

基于PSO算法BP神经网络的拱形温室大棚薄膜风雹耦合所致冰雹冲击力预测模型

戴益民, 罗浩, 邓尧, 龙彦文

湖南科技大学土木工程学院, 湖南 湘潭

收稿日期: 2025年1月20日; 录用日期: 2025年2月13日; 发布日期: 2025年2月25日

摘要

风雹灾害是造成农业生产设施破坏和经济损失的主要自然灾害之一, 因此有必要构建一个高效且准确的冰雹冲击力预测模型。本研究以拱形温室大棚薄膜风雹耦合试验为基础, 采用粒子群优化(Particle Swarm Optimization, PSO)算法与反向传播(Back Propagation, BP)神经网络相结合的方法, 构建一个高效且准确的冰雹冲击力预测模型。该模型的平均绝对误差为0.22929, 平均偏差误差为-0.09017, 确定系数为0.99704。相较于传统线性回归预测方法, 该模型可处理大数据量, 适应性强, 拟合效果好, 且避免了传统BP模型容易陷入局部最小的缺点。

关键词

风雹灾害, 拱形温室大棚, PSO优化算法, BP神经网络

PSO-Optimized BP Neural Network Model for Predicting Hail Impact Resulting from Wind-Hail Coupling on Greenhouse Film for Arched Greenhouses

Yimin Dai, Hao Luo, Yao Deng, Yanwen Long

School of Civil Engineering, Hunan University of Science and Technology, Xiangtan Hunan

Received: Jan. 20th, 2025; accepted: Feb. 13th, 2025; published: Feb. 25th, 2025

Abstract

Hail disasters are one of the major natural hazards causing damage to agricultural production facilities

文章引用: 戴益民, 罗浩, 邓尧, 龙彦文. 基于 PSO 算法 BP 神经网络的拱形温室大棚薄膜风雹耦合所致冰雹冲击力预测模型[J]. 土木工程, 2025, 14(2): 279-286. DOI: 10.12677/hjce.2025.142032

and economic losses, necessitating the development of an efficient and accurate hail impact force prediction model. This study employs a PSO-BP neural network approach, grounded in wind-hail coupling experiments on arched greenhouse films. The resultant model demonstrates superior performance with a mean absolute error (MAE) of 0.22929, a mean bias error (MBE) of -0.09017 , and a determination coefficient (R^2) of 0.99704. It surpasses traditional linear regression methods in handling large datasets, adaptability, fitting accuracy, and mitigating the issue of local minima in BP models.

Keywords

Wind-Hail Disaster, Arched Greenhouse, PSO Optimization Algorithm, BP Neural Network

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在全球气候变化的影响下, 极端天气事件如风雹灾害的频率和强度显著增加。风雹灾害不仅对人的生命安全造成危害还对农业生产设施构成严重的威胁[1] [2], 据应急管理部自然灾害统计: 2024 年前三季度, 风雹灾害共造成 783.1 万人次不同程度受灾, 因灾死亡 86 人, 农作物受灾面积 1118.1 千公顷, 直接经济损失 141.3 亿元[3]。拱形温室大棚作为现代农业设施的重要组成部分, 不仅为作物提供了适宜的生长环境, 而且在提高农产品产量和质量方面发挥了重要作用。然而, 当遭遇强风和冰雹等极端天气时, 这些设施极易遭到损害, 导致农作物受损、生产中断, 甚至造成重大经济损失。因此, 针对风雹灾害对农业设施的影响, 构建一个准确可靠的冲击力预测模型对于提前采取防范措施、减少经济损失具有重要意义。

智慧农业是我国发展现代农业的重要着力点, 因此有大量学者针对人工智能技术在农业中的应用进行了研究, 杨学军[4]等总结了双目立体视觉技术及其在智慧农业中的应用研究, 并对该技术未来在农业领域中的发展重点进行了展望; 余忠义[5]等对智慧农场管理系统进行了深入研究, 构建了相应系统并对其应用场景进行了探索; 戴益民[6]等在风雹耦合模拟试验的基础上建立 BP 神经网络模型及 GA-BP 神经网络模型用于预测风雹下单颗粒冰雹的冲击力。此外, 在防灾减灾领域, 智慧农业的发展需求尤为迫切。准确及时的灾害预警系统可以帮助农民提前采取防护措施, 减少损失; 同时, 通过对灾害发生规律的研究和技术手段的应用, 可以进一步提高农业设施抵御自然灾害的能力。

