

DOI: 10.16210/j.cnki.1007-7561.2024.02.024

陈家豪, 李嘉欣, 郑德乾, 等. 基于 GWO-BP 神经网络及粮食压缩实验对粮食孔隙率的预测[J]. 粮油食品科技, 2024, 32(2): 186-193.

CHEN J H, LI J X, ZHENG D Q, et al. Prediction of grain porosity based on GWO-BP neural network and grain compression experiment[J].

Science and Technology of Cereals, Oils and Foods, 2024, 32(2): 186-193.

基于 GWO-BP 神经网络及粮食压缩实验对粮食孔隙率的预测

陈家豪^{1,2}, 李嘉欣¹, 郑德乾¹, 尹君³, 黄海荣¹, 葛蒙蒙¹, 张佳怡¹

(1. 河南工业大学 土木工程学院, 河南 郑州 450001;

2. 河南省粮油仓储建筑与安全重点实验室, 河南 郑州 450001;

3. 国家粮食和物资储备局科学研究院 粮食储运研究所, 北京 100037)

摘要: 孔隙率是影响粮堆内热湿传递的关键参数, 为探究粮仓中散装粮堆孔隙率的分布规律, 通过开展粮食压缩实验来获取不同的粮食种类在不同水分含量和竖向压力条件下的孔隙率。提出了一种基于灰狼算法优化 BP (GWO-BP) 神经网络的粮食单元体孔隙率预测模型, 并将该模型与 BP 神经网络模型、随机森林模型的孔隙率预测结果进行对比, 最后利用粮食单元箱实验对该模型的泛化能力进行验证。结果表明, GWO-BP 神经网络模型的孔隙率预测性能最佳, 该模型的评价指标 R^2 为 0.960 5、RMSE 为 0.013 7 及 MAE 为 0.013 1, 均在允许的范围。本研究为粮食孔隙率的确定提供了一种神经网络预测的方法, 为深入开展粮堆多场耦合分析提供了重要基础, 为安全储粮提供了理论支持。

关键词: GWO-BP 模型; 粮食孔隙率; 压缩实验; 预测

中图分类号: S379.9 文献标识码: A 文章编号: 1007-7561(2024)02-0186-08

网络首发时间: 2023-12-27 13:23:41

网络首发地址: <https://link.cnki.net/urlid/11.3863.TS.20231226.1559.002>

Prediction of Grain Porosity Based on GWO-BP Neural Network and Grain Compression Experiment

CHEN Jia-hao^{1,2}, LI Jia-xin¹, ZHENG De-qian¹, YIN Jun³, HUANG Hai-rong¹,
GE Meng-meng¹, ZHANG Jia-yi¹

(1. College of Civil Engineering, Henan University of Technology, Zhengzhou, Henan 450001, China;

2. Henan Key Laboratory of Grain Storage Facility and Safety, Zhengzhou, Henan 450001, China;

3. Institute of Grain Storage and Logistics, Academy of National Food and Strategic Reserves Administration, Beijing 100037, China)

Abstract: Porosity is a key parameter that affects the heat and moisture transfer within a grain pile. In order

收稿日期: 2023-10-05

基金项目: 国家自然科学基金 (51608176); 河南省省级科技研发计划联合基金 (应用攻关类) (222103810082); 河南省粮油仓储建筑与安全重点实验室开放课题 (2020KF-B01); 河南工业大学青年骨干教师培育计划 (21420155)

Supported by: National Natural Science Foundation of China (No. 51608176); Joint Fund for Provincial Science and Technology Research and Development Programmes in Henan Province (Application Research Category) (No. 222103810082); Henan Provincial Key Laboratory of Grain and Oil Warehousing Construction and Safety Open Subjects (No. 2020KF-B01); Cultivation Programme for Young Backbone Teachers of Henan University of Technology (No. 21420155)

作者简介: 陈家豪, 男, 1985 年出生, 博士, 副教授, 研究方向为散体压力理论及仓储结构。E-mail: 1142653303@qq.com

to investigate the distribution law of porosity in bulk grain piles in grain silos, grain compression experiment was carried out to obtain the porosity of different grain types under different moisture content and vertical pressure conditions. A porosity prediction model for grain cell based on GWO-BP neural network was proposed, and the model was compared with the porosity prediction results of BP neural network model and random forest model. Finally, the generalization ability of the model was verified using the grain cell box test. The results showed that the porosity prediction performance of the GWO-BP neural network model was the best, and the evaluation indexes of the model, including R^2 of 0.960 5, RMSE of 0.013 7 and MAE of 0.013 1, were all within the permissible range. This study has provided a neural network prediction method for the determination of grain porosity, which could provide an important foundation for in-depth multi-field coupling analysis of grain piles and theoretical support for safe grain storage.

