

机器学习与面向对象技术相结合的山地树种 遥感精细识别——以秦巴山地为例

王晓峰^{1,2}, 杨紫环¹, 刘世荣³, 周潮伟¹, 陈吉臻³, 黄志霖³, 白娟¹

1. 长安大学 土地工程学院, 西安 710054;

2. 陕西省土地整治重点实验室, 西安 710054;

3. 中国林业科学研究院森林生态环境与自然保护研究所 国家林业和草原局森林生态环境重点实验室, 北京 100091

摘要: 山地森林作为重要的陆地碳库, 通过关键的气候反馈机制, 对大气化学过程、景观生态功能和生物多样性产生重要影响。然而, 受复杂地形与观测条件限制, 山地森林树种组成及其空间分布的精细刻画仍面临挑战。以Sentinel-2为代表的陆地卫星监测技术与人工智能算法的融合, 极大地革新了传统森林调查方式, 为森林树种监测与精细制图提供了新的路径。本研究整合地面样点与多源遥感数据, 通过谷歌地球引擎GEE (Google Earth Engine) 遥感云计算平台提取2020年—2023年Sentinel-2多时相影像特征, 结合JM (Jeffries-Matusita) 距离建立多维特征优选方案, 采用简单非迭代聚类SNIC (Simple Non-Iterative Clustering) 超像素算法与机器学习方法构建最优特征的随机森林模型, 实现秦巴山地树种的精细分类, 并揭示其时空分异规律。结果表明: (1) 地形特征是秦巴山地树种识别的重要特征, 结合JM距离的多特征组合方案能有效提升特征筛选效果; (2) 在有限样本、中分辨率影像和大区域条件下, 基于SNIC的面向对象随机森林模型具有良好的分类性能, 平均总体精度为0.837, Kappa系数为0.791, F_1 值均值为0.799; (3) 秦巴山地栎类、松类和杉类分布广泛, 其余树种呈零散分布。 (4) 2020年—2023年, 森林面积呈轻微上升趋势, 说明区域生态环境持续向好。松类与栎类对森林变化贡献度最大, 面积占比小的树种转换则比较频繁。综上, 本研究可为复杂山地森林生态系统的碳汇功能评估与生物多样性保护提供数据支撑。

关键词: 山地森林, 树种识别, 树种空间分布变化, 遥感数据, 树种时空分异

中图分类号: S771.8/P2

引用格式: 王晓峰, 杨紫环, 刘世荣, 周潮伟, 陈吉臻, 黄志霖, 白娟. 2026. 机器学习与面向对象技术相结合的山地树种遥感精细识别——以秦巴山地为例. 遥感学报, 30(6): 1627-1646

Wang X F, Yang Z H, Liu S R, Zhou C W, Chen J Z, Huang Z L and Bai J. 2026. Fine-scale tree species mapping in mountainous regions using integrated machine learning and object-based remote sensing: A case study of the Qinling-Daba Mountains. National Remote Sensing Bulletin, 30(6): 1627-1646 [DOI:10.11834/jrs.20265334]

1 引言

山地森林约占全球森林面积的25% (Abera等, 2024), 是生物多样性的热点地区 (Richter等, 2024) 和陆地碳汇的重要载体 (万杰等, 2024)。其空间分布格局直接影响生物挥发性有机化合物BVOC (Biogenic Volatile Organic Compounds) 及原生生物气溶胶PBA (Primary Biological Aerosols) 的释放过程, 进而调控区域气候与景观生态功能 (Ottosen等, 2020)。山地森林通过独特的水分拦截与循环

机制, 为周围低地提供可持续的淡水供应 (Abera等, 2024), 惠及全球至少50%的人口 (Thakur等, 2021)。同时, 复杂地形的山地森林具有更高的植物多样性 (Smyčka等, 2022), 尤其是小范围的山地特有物种比例显著增加 (Rahbek等, 2019), 使其成为生态保护的优先区域。秦巴山地森林生态系统具有典型的南北分异和垂直地带性, 表现出显著的气候与植被分布差异 (康慕谊和朱源, 2007), 是研究复杂环境下森林遥感监测的典型代表区域。

山地森林结构异质性强, 林分类型复杂多样,

收稿日期: 2025-08-30; 预印本: 2026-03-31

基金项目: 国家自然科学基金(编号:72349002); 中国林业科学研究院基本科研业务费专项(编号:CAFYBB2024ZA001)

第一作者简介: 王晓峰, 研究方向为生态遥感。E-mail: wangxf@chd.edu.cn

多分布于偏远且环境恶劣的区域,监测难度更高,数据更为稀缺。遥感技术有效克服了崎岖地形以及山区季节性通行限制对实地数据收集的挑战(Torresan等,2022),具备快速覆盖、大范围获取和重复观测(Laurin等,2016)等优势,能为偏远或难以到达的地区提供数据支持。目前已有研究在典型单一林分/优势树种的分类(王书凡等,2024)、分类模型的性能评估(Maxwell等,2018)、不同分类单元及尺度对树种识别的影响(赵阳等,2023)以及多特征优选方法对模型性能的提升(周小成等,2021)等方面取得了显著进展。

然而,不同分辨率的多光谱遥感数据在树种识别能力上存在显著的差异。多数研究集中在大尺度森林生态系统(如针叶林、阔叶林和混交林)和植被覆盖类型的分类,如ESA CCI Land Cover全球尺度的数据产品。此类产品分类体系较为粗略、空间分辨率较低,易存在混合像元问题(王怀警等,2019);在小尺度的平原地区或实验样地则需要高分辨率数据,如GF-2影像(冯林艳等,2022)、无人机与激光雷达数据(张书嵘等,2025),但数据处理成本高,在山地森林的复杂地形环境及大区域应用受限(Ma等,2021)。相较之下,以Sentinel-2为代表的中分辨率多光谱遥感数据,具备连续性、经济性和可访问性(Grabska等,2019)的优势,适用于生态环境复杂的较大地理区域(Yang等,2024)。

当前已经有诸多学者将遥感数据与机器学习结合进行树种分类,主要分为基于像素和面向对象的两种方法。相较于以单一像元为最小单位的传统方法,面向对象能够综合利用影像的光谱、形状、空间关系及纹理等特征,有效避免“椒盐”现象(赵阳等,2023),提高分类精度(Ballanti等,2016)。随着机器学习的发展,开始将分类单元的划分与复杂算法进行整合。随机森林(RF)在处理高维数据具有良好的性能(Belgiu和Drăguț,2016)。支持向量机(SVM)适用于小样本量和高维度问题,但算法复杂,对参数调节和函数选择较为敏感(侯逸晨等,2016)。分类与回归树CART(Classification and Regression Tree)算法通过二分递归分割方法实现分类(罗滨等,2025)。梯度提升决策树GBDT(Gradient Boosting Decision Tree)是一种集成学习方法,具有高度鲁棒性(Cheng等,2024)。已有研

究表明,在不同区域背景下,面向对象的RF模型精度优于CART、GBDT和SVM(Liang等,2024;Maxwell等,2018)。因此,本文选择RF、SVM、CART决策树和GBDT共4种分类方法,结合面向对象技术,识别适用于秦巴山地的最优分类方法。

尽管当前针对遥感树种识别的研究已取得一定的进展,但在森林结构复杂的山地区域,大范围 and 长时序的树种精细识别研究仍存在空缺。本文基于GEE云平台结合机器学习与面向对象技术实现秦巴山地树种遥感精细分类,研究主要解决以下问题:在有限样本、中分辨率影像和复杂山地森林环境下,实现树种的精细识别并提升分类精度;评估多种分类模型的适用性,筛选出最优方法以提升模型性能;构建不同特征组合,明确在提升分类精度中贡献最大的变量。与已有研究相比,本研究在2个方面拓展了树种分类的思路:一是结合JM距离与传统特征组合方法,系统量化了不同特征在提升分类精度中的贡献;二是在有限样本条件下,将面向对象分割与机器学习模型相结合,有效提升了中分辨率影像的树种分类精度。以期为复杂山地森林生态系统的碳平衡评估、生态恢复(Hermosilla等,2024)和生物多样性保护(Ni-Meister等,2024)等研究提供数据支撑。

2 研究区与数据

2.1 研究区概况

秦巴山地位于中国中部,介于 $26^{\circ}03'N$ — $45^{\circ}57'N$, $92^{\circ}13'E$ — $116^{\circ}39'E$,总面积约28万 km^2 ,横跨长江、黄河两大流域,地跨五省一市(甘肃省、陕西省、河南省、湖北省、四川省和重庆市),是中国的南北过渡带。地势起伏明显,海拔多在1000—2500 m,气候类型多样。区内植被区系复杂,森林茂密,兼备中国南北植物区系成分,北部为暖温带落叶阔叶林带,南部为北亚热带常绿阔叶林。作为“中华绿芯”,区域内栖息着太白红杉、秦岭冷杉、红豆杉等珍稀树种,是国家重要的生物多样性功能区和“世界生物基因库”。

2.2 数据来源及预处理

2.2.1 遥感数据采集

本文通过GEE云平台(Google Earth Engine)在

线调用 SRTM DEM 数据产品（数据集名称为 USGS/SRTMGL1_003）和 2020 年—2023 年的 Sentinel-2 地表反射率数据产品（数据集名称为 COPENICUS/S2_SR_HARMONIZED）。Sentinel-2 由两颗搭载了多光谱成像仪 MSI（Multi-Spectral Imager）的卫星

组成，于 2015 年 6 月发射，是欧空局 Copernicus 计划提供的中分辨率多光谱成像数据。影像包含 13 个波段，覆盖可见光、近红外到短波红外，具有 10—60 m 的空间分辨率，时间分辨率为 5 d，数据投影采用 WGS1984 Albers。




