

基于PINN的温室黄瓜蒸腾量估算方法研究

付益辉¹ 周 静^{1,2} 邓 俊¹ 黄志刚² 王纪章^{1,2}

(1. 江苏大学农业工程学院, 镇江 212013; 2. 江苏省物联网智慧园艺设施工程技术研究中心, 常熟 215555)

摘要: 植物蒸腾量(ET_c)的准确估算对于温室精准灌溉和水管理至关重要。传统彭曼-蒙特斯方程(Penman-Monteith)虽已包含净辐射(R_n)、温度(T)、湿度(R_H)、风速等关键驱动因子,但在温室特殊环境下,方程结果存在误差,作物系数(K_c)难以确定;而纯数据驱动模型缺乏物理机制约束,泛化能力有限。为解决这一问题,本文提出一种基于物理信息神经网络(PINN)的温室黄瓜 ET_c 估算新方法。以改进的彭曼公式作为物理硬约束,构建包含物理机理分支和数据驱动修正分支的并行混合网络结构,通过物理一致性损失函数作为软约束同时优化数据拟合精度和物理一致性。在玻璃温室开展试验,采集净辐射、空气温度、相对湿度及蒸腾量实测数据。结果表明,与全连接神经网络(FCNN)基准模型相比,PINN模型决定系数 R^2 从0.784 7提升至0.837 7,均方根误差(RMSE)为0.459 6 mm/d,降低13.17%,平均绝对误差为0.192 3 mm/d,降低35.12%。研究结果表明,将物理先验知识融入神经网络,不仅提高了 ET_c 估算精度,也使结果更符合物理机制,增强了模型可解释性与可靠性,从而为智慧农业精准灌溉决策提供了新的技术方案。

关键词: 黄瓜; 温室; 蒸腾量估算; 物理信息神经网络

中图分类号: S626 文献标识码: A 文章编号: 1000-1298(2026)14-0049-08 OSID: 

PINN-based Estimation Method for Transpiration Rates of Greenhouse Cucumbers

Fu Yihui¹ Zhou Jing^{1,2} Deng Jun¹ Huang Zhigang² Wang Jizhang^{1,2}

(1. School of Agricultural Equipment Engineering, Jiangsu University, Zhenjiang 212013, China
2. Jiangsu Provincial Engineering Technology Research Center for IoT-Based Smart Horticultural Facilities, Changshu 215555, China)

Abstract: Accurate estimation of plant transpiration (ET_c) is crucial for precise irrigation and water management in greenhouses. While the traditional Penman-Monteith equation incorporated key drivers such as net radiation (R_n), temperature (T), humidity (R_H), and wind speed, its results exhibited errors under greenhouse conditions, making crop coefficients (K_c) difficult to determine. Conversely, purely data-driven models lacked physical mechanism constraints and exhibited limited generalization capabilities. To address this challenge, a novel method for estimating greenhouse cucumber transpiration was proposed by using a physics-informed neural network (PINN). This approach employed an enhanced Penman formula as a hard physical constraint, constructing a parallel hybrid network architecture with both a physics-based branch and a data-driven correction branch. A physics consistency loss function served as a soft constraint, simultaneously optimizing data fitting accuracy and physical consistency. Field experiments were conducted in glass greenhouses in Zhenjiang, Jiangsu Province, collecting measured data on net radiation, air temperature, relative humidity, and transpiration. Results indicated that compared with the fully connected neural network (FCNN) baseline model, the PINN model improved the coefficient of determination R^2 from 0.784 7 to 0.837 7, reduced the root mean square error (RMSE) by 13.17% to 0.459 6 mm/d, and decreased the mean absolute error (MAE) by 35.12% to 0.192 3 mm/d. It was demonstrated that integrating physical prior knowledge into neural networks not only enhanced the accuracy of transpiration estimation but also made the results more aligned with physical mechanisms. This improved the model's interpretability and reliability, thereby providing a technical solution for precision irrigation decision-making in smart agriculture.

Key words: cucumber; greenhouse; transpiration estimation; physics-informed neural networks

收稿日期: 2026-03-11 修回日期: 2026-03-31
基金项目: 国家自然科学基金项目(32171896)和江苏省重点研发计划项目(BE2002327)
作者简介: 付益辉(2000—),男,硕士生,主要从事设施农业信息技术研究,E-mail: 2507298580@qq.com
通信作者: 王纪章(1981—),男,教授,博士,主要从事设施农业信息技术研究,E-mail: whxh@ujs.edu.cn

0 引言

植物蒸腾是土壤-植物-大气连续体 (SPAC) 中水分传输的关键环节,准确估算作物蒸腾量 (ET_c) 对于实现农业水资源高效利用和精准灌溉具有重要意义。在温室环境中,由于覆盖材料和低风速等微气候特征,作物蒸腾驱动机制与露地栽培存在较大差异^[1]。近年来,温室蒸腾量相关研究已经取得诸多进展^[2-3],这些研究为温室作物高效生产提供了重要支撑,同时也对蒸腾量估算模型精度和适应性提出了更高要求。彭曼-蒙特斯方程 (Penman - Monteith, PM) 作为联合国粮农组织 (FAO) 推荐的潜在蒸散发 (ET_0) 计算方法^[4],虽被广泛用于农业蒸散发估算,但在温室封闭或半封闭环境下,其应用往往需要对参数进行修正^[5]。