Key words: GWO-BP model; grain porosity; compression test; prediction

我国是粮食生产大国，也是储粮大国。粮食在储藏过程中易引发粮堆局部的结露、发热、霉变等问题，从而造成严重的储粮损失^[1-2]。粮仓机械通风是保障粮食安全储存的有效控制措施，粮堆中的孔隙结构复杂多变影响通风过程中的气流速度、气流方向以及通风效率，进而影响粮食的储藏品质^[3-4]。近年来，粮仓内粮堆的多场耦合理论是安全储粮领域的研究重点，粮堆孔隙率是影响热湿传递、储粮通风等的关键参数^[5]。因此，粮堆孔隙率的测定研究对计算粮堆的通风阻力、掌握粮堆热湿传递规律以及对提升粮食储藏品质都具有重要的意义。

国内外学者对孔隙率的测定开展了一系列的实验。Gustafson^[6]使用气体比重瓶测定了玉米的孔隙率，发现随着测试样品重量的增加，孔隙率逐渐减小。郝倩等^[7]依据理想气体状态方程测定了实验仓内小麦、玉米的孔隙率，提出了粮食孔隙率测量新思路。唐福元等^[8]基于理想气体状态方程，采用粮食回弹模量仪研究了稻谷堆的孔隙率分布规律。孔隙率测定常用的方法还有 CT 扫描法、压汞法、光学法、显微镜法及声学法等，这些方法虽然测量的精度高，但是能够测量的试样大小有所限制且测量设备无法对带压状态下的粮食孔隙率进行测定。因此这些方法不适用于粮仓内粮堆孔隙率的测定。本研究利用自制的粮食孔隙率测定仪可实现对不同受压状态下粮食孔隙率的测量，且该装置可允许的粮食试样尺寸较大，避免了因试样尺寸较小而产生的孔隙率测量的误差。

近年来，由于计算机科学取得许多突破性的进展，机器学习算法已广泛的应用到粮食安全储藏领域的多个方面，并解决了许多实际问题。Wu 等^[9]提出了一种基于图像分析和支持向量机的玉米籽粒质量快速评估方法，其识别准确率为 97.44%。邓玉睿等^[10]建立了预测粮食霉变的 BP 神经网络，用实仓数据对神经网络进行验证，得到的神经网络模型用于预测粮食霉变的准确率较高。机器学习在粮食储藏的虫害检测^[11]、霉变检测^[12]等方面也得到了广泛的研究，然而将机器学习用于粮食孔隙率预测的研究目前还很少。

本文将机器学习算法引入到粮食单元体孔隙率的预测模型中，选取粮食种类、水分含量以及竖向压力 3 个粮食孔隙率的影响因素作为输入变量。采用灰狼优化 BP 神经网络算法、BP 神经网络算法和随机森林算法来预测粮食孔隙率，并通过多个评价指标对模型进行评估，找到最优的粮食孔隙率预测模型，最终利用粮食单元箱实验对模型的泛化能力进行验证。


1 材料与方法

1.1 实验材料

实验选用小麦、玉米、大豆、稻谷为研究对象，参考美国农业工程师协会标准 (ASAE)^[13]，在 105 °C 干燥 72 h 后，测量粮食的初始湿基水分含量分别为 10.70%、11.58%、10.14%、12.93% w.b.。根据《粮油检验容重测定》(GB/T5498—2013) 和《粮油检验粮食、油料相对密度的测定》(GB/T5518—

2008), 测得不同粮食试样的初始密度、颗粒密度等材料参数, 由于篇幅所限各材料参数不在此列出。

本研究探究了粮食种类、水分含量以及竖向压力的不同对粮食试样孔隙率的影响。不同种类的粮食通过喷洒蒸馏水的方法, 分别配制了 3 种不同的水分含量。小麦配制的水分含量分别为 10.70%、11.26%、12.89%, 玉米配制的水分含量分别为 11.58%、12.34%、13.47%, 大豆配制的水分含量分别为 8.58%、10.14%、13.43%, 稻谷配制的水分含量分别为 11.69%、12.93%、14.52%。



注: (A): 正视图; (B) 侧视图。
Note: (A): front view; (B): side view.

