

doi:10.6041/j.issn.1000-1298.2024.08.032

基于超宽带雷达回波短时傅里叶变换的土壤含水率检测

尉鹏亮^{1,2} 周昱宏¹ 王若蓁¹ 郭交^{1,2}

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100;

2. 陕西省农业信息感知与智能服务重点实验室, 陕西杨凌 712100)

摘要: 土壤体积含水率监测对提高农业生产效率和制定合理土壤管理措施具有重要意义。超宽带雷达由于其高分辨率、强穿透能力在农业土壤动态信息实时监测中得到广泛应用。但以往对超宽带雷达信号的处理主要关注时域特征, 忽略了同样具有丰富信息的频域特征, 使得回波信号在土壤体积含水率反演过程中无法得到充分利用, 限制了土壤体积含水率的反演精度。本文基于超宽带雷达获取的土壤回波信号, 对其进行预处理并提取与土壤体积含水率有关的回波信号, 对该信号采用短时傅里叶变换(Short-time Fourier transform, STFT), 分析与土壤体积含水率有关的回波信号随时序变化的时频谱特征, 进而结合卷积神经网络(Convolutional neural network, CNN)建立土壤体积含水率分级以及回归预测模型。实验结果表明, 基于添加高斯白噪声后的数据, 对于土壤体积含水率的分级, 将时频特征和CNN模型相结合时, 分级总体精度和Kappa系数分别为98.69%和0.9849, 相较于10个时域特征与植被指数NDVI(Normalized difference vegetation index)建立的支持向量机模型(Support vector machine, SVM), 分级总体精度提升21.78个百分点, Kappa系数提高0.2515。对于土壤体积含水率的回归预测, 将时频特征和CNNR(Convolutional neural network regression)模型相结合时, 预测结果与真实值之间的决定系数(R^2)为0.9872, 均方根误差(RMSE)为0.0048 cm³/cm³, 相对分析误差(RPD)为6.2738, 相较于10个时域特征结合植被指数NDVI建立的CNNR模型, R^2 提升0.2316, RMSE降低1.3377 cm³/cm³, RPD提高4.2714。综上, 在土壤体积含水率分级和回归预测方面, 本文所提方法较传统信号检测处理方法具有明显优势。

关键词: 土壤体积含水率; 超宽带雷达; 短时傅里叶变换; 卷积神经网络

中图分类号: S24 文献标识码: A 文章编号: 1000-1298(2024)08-0352-09 OSID: 

Soil Volumetric Moisture Content Detection Based on Short-time Fourier Transform of Ultra-wide Band Radar Echo

WEI Pengliang^{1,2} ZHOU Yuhong¹ WANG Ruozhen¹ GUO Jiao^{1,2}

(1. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. Shaanxi Key Laboratory of Agriculture Information Perception and Intelligent Service, Yangling, Shaanxi 712100, China)

Abstract: Monitoring soil volumetric moisture content is crucial for enhancing agricultural production efficiency and devising reasonable soil management strategies. Ultra-wide band radar, due to its high resolution and strong penetration capabilities, is widely used in real-time monitoring of dynamic agricultural soil information. However, previous processing of ultra-wide band radar signals mainly focused on time-domain features, neglecting the equally informative frequency-domain characteristics. This oversight limited the utilization of echo signals in the inversion process of soil volumetric moisture content, thereby constraining the inversion accuracy. The soil echo signals obtained from ultra-wide band radar and extracts features related to soil volumetric moisture content were preprocessed. The signals were analyzed by using short-time Fourier transform (STFT) to investigate the time-frequency spectral characteristics related to soil volumetric moisture content variations over time. Furthermore, a soil volumetric moisture content classification and regression prediction algorithm model was established by combining these features with a convolutional neural network (CNN). Experimental results showed that

收稿日期: 2024-04-09 修回日期: 2024-05-17

基金项目: 中央高校基本科研业务费专项资金项目(2452023048)和陕西省重点研发计划项目(2020GY-162)

作者简介: 尉鹏亮(1993—), 男, 副教授, 博士, 主要从事农业遥感应用研究, E-mail: weipengliang@nwafu.edu.cn

通信作者: 郭交(1984—), 男, 副教授, 博士生导师, 主要从事农业遥感和精准农业研究, E-mail: gjiao@nwafu.edu.cn

based on data augmented with Gaussian white noise, the overall accuracy and Kappa coefficient for soil volumetric moisture content classification using time-frequency features combined with the CNN model were respectively 98.69% and 0.9849. Compared with support vector machine (SVM) model built with ten time-domain features and the normalized difference vegetation index (NDVI), there was an increase in overall accuracy by 21.78 percentage points and an improvement in the Kappa coefficient by 0.2515. For soil volumetric moisture content regression prediction, combining time-frequency features with a convolutional neural network regression (CNNR) model, the coefficient of determination (R^2) was 0.9872, the root mean square error (RMSE) was $0.0048\text{ cm}^3/\text{cm}^3$, and the relative percent difference (RPD) was 6.2738. Compared with the CNNR model established with ten time-domain features and NDVI, there was an increase in R^2 by 0.2316, a reduction in RMSE by $1.3377\text{ cm}^3/\text{cm}^3$, and an improvement in RPD by 4.2714. Overall, the method proposed showed a clear advantage over traditional signal detection and processing methods in terms of classifying and predicting soil volumetric moisture content.

