

DOI: 10.19783/j.cnki.pspc.210090

基于 GRU 和注意力机制的海上风机齿轮箱状态监测

苏向敬, 山衍浩, 周汶鑫, 符杨

(上海电力大学电气工程学院, 上海 200090)

摘要: 海上风电机组齿轮箱运行状态的有效监测和及时预警对海上风机运维工作具有重要意义。为此, 提出一种基于门控循环单元(Gated Recurrent Unit, GRU)和注意力机制的海上风电机组齿轮箱状态监测方法。在训练阶段, 通过注意力机制自动提取海上风电 SCADA 数据集输入参量与目标建模参量间的关联关系, 同时采用 GRU 网络提取数据间的时序依赖关系, 进而建立风电机组齿轮箱的正常行为模型。在测试阶段, 采用指数加权移动平均值(Exponentially Weighted Moving-Average, EWMA)控制图对目标建模参量实际值和模型预测值间的输出残差进行监控, 实现海上风机齿轮箱运行状态的实时监测和预警。最后基于东海大桥海上风电场真实数据对所提方法的有效性和优越性进行了验证。结果表明: 所提方法对故障和正常运行条件下的海上风电机组齿轮箱状态均可进行有效监测, 且相比现有陆上风机状态监测方法具有更高的精度和可解释性, 并能更早地揭示故障趋势。

关键词: 海上风电机组; 齿轮箱; 状态监测; 门控循环单元; 注意力机制

GRU and attention mechanism-based condition monitoring of an offshore wind turbine gearbox

SU Xiangjing, SHAN Yanhao, ZHOU Wenxin, FU Yang

(College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: The effective monitoring and early warning of an offshore Wind Turbine (WT) gearbox operating state is of great significance to its operation and maintenance. Therefore, a Condition Monitoring (CM) method for an offshore WT gearbox based on Gated Recurrent Unit (GRU) and attention mechanism is proposed. In the training phase, the attention mechanism is introduced to automatically extract the correlation between the input features and the target modeling feature of an offshore WT Supervisory Control and Data Acquisition (SCADA) dataset. The GRU network is used to effectively extract the temporal relationships between the data, thereby establishing the normal behavior model of the WT gearbox. In the test phase, an Exponentially Weighted Moving-Average (EWMA) control chart is applied to monitor the output residuals between the predicted value and the true value of the target modeling feature, so as to realize real-time monitoring and early warning of the operating status of the gearbox. Finally, the validity and superiority of the proposed method are verified based on real data from the Donghai Bridge offshore wind farm. The results show that the proposed method can effectively monitor the gearbox state under both fault and normal operating conditions, and has higher accuracy and interpretability than the existing onshore monitoring method, and can reveal early failure trends earlier.

This work is supported by the National Natural Science Foundation of China (No. 61873159) and the Project of Science and Technology Commission of Shanghai (No. 18020500700).

Key words: offshore wind turbine; gearbox; condition monitoring; GRU; attention mechanism

0 引言

风能因其清洁性和可持续性在世界范围内受到

广泛关注^[1-5]。相比陆上风电, 海上风电具有更好的风能资源且更接近负荷中心, 已经成为能源市场的重要参与者^[6-9]。但相比陆上风机, 海上风机面临着以下挑战: 首先, 恶劣的运行环境和复杂多变的气象海况导致海上风电机组的故障率更高^[10]; 其次, 受气象和运输条件限制, 海上风电机组的可及性差

基金项目: 国家自然科学基金面上项目资助(61873159); 上海市科委项目资助(18020500700)

且维护周期长,其运维成本可达总收入的25%,比陆上高出10%左右^[11]。上述因素使得以状态监测为基础的状态检修成为海上风机最理想的运维策略^[12],同时也对状态监测方法的有效性和预警时间提出了更高要求。作为风电机组的核心部件,齿轮箱故障引起的停机时间约占总停机时间的50%^[13],对应故障成本居所有部件之首^[11]。故对海上风机齿轮箱进行状态监测以提前发现故障并调整运维计划,对提升机组出力 and 降低运维成本非常关键。

近年来,随着监督控制和数据采集(Supervisory Control And Data Acquisition, SCADA)系统广泛应用于海上风电机组,基于数据驱动的状态监测研究得到大量关注。其中正常行为建模(Normal Behavior Modeling, NBM)是目前普遍采用的一种基于数据驱动的风电机组状态监测策略^[14-17]。该策略在确定模型输入参量的基础上,根据风机正常运行区段SCADA数据搭建目标建模参量的正常行为模型,并输出其在正常运行状态下的预测值。通过对比参量实际值与模型预测值间的残差,实现对部件的状态监测。

但现有基于正常行为建模的风电机组状态监测方法普遍存在以下两方面的不足。

一方面,在输入参量选取上,SCADA系统记录了不同传感器采集的数十个运行参量^[18]。但冗余输入参量将导致训练效率低下,且会因过拟合影响正常行为建模的精度,故有必要对训练正常行为模型的输入参量组合进行选择。目前风机状态监测通常基于领域知识或 Spearman 系数等相关性分析方法选择输入参量组合^[14-17]。上述方法虽考虑了机组各运行参量间的相关性,但其仅保留高于所设定相关度阈值的输入参量,且该阈值设置依赖于专家经验,存在较大主观性。同时只保留部分输入参量会造成参量关联信息的丢失,导致正常行为建模的精度降低。为此,本文采用注意力机制来解决上述问题^[19]。注意力机制能够自动提取SCADA数据集输入参量与目标建模参量的关联关系,并自适应地为各输入参量分配注意力权重,有效避免了传统参量选择方法存在的主观阈值限制;同时该机制可根据注意力权重完成增强关键参量表达并弱化冗余参量的过程,避免了现有参量选择方法因预设阈值选择部分输入参量而导致的关联信息丢失问题,保障了输入参量关联信息的完整性,有助于提高正常行为建模的准确性。

