

基于机器学习的铅铋堆中棒束振动预测

王东东¹, 王 端², 周志伟¹, 张 洞¹, 杨红义^{1*}, 杨宏伟¹

¹中国原子能科学研究院, 北京

²中国核工业学院, 天津

收稿日期: 2023年2月22日; 录用日期: 2023年2月28日; 发布日期: 2023年4月20日

摘 要

流致振动是一种复杂的非线性过程。在反应堆运行时, 冷却剂的流动会引起结构的振动, 长期的振动可能使结构发生疲劳损伤或联接件松动磨损, 迫使核电厂停堆检修, 造成较大的经济损失。本研究基于机器学习算法建立了流致振动参数在线实时监测模型, 提前预知掌握流致振动参数在未来一段时间内的变化规律, 为实现提前采取有效措施及时避免流致振动诱导事故发生的能力提供技术参考, 保障反应堆系统的运行安全。

关键词

流致振动, 机器学习, 在线监测

Prediction of Rod Bundle Vibration in Lead Bismuth Reactor Based on Machine Learning

Dongdong Wang¹, Duan Wang², Zhiwei Zhou¹, Jiong Zhang¹, Hongyi Yang^{1*}, Hongwei Yang¹

¹China Institute of Atomic Energy, Beijing

²Chinese Nuclear Industry College, Tianjin

Received: Feb. 22nd, 2023; accepted: Feb. 28th, 2023; published: Apr. 20th, 2023

Abstract

Flow induced vibration is a complex nonlinear process. During the operation of the reactor, the flow of coolant will cause the vibration of the structure. Long term vibration may cause fatigue

*通讯作者。

文章引用: 王东东, 王端, 周志伟, 张洞, 杨红义, 杨宏伟. 基于机器学习的铅铋堆中棒束振动预测[J]. 核科学与技术, 2023, 11(2): 133-140. DOI: 10.12677/nst.2023.112015

damage to the structure or loose wear of the connecting parts, forcing the nuclear power plant to shut down for maintenance, resulting in large economic losses. Based on the machine learning algorithm, this research has established an online real-time monitoring model for flow induced vibration parameters to predict and master the change law of flow induced vibration parameters in the future in advance, which provides technical reference for the ability to take effective measures in advance to avoid flow induced vibration induced accidents in time, and ensures the operation safety of the reactor system.

Keywords

Flow Induced Vibration, Machine Learning, Online Monitoring

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

液态铅铋合金具有良好的中子学、热工水力和安全特性，因此铅铋堆已成为第四代先进核能系统、加速器驱动核废料嬗变系统主要候选堆型之一[1]。然而由于铅铋流质密度大，流致振动较为突出。流致振动指固体与流体的物理场之间的相互作用所导致的流固耦合现象，流体力作用在固体上使之发生的形变会反过来影响流动特性，这是一种复杂的非线性动态关系。核电站中因流致振动导致反应堆或蒸汽发生器失效的事故并不少见，1995年大亚湾核电站因控制棒驱动结构的流致振动发生了落棒时间超限事故；1998年秦山一期发生吊篮下部防断支承组件因流致振动脱落事故[2]；2012年美国 San Onofre 核电站因蒸汽发生器传热管流致振动导致部分传热管磨穿[3]，这些事故带来了巨大的经济损失。因此，预知反应堆内流致振动现象，并提前采取相应措施预防振动导致事故的发生是尤为重要的。

