

洞庭湖湿地净初级生产力估算研究

张猛^{1,2,3}, 陈淑丹^{1,2,3}, 林辉^{1,2,3}, 刘洋⁴, 张怀清⁴

1. 中南林业科技大学 林业遥感信息工程研究中心, 长沙 410004;

2. 中南林业科技大学 林业遥感大数据与生态安全湖南省重点实验室, 长沙 410004;

3. 中南林业科技大学 南方森林资源经营与监测国家林业与草原局重点实验室, 长沙 410004;

4. 中国林业科学研究院资源信息研究所, 北京 100091

摘要: 湿地是地球上重要的“碳库”之一, 针对湿地净初级生产力 NPP (Net Primary Productivity) 模拟中时空分辨率不高和估算精度不稳定等方面的问题, 本文提出了一种修正的 CASA (Carnegie-Ames-Stanford Approach) 模型。首先采用遥感云计算下的时空融合算法快速、准确地获得了时间序列的 Landsat 8 多光谱影像, 解决湿地 NPP 估算中高时空分辨率影像缺失问题。然后, 利用 Landsat 8 数据集 (光谱波段、陆表水体指数、归一化植被指数等) 与自适应 Stacking 算法得到高精度的植被分类图, 并结合植被分类图确定每个植被像元理想条件下最大光能利用率 $\epsilon_{\max}$ 。同时, 利用时序陆表水体指数及降水数据计算获得 NPP 估算中所需的水分胁迫因子。最后, 基于归一化植被指数、水分胁迫因子、 $\epsilon_{\max}$ 及气象数据等多种参数, 驱动 CASA 模型对洞庭湖湿地 NPP 进行估测。研究结果显示, 与其他模型相比, 本文修正 CASA 模型估算的 NPP 与实测的 NPP 具有最高的相关系数 ($R^2=0.85$) 和最低的 RMSE (20.16 g C/m²), 表明该方法能有效、准确地模拟区域湿地生态系统 NPP。洞庭湖区主要湿地植被类型芦苇与苔草的 NPP 均值分别为 424.26 g C/m² 和 357.50 g C/m²。

关键词: 遥感, 湿地, 净初级生产力, CASA, 时空融合, 分类, 洞庭湖湿地

中图分类号: P2

引用格式: 张猛, 陈淑丹, 林辉, 刘洋, 张怀清. 2023. 洞庭湖湿地净初级生产力估算研究. 遥感学报, 27(6): 1454-1466

Zhang M, Chen S D, Lin H, Liu Y and Zhang H Q. 2023. Net primary productivity estimation of Dongting Lake wetland. National Remote Sensing Bulletin, 27(6): 1454-1466 [DOI: 10.11834/jrs.20221744]

1 引言

湿地是地球上重要的“碳库”之一 (张猛等, 2017; Mao等, 2020), 在调节碳平衡以及维持全球气候稳定方面具有不可替代的作用 (Cai等, 2020; Ye等, 2019)。净初级生产力 NPP (Net Primary Productivity) 是单位时间和单位面积内植被通过光合作用固定的有机物质的净积累, 是表征碳通量状况的重要指标 (张猛和曾永年, 2018; 朱文泉等, 2005)。由于持续的气候变化和人类活动, 湿地大面积的消失和退化, 因此, 适时、准确地估算湿地 NPP 对于湿地植被碳储量估算对湿地资源的可持续发展及区域碳循环具有重要的意义。

遥感影像覆盖范围广、重访周期短且获取成本低等特点, 使得遥感数据结合估算模型成为 NPP 反演的主要方法 (Bao等, 2016; Shang等, 2018; Yu等, 2018; 尹小君等, 2020)。早期湿地的 NPP 遥感估算研究主要依靠低空间分辨率遥感数据 (AVHRR, MODIS, SPOT Vegetation) (Bandaru等, 2013; Liu等, 2019), 尽管其能准确的反映 NPP 的时间变化, 但遥感数据空间分辨率过低会导致 NPP 估算结果的空间细节信息呈现不够, 同时还会给 NPP 精度验证带来困难。另外, 由于气候变化和人为因素的持续干扰, 湿地斑块破碎化越来越严重。因此, 高时空分辨率的遥感数据对于湿地 NPP 估算显得更为重要。目前的中高

收稿日期: 2021-12-03; 预印本: 2022-07-11

基金项目: 国家自然科学基金 (编号: 41901385); 高分辨率对地观测系统重大专项 (编号: 21-Y30B02-9001-19/22-2); 博士后科学基金 (编号: 2019M652815, 2020T130731)

第一作者简介: 张猛, 研究方向为湿地遥感。E-mail: mengzhang@csuft.edu.cn

通信作者简介: 张怀清, 研究方向为林业遥感。E-mail: zhang@ifrit.ac.cn

分辨率光学遥感影像数据源十分丰富, 综合考虑数据的历史记录、可获取性、覆盖范围、空间分辨率及处理难易程度, Landsat 数据为长时间序列湿地 NPP 估算的最佳遥感数据源 (Long 等, 2021)。然而受天气及重访周期的影响, 时序 Landsat 数据的获取受到限制。多源遥感时空融合方法的出现为获取时序 Landsat 提供了契机, 并有大量的研究利用时空融合技术来解决遥感影像的“时空矛盾”问题 (Gao 等, 2006; Zhu 等, 2010; Wu 等, 2015; Zhao 等, 2018; Zhang 等, 2021)。总体而言, 基于时空滤波器的融合框架 STARFM (Spatial and Temporal Adaptive Reflectance Fusion Model) 是应用最为广泛的方法。尽管进行了不同方式的改进与应用, 但基于时空滤波器的融合框架仍存在一些不足之处, 如复杂的变化预测能力和预测模型的鲁棒性等 (Cheng 等, 2017)。Cheng 等 (2017) 提出的基于时空非局部滤波器的融合模型 STNLFFM (Spatial and Temporal Nonlocal Filter-based Fusion Model) 在增强预测能力和准确性方面较 STARFM 更有优势, 尤其是针对于复杂多变的景观。然而, 传统的时空融合算法需要对遥感影像进行下载、预处理与融合, 面对大尺度、高时空遥感影像获取时, 时间与运算成本会大大增加。遥感云计算平台 GEE (Google Earth Engine) 为海量遥感数据的存储、快速处理和分析提供了可能, 改变了传统遥感数据的处理和分析模式, 极大地提高了运算效率。因此, 构建基于遥感云计算平台的时空融合算法, 能够快速、有效地解决大尺度、时序密集型 Landsat 数据的获取问题。

