

DOI: 10.13382/j.jemi.B2003049

基于增量式相对熵的风电机组实时状态监测*

王梓齐¹ 张书瑶¹ 刘长良^{1,2}

(1. 华北电力大学 控制与计算机工程学院 保定 071003;

2. 华北电力大学 新能源电力系统国家重点实验室 北京 102206)

摘要:针对风电机组的实时状态监测问题,提出了一种基于增量式相对熵的残差分析方法。首先,通过分析滑动窗口数据特点,推导了适用于实时运算的增量式相对熵的计算公式,其时间复杂度为 $O(1)$,要低于常规计算方法的 $O(n)$ 。接下来,提出了一种基于数据驱动和正常行为建模的风电机组实时状态监测方法,并将增量式相对熵作为实时残差分析的指标。最后,用某2 MW风电机组的实际齿轮箱故障数据为算例,验证了该方法的有效性。结果表明,相对熵残差分析能够至少提前8~10 d实现故障预警,优于常规的统计量;增量式相对熵的计算时间仅相当于常规方法的0.4%~1.9%,在实时性上有显著优势。

关键词:增量式相对熵;风电机组;状态监测;残差分析

中图分类号: TM315; TN014

文献标识码: A

国家标准学科分类代码: 470.4047

Real-time condition monitoring of wind turbine based on incremental relative entropy

Wang Ziqi¹ Zhang Shuyao¹ Liu Changliang^{1,2}

(1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China;

2. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources,

North China Electric Power University, Beijing 102206, China)

Abstract: Aiming at the problem of real-time condition monitoring of wind turbine, a real-time monitoring method based on incremental relative entropy was proposed. Firstly, based on the analysis of the characteristics of sliding window data, the formula of incremental relative entropy which is suitable for real-time calculation was derived. And the time complexity of incremental relative entropy is $O(1)$, which is lower than $O(n)$ of conventional calculation method. Next, a real-time wind turbine condition monitoring method based on data-driven and normal behavior modeling was proposed and the incremental relative entropy was used as the index of real-time residual analysis. The effectiveness of the proposed method was verified by the actual gearbox fault data of a 2 MW wind turbine. The results show that relative entropy residual analysis can realize fault warning at least 8~10 days in advance, which is better than the conventional statistics. The calculation time of incremental relative entropy was only 0.4%~1.9% of the conventional calculation method, which has significant advantages in real-time performance.

Keywords: incremental relative entropy; wind turbine; condition monitoring; residual analysis

0 引言

据全球风能协会截止2018年底的统计数据,全球风电装机总量已达597 GW,而中国的装机总量达216 GW,

全球占比超过36%^[1]。在装机总量大大增长的同时,风电机组的运维问题也受到了较广泛的关注。据调查,国内陆上风电场的运维成本约占总收入的10%~15%,海上风电场的占比更高、约为20%~25%^[2]。因此,有必要深入研究风电机组的状态监测技术,从而及时掌握关键设备的运行状态,助力风电场运维的信息化和智能化、降

低成本。

现有的风电机组状态监测方法,可大致分为基于传感器、基于机理模型和基于运行数据 3 类。基于传感器的方法是利用一些特殊传感器以实现状态监测,如振动分析^[3-4]、油液分析^[5-6]、声发射分析^[7-8]等,可靠性和准确性较高,但需要较大的前期投资和后期维护费用,且多为离线分析。基于机理模型的方法^[9-10]是根据设备和系统的运行机理建立数学模型以实现状态监测,理论基础坚实且实时性较好,但在实际应用中准确性和适应性较差。

基于运行数据的方法是利用监控与数据采集(supervisory control and data acquisition, SCADA)系统的历史和实时运行数据以实现状态监测^[11-12]。现今,绝大多数风电场均配置有 SCADA 系统,使得数据驱动方法的应用成本相对较低,受到了广泛关注。该方法可具体分为^[13]数据处理、正常行为建模和残差分析 3 部分。首先,将 SCADA 历史数据进行处理,仅保留正常运行数据;其次,基于神经网络、支持向量机等数据驱动算法,建立设备的正常行为模型;最后,分析实际测量值和模型估计值间的残差,从而评估设备当前的运行状态是否异常。

残差分析是数据驱动状态监测方法的最后阶段,其结果对于制定灵活化的运维方案有重要作用。现有研究中,多以一段残差数据的平均值^[14]、方差^[15]等常规统计量作为指标,并结合滑动窗口算法进行实时计算。但是,统计量变化的实质是残差的概率分布发生变化,仅仅通过数个统计量可能无法全面刻画概率分布的真实情况,从而得到变化趋势不显著、故障敏感度差的信息,无法反映设备的真实状态。