另一方面,在正常行为建模方法的选取上,文献[14]通过径向基神经网络和最小二乘支持向量机建立了基于组合预测的风电机组齿轮箱正常行为监

测模型;文献[15]利用XGBoost算法构建了风机齿轮箱的温度预测模型。上述正常行为建模状态监测研究均基于传统机器学习方法,虽获得了一定的监测效果,但本质上仍属于浅层学习模型,对具有非平稳、非线性和高噪声特性的海上风电SCADA数据的建模能力有限。相比之下,深度学习方法允许多层非线性变换,可更好地提取输入参量间的关系^[20-21]。例如文献[16-17]分别提出基于逐层编码网络和深度神经网络(Deep Neural Network, DNN)的正常行为建模方法,对风电机组主轴承与齿轮箱进行状态监测。实际上,风电机组SCADA数据是一个多维时间序列,当前时刻与历史时刻数据存在着一定时序依赖关系。受单时间点输入及无法挖掘时序依赖关系的限制,上述基于传统机器学习和深度学习方法的正常行为建模存在局限性。相比其他深度学习方法,循环神经网络(Recurrent Neural Network, RNN)引入了循环结构用于挖掘输入序列间的时序依赖关系,具有更高的时序预测精度^[22]。其中,门限循环单元网络(Gated Recurrent Unit, GRU)与长短期记忆网络(Long Short-Term Memory, LSTM)均是改进型RNN,在计及时序依赖关系的同时,能有效解决RNN自身存在的梯度消失缺陷^[22-23]。但与LSTM网络相比,GRU网络具有更少的训练参数,在精度相似的情况下具有更高的模型训练效率^[22],有助于海上风机状态监测的在线部署。GRU网络虽在电力领域逐渐得到关注,但在海上风机状态监测领域尚未应用。

综上,为充分利用参量间的关联关系和时序依赖关系,本文提出了一种基于GRU网络和注意力机制的高精度海上风电机组齿轮箱状态监测方法。一方面,通过注意力机制自动提取输入参量与目标建模参量间的关联关系,在保障输入参量关联信息完整性的同时,避免了现有输入参量选择过程中的主观阈值限制,提高了正常行为建模的准确性;另一方面,通过应用GRU网络有效提取多维SCADA数据间的时序依赖关系,以更早揭示机组早期故障的渐变趋势。最后,基于东海大桥海上风电场真实数据开展了仿真,其结果验证了所提海上风电齿轮箱状态监测方法的有效性和优越性。

1 基于GRU和注意力机制的齿轮箱正常行为模型训练过程

1.1 正常行为模型的时序建模流程

本文基于多维时序SCADA数据进行齿轮箱正常行为建模。正常行为模型的时序建模流程如下:

记风电机组目标建模参数的序列为 $\mathbf{Y} = (y^{(1)}, \dots, y^{(T)}) \in R^T$, 序列长度为 T , $y^{(t)}$ 表示目标建模参数在时刻 t 的测量值。其他运行参量及环境参量数据组成对应时刻的输入序列 $\mathbf{X} = (\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(T)})$, 展开如式(1)所示。其中 $\mathbf{x}^{(t)} = (x_1^{(t)}, x_2^{(t)}, \dots, x_m^{(t)}) \in R^{m \times 1}$ 为 m 个输入参量在时刻 t 的测量值集合, $x_j^{(t)}$ 表示第 j 个运行参量在时刻 t 的测量值。

$$\mathbf{X} = \begin{bmatrix} x_1^{(1)} & \dots & x_1^{(T)} \\ \vdots & & \vdots \\ x_m^{(1)} & \dots & x_m^{(T)} \end{bmatrix} \in R^{m \times T} \quad (1)$$

在此基础上, 风机正常行为建模过程可视为利用 1 至 T 时刻的输入参量测量值序列 \mathbf{X} , 预测 T 时刻的目标建模参量值 $\hat{y}^{(T)}$ 。记模型函数映射为 f_θ , 建模过程可表示为式(2)。

$$\hat{y}^{(T)} = f_\theta(\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(T)}) \quad (2)$$

1.2 参量注意力机制

为保障参量间关联信息的完整性, 同时克服现有参量选择方法的主观阈值限制, 本文在正常行为建模中引入了注意力机制。注意力机制在机器翻译、视频识别等领域有着广泛的应用, 通过模拟人的视觉行为, 将注意力集中于焦点区域, 减少甚至忽略对其他区域的关注^[24-26]。注意力机制可以自适应地为输入参量分配注意力权重, 从而提取 SCADA 数据集输入参量与目标建模参量间的关联关系, 而注意力权重则表征了各输入参量对目标建模参量建模的贡献率。

参量注意力机制的流程如图 1 所示, 以输入序列单时间步长的输入参量向量 $\mathbf{x}^{(t)} = [x_1^{(t)}, x_2^{(t)}, \dots, x_m^{(t)}] \in R^{m \times 1}$ 作为参量注意力机制输入, 根据文献[19]量化当前时刻各输入参量对应的注意力权重, 如式(3)所示; 并通过式(4)中 softmax 函数对各注意力权重做归一化处理^[19], 使其满足权重之和为 1 的概率分布。当前时刻各输入参量归一化后的注意力权重 $\alpha^{(t)}$ 计算如式(4)所示。

$$\mathbf{e}^{(t)} = \sigma(\mathbf{W}\mathbf{x}^{(t)} + \mathbf{b}) \quad (3)$$

式中: $\mathbf{e}^{(t)} = [e_1^{(t)}, e_2^{(t)}, \dots, e_m^{(t)}] \in R^{m \times 1}$; σ 为 sigmoid 激活函数; \mathbf{W} 为可训练系数矩阵; \mathbf{b} 为偏置。

$$\alpha_j^{(t)} = \frac{\exp(e_j^{(t)})}{\sum_{i=1}^m \exp(e_i^{(t)})} \quad (4)$$

将归一化后的注意力权重 $\alpha_j^{(t)}$ 与其相应参量值 $x_j^{(t)}$ 相乘以对第 j 个输入参量进行增强或削弱,

得到加权输入向量 $\mathbf{x}'^{(t)} \in R^{m \times 1}$, 如式(5)所示。

$$\mathbf{x}'^{(t)} = \alpha^{(t)} \square \mathbf{x}^{(t)} = [\alpha_1^{(t)} x_1^{(t)}, \alpha_2^{(t)} x_2^{(t)}, \dots, \alpha_m^{(t)} x_m^{(t)}] \quad (5)$$

