

DOI:10.3876/j.issn.1000-1980.2023.06.006

基于双阶段注意力机制的大坝变形深度学习预测模型

赵二峰^{1,2,3}, 李章寅^{1,2,3}, 袁冬阳^{1,2,3}

(1. 河海大学水灾害防御全国重点实验室, 江苏 南京 210098;

2. 河海大学水利水电学院, 江苏 南京 210098;

3. 河海大学水资源高效利用与工程安全国家工程研究中心, 江苏 南京 210098)

摘要: 为提升大坝结构变形预测精度, 采用完全自适应噪声集合经验模态分解(CEEMDAN)法将变形实测序列解耦为一组具有不同时间-频率特征的本征模态函数, 使用小波阈值消噪对高频分量平稳化处理后进行重构, 利用基于双阶段注意力机制的长短期记忆网络(DA-LSTM)模型对重构变形序列进行预测。实例验证结果表明, 联合 CEEMDAN 算法和小波阈值消噪方法能够有效识别并清洗实测数据中的异常值, 提升了测值对大坝运行性态的表征能力, 同时 DA-LSTM 模型可以充分挖掘大坝变形的滞后性和增强网络的可解释性, 据此构建的变形预测模型具有优良的稳健性。

关键词: 大坝变形; 深度学习; 消噪; 注意力机制; 长短期记忆网络; 预测

中图分类号: TV698.11

文献标志码: A

文章编号: 1000-1980(2023)06-0044-09

Deep learning model for deformation prediction of dam based on dual-stage attention mechanism

ZHAO Erfeng^{1,2,3}, LI Zhangyin^{1,2,3}, YUAN Dongyang^{1,2,3}

(1. The National key laboratory of Water Disaster prevention, Hohai University, Nanjing 210098, China;

2. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China;

3. National Engineering Research Center of Water Resources Efficient Utilization and Engineering Safety, Hohai University, Nanjing 210098, China)

Abstract: To improve the prediction accuracy on the deformation of dam structure, the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) algorithm was adopted in this work to decouple the measured sequence into a series of intrinsic mode functions with different time-frequency characteristics, and then the wavelet threshold denoising was used to stabilize the high frequency component for the reconstruction. Afterwards, a dual-stage attention-based long short-term memory network (DA-LSTM) model was introduced to predict the reconstructed deformation sequence. The results show that the denoising processing method combining CEEMDAN algorithm and wavelet threshold denoising can effectively identify and deal with the outliers in the measured data to improve the representation capacity on the dam performance. Moreover, the established model can exploit the hysteresis of dam deformation and enhance the interpretability of the DA-LSTM network, indicating the strong robustness.

Key words: dam deformation; deep learning; denoising; attention mechanism; long short-term memory network; prediction

随着我国众多水库大坝运行年限的不断增长, 大坝运行安全也逐渐受到广泛关注。采用实测资料表征坝体变形与影响因子之间的非线性关系, 建立可靠的大坝变形安全监控模型, 精准预测大坝结构变形, 充分了解其运行状态, 对保障大坝工程安全具有极其重要的意义^[1-2]。

传统广泛使用的数学统计模型, 比如基于最小二乘法的多元线性回归(multiple linear regression, MLR)模型简便易行, 但此类模型难以克服因子多重共线性问题。为此, 机器学习算法被引入到大坝安全监控领

基金项目: 国家自然科学基金项目(52079046, U2243223)

作者简介: 赵二峰(1986—), 男, 教授, 博士, 主要从事大坝安全监控与健康诊断研究。E-mail: zhaoerfeng@hhu.edu.cn

通信作者: 李章寅(1998—), 男, 硕士研究生, 主要从事大坝安全监控与健康诊断研究。E-mail: 1163162893@qq.com

引用本文: 赵二峰, 李章寅, 袁冬阳. 基于双阶段注意力机制的大坝变形深度学习预测模型[J]. 河海大学学报(自然科学版), 2023, 51(6): 44-52.

ZHAO Erfeng, LI Zhangyin, YUAN Dongyang. Deep learning model for deformation prediction of dam based on dual-stage attention mechanism[J]. Journal of Hohai University(Natural Sciences), 2023, 51(6): 44-52.

