doi:10.6041/j.issn.1000-1298.2026.12.034

日光温室颗粒物动态运移机制与预测模型研究

张　硕[1,2]　于海业[1,2]　郭　丽[1,2]　张　蕾[1,2]　张　博[1,2]　隋媛媛[1,2]
(1.吉林大学生物与农业工程学院,长春 130022;2.吉林省智慧农业装备与技术重点实验室,长春 130022)

摘要:精确预测温室内颗粒物浓度变化可为实时环境控制系统提供科学依据。基于中国东北地区典型温室生产场景,本文系统分析了温室内外不同粒径颗粒物($PM_{2.5}$和PM_{10})时序特征及其关联机制,构建了适用于不同通风模式的颗粒物动态运移模型。通过筛选关键环境驱动因子,建立了适用于温室环境的颗粒物浓度机器学习预测模型。研究结果表明:同一粒径范围内室内与室外颗粒物浓度变化相关性最强,室外颗粒物浓度是主导室内颗粒物浓度变化的主要驱动源;相比$PM_{2.5}$,温室内PM_{10}对室外颗粒物变化的响应较弱。所构建的动态运移模型在不同通风模式下颗粒物浓度计算值与实测值相对误差为 0.68% ~9.73%,能够较准确地量化温室内外颗粒物运移机制。在预测建模时,筛选室外颗粒物浓度、室内温度、相对湿度与风速等作为输入变量,建立的遗传算法-小波神经网络(GA-WNN)模型表现出优异的预测性能,$PM_{2.5}$和PM_{10}浓度决定系数分别为 0.912 ~0.938 和 0.898 ~0.917,并且超过 92.7% 和 90.3% 的实测$PM_{2.5}$和PM_{10}浓度落在 95% 预测区间内,验证了模型的准确性与可靠性。提出的基于室外颗粒物浓度与室内环境参数相结合的分析框架,为理解与预测温室内颗粒物浓度提供了有效方法,为温室环境精准调控与作物生产的有效管理提供了重要支撑。

关键词:日光温室;颗粒物;运移机制;机器学习;预测模型
中图分类号:S625　　**文献标识码**:A　　**文章编号**:1000-1298(2026)12-0364-10　　**OSID**:

Dynamic Transport Mechanisms and Predictive Modeling of Particulate Matter in Solar Greenhouse

ZHANG Shuo[1,2]　YU Haiye[1,2]　GUO Li[1,2]　ZHANG Lei[1,2]　ZHANG Bo[1,2]　SUI Yuanyuan[1,2]
(1. *College of Biological and Agricultural Engineering, Jilin University, Changchun* 130022, *China*
2. *Jilin Provincial Key Laboratory of Smart Agricultural Equipment and Technology, Changchun* 130022, *China*)

Abstract: Accurate prediction of temporal variations in particulate matter concentrations inside greenhouses is essential for data-driven, real-time environmental control. Focusing on representative production scenarios in Northeast China, the temporal characteristics and coupling mechanisms of indoor and outdoor particulate matter across different size fractions ($PM_{2.5}$ and PM_{10}) were systematically analyzed, and a dynamic particulate transport model applicable to multiple ventilation modes was developed. Key environmental drivers were then identified to build machine-learning models for predicting particulate concentrations in greenhouse environments. The results showed that indoor and outdoor concentrations exhibited the strongest correlations within the same particle-size fraction, and that outdoor concentration was the dominant driver of indoor variability. Compared with $PM_{2.5}$, indoor PM_{10} responded more weakly to outdoor fluctuations. Across ventilation modes, the dynamic transport model achieved mean deviations of 0.68% ~ 9.73% between simulated and observed values, enabling quantitative characterization of indoor-outdoor particulate exchange. For data-driven prediction, outdoor particulate concentration, indoor temperature, relative humidity, and air velocity were selected as input variables; the proposed GA - WNN model demonstrated excellent performance, with coefficients of determination of 0.912 ~0.938 and 0.898 ~0.917 for $PM_{2.5}$ and PM_{10}, respectively. Moreover, over 92.7% and 90.3% of measured $PM_{2.5}$ and PM_{10} concentrations fell within the 95% prediction intervals,

收稿日期:2026-02-02　修回日期:2026-03-02
基金项目:国家自然科学基金项目(32272006)
作者简介:张硕(1996—),女,博士生,主要从事设施农业环境调控研究,E-mail:zhangshuo22@mails.jlu.edu.cn
通信作者:隋媛媛(1985—),女,副教授,博士,主要从事设施农业环境调控与农情信息感知研究,E-mail:suiyuan@jlu.edu.cn

confirming the accuracy and reliability of the model. Overall, the proposed framework integrating outdoor pollution levels with indoor microclimate parameters provided an effective approach for interpreting and predicting particulate matter dynamics in greenhouses, supporting precision environmental regulation and effective crop production management.

Key words: solar greenhouse; particulate matter; dynamic transport mechanism; machine learning; predicting model

0　引言

为应对气候变化对全球粮食安全带来的不确定性，温室设施生产已成为世界各国降低生产风险、提升粮食供给效率的重要途径。中国是设施农业大国，设施园艺面积位居世界首位。截至 2022 年，我国设施园艺总面积已达 280 多万公顷，占世界设施总面积的 80% 以上[1]，其中，日光温室是我国特有的温室结构类型，在中国北方地区广泛应用[2]。中国东北地区受高纬度地理区位影响，冬季持续时间长且气候条件严酷，是农业生产的主要限制因素[3-4]。温室设施通过创建可控的微气候环境，能够有效优化环境条件、延长作物有效生长期，并显著提升单位面积产量与品质，从而在一定程度上缓解区域气候约束对农业生产的影响。

然而，由于温室采用半封闭式系统结构，外界颗粒物易通过通风系统及围护结构缝隙渗透进入温室内环境，进而对温室微环境稳定性与生态平衡构成显著威胁。其中，空气动力学直径小于等于 2.5 μm 颗粒物（$PM_{2.5}$）和空气动力学直径小于等于 10 μm 颗粒物（PM_{10}）因粒径小、迁移与渗透能力强而尤为值得关注。二者不仅可深入人体呼吸系统引发健康风险[5]，还会通过覆盖叶表、堵塞或诱导气孔调节异常、抑制光合作用等途径干扰作物正常生理活动，进而影响气体交换与代谢过程[6-7]。同时，还会悬浮于温室空气中降低透光率并削弱有效光照条件，进而诱发作物生长发育异常[8]。与温度、相对湿度等常规环境因子相比，颗粒物具有隐蔽性胁迫特征，在温室日常管理中往往缺乏系统监测与调控，易造成室内累积。因此，明确中国东北地区温室内不同粒径颗粒物运移机制及精准预测，可为制定差异化的温室环境动态精准调控方案提供科学依据。

