

6-23-2021

## Prediction Method for Health Degree of Front Bearing of Wind Turbine Generator and Implementation

Yin Shi

1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China; ;2. Zhong Neng Power-Tech Development Co., LTD, Beijing 100034, China;

Guolian Hou

1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China; ;

Chi Yan

2. Zhong Neng Power-Tech Development Co., LTD, Beijing 100034, China;

Linjuan Gong

1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China; ;

*See next page for additional authors*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Prediction Method for Health Degree of Front Bearing of Wind Turbine Generator and Implementation

## Abstract

**Abstract:** Aiming at the deterioration trend of front bearing of doubly-fed wind turbine generator, a new combined modeling method is proposed to predict health degree of front bearing of generator. *The GMM is used to identify operating conditions of wind turbines.* The temperature model of front bearing based on ELM is established respectively in each sub-condition. *Combining with temperature residual characteristics and time-frequency characteristics of vibration signal,* the health degree of front bearing is calculated. *Based on attention mechanism, the Bi-LSTM neural network is proposed to model and predict health degree of front bearing.* The result shows that the combined modeling method has high accuracy and generalization ability.

## Keywords

wind turbine, front bearing of generator, attention mechanism, Bi-LSTM, health degree

## Authors

Yin Shi, Guolian Hou, Chi Yan, Linjuan Gong, and Xiaodong Hu

## Recommended Citation

Yin Shi, Hou Guolian, Chi Yan, Gong Linjuan, Hu Xiaodong. Prediction Method for Health Degree of Front Bearing of Wind Turbine Generator and Implementation[J]. Journal of System Simulation, 2021, 33(6): 1323-1333.

# 风电机组发电机前轴承健康度预测方法及实现

尹诗<sup>1,2</sup>, 侯国莲<sup>1</sup>, 迟岩<sup>2</sup>, 弓林娟<sup>1</sup>, 胡晓东<sup>1</sup>

(1. 华北电力大学控制与计算机工程学院, 北京 102206; 2. 中能电力科技开发有限公司, 北京 100034)

**摘要:** 针对双馈式风电机组发电机前轴承劣化趋势问题, 提出了一种新的组合建模方法对发电机前轴承健康度进行趋势预测。采用高斯混合模型(Gaussian Mixture Model, GMM)对机组运行工况进行辨识, 并在各个子工况内分别建立基于极限学习机(Extreme Learning Machine, ELM)的发电机前轴承温度模型, 将温度残差特征与前轴承振动信号时频域特征相融合, 并计算前轴承健康度, 提出基于注意力机制的双向长短期记忆(Bi-directional Long Short Term Memory, Bi-LSTM)神经网络对前轴承健康度进行建模并预测其趋势。实验结果表明: 该组合建模方法具有较高的准确度和泛化能力。

**关键词:** 风电机组; 发电机前轴承; 注意力机制; 双向长短期记忆; 健康度

中图分类号: TK83; TP391.9

文献标志码: A

文章编号: 1004-731X (2021) 06-1323-11

DOI: 10.16182/j.issn1004731x.joss.20-0148

## Prediction Method for Health Degree of Front Bearing of Wind Turbine Generator and Implementation

Yin Shi<sup>1,2</sup>, Hou Guolian<sup>1</sup>, Chi Yan<sup>2</sup>, Gong Linjuan<sup>1</sup>, Hu Xiaodong<sup>1</sup>

(1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;

2. Zhong Neng Power-Tech Development Co., LTD, Beijing 100034, China)

**Abstract:** Aiming at the deterioration trend of front bearing of doubly-fed wind turbine generator, a new combined modeling method is proposed to predict health degree of front bearing of generator. The GMM is used to identify operating conditions of wind turbines. The temperature model of front bearing based on ELM is established respectively in each sub-condition. Combining with temperature residual characteristics and time-frequency characteristics of vibration signal, the health degree of front bearing is calculated. Based on attention mechanism, the Bi-LSTM neural network is proposed to model and predict health degree of front bearing. The result shows that the combined modeling method has high accuracy and generalization ability.

**Keywords:** wind turbine; front bearing of generator; attention mechanism; Bi-LSTM; health degree

## 引言

近年来, 风能在世界能源结构中的作用越来越重要, 风电将逐步成为继火电、水电之后的第三大能源<sup>[1]</sup>。双馈风力发电机组由于所需变频器容量小、造价低、重量轻且运输方便等特点, 是目前并网型风电机组中的主力机型, 但由于风电机组运行环境恶劣, 受气象、设备老化等多种不确定因素的

影响, 容易出现机组性能与运行状态劣化, 从而造成关键部件失效<sup>[2-3]</sup>。发电机轴承作为发电机设备核心部件, 一旦损坏其受限于检修过程和设备本身的复杂度往往导致检修时间较长, 不仅影响发电量, 也增加了风电场的运维成本。因此, 较早掌握其健康度水平、及早发现潜在劣化征兆、在可预知情况下合理安排检修对于保障风电机组安全高效运行有着重要的学术研究和工程应用价值。

收稿日期: 2020-03-28 修回日期: 2020-06-05

基金项目: 国家重点研发计划(2019YFB1505402); 国家自然科学基金(61973116)

第一作者: 尹诗(1988-), 男, 博士生, 工程师, 研究方向为风电机组故障预警、风电大数据分析。E-mail: yinshi502@163.com

国内外学者针对风电机组发电机轴承等大部件设备的健康度研究集中在劣化度与状态评估 2 个方面。文献[4]利用非线性状态估计(NSET)方法建立齿轮箱轴承温度模型并计算温度残差,当残差均值或标准差超出设定阈值则进行预警;文献[5]提出了采用改进辅助分类生成对抗网络(AC-GAN)的风电机组主轴承故障诊断方法,将机组振动数据处理为二维矩阵,通过判别器与生成器博弈达到平衡,提高小样本非平衡场景下故障识别准确率;文献[6]提出一种异常数据重建的风电机组故障预警方法,利用改进的衰退指标预警潜在故障;文献[7]提出一种基于小波包分解和并行隐马尔可夫的风电机组易损部件健康评价方法,引入信息熵计算评价模型中的权重,以模型输出对数似然概率值作为状态评价指标;文献[8]针对齿轮裂纹振动信号,提出基于小波包与倒频谱分析的风电机组齿轮箱齿轮裂纹诊断方法,综合利用 2 种频谱分析方法计算啮合频率和转速频率,从而诊断故障部位和类型。文献[9]提出了一种基于深度卷积特征学习的轴承健康度指标构建方法,通过多次卷积和合并运算从原始振动信号中学习特征,通过非线性变换将特征映射到健康指标,减少了对先验知识的依赖。

