

doi:10.6041/j.issn.1000-1298.2026.08.031

基于 Transformer – BiLSTM 混合模型的冬小麦估产与特征贡献度分析

竞霞¹ 赵天昊¹ 赵佳琪¹ 陈思媛² 刘峰¹ 陈兵³

(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; 3. 新疆农垦科学院棉花研究所, 石河子 832003)

摘要: 在全球气候变化持续加剧、粮食安全挑战日益严峻的背景下,精准、及时地估算作物产量至关重要。传统基于反射率光谱的植被指数难以实时捕捉作物光合生理状态,且单一 Transformer 和双向长短期记忆网络 (Bi-directional long short-term memory, BiLSTM) 模型在提取与产量相关的时序特征方面亦有一定局限性。为此,本研究提出一种日光诱导叶绿素荧光 (Solar-induced chlorophyll fluorescence, SIF) 以及实际蒸散发 (Actual evapotranspiration, Aet)、降水量 (Precipitation, Ppt) 和帕尔默干旱指数 (Palmer drought severity index, PDSI) 等数据融合的混合深度学习估产模型,通过结合 Transformer 提取全局依赖关系的优势以及 BiLSTM 捕捉局部细节变化方面的优势,构建了 Transformer – BiLSTM 冬小麦估产混合模型,并评估了模型泛化能力及特征贡献度。结果表明,在河南省 2013—2019 年县级尺度样本测试集数据中,Transformer – BiLSTM 混合模型拟合性能优越 (决定系数 R^2 为 0.89,归一化均方根误差 (NRMSE) 为 8.18%,相对预测偏差 (RPD) 为 2.90),各项指标均优于单一 Transformer 和 BiLSTM 模型 (R^2 均提高 0.04, NRMSE 分别降低 1.46、1.22 个百分点, RPD 由 2.46、2.53 提升至 2.90)。2020—2022 年河南省县级数据跨时间试验中,Transformer – BiLSTM 混合模型仍保持较高精度 (R^2 为 0.89, NRMSE 为 8.44%, RPD 为 2.77), R^2 较单一 Transformer 和 BiLSTM 模型分别提高 0.05 和 0.07, NRMSE 分别降低 1.92、1.56 个百分点, RPD 则由 2.25、2.33 提升至 2.77,体现了该模型良好的时间泛化能力。进一步将混合模型应用至产量分布更为复杂的安徽省,模型表现依然稳健 (R^2 为 0.87, NRMSE 为 11.07%, RPD 为 2.73), R^2 分别提高 0.07 和 0.08, NRMSE 分别降低 2.33、3.10 个百分点, RPD 由 2.25、2.13 提升至 2.73,验证了 Transformer – BiLSTM 混合模型具有较强的区域泛化能力。此外,将模型在像元尺度生成的高分辨率产量分布图汇总至县级后进行验证,结果亦表明其与统计产量具有较高的一致性 ($R^2 > 0.8$)。基于 SHAP (Shapley additive explanations) 特征重要性分析结果表明,1—2 月最低温和 3—6 月 SIF 对模型输出贡献最高,其中 SIF 在整个时序中始终保持较高重要性。同时,冬小麦拔节至灌浆期 PDSI、Ppt 和 Aet 等气象因子对产量预测亦具有显著影响,反映模型能有效捕捉作物生长过程与环境因子间的协同作用。

关键词: 冬小麦估产; 日光诱导叶绿素荧光; Transformer – BiLSTM 混合模型; 模型泛化性能; SHAP 法

中图分类号: TP79 **文献标识码:** A **文章编号:** 1000-1298(2026)08-0319-12 **OSID:** 

Winter Wheat Yield Estimation and Feature Contribution Degree Analysis Based on Transformer – BiLSTM Hybrid Model

JING Xia¹ ZHAO Tianhao¹ ZHAO Jiaqi¹ CHEN Siyuan² LIU Feng¹ CHEN Bing³

(1. College of Geomatics Science and Technology, Xi'an University of Science and Technology, Xi'an 710054, China
2. Power China Northwest Engineering Co., Ltd., Xi'an 710100, China
3. Cotton Research Institute, Xinjiang Academy Agricultural Reclamation Sciences, Shihezi 832003, China)

Abstract: Against the backdrop of intensifying global climate change and escalating food security challenges, accurately and timely estimating crop yields is important. Traditional vegetation indices based on reflectance spectra are difficult to capture the photosynthetic physiological state of crops in real time, while single-model approaches like Transformers and bi-directional long short-term memory network

(BiLSTM) also exhibit limitations in extracting yield-related temporal features. Therefore, a hybrid deep learning yield estimation model that integrated data such as solar-induced chlorophyll fluorescence (SIF), actual evapotranspiration (Aet), precipitation (Ppt), and Palmer drought severity index (PDSI) was proposed. By leveraging the advantages of Transformer in extracting global dependencies and the BiLSTM in capturing local detail changes, a Transformer – BiLSTM wheat yield estimation model was constructed. The generalization ability and feature contribution of the model were also evaluated. Results indicated that the Transformer – BiLSTM hybrid model demonstrated superior fitting performance on the 2013—2019 county-level sample test dataset from Henan Province ($R^2 = 0.89$, NRMSE was 8.18%, RPD was 2.90). All metrics outperformed those of both the single Transformer and BiLSTM models (R^2 was increased by 0.04, NRMSE was decreased by 1.46 and 1.22 percentage points respectively, and RPD was improved from 2.46 and 2.53 to 2.90). In the 2020—2022 cross-temporal experiment of county-level data in Henan Province, the Transformer – BiLSTM hybrid model maintained high accuracy ($R^2 = 0.89$, NRMSE was 8.44%, RPD was 2.77). Compared with single Transformer and BiLSTM models, R^2 was improved by 0.05 and 0.07, respectively, while NRMSE was decreased by 1.92 and 1.56 percentage points. The RPD was risen from 2.25 and 2.33 to 2.77, demonstrating the model’s robust temporal generalization capability. Further application of this hybrid model to Anhui Province, where yield distributions were more complex, exhibited robust performance ($R^2 = 0.87$, NRMSE was 11.07%, RPD was 2.73). The R^2 values were increased by 0.07 and 0.08, respectively, while the NRMSE was decreased by 2.33 and 3.10 percentage points. The RPD was improved from 2.25 and 2.13 to 2.73, confirming the strong regional generalization capability of the Transformer – BiLSTM hybrid model. Furthermore, aggregating the high-resolution yield distribution maps generated at the pixel scale to the county level for validation demonstrated high consistency with statistical yields ($R^2 > 0.8$). Based on Shapley additive explanations (SHAP) feature importance analysis, the minimum temperatures from January to February and the SIF from March to June contributed most significantly to the model outputs, with SIF maintaining consistently high importance throughout the entire time series. Concurrently, meteorological factors such as PDSI, Ppt, and Aet during the winter wheat jointing to grain filling stage also exerted significant influence on yield prediction, indicating the model’s ability to effectively capture synergistic interactions between crop growth processes and environmental factors.

