

基于传感器布设优化与天气预报的温室夜间温度 Transformer – BiLSTM 预测模型

周伟^{1,2} 刘硕¹ 董远德^{1,2} 郭俊先^{1,2} 刘娜³

(1. 新疆农业大学机电工程学院, 乌鲁木齐 830052; 2. 新疆智能农业装备重点实验室, 乌鲁木齐 830052;

3. 新疆农业科学院农业机械化研究所, 乌鲁木齐 830052)

摘要: 为解决日光温室夜间温度预测中空间异质性高、成本约束和缺乏前瞻信息(如未来天气预报)等问题,本文提出一种融合传感器布设优化与天气预报的 Transformer – BiLSTM 混合预测模型。首先,通过构建基于粒子群优化 BP 神经网络的多传感器数据集成框架,并结合熵权法对传感器数据质量及物理空间分区代表性进行评估,将监测点从 12 个优化至 4 个,在显著降低成本的同时,最大限度保留了温室整体温度场的关键代表性信息。基于此优化监测方案,构建了引入天气预报作为关键输入特征的 Transformer – BiLSTM 混合预测模型。该模型融合 BiLSTM 捕获双向时序依赖与 Transformer 的全局注意力机制,增强对复杂环境动态的建模能力。基于乌鲁木齐日光温室数据的试验结果表明,本文预测模型性能显著优于 BiLSTM、Transformer 等基线模型,决定系数 R^2 达到 0.98,平均绝对误差 MAE 为 0.30℃,均方根误差 RMSE 为 0.43℃,表明模型具有较高的预测精度。在不同天气条件下的泛化性验证表明,该模型在多种气象条件下均表现出良好的鲁棒性和预测精度, R^2 普遍高于 0.96,尤其在阴天和雨天条件下精度最高。

关键词: 日光温室; 温度预测; Transformer – BiLSTM; 传感器布设; 数据集成; 天气预报

中图分类号: S27

文献标识码: A

文章编号: 1000-1298(2026)19-0384-13

OSID:



Transformer – BiLSTM Greenhouse Nighttime Temperature Prediction Model Based on Optimized Sensor Deployment and Weather Forecasting

Zhou Wei^{1,2} Liu Shuo¹ Dong Yuande^{1,2} Guo Junxian^{1,2} Liu Na³

(1. College of Mechanical and Electrical Engineering, Xinjiang Agricultural University, Urumqi 830052, China

2. Xinjiang Key Laboratory of Intelligent Agricultural Equipment, Urumqi 830052, China

3. Institute of Agricultural Mechanization, Xinjiang Academy of Agricultural Sciences, Urumqi 830052, China)

Abstract: Aiming to address challenges such as high spatial heterogeneity, cost constraints, and lack of future weather data in solar greenhouse nighttime temperature prediction, a Transformer – BiLSTM hybrid model integrating optimized sensor deployment and weather forecasts was proposed. Firstly, by constructing a multi-sensor data integration framework based on a particle swarm optimization-backpropagation (PSO – BP) neural network, and then applying the entropy weight method to evaluate data quality and spatial representativeness across physical zones, an optimized sensor deployment (reducing monitoring points from 12 to 4) was achieved. This significantly cut costs while preserving key representative information of the overall greenhouse temperature field. Building on this, a Transformer – BiLSTM hybrid prediction model incorporating weather forecasts was developed. The model fused BiLSTM's bidirectional temporal dependency capture with Transformer's global attention mechanism for enhanced modeling of complex environmental dynamics. Experimental results from a Urumqi solar greenhouse demonstrated superior performance over baseline models (BiLSTM, Transformer), achieving an R^2 of 0.98, MAE of 0.30℃, and RMSE of 0.43℃. The model also showed robust generalization

收稿日期: 2025 – 06 – 13 修回日期: 2025 – 06 – 27

基金项目: 新疆维吾尔自治区重点研发项目(2023B02020, 2022B02049 – 1)

作者简介: 周伟(1976—),女,副教授,博士,主要从事设施农业与农业物联网研究,E-mail: zhouweijd@xjau.edu.cn

通信作者: 郭俊先(1975—),男,教授,博士,主要从事农牧业机械设计与试验研究,E-mail: junxianguo@163.com

across diverse weather conditions, with R^2 values consistently above 0.96, particularly excelling under cloudy and rainy conditions.

Key words: solar greenhouse; temperature prediction; Transformer – BiLSTM; sensor deployment; data integration; weather forecasting

0 引言

日光温室作为现代设施农业的核心载体,其内部环境调控对作物生长和产量具有决定性影响。其中,温度是关键的环境因子之一,其动态变化受多种复杂环境因素耦合作用,表现出显著的非线性与时滞性^[1-2]。实现温室温度的精准预测,是优化温室环境控制策略、提高能源利用效率、降低生产成本的关键技术。

然而,现有研究多侧重于全天候或昼间温室温度预测。夜间温室的热环境机制与日间显著不同,夜间温室缺乏太阳辐射输入,主要依赖于围护结构的保温性能、保温被的启闭状态及内部热储能的释放。特殊条件下,尤其是保温被闭合后自然对流增强导致温度场空间异质性与热分层效应更显著^[3-4]。因此,准确预测夜间温室温度对于降低作物呼吸消耗、预防低温冻害、优化夜间加温策略具有重要的实践价值^[5-6]。

针对夜间温室温度场的高空间异质性,传统的基于空间均匀性假设的单点传感器监测方法已难以准确表征温室整体温度状态。尽管等距布设^[7-8]或拓扑优化^[9-10]等高密度传感器布设方案可以实现精细化监测,但数百个传感器的硬件成本、布线复杂性和维护难度严重限制了其在实际生产中的应用。现有传感器优化布设方法^[11-12]往往采用静态模式,较少同时考虑传感器信息熵与空间代表性的平衡,难以完全适应温室夜间复杂动态环境的需求。这突显了在保证获取关键温度信息的前提下,寻求一种成本可控、数据具代表性的监测方案的必要性。

除夜间温度观测存在监测难点外,构建高精度夜间温度预测模型本身也存在诸多技术难题。现有数据驱动模型和机理驱动模型虽然在温室环境预测中取得进展,但在夜间场景下精度往往有所衰减^[13-14]。机理驱动模型对参数敏感性高且实时计算效率受限,难以满足实际应用需求^[15];数据驱动模型输入参数通常缺乏前瞻性信息(如未来天气预报等),且未能充分纳入保温被启闭状态等对夜间温度影响至关重要的调控参量^[16-19]。循环神经网络(RNN)及其变体长短期记忆网络(LSTM)^[20]因