以上这些研究方法在不同程度上对风电机组大部件设备的健康度研究起到了推动促进作用,但在如下方面仍需进一步拓展研究:

首先,在数据特征的选择过程中,单一的轴承温度特征或者振动信号特征很难用来表征轴承健康度的劣化趋势,造成其健康度预测精度不高;

其次,在轴承健康度模型建立的过程中,受限于故障样本和建模方法的选择,算法往往大都只考虑数据输入与输出之间的非线性关系建立健康度模型,往往忽略了数据的时间序列特征对健康劣化模型建立的影响;

第三,伴随着模型输入信息量的增加,模型所涵盖的信息量也越大,往往会导致信息过载问题,不仅会影响建模效率,也会影响建模精度。

本文在总结前人研究成果及研究盲点的基础上,将发电机前轴承温度残差特征和振动时频域特

征相融合,利用增加注意力机制的 Bi-LSTM 神经网络对发电机前轴承健康度建模并进行趋势预测。

## 1 建模方法设计

双馈式风电机组发电机轴承在运行过程中,由于变频技术的引入,导致其失效形式变得多样。常见的失效模式有:疲劳剥落、磨损或擦伤、压痕、塑性变形与断裂、电蚀和腐蚀、胶合等<sup>[10]</sup>。

不论发电机轴承出现何种故障模式,都会引起发电机异常运转,振动数据中体现出振动和噪声的急剧增加,SCADA 数据中体现出轴承温度的异常上升。因此,本文将发电机轴承温度和振动信号作为核心研究对象,开展双馈式风电机组发电机前轴承健康度建模及趋势预测,其整体建模方法设计流程图如图 1 所示。

首先,将参与模型训练和测试的风电机组 SCADA 数据进行预处理,并在此基础上利用 GMM 算法对机组运行工况进行辨识。根据运行工况不同建立 3 个子工况空间,在各个子工况空间内分别建立基于 ELM 算法的风电机组发电机前轴承温度模型并计算其温度残差特征。

其次,将发电机前轴承振动信号进行小波降噪,并在不同子工况下提取时域特征和频域特征并与前轴承温度残差特征相融合,从而避免单一数据特征对后续健康度模型建立的局限和偏差,能够最大限度的挖掘轴承劣化过程中温度特征和振动特征的变化,提升了健康度模型精度。

最后,采用基于注意力机制的 Bi-LSTM 神经网络对发电机前轴承健康度进行建模并进行趋势预测。Bi-LSTM 神经网络结构中输入门、遗忘门、更新门和输出门的设计,加之将前向 LSTM 神经网络和反向 LSTM 神经网络叠加在一起,使其更适用解决以长时间序列数据为特征的设备健康度劣化问题。通过引入注意力机制,在众多输入信息中聚焦于对模型输出更为关键的信息,降低对其他信息的关注度,甚至过滤掉无关信息,解决了健康度模型训练中信息过载问题,提高模型学习的效率和准确性,使其更加有利于工程应用。

