doi:10.6041/j.issn.1000-1298.2026.03.027

基于红光波段 SIF 的高寒草甸 GPP 遥感监测方法

竞　霞[1]　张二妮[1]　段维纳[1]　陈思媛[2]　张震华[1]

(1. 西安科技大学测绘科学与技术学院，西安 710054；2. 中国电建集团西北勘测设计研究院有限公司，西安 710100)

摘要：高寒草甸生态系统具有强大的碳汇能力，准确估计其总初级生产力(Gross primary productivity，GPP)对掌握全球碳循环具有重要意义。日光诱导叶绿素荧光(Solar-induced chlorophyll fluorescence，SIF)是指示植被光合作用过程的无损探针，红光波段 SIF(Red SIF，RSIF)包含了更多的 PS Ⅱ信息。为了探究 RSIF 对高寒草甸生态系统 GPP 的响应特性，本文综合 RSIF、环境变量以及冠层结构参数，分别基于随机森林回归(Random forest regression，RFR)、多元线性回归(Multiple linear regression，MLR)和简单线性回归(Simple linear regression，SLR)方法构建了高寒草甸 GPP 预测模型，并将其与远红光波段 SIF(Far-red SIF，FRSIF)的预测结果进行对比分析。结果表明：冠层 RSIF 和 FRSIF 均与 GPP 呈显著正相关关系，RSIF 与 GPP 的相关系数较 FRSIF 提高 23.53%，在高寒草甸 GPP 预测中较 FRSIF 具有更大的优势。在训练数据集中，综合 RSIF、环境变量以及冠层结构参数构建的 RFR 和 MLR 模型预测 GPP 与实测 GPP 间的平均 R^2 较 FRSIF 分别提高 5.79% 和 12.69%，平均 RMSE 分别降低 16.37% 和 30.56%，以单一 RSIF 为自变量构建的 SLR 模型预测 GPP 与实测 GPP 间的平均 R^2 较 FRSIF 提高 31.02%，平均 RMSE 降低 34.28%。在验证数据集中以 RSIF、环境变量以及冠层结构参数为自变量构建的 RFR 模型预测 GPP 和实测 GPP 之间的平均 R^2 较 MLR 提高 1.86%、较单一以 RSIF 为自变量的 SLR 模型提高 6.62%，其对应平均 RMSE 分别降低 1.04% 和 17.13%。RSIF 比 FRSIF 在高寒草甸生态系统 GPP 监测方面具有更大的潜力，研究结果亦对其它生态系统 GPP 遥感监测具有重要参考价值。

关键词：高寒草甸；总初级生产力；红光波段 SIF；塔基 SIF；模型精度

中图分类号：X87　　**文献标识码**：A　　**文章编号**：1000-1298(2026)03-0284-10　　**OSID**：

Remote Sensing Monitoring of GPP in Alpine Meadows Based on Red SIF

JING Xia[1]　ZHANG Erni[1]　DUAN Weina[1]　CHEN Siyuan[2]　ZHANG Zhenhua[1]

(1. *College of Geomatics Science and Technology*, *Xi'an University of Science and Technology*, *Xi'an* 710054, *China*
2. *PowerChina Northwest Engineering Corporation Limited*, *Xi'an* 710100, *China*)

Abstract: The alpine meadow ecosystem has a strong carbon sink capacity, and accurately estimating the gross primary productivity (GPP) is essential to grasp the global carbon cycle. Solar-induced chlorophyll fluorescence (SIF) is a non-destructive probe indicating the photosynthetic process of plants, and red SIF (RSIF) contains more information about PS Ⅱ. To explore the response characteristics of RSIF to the GPP of the alpine meadow ecosystem, integrating RSIF, environmental variables and canopy structure parameters, and respectively constructed GPP prediction models based on random forest regression (RFR), multiple linear regression (MLR), and simple linear regression (SLR) methods. The results showed that both canopy RSIF and FRSIF were significantly positively correlated with GPP, and the correlation between RSIF and GPP was 23.53% higher than that of FRSIF, which had greater advantages than FRSIF in the prediction of alpine meadow GPP. In the training data set, the RFR and MLR models constructed by combining RSIF, environmental variables and canopy structure parameters increased the average R^2 between predicted GPP and measured GPP by 5.79% and 12.69%, respectively, compared with FRSIF, and the average RMSE was decreased by 16.37% and 30.56%, respectively. Compared with FRSIF, the average R^2 between the predicted GPP and the measured GPP was increased by 31.02% and the average RMSE was decreased by 34.28% in SLR model with a single RSIF as the independent

收稿日期：2024-10-30　修回日期：2025-01-20

基金项目：国家自然科学基金项目(42171394)、遥感科学国家重点实验室开放基金项目(OFSLRSS202327)和陕西省自然科学基础研究计划项目(2025JC-YBQN-344)

作者简介：竞霞(1978—)，女，教授，博士，主要从事农业定量遥感研究，E-mail：jingxia1001@163.com

variable. In the validation data set, the average R^2 between predicted GPP and measured GPP predicted by the RFR model with RSIF, environment variables and canopy structure parameters as independent variables was increased by 1.86% compared with MLR, and by 6.62% compared with the single SLR model with RSIF as independent variable, and the corresponding average RMSE was decreased by 1.04% and 17.13%, respectively. RSIF had greater potential than FRSIF for GPP monitoring in alpine meadow ecosystem, and the results also had important reference value for GPP monitoring in other ecosystems.

Key words: alpine meadow; gross primary productivity; red SIF; tower-based SIF; model accuracy

0　引言

总初级生产力(Gross primary production, GPP)是生态系统中绿色植被通过光合作用固定的二氧化碳总和[1],是生态系统碳收支的关键指标,准确估计生态系统中的 GPP 对理解生态系统气候状况及环境变化和碳循环至关重要[2-3]。与光能利用率模型和生态过程模型相比,基于通量观测的数据驱动模型可以在站点尺度上利用通量数据协同气象变量和反射率光谱指数等遥感变量建立 GPP 估算模型。然而,反射率光谱指数主要反映冠层结构等信息,难以直接表征植被光合作用[4],仅使用反射率光谱数据难以及时、准确地反映植被光合作用的昼夜动态和季节变化[5]。与反射率光谱相比,日光诱导叶绿素荧光(Solar-induced chlorophyll fluorescence, SIF)与光合作用的关系更为直接,能够反映植被光合作用状态,被认为是探究 GPP 的理想指标[6-7]。

SIF 光谱包括红光波段(Red SIF, RSIF)和远红光波段(Far-red SIF, FRSIF)2 个发射峰值,由于 RSIF 受叶片内叶绿素吸收的影响较大[8],且其夫琅禾费吸收线的宽度与深度均小于 FRSIF[9],反演精度不如 FRSIF 稳健[10],因此目前利用 SIF 监测 GPP 主要集中于 FRSIF。已有研究表明在大豆[11]、水稻[12]、玉米[13]、常绿针叶林[14]和落叶阔叶林[15]等植被类型中,FRSIF 和 GPP 均具有良好的相关关系。RSIF 较 FRSIF 包含了更多的光系统Ⅱ(PS Ⅱ)信息[16],且 PS II 对光合作用的调节机制更为敏感[6],RSIF 能够更好地表征植被光合作用的有关信息。因此近年来也有一些专家开展了利用 RSIF 监测 GPP 的相关研究。JOINER 等[17]从 GOME-2 卫星反演出 RSIF,发现在干旱敏感地区 RSIF 的响应比 FRSIF 更明显。BUAREAL 等[18]发现 0.5 h 和日均尺度上 RSIF 和 FRSIF 均与 GPP 具有良好的相关性,但 RSIF 与 GPP 的相关性优于 FRSIF,RSIF 可以作为生态系统光合作用的等效或更好代表。LIU 等[9]将冠层水平 RSIF 降尺度到光系统水平后发现,光系统水平 RSIF 与 GPP 的相关性优于 FRSIF。已有的研究主要是针对森林[14]、农作物[11-12]等展开,然而在高海拔地区生态系统的通量信息已经发生了显著变化。高寒草甸生态系统是在寒冷气候条件下,由生长于高原和高山等高海拔地区的多年生耐寒草本植物构成的一种典型高寒生态系统。高寒草甸是以寒冷环境中生存的多年生草本植物为优势种而形成的植物群落,其所在的生态系统是陆地生态系统碳循环的重要组成部分[19]。目前对于高寒草甸这一特殊生态系统的 GPP 遥感监测的研究较少,尤其是 SIF 与 GPP 之间的关系尚不清晰。塔基平台的自动观测系统能够提供与通量数据在时间和空间尺度上相匹配的光谱信号,可以实现对植被进行长期的、自动的观测,在一定程度上解决时间和空间尺度的不匹配导致卫星遥感数据与地面通量站观测数据无法直接联系起来的问题[20]。