室内污染物质量平衡模型用于描述室内空气中污染物浓度分布与变化的数学模型[9]。其依据质量平衡原理，全面考虑污染物源释放、室内扩散以及移除等关键过程，并通过数学方程精确地表达这些过程间的联系，但预测精度在实际应用中受限于经验参数的可获得性与时变特性。机器学习通过数据驱动，能够更高效地预测污染物浓度。人工神经网络（Artificial neural network，ANN）是模拟人脑生物机制的数学模型结构，具有特殊的学习能力和适应性[10]。其中，反向传递神经网络（Back propagation neural network，BPNN）模型具有良好的非线性学习能力和灵活的网络结构，在各方面都有较成熟应用[11-12]。但同时面对不同对象数据时，其拟合结果也会存在差异，对于不同对象选择合适的 BPNN 结构仍是问题。小波神经网络（Wavelet neural network，WNN）是由小波基函数和前馈反馈网络结构组成的网络，在短期预测中具有更高精度、稳定性和更快训练速度，因此被广泛应用于多领域[13-14]。然而，在数据模型训练过程，初始随机权重会导致训练方向的不确定性，并降低训练效率。遗传算法（Genetic algorithm，GA）作为模仿生物进化过程的智能优化算法，通过近似自然进化方式搜索目标问题最优解[15-16]。采用 GA-WNN 能够全面搜索目标个体，通过进化过程多代遗传、变异和交换操作避免陷入局部最优，显著提升预测模型准确性和训练速度，但该架构在实际应用研究仍较为有限，可行性与准确性仍有待进一步验证。

本文以中国东北地区典型日光温室为研究对象，结合实际生产中常见 3 种通风情景（渗透通风、下墙通风、下墙-后墙通风），构建温室内外颗粒物（$PM_{2.5}$和 PM_{10}）浓度的动态运移机制。综合考虑温室内温度、相对湿度、风速以及温室外颗粒物浓度等关键驱动因子，建立并验证 GA-WNN 预测模型，以实现对温室内不同粒径颗粒物浓度的精准定量预测，为制定差异化的温室环境动态精准调控方案提供科学依据。

1　材料与方法

1.1　试验温室概况

试验日光温室位于吉林省蔬菜花卉科学研究院（43°83′N，125°40′E），结构与尺寸如图 1 所示。温室采用拱形钢桁架结构，室内无支柱。坐北朝南，东西走向，长度 32 m，跨度 8 m，脊高 4.4 m，北屋面水平投影长 2 m，后墙高度 2.4 m。后墙由厚 0.34 m 内部砖墙和厚 0.11 m 外部聚苯板组成。白天覆盖透明的 PO 薄膜，厚度为 0.1 mm，夜间覆盖太空棉保温被保温。共设有下、后墙 2 处通风口，均为卷膜启动闭合，最大开度 1.5 m，并自动控制通风口开度和

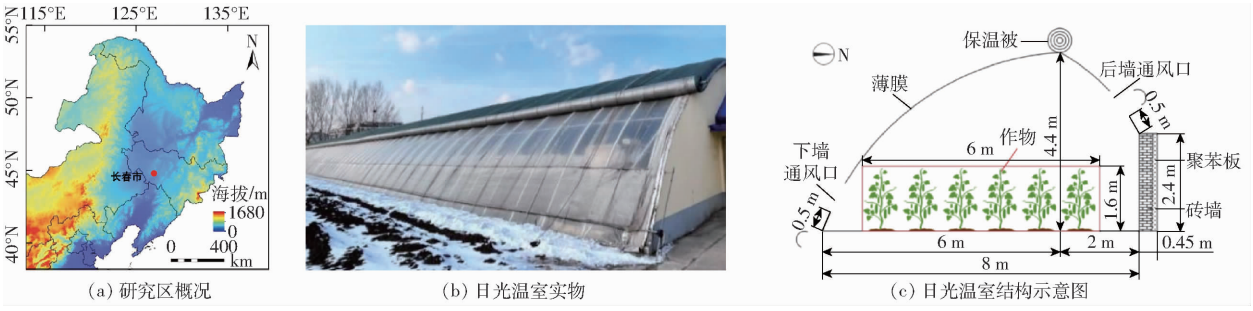

(a) 研究区概况 (b) 日光温室实物 (c) 日光温室结构示意图

图 1 日光温室结构与尺寸

Fig. 1 Structure and size of solar greenhouse

开启时间,确保室内温度维持在适宜范围内。东侧配有缓冲间,试验期间缓冲间窗户和屋门关闭。室内种植作物为番茄,南北方向种植,共有 15 垄,每垄长 6 m,宽 1 m,垄间距 1 m,番茄植株高 1.6 m。表 1 为日光温室 3 种通风模式。

表 1 日光温室 3 种类型通风模式

Tab. 1 Three ventilation modes of solar greenhouse

边界条件	渗透通风 (SG-1)	后墙通风 (SG-2)	下、后墙通风 (SG-3)
下墙通风口	关	关	开
后墙通风口	关	开	开
颗粒物入口边界	下墙通风口	后墙通风口	下墙通风口

1.2 试验数据获取

试验于 2023 年 6 月 29 日—2024 年 7 月 1 日进行,试验期间对日光温室内温度、相对湿度、风速、光照强度、压强以及 $PM_{2.5}$ 和 PM_{10} 浓度进行持续监测。温室内环境因子测量采用 9 点布点测量方式,高度分别为 0.8、1.6、2.5 m,共布置 27 个监测点,如图 2 所示。

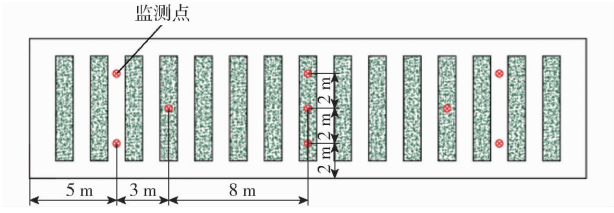

图 2 测点布置平面示意图

Fig. 2 Layout plan of measuring points

使用空气质量检测传感器(RS-MG,仁科)采集温室内温度、相对湿度、光照度、压强以及 $PM_{2.5}$ 和 PM_{10} 浓度数据。温度测量范围 -40 ~ 80℃,精度 ±0.5℃,分辨率 0.1℃;相对湿度测量范围 0 ~ 100%,精度 ±3%,分辨率 0.1%;光照度测量范围 0 ~ 200 000 Lux,精度 ±7%,分辨率 1 Lux;$PM_{2.5}$ 和 PM_{10} 浓度(质量浓度)测量范围 0 ~ 1 000 μg/m³,精度 ±3%,分辨率 1 μg/m³。温室内风速使用手持式 DLY-1603A 型多功能风速仪进行采集,风速测量范围 0 ~ 45 m/s,精度 ±0.3 m/s,分辨率 0.1 m/s。27 个传感器依据对应测量点进行布置,数据自动记录,时间间隔为 1 min。所有传感器在试验前均已在温室环境中完成校准。观测周期持续进行,每天持续 24 h。

使用锦州阳光气象公司生产的 PC-8 型便携式气象环境站采集温室外环境因子,气象环境站测量高度 2 m,位于室外开阔处。

1.3 温室内、外颗粒物浓度动态模型构建

建立运移方程主要是从质量守恒角度构建温室内、外颗粒物浓度变化关系。由于室内外环境动态变化,颗粒物来源与去向也随之变化。室内颗粒物浓度变化需综合考虑各种输运作用,如颗粒物散发源、颗粒物沉降、沉积及去除,同时结合室内外通风情况、建筑围护结构颗粒物穿透率,计算温室内颗粒物浓度[17]。具体平衡关系为

$$V\frac{\mathrm{d}C_i}{\mathrm{d}t}=(Q_n+F_{inf}Q_s+Q_m)(C_o-C_i)-k_dVC_i \quad (1)$$

