

doi:10.6041/j.issn.1000-1298.2022.S1.024

农田生态系统碳通量遥感估算方法研究

吴江梅^{1,2} 田泽众^{1,2} 张海洋^{1,2} 刘凯迪^{1,2} 李民赞^{1,2} 张 瑶^{1,2}

(1. 中国农业大学信息与电气工程学院, 北京 100083;

2. 中国农业大学智慧农业系统集成研究教育部重点实验室, 北京 100083)

摘要:为实现农田生态系统碳通量动态监测,提出一种基于Landsat系列多源遥感数据的农田生态系统碳通量估算方法。以美国东北部内布拉斯加州大学农业研发中心的3块试验田地为研究区域,并结合AmeriFlux公开的对应通量站点数据进行后续建模分析。从气候变量、土壤性质、植物性状3方面综合出发,优选与农田生态系统碳通量密切相关的遥感因子,构建覆盖农田生态过程关键环节的全遥感要素数据集。随后,构建基于随机森林(Random forest, RF)的农田碳通量回归预测模型,相比于岭回归模型和套索模型,该模型在农田生态系统碳通量估算方面效果更优,其决定系数(Coefficient of determination, R^2)达到0.94,均方根误差(RMSE)为4.281 g/(m²·d)。基于随机森林模型进行因子的重要性分析可知,DVI、NDWI、MSAVI、NRI、NDVI对碳通量估算的贡献度分别为35.6%、25.8%、12.2%、7.8%、5.2%。在以上研究基础上,通过农田生态系统碳收支时空演变特性分析可知,内布拉斯加州2013年作物生育期内的7、8月时农田碳汇能力最强,在种植初期大豆和玉米均呈现弱碳源,且玉米的碳源能力更强,在生长高峰期时玉米和大豆均呈碳汇,且玉米碳汇能力更强。本研究为农田生态系统碳收支精准估算,进而指导农业生产提供理论支持。

关键词:农田生态系统; 二氧化碳净交换量; 随机森林; 多源卫星遥感; 玉米; 大豆

中图分类号: TP79; S24 **文献标识码:** A **文章编号:** 1000-1298(2022)S1-0224-08

Remote Sensing Estimation Method of Carbon Flux in Farmland Ecosystem

WU Jiangmei^{1,2} TIAN Zezhong^{1,2} ZHANG Haiyang^{1,2} LIU Kaidi^{1,2} LI Minzan^{1,2} ZHANG Yao^{1,2}

(1. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China

2. Key Laboratory of Smart Agriculture System Integration, Ministry of Education, China Agricultural University, Beijing 100083, China)

Abstract: In order to realize the dynamic monitoring of farmland ecosystem carbon flux, a method for estimating farmland ecosystem carbon flux based on Landsat series multi-source remote sensing data was proposed. Three experimental fields of agricultural Research and Development Center of University of Nebraska, northeastern United States were selected as the study area, and the corresponding flux site data published by AmeriFlux was used for subsequent modeling analysis. Based on the comprehensive analysis of climate variables, soil properties and plant traits, remote sensing factors closely related to carbon flux of farmland ecosystem were selected, and a full remote sensing factor data set covering key links of farmland ecological process was constructed. Then, the farmland carbon flux regression prediction model based on random forest was constructed. Compared with the ridge regression model and the lasso model, the model was more effective in estimating farmland ecosystem carbon flux, with a coefficient of determination of 0.94 and a root mean square error of 4.281 g/(m²·d). According to the importance analysis of factors based on random forest model, the contributions of DVI, NDWI, MSAVI, NRI and NDVI to carbon flux estimation were 35.6%, 25.8%, 12.2%, 7.8% and 5.2%, respectively. On the basis of above research, through the farmland ecosystem carbon balance space-time evolution characteristics analysis, the farmland carbon sink capacity was the strongest in 2013 when the crop growth was in the period of July and August in Nebraska, at the beginning of the planting soybeans and corn were rendered weak carbon source, and the carbon source ability was stronger for corn, in growth peak of

收稿日期: 2022-06-11 修回日期: 2022-08-05

基金项目: 国家自然科学基金项目(41801245)和国家重点研发计划中英国际合作项目(2019YFE0125500)

作者简介: 吴江梅(1999—),女,硕士生,主要从事农作物碳循环关键参数定量监测研究,E-mail: jmaywu@cau.edu.cn

通信作者: 张瑶(1988—),女,副教授,主要从事农业定量遥感应用研究,E-mail: zhangyao@cau.edu.cn

corn and soybeans were in carbon sink, and the carbon sequestration ability was stronger for corn. The research result can provide theoretical support for accurately estimating the carbon budget of farmland ecosystems and guiding agricultural production.

Key words: farmland ecosystem; net ecosystem exchange; random forest; multi-source satellite remote sensing; corn; soybean

0 引言

随着国家“碳达峰、碳中和”战略的实施,农田生态系统成为实现双碳目标的重要领域^[1-3]。精准量化农田生态系统的碳收支,掌握农田碳源汇的时空差异,对于指导和管理农业生产活动、进一步推动农业领域节能减排具有重要意义,并为碳排放相关政策的制定提供科学依据^[4-5]。

