doi:10.6041/j.issn.1000-1298.2025.07.050

基于 IBKA－ACNN－DD 的短期土壤温度预测模型

杨玉强　宋　坤　罗焕芝
（广东海洋大学智慧海洋传感网及其装备工程技术研究中心，湛江 524088）

摘要：土壤温度是农业科学中一个非常重要的变量，其时空变化具有随机性、非线性和非平稳性的特点，极大影响了预测的准确性，为此，提出一种改进黑翅鸢算法（Improved black kite algorithm，IBKA）优化集成注意力机制的卷积神经网络（attention convolutional neural networks，ACNN）和树突网络（dendrite net，DD）的短期土壤温度预测模型。首先，通过自适应分层学习策略改进黑翅鸢算法，以增强算法的优化能力；接着，将集成注意力机制的卷积神经网络和树突网络两种模型融合得到新模型 ACNN－DD，用于挖掘土壤温度与特征变量之间的关系，进而输出未来 6 h 内的土壤温度预测结果。最后，为了验证该模型，将重庆市南川区峰岩乡风云村蔬菜种植基地、内蒙古奈曼农田生态系统国家野外科学观测研究站和陕西安塞农田生态系统国家野外科学观测研究站监测的土壤温度数据代入该模型，结果表明，该模型决定系数高达 0.98、0.98、0.99，均方根误差低至 1.12、1.35、1.37℃，平均绝对百分比误差降到 3.83%、5.54%、5.41%，均优于 ILSTM_Soil、MLP－FFA 和 SPA－GA－SVR 等传统的土壤温度预测模型。该模型可以有效预测未来 6 h 内的土壤温度，可为智慧农业领域的应用提供理论基础。

关键词：土壤温度预测；IBKA 算法；ACNN－DD 模型；特征提取；智慧农业
中图分类号：TP183；S24　　**文献标识码**：A　　**文章编号**：1000-1298(2025)07-0541-08　　**OSID**：

Short-term Soil Temperature Prediction Model Based on IBKA－ACNN－DD

YANG Yuqiang　SONG Kun　LUO Huanzhi
(*Research Center of Guangdong Smart Oceans Sensor Networks and Equipment Engineering*, *Guangdong Ocean University*, *Zhanjiang* 524088, *China*)

Abstract: Soil temperature is a very important variable in agricultural science, and its spatial and temporal variations are characterized by stochasticity, nonlinearity and non-stationarity, which greatly affects the accuracy of prediction, for this reason, an improved black kite algorithm (IBKA) was proposed to optimize a short-term soil temperature prediction model by integrating the attention mechanism of convolutional neural networks (ACNN) and dendrite networks (DD). Firstly, the black-winged kite algorithm was improved by adaptive hierarchical learning strategy to enhance the optimization ability of the algorithm; then the two models of convolutional neural networks (ACNN) and dendrite networks (DD) with integrated attention mechanism were fused to obtain a new model, ACNN－DD, which was used to mine the relationship between soil temperature and feature variables, and then to output the prediction of the soil temperature in the next 6 hours. Finally, in order to validate the model, soil temperature data monitored at the vegetable planting base in Fengyan Village, Fengyan Township, Nanchuan District, Chongqing, the National Field Scientific Observatory for Naiman Farmland Ecosystems, Inner Mongolia, and the National Field Scientific Observatory for Ansai Farmland Ecosystems, Shaanxi, were brought into the model. The results showed that the coefficients of determination of the model were as high as 0.98, 0.98, and 0.99, and the root mean square errors were as low as 1.12℃, 1.35℃, and 1.37℃, the mean absolute percentage errors were reduced to 3.83%, 5.54%, and 5.41%, which were all superior to that of the traditional soil temperature prediction models, such as ILSTM_Soil, MLP－FFA, and SPA－GA－SVR, etc. This showed that the model can effectively predict the soil temperature in the next 6 hours, which can provide a theoretical basis for the application in the field of smart agriculture.

Key words: soil temperature prediction; IBKA algorithm; ACNN－DD model; feature extraction; smart agriculture

收稿日期：2024－12－24　修回日期：2025－02－24
基金项目：广东省自然科学基金项目(2023A1515011212)
作者简介：杨玉强(1977—)，男，教授，博士生导师，主要从事光电传感与检测技术研究，E-mail：yangyuqiang@gdou.edu.cn

0 引言

土壤温度是由大气和陆地表面水热循环共同作用的结果,其监测技术在农业科学中占据着不可取代的位置[1]。目前土壤温度监测过程较为复杂,无法提供大面积监测点[2]。因此,精准地预测土壤温度有一定的应用价值。然而土壤温度的时空变化受各种环境因子的影响,给土壤温度的预测带来了巨大挑战[3]。近年来随着机器学习技术迅速发展,已在多个领域成功应用[4]。其中基于机器学习的预测模型在土壤温度预测中也取得一定成果[5-14]。然而,前人的研究主要基于多层感知器结合萤火算法,LSTM 和 XGBoost - LSTM 等方法实现土壤温度预测,缺少其他群智能优化法如改进黑翅鸢算法(IBKA),其他深度学习算法如集成注意力机制的卷积神经网络(ACNN)和树突网络(DD)相结合的研究。IBKA 算法是基于 BKA 算法[15]改进的随机搜索算法,擅长处理最优化问题。集成注意力的卷积神经网络是一类包含卷积计算且具有深度结构的前馈神经网络,具备局部特征提取能力[16],这种能力广泛应用在各领域[17]。DD 是一种全新的类似于支持向量机或多层感知器的机器学习算法,与多层感知器相比,具有更高的模型泛化能力[18]。本文将使用重庆市南川区峰岩乡风云村蔬菜种植基地、内蒙古奈曼农田生态系统国家野外科学观测研究站和陕西安塞农田生态系统国家野外科学观测研究站监测的数据进行测试。首先以 IBKA 算法作为 ACNN - DD 网络的最优网络结构的理论指导,再通过 ACNN 提取监测点数据集的局部特征,以 DD 网络对提取局部特征进一步特征构建,得到未来 6 h 内的土壤温度。

