

DOI:10.3876/j.issn.1000-1980.2026.05.005

考虑滞后效应的机器学习模型对淮北平原土壤温度的模拟研究

王迪¹, 鞠琴¹, 莫李娟², 卢怡然³, 何亚男^{1,4}, 梅海鹏⁴, 胡永胜⁴

(1. 河海大学水灾害防御全国重点实验室; 2. 太湖流域水文水资源监测中心(太湖流域水环境监测中心);
3. 武义县水务局; 4. 安徽省(水利部淮委)水利科学研究院五道沟水文水资源实验站)

摘要: 基于淮北平原五道沟实验站2000—2024年土壤温度与气象观测数据,采用相关性函数特征(CFF)方法系统分析了气温、气压等气象因子在不同土壤深度(10、20、40、80、160、320 cm)的滞后效应,将各深度滞后处理后的气象因子作为输入,驱动卷积神经网络(CNN)模型、长短期记忆网络(LSTM)模型及CNN-LSTM模型模拟6个深度土壤温度的演变过程,并评估了3个机器学习模型在不同深度的适用性与模拟精度。结果表明:气象因子的最优滞后时间随土壤深度增加而延长,浅层(10~20 cm)土壤滞后时间最短(0~3 d);中层(40~80 cm)延长至8~29 d;深层(160~320 cm)则延长至44~89 d;3个机器学习模型的模拟效果在不同深度表现出明显的分层差异,整体上浅层优于深层;CNN-LSTM模型在各深度均表现出更高的精度与稳定性,决定系数 R^2 普遍维持在0.94以上,优于单一模型;在320 cm深层土壤中,CNN-LSTM模型的 R^2 为0.941,较LSTM模型提升17%,较CNN模型提升45%,体现了卷积特征提取与时序记忆能力耦合的优势。

关键词: 土壤温度;气象因子;滞后效应;机器学习;CNN-LSTM模型;五道沟水文水资源实验站
中图分类号: S152.8 **文献标志码:** A **文章编号:** 1000-1980(2026)05-0039-10

Simulation of soil temperature in the Huaibei Plain using machine learning models considering lag effects

Wang Di¹, Ju Qin¹, Mo Lijuan², Lu Yiran³, He Ya'nan^{1,4}, Mei Haipeng⁴, Hu Yongsheng⁴

(1. State Key Laboratory of Water Disaster Prevention, Hohai University;
2. Taihu Basin Hydrology and Water Resources Monitoring Center (Taihu Basin Water Environment Monitoring Center);
3. Wuyi County Bureau of Water Resources;
4. Wudaogou Hydrology and Water Resources Experimental Station, Water Resources Research Institute of Anhui Province)

Abstract: Based on the soil temperature and meteorological observation data from the Wudaogou Experimental Station in the Huaibei Plain from 2000 to 2024, the correlation function feature (CFF) method was adopted to systematically analyze the lag effects of meteorological factors, such as air temperature and air pressure, at different soil depths (10, 20, 40, 80, 160, and 320 cm). Using the lag-processed meteorological factors at each depth as inputs, the convolutional neural network (CNN), long short-term memory (LSTM), and CNN-LSTM models were driven to simulate the evolution processes of soil temperature at the six depths, and the applicability and accuracy of the three machine learning models at different depths were evaluated. The results indicate that the optimal lag time of meteorological factors increases with the increase of soil depth. The lag time of shallow soil (10-20 cm) is the shortest (0-3 d); the lag time of middle soil (40-80 cm) is 8-29 d; the lag time of deep soil (160-320 cm) extends to 44-89 d. The simulation performance of the three machine learning models exhibits clear stratified differences at different depths, with the shallow layer generally outperforming the deep layer. The CNN-LSTM model demonstrates higher accuracy and stability at all depths, and its coefficient of determination (R^2) is generally maintained above 0.94, outperforming the single models. In the deep soil of 320 cm, the R^2 of the CNN-LSTM model is 0.941, which improves by 17% compared with the LSTM model and 45% compared with the CNN model. This reflects the advantages of coupling convolutional feature extraction with temporal memory capability.

Key words: soil temperature; meteorological factor; lag effect; machine learning; CNN-LSTM model; the Wudaogou Hydrology and Water Resources Experimental Station

基金项目: 国家自然科学基金项目(52279018);安徽省(水利部淮委)水利科学研究院青年科技创新计划项目(KY202307);江苏省大学生创新创业项目(X2026102940117)

作者简介: 王迪(2002—),男,硕士研究生,主要从事水文物理规律模拟及水文预报研究。E-mail:241301010112@hhu.edu.cn

通信作者: 鞠琴(1980—),女,副教授,博士,主要从事气候变化下水文响应研究。E-mail:juqin@hhu.edu.cn

土壤温度是多学科研究中的重要参数,反映土壤与环境的能量交换,影响土壤的物理、化学和生化过程。随着全球气温上升,温度变化对生态系统、农业生产和人类健康的影响日益加剧,土壤温度研究变得至关重要。根据联合国政府间气候变化专门委员会(IPCC)第六次评估报告,2011—2020 年全球地表气温比工业化前高出 1.09℃,而海洋表面温度升高 0.88℃,人类活动影响是主要原因^[1]。世界气象组织(WMO)指出,2014—2023 年为最热 10 a,2023 年成为 1850 年以来最热的一年,全球温度比工业化前偏高 1.45℃^[2]。在全球气候变化和极端高温频发的背景下,研究土壤温度与气候间的作用机制及提高模拟精度对农业和气候研究具有重要意义。

