doi:10.6041/j.issn.1000-1298.2025.11.035

基于遥感多参数和 Stacking 集成学习的冬小麦单产估测

王鹏新[1,2]　王静怡[1,2]　郭丰玮[1,2]　刘峻明[3]　李红梅[4]　叶　昕[1]

(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: 为探究模型融合在估产领域的应用潜力,实现高精度冬小麦单产估测和预测,本文以陕西省关中平原为研究区域,选取与冬小麦长势密切相关的旬尺度叶面积指数(LAI)、光合有效辐射吸收比率(FPAR)和条件植被温度指数(VTCI)作为遥感特征参数,构建基于多模型融合的 Stacking 集成学习估产模型。考虑不同机器学习算法训练原理差异,将长短期记忆网络(LSTM)、支持向量机(SVM)、弹性网络回归(ENet)、极端梯度提升机(XGBoost)、梯度提升决策树(GBDT)、随机森林(RF)作为备选基模型。基于皮尔逊相关系数量化各模型预测误差之间的相关性,选择相关系数平均值最低的 LSTM、SVM、ENet 和 XGBoost 作为基模型。以每个基模型预测结果作为元特征,并将线性回归模型作为元模型对元特征进行拟合,构建 Stacking 冬小麦估产集成模型。结果表明,相较于精度最高的单一估产模型 SVM,Stacking 集成模型具有更高的估测精度(R^2 为 0.67、RMSE 为 520.50 kg/hm^2、MAPE 为 9.21%),其 R^2 提升 0.03,RMSE 和 MAPE 分别下降 26.28 kg/hm^2、0.83 个百分点,因此,Stacking 集成估产模型能够融合单个估产模型优势,进而获得更准确的估产结果。

关键词: 冬小麦; 估产; Stacking 集成学习; 条件植被温度指数; 叶面积指数

中图分类号: TP79　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0369-09　　**OSID**:

Yield Estimation of Winter Wheat Based on Multiple Remotely Sensed Parameters and Stacking Ensemble Learning

WANG Pengxin[1,2]　WANG Jingyi[1,2]　GUO Fengwei[1,2]　LIU Junming[3]　LI Hongmei[4]　YE Xin[1]

(1. *College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Key Laboratory of Agricultural Machinery Monitoring and Big Data Applications*, *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: Aiming to explore the application potential of model fusion in crop yield estimation and further improve the accuracy of winter wheat model for yield estimation, Guanzhong Plain in Shaanxi Province was taken as the study area, vegetation temperature condition index (VTCI), leaf area index (LAI) and fraction of photosynthetically active radiation (FPAR), which were closely related to the growth and development of winter wheat, were selected as remotely sensed parameters, and a Stacking ensemble learning yield estimation model was constructed based on multi-model fusion. Considering the differences in training process among various machine learning algorithms, the long short-term memory (LSTM) network, support vector machine (SVM), elastic net regression (ENet), eXtreme gradient boosting (XGBoost), gradient boosting decision trees (GBDT) and random forest (RF) as alternative base models. Pearson correlation coefficient was used to quantify the correlation between estimation errors of the alternative base models, and according to the average correlation coefficient of prediction errors for each alternative base model, LSTM, SVM, ENet, and XGBoost were selected as the base models with the lowest average correlation coefficients of prediction errors. The estimated yields from each of the base models were used as meta-features and a linear regression model was employed as the meta-model to fit

收稿日期: 2024-08-04　修回日期: 2024-09-16

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的应用研究,E-mail: wangpx@cau.edu.cn

these meta-features and construct a Stacking ensemble model for winter wheat yield estimation. The results showed that compared with single yield estimation model with the highest accuracy, SVM, the Stacking ensemble model exhibited improved estimation accuracy (R^2 = 0.67, RMSE = 520.50 kg/hm^2, MAPE = 9.21%), indicating an increase in R^2 by 0.03, and reductions in RMSE and MAPE by 26.28 kg/hm^2 and 0.83 percentage points, respectively. Therefore, the Stacking ensemble yield estimation model, by integrating the strengths of individual models, achieved more precise yield estimation results.

Key words: winter wheat; yield estimation; Stacking ensemble learning; vegetation temperature condition index; leaf area index

0 引言

粮食生产安全对于提升我国农业经营管理效能、优化农作物种植结构以及稳固国家粮食供应体系具有不可或缺的作用[1]。小麦作为主要粮食作物之一,其产量精确估测对粮食经济发展以及民生保障具有深远影响。传统的作物产量估测方法主要依赖田间实地调查,过程繁琐且规模有限[2]。相较于传统的估测方法,遥感技术以其广泛的监测范围、高分辨率以及较强的实时性,可实现对小麦生长状况大面积、长时间监测。从遥感数据中获取的植被指数和生物物理参数表征小麦在不同时期的生长状况,将生长参数作为自变量构建的产量估测模型能够更准确地估测小麦产量[3],为作物估产提供科学、高效的手段。

在众多遥感参数中,归一化植被指数(Normalized difference vegetation index, NDVI)可以评估作物生长状态,是追踪与监测作物生长的重要参数。生物物理参数,如叶面积指数(Leaf area index, LAI)和光合有效辐射吸收比率(Fraction of photosynthetically active radiation, FPAR),已成为监测作物长势和估测产量方面的重要数据源[4-5]。然而,作物产量的形成是一个复杂过程,其中水分胁迫特别是干旱现象对作物产量的形成构成了严重威胁。为了有效监测作物生长过程的水分胁迫,王鹏新等[6]根据 NDVI 与地表温度(Land surface temperature, LST)散点图所呈现的三角形分布特征,提出了条件植被温度指数(Vegetation temperature condition index, VTCI)。VTCI 作为近实时的干旱监测指数,能够有效评估作物水分胁迫状态,并在区域尺度干旱监测得到了广泛应用[7]。