1 材料与方法

1.1 数据采集系统

本研究使用 DS18B20 型温度传感器、SHT35 型温湿度传感器、STM32F407 单片机、SX1278 - A 半双工无线传输模块、SX1278 - B 半双工无线传输模块和 TianYi510S 上位机设计数据采集系统,如图 1 所示。采集系统的工作流程为:DS18B20 型温度传感器监测 10 cm 深处的土壤温度,SHT35 型温湿度传感器监测距离地面 1 cm 高度的地面温湿度。作为系统的核心控制器,STM32F407 单片机汇总来自上述传感器的温湿度数据,之后通过 SX1278 - A 半双工无线传输模块和 SX1278 - B 半双工无线传输模块将数据传输至 TianYi510S 上位机中进行存储。本研究设计的数据采集系统数据字段详情如表 1 所示。由表 1 可得数据规范与物理量间的映射关系,为数据采集、存储及后续分析应用建立了统一的标准化框架。将设计好的数据采集系统部署在重庆市南川区峰岩乡蔬菜种植基地中进行数据采集,采集时间为 2023 年 1 月 1 日—2024 年 1 月 1 日,采集间隔为 1 h,共采集 8 784 条数据。

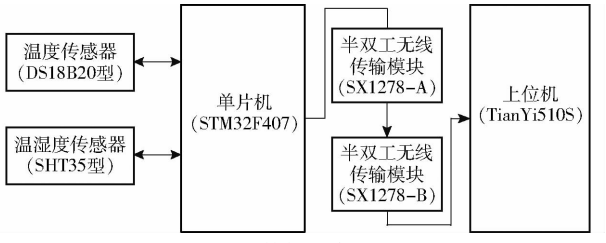

图 1 数据采集系统

Fig. 1 Data acquisition system

表 1 数据采集系统数据字段详情

Tab. 1 Details of data fields of data acquisition system

字段	类型	长度/范围	描述
device_id	String	最大 64 字符	设备唯一标识
name	String	最大 64 字符	测试点名称
timestamp	String	ISO8601	数据记录的时间戳,UTC 时区
soil_temperature	Float	-18 ~ 50℃	土壤温度
ground_humidity	Float	0 ~ 100%	地面相对湿度
ground_temperature	Float	-18 ~ 50℃	地面温度

1.2 土壤温度时序变化分析

为了更好地分析土壤温度时序变化,将采集到的 8 784 条土壤温度数据以折线图的形式进行展示,具体结果如图 2 所示。从图 2 可以看出距地表 10 cm 处的土壤温度变化规律,即在 1 月(0 ~ 616 h)内呈下降趋势,2—8 月(616 ~ 5 711 h)内呈上升趋势,9—12 月(5 711 ~ 8 784 h)内总体呈下降趋势。

1.3 特征选择与数据构建

为了更好地计算每个特征变量与土壤温度之间的相关性,引入相关系数 R,评估标准如下:当 $|R| \in (0.8,1]$,两者具有极强相关性,$|R| \in (0.6,0.8]$,两者具有强相关性,$|R| \in (0.4,0.6]$,两者具有中相关性,$|R| \in (0.2,0.4]$,两者具有弱相关性,$|R| \in [0,0.2]$,两者具有极弱相关性[19]。

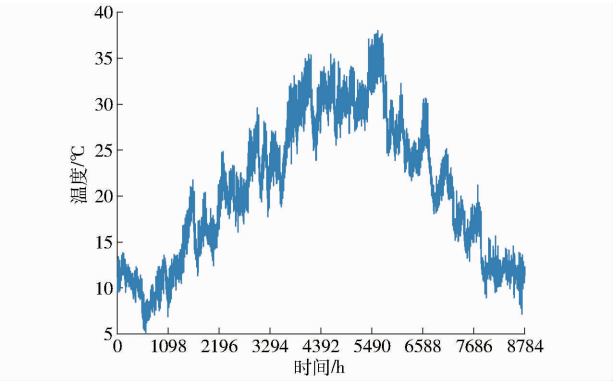

图 2　距地表 10 cm 处逐时土壤温度时间序列

Fig. 2　Time series of hourly soil temperatures at 10 cm from surface

通过数据采集系统采集的地面温度、地面相对湿度、中国气象局(https://www.cma.gov.cn/)下载的风速和重庆市南川区峰岩乡农田观测中心的历史光照强度得到:地面温度、地面相对湿度、光照强度和风速与土壤温度 $|R|$ 分别为 0.89、0.11、0.65 和 0.39。由此可得只有地面温度和光照强度的 $|R|$ 大于 0.6,因此本研究选择的特征输入变量为地面温度和光照强度。

