

# 基于改进粒子群优化的LSTM土壤温湿度预测模型研究

付锦山, 王丹\*

北华大学计算机科学技术学院, 吉林 吉林

收稿日期: 2026年4月15日; 录用日期: 2026年5月13日; 发布日期: 2026年5月25日

## 摘要

随着全球气候变化加剧与粮食安全需求增长, 农业生产向精细化、智能化转型成为必然趋势。土壤温湿度作为直接影响作物生长、水资源利用及温室气体排放的关键环境变量, 其精准预测是实施智慧农业管理决策的核心依据。但其面临多因素耦合、非线性强、时空异质性显著等挑战。为提高预测准确性以支持灌溉优化、产量预估与灾害预警, 文章聚焦深度学习技术在土壤环境预测中的应用, 融合智能优化算法对土壤温湿度预测方法展开深入研究, 针对传统长短期记忆网络超参数依赖经验设定、模型性能受限的问题, 提出一种基于改进粒子群优化算法的LSTM超参数自适应整定方法(OPT-PSO-LSTM)。首先, 构建包含气象、时间、土壤属性等多源特征的东北地区专用数据集并进行标准化处理; 其次, 利用粒子群算法的全局寻优能力, 以验证集损失最小化为目标, 对LSTM的关键超参数进行自动化搜索与优化。实验结果表明, 该方法在寻优效率与效果上均表现优异。具体而言, OPT-PSO-LSTM获得最佳验证损失0.1638, 显著优于网格搜索(0.1704)、随机搜索(0.1741)、遗传算法(0.1646)和粒子群算法(0.1693), 其收敛过程也快速稳定。优化后的模型在测试集上取得土壤温度预测 $R^2 = 0.8304$ 、土壤湿度预测 $R^2 = 0.7565$ 的可靠性能, 有效提升预测精度, 为构建适用于区域农业气象的鲁棒预测模型奠定自适应的参数基础。

## 关键词

土壤温湿度预测, 长短期记忆网络, 粒子群优化, 智慧农业

## Research on LSTM Soil Temperature and Humidity Prediction Model Based on Optimized Particle Swarm Optimization Attention Mechanism

Jinshan Fu, Dan Wang\*

\*通讯作者。

文章引用: 付锦山, 王丹. 基于改进粒子群优化的 LSTM 土壤温湿度预测模型研究[J]. 计算机科学与应用, 2026, 16(5): 139-152. DOI: 10.12677/csa.2026.165171

## Abstract

With the intensification of global climate change and the increasing demand for food security, the transformation of agricultural production towards precision and intelligence has become an inevitable trend. Soil temperature and humidity, as key environmental variables that directly affect crop growth, water resource utilization, and greenhouse gas emissions, require precise prediction to support the implementation of smart agricultural management decisions. However, the precise prediction of soil temperature and humidity faces challenges such as multi-factor coupling, strong non-linearity, and significant spatial heterogeneity. To improve the prediction accuracy and support irrigation optimization, yield estimation, and disaster warning, this paper focuses on the application of deep learning technology in soil environment prediction, integrates intelligent optimization algorithms to conduct in-depth research on the prediction method of soil temperature and humidity, and addresses the problems of traditional long short-term memory networks' reliance on empirical settings for hyperparameters and limited model performance by proposing an LSTM hyperparameter adaptive tuning method based on improved particle swarm optimization algorithm (OPT-PSO-LSTM). First, a dedicated dataset for Northeast China, containing multiple source features such as meteorology, time, and soil properties, is constructed and standardized. Secondly, using the global optimization ability of the particle swarm algorithm, with the goal of minimizing the loss in the validation set, the key hyperparameters of LSTM are automatically searched and optimized. Experimental results show that this method performs exceptionally well in terms of optimization efficiency and effectiveness. Specifically, OPT-PSO-LSTM achieves the best validation loss of 0.1638, significantly outperforming grid search (0.1704), random search (0.1741), genetic algorithm (0.1646), and particle swarm algorithm (0.1693). Its convergence process is also fast and stable. The optimized model achieves reliable performance on the test set, with a soil temperature prediction  $R^2$  of 0.8304 and a soil humidity prediction  $R^2$  of 0.7565, effectively improving the prediction accuracy and laying an adaptive parameter foundation for building a robust predictive model applicable to regional agricultural meteorology.

## Keywords

Soil Temperature and Humidity Prediction, Long Short-Term Memory Network, Particle Swarm Optimization, Intelligent Agriculture

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

### 1.1. 研究背景与意义

土壤温湿度是影响农业生产的核心环境因子, 共同构成作物生长的“地下小气候”。土壤水分作为作物吸收水分的唯一来源, 直接参与光合作用、养分运输等关键生理过程[1]。水分不足会引发干旱胁迫, 导致气孔关闭、光合作用停滞; 水分过多则造成涝渍胁迫, 引起根系缺氧腐烂。土壤温度深刻影响种子

发芽、根系生长和微生物活性,大部分作物根系在  $10^{\circ}\text{C}\sim 12^{\circ}\text{C}$  以上才开始活跃生长。此外,土壤湿度控制养分迁移,养分必须溶解于土壤水中才能被根系吸收;土壤温度驱动养分转化,调控微生物对养分的矿化过程[2]。在东北地区,春季土壤墒情直接决定播种质量和出苗率,而秋季土壤湿度过高会影响机械收获,导致粮食损失[3]。

智能预测需具备多目标协同优化能力,能够模拟管理措施的连锁效应,支持权衡分析与风险预估。随着传感器、遥感等技术普及,农业领域产生海量多源数据,智能预测需具备强大的时序数据融合与外推能力,应用深度学习等先进方法挖掘时空模式,将原始数据转化为决策洞察[4]。

## 1.2. 国内外研究现状

### 1.2.1. 土壤温湿度预测方法研究进展

国外在土壤温湿度预测领域的研究起步较早,技术相对成熟。国外学者在土壤湿度观测计划、遥感反演和模式模拟等方面开展大量工作,推动土壤湿度数据的高时空分辨率获取和应用。例如,全球土壤湿度网络(ISMN)的建立,为全球范围内的土壤湿度数据共享和模型验证提供重要平台。该网络通过严格的质量控制流程,将不同来源的观测数据转换为统一单位,其数据集在气候变化研究中得到广泛应用[4]。

#### 1) 国外研究现状

在国外,多篇研究将 LSTM 与 GRU、传统 RNN、CNN、Transformer 以及经典机器学习模型进行对比:

与其他神经网络对比:对于时序网络,混合模型往往优于单一模型。例如,结合多特征注意力机制的 LSTM 可进一步提升短时预报性能。标准 LSTM 及其双向结构(Bi-LSTM)被广泛用于捕捉土壤环境变量的时序依赖关系[5]。为提升模型性能,研究者们主要从两个方向进行改进:一是引入注意力机制,以增强模型对关键时间步或特征维度的聚焦能力,如时间注意力、特征注意力及自注意力机制(SAM)的应用[6]。

从国外的发展趋势和研究现状来看,在技术趋势上,国外研究正朝着更高精度、更高可靠性的方向发展,先进算法的结合将进一步提升系统的预测精度和抗干扰能力。

#### 2) 国内研究现状

近年来,随着农业现代化进程的加快,国内学者在土壤温湿度预测领域取得显著进展。研究重点逐渐从传统的统计模型和物理机理模型转向深度学习等先进的数据驱动方法。例如,“集群平均采样策略”(CAS)方法,通过无监督聚类技术将全球土壤湿度数据按土壤类型、地形等特点分组,确保模型均衡学习各类数据特性,显著提升预测准确度,尤其在干旱区和极地地区效果显著[7]。不同研究中也使用多种数据源和区域场景。Huang [5]等在中国区域使用 ERA5-Land 与土壤性质、地表覆盖、DEM 等静态数据,构建 LSTM 模型预测土壤含水量。ERA5-Land、ERA5 等再分析数据集包含高分辨率的土壤水分、气象等信息,可作为训练数据或背景场景[5]。

### 1.2.2. 优化算法在深度学习中的应用

优化算法是驱动深度学习模型从初始状态收敛至高性能解决方案的核心引擎,其应用贯穿模型训练与架构优化全流程。在模型训练中,基于梯度的一阶优化算法是绝对主力。从经典的随机梯度下降,到引入动量概念的 Momentum [8],再到自适应调节学习率的 AdaGrad、RMSProp 以及目前广泛使用的 Adam,其发展始终围绕加速收敛、逃离局部最优和稳定训练过程展开[9]。这些算法通过巧妙设计参数更新策略,在复杂的深度网络损失地形中寻找最优路径。

在超参数优化层面,自动化与智能化成为趋势。网格搜索与随机搜索效率低下,促使贝叶斯优化、进化算法等黑盒优化方法被用于高效探索学习率、网络层数等超参数组合[10]。研究中使用的粒子群优化算法正属于此类,它通过模拟群体智能,能在连续参数空间中为 LSTM 等复杂网络寻找到更优的超参数

配置, 有效提升模型预测性能[8]。

总之, 优化算法的进步是深度学习得以处理更复杂任务、训练更庞大模型的基础[9]。将 PSO 算法与深度学习模型相结合, 正是利用智能化方法突破手动调参瓶颈, 从而提升模型在土壤温湿度预测这一复杂时序任务中性能的典型实践。

### 1.3. 论文研究内容

基于传统 LSTM 模型在土壤温湿度预测中超参数优化依赖经验、难以有效捕捉多物理机制耦合作用的问题, 本文开展 PSO 优化融合的改进研究, 并构建适用于东北地区的预测模型。具体内容如下:

提出一种基于改进粒子群优化算法的 LSTM 超参数自适应整定方(OPT-PSO-LSTM): 针对 LSTM 超参数人工调优效率低、易陷入局部最优的问题, 设计一种分层优化框架。首先, 构建包含学习率、隐藏单元数、丢弃率等关键超参数的搜索空间, 采用粒子群优化算法进行全局寻优。在优化过程中, 引入动态惯性权重调整策略, 前期设置较大权重(0.9)增强全局探索能力, 后期逐步减小至 0.4 以提高局部精细搜索效率。其次, 设计基于验证集损失的适应度函数, 通过早停机制避免过拟合。针对超参数间的约束关系(如层数与丢弃率的关联), 采用自适应边界处理机制, 对违反约束的粒子进行智能修复而非简单抛弃。最后, 通过对比网格搜索、随机搜索等基准方法, 在东北地区数据集上验证 OPT-PSO-LSTM 的优化效率, 优化后的模型在测试集上取得土壤温度预测  $R^2 = 0.8304$ 、土壤湿度预测  $R^2 = 0.7565$  的可靠性能, 有效提升预测精度。

## 2. 相关理论基础

本章阐述与研究相关的基础理论及所使用的关键技术方法。首先, 介绍相关的基础理论主要包括土壤水热运移原理、深度学习模型的基本理论以及优化算法的数学基础。其次, 对将要用到的关键技术方法进行详细阐述, 主要包括长短期记忆网络、注意力机制以及粒子群优化算法的原理与实现。以上内容均为后续模型的改进和实际应用提供坚实的理论基础和技术支撑。

### 2.1. 深度学习理论基础

长短期记忆网络是一种特殊的循环神经网络, 通过引入门控机制有效解决长期依赖问题。其核心结构包含输入门、遗忘门和输出门三个关键组件[10]。

遗忘门控制历史信息的保留程度, 其计算式为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

输入门决定新信息的更新程度:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

输出门控制当前状态的输出:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3)$$

这种门控机制使 LSTM 能够有效捕捉时间序列中的长期依赖关系, 特别适合土壤温湿度这类具有明显时序特征的数据建模。

### 2.2. 优化理论基础

粒子群优化算法是一种模拟鸟群或鱼群社会性行为的群体智能优化算法[11]。其核心原理是: 一个由多个“粒子”组成的群体, 通过在解空间中协同飞行与信息共享, 共同寻找最优解。

每个粒子代表问题的一个潜在解, 在 D 维解空间中具有位置和速度两个属性。位置对应一组具体的

参数值(如在本研究中, 是 LSTM 的单元数、学习率等超参数组合), 速度决定粒子下一步的搜索方向和距离。算法为每个粒子定义一个适应度函数(在本研究中, 通常是模型在验证集上的损失), 用以评价其位置的好坏。

优化过程始于随机初始化粒子群的位置与速度。随后, 在迭代中, 每个粒子根据两条关键信息更新自身状态: 其一是自身在飞行史上找到的个体历史最优位置, 代表其个人经验; 其二是整个群体目前找到的全局历史最优位置, 代表集体智慧[12]。粒子的速度更新公式综合这三部分: 惯性(保持原运动趋势)、认知(向自身历史最佳学习)和社会(向群体历史最佳学习)。其位置则根据更新后的速度进行移动。

