

顾及空间异质性的大范围地面沉降时空预测

刘青豪^{1,2}, 刘慧敏¹, 张永红², 吴宏安², 邓敏¹

1. 中南大学 地球科学与信息物理学院, 长沙 410083;

2. 中国测绘科学研究院, 北京 100830

摘要: 大速率、不均匀的地面沉降已经威胁到人类的生产活动, 高精度的沉降预测结果对于地质灾害的精准防控具有重要意义。为掌握地面沉降的演化规律, 利用现场观测数据或InSAR数据开展了多项预测研究。然而, 由于空间异质性的存在, 大范围地面沉降的准确预测仍然是一项挑战。在这项研究中, 从数据驱动的角度提出了一种顾及空间异质性的地面沉降时空预测方法STLSTM (Spatio-temporal Long Short-Term Memory)。首先, 通过聚类识别地理空间中的均质子区; 然后, 在每个子区中, 一个特别的长短期记忆LSTM (Long Short-Term Memory)网络被用来捕捉局部位置的非线性特征; 最后, 利用预训练的网络对未来时刻的地面沉降进行定量预测。在实验部分, 哨兵1号影像数据被用来比较STLSTM与其他8种基准方法的性能, 利用空间统计指标分析了模型的有效性。结果表明, STLSTM在152 s内达到了最高的预测精度(71.4%), 且能够有效弱化空间异质性对大范围沉降预测任务的影响。总之, 这项研究将空间异质性处理策略融合到深度学习模型中, 实现了高精度、高时效的大范围地面沉降时空预测。

关键词: 遥感, 地面沉降, 时空预测, 异质性, LSTM, InSAR

引用格式: 刘青豪, 刘慧敏, 张永红, 吴宏安, 邓敏. 2022. 顾及空间异质性的地面沉降时空预测. 遥感学报, 26(7): 1315-1325

Liu Q H, Liu H M, Zhang Y H, Wu H A and Deng M. 2022. A spatio-temporal prediction method of large-scale ground subsidence considering spatial heterogeneity. National Remote Sensing Bulletin, 26(7): 1315-1325 [DOI: 10.11834/jrs.20211445]

1 引言

为了满足经济发展的需要, 煤、石油、天然气、地下水等多种地下自然资源被不断开采, 由此产生了大范围的地面沉降(张梁等, 1998)。据统计, 在2009年以前, 全国累计发生沉降超过200 mm的区域面积就超过了79000 km², 仅长三角地区, 在2005年以前因地面沉降造成的经济损失就已超过3000亿元(周飞飞, 2012)。为了减少地面沉降的发生, 营造一个安全的生活环境, 地面沉降防治工作刻不容缓。

自20世纪80年代以来, 各地政府采取了多项措施来降低地面沉降的潜在危害, 虽然部分城市的地面沉降问题得到了有效缓解, 然而, 仅通过机械地“限采”、“封井”、“回灌”等措施并不能

从根本上消除地面沉降与资源开采之间的矛盾, 反而造成了人力、物力、财力的被动式投入(李丽, 2014)。为了避免地面沉降防治工作中社会资源的浪费, 实现自然资源的可持续发展, 有必要提前掌握地面沉降的时空演化规律, 进而为防灾减灾、空间规划、资源开采等工作提供及时有效的指导(朱菊艳, 2014), 因此, 开展高精度的地面沉降预测工作势在必行。

目前, 大多数地面沉降预测方法都依赖于传统测绘手段(如水准测量、GPS测量等)获取的现场数据, 尽管相关技术具有较高的观测精度, 然而, 这些数据也具有某些缺陷, 例如空间代表性低、获取成本高、观测周期长等, 这严重限制了开展大范围、高精度的沉降预测(朱建军等, 2017)。随着InSAR技术的发展, 连续的大面积对

收稿日期: 2021-07-05; 预印本: 2021-11-03

基金项目: 国家自然科学基金(编号: 41730105, 41874014, 41771492); 政府间国际科技创新合作重点专项(编号: 2017YFE01071000)

第一作者简介: 刘青豪, 研究方向为InSAR形变监测与分析、时空数据挖掘。E-mail: 1580748414@qq.com

通信作者简介: 张永红, 研究方向为InSAR形变监测原理与应用。E-mail: yhzhang@casm.ac.cn

地观测已经成为现实(廖明生和林琿, 2003; 张永红等, 2018), 在这种背景下, 利用InSAR数据和深度学习技术实现大范围地面沉降的高精度预测成为一个重要的研究方向。

实际上, 现有的地面沉降预测方法可以被分为3类: 数理统计方法、物理机制方法和机器学习方法。数理统计方法旨在构造明确的数学表达式来拟合沉降变化曲线。通常将地面沉降构建为关于时间/空间/时空的经验函数, 李丽(2014)、范泽琳和张永红(2019)已经综述了一些经典的数理统计方法。该类方法简单易行, 然而, 由于未考虑地层岩性与水文介质之间的影响机制, 这些方法通常仅适用于形变趋势较为简单的情况。随着研究范围的扩大, 空间统计特性逐渐受到了学者们的关注, 时空自回归差分移动平均(STARIMA), 时空地理加权回归(GTWR)以及空间面板数据模型(SPDM)等方法也得到了广泛的应用(李世鹏, 2014; Murakami等, 2006; Ali等, 2020; Pesaran, 2015)。区别于数理统计方法, 物理机制方法需要满足复杂的固结理论假设条件, 通过实测的物理参数来模拟地面沉降的物理演化过程, 该类研究主要集中于地下资源开采或浅层空间开发所引起的沉降(王正帅和邓喀中, 2011; 张子文, 2017)。然而, 尽管它们可以解释地面沉降的演化过程, 但是过多的参数设置及模型假设限制了该类方法的实用性。机器学习方法是通过构建特征工程、模型训练、回归预测等过程来学习沉降模式并拟合沉降, 通常, 他们不需要在自变量和因变量之间建立可解释的数学公式, 并且免受研究区域复杂物理参数的约束。支持向量回归、人工神经网络、贝叶斯网络以及循环神经网络等方法在沉降预测领域均受到了认可(Shahin等2003; Cao等, 2012; Ocak和Seker, 2013; Zhou等, 2019)。然而, 由于特征提取困难以及样本数据粒度不同, 现有的机器学习方法仍然难以得到较高的预测精度。此外, 为全局所训练的机器学习模型忽略了自变量与因变量间关系会随着空间位置发生变化的事实, 这导致预测结果缺乏可解释性成为了普遍问题。

综合研究背景及现状, 虽然在地面沉降预测领域发展了许多研究成果, 但是, 已有的尝试大多是为了解决小区域或独立观测站所反映的地面沉降问题。一方面, 智慧城市的建设对大区域地面

