doi:10.6041/j.issn.1000-1298.2026.04.034

# 基于地下无线传播信号的土壤含水率预测方法

徐　兴[1,2]　刘国杰[1,2]　李碧芳[1,3]　段洁利[1,2]　杨　洲[1,2]　付　函[1,2]　金莫辉[1,2]

(1.国家香蕉产业技术体系机械研究室,广州 510642;2.华南农业大学工程学院,广州 510642;
3.华南农业大学电子工程学院(人工智能学院),广州 510642)

**摘要**:及时准确地获取土壤水分信息对全面掌握土壤含水率、提高用水效率、节约宝贵的水资源具有重要意义。当前,土壤水分信息远程采集需同时使用土壤水分传感器及无线传输模块,但局限于离散点的数据获取,不能实现对区域尺度全面评估。而且土壤水分传感器成本较高,往往无法进行批量部署。本文利用地下无线信号受土壤水分显著影响的工作特性及其无线传输通信优势,提出了一种低成本的基于地下无线传播信号对区域范围实现土壤含水率预测方法。基于 LoRa 技术和泛化能力强的快速机器学习方法实现,首先设计并制作了可用于地下环境工作的 LoRa 无线地下传感器网络,实现无线信号接收信号强度(Received signal strength indicator,RSSI)、信噪比以及土壤温度等数据的远程采集。接着,利用采集的数据,提出了基于多源数据的核极限学习机(Kernel extreme learning machine, KELM)模型和粒子群参数寻优计算土壤含水率,解决了土壤含水率与多源数据间的非线性关系复杂度高、大规模数据难以拟合、训练难收敛问题;试验结果表明,提出的基于粒子群参数寻优的 KELM 模型相对于极限学习机(Extreme learning machine,ELM)、支持向量机(Support vector regression,SVR)、长短记忆神经网络(Long short-term memory,LSTM)具有更高的土壤含水率反演精度。在训练集上,KELM 模型平均绝对误差(MAE)为 0.76%,均方根误差(RMSE)为 1.02%,在测试集上,MAE 为 0.72%,RMSE 为 1.07%,能更准确地得到土壤含水率。提出的方法可在不依赖密集布设土壤水分传感器情况下实现土壤含水率有效预测和远程采集,为远程土壤水分区域探测提供了更低成本的解决方案。

**关键词**:土壤含水率;预测方法;WUSN;预测模型

**中图分类号**:S24;S27　　**文献标识码**:A　　**文章编号**:1000-1298(2026)04-0347-08　　**OSID**:

# Soil Moisture Content Prediction Method Based on Underground Wireless Signal Propagation

XU Xing[1,2]　LIU Guojie[1,2]　LI Bifang[1,3]　DUAN Jieli[1,2]　YANG Zhou[1,2]　FU Han[1,2]　JIN Mohui[1,2]

(1. *Mechanization Research Laboratory*, *National Banana Industry Technology System*, *Guangzhou* 510642, *China*
2. *College of Engineering*, *South China Agricultural University*, *Guangzhou* 510642, *China*
3. *College of Electronic Engineering* (*College of Artificial Intelligence*), *South China Agricultural University*, *Guangzhou* 510642, *China*)

**Abstract**: Timely and accurate acquisition of soil moisture information is essential for comprehensively understanding soil water content, improving water use efficiency, and conserving valuable water resources. At present, remote collection of soil moisture data typically requires both soil moisture sensors and wireless transmission modules. However, these approaches are limited to discrete point measurements and cannot achieve comprehensive regional assessment. Moreover, the high cost of soil moisture sensors restricts large-scale deployment. A low-cost method for predicting soil water content over an area was proposed, utilizing the working characteristics of underground wireless signal propagation which was strongly influenced by soil moisture, and its advantages in wireless communication. Based on LoRa technology and a fast machine learning approach with strong generalization capability, a LoRa-based underground wireless sensor network was designed and developed for underground environments to remotely collect data such as received signal strength indicator (RSSI), signal-to-noise ratio (SNR),

收稿日期:2025-08-16　修回日期:2025-09-29

**基金项目**:广州市重点研发计划项目(2024B03J1355)、国家自然科学基金项目(32271996、32572183)、财政部和农业农村部:现代农业产业技术体系建设专项资金项目(CARS-31-11)和中央级公益性科研院所基本科研业务费项目(CATASCXTD202309)

**作者简介**:徐兴(1978—),男,副教授,主要从事果园农业无线传感器网络和农业物联网等研究,E-mail:xuxing@scau.edu.cn

and soil temperature. Using the collected data, a kernel extreme learning machine (KELM) model optimized by particle swarm optimization (PSO) was proposed to estimate soil water content, addressing the challenges of strong nonlinearity, poor fitting, and low convergence in large-scale data modeling. Experimental results showed that the proposed PSO-optimized KELM model achieved higher prediction accuracy than the extreme learning machine (ELM), support vector regression (SVR), and long short-term memory (LSTM) models. In the training dataset, the KELM model achieved a mean absolute error (MAE) of 0.76% and a root mean square error (RMSE) of 1.02%, while in the testing dataset, the MAE and RMSE were 0.72% and 1.07%, respectively. The proposed method can achieve effective prediction and remote acquisition of soil moisture content without relying on the dense deployment of soil moisture sensors, providing a low-cost solution for large-area soil moisture detection.