目前常见的估产模型有参数模型和非参数模型。线性回归是常见的参数模型,其模型复杂度偏低,但受限于无法充分捕捉产量数据中的复杂关系,从而导致欠拟合现象。BECKER 等[8]使用双向反射分布函数(Bidirectional reflectance distribution function, BRDF)校正每日地表反射率,开发了一个基于广义回归的经验模型,可在堪萨斯州冬小麦收获前 42 d 进行产量预测,预测结果与实际收获小麦产量之间均方根误差为 180 kg/hm^2。非参数模型可进一步细化为基于传统机器学习的模型和基于深度学习的复杂模型[9]。传统机器学习模型通常划分为两大类:树结构模型与非树结构模型。树结构模型主要包括随机森林(Random forest, RF)、梯度提升决策树(Gradient boosting decision tree, GBDT)、极端梯度提升(eXtreme gradient boosting, XGBoost)、轻量级梯度提升机(Light gradient boosting machine, LightGBM)等。裴杰等[10]应用 RF 以及地理加权随机森林回归(Geographically weighted random forest regression, GWRFR)2 种算法,探析 RF 和 GWRFR 在玉米产量估测的应用效能,结果表明,GWRFR 估产模型可在收获前 2 ~ 3 个月估测玉米产量。树模型以其非参数化的特性,无需预设特定的函数表达式,进一步提升预测结果的可解释性。王鹏新等[11]构建基于 LightGBM 的冬小麦产量估测模型,利用局部可解释性模型无关方法和基于沙普利值的加性解释方法,在准确估测作物产量的同时,对模型估测结果给出合理的解释。但树模型在应对数据不平衡的挑战时,往往展现出较低的泛化能力,特别是在对少数类别(即小样本数据)的预测上,其准确性略显不足,一定程度上限制了模型在实际中的应用。

相较于树模型,非树型模型在回归预测的性能上展现出独特的优势和局限性。支持向量机(Support vector machine, SVM)[12]在处理非线性关系以及小样本数据集时,展现出较好的性能,然而其对于缺失数据的敏感度较高,并且在实际应用中,核函数限制了 SVM 的应用。深度学习模型凭借多层级非线性映射和自适应学习机制能够高效地抽取数据中的高级特征,在处理时序数据方面展现出显著优势。深度学习模型在遥感数据驱动的作物长势监测与产量预测领域已展示出巨大的应用潜力和价值[13-14]。然而,深度学习模型通常是黑盒模型,其内部工作原理和决策过程很难被直观地解释和理解。此外,在处理小样本数据时,深度学习模型可能

会出现过拟合现象。

单一的学习模型在解释能力上存在局限性，仅通过优化单一模型往往难以显著提升其性能，同时其预测性能受到诸多因素的限制。为克服这些限制，在基于集成学习思想构建的模型中，Stacking 模型以其独特的优势得到广泛应用[13-16]。尽管 Stacking 模型已经在作物估产领域取得了成功，但其在实际应用中仍面临一些挑战，包括如何恰当地选择基学习器和元学习器，以及如何处理并整合基学习器的预测结果等问题，都需要进一步深入研究和探索。

本文以陕西省关中平原为研究区域，选取旬尺度的 VTCI、LAI 和 FPAR 作为 Stacking 集成模型的输入特征参数，基于 Pearson 相关系数度量单一模型之间的误差相关性，以选取具备高估测精度同时表现出较强多样性的基模型，避免模型冗余。此外，基于 Stacking 集成策略对选取的估产模型进行有效集成，探讨 Stacking 集成模型估产表现，以期达到比单一模型更优的估产精度，并在提高估产精度的同时，进一步增强模型鲁棒性。

1　研究区域与数据

1.1　研究区域概况

关中平原位于陕西省中部，106°22′～110°24′E，33°57′～35°39′N（图 1），地势西高东低，是由渭河、洛河等河流形成的广阔平原地带。关中平原属温带大陆性气候，年均温 6～13℃，年降水量 550～700 mm。研究区域地势平坦、土地肥沃、气候温和，适宜耕种，是我国重要农业区域之一。灌区以冬小麦和夏玉米轮作为主，旱作区以冬小麦种植为主[17]，通常，冬小麦在 10 月播种，次年 6 月收获。

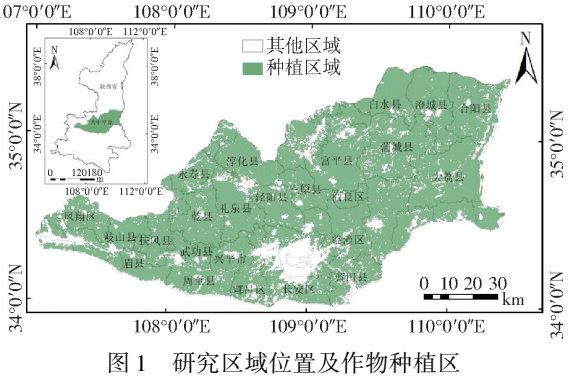


图 1　研究区域位置及作物种植区

Fig. 1　Location of study area and crop planting areas

1.2　数据来源与预处理

1.2.1　数据来源

采用的遥感数据来自美国国家航空航天局地球观测系统数据和信息系统网站，包括 2011—2022 年每年 3 月上旬—5 月下旬的 MODIS 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吸收比率产品（MCD15A3H）以及地表覆盖类型产品（MCD12Q1）。冬小麦产量数据来自于陕西省统计局发布的《陕西统计年鉴》。以 2011—2022 年关中平原 24 个县的旬尺度 VTCI、LAI、FPAR 以及冬小麦单产数据为基础开展相关研究。