Key words: winter wheat yield estimation; solar-induced chlorophyll fluorescence; Transformer – BiLSTM model; model generalization performance; SHAP

0 引言

小麦是全球最重要的粮食作物之一,每年种植面积超过 $2.2 \times 10^8 \text{ hm}^2$ ^[1]。中国作为全球最大的小麦生产与消费国,及时、准确评估小麦产量对于国家粮食安全政策制定具有重要意义^[2-3]。遥感技术作为一种非接触式观测方式,能克服传统人工调查方法效率低、成本高、难以大范围开展的局限性,为农作物估产提供高效、广泛的监测方案^[4-5]。近年来,日光诱导叶绿素荧光 (Solar-induced chlorophyll fluorescence, SIF) 被称为植被光合作用的“探针”,能直接反映光系统Ⅱ的光化学效率,与光能利用效率 (Light use efficiency, LUE) 及其碳同化过程具有更紧密的生理关系^[6]。随着 SIF 反演算法精度以及卫星影像时空分辨率的提高,基于星载传感器的 SIF 数据已被成功应用于陆地生态系统总初级生产力 (Gross primary productivity, GPP) 估算^[7] 及干旱胁迫^[8] 等监测。已有研究表明, SIF 与农作物地上生物量存在较强相关性^[9], 而生物量与作物产量间存

在直接耦合关系^[10], 这为构建基于 SIF 的产量预测模型提供了理论依据^[11-13]。遥感数据能反映作物群体的生物量积累与长势特征^[14], 而气象条件也能影响冬小麦的生长环境^[15]。适宜的温度和水分供应有助于促进光合作用和干物质积累, 保障产量形成; 而干旱、低温或极端降水等不利气象事件会抑制作物正常发育, 导致冬小麦减产。因此, 结合遥感与气象数据, 有望进一步提高冬小麦产量预测准确性^[16]。

基于遥感数据的农作物估产方法主要有机理驱动和数据驱动 2 类^[17]。机理驱动模型是以 LUE 为核心, 通过量化作物光合作用中光能转化为生物量的生物物理过程, 系统模拟从光能吸收到生物量累积的完整框架^[17]; 而数据驱动模型依赖机器学习从多源数据中挖掘统计关系, 但传统方法在表征作物全生育期长时序特征和关键物候响应方面存在不足。为弥补这一局限, 深度学习通过构建多层非线性映射结构, 为高阶特征提取与复杂模式识别提供有效途径, 尤其在捕捉时间序列的动态关联上表现

突出^[18],已被广泛应用于作物生长监测与产量估测^[19-22]。在作物时序建模中,传统循环神经网络(Recurrent neural network,RNN)与长短期记忆网络(Long short term memory,LSTM)能有效捕捉生育期内的时间依赖关系,因而常用于遥感估产研究。TIAN 等^[23]基于 LSTM 方法构建了融合条件植被温度指数、叶面积指数与气象因子等多时间步特征的冬小麦估产模型,其精度显著优于反向传播神经网络与支持向量机方法。刘照等^[21]提出了基于 LSTM 的玉米早期估产框架,将有效预测时间提前了约两个月,为农业生产早期干预提供了技术支持。然而,RNN 与 LSTM 在处理长序列数据时,仍面临梯度消失或爆炸、时间步依赖强以及长期记忆能力受限等问题^[24],制约了该方法在大尺度遥感时序建模中的应用潜力。Transformer 算法以自注意力机制为核心,结合位置编码方式克服了传统 RNN 架构对时间步处理的依赖,在捕捉长期依赖关系方面能力更强^[25]。此外,Transformer 并行计算结构也显著提升了在大规模数据场景下的运算效率,近年来已广泛应用于自然语言处理^[26]、农业^[20]等领域。GEORGE 等^[27]提出的基于 Transformer 的多时序特征提取方法,在草莓产量预测中优于卷积神经网络(Convolutional neural networks,CNN)、RNN 与 LSTM 等方法。ZHANG 等^[22]融合时间卷积网络(Temporal convolutional networks,TCN)与 Transformer,在县域尺度冬小麦产量估算精度优于 TCN、LSTM、单一 Transformer 及 CNN - BiLSTM 等方法。然而,Transformer 模型难以有效捕获关键时期的局部细节变化^[28],而 BiLSTM 尽管具备双向上下文信息提取能力,能较好表征短期连续变化,但在处理长距离时序依赖和多特征间交互关系方面仍显不足^[29]。

针对现有作物估产模型难以有效表征长时序特征关联和关键生育期动态变化的问题,本研究利用 Transformer 在多源时序特征间建模全局依赖关系优势,以及 BiLSTM 在时间维度上表征局部动态变化的能力,构建具有并行结构的 Transformer - BiLSTM 混合深度学习模型,并将其与单一 Transformer 模型和单一 BiLSTM 模型分别进行对比分析,进而评价 Transformer - BiLSTM 混合模型对冬小麦估产的性能。通过量化分析 Transformer 与 BiLSTM 的 2 个分支中间隐藏层时序特征,探讨模型在全局与局部信息提取方面的差异及其互补关系;利用跨时期、跨区域及跨尺度的模型试验,全面评估模型在不同应用场景下的泛化能力与稳健性;采用 SHAP 方法,解析 SIF 及关键气象因子在冬小麦关键生育阶段对产量

预测的贡献度,阐明模型决策的生理生态依据,以进一步探究模型机理并验证其在冬小麦产量预测中的实际应用效能。

1 研究区与数据

1.1 研究区概况

以河南省和安徽省为研究区域,其中河南省是我国典型的冬小麦主产区,县级产量数据连续、样本规模大,将该数据用于模型训练与测试;安徽省与河南省气候相似,且其区域具有一定差异,用于检验模型的空间泛化能力与适用性。河南省地处黄河中下游地区(31°23' ~ 36°22'N,110°21' ~ 116°39'E),地势西高东低,以黄淮海平原和南阳盆地为主,土壤肥沃,水资源较为丰富,气候属于温带向亚热带的过渡性气候。安徽省地处长江中下游地区(29°41' ~ 34°38'N,116°17' ~ 119°30'E),以江淮平原为主,具备较优的土壤条件和充沛的水资源,气候属于亚热带湿润气候。