**Key words**: soil moisture content; prediction method; WUSN; prediction models

## 0 引言

土壤水分作为重要的陆地表层系统要素，对生态、环境、农业等领域研究具有重要意义[1-2]。传统的土壤含水率监测方法，如土壤干燥法、中子水分仪法、张力计法等，需在土壤中埋设传感器或在地表进行点测量，这些方法既耗时耗力，成本高昂，只能获取离散点数据，又难以实现大范围面积探测。遥感技术可以突破传统土壤含水率监测方法的空间限制，但其时间分辨率较低，且易受天气条件的影响[3]。近年来，随着无线传感器网络（Wireless sensor network，WSN）技术发展，无线地下传感器网络（Wireless underground sensor network，WUSN）在陆地、农业和生态应用中得到了广泛关注和研究[4-10]。利用 WUSN 收集的数据，结合数据管理和基于人工智能分析，可以在不破坏农业过程并且不依赖昂贵土壤传感器的前提下，利用无线信号在地下传播过程中受到土壤含水率影响的特性[11-13]，通过测量无线信号的接收信号强度（Received signal strength indicator，RSSI），并结合其他相关因素和反演算法，实现对土壤含水率估计[14-15]。相比于传统方法，该方法具有低成本、高效率和长期稳定等优势，可以为农业和生态领域提供有价值的数据和服务。

目前，国内外已有一些研究者对基于 RSSI 变化测定土壤含水率的方法进行了探索和实验。DUJIĆ 等[16]提出了一种利用深度学习实现湿度传感的低成本低功耗传感器新概念，网关设备从传感器收集信号强度测量值。对采集数据分析表明，RSSI、信噪比（SNR）与土壤含水率呈显著相关。使用 SVR 和 LSTM 根据 RSSI 预测土壤含水率，发现 LSTM 模型比 SVR 模型有更高准确度和稳定性。BALIVADA 等[17]在覆盖半径 23 m 的农业田地上设计和部署了 530 个节点的 WUSN，并使 WUSN 在 3 个季节中持续运行，实时监测土壤体积含水率（VWC）、土壤温度（ST）和土壤电导率（EC）数据。使用 1 个多层感知器（MLP）作为模型结构，将 RSSI、$D$（无线节点与接收天线间距离）、AT（空气温度）、ST、RH（相对湿度）和 $P$（降水量）作为模型输入参数，其中 AT、RH 和 $P$ 从附近气象站获取。结果发现以 RSSI、$D$、AT、ST 和 RH 作为输入的模型能较好地预测土壤 VWC。BERTOCCO 等[18]利用机器学习和增强感测方法估计土壤 VWC，使用 1 个嵌入低成本、低精度土壤湿度传感器和 1 个长距离广域网络（LoRaWAN）收发器的 IoUT 传感器节点。在实验室用沙石模拟土壤环境收集了一组数据，并使用 3 种不同技术训练和测试了机器学习算法估计 VWC。结果表明，增强传感器在性能上超过了虚拟传感器和校准后的真实土壤湿度传感器。增强传感器均方根误差为 1.84%，进行过滤处理后，均方根误差可以降低到 1.53%。

尽管现有研究在不同程度上实现了基于 RSSI 反演土壤含水率的目标，但也存在一些不足。例如：没有考虑其他影响因素，如温度、信噪比等，这会导致精度损失和误差增加；依赖气象站获取 AT、ST、RH 和 $P$ 等参数，需要保证它们与 VWC 数据的时间和空间对齐，增加了数据处理和同步难度等；利用单一类型土壤（纯沙）模拟土壤环境或者在实验室用筛选好的理想条件下的土壤进行试验，忽略了真实农田土壤环境下其他环境因素对信号衰减的影响。

为克服上述不足，本文提出一种基于 LoRa 无线地下传感器网络（WUSN）与 KELM 模型的土壤含水率预测方法，利用无线 RSSI 和 SNR 数据，结合 ST、土壤湿度、$D$ 等数据，采用基于粒子群参数寻优的 KELM 模型进行反演计算[19-22]，融合极限学习机的快速学习能力和核方法的非线性映射优势，以及粒子群较好的全局寻优能力，以高效快速地处理复杂非线性问题。并将 KELM 模型与常用模型 ELM、SVR 和 LSTM 进行对比分析[23-24]，以实现土壤含水率高精度反演。

## 1　材料与方法

### 1.1　试验区概况

WUSN 部署在华南农业大学工程训练中心旁边的农田内，网关所处经纬度为 23.159 67°N，113.338 8°E，该农田位于广东省广州市，属于南亚热带海洋季风气候，年平均气温为 22 ~ 24℃，年平均降水量达 1 696.5 mm[25]。

农田如图 1a 所示，节点均放置地表，部署在距离基站约 2 m 半径范围内，相邻节点水平间距为 25 cm，节点天线和传感器均埋入土壤约 20 cm。为降低节点功耗，每次发送上行数据后，节点进入休眠状态，休眠周期为 5 min。试验以土壤含水率为自变量，将节点和网关放置在空地上进行为期 2 个月监测，测定节点土壤含水率、ST、EC、SNR 和 RSSI 数据，手动测量数据 $D$。试验中，所有节点通信频率为 433 MHz，扩频因子为 12，通信带宽为 125 kHz，发送功率为 14 dBm。



(a) 农田　　(b) 无线地下节点部署

图 1　试验区农田环境与无线地下传感器节点布置示意图

Fig. 1　Experimental farmland site and deployment of wireless underground sensor nodes