为了使 ACNN－DD 模型能够有效地预测未来多个数据,在模型中加入滑动窗口法(SW)[20]。窗口大小设置为 12,使用未来 6 h(即 6 个时间步长)的土壤温度作为输出标签的方式对数据集进行重构,滑动窗口法预测过程如图 3 所示。在图 3 中,模型输入部分使用 x_n、x_{n+1}、x_{n+2}、…、x_{n+11} 表示连续的真实观测数据,其中 x_n 表示第 n 时刻观测值,包括地面温度、光照强度以及土壤温度。而输出部分则用 y_{n+1}、y_{n+2}、…、y_{n+6} 表示相应的预测值。其中 y_{n+1} 表示第 $n+1$ 时刻预测的土壤温度。此外,按照比例 7:3 将数据集划分为训练集和测试集,即 70% 的数据用于训练模型,剩余 30% 的数据用于测试模型性能,以确保其预测能力的有效性。

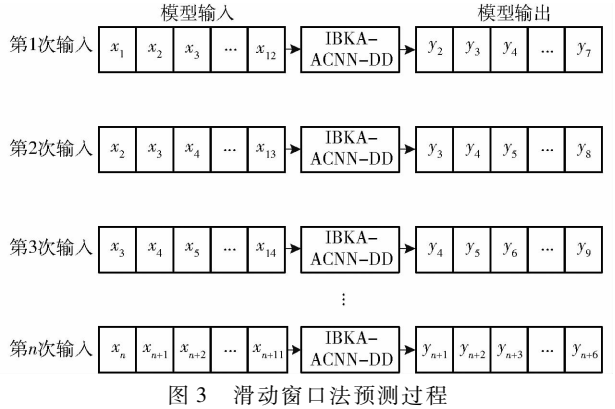

图 3　滑动窗口法预测过程

Fig. 3　Sliding window method forecasting process

1.4　土壤温度预测框架

本研究主要考虑 2 个问题:①哪种机器学习算法更符合土壤温度时间序列预测。②在神经网络参数优化方面,哪种群智能优化算法能够更快、稳定解决参数优化。为了解决以上问题,提出一种 IBKA－ACNN－DD 的短期土壤温度预测模型,如图 4 所示。首先在神经网络参数优化方面利用改进黑翅鸢优化算法加以优化,提升模型稳健性。接着通过集成注意力机制的卷积神经网络提取土壤温度数据集的局部特征。最后将提取的局部特征送入树突网络中,挖掘土壤温度与关键因子的关系,进而得出预测结果。

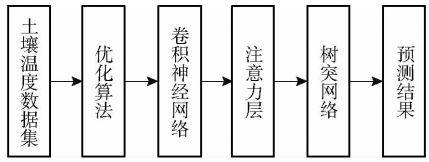

图 4　土壤温度预测框架

Fig. 4　Soil temperature prediction framework

1.5　优化算法

由于 ACNN－DD 网络结构的参数选择对土壤温度预测的稳健性具有较大影响,因此对 ACNN－DD 网络的网络参数进行优化十分必要。改进的 BKA 算法在收敛速度和精度方面都表现出良好的性能,因此采用 IBKA 对 ACNN－DD 网络结构的关键参数进行寻优。选取 ACNN－DD 网络模型中的初始学习率和最大迭代次数作为优化对象。

1.5.1　BKA 算法

黑翅鸢优化算法是一种灵感来源于黑翅鸢迁徙和捕食行为的新型群智能优化算法。算法主要通过黑翅鸢的攻击行为和迁徙行为来平衡全局探索和局部搜索能力,并确保种群多样性。黑翅鸢攻击行为和迁徙行为数学模型分别为

$$x_{ij}^{\text{new}}=\begin{cases}x_{ij}+0.05\mathrm{e}^{-2\left(\frac{t}{T}\right)^2}(1+\sin r_1)x_{ij} & (p<r_3)\\ x_{ij}+0.05\mathrm{e}^{-2\left(\frac{t}{T}\right)^2}(2r_2-1)x_{ij} & (p\geqslant r_3)\end{cases} \tag{1}$$

式中　t——当前迭代次数

T——最大迭代次数

r_1、r_2、r_3——0～1 随机数

p——常数,取 0.9

x_{ij}——第 i 只黑翅鸢在第 j 维的位置

x_{ij}^{new}——第 i 只黑翅鸢在第 j 维的位置更新位置

$$x_{ij}^{\text{new}}=\begin{cases}x_{ij}+C(0,1)(x_{ij}-L_j^t) & (F_i<F_{ri})\\ x_{ij}+C(0,1)\left(L_j^t-2x_{ij}\sin\left(r_4+\frac{\pi}{2}\right)\right) & (F_i\geqslant F_{ri})\end{cases} \tag{2}$$

式中 $C(0,1)$——服从柯西分布的数

r_4——0 ~ 1 随机数

L_j^t——第 t 次迭代中黑翅鸢在第 j 维中的领先得分者

F_i——在第 t 次迭代过程中,任意一只黑翅鸢在第 j 维的位置

F_{ri}——第 t 次迭代中任意黑翼鸢在第 j 维随机位置的适应度

1.5.2 IBKA 算法

对于 BKA 算法而言,其优化能力主要取决于如何平衡算法深度挖掘与全局搜索能力、如何确保种群多样性[21]。针对上述问题,提出一种基于自适应分层学习策略改进的 BKA 算法(IBKA)。该算法旨在通过自适应分层学习策略平衡算法深度挖掘与全局搜索能力并确保种群的多样性。