相对熵是信息论中的重要概念,可以作为两个概率分布之间距离或相似程度的一种定量度量^[16]。近年来,相对熵在状态监测相关领域^[17-18]中得到了一定应用。本文提出使用相对熵作为风电机组实时状态监测的指标,并根据滑动窗口数据的特点,推导了增量式相对熵的计算公式,以提高实时计算速度。用某发生齿轮箱故障的 2 MW 风电机组 SCADA 数据为算例进行实验,对比验证相对熵相比常规统计量在状态监测上的优势和增量式相对熵在计算速度上的优势。

1 增量式相对熵

1.1 相对熵的基本概念

设 P 和 Q 是连续随机变量 X 的两个概率分布, $p(x)$ 和 $q(x)$ 是 P 和 Q 的概率密度函数。定义 P 和 Q 的相对熵 $D(P \parallel Q)$ 如下:

$$D(P \parallel Q) = \int_{-\infty}^{+\infty} p(x) \log \frac{p(x)}{q(x)} dx \quad (1)$$

易证: $D(P \parallel Q) \geq 0$, 仅当函数 $p(x)$ 和 $q(x)$ 相等时等号

成立。对于正态分布,相对熵的计算公式如下^[19]:

$$D(P \parallel Q) = \frac{(\mu_1 - \mu_2)^2}{2\sigma_2^2} + \frac{\sigma_1^2}{2\sigma_2^2} - \log \frac{\sigma_1}{\sigma_2} - 0.5 \quad (2)$$

式中: μ_1 和 μ_2 是正态分布 P 和 Q 的均值; σ_1^2 和 σ_2^2 是方差。

但是,对于概率密度函数较为复杂的分布,如伽马分布^[19]等,式(1)化简后的复杂度很高或积分运算不存在解析解,较难投入实际应用。因此,可使用针对离散概率分布的相对熵计算公式如下:

$$D(P \parallel Q) = \sum_{i=1}^n P_i(x) \log \frac{P_i(x)}{Q_i(x)} \quad (3)$$

式中: $P_i(x)$ 和 $Q_i(x)$ 为 P 和 Q 在第 i 个离散化单元上的概率分布; n 是离散化单元的总个数。

以一维离散概率分布为例解释式(3)的实际应用: 将数轴事先分为 n 个子区间,设 P 和 Q 分别有 m 个对应的数据点,则 $D(P \parallel Q)$ 的计算公式如下:

$$D(P \parallel Q) = \sum_{i=1}^n P_i \log \frac{P_i}{Q_i} = \sum_{i=1}^n I_i \quad (4)$$

$$P_i = \frac{n_i^p}{m} \quad Q_i = \frac{n_i^q}{m} \quad (5)$$

式中: I_i 是第 i 个子区间的相对熵分量; n_i^p 和 n_i^q 是 P 和 Q 落在第 i 个子区间内的数据点个数; m 是数据总数。

基于相对熵进行状态监测的原理如下: 设 P 是设备正常时运行数据的分布, Q 是当前运行状态数据的分布。若 $D(P \parallel Q)$ 较小,说明当前运行状态与正常状态差别不大、设备基本正常;若 $D(P \parallel Q)$ 较大,则说明设备偏离了正常运行状态、可能发生异常,且 $D(P \parallel Q)$ 越大,偏离正常状态的幅度越大。

1.2 增量式相对熵的推导

滑动窗口算法是针对统计量实时计算的一种常用数据处理算法,其示意图如图 1 所示。

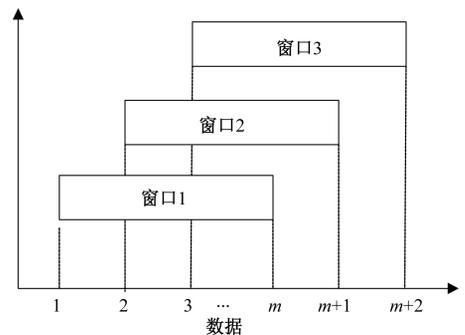


图 1 滑动窗口算法

Fig. 1 Sliding window algorithm

由图 1 可知,当新的实时数据到来后,滑动窗口向前移动 1 格,即将新数据点 $x(t)$ 加入窗中并将最旧的数据

点 $x(t-m)$ 移除。之后,可进一步计算窗中所有数据的统计量,实现数据流和统计量的实时更新。

对于相对熵,考虑令分布 P 代表设备的正常运行状态、不更新对应的数据; Q 代表当前运行状态、按照滑动窗口算法更新对应的数据。因此,常规滑动窗口相对熵的计算方法如下。

1) 划分 n 个子区间,基于式(5)和计算 P 的概率分布 (P_1, P_2, \dots, P_n) 。

2) 基于式(5)计算 Q 的概率分布 (Q_1, Q_2, \dots, Q_n) ,之后基于式(4)计算 $D(P \parallel Q)$ 。

3) 基于滑动窗口算法更新 Q 的数据,并重复步骤2)计算 $D(P \parallel Q)$ 。

上述方案能够实现相对熵的实时计算,但每次数据更新后,均需要遍历滑动窗口中的所有数据重新计算 Q 的概率分布和 $D(P \parallel Q)$ 、计算量相对较大。