Key words: soil volumetric moisture content; ultra-wide band radar; STFT; CNN

0 引言

土壤是农业生产最重要的基础之一。建立高质量的土壤状况监测机制,及时对土壤进行利用和保护,科学合理地利用土壤资源,对建设农业强国,保障国家经济和人民生活至关重要^[1]。随着农业技术的持续发展和社会对水资源管理的日益重视,水肥一体化和精准灌溉等创新理念受到了广泛关注,并且逐渐取代传统的定时灌溉方法^[2]。精准灌溉的关键在于实时监测和判断每个农田区块土壤含水率,以对不同农田区块的灌溉量实现精准控制,进而更好地在农业生产过程中实现高效节水和可持续发展^[3]。

土壤含水率是影响作物生长的重要因素,也是判断农业环境干旱程度的重要指标,对土壤体积含水率的准确检测不仅有助于预防干旱,减少水土流失,提高农作物产量和品质,同时也利于环境保护和水资源管理^[4],促进环境可持续发展^[5]。虽然传统的土壤体积含水率测定方法如干重法、加热法、中子法等测量结果较为准确^[6~9],但缺乏时效性、操作过程繁杂且耗时耗力,不适用于大面积测量^[10~11]。遥感观测虽可以克服这一问题,但由于其受到云层遮挡、植被覆盖、时空分辨率较低等限制导致无法实现精准测量^[12~13]。近年来,超宽带(Ultra-wide band, UWB)雷达因具备体积小、质量轻、高灵敏度和分辨率、强穿透能力^[14~16],以及可搭载到无人机或其他载体上实现大面积区域含水率检测等优点,在土壤检测领域逐渐得到广泛应用^[17~19]。例如,JING等^[20]利用超宽带雷达模块传感器,采集了不同土壤含水率地表下的反射信号;ZHU等^[21]利用超宽带雷达,并基于模糊逻辑方法获得了较高精度的土壤体积含水率。然而,以上研究选择的土壤环境条件较为理想,未考虑植被覆盖的情况,而实际农田中的土壤情况十分复杂,杂草或石

子均可能对实验结果产生较大影响。郭交等^[22]利用超宽带雷达信号和多光谱数据实现了不同植被覆盖程度的土壤体积含水率分级预测,验证了在复杂农田环境中利用超宽带雷达实现土壤体积含水率反演的可能。但该研究仅考虑了超宽带雷达信号时域特征和多光谱数据的结合,忽略了信号在频域环境下的特征指标。一般地,通过对频域信号的研究,可以更清楚地观察到信号中的主要频率成分,帮助理解信号的周期性和频率特性,有助于对信号的频谱密度以及频域能量分布进行分析。此外,通过频域对信号进行操作,可以更好地减小噪声对信号的影响,便于目标信息提取。而如果忽略了信号中的频域信息,则会造成雷达回波信号中的信息无法得到充分利用,进而限制了使用回波信号进行土壤体积含水率的反演及其分级精度。

因此,为进一步提升超宽带雷达在复杂农田环境中的土壤体积含水率反演及其分级精度,本文基于超宽带雷达模块在10块不同植被覆盖度区域分别采集土壤的雷达回波信号,对采集的信号进行预处理,提取与土壤体积含水率有关的回波信号,通过对回波信号进行短时傅里叶变换得到其时频特性^[23],进而结合该特性和卷积神经网络(CNN)^[24],建立土壤体积含水率分级算法模型和回归预测算法模型,并利用测试数据集验证算法模型的有效性,进一步推进农田土壤灌溉的精准预测及其科学可控性。

1 数据获取与预处理

1.1 研究数据获取

实验地点位于咸阳市杨凌区,总面积约100 m²,植被类型主要为狗尾草(*Setaria viridis* (L.) P. Beauv.)、披碱草(*Elymus dahuricus* Turcz.)及牛筋草(*Eleusine indica* (L.) Gaertn.)等杂草,植被覆盖度约42.10%,覆盖高度0~30 cm。选取实验地

内不同区域的 10 块 $2.5\text{ m} \times 2.5\text{ m}$ 实验田为对象并对其进行编号(1~10),实验田分布如图 1 所示。其中,1、2、3、7 号实验田植被覆盖情况较为稀疏,而 4、5、6、8、9、10 号实验田均表现出不同程度的植被覆盖情况。

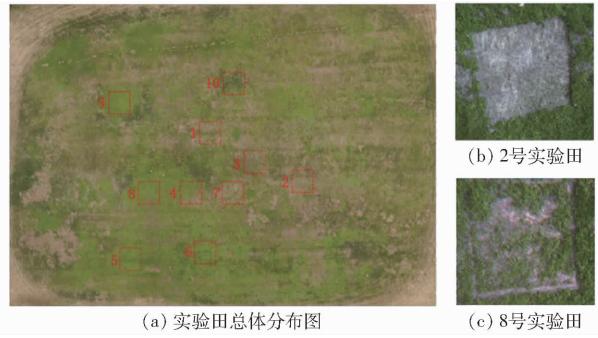


图 1 实验田分布示意图

Fig. 1 Diagrams of experimental field distribution

实验系统由超宽带雷达模块、发射天线、土壤样品、接收天线、计算机以及其他辅助设备组成,实验主设备和实验环境如图 2 所示。具体地,选用美国 Time Domain 公司 PulsOn 440 型单基站雷达模块,该模块支持 DC 4.5~48 V 供电,具有低功耗特性,可使用移动电源长期供电保证正常工作,可同时执行测距、数据传输、单基地雷达和多基地雷达 4 种功能;选用自带 BROADSPEC 椭圆形平面偶极子天线,可连接到 PulsOn 440 的 2 个天线端口实现全方向的发射和接收,天线具有稳定的时域特性和频域特性,有效射频带宽范围为 3.1~5.3 GHz,效率约为 90%,可满足 PulsOn 440 模块信号传输需求;利用低空扫描技术采集土壤回波信号,待测土壤区域位于发射天线和接收天线的正下方,高度为 1 m,使用 PulsOn 440 模块完成回波信号的发射和接收,计算机端采用 MRM 软件记录和存储回波信号数据。

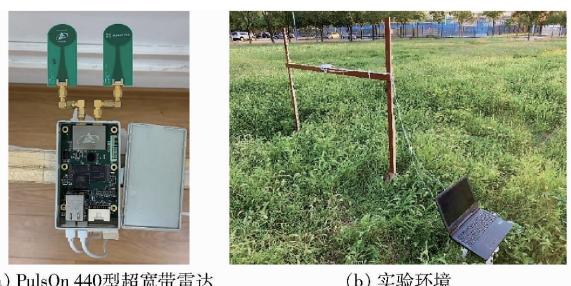


图 2 实验主设备和实验环境

Fig. 2 Main test equipment and test environment

选用顺科达公司 TR-6D 型便携式接触型土壤温湿度检测仪测量真实含水率,该检测仪工作环境为 -40~80°C,测量土壤体积含水率范围为 0~100%,分辨率 0.01%,探针长度为 7 cm,使用时可测量垂直安装条件下约 60 mm 土壤体积含水率,

