

DOI: 10.20103/j.stxb.202406201430

康濒月, 李佳旭, 宁园力, 李洪远. 机器学习在量化滨海蓝碳储量研究中的应用进展. 生态学报, 2025, 45(10): 5075-5089.

Kang B Y, Li J X, Ning Y L, Li H Y. Progress in machine learning for quantifying coastal blue carbon. Acta Ecologica Sinica, 2025, 45(10): 5075-5089.

## 机器学习在量化滨海蓝碳储量研究中的应用进展

康濒月, 李佳旭, 宁园力, 李洪远\*

南开大学环境科学与工程学院, 天津 300350

**摘要:** 科学量化滨海蓝碳生态系统(红树林、盐沼和海草床)碳汇能力是制定基于自然解决方案缓解全球气候变化措施的基础和前提。近年来多源遥感数据与机器学习技术的结合应用领域日益广泛, 然而缺乏对滨海蓝碳量化方法和技术体系的比较与系统评述。梳理了近五年多源遥感数据结合机器学习在蓝碳储量量化研究中的应用现状, 在归纳总结量化蓝碳的分类与预测路径基础上, 分析了不同遥感数据和机器学习算法的适用性, 聚焦分类与预测路径的模型表现及量化指标。结果表明, 分类与预测途径难以完全替代彼此, 分类路径适用于缺乏足够碳储量数据情形下快速量化蓝碳实现空间化, 而预测路径适用于精确量化碳储量的连续变量值, 在未来需发展“先分类、再预测”整合路径以提高结果精度与研究效率; 提出考虑气候变化、人类活动干预以及自然生态系统动态等多重因素, 发展蓝碳时空动态监测体系, 以支持滨海生态系统的可持续管理, 为实现可持续发展目标提供科学支撑。

**关键词:** 滨海蓝碳; 机器学习; 多源遥感数据; 碳储量

### Progress in machine learning for quantifying coastal blue carbon

KANG Binyue, LI Jiayu, NING Yuanli, LI Hongyuan\*

College of Environmental Science and Engineering, Nankai University, Tianjin 300350, China

**Abstract:** Accurately quantifying the carbon sequestration capacity of coastal blue carbon ecosystems (mangroves, salt marshes, and seagrass beds) is essential for developing nature-based solutions to mitigate global climate change. These ecosystems act as significant carbon sinks, yet traditional field-based assessments are often labor-intensive, time-consuming, and spatially limited. In recent years, the integration of multi-source remote sensing data with machine learning (ML) techniques has gained increasing attention, offering new possibilities for large-scale, high-resolution blue carbon quantification. However, there are limited reviews focusing on machine learning algorithms for quantifying blue carbon and the types of remote sensing data sources that can be used presenting a need for a systematic summary of pathways for applying multi-source data and machine learning algorithms to blue carbon ecosystems. This study systematically reviews the applications of machine learning in coastal blue carbon quantification from the recent five years, focusing on the utilization of classification and prediction frameworks. Utilizing multi-source datasets—including satellite, airborne, and drone-based sensors—these frameworks harness the strengths of various machine learning algorithms. Classification methods, such as Random Forest (RF), Support Vector Machines (SVM), and deep learning models, are primarily employed for mapping vegetation types and assessing spatial distributions. Prediction models, such as XGBoost, CatBoost, and Cubist, estimate carbon stocks as continuous variables by incorporating spectral, structural, and environmental features. Each approach presents distinct advantages—classification excels in large-scale ecosystem mapping, while prediction models provide high-accuracy stock assessments when reliable and sufficient training data is available. Combining these methods in a

基金项目: 国家自然科学基金项目(32171853)

收稿日期: 2024-06-20; 网络出版日期: 2025-03-18

\* 通讯作者 Corresponding author. E-mail: eialee@nankai.edu.cn

“classification-first, then prediction” framework enhances both spatial and quantitative precision. Despite significant progress, challenges persist in feature selection, data heterogeneity, and the interpretability of machine learning outputs, limiting model accuracy and applicability. Spectral signature variability, particularly in distinguishing similar vegetation types, and radiative saturation in dense biomass areas like mangrove forests introduce classification errors. The integration of Synthetic Aperture Radar (SAR), LiDAR, and hyperspectral imaging can mitigate these limitations by improving structural and biochemical feature extraction. Additionally, underwater remote sensing technologies such as autonomous underwater vehicles (AUVs) with optical sensors offer promising solutions for monitoring submerged seagrass meadows. Advancements in hybrid machine learning models and explainable artificial intelligence (AI) techniques can further enhance model reliability, ensuring more accurate and interpretable blue carbon quantification. As AI and remote sensing continue to evolve, their synergy presents new opportunities for refining carbon accounting methodologies and informing climate policy. Strengthening interdisciplinary collaboration between ecologists, data scientists, and policymakers will accelerate progress in this field, ensuring that machine learning-driven approaches contribute meaningfully to global carbon neutrality efforts.

**Key Words:** coastal blue carbon; machine learning; multi-source remote sensing data; carbon stock

海岸带蓝碳<sup>[1-2]</sup>又称滨海蓝碳<sup>[3-4]</sup>,是指位于海岸带、受海水周期性冲刷影响的盐沼、红树林和海草床等高等植物生态系统<sup>[5]</sup>。滨海蓝碳生态系统因卓越的固碳及储碳效能而成为全球碳储存密度最高的生态系统之一<sup>[6]</sup>,其在基于自然的解决方案中的角色对于缓解及适应全球气候变化显得尤为重要<sup>[7-8]</sup>。自2009年起,滨海蓝碳在气候变化中的作用逐渐受到国际重视<sup>[9]</sup>,保护与恢复工作已纳入国际减排目标。我国已充分认识到滨海蓝碳在实现碳中和目标中的潜力,在国家战略和政策层面部署了蓝碳工作,形成了中央总体规划与地方示范先行的格局<sup>[10]</sup>。科学评估滨海蓝碳的碳汇能力、固碳速率和碳埋藏来源是制定减排增汇措施的基础,对我国碳中和战略目标的实现至关重要<sup>[4]</sup>。

已有研究表明,海草床<sup>[11]</sup>和盐沼湿地<sup>[12-13]</sup>的分布不确定性较大,全球滨海蓝碳生态系统面积估值在 $36-1.85 \times 10^6 \text{ km}^2$ 之间,土壤和生物量可能蕴藏约 $8970-32650 \text{ Tg C}$ <sup>[14-15]</sup>。因采样技术、时空分辨率或生态系统界定标准的差异,数据不可比性较高。此外,滨海湿地生态系统的复杂性和异质性<sup>[1,4]</sup>使传统的实地调查和测量方法难以满足大尺度、高精度的蓝碳评估需求。近年来,伴随着传感器技术和遥感技术的不断发展和全球新一代生态系统观测研究网络的逐渐形成,海量遥感数据呈现出快速增长,天空地一体化观测体系成为了新时期生态系统观测乃至预测的关键特性和重要支持<sup>[16]</sup>,对滨海蓝碳生态系统的碳固定、存储与迁移进行精确的量化评估已成为可能<sup>[17-20]</sup>。机器学习能够从海量数据中自动提取特征、构建复杂的非线性模型,克服了传统经验模型的局限性<sup>[21]</sup>,提供了对大规模、多源遥感数据的高效处理手段,非常适用于滨海蓝碳储量的量化评估。

尽管已有少量文章围绕量化蓝碳的机器学习算法<sup>[20]</sup>和使用的遥感数据源类型<sup>[22]</sup>进行过梳理,但如何系统地将多源数据和机器学习算法应用于蓝碳生态系统,尚缺乏清晰的路径归纳和方法对比。在实际应用中,机器学习方法逐渐形成了分类和预测两大技术路径,但不同算法和数据源在适用性、准确性和解释性上存在显著差异。为此,本文系统梳理了量化蓝碳研究的分类和预测技术框架,归纳不同机器学习算法和多源遥感数据在分类与预测路径下具体应用,深入对比分析其适用性与局限性,旨在为蓝碳生态系统的科学管理提供更可靠的量化依据,为未来该领域的深入研究提供方向。

## 1 机器学习与遥感数据应用

### 1.1 机器学习的原理与应用

#### (1) 原理

基于数据驱动、以“学习”为核心的特点<sup>[23]</sup>机器学习在生态学研究逐渐受到重视,其核心原理在于通

过算法从海量数据中提取模式和规律,实现损失函数的最小化<sup>[24]</sup>以完成新数据的预测和分类任务。在量化滨海蓝碳储量的研究中,机器学习的主要作用是通过多种算法高效处理复杂数据、识别模式,解决非线性和高纬度问题<sup>[21]</sup>,从大量样本中提取关键特征,以实现分类和预测。

