

基于 Bi - LSTM 和支持向量机的风机叶片短期覆冰状态预测模型

熊昌全¹, 何泽其², 张宇宁¹, 黄 胜¹

(1. 国家电投集团四川电力有限公司, 四川 成都 610065;

2. 国家电投集团四川电力有限公司凉山分公司, 四川 西昌 615000)

摘要: 风机叶片覆冰灾害严重危害风电场安全经济运行, 对风机叶片覆冰状态的预测是预防覆冰灾害的有效手段。针对传统覆冰状态预测方法精度较差问题, 基于风电场 SCADA 监测数据, 提出一种基于 Bi - LSTM 和 SVM 的风机叶片短期覆冰状态预测模型。首先, 采用 PCA 对风机叶片覆冰状态监测特征指标进行降维, 筛选可以反映风机叶片覆冰状态的特征指标; 其次, 基于大量历史数据, 对 Bi - LSTM 和 SVM 模型进行训练, 训练结果表明模型有较好精确度; 最后, 将多组实际数据集输入 Bi - LSTM 预测模型, 预测输出值输入 SVM 模型, 对风机叶片是否会出现覆冰故障进行判别。结果表明, 所提方法可准确实现叶片覆冰状态预测, 准确率可达 95%。

关键词: 风机叶片覆冰; SCADA 监测系统; Bi - LSTM 预测模型; 主成分分析法; 支持向量机

中图分类号: TK83 **文献标志码:** A **文章编号:** 1003 - 6954 (2021) 03 - 0088 - 07

DOI: 10.16527/j.issn.1003 - 6954.20210316

Short - term Icing Status Prediction Model of Wind Turbine Blades Based on Bi - LSTM and SVM Models

Xiong Changquan¹, He Zheqi², Zhang Yuning¹, Huang Sheng¹

(1. SPIC Sichuan Electric Power Co., Ltd., Chengdu 610065, Sichuan, China;

2. Liangshan Branch of SPIC Sichuan Electric Power Co., Ltd., Xichang 615000, Sichuan, China)

Abstract: The icing disaster of wind turbine blades severely impair the safe and economic operation of wind farms, while the prediction of icing status of wind turbine blades is an effective method to prevent icing disaster. Based on the data of supervisory control and data acquisition (SCADA), a short - term icing status prediction model based on bidirectional long short - term memory (Bi - LSTM) and support vector machine (SVM) is proposed to solve the problem of inaccuracy of the traditional prediction method. Firstly, principal component analysis (PCA) are employed to reduce the dimension of characteristic index of wind turbine icing status, and the characteristic index that can reflect the fan blade icing status are screened. Secondly, Bi - LSTM and SVM models are trained based on a large number of historical data, and the training results show that the model has good accuracy. Finally, SVM is used to predict the icing status of the Bi - LSTM forecasting output data set to judge whether the fan blade will have icing failure. The results show that the proposed method can accurately predict the icing status of blades with an accuracy of 95%.

Key words: wind turbine blades icing; SCADA monitoring system; Bi - LSTM prediction model; principal component analysis; support vector machine

0 引 言

随着化石能源短缺以及环境污染等问题的出现, 风力资源作为绿色可再生能源受到科学与工业

界的高度重视^[1]。为充分有效地利用风力资源, 风电场一般建于高海拔山区或沿海区域, 这些地区往往具有昼夜温差大、湿度大、风力强等特点。在低温季节, 长期处于潮湿寒冷环境下的风电场面临严重的风机叶片覆冰问题。风机叶片覆冰将加剧叶片的疲劳载荷以及影响风机产能, 严重时会导致设备故

障和风机寿命缩短。极端情况下,过度积冰甚至可能发生风机塔筒坍塌^[2-3],严重影响风电场安全经济运行。因此亟需开展对风机叶片覆冰状态预测研究,提前采取防范措施以预防可能发生的覆冰危害,确保风电场安全高效运行。