光能利用效率模型 CASA (Carnegie-Ames-Stanford Approach) 是不同尺度 NPP 建模和时空动态演变使用最广泛的模型之一 (Potter 等, 1993; Singh, 2011; Yan 等, 2018; 许静 等, 2019; 孙金珂 等, 2020)。在 CASA 模型中, NPP 由植被吸收的光合作用有效辐射 (APAR) 和光能利用效率 (ε) 的乘积得到 (Mu 等, 2013; Piao 等, 2005)。CASA 模型中, 估算 ε 需要确定不同植被类型理想条件下的最大光能利用率 ($\varepsilon_{\max}$), 再结合水分胁迫因子 (W) 与温度胁迫因子 (T) 得到实际光能利用率 ε (Potter 等, 1993; Piao 等, 2005; Bao 等, 2016)。一方面, 确定不同类型的 $\varepsilon_{\max}$, 高精度的植被分布图十分关键。单一机器学习算法容易陷

入局部最优解, 未知样本的泛化能力较差, 在不同分类场景中鲁棒性和稳定性稍显不足。卷积神经网络 CNN (Convolutional Neural Networks) 作为目前深度学习扩展研究最热门的算法之一, 尽管 CNN 在图像分类上由巨大的效率和精度优势, 但其依赖于巨大的训练数据, 同时训练过程复杂且耗时量大。集成学习通过多个基分类器及元分类器来预测最终结果, 因此, 其适用于各种场景的能力较强, 分类准确率较高。目前 Stacking 算法在集成学习模型 (Boosting, Bagging, Stacking) 中在分类任务中相对稳定, 然而 Stacking 算法的基分类器最优组合结构需要多次重复实验才能确定, 当基分类器数量较多时, 该过程将十分繁琐。因此, 本文通过改进 Stacking 算法并对湿地植被进行识别, 以提高湿地植被分类精度和分类效率。

另一方面, CASA 模型中水分胁迫因子通常从单层预算土壤水分模型获得, 但是复杂的模型结构和粗糙分辨率的栅格土壤参数数据会影响 W 和 NPP 的估算精度 (Mao 等, 2014; Xiao 等, 2004; Bao 等, 2016)。陆表水体指数 LSWI (Land Surface Water Index) 代表叶片和冠层含水量以及土壤水分, 已有的研究表明利用 LSWI 可以较为准确地估算水分胁迫因子 W (Xiao 等, 2004; Bao 等, 2016)。然而, Xiao 等 (2004) 计算出来的水分胁迫系数的取值范围为 0 (非常湿润) 到 1 (极端干旱), 与 CASA 模型中水分胁迫因子的取值范围是 0.5 (在极端干旱条件下) 到 1 (在非常潮湿的条件下) 正好相反, Bao 等 (2016) 则对水分胁迫因子的范围进行了修正。利用 LSWI 得到的水分胁迫因子不仅在空间上呈现出与 NDVI 的一致性, 而且还能准确的表达区域的水分胁迫。

基于此, 本文以洞庭湖湿地为研究对象, 采用遥感云平台下的时空融合算法便捷、准确地获得了时间序列 Landsat 影像, 解决了 NPP 估算中高时空分辨影像缺失的问题; 发展自适应 Stacking 集成算法, 并基于该算法获得高精度的湿地植被分布图和单个植被像元中的最大光能利用率; 同时利用时序 Landsat 影像获得 LSWI, 并结合降水数据计算获得 NPP 估算中所需的水分胁迫因子, 最后驱动 CASA 模型对洞庭湖湿地 NPP 进行估测。本研究结果以期改善与提高湿地植被 NPP 估算及碳储量研究提供有效的技术方法。

2 研究区与数据

2.1 研究区概况

本文选择的研究对象为洞庭湖区, 位于长江中游地区的湖南省东北部, 是中国重要的湿地分布区, 也是中国重要的商品粮基地, 对区域气候及可持续发展具有十分重要的意义。该区属亚热带季风气候, 雨热条件十分优异, 主要自然湿地植被类型包括苔草、芦苇, 其他植被主要为林地及其他耕地上的轮值作物 (Cai 等, 2020; Zhang 等, 2020)。




图1 研究区位置图

Fig. 1 Study area

2.2 数据及预处理

研究使用的遥感数据包括 Landsat 8 OLI 多光谱影像和 MOD09Q1 反射率产品, 年份为 2017 年, 均下载于 Google Earth Engine。所下载 Landsat 8 OLI 行列号为 123/39、124/40, 云量均小于 5%, 共 12 景。所需 MOD09A1 数据行列号为 h28h06, 时间段为 1—12 月, 共 46 景。尽管 MOD09A1 数据在合成过程中去除了一些气溶胶和云污染, 但仍然存在着一些无效值, 因此本文利用 TIMESAT 软件包中的 Savitzky-Golay 滤波算法对时序 MOD09A1 进行滤波 (Jönsson 和 Eklundh, 2004)。MOD09A1 数据的预处理还包括转投影 (UTM, 与 Landsat 8 一致)、裁剪和与 Landsat 8 影像进行配准。

野外调查数据包括用于验证分类精度的调查数据和用于验证 NPP 估算的生物量调查数据。用于验证分类精度的调查数据的采集时间为 2017 年 5 月, 采用分层随机抽样方法进行采样, 分别获得

36 个苔草样本、40 个芦苇样本、42 个耕地样本、38 个林地样本、32 个湖泊/河流/库塘样本及 30 个其他样本。用于验证 NPP 估算的生物量样本采集时间为 2017 年 9—10 月, 主要为苔草 (22)、芦苇 (24) 以及两者的混合样本 (25)。为与 Landsat 影像像元相匹配, 样地大小为 30 m×30 m, 内置 5 个 1 m×1 m 的小样方 (位于大样方的对角线和中心位置)。在小样方内采集植被并烘干, 然后基于碳含量将生物质的干重转换为碳的重量, 本文使用的含碳系数为 0.475 (Ye 等, 2019)。

