

DOI: 10.19650/j.cnki.cjsi.J2513714

改进多层自组织映射网络驱动的风电机组状态监测*

金晓航, 杨宇辰, 喻轩昂

(浙江工业大学机械工程学院 杭州 310023)

摘要:针对现有风电机组状态监测方法未充分考虑机组与其关键部件间的关联与信息传递问题,提出一种改进多层自组织映射网络驱动的风电机组状态监测方法。首先,采用皮尔逊相关系数对风电机组数据采集与监控系统(SCADA)特征进行选择,将特征信息作为风电机组树状结构的底层节点信息;其次,考虑到风电机组数据的非线性和时序的特点,基于历史数据的学习训练并构建长短期记忆网络(LSTM)模型来预测 SCADA 特征数值,计算预测残差;随后,使预测残差代替特征信息作为多层自组织映射网络(MLSOM)模型中底层自组织映射网络(SOM)模型的输入构建部件的正常行为模型,基于训练后的 SOM 模型以最小量化误差作为指标来表征研究对象的健康状态,按照上述方法分别建立发电机、齿轮箱、变频器关键部件的监测模型;然后,将不同关键部件的健康指标融合作为顶层节点信息输入到多层自组织映射网络模型中的顶层 SOM 模型进行训练,构建机组的正常行为模型,得到机组的健康指标用于整台机组运行状态的监测分析。最后,通过两个风电机组案例分析结果表明,所提方法可有效将部件信息逐级传递并汇集在风电机组上,进而实现整台机组的状态监测。

关键词: 风电机组; 状态监测; 长短期记忆网络; 多层自组织映射网络

中图分类号: TH17 **文献标识码:** A **国家标准学科分类代码:** 460.99

Wind turbine condition monitoring based on improved multilayer self-organizing map

Jin Xiaohang, Yang Yuchen, Yu Xuanang

(College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310023, China)

Abstract: This paper proposes an improved multilayer self-organizing map (MLSOM) network-based method for wind turbine condition monitoring, addressing the lack of consideration for the interrelationship and information transmission between the unit and its key components in existing methods. Initially, the Pearson correlation coefficient is employed to select features from the supervisory control and data acquisition (SCADA) system, with the feature information serving as the input for the wind turbine's tree structure's bottom node. Recognizing the nonlinear and time-series nature of wind turbine data, long short-term memory (LSTM) models are developed and trained using historical data to predict SCADA feature values. The prediction residuals replace the feature information as input to the bottom node of the self-organizing map (SOM) network within the MLSOM model, creating a normal behavior model for each component. The minimum quantization error serves as an indicator for assessing component health using the trained SOM model. Monitoring models are established for key components such as the generator, gearbox, and converter. These component health indicators are then integrated as top-level node information and used as input for the top-level SOM model in the MLSOM to form a normal behavior model for the entire wind turbine, yielding a comprehensive health indicator for condition monitoring. Case study results of two wind turbines demonstrate that the proposed method effectively transmits and aggregates component information step by step, enabling the condition monitoring of the entire wind turbine.

Keywords: wind turbine; condition monitoring; long short-term memory networks; multilayer self-organizing map

0 引言

为了应对日渐严峻的能源危机和日趋严重的生态问题,风能作为一种可再生能源,其开发与利用越来越受到各个国家的重视^[1-2]。作为将风能转换为电能的风电机组同样发展迅速,累计装机容量持续增长^[3]。风电机组通常安装在风能丰富但自然条件恶劣的区域,存在运行维护困难、检修成本昂贵的问题^[4-5]。有统计资料表明,陆上风电机组的运维费用占到风电场收入的10%~15%,而海上风电机组的运维费用占到风电场收入的20%~35%^[6]。为有效掌握风电机组工作状态、降低运维成本以及提高运行效率,需要对风电机组的运行状态进行监测与评估。鉴于此,较多风电机组状态监测方法已被研究提出,如振动监测、油液监测以及数据采集与监控系统(supervisory control and data acquisition, SCADA)数据驱动的状态监测等^[7]。其中,振动监测、油液监测等传统的状态监测方法虽然能够提供较为准确的故障诊断信息,但需要安装额外的传感器,带来了一定的成本和技术挑战。相比之下,基于SCADA数据驱动的状态监测方法通过分析机组的数据来评估其运行状态,不依赖额外的物理传感器,减少了对设备的改造和传感器的需求。因此,越来越多的学者致力于数据驱动的风电机组状态监测研究。

随着人工智能的发展,基于深度学习算法的风电机组状态监测方法被广泛研究。He等^[8]利用深度残差网络、长短期记忆网络(long short-term memory, LSTM)和注意力机制对主轴轴承温度进行预测分析,实现风电机组故障的早期预警。Su等^[9]提出了可解释的卷积时空注意力网络,预测发电机轴承温度,根据残差值判断风电机组发电机故障情况。Zhang等^[10]提出基于条件变分生成对抗网络结合多源信息的方法,对风电机组轴承进行故障诊断,所提方法有效提高了复杂场景下风电机组轴承故障诊断的准确性。马同旭等^[11]结合油温预测和健康状态判别分析,实现了风电机组齿轮箱的故障预警。向玲等^[12]使用卷积自编码与双向长短期神经网络预测轴承温度,实现了对风电齿轮箱的状态监测。需要指出的是,上述工作都是从局部视角对风电机组的某一关键部件开展了状态监测研究,未从全局视角对整台风电机组的运行状态进行剖析与判断。

近年来,不少研究学者针对风电机组整机运行状态也进行了一定的研究。Wang等^[13]设计了一个负载传感器系统用于收集风电机组数据,结合神经网络用于风电机组状态评估。Chen等^[14]基于长短期记忆网络和自编码器构建了风电机组的性能评估模型,实现了对风电机组的状态监测。金晓航等^[15]通过计算风电机组不同部

件的劣化度,结合模糊综合评判法对机组的运行状态进行了监测。田雯雯等^[16]改进了自组织核回归模型,在风电机组状态监测的任务上具有较好的精度。上述方法从风电机组整机全局的视角对机组进行了状态监测,但忽略了关键部件与整台风电机组不同层面之间的信息传递与状态影响。