沉降的精准防治提出了更高要求; 另一方面, 基于线性假设的数理统计方法本质上难以准确模拟地面沉降的复杂非线性过程, 物理机制方法因模型参数或相关数据不易获取也难以在大区域得到应用。相比来说, 机器学习方法可以建模复杂的非线性时序关系, 通常具有更好的预测效果, 然而, 该类方法并没有很好地处理空间异质现象, 这导致预测误差存在空间自相关问题, 因此, 有必要考虑更合理的策略来预测沉降。

本文从数据驱动的角度出发, 提出一种顾及空间异质性的InSAR地面沉降时空预测方法, 着重对空间异质性以及时间非线性进行研究, 并利用真实沉降数据分析了模型参数对预测效果的影响, 以期为大范围地面沉降提供时空预测新思路。

2 研究思路及方法

作为一种新的机器学习分支, 深度学习是目前国内外人工智能领域的重点研究内容之一(Deng等, 2009; Zhou等, 2013; Sun等, 2014)。其中, 循环神经网络在对序列的非线性特征进行学习时具有一定优势, 已经在沉降预测领域得到了应用(Zhou等, 2019; 刘青豪等, 2021)。然而, 当涉及到大区域时, 复杂多样的驱动因素导致沉降观测结果出现结构性异质(空间分异)以及局域异质(空间自相关)现象。如果忽略这种空间异质特征, 构建的预测模型在局部区域可能会缺乏解释能力。针对这一问题, 本文首先采取空间分区与局域建模相结合的策略来弱化空间异质性的影响, 进而, 利用循环神经网络在时间序列建模方面的优势, 提出一种顾及空间异质性的InSAR地面沉降时空预测方法。

2.1 空间异质性建模

聚类分析可以根据时间序列之间的相似性和分离度将数据集划分为不同的簇, 进而描述相似的特征映射, 因此可用于确定空间分区(邓敏, 2011)。在这项研究中, 基于K-means(Wu等, 2008)和Delaunay边长约束(Estivill-Castro和Lee, 2002)的组合策略(以下简称KDP)被用来处理空间分异问题。该方法不仅考虑点目标与子区中心的专题属性距离, 同时保证了子区的空间独立性, 因而能够得到合理的分区结果。实际上, 相

关关系的变异不存在明显的空间边界，尽管空间分区可以弱化全局异质性造成的影响，但是邻近点目标之间仍然存在依赖关系。为此，本文采用反距离加权的方法获取每个点目标处的时空特征矩阵，从而在训练样本中以空间特征的形式表达局域异质信息。下面具体介绍空间分区与局域建模策略。

首先，对点目标的沉降属性进行 K-means 聚类。选择平均沉降速率之间的差异作为相似性度量指标，聚类结果的有效性通过经典的 DB 指数 (Davies 和 Bouldin, 1979) 和 Dunn 指数 (Dunn, 1974) 协同确定。如式 (1)—(2) 所示， S_i 和 S_j 表示簇样本点到簇质心距离的均值， d_{ij} 表示两簇质心间的距离， k 表示簇的数量。 $d_{\min}(C_i, C_j)$ 表示两簇内任意点目标之间距离的最小值， $diam(C_p)$ 表示簇的直径。一般的，DB 指数越小或者 Dunn 指数越大，聚类效果越好。

$$DB = \frac{1}{k} \sum_{i=1}^k \max_{i \neq j} \frac{S_i + S_j}{d_{ij}} \quad (1)$$

$$Dunn = \frac{\min_{i \neq j} d_{\min}(C_i, C_j)}{\max_p diam(C_p)} \quad (2)$$

然后，对 K-means 聚类结果中每个簇构建 Delaunay 三角网并划分子区。利用边长约束参数 α 识别空间邻接距离较大的边，如式 (3) 所示，如果某边长超过所在三角网中边长均值 α 倍标准差，则该边被标记为弱邻接，通过删除此类长边对每个聚类簇进行二次划分，进而确定空间分区。其中， $Const_L_i$ 表示簇 i 中构网边长约束阈值， L_i 表示簇 i 中所有边。

$$Const_L_i = mean(L_i) + \alpha STD(L_i) \quad (3)$$

最后，利用反距离加权对任意点目标进行局域建模。主要步骤包括：(1) 利用 Delaunay 三角网构建子区内点目标之间的空间邻接关系；(2) 基于反距离加权分别计算 0— p 阶邻近处点目标产生的异质影响；(3) 将局域异质信息与中心点处沉降序列融合为时空特征矩阵，作为预测模型在当前点目标处的样本源。在反距离加权过程中，权重表示为：

$$\omega_{ij} = d_{ij} / \sum_{j=1}^k d_{ij}^{\alpha} \quad (4)$$

式中， ω_{ij} 表示第 j 个点目标对第 i 个点目标的异质影响权重； d_{ij} 表示第 i 个点目标与第 j 个点目标之间的距离；每阶权重之和为 1；幂指数 α 为实测值

对建模位置的影响级别， α 越小，权重随距离增大衰减得越慢，本文将 α 设置为默认值 1。图 1 表示局域建模示意图。

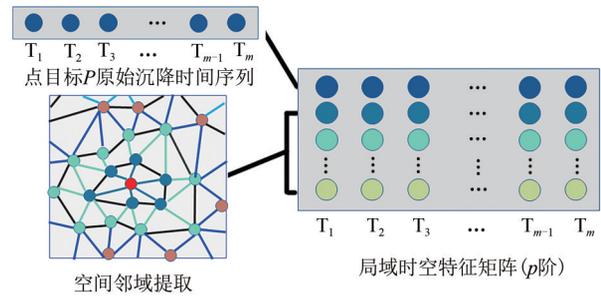


图 1 局域建模示意图

Fig. 1 Schematic diagram of local modeling

2.2 STLSTM 预测框架

如图 2 所示，STLSTM 预测框架可以分为 3 层网络和 3 个模块：输入层、隐藏层、输出层、异质模块、训练模块和预测模块。其中，异质模块负责对时空数据进行均质化处理，隐藏层通过 LSTM 模型进行建模，学习每个样本中的关联信息，输出层是不同点目标预测结果的集合。STLSTM 的输入数据为经过地理编码的沉降时空序列。在异质模块，原始数据被划分为一组均质子区，每个点目标经过局域建模被处理为时空特征矩阵，局域异质信息以空间特征的形式表达在样本中。

总体来说，STLSTM 模型的预测流程包括以下 3 步，首先，将标准化后的沉降数据划分为一组子区；然后，利用局域建模获取每个点目标处的时空特征矩阵；最后，构建一组 LSTM 模型学习每个子区下的沉降模式。

2.3 样本划分

在本研究中，假设一些固定长度的沉降序列中包含重要的形变模式。首先，为了准确学习这些形变模式，将每个点目标对应的沉降序列标记为 $S_m = \{s_1, s_2, \dots, s_m\}$ ， m 表示沉降序列的总长度。其中，每个沉降时序可提取出一个长度为可控参数 l 的训练样本，样本的后 y 个值作为样本标签，前 $(l - y)$ 个数值用作样本输入，且满足约束条件 $2 \leq l < m$ 、 $1 \leq y < l$ 。然后，依据局域建模的思想，将 1— p 阶邻近信息建模为 p 维空间特征并与原始沉降序列融合。最后，对每个样本进行 z-score 标准化以消除沉降时序数量级对训练效果的影响，标准化后的训练样本可以表示为 S'_{train} ：