接下来,结合滑动窗口数据的特点,考虑窗口每次向前移动1格的情况,推导增量式相对熵:数据更新后,窗口中新增加了1个数据点、移除了1个数据点。因此,至多有2个子区间内的数据点个数发生变化,从而概率分布 (Q_1, Q_2, \dots, Q_n) 和相对熵分量 (I_1, I_2, \dots, I_n) 中最多有2个对应的值发生改变。

设数据更新前后的相对熵分别为 $D(t)$ 和 $D(t+1)$,新增数据点隶属于子区间1,移除数据点隶属于子区间2,则 $D(t)$ 和 $D(t+1)$ 的计算公式如下:

$$D(t) = \sum_{i=1}^n I_i$$

$$D(t+1) = I'_1 + I'_2 + \sum_{i=3}^n I_i \quad (6)$$

式中: I'_1 和 I'_2 是更新后子区间1和2的相对熵分量。计算 $D(t)$ 到 $D(t+1)$ 的增量 ΔD 如下:

$$\Delta D = D(t+1) - D(t) = I'_1 - I_1 + I'_2 - I_2 =$$

$$P_1 \left(\log \frac{P_1}{Q'_1} - \log \frac{P_1}{Q_1} \right) + P_2 \left(\log \frac{P_2}{Q'_2} - \log \frac{P_2}{Q_2} \right) \quad (7)$$

式中: Q'_1 和 Q'_2 是更新后 Q 在子区间1和2上的概率分布。由于子区间1中的数据增多1个,子区间2中的数据减少1个,则 Q'_1 和 Q'_2 的计算公式如下:

$$Q'_1 = \frac{n_1^q + 1}{m} = Q_1 + \frac{1}{m}$$

$$Q'_2 = \frac{n_2^q - 1}{m} = Q_2 - \frac{1}{m} \quad (8)$$

式中: n_1^q 和 n_2^q 是更新前滑动窗口数据落在子区间1和2内的个数, Q_1 和 Q_2 是更新前 Q 在子区间1和2上的概率分布, m 是滑动窗口的宽度即数据总量。

结合上述推导,增量式相对熵的计算方法如下。

1) 划分 n 个子区间,基于式(4)和(5)计算 P 、 Q 的概率分布 (P_1, P_2, \dots, P_n) 、 (Q_1, Q_2, \dots, Q_n) 以及增量式

相对熵的初值 $D(1)$ 。

2) 实时数据到来后,判断新增和移除的数据点隶属的子区间 i 和 j ;若 $i=j$,则相对熵 $D(t+1)$ 等于前一拍的相对熵 $D(t)$;若 $i \neq j$,执行步骤3)。

3) 基于式(7)和(8),计算更新后的概率分布 Q'_i 、 Q'_j 和相对熵增量 ΔD ,则相对熵 $D(t+1) = D(t) + \Delta D$;之后,用 Q'_i 和 Q'_j 更新 Q 的概率分布并重复步骤2)。

从如下3个方面,对比分析常规相对熵计算方法和增量式相对熵。

1) 时间复杂度,常规方法需要遍历整个滑动窗口的数据,重新计算所有的概率分布 (Q_1, Q_2, \dots, Q_n) 和相对熵分量 (I_1, I_2, \dots, I_n) ,时间复杂度为 $O(n)$ 、与数据总量有关;增量式相对熵仅需确定新增和移除数据隶属的子区间,并基于式(7)和(8)进行简单运算即可完成,时间复杂度为 $O(1)$,与数据总量无关。

2) 数据存储,除滑动窗口数据以外,常规方法仅需存储概率分布 (P_1, P_2, \dots, P_n) ;增量式相对熵则需额外存储概率分布 (Q_1, Q_2, \dots, Q_n) 和相对熵 $D(t)$,但从宏观上看几乎与常规方法没有差别。

3) 计算准确性,从推导过程可以看出,增量式相对熵和常规方法的计算结果完全相等。

1.3 零概率问题及解决方法

实际应用过程中,可能会有某些离散化区间上的概率分布等于0的情形,即没有数据落在某些子区间内的零概率问题。由于含有对数运算,零概率问题会严重影响相对熵的计算。

若概率分布 $P_i=0$ 且 $Q_i \neq 0$,则基于式(4)相对熵分量 $I_i=0$ 。但由相对熵的基本性质可知,当且仅当 $P_i=Q_i$ 时 $I_i=0$,其他情况 $I_i>0$,因此上述结果是不符合基本性质的。若 $P_i \neq 0$ 且 $Q_i=0$,则式(4)的对数运算中分母为0,导致等式不成立而无法计算 I_i 。

