

Research on Condition Assessment of Airborne Anemometer in Wind Farms

Shuai Zhong Qingcan Long Pengju Gou Xian Wang*

School of Mechanical Engineering, Hunan University of Science and Technology, Xiangtan, Hunan, 411201, China

Abstract

The anemometer is one of the most critical sensors in wind turbines, and its operational status is essential for the safe and efficient operation of wind turbine systems. In this paper, we propose a condition assessment method for onboard anemometers in wind farms. Using deep learning techniques, we develop a predictive model that effectively captures the information correlation between measurement data from the target anemometer and neighboring anemometers. The condition assessment is achieved by analyzing the residual errors between the actual measurements of the target anemometer and the predicted values from the deep learning model. Simulation studies based on field data demonstrate that the proposed method can accurately reflect the actual condition of anemometers and provide effective fault warnings.

Keywords

Anemometer; Condition Assessment; Deep Learning

风电场机载风速仪状态评估研究

钟帅 龙庆灿 苟鹏举 王宪*

湖南科技大学机电工程学院, 中国·湖南 湘潭 411201

摘要

风速仪是风电机组最为关键的传感器之一, 它的状态对于风电机组的安全高效运行有着至关重要的作用。本文提出了一种风电场机载风速仪状态评估方法, 采用深度学习方法构建一种充分提取目标风速仪测量数据与位置相近的其他风速仪测量数据之间信息关联的风速仪测量数据预测模型, 通过分析目标风速仪实际测量值与深度学习模型预测值的残差实现风速仪状态评估。以现场数据为基础的仿真研究表明, 本文方法能准确反映风速仪实际状态, 可用于风速仪故障预警。

关键词

风速仪, 状态评估, 深度学习

1 引言

风能是一种具备大规模利用条件的可再生能源, 在全球追求绿色发展和能源转型的背景下, 风能的重要性不断攀升。Global wind energy council 发布的《GWEC global wind report 2024》显示, 2023 年全球新增风电装机容量达到创纪录的 117GW, 较 2022 年增长 50%^[1]。风电机组运行环境极其恶劣, 虽然设计和制造技术水平在不断进步, 故障率仍然居高不下, 重大事故时有发生, 风电机组可靠性仍然是一个

突出的问题。

风电机组的控制系统需要依据风速调整变桨、偏航和发电机等核心子系统的状态, 从而实现对风能的有效利用^[2]; 在不同的风速条件下风电机组的输出功率和关键部件振动、温度水平等则是评价风电机组健康状态的重要指标。风速信号由风电机组的机载风速仪获取, 风速仪的状态对于风电机组的安全高效运行有着至关重要的作用。

近年, 随着物联网、智慧城市等技术的快速发展以及高端装备的不断升级, 传感器及传感系统自身状态评估引起了越来越多的关注^[3]。基于深度学习的方法是传感器及传感系统状态评估领域最为活跃的研究方向^[4]。深度学习具有更强大的特征提取能力以及处理复杂、高维数据的能力^[5]。常见的深度学习模型包括 CNN^[6]、LSTM^[7]和门控循环单元 (GRU)^[8]等。Wang H 等人^[9]提出一种 CNN 结合小波变换的传感器异常评估模型, 用于自动驾驶汽车传感器的异常评估。Lin W 等人^[10]提出一种领域知识引导的图卷积网络 (MGCN) 结合门控循环单元 (GRU) 的传感器状态评估模型,

【基金项目】湖南省重大标志创新示范工程 (2022XK2301)

【作者简介】钟帅 (2000-), 男, 硕士, 从事风电大数据挖掘分析、深度学习等研究。

【通讯作者】王宪 (1982-), 男, 博士, 教授, 博士生导师, 从事工业环境下的视觉测量与机器学习, 工业大数据挖掘与利用等研究。

实现核电站压水反应堆上多类型传感器的状态评估与异常隔离。

虽然风电机组上部部署着大量传感器，其中很多传感器的测量数据和风速还存在很强的相关性。但上述相关性的具体模式会随着风电机组控制系统命令域参数的改变而改变，而控制系统命令域参数又与测量得到的风速有关。因此，大多数传感器测量量和风速之间耦合着极其复杂的因果关系，不适宜作为风速仪测量数据预测模型的输入，模型可使用的输入通常只有风电场中位置相近的其他风速仪。此外，受地形地貌影响，多风速仪之间时空信息关联是极其复杂、不便于利用的。与其他传感器的状态评估相比，风速仪的状态评估存在可利用的信息来源少，信息来源与目标风速仪监测量之间关联特性复杂等难点问题。