目前,常用的土壤温度模拟模型主要有物理过程驱动模型和数据驱动模型。物理过程驱动模型通过能量守恒定律及土壤热传导方程描述土壤温度传导机制,方程参数通常由观测或试验计算得到,具有物理意义。Hu 等^[3]提出了一种改进土壤温度热传导方程边界条件的热传导模型并应用于唐古拉观测点。Duc 等^[4]提出了一个应用衰减函数,考虑传热机制影响的非饱和土体导热函数(TCF)模型,并检验了其在黏土中的预测有效性。与物理过程驱动模型相比,数据驱动模型计算结构简单,参数需求少,善于从大量水文观测数据中提取潜在规律及隐含信息。随着计算能力的不断提升,该类模型日益受到研究者的广泛关注。数据驱动模型又可分为统计模型和机器学习模型,统计模型通过建立时间序列或多元回归方程实现,机器学习模型通过训练数据集挖掘提取数据信息并调整模型参数^[5]。深度学习具有更为复杂的神经网络结构,可对数据特征进行自动提取,如卷积神经网络(CNN)、循环神经网络及长短期记忆网络(LSTM)等,在水文变量预报方面应用效果较好。例如:Wang 等^[6]基于卫星遥感数据利用 CNN 计算地表温度;张观山等^[7]将 LSTM 与注意力机制结合构建 LSTM-AT 模型预测温室空气温度;Feng 等^[8]采用 ELM、GRNN、BPNN 和 RF 算法对黄土高原浅层土壤的半小时和逐日温度进行了预测;Zhang 等^[9]将经验模态分解方法与 LSTM 组合用于预测洞庭湖流域的地表温度,发现耦合模型在温度预测中更具优势;朱成杰等^[10]利用 SPA-GA-SVR 模型预测土壤水分及温度;徐俊杰等^[11]采用 6 种机器学习算法对西藏那曲土壤剖面温度进行模拟预测,发现 RBF 神经网络模型最优。

气象因子对土壤温度的影响并非即时发生,而是存在一定的时间延迟。地表气温的变化对土壤温度的影响通常需要经过土壤的热传导才能逐渐显现出来,而这一过程可能会持续数小时或数天。土壤温度的滞后效应与土壤的热储存和传导特性、表面植被的蒸散作用等因素密切相关。土壤温度与气温有正相关关系,较气温变化缓慢^[12-14],并且随着土层深度的增加,温度变化的延迟越来越明显^[15]。然而,目前有关土壤温度模拟方面的研究,较少考虑土壤温度相对于气象因子的滞后效应,探索其滞后效应及其在不同的机器学习模型中的应用有待进一步深入研究。

淮北平原位于中国南北气候过渡带,是中国重要的商品粮基地。本文基于淮北平原五道沟水文水资源实验站 2000—2024 年的实测土壤温度数据及气象数据,分析土壤温度的主要影响因素,采用相关性函数特征(CFF)方法优选各气象因子在土壤深度(0、10、20、40、80、160、320 cm)的最优滞后时间,构建 CNN、LSTM 和卷积长短期记忆网络(CNN-LSTM)3 个模型,用滞后处理的气象因子作为模型输入,优选出模拟精度相对较好的模型,旨在为淮北平原精准农业发展和气候变化适应策略制定提供有效工具支撑。

1 研究区概况和研究方法

1.1 研究区概况及数据来源

淮北平原地处黄淮海平原南侧,安徽省北部(32°25'N~34°35' N,114°55'E~118°10' E),处于南北方过渡带和冷暖气团交锋地带,年均降水量为 901.6 mm,年均气温 15.01℃,汛期 6—9 月降水量占全年总量的 62%左右。研究区域总面积为 3.74 万 km²,农田耕地面积达 3 206.5 万亩(1 km²=1 500 亩),占安徽省总耕地面积的 47.8%,是安徽省面积最大、人口最多的农业区,也是中国重要的粮食生产基地之一。本文使用的各深度土壤温度数据及气象数据来自淮北平原的五道沟水文水资源实验站,该实验站位于安徽省淮北地区南部蚌埠市北 25 km 的固镇县新马桥原种场境内,站内采用人工气象观测与高精度气象观测两种观测方式,两者均可以获取不同深度的土壤温度,土壤温度观测深度依次为 0、10、20、40、80、160、320 cm,于每日 8:00、14:00 和 20:00 观测。观测时间为 2000—2024 年,标准气象场的气象因子观测包括气温、地表温度、绝对湿度、水汽压力差和饱和差等,与土壤温度观测同步进行。本文将实测数据按时间顺序划分为训练集和测试

集,其中前 80%(2000 年 1 月 1 日至 2020 年 12 月 31 日)作为训练集用于模型训练,后 20%(2021 年 1 月 1 日至 2024 年 12 月 31 日)作为测试集用于检验模型的预测精度与泛化能力。

1.2 研究方法

本文采用 CFF 方法对气象因子的滞后效应进行处理,以优选各输入因子的最佳滞后时间。在此基础上,分别构建 CNN 模型、LSTM 模型以及 CNN-LSTM 模型 3 个机器学习模型用于土壤温度模拟。

1.2.1 相关性函数特征方法

CFF 方法常用于气象、水文和环境预测建模中,用来确定输入因子(如气温、湿度、降水等要素)与目标变量(例如土壤温度等)的相关性随时间滞后的变化情况。该方法通过计算目标变量与候选气象因子在不同滞后时间下的相关系数,揭示因子对目标变量的响应延迟效应,并确定最优滞后时间。