气象数据主要为 2017 年的月平均温度、降水及太阳辐射, 均下载于中国气象数据网 (<http://data.cma.cn>[2021-12-03])。这些数据来自于 40 个气象站和 20 个太阳辐射观测站。此外, 本研究区域中的 DEM (30 m) 及其衍生数据 (坡度、坡向) 结合多元线性回归方法来将气象数据空间化。

其他辅助数据包括 Google Earth 高分辨率影像、GF-1 多光谱影像 (2017 年 5 月) 以及湖南省土地利用现状数据, 主要用于辅助选取湿地分类样本。

3 研究方法

本文提出洞庭湖湿地 NPP 估算方法的技术路线如图 2, 主要包括 3 个部分: (1) 利用遥感云平台下的时空融合算法获得时间序列的 Landsat 8 多光谱影像, 并基于光谱影像计算得到时间序列的 Landsat 8 NDVI 与 LSWI; (2) 基于 Landsat 8 数据集, 利用自适应集成算法 (Stacking) 分类得到高精度的洞庭湖湿地植被分布图; (3) 利用植被分布图确定每个植被像元的最大光能利用率 ($\epsilon_{\max}$), 通过时序 LSWI 与月平均气温得到水分胁迫因子和温度胁迫因子, 同时结合太阳辐射与时序 NDVI, 并驱动 CASA 模型得到高时空分辨率的 NPP。

3.1 遥感云计算下的时空融合算法

本项目基于 GEE 遥感云平台拟构建的时空融合算法, 在解决运算量和运算时间成本高等问题的前提下, 改进了异质性问题, 当土地覆盖类型变动更复杂时, 能够有效提高融合精度。该算法通过 GEE 平台的 Python 端接口实现, 融合算法参考了 Cheng 等 (2017) 提出的 STNLFFM 时空融合模型, 并在数据融合影像的选择上进行了改进, 使得在选用所需融合影像时更加便捷, 总体技术

路线如图3。STNLFFM与STARFM、ESTARFM算法同属于基于时空滤波的数据融合方法,但在选取相似像元时,STNLFFM采用非局域滤波算法(Cheng等,2017)。该算法不仅考虑与中心像元临近的像元,而且还考虑非中心像元的临近像元,因而使得STNLFFM算法能充分利用遥感影像的融合信息,获取更多有用的相似像元信息。在STNLFFM算法中,每个目标像元预测的计算公式如下:

$$F(x, y, B, t_p) = \sum_{k=1}^M \sum_{i=1}^N W(x_i, y_i, B, t_k) \times (a(x_i, y_i, B, \Delta t_k) \times F(x_i, y_i, B, t_k) + b(x_i, y_i, B, \Delta t_k)) \quad (1)$$

式中, $F(x, y, B, t_p)$ 是目标(预测)像元 (x, y) 在预测日期 t_p 的精细分辨率反射率; M 是基准日期

的数目; N 是图像中类似像元的数目,包括目标像素本身。 (x_i, y_i) 是第 i 个相似像元的位置, $W(x_i, y_i, B, t_k)$ 是在基准日期 t_k 处的高分辨率反射图像的第 i 个相似像元的权重。关于STNLFFM与非局部滤波算法的更多细节信息与源代码可参考(Cheng等,2017)。在融合过程中,选择基期影像的日期尽量与预测目标影像的日期接近。通过STNLFFM算法,将2017年46期30 m分辨率的反射率数据融合预测出来,并通过公式计算得到时序NDVI与LSWI。同时,利用真实的Landsat影像对融合得到的Landsat影像进行精度验证,验证指标包括两者的决定系数(R^2)、均方根误差(RMSE)及光谱角(SAM)。




图2 技术路线图

Fig. 2 Flowchart

3.2 基于自适应Stacking集成算法的湿地植被分类

准确的湿地植被分布图是湿地NPP准确估算的一个重要的因素。在湿地植被分类方法,单一机器学习算法容易陷入局部最优解,未知样本的泛化能力较差。集成学习通过多个基分类器及元分类器来预测最终结果,因此,其适用于各种场景的能力较强,分类准确率较高(Zhang等,2020; Cai等,2020; Long等,2021)。目前最流行的集成分类算法包括Boosting、Bagging和Stacking,但Boosting算法在实际情况下常会过分偏向一些难分的样例从而降低了算法的性能,而Bagging算法对于稳定分类器的集成效果常常不是十分理想。因此,本文选择集成学习模型中对稳

定性的分类器集成效果较好的集成学习Stacking模型用于湿地分类研究(Cai等,2020; Zhang等,2020)。为进一步提高Stacking算法的鲁棒性和泛化能力,本文在Stacking算法的基础上,提出了自适应Stacking算法(图4)。在自适应Stacking算法中,首先确定了元分类器。以往的研究表明,使用泛化能力较强的机器算法(如RF(Random Forest))作为元分类器可以纠正多个机器算法对于训练集的偏置情况,并能够防止过拟合现象和提高预测性能。因此,在本研究中,RF算法被用作元分类器。然后,本文Stacking集成学习的分类器组合模型第一层选择学习能力较强和差异性较大的算法作为基分类器以便于提升模型的预测效果,包括支持向量机SVM(Support Vector Machine)、RF、k-近邻

kNN (k-NearestNeighbor)、逻辑回归 LR (Logistic Regression) 和朴素贝叶斯 NB (Naïve Bayes) 等机器学习算法。算法流程基本流程为: (1) 输入训练数据集, 让基分类器自由组合对训练数据集进行预

测, 并得到多个不同的新数据集; (2) 通过元分类器 (RF) 对新的数据集进行再次预测, 得到最终的预测结果。(3) 通过精度验证, 将精度最高的预测结果和最佳的基分类器组合进行输出和显示。




图3 遥感云计算下的时空融合算法流程

Fig. 3 Spatio-temporal fusion algorithm process under remote sensing cloud computing

由于洞庭湖湿地年内水文状况变化较大, 为反映研究区湿地植被真实分布情况, 本文选择了平水期 (5月) 的 Landsat 8 多光谱遥感影像、时间序列 NDVI 和 LSWI 数据用于湿地分类。基于《湿地公约》并结合遥感影像特征与洞庭湖区土地利用实际状况将遥感影像分为水体、苔草滩地、芦苇滩地、耕地、林地、建筑用地、其他。