农田生态系统中的碳存在于大气、土壤、岩石、植物中,碳以不同形式在各个碳库中流通即碳通量,本文所提的碳通量为农田生态系统与大气的二氧化碳的净交换量(Net ecosystem exchange, NEE)。传统的农田碳收支监测常采用涡度相关技术(Eddy covariance technique),可以实现农田碳收支的动态监测^[6-9]。然而,涡度相关法由于对下垫面要求比较高,无法观测地形特殊的农田生态系统,具有较大的局限性,并且测量生态系统碳交换的涡流通量站点数量有限,其中布设在农田生态系统的通量站点尤其稀疏^[10],存在严重的数据缺口,无法实现农田碳通量时空连续监测^[11]。空间遥感技术具有监测面积大、探测周期短、获取信息丰富、费用低廉等特点,因此可以实现对农田生态系统碳收支的连续时空监测。随着卫星观测数据的可使用性不断提升,利用遥感技术在农田生态系统精准量化生态系统碳通量和预测其趋势变化成为可能。

基于卫星遥感技术对农田生态系统碳收支估算的方法可以分为:植被指数法、光能利用率模型、同化动态植被模型、机器学习法和太阳光诱导的叶绿素荧光法。WAGLE 等^[12]在农田碳收支监测中,使用 Landsat 系列卫星衍生的增强型植被指数(EVI)和归一化差值植被指数(NDVI),比较了常规耕作和免耕管理系统下冬小麦二氧化碳通量的大小和季节动态变化,结果表明 NDVI 和 EVI 对农田碳收支变化的可解释度分别为 66% 和 69%。MENEFE 等^[13]利用 PlantScope 卫星数据构建 NDVI 指数实现棉花农田高空间分辨率碳通量时空分析。PIQUE 等^[14]构建了 SAFYE-CO 植被模型,融合 SPOT 卫星高时空分辨率遥感产品估算逐日的作物生物量、水分和碳通量等信息。

目前,植被指数法和光能利用模型法估算农田

碳收支,依赖于人们对陆地生态系统碳循环过程的认知,模型因子未全面考虑环境影响。同化动态植被模型法,模型输入数据、模型参数、模型的验证数据数量多且繁杂,增大训练模型工作量,在数据缺失较多时会导致附加的不确定性增加以及模拟精度低等问题。并且现阶段大部分基于卫星遥感技术对农田生态系统碳收支估算的研究多是基于单一传感器的数据产品,其数据的时间分辨率较低且缺乏一致性。

针对制约当前农田碳收支遥感监测发展的问题,亟需开展面向农田生态系统的碳收支遥感精准估算方法研究。本研究应用 Landsat 系列多源遥感数据,结合美国东北部内布拉斯加州大学农业研发中心的 3 个农田通量站点数据,综合作物、土壤、气象等多要素关键特征,围绕农田生态系统碳循环机理,深入开展农田尺度碳收支精准估算研究,以揭示农田碳收支时空演变机制,构建基于农田碳收支动态过程精准估算方法与模型。

1 材料与方法

1.1 研究区概况

研究地点位于美国东北部米德附近的内布拉斯加州大学农业研发中心的 3 块试验田,分别在每块地内设置了通量站点(US-NE1、US-NE2、US-NE3),如图 1 所示。研究区域海拔为 361 m,年平均气温为 10.07℃,年降水量为 790.37 mm,主要集中在 6—8 月,湿润大陆气候,即冬季潮湿,无旱季,夏季炎热。站点 US-NE1、US-NE2 的田地配备了中心枢纽灌溉系统,而站点 US-NE3 的田地仅依赖降雨。站点 US-NE1 持续种植玉米,站点 US-NE2 和站点 US-NE3 为玉米大豆轮作,种植的玉米品种为 M Pioneer 33P67,大豆品种为 Asgrow 2703,播种时间通常在 5 月中旬,收获时间在 10 月中旬或 10 月底^[15]。自 2001 年以来所有农田都是免耕的,并且作物管理(即植物种群,除草剂和杀虫剂的应用,灌溉)按照生产规模玉米系统规定的最佳管理实践实施^[16]。

3 个通量站点的涡流协方差测量系统均由以下传感器组成:R3 型全向 3D 声波风速计(Gill Instruments Ltd., 英国), LI6262 型闭路红外式 CO₂/

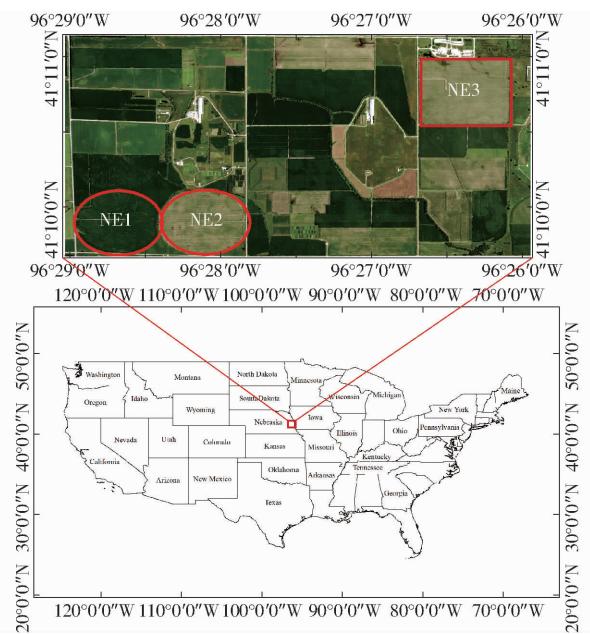


图1 研究区位置以及田块分布

Fig. 1 Location and field distribution of study area

H_2O 气体分析系统 (Li-Cor Inc., 美国) 和 KH-20 型氯湿度计 (Campbell Scientific, 美国)。当作物冠层短于 1 m 时, 涡流协方差测量系统在离地面 3.0 m 外, 后移动到 6.0 m 的高度直到收获^[16]。涡流协方差测量系统所测得的二氧化碳净交换量即可作为该农田的代表性碳通量并用于后续的建模研究。

