

DOI: 10.20103/j.stxb.202304070700

靳专, 胥焘, 黄应平, 肖敏, 张家璇, 周爽爽, 席颖, 熊彪. 三峡库区消落带植被 NPP 估算——基于机器学习优化 CASA 模型. 生态学报, 2024, 44(6): 2464-2478.

Jin Z, Xu T, Huang Y P, Xiao M, Zhang J X, Zhou S S, Xi Y, Xiong B. Estimation of vegetation carbon sink in fluctuation zone of Three Gorges Reservoir Area based on CASA Model optimized by machine learning. Acta Ecologica Sinica, 2024, 44(6): 2464-2478.

三峡库区消落带植被 NPP 估算 ——基于机器学习优化 CASA 模型

靳 专^{1,2,3}, 胥 焘³, 黄应平^{1,3,4}, 肖 敏^{1,2,3}, 张家璇^{1,2,3}, 周爽爽^{1,2,3}, 席 颖^{1,3,4}, 熊 彪^{1,2,3,*}

1 湖北省农田环境监测工程技术研究中心(三峡大学), 宜昌 443002

2 三峡大学计算机与信息学院, 宜昌 443002

3 三峡库区生态环境教育部工程研究中心(三峡大学), 宜昌 443002

4 三峡大学水利与环境学院, 宜昌 443002

摘要:三峡库区蓄水后,其生态效应受到广泛关注。消落带植被固碳量作为衡量库区生态系统健康状态的重要指标,对库区碳循环与生态净化具有重要意义。针对消落带不同高程植被接受光照的时间有所差异,且受河流水位变化影响,传统的 CASA 模型在计算消落带植被固碳量时,存在对植物的光能利用率计算不够精确等问题。以三峡库区香溪河陡坡消落带为研究区域,提出了一种耦合 RBFNN 模型(Radial Basis Function Neural Network)与 CASA 模型(Carnegie-Ames-Stanford approach)的新方法(RBF-CASA)。基于 RBFNN 建立环境影响因子模型,借助高程数据及植被指数等特征计算适合消落带区域的环境影响因子。结合 CASA 模型中温度和水分胁迫因子,提高植被在像元尺度上的净初级生产力(Net Primary Productivity, NPP)的估算精度,并对反演结果进行验证。模型验证结果显示:RBF-CASA 模型估算值与观测值的决定系数(Coefficient of determination, R^2)为 0.730 ($P < 0.01$, $n = 32$)。对比原始 CASA 模型,平均绝对误差(Mean absolute error, MAE)降低 10.991,均方根误差(Root mean square error, RMSE)降低了 23.861,相对均方根误差(Relative root mean square error, RRMSE)降低 5.10%,平均绝对百分误差(Mean absolute percentage error, MAPE)降低 1.12%。使用提出的 RBF-CASA 模型在库区水位落干期(7—8 月份)进行固碳量估算,结果表明:NPP 月均值在 66.234—134.144 g C/m²之间,NPP 随着高程的增加呈现起伏变化,其总量在 150—155 m 之间达到峰值,均值在 170 m 以上区域最高。在 2021 年 9 月植被 NPP 均值为 35.883 g C/m²,2022 年 9 月植被 NPP 均值为 25.964 g C/m²,由于降雨量减少、长江水位下降,在 2021—2022 年间植被恢复情况较差。研究结果可为库区碳循环、生态净化及生态修复等决策提供科学依据。

关键词:基于过程的遥感模型(CASA);机器学习;植被净初级生产力(NPP);无人机;环境影响因子模型

Estimation of vegetation carbon sink in fluctuation zone of Three Gorges Reservoir Area based on CASA Model optimized by machine learning

JIN Zhuan^{1,2,3}, XU Tao³, HUANG Yingping^{1,3,4}, XIAO Min^{1,2,3}, ZHANG Jiaxuan^{1,2,3}, ZHOU Shuangshuang^{1,2,3}, XI Ying^{1,3,4}, XIONG Biao^{1,2,3,*}

1 Hubei Engineering Technology Research Center for Farmland Environment Monitoring, China Three Gorges University, Yichang 443002, China

2 College of Computer and Information Technology, China Three Gorges University, Yichang 443002, China

3 Engineering Research Center of Eco-Environment in Three Gorges Reservoir Region, Ministry of Education, China Three Gorges University, Yichang 443002, China

基金项目:国家自然科学基金(22136003, 42177397);长江水环境教育部重点实验室(同济大学)开放基金项目(YRWEF202103);湖北省教育厅优秀中青年人才项目(Q20211205)

收稿日期:2023-04-07; **网络出版日期:**2023-12-22

* 通讯作者 Corresponding author. E-mail: 1173052866@qq.com

4 College of Hydraulic and Environmental Engineering, China Three Gorges University, Yichang 443002, China

Abstract: After the storage of the Three Gorges Reservoir, its ecological impact has received great attention. As an important indicator of ecosystem health in the reservoir area, carbon sequestration of vegetation in fluctuating zone is of great significance to carbon cycle and ecological purification in the reservoir area. Due to the differences in the time of receiving sunlight for vegetation at different elevations in the ebb and flow zone, and the impact of changes in river water levels, the traditional CASA model has problems such as inaccurate calculation of the light energy utilization rate of plants when calculating the carbon sequestration amount of vegetation in the ebb and flow zone. In this paper, a new method (RBF-CASA) for coupling the Radial Basis Function Neural Network (RBFNN) model with the Carnegie Ames Stanford approach (CASA) model is proposed based on the study area of the steep slope fluctuation zone of the Xiangxi River in the Three Gorges Reservoir Area. We have established an environmental impact factor model based on RBFNN. This model utilizes features such as elevation data and vegetation index to calculate environmental impact factors suitable for the region, and combines them with temperature and water stress factors to calculate environmental stress factors, in order to improve the accuracy of estimating vegetation net primary productivity (NPP) at the pixel scale. The results showed that the R^2 between the estimated value and the observed value of the RBF-CASA model was 0.730 ($P < 0.01$, $n = 32$). Compared with the CASA model, the MAE decreased by 10.991, RRMSE decreased by 5.10%, and MAPE decreased by 1.12%. Using the RBF-CASA model to estimate carbon sequestration in the typical steep slope and falling zone of the Three Gorges Reservoir area, the monthly average NPP of the study area in July, the most suitable month for vegetation growth, was between 66.234 and 134.144 g C/m². In the area of the ebb and flow zone, NPP fluctuated with the increase of elevation, with the total amount of NPP reaching a peak value between 150 and 155 m, and the area with the average value of NPP above 170 m had the highest value. In September 2021, the average NPP of vegetation was 35.883 g C/m², while in September 2022, the average NPP of vegetation was 25.964 g C/m². Due to the decrease in rainfall and the decline in the water level of the Yangtze River, the vegetation restoration situation was poor between 2021 and 2022. Therefore, this research can provide scientific basis for carbon cycle, ecological purification and ecological restoration decision-making.

