长短时记忆网络TS-InSAR 地表形变预测

陈毅,何毅,张立峰,陈宝山,何旭,蒲虹宇,曹胜鹏, 高丽雅,杨旺

1. 兰州交通大学 测绘与地理信息学院, 兰州 730070; 2. 地理国情监测技术应用国家地方联合工程研究中心, 兰州 730070; 3. 甘肃省地理国情监测工程实验室, 兰州 730070

摘 要:预测地面沉降对于城市基础设施损害的早期预警和及时采取补救措施具有重要意义。本文提出基于时序 InSAR 数据采用长短时记忆网络(LSTM)模型来预测地面沉降。以香港国际机场为研究区域,基于 Sentinel-1A 升轨影像利用时序雷达干涉技术(TS-InSAR)获取 2015 年—2020 年机场时序地面沉降监测 InSAR 结果;利用机场时序 InSAR 形变结果建立堆叠式 LSTM 预测模型,并将预测结果与 InSAR 真实结果进行对比分析。结果表明,2015 年—2020 年香港国际机场地表垂直方向的平均形变速率为-19—5 mm/a。预测值与真实值的拟合均方根误差和平均绝对误差均较低,分别为 0.75 mm 和 0.61 mm,同时其相关系数为 0.99,表明 LSTM 预测模型在点级尺度上具有良好的性能,能够基于时序 InSAR 数据较准确预测地面沉降。但预测过程中发现,LSTM 模型不适合长期预测,长期预测会出现失效性。本文提出的堆叠式 LSTM 预测模型可以作为一种有效方法来预测地表形变,尽管 LSTM 模型只是适用于短期预测,但其预测结果可用于辅助决策、早期预警和减轻危害。

关键词: 遥感,地面沉降, TS-InSAR, 地表形变预测, 深度学习, LSTM

引用格式: 陈毅,何毅,张立峰,陈宝山,何旭,蒲虹宇,曹胜鹏,高丽雅,杨旺.2022.长短时记忆网络TS-InSAR地表形变预测.遥感学报,26(7):1326-1341

Chen Y, He Y, Zhang L F, Chen B S, He X, Pu H Y, Cao S P, Gao L Y and Yang W. 2022. Surface deformation prediction based on TS-InSAR technology and long short-term memory networks. National Remote Sensing Bulletin, 26(7):1326-1341[DOI:10.11834/jrs.20221457]

1 引 言

城市地面沉降是自然和人为因素作用下形成的一种地质灾害,累积性的地面沉降极易引起建筑物受损、基础设施破坏、地下工程等多种危害,严重威胁人民的生命财产安全,造成国民经济损失(曹群等,2019)。目前,中国已超过50个城市发生不同程度的地面沉降(Deng等,2017),地面沉降问题已成为世界性地质问题。因此,面对城市地面沉降问题,迫切需要监测、分析和预测地面沉降时空变化。

在城市及复杂地形区域,相比于传统大地测量 技术(GPS、水准)的局部单点测量、空间分辨率 低和成本高等缺点(Aobpaet等, 2013),时序干涉合成孔径雷达TS-InSAR(Time-Series Interferometric Synthetic Aperture Radar)技术可以实现大范围、高精度、高密度和低成本的观测(Qu等, 2015)。其中永久散射体雷达干涉PS-InSAR(Permanent Scatterer Interferometric Synthetic Aperture Radar)技术和小基线集雷达干涉SBAS-InSAR(Small BAseline Subset Interferometric Synthetic Aperture Radar)技术被广泛用于地面沉降监测的应用(陈有东等, 2021;Galloway和Burbey,2011;He等, 2020,2021;Wang等, 2020;Dehghan-Soraki等, 2015)。PS-InSAR(Ferretti等, 2001,2004)技术基于高稳定性和强反射性的时序稳定点目标的

收稿日期: 2021-07-05; 预印本: 2022-01-17

基金项目: 中国博士后科学基金面上基金(编号:2019M660092XB);甘肃省科技计划资助(编号:20JR2RA002);甘肃省自然科学基金(编号:20JR10RA249);甘肃省青年科学基金(编号:20JR10RA272);兰州交通大学-天津大学创新项目基金项目(编号:2020055);兰州交通大学优秀平台(编号:201806);嘉峪关市主城区地表沉降InSAR监测系统(编号:221296)

第一作者简介: 陈毅, 研究方向为基于 InSAR 和深度学习地面形变研究。E-mail: 0219737@stu.lzjtu.edu.cn 通信作者简介: 何毅, 研究方向为 InSAR 形变监测和生态环境遥感。E-mail: heyi8738@163.com

相位信息进行时序建模与分析,极大地降低了大气延迟等带来的误差,使得形变精度可达毫米级别(林珲等,2017)。SBAS-InSAR(Berardino等,2002;Lanari等,2007)技术利用多主影像将长基线变成短基线形成干涉图对网络进行精确分析,有效减小时空基线过长带来的大气延迟和相关噪声误差(Ye等,2016)。这两种方法在地面沉降监测方面已经取得较大的成功。同时,TS-InSAR监测的形变结果作为一种精度高且范围广的数据源,可利用其对地面沉降进行预测。

长短时记忆LSTM (Long Short-Term Memory) 网络作为一类专门处理序列数据的神经网络,其 对时间序列数据特征学习有着独特的优势, 在 LSTM 中,有两个模块帮助它学习数据的时序特 征,一个是记忆模块,另一个是门模块,一个序 列的输出与其前面的输出有关系,相比较于其他 传统神经网络隐藏层之间不再是无连接而是有连 接(刘新等, 2020)。综上, 考虑到LSTM具有的 优势正好与时序 InSAR 结果相对应,因此,本文 提出采用LSTM网络模型进行地表时序InSAR形变 预测,基于TS-InSAR 时序形变结果模拟建立堆叠 式LSTM 预测模型,将其预测结果与真实InSAR结 果进行精度对比验证,利用LSTM 预测模型对香港 国际机场地面沉降进行短期时序预测,这对早期 预警和减轻地面沉降灾害具有重要意义,同时也 是实现城市可持续发展的必要条件。

2 研究区和数据源

2.1 研究区

香港国际机场位于亚洲东部亚热带季风气候区,其特点是年平均气温高(23.5°C)和年平均降水量高(2214.3 mm/a)(Zhao等,2011)。如图1所示,机场面积约为12.55 km²,平台构成约有25%是以两个现有自然岛屿为基础,即赤鱲角和榄洲,剩下的75%是由填海造岛建成(Wu等,2020)。机场修建首先从赤鱲角岛开始,北部和南部分别在1994年和1995年完成。最后完成榄洲岛以西和赤鱲角岛西北部分。其中T1航站楼于1998年完工并投入使用,占地面积为570000 m²。T2航站楼于2007年投入使用,占地面积140000 m²。跑道长达3800 m,可容纳各种型号和大小的客机和货机。自1998年启用以来,香港国际机场一直是东亚地区最大的机场之一。截至2018年,香港国际机场旅