域:陈优良等^[3-9]应用智能优化算法优化机器学习模型,剖析了大坝结构性态;胡江等^[10]利用主成分分析法和层次聚类法对拱坝变形进行分区,建立了面板数据回归模型用以预测坝体运行状态;杨庆等^[11-12]利用经验模态分解将大坝变形实测序列分解成具有不同尺度特征的平等信号再分别进行预测。然而,常规机器学习算法无法充分考虑历史变形行为对当前时刻大坝结构变形的影响,而深度学习可弥补这一缺陷,如长短期记忆(long short-term memory, LSTM)神经网络通过将上一时刻的输出作为当前时刻的输入来传递从目标序列中提取到的时间维度信息,可以取得更高的精度^[13-16]。此外,注意力机制与深度学习的结合可以更好地捕捉时间序列的长期时间依赖性,能够增强网络的可解释性^[17-21]。

通常情况下,测量仪器故障、人为因素和外界环境荷载骤变等会导致监测数据与真实值之间产生噪声,不能充分体现大坝真实的变形性态。完全自适应噪声集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise analysis, CEEMDAN)是一种新型信号分解方法,能够克服经验模态分解(empirical mode decomposition, EMD)中的模态混叠现象^[22-25]。本文采用 CEEMDAN 法将大坝变形实测序列分解成多个频率不同的本征模态函数,对高频分量进行小波阈值消噪,降低噪声对模型的干扰;为充分发掘大坝变形的时序特征,将降噪后的数据输入具有双阶段注意力机制的 LSTM 网络(dual-stage attention-based long short-term memory, DA-LSTM)模型中进行预测。

1 实测数据消噪处理方法

1.1 CEEMDAN 法

向待分解的信号 $x(t)$ (t 为时间) 添加 N 次均值为 0 的高斯白噪声序列,构造 N 个加噪信号 $x_i(t)$ ($i=1, 2, \dots, N$):

$$x_i(t) = x(t) + \varepsilon \delta_i(t) \quad (1)$$

式中: ε 为高斯白噪声权值系数; $\delta_i(t)$ 为第 i 次添加的白噪声序列。

分别对 $x_i(t)$ 进行 EMD 分解,得到 N 个 EMD 分量,取均值即为 CEEMDAN 分解产生的第 1 个阶段的本征模态函数(intrinsic mode function, IMF),记为 ζ_1 ,然后计算其残余分量 $r_1(t)$:

$$\zeta_1(t) = \frac{1}{N} \sum_{i=1}^N \zeta_{1i}(t) \quad (2)$$

$$r_1(t) = x(t) - \zeta_1(t) \quad (3)$$

式中 $\zeta_{1i}(t)$ 为第 1 个阶段中第 i 个加噪信号 EMD 分解得到的分量。

将分解后得到的第 j ($j=2, 3, \dots, N$) 阶段残余分量添加噪声,继续进行 CEEMDAN 分解:

$$\zeta_j(t) = \frac{1}{N} \sum_{i=1}^N E_1(r_{j-1}(t) + E_{j-1}(\delta_i(t))) \quad (4)$$

$$r_j(t) = r_{j-1}(t) - \zeta_j(t) \quad (5)$$

式中 $E_n(\cdot)$ 为 EMD 分解第 n 阶段得到的分量。

重复对残余分量加噪声进行 CEEMDAN 分解,直至余量信号极值点数最多不超过 2 个。最终,原始信号序列被分解为 N 个本征模态函数和 1 个残差项 $R(t)$:

$$x(t) = \sum_{n=1}^N \zeta_n + R(t) \quad (6)$$

1.2 小波阈值消噪

为了消除 CEEMDAN 分解得到的高频分量中的噪声对预测模型的影响,采用小波阈值法进行处理。小波阈值消噪是利用小波分解将含噪信号分解到不同尺度空间中,通过阈值处理过滤每一尺度中的噪声,利用小波逆变换将处理后的信号重构得到去噪后的序列。阈值获取方法选用最为常用的 Sqtwolog 阈值。

由于硬阈值函数处理容易引起局部突变,不能有效消除噪声信号,故采用可以使信号更平滑的小波去噪软阈值处理函数:

$$\sigma_\lambda(w) = \begin{cases} \text{sgn}(w) (|w| - \lambda) & |w| \geq \lambda \\ 0 & |w| < \lambda \end{cases} \quad (7)$$