Key Words: CASA model; machine learning; net primary productivity; unmanned aerial vehicle; environmental impact factor model

三峡水库为反季节、周期性水位调度模式,即冬季蓄水至 175m,夏季水位落干至 145m。这种特有的调度模式使得库区形成落差约 30m,面积约 348.9km²消落带区域^[1]。消落带分布着丰富的狗牙根、苍耳等典型植被。消落带中植被作为泥土、有机物、农药以及各种有害物质进入库区水域前的最后的生态防线,为库区生态安全提供了有力保障;同时,也为库区碳汇发挥着重要作用。植被固碳量作为衡量库区生态系统健康状态的重要指标,对其进行实时监测及估算能更好地了解库区的生态状况,对库区生态净化、碳循环具有重要指导意义。

NPP 是单位时间内单位面积植被累积有机物的总量^[2],代表植被的固碳能力。近年来,随着国际环境保护计划的实施以及双碳政策的不断落实,大量有关 NPP 的野外调查、定位估测以及建立模型模拟研究陆续开展,并取得了一系列成果。对 NPP 的估算也由野外监测到通过卫星影像进行模型估算^[3-4],其中主流方法就是通过 CASA 模型^[5]估算研究区域的 NPP 总量。与其他模型比较而言,CASA 模型所需数据的更易于获取,因此可以减少由于数据缺失以及人为因素引起的偏差。从而一定程度降低了实测数据用点代替面所造成的误差,且更便于推广使用^[6-7]。然而消落带区域随着水位的变化而变化,影响到 NPP 的估算精度。因此,CASA 模型在估算消落带植被 NPP 存在一定的局限性。

随着人工智能方法的发展,为人们计算 NPP 提供了新的途径。虽然机器学习方法在植被固碳估算精度和范围都有较好的效果,但是都需要大量现场测量数据,才能保证模型的准确度^[8-9]。同时,目前的固碳方法未尝试将机器学习与 CASA 模型进行结合。为此,本文提出运用少量野外实测数据建立环境影响因子模型并

耦合 CASA 模型计算 NPP 的方法。此外,大部分卫星影像存在分辨率低,难以获取实时目标数据的问题。而无人机具有灵活性强、航拍影像分辨率高、实时性好、在人力难以到达的区域可用性好等优点^[10-14]。并且无人机影像结合实测数据进行反演的方法已被证实在生态环境监测中具有更大的优势。

本研究采用无人机影像、高程数据、太阳辐射以及降雨数据。通过小样本的实测数据建立的环境影响因子模型,再结合 CASA 模型中温度和水分胁迫因子提高植被在像元尺度上的 NPP 估算精度。解决 CASA 模型在消落带估算 NPP 精度不高的问题。使得对消落带区域的 NPP 估算更加精确合理,从而能为消落带生态环境监测和评价提供依据。

1 研究区域概括与数据源

1.1 研究区域概括

香溪河流域地处东经 110°25′—111°06′,北纬 30°57′—31°34′之间,人口在 26.7 万人左右,河道总长 97.3km,流域总面积 3099km²;东源于神农架林区骡马店(东河),西源于神农架山南(西河),从北向南纵贯兴山县全境,最终于秭归县香溪镇东注入长江(图 1)。




图 1 三峡库区香溪河地理位置以及采样区分布

Fig.1 Geographic Location and Sampling Area Distribution of Xiangxi River in the Three Gorges Reservoir Area

该流域属亚热带大陆性季风气候,气候呈垂直变化^[15-16],气候特征十分显著。年均温度约为 17.46℃,年均降雨量约 919.734mm,年总辐射约为 4400MJ/m²。对消落带区域植被进行调查,共发现植物 18 科 34 属 34 种,其中禾本科植物种类最丰富为 9 种 9 属,菊科 4 种 4 属,大戟科 3 种 3 属,廖科、茄科、苋科均为 2 种 2 属。消落带植被垂直分布明显,底部区域主要分布狗牙根、香附子;中部区域物种较多但数量较少,其中稗呈现带状分布;上部区域植物种类和数量相对较多,主要植被为苍耳(图 2)。

1.2 数据来源

1.2.1 气象数据

研究中利用的温度、降雨数据来源于 NOAA 网站(<https://www.ncei.noaa.gov/>)以及中国气象数据网(<http://data.cma.cn/>),辐射数据来源于地理遥感生态网(<http://www.gisrs.cn/>),时间是 2021 与 2022 年的 7、8、9 月的,站点涉及 57461 宜昌站和 57359 兴山站。数据内容为日度降雨量、温度、辐射数据,通过处理获得

月降水量、月平均气温、月总太阳辐射数据。然后使用克里金插值获取研究区域的气象数据。

1.2.2 实测数据

研究考虑消落带区域较为狭窄细长,因此同一采样区降雨与温度变化不明显,所以选取香溪河消落带 8 个典型区域作为采样区,利用无人机对采样区进行航拍,规避部分影响。每个采样区沿消落带 145—175m 设置 4 个高程,每个高程选取两个样方,共 64 个样方。每个样方按照 0.3m×0.3m 的大小,应用收获法采集其全部植物体。采样时手持 GPS 定位获取并记录对应样方的高程数据、经纬度,以便进行高程校准。将样品装入袋中,带回实验室在 80℃ 恒温箱内烘至恒重,称其干重。由于 NPP 实测数据难以直接获取,参考大量文献发现,NPP 能通过生物量间接获取。因此,最终 NPP 的实测值是将生物量乘以转换系数(系数 $r=0.45$)进行换算^[17-18]。并将实测数据按照 1:1 的比例分割为训练集与验证集。由于缺少直接监测实际光能利用率的设备,所以将训练集中的实测 NPP 数据通过公式 1,推导计算实际光能利用率。



