

主蒸汽管道破裂事故下蒸汽发生器的 动态液位预测

殷钰卓, 汪标鑫, 林梅, 王秋旺

(西安交通大学能源与动力工程学院, 710049, 西安)

摘要: 为提升蒸汽发生器液位监测的实时性与准确性,以保障核动力系统安全运行,提出了主蒸汽管道破裂事故下蒸汽发生器的动态液位预测方法。首先,通过模拟主蒸汽管道破裂工况进行实验,采用 AP1000 蒸汽发生器缩比建模,结合电动球阀控制与高速相机图像识别,实现了液位与关键热工参数采集;接着,构建了液位时间序列集并进行了小波分解和相关性分析,研究了液位本身的时频特征以及与热工参数之间的关系;最后,建立了基于 Informer、深度线性网络(DLinear)的深度学习液位预测模型,并进行了预测结果的对比分析。结果显示,DLinear 模型在预测精度与模型鲁棒性方面均优于 Informer 模型,能更准确地反映液位剧烈波动特征,验证了其在处理长时序依赖问题中的适用性与优势。DLinear 模型在均方误差、平均绝对误差和决定系数上较 Informer 模型分别提升了 24.9%、16.0%、9.3%,在 ± 5 mm 误差范围内预测准确率达到 81.5%,不仅能更好地捕捉液位细节变化,还表现出更强的鲁棒性与泛化能力。研究验证了 DLinear 模型在液位预测任务中的高效性与工程应用潜力,为核电站事故预警和智能监测提供技术支持。

关键词: 深度学习;蒸汽发生器;液位预测;主蒸汽管道破裂事故

中图分类号: TL375.1 **文献标志码:** A

DOI: 10.7652/xjtuxb202508014 **文章编号:** 0253-987X(2025)08-0147-11

Dynamic Liquid Level Prediction of Steam Generator under Main Steam Pipe Rupture Accidents

YIN Yuzhuo, WANG Biaoxin, LIN Mei, WANG Qiuwang

(School of Energy and Power Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To enhance the real-time and accurate monitoring of liquid levels in steam generators during main steam pipe rupture accidents, thereby ensuring the safe operation of nuclear power systems, a dynamic liquid level prediction method is proposed. First, experiments simulating main steam pipe rupture conditions are conducted using a scaled model of the AP1000 steam generator. This involves the integration of electric ball valve control and high-speed camera image recognition to collect data on liquid levels and key thermal parameters. Next, a liquid level time series dataset is constructed, followed by wavelet decomposition and correlation analysis to examine the time-frequency characteristics of the liquid level itself and its relationship with thermal parameters. Finally, a deep learning liquid level prediction model based on Informer and DLinear is established to perform a comparative analysis of the prediction results. The results

收稿日期: 2025-02-27。 作者简介: 殷钰卓(2000—),男,硕士生;林梅(通信作者),女,研究员。 基金项目: 热能

动力技术重点实验室开放基金资助项目(TPL2022C01)。

网络出版时间: 2025-04-28

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20250428.1415.002>

indicate that the DLinear model outperforms the Informer model in terms of prediction accuracy and model robustness, accurately reflecting the characteristics of severe liquid level fluctuations and demonstrating its suitability and advantages in handling long-term sequence dependency issues. The DLinear model improves the mean squared error, mean absolute error, and coefficient of determination by 24.9%, 16.0%, and 9.3%, respectively, compared to the Informer model. It achieves a prediction accuracy of 81.5% within a ± 5 mm error range, capturing detailed changes in liquid levels while exhibiting stronger robustness and generalization ability. This study verifies the efficiency and engineering application potential of the DLinear model in liquid level prediction tasks, providing technical support for accident warnings and intelligent monitoring in nuclear power plants.

Keywords: deep learning; steam generator; level prediction; main steam line break accidents

主蒸汽管道破裂是核电站运行过程中可能发生的典型事故之一,具有发生突发性强、影响范围广、对系统安全挑战大等特点^[1]。该事故通常发生在蒸汽发生器出口至汽轮机入口之间的主蒸汽管道,一旦破裂,会导致二回路蒸汽瞬时大量泄漏,引发冷却剂温度和压力骤降,进而诱发蒸汽发生器内部剧烈沸腾^[2]。

蒸汽发生器液位是保障核动力系统安全运行的关键参数,其异常变化可能引发干烧、热管损坏或汽轮机故障,影响系统稳定性^[3]。主蒸汽管道破裂事故下,气泡比例剧烈波动会造成水位瞬时异常升降,形成虚假液位现象,若处理不当,可能引发满水或缺水事故^[4]。目前液位监测多采用压差式传感器,虽在稳态下效果良好,但在事故或海洋动态环境中测量精度大幅下降。此外,核反应堆复杂工况及辐射环境限制了超声波、激光等传统测量手段的应用,对监测方法的抗干扰性与适应性要求更高^[5]。

