

基于可解释性深度学习的遥感玉米估产研究

解毅^{1,2} 黄家一^{1,2} 荀兰^{1,2} 史姝璟^{1,2}

(1. 山西师范大学地理科学学院, 太原 030031; 2. 山西师范大学资源与环境信息化院士工作站, 太原 030031)

摘要: 准确获取区域玉米产量对制定农业政策和促进国民经济发展具有重要意义。长短期记忆网络 (Long short-term memory, LSTM) 和 Transformer 模型具有处理时序遥感数据优势, 广泛应用于农作物产量估测。为兼顾 LSTM 对局部时序信息提取和 Transformer 对全局依赖的高效表达, 本文将遥感多参数和玉米单产作为输入数据, 分别构建 Transformer Encoder-LSTM (TFEL)、Transformer-LSTM (TFL) 和 Transformer 估产模型, 利用贝叶斯优化算法获取模型最佳隐藏层数量、学习率等超参数, 进而估测山西省太原盆地和上党盆地的玉米单产; 基于沙普利值的加性解释方法 (Shapley additive explanations, SHAP) 对混合深度学习模型进行全局事后可解释性分析。结果表明, 相较于 TFL 模型 ($R^2=0.62$, $P<0.01$, RMSE 为 974.14 kg/hm², MAPE 为 13.50%, NRMSE 为 15.14%) 和 Transformer 模型 ($R^2=0.53$, $P<0.01$, RMSE 为 1 028.76 kg/hm², MAPE 为 19.13%, NRMSE 为 16.16%), TFEL 模型估产精度较高 ($R^2=0.72$, $P<0.01$, RMSE 为 756.43 kg/hm², MAPE 为 10.58%, NRMSE 为 11.86%); 区域单产估测结果呈现南北部高产、东西部低产的空间特征, 估测产量与统计产量间呈现较好的线性相关性, 表明 TFEL 模型具有良好的鲁棒性和泛化能力; 在 TFEL 模型和 TFL 模型中, 双波段增强植被指数 (Two-band enhanced vegetation index, EVI2) 和绿色叶绿素植被指数 (Green chlorophyll vegetation index, GCVI) 特征重要性排序位于前列; 相较于 TFL 模型, TFEL 模型更有效聚焦关键遥感参数, 稳定识别和量化关键遥感参数对产量估测的贡献度, 具有较高产量估测精度。综上所述, 基于 Transformer 和 LSTM 的混合模型在玉米产量估测中展现良好的应用潜力, 可为区域尺度作物估产提供理论与方法参考。

关键词: 玉米; 遥感估产; 多参数; 深度学习; 可解释性

中图分类号: S513 文献标识码: A 文章编号: 1000-1298(2026)08-0193-10 OSID: 

Remote Sensing-based Maize Yield Estimation via Explainable Deep Learning

XIE Yi^{1,2} HUANG Jiayi^{1,2} XUN Lan^{1,2} SHI Shujing^{1,2}

(1. College of Geographical Sciences, Shanxi Normal University, Taiyuan 030031, China

2. Academician Workstation for Resource and Environmental Information Management, Shanxi Normal University, Taiyuan 030031, China)

Abstract: Accurate acquisition of maize yield information was recognized as critical for formulating agricultural policies and supporting national economic development. Long short-term memory (LSTM) networks and Transformer models were employed for crop yield estimation due to their respective strengths in processing remote sensing time series data. To balance LSTM's capacity for capturing local temporal dependencies with the Transformer's efficiency in modeling global relationships, multi-source remote sensing parameters and maize yield were used as inputs to construct three yield estimation models: Transformer Encoder-LSTM (TFEL), Transformer-LSTM (TFL), and pure Transformer. A Bayesian optimization algorithm was applied to determine the optimal combinations of hidden layer size, learning rate, and other hyperparameters. These models were then used to estimate county-scale maize yields in the Taiyuan and Shangdang Basins of Shanxi Province. The Shapley additive explanations (SHAP) method was employed to quantify the contribution of each remote sensing feature within the hybrid models. The TFEL model demonstrated superior estimation accuracy (R^2 was 0.72, $P<0.01$, RMSE was 756.43 kg/hm², MAPE was 10.58%, NRMSE was 11.86%) compared with both the TFL model (R^2 was 0.62, $P<0.01$, RMSE was 974.14 kg/hm², MAPE was 13.50%, NRMSE was 15.14%) and the Transformer model (R^2 was 0.53, $P<0.01$, RMSE was 1 028.76 kg/hm², MAPE was 19.13%,

收稿日期: 2025-07-06 修回日期: 2025-09-11

基金项目: 山西省基础 Research 计划(自由探索类)项目(202303021212157、202303021221149)

作者简介: 解毅(1989—), 男, 副教授, 主要从事定量遥感及其在农业的应用研究, E-mail: xieyi@sxnu.edu.cn

通信作者: 荀兰(1995—), 女, 副教授, 主要从事定量遥感及其在农业的应用研究, E-mail: xunlan@sxnu.edu.cn

NRMSE was 16.16%). The spatial distribution of estimated yields showed higher values in the northern and southern regions and lower values in the eastern and western regions. A strong linear relationship was observed between estimated and statistical yields, confirming the TFEL model’s generalization capability. Results revealed that the two-band enhanced vegetation index (EVI2) and green chlorophyll vegetation index (GCVI) provided the greatest contributions to maize yield estimation in both the TFEL and TFL frameworks. Compared with the TFL model, the TFEL model focused more effectively on key remote sensing parameters, and consistently identified and quantified their contributions to yield estimation, thereby achieving higher estimation accuracy. In summary, the hybrid model based on Transformer and LSTM showed promising application potential in maize yield estimation, which can provide theoretical and method reference for regional crop yield assessment.