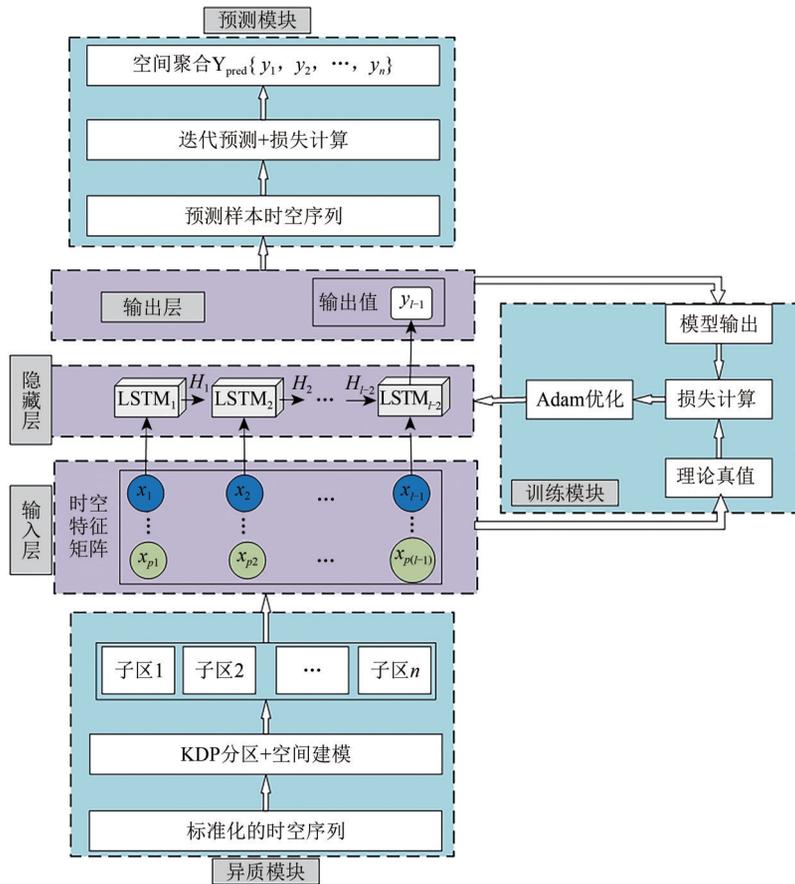


图2 STLSTM 预测框架

Fig. 2 STLSTM prediction framework

$$S'_{train} = \{S'_{m-l}, S'_{m-l+1}, \dots, S'_{m-1}\} \quad (5)$$

式中，数据标准化的具体方法如式(6)–(8)所示， $mean(S_{train})$ 和 $STD(S_{train})$ 分别表示任意样本序列差分沉降值的均值和标准差， s_t 表示标准化前任意序列中某时刻的差分沉降值。

$$s'_t = (s_t - mean(S_{train})) / STD(S_{train}) \quad (6)$$

$$mean(S_{train}) = \sum_{t=1}^m \frac{s_t}{m} \quad (7)$$

$$STD(S_{train}) = \sqrt{\frac{1}{m} \sum_{t=1}^m \left(s_t - \frac{1}{m} \sum_{t=1}^m s_t \right)^2} \quad (8)$$

样本划分方式如图3所示。此外，样本标签长度 y 也可以根据预测步长进行调整。为了便于理解，图3采用单步预测方式划分样本，即样本标签长度 y 为1。按照这种划分方法，每个点目标可提取一个样本用于训练或测试。随机选取研究区域70%的点目标作为训练点，其余30%作为测试点，经过训练及测试调整，获取预训练的模型对未来时刻进行预测。

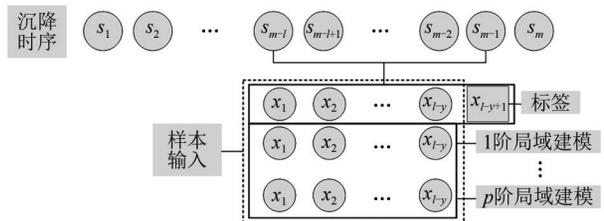


图3 样本划分示意图

Fig. 3 Schematic diagram of sample division

2.4 参数优化及模型更新

空间异质性建模和网络训练是运行 STLSTM 模型的主要内容。K-means 聚类可以根据沉降特征将研究区划分为若干形变区，AMOEBa 方法 (Estivill-Castro 和 LEE, 2002) 进一步将每级形变区划分为一系列均质子区，每个子区用于构建局部 LSTM 模型。网络训练是一个调整权重和偏差的过程，直到满足用户定义的停止标准。在本研究中，当训练集和测试集的“误差—迭代次数”曲线都收敛时，预训练模型被认为达到训练要求。通常，满足上述条件需迭代训练 20 次，该过程主要

依赖于调整网络内部神经元间的连接权重及偏置。

在训练 STLSTM 模型时, l 、 K 、 S 、 p 是最为关键的 网络参数, 分别代表样本序列长度、网络层数、隐藏层神经元数和局域建模阶数。一般采用 网格搜索策略来优化上述模型参数。在本研究中, 以降低平均预测误差作为参数优化的目标, 具体表示为

$$\min \varepsilon(Y, Y_{\text{pred}}) = |Y - Y_{\text{pred}}|$$

$$s.t. \begin{cases} 2 \leq l < m, \text{step}_l \\ 2 \leq K < i, \text{step}_K \\ 2 \leq S < S_{\text{max}}, \text{step}_S \\ 0 \leq p \leq 2, \text{step}_p \\ l, K, S, p \in N \end{cases} \quad (9)$$

式中, step_l 、 step_K 、 step_S 、 step_p 分别表示相关参数的 搜索步长。通常, 网络层数和隐藏层神经元数的 最大搜索范围 i 和 S_{max} 需要根据训练效果设定经 验值。在本研究中, Adam (Kingma 和 Ba, 2014) 优化算法被用作网络训练优化器。