客吞吐量7467.2万人次,货邮吞吐量512.1万t分别位居世界第8位、第1位。

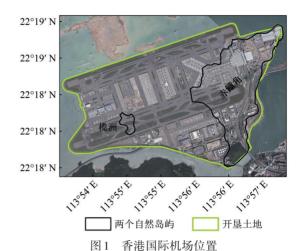


Fig. 1 Location of Hong Kong International Airport

2.2 数据源

本文使用的 SAR 数据是 C 波段 Sentinel-1A 影像。从欧空局 ESA(European Space Agency)获取 2015年—2020年 Sentinel-1A IW 模式影像和精密轨道数据 POD(Precise Orbit Ephemerides)进行后续处理分析。影像最大时间基线为 936 d,垂直基线范围是从 2.2—126.1 m。详细信息如表 1。为了去除地形相位,本实验所采用的数字高程模型是利用 ALOS PALSAR 数据(https://search.asf.alaska.edu/[2021-07-05] 获取的 12.5 m 高分辨率高程数据。

表 1 SAR 数据详细信息 Table 1 SAR data details

传感器	Sentinel-1A
波段	С
波长/cm	5.6
入射角/(°)	44.01
极化方式	VV
空间分辨率/m	5×20
重访周期/d	12
轨道方向	升轨
影像数量	152
日期范围	2015-06-2020-12

3 研究方法

3.1 PS-InSAR

PS-InSAR技术方法是由Ferretti等(2001)提出,该技术是根据影像的幅度、相位信息探测出

相关性高、稳定的点,即永久散射体,它被定义为在长时间序列中能够保持高相干性且强散射特性的地物目标,一般是岩石、人工建筑物等目标。其核心原理是对永久散射体点建立差分干涉相位模型,根据各相位分量的时空特性逐个分离,最终获取每个点的线性和非线性变量。采用一般的线性模型假设,利用线性模型进行估算目标点的残余高程和线性形变速率,残余误差中可通过空间域和时间域的滤波得到大气相位和非线性形变估计。具体算法如下:

获取覆盖同一区域的N+1 幅 SAR 影像,选择其中一幅影像作为参考影像,然后进行配准、重采样、去平地和地形相位和干涉处理得到N 幅干涉图像。利用参考 DEM 和卫星轨道数据对干涉图进行地形校正,第i 幅干涉对x 位置处的干涉图相位 ϕ_x 可以表示为

$$\phi_{x,i} = \phi_{\text{defo},x,i} + \phi_{\text{topo},x,i} + \phi_{\text{const},x,i} + \phi_{\text{slope},x,i} + \phi_{\text{slope},x,i} + \phi_{\text{noise},x,i}$$

$$(1)$$

式中, $\phi_{const,x,i}$, $\phi_{slope,x,i}$ 和 $\phi_{atm,x,i}$ 三分量之和被称为大气相位屏 APS(Atmospheric Phase Screen),分别是恒定相位值,由大气效应引起的线性相位值,以及非线性大气效应。 $\phi_{defo,x,i}$ 和 $\phi_{topo,x,i}$ 分别表示雷达视线向的地表形变相位和 DEM 误差造成的地形相位。 $\phi_{noise,x,i}$ 表示噪声相位(散射体变化、热噪声、配准误差等引入的误差)。

使用 ENVI 平台 SARscape 应用的 PS-InSAR 方法处理数据。首先对获取的影像进行差分干涉处理并配准到参考影像,然后借助 PS点的强反射性,利用振幅离差指数挑选出高振幅值的像素作为 PS候选点,对其进行稳定性分析后再从候选点中精选出 PS点(刘国祥等,2012),最后基于线性形变模型进行反演得到线性形变速率及高程误差等信息,再将残余误差进行分解得到非线性形变信息,从而获取地表形变信息。具体过程如图 2 所示。

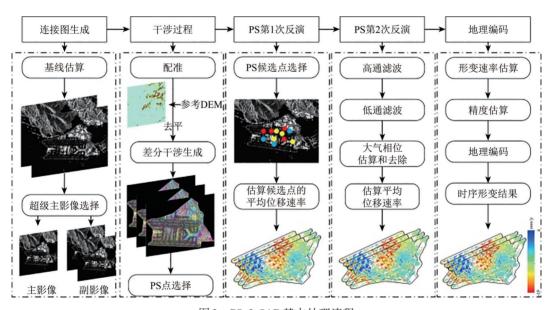


图 2 PS-InSAR 基本处理流程

Fig. 2 PS-InSAR basic processing flow

2018年5月18日图像被选择作为参考影像(图4)。第1次反演采用线性模型反演残余高度改正系数和候选PS点的平均变形速率。子区域大小为2 m²,根据振幅离差指数选择参考点,对每个子区域分别进行处理,对所有子区域的结果进行拼接,得到一个完整的结果,第2次反演使用一阶线性模型估计大气干扰相位分量,大气滤波器采用时间高通滤波器(365 d)和一个空间低通滤波器

(1200 m) 去除大气干扰相位成分,最后通过地理编码获得视线向形变速率和时间序列形变累积量。同时根据雷达入射角将视线向形变转为垂直向形变(He等,2020),转换公式如下:

$$d_v = \frac{d_{\text{Los}}}{\cos \theta} \tag{2}$$

式中, d_{Los} 为视线向形变结果, d_{v} 为垂直向形变结果, θ 为雷达入射角。

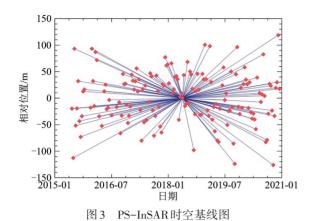


Fig. 3 PS-InSAR spatiotemporal baseline diagram

3.2 SBAS-InSAR

SBAS-InSAR技术是由 Berardino等(2002)提出,该技术核心原理是将所有的 SAR 影像据根据空间基线和时间基线在一定范围内的干涉对的组合成小基线集,使得各子集内图像基线距小,对每个子集中利用最小二乘法方法计算各子集内的时间序列的地表形变;对于各子集之间可能存在

的病态方程的参数解算的问题,应用奇异值分解 法来解决。通过多个干涉图的组合基于高相干点 建立线性形变模型进行反演得到线性形变速率及 高程误差等信息,再将残余误差进行分解得到非 线性形变信息。具体算法如下:

获取覆盖同一区域的 N+1 幅 SAR 影像,选择其中一幅影像作为参考影像,然后进行配准、重采样、去平地和地形相位,并根据合理的时空基线阈值得到 M 幅干涉图像,M 幅干涉对需满足 (N+1)/2 < M < N(N+1)/2不等式。第i 幅 $(i=1, \dots, M)$ 差分干涉图中像元 (x,y)的相位值为

$$\Delta\phi_{x}(x,y) = \phi(t_{B},x,y) - \phi(t_{A},x,y) \approx \Delta\phi_{\text{defo},(x,y),i} + \Delta\phi_{\text{lopo},(x,y),i} + \Delta\phi_{\text{atm},(x,y),i} + \Delta\phi_{\text{noise},(x,y),i}$$
(3)

式中, t_A 、 t_B ($t_A > t_B$)为第i幅干涉图对应的SAR影像获取时间, $\Delta \phi_{\text{defo.}(x,y),i}$ 为 $t_B \cong t_A$ 时刻对应的斜距向上的形变为形变相位, $\Delta \phi_{\text{topo.}(x,y),i}$ 为地形相位误差, $\Delta \phi_{\text{atm.}(x,y),i}$ 为大气相位误差, $\Delta \phi_{\text{noise.}(x,y),i}$ 为噪声相位误差。

