

引文格式:何毅,姚圣,陈毅,等.ConvLSTM神经网络的时序InSAR地面沉降时空预测[J].武汉大学学报(信息科学版),2025,50(3):483-496.DOI:10.13203/j.whugis20220657



Citation: HE Yi, YAO Sheng, CHEN Yi, et al. Spatiotemporal Prediction of Time-Series InSAR Land Subsidence Based on ConvLSTM Neural Network[J]. Geomatics and Information Science of Wuhan University, 2025, 50(3):483-496. DOI:10.13203/j.whugis20220657

ConvLSTM神经网络的时序InSAR地面沉降 时空预测

何毅^{1,2,3} 姚圣^{1,2,3} 陈毅^{1,2,3} 闫浩文^{1,2,3} 张立峰^{1,2,3}

1 兰州交通大学测绘与地理信息学院,甘肃 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,甘肃 兰州,730070

3 甘肃省地理国情监测工程实验室,甘肃 兰州,730070

摘要: 现有地面沉降时空预测方法存在时序特征捕捉能力差,未顾及空间邻域特征等问题,导致地面沉降时空预测的可靠性差。采用合成孔径雷达干涉测量技术(interferometric synthetic aperture radar, InSAR),提出了一种能够捕捉时序特征和空间邻域特征的卷积长短时记忆(convolutional long short-term memory, ConvLSTM)神经网络地面沉降时空预测方法。选取北京首都国际机场作为研究区,首先基于差分干涉测量短基线集InSAR(small baseline subset InSAR, SBAS-InSAR),利用Sentinel-1A影像获取地面沉降时空InSAR数据,然后构建ConvLSTM的地面沉降时空预测模型,模拟预测该区域未来一年的地面沉降。利用永久散射体干涉测量技术、SBAS-InSAR结果和水准点数据,交叉验证了时序InSAR结果的可靠性;时序InSAR地面沉降数据采用滑动窗口进行数据分割,形成多对一数据集模式;结合小波变换和评价指标确定时空预测模型的最佳时间步长,建立时序InSAR地面沉降的ConvLSTM时空预测模型。实验结果显示,所提模型的预测结果和真实结果的拟合度 R^2 达到0.997,基于图像评价指标结构相似性(structural similarity, SSIM)和多尺度结构相似性(multi-scale structural similarity, MS-SSIM)进一步评价了模型的性能,SSIM和MS-SSIM分别达到了0.914、0.975。此外,与支持向量回归、多层感知器、卷积神经网络和长短时记忆神经网络模型进行了对比分析,各项指标均显示所提模型最优。所提模型预测到2022年11月北京首都国际机场最大累积沉降量达到157 mm,研究成果可为城市地面沉降早期预防提供关键技术支撑。

关键词: 地面沉降;时序InSAR;时空预测;卷积长短时记忆神经网络

中图分类号:P237

文献标识码:A

收稿日期:2024-01-04

DOI:10.13203/j.whugis20220657

文章编号:1671-8860(2025)03-0483-14

Spatiotemporal Prediction of Time-Series InSAR Land Subsidence Based on ConvLSTM Neural Network

HE Yi^{1,2,3} YAO Sheng^{1,2,3} CHEN Yi^{1,2,3} YAN Haowen^{1,2,3} ZHANG Lifeng^{1,2,3}

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: Objective: The existing spatiotemporal prediction methods of land subsidence have some problems, such as poor ability to capture time-series features and ignoring spatial neighborhood features, which lead to poor reliability of spatiotemporal prediction of land subsidence. **Method:** This paper proposes a spatiotemporal prediction of land subsidence based on convolutional long short-term memory (ConvLSTM)

基金项目: 国家自然科学基金(42471471);甘肃省联合科研基金(24JRRA855);兰州市青年科技人才创新项目(2024-QN-12);城市国土资源监测与模拟重点实验室开放基金(KF-2021-06-014);甘肃省自然科学基金(20JR10RA249);兰州交通大学天佑青年托举人才计划(1520260109);兰州交通大学优秀平台(201806)。

第一作者: 何毅,教授,主要从事生态遥感和地质灾害等方面研究。heyi@mail.lzjtu.cn

通信作者: 陈毅,硕士。cy_rser@163.com

neural network, which can capture time-series features and spatial neighborhood features. First, based on small baseline subset interferometric synthetic aperture radar (SBAS-InSAR), Sentinel-1A images were used to obtain the spatiotemporal InSAR data of land subsidence at Beijing Capital International Airport (BCIA). Then, a ConvLSTM model is constructed to predict the land subsidence in the next year. Permanent scatters InSAR, SBAS-InSAR and benchmark results are used to cross-verify the reliability of time-series InSAR results. Time-series InSAR land subsidence data are segmented by sliding windows to form a many-to-one dataset model. Combined with wavelet transform and evaluation indexes to determine the optimal time step of the prediction model, the ConvLSTM spatiotemporal prediction model of time-series InSAR land subsidence is established. **Results:** The R^2 of the predicted and real results reaches 0.997. Meanwhile, the performance of the proposed model is further evaluated based on the image evaluation index structural similarity (SSIM) and multi-scale structural similarity (MS-SSIM), which reach 0.914 and 0.975, respectively. In addition, support vector regression, multilayer perceptron, convolutional neural network and the long-term memory neural network model are compared and analyzed, and each index reveals that the proposed model is optimal. **Conclusion:** The ConvLSTM spatiotemporal prediction model predicts that the maximum cumulative subsidence at BCIA will reach 157 mm by November 2022. This study can provide key technical support for the early prevention of urban land subsidence.

Key words: land subsidence; time-series InSAR; spatiotemporal prediction; convolutional long short-term memory (ConvLSTM) neural network

21世纪以来,全球范围内已有约150个城市发生地面沉降,其中中国有50多个城市经历了不同程度的地面沉降,累积沉降量超过200 mm的城市区面积超过 $7.9 \times 10^4 \text{ km}^2$,严重影响城市基础设施的结构健康^[1]。地面沉降实时监测和时空预测能够提前发现异常地面现象,防止地面沉降灾害发生。可见,实时监测和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预防措施具有重要意义。

合成孔径雷达干涉测量技术(interferometric synthetic aperture radar, InSAR)作为一种新兴的对地观测技术,能实现大范围、高精度、高密度、低成本和快速的区域地面沉降监测,被广泛应用^[2-8]。多时相 InSAR (multi-temporal InSAR, MT-InSAR)技术可利用同一地区多幅图像进行地面沉降监测^[9],显著提高地面沉降监测精度。短基线集 InSAR (small baseline subset InSAR, SBAS-InSAR)^[10]是典型的 MT-InSAR 技术,利用多主影像将长基线变成短基线,形成干涉图,并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^[11],在地面沉降监测方面已取得显著成效。SBAS-InSAR 能够获取高精度、大范围以及时间序列的地面沉降时空数据,可为地面沉降早期识别和时空预测模型构建提供理论和基础数据支撑。

随着深度学习技术的进步,基于时序 InSAR 数据利用深度学习方法进行时序预测已成为研

究热点,长短时记忆(long short-term memory, LSTM)^[12]网络和卷积神经网络(convolutional neural network, CNN)模型应用最为突出^[13]。LSTM是一类专门处理序列数据的神经网络,能够捕捉时序数据的变化特征,在时序 InSAR 数据预测中已取得显著成果^[14-16],但 LSTM 网络结构仅仅关注时序 InSAR 数据的时间特征,对于时序 InSAR 图像数据忽略了空间邻域信息,无法提取时序 InSAR 图像数据中的空间邻域特征,进而影响时序 InSAR 图像预测的精度^[17]。CNN是一类主动学习图像特征的神经网络,能够关注到时序图像的空间邻域特征,同时 CNN 网络提出了权值共享概念,减少了训练参数的数量,因此, CNN 在时序 InSAR 数据预测中也被广泛应用^[18-19],但 CNN 作为前馈神经网络结构,默认以最后一个全连接层作为输出,难以适应同时考虑不同时间深度特征^[20],影响时序数据预测精度。卷积长短时记忆网络(convolutional LSTM, ConvLSTM)^[21]作为 LSTM 核心思想的拓展,与 LSTM 网络结构类似,但不同的是 ConvLSTM 将 LSTM 中的全连接状态转换成了卷积状态,图像预测处理时无需进行数据一维化操作,使得 ConvLSTM 拥有了 LSTM 处理时序数据的能力和 CNN 善于学习空间邻域特征的能力。

本文选取北京首都国际机场为研究区,首先利用 SBAS-InSAR 技术获取时序 InSAR 地面沉降时空数据,然后构建 ConvLSTM 时空预测模

型,有效学习地面沉降时序特征和空间邻域特征,最后利用构建的 ConvLSTM 时空模型预测北京首都国际机场未来一年地面沉降。本文研究可为地面沉降早期预警提供关键技术支持,同时也为实现城市可持续发展提供理论基础。