图 2 香溪河消落带与植被情况

Fig.2 Xiangxi River Fading Zone with Vegetation

1.3 无人机数据

使用大疆精灵 4 RTK 四翼无人机搭载 1 个可见光传感器和 5 个多光谱单色传感器进行拍摄。该多光谱传感器可捕获红色波段、绿色波段、蓝色波段、近红外波段、红边波段 5 个波段信息。于 2021 年 9 月和 2022 年 7、9 月在香溪河消落带区域进行低空飞行以及数据采集。为实现消落带区域植被的动态监测,飞行拍摄高度约 100m,垂直于地平线进行拍摄。为确保获得影像不受大气等因素的影响,无人机飞行采样时段选择晴朗无云、无持续风。

研究所用的无人机数据由 NDVI 影像与高程模型影像组成,利用 Pix4Dmapper 导入数据、快速检查、加入控制点、空三、点云加密等^[12],获得 5 个波段信息的数字正射影像(Digital Orthophoto Map, DOM)以及数字地表模型(Digital Surface Model, DSM),将 DOM 通过波段运算获得 NDVI 影像;高程模型数据通过 DSM 与实测高程值,通过 ArcGIS 进行校正获得。利用 ENVI5.3 中支持向量机方法对 DOM 进行植被分类操作,并裁剪出消落带区域。其中 4 号研究区域的消落带植被影像、高程分布以及 NDVI 植被指数空间分布如图 3 所示。将 NDVI 影像数据、月降水量、月平均气温、月总太阳辐射数据以及高程影像数据进行像元尺度读取并代入优化后的模型中,计算整片区域像元尺度的 NPP。

2 研究方法

2.1 RBF-CASA 模型

在计算过程中,NPP 主要由植被所吸收的有效光合辐射(APAR)与实际光能利用率来确定。而消落带区域的植被生长情况很大程度上受蓄水的影响,不同高程的植被生长状况差距较大。因此使用高程数据以及多种植被指数,通过机器学习的方法来计算高程与 NDVI 对 NPP 的影响因子。改变实际光能利用率的计算方法,进而优化 CASA 模型。RBF-CASA 模型计算 NPP 整体技术路线流程如图 4:




图 3 典型区域的消落带植被影像、高程分布以及 NDVI 植被指数空间分布

Fig.3 Vegetation image, NDVI vegetation index spatial distribution and elevation distribution of fluctuating zone in typical area

NDVI:归一化植被指数 Normalized difference vegetation index




图 4 整体技术路线流程图

Fig.4 Overall Technical Route Flow Chart

NPP:净初级生产力 Net Primary Productivity; CASA:卡内基-艾姆斯-斯坦福方法 Carnegie-Ames-Stanford Approach; BP:反向传播 Back propagation; RBF:径向基神经网络 Radial basis function network; RF:随机森林 Random forest

RBF-CASA 模型总体框架如图 5:

计算过程:

$$NPP(x, t) = SR(x, t) \times FPAR(x, t) \times \varepsilon(x, t) \times 0.5 \quad (1)$$

式中, $NPP(x, t)$ 、 $SR(x, t)$ 、 $FPAR(x, t)$ 、 $\varepsilon(x, t)$ 分别代表植被净初级生产力 ($\text{gC m}^{-2} \text{a}^{-1}$)、像元 x 在 t 月的太阳总辐射量 (MJ/m^2)、有效辐射吸收比例、实际光能利用率 (gC/MJ); 0.5 表示植被所利用的有效辐射占总辐射的比例^[19];

$$FPAR(x, t) = (FPAR(x, t)_{\text{ndvi}} + FPAR(x, t)_{\text{srvi}}) / 2 \quad (2)$$

$$FPAR(x, t)_{\text{ndvi}} = \frac{(NDVI(x, t) - NDVI_{i, \min}) \times (FPAR_{\max} - FPAR_{\min})}{NDVI_{i, \max} - NDVI_{i, \min}} + FPAR_{\min} \quad (3)$$




图5 优化后的 CASA 模型总体框架图

Fig.5 Overall framework of optimized CASA model

SR: 太阳辐射 Solar Radiation; PAR: 植被能利用的光合有效辐射 Photosynthetically active radiation; FPAR: 光合有效辐射吸收比例 Fraction of photosynthetically Active Radiation; APAR: 光合有效辐射 Absorbent photosynthetically active radiation; DSM: 数字地表模型 Digital Surface Model; $\epsilon_{\max}$: 最大光能利用率 Maximum light energy utilization rate

$$FPAR(x, t)_{\text{srvi}} = \frac{(SRVI(x, t) - SRVI_{i, \min}) \times (FPAR_{\max} - FPAR_{\min})}{SRVI_{i, \max} - SRVI_{i, \min}} + FPAR_{\min} \quad (4)$$

$$SRVI(x, t) = \frac{1 + NDVI(x, t)}{1 - NDVI(x, t)} \quad (5)$$

式中, $FPAR(x, t)_{\text{ndvi}}$ 、 $FPAR(x, t)_{\text{srvi}}$ 是通过归一化植被指数与比值植被指数计算出来像元 x 在 t 月的植被层对光合有效辐射吸收比例; $NDVI(x, t)$ 、 $SRVI(x, t)$ 为像元 x 在 t 月的归一化植被指数与简单比值植被指数, $FPAR_{\max} = 0.95$ 与 $FPAR_{\min} = 0.001$ 作为独立参数, $NDVI_{i, \min}$ 、 $SRVI_{i, \min}$ 取所有 $NDVI$ 值与 $SRVI$ 值的 5% 百分位, $NDVI_{i, \max}$ 、 $SRVI_{i, \max}$ 取所 $NDVI$ 值与 $SRVI$ 值的 95% 百分位;

$$\epsilon(x, t) = T_1(x, t) \times T_2(x, t) \times W(x, t) \times \epsilon_{\max} \times \lambda(x) \quad (6)$$