长期以来，学者们采用实验或数值模拟的方法对不同类型柱体的流致振动现象进行了诸多研究，振动响应和相关机制得到了系统的解释[4] [5] [6] [7] [8]，然而此类方法只能对已有流动参数进行研究。随着计算机的飞速发展，人工智能技术在振动研究中应用中越来越广泛。董辉[9]基于数据挖掘技术对桥梁检测数据进行挖掘，发现桥梁结构和环境参数之间的关联规则，最终利用这些模型监测和识别桥梁的健康状况，阐述了机器学习对于状态监测和预测的可行性。黎善武[10]利用现场实测数据通过支持向量机(SVM)建立了数据驱动的某大跨度桥梁的抖振响应预测模型，利用该代理模型研究分析了抖振响应的影响因素，为振动预测的分析提供了铺垫。杨瑞峰[11]针对核主泵换热管提出了针对管板间碰撞力分析预测的深度深度学习在线预测模型，根据可测得的振动位移信号预测碰撞力，为估测碰撞处换热管的磨损情况提供了新的途径。翟立宾[12]分别采用BP神经网络方法、SVM方法和高斯过程回归(GPR)方法构建了垂直来流下柔性圆柱涡激振动响应的预报模型，根据流速、轴向力及轴向空间位置准确预测了横流向及顺流向位移和频率响应，阐述了多种机器学习算法对于振动预测的可行性。

上述研究阐述了机器学习方法在工程上对振动问题进行预测的应用，证明了机器学习算法对流致振动进行预测的可行性。然而已有研究多为水或空气等介质，对于铅铋流致振动预测的研究较少。本研究依据数值模拟方法，分别在稳态运行的两种工况下获取的铅铋介质中振动参数数据为机器学习提供数据集。利用多种机器学习算法对其进行实时监测方法研究，准确超前预测铅铋环境下堆芯单棒在流致振动影响下的整体状态，了解堆内系统设备运行状况，为振动的减弱提供重要技术支持。并针对堆内单棒的

振动情况提前采取相应的有效改善措施,对铅铋堆结构材料因流致振动问题导致的失效事故的发生进行一定的及时有效规避,保证反应堆的安全运行,提高服役期内反应堆的可靠性。

2. 基于机器学习方法的振动参数在线监测

本研究利用机器学习模型并行快速计算的优势,分别采用 BP 神经网络、XGBoost 算法和循环神经网络 LSTM,提出鲁棒性更强、精度更高的铅铋介质悬臂棒横向流致振动在线超实时监测模型,对铅铋流致振动响应的特征变量进行实时超前预测。使研究人员能够探究流致振动的演变规律,以避免出现振动超过阈值进而造成安全隐患,防止流致振动事故的发生。

利用数值模拟所得计算数据作为训练集训练神经网络模型,选取其中两种计算工况的 50 个时间步数据用于预测结果对比。采用单步向前滚动预测的方法,不同参数由于分布特征、变化趋势、波动/振荡与否的不同,其同时时间的预测精度、同精度的预测时间长度都有所不同。

2.1. XGBoost 模型

极端梯度提升(Extreme Gradient Boosting, XGBoost)算法一种在 GBDT 算法基础上改进的回归算法。XGBoost 模型建模流程如表 1 所示。

Table 1. XGBoost modeling process

表 1. XGBoost 建模流程

输入	铅铋介质流致振动数据集 D , 数据标签 L , 决策树数量 M , 数据集 D 的数据量 N
输出	x 所述类别 $H(x)$
1	Initialization Gain $\leftarrow 0, G \leftarrow g_0, H \leftarrow h_0$
2	for $i \leftarrow 1$ to M do $G_L \leftarrow 0, H_L \leftarrow 0$
3	for $j \leftarrow 1$ to N do
4	$G_L \leftarrow G_L + g_j; H_L \leftarrow H_L + h_j; G_R \leftarrow G - G_L; H_R \leftarrow H - H_L$
5	score $\leftarrow \max \left(\text{score}, \frac{G_L^2}{H_L + \Psi} + \frac{G_R^2}{H_R + \Psi} - \frac{G^2}{H + \Psi} \right)$

若以加法模型表示 XGBoost 算法如(1)所示,该算法更新方式与 GBDT 相同,都是利用残差拟合回归决策树,而 XGBoost 进一步优化了目标函数,添加正则化和二阶导数信息,在增强数据信息利用率的同时又可防止模型过拟合,因此保证 XGBoost 算法能够利用较短的训练时间获得比 GBDT 更好的训练结果。损失函数如式(2)所示,采用前向分布算法更新其梯度提升,

$$f_M(x) = \sum_{m=1}^M T(x; \Theta_m) \quad (1)$$

式中, $T(x; \Theta_m)$ 为回归决策树; Θ_m 为决策树的参数; M 为决策树的个数。

$$L(y, f_m(x)) = \sum_{i=1}^N l(y_i, f_m(x_i)) + \sum_{m=1}^M \Omega(f_m(x)) \quad (2)$$