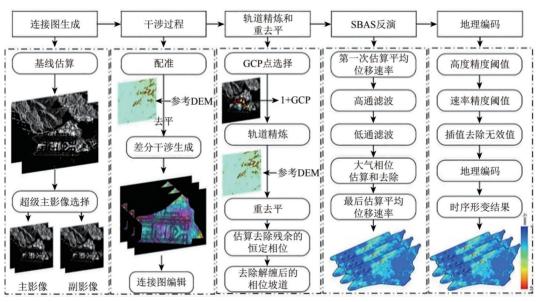


图 4 SBAS-InSAR 基本处理流程

Fig. 4 SBAS-InSAR basic processing flow

使用 ENVI 平台 SARscape 应用的 SBAS-InSAR 方法处理数据。首先对获取的影像进行基线估算筛选参考影像,同时将其与所有影像进行配准和重采样,然后通过去地平、干涉处理以及相位解缠得到差分干涉图和解缠图,并且进行轨道精炼和重去平去除残余相位。最后基于高相干点建立线性形变模型进行反演得到线性形变速率及高程

误差等信息,再将残余误差进行分解得到非线性 形变信息,利用SVD方法获取地表时序形变信息。 具体过程如图4所示。

2018年8月22日图像被选择作为参考影像(图5)。第1次反演采用线性模型反演残余高度改正系数和高相干点的初始平均变形速率,同时结合小基线数据利用SVD方法获取地表时序形变结

果。第2次反演使用一阶线性模型估计大气干扰相位分量,大气滤波器采用时间高通滤波器 (365 d)和一个空间低通滤波器 (1200 m)去除大气干扰相位成分,最后通过地理编码获得视线向形变速率和时间序列形变累积量,同时利用式 (2)根据雷达入射角将视线向形变转为垂直向形变。

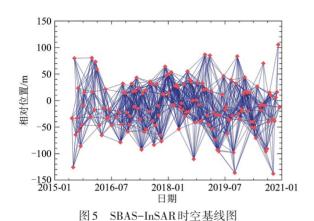


Fig. 5 SBAS-InSAR spatiotemporal baseline diagram

3.3 小波变换

小波分析是一种时、频多分辨率分析方法, 是时间和频率的区域变换,能有效的从信号中提 取信息(何毅等,2015),这里简单采用 Morlet 能 谱小波函数:

$$\psi_{(t)} = e^{-2\pi i t} \exp(-(2\pi/k\phi)^2 |t|^2)$$
 (4)

小波变化系数为

$$\xi(t',a) = a^{-\frac{1}{2}} \int f(t) \psi^* \left(\frac{t}{a} - \frac{t'}{a} \right) d_t \tag{5}$$

式中, $\xi(t',a)$ 是小波系数,f(t)是时间序列, ψ^* 是 $\psi_{(t)}$ 的共轭函数(魏凤英,2007);a是小波变换的尺度因子(伸缩因子);k是系数; ϕ 为相位。

本文采用小波变换来分析机场时间序列沉降的周期性变化,从而为LSTM预测模型中序列长度的选择提供参考。

3.4 地表形变预测模型

3.4.1 LSTM

LSTM 是传统循环神经网络的一种流行变体,由 Hochreiter等最早提出(Hochreiter和Schmidhuber,1997),目前已广泛应用于序列建模任务(Schmidhuber,2015)。相比于传统RNN,LSTM主要有两个模块帮助它从数据中学习时序特征(图6)。第1个是记忆模块,它被作为细胞状

态。第2个是门模块,一个输入门、输出门和一个遗忘门,可有效训练全连接层来控制细胞状态响应来自数据和模型过去输出的新输入。LSTM的门模块有效解决了传统循环神经网络梯度问题。对于较长的时间序列,RNN无法记住许多时间步之前的信息,进而无法学习到序列中可能存在的长期依赖问题。在LSTM中,数据信息被存储在一个单独的细胞中使用,这使得LSTM网络能够真正有效地利用长时间的时序信息(Graves, 2012)。

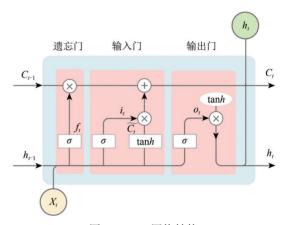


图6 LSTM网络结构

Fig. 6 Long short-term memory network structure

如图 6 所示,LSTM 第 1 阶段决定是否忘记或记住细胞状态下的信息,该阶段遗忘门的 sigmoid 层允许如果当前数据重要,以前的数据被遗忘。如果当前数据不需要,则可以记住以前的数据。遗忘门的计算公式如下:

$$f_t = \sigma \left(W_f \cdot (h_{t-1}, x_t) + b_f \right) \tag{6}$$

式中, σ 是 sigmoid 激活函数。 h_{t-1} 和 x_t 分别为t-1时刻的隐藏状态和输入向量, W_f 和 b_f 分别代表权重值和偏差值。如果 f_t 输出值接近0,表示以前的数据被遗忘,如果它接近1,则不表示以前的数据被记忆。

LSTM 第 2 阶段决定哪些新数据存储在细胞状态中。该阶段由两部分组成。(1) 输入门决定更新的值,以及一个 tanh 层创建一个新的候选值向量 \tilde{C}_i 它被添加到细胞状态。(2) 通过组合这两个阶段的数据,模型创建新值来更新细胞状态。输入门计算公式如下:

$$i_t = \sigma \left(W_i \cdot (h_{t-1}, x_t) + b_i \right) \tag{7}$$

$$\tilde{C}_{t} = \tan h \left(W_{c} \cdot (h_{t-1}, x_{t}) + b_{c} \right) \tag{8}$$

式中, σ 是 sigmoid 激活函数。 W_i 和 W_c 为更新的权

重, b, 为输入门的偏差, b, 为偏差。

LSTM 第 3 个阶段,利用 f_i 和 i_i · \tilde{C}_i 来更新旧的细胞状态 C_{i-1} , C_{i-1} 与 f_i 相乘来去除多余信息。新细胞状态 C_i 通过更新过去状态 C_{i-1} 获得。计算公式如下:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \tag{9}$$

LSTM最后一个阶段决定输出什么。首先通过 sigmoid 层输出 O_i , 它被应用于决定细胞状态的哪部分值将被输出。然后细胞状态通过 $\tan h$ 函数, 经过这个操作, 细胞状态值被缩放到-1和1之间。最后, 将结果与 sigmoid 门的输出相乘输出。计算公式如下:

$$O_t = \sigma \left(W_o \cdot (h_{t-1}, x_t) + b_o \right) \tag{10}$$

$$h_{t} = O_{t} \tan h(C_{t}) \tag{11}$$

式中, h_ι 代表新的输出值, W_a 和 b_a 分别为更新权值和输出门的偏差。

3.4.2 地表形变预测模型构建

LSTM作为一类专门处理序列数据的神经网络,其对时间序列数据特征学习有着独特的优势,而 InSAR 监测结果得到的是时间序列上的形变数据,即,时序形变数据x, $x = \{x_1, x_2, x_3, \cdots, x_{n-1}, x_n\}$ 。 考虑到LSTM具有的优势正好与时序 InSAR 结果相对应,本文基于时序 InSAR形变数据x, 采用堆叠式LSTM神经网络构建了地表形变数据x, 采用堆叠式LSTM神经网络构建了地表形变预测模型,如图7所示,模型由2层LSTM层、2层Dense层和3层Dropout层构成,预测模型能够有效学习时序形变数据的变化特征,通过堆叠式LSTM预测模型得到地表形变预测结果y, $y = \{y_1, y_2, y_3, \cdots, y_{n-1}, y_n\}$ 。