Key words: maize; yield estimation by remote sensing; multiple parameters; deep learning; interpretability

0 引言

玉米是中国主要粮食作物之一,可靠的玉米产量估测有助于调整管理策略、降低收益风险、优化资源分配以提高作物生产力^[1]。准确获取玉米长势和产量信息对制定农业政策和保障国家粮食安全具有重要意义^[2]。

遥感技术具有大范围实时监测的优势,广泛应用于农作物估产领域。基于遥感作物估产模型可分为经验回归模型^[3]、作物机理模型^[4]、半机理模型^[5]以及机器/深度学习模型^[6]。作物机理模型受限于所需参数较多、计算量较大等特性^[7]。半机理模型结合了遥感多参数和部分作物生长过程,在保留机理模型的基本生理结构基础上对复杂参数进行简化,却也受限于简化模型结构可能导致估测精度降低。随着深度学习模型的发展,通过构建产量驱动因素和产量间的非线性回归模型备受关注。玉米长势和产量间的关系主要表现为非线性。玉米生长过程受到气候变化和土壤成分等多种因素影响,深度学习方法可通过多层次、多尺度的非线性变换和学习,在作物产量估测领域展现较大潜力^[8]。ZHANG等^[9]将特征优选后的植被指数输入长短期记忆网络(Long short-term memory, LSTM)模型以估测玉米产量,发现绿色叶绿素植被指数(Green chlorophyll vegetation index, GCVI)、地表温度、累计降水量和标准化降水指数可解释约70%的产量变化。面对训练步长的增加, LSTM模型仍存在梯度爆炸、计算量大等问题。Transformer模型则摒弃了循环结构,是一种基于多头注意力机制的编码器-解码器框架,能更好地捕获不同数据之间的长期依赖关系^[10]。ONOUFRIOU等^[11]构建基于Transformer的多时间线时序提取方法并应用于草莓产量估测,结果表明产量估测精度优于LSTM、门控循环单元等模型。Transformer和LSTM的混合模型可通过先后串联或并联方法,既可兼顾LSTM捕获时序局部

信息,又能融合Transformer对全局依赖的高效表达,进一步提高模型对非线性过程的拟合能力。XIONG等^[12]将Transformer和LSTM结合作为时间滤波器,在多层级深度学习估产模型中捕获作物生长信息,结果表明该架构的玉米产量估测精度优于随机森林、LSTM和Transformer模型。将LSTM模型与Transformer模型组合,可提高模型对时间序列遥感参数的处理能力,而在优化模型架构设计和提高产量估测精度层面,仍具备深入探索潜力。

在神经网络构建和训练时,涉及多个超参数取值与组合。若仅依靠人工经验确定参数值,模型性能不足以达到最佳。神经网络模型与贝叶斯优化、麻雀搜索、粒子群算法等超参数优化算法的结合展现潜力^[13]。TIAN等^[14]利用粒子群算法优化反向传播神经网络(Back propagation neural network, BPNN)超参数并用于冬小麦产量估测,发现非线性递减权重的粒子群算法可有效训练BPNN,获取较为全面的冬小麦生长信息。贝叶斯优化算法通过筛选超参数取值以实现损失函数最小化,进而提升模型估测精度。ZHANG等^[15]构建贝叶斯优化的CatBoost(Categorical boosting)模型以估测冬小麦产量,结果表明贝叶斯优化后的CatBoost模型具备较高冬小麦估产精度。优化算法和神经网络模型结合表现良好,但由于神经网络计算过程不透明且难以解释的底层机制,被称为“黑箱”模型,较差的可解释性限制了其在农业遥感领域的推广应用。目前,可解释性分为事前和事后可解释性,事前可解释性为自身具有可解释性的模型,如决策树、线性回归等^[16]。事后可解释性侧重于分析输入数据对输出目标的影响,辅助理解模型内部结构的决策过程和目标估测结果^[17]。基于沙普利值的加性解释方法(Shapley additive explanations, SHAP)为事后可解释性提供一种定量分析方案。GUO等^[18]基于麻雀搜索算法和LSTM-Transformer构建冬小麦估产模型,并采用SHAP方法评估遥感参数对产量估测的重要性。结果表明,光合

有效辐射吸收比率在产量估测中贡献度最高。SHAP 方法可提高深度学习估产模型的透明度和可信度,但仍需要更多基于作物生育期内估测因子对作物产量的可解释性研究,特别是混合模型中时序植被指数对作物产量响应机制的深入探索。

本文以山西省太原盆地和上党盆地为研究区,结合 Sentinel-2 遥感影像计算的多种植被指数、贝叶斯优化算法和深度学习模型,构建不同架构机制的玉米估产模型,并通过 SHAP 方法解释混合模型内部决策和目标结果。

1 研究区与数据

1.1 研究区概况

太原盆地和上党盆地位于山西省中部和东南部,西起文水县,东至昔阳县,北接寿阳县,南至壶关县,地理范围为 $111^{\circ}21' \sim 114^{\circ}08'E$, $35^{\circ}49' \sim 38^{\circ}08'N$ (图 1)。研究区属于北温带大陆性气候,四季分明,年平均气温为 $4.2 \sim 14.2^{\circ}C$,降水量为 $358 \sim 621\text{ mm}$,夏季降雨相对集中。两地区同属盆地地形、土地肥沃、气候条件相似,是山西省春玉米产量最大区域。因相似的地形和气候,使得研究区内春玉米物候期具有相对一致性。春玉米一般在 4 月下旬播种、5 月初出苗、6 月中旬拔节、9 月中下旬成熟。




图 1 研究区位置及玉米种植分布

Fig. 1 Location of study area and distribution of maize cultivation

1.2 数据来源与预处理

1.2.1 数据来源

Sentinel-2 卫星由 2A、2B 和 2C 3 颗卫星组成,三星互补,重访周期由单颗 10 d 缩短至 5 d。其搭载的多光谱传感器具有 13 个波段,光谱涵盖范围从可见光至短波红外^[19]。选取的 Sentinel-2 遥感影像来源于谷歌地球引擎 (Google Earth Engine, GEE) 提供经过大气校正的 2A 级产品。所采用的空间分辨率 30 m 的数字高程模型 (Digital elevation model, DEM) 来自地理空间数据云 (<https://www.gscloud.cn/>)。研究区各县玉米单产来自山西省统计年鉴

(<https://tjj.shanxi.gov.cn/>)。

根据 2001—2023 年中国玉米种植分布数据集^[20],获取研究区玉米种植分布 (图 1)。该产品为基于空间分辨率 30 m 归一化植被指数融合数据集,采用时间加权动态时间规划算法生成。其中,山西省玉米分类的用户精度和生产者精度分别为 83.62% 和 73.48%,总体分类精度为 87.27%。

1.2.2 植被指数计算

多种植被指数已被证明与玉米的各种生理和生长特性密切相关^[21],采用遥感多参数可综合利用不同植被指数在反映植被结构、叶绿素信息等方面的优势进行互补,可较为全面地表征玉米生长趋势。