为了满足实际风电场中对风速仪状态进行全面可靠评估的需求，进而为风电场的安全运行和高效管理奠定基础，本文提出一种风电场机载风速仪状态评估方法。构建一个基于深度学习方法风速仪测量数据预测模型，通过在正常数据中模拟故障数据的仿真研究，验证评估方法的有效性。

2 提出的方法

2.1 整体架构

图1为提出的方法整体架构。使用邻近的风电机组风速仪测量值预测目标风电机组风速仪估计值；利用风电机组无故障运行期间的历史数据训练风速仪测量数据预测模型，使用模型和另外一部分风电机组无故障运行期间的历史数据统计计算传感器正常状态下的模型预警阈值 TH；将邻近的风电机组实时风速仪测量值输入预测模型，计算模型的实时数据预测残差，然后将预测残差与设定的预警阈值 TH 对比，判断目标风速仪的实时健康状态。




图1 提出的方法整体架构

2.2 风速仪测量数据预测模型

本文构建一个基于深度学习的风速仪测量数据预测模型，模型由 CNN 层、LSTM 层和全连接层组成。图2为风速仪测量数据预测模型整体结构图。

直接将风电机组风速仪测量值引入预测模型进行训练会导致模型的收敛速度变慢以及性能下降。在训练模型之

前，统计所有风电机组风速仪训练数据的均值和标准差，对所有原始数据统一进行 Z-score 标准化操作以优化训练效果，如下式所示：

$$Sw_a = \frac{w_a - \mu}{\sigma}$$

其中 w_a 是第 a 台风电机组风速仪的原始测量值， Sw_a 是第 a 台风电机组风速仪标准化后的测量值， μ 为所有训练数据的风速均值， σ 为标准差。




图2 风速仪测量数据预测模型整体结构图

对原始数据标准化以后，构造预测模型的输入序列。CNN 层通过卷积计算提取输入序列中不同位置风电机组风速仪数据的空间特征，通过池化对特征进行降采样保留关键信息的同时减少运算数据量。采用 4×4 个大小为 1×1 的卷积核，选择 Relu 作为激活函数，使用池化窗口大小为 2 的最大池化方法。

LSTM 层通过其内部的记忆单元和门控机制提取输入数据的时间序列特征。CNN 层输出中各时刻风速仪的空间特征按照时间顺序依次输入 LSTM 单元进行时间序列特征提取。最后，模型通过全连接层将 LSTM 层的输出从隐藏表示空间映射到模型输出空间，模型最后输出为目标风电机组风速仪预测值。

3 仿真研究

3.1 仿真参数设置

实验及仿真数据均来源于华中某山地风电场 2MW 直驱风力发电机组的 SCADA 系统 (Supervisory Control and Data Acquisition System, SCADA System)，数据时间分辨率为 10min。选择风电场中位置相近的、记录数据全面的 18~24 号风电机组作为研究对象。将 21 号风电机组风速仪作为本文状态评估方法的目标风速仪，其余六台风电机组风速仪测量值为风速预测模型的输入。选取 20040 组风电机组无故障运行期间的数据训练预测模型（数据时间分辨率为 10min），2100 组风电机组无故障运行期间的测试数据计算风速仪正常状态下预测残差的均值 mean 和标准差 std，并依据 $\text{mean} + 3\text{std}$ 设置预警阈值 TH。

表1为风速仪测量数据预测模型的超参数，其它训练相关的超参数设置如下：输入序列时间步长为 7，输出序列时间步长为 1；batch size 大小设置为 32；epoch 设置为

50; 初始学习率为 0.001, 采用每训练 10 个 epoch 后学习率减半的学习率衰减策略; 训练优化器为 Adam; 损失函数为均方误差 (MSE)。实验算法是在深度学习工作站 (Intel(R) Xeon(R) Gold 6139M CPU, NVIDIA Geforce RTX 3080 10GB GPU, 128GB RAM) 上通过 Python3.9 编程实现。

表 1 风速仪测量数据预测模型超参数设置

Network Layer	Hyperparameter	
CNN Layer	In channel	6
	Kernel number	48
	Kernel size	1
	Max pool	2
LSTM Layer	Input size	24
	Hidden size	24
	Layers num	1