针对风机叶片覆冰状况研究,文献[4]利用天气数据进行预测研究,将预测结果输入基于物理机理的 iceBlade 模型中,实现对风机叶片的覆冰监测。文献[5]基于压电陶瓷应力波测量,提出了风机叶片覆冰主动监测方法,结果表明,压电陶瓷电压测量信号与覆冰厚度存在显著的相关性,方法偏向实验分析。以上覆冰检测研究以覆冰产生机理和过程数值作为重点研究对象,缺少对风机自身运行数据的考量。文献[6]基于数据分析的风机状态监测方法,提出一种基于数据采集与监控系统(supervisory control and data acquisition, SCADA)数据变量相关性的监测方法,实现在不同工况下对风机健康状况的定量评估。文献[7]基于 SCADA 数据,提出了一种主动诊断式的覆冰监测方法,分别从机组整体性能、叶桨吸能效率、机组塔架振动对风机覆冰开展精细化研究,并进行了相互验证,但忽略了指标整体关联性。文献[8]通过 SCADA 系统收集的基础数据作为模型输入,提出了一种基于长短期记忆网络的叶片覆冰故障检测模型,但 LSTM 模型存在精确性不足等问题。文献[9]提出了一种基于 BP 神经网络的风机叶片故障预测方法,先根据行业经验,从 SCADA 监测数据集选出与风力发电机叶片结冰关联度高的数据,通过多源融合的方法利用 BP 神经网络自聚类算法进行叶片结冰故障预测,但对数据选择和处理较为粗糙,导致预测精度欠缺,且 BP 自聚类算法存在分类数据需求大的问题。支持向量机(support vector machine, SVM)在学习样本数较少的情况下比人工智能方法有更强的适应性、更好的分类能力^[10]。

综上所述,传统的覆冰状态监测方法不能精确判断风机叶片覆冰状态,且风机覆冰状态监测数据冗余,处理较为困难。针对这个问题,提出一种基于双向传播长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)和 SVM 的风机叶片覆冰状态预测模型。首先,基于主成分分析法对 SCADA

数据进行降维处理,得到与风力发电机叶片覆冰关联度较高的数据特征;其次,对筛选的数据特征历史数据进行数据分析与预处理,并作为训练集输入 Bi-LSTM 神经网络进行训练,Bi-LSTM 可以有效解决传统 LSTM 网络对长关联数据点信息识别能力较差的问题,经过测试表明预测模型精确度良好;最后,基于大量历史数据集训练好的 SVM 模型,对 Bi-LSTM 数据特征输出的预测数据进行覆冰状态判别,最终确定风机叶片是否会出现覆冰故障。

1 SCADA 数据特征处理

1.1 主成分分析法

基于 SCADA 监测系统得到的数据指标集维数较多,在此情况下,往往会使得计算量增大引发维数灾难,因此需要对数据指标集进行降维。主成分分析法^[11](principal component analysis, PCA)是一种广泛使用的数据指标降维方法,其目的是对能反映风机叶片覆冰状态特性的数据特征进行降维,同时对具有较高的原始变量信息量的数据特征进行排序,因此可利用该方法筛选影响风机叶片覆冰的关键指标。其步骤如下:

1) 对数据进行标准化处理

2) 计算标准化矩阵的相关系数矩阵

$$\mathbf{R} = (S_{ij})_{p \times p}, \quad i, j = 1, 2, \dots, p \quad (1)$$

式中: \mathbf{R} 为协方差矩阵; S_{ij} 为协方差矩阵中第 i 行和第 j 列所对应的数。

3) 计算相关系数矩阵的特征值和相应的特征向量

4) 选择主成分

每个特征根对应的特征向量为 a_1, a_2, \dots, a_p , 通过特征向量将标准化的数据指标转化为主成分

$$y_i = a_i' \beta \quad (2)$$

式中: y_i 为主成分; β 为预处理后的原变量值。

主成分的信息量大小由方差贡献率决定,其表达式为

$$\alpha_i = \frac{\lambda_i}{\sum_{i=1}^m \lambda_i} \quad (3)$$

式中: α_i 为方差贡献率; λ_i 为特征值; m 为选取协

方差矩阵特征值的个数。

累积方差贡献率表达式为

$$G(m) = \frac{\sum_{i=1}^m \lambda_i}{\sum_{k=1}^p \lambda_k} \quad (4)$$

式中: $G(m)$ 为累积方差贡献率; λ_k 为第 k 个主成分的特征值。

5) 计算主成分载荷

主成分载荷的表达式为

$$l_{ij} = \sqrt{\lambda_i} a_{ij} \quad (5)$$

式中: l_{ij} 为主成分载荷; a_{ij} 为各变量间的相关系数矩阵。

6) 主成分得分表达式

$$G_i = \alpha_1 y_1 + \alpha_2 y_2 + \dots + \alpha_p y_p \quad (6)$$

式中, G_i 为最终所提取的主成分得分。

最后, 将原始数据集带入主成分表达式中即可计算出主成分得分, 通过筛选主成分得分高的构成新的数据特征集, 通常当累计方差贡献率大于 85% 时, 所确定的主成分可以反映相关变量特性。

1.2 数据预处理

为使数据特征形式符合 Bi-LSTM 风机叶片覆冰预测模型的输入规范, 采用归一化和标准化对数据进行预处理^[12]。针对范围有限的数据特征, 采用归一化统一不同数据特征的取值范围, 即将数据特征的上限设为 1, 下限设为 0, 其表达式为

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

式中: X' 为预处理后的数据特征; X 为原始数据; X_{\max} 、 X_{\min} 分别为数据特征中的最大值和最小值。

对于范围不确定的数据, 采用标准化降低异常数据带来的影响, 即将数据特征的均值转化为 0, 方差转化为 1, 其表达式为

$$X' = \frac{X - \delta}{\zeta} \quad (8)$$

式中, δ 、 ζ 分别为数据特征的均值和标准差。

2 Bi-LSTM 神经网络

为解决一般的循环神经网络 (recurrent neural network, RNN) 存在的无法记忆长时间段信息和对

内存与计算时间要求高的局限性, LSTM 作为一种时间循环神经网络被设计提出^[13-14]。且双向机制可以提供给输出层输入序列中每一个点完整的过去和未来的上下文信息, 进一步提高网络对长关联信息的识别能力^[15]。

LSTM 单元包含 3 个门控: 输入门、遗忘门和输出门。此外, 每个序列索引位置 t 有向前传播的隐藏状态 $h(t)$, 同时还有一个用于描述前后时间耦合的细胞状态, 记为 $C(t)$ 。具体模型结构如图 1 所示。

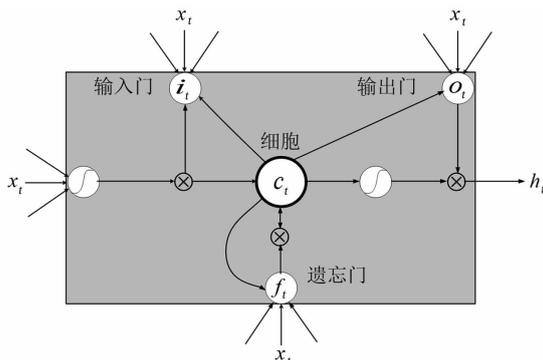


图 1 LSTM 内部结构

LSTM 的 3 个门控具体运作流程如下所述:

1) 遗忘门

遗忘门决定前一个时间步内部状态对当前时间步内部状态的更新。首先, 在遗忘门输入端输入上一序列的隐藏状态 h_{t-1} 和本序列数据 X_t ; 其次, 通过激活函数 σ , 得到遗忘门的输出 p_t ; 最后, 输出值 p_t 赋值给对应细胞状态变量 C_{t-1} , 表达式为

$$p_t = \sigma(W_p h_{t-1} + U_p X_t + b_p) \quad (9)$$

式中: W_p 、 U_p 为线性关系的系数; b_p 为 $t-1$ 时刻到达 t 时刻的神经元所对应输入门的偏置; σ 、 p_t 分别为 sigmoid 的激活函数和输出结果, 其中 $p_t \in (0, 1)$ 。