1 研究方法

1.1 SBAS-InSAR 技术

SBAS-InSAR 核心原理^[10]是将所有 SAR 影

像根据合理的空间基线和时间基线阈值生成干涉对,组合成小基线集,使得各子基线集内影像基线的间距小,在每个子基线集内利用最小二乘法计算时间序列的地表形变;利用奇异值分解法解算各子基线集之间可能存在的病态方程参数^[22];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,获得线性形变速率及高程误差等信息,再将残余误差通过时空滤波去除大气延迟,并进行分解得到非线性形变信息。SBAS-InSAR 技术处理流程如图 1 所示。

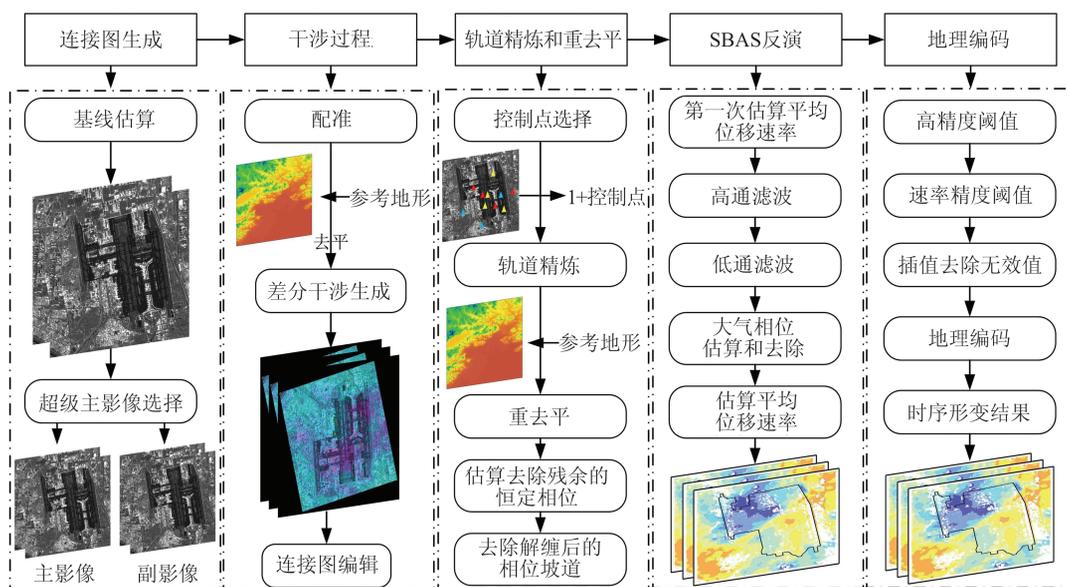


图 1 SBAS-InSAR 技术的处理流程

Fig. 1 Processing Flow of SBAS-InSAR Technology

1.2 地面沉降时空预测模型

1.2.1 ConvLSTM 模型

ConvLSTM 模型主要用于解决降水临近预报问题^[21],该预报可看作时空预测问题。ConvLSTM 将 LSTM 中输入层到隐藏层和隐藏层到隐藏层中的全连接换成卷积,使得 Conv-LSTM 在不同状态下都具有卷积结构,不仅具有 LSTM 处理时序问题的能力,还具有 CNN 善于学习局部空间特征的能力。ConvLSTM 模型的计算式为:

$$f_i = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_i = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_i = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_i = f_i \circ C_{t-1} + i_i \circ \tilde{C}_i \quad (4)$$

$$o_i = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_i \circ \tanh C_i \quad (6)$$

式中, t 代表时刻; f_i 、 i_i 和 o_i 分别代表遗忘门、输入门和输出门; C_t 和 h_t 分别代表记忆细胞状态和隐

藏状态; W_f 、 W_i 、 W_c 、 W_o 分别为不同结构的权重矩阵; b_f 、 b_i 、 b_c 、 b_o 分别为不同结构的偏置项; $[h_{t-1}, x_t]$ 表示将上一时间步单元的输出与当前单元的输入进行合并; σ 为 Sigmoid 激活函数; $*$ 为卷积运算; \circ 为哈达玛积运算; \tanh 为双曲正切函数。

ConvLSTM 结构如图 2 所示。由图 2 可以看出,在 ConvLSTM 内部结构中,输入层到隐藏层和隐藏层到隐藏层都进行了卷积操作。

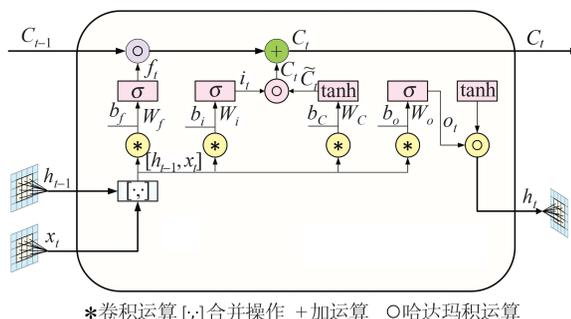


图 2 ConvLSTM 结构示意图

Fig. 2 ConvLSTM Structure Diagram

1.2.2 地面沉降时空预测模型构建

基于SBAS-InSAR时序地面沉降时空图像数据,利用ConvLSTM网络构建地面沉降时空预测模型,如图3所示。由图3可以看出,模型结构包括基于图像的CNN特征提取的编码过程、ConvLSTM时序预测过程和CNN特征图恢复解码过程。编码器采用6个时间分布(time distributed, TD)的二维卷积层(TD-Conv2D)、2个最

大池化层(Max Pool)、1个平均池化层(Average Pool),其中在第一次下采样中同时应用了最大池化和平均池化,并将其结果进行合并,减少了特征细节损失;预测器采用3个ConvLSTM层;解码器采用9个TD-Conv2D层、3个上采样层,其中在第二次上采样中同时应用了最近邻和双线性两种内插方式采样,并将输出结果合并,形成特征图。

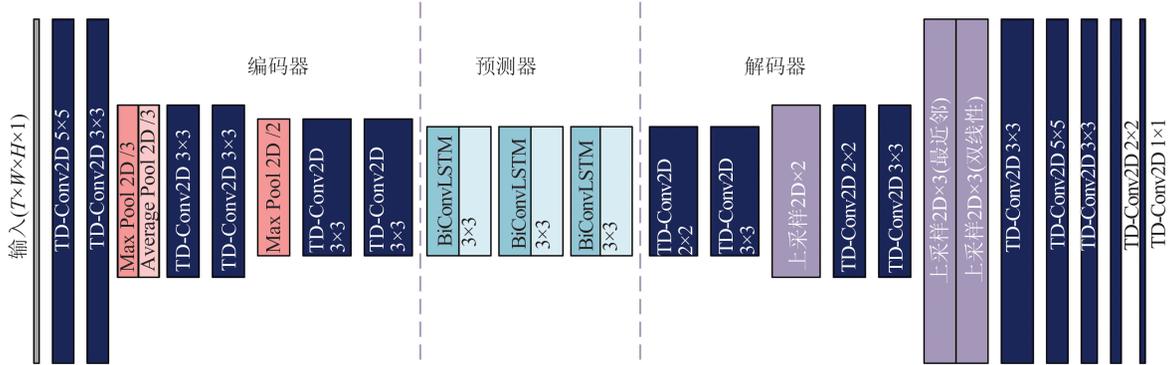


图3 地面沉降预测模型

Fig. 3 Ground Subsidence Prediction Model

具体训练过程为:

1) 时序 InSAR 图像数据预处理。基于 SBAS-InSAR 技术获取实验区时空 InSAR 形变数据的部分地区存在失相干,导致时序 InSAR 形变图像结果存在局部数据缺失。而构建的地面沉降 ConvLSTM 时空预测模型用于学习像素完整的时序 InSAR 图像时空特征,不接受空置输入,因此,需要对获取的时序 InSAR 图像数据进行插值处理。反距离加权(inverse distance weighted, IDW)插值方法是一种常用而简便的空间插值方法,它以插值点与样本点间的距离为权重进行加权平均,通过对邻近区域的每个采样点值平均运算获得内插单元。本文利用 IDW 插值方法对时序 InSAR 时空数据进行插值处理,得到空间像素完整的时序 InSAR 图像数据。

2) 时序 InSAR 图像数据归一化。时序 InSAR 地面沉降图像数据范围整体差异较大,深度学习模型训练过程中会引起梯度爆炸问题。因此,需要对时序 InSAR 数据进行归一化处理,消除数据之间量纲的影响,防止数据差异较大影响预测精度。采用传统的数据归一化方法对数据进行约束,使得归一化后栅格数值接近 0,容易导致梯度消失,进而影响预测精度。本文利用整个时序 InSAR 形变数据的最大值与最小值拟合四次多项式,进行数据尺度压缩,解决时序数据压缩问题,提高预测精度。计算式为:

$$f(x) = Ax^4 + Bx^3 + Cx^2 + Dx + E \quad (7)$$

式中, $A \sim E$ 为参数值。

利用 LM(Levenberg-Marquardt)算法^[23]求解上述多项式模板中 $A \sim E$ 5 个参数的最优解,时序极值点曲线拟合如图 4 所示。

