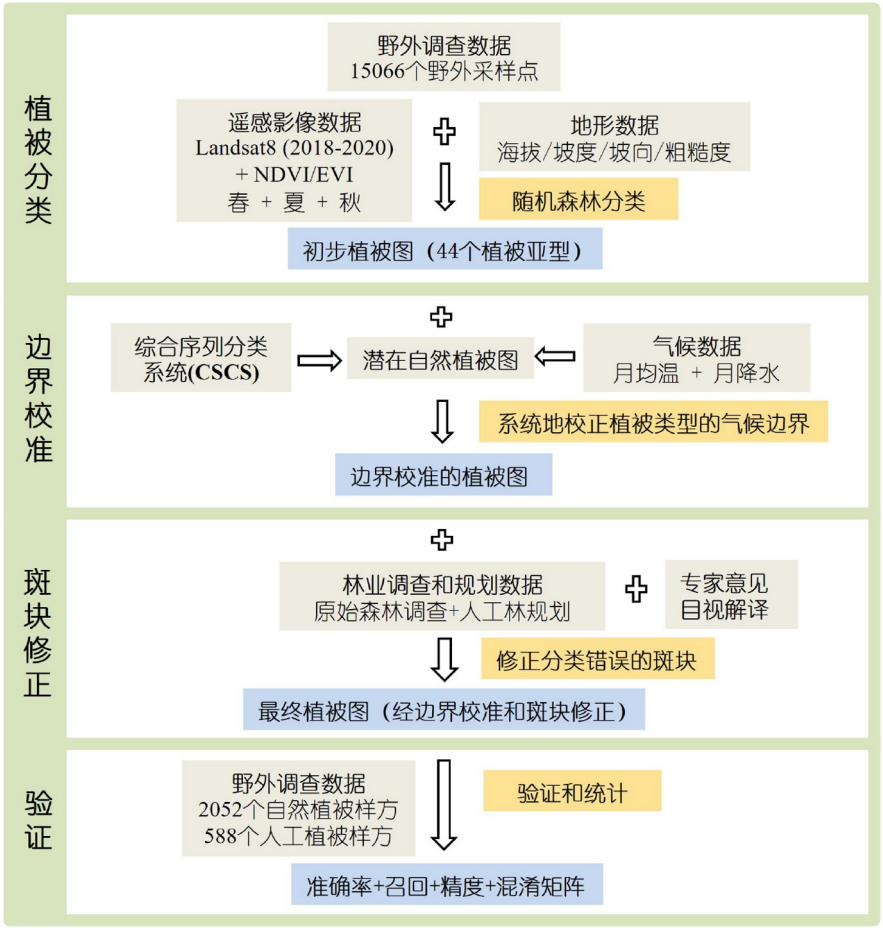

图 3　基于多源数据的植被制图流程

2.4.3　斑块修正

结合森林资源调查数据，修正了原始和人工植被斑块. 在遥感数据与调查数据不匹配的区域，根据调查数据调整植被类型. 这是因为遥感技术难以精准识别具体森林类型，而调查数据通过可靠的野外观测获得. 此外, 在手动检查过程中引入专家意见, 特别是针对复杂生态系统(如热带/亚热带区域)的过渡性和非典型植被类型. 为优化地图展示效果，将面积小于5hm^{2}的斑块合并至相邻较大斑块，因为这类小斑块在野外分布不稳定且较为罕见.

2.4.4　精度验证

利用2052个自然植被样方和588个人工植被样方评估了云南植被图的准确性. 这些样方提供了详细的群落信息, 用于计算总体准确率、分类精度和召回率. 其中，总体准确率为正确分类样方数量占总样方数的比例；分类精度指某植被类型的正确分类样方数量占预测为该类型总数的比例；召回率为某植被类型正确分类样方数量占实际该类型总数的比例. 所有数据处理工作均通过QGIS 3.16、R 4.0、Google Earth Engine和ANUSPLIN 4.4等软件完成.

3　结果

3.1　基于地面数据校正的植被图

随机森林、支持向量机和深度学习的总体分类精度分别为0.518、0.458和0.371，其中随机森林算法表现最优. 考虑到云南省植被类型多样(44种)、区域特征复杂以及野外调查数据有限，随机森林和支持向量机的分类精度已达到可接受水平. 由于许多植被类型在光谱和地形特征上具有相似性，在植被亚型层级实现精确分类存在较大难度，但在植被类型或植被群组层级的分类是可行的，这为后续的边界校准和斑块修正奠定了基础. 经统计，云南省48.41%(179117km^2)的区域经过边界校准和斑块修正. 其中，25.54%(94498km^2)的区域基于原始和人工植被的野外调查数据修正了植被类型，对地图改进贡献最大；14.37%(53169km^2)的区域主要依据PNV地图在亚型层级进行校准；其余8.5%(31450km^2)则结合专家建议和人工检查调整植被类型, 主要针对特殊植被类型和特定区域.

3.2　云南省植被类型的空间分布

云南省面积最大的植被类型是暖温性针叶林(以云南松*Pinus yunnanensis*为主), 覆盖约103108km^2, 广泛分布于全省, 从南部亚热带地区延伸至西北山区, 并在滇中高原广泛存在(图4a). 滇中高原的另一主要自然植被类型是半湿润常绿阔叶林(4191km^2), 但因频繁的人类活动和火扰动，大部分已退化. 农田覆盖约82448km^2，是云南第二大植被类型，主要分布在山间盆地和缓坡地区，突显农业的广泛影响. 云南南部山区分布有三种亚热带植被类型: 热性/暖热性山地灌丛(33113km^2)、暖热性针叶林(17626km^2)和季风常绿阔叶林(17023km^2). 在西北部，温凉性针叶林(12182km^2, 以华山松*Pinus armandii*为主)、寒温性针叶林(13749km^2，以云杉*Picea*和冷杉*Abies*为主)、温带山地灌丛(5451km^2)和高山草甸(5734km^2)共同构成横断山脉中上坡的垂直植被梯度. 南部山区的中山湿性常绿阔叶林(6390km^2)和山地苔藓常绿阔叶林(1533km^2)是温暖湿润地区的重要自然植被类型. 雨林面积约3029km^2, 以密集多样的植物群落为特征, 集中分布于湿润的热带河谷. 落叶季雨林(1178km^2)和半常绿季雨林(1652km^2)在受季风气候影响的宽谷中较为普遍. 干热河谷稀树灌木草丛(5130km^2)是夏季风垂直深谷中特有的植被类型. 在人工林中, 面积最大的是坚果种植园, 约11836km^2; 其次是橡胶种植园(9706km^2), 主要分布于南部热带地区.