图1 秦巴山地概况图
Fig.1 Overview map of the Qinling-Daba Mountains

2.2.2 样本数据及处理

样本点来源于一个历史积累的基础数据库，其原始采样时间覆盖 2010 年—2023 年（共计 1265 个点）。其中，2010 年—2019 年的样本共 378 个，主要用于分类体系构建和历史验证参考；2020 年—2023 年样本共 887 个，作为核心研究期数据，用于模型构建与趋势分析。此外，在已有样本点和面向对象逐年分割结果的基础上，通过目视判读增选样本点，辅助参考高分辨率的 Google Earth Engine 在线地图。在影像显著变化且与逐年分割结果存在差异的位置，不予选取样点，以确保样点具有代表性与时序一致性，最终得到约 2000 个样点。将所选样本按 8 : 2 的比例随机分为训练样本和验证样本。根据各类的代表树种，将样本点划分为 12 个树种类别，其分布情况如表 1 所示。树种分类结果经与 2013 年—2017 年 1 : 25 万《中国森林植被分布图》图集进行空间叠置分析作为对比验证。该图集来源于科技基础性工作专项“中国森林植被调查（2013FY111600）”。

3 研究方法

本文技术路线如图 2 所示。通过 GEE 在线调用 Sentinel-2 数据，剔除云量超过 20% 的影像，使用均值合成影像，减少云层、噪声和异常值的影响，结合 SRTMGL1_003 影像数据，提取光谱、植被指数、地形、纹理与物候特征，基于面向对象技术与 SNIC 分割算法构建逐年样本点集，采用 JM 距离与特征组合构建特征优选实验方案，通过对比不同方案与模型的差异和效果，选择最优方案与模型，获取秦巴山地树种分类结果。

3.1 面向对象分割——SNIC 算法

SNIC（Simple Non-Iterative Clustering）算法通过采用优先级队列改进了传统 SLIC 算法中的 k-means 迭代聚类过程（Achanta 等，2012），该优化设计可充分发挥 GEE 平台的云端并行计算优势，在保持超像素生成质量的同时显著提升运算效率。相较于 SLIC 算法在迭代过程中产生的高内存消耗，SNIC 通过改进迭代机制显著降低了内存占用（Achanta 和 Süsstrunk，2017），将其集成到 GEE 平台的遥感

影像分割流程中，为面向对象分类方法提供了更高效的技术实现路径。算法中控制分割结果的主要参数是seeds和compactness。对于本研究使用的Sentinel-2数据，选择一个小区域并参考谷歌地图进行分割精度对比。经过多次对比实验，发现紧凑度

调整对分割尺度影响较小，但对于减少齿状冗余有一定效果（图3）。为避免过分割和欠分割，设置seeds为30、compactness为10时，得到的影像对象地物类型较均一，分割效果较好。

表1 原始样本类别及数量分布
Table 1 Distribution of original sample categories and quantities

树种	样点个数	代表树种
栎类	416	枹栎、短柄枹栎、高山枹、榭栎、辽东枹、蒙古枹、楸树、锐齿榭栎、栓皮枹
松类	332	巴山松、北美乔松、高山松、华北落叶松、马尾松、华山松、日本落叶松、油松、云南松
杉类	112	巴山冷杉、臭冷杉、川西云杉、黄果冷杉林、柳杉、岷江冷杉、秦岭冷杉、四川红杉
山茶类	38	茶树
柏类	33	侧柏、岷江柏、扁柏、川柏、尖叶扁柏
栗类	24	板栗
竹类	26	箭竹
桦木类	27	光皮桦、红桦、牛皮桦
青冈类	24	滇青冈林、大叶青冈、米心水青冈、小叶青冈、多脉青冈
杨柳类	22	山杨、紫枝柳
胡桃类	40	核桃
其他树种	171	化香、喜树、黄枒、厚朴、漆树、四照花、光叶陇东海棠、宜昌润楠、桤木、樟树、泡桐、臭椿、白蜡林、柑橘、刺槐、李子




图2 树种识别框架

Fig.2 Tree species identification framework

3.2 特征变量数据集构建

图像特征提取是遥感图像分类的重要前提，通过组合多种特征变量，能够提高遥感分类的质

量与精度（熊皓丽 等，2021）。本研究考虑树种在光谱、高程、纹理与物候共4个方面的差异，构建包含33个特征参数的特征变量数据集（表2）。



图3 不同种子数量与紧凑度组合下的超像素分割结果

Fig.3 Superpixel segmentation results under different combinations of seeds quantity and compactness

3.2.1 光谱特征及植被指数特征

结合已有研究 (Bolyn 等, 2018; 谭深 等, 2019; 岳巍 等, 2022), 选择 Sentinel-2 影像的原始波段的反射率特征, 并基于此计算 8 种典型植被光谱指数 (表 2)。其中, 归一化植被指数 (NDVI) 广泛用于表征树种的生长状况; 增强型植被指数 (EVI) 通过引入蓝光波段, 能够有效降低大气散射和土壤背景的干扰, 对森林高生物量区域更为敏感; 叶绿素植被指数 (GCVI) 具有较大的动态范围, 可通过叶绿素含量辅助区分不同树种的生理状态, 适

用于高密度植被覆盖环境 (霍轩琳等, 2023); 红边归一化植被指数 (NDVI_{re}) 能够有效缓解经典 NDVI 的饱和效应, 结合蓝光—红边 1 简单比值指数 (SR_{Bre1}), 通过监测植被的叶绿素含量 (梁继 等, 2020), 提高树种信息提取的精度; 归一化水体指数 (NDWI) 和归一化湿度指数 (NHI) 对植被含水量较敏感, 能够区分不同树种在水分利用效率方面的差异; 归一化耕作指数 (NDTI) 多用于耕地与裸地分类, 在人类活动区域有助于减弱裸地背景对树种分类的干扰。

表2 特征变量数据集
Table 2 Characteristic variable dataset

光谱特征		植被指数	
波段	中心波长/nm	指数名称	公式
B2(Blue)	497	归一化植被指数 NDVI(Normalized Difference Vegetation Index)	$(\text{NIR}-\text{Red})/(\text{NIR}+\text{Red})$
B3(Green)	560	归一化耕作指数 NDTI(Normalized Difference Tillage Index)	$(\text{SWIR1}-\text{SWIR2})/(\text{SWIR1}+\text{SWIR2})$
B4(Red)	665	归一化水体指数 NDWI(Normalized Difference Water Index)	$(\text{NIR}_{\text{narrow}}-\text{SWIR1})/(\text{NIR}_{\text{narrow}}+\text{SWIR1})$
B5(Rededge1)	704	红边归一化植被指数 NDVI _{re} (Red-edge Normalized Difference Vegetation Index)	$(\text{NIR}_{\text{narrow}}-\text{Rededge1})/(\text{NIR}_{\text{narrow}}+\text{Rededge1})$
B6(Rededge2)	740	归一化湿度指数 NHI(Normalized Humidity Index)	$(\text{SWIR1}-\text{Green})/(\text{SWIR1}+\text{Green})$
B7(Rededge3)	783	蓝光—红边 1 简单比值指数 SR _{Bre1} (Simple Blue and Red-edge 1 Ratio)	$\text{Blue}/\text{Rededge1}$
B8(NIR)	835	增强型植被指数 EVI(Enhanced Vegetation Index)	$2.5\times(\text{NIR}-\text{Red})/(\text{NIR}+6\times\text{Red}-7.5\times\text{Blue}+1)$
B8A(NIR _{narrow})	865	叶绿素植被指数 GCVI(Green Chlorophyll Vegetation Index)	$\text{NIR}/\text{Green}-1$
B11(SWIR1)	1614		
B12(SWIR2)	2202		

地形特征		物候特征	
特征	定义	属性	定义
海拔(elevation)	地表高程的绝对高度信息	生长季的起始(SoS)	EVI增长到全年时间序列振幅的20%对应的时间点
坡度(slope)	坡面相对于水平面的夹角	生长季的结束(EoS)	EVI下降到全年时间序列振幅的20%对应的时间点
坡向(aspect)	高度值最大变化比率的方向(董咪娜等,2022)	生长季长度(LoS)	生长季起始点和结束点的时间长度
山体阴影(hillshade)	通过获取光线照射下地表每个像元的照明值,识别微地貌特征(陈刚等,2024)		

纹理特征	
属性	说明
Canny算子	该算子通过2个相关的阈值来确定边缘点
角二阶矩(gray_asm)	表征影像对象灰度分布的均匀性,反映纹理的规则程度
对比度(gray_contrast)	表征影像对象的清晰度与纹理的沟纹深浅
相关性(gray_corr)	衡量影像对象中像素灰度值在行列方向上的相似程度
方差(gray_var)	描述影像对象灰度变化的幅度
反差逆矩(gray_idm)	反映影像对象灰度值分布的局部变化程度
灰度和均值(gray_savg)	反映影像对象灰度值和的平均水平
熵(gray_ent)	描述影像对象灰度分布的随机性,表示纹理的复杂程度

3.2.2 地形特征

考虑到秦巴山地的地形高差大,并且地形特征能够有效减轻由于光谱混淆导致的森林光谱变异性的问题(Hermosilla等,2022)。基于已有研究(李坤玉等,2024;张艳可等,2021),通过SRTMGL1_003影像计算地形属性,包含海拔(elevation)、坡度(slope)、坡向(aspect)和山体阴影(hillshade)。

3.2.3 纹理特征

树冠的纹理信息也被普遍用于改进树种分类(Fassnacht等,2016),并且结合光谱和纹理特征能够提高分类的准确性(Mallinis等,2008)。因

此,本文使用gee调用.glcmmTexture()计算灰度图层,根据灰度特征结合Canny边缘检测算法,得到Canny边缘几何特征、角二阶矩(gray_asm)、对比度(gray_contrast)、相关性(gray_corr)、方差(gray_var)、反差逆矩(gray_idm)、灰度和均值(gray_savg)和熵(gray_ent)。灰度图像通过对Sentinel-2卫星原始图像的NIR、Red和Green波段进行线性组合生成(Tassi和Vizzari,2020)。具体计算公式如下:

$$\text{Gray} = (0.3 \times \text{NIR}) + (0.56 \times \text{RED}) + (0.11 \times \text{GREEN})$$

(1)

边缘检测是通过数学方法找到图像中灰度不连续的位置(钱立辉等,2016),Canny算子为

(Sharma 等, 2022) 是一种经典的多级边缘检测算法, 通过两个相关的阈值来确定边缘点, 具有控制边缘细节信息与抑制噪声的优点 (何梦梦 等, 2018)。canny 参数设置中阈值范围在 5—50, 高斯滤波器标准差在 0.5—2.0。经过多次对比实验, 本文阈值设置为 5, 高斯滤波器标准差为 0.5。