1.2 数据获取与预处理

1.2.1 冬小麦种植区域与产量数据

利用中国作物物候 1 km 分辨率数据集(ChinaCropPhen1km, <https://doi.org/10.6084/m9.figshare.8313530.v5>)^[30]及中国冬小麦种植与收获面积 10 m 分辨率分布图(ChinaWheatMap10, <https://doi.org/10.6084/m9.figshare.25097684.v3>)^[31]确定研究区冬小麦种植区域。同时,从中国经济社会大数据研究平台(<https://tjj.ah.gov.cn/ssah/qwfbjd/tjnj/index.html>)获取 2013—2022 年河南省与 2013—2019 安徽省县级冬小麦产量统计数据作为模型训练与验证的真实数据。为探究不同冬小麦产区产量分布的差异性以及不同样本集的产量分布特征,还对收集的冬小麦产量数据进行了变异系数(Coefficient of variation,CV)计算。

1.2.2 遥感数据

采用的月尺度 GOSIF 数据由基于 OCO - 2 (Orbiting carbon observatory - 2) 卫星观测的离散 SIF 数据构建^[32],该数据集空间分辨率为 0.05°,时间分辨率为月尺度,可在 Global Ecology Group (<https://globalecology.unh.edu/data/GOSIF.html>)获取^[32]。

1.2.3 气象数据

使用来源于 2013—2022 年全球高分辨率月尺度气候与水平衡数据的 Terra Climate 气象数据集(<https://climate.northwestknowledge.net/>)^[33]。该数据集空间分辨率为 1/24°,主要由 CRUTS、World Clim 以及 JRA - 55 再分析资料通过气候插值与

Delta 空间降尺度方法融合生成,包括实际蒸散发 (Actual evapotranspiration, Aet)、帕尔默干旱指数 (Palmer drought severity index, PDSI)、潜在蒸散发 (Potential evapotranspiration, Pet)、降水量 (Precipitation, Ppt)、土壤含水率 (Soil moisture, SM)、最高温 (Maximum air temperature, Tmax)、最低温 (Minimum air temperature, Tmin)、水汽压 (Water vapor pressure, Vap) 及饱和水汽压差 (Vapor pressure deficit, Vpd) 等数据。

1.2.4 数据预处理

以 2013—2019 年河南省为研究区域,收集每年 1—6 月冬小麦关键生育期内的 GOSIF 遥感数据与 Terra Climate 气象数据,用以表示植被光合特征与生境条件。为保障多源数据的空间一致性,将气象变量通过最近邻插值法重采样至与 GOSIF 数据相匹配的空间分辨率 (0.05°)。基于 ChinaCropPhen1km 数据获取研究区冬小麦种植空间分布图,进一步识别各县域的作物分布像元,并在县域尺度对 SIF、Aet、PDSI、Ppt 等变量分别进行像元求和,以综合反映县级尺度的相关信息。将所得多源时序特征与同期县域统计产量数据进行匹配,利用获得的 512 个有效样本构建 2013—2019 年河南省县级冬小麦产量样本集。在建模前,对所有输入特征进行归一化处理,以消除量纲差异并提升模型训练效率与稳定性。

2 研究方法

2.1 Transformer - BiLSTM 混合模型

针对长时间序列作物估产研究中全局依赖与局部动态协同建模需求,将 Transformer 在跨时段特征全局建模方面的优势,与 BiLSTM 在关键生育期局部双向上下文的表征能力相结合,构建用于冬小麦估产的 Transformer - BiLSTM 混合模型 (图 1)。如图 1 所示,构建的 Transformer - BiLSTM 混合模型包括输入层、并行 Transformer 与 BiLSTM 编码层、特征融合层、全连接层及输出层。该模型将多源时序特征数据同步输入至 2 个编码器进行处理。在 Transformer 编码器中,模型通过位置编码显式嵌入时序信息,并借助多头自注意力机制提取不同生育期内各特征的跨时序全局依赖关系,形成突出关键时段贡献的高维综合特征。BiLSTM 编码器则利用双向门控机制,沿时序同时建模前向与后向局部上下文信息,从而增强对连续时段内特征短期动态与局部依赖结构的捕捉能力。2 路编码器输出的高阶特征向量经融合层拼接后,由全连接层进行特征集成与非线性映射,最终输出县域尺度冬小麦产量预




图 1 Transformer - BiLSTM 估产模型整体结构

Fig. 1 Overall structure of Transformer - BiLSTM model

测结果。

2.1.1 Transformer 编码器

构建的 Transformer - BiLSTM 混合模型中,Transformer 模块主要用于捕获时序数据的全局依赖关系。针对自注意力机制本身缺乏对输入序列时序结构的显式感知能力问题,采用正弦-余弦位置编码方法,将每个时间步绝对位置信息映射为固定维度的位置向量,并将其叠加至输入特征中。通过引入位置编码,Transformer 模块能有效识别不同生育期在时序上的相对位置关系,从而增强模型在捕捉不同特征间跨时序依赖关系的表达能力。

融入位置信息后,输入序列被送入 Transformer 编码器进行全局依赖关系建模。每个编码器模块由多头自注意力子层、前馈神经网络子层以及相应的残差连接与层归一化结构组成。该结构能并行计算特征序列中所有时间步间的注意力权重,有效建立冬小麦不同生育期内遥感与气象因子的跨时期依赖关系,增强模型对时间维度复杂动态模式的表达能力。其中,多头自注意力机制通过将输入特征分别映射到多个子空间中进行并行计算,使模型能从多个维度捕捉全局依赖关系。在每个注意力头中,输入序列首先通过 3 个可学习的线性变换分别生成查询矩阵 (Q)、键矩阵 (K) 和值矩阵 (V),然后通过缩放点积注意力机制计算不同生育期之间的特征依赖强度。

2.1.2 BiLSTM 编码器

为增强模型对时序特征趋势变化的捕捉能力,采用双向长短期记忆网络 (BiLSTM) 对输入特征同

时进行编码。BiLSTM 编码器由前向与后向 2 个独立的 LSTM 单元组成,分别沿时间正向和反向对序列进行编码。通过 BiLSTM 能利用捕获上下文信息的能力,有效识别如拔节、抽穗和灌浆等关键生育期内局部时段的特征变化。