为有效兼顾全局探索和深度挖掘并确保种群的多样性,受分层学习的思想启发[22-23]。将原始种群按比例 1∶1∶8分为上层种群、中层种群和下层种群 3 层。随着迭代次数增加,上层种群的黑翅鸢数量逐渐增加,中层种群的黑翅鸢数量保持不变,下层种群的黑翅鸢数量逐渐减少。之后分别为上层种群设计专注于挖掘的学习策略,为中层种群设计兼顾挖掘和全局探索的学习策略,为下层种群设计倾向于全局探索的学习策略。

上层种群位置更新公式为

$$x_{ij}^{\mathrm{new1}} = \begin{cases} \omega x_{\mathrm{best}} + r_g a r_h & (0.5 < r_5 < 1.0) \\ \omega x_{ij} + 0.05\mathrm{e}^{-2\left(\frac{t}{T}\right)^2}(2r_2 - 1)x_{ij} & (0 \leqslant r_5 \leqslant 0.5) \end{cases} \tag{3}$$

其中

$$\omega = \begin{cases} \dfrac{1}{\pi \mathrm{e}^2} a \cos r_7 & (0 < r_6 < 0.5) \\ \dfrac{1}{\pi \mathrm{e}^2} a \sin r_8 & (0.5 \leqslant r_6 \leqslant 1.0) \end{cases} \tag{4}$$

$$r_g = r_9\left(0.1 - \frac{0.1t}{T}\right) \tag{5}$$

$$a = (x_{\mathrm{avg}} - x_{ij})^2 + [(x_{\mathrm{avg}} - x_{ij})r_{10}]^2 - 2(x_{\mathrm{avg}} - x_{ij})(x_{\mathrm{avg}} - x_{ij})r_{10}\cos(2\pi r_{11}) \tag{6}$$

式中 w——惯性因子

x_{best}——全局最优解

r_h——服从正态分布随机数

r_g——三角形游走权重

a——游走距离

x_{avg}——上层种群的中心位置

$r_5 \sim r_{11}$——0 ~ 1 随机数

中层种群位置更新公式为

$$x_{ij}^{\mathrm{new2}} = \omega x_{ij} |\sin(2\pi r_{12})| - \pi r_{12}\sin(2\pi r_{12}) \cdot \left| \left[2\pi\left(1 - \frac{\sqrt{5}-1}{2}\right) - \pi\right] x_{\mathrm{best}} - \left(2\pi\frac{\sqrt{5}-1}{2} - \pi\right) x_{ij}^t \right| \tag{7}$$

式中 r_{12}——[0,1]的随机数

下层种群位置更新公式为

$$x_{ij}^{\mathrm{new3}} = \begin{cases} \omega x_{ij} + 0.05\mathrm{e}^{-2\left(\frac{t}{T}\right)^2}(1 + \sin r_1)x_{ij} & (0 \leqslant r_{14} < 0.5) \\ \omega x_{\mathrm{best}} + \mathrm{e}^b \cos(4\pi(r_{13} - 0.5))|x_{\mathrm{best}} - x_{ij}| & (0.5 \leqslant r_4 \leqslant 1.0) \end{cases} \tag{8}$$

其中

$$b = \begin{cases} \cos\left(\pi\left(1 - \dfrac{t}{T}\right)\right) & (0 \leqslant r_{15} < 0.5) \\ \sin\left(\pi\left(1 - \dfrac{t}{T}\right)\right) & (0.5 \leqslant r_{15} \leqslant 1.0) \end{cases} \tag{9}$$

式中 r_{13}、r_{14}、r_{15}——0 ~ 1 的随机数

t——当前迭代次数

1.5.3 IBKA 算法流程

(1)输入 IBKA 种群大小 N_{IBKA}、问题维度 D、最大迭代次数 T 和当前迭代次数 t。

(2)初始化上、中、下层种群黑翅鸢比例以及黑翅鸢种群的初代领导者和种群全局最优解。

(3)按比例将原始种群分为上层种群、中层种群和下层种群。

(4)根据式(2)更新黑翅鸢种群领导者。

(5)根据式(3)更新上层种群中黑翅鸢位置。

(6)根据式(7)更新中层种群中黑翅鸢位置。

(7)根据式(8)更新下层种群中黑翅鸢位置。

(8)合并上、中、下层种群得到合并种群,并更新合并种群中的全局最优解。

(9)调整上下层种群黑翅鸢比例。

(10)当前迭代次数 $t = t + 1$。

(11)判断 t 是否大于 T。若达不到,则跳转到步骤(4),若达到,则进行下一步。

(12)得到全局最优解,算法停止运行。

其算法流程如图 5 所示。

1.6 ACNN-DD 模型

卷积神经网络是一种前馈神经网络,具备强大的局部特征提取能力,能够直接从原始数据中提取出重要的局部特征。

注意力机制是嵌入于机器学习模型中的核心组件,它使模型在处理输入数据时能够动态地为不同部分分配权重,从而更精准地聚焦于关键信息。在

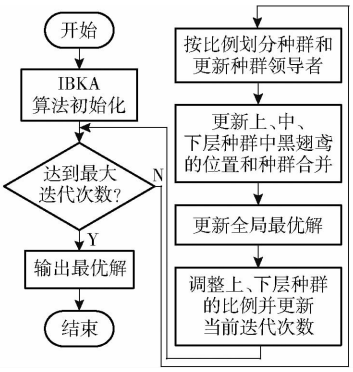

图 5　IBKA 算法流程图

Fig. 5　Flowchart of IBKA algorithm

CNN 中，这种机制尤其能够有效缓解信息过载的问题，进而增强模型性能与效率。

DD 是一种新型的机器学习算法，其设计原理类似于支持向量机和多层感知器。在 DD 中，通过 Hadamard 乘积和泰勒展开式来模拟非线性关系，与多层感知器相比，具有更快的收敛速度、更低的过拟合风险和更强的泛化能力[24]。