斑块面积反映了不同植被类型的破碎化程度. 自然植被中，斑块面积最大的是寒温性针叶林、湿性常绿阔叶林和高山草甸三种高山类型(图4b). 相比之下, 低海拔植被类型如落叶阔叶林和湿润雨林，其斑块面积较小. 人工植被中，橡胶种植园和农田的斑块面积较大, 超过其他种植园和果园. 在环境范围方面, 大多数植被类型偏好适中气候(约15℃气温、80cm降水量), 如暖温性针叶林和农田(图4c). 热带植被类型如雨林和橡胶种植园分布于最炎热、最湿润的区域. 常绿阔叶林也生长在降水量高的地区，但偏好比雨林更凉爽的温度. 高山区域则以耐寒植被为主，包括草甸、温带山地灌丛和寒温性针叶林.

3.3　精度评估

自然植被类型和亚型的总体精度分别为0.747和

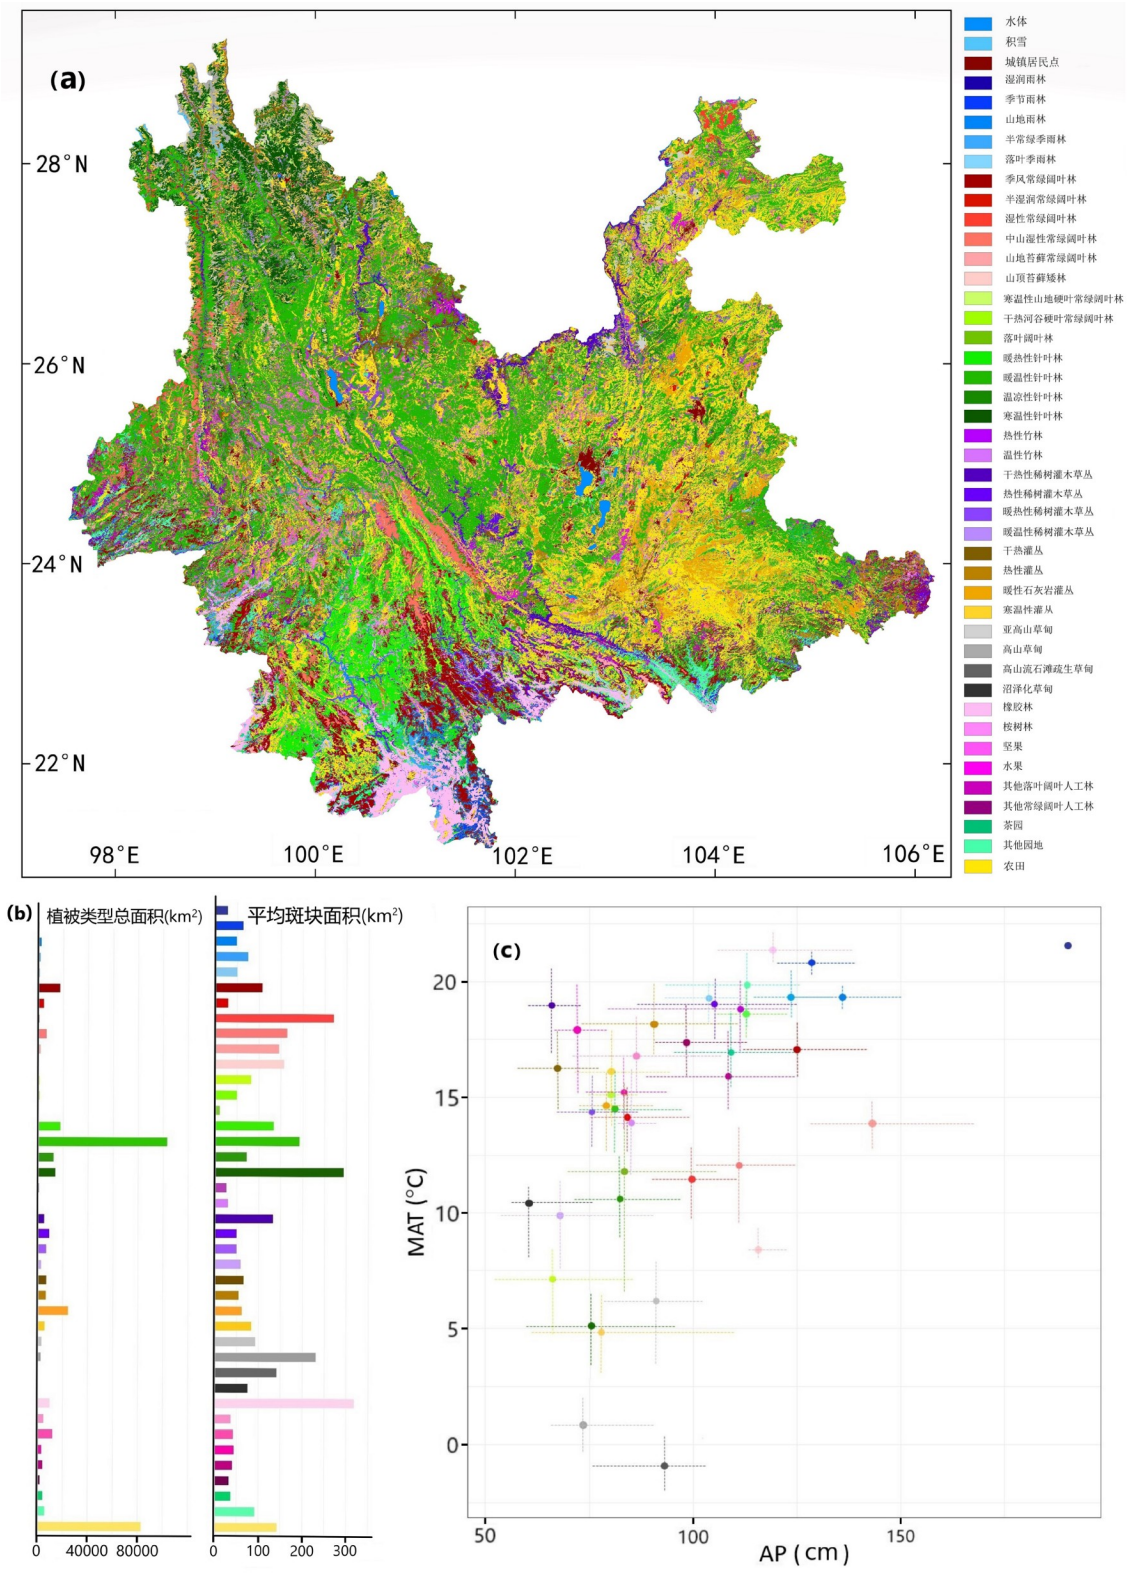

图 4　校正后的云南植被空间分布图(44个植被亚型)(a)、植被亚型的总面积及斑块面积(b)、植被亚型在年均温度(MAT)和年降水量(AP)上的分布范围(c)

0.710(表1; 网络版附表S2), 而人工植被类型和亚型的总体精度分别为0.905和0.891(表2; 网络版附表S3). 整体上, 人工植被类型的精度显著高于自然植被类型. 地带性植被类型在植被图中的分类精度较高, 优于破碎化和次生植被类型. 在自然植被类型中, 高山草甸、干热性灌丛和干热河谷稀树灌木草丛的分类精度最高(超过0.8). 大多数常绿阔叶林和针叶林的精度超过0.7, 高于其他类型的平均水平. 雨林的分类精度约为0.6, 尽管低于平均值, 但考虑到雨林分布的制图难度, 这一结果仍在可接受范围内. 破碎化和次生植被类型(如硬叶常绿阔叶林、落叶阔叶林和竹林)的分类精度则低于预期.

3.4　植被图细节

选取云南省五个30km×30km的样本来展示最终植被图的细节, 并与修改前的初步植被图和20世纪80年代的植被图进行比较. 总体来看, 经过校准和斑块修正后的最终地图比其他两张地图更为精细(图5). 在

表 1　自然植被类型和亚型的召回和精度

植被类型	数量	召回率	分类精度	植被亚型	数量	召回率	分类精度
雨林	110	0.71	0.83	季节雨林	71	0.61	0.74
				山地雨林	39	0.59	0.64
季雨林	34	0.59	0.38	半常绿季雨林	19	0.53	0.30
				落叶季雨林	15	0.47	0.37
常绿阔叶林	412	0.76	0.83	季风常绿阔叶林	179	0.71	0.82