目前利用 SIF 预测 GPP 时较少同时考虑气候变量等多种因素。然而在不同生态系统中,SIF 与 GPP 间的关系不仅会受到冠层结构、植被功能型的影响[21],还会受到入射辐射[22]、气候变量[23]等多种因素影响,这在一定程度上限制了模型预测精度。基于此,本文以青海省高寒草甸生态系统为研究对象,综合利用 SIF 数据、塔基通量站点的光谱数据、通量观测数据以及气象数据,分别利用随机森林回归(Random forest regression, RFR)、多元线性回归(Multiple linear regression, MLR)以及简单线性回归(Simple linear regression, SLR)SIF 算法建立 GPP 预测模型,分析不同算法下 RSIF 和 FRSIF 在预测 GPP 方面的性能,并探究冠层结构和环境因素对 SIF-GPP 关系的影响,以期确定 SIF 预测 GPP 的适宜模型。

1　数据与方法

1.1　研究区域

实验区阿柔(Arou, AR)站点位于青海省祁连县阿柔乡(100.464 3°E, 38.047 3°N,海拔 3 033 m),地处青藏高原东北部祁连山中部腹地,属于典型的高原大陆性气候。年平均气温 1.49℃,年平均总降水量 422.56 mm。该地区为典型的高寒草甸,天然植被种类以羊草为主,生长旺季羊草高度约

30 cm[24]。本实验于 2019—2021 年,在中国通量塔站点地面连续 SIF 观测网络——中国通量塔站点网络中的阿柔(AR)站点进行了基于塔基观测的长期连续原位光谱测量[25]。

1.2 冠层光谱测量

在 AR 站高 17 m 的通量塔平台上设计并安装了一个 SIF 自动光谱观测系统——SIFSpec,以进行连续且长期的 SIF 光谱测量。SIFSpec 自动光谱观测系统采用“三明治”顺序采集光谱数据。1 组数据包含 3 次光谱采集,通过控制 2 个电子开关的交替开闭依次采集下行太阳入射光谱和上行地物冠层反射光谱。在每次光谱采集前,光谱仪会根据接收到的光谱信号优化确定积分时间,并且在 2 个电子开关均开启时记录 SIF 观测系统的暗电流[9]。

1.3 通量以及气象观测

涡动相关(Eddy covariance,EC)系统用来测量高寒草甸冠层上方与大气之间的能量、H_2O 和 CO_2 的交换。EC 系统安装在距离地面 3.5 m 的高度,包括 1 台测量风速和温度的三维超声波风速仪(CSAT3 型, Campbell Scientific Inc.,美国)以及 1 台用于监测气体的开放路径气体分析仪(Li-7500 型, Li-Cor, 美国)。对原始 EC 数据进行处理后可得到 CO_2 净生态系统交换(Net ecosystem exchange, NEE)与生态系统呼吸(Ecosystem respiration,ER)等通量数据。结合通量及气象观测数据即可计算得到 GPP[26],计算式为

$$G_{PP} = E_R - N_{EE} \tag{1}$$

式中 G_{PP}——总初级生产力

E_R——生态系统呼吸

N_{EE}——CO_2 净生态系统交换

通量塔平台上的自动气象站(Automatic weather stations,AWS)可以观测气温(Ta)、气压(p)、饱和水气压差(VPD)、相对湿度(Rh)、降水、风速/风向、光合有效辐射(PAR)等气象数据,每 10 min 记录一次测量结果。0.5 h 平均气象资料采用 0.5 h 内多个 10 min 资料进行平均,日均气象资料采用日半小时平均资料进行平均。

1.4 冠层 SIF 反演

本次实验利用光谱拟合方法(Spectral fitting model,SFM)反演冠层 SIF,该方法的反射率 ρ 和 SIF 均由光谱曲线拟合确定[27-28]。不同于 FLD 方法中 SIF 和反射率 ρ 在 O_2A 和 O_2B 吸收线处保持恒定的假设,SFM 方法选取夫琅禾费吸收线附近的波段窗口($[\lambda_1,\lambda_2]$),且假设在该波段窗口内反射率 ρ 和 SIF 的光谱变化均能够通过一个多项式或其它适当的数学函数进行描述。因此,植物反射太阳辐射(L)可以表示为

$$L(\lambda) = \frac{\rho_{MOD}(\lambda)E(\lambda)}{\pi} + F_{MOD}(\lambda) + \varepsilon_0(\lambda) = L_{MOD}(\lambda) + \varepsilon_0(\lambda) \quad (\lambda \in [\lambda_1,\lambda_2]) \tag{2}$$

式中 $\rho_{MOD}(\lambda)$、$F_{MOD}(\lambda)$——用来描述反射率和荧光随波长变化的数学函数

L_{MOD}——数学函数模拟的表观辐亮度

$\varepsilon_0(\lambda)$——观测到的辐亮度与模拟辐亮度之间的差,表示每个波长处的拟合误差

$E(\lambda)$——入射到目标上的太阳辐照度

1.5 冠层 SIF 降尺度

植被发射的总荧光,即光系统水平的荧光(SIF_{PS}),能够直接反映植被生理变化。然而,传感器探测到的 SIF 是基于塔基平台观测的冠层方向性 SIF。从叶片内部发射出的 SIF 只有一小部分能够逃离冠层进入传感器。基于此,本研究将塔基光谱平台冠层方向性 SIF 降尺度到光系统水平,减弱冠层几何结构对传感器探测到的 SIF 的影响,进而探究生理层面 SIF-GPP 的关系。

植被光合有效辐射吸收比(Fraction of absorbed photosynthetically active radiation, FAPAR)与冠层结构、叶片吸收和太阳辐射等有关,是表征植被光合作用能力和生长状态的重要参量[9]。已有研究表明,在固定视角的观测条件下,NDVI 和 FAPAR 之间的关系几乎是不变的,NDVI 可以用来对 FAPAR 进行良好估计[30]。因此,利用 NDVI 进行 FAPAR 估计,描述植被指数与 FAPAR 之间的关系为

$$F_{APAR} = \frac{(N_{DVI} - N_{DVImin})(F_{APARmax} - F_{APARmin})}{N_{DVImax} - N_{DVImin}} + F_{APARmin} \tag{3}$$

式中 F_{APAR}——植被光合有效辐射吸收比

N_{DVI}——归一化植被指数

N_{DVImax}、N_{DVImin}——N_{DVI}最大值、最小值

$F_{APARmax}$、$F_{APARmin}$——F_{APAR}最大值、最小值

N_{DVImax}、N_{DVImin}、$F_{APARmin}$和 $F_{APARmax}$由 AR 站点土壤反射率原位测量数据得到。N_{DVI}由红光波段中心波长(685 nm)和近红外波段中心波长(770 nm)冠层反射率计算得到。