1.2 通量站点数据预处理

通量站点 US-NE1、US-NE2、US-NE3 数据收录于公开数据集 FLUXNET2015 (<http://fluxnet.fluxdata.org/data/fluxnet2015-dataset/>)。选用站点数据产品为第四级产品, 包括分辨率 30 min 的水平风速, 风向, 摩擦速度, CO_2 净交换量 (Net ecosystem exchange, NEE)、总初级生产力 (Gross primary production, GPP)、生态系统呼吸 (Ecosystem respiration, RE) 参数。所有数据都经过 AmeriFlux 和 FLUXNET 采用的标准质量检查^[17]。3 个站点数据集的时间跨度为 2001—2014 年, 各站点信息如表 1 所示。根据产品中的数据评价标志剔除异常数据以及缺失数据, 根据 Landsat 系列卫星过境时间, 将小时尺度的参数重采样为日时间分辨率。

表1 通量站点信息

Tab. 1 Flux site information

站点名称	种植面积/ hm^2	经度	纬度
US-NE1	48.7	96°28'35.9"W	41°9'54.2"N
US-NE2	52.4	96°28'12.3"W	41°9'53.5"N
US-NE2	65.4	96°26'22.7"W	41°10'46.8"N

1.3 遥感数据预处理

本文选用的卫星遥感数据为 Landsat 系列 5、7、

8 卫星影像数据, Landsat-5 卫星搭载专题制图仪 (TM) 和多光谱成像仪 (MSS), Landsat-7 卫星装备有增强型专题制图仪 (Enhanced thematic mapper plus, ETM+), Landsat-8 卫星装备有陆地成像仪 (Operational land imager, OLI) 和热红外传感器 (Thermal infrared sensor, TIRS)。Landsat 系列卫星的时间分辨率为 16 d, 空间分辨率为 30 m, 并且都覆盖红波段 (Red)、蓝波段 (Blue)、绿波段 (Green)、近红外波段 (NIR)、短波红外波段 (SWIR1、SWIR2)。

通过 Google Earth Engine 云平台 (<https://earthengine.google.com/>), 获取 2001—2014 年研究区域的 Level-2 级别地表反射率 (SR) 产品, 该级别产品数据经过辐射校正和几何校正, 并将校正后的图像数据映射到指定的地图投影坐标下。并手动剔除了云量高于 70% 的影像。QA (Quality assessment band) 波段是一种使用 FMASK 算法得到的影像质量评估数据, 其中包含了云、云影、卷云、水体等信息, 本文对 QA 波段进行特殊掩码操作, 消除研究区域云和云阴影的影响。

1.4 随机森林算法

随机森林算法 (Random forest, RF) 由多个决策树组成, 是一种高效、可靠的集成学习方法, 对样本数据的离群值和噪声具有良好的容忍性, 可以用于分类和回归问题^[18-20]。

设样本数据集为 $T = \{(x_i, y_i)\}, i = 1, 2, \dots, m$ 。其中 x_i 是第 i 个样本的输入变量, y_i 是第 i 个样本的输出变量, 然后从样本数据集 T 中使用有放回抽样 (Bootstrap) 方法随机抽样, 获得 N 个子样本集来建立回归模型, 随机森林树 $f(x)$ 是 N 个子样本集的集合, 即

$$f(x) = \frac{1}{N} \sum_{n=1}^N f_n(x) \quad (1)$$

式中 $f(x)$ —— 随机森林回归模型的预测结果

$f_n(x)$ —— 由单个决策树做出的预测结果

随机森林模型关键参数包括节点分裂评价准则、划分时考虑的最大特征比例、内部节点分裂的最小样本数、叶子节点的最小样本数、叶子节点中样本的最小权重、树的最大深度、叶子节点的最大数量、节点划分不纯度的阈值、决策树数量^[21]。其中决策树数量主要决定模型精度, 其太小容易欠拟合, 太大不能显著地提升模型精度^[22]。

1.5 模型评价指标

选择均方根误差 (Root mean square error, RMSE) 和决定系数 (Coefficient of determination, R^2) 作为农田碳通量模型的评价指标。均方根误差是预测值与真实值偏差的平方与观测次数比值的平方

根,衡量的是预测值与真实值之间的偏差,并且对数据中的异常值较为敏感。决定系数能体现估计值与真实值之间的变化趋势和拟合程度,其值越大,模型的拟合效果越好。

2 结果与讨论

2.1 农田生态系统碳通量影响因子

气候、植被、土壤及其人类活动等诸多因子影响着农田碳通量。其中,本文从土壤性质、气候变量、植物性状 3 方面选择农田生态系统碳通量影响因子。

农田土壤可以通过土壤养分、土壤含水量、土壤中的微生物和动物活动来影响农田生态系统的碳通量^[23]。土壤水分可以影响土壤的通气状况,从而影响土壤中的微生物对有机碳的分解和转化^[24]。土壤养分包括土壤氮(N)、土壤磷(P)、土壤钾(K),这 3 类主要供给作物生长元素^[25]。

气候因素方面,如降水量、温度、光照强度、霜降天数、降雪天数、蒸散量等变量是调节植物光合作用和呼吸作用的关键因素^[26]。其中,地表温度与生态系统总呼吸有强相关性,常用来估算夜间净二氧化碳交换量^[27]。

植物性状可以体现植物对外界环境的响应和适应,农田作物的叶面积指数、比叶面积、叶绿素含量、叶片含氮量、叶片含磷量等植物性状可以体现农田生态系统的生产力^[28-29]。