1.2.2　冬小麦种植区域提取

采用 Terra 和 Aqua 卫星上的 MODIS 传感器获取的地表覆盖类型产品（MCD12Q1），利用 MODIS 重投影工具（MODIS reprojection tools，MRT）对 MCD12Q1 数据进行预处理，将处理后的数据与关中平原行政边界矢量图叠加，得到各县（区）冬小麦种植区。2022 年关中平原冬小麦种植区分布如图 1 所示。

1.2.3　VTCI 数据生成

VTCI 由 MODIS 的地表温度产品（MYD11A1）和地表反射率产品（MYD09GA）计算生成。选取 2011—2022 年关中平原每年 3—5 月的 MYD11A1 和 MYD09GA 产品，其空间分辨率为 1 000 m，时间分辨率为 1 d。利用 MRT 工具分别对二者进行投影转换、重采样、影像拼接和剪裁等预处理，分别获取每年日 LST 和日 NDVI，通过日 LST 和日 NDVI 逐像素生成旬 LST 和旬 NDVI 最大合成产品。基于多年某一旬 LST 最大值合成产品，应用最小值合成技术，生成多年旬尺度 LST 最大-最小值合成产品。基于多年旬尺度 LST 和 NDVI 最大值合成产品确定 VTCI 热边界，基于多年旬尺度 LST 最大-最小值合成产品和 NDVI 最大值合成产品确定 VTCI 冷边界。通过以上处理后，旬尺度 VTCI[18] 计算式为

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

其中

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

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

式中　$VTCI$——条件植被温度指数

N_i——某一像素 NDVI 值

$L(N_i)$——研究区域内某一像素 NDVI 值为 N_i 时地表温度

$L_{\max}(N_i)$、$L_{\min}(N_i)$——研究区域内当 NDVI 值为 N_i 时所有像素地表温度最大值和最小值，即热边界和冷边界

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

基于3—5月生成的9旬VTCI影像,叠加关中平原县(区)冬小麦种植区分布图,逐像素取各县所包含的像素平均值作为该县旬VTCI。

1.2.4 LAI和FPAR数据生成

LAI和FPAR由MODIS的MCD15A3H生成。选取2011—2022年关中平原每年3—5月空间分辨率为500 m、时间分辨率为4 d的LAI和FPAR数据,并且对原始的LAI和FPAR数据进行上包络线Savitzky-Golay(S-G)滤波平滑去噪处理,以避免因云和大气等因素对数据质量的影响。将滤波后的LAI和FPAR影像应用最大值合成的方法逐像素地生成每年3—5月旬尺度LAI和FPAR。根据关中平原24县(区)冬小麦种植区域分布图,逐像素取各县所包含的像素平均值作为该县该旬LAI和FPAR。

VTCI和FPAR均在0~1,故对LAI进行归一化处理,处理后VTCI空间分辨率为1 000 m,而LAI和FPAR空间分辨率为500 m,为了使三者的空间分辨率一致,使用最邻近采样技术将VTCI重采样为500 m的空间分辨率。由于冬小麦产量为2 000~7 000 kg/hm^2,对产量进行归一化处理,使VTCI、LAI、FPAR和产量处于0~1。

2 研究方法

2.1 单一模型

对于单一估测模型而言,其估测精度往往受限于边际效用。Stacking方法将不同的机器学习算法按照特定策略进行组合,以达到比单一模型更优异的性能,但基模型性能对于Stacking集成模型最终性能具有决定性的影响。因此Stacking模型构建过程中,需根据每个基模型独立估测能力,考量基模型组合后的整体效果。

为确保Stacking集成学习模型能够达到较好的估测精度,选用RF、GBDT、XGBoost、SVM、弹性网络回归(Elastic net regression,ENet)、LSTM作为备选基模型。每个基模型基于网格验证和交叉验证寻找最优参数,各机器学习算法最优参数设置如下:RF通过自助聚合(Bootstrap aggregating,Bagging)集成策略结合多棵决策树改进模型的预测准确性和稳定性,RF设置决策树个数为100,叶节点最小样本数为1,每个节点划分时考虑的特征数量比例为1。SVM在处理小样本、非线性及高维回归问题时,有其独特的优势[19]。通过比较不同核函数,设置SVM核函数类型为linear,正则化参数为10,使用scale自动调整核函数系数。GBDT和XGBoost[20]通过提升算法逐步优化,估测能力更强、训练过程更高效。GBDT模型树最大深度设置为3,树数量为100,学习率为0.1。XGBoost模型树最大深度设置为3,树数量为300,学习率为0.01。ENet[21]通过在损失函数中同时加入L1和L2正则化项进行参数估计,并结合套索回归的变量选择能力和岭回归处理共线性能力,可有效地减少模型过拟合。将控制L1正则化和L2正则化比例参数L1ratio设置为0.9,正则化强度值设置为0.1。LSTM是一种特殊的循环神经网络(Recurrent neural network,RNN)架构,用于解决传统RNN在处理长序列时存在的梯度消失和梯度爆炸问题[22]。设置LSTM单元数量为50,使用ReLU激活函数,训练批次样本数量为128。为最大化Stacking模型估测性能,在Stacking集成模型架构第1层中选择估测结果差异度较大的模型作为基模型。

对于第2层模型的选择,选用简单而直观的线性回归作为元模型。其作为元模型可以在所使用的小样本数据中,更容易观察和理解各个变量对估产结果的影响,也能够在一定程度上提高Stacking模型稳定性。此外,在小样本数据中使用由多模型组合而成的较为复杂Stacking模型结合线性回归作为元模型,能够减少模型训练时间。