本文基于气温、水汽压力差、饱和差、地表温度和绝对湿度 5 个气象因子的原始序列分别构建 0~120 d 的滞后序列,将每一滞后版本的因子序列与对应土壤温度序列进行配对,剔除因滞后引入的缺失数据后,计算其与土壤温度的皮尔逊相关系数。最终根据皮尔逊相关系数的最大值确定最优滞后时间。通过该过程识别各因子在不同深度对土壤温度的响应延迟特性,为后续构建土壤温度模拟模型提供参数依据。

1.2.2 CNN 模型

CNN 模型是一种专用于处理具有网格结构数据(如图像、气象数据)的深度学习模型^[16-17]。其核心结构包括卷积层、池化层和全连接层。卷积层通过滑动卷积核提取局部特征,利用局部连接和参数共享减少计算量,提升模型效率。池化层(如最大池化或平均池化)进一步压缩数据,保留关键特征并降低维度^[18-19]。CNN 模型通过多层堆叠实现从低级到高级特征的抽象,最终由全连接层整合全局信息并输出模拟结果。凭借强大的特征提取能力,CNN 模型在计算机视觉和多源气象数据建模中表现优异,尤其擅长处理高维时空数据^[20]。

1.2.3 LSTM 模型

LSTM 模型是为解决传统循环神经网络(RNN)的长期依赖问题而设计的时序模型。其核心是带有门控机制的记忆单元,包括输入门、遗忘门和输出门。遗忘门决定历史信息的保留程度,输入门筛选当前输入的重要特征,输出门控制信息的传递^[21]。通过细胞状态,LSTM 能稳定保存和更新长期依赖关系,避免梯度消失或爆炸,其强大的信息存储与更新能力在面对复杂的时序数据时,表现出了独特的优势^[22-24]。

1.2.4 CNN-LSTM 模型

CNN-LSTM 模型结合了 CNN 模型的空间特征提取能力和 LSTM 模型的时序建模优势,既能降低高维数据的复杂度,又能捕捉长期动态变化,适用于多维时间序列预测^[25]。CNN 模块通过卷积和池化操作压缩输入数据并提取空间特征,全连接层将特征转换为 LSTM 适配的格式。LSTM 模块则利用门控机制学习时序依赖关系,通过全连接层最终输出预测模拟结果^[26]。CNN 模型、LSTM 模型和 CNN-LSTM 模型结构如图 1 所示。

本文模型以最大最小归一化处理后的时间序列为输入,首先通过序列折叠层将其转化为二维结构,并在卷积模块中依次采用二维卷积、批量归一化、ELU 激活函数与平均池化操作,实现局部空间特征的提取与压缩。卷积特征经由序列展开和展平层重新恢复为序列形式,输入至包含 32 个和 8 个隐藏单元的双层堆叠 LSTM 网络,以捕捉时间维度上的深层次依赖关系。卷积层与 LSTM 层通过卷积特征序列化后输入 LSTM 的方式实现耦合,其中 CNN 负责在每个时间步上提取局部模式,LSTM 则进一步学习跨时间步的动态变化。通过空间特征提取与时序依赖建模的有机结合提升预测精度。为提升模型的泛化能力与稳定性,网络在全连接层中引入 0.25 的 Dropout,结合 L2 正则化与梯度裁剪,同时采用 Adam 优化器进行 500 轮训练,并设置分段式学习率衰减策略。各机器学习模型的关键参数配置见表 1。

1.3 评价指标

为对比分析 3 个模型在淮北平原五道沟水文水资源实验站土壤温度模拟中的表现,本文选用决定系数(R^2)、平均偏差误差(MBE)、平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)作为评价指标^[27]。 R^2 越接近 1 表示模型拟合效果越好,越接近 0 表示模型解释能力较弱。MBE 反映了模型是否存在系统性的预测误差,为正表示模型预测偏大,为负则表示模型预测偏小。MAE 反映了模型预测的准确程度,值越小,说明模型模拟结果与实际值的差异越小。RMSE 能够量化预测误差的大小,值越小,表示模型的预测误差越小。MAPE 反映了模型在各个预测点上的相对误差,尤其适用于比较不同数据集的预测




图 1 CNN、LSTM 和 CNN-LSTM 模型结构示意图
Fig. 1 Schematic diagram of structures of CNN, LSTM, and CNN-LSTM models

表 1 机器学习模型参数					
Table 1 Machine learning model parameters					
类别	参数	设置值或说明	类别	参数	设置值或说明
通用参数	最大训练周期	500	CNN 参数	卷积层数	2
	批次大小	64		卷积核大小	[2,1],[3,1]
	优化器	Adam		卷积核个数	8,16
	初始学习率	0.01		步长	1
	学习率下降因子	0.2		填充方式	same
	学习率下降周期	400		池化层类型	平均池化
	正则化系数	1×10^{-3}		池化核大小	2x1
	Dropout 比例	0.25	LSTM 参数	LSTM 层数	2
	梯度阈值	1		隐藏节点数	32,8

效果,值越小表示模型在预测时的相对误差越小^[28]。

2 结果与分析

2.1 滞后效应分析

基于五道沟水文水资源实验站 2000—2024 年土壤温度和气象观测资料,揭示气象因子对土壤温度的滞后响应规律,确定土壤温度相对于各气象因子的最优滞后时间,为后续基于机器学习算法的预测建模提供合适的输入变量。