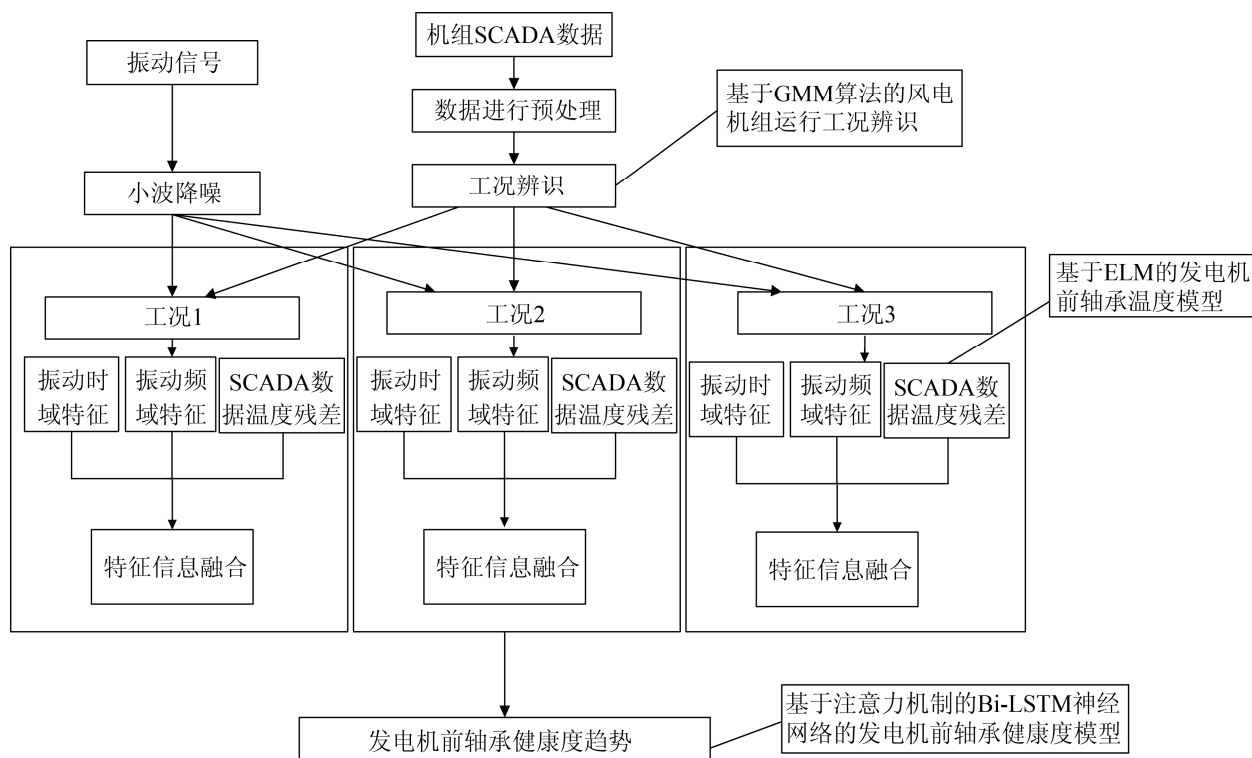


图 1 风电机组发电机前轴承健康度建模方法

Fig. 1 Modeling method for health degree of front bearing of wind turbine generator

## 2 算法原理及实现

### 2.1 数据预处理

在风电机组实际运行过程中, 因传感器故障、光纤环网通讯中断、风电机组控制系统宕机或掉电、数据采集系统接口故障、采集软硬件宕机等情况影响, 需要在模型训练和测试前对数据预处理。

数据预处理的 6 个详细步骤, 如图 2 所示。

(1) 数据排序: 将机组 SCADA 数据按照采集时间标签先后顺序进行排序。

(2) 数据去重: 将前一刻和后一刻相同的数据剔除。

(3) 数据阈值过滤: 将超出阈值范围的数据剔除。

(4) 数据停机点去除: 由于风电机组停机状态下轴承的转速接近于零, 无法在数据中体现出轴承的运行状态, 因此将停机状态下数据剔除。

(5) 数据归一化: 将参与训练和测试的 SCADA 数据进行归一化处理, 数据归一化公式为

$$x'_t = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中:  $x_t$  为  $t$  时刻 SCADA 时间序列数据;  $x_{\min}$  为时间序列数据中的最小值;  $x_{\max}$  为时间序列数据中的最大值;  $x'_t$  为归一化后的  $t$  时刻数据。



图 2 风电机组 SCADA 数据预处理流程

Fig. 2 Pre-processing of wind turbines' SCADA data

(6) 选取参与后续发电机前轴承温度模型训练和测试 SCADA 数据: 利用决策树计算 SCADA 数据特征贡献度, 见表 1 所示。根据表 1 的结果, 8 个参数的累计贡献率已达到 90% 以上, 因此, 发电机前轴承温度模型输入选择表 1 中风速、有功功率、实际扭矩、发电机转速、桨角、无功功率、机舱温度、环境温度 8 个参数。综合考虑前轴承温度模型训练时间及 SCADA 数据信息价值的稀疏性, 将秒级数据计算其 10 min 数据最大值、最小值和平均值作为温度模型训练数据和测试数据的输入, 发电机前轴承温度 10 min 平均值作为温度模型输出。

表 1 SCADA 数据的特征贡献度

Tab. 1 Characteristic contribution of SCADA data

排名	参数	特征贡献率/%	累计贡献率/%
1	风速	0.24	0.24
2	有功功率	0.15	0.39
3	实际扭矩	0.14	0.53
4	发电机转速	0.12	0.65
5	桨角	0.09	0.74
6	无功功率	0.08	0.82
7	机舱温度	0.05	0.87
8	环境温度	0.04	0.91

## 2.2 基于 GMM 的风电机组运行工况辨识

GMM 算法是多个高斯分布函数的线性组合, 通常用于解决同一集合下数据包含多种不同分布的情况, 每个高斯分布是一个聚类中心<sup>[11]</sup>。

单高斯模型的概率密度函数为

$$N(\mathbf{x} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{D/2} |\boldsymbol{\Sigma}|^{1/2}} \exp\left[-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right] \quad (2)$$

式中:  $\mathbf{x}$  为  $D$  维向量;  $\boldsymbol{\mu}$  为  $D$  维均值;  $\boldsymbol{\Sigma}$  为  $D \times D$  维协方差矩阵。

GMM 的概率密度函数为

$$p(\mathbf{x}) = \sum_{k=1}^K \varphi_k N(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \quad (3)$$

式中:  $K$  为高斯混合模型中高斯模型数量,

$$\sum_{k=1}^K \varphi_k = 1 \text{ 且 } 0 \leq \varphi_k \leq 1.$$

风电机组在实际运行过程中, 风速、有功功率、实际扭矩、发电机转速等变化幅度较大, 而温度特征、振动时频域特征和机组运行工况具有很强的相关性, 利用 GMM 算法对机组运行工况进行辨识, 可提高后续建模精度。

根据双馈式风电机组输出功率和发电机转速的关系, 分为最大风能追踪区、恒转速区、恒功率区 3 个运行区<sup>[12]</sup>。基于 GMM 算法的机组工况辨识同样建立 3 个子工况空间, 工况 1 是风电机组出力相对较低的工况, 对应功率控制中最大风能追踪区; 工况 3 是风电机组出力相对较高的工况, 对应恒功率区; 工况 2 介于 2 种工况之间, 基本对应功率控制中恒转速区。

将生成的每个高斯模型中数据期望值作为多维特征点, 代表隶属于本高斯模型中有效数据点的特征。基于 GMM 算法的机组工况辨识如图 3 所示, 每个工况的多维特征点如表 2 所示。




图 3 基于 GMM 算法的机组工况辨识

Fig. 3 Identification of wind turbine working conditions based on GMM algorithms

表 2 GMM 生成的多维特征点

Tab. 2 Multidimensional feature points generated by GMM

工况	多维特征点		
	风速/ (m·s <sup>-1</sup> )	发电机转速/ (r·min <sup>-1</sup> )	有功功率/kW
1	7.85	1 470	385
2	10.54	1 718	1 089
3	16.58	1 775	1 520