图 1 粮食压缩实验装置
Fig.1 Grain compression experimental device

1.3 实验原理

孔隙率的测定采用注水法。由于注水时间短 (粮食浸泡 1 min 的吸水率为 1.09%, 本实验注水在 1 min 内完成), 可忽略粮食颗粒对水的吸收。

粮食试样初始孔隙率公式为:

$$n_0 = \left(1 - \frac{\rho_0}{\rho_s}\right) \times 100\% \quad \text{式 (1)}$$

式中: n_0 为粮食初始孔隙率; ρ_0 为粮食试样初始密度, 单位为 kg/m^3 ; ρ_s 为粮食颗粒密度, 单位为 kg/m^3 。

加载过程中粮食试样孔隙率公式为:

$$n_i = \frac{\Delta V_i}{A(H_0 - \Delta H_i)} \times 100\% \quad \text{式 (2)}$$

式中: n_i 为粮食试样加载第 i 级压力后的孔隙率; ΔV_i 为第 i 级荷载加载后量筒中水的总体积变化量, 单位为 mm^3 ; A 为试样加载室底面积, 单

1.2 实验仪器

粮食压缩实验装置如图 1 所示, 试样加载室由高强度铝合金和有机玻璃制成, 内部尺寸为 $120 \text{ mm} \times 120 \text{ mm} \times 50 \text{ mm}$ 。金属加载板具有较大的刚度, 其下方粘贴有柔性橡胶垫。在试样加载室侧壁的底部位置开设有进水口, 进水口通过注水管与量筒相连, 在注水管上设置有阀门。在实验过程中, 竖向位移由百分表测量。压力传感器放置在试样的底部, 用于测量试样底部的竖向压力。

位为 mm^2 ; H_0 为粮食试样初始高度, 单位为 mm ; ΔH_i 为第 i 级荷载加载后粮食试样总压缩量, 单位为 mm 。

2 构建粮食孔隙率预测模型

2.1 BP 神经网络算法

BP 神经网络 (Back Propagation Neural Network, BPNN) 算法是一种误差反向传播的前馈神经网络, 由输入层、输出层和隐藏层三个部分组成, 包括正向传播和反向传播过程^[14]。

2.2 灰狼优化算法

灰狼优化 (Grey Wolf Optimizer, GWO) 是一种基于群体智能的元启发式算法, 该算法的灵感来自灰狼种群的社会结构^[15]。在灰狼的社会等级制度中, 有四种不同类型的灰狼, 包括 α 狼、 β 狼、 δ 狼和 ω 狼, 社会地位依次递减。四个等级的群狼分别代表了 GWO 优化过程搜索的四个解,

α 狼代表最优解, β 狼和 δ 狼为两个次优解, ω 狼为候选解。

GWO 算法的数学模型主要包括三个步骤——包围猎物、狩猎过程、攻击猎物。灰狼的行为可以用数学模型来定义:

$$D = |C \cdot X_p(t) - X(t)| \quad \text{式 (3)}$$

$$X(t+1) = X_p(t) - A \cdot D \quad \text{式 (4)}$$

式中: D 为灰狼与猎物之间的距离; A 和 C 为系数向量; t 为迭代次数; $X_p(t)$ 和 $X(t)$ 分别为 t 次迭代后猎物和灰狼的位置矢量; $X(t+1)$ 表示 $t+1$ 次迭代后灰狼的位置矢量。

其中 A 和 C 的计算方法见公式 (5) 和公式 (6):

$$A = 2a \cdot r_1 - a, \quad a = 2 - \frac{2t}{T_{\max}} \quad \text{式 (5)}$$

$$C = 2 \cdot r_2 \quad \text{式 (6)}$$

式中: a 为收敛因子, 随着迭代次数的增加, 收敛因子从 2 线性递减到 0; r_1 和 r_2 为 [0,1] 范围内的随机向量; T_{\max} 为最大迭代次数^[15]。