在网络训练达到收敛要求后, 进行网络预测。 首先, 从每个点目标的沉降序列中截取待预测样 本 $S_{\text{pred}} = \{s_{m-l+1}, s_{m-l+2}, \dots, s_m\}$ 。模型训练和预测 的准确率可以定量表达为式 (11)

$$\mu = 100 \cdot \left(1 - \frac{\text{MAE}}{\text{MAD}}\right) \% \quad (10)$$

$$\text{MAE} = \frac{1}{n} \sum |Y - Y_{\text{pred}}| \quad (11)$$

$$\text{MAD} = \frac{1}{n} \sum |Y| \quad (12)$$

式中, μ 表示模型的平均预测精度, MAE 表示平均 绝对误差, MAD 表示平均真实形变。

总的来说, STLSTM 是一个由 InSAR 数据驱动的 预测器。其中, 训练集和测试集仅用于训练或 调整预训练模型, 时间成本远低于 SAR 影像更新 周期 (通常为 12 d)。此外, 预训练的模型可以预 测第 m 时刻的沉降, 当第 m 时刻的真实沉降数据 得到更新后, 预测样本 S_{pred} 被立即提交给预训练的 模型, 从而更新模型参数。这意味着我们可以利用 最新的观测结果在短时间内预测未来时刻的 沉降。

3 数据概况及实验

3.1 数据概况

沧州地区是华北平原沉降最为严重的区域之

一 (Zhou 等, 2018), 该地区地面沉降具有速度 快、范围广、不均匀、危害重的特点。相关研究 (秦同春 等, 2018; Zhou 等, 2018; 刘青豪 等, 2021) 表明, 自 1970 年以来, 该地区最大累计沉 降已超过 3 m, 并仍处于缓慢发展阶段。为此, 本 研究将该地区作为研究区域, 实验数据来自于 Sentinel-1A 卫星 2017 年 1 月—2019 年 12 月采集的 80 幅 SAR 影像。此外, 利用多主影像相干目标小 基线技术 (Zhang 等, 2018) 反演形变信息, 并基 于 430476 个高相干点生成了累计形变时空序列 (图 4)。采用局部线性插值填充失相干所引起的 数据缺失时段, 最终, 每个点目标得到 89 个相等时 间间隔的沉降记录。基于国家二等水准数据的精 度验证结果表明, 控制点与形变反演结果间的中 误差为 7.2 mm。

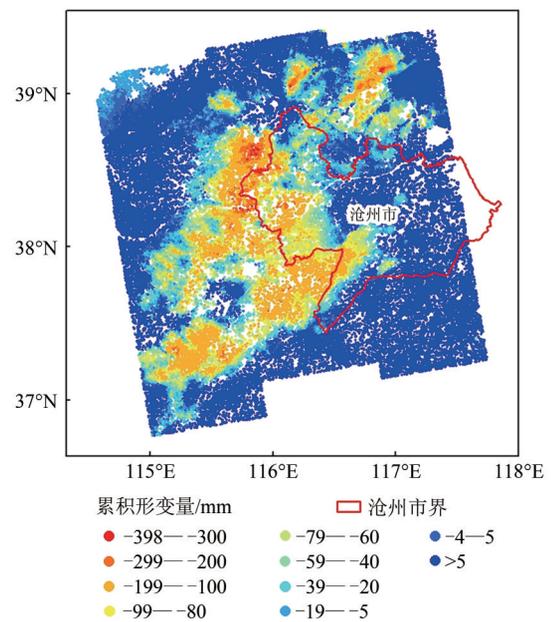


图 4 沧州地区沉降空间分布

Fig. 4 Spatial distribution of subsidence in Cangzhou area

3.2 空间分区

为了减少空间异质性的影响, 借助 Matlab 2016 软件环境, 采用 KDP 算法将研究区域划分为若干 均质子区。组合策略仅需设置边长约束常数 α (本 文实验 $\alpha=3$) 即可获得均质的子区。实验表明, 当 K-means 聚类数目为 2 时 (通常小于 10), 可以得 到较小的 DB 指数和较大的 Dunn 指数 (图 5)。应 该说, 边长约束常数 α 对于最终分区数目有直接 的影响, α 取值越低, 邻接关系的认定越严, 最终 的分区数目越多。

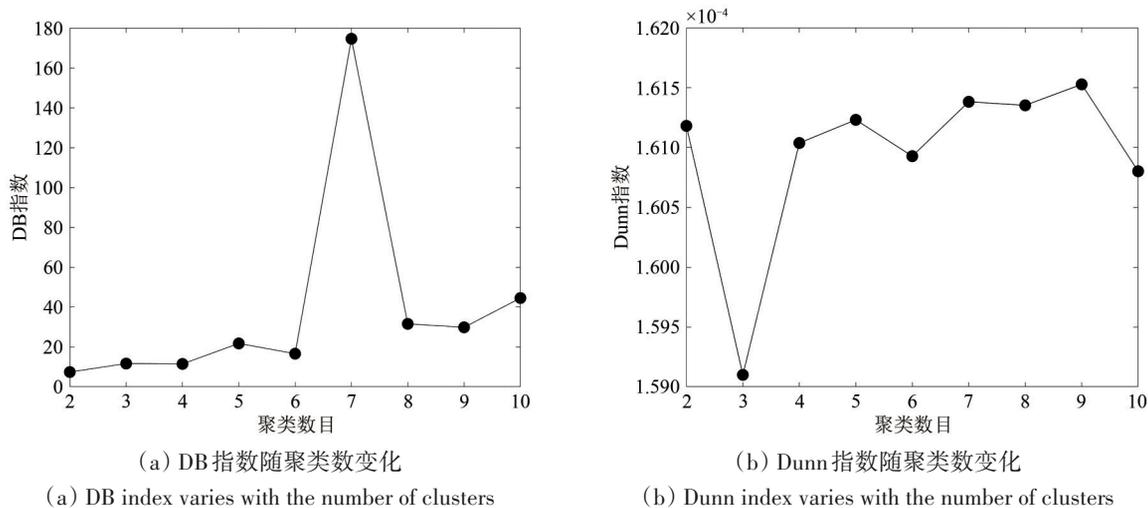


图5 不同聚类数目下的DB指数与Dunn指数分布
Fig. 5 Distribution of DB index and Dunn index under different number of clusters

本研究借鉴杨学习等 (2016) 的参数设定, 进一步划分出子区 2、3、5 (图6)。其中, 每个均质子区表示具有相似沉降特征和相邻空间位置的高相关点集合。该策略不仅描述了沉降序列间的相似性, 而且与沉降漏斗的空间分布高度吻合 (图6和

图4)。此外, 表1显示了基于 q -统计 (Wang 等, 2016) 的度量, 结果表明, 空间分区有效地削弱了研究区域的分层异质性, 因此, KDP算法可以较好地弱化地面沉降的空间异质性。