针对上述问题,提出一种改进多层自组织映射网络的风电机组状态监测方法,采用LSTM算法对机组正常运行状态下的数据进行建模预测分析,计算输入数据预测值与实际值的残差,并将其输入多层自组织映射网络(multilayer self-organizing map, MLSOM)进行信息的融合,构建正常运行状态下的行为模型,利用最小量化误差值作为风电机组的健康指标,进而自底向上统一实现关键部件及其整台风电机组的状态监测。

1 多层自组织映射网络

鉴于多层自组织映射网络是自组织映射网络(self-organizing map, SOM)的改进与扩展,在介绍多层自组织映射网络之前先介绍自组织映射网络。

1.1 自组织映射网络

自组织映射网络是一种无监督的人工神经网络,一般由输入层和输出层2层结构组成。其中,输入层用于接收输入特征,输出层用于神经元的学习和结果的输出^[17]。与一般的神经网络通过反向传播算法来训练模型参数不同,SOM网络运用竞争学习策略,依靠神经元之间的相互竞争逐步优化网络,并且使用近邻关系函数维持输入空间的拓扑结构。

自组织映射网络学习算法步骤^[17]为:

1) 网络初始化:设定输出层神经元个数、学习率、初始优胜邻域、训练次数,对输出层的每个神经元的权值赋予随机值并进行归一化处理。其中,神经元个数按照经验公式确定,如式(1)所示。

$$N = 5\sqrt{m} \quad (1)$$

式中: N 为神经元个数; m 为训练样本数量。

2) 输入样本寻找获胜神经元:首先,从训练集中随机选取一个输入向量,归一化,记为 \mathbf{X}_i ($i=1, 2, \dots, m$);其次,计算输入向量与每个神经元之间的欧式距离,寻找与输入向量欧式距离最小的神经元,将该神经元称为获胜神经元(best match unit, BMU)。欧式距离计算公式如式(2)所示。

$$d_{\text{BMU}} = \min \{ \|\mathbf{X}_i - \mathbf{W}_j\| \} \quad (2)$$

式中: d_{BMU} 为 \mathbf{X}_i 的最小欧氏距离; \mathbf{W}_j 为第 j 个神经元的权值, $\|\mathbf{X}_i - \mathbf{W}_j\|$ 表示输入向量与神经元权值之间的欧式距离。

3) 定义优胜邻域:以获胜神经元为中心,确定 t 时刻

的优胜邻域。优胜邻域由邻域函数确定,常见的函数有 Gaussian 函数、Bubble 函数等。

Gaussian 函数公式为:

$$h_{i,j}(t) = \exp\left(-\frac{\|p_i - p_j\|^2}{2\sigma^2(t)}\right) \quad (3)$$

Bubble 函数公式为:

$$h_{i,j}(t) = \begin{cases} 1, & \|p_i - p_j\|^2 \leq \sigma(t) \\ 0, & \|p_i - p_j\|^2 > \sigma(t) \end{cases} \quad (4)$$

式中: $\sigma(t)$ 为邻域半径; p_i 为获胜神经元*i*在竞争层中的位置向量; p_j 为神经元*j*在竞争层中的位置向量。

4) 调整权值:针对优胜邻域内所有节点调整权值,如式(5)所示。

$$w_j(t+1) = w_j(t) + \eta(t)h_{i,j}(t)(X_i - w_j(t)) \quad (5)$$

式中: $w_j(t+1)$ 为更新后的神经元权值; $w_j(t)$ 为更新前的神经元权值; $\eta(t)$ 为学习率; $h_{i,j}(t)$ 为邻域函数。

5) 结束检查:当训练次数达到预设次数,训练结束;若不满足结束条件则回到 2),直至满足结束条件。

1.2 多层自组织映射网络

树状数据有多个层次结构,能有效包含空间特征信息。大多数传统神经网络无法处理较为复杂的树状结构数据^[18]。因此,为了适应树状结构数据的分析,MLSOM 被提出^[19],一个 3 层的 MLSOM 模型结构如图 1 所示。

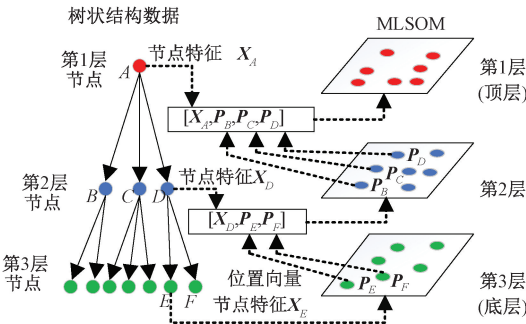


图 1 3 层 MLSOM 模型结构

Fig. 1 Structure of the three-layer MLSOM model

MLSOM 逐层对 SOM 网络进行训练。首先,对第 3 层节点进行训练,将特征信息作为输入向量,输入到第 3 层 SOM 网络中完成训练;然后,对第 2 层节点进行训练,将该层节点的特征信息和它子节点的位置信息作为输入向量,输入到第 2 层的 SOM 网络;最后,将第 1 层节点的特征信息和它子节点的位置信息输入到第 1 层 SOM 网络完成训练;至此,MLSOM 训练完成。

参照风电机组结构特点,可构建机组、部件和 SCADA 特征的树状结构,如图 2 所示。风电部件为满足机组整体工作的要求,面对不同的约束条件各自承受着复杂的内外部载荷。因此,为详细掌握风电机组运行状态,需从局部(部件)和全局(整台风电机组)的角度进行

监测分析。如前所述,MLSOM 正好适用于风电机组树状结构数据的信息挖掘和机组的状态监测分析。需要指出的是,SCADA 系统中仅有末端的特征信息数据,未含单独表征部件、整台风电机组的数据,该情况使得 MLSOM 模型中的第 1 层 SOM 缺少了输入数据;考虑到风电机组状态监测分析中,可采用健康指标(health indicator, HI)表征机组及其部件的运行状况^[15]。因此,这里将部件的健康指标融合作为第 1 层 SOM 的输入,进而分析整台风电机组的运行状态。改进的多层自组织映射网络计算流程为:将关键部件的特征信息输入到第 2 层 SOM 网络中,构建正常行为模型,并利用健康指标表征当前时刻部件的健康状态,实现对不同部件的状态监测;之后,将不同部件的健康指标进行整合,生成新的数据,输入到第 1 层 SOM 中,获得整台风电机组的健康指标,实现机组由部件到整机的健康状态监测。