其处理时序数据的能力被广泛应用^[21],但传统单向结构难以充分利用序列的后向信息。自注意力机制的 Transformer 模型^[22-23]在序列建模方面展现出强大潜力,为解决温室温度预测中的复杂依赖关系提供了新思路。

因此,设计一种既能有效降低监测成本,又能准确预测夜间温度,并能充分利用前瞻性信息的智能方法,对于提升日光温室管理水平具有重要意义。基于上述分析,本文旨在解决日光温室夜间温度监测成本与精度矛盾以及预测模型精度受限的问题。主要构建基于粒子群优化 BP 神经网络的数据集成框架,在此基础上,应用熵权法对各传感器的多个数据质量指标进行综合评估,并结合温室空间区域划分和代表性原则,筛选出最优的少量传感器组合,降低监测成本的同时提供可靠的温室整体温度序列;提出一种引入天气预报作为关键输入特征的 Transformer – BiLSTM 混合预测模型,以提升夜间温室温度预测精度。

1 材料与方法

1.1 试验概况与数据采集

1.1.1 试验温室

试验基地位于乌鲁木齐市,选用典型无后坡结构日光温室,东西轴向,坐北朝南,长 44 m、跨度 8 m、脊高 2.6 m。围护结构采用砖混墙与轻钢屋面,外覆 PO 薄膜(透光率不小于 92%),夜间覆盖保温被。顶部设有自动通风装置(温度高于 30℃ 时启动)。栽培区种植番茄品种为普罗旺斯,采用单行定植模式(株距 0.35 m,行距 0.8 m),种植密度 3.2 株/m²。温室结构及实景详见图 1。




图 1 温室结构及实景

Fig. 1 Greenhouse structure and actual scene

1.1.2 数据采集平台

本研究部署了一套多节点环境监测系统(图 2),实现了温室内外环境参数的实时采集。系统主要包括室外气象站、室内气象站以及数据集成模块。室外气象站采集室外温度、相对湿度、光照强度、风速和风向等参数。室内气象站分布于栽培区内部,监测室内温度、相对湿度、光照强度、土壤温湿度和二氧化碳浓度等参数。所有传感器数据通过 RS-485 总线传输至中央服务器进行集成。核心监测设备包括武汉新惠普科技公司生产的 PH 自动气象站、江苏精创公司生产的空气温湿度测量仪、浙江托普云农公司生产的温室环境监测仪器,详细技术参数见表 1。此外,为获取未来气象数据,基于 Matlab 编写网络爬虫程序,间隔 1 h 自动获取试验点的天气预

报信息,包括天气状况、温湿度及风速变化。




图 2 温室环境信息自动监测系统

Fig. 2 Automatic monitoring system for greenhouse environmental information

表 1 传感器技术参数
Tab. 1 Sensor specifications

设备	设备型号	传感器名称	测量范围	精度
PH 自动气象站	PH-CJ1 百叶箱型	温湿度传感器	温度: -50 ~ 100℃ 相对湿度: 0 ~ 100%	温度: 0.1℃ 相对湿度: 0.1%
		PHWS 风速传感器	0 ~ 45 m/s	0.1 m/s
		PHWDZ 风向传感器	0 ~ 360°	1°
		二氧化碳传感器	0 ~ 5 000 μL/L	± 50 μL/L
		土壤温湿度传感器	温度: -40 ~ 80℃	温度: ± 0.2℃
			湿度: 0 ~ 100% (m ³ /m ³)	湿度: 0.1% (m ³ /m ³)
温室环境检测仪	BNL-GPRS-10G	太阳总辐射传感器	0 ~ 2 000 W/m ²	± 1%
		光照强度传感器	0 ~ 200 000 lx	± 1%
精创温湿度记录仪	GSP-6	温湿度传感器	温度: -40 ~ 85℃	温度: ± 0.3℃
			相对湿度: 10% ~ 99%	相对湿度: ± 3%

1.1.3 温室温度传感器布设与区域划分

为获取并分析温室夜间空间温度场以指导后续传感器布设优化,在温室内部署了 12 个精创 GSP-6 型数字温度传感器(测量精度 ± 0.3℃,采集间隔 10 min),按 4 列 × 3 行布设于作物冠层上方 1.5 m 处,所有传感器部署前均经统一校准,并通过 4G 无线网络实时回传数据。基于温室结构北墙砖混、南向 PO 薄膜及夜间环境特性,将监测范围划分为 3 个主要功能区域(图 3):前部薄膜影响区(A 区),紧邻 PO 薄膜,受外界环境影响最直接;中部作物核心区(B 区),作物主要生长区代表主体温度状态;后部北墙影响区(C 区),靠近北侧蓄热墙体。为后续评估和选择具有空间代表性的传感器优化组合提供了关键的理论约束和评价依据。




图 3 温室温度传感器布设俯视图

Fig. 3 Top view of greenhouse temperature sensor deployment

础。为确保数据质量,使用标准差法处理异常数据,并采用线性插值法有效补全缺失数据。为消除多模态传感器数据的异质性影响,所有数据均进行归一化处理,使其取值范围在[0,1]之间,计算式为

$$Y^* = \frac{Y - Y_{\min}}{Y_{\max} - Y_{\min}}$$

(1)

式中 Y——原始数据
Y_{min}、Y_{max}——原始数据最小值和最大值
Y*——归一化后数据

1.2 数据处理与特征工程

1.2.1 夜间数据筛选与预处理

为保证后续分析与建模的准确性,对原始数据进行了筛选与预处理。筛选出每日 18:00—次日 07:00 时段的夜间数据作为后续分析的基

1.2.2 关键输入特征的选择

为了构建适用于夜间温室温度预测的高效模型，基于 Pearson 相关系数对各环境因子与夜间室内空气温度之间的相关性进行了分析(图 4)，以筛选关键输入特征。Pearson 相关系数的值越接近 1,表明线性相关性越强。分析结果显示,夜间室内空气相对湿度、室外空气温度、室外空气相对湿度、室外风速以及保温被关闭时长(二元特征:关闭为 1,开启为 0)与夜间

室内空气温度具有强相关性。同时,考虑到本研究定义的固定夜间时段(18:00—07:00)在不同季节其起始点实际光照条件存在差异,为使模型能准确捕捉此过渡阶段的温度变化,室内外光照强度亦被纳入关键输入特征。综合上述考量,并兼顾模型复杂度和计算效率,选择了这些具有显著相关性及重要物理意义的因子作为预测模型的基础输入特征集的一部分,而忽略其他相关性较低的因子。