2.1.1 不同深度土壤温度变化规律分析

土壤温度观测布设于 0、10、20、40、80、160、320 cm 共 7 个深度,每日于 8:00、14:00 和 20:00 进行 3 次测定,以三者的算术平均值作为当日土壤温度。由图 2(a)可知,所有深度的土壤温度均呈现显著的季节性波动,全年波动的相位一致但振幅不同。不同深度的温度变化幅度存在显著差异,土壤表层(0 cm)温度波动最剧烈,全年温差为 30.1℃,320 cm 深度土壤温度稳定在 15℃附近,波动幅度为 6.6℃。当表层土壤吸收到达地面的太阳辐射升温时,热量向下传播,下层土壤吸热升温,随着土壤深度增加,能量通量减少,出现振幅阻尼现象。表层土壤温度最高值出现在 7 月,随深度增加,土壤温度的峰现时间逐渐延后,在 320 cm 处土壤温

度峰值出现在 10 月,相较于表层滞后 3 个月。土壤中热量传播及气象作用需要时间,因此不同深度土壤到达温度循环周期同一相位的时间相较于表层土壤有所延迟,即时间滞后现象,随着深度增加,现象更加明显。

由图 2(b)可知,冬季和早春,土壤温度随深度增加而显著升高,深层土壤在此期间温度明显高于表层,表现出冬季温度高、夏季温度低的季节性分布特征。夏季由于表层土壤直接接受太阳辐射并受气温、蒸发等气象因子的影响,其温度显著高于深层。这种季节性温度极值的滞后现象,主要由于气象因子作用于表层土壤的热传导速度较慢,热量逐层向下传递的过程导致深层土壤对外部气象变化的响应具有一定延迟性。表层至深层的热量传输主导了温度振幅的衰减与相位的滞后。




图 2 土壤温度变化曲线
Fig. 2 Variation curves of soil temperature

2.1.2 气象因子与土壤温度变化对比分析

由图 3 可知,气象因子与土壤温度均表现出明显的周期性波动特征,在波动相位上,浅层土壤对气象因子的响应较为迅速,温度曲线与气象因子变化曲线波动相位相似,波峰波谷出现时间接近。随着土壤深度的增加,土壤温度的波峰出现时间滞后。深层土壤中温度变化幅度减小,其最高温度常常出现在气象因子峰值若干天之后,进一步体现出土壤对气候信号的时滞效应。对于土壤温度建模预测而言,准确识别这种滞后关系至关重要。




图 3 2021—2024 年气象因子与不同深度土壤温度 15 d 滑动平均值对比
Fig. 3 Comparison between meteorological factors and 15-day moving averages of soil temperature at different depths during 2021-2024

2.1.3 最优滞后时间的确定

为明确各气象因子对土壤温度的滞后响应关系,本文采用 CFF 方法,基于 2000—2024 年的观测数据系统分析气温、地表温度、绝对湿度、水汽压力差和饱和差等气象因子与不同深度土壤温度之间的关系。

CFF 方法计算出的不同深度的气象因子做 0~120 d 滞后处理后与土壤温度的皮尔逊相关系数如图 4 所示。浅层土壤温度受气象因子影响较直接,滞后效应较小,深层土壤温度存在强时滞性,滞后处理补偿了气象因子对土壤温度的延迟响应时间,滞后处理的气象因子与土壤温度的相关性得到显著提升。不同气象因子的最优滞后时间分布规律各异,但普遍存在浅层最优滞后时间短、深层最优滞后时间长的规律。经过滞后处理,气温、地表温度和绝对湿度与各深度土壤温度的最优相关系数均达到 0.90 以上。在 320 cm 深度,水汽压力差的相关系数由滞后处理前的 0.11 提升至 0.75,饱和差则由 0.05 提升至 0.56。气象因子与土壤温度之间的时序相关性经滞后处理得到了提升。




图4 滞后处理的气象因子与各深度土壤温度的相关系数热图

Fig. 4 Heat map of correlation coefficients between lag-processed meteorological factors and soil temperature at each depth

由图5可知(图中误差棒表示95%置信区间),地表温度在浅层土壤中的最优滞后时间最短,通常在3d以内,而在深层(如160cm及以下)则显著延后,最优滞后时达50~80d。所有的气象因子都呈现随土壤深度增加,最优滞后时间也增加的趋势,反映深层土壤中存在气象因子响应时间延迟效应。这一结果与Zhang等^[29]分析1958—2010年澳大利亚140个站点的土壤温度滞后响应的研究结果相符。




图5 气象因子在不同土壤深度的最优滞后时间分布

Fig. 5 Distribution of optimal lag time of meteorological factors at different soil depths

不同气象因子的滞后效应表现出一定差异,浅层土壤(10、20cm)中,所有气象因子的最优滞后时间均集中在0~3d。其中,地表温度与10cm土壤温度的最优滞后时间为0d,显示出二者变化几乎同步;饱和差的滞后时间稍大,为2~3d,可能与土壤水分向大气界面的传输过程有关。在中层(40、80cm),滞后时间显著延长,最优滞后时间普遍为8~29d。以地表温度为例,其在40cm深度的最优滞后时间为16d,在80cm深度延长至29d,反映出热量由表层传导至中层所需的时间周期约为两周至1月,显示出较强的热扩散时滞。对于深层土壤(160、320cm),滞后时间达到高峰。各因子的最优滞后时间普遍超过40d,最大可达89d。此结果说明气象因子对深层土壤温度的影响需经历更长的传播与缓冲过程,体现出深层土壤系统的热惯性特性和低频响应特征。