## (2) 算法选择依据

机器学习对数据量和样本覆盖要求较高,尤其在处理复杂地理特征、维度和尺度之间的交互关系时。表 1 总结了现阶段研究应用机器学习量化蓝碳研究中使用的算法类型和数据要求,每类算法均具备特定的应用场景和优势,例如,决策树类算法适用于多特征、多类别的数据集,研究应用最小样本量为 25 个<sup>[25]</sup>。增强集成算法则在大数据集和高维特征条件下表现优异,研究应用最小样本量为 50 个<sup>[26]</sup>。此外,深度学习可自动提取大规模遥感数据特征,显著提升碳储量空间分布的预测精度,有效解决了传统算法难以解析的非线性特征<sup>[25,27-28]</sup>,但需大量数据和计算资源,且解释性较差,带来结果透明性问题。因此在选择算法时应基于:①数据特征:包括数据量、维度、是否存在缺失值、特征之间的关系(如非线性关系)等。②模型性能:包括模型的预测准确性、计算效率和鲁棒性等。③解释性:决策树模型易于解释和展示决策路径,适合需要揭示数据关系的研究,例如,有研究利用增强回归树模型解释了气候因子对红树林土壤有机碳的显著影响,其中年均温因子占比 38.5%<sup>[29]</sup>;而深度学习和集成算法虽然准确性高,但解释性相对较低,适用于数据复杂、对精度要求高的任务。

整体来看,各类机器学习算法在蓝碳生态系统碳储量估算中具有不同的适应性,实际应用需结合数据采集的准确性和完整性、研究目标的需求及所面临的数据特征,以在性能与计算成本间取得平衡。当前多数研究通过比较多种算法来选择最优模型<sup>[30-32]</sup>,但何为最优算法目前尚无定论,依然需要根据具体研究对象和数据基础等条件进行选择。

## 1.2 遥感数据在滨海蓝碳监测中的应用

### (1) 遥感平台的应用优势

近年来发表在 *Science* 和 *Nature Sustainability* 上的研究表明,遥感数据集能够有效监测生态系统,尤其适用于受潮汐动态影响的滨海蓝碳生态系统<sup>[33-34]</sup>。获得的遥感数据集来自各类传感器对地物电磁波谱特征记录,大致可分为星载传感器、机载传感器和无人机系统(图 1)。星载传感器因其覆盖范围广、观测周期长,通常与多光谱成像和合成孔径雷达(SAR)结合,用于红树林的整体结构监测及其碳储量估算<sup>[35-37]</sup>。机载传感器具备较高灵活性和精度,与激光雷达和高光谱成像的结合为小范围内的精细监测提供了更高的精确度,尤其适用于海草床<sup>[38]</sup>和盐沼<sup>[39]</sup>的三维结构获取与生物量测量。此外,无人机平台则凭借低空、高分辨率的优势,与多光谱成像和激光雷达(LiDAR)结合,为滨海蓝碳生态系统提供更细致的地表覆盖数据和植被分布信息,适合作为大范围监测数据的补充。

### (2) 滨海蓝碳监测的技术挑战

红树林、盐沼和海草在潮间带的具体位置以及植被形态特征上的差异,为蓝碳生态系统的监测及精细化绘图工作带来了复杂性。就地表高程而言,红树林和盐沼的植被分布高于海草床。红树林的树冠常在水面之上,而盐沼植物则长期处于潮水的周期性浸泡之中,即便在潮位最低时,海草床也仍然被海水淹没。监测滨海蓝碳生态系统使用多光谱成像仍然是主流(图 1),但并非所有植被都适合多光谱传感器,例如,由于辐射饱和效应是多光谱影像在植被定量遥感研究中的通用缺陷,研究发现当红树林地上生物量高于 250 Mg/hm<sup>2</sup>时,预测模型出现明显低估<sup>[40]</sup>,因此建议使用 SAR 结合 Sentinel-2 影像联合反演红树林林业参数。此外,其他成像方式也具备独特的技术优势,例如 LiDAR 能够提供厘米级分辨率的地表和植被三维结构信息,获取高精度的地形高程数据,SAR 的极化特性和干涉技术(InSAR)能够提供植被高度、密度等三维结构信息,为红树林的结构参数反演、反应盐沼湿地微地形特征,监测滨海蓝碳生态系统并量化蓝碳提供了不同但互补的技术支持。

由于海草床常年位于水面以下不易观测,其光谱特性随着种类、生长状态、年龄及所在水深的不同而有所差异,分布和范围还会受到水质、温度、盐度和海浪等多种环境条件的影响,使得量化其蓝碳储量更加复

表 1 常见用于量化滨海蓝碳的机器学习算法

算法类型 Algorithm type	机器学习算法英文名称 Algorithms full english name	简称 Abbreviation	机器学习算法中文全称 Algorithms full chinese name	数据要求 Data requirements
决策树算法	Random Forest	RF	随机森林	操作简单,解释性强,适用于处理具有明显类别或层次的生态数据,但对噪声数据敏感,数据中的异常值可能会影响决策树的分支结构。因此,数据清洗和异常值检测对于提升算法效果至关重要,对于分类任务,类别标签需要明确且无误差。标签数据如果存在偏差或不准确,树的分割会偏向某一类标签,影响模型的泛化能力。
Decision tree algorithm	<i>Extremely Randomized Trees</i>	ET	极端随机树	
	Classification and Regression Trees	CART	分类回归树	
	Decision Tree	DT	决策树	
	Gradient Boosting Machine	GBM	梯度提升机	
	Gradient Boosted trees	GBDT	梯度提升决策树	
	Cubist	CUBIST	回归树模型	
增强-集成算法	Light Gradient Boosting Machine	LightGBM	轻量梯度提升	对高质量数据有较高需求,尤其是大规模数据集的应用。该算法对缺失数据的容忍度低,通常需要经过特征工程以提升模型的稳定性。此外,类别平衡对于集成算法的表现也至关重要,数据不平衡可能会导致偏差。
Boosting-ensemble algorithms	Extreme Gradient Boost	XGBoost	极端梯度提升	
	Categorical Boosting	CatBoost	分类提升机	
	Adaptive Boosting	AdaBoost	自适应提升	
基于核的算法	Support Vector Machine	SVM	支持向量机	适用于高维数据和小样本数据集,但对数据的可分性要求较高。如果数据分布中存在较多重叠或噪声,可能会影响模型效果,因此通常需要提前做好数据进行归一化处理。
Kernel-based algorithms	Radial Basis Function	RBF	径向基函数	
	Gaussian Processes	GP	高斯过程	
深度学习	Kernel-based Regularized Least Squares	KRLS	基于核的正则化最小二乘法	对数据量的需求最高,尤其在多层神经网络中,较少的数据容易引发过拟合。此外,数据质量和标注精确度也影响模型的表现;在遥感数据处理中,空间分辨率和时间分辨率的数据均需满足需求。
Deep learning	Multilayer Perceptron Neural Network	MLPNN	多层感知器神经网络	
	Deep Belief Networks	DBN	深度信念神经网络	
	Radial Basis Function Neural Network	RBFNN	径向基函数神经网络	
	Deep Convolutional Neural Networks	DCNN	深度卷积神经网络	
神经网络算法	Artificial Neural Network	ANN	人工神经网络	对数据的完整性要求较高,输入数据需保持一致的维度和格式。大规模、多维数据有助于模型挖掘特征,且模型稳定性依赖于数据均衡分布。此外,输入变量的选择和数据预处理对模型收敛速度和准确性也有显著影响。
Neural network algorithm				
统计学习方法	Linear Discriminant Analysis	LDA	线性判别分析	适用于有已知概率分布或规律的数据。数据的质量和连续性对模型的可信度有直接影响,需要完整、无缺失的时序数据来确保结果的统计意义。
Statistical learning methods	Maximum Likelihood Classifier	MLC	最大似然估计	
聚类算法	Iterative Self-Organizing Data Analysis Technique Algorithm	ISODATA	迭代自组织数据分析技术算法	对数据分布要求较高,适合较大规模的非监督数据集。为获得准确的聚类效果,数据需具备显著的分组特征。此外,噪声和离散值可能影响聚类效果,通常需要预处理数据以提高算法的准确性。
Clustering algorithms	K-Nearest Neighbor	KNN	K 近邻算法	