针对上述零概率问题,提出一种简单的解决方法如下:在计算得到 P 、 Q 落在各子区间内的数据点个数 n_i^p 、 n_i^q 后,统一做如下处理(对于增量式相对熵,仅在步骤1)执行该操作)。

$$n_i^q = n_i^q + 1n_i^q = n_i^q + 1 (i = 1, 2, \dots, n) \quad (9)$$

此时, P 、 Q 在各子区间上的概率分布计算公式如下:

$$P_i = \frac{n_i^p}{m+n}, Q_i = \frac{n_i^q}{m+n} \quad (10)$$

式中:分母 m 也应修正为 $m+n$ 。

式(9)保证了每个子区间内至少有1个数据,从而避免了零概率问题;式(10)保证了所有子区间的概率分布之和仍是1,确保了相对熵计算的正确性。在不同的运行数据分布、子区间划分情况下,上述方法均能够确保零概率问题下相对熵的正常计算。

2 风电机组实时状态监测方法

参照风电机组数据驱动状态监测方法的一般架构,基于增量式相对熵的实时监测方法如图 2 所示,具体步骤如下。

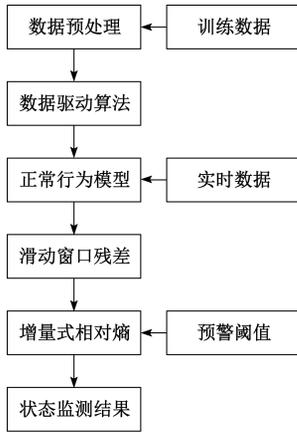


图 2 基于增量式相对熵的实时状态监测方法

Fig. 2 Real-time condition monitoring method based on incremental relative entropy

1) 从风电机组的 SCADA 数据库中导出一部分历史运行数据,经异常数据检测、特征选择、归一化等数据预处理操作后,以剩余的代表正常运行状态的历史数据作为训练数据。

2) 从运行参数中,确定表征关键设备运行状态的状态参数。以状态参数为输出变量,其余参数为输入变量,基于神经网络、支持向量机等数据驱动建模算法,使用训练数据建立正常行为模型。

3) 将实时数据中的非状态参数作为正常行为模型的输入,得到模型的输出即状态变量的估计值。计算状态变量实测值和估计值之间的残差,并结合滑动窗口算法对实时残差数据流进行处理。

4) 取一部分机组运行状态正常时得到的残差数据,作为相对熵中的分布 P 。以滑动窗口残差数据作为分布 Q ,根据 1.2 节的步骤,计算增量式相对熵并随时间推移得到相对熵变化曲线。

5) 以正常运行时的相对熵曲线为依据,制定预警阈值。若相对熵曲线长期超过阈值,则说明风电机组关键设备的运行状态可能发生了异常。

3 算例及分析

3.1 研究对象及数据处理

本算例的研究对象为福建省某陆上风电场的一台额定功率 2 MW 的双馈式机组,主要特征参数如下:切入风

速为 4 m/s,额定风速为 12 m/s,切出风速为 25 m/s,SCADA 数据的采样周期为 10 min。据 SCADA 系统记录,机组于 2016 年 7 月 13 日 10:20 发生齿轮箱故障导致非停,经维修后于 7 月 18 日 9:30 恢复正常运行。

导出时间跨度为 1 月 1 日 0:00~7 月 13 日 10:20 (齿轮箱故障前)和 7 月 18 日 9:30~12 月 31 日 23:50 (齿轮箱维修后)的两组历史数据,运行参数有风速、发电机转速、环境温度、有功功率和齿轮箱轴承温度共 5 个。齿轮箱轴承是承载齿轮箱主轴的载体,据统计约有 70% 的齿轮箱故障发生在轴承上^[20]。因此,选择齿轮箱轴承温度作为状态变量,即正常行为模型的输出;其余 4 个运行参数作为模型的输入。

本算例使用的数据预处理规则如下。

1) 删除有功功率小于等于 0,即风电机组停机、故障等运行状态下的数据。

2) 删除风速大于切出风速或小于切入风速,即风电机组未并网运行时的数据。

3) 基于拉依达准则,依次删除各运行参数中的异常值,以消除粗大误差对建模的影响。

4) 将运行数据进行 min-max 归一化,以消除量纲对建模的影响,具体公式如下:

$$x'_{ij} = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)} \quad (11)$$

式中: x_{ij} 为第 j 个运行参数对应的第 i 个数据; $\max(x_j)$ 和 $\min(x_j)$ 分别为第 j 个运行参数的最大值和最小值; x'_{ij} 为归一化后的数据。