				半湿润常绿阔叶林	137	0.75	0.83
				湿性常绿阔叶林	15	0.60	0.47
				中山湿性常绿阔叶林	56	0.73	0.71
				山地苔藓常绿阔叶林	16	0.69	0.85
				山顶苔藓矮林	8	0.75	1.00
硬叶常绿阔叶林	59	0.53	0.76	寒温性山地硬叶常绿阔叶林	21	0.54	0.73
				干热河谷硬叶常绿阔叶林	35	0.51	0.78
落叶阔叶林	56	0.10	0.63	落叶阔叶林	56	0.10	0.63
暖性针叶林	474	0.74	0.74	暖热性针叶林	48	0.65	0.69
				暖温性针叶林	426	0.75	0.74
温性针叶林	350	0.83	0.93	温凉性针叶林	96	0.71	0.70
				寒温性针叶林	253	0.76	0.90
竹林	22	0.41	0.69	热性竹林	15	0.40	0.75
				温性竹林	7	0.43	0.60
稀树灌木草丛	138	0.83	0.74	干热性稀树灌木草丛	140	0.80	0.95
灌丛	167	0.69	0.60	干热灌丛	30	0.69	0.66
				热性灌丛	35	0.51	0.78
				暖性灌丛	39	0.67	0.51
				温性灌丛	57	0.72	0.51
草甸	235	0.88	0.88	亚高山草甸	172	0.87	0.86
				高山草甸	14	0.76	0.43
				高山流石滩疏生草甸	14	0.79	1.00
				沼泽化草甸	27	0.52	0.82
总体准确率		0.747		总体准确率		0.710	

表 2　人工植被类型和亚型的召回和精度

植被类型	数量	召回率	分类精度	植被亚型	数量	召回率	分类精度
农田	249	0.91	0.99	农田	249	0.91	0.99
人工林	237	0.89	0.94	橡胶林	39	0.92	0.97
				桉树林	43	0.93	0.95
				坚果林	29	0.79	0.85
				水果林	21	0.95	0.76
				其他落叶阔叶人工林	29	0.82	0.92
				其他常绿阔叶人工林	76	0.86	0.91
园地	102	0.86	0.92	茶园	48	0.89	0.93
				其他园地	54	0.81	0.89
总体准确率		0.905		总体准确率		0.891	