### 1.2　LoRa 无线地下传感器网络

根据试验需求，设计如图 2 所示的系统架构。包括无线传感器节点、网关基站和云平台 3 部分，在 LoRa 终端上外接土壤水分传感器与执行器，将数据封装通过 LoRa 协议发送至网关，网关能同时接收和处理多个节点数据，并通过 UDP 协议传至腾讯云服务器，服务器利用 ChirpStack 服务器与 Grafana 应用实现数据可视化监测与管理。

无线传感器节点硬件电路设计方案整体硬件电路设计图如图 3a 所示，根据功能划分将系统电路分为 5 个模块：充电电路、保护电路、升压降压电路、串口转换电路和主控板外围电路。无线传感器节点采用 3.7 ~ 4.2 V 锂电池作为主电源，设计了太阳能和外部电源双重充电机制。在锂电池充电和使用过程中，可能会发生电压波动或过载等异常情况，保护电路能够迅速响应并切断电源，防止设备受到损害。由于不同设备对电压的需求各不相同，因此设计了升压降压电路。例如，PAK3172 模块需要稳定的 3.3 V 电压确保正常运行，而土壤水分传感器可能

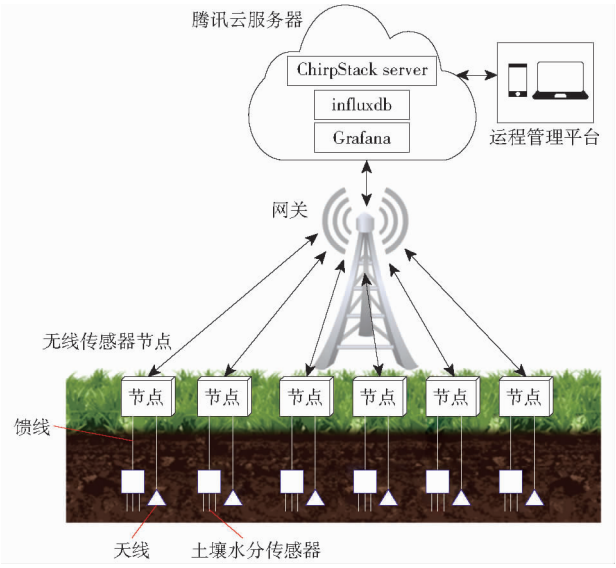


图 2　无线地下传感器网络总体框架

Fig. 2　Overall framework of wireless underground sensor network

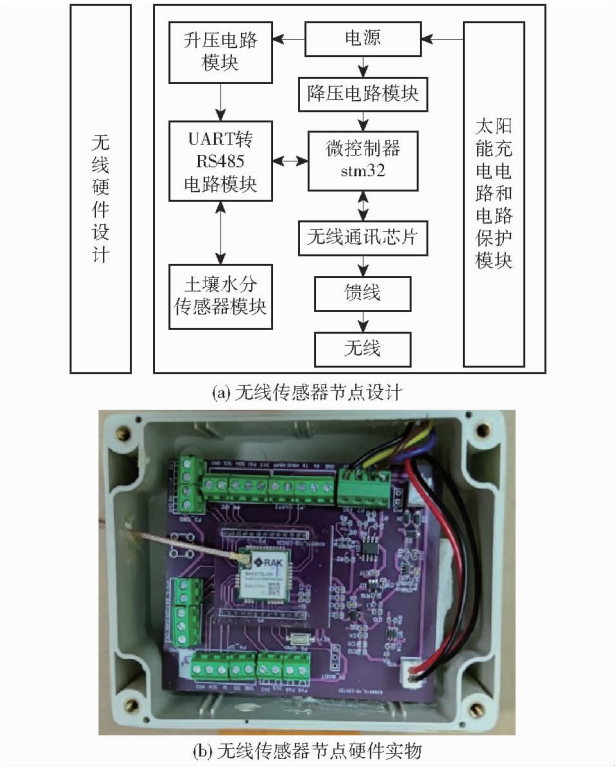


(a) 无线传感器节点设计

(b) 无线传感器节点硬件实物

图 3　无线传感器节点

Fig. 3　Wireless sensor node

需要 5 V 电压才能准确检测。针对土壤水分传感器与 RAK3172 模块通信不兼容的问题，设计了专门的串口转换电路，将 RAK3172 模块 UART 串口转换为 RS485 串口，从而确保土壤水分传感器能够顺畅地与节点进行数据交换。为保证 RAK3172 模块稳定运行，设计了一系列外围电路。这些电路包括用于滤波和稳定电压的电容，以及用于在异常情况下重置模块的复位电路。这些设计能够确保主控板在各种环境下都能保持稳定性能，另外还设计了扩展通

信接口电路,为节点预留足够引脚资源。

节点微控制器模块和通信模块选用集成 Semtech 的 SX1276 和 STM32WLE5CC 芯片的 RAK3172 模块,RAK3172 是一款低功耗远距离 LoRa 收发模块,支持 LoRaWAN1.0.3 协议和 LoRa P2P 通信,睡眠模式下功耗低至 5.6 μW。将节点工作频段设为 470 ~ 510 MHz。每个传感器节点由 1 个密封外壳(30 cm × 10 cm × 15 cm)保护,如图 3b 所示,外壳中包含电子元件、电源和发射天线,外壳放置在三角架上,三角架固定在地表,利用 1.5 m 馈线连接节点模块和天线,并将天线垂直插入土壤,以保持土壤结构不变,又能使无线模块发射的电磁波在土壤内传播。另外每个节点还配备 PR - 3000 - ECTH 型土壤水分传感器,将其垂直插入与天线同一水平的土壤中,用于测量节点附近的土壤含水率、ST 和 EC,为防止信号泄漏和干扰,试验中在模块 SMA 插头和馈线连接处用锡纸进行屏蔽。

