

# 基于 GEE 的森林动态变化研究

——以中央站国家级自然保护区为例

赵晨曦<sup>1,2</sup>, 姚允龙<sup>1,2\*</sup>, 王文姬<sup>1,2</sup>, 付怡<sup>1,2</sup>, 张鹏飞<sup>3</sup>, 张冰<sup>3</sup>, 潘明哲<sup>3</sup>

(1. 东北林业大学湿地生物多样性保护研究中心, 哈尔滨 150040;

2. 东北林业大学野生动物与自然保护地学院, 哈尔滨 150040;

3. 黑龙江省自然资源权益调查监测院, 哈尔滨 150080)

**摘要:**森林资源是我国极其珍贵的自然资源,森林内组分的精确信息对森林资源的保护和管理至关重要。然而,传统的实地森林清查费时费力,迫切需要一种快速准确的调查方法。本研究基于 Google Earth Engine(GEE)云计算平台及多时相 Sentinel-2(S-2)影像,综合地形以及气候等环境因素建立了随机森林模型,对黑龙江中央站黑嘴松鸡国家级自然保护区 2019 年及 2023 年的森林群落进行分类。结果显示,分类的总体精度为 0.90, kappa 系数为 0.87。其中,地形因素(海拔与坡度)对分类结果具有重要影响。此外,为了明确两个时期的森林群落变化,我们利用转移矩阵进行了空间分析,确定了白桦群落是变化最为剧烈的森林群落。本研究绘制了较高准确性的森林群落分布图,为黑龙江中央站黑嘴松鸡国家级自然保护区后续管理制度与政策的提出提供了科学依据。

**关键词:**大规模森林制图;森林群落变化;GEE;随机森林;Sentinel-2

**中图分类号:**S76 **文献标志码:**A **文章编号:**1672-2736(2024)-0051-11

## 0 引言

森林是陆地三大生态系统之一,可以保护土壤免受侵蚀,协助水文循环,是生物多样性保护的热点地区<sup>[1,2]</sup>。但由于人为活动的干扰与环境变化的威胁,全球森林面积大幅减少。准确的大规模森林组成图对于自然资源的管理和保护至关重要<sup>[3]</sup>,如可持续森林管理和规划、森林火灾监测<sup>[4]</sup>、生物多样性监测<sup>[5]</sup>以及陆地碳储量和通量评估<sup>[3,6-8]</sup>。基于实地调查的森林清查是许多区域最准确的数据来源,然而传统的实地调查需要花费大量的人力、物力,对于大范围的采样往往需要昂贵的时间成本<sup>[9]</sup>,因此需要一种客观经济的调查方法,帮助我们快速获得跨空间尺度的连续、一致的信息。

卫星遥感被认为是解决这一问题的有效方法,其具有覆盖面积大、数据采集可重复等特点,是森林组成变化监测和绘图的有效工具<sup>[10]</sup>。

Sentinel-2(S-2)获得的中等空间分辨率遥感数据已被广泛用于大规模森林参数估计和分类,例如,Grabska 等人使用 S-2 对波兰喀尔巴阡山脉的 11 个树种进行分类,准确率达到 85%<sup>[11]</sup>。然而,在大规模的分类任务中,获取和处理海量图像数据费时费力。近年来,Google Earth Engine(GEE)云平台已经被认为是用于大规模分类的良好工具,它具有大量数据访问和下载权限,并且可以使用高性能云计算平台来实现大规模地理空间数据处理<sup>[12]</sup>。GEE 平台提供了丰富的遥感数据集供用户进行研究,包括卫星影像、地表变化数据等,研究者在 GEE 上无需下载遥感影像,通过代码即可对感兴趣的影像进行在线调用和分析。

监督分类是大规模森林群落组成图绘制的常用方法<sup>[13]</sup>。其中,基于机器学习(ML)的监督分类模型可以对高维数据进行非线性分类,使其能够有效地进行大规模制图。目前有各种广泛

使用的基于 ML 的模型,包括随机森林(RF)<sup>[14]</sup>,支持向量机(SVM)<sup>[15]</sup>和决策树(DT)等<sup>[16]</sup>。在解决多类别分类问题时,树结构算法比 SVM 具有更大的优越性。作为多个 DT 的集合,RF 模型比 DT 模型更稳定。因此 RF 模型在自动分类方面的性能往往优于 DT 模型<sup>[17]</sup>。Parth Bhatt 等人使用 RF、SVM 和平均神经网络(avNNet)三种不同的机器学习算法对密歇根州的自然植被群落进行分类。结果表明 RF 提供了最好的准确性<sup>[18]</sup>。然而,哪些特征能够更好地帮助模型执行最精确的决策始终是各个研究的热点<sup>[19]</sup>。Ning 等人对新西兰一处地区的本土森林进行了树种分类,指出海拔等地形特征在随机森林分类模型中具有最高的重要性<sup>[10]</sup>。同时也有研究指出 S-2 自身携带的信息能够完成高精度的分类工作<sup>[20]</sup>,光谱信息以及环境因素等各个特征如何影响以及影响了多少分类的决策还需要进一步探究。