3.2 正常行为建模

经数据预处理后,齿轮箱故障前和维修后的两端运行数据均剩余 14 000 组。以前 9 000 组作为训练数据,分别建立齿轮箱故障前和维修后的正常行为模型;以后 5 000 组作为测试数据,用来评估不同模型的性能和进行状态监测对比实验。

使用两种典型的数据驱动算法进行建模:线性回归 (linear regression, LR) 和最小二乘支持向量机 (least squares support vector machine, LSSVM)。LR 模型的参数辨识方法为最小二乘法;LSSVM 模型基于 MATLAB 的 Regression Learner 工具箱实现,核函数为高斯函数。程序运行的软件平台为 MATLAB R2018a, CPU 型号为 i7-8750H,内存为 16 GB。

使用均方根误差 RMSE 和决定系数 R^2 对模型的精度进行评价。在齿轮箱故障前和维修后的两组数据上,LR 和 LSSVM 模型的训练和测试结果如表 1 所示。

训练数据上,LR 和 LSSVM 模型的表现较为接近且精度相对较高,说明模型能够有效学习和记忆设备的正常运行状态。LR 模型的测试和训练精度相差不大,而 LSSVM 的测试和训练精度相差较大,说明 LSSVM 的泛化

表 1 LR 模型和 LSSVM 模型的训练和测试结果

Table 1 Training and test results of the LR model and LSSVM model

		故障前		维修后	
		训练	测试	训练	测试
LR	RMSE	0.074	0.092	0.051	0.041
	R^2	0.88	0.87	0.95	0.94
LSSVM	RMSE	0.070	0.120	0.049	0.083
	R^2	0.89	0.74	0.95	0.77

能力相对较低。故障前各模型的测试精度要显著劣于训练精度,而维修后训练和测试精度的差别不大,说明在齿轮箱故障前,正常行为模型的估计精度有显著降低、运行状态可能发生异常。

齿轮箱故障前,LR 模型在测试数据上的残差序列如图 3 所示。

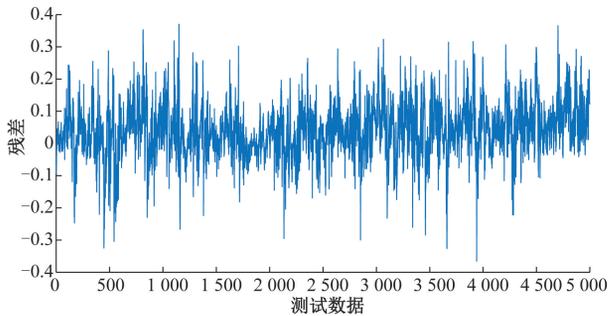


图 3 齿轮箱故障前 LR 模型的残差

Fig. 3 Residuals of the LR model before gearbox fault

由于风电机组运行环境的复杂性和不确定性,导致运行数据和残差序列的噪声和波动较大。因此,很难直观通过图 3 未经处理的残差数据判断设备的运行状态,有必要进一步进行残差分析以提取其中的有效信息。

3.3 基于增量式相对熵的残差分析

考虑残差序列的最大和最小值,以 ± 0.4 为界划分 40 个子区间,第 1 个子空间为 $(-\infty, -0.4]$,第 40 个子空间为 $(0.4, +\infty)$,其余为 $(-0.4, +0.4]$ 范围内等分的左开右闭子区间。依照上述子区间划分,计算 5 000 个残差数据中前 2 000 个(1~2 000)和后 2 000 个(3 001~5 000)残差的概率分布,如图 4 所示。

前 2 000 个残差的概率分布相对集中,而后 2 000 个残差的分布出现了显著的正移,说明残差的平均值增大,即整体上齿轮箱轴承温度的实测值要高于正常行为模型的输出、运行状态可能出现了异常。上述结论验证了基于残差概率分布进行状态监测的可行性,但在两个概率分布差异较小时,直接使用图 4 可能较难分辨,因此更适宜于定性分析。

以测试数据的前 2 000 个残差作为相对熵中的分布

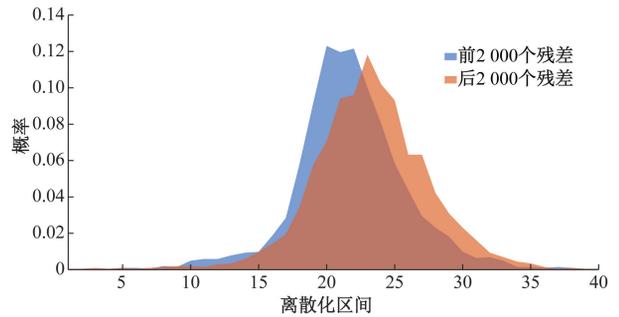


图 4 齿轮箱故障前 LR 模型残差的概率分布

Fig. 4 Probability distribution of the residuals of LR model before gearbox fault

