doi:10.6041/j.issn.1000-1298.2026.06.019

基于 LSTM－AM 的冬小麦单产估测模型构建及其可解释性分析

王鹏新[1,2]　韩弘炜[1,2]　李明启[1,2]　刘峻明[3]　张树誉[4]　叶　昕[1,2]

(1. 中国农业大学信息与电气工程学院，北京 100083；2. 农业农村部农机作业监测与大数据应用重点实验室，北京 100083；3. 中国农业大学土地科学与技术学院，北京 100193；4. 陕西省气象局，西安 710014)

摘要： 准确及时地估测作物产量对保障我国粮食安全和促进农业可持续发展具有重要意义。本文以陕西省关中平原作为研究区域，选取与冬小麦长势密切相关的条件植被温度指数(VTCI)、叶面积指数(LAI)、光合有效辐射吸收比率(FPAR)作为遥感特征参数，结合长短期记忆网络(LSTM)在时序数据处理上的优势，以及注意力机制(AM)对关键信息提取的能力，构建了 LSTM－AM 深度学习模型，用于冬小麦单产估测。结果表明，LSTM－AM 模型决定系数(R^2)为 0.65，均方根误差(RMSE)为 496.43 kg/hm^2，平均绝对百分比误差(MAPE)为 7.31%，归一化均方根误差(NRMSE)为 0.11，相较于 LSTM 模型(R^2 = 0.60，RMSE 为 527.81 kg/hm^2，MAPE 为 7.85%，NRMSE 为 0.15)，LSTM－AM 模型具有更高的模型估测精度，且对于 LSTM 模型存在的低产高估及高产低估现象均有所改善。为进一步提高模型可解释性，利用置换特征重要性方法(PFI)对模型估测结果进行了进一步的解释研究。结果表明，4 月下旬和 5 月上旬的 FPAR、3 月下旬至 5 月上旬 VTCI、4 月下旬至 5 月下旬的 LAI 对冬小麦最终产量影响较大。因此，LSTM－AM 模型不仅有着较高的估测精度，同时通过 PFI 方法提升了模型可解释性，可为后续冬小麦产量估测提供参考。

关键词： 冬小麦产量估测；遥感多参数；LSTM；注意力机制；可解释性分析

中图分类号： TP79　　**文献标识码：** A　　**文章编号：** 1000-1298(2026)06-0206-09　　**OSID：**

Construction and Interpretability Analysis of Winter Wheat Yield Estimation Model Based on LSTM－AM

WANG Pengxin[1,2]　HAN Hongwei[1,2]　LI Mingqi[1,2]　LIU Junming[3]　ZHANG Shuyu[4]　YE Xin[1,2]

(1. *College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Key Laboratory of Agricultural Machinery Monitoring and Big Data Application*, *Ministry of Agriculture and Rural Affairs*, *Beijing* 100083, *China*
3. *College of Land Science and Technology*, *China Agricultural University*, *Beijing* 100193, *China*
4. *Shaanxi Provincial Meteorological Bureau*, *Xi'an* 710014, *China*)

Abstract: Accurate and timely crop yield estimation is of great significance for ensuring food security and promoting sustainable agricultural development. Focusing on the Guanzhong Plain in Shaanxi Province, selecting the vegetation temperature condition index (VTCI), leaf area index (LAI), and fraction of photosynthetically active radiation (FPAR) as remotely sensed feature parameters closely related to winter wheat growth. By combining the advantages of long short-term memory network (LSTM) in processing time series data with the capability of the attention mechanism (AM) to extract key information, an LSTM－AM deep learning model for winter wheat yield estimation was constructed. The results indicated that the coefficient of determination (R^2) for the LSTM－AM model was 0.65, with a root mean squared error (RMSE) of 496.43 kg/hm^2 and a mean absolute percentage error (MAPE) of 7.31%, and a normalized root mean squared error (NRMSE) of 0.11. Compared with the LSTM model (R^2 = 0.60, RMSE is 527.81 kg/hm^2, MAPE is 7.85%, NRMSE is 0.15), the LSTM－AM model demonstrated higher estimation accuracy and mitigated the underestimation of high yields and overestimation of low yields observed in the LSTM model. To further enhance the model's interpretability, the permutation

收稿日期：2024－11－10　修回日期：2024－11－22

基金项目： 国家自然科学基金项目(42171332)

作者简介： 王鹏新(1965—)，男，教授，博士，主要从事定量遥感及其在农业中应用研究，E-mail：wangpx@cau.edu.cn

feature importance (PFI) method for an in-depth explanation of the estimation results was utilized. The findings indicated that FPAR from late April to early May, VTCI from late March to early May, and LAI from late April to late May significantly influenced the final yield of winter wheat. Therefore, the LSTM－AM model not only exhibited high estimation accuracy but also enhanced interpretability through the PFI method, providing a valuable reference for subsequent winter wheat yield estimation.

Key words: winter wheat yield estimation; remote sensing multi-parameters; LSTM; attention mechanism; interpretability analysis

0　引言

监测作物生长状况并进行高精度产量估测对确保粮食安全至关重要，也是当前农业研究主要挑战之一[1]。小麦是中国最重要粮食作物之一，据相关预测，到 2030 年中国小麦总产量将增加 15%[2]。因此，及时、准确地估测小麦产量，对确保粮食安全和粮食政策的制定具有重要意义[3]。

传统的作物产量估测方法主要依赖人工进行田间调查，过程繁琐且受限于调查区域与样本数量，导致其应用范围较有限[4]。近年来，遥感技术凭借其快速、便捷、监测范围广等优势，为农作物产量估测提供了科学有效的手段[5]。当前基于遥感参数进行作物产量估测的方法主要有：经验模型法、机理模型法和半经验半机理模型法[6]。其中，经验模型法相较另外 2 种方法具有灵活、易用的优点，是一种简便有效的大范围作物产量估测方法[7]。经验模型法被应用于产量估测时，可根据输入参数量被分为单参数估产模型和多参数估产模型[8]。基于遥感数据的长势监测参数中，归一化植被指数(Normalized difference vegetation index，NDVI)、光合有效辐射吸收比率(Fraction of photosynthetically active radiation，FPAR)和叶面积指数(Leaf area index，LAI)能够较好地表征作物生长状况，在作物产量估测中发挥着重要作用[9]。然而，作物产量不仅受自身生长状况影响，还与环境胁迫有密切关系，尤其是干旱会造成作物水分胁迫程度加剧，最终导致产量减少[10]。王鹏新等[11]在 NDVI 和地表温度(Land surface temperature，LST)散点图呈三角形区域分布的基础上，提出的条件植被温度指数(Vegetation temperature condition index，VTCI)可定量表征作物水分胁迫信息，目前已成功应用于关中平原作物产量估测[12]。