黑龙江中央站黑嘴松鸡国家级自然保护区位于黑龙江省大、小兴安岭交接地区,具有丰富的森林资源。但随着时间推移,其森林结构发生了一系列变化。因此本研究旨在基于 GEE 平台及 S-2 影像建立随机森林模型并对中央站区域的森林群落进行分类,探索保护区内优势群落的

分布与动态变化。具体研究目标包括以下三个部分:(1)基于 S-2 影像建立高精度的随机森林分类模型并绘制两个时期的中央站保护区森林群落组成图;(2)探究不同输入特征的重要性,确定模型分类的关键变量;(3)对两个时期的群落分类图进行对比分析,了解各个群落的面积及空间变化趋势。

## 1 材料与方法

### 1.1 研究区域

黑龙江中央站黑嘴松鸡国家级自然保护区位于黑龙江省黑河市嫩江县境内,地处大、小兴安岭山脉交接处的伊勒呼里山南部(E125°44'57"~126°13'31",N50°38'23"~50°48'10")。属温带大陆性季风气候,兼有寒温带大陆季风气候特征。保护区最高海拔 620.1 m,最低海拔 330.0 m,坡度多在 5°-15°之间。总面积为 46743 ha。其中,核心区面积 20271 ha,缓冲区 10194 ha,实验区 16278 ha,森林覆盖率达 82.4%。保护区内优势群落包括白桦群落、落叶松群落、蒙古栎群落以及蒙古栎-黑桦群落等<sup>[21]</sup>(图 1)。




图 1 研究区域位置与样本点分布

(来源:中国科学院环境资源科学数据中心的《2022 年中国区县行政区划边界数据》)

## 1.2 数据获取与预处理

### 1.2.1 遥感数据

本研究基于 GEE 平台对黑龙江中央站黑嘴松鸡国家级自然保护区内的森林群落进行研究, S-2 卫星以 10-20m 的空间分辨率每隔五天收集一次数据, 图像包括 13 个光谱波段, 从可见光、红边、近红外到短波红外。这些波段的分辨率如表 1 所示。本研究在 GEE 云平台上分别调用中央站区域 2019 年以及 2023 年的 Sentinel-2 level-2A 地表反射图像, 并选择植被生长旺盛的 6-9 月期间的影像, 经过云量筛选去除不合格的影像, 最终获取了 157 张 2019 年影像、144 张 2023 年影像, 采用中值合成的方法生成分类影像。

表 1 哨兵二号波段信息

| 波段名称   | 缩写  | 分辨率(m) |
|--------|-----|--------|
| 气溶胶    | B1  | 60     |
| 蓝      | B2  | 10     |
| 绿      | B3  | 10     |
| 红      | B4  | 10     |
| 红边 1   | B5  | 20     |
| 红边 2   | B6  | 20     |
| 红边 3   | B7  | 20     |
| 近红外    | B8  | 10     |
| 红边 4   | B8A | 20     |
| 水汽     | B9  | 60     |
| 短波红外 1 | B11 | 20     |
| 短波红外 2 | B12 | 20     |

### 1.2.2 样本数据

为了满足样本点分布均衡, 尽可能广泛覆盖保护区的要求, 将保护区内四大优势群落作为主要分类对象。同时, 考虑到保护区内分布有大量湿地, 在分类时容易造成混淆。因此最终的分类方案包括白桦群落、落叶松群落、蒙古栎群落、蒙古栎-黑桦群落以及湿地五类。样本点数据主要由两部分构成, 第一部分通过野外调查实地采样, 在 20 × 20m 的样方中使用 Topcon Hiper II G RTK 设备获取每一棵树的精确坐标, 但获取的样本点数量有限, 且样方调查无法覆盖整个保护

区范围, 不能满足训练样本数量充足、分布均匀的要求。因此, 第二部分样本点的获取是基于中央站区域的高清无人机影像(5cm)进行目视解译选取。最终共获取样本点 1948 个, 各个类别的具体数量信息见表 2。

表 2 样本数量表

| 群落类型     | 样本点数量 |
|----------|-------|
| 白桦群落     | 336   |
| 落叶松群落    | 421   |
| 蒙古栎群落    | 440   |
| 蒙古栎-黑桦群落 | 362   |
| 湿地       | 479   |
| 合计       | 1948  |