从以上 3 方面选出了归一化植被指数(NDVI)、比值植被指数(RVI)、差值植被指数(DVI)、增强型植被指数(EVI)、氮素反射指数(NRI)、转换型叶绿素吸收反射率指数(TCARI)、归一化水指数(NDWI)、归一化差值含水指数(NDMI)、修正土壤调节植被指数(MSAVI)、地表水(TPW)、温度(LST)、植被覆盖度(FVC)等作为农田碳通量的遥感因子,如表 2、图 2 所示。

表 2 植被指数

Tab. 2 Vegetation index

植被指数	公式
归一化植被指数(Normalized difference vegetation index, NDVI)	$NDVI = (R_{NIR} - R_{Red}) / (R_{NIR} + R_{Red})$
比值植被指数(Ratio vegetation index, RVI)	$RVI = R_{Red} / R_{NIR}$
差值植被指数(Difference vegetation index, DVI)	$DVI = R_{NIR} - R_{Red}$
增强型植被指数(Enhanced vegetation index, EVI)	$EVI = 2.5(R_{NIR} - R_{Red}) / (R_{NIR} + 6R_{Red} - 7.5R_{Blue} + 1)$
氮素反射指数(Nitrogen reflectance index, NRI)	$NRI = (R_{Green} - R_{Red}) / (R_{Green} + R_{Red})$
转换型叶绿素吸收反射率指数(Transformed chlorophyll absorption ratio index, TCARI)	$TCARI = 3[(R_{NIR} - R_{Red}) - 0.2(R_{NIR} - R_{Green})R_{NIR} / R_{Red}]$
归一化水指数(Normalized difference water index, NDWI)	$NDWI = (R_{Green} - R_{NIR}) / (R_{Green} + R_{NIR})$
归一化差值含水指数(Normalized difference moisture index, NDMI)	$NDMI = (R_{NIR} - R_{SWIR1}) / (R_{NIR} + R_{SWIR1})$
修正土壤调节植被指数(Modified soil adjusted vegetation index, MSAVI)	$MSAVI = (2R_{NIR} + 1 - \sqrt{(2R_{NIR} + 1)^2 - 8(R_{NIR} - R_{Red})}) / 2$

注: R_{NIR} 、 R_{Red} 、 R_{Green} 、 R_{Blue} 、 R_{SWIR1} 分别为近红外、红、绿、蓝和短波红外波段反射率。 $\sqrt{ } \quad$ 为计算平方根。

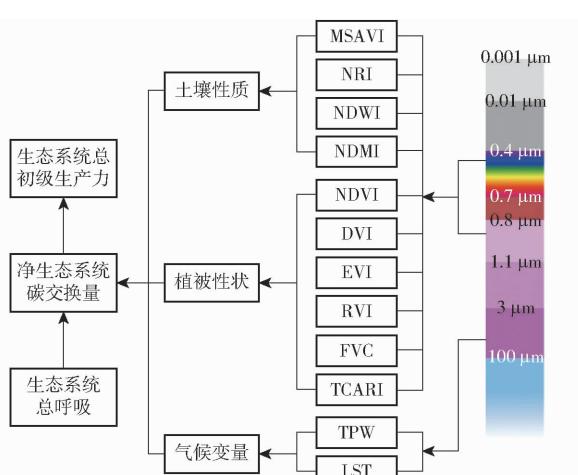


图 2 优选碳通量影响因子

Fig. 2 Influence factor of carbon flux

本文使用了皮尔逊相关系数(Pearson correlation coefficient),分别对 12 个遥感因子和农田

生态系统碳循环关键参数进行相关性分析。

在计算相关系数之前,先过滤数据以找出离群值(离群值可能会导致误导性的结果)的线性关系并对数据变量进行正态性检验。数据集属于小数据样本(一般样本数 5 000 以下),对数据进行 Shapiro-Wilk(S-W) 检验,检验 12 个遥感因子的正态性。由于通常现实情况下很难满足 S-W 检验,本文结合正态分布直方图,以及查看样本峰度绝对值是否小于 10 并且偏度绝对值小于 3 判断是否符合正态分布。结果表明 12 个遥感因子均呈显著性水平,虽然不满足 S-W 检验下的正态分布,但结合直方图可以看出,12 个遥感因子的正态图基本上呈现出钟形(中间高,两端低),则说明数据虽然不是绝对正态,但基本可接受为正态分布^[30]。