式中, $T_1(x, t)$ 与 $T_2(x, t)$ 为温度影响因子; $W(x, t)$ 为水分影响因子; $\epsilon_{\max}$ 为最大光能利用率^[20], 由于消落带区域典型植被属于草地, 所以本文参考 CASA 模型的相关研究结果^[21], 消落带的最大光能利用率取 0.542; $\lambda(x)$ 为高程影响因子和 $NDVI$ 影响因子;

$$\lambda(x) = \text{RBF}(NDVI(x, t), H(x)) \quad (7)$$

式中, $H(x)$ 为像元 x 的高程数据; $\text{RBF}(NDVI(x, t), H(x))$ 是将通过实测值推导出的 $\lambda(x)$ 与对应 $NDVI(x, t)$ 、 $H(x)$ 作为训练参数, 通过环境影响因子模型, 训练出来的函数。因为无人机影像受到坡度影响获得的 $NDVI$ 数据有所差异, 为了消除消落带地形的坡度影响, 将 $NDVI$ 再次作为参数输入, 以矫正坡度影响。由于消落带区域的高程与坡度特点, 不同高程土壤中含水量差异较大, 离河流更近的高程土壤含水量更高, 所以高程影响因子其实是间接性的关注土壤含水量对 NPP 的估算影响。

$$T_1(x, t) = 0.8 + 0.02 \times T_{\text{opt}}(x, t) - 0.0005 \times [T_{\text{opt}}(x, t)]^2 \quad (8)$$

$$T_2(x, t) = \frac{1.184}{1 + e^{0.2 \times (T_{\text{opt}}(x, t) - 10 - T(x, t))}} \times \frac{1}{1 + e^{0.3 \times (-T_{\text{opt}}(x, t) - 10 + T(x, t))}} \quad (9)$$

$$W(x, t) = 0.5 + 0.5 \times \frac{E(x, t)}{E_p(x, t)} \quad (10)$$

$$E_p(x,t) = \frac{E(x,t) + E_0(x,t)}{2} \tag{11}$$

$$E(x,t) = \frac{P(x,t) \times Rn(x,t) \times (P(x,t)^2 + Rn(x,t)^2 + P(x,t) \times Rn(x,t))}{(P(x,t) + Rn(x,t)) \times (P(x,t)^2 + Rn(x,t)^2)} \tag{12}$$

式中,取 NDVI 平均值最高月份的平均气温作为最适温度 $T_{opt}(x,t)$ ($^{\circ}\text{C}$); $T(x,t)$ 为像元 x 在 t 月的平均温度 ($^{\circ}\text{C}$); $P(x,t)$ 表示像元 x 在 t 月的降雨量(单位 mm); $E(x,t)$ 为实际蒸散量(单位 mm); $E_p(x,t)$ 为潜在蒸散量(单位 mm); $E_0(x,t)$ 表示局地潜在蒸发量(单位 mm); $Rn(x,t)$ 表示像元 x 在 t 月的地表净辐射量(单位 MJ/m^2)^[22]。

$$Rn(x,t) = \sqrt{E_0(x,t) \times P(x,t)} \times \left[0.369 + 0.598 \times \sqrt{\frac{E_0(x,t)}{P(x,t)}} \right] \tag{13}$$

$$E_0(x,t) = 16 \times \left(\frac{10 \times T(x,t)}{I_x} \right)^{a_x} \tag{14}$$

$$I_x = \sum_{i=1}^{12} \left(\frac{T(x,t)}{5} \right)^{1.514} \tag{15}$$

式中, I_x 为代表 12 个月总和热量指标; a_x 为因而异的常数。

2.2 优化模型特征选择

利用 ENVI5.3 的波段计算器,分别计算出基于多光谱影像的消落带区域多种植被指数^[23—24],所需植被指数计算公式见表 1:

表 1 植被指数计算公式
Table 1 Calculation Formula of Vegetation Index

植被指数类型 Vegetation index type	计算公式 Calculation formula	来源 Source
归一化植被指数 Normalized Difference Vegetation Index	$NDVI = (NIR - R) / (NIR + R)$	[25]
阴影植被指数 Shadow Vegetation Index	$SVI = NDVI \times NIR$	[26]
差值环境植被指数 Difference Environmental Vegetation Index	$DVI = NIR - R$	[27]
三角植被指数 Triangle Vegetation Index	$TVI = 60 \times (NIR - G) - 100 \times (R - G)$	[28]
土壤调节植被指数 Soil Adjusted Vegetation Index	$SAVI = (1 + L) \times (NIR - R) / (NIR + R + L)$	[29]
叶绿素指数 Green Chlorophyll Vegetation Index	$GCVI = (NIR / G) - 1$	[30]
增强型植被指数 Enhanced Vegetation Index	$EVI = 2.5 \times ((NIR - R) / (NIR + 6 \times R - 7.5 \times B + 1))$	[31]
修改型土壤调节植被指数 Modified Soil Adjusted Vegetation Index	$MSAVI = (2 \times NIR + 1 - \sqrt{(2 \times NIR + 1)^2 - 8(NIR - R)}) / 2$	[32]

SVI;阴影植被指数 Shadow Vegetation Index;DVI;差值环境植被指数 Difference Environmental Vegetation Index;TVI;三角植被指数 Triangle Vegetation Index;SAVI;土壤调节植被指数 Soil Adjusted Vegetation Index;GCVI;叶绿素指数 Green Chlorophyll Vegetation Index;EVI;增强型植被指数 Enhanced Vegetation Index;MSAVI;修改型土壤调节植被指数 Modified Soil Adjusted Vegetation Index;NIR;近红外波段 Near infrared band;R;红色波段 Red band;G;绿色波段 Green band;L;土壤调节系数 Soil regulation coefficient;B;蓝色波段 Blue

参考文献^[33—36]发现坡度与高程对于植被指数以及 NPP 有着重要影响,尤其在消落带区域植被指数随坡度的变化趋势相对明显和单一。在所有月份和季节里,呈现出随坡度增加而增大的趋势,并且植被指数是 NPP 与实际光能利用率的重要影响因素。因此,在优化模型的过程中本研究对多种植被指数与 NPP 和实际光能利用率进行相关性分析。实际光能利用率是通过实测 NPP 数据与公式 1 推导获得。如表 2 所示,NDVI 与 NPP 的相关性最高,相关系数达 0.799,并且排除温度与降雨的胁迫因子影响后 NDVI 对实际光能利用率的相关性依旧最高。因此,使用高程数据以及 NDVI 作为特征输入建立环境影响因子模型,输出 $\lambda(x)$ 影响因子。

2.3 环境影响因子模型

影响因子是实际光能利用率的重要组成部分,通过构建的环境影响因子模型提高环境因子的精度,从而

来对 CASA 模型进行优化。而 RBFNN^[37]能较好的拟合各种连续函数。因此,使用 RBFNN 来构建环境影响因子模型,模型训练步骤如图 6 所示。




图 6 环境影响因子模型训练流程图

Fig.6 RBF Training Environment Factor Flow Chart

H: 高程 elevation; h_i : 高程数据通过特征输入得到的数据; C_i : 中心点 Center point; $G1_i$: NDVI 通过激活函数后的数值 The value of NDVI after activating the function; $G2_i$: h_i 通过激活函数后的数值 The value of h_i after activating the function; $G1_i^+$: $G1_i$ 求逆矩阵 $G1_i$ inverse matrix; $G2_i^+$: $G2_i$ 求逆矩阵 $G2_i$ inverse matrix; $\lambda 1_i$: 环境影响因子 environmental impact factors; w_i : 高程影响因子矩阵 Elevation Impact Factor Matrix; W_i : NDVI 影响因子矩阵 NDVI Impact Factor Matrix