式中: w 为小波系数; λ 为阈值。

2 DA-LSTM 模型

LSTM 神经单元的学习能力通过门控结构实现,其中遗忘门决定单元状态中需要丢失的信息比重,输入门决定单元中将要储存的新信息,输出门决定单元的输出。注意力机制源于 seq2seq 模型,即一个序列到另一个序列的映射。传统的 seq2seq 模型对输入序列的组成部分缺乏判别性,引入注意力机制可以解决这个问题,而双阶段注意力机制模型^[26]则指在第一阶段中,使用输入注意力机制结合先前的编码器隐藏状态,在每个时间步自动提取驱动序列的有效成分;在第二阶段中,使用时间注意力机制在所有时间步中选择相关编码器隐藏状态解决长期依赖问题。DA-LSTM 模型结构如图 1 所示。




图 1 DA-LSTM 模型结构

Fig. 1 Model structure of DA-LSTM

模型输入为 $\mathbf{x} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_L) = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m)^T$, 其中, $\mathbf{X}_k = (X_{k1}, X_{k2}, \dots, X_{kL})^T$ 代表长度为 L 的输入序列, $\mathbf{x}_t = (x_{t1}, x_{t2}, \dots, x_{tm})^T$ 代表 t 时刻的 m 维输入序列。根据文献[1], 模型初始特征因子集 $\mathbf{x}_t$ 为

$$\mathbf{x}_t = \left(H, H^2, H^3, H^4, \sin \frac{2\pi\theta}{365}, \cos \frac{2\pi\theta}{365}, \sin \frac{4\pi\theta}{365}, \cos \frac{4\pi\theta}{365}, \theta, \ln\theta \right)^T \quad (8)$$

式中: H 为上游水位; θ 为监测日至始监测日的累计天数。

在 t 时刻, 编码器将输入序列 $\mathbf{x}_t$ 映射为 $\mathbf{h}_t$:

$$\mathbf{h}_t = f_1(\mathbf{h}_{t-1}, \mathbf{x}_t) \quad (9)$$

式中: f_1 为非线性函数, 是 LSTM 单元; $\mathbf{h}_t$ 为编码器隐藏层在 t 时刻的状态。

在编码阶段, 对输入 $\mathbf{x}_t$ 的各个维度给予不同的关注, 其中对更有影响的序列信息予以较大的关注。对于给定的第 k 个序列信息, 第一层注意力机制如下:

$$e_{tk} = \mathbf{v}_e^T \tanh(\mathbf{W}_e [\mathbf{h}_{t-1}; \mathbf{s}_{t-1}] + \mathbf{U}_e \mathbf{X}_k) \quad (10)$$

$$\alpha_{tk} = e^{e_{tk}} / \sum_{g=1}^m e^{e_{tg}} \quad (11)$$

式中: $\mathbf{s}_{t-1}$ 为编码层 LSTM 上一时刻的细胞状态; $\mathbf{v}_e, \mathbf{W}_e, \mathbf{U}_e$ 均为模型的学习过程参数; α_{tk} 为 t 时刻第 k 个输入特征的重要性。

根据每个特征重要性比例, 自动为输入序列每个时刻 t 对应的影响因素分配权重:

$$\tilde{\mathbf{x}}_t = (\alpha_{t1}x_{t1}, \alpha_{t2}x_{t2}, \dots, \alpha_{tm}x_{tm})^T \quad (12)$$

式中 α 为权重。

在 t 时刻, 隐藏层的状态可以更新为

$$\mathbf{h}_t = f_1(\mathbf{h}_{t-1}, \tilde{\mathbf{x}}_t) \quad (13)$$

在解码阶段, 传统的 Encoder-Decoder 模型易出现输入时间步信息缺失、表征能力差等问题, 故采用时间注意力机制选取时间步中相关的隐藏层状态:

$$l_t = \mathbf{v}_l^T \tanh(\mathbf{W}_l \cdot [\mathbf{d}_{a-1}; \mathbf{s}'_{a-1}] + \mathbf{U}_l \mathbf{h}_t) \quad (14)$$

$$\beta_t = e^{l_t} / \sum_{i=1}^L e^{l_i} \quad (15)$$

式中: $\mathbf{d}_{a-1}, \mathbf{s}'_{a-1}$ 分别为解码层第 $a-1$ 个时间步 LSTM 隐藏层状态和细胞状态; $\mathbf{v}_l, \mathbf{W}_l, \mathbf{U}_l$ 均为模型的学习过程