P 保持不变、视作正常运行状态;以所有测试数据结合滑动窗口算法作为分布 Q 、视作实时运行状态,窗口宽度 $m=2\ 000$ 。分别计算 LR 和 LSSVM 模型在故障前和维修后的增量式相对熵曲线如图 5 所示,并设置阈值 T 如下:

$$T = k \cdot \max(D_n) \quad (9)$$

式中: k 为阈值系数,本文取 $k=1.2$; D_n 为维修后的增量式相对熵序列。

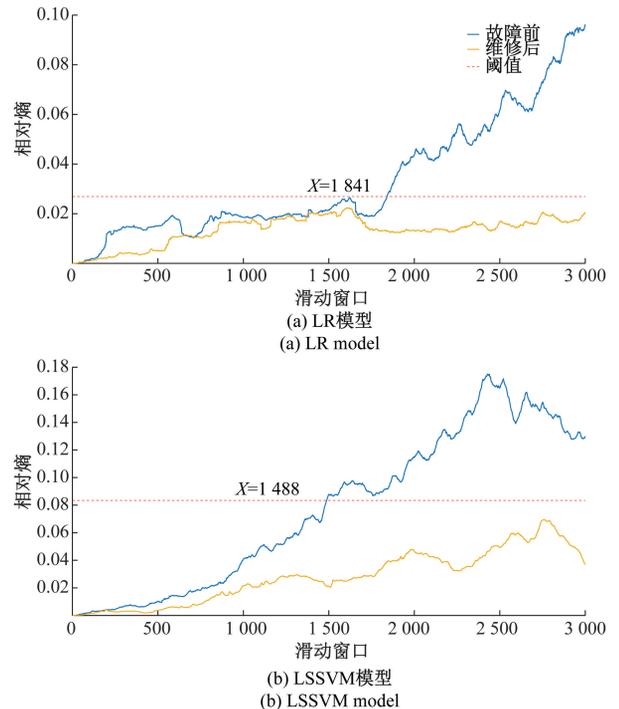


图 5 基于增量式相对熵的残差分析结果

Fig. 5 Residual analysis results based on incremental relative entropy

维修后相对熵曲线的变化趋势相对较为平缓,而故障前曲线的增长速度和幅度显著较高、与维修后的曲线产生鲜明对比,说明故障停机前,齿轮箱的运行状态已经逐步偏离了正常状态、可能发生了潜在故障。对于 LR

模型,曲线在第 1 841 个滑动窗口超过阈值,能至少提前 8 d 实现潜在故障的预警;LSSVM 模型在第 1 488 个窗口超过阈值,能至少提前 10 d 实现预警。

使用残差的滑动窗口平均值进行对比实验,窗口宽度和阈值计算方法和相对熵一致,曲线如图 6 所示。

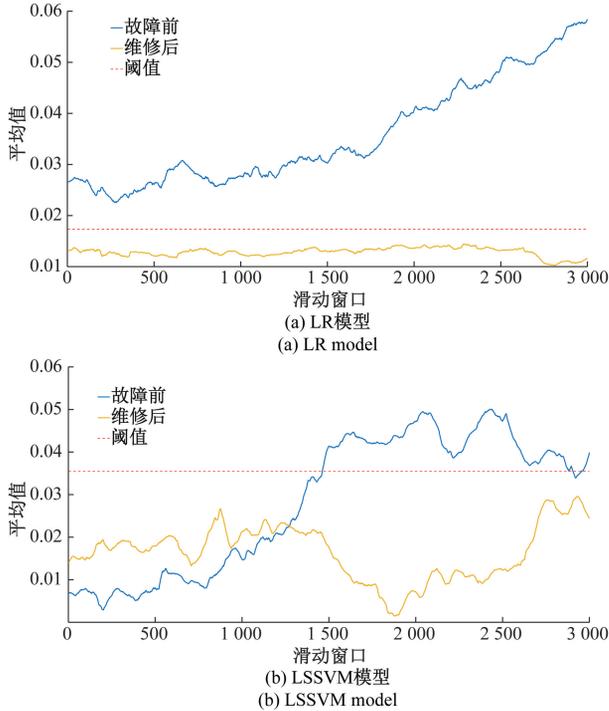


图 6 基于滑动窗口平均值的残差分析结果

Fig. 6 Residual analysis results based on the average of sliding window

如图 6 所示,对于 LR 模型,维修后的平均值曲线要远低于故障前的曲线,导致阈值起不到故障预警的作用;对于 LSSVM 模型,维修后的平均值曲线的波动幅度相对较大、阈值相对较高,导致故障前的曲线出现了反复穿越阈值的现象,可能会造成漏报警。