图 2 风电机组 MLSOM 模型结构

Fig. 2 Structure of MLSOM for wind turbine

2 基于改进多层自组织映射网络的风电机组状态监测模型

虽然 SOM 网络能够有效构建正常行为模型,但无法表征输入数据与正常行为模型之间的距离,判断输入数据对应的机组运行状态是否出现异常,为解决这一问题,最小量化误差(minimum quantification error, MQE)被提出^[20-21]。

2.1 最小量化误差

最小量化误差是实际数据与 SOM 中获胜神经元之间的欧氏距离,即实际数据与正常行为模型之间的最小距离。当对应于机组正常运行状态的数据输入时,最小量化误差较小;而对应于设备异常或故障数据输入时,最小量化误差较大。因此,可以采用最小量化误差作为设备的健康指标,对其进行运行状态评估,也就是通过最小量化误差大小的判断,来确定设备的实际监测数据与其正常数据分布空间之间的距离,进而结合机组工作机理评判输入数据对应的设备运行状态是否出现异常^[22]。具体过程为:1)使用设备正常运行时的健康数据对 SOM 网络进行训练,确定各神经元的权值;2)将测试数据输入

训练好的 SOM 网络,计算该时刻的特征数据与获胜神经元之间的距离;3)将 MQE 值作为设备的健康指标,将其与通过滑动窗口取平均的方法获得的阈值进行比较,判断设备运行情况。

最小量化误差的计算公式如式(6)所示。

$$MQE = \|X_i - W_{BMU}\| \quad (6)$$

式中: X_i 为输入向量; W_{BMU} 为获胜神经元权值向量; $\|X_i - W_{BMU}\|$ 表示计算输入向量与获胜神经元权值之间的欧式距离。

2.2 LSTM-MLSOM 神经网络

风电机组运行时,当前的运行状态无论是正常、异常或是故障,都与其之前较长时间段的历史运行数据密切相关。而 SOM 模型虽然能够对风电机组的运行数据进行聚类分析,但忽略了风电数据的时序特性。长短期记忆网络能够有效挖掘时间序列数据中的复杂模式和规律^[23],捕捉到历史风速、负载、温度等数据与设备性能之间的关系。因此,为了对风电机组的不同运行状况有更好地评估,利用 LSTM 模型对风电机组数据进行预测,通过预测值与实际值相减获得的残差,作为新的 SOM 模型输入。

将 LSTM 模型与 MLSOM 模型相结合得到 LSTM-MLSOM 模型,LSTM-MLSOM 模型首先利用 LSTM 网络对风电机组数据进行预测,充分考虑到风电机组运行数据的时序特性;之后通过 MLSOM 模型建立较为准确的风电机组健康状态模型,实现对风电机组部件和整机的状态监测。

基于 LSTM-MLSOM 的风电机组状态监测流程如图 3 所示。首先将发电机、变流器和齿轮箱作为关键部件对机组进行结构划分;再针对不同部件分别选取不同特征表征其运行状态,结合 LSTM 进行特征的预测分析,计算得到特征的预测值与实际测量值的残差;将残差输入到 MLSOM 中的底层 SOM 进行剖析,获得部件的 MQE 。通过底层 SOM 对风电数据进行可视化分析,可确定风电机组正常运行数据在 SOM 模型中的分布。之后,将不同部件的 MQE 值进行组合,生成新的数据,输入到顶层 SOM 中对风电机组运行状态进行监测分析。当风电机组运行状态发生异常时,通过不同部件 MQE 值的剖析与查询,确定故障发生的部件,实现故障溯源。

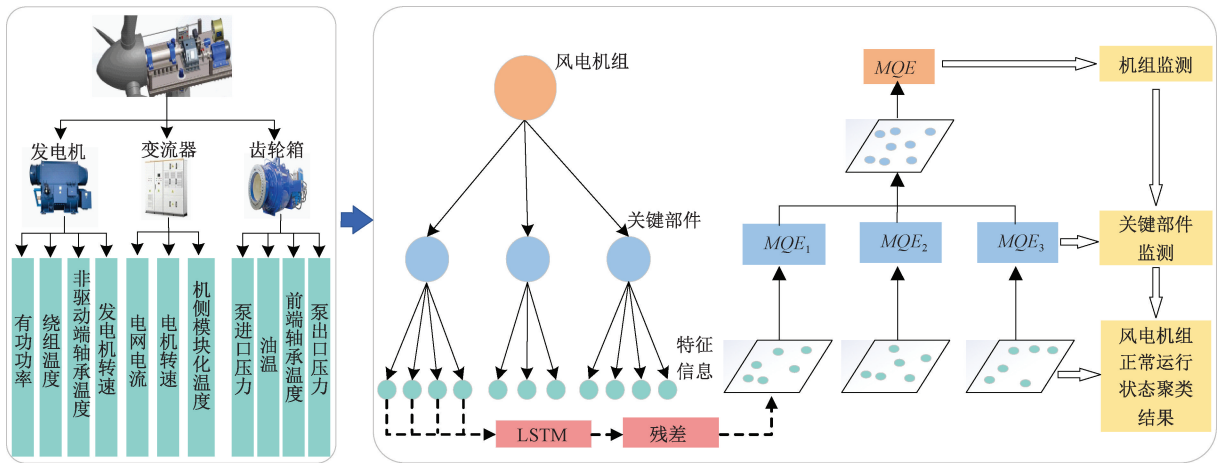


图 3 基于 LSTM-MLSOM 的风电机组整机状态监测方法整体框架

Fig. 3 Overall framework of wind turbine condition monitoring method based on LSTM-MLSOM

3 风电数据预处理与机组正常行为建模

为验证所提方法的有效性,对 2 台实际运行的风电机组进行状态监测。风电机组 SCADA 数据存在数据缺失、数值异常、数据不平衡等问题,需要对风电机组 SCADA 数据进行预处理与机组正常行为建模。

3.1 风电机组数据预处理

预处理工作不仅可以减少模型训练时间,还能提高模型预测结果的准确性。预处理工作包括数据清洗、特征选择和数据归一化等。

风电数据清洗是对机组历史数据中的异常数据进行删除。其中,异常数据包括缺失值数据、停机数据、限功率数据、超出风电机组正常运行区间的数、离群数据等。根据异常数据的不同特点,采取不同的清洗方式:1)直接删除缺失值数据、停机数据、限功率数据、超出风电机组正常运行区间的数;2)采用局部异常因子(local outlier factor, LOF)算法对离群数据进行筛选和删除。

