

面向大坝变形监测的时空一体化预测算法

毛莺池 曹海 何进锋

(河海大学计算机与信息学院 南京 211100)

摘要 大坝变形的时空演变预测分析有助于大坝管理人员及时掌握大坝空间的整体变形状态。目前,大坝变形预测研究分为两个方面:1)通过仅对分布变形仪器部位进行时间序列预测,得出下一时刻的变形值(如 BP 神经网络);2)利用周围变形数据进行空间插值,得到当前时刻未分布仪器点的变形值。单独使用上述任何一种方法都无法利用历史变形数据预测下一时刻未分布仪器部位的变形状况。针对该问题,结合空间预测模型时空克里金方法(STKriging, STK)与神经网络模型即 BP 神经网络及门限循环神经网络(Gated Recurrent Unit, GRU)各自的优势,构造了一种新型时空序列预测算法(BP-STK-GRU),实现了对未分布监测仪器部位的变形值预测。主要步骤包括:1)GRU 优化单个测点的历史时间序列变形值;2)BP 拟合测点下一时刻数据的整体趋势;3)利用 STK 拟合 BP 预测结果的稳定部分;4)结合空间插值及 BP 空间整体预测值,得出未分布仪器点的变形值。实验结果表明,所提方法是有效的,并且在未测点的变形预测稳定性及精确度方面都有很好的表现。

关键词 大坝变形,时空预测,门限循环神经网络,BP 网络,空间插值

中图分类号 TP311 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2019.02.034

Spatio-Temporal Integrated Forecasting Algorithm for Dam Deformation

MAO Ying-chi CAO Hai HE Jin-feng

(College of Computer and Information, Hohai University, Nanjing 211100, China)

Abstract The analysis of the spatial-temporal evolution of dam deformation is conducive for managers to master the overall deformation of the dam's space. The existing predictive research on dam deformation can be divided into two parts. The first part is only making time series prediction for instrument part with distribution deformation, and the second part is using a method of spatial interpolation at the current moment to obtain unknown point's value of deformation. Both of these cannot use the historical deformation time series data to predict the deformation of the undistributed instrument. To solve this problem, combining the advantages of traditional spatial-temporal prediction model(STK) and neural network modelssuch such as BP and Gated Recurrent Unit (GRU), this paper constructed a spatio-temporal sequence prediction algorithm named BP-STK-GRU. The main steps are described as follows. Firstly, GRU optimizes the historical time series of individual measuring points. Secondly, BP fits the overall trend of spatio-temporal data at measuring points of the next moment. Thirdly, STK fits the stable parts of BP prediction results. Lastly, the spatial residual value and the overall BP space prediction are combined to get the deformation of the undistributed instrument. The experimental results show that the method is effective, and it has good performance in predicting the stability and accuracy of the deformation value of the unknown point.

Keywords Dam deformation, Spatio-Temporal prediction, Gated recurrent unit, BP network, Spatial interpolation

1 引言

大坝运行状态监测是大坝安全运行的重要环节,其中大坝变形监测尤为重要。目前常见的变形预测处理方法分为两个方面。1)利用空间插值得出未知点的变形值。空间预测模型包括空间自回归(SAR)、地理加权回归(GWR)、克里金(Kriging)以及贝叶斯最大嫡等地理统计学方法。如 JHA

等^[1]应用二维克里金法来研究普加山谷地下不同深度热能显示区域的温度分布。邱莉婷等^[2]构造了一种新型时空预测算法(SRA-MC),解决了坝体变形预测精确度不高的问题。时空克里金方法(STK)从克里金方法^[3]发展而来,如 STK 应用边坡变形监测^[4]。STK 算法要求数据满足二阶平稳性特点,计算复杂且耗时长。与 STK 模型类似,STIDW 模型从反距离插值(IDW)发展而来^[5]。现有的许多研究已经对比过克里金

到稿日期:2018-07-31 返修日期:2018-10-16 本文受“十三五”国家重点研发计划项目(2018YFC0407105),华能集团重点研发课题(HNKJ17-21)资助。

毛莺池(1976-),女,博士,教授,硕士生导师,CCF 会员,主要研究方向为分布式数据管理,E-mail:yingchimao@hhu.edu.cn(通信作者);曹海(1991-),男,硕士生,主要研究方向为数据挖掘、分布式计算;何进锋(1993-),男,硕士,主要研究方向为数据分析。

