



引文格式:郭斐,陈惟杰,朱逸凡,等.一种融合相位、振幅与频率的GNSS-IR土壤湿度反演方法[J].武汉大学学报(信息科学版),2024,49(5):715-721.DOI:10.13203/j.whugis20210644

Citation: GUO Fei, CHEN Weijie, ZHU Yifan, et al. A GNSS-IR Soil Moisture Inversion Method Integrating Phase, Amplitude and Frequency[J]. Geomatics and Information Science of Wuhan University, 2024, 49(5): 715-721. DOI: 10.13203/j.whugis20210644

一种融合相位、振幅与频率的GNSS-IR土壤湿度反演方法

郭斐¹ 陈惟杰¹ 朱逸凡¹ 张小红¹

¹ 武汉大学测绘学院,湖北 武汉,430079

摘要:GNSS干涉测量(GNSS interferometric reflectometry, GNSS-IR)技术已经成为探测地表环境特性的一种新兴被动遥感技术,综合利用从土壤反射的GNSS信号中提取的相位、振幅、频率特征,提出了一种多类型特征数据融合的GNSS-IR土壤湿度反演方法,采用最小二乘支持向量机(least square support vector machine, LSSVM)、随机森林(random forest, RF)、BP神经网络(back propagation neural network, BPNN)三种机器学习模型,对比和验证了所提方法的可行性与效果。结果表明,多特征融合的LSSVM、RF和BPNN模型反演得到的土壤湿度与参考值的相关系数分别为0.830、0.953和0.980,对应的均方根误差分别为0.045、0.035和0.032 cm³/cm³。相比于单一特征反演法,土壤湿度反演精度和可靠性有显著提升。

关键词:GNSS-IR;土壤湿度;相位;振幅;频率;机器学习

中图分类号:P237

文献标识码:A

收稿日期:2022-02-11

DOI:10.13203/j.whugis20210644

文章编号:1671-8860(2024)05-0715-07

A GNSS-IR Soil Moisture Inversion Method Integrating Phase, Amplitude and Frequency

GUO Fei¹ CHEN Weijie¹ ZHU Yifan¹ ZHANG Xiaohong¹

¹ School of Geodesy and Geomatics, Wuhan University, Wuhan 430079, China

Abstract: Objectives: Global navigation satellite system (GNSS) interferometric reflectometry (GNSS-IR) is a new passive remote sensing technique for determining surface environment parameters, which places an important part in the inversion of earth's surface properties, such as soil moisture monitoring, snow parameter retrieval, and vegetation remote sensing, etc. GNSS-IR offers several benefits over the traditional soil moisture inversion approach, including all-weather capability, high temporal precision, and cheap cost. **Methods:** Considering the fact that the existing soil moisture inversion algorithms only utilize one single feature of GNSS reflected signal and from the perspective of increasing data availability, this paper proposes a GNSS-IR soil moisture inversion approach that integrates multi-type feature data by utilizing phase, amplitude, and frequency extracted GNSS signals reflected by soil. The main work is to effectively filter all available features extracted from the original GNSS signal-to-noise ratio observations. The feasibility and effect of the suggested method are compared and evaluated using three machine learning models, including least squares support vector machine (LSSVM), random forest (RF), and back propagation neural network (BPNN). **Results:** Comparing the inversion effects of above three models, BPNN model has the best inversion effect, followed by RF model, and LSSVM model is the worst. The results show that the correlation coefficients between the reference value and soil moisture inverted by the multi-feature fusion method LSSVM, RF, and BPNN models are 0.830, 0.953, and 0.980, respectively, and the corresponding root mean square errors are 0.045, 0.035 and 0.032 cm³/cm³.

基金项目:国家自然科学基金(42074029);湖北省杰出青年科学基金(2021CFA039)。

第一作者:郭斐,教授,主要从事GNSS精密单点定位及GNSS-R地学应用研究。fguo@sgg.whu.edu.cn

Conclusions: Compared with the single feature inversion method, both the accuracy and correlation coefficient of soil moisture inversion increase significantly. The results demonstrated that the proposed method has higher inversion accuracy and reliability than the single feature inversion method.