2) 输入门

输入门决定当前时间步的输入和前一个时间步的系统状态对内部状态的更新。具体为将过去的记忆与现在的记忆合并: 首先, 由 sigmoid 激活函数得到 i_t ; 其次, 由 tanh 激活函数得到 a_t ; 然后, 将 i_t 与 a_t 进行相乘; 最后, 用所乘结果对细胞状态进行更新, 其表达式为

$$\begin{cases} i_t = \sigma(W_i h_{t-1} + U_i X_t + b_i) \\ a_t = \tanh(W_a h_{t-1} + U_a X_t + b_a) \end{cases} \quad (10)$$

式中, W_i 、 b_i 分别为 $t-1$ 时刻到达 t 时刻的神经元所对应的输入门的权重函数和偏置; W_a 、 b_a 分别为

$t-1$ 时刻到达 t 时刻的神经元所对应的输入数据的权重函数和偏置; U_i 、 U_a 为输入门线性关系的系数。

细胞状态更新过程由 C_{t-1} 与遗忘门输出 p_t 的乘积和输入门 i_t 与 a_t 的乘积构成。此过程表达式为

$$C_t = C_{t-1} \odot p_t + i_t \odot a_t \quad (11)$$

式中: C_t 为新细胞状态; \odot 为哈达玛积。

3) 输出门

输出门决定内部状态对系统状态的更新。输出基于细胞状态,但最终输出结果会被过滤。首先,运行一个 sigmoid 层来确定细胞状态的输出部分;其次,把细胞状态通过 tanh 进行处理(得到一个在 $-1 \sim 1$ 之间的值)并将它和 sigmoid 门的输出相乘,最终输出结果。

$$o_t = \sigma[W_o(h_{t-1}, x_t) + b_o] \quad (12)$$

$$h_t = o_t \tanh(C_t) \quad (13)$$

式中: o_t 为输出门系数; W_o 和 b_o 分别为 $t-1$ 时刻到达 t 时刻的神经元所对应的输出门的权重函数和偏置。

Bi-LSTM 网络的基本思想是对于一个训练序列进行向前和向后两次 LSTM 训练,并连接着同一个输出层,从而提供给输出层输入序列中每一个点完整的过去和未来的上下文信息,如图 2 所示。其公式为:

1) 正向计算 LSTM 隐藏层状态

$$s_t = f(\mathbf{U} \cdot x_t + \mathbf{W} \cdot s_{t-1}) \quad (14)$$

2) 反向计算 LSTM 隐藏层状态

$$s'_t = f(\mathbf{U}' \cdot x_t + \mathbf{W}' \cdot s_{t+1}) \quad (15)$$

3) 最终输出取决于 s 和 s'

$$o_t = g(\mathbf{V} \cdot s_t + \mathbf{V}' \cdot s'_t) \quad (16)$$

式中: \mathbf{U} 、 \mathbf{V} 、 \mathbf{W} 为各个权重矩阵; f 、 g 为 LSTM 激活函数。

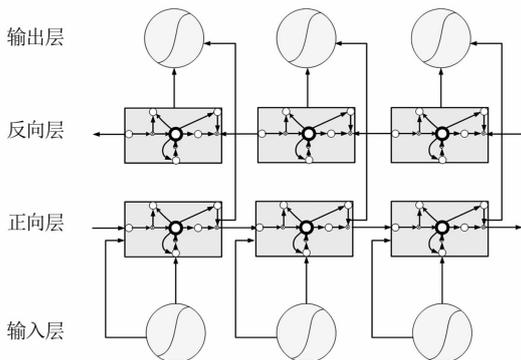


图2 Bi-LSTM

Bi-LSTM 网络拥有的特殊门结构和记忆功能,具有良好的时序数据处理能力。风机覆冰预测所需基础数据冗杂且都与时间序有关,所以 Bi-LSTM 网络适用于所提的风机叶片覆冰状态预测。

3 SVM 模型

支持向量机是由 Vapnik 等人提出^[10]。SVM 可用于高维模式的识别,即分类问题研究。其基本思想是,基于在数据集里找到支持向量,在特征空间上找到最佳分离超平面使得训练集上的不同样本间隔最大。

