

基于 CNN-LSTM-Attention 的风电机组状态监测与健康评估*

朱岸锋¹, 赵前程¹, 周凌^{1,2}, 杨天龙¹, 阳雪兵³

(1. 湖南科技大学机电工程学院 湘潭, 411201)

(2. 湖南工业大学电气与信息工程学院 株洲, 412002)

(3. 哈电风能有限公司 湘潭, 411102)

摘要 针对复杂多变的工作环境给风电机组状态监测带来的挑战,提出了一种基于深度学习和注意力机制组合的状态监测与健康评估方法。首先,将风电机组数据采集与监控(supervisory control and data acquisition,简称 SCADA)系统数据进行预处理;其次,将卷积神经网络(convolutional neural networks,简称 CNN)和长短期记忆网络(long short-term memory,简称 LSTM)相结合提取数据的时空特征,并引入注意力机制(Attention)为 LSTM 分配相应的权重;然后,利用指数加权移动平均来设置阈值,通过分析均方根误差实现风电机组的状态监测;最后,通过实例对风电机组的主轴承、发电机定子和叶片变桨电机状态进行监测分析和健康评估,验证该方法的有效性。

关键词 风电机组;数据采集与监控系统;神经网络;状态监测;健康评估

中图分类号 TM315

引言

随着能源需求日益增大,风能作为重要的清洁能源,发挥着越来越重要的作用^[1]。由于复杂多变的工作环境,风电机组关键部件如主轴承、齿轮和发电机等容易发生故障,带来较高的维护成本和运营费用^[2]。因此,对风电机组进行状态监测^[3-5]和健康评估^[6]十分必要。SCADA 系统采集了大量参数,包括风速、风向、温度、功率、电流和电压等。如果能够提取出这些数据之间隐含的特征,就可以监测风电机组的运行状态,预测早期故障^[7-8]。传统算法在处理大量数据时存在收敛速度慢、预测精度低等问题,而深度学习可以加快收敛过程和提高预测精度。近年来,深度学习在状态监测领域得到了广泛应用^[9]。

CNN 和 LSTM 方法在状态监测领域得到了大量应用,但单独使用其中的一种方法会忽略 SCADA 数据中的时间或空间特征,将 CNN 和 LSTM 方法相结合可以充分提取这些特征。注意力机制可以通过分配权重优化网络,提高模型的精度。因此,笔者将 CNN-LSTM 方法用于状态监测,提出了一种

基于 CNN-LSTM-Attention 的风电机组状态监测和健康评估方法。该方法将预处理后的 SCADA 数据经过相关性分析作为输入变量,通过 CNN 和 LSTM 分别提取隐藏在数据中的空间和时间特征,结合注意力机制提高模型精度;利用指数加权移动平均来监测风电机组运行状态,并用模糊综合评价对风电机组进行健康评估。

1 数据预处理

1.1 四分位法

四分位法是一种统计学方法,四分位数通过将排序后的数据平均划分为 4 个部分的 3 个数据点。对于一个升序排列的样本,四分位法的计算步骤如下。

1) 计算第 2 个四分位数即中位数 Q_2

$$Q_2 = \begin{cases} x_{\frac{n+1}{2}} & (n = 2k + 1) \\ \frac{1}{2} \left(x_{\frac{n}{2}} + x_{\frac{n+2}{2}} \right) & (n = 2k) \end{cases} \quad (1)$$

* 国家重点研发计划资助项目(2022YFF0608700);国家自然科学基金资助项目(51875199);湖南省教育厅青年资助项目(22B0590)

收稿日期:2023-05-10;修回日期:2023-05-31

2) 计算第1和第3个四分位数 Q_1 和 Q_3 。

当 $n = 4k + 3 (k = 0, 1, \dots)$ 时,有

$$\begin{cases} Q_1 = 0.75x_{k+1} + 0.25x_{k+2} \\ Q_3 = 0.25x_{3k+2} + 0.75x_{3k+3} \end{cases} \quad (2)$$

当 $n = 4k + 1 (k = 0, 1, \dots)$ 时,有

$$\begin{cases} Q_1 = 0.25x_k + 0.75x_{k+1} \\ Q_3 = 0.25x_{3k+1} + 0.75x_{3k+2} \end{cases} \quad (3)$$