蒸汽发生器的传统数学模型方法有集总参数模型和分布参数模型这两种模型方法^[6]。然而,由于工业过程的复杂性,很难建立精确的数学模型来描述被控对象。同时,诸如多变量、非线性以及大时滞等复杂控制难题使得经典控制理论方法在解决这些问题时往往效果不佳。因此,模型预测控制(MPC)应运而生,并得到了广泛的应用。与经典控制方法相比,MPC通过使用预测模型来预测未来的输出值,从而实现超前调节,优化控制效果。Wilson等^[7]提出了一种新的随机非最小的状态空间模型形式,既可用于自适应最优滤波,也可用于状态变量反馈控制。Tatjewski^[8]在线性状态空间模型的基础上,提出了应用于非线性情况的一种基于恒定状态扰动预测的新技术,并在非线性过程的仿真结果验证了该理论的有效性。Wang等^[9]开发了一种数据驱动模型预测控制策略,可以直接使用闭环输入输

出数据来进行输出预测。

以上经典控制理论和现代控制理论虽然严格遵循特定的数学理论,但在某些实际生产和生活场景中,已无法满足特定需求。随着深度学习算法的快速发展,一些智能控制方法开始被应用于蒸汽发生器(SG)液位的控制。这些方法能够处理复杂的非线性、多变量和大时滞等问题,提供更加灵活和高效的解决方案。曾碧凡等^[10]针对SG水位模型,通过设计切换函数并结合遗传算法,寻求滑模控制器的最优参数值。Cho等^[11]将模糊逻辑控制器(FLC)和模糊逻辑滤波器(FLF)应用于SG的液位控制,提出了一种确保稳定性的规则,同时通过FLF生成蒸汽流量的前馈信号。Dong等^[12]为了避免在低功率或者瞬态变化下测量数据的不确定性,提出了一种新的给水控制策略,仿真结果表明,该控制策略能够将核蒸汽发生器的水质量和水位保持在运行的极限范围。Demerdash等^[13]建立了压水堆核电站的详细动态模型,并将4种元启发式优化算法分别用于给水控制系统进行参数优化,通过仿真验证了所提优化控制器在负载瞬态下具有良好的动态性能。

随着人工智能在各领域的应用,已有一些研究使用神经网络进行液位控制,提出了一种基于长短时记忆网络(LSTM)的水位控制系统,该系统利用LSTM网络预测控制阀的开度,通过反馈信号动态调整网络参数并进行下一步预测。这种方法能够有效提升蒸汽发生器水位控制的精度和稳定性,为实际应用中的水位管理提供了有力支持^[14-15]。

主蒸汽管道破裂事故的研究主要依赖实验与程序仿真,Stefanova等^[16-17]对TRACE/PARCS与RELAP5的三维耦合结果进行了对比,分析了VVER-1000反应堆在主蒸汽管道破裂工况下的响应差异,Yang等^[18]则对沸水反应堆实验装置开展

核电站热工水力系统代码仿真验证。文献[19]通过搭建实验回路,并使用可视化窗口结合神经网络实现了液位的高精度、实时监测,验证了该方法对液位动态变化的良好响应能力。Wang 等^[20]采用小波分析与深度学习方法,进一步探讨了摇摆条件下液位变化特性。但是,由于实际工况下蒸汽发生器无法设置可视化窗口,本文旨在探索基于可测热工参数预测液位的方法,通过建立参数与液位之间的映射关系,实现主蒸汽管道破裂事故下液位的非可视化精确预测。

1 实验系统和方法

1.1 实验回路

本研究所采用的实验回路用于模拟主蒸汽管道破裂(MSLB)事故下的舰船蒸汽发生器运行工况,其系统结构如图 1 所示。本文的实验系统以蒸汽发生器为核心,主要由运行回路、液位图像采集、工质参数采集 3 部分组成。在运行回路中,循环泵将水箱中的工质输送至蒸汽发生器,进水端配备流量计、温度计和压力表,以实时监测工质的热物性参数。蒸汽发生器负责能量转换,通过 U 型加热管对工质进行加热,并设有可视化窗口用于液位高度监测。蒸汽经热电偶和压力表测量后,流经涡街流量计,并最终在冷凝器中冷凝回至水箱,冷凝器通过冷水机进行散热以维持循环稳定。




图 1 本文实验回路
Fig.1 Experimental circuit

液位图像采集部分依托可视化窗口和高速相机获取液位变化情况,而工质参数采集模块监测进水和蒸汽的温度、压力、流量等关键物性参数,为实验数据分析提供支撑。

为模拟 MSLB 事故的发生,本文实验采用电动阀门进行控制。在蒸汽发生器正常运行状态下,关闭电动阀门可模拟内部压力的升高,主动开启阀门则用于触发 MSLB 事故。电动控制球阀由反馈操作箱精确调节,具备 0.1% 的调节精度,调节范围为

0%~100%。阀门从全开至完全关闭的转动时间约为 10 s,确保了实验过程中对事故触发过程的可控性和重复性。破口事故发生时,没有给水。

液位图像的采集采用 MotionPro 高速相机,分辨率为 1 280×600 像素,拍摄频率为 100 Hz。为确保图像质量,实验使用额定功率 12 W 的 LED 灯进行补光,采用明视场照明方式,按照视场两倍原则从可视化窗口下方打光。同时,为满足高速相机对拍摄距离的要求,使用外置三脚架实现相机位置的灵活调节,包括拍摄距离与高度的自由调整。鉴于实验主要关注液位在纵向方向的变化,将相机顺时针旋转 90°,使拍摄图像尺寸变为 600×1 280 像素。通过训练好的神经网络对液位图像进行识别,提取液位数值,识别准确率高达 99.5%。

