doi:10.6041/j.issn.1000-1298.2025.11.060

多光谱遥感影像融合生成式对抗网络的农田生态系统 CO_2 排放通量反演模型

赵文举[1,2]　俞海英[1,3]　李浩霖[4]　丁　磊[1,2]　杨鹏涛[1,2]

(1. 兰州理工大学土木与水利工程学院, 兰州 730050; 2. 农业农村部智慧农业节水灌溉装备重点实验室, 兰州 730050;
3. 河西学院土木工程学院, 张掖 734000; 4. 北京工业大学环境科学与能源工程学院, 北京 100124)

摘要: 针对农田生态系统 CO_2 排放通量持续性、动态化监测难度大,实际样本获取成本高等问题,本研究以设施番茄为研究对象,基于多光谱遥感影像获取植被指数和纹理特征,使用支持向量机-递归特征消除(Support vector machine - recursive feature elimination,SVM - RFE)、皮尔逊相关系数法(Pearson correlation coefficient,PCC)和灰色关联度分析(Grey relational analysis,GRA)3 种变量筛选方法优选模型输入参数,以静态箱-气相色谱法定位观测作物冠层 CO_2 排放通量为实测值,构建基于极端梯度提升(Extreme gradient boosting,XGBoost)、支持向量机(Support vector machines,SVM)和随机森林(Random forest,RF)的农田生态系统 CO_2 排放通量反演模型。为提高模型预测性能和泛化能力,融合生成式对抗网络(Generative adversarial networks,GAN)扩增样本集。结果表明:3 种反演模型均可实现 CO_2 排放通量快速反演,反演效果从高到低依次为 XGBoost、SVM、RF,其中,通过变量筛选的纹理特征和植被指数作为模型输入参数,可有效提高模型反演精度。从不同机器学习算法来看,XGBoost 模型反演效果最优,其测试集决定系数为 0.565 ~ 0.762,均方根误差为 0.266 ~ 0.861 mg/(m^2·h),平均绝对误差为 0.222 ~ 0.793 mg/(m^2·h);从不同筛选方法来看,SVR - RFE 筛选后的变量特征作为输入参数的模型反演效果最优,其中 XGBoost - SVR - RFE 相结合的反演模型效果最优。整体来看,融合 GAN 的 9 种耦合模型鲁棒性和可靠性均有提高,所有模型 R_p^2/R_c^2 均高于 0.85,其中 GANXGBoost - SVR - RFE 反演模型结果鲁棒性最优。在此基础上,绘制了农田生态系统 CO_2 排放通量时空分布图,揭示番茄全生育期 CO_2 排放规律。研究结果可为农田生态系统 CO_2 排放通量的动态监测和科学计量提供理论依据。

关键词: 光谱指数; 纹理特征; GAN; 农田生态系统 CO_2 排放通量; 反演模型

中图分类号: TP79　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0621-11　　**OSID**:

Multispectral Remote Sensing Image Fusion GAN for Inverse Model of CO_2 Emission Flux in Agricultural Ecosystems

ZHAO Wenju[1,2]　YU Haiying[1,3]　LI Haolin[4]　DING Lei[1,2]　YANG Pengtao[1,2]

(1. *School of Civil and Hydraulic Engineering*, *Lanzhou University of Technology*, *Lanzhou* 730050, *China*
2. *Key Laboratory of Smart Agriculture Irrigation Equipment*, *Ministry of Agriculture and Rural Affairs*, *Lanzhou* 730050, *China*
3. *College of Civil Engineering*, *Hexi University*, *Zhangye* 734000, *China*
4. *College of Energy and Power Engineering*, *Beijing University of Technology*, *Beijing* 100124, *China*)

Abstract: For the difficult problems of the continuity and dynamic monitoring of CO_2 emission fluxes in agricultural ecosystems, as well as the high cost associated with acquiring actual samples, focusing on greenhouse-grown tomatoes, multispectral remote sensing images were utilized to obtain vegetation indices and texture features. The research optimized the model input layer through three variable selection methods: support vector machine - recursive feature elimination (SVM - RFE), Pearson correlation coefficient (PCC) method, and grey relational analysis (GRA). By using static chamber - gas chromatography observations of crop canopy CO_2 emission fluxes as ground - truth values, the inversion models for agricultural ecosystem CO_2 emission flux were constructed by employing extreme gradient

收稿日期: 2024-08-16　修回日期: 2024-09-12

基金项目: 国家自然科学基金项目(52379042)、甘肃省重点研发计划项目(23YFFA0019)和甘肃省青年科技基金项目(25JRRG013)

作者简介: 赵文举(1981—),男,教授,博士生导师,主要从事寒旱区生态水利研究,E-mail: wenjuzhao@126.com

boosting (XGBoost), support vector machines (SVM) and random forest (RF) algorithms. To enhance predictive performance and generalization ability of the models, it integrated generative adversarial networks (GAN) to augment the sample set. The results demonstrated that all three inversion models can achieve rapid inversion of CO_2 emission fluxes and the inversion effects from high to low were XGBoost, SVM and RF. Notably, utilizing selected texture features and vegetation indices as the model input layer through variable selection significantly enhanced the inversion accuracy. Among different machine learning algorithms, the XGBoost model exhibited optimal inversion performance, with R_p^2 ranging from 0.565 to 0.762, RMSEp from 0.266 mg/(m^2·h) to 0.861 mg/(m^2·h) and MAEp from 0.222 mg/(m^2·h) to 0.793 mg/(m^2·h) across test sets. Regarding variable selection methods, the model inversion performed best when variables filtered through SVR-RFE were used as input layers, with the XGBoost-SVR-RFE combination showing superior results. Overall, integrating GAN into nine coupled models improved their robustness and reliability, with all models having R_p^2/R_c^2 above 0.85, where the GANXGBoost-SVR-RFE inversion model demonstrated the highest robustness. Subsequently, temporal-spatial distribution maps of CO_2 emission flux in agricultural ecosystems were created, revealing emission patterns throughout the entire growth period of tomatoes. This research can offer a theoretical basis for dynamic monitoring and scientific quantification of CO_2 emission flux in agricultural ecosystems.

Key words: spectral indices; texture features; GAN; agricultural ecosystem CO_2 emission flux; inverse model

0 引言

大气中温室气体浓度增加导致全球变暖,其中 CO_2 占温室气体排放量的 72%[1]。全球农业用地占土地面积的 38%,农田生态系统 CO_2 排放通量影响大气碳循环管理和碳平衡调节[2]。因此,持续监测和科学计量农田生态系统 CO_2 排放通量,可更好理解碳循环过程,并采取适当管理措施减少农业温室气体排放[3-4]。传统的大区域农田碳收支监测常采用涡度相关技术,可实现碳收支的动态评估[5-6]。然而,涡度相关法对下垫面的高要求限制了地形特殊农田生态系统的观测,有限的生态系统碳交换涡流通量站点测量造成严重的数据缺口,无法实现农田碳通量时空连续监测[7];箱式法在农田小区域范围内可以对作物和土壤 CO_2 排放进行单独测量[8],但无法避免高成本和间断性[9]。因此,迫切需要开发更准确和高效的检测手段及方法,以实现农田生态系统 CO_2 排放通量的持续、动态监测,并降低样本获取成本。