双尾显著性检验结果显示 DVI、EVI、FVC、LST、

MSAVI、NDMI、NDVI、NRI、RVI、TPW 与 NEE 呈极显著 ($P < 0.01$) 负相关关系, TCARI、NDWI 与 NEE 呈

极显著正相关关系。皮尔逊相关性系数热力图如图 3 所示。

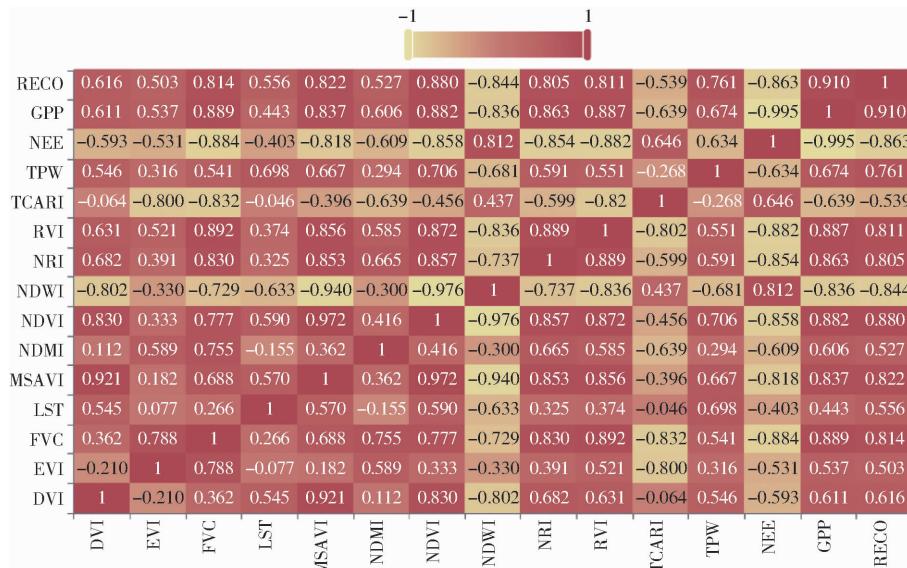


图 3 相关系数热力图

Fig. 3 Correlation coefficient thermogram

2.2 模型结果与对比

利用内布拉斯加州大学农业研发中心的 3 个农田通量站日净二氧化碳交换量(碳通量)作为真值,与 Landsat 系列卫星遥感影像计算出的 12 个优选遥感因子按遥感影像拍摄日期一一对应,构成数据集。

使用 Kennard – Stone(KS) 算法对数据集中的所有样本进行划分。将 KS 算法得出的差异性最大的前 70% 的数据作为训练集,后 30% 数据作为验证集。

经过大量试验,当模型叶子节点的最小样本数为 1、树的最大深度为 10、叶子节点的最大数量为 50、决策树数量为 50 时模型最优。

为了验证随机森林构建模型的有效性,分别选取岭回归模型(Ridge regression, RR)和套索回归模型(Lasso)作为对比模型。对比模型和随机森林模型均在 Python 3.7 的 scikit – learn 库中构建运行,操作系统为 Windows 10,CPU 采用 Intel i7 – 10750H 处理器,主频为 2.59 GHz。

由图 4 可以看出,在相同的训练集测试集下,随机森林模型的 R^2 达到 0.94,比岭回归模型提高 0.08,比套索模型提高 0.07。随机森林的 RMSE 为 $4.281 \text{ g}/(\text{m}^2 \cdot \text{d})$,岭回归模型 RMSE 为 $6.385 \text{ g}/(\text{m}^2 \cdot \text{d})$ 和套索模型的 RMSE 为 $6.236 \text{ g}/(\text{m}^2 \cdot \text{d})$,随机森林的 RMSE 最低,表明随机森林算法构建的模型在估算农田生态系统碳通量有较好的效果。

随机森林模型取得较好的预测效果可归因于 Bagging 策略,其降低各决策树之间的相关性,使决策过程更加多元。并且在 Bagging 策略下每次未被

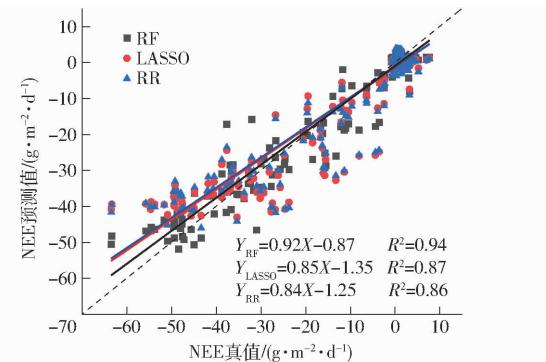


图 4 模型效果对比

Fig. 4 Comparison of model results

选中的样本形成包外数据集,所以不需要留出额外的数据进行交叉验证,随机样本的选取也减少了计算量,而最终的决策结果收集了所有决策树的信息,保证了模型的预测精度。对于岭回归模型,其通过放弃最小二乘法的无偏性,以损失部分信息、降低精度为代价使获得的回归系数更为符合实际、更可靠,所以精度低于随机森林模型。而套索回归模型通过引入 k 个单位阵,使得回归系数可估计,单位阵引入会导致信息失去去,所以其精度稍差于随机森林模型。

2.3 因子对 NEE 估算的贡献度分析

使用随机森林 Bagging 策略时使用有放回抽样(Bootstrap)方法,每次约有 $1/3$ 的样本不会出现在 Bootstrap 所采集的样本集合中,这些没有参加决策树的建立的数据称为袋外数据(Out-of-bag data, OOB)。本文利用随机森林的袋外数据错误率(Out-of-bag error)评价这 12 个遥感因子对模型的贡献度。

由图 5 可以看出,12 个遥感因子中对于随机森

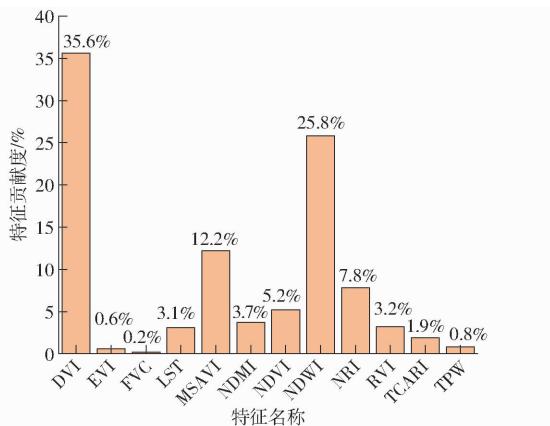


图 5 特征贡献度

Fig. 5 Feature contribution

林模型贡献度最高的是 DVI, 其次是 NDWI、MSAVI、NRI、NDVI。而 FVC、EVI、TPW 的贡献度较低, 试去除这 3 个遥感因子, 用剩余 9 个从植物性状、气候变量、土壤性质 3 方面挑选出来的遥感因子构建模型 (RF_9), 结果显示 R^2 为 0.92, 相较未删减模型 (RF_{12}) 略微下降, RMSE 略微增长至 $4.749 \text{ g}/(\text{m}^2 \cdot \text{d})$, 总体还是较上述对比模型效果好, 如图 6 所示。