近年来，深度学习模型在农业作物估产领域得到广泛应用[13]。长短期记忆神经网络(Long short-term memory，LSTM)凭借其独特的门控机制，在处理时序数据时有着强大的记忆能力。TIAN 等[14]构建了基于 LSTM 的冬小麦产量估测模型，研究表明模型在灌溉样点和旱作样点有着良好的稳健性，且对气候年际波动有着较好的适应性。在神经网络模型学习的过程中，通过引入注意力机制(Attention mechanism，AM)[15]，LSTM 网络得以增强其对信息重要性的评估和权衡能力，能够精准地聚焦于对当前任务至关重要的信息，从而提升模型整体性能。姜宇等[16]建立了一种基于注意力机制的 LSTM 模型，利用注意力机制捕捉特征间的相互依赖性，对河南省县级小麦产量进行估测，结果显示，该模型相较于传统机器学习模型有着更为良好的估测性能。但深度学习模型的网络结构对使用者来说是不透明的，导致估测结果难以解释，给模型在关键领域的进一步推广带来一定障碍。因此，理解并解释神经网络模型的决策过程对于提升模型的可解释性和泛化能力至关重要。

目前，深度学习的可解释性可分为：事前可解释性与事后可解释性[17]。事后可解释性依据可解释性的范围分为：全局可解释性和局部可解释性。其中全局可解释性方法能够提供模型在所有数据上的整体表现情况，具体方法包括置换特征重要性算法(Permutation feature importance，PFI)、基于沙普利值的加性解释方法(Shapley additive explanation，SHAP)等[18－19]。其中，PFI 法凭借其简单、易用、可靠性强的优点被广泛应用于深度学习模型的可解释性分析中。FAN 等[20]在重庆市水稻产量估测中，使用 PFI 法进行特征变量选择，有效地提升了产量估测准确性。

考虑到当前传统作物产量估测方法存在的问题以及深度学习方法缺乏可解释性的问题，以关中平原为研究区域，本文选取与冬小麦长势密切相关的 VTCI、LAI、FPAR 作为遥感特征参数，建立添加 AM 的 LSTM 模型，以期实现更精确的关中平原冬小麦产量估测；并使用 PFI 法对模型进行可解释性分析，进一步研究各遥感特征参数对小麦单产的重要性及影响。

1　材料与方法

1.1　研究区域概况

关中平原地处陕西省中部(图 1)，地理坐标范围为 106°22′～110°24′ E、33°57′～35°39′ N，介于秦

岭与黄土高原之间,属于典型暖温带大陆性季风气候[21]。因受季风气候影响,关中平原夏季温暖多雨,冬季寒冷干燥,年平均降水量为 550 ~ 700 mm,年平均气温为 6 ~ 13℃。该区域土壤丰饶,地形平坦,非常适合农作物种植[22]。在关中平原的灌溉区域,主要种植模式为夏玉米和冬小麦轮作,而在旱作区域则主要以种植冬小麦为主。冬小麦通常在 10 月上旬或中旬播种,次年 6 月上旬收获。根据关中平原冬小麦实际生长状况,将冬小麦越冬后的主要生育时期划分为返青期(3 月上旬—3 月中旬),拔节期(3 月下旬—4 月中旬),抽穗-灌浆期(4 月下旬—5 月上旬),乳熟期(5 月中旬—5 月下旬)。

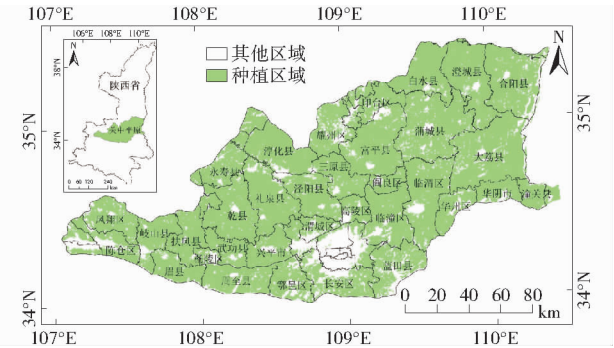

图 1 研究区域及 2022 年小麦种植区

Fig. 1 Study area and wheat planting areas in 2022

1.2 数据来源与处理

1.2.1 数据来源

所选用遥感数据为中分辨率成像光谱仪(MODIS)的地表温度产品(MYD11A1)、地表反射率产品(MYD09GA)、叶面积指数和光合有效辐射比率产品(MCD15A3H)、土地覆盖类型产品(MCD12Q1)。所使用关中平原 24 个县(区)2011—2022 年间的冬小麦单产数据,获取自各县(区)所在市统计局公开发布的统计年鉴。

1.2.2 冬小麦种植区域

采用 Terra 和 Aqua 卫星上的 MODIS 传感器所获取的 MCD12Q1 来提取冬小麦的种植区域。利用 MODIS reprojection tool(MRT)工具对原始数据进行遥感影像格式和地图投影的转换等预处理,并与关中平原行政边界矢量图进行叠加。最终,根据 IGBP 分类方案中代码 14 对应的农田/自然植被嵌入类型,提取到关中平原小麦种植区分布图(图 1)。