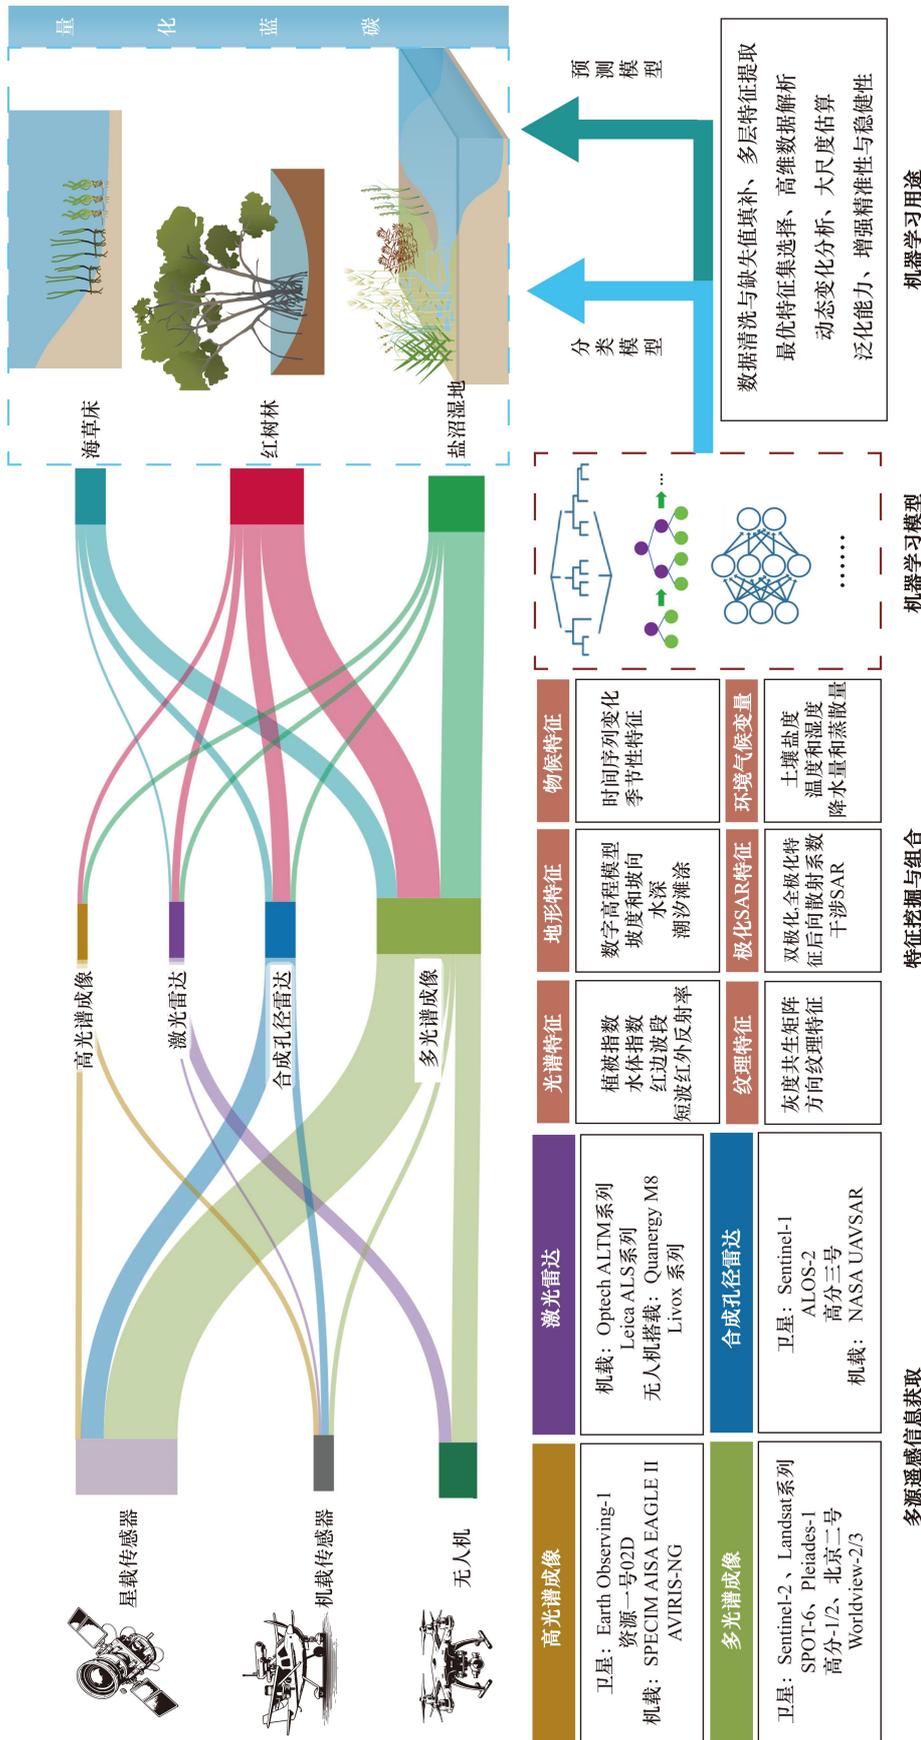


图 1 机器学习利用多源遥感传感器平台与成像技术在量化滨海蓝碳中的应用框架  
 Fig.1 Framework for the application of machine learning in quantifying coastal blue carbon using multi-source remote sensing sensor platforms and Imaging technologies

SAR: 合成孔径雷达 Synthetic aperture radar  
 仅展示部分卫星与传感器名称、重要特征变量与算法示例, 旨在提供概览, 实际应用中, 种类繁多

杂<sup>[27,41]</sup>。当前研究多聚焦于利用无人机对岸边海草残骸进行分类提取并估算碳储量<sup>[42]</sup>和利用长时间序列遥感影像对海草床进行识别分类<sup>[43-44]</sup>,但仍然难以克服海面水体反射光的影响。因此,水下遥感技术逐渐成为未来海草床监测的关键手段。作为目视检查的可行方案,配备光学传感器的自主水下航行器(Autonomous Underwater Vehicles, AUVs)能在海面以下执行更精细的监测任务。Francesco 等<sup>[45]</sup>提出了一种基于机器学习和计算机视觉的框架,利用配备水下摄像头的 AUV 能够自动识别和测量海草床的边界,可对草甸面积做出初步估算。遥感平台硬件能力的提升为遥感监测海草床提供更多可能,但由于不同传感器生成的海量遥感数据呈复杂多维特征,机器学习处理多维数据的出色能力无疑为大尺度蓝碳量化研究提供重要技术支持。

### (3) 特征组合在蓝碳估算中的作用

不同遥感平台生成的数据可通过特征集的组合在蓝碳储量研究中发挥重要作用(图 1)。在选择合适的特征组合用于蓝碳储量估算时,需结合蓝碳生态系统的独特特性和数据的可用性,确保所选特征能够准确表征系统的复杂性和空间变异性<sup>[46-47]</sup>。其中,光谱特征是基于机器学习量化蓝碳的核心特征之一,几乎所有研究都使用。物候指标提供植被动态生长状态信息,是区分不同盐沼植物物种的关键参数<sup>[30]</sup>。例如,张蓉<sup>[18]</sup>根据红树林树种物候期的细微差别,在分类特征集中加入了物候信息,并发现分类总体精度提升了 2.21%—5.21%。此外,地形数据的整合可以为量化蓝碳和海平面上升背景下未来海岸带生态系统响应预测提供更加精确的基础。例如,数字高程模型(DEM)数据的应用显著增强了对红树林地上生物量估算<sup>[27]</sup>和 underwater 海草物种分类<sup>[38]</sup>的精确度。

## 2 应用机器学习算法量化滨海蓝碳储量研究进展

### 2.1 基于机器学习算法的分类与预测技术框架

在机器学习模型中,分类和回归预测是两种常用任务<sup>[20,48]</sup>,分别适用于不同类型的输出。分类任务侧重于将数据分配到预设的类别或标签中,适用于输出结果为离散类别的情况,例如植被类型识别;而回归任务则涉及连续数值的预测,更适用于量化分析,例如估算生物量或碳储量。在现有基于机器学习算法结合遥感数据的研究中,通常依赖于这两种路径的应用:分类和预测(图 2)。

### 2.2 基于分类途径量化滨海蓝碳储量研究进展

本节总结了近 5 年来 17 篇基于机器学习分类途径的蓝碳量化典型研究案例(表 2)。值得注意的是,虽然针对滨海蓝碳生态系统的遥感提取和分类研究数量众多,但遥感分类只是实现蓝碳量化的前序处理步骤,本节所选取的研究不仅关注影像分类,更重要的是拓展至蓝碳储量的量化分析。这些研究在完成分类后,通过构建碳储量模型进一步估算蓝碳生态系统的碳储量,填补了仅限于影像分类的研究范畴,在蓝碳生态系统的碳汇功能精确量化方面具有较高的应用价值。

用于分类途径的机器算法使用频率最高的是 RF,其次是 SVM, CART、XGBoost 模型使用频率也较高。深度学习方法效果显著,得到的分类结果精度较高<sup>[27-28]</sup>。不同生境的植被适用分类算法可能不同,例如,在对位于水面以下的红树林进行识别提取时,呈现分类精度局限性<sup>[41]</sup>,而在盐沼湿地中 RF 的表现优于其他机器学习算法<sup>[52]</sup>,可以准确地对光谱相似的植物群落进行分类。Ha 等<sup>[31]</sup>通过比较五种算法,最终得到最适用于提取海草床分布的是 XGBoost(OA = 82%),并核算得到新西兰的海草床地上生物量密度为 0.61—1.39 Mg/hm<sup>2</sup>。不同于海草床,在盐沼湿地中,表现最好的为 RF(OA = 87.21%)<sup>[30]</sup>。

从分类层次来说,由于不同的湿地植被物种具有不同的生活史和碳封存能力<sup>[57]</sup>,因此分类最好在物种层面进行。徐芳<sup>[50]</sup>将优势种秋茄(*Kandelia candel*)视为群落中唯一一种,并使用异速生长模型计算地上、地下生物量和碳储量作为群落碳储量。2022 年及以后的研究几乎都已经将分类进行到了物种层面,区分物种数最多的达 6 种<sup>[18]</sup>,最少为 3 种<sup>[30]</sup>。在得到分类结果后,大部分研究都采用碳转换系数法,将植被生物量乘以固定系数(一般取 0.5)量化碳库,或使用 InVEST 模型得到碳库的多年动态差异<sup>[51]</sup>。部分研究仅对蓝碳生态系统地上碳库进行量化,大部分研究对地上、地下碳库都进行量化,而单独对于土壤有机碳库的研究较少<sup>[52]</sup>。