所用遥感影像均在 GEE 平台获取,筛选云量低于 20% 影像,计算植被指数并按月尺度进行最大值合成。基于 Savitzky-Golay 滤波对数据进行平滑和去噪,以消除云、雨等气象因素影响。利用重采样方法统一植被指数和种植分布产品的空间分辨率,最终获得空间分辨率为 30 m、时间分辨率为 30 d 的归一化植被指数 (Normalized difference vegetation index, NDVI)^[22]、绿光归一化植被指数 (Green normalized difference vegetation index, GNDVI)^[23]、土壤调节植被指数 (Soil adjusted vegetation index, SAVI)^[24]、优化土壤调节植被指数 (Optimized soil adjusted vegetation index, OSAVI)^[25]、比值植被指数 (Simple ratio index, SR)^[26]、双波段增强植被指数 (Two-band enhanced vegetation index, EVI2)^[27]、绿色叶绿素植被指数 (Green chlorophyll vegetation index, GCVI)^[28]。

计算研究区各县 2019—2022 年玉米 5—9 月均值时间序列植被指数,将其与玉米单产结合构建估产样本。最终形成 28 县 4 年植被指数和玉米单产,共 112 组样本。

2 研究方法

2.1 模型构建

基于 Transformer 和 LSTM 模型构建 2 种混合模型,一种是仅使用 Transformer 编码器的 Transformer Encoder-LSTM (TFEL) 模型,另一种则使用完整 Transformer 编码器-解码器的 Transformer-LSTM (TFL) 模型。TFL 模型由输入层、4 个 Transformer Encoder 层、4 个 Transformer Decoder 层、1 个 LSTM 层、1 个池化层、2 个全连接层和输出层组合而成 (图 2a)。TFEL 模型则少了 4 个 Transformer Decoder 层,其余层级和 TFL 模型一致。为确保估产模型能够从训练数据中充分学习到生育期内植被指数的变化趋势和玉米产量间的非线性关系^[29],将

112 组估产样本按照比例 8:2 随机划分为训练集和测试集,时序遥感参数 $\{X_1, X_2, \dots, X_n\}$ 作为估产模型的输入,其中 X_n 表示玉米多遥感参数 ($NDVI_n$, $GNDVI_n$, $SAVI_n$, $OSAVI_n$, SR_n , $EVI2_n$, $GCVI_n$) 组成的向

量。经过多次训练,确定优化器为 Adam、损失函数为均方根误差、批量大小为 32、训练步为 500,采用 L2 正则化提高模型泛化能力,其余超参数通过贝叶斯优化算法确定。




图 2 混合模型结构
Fig. 2 Hybrid model structure

2.2 LSTM 模型

LSTM 由若干个输入门、遗忘门和输出门组成的存储单元构成^[30](图 2b)。其中 h_{t-1} 为 LSTM 在 $t-1$ 时刻输出, x_t 为当前 t 时刻输入, h_t 为当前 t 时刻输出, C_t 和 C_{t-1} 分别为存储当前 t 时刻和 $t-1$ 时刻的细胞状态。 $\tilde{c}_t$ 为细胞状态; f_t 为遗忘门; v_t 为更新门; o_t 为输出门; σ 为激活函数; $\tanh(\cdot)$ 为双曲正切函数。

2.3 Transformer 模型

Transformer 模型是一种处理自然语言中的端到端深度学习框架,其主要由位置编码、多头注意力机制、残差连接和层归一化等组成的编码器-解码器结构^[31](图 2c、2d)。自注意力机制是 Transformer 模型的核心部分之一,其能够在输入时序数据中捕获全局信息并绘制输入遥感参数与估测产量间的全局依赖^[32]。通过得到输入向量对应的查询矩阵、键矩阵和值矩阵,根据查询矩阵和键矩阵之间的相关性得分,并将得分和值矩阵进行加权求和得到输出结果。

多头注意力机制由多个自注意力机制组成,使得该模型可应对不同层空间的信息^[33]。因此,Transformer 模型可实现获取时序数据的全局信息。

仅使用自注意力机制无法捕获输入序列的顺序信息,因此加入位置编码,计算式为

$$PE(pos, 2i) = \sin(pos/1\,000^{2i/d}) \tag{1}$$

$$PE(pos, 2i + 1) = \cos(pos/1\,000^{2i/d}) \tag{2}$$

式中 $PE(\cdot)$ ——位置编码
 pos ——植被指数位置
 d ——植被指数维度
 i ——植被指数第 i 个维度

2.4 贝叶斯优化算法

贝叶斯优化 (Bayesian optimization, BO) 是一种全局优化超参数算法,具有收敛快、扩增性强等优点,核心部分是概率代理模型和采集函数^[34],结构如图 3 所示。在已知有限样本点前提下,通过构造黑箱函数输出后验概率选择函数的最优值^[35]。采用贝叶斯优化算法迭代 30 次搜索、评估并确定深度学习模型的超参数取值(表 1)。

2.5 SHAP 方法

SHAP 是一种基于博弈论思想的事后可解释方法,优势在于能为深度学习模型提供较为一致的特征归因方法。SHAP 通过计算输入参数的边际贡献衡量各参数在深度学习模型中的影响,并计算 Shapley 值定量地评估输入参数对估测结果的贡献




图 3 贝叶斯优化算法
Fig. 3 Bayesian optimization

表 1 不同模型超参数

Tab. 1 Hyperparameters for different models			
模型	超参数	搜索范围	超参数取值
TFEL	隐藏层数量	1 ~ 3	2
	池化率	0 ~ 0.5	0.065 4
	学习率	0.000 1 ~ 0.01	0.000 3
	注意力头数	1 ~ 2	1
	隐藏层单元数量	32 ~ 256	128
TFL	隐藏层数量	1 ~ 3	3
	池化率	0 ~ 0.5	0.086 6
	学习率	0.000 1 ~ 0.01	0.000 6
	注意力头数	1 ~ 2	1
	隐藏层单元数量	32 ~ 256	169
Transformer	注意力头数	1 ~ 2	1
	池化率	0 ~ 0.5	0.276 4
	学习率	0.000 1 ~ 0.01	0.000 6

度^[36]。可解释性输出结果由各输入参数的 Shapley 值和所有样本估测变量均值组成,基于加权特征归因方法可定义为

$$g(z)=\phi_0+\sum_{i=1}^M\phi_iz_i$$

(3)