特征选择方法可以保留与风电机组运行状态密切相关的特征,减少冗余特征来降低模型的复杂度,避免发生过拟合等问题。此外,特征数量的减少还有助于节省计算机内存和处理时间、提高计算效率。因此在模型训练

前需要进行特征选择。风电机组发电机、齿轮箱、变流器 3 个部件故障频发,且在风电机组结构中属于关键部件^[8,12,24]。因此,选取风电机组中的发电机、齿轮箱和变流器这 3 个关键部件,通过这三者的状态来评估风电机组整机的健康状况。

通过皮尔逊相关系数分别对 3 个部件进行特征选择,发电机部件选择有功功率、发电机转速、发电机绕组温度 1、发电机非驱动端轴承温度作为输入特征;齿轮箱部件选取齿箱泵进口压力、出口压力、齿箱前端轴承温度作为输入特征;变流器部件选取电网电流 1、变流器电机转速、变流器机侧模块化温度作为输入特征。

3.2 正常行为建模

风电机组数据存在数据不平衡的问题,即正常历史运行数据远多于故障数据。鉴于此,采用正常行为建模的方法进行状态监测,正常行为模型仅使用正常的历史运行数据建立状态监测模型,可有效规避数据不平衡、缺少高质量故障数据集等问题。

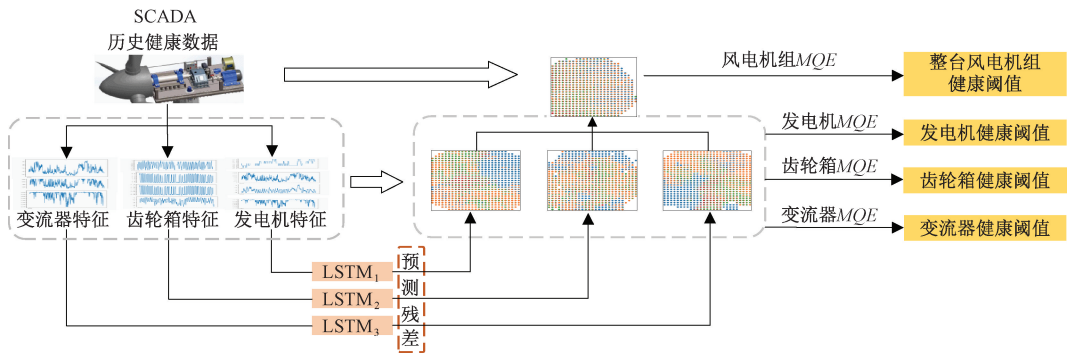


图 4 正常行为建模方法
Fig. 4 Method for normal behavior modeling

4 案例 1-故障风电机组数据的讨论分析

案例 1 所用的数据为中国西南地区的一台 1.5 MW 双馈式风电机组 2016 年 1 月~2017 年 5 月的实际运行数据。其中,机组 SCADA 系统于 2017 年 2 月 5 日 11:20 发出了发电机非驱动端轴承温度过高的异常报警,经运维工作人员检修后发现,此次报警是由于发电机轴承发

正常行为模型如图 4 所示。首先,将风电机组历史健康数据输入到 LSTM 模型中,计算输入特征预测值与实际值的残差,将健康数据的特征残差,输入到 SOM 模型中,对历史健康数据的残差进行学习与记忆,构建出正常数据分布空间,并通过滑动窗口取平均的方法获得健康阈值。在测试阶段,将实际数据输入到 LSTM 模型中,获得实际数据的残差值;之后,把残差值输入到已经训练好的 SOM 模型中,计算实际数据与 SOM 模型中每个神经元的欧式距离,将最小的欧式距离作为该实际数据与正常数据分布空间的距离;然后与阈值比较,确定风电机组运行状态情况。当实际数据为正常运行数据时,数据与正常数据分布空间之间的差异较小,最小量化误差较小,不会出现超出阈值的情况;而故障数据输入时,数据则会显著偏离正常数据分布空间,最小量化误差较大,超出设定的阈值,发生报警。

生跑圈故障所致。

4.1 基于 LSTM-SOM 故障机组的部件级状态监测

部件级的状态监测方法如图 5 所示。以发电机为例,对该部件的状态监测分析:1)对发电机运行状态相关的特征数据(有功功率、发电机转速、绕组温度、非驱动端轴承温度)进行预处理与归一化分析;2)将机组正常运行状态下的上述数据输入 LSTM 模型中进行训练,通过 LSTM 捕捉特征信息中的长时间依赖关系来实现各个特




图 5 基于 LSTM-SOM 的风电机组关键部件状态监测方法-以发电机为例

Fig. 5 Condition monitoring method of key components of wind turbine based on LSTM-SOM: A case study of generator

征的预测,计算得到特征预测值与实际测量值之间的残差;3)构建 SOM 并设定好模型中参数(通过训练数据和经验公式,计算得到 SOM 模型的神经元个数为 27×27),将特征残差输入 SOM 模型中进行训练,构建正常行为模型并获得训练数据的分布和健康阈值;4)将部件的在线监测数据输入到训练好的 LSTM-SOM 模型计算 MQE 值,通过与阈值的比较判断发电机是否工作正常。

同理,齿轮箱和变流器按照上述相同监测流程进行状态监测。由于风电机组选址偏僻、维修困难,为减少因误报而产生不必要的维修费用,因此采取 MQE 值连续超过阈值 5 次再发出报警的预警策略。

SOM 模型中采用不同的邻域函数会影响数据的分析结果,因此需要对邻域函数进行选择。常用的邻域函数有 Gaussian 函数和 Bubble 函数。为确定适合的邻域函数,分别利用上述 2 种邻域函数对机组正常运行的数据(2016 年 6 月~12 月)进行分析,结果如表 1 所示。

表 1 部件级状态监测超出阈值点与误报警次数对比

Table 1 Comparison of threshold exceedance points and false alarm counts in component-level condition monitoring