式中 C_i——温室内颗粒物浓度,μg/m³

t——时间,h

Q_n——自然通风量,m³/h

F_{inf}——渗透系数

Q_s——渗透通风量,m³/h

C_o——温室外颗粒物浓度,μg/m³

k_d——温室内颗粒物沉积率

Q_m——机械通风量,m³/h

V——温室体积,m³

F_{inf} 用于表征环境空气污染物进入温室内并持续悬浮的比例,也可称为穿透系数。由于风压、热压和通风情况导致 F_{inf} 随时间呈明显的阶段性与波动性变化。假设室内空气充分混合且室内颗粒物浓度恒定[18],可利用该系数测定室内外颗粒物浓度比值(I/O)。F_{inf} 计算式为

$$F_{inf}=\frac{C_i}{C_o}=I/O \quad (2)$$

1.3.1 渗透通风

当温室内为通风口及窗户全部关闭且无机械通

风的封闭状态时，室内颗粒物浓度只有室外渗透进入，室内颗粒物平衡表达式为

$$V\frac{\mathrm{d}C_i}{\mathrm{d}t}=F_{inf}Q_s(C_o-C_i)-k_dVC_i \tag{3}$$

则颗粒物浓度表达式为

$$C_t=\frac{F_{inf}Q_sC_o}{F_{inf}Q_s+k_dV}-\left(\frac{F_{inf}Q_sC_o}{F_{inf}Q_s+k_dV}-C_{t-1}\right)\mathrm{e}^{-\left(\frac{F_{inf}Q_s}{V}+k_d\right)t} \tag{4}$$

使用缝隙计算法计算渗透风量，温室通风口处渗透风量计算式为

$$Q_s=L\alpha(\Delta P_e)^b \tag{5}$$

式中　α——风压系数，取 0.5 ~ 0.6[19]

ΔP_e——内外压强差，Pa

b——缝隙渗风特征系数，取 0.67

1.3.2　自然通风

自然通风指室内外风力作用下风压形成室内外空气流动的换气方式。当温室处于通风口开启且无机械通风的封闭状态时，室内颗粒物主要由通风口流动，室内颗粒物平衡表达式为

$$V\frac{\mathrm{d}C_i}{\mathrm{d}t}=(Q_n+F_{inf}Q_s)(C_o-C_i)-k_dVC_i \tag{6}$$

则颗粒物浓度表达式为

$$C_t=\frac{F_{inf}Q_sC_o+Q_nC_o}{Q_n+F_{inf}Q_s+k_dV}-\left(\frac{F_{inf}Q_sC_o+Q_nC_o}{Q_n+F_{inf}Q_s+k_dV}-C_{t-1}\right)\mathrm{e}^{-\left(\frac{Q_n+F_{inf}Q_s}{V}+k_d\right)t} \tag{7}$$

自然通风量表达式为

$$Q_n=A\beta\sqrt{\frac{2\Delta P_e}{\rho}} \tag{8}$$

式中　A——通风口面积，m^2

β——流量系数，取 0.65

ρ——空气密度，取 1.2 kg/m^3

2　机器学习模型

2.1　GA－WNN 模型构建

WNN 是基于小波变换相同原理产生的特定神经网络。在构建机理上分为 2 类；①以小波变换工具提取神经网络输入输出特征，用于其他神经网络训练的离散型小波神经网络。②形式上以反向传递神经网络拓扑结构为基础，将隐藏节点激活函数替换为小波基函数，形成连续性小波神经网络[20]。由于小波基函数的引入，WNN 对于时频域的对象处理有更多优势。本文以连续性小波神经网络为对象进行建模，图 3 为 WNN 网络结构，主要由输入层、隐藏层和输出层组成。

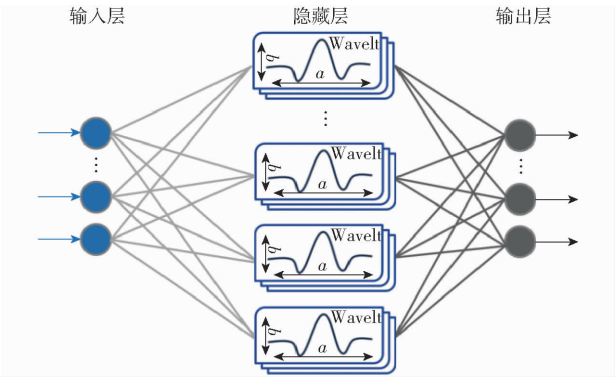

图 3　小波神经网络结构

Fig. 3　Schematic of WNN structure

遗传算法是一种模仿生物进化过程的智能优化算法，通过数学仿真运算，将问题求解过程转换为类似生物进化过程[21]。GA 从优化随机解中大范围搜索最优解，选择面越广泛越利于全局择优。因此 GA 在对不同复杂组合优化问题时拥有较快效率和更优结果[22－23]。GA－WNN 相比于单独 WNN，额外引入全局算法优化，使神经网络在训练开始前筛选出最优适应个体，作为最优初始权值，以提高整体网络收敛速度和预测效果。

模型训练中，BPNN 模型采用单隐藏层结构。输入层为 4 个输入节点，输入变量包括温室内温度、相对湿度、风速以及室外颗粒物浓度；输出节点为室内颗粒物浓度。其中，隐藏层激活函数采用 Tansig，输出层激活函数采用 Purelin 以满足连续值回归需求。模型训练采用反向传播计算梯度，隐藏层节点数为 20，参数更新采用 Adam 优化算法。

WNN 模型同样采用单隐藏层结构。输入变量和输出变量与 BPNN 一致。其中，隐藏层激活函数采用 Morlet，输出层激活函数采用 Purelin 以满足连续值回归需求。模型训练采用反向传播计算梯度，隐藏层节点数为 20，参数更新采用 Adam 优化算法。

GA－WNN 模型中，GA 配置初始化种群为 100 个，交叉概率为 0.8，变异概率为 0.1。1 次训练共进行 100 次种群进化。优化完成返回最优个体，继续进行神经网络部分训练。输入层为 4 个输入节点，输入变量包括温室外颗粒物浓度、温室内温度、相对湿度以及风速；输出变量为温室内颗粒物浓度；其中激活函数为 Purelin 函数；隐藏层节点数设为 20，激活函数为 Morlet 小波基函数。网络参数采用反向传播进行基于梯度的更新，优化器为 Adam。

2.2　模型验证

采用相对误差、决定系数（R^2）、平均绝对误差（MAE）和均方根误差（RMSE）评估模型性能。

3 结果与讨论

3.1 温室内、外颗粒物时序变化规律

如图 4 所示，温室外 $PM_{2.5}$ 浓度为 4.15 ~ 235.60 μg/m³，PM_{10} 浓度为 11.08 ~ 267.94 μg/m³。根据 GB 3095—2012《大气环境质量标准》，$PM_{2.5}$ 24 h 二级标准值为 75 μg/m³，一级标准值为 35 μg/m³。PM_{10} 24 h 二级标准值为 150 μg/m³，一级标准值为 50 μg/m³。$PM_{2.5}$ 浓度分别有 51、115 d 超过二级和一级标准。PM_{10} 浓度分别有 10、152 d 超过二级和一级标准。除限值差异外，污染物粒径决定的形成与清除机制也导致 $PM_{2.5}$ 与 PM_{10} 超标天数差异。$PM_{2.5}$ 更易受燃烧排放及二次生成（硫酸盐、硝酸盐与二次有机气溶胶）驱动，在静稳、逆温与高湿等不利扩散条件下更易累积并形成连续高值过程[24]；而 PM_{10} 中粗颗粒占比更高，常受扬尘、再悬浮与风速扰动影响，且沉降去除更快[25]，往往呈现超过较低阈值（>50 μg/m³）但难以长期维持并跨越更高阈值（>150 μg/m³）特征。