其中

$$\phi_i=\sum_{S\subseteq F\backslash\{i\}}\frac{|S|!(|F|-|S|-1)!}{|F|!}[f(S\cup\{i\})-f(S)]$$

(4)

式中 $g(\cdot)$ ——解释模型

ϕ_0 ——所有样本估测值均值

M ——输入变量数量

z_i ——第 i 个输入参数

ϕ_i ——第 i 个输入参数的 Shapley 值

F ——所有输入参数集合

S —— F 中不包含参数 i 的子集

f ——要解释的产量估测模型

$f(S)$ ——子集 S 估测结果

2.6 模型精度评价

为评价不同模型的估测产量精度,采用决定系数(Coefficient of determination, R^2)、平均绝对百分比误差(Mean absolute percentage error, MAPE)、均方根误差(Root mean square error, RMSE)和归一化均方根误差(Normalized root mean square error, NRMSE)评价模型估产精度^[37]。其中, R^2 越接近 1, 表示模型拟合精度越高; MAPE 越小, 表示模型准确度越高; RMSE 和 NRMSE 越小, 即模型估测产量与统计产量间差异越小, 估测精度越高。

在估产模型训练时每 50 次迭代输出损失值以评估 3 个模型拟合趋势。在进行县域尺度估产模型训练和精度对比后, 将研究区像元尺度时序植被指数输入最优估产模型, 基于最高精度估产模型估测研究区 2019—2022 年玉米产量, 并结合 DEM 和统计年鉴玉米产量数据, 对区域估产结果的时空分布特征及模型可靠性进行分析与验证。

3 结果与分析

3.1 不同估产模型精度对比

分别基于 TFL、TFEL 和 Transformer 算法构建 3 种估产模型, 并进行估产精度对比和分析(图 4)。与 TFL 模型 ($R^2 = 0.62$, $P < 0.01$, RMSE 为 974.14 kg/hm², NRMSE 为 15.14%, MAPE 为 13.50%) 和 Transformer 模型 ($R^2 = 0.53$, $P < 0.01$, RMSE 为 1 028.76 kg/hm², NRMSE 为 16.16%, MAPE 为 19.13%) 相比, TFEL 模型具有较高的估产精度 ($R^2 = 0.72$, $P < 0.01$, RMSE 为 756.43 kg/hm², NRMSE 为 11.86%, MAPE 为 10.58%)。相较于 TFL 模型, TFEL 模型 R^2 提升 0.10, RMSE 降低 217.71 kg/hm², NRMSE 降低 3.28 个百分点, MAPE 降低 2.92 个百分点。相较于 Transformer 估产模型, TFL 模型的 R^2 提升 0.09, RMSE 降低 54.62 kg/hm², NRMSE 降低 1.02 个百分点, MAPE 降低 5.63 个百分点。由此可见, 在贝叶斯优化超参数的基础上, Transformer 模型捕获时序遥感参数间的全局能力有限, 凭借 LSTM 结构特定的记忆单元和门控机制, 可进一步学习和捕获作物生长参数间的局部依赖关系。Transformer 解码器结构中增加自注意力机制, 其与 LSTM 的组合可有效处理小样本时序数据。面对现有数据量情况下, 增加过多结构或机制, 反而使得结构冗余, 从而增加训练复杂度和过拟合风险, 因而 TFL 模型估产精度低于 TFEL 模型。

由于 Transformer 编码器主要负责处理输入时序数据并生成上下文表示, 其用于学习和提取植被指数的长期依赖, 并处理复杂的全局信息, 而 LSTM




图 4 不同模型玉米单产估测精度

Fig. 4 Maize yield estimation accuracy of different models

凭借独特、循环的门控机制专注于捕获时序指数中局部细节和遥感参数间短期依赖,因此,二者可有机结合。Transformer 解码器主要为序列生成而设计,一般用于最终预测输出。相较编码器而言,解码器增加了掩码结构,掩码结构主要是为确保每个位置只能关注当前位置之前的植被指数,以避免泄露后续信息。时间序列植被指数估产本质为回归预测,为一种输入到输出的映射关系。对于小样本回归任务,复杂的解码器较为冗余,增加计算负担,使得模型估测精度下降。

在训练样本有限的前提下,估产结果存在产量高估或低估现象。如图 4 所示,玉米产量主要集中在 4 000 ~ 8 000 kg/hm² 之间。当玉米产量高于 8 000 kg/hm² 时,3 个模型均出现不同程度的产量低估,估产精度均有下降趋势。原因在于高产量样本的数据较少且分布不均匀,模型对该区间样本学习到的特征信息较少,从而出现高产低估。当玉米产量低于 4 000 kg/hm² 时,Transformer 模型样本点偏离较多,TFEL 模型和 TFL 模型则表现良好,表明 LSTM 机制可深入挖掘时序数据的局部信息。当玉米产量分布在 4 000 ~ 8 000 kg/hm² 区间时,Transformer 模型较为偏离 1:1 线;TFL 模型次之,TFEL 模型则表现良好。综上所述,TFEL 模型可较为有效地捕获输入参数和目标变量的局部和全局信息,从而提高模型估测精度。

3.2 不同估产模型损失值

基于测试集每 50 次迭代输出损失值评估 3 个模型拟合趋势(图 5)。结果表明,Transformer 模型损失值从迭代 50 次的 1.15 降到迭代 500 次的 0.18,降低 0.97;TFEL 模型损失值从迭代 50 次的 0.97 降到迭代 500 次的 0.11,降低 0.86;TFL 模型损失值从迭代 50 次的 1.29 降到迭代 500 次的 0.06,降低 1.23,最后阶段 3 个模型均达到相对较低的损失值。整体上损失值呈降低趋势,表明 Adam 优化器在训练过程可有效地调整模型权重和参数,以逐步提升模型对数据的拟合能力。贝叶斯优化算




图 5 不同模型训练损失值变化曲线

Fig. 5 Training loss curves for different models

法通过高斯过程和采集函数在迭代过程对具备“潜力”超参数组合进行评估,在多次迭代后,采集到较为合适超参数组合使得估产深度学习模型最终收敛。在同样的迭代次数下,Transformer 模型损失值最终稳定于 0.2 左右。在此基础上,引入 LSTM 层的混合模型,损失值下降速度提升。当迭代次数达到 300 后,损失值最终稳定于 0.1 左右。LSTM 层能进一步增强模型对时间序列数据的建模能力,最后损失值在一定范围内波动,表明估产模型参数、权重达到全局最优值。贝叶斯优化算法和深度学习混合模型结合可有效、合理选择超参数组合,间接调整训练过程中的权重参数,逐步减少估测误差,从而提升模型产量估测精度。