对于二分类问题,最优分类超平面的表达式可设为

$$w\varphi(x) + b = 0 \quad (17)$$

式中, w 、 b 分别为权重和阈值偏差。

进一步地,原样本空间的二分类问题可表示为

$$y_i(w\varphi(x) + b) \geq 1 \quad (18)$$

式中, $y_i \in [-1, 1]$, 为输出状态类别。

同时引入松弛变量 ε_i 、惩罚因子 C 以及 Lagrange 乘子 α_i 应对可能产生的样本分错问题,将原问题转换为对偶问题,即

$$\begin{cases} \max \left\{ \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \varphi(x_i) \varphi(x_j) \right\} \\ \text{s. t. } 0 \leq \alpha_i \leq C \quad \sum_{i=1}^l y_i \alpha_i = 0 \end{cases} \quad (19)$$

根据 Kuhn-Tucker 条件, α_i 须满足

$$\alpha_i \{ y_i [w\varphi(x) + b] - 1 + \varepsilon_i \} = 0 \quad (20)$$

求解上述问题,可得到最优分类函数

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^m \alpha_i y_i K(x, x_i) + b \right\} \quad (21)$$

式中: $\text{sgn}(u)$ 为符号函数,若 $u > 0$, 则 $\text{sgn}(u) = 1$, $u < 0$, 则 $\text{sgn}(u) = -1$; x_i 为是样本变量数据; y_i 为样本类标; x 为待分类样本; m 为支持向量个数; $K(x, x_i)$ 为核函数。

根据专家的先验知识预先选用核函数为

$$K(x, x_i) = \exp(-\gamma |u - v|^2) \quad (22)$$

式中, u 、 v 为数据集的样本。

4 模型求解

采用 MATLAB 软件平台,对所建立的基于 Bi-LSTM 和 SVM 的风机叶片覆冰状态预测模型进行求解。系统硬件环境为 Intel Core I5 CPU,3.30 GHz,8 GB 内存,操作系统为 Win10 64 bit。求解流程如图 3 所示,具体步骤如下:

1)采用 PCA 对原始指标数据集进行降维处理,降维得到与覆冰关联度贡献最大的特征指标。

2)基于降维得到的特征指标选择所对应的历史数据,进行数据标准化预处理,用于 Bi-LSTM 预测模型的训练及测试评估。

3)选择降维得到特征指标对应的覆冰及未覆冰状态的历史数据,对 SVM 分类进行训练。

4)将实际数据输入 Bi-LSTM 预测模型,输出得到特征指标预测数据,再输入 SVM 分类模型对风机叶片覆冰状态进行判断。

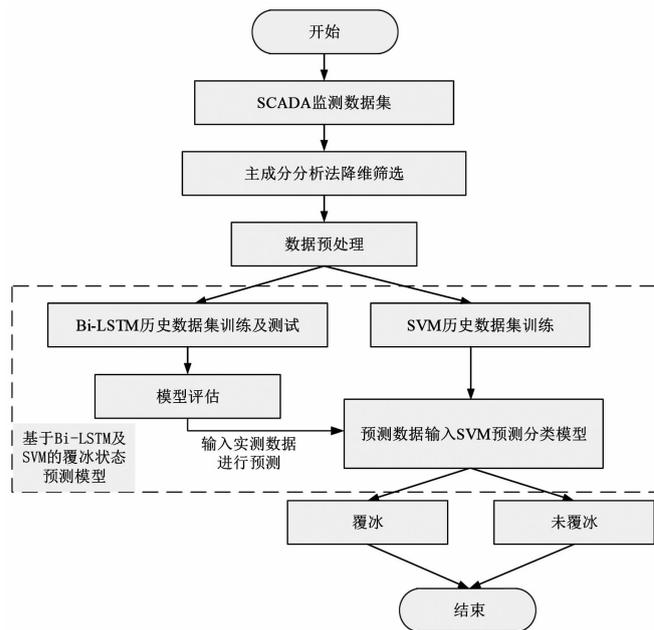


图 3 模型求解流程

5 算例分析

5.1 PCA 特征指标降维

基于 PCA 对 SCADA 特征指标集降维得到 13 个特征指标。根据主成分得分对叶片覆冰影响的重要程度由大到小的排序如表 1 所示。由于主成分舱内温度、环境温度及偏航位置的累积方差贡献率达