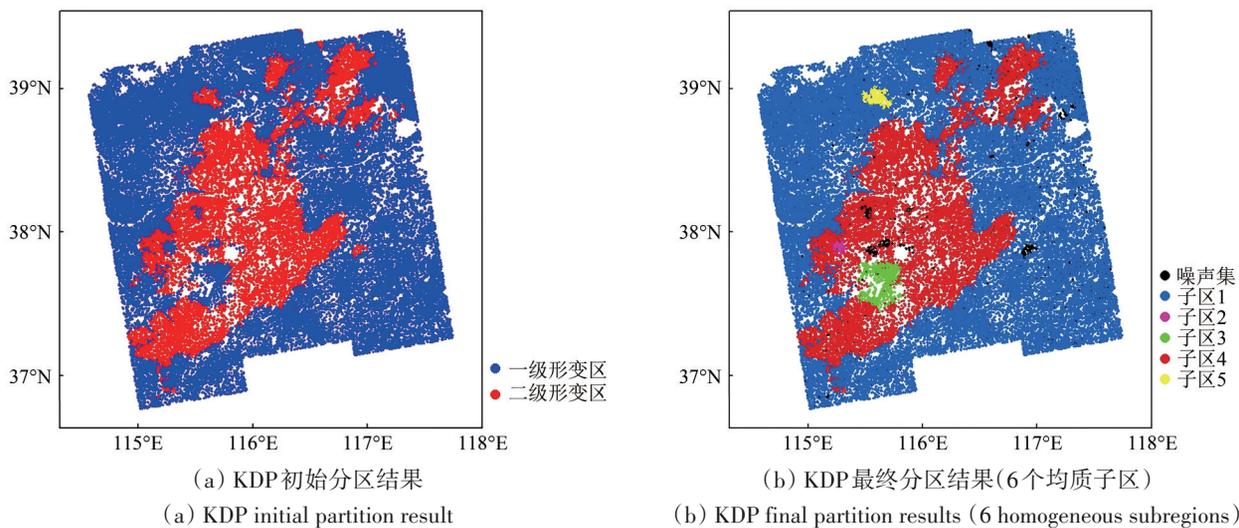


图6 KDP空间分区结果
Fig. 6 KDP space partition result

3.3 网络参数分析

首先, 利用图7分析了样本标签长度对预测效果的影响。在MAE热力图中, 颜色条表示网格中MAE取值的范围。可以发现, 随着样本标签长度(SLL)的增加, 不同样本输入长度(SIL)下的平均绝对误差也会提高, 这条规律启发用户将SLL优先设置为1。此外, 虽然误差间的差异很小, 但在

垂直方向上SIL并不是一直呈现线性趋势, 这表明存在一个不确定的SIL值来优化预测性能。

然后, 利用图8分析了不同网络参数下的预测效果。不同参数设置下的误差表明, 模型预测精度并不总是与模型复杂度呈正相关, 而是在局部形成出色的组合。当网格边界确定后, 最优网络参数的分布趋于一致。例如, 当“SIL=60, SLL=

1”时，最优参数始终位于“网络层数为3，神经元数为10”。

表1 分区前后分层异质性变化

Table 1 Changes in hierarchical heterogeneity before and after partitioning

数据状态	区域名称	q	$p(0.05)$	分层异质是否显著
原始数据	全局	0.5061	0	是
	子区1	0	0.9072	否
KDP 空间分区	子区2	0.0337	0.0741	否
	子区3	0.0051	0.4804	否
	子区4	0.0002	0.6241	否
	子区5	0	0.9865	否
	噪声集	0.0055	0.4651	否

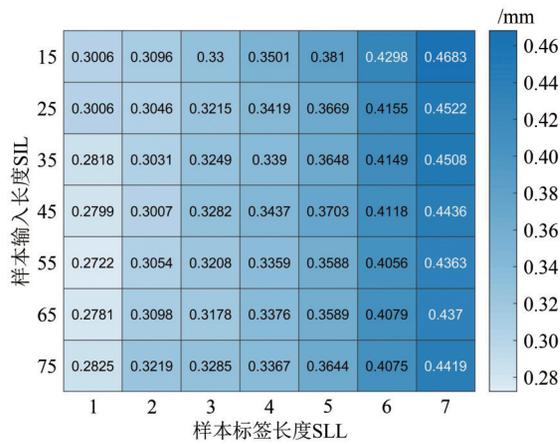


图7 MAE网格搜索结果($K=30, S=2$)

Fig. 7 MAE grid search results ($K=30, S=2$)

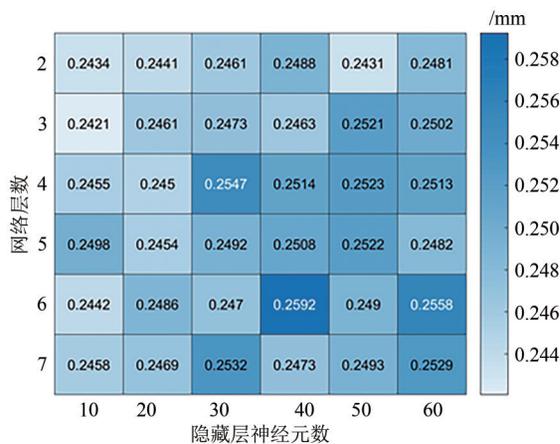


图8 最优网络参数组合 ($SIL=60, SLL=1$)

Fig. 8 Optimal network parameter combination ($SIL=60, SLL=1$)

此外，本文进一步分析了各子区不同样本输入长度下的预测结果。如图9所示，子区1—3被蓝色的一级形变区划分，子区4—5被红色的二级形变区划分，黑色噪声点表示孤立点和较小簇的

集合。图9表明，当SIL增加至一定范围后，不同子区的最小预测误差反而逐渐增加。这意味着预测效果并不总是随着SIL的增加而改善。另一方面，虽然一些子区处于相同级别的形变区，但地理环境的差异使其产生不同的沉降模式（例如，前3个子区均由一级形变区划分得到，但是具有不同的最优SIL），这进一步说明了划分子区时需要考虑空间约束。应该说，STLSTM的性能会受到数据量的影响，当子区点目标的数据体量较小时，训练一个拟合良好的神经网络会变得困难。在本实验中，数据体量小于1000的子区点目标数目总占比仅为1.9%，且子区合并训练所产生的误差在大区域下并不显著（图9中黑色折线），因此，本文将点目标数目较少的子区与孤立点合并为噪声集。

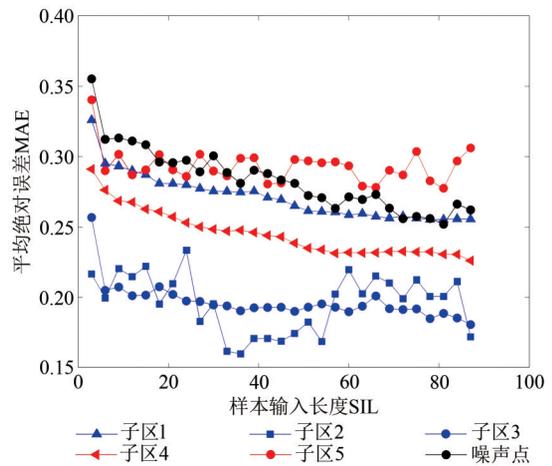


图9 不同子区SIL与MAE关系比较($p=0$)

Fig. 9 Comparison of the relationship between SIL and MAE in different subregions ($p=0$)