通过计算出的 Q_1 和 Q_3 ,可以得到四分位距为

$$I_{QR} = Q_3 - Q_1 \quad (4)$$

根据 I_{QR} 可以确定数据样本中异常值的内限为

$$[F_1, F_n] = [Q_1 - 1.5I_{QR}, Q_3 + 1.5I_{QR}] \quad (5)$$

1.2 参数选择

皮尔逊相关系数 r 可用于衡量两个变量之间的相似程度,相关系数越大,两变量的相关性越强;反之相关性越弱。其计算公式为

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (6)$$

其中: $\bar{X}$ 为 X 的平均值; $\bar{Y}$ 为 Y 的平均值; n 为样本数。

2 风电机组状态监测与健康评估模型

2.1 卷积神经网络

CNN 的权重共享和局部连接结构可以有效地从数据中提取深层次特征,同时最小化算法的复杂性^[10]。CNN 主要由卷积层、池化层和全连接层构成,通过卷积层、池化层和全连接层的交替使用,以获得原始序列数据中的特征。CNN 结构见图1。




图1 CNN结构

Fig.1 Structure of the CNN

2.2 长短期记忆网络

CNN 对时间序列的时间特征不敏感,而 LSTM 能更好地融合不同部分状态的时间特征^[11],其独特的结构能够解决循环神经网络训练过程中的

梯度消失问题。LSTM 结构见图2。其计算公式为

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (7)$$

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (8)$$

$$g_t = \tanh(W_{gx}x_t + W_{gh}h_{t-1} + b_g) \quad (9)$$

$$O_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (10)$$

$$C_t = g_t i_t + C_{t-1} f_t \quad (11)$$

$$h_t = \tanh(C_t) O_t \quad (12)$$

其中: W 为权值; b 为偏置; h_{t-1} 为上一时刻的中间状态; x_t 为当前时刻的输入; f_t 为遗忘门的输出; i_t, O_t 分别为输入、输出门的输出; g_t 为输入节点的输出; 输出变量包括单元状态 C_t 和中间状态 h_t 。




图2 LSTM结构

Fig.2 Structure of the LSTM

2.3 注意力机制

在 LSTM 中使用 Attention 来加强对输出变量的影响,从而提高方法的准确性。其计算公式为

$$e_i = u \tanh(w h_i + b) \quad (13)$$

$$a_i = \exp(e_i) / \sum_{i=1}^t \exp(e_i) \quad (14)$$

$$C = \sum_{i=1}^t a_i h_i \quad (15)$$

其中: h_i 为 LSTM 层 t 时刻的输出; b 为偏置系数; w 为权重系数; C 为注意力层 t 时刻的输出。

2.4 基于模糊评判的健康评估

针对风电机组的健康状态评估,将评估结果划为4个等级: $L = \{l_1, l_2, l_3, l_4\}$, 分别对应健康、良好、注意和故障。选择三角形和半梯形相结合分布隶属度函数,主轴承的健康状态等级隶属度函数为

$$l_1 = \begin{cases} 1 & (\beta < 1.37) \\ \frac{1.55 - \beta}{1.55 - 1.37} & (1.37 \leq \beta < 1.55) \\ 0 & (\beta \geq 1.55) \end{cases} \quad (16)$$

$$l_2 = \begin{cases} 0 & (\beta < 1.37) \\ \frac{\beta - 1.37}{1.55 - 1.37} & (1.37 \leq \beta < 1.55) \\ \frac{2.12 - \beta}{2.12 - 1.55} & (1.55 \leq \beta < 2.12) \\ 0 & (\beta \geq 2.12) \end{cases} \quad (17)$$

$$l_3 = \begin{cases} 0 & (\beta < 1.55) \\ \frac{\beta - 1.55}{2.12 - 1.55} & (1.55 \leq \beta < 2.12) \\ \frac{5.62 - \beta}{5.62 - 2.12} & (2.12 \leq \beta < 5.62) \\ 0 & (\beta \geq 5.62) \end{cases} \quad (18)$$

$$l_4 = \begin{cases} 0 & (\beta < 2.12) \\ \frac{\beta - 2.12}{5.62 - 2.12} & (2.12 \leq \beta < 5.62) \\ 1 & (\beta \geq 5.62) \end{cases} \quad (19)$$