本实验涡街流量计量程为 0~205 m³·h⁻¹,测量误差为 1.2%;温度热电偶量程为 -50~200 ℃,测量误差为 0.2%;压力表量程为 0~1.6 MPa 而测量误差为 2.6%;数据采集卡量程为 1~5 V,测量误差为 0.002 5%。蒸汽发生器采用基于 AP1000 原型的缩比建模方法进行设计,具体参数如表 1 所示。

表 1 蒸汽发生器模型参数
Table 1 Dimensions of the steam generator model

参数	数值	
	AP1000 原型	本文实验模型
长度/mm	10 170	700
下筒内径/mm	4 220	350
加热管内径/mm	15.44	20
加热管厚度/mm	1.02	0
加热管外径/mm	17.48	20
加热管间距/mm	24.89	25
加热管数量	10 025	15
加热功率/kW	1 707 500	30
比热容/(J·kg ⁻¹ ·K ⁻¹)	5 479.67	7 354.53
功率体积比	1.57×10 ⁵	1.59×10 ⁴
传热系数/(W·m ⁻² ·K ⁻¹)	35 252.7	3 507.36

缩比建模过程中应控制一系列关键无量纲参数^[21],这是影响蒸汽发生器内部液位变化的主要影响因素,即需要 AP1000 原型和本文实验模型的特定无量纲参数相等,长度的比例值和流通截面积的比例值如下

$$\rho_1^k = l_k/l_0 \tag{1}$$

$$\rho_2^k = a_k/a_0 \tag{2}$$

式中: l_k 为第 k 节构件长度; l_0 为参考长度; a_k 为第 k

节构件截面积; a_0 为参考截面积。

AP1000 原型和本文实验模型的特定物理过程的准则数相等。理查森数、回路摩擦和形状阻力、回路焓升、无量纲比热容计算式为

$$\rho_3 = l_h / u^2 \quad (3)$$

$$\rho_4 = \sum_i \left(\frac{a_0}{a_i} \right) \left(\frac{f_i}{d_i} + K_i \right) \quad (4)$$

$$\rho_5 = \frac{ql_c \xi}{\rho_0 u a_0 \Delta h} \left(\frac{\Delta \rho}{\rho_g} \right) \quad (5)$$

$$\rho_6 = \frac{\rho_s c_s T_0 a_s}{\rho_0 a_0 \Delta h} \quad (6)$$

式中: l_h 为初始长度; u 为初始速度; f 为摩擦系数; d 为热段水力学当量直径; K 为阻尼系数; q 为初始热流密度; l_c 为冷段初始长度; ξ 为热源热周; ρ_0 为初始密度; Δh 为工质相变焓升; $\Delta \rho$ 为气液相密度差值; ρ_g 为蒸汽密度; ρ_s 为热源密度; c_s 为热源热容; T_0 为热源温度; a_s 为热源截面积。

本文实验模型相对于 AP1000 原型, 功率体积比、传热系数和流速均缩小了 10 倍, 以确保实验条件与实际工况的相似性, 为液位变化的研究提供合理的物理基础。

1.2 实验工况

本文针对不同加热功率、破裂压强及相对破裂开度下的蒸汽发生器液位变化, 提取液位特征并进行数值预测。实验设计涵盖多个变量, 其中加热功率 P 为 8~16 kW。本文通过调节控制阀门, 将破裂开度设为 20%、40%、60%、80%、100% 这 5 种典型工况, 以研究不同破裂程度对蒸汽发生器液位的影响。破裂压强方面, 考虑实验设备安全限制(最大承压为 0.6 MPa, 进水泵额定压力为 0.3 MPa)及相似准则要求, 实验选取 0.05、0.075、0.1 MPa 这 3 个典型值作为破裂压强, 满足压强比相似性。冷却温度始终保持恒定在 18℃, 自动控制阀下游的背压稳定, 约等于一个标准大气压。


实验共采集 58 组数据, 物理量数据采集频率为 2 Hz, 包括蒸汽发生器进出口流量、压力和蒸汽温度等 5 项关键物理参数; 液位图像的拍摄频率则为 100 Hz, 以确保高精度的液位变化记录。实验数据涵盖 MSLB 事故发生前后共 60 s, 构建了完整的数据集, 以支持后续模型的训练与测试。

2 数据分析


2.1 热工水力参数

本实验选取加热功为 8 kW、破裂开度为 20%、


破裂压强为 0.05 MPa 的工况进行数据分析。记录的热工水力参数包括进口液体压力 p_w 、出口蒸汽压力 p_a 、出口蒸汽流量 q_{out} 、进口液体温度 T_{in} 以及出口蒸汽温度 T_{out} 。实验过程中, 为达到设定的破裂压强, 需要在加热过程中首先关闭出口电动阀门, 本工况中的关闭时间点为 340 s。发生 MSLB 事故即电动阀门打开至指定开度的时间点为 480 s, 破口稳定后全开阀门的时间点为 800 s, 热工水力参数变化曲线如图 2 所示。