遥感技术在陆地碳循环分析中具有动态、精准优势[10],结合碳通量监测与同化反演技术将是理解和评估农田生态系统碳动态空间格局的关键手段[11-12]。特别是无人机遥感技术因其高时空分辨率和灵活性而受到广泛应用,已成为现代农业、环境监测等领域的重要工具[13-15]。由于大气 CO_2 对特定波长光有吸收和散射作用[16-17],因此监测和分析作物冠层光谱反射率变化可以为探求农田生态系统 CO_2 通量变化提供重要线索[18-19]。LI 等[20]运用无人机多光谱系统测量了半干旱地区玉米净初级生产力(NPP)和玉米田地的光谱反射率,利用矩形双曲线模型计算了玉米最大 NPP,构建基于重要植被指数(VIs)的多元回归模型,计算分析不同植被指数对最大 NPP 变化的解释度;LU 等[21]基于地面观测数据及无人机多光谱影像,开发了基于劳埃德和泰勒的遥感模型(LT1-NIRV),结合 2 种不同来源数据集采用 5 种机器学习算法估算农田生态呼吸;此外,有研究表明,多光谱遥感影像中的纹理特征能进一步挖掘影像中具有反演价值的信息,与植被指数相结合可明显提高模型估测精度[22-23],YANG 等[24]将纹理特征与光谱指数结合,估测水稻叶面积指数(LAI),发现全生育期模型估测精度均有提高;谢坪良等[25]发现植被指数、图像纹理和表型参数构建的反向传播神经网络模型是夏玉米水分胁迫诊断的最佳模型;FAN 等[26]结合光谱和空间纹理特征的优点,用于识别异常像素以提取烧焦的植被区域,与单独的植被指数或纹理特征相比,其精度和 Kappa 系数均有提高。以上研究结果表明,基于植被指数与纹理特征构建的反演模型精度高、可靠性强,然而该技术在农田生态系统 CO_2 通量反演中的应用鲜有报道。

建立深度机器学习模型需依赖于大规模样本集[27],而样本集制备周期长且工作量大、成本高。因此,针对小样本集可采用样本增强方法提升机器学习模型的适用度,实现反演模型快速构建。生成对抗网络(Generative adversarial networks, GAN)[28]通过无监督学习获得数据分布并生成较逼真的数据,在样本增强效果和模型鲁棒性等方面具有显著优势[29]。王志强等[30]在进行番茄叶片病害识别研

究中采用基于 Wasserstein 距离的沃瑟斯坦生成式对抗网络(WGAN)进行数据增强,解决了样本数据不足和不均衡问题,提高模型泛化能力,番茄叶片病害识别准确率达 94.11%,较原始模型提高 2.84 个百分点;何少芳等[31]提出利用 GAN 合成伪高光谱数据和有机质含量的动态估测模型,将 GAN 结合原始数据建模集组合成新的增强建模集,从而提高反演模型组合决定系数 R^2。韩翔等[32]采用基于深度卷积网络的生成式对抗网络(DCGAN)进行图像增强,将甜樱桃分类准确率分别提高 16.44 个百分点和 13.94 个百分点。GAN 的数据增强技术被证明可显著提升小样本数据集建模的泛化能力,在遥感领域具有广泛的应用前景,然而,基于不同变量筛选方法和机器学习算法构建的反演模型中将 GAN 扩增的样本集作为输入层,可否实现对 CO_2 通量精准估测仍需进一步探索。

鉴于此,本研究以设施番茄为研究对象,基于无人机多光谱遥感影像及番茄冠层 CO_2 排放通量实测数据,利用 5 个波段光谱反射率构建与植物性状和土壤性质相关的 20 个植被指数,提取与 CO_2 排放通量相关性最高的近红外波段光谱反射率对应的 8 种纹理特征,采用 SVM-RFE、PCC 和 GRA 3 种变量筛选方法从 28 个特征变量中优选模型输入参数,构建 9 个基于 XGBoost、SVM 和 RF 等机器学习算法的农田生态系统 CO_2 排放通量反演模型,进一步融合 GAN 进行原始样本集扩增,通过模型精度评价选择农田 CO_2 排放通量最佳反演模型,绘制番茄全生育期 CO_2 排放通量时空分布图,以期为实现农田生态系统碳收支科学计量和数字化可持续农田管理提供理论依据。

1　材料与方法

1.1　试验区概况与试验设计

试验地点为兰州新区现代农业示范园区(36°33′N,103°43′E),研究区地处黄河流域上游,属典型的温带半干旱大陆性气候,年平均降水量 327 mm,年均气温 6.9℃,日照率 60%。研究区面积为 80 m × 16 m,种植作物为番茄,品种为‘金棚 8B’,采用沟垄相间的种植方式。番茄种植行距为 80 cm,株距为 40 cm,灌水量、施肥类型及施肥量等均采用前期已确定的设施番茄生长最优水肥调控模式。采样点选择中间位置处的连续 8 垄,每垄中间选择 5 株作为样本,共 40 个样本区,如图 1 所示。

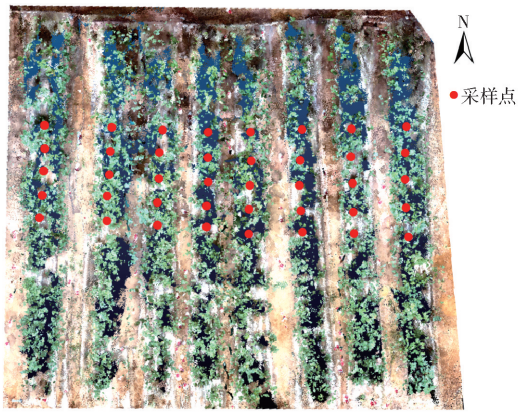


图 1　采样点分布图

Fig. 1　Sampling point distribution map

1.2　试验数据采集与预处理

1.2.1　气体样本采集

采用“静态箱-气相色谱法”观测番茄全生育期 CO_2 排放通量。气体采样时间均为 10:00—12:00,番茄自移栽后第 2 天起平均 7 d 采样 1 次,采样前加水密封,气体采样的同时用安插在箱体顶部的水银温度计测量箱内温度,取气前启动微型电风扇,使箱内气体均匀,气体样品采集使用气泵于静态箱密封后的第 0、10、20、30 分钟采样 4 次,气体样品用 0.5 L 铝箔采气袋封装,采样结束后立即带回实验室,采用气相色谱分析仪(Aglient-7890 型,美国)检测采集气体样品中的 CO_2 浓度。根据已测得的 CO_2 浓度,去除奇异点,估算浓度与时间线性回归的斜率,计算排放通量。计算式为

$$F=\rho h\frac{\mathrm{d}c}{\mathrm{d}t}\frac{273}{273+T} \tag{1}$$

式中　F——CO_2 排放通量,mg/(m²·h)

ρ——标准状态 CO_2 密度,取 1.997 kg/m³

h——静态箱有效高度,m

$\mathrm{d}c/\mathrm{d}t$——气体浓度变化率,mg/(m³·h)

T——采样时静态箱内平均空气温度,℃

将计算后的 40 个实测 CO_2 排放通量数据,随机选择 29 个样本作为建模集,11 个样本作为验证集,对其进行统计分析,结果如表 1 所示。

1.2.2　无人机多光谱遥感

以大疆创新科技有限公司生产的 DJI 精灵 4 无人机为平台,搭载 6 个 1/2.9 英寸 CMOS 影像传感器,包含 1 个彩色 RGB 传感器和 5 个单色光谱传感器,详细波段参数如表 2 所示。分别于 2023 年 9 月 12 日、10 月 10 日、11 月 14 日和 12 月 12 日进行野外气体采样,同步无人机飞行拍摄田间番茄冠层多光谱图像。无人机拍摄时段为 10:00—15:00,天气晴朗无云。测量前先进行白板校准,测量时番茄冠层与传感器探头距离为 2.5 m,并垂直向下,图像空间分辨率为 4.98 cm,测量结束后及时导出数据,通过 DJI Terra 及 ENVI 5.3 软件完成影像预处理及 5 个波段光谱反射率和 8 种纹理特征(对比度

表 1 农田 CO_2 排放通量统计特征

Tab. 1 Statistical characteristics of farmland CO_2 emission flux

数据集	样本数/个	上四分位数/($mg \cdot m^{-2} \cdot h^{-1}$)	下四分位数/($mg \cdot m^{-2} \cdot h^{-1}$)	均值/($mg \cdot m^{-2} \cdot h^{-1}$)	标准差/($mg \cdot m^{-2} \cdot h^{-1}$)	变异系数/%
全集	40	95.15	109.82	100.93	10.11	10.01
建模集	29	93.11	109.75	100.83	10.54	10.46
验证集	11	96.53	110.38	101.21	9.33	9.22