发电机定子的健康状态等级隶属度函数为

$$l_1 = \begin{cases} 1 & (\beta < 1.02) \\ \frac{1.86 - \beta}{1.86 - 1.02} & (1.02 \leq \beta < 1.86) \\ 0 & (\beta \geq 1.86) \end{cases} \quad (20)$$

$$l_2 = \begin{cases} 0 & (\beta < 1.02) \\ \frac{\beta - 1.02}{1.86 - 1.02} & (1.02 \leq \beta < 1.86) \\ \frac{8.27 - \beta}{8.27 - 1.86} & (1.86 \leq \beta < 8.27) \\ 0 & (\beta \geq 8.27) \end{cases} \quad (21)$$

$$l_3 = \begin{cases} 0 & (\beta < 1.86) \\ \frac{\beta - 1.86}{8.27 - 1.86} & (1.86 \leq \beta < 8.27) \\ \frac{13.64 - \beta}{13.64 - 8.27} & (8.27 \leq \beta < 13.64) \\ 0 & (\beta \geq 13.64) \end{cases} \quad (22)$$

$$l_4 = \begin{cases} 0 & (\beta < 8.27) \\ \frac{\beta - 8.27}{13.64 - 8.27} & (8.27 \leq \beta < 13.64) \\ 1 & (\beta \geq 13.64) \end{cases} \quad (23)$$

叶片变桨电机的健康状态等级隶属度函数为

$$l_1 = \begin{cases} 1 & (\beta < 1.62) \\ \frac{3.40 - \beta}{3.40 - 1.62} & (1.62 \leq \beta < 3.40) \\ 0 & (\beta \geq 3.40) \end{cases} \quad (24)$$

$$l_2 = \begin{cases} 0 & (\beta < 1.62) \\ \frac{\beta - 1.62}{3.40 - 1.62} & (1.62 \leq \beta < 3.40) \\ \frac{10.08 - \beta}{10.08 - 3.40} & (3.40 \leq \beta < 10.08) \\ 0 & (\beta \geq 10.08) \end{cases} \quad (25)$$

$$l_3 = \begin{cases} 0 & (\beta < 3.40) \\ \frac{\beta - 3.40}{10.08 - 3.40} & (3.40 \leq \beta < 10.08) \\ \frac{13.14 - \beta}{13.14 - 10.08} & (10.08 \leq \beta < 13.14) \\ 0 & (\beta \geq 13.14) \end{cases} \quad (26)$$

$$l_4 = \begin{cases} 0 & (\beta < 10.08) \\ \frac{\beta - 10.08}{13.14 - 10.08} & (10.08 \leq \beta < 13.14) \\ 1 & (\beta \geq 13.14) \end{cases} \quad (27)$$

3 CNN-LSTM-Attention模型的建立

3.1 模型结构

基于CNN和LSTM分别提取空间特征和时间特征的优点以及注意力机制的权值分配,建立CNN-LSTM-Attention预测模型。该模型结构如图3所示,由输入层、CNN层、LSTM层、注意力层和输出层组成。首先,CNN提取原始数据的空间特征,并将其作为LSTM网络的输入;其次,通过LSTM提取时间特征,将结果输入到注意力层;最后,注意力层根据输入数据计算权重。




图3 CNN-LSTM-Attention模型结构

Fig.3 Model structure of the CNN-LSTM-Attention

3.2 模型的建立

将CNN-LSTM-Attention预测的目标参数设定为主轴承温度、发电机定子温度和叶片变桨电机温度,模型建立的具体步骤如下。

1) 数据的选取。选取3~20 m/s正常风速之间风电机组的运行数据并剔除停机等非正常工况下的干扰数据,选取与目标参数相关性较大的参数作为输入参数,然后对选取的数据进行标准化处理,将值归化到[0,1]区间。

2) 预测模型的建立。CNN层的卷积核长度设为1,数量为64。原则上,LSTM隐含层越多拟合度

越好,但训练时间将随着层数的增加而显著增加,因此LSTM的层数设为2。第1层中的LSTM神经元数量为128,第2层神经元数量为64。激活函数为ReLU,优化器选择Adam。在注意力层中,注意力层的输入为LSTM的输出。模型的输出层为主轴承温度、发电机定子温度和叶片变桨电机温度,通过进一步分析残差来确定风电机组的运行状态。

3) 预测模型的训练。通过相关性分析选择模型的输入变量,并对模型进行训练。在测试过程中,如果输入数据为正常运行状态数据并能够适应模型,则预测的均方根误差(root mean square error, 简称RMSE)较小。如果输入数据为异常状态数据而不能适应模型,那么预测的RMSE误差就会增加。