LoRa 网关由“树莓派 + RAK2245 Pi HAT 模块”组合,RAK2245 Pi HAT 拥有 1 个基于 Semtech SX1301 的基带处理器,用于管理数据包,以及 2 个 Semtech SX1257,用于射频前端的 I/Q 收发,RAK2245 Pi HAT 模块负责 LoRa 信号收发,树莓派作为核心控制板,负责处理数据和运算。网关安装在试验地边缘,网关天线安装在离地面高度 1.8 m。网关接收所有节点上传的 RSSI、土壤含水率、SNR、ST 和 EC 数据,由于土壤参数变化会影响 RSSI 变化,算法在训练过程中识别这些变化,从而利用 RSSI 估计土壤含水率。

### 1.3 数据收集与处理

LoRa 网关将多个终端节点数据上传至腾讯云服务器,服务器利用 ChirpStack 服务与 Grafana 应用实现数据可视化,图 4 为节点 2 数据可视化界面,其中 RSSI 为无线地下传输信号,HUM 为土壤含水率,EC 为电导率,SNR 为信噪比,TEM 为土壤温度。

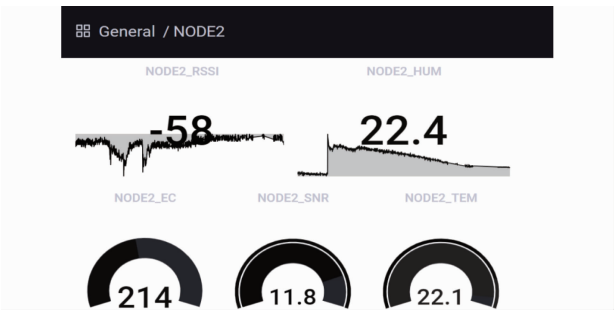


图 4 Grafana 应用可视化界面

Fig. 4 Visualization interface of Grafana application

LoRa 无线传感器网络部署时间为 2023 年 8 月 18 日—12 月 26 日,时长为 4 个月 8 天。期间,采集提取信息包括 RSSI、土壤温度、土壤湿度、时间戳以及节点 ID。其中,节点 1(距离网关 220 cm)接收到 2 220 个数据包,节点 2(距离网关 250 cm)接收到 4 300 个数据包,节点 3(距离网关 280 cm)接收到 1 800 个数据包。图 5、6 为节点 2 数据,可以发现,土壤含水率越大,RSSI 越小,两者呈负相关。图 7 为土壤含水率和 EC(土壤电导率)的关系,可以发现两者呈正相关。

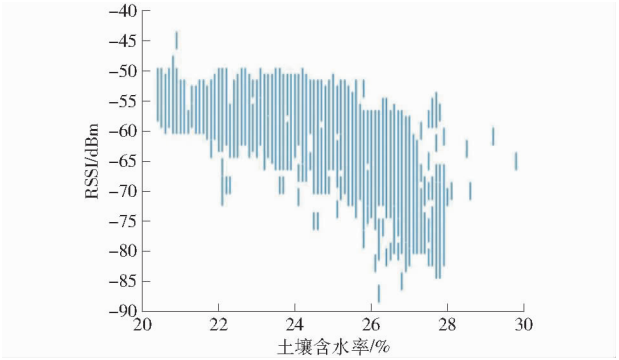


图 5 节点 2 RSSI 随土壤含水率变化散点图

Fig. 5 Scatter plot of RSSI varied with soil moisture content for Node 2

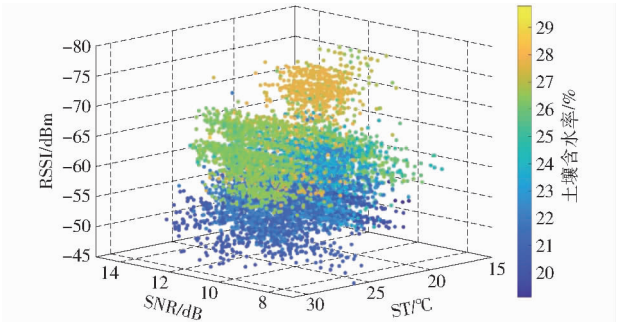


图 6 RSSI、ST、SNR、含水率变化散点图

Fig. 6 Scatter plot of RSSI, ST, SNR, and humidity variations

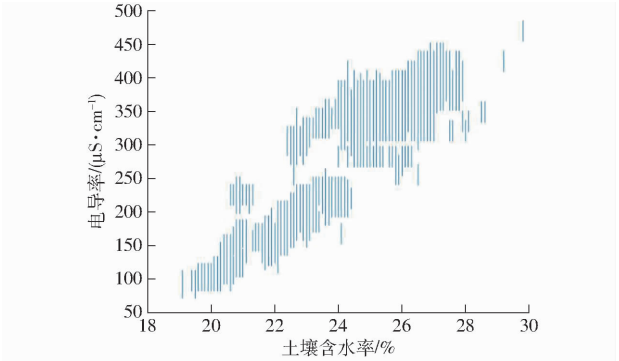


图 7 电导率随土壤含水率变化散点图

Fig. 7 Scatter plot of electrical conductivity versus soil moisture content

为研究各数据与土壤含水率关系,利用 Matlab R2021b 对所有数据进行相关性分析,结果如表 1 所示。分析发现,土壤含水率和EC呈正相关(相关系

表 1　特征参数与土壤含水率的 Pearson 分析

Tab. 1　Pearson correlation analysis between feature parameters and soil moisture content

