



龙溪口防护堤变形在线监控模型构建与优化

白太贵，陈明春，胡峰瑞

(四川岷江港航电开发有限责任公司，四川 乐山 614000)

摘要：龙溪口库区防护堤的地质条件与运行环境复杂，如何利用原型监测数据实现其安全运行状态的在线监控是亟待解决的关键问题。针对传统监控模型在非线性特征的监测序列方面存在泛化性差、精度低等问题，基于长短时记忆神经网络(LSTM)算法，以水位、温度、时效为输入量，变形为输出量，构建防护堤LSTM在线变形监控模型。通过对比分析不同模型参数对精度的影响规律，揭示学习率>分块尺寸>最大迭代次数>隐藏层单元数的多参数敏感性规律，并提出相关参数的建议取值。工程应用表明，该模型精度高，适用性和稳定性强。

关键词：防护堤；在线监控；变形；LSTM；模型优化

中图分类号：U615；U656.2

文献标志码：A

文章编号：1002-4972(2023)10-0176-07

Construction and optimization of online monitoring model for deformation of protective embankment in Longxikou

BAI Taigui, CHEN Mingchun, HU Fengrui

(Sichuan Minjiang Port & Shipping & Electricity Power Development Co., Ltd., Leshan 614000, China)

Abstract: The geological conditions and operating environment of the protective embankment in the Longxikou reservoir area are complex, and how to use the original monitoring data to achieve online monitoring of its safe operation status is a key issue that needs to be urgently solved. In response to the problems of poor generalization and low accuracy in traditional monitoring models for monitoring sequences with strong nonlinear features, a long short-term memory (LSTM) online deformation monitoring model for the protective embankment based on LSTM algorithm is built, with water level, temperature, and time as inputs and deformation as outputs. By comparing and analyzing the influence of different model parameters on the accuracy, the multi-parameter sensitivity law of learning rate>block size>maximum number of iterations>number of hidden layer units is revealed, and the recommended values of relevant parameters are proposed. Engineering applications show that the model has high accuracy, strong applicability, and stability.

Keywords: protective embankment; online monitoring; deformation; LSTM; model optimization

岷江龙溪口航电枢纽工程位于岷江乐山—宜宾中下游河段，是规划的岷江乐山—宜宾 162 km 长河段航电梯级开发的第 4 级航电枢纽，包括下渡乡、黄旗坝、虎吼坝、机场坝、丁家坝、康家坝、孝姑镇、铁炉乡、五一坝、龙孔镇等 10 个防护区。库区防护堤结构形式多样，总长达 45.8 km，其长期稳定安全运行事关沿江两岸群众生命财产安全。

纵观国内外防护堤大型失事案例，其原因大多数是因为缺乏对防护堤变形的有效监管、可靠的配套安全监控与预警系统造成的。近年来，国家相继颁布了《智能航运发展指导意见》^[1]、《关于完善流域防洪工程体系的指导意见》^[2]等相关文件，明确提出了加快智慧航电建设等要求，这对防护堤在线监控提出了新的更高要求。变形是结构性态变化的直观

收稿日期：2023-06-07

作者简介：白太贵（1979—），男，高级工程师，从事港口航道和水利水电工程建设管理。

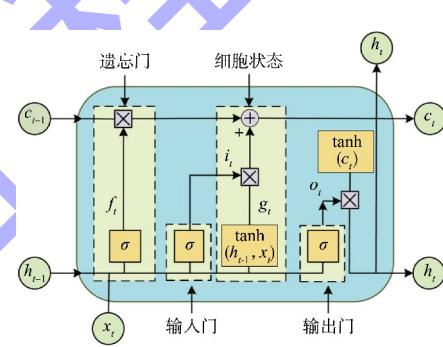
反映, 研究一种安全高效可靠的防护堤变形监控模型, 对提升防护堤运行安全在线监控与预警水平, 保障结构长期高效安全运行具有重要意义。