和 IDW 算法在空间预测上的表现,在大多数案例中,实验研究结果并不一致^[6]。2) 利用历史时间序列分析预测下一时刻的变形值,被广泛使用的时间序列预测方法包括指数平滑模型、状态空间模型以及自回归移动平均模型(Auto-Regressive Moving Average model, ARMA)等系列方法。ARMA 模型的主要研究对象是符合单变量、同方差条件的平稳序列。为处理非平稳时间序列, Asteriou 等^[7]提出了 ARIMA 模型。文献^[8]基于自回归移动平均模型(ARMA)对沈阳经济区各项经济指标建模并进行短期预测。STARMA 模型是在 ARMA 模型的基础上引入空间维度发展而来的,目的是借助空间相关性提高时间序列的预测精度,由于无法完全解释空间变异,因此对未知点的预测精度不高。

随着监测技术的改进,GNSS 被应用于大坝监测^[9],提高了分析数据的精度。在对未来时刻进行预测方面, Gourine 等^[10]对神经网络在大坝上的应用进行了分析。为提高预测精度, Su 等^[11]将基于小波的支持向量机应用于大坝变形监测。Dai 等^[12]利用随机森林模型建立大坝预测模型。除此之外,也存在其他应用于大坝变形预测的模型^[13-15]。但限于大坝的实际结构,变形仪器离散地分布在坝体内,且在时间与空间上都存在相关性,因此上述模型通过单独利用空间方式或时间的方式不能有效预测得到下一时刻未知点的变形情况。为了解决现有方法存在的问题,本文提出了一种时空一体化算法(BP-STK-GRU)。该方法考虑大坝在空间和时间两个维度上存在的依赖关系,利用 GRU^[16-17]优化历史数据,利用 BP 神经网络^[18-19]拟合大坝变形在时间维度上的整体变化趋势,利用空间插值 STK 拟合空间局部较为平稳的空间分布,即通过整体与局部相结合的方式预测未知点的变形情况。

2 研究问题

已知数量为 m 的位移传感器测点埋设在坝体内部,将每个传感器获取到的历史位移数据视作一个时间序列,则收集到的监测数据可以表示 m 条时间序列。图 1 中的数据组成了时间序列集合 $S = \{s_1, s_2, \dots, s_i\} (1 \leq i \leq m)$, S 表示所有测点的时间序列集合。 $s_i = \{x_1, x_2, \dots, x_j\}$ 表示单个测点 i 的时间序列监测数据,其中 $j \in \{t_1, t_2, \dots, t_n\}$ 。序列 s_i 中共有 n 个时间点, x_j 为第 j 个时间点的变形监测值。根据图 2,视大坝由众多空间点组成(已知测点及未知点),大坝连续变形监测数据可视为大坝内各点的时间序列,记作全集 A ,分布着监测仪器测点的历史时间序列已表示为 S ,则 S 是 A 的一个子集,表示为 $S \subseteq A$ 。




图 1 多测点时间序列分布

Fig. 1 Time series distribution of multi measuring points




图 2 变形测点的空间分布

Fig. 2 Spatial distribution of deformation measuring points

对图 2 中大坝所有已知测点变形数据随机选取一天进行莫兰指数(Moran's I)^[20]分析,得到莫兰指数为 0.32。具体公式如下:

$$I = \frac{n}{sum} \frac{\sum_{i=1}^n \sum_{j=1}^n \omega_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (1)$$

$$sum = \sum_{i=1}^n \sum_{j=1}^n \omega_{ij} \quad (2)$$

其中, n 为测点数量, ω_{ij} 代表观测点 i 与观测点 j 之间的权重, x_i, x_j 分别代表测点 i 和测点 j 的观测值, \bar{x} 为区域中观测值的平均数。式(2)中的 sum 为权重系数 ω_{ij} 的和。对时间跨度中的其他日期应用莫兰指数,发现莫兰指数在 0.35 左右徘徊,因此可得变形数据是空间相关的。

以大坝中的一条测点时间序列数据为例来说明测点数据存在时间相关性。自相关性方法(Auto Correlation Function, ACF)^[21]在时间序列建模中被用来检验同一条时间序列在不同时间点观测值之间的相关性。公式如下:

$$R(k) = \frac{E[(X_i - \mu_i)(X_{i+k} - \mu_{i+k})]}{\sigma^2} \quad (3)$$

其中, E 代表期望计算, k 表示时间步长, σ 表示标准差, X_i 代表在 i 时刻的时间观测值, X_{i+k} 代表在 $i+k$ 时刻的时间观测值, μ_i 和 μ_{i+k} 表示同一条时间序列中在 i 时刻和 $i+k$ 时刻的期望值。

基于时间相关性分析得出的时间自回归结果如图 3 所示。由图 3 可以看出,当前时间项位移值与延迟 180 天、360 天、540 天左右的位移值的相关性最大,但随着时间的推移,时间相关性缓慢减小。