具有体积小、质量轻、耗能低、准确率高等优点,可满足复杂环境下测量获得农田实际土壤体积含水率真值需求。具体地,使用 TR-6D 型便携式接触型土壤温湿度检测仪测量 PulsOn 440 型超宽带雷达下方约 $1.5\text{ m} \times 1.5\text{ m}$ 土壤实际的体积含水率并进行记录,测量时随机选取 $1.5\text{ m} \times 1.5\text{ m}$ 土壤范围内的 12 个点进行测量统计,计算时去除一个最低值和一个最高值后求平均值,所得数值作为该块土壤实际体积含水率并进行记录。

1.2 回波信号预处理

计算机采集到雷达回波信号后首先对信号进行预处理,提取出与土壤体积含水率相关联的信号^[25~27]。本实验所选用 PulsOn 440 模块收集到的土壤水分回波信号的离散时间为 480 ns,根据公式可以计算出包含土壤回波信号起始点位置信息,计算公式为

$$n' = \frac{t}{\tau} \quad (1)$$

$$\text{其中 } t = \frac{2s}{v} \quad (2)$$

$$v = \frac{c}{\sqrt{\epsilon_r}} \quad (3)$$

式中 v —雷达回波信号传播速度

ϵ_r —相对介电常数

c —真空条件下光速

t —传播时间 n' —时间指数

s —雷达波传播距离,取 1.0 m

τ —采样频率,取 61 p/s

根据式(1)可得 $n' = 109$,故在每个 480 ns 的回波数据中,自 109 ns 后的数据才包含土壤体积含水率的相关信息。已知 PulsOn 440 型超宽带雷达在土壤的穿透深度约为 50 cm,由经验公式^[28]可计算出包含土壤体积含水率的有效离散信号长度约为 244 ns,近似取为 250 ns,即采用每段回波信号的 109~359 ns 作为有效回波信号,以此为依据对雷达的回波数据进行截取,可以较好地排除天线耦合和环境噪声对结果的影响,提升实验使用信号的精确度。图 3 为土壤信息雷达回波示意图,其中橙色部

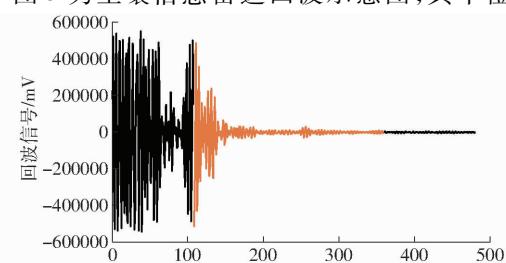


图 3 土壤信息雷达回波信号

Fig. 3 Soil information radar echo signal

分为与土壤体积含水率相关的回波信号。在10块实验田中共采集40组不同含水率的雷达回波信号,每组含有1000个回波信号样本,共获得40000组实验样本数据,土壤体积含水率范围为14.10%~28.59%,符合实际农田土壤体积含水率的情况^[29~30]。为在小尺度区域验证方法的可靠性,本文对获取的数据添加了信噪比为10的高斯白噪声。

2 土壤体积含水率反演

2.1 土壤体积含水率分级与定量反演

近年来,农业节水灌溉技术逐渐成为农业发展中的关键趋势,精准灌溉与信息技术的深度结合推动了自动化精准灌溉的兴起。然而,目前精准灌溉的控制水平难以实现对土壤体积含水率的准确预测,很难精确控制灌溉水量^[31~32]。为解决这一问题,可以选择采取一种逐步完善的策略。首先,将连续的土壤体积含水率区间进行分割,并量化为不同的等级,针对每个等级制定相应的灌溉水量控制方案。随着科技的不断进步,逐渐增加量化等级、精细化土壤体积含水率区间,实现土壤体积含水率的定量反演,达到高精度精准灌溉的目的,从而提高农业生产效率,促进农业可持续发展。

结合本文的研究目标,建立如图4所示的算法模型构建流程图,通过土壤体积含水率检测实验获得超宽带雷达回波信号及与之相对应的真实含水率数据^[33],对雷达回波信号进行预处理获取与土壤体积含水率相关的信号段,将其与真实含水率对应后建立完整的实验数据集。进一步地,根据特定比例(70%、30%)进行随机分割,分别建立训练数据集和测试数据集,在此基础上使用训练数据集对算法模型进行训练,使用测试数据集对训练得到的模型进行验证,并对验证结果进行评估,分析所构建算法模型的应用效果。

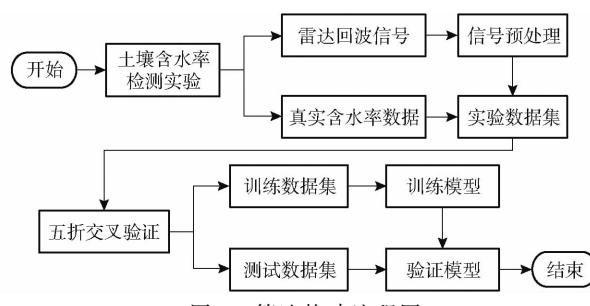


Fig. 4 算法构建流程图

2.2 特征集建立

(1) 时频特征建立

短时傅里叶变换是一种用于处理缓慢时变非平稳信号分析的技术,用于将信号分解为时域和频域

2个维度的信息,克服傅里叶变换仅能提供全局频率信息的局限性^[34]。土壤体积含水率雷达回波信号的表现特性随时间变化明显,是典型的非平稳信号,因此采用短时傅里叶变换充分提取土壤体积含水率雷达回波信号的特征信息。

短时傅里叶变换定义为

$$STFT_x(\omega, \delta) = \int_{-\infty}^{+\infty} x(r) w^*(r - \delta) e^{-j\omega r} dr \quad (4)$$