传统的统计回归模型、确定性模型和混合模型等方法在解析变形等效应量与水位、温度等环境量间的复杂非线性关系时, 存在精度不高、易受监测序列类型影响等不足^[3]。近年来, 随着机器学习算法的不断发展与成熟, 其在变形监控模型中的应用已成为当前研究的热点^[4], 如支持向量机(SVM)^[5]、相关向量机(RVM)^[6]、回归树(RT)^[7]、随机森林(RF)^[8]、极限学习机(ELM)^[9]、卷积神经网络(CNN)^[10]等智能算法以监测数据为训练集, 通过自学习、自修正、自适应的方式调整模型参数, 提高模型的拟合预测精度, 具有较强的自主学习能力与非线性数据挖掘能力, 逐渐广泛应用于水工安全监控领域, 一定程度上提高了水工监控模型的智能化水平^[11]。上述机器学习算法或其改进方法对于监控模型优化虽然取得了较好的效果, 但仍存在一些缺陷, 如神经网络模型存在泛化能力不足、收敛速度慢、模型训练过拟合等问题^[12]。长短时记忆神经网络(LSTM)是循环神经网络(RNN)的优势变体, 具有较好的自学习与时序数据处理能力, 在数据拟合、预测分析方面具有显著优势, 能够兼顾传递自然过程中的长期和短期记忆特征, 可以更好地挖掘非线性数据集之间的潜在联系, 在数据拟合、预测分析中具有显著优势。本文基于LSTM理论构建防护堤变形监控模型, 并针对防护堤安全监测序列类型繁复、非线性特性环境量响应明显的特征, 依托龙溪口航电枢纽保护区数据序列深入分析最大迭代次数、学习率、分块尺寸、隐藏层单元数等关键模型参数在不同类型和长度的数据序

列下所受到的影响, 并验证模型的精度和适用性。

1 长短时记忆神经网络的主要影响参数

LSTM是1997年Hochreiter等^[13]在RNN的基础上共同提出的, 其能有效避免模型训练中出现梯度消失和爆炸等问题, 较好地弥补了传统RNN模型的不足, 能更好地适用于大数据样本监测序列且能更好地处理非线性特征的序列。LSTM模型的核心在于运用门的概念控制状态 c_t 。在任意 t 时刻, LSTM的输入由 t 时刻细胞网络结构的输入值 x_t 、前一时刻 $t-1$ 的输出值 h_{t-1} 与单元状态 c_{t-1} 组成; 输出则由 t 时刻神经网络的输出值 h_t 和 t 时刻的单元状态 c_t 组成。LSTM神经元记忆网络结构见图1。



注: f_t 为遗忘门过滤值, σ 为激活函数, x_t 为 t 时刻的输入值, i_t 为输入门计算值, g_t 为候选值, o_t 为输出门值。

图 1 LSTM 神经元记忆网络结构

LSTM模型参数较为复杂, 包含学习率、分块尺寸、最大迭代次数、隐藏层单元数、丢弃率、输入层神经元数、运行环境选择、梯度阈值、全连接层数等, 其中重要参数的意义及其取值见表1。大量的试验与工程实例表明, LSTM模型的具体参数有可能受到不同工程、不同因素的影响, 从而改变最适宜的取值范围。因此, 有必要对具体的工程参数进行确定性分析。

表 1 LSTM 模型重要参数意义及其取值

参数	意义	作用	取值
学习率	代表模型自我学习、自我适应的能力	直接影响建模好坏与精度	0.000 1~0.1
分块尺寸	将数据集分割成小块的样本长度	直接影响模型的计算效率, 且成正比关系	1~40
最大迭代次数	训练样本数据的次数上限	限制训练次数, 适配神经网络中的权重系数与偏置项更新	1~1 000
隐藏层单元数	隐藏层及神经单元数量	直接影响模型的网络性能	1~500
丢弃率	作为层之间连接关系的一个破坏值	消除层之间的神经元连接, 避免出现过拟合现象	0.5
输入层神经元数	待处理数据中输入变量的数量	将待处理数据的数量进行量化	待处理数据输入变量数

2 防护堤变形监控模型构建

基于 LSTM 的防护堤变形监控模型构建流程如图 2 所示(图中 Attention 为 LSTM 中的注意力机制; Dropout 为丢弃层; $[1, T]$ 为变形序列时间区间, t 为该区间中任意时间点; $\alpha_i (i=1, 2, \dots, t, \dots, T)$ 为不同时刻的相似度; α 为所有 α_i 共同计算的向量), 具体步骤如下。