3.3 区域玉米单产估测

为探索 TFEL 模型空间拓展能力,并评估其揭示研究区玉米产量变化格局的可行性。基于 TFEL 模型对研究区 2019—2022 年玉米单产进行估测。其主要依据为:①研究区玉米物候期具有相对一致性,为估测尺度转换提供了基础。TFEL 模型学习植被指数和玉米产量间的复杂非线性关系,而非依赖于特定空间尺度的位置信息。②TFEL 模型具备从县域尺度数据中获取时序遥感参数所表征的玉米生长信息,能有效获取研究区内具有普适性植被指数和产量间的响应机制。

区域估测结果如图 6 所示,估测产量在空间上

呈现南部、北部较高,西部次之,中部、东部较少的分布格局。高产量集中分布于海拔相对较低且土壤肥沃的平原地区,而研究区中部、东部位于太行山脉及其部分余脉,海拔高且山地、沟坡较多,地形切割破碎,水土流失严重,一定程度影响玉米生长及其产量。对于研究区玉米产量的年际变化,区域玉米单产估测显示存在一定的波动性。2019 年整体产量明显高于其他年份,可能是由于山西省平均气温普遍上升。2022 年夏季,研究区多地出现历史性高温,出现阶段性干旱,影响本年度玉米产量。伴随高温而来的洪涝灾害,研究区在 2019—2022 年降水量呈现明显不均匀性,2020 年和 2021 年夏季至秋季,局部地区出现暴雨、洪水等,导致该地区玉米出现不同程度倒伏、局部积水等现象,直接或间接地影响玉米产量。




图 6 2019—2022 年区域玉米估产结果

Fig. 6 Regional maize yield estimation results from 2019 to 2022

将 2019—2022 年县域尺度玉米统计产量与 TFEL 模型估测产量进行线性回归分析(图 7),其回归 R^2 为 0.53,即 TFEL 模型估测值与统计值间表现良好的线性相关性。然而回归斜率偏小,表明整体上模型低估高产水平下的产量,回归截距显示在低产区域存在一定程度的偏移。MAPE 为 20.12%,表明模型在总体上具备较为稳健的估测能力,但在个别年份或地区的估测产量可能仍存在较大偏差。综上,尽管存在一定误差,TFEL 模型在区域尺度玉米单产估测表现出良好适用性。

3.4 不同植被指数全局贡献度

基于 SHAP 方法可量化混合模型各遥感参数在玉米产量估测中的重要性(图 8)。TFEL 模型中 EVI2 对产量估测贡献最大,其次为 GCVI;而在 TFL 模型中,GCVI 上升至首位,EVI2 位列第 2。遥感参




图 7 估测产量和统计产量间线性相关性分析

Fig. 7 Linear correlation analysis between estimated yields and county-level statistical yields




图 8 混合模型特征重要性排序

Fig. 8 Ranked feature importance of hybrid model

数贡献差异间接反映不同模型结构在特征响应机制的不同。TFEL 模型仅依赖编码器自注意力机制捕获遥感多参数全局依赖,最终输出的全序列聚合进行玉米产量估测,缺乏逐步反馈与重建过程,因而侧重于相邻时间步中局部特征的重要性提取。此时,在高叶面积指数条件下 EVI2 具有高灵敏性,且对饱和现象的抑制能力强,因此在 TFEL 模型特征重要性排序最高。TFL 模型引入解码器模块,在每一时间步的解码过程不仅利用自身已生成的历史状态(即上下文信息),且通过掩码注意力机制对编码器输出进行全局加权和动态重构,增强了跨时间步的信息融合与长期依赖关系的建模能力,有助于提取遥感多参数随时间演化的累计效应。GCVI 可表征玉米整个生育期内光合作用效率与氮素状况等生理特征,其累计效应在 TFL 模型中得到充分利用,因而在全局特征重要性排序表现较为突出。

在所选植被指数中,SAVI、NDVI 和 GNDVI 在 2

种混合模型贡献度居中。在 TFEL 模型中,GNDVI 的贡献略高于 SAVI。而 TFL 模型中 SAVI 的重要性排序相比在 TFEL 模型中有所提升,而 GNDVI 略有下降。在低贡献参数组中,SR、OSAVI 的 SHAP 值均在 0.13~0.16 区间,表明对模型估测结果影响有限。一定程度反映该组遥感参数信息与其余遥感参数存在冗余性,导致在遥感多参数产量估测贡献度相对较低。

TFEL 模型对输入参数的依赖较为集中,主要依赖少数高贡献参数,而 TFL 模型在特征重要性排序中呈现一定梯度排序现象,但仍缺乏突出特征依赖。虽提升了 TFL 模型对多源遥感信息的整合能力,但一定程度上难以对高权重遥感参数进行聚焦、利用,最终限制该模型估测精度。在构建模型时,需综合考虑估测产量与植被指数间的生物、物理关联,考虑不同架构变化对输入参数权重的动态调节作用。TFEL 模型凭借简化结构,有效聚焦于关键输入参数(EVI2),从而具备较高产量估测精度。

3.5 混合模型全局可解释性

SHAP 概要图可展示各遥感参数与其对应 SHAP 值的分布关系(图 9,图中每个数据点表示 1 个样本,点的颜色对应各遥感参数取值,红色表示较大遥感参数值,蓝色表示较小遥感参数值)。同时以 SHAP 值为零轴的垂直分界,左侧样本点表明遥感参数对玉米产量估测有负向贡献,右侧样本点则表示正向贡献。




