

DOI: 10.20040/j.cnki.1000-7709.2023.20221136

基于注意力机制和多传感器信息驱动模型的水轮发电机组故障预测系统

谭刚¹, 杜磊浩¹, 胡边², 何智成¹

(1. 湖南大学汽车车身先进设计制造国家重点实验室, 湖南长沙 410082;

2. 湖南五凌电力科技有限公司, 湖南长沙 410004)

摘要: 为满足水轮发电机组在大数据背景下的故障预测需求, 结合注意力机制特征提取能力强的特性和多传感器信息驱动可提高模型鲁棒性的优点, 提出了一种基于注意力机制和多传感器信息驱动(Bi-GRU-Attention)模型的水轮发电机组故障预测系统, 并将其应用于湖南省某水电站^{#8}机组8月在线监测数据中。实际运行结果表明, 该系统有效预测了水轮发电机组的振动趋势, 实现了水轮发电机的智能预测。

关键词: 水轮发电机组; 深度学习; 多传感器驱动; 注意力机制; 故障预测

中图分类号: TV734; TP29

文献标志码: A

文章编号: 1000-7709(2023)03-0195-03

1 引言

水轮发电机组作为水电工程建设中重要的动力设备发挥着重要作用, 为确保水轮发电机组正常运行, 建立一个高效、可靠的水轮发电机组故障预测系统就显得尤为重要。随着人工智能的迅速发展, 杜义等^[1]采用经验模态分解与多层前馈神经网络集成模型提取非线性空蚀信号特征, 对水电机组空蚀故障做出了精准判断; 杨彬等^[2]将自适应噪声完备集合模态分解法与 SVM 相结合, 有效地识别了水电机组的故障。传统机器学习方法在一定程度上实现了故障的预测功能, 但该方法过于依赖专家先验知识去实现高维特征提取处理, 以至于步入了“数据多而专家少”的困境, 难以满足水轮发电机组在大数据背景下的故障预测需求。而深度学习技术依靠其强大的建模和表征能力, 可较好地改善传统机器学习方法的缺陷, 在机械设备大数据健康监测中取得了卓越成果。另外, 水轮发电机组作为一个非常复杂的机电液一体化非线性系统, 其导轴承的振动因素不仅需考虑机械方面的原因, 还应考虑流体动压力和发电机组带来的电磁力影响^[3]。传统的一元预测模型仅考虑了目标特征与单一因素之间的影响关系, 无法适用于拥有复杂机电液一体化系统的

水轮发电机组, 因此需综合考虑水轮机振动影响因素, 才能搭建合理的水轮机预测模型。对此, 本文结合注意力机制特征提取能力强的特性和多传感器信息驱动可提高模型鲁棒性的优点, 提出了一种基于注意力机制和多传感器信息驱动模型的水轮发电机组故障预测系统, 并利用湖南省某水电站^{#8}机组2021年8月采集的数据对提出的预测系统进行验证; 发现该系统可有效预测机组的工作趋势, 能及时实现异常振动预警, 有助于工程人员对机组及时进行预防性维护, 从而降低设备不必要的停运次数, 提高机组发电效益。

2 数据预处理

采集于湖南省某水电站^{#8}机组2021年2、8月的振动数据, 采集信号包括导叶开度、励磁电流、有功功率、水头、水导轴承 X 振动、无功功率等数据。由于水轮发电机组工况条件复杂, 致使传感器收集到的原始数据存在缺失值、异常值及无效值等问题。为提高数据的有效性, 采用箱型图法和 KNN 算法^[4]对原始数据中的缺失与异常值进行填补和替换, 同时通过主效应分析模型^[5]对特征属性和故障类型进行关联性分析, 并对无关特征进行剔除处理, 从而形成水轮发电机组子特征集。预处理后的数据作为模型的输入, 用于

收稿日期: 2022-04-27, 修回日期: 2022-06-12

基金项目: 湖南省重点研发(2020GK2094); 湖南省自然科学基金面上项目(2020JJ4196)

