DOI：10.16285/j.rsm.2024.0451

基于人工神经网络的黄土含水率光纤被动感测技术研究

郭旭辉[1]，朱鸿鹄[1,2]，吴 冰[1]，高宇新[1]，胡乐乐[1]，曹鼎峰[3]

（1. 南京大学 地球科学与工程学院，江苏 南京 210023；2. 江苏省大地感知与控灾工程研究中心，江苏 南京 210023；
3. 中山大学 土木工程学院，广东 珠海 519082）

摘 要：土体含水率时空分布的精准监测对于岩土工程监测、地质灾害防治具有重要意义。针对被动分布式温度传感（passive distributed temperature sensing，简称 PDTS）技术在监测土体含水率方面存在的局限性，引入斯皮尔曼相关性分析法，定量分析辐射、气温、升温速率、土体温度、含盐量与含水率之间的相关性，并结合误差反向传播网络（back propagation network，简称 BP 神经网络），建立了一个考虑水-热-盐综合作用的土体含水率被动感测模型，用以替代传统 PDTS 技术中复杂的数值迭代算法。此模型不仅扩展了 PDTS 技术的应用范围，还大幅提高了含水率预测的精度。在黄土高原开展了长期观测，利用原位观测数据验证了所提模型的有效性。分析结果表明：黄土含水率与其含盐量、温度之间的极强正相关关系可以实现深度上的互补，输入变量与含水率在 2 m 深度内存在显著的相关关系；模型可对黄土含水率进行精确预测，其均方根误差低于 0.006 8 $m^3 \cdot m^{-3}$；模型误差主要来源于降雨及土体冻融效应，且整体上呈现出冬季小、夏季大的特征。研究内容为将 PDTS 技术应用于土体含水率监测提供了理论支持和实践参考，并揭示了黄土水盐运移机制。

关 键 词：被动分布式温度传感（PDTS）；人工神经网络；含水率；水热盐运移；光纤布拉格光栅

中图分类号：TU 444 **文献标识码：**A **文章编号：**1000－7598 (2025) 02－653－12

Fiber optic passive sensing of loess moisture content based on artificial neural network

GUO Xu-hui[1], ZHU Hong-hu[1,2], WU Bing[1], GAO Yu-xin[1], HU Le-le[1], CAO Ding-feng[3]

(1. School of Earth Sciences and Engineering, Nanjing University, Nanjing, Jiangsu 210023, China;
2. Jiangsu Engineering Research Center of Earth Sensing and Disaster Control, Nanjing, Jiangsu 210023, China;
3. School of Civil Engineering, Sun Yat-sen University, Zhuhai, Guangdong 519082, China)

Abstract: Accurate monitoring of the spatiotemporal distribution of soil moisture content is crucial for geotechnical engineering monitoring and geological disaster prevention and control. Given the limitations of passive distributed temperature sensing (PDTS) technology in monitoring soil moisture content, the Spearman correlation coefficient method was introduced to quantitatively analyze the correlations among radiation, air temperature, warming slope, soil temperature, salinity, and moisture content. By incorporating the back propagation (BP) neural network, a passive sensing model for soil moisture is proposed. The model considers the comprehensive effects of water, heat, and salt and can replace the complex numerical iterative algorithm in traditional PDTS technology. This model not only expands the application scope of PDTS technology, but also significantly improves the accuracy of moisture content prediction. Long-term observations on the Loess Plateau in China verified the effectiveness of the proposed model using in-situ data. The analysis results indicate a strong positive correlation between loess moisture content and salinity, temperature, which can complement each other in depth. The input variables maintain a shallow soil moisture content with a root mean square error below 0.006 8 $m^3 \cdot m^{-3}$. The model's errors mainly arise from rainfall and soil freeze-thaw processes, which tend to be smaller in winter and larger in summer. This study provides important theoretical support and practical reference for applying PDTS technology to soil moisture content monitoring and reveals the water-salt migration mechanism in loess.

收稿日期：2024-04-14 录用日期：2024-07-09
基金项目：国家重点研发计划课题（No. 2023YFF1303501）；国家杰出青年科学基金（No. 42225702）；国家自然科学基金面上项目（No. 42077235）。
This work was supported by the National Key Research and Development Program of China (2023YFF1303501), the National Science Fund for Distinguished Young Scholars of China (42225702) and the General Program of National Natural Science Foundation of China (42077235).
第一作者简介：郭旭辉，男，1999 年生，硕士研究生，主要从事岩土水分光纤监测技术的研究工作。E-mail: guoxh@smail.nju.edu.cn
通讯作者：朱鸿鹄，男，1979 年生，博士，教授，博士生导师，主要从事地质工程、岩土力学方面的教学和研究工作。E-mail: zhh@nju.edu.cn

Keywords: passive distributed temperature sensing; artificial neural network; moisture content; hydrothermal-saline transport; fiber Bragg grating

1 引 言

土体含水率是岩土工程、水文地质、农业生产、生态环境等诸多领域评价土体物理力学性能的重要参考指标，该指标是影响非饱和土变形、强度和稳定性的关键变量[1]。掌握原位土体的含水率及其时空分布特征，对岩土工程建设和地质灾害防治都具有重要的意义[2]。在现阶段，利用分布式温度传感（distributed temperature sensing，简称 DTS）技术可以实现高时空分辨率的土体温度感知（时间分辨率小于 1 min，空间分辨率小于 1 cm）[3]，根据温度变化曲线可以推算出土体含水率[4-7]。这一技术具有分布式、长距离、防腐蚀、抗干扰等优点，近年来发展迅速，已在滑坡防治、地面沉降预测等领域显示出旺盛的应用潜力[8-9]。

根据热源类型，DTS 技术可被进一步细分为主动式（active DTS，简称 ADTS）和被动式（passive DTS，简称 PDTS）两类。当用于土体含水率监测时，ADTS 技术需要对埋入土体中的光缆施加电流热脉冲。虽然该方法测量精度更高[10-12]，但加热系统的野外用电困难和电流泄漏的风险导致其不适用于长期、长距离或大面积监测[13]，限制了其在岩土工程监测中的推广应用。相较而言，PDTS 技术不需要人为输入热脉冲能量，可以通过测量由昼夜辐射引起的近地表温度波动来推算土体湿度。然而，该方法面临三大困难，难以适用于复杂环境中土体含水率的连续监测[14-15]。首先，该技术的实施依赖太阳辐射，并极易受到天气、植被及光缆埋设深度的影响，限制其只适用于日间温度波动较大的时间段以及 30 cm 深度以内的地表附近；其次，该技术仅考虑升温速率这一含水率表征变量，忽略了大气温度、辐射强度、土体温度等含水率影响变量，且升温速率易受气象条件、土体类型的影响，因此这种做法限制了预测的准确性和可靠性；最后，该技术在估算含水率时使用的 MATLAB 频率搜索函数过于复杂且对环境变化敏感，时间变化周期的确定亦有挑战，物理边界条件和模拟周期的不当设置会导致较大的测试误差[13]。

近年来，人工神经网络（artificial neural network，简称 ANN）被应用到光纤信号的处理中，在大量的光纤监测数据中自动提取特征，识别出隐藏的关联和趋势，从而在不增加系统成本的情况下实现对地质体和岩土结构状态的准确评估与预测[16]。如 Liu 等[17]基于 ANN 建立了人工神经网络模型以修正主动加热光纤技术在含水率监测中的误差；Gao 等[18]结合 ANN 建立了光纤应变数据与地面沉降量的转换模型。

为了克服传统 DTS 技术在土体含水率监测方面的缺陷，本文引入斯皮尔曼相关性分析法，计算确定了与土体含水率密切相关的多个环境变量，并结合 ANN 建立了一种考虑水−热−盐综合作用的含水率被动感测模型。基于在黄土高原开展的长期观测示范，验证了该模型的有效性，为推动 PDTS 技术应用于土体含水率监测提供了理论支撑和参考依据。