2.3 基于 GWO-BP 的粮食孔隙率预测模型构建过程

BP 神经网络本质上是一种梯度下降法, 具有自适应、自学习、非线性、自组织能力强等显著优势。但 BP 神经网络在运行时过于依赖初始化参数, 待优化的目标函数非常复杂导致收敛速度缓慢, 容易陷入局部最优。

因此, 针对 BP 神经网络独立运行时的诸多缺陷, 在 BP 神经网络算法中引入了 GWO 算法。利用 GWO 算法收敛速度快、全局搜索能力强的特点, 将 BP 神经网络的权重和阈值视为灰狼的位置信息, 利用灰狼搜索猎物的能力更新位置信息, 即更新 BP 神经网络的权重和阈值。通过多次迭代, 得到全局最优权重和阈值, 并对 BP 神经网络进行优化, 从而改善 BP 神经网络的梯度信息, 缩短误差。基于 GWO-BP 的粮食孔隙率预测模型的流程图如图 2 所示。

2.4 模型评价指标

为了检验预测模型的可靠性和精确性, 选用决定系数 (Coefficient of Determination, R^2)、均

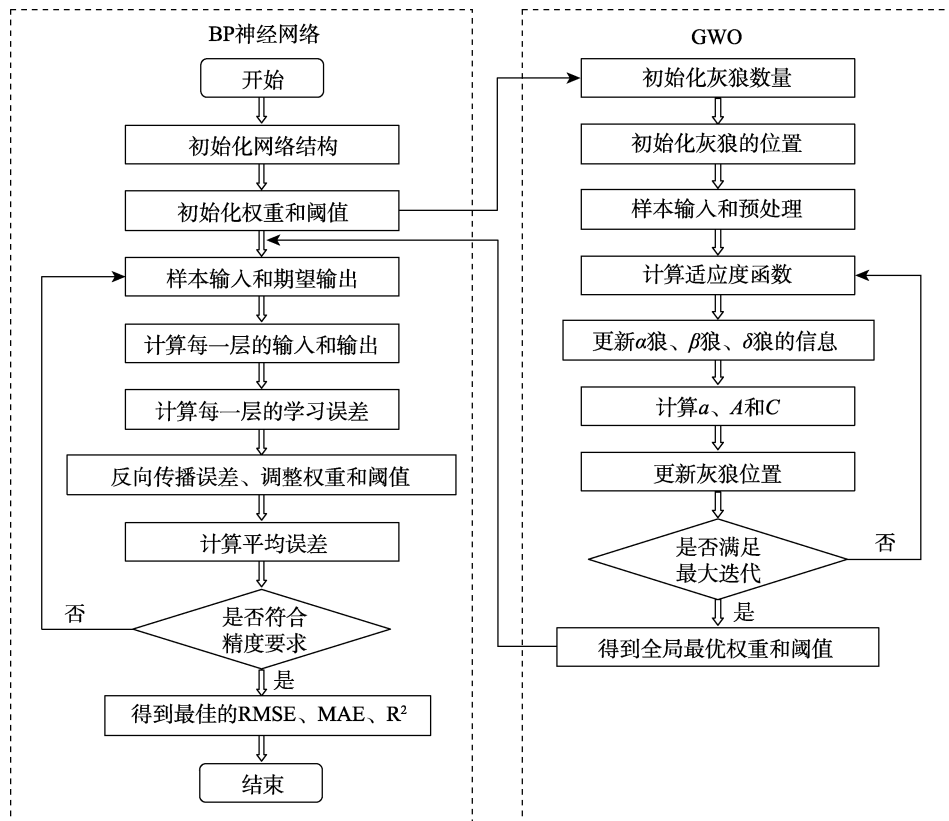


图 2 基于 GWO-BP 的粮食孔隙率预测模型流程图

Fig.2 Flow chart of grain porosity prediction model based on GWO-BP

方根误差 (Root Mean Square Error, RMSE) 和平均绝对误差 (Mean Absolute Error, MAE) 作为模型评价指标^[16]。其计算公式为:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2} \quad \text{式 (7)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad \text{式 (8)}$$

$$MAE = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n} \quad \text{式 (9)}$$

