

DOI:10.19651/j.cnki.emt.2107161

核电站板式换热器污垢热阻长时预测方法*

唐健¹ 肖明轩¹ 侯晔² 沈超¹ 徐华¹ 冯春³(1.盐城师范学院物理与电子工程学院 盐城 224007; 2.大亚湾核电运营管理有限公司 深圳 518124;
3.中国科学院半导体研究所 北京 100083)

摘要:核电站对板式换热器使用需求正逐步上升,现有的污垢热阻预测模型泛化能力较低,时序序列角度设计方案较少。针对国内某核电站1号机组的RRI/SEC换热器的实验数据进行主成分分析,优化长短期记忆神经网络设计模型来预测瞬时污垢热阻,覆盖12条管道温度和4条管道流量等变量。模型可精确预测未来25天内的污垢清洗需求,精度可达99.35%,能够在实际使用中,减少换热器监测的人力成本,以提前对板式换热器部分机组停机清洗,增加使用周期和整体机组换热效率。

关键词:板式换热器;长短期记忆神经网络;污垢热阻预测模型

中图分类号: TQ051.5; TP274 **文献标识码:** A **国家标准学科分类代码:** 520.2

Long-term prediction method for fouling and thermal resistance of plate heat exchangers in nuclear power plants

Tang Jian¹ Xiao Mingxuan¹ Hou Yc² Shen Chao¹ Xu Hua¹ Feng Chun³(1. School of Physics and Electronic Engineering, Yancheng Teachers University, Yancheng 224007, China;
2. Daya Bay Nuclear Operation & Management Company, Shenzhen 518124, China;
3. Institute of Semiconductors, Chinese Academy of Sciences, Beijing 100083, China)

Abstract: Nuclear power plants have gradually increasing demand for the use of plate heat exchangers. Existing fouling thermal resistance prediction models have low generalization capabilities and few design options from the time series angle. Through the principal component analysis of the experimental data of the RRI/SEC heat exchanger of Unit 1 of the nuclear power plant, the long short-term memory neural network design model was optimized to predict the instantaneous fouling thermal resistance, covering variables such as the temperature of 12 pipelines and the flow rate of 4 pipelines. The model can accurately predict the demand for dirt cleaning in the next 25 days with an accuracy of 99.35%. In actual use, it can reduce the labor cost of heat exchanger monitoring, so as to stop and clean some units of plate heat exchangers in advance, extend the life cycle and improve heat exchange efficiency.

Keywords: plate heat exchanger; long short-term memory; fouling thermal resistance prediction model

0 引言

在核电站环境下,换热器污垢复杂的形成机制使污垢热阻成为换热器最难预测的工作要素之一。目前换热器污垢热阻预测方法主要分为两类:1)基于化学/物理形成机制的预测方法;2)数据驱动建模预测方法。

基于形成机制的预测方法主要是数值预测,按照污垢形成的化学/物理过程,国内外学者在污垢热阻预测方向已取得大量成果;Gu等^[1]对板式热交换器实验数据进行量纲分析,预测乳清蛋白浓度和钙浓度等因子关于污垢生成的

经验相关性。Ocloń等^[2]研究了高温翅片管换热器热性能、结构性能关于污垢层的变化规律。徐志明等^[3]利用计算流体力学软件对换热器在不同速度条件下的流体流动和传热进行了数值模拟。Schoenitz等^[4]回顾了这一领域10多年进展并得出结论,对化学反应结垢的形成机理和重要工艺参数的影响的认识仍很不全面,尚需进一步研究。

数据驱动建模预测方法主要包含机器学习方法,特别是人工神经网络被逐渐应用在污垢热阻预测上。基于形成机制的预测方法由于计算机硬件水平的制约,多采用恒定边界温度,缺乏对热流和冷流之间的金属板的考虑,使数值