具体训练过程如下: (1) 网络初始化。初始化权重W和偏置向量,LSTM网络层数为2层,Dense层数为2层,采用Dropout层来抑制网络训练过程中出现过拟合情况,学习率为0.0001。最大训练次数2000,优化器为适应性动量估计Adam (Adaptive Moment Estimation)。

(2) 数据集归一化。为消除数据间产生量纲影响,需对原始时序 InSAR 数据集进行 Min-Max 归一化。原始时序 InSAR 数据集为 $x = \{x_1, x_2, \dots, x_n\}$,归一化数据集为 $x' = \{x'_1, x'_2, \dots, x'_n\}$,公式如下:

$$x' = (x - x_{\text{mean}})/(x_{\text{max}} - x_{\text{min}})$$
 (12)

(3) 数据集划分。为了增加时序InSAR数据的

样本容量,根据历史序列长度L,利用滑动窗口思想创建新的时序数x'', $x'' = \{x''_1, x''_2, \dots, x''_t, \dots, x''_{n-L-1}\}$,其中 $x''_t = (x''_t, x''_{t+1}, \dots x''_{t+L})$ 。并将x''划分为80%训练集和20%测试集,训练集 $x_{train} = \{x''_1, x''_2, \dots, x''_d\}$,测试集为 $x_{test} = \{x''_{d+1}, x''_{d+2}, \dots, x''_{n-L-1}\}$ 。

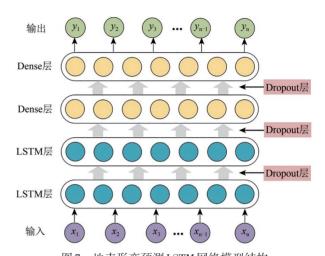


图 7 地表形变预测 LSTM 网络模型结构

Fig. 7 Structure of LSTM network model for surface deformation prediction

- (4) 输入输出形状。输入形状= (N, L, F); $N \times L \times F$ 分别代表样本数量、时间步长、特征数量。最后输出通过全连接层得到预测 $\{p_1, p_2 \cdots, p_n\}$ 值,输出形状= (1, F)。
- (5) 数据反归一化。将预测值 $\{p_1, p_2, \dots, p_n\}$ 反归一化得到最终的预测结果 $\{y_1, y_2, \dots, y_n\}$ 。公式如下:

$$y_n = p_n \left(x_{\text{max}} - x_{\text{min}} \right) + x_{\text{mean}}$$
 (13)

3.5 评价方法

为了评估构建的LSTM神经网络模型的预测精度,本研究使用两种精度指标分别是均方根误差RMSE(Root Mean Square Error)和平均绝对误差MAE(Mean Absolute Error)来评价预测模型的预测精度。

RMSE =
$$\sqrt{\sum_{t=1}^{N} (y_t - \tilde{y}_t)^2 / N}$$
 (14)

$$MAE = \frac{1}{N} \sum_{i=1}^{N} |y_i - \tilde{y}_i|$$
 (15)

式中, y_i 和 \tilde{y}_i 分别是时刻的沉降观测值和预测值;N为测试数据集的个数。

4 结果与讨论

4.1 精度验证

4.1.1 交叉验证

为了验证本文InSAR监测结果的可靠性,将 两种时序分析方法 (PS-InSAR 和 SBAS-InSAR) 的监测结果进行相关性计算。如图8所示,两种监 测结果相关性较高,相关系数为0.72,表明两种 方法的监测结果精度均较高,但从图8中看出绝大 部分点较为集中,大约在-10-5 mm,少部分点离 散,大约在-20-10 mm,这可能是由于两种方法 实现的不同,特别是连接图和GCP点的选择过程 不同,导致变形速率值出现差异。同时本文是利 用PS-InSAR 结果的高相干性PS点去提取SBAS-InSAR结果的像元值,在这个过程中,由于SBAS-InSAR 监测的是更密集分布点目标, PS点提取的 SBAS 像元值相干性会存在部分偏差。总的来说, PS-InSAR 和 SBAS-InSAR 监测结果的交叉验证 能够在一定程度上表明本文InSAR监测结果是可 靠的。

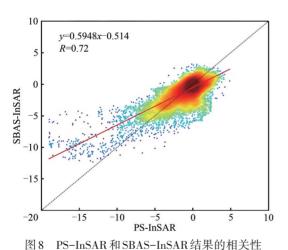


Fig. 8 Correlation of PS-InSAR and SBAS-InSAR results

4.1.2 外部验证

进一步采用水准数据验证监测结果的精度,选取水准点 100 m 缓冲区范围内 PS 点形变值的均值,并与水准点数据作对比。图 9 显示了 PS-InSAR 在 P1 区域的监测结果与水准数据误差为0.44 mm 和-1.03 mm, SBAS-InSAR 监测结果与水准数据误差为10.09 mm和 10.90 mm。说明在地表

物体丰富的城市区域,相比于SBAS-InSAR技术,PS-InSAR技术更适合于监测城市区域的地表形变变化,同时Ma等和Wu等的机场地表形变监测结果与本文结果基本一致(Ma等,2019; Wu等,2020)。因此,本文的形变监测结果是可靠的,并选取PS-InSAR的形变结果进行香港国际机场地表形变预测。

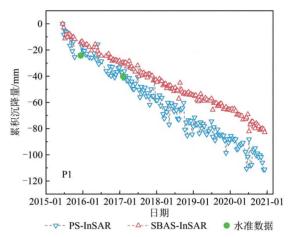


图 9 PS-InSAR和SBAS-InSAR结果与水准数据比较 Fig. 9 Comparison of PS-InSAR and SBAS-InSAR results with levelling data

4.2 香港国际机场地表形变时空分布

基于 152 幅升轨 Sentinel-1A 影像,利用 PS-InSAR技术的获取香港国际机场 2015 年—2020 年地表垂直向形变监测结果(图 10)。覆盖机场共计有 35816个 PS点,最大垂直沉降速率约为-19 mm/a,垂直抬升速率为 5 mm/a。

图10显示出机场典型区域的P1、P2、P3、P4、P5和P6点地表形变空间变化。航站楼附近的区域(P1)沉降程度较大,沉降速率最大已达-19 mm/a;机场东南方向建筑区(P3)有沉降,沉降速率大致在-16—-14 mm/a;北跑道沉降分布不均匀,东部(P2)和西部(P4)沉降较为严重,垂直沉降速率分别约为-16 mm/a和-14 mm/a;南跑道有轻微沉降,西部沉降速率约为-11 mm/a,值得注意的是,南跑道附近(P5点)所在区域地面沉降较为明显,沉降速率大约在-19—-16 mm/a,这可能导致南跑道西部发生沉降。P6所在区域形变速率大约在0—2 mm/a,该区域基本无变形。

图11显示出6个典型地表形变点的原始数据存在部分噪声,为防止其在地表形变预测模型构

建时产生误差影响,本文采用局部加权散点平滑法 Loess(Locally weighted scatterplot smoothing)进行降噪和平滑,该方法能够将线性回归的简易性与非线性回归的灵活性结合起来,极大程度保留了原始数据的特征变化(王海霞和李凯勇,2019)。