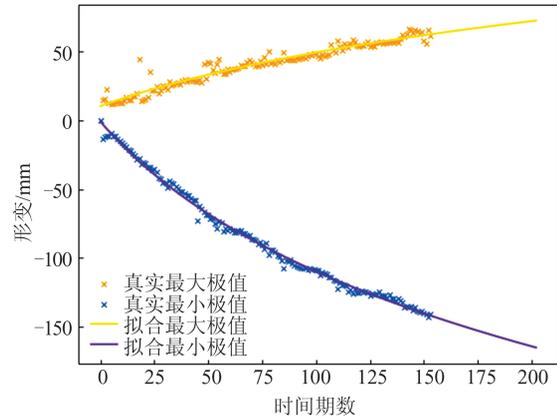


图4 时序极值点曲线拟合结果

Fig. 4 Curve Fitting Results for the Time-Series Extreme Value Points

使用拟合后的多项式函数,逐时序图像、逐像素地对 SBAS-InSAR 时序形变图的像素值进行压缩,计算式为:

$$O_{i,j} = \begin{cases} \frac{M_{i,j}}{f_{\max}(t)}, & M_{i,j} > 0 \\ \frac{M_{i,j}}{|f_{\min}(t)|}, & M_{i,j} \leq 0 \end{cases} \quad (8)$$

式中, $M_{i,j}$ 为图像第 i 行、 j 列的像素值; $O_{i,j}$ 为图像压缩后的输出值; $f_{\max}(t)$ 、 $f_{\min}(t)$ 为多项式拟合后的极大值拟合函数和极小值拟合函数, 像素值压

缩后范围为 $[-1, 1]$ 。数据压缩前后分布范围如图 5 所示, 分段压缩至 $[-1, 1]$ 之间, 保证分段节点一致, 不改变数据分布特征。

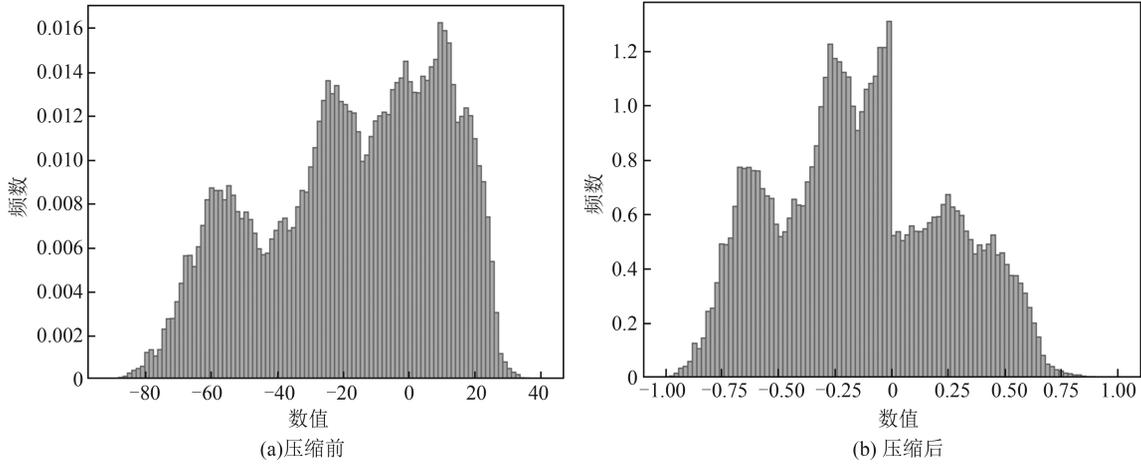


图 5 数据压缩前后对比

Fig. 5 Comparison Before and After Data Compression

3) 数据集划分。基于归一化后的时序 InSAR 图像数据, 本文采用滑动窗口进行数据分割, 利用多对一的预测方式进行预测, 即输入一定时间步长的图像, 预测下个时间步的图像(标签)。整体数据集中首先将最后 15 期数据对抽出作为测试集, 然后从其余的数据中随机抽取, 分为 80% 的训练集与 20% 的验证集。

4) 时空预测数据反归一化。通过所提模型预测的像素值范围为 $[-1, 1]$, 为了将预测图像还原为原本尺度, 采用反多项式函数进行换算, 图像中像素正值乘拟合极大值, 负值乘拟合极小值, 计算式为:

$$O_{i,j} = \begin{cases} \frac{M_{i,j}}{\max(M)} f_{\max}(t), M_{i,j} > 0 \\ \frac{M_{i,j}}{|\min(M)|} |f_{\min}(t)|, M_{i,j} \leq 0 \end{cases} \quad (9)$$

通过多次试验, 综合考虑模型计算效率、结果精度以及硬件条件 3 个方面, 实验最终将迭代次数设置为 128, 批量大小设置为 1, 选用自适应矩估计作为优化器, 并将初始学习率设置为 1×10^{-4} , 评价指标为结构相似性(structural similarity, SSIM)。经过训练集的 128 次完整迭代, 网络近似收敛, 在训练集和测试集的训练过程曲线中, 一般表现为输入的时间步长越长, SSIM 值越高。本文挑选了两个有代表性的时间步长的训练曲线, 用来展示模型的训练性能, 如图 6 所示。

1.3 评价指标

为了定量评估 InSAR 地面沉降时空预测模

型的性能, 本文进行准确性评估的评价指标包括: 均方误差(mean square error, MSE)、平均绝对误差(mean absolute error, MAE)、SSIM、多尺度结构相似性(multi-scale structural similarity, MS-SSIM)和峰值信噪比(peak signal to noise ratio, PSNR)。

MSE 和 MAE 的计算式分别为:

$$E_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_t - \tilde{y}_t)^2 \quad (10)$$

$$E_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |y_t - \tilde{y}_t| \quad (11)$$

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

SSIM 是一种全新的图像质量评价模型^[24]。它是基于一个假设: 人类视觉能提取图像结构性信息, 即亮度、对比度和结构, 自然图像的像素并不是独立存在, 而是与邻域像素形成图像结构信息, 该方法从亮度、对比度和结构 3 个方面评价图像的失真。SSIM 取值范围一般是 $[0, 1]$, 其值越接近 1, 表示图像质量越高, 计算式为:

$$\text{SSIM}(x, y) = \frac{[2\mu_x \mu_y + (k_1 L)^2][2\sigma_{xy} + (k_2 L)^2]}{[\mu_x^2 + \mu_y^2 + (k_1 L)^2][\sigma_x^2 + \sigma_y^2 + (k_2 L)^2]} \quad (12)$$

式中, μ_x 、 μ_y 分别为两幅图像的均值; σ_x 、 σ_y 分别为两幅图像的标准差; σ_{xy} 为两幅图像的协方差; L 是像素值的动态范围; k_1 、 k_2 是两个标量常数, 默认为 $k_1=0.01$, $k_2=0.03$ 。

MS-SSIM 的计算式为:

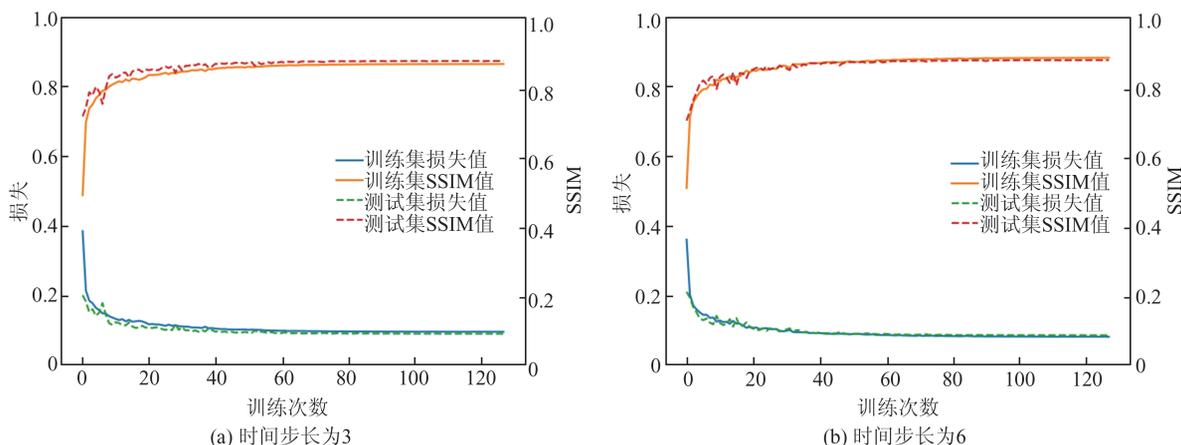


图6 训练过程指标值变化

Fig. 6 Changes of Index Values During Training Process

$$\text{MS-SSIM}(x, y) =$$

$$\left[l_M(x, y) \right]^{\alpha_M} \prod_{j=1}^M \left[c_j(x, y) \right]^{\beta_j} \left[s_j(x, y) \right]^{\gamma_j} \quad (13)$$