式中, $l(y, f(x))$ 为平方损失函数, $\Omega(f_k(x))$ 为正则项。

XGBoost 预测结果如图 1 所示。

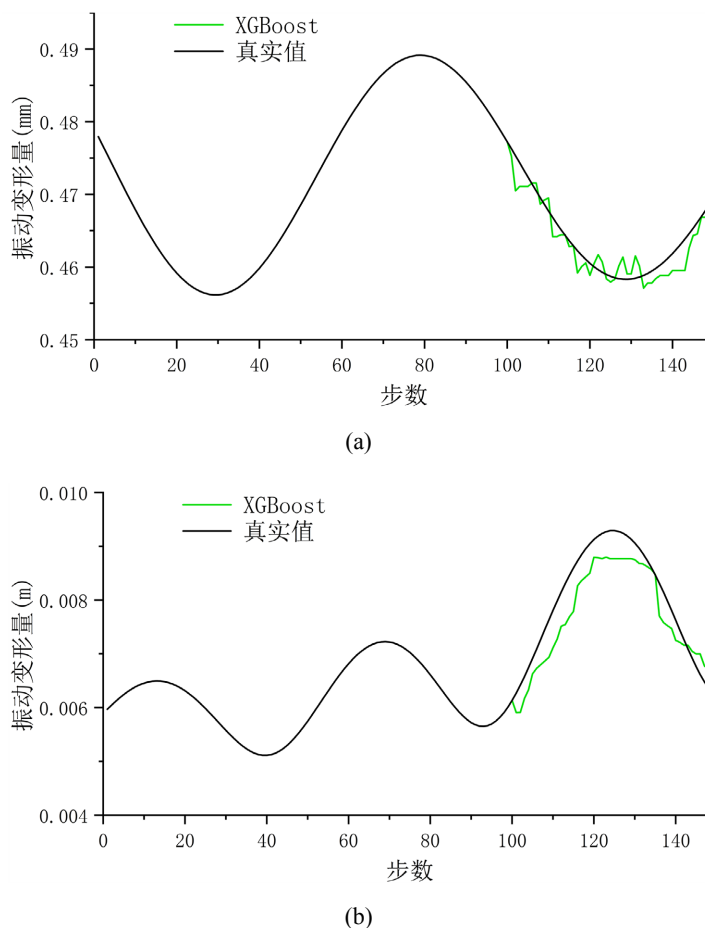


Figure 1. XGBoost forecast results comparison
图 1. XGBoost 预测结果对比

从图中可以看出，XGBoost 预测模型针对铅铋堆单棒流致振动变形量的超实时预测总体效果良好，在变化较为平滑的区域预测效果非常准确，而在振荡区域预测效果较差。

2.2. BP 神经网络预测

BP 神经网络是一种有监督的学习算法，具有很强的自适应、自学习、非线性映射能力，能较好地解决数据少、信息贫、不确定性等问题，且不受非线性模型的限制。BP 神经网络由多层全连接神经网络连接而成，结构包括输入层、隐含层和输出层，各层之间全连接，同层之间无连接，隐含层可以有很多层。输出层神经元的输出如式(3)所示，以此实现 n 维空间向量对 m 维空间的近似映射，并通过输出值与真实值的误差信号的梯度求导反向传播，如式(4)所示，在权向量空间执行误差函数梯度下降策略，动态迭代更新一组权向量，如式(5)所示，使网络误差函数达到最小值，从而完成模型的构建。

$$y_i = f_2 \left(\sum_{k=0}^n w_{jk} z_k \right) \tag{3}$$

式中，为隐含层神经元的输出。

$$\frac{\partial E_i}{\partial w_{jk}} = \frac{\partial E_i}{\partial S_j} \cdot \frac{\partial S_j}{\partial w_{jk}} = -\delta_{ij} z_k = -\sum_{j=1}^m (q_j^i - y_j^i) f_2'(S_j) \cdot z_k \tag{4}$$

$$\Delta w_{jk} = \sum_{i=1}^P \sum_{j=1}^m \eta (q_j^i - y_j^i) f_2'(S_j) z_k \quad (5)$$