图 9 混合模型 SHAP 概要图

Fig. 9 SHAP summary plot of hybrid model

如图 9 所示,在 TFEL 模型中,EVI2、GCVI、OSAVI、NDVI 等植被指数高值普遍分布在正向贡献

区域,表明该部分植被指数对产量估测表现为正向推动作用;反之,低值植被指数集中于负向贡献区域,即植被稀疏或叶绿素含量不足时对产量估测结果表现抑制作用。而 TFL 模型 SHAP 概要图表现较为集中的点云分布,极端值在 TFL 模型中的分布较 TFEL 模型更为接近 SHAP 零轴,可见解码器模块可通过全局特征整合机制,降低植被指数极端值对产量估测结果的影响。其中,TFL 模型中 SAVI 和 GCVI 红色点在横轴上的扩展范围相较于 TFEL 模型分布较广,一定程度表明解码器层能有效增强模型对土壤信息及叶绿素信息的敏感性。此外,在 TFL 模型中,部分遥感参数(如 SR、OSAVI、GNDVI)的 SHAP 值点云分布范围较窄,且其 SHAP 绝对值普遍较小,可见其对混合模型产量估测结果影响有限。

TFEL 模型仅采用编码器层,其输入时序参数与估测产量间信息传递路径较短,有助于避免因信息传递路径过长而带来的参数信息缺失,一定程度提升该模型对关键参数的响应强度。TFEL 模型主要通过自注意力机制和遥感参数与产量间的关联进行估测,对输入植被指数序列中极值的响应较为显著;而完整的编码器-解码器架构通过全局注意力与解码器状态重建,增强对时间序列中长期依赖关系与遥感参数间复杂交互的建模能力。然而,解码器层的引入导致 TFL 模型较为依赖全局特征间的内部特征重构与权重分配机制,削弱关键遥感参数对产量估测的影响,导致模型对关键遥感参数的响应不足,从而影响该模型的产量估测精度。综上,TFEL 模型可稳定识别和量化关键遥感参数对估测结果的贡献度,可有效降低特征噪声干扰,确保产量估测准确性。

4 讨论

将 Transformer、LSTM 模型与时间序列遥感数据相结合,深入挖掘遥感多参数和玉米单产之间的非线性信息,实现从模型训练到区域尺度估测扩展。研究结果表明,将不同模型结构简单地混合并不能获得更好的估测精度,需结合估测产量与植被指数间的生物、物理关联,将不同运行机制有机结合,充分发挥不同模块结构特性,以实现高精度的产量估测。然而,深度学习模型通常需大量训练数据以达到最佳训练结果,Sentinel-2 卫星于 2015 年发射成功,GEE 平台上该系列卫星大气校正后的数据集年限较短,且玉米关键生育期处于夏季,雨热同期,研究区内合适的遥感影像数量有限。受限于单一遥感数据源和样本量较少,所构建的混合模型对统计年

鉴玉米产量中极值和遥感参数间的复杂非线性关系学习不足。未来可采用多种方法改善样本量限制：①使用数据增强技术对数据集进行扩充^[38]，如合成少数类过采样法（Synthetic minority over-sampling technique, SMOTE）、生成对抗网络等。②使用迁移学习方法^[39]，将现有大范围或相似区域同种作物训练得到的模型知识迁移至现研究中，缓解单一数据源带来的样本限制。③考虑多源遥感数据融合方法^[40]，基于时空自适应反射融合模型（Spatial and temporal adaptive reflectance fusion model, STARFM）、增强自适应时空反射融合模型（Enhanced spatial and temporal adaptive reflectance fusion model, ESTARFM）等时空数据融合算法将 MODIS 产品、Sentinel-2 和 Landsat 系列遥感影像进行数据融合，生成可兼顾高时空分辨率的合成影像。未来有望从高时空分辨率多源遥感数据集中获取较为精细的作物生长信息，从而提高区域产量估测精度。

深度学习模型因其内部庞大且复杂的运行机制被称为“黑箱”模型，一定程度上限制了深度学习模型在农业遥感领域的应用。本研究通过 SHAP 方法可量化输入参数对估测产量的贡献，辅助分析模型决策过程和目标结果。全局可解释性有助于理解估产模型的特征重要性和影响，进一步提高深度学习模型的透明度和可信度^[41]。SHAP 方法为全局可解释性提供了一种定量分析的可行方案，然而估产模型构建和输入参数选择往往取决于设计者的专业知识，仍需定量和定性分析输入参数选取、组合和模型构建，建立广泛接受的标准和方法以评估可解释的质量及其对模型估测精度的影响。一些研究者开始探索其他方法进一步提高现有机器学习和深度学习模型的可解释性，如剖析和可视化、文本对齐等技术^[42]。将多种评估方法纳入未来研究，有助于提高深度学习模型在农业遥感估测中的可信度和透明度。

此外，神经网络主要通过多层感知运算、捕捉等方式进行数据训练、学习，对农作物生长过程的机理表示仍有待探究。有学者将农业生产系统模型（Agricultural production systems simulator, APSIM）和机器学习算法集成用于马铃薯、小麦等作物产量估测^[43]。然而面对大量的温度、湿度、降水量等气象数据和不同深度、湿度的土壤理化因子，以及不同时空分辨率的遥感反演参数，机器学习捕获不同数据间的非线性关系能力有限^[44]。未来可尝试将数据同化方法和深度学习模型结合，充分发挥深度学习模型优势，在众多参数中提取较为有效的生长信息，识别作物生长与环境间的复杂关系，利用数据同化方法量化估测结果的可信度和不确定性，不断校正模型参数，进一步提高估测产量精度。

5 结论

（1）相较于 TFL 模型和 Transformer 模型，TFEL 模型估测精度较高（ $R^2 = 0.72$ ， $P < 0.01$ ，RMSE 为 756.43 kg/hm²，MAPE 为 10.58%，NRMSE 为 11.86%），且 TFEL 模型在区域尺度玉米单产估测表现出较好的适用性。

（2）贝叶斯优化算法与混合深度学习模型结合，可获取较为合适的超参数组合，通过间接调整混合模型训练过程中的权重参数，逐步减少估测误差，从而提升混合模型对时序植被指数与玉米单产间的拟合能力。

（3）基于 SHAP 方法的全局可解释性分析，结果表明 GCVI 和 EVI2 在玉米产量估测中起着不可或缺的作用。在构建模型时，需综合考虑估测产量与植被指数间的生物、物理关联。而相较于 TFL 模型，TFEL 模型可有效聚焦于关键遥感参数信息，可稳定识别和量化关键遥感参数对估测结果的贡献度，具备较高产量估测精度。

参 考 文 献

[1] RATTALINO E J I, ANDRADE J F, CASSMAN K G, et al. Spatial frameworks for robust estimation of yield gaps[J]. Nature Food, 2021, 2(10): 773–779.