Key words: GNSS-IR; soil moisture; phase; amplitude; frequency; machine learning

高精度、高时空分辨率的土壤湿度监测和预报数据对区域水文气候研究、农业生产生活等具有重要意义。全球导航卫星系统(global navigation satellite system, GNSS)干涉测量(GNSS interferometric reflectometry, GNSS-IR)技术作为一种新兴的被动遥感技术,被广泛地应用于土壤湿度监测、积雪参数反演、植被遥感等地球地表特性反演问题的研究中^[1-2]。相比于传统的称重法、滴定法、时域测定法、频域测定法等^[3],基于GNSS-IR技术的土壤湿度反演方法具有全天候、高时间分辨率、低成本等优点。

GNSS-IR技术用于土壤湿度反演的研究最初由Larson等提出,其团队开展了一系列地基试验,验证了在裸土和植被覆盖条件下GNSS反射信号与表层土壤湿度具有较强的相关性,并且基于美国大陆板块边界观测网(plate boundary network, PBO)提出了反演土壤湿度的经验线性模型^[4-6]。Vey等^[7]分析了GPS的频率、天线以及季节性变化对反演土壤湿度的影响,得出L2频率反演效果优于L1的结论。Chew等^[8-9]验证了利用信噪比(signal-to-noise ratio, SNR)反射信号分量的振幅、反射器高度、相位来反演土壤湿度的可行性。上述研究表明,SNR反射分量特征量(相位、振幅、频率等)与土壤湿度有较强的相关性,但并没有能够建立土壤湿度监测与预报的解析模型^[10]。机器学习方法在解决非线性回归问题方面具有优势,能够有效学习和预测输入量与输出量之间的复杂映射关系,因此也被广泛应用于GNSS-IR土壤湿度反演。Zhang等^[11]利用最小二乘支持向量机,使用多种特征组合测试了相应的反演效果;Ren等^[12]、孙波等^[13]开展了类似的工作。陈堃等^[14]对比分析了深度置信网络、传统线性回归模型、BP神经网络3种方法反演土壤湿度的效果,结果表明深度置信网络方法反演精度最优。

综合上述国内外研究现状来看,目前用于输入机器学习回归器或者神经网络回归器的数据特征主要是基于反射信号中的相位或者振幅序列。单一的特征输入数据可靠性较差,容易造成回归器的反演结果失真^[15]。因此,本文提出一种融合相位、振幅和频率3种特征数据的GNSS-IR

土壤湿度反演方法,通过同时输入3种特征的全部可用数据,并且根据一定的筛选方法来对输入的特征数据进行调整,提升GNSS-IR土壤湿度反演的精度和可靠性。

1 GNSS-IR土壤湿度反演模型

1.1 GNSS-IR几何原理

在理想观测环境下,GNSS信号的多路径反射几何原理如图1所示。

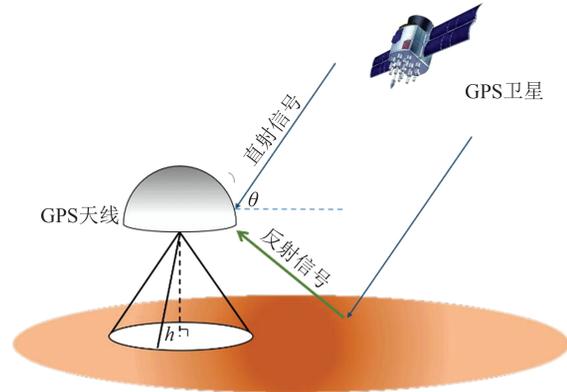


图1 直射、反射过程示意图

Fig. 1 Schematic Diagram of Direct Radiation and Reflection Process

GNSS-IR土壤湿度反演通常使用SNR观测值,接收机接收到的SNR信号包括直射信号和反射信号,可表示为:

$$\text{SNR}^2 = A_d^2 + A_m^2 + 2A_d A_m \cos\phi \quad (1)$$

式中, A_d 表示直射信号振幅; A_m 表示反射信号振幅; ϕ 表示反射信号相对于直射信号的相位延迟。通过低阶多项式拟合、去除趋势项可以消去式(1)中的 $A_d^2 + A_m^2$ (直射信号和少量的反射信号)项,剩余部分可用余弦模型近似表示:

$$\text{SNR}_r = A \cos\left(\frac{4\pi H}{\lambda} \sin\theta + \phi\right) \quad (2)$$