并行编码完成后,将 Transformer 分支输出的全局依赖特征与 BiLSTM 分支输出的局部动态特征在特征维度上进行拼接,构建融合全局与局部信息的高阶表征向量。该向量经全连接层进行非线性映射并输出产量预测结果。与单一 Transformer 或单一 BiLSTM 相比,并行结构在保证全局依赖建模能力的同时,显著提升了对关键时期局部变化的提取能力。

2.2 模型验证与分析

2.2.1 模型隐藏特征提取

为分析 Transformer - BiLSTM 混合模型的时序表征机制,对 Transformer 编码器与 BiLSTM 编码器的内部特征分别进行了可视化分析。在 Transformer 编码器,提取 2 层多头自注意力机制输出的注意力权重矩阵,矩阵各行对应低级输入特征的时间序列位置,各列对应高级输出特征的序列位置,自注意力权重反映了输入特征在时间维度上对输出特征的影响程度^[34]。为进一步揭示模型关注模式,将每层编码器各注意力头权重在头维度上取平均,获得具有代表性的自注意力权重分布,用以分析模型在不同月份间的注意力分配规律及其全局依赖建模特性。对于 BiLSTM 编码器,则提取各月份正向与反向 LSTM 的 128 维隐藏状态,在样本维度上计算平均值并绘制隐藏状态热力图。其中,隐藏状态是 LSTM 单元在门控机制调控下,由细胞状态映射得到的时序输出向量,表征模型在当前时间步对双向上下文时序信息的编码结果,其数值可理解为对应隐藏单元在该时刻对输入特征的响应强度。通过比较正向与反向隐藏状态的分布差异,可分析 LSTM 在不同生育阶段对局部时序变化的响应模式。

2.2.2 模型精度评价

使用归一化均方根误差 (Normalized root mean square error, NRMSE)、相对预测偏差 (Relative percent deviation, RPD) 以及决定系数 (Determination coefficient, R^2) 作为模型精度评价指标,分别从预测误差标准化、偏差程度以及模型拟合优度等方面综合评价冬小麦估产模型性能^[35]。

2.2.3 SHAP 贡献度分析

SHAP 是一种基于博弈论中 Shapley 值的可解释性方法,能量化每个输入特征对模型预测结果的贡献程度,从而评估特征重要性^[36]。SHAP 通过计算每个特征 Shapley 绝对值均值获得全局解

释性指标,主要衡量各特征在所有样本中的平均重要性。

3 结果与分析

3.1 Transformer - BiLSTM 混合模型构建与精度评价

3.1.1 Transformer 编码器隐藏特征提取

Transformer - BiLSTM 混合模型在 Transformer 编码器集成了多头自注意力机制,能在时间维度上对输入序列中各时间步特征进行动态权重分配。每个编码器的自注意力模块均会生成一个注意力权重矩阵,用以表征不同时间步间的信息依赖关系。为进一步剖析 Transformer 在时间序列建模过程对全局依赖关系的表征能力,基于 2 层 Transformer 编码器的自注意力矩阵绘制了注意力权重分布图 (图 2)。其中横轴与纵轴分别表示输入与输出时间步 (1—6 月)。由于每个时间步的输入向量均融合了该月份的多源遥感数据及其气象特征,因此该注意力图同时反映了模型在时间维度上的依赖建模与多源特征融合过程的权重分配特征。结果表明,注意力权重并非集中在主对角线附近,而是在 3—5 月冬小麦关键生育期附近形成明显的“条状”高响应区域。无论对哪一个输出时间步进行编码,模型均对这些冬小麦关键生育期对应的月份赋予较高注意力权重。表明 Transformer 在构建任意月份的特征表示时,能以冬小麦关键生育期月份作为信息枢纽,主动整合其前后多个月份的观测信息,并对不同时间步特征进行重新加权融合。这种全局感知机制能有效捕捉不同月份间的远程依赖关系与信息互补性,强化关键生育期在整体时间序列中的表征权重,从而为产量预测提供更加稳定且具备全局依赖建模能力的时序特征表示。




图 2 Transformer 编码层产生的归一化自注意力权重
Fig. 2 Normalized self-attention weights produced by Transformer encoder layer

3.1.2 BiLSTM 编码器隐藏特征提取

为直观展示 BiLSTM 在时间维度上捕获局部动态的能力,基于 2013—2019 年样本集对 BiLSTM 编码器隐藏特征进行了可视化分析,以单一 SIF 特征为例,该时段 SIF 月均值时序变化规律如图 3a 所示。




图 3 正反向 LSTM 层隐藏状态

Fig. 3 Hidden states of forward and backward LSTM layers

由图 3a 可看出,SIF 在 1—2 月处于较低水平,3 月开始快速上升,4 月达到峰值,随后于 5—6 月明显回落。在此基础上,分别提取正向与反向 LSTM 在各时间步的 128 维隐藏状态,并在样本维度上取平均,得到 2 组隐藏状态矩阵并绘制热力图。由图 3b、3c 可看出,2 幅热力图均在 SIF 剧烈变化的 3—5 月期间呈现连续的高激活带状区域,而在变化相对平缓的 1—2 月及 6 月,隐藏单元整体保持较弱激活。表明 BiLSTM 能自发聚焦于 SIF 快速升降的冬小麦关键生育期,对其局部梯度变化表现出更高的敏感性。依托遗忘门和输入门等门控机制,LSTM 可在短时间窗内实现信息的选择性保留与更新,从而增强关键局部动态的表征,并抑制信息冗余。进一步观察发现,正向 LSTM 在 4—6 月 SIF 衰减阶段的激活更为突出,而反向 LSTM 在 2—4 月的上升阶段响应更强。这一差异表明双向结构分别从“前向”和“后向”2 个时间视角对局部变化过程进行互补性建模。BiLSTM 能围绕生长季中关键转折月份实现局部特征的强化与细化,为短时间尺度上的上升、峰值与回落过程提供更精细的时序描述。在捕捉冬小麦关键生育期内快速变化的时序动态方面,该结构相较于主要依赖全局建模的 Transformer 方法展现出独特优势。