作者简介: 谭刚(1998-), 男, 硕士研究生, 研究方向为故障诊断, E-mail: 947675637@qq.com

训练模型参数。

3 水轮发电机组故障预测系统

3.1 双向门控循环单元

3.1.1 循环神经网络

循环神经网络(RNN)的工作原理为提出一个具有记忆功能的单元,将计算结果保存在该记忆单元,此后,再集合此次记忆单元与下一次的输入数据,一并输入至下一个网络中,其示意图见图 1。




图 1 循环神经网络(RNN)模型示意图

Fig. 1 Schematic diagram of the recurrent neural network model

3.1.2 门控单元循环网络

当时间序列过长时,由于 RNN 网络易呈现出梯度爆炸及消失等现象,会影响到网络训练时梯度的传递性,以至于传递性不好,这类问题被称为长程依赖缺陷^[6]。基于此缺陷,长短时记忆网络(LSTM)和门控单元循环网络(GRU)相继被提出。与 LSTM 相比,GRU 的结构更为简单,因为 GRU 将 LSTM 中的输入门和忘记门合成一个“更新门”的新门。而更新门的存在使得网络不用再给出如 LSTM 中的额外记忆状态,仅需将输出的结构作为新的记忆状态向后不断循环传递,从而简化了网络模型结构。

GRU 通过上一个传输下来的状态 h_{t-1} 和当前节点的输入 x_t 来获取重置门 r_t 和更新门 z_t 的状态。其更新记忆阶段的更新表达式为:

$$\tilde{h}_t = \text{Tanh}(x_t W_{hx} + r_t \odot h_{t-1} W_{hh} + b_h) \quad (1)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (2)$$

式中, \tilde{h}_t 为当前候选隐藏层状态,包含了 x_t 的信息和 h_{t-1} 的选择性保留; W_{hx} 、 W_{hh} 均为隐藏状态对应的权重; b_h 为隐藏状态对应的偏置。

虽然 GRU 有效解决了长程依赖问题,但缺乏对未来时刻信息的参考,以至于无法应对传感器在采集过程中因客观原因造成的不确定性问题。因此,双向门控循环单元(Bi-GRU)作为能同时学习历史时刻信息和未来时刻信息的新结构被提出。其结构见图 2。

3.2 注意力机制

注意力机制(Attention Mechanism)通过注意力权重的再分配可达到聚焦关键信息和过滤无




图 2 Bi-GRU 结构图

Fig. 2 Bi-GRU structure diagram

关信息的目的。注意力模块的工作原理为:①对特征图 Feature map 进行全局池化 F_{sq} 降维处理;②将降维处理的特征提取结果输入到后续的全连接层 F_{ex} 中,经压缩处理生成不同的通道注意力权重;③将生成的注意力权重与输入的 Feature map 逐通道相乘,赋予每个通道不同的注意力权重,以提升有效特征并减少无关特征,从而自适应地校准通道,增加网络的精度^[7]。注意力模块示意图见图 3。




图 3 注意力模块示意图

Fig. 3 Schematic diagram of the attention module

3.3 基于注意力机制和多传感器信息驱动的深度神经网络(Bi-GRU-Attention)

Bi-GRU-Attention 模型示意图见图 4, Bi-GRU-Attention 模型结构参数见表 1。




图 4 Bi-GRU-Attention 模型示意图

Fig. 4 Schematic diagram of Bi-GRU-Attention model

表 1 Bi-GRU-Attention 模型结构参数

Tab. 1 Bi-GRU-Attention model structure parameters

网络层	输出数据维度	参数/个
BiGRU_1	(None, 64, 50)	8 046
BiGRU_2	(None, 128, 50)	49 536
BiGRU_3	(None, 256)	197 376
Dropout 层	(None, 256)	0
注意力层	(None, 256)	4 360
全连接层	100	25 700
输出层	1	101
参数总计		285 137

