

考虑变量滞后性的 LSTM 大坝变形 安全监控预测模型

郁怀光¹, 顾冬¹, 徐乐意¹, 侯回位^{2,3}

(1. 南京市水利规划设计院股份有限公司, 江苏南京 210000; 2. 西北勘测设计研究院有限公司, 陕西西安 710065; 3. 河海大学水利水电学院, 江苏南京 210098)

摘要: 为进一步提升大坝变形的预测精度, 充分反映外部环境变量对大坝变形影响的滞后性, 考虑影响大坝变形的变量时间滞后效应, 利用长短期记忆 (long short-term memory, LSTM) 网络算法, 提出一种考虑变量滞后性的改进 LSTM 的大坝变形预测模型。将输入数据分为通过 LSTM 存储块的延迟变量和不通过存储块的无延迟变量, 使模型在物理解释上更合理; 为提高预测模型的非线性表达能力, 增加第二个隐藏层, 使时间效应量等无延迟变量在最后一个时间步可直接使用, 不需进行复杂的转换形成原始输入时所需的子序列; 结合具体案例计算验证改进模型的可靠度和精度。结果表明: 改进 LSTM 模型的平均绝对误差 (MAE)、均方误差 (MSE) 较 LSTM 模型分别降低了 11.94%, 25.60%, 具有更高的预测精度; 改进模型的预测残差正负分布范围较 LSTM 模型小, 预测值整体在实测值附近变化。改进 LSTM 模型的预测结果优于 LSTM 模型, 能更合理地对大坝变形进行预测。

关键词: 大坝; 变形预测; 长短期记忆网络 (LSTM); 安全监控

中图分类号: TV 642 **文献标志码:** A **doi:** 10.12415/j.issn.1671-7872.22245



Prediction Model of LSTM Dam Deformation Safety Monitoring Considering Variable Hysteresis

YU Huaiguang¹, GU Dong¹, XU Leyi¹, HOU Huiwei^{2,3}

(1. Nanjing Water Conservancy Planning and Design Institute Co., Ltd, Nanjing 210000, China; 2. Northwest Engineering Co., Ltd, Xi'an 710065, China; 3. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China)

Abstract: To further improve the prediction accuracy of dam deformation, fully reflecting the hysteresis of the impact of external environmental variables on dam deformation, and considering the time lag effect of variables affecting dam deformation, a modified LSTM (long short-term memory) dam deformation prediction model was proposed by using the LSTM algorithm. The input data was divided into delay variables passing through LSTM storage block and non delay variables not passing through storage block, which made the model more reasonable in physical interpretation. In order to improve the nonlinear expression ability of the prediction model, a second hidden layer was added, so that the time effect and other non delayed variables could be directly used in the last time step without complex transformation to form the subsequence required for the original input. The reliability and accuracy

收稿日期: 2022-09-27

基金项目: 国家重点研发计划 (2018YFC1508603)

作者简介: 郁怀光 (1991—), 男, 江苏徐州人, 工程师, 主要研究方向为水利工程设计和大坝安全管理。

引文格式: 郁怀光, 顾冬, 徐乐意, 等. 考虑变量滞后性的 LSTM 大坝变形安全监控预测模型 [J]. 安徽工业大学学报 (自然科学版), 2023, 40(1): 89-96.

of the improved model were verified by calculating a specific case. The results show that the mean absolute error (MAE) and mean square error (MSE) of the improved LSTM model are 11.94% and 25.60% lower than those of the LSTM model, respectively, and have higher prediction accuracy. The positive and negative distribution range of the prediction residuals of the improved model is smaller than that of the LSTM model, and the prediction values generally change near the measured values, which can more reasonably predict the dam deformation. The prediction results of the improved LSTM model are better than those of LSTM model, which can more reasonably predict the dam deformation.