2.2 基模型选择

在产量估测模型集成过程中,若多个独立产量估测模型估测结果呈高度相似性,则会导致信息冗余,进而影响整个模型集成估测精度。因此,构建Stacking集成模型时,为确保基模型多样性并减少模型数量,需要对各单一估产模型估测误差相似性进行判别,避免模型冗余[23]。为选择最佳基模型进行组合,本研究构建多个单一估产模型,将各个单一模型单独进行小麦估产所产生的估测误差进行比较,采用Pearson相关系数作为相关性指标,计算各模型间误差相关系数,以量化它们之间的相关性。

根据各模型间估测误差的相关系数,计算每个单一模型与其他模型估测误差相关系数平均值,从6个备选基模型中选择相关系数平均值最小的4个模型作为基模型。

2.3 Stacking集成学习模型构建

Stacking集成方法将多个基模型(也称作初级学习器)估测结果作为元特征,随后使用一个元模型(也称作次级学习器)对元特征进一步的估测,生成最终估测结果[24]。Stacking模型结构如图2所示,基于Stacking集成模型的冬小麦产量估测流程为:

(1)2011—2022年间关中平原24个县(区)3—5月旬尺度VTCI、LAI、FPAR,以及相应年份的单产

数据，共构成 288 组样本。采用随机抽样的方式对样本进行划分，选取 70% 的样本作为训练集，用于模型构建和参数调整，剩余 30% 样本作为测试集，评估模型泛化能力和估测准确性。

(2)采用网格搜索和交叉验证的方法优化每个基模型的超参数。运用 Pearson 相关系数量化各个估测算法在训练过程中的估测误差分布情况，并基于这些差异，选取误差表现差异较大的模型作为 Stacking 框架中的第 1 层基模型。

(3)在模型超参数调优后，若直接利用基模型训练集的估测结果构造次级训练集，可能会出现过拟合现象。为防止数据在双层学习架构中被重复使用，采用 5 折交叉验证对训练集的使用过程进行划分(图 2)。使用划分后的训练集对 Stacking 框架中的第 1 层基模型分别进行训练。训练完成后，将各模型估测结果整合生成用于下一阶段训练的新数据集。

(4)利用新生成的数据集对 Stacking 框架中的第 2 层元模型进行训练。完成基于多模型融合的 Stacking 集成学习算法的训练，再将测试集经过训练好的基模型处理和训练好的元模型处理等步骤，得到测试集估测结果，并评估模型。

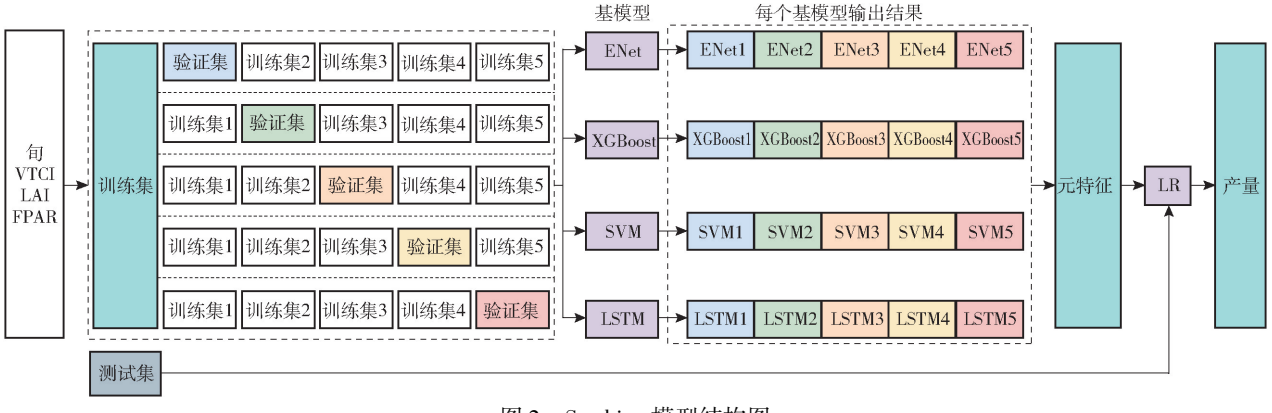


图 2　Stacking 模型结构图

Fig. 2　Structure diagram of Stacking model

2.4　模型性能评估

使用决定系数(Coefficient of determination，R^2)、均方根误差(Root mean squared error，RMSE)以及平均绝对百分比误差(Mean absolute percentage error，MAPE)作为性能评估指标。

3　结果与分析

3.1　基模型确定

通过每个单一模型与其他模型估测误差平均 Pearson 相关系数，从 SVM、LSTM、ENet、XGBoost、GBDT、RF 单一模型中选出合适的模型作为基模型。单一模型估测误差间的 Pearson 相关系数如表 1 所示。根据每一个单一模型与其他 5 个单一模型之间的相关系数，计算当前单一模型与其他 5 个单一模型误差相关系数平均值，选择相关系数平均值最小的 SVM(0.80)、XGBoost(0.80)、ENet(0.81)、LSTM(0.47)作为基模型，以构建最优基模型组合的 Stacking 集成模型。为验证基于 Pearson 相关系数进行基模型选择以避免模型冗余可行性，构建 2 个由不同基模型组合所构建的 Stacking 集成模型，将 2 个 Stacking 模型在同一测试集下的统计产量与估测产量进行回归分析，结果如图 3 所示。可以看出，由 SVM、LSTM、ENet、XGBoost、GBDT、RF 作为基模型

表 1　单一估产模型估测误差 Pearson 相关系数

Tab. 1　Pearson correlation coefficient value of estimation error in single yield estimation model