依据 BP 神经网络的原理, 假设观测点时间表示为 t_i , 时序数据的时间步长表示为 Δt , 观测点数表示为 n , 则时序数据可表示为 $[X_{t_i}, X_{t_i+\Delta t}, X_{t_i+2\Delta t}, \dots, X_{t_i+n\Delta t}]$ 。而输入可表示为 $[X_{t_i}, X_{t_i+\Delta t}, X_{t_i+2\Delta t}, \dots, X_{t_i+k\Delta t}]$, 其中 k 为输入的时间序列数据个数, 同时也是神经网络输入层神经元的个数; 根据神经网络输出层神经元的个数, 输出可以表示为 $[X_{t_j+(k+1)\Delta t}, X_{t_j+(k+2)\Delta t}, \dots, X_{t_j+(k+w)\Delta t}]$ 或 $[X_{t_j+(k+w)\Delta t}]$, 其中 w 为输出的时序数据为输入时序数据之后的 w 个或者第 w 个。根据预测结果可以选取不同参数所对应的相对准确的 w 。

对于时序数据, BP 神经网络已被证明只有一个隐层的神经网络, 只要隐节点足够多, 就可以以任意精度逼近一个非线性函数。

BP 预测结果如图 2 所示, 可以看出 BP 预测模型的预测结果与真实值趋势相符, 曲线较为平滑, 在峰值处预测存在偏差, 拐点处与真实值较为接近, 说明在预测振荡过程中并不能很好地对应波峰附近的数据。