### 1.3 输入特征

由于 S-2 的气溶胶、水汽和卷云波段不用于土地覆盖分类, 因此在波段选择时排除了这三个波段。选取了从可见光到短波红外范围内的十个波段, 具体包括(B2、B3、B4、B5、B6、B7、B8、B8A、B11、B12)。根据 S-2 的相关波段计算了表 3 中报告的植被指数。这些植被指数已经被用于树种分类并被证明是有效的<sup>[22]</sup>。它们在色素含量、水分含量以及细胞结构的估测方面具有显著优势。以上基于 S-2 影像共产生了 15 个特征(10 个波段 + 5 个指数)。

除了影像自身提取的特征, 气候、地形等环境变量也是分类的重要特征。这些环境变量是植物生长和树种组成的重要决定因素。为了描述气候特征, 在 GEE 平台上选择了由哥白尼气候变化服务公司提供的第五代全球气候再分析产品来描述研究区域的月平均温度。地形数据来自于 NASA 出品的 SRTM 数字高程模型(30m), 根据 DEM 影像计算了研究区域的海拔、坡度。环境因素共提供了 3 个特征(1 个气候因素 + 2 个地形因素)。

因此, 最终参与分类的特征共 18 个特征, 包括 S-2 影像计算的 15 个特征以及环境变量 3 个特征。此外, 为了明确哪些特征在分类过程中具有最高的重要性, 使用随机森林重要性评估对 18 个特征的贡献进行了比较。

表 3 本研究所使用的变量特征

| 特征类型  | 缩写    | 波段名称      | 计算公式   |                           |
|-------|-------|-----------|--|---------------------------|
| 波段特征  | B2    | 蓝         |  |                           |
|       | B3    | 绿         |  |                           |
|       | B4    | 红         |  |                           |
|       | B5    | 红边 1      |  |                           |
|       | B6    | 红边 2      |  |                           |
|       | B7    | 红边 3      |  |                           |
|       | B8    | 近红外       |  |                           |
|       | B8A   | 红边 4      |  |                           |
|       | B11   | 短波红外 1    |  |                           |
|       | B12   | 短波红外 2    |  |                           |
|       | 植被指数  | NDVI      | 归一化植被指数  | $(B8 - B4) / (B8 + B4)$   |
|       |       | NDMI      | 归一化水分指数  | $(B8 - B11) / (B8 + B11)$ |
| GI    |       | 绿度指数      | $(B3 - B2) / (B3 + B2)$                          |                           |
| EVI   |       | 增强植被指数    | $2.5 * (B8 - B4) / (B8 + 6 * B4 - 7.5 * B2 + 1)$ |                           |
| NDREI |       | 归一化差异红边指数 | $(B8 - B5) / (B8 + B5)$                          |                           |
| 环境特征  | Elev  | 海拔高度      |  |                           |
|       | Slope | 坡度        |  |                           |
|       | Temp  | 气温        |  |                           |

#### 1.4 分类模型及精度评价

本研究使用了随机森林算法进行森林群落分类。随机森林模型以处理高维和多重共线性数据而闻名。它是 DT 的集合。每棵树对分配给给定样本的类进行投票,最常被选中的类赢得投票。RF 可以克服 DT 的局限性,如对过拟合不敏感<sup>[23]</sup>。同时为了减轻不平衡训练类的影响,RF 可以结合类权重来减少稀有类别的错误分类<sup>[24]</sup>。本研究选择 100 棵决策树建立随机森林,使用 75% 的样本点用于模型的训练,25% 的样本点用于验证模型的精度。基于 2023 年的输入特征构建随机森林模型,并通过构建的模型对 2019 年与 2023 年的中央站保护区森林群落进行监督分类。

使用混淆矩阵对模型进行准确性评估以确定模型和分类结果的质量。总体精度(OA)、生产者精度(PA)、用户精度(UA)以及 kappa 系数是使用最广泛的准确性评估指标。OA 指示在所有像素中被正确分类的可能性。PA 与遗漏误

差有关,反映了某一区域的某种土地覆盖被划为此类的可能性。UA 与错分误差有关,是指地图上某一类实际上在真实的观测值中出现的频率。kappa 系数统计评估定性项目的预测值一致性和观测值一致性。

#### 1.5 面积变化及时空分析

基于群落分类图的面积变化与时空分析在开源统计软件 R(R-4.3.1)中完成。在 GEE 平台计算各个群落在影像上的面积,随后使用 R 中的 ggplot2 包绘制了各个群落在四年内的面积分布柱状图。通过相交分析,并建立群落转移矩阵,转移矩阵是依据同一地区但不同时相的森林群落的变化关系,获得的一个二维矩阵。它描述了不同的群落类型在不同年份发生变化的群落类别以及发生变化的位置和变化面积。能够反映各个类别的面积转出以及转入情况,可了解群落类型变化的总体趋势和结构变化<sup>[25]</sup>。建立转移矩阵以反映群落变化的具体方向与程度,并绘制群落变化图使数据可视化。