值得注意的是, 注意力机制的引入使得所提方法具有了一定的可解释性, 避免了现有模型普遍存在的“黑箱”问题。具体来说, 通过提取每次迭代各输入参量的注意力权重, 可计算当前模型对各输入参量的“关注程度”, 即各输入参量对目标建模参量建模的贡献率。在模型训练过程中, 通过系数迭代对各参量的注意力权重进行再分配, 各参量注意力权重的最终值在模型迭代至收敛时得以确定。通过观察注意力权重的变化趋势及最终结果, 可对所提方法的合理性进行验证。

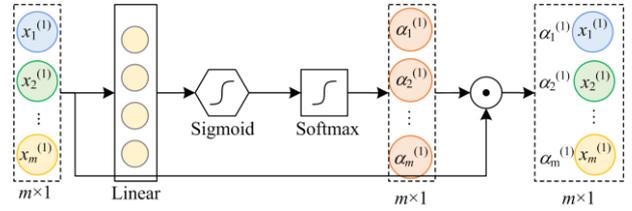


图 1 参量注意力机制

Fig. 1 Illustration of the feature attention mechanism

1.3 海上风机齿轮箱正常行为建模流程

本文提出的海上风机齿轮箱正常行为建模流程如图 2 所示, 主要分为参量注意力层、GRU 层和全连接层。具体而言, 将输入序列 \mathbf{X} 送至注意力层以获得经注意力加权后的新输入序列 \mathbf{X}' ; 随后将 \mathbf{X}' 送至 GRU 层以提取隐藏时序信息; 最后将末端 GRU 单元输出的隐藏时序信息 \mathbf{h}_T 送至全连接层, 以输出该序列对应的目标建模参量预测值 $\hat{y}^{(T)}$ 。模型中各层详细描述如下:

1) 参量注意力层。对于输入序列 \mathbf{X} , 采用参量注意力机制以自动提取输入参量与目标建模参量间的关联关系。通过循环结构对所有时刻各参量分别分配注意力权重, 输出则为考虑各参量注意力权重后的加权新序列 \mathbf{X}' 。

2) GRU 层。输入为加权后的新序列 \mathbf{X}' , 通过搭建单层 GRU 结构捕获数据的时序依赖关系。因序列长度为 T , 输入参量共 m 个, 故 GRU 层由 T 个顺序串联的 GRU 单元组成, 每个 GRU 单元的输入维度为 m 。序列数据将分时刻输入到各单元, 经 GRU 单元提取并向前传递隐藏时序信息, 输出为末端 GRU 单元的输出隐藏状态 \mathbf{h}_T 。更多 GRU 原理和结构, 详见文献[22]。

3) 全连接层。输入为 GRU 层输出的最后隐藏状态 \mathbf{h}_T , 依据式(6)计算输出 T 时刻目标建模参量的预测值 $\hat{y}^{(T)}$ 。

$$\hat{y}^{(T)} = \mathbf{W}_F \mathbf{h}_T + b_F \quad (6)$$

式中: \mathbf{W}_F 为可训练系数矩阵; b_F 为偏置。

记模型所涉及的系数集合为 θ , 以最小化式(7)中的损失函数为训练目标, 对模型中各层系数进行迭代更新, 最终得到目标建模参数的正常行为模型。

$$J(\hat{y}^{(T)}, y^{(T)}, \theta) = \frac{1}{N} \sum_{k=1}^N (\hat{y}_k^{(T)} - y_k^{(T)})^2 \quad (7)$$

式中, N 为样本个数。

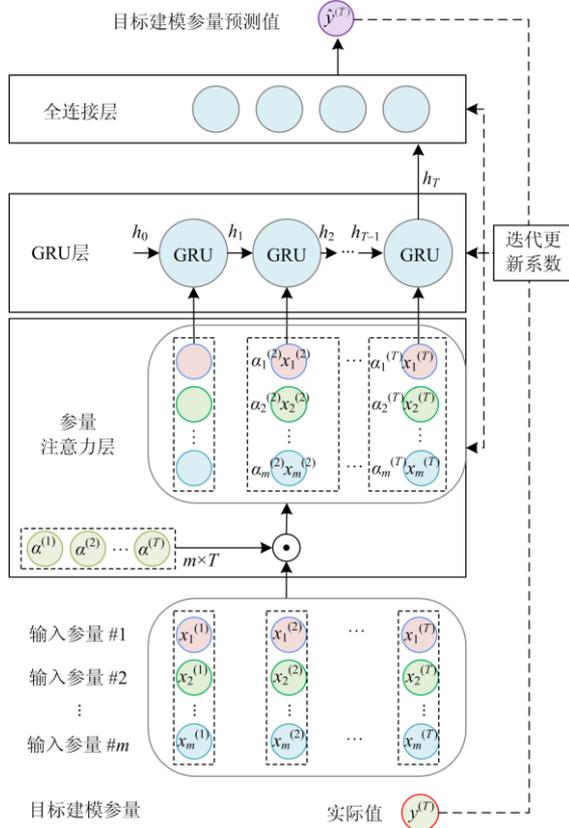


图2 所提齿轮箱正常行为建模流程

Fig. 2 Proposed NBM process of gearbox

2 基于EMWA控制图的齿轮箱正常行为模型测试过程

2.1 EMWA 控制图监测原理

本文所提监测方法基于齿轮箱的正常运行状态建模, 而正常运行状态下目标建模参量实际值与模型预测值之间的残差在零均值附近波动, 故输出残差的变化可揭示潜在的齿轮箱故障。输出残差计算如式(8)所示。

$$R_t = y_t^{(T)} - \hat{y}_t^{(T)} \quad (8)$$

式中: R_t 为时刻 t 的输出残差; $y_t^{(T)}$ 为时刻 t 的实际值; $\hat{y}_t^{(T)}$ 为时刻 t 的模型预测值。

为有效滤除噪声并提高识别精度, 采用 EWMA

控制图对测试集的输出残差序列进行监测^[16]。根据式(9), 计算得到时刻 t 的 EWMA 值:

$$E_{EWMA_t} = \begin{cases} \lambda R_t + (1-\lambda)E_{EWMA_{t-1}} & t > 0 \\ R_{\text{mean}} & t = 0 \end{cases} \quad (9)$$