| | RSSI | SNR | TEM | EC | DIS |
|---|---|---|---|---|---|
| HUM | -0.754 1 | -0.152 9 | 0.167 6 | 0.720 0 | -0.239 4 |

数 $R=0.72$)，这说明土壤含水率越高，溶液中阳离子越多，土壤导电能力越强，EC 也更高[26]。另一方面，土壤含水率和 RSSI 呈负相关($R=-0.754\ 1$)，这说明 RSSI 和土壤含水率具有较大相关性，但仅用 RSSI 可能不足以准确估计土壤含水率，因为电磁信号在地下传播还受到其他因素的影响[27-28]，如天气和土壤介质等，因此，除考虑 RSSI 外，还可以考虑环境因素来提高土壤含水率预测精度。

### 1.4　核极限学习机

KELM 是基于 ELM[20] 并结合核函数所提出的改进算法，KELM 能够在保留 ELM 优点的基础上提高模型预测性能，相对于极限学习机算法，其解决回归预测问题的能力更强，泛化性能更好，在获得更好或相似的预测准确度时，计算速度更快。在基于核极限学习机算法中，其自身特性决定了隐层节点中特征映射函数的具体形式不用给出，而只需知道核函数形式就能够求出输出函数值。同时，在求解输出函数值时也无需设定隐层节点数量，从而不需要特别设定隐含层初始权重和偏置值[21-22]。

粒子群寻优(Particle swarm optimization，PSO)是一种基于群体智能的优化算法。在 PSO 中，每个优化问题潜在解都是搜索空间中的 1 只鸟，抽象为粒子，每个粒子都有 1 个由目标函数决定的适应值，每个粒子有位置、速度等基本属性。通过不同迭代，更新粒子速度和位置得到最适解，粒子在某一个位置越集中，代表该问题解所在[29]。本次试验最优惩罚参数 $C$(0.1 ~ 2 000)和核函数参数(0.01 ~ 100)进行 300 次迭代寻优。

### 1.5　评估指标

采用均方根误差(RMSE)、平均绝对误差(MAE)和决定系数($R^2$)作为评估指标。

## 2　结果与分析

将无线地下传感器网络按照图 1 所示安装后，系统持续采集 RSSI、SNR、ST 等数据，并以土壤水分传感器测得的含水率作为真实值，开展模型训练与测试分析。

### 2.1　数据预处理

核极限学习机输入参数包括 WUSN 的 RSSI、$D$、ST、EC 和 SNR。由于收集数据中变量具有不同尺度，相对湿度以百分比表示，RSSI 以分贝表示，因此需对原始数据进行预处理和标准化，使数据具有可比性和统一性，将所有输入和目标参数归一化到 0 ~ 1 范围内。

选取 2023 年 8—11 月预处理数据作为训练集。选择该时间段数据是为了更好地分析 RSSI 随土壤含水率变化的规律。另外，为确保测量一致性，测试集也要从先前描述的时间框架中选择，所以总数据集被随机分为 70% 用于训练(4 424 个数据点)、30% 用于测试(1 896 个数据点)。

### 2.2　不同输入特征结果

以外接土壤水分传感器采集的土壤含水率作为模型真实数据和目标参数。以埋地传感器节点与基站天线间的 RSSI 和 $D$、ST 和 SNR 为模型输入参数，训练并评估模型性能。表 2 为该模型在不同输入参数组合下的预测能力。从表 2 可看出，仅使用 RSSI 和 $D$ 作为输入参数时，模型预测能力最低，加入 SNR 后，模型性能有所提升，但不明显；再加入 ST 作为输入参数后，模型预测能力明显变高。因此，最佳输入组合为 RSSI、$D$、ST 和 SNR。

表 2　不同输入特征对比

Tab. 2　Comparison of different input features

| 输入特征 | 训练集 | | | 测试集 | | |
|---|---|---|---|---|---|---|
| | RMSE/% | MAE/% | $R^2$ | RMSE/% | MAE/% | $R^2$ |
| RSSI + $D$ | 1.45 | 1.17 | 0.475 2 | 1.52 | 1.18 | 0.424 2 |
| RSSI + $D$ + TEM | 1.18 | 8.74 | 0.700 4 | 1.19 | 8.98 | 0.692 7 |
| RSSI + $D$ + SNR | 1.40 | 1.08 | 0.535 4 | 1.41 | 1.19 | 0.504 8 |
| RSSI + $D$ + SNR + $M$ | 1.02 | 0.76 | 0.795 0 | 1.07 | 0.72 | 0.769 9 |

### 2.3　特征组合选择

采用上述最优参数组合($D$、RSSI、ST 和 SNR)作为模型输入特征，图 8 为 KELM 模型训练集和测试集拟合结果。

图 8 直观地反映了模型预测值与实际值间的对比，验证了模型在预测土壤含水率方面的有效性。在训练集上，模型展现出较高拟合度，RMSE 和 MAE 分别为 1.02% 和 0.76%，表明模型在已知数据集上的性能较优。而在测试集上，模型同样表现出良好预测能力，RMSE 和 MAE 分别为 1.07% 和 0.72%，该结果表明，即使在有限数据集上，模型也能根据接收信号强度和环境参数较为准确地估计土壤含水率。