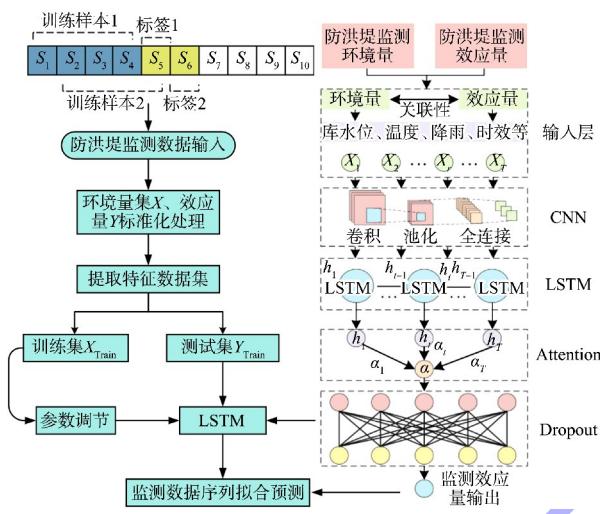


图 2 LSTM 变形监控模型构建流程

1) 数据的标准化处理。将防护堤运行安全监测中的气温、降雨、河道水位等环境量集 $X = \{X_1, X_2, \dots, X_m\}$, 以及变形监测效应量集 $Y = \{Y_1, Y_2, \dots, Y_m\}$ 都采用式(1)进行标准化处理。

$$X^* = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (i=1, 2, \dots, m) \quad (1)$$

式中: X^* 为标准化处理后的值, X_{\max} 、 X_{\min} 分别为环境量(效应量)实测值的最大值、最小值。

2) 确定适宜的输入变量。输入变量的数量决定了输入层的神经元数量, 输入适宜的自变量因子能有效提高模型的训练精度和预测效果, 还能大幅降低计算时间。防护堤变形是结构特点、材料特性、基础条件等内部因素和河道水位、气温、降雨等环境因素综合作用的结果, 因此建立变形 LSTM 模型时, 输入变量主要考虑水位、温度、时效等环境量分量。

3) 优化模型参数。LSTM 模型中可优化的参数较多, 包括学习率、隐藏层神经元个数、训练次数等。参数取值对 LSTM 模型的精度和计算效

率均有较大影响, 应进行优化。

4) 计算与输出。采用优化后的模型参数进行防护堤变形、渗流等监测数据序列的拟合与预测, 输出相应日期的预测数据, 并与实测数据对比实现在线监控。

3 LSTM 模型参数优化分析

影响 LSTM 模型精度的参数相对较多, 本文选取的参数允许设置范围较大, 且对模型精度影响较大的参数进行优化, 主要包括学习率、最大迭代次数、分块尺寸和隐藏层单元数。

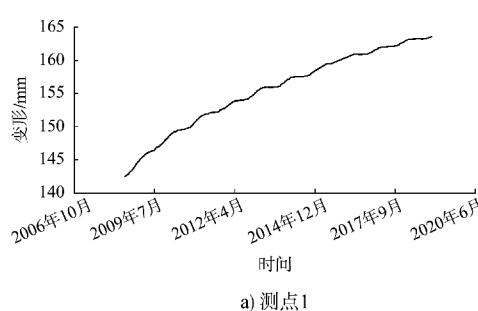
为保证模型优化参数的合理性和适用性, 本文结合航电枢纽工程防护堤安全监测数据的特征, 设置趋势型、周期型、无规律型 3 种数据类型和短序列、中等序列、长序列 3 种长度的监测数据序列, 采用单一变量控制法分析不同参数对模型精度的影响, 其序列特性、过程线分别见表 2、图 3。本文采用可决系数 R^2 评估监控模型的精度。 R^2 取值通常在 0~1, 且值越大表示模型的拟合效果越优, 其计算公式为:

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (2)$$

式中: y_i 为观测数据值, \bar{y} 为观测数据平均值, \hat{y}_i 为拟合数据值。

表 2 分析采用的数据序列特性

测点	数据序列特征	序列长度	监测数据量
1	趋势型	中等	279
2	周期型	长	356
3		中等	500
4	无规律型	短	250
5			50



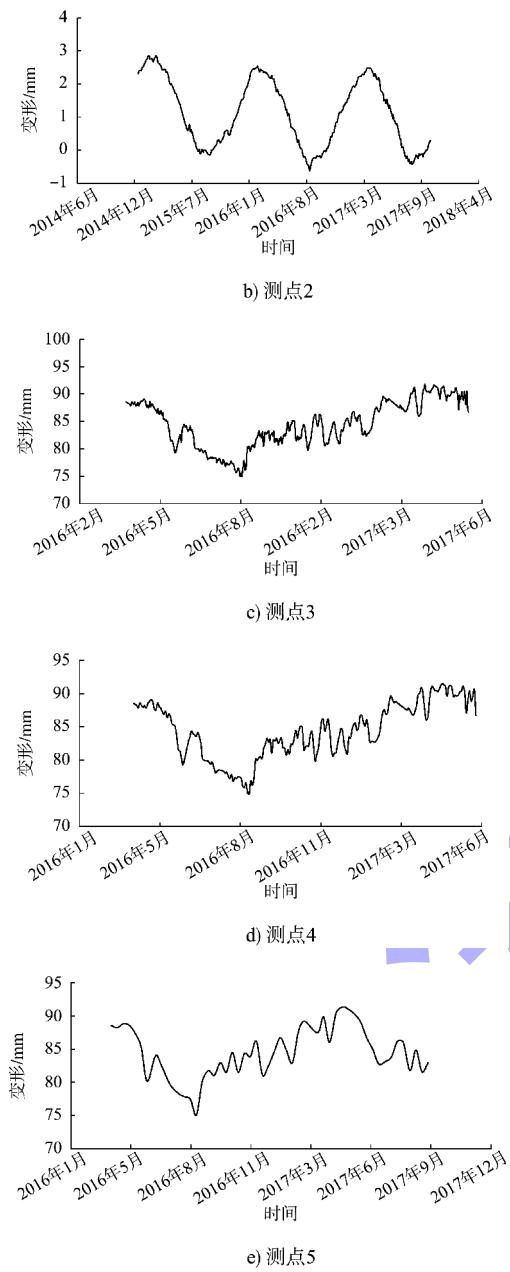


图 3 不同特性的监测序列

3.1 模型参数优化分析

3.1.1 学习率

学习率是 LSTM 模型参数中最重要的影响因子, 能够直接决定模型自我学习、自我适应的能力。合理的学习率可明显提升模型精度, 并保持计算时间、收敛速度良好; 不合理的学习率可能导致模型直接崩溃。为分析学习率对模型精度和计算效率的影响, 参考类似工程设置分块尺寸、隐藏层单元数和最大迭代次数分别为 20、200、100, 并在 0.000 1~0.100 0 范围内等概率(均匀分布)抽取 20 种不同学习率进行计算, 结果如图 4、

5 所示。可以看出, 学习率对模型精度的影响较大, 学习率取值过大导致模型失效; 学习率在 0.000 1~0.010 0 取值时, 各种类型及各种长度的数据序列的模型精度较高, 模型的适用性较高; 随学习率的增大, 不同数据类型的模型精度差异较大, 且数据序列越长, 模型精度降低越快。因此, 建议学习率在 0.005~0.010 范围内取值, 本文防护堤变形监控模型学习率取 0.005。