式中: R_{mean} 为所有正常工况时刻输出残差的均值; $E_{EWMA_{t-1}}$ 为时刻 $t-1$ 的 EWMA 值; λ 为历史数据对当前 EWMA 值的权重, 本文取 0.2^[16]。EWMA 控制图的时间窗口取为测试集长度。

鉴于齿轮箱故障通常伴随着目标建模参量实际值的升高, 从而导致输出残差上升, 故本文仅选择 EWMA 控制图的上限(UCL)用于监测齿轮箱并识别异常状态^[16], 具体计算如式(10)所示。

$$UCL(t) = R_{\text{mean}} + K\sigma_e \sqrt{\frac{\lambda}{2-\lambda} [1 - (1-\lambda)^{2t}]} \quad (10)$$

式中: σ_e 为输出残差的标准差; K 为阈值系数, 依据文献[16]设置为 3。此外考虑到海上风电机组运行环境复杂多变, 易导致短时越限频发, 为避免虚警, 同时考虑到监测方法的性能, 设定 10 min 为越限时长的阈值。即当连续越限超过 10 min 时, 所提在线监测系统将会发出故障告警信号。

2.2 齿轮箱正常行为模型评价指标

本文采用均方根误差(Root Mean Square Error, RMSE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)指标来评价所提正常行为模型对海上风机目标建模参数的拟合能力^[27]。两个指标数值越小, 拟合结果越准确, 具体定义如式(11)和式(12)所示。

$$R_{\text{RMSE}} = \sqrt{\frac{\sum_{k=1}^N (y_k^{(T)} - \hat{y}_k^{(T)})^2}{N}} \quad (11)$$

$$M_{\text{MAPE}} = \frac{100\%}{N} \sum_{k=1}^N \left| \frac{y_k^{(T)} - \hat{y}_k^{(T)}}{y_k^{(T)}} \right| \quad (12)$$

3 海上风机齿轮箱状态监测流程

本文所提海上风机齿轮箱状态监测方法的流程如图 3 所示。

1) 对 SCADA 训练数据集和 SCADA 测试数据集分别进行数据预处理, 获得正常运行训练集以及预处理后测试数据集。

2) 在训练阶段, 输入正常运行训练集, 基于所提方法训练齿轮箱目标建模参数的正常行为模型。

3) 在测试阶段, 将预处理后测试数据集输入已训练的正常运行行为模型, 利用 EWMA 控制图监测目标建模参数的实际值和模型预测值间的输出残差, 并在越限时报警。

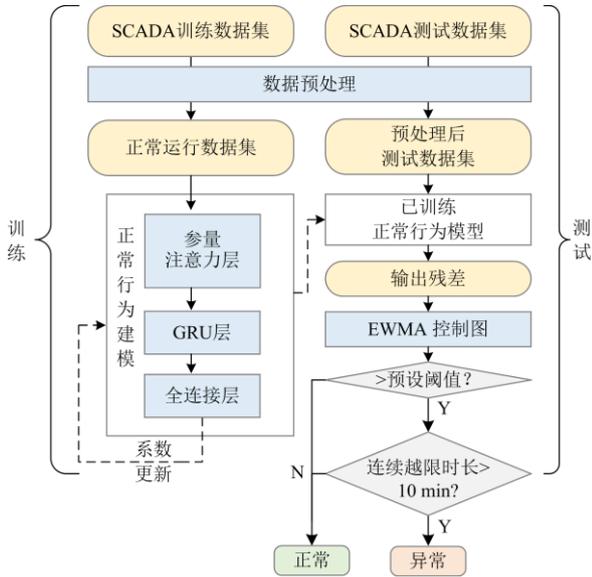


图 3 海上风机齿轮箱状态监测流程

Fig. 3 Offshore WT gearbox CM flowchart

4 算例验证分析

4.1 仿真算例

本文验证算例选用东海大桥海上风电场两台额定功率为 3 MW 的双馈式风电机组, 型号为 SL3000, 具体技术参数见[28]。SCADA 系统的采样周期为 30 s, 数据集记录了海上风机主要部件所对应的运行参量及环境参量共 23 个, 具体如表 1 所示。仿真案例设置方面, 为验证所提状态监测方法的有效性, 本文分别选择齿轮箱故障、正常运行两个案例进行仿真分析; 同时为验证所提状态监测方法的优越性, 本文基于故障案例对比了不同算法对故障状态的监测能力, 并基于正常案例对比了不同算法对齿轮箱目标建模参量进行正常行为建模的精度。

表 1 海上风电 SCADA 数据参量集

Table 1 Offshore WT SCADA data feature set

| 参量 | 单位 | 参量 | 单位 |
|---------------|------------------|---------------|---------------------------|
| 300 柜温度 | °C | 环境温度 | °C |
| 电机非驱动侧轴温 | °C | 电机驱动侧轴温 | °C |
| 叶轮转速 | $r \cdot s^{-1}$ | 电网电流 | A |
| 有功 | kW | 发电机转速 | $r \cdot \text{min}^{-1}$ |
| 风速 | $m \cdot s^{-1}$ | 机舱温度 | °C |
| 变桨力矩 1、2、3 | N·m | 变桨角度 1、2、3 | (°) |
| 变桨电机 1、2、3 温度 | °C | 电机绕组 1、2、3 温度 | °C |
| 齿轮箱油温 | °C | — | — |

仿真数据集选择方面, 20 号风机在 2018 年 12 月发生了齿轮箱故障, 故以该风机为例开展故障状态监测验证, 其对应现场运维日志如表 2 所示。训练集采用正常运行的 2018 年 7 月至 9 月的 SCADA

数据; 测试集采用运行状态逐渐异常的 2018 年 10 月至 12 月 SCADA 数据。同时, 23 号风机在 2018 年全年未记录到齿轮箱故障, 故以该风机为例开展正常状态监测验证, 训练集及测试集的时间范围与 20 号风机案例相同。各数据集情况如表 3 所示, SCADA 系统截取的部分数据如表 4 所示。

表 2 20 号风机现场运维日志

Table 2 Operation and maintenance log of WT #20

| 日期 | 停机原因 | 现场处理情况 |
|------------|-----------|-------------------------|
| 2018/12/12 | 叶轮超速故障 | 风大未出海 |
| 2018/12/14 | 齿轮箱内部异常冲击 | 检查叶轮超速问题, 发现齿轮箱内部异常冲击声响 |
| 2018/12/15 | 齿轮箱内部异常冲击 | 拆除齿轮箱检查, 发现二级行星轮及大齿圈断齿 |