本研究基于上述背景, 以拱形温室大棚薄膜风雹耦合试验为基础, 采用粒子群优化(Particle Swarm Optimization)算法与反向传播神经网络相结合的方法, 旨在建立一个高效且准确的冰雹冲击力预测模型。PSO 算法以其全局搜索能力强的特点, 能够有效避免 BP 神经网络训练过程中容易陷入局部最优解的问题; 而 BP 神经网络则具备强大的非线性映射能力和自适应学习能力, 可以很好地拟合复杂的气象条件与冰雹冲击力之间的关系; 两者结合, 不仅提高了预测模型的精度, 还增强了其泛化能力和稳定性。通过构建此预测模型, 可帮助农业生产者更好地应对风雹灾害带来的风险, 并可为智慧农业防灾减灾体系的建设做出一定贡献。综上所述, 面对日益频发的风雹灾害及其对农业生产的严重威胁, 发展基于先进算法和智能技术的预测模型不仅是必要的, 也是智慧农业发展的必然趋势。

2. 试验概况

2.1. 拱形温室薄膜大棚风雹耦合试验

为模拟风雹耦合实际情况, 本研究自主设计了一套适用于风洞内的风雹耦合试验系统(图 1), 可实现

不同工况下拱形温室大棚薄膜风雹耦合试验要求。系统由冰雹发射及数据采集系统构成。发射系统含可遥控冰雹垂直发射装置、风洞固定支架、气泵及发射控制台；数据采集系统由风洞测力天平支架、高清摄像机、测力天平和三维脉动风速仪组成。

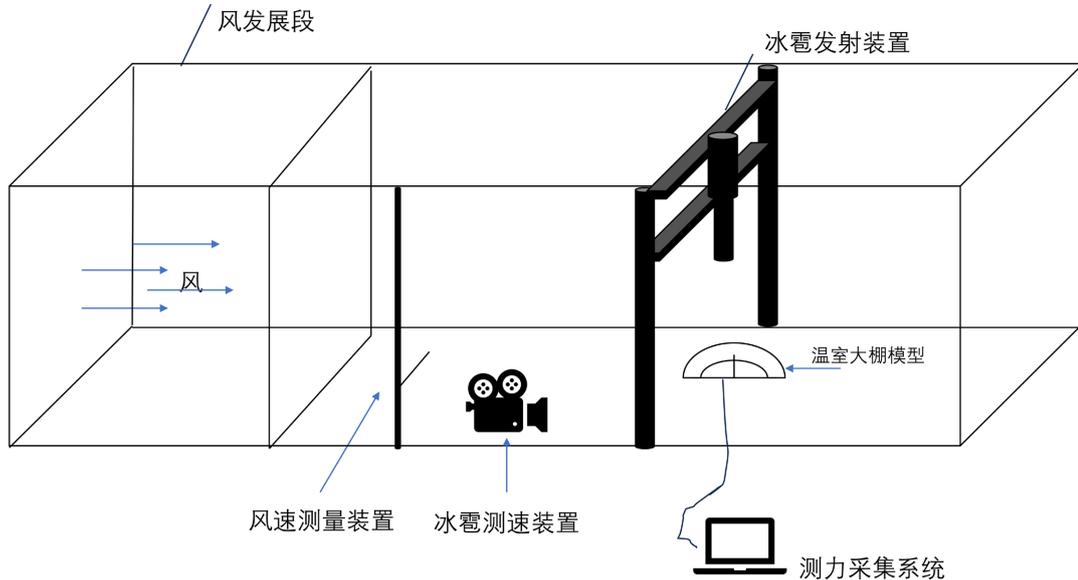


Figure 1. Schematic diagram of the experiment
图 1. 试验原理图

试验使用的风洞测力天平支架为长 1200 mm，宽 1000 mm，高 400 mm 的拱形大棚骨架模型。支架安装完成后，再对测力天平支架进行覆膜。覆膜完成后，使用发射系统对天平支架进行冲击，其中有风工况以模型长边正对来流方向作为 0° 风向角，冲击完成后由测力天平记录所得冲击力数据，试验工况如表 1。