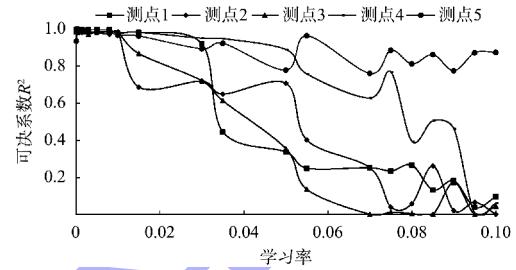


图 4 各测点学习率与可决系数的模型训练关系

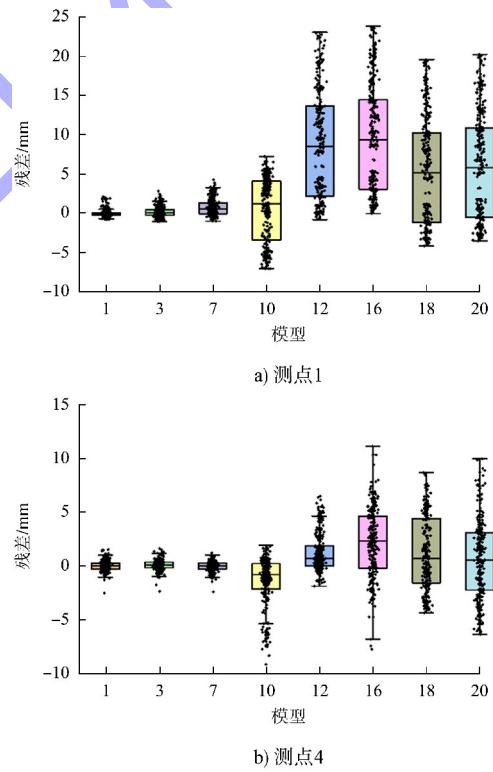


图 5 不同学习率下典型测点模型残差分布箱形图

3.1.2 最大迭代次数

最大迭代次数指一次建模中数据应用最大的训练次数。在模型一次训练过程中, 不同监测项目对应的最大迭代次数差异性较大。最大迭代次数设置越高, 神经网络中的权重系数和偏置项的更新也相应增加, 需要传递更多次训练集数据,

模型计算效率也越低。因此，针对不同监测类型的数据，设置合理的最大迭代次数对提高模型精度和计算效率均有重要影响。

为分析最大迭代次数对模型精度和计算效率的影响，结合前述学习率的优化结果，设置分块尺寸、隐藏层单元数和学习率分别为 20、200、0.005，并在 10~1 000 范围内等概率(均匀分布)抽取设置 20 种不同最大迭代次数进行计算，结果见图 6、7。可以看出，最大迭代次数对模型精度的影响不大，主要影响建模的耗时，即最大迭代次数越大，模型耗时越长。考虑到迭代次数过小时，模型精度有较明显的波动，因此建议最大迭代次数在 100~300 范围内取值。

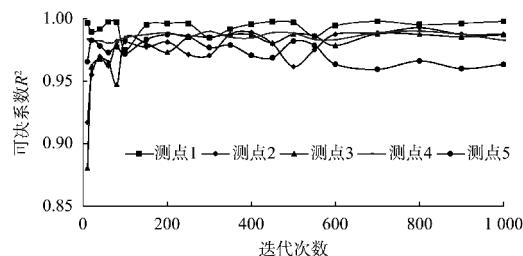
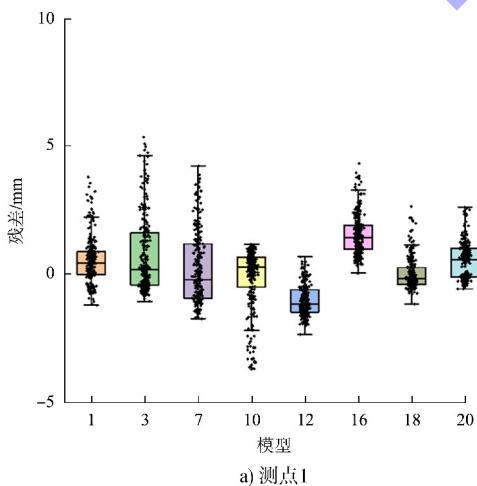
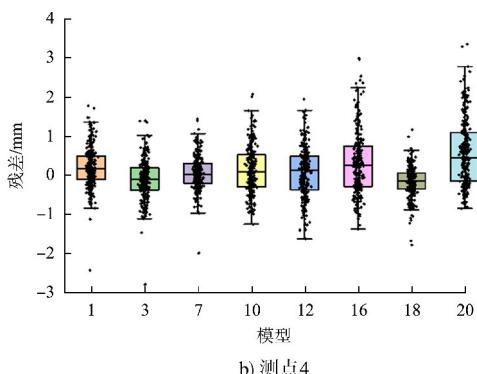