DD 模块计算公式为

$$\boldsymbol{A}^{l}=\boldsymbol{W}^{l,l-1}\boldsymbol{A}^{l-1}\circ\boldsymbol{X} \tag{10}$$

式中　$\boldsymbol{A}^{l-1}$、$\boldsymbol{A}^{l}$——模型输入、输出

$\boldsymbol{X}$——树突网络输入参数

$\boldsymbol{W}^{l,l-1}$——从 $l-1$ 到第 l 个模型权重矩阵

$\circ$——Hadamard 乘积符号

本研究设计的 ACNN－DD 模型如图 6 所示。CNN 网络主要设置 3 层二维卷积层、1 层池化层和注意力层。第 1、2、3 层卷积层中的卷积核尺寸均设置为 1×1，包含 64、32 和 16 个卷积核，激活函数均采用 ReLU 函数。池化层采用全局平均池化操作。DD 网络主要设置一层输入层、树突网络。树突网络中的网络层数设置为 6 层。

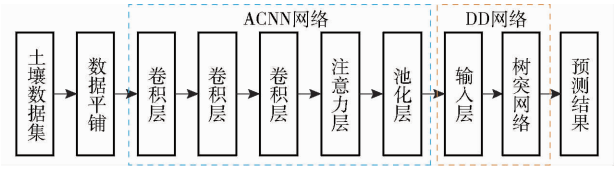

图 6　ACNN－DD 网络结构图

Fig. 6　Diagram of ACNN－DD network structure

1.7　土壤温度预测模型

建立良好的土壤温度预测模型在于如何确定 ACNN－DD 网络的最大迭代次数、初始学习率。结合 IBKA 算法搜索 ACNN－DD 网络的最优网络参数，使模型在测试集均方根误差最小，从而提高预测模型精度。IBKA－ACNN－DD 模型的学习算法具体步骤如下：

(1)划分测试集、训练集。

(2)数据集数据归一化处理。

(3)适应度函数初始化。

(4)确定 IBKA 种群大小 N_{IBKA}、问题维度 D、最大迭代次数 T 和当前迭代次数 t。

(5)初始化种群和设置上、中、下层种群比例。

(6)初始化黑翅鸢种群领导者和全局最优解。

(7)按比例将原始种群分为上层种群、中层种群和下层种群。

(8)根据式(2)更新黑翅鸢种群的领导者。

(9)根据式(3)更新上层种群中黑翅鸢位置。

(10)根据式(7)更新中层种群中黑翅鸢位置。

(11)根据式(8)更新下层种群中黑翅鸢位置。

(12)合并上、中、下层种群得到合并种群，并更新合并种群中的全局最优解。

(13)调整上下层种群黑翅鸢比例。

(14)判断 t 是否大于 T。若达不到，则跳转到步骤(8)，若达到，则进行下一步。

(15)得到全局最优解，即最优的初始学习率和最大迭代次数。

(16)运用最优的初始学习率和最大迭代次数重新训练 ACNN－DD 网络。

(17)数据反归一化得到预测结果并展示。

算法流程如图 7 所示。

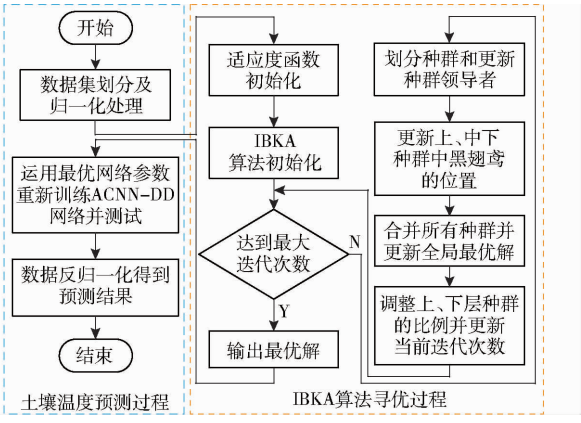

图 7　IBKA－ACNN－DD 土壤温度短期预测模型流程图

Fig. 7　Flowchart of IBKA－ACNN－DD short-term prediction model for soil temperature

1.8　预测模型评价指标

为了分析和评估模型预测性能，采用均方根误差(RMSE)、决定系数(R^2)以及平均绝对百分比误差(MAPE)作为评价标准。当均决定系数越接近 1，均方根误差和平均绝对百分比误差越接近 0，模型稳定性和精度越高[25]。

2　结果与分析

为验证 IBKA－ACNN－DD 模型的优越性以及局部特征提取和 IBKA 优化网络的必要性，进而说明该方法对预测土壤温度有明显提升和改进，分别

采用本文模型、BKA－ACNN－DD 模型、ACNN－DD 模型与 DD 模型这 4 种预测模型进行预测，考虑到算法的实时性，将优化模块中的 IBKA 和 BKA 算法的最大迭代次数设置为 20，种群数量为 30。试验结果见表 2。