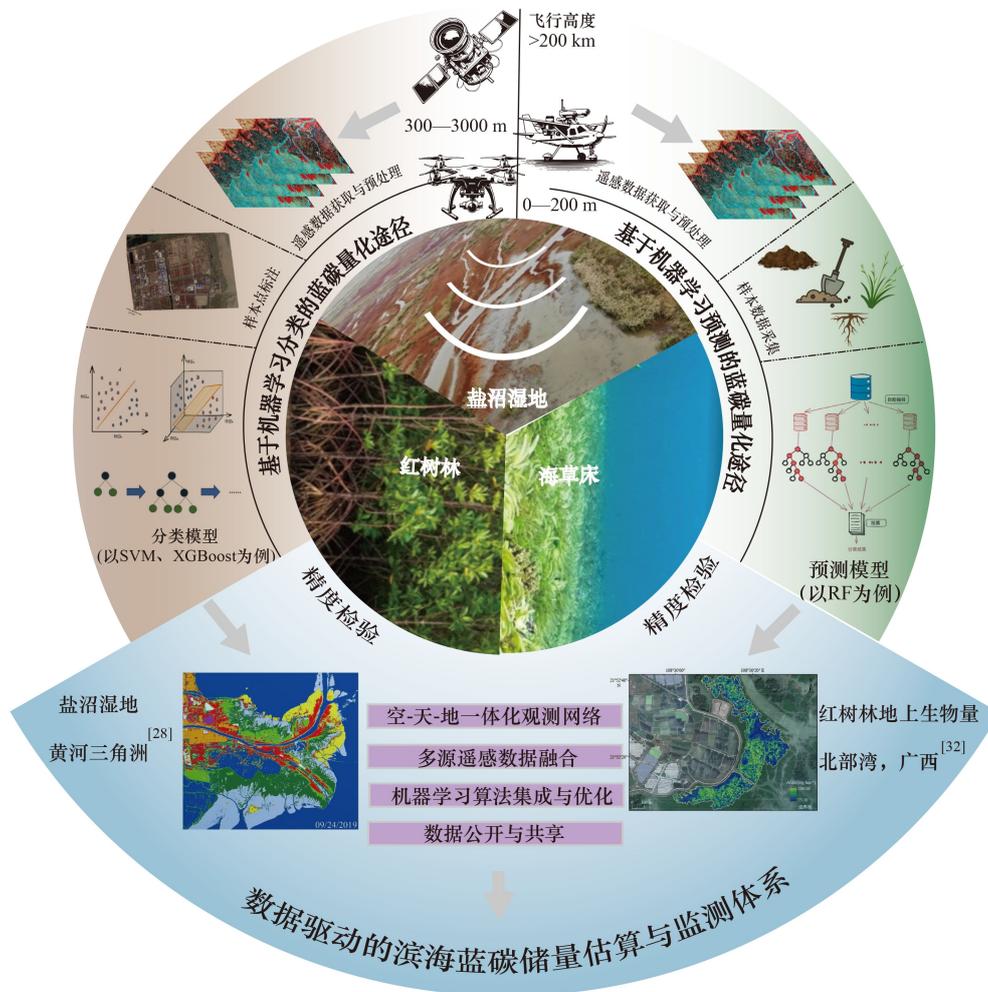


图 2 基于机器学习的滨海蓝碳储量量化技术流程<sup>[28,32]</sup>

Fig.2 Workflow of coastal blue carbon stock quantification using machine learning techniques<sup>[28,32]</sup>

RF:随机森林 Random Forest;SVM:支持向量机 Support Vector Machine;XGBoost:极端梯度提升 Extreme Gradient Boost

### 2.3 基于预测途径量化滨海蓝碳研究进展

本节总结了近 5 年内 21 篇基于机器学习预测途径的蓝碳量化研究(表 3)。在预测途径中,最常用的算法为 RF,其次为 SVM 和 XGBoost。尽管深度学习和 CUBIST 算法使用频率较低,但应用逐渐增多,效果表现良好。相较于分类途径,预测途径的研究更侧重于算法的精度与适用性(表 2),例如,Tian 等<sup>[63]</sup>比较了 8 种机器学习算法,发现 XGBoost 通过防止过度拟合并优化计算效率,在量化红树林 AGB 中表现优异,得到最优精度模型  $R^2$  为 0.83。

在选取的研究案例中,SOC 和 TOC 作为预测指标的应用频率相对较低。由于地理限制和保护区的特殊性,地下生物量的实地调查存在难度,因此学者更关注 AGB 和 AGC 的预测<sup>[69]</sup>。红树林的研究最为广泛,预测指标 SOC、AGC 和 AGB 使用频率较高。目前针对海草床碳库量化的研究较少,主要集中在澳大利亚<sup>[31,62]</sup>和美国<sup>[70]</sup>,我国海草床碳储量研究仅在广东省有报道<sup>[71]</sup>。大多数蓝碳量化研究集中于红树林和盐沼湿地,但样本量不足仍是挑战,Chen 等<sup>[28]</sup>通过生成对抗网络(GANs)扩展了数据集,将原始生物量数据从 13 扩展至 200,显著提升了模型泛化能力,降低了 RMSE。最少样本量的研究使用了 25 个样本,模型  $R^2$  最低为 0.596<sup>[25]</sup>,样本量最多的案例使用了共 10331 个土壤 SOC 数据,绘制了全球的红树林 SOC,最优精度达 0.82<sup>[61]</sup>;盐沼湿地的研究均针对量化 AGC 和 AGB,样本量在 60—409 之间<sup>[72]</sup>。相比之下,海草床的研究相对较少,主要集中在 SOC 和 TOC 的预测上,样本量为 57—285 个。

表 2 基于机器学习分类途径的蓝碳量化典型研究案例

Table 2 Typical Cases of Blue Carbon Quantification Based on Machine Learning Classification Approach

滨海蓝碳生态系统类型 Coastal blue carbon ecosystems	物种组成 Species composition	研究区 Study area	机器学习方法 Machine learning method	测试集最优模型表现 Optimal model performance for test set	量化指标 Quantitative indicators	参考文献 References
红树林 Mangrove	—	Senarang 地区 (印度尼西亚)	RF	—	AGC+BGC	[49]
	秋茄 <i>Kandelia candel</i>	九龙江口, 福建	RF	OA = 93.73% Kappa = 0.9723	AGC+BGC	[50]
	桐花树 <i>Aegiceras corniculatum</i>	福建漳江口, 广东镇 海湾, 广东湛江	RF	OA = 85.57%—88.11% Kappa = 0.83—0.86	AGB	[18]
	秋茄 <i>Kandelia candel</i>					
	白骨壤 <i>Avicennia marina</i>					
	木榄 <i>Bruguiera gymnorhiza</i>					
	红海榄 <i>Rhizophora stylosa</i>					
	无瓣海桑 <i>Sonneratia apetala</i>					
海草床 Seagrass bed	—	St. Joseph Bay, Florida(美国)	DCNN	OA = 96% Kappa = 0.93	BGC	[27]
	—	新西兰河口	RF, SVM, XGBoost*, LightGBM, CatBoost	OA = 82%	AGB	[31]
	—	巴哈马	RF	OA = 71%—76.55% F1-Score = 61.71%—74.76%	AGC+BGC	[43]
	—	天鹅湖, 山东	UNet, SegNet*	OA = 90.1%—95.1%	AGC+BGC	[44]
	大叶藻 <i>Zostera marina</i>	Futtsu(日本)	ISODATA*, SVM, RF, MLC	OA = 90%—93%	AGC+BGC	[42]
盐沼湿地 Saltmarsh	—	Senarang 地区 (印度尼西亚)	RF	—	AGC+BGC	[49]
	芦苇 <i>Phragmites australis</i>	黄河三角洲, 胶州湾	PCA-DBN	$R^2 = 0.85$	AGB	[28]
	碱蓬 <i>Suaeda glauca</i>					
	互花米草 <i>Spartina alterniflora</i>					
	混合物种					
	盐地碱蓬 <i>Suaeda glauca</i>					
	芦苇 <i>Phragmites australis</i>	中国	RF	OA = 90.04% Kappa = 0.89	AGC+BGC	[51]
	互花米草 <i>Spartina alterniflora</i>					
	海三棱藨草 <i>Scirpus mariqueter</i>					
	—	3 个地区 (爱沙尼亚)	RF	OA = 88%—97% Kappa = 0.84—0.96	SOC	[52]
	盐地碱蓬 <i>Suaeda glauca</i>	辽河口	DT	$R^2 = 0.852$	AGC+BGC	[53]

续表

滨海蓝碳生态系统类型 Coastal blue carbon ecosystems	物种组成 Species composition	研究区 Study area	机器学习方法 Machine learning method	测试集最优模型表现 Optimal model performance for test set	量化指标 Quantitative indicators	参考文献 References
红树林、盐沼湿地 Mangrove and Saltmarsh	怪柳 <i>Tamarix chinensis</i>	莱州湾南岸	PCA-SVM	OA = 88.6% Kappa = 0.81	AGC	[ 54 ]
	盐地鼠尾粟 <i>Sporobolus virginicus</i>	Hunter River estuary (澳大利亚)	RF	OA = 68.5%—93.8%	AGC+BGC	[ 55 ]
	盐角草 <i>Sarcocornia quinqueflora</i>					
	盐地碱蓬 <i>Suaeda glauca</i>	渤海湾天津区域	RF*, SVM, CART, GBM	OA = 87.21% Kappa = 0.84	AGC+BGC	[ 30 ]
	盐地碱蓬 <i>Suaeda glauca</i>					
芦苇 <i>Phragmites australis</i>						
互花米草 <i>Spartina alterniflora</i>	中国	RF	OA = 91.43% Kappa = 0.9	AGC+BGC	[ 56 ]	