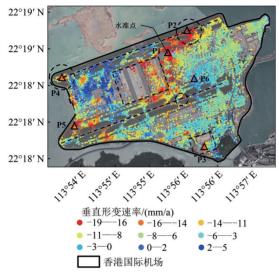


图 10 香港国际机场的垂直形变速率图 Fig. 10 Vertical deformation rates at Hong Kong International Airport

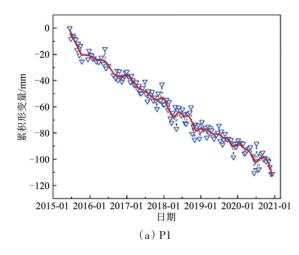
基于 PS 点监测结果利用反距离加权 IDW (Inverse Distance Weighted) 插值方法得到香港国际机场 2015年—2020年时序形变年际变化图,图 12中显示出机场地表形变空间分布不均匀,机场的东北方向、中心和西南方向沉降随着时间推移逐渐增加。其中南北跑道有较大沉降,航站楼附近和中

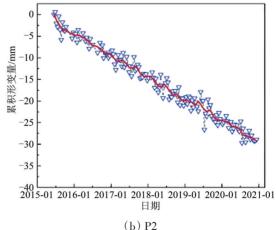
场客运廊道沉降较为严重,时序图显示机场累积沉降量逐渐增加,最大累积沉降量已达116 mm。

4.3 香港国际机场地表形变预测

4.3.1 确定历史序列 L 长度

本文基于35816个PS地表形变点数据,经过 数据预处理,利用Python 3.7语言和Tensorflow 2.0 深度学习框架构建LSTM 预测模型。实验过程中, 采用滑动窗口思想创建时序InSAR地表形变数据 集时发现不同历史序列长度会影响模型预测结果 的精度。本文利用小波变换确定最佳历史序列长 度,样本数量N和特征数量F的取值分别为146和 35816。首先利用小波变换进行机场时序 InSAR 地 表沉降的周期监测,图13显示出香港国际机场地 表沉降存在几个主周期,波峰大致在1-25、50、 85 和 130 附近,本文选择沉降主周期作为历史序 列长度L,通过对比不同历史序列的误差变化进一 步确定最佳历史序列长度。误差变化如图14所示, 随着历史序列长度变化,均方根误差和平均绝对 误差波动变化较大, 当1<L<5, 误差变化趋势逐渐 降低, 当5<L<10, 误差变化趋于平稳, 当10<L< 130, 误差变化波动较大, 虽然误差也有逐渐下降 的趋势, 但是误差变化不稳定会影响预测结果的 精度,误差结果表明LSTM模型并不适合过长的历 史序列长度。因此,本文历史序列长度的选择规 则为误差变化平稳且误差值较低,由于5<L<10的 序列长度误差变化稳定, 所以选取的最佳历史序 列 L=5。





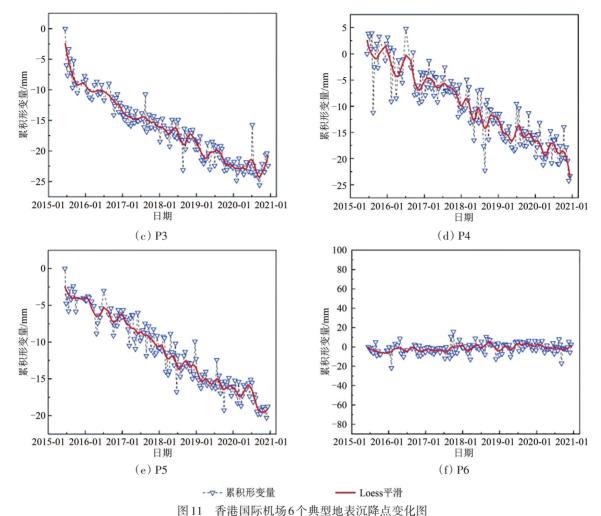


Fig. 11 Changes in six typical surface subsidence points at Hong Kong International Airport

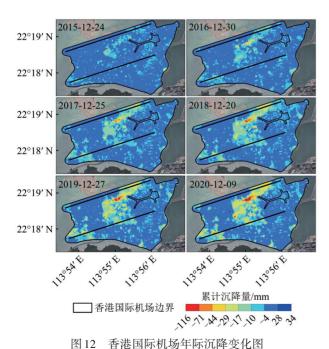
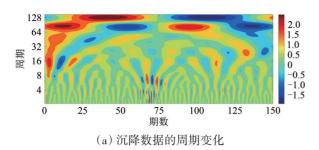


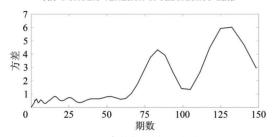
图 12 背後国际机场中外机罐变化图 Fig. 12 Interannual subsidence variation at Hong Kong International Airport

4.3.2 模拟结果

LSTM 预测模型受网络层数、学习率,隐藏层 单元数和训练次数等多个超参数的影响,其中样 本划分长度(历史序列长度)、网络层数和隐藏层 单元数影响最为关键。因此,通过试错法调试超 参数,经过多次调试得到最佳超参数,样本划分 长度(历史序列长度)为5,LSTM网络层数为2, 隐藏层单元数,第1层256,第2层128,同时利用 这些超参数训练得到 LSTM 预测模型。从图 15 可 以看出,模型训练过程中,损失函数(Loss)和平 均绝对误差 (MAE) 变化收敛正常, 网络训练中 出现的过拟合被有效抑制,因此,本文训练的 LSTM模型是一个有效模型。利用LSTM预测模型 拟合训练数据集和测试数据集,发现预测模型在 训练数据集和测试数据集上都有良好的性能表现。 此外,通过随机抽取测试数据集6个时期的形变数 据和预测数据进行相关性计算,如图16所示,相 关性系数均为0.99,两者相关性高,表明本文实验训练的LSTM预测模型是有效的。



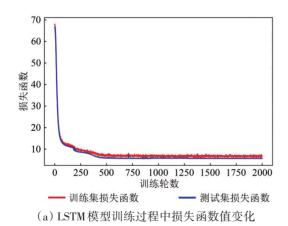
(a) Periodic variation of subsidence data



(b) 沉降数据的方差变化(b) Variance change of subsidence data

图 13 香港国际机场沉降的周期检测

Fig. 13 Periodic detection of subsidence at Hong Kong International Airport



(a) Variation of Loss function value during LSTM model training

图 17显示了 LSTM 模型在原始时序形变数据的拟合结果,真实值和预测值的 RMSE和 MAE 均较低,最低分别为 0.75 mm 和 0.61 mm,表明 LSTM 模型对于时序数据波动变化有良好的捕捉能力。因此,在处理时序数据时,LSTM 网络具有独特的优势。

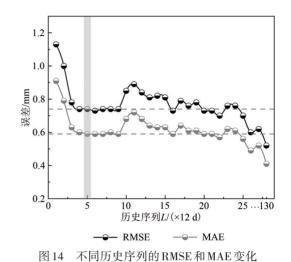
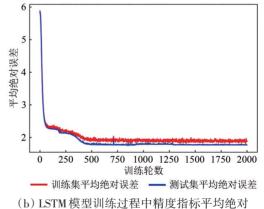