3.1.3 Transformer-BiLSTM 混合模型精度评价
为构建河南省县级尺度冬小麦产量估测模

型,以 SIF 等多源遥感与气象数据为自变量,结合 Transformer 的自注意力机制与 BiLSTM 的时序特征提取能力,提出了一种用于冬小麦估产的 Transformer-BiLSTM 混合模型。共搜集 2013—2019 年间 512 组样本数据,并按比例 7:3 随机划分为训练集和验证集,分别用于模型构建与精度评价。其中,每组样本均包括县级冬小麦产量、1—6 月月尺度 SIF 遥感数据,以及 Aet、PDSI、SM、Pet、Ppt、Tmax、Tmin、Vap 和 Vpd 9 项气象数据。此外,为提高模型预测精度及稳定性,在模型训练过程采用 Adam 优化器以及 Piecewise 学习率衰减策略进行参数更新。Adam 优化器初始学习率设定为 0.01,最大迭代次数为 300,学习率衰减策略设定为每训练 90 个训练周期,将当前学习率乘以一个衰减因子 0.2。

基于验证集对 Transformer-BiLSTM 混合模型与 2 种单一模型预测精度分析,结果如图 4 所示。由图 4 可知,3 种模型预测产量与统计产量样本点均分布在 1:1 线附近,仅有约 3% 预测点落在 95% 预测区间外,表明 3 种模型均具备较好的预测稳定性。Transformer-BiLSTM 混合模型表现最优,其预测产量与统计产量之间 R^2 较 Transformer 和 BiLSTM 单一模型均提高 0.04,NRMSE 分别降低 1.46、1.22 个百分点,RPD 由单一模型的 2.46 和 2.53 提升至 2.90,表明其预测不确定性更小,结




图 4 2013—2019 年河南省县级冬小麦估产模型精度验证

Fig. 4 Accuracy verification of county-level winter wheat yield estimation model in Henan Province, 2013—2019

果更加集中。

3.2 Transformer-BiLSTM 混合模型泛化性能评估

3.2.1 模型跨时期泛化性能评估

为更好地评估 Transformer-BiLSTM 混合模型在时间维度上的泛化能力,利用河南省 2020—2022 年 272 组县级冬小麦产量样本数据,对已训练的 Transformer-BiLSTM 混合模型、Transformer 单一模型和 BiLSTM 单一模型进行跨时期泛化性能测试

(图 5)。由图 5 可看出,Transformer-BiLSTM 混合模型在 2020—2022 年保持较好预测性能,预测产量与统计产量间呈极显著相关关系。相较于单一 Transformer 和 BiLSTM 模型,混合模型 R^2 分别提高 0.05 和 0.07,NRMSE 分别降低 1.92、1.56 个百分点,RPD 则由 2.25 和 2.33 提高至 2.77。此外,混合模型预测点更紧密地分布在 1:1 线附近,显示出更优的泛化稳定性。




图 5 2020—2022 年河南省县级冬小麦产量预测

Fig. 5 2020—2022 county-level winter wheat production forecast for Henan Province

3.2.2 模型跨空间泛化性能评估

为更好地评估 Transformer-BiLSTM 混合模型不同空间分布的泛化能力,将安徽省冬小麦产量样本数据与河南省冬小麦产量样本数据进行对比分析(图 6)。由图 6a 可看出,2013—2019 年安徽省县级冬小麦产量样本主要集中在 $0 \sim 2 \times 10^5$ t 区间,占总样本的 62%,而 $2 \times 10^5 \sim 4 \times 10^5$ t 和 $4 \times 10^5 \sim 6 \times 10^5$ t 占比均低于 15%。河南省(图 6b)样本则主要分布于 $0 \sim 6 \times 10^5$ t 区间,其中 $0 \sim 2 \times 10^5$ t、 $2 \times$

$10^5 \sim 4 \times 10^5$ t 和 $4 \times 10^5 \sim 6 \times 10^5$ t 占比分别为 28%、33% 和 29%。在 $6 \times 10^5 \sim 1 \times 10^6$ t 区间,两省差异较小,安徽省与河南省占比分别为 17% 和 10%。从整体分布特征来看,安徽省冬小麦产量分布变异系数(CV 为 1.09)明显高于河南省(CV 为 0.52),说明安徽省县级冬小麦产量在空间上表现出更强的离散性与异质性。这种空间分布差异为检验模型在异质区域中的泛化性能提供了更具挑战性的数据基础。




图 6 安徽省和河南省县级冬小麦产量分布

Fig. 6 County-level production distribution in Anhui and Henan Provinces

基于 2013—2019 年间安徽省 372 个县级冬小麦产量样本数据,进一步评价了 Transformer-BiLSTM 混合模型、Transformer 单一模型和 BiLSTM 单一模型估产精度(图 7),以验证不同模型在异质性较强的空间分布下泛化性能。由图 7 可以看出,

Transformer-BiLSTM 混合模型对安徽省县级冬小麦产量的预测精度显著优于 2 种单一模型,预测产量与统计产量之间 R^2 较 Transformer 和 BiLSTM 模型分别提高 0.07 和 0.08,NRMSE 分别降低 2.33、3.10 个百分点,RPD 则由单一模型的 2.25 和 2.13




图 7 2013—2019 年安徽省县级冬小麦产量预测

Fig. 7 2013—2019 county-level winter wheat production forecast for Anhui Province

提升至 2.73,表明 Transformer – BiLSTM 混合模型在空间异质条件下具有更好的稳定性与泛化能力。

3.2.3 模型跨尺度泛化性能评估

Transformer – BiLSTM 混合模型在跨年份、跨区域的县级尺度冬小麦产量估算中均表现出较高精度。为进一步获取更精细的空间分布信息,将训练完成的 2013—2019 年河南省县级尺度 Transformer – BiLSTM 混合模型拓展应用于像元尺度(图 8)。由图 8 可看出,河南省像元尺度预测的冬小麦产量呈

现明显的“西低东高”空间梯度分布,这与河南省的地形分布特点及其耕作条件有关。河南省西部及南部地区受地形起伏和耕地分布限制,产量普遍较低,而东部黄淮海平原地势平坦、耕地集中连片,种植密度高,形成了多个高产区域。与县级尺度冬小麦估产相比,像元尺度估产能在更精细的空间分辨率下捕捉空间分布上的产量差异,直观揭示区域内产量高低产分布,避免因行政单元平均化而掩盖局地异质性。




图 8 2013—2019 年河南省冬小麦产量分布预测

Fig. 8 Forecast of winter wheat production distribution in Henan Province, 2013—2019

为进一步评估像元尺度模型估产精度,将像元尺度估算结果按县级行政区进行汇总,并与对应县级的统计产量进行对比(图 9)。由于缺少像元尺度的实地验证数据,该聚合方法可在县级尺度上间接验证模型的空间分布合理性。由图 9 可看出,各年份预测产量与统计产量的 R^2 均高于 0.8, NRMSE 均低于 11%,表明像元尺度产量分布不但与县级统计结果保持一致,而且可以提供更丰富的空间细节信息。