RMSE的计算公式为

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (r_i - \hat{r}_i)^2} \quad (28)$$

其中: r_i 为实际值; $\hat{r}_i$ 为预测值; n 为样本数。

通过分析模型的结果,可以确定主轴承、发电机定子和叶片变桨电机的工作状态。同时,将模型预测得到的RMSE通过模糊综合评价,得出主轴承、发电机定子和叶片变桨电机的健康状态评估。基于CNN-LSTM-Attention的状态监测和健康评估流程如图4所示。




图4 状态监测和健康评估流程

Fig.4 Status monitoring and health assessment process

3.3 时间滑动窗口模型

时间滑动窗口如图5所示。其中: x_i 为 t_i 时刻的数据;窗口宽度 h 为数据长度; l 为移动增量;第 k 个窗口对应时间 t_{k-h} 至 t_k 的数据。当第 k 个窗口的数据

处理完后,窗口两端沿时间递增方向同时移动 l ,然后再对第 $k+1$ 个窗口中的数据进行处理。实际的数据分析中 h 和 l 分别取5和1。




图5 时间滑动窗口模型

Fig.5 Time sliding window model

3.4 异常检测方法

深度学习模型的预测值与实际值之间的误差称为残差,其包含了变量中的各种变化信息,可以反映风电机组的健康水平。

得到预测值后,通过设定阈值观察RMSE的变化趋势和突变程度来判别风电机组的工作状态。本研究使用指数加权移动平均(exponentially weighted moving average, 简称EWMA)来设置阈值。通过EWMA设定的阈值可以有效检测残差的RMSE波动。EWMA的计算公式为

$$S_t = \lambda \text{RMSE} + (1 - \lambda) S_{t-1} \quad (29)$$

其中: λ 为历史数据的权重,本研究取 $\lambda=0.2$; S_t 为EWMA控制线的统计量。

监测风电机组运行状态的阈值是EWMA的上限,其计算公式为

$$U_t = \mu_R + X \sigma_R \sqrt{\lambda [1 - (1 - \lambda)^{2t}] / (2 - \lambda)} \quad (30)$$

其中: μ_R 为RMSE的均值; σ_R 为RMSE的标准差; X 为与阈值位置相关的常数,本研究取 $X=3$ 。

3.5 评价指标

采用RMSE、平均绝对误差(mean absolute error, 简称MAE)和平均绝对百分比误差(mean absolute percentage error, 简称MAPE)来定量分析结果并验证所提模型的性能,计算公式分别为

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (31)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (32)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (33)$$

其中: n 为采样点数; y_i 为实际值; $\hat{y}_i$ 为预测值。

4 实例分析

4.1 数据预处理

以某风场的风电机组为研究对象,选取了 3 组 SCADA 数据进行分析,数据收集间隔为 10 min。根据故障日志可知,由于主轴承、发电机定子和叶片变桨电机的高温故障,风电机组分别于 2016 年 2 月 6 日、2015 年 9 月 12 日和 2016 年 12 月 3 日进行了停机维修。分别选取 1 月 1 日至 1 月 31 日、7 月 1 日至 8 月 31 日、8 月 1 日至 10 月 31 日之间的数据作为训练样本,2 月 6 日主轴承高温故障停机前 400 个采样点、9 月 12 日发电机定子高温故障停机前 400 个采样点和 12 月 3 日叶片变桨电机高温故障前 400 个采样点作为测试样本进行分析。

首先,根据风速结合切入风速对 SCADA 数据进行处理。滤除异常数据前后的风速功率散点图如图 6 所示。由图 6(a)可以看出,风速范围集中分布在 0~14 m/s,而有功功率数据主要分布在风速 3~14 m/s 内,因此筛选出风速为 3~14 m/s 的数据。然后,利用四分位法对数据进一步清洗。图 6(b)为过滤后的风速功率散点图。




图 6 滤除异常数据前后的风速功率散点图

Fig.6 Scatter diagram of wind speed power before and after filtering abnormal data

4.2 参数选择

变量过多会造成数据冗余,影响预测模型的准确性。本研究选择的目标变量分别为主轴承温度、发电机定子温度和叶片变桨电机温度,选取相关系数大于 0.8 的变量作为输入变量。通过相关性分析,选择与主轴承温度、发电机定子温度和叶片变桨电机温度相关性高的变量作为输入变量。变量的选择如表 1 所示。各参数的相关性如图 7 所示。