表 2 消融试验结果对比

Tab. 2 Comparisons of algorithms

模型	R^2	RMSE/℃	MAPE/%
DD	0.92	1.99	6.21
ACNN－DD	0.95	1.65	5.69
BKA－ACNN－DD	0.97	1.26	4.45
IBKA－ACNN－DD	0.98	1.12	3.83

从表 2 可得，ACNN－DD 模型与 DD 模型相比，决定系数增加 0.03，均方根误差减小 0.34℃，平均绝对百分比误差减小 0.52 个百分点。这说明 ACNN 能够提升模型精度。BKA－ACNN－DD 模型与 ACNN－DD 模型相比，决定系数增加 0.02，均方根误差减小 0.39℃，平均绝对百分比误差减小 1.24 个百分点。这说明 BKA 算法能够提升模型的稳健性。IBKA－ACNN－DD 模型与 BKA－ACNN－DD 模型相比，决定系数增加 0.01，均方根误差减小 0.14℃，平均绝对百分比误差减小 0.62 个百分点，这说明 IBKA 算法能够有效避免 BKA 算法局部最优问题。

为进一步分析与评估模型预测性能，本研究使用文献[7]提出的 MLP－FFA 模型、文献[9]提出的 XGBoost－LSTM 模型、文献[10]提出的 ILSTM_Soil 模型、文献[13]提出的 SPA－GA－SVR 模型和本研究提出的模型进行土壤温度预测。所得结果详见表 3。

表 3 模型性能对比

Tab. 3 Comparisons of model performance

模型	R^2	RMSE/℃	MAPE/%
XGBoost－LSTM	0.94	1.59	5.73
SPA－GA－SVR	0.95	1.52	5.24
ILSTM_Soil	0.97	1.23	4.29
MLP－FFA	0.96	1.34	4.94
IBKA－ACNN－DD	0.98	1.12	3.83

从表 3 可以看出，IBKA－ACNN－DD 模型土壤温度预测模型表现最优，其决定系数高达 0.98，均方根误差低至 1.12℃，平均绝对百分比误差降至 3.83%。相较于 ILSTM_Soil 模型，本文提出的模型将平均绝对百分比误差降低 10.72%，均方根误差减少 8.94%，并且决定系数提升 1.03%。与 MLP－FFA 模型相比，本文模型平均绝对百分比误差减少 22.47%，均方根误差降低 16.42%，决定系数提高 1.62%。此外，与 SPA－GA－SVR 模型相比，本文模型的平均绝对百分比误差减少 26.91%，均方根误差降低 26.32%，决定系数提升 3.16%。因此，本研究提出的模型的 3 个关键指标均显著优于 ILSTM_Soil、MLP－FFA 和 SPA－GA－SVR 等传统土壤温度预测模型。

为验证土壤温度预测模型的通用性和准确性，本研究将从内蒙古奈曼农田生态系统国家野外科学观测研究站（https://nmd.cern.ac.cn/）和陕西安塞农田生态系统国家野外科学观测研究站（https://asa.cern.ac.cn/）2 个站点获取的 2019 年 1 月 1 日至 2020 年 12 月 31 日和 2020 年 1 月 1 日至 2022 年 12 月 31 日采集间隔为 1 h 1 次的 10 cm 地温数据和天气数据，分别代入 XGBoost－LSTM、SPA－GA－SVR、ILSTM_Soil、MLP－FFA 和 IBKA－ACNN－DD 模型中进行试验，最终结果详见表 4 和表 5。

表 4 内蒙古奈曼站土壤温度预测模型性能对比

Tab. 4 Comparison of performance of soil temperature prediction models at Naiman Station, Inner Mongolia

模型	R^2	RMSE/℃	MAPE/%
XGBoost－LSTM	0.94	2.19	9.61
SPA－GA－SVR	0.96	1.88	8.11
ILSTM_Soil	0.97	1.75	7.34
MLP－FFA	0.95	1.97	8.31
IBKA－ACNN－DD	0.98	1.35	5.54

表 5 陕西安塞站土壤温度预测模型性能对比

Tab. 5 Comparison of performance of soil temperature prediction models at Ansai Station, Shaanxi

模型	R^2	RMSE/℃	MAPE/%
XGBoost－LSTM	0.95	2.09	9.29
SPA－GA－SVR	0.97	1.88	8.08
ILSTM_Soil	0.98	1.61	6.85
MLP－FFA	0.96	1.98	8.51
IBKA－ACNN－DD	0.99	1.37	5.41

从表 4 可以看出，IBKA－ACNN－DD 模型土壤温度预测模型展现出了最优的预测性能，其决定系数达到 0.98，均方根误差仅为 1.35℃，平均绝对百分比误差低至 5.54%。相较于 ILSTM_Soil 模型，本文提出模型的平均绝对百分比误差减少 24.52%，均方根误差下降 22.86%，决定系数提升 0.43%。与 SPA－GA－SVR 模型对比，本文模型的平均绝对百分比误差降低 31.69%，均方根误差减少 28.19%，决定系数提高 1.76%。此外，与 MLP－FFA 模型相比，本模型平均绝对百分比误差减少 33.33%，均方根误差降低 31.47%，决定系数增加 2.83%。综上所述，本研究所提出模型的所有评估