SCADA 系统收集数据会因为通信系统故障或者维修等原因导致部份数据缺失。本文的模型训练数据中使用临近的有效记录值对缺失值进行补全, 以确保训练数据的连续性; 对预测数据的所有缺失值统一进行 0 值补全。

为了更清晰的将风速仪性能状态呈现, 将风速仪测量数据预测模型的预测残差序列的绝对值进行滑动窗口平均后作为评估风速仪状态的指标。

$$re_i = \frac{1}{k} \sum_{j=0}^k |y_{i-j} - x_{i-j}|$$

式中, re_i 为第 i 时刻的残差绝对值, k 为滑动窗口大小, y_{i-j} 为第 $i-j$ 时刻风速预测模型的预测值, x_{i-j} 为第 $i-j$ 时刻目标风速仪真实值。

3.2 目标风速仪出现故障的状态评估仿真

仿真数据选取 2017 年 7 月 21 日 9:25 至 2017 年 8 月 14 日 16:35 共 3500 组风电机组实际运行期间的数据。在仿真数据的两个时间段对 21 号风电机组的风速仪 (即目标风速仪) 模拟卡死和固定偏差两种不同的故障。卡死故障为将目标风速仪的测量值置为 m/s 的恒定数值; 固定偏差故障为在目标风速仪的测量值上叠加一个 1m/s 固定偏差模拟。

图 3(a) 为卡死故障预测残差曲线, 故障发生时预测残差迅速超过预警阈值 TH, 残差最大值达到 12.66m/s。图 3(b) 为固定偏差故障预测残差曲线, 在模拟故障时间段预测残差明显超出了预警阈值 TH, 且维持在较高水平。本文方法能及时、有效的对这两种故障进行预警。

4 结论

为在实际风电场中实现对风速仪状态的全面可靠评估, 进而为风电场的安全、高效运行奠定基础, 本文研究了一种风电场机载风速仪状态评估方法。通过构建一种风速仪测量数据预测模型, 充分提取目标风速仪测量数据与位置相近的其他风速仪测量数据之间的信息关联, 对模型预测残差进行阈值判断实现风速仪状态评估。仿真研究结果表明本文方法在两种故障发生时的变化与风速仪实际状态相符, 能用于风

速仪故障预警。




图 3 目标风速仪存在故障的状态评估结果 (a) 卡死故障 (b) 固定偏差故障

参考文献

- [1] Council G W E. GWEC global wind report 2024[R]. Global wind energy council, 2024.
- [2] Han J, Wang X, Yang X, et al. Yaw system restart strategy optimization of wind turbines in mountain wind farms based on operational data mining and multi-objective optimization[J]. Engineering Applications of Artificial Intelligence, 2023, 126: 107036.
- [3] 张世栋,左新斌,孙勇,等.一种配电主设备分布式状态传感器可靠性评估方法[J].华北电力大学学报(自然科学版),2021,48(01):33-41.
- [4] Sharifani K, Amini M. Machine learning and deep learning: A review of methods and applications[J]. World Information Technology and Engineering Journal, 2023, 10(07): 3897-3904.
- [5] 龙寰,杨婷,徐劲辉,等.基于数据驱动的风电机组状态监测与故障诊断技术综述[J].电力系统自动化,2023,47(23):55-69.
- [6] 陶彦亭,王霄,吴青,等.基于CNN-BiGRU的海上风电机组异常状态监测[J/OL].机床与液压,1-8[2025-03-21].
- [7] Yu Y, Si X, Hu C, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. Neural computation, 2019, 31(7): 1235-1270.
- [8] Mim T R, Amatullah M, Afreen S, et al. GRU-INC: An inception-attention based approach using GRU for human activity recognition[J]. Expert Systems with Applications, 2023, 216: 119419.
- [9] Wang H, Li Y F. Wavelet-powered hierarchical frequency filtering framework for autonomous vehicle sensors fault diagnosis and correction under open environments[J]. Engineering Applications of Artificial Intelligence, 2024, 136: 108848.
- [10] Lin W, Miao X, Chen J, et al. Fault detection and isolation for multi-type sensors in nuclear power plants via a knowledge-guided spatial-temporal model[J]. Knowledge-Based Systems, 2024, 300: 112182.