每个粒子根据个体最优和群体最优更新自身位置和速度:

$$v_i^{t+1} = wv_i^t + c_1r_1(pbest_i - x_i^t) + c_2r_2(gbest - x_i^t) \quad (4)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (5)$$

其中,  $w$  为惯性权重,  $c_1$ 、 $c_2$  为学习因子,  $r_1$ 、 $r_2$  为随机数。PSO 算法具有全局搜索能力强、收敛速度快的特点。

通过这种个体经验与群体智慧结合的协同搜索机制, 粒子群能高效地探索复杂的高维参数空间, 并逐渐收敛至全局最优解或优质解区域[13]。在本研究中, 应用 PSO 自动搜索 LSTM 超参数, 正是为克服手动调参的盲目性与高成本, 让模型能自主发现更优的配置, 从而提升土壤温湿度预测的性能上限。

### 2.3. 预测模型评价指标

预测模型评价指标是量化模型性能、比较不同模型的客观标准, 需从多个维度综合评估[14]。回归预测任务常用的核心指标主要包括以下几类:

1) 误差指标: 直接衡量预测值与真实值之间的差距。

均方根误差: 为 MSE 的平方根, 与预测目标具有相同量纲, 更直观。常用于评估预测的“典型”误差幅度。

平均绝对误差: 计算误差绝对值的平均, 对大误差的敏感性低于 MSE, 解释性更强, 能直接反映预测的平均偏差量。

2) 拟合优度指标: 衡量模型解释数据变异的比例。

决定系数: 表示模型预测值能解释目标变量总方差的比例, 是衡量模型整体拟合优度的核心指标, 其值越接近 1 越好[15]。

为全面评估模型性能, 本文采用多维度评价指标体系。均方根误差(RMSE)和平均绝对误差(MAE)用于衡量预测精度:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

决定系数( $R^2$ )用于评估模型拟合优度:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

在本研究的土壤温湿度预测中, 这些指标为后续模型优化效果评估提供完整的度量标准。

### 3. 基于改进粒子群优化的 LSTM 超参数整定方法(OPT-PSO-LSTM)

#### 3.1. 介绍

传统 LSTM 模型在土壤温湿度预测应用中面临超参数敏感性强和人工调优效率低的双重挑战。首先, LSTM 网络包含隐藏层单元数、网络层数、丢弃率、学习率等多达 7~10 个关键超参数, 且这些参数之间存在复杂的耦合关系。经验表明, 仅学习率一个参数的调整就可能使模型性能波动 15%~20%, 而手工调参通常需要数百次试验才能获得相对满意的结果[16]。其次, 现有的自动化超参数优化方法仍存局限。网格搜索虽全面但计算成本高昂, 当超参数数量为  $n$ , 每个参数取  $m$  个值时, 搜索空间达  $m^n$  规模。随机搜索效率有所提升, 但缺乏方向性指导, 收敛速度慢。贝叶斯优化虽样本效率高, 但对高维问题(超参数  $> 10$ )效果下降, 且实现复杂[17]。更为关键的是, 土壤温湿度预测具有明显的时序特性和物理约束, 传统优化方法难以融入领域知识。例如, 土壤温度变化具有周期性规律, 需要 LSTM 具备较强的长期记忆能力; 而土壤湿度受多因素瞬时影响, 需要模型能快速响应特征变化。这种差异化需求要求超参数优化过程能够自适应调整搜索策略[18]。

基于此, 本章提出一种面向土壤温湿度预测任务的、基于改进粒子群优化的 LSTM 超参数整定方法(OPT-PSO-LSTM)。该方法旨在将领域问题特征与优化算法设计紧密结合, 通过设计混合编码方案以适应 LSTM 参数类型, 构建融合验证损失与模型复杂度的适应度函数以契合应用目标, 并实现自适应搜索策略以引导算法在专属的、有物理意义的超参数空间中高效寻优, 从而为后续构建高性能预测模型奠定坚实的基础。

#### 3.2. OPT-PSO-LSTM 算法

基于 3.1 节介绍的改进动机, 本章提出 OPT-PSO-LSTM 算法, 其核心思想是将 LSTM 超参数优化建模为一个黑箱优化问题, 通过粒子群算法在连续空间中进行高效搜索。算法整体框架包含四个主要模块: 超参数编码、适应度评估、粒子更新和收敛判断。算法流程图实现如图 1 所示:

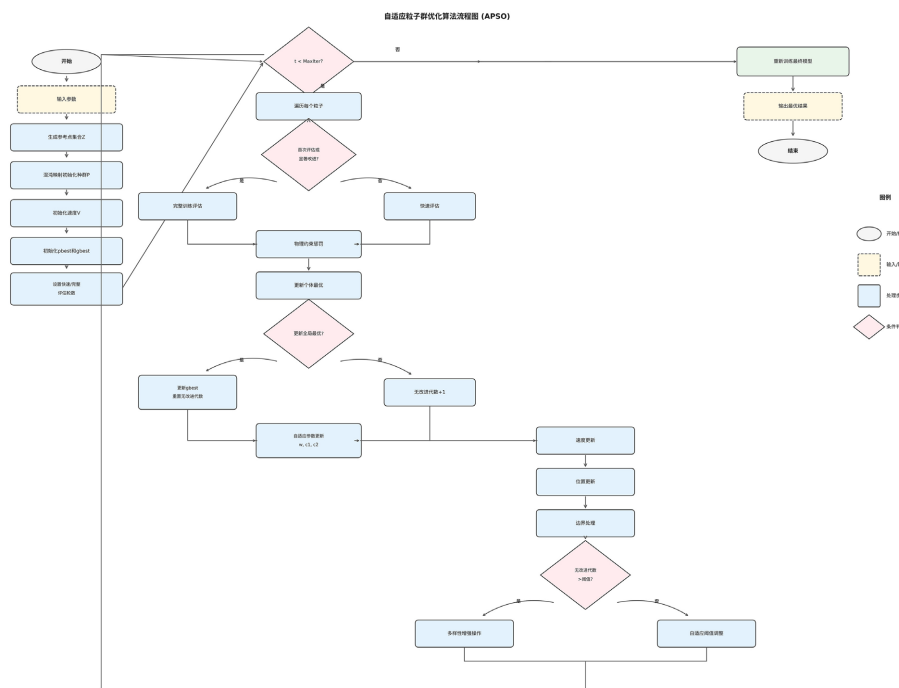


Figure 1. Algorithm flow chart  
图 1. 算法流程图

### 3.2.1. 长短期记忆网络(LSTM)

针对 LSTM 超参数的混合类型特性(连续型、离散型、类别型), 设计分类型编码方案: 连续型超参数(学习率、丢弃率)采用实数编码:

$$\text{learning rate} \in [1e^{-4}, 1e^{-2}] \quad (\text{对数均匀采样}) \quad (9)$$

$$\text{dropout rate} \in [0.1, 0.5] \quad (\text{均匀采样}) \quad (10)$$

离散型超参数(层数、单元数)采用整数编码:

$$\text{lstm\_units} \in [64, 256] \quad (\text{步长为 32 的整数}) \quad (11)$$

$$\text{num\_layers} \in [1, 3] \quad (\text{整数}) \quad (12)$$

类别型超参数(优化器类型)采用 one-hot 编码:

$$\text{optimizer} \in \{\text{Adam}, \text{RMSprop}, \text{SGD}\} \quad (13)$$

### 3.2.2. 适应度函数设计

本研究设计的适应度函数综合考量预测精度与模型复杂度双重目标, 旨在获得既准确又简洁的 LSTM 模型配置。函数设计采用多组件融合架构, 主要包含三个关键部分: 模型性能评估、复杂度惩罚项以及综合适应度计算。在模型性能评估阶段, 首先根据当前超参数组合构建 LSTM 网络架构, 随后采用带早停机制的精简训练流程(最大训练轮数设为 50, 早停耐心值为 5), 以验证集上的最小损失作为模型精度的量化指标。这一设计既保证评估效率, 又有效防止过拟合现象。复杂度惩罚项的设计体现对模型简洁性的追求, 通过参数数量惩罚和层数惩罚两个维度实现。参数数量惩罚与 LSTM 单元数和网络层数成正比, 其计算方式为单元数与层数的乘积除以 1000, 这一归一化处理确保惩罚量级的合理性。层数惩罚则直接与网络深度线性相关, 每增加一层带来 0.01 的惩罚增量。两者加权组合后, 形成完整的复杂度惩罚项, 其中权重系数 0.1 经过大量实验验证, 能够在精度与复杂度间取得最佳平衡。

### 3.2.3. 自适应参数调整策略

标准 PSO 的固定参数难以适应优化过程不同阶段的需求。本文提出自适应参数调整策略, 使算法在早期注重全局探索, 后期注重局部开发。

自适应惯性权重: 自适应惯性权重  $w$  控制粒子保持先前速度的倾向性。采用非线性递减策略:

$$w(t) = w_{\min} + (w_{\max} - w_{\min}) \times \left(1 - \frac{t}{T_{\max}}\right)^{\alpha} + \beta \times \frac{\text{无改进代数}}{\text{最大停滞代数}} \quad (14)$$

其中,  $\alpha$  控制递减曲线形状(通常取 2),  $\beta$  为停滞惩罚系数。当算法长时间无改进时, 增加  $w$  以增强探索能力。

自适应学习因子: 个体学习因子  $c_1$  和社会学习因子  $c_2$  分别控制粒子向个体最优和全局最优移动的倾向。采用动态调整策略:

$$c_1(t) = c_{1,final} + (c_{1,init} - c_{1,final}) \times \left(1 - \frac{t}{T_{\max}}\right) \quad (15)$$

$$c_2(t) = c_{2,init} + (c_{2,final} - c_{2,init}) \times \frac{t}{T_{\max}} \quad (16)$$

### 3.2.4. 多样性增强策略

为防止算法早熟收敛, 引入多种多样性增强策略:

混沌扰动: 当种群多样性低于阈值时, 对部分粒子进行混沌扰动[19]。

子群重组: 将种群分为多个子群独立进化, 定期交换信息[20]。

精英引导变异: 基于全局最优解引导变异方向[21]。

### 3.3. 实验分析

#### 3.3.1. 数据描述

本研究中的“土壤监测数据”主要指用作基准真值的高质量、经过验证的再分析数据, 而非单点原位测量。其主要来源是 ERA5-Land 地表再分析数据集, 该数据集在土地应用方面表现出比其他模型输出、遥感及再分析产品更高的准确性。

数据集包含关键土壤属性的垂直分层信息, 特别是土壤水分和土壤温度。其中土壤水分提供四个垂直层的数据(层 1: 0~7 厘米, 层 2: 7~28 厘米, 层 3: 28~100 厘米, 层 4: 100~289 厘米), 土壤温度也对应相同的四个层次。这些数据可以对模型土壤水热动态垂直变化的模拟能力进行有效验证。此外, 数据集包含地表感热通量、潜热通量、径流等与土壤状况密切相关的陆地表面变量, 共同构成评估模型性能的综合指标集。

为丰富数据集的空间属性信息, LandBench1.0 整合多种源自遥感的静态生理属性数据。这些数据描述不随时间变化或缓慢变化的下垫面特征, 对于理解地表空间异质性、改进预测模型十分重要。

核心的遥感数据产品包括: 来自 SoilGrids 的土壤质地数据(沙土、黏土、粉土含量), 以及叶面积指数(LAI)、植被类型和土壤持水能力等。这些静态变量与动态的气象强迫数据相结合, 为模型提供刻画土壤-植被-大气相互作用的背景场。例如, 土壤质地影响着水分的入渗和保持, 而植被类型和叶面积指数关系到冠层截留和蒸散发的空间差异, 这些都是精准预测土壤温湿度的关键背景信息。

LandBench1.0 遵循 FAIR(可发现、可获取、可互操作、可重用)原则, 在数据质量控制上实施严格规范的处理流程。一是对原始数据进行时空重采样, 采用双线性插值法将所有数据统一至四种标准分辨率(0.5°, 1°, 2°, 4°), 确保数据在空间上的可比较性和模型输入的便利性。针对静态数据(如土壤纹理)缺失值问题, 利用 `scipy.interpolate` 等工具进行插值填补, 确保数据的空间连续性。

核心策略基于时间顺序分割, 避免未来信息泄露到训练过程中。

时间顺序划分比例: 训练集(60%)、验证集(20%)、测试集(20%)。

时间范围:

训练集: 2011 年 1 月 1 日~2016 年 12 月 31 日(6 年)。

验证集: 2016 年 1 月 1 日~2018 年 12 月 31 日(3 年)。

测试集: 2019 年 1 月 1 日~2020 年 12 月 31 日(2 年)。

空间网络划分: 全球网格系统(按经纬度将地球表面分为规则网架来划定空间独立性, 以保证训练集、验证集和测试集在空间上不重叠, 防止空间自相关导致评估偏差)。

1) 0.5°分辨率: 360 × 720 网格点。

2) 1°分辨率: 180 × 360 网格点。

3) 2°分辨率: 90 × 180 网格点。

4) 4°分辨率: 45 × 90 网格点。

#### 3.3.2. 缺失值处理策略

在代码实现中, 缺失值处理采用分层策略。首先通过 `pd.isnull().sum()` 进行缺失值统计, 识别缺失模式。对于时间序列数据, 优先使用 `fillna(method='ffill')` 进行前向填充, 保持时间连续性。当连续缺失较长时, 采用 `scipy.interpolate` 的样条插值进行局部拟合。对于静态空间数据(如土壤质地), 使用 `griddata` 进行

空间插值填补空白区域。所有处理过程记录缺失位置和填补方法, 确保可追溯性。

### 3.3.3. 时序数据对齐分析

构建统一时间索引作为对齐基准, 使用 `pd.to_datetime()` 统一时间格式。多源数据通过 `pd.merge_asof()` 设置合理容差范围进行最近时间匹配。不同频率数据采用 `resample().interpolate()` 进行重采样, 高频到低频使用均值聚合, 低频到高频使用样条插值。最终检查时间轴连续性, 确保无重复或缺失时间戳。

### 3.3.4. 特征工程体系构建

多源特征集合构建采用分层设计理念, 将特征划分为基础层、衍生层和聚合层[22]。基础层包含原始观测数据(土壤温湿度、气象要素), 衍生层通过数学变换生成新特征, 聚合层则通过时间窗口统计捕捉序列模式。

程序实现采用模块化设计, 每个特征类型对应独立的计算方法。时间特征通过 `pd.DatetimeIndex` 提取小时、月份等组件, 并进行正弦余弦编码以保持周期性。滞后特征使用 `pd.shift()` 函数生成历史时间步特征, 移动统计特征通过 `rolling().mean()` 等窗口函数计算。

特征交互基于协同效应理论, 捕捉变量间的非线性关系[23]。程序实现采用显式交互项生成方法, 通过特征相乘、比值等运算创建组合特征。对于土壤温湿度预测, 重点构建温度-湿度、温度-辐射等物理意义明确的交互项。非线性变换应用标度变换理论, 对偏态分布特征进行对数变换改善分布形态。多项式特征通过 `sklearn.preprocessing.PolynomialFeatures` 生成, 捕捉变量间的曲线关系。基于领域知识的定制变换(如热力学公式推导的特征)则通过自定义函数实现。