式中, λ 为信号波长; θ 为卫星高度角; H 为等效的反射器高度; A 为振幅; ϕ 为相位; SNR_r 为SNR反射信号分量。研究表明,卫星反射信号特征(包括振幅、相位和频率)和土壤湿度之间存在较强的相关性,能够用于土壤湿度的回归反演^[8-9]。通过Lomb-Scargle分析(非均匀周期性采样)可得到等效天线高度 H ,且式(2)中等效反射器高度 H

和反射信号频率 f 具有如下关系:

$$f = \frac{4\pi H}{\lambda} \quad (3)$$

由于 π 、 λ 都是常量,因此在反演过程中可用 H 表征频率。进一步利用最小二乘法拟合反射信号的时间序列,可得到 A 、 ϕ 。

1.2 机器学习模型

使用最小二乘支持向量机(least square support vector machine, LSSVM)、随机森林(random forest, RF),以及 BP 神经网络(back propagation neural network, BPNN)等机器学习模型,对各类信号特征进行训练和测试,即可反演得到测站附近的土壤湿度。

1.2.1 LSSVM

支持向量机(support vector machine, SVM)通过求解样本数据的最大间隔分离超平面并按照监督学习方式对数据进行二分类。文献[16-17]通过使用二范数形式的目标函数和用等式约束条件替代不等式约束条件,提出了可用于回归问题的 LSSVM 模型。在 LSSVM 中,求解的优化问题可以表示为:

$$\begin{cases} \min_{\mathbf{w}, \mathbf{b}, \mathbf{e}} (\mathbf{w}, \mathbf{e}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2 \\ \mathbf{y}_k = \mathbf{w}^T \varphi(\mathbf{x}_k) + \mathbf{b} + e_k \\ k = 1, 2, \dots, N \end{cases} \quad (4)$$

式中, \mathbf{w} 、 \mathbf{b} 是待求的分离超平面参数; e_k 为分类误差; γ 为惩罚系数,在式(4)中表示对所有样本分类误差平方和的容忍度; $\varphi(\cdot)$ 表示将使样本由低维空间转向高维空间的核函数。其中高斯核函数的表达式为:

$$\varphi(x_1, x_2) = e^{-\frac{(x_2 - x_1)^2}{2\sigma^2}} \quad (5)$$

式中, σ 为控制高斯核函数作用范围的参数,最终完成预报的公式如下:

$$\mathbf{y} = \mathbf{w}^T \varphi(\mathbf{x}) + \mathbf{b} \quad (6)$$

LSSVM 具有较快的求解速度,对小样本数据处理的效果较好,但是它的解不具备稀疏性,也无法保证是全局最优解。

1.2.2 RF

RF 根据集成学习的思想,通过 Bootstrap 算法对样本数据进行多次独立采样得到多个子样本集,每个子样本集根据一定的特征集合和分裂规则独立地生成一个弱决策树,最后通过集成多个弱决策树的预测结果得到最终预测结果。算法流程如图 2 所示。

RF 具有模型简单、求解速度较快的优点,且

由于每个子样本集及其特征集合都是原始数据集和原始特征集合的随机子集,因此具有较好的拟合效果和鲁棒性^[18],但缺点是在处理噪声较大的数据时容易出现过拟合现象,以及对特征较少的数据处理效果较差。