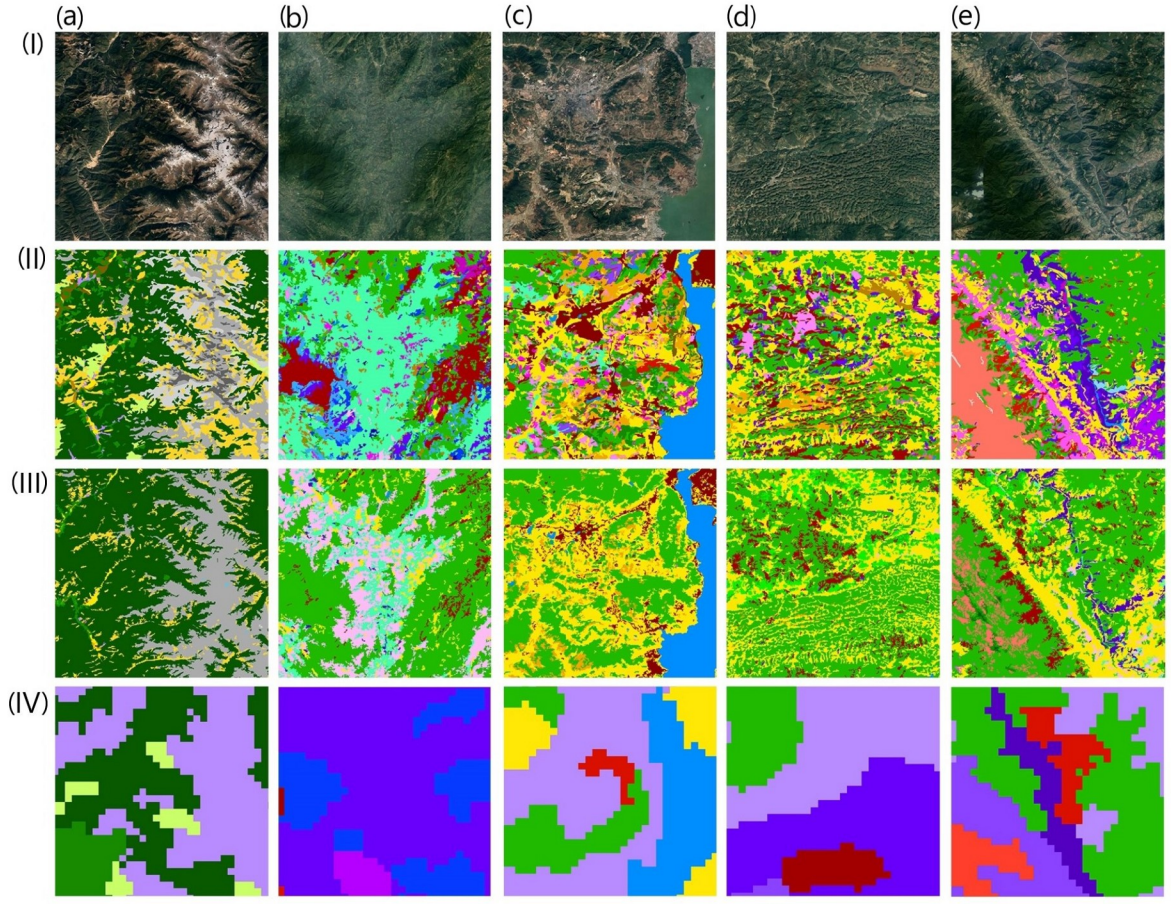

图 5　云南五个区域的植被图细节对比

I, Google Earth影像; II, 修正后植被图; III, 初步植被图; IV, 20世纪80年代《云南植被》中的植被图. 植被类型的颜色与图4相同. (a)~(e) 五个区域的位置见网络版附图S2

高山区域, 地图将草甸和针叶林细化为更具体的类型, 同时识别了更多亚高山灌丛和硬叶常绿阔叶林. 在热带地区, 最终的植被图更准确地描绘了种植园和果园的分布. 在城市周边, 地图区分了不同的人工土地利

用类型, 并修正了错误分类的斑块. 此外, 最终的植被图还重点改进了喀斯特山地和干热河谷的植被类型描绘.

4　讨论

4.1　云南植被图的精度评估

本研究为生物多样性热点地区的植被制图与验证构建了一个实用框架. 自然植被类型和亚型的总体精度分别为0.747和0.710, 人工植被类型和亚型的精度分别为0.905和0.891. 整体上, 植被图的精度与空间分辨率、分类系统和研究区域密切相关, 同时还受到数据来源和制图方法的显著影响(Xie等, 2008; Räsänen和Virtanen, 2019). 我们试图在空间分辨率、分类系统、制图精度和效率之间找到一个平衡的方法, 以全面反映云南多样的植被类型和复杂的生态系统的空间分布.

在大陆尺度上, 植被图的分类系统通常较为全面, 但空间分辨率较低. 由于覆盖范围广、环境异质性高且植被类型复杂, 这些植被图的精度往往低于本研究(Roy等, 2015; Raynolds等, 2019). 例如, 新一代中国植被图在植被型组层级的总体精度为64.8%, 在植被类型/亚型层级的精度为61%(Su等, 2020). 在区域尺度上, 许多研究生成了高分辨率、高精度的植被图. 例如, 雨林和热带种植园的分布制图精度达75%(Erinjery等, 2018); 萨赫勒地区土地利用图的精度为72%±3.9%(Schulz等, 2021); 西澳大利亚24种植被类型的分类精度为74%(Macintyre等, 2020). 然而, 由于分类系统较简单且制图范围有限, 这些地图的应用常受限制(Li等, 2020; Lopes等, 2020). 在国家和省级尺度上, 植被图的精度主要取决于研究区内植被和环境的复杂性. 环境同质性高、生物多样性较低的地区通常具有更高的精度, 而环境复杂、生物多样性高的地区精度较低(Zhang等, 2019; Ghorbanian等, 2020; Liu等, 2020; Preidl等, 2020).

4.2　基于数据融合的制图方法的优势与不足

得益于多源数据和数据融合的制图方法(Del Valle和Jiang, 2022), 我们的植被图具有相对较高的精度, 准确描述了云南复杂多样的植被群落(Ran等, 2012; Zhang和Xie, 2014; Yao等, 2020). 本研究解决了多种植被类型光谱特征相似的问题, 弥补了单纯依赖遥感数据的制图方法的不足. 即使在高质量遥感影像和先进分类算法支持下, 充足的地面数据仍是保障植被制图精度的关键. 本研究的随机森林算法的训练数据包括覆盖整个研究区域的15066个野外样点, 数据量远超大多数植被图, 为算法的稳健性和分类准确性提供了有力支撑(Lopes等, 2020; Wu等, 2021).