3.3 基于改进 CASA 模型的湿地高时空 NPP 估算与验证

CASA 模型是 Monteith (1972) 提出的一种植

被光合作用模型, 其中植被的 NPP 可以用 APAR 和光能利用效率 (ε) 表示:

$$NPP(x, t) = PAR(x, t) \times FPAR(x, t) \times \varepsilon(x, t) \quad (2)$$

$$\varepsilon(x, t) = f_1(x, t) \times f_2(x, t) \times W(x, t) \times \varepsilon_{\max} \quad (3)$$

式中, $PAR(x, t)$ 为像元 x 在 t 月的太阳总辐射量, $FPAR(x, t)$ 为植被吸收光合作用的有效辐射, $\varepsilon(x, t)$ 为植被的实际光能利用率; $f_1(x, t)$ 和 $f_2(x, t)$ 为低温和高温下的温度胁迫因子, $W(x, t)$ 为水分胁迫因子, $\varepsilon_{\max}$ 为理想条件下的植被最大光能利用率。




图4 自适应集成学习模型

Fig. 4 Adaptive stacking algorithm

最大光能利用效率 ($\epsilon_{\max}$) 受植物种类的影响, 取决于生命形态 (即草本或木质) 和碳固存的代谢途径 (C_3 或 C_4)。在本研究中, 使用了 Zhu 等 (2006) 基于 BIOME-BGC 模型人生成的 $\epsilon_{\max}$, 该 $\epsilon_{\max}$ 更适合中国的植被状况, 林地、芦苇、苔草以及耕地的最大光能利用率分别设置为 0.692、0.429、0.542 和 0.542。

Xiao 等 (2004) 提出了植被光合作用模型 (VPM) 中的水分胁迫参数 W_{vpm} , 用于估算 CASA 模型中的每个像元的水分胁迫因子:

$$W_{\text{vpm}} = \frac{1 + \text{LSWI}}{1 + \text{LSWI}_{\max}} \quad (4)$$

式中, W_{vpm} 和 $\text{LSWI}_{\max}$ 分别是植被光合作用模型中的水分胁迫因子和单个像元的最大 LSWI (使用最大合成法 MVC 方法计算得到)。然而, 式 (4) 计算出来的 W_{vpm} 水分胁迫系数的取值范围为 0 (非常湿润) 到 1 (极端干旱), 与 CASA 模型中水分胁迫因子的取值范围是 0.5 (在极端干旱条件下) 到 1 (在非常潮湿的条件下) 正好相反。本文利用 Bao 等 (2016) 提出的水分胁迫因子修改算法和时序 Landsat 影像得到的 LSWI 指数计算水分胁迫因子 W , 这不仅增强了数据的准确性, 也提高了数据的分辨率, 具体计算公式如下:

$$W = \left(1 - \frac{1 + \text{LSWI}}{1 + \text{LSWI}_{\max}} \right) + 0.5 \quad (5)$$

根据 Wu 和 Chen (2012), 将降水信息纳入生态系统模型可以提高植被生产力确定的预测性能。因此, 可以通过将 W 与降水标量 (Scaled_p) 相乘来

生成最终的水分胁迫因子 (W_{LSWI}):

$$W_{\text{LSWI}} = W \times \text{Scaled}_p \quad (6)$$

$$\text{Scaled}_p = \frac{\text{Precipitation}}{\text{Precipitation}_{\max}} \quad (7)$$

式中, Precipitation 和 $\text{Precipitation}_{\max}$ 代表空间降水的单个像元在生长季节内的月降水量和月最大降水量。

确定最大光能利用效率和水分胁迫系数后, 本文应用 CASA 模型估算洞庭湖湿地生态系统的 NPP, 估算过程中不需要更改模型中的 PAR, FPAR 和两个温度胁迫因子的计算。利用从地上生物量数据得到的 NPP 值来验证利用本文方法估算得到的 NPP 结果, 验证指标主要为两种数据之间的决定系数 (R^2) 和均方根误差 (RMSE)。

4 结果与分析

4.1 遥感影像融合结果及精度验证

本文选择了 2017 年 5 月 23 日、10 月 14 日的 Landsat 8 与 MOD09Q1 数据作为基期影像, 融合了 2017 年 4 月 21 日 Landsat 8 影像, 并选择了典型湿地分布区 (芦苇、苔草) 来显示和验证基于遥感云平台的融合算法预测结果的精度, 包括影像光谱波段、以及在后续 NPP 研究中需要用到的 NDVI 与 LSWI 指数 (图 5)。从目视效果上, STNLFMM 在利用基期 Landsat 与 MODIS 影像对来预测目标日期的 Landsat 表现出较好的性能。在真彩色合成 (红波段、绿波段及蓝波段) 的情形下, 从空间分布上看, 融合 Landsat 影像与真实 Landsat 影像十分接近, 除了小部分区域外。同时, 基于融合影像计算得到的 NDVI 与 LSWI 指数与真实影像也差异很小。

同时, 本文通过定量的方法来对融合的 Landsat 影像进行精度评价, 融合 Landsat 与真实 Landsat 影像的相关系数、均方根误差及光谱角如表 1。结果显示, 融合影像与真实影像波段之间的决定系数 (R^2) 均大于 0.88, 均方根误差 (RMSE) 均小于 0.03, 且光谱角 (SAM) 小于 3, 这表明融合得到的 Landsat 影像在光谱和空间上与真实的 Landsat 影像基本一致, 融合效果较好, 可以用于后续的湿地制图与 NPP 估算等研究。

4.2 湿地植被分类图

利用自适应 Stacking 算法得到的洞庭湖湿地植

被分布图如图6所示。苔草和芦苇是天然湿地植被，强烈依赖于水资源，因此，主要沿洞庭湖主体周围分布。耕地主要分布在研究区域的中部，那里河网密布且人类活动相对活跃。林地多分布于丘陵和山地，主要分布在研究区的四周。通过自适应集成算法中基分类器的自由组合和测试，

最终算法选择的最优基分类器组合为SVM、kNN和RF，总体分类精度和Kappa系数分布在90%和0.88以上（图7）。此外，植被类型的用户精度和生产者精度分别在85%—92%和83%—91%。结果表明，自适应Stacking算法能够较好的区分不同土地覆盖类型。