环境影响因子模型构建三层网络。第一层为输入层,输入数据将特征信息传递给隐含层,模型读入 NDVI、高程、 λ 数据,并对高程数据进行特征缩放,将不同特征的值量化到 $[0, 1]$ 之间。

第二层为隐含层,本层确定其节点数目、核函数、中心点以及径基宽度。使用 RBF 函数即(高斯函数)作为模型的核函数,高斯函数如公式 16,径基宽度的求解方法如式 17:

$$\varphi(x) = \exp\left(-\frac{\|x - c_i\|^2}{\sigma_i^2}\right) \quad (16)$$

$$\sigma_i = \frac{c_i}{\sqrt{2n}} \quad (17)$$

式中, x 为输入的特征向量,在该模型中为高程特征与 NDVI 特征; $\varphi(x)$ 为特征向量通过高斯径向基函数得到

的第 i 个输出向量; σ_i 为第 i 个中心点通过公式 17 获得的半径宽度; c_i 为第 i 个隐含层节点的中心点, n 为中心点的个数。该网络层中, 先使用聚类算法替代随机选取计算出中心点, 进而计算出半径宽度; 样本经过 RBF 激活函数进行转换后, 再计算每个中心点到样本的距离; 然后训练出隐藏层与输出层之间的权重, 通过对比替代前后效果, 使用聚类算法的模型鲁棒性得到提升。

第三层为输出层, 通过该层得到建立的模型和模拟结果。本文将计算出的高程与 NDVI 影响系数输出与 CASA 模型结合, 再评价模拟值与真实值的差异。

表 2 消落带植被的 NPP、实际光能利用率 $\epsilon = \text{NPP} / \text{APAR}$ 与植被指数的相关系数

Table 2 Correlation coefficient between actual light energy utilization rate and vegetation index of vegetation in the subsidence zone

植被指数 Vegetation index	与 NPP 的相关系数 Correlation coefficient with NPP	与光能利用率的相关系数 Correlation coefficient with actual light energy utilization
归一化植被指数 Normalized Difference Vegetation Index	0.799	0.973
阴影植被指数 Shadow Vegetation Index	0.285	0.627
差值环境植被指数 Difference Environmental Vegetation Index	0.204	0.545
三角植被指数 Triangle Vegetation Index	0.312	0.626
土壤调节植被指数 Soil Adjusted Vegetation Index	0.349	0.667
叶绿素指数 Green Chlorophyll Vegetation Index	0.252	0.518
增强型植被指数 Enhanced Vegetation Index	0.331	0.567
修改型土壤调节植被指数 Modified Soil Adjusted Vegetation Index	0.334	0.654

3 结果与分析

将 NDVI 作为特征输入对 NPP 进行预测, 通过使用径向基神经网络与 BP 神经网络来对 NPP 进行反演, 并与原始 CASA 模型进行对比。BP 神经网络反演结果 R^2 为 0.585, RBF 神经网络反演结果决定系数 $R^2 = 0.646$, CASA 模型反演结果决定系数 $R^2 = 0.566$ 。三种模型对比效果相差不大, 而使用 RBF-CASA 模型反演结果决定系数达到 0.730, CASA 模型的模拟值与实测值的相关系数为 0.812, 优化后的模型模拟值与实测值的相关性达到 0.855。结果表明优化后的模型在消落带区域的 NPP 估算更具有优势。

环境影响因子模型使用 RBF 神经网络来进行构建, 将 NDVI 与高程两个数据作为特征输入网络进行训练, 获得植被的环境影响因子, 进而将环境影响因子与 CASA 模型结合计算出 NPP。再对多种模型结果进行对比, 对比效果如图 7 所示, 通过 CASA 模型和 RBF 模型计算 NPP 时, 模型估算的 NPP 值与真实值相差较大。加入 NDVI 计算的影响因子后, 缩小了与真实值之间的差异。再次加入高程计算的影响因子后, 与真实值之间的差异进一步缩小。结果表明模型计算出的环境影响因子能有效地校正 NPP 值。

3.1 模型对比

对多种模型结果进行对比分析, 模型预测值与真实值的 R^2 比较结果如图 8 所示。图中依次为 CASA 模型、




图 7 模型验证结果对比图

Fig.7 Comparison Chart of Model Verification Results

RBF: 径向基神经网络 Radial basis function network; RBF-CASA($H(x)$): 基于高程的径向基函数耦合卡内基-艾姆斯-斯坦福方法 Elevation based radial basis function coupling CASA; RBF-CASA($NDVI(x)$): 基于归一化植被指数的径向基函数耦合卡内基-艾姆斯-斯坦福方法 Normalized Difference Vegetation Index based radial basis function coupling CASA; RBF-CASA($H(x)$, $NDVI(x)$): 基于归一化植被指数和高程的径向基函数耦合卡内基-艾姆斯-斯坦福方法 Radial basis function coupling CASA based on normalized vegetation index and elevation

RBF 神经网络模型(对比 BP、RF、RBF 三种神经网络,RBF 神经网络最优)、NDVI 影响因子优化 CASA 模型(RBF-CASA(NDVI(x, t)))、高程影响因子优化 CASA 模型(RBF-CASA($H(x)$))、高程和 NDVI 影响因子优化 CASA 模型(RBF-CASA($H(x), \text{NDVI}(x, t)$))。表明消落带中高程对于 NPP 的影响的重要性。




图 8 净初级生产力模拟值与实测值的比较图

Fig.8 Plot of simulated versus measured values of net primary productivity

从图 8 中可见使用 CASA 模型在对消落带区域的植被进行模拟效果不佳, R^2 为 0.648。而 Xiaolu^[38] 使用 CASA 模型在混交林的模拟的 R^2 为 0.770, 老黑云杉为 0.620; Gang^[39] 使用基于 LSWI 的 CASA 生态系统模型对蒙古高原半干旱气候下陆地生态系统进行模拟得到 R^2 为 0.717; 施亚林等人^[18] 使用改进后的 CASA 模型对河流域草地进行模拟验证得到 R^2 为 0.697。表明 CASA 模型在对草地的 NPP 模拟时深受河流的影响, 而消落带作为最靠近河流区域的草地受到河流的影响最为突出。李传华等人^[40] 使用机器学习的方法对青藏高原冻土区草地 NPP 进行模拟, 使用随机森林模拟得到 R^2 为 0.747, 使用 RBF 神经网络得到 R^2 为 0.741, 表明机器学习方法在对草地的 NPP 模拟有可靠的结果。本文使用李传华等人^[40] 的 RBF 神经网络模型对消落带植被 NPP 进行模拟, 由于消落带实测数据较少, R^2 为 0.646。以及使用朱文泉教授改进的 CASA 模型^[20] 对消落带植被 NPP 进行模拟, R^2 为 0.566。然而, 使用机器学习的方法来计算该区域的环境影响因子, 再结合 CASA 模型得 R^2 为 0.730, 可见优化后的 CASA 模型对消落带模拟 NPP 效果更佳。