森林调查数据在植被图的斑块修正中发挥了关键作用, 它帮助我们区分了几种森林亚型(如原生林与次生林、天然林与种植林), 并识别了果园(如茶园、水果园、坚果园)和种植园(如橡胶、桉树种植园)中的树种. 这些信息对植被保护和可持续管理至关重要, 但以往的植被图往往忽视了这些细节(Trisasongko和Paull, 2020; Azizan等, 2021). 此外, 通过CSCS模型和潜在植被图, 系统地模拟了云南植被分布与气候条件的复杂关系(Biermann, 2007; Ni和Herzschuh, 2011; Zhu等, 2016; Fan和Bai, 2021). 综合考虑了累积温度、湿度指数及其相互作用, 并结合地带性植被类型分布的经验知识(Liang等, 2012; Du等, 2022), 调整了不同植被类型的气候阈值, 为确定地带性植被类型的气候边界提供了可靠的参考.

然而, 我们也发现一些植被类型的分类精度仍需提升, 特别是过渡性、次生、破碎化和零散分布的植被类型. 例如, 季雨林等过渡性和非典型植被难以通过遥感影像和植被气候模型准确识别其关键特征, 需要更多植物分类和植物区系的专业知识来提升精度. 次生植被类型(如稀树灌木草丛)因受频繁自然或人为干扰的影响, 外观和分布具有较大的变异性, 对野外数据的数量和质量提出了更高要求. 而对于零散分布的植被类型(如落叶阔叶林和竹林), 未来需要更有针对性的野外调查以提高分类精度.

4.3　云南植被分布与生物多样性保护

本研究通过植被分布揭示了云南的环境异质性、生态复杂性和生物多样性. 云南的气候跨度大, 涵盖了从温暖(年均温度>25℃)到寒冷(年均温度<−5℃)、从湿润(年降水量>2000mm)到干旱(年降水量<500mm)的自然环境, 孕育了丰富的植被类型与高生物多样性. 在水平梯度上, 南低北高的地形造就了显著的气候和植被分带. 南部以雨林、季雨林和季风常绿阔叶林为

主; 滇中高原分布有半湿润常绿阔叶林和中温性针叶林; 西北山区则以寒温性针叶林为主. 垂直梯度上, 复杂的地形(山脉与山谷相间)形成了明显的山地植被分带. 在南部, 植被从河谷的湿润雨林逐渐过渡到山地雨林、季风常绿阔叶林、中山湿润常绿阔叶林、山地苔藓常绿阔叶林及苔藓矮林; 在西北部, 植被从干热河谷的稀树灌木草丛向温性针叶林、山地灌丛、高山草甸依次演替. 此外, 西南季风和东南季风的共同作用使云南植被呈现过渡特征. 西南季风影响南部区域, 使其植被与中南半岛相似; 东南季风则影响东部区域, 使其植被更接近华南季风区的特点.

我们的植被图揭示了生物多样性保护和生态系统管理中需要优先关注的区域和植被类型. 首先, 应重点保护面积小、破碎化严重且受干扰频繁的植被类型, 如雨林和季雨林. 这些类型易受气候变化和人类活动的威胁, 一旦破坏, 恢复难度极大(Taubert等, 2018; Liu等, 2019). 其次, 次生植被类型通常是自然森林破坏后短期恢复的过渡阶段. 通过减少人为干扰并加强保护, 这些植被有望逐步演替为更高级的植物群落, 进而影响生态系统服务和碳循环(Wang等, 2017; Zeng等, 2019). 此外, 具有顶级群落结构的自然植被类型为动植物提供了关键的栖息地和避难所(Verrall和Pickering, 2020), 也应重点保护.

5 结论

本研究绘制了云南省植被类型的空间分布图(1:50000), 揭示了生态系统的复杂性和多样性. 采用多源数据, 构建了基于数据融合的制图方法, 以应对生物多样性热点地区大尺度遥感植被制图的挑战. 具体而言, 利用充足的地面观测数据为随机森林分类器提供可靠的训练数据, 并为地图验证提供支持; 模拟了气候与植被的关系, 系统修正了植被类型的气候边界; 引入独立的原始森林调查数据, 细化森林亚型划分; 利用人工林调查规划数据绘制了人工生态系统分布. 最终, 本研究绘制并验证了云南省17种植被类型和44个亚型的空间分布. 自然植被型和亚型的总体精度分别为0.747和0.710, 人工植被型和亚型的总体精度分别为0.905和0.891. 此地图空间分辨率高(30m), 为生态系统研究、生物多样性保护和可持续管理提供了丰富而精确的空间信息.

致谢 感谢杨涛、左艳洁、蒙薇、李富利、段江华、任丽娜、苏秀丽和康娅在野外调查中的贡献.

参考文献

高正文, 孙航, 欧晓昆. 2021. 云南省生态系统名录. 昆明: 云南科技出版社

任继周, 胡自治, 牟新待, 张普金. 1980. 草原的综合顺序分类法及其草原发生学意义. 中国草原, (1): 12–24

陶晶, 温庆忠, 华朝朗. 2016. 原始林研究现状与展望. 林业调查规划, (2): 38–42

吴征镒, 朱彦丞. 1987. 云南植被. 北京: 科学出版社

Adam E, Mutanga O, Rugege D. 2010. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: A review. Wetlands Ecol Manage, 18: 281–296

Azizan F A, Kiloes A M, Astuti I S, Abdul Aziz A. 2021. Application of optical remote sensing in rubber plantations: A systematic review. Remote Sens, 13: 429

Belgiu M, Drăguţ L. 2016. Random forest in remote sensing: A review of applications and future directions. ISPRS J Photogramm Remote Sens, 114: 24–31

Biermann F. 2007. 'Earth system governance' as a crosscutting theme of global change research. Glob Environ Change, 17: 326–337

Bioucas-Dias J M, Plaza A, Camps-Valls G, Scheunders P, Nasrabadi N, Chanussot J. 2013. Hyperspectral remote sensing data analysis and future challenges. IEEE Geosci Remote Sens Mag, 1: 6–36

Carreiras J M B, Jones J, Lucas R M, Shimabukuro Y E. 2017. Mapping major land cover types and retrieving the age of secondary forests in the Brazilian Amazon by combining single-date optical and radar remote sensing data. Remote Sens Environ, 194: 16–32