到了 85% 以上,具有较高的原始变量信息量,可以反映叶片覆冰状态之间的相关性,因此选择上述 3 个特征指标作为所提模型的输入量。

5.2 Bi-LSTM 预测模型分析

对覆冰和正常状态的数据集添加标记以区分,总共采集 2000 组数据,其中后 400 组数据为覆冰状态数据。根据模型经验^[16],并对比在不同训练样本和测试样本下的预测精度,如图 4 所示,可知训练数据和测试数据的数量之比为 1600:400 时能获得较好的预测精度,且再增加训练样本时,模型的预测精度基本保持不变。因此选用 1600 组数据用于模型训练,400 组数据用于模型测试。通过多次试验,Bi-LSTM 预测模型的参数为:2 层隐藏层,每层神经元数依次为 64、128 个;训练 1000 轮;激活函数为 adma;批大小为 32。

表 1 13 个数据特征排序

数据特征排序	数据特征名称
1	舱内温度/ $^{\circ}\text{C}$
2	环境温度/ $^{\circ}\text{C}$
3	偏航位置/ $^{\circ}$
4	水平方向加速度/ $(\text{m} \cdot \text{s}^{-2})$
5	垂直方向加速度/ $(\text{m} \cdot \text{s}^{-2})$
6	叶片 1 开关温度/ $^{\circ}\text{C}$
7	变桨电动机 1 温度/ $^{\circ}\text{C}$
8	叶片 1 速度/ $(\text{m} \cdot \text{s}^{-1})$
9	发电机转速/ $(\text{m} \cdot \text{s}^{-1})$
10	风向角/ $^{\circ}$
11	偏航速度/ $(\text{m} \cdot \text{s}^{-1})$
12	风速/ $(\text{m} \cdot \text{s}^{-1})$
13	网侧有功功率/ kW

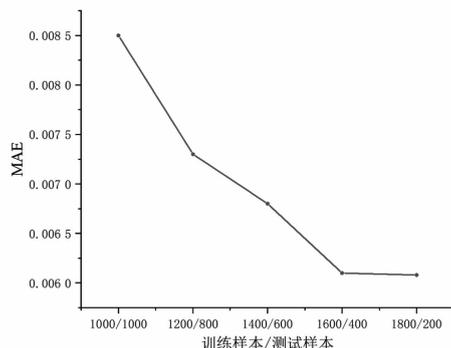


图 4 不同训练样本/测试样本比例下模型预测效果对比

选取主成分得分前三的数据特征的舱内温度、环境温度及偏航位置 3 组指标,通过可视化视图显示 Bi-LSTM 训练集数据的预测结果。图 5、图 6 和图 7 分别展示了预处理后的机舱温度、环境温度及偏航位置预测值和实际值走势。从图中可看出,预测值和实际值具有较高的重合度,说明所提方法 Bi-LSTM 预测模型有效性。