OA: 总体精度; AGC: 地上碳储量 Aboveground Carbon; BGC: 地下碳储量 Belowground Carbon; AGB: 地上生物量 Aboveground Biomass; SOC: 土壤有机碳 Soil Organic Carbon; 物种组成中“—”表示未区分物种; 机器学习方法中带 \* 代表研究最终选择的最优表现算法并基于该算法进行后续分析

表 3 基于机器学习预测途径的蓝碳量化典型研究案例

Table 3 Typical cases of blue carbon quantification based on machine learning prediction approach

滨海蓝碳生态系统类型 Coastal blue carbon ecosystems	预测指标 Predictive indicators	样本量 Sample volume	机器学习方法 Machine learning method	测试集最优模型表现 Optimal model performance for test set	参考文献 References
红树林 Mangrove	SOC(1 m)	85	PSO-CatBoost	$R^2 = 0.809$ RMSE = 9.30 Mg C/hm <sup>2</sup>	[35]
	AGC	50	RF, SVM, GA-XGBoost *	$R^2 = 0.857$ RMSE = 15.4 Mg C/hm <sup>2</sup>	[26]
	AGB	25	PCA-SVM *, PCA-MLPNN, PCA-RBFNN, PCA-GP, PCA-RF	$R^2 = 0.596$ $\log_{10}$ RMSE = 0.187 $\log_{10}$ MAE = 0.123	[25]
	AGB	227	PSO-LightGBM *, PSO-RF, PSO-KNNR, PSO-XGBoost	$R^2 = 0.7807$ RMSE = 24.69 Mg/hm <sup>2</sup>	[36]
	AGC	88	RF *, SVM, ANN	$R^2 = 0.81$ 相对 RMSE = 0.2 相对 MAE = 0.14	[58]
	AGC	90	RBF	$R^2 = 0.87$	[59]
	SOC	—	RF *, SVM, XGBoost	$R^2 = 0.95$ RMSE = 0.025 Mg C/hm <sup>2</sup> MAE = 0.01 Mg C/hm <sup>2</sup>	[60]
	SOC(1m)	10331	Stacking( LDA, CART, SVM)	$R^2 = 0.44-0.82$	[61]
	SOC(30 cm)	205	CUBIST	$\rho_c = 0.78$ RMSE = 0.2 Mg C/hm <sup>2</sup>	[62]
	AGB	97	RF	$R^2 = 0.62$ RMSE = 50.36 Mg/hm <sup>2</sup>	[40]
	AGB	57	XGBoost *, LightGBM, CatBoost, AdaBoost	$R^2 = 0.8338$ RMSE = 1.55 Mg/hm <sup>2</sup>	[32]
	AGB	96	XGBoost	$R^2 = 0.7237$ RMSE = 21.7 Mg/hm <sup>2</sup>	[37]
	AGB	64	XGBoost *, GBM, RF, SVM, GP, DT, ET, KNN	$R^2 = 0.8319$ RMSE = 22.7638 Mg/hm <sup>2</sup>	[63]
	AGB	104	GA-XGBoost *, GA-CatBoost, GA-GB, GA-SVM, GA-RF	$R^2 = 0.683$ RMSE = 25.08 Mg/hm <sup>2</sup>	[64]
	AGB	227	RF, KNN, XGBoost *	$R^2 = 0.7512$ RMSE = 27.494 Mg/hm <sup>2</sup>	[65]
海草床 Seagrass bed	TOC (50cm)	57	GWO-CatBoost *, GWO-RF, GWO-XGBoost, GWO-RoF	$R^2 = 0.74$ RMSE = 10.64 Mg C/hm <sup>2</sup>	[66]
	SOC(30 cm)	285	CUBIST	$\rho_c = 0.78$ RMSE = 0.2 Mg C/hm <sup>2</sup>	[62]
盐沼湿地 Saltmarsh	AGC	409	RF	$R^2 = 0.36-0.63$ RMSE = 3.1 Mg C/hm	[43]
	AGB	60	RF *, GBM, ANN, KRLS	$R^2 = 0.90$ RMSE = 1.0 Mg/hm <sup>2</sup>	[67]
	AGB	74	RF	$R^2 = 0.72$ RMSE = 1.66 Mg/hm <sup>2</sup>	[48]
	AGB	74	RF	$R^2 = 0.843$ RMSE = 1.47 Mg/hm <sup>2</sup>	[39]
	AGB	84	RF	$R^2 = 0.43$ MAE = 2.573 Mg/hm <sup>2</sup>	[68]

TOC:总有机碳 Total Organic Carbon; RMSE:均方根误差 Root Mean Square Error; MAE:平均绝对误差 Mean Absolute Error;  $\rho_c$ , 协和相关系数 (Concordance Correlation Coefficient), 是评价预测值与真实值一致性的综合指标, 能衡量精度 (Pearson 相关系数) 和一致性 (偏差) 之间的相似性; 部分研究的均方根误差和平均绝对误差没有单位是由于经历了包括归一化, 对数转换等数据预处理步骤

在预测途径中, 特征选择和变量重要性分析逐渐受到重视。主成分分析 (PCA)<sup>[25]</sup>、粒子群优化

(PSO)<sup>[35-36]</sup>、遗传算法(GA)<sup>[26,64]</sup>、灰狼算法(GWO)<sup>[66]</sup>等方法广泛用于特征选择阶段,显著提升了模型的精度和稳定性。Rijal 等<sup>[26]</sup>使用遗传算法从 32 个特征集中筛选了 12 个并且将原 XGBoost 模型精度提升了 0.186,并发现红边波段和两个近红外波段对红树林的 AGC 最敏感。此外,气候和环境变量(如温度、降雨量、太阳辐射等)对蓝碳储量的影响显著<sup>[59]</sup>,如年均温对澳大利亚大堡礁红树林 SOC 的影响率高达 38.5%。

## 2.4 分类与预测途径对比分析

表 4 从十个维度比较了基于机器学习量化蓝碳的分类与预测路径。分类路径侧重于将生态系统的不同植被类型分配到预设的类别中(如红树林、盐沼和海草等),适用于输出结果为离散类别的情况。而预测路径则针对蓝碳储量的连续变量(如地上生物量和土壤有机碳)进行估算,得出碳储量的数值分布。

表 4 分类与预测途径对比

Table 4 Comparison of classification and prediction approaches

比较维度 Comparison dimension	分类途径 Classification approach	预测途径 Prediction approach
目标 Objective	将蓝碳生态系统中的不同植被类型进行分类,识别不同植被的空间分布,结合实测植物生物量或使用碳转换系数实现碳储量估算	根据输入变量预测蓝碳储量的具体数值,以提供精确储量估算
数据需求 Data requirement	样本为不同植被类型的地理坐标记录点;注重空间分辨率	样本为与地理坐标对应的 SOC 或生物量数据,需求高质量的样本,样本量越大,预测精度越高
数据源 Data source	多光谱、SAR、无人机和 LiDAR,其中应用较为广泛的是多光谱遥感数据,尤其是 Landsat 和 Sentinel-2 系列,多源数据融合也逐渐成为主流	广泛采用多源融合数据,包括多光谱、高光谱、SAR 数据,以及 LiDAR,用于增强模型的预测准确性。适合获取多维信息,增强预测模型稳定性和精度。其中,星载中分辨率多光谱和 SAR 数据的结合最为常见
常用算法 Common algorithms	RF、SVM、CART 等适合空间分布的离散分类	RF、XGBoost、CUBIST、深度学习模型适合定量估算,适用于 SOC 储量或生物量的连续性预测
特征选择 Feature selection	主要使用光谱特征、物候特征、地形特征等,适用于初步分辨植被类型	除分类途径使用的特征外,还使用环境因素以及包括社会经济等特征
误差评估方法 Error assessment method	基于模型准确度评估,例如 OA 和 Kappa 系数等	回归误差,常用的评估指标包括 $R^2$ 和 RMSE 等
误差范围 Error range	受制于分类算法性能,受光谱特征、数据质量和生态系统类型影响,误差范围中等 红树林 OA:85.57%—96% 海草床 OA:71%—96% 盐沼 OA:68.5%—97%	误差范围视数据和算法选择而定,通常更精准,但需大数据支持 红树林 $R^2 = 0.44—0.95$ 海草床 $R^2 = 0.74—0.78$ 盐沼 $R^2 = 0.36—0.90$
适用性 Applicability	①数据量较少或基础数据不全时较适用 ②需要大尺度估算,且遥感数据源充足时适用	当数据量充足且具备多维特征时更适用,适合对高精度蓝碳储量预测
优势 Advantages	①可生成蓝碳生态系统空间格局分布情况 ②成本较低,适用于资源有限的区域 ③可较快速完成分类分析	①可生成精确的蓝碳储量数据 ②可结合多种变量,提高预测能力 ③适用性强,适合长时间序列数据分析
不足 Limitations	①分类精度依赖数据源和特征选择,易受光谱相似性影响 ②部分研究仅量化蓝碳生态系统地上碳库,大部分研究对地上、地下碳库都进行量化,而单独对于土壤有机碳库的研究较少 ③部分研究精度评价结果仅针对分类结果,很难得到真实验证	①需要大量样本和高质量数据 ②模型复杂度和计算资源要求高 ③对数据特征选择和变量处理要求高 ④模型过拟合风险