2.4 农田生态系统碳收支时空演变特性分析

为了探究不同生育期、不同种植作物的碳源汇能力, 选择 2013 年美国内布拉斯加州的农作物种植地区作为研究区域, 分析其在 6—9 月(即作物关键生育期)的农田生态系统 NEE 时空变化特性。2013 年美国国家农业部(USDA)发布内布拉斯加州的土地覆盖作物调查报告中土地覆盖类型如图 7 所示, 内布拉斯加州的西部主要是由牧草所覆盖, 农作物

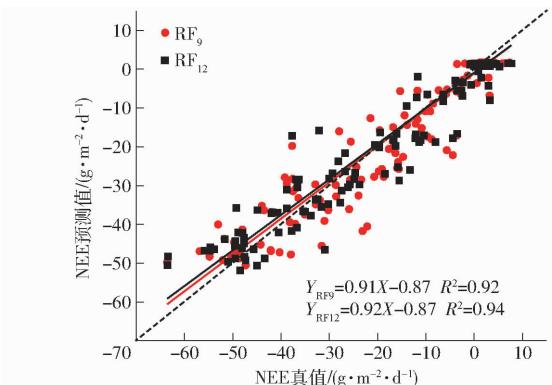


图 6 模型效果

Fig. 6 Comparison of model results

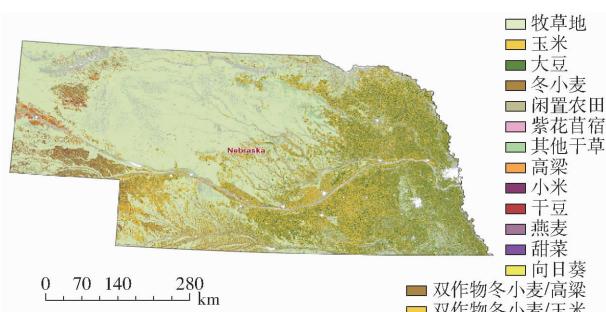


图 7 内布拉斯加州土地覆盖类型

Fig. 7 Land cover types in Nebraska

主要分布在东部地区, 其中种植面积最多的粮食作物是玉米(C4 作物), 其次是大豆(C3 作物)。

将上述本地训练好的随机森林模型移植到 GEE 云平台, 实现农田碳通量估算模型全过程云计算。2013 年 6—9 月的内布拉斯加州的 NEE 分布如图 8 所示。内布拉斯加州 2013 年的作物播种时间

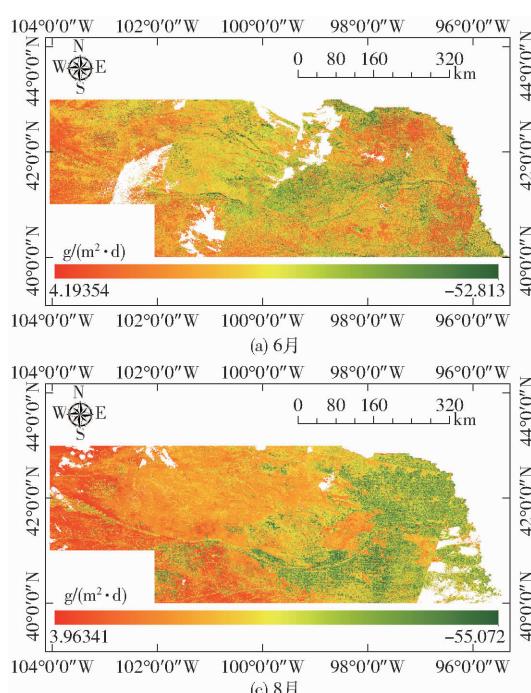
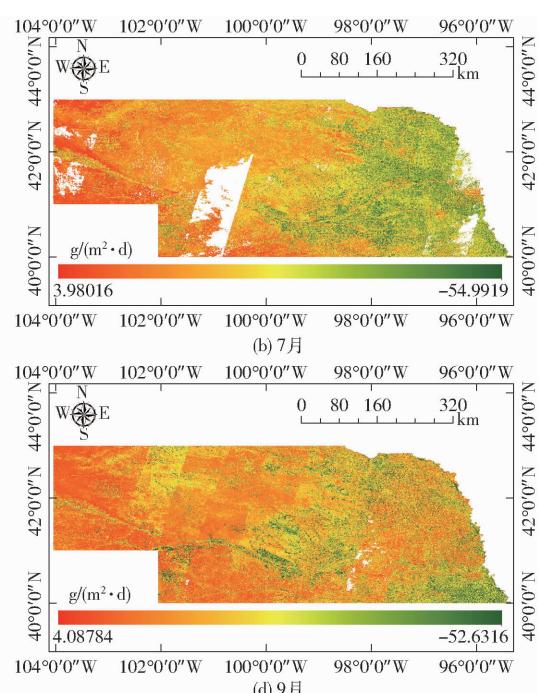


图 8 内布拉斯加州的 NEE 分布

Fig. 8 NEE distribution in Nebraska



集中在5月底至6月初,收获时间集中在9月中旬至10月中旬。可以发现在内布拉斯加州东部农田,在6月至9月作物生长期呈碳汇状态,且碳汇能力逐渐加强直至收获作物。在此期间其碳汇能力远高于西部草地。农田碳吸收峰值出现在7、8月,此时农田碳汇能力最强,最强的田块能达到 $-55.072 \text{ g}/(\text{m}^2 \cdot \text{d})$ 。