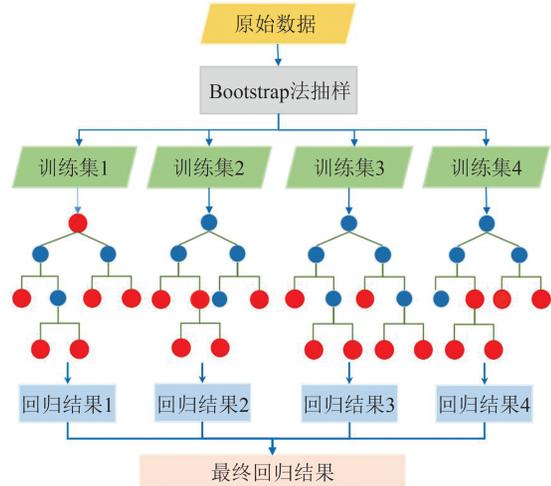


图 2 RF 示意图

Fig. 2 Random Forest Diagram

1.2.3 BPNN

BPNN 是根据误差反向传播定律提出的一种多层前馈神经网络,由输入层、隐藏层、输出层构成,隐藏层由若干个神经元构成。BP 神经网络的流程如图 3 所示,输入数通过正向传播到达输出层,计算损失函数后开始负向传播,经过各神经元并根据损失修改所在神经元的权重,通过重复上述过程实现神经网络的收敛稳定^[19]。

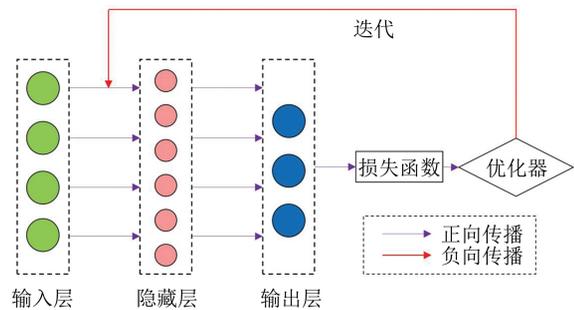


图 3 BPNN 示意图

Fig. 3 Structure of BP Neural Network

BPNN 具备处理任何非线性映射的能力,对于复杂问题的处理效果较好,但它属于一种局部搜索的优化方法,有时会因为模型的学习能力过强而出现过拟合。

2 融合多特征的土壤湿度反演方法

融合相位、频率和振幅 3 种特征反演土壤湿

度的算法流程如图4所示,具体步骤如下:

1)提取SNR反射信号特征序列。根据§1.1介绍的GNSS-IR几何原理,提取反射信号的相位、频率和振幅时间序列。

2)数据归一化处理。由于GPS卫星功率水平不同,不同卫星特征序列数值上存在差异;且相位、振幅、频率3种特征序列本身量纲不同,数值差异也较大,因此需要对特征数据进行归一化后映射到0~1之间,从而保证不同的特征数据对模型的影响权重相同。文献[8-9]提供了一种数据归一化的计算方法,计算式如下:

$$\bar{x}_i = \frac{x_i - x_{\text{start}}}{x_{\text{end}} - x_{\text{start}}} \quad (7)$$

式中, x_{start} 、 x_i 和 x_{end} 分别表示特征序列的第一个、第*i*个和最后一个数据; \bar{x}_i 表示经过归一化后的某个数据。

3)基于相关性的单一特征筛选。通过步骤1)初步提取的特征序列数目较大,导致输入特征数据矩阵的维度过高,这样不仅加重计算负担,而且容易产生过拟合,导致反演精度变差,因此需要对所提取特征序列进行质量评估、筛选,即有选择地对特征序列进行融合。文献[15]表明在特征选择算法中,可以根据单一特征拟合的相关系数大小进行排序,选择最优的几个特征,从而完成筛选,其中相关系数的计算公式如下:

$$R(y_{\text{true}}, y_{\text{pred}}) = \frac{\text{Cov}(y_{\text{true}}, y_{\text{pred}})}{\sqrt{\text{Var}(y_{\text{true}})} \sqrt{\text{Var}(y_{\text{pred}})}} \quad (8)$$

式中, y_{true} 、 y_{pred} 分别表示土壤湿度的参考值和预测值。

由于单一特征序列也可以进行简单的线性回归反演^[8-9],因此先用每一条特征序列做一元线性回归反演,将预测结果和土壤湿度的相关系数*R*作为特征序列筛选的依据。

假设所有特征序列的相关系数计算结果为 $R_1, R_2, \dots, R_N (R_1 > R_2 > \dots > R_N)$,在所有结果中,以最好反演结果 r_1 为参考,对 $\frac{R_i}{R_1} < k$ 的特征序列进行剔除。其中, k 是相关系数容忍因子, k 越小则可接受的特征序列越多,实验中通过选择不同的*k*值来得到不同层次的特征选择结果。