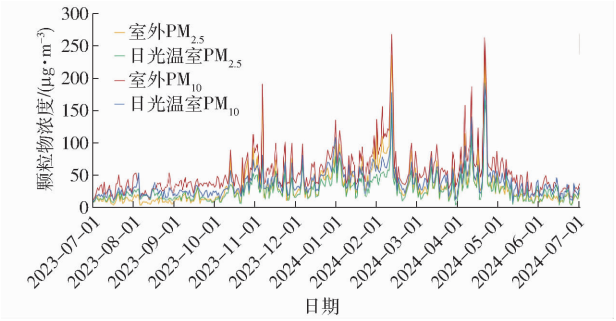

图 4 日光温室与室外颗粒物浓度变化曲线

Fig. 4 Variation curves of particulate matter concentration in solar greenhouse and outdoor

其中，超标日集中在 10 月至次年 1 月，显示出明显的季节性聚集特征。这种现象与长春地区特有的气候-能量耦合机制密切相关：①冬季供暖系统高强度运行导致生物质燃烧产生的颗粒物及其前体污染物（SO_2、氮氧化物）排放增加[26]。②冬季稳定的大气边界层使污染物积聚加剧，严重阻碍污染物垂直扩散[27]。这种由气候变化驱动的典型污染模式，最终导致长春地区颗粒物浓度持续升高。

温室内 $PM_{2.5}$ 浓度为 3.29 ~ 171.92 μg/m³，PM_{10} 浓度为 8.43 ~ 192.75 μg/m³。从季节性来看，除夏季外，温室外颗粒物浓度均高于室内浓度，源于夏季高温时通风和散热需求增加导致温室内气流速度加快，从而增加空气动力剪切力，使沉降颗粒重新悬浮并提升了颗粒物浓度[28]。由于 PM_{10} 中粗颗粒（粒径 2.5 ~ 10 μm）对气流扰动更为敏感，夏季温室内 PM_{10} 浓度较 $PM_{2.5}$ 浓度增长 18.34%。温室内较高风速与湍流强度显著促进地表及作物表面沉积颗粒再悬浮，从而优先抬升 $PM_{2.5-10}$ 浓度，并驱动 PM_{10} 整体浓度上升[29]。同时，较强的气流剪切与湍流扩散作用可延长粗颗粒悬浮时间，进一步放大 PM_{10} 相对于 $PM_{2.5}$ 浓度增幅。并且日光温室覆盖了聚氯乙烯材料，其表面极易产生静电，导致颗粒物附着其上；随后风速增加会引发这些颗粒物再悬浮。此外，聚氯乙烯在炎热夏季可能释放挥发性有机物（VOCs），这些物质经光化学反应生成次生颗粒物（如硝酸盐和硫酸盐），从而提高温室内颗粒物浓度。

3.2 温室内、外颗粒物动态运移模型验证

采用室外颗粒物浓度按小时变化处理方式，即在每 1 h 内，室外颗粒物浓度视为恒定值。按照小时为最小计算时段，选取不同通风方式 F_{inf} 最大值和最小值，求解温室内颗粒物浓度最大值 $C_{i,\max}$ 和最小值 $C_{i,\min}$，得到不同通风方式下温室内颗粒物浓度范围，如图 5、6 所示。SG-1 室内颗粒物浓度水平最高，说明在缺乏主动通风稀释条件下，$PM_{2.5}$ 和 PM_{10} 浓度均受外界输入驱动且呈现累积特征。说明在密闭渗透主导的换气模式下，F_{inf} 波动会直接放大室内颗粒物浓度预测的不确定性。对于 SG-2，室内颗粒物浓度显著降低且波动幅度收敛。表明上通风口开启后，温室内形成一定的排出通道与混合稀释效应，使得外界波动向室内传递被钝化，系统更接近输入与去除的动态平衡状态，且等效渗透水平更接近中值。对于 SG-3，室内颗粒物浓度最低，说明该通风模式不仅增强了通风稀释，而且在等效意义

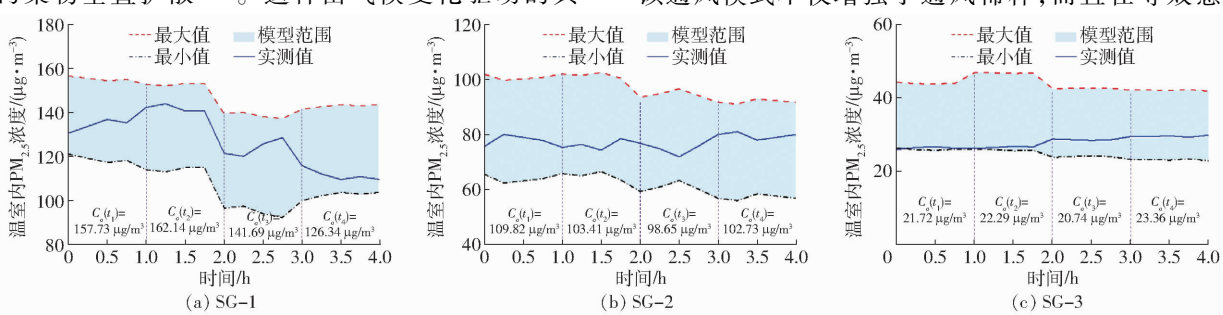

图 5 日光温室 $PM_{2.5}$ 动态运移模型浓度范围与实测值

Fig. 5 Concentration range of $PM_{2.5}$ dynamic transport model and measured value in solar greenhouse

上削弱了渗透输入对室内颗粒物浓度的控制作用。并且在室外颗粒物浓度较低背景下，室内 $PM_{2.5}$ 和 PM_{10} 浓度实测值均略高于室外，并且 PM_{10} 浓度高于模型最大值，说明除渗透外存在背景滞留、地表沉积再悬浮等内部源汇贡献。如表 2 所示，整体模型平均计算值与实际观测值间相对误差为 0.68% ~ 9.73%，较好地验证了室外颗粒物对温室内颗粒物浓度的影响。