### 2.4　与其他模型对比

SVR 是一种用于回归分析的机器学习算法。其目标是找到一个函数，可以近似输入变量和连

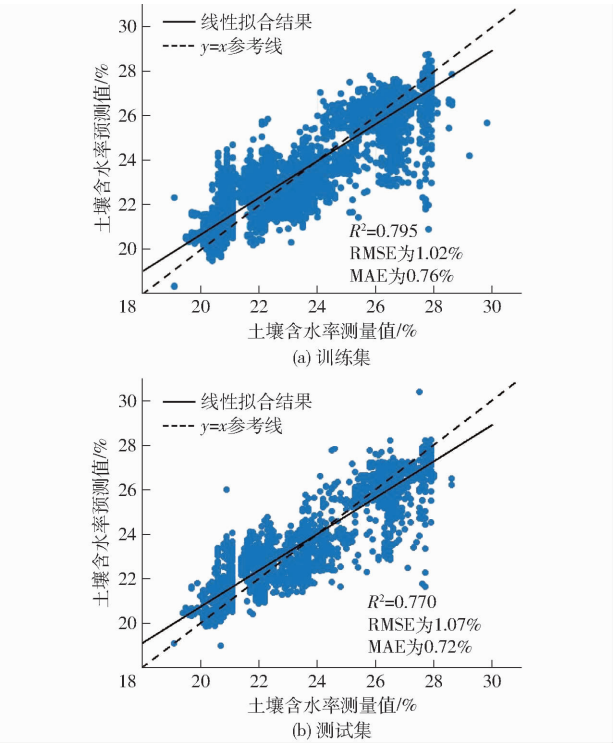


图 8 模型拟合结果

Fig. 8 Model fitting results

续目标变量间的关系,同时最小化预测误差[29]。SVR 超参数主要有 $C$、$\gamma$ 和 $\varepsilon$,$C$ 为正则化参数,用于控制分类器对误分类样本的惩罚程度,$\gamma$ 为核函数参数,控制样本点映射到高维空间后的分布特征,$\varepsilon$ 为浮点数,作用于损失函数,设为 0.01,将正则化参数和 $\gamma$ 进行参数寻优。

LSTM 是一种强大的学习算法,其改善了 RNN 中存在的长期依赖问题,能够学习长序列的依赖关系,可作为复杂的非线性单元用于构造更大型深度神经网络,非常适合用于进行映射关系挖掘和时序预测[30]。本研究 LSTM 模型优化器为 Adam 梯度下降算法,将隐藏层单元数目(30 ~ 150)、最大训练周期(50 ~ 80)、初始学习率(0.001 ~ 0.05)、正则化系数 L2($1\times10^{-4}$ ~ $1\times10^{-3}$)进行参数寻优。

ELM 是一种机器学习算法,用于回归分析。在 ELM 中,隐层权值和隐层阈值是随机初始化的,然后通过解析解来计算输出层权重。这些权重和阈值可以通过训练数据进行优化。在 Matlab 中,可以使用 elmtrain 函数训练 ELM 模型,然后使用 elmpredict 函数进行预测,本试验使用激活函数(Sigmoid、tanh、ReLU 和 rbf)对层隐藏神经元数量进行寻优。在 ELM 模型隐藏层中测试 5 ~ 1 000 个神经元数量,增量为 5。

将 RSSI、$D$、ST 和 SNR 4 个参数作为输入,并将 KELM 模型与另外 3 种常用的回归模型进行性能对比。表 3 为 4 种模型评价指标对比,从表 3 可看出,

表 3 4 种模型评估指标对比

Tab. 3 Comparison of evaluation metrics for four models

| 模型 | 训练集 | | | 测试集 | | |
|---|---|---|---|---|---|---|
| | RMSE/% | MAE/% | $R^2$ | RMSE/% | MAE/% | $R^2$ |
| LSTM | 1.37 | 1.10 | 0.695 4 | 1.37 | 1.10 | 0.692 8 |
| SVR | 1.31 | 1.15 | 0.065 6 | 1.24 | 1.19 | 0.066 8 |
| ELM | 1.15 | 0.87 | 0.785 6 | 1.16 | 0.88 | 0.779 0 |
| KELM | 1.02 | 0.76 | 0.795 0 | 1.07 | 0.72 | 0.769 9 |

KELM 模型 MAE 低于其他 2 个模型,这说明该模型预测精度优于 SVR、LSTM 和 ELM 模型。而更低的 RMSE 进一步表明,KELM 模型预测结果最接近真实值,且预测具有长期稳定性,可用于土壤含水率的准确预测。

KELM 模型优越性可归因为:① KELM 通过引入核函数,可以有效映射输入数据到高维空间,从而能够处理复杂的非线性关系。这使得 KELM 能更好地捕捉土壤含水率的变化模式,降低误差。② KELM 模型在训练过程中自动确定隐层参数,并仅需调整核函数参数,减少了过拟合风险,增强了模型泛化能力。因此,其在未参与训练数据集上的表现更为稳定,预测结果更加可靠。③KELM 通过粒子群全局寻优参数,优化模型结构,使模型更好地拟合数据,从而降低预测误差(如 MAE 和 RMSE),提高预测结果准确性。

### 2.5 讨论

由表 3 可知,KELM 模型在多源数据驱动的土壤含水率预测中具有显著优势。首先,KELM 能够有效刻画 RSSI、SNR、$D$ 和 ST 与土壤含水率间的复杂非线性关系,其预测值更接近真实观测值,表现出更强的稳定性。其次,相较于 LSTM 模型,KELM 训练效率更高,避免了深度学习模型收敛慢的问题;与传统的 SVR 和 ELM 相比,KELM 在精度和稳定性上均有提升。这表明 KELM 结合粒子群优化后的参数寻优策略,能够在保证预测精度的同时兼顾模型适应性,因而在大面积土壤含水率预测和实时监测中更具应用潜力。