图 4 室内温度与环境因子之间的相关系数

Fig. 4 Correlation coefficient between room temperature and environment factors

1.3 日光温室夜间温度传感器布设优化方法

1.3.1 温室夜间温度场空间异质性分析

为精准预测温室夜间整体温度,需准确感知其复杂的热环境。图 5 展示了部分夜间周期内 12 个传感器的温度变化,直观地揭示了温室内部温度场存在显著且复杂的时空异质性。在夜间降温初期,各传感器测值波动剧烈且相互交错,反映了热环境的动态不稳定性。随着环境趋于稳定,温度曲线表现出明显的空间分层现象:后部北墙 C 区因墙体蓄热而处于高温区;前部薄膜 A 区因薄膜散热而稳定在低温区;中部 B 区则表现为过渡状态。值得注意的是,位于 C 区的 S4 传感器在降温初期表现出远超其他传感器的高频振荡,这表明仅依靠宏观区域划分,难以表征这类剧烈的局部微环境扰动。

综上所述,温室夜间温度场的复杂动态及独特的局部微环境,证明了任何单一传感器的读数均难以全面代表温室的整体温度状态。简单依赖直觉或常规物理认知选择少数测点存在固有风险。因此,本研究的核心任务在于,针对温室内部复杂的温度异质性,

构建一种有效的数据集成与传感器优化筛选方法,以期在显著降低监测成本的同时,获取高保真度的温室整体温度信息,为精准预测模型提供可靠输入。




图 5 传感器 S1 ~ S12 夜间温度变化曲线

Fig. 5 S1 ~ S12 nighttime temperature variation curves

1.3.2 基于粒子群优化 BP 神经网络的多温度传感器数据集成与参考序列生成

针对温室夜间温度场存在的空间异质性,且传感器在实际数据采集过程中仍可能存在残余随机误差或受局部瞬时波动影响,本研究构建了粒子群优

化(PSO)的BP神经网络多点温度数据集成框架(图6)。此框架的核心目标并非生成一个能完美复现所有空间细节的温室整体温度估计值,而是旨在从12个传感器的测量值中学习并提取出一个能够代表温室整体温度变化的参考序列。




图6 用于生成参考温度序列的 PSO-BP 数据集成框架

Fig.6 PSO-BP data integration framework for generating reference temperature series

为实现这一目标,选择12个传感器测量值的算术平均值作为BP神经网络的初始训练目标。采用算术平均值作为目标,主要考虑其能够初步平滑掉个体传感器数据中可能存在的、与整体趋势无关的高频噪声或极端瞬时波动,从而为神经网络提供一个相对稳定且易于学习的初始映射基准。尽管算术平均值本身可能无法完全捕捉温室复杂的空间温度分布细节,但BP网络通过学习从12个独立传感器输入到该平滑平均值之间的复杂非线性映射关系,能够进一步提炼和整合信息。

该框架的核心是BP神经网络,其输入层包含12个神经元,分别对应12个均匀分布的温度传感器(S1~S12)的测量值。BP神经网络包含2个隐藏层,分别有25、15个神经元,激活函数均为ReLU。输出层包含1个神经元,输出融合后的温室整体温度估计值,采用线性激活函数。模型的训练目标是最小化BP网络输出与12个传感器测量值算术平均值之间的均方误差(MSE)。粒子群优化(PSO)算法用于优化BP网络的权值和偏置,具体参数设置为:粒子群规模为30,最大迭代次数为100,学习因子c1和c2均为2,惯性权重线性递减,从0.9减小到0.4。通过学习这种映射关系,网络能够整合不同传感器的数据,抑制个体传感器的瞬时波动,从而生成更具代表性的温室整体温度参考序列,用于后续的传感器评估和预测模型训练。

1.3.3 基于熵权法的传感器数据质量初步评估

为了客观、综合评价各传感器的性能并筛选出

最具代表性的传感器用于后续预测模型,基于PSO-BP数据集成结果,提取了反映传感器数据质量与代表性的3个关键性能指标:PSO-BP数据集成过程中学习到的该传感器输入特征的权重,该传感器测量值相对于融合值的平均绝对误差(MAE),最优数据占比。最优数据占比定义为该传感器测量值与PSO-BP融合值之间的绝对误差小于预设阈值(考虑到温度控制中常用的温度精度,本研究设为0.5℃)的时间样本占总时间样本的比例。

采用熵权法对这3个指标进行赋权并计算了各传感器的综合评分。熵权法根据指标数据的离散程度确定权重,离散程度越大,信息熵越小,表明指标包含的信息越多,权重应越高。具体实施步骤如下:

(1)数据标准化处理。对原始指标数据进行标准化处理,消除不同指标量纲和取值范围的影响。对于所有传感器值都相同的指标,标准化后该列值设为极小值0.0001,以确保模型仍能利用该指标。

(2)计算指标信息熵。根据标准化后的数据,计算各指标下每个传感器的比重,进而计算第j个指标的信息熵 e_j 。信息熵值越小,指标包含的信息量越大。其计算式为

$$e_j = -k \sum_{i=1}^n y_{ij} \ln y_{ij} \tag{2}$$

式中 e_j ——第j项评价指标的信息熵

k ——常数,取 $\frac{1}{\ln n}$

n ——传感器样本总数量

y_{ij} ——经标准化处理后,第i个传感器在第j项指标下的指标比重

(3)计算指标权重。根据信息熵计算各指标的差异系数 d_j 和熵权 w_j ,即

$$d_j = 1 - e_j \tag{3}$$

$$w_j = \frac{d_j}{\sum_{j=1}^3 d_j} \tag{4}$$

式中 d_j ——第j项指标的差异系数

w_j ——第j项指标的熵权

(4)计算传感器综合评分。根据计算出的指标权重 w_j 和标准化后的指标值,计算第i个传感器的综合评分 s_i ,其计算式为

$$s_i = \sum_{j=1}^3 w_j p_{ij} \tag{5}$$

式中 p_{ij} ——第i个传感器在第j项指标下的标准化指标值

传感器的综合评分 s_i 值越高,表明该传感器性能越好,数据质量和代表性越高。该数据质量评分是后续结合空间代表性进行传感器组合筛选的重要考量。

1.3.4 融合空间代表性的传感器优化组合确定

为获得一个既能有效降低监测成本,又能全面、准确地捕捉温室夜间复杂温度场关键信息的传感器优化组合,根据熵权法计算出的综合得分,对 12 个传感器进行排序,筛选出排名靠前的候选传感器,同时寻求一个能够覆盖全部 3 个关键物理区域(A、B、C 区)的最优组合。其所选定传感器的原始、未经任何融合处理的夜间温度测量数据,将直接作为后续 Transformer - BiLSTM 预测模型的核心输入特征之一。