### 2.3 基于 ELM 的发电机前轴承温度模型

ELM 极限学习机是一种基于前馈神经网络构建的机器学习方法。对于单隐层神经网络, ELM 可以随机初始化输入权重和偏置得到相应的输出权重。

给定  $N$  个任意的样本  $(x_i, t_i)$ , 对于一个有  $L$  个隐层节点的单隐层神经网络可以表示为

$$o_j = \sum_{i=1}^L \beta_i g(W_i \cdot x_j + b_i), j = 1, 2, \dots, N \quad (4)$$

式中:  $g(x)$  为隐含层激活函数;  $W_i$  为输入权重,  $\beta_i$  为输出权重;  $b_i$  为第  $i$  个隐含层单元的偏置;  $W_i \cdot x_j$  为两者之间的内积。

ELM 的学习目标为输出误差最小, 表示为

$$\sum_{j=1}^N \|o_j - t_j\| = 0 \quad (5)$$

存在  $\beta_i$ ,  $W_i$  和  $b_i$ , 即:

$$\|H(\hat{W}_i, \hat{b}_i) \cdot \hat{\beta}_i - T\| = \min_{W, b, \beta} \|H(W_i, b_i) \beta_i - T\| \quad (6)$$

传统基于梯度下降的算法需要在迭代的过程中调整所有参数, 而在 ELM 算法中, 一旦输入权重  $W_i$  和隐层的偏置  $b_i$  被随机确定, 隐层的输出矩阵  $H$  就被唯一确定, 输出权重:

$$\hat{\beta}_i = H^+ T \quad (7)$$

式中:  $H^+$  为矩阵  $H$  的 Moore-Penrose 广义逆矩阵<sup>[13]</sup>。

ELM 相较传统神经网络的优点是无需多次迭代训练, 在保证学习精度的前提下具有较快的学习速度。

利用 GMM 算法对机组运行工况进行辨识, 形成各相应工况下的训练样本集, 并在 3 个子工况空间内建立基于 ELM 的发电机前轴承温度模型。

发电机前轴承温度残差的计算公式为

$$R_i = y_i - \hat{y} \quad (8)$$

式中:  $y_i$  为发电机前轴承数据;  $\hat{y}$  为发电机前轴承温度模型输出。

### 2.4 振动信号时频特征和温度残差特征融合

风电机组发电机轴承发生异常时通常会导致

振动信号时频域特征参数发生变化。首先对振动信号进行小波降噪, 然后提取其时频域特征, 其中时域特征为: 有效值、峰峰值、峰值指标、波形指标、脉冲指标、裕度指标、峭度指标 7 个, 具体表达式见表 3。

表 3 振动信号时域特征指标

Tab. 3 Time domain characteristic index of vibration signal

特征名称	表达式
有效值	$x_{rms} = \sqrt{\frac{1}{N} \sum_{n=1}^N x^2(n)}$
峰峰值	$x_{p-p} = x_{max} - x_{min}$
峰值指标	$C_f = x_{max} / x_{rms}$
波形指标	$S_f = x_{rms} / \frac{1}{N} \sum_{n=1}^N  x(n) $
脉冲指标	$I_f = x_{max} / \frac{1}{N} \sum_{n=1}^N  x(n) $
裕度指标	$CL_f = x_{max} / \frac{1}{N} \sum_{n=1}^N \sqrt{ x(n) ^2}$
峭度指标	$CL_f = x_{max} / \frac{1}{N} \sum_{n=1}^N \sqrt{ x(n) ^2}$

注:  $x(n)$  为特征序列向量,  $N$  为特征序列向量长度,  $x_{max}$ ,  $x_{min}$ ,  $x_{rms}$  分别为特征序列向量最大值、最小值、有效值

发电机前轴承振动信号为加速度高频振动信号, 振动频谱反映信号在不同频率下幅值分布情况, 轴承正常机组和异常机组的频谱结构有很大差别, 通过频谱分析可以判断轴承健康程度。根据傅里叶级数理论, 假设离散化后的振动信号时间序列为  $x(n)$ , 采样频率为  $f_s$ , 采样点数为  $N$ , 频谱为  $s(k)$ ,  $k=1, 2, \dots, K$ ,  $K$  为谱线数。本文采用 6 个频域指标, 表达式见表 4。

表 4 中频域特征指标  $F_1$  反映振动能量的大小;  $F_2$  反映信号频谱与信号频谱均值的偏离程度;  $F_3$  反映了信号频谱相对均值的不对称程度;  $F_4$  反映了信号在均值处峰值的大小;  $F_5$  反映了信号主频带位置的变化;  $F_6$  反映了频谱集中或分散的程度<sup>[14]</sup>。

综上, 发电机前轴承健康度模型输入特征向量见表 5 所示。



表4 振动信号频域特征指标

Tab. 4 Frequency domain characteristic index of vibration signal

特征名称	表达式
$F_1$	$F_1 = \sum_{k=1}^K s(k) / K$
$F_2$	$F_2 = \sum_{k=1}^K (s(k) - F_1)^2 / (K - 1)$
$F_3$	$F_3 = \sum_{k=1}^K (s(k) - F_1)^3 / (K(\sqrt{F_2})^3)$
$F_4$	$F_4 = \sum_{k=1}^K (s(k) - F_1)^4 / (K(F_2)^2)$
$F_5$	$F_5 = \sum_{k=1}^K f_k s(k) / \sum_{k=1}^K s(k)$
$F_6$	$F_6 = \sqrt{\frac{\sum_{k=1}^K (f_k - F_5)^2 s(k)}{K}}$

表5 健康度模型输入特征向量

Tab. 5 Input eigenvector of health model

名称	输入特征向量
SCADA 数据特征(1个)	发电机前轴承温度残差
振动信号时域特征(14个)	加速度有效值、加速度峰峰值、加速度波形指标、加速度峰值指标、加速度脉冲指标、加速度裕度指标、加速度峭度指标、速度有效值、速度峰峰值、速度波形指标、速度峰值指标、速度脉冲指标、速度裕度指标、速度峭度指标
振动信号频域特征(18个)	6个加速度频谱特征, 6个速度频谱特征, 6个加速度包络频谱特征。(频谱特征的计算公式见表4)