收稿日期:2021-07-04

*基金项目:国家自然科学基金(61771417)项目资助

模拟与实际结果误差较大。机器学习方法能够学习温度及流量等有效特征和污垢热阻之间的关系^[5],目前,该领域的模型主要包括偏最小二乘回归^[6]、主成分回归、BP 神经网络、RBF 神经网络^[7]、广义回归神经网络等。随着算力的增强和算法的开发,DL 在多元序列预测领域迅速发展,DNN 比传统 ANN 具有更强的准确性和泛化能力。刘津等^[8]根据闭式冷却塔的运行工况搭建了模拟试验台,建立了基于 BP 神经网络的闭式冷却塔换热管外壁污垢热阻预测模型,有助于对污垢特性的理解。张仲彬等^[9]根据流动及换热作业中的板式换热器不同时刻的松花江水水质参数、pH 值等因子,并基于全要素 BP 神经网络对污垢热阻值进行预测,通过比较总结出 BP 神经网络在预测板式换热器污垢热阻方面有较强的准确性。王久生等^[10]利用动态模拟装置得到换热器循环水等一系列参数和污垢热阻,根据归一化处理及模型训练,基于 GRNN 建立了污垢热阻与预测模型,能够适应多数水质环境中污垢热阻的预测。

根据板式换热器多项温度、流量测量值和污垢热阻结果之间建立长短期记忆神经网络 LSTM,通过主成分分析法对 4 条管道入口温度,8 条管道出口温度和 4 条管道流量一系列样本特征降维,作为预测模型的输入,并采用贝叶斯优化确定模型结构,提出一种数据驱动的 RRI/SEC 板式换热器污垢热阻长时预测模型(long-term prediction model of fouling thermal resistance, LPMFTR),以期核电站机组的监测预警系统构建提供借鉴与依据。

1 实验装置

国内某核电站 1 号机组的 RRI/SEC 板式换热器是由板式换热器板片、板式换热器密封垫片、固定压紧板、夹紧螺丝、上下导杆和后立柱等组成。板式换热器板片是具有波纹特征的板片,一系列相互平行且具备波纹特征的板片由上下导杆固定在后立柱上,并由夹紧螺丝和固定压紧板组成^[11]。相互临近的板式换热器板片中间形成供液体或气体等流体流动的区域,通过将冷热流动区域相互错开摆放进行换热。核电站换热器中的污垢,具体是指核电站换热器运行过程中,机械设备表面产生并积聚的非预期材质。无论结构是否为腐蚀介质,都会加速金属的腐蚀,如异物附着管壁产生电位差后导致腐蚀。根据不完全调查数据的统计,若核电站换热器设备表面污垢每增加 0.015 mm,其传热效率将降低原传热指标的近 50%,结垢除导致能量损耗外,还会增加修理设备及清洁设备的经济负担。对换热器污垢热阻的预测,可减少污垢引起的换热管堵塞、操作失效、换热效率低等问题,具有节能减排等现实意义。

试验所研究的换热器板片模型以 Alfa 公司提供的人字形板式换热器为研究对象。板片波纹为人字形波纹,波纹角度为 60°,板式换热器由板片交错叠放安装,从侧面观察呈蜂窝状,板片间通过橡胶圈密封,形成流道区域,并避免换热液体渗出。图 1 所示为利用 CAD 软件结合实际结

构参数所建立的人字形板式换热器板片的有限元几何模型。




图 1 人字形板式换热器板片的有限元几何模型

2 长短期记忆神经网络与优化

传统 RNN 通常只保留最后几个时刻的信息,很难处理长时独立任务。为解决这一问题,LSTM 加入 3 个门层以改进基本 RNN,从而保留了更多有用的输入信息^[12],其计算过程依次如下所示。

$$f_t = \sigma(w_f[h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(w_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$c'_t = \sigma(w_c[h_{t-1}, x_t] + b_c) \quad (3)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot c'_{t-1} \quad (4)$$

$$o_t = \sigma(w_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \odot \tanh(c_t) \quad (6)$$

如图 2 所示,LSTM 网络的主要结构包括:

1) 输入门。输入门基于当前输入 x_t 和上一时刻的隐藏层状态 h_{t-1} 生成 i_t 。输入系数 i_t 决定了来自 x_t 的信息有多少可用于计算细胞状态。

2) 遗忘门。遗忘系数 f_t 由遗忘门生成,它决定了 c_t 中保留多少上一时刻的细胞状态 c_{t-1} 。

3) 输出门。式(6)表示输出系数 o_t 如何控制网络的最终输出。




图 2 长短期记忆神经网络模型

LSTM 的这些门有助于捕捉输入时间序列数据的长期和短期相关性,一定程度缓解了信息传输中的梯度消失或爆炸^[13]。LSTM 实现长期记忆的关键在于将每一时间同步的输入信息保存在细胞状态中。每个输出的隐藏层状态包含当前时刻之前的所有输入信息。由于隐藏层状态通常由一定长度的向量表示,随着时间的推移,网络逐渐压缩所有信息。然而,这种无差别地压缩将在一定程度上削弱输入特征之间的时间差异,可能无法突出历史信息中的重要信息且容易过拟合。因此,在网络的每次训练迭代中,使用 Dropout 强化 LSTM 学习能力,如图 3 所示,左图为全连接网络,右图为应用 Dropout 后的网络,相当于每次生成一个相对较小的网络。




图 3 Dropout 变化示例

应用于 RNN 的 Dropout 变体中,在每个时间步长对输入、输出和循环层重复相同的 Dropout 掩码(在每个时间步长丢弃相同的网络单元)^[14]。LSTM 应用 Dropout 的方法与 RNN 相同,值得注意的是,在每次训练中,丢弃的单元是随机的,这些单元的参数不会更新,所有的单元都会在模型测试中使用。

3 板式换热器污垢热阻长时预测模型

LPMFTR 为建立一个可靠的污垢热阻预测模型,通过 PCA 对数据进行特征工程,采用两层 LSTM 模型,由于 LSTM 单元的输出是多维向量,所以最后一个 LSTM 单元的第 2 层的输出连接到全连接层。经贝叶斯优化确定网络的最终超参数后进行预测结果评价及模型比较。所提出模型的建立过程如图 4 所示。

3.1 数据预处理及 PCA

模型收集 4 条管道入口温度,8 条管道出口温度和 4 条管道流量等共 16 个因子,温度、压力是换热器的常规监测参数,投资少、精度高,而且易于测量。使用平均值补充缺失值、归一化对试验数据进行预处理,不同的样本特征往往使用不同的量级和量级单位,会影响数据分析的结果。为了消除特征之间的量纲影响,需要进行数据归一化,解决样本特征之间的可比性问题。对原始数据归一化后,各项指标处于同一量级,适合综合比较评价。2015 年 RRI 出入口温度数据归一化后的折线图、皮尔逊相关系数矩阵与热力图如图 5、6 所示。