冠层水平 SIF 和光系统水平 SIF 之间的关系为

$$SIF_{PS} = \frac{SIF}{\varepsilon} \tag{4}$$

式中 SIF_{PS}——光系统水平 SIF

SIF——冠层水平 SIF

ε——光系统水平到冠层水平逃逸概率

由于叶片和冠层的散射和重吸收作用，ε 在 RSIF 和 FRSIF 表现出不同特性。根据 ZENG 等[30]和 LIU 等[9]的研究结果，RSIF 和 FRSIF 的逃逸概率分别表示为

$$\varepsilon(Red) \approx \frac{R_{\mathrm{Red}} N_{\mathrm{DVI}}^2}{F_{\mathrm{APAR}}} \tag{5}$$

$$\varepsilon(NIR) = \frac{R_{\mathrm{NIR}} N_{\mathrm{DVI}}}{F_{\mathrm{APAR}}} \tag{6}$$

式中　R_{Red}——红光波段冠层反射率

R_{NIR}——近红外波段冠层反射率

1.6　光谱指数的计算

光谱指数被广泛用来评价植被覆盖度及其生长活力。其中，NDVI 对冠层结构参数敏感，与叶面积指数（Leaf area index，LAI）间具有极显著线性相关关系[31]。叶绿素含量是反映叶片光合作用能力的有效指标，MERIS 陆地叶绿素指数（MERIS terrestrial chlorophyll index，MTCI）能够敏感反映叶绿素含量的变化[32]。基于此，本文利用塔基冠层观测的红光波段中心波长、红边波段中心波长（710 nm）以及近红外波段中心波长的冠层反射率数据分别计算得到 NDVI 和 MTCI，以此作为估测 GPP 的光谱变量。

$$N_{\mathrm{DVI}} = \frac{R_{770} - R_{685}}{R_{770} + R_{685}} \tag{7}$$

$$M_{\mathrm{TCI}} = \frac{R_{770} - R_{710}}{R_{710} - R_{685}} \tag{8}$$

式中　R_{770}、R_{710}、R_{685}——波长 770、710、685 nm 处的冠层光谱反射率

M_{TCI}——MERIS 陆地叶绿素指数

1.7　随机森林回归算法

随机森林回归（Random forest regression，RFR）算法是一种通过构建多个决策树进行回归分析的机器学习算法[33]。该算法是利用 bootstrap 重采样构建不同的样本子集，每个训练子集构建一种决策树，依据最佳节点和最优特征进行决策树分裂，构建独立的决策树模型，最后通过多数投票或者加权平均原则得到随机森林最终的预测结果[23]。RFR 由于样本选择和分裂节点的随机性，使其能够在处理变量间的非线性关系时表现出更高的预测精度，同时可以降低过拟合风险，提高模型的泛化能力[34]。

2　结果与分析

2.1　RSIF 与 GPP 的相关性

为了更好地评价 RSIF 监测 GPP 的性能，分别分析了冠层水平（图 1）和光系统水平（图 2）下 RSIF 与 GPP 的相关性，并将其与 FRSIF 进行对比分析。由图 1 可以看出，RSIF 及 FRSIF 与 GPP 之间均达到

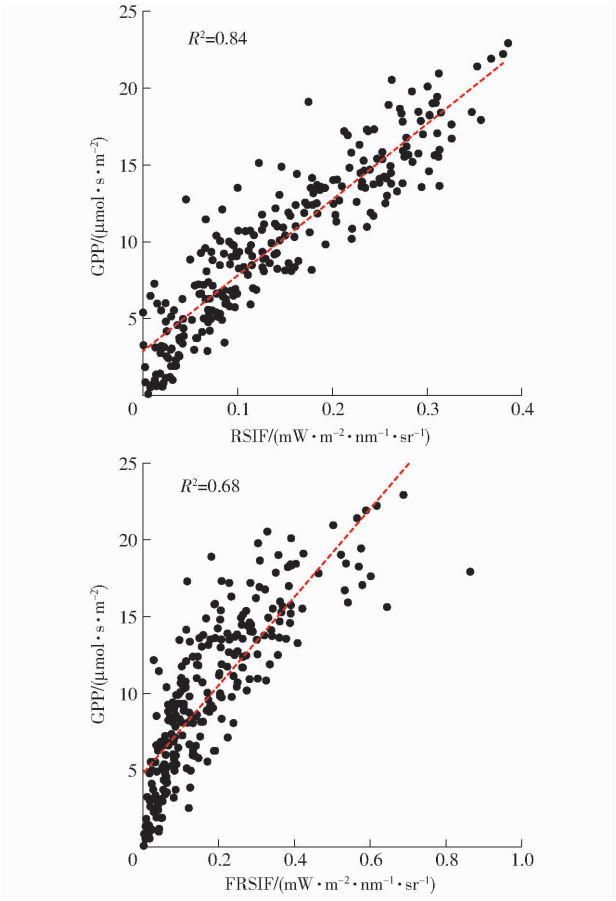

图 1　冠层尺度 RSIF 和 FRSIF 与 GPP 的相关性

Fig. 1　Correlations of RSIF and FRSIF with GPP

了极显著正相关关系，且在冠层水平和光系统水平 2 种尺度下，RSIF 与 GPP 之间的相关性较 FRSIF 均有不同程度的提高。其中，冠层水平下 RSIF 与 GPP 之间的 R^2 较 FRSIF 提高 23.53%，光系统水平下提高 89.47%。这是因为 RSIF 主要来自 PSⅡ的贡献，FRSIF 则同时受到了来自 PSⅠ和 PSⅡ的双重贡献[16]。PSⅡ的荧光随光化学反应的变化而变化，对光合作用更敏感[6]。在光合作用光反应中，PSⅡ首先捕获光能和启动电子传递，并将产生的电子通过一系列电子载体传递给 PSⅠ。PSⅡ的活性直接影响着光化学反应，且 PSⅡ的电子传递速率与光合作用的关系更为直接且关键[5]。RSIF 包含了更多关于 PSⅡ的信息，因此 RSIF 的生理贡献大于结构贡献是冠层 RSIF 和 GPP 表现出强相关性的重要原因。RSIF 追踪 GPP 的有效性在甜菜田[35]、玉米[28]和高寒草甸[3]等已得到证实，RSIF 在监测 GPP 方面具有显著优势。

为了更深入地探究高寒草甸生态系统植被生理因素和冠层结构因素对 SIF－GPP 关系的影响，本文对冠层水平 SIF 降尺度至光系统水平。综合分析图 1 和图 2 可知，针对高寒草甸生态系统，RSIF 和 FRSIF 降尺度至光系统水平后，二者与 GPP 的相关