图 3 时间自回归结果

Fig. 3 Results of time autoregression

通过时间相关性与空间相关性分析得出:大坝变形数据在时间和空间上都存在相关性,且在数据上存在非平稳性。

定义本文研究的问题为:在给定的时刻 $t (t < n)$,基于有限测点集合 S ,使用集合 S 中 $(1, \dots, t)$ 时刻的数据预测全集 A (S 及其补集 $C_A S$) 的点在 $t+1$ 时刻的变形值。问题描述如图 4 所示,当前时间点为 t_3 ,利用测点 s_1, s_2, s_3 在时刻 t_1, t_2, t_3 上的数据预测 s_1, s_2, s_3 空间周围某一位置在 t_4 时刻的变形值。




图 4 时空预测问题的示意图

Fig. 4 Schematic diagram of spatial-temporal prediction problem

3 BP-STK-GRU 算法

3.1 基于 GRU 的 BP 输入变量的优化

为使 BP 模型的空间整体趋势预测更准确,需保证 BP 模型输入测点时间序列变形值的趋势稳定性,即模型需要准确的历史时间序列特征。根据第 2 节中的时间相关性分析单个测点的时间序列,测点变形值在时间序列上的自相关性趋势明显。针对这一特征,实验采用了 GRU 循环神经网络来拟合 BP 模型输入测点时间序列的变形值。利用预测后的变形时间序列代替原始时间序列作为 BP 模型的输入值。

对于 GRU 来说,由前向传播计算重置门 r_t 、更新门 z_t 、当前缓存记忆内容 g_t 、当前时间的最终记忆 h_t 这 4 个向量的值。计算过程依次为:

$$r_t = \sigma(W_r x_t + U_r h_{t-1}) \quad (4)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (5)$$

$$g_t = \tanh(W_g (h_{t-1} \odot r_t) + x_t U_g) \quad (6)$$

$$h_t = y_t = h_{t-1} \odot (1 - z_t) + z_t \odot g_t \quad (7)$$

式(4)和式(5)中, σ 为 Sigmoid 激活函数;表示 x_t 时刻 t 的输入, h_{t-1} 保存 $t-1$ 时刻的记忆; W 和 U 分别代表 GRU 网络中的权重系数。其训练过程如图 5 所示。

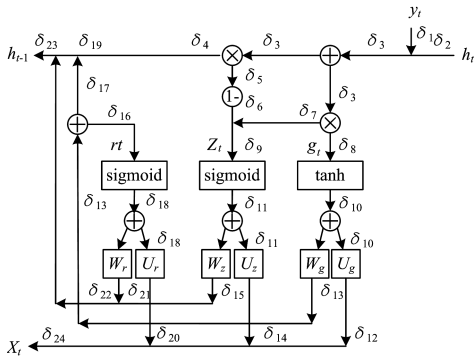


图 5 GRU 的反向传播过程

Fig. 5 Back propagation process of GRU

通过输入原始的测点变形时间序列进行训练,最终得到优化后的历史时间序列值。

3.2 BP 模型拟合整体时空趋势

BP 模型在大坝位移预测中使用历史观测值作为训练数据来训练网络,拟合时空趋势。模型的输入为大坝测点的三维坐标 (x, y, z) 和时间点节点,以及其他影响因子;输出为该测点对应的时间点的变形值,即位移值。在训练好的 BP 模型中输入未知点的空间位置及时间节点,得出其在整体时空上的趋势值。

3.3 STK 预测方法拟合局部趋势

去除上节 BP 神经网络拟合的整体趋势,得到局部平稳

的时空趋势。由于发生在限定区域内的测点观测值在空间和时间两个维度上都具有相关性,因此通过空间克里金构造时空半方差(Spatio-Temporal Variogram)函数,引入时间维度,发展时空克里金方法。时空半方差与时空协方差之间可以通过数学公式相互转换,由二阶平稳性可得转换式 $\gamma(h, \tau) = C(0, 0) - C(h, \tau)$,式中 h 代表空间维度的变化值, τ 代表时间维度的变化值。时空半方差函数可以简单直观地反映随机场中变量随时空变化的变异程度。

$\{Z(s, t); s \in R^d, t \in R\}$ 构成包含时间与空间维度的随机场, s 代表测点位置, t 代表某时间点, $Z(s, t)$ 代表点 s 在 t 时刻的属性值, d 代表空间维数,常见的有二维空间和三维空间。应用时空克里金算法的前提是数据要满足以下平稳条件(即二阶平稳):

$$i: E[Z(s, t)] = \mu \quad (8)$$

$$ii: \text{Cov}[Z(s+h, t+\tau), Z(s, t)] = \text{Cov}[Z(h, \tau), Z(0, 0)] =: C(h, \tau) \quad (9)$$