关键部件	模型	邻域函数	超出阈值点	误报警次数
发电机	SOM	Gaussian	367	49
		Bubble	704	189
	LSTM-SOM	Gaussian	43	0
		Bubble	105	2
齿轮箱	SOM	Gaussian	345	76
		Bubble	404	181
	LSTM-SOM	Gaussian	57	0
		Bubble	105	0
变流器	SOM	Gaussian	152	0
		Bubble	370	3
	LSTM-SOM	Gaussian	73	0
		Bubble	145	0

SOM 模型和 LSTM-SOM 模型利用 Gaussian 函数作为邻域函数监测到的超出阈值点和误报警次数都少于利用 Bubble 函数作为邻域函数的模型。因此,采用 Gaussian 函数作为邻域函数。从表 1 中的结果也可以发现 LSTM-SOM 模型性能(超出阈值点和误报警次数更少)优于 SOM 模型,能更好地用于风电机组部件的状态监测。

图 6 为 SOM 模型与 LSTM-SOM 模型的聚类结果。由于风电机组工况复杂多变,数据分布间没有较为清晰的界限,为体现出该特点,以风速大小为参照对数据在 SOM 神经元的聚集情况进行了可视化。从图 6 可以看出

3 个部件的 SOM 模型都出现了较多的“死神经元”,即没有输入数据的神经元,而 LSTM-SOM 模型中存在“死神经元”的数量明显少于 SOM 模型,文献[25]中提到“‘死神经元’会增加网络的量化误差”,这也说明了 LSTM-SOM 模型的效果优于 SOM 模型。

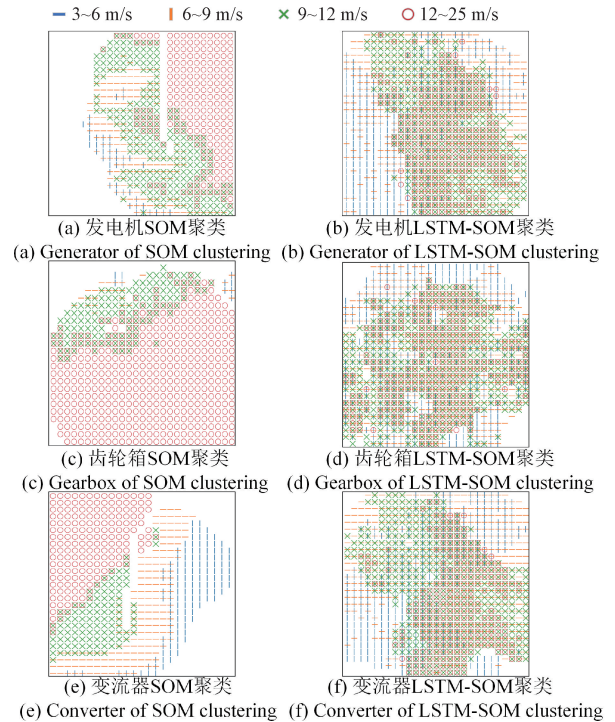


图 6 基于 SOM 和 LSTM-SOM 风电机组不同部件聚类结果

Fig. 6 Clustering results of different components of wind turbine based on SOM and LSTM-SOM

风电机组不同部件的状态监测结果如图 7 所示。以图 7(a)中发电机的状态监测结果为例,可以看到 2017 年 1 月底大量 MQE 超出了阈值线。统计分析发现模型在 2017 年 1 月 28 日 5 点 20 分首次发生了报警,相较于 SCADA 系统的报警时间提前了 8 天。2016 年 6 月至 12 月期间 MQE 值基本处于阈值线的下方,也有部分时刻的 MQE 值超出了阈值线,经过统计分析,并未发现有连续 5 个时刻的 MQE 值超过阈值的情况发生。图 7(b)、(c)分别为齿轮箱、变流器的状态监测结果,可以看出这 2 个部件的 MQE 值基本位于阈值线下方,虽然由于风速或风向的突变,导致部分时刻的 MQE 值出现大于阈值的情况^[26],但并未达到报警条件,表明齿轮箱和变流器处于正常运行状态。

4.2 基于 LSTM-MLSOM 故障机组的整机状态监测

为全面掌握机组的运行状态及时发现潜在异常,需对整台风电机组进行状态监测。在风电机组部件级状态监测分析的基础上,再次利用 LSTM-MLSOM 方法对部件级结果进行融合分析,进而实现整台风电机组运行状态

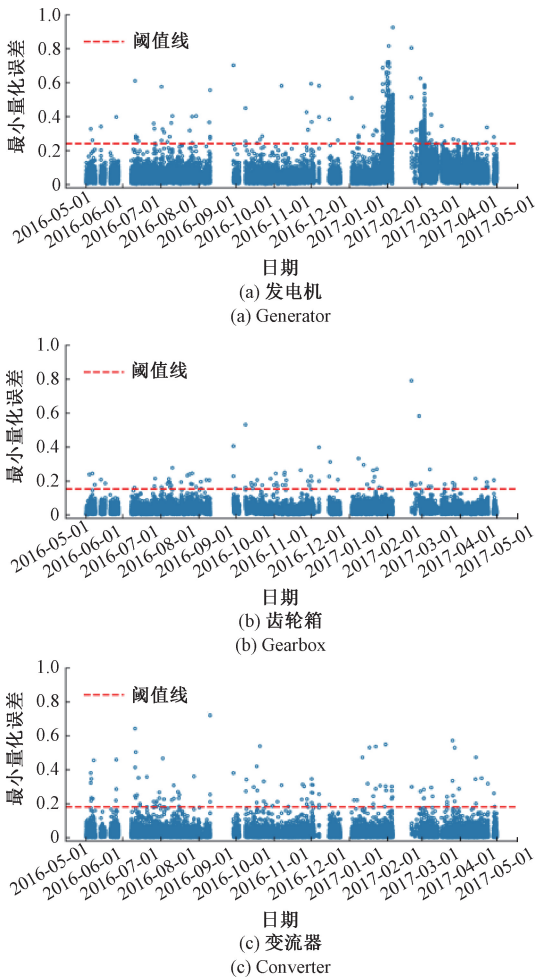


图 7 基于 LSTM-SOM 故障风电机组不同部件的状态监测结果

Fig. 7 Condition monitoring results of different components of fault wind turbine based on LSTM-SOM