3.3 SHAP 特征贡献分析

虽然深度学习模型具有较强的预测能力,但其“黑箱”特性往往掩盖了输入特征与产量间的内在联系。为此,采用 SHAP 方法,对 2013—2019 年河

南省县级冬小麦样本的 Transformer – BiLSTM 混合模型进行特征贡献度解析,并结合相关性分析,系统评估各特征在冬小麦不同生育阶段对产量预测的作用。由不同特征在 1—6 月的 SHAP 值变化可看出(图 10a),1—2 月 T_{min} 和 3—6 月 SIF 的 SHAP 值最高,显著高于其余气象因子。此外, PDSI、Ppt、Aet 对模型输出也表现出较高贡献度。从生育阶段看,1—2 月为冬小麦越冬期,植株抗逆性较弱,低温冻害易导致生长受阻进而影响产量,因此该阶段 T_{min} 重要性显著上升。而 3—5 月分别对应冬小麦拔节期、抽穗期和灌浆期,其中 3 月是冬小麦地上生物量快速累积阶段,冬小麦生长主要依赖光合作用驱动的碳积累,此时 SIF 对模型的贡献显著增强。在




图 9 2013—2019 年河南省像元冬小麦产量分布验证

Fig. 9 Verification of winter wheat yield distribution by pixels in Henan Province from 2013 to 2019




图 10 冬小麦产量预测的特征贡献度与相关性分析

Fig. 10 Feature contribution degree and correlation analysis of winter wheat yield prediction

4—5 月,冬小麦易受干旱、高温以及病虫害等胁迫影响,仅利用气象因子难以全面、及时地捕捉对生长状况的综合影响。相比之下,直接表征植被光合作用过程的 SIF 作为光合作用有效探针,更能反映植株生理状态,因此该时期 SIF 对产量预测具有更高贡献度。

图 10b 进一步展示了各特征在 1—6 月与实测产量的相关性,其中 SIF、Vap、Pet 和 Tmax 与冬小麦产量相关性较高。然而,冬小麦产量受多因素综合作用,在深度学习模型中,特征表征并不局限于简单的线性响应,更依赖于对时序特征非线性关系的表述。SIF 与冬小麦产量相关系数在 1—2 月分别为 0.40 和 0.43,总体偏低。3 月开始显著上升,并于 3—5 月分别达到 0.63、0.78 和 0.81,6 月为 0.64,

表明 3—5 月是 SIF 与产量线性拟合的最强时期。Transformer 编码器通过多头自注意力机制,有效整合了不同月份 SIF 与气象因子的关联,从而模型整体提升了 SIF 重要性。Pet、Vap 以及 Tmax 自 2 月起即与产量保持较高的相关性,3—6 月多数月份的相关系数超过 0.81;且 Vap、Vpd、Tmax 以及 Tmin 在冬小麦生长中后期的相关系数也普遍高于 0.7。而 PDSI 以及 Ppt 与冬小麦产量的相关性整体较低,多数月份不超过 0.45。这是因为 BiLSTM 编码器依托双向门控结构,持续捕捉特征的时序动态,增强了对关键生育阶段局部变化的表征能力,使模型能更灵敏地响应 PDSI、Ppt 及 Tmin 等特征在特定时期对产量的影响。

4 讨论

提出的 Transformer 与 BiLSTM 混合框架在县级尺度冬小麦估产预测效果表现稳定。相较于单一 Transformer 或单一 BiLSTM,混合模型在河南省 2013—2019 年训练阶段能更有效地表征产量变化特征,并在验证阶段保持更好的泛化能力。从时序表征机制看,Transformer 分支的注意力分配并未局限于相邻月份,而是更集中于 3—5 月关键生育期,并通过整合跨月信息增强对关键阶段信号的利用效率。表明模型可在 1—6 月全时序范围内重新分配信息权重,将拔节至灌浆阶段的生理状态变化转化为对最终产量更具解释力的综合表征。与此同时,BiLSTM 分支依托双向门控机制对局部时序波动更为敏感,能更准确地跟踪关键阶段的短期变化,其与 Transformer 的全局建模形成互补,使混合模型在不同产量水平下均保持较稳定的预测输出。

模型泛化性能评估进一步验证了该模型的应用潜力。在跨年份评估中,混合模型能在气象背景与

生育进程存在差异的条件下维持相对稳定的预测表现,说明对年际气候波动与样本分布变化具有一定适应性。在跨区域评估中,即使研究区地形背景与产量分布格局差异明显,模型仍能获得较可靠的估产结果,表明并行融合结构对空间异质性具有一定稳健性。但在中高产区间可能出现一定的系统性偏差,当高产样本覆盖不足或区域管理差异较大时,模型会受到样本不平衡影响。在跨尺度拓展方面,将县域尺度训练模型应用于像元尺度估产,以在地面样本难以大范围获取条件下实现更精细的产量空间表达。像元尺度预测在空间格局与总体变化趋势上与县域统计产量保持较高一致性,表明模型所学习的时序关系具有一定的尺度适用性,可为区域产量制图提供方法支撑。但需要指出的是,像元尺度缺乏直接地面验证数据,目前主要依赖聚合一致性检验,仍难以完全排除局地偏差与误差抵消的影响,后续仍需结合样方或站点产量等更细尺度数据开展严格的验证与误差溯源。

在模型特征贡献分析中,越冬期 1—2 月 Tmin 的 SHAP 值最高,而 SIF 在 3—6 月保持较高贡献并在 4—5 月更为突出,同时 PDSI、Ppt、Aet 等与能量相关因子也发挥了重要作用。越冬期低温胁迫会影响分蘖成活与后续穗粒形成,并产生滞后效应,因此 Tmin 在生育期早期较高的重要性符合冬小麦生育规律。进入 3—5 月后,产量形成直接受光合同化与干物质积累过程影响,SIF 能直接表征冠层光合活性,并在水分与热量条件共同作用下综合反映作物生理状态,因此在模型贡献中占据主导地位。与此同时,灌浆期 Aet、Pet、Ppt 和 SM 等因子通过调节蒸散耗水与水分供给影响冠层光合效率与籽粒灌浆进程,从而成为产量预测的重要补充信息。需要指出的是,相关性分析与 SHAP 重要性可能并不完全一致。部分变量在线性相关性上并不突出,但在模型中却呈现较高贡献,这与深度学习模