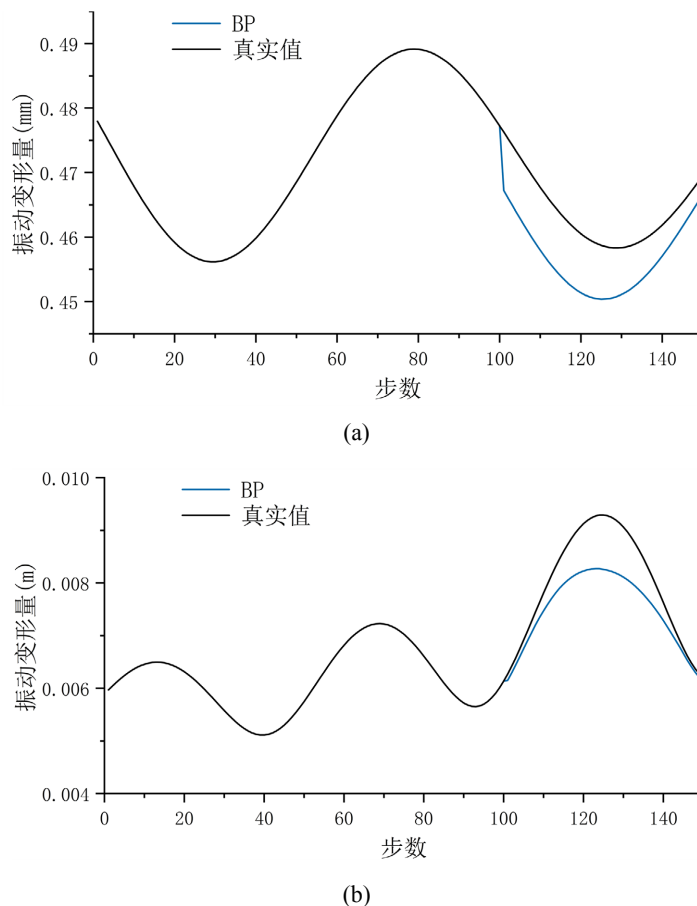


Figure 2. Comparison of BP prediction results
图 2. BP 预测结果对比

2.3. 循环神经网络预测

将马尔可夫模型应用于铅铋流致振动数据的预测建模, 并使用长短期记忆网络(LSTM)对数据进行预

测，模型的输入输出可参考 BP 网络的设计。LSTM 节点中设置了称为门的结构，以控制节点中信息的增減。门实际上是一层全连接层，其输入是一个向量，输出是一个 0 到 1 之间的实数向量。一般一个 LSTM 节点包含三种门：遗忘门、输入门和输出门，LSTM 节点除了节点自身的输出之外还增加了一个新的单元状态，其作用是保存距离当前时刻较长时间的序列信息，即长期记忆。此网络解决了隐变量模型存在着长期信息保存和短期输出 缺 失 的 问 题，LSTM 模型结构如图 3 所示。

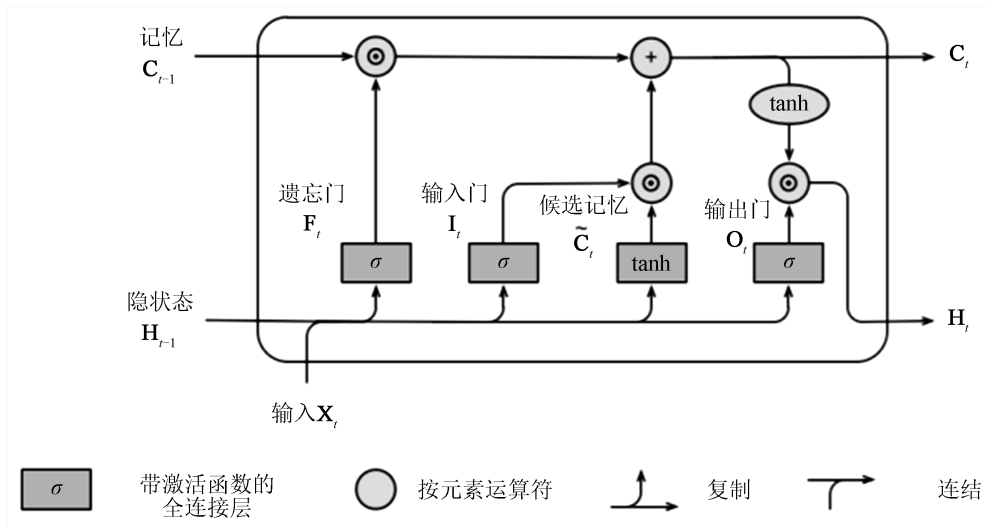



Figure 3. LSTM model structure diagram

图 3. LSTM 模型结构图

图中：

$$\begin{aligned}
 I_t &= \sigma(X_t W_{xi} + H_{t-1} W_{hi} + b_i), \\
 F_t &= \sigma(X_t W_{xf} + H_{t-1} W_{hf} + b_f), \\
 O_t &= \sigma(X_t W_{xo} + H_{t-1} W_{ho} + b_o), \\
 \tilde{C}_t &= \tanh(X_t W_{xc} + H_{t-1} W_{hc} + b_c), \\
 C_t &= F_t \odot C_{t-1} + I_t \odot \tilde{C}_t
 \end{aligned}$$



(a)