分析对比图 5 和 6 可得到如下结论。

1) 对比 LR 和 LSSVM 模型,相对熵曲线均实现了故障预警,结论一致只是预警时刻有差异,说明相对熵残差分析能够适应不同的建模算法;而对于平均值曲线,LR 模型未能实现预警而 LSSVM 模型有反复穿越阈值的现象,不同建模算法得到的结果不一致。

2) 对比故障前和维修后,两条相对熵曲线的起点均为 0,使得能够直接对比不同时间阶段设备运行状态的相对变化、便于进行对比实验;而对于平均值曲线,故障前和维修后的曲线的差异较大,特别是 LR 模型,会导致不同实验得到的状态监测曲线难以互相参照。

上述结论能够说明相对熵在状态监测问题上的表现要优于常规统计量。但值得注意的是,相对熵无法区分

概率分布的偏移方向,即残差是整体增大还是减小,实际应用中可与平均值配合使用。

常规相对熵计算方法、增量式相对熵和滑动窗口平均值法在不同实验中的计算时间(计算 3 000 组滑动窗口数据所需的总时间)如表 2 所示。

表 2 各残差分析方法的计算时间

Table 2 Calculation time of each residual analysis method

		常规相对熵	增量式相对熵	滑动平均值
故障前	LR	7.3×10^{-1}	1.4×10^{-2}	3.8×10^{-2}
	LSSVM	6.9×10^{-1}	4.1×10^{-3}	2.1×10^{-2}
维修后	LR	6.2×10^{-1}	4.1×10^{-3}	2.1×10^{-2}
	LSSVM	6.3×10^{-1}	2.6×10^{-3}	1.7×10^{-2}

增量式相对熵在运算速度上有显著优势,计算时间仅为常规方法的 0.4%~1.9%,相比滑动平均值法也有着较大优势。因此,在同时监测多台机组的多个运行参数等实时数据量较大的场景下,增量式相对熵有着较大的应用前景。

4 结论

本文提出了一种基于增量式相对熵的风电机组实时状态监测方法,并使用某 2 MW 风电机组齿轮箱故障前和维修后的两组运行数据为算例,分别结合 LR 和 LSSVM 两种数据驱动建模算法验证了该方法的有效性。结果表明,相比于基于滑动窗口平均值的残差分析方法,相对熵在状态监测问题上的表现更好,能够至少提前 8~10 d 实现齿轮箱故障的预警;经理论分析,增量式相对熵的时间复杂度为 $O(1)$,低于常规相对熵计算方法的 $O(n)$,而经实验验证,增量式相对熵的计算时间仅相当于常规方法的 0.4%~1.9%,在实时性上有显著优势。