LiDAR:激光雷达 Light detection and ranging; 表中所列算法和数据源仅为主流应用的代表,并非全面覆盖;此外,误差范围基于本章节综述的所有研究,旨在提供参考价值,无统计学意义

两种路径在应用中各有挑战。分类路径在遥感数据的准确性与精细度上具有更高要求,尤其是对地物特征相似的生态系统的识别,需要高精度的遥感影像和大量的地面验证数据。对具有水下特征的海草床,则更依赖于无人机及水下遥感。反之,预测路径的难点在于需要精确的实测数据样本和大量特征选择步骤以提高模型的稳健性。

在碳储量数据稀缺或未知的情况下,分类途径更具优势;而当数据充足且质量较高时,预测途径更适用。本文综述的案例验证了单独应用两种途径的有效性,而将分类和预测结合的“先分类、再预测”方法可更精准地量化蓝碳储量,既提供了用地类型分布,又提高了储量估算精度。已有研究指出,面积是影响蓝碳储量的主要因素<sup>[73]</sup>,仅凭分类是否足以合理估算蓝碳储量仍有待深入探讨。从模型精度角度,目前尚难评估分类与预测途径的优劣,实际应用中,需综合考虑数据准确性、研究目标和数据特征,以实现性能与成本的最佳平衡。未来研究可进一步优化这两种途径的整合策略,通过分类支持下的精细预测,避免处理整个数据集的复杂性,缩短训练时间,降低资源需求,并提升整体效率。

### 3 结论

(1) 现有研究案例地理分布广泛,主要集中在亚洲地区,澳大利亚和美国,全球尺度的研究相对较少。研究主要集中于量化红树林的地上生物量、盐沼湿地碳储量,而对海草床的研究较少。统计显示,RF 作为决策树模型的代表使用频次最多,XGBoost 模型使用频次逐渐增加,深度学习的应用趋势愈发显著。

(2) 多源数据融合是研究热点与趋势。结合星载中分辨率多光谱和 SAR 数据最为常见,但辐射饱和效应等问题仍需解决。UAV 与 LiDAR 的结合也显示出巨大潜力。然而,由于数据源成本和数据处理复杂度等原因,目前结合高光谱、多光谱和 SAR 的研究相对较少。

(3) 特征选择与变量重要性分析在蓝碳量化研究中越来越受到重视,使用主成分分析、粒子群优化、遗传算法和灰狼算法等方法可以有效提升模型精度,减少过拟合风险。

### 4 研究展望

#### 4.1 发展多源数据融合技术

未来蓝碳储量研究的发展趋势在于强化多源遥感数据融合和新型技术的应用,以克服传统单一数据源的局限性,从而显著提升监测精度和覆盖广度。例如,有学者认为将高空间分辨率无人机光学数据和高时间分辨率的 SAR 数据融合可能会在平台间产生强大的协同效应<sup>[74]</sup>。目前,星载中分辨率多光谱和 SAR 数据的结合最为常见<sup>[19,66]</sup>。UAV 与 LiDAR 结合使用的频率也较高,UAV 能够获取高分辨率的地面影像,LiDAR 能够提供三维结构信息,在盐沼湿地<sup>[67]</sup>和红树林<sup>[32,63]</sup>中得到应用并显示出巨大潜力。未来,蓝碳生态系统的监测将需要扩展至水下遥感领域,特别是对于传统遥感难以监测的海草床生态系统。水下无人机(AUV)配备光学传感器,能够克服传统遥感在水下场景中的限制,为海草床蓝碳储量的精确量化提供可能。Francesco 等<sup>[45]</sup>通过机器学习和计算机视觉技术,AUV 可在水下生成二维和三维影像,实现对海草床底部覆盖率和碳储量的动态量化,该技术的发展与多源遥感数据的融合使得蓝碳储量量化研究更加精确而全面。

#### 4.2 强化多维驱动因子的耦合分析

全面纳入气候变化、人类活动干预和自然生态动态等多重因素对于精准预测未来碳储量变化至关重要。在复杂环境下,这些驱动因素往往相互作用,导致碳储量在时空上呈现动态变化,因此亟需构建系统性耦合模型,以揭示变化机制并明确主导因素。在气候变化背景下,海平面上升、气温波动及极端天气事件频发等直接影响生态系统的碳储能力,构建跨尺度、多维度的协同效应与权衡关系模型,有助于深入理解蓝碳储量空间分布与时间演变的关键驱动力。此外,多维驱动因子的协同作用不仅限于气候,还涉及土地利用变化、沿海开发强度、污染压力和生态保护政策等人类活动带来的影响<sup>[75]</sup>。随着沿海开发强度加剧,红树林、盐沼等蓝碳生态系统受到挤压,生态空间逐渐缩小,碳储量因此减少<sup>[76]</sup>,而实施生态保护政策则有助于逆转这一趋势<sup>[77]</sup>。构建多源遥感数据、长时间序列观测及统计模型的集成分析框架,有助于揭示不同区域碳储量的动态变化及其生态驱动机制。通过遥感数据与机器学习技术的深度融合,可在多情景耦合分析下模拟气候因子和人类活动共同作用下的蓝碳储量变化,为滨海生态系统的管理提供有效支持。

#### 4.3 优化样本量与模型可解释性

在蓝碳储量研究中,样地面积、样本量与精度三者之间难以量化出具备统计学显著性的直接关系。虽然

样本量越多通常可提升模型稳健性,但样本量与面积的关系因生态系统类型差异显著,无法一概而论。未来研究应致力于不同生态系统类型中最佳样本量的优化,以实现高效精确的碳储量估算。这不仅有助于在有限资源下获得最佳精度,还能为生态系统管理和政策制定提供有效的支持。此外,采用可解释性机器学习将更有助于模型的可控性,结合土壤学、生态学和海洋学等学科知识,建立具备解释性的耦合机理模型,以进一步解析蓝碳储量的空间分布和变化机制。最后,通过整合分类与预测途径,逐步建立科学成熟的数据融合方法体系,支持多尺度、多时空的综合分析,并提供更全面的生态系统管理信息。