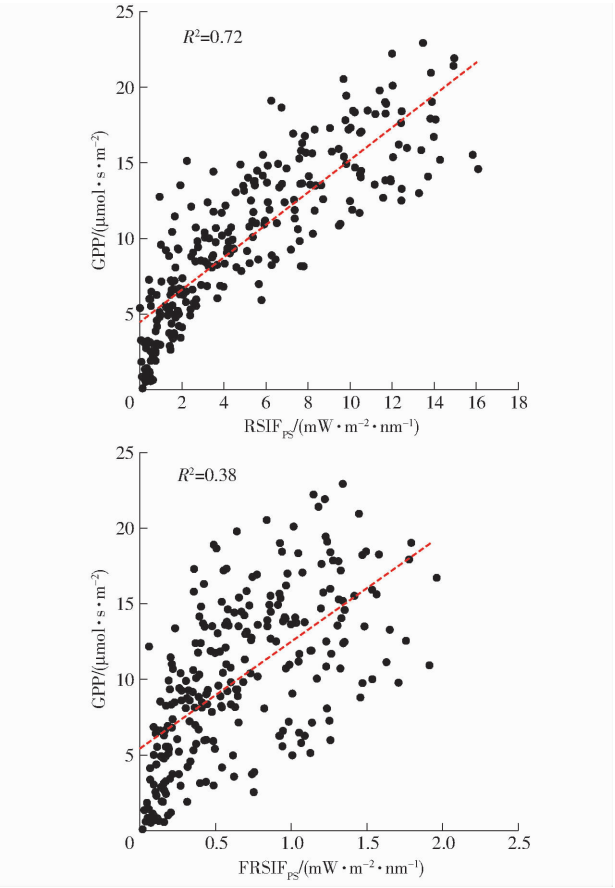

图 2 RSIF$_{PS}$和 FRSIF$_{PS}$与 GPP 的相关性

Fig. 2 Correlations of RSIF$_{PS}$ and FRSIF$_{PS}$ with GPP

性均出现了不同程度的降低。其中,光系统水平 RSIF(RSIF$_{PS}$)与 GPP 之间的 R^2 较冠层水平降低 14.29%,FRSIF(FRSIF$_{PS}$)则降低 44.12%。这与 LIU 等[9]和竞霞等[10]的研究结果不一致。这是因为对于森林等冠层结构较为复杂植被类型,在冠层水平上,SIF 受重吸收和散射效应的影响较大。其中,RSIF 受叶片内叶绿素吸收的强烈影响,FRSIF 主要受冠层结构散射效应的影响[35]。将冠层 SIF 降尺度到光系统水平后,能够在一定程度上减弱冠层结构等因素对传感器感测到的冠层方向性 SIF 的影响,提高 GPP 的预测精度。高寒草甸生态系统中植被冠层结构较为单一,草层低矮且层次分化不明显。传感器探测到的冠层 SIF 变化受冠层结构的影响较小,主要受植被生理变化的控制。因此在该生态系统中,冠层结构对 RSIF 的重吸收影响不具显著依赖性[27],使得与植被生理密切相关的 RSIF 在追踪 GPP 的优势更加突出。此外,将传感器探测到的冠层 SIF 降尺度到光系统水平后,逃逸率的计算在一定程度上引入了额外的估测误差。因此,对于高寒草甸生态系统这一较特殊的生态系统,光系统水平下 SIF 与 GPP 的相关性较冠层水平反而有所下降。

2.2 模型构建与精度评价

本文将 261 个原始数据随机分为训练集和验证集,其中 200 个样本数据作为训练样本进行模型构建,剩余的 61 个样本数据作为验证样本进行模型精度评价。为了使模型精度的评价结果更客观,实验过程中将样本数据进行 3 次随机分组(记为 A 组、B 组、C 组),并采用保留样本交叉检验的方式对模型精度进行评价。

2.2.1 模型构建

本文基于 SLR、MLR 以及 RFR 方法,分别以单一 SIF 变量以及综合 SIF、环境变量(Ta、VPD、PAR)、反射率光谱指数(NDVI、MTCI)等多源数据建立了 3 种 GPP 预测模型。由于决策树数量与最小叶子节点的确定是保障 RFR 模型精度的关键,在兼顾模型精度和计算效率的前提下,利用袋外误差(Out-of-bag error,OOB error)方法确定了最优决策树数目为 200,最优叶子节点数目为 6。为了更好地分析高寒草甸生态系统中利用 RSIF 预测 GPP 的精度,将上述模型的 GPP 预测精度与 FRSIF 进行对比(图 3~8)。

综合分析图 3 和图 4 可知,在 A、B、C 3 组训练样本中,仅以 RSIF 为自变量构建的 SLR 模型预测 GPP 与实测 GPP 间的 R^2 较同组 FRSIF 分别提高

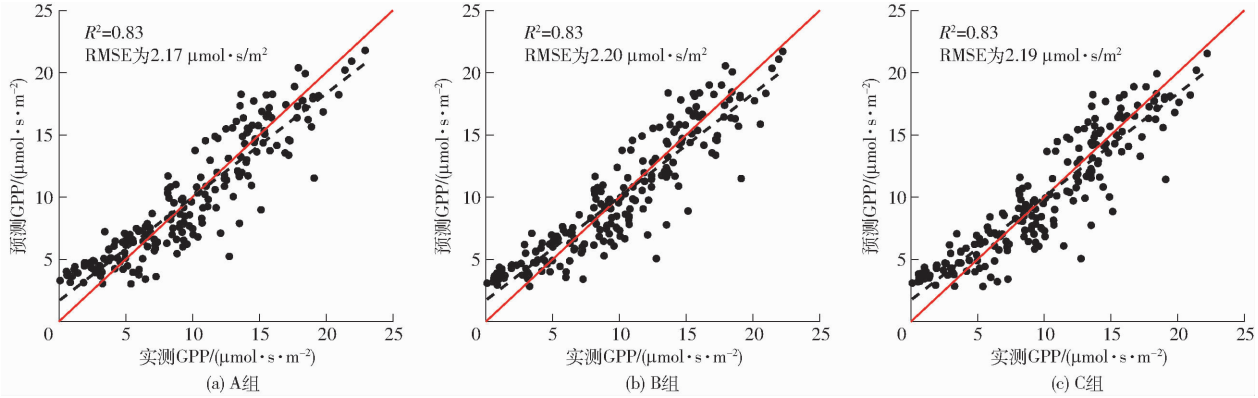

图 3 RSIF 基于单一变量线性回归方法的 GPP 估算模型

Fig. 3 Estimation models of GPP with RSIF as independent variable based on SLR model

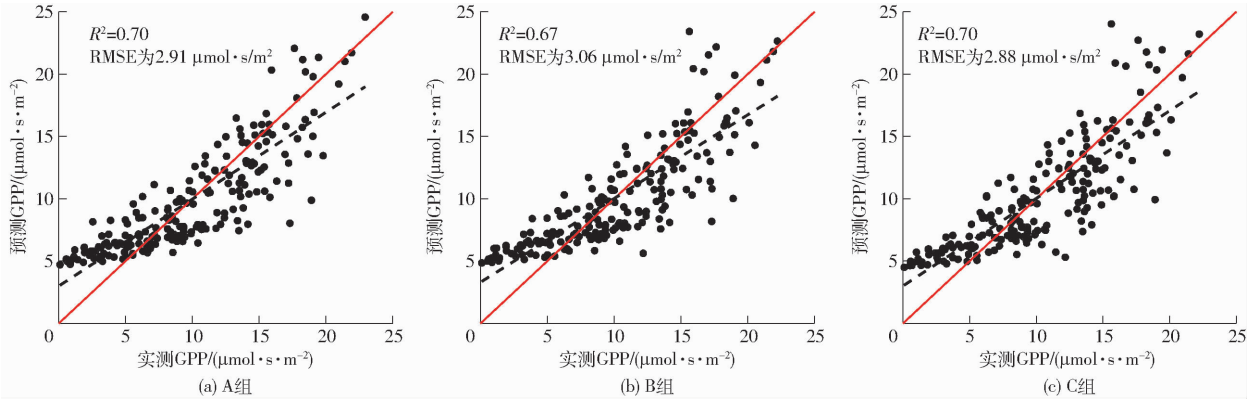

图 4　FRSIF 基于单一变量线性回归方法的 GPP 估算模型

Fig. 4　Estimation models of GPP with FRSIF as independent variable based on SLR model