4)多特征土壤湿度回归反演。由步骤1)~3)可以得到待输入回归反演模型的特征数据,由于机器学习算法的黑匣子特性,GNSS-IR土壤湿度回归反演问题可表示为:

$$\text{SMC} = f_i(\bar{X}), i = 1, 2, 3 \quad (9)$$

$$\bar{X} = [\bar{P}_1 \bar{P} \dots \bar{P}_{n_1} \bar{A}_1 \bar{A}_2 \dots \bar{A}_{n_2} \bar{H}_1 \bar{H}_2 \dots \bar{H}_{n_3}] \quad (10)$$

式中,SMC(soil moisture content)表示土壤湿度的预测结果; f_i 表示用于回归的机器学习模型; \bar{X} 表示经过归一化和特征筛选后的输入特征矩阵; \bar{P} 、 \bar{A} 、 \bar{H} 分别表示相位、振幅和频率特征序列, n_1 、 n_2 、 n_3 分别是其相应的特征序列数目。

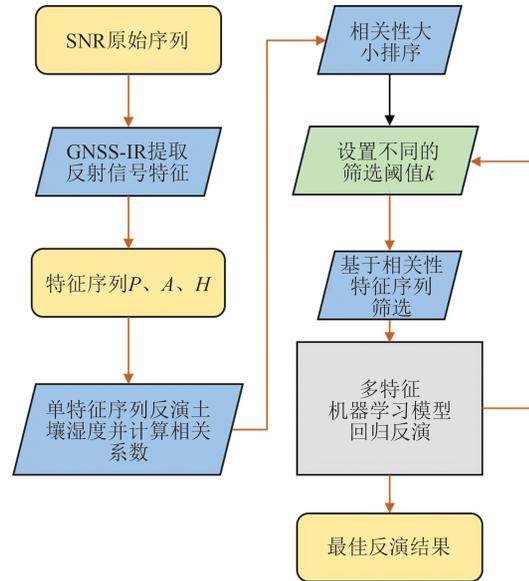


图4 本文算法流程图

Fig. 4 Flowchart of the Proposed Method

3 实验验证

3.1 实验数据

实验数据来自美国大陆板块边界观测网(PBO<https://www.unavco.org>)中的P035、P037、P038、P040共4个测站,站点周围无遮挡,植被稀疏,地形平坦。PBO网络有GPS双频观测值,但文献[7]表明GPS系统L2频率的SNR观测值更适于地基土壤湿度反演,因此实验中使用L2频率的SNR观测值。实验数据采集的测站情况见表1。土壤湿度参考数据来自PBO H₂O Data Portal(<http://cires1.colorado.edu/portal/>)。

3.2 实验结果与分析

基于上述理论和方法,反演得到各测站连续2个月(2017年年积日178—230)的土壤湿度时间序列。以P040测站为例,图5给出了利用单一相位、振幅、频率以及三者融合的土壤湿度反演结果及其与参考值的相关系数(*R*)。其他测站结果类似,限于篇幅,不一一罗列。4个测站反演结果的均方根误差(root mean square error, RMSE)和相关系数*R*统计如表2所示。

表 1 实验数据采集的测站情况

Table 1 Situation of the Stations in the Experiment Data

测站名	经纬度	测站环境	接收机	天线
P035	105.08°W, 36.60°N	草地, 四周空旷	Trimble NetRS	TRM29659.00
P037	105.10°W, 38.42°N	草地, 四周空旷	Trimble NetRS	TRM29659.00
P038	103.41°W, 34.15°N	灌木丛, 四周空旷	Trimble NetRS	TRM29659.00
P040	102.69°W, 38.07°N	草地, 四周空旷	Trimble NetRS	TRM29659.00