单一模型	SVM	RF	XGBoost	ENet	LSTM	GBDT
SVM	1	0.92	0.88	0.93	0.35	0.93
RF	0.92	1	0.97	0.91	0.37	0.98
XGBoost	0.88	0.97	1	0.86	0.86	0.97
ENet	0.93	0.91	0.86	1	0.42	0.93
LSTM	0.35	0.37	0.33	0.42	1	0.34
GBDT	0.93	0.98	0.97	0.93	0.34	1
平均值	0.80	0.83	0.80	0.81	0.47	0.83

所构建的 Stacking 集成模型 R^2 达到 0.67，而基于模型误差的 Pearson 相关系数，选择 SVM、LSTM、ENet、XGBoost 作为基模型构建的 Stacking 集成模型，在基模型精简情况下依然能够达到相同产量估测精度(R^2 为 0.67)。基于 Pearson 相关系数选择基模型，可以在不牺牲模型性能情况下，通过选择误差相关性低的基模型避免模型冗余，从而减少模型复杂性。因此，基于 Pearson 相关系数的基模型选择方法在提升模型效率与保持产量估测准确度方面表现出较好的可行性。

3.2　单一模型和 Stacking 集成模型性能对比

构建的 Stacking 集成模型和 LSTM、SVM、XGBoost、ENet 单一模型 R^2、RMSE 和 MAPE 如

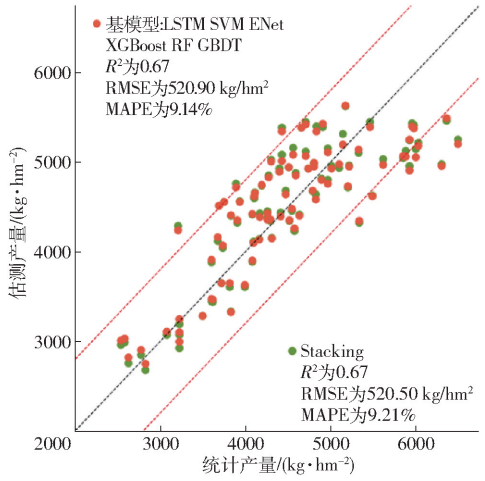


图 3 不同基模型构建的 Stacking 模型精度对比

Fig. 3 Comparison of Stacking model accuracy based on different numbers of base models

表 2 所示。与单一模型相比,Stacking 集成模型达到更优的估测精度(RMSE 为 520.50 kg/hm²,MAPE 为 9.21%,R^2 为 0.67)。相较于估测精度最高的单一估测模型 SVM(RMSE 为 546.78 kg/hm²,MAPE 为 10.04%,R^2 为 0.64),R^2 增加 0.03,RMSE 和 MAPE 分别减少 26.28 kg/hm² 和 0.83 个百分点,

表 2 模型估测精度

Tab. 2 Estimation results of models

模型	R^2	RMSE/(kg·hm⁻²)	MAPE/%
LSTM	0.55	613.19	11.65
SVM	0.64	546.78	10.04
XGBoost	0.63	554.54	9.93
ENet	0.59	584.99	9.88
Stacking	0.67	520.50	9.21

Stacking 估产模型 R^2、RMSE 与 MAPE 均得到提升,表明 Stacking 集成模型可实现比单一模型更高的估测精度。

Stacking 集成模型同 4 个单一模型小麦统计产量与估测产量回归分析结果如图 4 所示。从整体上看,5 种模型统计产量与估测产量散点大致分布在1∶1线,大多数散点处于误差 800 kg/hm² 内,少数散点统计产量与估测产量之间误差大于 800 kg/hm²。根据统计单产,将产量划分为低产(低于 3 500 kg/hm²)、中产(3 500 ~ 5 000 kg/hm²)和高产(超过 5 000 kg/hm²)3 个产量区间。由于样本量以及样本不均衡的原因,冬小麦产量主要在 3 500 ~ 5 000 kg/hm² 区间内,低于 3 500 kg/hm² 的低产样本和超过 5 000 kg/hm²