2 含水率被动感测模型

2.1 输入变量选取

土体含水率受多种环境变量共同影响，气象条件直接控制着土中水分的蒸发和补充，而土体温度和含盐量则通过改变土体的渗透势，从而间接影响非饱和土中水分的运移过程，升温速率可以反映土体导热系数，进而推算含水率。故综合考虑大气温度 T_a、土体温度 T_s、升温速率 K、净辐射值 R、含盐量 S 这 5 个变量的影响，将其作为含水率被动感测模型的输入向量，可以降低模型在含水率预测中的误差。升温速率 K 是表征土体含水率的关键变量，其定义为

$$K=\frac{\mathrm{d}T(z,t)}{\mathrm{d}t} \tag{1}$$

式中：$T(z,t)$ 为土体特定深度 z 和时间 t 处的温度；t 为时间。

斯皮尔曼相关性分析法可以考虑变量之间关系的单调性，适用于反映自然环境变量之间近似单调的相关关系[19]。故本研究采用此方法来定量分析土体含水率与各环境变量之间的相关性。斯皮尔曼相关系数 ρ 定义为

$$\rho=\frac{\sum_{d}^{N}(R_d-\overline{R})(S_d-\overline{S})}{\sqrt{\sum_{d}^{N}(R_d-\overline{R})^2\sum_{d}^{N}(S_d-\overline{S})^2}} \tag{2}$$

式中：R_d、S_d 分别为变量 x、y 在各自顺序排列样本中第 d 个元素的秩次；$\overline{R}$ 和 $\overline{S}$ 分别为 R_d、S_d 的均值；N 为样本数量。

ρ 的取值范围在−1～1 之间，ρ 的正负表示两变量的相关方向，当 ρ 为负时，说明两变量呈负相关关系；当 ρ 为正时，说明两变量呈正相关关系。$|\rho|<0.2$ 时，表示两变量极弱相关或不相关；$0.2\leqslant$

$|\rho|<0.4$ 时，表示两变量弱相关；$0.4\leqslant|\rho|<0.6$ 时，表示两变量中度相关；$0.6\leqslant|\rho|<0.8$ 时，表示两变量强相关；$0.8\leqslant|\rho|<1$ 时，表示两变量极强相关[20]。

2.2　模型构建

由于 T_a、T_s、K、R、S 5 个变量可以影响或表征土体体积含水率 θ，且各输入变量与 θ 之间的关系通常是非线性的。因此，在构建含水率被动感测模型时，需要一个综合性方法来考虑所有相关因素并处理变量间的非线性关系。在现有的分析方法中，误差反向传播网络（back propagation network，简称 BP 神经网络）具有出色的自组织能力支持其通过反向传播算法，调整各层神经元权重，以减小模型误差；自学习能力支持其通过训练数据集进行学习，提取输入数据特征并自动学习，从而识别出与土体含水率相关的关键特征，提高模型的预测性能；自适应能力支持其通过自动调整输入参数，适应气象、土体温度等环境条件的变化，保持良好的预测性能[21-22]。因此，BP 神经网络可作为处理各输入变量与土体含水率间非线性关系的有效方法，本文基于 BP 神经网络，提出了一种考虑水-热-盐综合作用的含水率被动感测模型，以对传统 PDTS 含水率监测技术进行改进。

含水率被动感测模型的构建可由 MATLAB 的神经网络工具箱实现。模型由输入层、隐含层和输出层 3 层组成，将 T_a、T_s、K、R、S 5 个变量作为 BP 神经网络的输入向量，$\boldsymbol{\theta}$ 作为输出向量，建立一个网络结构为 5-M-1（其中，5 为输入层节点个数，M 为隐含层节点个数，1 为输出层节点个数）的含水率被动感测模型。其中，隐含层节点数 M 对 BP 神经网络的预测精度影响重大，数目过多容易出现过拟合现象，数目过少又会降低模型性能[23]。因此，先利用经验公式确定 M 的范围，再用试凑法来确定网络隐含层中神经元的最佳数量。隐含层神经元个数范围可按如下经验公式确定：

$$m=\sqrt{a+b}+q \tag{3}$$

式中：m 为隐含层神经元个数；a 为输入层神经元个数；b 为输出层神经元个数；q 为常数，取值在 0～10 之间。

根据式（3），本模型隐含层的神经元个数在 3～13 个为宜，故本模型采用 3～13 个隐含层的神经元个数对各深度 θ 进行预测，并以训练集归一化后的根均方误差 R_{MSE} 最小值作为确定最佳隐含层节点数量的依据，BP 神经网络拓扑结构如图 1 所示，图中 W_{ij} 为输入层第 i 个神经元节点与隐含层第 j 个神经元节点之间连接权值，V_j 为隐含层第 j 个神经元节点与输出层神经元节点之间连接权值。

模型包括训练和预测两个部分。神经网络训练前，为了能够达到更加精准的预测结果，需要对试验数据进行量纲归一化处理，使得各个维度不同的数据统一转化到 0～1 区间内，以此来消除各输入样本之间数量级的差异。目前最常用的量纲归一化处理方法为最大最小法，该方法的计算式为

$$x_u'=\frac{x_u-x_{\min}}{x_{\max}-x_{\min}} \tag{4}$$

式中：x_u 和 x_u' 分别为第 u 个样本归一化前、后的数据；$x_{\max}$ 和 $x_{\min}$ 分别为样本数据 x_u 的最大、最小值。

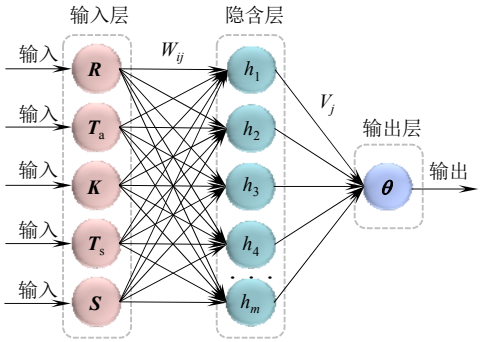

图 1　BP 神经网络结构

Fig.1　BP neural network structure

2.3　模型输入变量相对重要性评价指标

在模型构建与优化过程中，对输入变量的相对重要性进行定量分析有助于识别出对模型输出贡献较小的变量。通过明确这些次优变量的层级，可以有选择性地将其排除，以节约监测成本、简化模型结构并提高计算效率。

Olden 法是一种评估各个输入变量对输出变量影响程度的方法，称为连接权值法（connection weight approach），可以准确量化变量的重要性。本研究采用 Olden 法对土体不同深度处的输入变量进行相对重要性分析，输入变量 x_i 对输出变量 θ 的相对影响程度可由 O_i 表示：

$$O_i=\frac{\sum_{j=1}^{m}W_{ij}V_j}{\sum_{i=1}^{5}\sum_{j=1}^{m}W_{ij}V_j} \tag{5}$$

式中：O_i 为输入变量 x_i 对 θ 的敏感性指标值，O_i 的值越大，则该变量对相关的测试指标的影响程度越大。

2.4　模型预测结果评价指标

决定系数 R^2、均方根误差 R_{MSE}、平均绝对误

差 M_{AE} 这 3 项指标常用来衡量模型的含水率预测精度。因此，本文采用上述 3 项指标来评价模型预测性能，各评价指标计算公式为

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(Y_i - y_i)^2}{\sum_{i=1}^{n}(Y_i - \bar{y})^2} \tag{6}$$

$$R_{MSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(Y_i - y_i)^2} \tag{7}$$

$$M_{AE} = \frac{1}{n}\sum_{i=1}^{n}|Y_i - y_i| \tag{8}$$

式中：y_i 为含水率监测数据；Y_i 为含水率预测数据；$\bar{y}$ 为含水率监测值的平均值；n 为含水率预测值的数量。当 R^2 越接近于 1，R_{MSE}、M_{AE} 两项指标越小时，含水率预测效果越好。