1.4 基于天气预报的 Transformer - BiLSTM 夜间温度预测模型

本研究针对日光温室夜间温度预测的难点,提

出一种融合双向长短期记忆网络(BiLSTM)和 Transformer 模型,并引入天气预报信息的混合深度学习模型。该模型旨在结合 BiLSTM 在处理时间序列局部依赖上的优势与 Transformer 在捕捉全局关联和长距离依赖上的能力,并通过集成前瞻性的天气预报数据,提高复杂环境条件下夜间温室温度的预测精度和鲁棒性。模型最终输出夜间未来 10 min 预测步长的温室空气温度预测值(模型训练的温度标签基于 PSO - BP 融合值)。

1.4.1 模型架构与输入特征

本文构建的 Transformer - BiLSTM 混合模型采用如图 7 所示的串联架构。具体过程如下:

(1) 设输入时间序列长度为 L , 表示为 $X =$




图 7 Transformer - BiLSTM 模型结构图

Fig. 7 Transformer - BiLSTM model structure diagrams

$\{\mathbf{x}_t\}_{t=1}^L$, 其中 $\mathbf{x}_t$ 是时间步 t 的特征向量。

(2) 输入序列 X 首先送入 BiLSTM 层。BiLSTM 从输入序列中提取局部时序特征,捕捉数据的双向依赖性,输出序列化的隐藏状态表示为 $H_{\text{BiLSTM}} = \{h_t\}_{t=1}^L$, h_t 表示 BiLSTM 局部隐藏状态。

(3) BiLSTM 的输出序列 H_{BiLSTM} 作为输入送入 Transformer Encoder。Transformer Encoder 利用其全局自注意力机制,对 H_{BiLSTM} 进行深层特征提取和全局关联建模,输出增强的特征序列 $H_{\text{Transformer}} = \{h'_t\}_{t=1}^L$ 这一阶段增强了模型对序列中长期依赖的建模能力, h'_t 表示为 Transformer 编码器基于全局自注意力机制优化后的增强时序表征。

(4) Transformer Encoder 的输出序列 $H_{\text{Transformer}}$ 通过一个线性层映射到最终的预测值。取最后一个时间步 L 的输出向量 $\mathbf{h}'_L$, 通过线性变换得到未来 10 min 的预测温度 $\hat{y}_{t+10}$ 。

模型的输入特征集包含来自传感器布设优化的实时温度测量数据,以及室内外其他环境监测数据、保温被状态和天气预报数据。天气预报数据通过网络爬虫从中国天气网获取,包含试验地点的未来天气状况、未来气温、未来相对湿度和未来风速。考虑到模型预测步长为 10 min,而天气预报通常是逐小时提供的,本文采用复用策略:对于任意一个 10 min 的时间点,其对应的天气预报数据取自该时间点所属小时的整点天气预报。例如,预测 18:10 的温度时,使用的天气预报数据是 18:00 的预报值。对于天气状况(晴、阴、雨、雪、多云等),采用独热编码将其转换为数值型向量作为模型输入,每个类别对应一个维度,该维度值为 1,其余为 0。其他天气预报特征(气温、相对湿度、风速)直接使用数值进行归一化后输入模型。模型输入特征序列见表 2。

表 2 模型输入特征示例

Tab.2 Example of model input features

时刻	室内相对湿度/%	室外温度/℃	室内光照强度/lx	室外相对湿度/%	室外光照强度/lx	室外风速/(m·s ⁻¹)	保温被状态(0/1)	预报天气状况(晴、阴、雨、雪、多云)	预报气温/℃	预报相对湿度/%	预报风速/(m·s ⁻¹)
19:10	85.2	-5.1	0	70.1	0	1.2	1	0,1,0,0,0	-6	75	1.5
19:20	86.0	-5.5	0	70.1	0	1.2	1	0,1,0,0,0	-6	75	1.5

1.4.2 BiLSTM 特征提取模块

双向长短期记忆网络(BiLSTM)通过叠加前向、后向 LSTM 层(图 7c)捕获时间序列的动态特性。前向层处理正向时间依赖,后向层提取逆向时序特征,双通道输出经权重矩阵融合后,得到 BiLSTM 在时间步 t 的输出表示 y_t ,即

$$y_t = \text{ReLU}(\mathbf{W}_y[\vec{h}_t \oplus \overleftarrow{h}_t] + \mathbf{b}_y) \tag{6}$$

$$\vec{h}_t = \text{LSTM}(\mathbf{W}_f[\mathbf{x}_t \oplus \vec{h}_{t-1}] + \mathbf{b}_f) \tag{7}$$

$$\overleftarrow{h}_t = \text{LSTM}(\mathbf{W}_b[\mathbf{x}_t \oplus \overleftarrow{h}_{t+1}] + \mathbf{b}_b) \tag{8}$$

式中 y_t ——通过拼接前向隐藏状态 $\vec{h}_t$ 和后向隐藏状态 $\overleftarrow{h}_t$ 而形成的输出

$\mathbf{W}_f$ ——前向 LSTM 层到输出层的权重矩阵

$\mathbf{W}_b$ ——后向 LSTM 层到输出层的权重矩阵

$\mathbf{b}_f, \mathbf{b}_b, \mathbf{b}_y$ ——门控偏置矩阵

$\mathbf{W}_y$ ——用于对拼接后的前、后向隐藏状态进行线性变换的权重矩阵

1.4.3 Transformer

Transformer 模型采用编码器-解码器架构。本研究中,主要使用了 Transformer 的编码器(Encoder)部分来处理 BiLSTM 输出的序列特征。Transformer Encoder 由多个相同的层堆叠而成,每一层主要包含 2 个子层:1 个多头自注意力(Multi-head self-Attention)机制(图 7b)和 1 个前馈神经网络。每个子层都采用了残差连接和层归一化。

2 结果与分析

2.1 传感器优化结果与分析

2.1.1 PSO-BP 多温度传感器数据集成结果

为了验证基于 PSO-BP 的多传感器数据集成模型的有效性,使用 2024 年 6—12 月期间采集的温室内 12 个传感器的实际温度数据进行试验(共 30 816 组数据点,间隔 10 min)。图 8 展示了部分时段内 PSO-BP 融合值与 12 个传感器算术平均值的对比曲线。结果表明,多数时间点上 PSO-BP 融合值与算术平均值高度吻合,说明模型有效学习了传感器数据的整合。然而,在某些时段(图 8 中时序步长 5~20),算术平均值因个别传感器读数的快速变化或瞬时异常而出现明显波动,而 PSO-BP 融合值曲线则表现得更为稳定,有效抑制了这些瞬时扰动。这初