## 2 结果

### 2.1 分类模型精度

精度评价结果显示模型分类结果具有较高的准确性(表4)。它的 OA 为 0.90, kappa 系数为 0.87。其中,湿地类别在模型结果中的 PA 和 UA 都表现出了最好的准确性,PA 达到了 0.98, UA 为 0.95。优势森林群落(除白桦外)在的分类结果中都表现出了较高的准确性,其中最高的是的落叶松群落,PA 达到了 0.93。

表 4 随机模型分类精度

| 群落类型     | OA   | Kappa | UA   | PA   |
|----------|------|-------|------|------|
| 蒙古栎群落    |      |       | 0.91 | 0.83 |
| 蒙古栎-黑桦群落 |      |       | 0.85 | 0.90 |
| 白桦群落     | 0.90 | 0.87  | 0.89 | 0.78 |
| 落叶松群落    |      |       | 0.86 | 0.93 |
| 湿地       |      |       | 0.95 | 0.98 |

### 2.2 分类特征重要性评估

特征重要性结果显示:地形数据如 Elev 和 Slope 是具有最高重要性的特征,其次是原始波段对植被分类也具有重要意义,短波红外在分类中都表现出了较高的贡献度,但可见光、红边与近红外等波段的重要性表现并不稳定,红边波段是最重要的原始波段。对于植被指数,GI 和 EVI 是模型中最重要的特征。此外,NDREI 也表现出了较高的重要性。值得注意的是,气候条件并没有像预期一样占据较高的贡献度并明显提升模型精度,在模型中,气候条件的贡献度明显低于其他特征。各个特征详细的重要性见表 5。

表 5 分类特征重要性

| 特征名称 | 特征重要性 |
|------|-------|
| B11  | 0.061 |
| B12  | 0.061 |
| B2   | 0.053 |
| B3   | 0.056 |
| B4   | 0.058 |
| B5   | 0.059 |
| B6   | 0.048 |

|       |       |
|-------|-------|
| B7    | 0.051 |
| B8    | 0.052 |
| B8A   | 0.056 |
| Elev  | 0.071 |
| EVI   | 0.054 |
| GI    | 0.057 |
| Temp  | 0.036 |
| NDMI  | 0.052 |
| NDREI | 0.052 |
| NDVI  | 0.053 |
| Slope | 0.065 |
| 合计    | 1     |

### 2.3 森林群落分类结果及面积变化

中央站国家级自然保护区 2019 年与 2023 年森林群落分布如图 2 所示。基于高分辨率谷歌地图与保护区范围内的无人机正射影像(5cm)对分类结果进行目视判别,湿地分布基本符合实际情况。树种方面参照中央站保护区林相图进行对比验证。白桦作为先锋树种,依靠湿地沿岸进行分布;落叶松则主要分布在保护区西侧的高海拔地区;蒙古栎、黑桦等阔叶林则在东部较为丰富。分类结果符合实际情况。

由分类结果计算的 2019 年与 2023 年黑龙江中央站黑嘴松鸡国家级自然保护区各个群落的面积与变化如图 3 所示。在 2019 年与 2023 年,保护区内森林群落和湿地的总体面积格局(除蒙古栎和白桦群落外)没有显著变化。落叶松群落始终是保护区内面积最大的森林群落,其次是湿地,蒙古栎群落在 2019 年的面积小于白桦群落,但 2023 年超过了白桦群落。面积变化方面,森林总面积呈上升趋势,而湿地面积则由 126.98km<sup>2</sup> 下降至 115.05km<sup>2</sup>,这一变化能够在图 2 的对比中得出。湿地退化并演变为森林群落,主要变化为白桦等先锋树种分布在湿地沿岸。对于具体的森林群落而言,随着时间的推移落叶松和蒙古栎群落面积应当增加,而白桦群落等先锋物种的面积会减少。我们的结果遵循这一预期,落叶松和蒙古栎群落的面积有较大增加,分别增加了 11.43km<sup>2</sup> 和 14.20km<sup>2</sup>,蒙古栎

—黑桦群落与白桦群落的面积则呈下降趋势,其中蒙古栎—黑桦群落下降了  $8.11\text{km}^2$ ,白桦群落面积下降了  $9.56\text{km}^2$ 。

空间变化方面土地利用转移矩阵更详细的

量化了各个群落之间发生了演变动态。具体的变化信息则在表 6 中进行了报告,从表 6 中可以看出,湿地与白桦群落之间的转移较为明显,这与白桦作为先锋物种喜水的习性有关。湿地退