#### 参考文献(References):

- [ 1 ] 唐剑武,叶属峰,陈雪初,杨华蕾,孙晓红,王法明,温泉,陈少波. 海岸带蓝碳的科学概念、研究方法以及在生态恢复中的应用. *中国科学:地球科学*, 2018, 48(6): 661-670.
- [ 2 ] 韩广轩,宋维民,李远,肖雷雷,赵明亮,初小静,谢宝华. 海岸带蓝碳增汇:理念、技术与未来建议. *中国科学院院刊*, 2023, 38(3): 492-503.
- [ 3 ] 陈鹭真,潘良浩,邱广龙. 中国滨海蓝碳及其人为活动影响. *广西科学院学报*, 2021, 37(3): 186-194.
- [ 4 ] 王法明,唐剑武,叶思源,刘纪化. 中国滨海湿地的蓝色碳汇功能及碳中和对策. *中国科学院院刊*, 2021, 36(3): 241-251.
- [ 5 ] 隋玉正,陈小璇,李淑娟,孙大鹏,马歆宁,周涛. 海岸带蓝碳时空演变及其服务价值评估——以胶州湾为例. *资源科学*, 2019, 41(11): 2119-2130.
- [ 6 ] Duarte C M, Middelburg J J, Caraco N. Major role of marine vegetation on the oceanic carbon cycle. *Biogeosciences*, 2005, 2(1): 1-8.
- [ 7 ] McLeod E, Chmura G L, Bouillon S, Salm R, Björk M, Duarte C M, Lovelock C E, Schlesinger W H, Silliman B R. A blueprint for blue carbon: toward an improved understanding of the role of vegetated coastal habitats in sequestering CO<sub>2</sub>. *Frontiers in Ecology and the Environment*, 2011, 9(10): 552-560.
- [ 8 ] Wang F M, Liu J H, Qin G M, Zhang J F, Zhou J G, Wu J T, Zhang L L, Thapa P, Sanders C J, Santos I R, Li X Z, Lin G H, Weng Q H, Tang J W, Jiao N Z, Ren H. Coastal blue carbon in China as a nature-based solution toward carbon neutrality. *Innovation*, 2023, 4(5): 100481.
- [ 9 ] Nellemann C, Corcoran E, Duarte C M, Valdes L, De Young C, Fonseca L E, Grimsditch G. Blue carbon: the role of healthy oceans in binding carbon; a rapid response assessment. Arendal, Norway: GRID-Arendal, 2009.
- [ 10 ] 程浩,邢庆会,陈虹,毛竹,韩建波. 碳中和背景下我国发展滨海蓝色碳汇的优势、挑战及对策. *海洋开发与管理*, 2023, 40(08): 3-10.
- [ 11 ] McKenzie L, Nordlund L, Jones B L, Cullen-Unsworth L, Roelfsema C, Unsworth R. The global distribution of seagrass meadows. *Environmental Research Letters*, 2020, 15(7): 074041.
- [ 12 ] Murray N, Phinn S, Clemens R, Roelfsema C, Fuller R. Continental scale mapping of tidal flats across east Asia using the landsat archive. *Remote Sensing*, 2012, 4(11): 3417-3426.
- [ 13 ] Mcowen C, Weatherdon L, Bochove J W, Sullivan E, Blyth S, Zockler C, Stanwell-Smith D, Kingston N, Martin C, Spalding M, Fletcher S. A global map of saltmarshes. *Biodiversity Data Journal*, 2017, 5: e11764.
- [ 14 ] Wang F M, Sanders C J, Santos I R, Tang J W, Schuerch M, Kirwan M L, Kopp R E, Zhu K, Li X Z, Yuan J C, Liu W Z, Li Z A. Global blue carbon accumulation in tidal wetlands increases with climate change. *National Science Review*, 2020, 8(9): nwa296.
- [ 15 ] Macreadie P I, Costa M D P, Atwood T B, Friess D A, Kelleway J J, Kennedy H, Lovelock C E, Serrano O, Duarte C M. Blue carbon as a natural climate solution. *Nature Reviews Earth & Environment*, 2021, 2: 826-839.
- [ 16 ] 牛书丽,王松,汪金松,夏建阳,于贵瑞. 大数据时代的整合生态学研究——从观测到预测. *中国科学:地球科学*, 2020, 50(10): 1323-1338.
- [ 17 ] 陈一宁,陈鹭真. 滨海蓝碳生态系统的碳库间相互作用研究进展及展望. *海洋学研究*, 2023, 41(1): 3-13.
- [ 18 ] 张蓉. 基于多源遥感数据的红树植物群落地上生物量估算[D]. 长春:中国科学院大学, 2023.
- [ 19 ] Pham T D, Xia J S, Ha N T, Bui D T, Le N N, Takeuchi W. A review of remote sensing approaches for monitoring blue carbon ecosystems: mangroves, seagrasses and salt marshes during 2010—2018. *Sensors*, 2019, 19(8): 1933.
- [ 20 ] Pham T D, Ha N T, Saintilan N, Skidmore A, Phan D C, Le N N, Viet H L, Takeuchi W, Friess D A. Advances in Earth observation and machine learning for quantifying blue carbon. *Earth-Science Reviews*, 2023, 243: 104501.
- [ 21 ] Breiman L. Random forests. *Machine Learning*, 2001, 45(1): 5-32.
- [ 22 ] Araya-Lopez R, de Paula Costa M D, Wartman M, Macreadie P I. Trends in the application of remote sensing in blue carbon science. *Ecology and Evolution*, 2023, 13(9): e10559.
- [ 23 ] 刘瑜,巨袁臻,许强,徐可心,张菁,金时超,李敏,郭庆华,杨秋丽,宣晶,刘瑾,苏艳军. 深度学习在生态资源研究领域的应用、方法和挑战. *中国科学:地球科学*, 2020, 50(10): 1354-1373.
- [ 24 ] Breiman L. Statistical Modeling: The Two Cultures (with comments and a rejoinder by the author). *Statistical Science*, 2001, 16(3): 199-231.
- [ 25 ] Pham T D, Yoshino K, Le N N, Bui D T. Estimating aboveground biomass of a mangrove plantation on the Northern coast of Vietnam using machine learning techniques with an integration of ALOS-2 PALSAR-2 and Sentinel-2A data. *International Journal of Remote Sensing*, 2018, 39(22): 7761-7788.

- [26] Rijal S S, Pham T D, Noer'Aulia S, Putera M I, Saintilan N. Mapping mangrove above-ground carbon using multi-source remote sensing data and machine learning approach in loh buaya, Komodo National Park, Indonesia. *Forests*, 2023, 14(1): 94.
- [27] Lebrasse M C, Schaeffer B A, Coffey M M, Whitman P J, Zimmerman R C, Hill V J, Islam K A, Li J, Osburn C L. Temporal stability of seagrass extent, leaf area, and carbon storage in St. Joseph bay, Florida: a semi-automated remote sensing analysis. *Estuaries and Coasts*, 2022, 45: 2082-2101.
- [28] Chen C, Ma Y, Ren G B, Wang J B. Aboveground biomass of salt-marsh vegetation in coastal wetlands: Sample expansion of *in situ* hyperspectral and Sentinel-2 data using a generative adversarial network. *Remote Sensing of Environment*, 2022, 270: 112885.
- [29] Duarte C M, Lovelock C E, Waltham N J, Young M, Adame M F, Bryant C V, Butler D, Green D, Rasheed M A, Salinas C, Serrano O, York P H, Whitt A A, Macreadie P I. Current and future carbon stocks in coastal wetlands within the Great Barrier Reef catchments. *Global Change Biology*, 2021, 27(14): 3257-3271.
- [30] Kang B Y, Chen X Q, Du Z B, Meng W Q, Li H Y. Species-based mapping of carbon stocks in salt marsh: Tianjin coastal zone as a case study. *Ecosystem Health and Sustainability*, 2023, 9: 0052.
- [31] Ha N T, Manley-Harris M, Pham T D, Hawes I. The use of radar and optical satellite imagery combined with advanced machine learning and metaheuristic optimization techniques to detect and quantify above ground biomass of intertidal seagrass in a New Zealand estuary. *International Journal of Remote Sensing*, 2021, 42(12): 4712-4738.
- [32] 罗瑾璇, 田义超, 张强, 陶进, 黄友菊, 王京真, 张亚丽, 黄卓梅, 邓静雯, 谭雨欣. 利用无人机激光雷达估算红树林地上生物量. *海洋学报*, 2023, 45(8): 108-119.
- [33] Murray N J, Worthington T A, Bunting P, Duce S, Hagger V, Lovelock C E, Lucas R, Saunders M I, Sheaves M, Spalding M, Waltham N J, Lyons M B. High-resolution mapping of losses and gains of Earth's tidal wetlands. *Science*, 2022, 376(6594): 744-749.
- [34] Wang X, Xiao X, Xu X, Zou Z, Chen B, Qin Y, Zhang X, Dong J, Liu D, Pan L, Li B. Rebound in China's coastal wetlands following conservation and restoration. *Nature Sustainability*, 2021, 4(12): 1076-1083.
- [35] Le N N, Pham T D, Yokoya N, Ha N T, Nguyen T T T, Tran T D T, Pham T D. Learning from multimodal and multisensor earth observation dataset for improving estimates of mangrove soil organic carbon in Vietnam. *International Journal of Remote Sensing*, 2021, 42(18): 6866-6890.
- [36] Huang Z M, Tian Y C, Zhang Q, Huang Y J, Liu R D, Huang H, Zhou G Q, Wang J Z, Tao J, Yang Y W, Zhang Y L, Lin J L, Tan Y X, Deng J W, Liu H X. Estimating mangrove above-ground biomass at Maowei Sea, Beibu Gulf of China using machine learning algorithm with Sentinel-1 and Sentinel-2 data. *Geocarto International*, 2022, 37(27): 15778-15805.
- [37] 谭雨欣, 田义超, 黄卓梅, 张强. 北部湾茅尾海无瓣海桑红树林地上生物量反演——基于 XGBoost 机器学习算法. *生态学报*, 2023, 43(11): 4674-4688.
- [38] Ekelund A, Waddington A, Harris S D, Howe W, Dersell C, Josefsson E, Olszewski J, Tingåker T, Yang E, Duarte C M, Gallagher A J. High-resolution, precision mapping of seagrass blue carbon habitat using multi-spectral imaging and aerial LiDAR. *Estuarine, Coastal and Shelf Science*, 2024, 304: 108832.
- [39] 杜英坤. 高分辨率高光谱等多源数据的滩涂植被精细分类与地上生物量估算方法研究[D]. 武汉: 武汉大学, 2023.
- [40] 王德智. 结合 UAV-LiDAR 和卫星遥感数据的红树林多尺度观测方法研究[D]. 武汉: 中国地质大学, 2021.
- [41] Lebrasse M C, Schaeffer B A, Zimmerman R C, Hill V J, Coffey M M, Whitman P J, Salls W B, Graybill D D, Osburn C L. Simulated response of St. Joseph Bay, Florida, seagrass meadows and their belowground carbon to anthropogenic and climate impacts. *Marine Environmental Research*, 2022, 179: 105694.
- [42] Chen J D, Sasaki J, Guo Z L, Endo M. UAV-based seagrass wrack orthophotos classification for estimating blue carbon. *Estuarine, Coastal and Shelf Science*, 2023, 293: 108476.
- [43] Blume A, Pertiwi A P, Lee C B, Tragano D. Bahamian seagrass extent and blue carbon accounting using Earth Observation. *Frontiers in Marine Science*, 2023, 10: 1058460.
- [44] 王璐璐. 基于遥感数据的天鹅湖海草床时空分布分析及碳储量估算[D]. 南京: 南京信息工程大学, 2024.
- [45] Ruscio F, Costanzi R, Gracias N, Quintana J, Garcia R. Autonomous boundary inspection of *Posidonia oceanica* meadows using an underwater robot. *Ocean Engineering*, 2023, 283: 114988.
- [46] Zhang Z, Jiang W G, Peng K F, Wu Z F, Ling Z Y, Li Z. Assessment of the impact of wetland changes on carbon storage in coastal urban agglomerations from 1990 to 2035 in support of SDG15.1. *Science of the Total Environment*, 2023, 877: 162824.
- [47] Chen G W, Jin R J, Ye Z J, Li Q, Gu J L, Luo M, Luo Y M, Christakos G, Morris J, He J Y, Li D, Wang H W, Song L, Wang Q X, Wu J P. Spatiotemporal mapping of salt marshes in the intertidal zone of China during 1985-2019. *Journal of Remote Sensing*, 2022, 2022: 2022/9793626.
- [48] Rasel S M M, Chang H C, Ralph T J, Saintilan N, Diti I J. Application of feature selection methods and machine learning algorithms for saltmarsh biomass estimation using Worldview-2 imagery. *Geocarto International*, 2021, 36(10): 1075-1099.
- [49] Sejati A W, Buchori I, Kurniawati S, Brana Y C, Fariha T I. Quantifying the impact of industrialization on blue carbon storage in the coastal area of Metropolitan Semarang, Indonesia. *Applied Geography*, 2020, 124: 102319.
- [50] 徐芳. 基于 Sentinel-2 的红树林提取及碳储量估算研究[D]. 兰州: 兰州交通大学, 2020.
- [51] Li J T, Yan D D, Yao X Y, Liu Y, Xie S Y, Sheng Y F, Luan Z Q. Dynamics of Carbon Storage in Saltmarshes Across China's Eastern Coastal Wetlands From 1987 to 2020. *Frontiers in Marine Science*, 2022, 9: 915727.