3 数据集建立

3.1 场地概况

为了验证本文模型的有效性，2020 年 12 月 13 日至 2023 年 2 月 15 日期间，于甘肃省白银市会宁县（35° 36′21″N，104° 58′47″E）开展了黄土高原多场分布式光纤综合观测示范。监测场地为裸土覆盖区，研究区域深度 H 为 2 m。该场地位于黄土高原西南部，为典型的黄土塬地区，土体为第四纪黄土，厚度为 10～20 m，以低塑性粉质黏土为主，级配曲线如图 2 所示，图中，D_{10}、D_{30}、D_{60} 分别为有效粒径、中值粒径和限制粒径。土体的主要物理参数见表 1。研究区属中温带半干旱气候，年平均降水量为 180～450 mm，集中在 7—9 月，年平均气温为 6～9 ℃。历史上，该研究区记录的最低气温为−23.3 ℃，最大土体冻结深度约为 100 cm[24-25]。该区域河川径流量少，地下水埋藏很深，地下水位在 30 m 以下。因此，降雨是该地黄土水分的主要补给来源。监测场地地势平坦，除有大暴雨导致地表积水产生径流排泄外，蒸发是地表水以及土体水分的主要排泄途径[26]。

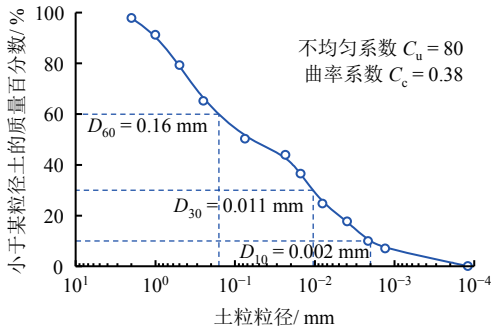

图 2 黄土颗粒级配曲线

Fig.2 Particle size distribution of the loess

表 1 黄土基本物理参数

Table 1 Basic physical parameters of the loess

干密度 ρ_d / (g·cm^{-3})	渗透系数 k / (m·s^{-1})	最优含水率 θ_{opt} / (m^3·m^{-3})	饱和含水率 θ_s / (m^3·m^{-3})	塑限 ω_P / %	液限 ω_L / %
1.42	8.02×10^{-8}	0.196	0.395	24.5	36.9

3.2 监测设置

图 3 为监测场地内各类设备的布置图。在整个监测期间，采用武汉中科能慧科技发展有限公司生产的 NH148-40 型时域反射（time domain reflectometry，简称 TDR）传感器实时采集土体的含水率、温度和含盐量。7 个测点分别位于土体深度 10、20、40、60、100、150、200 cm 处，数据采集周期为 5 min。

同时，采用课题组研制的主动加热光纤布拉格光栅（actively heated fiber Bragg grating，简称 AH-FBG）传感器获取土体温度。由于监测系统包含 AH-FBG 与 TDR 两类测温传感器，所以在模型训练及土体温度云图绘制中综合采用两类传感器所测土体深度（10、20、40、60、80、100、120、150、200 cm）处的土体温度数据。AH-FBG 传感器由准分布式光纤布拉格光栅、电阻丝、刚玉管和不锈钢套管组成，总长为 130 cm，测温精度为 0.1 ℃，测温范围为−40～60 ℃[27]。现场布设的光纤布拉格光栅共有 6 个测点，间距为 20 cm，分别位于土体深度 20、40、60、80、100、120 cm 处。光纤布拉格光栅的测温原理为依据布拉格光栅反射光信号的中心波长和温度之间的线性关系，通过解调仪读取中

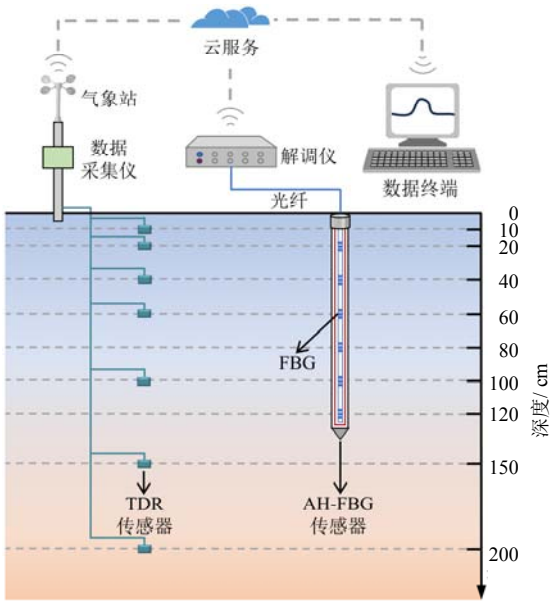

图 3 原位监测系统布设示意图

Fig.3 Schematic diagram of in-situ monitoring platform

心波长来推算温度。对于不受应变影响的松弛光纤，其中心波长仅对温度变化敏感，即

$$\Delta T=\frac{\Delta\lambda_{\mathrm{B}}}{\lambda_{\mathrm{B}}(\alpha_{\mathrm{F}}+\xi)} \tag{9}$$

式中：ΔT 为温度变化量；λ_{B} 为反射光中心波长；$\Delta\lambda_{\mathrm{B}}$ 为反射光中心波长的变化量；α_{F} 为光纤的线性热膨胀系数；ξ 为光纤的热光系数。α_{F} 和 ξ 的取值可通过室内标定试验确定。将 AH-FBG 传感器连接至光纤解调仪，在整个监测周期内设置温度采集周期为 10 s。需要指出的是，由于本文仅研究 PDTS 技术，因此未对电阻丝进行通电加热。

此外，由无线气象站连续采集气温、净辐射值、降雨量等气象数据。上述所有设备的监测数据均通过云端传输到数据处理中心，从而实现远程地下多场信息的实时传输、处理、分析和显示。

3.3　参数选取

本研究涉及到的参数有输入变量（T_{a}、T_{s}、K、R、S）和输出变量（θ）两类，由于 T_{s}、K、S、θ 受土体深度影响显著，故依据变量监测深度将其划分为 7 组变量，分别为 T_{sH}、K_H、S_H、θ_H（H = 10、20、40、60、100、150、200 cm），采用 2020 年 12 月 13 日至 2023 年 2 月 15 日的数据，以 0.5 h 作为数据间隔，除去 TDR 采集仪因遇水故障而空缺数据的时间段，共有 35 945 个时刻的相关数据。表 2 为土体体积含水率数据的统计特性。将 35 945 个时刻的气象因素（T_{a}、R）与深度的土体参数（T_{sH}、K_H、S_H、θ_H）组成 7 组原始数据库，并采用随机抽样原则将每组数据库划分为训练集和测试集。使用训练集数据库（70%数据）训练模型，测试集数据库（30%数据）验证模型。

表 2　土体体积含水率的统计特性

Table 2　Statistical characteristics of soil volumetric moisture content

深度 H / cm	土体体积含水率/ ($m^3 \cdot m^{-3}$)		
	平均值	最大值	最小值
10	0.080 79	0.164 79	0.019 52
20	0.089 60	0.146 13	0.035 43
40	0.106 81	0.153 76	0.045 36
60	0.129 80	0.173 21	0.074 41
100	0.153 71	0.179 23	0.118 56
150	0.242 99	0.259 03	0.227 12
200	0.215 51	0.223 84	0.204 95

4　结果分析

4.1　相关性分析

图 4 显示了气象因素（T_{a}、R）与土体参数（T_{sH}、K_H、S_H、θ_H）之间的 ρ 值，图中圆形表示各变量之间的相关性，P 用来衡量变量之间的相关性是否由于随机性造成，较低的 P 值（P<0.05）表明相关性显著，即变量之间的 ρ 值可靠。总体而言，变量之间的相关性并非恒定不变，而是随着土体深度的增加而发生变化。