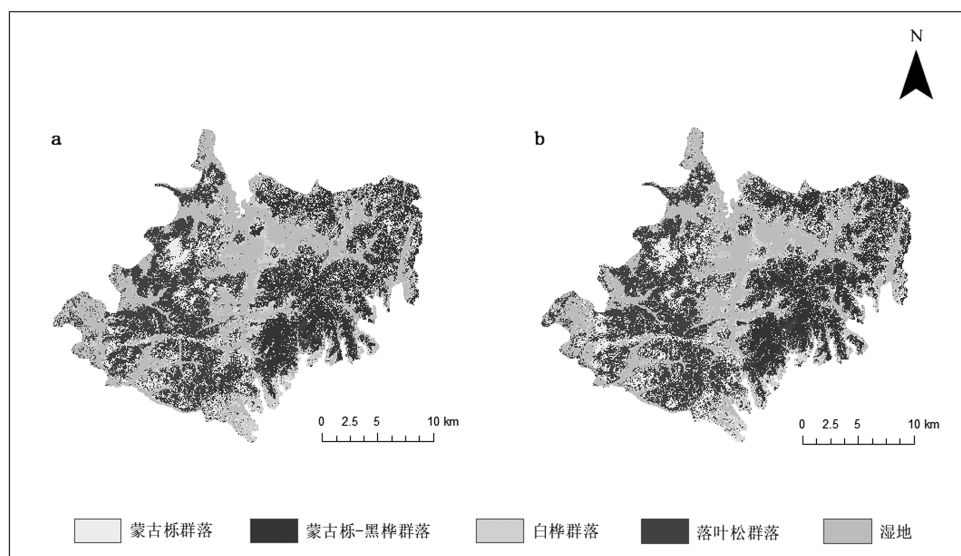


图 2 中央站森林群落分类图

a 为 2019 年中央站保护区森林群落分类图,b 为 2023 年中央站保护区森林群落分类图。

(来源:中国自然保护区标本资源共享平台地理信息库《黑龙江省中央站黑嘴松鸡国家级自然保护区边界数据》)




图 3 2019 年与 2023 年森林群落面积变化直方图

表 6 森林群落转移矩阵

| 2019(km <sup>2</sup> ) | 2023(km <sup>2</sup> ) |        |          |       |        | 总计     |
|------------------------|------------------------|--------|----------|-------|--------|--------|
|                        | 白桦群落                   | 落叶松群落  | 蒙古栎-黑桦群落 | 蒙古栎群落 | 湿地     |        |
| 白桦群落                   | 31.55                  | 10.18  | 4.77     | 12.93 | 6.01   | 65.45  |
| 落叶松群落                  | 7.57                   | 106.18 | 5.03     | 10.93 | 1.49   | 131.22 |
| 蒙古栎-黑桦群落               | 4.54                   | 11.21  | 57.78    | 17.61 | 0.69   | 91.85  |
| 蒙古栎群落                  | 4.89                   | 13.51  | 13.06    | 29.41 | 1.49   | 62.36  |
| 湿地                     | 11.31                  | 1.54   | 3.09     | 5.67  | 105.35 | 126.98 |
| 总计                     | 59.89                  | 142.63 | 83.74    | 76.56 | 115.05 | 477.88 |

化后白桦便开始在新生的土地上生长,2019 年与 2023 年有 11.31km<sup>2</sup> 的湿地转移为白桦群落,占据湿地空间转移的 50%。森林群落方面,白桦和预期一样是转移最多的树种,超过一半的白桦转移为蒙古栎、落叶松等优势物种;落叶松群落作为保护区内的优势物种,空间变化比较稳定,几乎不向其他群落进行转移;蒙古栎群落与蒙古栎-黑桦群落的光谱特征类似,在分类时可能发生较大程度的混淆,导致两者之间的转移较为剧烈,有 17.61km<sup>2</sup> 的蒙古栎-黑桦转移为了蒙古栎群落,也有 13.06km<sup>2</sup> 的蒙古栎群落转移为了蒙古栎-黑桦群落。

### 3 讨论

#### 3.1 模型精度与错误混淆

与其他研究相比,本研究基于 S-2 卫星影像建立的随机森林模型的总体准确性高于 85%,各个森林群落的 UA 和 PA 也满足分类精度的要求,说明了 RF 用于群落分类的有效性。Immitzer 等人在奥地利的一个小型生物圈保护区对 12 个树种进行分类时,准确率达到 89%<sup>[22]</sup>;Persson 等人使用免费的十三波段 S-2 数据对瑞典中部的五种树种进行分类,总体分类准确率为 88.2%<sup>[26]</sup>;Yang 等人利用 2019 年至 2021 年三年的 1-2 时间序列,通过随机森林模型,对林下群落进行分类,总体精度高达 93%,个别生产者精度达到了 99%<sup>[27]</sup>。此外,在本研究的分类过程中,混淆矩阵显示蒙古栎群落与蒙古栎-黑桦群落存在最严重的混淆,我们认为这是由于二者的相似性导致了较大的误差,在选取样