图5 MODIS影像、真实Landsat影像与融合Landsat影像
Fig. 5 MODIS, real Landsat and fusion Landsat images

表1 融合 Landsat 与真实 Landsat 之间的决定系数 (R^2)、均方根误差及光谱角

Table 1 Determination coefficient (R^2), RMSE and SAM between fusion Landsat and real Landsat images

波段	参数		
	R^2	RMSE	SAM
Band1	0.913	0.018	2.718
Band2	0.882	0.021	
Band3	0.928	0.022	
Band4	0.875	0.023	
Band5	0.905	0.015	
Band6	0.912	0.022	




图6 基于自适应Stacking算法的洞庭湖湿地分布图
Fig. 6 Distribution map of Dongting Lake wetland based on adaptive Stacking algorithm




图7 基于自适应Stacking算法的湿地分布图分类精度
Fig. 7 Classification accuracy of wetland distribution map based on adaptive stacking algorithm

此外, 本文对自适应Stacking算法与其他传统机器学习方法得到植被分布图的精度进行了对比 (图8)。结果表明, 自适应Stacking算法的分类精度明显高于传统单一分类算法 (总体分类精度和

Kappa系数), 表明该方法在识别复杂条件下的土地覆盖类型具有优势。由于湿地生态系统比较复杂, 在分类中常常存在一些挑战, 例如湿地植被类型之间以及湿地植被和其他植被之间的光谱混合。现有的机器学习算法具有不同的优点和缺点, 因此, 在单一数据集下往往难以得到满意的分类精度。本文提出的湿地分类方案在考虑植被光谱混合问题的同时, 还利用集成学习结合了不同机器分类方法的优势, 从而提高了湿地分类的准确性。




图8 传统机器学习方法与自适应Stacking算法的分类精度对比
Fig. 8 Comparison of classification accuracy between traditional machine classification method and adaptive Stacking algorithm

4.3 湿地NPP估算结果精度验证

在获得湿地植被分布图, 确定NPP估算中苔草、芦苇和林地最终的 $\varepsilon_{\max}$, 并使用修正后的CASA模型估算整个研究区的NPP。基于融合的Landsat NDVI估算得到的NPP具有较高的空间分辨率和详细的空间信息, 显示了不同地类之间的细微差异 (图9 (a))。苔草, 芦苇和耕地之间的差异非常明显, 植被类型之间的界限也很明显。在洞庭湖区的中部, 基本被水域覆盖, 因此其NPP接近于0。苔草和芦苇覆盖的地区, 其年NPP总量达到约300—500 g C/m²。由于人类活动的影响, 研究区域的中部分布着大量耕地, NPP总量大约在250—300 g C/m²。林地主要分布在研究区东部和南部, 其年均NPP总量约为893 g C/m² (图9 (c))。本文利用地上生物量数据得出的NPP实测值来验证模拟NPP的准确性。利用改进CASA模型估算得到的NPP和实测NPP之间的相关系数为 $R^2=0.85$, 两者之间的RMSE为20.16 g C/m² (图9 (b)), 表现出显著的线性关系。因此, 基于CASA模型基于融合得到的Landsat 8 NDVI与LSWI数据的估算得到NPP精度较好, 可以适用于区域高时空NPP的模拟与估算。




图9 洞庭湖湿地 NPP 估算结果及精度

Fig. 9 NPP estimation results and accuracy of Dongting Lake wetland

图 10 显示了 2017 年研究区月 NPP 的空间分布和变化。3—11 月的 NPP 表现出较大的时空变化，这对于湿地植被变化检测和监测具有重要的意义。由于研究区域四季分明，因此植被的生长随季节而变化。因此，研究区域的最大平均 NPP 出现在 8—9 月。同时，估算结果显示的研究区东北部 6—9 月的 NPP 平均值较小，主要原因是由于夏季和秋季降水量较大，苔草、芦苇甚至农作物大面积被淹没，导致相应遥感图像的 NDVI 值降低的缘故。本文的 NPP 估算方法有望为区域湿地碳储量和可持续发展等定量研究提供科学的数据支持。

5 讨论

5.1 不同估算模型下 NPP 估算结果比较

为了验证本文修正 CASA 模型在湿地 NPP 估算中的适用性，将修正 CASA 模型估算的 NPP 结果与其他学者构建的 CASA 模型估计的 NPP 结果进行了比较，包括 CASA (Monteith, 1972)、Zhu-CASA (Zhu 等, 2005) 和 LSWI-CASA (Xiao 等, 2004)。尽管不同 CASA 模型下各种植被类型的 NPP 估算结果存在一些差异，本文修正 CASA 模型、CASA 模型、Zhu-CASA 模型以及 LSWI-CASA 模型估算得到的

研究区 NPP 均值分别为 450.89 g C/m^2 、 463.92 g C/m^2 、 446.31 g C/m^2 和 459.51 g C/m^2 ，但本文修正 CASA 模型模拟的 NPP 值与其他 CASA 模拟的结果比较接近 (表 2)。同时，修正 CASA 模型估算得到的湿地 (芦苇与苔草) NPP 均值，与其他模型估算的结果也较为接近。此外，本文修正 CASA 模型估算的 NPP 值与 NPP 实测值之间表现出了最高的决定系数和最低的 RMSE。误差的存在是不可避免的，但其本文修正 CASA 模型估算的 NPP 值的误差在可接受的合理变化范围内，说明本研究中 CASA 模型估算的 NPP 具有较高的准确性和应用价值，可以作为区域湿地高时空分辨率 NPP 模拟与估算的参考数据。

5.2 本文方法的创新性与局限性

目前，利用高时空分辨率影像进行大范围湿地 NPP 高精度估算的研究比较少。本文借助于遥感云平台下的时空融合技术，获得了高时空分辨率的 NDVI 和 LSWI。基于 CASA 模型的原理，结合植被分布图获得了准确的植被最大光能利用率 ($\varepsilon_{\max}$)，并利用 LSWI 和降水数据，获得了与 NDVI 一致的空间分辨率的水胁迫因子 (W)。结果表明，与其他 CASA 模型相比，本文提出的改进 CASA 模型模拟的 NPP 具有更高的估算精度。