3.4 水轮发电机组故障预测系统

针对水轮发电机组在复杂工况条件下的故障预测需求,本文提出了基于注意力机制和多传感器信息驱动模型的水轮发电机组故障预测系统,其流程见图 5。具体步骤如下。

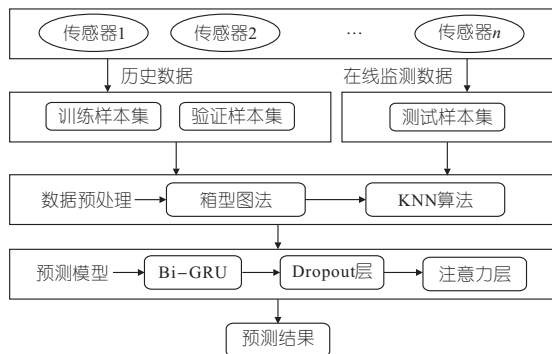


图 5 水轮发电机组故障预测系统设计流程图

Fig. 5 Flow chart of design of fault prediction system for hydro-generator unit

步骤 1 对传感器采集到的水轮机数据集进行异常值判定和缺失值填补处理,再将预处理后的历史数据集划分为所需要的样本训练集和样本测试集。

步骤 2 将多传感器融合的信号输入到 Bi-GRU 层中自适应提取时序特征,并通过注意力层进行权重再分配,得到带有注意力权重的高维特征。

步骤 3 将带有注意力权重的高维特征输入到全连接层中进行特征整合后实现故障预测。

4 结果与分析

4.1 模型验证

为验证所提模型的优越性,选择了三种传统预测模型进行对比,即支持向量回归机(SVR)、极限学习机(ELM)和门控单元循环网络(GRU)。为更好地反映模型的预测精度,引入三个评价指标对模型进行评价,分别为相对误差(R_{RE})、均方根误差(R_{RMSE})和平均误差(M_{MAE})。

不同模型评价指标对比见表 2,不同模型对水轮发电机组导轴承的振动预测结果对比见图 6。由表 2 可知:①本文模型与其他模型相比,三种评价指标均有很好的表现;②本文模型在所有模型中具有最小的 R_{RE} 、 M_{MAE} 和 R_{RMSE} ;③本文模型与 GRU 模型相比, M_{MAE} 、 R_{RMSE} 误差分别降低了 57.79%、56.42%,与其他模型相比,减少的误差更大。由图 6 可知,与其他模型相比,本文模型预测精度最高,与观测数据最接近。由此验证了本文模型可行、有效。

表 2 不同模型评价指标对比

Tab. 2 Comparison of evaluation index with different models

模型	R_{RE}	M_{MAE}	R_{RMSE}	模型	R_{RE}	M_{MAE}	R_{RMSE}
SVR	0.034	5.47	6.71	GRU	0.016	2.63	3.19
ELM	0.078	15.02	15.06	本文模型	0.007	1.11	1.39




图 6 不同模型预测结果对比

Fig. 6 Comparison of prediction results of different models

4.2 运行效果

利用湖南省某水电站^{#8}机组 8 月在线监测数据来验证水轮发电机组故障预测系统的有效性,预测结果见图 7。由图 7 可知,预测数据趋势与监测数据趋势具有较好的拟合性,该方法有效预测了水轮发电机组未来一段时间内的振动趋势,预测数据可有效地实现水轮发电机组的故障预警。




图 7 8 月数据验证结果对比

Fig. 7 Comparison of data verification results in August

5 结论

a. 针对大数据背景下的水轮发电机组故障预测需求,本文提出了一种基于注意力机制和多传感器信息驱动模型(Bi-GRU-Attention)的水轮发电机组故障预测系统。

b. 与 SVR、ELM 和 GRU 模型相比, Bi-GRU-Attention 模型显著降低了预测误差,极大地提升了预测精度。

c. 实际应用结果表明,本文方法有效预测了水轮发电机组的振动趋势,且与监测数据具有较好的拟合性,实现了水轮发电机组的故障预警。

的敏感性最高,转轮故障的敏感性最低,在水导轴承故障的敏感性分析中,轴承温升影响较大。针对导水机构故障、中间节点导叶故障的敏感性影响远高于接力器故障和顶盖故障,且导叶故障中剪断销剪断的敏感性最高,其次为导叶漏水严重、开度信号报警和摩擦装置报警。水轮机故障的贝叶斯网络模型得出的数据和实际故障影响程度较为相符,具有可参考性。

5 结 论

a. 为解决水轮机故障诊断过度依赖专家经验且效率低的现状,构建了水轮机故障的故障树模型,将故障树模型与贝叶斯网络模型形成映射,利用贝叶斯网络模型的反向诊断技术实现故障诊断和定位,并将故障诊断以概率量化的形式体现。