其中, 发电机前轴承加速度高频振动信号为每 8 h 采集一次, 而发电机前轴承温度残差特征为每 10 min 均值, 需要将发电机前轴承振动信号时频域特征与温度残差特征按照统一时间尺度下进行融合, 具体做法为: 将振动信号每 8 h 时间点采集的数据和该时间点对应的 10 min 区间内的前轴承温度残差均值, 两者相结合, 最终得到参与发电机前轴承健康度模型的输入特征向量。

发电机前轴承健康度模型的输出为前轴承健康度, 根据文献[15]中论述的轴承劣化度, 计算发电机前轴承健康度为

$$y_i = t_i / T \quad (9)$$

式中:  $t_i$  为前轴承出现警告的时刻到当前时刻的时间跨度;  $T$  为前轴承出现警告的时刻到前轴承更换时刻的时间跨度。前轴承出现警告时刻由专业人员每天根据振动诊断平台确认并标记。

## 2.5 基于注意力机制的 Bi-LSTM 神经网络的发电机前轴承健康度模型

深度神经网络模型是一种拥有多个非线性映射层级, 能够对输入信号逐层抽象并提取特征, 挖掘出更深层次的潜在规律<sup>[16]</sup>。在众多深度神经网络模型中, LSTM 神经网络层中加入记忆和遗忘长期特征的变量, 通过遗忘门, 更新门和输出门 3 个门实现了对长短期记忆的控制。图 4 为 LSTM 神经网络结构。




图4 LSTM神经网络结构

Fig. 4 Network structure of LSTM

LSTM 的前向计算公式为

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (10)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (11)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (12)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (13)$$

$$h_t = o_t \tanh(c_t) \quad (14)$$

$$y_t = \tanh(W_y h_t + b_y) \quad (15)$$

式中:  $i_t$ ,  $f_t$ ,  $c_t$ ,  $o_t$  分别代表输入门、遗忘门、



细胞状态、输出门;  $W$  和  $b$  分别为对应的权重系数矩阵和偏置项;  $\sigma$  和  $\tanh$  分别为 sigmoid 和双曲正切激活函数<sup>[17]</sup>。

Bi-LSTM 是对传统 LSTM 的扩展, Bi-LSTM 是利用前向 LSTM 神经网络和反向 LSTM 神经网络叠加在一起组成, 输出由 2 个 LSTM 的状态共同决定, 算法既考虑时序数据的过去, 也考虑时序数据的将来, 因此具有较强的时间特征<sup>[18]</sup>。而注意力机制是模拟人把注意力集中在重要信息上, 忽略次要信息。通过计算注意力概率分布, 对事物的关键性部分分配更重的权重, 进而进行突出, 起到模型优化的作用。

注意力机制已成为神经网络结构中重要组成部分, 并在情感分析、语义识别、计算机等相关领域有着较为成功的应用案例<sup>[19-21]</sup>, 但在设备劣化相关方面鲜有相关研究。风电机组发电机前轴承健康劣化趋势的渐变过程同样是典型的时间序列数据, 为解决以长时间变化为特征的设备健康度劣化问题, 同时提高健康度模型建模效率, 本文将基于注意力机制的 Bi-LSTM 神经网络引入到风电机组发电机前轴承健康度预测模型中。

基于注意力机制的 Bi-LSTM 神经网络框图如图 5 所示。构建注意力机制如式(16)~(19)所示。

$$e_i = \tanh(W_s h_i + b_s) \tag{16}$$

$$a_i = \frac{\exp(e_i)}{\sum_{i=1}^T \exp(e_i)} \tag{17}$$

$$s = \sum_{i=1}^T a_i h_i \tag{18}$$

$$y = \text{softmax}(W_o s + b_o) \tag{19}$$

式中:  $h_i$  为隐藏层特征;  $a_i$  为注意力权值, 依据注意力权值对隐含层中所有节点向量进行加权, 得到最终特征向量  $s$ ;  $W_o$  为权重矩阵;  $b_o$  为偏置量;  $y$  为算法输出<sup>[22]</sup>。

### 3 实例分析及验证

由于发电机前轴承损坏案例较少, 本文选取河北某 3 个风电场同一机型共计 25 台 1.5 MW 风力

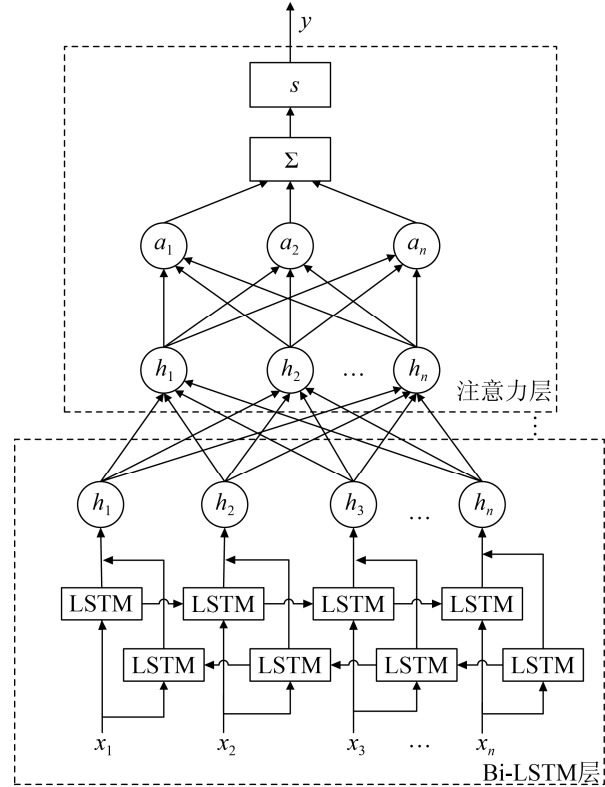


图 5 基于注意力机制的 Bi-LSTM 神经网络框图  
Fig. 5 Block diagram of Bi-LSTM neural network based on attention mechanism