本点时基于中央站区域第二次全国土地利用调查信息,黑桦等阔叶林群落常与蒙古栎群落混交杂生,在分类时部分的蒙古栎群落被错误的分类至蒙古栎-黑桦群落。白桦群落的 PA 相较于其他群落出现了明显差距,这可能是由于样本点不均衡导致的,白桦群落的样本点数量相较于其他群落较少,这会导致在分类发生混淆时,模型会更偏向于将其分类为数量更占优势的类别。

此外,我们基于保护区范围内的高分辨率无人机正射影像(5cm)与实地的样地(500 × 500m)调查数据对分类结果进行了验证。具体来说,我们结合实地调查的样本数据确定不同树种在该无人机高清影像上的冠层形状信息,对湿地与各个森林群落的分布进行了验证,分类结果基本符合实际情况。样地调查在 2022 年 6 月进行,在 500 \* 500m 的大样地中精确测量了每一棵树的坐标与结构参数。我们依据样地范围内的树种点信息检验分类像元,结果依旧符合实际调查结果。但中央站区域内森林资源丰富,各个群落混交杂生,仅仅按四大优势群落划分并不能完全代表保护区内的森林资源。在未来,我们希望随着样本点的增加能够考虑更多的群落加入分类方案,更准确地反应保护区的森林资源。

#### 3.2 指标对分类的重要性

Elev 在模型中都表现出了最高的特征重要性,表明不同植被类型的分布受海拔的影响较大。研究区域最高海拔与最低海拔差异比较明显,导致植被类型及分布发生明显变化。许多研究已经证实,不同海拔形成了不同的温度、湿度等环境变量,因此植被类型的分布会随着海拔的

变化形成特殊的格局<sup>[10,28,29]</sup>。对于 S-2 影像的原始波段,各个波段的表现并不稳定,但短波红外波段反而表现出了较高的重要性,说明不同植被内的水分含量存在较为明显的差异,而近红外、红边等反映叶片结构信息的波段并没有展现良好的重要性。此外,气候特征的重要性不在预期之中,与其他特征相比产生了断崖性的减少,可能是由于我们仅选取了 6-9 月的月平均温度,产生的数据量较少且没有明显差异,没有充分考虑物候的影响,在未来的研究中期待更大时间尺度的气候信息在模型中被应用以提升准确性。

### 3.3 限制与未来方向

本研究的结果初步给出了黑龙江中央站国家级自然保护区内优势群落的地理分布及动态变化,但仍存在较多限制。尽管在抽样选择的过程中考虑了样本点均匀的问题,但最终的分类方案中,白桦的数量依旧明显少于其他的样本数量,这导致了对白桦群落的低估,因为优势类别和稀有类别的频率之间的不平衡可以使分类模型的预测概率分布偏向于优势类别<sup>[30]</sup>。若训练样本间存在严重的不平衡,则需要不同的方法来适应不平衡的训练数据:例如对次要类别进行上采样,对主导类别进行下采样<sup>[24]</sup>,调整先验概率,调整案例权重,抽样方法和成本敏感训练等。本研究训练样本并不存在严重的失衡现象,因此并未采用上述方法,但在未来的研究中仍要尽可能地平衡不同类别的样本点数量。

此外,本研究只选取了 6-9 月植物生长季的影像,并不能充分展现不同植被群落物候特征上的差异,然而物候特征也是不同的植被群落分类的重要依据,不同的植被对物候变化的响应程度等差异可以在光谱上造成明显的区别,例如落叶和常绿植物的 NDVI 在夏季可能很难区分,但两者在冬季差异是显而易见的。因此,来自不同物候阶段的图像组合很重要。时间序列等图像合成方法能够克服基于图像无法捕捉物候特征快速变化局限性,通过平滑与插值等方法保留了与物候和非生物因素相关的时间信号<sup>[31,32]</sup>。

Hemmerling 等人利用 2021 年的 S-2 影像,通过时间序列合成的方法对德国温带森林内的 17 类树种进行了精确分类,指出了 S-2 时间序列影像在树种分类方面的强大潜力<sup>[20]</sup>,因此,在未来的研究中应当充分考虑物候特征对树种分类的重要性,探究并选择最适合的方法。