型刻画非线性关系及特征交互的能力密切相关。以 PDSI 与 Ppt 为例,其对产量的影响具有明显的阶段性与条件性,往往通过改变土壤水分状况与蒸散过程间接影响冠层结构与光化学效率。当这些水分因子与温度、蒸散发以及 SIF 等状态信息共同作用时,更易形成对产量变化具有辨识度的组合信号,因此即便单变量线性相关性较弱,也可能体现为较高的边际贡献。

5 结 论

(1)河南省 2013—2019 年训练与测试结果表明,Transformer - BiLSTM 混合模型较单一 Transformer 和 BiLSTM 模型表现更优, R^2 均提高 0.04,NRMSE 降低 1.46、1.22 个百分点,预测结果分布更加集中,表明该模型在县域尺度上具备更高的预测精度与稳定性。

(2)模型泛化性能评估结果表明,在河南省 2020—2022 年跨年份测试中,混合模型仍保持显著优势,较单一 Transformer 和 BiLSTM 模型 R^2 分别提升 0.05、0.07,RPD 同步提高;在安徽省跨区域测试中, R^2 分别提升 0.07、0.08,NRMSE 降低 2.33、3.10 个百分点。此外,将县域模型拓展至像元尺度并生成高分辨率产量分布图,经县级汇总验证,各年份 R^2 均高于 0.8,NRMSE 低于 11%,能更精细地刻画产量空间格局,并与统计产量保持较高一致性。

(3)模型特征贡献在不同生育期表现出明显差异。越冬期(1—2 月) Tmin 对模型输出的贡献最高,说明低温胁迫在越冬期和后续穗粒形成中具有重要作用。进入 3—6 月后,SIF 贡献持续增强,并在 4—5 月达到峰值,表明光合同化与干物质积累过程在产量形成中起主导作用。同时,PDSI、Ppt 和 Aet 等水分与能量因子在关键阶段发挥协同调节效应,反映水热条件对冠层光合效率与籽粒灌浆进程的综合影响。

参 考 文 献

[1] SINGH S K, KUMAR S, KASHYAP P L, et al. Wheat[M]//GHOSH P K, DAS A, SAXENA R, et al. Trajectory of 75 years of Indian agriculture after independence. Singapore: Springer Nature Singapore, 2023: 137 - 162.

[2] WU B, ZHANG M, ZENG H, et al. Challenges and opportunities in remote sensing-based crop monitoring: a review[J]. National Science Review, 2023, 10(4): nwac290.

[3] 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)

[4] WEST H, QUINN N, HORSWELL M. Remote sensing for drought monitoring & impact assessment: progress, past challenges and future opportunities[J]. Remote Sensing of Environment, 2019, 232: 111291.

[5] 竞霞, 闫菊梅, 邹琴, 等. 基于 CC - MPA 特征优选算法的小麦条锈病遥感监测[J]. 农业机械学报, 2022, 53(9): 217 - 225, 304.

JING Xia, YAN Jumei, ZOU Qin, et al. Remote sensing monitoring of wheat stripe rust based on CC-MPA feature optimization algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 217-225, 304. (in Chinese)

[6] 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.

[7] JOINER J, YOSHIDA Y, ZHANG Y, et al. Estimation of terrestrial global gross primary production (GPP) with satellite data-driven models and eddy covariance flux data[J]. Remote Sensing, 2018, 10(9): 1346.

[8] DE CANNIÈRE S, VEREECKEN H, DEFOURNY P, et al. Remote sensing of instantaneous drought stress at canopy level using sun-induced chlorophyll fluorescence and canopy reflectance[J]. Remote Sensing, 2022, 14(11): 2642.

[9] GUAN K, BERRY J A, ZHANG Y, et al. Improving the monitoring of crop productivity using spaceborne solar-induced fluorescence[J]. Global Change Biology, 2016, 22(2): 716-726.

[10] RAYA-SERENO M D, ALONSO-AYUSO M, PANCORBO J L, et al. Residual effect and N fertilizer rate detection by high-resolution VNIR-SWIR hyperspectral imagery and solar-induced chlorophyll fluorescence in wheat[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-17.

[11] GAO Y, WANG S, GUAN K, et al. The ability of sun-induced chlorophyll fluorescence from OCO-2 and MODIS-EVI to monitor spatial variations of soybean and maize yields in the Midwestern USA[J]. Remote Sensing, 2020, 12(7): 1111.

[12] JOSHI A, PRADHAN B, CHAKRABORTY S, et al. Winter wheat yield prediction in the conterminous United States using solar-induced chlorophyll fluorescence data and XGBoost and random forest algorithm[J]. Ecological Informatics, 2023, 77: 102194.

[13] LI X, JIN H, EKLUNDH L, et al. Estimation of district-level spring barley yield in southern Sweden using multi-source satellite data and random forest approach[J]. International Journal of Applied Earth Observation and Geoinformation, 2024, 134: 104183.

[14] SIEGMANN B, CENDRERO-MATEO M P, COGLIATI S, et al. Downscaling of far-red solar-induced chlorophyll fluorescence of different crops from canopy to leaf level using a diurnal data set acquired by the airborne imaging spectrometer HyPlant[J]. Remote Sensing of Environment, 2021, 264: 112609.

[15] LU Y, HU H, LI C, et al. Increasing compound events of extreme hot and dry days during growing seasons of wheat and maize in China[J]. Scientific Reports, 2018, 8(1): 16700.

[16] 王永昊, 王鸣雷, 闫慧敏, 等. VPM 模型与转产系数结合的吉林省玉米估产[J]. 农业工程学报, 2024, 40(20): 195-201.

WANG Yonghao, WANG Minglei, YAN Huimin, et al. Estimating maize yield in Jilin Province of China using VPM model combined with conversion coefficient[J]. Transactions of the CSAE, 2024, 40(20): 195-201. (in Chinese)

[17] SABZCHI-DEHKHARGHANI H, BISWAS A, MESHRAM S G, et al. Estimating gross and net primary productivities using earth observation products: a review[J]. Environmental Modeling & Assessment, 2024, 29(1): 179-200.

[18] WANG S, CAO J, YU P S. Deep learning for spatio-temporal data mining: a survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(8): 3681-3700.

[19] TIAN H, WANG P, TANSEY K, et al. Attention mechanism-based deep learning approach for wheat yield estimation and uncertainty analysis from remotely sensed variables[J]. Agricultural and Forest Meteorology, 2024, 356: 110183.

[20] 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)

[21] 刘照, 李华朋, 陈慧, 等. 基于时序影像及不同模型的玉米早期估产研究[J]. 光谱学与光谱分析, 2023, 43(8): 2627-2637.