1.2.3 时间序列 VTCI 数据生成

对关中平原 2011—2022 年每年 3—5 月的 MYD11A1(空间分辨率为 1 000 m)和 MYD09GA 产品(空间分辨率为 500 m)进行重采样等预处理操作。经过处理,得到关中平原 2011—2022 年每年 3—5 月空间分辨率为 1 000 m 的日 LST 和日 NDVI 数据。运用最大值合成法(Maximum value composite,MVC),分别生成旬尺度的 NDVI 和 LST 的最大值合成产品。VTCI 计算需用到冷、热边界,确定冷、热边界的方法参照文献[14]。旬尺度下 VTCI 具体计算公式为[23-24]

$$VTCI = \frac{L_{\max}(N_i) - L(N_i)}{L_{\max}(N_i) - L_{\min}(N_i)} \tag{1}$$

其中

$$L_{\max}(N_i) = a + bN_i \tag{2}$$

$$L_{\min}(N_i) = a' + b'N_i \tag{3}$$

式中 N_i——研究区域某一像素 NDVI 值

$L(N_i)$——某一像素 NDVI 值为 N_i 时地表温度

$L_{\max}(N_i)$、$L_{\min}(N_i)$——研究区域中 NDVI 值为 N_i 的所有像素中 LST 最大值与最小值,也称热、冷边界

a、b、a'、b'——待定系数,由研究区域 NDVI 和 LST 的散点图近似获得

基于生成的旬时间尺度的 VTCI 值,叠加关中平原各县(区)的冬小麦种植区域图,将各县种植区域内所包含像素内的 VTCI 平均值作为该县域该旬的 VTCI 值。

1.2.4 时间序列 LAI 与 FPAR 数据生成

LAI 和 FPAR 从空间分辨率为 500 m 和时间分辨率为 4 d 的 MCD15A3H 产品中进行提取。由于云层、大气等环境因素干扰,原始 LAI 和 FPAR 数据可能有骤降情况发生,不能直接反映作物 LAI 和 FPAR 的实际变化规律。因此,使用上包络线 Savitzky - Golay 滤波方法对原始 LAI 和 FPAR 数据进行平滑去噪处理[25]。考虑到 VTCI 和 FPAR 的取值范围均在 0 ~ 1 之间,为使 LAI 与两者具有相同取值范围,因此对经滤波处理的 LAI 数据进行了归一化处理。基于滤波后的 LAI 和 FPAR 数据,逐像素取各旬所包含的多时相 LAI 和 FPAR 的最大值作为该旬的 LAI 和 FPAR 值。此外,由于处理后的 LAI 和 FPAR 数据的空间分辨率与 VTCI 的空间分辨率不同,因此采用最邻近法将 VTCI 的空间分辨率由 1 000 m 重采样至 500 m。最终将各县域内计算得到的 LAI 与 FPAR 的平均值作为该区域当年各旬的 LAI 和 FPAR 值。

1.3 研究方法

1.3.1 技术路线与评价指标

技术路线图如图 2 所示,对关中平原 2011—2022 年间每年 3—5 月的 MYD11A1、MYD09GA 和 MCD15A3H 产品进行预处理,生成各县域旬尺度下的 VTCI、LAI、FPAR 数据。将 9 个旬、3 个遥感参数

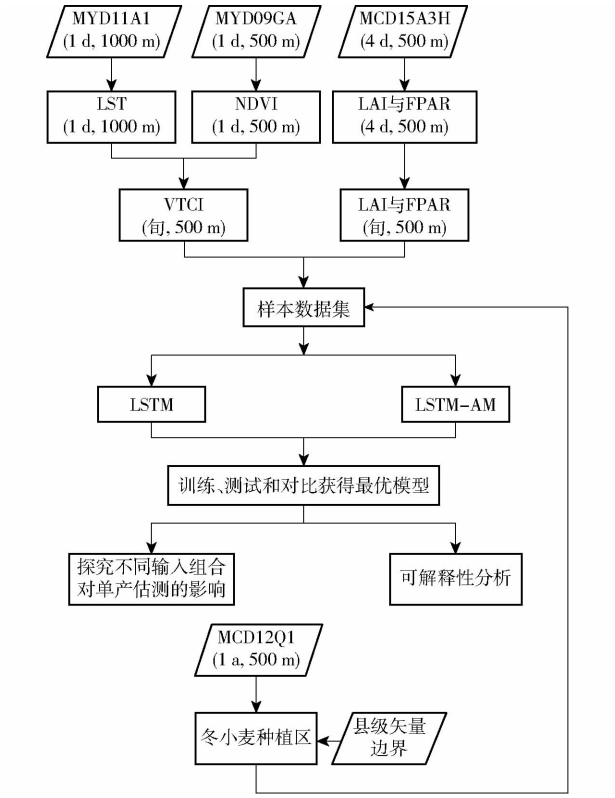

图 2　技术路线图

Fig. 2　Technical roadmap

组成的共 27 个特征值以张量形式输入模型进行训练，采用关中平原各县域产量真实值作为样本标签值，经过训练、测试和对比得到最优模型，探究不同特征组合对单产估测的影响。最后使用 PFI 法对模型进行可解释性分析，分析冬小麦不同特征对产量形成的重要性及影响，提高模型可解释性。采用决定系数（Coefficient of determination，R^2）、均方根误差（Root mean squared error，RMSE）、平均绝对百分比误差（Mean absolute percentage error，MAPE）、归一化均方根误差（Normalized root mean squared error，NRMSE）对模型在产量估测中的性能进行评估。

1.3.2　LSTM 模型

循环神经网络（Recurrent neural network，RNN）是一种特殊的神经网络架构，具备独特的短时记忆能力。RNN 中的神经元不仅能够接收并处理来自其他神经元以及自身信息，还能处理自身的反馈信号，从而构建出循环连接的网络结构。然而，当输入序列较长时，RNN 可能会出现梯度消失或梯度爆炸问题，LSTM 对传统 RNN 进行了改进，其由多个记忆细胞结构组成，每个记忆细胞结构由 3 个“门”控制[26]。3 个门的具体存储单元结构如图 3 所示。遗忘门f_t决定要丢弃的单元状态信息的数量；输入门确定要存储在当前单元状态 c_t中的新获取信息的比例；输出门 o_t根据输入信息和记忆单元决定要输出的内容。LSTM 通过门控机制的引入，一定程度上解决了循环神经网络梯度爆炸或消失问题。

遗忘门（f_t）决定在训练过程中当前单元中哪些信息将被丢弃，即

$$f_t = \sigma(\boldsymbol{W}_f[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_f) \tag{4}$$

式中　f_t——遗忘门输出

σ——Sigmoid 函数

$\boldsymbol{h}_{t-1}$——前一个时刻输出

$\boldsymbol{x}_t$——第 t 时刻输入

$\boldsymbol{W}_f$、$\boldsymbol{b}_f$——遗忘门权重矩阵和偏置向量

输入门（i_t）决定哪些信息将被存储在当前单元中，包括 2 个部分：①由 Sigmoid 函数决定将要更新的值。②应用 tanh 函数创建一个新的候选值向量状态$\tilde{c}_t$，计算公式分别为

$$i_t = \sigma(\boldsymbol{W}_i[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_i) \tag{5}$$

$$\tilde{c}_t = \tanh(\boldsymbol{W}_c[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_c) \tag{6}$$