式中 $x(r)$ ——非稳态连续信号

r ——信号观测时间

$w(r - \delta)$ ——窗函数,中心点为 δ

ω ——角频率 *——共轭运算符

由于在实际过程中收集到的信号是离散的,故需要对 $STFT_x(\omega, \delta)$ 进行离散处理,即

$$STFT_x(n, k) = \sum_{m=0}^{N-1} x(n+m) w(m) e^{-j2\pi nk/N} \quad (5)$$

式中 $x(n+m)$ ——非稳态离散信号

$w(m)$ ——窗函数 k ——频率索引

N ——采样点个数 n ——时间索引

经离散处理后的短时傅里叶变换结果包含时域和频域2个维度信息,处理后的输出结果分别为:表示时频域特征的 s 向量,表示循环频率的 f 向量以及表示时间的 t 向量。采取时频特征图的形式对短时傅里叶变换后的结果进行可视化表示,图5(图中不同颜色表示归一化后的雷达回波信号值分布)

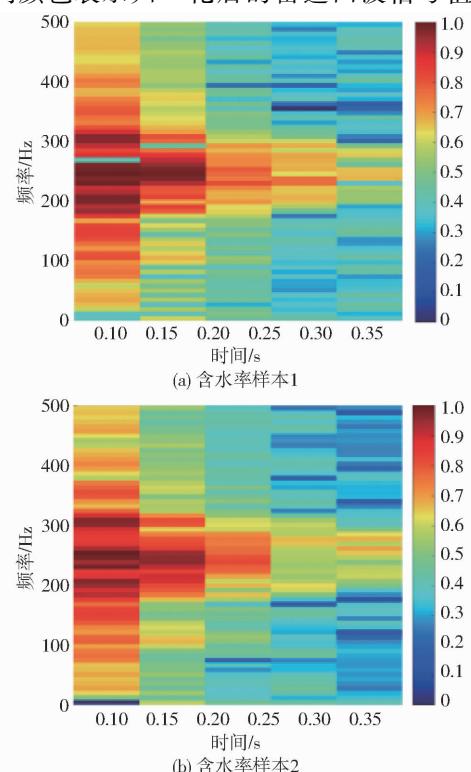


图5 短时傅里叶变换后时频特征可视化结果

Fig. 5 Visualization of time-frequency calculated from short-time Fourier transform

from short-time Fourier transform

为2个样本的雷达成回波特征信号经短时傅里叶变换后的时频图。为了在后续的分类和回归任务中消除尺度影响,改善算法的数值稳定性和收敛速度,提高模型的泛化能力,对获取的时频特征进行归一化处理。在不同的含水率样本中,雷达成回波信号频率的主要分布随时间变化逐渐收窄,而不同含水率的时频特征初始宽度和收窄速率表现不同^[35]。进一步地,以归一化后的时频图谱为特征数据,对含水率样本的雷达成回波信号进行分级与回归预测。

(2) 时域特征建立

实验中所使用的10个时域特征,包括最大幅值、最小幅值、整流平均值、峰-峰值、均方根等有量纲的数据,以及特征峭度、偏斜度、峰值因子、脉冲因子等无量纲的数据^[36]。

(3) 高光谱特征建立

实验中所使用的高光谱特征选用归一化植被指数(Normalized difference vegetation index, NDVI),该植被指数可以消除大部分太阳角、地形、云阴影和大气条件造成的影响,是使用较为广泛的一种植被指数^[37-39]。该植被指数通过计算可见光和近红外波段的遥感数据来评估地表植被覆盖情况,计算公式为

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (6)$$

式中 ρ_{NIR} ——近红外波段反射率

ρ_{RED} ——红外波段反射率

2.3 卷积神经网络模型

基于短时傅里叶变换所提取的时频特征,采用卷积神经网络进行土壤体积含水率的分级与预测。卷积神经网络是一种深度学习模型,其平移不变性、局部连接和权值共享的特性,使其对于图像处理可以实现自动特征提取,具备很好的泛化能力。卷积神经网络结构通常由数据输入层(Input layer)、卷积计算层(CONV layer)、ReLU激活层(ReLU layer)、池化层(Pooling layer)和全连接层(FC layer)组成^[40]。

采用卷积神经模型对短时傅里叶变换后的时频谱特征数据进行分级预测和回归预测,其中,用于分级所构建的CNN(Convolutional neural network)网络结构如图6所示,用于回归所构建的CNRR(Convolutional neural network regression)网络结构如图7所示。

图6所示的CNN土壤体积含水率分级网络主要包含2个卷积层、2个最大池化层、1个全连接层和1个Softmax层。输入层首先根据分级数据集的特征,对数据进行接收和标准化处理,并将其大小确

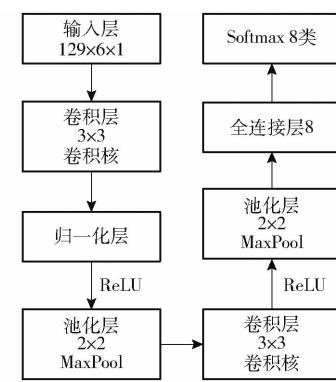


图6 CNN 分级网络结构图

Fig. 6 CNN hierarchical network diagram

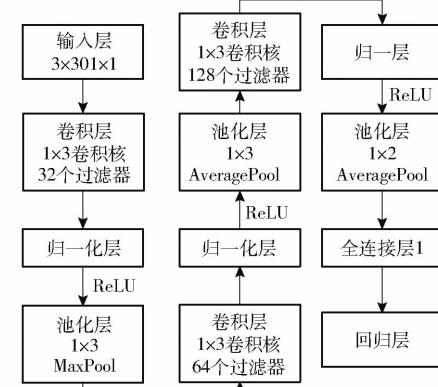


图7 CNRR 网络结构图

Fig. 7 CNRR network architecture diagram

定为 $129 \times 6 \times 1$ (其中129为频谱图高度,6为频谱图宽度,1为通道数)。接着,根据输入层数据大小,确定卷积核大小为 3×3 ,并在输入数据上进行滑动和点积运算,以捕捉图像局部特征。为了增强模型表达能力,在卷积后使用非线性激活函数(ReLU)进行变换。然后,将结果输入到大小为 2×2 的最大池化层进行池化操作,以降低模型复杂度、减少过拟合风险,并增强模型平移不变性和对局部变换鲁棒性。最后,通过全连接层和Softmax层对前面提取到的特征进行综合和判断,从而实现土壤含水率的分级预测。