Table 1. Table of text conditions
表 1. 试验工况表

冰雹直径 (mm)	冰雹速度 (m/s)	风速 (m/s)	风向角 ($^\circ$)
20	20.5/21/21.5/22/22.5/23	7/9/11	0/15/30/45/60
25	22.5/23/23.5/24/24.5/25	7/9/11	0/15/30/45/60
30	24/24.5/25/25.5/26/26.5	7/9/11	0/15/30/45/60

2.2. 特征选择与数据处理

本研究采用上述实验中所获取的不同风速和风向角下冰雹冲击模拟试验的 100 组数据作为训练数据集。数据集采用冰雹粒径、冰雹速度、风速、风向角作为输入特征，以所得冲击力作为输入特征，数据集中训练、验证和测试集划分方法采用 10-折交叉验证法：将数据打乱后分为十份，其中 8 份作为训练集输入，2 份作为验证集输入，重复以上过程 10 次，该方法可实现数据的高效使用同时提升模型评估的准确性。

明确数据集特征及其划分后，对数据集进行归一化处理以消除量纲不同所造成的系统误差，常用的

归一化方法有 min-max 方法、Z-Score 标准化、log 函数、atan 函数等方法，各方法优缺点及应用场景不同，本文采用 min-max 归一化方法，该方法可将原始数据线性变换到一个[0, 1]区间内，具有适用性强，应用场景广泛等优点。Min-max 方法的计算公式为：

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

式中： x 为原始数据点； x' 是归一化后的数据点； $\min(x)$ 为该特征的最小值； $\max(x)$ 是该特征的最大值。

3. PSO-BP 神经网络模型

3.1. BP 神经网络模型构建

根据通用逼近定理，一个具有足够多神经元的前馈网络可以逼近任何连续函数。因此，考虑到模型数据集中的样本量较少等问题，将模型构建为单隐藏层前馈网络模型。隐藏层神经元则根据经验法则应设置在输入特征数量和输出节点数量之间的某个值，因此本模型层隐藏神经元设置为 3 个节点，神经网络预测模型结构如图 2 所示。

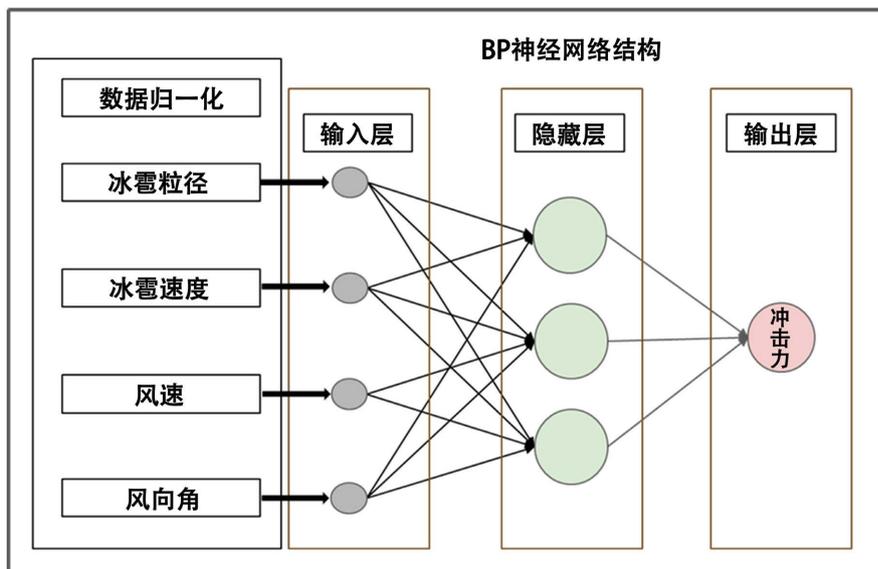


Figure 2. Neural network model architecture
图 2. 神经网络模型结构

确立 BP 神经网络模型结构后，对神经网络训练的基本参数进行设置，本模型最大迭代次数设置为 1000 次，目标误差设置为 1×10^{-6} ，确定学习率为 0.01。模型采用 tansig (双曲正切 S 函数) 作为输入层到隐藏层的激活函数，purelin (线性激活函数) 作为隐藏层到输出层的激活函数。

3.2. PSO 算法的相关参数设计

粒子群优化(Particle Swarm Optimization, PSO)算法是一种基于群体智能的全局优化算法，能够有效地探索解空间，避免模型陷入局部最优解，该优势对于 BP 神经网络来说非常重要，因为传统的梯度下降方法容易受到局部极小值的影响，而采用 PSO 优化后的神经网络可以有效避免该问题。