式中　i_t——输入门输出

$\tilde{c}_t$——第 t 时刻要加入到记忆细胞中的信息

$\boldsymbol{W}_i$、$\boldsymbol{W}_c$——输入门和输入候选元素权重矩阵

$\boldsymbol{b}_i$、$\boldsymbol{b}_c$——输入门和输入候选元素相应偏置向量

单元状态是用于存储长期记忆的关键组成部

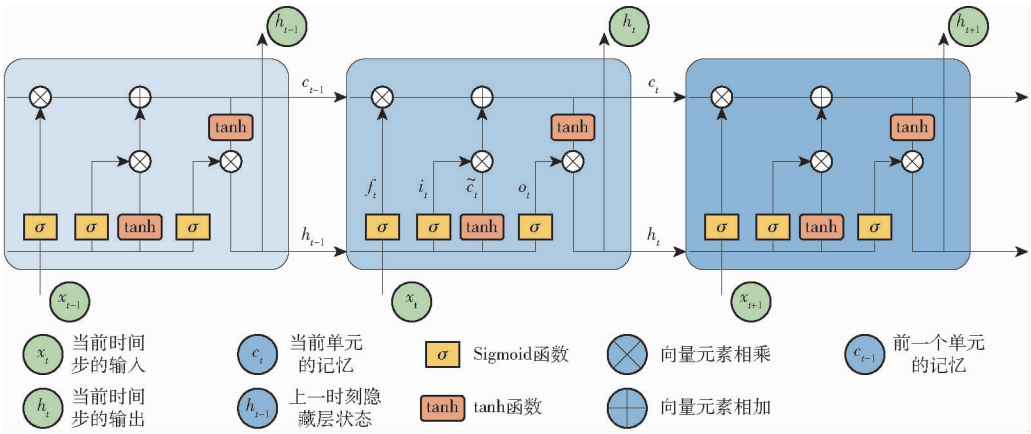

图 3　LSTM 模型结构

Fig. 3　LSTM model structure

分,从旧单元状态 c_{t-1} 更新为新单元状态 c_t,即

$$c_t = f_t c_{t-1} + i_t \tilde{c}_t \tag{7}$$

输出门(o_t)是数据通过 LSTM 神经元的第 3 步,在 t 时刻,输出门根据记忆细胞的状态来决定哪些信息将被输出

$$o_t = \sigma(\boldsymbol{W}_o[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_o) \tag{8}$$

$$\boldsymbol{h}_t = o_t \tanh(C_t) \tag{9}$$

式中 $\boldsymbol{W}_o$、$\boldsymbol{b}_o$——输出门权重矩阵和偏置向量

$\boldsymbol{h}_t$——t 时刻输出

1.3.3 LSTM - AM 模型建立

将注意力机制应用于多参数作物长势信息的提取,有助于充分学习不同参数之间的相互依赖和非线性关系。基于此,构建了一种基于注意力机制的 LSTM 网络(LSTM with an attention mechanism,LSTM - AM),通过在 LSTM 网络中引入注意力机制,增强对关键特征的表达能力(图 4)。模型由 1 个输入层、1 个 LSTM 层、1 个注意力机制层、1 个 Dropout 层和 1 个输出层组成。将关中平原 24 个县(区)2011—2022 年的单产数据(y)与其对应年份的 3 月上旬至 5 月下旬的 VTCI、LAI、FPAR,作为一组样本,共 288 组样本,并将上述样本按照比例 8∶2 划分为训练集与测试集。通过多次训练调优,最终确定最优参数为:批处理大小为 32,初始学习率为 0.001,LSTM 层神经元数量为 64,训练周期 200 个,优化器为 Adam,损失函数为均方误差。同时,在注意力机制层后添加 1 个 Dropout 层,以减少模型过拟合问题,其值设置为 0.25。

构建了 1 个 4 层的 LSTM 产量估测模型作为基线模型,与 LSTM - AM 模型相比少 1 个注意力机制层。同时,为保证研究过程公平性与研究结果可比性,将基线模型参数设置与 LSTM - AM 模型保持一致。

1.3.4 PFI 法

PFI 法最早用于随机森林可解释性分析[27],后续该模型也被用于对 LSTM 等深度学习模型进行可解释性分析,PFI 算法流程如图 5 所示。PFI 算法采用对预测特征进行随机排列方式,若模型估测性能因某个预测特征顺序发生改变而显著下降,则表明该特征具有较高的特征重要性;若模型估测性能未发生较大变化,则表明该估测特征重要性较低。

2 结果与分析

2.1 单产估测结果

对相同模型参数条件下的 LSTM 与 LSTM - AM 进行训练测试(表 1),由表 1 可知,相较于传统 LSTM 模型,LSTM - AM 的 R^2 提升 0.05,RMSE 降低 31.38 kg/hm^2,MAPE 下降 0.54 个百分点,NRMSE 降低 0.04。其原因是注意力机制使模型能够动态地关注输入序列中的不同部分。在传统的 LSTM 模型中,输入序列中每个元素对输出的贡献被看作是相等的。然而,在实际应用中,某些特定时间步的信息可能对估测结果更为关键。注意力机制通过为每个时间步分配不同权重,使模型能够更加关注与当前估测任务最相关的信息,从而提高了估测准确性。