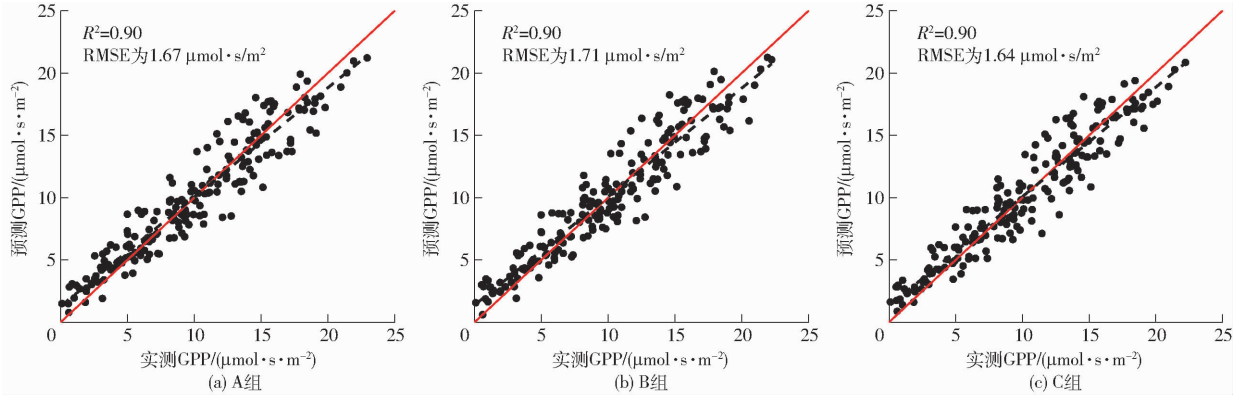

图 5　RSIF 基于多元线性回归方法的 GPP 估算模型

Fig. 5　Estimation models of GPP with RSIF as independent variable based on MLR model

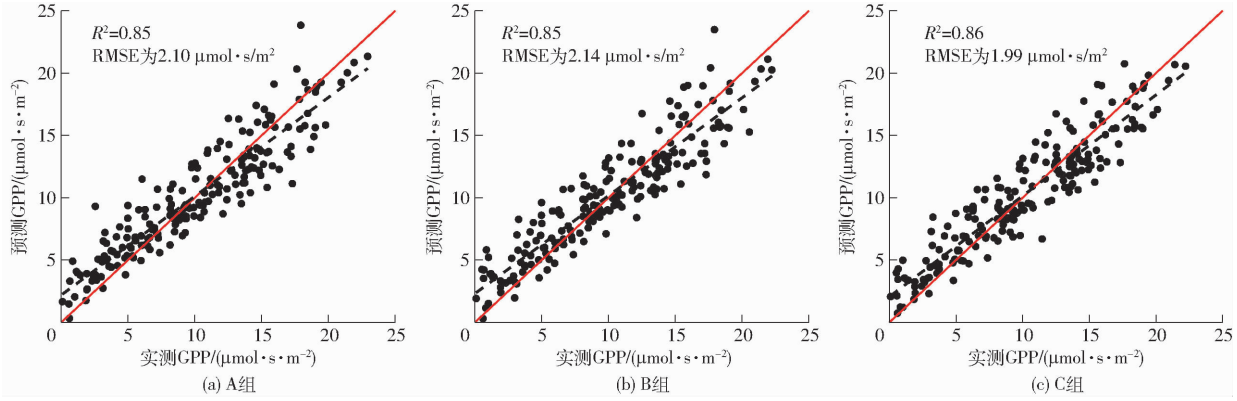

图 6　FRSIF 基于多元线性回归方法的 GPP 估算模型

Fig. 6　Estimation model of GPP with FRSIF as independent variable based on MLR model

18.57%、23.88% 和 18.57%，RMSE 分别降低 25.43%、28.10% 和 23.96%。以 RSIF 和其它数据（Ta、VPD、NDVI、MTCI 和 PAR）为自变量构建的 MLR 模型的预测 GPP 与实测 GPP 间的平均 R^2 较 FRSIF 提高 5.47%，平均 RMSE 降低 19.39%（图 5 和图 6）。综合图 3～6 可以看出，以 RSIF 和其它数据为自变量构建的 MLR 模型精度优于以单一 RSIF 构建的 SLR 模型，其预测 GPP 和实测 GPP 间平均 R^2 较 SLR 模型增加 8.43%，平均 RMSE 减少 23.43%。分析图 7 和图 8 可知，综合 RSIF 和其它数据为自变量构建的 RFR 模型精度优于综合 FRSIF 和其它数据，且 3 个样本组中预测 GPP 和实测 GPP 的平均 R^2 较 FRSIF 提高 1.05%，平均 RMSE 降低 5.89%。综合图 3～8 可以看出，以 RSIF 和其它数据为自变量构建的 RFR 模型精度优于 MLR 模型和单一 RSIF 的 SLR 模型，RFR 模型的预测 GPP 值和实测 GPP 值的平均 R^2 较 MLR 模型和 SLR 模型平均 R^2 分别提高 6.67% 和 15.66%，平均 RMSE 分别降低 33.07% 和 48.78%。这与 PSⅡ的荧光发射贡献率在红光波段占比较高的现象一致，RSIF 表现出对植被生理变化更强的响应。这些结果表明，RSIF 比 FRSIF 能够更好地预测 GPP。

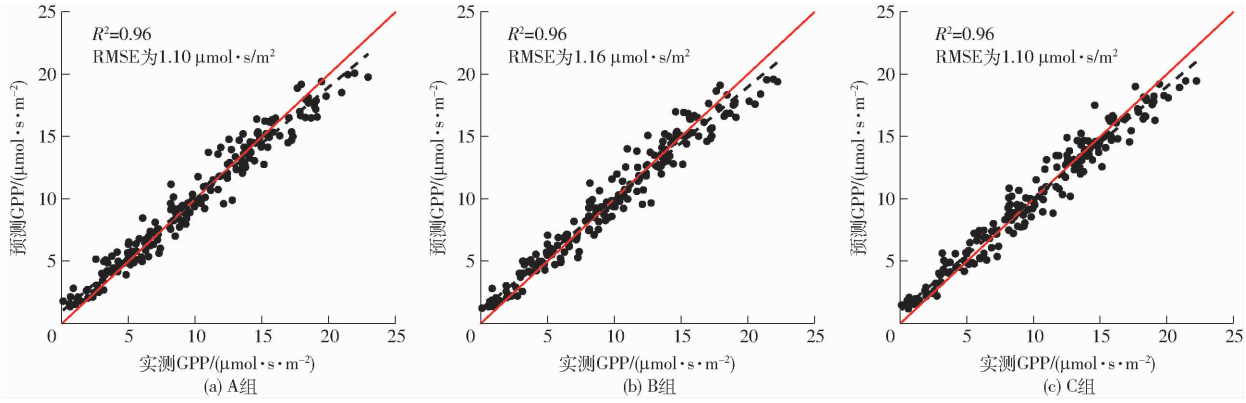

图 7 RSIF 基于随机森林算法的 GPP 估算模型

Fig. 7 Estimation model of GPP with RSIF as independent variable based on RFR model