表 2 机载光谱仪波段参数

Tab. 2 Multispectral parameters of UAV nm

名称	中心波长
蓝波段(Blue)	450 ± 16
绿波段(Green)	560 ± 16
红波段(Red)	650 ± 16
红边波段(RedEdge)	730 ± 16
近红外波段(NIR)	840 ± 16

(Contrast,CON)、熵(Entropy,ENT)、方差(Variance,VAR)、均值(Mean,MEA)、协同性(Homogeneity,HOM)、相异性(Dissimilarity,DIS)、二阶矩(Second moment,SEM)和相关性(Correlation,COR))提取。

1.3 光谱指数构建与筛选

1.3.1 光谱指数构建

由于多光谱遥感影像提供不同波段的光谱信息,可捕捉不同植被类型及其生理状态下的特征。基于多光谱波段构建与碳循环相关的植被指数,并提取不同光谱波段的纹理特征,可简单有效地估测农田生态系统碳排放通量。基于前人研究结果,本研究初步构建与植被形状和土壤性质相关的 20 个植被指数,具体计算公式如表 3 所示。

表 3 植被指数

Tab. 3 Vegetation index

影响因子	植被指数	计算公式
作物	归一化差值植被指数(Normalized difference vegetation index,NDVI)	$NDVI=(N-R)/(N+R)$
	绿光归一化植被指数(Green normalized difference vegetation Index,GNDVI)	$GNDVI=(N-G)/(N+G)$
	蓝光归一化植被指数(Blue normalized difference vegetation index,BNDVI)	$BNDVI=(N-B)/(N+B)$
	归一化差异红色边缘指数(Nomalized difference red edge,NDRE)	$NDRE=(N-RE)/(N+RE)$
	核归一化差异植被指数(Kernel normalized difference vegetation index,kNDVI)	$kNDVI=(1-k(N,R))/(1+k(N,R))=\tanh((n-r)/2\sigma)^2,\sigma=0.5(N+R)$
	再归一化植被指数(Renormalized difference vegetation index,RDVI)	$RDVI=(N-R)/(N+R)^{0.5}$
	比值植被指数(Ratio vegetation index,RVI)	$RVI=R/N$
	改进简单比值植被指数(Modified simple ratio index,MSR)	$MSR=(NIR/R-1)/[(NIR/R)^{0.5}+1]$
	改进非线性植被指数(Modified non-linear vegetation index,MNLI)	$MNLI=[(1+L)N^2-R)]/(N^2+R+L)$
	增强型植被指数(Enhanced vegetation index,EVI)	$EVI=2.5(N-R)/(N+6R-7.5B+1)$
	红边叶绿素植被指数(Red edge chlorophyll index,RECI)	$RECI=N/R-1$
	绿色叶绿素植被指数(Green chlorophyll index,GCI)	$GCI=N/G-1$
	归一化差异叶绿素指数(Normalized difference chlorophyll index,NDCI)	$NDCI=(RE-R)/(RE+R)$
	叶绿素吸收反射指数(Chlorophyll absorption reflectance index,CARI)	$CARI=R+2(RE-R)(B-R)$
	转换型叶绿素吸收反射率指数(Transformed chlorophyll absorption ratio index,TCARI)	$TCARI=3[N-R-0.2(N-G)N/R]$
土壤	氮素归一化指数(Nitrogen reflectance index,NRI)	$NRI=(G-R)/(G+R)$
	土壤调节植被指数(Soil regulatory vegetation index,SAVI)	$SAVI=(N-R)/(N+R+L)(1+L)$
	修正土壤调节植被指数(Modified soil adjusted vegetation index,MSAVI)	$MSAVT=[2N+1-\mathrm{sqrt}((2N+1)^2-8(N-R))]/2$
	优化土壤调节植被指数(Optimization of soil regulatory vegetation index,OSAVI)	$OSAVI=(N-R)/(N+R+0.16)$
	归一化水体指数(Normalized difference water index,NDWI)	$NDWI=(G-N)/(G+N)$

注:B、G、R、RE、N 分别表示蓝、绿、红、红边、近红外波段光谱反射率;L 为土壤调整系数,取 0.5;$k(N,R)$ 表示 2 个波段间的相似性。

1.3.2 光谱指数筛选方法

支持向量机-递归特征消除(SVM-RFE)算法融合了支持向量机的分类能力和递归特征选择的思路,通过迭代过程中剔除影响较小特征构建出最佳

特征子集。与传统相关性筛选相比，该方法能有效避免重要变量在模型构建前被过度筛选的问题[33]。在遥感领域，此技术通常搭配各类机器学习模型以加强数据预处理和提高模型精度[34-35]。本研究将 20 个植被指数和 8 个纹理特征作为输入数据参与特征选择。同时，将结果与常见的皮尔逊相关系数法（Pearson correlation coefficient，PCC）和灰色关联度分析（Grey relational analysis，GRA）进行对比验证。

1.4　样本增强

为尽可能获得多样性样本集，解决由于试验条件限制造成的低样本量、低模型精度或过拟合问题，采用生成对抗网络（GAN）增强样本。GAN 以零和博弈作为其逻辑基础，通过无监督学习的方式获得数据分布，并以此生成符合该分布的数据集[36]。其由生成器网络（Generator nets，G）和判别器网络（Discriminator nets，D）构成，通过 G 利用输入的高斯噪声向量生成符合其学习到的“真实分布”数据，再使用 D 甄别输入的数据是来自真实样本还是由 G 生成的。如果输入为真实样本，则使其判定结果尽可能为 1，否则，使其判别结果尽可能为 0。随着生成器网络和判别器网络连续不断地进行交替训练，两者最终将达到纳什平衡，这也意味着此时的生成器网络拥有生成真实数据的能力[37]。G 通过随机采样生成数据 $G(z)$，其分布记作 $Pg(z)$，该分布应尽量逼近真实分布 $P_L(x)$。真实数据 P_L 和生成数据 $G(z)$ 输入到 D 中，输出值概率为 $D(G(z))$，其值越大表示生成数据为真实数据的概率越大。

1.5　模型构建与精度评价

1.5.1　模型构建

极端梯度提升（XGBoost）是一种高效、可扩展的梯度提升树框架，结合多个学习方法以实现比任何单独的学习应用程序更高的预测准确性[38]。作为一种基于决策树的集成机器学习方法，XGBoost 广泛应用于数据科学领域[39]。在求解损失函数极值时，采用牛顿法，将损失函数 Taylor 展开到二阶，并在损失函数中加入一个正则化项[40]。XGBoost 作为 Boosting 算法，能将数千个性能较差的预测模型反复合并在可接受的参数值范围内，组装成一个强大、高性能的模型，可实现反复迭代和逐步优化[41]。

此外，引入支持向量机（SVM）和随机森林（RF）作为 XGBoost 的对照，以最清晰、直观方式寻找最优估测模型，同时在每个估测模型中融入 GAN 样本扩增理论，旨在进一步提高模型反演精度。

1.5.2　模型精度评价

通过 11 个验证集样本实际值和预测值的拟合效果验证农田生态系统 CO_2 排放通量估测模型精度，模型决定系数 R^2 越接近 1，均方根误差（Root mean squared error，RMSE）和平均绝对误差（Mean absolute error，MAE）越小，表明预测值和实测值之间的偏差越小，模型反演效果越好。

2　结果与分析

2.1　相关性分析

2.1.1　不同光谱波段反射率相关性分析

将研究区番茄 CO_2 排放通量与同时段不同波段的光谱反射率进行相关性分析，如图 2（图中 *** 表示 $P<0.001$）所示。由图 2 可知，各波段光谱反射率与 CO_2 排放通量相关性极显著（$P<0.001$），相关系数从小到大依次为 NIR、Green、RedEdge、Blue、Red。为简化工作量，选择与 CO_2 排放通量相关性最强的近红外波段对其进行 8 种纹理特征的提取，并将其定义为：NIR－CON、NIR－ENT、NIR－VAR、NIR－MEA、NIR－HOM、NIR－DIS、NIR－SEM 和 NIR－COR。