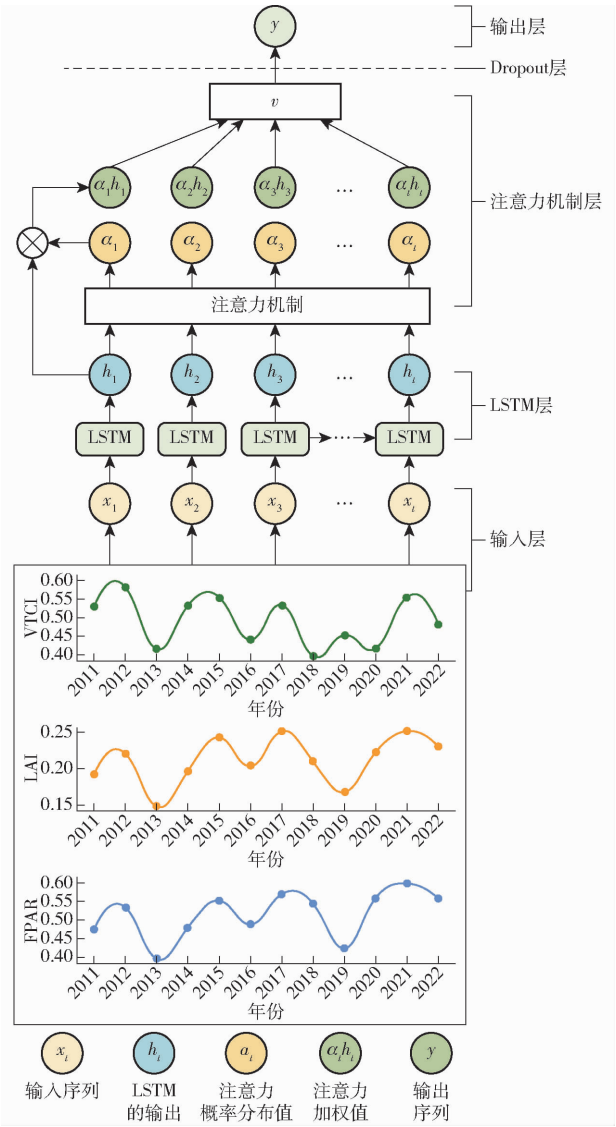

图 4 LSTM - AM 模型结构

Fig. 4 LSTM - AM model structure

表 1 LSTM 和 LSTM - AM 模型精度对比

Tab. 1 Accuracy comparison of LSTM and LSTM - AM models

模型	R^2	RMSE/(kg·hm^{-2})	MAPE/%	NRMSE
LSTM	0.60	527.81	7.85	0.15
LSTM - AM	0.65	496.43	7.31	0.11

为进一步评估模型在估产方面的准确性,分别使用 LSTM 和 LSTM - AM 模型对估测单产与统计单

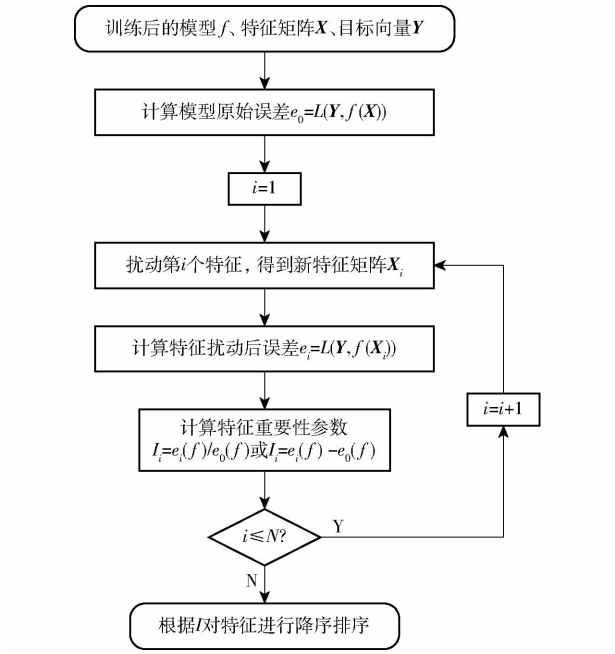

图 5　PFI 算法流程图

Fig. 5　Flowchart of PFI algorithm

产作回归分析(图 6)。由图 6 可知,LSTM－AM 估产模型 R^2、RMSE、MAPE、NRMSE 分别为 0.62、469.99 kg/hm^2、8.58% 和 0.12,相较于 LSTM 估产模型,LSTM－AM 估产模型 RMSE 下降 40.03 kg/hm^2,MAPE 下降 0.36 个百分点,NRMSE 下降 0.04。同时,由于关中平原的 24 个县(区)冬小麦产量大多集中在 3 000～5 000 kg/hm^2,而超出此范围的低产样本和高产样本占比较少,深度学习估产模型易产生低产高估或高产低估现象。但从模型在低产部分及高产部分的估测结果来看,LSTM－AM 模型的估产精度均优于 LSTM 模型。对于产量小于 3 000 kg/hm^2 的低产部分,LSTM－AM 估产模型的斜率更接近 1,估产结果相较于传统 LSTM 模型更接近 1∶1线,且估测单产与统计单产的产量分布直方图更加接近;对于产量高于 5 000 kg/hm^2 的高产部分,LSTM－AM 模型的统计单产与估测单产的散点大多分布在 ±800 kg/hm^2 的误差线以内。因此,从模型整体以及局部(低产部分和高产部分)估产结果来看,添加注意力机制的 LSTM 模型能够更有效地捕捉到与作物长势相关的特征信息,相较于 LSTM 模型能够较好地改善低产高估及高产低估现象,进一步提高了模型估产准确度。

2.2　不同输入组合对估产结果的影响

模型性能的提升不仅依赖于网络结构的优化,还与输入特征的合理选择密切相关。为验证本研究所选取遥感特征的有效性,分别建立单参数(VTCI、LAI 或 FPAR)、双参数(VTCI 和 LAI、VTCI 和 FPAR、LAI 和 FPAR)、多参数(VTCI、LAI 和 FPAR)