因此，本模型采用 PSO 算法来赋值 BP 神经网络中的权重和偏置，而非采用传统梯度下降法直接优化训练过程中的权重。具体工作流程为：首先随机生成一组粒子(即一组可能的权重和偏置组合)；随后在

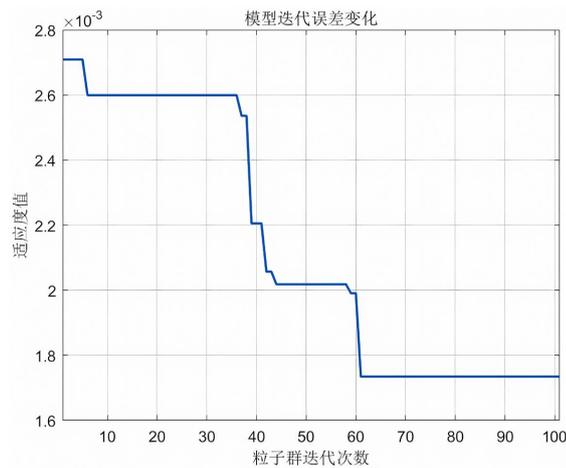
训练过程中逐步评估每个粒子对应的神经网络在训练数据上的表现(如误差等), 适应度值越低, 表示该粒子所代表的权重和偏置越好; 寻找一组粒子中最优表现, 并更新每个粒子的权重与偏置; 最后重复上述评估和更新步骤若干次, 逐步改善粒子的速度与位置(即权重和偏置), 直到达到目标误差或到达最大迭代次数; 最后将经过多次迭代所得到的全局最优解作为最终的权重和偏置, 并将其赋值给神经网络。

PSO 粒子群优化算法的性能高度依赖算法参数的选择, 在种群更新次数为 100 的情况下, 不同种群规模适应度函数值如图 3 所示, 由图 3 可知不同粒子群规模下, 粒子群迭代次数在 100 次迭代趋于稳定且达到模型精度要求, 因此粒子群迭代次数设置为 100, 模型总迭代次数设置为 1000。种群规模过大易浪费算法资源且收敛难度大, 过小会限制算法的多样性导致搜索能力不足, 因此模型设置种群规模为 30, 该规模能够充分利用算法资源的同时保证搜索效率和质量。此外, 粒子群模型的速度及位置边界都设置为 ± 1.0 。本研究采用 PSO 相关算法参数如表 2 所示。

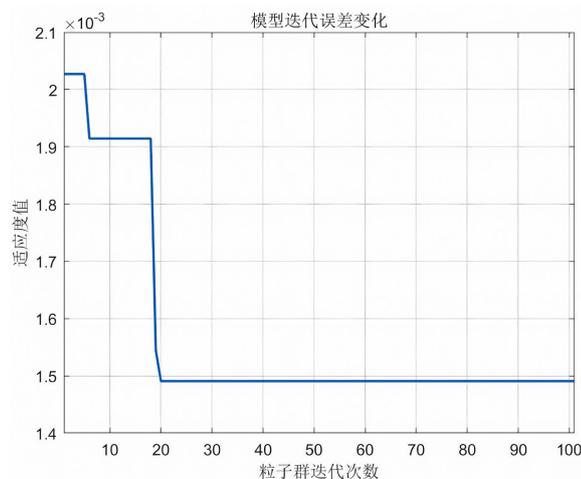
Table 2. Parameters related to particle swarm optimization algorithm

表 2. 粒子群优化算法相关参数

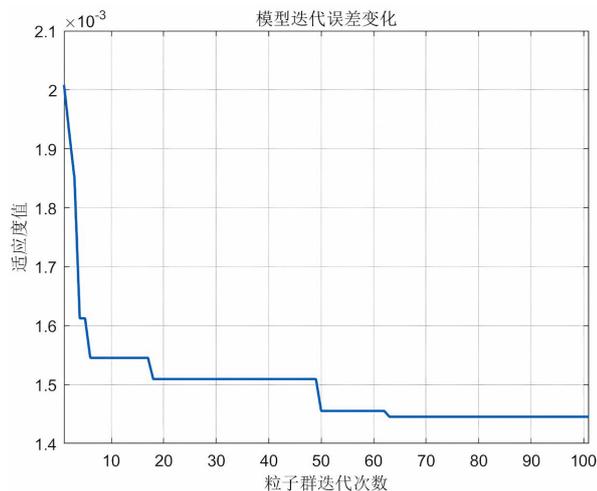
迭代次数	种群规模	速度及位置边界	学习因子 C1	学习因子 C2
100	30	± 1.0	3.694	3.694