3.4 预测方法对比

为了分析STLSTM模型的预测性能，本文将STLSTM与二次指数平滑等其他8种方法进行比较，选取建模时间（包括预处理）和预测误差作为评价指标，所有方法使用相同的数据源。

表2表示本文方法最终的参数优选结果。从表3可以看出，与其他算法相比，LSTM和STLSTM具有更好的性能。需要注意的是，差分自回归移动平均（ARIMA）模型和时空差分自回归移动平均（STARIMA）模型需要在每个点目标处重复建模，从而消耗大量的时间成本，因此，它们不适合应用在大区域沉降预测中。在表2中，这两种方

法的建模时间为系统抽样估计值。实验结果反映：
 (1) 在预测沉降时，为时间序列预测所设计的深度学习网络优于典型的统计方法和机器学习方法。
 (2) 长期依赖确实对地面沉降预测有影响（比较RNN和LSTM）。
 (3) 新提出的空间异质性处理策略使LSTM的预测精度提高了0.6%，得到了更连续的绝对误差分布（比较STLSTM和LSTM）。图10

表明，对于相同点目标，红色预测值（STLSTM）比蓝色预测值（LSTM）更接近 $Y=X$ 等值线。显然，STLSTM对点目标预测结果的整体方法有一定的抑制作用，特别是随着真实形变量的增加，这种改进更加明显。
 (4) 所提出的STLSTM获得了最低的MAE和MSE，证明了所提出方法的有效性。

表2 各子区的网络超参数设置

Table 2 Network hyperparameter settings of each subregion

形变区	子区ID	邻近阶数	样本输入长度	隐藏层层数	单层神经元数	共同参数
一级形变区	子区1	0	87	2	30	样本输出长度:1 迭代次数:20 学习率:0.001
	子区2	1	33	3	30	
	子区3	1	57	2	30	
二级形变区	子区4	1	75	3	30	
	子区5	1	9	2	20	
噪声集		1	42	3	30	

表3 不同预测方法之间的性能对比

Table 3 Comparison of performance between different prediction methods

模型	误差			精度/%	时间
	MAE/mm	SD/mm	MSE/mm ²		
SES	0.5417	1.4868	3.2499	37.7	23 s
ARIMA	0.3612	0.3202	0.2329	58.6	518 h
STARIMA	0.2991	0.2711	0.1629	65.6	610 h
GWR	0.2774	0.2575	0.1433	68.1	712 s
MLR	0.4473	0.3582	0.3284	48.6	450 s
SVR	0.2675	0.2676	0.1431	66.1	241 s
RNN	0.2846	0.2699	0.1539	69.3	367 s
LSTM	0.2543	0.2493	0.1268	70.8	226 s
一级形变区	0.2500	0.2443	0.1222		134 s
二级形变区	0.2433	0.2295	0.1119	71.4	66 s
全局	0.2492	0.2414	0.1204		134 s

注:MAE:平均绝对误差; SD:标准差; MSE:均方误差。

3.5 空间分析

为分析沧州地区沉降预测结果的整体效果，利用图11进行了预测值与误差值的大尺度表达。结果表明，预测值与真实沉降高度一致，沉降漏斗显示清晰，88.43%的点目标预测误差在±0.5 mm以内。此外，在430476个点目标中，平均预测精度达到71.4%。由于STLSTM独立训练每个子区，主要的建模时间消耗在异质模块（18 s）和子区4（134 s）。

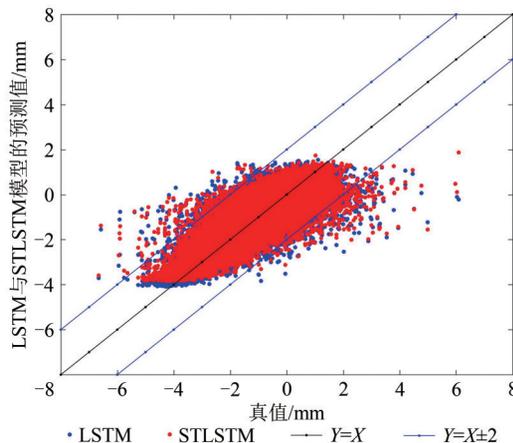


图10 STLSTM与LSTM方法的误差分布对比
 Fig. 10 Comparison of error distribution between STLSTM and LSTM methods

InSAR时间序列分析为揭示地面沉降的宏观模式和演化规律提供了重要参考（朱建军等，2017）。为验证预测模型的有效性，进一步利用ArcGIS等工具对预测结果和真实值的空间统计特征进行对比分析。如表4所示，借助不同空间分析指标对空间自相关、分层异质性、空间点格局等特性进行度量，结果表明，STLSTM模型的预测结果并未显著改变真实沉降的空间统计特征。也就是说，大尺度的预测结果仍然保持了原始InSAR反演结果的沉降模式，这在空间上验证了深度学习方法在沉降预测任务中的可行性。

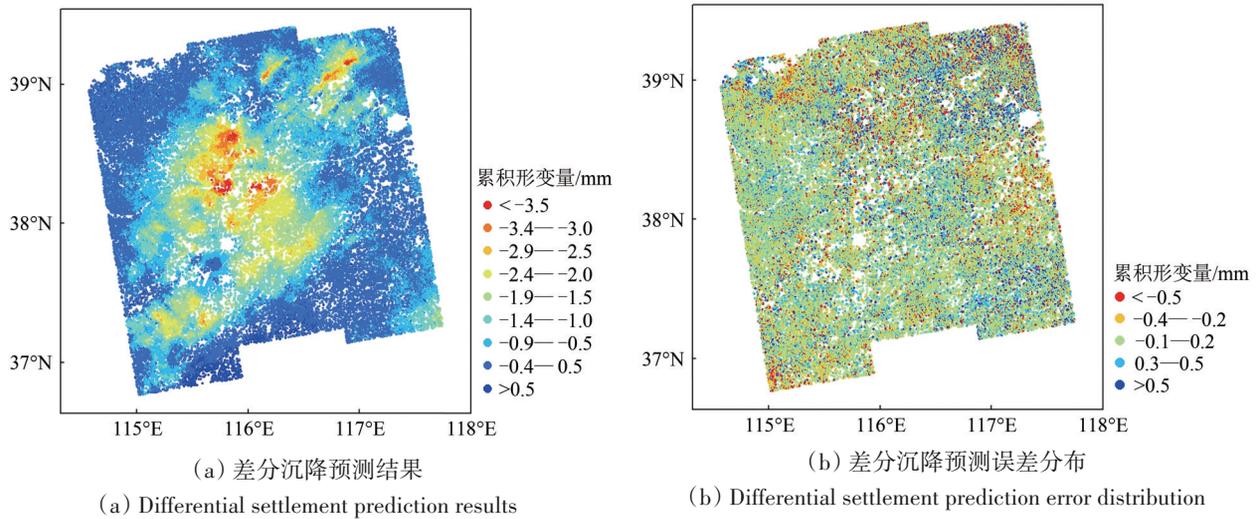


图 11 沧州地区沉降预测结果
Fig. 11 Prediction results of subsidence in Cangzhou area

表 4 预测值与真值的空间统计特性对比
Table 4 Comparison of the spatial statistical characteristics of the predicted value and the real value