3.2.4 物候特征

物种辨别的重要特征之一是物候, 并且需要将图像采集时间与所研究物种的物候周期保持一致 (Gärtner 等, 2016)。因此, 本文对各年中 73 景 EVI 数据进行去云插值处理以及时间序列重建, 运用多项式次数为 3 的 Savitzky-Golay 滤波法平滑时序曲线。基于目前已开发的几种提取植被物候的方法, 采用广泛使用的动态阈值法 (Descals 等, 2020) 从重建的 EVI 时间序列中提取植被物候, 结合以往研究对阈值的设定, 使用 20% 的振幅估计的阈值指标受偏差的影响较小 (杨涵 等, 2024; 赵倚霏 等, 2024; 冯莉 等, 2016), 因此将阈值比例 p 设定为 0.2。物候值的计算公式为

$$u = (V_{\min} - V_{\max}) \times p + V_{\min} \quad (2)$$

式中, u 为动态阈值, 该值取决于时间序列的年振幅, 用来判断 SoS 和 EoS。在本研究中, 当 EVI 值超过 u 时, 则认为生长季开始或结束; $V_{\min}$ 和 $V_{\max}$ 为时间序列中的年最小值和最大值; p 是阈值比例, 即时间序列振幅的给定比例, %。

3.3 特征优化设计

通过 Sentinel-2 和 DEM 数据提取光谱、植被、地形、纹理和物候特征, 设计 5 组不同特征组合的方案 (表 3)。通过排序所有特征变量的重要性, 对其降序结果做累计百分比统计, 分别取累计重要性为 60%、70%、80% 和 90% 的变量作为 JM 距离算法的输入特征。选择计算训练数据集中每类样本点的均值和方差, 得到不同输入特征下树种之间的 JM 距离, 最终依据 JM 距离均值大小优选特征构建方案。

JM (Jeffries-Matusita) 距离是基于数据正态分布的假设来度量类间可分程度的评价方法。JM 距离考虑了各类别的概率分布与交叠程度, 能够处理类别间距离差异较大的情况 (安琼 等, 2008), 是特征选择广泛使用的方法 (Dabboor 等, 2014)。JM 距离的表达式为

$$JM = 2(1 - e^{-B}) \quad (3)$$

$$B = \frac{1}{8} (e_1 - e_2)^2 \frac{2}{\delta_1^2 + \delta_2^2} + \frac{1}{2} \ln \left(\frac{\delta_1^2 + \delta_2^2}{2\delta_1^2 + \delta_2^2} \right) \quad (4)$$

式中, B 表示某一特征维上的巴氏距离 (Bhattacharyya Distance); e_k 表示某类特征的均值; δ_k^2 表示某类特征的方差。JM 的取值范围为 $[0, 2]$, 0 表示完全不可分, 2 表示完全可分, 该值越大表示类别之间可分度越高。

表 3 特征变量组合方案

Table 3 Combination schemes of feature variables

编号	特征组合
1	光谱特征+植被指数
2	光谱特征+植被指数+纹理特征
3	光谱特征+植被指数+地形特征
4	光谱特征+植被指数+物候特征
5	全部特征

3.4 分类模型构建

本研究中选择随机森林 (RF)、支持向量机 (SVM)、CART 决策树及梯度提升树 (GBDT) 4 种典型分类模型, 其中随机森林模型在多次对比实验中表现力较好, 作为主要分类模型。

本研究初期在预实验阶段对多种常用分类器进行了精度评估, 包括最小距离分类器 (Minimum-Distance) 和 KNN (k -最近邻) 方法。最小距离分类器仅考虑每类样本的平均值而忽略类内方差与类间协方差, 因此分类精度有限 (韩冰冰和陈圣波, 2020)。KNN 方法在样本分布不均的情况下, 分类效果较差, 且需对所有训练样本进行距离计算, 计算成本高 (赵理君和唐娉, 2016; 薛梦姣 等, 2015)。本研究实验结果发现这 2 种方法在秦巴山地的分类精度较低 (表 4), OA 和 Kappa 年均值远低于其他分类器。其中, KNN 的 OA 与 Kappa 年均值分别为 0.632 与 0.517, 最小距离分类器分别为 0.628 与 0.511, 难以满足本研究对分类精度的要求。

此外, 已有研究也表明 KNN 与最小距离分类器的表现明显低于其他方法。如李宏达等 (2021) 在对比 7 种分类器时发现, KNN 的分类精度比 GBDT 低 12.02%; 李斌等 (2021) 对比最小距离、RF 和 CART3 种模型时指出, 最小距离分类器的总体精度为 0.80, 比 RF 低 12%。因此最小距离分类器 (Minimum-Distance) 和 KNN (k -最近邻) 模型不予选用。

表4 预实验中模型KNN与最小距离分类器精度对比
Table 4 Accuracy comparison of KNN and Minimum Distance classifiers (pre-experiment)

年份/年	KNN		最小距离分类器	
	OA	Kappa	OA	Kappa
2020	0.611	0.479	0.608	0.469
2021	0.651	0.546	0.645	0.538
2022	0.645	0.531	0.640	0.526
2023	0.621	0.511	0.619	0.509
均值	0.632	0.517	0.628	0.511

随机森林模型是一个由多颗决策树集成的非参数机器学习算法。通过抽放初始样本，生成 N 个训练集，从样本集的总特征 M 里随机选取 m 个特征，其中 $m \leq M$ ，通过完全分裂节点构建决策树，根据分类结果投票得到新样本类别（陈志波等，2025）。RF算法可以在处理大量输入变量的同时避免过拟合，擅长高维非线性分类，具有较好的准确性、泛化性和鲁棒性（Biau, 2012）。本研究使用网格搜索法寻找最优参数，参数设置见表5。

支持向量机（SVM）通过非线性映射将数据转换到高维特征空间，并在此空间中求解最优分类超平面，以最大化样本间间隔为目标，将分类误差作为约束条件构建数学模型（贾诗超等，2018）。本研究使用网格搜索法寻找最优参数，2020年—2023年均使用RBF径向基函数，gamma值设为1，cost值设为10。

CART决策树是在无序无规则的训练样本中推导出最佳分类模型的方法，具有训练过程简单、树结构易于理解与处理数据类型多样等优点（范强等，2023）。经多次调参，发现默认参数能够较好适应本研究的有限样本条件，因此2020年—2023年均使用默认参数，其中maxNodes设为null（不限制树节点数量），minLeafPopulation设为1（叶子节点最少样本数为1）。

梯度提升树（GBDT）是由Freiman提出的基于Boosting策略的集成机器学习算法（张海洋等，2023）。该算法通过不断结合函数的线性组合来减少在训练过程中的残差，从而实现回归（Li等，2024）。研究使用网格搜索法寻找最优参数，参数设置见表5。

3.5 精度评价

研究使用混淆矩阵（Confusion Matrix）对树

种分类进行精度评估，主要选取总体精度OA（Overall Accuracy）、Kappa系数和 F_1 即生产者精度PA（Producer’s Accuracy）和用户精度UA（User’s Accuracy）的调和平均值，共3个评价指标对分类精度进行评价分析，其中总体精度和Kappa系数作为评价总体分类精度的指标， F_1 作为综合评价指标用以避免在实际分类操作中PA与UA的制衡问题（肖庆琳等，2024；谢君洋等，2024）。 F_1 的取值范围为 $[0, 1]$ ，其表达式为

$$F_1 = 2 \times \frac{PA \times UA}{PA + UA} \tag{5}$$

表5 RF和GBDT模型逐年树个数
Table 5 Annual number of trees for RF and GBDT models

年份/年	RF	RF面向对象	GBDT
2020	410	220	400
2021	350	180	380
2022	350	210	350
2023	380	210	450

3.6 树种面积相对增长率

复合年均增长率（CAGR）采用几何平均法计算（Puyravaud, 2003），强调比例关系，适合比较不同树种的相对增长速度，其表达式为

$$CAGR = \left(\frac{A_{2023}}{A_{2020}} \right)^{\frac{1}{n}} - 1 \tag{6}$$

式中，CAGR为复合年均增长率，%； A_{2020} 和 A_{2023} 分别为初始年与结束年的树种面积， km^2 ； n 为间隔年份。

4 结果与分析

4.1 特征重要性评价

特征重要性按降序划分依次为地形、物候、植被指数、纹理和光谱（图4）。在地形特征中，elevation在2020年—2023年的特征排序中均为最重要特征，其贡献率为4.30%—4.85%，显著高于其他特征（图4）；物候特征（SoS、EoS、LoS）在不同年份普遍占据特征重要性排序的前5名（图4）；植被指数对于分类的贡献则较为稳定，其中EVI、NDWI和SR_Bre1表现良好（图4）；纹理特征在年际间存在一定波动，可优先选择gray_contrast和gray_savg，其中gray_asm和gray_ent贡献度最低，故而剔除；光谱特征的贡献率则整体较低（图4）。此外，选取累计重要性排名前10的特征并计算其

比例，发现地形、物候和植被指数对分类精度的贡献率最高。此外，2020年—2023年排名前10的

特征累计贡献率约为30%—40%，说明特征的分布较为分散，没有出现少数特征占据主导的情况。




图4 不同年份不同特征重要性累加百分比
Fig. 4 Cumulative percentage of feature importance across different years

4.2 分类精度评价

4.2.1 面向对象的特征优选精度对比

采用面向对象的随机森林模型进行特征优选，取累计特征重要性为90%（去除贡献度较低的2个特征，取剩余特征的90%，共27个特征）、80%、70%和60%的特征组合，对应的JM距离均值如图5所示。结果表明，2020年—2023年的JM距离均值随着比例缩小而降低。其中，2020年和2021年的降幅较大，而2022年和2023年的降幅较小。具体来看，2021年和2023年在比例从90%降低到80%时，JM距离均值下降幅度最大；2020年和2021年在比例从80%降低到70%时，下降幅度最大。综合各年份表现，累计特征重要性取90%时，

JM距离均值均达到各比例的最高值（2020年—2023年分别为1.780、1.782、1.777、1.777），因此确定累计特征重要性为90%的特征组合作为最终的分类优化方案。