在应用彭曼公式估算作物蒸腾量时,关键在于获取作物系数 (K_c),然后通过 K_c 和 ET_0 的乘积估算出作物实际蒸腾量。但 K_c 随作物品种、生育阶段和环境条件动态变化,难以准确获取^[6-7]。传统 K_c 的获取方法包括 FAO 分段法^[8-10]、蒸渗仪实测法^[11] 和无人机遥感反演法^[12] 等,但这些方法适用范围小,适用于大田而不适用于温室,且设备昂贵,同时受覆盖材料干扰。近年来,全连接神经网络 (FCNN)、支持向量机 (SVM) 等数据驱动方法^[13-17] 因强大的非线性拟合能力被引入该领域。但此类纯“黑箱”模型完全依赖数据统计规律,缺乏植物生理与能量平衡机制约束。特别是在温室实测数据稀缺或存在噪声时,纯数据模型易出现过拟合和预测失常等问题^[18],亟需构建一种既能利用数据拟合复杂环境因子,又能嵌入物理机制约束以确保预测结果符合生物物理规律的估算方法。

物理信息神经网络 (Physics-informed neural networks, PINN) 是由 Raissi 等^[19] 提出的一种新型深度学习框架,核心思想是将物理系统偏微分方程或代数方程作为软约束嵌入神经网络损失函数中。PINN 已在流体力学^[20]、电力行业^[21]、医疗科学^[22] 等领域取得成功应用,但在农业工程领域的应用尚处于起步阶段^[23]。

本文提出一种基于 PINN 的温室黄瓜蒸腾量估算方法。针对彭曼公式中的代数关系,设计并行混合网络结构,将 PM 方程作为物理约束嵌入损失函数,以实现模型物理一致性建立和 K_c 动态辨识。

1 材料与方法

1.1 试验方法与数据获取

试验于 2024 年 2—6 月在江苏省镇江市新港农

业生产基地 (32°11'N, 119°45'E) Venlo 型玻璃温室内进行。镇江市地处长江下游,属于亚热带季风气候,四季分明,夏季气温较高,潮湿多雨,冬季干燥寒冷,年平均风速约 2.5 m/s,年平均气温 14.6℃,年平均相对湿度 75%,冬季平均气温为 3.8℃,夏季平均气温为 26.6℃。温室覆盖材料为厚 4 mm 浮法玻璃,透光率约 95%。供试作物为‘荷兰 8316’水果黄瓜,于 1 月 20 日完成移栽定植。栽培基质为商品有机营养土,由少量珍珠岩、有机肥、泥炭和蛭石构成。其中总营养成分 (N + P₂O₅ + K₂O) 含量为 3% 左右,有机质含量大于 20%,pH 值为 6.0 ~ 7.5,电导率为 2.5 mS/cm。

黄瓜整个生长周期为 2024 年 2—6 月,数据采集系统由多类传感器构成,如图 1 所示。在水平截面上以 3 × 3 布置,垂直位置自下而上分别在 1、3、5 m 布置总计 27 个空气温湿度传感器 (SM5391B 型)。在温室正中间顶部高 5 m 处安装净辐射传感器 (TDD-2 型),底部安装蒸发皿 (J16021 型) 和高精度电子秤 (精度 0.1 g)。使用数据采集器 (CR1000X 型) 以 30 min 为间隔连续记录冠层净辐射 R_n 、 T 和 R_H 3 个参数。作物实际 ET_c 通过对蒸发皿实时称量测定,并采用蒸发皿系数 0.9 进行修正^[24]。




图 1 温室传感器布局

Fig. 1 Greenhouse sensor layout

1.2 PINN 模型构建与方法

1.2.1 模型选择

物理信息神经网络 (PINN) 是一种融合物理定律与机器学习的新型建模框架^[25],核心思想是将描述物理系统运行规律方程,如偏微分方程或代数方程,作为软约束条件嵌入神经网络损失函数中。这种方法将物理先验知识转换为一种强有力的正则化项,引导模型学习方向。与传统纯数据驱动的“黑箱”模型相比,这种“物理 + 数据”双驱动范式能够在不依赖海量标注数据情况下,有效提升模型泛化能力和预测结果的物理一致性,同时增强模型可解释性。

现有 PINN 主要求解由偏微分方程 (PDE) 控制的连续介质问题,需通过自动微分计算时空导数算子,但将其运用于代数方程的参数辨识问题同样被证实是可行的^[26]。针对温室蒸腾量估算中 K_c 难以

动态辨识问题,利用 PINN 框架将改进的 PM 代数方程作为物理约束,构建一种能够同时预测 ET_c 和动态辨识 K_c 的并行混合网络架构,由物理机理分支和数据驱动修正分支并行构成。前者基于改进的彭曼方程直接衡量预测值和物理定律偏差,通过硬约束确保符合能量平衡原理与空气动力学原理^[4];后者利用 FCNN 的非线性映射能力,动态辨识 K_c 并补偿复杂环境导致的模型预测偏差。在此基础上,设计了 1 个包含数据拟合误差与 K_c 生理范围、稳定性及非负性等物理一致性损失函数作为软约束。通过改进,将确定性物理模型机理优势与神经网络处理复杂非线性映射的能力结合,尝试在解决传统代数方程中参数难以动态确定问题的同时,确保模型预测结果在物理机制上的合理性与可解释性。整体网络结构如图 2 所示。