参数; β_t 为编码层在 t 时刻隐藏层状态的重要性。

由式 (13) 和式 (15) 得到的各时刻的 h_t 和 β_t 便能自适应获得第 $a-1$ 个时间步的中间向量 c_{a-1} , 再结合目标序列 $\{y_1, y_2, \cdots, y_{a-1}\}$ 得到模型输出 $\hat{y}_{a-1}$, 利用其更新 d_a , 并结合第 a 个时间步的中间向量 c_a 实现对时间序列的预测:

$$c_{a-1} = \sum_{t=1}^L \beta_t h_t \tag{16}$$

$$\hat{y}_{a-1} = \hat{w}^T [y_{a-1}; c_{a-1}] + \hat{b} \tag{17}$$

$$d_a = f_2(d_{a-1}, \hat{y}_{a-1}) \tag{18}$$

$$\hat{y}_a = v_y^T (W_y \cdot [d_a; c_a] + b_w) + b_v \tag{19}$$

式中: f_2 为非线性函数, 是 LSTM 单元; $[y_{a-1}; c_{a-1}]$ 为第 $a-1$ 个时间步的目标值与中间向量的拼接; $[d_a; c_a]$ 为解码器隐藏层状态与中间向量的拼接; $\hat{w}, \hat{b}, v_y, W_y, b_w, b_v$ 均为模型的学习过程参数。

综上, 通过给定输入序列 $X=(\tilde{X}_1, \tilde{X}_2, \cdots, \tilde{X}_p)$ 和已有的目标序列 $Y=(y_1, y_2, \cdots, y_{p-1})$, 学习其中规律, 即可对最终的目标 $\hat{y}_p$ 进行回归预测:

$$\hat{y}_p = F(y_1, y_2, \cdots, y_{p-1}, \tilde{X}_1, \tilde{X}_2, \cdots, \tilde{X}_p) \tag{20}$$

式中: $F(\cdot)$ 是非线性映射函数; $\tilde{X}_i$ 为第 p 天的输入特征因子集。

采用均方根误差 RMSE、平均绝对误差 MAE 和平均绝对百分比误差 MAPE 评价模型预测效果, 它们的值越接近 0, 代表模型的预测性能越好。

3 模型预测流程

实测数据消噪处理和 DA-LSTM 模型的预测流程如图 2 所示。




图 2 耦合 CEEMDAN-小波阈值消噪的大坝变形 DA-LSTM 模型预测流程

Fig. 2 DA-LSTM prediction procedure of dam deformation coupled with CEEMDAN and wavelet threshold denoising

具体步骤如下:

- 步骤 1 输入大坝变形与环境量的实测数据, 对缺失值进行插补。
- 步骤 2 对变形数据进行 CEEMADAN 分解, 分解成 N 个 IMF 分量和 1 个残差项 $R(t)$ 。
- 步骤 3 对高频 IMF 分量进行小波分解和阈值处理, 滤除噪声信号, 并剔除残差项。
- 步骤 4 将消噪后的 IMF 分量与低频 IMF 分量重构, 得到降噪后的变形数据。
- 步骤 5 将处理后的初始特征因子集和变形序列归一化, 划分训练集和测试集, 输入 DA-LSTM 模型。

- 步骤 6 输入注意力机制通过结合之前时刻的隐藏层状态信息为输入序列的各因子赋权,形成新的输入序列。
- 步骤 7 新的输入序列通过编码器转换成新的隐藏层状态。
- 步骤 8 时间注意力机制结合上一时刻解码器的隐藏层状态为步骤 7 中所有隐藏层状态赋权,加权求和得到包含所有时刻输入序列信息的中间向量。
- 步骤 9 将中间向量和之前时刻的变形数据输入解码器得到当前时刻的输出值,反归一化得到预测结果。

4 实例验证

4.1 模型有效性分析

利用某混凝土双曲拱坝的变形监测数据,对提出的模型进行有效性检验。该坝最大坝高为 305 m,共 26 个坝段。选取该坝变形最大部位的 PL13-4 垂线测点(位于拱冠梁 1/2 坝高处)的 2015 年 8 月 1 日至 2021 年 2 月 5 日的实测数据用于检验模型的有效性。该测点变形与上游库水位变化实测过程线如图 3 所示,选取前 70% 实测数据作为模型训练集,后 30% 实测数据作为模型测试集。

如图 4 所示,在变形实测数据中随机添加了 20 个噪声数据,变化幅度在 $-1.50 \sim 1.50 \text{ mm}$ 之间,红色圈内为添加的噪声点。采用 CEEMDAN 法对实测数据进行模态分解,分解结果如图 5 所示。IMF1 ~ IMF3 为包含噪声的高频分量,需进行小波阈值滤波消噪,以提取有效成分;IMF4 ~ IMF8 为基本不包含噪声的低频分量,可不进行处理; $R(t)$ 为残余分量,量级很小,可以忽略。