图 6 各测点最大迭代次数与可决系数的模型训练关系



a) 测点1



b) 测点4

图 7 不同最大迭代次数下典型测点模型残差分布箱形图

3.1.3 分块尺寸

LSTM 模型学习需要的数据量非常大，为保证顺利计算，常将数据集分割成小块，再以小块的形式读入内存中，并更新模型网络中的参数权重。分块尺寸也称最小批量，对模型的精度和训练时间都有一定的影响。采用较大的分块尺寸，学习速度快，但过程不稳定，且分类精度差异较大，过大的分块尺寸会使相邻块间的梯度无显著区别，易陷入局部最小；较小的分块尺寸会使学习速度大幅降低，且过小的分块尺寸容易造成相邻块间的差异过大而出现较大严重的震荡现象，不利于模型收敛。分块尺寸一般的选取范围为 10~40。为分析分块尺寸对模型精度和计算效率的影响，结合前述结果，设置隐藏层单元数、最大迭代次数、学习率分别为 200、100、0.005，并在 10~40 范围内等概率(均匀分布)抽取 20 种不同分块尺寸进行计算，结果见图 8、9。可以看出，分块尺寸对模型的精度影响并不大，但是对耗时的影响明显，分块尺寸越小，耗时越长。考虑到较小的分块会导致建模耗时大，且精度也相对下降，因此建议分块尺寸在 10~20 范围内取值。

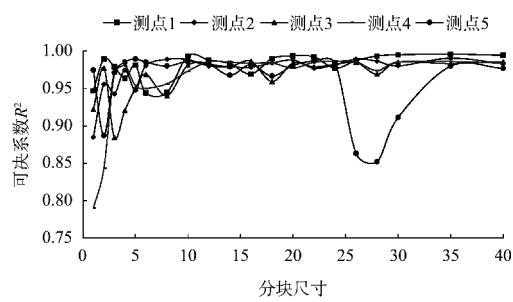
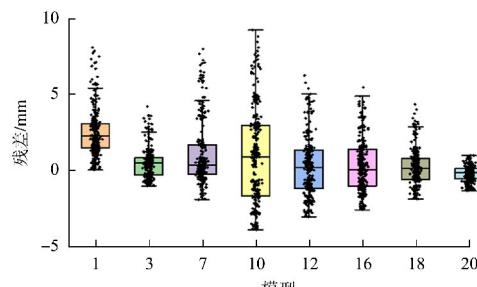


图 8 各测点分块尺寸与可决系数的模型训练关系



a) 测点1

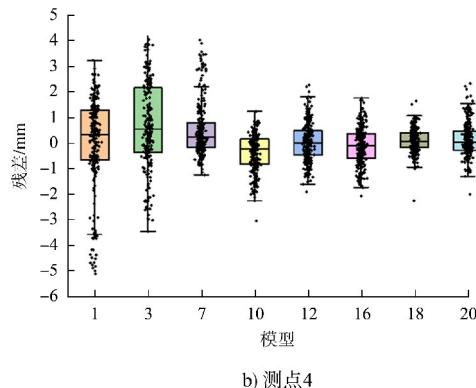


图 9 不同分块尺寸下典型测点模型残差分布箱形图

3.1.4 隐藏层单元数

隐藏层单元数对 LSTM 模型网络性能影响显著, 若隐藏层神经元数过小, 可能使模型无法正常训练; 过大的隐藏层神经元数则会导致残留噪声难以消除、网络训练速度极慢等问题, 易出现过拟合现象。选择适宜的隐藏层单元数能使模型精度大幅提升, 其选取范围一般为 10~500。为分析隐藏层单元数对模型精度和计算效率的影响, 采用前述优化结果, 将分块尺寸、最大迭代次数、学习率分别设置为 20、100、0.005, 并在 10~500 范围内等概率(均匀分布)抽取 20 种不同隐藏层单元数进行计算, 结果见图 10、11。可以看出, 隐藏层单元数对模型精度和耗时影响均相对较小, 考虑到隐藏层单元数超过 200 时, 模型精度会出现一定的波动, 同时为避免取值过小而导致模型无法正常训练, 因此建议隐藏层单元数在 100~200 范围内取值。