(a) 压力变化



(b) 流量变化



(c) 温度变化

图2 热工水力参数变化曲线

Fig. 2 Thermal-hydraulic parameter variation curves

从图 2(a)可以看出,在阀门关闭后,压力持续上升,直到指定破裂压强,随后电动阀门开始动作,以模拟 MSLB 事故的发生。当破裂事故发生后,压力瞬间下降。然而,在破裂稳定,即阀门动作至指定开度后,稳定蒸汽压力仍然高于阀门关闭前的稳态加热阶段。随着 MSLB 事故的发生,蒸汽压力初期由于大量蒸汽瞬间释放而急剧下降。然而,随着蒸汽发生器换热增强,更多的热量从一次侧传递至二次侧,导致蒸汽生成速率上升,因此虽然压力由于泄漏有急剧下降,但是最终在破裂稳定后,液体工质蒸发速率要比破裂事故发生前高,压力维持在高于无破裂加热阶段的水平。

从图 2(b)可以看出,在初期稳定加热阶段,蒸汽发生器持续产生蒸汽。然而,在 100 s 时出口蒸汽流量出现突变,这可能是由于初始阶段水受热分布不均,导致局部区域的蒸汽突然释放,使流量短暂升高。随着系统逐渐稳定,蒸汽的生成趋于均匀,流量随之下降并进入稳态。在阀门关闭后,蒸汽流量显著减少并趋于零。当阀门打开以模拟 MSLB 事故瞬间,蒸汽流量迅速上升,随后随着系统调节逐渐下降并趋于稳定。

从图 2(c)可以看出,出口蒸汽温度在阀门关闭后开始上升,而在阀门打开模拟破裂后,温度迅速下降。但在破裂稳定后,出口蒸汽温度仍高于无破裂加热阶段,表明 MSLB 事故改变了蒸汽发生器的加热状态,提高了蒸汽蒸发速率。在此情况下,若不及时加水,极易导致水位过低的风险,进而影响蒸汽发生器的正常运行和安全性。

2.2 液位数据

通过液位识别网络获得的 MSLB 事故下蒸汽发生器液位高度 H 变化如图 3 所示,为便于展示,横坐标的时间起始点设为 0,但实际上对应于破裂事故发生前 15 s,即热工水力参数记录的 465 s。破裂事故发生后,蒸汽发生器内部压力剧烈变化,导致工质迅速沸腾,液位大幅上升。随着泄漏的持续,压力进一步下降,沸腾强度逐渐减弱,液位开始回落,同时波动幅度也有所降低。整体来看,MSLB 事故发生后,液位波动的振幅明显增大,变化频率显著提高,表明液位动态特性在事故影响下也发生了显著变化。因此,为了选择合适的液位预测方法,有必要对液位变化特性进行深入分析。

通过多分辨率分析中的小波变换对液位进行多分辨率分析,这不仅能够捕捉信号的全局特征,还能定位和检测关键的瞬态特征,对于非平稳信号的分

析尤为重要。同时,相比传统的傅里叶变换仅提供频率信息,小波变换能够同时提供时间-频率信息^[22],实现时频局部化分析,因此在处理非平稳信号时具有显著优势。




图 3 MSLB 事故下的蒸汽发生器液位变化曲线
Fig. 3 Steam generator level change curve under MSLB accident

本文对液位数据经过连续小波变换(CWT)处理,最终发现液位信号的主要频率都集中在 10 Hz 以下。根据奈奎斯特采样定理,采样频率需高于信号主频的两倍才能准确重构信号,100 Hz 的相机采样频率足以满足液位信号的重建需求。同时,在整体时间域上,存在 3 个能量较高的信号点:20 s 时频率为 3.12 Hz 的信号点,在 26 s 频率为 1.76 Hz 的信号点,在 36 s 频率为 2.91 Hz 的信号点。

在 15 s 前液位变化频率较为分散,但主要以低频分量为主,表明系统处于较为稳定的状态。在 15.00~37.00 s 时,对应破裂事故发生后的时间段,液位变化的主要频率集中在 1~5 Hz,并伴随着较大的振幅波动,说明液位变化较为剧烈。在 37.00 s 之后,系统逐渐趋于稳定,液位波动的幅度和频率变化也随之减弱,最终进入相对平稳的状态。

液位振荡主要变化频率集中在 10 Hz 以下,而在时间域 15.00~37.00 s,对应破裂发生至系统趋于稳定阶段。同时,液位信号的频率分布在全时间尺度范围内均低于 100 Hz,说明液位图像的拍摄频率足以准确捕捉液位变化,为进一步提取液位特征并使用神经网络进行液位预测提供了可行性。

2.3 相关性分析

为了分析热工物理量与液位变化之间的关系,本文选取了同一工况下的测量数据,对相关物理量和液位数据进行归一化处理,并绘制其变化曲线,如图 4 所示,可以看出,在 MSLB 事故中,事故主要通过改变出口压力,进而影响蒸汽发生器内部的饱和