表 3 各数据集情况

Table 3 Overview of datasets

| SCADA 数据集名称 | 样本点总数 | 风机 | 日期 |
|-------------|---------|-----|-------------------|
| 故障案例训练集 | 217 050 | #20 | 20180701—20180930 |
| 故障案例测试集 | 188 906 | #20 | 20181006—20181210 |
| 正常案例训练集 | 217 050 | #23 | 20180701—20180930 |
| 正常案例测试集 | 183 146 | #23 | 20181006—20181208 |

表 4 SCADA 系统中部分数据截面

Table 4 Part of the SCADA data

| 日期 | 风机 | PLC 代码 | 300 柜温度/°C | ... |
|--------------------|-----|--------|------------|-----|
| 2018/10/10 4:57:30 | #20 | 7 | 25.99 | ... |
| 2018/10/10 4:58:00 | #20 | 7 | 25.94 | ... |

4.2 数据预处理与参量设置

在数据预处理阶段, 对于故障及正常案例的训练集, 本文基于可编程逻辑控制器(Programmable Logic Controller, PLC)状态代码对其进行数据预处理, 用以提取正常运行数据^[29]。根据机组运行手册, 仅代码 7 表示机组处于稳定发电的正常运行状态, 故仅保留 PLC 代码为 7 的正常运行数据区间; 同时剔除上述区间中输入参量缺失、有功小于等于零、风速小于切入或大于切出风速的不良数据, 获得正常运行训练集。而对于故障及正常案例的测试集, 通过向前填充方式补全缺失值, 获得预处理后测试集。

在参量设置阶段, 当风机齿轮箱出现故障时, 齿轮箱油温往往会在短时内升高^[15], 故选择齿轮箱油温作为正常行为建模的目标建模参量。在此基础上, 表 1 中其余 22 个运行及环境参量作为输入参量。此外, 为降低输入参量量纲不同对计算结果产生的影响, 对各数据集的输入数据进行归一化处理。

4.3 正常行为模型仿真参数设置

模型参数方面, 本文设定序列长度为 100, 即

利用 1~100 时刻的其他输入参量序列对第 100 时刻的齿轮箱油温进行建模。注意力层及 GRU 层的输入维度为 22，隐藏层维度为 64，层数为 1。模型的学习率设置为 0.001，训练批次设置为 256，迭代次数设置为 1 000 次，优化器选择 Adam 优化器。

4.4 故障状态下的齿轮箱监测

采用故障案例测试集对所提方法性能进行仿真验证，结果如图 4 所示。其中，图 4(a)、4(b)为 20 号风机在整体区间的齿轮箱油温 EWMA 控制图及对应越限时长，图 4(c)、4(d)、4(e)为该风机在故障发生前一周的关键区间内齿轮箱油温拟合情况、EWMA 控制图及对应越限时长。由图 4(a)、4(b)可以看出，在 2018 年 10 月 1 日至 12 月 6 日之间出现了两次越限时长超过 10 min 的情况，经查为风机切换模式所致，除此之外 12 月 6 日前未出现报警情况。

由图 4(c)、4(d)、4(e)可以看出，齿轮箱油温的模型预测值与实际值自 12 月 6 日 17:00 开始出现较大偏差，致使 EWMA 值逐渐上升。当日 18:00，所提方法首次监测到 EWMA 越限情况，越限时长达 46 min 并首次触发警报，此后又出现多次短时越限情况；随后自 12 月 7 日 04:00 时开始，所提方法又监测到多次越限情况，并在 07:30 监测到长达 239 min 的长时越限情况，连续触发警报；随后当天 13:00，所提方法监测到长达 2 468 min 的长时

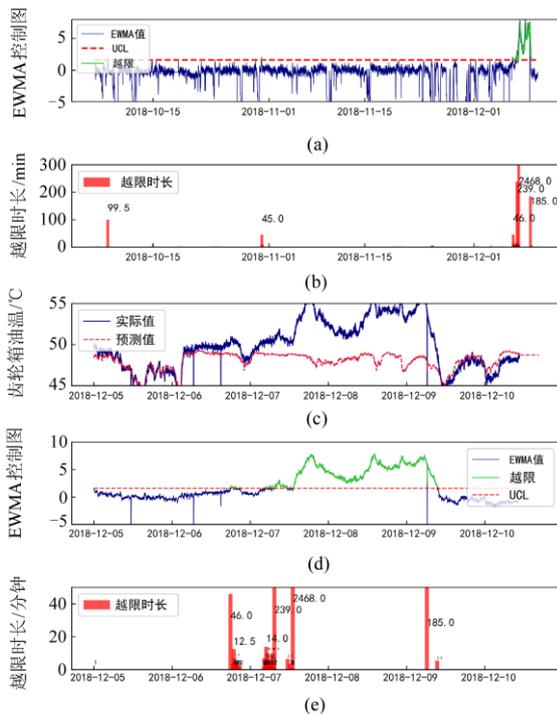


图 4 故障案例的齿轮箱油温监测结果

Fig. 4 Monitoring result of gearbox oil temperature of failure gearbox case

越限情况，并触发警报。与表 2 中的现场检查记录相比，本文所提状态监测方法可提前 8 天发现潜在故障，证明了其对海上风机齿轮箱故障状态监测的有效性。

4.5 正常状态下的齿轮箱监测

除故障状态外，所提方法也可有效监测海上风机齿轮箱的正常运行状态。采用正常案例测试集得到的状态监测结果如图 5 所示，其中图 5(a)展示了 23 号风机在整体区间的齿轮箱油温拟合情况，图 5(b)、5(c)展示了该风机齿轮箱油温 EWMA 控制图及对应越限时长。由图 5(a)、5(b)可以看出，齿轮箱油温的实际值与模型预测值在整体区间内的偏差较小，EWMA 值长期处于 UCL 阈值内。由图 5(c)可以看出，在 11 月 9 日监测到了时长 27 min 的越限现象，通过查询现场运维记录，当日对齿轮箱隔块进行了更换，导致油温异常升高。除此之外，其他时刻的越限时长均未超过 10 min 阈值，不会触发警报。该案例的监测情况与 23 号风机的现场运维记录一致，证明了所提方法对海上风机齿轮箱正常状态监测的有效性。