通过对比多种模型中 NDVI 与 NPP 的关系(图 9)发现, CASA 模型中 NDVI 与 NPP 之间的关系是线性




图9 影响因子分析图

Fig.9 Influence factor analysis plots

的。NPP 随着 NDVI 的增加,增长趋势也不断增大;RBF 模型中 NDVI 与 NPP 之间的关系也是线性变化,其中 NPP 随着 NDVI 的增加达到一定数值,增长趋势开始减弱;在 RBF-CASA 模型中,使用 NDVI 特征计算环境影响因子,显示增长趋势比 CASA 模型增长的更快;在添加高程影响因子后,模型中 NDVI 与 NPP 的关系由以前的线性转变为非线性,并且整体的增长趋势也较快;通过对高程影响因子与高程特征进行分析可得,高程对 NPP 的影响呈起伏状。在不同高程区域,影响因子变化不同,在 160m 左右影响因子系数最大。同时证实消落带区域高程因子是估算 NPP 的重要影响因素。

3.2 评价指标

如表 3 本文分别采用 RRMSE、MAE、RMSE、MAPE 及 R^2 等指标对模型的性能进行评价。对比发现 CASA 模型与使用神经网络训练结果相差不大。代入 NDVI 计算的影响因子模型,决定系数达到 0.650;代入高程计

算的影响因子模型,决定系数提升到 0.684;将 NDVI 与高程计算的影响因子同时代入模型,决定系数提升到 0.730;结果表明针对消落带区域,在 CASA 模型中使用 NDVI 与高程计算影响系数能够使得结果更加接近真实值。结合陈艳英等人^[33]的研究,发现由于坡度与高度的原因,使得获得的 NDVI 数据受到一定影响。同时由于代入高程数据,模型效果提升更加明显,可见高程因子能够较好的提高模型估算精度。

表 3 多种 NPP 估算模型评价指标对比

Table 3 Comparison of evaluation indicators for multiple NPP estimation models

模型 Model	相对均方根误差 Relative root mean square error	均方根误差 Root mean square error	平均绝对百分误差 Mean absolute percentage error	平均绝对误差 Mean absolute error	决定系数 Coefficient of determination
CASA	0.244	113.064	0.146	75.180	0.566
RBF	0.259	119.721	0.140	73.573	0.646
RBF-CASA($H(x)$)	0.208	96.439	0.143	68.649	0.684
RBF-CASA(NDVI(x))	0.220	101.590	0.138	70.109	0.650
RBF-CASA($H(x)$, NDVI(x))	0.193	89.203	0.135	64.189	0.730

3.3 空间分布格局

在香溪河消落带 4 号采样区域中,由于区域较小,通过温度与降雨计算的胁迫因子为同一数值。在研究过程中通过空间分布图(图 10)能够快速准确地发现不太区域的差异性与相似性。其中环境影响因子的范围为 0.332—1.339。该区域形成随着高程的不断增加环境影响因子也不断递增的空间格局,并且环境影响因子与实际光能利用率形成递增关系;高程影响因子的空间分布情况显示随着高程的变化,环境影响因子也会随之变化,其中植被在 165m—175m 高程之间对光能的利用率最强,其次在 140—155m 高程之间;实际光能利用率表示该区域的植被对光照的利用情况,计算出的实际光能利用率的范围在 0.170—0.686;香溪河典型消落带区域 7 月份 NPP 范围在 1.454—289.904g C/m²,平均 NPP 约为 103.352g C/m²,平均碳密度为 29.444—59.633g C/m²之间。可见植被 NPP 的空间分布随着高程变化而变化,其中位于 150—155m 的植被最为茂盛。根据张雪蕾等人^[41]研究显示,三峡库区在 7 月 NPP 达到峰值 160g C/m²。考虑到植被类型以及区域,本研究的反演结果在合理范围内,并且反映不同高程区域的植被的空间分布情况以及生态修复情况。




图 10 空间分布图

Fig.10 Spatial Distribution Map

3.4 高程对 NPP 的影响

如图 11 所示,柱状图为各高程区域 NPP 均值情况,折线图为各高程 NPP 总量情况,饼状图为高程区域面积在消落带区域所占百分比情况。分析图 11 可得,在 150—155m 高程中 NPP 总量最高,最靠近河岸的植被 NPP 均值与 NPP 总量都最低。其主要原因是越靠近河岸区域的水分越充足,当水分超过植被生长所需后,反而抑制植被的生长,其他文献也得到过相似结论。在 170m 以上区域植被 NPP 均值最高,最主要原因是 170m 以上区域存在少量灌木以及苍耳等植被。在消落带区域中 155—160m 高程的面积占比最大,其次是 150—155m,最少是 145m 以下区域。




图 11 高程影响分析图

Fig.11 Elevation Impact Analysis Diagram

3.5 净初级生产力的时间动态分布

2021—2022 年香溪河 8 个典型消落带区域裸露月份的月均 NPP 变化情况如图 12 所示,植被恢复情况较差。在空间分布上对 8 个样区进行比较,可见其中 6 号区域与 8 号区域固碳情况最为突出,3 号区域植被恢复情况较差。通过 8 个采样区的分布情况与对应的月均 NPP 发现,上游植被 NPP 最高,其次是下游,中游最低。从时间分布上对 8 个样区进行比较,在 2021 年 9 月植被 NPP 均值为 35.883 g C/m^2 ,2022 年 9 月植被 NPP 均值为 25.964 g C/m^2 ,发现 22 年植被生长情况明显弱于 21 年。通过分析降雨、温度、辐射发现,22 年 7 月、8 月温度持续升高,使得消落带植被枯死。22 年 9 月 16.002 mm 的降雨量远少于 21 年 9 月 97.536 mm 的降雨量,同时长江水位大幅度下降,使得植被无法及时补充水分。