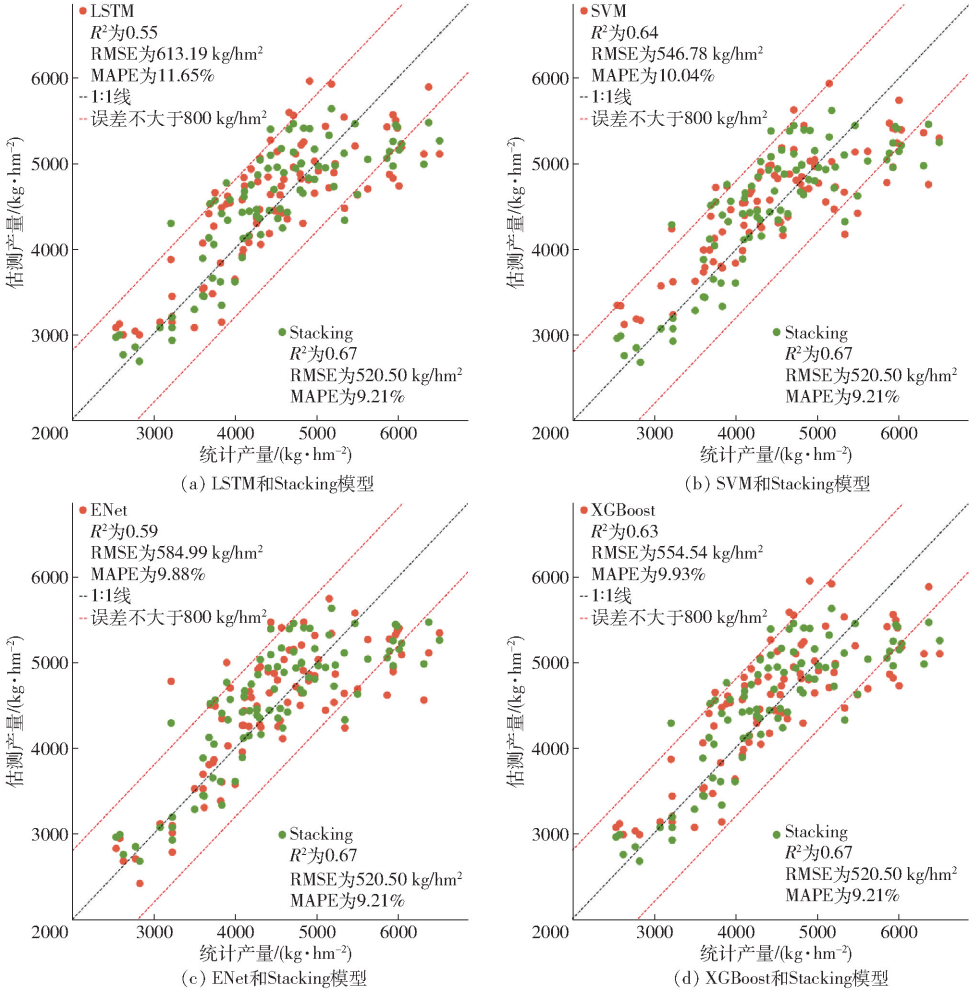


图 4 单一基模型和 Stacking 集成模型单产估测精度对比

Fig. 4 Comparison of yield estimation accuracy between single base model and Stacking ensemble model

的高产样本数量较少，单一模型和 Stacking 集成模型均较容易出现高产低估或低产高估的现象[25]，在低产以及高产范围内的统计产量与估测产量之间的误差较大，产量估测精度均有所下降。但从 4 个单一模型和 Stacking 集成模型在高产或低产的局部产量估测来看，Stacking 集成模型在对局部产量估测表现优于单一模型。相较于单一估产模型，Stacking 模型在低产或高产部分的散点更接近 1∶1 线，并且在高产部分的预测误差大多分布在误差线 ±800 kg/hm^2 以内，对于低产高估以及高产低估现象有所改善，表明 Stacking 模型在局部产量范围内估测准确性和拟合能力有所提高。

单一估产模型和 Stacking 集成模型在不同产量区间的残差箱形图，如图 5 所示。在低产区间，单一模型和 Stacking 集成模型都是负残差占主体，相较于 LSTM、SVM、ENet、XGBoost 单一估产模型，Stacking 模型残差更接近于 0，低产量估测效果较好，且估测效果显著优于 LSTM 和 SVM 模型，较 XGBoost 和 ENet 模型也有所提升，表明 Stacking 集成模型对于低产量数据特征的捕获优于单一估产模型。在中产区间，单一模型和 Stacking 模型残差基本都在 0 上下，对于中产量数据特征均显示出较好的捕捉能力。在高产区间，单一模型和 Stacking 集成模型都是正残差占主体，但 Stacking 集成模型正残差整体小，在高产量估测方面表现优于 LSTM、SVM、ENet 和 XGBoost 单一产量估测模型。因此，与单一基模型相比，Stacking 集成模型在不同产量区间进行单产估测性能表现更优，进一步表明 Stacking 集成模型在局部特征提取过程中的优势，能够更准确地捕捉与冬小麦产量紧密相关的信息。

3.3　冬小麦估测产量时空变化

基于旬尺度的多参数构建的 Stacking 集成模型，逐像素估测关中平原 2018—2023 年冬小麦产量（图 6）。由图 6 可知，研究区域冬小麦产量呈由西向东递减空间分布。根据冬小麦单产年际变化可以看出，2018—2023 年冬小麦产量呈增长趋势，但在个别年份，产量出现较为明显波动。2019 年因气温异常升高而引发阶段性干旱现象，影响冬小麦生长发育，导致该年度冬小麦产量呈近几年最低。2023 年 5 月下旬至 6 月上旬阴雨天气导致关中平原小麦灌浆受阻，部分小麦根系和叶片早衰，光合作用速率低，最终造成 2023 年小麦产量有所下降。而 2020 年、2021 年和 2022 年，在冬小麦生长关键期，雨水充沛，温度条件较为理想，这些因素共同促成较高的产量表现，估测结果与实际情况相符。

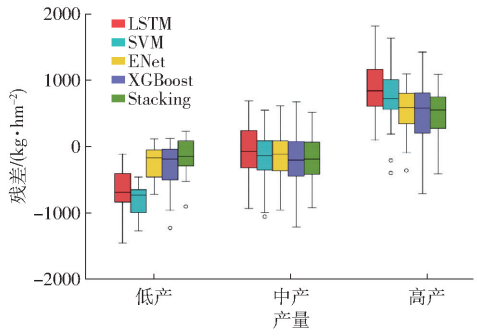


图 5　单一基模型和 Stacking 模型在不同产量区间残差箱形图

Fig. 5　Box plot of yield residuals at different yield intervals using Stacking model and single models

4　讨论

选取 VTCI、LAI 和 FPAR 3 个遥感参数作为模型输入特征，构建 Stacking 估产模型估测关中平原冬小麦产量。结果表明，Stacking 集成模型在单产估测领域具有一定的适用性。但本文在特征变量选择上，虽聚焦于与小麦长势及单产紧密相关的