4.3 主轴承状态监测与健康评估

将预处理后的数据导入 CNN-LSTM-Attention 模型进行分析,通过计算实际值与预测值之间




图 7 各参数的相关性

Fig.7 Correlation of various parameters

表 1 变量的选择

Tab.1 Selection of variables

序号	变量	主轴承状态	发电机定子	叶片变桨电机
		监测模型	状态监测模型	状态监测模型
1	输出变量	主轴承温度	发电机定子温度	叶片变桨电机温度
2	输入变量	轮毂转速	轮毂转速	风速
3		风速	风速	输出功率
4		输出功率	输出功率	变桨电机电流
5		发电机电流	发电机电流	发电机定子温度
6		发电机运行频率	发电机运行频率	发电机运行频率
7		发电机定子温度	主轴承温度	主轴承温度
8		机舱温度	机舱温度	机舱温度
9		控制柜温度	控制柜温度	控制柜温度

的 RMSE 来判断主轴承的运行状态,并使用 EW-MA 来设置阈值。为了连续反映 RMSE 的变化趋势,使用宽度为 5 的滑动窗口进行统计。主轴承模型预测结果如图 8 所示。可以看出:在第 260 个采样点 RMSE 首次超出阈值;此后阈值被多次超过,并在发生故障时出现较大突变;在 2 月 6 日风电机组停机之前达到最大值。当 RMSE 超出阈值时,说明主轴承的状态异常。预测时间与实际故障时间一致,因此可以判定该预测模型预测结果有效。

为了进一步验证该模型的优越性,分别针对主轴承模型故障发生前后,将 CNN-LSTM-Attention 模型的评价指标与 CNN-LSTM 模型和 LSTM 模型

的评价指标进行了比较,如表 2,3 所示。主轴承状态监测模型比较如图 9 所示。由图可知:在正常运行状态下,所提出模型的 RMSE 中值更小且更集中,这表明该模型的预测效果更好;在异常状态下, RMSE 具有突变值。从 RMSE 值的整体变化趋势来看, CNN-LSTM-Attention 模型在检测到故障时表现出更明显的变化。表 2,3 的评价指标数值变化趋势与图 9 一致,说明 CNN-LSTM-Attention 模型在预测主轴承的运行状态时更加准确有效。

表 2 主轴承模型故障发生前评价指标比较

Tab.2 Comparison of evaluation indexes before main bearing model failure

指标	模型		
	LSTM	CNN-LSTM	CNN-LSTM-Attention
RMSE	2.882	1.873	0.816
MAE	2.723	1.796	0.709
MAPE	6.834	4.563	1.351

表 3 主轴承模型故障发生后评价指标比较

Tab.3 Comparison of evaluation indicators after main bearing model failure

指标	模型		
	LSTM	CNN-LSTM	CNN-LSTM-Attention
RMSE	6.757	8.738	10.746
MAE	6.628	8.691	10.686
MAPE	9.245	12.132	15.051

主轴承健康状态见图 10。主轴承在前 260 个采样点处运行时处于“健康”和“良好”状态,机组运行正常;在 261~316 个采样点间,健康状态出现显著退化,为“注意”状态,说明此时主轴承可能出现异常;317 个采样点后主轴承的健康状态处于“故障”状态。从“注意”阶段到“故障”阶段的过渡趋势与 CNN-LSTM-Attention 模型的 RMSE 曲线基本一致。




图 8 主轴承模型预测结果

Fig.8 Main bearing model prediction results




图 9 主轴承状态监测模型比较

Fig.9 Comparison of main bearing condition monitoring models




图 10 主轴承健康状态

Fig.10 Main bearing health status

4.4 发电机定子温度状态监测与健康评估

图 11 为发电机定子模型预测结果,可以看出,在第 202 个采样点后 RMSE 首次超出阈值,说明发电机定子的状态异常,并在 9 月 12 日风电机组停机之前达到最大值。由于预测时间与实际故障时间一致,可以判定该模型预测结果有效。

针对发电机定子故障发生前后,将 CNN-LSTM-Attention 模型的评价指标与 CNN-LSTM 模型和 LSTM 模型的评价指标进行了比较,分别如表 4,5 所示。发电机定子状态监测模型比较如图 12 所示。由表 4,5 可以看出, CNN-LSTM-Attention 模型的评价指标优于其他模型。由图 12 可知,在正常运行状态下,所提出模型的 RMSE 中值更小;在异常状态下, RMSE 值发生较大突变。从 RMSE 值的整体变化趋势来看, CNN-LSTM-Attention 模型在检测到故障时出现更明显的变化。