Keywords: dam; prediction of deformation; long short-term memory; safety monitoring

新中国成立后,我国在水利领域的投入进入了高潮,建设的大坝超过 10 万座,这些大坝为国民经济的稳定发展提供了基础性保障^[1]。为监测大坝服役的健康状态,一般在大坝的关键部位埋设监测仪器,大坝位移是最直接反映大坝运行状况的指标之一^[2]。影响大坝变形的变量因素较多,如上下游水位、气温等,变量的时间序列具有非平稳、非线性特征。因此,通过监测数据预测大坝的位移具有一定的难度。为此,彭圣军^[3]提出了基于回归分析法的统计模型,该模型原理较清晰,但无法充分挖掘外部环境变量对大坝变形的滞后性影响,预测精度也有所局限。为提高统计模型的精度,研究者采用神经网络、支持向量机等算法^[4-6]进行数据库的训练,但神经网络预测复杂时间序列易出现过拟合的现象;支持向量机能在一定程度上可克服神经网络的上述问题,但存在复杂情况下求解核函数困难、计算时间较长等难题。此外,上述模型在挖掘外部环境变量对大坝变形的时间滞后性影响方面仍不够完善。

为解决上述算法存在的难题,Tian 等^[7]利用长短期记忆(long short-term memory, LSTM)网络算法,通过引入常量误差传输(constant error carousel, CEC)单元,将传统神经网络的简单节点改进为存储块,避免了传统模型在学习时长跨度大的数据时出现梯度消失和爆炸的问题。该算法不仅提升了训练预测的精度,还可通过设置门单元减少存储信息和已输出信息的扰动。由于 LSTM 学习处理长时间跨度数据的优越性,其在大坝变形预测中得到了较多的应用^[8-9]。然而, LSTM 模型的所有输入变量均通过 LSTM 的存储单元,但并非所有输入变量都需考虑其对大坝变形的滞后影响。因此,提出一种基于改进 LSTM 的大坝变形预测模型,将输入变量分为延迟变量和无延迟变量两部分,且分别通过 LSTM 存储单元和普通单元的隐藏节点进行处理,综合提升大坝变形的预测精度。

1 改进 LSTM 大坝变形预测模型的构建

1.1 LSTM 网络基本原理

LSTM 是一种反向传播的递归型神经网络,将传统递归神经网络(recurrent neural network, RNN)中的隐藏层节点改进为存储单元的形式^[10]。这种存储形式可有效挖掘长时间序列中监测数据之间的关联性,标准的 LSTM 存储块结构如图 1。

由图 1 可知:LSTM 存储块包括输入门、输出门、遗忘门、存储单元。存储块的核心功能是通过存储单元的自连通循环特性实现的,为有效挖掘长时间跨度下监测数据之间的关联性,该单元通过一定的约束条件选定前一时刻的单元状态。此外,该单元结构克服了长时间跨度下梯度消失或爆炸问题。三类门组成存储块的控制模式^[11],利用 sigmoid 激活单元函数决定其状态,选择输入值、预测值、单元状态等中的有效信息进行选择性记忆,以达到长时间序




图1 LSTM 存储块结构

Fig. 1 LSTM storage block structure

列处理的目的。该算法结构的具体计算公式如下^[12]:

$$z_t = g(W_{xz}x_t + W_{hz}h_{t-1} + b_z) \quad (1)$$

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (2)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (3)$$

$$c_t = i_t z_t + f_t c_{t-1} \quad (4)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \quad (5)$$

$$h_t = o_t h(c_t) \quad (6)$$

式中: z_t 为 t 时刻的块输入, 由当前输入值 x_t 和前一时刻预测值 h_{t-1} 求得; c_t 为 t 时刻的单元状态, 由 z_t 和前一时刻的 c_{t-1} 求得; i_t 为 t 时刻的输入门, c_t 输入值的保留量由其求得; f_t 为 t 时刻的遗忘门, c_{t-1} 由其求得; o_t 为 t 时刻的输出门, 与 c_t 一起求得 t 时刻的预测值 h_t ; σ , g , h 为非线性激活函数; W , b 为输入值和预测值在各阶段的权重矩阵和偏置向量。

LSTM 网络由许多隐藏层组成, 每个隐藏层包含许多存储块, 每个存储块又包含一个或多个存储单元。文中主要考虑单个存储块只有一个存储单元的情况, 存储块外的反向传播采用时序反向传播 (back propagation through time, BPTT) 算法^[13]。