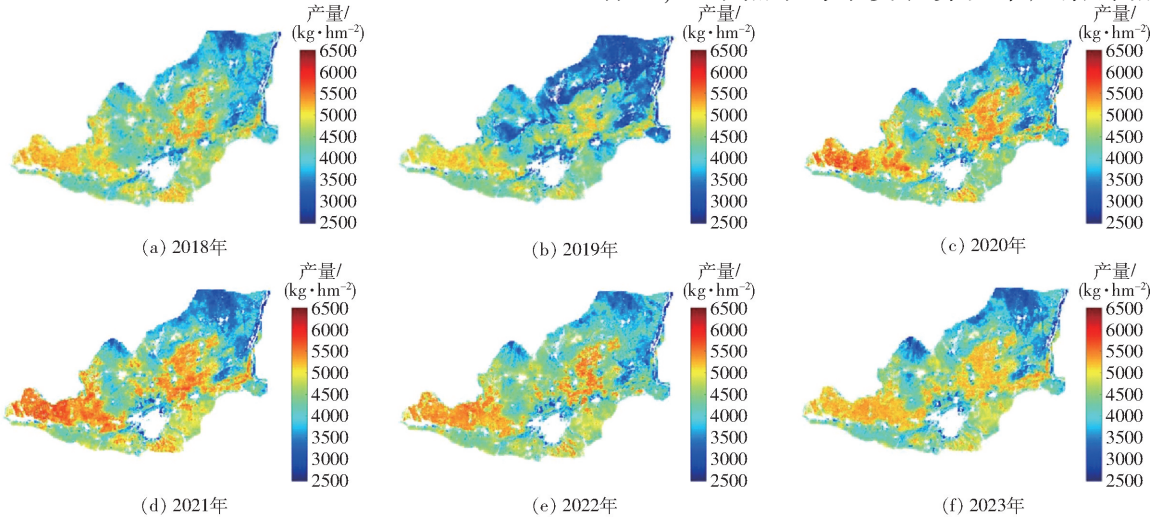


图 6　2018—2023 年关中平原冬小麦单产估测结果

Fig. 6　Estimation results of winter wheat yield in Guanzhong Plain from 2018 to 2023

VTCI、FPAR 和 LAI,然而,小麦生长发育过程还会受到温度、土壤肥力等因素的影响。鉴于此,未来可以考虑整合土壤和气象等数据为输入参数,以实现更为全面且准确的小麦产量估测。

由于 Stacking 方法涉及多个模型的训练和估测,计算资源和时间消耗较高,故选择计算复杂度相对较低的线性回归作为元模型。然而,元模型选择并不仅限于线性回归,故在未来研究中可尝试选择岭回归、朴素贝叶斯等模型作为元模型,研究其在冬小麦单产估测中的表现,以找到最优元模型。此外,未来将探索更多的如 Transformer、二维卷积神经网络等深度学习模型算法作为基模型,尝试更多不同的基模型组合,进一步提升 Stacking 模型性能。

基于 Stacking 集成模型可实现对不同算法模型优势的深度融合。但鉴于 Stacking 框架构造,需对每个基模型依次进行寻找最优参数和多次训练。未来将尝试构建分布式计算环境,以实现对不同基础模型的并行化建模,降低算法时间复杂度,进一步提升 Stacking 集成学习整体效率。

5 结论

(1)以 SVM、LSTM、ENet、XGBoost、GBDT 及 RF 作为基模型构建的集成模型 R^2 为 0.67;分析模型间的误差关联,利用模型误差间的 Pearson 相关系数优化基模型选择,仅选取 SVM、LSTM、ENet、XGBoost 作为基模型构建 Stacking 集成模型,同样达到 R^2 为 0.67 的估测精度。在减少基础模型数量的同时,不牺牲模型估测能力,可以达到相同的估测精度,表明基于 Pearson 相关系数筛选基模型以避免模型冗余的策略是可行的。

(2)构建的 Stacking 集成模型的冬小麦产量估测精度优于 LSTM、SVM、ENet 和 XGBoost 单一估测模型。相较于估测精度最高的单一模型 SVM,Stacking 集成模型估测精度 RMSE、MAPE 分别降低 26.28 kg/hm^2 和 0.83 个百分点,R^2 提高 0.03。此外,Stacking 集成模型对于单一估产模型所存在的高产低估和低产高估现象有所改善,在捕捉与冬小麦产量紧密相关的信息方面,展现较好的准确性。

(3)基于最优 Stacking 集成模型逐像素的产量估测结果表明,关中平原冬小麦产量在空间分布上符合关中平原西部较高而东部较低的产量分布特征。从年际变化可以看出,估测产量总体呈上升趋势,时间变化特征与实际情况及基本一致。

参 考 文 献

[1] 宋成阳, 耿洪伟, 费帅鹏, 等. 基于多源数据的小麦品种产量估测研究[J]. 光谱学与光谱分析, 2023, 43(7): 2210-2219.
SONG Chengyang, GENG Hongwei, FEI Shuaipeng, et al. Study on yield estimation of wheat varieties based on multi-source data[J]. Spectroscopy and Spectral Analysis, 2023, 43(7): 2210-2219. (in Chinese)

[2] TIAN H, WANG P, 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.