图 12 样区月均 NPP 情况图

Fig.12 Monthly Average NPP in Sample Area

4 不足与展望

由于研究区域狭长和消落带区域气象站较少,对克里金插值法获得的研究区域的温度、降雨、辐射影响较大,只能通过多个典型采样区进行采样,规避部分影响;消落带植被都属于草地类型,未考虑消落带以上区域还存在人工种植的灌木以及树木对消落带的影响;采样 ENVI 5.3 中支持向量机方法对植被进行分类,分类精确度不够高;无人机图像采集 8 个典型区域的 7、9 月影像来探测植被的修复情况以及固碳潜力,但不能代替香溪河消落带整体区域的修复情况以及固碳潜力。后续应采集逐月的消落带区域影像,以便更准确的对消落带区域进行监测;由于香溪河消落带区域较长,获取无人机影像较为费时,未来可使用无人机图像结合高分卫

星影像对消落带区域进行监测,从而提高估算精度。

综上所述,对植被分类算法做出优化,以便能够精确的分割出消落带的各种植被。同时扩大研究区域,采集各种植被数据,提高模型的适用性。尝试使用深度学习方法来对环境影响因子模型进一步优化。

5 结论

本研究以香溪河消落带生态系统的无人机航拍数据为基础;借助与 ENVI 5.3 软件对波段影像进行波段运算得到 NDVI 数据;在 Python 语言支持下对 CASA 模型进行优化;再应用于该区域生态系统研究当中,计算出 8 个样区的固碳情况进而分析香溪河消落带的生态修复情况;并通过 ArcGIS 绘画出采样区的空间分布图,进而分析消落带区域高程对 NPP 的影响情况;估算研究区域净初级生产力数据,并探讨研究区域净初级生产力的月度变化、年度变化。

得到主要结论为:通过建立的 RBF-CASA 模型进行验证,估算值与观测数据的 R^2 为 0.730 ($P < 0.01$, $n = 32$),对比 CASA 模型 MAE 降低 10.991,RRMSE 降低 5.10%,MAPE 降低 1.12%;消落带区域中,高程对 NPP 的影响较大。NPP 随高程增加呈现起伏变化,不同高程区域的 NPP 总量或均值都存在较大差距。其中高程在 150—155m 之间的 NPP 总量最高,在 170m 以上区域 NPP 均值最高;在植被生长最茂盛的月份,8 个采样区 NPP 均值在 66.234—134.144g C/m² 之间,平均碳密度在 29.444—59.633g C/m² 之间。并且位于中游区域的 3 号点的 NPP 最低,在 2021—2022 年间由于降雨量减少、长江水位下降,植被总体恢复情况较差;本文构建的 RBF-CASA 模型为固碳模型提供新优化方向,并且为消落带生态系统的功能以及生态评估提供数据和技术支持。消落带的固碳经济为消落带防护经济效益计算提供新的参考。

参考文献 (References):

- [1] 董智,李留彬,向国伟,耿倩雯,殷凡,郑杰,李昌晓. 三峡库区忠县消落带植物群落特征及其与环境因子的关系. 西南大学学报: 自然科学版, 2022, 44(7): 2-13.
- [2] 王丽霞,丁慧兰,刘招,张双成,孔金玲. 基于 CASA 模型探究泾河流域植被 NPP 时空动态及其对气候变化的响应. 水土保持研究, 2022, 29(1): 190-196.
- [3] 涂海洋,古丽·加帕尔,于涛,李旭,陈柏建. 中国陆地生态系统净初级生产力时空变化特征及影响因素. 生态学报, 2023, 43(3): 1219-1233.
- [4] Zhao J F, Liu D S, Cao Y, Zhang L J, Peng H W, Wang K L, Xie H F, Wang C Z. An integrated remote sensing and model approach for assessing forest carbon fluxes in China. *Science of the Total Environment*, 2022, 811: 152480.
- [5] Christopher S P, James T R, Christopher B F, Pamela A M, Peter M V, Harold A M, Steven A K. Terrestrial ecosystem production: A process model based on global satellite and surface data. *Global Biogeochemical Cycles*. 1993, 7(4): 811-841.
- [6] Wang Y L, Xu X G, Huang L S, Yang G J, Fan L L, Wei P F, Chen G. An improved CASA model for estimating winter wheat yield from remote sensing images. *Remote Sensing*, 2019, 11(9): 1088.
- [7] 刘剑锋,陈琳,孟琪,王璇,王远征,王来刚,张喜旺. 基于 CASA-VPM 模型的植被最大光能利用率研究. 河南农业科学, 2019, 48(12): 157-163.
- [8] Bai X Y, Li Z H, Li W, Zhao Y, Li M X, Chen H Y, Wei S C, Jiang Y M, Yang G J, Zhu X C. Comparison of machine-learning and CASA models for predicting apple fruit yields from time-series planet imageries. *Remote Sensing*, 2021, 13(16): 3073.
- [9] Cho S, Kang M, Ichii K, Kim J, Lim J H, Chun J H, Park C W, Kim H S, Choi S W, Lee S H, Indrawati Y M, Kim J. Evaluation of forest carbon uptake in South Korea using the national flux tower network, remote sensing, and data-driven technology. *Agricultural and Forest Meteorology*, 2021, 311: 108653.
- [10] 田义超,黄远林,陶进,张强,吴彬,张亚丽,梁铭忠,周国清. 基于无人机影像的北部湾典型岛群红树林生态系统净初级生产力估算. 热带地理, 2019, 39(4): 583-596.
- [11] 高燕,梁泽毓,王彪,吴艳兰,刘诗雨. 基于无人机和卫星遥感影像的升金湖草滩植被地上生物量反演. 湖泊科学, 2019, 31(2): 517-528.
- [12] 林怡,张文豪,宇洁,张翰超. 基于无人机影像的城市植被精细分类. 中国环境科学, 2022, 42(6): 2852-2861.
- [13] 张正健,李爱农,边金虎,赵伟,南希,靳华安,谭剑波,雷光斌,夏浩铭,杨勇帅,孙明江. 基于无人机影像可见光植被指数的若尔盖草地上生物量估算研究. 遥感技术与应用, 2016, 31(1): 51-62.
- [14] Freitas R G, Pereira F R S, Dos Reis A A, Magalhães P S G, Figueiredo G K D A, do Amaral L R. Estimating pasture aboveground biomass under an integrated crop-livestock system based on spectral and texture measures derived from UAV images. *Computers and Electronics in Agriculture*,