### 3.3.5. 数据分析

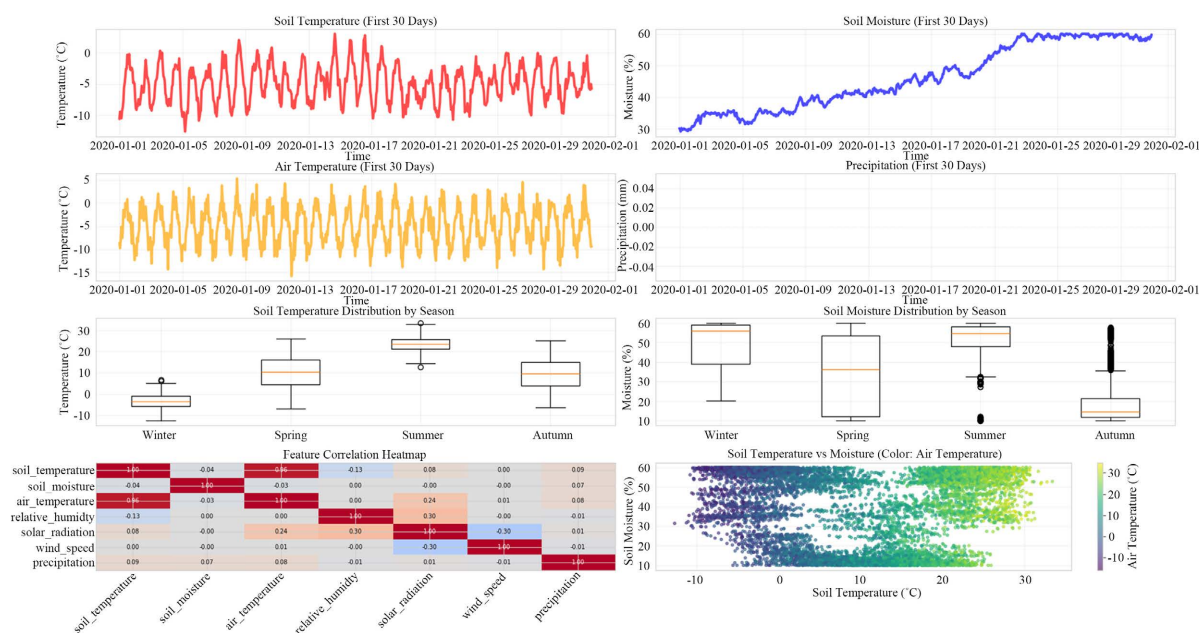


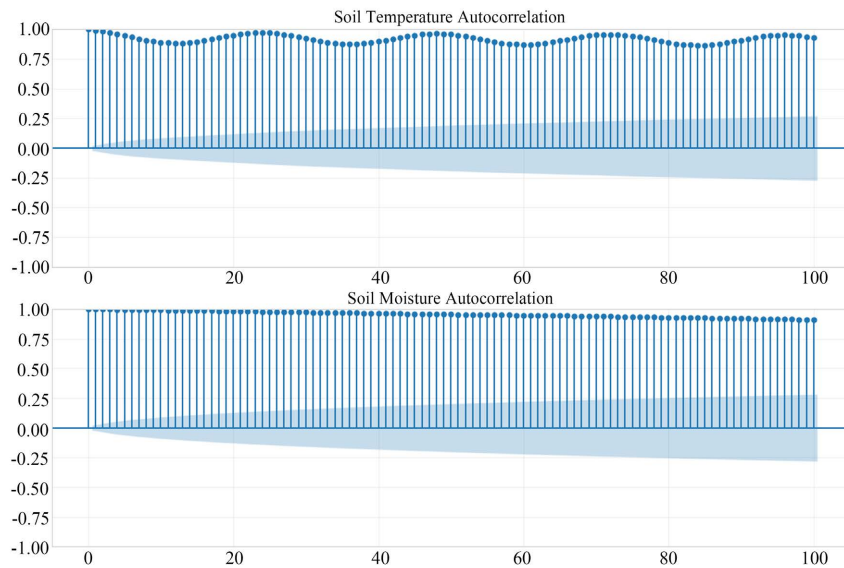
Figure 2. 2020 soil data analysis chart

图 2. 2020 年土壤数据分析图

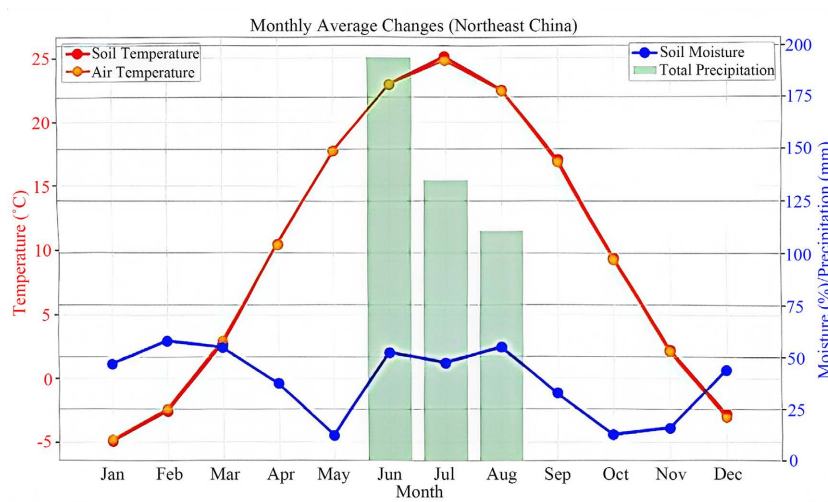
如图 2 所示, 东北地区数据呈现出多层次的时空变化特征。其中, 2020 年 1 月前 30 天数据显示, 土壤温度在  $-10^{\circ}\text{C}$ ~ $5^{\circ}\text{C}$  区间波动, 土壤湿度由 30% 上升至 60% 左右, 空气温度于  $-15^{\circ}\text{C}$  到  $5^{\circ}\text{C}$  之间同步变化, 期间降水量几乎为零, 构成了冬季低温少雨背景下特殊的土壤水热动态。四季土壤温湿度分布的箱线图,

进一步揭示不同季节的数据离散程度与集中趋势存在明显差异, 季节差异与区域气候条件密切相关, 如夏季降水增多、冬季低温冻结对土壤水分迁移过程的不同影响等, 春秋季节的变异性尤为突出。相关性热力图表明土壤温度温度呈现强正相关(系数达到 0.85 以上), 而土壤湿度与降水量之间存在显著但滞后性的关联, 这种复杂的关联网络在土壤湿润与温度的散点图中进一步体现为非线性状结构, 以空气温度色彩的分散点分布, 暗示土壤水热耦合关系受到多种环境因子的综合调控。

在时间序列特征方面, 如图 3 显示, 在 0 到 100 的滞后阶数范围内, 多数滞后阶数下的自相关系数保持在 0.5 以上, 表明土壤湿度具有较强的记忆效应, 这种持续性特征在土壤温度的自相关图中同样明显, 其自相关系数维持在 0.75~1.00 的高位区间, 这为构建基于历史数据的预测模型提供重要的理论依据, 特别是在考虑土壤水分运动与热量传递的物理过程中, 高自相关性意味着前期的土壤状态对后续变化具有较强指示作用。



**Figure 3.** Soil temperature-humidity autocorrelation plot  
**图 3.** 土壤温度 - 湿度的自相关图



**Figure 4.** Monthly average change chart  
**图 4.** 月平均变化图

如图 4 所示, 从月平均变化趋势观察, 东北地区的气候要素呈现典型的温带季风气候特征, 夏季(6 月至 8 月)土壤温度与空气温度同步升至年度峰值, 同时土壤湿度和降水量也达到最高水平, 而冬季(12 月至 2 月)各指标则均处于年内低谷, 这种明显的季节性周期不仅反映太阳辐射和大气环流的年际变化规律, 也对农作物生长周期和土壤微生物活动产生深远影响, 例如春季解冻期土壤水分的急剧变化往往与作物播种时机密切相关, 而秋季降温过程则影响着土壤养分的转化与存储, 这些多时间尺度的变化模式共同构成区域农业气象系统的复杂动态, 为深入理解土壤 - 植物 - 大气连续体中的能量与物质交换机制提供实证基础, 同时也为农业水资源管理和灾害预警系统的优化提出新的研究方向。

### 3.4. OPT-PSO-LSTM 的对比实验

实验采用东北地区 2010~2020 年的土壤温湿度监测数据。数据集按 6:2:2 划分为训练集、验证集和测试集。对比算法包括: 网格搜索(每个超参数取 3~5 个值, 全面但耗时)、随机搜索(随机采样 100 组超参数配置)、贝叶斯优化(使用高斯过程, 迭代 100 次)、遗传算法(种群大小 50, 进化 100 代)、标准 PSO 算法(粒子数 20, 最大迭代 50, 固定参数  $w = 0.729$ ,  $c_1 = c_2 = 1.496$ , 作为性能比较的基准)、本文 OPT-PSO-LSTM(粒子数 30, 迭代 50 次, 引入自适应参数调整、多样性增强策略与自适应阈值与多阶段评估)。评估指标包括: 迭代次数、验证损失和优化时间。

**Table 1.** Ablation experience summary table

**表 1.** 消融实验结果汇总表

优化方法	最佳验证损失	相对提升
标准 PSO	0.1693	
OPT-PSO	0.1638	3.25%

**Table 2.** Comparative experimental statistical results chart

**表 2.** 对比实验统计结果表

优化方法	最佳验证损失
表格搜索	0.170409
随机搜索	0.174107
遗传算法	0.168441
标准 PSO	0.169386
OPT-PSO	0.163765