温度。随着沸点的降低,工质的沸腾程度显著增强,大量气泡的生成与破灭引发液位的剧烈波动。




图 4 液位与物理量数据的归一化对比图

Fig. 4 Normalized comparison chart of level and physical quantity data

破裂事故发生时,蒸汽泄漏会导致蒸汽温度降低,由于系统内部压强变化,入口压力相应下降,这种变化属于被动响应过程。本实验工况均在静态加热条件下进行,未引入注水操作,尽管注水工况更贴近实际运行情况,但从研究角度来看,实验中主要关注加热功率、破裂开度以及破裂压强等因素的影响,入口流量基本保持稳定,未出现显著波动。

为定量分析各物理量与液位数据之间的相关性,从而筛选出与液位变化密切相关的输入特征,以提升预测模型的准确性与稳定性,本文采用皮尔逊相关系数进行相关性分析,计算公式如下

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (7)$$

式中: x_i 、 y_i 为 2 个变量的真实数值; $\bar{x}$ 、 $\bar{y}$ 为平均值。皮尔逊相关系数用于衡量两个变量之间的线性相关程度,取值为 $[-1, 1]$, 相关系数越接近 1, 表示变量之间的正相关性越强,即某一特征变量的增加通常伴随着液位的升高,接近 -1 则表明二者呈强负相关性。

进口流量的皮尔逊相关系数为 0.035, 蒸汽流量的皮尔逊相关系数为 0.243, 蒸汽压力的皮尔逊相关系数为 -0.093, 进口压力的皮尔逊相关系数为 -0.123, 蒸汽温度的皮尔逊相关系数为 -0.130。

可以发现,MSLB 事故下蒸汽发生器内液位的上升伴随着蒸汽流量的增大,MSLB 事故则会导致蒸汽压力和温度的降低,这与液位之间表现出负相关关系,因此液位与这两项物理量的皮尔逊相关系数为负值。相比之下,进口流量与液位的相关性较弱,对整体预测结果的影响有限,这一现象与实验在纯加热状态下进行有关,尚未引入注水过程。

液位数据通过可视化窗口拍照后识别获得,具有一定的波动性,而物理量数据则由数据采集装置实时记录,两者在数据质量和稳定性方面存在差异,可能会影响实际相关性计算的精确性。尽管从物理机理上蒸汽压力对液位具有直接影响,但计算得到的相关系数未必完全体现出这一关系。综合考虑物理机制及相关性分析结果,本文仍保留全部 5 项物理量作为模型输入特征,并采用多变量时间序列预测方法对液位变化进行建模,以提高模型对复杂工况下液位动态变化的适应能力与预测精度。

3 预测模型

3.1 Informer 模型

Informer 网络是一种专为长序列时间序列预测设计的高效 Transformer 变体^[23], 模型结构如图 5 所示。Informer 通过概率稀疏自注意力和层间降采样显著降低计算复杂度,使其能够高效建模长时依赖关系,并精准捕捉关键特征。在蒸汽发生器水位预测任务中,水位变化受加热功率、蒸汽流量、压力波动等多因素影响,具有非线性、长时依赖和突变特性,而传统 LSTM 或 Transformer 难以有效建模这些复杂动态。




图 5 Informer 模型结构

Fig. 5 Informer model structure

相比之下,Informer 模型能够在较低计算成本下准确预测水位变化,在处理长序列非平稳信号时表现优异。其时频局部化特性有助于识别蒸汽发生器水位的主要振荡模式,提高预测精度和稳定性。

此外,Informer 的计算复杂度从 $O(L^2)$ 降低至 $O(L\log L)$, L 为时间序列长度,适用于实时监测和预测,为蒸汽发生器水位调控和安全保障提供高效可靠的解决方案。

3.2 深度线性网络模型

在长时间序列预测任务中,基于自注意力机制的模型虽然在许多领域表现优异,但其在捕捉长期依赖关系时可能遇到困难,尤其在序列非常长的情况下,模型更关注局部信息,忽略了重要的长期趋势变化。这些问题使得 Transformer 类模型在处理具有明显趋势的时间序列数据时,表现不如预期。针对这些问题,深度线性网络(DLinear)模型提供了一种更简洁且高效的解决方案。

DLinear 模型是一种结构简洁且高效的深度学习模型,特别适用于处理具有明显线性趋势或周期性波动的时间序列数据^[24]。模型结构如图 6 所示,在蒸汽发生器液位预测任务中,DLinear 模型能够快速捕捉液位变化的长期趋势和细节性特征,同时保持较高的预测精度。该模型通过线性结构简化了复杂的计算过程,降低了训练和推理的时间成本,特别适合实时性要求较高的应用场景。此外,DLinear 模型在处理液位数据时,能够有效减少过拟合,保持较好的泛化能力,且具有较强的可解释性,便于分析液位变化的主要驱动因素。




Fig. 6 DLinear model structure

为了展示 DLinear 模型在识别液位变化主要驱动因素方面的能力,本研究使用移动平均对液位数据进行了分解,将其划分为趋势项与细节项两部分,并分别计算这两部分与 5 个物理特征之间的皮尔逊相关系数。入口流量的趋势项和细节项的皮尔逊相关系数分别为 0.02、0.01,蒸汽流量的皮尔逊相关系数分别为 0.23、-0.02,蒸汽压力的皮尔逊相关系数分别为 -0.20、0.02;入口压力的皮尔逊相关系数分别为 -0.19、0.02;蒸汽温度的皮尔逊相关系数