图 2 PINN 并行混合架构

Fig. 2 Parallel hybrid architecture of PINN model

1.2.2 数据预处理

从原始数据到模型可用输入需经过一系列预处理。采用 2 月数据作为神经网络预测结果研究样本,对原始数据集进行质量控制,依据物理可能范围与 3σ 法则剔除明显异常记录,最终获得有效数据样本 1 330 组。

为评估模型泛化性能并避免丢失时序信息,将数据按时间顺序划分为 3 个独立子集:训练集 (930 条,70%)、验证集 (200 条,15%) 与测试集 (200 条,15%)。此按序划分方式模拟模型在实际部署中利用历史数据预测未来的场景。

为提高模型训练稳定性与收敛速度,对输入特征与目标变量分别进行 Z-score 标准化处理。每个输入特征 x (包括 R_n 、 T 、 R_h) 转换为零均值、单位方差形式,转换参数 (均值和标准差) 仅从训练集中计算得到,并同样应用于验证集与测试集转换,以确保数据分布一致性。目标变量 ET_c 也进行类似标准化处理。所有标准化参数均仅从训练数据中学习,以

严格保证模型评估公正性。

1.2.3 物理机理模型选择

彭曼-蒙蒂斯方程是基于能量平衡和空气动力学的物理公式,在日尺度和小时尺度上都成立。只需输入相应时间步长气象数据,即可计算该时间步长 ET_0 ^[4]。

选取王健等^[27]修正的适合温室环境的 PM 方程作为 PINN 神经网络物理模型基础,该方程适宜在没有采用强制通风的温室中应用^[28],计算式为

$$ET_0 = \frac{0.408\delta(R_n - G) + \gamma \frac{628}{T + 273}(e_s - e_a)}{\delta + 1.24\gamma} \quad (1)$$

其中

$$e_s = 0.6108 \exp\left(\frac{17.27T}{T + 237.3}\right) \quad (2)$$

$$e_a = e_s R_h \quad (3)$$

$$\delta = \frac{4098e_s}{(T + 237.3)^2} \quad (4)$$

式中 ET_0 ——潜在蒸散发量,mm/d

G ——土壤热通量,取 50 W/m²

T ——空气温度,℃

e_s ——饱和水汽压,kPa

e_a ——实际水汽压,kPa

δ ——饱和水汽压-温度曲线斜率,kPa/℃

γ ——干湿表常数,取 0.665 kPa/℃

通过改进彭曼公式作为物理模块提供 PINN 中先验知识,从而计算蒸腾过程的理论基准值,为神经网络预测奠定基础。

1.2.4 数据驱动修正神经网络设计

设计 PINN 神经网络架数据驱动修正神经网络分支。该分支作为模型核心计算单元,旨在通过 FCNN 挖掘环境因子与作物生理响应之间的非线性映射关系,输出动态 K_c 及偏差修正项 ϵ ,以实现对物理机理模型输出结果进行修正。

网络架构如图 3 所示,该分支采用多层感知机 (MLP) 架构,由输入层、预处理模块、3 个隐藏层及双路输出层构成,数据流向从左至右依次处理。




图 3 数据驱动修正神经网络结构

Fig. 3 Structure of data-driven correction neural network

首先是输入与预处理,网络接收数据库中或实时的气象特征向量 $x = (R_n, T, R_h)^T$ 作为输入。为消除不同气象变量间的量纲差异并加速模型收敛,

输入数据经过 Z-score 标准化处理,转换为均值为 0、标准差为 1 的标准正态分布数据。

通过隐藏层进行特征提取,标准化后的数据进入由 3 个全连接层 (Dense layers) 组成的深度特征提取模块,神经元数量依次设置为 128、64 和 32,形成逐层抽象的“漏斗型”结构。3 个隐藏层均统一采用 ReLU 激活函数引入非线性,并嵌入 Batch Normalization (BN) 层以加速收敛。其中,首个隐藏层后额外加入 Dropout 层 (丢弃率 0.3) 以增强泛化能力。

网络末端分为 2 个独立的输出通路,分别对应物理模型所需的 2 个关键变量,并通过特定的激活函数施加结构性硬约束:

动态作物系数 (K_c): 采用 Softplus 激活函数 ($f(x) = \ln(1 + e^x)$) 从网络结构上强制约束 $K_c > 0$, 使其符合作物系数非负物理属性。

偏差修正项 (ϵ): 采用 Linear 激活函数设计允许输出正值或负值,使模型能够灵活补偿 PM 方程在温室低风速、高湿度等特殊微气候条件下产生的系统性正向或负向偏差。