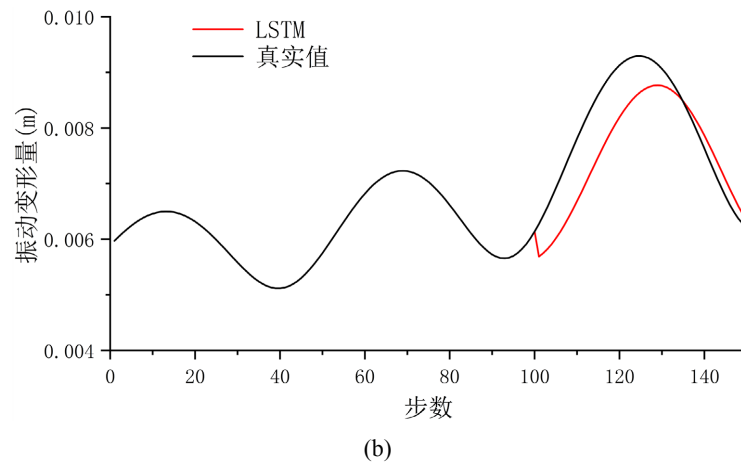


Figure 4. Comparison of LSTM prediction results
图 4. LSTM 预测结果对比

LSTM 预测结果如图 4 所示, 从图中可知预测值与真实值的变化趋势能够拟合, 说明 LSTM 适用于该流致振动数据的超前预测。虽然预测结果与真实值趋势相符, 但存在一定差值。

2.4. 三种算法的对比

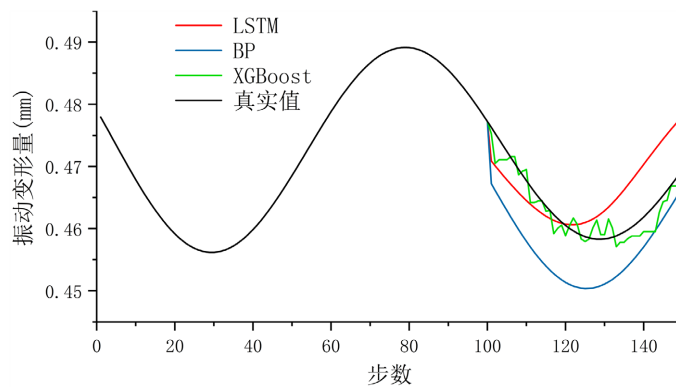


Figure 5. Comparison of parameter prediction results under test condition 1
图 5. 测试工况 1 参数预测结果对比

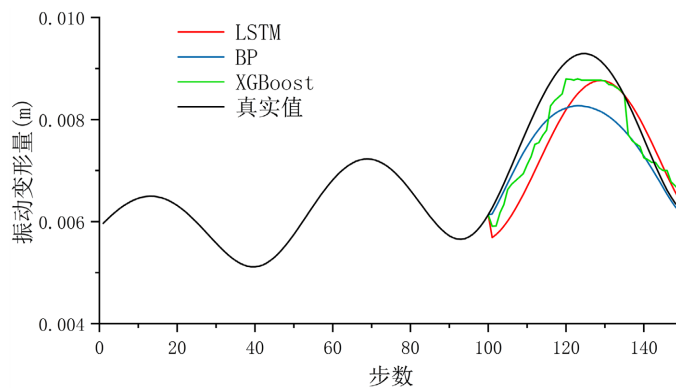


Figure 6. Comparison of parameter prediction results under test condition 2
图 6. 测试工况 2 参数预测结果对比

LSTM、BP、XGBoost 三种算法在两种测试工况下的预测结果对比如图 5 和图 6 所示。从预测结果观察对比分析, 可以得出结论如下: LSTM 预测模型针对铅铋堆单棒流致振动位移参数的超实时预测总体效果较好, LSTM 与 BP 模型都能够很好的预测出参数的变化趋势, 但是后者的整体误差较大; 而 XGBoost 模型对于振动参数的拟合精度最高, 但是存在预测结果振荡的不稳定现象。同时, 三种模型预测值与真实值二者之间始终相差一个稳定的误差值, 造成此现象的主要原因是训练集与测试集数据的二者差异所致, 根据训练集训练学习到的数据变化规律显然在测试集上的误差会较大, 工程应用中需要根据具体的实时监测参数数据对误差进行适当的修正。

在实际的工程应用中, 针对部分预测结果良好的数据, 可适当延长其预测的时间长度, 沿均值上下波动且波动逐渐减弱的的数据预测效果最好, 较大振荡的数据无法精准预测, 其余数据介于两者之间。