图 10 洞庭湖湿地月 NPP 变化

Fig. 10 Monthly NPP change of Dongting Lake wetland

表 2 不同 CASA 模型下的 NPP 估算结果比较

Table 2 Comparison of NPP estimation results under different CASA models

植被类型	本文修正 CASA	CASA	Zhu-CASA	LSWI-CASA
林地/(g C/m ²)	639.72	668.23	625.36	645.08
芦苇/(g C/m ²)	424.26	402.74	386.04	430.16
苔草/(g C/m ²)	357.50	386.65	348.18	368.49
耕地/(g C/m ²)	382.06	398.05	425.64	394.27
决定系数 R ²	0.8745	0.8264	0.8429	0.8526
RMSE/(g C/m ²)	20.16	23.58	22.85	21.32

在时空融合算法方面,本研究借助遥感云平台 and STNLFFM 算法原理,构建了遥感云计算下的时空融合模型,面对大尺度、高时空遥感影像获取时,大大减少了时间与运算成本。同时,STNLFFM 模型采用非局部滤波算法来选择相似像元,选择参考日期和预测日期之间的时间变化更接近目标像元的变化作为候选相似像元,相比于传统的 STARFM 与 ESTARFM 模型在预测精度上更有优势,尤其是复杂变化的景观。针对湿地这种动态性较强的地理景观,本文方法能够较为准确地抓住湿地随时间发生地变化,从而能对时序 Landsat 数据进行有效预测。植被分类算法方面,本文基于 Stacking 算法框架,发展了自适应融合算法,提

高分类精度的同时,增强了算法的鲁棒性。

尽管能够准确地呈现高时空分辨率 NPP,但本文修正的 CASA 模型存在着一定的局限性。利用基于云平台的时空融合数据能够在快速获取时序 Landsat 影像,解决云雨地区的数据缺失问题。由于洞庭湖湿地的水文情况变化迅速且剧烈,加之混合像元的存在,在数据融合过程中难以捕捉到一些细微变化,在一定程度上会影响融合影像的质量与精度。相较于单一的机器学习,本文提出的自适应集成学习有效提高了分类的精度和算法的鲁棒性。近年来,深度学习中的卷积神经网络在影像分类方面取得了突破,然而海量训练数据及标签的制作限制了其在大尺度土地利用分类上的应用。因此,利用卷积神经网络提取遥感影像深层次特征,再结合集成学习进行影像分类值得探讨。此外,本文构建的修正 CASA 模型还需要在更大范围及其他生态系统中进一步地验证其估算 NPP 的实用性和精度。

6 结 论

针对区域高时空分辨率湿地 NPP 估算研究相对薄弱,本研究基于遥感云平台下的时空融合技术获取了的时间序列 Landsat 数据,并修正的 CASA

模型估算了洞庭湖湿地高时空分辨率的NPP, 解决了高时空分辨率湿地NPP估算中的数据缺失问题以及估算精度不高的问题。结果显示, 融合得到的Landsat数据质量较好, 与真实影像相关性较高。通过精度验证可知, 湿地植被分布图分类精度高。另外, 利用修正CASA估算的NPP与实测的NPP具有较高的相关系数($R^2=0.85$)和较低的RMSE (20.16 g C/m^2)。本文的研究结果以期为湿地遥感分类NPP估算提供数据与技术支持。此外, 本文利用光能利用率模型CASA与NDVI植被指数对湿地植被NPP进行了估算, 但模型和指数都存在对着饱和问题的欠考虑。后续研究将顾及饱和现象, 构建新型植被指数和顾及光饱和的NPP估算模型, 拟进一步提高湿地植被NPP估算精度。

参考文献(References)