图 3 大坝变形与上游库水位实测过程线
Fig. 3 Measured time series of dam deformation and upstream reservoir water level




图 4 加噪后的大坝变形实测过程线
Fig. 4 Measured time series of dam deformation after adding noises




图 5 变形实测数据 CEEMDAN 分解结果(单位:mm)
Fig. 5 CEEMDAN decomposition results of measured deformation data(unit:mm)

对高频分量进行小波变换,得到不同尺度的小波系数,再对系数进行软阈值处理,小波基选择 sym7 小波,分解层数为 3,阈值根据式(7)计算为 3.901。将小波滤波处理过的高频分量和基本不含噪的低频分量进行重构,消噪后的变形序列如图 6 所示,所滤除噪声变幅介于 $-1.39 \sim 1.51 \text{ mm}$ 之间,降噪效果显著。降噪前后数据与实测值对比如图 7 所示,结合表 1 统计指标,数据降噪后,除最大值降低 0.8938 mm 外,其余指标未有明显变化,表明 CEEMDAN 分解结合小波阈值消噪方法能够在保证样本趋势特征不变的情况下,有效识别并剔除噪声数据干扰,从而提升了实测数据对大坝变形性态的表征能力。




图 6 小波阈值消噪后的 IMF 分量(单位:mm)

Fig. 6 IMF components after wavelet threshold denoising(unit:mm)




图 7 降噪前、后数据与实测值对比

Fig. 7 Comparison of measured values and data before and after denoising

表 1 变形实测值与降噪后数据的统计指标

Table 1 Statistical indicators of measured values and denoised data

统计指标	最大值/mm	最小值/mm	平均值/mm	中位数/mm	标准差/mm
实测值	44.590 0	18.850 0	35.411 1	39.590 0	7.544 3
降噪后	43.696 2	18.975 1	35.411 1	39.554 7	7.542 1

DA-LSTM 模型结构采用 2 层长短期记忆网络和 1 层全连接网络,采用 sigmoid 函数和 tanh 函数作为激活函数,均方误差作为损失函数。模型测试集为 2019 年 6 月 14 日至 2021 年 2 月 5 日(图 3)。为便于对比,分别选择 MLR、BP 和 LSTM 模型与 DA-LSTM 模型对降噪后的实测数据进行建模。经多次试验,设置 DA-LSTM模型时间步为 10,编码层和解码层隐藏层状态的维度分别为 128 和 256,batch_size 为 20,迭代次数为 30,其他学习过程参数通过 Adam 算法寻优确定。由图 8 可知,相比于 MLR 和 BP 模型,在库水位上升、下降以及维持高水位期间,基于 LSTM 的 2 个模型残差值较小,而且残差分布随机性更强,表明模型预测精度更高,能够充分用于剖析大坝运行过程中变形监测数据的时序信息以及库水位、温度和时效变化的影响规律。除此之外,DA-LSTM 模型比 LSTM 模型的稳定性更好,主要体现在水库低水位期间的模型预测结果与实测值更为接近,不仅表明 DA-LSTM 模型能够反映库水位和温度变化这两大主要荷载对拱坝变形的显著相关性,同时也说明添加两层注意力机制能够增强 DA-LSTM 模型对输入序列局部特征信息的挖掘能力,也即能够得到大坝变形序列的时间依赖性。




图 8 4 种模型的预测性能对比

Fig. 8 Prediction performance comparison of four models

由表 2 可知,DA-LSTM 模型的 MAE、RMSE、MAPE 值分别为 0.0747 mm、0.1017 mm、0.22%,相比于 LSTM、BP 和 MLR 模型,均有明显提高,体现了 DA-LSTM 模型在模拟库水位、温度变化等荷载对拱坝变形非线性影响关系的优越性。这不仅检验了 DA-LSTM 模型在大坝安全监控应用中较强的鲁棒性和泛化能力,而且实现了对传统统计回归模型在获得最佳影响因子方面局限性的突破。

通过输入注意力层可以在编码阶段自适应地提取最相关的驱动序列,测试集时段输入向量因子 H_1 、 H_2 、 H_3 、 H_4 、 T_1 、 T_2 、 T_3 、 T_4 、 S_1 、 S_2 的综合注意力权重分别为 0.139 2、0.125 4、0.120 4、0.105 3、0.102 1、0.099 1、0.096 9、0.095 6、0.060 3、0.055 7,它们依次对应式(8)中的 10 个影响因子,将水位因子、温度因子和时效因子的所占注意力权重叠加,可量化荷载变化对大坝变形的影响程度:库水位变化影响占 49.03%,温度变化影响占 39.37%,时效因素影响占 11.6%。结合图 3 库水位实测过程线可知,坝体实测变形变化受上游库水位升降影响明显,同时受温度变化的影响也十分明显,且表现出一定的时效性。上述分离结果充分反映了坝体变形与库水位、温度等荷载的非线性因果关系,同时 DA-LSTM 模型对该坝变形预测精度高,可有效指导工程运行。