本文中式(8)表示测点属性值的期望保持不变,不随时间或地点的变化而变化。式(9)表示在实验研究区域中,总存在变形数据的协方差函数,协方差函数与具体空间坐标或时间坐标无关,与式(9)中的空间维度变化值 h 和时间维度的变化值 τ 相关。考虑时间因素的半方差函数的构造如下:

$$2\gamma(h, \tau) = \text{Var}[Z(s+h, t+\tau) - Z(s, t)] \quad (10)$$

时空半方差函数随着 $|h|$ 的增大而增大,当 $|h|$ 足够大时,时空半方差函数的值会位于高位且保持稳定, $\gamma(h, \tau) = C_0 + C$, C_0 为块金常数,用于衡量时空变量的随机性。估计半方差函数的公式为:

$$\hat{\gamma}(h, \tau) = \frac{1}{2|N(h, \tau)|} \sum_{N(h, \tau)} \{[Z(s+h, t+\tau) - Z(s, t)]^2\} \quad (11)$$

其中, $N(h, \tau) = \{(s_i, t_i), (s_j, t_j)\}, s_i - s_j = h, t_i - t_j = \tau$ 。

克里金插值 $\tilde{Z}(s_0) = \sum_{i=1}^N \lambda_i Z(s_i)$ 中 $\tilde{Z}(s_0)$ 表示点 s_0 处的预测值, λ_i 为公式系数,满足 $\min_{\lambda_i} \text{Var}(\tilde{Z}(s_0) - Z(s_0))$ 且 $\sum_{i=1}^N \lambda_i = 1$, 得到:

$$D[\tilde{Z}(s_0) - Z(s_0)] = - \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j \gamma(s_i, s_j) + 2 \sum_{i=1}^N \lambda_i \gamma(s_i, s_0) \quad (12)$$

求解式(12)的思路是将问题转化为求解最优化问题,最终可以得到最小方差,从而求得权重系数。利用权重系数,可得未知点的局部预测值。

3.4 整体与局部趋势方法的融合

将 3.2 节中的模型预测输出记作 $global_{pre}$, 将 3.3 节中的局部拟合结果记作 $local_{pre}$, 则有:

$$pre = global_{pre} + local_{pre} + e \quad (13)$$

其中, pre 为预测点的预测值; e 为模型自身存在的误差。

最终, BP-STK-GRU 的网络结构图如图 6 所示。图 6 中 GRU 作用在 BP 输入和整体趋势分离两个部分: GRU 优化输入主要排除了 BP 模型的误差; 在整体趋势分离部分, 得到局部稳定趋势后由 STK 算法做空间分析插值。最后, 结合两者结果得到最终的预测值。




图6 BP-STK-GRU 结构图

Fig. 6 Schematic diagram of BP-STK-GRU

4 实验与分析

4.1 实验数据

实验数据来源于某大坝实测数据,时间跨度为2012年6月1日—2016年9月6日,实验中对属于字符型的时间节点输入量进行转换。选取2012年6月1日以后的数据,使用相对于2012年6月1日的天数表示,如2015年6月1日与2012年6月1日相距1095天,以1095时间戳代替日期2015年6月1日。实验数据包括42个测点顺河向位移(mm)、环境变量、上下游水位、温度、降雨以及大坝的流量。结合工程经验对42个测点历史顺河向位移数据应用箱线图法去除异常值。使用3次样条插值法补充数据缺失值,得到用于实验分析的数据。

对42个变形监测仪器分别编号,依次为1号到42号。测试集选取C4-A25-IP-01, C4-A25-PL-06, C4-A29-IP-01, C4-A29-PL-05测点从2015年11月1日—2016年9月6日时间段的变形监测数据作为测试集,训练集为剔除上述4个测点外剩余的38个测点从2012年6月1日—2015年10月31日的变形监测数据(共41600条)。

4.2 实验对比及评价指标

对网络模型隐藏层数确定、局部空间插值方法、整体空间预测方法以及输入优化方法做了4组不同的实验对比分析,以比较不同算法及输入变量对算法性能的影响。具体数据如表1所列。

表1 实验对比

Table 1 Experimental comparison

BP模型	序列拟合		时空一体化
	BP	STIDW	BP
迭代训练	GRU	STK	BP-STK BP-STK-GRU

其中,时间序列拟合优化算法采用了BP与GRU进行对比。局部趋势算法采用STIDW与STK进行对比。时空一体化算法则将BP, BP-STK, BP-STK-GRU方法进行对比。