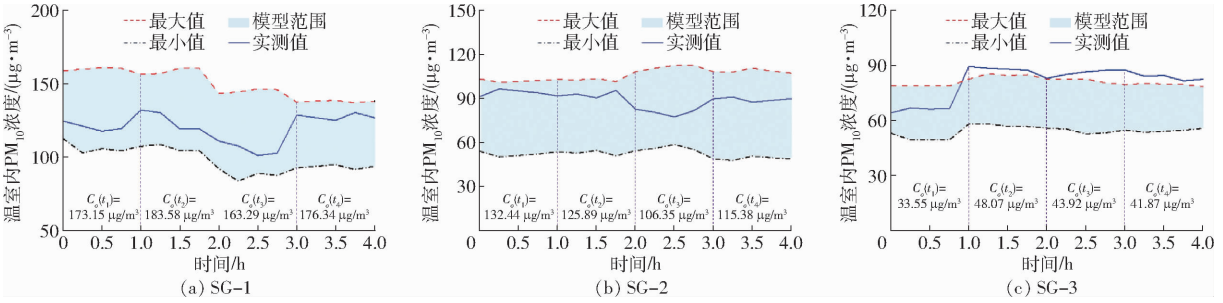

图 6　日光温室 PM_{10} 动态运移模型浓度范围与实测值

Fig. 6　Concentration range of PM_{10} dynamic transport model and measured value in solar greenhouse

表 2　日光温室不同通风模式下动态运移模型的相对误差和 RMSE

Tab. 2　MAE and RMSE for dynamic transport model under different ventilation modes in solar greenhouse

参数	SG－1		SG－2		SG－3	
	$PM_{2.5}$	PM_{10}	$PM_{2.5}$	PM_{10}	$PM_{2.5}$	PM_{10}
相对误差/%	0.83 ~ 2.61	2.24 ~ 9.73	0.92 ~ 1.98	1.98 ~ 8.61	0.68 ~ 1.67	2.07 ~ 6.90
RMSE/(μg·m^{-3})	1.07 ~ 3.32	1.97 ~ 11.44	0.84 ~ 3.47	2.05 ~ 10.83	1.04 ~ 2.18	2.36 ~ 7.39

与 $PM_{2.5}$ 相比，室内 PM_{10} 浓度对室外 PM_{10} 响应较弱，主要源于与粒径相关的传输和留存机制差异。在质量守恒框架下，室内颗粒物浓度受室外渗透输入主导，但 PM_{10} 因粒径较大，在通过通风口及建筑缝隙时更易发生惯性碰撞与拦截[30]，导致渗透效率显著低于 $PM_{2.5}$；同时，PM_{10} 具有更高的沉降速率与沉积通量，在作物、地面及构筑物表面沉积更快，室内滞留时间更短。此外，温室内存在丰富的粗颗粒物源（如土壤、积尘等），在通风增强时易发生再悬浮，使得室内 PM_{10} 变化更易受内部扰动主导，从而降低与室外 PM_{10} 相关性。相比之下，$PM_{2.5}$ 渗透能力强、沉降缓慢，且室内源有限，因此浓度变化更显著地受室外 $PM_{2.5}$ 驱动。

3.3　温室环境因素与颗粒物浓度相关性分析

如图 7 所示，采用相关系数矩阵对温室内外环境因子间耦合关系进行了定量分析。结果表明，温室内 $PM_{2.5}$ 和 PM_{10} 浓度与室外颗粒物水平呈显著联动趋势，说明室内颗粒物浓度主要受室外背景浓度通过渗透与通风交换输入的影响，符合外源输入主导的传输机制。同粒径室内-室外对应关系最为紧密，室内 PM_{10} 随室外 PM_{10} 同步变化、室内 $PM_{2.5}$ 随室外 $PM_{2.5}$ 同步变化，说明温室颗粒物浓度主要受室外背景浓度变化驱动，室内同粒径颗粒物浓度对外界污染过程具有明显的响应特征。

同时，风速与室内 $PM_{2.5}$ 和 PM_{10} 浓度整体呈负相关，风速适当增强通常更有利大气扩散条件或更强的换气稀释效应，有助于抑制颗粒物在室内累积，体现了其对颗粒物输运与稀释的关键影响。在温湿因子方面，温度与相对湿度呈显著负相关，反映了温室环境中典型的热湿耦合规律；通风过程对热量与水汽同步交换进一步强化了耦合关系，表明气象因子间存在明显的传递与约束作用。此外，温度和相对湿度也与室内颗粒物浓度显著相关。基于上述相关性分析结果，最终选取室外颗粒物浓度、室内温度、相对湿度及风速作为预测模型输入变量。

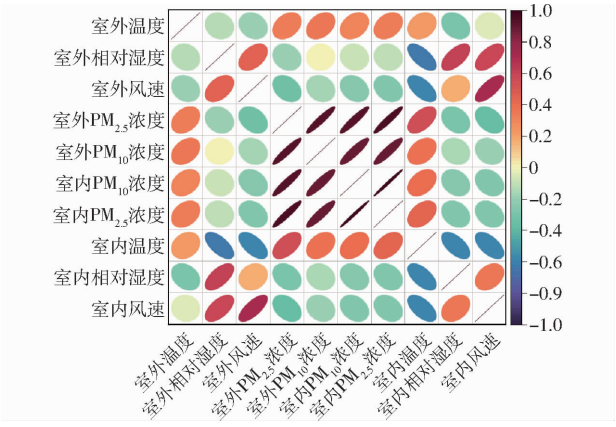

图 7　不同通风模式下环境因素与颗粒物浓度的相关性分析

Fig. 7　Correlation analysis of environment factors and particulate matter concentration at different ventilation modes

3.4　模型结果验证与分析

表 3 为 3 种通风模式下温室 $PM_{2.5}$ 和 PM_{10} 浓度训练集与验证集 R^2。从表 3 可知，3 种模型在不同

通风模式下均能较好表征温室内颗粒物浓度变化，但整体性能呈现稳定排序：GA－WNN 最优、WNN 次之、BPNN 相对最低，且该结论对 $PM_{2.5}$ 与 PM_{10} 浓度预测均保持一致。与此同时，GA－WNN 训练与验证差距整体更小，说明遗传算法的全局寻优有助于缓解小波神经网络参数寻优过程的局部最优问题，从而提升复杂非线性条件下拟合能力与泛化稳定性。进一步对比 2 类污染物可发现，$PM_{2.5}$ 整体预测精度略高于 PM_{10}，说明在相同模型与通风模式下，$PM_{2.5}$ 主要受室外背景与交换过程连续性调制，而 PM_{10} 在此基础上更易受到再悬浮、沉降等局地随机过程影响，导致可预测性相对降低。由图 8（图中 R_c^2、R_p^2 分别为训练集和验证集决定系数）可知，GA－WNN 模型能有效捕捉 $PM_{2.5}$ 和 PM_{10} 主要变化特征。值得注意的是，随着颗粒物浓度升高，95% 预测带出现明显扩张，说明高污染过程的不确定性增加，与颗粒物受瞬时通风状态变化、外界输入突变及局地扰动影响增强的事实相吻合。从定量指标看，在 3 种通风工况下 GA－WNN R_p^2 为 0.898～0.938，均表现出最优的拟合与泛化能力。

表 3 不同通风模式下 3 种模型对温室内 $PM_{2.5}$ 和 PM_{10} 浓度的预测 R^2

Tab. 3 R^2 of three models for predicting $PM_{2.5}$ and PM_{10} concentrations in greenhouse under different ventilation modes