空间特征	指标	真值	预测值	对比
全局自相关	Moran's I	$p = 0 < 0.05$ $z = 2055$	$p = 0 < 0.05$ $z = 2391$	一致
局部自相关	Getis G*	冷热分明	冷热分明	一致
分层异质性	q-统计	$p = 0 < 0.05$ $q = 0.5216$	$p = 0 < 0.05$ $q = 0.5217$	一致
点格局	NNI	$R = 0.45 < 1$	$R = 0.45 < 1$	一致

4 结 论

本研究通过构建 STLSTM 网络模型，将空间异质性融入地面沉降预测方法中，实现了高精度、高时效的大范围地面沉降时空预测。实验结果表明：

(1) 与经典的深度学习方法 (RNN 和 LSTM) 相比，准确性和处理时间略有提高。

(2) 基于 STLSTM 的沉降预测方法可以有效保持地面沉降的空间格局。通过对比预测前后的空间度量指标验证了该方法的有效性。

(3) 与其他物理方法和机器学习方法相比，STLSTM 在没有水文、地质等相关资料的条件下具有更高的参考价值，然而，在实际监测应用中，仍需结合降水、开采方式等多种因素来分析地面沉降。

虽然本研究获取的预训练模型仅适用于沧州地区的时空预测任务，但 STLSTM 方法对于其他区

域的沉降案例同样具有可行性。需要指出的是，这项预测分析工作是由 InSAR 形变数据所驱动，因此，InSAR 反演过程中的一些误差源会不可避免地影响实际预测精度。此外，地面沉降的空间异质性会随时间发生变化，如何准确捕捉地理相似性是一个值得研究的问题。在进一步的工作中，将考虑更多驱动因素来实现大区域的地面沉降预测。

参考文献 (References)

Ali M Z, Chu H J and Burbey T J. 2020. Mapping and predicting subsidence from spatio-temporal regression models of groundwater drawdown and subsidence observations. *Hydrogeology Journal*, 28(8): 2865-2876 [DOI: 10.1007/s10040-020-02211-0]

Cao L, Zhan Z B and Han Y. 2012. Deformation prediction and inversion of Shuibuya project based on artificial neural network and genetic algorithm. *Applied Mechanics and Materials*, 170-173: 2115-2118 [DOI: 10.4028/www.scientific.net/AMM.170-173.2115]

Davies D L and Bouldin D W. 1979. A cluster separation measure. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-1(2): 224-227 [DOI: 10.1109/TPAMI.1979.4766909]

Deng J, Dong W, Socher R, Li L J, Li K and Li F F. 2009. A large-scale hierarchical image database. *Proc. of IEEE Computer Vision and Pattern Recognition*, 248-255 [DOI: 10.1109/CVPR.2-009.5206848]

Deng M, Liu Q L, Li G Q and Huang J B. 2011. *Spatial Cluster Analysis and Application*. Beijing: Science Press: 75-76 (邓敏, 刘启亮, 李光强, 黄健柏. 2011. 空间聚类分析及应用. 北京: 科学出版社: 75-76)