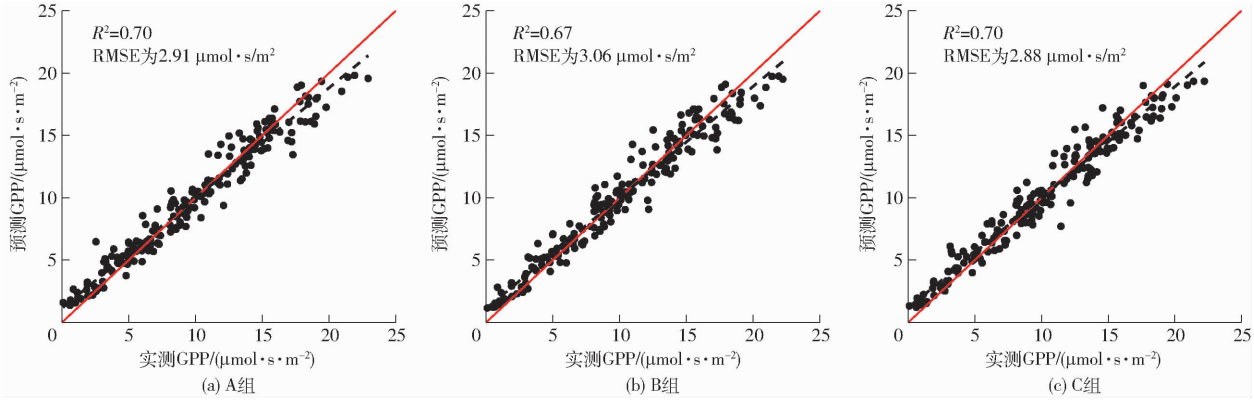

图 8 FRSIF 基于随机森林算法的 GPP 估算模型

Fig. 8 Estimation model of GPP with FRSIF as independent variable based on RFR model

PAR 是驱动 SIF 与 GPP 关系的关键因素,其变化对植被光合作用有直接的影响。NDVI 与冠层结构和群体生物量有关,且与叶面积指数 LAI 有良好的线性关系,能够反映植被冠层结构水平,MTCI 作为表征叶绿素水平的指标,可以与 NDVI 进行良好协同。同时温度和水分也是植被在进行光合作用时不可忽视的重要气象因子。在训练集的模型中,加入 Ta、VPD、NDVI、MTCI 和 PAR 后的 RFR 模型和 MLR 模型的预测 GPP 和实测 GPP 的平均 R^2 较单一 SLR 模型在 RSIF 上分别提高 15.66% 和 8.43%,平均 RMSE 分别降低 48.78% 和 23.48%;在 FRSIF 上分别提高 37.74% 和 23.72%,平均 RMSE 分别降低 59.64% 和 29.60%。因此,在 SIF 与 GPP 的关系中,增加环境因子和光谱指数能够提高 GPP 的估计精度。

2.2.2 模型精度评价

利用决定系数和均方根误差分别对 SLR 模型、MLR 模型和 RFR 模型进行精度评价(表 1)。由表 1 可以看出,在 3 组验证样本数据中,以 RSIF 为自变量构建的 SLR 模型优于 FRSIF。其中,仅以 RSIF 为自变量构建的 SLR 模型预测 GPP 与实测 GPP 间的平均 R^2 较 FRSIF 提高 31.02%,平均 RMSE 降低 34.28%。综合 RSIF 和其它数据为自变量构建的 RFR 模型和 MLR 模型预测 GPP 与实测 GPP 间的平均 R^2 较 FRSIF 分别提高 5.79% 和 12.69%,平均 RMSE 分别降低 16.37% 和 30.56%。综合利用 RSIF 和其它数据为自变量构建的 MLR 模型预测 GPP 与实测 GPP 间的平均 R^2 较单一 RSIF 的 SLR 模型提高 4.67%,平均 RMSE 降低 16.28%。综合利用 RSIF 和其它数据为自变量构建的 RFR 模

表 1 模型精度检验

Tab. 1 Model accuracy test

自变量类型	变量	模型	精度指标	A 组	B 组	C 组
单变量	RSIF	SLR	R^2	0.85	0.86	0.86
			RMSE/(μmol·s·m⁻²)	2.02	1.87	1.94
	FRSIF	SLR	R^2	0.62	0.72	0.63
			RMSE/(μmol·s·m⁻²)	3.18	2.67	3.05
多变量	RSIF + 其它数据	MLR	R^2	0.90	0.91	0.88
			RMSE/(μmol·s·m⁻²)	1.61	1.51	1.76
		RFR	R^2	0.92	0.92	0.90
			RMSE/(μmol·s·m⁻²)	1.59	1.49	1.75
	FRSIF + 其它数据	MLR	R^2	0.82	0.82	0.75
			RMSE/(μmol·s·m⁻²)	2.25	2.17	2.62
		RFR	R^2	0.87	0.87	0.85
			RMSE/(μmol·s·m⁻²)	1.90	1.83	2.04

注:其它数据为 Ta、VPD、NDVI、MTCI 和 PAR。

型的预测 GPP 和实测 GPP 间的平均 R^2 较 MLR 模型和单一 RSIF 的 SLR 模型分别提高 1.86% 和 6.62%，平均 RMSE 分别降低 1.04% 和 17.13%。验证数据集中 RFR 模型的预测精度最高，其次为 MLR 模型和 SLR 模型，这与模型的训练结果一致。

2.3　季节变化对 GPP 预测结果的影响

为了更好地分析 GPP 模型预测结果的季节变化趋势，对比了 RFR、MLR 以及 SLR 3 种方法的 GPP 估算结果（分别表示为 RFR_GPP、MLR_GPP 和 SLR_GPP）与站点实测值（EC_GPP）之间的季节变化特征（图 9 和图 10）。由图 9 和图 10 可以看出，3 种方法估算的 GPP 季节性变化规律相似，区别仅在于随时间的变化幅度不同。在生长季初期，RFR_GPP、MLR_GPP 和 SLR_GPP 均呈现波动上升的趋势，在 DOY 为 180 ~ 210 达到季节峰值，在生长季后期，则均呈现波动下降的趋势。总之，3 种方法预测的 GPP 均能够较好地体现高寒草甸 GPP 的季节变化特征，与 EC_GPP 的单峰季节性变化趋势保持一致。其中，利用 RSIF 预测的 GPP 的季节变化幅度与实测 GPP 的一致性优于 FRSIE，特别是在 DOY 为 170 ~ 176 期间。在生长季早期（DOY 为 151 ~ 163），由 RSIF 和其它数据拟合的 RFR_GPP 与 EC_GPP 间的 MAE 为 0.72 μmol·s/m^2，而由 FRSIF 和其它数据拟合的 RFR_GPP 则出现了严重的 GPP 高估现象，其 MAE 为 1.68 μmol·s/m^2。此外，以 2021 年 RSIF 为自变量构建的 GPP 模型的预测结果看，SLR_GPP 相对于 MLR_GPP 和 RFR_GPP 在整个生长季都出现明显估计误差，尤其是在生长季后期（DOY 为 250 ~ 270），单一变量模型的结果难以反映真实的 GPP 变化。MLR_GPP 的拟合结果则远优于 SLR_GPP，这是因为 MLR 模型在单一 SIF 变量的基础上引入了环境因子（PAR、VPD、Ta）和反射率光谱指数（NDVI 和 MTCI），但在生长季中期（DOY 为 224 ~ 232）MLR_GPP 的结果与 EC_GPP 之间出现了较大误差。RFR_GPP 与 EC_GPP 之间季节变化幅度的一致性优于 MLR_GPP 和 SLR_GPP。这是因为 RFR 模型在平滑方差时通过聚合单个决策树的不同输出减少了可能导致决策树错误的方差，更敏感地捕捉 EC_GPP 的波动，进而减少对 GPP 峰值的低估或者高估，提高了 GPP 预测的精度。

由 2019—2021 年高寒草甸 GPP 季节性总和对比可知，虽然 RFR 模型、MLR 模型和 SLR 模型在 3 年内的预测精度各有不同，但 3 种模型预测的 GPP 结果和 EC_GPP 的季节总和差异很小（相对误差 RE 均在 ±1% 范围内）。从 3 年的生长季数据来看，由 RSIF 和其它数据为自变量的 RFR 模型预测的 GPP