式中, M 为最高尺度(原始图像尺度为 1, 低通滤波下采样 2 倍后尺度增加 1), MS-SSIM 只在最高尺度下计算亮度进行比较, 在不同尺度的重要性参数 α_M 、 β_j 和 γ_j 采用默认值 ($\beta_1 = \gamma_1 = 0.044\ 8$, $\beta_2 = \gamma_2 = 0.285\ 6$, $\beta_3 = \gamma_3 = 0.300\ 1$, $\beta_4 = \gamma_4 = 0.236\ 3$, $\alpha_5 = \beta_5 = \gamma_5 = 0.133\ 3$)。

PSNR 是一种广泛使用的图像评价指标。PSNR 考虑了平均差异和图像灰度变化的关联, 其值大小体现图像的失真程度, PSNR 值越高, 表示图像失真小、质量好^[25]。本实验图像为 32 bit, 故 n 取 32, PSNR 计算式为:

$$\text{PSNR} = 10 \times \lg \left[\frac{(2^n - 1)^2}{E_{\text{MSE}}} \right] \quad (14)$$

2 研究区与数据源

北京首都国际机场位于永定河冲积-洪积扇末端温榆河与潮白河之间的平坦地区, 高程约为 22.0~35.4 m; 气候为暖温带半湿润半干旱季风型; 年均降雨量在 1959—2010 年间为 624 mm/a, 2000—2010 年间减少到 517 mm/a^[26], 降水季节分配很不均匀, 6 月—8 月降水集中, 约占全年 80%; 年平均气温 10~12 °C^[27]。研究区域如图 7 所示, 其中有 T1 航站楼(1980 年投入使用)、T2 航站楼(1999 年投入使用)与 T3 航站楼(2008 年完工, 分为 T3C、T3D 和 T3E 共 3 栋), 3 条跑道编号分别为 36L、36R 和 01, 长度分别为 3 200 m、3 800 m 和 3 800 m。截至 2018 年, 北京首都国际机场年旅客吞吐量由 103 万人次增长到 1 亿 100

万人次, 位居亚洲第一、全球第二。



图7 研究区域

Fig. 7 The Study Area

本文选取欧洲空间局 2016—2021 年 C 波段的 Sentinel-1A 干涉宽幅模式影像和精密轨道数据, 详细信息如表 1 所示。

3 结果与分析

3.1 地面沉降 SBAS-InSAR 监测结果的精度验证

3.1.1 内部检验

SBAS-InSAR 是根据均值相干系数选取稳定的点, 为检验监测结果的可靠性, 本文对获取研究时段内的时序相干性图进行对比分析(图 8)。相干性系数越接近 1, 所得干涉相位测量值越可靠。相干性系数的计算式为:

表 1 SAR 数据详细信息

Table 1 SAR Data Details

项目	信息
传感器	Sentinel-1A
波段	C
波长/cm	5.6
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/张	151
日期范围	2016年1月至2021年11月
垂直基线范围/m	1.853~141.698

$$r = \frac{\left| \sum_{i=1}^P \sum_{j=1}^Q \mu_1(i,j) \otimes \mu_2(i,j) \right|}{\sqrt{\sum_{i=1}^P \sum_{j=1}^Q |\mu_1(i,j)|^2 \sum_{i=1}^P \sum_{j=1}^Q |\mu_2(i,j)|^2}} \quad (16)$$

式中, P 和 Q 代表用于计算相干性的数据块大小; i 和 j 分别表示数据块的行号和列号; μ_1 和 μ_2 是主影像对数据块, 在图中坐标 (i, j) 处的复数值; \otimes 表示共轭相乘。

从图 8 可以看出, 不同时段内的相干性图以及相干性系数有所差异, 但整个时段内的相干性系数大部分均在 0.5 以上, 理论上认为相干性系数大于 0.5 能保证干涉高质量完成, 相位展开正确, 能获得可靠形变信息^[27-28], 因此, 从理论精度上说明本文 SBAS-InSAR 形变监测数据结果可靠。

3.1.2 交叉验证和水准点验证

本文利用永久散射体 (persistent scatterer, PS) InSAR (PS-InSAR) 和 SBAS-InSAR 的监测结果进行交叉验证, 得到 2016—2021 年北京首都国际机场的地面沉降监测结果 (图 9)。首先利用 PS 点提取相对应同一位置的 SBAS-InSAR 的结果, 然后去除结果中的空值和异常点, 最后将两者做相关性分析, 如图 10 所示。PS-InSAR 和 SBAS-InSAR 的相关系数为 0.910, 表明两种时序分析方法的结果高度相关, 也说明本文对 2016—2021 年北京首都国际机场的地面沉降监测结果的精度可靠。但是两种结果在空间分布上存在一定的差异, 这主要是由于两种实现方法原理不同, 特别是连接图的组合和散射体的选择过程不同, 可能导致了垂直形变速率值的偏差。

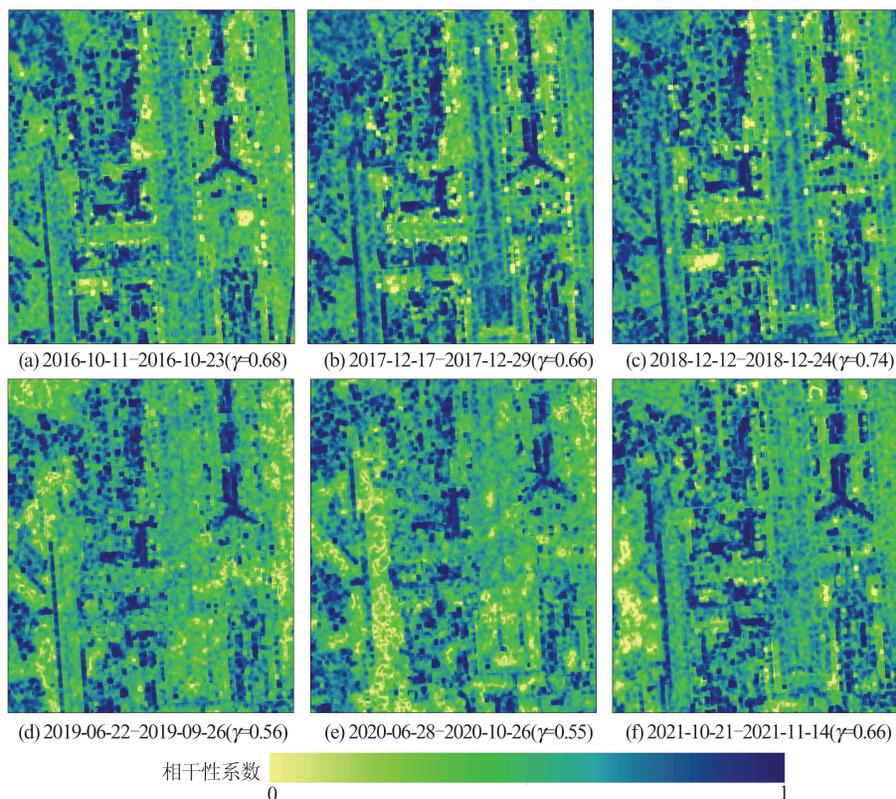


图 8 SBAS-InSAR 不同时段内的相干性图及相干性系数

Fig. 8 Coherence Graphs and Coherence Coefficients of SBAS-InSAR in Different Time Periods

与现有的基准点数据对比验证, 由于本文数据时间段较新, 新年份水准点数据难以获取, 通过查阅选取 2016 年 9 月和 2017 年 9 月的基准数据^[29]

对本文的 InSAR 测量变形结果进行验证 (图 11)。文献 [29] 中水准数据记录该点的相对累积垂直沉降值, 因此, 计算 2016 年 10 月至 2017 年 10 月相对