如图6所示，采用面向对象的随机森林模型结合各特征优选方案的对比实验，2020年模型表现力由高到低依次为：实验5>实验3>JM最优90%>实验4>实验2>实验1；2021年表现力由高到低依次为：JM最优90%>实验5>实验3>实验4>实验2>实验1；2022年表现力由高到低依次为：实验5>JM最优90%>实验1>实验4>实验3>实验2；2023年表现力由高到低依次为：实验5>实验4>JM最优90%>实验3>实验1>实验2。实验3和实验4的精度仅次于实验5和JM距离优选90%的特征

方案, 因此, 在全部特征中地形、物候对于特征选取的贡献度较高。2021年采用JM优选特征90%的方案, 2020年、2022年和2023年采用全部特征进行分类。






图5 不同比例特征选择的JM均值

Fig.5 Mean values of JM for different proportional feature choices



(a) 不同实验方案OA值对比

(a) Comparison of OA values under different experimental schemes



(b) 不同实验方案Kappa值对比

(b) Comparison of Kappa values under different experimental schemes

图6 不同年份不同实验方案的OA和Kappa精度对比

Fig.6 Comparison of OA and Kappa accuracies under different experimental schemes across different years

4.3 面向对象树种分类结果及面积变化

栎类、松类和杉类是主要树种, 分布范围广、数量较多, 其余树种分布破碎、数量少 (图7)。其中: 栎类在除西部大部分地区、中部和东部小部分地区外均有大量分布; 松类集中分布在西部和南部; 杉类集中分布在东部。柏类、山茶类、青冈类、胡桃类、桦木类及竹类均呈少量零散分布; 栗类及杨柳类均呈少量零星分布。其中柏类

4.2.2 不同分类模型精度对比

由表6可见, 4个模型中, 随机森林模型表现力最好, 在此基础上结合面向对象方法进行分类效果较好。其中: 2020年、2021年和2023年各分类模型的精度由高到低排序为 RF>GBDT>CART>SVM; 2022年各分类模型的精度由高到低排序为: GBDT>RF>CART>SVM。随机森林的年均分类精度OA为0.740, Kappa系数为0.662, 采用面向对象的方法, OA为0.837, 提升了0.097, Kappa系数为0.791, 提升了0.129。

在不同树种的识别效果中, F_1 最高值的树种为竹类, 最低值为其他树种 (表7), 推测是由于秦巴山地树种多样性较高并且实地采集的样点类型有限所导致。总体而言, 使用JM距离进行特征优选后采用面向对象的随机森林模型的分类精度最高, 总体精度均值为0.837, Kappa系数为0.791, F_1 为0.799。

在秦巴山地均有分布; 青冈类西北部分布较少; 山茶类主要集中在中东部、东南部边缘地区, 呈条带状; 胡桃类多呈条带状分布在北部和南部边缘地区; 桦木类及竹类主要分布在西部。

受人类活动与气候变化影响, 秦岭以北森林呈减少趋势的主要集中在西部 (甘肃中部) 和北部边缘 (陕西中部), 呈增加趋势的分布在东部 (河南西南部) 与西部 (甘肃东部); 秦岭以南森林呈减少趋势的主要集中在中部 (陕西南部)、西部

(甘肃东南部)与东北部(河南西南部),呈增加趋势的分布在中西部(陕西西南部、甘肃东南部)与南部边缘(四川东北部、重庆北部)。

表6 各分类模型与特征优化的精度对比
Table 6 Comparison of the accuracy of each classification model with feature optimization

模型	评价指标	2020年	2021年	2022年	2023年	均值
RF	OA	0.739	0.739	0.753	0.727	0.740
	Kappa	0.661	0.659	0.675	0.651	0.662
RF(面向对象)	OA	0.829	0.833	0.838	0.848	0.837
	Kappa	0.781	0.788	0.791	0.803	0.791
SVM	OA	0.615	0.668	0.643	0.622	0.637
	Kappa	0.469	0.541	0.513	0.492	0.504
CART	OA	0.657	0.672	0.687	0.679	0.674
	Kappa	0.568	0.592	0.616	0.598	0.594
GBDT	OA	0.727	0.726	0.753	0.693	0.725
	Kappa	0.647	0.646	0.681	0.601	0.644

注：加粗部分为表现最佳的模型结果。

由表8可见：2020年—2023年，秦巴山地森林总面积增加257.87 km²，复合年均增长率增加0.42%，

呈轻微上升趋势(表8)。由图8可见2020年—2022年增幅最大，2022年—2023年增幅较小。

表7 随机森林面向对象分类F₁值
Table 7 Random Forest object-oriented classification F₁ values

树种	2020年	2021年	2022年	2023年	均值
松类	0.791	0.815	0.816	0.826	0.812
杉类	0.857	0.806	0.792	0.897	0.838
柏类	0.889	0.909	0.809	0.769	0.844
青冈类	0.909	0.947	0.646	0.889	0.848
山茶类	0.713	0.833	0.824	0.824	0.798
栎类	0.855	0.919	0.832	0.773	0.845
栗类	0.725	0.787	0.691	0.839	0.760
胡桃类	0.833	0.711	0.882	0.769	0.799
杨柳类	0.714	0.838	0.747	0.805	0.776
桦木类	0.824	0.794	0.876	0.923	0.854
竹类	0.857	0.923	0.871	0.828	0.870
其他树种	0.571	0.592	0.533	0.491	0.547
均值	0.795	0.823	0.777	0.803	0.799

注：加粗部分为F₁值最大的树种。




图7 2020年—2023年面向对象的树种分类图
Fig.7 Object-oriented tree classification chart from 2020 to 2023

4年间,树种发生了显著的变化。松类面积增长最为显著其中总变化量增加1457.65 km²,年均变化量增长485.88 km²;栎类则面积略有下降,总变化量降低614.26 km²,复合年均增长率降低1.62%(表8)。松类和栎类是森林面积变化贡献度最大的树种,两者的相互转换较为明显(图8)。部分小面积树种(如柏类、栗类和杨柳类)复合年均增长

率分别增长41.60%、14.07%和15.38%,保持较快增长;山茶类、桦木类、竹类和胡桃类则出现显著下降,其中桦木类复合年均增长率减少55.07%,降幅最大(表8)。整体来看,不同树种的演变存在明显差异,表现为针叶林(如松类、柏类)面积增加,而部分阔叶林(如山茶类、桦木类、胡桃类)面积降低。

表 8 树种面积变化分析表
Table 8 Analysis of tree species area changes

树种	2020年面积/km ²	2023年面积/km ²	总变化量/km ²	年均变化量/(km ² /年)	CAGR/%
松类	3827.78	5285.43	1457.65	485.88	11.35%
杉类	956.2	859.87	-96.33	-32.11	-3.42%
柏类	26.03	74.37	48.34	16.12	41.60%
青冈类	155.09	102.45	-52.64	-17.55	-12.92%
山茶类	432.69	89.15	-343.54	-114.51	-40.94%
栎类	13090.27	12476.01	-614.26	-204.75	-1.62%
栗类	78.13	115.99	37.86	12.62	14.07%
胡桃类	290.25	165.28	-124.97	-41.65	-17.20%
杨柳类	10.62	16.29	5.67	1.89	15.38%
桦木类	187.98	19.68	-168.3	-56.1	-55.07%
竹类	371.72	204.55	-167.17	-55.72	-18.05%
其他树种	1050.95	1326.48	275.53	91.84	8.07%
总计	20477.70	20735.57	257.87	85.96	0.42%

注：加粗部分为面积变化指标最大的树种。




图 8 2020 年—2023 年树种变化图

Fig.8 Tree species transitions from 2020 to 2023

从时序上看，杉类、柏类、青冈类、山茶类、栎类、栗类、胡桃类与竹类的面积呈“先降—后增—再降”的波动趋势，松类与杨柳类呈“先增—后降—再增”的趋势，而桦木类与其他树种呈“先增—后降”的趋势（图 8）。

总体而言，栎类和松类在秦巴山地森林中占主导地位，而面积占比小的树种转换则比较频繁。树种变换的年际差异可能受到分类误差、人类干扰、生态政策、气候异常、自然灾害及实际生态演变的综合影响。

5 讨 论

5.1 特征选择对分类精度的影响

在本研究中特征贡献率由高到低依次为地形、

物候、植被指数、光谱和纹理。地形特征则在复杂山地中表现更为稳定，并且能够有效降低山体效应带来的光谱差异，减少错分概率（王洁 等，2024）。在小区域、高光谱影像背景下，纹理特征更为突出，对于地物识别起到主要正向作用（谢天义 等，2023），推测是由于秦巴山地区域较大且采用中分辨率影像导致细节纹理缺失，并且地形复杂和树种多样导致同类地物差异较大，分类精度低。在本研究中加入纹理特征对于分类精度起负面作用，与已有关于树种分类的研究一致（冯林艳 等，2022），特征重要性排名中纹理特征处于靠后位置（王洁 等，2024）。纹理特征的加入对树种识别的效率受区域特征与纹理窗口大小一致性、影像数据的干扰信息数量、空间分辨率和纹理计算方式等多种条件的影响（Franklin 等，1996），分类精度对纹理特征的响应具有不规律性。

由于秦巴山地的自然地理环境复杂，特征选择的顺序和方案也随年际波动而改变。主要受 3 个方面的影响：一是山地云雨丰富，可用影像有限；二是在全年综合评估中，特定季节的敏感波段重要性易被较为稳定的特征削弱；三是特征变量本身存在年际间波动。

秦巴山地海拔最高可达 5495 m，河流众多，山地抬升所致地形云具有明显的增水效应，使得区域云雨丰富。表 9 所示云量>50% 的影像数量占全年影像的一半以上，直接影响了可用影像的时相分布（丁明涛 等，2025），从而对光谱、植被指数和纹理特征的提取产生较大影响。

表9 2020年—2023年 Sentinel-2 影像的云量统计表

Table 9 Cloud cover statistics of Sentinel-2 imagery from 2020 to 2023

指标	2020年	2021年	2022年	2023年
总影像数量	7251	7175	7223	7122
云量>50%的影像数量	4804	4354	4143	4020
比例/%	66.25	60.68	57.36	56.44