参考文献

- [1] 陈雪峰,郭艳婕,许才彬,等. 风电装备故障诊断与健康监测研究综述[J]. 中国机械工程, 2020, 31(2): 175-189.
CHEN X F, GUO Y J, XU C B, et al. Review of fault diagnosis and health monitoring for wind power equipment[J]. China Mechanical Engineering, 2020, 31(2): 175-189.
- [2] 徐启圣,白琨,徐厚昌,等. 风电齿轮箱状态监测和故障诊断的研究现状及发展趋势[J]. 润滑与密封, 2019, 44(8): 138-147.
XU Q SH, BAI K, XU H CH, et al. Research status and development trend of wind power gearbox condition monitoring and fault diagnosis [J]. Lubrication Engineering, 2019, 44(8): 138-147.
- [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 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.
- [4] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报, 2015, 35(13): 3358-3365.
- LIU CH L, WU Y J, ZHEN CH G. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering[J]. Proceedings of the CSEE, 2015, 35(13): 3358-3365.
- [5] 梁培沛, 孙玉彬, 陈铁, 等. 风电机组齿轮箱油液监测典型案例分析[J]. 润滑与密封, 2016, 41(4): 141-145.
- LIANG P P, SUN Y B, CHEN T, et al. Typical cases of oil-monitoring for gearbox of wind turbine [J]. Lubrication Engineering, 2016, 41(4): 141-145.
- [6] YANG X Y, FANG Z G, YANG Y J, et al. A novel multi-information fusion grey model and its application in wear trend prediction of wind turbines [J]. Applied Mathematical Modelling, 2019, 71: 543-557.
- [7] FUENTES R, DWYER R S, MARSHALL M B, et al. Detection of sub-surface damage in wind turbine bearings using acoustic emissions and probabilistic modelling[J]. Renewable Energy, 2020, 147: 776-797.
- [8] 陈长征, 赵新光, 周勃, 等. 风电机组叶片裂纹故障特征提取方法 [J]. 中国电机工程学报, 2013, 33(2): 112-117.
- CHEN CH ZH, ZHAO X G, ZHOU B, et al. Study on extracting crack fault feature of wind turbine blades[J]. Proceedings of the CSEE, 2013, 33(2): 112-117.
- [9] 曹梦楠, 邱颖宁, 冯延晖, 等. 基于等效热网络法的风力发电机故障诊断[J]. 工程热物理学报, 2019, 40(2): 306-313.
- CAO M N, QIU Y N, FENG Y H, et al. Fault diagnosis of a wind generator based on equivalent thermal network method [J]. Journal of Engineering Thermophysics, 2019, 40(2): 306-313.
- [10] DEY S, PISU P, AYALEW B. A comparative study of three fault diagnosis schemes for wind turbines[J]. IEEE Transactions on Control Systems Technology, 2015, 23(5): 1853-1868.
- [11] JANNIS T W, SIMON J W. Using SCADA data for wind turbine condition monitoring: A review [J]. IET Renewable Power Generation, 2017, 11(4): 382-394.
- [12] 王梓齐, 刘长良. 基于 Box-Cox 变换和相对熵残差分析的风电机组齿轮箱状态监测[J]. 中国电机工程学报, 2020, 40(13): 4210-4219.
- WANG Z Q, LIU CH L. Wind turbine gearbox condition monitoring based on Box-Cox transformation and relative entropy residual analysis[J]. Proceedings of the CSEE, 2020, 40(13): 4210-4219.
- [13] 王梓齐, 刘长良, 刘帅. 基于集成 NSET 和模糊软聚类的风电机组齿轮箱状态监测[J]. 仪器仪表学报, 2019, 40(7): 138-146.
- WANG Z Q, LIU CH L, LIU SH. Condition monitoring of wind turbine gearbox based on ensemble nonlinear state estimation technique [J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 138-146.
- [14] 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 D ZH, CHANG CH, XU B K. Wind turbine gearing temperature prediction based on sample optimization[J]. Journal of System Simulation, 2017, 29(2): 374-380.
- [15] 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 H SH, LIU H H. Fault detection of wind turbine main bear based on deep learning network [J]. Acta Energeiae Solaris Sinica, 2018, 39(3): 588-595.
- [16] 郑巧玲, 唐求, 滕召胜, 等. 基于 K-L 散度液位自适应判定的乌式粘度仪系统设计[J]. 电子测量与仪器学报, 2018, 32(5):151-158.
- ZHENG Q L, TANG Q, TENG ZH SH, et al. Design of Ubbelohde viscometer system based on K-L divergence liquid-level adaptive determination [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(5):151-158.
- [17] ZENG J, KRUGER U, GELUK J, et al. Detecting abnormal situations using the Kullback-Leibler divergence[J]. Automatica, 2014, 50(11): 2777-2786.
- [18] 蒋栋年, 李炜. 基于数据驱动残差评价策略的故障检测方法[J]. 控制与决策, 2017, 32(7): 1181-1188.
- JIANG D N, LI W. Fault detection method based on data-driven residual evaluation strategy[J]. Control and Decision, 2017, 32(7): 1181-1188.
- [19] 朱成莲. 两个广义伽玛分布之间的相对熵及其性质[J]. 统计与决策, 2017(24): 30-34.
- ZHU CH L. Relative entropy and its properties between two generalized Gamma distributions [J]. Statistics and Decision, 2017(24): 30-34.
- [20] BHARDWAJ U, TEIXEIRA P, GUEDES C. Reliability prediction of an offshore wind turbine gearbox [J].

Renewable Energy, 2019, 141: 693-706.

作者简介



王梓齐, 2017 年于华北电力大学获学士学位, 现为华北电力大学博士研究生, 主要研究方向为风电机组状态监测与故障预警。

E-mail: wangziqincepu@163.com

Wang Ziqi received his B. Sc. degree from North China Electric Power University in 2017. He is now a Ph. D. candidate at North China Electric Power University. His main research interests include wind turbine condition monitoring and fault warning.



张书瑶, 2019 年于华北电力大学获学士学位, 现为华北电力大学博士研究生, 主要研究方向为风电机组状态监测与故障预警。

E-mail: zsy_ncepu@163.com

Zhang Shuyao received her B. Sc.

degree in 2019 from North China Electric Power University. She is now a Ph. D. candidate at North China Electric Power University. Her main research interests include wind turbine condition monitoring and fault warning.



刘长良 (通信作者), 分别于 1985 和 1990 年于华北电力学院获学士学位和硕士学位, 2002 年于华北电力大学博士学位, 现为华北电力大学教授、博士生导师, 主要研究方向为电力设备状态监测和故障诊断。

E-mail: 13603123513@163.com

Liu Changliang (Corresponding author) received his B. Sc. degree and M. Sc. degree both from North China Electric Power College in 1985 and 1990, and Ph. D. degree from North China Electric Power University in 2002. He is now a professor and Ph. D. supervisor at North China Electric Power University. His main research interests include equipment condition monitoring and fault diagnosis.