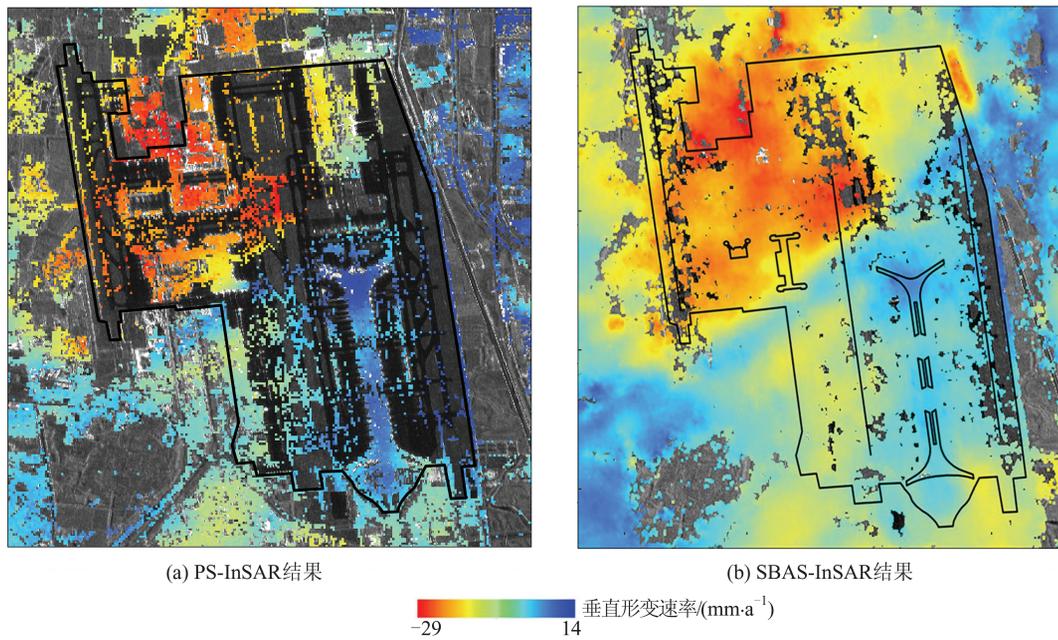


图9 机场的垂直形变速率

Fig. 9 Vertical Deformation Velocity Rate of Airport

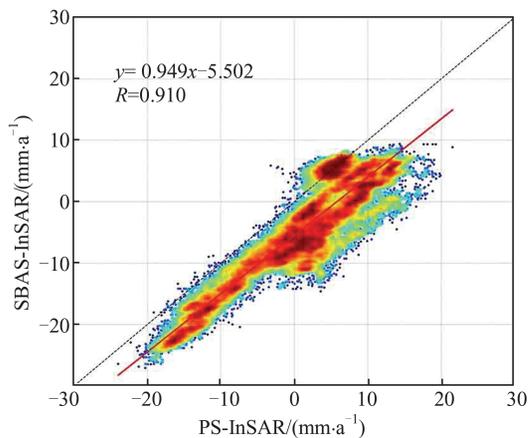


图10 PS-InSAR和SBAS-InSAR结果的相关性散点图

Fig. 10 Correlation Scatter Plot of PS-InSAR and SBAS-InSAR Results

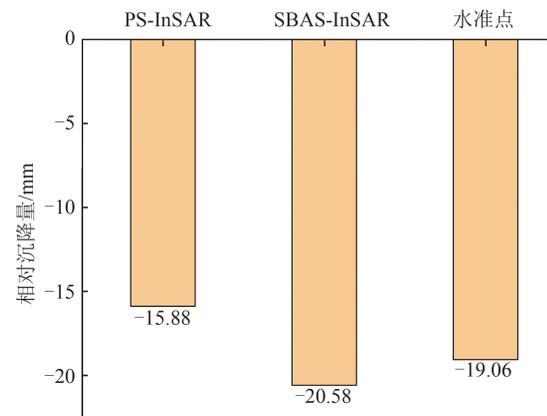


图11 PS-InSAR、SBAS-InSAR结果与水准点对比

Fig. 11 Comparison of PS-InSAR and SBAS-InSAR Results with Benchmark Point Result

沉降值进行对比分析。在距离水准点位置100 m半径的圆形缓冲区中提取2017年10月和2016年10月的PS-InSAR和SBAS-InSAR垂直沉降矢量监测点,计算其相对沉降值,并将InSAR变形结果与水准值进行比较。如图11所示,基准点处的InSAR结果与基准点结果呈现出一致的趋势。与水准点比较的误差范围为 ± 5 mm,尤其SBAS-InSAR结果误差为1.52 mm,均符合地面运动测量的要求。由此可见,SBAS-InSAR监测结果与基准结果具有较高的一致性,证明本文设置的实验参数合理,InSAR变形结果可靠。

3.2 机场地面沉降时空特征

本文基于151景Sentinel-1A数据,利用SBAS-

InSAR技术得到了2016—2021年北京首都国际机场151期时序累积地面形变空间分布结果,并每隔一年绘制北京首都国际机场年际形变空间分布图,如图12所示。由图12可知,机场地面沉降在空间上分布不均匀,累积沉降变化由东南向西北递增,机场东南方向和西北方向的差异越来越显著,最大累积沉降量为142 mm。从空间分布图还可以发现,机场沉降空间格局中存在一个线性边界,线性边界两侧沉降有明显差异。文献资料显示该线性边界在空间上与顺义-良乡断层对应,表明二者之间存在潜在联系^[27,30]。断层线西北方向沉降比东南方向严重,其中西北方向的货运区沉降较为严重,沉降速率约为9~24 mm/a。T1和T2航站楼存在轻微地面沉降,沉降速率范围

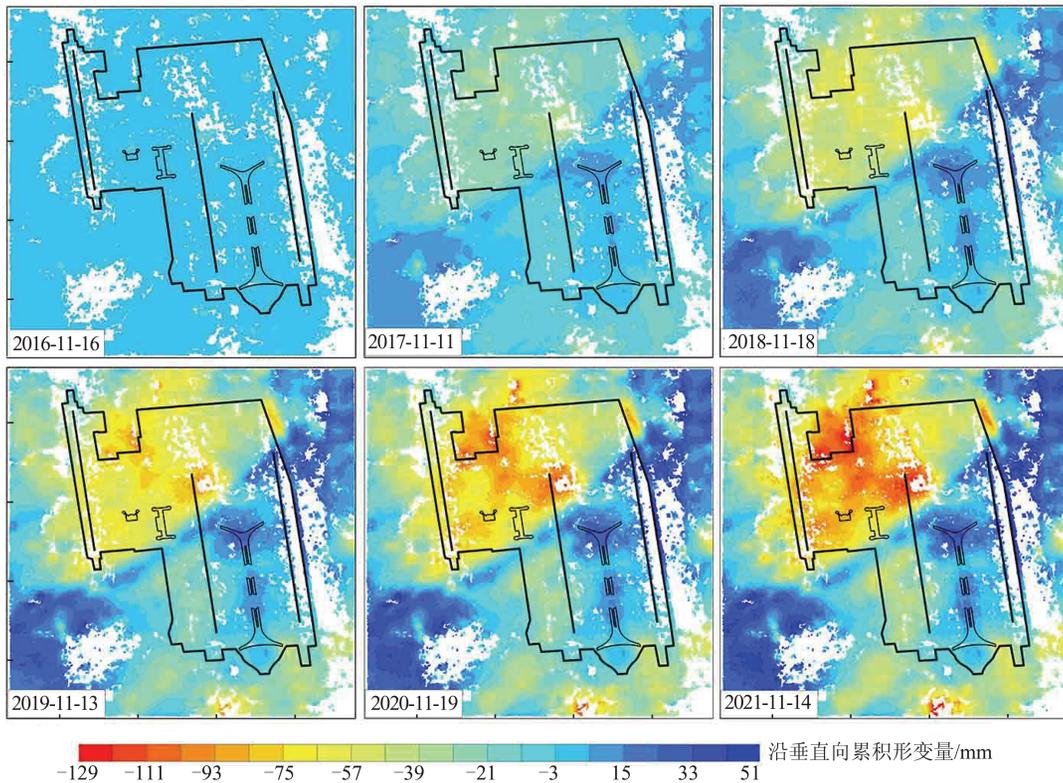


图 12 北京首都国际机场年际沉降变化图

Fig. 12 Interannual Subsidence Variation of Beijing Capital International Airport

为 4~14 mm/a,同时跑道 36L 南北向的地面沉降空间分布不均匀,其中南部沉降较为明显,大约为 9~20 mm/a。值得注意的是,跑道 36R 北部有显著的沉降漏斗,沉降速率约为 9~26 mm/a,该区域地面沉降可能是货运区发生严重地面沉降所导致。

由图 12 可以看出,北京首都国际机场地面随着时间推移,沉降量不断增加,同时空间上不断扩展。此外,SBAS-InSAR 时序图像空间失相干的区域很少,空值像素较少,得到时序图像达到 151 景,数据量丰富,而且变化过程具有非线性时序特征,能够满足本文构建的 ConvLSTM 时空预测模型训练需要的丰富数据源。

3.3 机场时序 InSAR 地面沉降时空模拟与预测

3.3.1 地面沉降模拟

本文获取了 2016—2021 年北京首都国际机场 151 期时序地面沉降结果,由于 2017-06-20、2019-01-29 和 2019-09-14 为缺失观测值,所以为保证观测时间的连续性,即每期时序结果时间为等间隔,通过取缺失值的前后观测值的平均值进行插值得到 154 期时序 InSAR 形变数据。基于时序 InSAR 形变数据通过滑动窗口创建时序形变新数据集,利用新数据集构建 ConvLSTM 预测模型,实验过程中发现,不同时间步长会影响预测

模型的精度。为确定最佳时间步长,利用小波变换检测机场地面沉降的周期性。如图 13 所示,机场地面沉降存在几个主周期波峰,周期大约在 30、52、80、128 附近。综合考虑模型计算效率、结果精度以及硬件条件 3 个方面,最佳时间步长的确定依据周期检测结果计算 $\{3, 6, \dots, 30, 52, 80\}$ 时间步长的所有评价指标值。