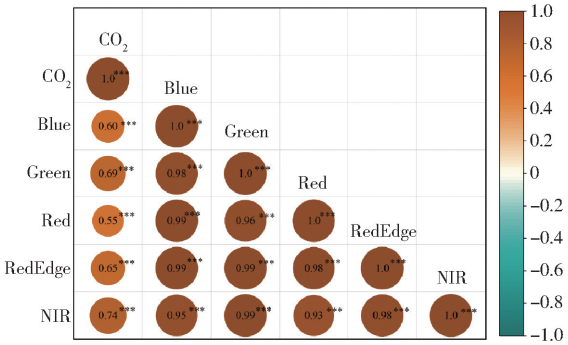


图 2　光谱波段反射率与 CO_2 排放通量相关性分析

Fig. 2　Correlation analysis of spectral band reflectance and CO_2 emission flux

2.1.2　特征变量筛选

分别采用 SVM－RFE、PCC 及 GRA 3 种方法对构建的 20 个光谱指数及 8 个纹理特征进行筛选，将筛选阈值均设置为 1.0，变量值越接近 1，表明与 CO_2 排放通量的相关性越高。将筛选结果根据变量值进行重要性排序，如表 4 所示。由表 4 可知，kNDVI 在每种筛选方法中重要性排序均为第 2 位，说明该植被指数与 CO_2 排放通量之间表现出较强的相关性。此外，与土壤相关的植被指数，如 SAVI、MSAVI、OSAVI 及 NDWI 经过 3 种筛选方法后均参与反演，且在 PCC 筛选重要性排序中排名靠前，说明土壤植被指数与 CO_2 排放通量呈显著线性相关，而纹理特征在每种筛选方式下的重要性排序均靠后。通过逐次增加筛选变量数量，发现 SVM－RFE 和 GRA 设置保留特征值为 20 个、PCC 为 15 个时反演精度最好，为避免相关性不强特征值对模型精度

表 4 基于不同筛选方法的特征变量重要性排序

Tab. 4 Feature variable importance ranking based on various screening methods

排序	SVM－RFE		PCC		GRA	
	特征变量	变量值	特征变量	变量值	特征变量	变量值
1	GCI	0.935 6	TCARI	0.818 1	MNLI	0.925 2
2	kNDVI	0.932 1	kNDVI	0.786 3	kNDVI	0.917 9
3	EVI	0.930 5	GCI	0.771 1	TCARI	0.915 6
4	OSAVI	0.926 5	NDWI	0.766 4	EVI	0.911 9
5	RDVI	0.924 8	GNDVI	0.761 5	RVI	0.906 8
6	CARI	0.924 1	NDCI	0.691 6	RDVI	0.901 6
7	RVI	0.922 5	RECI	0.690 2	NIR－ENT	0.900 4
8	RECI	0.918 5	MSR	0.687 3	CARI	0.897 1
9	MSAVI	0.917 1	SAVI	0.658 3	MSAVI	0.896 2
10	NDWI	0.916 4	OSAVI	0.658 2	NDWI	0.895 4
11	GNDVI	0.912 2	BNDVI	0.642 2	GNDVI	0.895 4
12	NDCI	0.911 5	MSAVI	0.633 5	NDRE	0.887 0
13	SAVI	0.908 5	RVI	0.633 0	BNDVI	0.886 9
14	NDVI	0.901 3	BNDVI	0.622 1	CARI	0.884 1
15	NRI	0.894 2	NDRE	0.578 3	SAVI	0.880 0
16	TCARI	0.892 5	RDVI	0.496 6	OSAVI	0.880 0
17	NIR－COR	0.882 1	NIR－ENT	0.444 7	NIR－MEA	0.875 5
18	NIR－DIS	0.881 9	NIR－SEC	0.444 3	NDCI	0.871 0
19	NIR－ENT	0.875 3	NIR－MEA	0.442 5	GCI	0.870 0
20	NIR－SEC	0.864 5	EVI	0.408 1	MSR	0.868 5

的影响，对 SVM－RFE 和 GRA 筛选设置 20 个特征变量，PCC 设置 15 个特征变量，分别作为估测模型的输入参数参与反演。

2.2 基于变量优选的农田 CO_2 排放通量估测模型

为探究农田生态系统 CO_2 排放通量的最佳估测模式，将 3 种筛选方法与 3 种机器学习算法结合构建估测模型，与未筛选特征变量构建的估测模型进行对比，通过分析建模集和验证集 R^2、RMSE 及 MAE 确定最佳估测模型组合，如表 5 所示。

由表 5 可知，CO_2 排放通量反演模型训练集的 R^2、RMSE 和 MAE 分别为 0.519～0.863、0.203～0.882 mg/(m²·h)、0.156～0.773 mg/(m²·h)，测试集的 R^2、RMSE 和 MAE 分别为 0.501～0.762、0.266～0.880 mg/(m²·h)、0.222～0.799 mg/(m²·h)。XGBoost、SVR 及 RF 3 种估测模型的 R_p^2 分别为 0.565～0.762、0.524～0.693、0.501～0.652，RMSEp 分别为 0.266～0.861 mg/(m²·h)、0.586～0.871 mg/(m²·h)、0.635～0.880 mg/(m²·h)，MAEp 分别为 0.222～0.793 mg/(m²·h)，0.452～0.799 mg/(m²·h)、0.405～0.793 mg/(m²·h)，说明 3 种机器学习算法均可实现 CO_2 排放通量反演，反演精度由高到低依次为 XGBoost、SVR、RF。此外，经分析可知，SVR－RFE 筛选效果优于 PCC 和 GRA。综合而言，3 种机器学习算法与 3 种筛选方法相结合的模式均可反演 CO_2 排放通量，其中 XGBoost－SVR－RFE 模型反演效果最优。

表 5 CO_2 排放通量估测模型精度

Tab. 5 Accuracy of CO_2 emission flux estimation model

机器学习模型	变量筛选	训练集			测试集		
		R_c^2	RMSEc/(mg·m⁻²·h⁻¹)	MAEc/(mg·m⁻²·h⁻¹)	R_p^2	RMSEp/(mg·m⁻²·h⁻¹)	MAEp/(mg·m⁻²·h⁻¹)
XGBoost	未筛选	0.647	0.758	0.688	0.565	0.861	0.793
	SVR－RFE	0.863	0.203	0.156	0.762	0.266	0.222
	PCC	0.854	0.286	0.162	0.753	0.371	0.346
	GRA	0.837	0.266	0.248	0.707	0.407	0.462
SVR	未筛选	0.568	0.866	0.773	0.524	0.871	0.799
	SVR－RFE	0.734	0.564	0.361	0.693	0.586	0.452
	PCC	0.678	0.564	0.402	0.624	0.630	0.525
	GRA	0.618	0.620	0.369	0.606	0.637	0.553
RF	未筛选	0.519	0.882	0.773	0.501	0.880	0.793
	SVR－RFE	0.727	0.537	0.433	0.614	0.635	0.405
	PCC	0.621	0.555	0.453	0.581	0.701	0.553
	GRA	0.723	0.495	0.394	0.652	0.646	0.443

基于以上 3 种机器学习算法与 3 种筛选方法相结合的模型反演结果，绘制测试集实测值与预测值线性拟合曲线，如图 3 所示。各反演模型预测结果的真实值大部分位于 95% 置信区间，表明反演模型的估算具有较高的统计可靠性和准确性。从不同机器学习算法来看，XGBoost 模型预测值与真实值间拟合效果最优，其 R^2 为 0.72～0.87，从不同筛选方法来看，SVR－RFE 筛选后的变量特征作为输入参数的模型预测值与真实值间线性拟合效果最优，R^2 为 0.81～0.87，其中 XGBoost－SVR－RFE 相结合的反演模型，线性拟合效果最优，其 R^2 为 0.87，进一步