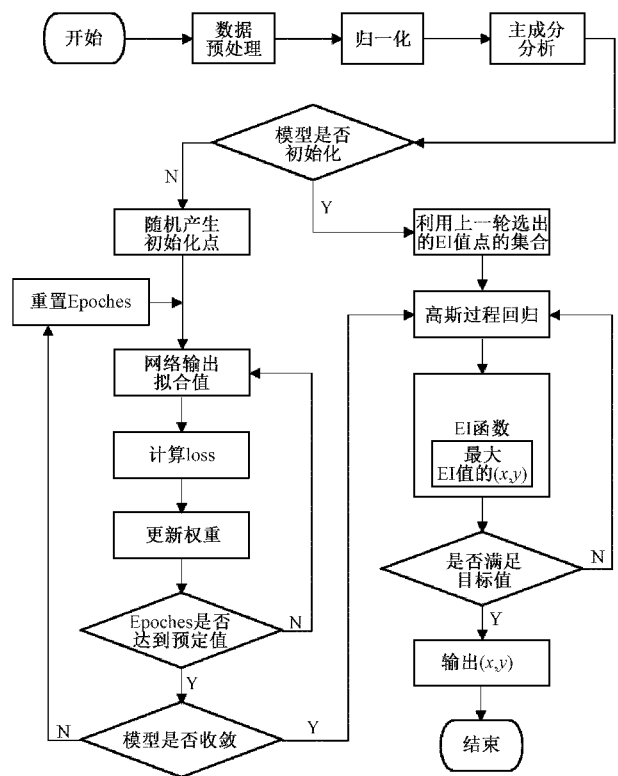


图 4 LPMFTR 建立过程

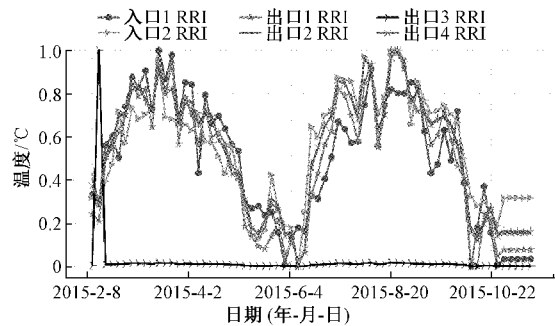


图 5 2015 年测量数据折线图




图 6 相关系数矩阵与热力图

3.2 贝叶斯优化

LPMFTR 使用贝叶斯优化 (Bayesian optimization, BO) 来优化 LSTM 网络的超参数, BO 是在不确定条件下获得黑盒函数 $f(x)$ 最优解的有力数学工具, 通过构造 $f(x)$ 的后验分布 (高斯过程) 来工作^[15]。BO 的获取函数有多种类型, 如置信上限 (UCB)、改善概率 (PI) 和预期改善 (expected improvement, EI)^[16]。在最优值搜索中, 经过多次实验, 使用 EI 作为采集函数是最有效的。特别是, EI 以前被用来解决许多问题^[17], 计算过程如下所示, 其中 $\Phi(\cdot)$ 和 $\varphi(\cdot)$ 表示累计分布函数和标准正态分布的概率密度分布函数, EI 用于求出新的观测值大于 f_n^* 的期望。

$$EI_n(x) = (\mu_n(x) - f_n^*) \Phi\left(\frac{\mu_n(x) - f_n^*}{\sigma_n(x)}\right) + \sigma_n(x) \varphi\left(\frac{\mu_n(x) - f_n^*}{\sigma_n(x)}\right) \quad (7)$$

4 实验结果与分析

4.1 实验环境及数据

实验所用设备软硬件配置如下, 操作系统: Ubuntu18.04.5lts, CPU: Intel(R) Core(TM) i7-7700HQ, 内存: 6 GB, 硬盘: 119 GB。LPMFTR 选择 Anaconda Jupyter Notebook 开发环境和 Python 3.7 作为编程语言, 研究依赖于机器学习框架 Scikit-learn、Keras 和 Pandas、Numpy 等, LPMFTR 对样本进行主成分分析时, 使用 sklearn 库中的 PCA 方法, 并通过 ANSYS 和 Python 的 Matplotlib 库进行数据分析可视化。

本研究的数据来源于国内某核电站 1 号机组设备 2004~2017 年运行所得的实际运行参数、阈值。目前该板式换热器机组通过安装时提供的热阻系数来判断清洗需求, 本研究通过测量外围数据预测恒定运行的机组何时达到瞬时阈值, 对未来污垢热阻和清洗需求进行分析预测。板式换热器数据具体提供类别如表 1 所示。

表 1 板式换热器机组数据类别

试验参数	测量结果
SEC 中水的比热	实际入口温度
RRI 中水的比热	实际出口温度
换热面积	实际机组 SEC 流量
板片常数	实际机组 RRI 流量
理论设计下传热系数	实际机组热交换系数
理论设计下 SEC 流量	瞬时污垢热阻
理论设计下 RRI 流量	允许最大污垢热阻
理论热交换功率	清洗需求