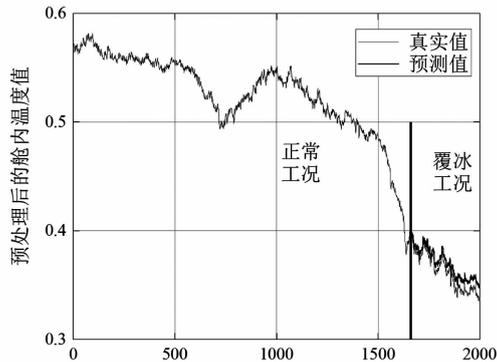


图 5 舱内温度真实值与预测值对比

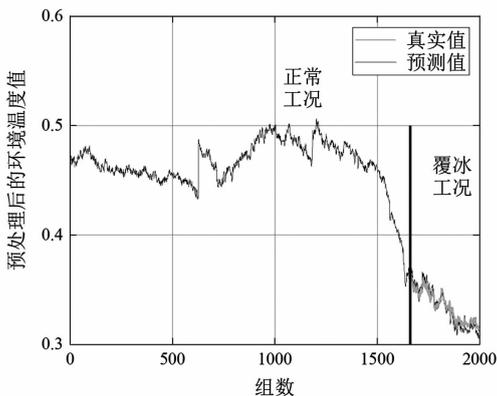


图 6 环境温度真实值与预测值对比

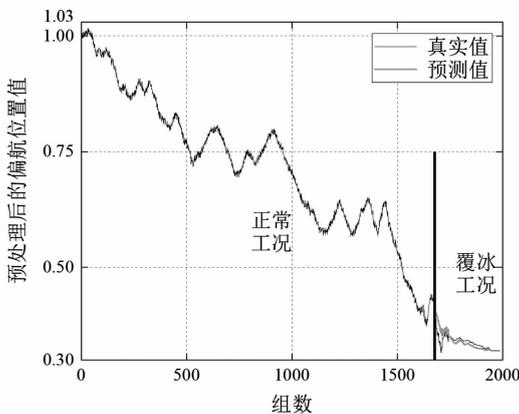


图 7 偏航位置真实值与预测值对比

为进一步说明采用 Bi-LSTM 预测模型的准确性,采用表 2 中的 3 种误差函数作为模型评价指标^[17]。

表 2 误差函数

函数名称	函数作用
平均绝对误差	反映预测值误差实际情况
平均绝对误差百分比	反映数据特征的变化程度
均方根误差	反映预测值与真实值偏离的大小

误差函数的公式如下:

1) 平均绝对误差(mean absolute error, MAE)

$$\tau = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (23)$$

2) 平均绝对百分比误差(mean absolute percentage error, MAPE)

$$\beta = \frac{1}{m} \sum_{i=1}^m \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (24)$$

3) 均方根误差(root mean square error, RMSE)

$$\gamma = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (25)$$

式中: \hat{y}_i 、 y_i 分别为测试集中的预测值和原始值; m 代表测试集的大小。模型拟合度的高低与上述指标值的大小成反比,值越小表明结果越精确。

通过测试集数据预测结果,选取舱内温度为例,对比 Bi-LSTM 与其他 3 种预测模型的 MAE、MAPE 和 RMSE 评价指标,如表 3 所示。所采用的 Bi-LSTM 模型评价指标均优于其他两种模型,由此可见 Bi-LSTM 预测准确性更好。

表 3 4 种预测模型的性能指标结果

预测方法	评价指标		
	MAE	MAPE/%	RMSE
所建模型	0.006 1	1.73	0.007 5
LSTM 网络	0.006 5	1.92	0.007 8
线性回归模型	0.044 9	12.75	0.045 6
神经网络模型	0.006 9	1.95	0.008

5.3 风机覆冰状态预测分析

基于 Bi-LSTM 和 SVM 的风机叶片短期覆冰状态预测模型,自动判断未来一段时间内是否会出现风机叶片覆冰故障。首先,分别从 2000 组正常工况和覆冰工况预测数据集中各挑选 300 组标签数据,将标签数据输入 SVM 模型进行深度训练,将覆冰工况下每组数据的训练值标记为 1,正常工况下每组数据的训练值标记为 0。当 SVM 模型训练完成后,通过将真实数据输入 Bi-LSTM 预测模型,再

将预测输出值输入 SVM 模型,对应可得到一个在 0.5 左右的聚类输出值,若输出值大于 0.5,则判断 1,状态为覆冰;若输出值小于 0.5,则判断为 0,状态为正常。

从实际数据集中各挑选 40 组正常和覆冰工况下的数据输入 Bi-LSTM 状态预测模型,得到舱内温度、环境温度及偏航位置的预测值,将其输入 SVM 分类模型,最后根据预测输出值判断风机叶片覆冰状态,基于 Bi-LSTM 和 SVM 状态预测模型输出结果最终只有 4 组数据发生误判,76 组预测输出为正确。通过此实验可以得出,所提的预测方法准确率为 95.0%。