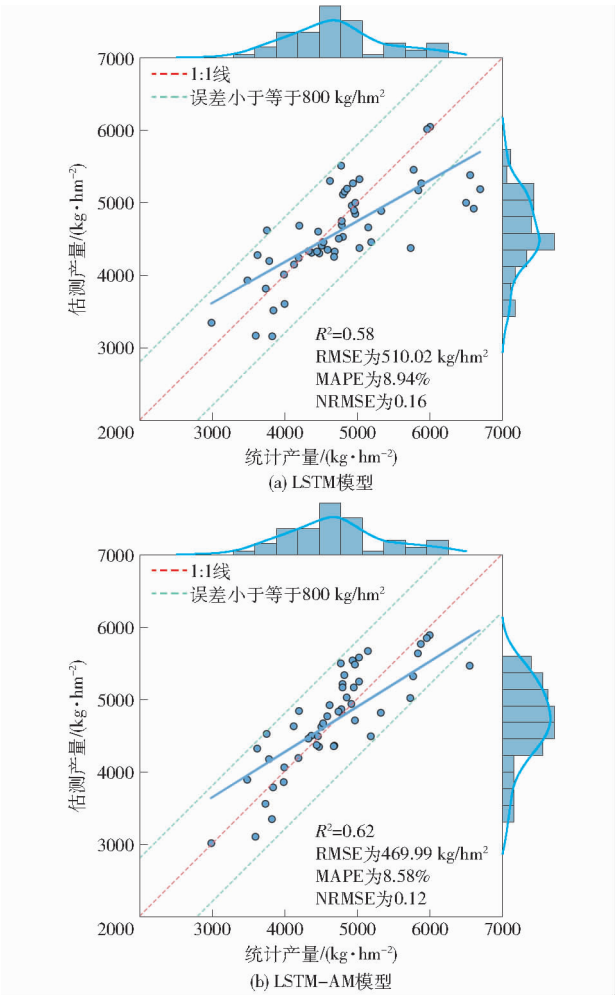

图 6　估测单产与统计单产的回归分析

Fig. 6　Regression analysis of estimated yield and statistical yield

的冬小麦估产模型,得到不同特征组合下模型估测性能(图 7)。由图 7 可知,在 3 个单参数模型中,FPAR 单参数模型的估测精度最高。其原因为冬小麦的产量形成与光合作用高度相关,而 FPAR 作为衡量光合作用效率的重要指标,在作物生长过程具有显著作用。因此,相较于 VTCI 和 LAI,FPAR 与冬小麦产量之间可能存在更加直接且紧密的联系。

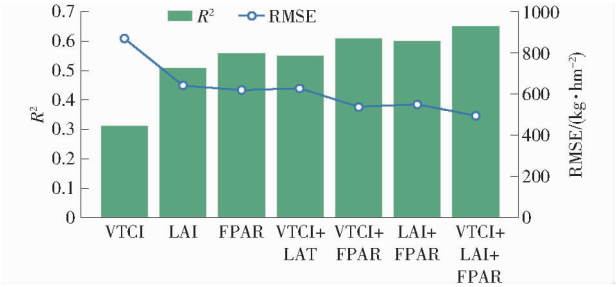

图 7　不同输入组合下估产性能对比

Fig. 7　Comparison of estimated yield performance under different input combinations

3 个双参数模型中,VTCI 与 FPAR 的参数组合精度最高,其原因可能是 VTCI 与作物水分状况和

蒸腾作用紧密相关。冬小麦的生长和产量不仅受光合作用影响,还受到水分胁迫和环境温度等因素制约,而 VTCI 则补充了水分状况和环境温度方面信息。这种互补作用使得 VTCI 与 FPAR 组成的双参数模型能够更准确地估测冬小麦产量。

相较于单参数与双参数模型,多参数模型具有最优的估测性能,其原因在于 LAI 反映了植被的叶片密集程度和生物量,将其与 VTCI、FPAR 组合在一起使用时能够更全面地体现植被生长和产量形成过程。同时,在估测模型中,使用较少特征参数可能会因为参数本身的不确定性或局限性而导致产量估测误差。当多参数组合使用时,参数之间的互补作用可在一定程度减少这种不确定性,提高估测稳定性。

2.3 模型可解释性分析

为更好地理解深度学习模型做出相关估测的原因,增强模型的可解释性。使用 PFI 算法对 LSTM - AM 冬小麦估测模型进行可解释性分析,结果如图 8 所示。为便于对比,将特征重要性值进行和为 1 的归一化处理。由图 8 可知,FPAR 特征重要性最高的旬为 4 月下旬和 5 月上旬。此期间冬小麦正处于抽穗-灌浆期。抽穗-灌浆期时小麦会吸收大量营养物质以供其生长发育,是小麦提高产量与品质的关键时期,而 FPAR 能够直接体现冬小麦叶片对光合有效辐射的吸收能力,从而反映其光合作用的效率和生长状态,因此,4 月下旬至 5 月上旬的 FPAR 对冬小麦产量有着重要影响。

VTCI 在 3 月下旬至 5 月上旬期间有着较高的特征重要性。此期间冬小麦处于拔节期与抽穗-灌浆期。拔节期是冬小麦从营养生长向生殖生长过渡的关键时期。在这一阶段,植株开始积累大量养分,为后续的生殖生长(如穗的形成和籽粒的发育)提供必要的物质基础。抽穗-灌浆期是冬小麦光合作用和物质积累的高峰期。此时,植株的叶片仍保持较高的光合能力,能够产生大量有机物并输送到籽粒中。在这 2 个时期中冬小麦对水分和养分的需求达到高峰。如果此时水分或养分供应不足,会严重影响植株的生长和发育,进而导致产量下降。

LAI 在 4 月下旬至 5 月下旬期间有着较高的特征重要性。此期间冬小麦处于抽穗-灌浆期与乳熟期。抽穗-灌浆期的冬小麦对环境因素(如温度、光照、水分等)的变化非常敏感。不利环境条件可能导致光合作用受阻、物质积累减少或籽粒发育不良等问题,从而影响产量。乳熟期是冬小麦从灌浆到成熟的关键阶段,可反映冬小麦干物质积累和分配情况。较高的 LAI 意味着更多的光能被截获,从而有更多的干物质被生产并输送到籽粒中。较低的 LAI 则可能导致干物质积累不足,进而影响籽粒充实度和最终产量。

3 讨论

选取与冬小麦生长密切相关的遥感特征参数,结合 LSTM 模型在时序数据处理上的优势以及注意力机制在提取关键特征方面的能力,构建了 LSTM - AM 估产模型,并应用于陕西省关中平原冬小麦产量的估算。以往的冬小麦产量估测研究通常在生育时期尺度下进行,但这往往会造成对作物生长动态变化的忽视,无法充分反映作物在不同生长阶段的细微变化,最终导致特征信息丢失和估测结果准确性降低[28]。所采用的旬时间尺度提供了更高的时间分辨率,能够更精准地反映作物的动态生长过程,具有时效性强、对特征变化更敏感的优势。研究结果表明,引入注意力机制的 LSTM 模型能够有效捕捉旬尺度下 VTCI、LAI、FPAR 特征与产量之间复杂的非线性关系,表现出较高的估测精度。然而,尽管 LSTM - AM 模型在产量估测方面有着较好表现,但模型的估测结果仍存在一定程度的不确定性,主要源于模型本身的结构特性与参数设置,后续可采用集成学习的方法,将多个模型的预测结果进行组合,并对调整后的模型参数进行交叉验证,确定最优参数组合,以提高模型的鲁棒性与稳定性。