(a) 种群规模 10



(b) 种群规模 30



(c) 种群规模 50

Figure 3. Fitness value changes of PSO-BP models with different population sizes
图 3. 不同种群规模的 PSO-BP 模型适应度值变化

3.3. 结果分析与讨论

本研究模型的预测精度主要通过以下指标进行评估：平均绝对误差(MAE)、平均偏差误差(MBE)以及决定系数(R^2)。具体计算公式如下：

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

$$\text{MBE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

式(2)(3)(4)中， y_i 为真实值， \hat{y}_i 为预测值， \bar{y} 为真实值的平均值， n 为样本数量。其中 MAE、MBE 越小，说明拟合结果与实际值越接近，即模型预测效果越好； R^2 的取值范围为[0, 1]，其越接近 1 表明模型对数据的拟合程度越好。

为保证模型的可靠性，将 PSO-BP 神经网络经 10-折交叉法验证后通过以上评估指标对模型训练集和测试集进行评估，相关参数如下表(表 3)所示：

Table 3. Model evaluation metrics

表 3. 模型评估指标

	MAE	MBE	R^2
训练集	0.11958	-0.01025	0.99957
测试集	0.22929	-0.09017	0.99704

由表 3 可得，PSO-BP 神经网络模型无论在训练集或测试集中均表现出较好的预测能力，可以有效的预测风雹环境下拱形温室大棚薄膜所受单颗冰雹冲击力峰值。图 4 为训练集与测试集的数据回归图，可

看出无论训练集或测试集均有好的拟合精度。此外图 5 给出了 PSO-BP 神经网络的预测对比图, 从图中可以看出, 该模型在训练后能够有效地挖掘冰雹直径、冰雹速度、风速和风向角与拱形温室大棚薄膜所受单颗冰雹冲击力峰值之间的关系。