1.2.5 模型融合与物理一致性损失函数设计

基于上述物理机理模型和数据驱动修正神经网络,最后将二者的输出通过乘法-加法连接融合,最终预测蒸腾量计算式为

$$ET_c^{pred} = ET_0 K_c + \epsilon \tag{5}$$

式中, ET_0 为物理分支计算的确定性基准值, K_c 和偏差修正项 ϵ 为数据驱动分支输出的动态参数。这种融合机制确保了模型预测主要由物理定律 ($ET_0 K_c$) 主导,而神经网络仅负责参数动态辨识与微量误差修正,从而在保证预测精度的同时,尽可能地保留模型可解释性。

为了使 K_c 和 ϵ 也能符合物理机理,设计了 1 组物理一致性损失函数作为软约束,总损失函数定义为各项损失加权和,共分为下 5 个部分。

(1) 为保障模型预测 K_c 具有明确的生物物理意义,引入 2 项针对性约束。 K_c 范围约束损失 $L_{k_{c_{range}}}$ 通过惩罚函数强制将 K_c 值域限制在合理的生理区间 $[0.3, 1.5]$ [4,8], 即

$$L_{k_{c_{range}}} = \frac{1}{N} \sum_{i=1}^N [\max(0.3 - K_c^{(i)}, 0)^2 + \max(K_c^{(i)} - 1.5, 0)^2] \tag{6}$$

式中 N ——样本总数

$K_c^{(i)}$ ——第 i 个样本作物系数预测值

(2) K_c 稳定性约束损失 $L_{k_{c_{stability}}}$ 通过最小化 K_c 预测值的方差,鼓励模型学习在短时尺度上平滑、稳定的变化模式,避免非物理剧烈波动,即

$$L_{k_{c_{stability}}} = \frac{1}{N} \sum_{i=1}^N (K_c^{(i)} - \overline{K_c})^2 \tag{7}$$

式中 $\overline{K_c}$ ——所有 K_c 平均值

(3) 针对模型结构中偏差修正项 ϵ , 设计残差相对约束损失 L_{bias} 确保残差项仅作为对物理主项 ($ET_0 K_c$) 的微调,维持物理驱动机制在预测中主导地位,即

$$L_{bias} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\epsilon^{(i)}}{ET_0^{(i)} K_c^{(i)} + \epsilon} \right)^2 \tag{8}$$

(4) 同时,加入非负约束损失 $L_{non_negative}$, 严格禁止模型输出负蒸腾量,直接对应于水分流失量不能为负的基本物理事实,即

$$L_{non_negative} = \frac{1}{N} \sum_{i=1}^N \max(0, -ET_{c,pred}^{(i)})^2 \tag{9}$$

(5) 损失函数核心,数据拟合损失 L_{data} 直接衡量模型预测值 $ET_{c,pred}$ 与真实观测值 $ET_{c,obs}$ 之间的均方误差,是模型学习的基础驱动力。计算式为

$$L_{data} = \frac{1}{N} \sum_{i=1}^N (ET_{c,pred}^{(i)} - ET_{c,obs}^{(i)})^2 \tag{10}$$

5 项损失加权组合成为总损失 L_{total} , 即

$$L_{total} = w_1 L_{k_{c_{range}}} + w_2 L_{k_{c_{stability}}} + w_3 L_{bias} + w_4 L_{non_negative} + w_5 L_{data} \tag{11}$$

式中, $w_1 \sim w_5$ 为各损失项权重,根据试验最终分别设定为 0.1、0.05、0.01、0.01 和 1.0。该权重配置明确了以数据拟合为主导,同时以物理约束为正则化项优化策略,旨在平衡模型准确性与机理合理性。利用 PINN 中软约束的思想,设计这样的 1 组物理一致性损失函数,期望使模型预测结果更符合物理机理约束。

1.3 模型优化与评价

1.3.1 低辐射后处理与模型训练优化策略

基于温室作物在夜间条件下气孔关闭、蒸腾趋近于零的生理机制 [29], 本模型在预测阶段引入基于 R_n 阈值的后处理规则。当输入 R_n 低于设定的生理阈值 (R_n^{th}) 时,强制将 ET_c^{pred} 置零。该策略作为强物理约束,目的是修正模型在低能量输入情况下可能产生的非物理解释。

模型训练采用 Adam 优化器,初始学习率为 0.001。训练过程采用基于验证集损失的平台期学习率衰减策略动态调整学习率 (耐心值 10, 衰减因子 0.5), 并配合早停机制 (耐心值 50) 以防止过拟合。批量大小设置为 32, 最大训练轮数为 300。

1.3.2 模型性能评价方法

为评估 PINN 方法的优越性,参照文献 [30], 设置纯数据驱动的 FCNN 作为基准模型进行对比。FCNN 采用与 PINN 中神经网络分支相同的 3 层架

构(128-64-32 神经元),同时包含相同的批归一化层和 Dropout 层。但移除物理分支和所有物理约束,仅通过最小化 MSE 进行训练。

采用决定系数(R^2)、均方根误差(RMSE)和平均绝对误差(MAE)定量评价模型性能。

2 结果与分析

2.1 参数选择和相关性分析

为了探究环境参数对黄瓜蒸腾量的影响,参照文献[31],同时考虑模型的简洁性和测量的简便性,选择 R_n 、 T 和 R_H 3个参数进行研究。3个参数首先是计算改进彭曼公式所必需的参数,其次是与蒸腾量存在较为显著的相关性,如图4所示,*表示 $P < 0.05$ 。