## 3 结束语

提出了一种基于地下无线传播信号和快速机器学习方法的低成本土壤含水率预测方法。设计了基于 LoRa 的地下无线传感网络,实现了 RSSI、SNR、无线节点与接收天线间距离和土壤温度等多源数据的远程采集,并结合核极限学习机(KELM)模型与粒子群参数寻优方法进行土壤含水率预测。试验结果表明,该方法无需昂贵的土壤水分传感器,即可实现对区域土壤含水率有效探测。在对比试验中,

KELM 模型在测试集上结果优异，其 MAE 为 0.72%、RMSE 为 1.07%，相较于 LSTM、SVR 和 ELM 等常用方法具有更高精度与稳定性。提出的土壤含水率预测方法为大面积、低成本、远程土壤含水率监测提供了一种可行的新途径，对精准农业与水资源高效利用具有重要应用价值。

## 参 考 文 献


[1] LEKSHMI S U, SINGH D N, BAGHINI M S. A critical review of soil moisture measurement[J]. Measurement, 2014, 54: 92 – 105.

[2] 潘宁, 王帅, 刘焱序, 等. 土壤水分遥感反演研究进展[J]. 生态学报, 2019, 39(13): 4615 – 4626.
PAN Ning, WANG Shuai, LIU Yanxu, et al. Advances in soil moisture retrieval from remote sensing[J]. Acta Ecologica Sinica, 2019, 39(13): 4615 – 4626. (in Chinese)

[3] HU Q, LI Y, LIU W, et al. Research on soil moisture inversion method for canal slope of the Middle Route Project of the South to North Water Transfer based on GNSS – R and deep learning[J]. Remote Sensing, 2023, 15(17): 4340.

[4] DONG X, VURAN M C. A channel model for wireless underground sensor networks using lateral waves[C]// IEEE Global Telecommunications Conference (GLOBECOM 2011). IEEE, 2011: 1 – 6.

[5] DONG X, VURAN M C. Impacts of soil moisture on cognitive radio underground networks[C]// Proceedings of the 1st International Black Sea Conference on Communications and Networking (BlackSeaCom). IEEE, 2013: 222 – 227.

[6] 张增林. 农田土壤水分无线地下传感器监测网络关键技术研究[D]. 杨凌: 西北农林科技大学, 2015.
ZHANG Zenglin. Research on key technologies of wireless underground sensor network for farmland soil moisture water content [D]. Yangling: Northwest A&F University, 2015. (in Chinese)

[7] YU X, WU P, ZHANG Z, et al. Electromagnetic wave propagation in soil for wireless underground sensor networks[J]. Progress in Electromagnetics Research M, 2013, 30: 11 – 23.

[8] AKKAŞ M A, SOKULLU R. Channel modeling and analysis for wireless underground sensor networks in water medium using electromagnetic waves in the 300 – 700 MHz range[J]. Wireless Personal Communications, 2015, 84: 1449 – 1468.

[9] AKYILDIZ I F, STUNTEBECK E P. Wireless underground sensor networks: research challenges[J]. Ad. Hoc. Networks, 2006, 4(6): 669 – 686.

[10] VURAN M C, SALAM A, WONG R, et al. Internet of underground things in precision agriculture: architecture and technology aspects[J]. Ad. Hoc. Networks, 2018, 81: 160 – 173.

[11] LIEDMANN F, HOLEWA C, WIETFELD C. The radio field as a sensor—a segmentation based soil moisture sensing approach [C]// IEEE Sensors Applications Symposium (SAS). IEEE, 2018: 1 – 6.

[12] LIEDMANN F, WIETFELD C. SoMoS—a multidimensional radio field based soil moisture sensing system[C]// IEEE Sensors. IEEE, 2017: 1 – 3.

[13] PEPLINSKI N R, ULABY F T, DOBSON M C. Dielectric properties of soils in the 0.3 ~ 1.3 GHz range[J]. IEEE Transactions on Geoscience and Remote Sensing, 1995, 33(3): 803 – 807.

[14] 邝晓飞,万里平,连嘉茜,等.基于 Transformer 和多序列特征的土壤含水率预测[J].农业机械学报,2025,56(8):120 – 127.
KUANG Xiaofei, WAN Liping, LIAN Jiaqian, et al. Prediction of soil moisture content based on Transformer and multi sequence feature[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(8): 120 – 127. (in Chinese)

[15] 李瑞平,赵建伟,王福强,等.考虑时空融合环境因子的土壤含水率机器学习反演模型优化[J].农业机械学报,2025,56(8):370 – 379.
LI Ruiping, ZHAO Jianwei, WANG Fuqiang, et al. Optimization of soil moisture machine learning inversion model considering spatiotemporal fusion of environmental factors[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(8): 370 – 379. (in Chinese)

[16] DUJIĆ R L, ŽUPANOVIĆ T, PERKOVIĆ T, et al. Machine learning and soil humidity sensing: signal strength approach[J]. ACM Transactions on Internet Technology (TOIT), 2021, 22(2): 39.

[17] BALIVADA S, GRANT G, ZHANG X, et al. A wireless underground sensor network field pilot for agriculture and ecology: soil moisture mapping using signal attenuation[J]. Sensors, 2022, 22(10): 3913.