颗粒物	通风模式	BPNN		WNN		GA－WNN	
		训练集	验证集	训练集	验证集	训练集	验证集
$PM_{2.5}$	SG－1	0.923	0.894	0.935	0.903	0.947	0.925
	SG－2	0.917	0.899	0.934	0.908	0.951	0.938
	SG－3	0.895	0.861	0.907	0.892	0.931	0.912
PM_{10}	SG－1	0.904	0.891	0.915	0.901	0.938	0.917
	SG－2	0.895	0.872	0.907	0.884	0.920	0.905
	SG－3	0.867	0.833	0.879	0.853	0.912	0.898

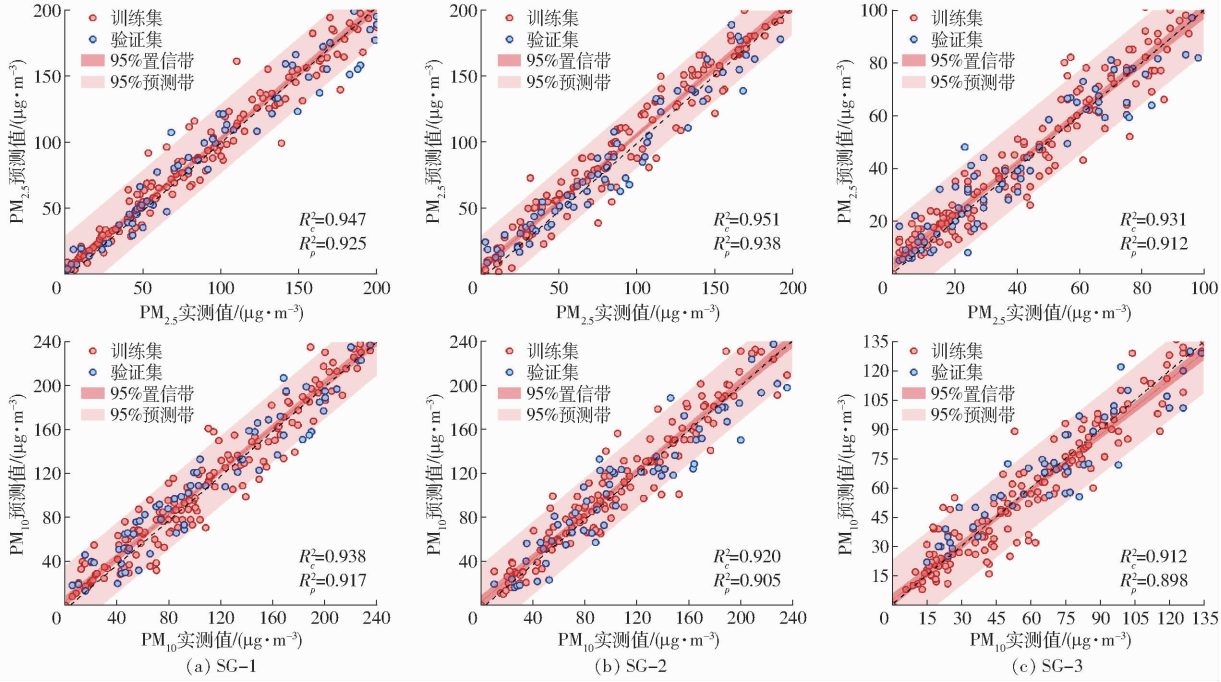

图 8 不同通风模式下基于 GA－WNN 模型的 $PM_{2.5}$ 和 PM_{10} 浓度预测值与实测值散点图

Fig. 8 Scatter plots of predicted and measured values of $PM_{2.5}$ and PM_{10} concentrations under different ventilation modes

GA－WNN 对极端事件具有更强捕捉能力的机理主要来自小波多尺度表征与遗传算法全局寻优的协同作用[31]。温室颗粒物的极端过程通常具有非平稳性与时间局部性，可能由室外颗粒物浓度短时突增、通风口状态切换导致的流场重构、短路流形成或近地层再悬浮等触发。与采用全局激活函数、易产生平滑化偏差的 BPNN 不同，WNN 采用小波基函数作为隐层单元，具有明显的局部响应与多尺度分辨能力，可同时拟合低频背景变化与高频突变过程，从而降低对尖峰的削顶倾向。在此基础上，GA－WNN 通过遗传算法对小波网络的尺度、平移与权重等关键参数进行全局搜索优化，能够缓解梯度训练在非凸损失函数下对初值敏感、易陷入局部最优的问题，使小波核更准确对齐尖峰发生的时间位置与特征时间尺度，进而提升尖峰幅值刻画能力与验证集预测稳定性。

与 SG－1 和 SG－2 相比，3 种模型下 SG－3 的 R_p^2 整体偏低，可能与 2 方面因素有关：①SG－3 颗粒物浓度动态范围较窄，导致测量噪声与局地扰动对相对误差贡献被放大。②下进上出通风模式更易引发近地层流扰动，入口射流对地表沉积颗粒再悬浮效应可能增强。相对而言，SG－1 与 SG－2 在验

证集下呈现更稳定的输入与输出映射，因此模型更易学习并获得更高的 R_p^2。综合来看，GA－WNN 在 3 类通风策略下均表现出最优的一致性与泛化能力，可为温室空气质量风险评估与控制预测提供更可靠的模型支撑。

图 9 为 MAE 和 RMSE 误差分析，3 种模型 $PM_{2.5}$ 和 PM_{10} 误差分布呈现一致的排序关系：GA－WNN 的 MAE 与 RMSE 均处于最低水平且分布最为集中，表明其预测误差不仅更小且稳定性更优；WNN 次之；BPNN 误差最高且离散度最大。值得注意的是，BPNN 的 RMSE 显著高于其 MAE，说明模型在少量样本上产生了较大预测偏差，反映对颗粒物突变及极端天气的鲁棒性不足。相较之下，GA－WNN 的 RMSE 与 MAE 间差距较小且尾部收敛，表明能够有效抑制极端误差，对极端事件具有更强的表征与泛化能力，充分证明了 GA－WNN 模型在温室环境中对污染物浓度场的精准预测能力。

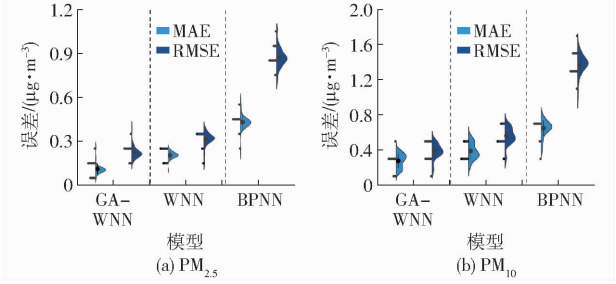

图 9　MAE 和 RMSE 误差分布

Fig. 9　MAE and RMSE error distributions

各模型误差直方图如图 10 所示，直观呈现了模型在训练和测试场景性能表现。由图 10 可知，GA－WNN 模型在 $PM_{2.5}$ 和 PM_{10} 浓度预测方面均展现出最低误差。