图4 皮尔逊相关性分析

Fig.4 Pearson correlation analysis

由图4可得, ET_c 与 R_n 成正比,随着太阳辐射增强,黄瓜蒸腾量逐渐提高。 ET_c 与 R_H 成反比,随着湿度增高气孔导度逐渐降低,使得蒸腾量逐渐降低。 ET_c 与 T 成正比,随着 T 上升叶片光合反应速度加快, ET_c 也逐渐提高。3个环境因子都与 ET_c 具有显著的相关性,适合进行研究,其余环境因子在综合模型的复杂度和测量便捷程度后暂时忽略。

2.2 模型训练过程分析

如图5所示,PINN模型在第62轮训练后因早停机制而终止,FCNN模型则在第57轮终止。尽管PINN总损失因包含多项正则化项而在训练初期高于FCNN,但验证损失收敛至更低的稳定平台。FCNN模型在训练后期表现出典型的过拟合特征,即验证损失在达到最低点后开始波动并上升。相比之下,PINN验证损失曲线在约50轮后趋于平稳,未出现明显回升,表明嵌入的物理约束发挥了正则化作用,一定程度上提升了模型泛化能力,抑制了对训练数据噪声的过度拟合。

2.3 预测精度

如表1所示,在独立测试集上的性能对比充分证明了PINN方法的优越性,PINN模型在所有评价




图5 PINN与FCNN训练损失对比

Fig.5 Comparison of training losses between PINN and FCNN

表1 PINN和FCNN性能

Tab.1 Performance of PINN and FCNN models

参数	PINN	FCNN
R^2	0.837 7	0.784 7
RMSE/(mm·d ⁻¹)	0.459 6	0.529 2
MAE/(mm·d ⁻¹)	0.192 3	0.296 4

指标上均优于纯数据驱动的FCNN模型。PINN的 R^2 达到0.8377,比FCNN的0.7847提升6.75%。在误差指标方面,PINN的RMSE为0.4596 mm/d,较FCNN降低13.17%;MAE为0.1923 mm/d,降低35.12%。这些定量结果表明,物理信息的引入在不损害模型拟合能力的前提下,通过引导学习方向,提高了模型预测准确性与稳定性。

2.4 物理可解释性

2.4.1 单月作物系数预测与分布

如图6所示,通过对神经网络分支输出的 K_c^{pred} 分析,可以发现模型学习到生物物理规律。 K_c^{pred} 均值为0.876,中位数为0.848,标准差为0.281,分布主要集中在0.5~1.5之间。这一范围与FAO-56推荐值(1.00)及温室实测范围(0.8~1.14)基本吻合^[4,8],证明了模型成功学习到合理的作物水分生理特征。图中存在1个 $K_c > 5$ 的离群点,采用 3σ 原则进行离群点检验,该点超出3倍标准差范围,判断为极端工况导致的测量误差。鉴于该点为孤立异常值,在模型训练前予以剔除,剔除数据




图6 有效样本的 K_c 分布

Fig.6 Distribution of K_c for valid samples

占比小于 2%。

在物理一致性损失函数中设计的 K_e 约束发挥了作用。 K_e 范围约束(0.3~1.5)作为硬性先验,直接将模型搜索空间限制在生理学可信区间内。 K_e 稳定性约束则作为一种平滑先验,促使模型学习到随时间与环境连续变化的 K_e 轨迹,符合作物生理状态的渐变特性,也提升了模型泛化性能。

2.4.2 全生长周期作物系数预测分析

在整个数据集上学习到的 K_e 表现出与作物生育阶段相吻合的时间变化规律,符合 FAO 提供的 K_e 和现有的研究结论。不同月份 K_e^{pred} 如表 2 所示。

表 2 不同月份 K_e^{pred} 统计特征

Tab.2 Statistical Characteristics of K_e^{pred} by month			
时间	中位数	数值 ^[4,8]	生长阶段
2月	0.85	0.52~0.98	苗期-开花初期
3月	0.94	0.71~1.11	开花期-结果初期
4月	1.04	0.82~1.20	结果初期-盛果期
5月	1.10	0.85~1.32	盛果期-末果期
6月	0.65	0.45~0.88	末果期-拉秧

从表 2 可看出,模型预测的 K_e 中位数呈先升后降的单峰型变化趋势,反映温室黄瓜早春茬的需水特性与生产实际一致。如前文所述,通过预测出的 K_e 可以较为准确地预测最终的 ET_e 。

2月作物处于苗期后期并向开花初期过渡,冠层基本建成,蒸腾需求稳步上升,模型预测的 K_e 中位数为 0.85。3月进入开花期与结果初期,作物进入营养生长与生殖生长并进阶段, K_e 中位数升至 0.94。4月作物从结果初期进入盛果期,此时植株已完成坐果,果实开始迅速膨大,叶面积指数持续增加,蒸腾强度显著上升,但尚未达到全生育期最高峰,模型预测的 K_e 中位数为 1.04,准确刻画了该阶段由结果初期向盛果期过渡的生理特征。5月作物从盛果期进入末果期,5月上旬仍为日光温室黄瓜的高产高峰期,植株蒸腾强烈,水分需求旺盛,5月下旬部分下位叶开始老化,生理活性略有下降,进入盛果期末期,模型预测的 K_e 中位数达到全生育期峰值 1.10,该峰值既体现了盛果期的高耗水特性,也兼顾了末果期初期可能出现的微弱回落,反映了模型对生育阶段连续变化较好的捕捉能力。6月作物从末果期进入拉秧阶段,植株生理活性显著下降,6月中旬起陆续拉秧,模型预测的 K_e 中位数降至 0.65,与生产实际一致。