进一步研究发现不同季节的树种敏感波段存在差异：B4和B5波段有利于春季的树种区分，B3

和B5适用于夏季，B5在秋季表现较好，B11和B12则利于冬季的树种区分（图9）。与已有研究一致，季节性变化会对光谱特征产生多维度影响（党柯皓和李新通，2025）。然而，特定季节中的敏感波段在综合评估中往往特征重要性排序中位置靠后，一方面是特征重要性的评估是基于全年而非特定季节的结果，另一方面是光谱特征在综合评估中的重要性易被地形和物候这两种较为稳定的特征所削弱。




图9 不同季节各树种的光谱敏感性

Fig.9 Spectral sensitivity of different tree lasohispecies in various seasons

其次，研究通过提取2020年—2023年秦巴山地同一位置点的物候信息，发现树种生长季开始/结束的时间存在小幅度偏移的情况（图10），偏移量约为5日前后，说明物候值存在年际的小幅波动。

综上所述，不同特征的贡献率差异与秦巴山

地复杂的自然地理环境密切相关。依靠JM距离算法结合设计多种特征组合的实验方案，能够更加全面的评估特征的贡献度与不同特征组合形式的优势和差异。在未来研究中，可结合几何特征、雷达特征等多种图像信息提高分类的准确度。




图10 2020年—2023年同一位置样点的物候偏移

Fig.10 Phenological shifts at the same sample location from 2020 to 2023

5.2 样点数量与丰富度对分类精度的影响

树种分类结果经与中国林业科学院发布的1:25万《中国森林植被分布图》图集(2013年—2017年)进行空间叠置分析数据对比,结果显示在松类、杉类、栎类、栗类、胡桃类、桦木类和竹类分布基本一致,柏类的东南部、青冈类的东部、山茶类的东部及东南部、杨柳类的东北角存在错分。部分主要树种(如山茶类、柏类、栗类、竹类、桦木类、青冈类、杨柳类、胡桃类)在基础样本库中的样本量均不足40个,难以满足模型训练的需求。秦巴山地实际树种类型繁多并且实地采集的样点种类有限,导致样本在类别和数量的分布中存在不足。研究中 F_1 值最低的树种类别为其他

树种也进一步验证了样本不足对分类精度产生的负面影响。此外,受限于样本点的采集类别固定且部分主要树种的占地面积小,影像易存在混合像元(王怀警等,2019),导致该树种较难与其他树种进行区分,已有研究发现林分混合物异质性越高,分类精度越低(Modzelewska等,2020),这也是造成部分树种错分和漏分的原因之一。

为确保各类别树种具有足够的代表性样本用于模型训练和验证,研究实施了基于高分辨率影像的密集目视解译增补。通过Google Earth Engine平台提供的最新高分辨率影像,结合面向对象逐年分割结果图斑,对上述样本量不足的树种分布区域进行重点目视判读,在最大程度上补充了合理的样本数量,提升样本的空间覆盖度和代表性。未

来研究应补充基础数据的完整程度，提高样本采集的多样性和丰富性，包含实地采集、LiDAR与高光谱数据结合（Fassnacht等，2016），融合高分影像实现高精度、高分辨率和长时间序列的树种信息提取，为森林管理提供实践依据。

5.3 不同分类器与面向对象技术对山地树种遥感识别的响应

在本研究中，RF结合面向对象技术在树种中的表现优于传统的基于像元的方法。2020年—2023年的OA多年均提升约10%，Kappa系数的多年均值提升12.9%。这一结果与已有研究一致，表明在复杂的森林环境中，面向对象的方法能够取得较好的分类效果（Feret和Asner，2013）。因此，相较于基于像素的遥感识别，面向对象技术在提升分类精度方面更具有优势，与目前多数使用面向对象和基于像素的进行遥感地物分类的对比研究中（罗滨等，2025；聂倩等，2021；赵阳等，2023）结论一致。采用图像分割技术分类的结果离散点较少，能够减少遥感识别的椒盐现象（张磊等，2019）。本研究采用的SNIC参数（seeds=30、compactness=10）在大区域、中分辨率影像的山地环境中表现出良好的适用性，能够与地物边界相匹配，从而提升分类的精度。但在不同地形区的最优分割参数可能存在差异。如果逐地形区分别优化参数，可能会出现样本量被稀释的问题，导致模型的泛化能力下降。因此，本研究采用统一的分割参数，并通过特征优化设计来增强鲁棒性。然而采用该方法的研究多集中于高分辨率的地物提取（刘通和任鸿瑞，2022；岳巍等，2022），在中分辨率的遥感地物识别研究较少，因此本研究依据Sentinel-2影像展开大区域的树种遥感分类，填补了中分辨率尺度下秦巴山地的树种遥感精细识别的研究空缺。

在4种分类器中，模型综合表现力的排序依次为RF>GBDT>CART>SVM。SVM对高维特征具有较强的包容性和学习能力，而RF主要依据少数起决定性区分作用的特征进行分类，然而SVM在本研究中模型表现力最差，RF模型表现力最佳。SVM则是针对小样本处理的分类方法并且依赖所选样本的代表性（赵理君和唐娉，2016），同时模型参数的设置导致模型复杂度增加。对于中等数量且分布不平衡的数据集来讲，RF能够平衡误差，山

区的林分环境复杂，树木的光谱特征易受干扰，考虑可能存在特征丢失的情况，如特征变量中纹理特征的角二阶矩（gray_asm）和熵（gray_ent）两个变量在特征重要性贡献度极低。RF分类器对特征维数增加则表现得并不敏感（赵理君和唐娉，2016），由于这一特性，使得RF在复杂混合像元和有限样本的限制下能够维持模型准确度。因此，将RF与面向对象技术相结合于地形复杂、森林类型多样且样本量有限的地区较为契合。

6 结 论

本文以秦巴山地为研究区，依托GEE云平台调用2020年—2023年Sentinel-2卫星与SRTMGL1_003影像数据，提取光谱、植被指数、地形、纹理与物候特征，结合面向对象技术与SNIC分割算法，采用JM距离与特征组合构建特征优选实验方案，对比不同方案与模型的差异和效果，选择最优方案与模型获取秦巴山地树种分类结果。主要结论如下：

（1）特征重要性按降序划分依次为地形、物候、植被指数、纹理和光谱。地形特征在山区树种的分类中可作为优先选择的特征变量，结合物候与植被指数可作为特征组合方案。

（2）在满足有限样本、中分辨率影像和较大区域3个条件下，可优先选择随机森林与SNIC面向对象相结合的技术进行树种分类。由于不同的分割参数设置分类准确度不同，不同区域的分割参数设置分类准确度也存在差异（Cross等，2019），因此需要注意对象的分割尺度问题。

（3）2020年—2023年，秦巴山地森林面积呈轻微上升趋势，针叶林（如松类、柏类）面积增加，而部分阔叶林（如山茶类、桦木类、胡桃类）面积降低。松类与栎类对森林变化贡献度最大，面积占比小的树种转换则比较频繁。其中马尾松、华山松和高山松在松类中的占比最大，短柄枹栎、栓皮栎、锐齿槲栎和蒙古栎在栎类中占比最大，可适当发挥该树种的生态与经济价值。

参考文献(References)

- Abera T A, Heiskanen J, Maeda E E, Muhammed M A, Bhandari N, Vakkari V, Hailu B T, Pellikka P K E, Hemp A, Van Zyl P G and Zeuss D. 2024. Deforestation amplifies climate change effects on warming and cloud level rise in African Montane forests. *Nature Communications*, 15(1): 6992 [DOI: 10.1038/s41467-024-51324-7]