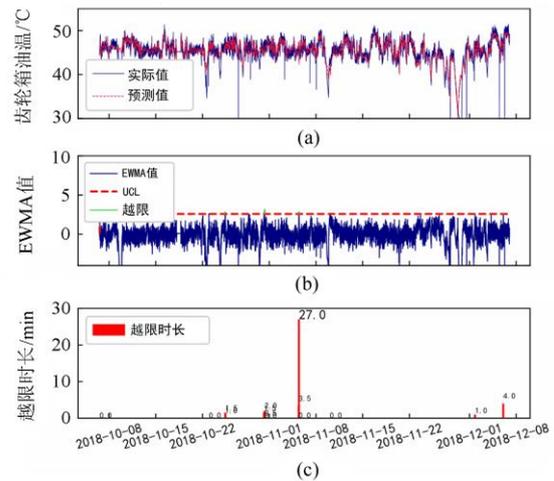


图 5 正常案例的齿轮箱油温监测结果

Fig. 5 Monitoring result of gearbox oil temperature of normal gearbox case

4.6 不同状态监测方法性能对比

为验证本文所提状态监测方法性能的优越性，在相同的数据集及仿真参数设置情况下，分别与 XGBoost、DNN 两种陆上风机常用监测方法及原始 GRU 网络进行仿真对比。在故障案例测试集上的 EWMA 监测结果如图 6 所示，用于衡量各方法对齿轮箱故障状态的监测能力。图 6(a)—6(d)展示范围为整体区间，用于对比各方法的整体建模误差及虚警情况；图 6(e)—6(h)展示范围为故障发生前两周

的关键区间, 用于对比各方法的提前预警时间及对早期故障的监测能力。表 5 则给出了各方法在正常案例测试集上的 RMSE、MAPE 误差指标, 用于衡量各方法建立的正常行为模型的准确性。

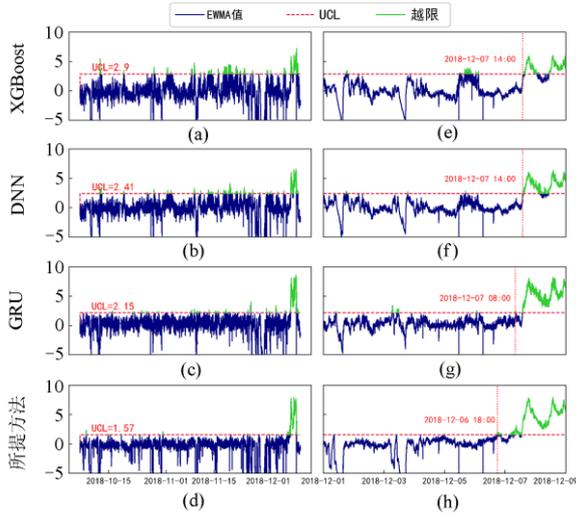


图 6 不同监测算法下齿轮箱油温 EWMA 控制图

Fig. 6 EWMA control chart of gearbox oil temperature in fault case under different algorithms

由图 6(a)—6(d)可看出, 对于 XGBoost、DNN 模型, 其 EWMA 值整体偏高, 表明其输出残差整体偏高, 预测精度较低。同时可以观察到, 其 EWMA 值的波动性更大, 更容易产生虚警。而考虑时序依赖关系的 GRU 网络及本文所提方法在整体监测区段内的 EWMA 值相对较低、波动性更小, 基本不存在虚警现象, 表明考虑时序依赖关系的正常行为建模方法相比传统方法更为准确。另外相比于 GRU 网络, 本文所提方法的整体 EWMA 值更低、波动性更小, 虚警现象也更少, 这表明注意力机制的引入进一步提高了 GRU 网络正常行为建模的准确性。

由图 6(e)—6(h)可以看出, 相比 XGBoost、DNN 模型, GRU 网络以及本文所提方法的预警时间分别提前了 6 h 和 20 h, 表明考虑时序依赖关系可以建立更为准确的正常行为模型, 更早反映机组早期故障的渐变趋势; 由图 6(g)、6(h)可以看出, 相比 GRU 网络, 本文所提方法的预警时间提前了 14 h, 表明所提方法能更早揭示早期故障趋势。同时更低的 EMWA 值也表明了其输出残差普遍较低, 正常行为建模准确度更高。

另外由表 5 可以看出, 相比其他 3 种模型, 所提方法的 R_{RMSE} 、 M_{MAPE} 指标均为最低, 同样表明了该方法具有优越的正常行为建模准确性, 更适合海上风电机组齿轮箱的状态监测。

表 5 监测方案性能对比

| Table 5 Performance comparison of different algorithms | | |
|--|-----------------|--------------------|
| 算法 | 正常案例 R_{RMSE} | 正常案例 $M_{MAPE}/\%$ |
| XGBoost | 2.35 | 3.2 |
| DNN | 1.64 | 2.01 |
| GRU | 1.42 | 1.86 |
| 所提方法 | 1.31 | 1.71 |

4.7 所提方法的可解释性

现有数据驱动状态监测研究普遍存在黑箱问题, 而本文所采用的基于参量注意力机制的 GRU 模型具备一定的可解释性, 可对所提方法的合理性进行验证: 提取正常运行数据集中某序列在模型训练过程中第 1 次、第 300 次、第 600 次、第 900 次(收敛)迭代时各输入参量的注意力权重变化趋势, 如图 7 所示。其中横轴为样本时间点, 纵轴为输入参量, 色块深浅表示参量注意力权重大小, 也表征了各输入参量对目标建模参量建模的贡献率。