式中: n 为样本总数; i 为样本序列数; \bar{Y}_i 为平均值; Y_i 为真实值; \hat{Y}_i 为预测值。

其中, R^2 越接近 1, 表示模型具有较好的预测效果。RMSE 和 MAE 值越接近 0, 说明预测值

越接近真实值, 模型的预测精度越高。

2.5 数据来源与预处理

根据粮食种类、水分含量的不同共设置 12 组实验。依据粮仓内粮堆的竖向压力取值范围, 选取竖向压力分别为 0、20.82、41.64、83.28、124.92 kPa 共 5 个等级对每组试样进行逐级加载, 共获得 60 组实验数据。由于篇幅所限, 粮食压缩实验的部分结果见表 1。

模型所需的数据库除了从实验中获取数据以外, 还收集了文献中的实验数据^[17-21], 包括粮食单元体的压缩实验、利用图像处理技术获取粮堆孔隙率、PFC 数值模拟等。由于篇幅所限, 收集的文献数据不在此列出。通过实验和文献数据采集的方式, 共获得 400 组数据。将数据库中的数据按照 7:3 的比例随机划分为两部分, 其中 280 组数据作为训练集, 剩余 120 组数据作为测试集。

表 1 粮食压缩实验的部分结果

Table 1 Partial results of compression tests on grain samples

序号	粮食种类	水分含量/%	竖向压力/kPa	孔隙率	序号	粮食种类	水分含量/%	竖向压力/kPa	孔隙率
1	小麦	10.70	0	0.414	11	大豆	8.58	0	0.373
2	小麦	10.70	20.82	0.405	12	大豆	8.58	20.82	0.363
3	小麦	10.70	41.64	0.398	13	大豆	8.58	41.64	0.353
4	小麦	10.70	83.28	0.385	14	大豆	8.58	83.28	0.330
5	小麦	10.70	124.92	0.377	15	大豆	8.58	124.92	0.306
6	玉米	11.58	0	0.399	16	稻谷	12.93	0	0.487
7	玉米	11.58	20.82	0.391	17	稻谷	12.93	20.82	0.480
8	玉米	11.58	41.64	0.384	18	稻谷	12.93	41.64	0.474
9	玉米	11.58	83.28	0.374	19	稻谷	12.93	83.28	0.464
10	玉米	11.58	124.92	0.367	20	稻谷	12.93	124.92	0.456

在建立孔隙率预测模型之前, 为了便于数据提取以及提高模型的准确性, 需要对数据库中的原始数据进行预处理。将原始输入和输出数据归一化到[0,1], 再进行模型训练, 归一化公式参考文献[16]。

3 模型预测结果与分析

3.1 三种机器学习模型的孔隙率预测结果对比

粮食孔隙率的预测属于回归问题, 可以采用的机器学习算法有很多。为了得到预测精度高的

机器学习模型, 还建立了 BP 神经网络模型和随机森林 (Random Forest, RF) 模型。其中 BP 模型是通过对输入数据的学习, 可以建立输入与输出数据之间的映射关系^[22]。RF 模型是以决策树算法为基础, 将大量决策树组合成一个复杂的模型, 从而做出最终的决策^[23]。

将 GWO-BP 模型与 BP、RF 模型进行比较, 图 3~5 分别为基于测试集的 BP、RF、GWO-BP 模型的预测值与真实值。图 6 为基于测试集的三种机器学习模型的孔隙率预测误差。从图 3~5 可以

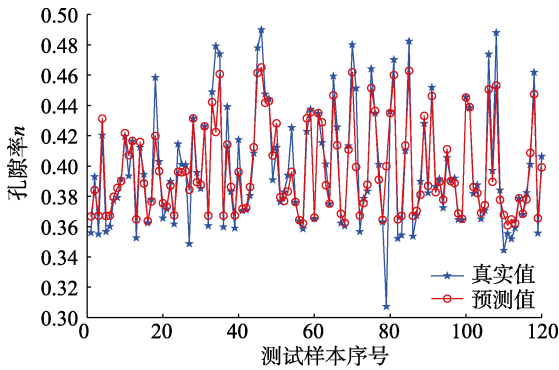


图 3 基于测试集的 RF 模型对孔隙率的预测值与真实值对比
Fig.3 Predicted versus true values of porosity by RF model based on test set




图 6 基于测试集的三种机器学习模型的孔隙率预测误差
Fig.6 Porosity prediction errors of three machine learning models based on test sets




图 4 基于测试集的 BP 模型对孔隙率的预测值与真实值对比
Fig.4 Predicted versus true values of porosity by BP model based on test set