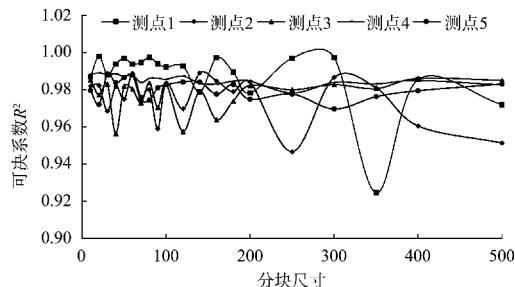


图 10 各测点隐藏层单元数与可决系数的模型训练关系

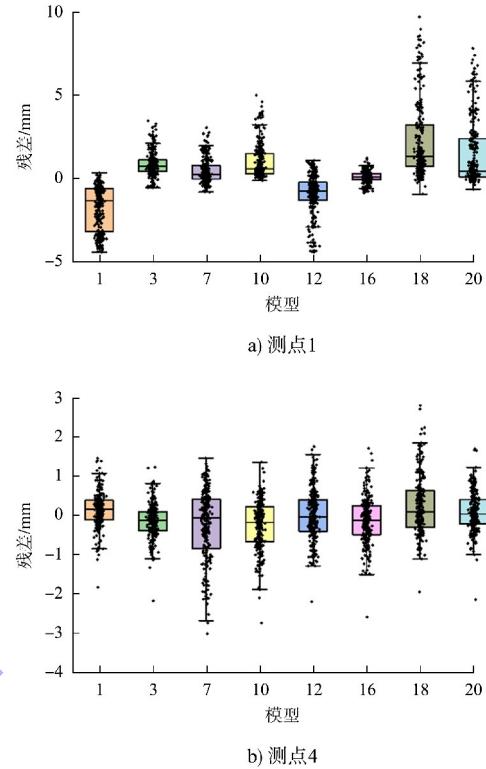


图 11 不同隐藏层单元数下典型测点模型残差分布箱形图

由以上研究可知, LSTM 模型精度与网络参数结构存在紧密联系, 参数选取对模型精度影响较大, 且针对不同类型测点, 其最优的网络参数取值差异性较大。综合考虑模型精度的稳定性和计算效率, 龙溪口防护堤运行安全 LSTM 监控模型的学习率、最大迭代次数、分块尺寸、隐藏层单元数建议分别取 0.005、100、20、150。

3.2 模型精度校验

为进一步验证 LSTM 模型的精度, 仍采用表 2 中的 5 个典型测值序列, 分别构建 LSTM 模型和逐步回归模型, 并采用可决系数 R^2 、均方根误差 E_{RMS} 和平均绝对偏差 E_{MA} 3 个指标综合评价模型的精度。学习率、最大迭代次数、分块尺寸、隐藏层单元数分别取 0.005、100、20、150, 计算 LSTM 模型和逐步回归模型精度评价指标, 见表 3 和图 12。可以看出, 对趋势性和周期性数据序列, 逐步回归法和 LSTM 模型的精度和拟合效果基本

相当,但对无规律性数据序列,LSTM 模型的精度和拟合效果均明显优于逐步回归模型,特别是无规律型的短数据序列提升更为明显,说明 LSTM 模型的适用性和稳定性均较高,可作为防护堤运行安全监控模型。

表 3 各测点逐步回归、LSTM 模型应用效果评价指标结果对比

测点	逐步回归模型评价			LSTM 模型评价			
	指标的计算结果			指标的计算结果			
	R^2	E_{RMS}	E_{MA}		R^2	E_{RMS}	E_{MA}
1	0.998	0.33	0.26	0.997	0.86	0.63	
2	0.966	0.19	0.16	0.981	0.14	0.11	
3	0.816	1.64	1.32	0.986	0.58	0.44	
4	0.811	1.67	1.34	0.984	0.87	0.71	
5	0.789	1.73	1.37	0.980	0.54	0.44	