4.2 模型适用性和稳定性分析

为验证模型的适用性,选取该坝其他测点(比如相邻垂线测点 PL16-4)的相同时段实测变形数据进行分析。同样取前 70% 作为训练集,后 30% 作为测试集,输入 DA-LSTM 模型中进行预测,具体过程不再赘述。预测结果如图 9 所示,残差较小,模型的 MAE、RMSE、MAPE 值分别为 0.081 3 mm、0.115 0 mm、0.24%,表明该模型预测精度较高,具有较好的适用性。

为验证模型在不同训练集样本时的稳定性,对训练集占比分别为 50%、60%、80% 和 90% 的不同情况进行分析,同时与 MLR、BP 和 LSTM 模型进行对比,通过 MAE、RMSE 和 MAPE 性能指标来评定模型预测性能。由图 10 可知,4 种模型预测性能都是随着训练集占比的增加而增强。在相同训练集占比情况下,BP、LSTM 和 DA-LSTM 的预测性能要优于 MLR 模型,说明神经网络模型在处理非线性数据方面的能力较优。基于 LSTM 的模型预测性能要优于 BP 模型,说明 LSTM 提取时间序列信息的能力相对较强。尽管如此,单纯的 LSTM 模型随着训练集占比的不同,预测性能变化幅度较大,且随着训练集占比的增大,与 BP 模型相比的优势在逐渐减小,但 DA-LSTM 模型的预测性能指标变化幅度较小,说明两层注意力机制在增强模型预测精度的同时,还提升了模型的稳定性,使模型在训练集占比较小的时候也能保持较高的预测精度。

表 2 预测性能指标

模型	MAE/mm	RMSE/mm	MAPE/%
MLR	1.508 0	1.745 0	3.90
BP	0.954 5	1.163 1	2.86
LSTM	0.517 8	0.713 6	1.64
DA-LSTM	0.074 7	0.101 7	0.22




图 9 PL16-4 测点的 DA-LSTM 模型预测结果
Fig. 9 DA-LSTM prediction results of PL16-4 measuring point




图 10 模型稳定性对比

Fig. 10 Comparison of model robustness

5 结 论

- a. 针对在大坝变形监测数据中的随机噪声与异常值,采用 CEEMDAN 分解与小波阈值消噪对实测数据进行降噪处理,得到了能够反映大坝工作性态的真实数据,有效地消除了粗差对模型预测精度的影响。
- b. 建立了 DA-LSTM 模型,利用输入注意力机制能够自适应地赋予每个影响因子不同的关注度以及提取有效特征量,提升了模型对输入变量的可解释性,而且通过时间注意力机制提取相关编码器隐藏状态的前期变化过程数据,能够增强模型的鲁棒性和泛化能力。
- c. 实例验证结果表明,本文建立的 DA-LSTM 模型相比于 MLR、BP 和 LSTM 模型,具有更高的预测精度和稳定性,预测结果符合工程实际情况。需指出的是,该模型主要参数对其学习性能和预测精度影响较大,时间步 L 若取值太小会导致模型耗时增加,取值太大易得到局部最优解;编码层和解码层隐藏层状态的维度若取值太小会导致模型的预测精度降低,取值太大则会出现过拟合现象。今后可引入仿生智能算法对模型学习过程参数开展优化研究,进一步增强模型的适用性。

参考文献:

[1] 顾冲时,吴中如. 大坝与坝基安全监控理论和方法及其应用[M]. 南京:河海大学出版社,2006.