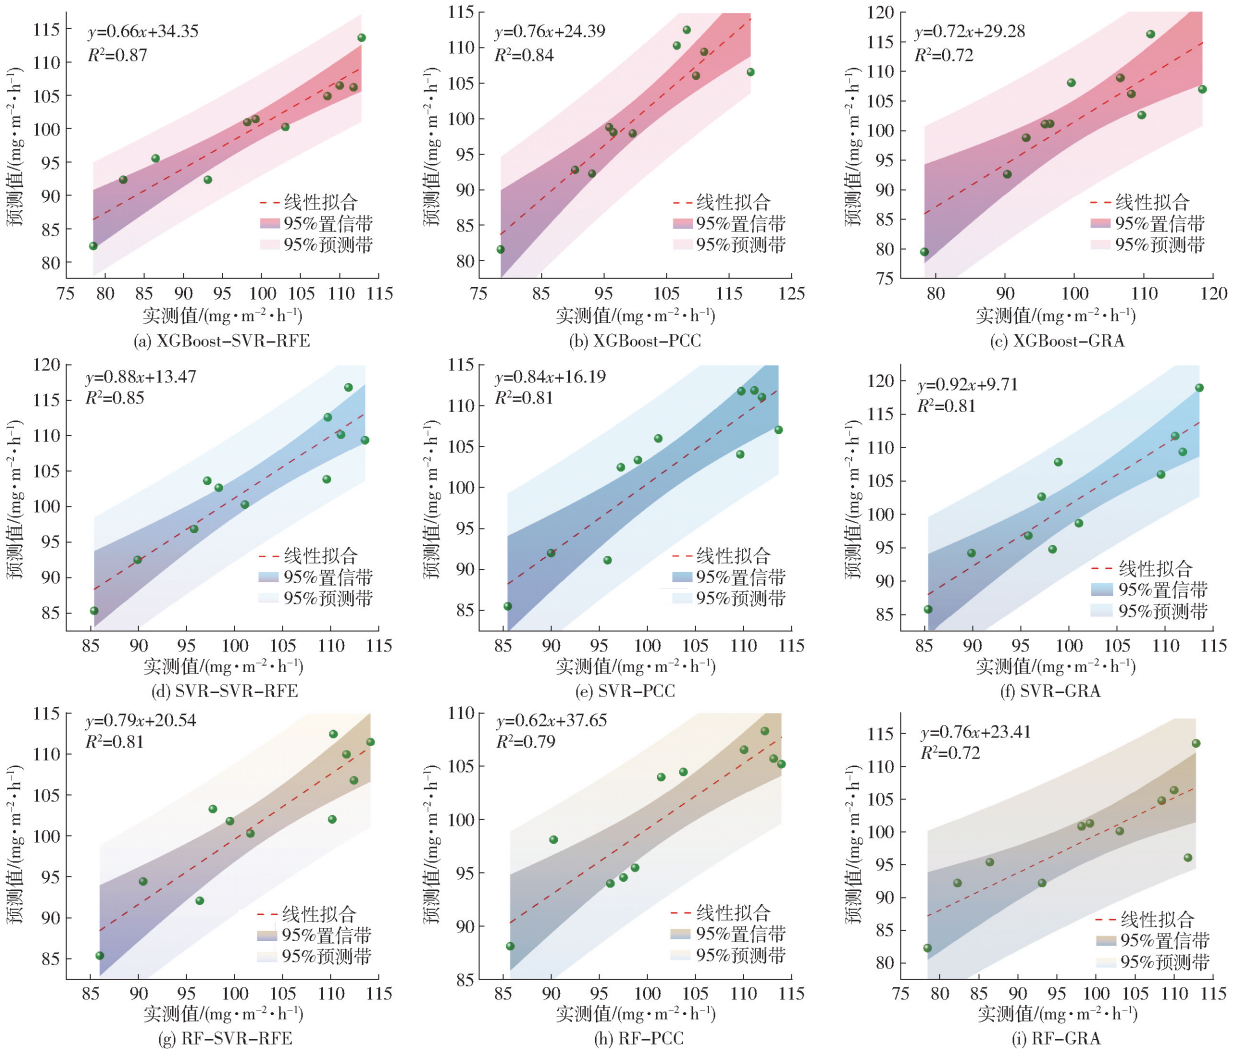


图 3　CO_2 排放通量实测值与预测值线性拟合曲线

Fig. 3　Linear fitting effect plot of measured and predicted values of CO_2 emission flux

验证了该模型可用于 CO_2 排放通量反演。

2.3　融合样本扩增反演模型评价

为进一步改善模型泛化能力、降低模型过拟合风险，并提高反演对 CO_2 排放通量的预测准确性，采用 GAN 进行数据增强。为保证生成数据的稳定性，利用 3 种筛选方法筛选特征变量用于样本扩增，再利用 3 种机器学习算法对扩充后的数据进行学习，继续完成扩增样本与原始数据融合的反演计算，反演结果如图 4 所示。结果表明，使用生成对抗网络扩增样本后，模型预测能力得到一定提升，生成样本在一定程度上优化了预测模型的泛化能力。

9 种组合反演模型在训练集和测试集的 R^2 分别提高 5.68% ~ 55.89% 和 7.7% ~ 44.92%，RMSE 分别减小 15.68% ~ 59.73% 和 5.21% ~ 47.55%，MAE 分别减小 13.59% ~ 71.01% 和 23.38% ~ 47.76%。其中，RF 机器学习算法对样本扩增较为敏感，测试集 R^2 提高 27.15% ~ 44.92%，RMSE 减小 37.92% ~ 43.89%，MAE 减小 33.99% ~ 47.64%。但整体而言，融合样本扩增的 9 种耦合模型中，XGBoost - SVR - RFE 反演模型鲁棒性最好（R_p^2/R_c^2 =0.977），其次为 SVR - SVR - RFE（R_p^2/R_c^2 =