采用 PFI 法对基于 LSTM - AM 的冬小麦产量

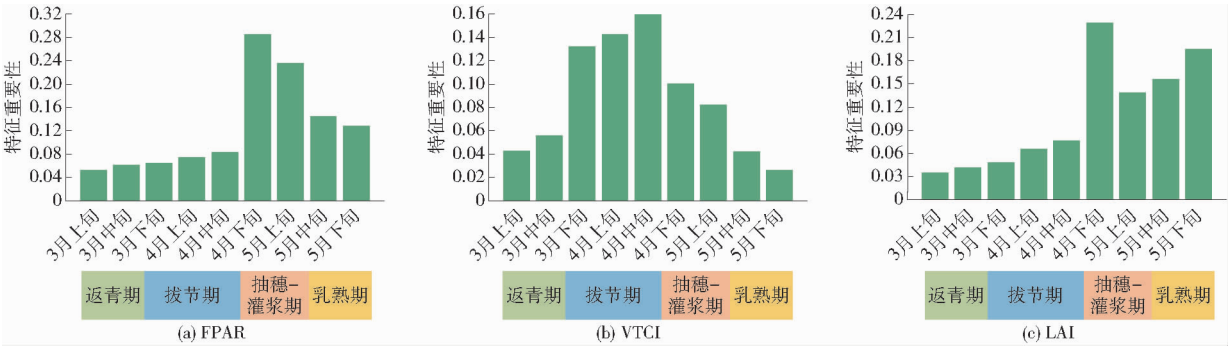

图 8 FPAR、VTCI、LAI 特征重要性

Fig. 8 Feature importance of FPAR, VTCI and LAI

估测模型进行了系统的可解释性分析，通过量化旬尺度下各特征参数的重要性，得到不同特征对冬小麦产量贡献的相对权重，提升了模型可解释性。分析结果显示，各特征重要性随时间的变化趋势相对平稳，未出现某一生育时期各旬特征重要性骤升骤降的变化情况，且特征重要性与前人利用 SHAP 法进行可解释性分析后得出的研究结果相符[29]。然而，本研究的可解释性分析主要聚焦于关中平原整体区域的特征差异性，尚未深入探讨区域内部各县域的具体特征表现。未来研究可进一步开展关中平原不同区域中更为细化的可解释性分析，以揭示小尺度区域内特征的重要性差异，从而为更精准的田间管理和农业决策提供依据，有助于针对特定区域环境条件制定更优化的农业管理政策，进一步提升冬小麦的产量及资源利用效率。

4　结论

（1）相较于传统 LSTM 模型，LSTM－AM 模型能够更有效地捕捉到与作物长势相关的特征信息，LSTM－AM 模型的 R^2 提升 0.05，RMSE 下降 31.38 kg/hm^2，MAPE 下降 0.54 个百分点，NRMSE 降低 0.04，表明 LSTM－AM 模型相较于 LSTM 模型在估测精度上有了进一步提升。此外，LSTM－AM 模型对于 LSTM 模型所存在的低产高估及高产低估现象均有所改善，表明该模型能够较好地适用于关中平原冬小麦产量估测。

（2）基于 VTCI、LAI 和 FPAR 组成的多参数特征组合构建了产量估测模型，相较于单参数与双参数构建的估产模型在性能上具有较大提升，表明模型能够在多参数组合中提取到更多有助于产量估测的信息，验证了本文选取特征的有效性。

（3）针对深度学习模型估测结果难以解释的情况，使用 PFI 算法对 LSTM－AM 冬小麦产量估测模型进行可解释性分析。结果表明，4 月下旬和 5 月上旬的 FPAR、3 月下旬至 5 月上旬 VTCI、4 月下旬至 5 月下旬 LAI 对冬小麦最终产量影响最大，研究结果有助于农业生产者后续制定及调整相关农业生产措施。

参　考　文　献

[1] KUWATA K, SHIBASAKI R. Estimating corn yield in the United States with MODIS EVI and machine learning methods[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, III－8: 131－136.

[2] ZHAO H, CHANG J F, HAVLIK P, et al. China's future food demand and its implications for trade and environment[J]. Nature Sustainability, 2021, 4(12): 1042－1051.

[3] TILMAN D, BALZER C, HILL J, et al. Global food demand and the sustainable intensification of agriculture[J]. Proceedings of the National Academy of Sciences of the United States of America, 2011, 108(50): 20260－20264.

[4] TIAN H R, WANG P X, TANSEY K, et al. A deep learning framework under attention mechanism for wheat yield estimation using remotely sensed indices in the Guanzhong Plain, PR China[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 102: 102375.

[5] 王鹏新, 李明启, 张悦, 等. 基于遥感多参数和 IPSO－WNN 的冬小麦单产估测[J]. 农业机械学报, 2024, 55(1): 154－163.
WANG Pengxin, LI Mingqi, ZHANG Yue, et al. Yield estimation of winter wheat based on remotely sensed multi-parameters and IPSO－WNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 154－163. (in Chinese)

[6] 赵春江. 农业遥感研究与应用进展[J]. 农业机械学报, 2014, 45(12): 277－293.
ZHAO Chunjiang. Advances of research and application in remote sensing for agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(12): 277－293. (in Chinese)

[7] 杨鹏, 吴文斌, 周清波, 等. 基于作物模型与叶面积指数遥感影像同化的区域单产估测研究[J]. 农业工程学报, 2007, 23(9): 130－136.
YANG Peng, WU Wenbin, ZHOU Qingbo, et al. Assimilating remotely sensed LAI into GIS-based EPIC model for yield assessment on regional scale[J]. Transactions of the CSAE, 2007, 23(9): 130－136. (in Chinese)

[8] TUNCA E, KOKSAL E S, CETIN S, et al. Yield and leaf area index estimations for sunflower plants using unmanned aerial vehicle images[J]. Environmental Monitoring and Assessment, 2018, 190: 682.