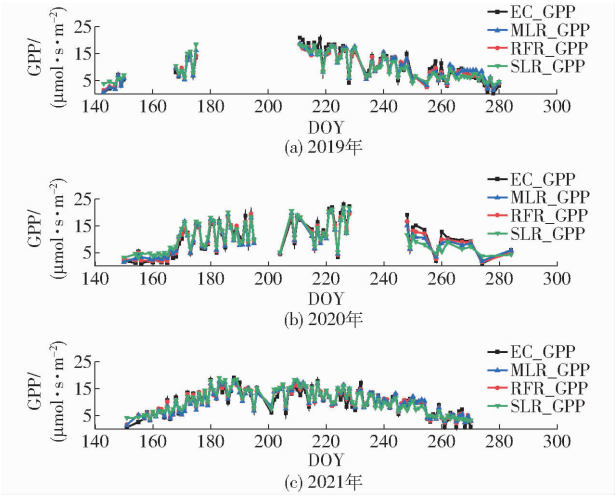

图 9　基于 RSIF 的 GPP 预测模型结果与地面监测 EC_GPP 的时间变化曲线

Fig. 9　Time changes of model estimated GPP based on RSIF and ground monitored monthly EC_GPP

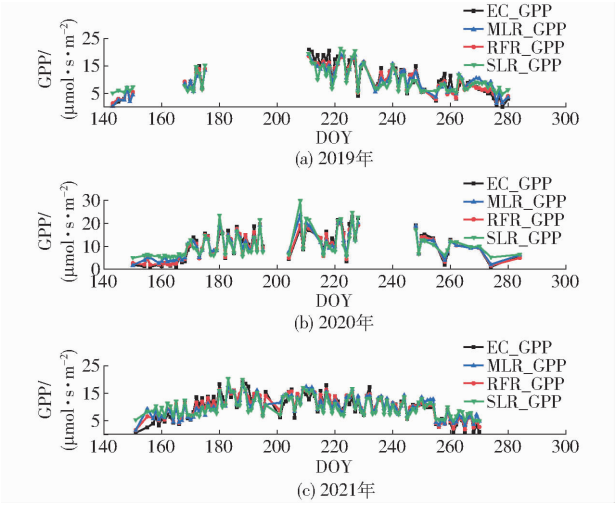

图 10　基于 FRSIF 的 GPP 预测模型结果与地面监测 EC_GPP 的时间变化曲线

Fig. 10　Time changes of model estimated GPP based on FRSIF and ground monitored monthly EC_GPP

季节性总和为2 627.15 μmol·s/m^2，较实测 GPP 总和精度仅低估 0.06%，而 MLR 模型和 SLR 模型则分别高估 0.50% 和 0.63%。由 FRSIF 和其它数据为自变量的 RFR 模型预测 GPP 的季节性总和为 2 614.78 μmol·s/m^2，较实际 GPP 总和低估 0.53%，而 MLR 模型和 SLR 模型则分别高估 0.58% 和 0.88%。在探究不同站点 SIF 对 GPP 的预测影响时，BAI 等[23]比较了综合利用 GOSIF、Ta、VPD、SW 和 LAI 建立的 RFR 模型和利用单一的 GOSIF 建立的 SLR 模型的 GPP 预测精度。结果表明，单一的 SIF 模型预测性能最差，而 RFR 模型预测性能最好。同时与 FRSIF 的预测结果相比，基于 RSIF 的 GPP 预测总值在 3 年内表现出最小的误差。因此，RSIF 在高寒草甸生态系统监测 GPP 性能较 FRSIF 有更

大潜力。

3 讨论

本文利用 NDVI 的简单线性模型计算 FAPAR，这种模型能够较精准地估计 FAPAR 及其日变化[36]。在利用 LIU 等[9]提出的方法进行降尺度时，逃逸率计算公式中同时使用到了 NDVI 和由 NDVI 计算的 FAPAR，这在一定程度上影响了降尺度的结果，这对估测光系统水平的 SIF 具有一定的影响。已有研究表明宽动态范围植被指数(Wide dynamic range vegetation index，WDRVI)与 FAPAR 具有良好的相关性，并被广泛应用[37-38]。此外 FAPAR 作为 APAR 与 PAR 的比值，可以通过测量冠层植被不同角度上的入射辐射计算得出[36]。后续将对相关问题进行进一步研究。

4 结论

(1)在 2019—2021 年高寒草甸生长季，基于塔基自动光谱观测系统、涡度协方差系统和自动气象站的连续观测数据，分析了高寒草甸生态系统中 SIF 与 GPP 的关系，并利用 RFR 等方法建立了基于 SIF 的 GPP 预测模型。

(2)冠层水平 RSIF 及 FRSIF 与 GPP 之间均达到了极显著正相关关系，且 RSIF 与 GPP 之间的 R^2 较 FRSIF 提高 23.53%，RSIF 能够更好地表征高寒草甸光合作用。

(3)以 RSIF 为主要自变量构建的 3 种 GPP 预测模型精度均优于 FRSIF。其中综合 RSIF 和其它数据构建的 RFR 和 MLR 模型预测 GPP 与实测 GPP 间的平均 R^2 较 FRSIF 分别提高 5.79% 和 12.69%，平均 RMSE 分别降低 16.37% 和 30.56%。以单一 RSIF 为自变量构建的 SLR 模型预测 GPP 与实测 GPP 间的平均 R^2 较 FRSIF 增加 31.02%，平均 RMSE 降低 34.28%。

(4)在 SIF 中加入环境因子和植被指数能够有效提高 GPP 的预测精度。综合利用 RSIF 和其它数据为自变量构建的 RFR 模型预测 GPP 和实测 GPP 之间的平均 R^2 较 MLR 提高 1.86%、较单一以 RSIF 为自变量的 SLR 模型提高 6.62%，其对应平均 RMSE 分别降低 1.04% 和 17.13%。

参 考 文 献

[1] BALLANTYNE A, ALDEN C, MILLER J, et al. Increase in observed net carbon dioxide uptake by land and oceans during the past 50 years[J]. Nature, 2012, 488(7409): 70-72.

[2] HILKER T, COOPS N, WULDER M, et al. The use of remote sensing in light use efficiency based models of gross primary production: a review of current status and future requirements[J]. Science of the Total Environment, 2008, 404(2-3): 411-423.

[3] DUAN W, LIU X, CHEN J, et al. Investigating the performance of red and far-red sif for monitoring GPP of alpine meadow ecosystems[J]. Remote Sensing, 2022, 14(12): 2740.

[4] GRACE J, NICHOL C, DISNEY M, et al. Can we measure terrestrial photosynthesis from space directly, using spectral reflectance and fluorescence? [J]. Global Change Biology, 2007, 13(7): 1484-1497.

[5] PAUL-LIMOGES E, DAMM A, HUENI A, et al. Effect of environmental conditions on sun-induced fluorescence in a mixed forest and a cropland[J]. Remote Sensing of Environment, 2018, 219: 310-323.

[6] PORCAR-CASTELL A, TYYSTJÄRVI E, ATHERTON J, et al. Linking chlorophyll a fluorescence to photosynthesis for remote sensing applications: mechanisms and challenges[J]. Journal of Experimental Botany, 2014, 65(15): 4065-4095.

[7] GU L, HAN J, WOOD J, et al. Sun-induced Chl fluorescence and its importance for biophysical modeling of photosynthesis based on light reactions[J]. New Phytologist, 2019, 223(3): 1179-1191.