发电机组(包含 15 台发电机前轴承正常机组和 10 台发电机前轴承异常机组)进行方法验证。该机组主要参数为: 切入风速为 3 m/s, 切出风速为 25 m/s, 在风速为 11.5 m/s 时进入恒功率阶段, 发电机为双馈绕线式异步发电机。

发电机前轴承温度模型训练和测试选择 10 台发电机前轴承正常机组, 每台机组选取任意 2 个月 SCADA 数据。按照 2.1 章节的要求对参与训练和测试的数据进行预处理。为保证温度模型训练过程的适应性, 训练所需 SCADA 数据覆盖风速 3~25 m/s 的正常运行工况, 预处理后数据共计 34 800 条, 按照 80%训练集、20%测试集进行数据划分。

ELM 算法参数选择为: 输入层有 24 个神经元(8 个参数的 10 min 数据最大值、最小值、平均值), 隐层设置 48 个神经元, 输出层共 1 个神经元(发电机前轴承温度十分钟数据均值), 激活函数选择 sigmoid 函数。

3 个子工况下基于 ELM 的发电机前轴承温度模型训练图见图 6, 图中红色虚线为发电机前轴承温度模型输出, 蓝色实线为 SCADA 数据输出, 绿色点划线为两者之间的残差。

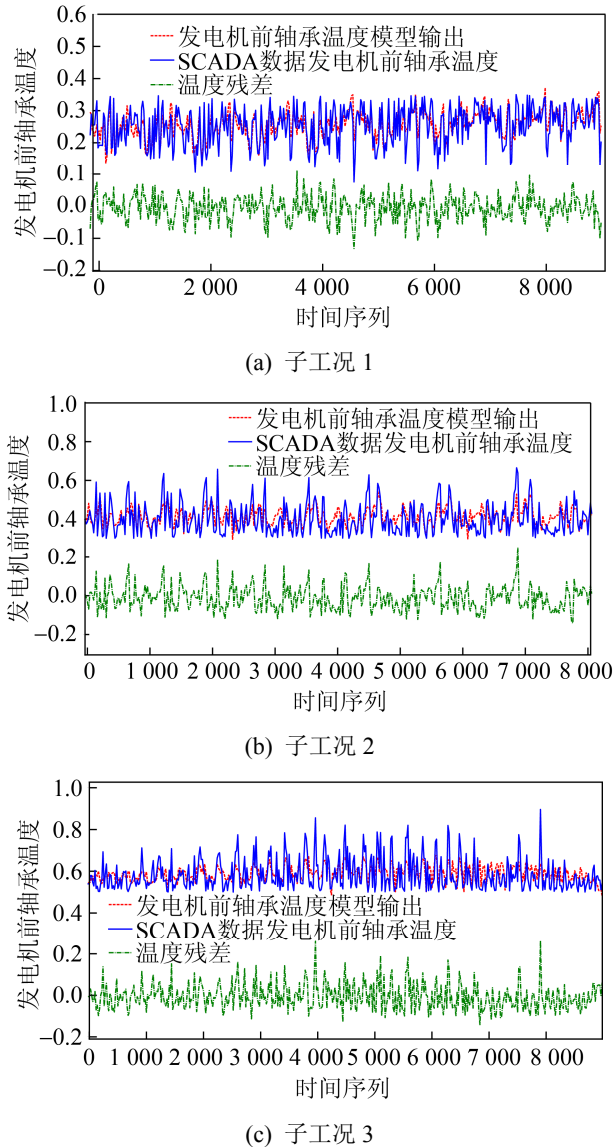


图 6 基于 ELM 的发电机前轴承温度模型训练图

Fig. 6 Training diagram of front bearing temperature model of generator based on ELM

基于 ELM 算法的发电机前轴承温度模型测试样本数据在 3 个子工况下的误差评价指标如表 6 所示。

表 6 温度模型测试样本数据评价指标

Tab. 6 Evaluation indexes of test sample data of temperature model

评价指标	子工况 1	子工况 2	子工况 3
MAE	0.047	0.04	0.045
MSE	0.038	0.027	0.029
R <sup>2</sup>	0.687	0.727	0.698

$$\text{平均绝对误差: } MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (20)$$

$$\text{均方误差: } MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (21)$$

$$\text{判定系数: } R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (22)$$

从表 6 可以得出, ELM 算法在 3 个子工况空间内均能很好的拟合发电机前轴承温度。

发电机前轴承健康度模型选取与温度模型训练和测试不同的剩余 15 台机组, 其中: 模型训练和测试选取 13 台机组(发电机前轴承正常机组 4 台, 异常机组 9 台), 剩余的 2 台机组(1 台发电机前轴承正常机组, 1 台发电机前轴承异常机组)用来测试模型的准确性和泛化性。在数据选择过程中, 前轴承正常机组选择任意 6 个月连续时间段内的数据, 前轴承异常机组选取振动诊断平台判定并核实的前轴承异常告警到更换时间段内的运行数据。按照 2.4 章节说明将振动信号提取时频域特征并按照时间序列提取对应时间段的发电机前轴承温度残差组成新的特征, 作为健康度模型的输入, 按照式(9)计算相应健康度作为模型的输出, 健康度范围为[0, 1], 健康度为 0 为前轴承正常, 1 为前轴承异常更换, 0~1 之间标识健康度劣化趋势。将振动信号时频域特征和温度特征融合后数据共计 8 945 条, 按 80%训练集、20%测试集进行划分。

本文采用深度学习 Keras 框架搭建基于注意力机制的 Bi-LSTM 神经网络, 参数选取输入层维数设置为 33, 隐藏层维数设置为 128, 注意力权重维数设置为 128, 输出层维数设置为 1, 注意力权重初始化系数采用均匀分布  $U(-0.25, 0.25)$ , 初始学习