实验使用均方误差(MSE)、平均绝对误差(MAE)和平均绝对百分误差(MAPE)3个指标来验证模型的预测精确度,如式(14)~式(16)所示:

$$MSE = \frac{1}{N} \sum_{t=1}^N (\text{observed}_t - \text{predicted}_t)^2 \quad (14)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |\text{observed}_t - \text{predicted}_t| \quad (15)$$

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{\text{observed}_t - \text{predicted}_t}{\text{observed}_t} \right| \quad (16)$$

4.3 模型结构对比分析

BP易受网络中隐藏层神经元的影响,本节对不同隐含层的BP训练结果进行对比,找出适合本实验的最佳BP网络模型结构,训练输入为大坝测点的三维坐标(x, y, z)和时间,两者均为数值型变量。不同隐含层得到的不同评判指标结果如表2~表4所列。

表2 隐藏层中不同个数神经元下BP网络的MSE

Table 2 MSE of BP network with different unnumber of neurons in hidden layer

	(单位:%)			
	0	5	10	20
5	10.3945	6.3517	8.1520	7.7333
10	8.7324	4.9352	8.3675	10.0731
20	6.8562	7.1616	6.9916	9.9651
30	11.4211	11.2362	8.1374	6.1910
40	6.9396	12.0273	5.1013	8.7153
50	14.5793	6.6870	7.2182	7.4318
60	11.0438	5.1339	12.9815	12.8457
70	21.0747	11.8291	17.1037	8.8391

表2中在第一层隐含神经元节点数不变的情况下,随着第二层隐含神经元节点数的增加,MSE呈逐渐减小的趋势,但随着层数的不断增加,MAE值也逐渐增大。当神经元个数第一层为40,第二层为10,以及第一层为60,第二层为5时,表现得最为显著。

表3 隐藏层中不同个数神经元下BP网络的MAE

Table 3 MAE of BP network with different number of neurons in hidden layer

	(单位:%)			
	0	5	10	20
5	3.2240	2.5202	2.8551	2.7808
10	2.9550	2.2215	2.8926	3.1738
20	2.6184	2.6761	2.6441	3.1567
30	3.3795	3.3520	2.8526	2.48817
40	2.6343	3.4680	2.2586	2.9521
50	3.8182	2.5859	2.6866	2.7261
60	3.3232	2.2658	3.6029	3.5840
70	4.5907	3.4393	4.1356	2.9730

表3得出了在两隐含层中第二层隐含层神经元个数不变的情况下,增加第一层隐含层中神经元个数时MAE变得较小,当第二层神经元个数为10时,随着第一层神经元各个数的不断增加,MAE逐渐减小,当第一层神经元个数达到40时,MAE达到最小值2.2586。

表4 隐藏层中不同个数神经元下BP网络的MAPE

Table 4 MAPE of BP network with different number of neurons in hidden layer

	(单位:%)			
	0	5	10	20
5	0.1012	0.0901	0.1071	0.1110
10	0.1023	0.0886	0.1170	0.1116
20	0.1046	0.0993	0.1098	0.1169
30	0.1228	0.1114	0.1099	0.0928
40	0.1048	0.1131	0.0798	0.1072
50	0.1203	0.1064	0.1043	0.1017
60	0.1134	0.0821	0.1104	0.1157
70	0.1301	0.1048	0.1196	0.1137

表4中随着两层隐含层中神经元个数的增加,MAPE并没有发生较大的变化,都稳定在0.1左右,这是因为BP能够很好地拟合整体上的数据值。

综合以上 3 张表可知,应用两层隐含层,在个数分别为 40 和 10 的情况下,MAPE 值最小,为 0.0798,且 MSE 以及 MAE 也处于较低水平。最终 BP 网络选用 4 层网络结构,即输入层、两层隐含层、输出层,其中隐含层神经元个数分别为 40 和 10。

4.4 局部趋势算法的对比分析

由 BP 模型除去整体趋势后得到时空稳定部分,对时空稳定部分进行空间插值分析。实验中对比了 STIDW 与 STK 两种算法的时空预测精度,预测结果如表 5 所列。