- [52] Villoslada M, Sipelgas L, Bergamo T F, Ward R D, Reintam E, Astover A, Kumpula T, Sepp K. Multi-source remote sensing data reveals complex topsoil organic carbon dynamics in coastal wetlands. *Ecological Indicators*, 2022, 143: 109329.
- [53] 陈官滨. 辽河滨海湿地翅碱蓬群落年碳储量遥感评估[D]. 大连: 大连海洋大学, 2018.
- [54] 杨国强. 昌邑国家海洋生态特别保护区怪柳地上生物量与地上碳储量遥感估算研究[D]. 呼和浩特: 内蒙古师范大学, 2017.
- [55] Lanceman D, Sadat-Noori M, Gaston T, Drummond C, Glamore W. Blue carbon ecosystem monitoring using remote sensing reveals wetland restoration pathways. *Frontiers in Environmental Science*, 2022, 10: 924221.
- [56] 李静泰, 闫丹丹, 么秀颖, 谢思炎, 刘垚, 盛昱凤, 栾兆擎. 中国滨海湿地碳储量估算. *土壤学报*, 2023, 60(3): 800-814.
- [57] 周金戈, 覃国铭, 张靖凡, 卢哲. 中国盐沼湿地蓝碳碳汇研究进展. *热带亚热带植物学报*, 2022, 30(6): 765-781.
- [58] Li Z, Zan Q J, Yang Q, Zhu D H, Chen Y J, Yu S X. Remote estimation of mangrove aboveground carbon stock at the species level using a low-cost unmanned aerial vehicle system. *Remote Sensing*, 2019, 11(9): 1018.
- [59] Anand A, Pandey P C, Petropoulos G P, Pavlides A, Srivastava P K, Sharma J K, Malhi R K M. Use of hyperion for mangrove forest carbon stock assessment in Bhitarkanika forest reserve: a contribution towards blue carbon initiative. *Remote Sensing*, 2020, 12(4): 597.
- [60] Xu W B, He M X, Meng W Q, Zhang Y, Yun H F, Lu Y L, Huang Z M, Mo X Q, Hu B B, Liu B Q, Li H Y. Temporal-spatial change of China's coastal ecosystems health and driving factors analysis. *Science of the Total Environment*, 2022, 845: 157319.
- [61] Maxwell T L, Hengl T, Parente L L, Minarik R, Worthington T A, Bunting P, Smart L S, Spalding M D, Landis E. Global mangrove soil organic carbon stocks dataset at 30 m resolution for the year 2020 based on spatiotemporal predictive machine learning. *Data in Brief*, 2023, 50: 109621.
- [62] Walden L, Serrano O, Zhang M X, Shen Z F, Sippl J Z, Bennett L T, Maher D T, Lovelock C E, Macreadie P I, Gorham C, Lafratta A, Lavery P S, Mosley L, Reithmaier G M S, Kelleway J J, Dittmann S, Adame F, Duarte C M, Gallagher J B, Waryszak P, Carnell P, Kasel S, Hinko-Najera N, Hassan R, Goddard M, Jones A R, Viscarra Rossel R A. Multi-scale mapping of Australia's terrestrial and blue carbon stocks and their continental and bioregional drivers. *Communications Earth & Environment*, 2023, 4: 189.
- [63] Tian Y C, Huang H, Zhou G Q, Zhang Q, Tao J, Zhang Y L, Lin J L. Aboveground mangrove biomass estimation in Beibu Gulf using machine learning and UAV remote sensing. *Science of the Total Environment*, 2021, 781: 146816.
- [64] Pham T D, Yokoya N, Xia J S, Ha N T, Le N N, Nguyen T T T, Dao T H, Vu T T P, Pham T D, Takeuchi W. Comparison of machine learning methods for estimating mangrove above-ground biomass using multiple source remote sensing data in the red river delta biosphere reserve, Vietnam. *Remote Sensing*, 2020, 12(8): 1334.
- [65] 黄友菊, 田义超, 张强, 陶进, 张亚丽, 杨永伟, 林俊良. 资源一号 02D 高光谱数据红树林地上生物量反演. *光谱学与光谱分析*, 2023, 43(12): 3906-3915.
- [66] Ha N T, Pham T D, Pham H T, Tran D A, Hawes I. Total organic carbon estimation in seagrass beds in Tauranga Harbour, New Zealand using multi-sensors imagery and grey wolf optimization. *Geocarto International*, 2023, 38(1): 2160832.
- [67] Tang Y N, Ma J, Xu J X, Wu W B, Wang Y C, Guo H Q. Assessing the impacts of tidal creeks on the spatial patterns of coastal salt marsh vegetation and its aboveground biomass. *Remote Sensing*, 2022, 14(8): 1839.
- [68] Jensen D, Thompson D R, Simard M, Solohin E, Castañeda-Moya E. Imaging spectroscopy-based estimation of aboveground biomass in Louisiana's coastal wetlands: toward consistent spectroscopic retrievals across atmospheric states. *Journal of Geophysical Research: Biogeosciences*, 2024, 129(9): e2024JG008112.
- [69] Tang W W, Zheng M R, Zhao X, Shi J Y, Yang J X, Trettin C. Big geospatial data analytics for global mangrove biomass and carbon estimation. *Sustainability*, 2018, 10(2): 472.
- [70] Byrd K B, Ballanti L, Thomas N, Nguyen D, Holmquist J R, Simard M, Windham-Myers L. A remote sensing-based model of tidal marsh aboveground carbon stocks for the conterminous United States. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 139: 255-271.
- [71] 张彤, 凌娟, 岳维忠, 王友绍, 程皓, 孙红岩, 黄小芳, 梁童茵, 周卫国, 董俊德. 基于 CiteSpace 的广东省典型蓝碳生态系统碳汇研究进展的可视化分析. *热带海洋学报*, 2024, 43(5): 58-68.
- [72] Cai W B, Zhu Q, Chen M T, Cai Y L. Spatiotemporal change and the natural-human driving processes of a megacity's coastal blue carbon storage. *International Journal of Environmental Research and Public Health*, 2021, 18(16): 8879.
- [73] Tang Z W, Chen H F. Estimating sediment carbon stocks in the environment of Taiwan's coastal blue carbon system//EGU General Assembly 2023. Vienna, Austria: Copernicus Meetings, 2023; EGU23-2547.
- [74] Alvarez-Vanhard E, Corpetti T, Houet T. UAV & satellite synergies for optical remote sensing applications: a literature review. *Science of Remote Sensing*, 2021, 3: 100019.
- [75] 智烈慧, 马田田, 高原, 李晓文, 邵冬冬, 郭卫华, 崔保山. 围垦开发下滨海湿地格局演变的自然-人为复合驱动过程. *生态学报*, 2024, 44(21): 9626-9635.
- [76] Wang X X, Xiao X M, Zhang X, Wu J H, Li B. Rapid and large changes in coastal wetland structure in China's four major river deltas. *Global Change Biology*, 2023, 29(8): 2286-2300.
- [77] Duarte C M, Adame M F, Bryant C V, Hill J, Kelleway J J, Lovelock C E, Ola A, Rasheed M A, Salinas C, Serrano O, Waltham N, York P H, Young M, Macreadie P. Quantifying blue carbon stocks and the role of protected areas to conserve coastal wetlands. *Science of the Total Environment*, 2023, 874: 162518.