图 5 基于测试集的 GWO-BP 模型对孔隙率的预测值与真实值对比
Fig.5 Predicted versus true values of porosity by GWO-BP model based on test set

表 2 三种模型的孔隙率预测性能比较
Table 2 Comparison of porosity prediction performance of three models

模型	R ²	RMSE	MAE
GWO-BP	0.952 8	0.008 0	0.005 2
BP	0.887 4	0.012 9	0.008 8
RF	0.857 2	0.015 5	0.009 4

三种机器学习模型预测精度从高到低依次为 GWO-BP、BP、RF。综合上述分析可以得到，GWO-BP 神经网络模型是最佳的预测模型。

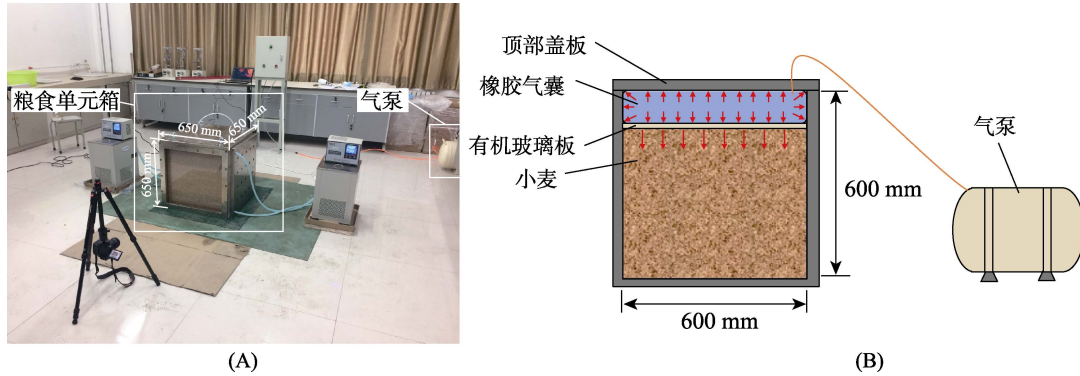
3.2 基于 GWO-BP 的孔隙率预测模型的实验验证

为了验证建立的 GWO-BP 模型在实际应用中的有效性及泛化能力，将粮食单元箱实验的数据代入 GWO-BP 模型中。粮食单元箱如图 7 所示，内部净尺寸为 600 mm×600 mm×600 mm。粮食单元箱实验模拟的是粮仓中散装粮堆的一个单元体，通过对单元箱内的粮食施加不同的压力，该粮食单元体能够代表粮仓中任一位置处于不同压力状态下的粮食。实验采用橡胶气囊对箱内储料进行竖向加载，外接气压控制系统为气囊提供稳定的气体压力。粮食单元箱实验以小麦作为储料对其孔隙率进行测定，小麦粮堆的湿基水分含量为 10.89%，初始孔隙率为 0.429。分别测定竖向压力为 0、25、50、75、100、125、150 kPa 时的小麦孔隙率，共获得 7 组实验数据用于验证。

将粮食单元箱实验的数据导入 GWO-BP 模型进行预测，模型预测结果与实验结果对比如图 8 所示。由图可知，GWO-BP 模型得到的孔隙率预测值略小于粮食单元箱实验中孔隙率的实验值，随着竖向压力的增大，孔隙率预测值和实验值均

看出，BP 和 RF 模型的预测值和真实值相差较大，GWO-BP 模型的预测值更接近真实值。从图 6 可以看出，GWO-BP 模型的误差小于两种单一模型。

表 2 为三个机器学习模型的 R²、RMSE 和 MAE 三种评价指标值。从表 2 可以看出，与 BP、RF 模型相比，GWO-BP 模型的 R² 值最大为 0.954 2，RMSE 和 MAE 值均最小分别为 0.007 9 和 0.004 4；RF 模型的 R² 值最小，RMSE 和 MAE 值都最大。




注：(A)：实验平台实物图；(B) 加载原理图。

Note: (A): physical diagram of the experimental platform; (B): loading schematic diagram.

图 7 粮食单元箱实验装置

Fig.7 Grain cell box test device



注：图中的 R^2 表示曲线拟合的决定系数。

Note: R^2 in the figure represents the coefficient of determination for curve fitting.