指标均显著优于 ILSTM_Soil、SPA－GA－SVR 和 MLP－FFA 等传统的土壤温度预测模型。

由表 5 可知，IBKA－ACNN－DD 土壤温度预测模型展示出最佳的预测性能，其决定系数达到 0.99，均方根误差低至 1.37℃，平均绝对百分比误差降至 5.41%。相较于 ILSTM_Soil 模型，本文模型平均绝对百分比误差减少 21.02%，均方根误差下降 14.91%，决定系数提升 1.02%。与 SPA－GA－SVR 模型相比，本模型的平均绝对百分比误差降低 33.04%，均方根误差减少 27.13%，决定系数提高 2.06%。而与 MLP－FFA 模型比较，本文模型平均绝对百分比误差减少 36.43%，均方根误差降低 30.81%，决定系数提升 3.13%。上述结果表明，本文模型的决定系数、均方误差和平均绝对百分比误差这 3 个关键指标，全面超越了 ILSTM_Soil、SPA－GA－SVR 和 MLP－FFA 等传统土壤温度预测模型。

从重庆蔬菜基地、内蒙古奈曼站和陕西安塞站测试集中随机抽取 48 h 的数据，按本研究的设计方案进行数据预处理后，代入训练好的 IBKA－ACNN－DD、ILSTM_Soil、SPA－GA－SVR、MLP－FFA 和 XGBoost－LSTM 模型中进行预测，实际值与预测值关系如图 8 所示。

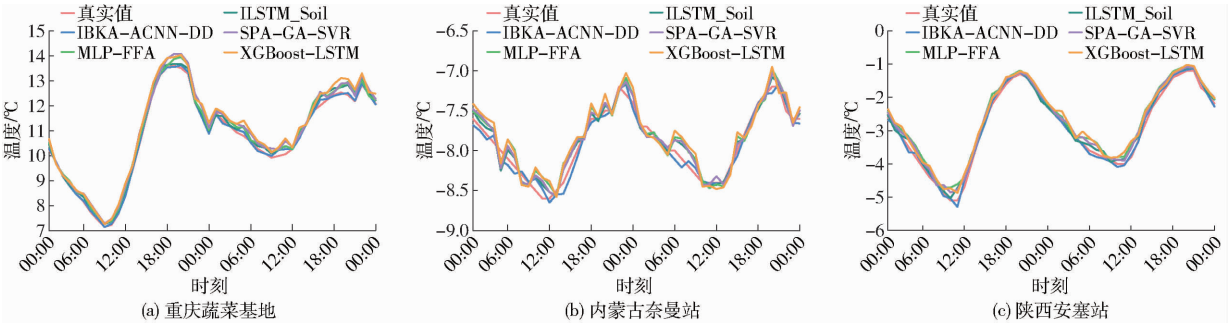

(a) 重庆蔬菜基地　(b) 内蒙古奈曼站　(c) 陕西安塞站

图 8　3 个站点 48 h 土壤温度预测结果对比

Fig. 8　Comparison of 48-hour soil temperature predictions at three sites

从图 8 可得，IBKA－ACNN－DD 模型相较于 ILSTM_Soil、SPA－GA－SVR 及 MLP－FFA 等模型，展现出了更为出色的预测性能。其曲线拟合度较高，土壤温度预测值与实际观测值之间的偏差较小。在 3 个监测站点中，重庆蔬菜基地预测精准度最高，与真实值的偏差最小；陕西安塞站和内蒙古曼谷站紧随其后，同样表现出色。这一显著差异的根源在于各地独特的气候特点。陕西省气候使得土壤温度呈现出鲜明的季节性变化，冬季温度较低，夏季则相对较高。内蒙古气候则导致土壤温度波动较大，而重庆市气候则相对温和，使得土壤温度保持在一个相对稳定的范围内。这些气候特征对土壤温度预测模型的性能产生了重要影响。

综上所述，本文所提出的预测模型不仅在预测精度上实现了显著提升，更展现出了卓越的稳定性，为土壤温度预测领域带来了一个高效且创新的新方案。

3　结束语

提出了一种 IBKA－ACNN－DD 的短期土壤温度预测模型，能够揭示未来 6 h 内土壤温度的变化规律。在训练过程中通过 IBKA 算法对 ACNN－DD 网络参数进行优化，提升模型的可靠性。利用优化后的 ACNN 网络提取土壤温度数据集的局部特征，再将提取的数据输入到优化后的 DD 网络进行土壤温度预测，提高了模型预测精度。试验结果显示，该模型在不同测试条件下均表现出色，其决定系数分别达到 0.98、0.98、0.99，均方根误差低至 1.12、1.35、1.37℃，平均绝对百分比误差降到 3.83%、5.54%、5.41%。本文提出的预测模型不仅有效提高了预测精度，而且展现了优异的稳定性，为土壤温度预测提供了一个新的高效解决方案。

参　考　文　献

[1] SHALINI O, DANIEL H, LOUIS D, et al. Evaluation of simulated soil moisture and temperature for a Canadian boreal forest [J]. Agricultural and Forest Meteorology, 2022, 323(C): 109078.

[2] LIU M. Modified monitoring system of soil temperature based on ARM[J]. Environmental Technology & Innovation, 2021, 21: 101346.

[3] TAHERI M, SCHREINER K H, MOHAMMADIAN A, et al. A review of machine learning approaches to soil temperature tstimation[J]. Sustainability, 2023, 15(9): 7677.

[4] 赵程栋，庄继晖，程晓鸣，等. 基于特征注意力机制的 RNN－Bi－LSTM 船舶轨迹预测[J]. 广东海洋大学学报，2022，42(5)：102－109.