图7所示的CNRR土壤体积含水率回归网络主要包含3个卷积层、3个归一化层、1个最大池化层和2个平均池化层以及1个全连接层和1个回归层。输入层首先根据回归任务数据集特征,对输入的原始数据进行接收和预处理操作,并将其大小确定为 $3 \times 301 \times 1$ (其中3为短时傅里叶变换后提取的特征数,301为序列数据长度,1表示一维数据)。随后,根据输入层数据大小,确定回归网络卷积核大小为 1×3 ,并在输入数据上进行滑动和点积运算,捕捉图像局部特征。为了增强模型表达能力,在卷积后同样使用非线性激活函数(ReLU)进行变换。为了增强模型平移不变性和对局部变换的鲁棒性,

并降低模型复杂度、减少过拟合风险,CNNR 网络采取了最大池化层和平均池化层相结合的形式进行池化操作。最后,通过全连接层和回归层,实现对土壤体积含水率数据的预测。

3 实验结果与分析

3.1 实验设置

为了满足精准灌溉技术的需求,以更高的精度量化不同的土壤体积含水率,将数据预处理所得到的实际土壤体积含水率从 14.01% 分为 8 级^[22], 分级结果如表 1 所示。

表 1 含水率区间分级

Tab. 1 Classification of moisture content intervals

| 分级 | 含水率区间/% | 分级 | 含水率区间/% |
|-------|---------------|-------|---------------|
| 第 1 级 | 14.01 ~ 16.00 | 第 5 级 | 22.01 ~ 24.00 |
| 第 2 级 | 16.01 ~ 18.00 | 第 6 级 | 24.01 ~ 26.00 |
| 第 3 级 | 18.01 ~ 20.00 | 第 7 级 | 26.01 ~ 28.00 |
| 第 4 级 | 20.01 ~ 22.00 | 第 8 级 | 28.01 ~ 30.00 |

为了进一步降低模型在分级和回归任务中出现过度拟合或欠拟合的风险,并确保模型具有较高的准确性和泛化能力,采用五折交叉验证的方法,通过将数据分成 5 个互斥的子集,在每次训练中使用 4 个子集进行模型训练,而剩余的 1 个子集用于验证模型,可以获得更可靠的模型评估结果。这种方法有助于评估模型对不同数据集的泛化能力,并有效降低实验结果偏差,提高实验可信度和可靠性。

3.2 土壤体积含水率分级预测

将基于时频特征构建的 CNN 和 BP (Back propagation neural network) 模型,以及参考文献[22] 中基于时域特征和 NDVI 构建的 SVM (Support vector machine) 模型进行对比分析。基于测试数据集,CNN 和 BP 网络所获取的土壤体积含水率等级分级预测结果分别如图 8 所示,各模型性能对比结果如表 2 所示。从表 2 可以发现,在加入信噪比为 10 的高斯白噪声处理之后,相较于 10 个时域特征结合 NDVI 建立的 SVM 模型^[22],时频特征建立的 CNN 模型分级效果更好,分级总体精度提升 21.78 个百分点,Kappa 系数提高 0.251 5,大大提升了土壤体积含水率分级的预测精度。同样地,相较于采用时频特征建立的 BP 神经网络分级模型,CNN 卷积神经网络分级模型对土壤体积含水率等级分级预测的结果更好,总体精度提升 3.74 个百分点,Kappa 系数提高 0.043 1。这表明基于时频特征构建的 CNN 土壤体积含水率分级预测模型,能够更为准确地预测土壤体积含水率等级,并且具有一定的抗噪

声干扰能力。

| | | | | | | | | |
|---|------|-----|------|------|------|------|------|-----|
| 1 | 1037 | 0 | 3 | 3 | 0 | 0 | 0 | 0 |
| 2 | 1 | 962 | 0 | 0 | 1 | 5 | 44 | 0 |
| 3 | 0 | 0 | 1196 | 1 | 0 | 0 | 8 | 1 |
| 4 | 0 | 0 | 5 | 1480 | 2 | 1 | 3 | 1 |
| 5 | 0 | 0 | 6 | 0 | 1517 | 1 | 6 | 0 |
| 6 | 0 | 0 | 0 | 1 | 1 | 1274 | 2 | 0 |
| 7 | 0 | 0 | 3 | 1 | 19 | 0 | 1686 | 6 |
| 8 | 3 | 0 | 1 | 0 | 1 | 2 | 1 | 717 |
| 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | |

(a) CNN 卷积神经网络

| | | | | | | | | |
|---|------|------|------|------|------|------|------|-----|
| 1 | 1000 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 2 | 0 | 1000 | 0 | 0 | 0 | 0 | 0 | 0 |
| 3 | 0 | 0 | 1245 | 1 | 0 | 0 | 4 | 0 |
| 4 | 1 | 36 | 0 | 1250 | 0 | 213 | 0 | 0 |
| 5 | 0 | 0 | 0 | 0 | 1500 | 0 | 0 | 0 |
| 6 | 0 | 0 | 1 | 239 | 0 | 1000 | 10 | 0 |
| 7 | 0 | 0 | 0 | 0 | 0 | 0 | 1750 | 0 |
| 8 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 750 |
| 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | |

(b) BP 神经网络

图 8 土壤体积含水率分级预测混淆矩阵

Fig. 8 Confusion matrix for soil volumetric moisture content classification prediction

表 2 不同土壤体积含水率分级预测模型性能对比

Tab. 2 Performance comparison of different soil volumetric moisture content classification prediction models

| 模型 | 总体精度/% | Kappa 系数 |
|------------------------|--------|----------|
| 基于时域特征 + NDVI 的 SVM 模型 | 76.91 | 0.733 4 |
| 基于时频特征的 BP 神经网络模型 | 94.95 | 0.941 8 |
| 基于时频特征的 CNN 卷积神经网络模型 | 98.69 | 0.984 9 |