针对 OPT-PSO-LSTM 模型的对比实验, 其结果显示(见表 1、表 2 和图 5)经过优化的粒子群算法在超参数调优中取得显著成效。具体而言, 在耗时 0.58 小时、进行 50 次迭代后, 优化 PSO 将 LSTM 模型的验证损失降至 0.163765, 该数值在对比的几种寻优策略中为最优。将此组超参数应用于独立测试集, 模型在土壤温度与湿度预测上分别取得 0.8304 和 0.7565 的  $R^2$  值, 其对应的均方根误差分别为 0.3994 与 0.5034。这一性能表现, 尤其是相对于基础 PSO 算法实现了 3.25% 的验证损失降低, 印证该优化策略的有效性。

深入分析性能提升的原因, 优化 PSO 所采用的特定参数设置起到关键作用。将粒子数量增加至 30 并迭代 50 次, 极大地扩展搜索的覆盖范围与深度, 有助于跳出局部最优; 其惯性权重在 0.40 至 0.90 区间内动态衰减, 并在算法中后期辅以自适应加速常数, 这种设计巧妙地平衡全局探索与局部开发能力。然

而, 与遗传算法等对比方法相比, 优化 PSO 为获取上述精度优势付出更高的计算成本, 这引出关于寻优效率与精度取舍的进一步思考。该实验结果从实践层面表明, 在计算资源允许的条件下, 采用经过精心设计的元启发式优化算法, 能够系统性地提升 LSTM 模型在土壤属性预测任务中的泛化性能与预测精度。

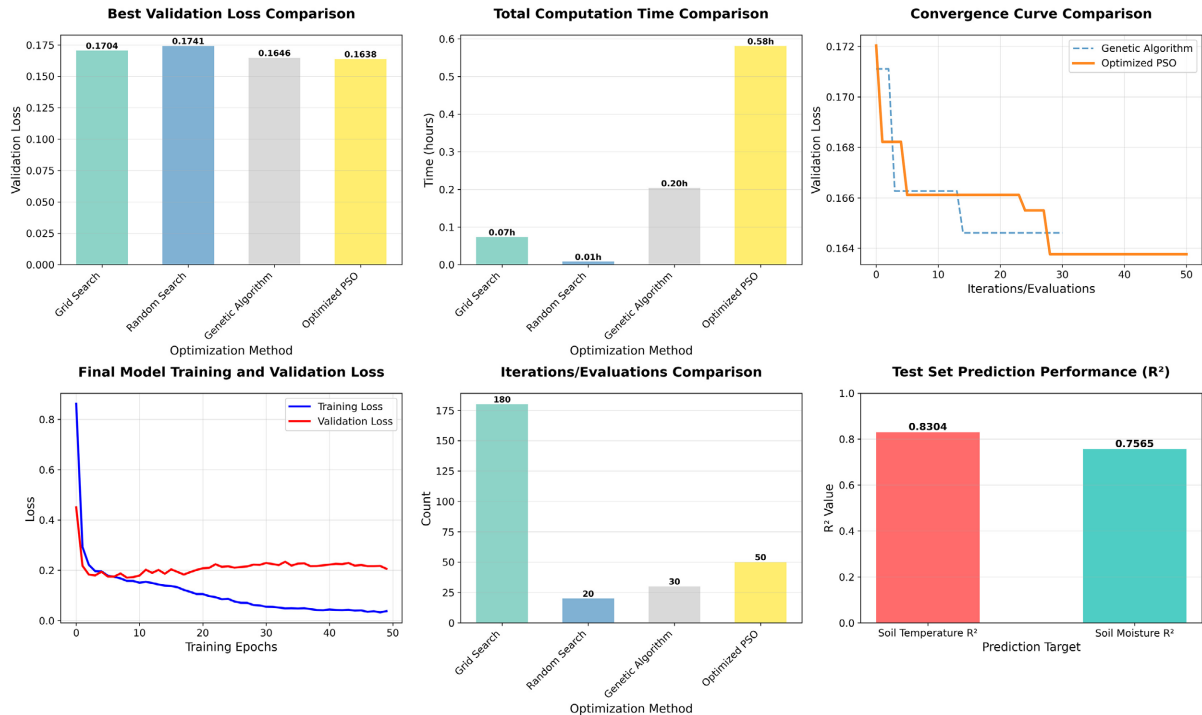


Figure 5. Comparative experimental visualization results diagram

图 5. 对比实验可视化结果图

### 3.5. 小结

本章针对 LSTM 超参数优化难题, 提出基于粒子群算法的 OPT-PSO-LSTM 方法。主要贡献包括: 设计面向 LSTM 超参数特性的混合编码方案, 建立融合预测精度和模型复杂度的多目标适应度函数, 开发融入领域知识的约束处理机制。相比传统优化方法, OPT-PSO-LSTM 在优化效率和最终性能上均有显著提升。通过系统的对比实验, 证明 OPT-PSO-LSTM 在优化质量(损失降低 3.25%)上的优势。超参数敏感性分析为模型设计提供重要指导。OPT-PSO-LSTM 方法的主要优势在于平衡优化效率与解的质量, 融入领域知识, 具备良好的可扩展性。

## 4. 讨论

土壤温湿度作为联结气候变化与农业生产的核心环境变量, 其精准预测对保障粮食安全、优化水资源配置具有重要战略意义[23]。东北地区作为我国重要的商品粮生产基地, 面临季节性冻融循环复杂、极端天气频发等多重挑战, 传统预测方法难以兼顾精度与可解释性的双重需求[24]。在此背景下, 本研究围绕“如何构建契合物理机制且具备自适应优化能力的智能预测模型”这一核心问题, 从超参数自动整定、差异化建模机制、物理知识融合三个层面展开系统性探索。

针对 LSTM 超参数依赖人工经验设定、难以适应复杂时序预测任务的问题, 提出基于改进粒子群优化的超参数自适应整定方法。在东北地区多源数据集上的实验表明, 该方法以 0.58 小时的优化耗时获得 0.1638 的验证损失, 较基础 PSO 算法降低 3.25%。优化后的模型在土壤温度与湿度预测中分别取得 0.8304

和 0.7565 的决定系数。值得注意的是, 粒子群算法在搜索后期展现出的局部精细调优能力, 使模型能够发现传统方法难以触及的超参数组合区域。这一发现提示, 将群体智能与深度学习相结合, 不仅是性能提升的技术路径, 更是突破人工调参认知局限的有效手段。