逐月分析结果证明,本研究所构建的 PINN 模型不仅能够准确估算瞬时蒸腾量,而且成功模拟了 K_e 随生育期演进的动态规律。模型学习到的 K_e 全生育期变化轨迹,与温室黄瓜早春茬的生理机制和

生产实际一致,严格约束在 0.52~1.32 的生理合理区间内。进一步验证了将动态 K_e 作为环境条件与作物隐性状态响应函数的建模思路的可行性,以及复合损失函数中物理约束的有效引导作用。

2.4.3 残差项贡献与后处理效果

神经网络预测残差项均值为 0.024 mm/d,标准差为 0.186 mm/d,绝对值远小于物理主项(ET_0K_e)。表明物理模型已能解释 ET_e 变化的主要部分,残差仅承担约 5% 的修正作用。说明损失函数起到了效果,结果与“残差相对约束”的设计目标一致。

如图 7 所示,低辐射后处理策略的应用效果显著。测试集共有 42 个样本 R_n 低于阈值。对这些样本进行分析,可得应用后处理规则将预测值归零后,标准差从 0.186 mm/d 降至 0.032 mm/d。表明此策略通过强制模型遵守夜间蒸腾极低的物理常识,增强了模型夜间预测准确性。




图 7 R_n 阈值处理效果
Fig.7 Processing effect of R_n threshold

2.5 数据量敏感性

为客观评估 PINN 模型在有限数据条件下优越性和数据效率,设计了系统对比试验。试验分别从原始训练集中随机抽取 20%、40%、60%、80% 和 100% 的数据作为训练子集,验证集和测试集保持不变。在每个数据量条件下,分别训练 PINN 和 FCNN 模型,并在相同测试集上评估性能,所有试验均重复 5 次以减少随机性影响,结果取平均值。试验结果如图 8 所示。

由图 8 可知,在仅使用 20% 训练数据时,PINN 模型已取得 $R^2 = 0.333$ 的性能,优于 FCNN 模型 ($R^2 = 0.302$),提升 10.3%。随着数据量增加至 40% (约 372 个样本),PINN 的 R^2 快速提升至 0.652,相对 FCNN ($R^2 = 0.526$) 的优势扩大至 24.0%,反映了物理约束在中等数据量条件下开始发挥关键的引导作用。当数据量达到 60% 时,PINN 的 R^2 达到 0.802,相对于 FCNN ($R^2 = 0.703$) 仍有 14.1% 的优势。即使在 100% 数据量下,PINN ($R^2 = 0.847$) 仍保持相对于 FCNN ($R^2 = 0.823$) 的 2.9% 优势。




图 8 不同数据量的预测结果

Fig.8 Prediction results under different training data volumes

通过插值计算,PINN 仅需约 75.4% 的数据即可达到 FCNN 使用 100% 数据时 R^2 性能,数据效率显著提升,说明 PINN 模型具有更优的数据利用效率。

3 结论

(1)提出了一种基于 PINN 神经网络的温室黄瓜蒸腾量估算新方法,构建了包含物理机理分支和数据驱动修正分支的并行混合网络结构。物理机理模型采用改进的彭曼公式作为硬约束,确保预测结果符合能量平衡原理;数据驱动修正模型通过 FCNN 动态辨识 K_e ,补偿环境复杂性带来的系统偏差;物理一致性损失函数作为软约束,通过多维度物理约束确保预测结果的合理性。

(2)模型验证结果表明,与 FCNN 基准模型相比,PINN 模型 R^2 从 0.784 7 提升至 0.837 7, RMSE 降低 13.17%,MAE 降低 35.12%。在数据稀缺条件下,当训练样本减少 60% 时,PINN 模型仍保持较高的预测精度,验证了物理先验知识对数据效率的提升作用。

参 考 文 献

[1] 毛罕平, 晋春, 陈勇. 温室环境控制方法研究进展分析与展望[J]. 农业机械学报, 2018, 49(2): 1-13.
Mao Hanping, Jin Chun, Chen Yong. Research progress and prospect on control methods of greenhouse environment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(2): 1-13. (in Chinese)

[2] 胡瑾, 杨永霞, 李远方, 等. 温室环境控制方法研究现状分析与展望[J]. 农业工程学报, 2024, 40(1): 112-128.
Hu Jin, Yang Yongxia, Li Yuanfang, et al. Analysis and prospect of the environmental control systems for greenhouse[J]. Transactions of the CSAE, 2024, 40(1): 112-128. (in Chinese)

[3] 万敏, 杨魏, 刘竹青, 等. 不同通风方式日光温室微环境模拟与作物蒸腾研究[J]. 农业机械学报, 2024, 55(1): 328-338, 349.
Wan Min, Yang Wei, Liu Zhuqing, et al. Microenvironment simulation and crop transpiration analysis of solar greenhouse with different ventilation modes[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 328-338, 349. (in Chinese)

[4] Pereira L S, Allen R G, Smith M, et al. Crop evapotranspiration estimation with FAO56: past and future[J]. Agricultural Water Management, 2015, 147: 4-20.