2.2 机器学习模型对土壤温度的模拟效果对比

由表2可知,3个模型的 R^2 均为浅层高,深层低。相关性方面,CNN-LSTM模型在所有深度的土壤中均表现优异,预测效果最好。在10~20cm浅层土壤中,CNN、LSTM和CNN-LSTM模型的预测精度较为接近, R^2 均大于0.88。但随着土壤深度的增加,CNN-LSTM模型的优势逐渐显现,3个模型在80cm深度模拟的 R^2

差值扩大至 0.2,预测精度差异增大。在 160 cm 深度,CNN-LSTM 模型的 R^2 为 0.979,相较于 LSTM 模型的 0.868 提升 13%,较 CNN 模型的 0.714 提升 37%,在 320 cm 深度的土壤中,CNN 模型表现最差, R^2 降低至 0.65,CNN-LSTM 模型相较于 CNN 和 LSTM 模型的相关系数分别提升 45%和 17%,表明耦合模型在深层土壤温度预测中具有一定的优势,在 80~320 cm 的中深层土壤中 CNN-LSTM 模型的 R^2 均为最高值,明显高于 CNN 模型和 LSTM 模型。

表 2 各模型不同深度土壤测试集预测评价指标
Table 2 Prediction evaluation metrics of each model on test set at different soil depths

土壤深度/cm	模型	R^2	MAE/℃	MBE/℃	RMSE/℃	MAPE/%
10	CNN	0.938	1.910	-1.593	2.323	0.185
	LSTM	0.961	1.457	0.476	1.847	0.181
	CNN-LSTM	0.962	1.405	-0.010	1.823	0.155
20	CNN	0.891	2.293	0.639	2.847	0.197
	LSTM	0.953	1.502	-0.606	1.871	0.141
	CNN-LSTM	0.974	1.096	0.089	1.360	0.090
40	CNN	0.884	2.081	-0.609	2.537	0.155
	LSTM	0.946	1.400	0.276	1.728	0.113
	CNN-LSTM	0.977	0.821	0.153	1.118	0.065
80	CNN	0.775	2.458	-0.935	2.955	0.155
	LSTM	0.888	1.719	-0.778	2.079	0.098
	CNN-LSTM	0.976	0.756	0.061	0.983	0.048
160	CNN	0.714	1.924	-0.089	2.355	0.115
	LSTM	0.868	1.820	1.378	2.257	0.102
	CNN-LSTM	0.979	0.672	0.267	0.877	0.044
320	CNN	0.650	1.209	-0.040	1.443	0.070
	LSTM	0.807	0.814	-0.593	1.045	0.046
	CNN-LSTM	0.941	0.509	0.452	0.589	0.029

误差评价中,CNN-LSTM 模型综合表现最好,其在 10~20 cm 浅层的表现优异,在 10 cm 处其 MAE、RMSE、MAPE 分别为 1.405℃、1.823℃、0.155%,且 MBE 小于 0.01℃接近无偏,LSTM 和 CNN-LSTM 模型的表现接近,MAE 与 RMSE 数值接近,均优于 CNN 模型;40~80 cm 中层,CNN-LSTM 模型的 MAE 为 0.789℃,较 LSTM 和 CNN 模型分别降低 49%和 65%,MAPE 降至 0.057%,偏差控制 MBE 为 0.107℃,优于其他模型;在 160~320 cm 深层,CNN 和 LSTM 模型稳定性下降,且普遍存在预测值低估问题,CNN-LSTM 模型在 160 cm 的平均绝对误差 MAE 仅为 CNN 模型的 35%,MAPE 低至 0.044%,平均偏差误差 MBE 为 0.267℃轻微可控,深层表现优于两个单一模型。

由图 6、图 7 可知,3 个模型大致符合实际土壤温度的变化趋势,测试集的结果要略优于训练集,各模型在浅层土壤的预测大致相同,随土壤深度增加,CNN 和 LSTM 模型在模拟土壤温度时,模拟偏差主要体现在峰谷值,波峰和波谷与实际曲线产生较大误差,在深层土壤中更明显。CNN-LSTM 模型预测土壤温度曲线变化趋势与实际土壤温度变化基本吻合,甚至在某些时段内与土壤温度观测值曲线重合;在预测曲线上其预测值的波动性较小,表现出更高的平滑度和稳定性,在时间序列上不同深度的曲线拟合度均高于 LSTM 和 CNN 模型。

2.3 讨论

土壤温度在不同深度呈现出典型的时空变化特征。浅层土壤温度与地表气温同步性较强,受大气辐射和降水等外界因素的直接影响,表现出显著的季节变化。然而,随着深度增加,土壤温度的波动幅度逐渐减小,且存在明显的时间滞后现象。在夏季地表气温已经达到最高值的情况下,深层土壤往往需要经过数周甚至几个月才逐渐达到峰值。这种现象是由于热量在土壤中传导过程缓慢,且深层土壤热容量较大,对外界气候波动的响应延迟显著。土壤温度在年尺度上的变化趋势近似于正弦曲线,波动平稳且规律性较强。浅层温度曲线起伏明显,而深层则呈现出“低频滤波”特征,即高频的短期扰动逐渐被削弱,仅保留长期平滑的变化。这一结果与江西省^[30]的研究相吻合。本研究中所揭示的滞后效应,符合土壤热力学过程的基本规律。