的评估。

将发电机、齿轮箱和变流器 2016 年 1 月至 5 月的健康指标进行融合,生成新的数据输入到第 1 层的 SOM 模型中,构建风电机组整机的正常行为模型。为验证 LSTM-MLSOM 的有效性,利用 MLSOM 和 LSTM-MLSOM 分别对 2016 年 6 月至 12 月的健康数据进行状态监测,其结果如表 2 所示。

表 2 整机状态监测超出阈值点与误报警次数对比
Table 2 Comparison of the number of threshold exceedances and false alarms in wind turbine condition monitoring

模型	超出阈值点	误报警次数
MLSOM	458	69
LSTM-MLSOM	300	8

风电机组的状态监测结果如图 8 所示。可以看到在

2017 年 1 月底至 2 月初这一时间段,有大量的 MQE 值超过健康阈值线。对该段时间的 MQE 值进行统计分析发现在 2017 年 1 月 28 日 5 点 40 分首次发生了报警情况,与部件级发电机的报警时间相近,说明 MLSOM 方法能将状态信息逐级上传进而实现整台风电机组的状态监测分析。在 2016 年 6 月至 12 月期间,仅有部分 MQE 值超出阈值线,但也出现了误报警的情况。通过分析认为误报警是在风电机组停机较长时间后再启动运行的一段时间内发生的;机组处于低功率(0~500 kW)运行状态,部分零件还未达到稳定状态(如部件的温度还在上升过程中),导致监测到的数据与其正常运行状态的数据偏差较大,进而使得 MQE 值超出了阈值线。下一节将对该情况做进一步的剖析。





图 8 故障机组的整机状态监测结果

Fig. 8 Condition monitoring results of the fault wind turbine

4.3 低功率不稳定运行时故障机组的异常数据分析

从图 8 中可以看出,尽管在监测上采取了较为宽松的策略,仍有部分 MQE 值超出阈值。查阅风电机组原始数据后发现,风电机组停机再启动的一段时间内,频繁出现 MQE 值由较高值逐渐下降到正常值的现象。通过分析认为,风电机组停机再启动时,有功功率快速上升到某一数值,但温度类型特征需要一定时间才能上升到稳定的数值,导致采集到的特征数据与正常运行状态的数据有所偏差,进而使得停机再启动的一段时间内的 MQE 值较大。为了验证上述分析,选择 2016 年 11 月的 MQE 值进行验证,如图 9 所示,由于停机再启动的数据较多,仅报告 11 月 27 日的数据分析结果。

从图 9(c)中可以看出,11 月 27 日 7:30 至 9:10,有功功率未发生明显波动,但发电机组组温度在该时间段



(a) 11-12 月风电机组整机监测结果

(a) The monitoring results of wind turbine from November

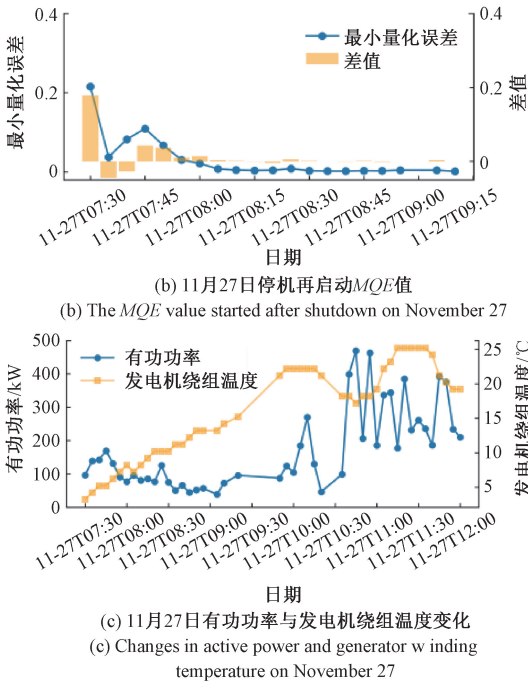


图9 故障机组低功率不稳定运行状态剖析
Fig. 9 Analysis of unstable operation state of wind turbine in low power

内不断上升,之后才趋于稳定,这与MQE值的变化情况较吻合。从图9(b)中发现,停机再启动的30 min时间内,MQE值有着显著地波动,为减少此类情况对状态监测的影响,对停机再启动30 min内的数据进行删除,并与未清洗的监测结果对比,如图10所示。

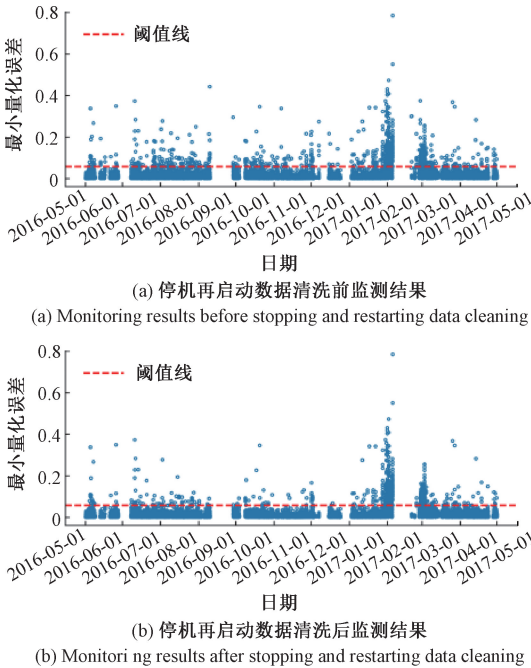


图10 故障机组停机再启动数据清洗前后对比
Fig. 10 Comparison of fault wind turbine shutdown and restart data before and after cleaning

从图10中可以看出,清洗过后MQE值超出阈值的情况显著减少,降低了误报警情况,说明低功率不稳定运行状态会对风电机组的状态监测判断有一定的干扰。

5 案例2-健康风电机组数据分析

案例2所用的数据为另一台1.5 MW双馈式风电机组2017年6月至8月的实际运行数据,该风电机组在该阶段正常运行,未发生故障。

5.1 基于LSTM-SOM健康机组的部件级状态监测

选取该机组2017年6月至7月的SCADA数据作为训练数据集,7月至8月的数据作为测试集。按照上文所述的部件级状态监测方法,对发电机、齿轮箱和变流器这3个部件进行状态监测,最终的监测结果如图11所示。