- Achanta R, Shaji A, Smith K, Lucchi A, Fua P and Süsstrunk S. 2012. SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11): 2274-2282 [DOI: 10.1109/TPAMI.2012.120]
- Achanta R and Süsstrunk S. 2017. Superpixels and polygons using simple non-iterative clustering//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE: 4895-4904 [DOI: 10.1109/CVPR.2017.520]
- An Q, Yang B J and Guo L. 2008. Method for object-oriented feature selection based on genetic algorithm with multi spectral images. *Transactions of the Chinese Society of Agricultural Engineering*, 24(4): 181-185 (安琼, 杨邦杰, 郭琳. 2008. 面向对象的多光谱图像特征遗传选优方法. *农业工程学报*, 24(4): 181-185) [DOI: 10.3321/j.issn:1002-6819.2008.04.035]
- Ballanti L, Blesius L, Hines E and Kruse B. 2016. Tree species classification using hyperspectral imagery: a comparison of two classifiers. *Remote Sensing*, 8(6): 445 [DOI: 10.3390/rs8060445]
- Belgiu M and Drăguț L. 2016. Random forest in remote sensing: a review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114: 24-31 [DOI: 10.1016/j.isprsjprs.2016.01.011]
- Biau G. 2012. Analysis of a random forests model. *The Journal of Machine Learning Research*, 13: 1063-1095
- Bolyn C, Michez A, Gauche P, Lejeune P and Bonnet S. 2018. Forest mapping and species composition using supervised per pixel classification of Sentinel-2 imagery. *Biotechnology, Agronomy and Society and Environment*, 22(3): 172-187 [DOI: 10.25518/1780-4507.16524]
- Chen G, Hao S F, Jiang B, Yu Y X, Che Z G, Liu H H and Yang R H. 2024. Identification and assessment of small landslides in densely vegetated areas based on airborne LiDAR technique. *Remote Sensing for Natural Resources*, 36(3): 196-205 (陈刚, 郝社锋, 蒋波, 喻永祥, 车增光, 刘汉湖, 杨容浩. 2024. 基于机载 LiDAR 技术植被茂密区小型滑坡识别与评价. *自然资源遥感*, 36(3): 196-205) [DOI: 10.6046/zrzyyg.2023101]
- Chen Z B, Li D X, Chen C, Huang W and Tang X F. 2025. Dynamic evaluation of landslide susceptibility based on machine learning and InSAR technology. *Journal of Natural Disasters*, 34(2): 56-65 (陈志波, 李鼎兴, 陈澄, 黄卫, 唐雪峰. 2025. 基于机器学习和 InSAR 技术的滑坡易发性动态评价. *自然灾害学报*, 34(2): 56-65) [DOI: 10.13577/j.jnd.2025.0206]
- Cheng H S, Wang Y H, Shan L, Chen Y, Yu K Y and Liu J. 2024. Mapping fine-scale carbon sequestration benefits and landscape spatial drivers of urban parks using high-resolution UAV data. *Journal of Environmental Management*, 370: 122319 [DOI: 10.1016/j.jenvman.2024.122319]
- Cross M, Scambos T, Pacifici F, Vargas-Ramirez O, Moreno-Sanchez R and Marshall W. 2019. Classification of tropical forest tree species using meter-scale image data. *Remote Sensing*, 11(12): 1411 [DOI: 10.3390/rs11121411]
- Dabboor M, Howell S, Shokr M and Yackel J. 2014. The Jeffries-Matusita distance for the case of complex Wishart distribution as a separability criterion for fully polarimetric SAR data. *International Journal of Remote Sensing*, 35(19): 6859-6873 [DOI: 10.1080/01431161.2014.960614]
- Dang K H and Li X T. 2025. Research on high spatiotemporal resolution NDVI calculation method supported by GEE. *Journal of Subtropical Resources and Environment*, 20(2): 187-197 (党柯皓, 李新通. 2025. GEE 支持下的高时空分辨率 NDVI 计算方法研究. *亚热带资源与环境学报*, 20(2): 187-197) [DOI: 10.19687/j.cnki.1673-7105.2025.02.022]
- Descals A, Verger A, Yin G F and Peñuelas J. 2020. Improved estimates of arctic land surface phenology using Sentinel-2 time series. *Remote Sensing*, 12(22): 3738 [DOI: 10.3390/rs12223738]
- Ding M T, Lu Z L, Li Z H, Jiang H and Huang W B. 2025. S2OGAN: a SAR-optical image generative translation method for texture and edge fidelity. *Journal of Earth Sciences and Environment*, 47(4): 806-828 (丁明涛, 卢昭龙, 李振洪, 江辉, 黄武彪. 2025. S2OGAN: 一种纹理与边缘保真的 SAR-光学影像生成式翻译方法. *地球科学与环境学报*, 47(4): 806-828) [DOI: 10.19814/j.jese.2024.10023]
- Dong M N, Xie X P, Li B, Wang F, Yang S and Li J L. 2022. Analysis of terrain feature extraction based on DEM. *Journal of Shanxi Normal University (Natural Science Edition)*, 36(2): 102-111 (董咪娜, 谢小平, 李冰, 王芳, 杨帅, 李佳丽. 2022. 基于 DEM 的地形特征提取分析. *山西师范大学学报(自然科学版)*, 36(2): 102-111) [DOI: 10.16207/j.cnki.1009-4490.2022.02.003]
- Fan Q, Huo C, Zhang B and Zhang J C. 2023. Land cover classification of fully polarimetric radar images based on feature selection. *Science of Surveying and Mapping*, 48(8): 102-110 (范强, 霍畅, 张兵, 张继超. 2023. 特征优选下的全极化雷达影像土地覆盖分类. *测绘科学*, 48(8): 102-110) [DOI: 10.16251/j.cnki.1009-2307.2023.08.013]
- Fassnacht F E, Latifi H, Stereńczak K, Modzelewska A, Lefsky M, Waser L T, Straub C and Ghosh A. 2016. Review of studies on tree species classification from remotely sensed data. *Remote Sensing of Environment*, 186: 64-87 [DOI: 10.1016/j.rse.2016.08.013]
- Feng L, Li L H, Guo S and Lu D. 2016. Comparative study on extracting vegetation phenology information from HJ-1 A NDVI and MODIS NDVI time series. *Remote Sensing Technology and Application*, 31(6): 1158-1166 (冯莉, 李柳华, 郭松, 卢获. 2016. HJ-1A NDVI 与 MODIS NDVI 时间序列提取植被物候特征对比研究. *遥感技术与应用*, 31(6): 1158-1166) [DOI: 10.11873/j.issn.1004-0323.2016.6.1158]
- Feng L Y, Tan B X, Liu Q W, Zhou C F, Yu H, Zhang H R and Fu L Y. 2022. Land cover and tree species classification of the Chongli Winter Olympic core area based on GF-2 images. *Scientia Silvae Sinicae*, 58(10): 10-23. (冯林艳, 谭炳香, 刘清旺, 周超凡, 于航, 张会儒, 符利勇. 2022. 基于 GF-2 影像的崇礼冬奥核心区土地覆盖和树种分类. *林业科学*, 58(10): 10-23) [DOI: 10.11707/j.1001-7488.20221002]
- Feret J B and Asner G P. 2013. Tree species discrimination in tropical forests using airborne imaging spectroscopy. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1): 73-84 [DOI: 10.1109/

- TGRS.2012.2199323]
- Franklin S E, Wulder M A and Lavigne M B. 1996. Automated derivation of geographic window sizes for use in remote sensing digital image texture analysis. *Computers and Geosciences*, 22(6): 665-673 [DOI: 10.1016/0098-3004(96)00009-X]
- Gärtner P, Förster M and Kleinschmit B. 2016. The benefit of synthetically generated RapidEye and Landsat 8 data fusion time series for riparian forest disturbance monitoring. *Remote Sensing of Environment*, 177: 237-247 [DOI: 10.1016/j.rse.2016.01.028]
- Grabska E, Hostert P, Pflugmacher D and Ostapowicz K. 2019. Forest stand species mapping using the Sentinel-2 time series. *Remote Sensing*, 11(10): 1197 [DOI: 10.3390/rs11101197]
- Han B B and Chen S B. 2020. Time series remote sensing image classification method based on GEE. *Global Geology*, 39(3): 706-713 (韩冰冰, 陈圣波. 2020. 基于GEE时间序列遥感影像分类方法研究. *世界地质*, 39(3): 706-713) [DOI: 10.3969/j.issn.1004-5589.2020.03.022]
- He M M, Guo Q, Li A, Chen J, Chen B and Feng X X. 2018. Automatic fast feature-level image registration for high-resolution remote sensing images. *National Remote Sensing Bulletin*, 22(2): 277-292 (何梦梦, 郭擎, 李安, 陈俊, 陈勃, 冯旭祥. 2018. 特征级高分辨率遥感图像快速自动配准. *遥感学报*, 22(2): 277-92) [DOI: 10.11834/jrs.20186420]
- Hermosilla T, Bastyr A, Coops N C, White J C and Wulder M A. 2022. Mapping the presence and distribution of tree species in Canada's forested ecosystems. *Remote Sensing of Environment*, 282: 113276 [DOI: 10.1016/j.rse.2022.113276]
- Hermosilla T, Wulder M A, White J C, Coops N C, Bater C W and Hobart G W. 2024. Characterizing long-term tree species dynamics in Canada's forested ecosystems using annual time series remote sensing data. *Forest Ecology and Management*, 572: 122313 [DOI: 10.1016/j.foreco.2024.122313]
- Hou Y C, Zhao P X, Yang W Z and Zhang X L. 2016. Forest classification and accuracy assessment in ZY3 image with SVM method. *Journal of Northwest Forestry University*, 31(1): 180-185 (侯逸晨, 赵鹏祥, 杨伟志, 张晓莉. 2016. 基于SVM的资源三号影像林地分类及精度评价研究. *西北林学院学报*, 31(1): 180-185) [DOI: 10.3969/j.issn.1001-7461.2016.01.32]
- Huo X L, Niu Z G, Zhang B, Liu L S and Li X. 2023. Remote sensing feature selection for alpine wetland classification. *National Remote Sensing Bulletin*, 27(4): 1045-1060 (霍轩琳, 牛振国, 张波, 刘林崧, 李霞. 2023. 高寒湿地分类的遥感特征优选研究. *遥感学报*, 27(4): 1045-1060) [DOI: 10.11834/jrs.20222080]
- Jia S C, Xue D J and Li C R. 2018. Application of Polarization Characteristic Combination in ALOS PALSAR Data Classification. *Bulletin of surveying and mapping*, 7: 29-33, 47 (贾诗超, 薛东剑, 李成绕. 2018. 极化特征组合在ALOS PALSAR数据地物分类中的应用. *测绘通报*, (7): 29-33, 47) [DOI: 10.13474/j.cnki.11-2246.2018.0204]
- Kang M Y and Zhu Y. 2007. Discussion and analysis on the geo-ecological boundary in Qinling Range. *Acta Ecologica Sinica*, 27(7): 2774-2784 (康慕谊, 朱源. 2007. 秦岭山地生态分界线的论证. *生态学报*, 27(7): 2774-2784) [DOI: 10.3321/j.issn:1000-0933.2007.07.014]
- Laurin G V, Puletti N, Hawthorne W, Liesenberg V, Corona P, Papale D, Chen Q and Valentini R. 2016. Discrimination of tropical forest types, dominant species, and mapping of functional guilds by hyperspectral and simulated multispectral Sentinel-2 data. *Remote Sensing of Environment*, 176: 163-176 [DOI: 10.1016/j.rse.2016.01.017]
- Li B, Li C G and Li Y. 2021. Research on larch extraction in Saihanba mechanical forest farm based on Sentinel-2 data. *Forest Resources Wamagement*, (2): 117-123 (李斌, 李崇贵, 李煜. 2021. 基于Sentinel-2数据的塞罕坝机械林场落叶松人工林提取. *林业资源管理*, (2): 117-123) [DOI: 10.13466/j.cnki.lyzygl.2021.02.016]
- Li H D, Gao X H and Tang M. 2021. Land cover classification for SPOT-6 image from decision fusion method. *Journal of Geo-information Science*, 23(5): 928-937 (李宏达, 高小红, 汤敏. 2021. 基于决策融合的SPOT-6影像土地覆被分类研究. *地球信息科学学报*, 23(5): 928-37) [DOI: 10.12082/dqxxkx.2021.200339]
- Li K Y, Wang X M, Li R and Li D. 2024. The object-oriented land use classification incorporating auxiliary data sets. *Acta Scientiarum Naturalium Universitatis Sunyatseni*, 63(1): 34-44 (李坤玉, 王雪梅, 李锐, 李顿. 2024. 融入辅助数据集的面向对象土地利用分类研究. *中山大学学报(自然科学版)(中英文)*, 63(1): 34-44) [DOI: 10.13471/j.cnki.acta.snus.2023D031]
- Li X N, Chen M G, He S Y, Xu X Y, He L X, Wang L, Gao Y, Tang F D, Gong T, Wang W Y, Xu M, Liu C Y, Yu L, Liu W G and Yang W Y. 2024. Estimation of soybean yield based on high-throughput phenotyping and machine learning. *Frontiers in Plant Science*, 15: 1395760 [DOI: 10.3389/fpls.2024.1395760]
- Liang J, Zheng Z W, Xia S T, Zhang X T and Tang Y Y. 2020. Crop recognition and evaluation using red edge features of GF-6 satellite. *Journal of Remote Sensing (in Chinese)*, 24(10): 1168-1179 (梁继, 郑镇炜, 夏诗婷, 张晓彤, 唐媛媛. 2020. 高分六号红边特征的农作物识别与评估. *遥感学报*, 24(10): 1168-1179) [DOI: 10.11834/jrs.20209289]
- Liang J X, Sawut M, Cui J T, Hu X, Xue Z J, Zhao M, Zhang X Y, Rouzi A, Ye X W and Xilike A. 2024. Object-oriented multi-scale segmentation and multi-feature fusion-based method for identifying typical fruit trees in arid regions using Sentinel-1/2 satellite images. *Scientific Reports*, 14(1): 18230 [DOI: 10.1038/s41598-024-68991-7]
- Liu T and Ren H R. 2022. Object-oriented extraction of paddy rice planting areas using phenological features from the GEE platform. *Transactions of the Chinese Society of Agricultural Engineering*, 38(12): 189-196 (刘通, 任鸿瑞. 2022. GEE平台下利用物候特征进行面向对象的水稻种植分布提取. *农业工程学报*, 38(12): 189-196) [DOI: 10.11975/j.issn.1002-6819.2022.12.022]
- Luo B, Mao D H, Zhang J P, Wang M and Wang Z M. 2025. Fine classification of urban wetlands based on Sentinel-1/2 images and random forest classification in the built-up area of Haikou. *Geographical Science*, 45(2): 389-402 (罗滨, 毛德华, 张金萍, 王铭, 王宗明. 2025. 基于Sentinel-1/2影像和随机森林的海口市建成区城