发电机定子健康状态如图 13 所示。发电机定

表 4 发电机定子模型故障发生前评价指标比较

Tab.4 Comparison of evaluation indexes before generator stator model failure

指标	模型		
	LSTM	CNN-LSTM	CNN-LSTM-Attention
RMSE	1.834	1.448	0.598
MAE	1.805	1.181	0.557
MAPE	3.896	2.472	1.129

表 5 发电机定子模型故障发生后评价指标比较

Tab.5 Comparison of evaluation indexes after generator stator model failure

指标	模型		
	LSTM	CNN-LSTM	CNN-LSTM-Attention
RMSE	15.072	18.527	21.153
MAE	15.138	18.493	21.116
MAPE	19.561	24.239	27.775




图 11 发电机定子模型预测结果
Fig.11 Generator stator model prediction results




图 12 发电机定子状态监测模型比较
Fig.12 Comparison of generator stator condition monitoring models




图 13 发电机定子健康状态
Fig.13 Generator stator health status

子在前 202 个采样点处运行时处于“健康”和“良好”状态;在 203~241 个采样点间,健康状态出现退化,为“注意”状态,说明此时发电机定子可能出现异常;242 个采样点以后发电机定子的健康状态处于“故障”状态。从“注意”阶段到“故障”阶段的过渡趋势与 CNN-LSTM-Attention 模型的 RMSE 曲线一致,说明发电机定子部件发生了异常。

4.5 叶片变桨电机温度状态监测与健康评估

将预处理后的数据导入 CNN-LSTM-Attention 模型进行分析,叶片变桨电机模型预测结果如图 14 所示。可以看出,在第 285 个采样点后 EMSE 首次超出阈值,在 12 月 3 日风电机组停机之前达到最大值。该模型可以有效地检测出叶片变桨电机故障。

同样地,针对叶片变桨电机故障发生前后,将 CNN-LSTM-Attention 模型的评价指标与 CNN-LSTM 模型和 LSTM 模型的评价指标进行了比较,分别如表 6,7 所示。叶片变桨电机状态监测模型比较如图 15 所示。由表 6,7 可以看出, CNN-LSTM-Attention 模型的评价指标优于其他模型,说明该模型能够更好地提取输入向量和输出向量之间的逻辑关系。由图 15 可知:在正常运行状态下,所提出模型的 RMSE 中值更小,说明该模型的

预测效果更好;在异常状态下, RMSE 值发生很大突变。从 RMSE 值的整体变化趋势来看, CNN-LSTM-Attention 模型在检测到故障时出现更明显的变化,表明 CNN-LSTM-Attention 模型在预测叶片变桨电机的运行状态时更加准确。

叶片变桨电机健康状态如图 16 所示。叶片变桨电机在前 285 个采样点处运行时处于“健康”和“良好”状态;在 286~343 个采样点间健康状态出现

表 6 叶片变桨电机模型故障发生前评价指标比较
Tab.6 Comparison of evaluation indexes before blade pitch motor model failure

指标	模型		
	LSTM	CNN-LSTM	CNN-LSTM-Attention
RMSE	3.255	2.714	1.611
MAE	3.478	2.872	1.547
MAPE	4.797	3.665	2.553

表 7 叶片变桨电机模型故障发生后评价指标比较
Tab.7 Comparison of evaluation indexes after blade pitch motor model failure

指标	模型		
	LSTM	CNN-LSTM	CNN-LSTM-Attention
RMSE	11.235	12.963	15.592
MAE	11.225	12.950	15.568
MAPE	12.834	14.891	17.996




图 14 叶片变桨电机模型预测结果
Fig.14 Blade pitch motor model prediction results




图 15 叶片变桨电机状态监测模型比较
Fig.15 Comparison of condition monitoring models for blade pitch motors




图 16 叶片变桨电机健康状态
Fig.16 Blade pitch motor health status

退化,为“注意”状态,说明此时叶片变桨电机可能出现异常;344个采样点以后叶片变桨电机的健康状态处于“故障”状态。从“注意”阶段到“故障”阶段的过渡趋势与CNN-LSTM-Attention模型的RMSE曲线基本一致,由于过渡过程非常迅速,说明有关键部件发生了异常,此时应当立即检修排查故障。