Chen C, Park T, Wang X, Piao S, Xu B, Chaturvedi R K, Fuchs R, Brovkin V, Ciais P, Fensholt R, Tømmervik H, Bala G, Zhu Z, Nemani R R, Myneni R B. 2019. China and India lead in greening of the world through land-use management. Nat Sustain, 2: 122–129

Chen J, Yan F, Lu Q. 2020. Spatiotemporal variation of vegetation on the Qinghai-Tibet Plateau and the influence of climatic factors and human activities on vegetation trend (2000–2019). Remote Sens, 12: 3150

de Castro A I, Shi Y, Maja J M, Peña J M. 2021. UAVs for vegetation monitoring: Overview and recent scientific contributions. Remote Sens, 13: 2139

Del Valle T M, Jiang P. 2022. Comparison of common classification strategies for large-scale vegetation mapping over the Google Earth Engine platform. Int J Appl Earth Obs Geoinf, 115: 103092

Du H, Zhao J, Shi Y. 2022. Spatio-temporal distribution of sensitive

regions of potential vegetation in China based on the Comprehensive Sequential Classification System (CSCS) and a climate-change model. Rangeland J, 43: 353–361

Erinjery J J, Singh M, Kent R. 2018. Mapping and assessment of vegetation types in the tropical rainforests of the Western Ghats using multispectral Sentinel-2 and SAR Sentinel-1 satellite imagery. Remote Sens Environ, 216: 345–354

Fagan M E, Morton D C, Cook B D, Masek J, Zhao F, Nelson R F, Huang C. 2018. Mapping pine plantations in the southeastern U.S. using structural, spectral, and temporal remote sensing data. Remote Sens Environ, 216: 415–426

Fan Z, Bai X. 2021. Scenarios of potential vegetation distribution in the different gradient zones of Qinghai-Tibet Plateau under future climate change. Sci Total Environ, 796: 148918

Flood N, Watson F, Collett L. 2019. Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia. Int J Appl Earth Obs Geoinf, 82: 101897

Franklin J. 1995. Predictive vegetation mapping: Geographic modelling of biospatial patterns in relation to environmental gradients. Prog Phys Geog, 19: 474–499

Gašparović M, Dobrinić D. 2020. Comparative assessment of machine learning methods for urban vegetation mapping using multitemporal Sentinel-1 imagery. Remote Sens, 12: 1952

Ghorbanian A, Kakooei M, Amani M, Mahdavi S, Mohammadzadeh A, Hasanlou M. 2020. Improved land cover map of Iran using Sentinel imagery within Google Earth Engine and a novel automatic workflow for land cover classification using migrated training samples. ISPRS J Photogramm Remote Sens, 167: 276–288

Gottfried M, Pauli H, Futschik A, Akhalkatsi M, Barančok P, Benito Alonso J L, Coldea G, Dick J, Erschbamer B, Fernández Calzado M R, Kazakis G, Krajči J, Larsson P, Mallaun M, Michelsen O, Moiseev D, Moiseev P, Molau U, Merzouki A, Nagy L, Nakhutsrishvili G, Pedersen B, Pelino G, Puscas M, Rossi G, Stanisci A, Theurillat J P, Tomaselli M, Villar L, Vittoz P, Vogiatzakis I, Grabherr G. 2012. Continent-wide response of mountain vegetation to climate change. Nat Clim Change, 2: 111–115

Grimaldi S, Xu J, Li Y, Pauwels V R N, Walker J P. 2020. Flood mapping under vegetation using single SAR acquisitions. Remote Sens Environ, 237: 111582

Hansen M C, Loveland T R. 2012. A review of large area monitoring of land cover change using Landsat data. Remote Sens Environ, 122: 66–74

Homer C, Dewitz J, Yang L, Jin S, Danielson P, Xian G, Megown K. 2015. Completion of the 2011 National Land Cover Database for the conterminous United States—Representing a decade of land cover change information. Photogramm Eng Remote Sens, 81: 345–354

Hutchinson M F. 1995. Interpolating mean rainfall using thin plate smoothing splines. Int J Geogr Inf Syst, 9: 385–403

Ienco D, Interdonato R, Gaetano R, Minh D H T. 2019. Combining Sentinel-1 and Sentinel-2 satellite image time series for land cover mapping via a multi-source deep learning architecture. ISPRS J Photogramm Remote Sens, 158: 11–22

Kattenborn T, Leitloff J, Schiefer F, Hinz S. 2021. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. ISPRS J Photogramm Remote Sens, 173: 24–49

Kuchler A W, Zonneveld I S. 1967. Vegetation Mapping. Boston: Kluwer Academic Publishers

Li R, Kraft N J B, Yang J, Wang Y. 2015. A phylogenetically informed delineation of floristic regions within a biodiversity hotspot in Yunnan, China. Sci Rep, 5: 9396

Li W, Buitenwerf R, Munk M, Bøcher P K, Svenning J C. 2020. Deep-learning based high-resolution mapping shows woody vegetation densification in greater Maasai Mara ecosystem. Remote Sens Environ, 247: 111953

Liang T G, Feng Q S, Cao J J, Xie H J, Lin H L, Zhao J, Ren J Z. 2012. Changes in global potential vegetation distributions from 1911 to 2000 as simulated by the Comprehensive Sequential Classification System approach. Chin Sci Bull, 57: 1298–1310

Liang W, Abidi M, Carrasco L, McNelis J, Tran L, Li Y, Grant J. 2020. Mapping vegetation at species level with high-resolution multispectral and lidar data over a large spatial area: A case study with Kudzu. Remote Sens, 12: 609

Liu J, Coomes D A, Gibson L, Hu G, Liu J, Luo Y, Wu C, Yu M. 2019. Forest fragmentation in China and its effect on biodiversity. Biol Rev, 94: 1636–1657

Liu Y, Lyu Y, Bai Y, Zhang B, Tong X. 2020. Vegetation mapping for regional ecological research and management: A case of the Loess Plateau in China. Chin Geogr Sci, 30: 410–426