[3] 陈仲新, 任建强, 唐华俊, 等. 农业遥感研究应用进展与展望[J]. 遥感学报, 2016, 20(5): 748-767.
CHEN Zhongxin, REN Jianqiang, TANG Huajun, et al. Progress and perspectives on agricultural remote sensing research and applications in China[J]. Journal of Remote Sensing, 2016, 20(5): 748-767. (in Chinese)

[4] 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)

[5] 任建强, 陈仲新, 周清波, 等. MODIS 植被指数的美国玉米单产遥感估测[J]. 遥感学报, 2015, 19(4): 568-577.
REN Jianqiang, CHEN Zhongxin, ZHOU Qingbo, et al, MODIS vegetation index data used for estimating corn yield in USA[J]. Journal of Remote Sensing, 2015, 19(4): 568-577. (in Chinese)

[6] 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)

[7] 李艳, 王鹏新, 刘峻明, 等. 基于条件植被温度指数的冬小麦主要生育时期干旱监测效果评价Ⅲ——干旱对冬小麦产量的影响评估[J]. 干旱地区农业研究, 2014, 32(5): 218-222.
LI Yan, WANG Pengxin, LIU Junming, et al. Evaluation of drought monitoring effects in the main growth and development stages of winter wheat using vegetation temperature condition index Ⅲ—impact evaluation of drought on wheat yield[J]. Agricultural Research in the Arid Areas, 2014, 32(5): 218-222. (in Chinese)

[8] BECKER R I, VERMOTE E, LINDEMAN M, et al. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data[J]. Remote Sensing of Environment, 2010, 114(6): 1312-1323.

[9] 史佳琪，张建华. 基于多模型融合 Stacking 集成学习方式的负荷预测方法[J]. 中国电机工程学报，2019，39(14)：4032－4042.
SHI Jiaqi，ZHANG Jianhua. Load forecasting based on multi-model by Stacking ensemble learning[J]. Proceedings of the CSEE，2019，39(14)：4032－4042.（in Chinese）

[10] 裴杰，谭绍锋，郭韩，等. 结合 GWRFR 和作物物候信息的玉米产量早期预测[J]. 农业工程学报，2024，40(1)：153－161.
PEI Jie，TAN Shaofeng，GUO Han，et al. Early prediction of maize yield by integrating GWRFR and crop[J]. Transactions of the CSAE，2024，40(1)：153－161.（in Chinese）

[11] 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 LinghtGBM[J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(12)：197－206.（in Chinese）

[12] 黎锐，李存军，徐新刚，等. 基于支持向量回归(SVR)和多时相遥感数据的冬小麦估产[J]. 农业工程学报，2009，25(7)：114－117.
LI Rui，LI Cunjun，XU Xin'gang，et al. Winter wheat yield estimation based on support vector machine regression and multi-temporal remote sensing data[J]. Transactions of the CSAE，2009，25(7)：114－117.（in Chinese）

[13] REICHSTEIN M，CAMPSVALLS G，STEVENS B，et al. Deep learning and process understanding for data-driven earth system science[J]. Nature，2019，566(7743)：195－204.

[14] 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 different model[J]. Spectroscopy and Spectral Analysis，2023，43(8)：2627－2637.（in Chinese）

[15] 费帅鹏，禹小龙，兰铭，等. 基于高光谱遥感和集成学习方法的冬小麦产量估测研究[J]. 中国农业科学，2021，54(16)：3417－3427.
FEI Shuaipeng，YU Xiaolong，LAN Ming，et al. Research on winter wheat yield estimation based on hyperspectral remote sensing and ensemble learning method[J]. Scientia Agricultura Sinica，2021，54(16)：3417－3427.（in Chinese）

[16] 陈一凡，李璇，王绍雯，等. 集成学习结合多源数据预测河南省冬小麦单产[J]. 农业工程学报，2024，40(4)：177－185.
CHEN Yifan，LI Xuan，WANG Shaowen，et al. Predicting winter wheat yield per uint area in Henan Province of China using ensemble learning and multi-source data[J]. Transactions of the CSAE，2024，40(4)：177－185.（in Chinese）

[17] 郭丰玮，王鹏新，刘峻明，等. 基于遥感多参数和 VMD－GRU 的冬小麦单产估测[J]. 农业机械学报，2024，55(1)：164－174,185.
GUO Fengwei，WANG Pengxin，LIU Junming，et al. Yield estimation of winter wheat based on multiple remotely sensed parameters and VMD－GRU[J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(1)：164－174，185.（in Chinese）

[18] 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）

[19] 王振武，孙佳骏，尹成峰. 改进粒子群算法优化的支持向量机及其应用[J]. 哈尔滨工程大学学报，2016，37(12)：1728－1733.
WANG Zhenwu，SUN Jiajun，YIN Chengfeng. A support vector machine based on an improved particle swarm optimization algorithm and its application[J]. Journal of Harbin Engineering University，2016，37(12)：1728－1733.（in Chinese）

[20] BILALI B E，HADRI A，TALEB A，et al. A novel hybrid modeling approach based on empirical methods，PSO，Xgboost，and multiple GCMS for forecasting long-term reference evapotranspiration in a data scarce-area[J]. Computers and Electronics in Agriculture，2025，232：110106.

[21] 方维维，刘梦然，王云鹏，等. 面向物联网隐私数据分析的分布式弹性网络回归学习算法[J]. 电子与信息学报，2020，42(10)：2403－2411.
FANG Weiwei，LIU Mengran，WANG Yunpeng，et al. A distributed elastic net regression algorithm for private data analytics in Inernet of Things[J]. Journal of Electronics & Information Technology，2020，42(10)：2403－2411.（in Chinese）

[22] LIU Q，WANG Q，WANG X. Rvfl－LSTM：a lightweight model with long-short term memory for time series[J]. Knowledge-Based Systems，2025，309：112896.

[23] TANG E，SUGANTHAN P，YAO X. An analysis of diversity measures[J]. Machine Learning，2006，65(1)：247－271.

[24] CAO H，GU Y，FANG J，et al. Application of stacking ensemble learning model in quantitative analysis of biomaterial activity[J]. Microchemical Journal，2022，183：108075.

[25] 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）