变量之间的相关性通常表现为正相关性，尽管存在少数负相关的例子，但它们的相关性通常为弱

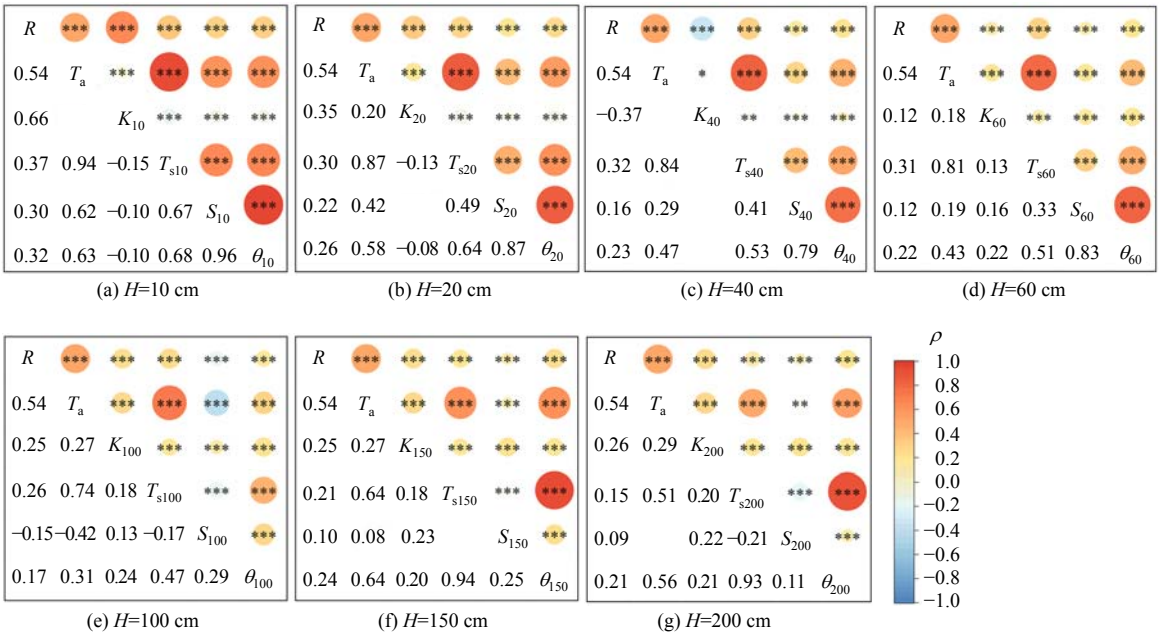

注：***表示极显著相关（P<0.001）；**表示高显著相关（P<0.01）；*表示显著相关（P<0.05）。

图 4　不同深度处各变量间斯皮尔曼相关系数

Fig.4　Spearman correlation coefficients of different variables at different depths

或极弱相关。首先，采用 T_a、R 与 T_{sH}、K_H 之间的 ρ 值来说明陆-气相互作用。分析可知，T_a 与 T_s 的相关性普遍较高且随着深度增加而降低，在土体 60 cm 以上范围内为极强正相关关系，说明 T_s 与 T_a 密切相关，在地表附近尤其显著，直观地反映了 T_a 能够有效地通过土体传导，对 T_s 产生显著影响。相比之下，R 与 T_s 的相关性很低，为弱相关（$\rho<0.37$）；但 R 与 K_{10} 之间的强相关性（$\rho=0.66$）表明，在日照充足的情况下，净辐射是影响近地表层温度变化的主要驱动力，然而，这种强相关性只存在于 10 cm 以上的表层土体，随着深度的增加，相关性急剧下降，转变为弱相关或不相关。

其次，采用 T_{sH}、S_H、θ_H 之间的 ρ 值来说明土体内部的水-热-盐相互作用。ρ 值随土体深度的复杂变化表明了土体水-热-盐相互作用的高空间异质性。对于水-热相互作用，θ 与 T_s 在所有深度上显示出中等以上的正相关关系，特别是在土体深度 150～200 cm 范围内显示出极强的正相关关系（$\rho>0.93$），说明在深层土体处，土体水分起着较为稳定的冷却作用，从而对土体温度产生了潜在的调节作用；对于水-盐相互作用，θ 与 S 在土体深度 60 cm 以上范围内为极强正相关关系，然而，在更深层的土体中，两者之间的相关关系不显著；对于热-盐相互作用，T_s 与 S 仅在土体深度 20 cm 以上显示出中等正相关关系，但这种相关性随着土体深度增加而减弱，并在 100 cm 深度以下变为极弱或无相关性。

综上所述，水-盐、水-热的相互作用在水-热-盐相互作用中占主导地位，且水-盐在土体深度 100 cm 以上范围内的极强正相关关系和水-热在土体深度 100～200 cm 范围内的极强正相关关系可以实现深度上的互补，以确保输入变量整体上对 200 cm 深度范围内的 θ 保持显著的相关关系。

4.2 模型含水率预测效果

采用含水率被动感测模型对 7 组数据进行训练，将每组数据的 $\boldsymbol{T}_a$、$\boldsymbol{R}$、$\boldsymbol{T}_{sH}$、$\boldsymbol{K}_H$、$\boldsymbol{S}_H$ 作为输入向量，$\boldsymbol{\theta}_H$ 作为输出向量，每组测试集（30%数据）生成 10 783 个体积含水率预测值。将模型预测 θ_A 与 TDR 传感器测量 θ_T 的含水率进行比较并生成模型预测性能指标，各深度土层所对应的最佳隐含层神经元个数及测试集预测性能指标如表 3 所示。

为了判定含水率被动感测模型对于各深度土体的适用性，本节将评估回归模型拟合优度的统计指标 R^2 作为模型预测效果的分级指标，以 $R^2=0.99$、0.95 将 7 组土体深度的含水率预测效果分为 3 个梯度，并对每个梯度的数据的 R_{MSE}、M_{AE} 进行综合计算，结果如图 5 所示。

表 3 隐含层神经元个数与评估指标详情

Table 3 Number of neurons and details of evaluation metrics

深度 H / cm	隐含层神经元个数/个	R^2	R_{MSE} / ($m^3 \cdot m^{-3}$)	M_{AE} / ($m^3 \cdot m^{-3}$)
10	13	0.960 79	0.006 72	0.004 72
20	12	0.982 92	0.003 73	0.002 53
40	11	0.970 15	0.005 22	0.003 55
60	12	0.967 43	0.004 31	0.003 24
100	13	0.817 67	0.003 39	0.002 29
150	13	0.998 26	0.000 38	0.000 30
200	13	0.993 72	0.000 36	0.000 27

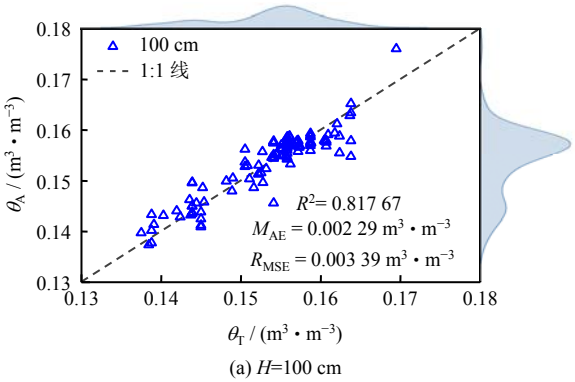

(a) H=100 cm

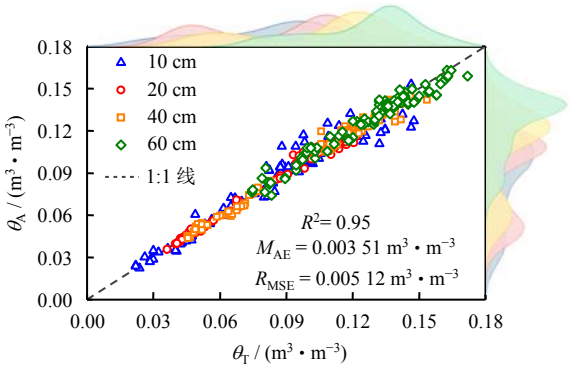

(b) H=10、20、40、60 cm

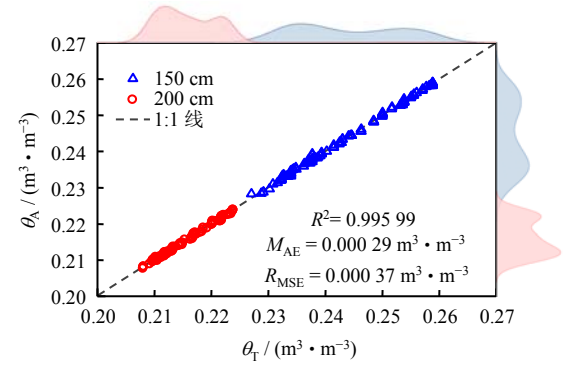

(c) H=150、200 cm

图 5 体积含水率模型预测值 θ_A 和 TDR 传感器测量值 θ_T 的比较

Fig.5 Comparison of volumetric water content between predicted values of model θ_A and observations from TDR sensors θ_T