取板式换热器分散区所在位置做具体分析, 由于板式换热器为对称结构, 其集热区和分散区板片和流道结构也为对称结构, 故对板式换热器的集热区和分散区分析结果

规律一致, 本研究对板式换热器分散区即板式换热器的流体入口处分析, 采用 3 层板片和 2 条流道分析。如图 7 所示, 压力从入口到出口逐渐降低, 在分散凸出的几何结构在出口出现极大的压力跳变, 可能会造成阻力的增大, 且易造成污垢沉积, 致使热阻提高降低板式换热器的换热效率下降。




图 7 RRI 压力分布

4.2 实验结果

本研究首先针对板式换热器机组瞬时污垢热阻进行预测, 图 8 为实际污垢热阻与模型生成的预测值对比图, 其中实线为测试集实际污垢热阻测量值, 虚线为 LPMFTR 给出的预测值, 精度为 99.35%。




图 8 瞬时污垢热阻预测对比

为方便板式换热器检测人员监测设备工况, 并不只依靠板式换热器安装时提供的允许的瞬时污垢热阻阈值数据, 模型进一步对最大污垢热阻允许值进行预测, 以预测板式换热器机组的清洗需求, 如图 9 所示, 其中方框表实际清洗需求, 三角表算法生成清洗需求, 根据图中数据对比分析, 预测出的瞬时污垢热阻值绝大部分处于允许值范围内, 这与实际数据相符, 虽在部分时间段预测数据并未与实际数据瞬时值一致, 但所预测的数据值都处于允许值范围内, 最终结果仍然一致为无需清洗, 所以针对污垢热阻预测结果是可靠的。

4.3 模型比较

在这一部分, 为验证所提出方法的性能, 比较了 4 个模




图 9 清洗需求预测匹配度

型的预测效果,包括 SVM、MLP、GRU 和 LSTM-Attention。所有模型使用相同的数据集。原始数据直接用作 GRU 和 SVM 预测模型的输入数据。GRU 同 LSTM 一样已被广泛应用于时间序列预测。SVM 使用常用的径向基函数作为核函数^[18]。MLP 具有良好的泛化能力,广泛应用于预测领域^[19]。通过实验优化 MLP 的各种超参数,采用 4 层网络结构,1 个输入层,2 个隐藏层,1 个输出层。表 2 所示为使用这些模型对板式换热器瞬时污垢最大热阻的预测指标。LPMFTR 模型对污垢热阻的 MAE、RMSE 和 MAPE 值的误差测度分别为 3.771 9、4.192 8 和 0.151 7,远小于其他模型,预测值更接近原始值。

表 2 模型性能度量对比

模型	MAE	RMSE	MAPE
SVM	17.460 8	19.122 3	0.811 5
MLP	8.902 2	10.144 8	0.498 3
GRU	5.110 4	6.916 9	0.261 3
LSTM-Attention	5.990 1	6.314 1	0.201 5
LPMFTR	3.771 9	4.192 8	0.151 7

5 结 论

作为各行业中重要的换热设备,板式换热器污垢热阻变化情况会直接影响工厂的产能和工艺稳定性;因此对其分析和预测的研究就变得十分重要。提出了一种使用 PCA、Dropout、BO 的污垢热阻预测 LSTM 模型。使用国内某核电站 1 号机组的 RRI/SEC 换热器实际数据,对 Alfa 板式换热器在 SEC WATER 和 RRI WATER 介质下的工况进行可视化,对实验数据深入理解,进而设计模型并对比 SVM、MLP、GRU、LSTM-Attention 方法进行评价。在 MAE、RMSE、MAPE 的验证下,LPMFTR 模型在所使用的模型中表现最好,模型得出的板式换热器清洗需求具有较高的预测精度和合理的预测偏差。另外,由于数据集规模较小,模型训练存在过拟合风险,当前的工作旨在通过生成对抗样本增强数据^[20]、基于 Attention 机制来进一步提高模型的鲁棒性和稳定性。