步验证了 PSO-BP 融合方法能生成一个比简单算术平均值更鲁棒、可靠的温室整体温度参考序列。




图 8 PSO-BP 融合值与简单算术平均值对比

Fig.8 Comparison of PSO-BP fusion values and simple mean values

2.1.2 基于综合评价与空间代表性的传感器部署方案确定

为在保证监测数据质量与空间代表性的前提下,筛选出经济高效的传感器布设优化方案,依据提出的传感器组合筛选策略,综合考量各传感器的数据质量与空间代表性,对 12 个传感器组合进行了分析与筛选。为在监测成本与信息获取完整性之间寻求更优的平衡,本研究重点考察了四传感器组合的优化布设。优先覆盖 A、B 和 C 3 个区域,各区域内选择数据质量较高者,并兼顾空间分布均衡与信息互补的原则。

根据表 3 熵权法评估结果,首先纳入数据质量综合评分最高的 S3(前部薄膜影响区)和 S8(中部核心区)。为确保对后部北墙影响区的有效监测,选择了该区域内数据质量评分最高的传感器 S1。同时为增强对高敏感区域的监测,增加了第 4 个传感器 S12,将 S12 与 S3 共同布设于 A 区,能够更全面地捕捉该区域的温度动态和潜在的横向不均匀性。选择更多传感器可能会引入冗余信息,增加成本和复杂度,而对整体温度场的代表性贡献较小,且 S8、S3、S1、S12 的最优数据占比总计达 67.78%,同时确保了对温室所有关键物理区域的有效监控。最终,确认 S1、S3、S8 和 S12 组成的 4 个传感器优化布设方案(图 9)。

2.2 夜间温度预测模型性能分析

2.2.1 模型参数设置与训练说明

数据集来自乌鲁木齐市新疆农业大学三坪温室

表 3 S1 ~ S12 传感器在 3 个指标上的评估结果

Tab.3 Evaluation results of S1 ~ S12 sensors on three indicators

传感器 编号	传感器权重	平均绝对 误差/℃	最优数据 占比/%	综合评分
S1	0.079 9	0.609 6	5.72	0.479 9
S2	0.118 9	0.910 3	6.42	0.673 8
S3	0.094 9	0.443 8	23.89	0.788 2
S4	0.063 7	1.273 3	1.39	0.047 4
S5	0.076 7	0.741 8	7.12	0.430 8
S6	0.089 6	1.377 2	2.95	0.186 0
S7	0.088 2	1.289 7	2.87	0.159 8
S8	0.079 1	0.319 0	29.58	0.885 9
S9	0.077 6	1.158 0	3.30	0.205 2
S10	0.078 2	0.634 8	5.21	0.430 4
S11	0.067 9	0.677 6	4.25	0.385 7
S12	0.085 3	0.898 7	8.32	0.637 4




图 9 优化后的传感器布设方案

Fig. 9 Optimized sensor placement scheme

基地,涵盖 2024 年 6 月 1 日至 12 月 31 日期间采集的数据。其中,2024 年 6 月 1 日至 10 月 25 日的数
据(共 21 312 组)用于模型训练,2024 年 10 月 25 日
至 12 月 31 日的数据(共 9 504 组数据点)用于模型
测试,训练集与测试集比例约为 7:3。

模型的关键超参数是基于验证集性能,通过反
复进行经验性试验和调整来确定的。模型架构首先
采用 BiLSTM 层处理输入序列的特征和时序依赖
性,BiLSTM 层包含 128 个隐藏单元。BiLSTM 层的
输出序列作为 Transformer Encoder 的输入。
Transformer Encoder 由 2 个相同的编码层堆叠而成,
每个编码层包含 1 个多头自注意力机制和 1 个前馈
神经网络。多头自注意力机制设置 7 个注意力头,
每个头的维度为 128。前馈神经网络的隐藏层维度
设置为 512。Transformer Encoder 的输入输出维度
与 BiLSTM 层的输出维度一致为 128。最后进入
Transformer 模块对 BiLSTM 网络输出的特征进行全
局建模。模型的训练采用 Adam 优化器,初始学习
率设置为 0.001。训练过程共 300 批次,每个批次
处理大小设置为 64。

2.2.2 不同传感器布设方案预测模型性能验证

为验证传感器布设优化策略的有效性 with 成本效
益,对比了 4 种传感器输入方案下 Transformer –

BiLSTM 模型的温室夜间温度预测性能,各方案超参
数及其他非传感器输入特征均保持一致。方案分别
为:方案 1(全部 12 个传感器)、方案 2(评分筛选覆
盖 A、B 和 C 3 个区域的 S1、S3、S8、S12、S2 和 S5 共
6 个传感器)、方案 3(S1、S3、S8 和 S12 共 4 个传感
器)、方案 4(熵权法评分最高的 S3、S8 双传感器)。
图 10 展示了 4 种方案下模型预测曲线与实际值(基
于 PSO – BP 融合值)的部分对比。从图中可以看
出,4 种布设方案下的模型均能基本跟踪温室夜间
实际温度的变化趋势。其中,方案 1 的预测曲线与
实际值吻合度最高,表现出最佳的细节捕捉能力。
方案 2 的预测效果也较为理想,仅次于方案 1。方
案 3 的预测曲线与方案 1 高度接近,尤其在温度峰
谷值和变化拐点处均能实现较好跟随。方案 4 由于
传感器数量最少,在部分变化复杂的时段,其预测曲
线与实际值的偏差相对较大。




图 10 4 种方案下模型预测曲线与实际值(基于
PSO – BP 融合值)的部分对比

Fig. 10 Partial comparison of model predicted curves
and PSO – BP fusion measured values for four schemes

表 4 数据显示,方案 3 在预测精度与成本效益
间实现了较好平衡。其 R^2 达 0.98,与方案 1 和方
案 2 均持平。相较于方案 1,方案 3 在传感器数量
减少 2/3 的情况下,其平均绝对误差 MAE 和均方根
误差 RMSE 仅较方案 1 分别增加 0.05℃ 和 0.04℃。
而与方案 2 相比,方案 3 进一步将传感器数量从 6
个减少至 4 个,其 MAE 和 RMSE 也仅分别从
0.31℃ 微增至 0.33℃、从 0.38℃ 微增至 0.39℃,以
更少的传感器实现了较好的预测性能,突显了其在
成本效益上的显著优势。此种优化布设的有效性,
在对比仅采用 2 个传感器的方案 4 时表现得更为显