图 5 显示，模型在土体深度 100 cm 处的 R^2 较低，因为该深度位于冻结锋面附近，冻融过程中的冰水相变，加剧了该区域范围内的含水率变化，其次相变过程中复杂的热量变化及盐分的结晶与溶解，也降低了各因素与含水率的关联性，使得土体深度 100 cm 处模型的 R^2 较低。虽然土体深度 100 cm 处的 R^2 较低，但由于土体的含水率变化范围随着土体深度的增加而减小，该深度处的 R_{MSE}、M_{AE} 依然较低，说明模型误差依然较小，含水率被动感测模型在该深度处仍有较高的适用性。除土体深度 100 cm 处的 R^2 较低外，其余各深度处的评价指标都显示出模型良好的预测效果，所有土体深度处的 R_{MSE} 和 M_{AE} 值均较小（低于 0.006 8 $\mathrm{m^3 \cdot m^{-3}}$），特别是在土体深度 150、200 cm 处，两者值非常低（低于 0.000 38 $\mathrm{m^3 \cdot m^{-3}}$）。$R_{\mathrm{MSE}}$ 和 M_{AE} 两评价指标值均较小且规律一致，表明模型整体上预测的精确性很高。对于土体深度 10、20、40、60 cm 处，R^2 均大于 0.95，可准确预测土体含水率，且该深度范围内模型对低含水率（$\theta < 0.09\ \mathrm{m^3 \cdot m^{-3}}$）土体的含水率预测效果更好；对于土体深度 150、200 cm 处，R^2 均大于 0.99，可精确预测土体含水率。图 6 中阴影部分表示 θ 在不同深度的聚集程度，初步显示了土体含水率沿着深度的变化范围和分布特征。

综合分析 R^2、R_{MSE} 和 M_{AE} 3 项指标可知，含水率被动感测模型对于 2 m 深度范围内的土体含水率有着良好的预测效果，尤其对深层土体（150～200 cm）有着极高的预测精度。

4.3　模型参数重要性分析

本节采用 Olden 法对 7 组深度的模型输入变量进行了相对重要性分析，结果如图 6 所示。模型量化了 7 组深度输入变量对模型预测精度的影响程度。分析可得，S_H、T_{sH} 对于各土体深度的模型预测精度均具有高度影响且相对稳定，其中 T_{s60} 对于模型预测精度的影响最为显著（相对重要性为 53.8%）；除 K_{60} 影响权重较小外，K_H 对其余土体深度的模型预测精度有着中等程度的影响且相对稳定；T_{a}、R 对模型预测精度的影响在土体不同深度处存在明显差异。随土体深度的增加，两者的影响权重均呈现出先降低后增加的趋势，除土体深度 10、200 cm 处为中等影响权重外，其余深度处影响权重极小，T_{a} 对 θ 的影响权重整体上大于 R。

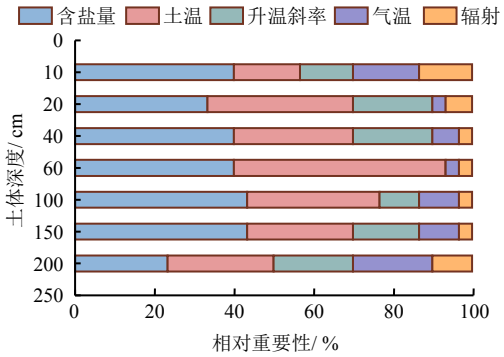

图 6　模型输入变量相对重要性

Fig.6　Relative importance of model variables

计算各深度处输入变量对模型预测精度的影响权重的平均值，分析其对模型整体预测精度的影响可得，影响含水率被动感测模型预测精度的关键因素为 T_{sH}、S_H，平均相对重要性大于 30%；重要因素为 K_H，平均相对重要性为 15%；次要因素为 T_{a}、R，平均相对重要性小于 10%。

4.4　含水率预测误差时空分析

为探究模型含水率预测误差的影响因素及其分布规律，采用数据交错分组的方法划分训练集（75%）和测试集（25%），从而生成全范围时间段内呈规律（以 2 h 为间隔）分布的 θ_{A}，将 θ_{A} 减去 θ_{T}，得到预测含水率的绝对误差 $\Delta\theta$。图 7 显示了 $\Delta\theta$ 的时空分布情况，由于缺失部分时间段的 θ_{T} 数据，图中对应时间段的 $\Delta\theta$ 空缺。

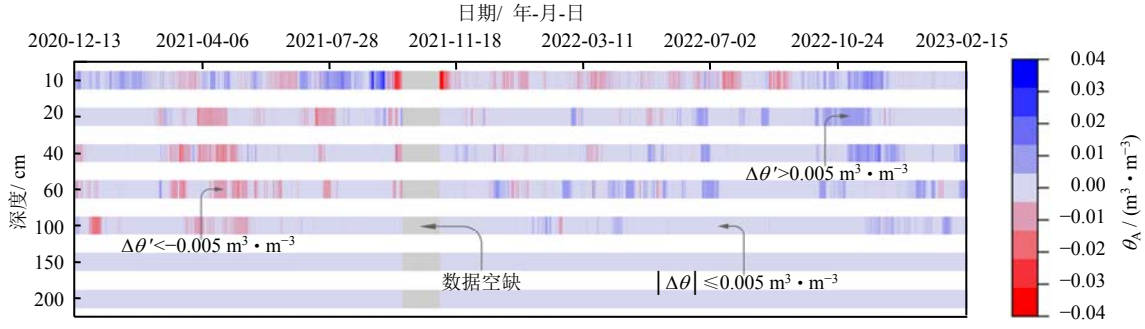

图 7　含水率预测误差时空分布

Fig.7　Distribution of water content prediction errors

由图 7 可知，$\Delta\theta$ 整体较小且分布较为规律，其中，$|\Delta\theta| \leqslant 0.005\ \mathrm{m^3 \cdot m^{-3}}$ 分布最为广泛，说明模型整体预测精度较高。在之后的分析中仅对较大误差 $\Delta\theta'$（$|\Delta\theta| > 0.005\ \mathrm{m^3 \cdot m^{-3}}$）的成因进行探究。分析可知，$\Delta\theta'$ 最大值（$|\Delta\theta| = 0.038\ 6\ \mathrm{m^3 \cdot m^{-3}}$）出现在土体深度 10 cm 处且该深度处$\Delta\theta'$分布最为密集。结合图 7 和图 8(a)可知，土体深度 10 cm 处 $\Delta\theta'$ 多集中于降雨时间段范围内，$|\Delta\theta|$ 峰值出现于降雨事件前后并随着土体干燥而逐渐减小（如图 7 中的 2021 年 9 月 23 日），这是由于表层土体含水率易受降雨入渗及水分蒸发的影响。由于黄土的低渗透系数决定了降水过程中雨水的入渗量十分有限，且研究区属于冬季降雨量低的中温带半干旱气候，故降雨对模型误差的显著影响多存在于夏季时间范围内 10 cm 深度以上的表层土体。土体深度 20 cm 以下 $\Delta\theta'$ 较小且相对集中，多分布于土体温度 0 ℃以上的时间段，进一步分析发现，由于冻土区域内部液态水含量较低且土体含水率相对稳定，土体处于冻结状态时 $|\Delta\theta|$ 显著降低；土体温度穿越 0 ℃时的土体冻结和融化过程是模型出现 $\Delta\theta'$ 的高峰期。这是由于研究区位于季节性冻土区，当土体温度达到 0 ℃以下时，土体中部分水发生冻结，冰水相变过程极大地影响了土体中液态水和固态水的分布。此时 TDR 传感器测量的是土体中未被冻结的水分含量，这与总含水率之间存在由于含冰量产生的误差，从而造成当水结冰时模型 $\Delta\theta$ 正增长，而当冰融化为水时模型 $\Delta\theta$ 负增长的现象[26]，这表明了冰水相变是造成模型预测误差的主要原因。由于在深层土体（150～200 cm）中，土体温度大于 0 ℃，不涉及土体的冻融过程且土体含水率变化范围较小，使得全范围时间段内 $\Delta\theta$ 较小（$|\Delta\theta| < 0.005\ \mathrm{m^3 \cdot m^{-3}}$）。