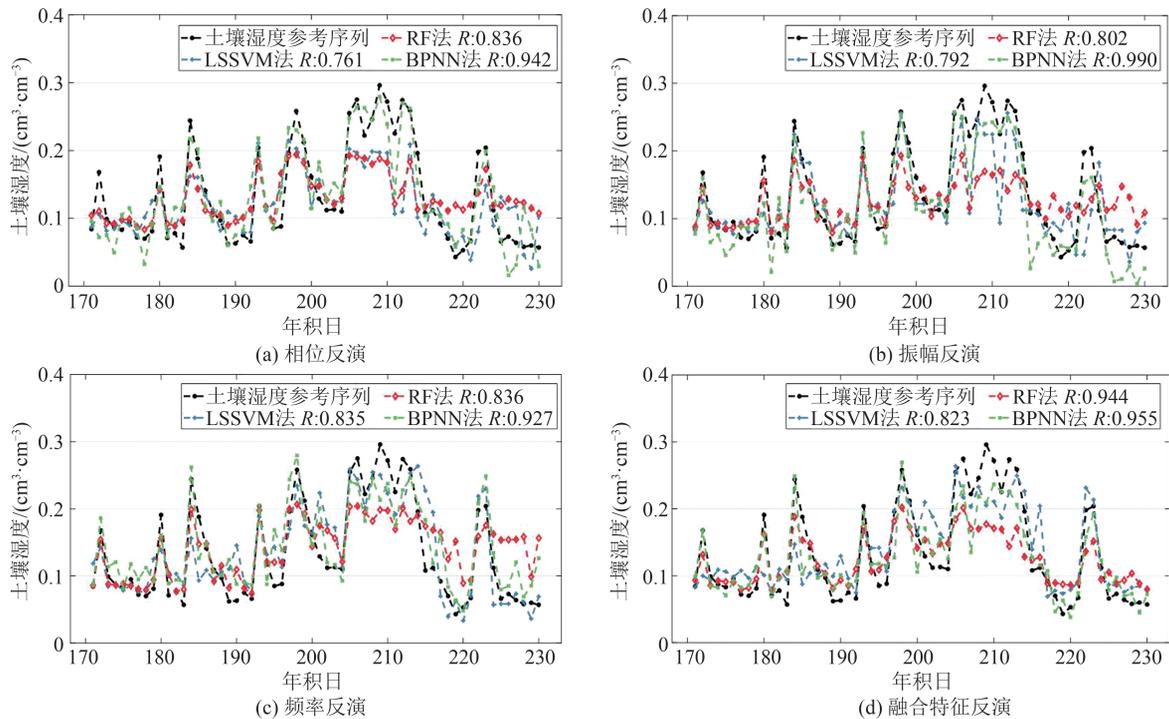


图 5 P040 测站相位、振幅、频率、融合特征反演土壤湿度序列

Fig. 5 Phase, Amplitude, Frequency, Combined Soil Moisture Sequences at P040 Station

表 2 反演结果精度指标统计

Tab. 2 Statistics of Inversion Result Accuracy Index

统计项	指标	LSSVM	RF	BPNN
相位	R	0.792	0.849	0.934
	RMSE/(cm ³ ·cm ⁻³)	0.050	0.034	0.038
振幅	R	0.776	0.841	0.968
	RMSE	0.053	0.046	0.033
频率	R	0.836	0.909	0.941
	RMSE/(cm ³ ·cm ⁻³)	0.045	0.037	0.037
融合	R	0.830	0.953	0.980
	RMSE/(cm ³ ·cm ⁻³)	0.045	0.035	0.032

由图 5 可知,基于不同特征数据、不同模型反演得到的土壤湿度具有一定差异,但总体上与土壤湿度参考值具有较好的一致性。

由表 2 的统计结果可知,基于单一相位、振幅和频率特征数据,RF 模型反演得到的土壤湿度与参考值的相关系数介于 0.841~0.909, RMSE 为 0.034~0.046 cm³/cm³; LSSVM 模型的相关系数介于 0.776~0.836, RMSE 为 0.045~0.053 cm³/cm³;

BPNN 模型的相关系数介于 0.934~0.968, RMSE 为 0.033~0.038 cm³/cm³。基于三者融合的特征数据,RF、LSSVM 和 BPNN 模型的相关系数分别为 0.953、0.830 和 0.980,对应的 RMSE 分别为 0.035、0.045 和 0.032 cm³/cm³。比较 3 种机器学习模型的反演效果不难发现, BPNN 模型相对最优, RF 模型次之, LSSVM 模型最差。