ZHAO Chengdong, ZHUANG Jihui, CHENG Xiaoming, et al. Ship trajectory prediction of RNN - Bi - LSTM based on characteristic attention mechanism[J]. Journal of Guangdong Ocean University, 2022,42(5):102 - 109. (in Chinese)

[5] CHEN P P, LI Y, LIU X J, et al. Improving yield prediction based on spatio-temporal deep learning approaches for winter wheat: a case study in Jiangsu Province, China[J]. Computers and Electronics in Agriculture,2023,213:108201.

[6] SUJAN G,C R D, DAVID C, et al. Deep learning CNN - LSTM - MLP hybrid fusion model for feature optimizations and daily solar radiation prediction[J]. Measurement, 2022,202:111759.

[7] SAMADIANFARD S,GHORBANI M A,MOHAMMADI B. Forecasting soil temperature at multiple-depth with a hybrid artificial neural network model coupled-hybrid firefly optimizer algorithm[J]. Information Processing in Agriculture,2018,5(4): 465 - 476.

[8] YU F,CUI N,HAO W, et al. Estimation of soil temperature from meteorological data using different machine learning models [J]. Geoderma, 2019,338:67 - 77.

[9] 李清亮,蔡凯旋,耿庆田,等. 极限梯度提升和长短期记忆网络相融合的土壤温度预测[J]. 光学精密工程, 2020, 28(10):2337 - 2348.
LI Qingliang, CAI Kaixuan, GENG Qingtian, et al. Estimation of soil temperature based on XGBoost and LSTM methods[J]. Optics and Precision Engineering, 2020,28(10):2337 - 2348. (in Chinese)

[10] LI Q L,ZHU Y H, SHANGGUAN W, et al. An attention-aware LSTM model for soil moisture and soil temperature prediction [J]. Geoderma, 2022,409:115651.

[11] 连帅明,许仲林,王文栋. 阿尔泰山森林土壤温度动态变化及其预测[J]. 西北林学院学报, 2022,37(5):62 - 71.
LIAN Shuaiming, XU Zhonglin, WANG Wendong. Dynamic change and prediction of forest soil temperature in the Altai Mountain[J]. Journal of Northwest Forestry University, 2022,37(5):62 - 71. (in Chinese)

[12 DAS C L,ZHANG Z,CRABBE C J M. Optimization of data-driven soil temperature forecast-the first model in bangladesh[J]. Applied Sciences, 2023,13(23):12616.

[13] 朱成杰,汪正权. 基于 SPA - GA - SVR 模型的土壤水分及温度预测[J]. 中国农村水利水电, 2024(1):30 - 36.
ZHU Chengjie, WANG Zhengquan. Soil moisture content and temperature prediction based on SPA - GA - SVR model[J]. China Rural Water and Hydropower, 2024(1):30 - 36. (in Chinese)

[14] LI X X, ZHANG L,WANG X Y, 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.

[15] WANG J, WANG W H, HU X X, et al. Black-winged kite algorithm: a nature-inspired meta-heuristic for solving benchmark functions and engineering problems[J]. Artificial Intelligence Review, 2024,57(4):97.

[16] HU X Y,LIU W,HUO H. An intelligent network traffic prediction method based on butterworth filter and CNN - LSTM[J]. Computer Networks, 2024,240(C):110172.

[17] LU W J, LI J Z, WANG J Y, et al. A novel model for stock closing price prediction using CNN - attention - GRU - attention [J]. Economic Computation and Economic Cybernetics Studies and Research, 2022,56(3):251 - 264.

[18] LIU G, WANG J. Dendrite net: a white-box module for classification, regression, and system identification[J]. IEEE Transactions on Cybernetics, 2022, 2(12):13774 - 13787.

[19] 王鹏,方凯,汪晨,等. 基于多模态数据融合的室温预测算法研究[J]. 传感技术学报, 2023,36(7):1048 - 1054.
WANG Peng, FANG Kai, WANG Chen, et al. Research on room temperature prediction algorithm based on multimodal data fusion[J]. Chinese Journal of Sensors and Actuators, 2023,36(7):1048 - 1054. (in Chinese)

[20] 唐旺,马尚昌,李程. 基于滑动窗口的 LSTM 地温预测方法[J]. 成都理工大学学报(自然科学版), 2021,48(3):377 - 384.
TANG Wang,MA Shangchang,LI Cheng. LSTM ground temperature prediction method based on sliding window[J]. Journal of Chengdu University of Technology(Science & Technology Edition), 2021,48(3):377 - 384. (in Chinese)

[21] DENG L Y,LIU S Y. Snow ablation optimizer: a novel metaheuristic technique for numerical optimization and engineering design[J]. Expert Systems with Applications, 2023, 225(C):120069.

[22] AMIR S. WOASCALF: a new hybrid whale optimization algorithm based on sine cosine algorithm and levy flight to solve global optimization problems[J]. Advances in Engineering Software, 2022,173(C):103272.

[23] SUN C J, GAO F. A tent marine predators algorithm with estimation distribution algorithm and gaussian random walk for continuous optimization problems[J]. Computational Intelligence and Neuroscience, 2021,2021(1):7695596.

[24] 袁懿琳,赵荣焕,何坤,等. 基于随机森林和树突网络的煤镜质组反射率估计[J]. 工矿自动化, 2023, 49(8):148 - 155.
YUAN Yilin, ZHAO Ronghuan, HE Kun, et al. Estimation of coal vitrinite reflectance based on random forest and dendritic network[J]. Journal of Mine Automation, 2023, 49(8):148 - 155. (in Chinese)

[25] 胡瑾,雷文畔,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)