[2] 赵龙才, 李粉玲, 常庆瑞. 农作物遥感识别与单产估算研究综述[J]. 农业机械学报, 2023, 54(2): 1–19.

ZHAO Longcai, LI Fenling, CHANG Qingrui. Review on crop type identification and yield forecasting using remote sensing [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 1–19. (in Chinese)

[3] CORRALES D C, SCHOVING C, RAYNAL H, et al. A surrogate model based on feature selection techniques and regression learners to improve soybean yield prediction in southern France[J]. Computers and Electronics in Agriculture, 2022, 192: 106578.

[4] XIAO G, HUANG J, ZHUO W, et al. Progress and perspectives of crop yield forecasting with remote sensing: a review[J]. IEEE Geoscience and Remote Sensing Magazine, 2025, 13(3): 338–368.

[5] XU T, ZHANG G, CHEN F, et al. Enhancing water-carbon fluxes and yield predictions of winter wheat using irrigation and data assimilation techniques in a land surface model[J]. Computers and Electronics in Agriculture, 2024, 224: 109140.

[6] 王鹏新, 王颖, 田惠仁, 等. 基于 LightGBM 的冬小麦产量估测与可解释性研究[J]. 农业机械学报, 2023, 54(12): 197–206.

WANG Pengxin, WANG Ying, TIAN Huiren, et al. Interpretability on yield estimation of winter wheat based on LightGBM

- [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 197–206. (in Chinese)
- [7] XIE Y. Combining CERES–Wheat model, Sentinel–2 data, and deep learning method for winter wheat yield estimation[J]. International Journal of Remote Sensing, 2022, 43(2): 630–648.
- [8] ZHAO L, UM D, NOWKA K, et al. Cotton yield prediction utilizing unmanned aerial vehicles (UAV) and Bayesian neural networks[J]. Computers and Electronics in Agriculture, 2024, 226: 109415.
- [9] ZHANG L, ZHANG Z, LUO Y, et al. Integrating satellite-derived climatic and vegetation indices to predict smallholder maize yield using deep learning[J]. Agricultural and Forest Meteorology, 2021, 311: 108666.
- [10] SHAO K, LI D, TANG H, et al. Improving multi-step dissolved oxygen prediction in aquaculture using adaptive temporal convolution and optimized transformer[J]. Computers and Electronics in Agriculture, 2025, 235: 110329.
- [11] ONOUFRIOU G, HANHEIDE M, LEONTIDIS G. Premonition net, a multi-timeline transformer network architecture towards strawberry tabletop yield forecasting[J]. Computers and Electronics in Agriculture, 2023, 208: 107784.
- [12] XIONG X, ZHONG R, TIAN Q, et al. Daily DeepCropNet: a hierarchical deep learning approach with daily time series of vegetation indices and climatic variables for corn yield estimation[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2024, 209: 249–264.
- [13] VAN KLOMPENBURG T, KASSAHUN A, CATAL C. Crop yield prediction using machine learning: a systematic literature review[J]. Computers and Electronics in Agriculture, 2020, 177: 105709.
- [14] TIAN H, WANG P, TANSEY K, et al. An IPSO–BP neural network for estimating wheat yield using two remotely sensed variables in the Guanzhong Plain, PR China[J]. Computers and Electronics in Agriculture, 2020, 169: 105180.
- [15] ZHANG H, ZHANG Y, LIU K, et al. Winter wheat yield prediction using integrated Landsat 8 and Sentinel–2 vegetation index time-series data and machine learning algorithms[J]. Computers and Electronics in Agriculture, 2023, 213: 108250.
- [16] WANG Y, WANG P, TANSEY K, et al. An interpretable approach combining Shapley additive explanations and LightGBM based on data augmentation for improving wheat yield estimates[J]. Computers and Electronics in Agriculture, 2025, 229: 109758.
- [17] NAUTA M, TRIENES J, PATHAK S, et al. From anecdotal evidence to quantitative evaluation methods: a systematic review on evaluating explainable ai[J]. ACM Computing Surveys, 2023, 55(13s): 1–42.
- [18] GUO F, WANG P, TANSEY K, et al. A novel transformer-based neural network under model interpretability for improving wheat yield estimation using remotely sensed multi-variables[J]. Computers and Electronics in Agriculture, 2024, 223: 109111.
- [19] 解毅, 王佳楠, 刘钰. 基于 Sentinel–1/2 数据特征优选的冬小麦种植区识别方法研究[J]. 农业机械学报, 2024, 55(2): 231–241.
- XIE Yi, WANG Jia'nan, LIU Yu. Research on winter wheat planting area identification method based on Sentinel–1/2 data feature optimization[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 231–241. (in Chinese)
- [20] 彭琼艳, 沈若缺, 李向前, 等. 2001—2023 年中国玉米种植分布数据集[DS/OL]. 国家生态科学数据中心, 2023. <https://doi.org/10.57760/sciencedb.08490>. <https://cstr.cn/31253.11.sciencedb.08490>.
- [21] ABBASZADEH P, GAVAH K, ALIPOUR A, et al. Bayesian multi-modeling of deep neural nets for probabilistic crop yield prediction[J]. Agricultural and Forest Meteorology, 2022, 314: 108773.
- [22] LU C, LENG G, LIAO X, et al. In-season maize yield prediction in Northeast China: the phase-dependent benefits of assimilating climate forecast and satellite observations[J]. Agricultural and Forest Meteorology, 2024, 358: 110242.
- [23] 韩文霆, 彭星硕, 张立元, 等. 基于多时相无人机遥感植被指数的夏玉米产量估算[J]. 农业机械学报, 2020, 51(1): 148–155.
- HAN Wenting, PENG Xingshuo, ZHANG Liyuan, et al. Summer maize yield estimation based on vegetation index derived from multi-temporal UAV remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 148–155. (in Chinese)
- [24] ZHANG L, ZHANG Z, LUO Y, et al. Integrating satellite-derived climatic and vegetation indices to predict smallholder maize yield using deep learning[J]. Agricultural and Forest Meteorology, 2021, 311: 108666.
- [25] BARZIN R, PATHAK R, LOTFI H, et al. Use of UAS multispectral imagery at different physiological stages for yield prediction and input resource optimization in corn[J]. Remote Sensing, 2020, 12(15): 2392.
- [26] NILE W, RINA S, MULA N, et al. Inversion of leaf chlorophyll content in different growth periods of maize based on multi-source data from “Sky–Space–Ground”[J]. Remote Sensing, 2025, 17(4): 572.
- [27] LI F, MIAO Y, CHEN X, et al. In-season prediction of corn grain yield through PlanetScope and Sentinel–2 images[J]. Agronomy, 2022, 12(12): 3176.
- [28] MA Y, LIANG S Z, MYERS D B, et al. Subfield-level crop yield mapping without ground truth data: a scale transfer framework[J]. Remote Sensing of Environment, 2024, 315: 114427.
- [29] LU J, LI J, FU H, et al. Estimation of rice yield using multi-source remote sensing data combined with crop growth model and deep learning algorithm[J]. Agricultural and Forest Meteorology, 2025, 370: 110600.
- [30] WANG Y, FENG K, SUN L, et al. Satellite-based soybean yield prediction in Argentina: a comparison between panel regression and deep learning methods[J]. Computers and Electronics in Agriculture, 2024, 221: 108978.