综上所述，降雨是影响土体深度 10 cm 以上表层含水率预测误差的主要因素，土体的冻融过程是影响土体深度 100 cm 以上含水率预测误差的主要因素。土体深度 100 cm 以上的含水率预测误差 $\Delta\theta'$ 整体上呈现出冬季稀疏、夏季密集的特点。

4.5 试验区地下多物理场时空演化规律

前文已经验证了含水率被动感测模型的适用性，本节将模型预测所得的土体含水率时空分布（见图 8(d)）与气象数据、土体温度场、盐分场进行综合分析，进一步探究黄土的水–热–盐迁徙规律及相互作用机制。

首先，对土体温度而言，其热量主要来源于太阳辐射，土体和大气间随时都存在热量交换，地温变化与气温变化有较好的一致性并随着深度的增加而减弱。图 8(a)、8(b)中土体温度与气温呈现出同步变化趋势，说明了土体温度对大气的响应。此外，气温于 2021 年 7 月 31 日 16:00 达到年峰值，而土体温度 T_{s10}、T_{s20} 达到峰值的时间分别比其晚了 1.5、5 h，说明土体温度对气温的响应存在滞后效应，这归因于热传导的时间消耗。除气温外，降雨事件会引起地表土体温度的显著降低，其降温程度与降雨强度正相关[28]。近似认为土体温度稳定处于 0 ℃以下时，土体进入冻结状态，图 8(b)中的 T_0 等温线所处深度即为冻结锋面，土体最大冻结深度为 82.02 cm。综合分析图 8(b)～8(d)可知，土体温度在穿越 0 ℃时，土体含水率及含盐量会发生显著变化，其中，冻结期的土体含水率及含盐量低，融化期的土体含水率及含盐量高，土体含水率及含盐量的变化趋势一致进一步说明了两者间存在显著的正相关关系。

其次，对土体含水率而言，土体深度 20 cm 以上的 θ 对时间最灵敏，变化幅度随土层深度增加而减小。冻结期随着气温下降，表层土体开始冻结，随着冻层不断加厚，冻层内的储冰量增加，下层含水率减小。Miller[29]将土体划分为冻结区、冻结边缘区和未冻结区。由图 8(b)、8(d)可知，位于 T_0 等温线以下冻结边缘区内的土体含水率很低，故难以发生冻胀，但该区域冰水相变更为剧烈且存在温度梯度，未冻结区中水分不断向冻层移动，携带着盐分运移至冻结区聚集并形成结晶。解冻期较短，约 7 d 左右，消融过程中，冻层的冰以及表层积雪的融化淋溶盐分，使表层含盐量降低。黄土水–盐之间显著的正相关关系主要集中在土体深度 80 cm 以上范围内。由图 8(b)、8(c)可知，土体深度 80 cm 以上范围内，土体温度小于 0 ℃时，土体温度与土体含水率及含盐量呈正相关关系；土体温度大于 0 ℃时，土体温度与土体含水率及含盐量间无显著相关关系。由图 8(c)、8(d)可知，土体含水率与含盐量的空间分布模式存在着较强的相似性，土体含水率较高的区域含盐量一般较高（夏季表层土体），土体含水率相对较低的区域含盐量相对较小（冬季表层土体），说明土体含水率与含盐量呈正相关关系。在土体深度 80 cm 以下范围内的土层中，土体含水率和含盐量趋于稳定，变化程度较低。

综上所述，土体温度是影响土体水分冰水相变和运移的直接因素[30]。土体水分既是盐分的溶剂，又是盐分的载体，冰水相变影响着盐分结晶和溶解，水分运移决定着盐分运移的方向和数量[31-32]。因此，土体温度对土体水盐变化起着决定性作用，是土体