6 结 语

以某风电场风电机组 SCADA 数据为基础,提出了一种基于 Bi-LSTM 和 SVM 的风机叶片覆冰状态预测模型,通过大量历史数据对 Bi-LSTM 预测模型及 SVM 模型进行训练,Bi-LSTM 预测可以得到更好的预测效果。此外,结合实际数据,对风机叶片未来一段时间是否会出现覆冰故障进行预测,预测结果表明所提的方法正确率可以达到 95.0%,在准确性和时效性上要强于其他传统方法。进一步地,当获得新的实际数据后,预测模型可以继续对训练集进行扩展,进而提高预测准确率。同时可以为风机叶片覆冰状态预测提供可靠的决策依据,确保风电场在严寒季节能安全经济运行。

参考文献

- [1] 都亮. 电力工业可持续发展技术[M]. 北京:中国水利水电出版社,2013.
- [2] 东乔天,金哲岩,杨志刚. 风力机结冰问题研究综述[J]. 机械设计与制造,2014(10):269-272.
- [3] 王雪冬. 浅谈风机叶片覆冰情况分析及运行监控[J]. 海峡科技与产业,2017(10):77-78.
- [4] Davis N, Hahmann A N, Clausen N E, et al. Forecast of Icing Events at A Wind Farm in Sweden[J]. Journal of Applied Meteorology and Climatology,2014,53(2):262-281.
- [5] 许斌,郭雪怡,陈洪兵. 基于压电陶瓷的风机叶片模型覆冰主动监测[J]. 压电与声光. 2017(1):72-76.
- [6] Yang W, Court R, Jiang J. Wind Turbine Condition Monitoring by the Approach of SCADA Data Analysis[J]. Renewable Energy,2013,53:365-376.
- [7] 张启亮. 基于 SCADA 数据特征的风电机组叶浆结冰辨识研究[D]. 北京:华北电力大学,2018.
- [8] Li M, He X. An Accurate Detection Method for Turbine Icing Issues Using LSTM Network[J]. IOP Conference Series: Earth and Environmental Science, 2019, 237(3): 032109.
- [9] 池昊,彭成,贺婧,等. 基于 SCADA 数据的风机叶片结冰短期预测方法[J]. 信息与电脑,2019(4):61-65.
- [10] 周志华,王珏. 机器学习及其在应用 2009[M]. 北京:清华大学出版社,2009.
- [11] 王敏,陈民锋,刘广为,等. 主成分分析法确定海上油田水驱效果评价关键指标[J]. 油气地质与采收率, 2015,22(2):112-116.
- [12] 李铭璐. 基于深度学习的风机叶片覆冰故障检测方法研究[D]. 武汉:华中科技大学,2019.
- [13] Greff K, Srivastava R K, Koutnik J, et al. LSTM: A Search Space Odyssey[J]. IEEE Transactions on Neural Networks & Learning Systems, 2016, 28(10): 2222-2232.
- [14] 唐子卓,刘洋,许立雄,等. 基于负荷数据频域特征和 LSTM 网络的类别不平衡负荷典型用电模式提取方法[J]. 电力建设,2020,41(8):17-24.
- [15] 杨龙,吴红斌,丁明,等. 新能源电网中考虑特征选择的 Bi-LSTM 网络短期负荷预测[J]. 电力系统自动化,2021,45(3):166-173.
- [16] 石晓文,蒋洪迅. 面向高精度与强鲁棒的空气质量预测 LSTM 模型研究[J]. 统计与决策,2019(16): 49-53.
- [17] 陈雨鸽,高伟,林鸿伟,等. 一种基于长短期记忆网络的线路覆冰预测模型研究[J]. 电工电气,2020(3): 5-11.

作者简介:

熊昌全(1966),男,高级工程师,主要研究方向为风电场安全稳定运行、电力系统安全;

张宇宁(1981),男,工程师,主要研究方向为风电场安全稳定运行、电力系统安全。

(收稿日期:2021-01-14)