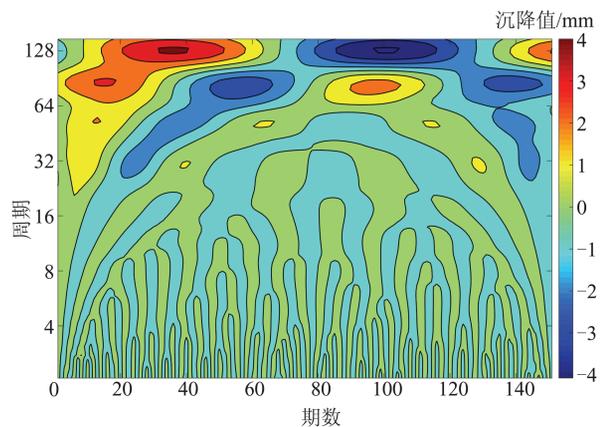


图 13 北京首都国际机场地面沉降的周期检测

Fig. 13 Periodic Detection of Ground Subsidence at Beijing Capital International Airport

本文将数据集最后 15 期时序 InSAR 形变图作为验证集,表 2 显示了 ConvLSTM 模型在验证

集上不同时间步长下的4种评价指标值变化。为考虑所有评价指标的表现,对不同步长对应预测模型的评价指标值进行排序,同时对当前模型每一项评价指标的名次进行求和,进而挑选出名次之和最小的模型即为最优模型,最优模型对应的时间步长即为最佳时间步长。经过计算得出最佳时间步长为15,因此,首都国际机场时空预测模型的时间步长为15。

为了验证模型的可信度,随机挑选验证数据集中2021-05-18和2021-11-14的时序InSAR形变数据,将其与ConvLSTM模型预测值进行对比分析,如图14所示。真实时序InSAR形变图与预测形变图的拟合精度高,5种评价指标性能表现均良好,其中图像评价指标SSIM分别为0.946、0.917,表明构建的ConvLSTM地面沉降时空预测模型有效,可以进行地面沉降时空预测。

为了更好地验证模型的预测精度,随机挑选验证数据集中2021-05-18的时序InSAR形变数据,绘制3个剖面的时序形变图,将其与提出的ConvLSTM模型预测值进行对比,分析提出模型的局部预测结果的效果,如图15所示。由图15

可以看出,3个剖面中真实时序InSAR形变图与预测形变图的拟合精度均较高,残差值均在0附近波动,表明构建的ConvLSTM地面沉降时空预测模型训练过程中能够学习到时序InSAR图像的局部特征,预测结果可靠性较高。

表2 不同时间步长预测模型的评价指标值变化
Table 2 Variation of Evaluation Index Values for Prediction Models with Different Time Steps

时间步长	评价指标				
	MAE	MSE	SSIM	MS-SSIM	PSNR
3	2.663	12.626	0.901	0.971	35.152
6	2.872	14.145	0.904	0.972	34.614
9	2.759	13.108	0.905	0.972	34.983
12	2.583	11.666	0.913	0.975	35.504
15	2.583	11.851	0.914	0.975	35.426
18	2.505	11.396	0.907	0.973	35.612
21	2.899	14.179	0.912	0.974	34.616
24	2.609	12.012	0.909	0.973	35.349
27	2.909	14.313	0.909	0.973	34.601
30	2.888	14.360	0.908	0.972	34.598
52	3.403	19.258	0.907	0.971	33.280
80	2.854	14.065	0.901	0.970	34.668

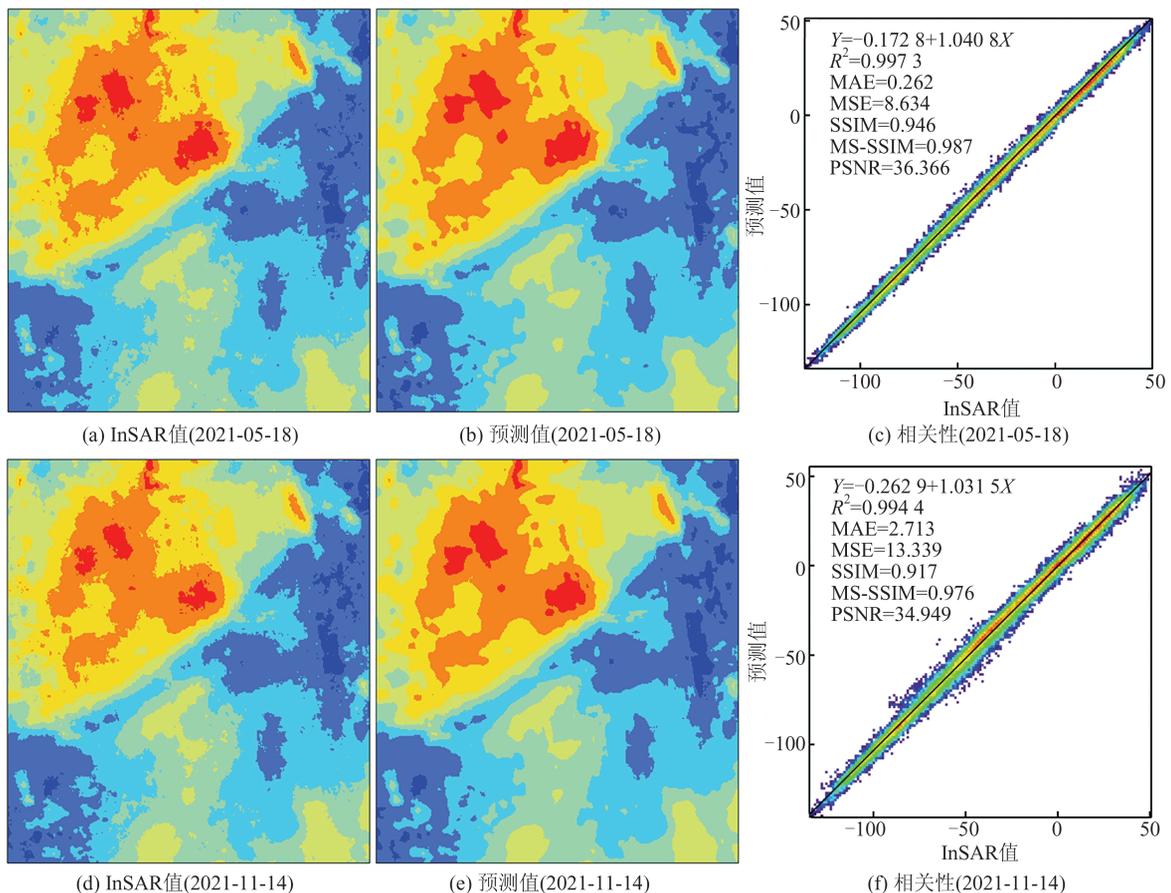


图14 InSAR真实值与预测值的相关性散点图

Fig. 14 Scatter Plot of Correlation Between InSAR Real Value and Predicted Value

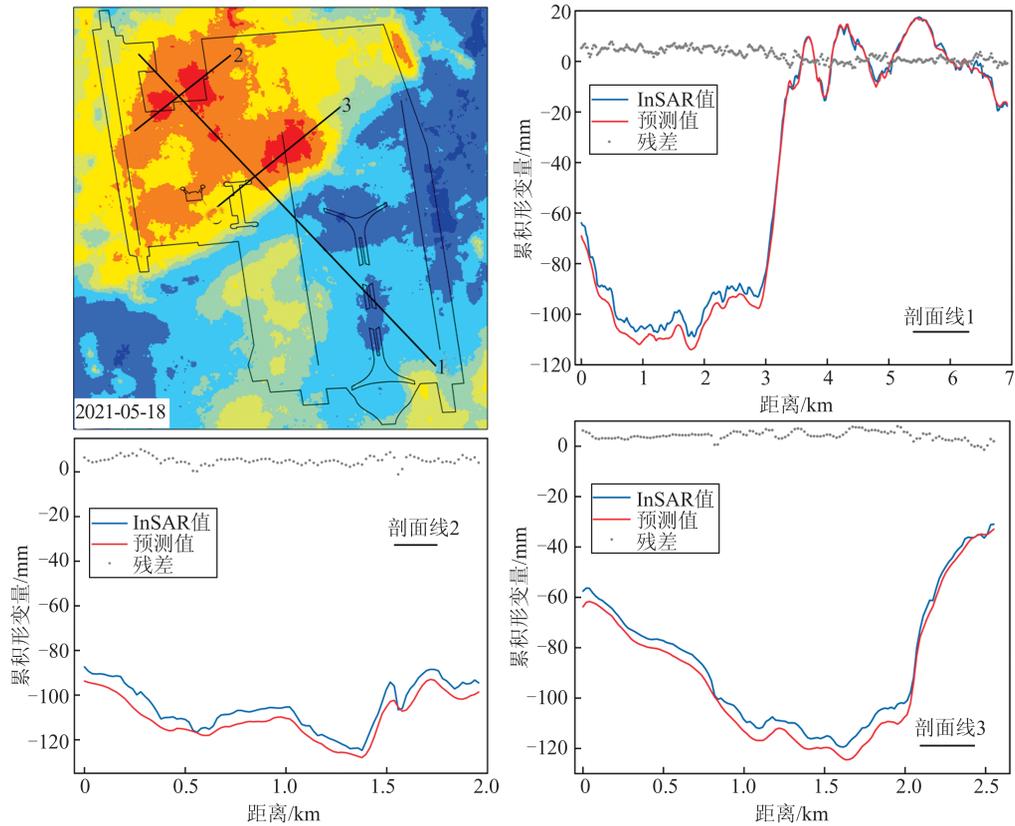


图 15 局部区域时序 InSAR 真实值与预测值的对比

Fig. 15 Comparison of InSAR Real Value with Predicted Value in Local Area

为了进一步验证 ConvLSTM 模型的性能,本文采用了支持向量回归 (support vector regression, SVR)、多层感知器 (multilayer perceptron, MLP)、CNN、LSTM 模型 5 种评价指标进行对比分析,结果见表 3。表 3 显示,本文所提模型在 MAE、MSE、MS-SSIM 和 PSNR 评价指标中性能表现最优。总体而言,ConvLSTM 模型的误差最小,表明本文所提模型具有最高的预测精度。