通过敏感性分析获取根节点对叶节点的影响程度,提升了贝叶斯网络模型诊断的准确性,为检修工作人员提供了参考意见。

b. 现阶段仅在水轮机故障诊断中应用了贝叶斯网络诊断模型,未来应进行多元耦合的贝叶斯故障诊断。

参 考 文 献:

[1] 李俊川,胡葛庆,秦国军,等. 贝叶斯网络理论及其在设备故障诊断中的应用[J]. 中国机械工程,2003(10):92-96,6.
 [2] 周忠宝,马超群,周经伦,等. 基于贝叶斯网络的多态故障树分析方法[J]. 数学的实践与认识,2008(19):89-95.
 [3] 于劲松,沈琳,唐获音,等. 基于贝叶斯网络的故障诊断系统性能评价[J]. 北京航空航天大学学报,2016,42(1):35-40.

Research on Fault Diagnosis of Hydraulic Turbine Based on Bayesian Network

SUN Shao-nan, LI Bo-yu, NIE Xiang-tian

(School of Water Conservancy, North China University of Water Resources and Electric Power, Zhengzhou 450000, China)

Abstract: In order to solve the current situation that hydraulic turbine fault diagnosis relies excessively on expert experience and has low efficiency, the historical data of hydraulic turbine fault and relevant expert experience were used to establish the fault tree model for seeking the mapping between risk hidden danger and fault diagnosis. Through the conversion of fault tree model and Bayesian network model, the probability importance and sensitivity of root node were deeply studied by using the reverse diagnosis technology of Bayesian network. Hydraulic turbine components and fault causes were inferred to realize the fault diagnosis.

Key words: Bayesian networks; fault diagnosis; fault trees; sensitivity analysis

 (上接第 197 页)

参 考 文 献:

[1] 杜义,周建中,单亚辉,等. 基于 EMD-BPNN 的水电机组空蚀故障诊断[J]. 水电能源科学,2018,36(3):157-160.
 [2] 杨彤,王卫玉,张培,等. 基于 CEEMDAN 和混合灰狼算法优化 SVM 的水电机组故障诊断方法[J]. 水电能源科学,2022,40(3):195-198.
 [3] 刘涵. 水电机组多源信息故障诊断及状态趋势预测方法研究[D]. 武汉:华中科技大学,2019.
 [4] YEWANG CHEN, XIAOLIANG HU, WENTAO FAN, et al. Fast density peak clustering for large scale data based on kNN[J]. Knowledge-based systems, 2020,187:104824.
 [5] HE Z C, QIU Y, LI E, et al. Analysis on loudness of exhaust noise and improvement of exhaust system based on structure-loudness mode[J]. Applied acoustics, 2019,105:104-112.
 [6] 倪祥龙,石长安,麻曰亮,等. 基于 Bi-LSTM 的电子装备故障预测方法研究[J/OL]//航空兵器:1-9. [2022-05-19].
 [7] SANGHYUN WOO, JONGCHAN PARK, JOON-YOUNG LEE, et al. CBAM: Convolutional Block Attention Module[EB/OL]. <https://doi.org/10.48550/arXiv.1807.06521>,2018-07-17.

Attention Based Mechanism and Multi-sensor Information Driven Fault Prediction System for Hydro-generating Units

TAN Gang¹, DU Lei-hao¹, HU Bian², HE Zhi-cheng¹

(1. State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Hunan University, Changsha 410082, China; 2. Hunan Wuling Power Technology Co., Ltd., Changsha 410004, China)

Abstract: To meet the fault prediction needs of hydro-generator units in the context of big data, combining the characteristics of the attention mechanism with good feature extraction ability and the advantages of model robustness for multi-sensor information driving, this paper proposed a fault prediction system of hydro-generating units based on the attention mechanism and multi-sensor information driving. The system was applied to on-line monitoring of unit # 8 in August for a hydropower station in Hunan Province. The actual operation results show that the system can effectively predict the vibration trend of the hydro-generator set and realize the intelligent prediction of the hydro-generator.

Key words: hydro-generators; deep learning; multi-sensor drive; attention mechanism; fault prediction