CNN 模型虽然擅长提取局部空间特征,但缺乏对时序滞后关系的刻画能力,因此在深层预测中表现最差, R^2 从 10 cm 的 0.938 降至 320 cm 的 0.650。LSTM 模型依靠其记忆机制能够在一定程度上保留气象因子




图 6 不同土壤深度训练集土壤温度预测结果对比

Fig. 6 Comparison of prediction results of soil temperature at different soil depths on training set




图 7 不同土壤深度测试集土壤温度预测结果对比

Fig. 7 Comparison of prediction results of soil temperature at different depths on test set

的历史信息,从而减轻滞后效应带来的精度损失,预测性能更为稳健。而融合了 CNN 与 LSTM 优势的 CNN-LSTM 模型在不同深度均能保持较高的拟合水平,在 320 cm 深度时 R^2 仍高达 0.941,显示出优异的稳定性与适应性。CNN 和 LSTM 的结合不仅能处理空间特征,也能高效捕捉时间依赖性,这种融合模型能够在不同土壤深度上保持更好的泛化能力^[31]。土壤温度序列是多种周期性信号的叠加,对于较浅的土壤,空间特征的作用较大,CNN 能有效地从输入数据中提取这些信息,而随着土壤深度的增加,时间依赖性变得愈加重要,

LSTM 能够在这些深层次的数据中维持较好的预测效果。传统模型在深层土壤温度预测中的表现欠佳,使用耦合模型可以达到分别处理不同信号的目的,减少单一模型的系统误差和不确定性,更高效地处理数据间的非线性关系以提高模拟精度。

本文主要聚焦于气象因子对土壤温度的作用,而土壤类型、植被覆盖和土壤湿度等下垫面因素对土壤温度也具有重要的调控作用,不同质地的土壤在导热率和比热容上存在差异,砂质土壤温度变化更快,植被覆盖通过能量收支和蒸散作用影响地表传热过程,而土壤湿度则决定了热容量和传导性能,湿润条件下土壤对气候波动的响应更为迟滞。后期将结合更多的下垫面因素构建更综合的评价因子开展土壤温度的模拟预测研究,以提高模型的区域适用性和解释力。

3 结 论

a. 五道沟水文水资源实验站土壤温度呈显著季节性波动,表层温度波动剧烈、全年温差大,而深层温度变化平稳、振幅小。浅层土壤对气象变化反应迅速,深层土壤则响应滞后,表现出“冬季暖、夏季冷”的季节性热分布特征,同时显示出深层土壤良好的热稳定性和明显的热惯性效应。体现了土壤温度与气象条件的密切关联性。

b. 浅层土壤温度滞后气象因子时间集中于 0~3 d,中层 8~29 d,而深层则可延长至 44~89 d。不同因子的滞后效应差异显著,地表温度和气温在深层中的最佳滞后时间最长,水汽压力差和绝对湿度的最佳滞后时间相对较短,表现出差异化的时间响应特征。

c. CNN-LSTM 模型整体表现最优。在浅层,CNN、LSTM 和 CNN-LSTM 模型均能获得较高精度,但在深层,模型表现差异明显,CNN-LSTM 模型在 320 cm 深度的 R^2 达 0.941,高于 LSTM 模型的 0.807 和 CNN 的 0.650,同时其 MAE 较 CNN 模型降低约 58%。CNN-LSTM 模型对深层缓变特征拟合能力更强,尤其在面对高滞后输入条件时,能够保持稳定输出,在不同深度的时间序列拟合中展现出更高的平滑度与稳定性。

参考文献:

[1] 赵宗慈,罗勇,黄建斌. 全球气候指标、气候影响驱动因子与全球变暖[J]. 气候变化研究进展,2024,20(3):384-388. (Zhao Zongci,Luo Yong,Huang Jianbin. Global climate indicators, climatic-impact drivers and global warming[J]. Climate Change Research,2024,20(3):384-388. (in Chinese))

[2] 鞠琴,高慧滨,王国庆,等. 基于能量平衡原理的潜在蒸散发模型构建[J]. 水科学进展,2022,33(5):794-804. (Ju Qin,Gao Huibin,Wang Guoqing,et al. Modeling potential evapotranspiration based on energy balance[J]. Advances in Water Science,2022,33(5):794-804. (in Chinese))

[3] Hu Guojie,Zhao Lin,Wu Xiaodong,et al. An analytical model for estimating soil temperature profiles on the Qinghai-Tibet Plateau of China[J]. Journal of Arid Land,2016,8(2):232-240.

[4] Duc C T,Thota S K,Vahedifard F,et al. A temperature-dependent model for thermal conductivity function of unsaturated soils [M]. Reston:American Society of Civil Engineers,2021.

[5] 冯钧,邵萍萍,张继茹,等. 物理引导数据驱动方法研究综述及其在水文模型构建中的应用与展望[J]. 河海大学学报(自然科学版),2025,53(5):1-9. (Feng Jun,Shao Pingping,Zhang Jiru,et al. Research review of physics-guided data-driven methods and their application and prospects in hydrological model development[J]. Journal of Hohai University (Natural Sciences),2025,53(5):1-9. (in Chinese))

[6] Wang Shaofei,Zhou Ji,Lei Tianjie,et al. Estimating land surface temperature from satellite passive microwave observations with the traditional neural network,deep belief network,and convolutional neural network[J]. Remote Sensing,2020,12(17):2691.