5 结束语

笔者提出一种基于CNN-LSTM-Attention的风电机组状态监测与健康评估方法。其中:CNN用于提取隐藏数据中的空间特征;LSTM更好地融合了部件状态的时间特性;注意力机制以概率分配权重替代随机分配权重,可提高模型的精度;模糊理论用于对风电机组的健康状态进行评估。对实际运行的风电机组应用结果表明,该方法的状态监测与状态评估结果更加准确,对保障风电机组安全稳定运行具有重要意义。

参 考 文 献

- [1] 秦海岩.“十四五”,大力发展风电正当时[J].风能,2021(11):1.
QIN Haiyan. It is timely to vigorously develop wind power during the 14th five year plan period[J]. Wind Energy, 2021(11): 1. (in Chinese)
- [2] 肖钊,邓杰文,刘晓明,等.基于运行规律和TICC算法的风电SCADA高维时序数据聚类方法[J].机械工程学报,2022,58(23):196-207.
XIAO Zhao, DENG Jiewen, LIU Xiaoming, et al. Clustering method of high-dimensional time series SCADA data from wind turbines based on operational laws and TICC algorithm[J]. Journal of Mechanical Engineering, 2022, 58(23): 196-207. (in Chinese)
- [3] YANG G, ZHAO Y L, GU X H. A novel bayesian framework with enhanced principal component analysis for chemical fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-9.
- [4] 金晓航,泮恒拓,徐正国.数据驱动的风电机组变桨系统状态监测[J].太阳能学报,2022,43(4):409-417.
JIN Xiaohang, PAN Hengtuo, XU Zhengguo. Condition monitoring of wind turbine pitch system using data-driven approach [J]. Acta Energetica Solaris Sinica, 2022, 43(4): 409-417. (in Chinese)
- [5] 李辉,刘盛权,冉立,等.大功率并网风电机组变流器状态监测技术综述[J].电工技术学报,2016,31(8):1-10.
LI Hui, LIU Shengquan, RAN Li, et al. Overview of condition monitoring technologies of power converter

for high power grid-connected wind turbine generator system[J]. Transactions of China Electrotechnical Society, 2016, 31(8): 1-10. (in Chinese)

- [6] KANDUKURI S T, KLAUSEN A, KARIMI H R, et al. A review of diagnostics and prognostics of low-speed machinery towards wind turbine farm-level health management [J]. Renewable and Sustainable Energy Reviews, 2016, 53: 697-708.
- [7] KUSIAK A, VERMA A. Analyzing bearing faults in wind turbines: a data-mining approach [J]. Renewable Energy, 2012, 48: 110-116.
- [8] 梁颖,方瑞明.基于SCADA和支持向量回归的风电机组状态在线评估方法[J].电力系统自动化,2013,37(14):7-12,31.
LIANG Yin, FANG Ruiming. On line assessment method of wind turbine state based on SCADA and support vector regression[J]. Automation of Electric Power Systems, 2013, 37(14): 7-12, 31. (in Chinese)
- [9] 王丽华,谢阳阳,周子贤,等.基于卷积神经网络的异步电机故障诊断[J].振动、测试与诊断,2017,37(6):1208-1215.
WANG Lihua, XIE Yangyang, ZHOU Zixian, et al. Asynchronous motor fault diagnosis based on convolutional neural network[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(6): 1208-1215. (in Chinese)
- [10] JIN T T, YAN C L, CHEN C H, et al. Light neural network with fewer parameters based on CNN for fault diagnosis of rotating machinery[J]. Measurement, 2021, 181: 109639.
- [11] ZHU A F, ZHAO Q C, YANG T L, et al. Condition monitoring of wind turbine based on deep learning networks and kernel principal component analysis [J]. Computers and Electrical Engineering, 2023, 105: 108538.



第一作者简介:朱岸锋,男,1995年7月生,博士生。主要研究方向为在线检测与监控、设备运行状态评估。曾发表《Condition monitoring of wind turbine based on deep learning networks and kernel principal component analysis》(《Computers and Electrical Engineering》2023, Vol.105)等论文。
E-mail:547729870@qq.com

通信作者简介:赵前程,男,1969年10月生,博士、教授、博士生导师。主要研究方向为在线检测与监控、设备运行状态评估和机器视觉测量。
E-mail: qczhao@hnust.edu.cn