[8] 黄长平. 太阳光诱导下的植被叶绿素荧光遥感反演方法研究[D]. 北京：中国科学院大学，2013.
HUANG Changping. Retrieval of solar-induced vegetation chlorophyll fluorescence from remotely-sensed data[D]. Beijing: Chinese Academy of Sciences, 2013. (in Chinese)

[9] LIU X, LIU L, HU J, et al. Improving the potential of red SIF for estimating GPP by downscaling from the canopy level to the photosystem level[J]. Agricultural and Forest Meteorology, 2020, 281: 107846.

[10] 竞霞，赵佳琪，叶启星，等. 基于红光波段冠层 SIF 降尺度的小麦条锈病遥感监测[J]. 农业机械学报，2024, 55(7): 252-259.
JING Xia, ZHAO Jiaqi, YE Qixing, et al. Remote sensing monitoring of wheat stripe rust based on canopy downscaling using red SIF[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 252-259. (in Chinese)

[11] MIAO G, GUAN K, YANG X, et al. Sun-induced chlorophyll fluorescence, photosynthesis, and light use efficiency of a soybean field from seasonally continuous measurements[J]. Journal of Geophysical Research: Biogeosciences, 2018, 123(2): 610-623.

[12] YANG K, RYU Y, DECHANT B, et al. Sun-induced chlorophyll fluorescence is more strongly related to absorbed light than to photosynthesis at half-hourly resolution in a rice paddy[J]. Remote Sensing of Environment, 2018, 216: 658-673.

[13] LI Z, ZHANG Q, LI J, et al. Solar-induced chlorophyll fluorescence and its link to canopy photosynthesis in maize from continuous ground measurements[J]. Remote Sensing of Environment, 2020, 236: 111420.

[14] MAGNEY T, BOWLING D, LOGAN B, et al. Mechanistic evidence for tracking the seasonality of photosynthesis with solar-

induced fluorescence[J]. Proceedings of the National Academy of Sciences, 2019, 116(24): 11640 – 11645.

[15] 袁艳斌, 张城芳, 黄鹏, 等. 基于日光诱导叶绿素荧光的陆地总初级生产力估算[J]. 农业机械学报,2022, 53(4): 183 – 191.
YUAN Yanbin, ZHANG Chengfang,HUANG Peng, et al. Estimation of global terrestrial gross primary productivity based on solar-induced chlorophyll fluorescence[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 183 – 191. (in Chinese)

[16] LIU Z, ZHAO F, LIU X, et al. Direct estimation of photosynthetic CO_2 assimilation from solar-induced chlorophyll fluorescence (SIF)[J]. Remote Sensing of Environment, 2022, 271: 112893.

[17] JOINER J, YOSHIDA Y, GUANTER L, et al. New methods for the retrieval of chlorophyll red fluorescence from hyperspectral satellite instruments: simulations and application to GOME – 2 and SCIAMACHY[J]. Atmospheric Measurement Techniques, 2016, 9(8): 3939 – 3967.

[18] BUAREAL K, KATO T, MOROZUMI T, et al. Red solar-induced chlorophyll fluorescence as a robust proxy for ecosystem-level photosynthesis in a rice field[J]. Agricultural and Forest Meteorology, 2023, 336: 109473.

[19] KATO T, TANG Y, GU S, et al. Carbon dioxide exchange between the atmosphere and an alpine meadow ecosystem on the Qinghai – Tibetan Plateau, China[J]. Agricultural and Forest Meteorology, 2004, 124(1 – 2): 121 – 134.

[20] LIU X, LIU L, HU J, et al. Modeling the footprint and equivalent radiance transfer path length for tower-based hemispherical observations of chlorophyll fluorescence[J]. Sensors, 2017, 17(5): 1131.

[21] KIM J, RYU Y, DECHANT B, et al. Solar-induced chlorophyll fluorescence is non-linearly related to canopy photosynthesis in a temperate evergreen needleleaf forest during the fall transition[J]. Remote Sensing of Environment, 2021, 258: 112362.

[22] LIU X, LIU Z, LIU L, et al. Modelling the influence of incident radiation on the SIF-based GPP estimation for maize[J]. Agricultural and Forest Meteorology, 2021, 307:108522.

[23] BAI J, ZHANG H, SUN R, et al. Estimation of global GPP from GOME – 2 and OCO – 2 SIF by considering the dynamic variations of GPP – SIF relationship[J]. Agricultural and Forest Meteorology, 2022, 326: 109180.

[24] WANG Y, MA Y, LI H, et al. Carbon and water fluxes and their coupling in an alpine meadow ecosystem on the northeastern Tibetan Plateau[J]. Theoretical and Applied Climatology, 2020, 142: 1 – 18.

[25] ZHANG Y, ZHANG Q, LIU L, et al. ChinaSpec: a network for long-term ground-based measurements of solar-induced fluorescence in China[J]. Journal of Geophysical Research: Biogeosciences, 2021, 126(3): e2020JG006042.

[26] REICHSTEIN M, FALGE E, BALDOCCHI D, et al. On the separation of net ecosystem exchange into assimilation and ecosystem respiration: review and improved algorithm[J]. Global Change Biology, 2005, 11(9): 1424 – 1439.

[27] MERONI M, COLOMBO R. Leaf level detection of solar induced chlorophyll fluorescence by means of a subnanometer resolution spectroradiometer[J]. Remote Sensing of Environment, 2006, 103(4): 438 – 448.

[28] MERONI M, ROSSINI M, GUANTER L, et al. Remote sensing of solar-induced chlorophyll fluorescence: review of methods and applications[J]. Remote Sensing of Environment, 2009, 113(10): 2037 – 2051.

[29] SIMS D, RAHMAN A, CORDOVA V, et al. Midday values of gross CO_2 flux and light use efficiency during satellite overpasses can be used to directly estimate eight-day mean flux[J]. Agricultural and Forest Meteorology, 2005, 131: 1 – 12.

[30] ZENG Y, BADGLEY G, DECHANT B, et al. A practical approach for estimating the escape ratio of near-infrared solar-induced chlorophyll fluorescence[J]. Remote Sensing of Environment, 2019, 232: 111209.

[31] KODANI E, AWAYA Y, TANAKA K, et al. Seasonal patterns of canopy structure, biochemistry and spectral reflectance in a broad-leaved deciduous Fagus crenata canopy[J]. Forest Ecology and Management, 2002, 167(1 – 3): 233 – 249.

[32] DASH J, CURRAN P. The MERIS terrestrial chlorophyll index[J]. International Journal of Remote Sensing, 2004,25(23): 5403 – 5413.

[33] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45: 5 – 32.

[34] AHMAD M W, REYNOLDS J, REZGUI Y. Predictive modelling for solar thermal energy systems: a comparison of support vector regression, random forest, extra trees and regression trees[J]. Journal of Ceaner Production, 2018, 203: 810 – 821.

[35] WIENEKE S, BURKART A, CENDRER-MATEO M P, et al. Linking photosynthesis and sun-induced fluorescence at sub-daily to seasonal scales[J]. Remote Sensing of Environment, 2018, 219: 247 – 258.

[36] UZDZICKA B, JUSZCZAK R, SAKOWSKA K, et al. NDVI and PRI as indicators of diurnal changes in fraction of absorbed photosynthetically active radiation for fallow and selected species of crop plants[J]. Remote Sensing of Environment, 2013, 20(4): 705 – 720.

[37] LIU X, GUANTER L, LIU L, et al. Downscaling of solar-induced chlorophyll fluorescence from canopy level to photosystem level using a random forest model[J]. Remote Sensing of Environment, 2019, 231: 110772.

[38] LIU L, LIU X, CHEN J, et al. Estimating maize GPP using near-infrared radiance of vegetation[J]. Science of Remote Sensng 2020, 2: 100009.