3.3 土壤体积含水率回归预测

本文探索了基于短时傅里叶变换的时频特征和 CNNR 进行土壤体积含水率定量反演的潜力,并将其实与基于时域特征和 NDVI 构建的 SVR (Support vector regression)、GRNN (General regression neural network)、CNNR 模型进行对比,采用决定系数 (Determination coefficients, R^2),均方根误差 (Root mean squared error, RMSE) 和相对分析误差 (Relative percent difference, RPD) 等参数来评估模型间的差异。 R^2 用于评估模型拟合程度,其值越接近 1 表示该模型拟合程度越好;RMSE 用于衡量预测值和真实值之间的偏差,RMSE 越小,说明该模型预测效果越好;RPD 是一种用于评估所建模型稳定性能的指标,RPD 越大,说明所建模型波动越小,稳定性越好。基于测试数据集,CNNR 获取的土壤体

积含水率预测结果如图9所示,不同方法的评价指标如表3所示。从表3可知,在加入信噪比为10的高斯白噪声处理后,基于时频特征建立的CNNR模型获取的土壤体积含水率 R^2 为0.9872,RMSE为0.0048 cm³/cm⁻³,RPD为6.2738。相较于10种时域特征结合NDVI建立的SVR模型、GRNN模型、CNNR模型回归预测的结果^[36], R^2 分别提升0.2681、0.2036、0.2316,RPD分别提升4.7495、

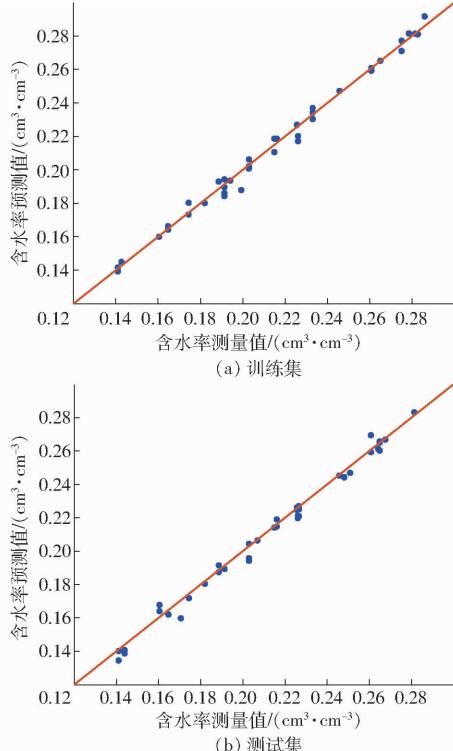


图9 基于STFT时频谱特征的CNNR模型土壤体积含水率预测结果

Fig.9 Prediction results of soil volumetric moisture content of CNNR driven by STFT time-spectrum feature

4.6995和4.2714,RMSE分别降低1.7587、1.7038、1.3377 cm³/cm⁻³。无论是在训练数据集还是测试数据集上,基于时频特征建立的CNNR模型反演的土壤体积含水率预测值的分布逼近于真实值,均方根误差极小,预测结果与实际观测值体现为高度一致。这表明时频特征构建的回归模型预测结果准确,预测精度高,有效学习了回波信号特征与土壤体积含水率的关系,且具备较好的抗噪和泛化能力。

表3 不同土壤体积含水率预测模型性能对比

Tab.3 Comparison of performance of different soil volumetric moisture content prediction models

| 模型 | R^2 | RMSE/(cm ³ ·cm ⁻³) | RPD |
|--------------------|--------|---|--------|
| 基于时域特征+NDVI的SVR模型 | 0.7191 | 1.7635 | 1.5243 |
| 基于时域特征+NDVI的GRNN模型 | 0.7836 | 1.7076 | 1.5743 |
| 基于时域特征+NDVI的CNNR模型 | 0.7556 | 1.3425 | 2.0024 |
| 基于时频特征的CNNR模型 | 0.9872 | 0.0048 | 6.2738 |

4 结论

(1) 基于超宽带雷达回波信号提取的时频特征建立的CNN土壤体积含水率分级模型获取的分级结果总体精度可达98.69%,Kappa系数为0.9849,其性能明显优于基于时频特征建立的BP土壤体积含水率分级预测模型,以及10个时域特征结合NDVI建立的SVM土壤体积含水率分级预测模型。

(2) 基于超宽带雷达回波信号提取的时频特征建立的CNNR土壤体积含水率回归模型获取的土壤体积含水率决定系数可达0.9872,其性能明显优于基于时域特征结合NDVI建立的SVR、GRNN、CNNR土壤体积含水率回归模型。

参 考 文 献

- [1] 陈书林,刘元波,温作民. 卫星遥感反演土壤水分研究综述[J]. 地球科学进展, 2012, 27(11):1192–1203.
CHEN Shulin, LIU Yuanbo, WEN Zuomin. Satellite retrieval of soil moisture: an overview[J]. Advance in Earth Science, 2012, 27(11):1192–1203. (in Chinese)
- [2] 刘永华,俞卫东,沈明霞,等. 智能化精准灌溉施肥技术研究现状与展望[J]. 江苏农业科学, 2014, 42(8):384–387.
LIU Yonghua, YU Weidong, SHEN Mingxia, et al. Research status and prospects of intellectualized precise irrigation and fertilization techniques[J]. Jiangsu Agricultural Sciences, 2014, 42(8):384–387. (in Chinese)
- [3] 王平,高丹,郑淑红. 精准灌溉技术研究现状及发展前景[J]. 中国水利, 2013(增刊1): 52–53, 46.
- [4] LEGATES R D. Soil moisture: a central and unifying theme in physical geography[J]. Progress in Physical Geography, 2011, 35(1): 65–86.
- [5] 李旺霞,陈彦云. 土壤水分及其测量方法的研究进展[J]. 江苏农业科学, 2014, 42(10):335–339.
LI Wangxia, CHEN Yanyun. Research progress of soil moisture and its measurement methods [J]. Jiangsu Agricultural Sciences, 2014, 42(10):335–339. (in Chinese)
- [6] 陈祎彤,李敏,司炳成,等. 宇宙射线中子法测量中尺度土壤体积含水率研究综述[J]. 灌溉排水学报, 2021, 40(11): 26–36.
CHEN Yitong, LI Min, SI Bingcheng, et al. Measuring soil water content using the cosmic-ray neutron probe: a review [J]. Journal of Irrigation and Drainage, 2021, 40(11):26–36. (in Chinese)
- [7] KELLY B C, SIVAKUMAR V. Water content determinations for peat and other organic soils using the oven-drying method[J].