1.2 LSTM 预测大坝变形的计算过程

考虑到大坝变形与水压、温度、时效等因素之间具有高度密切的关系, 将不同时刻的环境因素监测值按顺序输入 LSTM 网络, 构成三维时间序列 X_{jv} 。 i 表示位移监测数据; j 表示实测序列的监测时间; v 表示输入变量, 包含水位 H_i 、温度 T_i 和时效 θ_i 。监测时间 j 的最大值 k 对应监测数据的观测总时间, 也控制输入子序列的总长度。在时间步长的选择上, 考虑到大坝变形与日水位、历史日温度等监测数据有关, 将时间间隔设置为 1 d。LSTM 预测大坝变形的计算过程如图 2: 整体网络结构分为输入层、隐藏层和输出层, 输入层将预处理后的时间序列 X_{jv} 输入至隐藏层, 经隐藏层中若干 LSTM 存储块的运算得出最后一个时间步的大坝变形预测值 $h_i(t_k)$, 再对存储块的输出应用一个 sigmoid 转换, 在输出层输出最终的预测数据 $y_i(t_k)$ 。




图2 LSTM 预测大坝变形的计算过程

Fig. 2 Calculation process of dam deformation of LSTM prediction

1.3 LSTM 大坝变形预测模型的改进

在实际情况中, 并不是所有输入的环境监测量都需考虑其对大坝变形影响的滞后性, 如水位、时效等因素。与温度变量不同, 上述变量对大坝变形的影响一般是实时产生的, 不会与大坝变形在时间过程线上表现出明显的滞后关系。但也有特殊情况, 如水位因素, 历史水位会对坝体和围岩的温度分布和水压产生特殊影响, 从而对坝体的变形产生一定的滞后作用^[14]。因此, 考虑水位因素对大坝变形的滞后影响具有一定的合理性。

针对上述问题, 提出一种改进的 LSTM 预测模型, 如图 3, 图中 m 和 n 分别表示延迟变量和无延迟变量的个数。将输入变量分为延迟变量和无延迟变量, 延迟变量参与 LSTM 模型 (图 2) 的计算, 并由存储块输出预测值, 再与无延迟变量合并形成新的输入值。为提高神经网络的非线性表达能力, 增加第二个隐藏层, 使时间效应等无延迟变量在最后一个时间步可直接使用, 不需进行复杂的转换形成原始输入时所需的子序列。

在计算时间方面,由于无延迟变量不需进入存储块进行循环计算,在一定程度上节省了改进 LSTM 模型的训练时间。但由于第二隐藏层的增加,改进 LSTM 模型的整体计算时间比 LSTM 模型略有增加^[15]。因此,适当设置改进 LSTM 模型中神经元的数量与第二隐藏层的传递函数,尽量控制改进模型的计算时间。




图3 改进 LSTM 模型的计算过程

Fig. 3 Calculation process of improved LSTM model

2 工程案例的预测验证

为评价改进 LSTM 模型的预测精度,需采用相应的评价指标度量。选用均方误差 (mean square error, MSE)、平均绝对误差 (mean absolute error, MAE) 及相关系数 R 评价模型的预测精度^[16], 计算公式分别为:

$$e_{\text{MSE}} = \frac{1}{N} \sum_{a=1}^N (x_a - y_a)^2 \quad (7)$$

$$e_{\text{MAE}} = \frac{1}{N} \sum_{a=1}^N |x_a - y_a| \quad (8)$$

$$R = \frac{\sum_{a=1}^N (y_a - \bar{y}_a)(x_a - \bar{x}_a)}{\sqrt{\sum_{a=1}^N (y_a - \bar{y}_a)^2 \sum_{a=1}^N (x_a - \bar{x}_a)^2}} \quad (9)$$

式中: N 为样本数; x_a, y_a 分别为第 a 个数据的实测与预测值; $\bar{x}_a, \bar{y}_a$ 分别为第 a 个数据实测与预测的平均值。