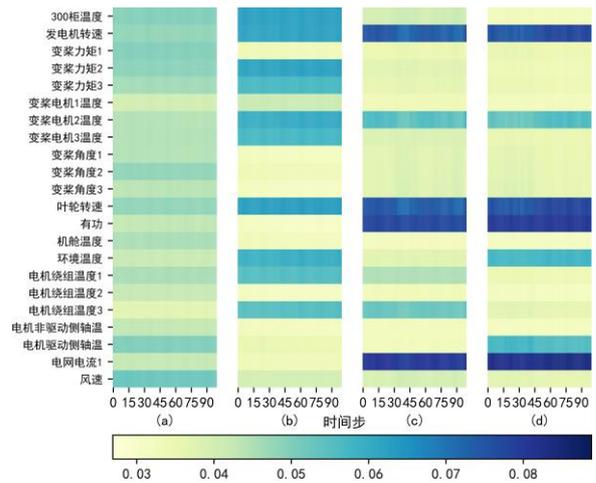


图 7 输入参量注意力权重变化趋势

Fig. 7 Trend of input feature attention weight

由图 7 可以看出: 在模型迭代过程中, 输入参量发电机转速、叶轮转速、有功、电网电流的注意力权重逐渐升高至 0.09, 表明模型认为这些输入参量对目标建模参量齿轮箱油温的正常行为建模贡献率最大; 而输入参量环境温度、变桨电机 2 温度、电机驱动侧轴温的注意力权重升至 0.06; 其他输入参量的注意力权重最后稳定在 0.03 左右。上述结果与领域知识基本一致, 具体来说: 由于齿轮箱油温与风机运行状态紧密相关, 故发电机转速、叶轮转速、有功、电网电流等直接反映风机运行状态的输入参量对齿轮箱油温的正常行为建模极为关键。同时齿轮箱油温受环境温度影响较大, 变桨电机 2 温度、电机驱动侧轴温等输入参量则反映了风机部件

的空间关联，权重也相对较高。而其他输入参量与齿轮箱油温关联不大，其注意力权重相对较低。注意力权重的变化趋势及最终收敛结果证明了本文所提方法可以自行挖掘 SCADA 数据集输入参量与目标参量间的关联关系，也证明了本文所提方法的合理性。

5 结论

为充分利用 SCADA 数据参量间的关联关系和时序依赖关系，本文提出了一种基于 GRU 和注意力机制的海上风电机组齿轮箱状态监测方法，并基于东海大桥海上风电场真实案例进行了仿真测试。主要结论如下：

1) 参量注意力机制的引入可自动提取 SCADA 数据集输入参量与目标建模参量间的关联关系，提高了正常行为建模的准确性。

2) GRU 网络可有效提取多维 SCADA 数据的时序依赖关系，进而更早反映机组早期故障的渐变趋势。

3) 本文所提基于 GRU 和注意力机制的监测方法对故障和正常运行条件下的海上风电机组齿轮箱状态均可进行有效监测；相比传统陆上风机监测方法，具有更高的预测准确性和可解释性，并能更早揭示早期故障趋势。

参考文献

[1] BADAL F R, DAS P, SARKER S K, et al. A survey on control issues in renewable energy integration and microgrid[J]. Protection and Control of Modern Power Systems, 2019, 4(1): 87-113. DOI 10.1186/s41601-019-0122-8.

[2] 张丽英, 叶廷路, 辛耀中, 等. 大规模风电接入电网的相关问题及措施[J]. 中国电机工程学报, 2010, 30(25): 1-9.
ZHANG Liying, YE Tinglu, XIN Yaozhong, et al. Problems and measures of power grid accommodating large scale wind power[J]. Proceedings of the CSEE, 2010, 30(25): 1-9.

[3] 许志恒, 张勇军, 陈泽兴. 考虑 P2G 备用服务的电—气联合网络风电消纳及低碳效益分析[J]. 电力科学与技术学报, 2020, 35(3): 36-45.
XU Zhiheng, ZHANG Yongjun, CHEN Zexing. The benefit on wind power accommodation and low carbon effects of integrated electricity and gas network considering reserve service of P2G facilities[J]. Journal of Electric Power Science and Technology, 2020, 35(3): 36-45.

[4] 唐夏菲, 吴献祥, 任青青, 等. 利用云储能租赁服务的

风电场储能容量优化配置[J]. 电力科学与技术学报, 2020, 35(1): 90-95.

TANG Xiafei, WU Xianxiang, REN Qingqing, et al. Optimized configuration of energy storage capacity of wind farms using cloud energy storage leasing services[J]. Journal of Electric Power Science and Technology, 2020, 35(1): 90-95.

[5] 陈庆攀, 刘洋, 许立雄, 等. 含风电的电力系统鲁棒优化调度[J]. 电测与仪表, 2020, 57(8): 78-84.
CHEN Qingpan, LIU Yang, XU Lixiong, et al. Robust optimal dispatch of power system containing wind power[J]. Electrical Measurement & Instrumentation, 2020, 57(8): 78-84.

[6] 傅质馨, 袁越. 海上风电机组状态监控技术研究现状与展望[J]. 电力系统自动化, 2012, 36(21): 121-129.
FU Zhixin, YUAN Yue. Status and prospects on condition monitoring technologies of offshore wind turbine[J]. Automation of Electric Power Systems, 2012, 36(21): 121-129.

[7] 李晓燕, 余志. 海上风力发电进展[J]. 太阳能学报, 2004, 25(1): 78-84.
LI Xiaoyan, YU Zhi. Developments of offshore wind power[J]. Acta Energiæ Solaris Sinica, 2004, 25(1): 78-84.

[8] 陈夏, 辛妍丽, 唐文虎, 等. 海上风电场黑启动系统的风柴协同控制策略[J]. 电力系统自动化, 2020, 44(13): 98-105.
CHEN Xia, XIN Yanli, TANG Wenhui, et al. Coordinated control strategy of wind turbine and diesel generator for black-start system of offshore wind farm[J]. Automation of Electric Power Systems, 2020, 44(13): 98-105.

[9] 符杨, 杨赛松, 魏书荣, 等. 考虑电磁环境约束的大型海上风电场集电网络拓扑博弈优化[J]. 电力系统自动化, 2019, 43(1): 201-208.
FU Yang, YANG Saisong, WEI Shurong, et al. Game based topology optimization for power collection system of large-scale offshore wind farm considering electromagnetic environment constraints[J]. Automation of Electric Power Systems, 2019, 43(1): 201-208.

[10] 魏书荣, 何之倬, 符杨, 等. 海上风电机组故障容错运行研究现状分析[J]. 电力系统保护与控制, 2016, 44(9): 145-154.
WEI Shurong, HE Zhizhuo, FU Yang, et al. Research status and prospect of offshore wind turbine fault tolerance[J]. Power System Protection and Control, 2016, 44(9): 145-154.