表 5 STIDW 与 STK 的预测结果对比

Table 5 Comparison of prediction results between STIDW and STK

评价指标	MSE	MAE	MAPE
STIDW	0.4617	0.6794	0.1508
STK	0.2300	0.4796	0.1868

从表 5 中 3 种指标的对比可以得出,STIDW 的 MSE 为 0.4617,STK 算法的空间插值 MSE 为 0.2300。通过数值比较得出 STK 明显优于 STIDW。对于 MAE,同样可以得出 STK 的结果优于 STIDW。通过 MAPE 的对比可以看出,STIDW 优于 STK。综合上述 3 种指标可以得出,整体上,STK 的表现优于 STIDW,因此选取 STK 作为后续实验中拟局部稳定趋势的算法。

4.5 GRU 优化输入的对比分析

GRU 循环网络由于引入了环状结构,在处理时间序列时具有优势。为优化整体时空趋势模型的输入,选取 GRU 对原始输入数据进行优化。为验证 GRU 优化的有效性,实验中对 4 个测试集进行了 BP 与 GRU 时间序列数据的拟合对比实验。

经过多次训练后,测试集数据在 GRU 网络训练与测试迭代过程中的损失结果如图 7 所示。




图 7 GRU 训练和测试的损失结果

Fig.7 Loss of GRU training and testing

根据图 6,当迭代次数达到 5 次左右时,训练损失误差已经降低到 0.02;在训练达到 20 次时,训练误差已经趋于 0.01。从图中得出结论:GRU 在训练及测试过程中既没有过拟合,也没有欠拟合,证明了 GRU 模型优化的可行性。

图 8 和图 9 以测点 C4-A25-PL-06 为例分别给出了时间序列的预测结果,其中图 8 为 BP 网络时间序列拟合图,图 9 为 GRU 拟合图。

由图 8 可以得出如下结论:

1)根据图 8 中的训练预测值,与实测变形值对比分析训练集在训练数据上在 200,400,600,800,1000 时间点附近出现较大欠拟合的主要原因在于 BP 不能够很好地拟合具有周期性的时间序列。

2)对比分析测试部分的预测值与实测变形值可以看出,

BP 在预测时由于不能拟合周期趋势,出现了与真实值之间存在较大偏差的情况。




图 8 BP 网络的时间序列预测结果

Fig.8 Time series prediction results of BP network




图 9 GRU 时间序列预测结果

Fig.9 Time series prediction results of GRU

由图 9 可以得出如下结论:

1)在图 9 所示的 GRU 训练预测值与实测变形值对比分析过程中,训练集在 200,400,600,800,1000 时间戳左右时 GRU 能够准确地拟合其实际的变形值,其主要原因在于 GRU 循环网络引入了环状结构,在对时间序列的周期处理上具有优势。

2)对比分析测试部分的预测值与实测变形值可以看出,GRU 在预测时由于能够拟合周期趋势,虽然在时间戳 1200 处出现了拟合偏差,但在测试集上的整体表现良好。

由上述实验可知,相比于 BP 网络,GRU 网络对时间序列的预测更有优势。因此,选取 GRU 网络对单测点拟合的历史时间序列作为整体时空趋势模型的输入,这样能够更准确地去除数据整体空间趋势。

4.6 时空一体化算法的对比分析

本节以测试集点 C4-A25-IP-01 为例给出不同时空一体化算法下的预测结果,即不加入 STK 的时空预测、加入 STK 的时空预测、加入 GRU 优化后的时空预测。图 10 给出在仅使用 BP 网络的情况下的时空预测结果。图 11 给出在 BP 网络的基础上增加 STK 方法拟合的局部时空趋势(即 BP-STK 算法)并考虑残差的优化预测结果。图 12 给出引入 GRU 网络优化后的 BP-STK-GRU 算法的预测结果。




图 10 BP 网络的时空预测结果

Fig.10 Spatio-temporal prediction results of BP network

根据图 10 所示的预测结果可以得出, BP 在时间戳 1350 之后出现了较明显的欠拟合现象, 尤其在时间戳 1450 左右处欠拟合现象更为明显。此时, 根据数据误差曲线得出其误差接近于整体测试集误差的最高值 2 mm。




图 11 BP-STK 的时空预测结果

Fig. 11 Spatio-temporal prediction results of BP-STK

根据图 11 的预测结果可以得出, BP-STK 与 BP 相似, 在时间戳 1350 之后也出现了较明显的欠拟合现象; 同样地, 在时间戳 1450 左右处欠拟合现象更为明显, 且在周期预测上有较大偏差。此时, 根据数据误差曲线得出其误差接近于整体测试集误差的最高值 2 mm。