## 4 结论

本研究基于 GEE 平台,通过使用 S-2 影像建立了高精度的随机森林模型并对黑龙江省中央站黑嘴松鸡国家级自然保护区的森林群落进行了两个时期的分类。结果表明模型的 OA 为 0.89, kappa 系数为 0.87。其中海拔是最重要的特征。空间变化分析显示了在 2019 年与 2023 年期间森林群落面积上升,湿地群落面积下降的总体趋势。综上所述,本研究利用 S-2 图像确定了中央站保护区内各个优势森林群落的分布及空间变化,为未来更精细的森林组分研究提供了基础信息,有助于保护区管理和保护政策的制定与实施。同时,我们期望在未来的研究中充分考虑物候等其他因素,利用时间序列、深度学习等新兴技术建立更精确的分类模型,从而获得更精确的大规模森林群落分类图。

### 参考文献(References):

- [1] Marden M, Lambie S, Phillips C. Biomass and root attributes of eight of New Zealand's most common indigenous evergreen conifer and broadleaved forest species during the first 5 years of establishment [J]. *New Zealand Journal of Forestry Science*, 2018, 48.
- [2] Shile D. Forests, atmospheric water and an uncertain future: the new biology of the global water cycle [J]. *Forest Ecosystems*, 2018, 5(3): 236-57.
- [3] Ghosh A, Joshi P K. A comparison of selected classification algorithms for mapping bamboo patches in lower Gangetic plains using very high resolution WorldView 2 imagery [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2014, 26: 298-311.
- [4] Calviño - Cancela M, Chas - Amil M L, García -

- Martínez E D, et al. Interacting effects of topography, vegetation, human activities and wildland – urban interfaces on wildfire ignition risk [J]. *Forest Ecology and Management*, 2017, 397: 10 – 7.
- [5] Wallis C I B, Brehm G, Donoso D A, et al. Remote sensing improves prediction of tropical montane species diversity but performance differs among taxa [J]. *Ecological Indicators*, 2017, 83: 538 – 49.
- [6] Wang R, Gamon J A. Remote sensing of terrestrial plant biodiversity [J]. *Remote Sensing of Environment*, 2019, 231.
- [7] Xiao J F, Chevallier F, Gomez C, et al. Remote sensing of the terrestrial carbon cycle: A review of advances over 50 years [J]. *Remote Sensing of Environment*, 2019, 233.
- [8] Chiarucci A, Piovesan G. Need for a global map of forest naturalness for a sustainable future [J]. *Conservation Biology*, 2020, 34(2): 368 – 72.
- [9] Ansari A A, Saggi S, Abbas Z K, et al. Aquatic Plant Biodiversity: A Biological Indicator for the Monitoring and Assessment of Water Quality [M]. *Plant Biodiversity: Monitoring, Assessment and Conservation*, 2017.
- [10] Ye N, Morgenroth J, Xu C, et al. Indigenous forest classification in New Zealand – A comparison of classifiers and sensors [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 102.
- [11] Grabska E, Frantz D, Ostapowicz K. Evaluation of machine learning algorithms for forest stand species mapping using Sentinel – 2 imagery and environmental data in the Polish Carpathians [J]. *Remote Sensing of Environment*, 2020, 251.
- [12] Gorelick N, Hancher M, Dixon M, et al. Google Earth Engine: Planetary – scale geospatial analysis for everyone [J]. *Remote Sensing of Environment*, 2017, 202: 18 – 27.
- [13] Ma Y, Zhen Z, Li F R, et al. An innovative lightweight 1D – CNN model for efficient monitoring of large – scale forest composition: a case study of Heilongjiang Province, China [J]. *GIScience & Remote Sensing*, 2023, 60(1).
- [14] Fedrigo M, Newnham G J, Coops N C, et al. Predicting temperate forest stand types using only structural profiles from discrete return airborne lidar [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 136: 106 – 19.
- [15] Pham L T H, Brabyn L. Monitoring mangrove biomass change in Vietnam using SPOT images and an object – based approach combined with machine learning algorithms [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 128: 86 – 97.
- [16] Sanchez – Hernandez C, Boyd D S, Foody G M. Mapping specific habitats from remotely sensed imagery: Support vector machine and support vector data description based classification of coastal salt-marsh habitats [J]. *Ecological informatics*, 2007, 2(2): 83 – 8.
- [17] Correll M D, Hantson W, Hodgman T P, et al. Fine – Scale Mapping of Coastal Plant Communities in the Northeastern USA [J]. *Wetlands*, 2019, 39(1): 17 – 28.
- [18] Bhatt P, Maclean A L. Comparison of high – resolution NAIP and unmanned aerial vehicle (UAV) imagery for natural vegetation communities classification using machine learning approaches [J]. *GI-Science & Remote Sensing*, 2023, 60(1).
- [19] Kattenborn T, Leitloff J, Schiefer F, et al. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 173: 24 – 49.
- [20] Hemmerling J, Pflugmacher D, Hostert P. Mapping temperate forest tree species using dense Sentinel – 2 time series [J]. *Remote Sensing of Environment*, 2021, 267.
- [21] 李国富, 尹伟平, 邱国良, 等. 基于红外相机技术的黑龙江中央站黑嘴松鸡国家级自然保护区兽类和鸟类初步监测 [J]. *野生动物学报*, 2018, 39(03): 559 – 565.
- [22] Immitzer M, Neuwirth M, Böck S, et al. Optimal Input Features for Tree Species Classification in Central Europe Based on Multi – Temporal Sentinel