图 8 GWO-BP 模型预测孔隙率与粮食单元箱实验结果对比
Fig. 8 Comparison of GWO-BP model predicted porosity with grain cell box experiment results

逐渐减小。将模型预测值与实验值分别进行拟合得到两条拟合曲线，这两条曲线的变化趋势基本一致，且二者在纵坐标上近似相差一个常数。GWO-BP 模型和粮食单元箱实验的初始孔隙率分别为 0.416 和 0.429，二者仅相差 3.03%。当竖向压力为 150 kPa 时，GWO-BP 模型和粮食单元箱实验的孔隙率分别为 0.378 和 0.389，二者仅相差 2.83%。

根据式 (7) ~ 式 (9) 得到 GWO-BP 模型预测值与粮食单元箱实验值之间的 R^2 为 0.960 5，RMSE 为 0.013 7 及 MAE 为 0.013 1，说明 GWO-BP 模型的预测精度高，训练效果好；同时也说明模型预测值与实验值之间的误差在允许范围内，能够将 GWO-BP 模型用于预测粮食单元箱中的孔隙率，表明 GWO-BP 模型具有较强的泛化

能力。通过 GWO-BP 模型与粮食单元箱实验的结果进行对比，验证了将 GWO-BP 模型用于预测粮食单元体孔隙率的可行性。

4 结论

通过实验获得粮食单元体孔隙率的方法，耗时长且效率不高，在前人开展实验获取孔隙率的基础上，提出一种基于机器学习的粮食单元体孔隙率预测模型。将 BP、RF 和 GWO-BP 三种模型的孔隙率预测结果进行对比，得到 GWO-BP 模型的预测精度最高。

为了验证 GWO-BP 模型的泛化性能，将 GWO-BP 模型的预测值与粮食单元箱实验的实验值进行比较，结果表明：预测值与实验值基本一致，两者之间的误差在允许的范围内。GWO-BP 模型有较强的泛化能力能够有效地对较大尺寸的粮食单元体孔隙率进行预测，为预测粮仓中粮堆的孔隙率提供依据。

参考文献：

[1] 崔宏伟, 吴文福, 吴子丹, 等. 基于温度场云图的储粮数量监控方法研究[J]. 农业工程学报, 2019, 35(4): 290-298.
CUI H W, WU W F, WU Z D, et al. Monitoring method of stored grain quantity based on temperature field cloud maps[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(4): 290-298.

[2] 尹君, 吴子丹, 张忠杰, 等. 不同仓型的粮堆温度场重现及对比分析[J]. 农业工程学报, 2015, 31(1): 281-287.
YIN J, WU Z D, ZHANG Z J, et al. Comparison and analysis of temperature field reappearance in stored grain of different