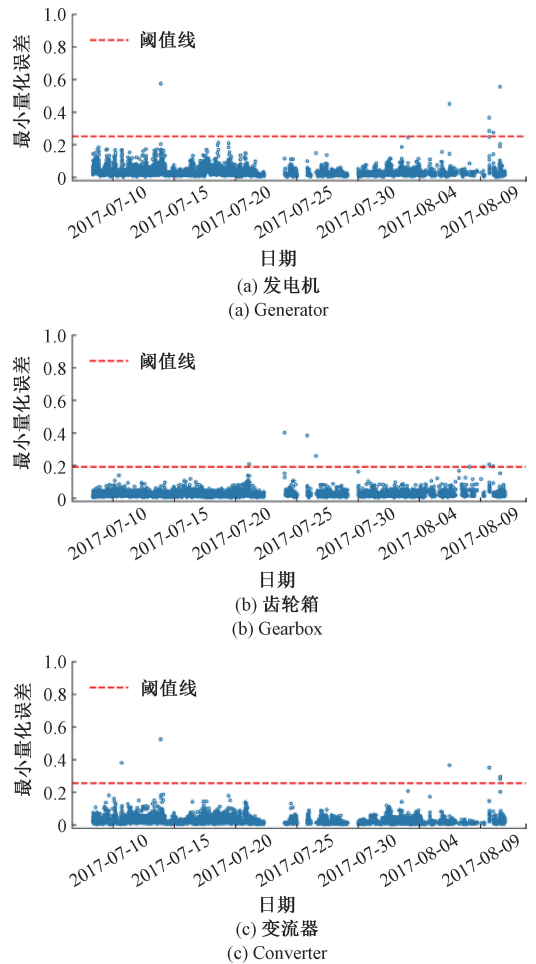


图11 基于LSTM-SOM的健康风电机组不同部件的状态监测结果
Fig. 11 Condition monitoring results of different components of healthy wind turbine based on LSTM-SOM

从图 11 中可以看出,发电机、齿轮箱和变流器 3 个关键部件的状态监测结果都为正常运行,与实际风电机组 SCADA 系统监测的情况相同,验证了 LSTM-SOM 部件级状态监测方法的有效性。

5.2 基于 LSTM-MLSOM 健康机组的整机状态监测

将风电机组部件的状态监测结果进行融合分析,对风电机组整机进行状态评估,并对低功率不稳定运行数据进行分析,同样出现了与案例 1 中类似的情况,低功率不稳定数据分析结果如图 12 所示。




图 13 健康风电机组的状态监测结果

Fig. 13 Condition monitoring results of healthy wind turbine

6 结 论

针对现有风电机组状态监测方法未充分考虑风电机组与其关键部件间的关联与信息传递问题,提出一种改进多层自组织映射网络的机组状态监测方法。针对 SOM 模型无法充分考虑风电数据的时间序列特性,引入 LSTM 方法对风电机组数据进行预测,计算输入特征实际值与预测值的残差,将其作为 SOM 的输入,提高了模型的准确性。通过 MLSOM 方法,构建风电机组不同关键部件的正常行为模型,获得了不同部件的健康指标,并将不同部件的健康指标进行融合,实现了对风电机组部件和整机的健康状态分析。实际应用结果表明,该方法能对风电机组部件和整机进行早期预警。


参考文献

[1] 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 X H, SUN Y, SHAN J H, et al. Fault diagnosis and prognosis for wind turbines: An overview [J]. Chinese Journal of Scientific Instrument, 2017, 38(5): 1041-1053.

[2] 朱彦民, 李忠虎, 王金明, 等. 基于 Transformer 的风电机组故障预测 [J]. 电子测量技术, 2024, 47(13): 45-52.
 ZHU Y M, LI ZH H, WANG J M, et al. Transformer based fault prediction for wind turbines [J]. Electronic Measurement Technology, 2024, 47(13): 45-52.


[3] 吕游, 封烁, 郑茜, 等. 基于 LeNet5like 的迁移学习风电机组叶片覆冰故障诊断研究 [J]. 仪器仪表学报, 2024, 45(3): 128-143.
 LYU Y, FENG SH, ZHENG X, et al. Research on fault diagnosis of wind turbine icing characteristics based on LeNet5like transfer learning [J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 128-143.

[4] TAN X G, ZHANG G M. Research on surface defect




(a) 风电机组整机状态监测结果

(a) Condition monitoring results of the wind turbine



(b) 8月10日停机再启动MQE值

(b) The MQE value started after shutdown on August 10



(c) 8月10日有功功率与发电机绕组温度变化

(c) Changes in active power and generator winding temperature on August 10

图 12 健康风电机组低功率不稳定运行状态剖析

Fig. 12 Analysis of low power unstable operation state of healthy wind turbine

将低功率不稳定数据清洗后,风电机组整机的状态监测结果如图 13 所示。从图中可以看出,风电机组整机的 MQE 值基本位于阈值线下方,只有少数几个时刻的 MQE 值超出了阈值线,但并未触发报警策略,整机状态处于正常运行状态,与部件级状态监测结果相同,进一步验证了 LSTM-MLSOM 对风电机组运行状态的有效分析。