3. 结论

本研究分别采用 BP 神经网络、XGBoost 算法和循环神经网络 LSTM 建立了铅铋介质中流致振动参数实时超前监测模型, 并对比分析了产生误差的原因和实际工程应用的注意事项。通过比较几种预测结果之间的差异对预测结果进行了评估, 其中 XGBoost 模型虽然存在振荡现象, 但其拟合精度较高, 可应用于短期预测; 而 LSTM 与 BP 模型虽然很好的预测出参数的变化趋势, 但在振荡处误差相对较大, 其中 BP 模型在振动变形峰值处与真实值误差较大, 而 LSTM 模型则在其余区段存在明显误差, 因此这两种模型适用于长期预测。

通过短期预测结合长期预测的方式, 结合以上三种机器学习算法, 可以实现对铅铋流动的各个运行阶段的超前准确预测。预测结果表明, 选取的多种智能算法所得预测值与真实值较为拟合, LSTM 和 BP 模型分别适用于不同流动工况下的铅铋震动趋势预测, 而 XGBoost 则适用于短期高精度分析, 结合三种模型可应用于对铅铋流致振动的超实时预测, 能够及时、有效降低流致振动事故发生概率, 表明智能预测在该领域具有良好的应用前景。

参考文献

- [1] 王正阳, 瞿叶高, 余晓菲, 等. 铅铋流体作用下螺旋管束的流致振动机理研究[J]. 核技术, 2021, 44(11): 73-81.
- [2] 杨杰, 席志德, 喻丹萍, 等. 华龙一号堆内构件流致振动试验研究[J]. 核动力工程, 2016, 37(S2): 37-39.
- [3] 姜乃斌. 浅析 SONGS 核蒸汽发生器传热管磨穿事故[C]//中国力学学会固体力学专业委员会、国家自然科学基金委员会数理科学部. 2018 年全国固体力学学术会议摘要集(下). 2018: 268.
- [4] Williamson, C.H.K. and Govardhan, R. (2008) A Brief Review of Recent Results in Vortex-Induced Vibrations. *Journal of Wind Engineering and Industrial Aerodynamics*, **96**, 713-735. <https://doi.org/10.1016/j.jweia.2007.06.019>
- [5] Sarpkaya, T. (2004) A Critical Review of the Intrinsic Nature of Vortex-Induced Vibrations. *Journal of Fluids and Structures*, **19**, 389-447. <https://doi.org/10.1016/j.jfluidstructs.2004.02.005>
- [6] Sumner, D. (2010) Two Circular Cylinders in Cross-Flow: A Review. *Journal of Fluids and Structures*, **26**, 849-899. <https://doi.org/10.1016/j.jfluidstructs.2010.07.001>
- [7] Singh, S.P. and Mittal, S. (2005) Vortex-Induced Oscillations at Low Reynolds Numbers: Hysteresis and Vortex-Shedding Modes. *Journal of Fluids and Structures*, **20**, 1085-1104.
- [8] Bourguet, R., Karniadakis, G.E. and Triantafyllou, M.S. (2011) Vortex-Induced Vibrations of a Long Flexible Cylinder in Shear Flow. *Journal of Fluid Mechanics*, **677**, 342-382. <https://doi.org/10.1017/jfm.2011.90>
- [9] 董辉, 李烈彪, 刘实践, 等. 桥梁监测数据的数据挖掘模型[J]. 计算机应用, 2006(S1): 100-101.
- [10] 黎善武. 基于大数据技术的大跨度桥梁抖振响应原型监测数据分析[D]: [硕士学位论文]. 哈尔滨: 哈尔滨工业大学, 2014.
- [11] 杨瑞峰. 基于深度学习的核主泵换热管动力接触在线预测与碰磨分析[D]: [硕士学位论文]. 大连: 大连理工大学, 2021.
- [12] 翟立宾. 基于机器学习方法的柔性圆柱涡激振动预报[D]: [硕士学位论文]. 天津: 天津大学, 2019.