图 12 BP-STK-GRU 的时空预测结果

Fig. 12 Spatio-temporal prediction result of BP-STK-GRU

根据图 12 的预测结果可以得出, 优化后的 BP-STK-GRU 在时间戳 1400 之后才出现较为明显的欠拟合现象, 相比于 BP 及 BP-STK, 其出现欠拟合的时间戳节点较晚, 这是因为 GRU 的加入增强了模型对时间序列的拟合。此时, 根据数据误差曲线得出其误差在 1 mm 左右, 结果也优于 BP 和 BP-STK。

为了进一步验证 BP-STK-GRU 在空间预测上的合理性, 图 13—图 15 分别给出对应各方法测试集 C4-A25-IP-01 的误差分布区间。其中, 图 13 给出 BP 预测的空间误差结果分布, 图 14 给出 BP-STK 的误差结果分布, 图 15 给出 BP-STK-GRU 的误差结果分布。误差在 0.02~0.03 之间可视为 0 误差。




图 13 BP 的误差分布结果

Fig. 13 Error distribution of BP

从图 13 中可以看出有 20 个点落在 0 区域。但是, BP 中误差落在区域大于 1 的点的数量约为 100, 落在区间 -0.32~-0.05 的点最多。从误差的整体分布情况来看, 误差分布大

多落在误差较大的区域。




图 14 BP-STK 的误差分布

Fig. 14 Error distribution of BP-STK

根据图 14 中 BP-STK 的误差区间分布可以得出, 不同于 BP 误差分布, BP-STK 误差基本落在较小的区间, 这说明加入 STK 后, 大多数误差点落在 0.02~0.5 之间, 误差有所改善。但 BP-STK 也存在有一部较多点落在 1.0~1.4 之间。




图 15 BP-STK-GRU 的误差分布

Fig. 15 Error distribution of BP-STK-GRU

根据图 15 中 BP-STK-GRU 的误差区间分布图可以得出, 误差大部分落在以 0.3 为中心的两侧。虽然在区间 -0.4~-0.3 与区间 1.1~1.3 出现较小范围的误差点聚集现象, 但从整体的误差分布来看, BP-STK-GRU 的误差分布较为合理, 基本符合误差噪声的高斯分布。

对比 3 种方法的误差分布图可以看出, BP 是 3 种预测方法中 0 误差最多的, 但是其误差分布不均衡; BP-STK 与 BP 一样, 存在误差分布不均衡问题。但从图 14 中可以看出, 优化后的 BP-STK-GRU 算法的误差分布十分合理。

结束语 本文将大坝变形时空过程加以分解, 提出一种新的分别拟合总体时空趋势和残差时空趋势的时空插值预测算法(BP-STK-GRU)。利用 BP 神经网络拟合变形数据在时间尺度上的趋势, 利用 STK 拟合变形数据在空间尺度上的趋势。从结果上看, 该算法可以较精确地预测大坝未知点整体的变形趋势。

该实验场景是针对大坝变形监测进行设计的, 但实验的方法对于地理统计学的其他很多场景都具有适用性。在具体问题的应用上, 需要根据不同场景做调整, 如海平面温度预测、空气污染预测和矿物分布预测等。由于大坝监测点的位置固定, 在解决固定点时空序列预测问题后, 思考如果测点随时间不断移动, 如手持传感器、车载传感器等, 这里对时空序列的定义就发生了变化, 其不再是像大坝检测点一样具有固定空间坐标。此时, 测点坐标值随着时间的变化而变化, 为此时间序列的观测值中要加入移动的测点位置, 这在解决城市拥堵、车流预测等方面有很大的应用前景。