参考文献

- [1] GU Y, BOUVIER L, TONDA A, et al. A mathematical model for the prediction of the whey protein fouling mass in a pilot scale plate heat exchanger[J]. Food Control, 2019, DOI:10.1016/j.foodcont.2019.106729.
- [2] OCLON P, ŁOPATA S. Study of the effect of fin-and-tube heat exchanger fouling on its structural performance[J]. Heat Transfer Engineering, 2017, DOI:10.1080/01457632.2017.1363619.
- [3] 徐志明,王月明,张仲彬.板式换热器性能的数值模拟[J].动力工程学报,2011,31(3):198-202.
- [4] SCHOENITZ M, GRUNDEMANN L, AUGUSTIN W, et al. Fouling in microstructured devices: A review[J]. Chemical Communications, 2015, DOI:10.1039/C4CC07849G.
- [5] 张培培,王昭,王菲.基于深度学习的图像目标检测算法研究[J].国外电子测量技术,2020,39(8):42-47.
- [6] 徐志明,文孝强,郑娇丽,等.板式换热器冷却水污垢热阻预测的偏最小二乘回归法[J].化工学报,2011(6):1531-1536.
- [7] 彭珍,张充,吴立锋,等.基于 RBF 神经网络的换热管污垢热阻预测[J].煤气与热力,2008(6):26-28.
- [8] 刘津,章立新,沈艳,等.基于 BP 神经网络的闭塔换热管壁污垢热阻预测[J].热能动力工程,2020,12:66-71.
- [9] 张仲彬,李煜,郭进生,等.预测板式换热器污垢热阻的新方法[J].东北电力大学学报,2014,34(2):1-6.
- [10] 王久生,张春波,苏涛,等.基于广义回归神经网络的污垢热阻预测[J].科学技术与工程,2019,19(34):169-173.
- [11] 李飞,张平,苑玮琦.板式换热器波纹管深度在线检测方法研究[J].仪器仪表学报,2020,41(2):117-127.
- [12] 李孟威,史元浩,杨彦茹,等.融合 EMD 和 LSTM 的受热面积灰预测研究[J].电子测量与仪器学报,2020,34(11):166-172.
- [13] CHENG H, XIE Z, WU L, et al. Data prediction model in wireless sensor networks based on bidirectional LSTM[J]. EURASIP Journal on Wireless Communications and Networking, 2019, DOI:10.1186/s13638-019-1511-4.
- [14] GAL Y, GHAHRAMANI Z. A theoretically grounded application of dropout in recurrent neural networks[J]. Statistics, 2015:285-290.
- [15] SHAHRIARI B, SWERSKY K, WANG Z, et al. Taking the human out of the loop: A review of bayesian optimization[J]. Proceedings of the IEEE, 2015, 104(1):148-175.
- [16] CALANDRA R, GOPALAN N, SEYFARTH A, et al. Bayesian gait optimization for bipedal locomotion[C]. International Conference on Learning and Intelligent

- Optimization, 2014, DOI:10.1007/978-3-319-09584-4_25.
- [17] KHASHEI M, BIJARI M. Fuzzy artificial neural network p, d, q model for incomplete financial time series forecasting[J]. Journal of Intelligent & Fuzzy Systems Applications in Engineering & Technology, 2014, 26(2): 831-845.
- [18] TAY F, CAO L. Application of support vector machines in financial time series forecasting [J]. Omega, 2007, 29(4): 309-317.
- [19] GÜRESEN E, KAYAKUTLU G, DAIM T U. Using artificial neural network models in stock market index prediction [J]. Expert Systems with Applications, 2011, 38(8): 10389-10397.
- [20] 杨鸿杰,陈丽,张君毅. 基于生成对抗网络的数字信号生成技术研究[J]. 电子测量技术, 2020, 43(20):132-137.

作者简介

唐健(通信作者),工学博士,副教授,主要研究方向为新型电子器件与智能电子系统等研究。

E-mail: tangj01@yctu.edu.cn

肖明轩,工学学士,主要研究方向为时序序列预测、自然语言处理对抗攻击与防御等。

E-mail: xiaomingxuan0514@sina.com