- 2 Data [J]. *Remote Sensing*, 2019, 11(22).
- [23] Belgiu M, Dragut L. Random forest in remote sensing: A review of applications and future directions [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 114: 24 – 31.
- [24] Chen C, Breiman L. Using random forest to learn imbalanced data[J]. *Machine Learning*, 2004, 45, 5 – 32.
- [25] Zheng H, Li H. Spatial – temporal evolution characteristics of land use and habitat quality in Shandong Province, China[J]. *Scientific Reports*, 2022, 12: 15422.
- [26] Persson M, Lindberg E, Reese H J R S. Tree Species Classification with Multi – Temporal Sentinel – 2 Data[J]. *Remote Sensing*, 2018, 10(11): 1794.
- [27] Yang X C, Qiu S, Zhu Z, et al. Mapping understory plant communities in deciduous forests from Sentinel – 2 time series[J]. *Remote Sensing of Environment*, 2023, 293.
- [28] Davis M B, Shaw R G. Range shifts and adaptive responses to Quaternary climate change[J]. *Science (New York, NY)*, 2001, 292(5517): 673 – 9.
- [29] 周婉诗, 张楚婷, 周志平, 等. 植被分布的海拔与纬度相互关系模式的校正[J]. *中国科学: 生命科学*, 2021, 51(3): 12.
- [30] Maxwell A E, Warner T A, Fang F. Implementation of machine – learning classification in remote sensing: an applied review[J]. *International Journal of Remote Sensing*, 2018, 39(9): 2784 – 817.
- [31] Bendini H D, Fonseca L M G, Schwieder M, et al. Detailed agricultural land classification in the Brazilian cerrado based on phenological information from dense satellite image time series[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2019, 82.
- [32] Schwieder M, Leitao P J, Pinto J R R, et al. Landsat phenological metrics and their relation to aboveground carbon in the Brazilian Savanna [J]. *Carbon Balance and Management*, 2018, 13.

---

#### 作者简介:

第一作者:赵晨曦,2002 年生,男,河南三门峡人,本科,东北林业大学,学生,主要研究方向为生态遥感。Email: 15939883372@nefu.edu.cn

通讯作者:姚允龙,1982 年生,男,黑龙江哈尔滨人,博士,东北林业大学,副教授,主要研究方向为生态遥感。Email: yl.yao@163.com

---

## Research on Forest Dynamic Changes Based on GEE ——Taking the Central Station National Nature Reserve as an Example

ZHAO Chenxi<sup>1,2</sup>, YAO Yunlong<sup>1,2</sup>, WANG Wenji<sup>1,2</sup>, FU Yi<sup>1,2</sup>, ZHANG Pengfei<sup>3</sup>,  
ZHANG Bing<sup>3</sup>, PAN Mingzhe<sup>3</sup>

(1. Wetland Biodiversity Conservation and Research Center, Northeast Forestry University, Harbin 150040, China;

2. College of Wildlife and Protected Area, Northeast Forestry University, Harbin 150040, China;

3. Heilongjiang Provincial Natural Resources Rights and Interests Investigation  
and Monitoring Institute, Harbin 150080, China)

**Abstract:** Forest resources are extremely precious natural resources in our country, and the accurate information of forest components is very important to the protection and management of forest resources. However, the traditional field forest inventory is time-consuming and laborious, so a fast and accurate survey method is urgently needed. Based on Google Earth Engine (GEE) cloud computing platform and multi-temporal Sentinel-2 images, a stochastic forest model was established based on terrain, climate and other environmental factors, and the forest communities of Heilongjiang Central Station Black Grouse National Nature Reserve in 2019 and 2023 were classified. The results show that the overall accuracy of classification is 0.90, and the kappa coefficient is 0.87. Among them, topographic factors (elevation and slope) have important effects on classification results. In addition, in order to clarify the changes of forest communities in the two periods, we conducted a spatial analysis and identified the birch community as the forest community with the most drastic changes. This study has drawn a forest community distribution map with high accuracy, which provides a scientific basis for the subsequent management system and policy of Heilongjiang Central Station Black Grouse National Nature Reserve.

**Key words:** large-scale forest mapping; forest community change; GEE; random forest; Sentinel-2