[2] 赵二峰,顾冲时. 混凝土坝长效服役性态健康诊断研究述评[J]. 水力发电学报,2021,40(5):22-34. (ZHAO Erfeng, GU Chongshi. Review on health diagnosis of long-term service behaviors for concrete dams[J]. Journal of Hydroelectric Engineering, 2021,40(5):22-34. (in Chinese))

[3] 陈优良,陈洋,肖钢,等. 改进蝙蝠算法优化极限学习机的大坝变形预测模型分析[J]. 测绘通报,2021(9):68-73. (CHEN Youliang, CHEN Yang, XIAO Gang, et al. Dam deformation prediction model based on IBA-ELM model[J]. Bulletin of Surveying and Mapping, 2021(9):68-73. (in Chinese))

[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]. 水利学报,2022,53(6):733-746. (YUAN Dongyang, GU Chongshi, GU Hao. Displacement behavior analysis and prediction model of concrete gravity dams in cold region [J]. Journal of Hydraulic Engineering, 2022,53(6):733-746. (in Chinese))

[5] 徐卫亚,徐伟,闫龙,等. 基于 LM-BP 和 SVR 的倾倒变形体变形预测[J]. 河海大学学报(自然科学版),2021,49(1):64-69. (XU Weiya, XU Wei, YAN Long, et al. Deformation prediction of toppling deformed slope based on LM-BP and SVR[J]. Journal of Hohai University(Natural Sciences), 2021,49(1):64-69. (in Chinese))

[6] 王飞,张宗亮,王佳俊,等. 基于改进 M5'-主成分模型树的高心墙堆石坝沉降变形预测[J]. 河海大学学报(自然科学版),2018,46(4):353-359. (WANG Fei, ZHANG Zongliang, WANG Jiajun, et al. Forecasting of the settlement deformation for high core rock-fill dam based on the improved M'-PCR model tree[J]. Journal of Hohai University(Natural Sciences), 2018,46(4):353-359. (in Chinese))

[7] 周兰庭,柳志坤,龚云柱. 基于多重分形的混凝土重力坝水平位移波动分析[J]. 河海大学学报(自然科学版),2022,50(1):76-84. (ZHOU Lanting, LIU Zhikun, GONG Yunzhu. Analysis of horizontal displacement fluctuation of concrete gravity dam based on multifractal[J]. Journal of Hohai University(Natural Sciences), 2022,50(1):76-84. (in Chinese))

[8] 谷艳昌,吴云星,黄海兵,等. 基于遗传算法优化支持向量机的大坝安全性态预测模型[J]. 河海大学学报(自然科学版),2020,48(5):419-425. (GU Yanchang, WU Yunxing, HUANG Haibing, et al. Prediction model of dam safety behavior based on genetic algorithm optimized support vector machine[J]. Journal of Hohai University(Natural Sciences), 2020,48(5):419-425. (in Chinese))

[9] 张石,郑东健,陈卓研. 基于改进 PSO-RF 算法的大坝变形预测模型[J]. 水利水电科技进展,2022,42(6):39-44. (ZHANG Shi, ZHENG Dongjian, CHEN Zhuoyan. Dam deformation prediction model based on improved PSO-RF algorithm[J]. Advances in Science and Technology of Water Resources, 2022,42(6):39-44. (in Chinese))

[10] 胡江,马福恒,王春红. 特高拱坝变形监测的分区及其模型构建方法[J]. 河海大学学报(自然科学版),2021,49(2):148-154. (HU Jiang, MA Fuheng, WANG Chunhong. Zoned deformation monitoring and its model building method for super high arch dams[J]. Journal of Hohai University(Natural Sciences), 2021,49(2):148-154. (in Chinese))

[11] 杨庆,任超. 大坝变形的去噪傅里叶模型预测[J]. 测绘科学,2019,44(2):158-163. (YANG Qing, REN Chao. Prediction of dam deformation based on de-noising Fourier model[J]. Science of Surveying and Mapping, 2019,44(2):158-163. (in Chinese))