[9] 王鹏新, 田惠仁, 张悦, 等. 基于深度学习的作物长势监测和产量估测研究进展[J]. 农业机械学报, 2022, 53(2): 1－14.
WANG Pengxin, TIAN Huiren, ZHANG Yue, et al. Crop growth monitoring and yield estimation based on deep learning: state of the art and beyond[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 1－14. (in Chinese)

[10] 马雅丽, 郭建平, 栾青, 等. 持续性水分胁迫对冬小麦光合特性及产量的影响[J]. 气象, 2022, 48(10): 1303－1311.
MA Yali, GUO Jianping, LUAN Qing, et al. Effects of persistent water stress on photosynthetic characteristics and yield of winter wheat[J]. Meteorological Monthly, 2022, 48(10): 1303－1311. (in Chinese)

[11] 王鹏新, 孙辉涛, 王蕾, 等. 基于 4D－VAR 和条件植被温度指数的冬小麦单产估测[J]. 农业机械学报, 2016, 47(3): 263－271.
WANG Pengxin, SUN Huitao, WANG Lei, et al. Winter wheat yield estimation based on 4D variational assimilation method and remotely sensed vegetation temperature condition index[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(3): 263－271. (in Chinese)

[12] 王鹏新，王婕，田惠仁，等. 基于遥感多参数和门控循环单元网络的冬小麦单产估测[J]. 农业机械学报，2022，53(9)：207－216.
WANG Pengxin，WANG Jie，TIAN Huiren，et al. Yield estimation of winter wheat based on multiple remotely sensed parameters and gated recurrent unit neural network[J]. Transactions of the Chinese Society for Agricultural Machinery，2022，53(9)：207－216.(in Chinese)

[13] 刘峻明，和晓彤，王鹏新，等. 长时间序列气象数据结合随机森林法早期预测冬小麦产量[J]. 农业工程学报，2019，35(6)：158－166.
LIU Junming，HE Xiaotong，WANG Pengxin，et al. Early prediction of winter wheat yield with long time series meteorological data and random forest method[J]. Transactions of the CSAE，2019，35(6)：158－166.(in Chinese)

[14] TIAN H R，WANG P X，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.

[15] PEI W，BALTRUŠAITIS T，TAX D M J，et al. Temporal attention-gated model for robust sequence classification[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition，2017：6730－6739.

[16] 姜宇，马廷淮. 基于 CNN－LSTM－Attention 网络的河南省冬小麦产量预测[J]. 麦类作物学报，2024，44(10)：1352－1359.
JIANG Yu，MA Tinghuai. Prediction of Henan winter wheat yield using CNN－LSTM－Attention network[J]. Journal of Triticeae Crops，2024，44(10)：1352－1359.(in Chinese)

[17] 纪守领，李进锋，杜天宇，等. 机器学习模型可解释性方法、应用与安全研究综述[J]. 计算机研究与发展，2019，56(10)：2071－2096.
JI Shouling，LI Jinfeng，DU Tianyu，et al. Survey on techniques，applications and security of machine learning interpretability[J]. Journal of Computer Research and Development，2019，56(10)：2071－2096.(in Chinese)

[18] RIBEIRO M T，SINGH S，GUESTRIN C. "Why should I trust you?"：explaining the predictions of any classifier[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining，Association for Computing Machinery，2016：1135－1144.

[19] FRIEDMAN H J. Greedy function approximation：a gradient boosting machine[J]. The Annals of Statistics，2001，29(5)：1189－1232.

[20] FAN L，FANG S B，FAN J L，et al. Rice yield estimation using machine learning and feature selection in hilly and mountainous Chongqing，China[J]. Agriculture，2024，14(9)：1615.

[21] 丁莹莹，邱德勋，吴常雪，等. 关中平原极端降水时空变化及其与大气环流的关系[J]. 干旱区研究，2022，39(1)：104－112.
DING Yingying，QIU Dexun，WU Changxue，et al. Temporal and spatial variation of extreme precipitation in Guanzhong Plain and its relationship with atmospheric circulation[J]. Arid Zone Research，2022，39(1)：104－112.(in Chinese)

[22] 常艳丽，刘俊梅，李玉会，等. 陕西关中平原小麦/玉米轮作体系施肥现状调查与评价[J]. 西北农林科技大学学报(自然科学版)，2014，42(8)：51－61.
CHANG Yanli，LIU Junmei，LI Yuhui，et al. Investigation and evaluation of fertilization under winter wheat and summer maize rotation system in Guanzhong Plain，Shaanxi Province[J]. Journal of Northwest A&F University(Natural Science Edition)，2014，42(8)：51－61.(in Chinese)

[23] 孙威，王鹏新，韩丽娟，等. 条件植被温度指数干旱监测方法的完善[J]. 农业工程学报，2006，22(2)：22－26.
SUN Wei，WANG Pengxin，HAN Lijuan，et al. Further improvement of the approach to monitoring drought using vegetation and temperature condition indexes from multi years' remotely sensed data[J]. Transactions of the CSAE，2006，22(2)：22－26.(in Chinese)

[24] 王鹏新，龚健雅，李小文. 条件植被温度指数及其在干旱监测中的应用[J]. 武汉大学学报(信息科学版)，2001，26(5)：412－418.
WANG Pengxin，GONG Jianya，LI Xiaowen. Vegetation temperature condition index and its application for drought monitoring[J]. Geomatics and Information Science of Wuhan University，2001，26(5)：412－418.(in Chinese)

[25] 王鹏新，荀兰，李俐，等. 基于时间序列叶面积指数傅里叶变换的作物种植区域提取[J]. 农业工程学报，2017，33(21)：207－215.
WANG Pengxin，XUN Lan，LI Li，et al. Crop cultivation an extraction of planting areas of main crops based on Fourier transformed characteristics of time series leaf area index products[J]. Transactions of the CSAE，2017，33(21)：207－215.(in Chinese)

[26] HOCHREITER S，SCHMIDHUBER J. Long short-term memory[J]. Neural Computation，1997，9(8)：1735－1780.

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

[28] WANG J，WANG P X，TIAN H R，et al. A deep learning framework combining CNN and GRU for improving wheat yield estimates using time series remotely sensed multi-variables[J]. Computers and Electronics in Agriculture，2023，206：107705.

[29] GUO F W，WANG P X，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.