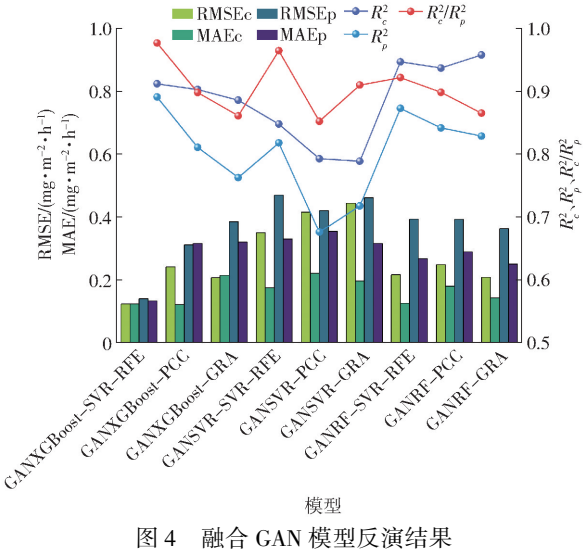


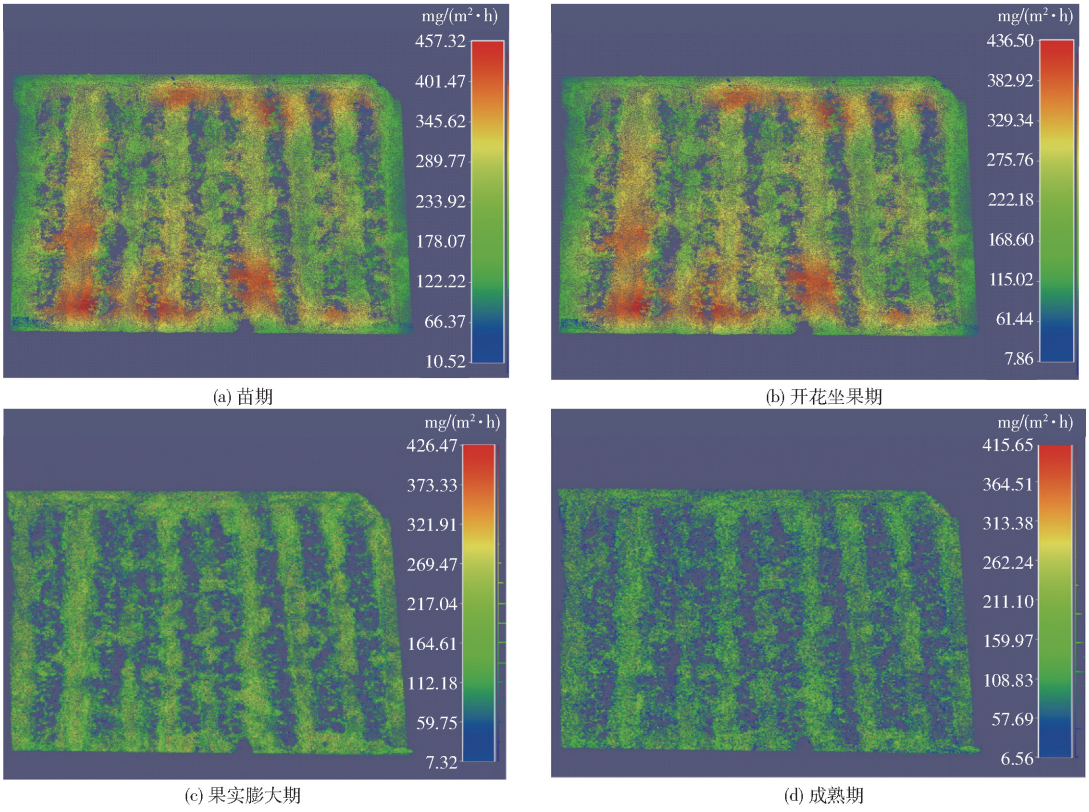
图 4　融合 GAN 模型反演结果

Fig. 4　Inversion results of model fused with sample augmentation

0.964),而 SVR - RCC 最差(R_p^2/R_c^2 = 0.852)。此外,所有模型的 R_p^2/R_c^2 均高于 0.85。这再次证明,9 种反演模型组合中融入样本扩增可有效提高模型预测准确性和鲁棒性。

2.4 CO_2 排放通量时空分布特征

基于最优反演模型估算结果,绘制全生育期番茄 CO_2 排放通量空间分布图(图 5)。从图 5 可以看出,不同生育期番茄 CO_2 排放通量存在显著差异,由于本研究阶段处于秋季栽培期,随着生长阶段推进,CO_2 排放通量随着温度降低总体呈减小趋势。苗期番茄 CO_2 排放通量在 151 ~ 415.65 mg/(m²·h)之间波动,开花坐果期番茄 CO_2 排放通量在 57.31 ~ 297 mg/(m²·h)之间波动,果实膨大期番茄 CO_2 排放通量在 42.73 ~ 168 mg/(m²·h)之间波动,成熟期番茄 CO_2 排放通量在 6.56 ~ 87.72 mg/m²·h 之间波动,且反演值与实测值波动趋势及范围极为相符。



(a) 苗期 (b) 开花坐果期

(c) 果实膨大期 (d) 成熟期

图 5 全生育期 CO_2 排放通量时空分布图

Fig. 5 Dynamic change diagrams of CO_2 emission flux during whole growth period

3 讨论

农田生态系统 CO_2 排放受气象条件、农业管理措施和季节性变化的综合影响,是一个动态变化过程[42-43]。为掌握农田碳汇及其深层机制并确定减排措施,对 CO_2 排放通量进行持续性精准估测尤为重要[44]。本研究基于多光谱遥感影像中的光谱反射率,构建 20 个与作物性状和土壤性质相关的植被指数,并提取与 CO_2 排放通量相关性较高的近红外波段对应的 8 种纹理特征。通过建立植被指数和纹理特征与地面实测数据间的拟合关系,采用特征变量筛选和机器学习算法构建了农田生态系统 CO_2 排放通量反演模型,同时,引入 GAN 扩增样本集,进一步提升模型预测性能和泛化能力,为动态化和科学性监测农田生态系统 CO_2 排放通量提供了全新的技术手段。

本研究通过皮尔逊相关性筛选,发现与 CO_2 排放通量相关性最高的波段为 NIR,这是因为 CO_2 在近红外波段通常表现为轻微的吸收特征[45]。然而,近红外波段对应的 8 种纹理特征与 CO_2 排放通量的相关性并不高,原因可能是因为受到样本集数量的影响,当样本数量较少时很难发现参数之间的相关性[46]。但通过 SVR - RFE 筛选后,具有相对较多纹理特征与植被指数相结合的特征变量组作为模型输入参数参与反演,效果较为理想。YANG 等[24]也发现光谱反射率对应的植被指数与纹理特结合能有效提高反演模型估测精度,这与本研究结果一致。此外,通过 5 个波段光谱反射率构建的植被指数中,kNDVI 与 CO_2 排放通量相关性最高,在 3 种变量筛选后的重要性排序中均为第 2 位,这是因为与其他植被指数相比,基于核函数的 kNDVI 可以整合不同尺度的信息,具有更强的空间分辨率[47]。它适用于

各种研究和监测需求，对植被的敏感性较高，并更好地捕捉植被特征。同时，减少了土地利用和植被对遥感数据的影响，以更准确地反映植被状况。GUSTAU 等[48]提出，kNDVI 在总初级生产力监测准确性和太阳诱导叶绿素荧光计算中的相关系数为 0.68，高于相关系数为 0.59 的 NDVI，本研究中 kNDVI 与 CO_2 排放通量的相关性也明显高于 NDVI，与其结果类似，进一步证明了 kNDVI 在 CO_2 排放通量反演中的可行性和优越性。

机器学习算法需要大量实测样本，而实际农田环境中采用静态箱气相色谱法采集 CO_2 排放通量样本成本较高，但当训练集样本缺失时，容易出现过拟合或陷入局部最优解等现象[49]。为解决以上问题，本研究在 9 种反演模型组合中融入 GAN 进行样本扩增，各反演模型精度均有提高。其中，GANRF 机器学习算法对样本扩增较为敏感，而 GANXGBoost－SVR－RFE 反演模型鲁棒性最好，其 R_p^2/R_c^2 高达 0.977。李佳怿等[50]在研究棉田土壤含盐量精准反演模型时将光谱技术与样本增广技术相结合，其 EPO－DCGAN－RNet 建模集 R^2 和均方根误差分别为 0.942、115.420 μS/cm，验证集 R^2 和均方根误差分别为 0.910 和 136.472 μS/cm。以上研究结果与本研究结果一致，再次说明样本扩增方法能有效降低深度学习算法对样本量的依赖性，得到更优的模型预测性能。

本研究基于多光谱遥感影像数据融合 GAN 构建农田生态系统 CO_2 排放通量反演模型，取得较好的反演效果。然而气候条件、生长季节、灌溉施肥、土壤环境及作物类型等均是影响农田生态系统 CO_2 排放通量反演精度的关键因素，探索不同作物类型及多因素交互对 CO_2 排放通量反演模型适用性和精准度的影响将是未来主要研究方向。

4　结论

（1）3 种反演模型均可实现农田生态系统 CO_2 排放通量的快速反演，反演精度由高到低依次为 XGBoost、SVM、RF，其中，通过变量筛选的纹理特征和植被指数作为反演模型输入参数，可有效提高模型反演精度。从不同机器学习算法来看，XGBoost 模型反演效果最优；从不同筛选方法来看，SVR－RFE 筛选后的变量特征作为输入参数的模型反演效果最优，其中 XGBoost－SVR－RFE 相结合的反演模型效果最优，其测试集 R_p^2 最大（0.762），RMSEp（0.266 mg/（m^2·h））和 MAEp（0.222 mg（m^2·h））均最小。