[12] 宋洋,杨杰,宋锦焘,等. 基于 CEEMDAN-PE-LSTM 的混凝土坝变形预测[J]. 水利水电工程学报,2021(3):41-49. (SONG

- Yang, YANG Jie, SONG Jintao, et al. Concrete dam deformation prediction based on CEEMDAN-PE-LSTM model[J]. Hydro-Science and Engineering, 2021(3):41-49. (in Chinese))
- [13] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9:1735-1780.
- [14] 胡安玉, 包腾飞, 杨晨蕾, 等. 基于 LSTM-Arima 的大坝变形组合预测模型及其应用[J]. 长江科学院院报, 2020, 37(10): 64-68. (HU Anyu, BAO Tengfei, YANG Chenlei, et al. LSTM-ARIMA-based prediction of dam deformation model and its application[J]. Journal of Yangtze River Scientific Research Institute, 2020, 37(10):64-68. (in Chinese))
- [15] 周兰庭, 邓思源, 柳志坤, 等. 基于 SSA-LSTM-GF 的混凝土坝变形预测方法[J]. 河海大学学报(自然科学版), 2023, 51(2):73-80. (ZHOU Lanting, DENG Siyuan, LIU Zhikun, et al. Deformation analysis and prediction method of concrete dam based on SSA-LSTM-GF[J]. Journal of Hohai University(Natural Sciences), 2023, 51(2):73-80. (in Chinese))
- [16] 康俊锋, 胡祚晨, 陈优良. 基于布谷鸟搜索算法优化 LSTM 的大坝变形预测[J]. 排灌机械工程学报, 2022, 40(9):902-907. (KANG Junfeng, HU Zuochen, CHEN Youliang. Dam deformation prediction based on optimization of LSTM by using cuckoo search algorithm[J]. Journal of Drainage and Irrigation Machinery, 2022, 40(9):902-907. (in Chinese))
- [17] 刘建伟, 刘俊文, 罗雄麟. 深度学习中注意力机制研究进展[J]. 工程科学学报, 2021, 43(11):1499-1511. (LIU Jianwei, LIU Junwen, LUO Xionglin. Research progress in attention mechanism in deep learning[J]. Chinese Journal of Engineering, 2021, 43(11):1499-1511. (in Chinese))
- [18] 胡鹤轩, 隋华超, 胡强, 等. 基于图注意力网络与双阶注意力机制的径流预报模型[J]. 计算机应用, 2022, 42(5):1607-1615. (HU Hexuan, SUI Huachao, HU Qiang, et al. Runoff forecast model based on graph attention network and dual-stage attention mechanism[J]. Journal of Computer Applications, 2022, 42(5):1607-1615. (in Chinese))
- [19] 苏燕, 付家源, 林川, 等. 基于时间注意力机制的大坝动态变形预测模型[J]. 水力发电学报, 2022, 41(7):72-84. (SU Yan, FU Jiayuan, LIN Chuan, et al. Prediction model of dam structure dynamic deformation based on time attention mechanism[J]. Journal of Hydroelectric Engineering, 2022, 41(7):72-84. (in Chinese))
- [20] 王晓玲, 李克, 张宗亮, 等. 耦合 ALO-LSTM 和特征注意力机制的土石坝渗压预测模型[J]. 水利学报, 2022, 53(4):403-412. (WANG Xiaoling, LI Ke, ZHANG Zongliang, et al. Coupled ALO-LSTM and feature attention mechanism prediction model for seepage pressure of earth-rock dam[J]. Journal of Hydraulic Engineering, 2022, 53(4):403-412. (in Chinese))
- [21] QIN Y, SONG D J, CHEN H F, et al. A dual-stage attention-based recurrent neural network for time series prediction[C]//Proceedings of the 2017 26th International Joint Conference on Artificial Intelligence. California: IJCAI Organization, 2017:2627-2633.
- [22] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]//2011 IEEE international conference on acoustics, speech and signal processing (ICASSP). Prague: IEEE, 2011:4144-4147.
- [23] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society. Mathematical, Physical and Engineering Sciences, 1998, 454(1971):903-995.
- [24] 费鸿禄, 山杰. CEEMDAN-小波阈值法在爆破振动信号处理中的应用[J]. 爆破, 2022, 39(3):41-47. (FEI Honglu, SHAN Jie. Application of CEEMDAN-wavelet threshold method in blasting vibration signal processing[J]. Blasting, 2022, 39(3):41-47. (in Chinese))
- [25] 于宏旭, 文汉江, 刘焕玲, 等. 基于 CEEMDAN 和小波包多阈值的 GNSS 高程时间序列去噪方法[J]. 大地测量与地球动力学, 2022, 42(10):1005-1009. (YU Hongxu, WEN Hanjiang, LIU Huanling, et al. GNSS height time series denoising method based on CEEMDAN and wavelet packet multi-threshold[J]. Journal of Geodesy and Geodynamics, 2022, 42(10):1005-1009. (in Chinese))
- [26] 戈苗苗, 陆振宇, 梁邵阳, 等. 基于改进双阶段注意力机制的降水智能预报[J]. 南京信息工程大学学报(自然科学版), 2021, 13(6):744-752. (GE Miaomiao, LU Zhenyu, LIANG Shaoyang, et al. Intelligent precipitation forecast based on improved dual-stage attention mechanism[J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2021, 13(6):744-752. (in Chinese))

(收稿日期:2022-11-08 编辑:刘晓艳)