对比融合 3 种特征的反演结果相比单一特征的改善效果可以发现,在大多数情况下,使用融合特征的反演效果都有不同程度的改善。就 3 种机器学习模型反演精度提升的平均水平而言,在相位、振幅、频率上,使用多特征融合法后的反演精度分别提高了 7.7%、14% 和 6.3%。

需要说明的是,不同机器学习或深度学习模型反演土壤湿度的精度取决于输入特征数据的质量好坏,以及该模型对于不同特征的拟合与预测能力。如前文所述, GNSS-IR 方法提取的 GNSS 反射信号中不同卫星对应的特征序列本身具有相关性,尤其是在提取的信息中具有较多的

噪声时容易使模型出现过拟合,从而导致由于模型自身特性引起的反演精度下降问题。因此,相较于单一特征输入的土壤湿度反演方法,采用相位、振幅和频率数据特征进行融合反演的方法,在不同反演模型的表现上相当于取3种特征的最优值,既增强了数据可用性,又提高了GNSS-IR土壤湿度反演的精度和可靠性。

4 结 语

针对单一特征数据质量参差不齐、可靠性差,模型反演结果不稳定的问题,本文提出了一种融合相位、振幅、频率3种特征数据的GNSS-IR土壤湿度反演方法,通过对不同特征数据进行聚类分析和归一化,评估各类特征数据质量,并筛选出质量好的特征数据用于模型训练,从而提高模型预测能力:

为验证本文方法的有效性,利用美国PBO 4个GPS观测站的实测数据,采用LSSVM、RF和BPNN 3种机器学习模型,对比分析了基于单一相位、振幅、频率以及三者融合特征输入的土壤湿度反演性能,结果表明:

1)基于不同特征数据、不同模型反演得到的土壤湿度总体上与土壤湿度参考值具有较好的一致性,相关系数达到0.776~0.980, RMSE为0.032~0.053 cm³/cm³。

2)相比于单一特征反演方法,多特征融合的反演方法能够提高土壤湿度反演的精度和可靠性;但不同机器学习模型反演结果存在差异。RF、LSSVM和BPNN模型的相关系数分别为0.953、0.830和0.980,对应的RMSE分别为0.035、0.045和0.032 cm³/cm³,即BPNN模型相对最优,RF模型次之,LSSVM模型最差。

未来拟对GNSS-IR提取的特征进行降维、筛选,并尝试加入其他外部数据,如地形、温度、天气、设备等信息来削弱由于反射信号噪声引起的误差,利用更加多样化的特征数据来提高目前使用的机器学习、深度学习算法的反演性能。

参 考 文 献

- [1] Zhang Shuangcheng, Dai Kaiyang, Nan Yang, et al. Preliminary Research on GNSS-MR for Snow Depth [J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(2): 234-240. (张双成, 戴凯阳, 南阳, 等. GNSS-MR技术用于雪深探测的初步研究[J]. 武汉大学学报(信息科学版), 2018, 43(2): 234-240.)
- [2] Wu Jizhong, Wang Tian, Wu Wei. Retrieval Model for Soil Moisture Content Using GPS-Interferometric Reflectometry[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(6): 887-892. (吴继忠, 王天, 吴玮. 利用GPS-IR监测土壤含水量的反演模型[J]. 武汉大学学报(信息科学版), 2018, 43(6): 887-892.)
- [3] Deng Yingchun, Xu Yonghui. A Review of Research on Soil Moisture Measurement Methods [J]. *Hydrology*, 2007(4):20-24. (邓英春, 许永辉. 土壤水分测量方法研究综述[J]. 水文, 2007(4):20-24.)
- [4] Small EE, Larson K M, Chew C C, et al. Validation of GPS-IR Soil Moisture Retrievals: Comparison of Different Algorithms to Remove Vegetation Effects [J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2016, 9(10): 4759-4770.
- [5] Larson K M, Braun J J, Small E E, et al. GPS Multipath and Its Relation to Near-Surface Soil Moisture Content [J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2010, 3(1):91-99.
- [6] Larson K M, Small E E, Gutmann E D, et al. Use of GPS Receivers as a Soil Moisture Network for Water Cycle Studies[J]. *Geophysical Research Letters*, 2008, 35(24): L24405-1.
- [7] Vey S, Güntner A, Wickert J, et al. Long-Term Soil Moisture Dynamics Derived from GNSS Interferometric Reflectometry: A Case Study for Sutherland, South Africa [J]. *GPS Solutions*, 2016, 20(4):641-654.
- [8] Chew CC, Small E E, Larson K M. An Algorithm for Soil Moisture Estimation Using GPS-Interferometric Reflectometry for Bare and Vegetated Soil [J]. *GPS Solutions*, 2016, 20(3): 525-537.
- [9] Chew C C, Small E E, Larson K M, et al. Effects of Near-Surface Soil Moisture on GPS SNR Data: Development of a Retrieval Algorithm for Soil Moisture [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(1): 537-543.
- [10] Feng Qiulin. Soil Moisture Retrieval Using GNSS Reflected Signal Based on Machine Learning [D]. Xuzhou: China University of Mining and Technology, 2019. (丰秋林. 基于机器学习的GNSS反射信号土壤湿度反演方法研究[D]. 徐州: 中国矿业大学, 2019.)
- [11] Zhang S B, Roussel N, Boniface K, et al. Use of Reflected GNSS SNR Data to Retrieve Either Soil Moisture or Vegetation Height from a Wheat Crop