[5] 龚雪文, 李雨, 葛建坤, 等. 基于室外气象信息的温室通风期室内参考作物蒸发蒸腾量估算模型[J]. 农业机械学报, 2025, 56(6): 649-659.
Gong Xuewen, Li Yu, Ge Jiankun, et al. Calculation model of reference crop evapotranspiration in greenhouse based on outdoor meteorological data during ventilation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(6): 649-659. (in Chinese)

[6] 周富成, 连利叶, 温军, 等. 基于涡动相关的农田蒸散量及作物系数研究[J]. 青海大学学报, 2024, 42(4): 41-48.
Zhou Fucheng, Lian Liye, Wen Jun, et al. Research on the field evapotranspiration and crop coefficient based on eddy correlation[J]. Journal of Qinghai University, 2024, 42(4): 41-48. (in Chinese)

[7] 裴冬杰, 魏新光, 崔宁博, 等. 温室葡萄蒸散量时间尺度提升方法优选[J]. 农业工程学报, 2022, 38(14): 88-97.
Pei Dongjie, Wei Xinguang, Cui Ningbo, et al. Optimization of the time scale improvement method for grape evapotranspiration in greenhouses[J]. Transactions of the CSAE, 2022, 38(14): 88-97. (in Chinese)

[8] 闫浩芳, 毋海梅, 张川, 等. 基于修正双作物系数模型估算温室黄瓜不同季节腾发量[J]. 农业工程学报, 2018, 34(15): 117-125.
Yan Haofang, Wu Haimei, Zhang Chuan, et al. Estimation of evapotranspiration of greenhouse cucumber in different seasons based on modified dual crop coefficient model[J]. Transactions of the CSAE, 2018, 34(15): 117-125. (in Chinese)

[9] 赵爽, 闫浩芳, 张川, 等. 基于改进的双作物系数模型与 Priestley-Taylor 模型估算温室黄瓜蒸散量[J]. 排灌机械工程学学报, 2023, 41(8): 849-857.
Zhao Shuang, Yan Haofang, Zhang Chuan, et al. Estimation of evapotranspiration of greenhouse cucumber based on improved dual crop coefficient model and Priestley-Taylor model[J]. Journal of Drainage and Irrigation Machinery Engineering, 2023, 41(8): 849-857. (in Chinese)

[10] Nagy A, Kiss N É, Buday-Bódi E, et al. Precision estimation of crop coefficient for maize cultivation using high-resolution satellite imagery to enhance evapotranspiration assessment in agriculture [J]. Plants, 2024, 13(9): 1212.

[11] 张子怡, 孙旭光, 景翠蛟, 等. 基于称重式蒸渗池的黑龙港地区冬小麦作物系数的本地化优化[J]. 河北农业大学学报, 2025, 48(4): 108-117.
Zhang Ziyi, Sun Xuguang, Jing Cuijiao, et al. Localization optimization of winter wheat crop coefficient in Heilonggang area