率为 0.001, Dropout 设置为 0.5, 批处理数量选择 200, 样本训练选取 30 个 epochs, 采用适应性矩估计 Adam 优化器, 损失函数采用交叉熵。

发电机前轴承健康度模型测试样本数据在循环神经网络(Recurrent Neural Network, RNN), LSTM, Bi-LSTM, 注意力机制的 Bi-LSTM, 单独将温度残差特征或振动特征作为模型特征输入时其模型误差评价指标如表 7 所示。


表 7 健康度模型测试样本数据评价指标  
Tab. 7 Evaluation indexes of health degree model of test sample data

评价指标	MAE	MSE	R <sup>2</sup>
RNN	0.065	0.020	0.65
LSTM	0.051	0.016	0.72
Bi-LSTM	0.042	0.009	0.76
attention+ Bi-LSTM	0.028	0.005	0.80
单独温度残差特征+attention+ Bi-LSTM	0.09	0.025	0.46
单独振动特征+ attention+ Bi-LSTM	0.045	0.011	0.71

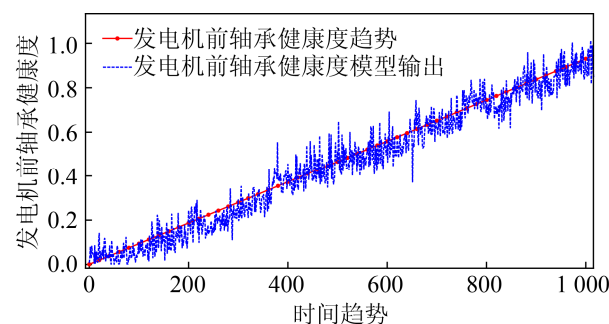
从表 7 中可以得出, 在前轴承温度残差特征和振动特征相结合的前提下, 基于注意力机制的 Bi-LSTM 神经网络在测试集上的准确率最高, RNN 神经网络在测试集中的准确率最低。增加注意力机制能够很好的提升发电机前轴承健康度模型精度, 同时, 温度残差特征和振动时频域特征相结合能够更好的提升发电机前轴承健康度模型精度。

下一步验证基于注意力机制的 Bi-LSTM 神经网络健康度模型在剩余 2 台机组(72#机组发电机前轴承正常、23#机组发电机前轴承异常)中的准确度和泛化能力, 其健康劣化趋势如图 7 所示。

由图 7 可以看出, 发电机前轴承正常机组健康度模型输出始终在 0.05 以下, 发电机前轴承异常机组健康度模型输出能够较好的跟踪健康度从 0~1 的劣化趋势。



(a) 72#机组发电机前轴承健康度趋势图(前轴承正常)



(b) 23#机组发电机前轴承健康度趋势图(前轴承异常)

图 7 机组健康度劣化趋势图

Fig. 7 Trend of health degree deterioration of wind turbines

2 台测试机组的在单独温度残差特征、单独振动特征和将两者融合下作为健康度模型输入下误差评价指标如表 8 所示。

表 8 发电机前轴承健康度模型评价指标  
Tab. 8 Evaluation indexes of health degree model of generator front bearing

发电机组	MAE	MSE	R <sup>2</sup>
72#机组(特征融合)	0.025	0.000 8	0
72#机组(单独温度残差特征)	0.05	0.003	0
72#机组(单独振动特征)	0.037	0.001 6	0
23#机组(特征融合)	0.044	0.003	0.92
23#机组(单独温度残差特征)	0.105	0.026	0.55
23#机组(单独振动特征)	0.077	0.01	0.78

从表 8 中可以得出, 将温度残差特征和振动时频域特征相结合能够更好的提升发电机前轴承健康度模型的精度和泛化能力。

结果表明: 基于注意力机制的 Bi-LSTM 神经网络能够很好的跟踪发电机前轴承健康度劣化趋势, 说明本文提出的建模方法具有很好的准确度和泛化能力, 方法也可推广至其它同类轴承的健康趋

势预测中。

## 4 结论

本文以风电机组发电机前轴承健康度为研究对象,采用 GMM 算法对风电机组运行工况进行辨识,在 3 个子工况空间内建立基于 ELM 的风电机组发电机前轴承温度模型,计算其温度残差特征,将该特征和振动信号时频域特征相结合,并建立基于注意力机制的 Bi-LSTM 神经网络对发电机前轴承健康度进行趋势预测。通过对某大型风电场风电机组进行仿真分析,实验结果表明,基于注意力机制的 Bi-LSTM 神经网络对比 RNN、LSTM、Bi-LSTM 更适用解决以时序数据为特征的设备健康度劣化问题,同时在健康度模型中,将发电机前轴承温度模型残差特征和振动信号时频域特征相融合,比单独使用温度残差特征或振动数据时频域特征提升了其建模精度和泛化能力。