## 参考文献

- [1] Li, M.X., Yao, Y. and Yu, M. (2022) Improved Daily SMAP Satellite Soil Moisture Prediction over China Using a Deep Learning Model with Transfer Learning. *Journal of Hydrology*, **607**, Article 127124.
- [2] Celik, M.F., Isik, M.S., Yuzugullu, O., Fajraoui, N. and Erten, E. (2022) Soil Moisture Prediction from Remote Sensing Images Coupled with Climate, Soil Texture and Topography via Deep Learning. *Remote Sensing*, **14**, Article 5584. <https://doi.org/10.3390/rs14215584>
- [3] Zhao, L., Luo, T., Jiang, X. and Zhang, B. (2023) Prediction of Soil Moisture Using BIGRU-LSTM Model with STL Decomposition in Qinghai-Tibet Plateau. *PeerJ*, **11**, e15851. <https://doi.org/10.7717/peerj.15851>
- [4] Wang, Y., Shi, L., Hu, Y., Hu, X., Song, W. and Wang, L. (2024) A Comprehensive Study of Deep Learning for Soil Moisture Prediction. *Hydrology and Earth System Sciences*, **28**, 917-943. <https://doi.org/10.5194/hess-28-917-2024>
- [5] Huang, F., Zhang, Y., Zhang, Y., Shangguan, W., Li, Q., Li, L., et al. (2023) Interpreting Conv-LSTM for Spatio-Temporal Soil Moisture Prediction in China. *Agriculture*, **13**, Article 971. <https://doi.org/10.3390/agriculture13050971>
- [6] Li, Q., Zhu, Y., Shangguan, W., Wang, X., Li, L. and Yu, F. (2022) An Attention-Aware LSTM Model for Soil Moisture and Soil Temperature Prediction. *Geoderma*, **409**, Article 115651. <https://doi.org/10.1016/j.geoderma.2021.115651>
- [7] Quy, V.K., Hau, N.V., Anh, D.V., Quy, N.M., Ban, N.T., Lanza, S., et al. (2022) IoT-Enabled Smart Agriculture: Architecture, Applications, and Challenges. *Applied Sciences*, **12**, Article 3396. <https://doi.org/10.3390/app12073396>
- [8] Jawad, M., Wahid, F., Ali, S., Ma, Y., Alkhyat, A., Khan, J., et al. (2025) Energy Optimization and Plant Comfort Management in Smart Greenhouses Using the Artificial Bee Colony Algorithm. *Scientific Reports*, **15**, Article No. 1752. <https://doi.org/10.1038/s41598-024-84141-5>
- [9] Sungmin, O. and Orth, R. (2021) Global Soil Moisture Data Derived through Machine Learning Trained with In-Situ Measurements. *Scientific Data*, **8**, Article No. 170. <https://doi.org/10.1038/s41597-021-00964-1>
- [10] Badgajar, C., Das, S., Figueroa, D.M. and Flippo, D. (2023) Application of Computational Intelligence Methods in Agricultural Soil-Machine Interaction: A Review. *Agriculture*, **13**, Article 357. <https://doi.org/10.3390/agriculture13020357>
- [11] Geng, Q., Yan, S., Li, Q. and Zhang, C. (2024) Enhancing Data-Driven Soil Moisture Modeling with Physically-Guided LSTM Networks. *Frontiers in Forests and Global Change*, **7**, Article 1353011. <https://doi.org/10.3389/ffgc.2024.1353011>
- [12] Jiang, P., Niu, G.Z. and Li, G.M. (2024) Soil Moisture Prediction Based on Long Short-Term Memory Networks and Meteorological Data. <https://doi.org/10.21203/rs.3.rs-4888081/v1>
- [13] Li, L., Wu, S.G., Dai, Y.J., et al. (2022) Attention-Based Convolutional LSTM Model for Multistep Soil Moisture Forecasting. *Journal of Hydrometeorology*, **23**, 337-350.
- [14] 高鹏, 谢家兴, 孙道, 等. 基于物联网和 LSTM 的柑橘园土壤含水量和电导率预测模型[J]. 华南农业大学学报(自然科学版), 2020, 41(6): 134-144.
- [15] 王钥, 郑方元, 雍婷, 查元源, 等. 基于 Transformer 和 LSTM 算法的河套灌区土壤水分预测研究[J]. 农业水土资源与生态环境, 2025, 10(2): 1-8.
- [16] Shen, C. (2018) A Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists. *Water Resources Research*, **54**, 8558-8593. <https://doi.org/10.1029/2018wr022643>
- [17] Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., et al. (2019) Deep Learning and Process Understanding for Data-Driven Earth System Science. *Nature*, **566**, 195-204. <https://doi.org/10.1038/s41586-019-0912-1>
- [18] Yu, J., Zhang, X., Xu, L., Dong, J. and Zhangzhong, L. (2021) A Hybrid CNN-GRU Model for Predicting Soil Moisture in Maize Root Zone. *Agricultural Water Management*, **245**, Article 106649. <https://doi.org/10.1016/j.agwat.2020.106649>
- [19] Shi, X., Chen, Z., Wang, H., et al. (2015) Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. *Advances in Neural Information Processing Systems*, **28**, 802-810.
- [20] Dorigo, W., Wagner, W., Albergel, C., Albrecht, F., Balsamo, G., Brocca, L., et al. (2017) ESA CCI Soil Moisture for Improved Earth System Understanding: State-of-the Art and Future Directions. *Remote Sensing of Environment*, **203**, 185-215. <https://doi.org/10.1016/j.rse.2017.07.001>

- [21] Van den Bergh, J., De Ceuster, G. and Van Hulle, S. (2022) A Temporal-Decomposition LSTM Model for Hyperlocal Forecasting. *IEEE Transactions on Intelligent Transportation Systems*, **23**, 21005-21014.
- [22] Dorigo, W.A., Brocca, L., Beck, H.E., *et al.* (2020) Soil Moisture Spatio-Temporal Variability in SMAP and CCI Products: Insights from Machine Learning. *Remote Sensing of Environment*, **242**, Article 111752.
- [23] Zeng, L., Gao, X., Shi, B., *et al.* (2021) Deep Learning for Predicting Soil Moisture: A Case Study in Agricultural Fields. *Agricultural and Forest Meteorology*, **306**, Article 108475.
- [24] Wang, L., Liu, Q. and Qiao, L. (2023) Short-Term Soil Moisture Forecast Using LSTM and Gradient Boosting. *Soil and Tillage Research*, **230**, Article 105467.