Fig. 14 Changes in RMSE and MAE for different historical



(b) LSTM 模型训练过程中精度指标平均绝对 误差值变化

(b) Variation of accuracy metric mean absolute error values during LSTM model training

图 15 LSTM模型训练过程中指标值变化

Fig. 15 Changes in metric values during LSTM model training

4.3.3 预测结果

本文基于构建的 LSTM 预测模型,设 InSAR形变时间序列为 $x = \{x_i\}, t = 1, 2, 3, \cdots, n$,其中 x_i 是t时刻的 InSAR 形变观测值。X和 Y分别为输入数据、预测数据。采用t个连续沉降观测值,预测之后 Delay 个时间步的沉降量,其中 Delay=1,预测

过程采用循环预测模式,即利用上一次时序数据 预测得到的Y,将其添加到输入数据集中组成新的 数据集X,然后再预测新的Y。

在最后一期形变数据基础上,即 2020年12月9日的形变数据。利用构建的堆叠式 LSTM 预测模型,通过循环预测模式获取香港国际机场未来一年

的地表形变预测结果,如图18(a)所示,LSTM预 测值随着时间增加呈波动趋势,大约在6个月以后 的预测值呈水平趋势,即,形变基本保持不变, 表明构建的堆叠式LSTM预测模型具有短期预测的 能力,并不适合长期预测,长期预测可能会导致

模型失效。因此,本文提出的堆叠式LSTM 预测模 型可以进行短期地表形变预测, 短期预测的尺度 约为6个月,预测的变形可用于辅助决策,预防和 缓解地面沉降。

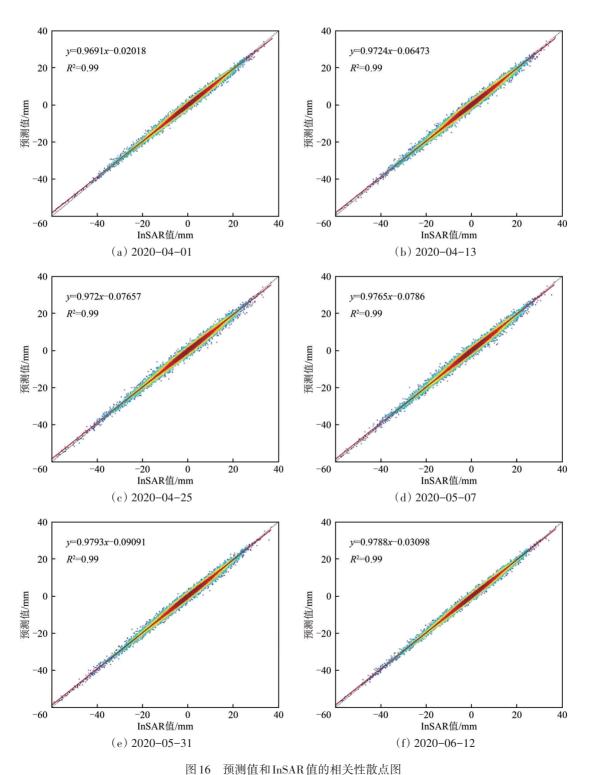


Fig. 16 Scatter plot of correlation between predicted and InSAR values

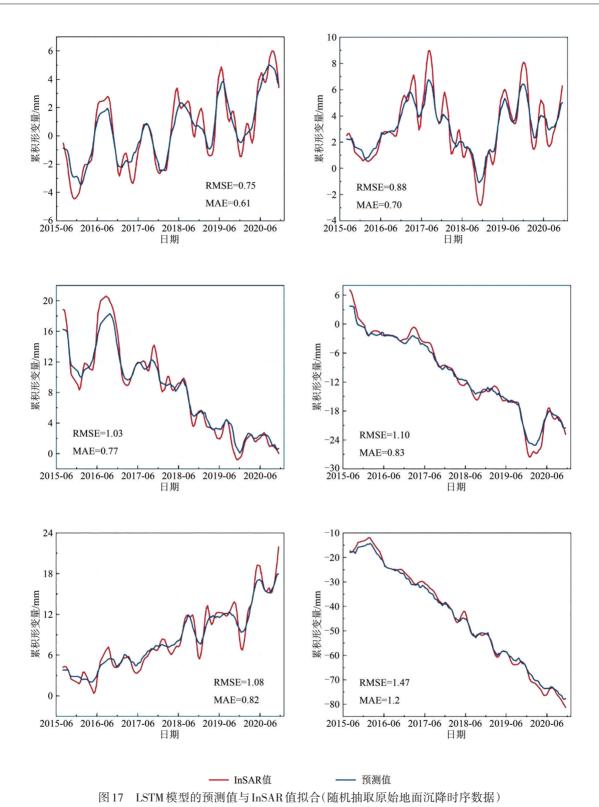
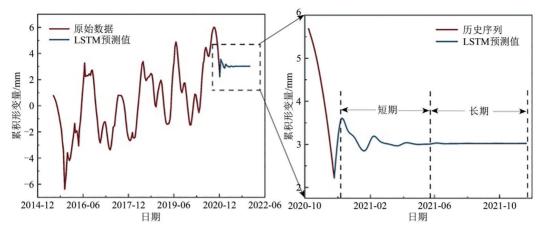


Fig. 17 Predicted values from LSTM model fitted to InSAR values (Randomly selected original ground subsidence time series data)

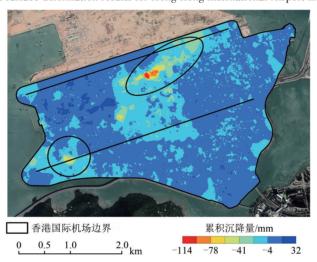
本文利用构建的堆叠式LSTM预测模型获取了香港国际机场未来6个月的短期地表形变预测结果,如图18(b)所示,未来6个月香港国际机场地表最大累积沉降量将达到114 mm,形变程度有所减轻,特别是航站楼附近,同时机场南北跑道

形变空间分布不均匀,北跑道东部和西部发生形变,最大累积沉降量将达55 m,南跑道西部和中部发生形变,累积沉降量将达77 mm。机场未来短期地表形变预测结果对于机场安全设施管理的及时修补具有重要意义。



(a) 香港国际机场未来一年地表形变预测结果

(a) Predicted surface deformation results for Hong Kong International Airport in the next year



(b) 香港国际机场6个月(2021-01-07-2021-06-07)地表形变预测插值结果

(b) Interpolation results of surface deformation prediction of Hong Kong International Airport in six months(2021-01-07—2021-06-07) 图 18 香港国际机场地表形变预测结果

Fig. 18 Predicted surface deformation results for Hong Kong International Airport

5 结 论

本文基于TS-InSAR技术,利用152幅C波段Sentinel-1A影像获取2015年—2020年香港国际机场地表时序形变监测结果,同时对InSAR地表时序形变结果进行预处理并构建堆叠式LSTM预测模型,最后采用循环预测模式得到香港国际机场地表未来6个月时序形变预测结果。结论如下:

(1) TS-InSAR 监测香港国际机场 2015年—2020年垂直方向的形变速率为-19—5 mm/a, 机场地表沉降逐渐增加, 2020年12月垂直方向的累积沉降量已达116 mm。南北跑道和航站楼附近区域累积沉降较为明显, 机场南北跑道形变空间分布不均匀。通过两种时序分析方法的交叉验证以及