Lopes M, Frison P, Durant S M, Schulte to Bühne H, Ipavec A, Lapeyre V, Pettorelli N, Horning N. 2020. Combining optical and radar satellite image time series to map natural vegetation: Savannas as an example. Remote Sens Ecol Conserv, 6: 316–326

Macintyre P, van Niekerk A, Mucina L. 2020. Efficacy of multi-season Sentinel-2 imagery for compositional vegetation classification. Int J Appl Earth Obs Geoinf, 85: 101980

Madonsela S, Cho M A, Mathieu R, Mutanga O, Ramoelo A, Kaszta Ż, Kerchove R V D, Wolff E. 2017. Multi-phenology WorldView-2 imagery improves remote sensing of savannah tree species. Int J Appl Earth Obs Geoinf, 58: 65–73

Mountrakis G, Im J, Ogole C. 2011. Support vector machines in remote

sensing: A review. ISPRS J Photogramm Remote Sens, 66: 247–259

Myers N, Mittermeier R A, Mittermeier C G, da Fonseca G A B, Kent J. 2000. Biodiversity hotspots for conservation priorities. Nature, 403: 853–858

Ni J, Herzschuh U. 2011. Simulating biome distribution on the Tibetan Plateau using a modified global vegetation model. Arctic Antarctic Alpine Res, 43: 429–441

Pedrotti F. 2012. Plant and Vegetation Mapping. Springer Science & Business Media

Preidl S, Lange M, Doktor D. 2020. Introducing APiC for regionalised land cover mapping on the national scale using Sentinel-2A imagery. Remote Sens Environ, 240: 111673

Ran Y H, Li X, Lu L, Li Z Y. 2012. Large-scale land cover mapping with the integration of multi-source information based on the Dempster-Shafer theory. Int J Geogr Inf Sci, 26: 169–191

Räsänen A, Virtanen T. 2019. Data and resolution requirements in mapping vegetation in spatially heterogeneous landscapes. Remote Sens Environ, 230: 111207

Raynolds M K, Walker D A, Balser A, Bay C, Campbell M, Cherosov M M, Daniëls F J A, Eidesen P B, Ermokhina K A, Frost G V, Jedrzejek B, Jorgenson M T, Kennedy B E, Kholod S S, Lavrinenko I A, Lavrinenko O V, Magnússon B, Matveyeva N V, Metúsalemsson S, Nilsen L, Olthof I, Pospelov I N, Pospelova E B, Pouliot D, Razzhivin V, Schaepman-Strub G, Šibík J, Telyatnikov M Y, Troeva E. 2019. A raster version of the Circumpolar Arctic Vegetation Map (CAVM). Remote Sens Environ, 232: 111297

Roberts D W, Cooper S V. 1989. Concepts and techniques of vegetation mapping. In: Ferguson D, Morgan P, Johnson F D, eds. Land Classification Based on Vegetation: Applications for Resource Management. Ogden: USDA Forest Service GTR INT-257. 90–96

Roy P S, Behera M D, Murthy M S R, Roy A, Singh S, Kushwaha S P S, Jha C S, Sudhakar S, Joshi P K, Reddy C S, Gupta S, Pujar G, Dutt C B S, Srivastava V K, Porwal M C, Tripathi P, Singh J S, Chitale V, Skidmore A K, Rajshekhar G, Kushwaha D, Karnatak H, Saran S, Giriraj A, Padalia H, Kale M, Nandy S, Jeganathan C, Singh C P, Biradar C M, Pattanaik C, Singh D K, Devagiri G M, Talukdar G, Panigrahy R K, Singh H, Sharma J R, Haridasan K, Trivedi S, Singh K P, Kannan L, Daniel M, Misra M K, Niphadkar M, Nagabhatla N, Prasad N, Tripathi O P, Prasad P R C, Dash P, Qureshi Q, Tripathi S K, Ramesh B R, Gowda B, Tomar S, Romshoo S, Giriraj S, Ravan S A, Behera S K, Paul S, Das A K, Ranganath B K, Singh T P, Sahu T R, Shankar U, Menon A R R, Srivastava G, Neeti G, Sharma S, Mohapatra U B, Peddi A, Rashid H, Salroo I, Krishna P H, Hajra P K, Vergheese A O, Matin S, Chaudhary S A, Ghosh S, Lakshmi U, Rawat D, Ambastha K, Malik A H, Devi B S S, Gowda B, Sharma K C, Mukharjee P, Sharma A, Davidar P, Raju R R V, Katewa S S, Kant S, Raju V S, Uniyal B P, Debnath B, Rout D K, Thapa R, Joseph S, Chhetri P, Ramachandran R M. 2015. New vegetation type map of India prepared using satellite remote sensing: Comparison with global vegetation maps and utilities. Int J Appl Earth Obs Geoinf, 39: 142–159

Schulz D, Yin H, Tischbein B, Verleysdonk S, Adamou R, Kumar N. 2021. Land use mapping using Sentinel-1 and Sentinel-2 time series in a heterogeneous landscape in Niger, Sahel. ISPRS J Photogramm Remote Sens, 178: 97–111

Senf C, Pflugmacher D, van der Linden S, Hostert P. 2013. Mapping rubber plantations and natural forests in Xishuangbanna (Southwest China) using multi-spectral phenological metrics from MODIS time series. Remote Sens, 5: 2795–2812

Shao Y, Lunetta R S. 2012. Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. ISPRS J Photogramm Remote Sens, 70: 78–87

Shi H, Chen J. 2018. Characteristics of climate change and its relationship with land use/cover change in Yunnan Province, China. Int J Climatol, 38: 2520–2537

Su Y, Guo Q, Hu T, Guan H, Jin S, An S, Chen X, Guo K, Hao Z, Hu Y, Huang Y, Jiang M, Li J, Li Z, Li X, Li X, Liang C, Liu R, Liu Q, Ni H, Peng S, Shen Z, Tang Z, Tian X, Wang X, Wang R, Xie Z, Xie Y, Xu X, Yang X, Yang Y, Yu L, Yue M, Zhang F, Ma K. 2020. An updated Vegetation Map of China (1:1000000). Sci Bull, 65: 1125–1136