- 市湿地精细分类. 地理科学, 45(2): 389-402 [DOI: 10.11975/j.issn.1002-6819.2022.12.022]
- Ma M F, Liu J H, Liu M X, Zeng J C and Li Y H. 2021. Tree Species classification based on Sentinel-2 imagery and random forest classifier in the eastern regions of the Qilian Mountains. *Forests*, 12(12): 1736 [DOI: 10.3390/f12121736]
- Mallinis G, Koutsias N, Tsakiri-Strati M and Karteris M. 2008. Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(2): 237-250 [DOI: 10.1016/j.isprsjprs.2007.08.007]
- Maxwell A E, Warner T A and Fang F. 2018. Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, 39(9): 2784-2817 [DOI: 10.1080/01431161.2018.1433343]
- Modzelewska A, Fassnacht F E and Stereńczak K. 2020. Tree species identification within an extensive forest area with diverse management regimes using airborne hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, 84: 101960 [DOI: 10.1016/j.jag.2019.101960]
- Nie Q, Qi K K and Zhao Y F. 2021. Object-oriented classification of high-resolution image combining super-pixel segmentation. *Bulletin of Surveying and Mapping*, (6): 44-49 (聂倩, 七珂珂, 赵艳福. 2021. 融入超像素分割的高分辨率影像面向对象分类. 测绘通报, (6): 44-49) [DOI: 10.13474/j.cnki.11-2246.2021.0174]
- Ni-Meister W, Albanese A and Lingo F. 2024. Assessing data preparation and machine learning for tree species classification using hyperspectral imagery. *Remote Sensing*, 16(17): 3313 [DOI: 10.3390/rs16173313]
- Ottosen T B, Petch G, Hanson M and Skjøth C A. 2020. Tree cover mapping based on Sentinel-2 images demonstrate high thematic accuracy in Europe. *International Journal of Applied Earth Observation and Geoinformation*, 84: 101947 [DOI: 10.1016/j.jag.2019.101947]
- Puyravaud J P. 2003. Standardizing the calculation of the annual rate of deforestation. *Forest Ecology and Management*, 177(1/3): 593-596 [DOI: 10.1016/S0378-1127(02)00335-3]
- Qian L H, Yu C L, Xu J and Wang S Q. 2016. Extracting water body information based on canny algorithm and decision tree. *Geomatics and Spatial Information Technology*, 39(10): 178-181 (钱立辉, 于成龙, 徐进, 王抒群. 2016. 基于Canny算子与决策树模型的水体信息提取研究. 测绘与空间地理信息, 39(10): 178-181) [DOI: 10.3969/j.issn.1672-5867.2016.10.051]
- Rahbek C, Borregaard M K, Colwell R K, Dalsgaard B, Holt B G, Morueta-Holme N, Nogues-Bravo D, Whittaker R J and Fjeldså J. 2019. Humboldt's enigma: what causes global patterns of mountain biodiversity?. *Science*, 365(6458): 1108-1113 [DOI: 10.1126/science.aax0149]
- Richter T, Geres L, König S, Braziunas K H, Senf C, Thom D, Bässler C, Müller J, Seidl R and Seibold S. 2024. Effects of climate and forest development on habitat specialization and biodiversity in Central European mountain forests. *Communications Biology*, 7(1): 1518 [DOI: 10.1038/s42003-024-07239-6]
- Sharma V K, Luthra D, Mann, E, Chaudhary P, Chowdary V M and Jha C S. 2022. Change detection and feature extraction using high-resolution remote sensing images. *Remote Sensing in Earth Systems Sciences*, 5(3): 154-164 [DOI: 10.1007/s41976-022-00073-6]
- Smyčka J, Roquet C, Boleda M, Alberti A, Boyer F, Douzet R, Perrier C, Rome M, Valay J G, Denoeud F, Šemberová K, Zimmermann N E, Thuiller W, Wincker P, Alsos I G, Coissac E and Lavergne S. 2022. Tempo and drivers of plant diversification in the European mountain system. *Nature Communications*, 13(1): 2750 [DOI: 10.1038/s41467-022-30394-5]
- Tan S, Wu B F and Zhang X. 2019. Mapping paddy rice in the Hainan Province using both Google Earth Engine and remote sensing images. *Journal of Geo-information Science*, 21(6): 937-947 (谭深, 吴炳方, 张鑫. 2019. 基于Google Earth Engine与多源遥感数据的海南水稻分类研究. 地球信息科学学报, 21(6): 937-947) [DOI: 10.12082/dqxxkx.2019.180423]
- Tassi A and Vizzari M. 2020. Object-oriented LULC classification in Google Earth Engine combining SNIC, GLCM, and machine learning algorithms. *Remote Sensing*, 12(22): 3776 [DOI: 10.3390/rs12223776]
- Thakur S, Negi V S, Dhyani R, Satish K V and Bhatt I D. 2021. Vulnerability assessments of mountain forest ecosystems: a global synthesis. *Trees, Forests and People*, 6: 100156 [DOI: 10.1016/j.tfp.2021.100156]
- Torresan C, Luyssaert S, Filippa G, Imangholiloo M and Gaulton R. 2022. Remote sensing technologies for assessing climate-smart criteria in mountain forests//Tognetti R, Smith M, Panzacchi P, eds. *Climate-Smart Forestry in Mountain Regions*. Cham: Springer: 399-433 [DOI: 10.1007/978-3-030-80767-2_11]
- Wan J, Wang C C, Zhu J J and Fu H Q. 2024. Research progress on tomographic SAR three-dimensional imaging methods and forest parameter inversion. *National Remote Sensing Bulletin*, 28(3): 576-590 (万杰, 汪长城, 朱建军, 付海强. 2024. 层析SAR三维成像方法与森林参数反演研究进展. 遥感学报, 28(3): 576-590) [DOI: 10.11834/jrs.20222107]
- Wang H J, Tan B X, Wang X H, Fang X F and Li S M. 2019. Multiple classifiers combination method for precise classification of forest type. *Remote Sensing Information*, 34(2): 104-112 (王怀警, 谭炳香, 王晓慧, 房秀凤, 李世明. 2019. 多分类器组合森林类型精细分类. 遥感信息, 34(2): 104-112) [DOI: 10.3969/j.issn.1000-3177.2019.02.017]
- Wang J, Li H K, Long B P and Zhang J Y. 2024. Tree species identification in southern hilly areas using sentinel series images with multi-temporal features. *Journal of Northeast Forestry University*, 52(3): 60-68 (王洁, 李恒凯, 龙北平, 张建莹. 2024. 应用多时序特征的哨兵系列影像对南方丘陵区树种识别. 东北林业大学学报, 52(3): 60-68) [DOI: 10.13759/j.cnki.dlxb.2024.03.003]
- Wang S F, Liu C, Wu H B and Li W Y. 2024. Urban tree species classification combining spaceborne LiDAR and multispectral imagery. *Journal of Tongji University (Natural Science)*, 52(6): 970-981 (王