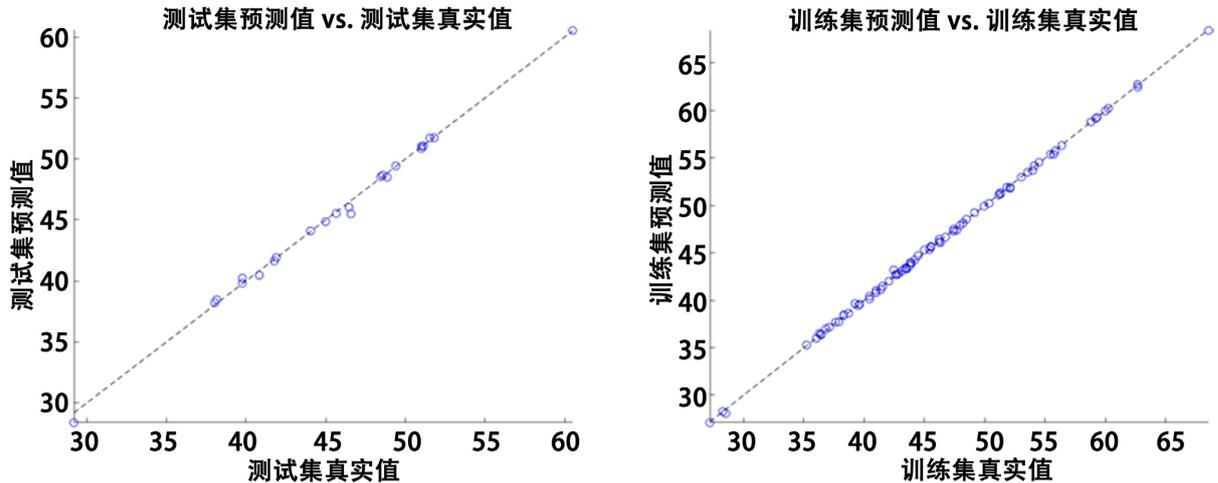


Figure 4. Neural network training performance graph

图 4. 神经网络训练效果图

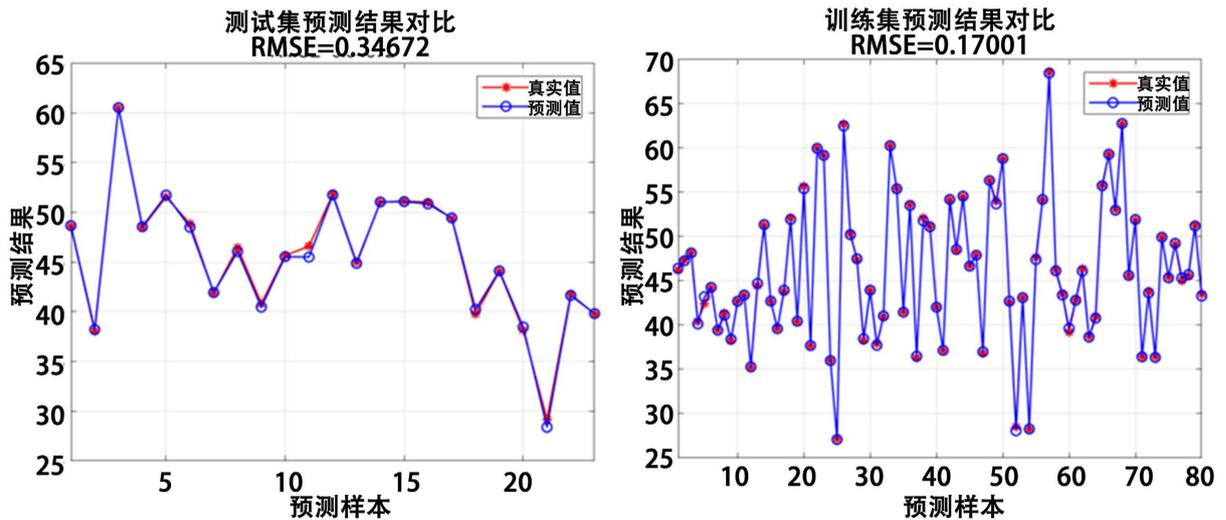


Figure 5. Neural network prediction comparison diagram

图 5. 神经网络预测对比图

4. 结论

本研究简要介绍了 PSO-BP 神经网络模型的搭建以及对应的网络结构。并依据其网络结构特点调整相关参数, 模型训练数据由拱形温室大棚风雹耦合模拟试验获得, 神经网络的输入是风速、风向角、冰雹速度、冰雹粒径, 输出为风雹灾害下单颗粒冰雹粒子冲击拱形温室大棚结构峰值力。最后采用 10-折交叉验证法进行模型评估。主要结论如下:

(1) PSO-BP 神经网络预测模型测试集平均绝对误差为 0.22929, 平均偏差误差为-0.09017, 确定系数为 0.99704, 相较于传统多元回归分析具有更好的拟合效果, 且避免了 BP 神经网络易陷入局部最小导致

过拟合的缺陷。

(2) PSO-BP 神经网络模型构建中, 调整种群规模与迭代次数之间的关系是提高算力效率与模型精度的关键。

(3) 该模型若使用不同场景的训练数据进行训练, 则可应用于拱形温室大棚防灾减灾场景的建模。

参考文献

- [1] 汤兴芝, 黄治勇, 张荣, 等. 2010-2020 年全国冰雹灾害事件时空分布特征[J]. 暴雨灾害, 2023, 42(2): 223-231.
- [2] 孙朝锋, 吴立, 黄川容, 等. 基于 GIS 的福建省塑料大棚风害风险评估与区划[J]. 气象与环境科学, 2022, 45(4): 67-73.
- [3] 2024 年上半年全国自然灾害形势公布[J]. 职业卫生与应急救援, 2024, 42(4): 445.
- [4] 杨学军, 钟金彪, 林开颜, 等. 双目立体视觉技术及其在智慧农业中的应用研究进展[J]. 农业工程学报, 2025, 41(1): 27-39.
- [5] 余忠义, 全春夏, 方舟, 等. 数智农田构建关键技术装备及展望[J]. 农业工程学报, 2024, 40(23): 1-14.
- [6] 戴益民, 李怿歆, 徐瑛, 刘泰廷, 王威. 基于 GA-BP 神经网络的风雹耦合所致冰雹冲击力预测[J]. 工程力学, 2023, 41: 1-10.