- 2022, 198: 107122.
- [15] 陈功, 李晓玲, 黄杰, 向玲, 孙雷, 杨进, 胥焘, 黄应平. 三峡水库秭归段消落带植物群落特征及其与环境因子的关系. 生态学报, 2022, 42(2): 688-699.
- [16] Yang Z J, Wei C Y, Liu D F, Lin Q C, Huang Y L, Wang C F, Ji D B, Ma J, Yang H. The influence of hydraulic characteristics on algal bloom in Three Gorges Reservoir, China: a combination of cultural experiments and field monitoring. Water Research, 2022, 211: 118030.
- [17] Zhang M, Yuan N Q, Lin H, Liu Y, Zhang H Q. Quantitative estimation of the factors impacting spatiotemporal variation in NPP in the Dongting Lake wetlands using Landsat time series data for the last two decades. Ecological Indicators, 2022, 135: 108544.
- [18] 施亚林, 曹艳萍, 苗书玲. 黄河流域草地净初级生产力时空动态及其驱动机制. 生态学报, 2023, 43(2): 731-743.
- [19] 原一荃, 薛力铭, 李秀珍. 基于 CASA 模型的长江口崇明东滩湿地植被净初级生产力与固碳潜力. 生态学杂志, 2022, 41(2): 334-342.
- [20] 杜金荣, 于德永. 气候变化和人类活动对中国北方农牧交错区草地净初级生产力的影响. 北京师范大学学报: 自然科学版, 2018, 54(3): 365-372.
- [21] 朱文泉, 潘耀忠, 张锦水. 中国陆地植被净初级生产力遥感估算. 植物生态学报, 2007, 31(3): 413-424.
- [22] Chen Y, Chen X W, Zheng P, Tan K M, Liu S Q, Chen S X, Yang Z X, Wang X L. Value compensation of net carbon sequestration alleviates the trend of abandoned farmland: a quantification of paddy field system in China based on perspectives of grain security and carbon neutrality. Ecological Indicators, 2022, 138: 108815.
- [23] 王莉雯, 卫亚星. 植被光能利用率高光谱遥感反演研究进展. 测绘与空间地理信息, 2015, 38(6): 15-22, 38, 41.
- [24] Li C Q, Han W T, Peng M M. Improving the spatial and temporal estimating of daytime variation in maize net primary production using unmanned aerial vehicle-based remote sensing. International Journal of Applied Earth Observation and Geoinformation. 2021, 103: 102467.
- [25] 惠嘉伟, 白中科, 刘凯杰, 王子昊. 归一化植被指数 (NDVI) 在草原露天煤矿区的适用性分析. 工程科学学报, 2023, 45(1): 54-63.
- [26] 许章华, 林璐, 王前鋒, 黄旭影, 刘健, 余坤勇, 陈崇成. 归一化阴影植被指数 NSVI 的构建及其应用效果 (英文). 红外与毫米波学报, 2018, 37(2): 154-162.
- [27] 李艳大, 舒时富, 陈立才, 叶春, 黄俊宝, 孙滨峰, 王康军, 曹中盛. 基于便携式作物生长监测诊断仪的江西双季稻氮肥调控研究. 农业工程学报, 2019, 35(2): 100-106.
- [28] Qian B X, Ye H C, Huang W J, Xie Q Y, Pan Y H, Xing N C, Ren Y, Guo A T, Jiao Q J, Lan Y B. A sentinel-2-based triangular vegetation index for chlorophyll content estimation. Agricultural and Forest Meteorology, 2022, 322: 109000.
- [29] 谢京凯, 王福民, 王飞龙, 张东尼. 面向水稻 LAI 监测的植被指数土壤调节参数修正. 遥感技术与应用, 2018, 33(2): 342-350.
- [30] Zhang L L, Zhang Z, Luo Y C, Cao J, Xie R Z, Li S K. Integrating satellite-derived climatic and vegetation indices to predict smallholder maize yield using deep learning. Agricultural and Forest Meteorology, 2021, 311: 108666.
- [31] 文可, 姚焕玫, 龚祝清, 纳泽林, 韦毅明, 黄以, 陈华权, 廖鹏任, 唐丽萍. 水淹频率变化对鄱阳湖增强型植被指数的影响. 植物生态学报, 2022, 46(2): 148-161.
- [32] 徐红涛, 陈春波, 郑宏伟, 罗格平, 杨辽, 王伟胜, 吴世新. 集成建模变量优选和参数学习的 SVR 盐渍化监测. 遥感技术与应用, 2021, 36(1): 176-186.
- [33] 陈艳英, 游扬声, 唐云辉, 张建平. 重庆市植被指数与高度/坡度的关系研究. 西南师范大学学报: 自然科学版, 2016, 41(11): 122-129.
- [34] 邵嘉豪, 李晶, 闫星光, 马天跃, 张瑞. 基于地理探测器的山西省 2000—2020 年 NPP 时空变化特征及驱动力分析. 环境科学, 2023, 44(1): 312-322.
- [35] 陈玉兰, 焦菊英, 田红卫, 徐倩, 冯兰茜, 王楠, 白雷超, 杨雪. 黄土高原归一化植被指数与自然环境因子的空间关联性——基于地理探测器. 生态学报, 2022, 42(9): 3569-3580.
- [36] Prakash Sarkar D, Uma Shankar B, Ranjan Parida B. Machine learning approach to predict terrestrial gross primary productivity using topographical and remote sensing data. Ecological Informatics, 2022, 70: 101697.
- [37] 赵文杰, 李洪平, 刘海行. SMAP 卫星的 RBF 神经网络海表盐度遥感反演. 海洋科学进展, 2022, 40(3): 513-522.
- [38] Zhou X L, Peng C H, Dang Q L, Sun J F, Wu H B, Hua D. Simulating carbon exchange in Canadian Boreal forests. Ecological Modelling, 2008, 219(3/4): 287-299.
- [39] Bao G, Bao Y H, Qin Z H, Xin X P, Bao Y L, Bayarsaikhan S, Zhou Y, Chuntai B. 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, 2016, 46: 84-93.
- [40] 李传华, 孙皓, 王玉涛, 曹红娟, 殷欢欢, 周敏, 朱同斌. 基于机器学习估算青藏高原多年冻土区草地净初级生产力. 生态学杂志, 2020, 39(5): 1734-1744.
- [41] 张雪蕾, 肖伟华, 王义成. 基于改进的 CASA 模型三峡库区 NPP 时空特征及气候驱动机制. 生态学报, 2021, 41(9): 3488-3498.