- [J]. *Hydrology and Earth System Sciences*, 2017, 21(9): 4767-4784.
- [12] Ren C, Liang Y J, Lu X J, et al. Research on the Soil Moisture Sliding Estimation Method Using the LS-SVM Based on Multi-Satellite Fusion [J]. *International Journal of Remote Sensing*, 2019, 40(5/6): 2104-2119.
- [13] Sun Bo, Liang Yong, Han Mutian, et al. GNSS-IR Soil Moisture Inversion Method Based on GA-SVM[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2019, 45(3): 486-492. (孙波, 梁勇, 汉牟田, 等. 基于 GA-SVM 的 GNSS-IR 土壤湿度反演方法[J]. 北京航空航天大学学报, 2019, 45(3): 486-492.)
- [14] Chen Kun, Shen Fei, Cao Xinyun, et al. Retrieving GNSS-IR Soil Moisture Based on Deep Belief Network[J]. *Bulletin of Surveying and Mapping*, 2020(9): 100-105. (陈堃, 沈飞, 曹新运, 等. 基于深度置信网络的 GNSS-IR 土壤湿度反演[J]. 测绘通报, 2020(9): 100-105.)
- [15] Jia Yan, Jin Shuanggen, Xiao Zhiyu, et al. Soil Moisture Remote Sensing Using Global Navigation Satellite System-Reflectometry: Current Status and Opportunity[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(11): 1784-1799. (贾燕, 金双根, 肖智宇, 等. 全球导航卫星系统反射测量土壤水分遥感: 现状与机遇[J]. 武汉大学学报(信息科学版), 2023, 48(11): 1784-1799.)
- [16] Suykens J, Lukas L, Van Dooren P. Least Squares Support Vector Machine Classifiers: A Large Scale Algorithm [C]//European Conference on Circuit Theory and Design(ECCTD'99), Stresa, Italy, 1999.
- [17] Suykens J A K, Brabanter J D, Lukas L, et al. Weighted Least Squares Support Vector Machines: Robustness and Sparse Approximation [J]. *Neurocomputing*, 2002, 48(1-4):85-105.
- [18] Sun Bo, Zhang Chi, Yin Shichao, et al. Research on GNSS-IR Soil Moisture Inversion Method Based on PSO-RF[J]. *Radio Engineering*, 2021, 51(10): 1080-1085. (孙波, 张弛, 尹世超, 等. 基于 PSO-RF 的 GNSS-IR 土壤湿度反演方法研究[J]. 无线电工程, 2021, 51(10): 1080-1085.)
- [19] Liang Y J, Chao R, Wang H Y, et al. Research on Soil Moisture Inversion Method Based on GA-BP Neural Network Model[J]. *International Journal of Remote Sensing*, 2019, 40(5/6): 2087- 2103.