[7] 张观山,丁小明,何芬,等. 基于 LSTM-AT 的温室空气温度预测模型构建[J]. 农业工程学报,2024,40(18):194-201. (Zhang Guanshan,Ding Xiaoming,He Fen,et al. Predicting greenhouse air temperature using LSTM-AT[J]. Transactions of the Chinese Society of Agricultural Engineering,2024,40(18):194-201. (in Chinese))

[8] Feng Yu,Cui Ningbo,Hao Weiping,et al. Estimation of soil temperature from meteorological data using different machine learning models[J]. Geoderma,2019,338:67-77.

[9] Zhang Xike,Zhang Qiuwen,Zhang Gui,et al. A novel hybrid data-driven model for daily land surface temperature forecasting using long short-term memory neural network based on ensemble empirical mode decomposition[J]. International Journal of Environmental Research and Public Health,2018,15(5):1032.

- [10] 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))
- [11] 徐俊杰,于一雷,杨丽虎,等. 六种机器学习算法对西藏那曲草甸土土壤剖面温度的模拟效果对比[J]. 中国农业气象, 2025, 46(6): 781-795. (Xu Junjie, Yu Yilei, Yang Lihu, et al. Comparative simulation of six machine learning algorithms on soil profile temperature in Naqu, Xizang[J]. Chinese Journal of Agrometeorology, 2025, 46(6): 781-795. (in Chinese))
- [12] 谭晓晴,罗斯琼,舒乐乐,等. 基于机器学习的土壤温度预估研究综述[J]. 高原气象, 2022, 41(2): 268-281. (Tan Xiaoping, Luo Siqiong, Shu Lele, et al. A review of soil temperature estimation research based on machine learning[J]. Plateau Meteorology, 2022, 41(2): 268-281. (in Chinese))
- [13] 杨晓霞,贾嵩,张承明,等. 一种基于神经网络的土壤湿度预测方法[J]. 江苏农业科学, 2018, 46(10): 232-236. (Yang Xiaoxia, Jia Song, Zhang Chengming, et al. A soil moisture prediction algorithm based on artificial neural network[J]. Jiangsu Agricultural Sciences, 2018, 46(10): 232-236. (in Chinese))
- [14] 秦红灵,高旺盛,李春阳. 北方农牧交错带免耕对农田耕层土壤温度的影响[J]. 农业工程学报, 2007, 23(1): 40-47. (Qin Hongling, Gao Wangsheng, Li Chunyang. Impacts of no-tillage on soil temperature of field in Ecotone of North China[J]. Transactions of the CSAE, 2007, 23(1): 40-47. (in Chinese))
- [15] 张燕,张振华,姚付启,等. 土壤温度相对于气象因子的滞后效应分析[J]. 农业现代化研究, 2008, 29(4): 468-470. (Zhang Yan, Zhang Zhenhua, Yao Fuqi, et al. Analysis on time lag effect of soil temperature compared to meteorological factors[J]. Research of Agricultural Modernization, 2008, 29(4): 468-470. (in Chinese))
- [16] Kala S, Jose B R, Mathew J, et al. High-performance CNN accelerator on FPGA using unified Winograd-GEMM architecture[J]. IEEE Transactions on Very Large Scale Integration (VLSI) Systems, 2019, 27(12): 2816-2828.
- [17] 刘永伟,王文,刘元波,等. 水文模型模拟预报的多源数据同化方法及应用研究进展[J]. 河海大学学报(自然科学版), 2021, 49(6): 483-491. (Liu Yongwei, Wang Wen, Liu Yuanbo, et al. Advances in multi-source data assimilation approach and application in simulation and forecast of hydrological model[J]. Journal of Hohai University (Natural Sciences), 2021, 49(6): 483-491. (in Chinese))
- [18] Ruan Diwang, Wang Jin, Yan Jianping, et al. CNN parameter design based on fault signal analysis and its application in bearing fault diagnosis[J]. Advanced Engineering Informatics, 2023, 55: 101877.
- [19] 刘东,姜宸一,张亮亮,等. 基于 GA-CNN 的农业旱灾恢复力及影响因素[J]. 南水北调与水利科技(中英文), 2024, 22(4): 672-683. (Liu Dong, Jiang Chenyi, Zhang Liangliang, et al. Agricultural drought resilience and influencing factors based on optimized convolutional neural network of genetic algorithm[J]. South-to-North Water Transfers and Water Science & Technology, 2024, 22(4): 672-683. (in Chinese))
- [20] Kotaridis I, Lazaridou M. Cnns in land cover mapping with remote sensing imagery: a review and meta-analysis[J]. International Journal of Remote Sensing, 2023, 44(19): 5896-5935.
- [21] 鞠琴,吴金雨,王兴平,等. 机器学习算法在降水和气温多模式集成中的应用[J]. 水资源保护, 2024, 40(3): 106-115. (Ju Qin, Wu Jinyu, Wang Xingping, et al. Application of machine learning algorithms in multimodal integration of precipitation and temperature[J]. Water Resources Protection, 2024, 40(3): 106-115. (in Chinese))
- [22] 周涛,李成林,殷峻暹,等. 改进的多层 LSTM 深圳道路积水大数据预测模型[J]. 南水北调与水利科技(中英文), 2025, 23(1): 66-71. (Zhou Tao, Li Chenglin, Yin Junxian, et al. Big data-driven waterlogging prediction model based on improved multi-layer LSTM in Shenzhen[J]. South-to-North Water Transfers and Water Science & Technology, 2025, 23(1): 66-71. (in Chinese))
- [23] Lees T, Buechel M, Anderson B, et al. Benchmarking data-driven rainfall-runoff models in Great Britain: a comparison of long short-term memory (LSTM)-based models with four lumped conceptual models[J]. Hydrology and Earth System Sciences, 2021, 25(10): 5517-5534.
- [24] 郭明辰,张润润,闻余华. 基于 PSO-LSTM 模型的平原河网汛期水位预测[J]. 水利水电科技进展, 2024, 44(6): 64-70. (Guo Mingchen, Zhang Runrun, Wen Yuhua. Prediction of water level of plain river network during flood season based on PSO-LSTM model[J]. Advances in Science and Technology of Water Resources, 2024, 44(6): 64-70. (in Chinese))
- [25] Hou Jingwei, Wang Yanjuan, Zhou Ji, et al. Prediction of hourly air temperature based on CNN-LSTM[J]. Geomatics, Natural Hazards and Risk, 2022, 13(1): 1962-1986.