- Drying Technology, 2014, 32(6): 631–643.
- [8] 武强, 黄娜, 罗攀攀, 等. 宇宙射线中子法测量区域土壤水分准确性季节变化研究[J]. 农业机械学报, 2022, 53(1): 321–330.
- WU Qiang, HUANG Na, LUO Guoguo, et al. Seasonal variations of regional soil moisture measurement accuracy based on cosmic-ray neutron sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(1): 321–330. (in Chinese)
- [9] 李明, 汪雅婷, 黄致绮. 土壤含水率测量方法分析及比较[J]. 仪表技术, 2017(8): 15–17.
- LI Yue, WANG Yating, HUANG Zhiqi. Study on probe-type soil moisture sensor[J]. Instrumentation Technology, 2017(8): 15–17. (in Chinese)
- [10] 王大龙, 舒英格. 土壤含水量测定方法研究进展[J]. 山地农业生物学报, 2017, 36(2): 61–65.
- WANG Dalong, SHU Yingge. Research progress in determination methods for soil water content[J]. Journal of Mountain Agriculture and Biology, 2017, 36(2): 61–65. (in Chinese)
- [11] 郭交, 刘健, 宁纪锋, 等. 基于 Sentinel 多源数据的农田地表土壤水分反演模型构建与验证[J]. 农业工程学报, 2019, 35(14): 71–78.
- GUO Jiao, LIU Jian, NING Jifeng, et al. Construction and validation of soil moisture retrieval model in farmland based on Sentinel multi-source data[J]. Transactions of the CSAE, 2019, 35(14): 71–78. (in Chinese)
- [12] 姚一飞, 王爽, 张珺锐, 等. 基于 GF-1 卫星遥感的河套灌区土壤体积含水率反演模型研究[J]. 农业机械学报, 2022, 53(9): 239–251.
- YAO Yifei, WANG Shuang, ZHANG Junrui, et al. Inversion model of soil moisture in Hetao irrigation district based on GF-1 satellite remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 239–251. (in Chinese)
- [13] LOEWER M, GUENTHER T, IGEL J, et al. Ultra-broad-band electrical spectroscopy of soils and sediments—a combined permittivity and conductivity model[J]. Geophysical Journal International, 2017, 210(3): 1360–1373.
- [14] 谢国青, 陈紫秋. 探地雷达功率谱特征与土壤体积含水率相关关系分析[J]. 中国水运(下半月), 2022, 22(11): 156–158.
- [15] WEIHERMÜLLER L, HUISMAN J A, LAMBOT S, et al. Mapping the spatial variation of soil water content at the field scale with different ground penetrating radar techniques[J]. Journal of Hydrology, 2007, 340(3–4): 205–216.
- [16] 林相泽, 王祥, 林彩鑫, 等. 基于超宽带的温室农用车辆定位信息采集与优化[J]. 农业机械学报, 2018, 49(10): 23–29, 45.
- LIN Xiangze, WANG Xiang, LIN Caixin, et al. Location information collection and optimization for agricultural vehicle based on UWB[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(10): 23–29, 45. (in Chinese)
- [17] 金宏智, 严海军, 钱一超. 国外节水灌溉工程技术发展分析[J]. 农业机械学报, 2010, 41(增刊): 59–63.
- JIN Hongzhi, YAN Haijun, QIAN Yichao. Overseas development of water-saving irrigation engineering technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2010, 41(Supp.): 59–63. (in Chinese)
- [18] HUISMAN J A, HUBBARD S S, REDMAN J D, et al. Measuring soil water content with ground penetrating radar: a review[J]. Vadose Zone Journal, 2003, 2(4): 476–491.
- [19] 何亮, 王旭东, 杨放, 等. 探地雷达测定土壤含水量的研究进展[J]. 地球物理学进展, 2007(5): 1673–1679.
- HE Liang, WANG Xudong, YANG Fang, et al. Estimation of soil water content by ground penetrating radar[J]. Progress in Geophysics, 2007(5): 1673–1679. (in Chinese)
- [20] JING L, FANG Q Z. Soil moisture retrieval from UWB sensor data by leveraging fuzzy logic[J]. IEEE Access, 2018, 6: 29846–29857.
- [21] ZHU F, LIU H, LIANG J. Soil moisture retrieval using fuzzy logic based on UWB signals[C]//WCSP 2015, 2015: 1–5.
- [22] 郭交, 白清源, 郭文川. 基于超宽带雷达和多光谱数据融合的土壤体积含水率检测[J]. 农业机械学报, 2021, 52(9): 241–249.
- GUO Jiao, BAI Qingyuan, GUO Wenchuan. Monitoring method of soil moisture based on ultra-wide band radar and multispectral data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(9): 241–249. (in Chinese)
- [23] 李小昱, 肖武, 李培武, 等. 基于近红外傅里叶特征提取方法的土壤体积含水率检测[J]. 农业机械学报, 2009, 40(5): 64–67.
- LI Xiaoyu, XIAO Wu, LI Peiwu, et al. Infrared spectral detection of soil moisture based on feature extraction of FFT[J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(5): 64–67. (in Chinese)
- [24] 冀荣华, 李鑫, 张舒蕾, 等. 基于时延神经网络的多深度土壤体积含水率预测[J]. 农业工程学报, 2017, 33(增刊1): 132–136.
- JI Ronghua, LI Xin, ZHANG Shulei, et al. Prediction of soil moisture in multiple depth based on time delay neural network[J]. Transactions of the CSAE, 2017, 33(Supp. 1): 132–136. (in Chinese)
- [25] 马福建, 雷少刚, 杨赛, 等. 土壤含水率与探地雷达信号属性的关系研究[J]. 土壤通报, 2014, 45(4): 809–815.
- MA Fujian, LEI Shaogang, YANG Sai, et al. Study on the relationship between soil water content and ground penetrating radar signal attributes[J]. Chinese Journal of Soil Science, 2014, 45(4): 809–815. (in Chinese)