2.1 大坝变形监测数据预处理

某混凝土拱坝位于湖南省,该坝共 29 个坝段,采用正垂线法和倒垂线法组合测量坝体水平位移。假设基岩参考点的位移为 0,即可计算出坝体各监测点的实际水平位移。取 15#坝段监测点 (高程 291 m 处) 自 2000 年 6 月 11 日至 2014 年 5 月 29 日的 341 组监测数据作为原始样本,包含该监测点处的径向位移、水库日水位和温度,图 4、5 为相应的水位及温度过程线。在输入变量的选择上,对于 LSTM 模型,采用图 2 中的水位、温度和时效 3 种影响因素;而改进 LSTM 模型将水位和温度作为延迟变量、时效作为非延迟变量。

将监测数据样本按 0.8 的比值分为训练样本和测试样本数据集,其中训练样本为前 272 组,测试样本为后 69 组。运行模型前,对数据进行标准化处理,利用 python 第三方库的数学处理工具 pandas 程序包将数据转换为满足 LSTM 计算的映射关系,且将样本数据归一化到 $[0, 1]$ 范围。




图4 水位过程线

Fig. 4 Water level hydrograph




图5 温度过程线

Fig. 5 Temperature hydrograph

2.2 LSTM 模型参数设置

LSTM 模型中包括训练时数、收敛容差、隐藏层个数、隐藏层节点个数、传递函数、学习速率及其更新器、输入子序列长度等参数, 初始参数的设置会对大坝变形的预测结果产生较大影响。为提高模型预测精度, 文中采用训练组数据寻找 LSTM 模型及其改进模型的最优参数, 通过试错法及 5 折交叉验证, 最终设置模型的训练时数为 3 000、收敛容差为 0.001。在 LSTM 模型及其改进模型中, 第一隐藏层的网络结构设计相同, 均包含 3 个存储块, 在改进 LSTM 模型第一隐藏层后设置包含 4 个神经元的第二隐藏层; LSTM 模型运行稳定, 几乎不存在过拟合等问题, 未设置第二隐藏层。通过迭代计算, 最终在第二隐藏层中使用线性整流函数^[17](rectified linear unit, ReLU)作为传递函数, 在输出层中使用线性传递函数代替初始的 sigmoid 函数。设置 LSTM 模型的初始学习速率为 0.01, 采用 Adam 算法作为更新器, 对不同的参数设置独立的自适应学习率, 从而加快收敛速度。研究^[18]表明, 该方法具有较好的性能。

结合上述初始参数和监测数据, 进行 LSTM 模型预测实验, 分析输入子序列长度对 LSTM 模型预测精度的影响, 结果如图 6。由图 6 可看出: 输入子序列长度大于 60 d 时, 两模型训练组和测试组的 MSE 较小, 且在长度为 135 d 时测试组的均方误差最小; 输入子序列长度小于 45 d 时, 两模型训练组和测试组的均方误差显著提升。由于短长度输入子序列信息不足, LSTM 模型不能很好地拟合预测位移, 但输入子序列长度足够长对提高精度也没有太大帮助。因此, 文中设置输入子序列长度为 135 d。




图6 不同输入子序列长度下 LSTM 模型的均方误差

Fig. 6 Mean square error of LSTM model under different input subsequence lengths

2.3 模型预测结果精度分析

在数据预处理并设置初始参数后,运用 LSTM 模型和改进 LSTM 模型进行大坝变形预测。由于 LSTM 模型及其改进模型的权重和偏差矩阵均采用均值为 0、方差为 1 的正态分布进行初始化,两模型分别运行 5 次,计算各自预测模型的评价指标,求其均值作为模型最终的预测结果,尽可能避免不同初始权重和偏差对预测结果产生的影响。两模型的预测精度评价指标及训练时间如表 1,2。

表 1 LSTM 模型预测精度评价指标及训练时间

Tab. 1 Prediction accuracy evaluation index and training time of LSTM model

运行次数	MAE/mm		MSE/mm ²		R		训练时间/s
	训练组	测试组	训练组	测试组	训练组	测试组	
1	1.106	1.120	1.996	2.073	0.987	0.989	339.63
2	1.034	1.593	1.612	4.902	0.990	0.977	337.36
3	1.119	1.105	1.930	2.116	0.988	0.988	336.45
4	1.296	1.124	2.529	1.860	0.987	0.989	338.44
5	0.859	1.548	1.325	3.189	0.992	0.984	328.54
平均值	1.083	1.298	1.878	2.828	0.989	0.986	336.08