- detection technology of wind turbine blade based on UAV image[J]. *Instrumentation*, 2022, 9(1): 41-48.
- [5] JIN X H, LYU SH Y, KONG Z Q, et al. Graph spatio-temporal networks for condition monitoring of wind turbine[J]. *IEEE Transactions on Sustainable Energy*, 2024, 15(4): 2276-2286.
- [6] 金晓航, 许壮伟, 孙毅, 等. 基于生成对抗网络的风电机组在线状态监测[J]. *仪器仪表学报*, 2020, 41(4): 68-76.
- JIN X H, XU ZH W, SUN Y, et al. Online condition monitoring of wind turbine based on generative adversarial network[J]. *Chinese Journal of Scientific Instrument*, 2020, 41(4): 68-76.
- [7] 王朋飞, 刘长良, 徐建, 等. 基于图注意力和时间卷积网络的风电齿轮箱故障预警方法[J]. *电子测量与仪器学报*, 2023, 37(8): 204-213.
- WANG P F, LIU CH L, XU J, et al. Wind turbine gearbox fault warning method based on graph attention and temporal convolutional network [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(8): 204-213.
- [8] HE Y W, LIU J Y, WU SH J, et al. Condition monitoring and fault detection of wind turbine driveline with the implementation of deep residual long short-term memory network [J]. *IEEE Sensors Journal*, 2023, 23(12): 13360-13376.
- [9] SU X J, DENG CH, SHAN Y H, et al. Fault diagnosis based on interpretable convolutional temporal-spatial attention network for offshore wind turbines[J]. *Journal of Modern Power Systems and Clean Energy*, 2024, 12(5): 1459-1471.
- [10] ZHANG L, ZHANG H, CAI G W. The multiclass fault diagnosis of wind turbine bearing based on multisource signal fusion and deep learning generative model[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-12.
- [11] 马同旭, 刘帅, 刘卫亮, 等. 基于两阶段多维数据生成与实时健康指数的风机齿轮箱故障预警[J]. *仪器仪表学报*, 2024, 45(11): 266-276.
- MA T X, LIU SH, LIU W L, et al. Fault warning of wind turbine gearbox based on two-stage multidimensional data generation and real-time health index[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(11): 266-276.
- [12] 向玲, 朱浩伟, 丁显, 等. 基于 CAE 与 BiLSTM 结合的风电机组齿轮箱故障预警方法研究[J]. *动力工程学报*, 2022, 42(6): 514-521.
- XIANG L, ZHU H W, DING X, et al. Research on fault warning method of wind turbine gearbox based on CAE and BiLSTM[J]. *Journal of Chinese Society of Power Engineering*, 2022, 42(6): 514-521.
- [13] WANG Y F, HE R, SCHÜNEMANN W, et al. Degradation assessment of wind turbine based on additional load measurements [J]. *Renewable Energy*, 2024, 235: 121271.
- [14] CHEN H S, LIU H, CHU X N, et al. Anomaly detection and critical SCADA parameters identification for wind turbines based on LSTM-AE neural network[J]. *Renewable Energy*, 2021, 172: 829-840.
- [15] 金晓航, 秦治伟, 郭远晶, 等. 基于改进劣化度模型的风电机组日常运行状态评估[J]. *太阳能学报*, 2023, 44(1): 239-246.
- JIN X H, QIN ZH W, GUO Y J, et al. Evaluation of wind turbines daily operation conditions based on improved degradation model[J]. *Acta Energeticae Solaris Sinica*, 2023, 44(1): 239-246.
- [16] 田雯雯, 吕丽霞, 刘长良, 等. 基于动态矩阵与特征相似度的 AAKR 风电机组状态监测[J]. *太阳能学报*, 2024, 45(10): 536-543.
- TIAN W W, LYU L X, LIU CH L, et al. Dynamic matrix and feature similarity-based auto associative kernel regression for condition monitoring of wind turbine[J]. *Acta Energeticae Solaris Sinica*, 2024, 45(10): 536-543.
- [17] LU L ZH, LIU J, HUANG X, et al. Gear fault diagnosis and life prediction of petroleum drilling equipment based on SOM neural network[J]. *Computational Intelligence and Neuroscience*, 2022, 2022(1): 9841443.
- [18] RAHMAN M K M, YANG W P, CHOW T W S, et al. A flexible multi-layer self-organizing map for generic processing of tree-structured data[J]. *Pattern Recognition*, 2007, 40(5): 1406-1424.
- [19] ZHANG H J, CHOW T W S, WU Q M J. Organizing books and authors by multilayer SOM [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(12): 2537-2550.
- [20] 向颖, 严慧峰, 余旭阳, 等. 基于特征优选及改进自组织神经网络的非侵入式负荷辨识[J]. *中国电机工程学报*, 2022, 42(S1): 106-114.
- XIANG Y, YAN H F, YU X Y, et al. Non-invasive load identification based on feature data optimization and improved self-organizing map neural network[J]. *Proceedings of the CSEE*, 2022, 42(S1): 106-114.
- [21] 王磊, 刘永强. 基于不平衡样本的 CF-SOM-MQE 感应电机状态分析[J]. *华南理工大学学报(自然科学版)*, 2019, 47(3): 30-36, 92.
- WANG L, LIU Y Q. State analysis of induction motor

- based on CF-SOM-MQE under unbalanced sample condition [J]. *Journal of South China University of Technology (Natural Science Edition)*, 2019, 47(3): 30-36, 92.
- [22] DING L S, WEI X Y, WANG D ZH, et al. Construction of multi-features comprehensive indicator for machinery health state assessment [J]. *Measurement Science and Technology*, 2024, 35(6): 066202.
- [23] 刘家瑞, 杨国田, 王孝伟. 基于孪生深度神经网络的风电机组故障诊断方法[J]. *系统仿真学报*, 2022, 34(11): 2348-2358.
- LIU J R, YANG G T, WANG X W. A wind turbine fault diagnosis method based on siamese deep neural network [J]. *Journal of System Simulation*, 2022, 34(11): 2348-2358.
- [24] ZHANG H, GUO X Q, ZHANG P J. Improved PSO-SVM-Based fault diagnosis algorithm for wind power converter [J]. *IEEE Transactions on Industry Applications*, 2024, 60(2): 3492-3501.
- [25] DLUGOSZ R, TALASKA T, PEDRYCZ W, et al. Realization of the conscience mechanism in CMOS implementation of winner-takes-all self-organizing neural networks [J]. *IEEE Transactions on Neural Networks*, 2010, 21(6): 961-971.
- [26] 金晓航, 泮恒拓, 许壮伟, 等. 基于 SCADA 数据和单分类简化核极限学习机的风电机组发电机状态监测 [J]. *计算机集成制造系统*, 2022, 28(8): 2408-2418.
- JIN X H, PAN H T, XU ZH W, et al. Condition monitoring of wind turbine generators using SCADA data and OC-RKELM [J]. *Computer Integrated Manufacturing Systems*, 2022, 28(8): 2408-2418.

作者简介



金晓航(通信作者), 2014年于香港城市大学获得博士学位, 现为浙江工业大学教授, 主要研究方向为工业大数据分析, 复杂装备的状态监测、故障诊断、寿命预测、智能运维。

E-mail: xhjin@zjut.edu.cn

Jin Xiaohang (Corresponding author) received the Ph. D. degree from City University of Hong Kong in 2014. He is a professor with the College of Mechanical Engineering, Zhejiang University of Technology. His research interests include industrial big data analysis, condition monitoring, fault diagnosis and prognosis, and intelligent maintenance for complex electro-mechanical equipment.