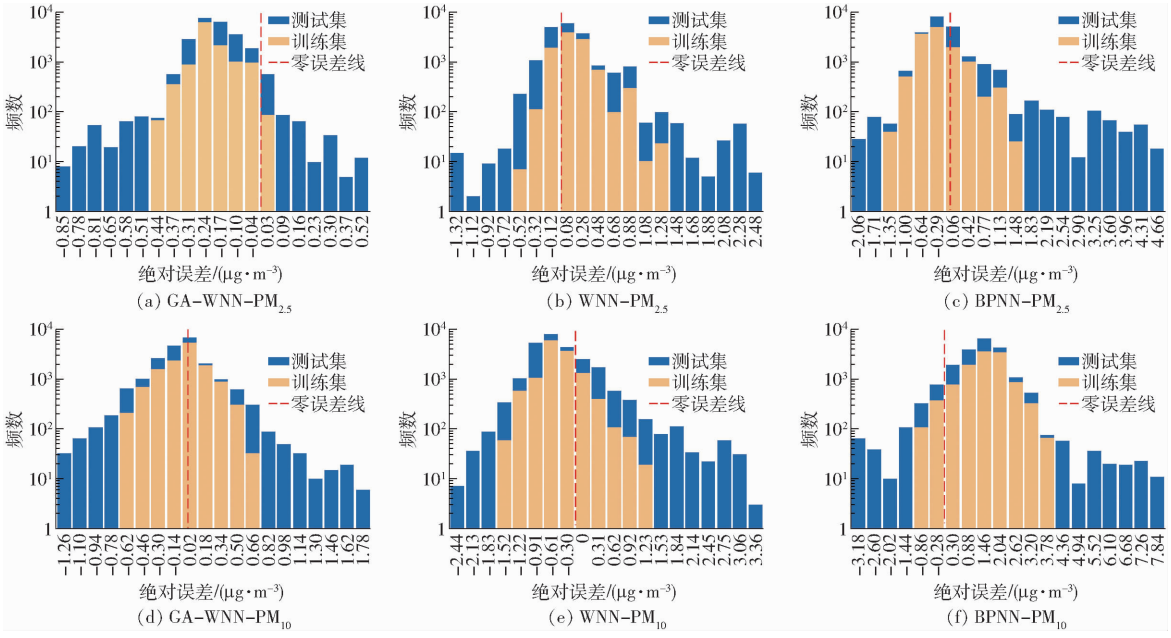

图 10　模型误差直方图

Fig. 10　Error histograms of advanced models

3.5　GA－WNN 模型预测对比

图 11 为测试集实测 $PM_{2.5}$ 和 PM_{10} 日均浓度在 95% 预测区间内覆盖范围。通过对比部分测试集时间趋势发现，超过 92.7% 实测 $PM_{2.5}$ 浓度均落在 95% 预测区间内，以及超过 90.3% 实测 PM_{10} 浓度均落在 95% 预测区间内。研究结果表明，基于环境数据的 GA－WNN 预测模型具有合理性，在预测温室内颗粒物浓度方面展现出良好的泛化能力。预测结果与实测序列整体高度一致，能够同时捕捉季节性趋势与短时尖峰变化；实测值大多落入 95% 预测区间，表明 GA－WNN 模型在概率意义上具有良好的覆盖性。值得注意的是，预测区间在高浓度与极端

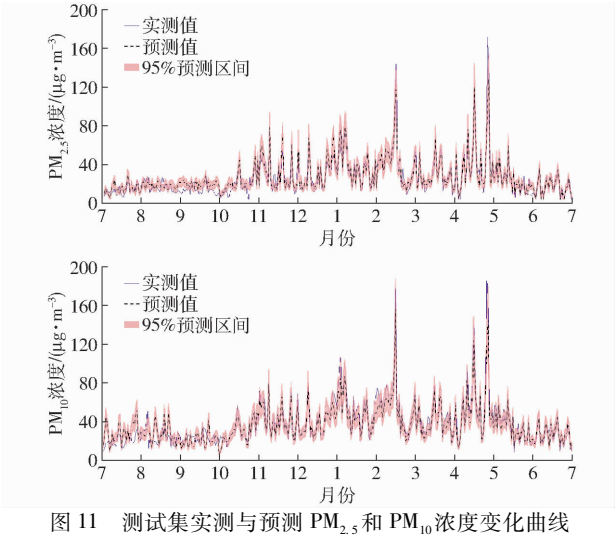

图 11　测试集实测与预测 $PM_{2.5}$ 和 PM_{10} 浓度变化曲线

Fig. 11　Variation curves of measured and predicted $PM_{2.5}$ and PM_{10} concentrations for test dataset

峰值阶段明显变宽,说明不确定性随污染程度增强而增大,极端事件仍是模型误差的主要来源之一。GA－WNN 模型在应对突发状况时存在不足,其预测能力仍有提升空间。

4 结论

(1)阐明了不同通风模式下日光温室内颗粒物运移机制,构建温室内外 $PM_{2.5}$ 和 PM_{10} 浓度动态平衡方程,能够依据室外颗粒物浓度的实时变化,较为准确地量化室内颗粒物浓度变化范围。模型计算值与实测值相对误差为 0.68% ~9.73%,较好地验证了外界颗粒物对温室内颗粒物浓度的影响。

(2)定量分析了温室内外环境因子与室内 $PM_{2.5}$ 以及 PM_{10} 浓度的关系。其中,同一粒径范围内室内与室外颗粒物浓度变化相关性最强;相比 $PM_{2.5}$,温室内 PM_{10} 对室外颗粒物变化的响应较弱。颗粒物浓度呈季节性变化,且夏季温室内 PM_{10} 浓度较 $PM_{2.5}$ 浓度增长 18.34%。筛选出室外颗粒物浓度、室内温度、相对湿度及风速等因素作为温室内颗粒物预测模型输入变量。

(3)GA－WNN 模型能够精准预测温室内 $PM_{2.5}$ 和 PM_{10} 浓度,R^2 分别为 0.912 ~0.938 和 0.898 ~0.917,均展现出低误差率和稳定性能,并且超过 92.7% 和 90.3% 的实测 $PM_{2.5}$ 和 PM_{10} 浓度落在 95% 预测区间内;相较于 BPNN 和 WNN 模型,GA－WNN 模型在预测日光温室不同通风模式颗粒物浓度方面展现出显著优势,表现出最优的拟合与泛化能力。

参 考 文 献

[1] 李天来,齐明芳,孟思达. 中国设施园艺发展 60 年成就与展望[J]. 园艺学报,2022,49(10):2119－2130.
LI Tianlai, QI Mingfang, MENG Sida. Sixty years of facility horticulture development in China: achievements and prospects [J]. Acta Horticulturae Sinica, 2022, 49(10): 2119－2130. (in Chinese)

[2] 毕玉革,麻硕士,崔红梅,等. 北方干寒地区日光温室 CO_2 预测模型建立与冬季试验[J]. 农业机械学报,2010,41(12):183－189.
BI Yuge, MA Shuoshi, CUI Hongmei, et al. Forecasting model of CO_2 concentration of solar greenhouse in the northern drought cold area and experimental verification in winter[J]. Transactions of the Chinese Society for Agricultural Machinery, 2010, 41(12): 183－189. (in Chinese)

[3] CHEN L, LI S, QIN X, et al. Change characteristics and prediction of climatic conditions of heating in Northeast China[J]. Journal of Natural Resources, 2014, 29(7): 1185－1195.