- Bandaru V, West T O, Ricciuto D M and Lzaualde R C. 2013. Estimating crop net primary production using national inventory data and MODIS-derived parameters. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80: 61-71 [DOI: 10.1016/j.isprsjprs.2013.03.005]
- Bao G, Bao Y H, Qin Z H, Xin X P, Bao Y L, Bayarsaikan S, Zhou Y and Chuntai B. 2016. Modeling net primary productivity of terrestrial ecosystems in the semi-arid climate of the Mongolian Plateau using LSWI-based CASA ecosystem model. *International Journal of Applied Earth Observation and Geoinformation*, 46: 84-93 [DOI: 10.1016/j.jag.2015.12.001]
- Cai Y T, Li X Y, Zhang M and Lin H. 2020. Mapping wetland using the object-based stacked generalization method based on multi-temporal optical and SAR data. *International Journal of Applied Earth Observation and Geoinformation*, 92: 102164 [DOI: 10.1016/j.jag.2020.102164]
- Cheng Q, Liu H Q, Shen H F, Wu P H and Zhang L P. 2017. A spatial and temporal nonlocal filter-based Data fusion method. *IEEE Transactions on Geoscience and Remote Sensing*, 55(8): 4476-4488 [DOI: 10.1109/TGRS.2017.2692802]
- Gao F, Masek J, Schwaller M and Hall F. 2006. On the blending of the Landsat and MODIS surface reflectance: predicting daily Landsat surface reflectance. *IEEE Transactions on Geoscience and Remote Sensing*, 44(8): 2207-2218 [DOI: 10.1109/TGRS.2006.872081]
- Jönsson P and Eklundh L. 2004. TIMESAT-a program for analyzing time-series of satellite sensor data. *Computers and Geosciences*, 30(8): 833-845 [DOI: 10.1016/j.cageo.2004.05.006]
- Liu Z H, Wang T, Qu Y H, Liu H M, Wu X F and Wen Y. 2019. Prediction of high-quality MODIS-NPP product data. *Remote Sensing*, 11(12): 1458 [DOI: 10.3390/rs11121458]
- Long X R, Li X Y, Lin H and Zhang M. 2021. Mapping the vegetation distribution and dynamics of a wetland using adaptive-stacking and Google Earth Engine based on multi-source remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, 102: 102453 [DOI: 10.1016/j.jag.2021.102453]
- Mao D H, Wang Z M, Du B J, Li L, Tian Y L, Jia M M, Zeng Y, Song K S, Jiang M and Wang Y Q. 2020. National wetland mapping in China: a new product resulting from object-based and hierarchical classification of Landsat 8 OLI images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164: 11-25 [DOI: 10.1016/j.isprsjprs.2020.03.020]
- Mao D H, Wang Z M, Li L and Ma W H. 2014. Spatiotemporal dynamics of grassland aboveground net primary productivity and its association with climatic pattern and changes in Northern China. *Ecological Indicators*, 41: 40-48 [DOI: 10.1016/j.ecolind.2014.01.020]
- Monteith J L. 1972. Solar radiation and productivity in tropical ecosystems. *Journal of Applied Ecology*, 9(3): 747-766 [DOI: 10.2307/2401901]
- Mu S J, Zhou S X, Chen Y Z, Li J L, Ju W M and Odeh I O A. 2013. Assessing the impact of restoration-induced land conversion and management alternatives on net primary productivity in Inner Mongolian grassland, China. *Global and Planetary Change*, 108: 29-41 [DOI: 10.1016/j.gloplacha.2013.06.007]
- Piao S L, Fang J Y, Zhou L M, Zhu B, Tan K and Tao S. 2005. Changes in vegetation net primary productivity from 1982 to 1999 in China. *Global Biogeochemical Cycles*, 19(2): GB2027 [DOI: 10.1029/2004GB002274]
- Potter C S, Randerson J T, Field C B, Matson P A, Vitousek P M, Mooney H A and Klooster S A. 1993. Terrestrial ecosystem production: a process model based on global satellite and surface data. *Global Biogeochemical Cycles*, 7(4): 811-841 [DOI: 10.1029/93GB02725]
- Shang E P, Xu E Q, Zhang H Q and Liu F. 2018. Analysis of spatiotemporal dynamics of the Chinese vegetation net primary productivity from the 1960s to the 2000s. *Remote Sensing*, 10(6): 860 [DOI: 10.3390/rs10060860]
- Singh D. 2011. Generation and evaluation of gross primary productivity using Landsat data through blending with MODIS data. *International Journal of Applied Earth Observation and Geoinformation*, 13(1): 59-69 [DOI: 10.1016/j.jag.2010.06.007]
- Sun J K, Niu H P and Yuan M. 2020. Spatial pattern change and analysis of NPP in terrestrial vegetation ecosystem in China. *Transactions of the Chinese Society for Agricultural Machinery*, 51(6): 162-168 (孙金珂, 牛海鹏, 袁鸣. 2020. 中国陆地植被生态系统NPP空间格局变迁分析. *农业机械学报*, 51(6): 162-168) [DOI: 10.6041/j.issn.1000-1298.2020.06.017]
- Wu C and Chen J M. 2012. The use of precipitation intensity in estimating gross primary production in four northern grasslands. *Journal of Arid Environment*, 82: 11-18 [DOI: 10.1016/j.jaridenv.2012.02.014]
- Wu P H, Shen H F, Zhang L P and Göttsche F M. 2015. Integrated fusion of multi-scale polar-orbiting and geostationary satellite observations for the mapping of high spatial and temporal resolution land surface temperature. *Remote Sensing of Environment*, 156: 169-181 [DOI: 10.1016/j.rse.2014.09.013]

- Xiao X M, Hollinger D, Aber J, Goltz M, Davidson E A, Zhang Q Y and Moore III B. 2004. Satellite-based modeling of gross primary production in an evergreen needleleaf forest. *Remote Sensing of Environment*, 89(4): 519-534 [DOI: 10.1016/j.rse.2003.11.008]
- Xu J, Chen D, Li W L and Wei W. 2019. Study of vegetation net primary productivity in Gannan based on light use efficiency model. *Pratacultural Science*, 36(10): 2455-2465 (许静, 陈迪, 李文龙, 魏巍. 2019. 基于光能利用率模型的甘南州植被净初级生产力研究. *草业科学*, 36(10): 2455-2465) [DOI: 10.11829/j.issn.1001-0629.2018-0018]
- Yan Y C, Liu X P, Ou J P, Li X and Wen Y Y. 2018. Assimilating multi-source remotely sensed data into a light use efficiency model for net primary productivity estimation. *International Journal of Applied Earth Observation and Geoinformation*, 72: 11-25 [DOI: 10.1016/j.jag.2018.05.013]
- Ye X C, Meng Y K, Xu L G and Xu C Y. 2019. Net primary productivity dynamics and associated hydrological driving factors in the floodplain wetland of China's largest freshwater lake. *Science of the Total Environment*, 659: 302-313 [DOI: 10.1016/j.scitotenv.2018.12.331]
- Yin X J, Zhu H H, Gao J, Gao J, Guo L J and Gou Z H. 2020. NPP simulation of agricultural and pastoral areas based on Landsat and MODIS data fusion. *Transactions of the Chinese Society for Agricultural Machinery*, 51(8): 163-170 (尹小君, 祝宏辉, Gao J, 高军, 郭丽洁, 苟贞珍. 2020. 基于 Landsat 和 MODIS 数据融合的农牧区 NPP 模拟. *农业机械学报*, 51(8): 163-170) [DOI: 10.6041/j.issn.1000-1298.2020.08.018]
- Yu T, Sun R, Xiao Z Q, Zhang Q, Liu G, Cui T X and Wang J M. 2018. Estimation of global vegetation productivity from global LAnd surface satellite data. *Remote Sensing*, 10(2): 327 [DOI: 10.3390/rs10020327]
- Zhang M, Lin H, Long X R and Cai Y T. 2021. Analyzing the spatio-temporal pattern and driving factors of wetland vegetation changes using 2000-2019 time-series Landsat data. *Science of the Total Environment*, 780: 146615 [DOI: 10.1016/j.scitotenv.2021.146615]
- Zhang M and Zeng Y N. 2018. Net primary production estimation by using fusion remote sensing data with high spatial and temporal resolution. *Journal of Remote Sensing*, 22(1): 143-152 (张猛, 曾永年. 2018. 融合高时空分辨率数据估算植被净初级生产力. *遥感学报*, 22(1): 143-152) [DOI: 10.11834/jrs.20186499]
- Zhang M, Zeng Y N and Zhu Y S. 2017. Wetland mapping of Dongting Lake Basin based on time-series MODIS data and object-oriented method. *Journal of Remote Sensing*, 21(3): 479-492 (张猛, 曾永年, 朱永森. 2017. 面向对象方法的时间序列 MODIS 数据湿地信息提取——以洞庭湖流域为例. *遥感学报*, 21(3): 479-492) [DOI: 10.11834/jrs.20176129]
- Zhang M, Zhang H Q, Li X Y, Liu Y, Cai Y T and Lin H. 2020. Classification of paddy rice using a stacked generalization approach and the spectral mixture method based on MODIS time series. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 2264-2275 [DOI: 10.1109/JSTARS.2020.2994335]
- Zhao Y G, Huang B and Song H H. 2018. A robust adaptive spatial and temporal image fusion model for complex land surface changes. *Remote Sensing of Environment*, 208: 42-62 [DOI: 10.1016/j.rse.2018.02.009]
- Zhu W Q, Pan Y Z, He H, Yu D Y and Hu H B. 2006. Simulation of maximum light use efficiency for some typical vegetation types in China. *Chinese Science Bulletin*, 51(4): 457-463 [DOI: 10.1007/s11434-006-0457-1]
- Zhu W Q, Pan Y Z, Long Z H, Chen Y H, Li J and Hu H B. 2005. Estimating net primary productivity of terrestrial vegetation based on GIS and RS: a case study in Inner Mongolia, China. *Journal of Remote Sensing*, 9(3): 300-307 (朱文泉, 潘耀忠, 龙中华, 陈云浩, 李京, 扈海波. 2005. 基于 GIS 和 RS 的区域陆地植被 NPP 估算——以中国内蒙古为例. *遥感学报*, 9(3): 300-307) [DOI: 10.11834/jrs.20050344]
- Zhu X L, Chen J, Gao F, Chen X H and Masek J G. 2010. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. *Remote Sensing of Environment*, 114(11): 2610-2613 [DOI: 10.1016/j.rse.2010.05.032]