参考文献

[1] JHA S K, PUPPALA H. Assessment of subsurface temperature

- distribution from the gauged wells of Puga Valley, Ladakh[J]. *Geothermal Energy*, 2017, 5(1): 3-17.
- [2] QIU L T, SHEN Z Z, NIE B S. Deformation Prediction of Dam Based on Stepwise Regression Analysis-Markov Chain Model [J]. *Water Resources and Power*, 2014, 32(5): 51-55. (in Chinese)
邱莉婷, 沈振中, 聂柏松. 基于逐步回归分析——马尔可夫链模型的大坝变形预测[J]. *水电能源科学*, 2014, 32(5): 51-55.
- [3] LI S, SHU H, DONG L. Research and realization of Kriging interpolation based on spatial-temporal variogram [J]. *Computer Engineering and Applications*, 2011, 47(23): 25-26. (in Chinese)
李莎, 舒红, 董林. 基于时空变异函数的 Kriging 插值及实现[J]. *计算机工程与应用*, 2011, 47(23): 25-26.
- [4] WANG J M, ZHANG J, DENG Z B, et al. Slope deformation analysis with space-time Kriging interpolation method [J]. *Journal of China Coal Society*, 2014, 39(5): 874-879. (in Chinese)
王建民, 张锦, 邓增兵, 等. 时空 Kriging 插值在边坡变形监测中的应用[J]. *煤炭学报*, 2014, 39(5): 874-879.
- [5] LI L, REVESZ P. Interpolation methods for spatio-temporal geographic data [J]. *Computers Environment & Urban Systems*, 2004, 28(3): 201-227.
- [6] HAYHOE H, LAPEN D, ANDREWS C. Using weather indices to predict survival of winter wheat in a cool temperate environment [J]. *International Journal of Biometeorology*, 2003, 47(2): 62-72.
- [7] ASTERIOU D, HALL S G. ARIMA Models and the Box-Jenkins Methodology [M] // *Applied Econometrics* Palgrave MacMillan. 2011: 265-286.
- [8] HAN R L, TONG L J, ZHU S H, et al. The Coordinated Development of Economy and Environment Based on ARMA Model in Shenyang Economic Zone [J]. *Scientia Geographica Sinica*, 2014, 34(1): 32-39. (in Chinese)
韩瑞玲, 佟连军, 朱绍华, 等. 基于 ARMA 模型的沈阳经济区经济与环境协调发展研究[J]. *地理科学*, 2014, 34(1): 32-39.
- [9] BARZAGHI R, CAZZANIGA N E, DE GAETANI C I, et al. Estimating and Comparing Dam Deformation Using Classical and GNSS Techniques [J]. *Sensors*, 2018, 18(3): 756-766.
- [10] GOURINE B, KHELIFA S. Analysis of Dam Deformation Using Artificial Neural Networks Methods and Singular Spectrum Analysis [C] // *Euro-Mediterranean Conference for Environmental Integration*. Springer, Cham, 2017: 871-874.
- [11] SU H Z, LI X, YANG B B, et al. Wavelet support vector machine-based prediction model of dam deformation [J]. *Mechanical Systems and Signal Processing*, 2018, 110: 412-427.
- [12] DAI B, GU C, ZHAO E, et al. Statistical model optimized random forest regression model for concrete dam deformation monitoring [J]. *Structural Control & Health Monitoring*, 2018, 25(8): e2170.
- [13] ZHANG H L, FAN Z D. Nonlinear Monitoring Model of Concrete Dam Deformation Based on Improved PSO-ELM Algorithm [J]. *Water Resources & Power*, 2018, 36(1): 82-84. (in Chinese)
张海龙, 范振东. 基于改进 PSO-ELM 算法的混凝土坝变形非线性监控模型[J]. *水电能源科学*, 2018, 36(1): 82-84.
- [14] SU H Z, WEN Z P, YAN X Q, et al. Early-warning model of deformation safety for roller compacted concrete arch dam considering time-varying characteristics [J]. *Composite Structures*, 2018, 203: 373-381.
- [15] JIN S J, BAO T F, CHEN D H, et al. EMD decomposition method-based dam deformation prediction model and its application [J]. *Water Resources & Hydropower Engineering*, 2017, 48(12): 41-44. (in Chinese)
金盛杰, 包腾飞, 陈迪辉, 等. 基于 EMD 分解法的大坝变形预测模型及应用[J]. *水利水电技术*, 2017, 48(12): 41-44.
- [16] DEY R, SALEMT F M. Gate-variants of Gated Recurrent Unit (GRU) neural networks [C] // *International Midwest Symposium on Circuits and Systems*. IEEE, 2017: 1597-1600.
- [17] NIU Z W, YU Z Y, LI B, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network [J]. *Electric Power Automation Equipment*, 2018, 38(5): 36-42. (in Chinese)
牛哲文, 余泽远, 李波, 等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. *电力自动化设备*, 2018, 38(5): 36-42.
- [18] JI K. Evaluation of Mining Engineering technology innovation ability and application based on BP neural network [C] // *International Conference on Industrial Technology and Management*. IEEE, 2017: 55-59.
- [19] WANG J, SHI P, JIANG P, et al. Application of BP Neural Network Algorithm in Traditional Hydrological Model for Flood Forecasting [J]. *Water*, 2017, 9(1): 1-48.
- [20] SHEN C, LI C, SI Y. Spatio-temporal autocorrelation measures for nonstationary series: A new temporally detrended spatio-temporal Moran's index [J]. *Physics Letters A*, 2016, 380(1-2): 106-116.
- [21] SIDAK E V, SMIRNOV D A, BEZRUCHKO B P. Estimation of the coupling delay time from time series of self-oscillatory systems with allowance for the autocorrelation function of phase noise [J]. *Technical Physics Letters*, 2014, 40(10): 934-936.