水分运移的直接影响因素，是土体盐分运移的间接　　影响因素。

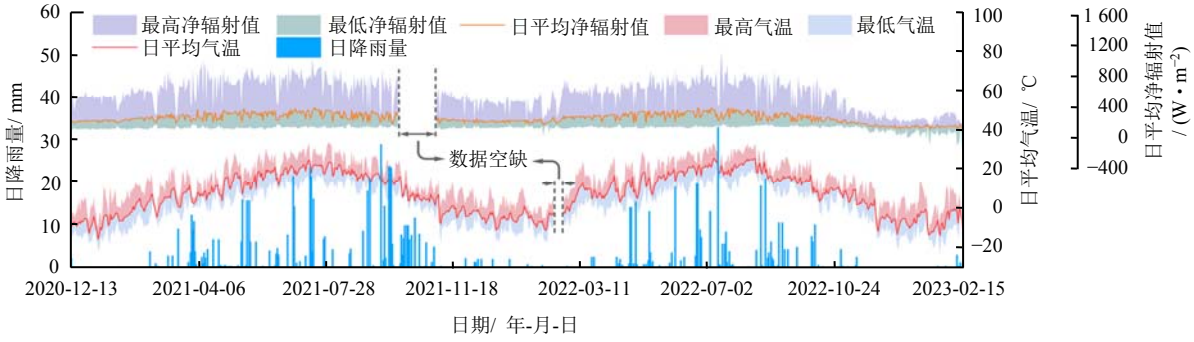

(a) 净辐射、气温及降雨事件

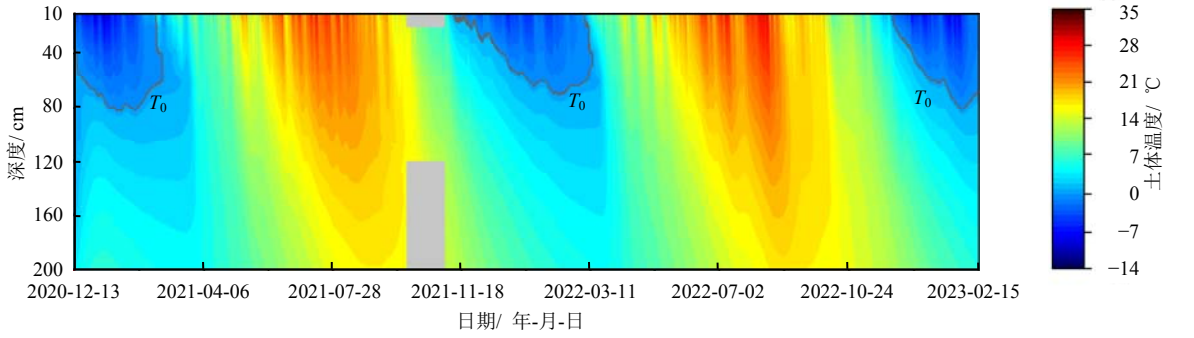

(b) 土体温度

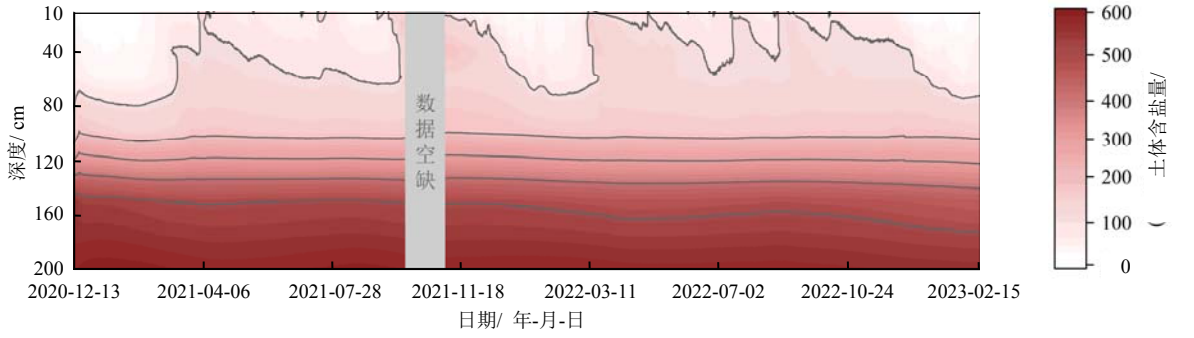

(c) 土体含盐量

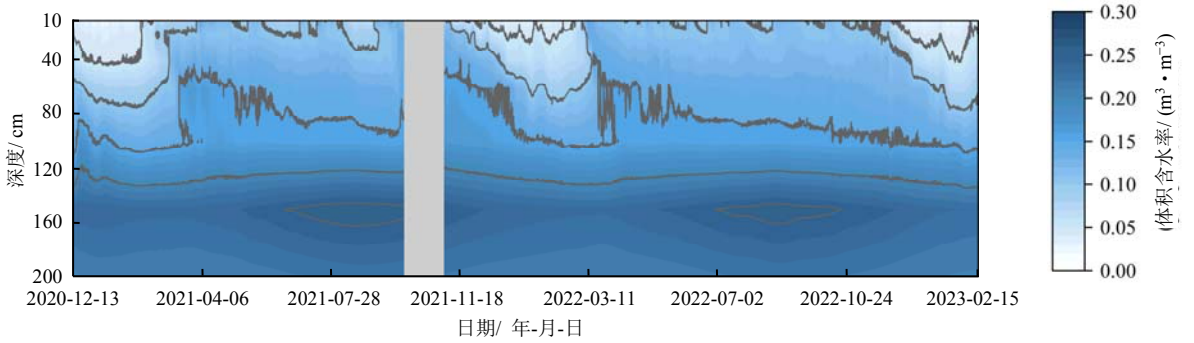

(d) 体积含水率

图 8　气象记录及地下多物理场时空演化

Fig.8　Meteorological records and spatiotemporal evolution of subsurface multi-physics

5 结 论

本文考虑了被动分布式温度传感在监测土体体积含水率时水−热−盐的综合作用，改进了推算含水率的计算方法，建立了一种考虑水−热−盐综合作用的含水率被动感测模型。以甘肃会宁监测站原位监测数据为算例，实现了土体深度 2 m 范围内含水率的精准预测，验证了被动分布式温度传感技术大面积监测黄土含水率的可行性。得出主要结论如下：

（1）输入变量整体上与土体深度 200 cm 范围内的含水率存在极强的相关关系（$\rho > 0.8$）。其中，水−盐在土体深度 100 cm 以上范围内的极强正相关关系和水−热在土体深度 100～200 cm 范围内的极强正相关关系占主导地位。土体温度、含盐量对土体含水率预测精度的影响程度最大，平均相对重要性均大于 30%。

（2）含水率被动感测模型可实现深度 200 cm 范围内裸露土体含水率的精准预测。监测精度整体上随着土体深度的增加而增加。土体深度 10 cm 处 R_{MSE} 最大，为 0.006 72 $\mathrm{m^3 \cdot m^{-3}}$；土体深度 200 cm 处 R_{MSE} 最小，为 0.000 36 $\mathrm{m^3 \cdot m^{-3}}$。

（3）降雨是引起土体深度 10 cm 范围内预测误差的主要因素，冻融作用是引起土体深度 100 cm 范围内预测误差的主要因素，模型误差存在冬季小、夏季大的特点。

（4）土体温度对土体水盐变化起着决定性作用，是土体水分运移的直接影响因素，是土体盐分运移的间接影响因素。研究区土体最大冻结深度为 82 cm，土体含水率与含盐量在土体深度 80 cm 范围内的空间分布模式存在着较强的相似性且变化程度较大，在土体深度 80 cm 以下范围内的土层中，土体含水率和含盐量趋于稳定，变化程度较低。

本文提出的含水率被动感测模型可以进行土体含水率智能模拟和精准预测。然而，受限于土体冻结边缘处复杂物理场所带来的潜在误差，该模型对于冬季冻结边缘区的预测效果有待进一步验证和提升。同时，本文采用的数据均来自于甘肃会宁监测现场，由于土体水分运移与自然环境及土地类型关系紧密，在不同场地条件使用模型时应根据区域特征选择输入变量。由于土体温度、含盐量与土体含水率关系密切，对模型预测精度有高度影响；升温速率可以通过土体温度数据间接获取，对模型预测精度有中等程度影响。因此，建议将土体温度、含盐量、升温速率作为通用输入变量，将其他区域特征变量作为补充输入变量，通过本地数据对模型进行训练，以准确预测土体含水率。

参 考 文 献

[1] 刘喜凤, 朱鸿鹄, 王家琛, 等. 基于神经网络的改进型土壤水分光纤感测技术研究[J]. 岩土工程学报, 2022, 44(9): 1721-1729, 11.
LIU Xi-feng, ZHU Hong-hu, WANG Jia-chen, et al. Improved fiber optic sensing technology of soil moisture based on neural network[J]. **Chinese Journal of Geotechnical Engineering**, 2022, 44(9): 1721-1729, 11.

[2] 钟鹏, 施斌, 郝瑞, 等. 支持向量回归算法在土体含水率 AHFO 测试中的应用研究[J]. 工程地质学报, 2023, 31(1): 60-67.
ZHONG Peng, SHI Bin, HAO Rui, et al. Application research of support vector regression algorithm in AHFO test of soil water content[J]. **Journal of Engineering Geology**, 2023, 31(1): 60-67.

[3] SELKER J S, THÉVENAZ L, HUWALD H, et al. Distributed fiber-optic temperature sensing for hydrologic systems[J]. **Water Resources Research**, 2006, 42(12): W12202.

[4] WEISS J D. Using fiber optics to detect moisture intrusion into a landfill cap consisting of a vegetative soil barrier[J]. **Journal of the Air & Waste Management Association**, 2003, 53(9): 1130-1148.

[5] SAYDE C, BUELGA J B, RODRIGUEZ-SINOBAS L, et al. Mapping variability of soil water content and flux across 1–1 000 m scales using the actively heated fiber optic method[J]. **Water Resources Research**, 2014, 50(9): 7302-7317.

[6] 郭君仪, 孙梦雅, 施斌, 等. 不同环境温度下土体含水率主动加热光纤法监测试验研究[J]. 岩土力学, 2020, 41(12): 4137-4144.
GUO Jun-yi, SUN Meng-ya, SHI Bin, et al. Experimental study of water content in soils monitored with active heated fiber optic method at different ambient temperatures[J]. **Rock and Soil Mechanics**, 2020, 41(12): 4137-4144.

[7] 吴冰, 朱鸿鹄, 曹鼎峰, 等. 黄土水分场光纤原位监测及非饱和渗透系数估算[J]. 防灾减灾工程学报, 2019, 39(5): 691-699.
WU Bing, ZHU Hong-hu, CAO Ding-feng, et al. In-situ monitoring of moisture field and estimation of unsaturated permeability coefficient of loess foundation[J]. **Journal of Disaster Prevention and**

Mitigation Engineering, 2019, 39(5): 691-699.

[8] DOBRIYAL P, QURESHI A, BADOLA R, et al. A review of the methods available for estimating soil moisture and its implications for water resource management[J]. **Journal of Hydrology**, 2012, 458: 110-117.

[9] SU S L, SINGH D N, BAGHINI M S. A critical review of soil moisture measurement[J]. **Measurement**, 2014, 54(8): 92-105.

[10] CIOCCA F, LUNATI I, DE GIESEN N V, et al. Heated optical fiber for distributed soil-moisture measurements: a lysimeter experiment[J]. **Vadose Zone Journal**, 2012, 11(4): 1-10.