Sun H, Wang J, Xiong J, Bian J, Jin H, Cheng W, Li A, García Mozo H. 2021. Vegetation change and its response to climate change in Yunnan Province, China. Adv Meteor, 2021: 1–20

Taubert F, Fischer R, Groeneveld J, Lehmann S, Müller M S, Rödig E, Wiegand T, Huth A. 2018. Global patterns of tropical forest fragmentation. Nature, 554: 519–522

Tong X Y, Xia G S, Zhu X X. 2023. Enabling country-scale land cover mapping with meter-resolution satellite imagery. ISPRS J Photogramm Remote Sens, 196: 178–196

Treitz P M, Howarth P J, Suffling R C, Smith P. 1992. Application of detailed ground information to vegetation mapping with high spatial resolution digital imagery. Remote Sens Environ, 42: 65–82

Trisasongko B H, Paull D. 2020. A review of remote sensing applications in tropical forestry with a particular emphasis in the plantation sector. Geocart Int, 35: 317–339

Tsai Y H, Stow D, Chen H L, Lewison R, An L, Shi L. 2018. Mapping vegetation and land use types in Fanjingshan National Nature Reserve using Google Earth Engine. Remote Sens, 10: 927

Tuanmu M N, Viña A, Bearer S, Xu W, Ouyang Z, Zhang H, Liu J. 2010. Mapping understory vegetation using phenological character-

istics derived from remotely sensed data. Remote Sens Environ, 114: 1833–1844

van Beijma S, Comber A, Lamb A. 2014. Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data. Remote Sens Environ, 149: 118–129

van der Maarel E, Franklin J. 2012. Vegetation Ecology. New York: John Wiley & Sons

Verrall B, Pickering C M. 2020. Alpine vegetation in the context of climate change: A global review of past research and future directions. Sci Total Environ, 748: 141344

Verrelst J, Camps-Valls G, Muñoz-Marí J, Rivera J P, Veroustraete F, Clevers J G P W, Moreno J. 2015. Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties—A review. ISPRS J Photogramm Remote Sens, 108: 273–290

Wagner F H, Sanchez A, Tarabalka Y, Lotte R G, Ferreira M P, Aidar M P M, Gloor E, Phillips O L, Aragão L E O C, Pettorelli N, Clerici N. 2019. Using the U-net convolutional network to map forest types and disturbance in the Atlantic rainforest with very high resolution images. Remote Sens Ecol Conserv, 5: 360–375

Walker D A, Raynolds M K, Daniëls F J A, Einarsson E, Elvebakk A, Gould W A, Katenin A E, Kholod S S, Markon C J, Melnikov E S, Moskalenko N G, Talbot S S, Yurtsev B A, The other members of the CAVM Team . 2005. The circumpolar Arctic vegetation map. J Veg Sci, 16: 267–282

Wang F, Ding Y, Sayer E J, Li Q, Zou B, Mo Q, Li Y, Lu X, Tang J, Zhu W, Li Z, Gallery R. 2017. Tropical forest restoration: Fast resilience of plant biomass contrasts with slow recovery of stable soil C stocks. Funct Ecol, 31: 2344–2355

Wang X, Yao Y F, Wortley A H, Qiao H J, Blackmore S, Wang Y F, Li C S. 2018. Vegetation responses to the warming at the Younger Dryas-Holocene transition in the Hengduan Mountains, south-western China. Quat Sci Rev, 192: 236–248

Wu T, Luo J, Gao L, Sun Y, Dong W, Zhou Y, Liu W, Hu X, Xi J, Wang C, Yang Y. 2021. Geo-object-based vegetation mapping via machine learning methods with an intelligent sample collection scheme: A case study of Taibai Mountain, China. Remote Sens, 13: 249

Xiahou M, Liu Y, Yang T, Shen Z. 2024. Estimating potential vegetation distribution and restoration in a biodiversity hotspot region under future climate change. J Geogr Sci, 34: 2128–2144

Xie Y, Sha Z, Yu M. 2008. Remote sensing imagery in vegetation mapping: A review. J Plant Ecol, 1: 9–23

Yao Y, Suonan D, Zhang J. 2020. Compilation of 1:50000 vegetation type map with remote sensing images based on mountain altitudinal belts of Taibai Mountain in the North-South transitional zone of China. J Geogr Sci, 30: 267–280

Ye P, Zhang G, Wu J. 2020. Hotspots and conservation gaps: A case study of key higher plant species from Northwest Yunnan, China. Glob Ecol Conserv, 23: e01005

Zeng Y, Gou M, Ouyang S, Chen L, Fang X, Zhao L, Li J, Peng C, Xiang W. 2019. The impact of secondary forest restoration on multiple ecosystem services and their trade-offs. Ecol Indicators, 104: 248–258

Zhang C, Xie Z. 2014. Data fusion and classifier ensemble techniques for vegetation mapping in the coastal Everglades. Geocarto Int, 29: 228–243

Zhang H, Eziz A, Xiao J, Tao S, Wang S, Tang Z, Zhu J, Fang J. 2019. High-resolution vegetation mapping using extreme gradient boosting based on extensive features. Remote Sens, 11: 1505

Zhu Z, Piao S, Myneni R B, Huang M, Zeng Z, Canadell J G, Ciais P, Sitch S, Friedlingstein P, Arneth A, Cao C, Cheng L, Kato E, Koven C, Li Y, Lian X, Liu Y, Liu R, Mao J, Pan Y, Peng S, Peñuelas J, Poulter B, Pugh T A M, Stocker B D, Viovy N, Wang X, Wang Y, Xiao Z, Yang H, Zaehle S, Zeng N. 2016. Greening of the Earth and its drivers. Nat Clim Change, 6: 791–795

Zomer R J, Xu J, Wang M, Trabucco A, Li Z. 2015. Projected impact of climate change on the effectiveness of the existing protected area network for biodiversity conservation within Yunnan Province, China. Biol Conserv, 184: 335–345

(责任编委: 施建成)