（2）在 9 种反演模型中融入生成对抗网络（GAN）进行样本扩增，提高了各组合模型测试集的 R_p^2，减小了 RESEp 和 MAEp，且所有模型测试集的 R_p^2/R_c^2 均高于 0.85，其中 GANXGBoost－SVR－RFE 反演模型的鲁棒性最好，GANSVR－SVR－RFE 次之。

（3）基于 GANXGBoost－SVR－RFE 最优反演模型组合的估测数据，绘制番茄全生育期 CO_2 排放通量时空分布图，结果表明，秋季栽培期番茄 CO_2 排放通量随着温度的降低整体呈递减趋势，在苗期和开花坐果期 CO_2 排放通量较高，果实膨大期、成熟期逐步下降，全生育期 CO_2 排放通量在 6.56～415.65 mg/（m^2·h）之间波动，且反演值与实测值变化趋势和波动范围极为相符。

参　考　文　献

[1] WANG Y, TAO F, YIN L, et al. Spatiotemporal changes in greenhouse gas emissions and soil organic carbon sequestration for major cropping systems across China and their drivers over the past two decades[J]. Science of the Total Environment, 2022, 833:155087.

[2] WANG R, PAN Z, LIU Y, et al. Full straw incorporation into a calcareous soil increased N_2O emission despite more N_2O being reduced to N_2 in the winter crop season[J]. Agriculture, Ecosystems & Environment, 2022, 335:108007.

[3] BHATTACHARYYA S S, LEITE F F G D, FRANCE C L, et al. Soil carbon sequestration, greenhouse gas emissions, and water pollution under different tillage practices[J]. Science of the Total Environment, 2022, 826:154161.

[4] WANG J, WU Q, HE Y, et al. Maximizing the carbon sink function of paddy systems in China with machine learning[J]. Science of the Total Environment, 2024, 909:168542.

[5] TAO F, LI Y, CHEN Y, et al. Daily, seasonal and inter-annual variations in CO_2 fluxes and carbon budget in a winter-wheat and summer-maize rotation system in the North China Plain[J]. Agricultural and Forest Meteorology, 2022, 324: 109098.

[6] 李思恩，康绍忠，朱治林，等. 应用涡度相关技术监测地表蒸发蒸腾量的研究进展[J]. 中国农业科学，2008，41(9)：2720－2726.
LI Sien, KANG Shaozhong, ZHU Zhilin, et al. Research progress in the application of eddy covariance technology to monitor surface evapotranspiration [J]. Scientia Agricultura Sinica, 2008, 41(9):2720－2726. (in Chinese)

[7] 陈世苹，游翠海，胡中民，等. 涡度相关技术及其在陆地生态系统通量研究中的应用[J]. 植物生态学报，2020，44(4)：291－304.
CHEN Shiping, YOU Cuihai, HU Zhongmin, et al. Vorticity correlation technique and its application in terrestrial ecosystem flux research[J]. Chinese Journal of Plant Ecology, 2020,44(4):291－304. (in Chinese)

[8] 李成，王让会，李兆哲，等. 冬小麦-夏玉米农田蒸散与 CO_2 净交换特征及影响因素[J]. 农业机械学报，2022，53(1)：

331 – 339.
LI Cheng, WANG Ranghui, LI Zhaozhe, et al. Net exchange characteristics and influencing factors of evapotranspiration and CO_2 in winter wheat – summer maize field[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(1): 331 – 339. (in Chinese)
[9] LIU C, LIU Y, GAO W, et al. The effect of chamber placement site on N_2O emission under different fertilizer regimes from maize field[J]. Agriculture, Ecosystems & Environment, 2023, 341: 108210.
[10] LIANG L, GENG D, YAN J, et al. Remote sensing estimation and spatiotemporal pattern analysis of terrestrial net ecosystem productivity in China[J]. Remote Sensing, 2022, 14(8): 1902.
[11] 于贵瑞,方华军,伏玉玲,等. 区域尺度陆地生态系统碳收支及其循环过程研究进展[J]. 生态学报,2011,31(19):5449 – 5459.
YU Guirui, FANG Huajun, FU Yuling, et al. Advances in carbon budget and cycle processes of terrestrial ecosystems at regional scale[J]. Acta Ecologica Sinica, 2011, 31(19): 5449 – 5459. (in Chinese)
[12] XIAO J, CHEVALLIER F, GOMEZ C, et al. Remote sensing of the terrestrial carbon cycle: a review of advances over 50 years[J]. Remote sensing of Environment, 2019, 233: 111383.
[13] 陈俊英, 项茹, 贺玉洁, 等. 基于 Landsat8 与 Sentinel – 1 遥感图像融合的土壤含水率反演模型[J]. 农业机械学报, 2024, 55(2): 208 – 219.
CHEN Junying, XIANG Ru, HE Yujie, et al. Soil moisture inversion model based on Landsat8 and Sentinel – 1 remote sensing image fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 208 – 219. (in Chinese)
[14] 赵文举,马芳芳,马宏,等. 基于无人机多光谱影像的土壤盐分反演模型[J]. 农业工程学报,2022,38(24):93 – 101.
ZHAO Wenju, MA Fangfang, MA Hong, et al. Inversion model of soil salinity based on multispectral images from UAVs[J]. Transactions of the CSAE, 2022, 38(24): 93 – 101. (in Chinese)
[15] ZHAO W, ZHOU C, ZHOU C, et al. Soil salinity inversion model of oasis in arid area based on UAV multispectral remote sensing[J]. Remote Sensing, 2022, 14(8): 1804.
[16] LIN S, HAO D, ZHENG Y, et al. Multi-site assessment of the potential of fine resolution red-edge vegetation indices for estimating gross primary production[J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 113: 102978.
[17] ZHANG B, FAN G, ZHANG T. Simulation and analysis of the CO_2 range-resolved differential absorption LiDAR system at 2 μm[J]. Scientific Reports, 2024, 14(1): 17248.
[18] HILL A C, VÁZQUEZ-LULE A, VARGAS R. Linking vegetation spectral reflectance with ecosystem carbon phenology in a temperate salt marsh[J]. Agricultural and Forest Meteorology, 2021, 307: 108481.
[19] YU W, CHEN S, YANG W, et al. Spatial mapping of soil CO_2 flux in the Yellow River Delta Farmland of China using multi-source optical remote sensing data[J]. Agriculture, 2024, 14(9): 1453.
[20] LI C, HAN W, PENG M. Improving the spatial and temporal estimating of daytime variation in maize net primary production using unmanned aerial vehicle-based remote sensing [J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 103: 102467.
[21] LU R, ZHANG P, FU Z, et al. Improving the spatial and temporal estimation of ecosystem respiration using multi-source data and machine learning methods in a rainfed winter wheat cropland[J]. Science of the Total Environment, 2023, 871: 161967.
[22] 贾丹,陈鹏飞. 低空无人机影像分辨率对冬小麦氮浓度反演的影响[J]. 农业机械学报,2020,51(7):164 – 169.
JIA Dan, CHEN Pingfei. Effect of low-altitude UAV image resolution on inversion of winter wheat nitrogen concentration[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 164 – 169. (in Chinese)
[23] ZHANG X, ZHANG K, SUN Y, et al. Combining spectral and texture features of UAS-based multispectral images for maize leaf area index estimation[J]. Remote Sensing, 2022, 14(2): 331.
[24] YANG K, GONG Y, FANG S, et al. Combining spectral and texture features of UAV images for the remote estimation of rice LAI throughout the entire growing season[J]. Remote Sensing, 2021, 13(15): 3001.
[25] 谢坪良,张智韬,巴亚岚,等. 基于无人机图像纹理和表型参数的夏玉米水分胁迫诊断[J]. 农业工程学报,2024, 40(10): 136 – 146.
XIE Pengliang, ZHANG Zhitao, BA Yalan, et al. Water stress diagnosis of summer maize based on UAV image texture and phenotypic parameters[J]. Transactions of the CSAE, 2024, 40(10): 136 – 146. (in Chinese)
[26] FAN J, YAO Y, TANG Q, et al. A hybrid index for monitoring burned vegetation by combining image texture features with vegetation indices[J]. Remote Sensing, 2024, 16(9): 1539.
[27] AGGARWAL A, MITTAL M, BATTINENI G. Generative adversarial network: an overview of theory and applications[J]. International Journal of Information Management Data Insights, 2021, 1(1): 100004.
[28] 詹燕,胡蝶,汤洪涛,等. 基于改进生成对抗网络的图像数据增强方法[J]. 浙江大学学报(工学版),2023,57(10): 1998 – 2010.
ZHAN Yan, HU Die, TANG Hongtao, et al. An image data enhancement method based on improved generative adversarial networks[J]. Journal of Zhejiang University(Engineering Science), 2023, 57(10): 1998 – 2010. (in Chinese)
[29] 杨森,张新寿,王振民,等. 基于近红外光谱和深度学习数据增强的大米品种检测[J]. 农业工程学报,2023,39(19): 250 – 257.
YANG Sen, ZHANG Xinying, WANG Zhenmin, et al. Detection of rice varieties based on near-infrared spectroscopy and deep learning data enhancement[J]. Transactions of the CSAE, 2023, 39(19): 250 – 257. (in Chinese)
[30] 王志强, 于雪莹, 杨晓婧, 等. 基于 WGAN 和 MCA – MobileNet 的番茄叶片病害识别[J]. 农业机械学报, 2023, 54(5): 244 – 252.