分别为 -0.05、0。

上述研究结果表明,物理量数据与趋势项之间的相关性普遍较高,说明物理特征的变化主要对液位的趋势变化产生影响。这一结果与前述原始液位数据与物理特征的相关性分析结果基本一致,其中蒸汽压力、蒸汽流量以及入口压力与趋势项的相关性尤为显著。

相较之下,细节项与物理特征之间的相关性普遍较弱,表明液位的周期性波动成分受物理量变化的影响较小。在液位预测中,若能够准确捕捉液位的趋势变化,即可较好地掌握整体液位变化方向,从而实现及时判断与有效干预。

4 预测结果与分析

本文将实验获得的 58 个随机工况作为数据集,将每个工况测得的物理量与液位数据按照 7 : 2 : 1 的比例划分为训练集、测试集、验证集。液位数据集的频率为 100 Hz,通过实验测得的热工水力参数对液位高度进行预测。在训练过程中,为了防止模型过拟合,本文引入了早停机制,该机制通过持续监控模型在验证集上的损失函数,当该指标在连续若干个训练周期内未能显著提升时,便自动中止训练过程。这一策略不仅避免了模型在训练集上过拟合,导致泛化能力下降,还能有效缩短训练时间,提高计算效率。

模型的构建使用了 Pytorch 框架,训练运行在 Intel(R) Core(TM) i7-9700F CPU@3.00 GHz 的计算机 CPU 上,预测结果的精度通过均方误差 E_1 和平均绝对误差 E_2 来衡量,计算公式如下

$$E_1 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{8}$$

$$E_2 = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{9}$$

式中: y_i 为真实值; $\hat{y}_i$ 为预测值。

为进一步量化,使用了决定系数 R ,用于评估回归模型拟合效果的统计量,反映了自变量解释因变量的程度,其计算式为

$$R = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{10}$$

式中: $\bar{y}$ 为真实值的平均值。 R 介于 0 到 1 之间,越接近 1,说明模型对数据的拟合程度越好。

在对 Informer 网络进行超参数调优后,最终确


定模型的最佳参数配置如下:学习率设为 0.000 1,编码层数为 2,解码层数为 3,注意力头数为 4,模型预测单元数为 512。此外,输入序列长度为 80,预测序列长度为 10。DLinear 模型的最佳参数配置如下:学习率为 0.01,线性层神经元数量为 128,输入序列长度为 80,预测序列长度为 10。Informer、DLinear 模型的预测误差和预测速度对比如表 2 所示,其中误差值为多次重复实验的平均值,以增强结果的稳定性与可靠性。

表 2 两模型预测误差与预测速度对比


Table 2 Prediction errors and speed

参数	数值	
	Informer 模型	DLinear 模型
E_1/mm^2	25.61	19.22
E_2/mm	3.69	3.10
R	0.75	0.82
单次预测时间/s	0.003	0.07

从表 2 可以看出,DLinear 模型在所有评价指标上均优于 Informer,展现出更高的预测精度,在 E_1 、 E_2 和 R 这 3 个预测精度评价指标上,DLinear 模型分别提升了 24.9%、16.0%和 9.3%。这一结果充分体现了趋势分解与线性建模在长时序预测中的优势,使模型能够更准确地捕捉时间序列的长期趋势与变化规律。此外,为评估模型在实际工程中的实时性表现,在单次预测时间这一预测速度评价指标上,相同硬件环境下,DLinear 模型的单次预测时间为 Informer 模型的 4.29%。说明 DLinear 模型在响应速度方面具备显著优势,适用于对实时性要求较高的液位预测任务。在加热功率 8 kW、破裂开度 20%、破裂压强 0.05 MPa 工况下,Informer、DLinear 模型的预测值与真实值对比如图 7 所示。



(a)Informer 模型



(b)DLinear 模型

图 7 液位高度预测值与真实值对比

Fig. 7 Predicted results and true values

由图 7 可以看出,两种模型均能够较好地拟合液位数据的变化,通过放大部分数据点,可知 DLinear 在细节变化上的捕捉能力更强,而 Informer 模型预测结果存在一定的时间延迟,导致其在突变点或快速变化区域的拟合效果较差。这种滞后效应是 Informer 模型预测误差较大的主要原因,进一步说明了 DLinear 模型在时间序列长时依赖建模中的优势。

为进一步分析预测结果的分布趋势,本文将真实值与预测结果分别作为横纵坐标绘制散点图,图 8 直观展示了模型预测值与实际数据的对比关系,通过观察散点分布,可以评估模型的预测精度、误差分布以及对数据趋势的捕捉能力。