监测结果与水准数据的对比,表明本文InSAR监测结果具有较高精度和可靠性。

(2) 基于时序 InSAR 监测结果建立堆叠式 LSTM 预测模型,并将 InSAR 观测结果与堆叠式 LSTM 预测结果进行对比分析,发现构建的堆叠式 LSTM 预测模型的 RMSE和 MAE 均较低,同时通过相关性分析发现相关系数均为 0.99,并且从拟合曲线上看出构建的堆叠式 LSTM 模型能较好地捕捉到时序数据的波动变化,表明堆叠式 LSTM 模型在点级尺度上具有良好的准确性,更适合于时序沉降数据的预测。依据 2015 年—2020 年的时序 InSAR形变数据,利用堆叠式 LSTM 模型预测了香港国际机场 2021 年的时序沉降,分析发现堆叠式 LSTM 预测模型长期预测过程中在 6个月以后出现

失效性。因此,堆叠式LSTM预测模型适合短期预测,短期预测尺度约为6个月,在2021年6月机场垂直方向最大累积沉降将达到114 mm。

LSTM模型是一种很有前景的预测时序 InSAR 地表形变的方法,因此,它能够用于早期预警系统。尽管 LSTM模型只适用于预测短期形变结果,但是其预测结果同样可以作为辅助决策、预防和缓解地面沉降。在未来将更多的数据纳入 LSTM模型中,同时考虑 PS-InSAR 和 SBAS-InSAR 两类方法在获取形变结果核心原理的差异性,精确判断该模型是否适用长期预测,从而提高预测模型的鲁棒性。

志 谢 此次实验的 Sentinel-1A 和 ALOS PALSAR 数据获取由欧洲空间局和阿拉斯加卫星设施提供,在此表示衷心的感谢!

参考文献(References)

- Aobpaet A, Cuenca M C, Hooper A and Trisirisatayawong I. 2013. In-SAR time-series analysis of land subsidence in Bangkok, Thailand. International Journal of Remote Sensing, 34 (8): 2969-2982 [DOI: 10.1080/01431161.2012.756596]
- Berardino P, Fornaro G, Lanari R and Sansosti E. 2002. A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms. IEEE Transactions on Geoscience and Remote Sensing, 40(11): 2375-2383 [DOI: 10.1109/TGRS.2002.803792]
- Cao Q, Chen B B, Gong H L, Zhou C F, Luo Y, Gao M L, Wang X, Shi M, Zhao X X and Zuo J J. 2019. Monitoring of land subsidence in Beijing-Tianjin-Hebei Urban by combination of SBAS and IPTA. Journal of Nanjing University (Natural Science), 55(3): 381-391 (曹群, 陈蓓蓓, 宫辉力, 周超凡, 罗勇, 高明亮, 王旭, 史珉, 赵笑笑, 左俊杰. 2019. 基于 SBAS 和 IPTA 技术的京津冀地区地面沉降监测. 南京大学学报(自然科学), 55(3): 381-391) [DOI: 10.13232/j.cnki.jnju.2019.03.005]
- Chen Y D, Zhang L F, He Y, Wang W H and Yang W. 2021. Ground deformation monitoring and analysis of Zhongchuan International Airport based on the time series InSAR of Sentinel-1A with ascending and descending orbits. Journal of Engineering Geology (陈有东, 张立峰, 何毅, 王文辉, 杨旺. 升降轨 Sentinel-1A 时序 InSAR 的中川国际机场地表形变监测与分析. 工程地质学报) [DOI: 10.13544/j.cnki.jeg.2020-609]
- Dehghan-Soraki Y, Sharifikia M and Sahebi M R. 2015. A comprehensive Interferometric process for monitoring land deformation using ASAR and PALSAR satellite Interferometric data. GIScience and Remote Sensing, 52(1): 58-77 [DOI: 10.1080/15481603.2014.

989774]

- Deng Z, Ke Y H, Gong H L, Li X J and Li Z H. 2017. Land subsidence prediction in Beijing based on PS-InSAR technique and improved grey-Markov model. Giscience and Remote Sensing, 54(6): 797-818. [DOI: 10.1080/15481603.2017.1331511]
- Ferretti A, Novali F, Bürgmann R, Hilley G and Prati C. 2004. InSAR permanent scatterer analysis reveals ups and downs in San Francisco Bay Area. Eos, Transactions American Geophysical Union, 85(34): 317-324 [DOI: 10.1029/2004EO340002]
- Ferretti A, Prati C and Rocca F. 2001. Permanent scatterers in SAR interferometry. IEEE Transactions on Geoscience and Remote Sensing, 39(1): 8-20 [DOI: 10.1109/36.898661]
- Galloway D L and Burbey T J. 2011. Review: regional land subsidence accompanying groundwater extraction. Hydrogeology Journal, 19 (8): 1459-1486 [DOI: 10.1007/s10040-011-0775-5]
- Graves A. 2012. Supervised Sequence Labelling with Recurrent Neural Networks. Berlin: Springer [DOI: 10.1007/978-3-642-24797-2]
- He Y, Chen Y D, Wang W H, Yan H W, Zhang L F and Liu T. 2021.

 TS-InSAR analysis for monitoring ground deformation in Lanzhou New District, the loess Plateau of China, from 2017 to 2019.

 Advances in Space Research, 67(4): 1267-1283 [DOI: 10.1016/j. asr.2020.11.004]
- He Y, Wang W H, Yan H W, Zhang L F, Chen Y D and Yang S W. 2020. Characteristics of surface deformation in Lanzhou with sentinel-1A TOPS. Geosciences, 10(3): 99 [DOI: 10.3390/geosciences10030099]
- He Y, Yang T B, Chen J and Ji Q. 2015. Remote sensing detection of glacier changes in Dong Tianshan Bogda region in 1972-2013. Scientia Geographica Sinica, 35(7): 925-932 (何毅, 杨太保, 陈杰, 冀琴. 1972~2013年东天山博格达峰地区冰川变化遥感监测. 地理科学, 35(7): 925-932) [DOI: 10.13249/j.cnki.sgs.2015. 07.9251
- Hochreiter S and Schmidhuber J. 1997. Long short-term memory. Neural Computation, 9(8): 1735-1780 [DOI: 10.1162/neco.1997.9.8.
- Lanari R, Casu F, Manzo M, Zeni G, Berardino P, Manunta M and Pepe A. 2007. An overview of the small BAseline subset algorithm: a DInSAR technique for surface deformation analysis. Pure and Applied Geophysics, 164(4): 637-661 [DOI: 10.1007/s00024-007-0192-9]
- Lin H, Ma P F and Wang W X. 2017. Urban Infrastructure Health Monitoring with Spaceborne Multi-temporal Synthetic Aperture Radar Interferometry. Acta Geodaetica et Cartographica Sinica, 46 (10): 1421-1433 (林珲, 马培峰, 王伟玺. 2017. 监测城市基础设施健康的星载 MT-InSAR 方法介绍. 测绘学报, 46(10): 1421-1433) [DOI: 10.11947/j.AGCS.2017.20170339]
- Liu G X, Chen Q, Luo X and Cai G L. 2012. Theory and Method of Permanent Scatterer Radar Interferometry. Beijing: Science Press (刘国祥, 陈强, 罗小军, 蔡国林. 2012. 永久散射体雷达干涉理