表 4 不同布设方案的预测性能对比

Tab.4 Prediction performance comparison under
different sensor deployment schemes

方案编号	传感器布设方案	R^2	MAE/℃	RMSE/℃
方案 1	12 个传感器	0.98	0.28	0.35
方案 2	S1, S3, S8, S12, S2, S5	0.98	0.31	0.38
方案 3	S1, S3, S8, S12	0.98	0.33	0.39
方案 4	S3, S8	0.97	0.40	0.49

著,后者误差明显增大。这充分验证了本研究结合数据质量评估与空间代表性原则进行传感器布设优化策略的有效性,并在保证高性能与降低成本间取得了卓越平衡。因此,后续模型研究均基于方案3传感器原始数据进行。

2.2.3 不同预测模型性能对比

为了验证本文提出的基于天气预报 Transformer-BiLSTM 模型的性能,将其与 3 种基线模型(不含天气预报输入的 Transformer-BiLSTM 模型、Transformer 模型和 BiLSTM 模型)在同一测试集上进行了对比,所有对比模型使用相同的输入特征集。图 11 展示了各模型在测试集上的部分预测曲线,




图 11 不同算法部分测试集预测曲线

Fig. 11 Prediction curves for different algorithms for partial test sets

图 12 给出了各模型散点拟合图和残差分析。




图 12 各模型散点图和残差分析

Fig. 12 Scatter plots and residual analysis of each model

图 11 表明,各模型都能够基本捕捉到温度的整体变化趋势,但细节表现差异显著。本文模型与实际值的吻合度最高,在温度剧烈波动和极值出现时,均优于其他基线模型。后者在捕捉快速变化和极端值方面表现稍逊,存在明显的滞后、提前或幅度上的偏差。

图 12 通过散点图和残差分析进一步量化了各模型的预测性能。本文模型散点图中的点密集地分布在理想的 $y=x$ 对角线附近,线性拟合最优。其决定系数 R^2 高达 0.99,均方根误差 RMSE 为 0.43℃,平均绝对误差 MAE 为 0.30℃,其预测精度显著优于所有基线模型。相较于未引入天气预报信息的 Transformer-BiLSTM 模型,其 R^2 为 0.94, RMSE 为

0.92℃,MAE 为 0.74℃,本文模型的 RMSE 和 MAE 分别显著降低, R^2 亦有提升。这有力证明了天气预报信息的引入对预测精度有显著提升。同时,本文模型的残差分布更集中且波动更小,表明其预测稳定性更优。

2.2.4 不同天气条件下模型泛化能力分析

为了全面评估所提出模型在不同环境下的泛化能力和鲁棒性,验证了模型在阴天、雨天、雪天、晴天和多云 5 种典型天气下的预测性能。图 13 展示了各类天气下的预测曲线与实际值的对比,表 5 汇总了相应的 R^2 、MAE 和 RMSE 指标。结果表明,该模型在不同气象条件下均表现出良好的鲁棒性和预测精度。在温度变化相对平缓的阴天和雨天,模型性




图 13 不同天气情况模型验证

Fig. 13 Validation of models for different weather conditions

表 5 模型在不同天气下的指标

Tab. 5 Indicators of model under different weather				
天气类型	R^2	MAE/℃	RMSE/℃	日期
阴天	0.97	0.29	0.39	2024/10/27
阴天	0.98	0.24	0.31	2024/12/18
雨天	0.97	0.28	0.38	2024/11/13
雨天	0.97	0.33	0.47	2024/11/17
多云	0.96	0.40	0.63	2024/11/12
多云	0.95	0.50	0.78	2024/12/09
雪天	0.96	0.36	0.61	2023/12/07
雪天	0.97	0.28	0.41	2024/12/12
晴天	0.95	0.39	0.57	2024/10/28
晴天	0.96	0.32	0.51	2024/12/21

能最优, $R^2\geqslant0.97$,且误差指标最低。在晴天和雪天条件下,模型仍保持可靠的精度, $R^2\geqslant0.96$ 。尽管多云天气下预测误差略有增加,模型仍能有效跟踪实

际温度趋势。图 13 表明,在阴天和雨天,模型的预测曲线与实际温度曲线几乎完美贴合。在雪天和晴天,模型也能较好地捕捉温度的主要变化趋势和转折点。即便是在预测难度相对较大的多云天气,模型预测曲线依然能够基本跟踪实际温度的波动,未出现严重的偏离。

对模型在不同天气条件下表现差异的分析表明,预测精度与各天气类型下温度变化特性密切相关。阴天和雨天时,持续的云层有效缓冲了夜间辐射降温,使得温度变化平缓,模型更容易捕捉。多云天气由于云层高度不确定且变化快,导致温度波动更为复杂,对模型而言是最大的挑战。总体而言,本文模型具备在多种天气环境下提供高精度温度预测的能力,具有较高的实际应用价值。同时,在应对极度复杂和不确定性高的气象条件时,模型仍存在进

一步优化的空间。

2.2.5 模型计算效率分析

在农业设施智能控制中,预测模型的计算效率和实时性至关重要。结合硬件配置试验与对比研究系统分析了引入天气预报 Transformer - BiLSTM 模型的计算效能。本文模型的训练耗时与数据集规模、模型复杂度及计算资源密切相关。基于 2024 年秋冬季节温室数据集,模型在不同硬件平台进行了测试:在 Intel Core i7 - 8845H CPU 平台上,模型训练耗时 7.3 h (26 280 s), 单次预测响应时间为 0.86 s; 配备 Intel Core i9 - 13900H CPU 和 NVIDIA GeForce RTX 4080 GPU 的平台,训练时间显著缩短至 3.9 h (14 040 s), 预测响应时间降至 0.078 s。试验数据表明,高性能计算设备可缩短 46.7% 的训练耗时,同时其预测延迟也完全满足温室环境实时调控的需求。尽管本文模型在高性能硬件表现优异,但在农业技术基础设施薄弱的小规模生产场景中,可能无法获得同等水平的硬件支持。可以考虑模型简化:通过减少 BiLSTM 模型的层数、神经元数量,降低模型复杂度,从而减少计算量。