[4] 汪恩良,富翔,韩红卫,等. 中国东北地区季节性积雪导热系数及温度变化特征分析[J]. 农业机械学报,2021,52(1):154－163.
WANG Enliang, FU Xiang, HAN Hongwei, et al. Analysis of thermal conductivity and temperature variation characteristics of seasonal snow in Northeast China[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 154－163. (in Chinese)

[5] MOLINA C, TORO A R, MANZANO C, et al. Airborne aerosols and human health: leapfrogging from mass concentration to oxidative potential[J]. Atmosphere, 2020, 11(9): 917.

[6] DARESTA B E, ITALIANO F, GENNARO G D, et al. Atmospheric particulate matter (PM) effect on the growth of *Solanum lycopersicum* cv. Roma plants[J]. Chemosphere, 2015, 119: 37－42.

[7] MIRLEAU-THEBAUD V, DAYDE J, SCHEINER J D. The influence of soil compaction and conservation tillage on sunflower's (*Helianthus annuus* L.) below ground system[J]. Phyton-International Journal of Experimental Botany, 2017, 86: 53－67.

[8] LEE J H, HONG E P, LEE S I, et al. Experimental study for the reproduction of particulate matter deposition on greenhouse plastic films[J]. Biosystems Engineering, 2022, 223: 189－205.

[9] 许悦,王可,刘雪梅,等. 室内外 $PM_{2.5}$ 中金属元素的污染特征及来源[J]. 中国环境科学,2018,38(4):1257－1264.
XU Yue, WANG Ke, LIU Xuemei, et al. Pollution characteristics and sources of metal elements in indoor and outdoor $PM_{2.5}$ [J]. China Environmental Science, 2018, 38(4): 1257－1264. (in Chinese)

[10] MEHDI K, MEHDI B. A novel hybridization of artificial neural networks and ARIMA models for time series forecasting[J]. Applied Soft Computing, 2011, 11(2): 2664－2675.

[11] 李骅,吕大伟,王永健,等. 基于 BP－NSGA－Ⅱ算法的小麦低损脱粒自适应调控方法[J]. 农业机械学报,2025,56(11):243－252.
LI Hua, LÜ Dawei, WANG Yongjian, et al. Adaptive regulation of low-loss threshing in wheat based on BP－NSGA－Ⅱ algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 243－252. (in Chinese)

[12] 杨仕,陈维汉,杨明金,等. 基于机器学习的空气源热泵干燥能耗回归预测[J]. 农业工程学报,2024,40(2):41－51.
YANG Shi, CHEN Weihan, YANG Mingjin, et al. Regression prediction of the energy consumption of air source heat pump drying based on machine learning[J]. Transactions of the CSAE, 2024, 40(2): 41－51. (in Chinese)

[13] ZHANG J, WALTER G G, MIAO Y B, et al. Wavelet neural networks for function learning[J]. IEEE Transactions on Signal

Processing, 1995, 43(6): 1485 – 1497.

[14] CHEN Y H, YANG B, DONG J W. Time-series prediction using a local linear wavelet neural network[J]. Neurocomputing, 2006, 69(4 – 6): 449 – 465.

[15] 吴静,李振波,朱玲,等. 融合 ARIMA 模型和 GAWNN 的溶解氧含量预测方法[J]. 农业机械学报,2017,48(增刊): 205 – 210.
WU Jing, LI Zhenbo, ZHU Ling, et al. Hybrid model of ARIMA model and GAWNN for dissolved oxygen content prediction [J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 205 – 210. (in Chinese)

[16] XU X, SUN Y, KRISHNAMOORTHY S, et al. An empirical analysis of green technology innovation and ecological efficiency based on a greenhouse evolutionary ventilation algorithm fuzzy-model[J]. Sustainability, 2020, 12(9): 3886.

[17] 汪开英,李开泰,李王林娟,等. 保育舍冬季湿热环境与颗粒物 CFD 模拟研究[J]. 农业机械学报,2017,48(9):270 – 278.
WANG Kaiying, LI Kaitai, LI Wanglinjuan, et al. CFD simulation of indoor hygrothermal environment and particle matter of weaned pig building[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(9): 270 – 278. (in Chinese)

[18] ZHANG H, FAN Y, HAN Y, et al. Partitioning indoor-generated and outdoor-generated $PM_{2.5}$ from real-time residential measurements in urban and peri-urban Beijing[J]. Science of the Total Environment, 2022, 845: 157249.

[19] MARAVEAS C. Wind pressure coefficients on greenhouse structures[J]. Agriculture, 2020, 10(5): 1 – 21.

[20] 杨锡震,陈俊英,张秋雨,等. 基于小波特征和冬小麦生理参数的土壤水分高光谱模型优化[J]. 农业工程学报,2023, 39(10):66 – 75.
YANG Xizhen, CHEN Junying, ZHANG Qiuyu, et al. Optimization of the soil moisture model based on hyperspectral inversion by integrating wavelet features and growth parameters of winter wheat[J]. Transactions of the CSAE, 2023, 39(10): 66 – 75. (in Chinese)

[21] DU W, ZHANG Q, CHEN Y, et al. An urban short-term traffic flow prediction model based on wavelet neural network with improved whale optimization algorithm[J]. Sustainable Cities and Society, 2021, 69: 102858.

[22] SHARMA V, YANG D, WALSH W, et al. Short term solar irradiance forecasting using a mixed wavelet neural network[J]. Renewable Energy, 2016, 90: 481 – 492.

[23] SONG W, HUO L. Machine learning for enhancing manufacturing quality control in ultrasonic nondestructive testing: a wavelet neural network and genetic algorithm approach[J]. Advances in Production Engineering & Management, 2024, 19(3): 347 – 357.

[24] HUANG X, LIU Z, GE Y, et al. Aerosol high water contents favor sulfate and secondary organic aerosol formation from fossil fuel combustion emissions[J]. NPJ Climate and Atmospheric Science, 2023, 173(6): 1 – 10.

[25] FAN S Y, GAO Y, SHERRELL R M, et al. Concentrations, particle-size distributions, and dry deposition fluxes of aerosol trace elements over the Antarctic Peninsula in austral summer[J]. Atmospheric Chemistry and Physics, 2021, 21(3): 2105 – 2124.

[26] ZHU J, CHEN L, LIAO H, et al. Enhanced $PM_{2.5}$ decreases and O_3 increases in China during COVID – 19 lockdown by aerosol-radiation feedback[J]. Geophysical Research Letters, 2020, 48: e2020GL090260.

[27] LI Q, ZHANG H, CAI X, et al. The impacts of the atmospheric boundary layer on regional haze in North China[J]. NPJ Climate and Atmospheric Science, 2021, 4(9): 1 – 10.

[28] AMATO F, BEDOGNI M, PADOAN E, et al. Characterization of road dust emissions in Milan: impact of vehicle fleet speed [J]. Aerosol and Air Quality Research, 2017, 17: 2438 – 2449.

[29] YOU S, WAN M P. Statistical analysis of fine particle resuspension from rough surfaces by turbulent flows[J]. Aerosol and Air Quality Research, 2017, 17: 843 – 856.

[30] LÜ Y, WANG H, WEI S, et al. The experimental study on indoor and outdoor penetration coefficient of atmospheric fine particles[J]. Building and Environment, 2018, 132: 70 – 82.

[31] DAI W, WANG L, WANG B, et al. Research on WNN greenhouse temperature prediction method based on GA[J]. Phyton-International Journal of Experimental Botany, 2022, 91(10): 2283 – 2296.