为了进一步探究不同种植农作物的碳源汇能力,本研究利用土地作物覆盖类型(图9)提取部分目标区域内的两种主要种植作物(玉米和大豆)的NEE空间分布结果。可以看出在种植初期大豆和玉米都呈现弱碳源,且玉米的碳源能力更强,在生长高峰期时玉米和大豆都呈碳汇,且玉米碳汇能力更强。

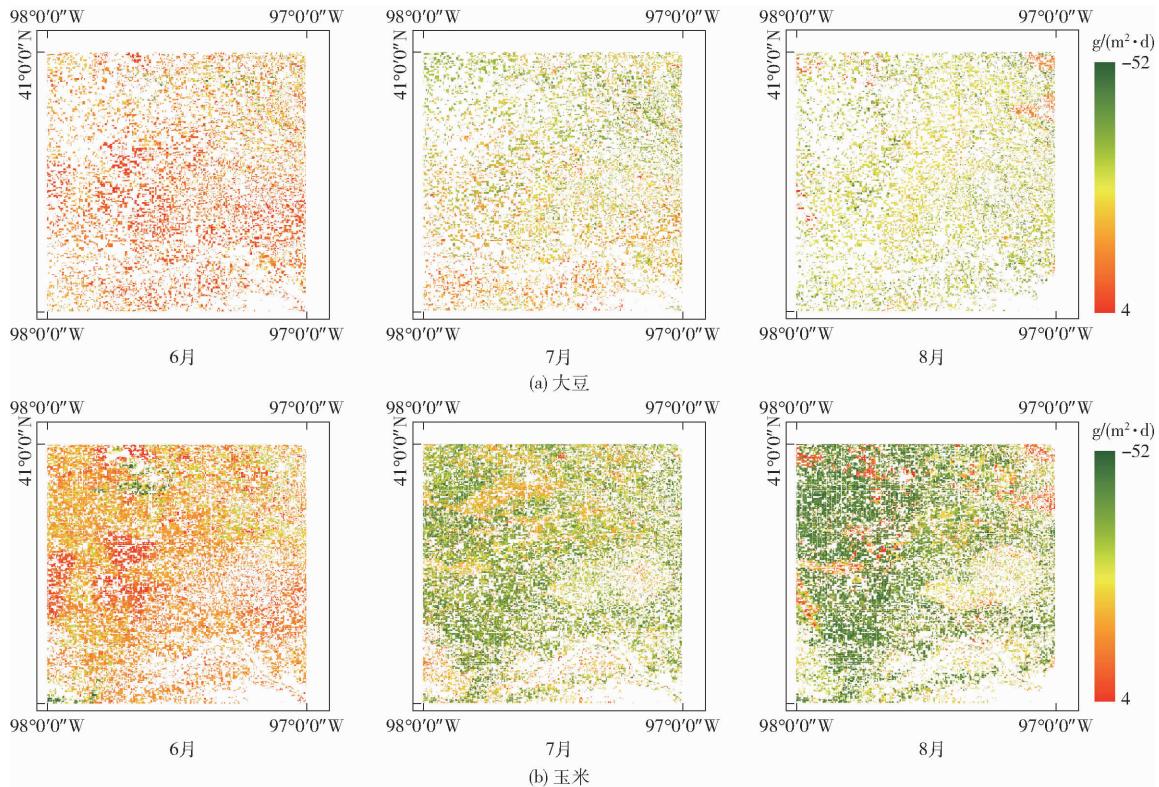


图9 不同作物的 NEE 分布

Fig. 9 Distribution of NEE of different crops

3 结论

(1)从气候变量、植物性状、土壤性质3方面环境因素考虑,选出12个与农田碳通量密切相关的遥感因子。利用随机森林模型进行重要性分析可知DVI、NDWI、MSAVI、NRI、NDVI对碳通量估算的贡献度分别为35.6%、25.8%、12.2%、7.8%、5.2%,FVC、EVI、TPW的贡献可以忽略不计。去除掉贡献度低的3个遥感因子构建模型,其精度依旧高于传统的回归模型。

(2)利用随机森林算法构建农田碳通量模型,

其 R^2 达到0.94, RMSE为 $4.281 \text{ g}/(\text{m}^2 \cdot \text{d})$ 。相较于岭回归模型和套索模型,随机森林模型预测精度最佳,表明随机森林算法构建的模型在估算农田生态系统碳通量有较好的效果。

(3)利用GEE云平台对2013年内布拉斯加州的农田生态系统碳收支进行时空演变特性分析,结果表明农田碳吸收峰值出现在7、8月,此时农田碳汇能力最强,在种植初期大豆和玉米都呈现弱碳源,且玉米的碳源能力更强,在生长高峰期时玉米和大豆都呈碳汇,且玉米碳汇能力更强。

参考文献

- [1] 赵辉,朱盛强,刘贞,等. 基于涡度相关技术的农田生态系统碳收支评估[J]. 环境科学学报, 2021, 41(11): 4731–4739.
- [2] FAN J, MCCONKEY B G, CHANG L B, et al. Increasing crop yields and root input make Canadian farmland a large carbon sink[J]. Geoderma, 2019, 336:49–58.
- [3] YI P, GITELSON A A. Remote estimation of gross primary productivity in soybean and maize based on total crop chlorophyll content[J]. Remote Sensing of Environment, 2012, 117:440–448.
- [4] 刘良云,白雁,孙睿,等.“全球生态系统碳循环关键参数立体观测与反演”项目概述与研究进展[J]. 遥感技术与应用,