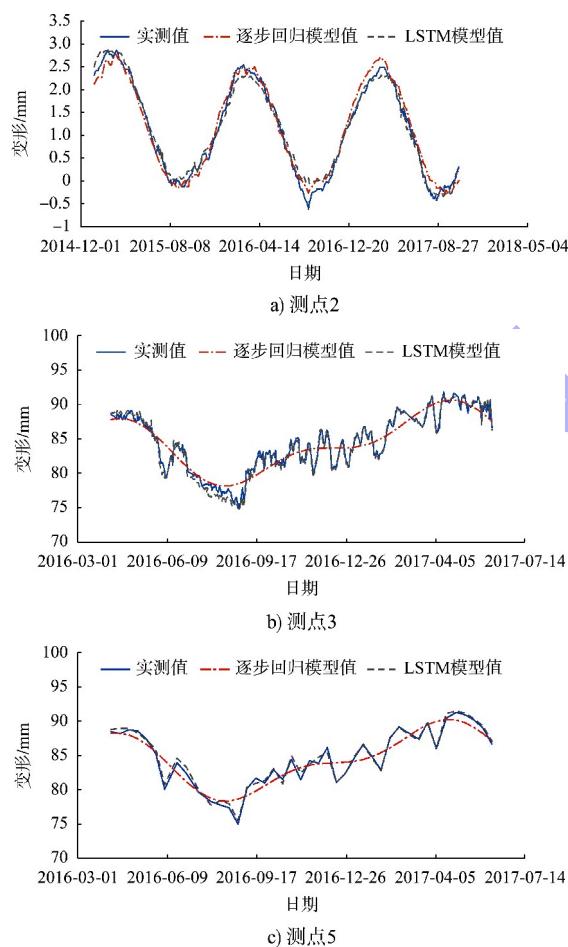


图 12 不同测点逐步回归、LSTM 模型拟合效果对比

4 结论

1) 基于 LSTM 的防护堤变形模型中,最大迭代次数、学习率、隐藏层单元数、分块尺寸 4 项参数的选取对于模型精度影响显著,通过参数敏感性

分析得出,敏感性排序为学习率>分块尺寸>最大迭代次数>隐藏层单元数,其对应建议值分别为 0.005、20、100 和 150。

2) 工程校验表明,本文提出的 LSTM 变形监控模型精度较高,且表现出较好的适用性和稳定性。研究成果有助于提高防护堤运行安全在线监控与预警水平。

参考文献:

- [1] 交通运输部,中央网信办,国家发展改革委,等.智能航运发展指导意见[A].北京:交通运输部,2019.
- [2] 水利部.关于完善流域防洪工程体系的指导意见[A].北京:水利部,2021.
- [3] 吴中如,陈波.大坝变形监控模型发展回眸[J].现代测绘,2016,39(5):1-3,8.
- [4] 袁冬阳,顾冲时,顾昊.严寒地区混凝土重力坝变形行为分析与预测模型[J].水力学报,2022,53(6):733-746.
- [5] 李润鸣,包腾飞,卢远富,等.基于 GAMP-SO-SVM 的大坝变形监控模型[J].三峡大学学报(自然科学版),2015,37(6):42-46.
- [6] 胡雨菡,包腾飞,朱征,等.基于 IABC-FCM-RVM 算法的拱坝变形预测模型[J].武汉大学学报(工学版),2020,53(12):1055-1064.
- [7] SALAZAR F, TOLEDO M A, ONATE E, et al. Interpretation of dam deformation and leakage with boosted regression trees [J]. Engineering structures, 2016, 119: 230-251.
- [8] 罗浩,郭盛勇,包为民.拱坝变形监测预报的随机森林模型及应用[J].南水北调与水利科技,2016,14(6):116-121,158.
- [9] 曹恩华,包腾飞,胡绍沛,等.基于变量筛选优化极限学习机的混凝土坝变形预测模型[J].长江科学院院报,2022,39(7):59-65.
- [10] 翟征秋,程林,宋效第,等.基于卷积神经网络的防坡堤施工沉降预测[J].水运工程,2021(8):202-206,219.
- [11] 魏博文,罗绍杨,徐富刚,等.基于监测时序分解再重构的混凝土拱坝位移预测组合模型[J].工程科学与技术,2022,54(5):51-63.
- [12] 黄梦婧,杨海浪.基于 PSO 的 SVM-ARIMA 大坝安全监控模型[J].人民黄河,2018,40(8):149-151,156.
- [13] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural computation, 1997, 9(8):1735-1780.

(本文编辑 王璁)