Dunn J C. 1974. Well-separated clusters and optimal fuzzy partitions. *Jour-*

- nal of Cybernetics, 4(1): 95-104 [DOI: 10.1080/01969727408546059]
- Estivill-Castro V and Lee I. 2002. Multi-level clustering and its visualization for exploratory spatial analysis. *GeoInformatica*, 6(2): 123-152 [DOI: 10.1023/A:1015279009755]
- Fan Z L and Zhang Y H. 2019. Research progress on intelligent algorithms based ground subsidence prediction. *Geomatics and Spatial Information Technology*, 42(5): 183-188 (范泽琳, 张永红. 2019. 智能算法在地面沉降预测中的应用综述. *测绘与空间地理信息*, 42(5): 183-188) [DOI: 10.3969/j.issn.1672-5867.2019.05.054]
- Kingma D P and Ba J. 2014. Adam: A Method for Stochastic Optimization *Computer Science* [DOI: 10.48550/arXiv.1412.6980]
- Li L. 2014. Study on Forecasting Model of Land Subsidence and Its Application. Xi'an: Chang'an University (李丽. 2014. 地面沉降预测模型及其应用研究. 西安: 长安大学)
- Li S P. 2014. Deformation Analysis Based on Space-Time Series Model. Xi'an: Chang'an University (李世鹏. 2014. 基于时空序列模型的变形分析研究. 西安: 长安大学)
- Liao M S and Lin H. 2003. *Synthetic Aperture Radar Interferometry: Principle and Signal Processing*. Beijing: Surveying and Mapping Publishing House: 1-2 (廖明生, 林珏. 2003. 雷达干涉测量: 原理与信号处理基础. 北京: 测绘出版社: 1-2)
- Liu Q H, Zhang Y H, Deng M, Wu H A, Kang Y H and Wei J J. 2021. Time series prediction method of large-scale surface subsidence based on deep learning. *Acta Geodaetica et Cartographica Sinica*, 50(3): 396-404 (刘青豪, 张永红, 邓敏, 吴宏安, 康永辉, 魏钜杰. 2021. 大范围地表沉降时序深度学习预测法. *测绘学报*, 50(3): 396-404) [DOI: 10.11947/j.AGCS.2021.20200038]
- Murakami S, Yasuhara K and Suzuki K. 2005. Reliable land subsidence mapping by a geostatistical spatial interpolation procedure: Proceedings of the 16th International Conference on Soil Mechanics and Geotechnical Engineering. IOS Press: 2829-2832 [DOI: 10.3233/978-1-61499-656-9-2829]
- Ocak I and Seker S E. 2013. Calculation of surface settlements caused by EPBM tunneling using artificial neural network, SVM, and Gaussian processes. *Environmental Earth Sciences*, 70(3): 1263-1276 [DOI: 10.1007/s12665-012-2214-x]
- Pesaran M H. 2015. *Spatial panel econometrics*//Pesaran M H, ed. *Time Series and Panel Data Econometrics*. Oxford: Oxford University Press [DOI: 10.1093/acprof:oso/9780198736912.001.0001]
- Qin T C, Cheng G M and Wang H G. 2018. The latest progress of research on land subsidence abroad and its inspiration to China. *Geological Bulletin of China*, 37(2/3): 503-509 (秦同春, 程国明, 王海刚. 2018. 国际地面沉降研究进展的启示. *地质通报*, 37(2/3): 503-509) [DOI: 10.3969/j.issn.1671-2552.2018.02.028]
- Shahin M A, Maier H R and Jaksa M B. 2003. Settlement prediction of shallow foundations on granular soils using B-spline neurofuzzy models. *Computers and Geotechnics*, 30(8): 637-647 [DOI: 10.1016/j.compgeo.2003.09.004]
- Sun Y, Chen Y H, Wang X G and Tang X O. 2014. Deep learning face representation by joint identification-verification//Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal: MIT Press: 1988-1996
- Wang J F, Zhang T L and Fu B J. 2016. A measure of spatial stratified heterogeneity. *Ecological Indicators*, 67: 250-256 [DOI: 10.1016/j.ecolind.2016.02.052]
- Wang Z S and Deng K Z. 2011. Richards model of surface dynamic subsidence prediction in mining area. *Rock and Soil Mechanics*, 32(6): 1664-1668 (王正帅, 邓喀中. 2011. 采动区地表动态沉降预测的 Richards 模型. *岩土力学*, 32(6): 1664-1668) [DOI: 10.3969/j.issn.1000-7598.2011.06.012]
- Wu X D, Kumar V, Quinlan J R, Ghosh J, Yang Q, Motoda H, Mclachlan G J, Ng A, Liu B, Yu P S, Zhou Z H, Steinbach M, Hand D J and Steinberg D. 2008. Top 10 algorithms in data mining. *Knowledge and Information Systems*, 14(1): 1-37 [DOI: 10.1007/s10115-007-0114-2]
- Yang X X, Shi Y, Deng M and Tang J B. 2016. A new method of spatial outlier detection by considering multi-level thematic attribute constraints. *Geomatics and Information Science of Wuhan University*, 41(6): 810-817 (杨学习, 石岩, 邓敏, 唐建波. 2016. 一种基于多层次专题属性约束的空间异常探测方法. *武汉大学学报(信息科学版)*, 41(6): 810-817) [DOI: 10.13203/j.whugis.20140425]
- Zhang L, Zhang Y C and Luo Y H. 1998. *Theory and Practice of Geological Disaster Assessment*. Wuhan: Geological Publishing House: 1-2 (张梁, 张业成, 罗元华. 地质灾害灾情评估理论与实践. 武汉: 地质出版社: 1-2)
- Zhang Y H, Liu B, Wu H A, Cheng X and Kang Y H. 2018. Ground subsidence in Xiong'an new area from 2012 to 2016 monitored by InSAR technique. *Journal of Earth Sciences and Environment*, 40(5): 652-662 (张永红, 刘冰, 吴宏安, 程霞, 康永辉. 2018. 雄安新区 2012—2016 年地面沉降 InSAR 监测. *地球科学与环境学报*, 40(5): 652-662) [DOI: 10.3969/j.issn.1672-6561.2018.05.013]
- Zhang Z W. 2017. *Land Subsidence Monitoring Based on Time Series inSAR and Parameter Inversing of Groundwater-Subsidence Prediction Model*. Fuxin: Liaoning Technical University (张子文. 2017. 时序 InSAR 地面沉降监测与地下水—地面沉降预测模型参数反演. 阜新: 辽宁工程技术大学)
- Zhou F F. 2012. Interpretation of "National Land Subsidence Prevention and Control Plan 2011—2020" -interview with Tao Qingfa, deputy director of the department of geological environment, ministry of land and resources. *China Emergency Management*, (3): 56-59 (周飞飞. 2012. 《全国地面沉降防治规划(2011—2020年)》解读——访国土资源部地质环境司副司长陶庆法. *中国应急管理*, (3): 56-59)
- Zhou H Y, Wang Y J, Yan S Y, Li Y, Liu X X and Zhang F Y. 2018. Monitoring of recent ground surface subsidence in the Cangzhou region by the use of the InSAR time-series technique with multi-orbit Sentinel-1 TOPS imagery. *International Journal of Remote Sensing*, 39(21/22): 8113-8128 [DOI: 10.1080/01431161.2018.1482020]
- Zhou P, Liu C, Liu Q F, Dai L R and Jiang H. 2013. A cluster-based multiple deep neural networks method for large vocabulary continuous speech recognition//Proceedings of 2013 IEEE International Conference on Acoustics, Speech and Signal Processing.

- Vancouver: IEEE [DOI: 10.1109/ICASSP.2013.6638948]
- Zhou Q C, Shen H H, Zhao J and Xiong X L. 2019. Tunnel settlement prediction by transfer learning. *Journal of ICT Research and Applications*, 13(2): 118-132 [DOI: 10.5614/itbj.ict.res.appl.2019.13.2.3]
- Zhu J J, Li Z W and Hu J. 2017. Research progress and methods of InSAR for deformation monitoring. *Acta Geodaetica et Cartographica Sinica*, 46(10): 1717-1733 (朱建军, 李志伟, 胡俊. 2017. InSAR变形监测方法与研究进展. *测绘学报*, 46(10): 1717-1733) [DOI: 10.11947/j.AGCS.2017.20170350]
- Zhu J Y. 2014. *Research on Land Subsidence Mechanism and Prediction of Settlement in Cangzhou Area*. Beijing: China University of Geosciences (Beijing) (朱菊艳. 2014. 沧州地区地面沉降成因机理及沉降量预测研究. 北京: 中国地质大学(北京))

A spatio-temporal prediction method of large-scale ground subsidence considering spatial heterogeneity

LIU Qinghao^{1,2}, LIU Huimin¹, ZHANG Yonghong², WU Hongan², DENG Min¹

1. College of Earth Sciences and Information Physics, Central South University, Changsha 410083, China;

2. Chinese Academy of Surveying and Mapping, Beijing 100830, China

Abstract: The rapid and uneven ground subsidence has threatened human production activities, and high-precision subsidence prediction results are of great significance for the precise prevention and control of geological disasters. In order to grasp the evolution law of ground subsidence, a number of prediction studies have been carried out using field observation data or InSAR data. However, due to the existence of spatial heterogeneity, accurate prediction of large-scale ground subsidence is still a challenge.

In this study, a spatio-temporal prediction method considering spatial heterogeneity for large-scale ground subsidence STLSTM (Spatio-temporal Long Short-Term Memory) is proposed from a data-driven perspective. First, clustering is used to identify homogenous subregions in geographic space; then, in each subregion, a special Long Short-Term Memory (LSTM) networks are used to capture the nonlinearity features of local locations; Finally, the pre-trained network is used to quantitatively predict the ground subsidence at the future time.

In the experimental part, the sentinel-1 image data was used to compare the performance of STLSTM with the other 8 benchmark methods, and the effectiveness of STLSTM was analyzed using spatial statistical indicators. The results show that STLSTM achieves the highest prediction accuracy (71.4%) within 152 secs, and can effectively weaken the effect of spatial heterogeneity on large-scale subsidence prediction tasks.

In conclusion, this paper integrates the spatial heterogeneity processing strategy into the deep learning model, and large-scale subsidence prediction is realized with high precision and time efficiency.

Key words: remote sensing, ground subsidence, spatio-temporal prediction, heterogeneity, LSTM, InSAR

Supported by National Natural Science Foundation of China (No. 41730105, 41874014, 41771492)