[18] BERTOCCO M, PARRINO S, PERUZZI G, et al. Estimating volumetric water content in soil for IoUT contexts by exploiting RSSI-based augmented sensors via machine learning[J]. Sensors, 2023, 23(4): 2033.

[19] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1 – 3): 489 – 501.

[20] HUANG G B, BAI Z, KASUN L L C, et al. Local receptive fields based extreme learning machine[J]. IEEE Computational Intelligence Magazine, 2015, 10(2): 18 – 29.

[21] 韩宏泉, 吴珊, 侯本伟. 采用核极限学习机的短期需水量预测模型[J]. 哈尔滨工业大学学报, 2022, 54(2): 17 – 24.
HAN Hongquan, WU Shan, HOU Benwei. Short-term water demand prediction model using kernel-based extreme learning machine[J]. Journal of Harbin Institute of Technology, 2022, 54(2): 17 – 24. (in Chinese)

[22] 宋佳, 石若凌, 郭小红, 等. 基于核极限学习机的飞行器故障诊断方法[J]. 清华大学学报(自然科学版), 2020,

60(10): 795 - 803.
SONG Jia, SHI Ruoling, GUO Xiaohong, et al. KELM based diagnostics for air vehicle faults[J]. Journal of Tsinghua University (Science and Technology), 2020, 60(10): 795 - 803. (in Chinese)
[23] GILL M K, ASEFA T, KEMBLOWSKI M W, et al. Soil moisture prediction using support vector machines[J]. Journal of the American Water Resources Association, 2006, 42(4): 1033 - 1046.
[24] HONG Z, KALBARCZYK Z, IYER R K. A data-driven approach to soil moisture collection and prediction[C]// IEEE International Conference on Smart Computing (SMARTCOMP). IEEE, 2016: 1 - 6.
[25] 赵文博, 刘洪杰, 田雪婷, 等. 基于 UCMap 的城市环境气候空间格局分析——以广州市为例[J]. 地理科学进展, 2019, 38(3): 452 - 464.
ZHAO Wenbo, LIU Hongjie, TIAN Xueting, et al. Environmental climate spatial pattern of Guangzhou City based on urban climatic map[J]. Progress in Geography, 2019, 38(3): 452 - 464. (in Chinese)
[26] 张西良,谢飞洋,盛庆元,等. 基于电导率对相对介电常数补偿的土壤含水率电容传感器标定方法[J]. 农业机械学报, 2024,55(8):344 - 351.
ZHANG Xiliang, XIE Feiyang, SHENG Qingyuan, et al. Calibration method of soil moisture capacitance sensor based on compensation of electrical conductivity to relative permittivity[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 344 - 351. (in Chinese)
[27] CHAAMWE N, LIU W, JIANG H. Wave propagation communication models for wireless underground sensor networks[C]// IEEE 12th International Conference on Communication Technology. IEEE, 2010: 9 - 12.
[28] LI W Z, ZHANG G, LI Z. Simulation of channel model for WUSN based on NS2[J]. Computer and Modernization, 2016(1): 121.
[29] EBERHART R, KENNEDY J. Particle swarm optimization[C]// Proceedings of the IEEE International Conference on Neural Networks. IEEE, 1995: 1942 - 1948.
[30] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273 - 297.

(上接第 338 页)

[25] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020,8(1): 22 - 34.
[26] 孟志军,刘淮玉,安晓飞,等. 基于 SPA - SSA - BP 的小麦秸秆含水率检测模型[J]. 农业机械学报,2022,53(2):231 - 238,245.
MENG Zhijun, LIU Huaiyu, AN Xiaofei, et al. Prediction model of wheat straw moisture content based on SPA - SSA - BP[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 231 - 238,245. (in Chinese)
[27] 祖林禄,柳平增,赵妍平,等. 基于 SSA - LSTM 的日光温室环境预测模型研究[J]. 农业机械学报,2023,54(2):351 - 358.
ZU Linlu, LIU Pingzeng, ZHAO Yanping, et al. Solar greenhouse environment prediction model based on SSA - LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 351 - 358. (in Chinese)
[28] 麻芳兰,罗一鸣,李嘉诚,等. 甘蔗收获机根部切割系统负载压力预测模型研究[J]. 农业机械学报,2024,55(12):81 - 89.
MA Fanglan, LUO Yiming, LI Jiacheng, et al. Load pressure prediction model for sugarcane harvester base-cutting system[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(12):81 - 89. (in Chinese)
[29] 刘潭,李子默,冯帅,等. 基于 LMPSO - SVM 的高光谱水稻稻瘟病害分级检测[J]. 农业机械学报,2023,54(11):208 - 216,235.
LIU Tan, LI Zimo, FENG Shuai, et al. Classification detection of hyperspectral rice blat disease based on LMPSO - SVM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 208 - 216,235. (in Chinese)
[30] 解毅,王佳楠,刘钰. 基于 Sentinel - 1/2 数据特征优选的冬小麦种植区识别方法研究[J]. 农业机械学报,2024,55(2): 231 - 241.
XIE Yi, WANG Jia'nan, LIU Yu, et al. Research on winter wheat planting area identification method based on Sentinel - 1/2 data feature optimization[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 231 - 241. (in Chinese)
[31] LI S, CHEN H, WANG M, et al. Slime mould algorithm: a new method for stochastic optimization[J]. Future Generation Computer Systems, 2020, 111: 300 - 323.