- 论与方法. 北京: 科学出版社)
- Liu X, Zhao N, Guo J Y and Guo B. 2020. Prediction of monthly precipitation over the Tibetan Plateau based on LSTM neural network. Journal of Geo-information Science, 2020, 22(8): 1617-1629 (刘新, 赵宁, 郭金运, 郭斌. 2020. 基于LSTM 神经网络的青藏高原月降水量预测. 地球信息科学学报, 22(8): 1617-1629) [DOI: 10.12082/dqxxkx.2020.190378]
- Ma P F, Wang W X, Zhang B W, Wang J L, Shi G Q, Huang G Q, Chen F L, Jiang L M and Lin H. 2019. Remotely sensing largeand small-scale ground subsidence: a case study of the Guangdong-Hong Kong-Macao Greater Bay Area of China. Remote Sensing of Environment, 232: 111282 [DOI: 10.1016/j.rse.2019. 111282]
- Qu F F, Lu Z, Zhang Q, Bawden G W, Kim J W, Zhao C Y and Qu W. 2015. Mapping ground deformation over Houston-Galveston, Texas using multi-temporal InSAR. Remote Sensing of Environment, 169: 290-306 [DOI: 10.1016/j.rse.2015.08.027]
- Schmidhuber J. 2015. Deep learning in neural networks: an overview.

 Neural Networks, 61: 85-117 [DOI: 10.1016/j. neunet. 2014.

 09.003]
- Wang H X and Li K Y. 2019. Lithium-ion battery life prediction based on modified extend Kalman Filter. Computer Measurement and Control, 27(8): 271-275 (王海霞, 李凯勇. 2019. 基于扩展卡尔

- 曼滤波的锂离子电池寿命预测方法. 计算机测量与控制, 27 (8): 271-275) [DOI: 10.16526/j.cnki.11-4762/tp.2019.08.057]
- Wang W H, He Y, Zhang L F, Chen Y D, Qiu L S and Pu H Y. 2020.

 Analysis of surface deformation and driving forces in Lanzhou.

 Open Geosciences, 12(1): 1127-1145 [DOI: 10.1515/geo-2020-0128]
- Wei F Y. 2007. Modern Climate Statistical Diagnosis and Prediction Technology. 2nd ed. Beijing: China Meteorological Press: 175-181 (魏风英. 现代气候统计诊断与预测技术. 2版. 北京: 气象出版社: 175-181)
- Wu S B, Yang Z F, Ding X L, Zhang B C, Zhang L and Lu Z. 2020.
 Two decades of settlement of Hong Kong International Airport measured with multi-temporal InSAR. Remote Sensing of Environment, 248: 111976 [DOI: 10.1016/j.rse.2020.111976]
- Ye S J, Luo Y, Wu J C, Yan X X, Wang H M, Jiao X and Teatini P. 2016. Three-dimensional numerical modeling of land subsidence in Shanghai, China. Hydrogeology Journal, 24(3): 695-709 [DOI: 10.1007/s10040-016-1382-2]
- Zhao Q, Lin H, Wei G, Zebker H, Chen A and Yeung K. 2011. InSAR detection of residual settlement of an ocean reclamation engineering project: a case study of Hong Kong International Airport. Journal of Oceanography, 67(4): 415-426 [DOI: 10.1007/s10872-011-0034-3]

Surface deformation prediction based on TS-InSAR technology and long short-term memory networks

CHEN Yi, HE Yi, ZHANG Lifeng, CHEN Baoshan, HE Xu, PU Hongyu, CAO Shengpeng, GAO Liya, YANG Wang

- 1. Faculty of Geomatics, Lanzhou Jiaotong University, Lanzhou 730070, China;
- 2. National-Local Joint Engineering Research Center of Technologies and Applications for National Geographic State Monitoring, Lanzhou 730070, China;
 - 3. Gansu Provincial Engineering Laboratory for National Geographic State Monitoring, Lanzhou 730070, China

Abstract: Urban land subsidence is a geological disaster formed by natural and human factors. Cumulative land subsidence easily causes damage to buildings, infrastructure, underground engineering, and other hazards, which seriously threaten the safety of people's lives and property and cause national economic losses. In the face of urban land subsidence, monitoring, analyzing, and predicting spatiotemporal changes in land subsidence are necessary. The prediction of land subsidence is a crucial step for the early warning of urban infrastructure damage and establishment of a timely remedy.

In this study, the Time Series Interferometric Synthetic Aperture Radar (TS-InSAR) technique was utilized to monitor the time series land subsidence at Hong Kong International Airport from 2015 to 2020 by using 152 Sentinel-1A images with an ascending orbit. The local weighted scatter smoothing (Loess) method was used to reduce and smooth the noise in the original data of surface deformation points. Given that the advantages of LSTM correspond to the results of TS-InSAR, on the basis of TS-InSAR data, a stacked LSTM neural network was used to construct a surface deformation prediction model with two LSTM layers, two dense layers, and three dropout layers. The stacked LSTM model was employed to predict the surface deformation of the airport, and its results were compared the predicted results obtained with the true InSAR findings.

The average vertical deformation rate of Hong Kong International Airport's surface for 2015—2020 was -19—5 mm/year. The surface subsidence of the airport gradually increased, and the cumulative subsidence in the vertical direction reached 116 mm in December 2020. The cross-validation of the two time-series analysis methods and the comparison of the monitoring results with the level data showed that

the InSAR monitoring results in this study had high accuracy and reliability. A stacked LSTM prediction model was established based on the time-series InSAR monitoring results, and the InSAR observation results were compared with the stacked LSTM prediction results. The root-mean-square error and mean absolute error of the predicted and true values were low, namely, 0.75 and 0.61 mm, respectively, and the correlation coefficient was 0.99. The LSTM prediction model demonstrated good performance at the point level scale and could predict ground subsidence accurately on the basis of TS-InSAR data. The stacked LSTM model was employed to predict the time-series subsidence of Hong Kong International Airport in 2021 by using TS-InSAR deformation data from 2015—2020. The analysis revealed that the long-term prediction process of the stacked LSTM prediction model became invalid after six months. Therefore, the stacked LSTM prediction model is suitable for short-term predictions with a short-term prediction scale of about six months, and the maximum cumulative vertical subsidence of the airport will reach 114 mm in June 2021.

In summary, the stacked LSTM prediction model proposed in this study can be used as an effective method to predict surface deformation, and although the LSTM model is only suitable for short-term predictions, its prediction results can be used to assist in decision-making, early warning, and hazard mitigation. In the future, additional data can be incorporated into the LSTM model to accurately determine if the model is suitable for long-term predictions and improve the robustness of the prediction model.

Key words: remote sensing, land deformation, TS-InSAR, surface deformation prediction, deep Learning, LSTM

Supported by China Postdoctoral Science Foundation (No. 2019M660092XB); Gansu Province Science and Technology Program Funding (No. 20JR2RA002); Natural Science Foundation of Gansu Province (No. 20JR10RA249); Youth Science Foundation of Gansu Province (No. 20JR10RA272); Lanzhou Jiaotong University-Tianjin University Innovation Project Fund Project (No. 2020055); LZJTU EP (No. 201806)