表 3 不同模型的指标比较

Table 3 Comparison of Indicators of Different Models

模型	评价指标				
	MAE	MSE	SSIM	MS-SSIM	PSNR
MLP	3.175	21.099	0.854	0.970	33.093
SVR	2.983	18.630	0.945	0.975	33.389
CNN	2.901	14.345	0.913	0.974	34.659
LSTM	4.359	31.221	0.876	0.949	31.186
ConvLSTM	2.583	11.851	0.914	0.975	35.426

3.3.2 地面沉降预测

本文基于构建的 ConvLSTM 时空预测模型,设时序 InSAR 形变图像数据为 $X = \{X_T\}, T = 1, 2, \dots, n$; X 和 Y 分别为输入数据和预测数据。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时序形变数据集 X 。

在最后一期时序 InSAR 形变图像基础上,即 2021-11-14, 利用构建的 ConvLSTM 模型通过循环预测模式预测到第 30 期截止,即 2022-11-09, 获取首都国际机场未来一年的地表形变时空变化结果,绘制 4 期地表形变空间分布,如图 16 所示。

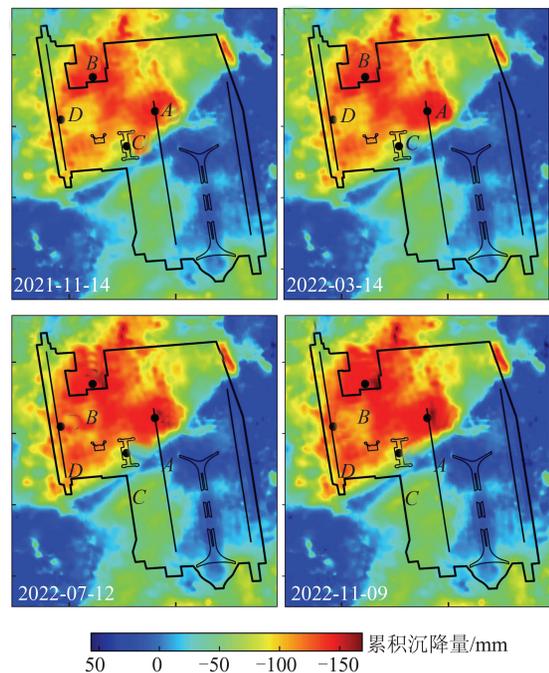


图 16 未来一年预测结果

Fig. 16 1-Year Forecast Results

为了进一步分析北京首都国际机场未来一年地面沉降时序特征,本文选取了首都国际机场4个典型地区的位置点A、B、C和D,A点位于跑

道36L北部,B点位于货运区,C点位于T2航站楼,D点位于跑道36R,统计了4个点的地面沉降年际时间序列变化,结果如图17所示。

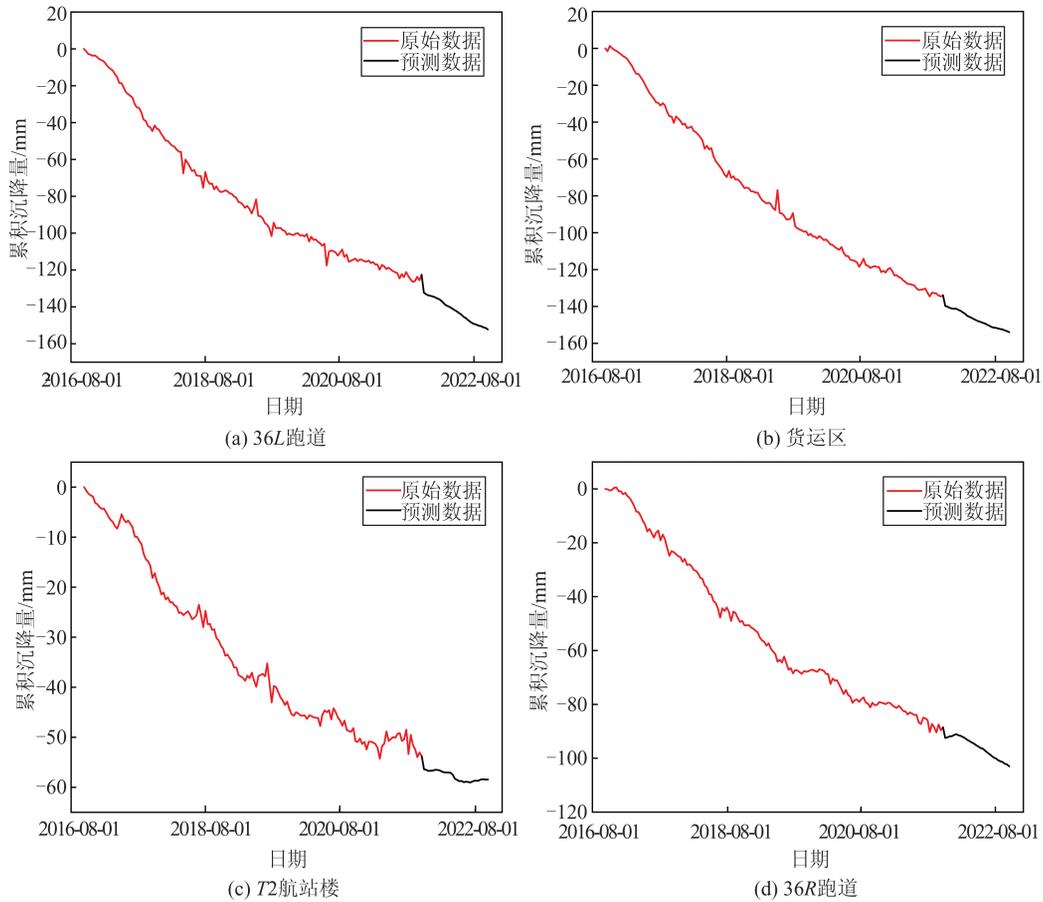


图17 北京首都国际机场地面沉降时间序列变化

Fig. 17 Time Series Change of Land Subsidence at Beijing Capital International Airport

由图16可以看出,北京首都国际机场未来一年地面累积沉降量不断增加,空间上地面沉降呈现不断扩展趋势。机场西北和东南方向的地面沉降空间分布差异逐渐增大,其中西北方向的货运区沉降较为严重,最大累积沉降量达到157 mm,同时机场跑道36L南北地面沉降不均匀,跑道36R北部出现的沉降漏斗扩张明显,航站楼地面沉降较为明显,累积沉降约为65~113 mm。

从图17可以看出,A、B和D处地面沉降持续增大,跑道36L北部、货运区和跑道36R未来一年的最大累积沉降量分别达到150 mm、157 mm和102 mm。T2航站楼未来一年地面沉降逐渐减缓,呈现波动变化趋势,最大累积沉降量约为60 mm。本文结果可为机场安全设施管理提供数据支撑。

4 结 语

基于2016—2021年的北京首都国际机场

的时序InSAR地面沉降监测结果,构建了ConvLSTM地面沉降时空预测模型,随机挑选2021-05-18和2021-11-14的真实InSAR形变数据,与其ConvLSTM的预测结果进行对比分析发现拟合精度高, R^2 最大为0.997。图像评价指标在结构相似度、质量和失真方面取得了良好的准确性,尤其 $T=15$ 时,SSIM和MS-SSIM分别达到了0.914、0.975。此外,与SVR、MLP、CNN和LSTM模型进行了对比分析,所提模型在MAE、MSE、MS-SSIM和PSNR评价指标中性能表现最优,说明构建的ConvLSTM地面沉降时空预测模型具有可靠性。此外,利用构建的ConvLSTM预测模型,通过循环预测模式获取北京首都国际机场向后预测未来一年的地表形变时空预测结果,截至2022-11-09,北京首都国际机场西北和东南方向的地面沉降空间分布差异逐渐增大,机场西北方向的货运区沉降较为严重,最大累积沉降量将达到157 mm,同时机场跑道36L南北地面沉

降不均匀,跑道 36R 北部出现的沉降漏斗扩张明显,航站楼地面沉降较为明显,累积沉降约为 65~113 mm。

地面沉降时空预测模型构建过程中仅利用了时序 InSAR 监测数据,未考虑降雨、地形和地下水等环境因子对地面沉降的影响。后续工作将结合环境因子构建时空预测模型,进而提高地面沉降预测精度。