[11] STRIEGL A M, LOHEIDE S P, LOHEIDEII S P. Heated distributed temperature sensing for field scale soil moisture monitoring[J]. **Groundwater**, 2012, 50(3): 340-347.

[12] SAYDE C, GREGORY C, GIL-RODRIGUEZ M, et al. Feasibility of soil moisture monitoring with heated fiber optics[J]. **Water Resources Research**, 2010, 46(6): W06201.

[13] CAO D F, ZHU H H, GUO C C, et al. Passive distributed temperature sensing (PDTS)-based moisture content estimation in agricultural soils under different vegetative canopies[J]. **Paddy and Water Environment**, 2021, 19: 383-393.

[14] STEELE-DUNNE S C, RUTTEN M M, KRZEMINSKA D M, et al. Feasibility of soil moisture estimation using passive distributed temperature sensing[J]. **Water Resources Research**, 2010, 46(3): 1-12.

[15] 胡优, 李敏, 任姮烨, 等. 基于加热光纤分布式温度传感器的土壤含水率测定方法[J].农业工程学报, 2019, 35(10): 42-49.
HU You, LI Min, REN Heng-ye, et al. Soil moisture determination method based on heated fiber-optic distributed temperature sensing[J]. **Transactions of the Chinese Society of Agricultural Engineering**, 2019, 35(10): 42-49.

[16] KARAPANAGIOTIS C, KREBBER K. Machine learning approaches in brillouin distributed fiber optic sensors[J]. **Sensors**, 2023, 23(13): 6187.

[17] LIU X F, ZHU H H, WU B, et al. Artificial intelligence-based fiber optic sensing for soil moisture measurement with different cover conditions[J]. **Measurement**, 2023, 206: 112312.

[18] GAO Y X, ZHU H H, QIAO L, et al. Feasibility study on sinkhole monitoring with fiber optic strain sensing nerves[J]. **Journal of Rock Mechanics and Geotechnical Engineering**, 2023, 15(11): 3059-3070.

[19] XING C, LIU M, PENG J, et al. Disturbance frequency trajectory prediction in power systems based on LightGBM spearman[J]. **Electronics**, 2024, 13(3): 597.

[20] 王佳, 朱鸿鹄, 叶霄, 等. 考虑时滞效应的库区滑坡位移预测——以新铺滑坡为例[J]. 工程地质学报, 2022, 30(5): 1609-1619.
WANG Jia, ZHU Hong-hu, YE Xiao, et al. Prediction of reservoir landslide displacements considering time lag effect—a case study of the Xinpu landslide in the Three Gorges reservoir area, China[J]. **Journal of Engineering Geology**, 2022, 30(5): 1609-1619.

[21] BASHEER I A, HAJMEER M. Artificial neural networks: fundamentals, computing, design, and application[J]. **Journal of Microbiological Methods**, 2000, 43(1): 3-31.

[22] 李双成, 郑度. 人工神经网络模型在地学研究中的应用进展[J]. 地球科学进展, 2003, 18(1): 68-76.
LI Shuang-cheng, ZHENG Du. Progress in the application of artificial neural network models in geological research[J]. **Advance in Earth Sciences**, 2003, 18(1): 68-76.

[23] WANG C. Research on GPS height partition fitting method[J]. **Applied Mechanics and Materials**, 2014, 580: 2860-2864.

[24] WANG T, LI P, LI Z, et al. The effects of freeze-thaw process on soil water migration in dam and slope farmland on the Loess Plateau, China[J]. **Science of the Total Environment**, 2019, 666: 721-730.

[25] CAO D F, ZHU H H, WU B, et al. Investigating temperature and moisture profiles of seasonally frozen soil under different land covers using actively heated fiber Bragg grating sensors[J]. **Engineering Geology**, 2021, 290: 106197.

[26] WU B, ZHU H H, CAO D F, et al. Fiber optic sensing-based field investigation of thermo-hydraulic behaviors of loess for characterizing land-atmosphere interactions[J]. **Engineering Geology**, 2023, 315: 107019.

[27] ZHU H H, WU B, CAO D F, et al. Characterizing thermo-hydraulic behaviors of seasonally frozen loess via a combined opto-electronic sensing system: field monitoring and assessment[J]. **Journal of Hydrology**, 2023, 622(A): 129647.

[28] 张明礼, 雷兵兵, 周志雄, 等. 考虑雨水感热的降雨对多年冻土水热变化影响模型研究[J]. 岩土力学, 2023, 44(5): 1530-1544.
ZHANG Ming-li, LEI Bing-bing, ZHOU Zhi-xiong, et al. Model study on rainfall effect on hydrothermal dynamics of permafrost considering rainwater sensible heat[J]. **Rock and Soil Mechanics**, 2023, 44(5): 1530-1544.

[29] MILLER R D. Freezing and heaving of saturated and unsaturated soils[J]. **Highway Research Record**, 1972, 393: 1-11.

[30] PIKUL J L, ZUZEL J F, WILKINS D E. Water infiltration into frozen soil: field measurements and simulation[J]. **Proceedings of the National Symposium**, 1991, 16(7): 357-366.

[31] 程国栋. 中国冰川学冻土学研究 40 年进展和展望[J]. 冰川冻土, 1999, 21(4): 289-309.
CHENG Guo-dong. Glaciology and geocryology of China during the past 40 years: progress and prospects[J]. **Journal of Glaciology and Geocryology**, 1999, 21(4): 289-309.

[32] 朱晶, 裴强强, 郭青林, 等. 基于尺寸效应的夯土水盐运移分布特征研究[J]. 岩土力学, 2024, 45(5): 1481-1494.
ZHU Jing, PEI Qiang-qiang, GUO Qing-lin, et al. Distribution characteristics of water and salt transport in rammed earth sites based on size effect[J]. **Rock and Soil Mechanics**, 2024, 45(5): 1481-1494.

《岩土力学》2024 年第 3 期被 EI 收录论文（27 篇，收录率 100 %）（1）

序号	论文题名	作者	页码
1	微膨胀泥岩地基原位水分入渗响应特征试验研究	余云燕，丁小刚，马丽娜，等	647－658
2	荷载作用下多裂隙煤体力学特性与起裂角研究	王 磊，商瑞豪，刘怀谦，等	659－673
3	分级动荷载下土石混合体滞回曲线形态特征试验研究	黄 锋，米吉龙，杨永浩，等	674－684
4	循环加卸载过程中灰岩微细观损伤特征的试验研究	刘汉香，叶刁瑜，别鹏飞，等	685－696
5	物理化学效应对膨胀土收缩特性的影响机制	马田田，于海文，韦昌富，等	697－704
6	橡胶混合黏土小应变剪切模量特性试验研究	周恩全，白宇航，姚 缘，等	705－713
7	基于纤维加固砂土静力液化评估的超孔隙压力系数研究	张希栋，董晓强，段 伟，等	714－724
8	基于 3D 打印的粗糙结构面模型表征及渗流特性试验研究	王培涛，黄 浩，张 博，等	725－736
9	跨煤岩界面穿层压裂裂缝动态扩展特征试验研究	李浩哲，姜在炳，范宗洋，等	737－749
10	局域共振超材料表面波屏障带隙特性与隔振性能	厉 超，庄培芝，李利平，等	750－758
11	土工袋抑制膨胀土冻胀性能试验及机制探讨	张勇敢，鲁 洋，刘斯宏，等	759－768
12	反滤压重及埋深对深厚覆盖层允许坡降影响研究	张会豪，邱子源，金 伟，等	769－776
13	基于复变函数理论的无中导连拱隧道应力与位移解析解	毕钛俊，邓 琴，汤 华，等	777－787
14	竖向和水平组合荷载下能量桩单桩变形特性	蒋济泽，王成龙，黄煜镔，等	788－796
15	基于被动区土弹簧刚度降低过程的基坑围护结构计算增量法及软化 *p-y* 曲线	雷国平，苏 栋，程马遥，等	797－808

（未完，见第 684 页）