从图 8 可以看出,DLinear 模型的预测值与真实值散点的拟合曲线更接近参考线 $y = x$,即理想预测结果的分布线,说明该模型在大多数样本上能够较为准确地还原液位的实际变化趋势,预测精度相较其他模型更高。散点整体较为集中,说明两种模型在整体趋势上均能较好地拟合真实数据。然而,针对偏离 $y = x$ 直线较远的异常点,Informer 模型预测结果的异常点数量相对较多,导致整体预测精度较低。这进一步表明,DLinear 模型在细节捕捉和误差控制方面更具优势。

为进一步分析不同时间段的预测精度,展示模型在不同时间点的误差分布情况,绘制预测误差变化图,如图 9 所示。Informer 模型的误差变化范围为 $-24.54 \sim 40.86$ mm,DLinear 模型的为 $-22.67 \sim 37.98$ mm。




图 8 预测值与真实值散点图

Fig. 8 Scatter plot of prediction results and true values




图 9 两模型预测结果的误差

Fig. 9 Prediction deviation

由图 9 可以看出,两种模型的误差曲线均存在局部极大或极小值,主要原因在于实验数据中存在部分异常点,使得相邻时间步的液位变化幅度过大。这些异常数据可能会影响模型的整体预测效果,尤其是 Informer 模型可能对异常值过度关注,从而影响其对整体趋势的捕捉。而 DLinear 模型凭借其线性建模能力,能够较好地减弱异常值的影响,提高模型的泛化性能。

为进一步量化模型的预测性能,本文设定当预测误差在判定阈值范围内时,可视为预测准确。根据标准统计预测结果,可计算整体预测准确率

$$P_2 = \frac{N_c}{N_t} \tag{11}$$

式中: N_c 为识别正确的数量; N_t 为总数据点数。

在判定阈值为 $\pm 5\text{ mm}$ 时,可以计算出 Informer 模型预测结果 $P_2=74.7\%$,而 DLinear 模型预测结果 $P_2=81.5\%$,整体预测准确率提升了 6.8% 。如果将该阈值扩大至 $\pm 10\text{ mm}$,DLinear 模型预测准确率可以达到 96.9% ,而 Informer 模型的预测准确率为 94.5% 。此外,Lei 等^[25]采用 LSTM 模型预测了冷却剂丧失事故和蒸汽发生器传热管破裂事故的蒸汽发生器液位,所得 E_2 为 0.073 ,本文的 DLinear 模型预测液位的 E_2 为 0.044 ,进一步验证了本模型在预测精度方面的有效性。

5 结 论

本文通过分析用于模拟 MSLB 事故的蒸汽发生器实验数据,在一种蒸汽发生器动态液位快速监测方法的帮助下,获得了实际的液位时间序列数据集以及相关热工水力参数;通过深度学习方法,结合蒸汽发生器热工水力参数,构建了能够响应 MSLB 事故的液位预测模型;利用蒸汽发生器的热工水力参数,对 MSLB 事故时的动态液位进行预测。对比不同的深度学习方法,分析了相应的预测结果,可得如下结论。

(1) 本文构建了基于 AP1000 缩比模型的蒸汽发生器实验平台,设计了不同加热功率、破裂压强及开度等工况,采集液位及关键热工参数数据,旨在分析 MSLB 事故对液位变化特性的影响。典型工况结果表明,破裂事故通过降低出口压力进而影响饱和温度,显著增强工质沸腾强度,气泡的大量生成与破裂引发液位剧烈波动,同时伴随着蒸汽温度与压力的明显下降。

(2) 对 Informer、DLinear 模型进行了超参数

调优,并在多个指标上评估其预测性能。实验结果表明,DLinear 模型在所有评价指标上均优于 Informer 模型,预测精度分别提升了 24.9%、16.0%和 9.3%,表明 DLinear 在长时序依赖建模中的优势。同时,虽然两种模型均能较好地拟合液位变化趋势,但 Informer 模型预测结果存在一定的时间滞后,而 DLinear 模型能够更准确地捕捉局部细节变化,从而降低预测误差。

(3)从散点图分布和误差波动范围角度来评估模型,DLinear 模型预测值与真实值散点图的拟合直线更接近 $y=x$,异常点更少,误差分布更集中,鲁棒性更强。基于 $\pm 5\text{ mm}$ 判定阈值,DLinear 模型整体预测准确率比 Informer 模型提高了 6.8%,表现出更优的泛化能力和稳定性。

参考文献:

- [1] 李冬生. 主蒸汽管道破裂事故的安全评价 [J]. 核动力工程, 1997, 18(4): 303-306.
LI Dongsheng. Safety assessment of main steam line break accidents [J]. Nuclear Power Engineering, 1997, 18(4): 303-306.
- [2] LIU Li, YING Bingbin. Effect of water level on performance of swirl-vane separator and steam dryer in PWR SG [J]. Nuclear Engineering and Design, 2020, 370: 110918.
- [3] 俞尔俊. 秦山核电厂主蒸汽管道破裂事故的分析研究 [J]. 原子能科学技术, 1989, 23(5): 15-22.
YU Erjun. Analysis for postulated mainsteam line break accident in Qinshan nuclear power plant [J]. Atomic Energy Science and Technology, 1989, 23(5): 15-22.
- [4] KONG Xiangsong, SHI Changqing, LIU Hang, et al. Performance optimization of a steam generator level control system via a revised simplex search-based data-driven optimization methodology [J]. Processes, 2022, 10(2): 264.
- [5] KOTHARE M V, METTLER B, MORARI M, et al. Level control in the steam generator of a nuclear power plant [J]. IEEE Transactions on Control Systems Technology, 2000, 8(1): 55-69.
- [6] CHEN Yongwei, XIE Yongjing, LI Yonggang, et al. Full-range steam generator's water level model and analysis method based on cross-calculation [J]. Progress in Nuclear Energy, 2021, 133: 103635.
- [7] WILSON E D, CLAIRON Q, TAYLOR C J. Non-minimal state-space polynomial form of the Kalman filter for a general noise model [J]. Electronics Letters, 2018, 54(4): 204-206.
- [8] TATJEWSKI P. Offset-free nonlinear model predictive control with state-space process models [J]. Archives of Control Sciences, 2017, 27(4): 595-615.
- [9] WANG Youqing, FANG Mengqi, JIANG Xu, et al. Intensive insulin therapy for critically ill subjects based on direct data-driven model predictive control [J]. Journal of Process Control, 2014, 24(5): 493-503.
- [10] 曾碧凡, 吴婕, 武万强, 等. 基于遗传算法的核电站蒸汽发生器水位动态滑模控制 [J]. 热力发电, 2016, 45(8): 43-48.
ZENG Bifan, WU Jie, WU Wanqiang, et al. Genetic algorithm based dynamic sliding mode water level control for steam generators in nuclear power stations [J]. Thermal Power Generation, 2016, 45(8): 43-48.
- [11] CHO B H, NO H C. Design of stability-guaranteed fuzzy logic controller for nuclear steam generators [J]. IEEE Transactions on Nuclear Science, 1996, 43(2): 716-730.
- [12] DONG Wei, DOSTER J M, MAYO C W. Steam generator control in nuclear power plants by water mass inventory [J]. Nuclear Engineering and Design, 2008, 238(4): 859-871.
- [13] DEMERDASH N A, EL-HAMEED M A, EISAWY E A, et al. Optimal feed-water level control for steam generator in nuclear power plant based on meta-heuristic optimization [J]. Journal of Radiation Research and Applied Sciences, 2020, 13(1): 468-484.
- [14] RODRÍGUEZ-ABREO O, RODRÍGUEZ-RESÉNDIZ J, FUENTES-SILVA C, et al. Self-tuning neural network PID with dynamic response control [J]. IEEE Access, 2021, 9: 65206-65215.
- [15] SHE Jingke, WANG Jiani, YANG Suyuan, et al. The design and implementation of an LSTM-based steam generator level prediction model [C]//Nuclear Power Plants: Innovative Technologies for Instrumentation and Control Systems. Singapore: Springer Singapore, 2021: 505-517.
- [16] STEFANOVA A, GROUDEV P, SANCHEZ-ESPINOZA V H, et al. Comparison of MSLB transient results using the 3D coupled code TRACEv5p05/PARCS and the system thermal hydraulic code RELAP5 [J]. Annals of Nuclear Energy, 2024, 203: 110518.
- [17] STEFANOVA A, GROUDEV P. Comparison of VVER1000 plant respond during MSLB scenario using TRACE and RELAP computer codes [C]//IOP Conference Series: Earth and Environmental Science. Bristol, UK: IOP Publishing, 2024: 012022.

[18] YANG Ye, HU Mengyan, ZHANG Xueyan, et al. Analysis of main steam line break accident on a BWR test facility using TRACE [J]. Nuclear Engineering and Design, 2024, 416: 112765.

[19] CHEN Jianhao, HUANG Zhiwen, HU Bin, et al. Visualization and monitoring dynamic water levels of steam generators based on deep learning [J]. Progress in Nuclear Energy, 2024, 169: 105052.

[20] WANG Biaoxin, JIANG Yuang, LIN Mei, et al. Prediction of steam generator liquid level under main steam line break accident based on wavelet decomposition combined with deep learning [J]. Nuclear Engineering and Design, 2025, 436: 113998.

[21] BHOWMIK P K, SABHARWALL P, JOHNSON J T, et al. Scaling methodologies and similarity analysis for thermal hydraulics test facility development for water-cooled small modular reactor [J]. Nuclear Engineering and Design, 2024, 424: 113235.

[22] RHIF M, BEN ABBES A, FARAH I R, et al. Wavelet transform application for/in non-stationary time-series analysis: a review [J]. Applied Sciences, 2019, 9(7): 1345.

[23] ZHOU Haoyi, ZHANG Shanghang, PENG Jieqi, et al. Informer: beyond efficient transformer for long sequence time-series forecasting [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, CA, USA: AAAI Press, 2021: 11106-11115.

[24] ZENG Ailing, CHEN Muxi, ZHANG Lei, et al. Are transformers effective for time series forecasting? [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, CA, USA: AAAI Press, 2023: 11121-11128.

[25] LEI Jichong, REN Changan, LI Wei, et al. Prediction of crucial nuclear power plant parameters using long short-term memory neural networks [J]. International Journal of Energy Research, 2022, 46(15): 21467-21479.

(编辑 赵炜)

zkxb. xjtu. edu. cn