Net primary productivity estimation of Dongting Lake wetland

ZHANG Meng^{1,2,3}, CHEN Shudan^{1,2,3}, LIN Hui^{1,2,3}, LIU Yang⁴, ZHANG Huaiqing⁴

1. Research Center of Forestry Remote Sensing & Information Engineering, Central South University of Forestry & Technology, Changsha 410004, China;

2. Key Laboratory of Forestry Remote Sensing Based Big Data & Ecological Security for Hunan Province, Central South University of Forestry & Technology, Changsha 410004, China;

3. Key Laboratory of State Forestry & Grassland Administration on Forest Resources Management and Monitoring in Southern Area, Central South University of Forestry & Technology, Changsha 410004, China;

4. Research Institute of Forest Resources Information Techniques, Chinese Academy of Forestry, Beijing 100091, China

Abstract: Wetlands, which are an important carbon pool on Earth, is crucial for human beings and the environment. An accurate estimation of wetland carbon storage and its temporal and spatial changes are conducive to understanding the sustainable development of wetland

ecosystems. Net Primary Productivity (NPP) is the net accumulation of organic matter fixed by photosynthesis per unit time and per unit area of green vegetation and is an important indicator to characterize the status of carbon flux. Therefore, accurate estimation of the spatial patterns and temporal dynamics of wetland NPP at a regional scale is crucial to improving our understanding of the carbon dynamics and sustainable development of terrestrial ecosystems. In China, similar studies have mapped wetlands or estimated wetland NPP using optical data. However, only a few studies have used dense high-spatiotemporal-resolution multispectral images for wetland mapping and considered the accuracy of the light-use efficiency (ϵ) of wetland vegetation types for NPP estimation.

In this study, we proposed an improved Carnegie-Ames-Stanford Approach (CASA) model to generate wetland NPP with high spatiotemporal resolution. First, spatiotemporal fusion algorithm process under remote sensing cloud computing was utilized to produce dense Landsat 8 reflectance images based on Landsat 8 and MOD09A1 images. Then, we explored the potential of the Landsat 8 dataset for vegetation type mapping in a subtropical wetland ecosystem using the adaptive stacking algorithm. Subsequently, the vegetation classification map was used to determine the final prior specification of a maximum ϵ (ϵ_{max}) of each vegetation pixel. Finally, wetland NPP with CASA was estimated using the normalized difference vegetation index, LSWI and wetland vegetation map.

Visually, the SpatioTemporal Fusion Algorithm (STFA) process based on Google Earth Engine (GEE) showed good performance in downscaling MODIS at low to high spatial resolutions, except for some minor flaws that did not affect the overall product. For the fused image, the STFA based on GEE produced an R^2 value larger than 0.88, $RMSE$ less than 0.05, and SAM less than 3, which indicated that the fused image was nearly consistent with original Landsat spectrally and spatially. Therefore, STFA based on GEE is suitable for image fusion in areas experiencing rapid change, such as wetlands and city suburbs. The overall accuracy of the wetland map was above 88%, which indicates the potential of the improved stacking algorithm for delineating different land cover types. Additionally, the user and producer accuracies of vegetation types varied within 85%–92% and 83%–91%, respectively. The classification accuracy associated with the proposed method are notably higher than those of the classical methods (e.g., SVM, RF, and kNN), indicating the superiority of the adaptive stacking algorithm for discriminating land cover in a wetland with complex conditions. The measured NPP values derived from field aboveground biomass data were used to validate the accuracy of simulated NPP. The high correlation coefficient ($R^2=0.85$) and low $RMSE$ (20.16 g C/m²) between the estimated and measured NPP demonstrated a significant linear relationship, and thus the estimated NPP based on Landsat data using the CASA model with the input parameters described above is creditable. The average NPP of sedges and reed wetland were 357.50 and 424.26 g C/m², respectively. The mean NPP values of wetlands (reed and tussock) estimated by the modified CASA model in this study were also closer to those estimated by other models.

In this study, time-series Landsat data were obtained on the basis of the STFA based on GEE, and the modified CASA model estimated the NPP of the Dongting Lake wetlands with high spatiotemporal resolution. The NPP estimation method in this study is expected to provide scientific data support for quantitative research on regional wetland carbon reserves and sustainable development.

Key words: remote sensing, wetland, net primary productivity, CASA, spatio-temporal fusion, classification, Dongting Lake wetland

Supported by National Natural Science Foundation of China (No. 41901385); Forestry Remote Sensing Application System Based on GF Satellites (Phase 2) (No.21-Y30B02-9001-19/22-2); China Postdoctoral Science Foundation (No.2019M652815, 2020T130731)