Sen, Qian Li, Hu Maodi, et al. Review of research progress on question-answering techniques based on large language models[J]. Data Analysis and Knowledge Discovery, 2024, 8(6): 16-29. (in Chinese))

[25] Li Binglei, Liu Tong, Ma Jian, et al. Evolving chain-of-thought and automatic text annotation based intent classification method for wireless network[J]. Computer Networks, 2025, 259: 111074.

[26] 刘畅成, 桑磊, 李炜, 等. 大语言模型驱动的多元关系知识图谱补全方法[J]. 计算机科学, 2025, 52(1): 94-101. (Liu Changcheng, Sang Lei, Li Wei, et al. Large language model driven multi-relational knowledge graph completion method[J]. Computer Science, 2025, 52(1): 94-101. (in Chinese))

[27] Zhang Minling, Li Yukun, Liu Xuying, et al. Binary relevance for multi-label learning: an overview[J]. Frontiers of Computer Science, 2018, 12(2): 191-202.

[28] Lavalley M P. Logistic regression[J]. Circulation, 2008, 117(18): 2395-2399.

[29] 张才科, 李小龙, 郑胜, 等. 基于大语言模型的知识图谱构建及应用研究[J]. 计算机科学与探索, 2024, 18(10): 2656-2667. (Zhang Caike, Li Xiaolong, Zheng Sheng, et al. Research on construction and application of knowledge graph based on large language model[J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(10): 2656-2667. (in Chinese))

[30] Wang Yu, Ye Feng, Li Binqun, et al. UrbanFloodKG: an urban flood knowledge graph system for risk assessment[C]// Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. Birmingham: ACM, 2023: 2574-2584.

[31] Butucea C, Ndaoud M, Stepanova N A, et al. Variable selection with Hamming loss[J]. The Annals of Statistics, 2018, 46(5): 1837-1875.

[32] Zhang Minling, Zhou Zhihua. ML-KNN: a lazy learning approach to multi-label learning[J]. Pattern Recognition, 2007, 40(7): 2038-2048.

(收稿日期: 2025-07-04 编辑: 刘晓艳)

(上接第 48 页)

[26] Elmaz F, Eyckerman R, Casteels W, et al. CNN-LSTM architecture for predictive indoor temperature modeling[J]. Building and Environment, 2021, 206: 108327.

[27] Ishida K, Ercan A, Nagasato T, et al. Use of one-dimensional CNN for input data size reduction in LSTM for improved computational efficiency and accuracy in hourly rainfall-runoff modeling[J]. Journal of Environmental Management, 2024, 359: 120931.

[28] 黄克威, 王根绪, 宋春林, 等. 基于 LSTM 的青藏高原冻土区典型小流域径流模拟及预测[J]. 冰川冻土, 2021, 43(4): 1144-1156. (Huang Kewei, Wang Genxu, Song Chunlin, et al. Runoff simulation and prediction of a typical small watershed in permafrost region of the Qinghai-Tibet Plateau based on LSTM[J]. Journal of Glaciology and Geocryology, 2021, 43(4): 1144-1156. (in Chinese))

[29] Zhang Tianpeng, Huang J C, Lei Qiuliang, et al. Empirical estimation of soil temperature and its controlling factors in Australia: implication for interaction between geographic setting and air temperature[J]. CATENA, 2022, 208: 105696.

[30] 蔡哲, 段里成, 郭瑞鸽, 等. 江西省土壤温度变化特征及其与气象要素的关系[J]. 中国农学通报, 2024, 40(4): 118-125. (Cai Zhe, Duan Licheng, Guo Ruige, et al. Characteristics of soil temperature variation in Jiangxi province and its relationship with meteorological elements[J]. Chinese Agricultural Science Bulletin, 2024, 40(4): 118-125. (in Chinese))

[31] 刘娣, 孙佳倩, 余钟波. 基于机器学习模型的多层土壤湿度反演[J]. 河海大学学报(自然科学版), 2024, 52(3): 7-14. (Liu Di, Sun Jiaqian, Yu Zhongbo. Multi-layer soil moisture inversion based on machine learning models[J]. Journal of Hohai University (Natural Sciences), 2024, 52(3): 7-14. (in Chinese))

(收稿日期: 2025-09-06 编辑: 刘晓艳)