WANG Zhiqiang, YU Xueying, YANG Xiaojing, et al. Identification of tomato leaf diseases based on WGAN and MCA - MobileNet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5):244 - 252. (in Chinese)
[31] 何少芳,沈陆明,谢红霞. 生成式对抗网络的土壤有机质高光谱估测模型[J]. 光谱学与光谱分析,2021,41(6):1905 - 1911.
HE Shaofang, SHEN Luming, XIE Hongxia. Hyperspectral estimation model of soil organic matter based on generative adversarial networks[J]. Spectroscopy and Spectral Analysis, 2021,41(6):1905 - 1911. (in Chinese)
[32] 韩翔,李玉强,高昂,等. 基于改进生成对抗网络的甜樱桃数据增强方法[J]. 农业机械学报,2024,55(10):252 - 262.
HAN Xiang, LI Yuqiang, GAO Ang, et al. Data augmentation method for sweet cherries based on improved generative adversarial network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(10):252 - 262. (in Chinese)
[33] 甄佳宁,蒋侠朋,赵德梅,等. 利用 Sentinel - 2 影像超分辨率重建的红树林冠层氮含量反演[J]. 遥感学报,2022,26(6):1206 - 1219.
ZHEN Jianing, JIANG Xiapeng, ZHAO Demei, et al. Inversion of mangrove canopy nitrogen content using Sentinel - 2 image super-resolution reconstruction[J]. National Remote Sensing Bulletin, 2022, 26(6):1206 - 1219. (in Chinese)
[34] HANKUI Z, BO H, LE Y. Kernel function in SVM - RFE based hyperspectral data band selection[J]. Remote Sensing Technology and Application, 2014, 28(5):747 - 752.
[35] CHEN L, XING M, HE B, et al. Estimating soil moisture over winter wheat fields during growing season using machine-learning methods[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14:3706 - 3718.
[36] CHENG L, YU T. A new generation of AI: a review and perspective on machine learning technologies applied to smart energy and electric power systems[J]. International Journal of Energy Research, 2019, 43(6):1928 - 1973.
[37] SAXENA D, CAO J. Generative adversarial networks (GANs) challenges, solutions, and future directions[J]. ACM Computing Surveys (CSUR), 2021, 54(3):1 - 42.
[38] 晏红波,梁雨豪,卢献健,等. 基于 XGBoost 融合多维度时空数据的干旱遥感建模及应用研究[J]. 地球信息科学学报,2024,26(6):1531 - 1546.
YAN Hongbo, LIANG Yuhao, LU Xianjian, et al. Research on drought remote sensing modeling and application based on XGBoost fusion multi-dimensional spatio-temporal data[J]. Journal of Geo-information Science, 2024, 26(6):1531 - 1546. (in Chinese)
[39] 孙钊,谢运鸿,王宝莹,等. 基于无人机多维数据集的森林地上生物量估测模型研究[J]. 农业机械学报,2024,55(6):186 - 195,236.
SUN Zhao, XIE Yunhong, WANG Baoying, et al. Development of forest above ground biomass estimation model based on multidimensional dataset of UAV[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(6):186 - 195,236. (in Chinese)
[40] 于跃, 于海业, 李晓凯, 等. 优化光谱指数建立水稻叶片 SPAD 的高光谱反演模型[J]. 光谱学与光谱分析, 2022, 42(4):1092 - 1097.
YU Yue, YU Haiye, LI Xiaokai, et al. Hyperspectral inversion model for SPAD of rice leaves based on optimized spectral index[J]. Spectroscopy and Spectral Analysis, 2022, 42(4):1092 - 1097. (in Chinese)
[41] NGUYEN H, NUYEN N M, CAO M T, et al. Prediction of long-term deflections of reinforced-concrete members using a novel swarm optimized extreme gradient boosting machine[J]. Engineering with Computers, 2022, 38(2):1255 - 1267.
[42] ZHONG Z, WANG X, YANG C, et al. Contrasting carbon cycle responses of semiarid abandoned farmland to simulated warmer-drier and warmer-wetter climates[J]. Science of the Total Environment, 2024, 948:174693.
[43] BHATTACHARYYAA S S, LEITE F F G D, FRANCE C L, et al. Soil carbon sequestration, greenhouse gas emissions, and water pollution under different tillage practices[J]. Science of the Total Environment, 2022, 826:154161.
[44] RUEHR S, KEENAN T F, WILLIAMS C, et al. Evidence and attribution of the enhanced land carbon sink[J]. Nature Reviews Earth & Environment, 2023, 4(8):518 - 534.
[45] 杨慧,范怀伟,徐晓,等. 能源资源开发区域大气 CO_2 时空变化及影响因素分析[J]. 地学前缘,2024,31(4):147 - 164.
YANG Hui, FAN Huaiwei, XU Xiao, et al. Analysis of the temporal and spatial variation of atmospheric CO_2 and its influencing factors in the energy resource development area[J]. Earth Science Frontiers, 2024,31(4):147 - 164. (in Chinese)
[46] DU L, GUO X, SUN W, et al. False discovery rate control under general dependence by symmetrized data aggregation[J]. Journal of the American Statistical Association, 2023, 118(541):607 - 621.
[47] WANG Q, MORENO-MARTÍNEZ Á, MUÑOZ-MARÍ J, et al. Estimation of vegetation traits with kernel NDVI[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 195:408 - 417.
[48] GUSTAU C V, MANUEL C T, ÁLVARO M M, et al. A unified vegetation index for quantifying the terrestrial biosphere[J]. Science Advances, 2021, 7(9):7447.
[49] HELMER M, WARRINGTON S, MOHAMMADI-NEJAD A R, et al. On the stability of canonical correlation analysis and partial least squares with application to brain-behavior associations[J]. Communications Biology, 2024, 7(1):217.
[50] 李佳怿,张翼腾,周宝闯,等. 光谱技术结合水分校正与样本增广的棉田土壤盐分精准反演[J]. 农业工程学报,2024,40(1):171 - 181.
LI Jiayi, ZHANG Yiteng, ZHOU Baochuang, et al. Accurate inversion of soil salinity in cotton field by spectral technology combined with water correction and sample augmentation[J]. Transactions of the CSAE, 2024, 40(1):171 - 181. (in Chinese)