3 讨论

本研究旨在解决日光温室夜间温度预测面临的高成本监测、复杂空间异质性以及传统模型精度受限等问题。为此,构建了一套结合传感器布设优化与基于天气预报的 Transformer - BiLSTM 混合预测方案。在传感器布设优化方面,采用了一种“数据-物理”结合的优化方法。首先,利用 PSO - BP 模型生成代表温室整体热环境的参考温度序列,为评价各传感器代表性提供统一基准。在此基础上,通过熵权法评价传感器的数据质量及其在温室前、中、后区域的空间分布代表性,筛选出最优传感器组合 (S1、S3、S8、S12)。该优化方案不仅降低了硬件和维护成本,更重要的是,其预测精度与采用更多传感器的方案相比几乎没有损失,优于仅凭数据质量筛选的双传感器方案。这证明了所提策略在平衡监测成本、信息保真度与预测性能方面的优越性,为资源受限条件下的精准农业监测提供了实用方法。

在夜间温度预测模型构建上,传统依赖历史数据的模型难以准确预测天气突变引起的温度波动。考虑到夜间温度对外部气象条件的强依赖性,创新性地 将未来天气预报数据融入 Transformer - BiLSTM 预测模型。该模型中,BiLSTM 负责捕捉温

度数据自身的时间序列特征,Transformer 则能有效关联温室历史状态与未来天气预报。结果表明,引入天气预报后,模型预测 R^2 达到 0.98,在多种天气条件下均保持良好预测效果,证明了外部前瞻性信息对提高长时间尺度预测精度的重要性。

然而,本研究在实际应用和推广方面仍面临若干困难。首先,温度预测模型的普适性有待进一步验证,因其主要基于乌鲁木齐特定结构温室的数据;在不同温室结构、气候区域或作物环境下其表现尚需考察。其次,传感器布设优化方法本身亦有深化空间:当前采用算术平均值生成参考序列的方法,在面对高度复杂的空间异质性时,其代表性或有提升余地;同时,传感器数量的最优性判定目前依赖经验和关键区域覆盖,未来可探索更形式化的多目标协同优化决策模型。再者,本研究的优化主要针对温度参数,构建能够协同优化温度、相对湿度等多环境因子监测点布设的体系,将是未来提升的关键方向。最后,模型性能在一定程度上依赖外部天气预报数据的可用性与稳定性。本文采用的逐小时更新预报数据,虽通过 10 min 步长复用缓解了频率不匹配问题,但在捕捉短时天气波动方面仍存局限,未来引入更高分辨率的气象数据或时间插值方法有望改善此问题。

4 结论

(1) 针对日光温室夜间温度预测中的核心挑战,提出了一种整合传感器布设优化与基于天气预报的 Transformer - BiLSTM 混合模型的技术方法。

(2) 通过构建 PSO - BP 多传感器数据集成框架并结合熵权法进行数据质量评估与温室物理空间分区代表性原则,成功将温室温度监测点从 12 个优化至 4 个,在保证了对温室关键区域温度信息的全面捕捉的同时,显著降低了硬件部署成本与系统复杂度。

(3) 构建的引入天气预报的 Transformer - BiLSTM 混合预测模型,有效融合了序列局部与全局特征捕捉能力,并通过利用前瞻性天气信息,实现了夜间温室温度的高精度预测,并在不同天气条件下展现出良好的鲁棒性。

(4) 本研究提出的方法为日光温室夜间温度的精准监测和预测提供了有效手段,对于发展基于预测的智能环境控制策略、提升能源利用效率和作物生产管理水平具有重要的应用价值。

参 考 文 献

[1] 胡瑾, 雷文晔, 卢有琦, 等. 基于 1D CNN - GRU 的日光温室温度预测模型研究[J]. 农业机械学报, 2023, 54(8): 339 - 346.

Hu Jin, Lei Wenye, Lu Youqi, et al. Solar greenhouse temperature prediction model based on 1D CNN-GRU[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 339-346. (in Chinese)

[2] 陈瑾萱, 杜震宇. 基于裸土地面的日光温室室内温湿度预测模型构建[J]. 太阳能学报, 2024, 45(8): 414-422. DOI: 10.19912/j.0254-0096.tynxb.2023-0575.

Chen Jinxuan, Du Zhenyu. Construction of indoor temperature and humidity prediction model for solar greenhouse based on bare ground surface[J]. Journal of Solar Energy, 2024, 45(8): 414-422. (in Chinese)

[3] 张传坤, 马迎春, 付文敏, 等. 不同保温被对喀什地区日光温室夜间温度影响的量化分析[J]. 中国蔬菜, 2025(3): 98-103. DOI:10.19928/j.cnki.1000-6346.2025.5005.

Zhang Chuankun, Ma Yingchun, Fu Wenmin, et al. Quantitative analysis of the impact of different thermal insulation covers on nighttime temperatures in solar greenhouses in Kashgar region[J]. China Vegetables, 2025(3): 98-103. (in Chinese)

[4] 佟国红, 王淼, 吴红爽, 等. 日光温室附阴棚及保温对室内温度的影响[J]. 中国农业大学学报, 2024, 29(2): 99-109.

Tong Guohong, Wang Miao, Wu Hongshuang, et al. Impact of attached shading sheds and thermal insulation on indoor temperature in solar greenhouses[J]. Journal of China Agricultural University, 2024, 29(2): 99-109. (in Chinese)

[5] Li X, Zhang L, Wang X, et al. Forecasting greenhouse air and soil temperatures: a multi-step time series approach employing attention-based LSTM network[J]. Computers and Electronics in Agriculture, 2024, 217: 108602.

[6] Jiao W, Liu Q, Gao L J, et al. Computational fluid dynamics-based simulation of crop canopy temperature and humidity in double-film solar greenhouses[J]. Journal of Sensors, 2020, 2020: 8874468. DOI:10.1155/2020/8874468.

[7] Do Nascimento F A L, Da Silva A J P, De Freitas F T O, et al. Sensor placement in 2D/3D wetting patterns from drip irrigation for quantification of evapotranspiration[J]. Computers and Electronics in Agriculture, 2021, 188: 106356.

[8] 塔娜, 张驰, 朱英凯, 等. 温室内温度无线测试系统及温度场模拟[J]. 东北农业大学学报, 2014, 45(2): 111-115.

Ta Na, Zhang Chi, Zhu Yingkai, et al. Wireless temperature testing system and temperature field simulation in greenhouse[J]. Journal of Northeast Agricultural University, 2014, 45(2): 111-115. (in Chinese)

[9] Feng L, Li H, Zhi Y. Greenhouse CFD simulation for searching the sensors optimal placements[C]//Proceedings of the 2013 Second International Conference on Agro-Geoinformatics. Fairfax, USA, 2013: 504-507. DOI:10.1109/Argo-Geoinformatics.2013.6621972.