- [26] 康学远,林琳,刘义佳,等. 土壤介电常数-含水量关系模型研究[J]. 中国农村水利水电, 2015(8):8–12.
KANG Xueyuan, LIN Lin, LIU Yijia, et al. Soil moisture content detection with ground-penetrating-radar and its calibration models of soil moisture content vs. dielectric constant and its measurement accuracy[J]. China Rural Water and Hydropower, 2015(8):8–12. (in Chinese)
- [27] 朱安宁,吉丽青,张佳宝,等. 不同类型土壤介电常数与体积含水量经验关系研究[J]. 土壤学报, 2011,48(2):263–268.
ZHU Anning, JI Liqing, ZHANG Jiabao, et al. Empirical relationship between soil dielectric constant and volumetric water content in various soils[J]. Acta Pedologica Sinica, 2011,48(2):263–268. (in Chinese)
- [28] 陈权,曾江源,李震,等. 遥感监测介电常数与土壤体积含水率关系模型[J]. 农业工程学报, 2012,28(12):171–175.
CHEN Quan, ZENG Jiangyuan, LI Zhen, et al. Relationship model of soil moisture and dielectric constant monitored with remote sensing [J]. Transactions of the CSAE, 2012,28(12):171–175. (in Chinese)
- [29] 张秋霞,张合兵,刘文楷,等. 高标准基本农田建设区域土壤重金属含量的高光谱反演[J]. 农业工程学报, 2017, 33(12):230–239.
ZHANG Qiuxia, ZHANG Hebing, LIU Wenkai, et al. Inversion of heavy metals content with hyperspectral reflectance in soil of well-facilitated capital farmland construction areas[J]. Transactions of the CSAE, 2017,33(12):230–239. (in Chinese)
- [30] 代希君,彭杰,张艳丽,等. 基于光谱分类的土壤盐分含量预测[J]. 土壤学报, 2016,53(4):909–918.
DAI Xijun, PENG Jie, ZHANG Yanli, et al. Prediction on soil salt content based on spectral classification [J]. Acta Pedologica Sinica, 2016,53(4):909–918. (in Chinese)
- [31] 梁忠伟,刘晓初,萧金瑞,等. 农业精准灌溉技术理念及系统进展综述[J]. 农业工程技术, 2021,41(33):88.
LIANG Zhongwei, LIU Xiaochu, XIAO Jinrui, et al. Review of conceptual and systematic progress of precision irrigation [J]. Journal of Agricultural Engineering Technology, 2021,41(33):88. (in Chinese)
- [32] 谢国青,聂俊丽,陈紫秋,等. 基于探地雷达功率谱属性参数的土壤含水状态预测[J]. 节水灌溉, 2023(10):28–35.
XIE Guoqing, NIE Junli, CHEN Ziqiu, et al. Soil moisture state prediction based on ground penetrating radar power spectrum properties parameters[J]. Water Saving Irrigation, 2023(10):28–35. (in Chinese)
- [33] XU Hanxiao, CAO Yingui, LUO Gubai, et al. Variability in reconstructed soil bulk density of a high moisture content soil: a study on feature identification and ground penetrating radar detection[J]. Environ. Earth Sciences, 2022, 81(9):249.
- [34] MINET J, BOGAERT P, VANCLOOSTER M, et al. Validation of ground penetrating radar full-wave form inversion for field scale soil moisture mapping[J]. Journal of Hydrology, 2012, 424(5): 112–113.
- [35] 张建国,孙晓东,张礼勇. 基于时频分析的信号特征提取方法研究[J]. 电测与仪表, 2005(6):6–9.
ZHANG Jianguo, SUN Xiaodong, ZHANG Liyong. Research on the signal characteristic extraction method based on time-frequency analysis[J]. Electrical Measurement and Instrument, 2005(6):6–9. (in Chinese)
- [36] 白清源. 基于微波-光学多源遥感的农田地表土壤水分监测方法研究[D]. 杨凌:西北农林科技大学, 2023.
BAI Qingyuan. Farmland surface soil moisture monitoring method based on microwave optical multi-source remote sensing[D]. Yangling: Northwest A&F University, 2023. (in Chinese)
- [37] 白燕英,高聚林,张宝林. 基于NDVI与EVI的作物长势监测研究[J]. 农业机械学报, 2019,50(9):153–161.
BAI Yanying, GAO Julin, ZHANG Baolin. Monitoring of crops growth based on NDVI and EVI[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019,50(9):153–161. (in Chinese)
- [38] 张智韬,王海峰,韩文霆,等. 基于无人机多光谱遥感的土壤含水率反演研究[J]. 农业机械学报, 2018,49(2):173–181.
ZHANG Zhitao, WANG Haifeng, HAN Wenting, et al. Inversion of soil moisture content based on multispectral remote sensing of UAVs[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018,49(2):173–181. (in Chinese)
- [39] 陈昊宇,杨光,韩雪莹,等. 基于连续小波变换的土壤有机质含量高光谱反演[J]. 中国农业科技导报, 2021,23(5): 132–142.
CHEN Haoyu, YANG Guang, HAN Xueying, et al. Hyperspectral inversion of soil organic matter content based on continuous wavelet transform[J]. Journal of Agricultural Science and Technology, 2021,23(5):132–142. (in Chinese)
- [40] 黄铝文,谦博,关非凡,等. 基于小波变换与卷积神经网络的羊脸识别模型[J]. 农业机械学报, 2023,54(5):278–287.
HUANG Lüwen, QIAN Bo, GUAN Feifan, et al. Goat face recognition model based on wavelet transform and convolutional neural networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(5):278–287. (in Chinese)