LIU Zhao, LI Huapeng, CHEN Hui, et al. Maize yield forecasting and associated optimum lead time research based on temporal remote sensing data and different model[J]. Spectroscopy and Spectral Analysis, 2023, 43(8): 2627-2637. (in Chinese)

[22] ZHANG L, LI C, ZHANG G, et al. Winter wheat yield estimation based on multisource remote sensing data: a dual-branch TCN-Transformer model and analysis of growth-stage feature transition mechanisms[J]. Computers and Electronics in Agriculture, 2025, 239: 111014.

[23] TIAN H, WANG P, TANSEY K, et al. An LSTM neural network for improving wheat yield estimates by integrating remote sensing data and meteorological data in the Guanzhong Plain, PR China[J]. Agricultural and Forest Meteorology, 2021, 310: 108629.

[24] LI W, LIU C, HU C, et al. Application of a hybrid algorithm of LSTM and Transformer based on random search optimization for improving rainfall-runoff simulation[J]. Scientific Reports, 2024, 14(1): 11184.

[25] NOOR N, BILAL M, ABBASI F S, et al. A novel Transformer-based approach for cardiovascular disease detection[J]. Frontiers in Digital Health, 2025, 7:1548448.

[26] SU R, GAO S, ZHAO K, et al. Adaptive feature interaction enhancement network for text classification[J]. Scientific

Reports, 2025, 15(1): 11488.

[27] GEORGE O, MARC H, GEORGIOS L. Premonition net, a multi-timeline transformer network architecture towards strawberry tabletop yield forecasting[J/OL]. Computers and Electronics in Agriculture,2023,208. DOI: 10.1016/J.COMPAG.2023.107784.

[28] GUO X, KIM Y, NING X, et al. Enhancing the transformer model with a convolutional feature extractor block and vector-based relative position embedding for human activity recognition[J]. Sensors, 2025, 25(2): 301.

[29] XU D, CAO B. Adaptive multiobjective evolutionary generative adversarial network for metaverse network intrusion detection [J]. Research, 2025, 8: 0665.

[30] LUO Y, ZHANG Z, CHEN Y, et al. ChinaCropPhen1km: a high-resolution crop phenological dataset for three staple crops in China during 2000—2015 based on leaf area index (LAI) products[J]. Earth System Science Data, 2020, 12(1): 197–214.

[31] HU J, ZHANG B, PENG D, et al. Mapping 10-m harvested area in the major winter wheat-producing regions of China from 2018 to 2022[J]. Scientific Data, 2024,11(1):1038.

[32] LI X, XIAO J. A global, 0.05-degree product of solar-induced chlorophyll fluorescence derived from OCO-2, MODIS, and reanalysis data[J]. Remote Sensing, 2019, 11(5): 517.

[33] ABATZOGLOU J T, DOBROWSKI S Z, PARKS S A, et al. Terra climate, a high-resolution global dataset of monthly climate and climatic water balance from 1958—2015[J]. Scientific Data, 2018, 5(1): 170191.

[34] GARNOT V S F, LANDRIEU L, GIORDANO S, et al. Satellite image time series classification with pixel-set encoders and temporal self-attention[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 12322–12331.

[35] TATACHAR A V. Comparative assessment of regression models based on model evaluation metrics[J]. International Research Journal of Engineering and Technology (IRJET), 2021, 8(9): 853–860.

[36] TALBOT N, TAKADA A, BINGHAM A H, et al. An investigation of the impacts of a successful COVID-19 response and meteorology on air quality in New Zealand[J]. Atmospheric Environment, 2021, 254: 118322.

(上接第 318 页)

[31] 胡婵娟,郭雷. 植被恢复的生态效应研究进展[J]. 生态环境学报, 2012, 21(9): 1640–1646.
HU Chanjuan, GUO Lei. Advances in the study of ecological effects of vegetation restoration[J]. Journal of Environmental and Ecological Science, 2012, 21(9): 1640–1646. (in Chinese)

[32] 郭泽呈,魏伟,石塔基,等. 中国西北干旱区土地沙漠化敏感性时空格局[J]. 地理学报, 2020, 75(9): 1948–1965.
GUO Zecheng, WEI Wei, SHI Peiji, et al. Spatiotemporal pattern of land desertification sensitivity in the arid northwestern China[J]. Acta Geographica Sinica, 2020, 75(9): 1948–1965. (in Chinese)

[33] PU Y, YANG L, ZHANG L, et al. Major contributions of agricultural management practices to topsoil organic carbon distribution and accumulation in croplands of East China over three decades[J]. Agriculture, Ecosystems & Environment, 2024, 359: 108749.

[34] MUHIE S H. Novel approaches and practices to sustainable agriculture[J]. Journal of Agriculture and Food Research, 2022, 10: 100446.

[35] YU Z, MA R, XU J, et al. A dataset of the TSI of Hulun Lake in summer,1986—2020[J]. China Scientific Data, 2023, 8(4): 21–25.

[36] BABUR E, DINDAROGLU T. Seasonal changes of soil organic carbon and microbial biomass carbon in different forest ecosystems[J]. Environmental Factors Affecting Human Health, 2020, 1: 1–21.

[37] 牛振国,景雨航,张东启,等. 气候变化背景下青藏高原湿地生态系统响应特征:回顾与展望[J]. 气候变化研究进展, 2024, 20(5):509–518.
NIU Zhenguo, JING Yuhang, ZHANG Dongqi, et al. Response characteristics of wetland ecosystems on the Qinghai-Tibet Plateau under climate change: a review and prospect[J]. Advances in Climate Change Research, 2024, 20(5): 509–518. (in Chinese)

[38] 翟夏杰,崔丽娟,李伟,等. 中国典型湿地生态系统的固碳价值研究[J]. 水生态学杂志, 2024, 45(6): 1–8.
ZHAI Xiajie, CUI Lijuan, LI Wei, et al. Study on carbon sequestration value of typical wetland ecosystems in China[J]. Journal of Hydroecology, 2024, 45(6): 1–8. (in Chinese)

[39] 齐智娟,徐敬文,张忠学,等. 秸秆还田配施氮肥对黑土玉米田土壤 CO₂ 排放与碳平衡的影响[J]. 农业机械学报, 2024, 55(6):284–293.
QI Zhijuan, XU Jingwen, ZHANG Zhongxue, et al. Effects of straw returning combined with nitrogen fertilizer application on soil CO₂ emission and carbon balance in black soil maize fields [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(6): 284–293. (in Chinese)