表 2 改进 LSTM 模型预测精度评价指标及训练时间

Tab. 2 Prediction accuracy evaluation index and training time of improved LSTM model

运行次数	MAE/mm		MSE/mm ²		R		训练时间/s
	训练组	测试组	训练组	测试组	训练组	测试组	
1	1.086	1.078	1.859	1.942	0.988	0.990	341.55
2	1.204	1.206	2.258	2.358	0.987	0.987	341.64
3	1.046	1.194	1.665	2.329	0.990	0.989	338.41
4	0.899	0.994	1.383	1.606	0.992	0.991	338.71
5	1.204	1.245	2.292	2.284	0.987	0.988	340.83
平均值	1.088	1.143	1.891	2.104	0.989	0.989	340.23

对比表 1,2 可知:LSTM 模型与改进 LSTM 模型的训练精度基本相同,三类评价指标的偏差均在 1% 内,说明在基础观测数据输入量足够的情况下,LSTM 模型及其改进模型均有较强的挖掘长时间监测数据之间关联性的能力,对历史变形监测数据的拟合精度较高;在大坝变形的预测效果方面,改进 LSTM 模型对大坝变形的预测精度高于 LSTM 模型,相比于 LSTM 模型,改进 LSTM 模型的平均绝对误差降低了 11.94%,均方误差降低了 25.60%, R 提升了 0.3%。这是由于改进 LSTM 模型考虑了非线性变量的滞后性,提高了输出变量和变形之间的关联度, R 的提高意味着模型的学习精度提高。由此表明,改进 LSTM 模型能进一步提升大坝变形的预测精度。

为直观表现改进 LSTM 模型用于大坝变形预测的适用性和优越性,给出两模型的径向位移预测值及相应残差,结果如图 7,8。从图 7,8 可看出:改进 LSTM 模型的预测值与实测值较接近,整体上预测值在实测值附近上下波动;LSTM 模型的预测值与实测值变化趋势整体一致,但在变形过程线的某些位置特别是峰值与谷值处拟合和预测的偏差较大,精度不高;改进 LSTM 模型在预测阶段的准确率较高,没有上升趋势和下降趋势,也没有产生过拟合的问题,其预测残差正负分布范围较小,能够保证预测值整体在实测值附近变化。上述分析表明,改进 LSTM 模型能充分反映外部环境变量对大坝变形的滞后性影响,具有较高的预测精度。

从图 7,8 还可得到:LSTM 模型和改进 LSTM 模型均在 2007 年 8 月 19 日有较大的负偏差,这主要是由于水位的突然上升(见图 4)。因此,两模型不适用于短期内水位发生大幅度骤变的变形预测。但一般情况下,水位骤变与洪水、渗漏等特殊状况有关,此时更需关注坝体本身的实际情况,变形预测的精度并不重要。从表 1,2 也可看出,LSTM 及其改进模型一次训练需超过 300 s,这是深度学习模型的主要不足之处,可通过增强 GPU 的并行处理能力来加速 LSTM 的训练和推理过程。




图7 LSTM 模型的径向位移预测值及残差

Fig. 7 Predicted value and residual of radial displacement of LSTM model




图8 改进 LSTM 模型的径向位移预测值及残差

Fig. 8 Predicted value and residual of radial displacement of improved LSTM model

3 结 论

考虑变量的滞后性, 构建改进的 LSTM 大坝变形预测模型, 结合工程案例进行大坝变形预测, 对比分析 LSTM 与改进 LSTM 模型的预测结果, 得到以下结论:

- 1) 改进 LSTM 模型的训练精度与 LSTM 模型相近, 但预测结果优于 LSTM 模型, 改进模型在大坝变形预测中具有较高的精度;
- 2) 改进 LSTM 模型能有效利用 LSTM 模型的优势, 充分挖掘大坝变形、水位、温度等监测数据在时间维度上的关联性, 并通过输入变量的分类更合理地对大坝变形进行预测, 可充分反映外部环境变量对大坝变形的滞后性影响, 综合提升大坝变形的预测精度;
- 3) 改进 LSTM 模型由于增加第二隐藏层, 整体运行时间较 LSTM 模型略有提升, 在 GPU 处理能力有限

的情况下需对初始参数进行调整,此外模型不适用于监测数据存在大幅度骤变的预测,不同大坝之间影响变形的延迟和非延迟因素有所不同,需综合考虑不同影响因素进行大坝变形的预测。

参考文献:

- [1] 司海宝,李会.某小(1)型水库大坝坝基岩体渗透性分析[J].安徽工业大学学报(自然科学版),2018,35(1):61-65.
- [2] 徐小枫,黄耀英,朱赵辉,等.混凝土大坝变形监控指标拟定的混合法[J].中国水利水电科学研究院学报(中英文),2022,20(4):334-342.
- [3] 彭圣军.混凝土坝安全监控模型数值优化及变位预警指标研究[D].南昌:南昌大学,2014:5-10.
- [4] 范哲南,刘小生.NARX神经网络在大坝变形预测中的应用[J].人民黄河,2022,44(2):125-128.
- [5] 李明军,王均星,潘江洋,等.基于改进GWO和SVM的大坝变形预测[J].水力发电,2021,47(3):89-93.
- [6] 刘永涛,郑东健,孙雪莲,等.基于EEMD-RVM的土石坝渗流量时间序列预测模型[J].水利水电科技进展,2021,41(3):89-94.
- [7] TIAN W J, ZHANG X P, LV D P, et al. Sliding mode control strategy of 3-UPS/S shipborne stable platform with LSTM neural network prediction[J]. Ocean Engineering, 2022, 265, 112497:1-18.
- [8] MA X L, TAO Z M, WANG Y H, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data[J]. Transportation Research Part C:Emerging Technologies, 2015, 54:187-197.
- [9] PASCUAL S, BONAFONTE A. Multi-output RNN-LSTM for multiple speaker speech synthesis with α -interpolation model[C]//Proceedings of the 9th ISCA Speech Synthesis Workshop. Sunnyvale, USA: International Speech Communication Association (ISCA), 2016:112-117.
- [10] 杨丽,吴雨茜,王俊丽,等.循环神经网络研究综述[J].计算机应用,2018,38(S2):1-6,26.
- [11] 胡昊,马鑫,徐杨,等.基于权重修正和DRSN-LSTM模型的向家坝下游水位多时间尺度预测[J].水利水电技术(中英文),2022,53(7):46-57.
- [12] 魏明桦,郑金贵.基于模糊校正的深度时序信息安全评估算法[J].河海大学学报(自然科学版),2018,46(5):464-470.
- [13] HE H, YI S, LIU W W. Intelligent English learning model based on BPTT algorithm and LSTM network[J]. Journal of Intelligent & Fuzzy Systems, 2020, 39(4):1-12.
- [14] KANG F, LIU J, LI J J, et al. Concrete dam deformation prediction model for health monitoring based on extreme learning machine[J]. Structural Control and Health Monitoring, 2017, 24(10):1-11.
- [15] SHAO B L, SONG D, BIAN G Q, et al. A hybrid approach by CEEMDAN-improved PSO-LSTM model for network traffic prediction[J]. Security and Communication Networks, 2022, 4975288:1-21.
- [16] 唐菲菲,唐天俊,朱洪洲,等.结合注意力机制和Bi-LSTM的降雨型滑坡位移预测[J].测绘通报,2022(9):74-79,104.
- [17] 钱兴,张晓明,郝子浩.基于改进的卷积神经网络的步态识别[J].导航定位与授时,2022,9(2):91-97.
- [18] KINGMA D P, BA J. ADAM: a method for stochastic optimization[C]// Proceedings of the 3rd International Conference for Learning Representations. San Diego, USA: California, 2015. abs/1412.6980:1-9.

责任编辑:何莉