- warehouses[J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(1): 281-287.
- [3] 姚渠, 张忠杰, 尹君, 等. 气膜钢筋混凝土球形仓小麦储藏品质的分析研究[J]. 粮油食品科技, 2022, 30(4): 199-205.
 YAO Q, ZHANG Z J, YIN J, et al. Research on storage quality of wheat in air-film reinforced concrete spherical silo[J]. Science and Technology of Cereals, Oils and Foods, 2022, 30(4): 199-205.
- [4] 王远成, 潘钰, 尉尧方, 等. 仓储粮堆内部自然对流和热湿传递的数学分析及验证[J]. 中国粮油学报, 2017, 32(9): 120-125+130.
 WANG Y C, PAN Y, YU Y F, et al. Mathematical analysis and validation for natural convective heat and moisture transfer in grain bulk during sealed storage[J]. Journal of the Chinese Cereals and Oils Association, 2017, 32(9): 120-125+130.
- [5] YUE R, ZHANG Q. A pore-scale model for predicting resistance to airflow in bulk grain[J]. Biosystems Engineering, 2017, 155: 142-151.
- [6] GUSTAFSON R J, HALL G E. Density and porosity changes of shelled corn during drying[J]. Transactions of the ASAE, 1972, 15(3): 523-525.
- [7] 郝倩, 陈弘毅, 平学文, 等. 一种新型粮食孔隙度就仓测量系统研究[J]. 农机化研究, 2015, 37(9): 180-184.
 HAO Q, CHEN H Y, PING X W, et al. Study of a new in-bin porosity measurement method[J]. Journal of Agricultural Mechanization Research, 2015, 37(9): 180-184.
- [8] 唐福元, 许倩, 程绪铎. 筒仓中稻谷的空隙率分布研究[J]. 中国粮油学报, 2017, 32(12): 110-116.
 TANG F Y, XU Q, CHENG X D. Research on porosity distribution of paddy in silos[J]. Journal of the Chinese Cereals and Oils Association, 2017, 32(12): 110-116.
- [9] WU A, ZHU J, YANG Y, et al. Classification of corn kernels grades using image analysis and support vector machine[J]. Advances in Mechanical Engineering, 2018, 10(12): 1687814018817642.
- [10] 邓玉睿, 周勇, 唐芳, 等. BP神经网络在粮食霉变预测中的应用研究[J]. 中国粮油学报, 2019, 34(11): 128-132.
 DENG Y R, ZHOU Y, TANG F, et al. Application of BP neural network in prediction of grain mildew[J]. Journal of the Chinese Cereals and Oils Association, 2019, 34(11): 128-132.
- [11] NANNI L, MANFÈ A, MAGUOLO G, et al. High performing ensemble of convolutional neural networks for insect pest image detection[J]. Ecological Informatics, 2022, 67: 101515.
- [12] JIA Y, LI Z, GAO R, et al. Mildew recognition on maize seed by use of hyperspectral technology[J]. Spectroscopy Letters, 2022, 55(4): 240-249.
- [13] ASAE. Moisture measurement—unground grain and seeds: S352.2 APR1988 (R2017)[S]. Michigan, USA: ASAE, 2017.
- [14] 赵纯, 陈学永, 吴少霜, 等. 基于 BP 神经网络的面包工业化生产发酵程度视觉判定[J]. 食品与机械, 2022, 38(2): 197-202.
 ZHAO C, CHEN X Y, WU S S, et al. Study on visual judgment method of fermentation degree in industrialized bread production based on BP neural network[J]. Food & Machinery, 2022, 38(2): 197-202.
- [15] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in engineering software, 2014, 69: 46-61.
- [16] GUO Y, TANG D, TANG W, et al. Agricultural price prediction based on combined forecasting model under spatial-temporal influencing factors[J]. Sustainability, 2022, 14(17): 10483.
- [17] 李倩倩, 陈鑫, 毕文雅, 等. 小麦堆孔隙率测定方法及影响因素研究[J]. 粮油食品科技, 2021, 29(1): 187-193.
 LI Q Q, CHEN X, BI W Y, et al. Research on determination method and influencing factors of porosity of wheat pile[J]. Science and Technology of Cereals, Oils and Foods, 2021, 29(1): 187-193.
- [18] 张小正. 仓储粮堆孔隙结构参数研究[D]. 北京: 中国农业大学, 2010.
 ZHANG X Z. Study on the pore parameter of grain heap[D]. Beijing: China Agricultural University, 2010.
- [19] 王娟. 粮堆孔隙度的实验研究[D]. 郑州: 河南工业大学, 2016.
 WANG J. Test study on the porosity of grain mass[D]. Zhengzhou: Henan University Of Technology, 2016.
- [20] 葛蒙蒙, 陈桂香, 刘超赛, 等. 不同粮种竖向压力孔隙率与密度研究[J]. 河南工业大学学报(自然科学版), 2021, 42(4): 89-95.
 GE M M, CHEN G X, LIU C S, et al. Study on porosity and density of different grains under vertical pressure[J]. Journal of Henan University of Technology (Natural Science Edition), 2021, 42(4): 89-95.
- [21] 周洋, 刘超赛, 岳龙飞, 等. 单向压缩对小麦堆蠕变特性及品质影响的研究[J]. 河南工业大学学报(自然科学版), 2023, 44(1): 112-116+134.
 ZHOU Y, LIU C S, YUE L F, et al. Effect of uniaxial compression on creep behavior and quality of wheat bulk[J]. Journal of Henan University of Technology(Natural Science Edition), 2023, 44(1): 112-116+134.
- [22] SALEH I A, ALAWSI W A, ALSAIF O I, et al. A prediction of grain yield based on hybrid intelligent algorithm[C]. Journal of Physics: Conference Series, 2020: 012027.
- [23] BREIMAN L. Random forests[J]. Machine learning, 2001, 45: 5-32. 完
- 备注: 本文的彩色图表可从本刊官网 (<http://lyspkj.ijournal.cn>)、中国知网、万方、维普、超星等数据库下载获取。