参 考 文 献

- [1] 曹群,陈蓓蓓,宫辉力,等. 基于 SBAS 和 IPTA 技术的京津冀地区地面沉降监测[J]. 南京大学学报(自然科学), 2019, 55(3): 381-391.
CAO Qun, CHEN Beibei, GONG Huili, et al. Monitoring of Land Subsidence in Beijing-Tianjin-Hebei Urban by Combination of SBAS and IPTA [J]. *Journal of Nanjing University (Natural Science)*, 2019, 55(3): 381-391.
- [2] HE Y, CHEN Y D, WANG W H, et al. TS-InSAR Analysis for Monitoring Ground Deformation in Lanzhou New District, the Loess Plateau of China, from 2017 to 2019 [J]. *Advances in Space Research*, 2021, 67(4): 1267-1283.
- [3] WANG W H, HE Y, ZHANG L F, et al. Analysis of Surface Deformation and Driving Forces in Lanzhou [J]. *Open Geosciences*, 2020, 12(1): 128.
- [4] 陈有东,何毅,张立峰,等. 联合升降轨 Sentinel-1A 的地表形变监测技术研究[J]. 海洋测绘, 2020, 40(4): 59-64.
CHEN Youdong, HE Yi, ZHANG Lifeng, et al. Research on Ground Deformation Monitoring Technique of Jointing Ascending and Descending Sentinel-1A [J]. *Hydrographic Surveying and Charting*, 2020, 40(4): 59-64.
- [5] 王文辉,何毅,张立峰,等. 基于 PS-InSAR 和 GeoDetector 的兰州主城区地表变形监测与驱动力分析[J]. 兰州大学学报(自然科学版), 2021, 57(3): 382-388.
WANG Wenhui, HE Yi, ZHANG Lifeng, et al. Ground Deformation Monitoring and Driving Force Analysis of the Main City Area in Lanzhou Based on PS-InSAR and GeoDetector [J]. *Journal of Lanzhou University (Natural Sciences)*, 2021, 57(3): 382-388.
- [6] 杨成生,张勤,赵超英,等. 短基线集 InSAR 技术用于大同盆地地面沉降、地裂缝及断裂活动监测[J]. 武汉大学学报(信息科学版), 2014, 39(8): 945-950.
YANG Chengsheng, ZHANG Qin, ZHAO Chaoying, et al. Small Baseline Subset InSAR Technology Used in Datong Basin Ground Subsidence, Fissure and Fault Zone Monitoring [J]. *Geomatics and Information Science of Wuhan University*, 2014, 39(8): 945-950.
- [7] 杨梦诗,廖明生,史绪国,等. 联合多平台 InSAR 数据集精确估计地表沉降速率场[J]. 武汉大学学报(信息科学版), 2017, 42(6): 797-802.
YANG Mengshi, LIAO Mingsheng, SHI Xuguo, et al. Land Subsidence Monitoring by Joint Estimation of Multi-platform Time Series InSAR Observations [J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(6): 797-802.
- [8] 李永生,张景发,李振洪,等. 利用短基线集干涉测量时序分析方法监测北京市地面沉降[J]. 武汉大学学报(信息科学版), 2013, 38(11): 1374-1377.
LI Yongsheng, ZHANG Jingfa, LI Zhenhong, et al. Land Subsidence in Beijing City from InSAR Time Series Analysis with Small Baseline Subset [J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(11): 1374-1377.
- [9] 许文斌,罗兴军,朱建军,等. InSAR 火山形变监测与参数反演研究进展[J]. 武汉大学学报(信息科学版), 2023, 48(10): 1632-1642.
XU Wenbin, LUO Xingjun, ZHU Jianjun, et al. Review of Volcano Deformation Monitoring and Modeling with InSAR [J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(10): 1632-1642.
- [10] BERARDINO P, FORNARO G, LANARI R, et al. A New Algorithm for Surface Deformation Monitoring Based on Small Baseline Differential SAR Interferograms [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2002, 40(11): 2375-2383.
- [11] YANG C S, ZHANG Q, ZHAO C Y, et al. Monitoring Land Subsidence and Fault Deformation Using the Small Baseline Subset InSAR Technique: A Case Study in the Datong Basin, China [J]. *Journal of Geodynamics*, 2014, 75: 34-40.
- [12] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [13] RADMAN A, AKHOONDZADEH M, HOSSEINY B. Integrating InSAR and Deep-Learning for Modeling and Predicting Subsidence over the Adjacent Area of Lake Urmia, Iran [J]. *GIScience & Remote Sensing*, 2021, 58(8): 1413-1433.
- [14] CHEN Y, HE Y, ZHANG L F, et al. Prediction of InSAR Deformation Time-Series Using a Long

- Short-Term Memory Neural Network[J]. *International Journal of Remote Sensing*, 2021, 42(18): 6919-6942.
- [15] 杨梦诗, 廖明生, 常玲, 等. 城市场景时序 InSAR 形变解译: 问题分析与研究进展[J]. 武汉大学学报(信息科学版), 2023, 48(10): 1643-1660.
YANG Mengshi, LIAO Mingsheng, CHANG Ling, et al. Interpretation of Multi-Epoch InSAR Deformation for Urban Scenes: A Problem Analysis and Literature Review[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(10): 1643-1660.
- [16] 陈毅, 何毅, 张立峰, 等. 长短时记忆网络 TS-InSAR 地表形变预测[J]. 遥感学报, 2022, 26(7): 1326-1341.
CHEN Yi, HE Yi, ZHANG Lifeng, et al. Surface Deformation Prediction Based on TS-InSAR Technology and Long Short-Term Memory Networks [J]. *National Remote Sensing Bulletin*, 2022, 26(7): 1326-1341.
- [17] 程成. 基于深度学习的设备剩余寿命预测算法研究及其应用[D]. 北京: 北京化工大学, 2020.
CHENG Cheng. Research and Application of Equipment Remaining Life Prediction Algorithm Based on Deep Learning [D]. Beijing: Beijing University of Chemical Technology, 2020.
- [18] MA P F, ZHANG F, LIN H. Prediction of InSAR Time-Series Deformation Using Deep Convolutional Neural Networks [J]. *Remote Sensing Letters*, 2020, 11(2): 137-145.
- [19] SUN J, WAUTHIER C, STEPHENS K, et al. Automatic Detection of Volcanic Surface Deformation Using Deep Learning[J]. *Journal of Geophysical Research: Solid Earth*, 2020, 125(9): e2020JB019840.
- [20] HE Y, ZHAO Z A, YANG W, et al. A Unified Network of Information Considering Superimposed Landslide Factors Sequence and Pixel Spatial Neighbourhood for Landslide Susceptibility Mapping [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 104: 102508.
- [21] SHI X J, CHEN Z R, WANG H, et al. Convolutional LSTM Network[C]//The 29th International Conference on Neural Information Processing Systems, Montreal, Canada, 2015.
- [22] 俞晓莹. 改进的 SBAS 地表形变监测及地下水应用研究[D]. 长沙: 中南大学, 2012.
YU Xiaoying. Improved SBAS Technology for Land Deformation Detection and Groundwater Application [D]. Changsha: Central South University, 2012.
- [23] MORE J J. The Levenberg-Marquardt Algorithm: Implementation and Theory[C]// Numerical Analysis. Berlin, Heidelberg: Springer, 1978: 105-116.
- [24] WANG Z, BOVIK A C, SHEIKH H R, et al. Image Quality Assessment: From Error Visibility to Structural Similarity [J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.
- [25] 赵岩, 孟丽茹, 王世刚, 等. 符合人眼视觉感知特性的改进 PSNR 评价方法[J]. 吉林大学学报(工学版), 2015, 45(1): 309-313.
ZHAO Yan, MENG Liru, WANG Shigang, et al. Improved PSNR Evaluation Method Consistent with Human Visual Perception [J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2015, 45(1): 309-313.
- [26] ZHU L, GONG H L, LI X J, et al. Land Subsidence Due to Groundwater Withdrawal in the Northern Beijing Plain, China [J]. *Engineering Geology*, 2015, 193: 243-255.
- [27] GAO M L, GONG H L, CHEN B B, et al. InSAR Time-Series Investigation of Long-Term Ground Displacement at Beijing Capital International Airport, China [J]. *Tectonophysics*, 2016, 691: 271-281.
- [28] DAI K R, LIU G X, LI Z H, et al. Monitoring Highway Stability in Permafrost Regions with X-Band Temporary Scatterers Stacking InSAR [J]. *Sensors*, 2018, 18(6): 1876.
- [29] GAO M L, GONG H L, LI X J, et al. Land Subsidence and Ground Fissures in Beijing Capital International Airport (BCIA): Evidence from Quasi-PS InSAR Analysis [J]. *Remote Sensing*, 2019, 11(12): 1466.
- [30] DAI K R, SHI X L, GOU J S, et al. Diagnosing Subsidence Geohazard at Beijing Capital International Airport, from High-Resolution SAR Interferometry [J]. *Sustainability*, 2020, 12(6): 2269.