- 书凡, 刘春, 吴杭彬, 李巍岳. 2024. 结合星载激光和多光谱影像的城市树种分类. 同济大学学报(自然科学版), 52(6): 970-981 [DOI: 10.11908/j.issn.0253-374x.22359]
- Xiao Q L, Zhang J L, Cao J, Liu L, Wang F P, Yin T Y and Yang K. 2024. Research on the classification of dominant tree species in Pu'er city by coupling multiple characteristics and multiple phases. *Forest Engineering*, 40(2): 117-126 (肖庆琳, 张加龙, 曹军, 刘灵, 王飞平, 殷唐燕, 杨坤. 2024. 耦合多特征多时相的普洱市优势树种分类研究. *森林工程*, 40(2): 117-126) [DOI: 10.3969/j.issn.1006-8023.2024.02.013]
- Xie J Y, Lin A Q, Wu H, Wu Z W, Wu W B and Yu Q Y. 2024. JAM-R-CNN deep learning network model for remote sensing recognition of terraced fields. *National Remote Sensing Bulletin*, 28(12): 3136-3146 (谢君洋, 林安琪, 吴浩, 吴紫薇, 吴文斌, 余强毅. 2024. 面向梯田遥感识别的JAM-R-CNN深度网络模型. *遥感学报*, 28(12): 3136-3146) [DOI: 10.11834/jrs.20233126]
- Xie T Y, Pan J, Sun Y L and Zheng G. 2023. Classification of forest tree species using multi-dimensional remote sensing information coordination. *Journal of Northeast Forestry University*, 51(3): 73-78 (谢天义, 潘洁, 孙玉琳, 郑光. 2023. 应用多维遥感信息协同的森林树种分类. *东北林业大学学报*, 51(3): 73-78) [DOI: 10.3969/j.issn.1000-5382.2023.03.013]
- Xiong H L, Zhou X C, Wang X Q and Cui Y J. 2021. Mapping the spatial distribution of tea plantations with 10 m resolution in Fujian Province using Google Earth Engine. *Journal of Geo-information Science*, 23(7): 1325-1337 (熊皓丽, 周小成, 汪小钦, 崔雅君. 2021. 基于GEE云平台的福建省10m分辨率茶园专题空间分布制图. *地球信息科学学报*, 23(7): 1325-1337) [DOI: 10.12082/dqxxkx.2021.200583]
- Xue M J, Chen G, Zhang X, Yu J, Duan M R and Chen R F. 2015. Research on object-oriented classification with ZY-3 satellite image. *Bulletin of Surveying and Mapping*, (7): 42-45 (薛梦姣, 陈刚, 张笑, 于靖, 段淼然, 陈瑞芳. 2015. 面向对象的资源三号卫星影像分类研究. *测绘通报*, (7): 42-45) [DOI: 10.13474/j.cnki.11-2246.2015.0207]
- Yang B, Wu L, Liu M L, Liu X N, Zhao Y X and Zhang T W. 2024. Mapping forest tree species using Sentinel-2 time series by taking into account tree age. *Forests*, 15(3): 474 [DOI: 10.3390/f15030474]
- Yang H, Sun H L, Ye M, Ge X Y, Wu F, Jin X L and Wu R. 2024. Characteristics of vegetation phenology changes and its response to climate change in the Yili River Valley. *Acta Agrestia Sinica*, 32(3): 859-868 (杨涵, 孙慧兰, 叶茂, 葛翔宇, 吴芳, 金晓亮, 伍蕊. 2024. 伊犁河谷植被物候变化特征及其对气候变化的响应. *草地学报*, 32(3): 859-868) [DOI: 10.11733/j.issn.1007-0435.2024.03.022]
- Yue W, Li S M, Li Z Y, Liu Q W, Pang Y and Si L. 2022. Identification of dominant tree species based on multi-temporal Sentinel-2 images and SNIC segmentation algorithm. *Scientia Silvae Sinicae*, 58(9): 60-69 (岳巍, 李世明, 李增元, 刘清旺, 庞勇, 斯林. 2022. 基于多时相Sentinel-2影像和SNIC分割算法的优势树种识别. *林业科学*, 58(9): 60-69) [DOI: 10.11707/j.1001-7488.20220906]
- Zhang H Y, Zhang Y, Tian Z Z, Wu J M, Li M Z and Liu K D. 2023. Extraction of planting structure of winter wheat using GBDT and Google Earth Engine. *Spectroscopy and Spectral Analysis*, 43(2): 597-607 (张海洋, 张瑶, 田泽众, 吴江梅, 李民赞, 刘凯迪. 2023. 基于GBDT和Google Earth Engine的冬小麦种植结构提取. *光谱学与光谱分析*, 43(2): 597-607) [DOI: 10.3964/j.issn.1000-0593(2023)02-0597-11]
- Zhang L, Gong Z N, Wang Q W, Jin D D and Wang X. 2019. Wetland mapping of Yellow River Delta wetlands based on multi-feature optimization of Sentinel-2 images. *National Remote Sensing Bulletin*, 23(2): 313-326 (张磊, 宫兆宁, 王启为, 金点点, 汪星. 2019. Sentinel-2影像多特征优选的黄河三角洲湿地信息提取. *遥感学报*, 23(2): 313-326) [DOI: 10.11834/jrs.20198083]
- Zhang S R, Fu B L, Gao E T, Jia M M, Sun W W, Wu Y and Zhou G Q. 2025. Combining UAV-LiDAR point clouds and SSAFormer algorithms for fine classification of mangrove communities. *National Remote Sensing Bulletin*, 29(5): 1140-1163 (张书嵘, 付波霖, 高二涛, 贾明明, 孙伟伟, 武炎, 周国清. 2025. 联合UAV-LiDAR点云和SSAFormer的红树林群落精细分类. *遥感学报*, 29(5): 1140-1163) [DOI: 10.11834/jrs.20243515]
- Zhang Y K, Wang J L, Su H and Cheng F. 2021. Study on landform classification of dual-scale watershed units based on CART: a case study of the tropic of cancer (Yunnan Section). *Geography and Geo-Information Science*, 37(2): 84-92 (张艳可, 王金亮, 苏怀, 程峰. 2021. 基于CART决策树的双尺度流域单元地貌分类研究——以北回归线(云南段)地区为例. *地理与地理信息科学*, 37(2): 84-92) [DOI: 10.3969/j.issn.1672-0504.2021.02.012]
- Zhao L J and Tang P. 2016. Scalability analysis of typical remote sensing data classification methods: a case of remote sensing image scene. *National Remote Sensing Bulletin*, 20(2): 157-171 (赵理君, 唐嫔. 2016. 典型遥感数据分类方法的适用性分析——以遥感图像场景分类为例. *遥感学报*, 20(2): 157-171) [DOI: 10.11834/jrs.20164279]
- Zhao Y, Tian Z, Li W W, Xue Z Y and Zhu J H. 2023. Study on the refined classification method of mangrove tree species based on Sentinel-2 MSI images combined with object-oriented. *Marine Science Bulletin*, 42(3): 352-360 (赵阳, 田震, 李尉尉, 薛志泳, 朱建华. 2023. 基于Sentinel-2 MSI影像与面向对象相结合的红树林树种精细化分类方法研究. *海洋通报*, 42(3): 352-360) [DOI: 10.11840/j.issn.1001-6392.2023.03.012]
- Zhao Y P, Liu J F, Wang Q, Huang R Z, Sun J Y, Nie W and Yang S W. 2024. Differences in the response of different vegetation types to frost event and their driving forces. *Acta Ecologica Sinica*, 44(15): 6744-6757 (赵倚霏, 刘建锋, 王奇, 黄睿智, 孙婧依, 聂稳, 杨绍微. 2024. 不同植被类型物候对冰冻事件的响应差异及其驱动力. *生态学报*, 44(15): 6744-6757) [DOI: 10.20103/j.stxb.202311142468]
- Zhou X C, Zheng L and Huang H Y. 2021. Classification of forest stand based on multi-feature optimization of UAV visible light remote sensing. *Scientia Silvae Sinicae*, 57(6): 24-36 (周小成, 郑磊, 黄洪宇. 2021. 基于多特征优选的无人机可见光遥感林分类型分类. *林业科学*, 57(6): 24-36) [DOI: 10.11707/j.1001-7488.20210603]

Fine-scale tree species mapping in mountainous regions using integrated machine learning and object-based remote sensing: A case study of the Qinling-Daba Mountains

WANG Xiaofeng^{1,2}, YANG Zihuan¹, LIU Shirong³, ZHOU Chaowei¹,
CHEN Jizhen³, HUANG Zhilin³, BAI Juan¹

1. School of Land Engineering, Chang'an University, Xi'an 710054, China;

2. Key Laboratory of Shaanxi Land Consolidation, Xi'an 710054, China;

3. Key Laboratory of Forest Ecology and Environment of National Forestry and Grassland Administration,
Ecology and Nature Conservation Institute, Chinese Academy of Forestry, Beijing 100091, China

Abstract: Mountain forests, as critical terrestrial carbon reservoirs, exert significant impacts on atmospheric chemical processes, landscape ecological functions, and biodiversity through key climate feedback mechanisms. However, owing to the constraints of complex topography and observation conditions, the accurate characterization of tree species composition and spatial distribution in mountain forests remains challenging. The integration of terrestrial satellite monitoring technologies, represented by Sentinel-2, with artificial intelligence algorithms has greatly transformed traditional forest survey approaches, offering new opportunities for tree species monitoring and fine-scale mapping. In this study, ground sample plots and multisource remote sensing data were integrated, and multitemporal Sentinel-2 imagery from 2020 to 2023 was processed via the Google Earth Engine platform. A multidimensional feature optimization scheme was developed using the Jeffries-Matusita (JM) distance, followed by SNIC segmentation and machine learning approaches to build a random forest model with optimal features for fine-scale tree species classification in the Qinling-Daba Mountains, thereby revealing spatiotemporal differentiation patterns. The results are as follows: (1) Topographic features are key variables for tree species identification in the Qinling-Daba Mountains, and JM distance-based feature combination schemes can effectively improve feature selection. (2) Under conditions of limited samples, medium-resolution imagery, and large-scale areas, the object-oriented random forest model based on SNIC segmentation demonstrated robust classification performance, with an average overall accuracy of 0.837, a kappa coefficient of 0.791, and a mean F_1 -score of 0.799. (3) *Quercus*, *Pinus*, and *Cunninghamia* species were widely distributed, whereas other species exhibited scattered distributions. (4) From 2020 to 2023, the forest area showed a slight upward trend, indicating continuous ecological improvement in the region. *Pinus* and *Quercus* contributed the most to forest change, whereas species with smaller area proportions exhibited more frequent transitions. This study provides valuable data support for carbon sink assessment and biodiversity conservation in complex mountain forest ecosystems.

Key words: mountain forests, tree species identification, spatial distribution dynamics of tree species, remote sensing data, spatiotemporal differentiation of tree species

Supported by National Natural Science Foundation of China (No. 72349002); Fundamental Research Funds of CAF (No. CAFYBB2024ZA001)