[11] CARROLL J, MCDONALD A, MCMILLAN D. Failure rate, repair time and unscheduled O&M cost analysis of offshore wind turbines[J]. Wind Energy, 2016, 19(6): 1107-1119.

- [12] 黄玲玲, 曹家麟, 张开华, 等. 海上风电机组运行维护现状研究与展望[J]. 中国电机工程学报, 2016, 36(3): 729-738.
HUANG Lingling, CAO Jialin, ZHANG Kaihua, et al. Status and prospects on operation and maintenance of offshore wind turbines[J]. Proceedings of the CSEE, 2016, 36(3): 729-738.
- [13] 李东东, 周文磊, 郑晓霞, 等. 基于多重分形谱和支持向量机的风电机组行星齿轮箱故障诊断与研究[J]. 电力系统保护与控制, 2017, 45(11): 43-48.
LI Dongdong, ZHOU Wenlei, ZHENG Xiaoxia, et al. Diagnosis and research of wind turbine planetary gearbox faults based on multifractal spectrum support vector machine (SVM)[J]. Power System Protection and Control, 2017, 45(11): 43-48.
- [14] 向玲, 邓泽奇, 赵玥. 基于 SCADA 数据的风电机组异常识别方法[J]. 太阳能学报, 2020, 41(11): 278-284.
XIANG Ling, DENG Zeqi, ZHAO Yue. Anomaly recognition method for wind turbines based on SCADA data[J]. Acta Energetica Solaris Sinica, 2020, 41(11): 278-284.
- [15] 王桂松, 郭鹏, 胥佳, 等. 基于 XGBoost 建模和 Change-Point 残差处理的风电机组齿轮箱温度预警[J]. 电力科学与工程, 2018, 34(9): 46-53.
WANG Guisong, GUO Peng, XU Jia, et al. Temperature warning of wind turbines gearbox based on XGBoost modeling and change-point residual processing[J]. Electric Power Science and Engineering, 2018, 34(9): 46-53.
- [16] 赵洪山, 刘辉海. 基于深度学习网络的风电机组主轴轴承故障检测[J]. 太阳能学报, 2018, 39(3): 588-595.
ZHAO Hongshan, LIU Huihai. Fault detection of wind turbine main bear based on deep learning network[J]. Acta Energetica Solaris Sinica, 2018, 39(3): 588-595.
- [17] WANG L, ZHANG Z, LONG H, et al. Wind turbine gearbox failure identification with deep neural networks[J]. IEEE Transactions on Industrial Informatics, 2017, 13(3): 1360-1368.
- [18] TAUTZ-WEINERT J, WATSON S J. Using SCADA data for wind turbine condition monitoring-a review[J]. IET Renewable Power Generation, 2017, 11(4): 382-394.
- [19] DING Y, ZHU Y, FENG J, et al. Interpretable spatio-temporal attention LSTM model for flood forecasting[J]. Neurocomputing, 2020, 403: 348-359.
- [20] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [21] HELBING G, RITTER M. Deep learning for fault detection in wind turbines[J]. Renewable and Sustainable Energy Reviews, 2018, 98: 189-198.
- [22] 谢谦, 董立红, 匡向阳. 基于 Attention-GRU 的短期电价预测[J]. 电力系统保护与控制, 2020, 48(23): 154-160.
XIE Qian, DONG Lihong, SHE Xiangyang. Short-term electricity price forecasting based on Attention-GRU[J]. Power System Protection and Control, 2020, 48(23): 154-160.
- [23] 吉铎格, 李慧, 刘思嘉, 等. 基于 MIE-LSTM 的短期光伏功率预测[J]. 电力系统保护与控制, 2020, 48(7): 50-57.
JI Xingge, LI Hui, LIU Sijia, et al. Short-term photovoltaic power forecasting based on MIE-LSTM[J]. Power System Protection and Control, 2020, 48(7): 50-57.
- [24] 汪欣, 蔡旭, 李征. 结合交叉局部异常因子和注意力机制的超短期风电功率预测方法[J]. 电力系统保护与控制, 2020, 48(23): 92-99.
WANG Xin, CAI Xu, LI Zheng. Ultra-short-term wind power forecasting method based on a cross LOF preprocessing algorithm and an attention mechanism[J]. Power System Protection and Control, 2020, 48(23): 92-99.
- [25] 崔宇, 侯慧娟, 胥明凯, 等. 基于双重注意力机制的变压器油中溶解气体预测模型[J]. 中国电机工程学报, 2020, 40(1): 338-347, 400.
CUI Yu, HOU Huijuan, XU Mingkai, et al. A prediction method for dissolved gas in power transformer oil based on dual-stage attention mechanism[J]. Proceedings of the CSEE, 2020, 40(1): 338-347, 400.
- [26] CHOI H, CHO K, BENGIO Y. Fine-grained attention mechanism for neural machine translation[J]. Neurocomputing, 2018, 284: 171-176.
- [27] STETCO A, DINMOHAMMADI F, ZHAO X, et al. Machine learning methods for wind turbine condition monitoring: a review[J]. Renewable Energy, 2019, 133: 620-635.
- [28] 华锐风电. 3 MW 系列风力发电机组[EB/OL]. [2021-01-20]. <http://www.sinovel.com/content/?108.html>.
- [29] WEI L, QIAN Z, ZAREIPOUR H. Wind turbine pitch system condition monitoring and fault detection based on optimized relevance vector machine regression[J]. IEEE Transactions on Sustainable Energy, 2020, 11(4): 2326-2336.

收稿日期: 2021-01-22; 修回日期: 2021-03-05

作者简介:

苏向敬(1984—), 男, 博士, 副教授, 主要研究方向为海上风电大数据、智能配电网优化规划及运行; E-mail: xiangjing_su@126.com

山衍浩(1996—), 男, 硕士研究生, 主要研究方向为海上风电状态监测与故障预警; E-mail: 954636907@qq.com

符杨(1968—), 男, 通信作者, 博士, 教授, 博士研究生导师, 主要研究方向为变压器故障监测与故障诊断、风力发电与并网技术。E-mail: mfuldong@126.com

(编辑 葛艳娜)