- 2021, 36(1): 11–24.
- [5] 姜克隽. IPCC 1.5℃特别报告发布,温室气体减排新时代的标志[J]. 气候变化研究进展, 2018, 14(6): 640–642.
- [6] 戴衍晨, 王瑞, 张继光, 等. 恩施烟区烟田生态系统 CO₂ 通量变化特征分析[J]. 中国烟草学报, 2015, 21(4): 63–69.
- [7] 时元智, 时红, 崔远来, 等. 基于涡度相关法的长江中下游稻田水分利用效率变化规律[J]. 农业工程学报, 2021, 37(4): 130–139.
- [8] WANG Y, HU C, DONG W, et al. Carbon budget of a winter-wheat and summer-maize rotation cropland in the North China Plain[J]. Agriculture Ecosystems & Environment, 2015, 206: 33–45.
- [9] WANG Z, KGAB C, BPAB C, et al. Quantifying carbon budget, crop yields and their responses to environmental variability using the ecosys model for U.S. Midwestern agroecosystems[J]. Agricultural and Forest Meteorology, 2021, 307: 108521.
- [10] YUE Y Y Y, NI J N J, CIAIS P C P, et al. Lateral transport of soil carbon and land-atmosphere CO₂ flux induced by water erosion in China[J]. Proceedings of the National Academy of Sciences of the United States of America, 2016, 113(24): 6617–6622.
- [11] FU D, CHEN B, ZHANG H, et al. Estimating landscape net ecosystem exchange at high spatial-temporal resolution based on Landsat data, an improved upscaling model framework, and eddy covariance flux measurements [J]. Remote Sensing of Environment, 2014, 141: 90–104.
- [12] WAGLE P, GOWDA P H, NORTHUP B K, et al. Variability in carbon dioxide fluxes among six winter wheat paddocks managed under different tillage and grazing practices[J]. Atmospheric Environment, 2018, 185(7): 100–108.
- [13] MENEFEET D, RAJAN N, SONG C, et al. Carbon exchange of a dryland cotton field and its relationship with PlanetScope remote sensing data[J]. Agricultural and Forest Meteorology, 2020, 294(2): 108130.
- [14] PIQUE G, FIEUZAL R, BITAR A A, et al. Estimation of daily CO₂ fluxes and of the components of the carbon budget for winter wheat by the assimilation of Sentinel 2-like remote sensing data into a crop model[J]. Geoderma, 2020, 376: 114428.
- [15] AMOS B, ARKEBAUER T J, DORAN J W. Soil surface fluxes of greenhouse gases in an irrigated maize-based agroecosystem [J]. Soil Science Society of America Journal, 2005, 69(2): 387–395.
- [16] VERMA S B, DOBERMANN A, CASSMAN K G, et al. Annual carbon dioxide exchange in irrigated and rainfed maize-based agroecosystems[J]. Agricultural and Forest Meteorology, 2005, 131(1–2): 77–96.
- [17] HOUSEN C, BALDOCCHI D D, CRISTINA P, et al. Temporal dynamics of aerodynamic canopy height derived from eddy covariance momentum flux data across North American flux networks[J]. Geophysical Research Letters, 2018, 45(17): 9275–9287.
- [18] HO T K. The random subspace method for constructing decision forests[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 1998, 20(8): 832–844.
- [19] AMIT Y, GEMAN D. Shape quantization and recognition with randomized trees[J]. Neural Computation, 2006, 9(7): 1545–1588.
- [20] DIETTERICH T G. An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization[J]. Machine Learning, 2000, 40(2): 139–157.
- [21] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5–32.
- [22] GIESEKE F, IGEL C. Training big random forests with little resources[C]//Proceedings of the 24th ACM Sigkdd International Conference on Knowledge Discovery & Data Mining, 2018: 1445–1454.
- [23] WANG W J, DALAL R C, MOODY P W, et al. Relationships of soil respiration to microbial biomass, substrate availability and clay content[J]. Soil Biology and Biochemistry, 2003, 35(2): 273–284.
- [24] LÜTZOW M, KÖGEL-KNABNER I, EKSCHMITT K, et al. Stabilization of organic matter in temperate soils: mechanisms and their relevance under different soil conditions—a review[J]. European Journal of Soil Science, 2006, 57(4): 426–445.
- [25] WEI H, GUENET B, VICCA S, et al. High clay content accelerates the decomposition of fresh organic matter in artificial soils [J]. Soil Biology and Biochemistry, 2014, 77: 100–108.
- [26] BEER C, REICHSTEIN M, TOMELLERI E, et al. Terrestrial gross carbon dioxide uptake: global distribution and covariation with climate[J]. Science, 2010, 329(5993): 834–838.
- [27] ZHOUT, SHI P, HUI D, et al. Global pattern of temperature sensitivity of soil heterotrophic respiration (Q10) and its implications for carbon-climate feedback[J]. Journal of Geophysical Research: Biogeosciences, 2009, 114: G02016.
- [28] DOMINGUEST F, MEIR P, FELDPAUSCH T R, et al. Co-limitation of photosynthetic capacity by nitrogen and phosphorus in West Africa woodlands[J]. Plant, Cell & Environment, 2010, 33(6): 959–980.
- [29] XIA J, NIU S, CIAIS P, et al. Joint control of terrestrial gross primary productivity by plant phenology and physiology[J]. Proceedings of the National Academy of Sciences, 2015, 112(9): 2788–2793.
- [30] 谢明文. 关于协方差、相关系数与相关性的关系[J]. 数理统计与管理, 2004(3): 33–36.