- [19] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016:779–788.
- [20] LIU Yu, LI Xiukun, FAN Yiming, et al. Classification of peanut pod rot based on improved YOLO v5s[J]. *Frontiers in Plant Science*, 2024, 15:1364185.
- [21] YANG Zhengqiang, XIE Ruonan, LIU Linyue, et al. Dense – YOLO v7: improved real-time insulator detection framework based on YOLO v7[J]. *International Journal of Low-Carbon Technologies*, 2024, 19: 157–170.
- [22] CHEN Sibao, WEI Qingsong, WANG Wenzhong, et al. Remote sensing scene classification via multi-branch local attention network[J]. *IEEE Transactions on Image Processing*, 2021, 30: 99–109.
- [23] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. *Proceedings of the IEEE International Conference on Computer Vision*, 2017:2980–2988.
- [24] ZHANG Yifan, REN Weiqiang, ZHANG Zhang, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. *Neurocomputing*, 2022, 506: 146–157.
- [25] ANDREW H, MARK S, GRACE C, et al. Searching for MobileNetV3[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2019:1314–1324.
- [26] FRANÇOIS C. Xception: deep learning with depthwise separable convolutions[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2017:1800–1807.
- [27] TAN M, LE Q. EfficientNetV2: smaller models and faster training[C]//International Conference on Machine Learning. PMLR, 2021:10096–10106.
- [28] 蒙永合, 雷振华, 王振东, 等. 基于改进 YOLO v9s 的变电设施渗漏油高效检测及模型部署[J]. *物联网技术*, 2025, 15(19): 132–135, 139.
MENG Yonghe, LEI Zhenhua, WANG Zhendong, et al. Efficient detection and model deployment of leakage oil in power facilities based on improved YOLO v9s[J]. *Internet of Things Technology*, 2025, 15(19): 132–135, 139. (in Chinese)
- [29] 胡文豪, 蒋亚军, 吴文龙, 等. 基于改进 YOLO v10s 的镀锌铁板缺陷检测算法研究[J]. *中国机械*, 2025(27): 50–56.
HU Wenhao, JIANG Yajun, WU Wenlong, et al. Research on defect detection algorithm for galvanized iron sheets based on improved YOLO v10s[J]. *Machine China*, 2025(27): 50–56. (in Chinese)
- [30] WANG Dingran, TAN Jiasheng, HONG Wangcai, et al. SDS – YOLO: an improved vibratory position detection algorithm based on YOLO v11[J]. *Measurement*, 2025, 244: 116518.

(上接第 202 页)

- [31] VASWANI A. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 5998–6008.
- [32] HAN K, WANG Y, CHEN H, et al. A survey on vision transformer[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 45(1): 87–110.
- [33] DU J, ZHANG Y, WANG P, et al. Enhancing winter wheat yield estimation with a CNN-transformer hybrid framework utilizing multiple remotely sensed parameters[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 4405213.
- [34] 崔佳旭, 杨博. 贝叶斯优化方法和应用综述[J]. *软件学报*, 2018, 29(10): 3068–3090.
CUI Jiaxu, YANG Bo. Survey on Bayesian optimization methodology and applications[J]. *Journal of Software*, 2018, 29(10): 3068–3090. (in Chinese)
- [35] 李亚茹, 张宇来, 王佳晨. 面向超参数估计的贝叶斯优化方法综述[J]. *计算机科学*, 2022, 49(6A): 86–92.
LI Yaru, ZHANG Yulai, WANG Jiachen. Survey on Bayesian optimization methods for hyper-parameter tuning[J]. *Computer Science*, 2022, 49(6A): 86–92. (in Chinese)
- [36] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[J]. *Advances in Neural Information Processing Systems*, 2017, 30:4768–4777.
- [37] 王鹏新, 杜江莉, 张悦, 等. 基于遥感多参数和 CNN – Transformer 的冬小麦单产估测[J]. *农业机械学报*, 2024, 55(3): 173–182.
WANG Pengxin, DU Jiangli, ZHANG Yue, et al. Yield estimation of winter wheat based on multiple remotely sensed parameters and CNN – Transformer[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(3): 173–182. (in Chinese)
- [38] WON S, BAE S H, KIM S T. Effects of mixed sample data augmentation on interpretability of neural networks[J]. *Neural Networks*, 2025, 190: 107611.
- [39] MA Y, CHEN S, ERMON S, et al. Transfer learning in environmental remote sensing[J]. *Remote Sensing of Environment*, 2024, 301: 113924.
- [40] LI J, LIU X, LI Y, et al. Combining filling and fusion strategies for generating synthetic daily Landsat time series image on Google Earth Engine[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5401415.
- [41] HASSIJA V, CHAMOLA V, MAHAPATRA A, et al. Interpreting black-box models: a review on explainable artificial intelligence[J]. *Cognitive Computation*, 2024, 16(1): 45–74.
- [42] MINH D, WANG H X, LI Y F, et al. Explainable artificial intelligence: a comprehensive review[J]. *Artificial Intelligence Review*, 2022, 55(5): 3503–3568.
- [43] PAUDEL D, BOOGAARD H, DE WIT A, et al. Machine learning for large-scale crop yield forecasting[J]. *Agricultural Systems*, 2021, 187: 103016.
- [44] FENG P, WANG B, LI L D, et al. Dynamic wheat yield forecasts are improved by a hybrid approach using a biophysical model and machine learning technique[J]. *Agricultural and Forest Meteorology*, 2020, 285: 107922.