- based on weighing lysimeter[J]. *Journal of Hebei Agricultural University*, 2025, 48(4): 108–117. (in Chinese)
- [12] 韩文霆, 邵国敏, 马代健, 等. 大田玉米作物系数无人机多光谱遥感估算方法[J]. *农业机械学报*, 2018, 49(7): 134–143.
Han Wenting, Shao Guomin, Ma Daijia, et al. Estimating method of crop coefficient of maize based on UAV multispectral remote sensing[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(7): 134–143. (in Chinese)
- [13] 白燕英, 苗丰, 李二珍, 等. 基于 CNN 和 LSTM 深度学习算法的作物播期差异遥感识别[J]. *农业机械学报*, 2026, 57(2): 276–289.
Bai Yanying, Miao Feng, Li Erzhen, et al. Remote sensing identification of crop sowing date differences based on CNN and LSTM deep learning algorithms[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2026, 57(2): 276–289. (in Chinese)
- [14] 唐红亮, 王冬, 董延军, 等. 基于 SVM 参数优化的饮用水水源地风险预警[J]. *水资源保护*, 2025, 41(2): 209–215, 232.
Tang Hongliang, Wang Dong, Dong Yanjun, et al. Risk warning of drinking water source areas based on SVM parameter optimization[J]. *Water Resources Protection*, 2025, 41(2): 209–215, 232. (in Chinese)
- [15] 李莉, 李文军, 马德新, 等. 基于 LSTM 的温室番茄蒸腾量预测模型研究[J]. *农业机械学报*, 2021, 52(10): 369–376.
Li Li, Li Wenjun, Ma Dexin, et al. Prediction model of transpiration of greenhouse tomato based on LSTM[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(10): 369–376. (in Chinese)
- [16] 韩坤林, 王钊英, 杨会民, 等. 基于 PCA-BPNN 的温室番茄果实直径预测模型[J]. *新疆农业科学*, 2022, 59(2): 485–492.
Han Kunlin, Wang Zhaoying, Yang Huimin, et al. Prediction model of tomato fruit diameter in green houses based on PCA-BPNN[J]. *Xinjiang Agricultural Sciences*, 2022, 59(2): 485–492. (in Chinese)
- [17] 李莉, 李伟, 耿磊, 等. 基于 RF-GRU 的温室番茄结果前期蒸腾量预测方法[J]. *农业机械学报*, 2022, 53(3): 368–376.
Li Li, Li Wei, Geng Lei, et al. Prediction method of greenhouse tomato transpiration in early fruiting stage based on RF-GRU[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(3): 368–376. (in Chinese)
- [18] 崔晨璐, 张轩, 吴永祥, 等. 基于 LSTM 的洪水预报残差修正方法研究[J/OL]. *中国农村水利水电*, 2025–12–08. <https://link.cnki.net/urlid/42.1419.TV20251205.1944.008>.
- [19] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. *Journal of Computational Physics*, 2019, 378: 686–707.
- [20] 张橙, 李雪, 叶茂, 等. 物理信息神经网络在两相流中的应用[J]. *化工学报*, 2024, 75(11): 3835–3856.
Zhang Cheng, Li Xue, Ye Mao, et al. Application of physics-informed neural network in two-phase flow[J]. *CIESC Journal*, 2024, 75(11): 3835–3856. (in Chinese)
- [21] 程凯, 王鹏宇, 包涛, 等. 信息物理融合的电力系统日前-日内优化调度[J]. *电气传动*, 2023, 53(10): 49–56.
Cheng Kai, Wang Pengyu, Bao Tao, et al. Day-ahead and intra-day optimal dispatching of cyber-physical integrated power system[J]. *Electric Drive*, 2023, 53(10): 49–56. (in Chinese)
- [22] Berkhahn S, Ehrhardt M. A physics-informed neural network to model COVID-19 infection and hospitalization scenarios[J]. *Advances in Continuous and Discrete Models*, 2022, 2022(1): 61.
- [23] 聂娟, 孙瑞志, 曹振丽, 等. 精准农业信息物理融合系统的事件模型研究[J]. *农业机械学报*, 2015, 46(1): 285–291, 314.
Nie Juan, Sun Ruizhi, Cao Zhenli, et al. Preliminary study on event model in cyber-physical systems for precision agriculture[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2015, 46(1): 285–291, 314. (in Chinese)
- [24] 刘浩, 段爱旺, 孙景生, 等. 温室番茄节水调质灌水方案评价[J]. *排灌机械工程学报*, 2014, 32(6): 529–534, 540.
Liu Hao, Duan Aiwang, Sun Jingsheng, et al. Evaluation of irrigation scheme with high quality and efficiency for greenhouse grown tomato[J]. *Journal of Drainage and Irrigation Machinery Engineering*, 2014, 32(6): 529–534, 540. (in Chinese)
- [25] 刘肖廷, 闵建, 于相楠, 等. 物理信息神经网络的应用与研究进展[J]. *河南科学*, 2024, 42(7): 945–959.
Liu Xiaoting, Min Jian, Yu Xiangnan, et al. Applications and advancements of physics-informed neural networks: an overview[J]. *Henan Science*, 2024, 42(7): 945–959. (in Chinese)
- [26] Jagtap A D, Kharazmi E, Karniadakis G E. Conservative physics-informed neural networks on discrete domains for conservation laws: applications to forward and inverse problems[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 365: 113028.
- [27] 王健, 蔡焕杰, 李红星, 等. 日光温室作物蒸发蒸腾量的计算方法研究及其评价[J]. *灌溉排水学报*, 2006(6): 11–14.
Wang Jian, Cai Huanjie, Li Hongxing, et al. Study and evaluation of the calculation methods of reference crop evapotranspiration in solar-heated greenhouse[J]. *Journal of Irrigation and Drainage*, 2006(6): 11–14. (in Chinese)
- [28] 陈新明, 蔡焕杰, 李红星, 等. 温室大棚内作物蒸发蒸腾量计算[J]. *应用生态学报*, 2007(2): 317–321.
Chen Xinming, Cai Huanjie, Li Hongxing, et al. Calculation of crop evapotranspiration in greenhouse[J]. *Chinese Journal of Applied Ecology*, 2007(2): 317–321. (in Chinese)
- [29] Stanghellini C. Horticultural production in greenhouses: efficient use of water[J]. *Acta Horticulturae*, 2014, 1034: 25–32.
- [30] Yan L, Zhou Y, Liu H, et al. An improved method for physics-informed neural networks that accelerates convergence[J]. *IEEE Access*, 2024, 12: 23943–23953.
- [31] 闫浩芳, 赵宝山, 张川, 等. Penman-Monteith 模型模拟 Venlo 型温室黄瓜植株蒸腾[J]. *农业工程学报*, 2019, 35(8): 149–157.
Yan Haofang, Zhao Baoshan, Zhang Chuan, et al. Estimating cucumber plants transpiration by Penman-Monteith model in Venlo-type greenhouse[J]. *Transactions of the CSAE*, 2019, 35(8): 149–157. (in Chinese)