[10] Cheng X, Li D, Shao L, et al. A virtual sensor simulation system of a flower greenhouse coupled with a new temperature microclimate model using three-dimensional CFD[J]. Computers and Electronics in Agriculture, 2021, 181: 105934. DOI: 10.1016/j.compag.2020.105934.

[11] Yang S, Liu X, Liu S, et al. Real-time temperature distribution monitoring in Chinese solar greenhouse using virtual LAN[J]. Agronomy, 2022, 12(7): 1565. DOI:10.3390/agronomy12071565.

[12] 宋成宝, 刘平增, 刘兴华, 等. 基于 HSIC 的日光温室温度传感器优化配置策略[J]. 农业工程学报, 2022, 38(8): 200-208.

Song Chengbao, Liu Pingzeng, Liu Xinghua, et al. Optimization configuration strategy of temperature sensors in solar greenhouse based on HSIC[J]. Transactions of the CSAE, 2022, 38(8): 200-208. DOI:10.11975/j.issn.1002-6819.202201146. (in Chinese)

[13] 秦琳琳, 马姣, 黄昀梦, 等. 基于积温理论的温室温度混杂系统预测控制[J]. 农业机械学报, 2018, 49(10): 347-355.

Qin Linlin, Ma Jiao, Huang Yunmeng, et al. Predictive control of greenhouse temperature hybrid system based on accumulated temperature theory[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(10): 347-355. (in Chinese)

[14] Jia W, Wei Z. Short-term prediction model of environmental parameters in typical solar greenhouse based on deep learning neural network[J]. Applied Sciences, 2022, 12(24): 12529. DOI:10.3390/app122412529.

[15] 陈立军, 杜尚丰, 李加鹏, 等. 温室环境温度预测自适应机理模型参数在线识别方法[J]. 农业工程学报, 2017, 33(增刊1): 315-321.

Chen Lijun, Du Shangfeng, Li Jiapeng, et al. Online parameter identification method for adaptive mechanism model of greenhouse environmental temperature prediction[J]. Transactions of the CSAE, 2017, 33(S1): 315-321. (in Chinese)

[16] Jose D M, Vincent A M, Dwarakish G S. Improving multiple model ensemble predictions of daily precipitation and temperature through machine learning techniques[J]. Scientific Reports, 2022, 12(1): 4678. DOI:10.1038/s41598-022-10000-x.

[17] Cai W, Wei R, Xu L, et al. A method for modelling greenhouse temperature using gradient boost decision tree[J]. Information Processing in Agriculture, 2022, 9(3): 343-354. DOI:10.1016/j.inpa.2022.01.002.

[18] 陈鑫, 唐湘璐, 李想, 等. 二次聚类与神经网络结合的日光温室温度二步预测方法[J]. 农业机械学报, 2017, 48(增刊1): 353-358.

Chen Xin, Tang Xianglu, Li Xiang, et al. Two-step prediction method for solar greenhouse temperature based on secondary clustering combined with neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(S1): 353-358. (in Chinese)

[19]倪美玉,杜子涛,曹卫刚.基于优化小波神经网络的作物温室环境温度预测模型[J].中国农机化学报,2024,45(12):73-80. DOI:10.13733/j.jcam.issn.2095-5553.2024.12.012.
Ni Meiyu, Du Zitao, Cao Weigang. Crop greenhouse environmental temperature prediction model based on optimized wavelet neural network[J]. Journal of China Agricultural Mechanization, 2024, 45(12): 73-80. (in Chinese)

[20]Jung D H, Kim H S, Jhin C, et al. Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse[J]. Computers and Electronics in Agriculture, 2020, 173: 105402.

[21]张冠山,李天华,侯加林.考虑动态吸收率的玻璃温室覆盖层温度预测模型[J].农业工程学报,2020,36(5):201-211.
Zhang Guanshan, Li Tianhua, Hou Jialin. Temperature prediction model for glass greenhouse cladding considering dynamic absorptivity[J]. Transactions of the CSAE, 2020, 36(5): 201-211. (in Chinese)

[22]郝璇,任守纲,舒欣,等.基于 TimesTransformer 的农业设施环境预测与调控研究[J].南京农业大学学报,2026,49(3):653-664.
Hao Xuan, Ren Shougang, Shu Xin, et al. Research on environmental prediction and regulation of agricultural facilities based on TimesTransformer[J]. Journal of Nanjing Agricultural University, 2026,49(3):653-664. (in Chinese)

[23]Cai X, Liu T. State of health prediction for lithium-ion batteries using transformer-LSTM fusion model[J]. Applied Sciences, 2025, 15(7): 3747.



(上接第 374 页)

[26]于丰华,曹慧妮,金忠煜,等.基于 NSWOA-ELM 算法的水稻冠层氮素含量反演方法[J].农业机械学报,2025,56(7):532-540.
Yu Fenghua, Cao Huini, Jin Zhongyu, et al. Inversion method of nitrogen content in rice canopy based on NSWOA-ELM algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(7): 532-540. (in Chinese)

[27]Liu X, Ma T, Zhang H, et al. The accumulation of fungal not bacterial residue carbon is management-dependent under conventional and organic practices in apple-orchard soil[J]. Geoderma, 2024, 448: 116968.

[28]张鹏,翁建文,康晴,等.基于卷积神经网络的太阳光谱辐照度超分辨率重建方法[J].光子学报,2025,54(3):221-230.
Zhang Peng, Weng Jianwen, Kang Qing, et al. Super-resolution solar spectral irradiance reconstruction method based on convolutional neural network[J]. Acta Photonica Sinica, 2025, 54(3): 221-230. (in Chinese)

[29]Koch M, Schodlok M C, Guggenberger G, et al. Effects of water tension and surface roughness on soil hyperspectral reflectance [J]. Geoderma, 2021, 385: 114888.

[30]Wilson R H, Nadeau K P, Jaworski F B, et al. Review of short-wave infrared spectroscopy and imaging methods for biological tissue characterization[J]. Journal of Biomedical Optics, 2015, 20(3): 030901.

[31]Tsenkova R, Muncán J, Pollner B, et al. Essentials of aquaphotomics and its chemometrics approaches[J]. Frontiers in Chemistry, 2018, 6: 363.

[32]Bablet A, Vu P V H, Jacquemoud S, et al. MARMIT: a multilayer radiative transfer model of soil reflectance to estimate surface soil moisture content in the solar domain (400 ~ 2 500 nm) [J]. Remote Sensing of Environment, 2018, 217: 1-17.

[33]Ding A, Ma H, Zhao P, et al. Improved Hapke model to characterize soil moisture content variation[J]. Environmental Sciences Proceedings, 2024, 29(1): 76.