## 参考文献:

- [1] 刘振亚. 中国电力与能源[M]. 北京: 中国电力出版社, 2012.  
Liu Zhenya. China Power and Energy[M]. Beijing: China Electric Power Press, 2012.
- [2] Tchakoua P, Wamkeue R, Ouhrouche M, et al. Wind Turbine Condition Monitoring: State-of-the-Art Review, New Trends, and Future Challenges[J]. Energies (S1996-1073), 2014, 7(4): 2595-2630.
- [3] 金晓航, 孙毅, 单继宏, 等. 风力发电机组故障诊断与预测技术研究综述[J]. 仪器仪表学报, 2017, 38(5): 1041-1053.  
Jin Xiaohang, Sun Yi, Shan Jihong, et al. Fault Diagnosis and Prognosis for Wind Turbines: An Overview[J]. Chinese Journal of Scientific Instrument, 2017, 38(5): 1041-1053.
- [4] 李大中, 常城, 许炳坤. 基于样本优化的风电机组齿轮箱轴承温度预测[J]. 系统仿真学报, 2017, 29(2): 374-380.  
Li Dazhong, Chang Cheng, Xu Bingkun. Wind Turbine Gearing Temperature Prediction based on Sample Optimization[J]. Journal of System Simulation, 2017, 29(2): 374-380.
- [5] 黄南天, 杨学航, 蔡国伟, 等. 采用非平衡小样本数据的风机主轴承故障深度对抗诊断[J]. 中国电机工程学报, 2020, 40(2): 563-574.  
Huang Nantian, Yang Xuehang, Cai Guowei, et al. A Deep Adversarial Diagnosis Method for Wind Turbine Main Bearing Fault with Imbalanced Small Sample Scenarios[J]. Proceedings of the CSEE, 2020, 40(2): 563-574.
- [6] 刘帅, 刘长良, 甄成刚. 基于数据分类重建的风电机组故障预警方法[J]. 仪器仪表学报, 2019, 40(8): 1-11.  
Liu Shuai, Liu Changliang, Zhen Chenggang. Fault Warning Method for Wind Turbine based on Classified Data Reconstruction[J]. Chinese Journal of Scientific Instrument, 2019, 40(8): 1-11.
- [7] 郑小霞, 李美娜. 基于小波包和并行隐马尔科夫的风力机易损部件健康状态评价[J]. 太阳能学报, 2019, 40(2): 370-379.  
Zheng Xiaoxia, Li Meina. Health State Evaluation based on Wavelet Packet and PCHMM for Vulnerable Components of Wind Turbines[J]. Acta Energetica Sinica, 2019, 40(2): 370-379.
- [8] 罗毅, 甄立敬. 基于小波包与倒频谱分析的风电机组齿轮箱齿轮裂纹诊断方法[J]. 振动与冲击, 2015, 34(3): 210-214.  
Luo Yi, Zhen Lijing. Diagnosis Method of Turbine Gearbox Gear Crack based on Wavelet Packet and Cepstrum Analysis[J]. Journal of Vibration and Shock, 2015, 34(3): 210-214.
- [9] Liang G, Saibo X, Naipeng L, et al. Deep Convolution Feature Learning for Health Indicator Construction of Bearings[C]// 2017 Prognostics and System Health Management Conference, 2017: 1-6.
- [10] 马宏忠, 李思源. 双馈风力发电机轴承故障诊断研究现状与发展[J]. 电机与控制应用, 2018, 45(9): 117-124.  
Ma Hongzhong, Li Siyuan. Research Status and Development of Bearing Fault Diagnosis for Doubly-fed Induction Generator[J]. Electric Machines & Control Application, 2018, 45(9): 117-124.
- [11] Zivkovic Z. Improved Adaptive Gaussian Mixture Model for Background Subtraction[C]// The 17th International Conference on Pattern Recognition, ICPR 2004, IEEE, 2004: 1-4.
- [12] 孙漂. 双馈式异步风力发电机发电过程的建模与仿真研究[D]. 重庆: 重庆大学, 2016.  
Sun Li. Modeling and Simulation of Doubly-fed Induction Wind Power System[D]. Chongqing: Chongqing University, 2016.
- [13] Huang G B, Zhu Q Y, Siew C K. Extreme Learning Machine: Theory and Applications[J]. Neurocomputing (S0925-2312), 2006, 70(1/3): 489-501.

<http://www.china-simulation.com>

• 1332 •

- [14] 董正. 基于 AdaBoost\_RVM 的滚动轴承剩余寿命预测方法研究[D]. 哈尔滨: 哈尔滨理工大学, 2018.  
Dong Zheng. Research on Remaining Useful Life Prediction Method of a Rolling Bearing based on AdaBoost\_RVM[D]. Harbin: Harbin University of Science and Technology, 2018.
- [15] Wang Q, Bo Z, Ma H, et al. A Method for Rapidly Evaluating Reliability and Predicting Remaining Useful Life using Two-dimensional Convolutional Neural Network with Signal Conversion[J]. Journal of Mechanical Science and Technology (S1976-3824), 2019, 33(6): 2561-2571.
- [16] Lecun Y, Bengio Y, Hinton G. Deep Learning[J]. Nature (S0028-0836), 2015, 521(7553): 436-444.
- [17] Greff K, Srivastava R K, Koutnik J, et al. LSTM: A Search Space Odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems (S1045-9227), 2015, 28(10): 1-11.
- [18] Graves A, Schmidhuber J. Frame Wise Phoneme Classification with Bidirectional LSTM and other Neural Network Architectures[J]. Neural Networks (S0893-6080), 2005, 18(5/6): 602-610.
- [19] 刘全, 梁斌, 徐进, 等. 一种用于基于方面情感分析的深度分层网络模型[J]. 计算机学报, 2018, 41(12): 2637-2652.  
Liu Quan, Liang Bin, Xu Jin, et al. A Deep Hierarchical Neural Network Model for Aspect-based Sentiment Analysis[J]. Chinese Journal of Computers, 2018, 41(12): 2637-2652.
- [20] 任朝淦, 杨燕, 贾真, 等. 基于注意力机制的问句实体链接[J]. 模式识别与人工智能, 2018, 31(12): 1127-1133.  
Ren Chaogan, Yang Yan, Jia Zhen, et al. Attention Mechanism based Question Entity Linking[J]. Pattern Recognition and Artificial Intelligence, 2018, 31(12): 1127-1133.
- [21] Liu J, Wang G, Duan L Y, et al. Skeleton-Based Human Action Recognition with Global Context-Aware Attention LSTM Networks[J]. IEEE Transactions on Image Processing (S1057-7149), 2018, 27(4): 1586-1599.
- [22] Zhou Peng, Shi Wei, Tian Jun, et al. Attention-Based Bidirectional Long Short-Term Memory Networks for Relation Classification[C]// The 54th Annual Meeting of the Association for Computational Linguistics, 2016(2): 207-212.