

DOI: 10.19650/j.cnki.cjsi.J2311119

基于 CNN-LSTM-AM 动态集成模型的 电站风机状态预测方法*

魏玮¹, 吕游^{1,2}, 齐欣宇¹, 刘吉臻^{1,2}, 房方^{1,2}

(1. 华北电力大学控制与计算机工程学院 北京 102206; 2. 新能源电力系统国家重点实验室
(华北电力大学) 北京 102206)

摘要:针对电站负荷变化时风机状态预测模型精度降低的问题,提出一种基于卷积神经网络(CNN)、长短时记忆(LSTM)网络与注意力机制(AM)的动态集成状态预测方法。首先,利用CNN将样本数据划分为边界有重叠的不同类别,实现风机运行状态的软分类;其次,在传统的LSTM网络的中引入AM层,构造不同工况下的LSTM-AM子模型,并将CNN输出的软分类标签作为初始权值,使用遗传算法对权值偏置进行搜索寻优;最后,对各个子模型的输出值加权求和,得到风机不同运行状态下的集成预测值。实验结果表明,相较各个LSTM-AM子模型和单一LSTM-AM模型,本文提出的基于CNN-LSTM-AM的动态集成模型在电站风机变负荷运行时可以将预测结果的均方根误差分别减小11.5%和22.3%,说明此模型具有更好的鲁棒性和适用性。

关键词: 状态预测;卷积神经网络;长短时记忆网络;注意力机制;集成学习

中图分类号: TM315 TH442 **文献标识码:** A **国家标准学科分类代码:** 470.40

State prediction method for power plant fans based on the CNN-LSTM-AM dynamic integrated model

Wei Wei¹, Lyu You^{1,2}, Qi Xinyu¹, Liu Jizhen^{1,2}, Fang Fang^{1,2}

(1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;
2. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources,
North China Electric Power University, Beijing 102206, China)

Abstract: To solve the problem of low accuracy of the fan state prediction model when the power plant load changes, a dynamic integrated state prediction method based on convolutional neural network (CNN), long short-term memory (LSTM) network and attention mechanism (AM) is proposed. Firstly, the CNN is used to divide the sample data into different classes with overlapping boundaries to achieve soft classification of wind turbine operating conditions. Then, the AM layer is introduced into the traditional LSTM network. LSTM-AM networks as sub-learners are established under different work conditions. The soft classification labels output by CNN are used as the initial weights, and the genetic algorithm is used to search for the optimal weight bias. Finally, the output of each sub-learner is multiplied with corresponding weights and summed to obtain the integrated prediction value, which could improve the prediction accuracy under different operating conditions of power plant fans. The experimental results show that, compared with each LSTM-AM sub-model and signal LSTM-AM model, the proposed CNN-LSTM-AM dynamic integrated model can reduce the relative mean square error by 11.5% and 22.3% when power plant fans are operating under variable loads. Results indicate that the model has better robustness and applicability.

Keywords: state prediction; convolutional neural network; long short-term memory network; attention mechanism; ensemble learning

0 引言

随着电力系统的升级改造,新能源电力逐步规模化接入电网,对燃煤机组的弹性运行能力提出了更高的要求^[1]。风机是火电站重要的辅机设备,长期工作在高温气流与飞灰的冲刷下,具有较高的故障率。在锅炉启停、负荷变化及深度调峰时,风机轴承振动升高,更易引发叶片疲劳甚至转子断裂、叶片飞出等故障^[2]。因此,对风机的运行状态进行准确预测对保障火电站的安全稳定运行具有重要意义。

随着计算机技术的飞速发展,基于历史运行数据构造风机的状态预测模型逐渐成为设备故障预警与健康管管理^[3-5](prognostics health management, PHM)领域的主流方法,即利用大量的监测数据和信息,借助各种模型或人工智能算法,监控、预测、评估和管理设备的健康状态,及时发现隐患,制定相应的维修策略,最大程度上降低故障影响,实现设备自主保障。如利用非线性状态估计^[6]、支持向量机^[7]、长短时记忆(long short-term memory, LSTM)网络^[8-9]、Elman网络^[10]、变分自编码网络^[11]和堆叠自编码网络^[12]等建立设备的状态预测模型。其中,LSTM网络在隐含层增设了一个单元状态,用于保存历史时刻的状态信息,能够充分考虑数据变化过程的动态特性,因而表现出更好的预测效果^[13-17]。

工况样本的特性分布对模型的精度具有较大的影响,文献[18]采用K-means聚类算法进行样本分类,根据分类后的数据训练相应的神经网络模型,提高了不同类别下的建模精度。然而,使用K-means聚类算法进行状态分类,只考虑了数据的幅值特性,分类后得到的数据不一定具备原始输入中的时间连续性,在后续构建预测模型时无法选用要求时间特性的相关网络。卷积神经网络(convolutional neural network, CNN)是一种带有卷积结构的深度神经网络^[19],具有良好的鲁棒性和泛化能力,作分类器时不仅具有较高的识别精度,且相对K-means等低维聚类算法,可以直接处理二维或三维输入;若将时间序列重构为二维矩阵,以图像的形式输入CNN进行特征识别,便可实现动态工况的分类。如果根据CNN的输出分类值选取LSTM模型的训练数据,既能考虑时间序列内的数值分布规律的差异,又能捕捉风机状态变化过程的动态特性。

鉴于此,本文引入注意力机制(attention mechanism, AM),提出了一种基于CNN-LSTM-AM的动态集成风机状态预测模型。首先,考虑利用CNN对风机状态数据进行软划分,进而构建不同工况下的LSTM子模型,并引入AM层改进LSTM网络的结构来提高计算速度;同时,将CNN输出的软分类标签作为初始权值,对各LSTM-AM子模型

的输出进行加权综合得到集成预测值,以集成预测值与实际观测值的偏差最小为目标函数,利用遗传算法完成权重偏置寻优;最后,以某燃煤锅炉的送风机实际运行数据为算例,将本文提出的CNN-LSTM-AM模型与单一LSTM-AM模型的预测效果进行对比,验证了本方法的优势。

1 方法原理及实现

1.1 基于CNN的风机状态软分类

卷积神经网络是一类包含卷积运算的前馈神经网络(feedforward neural networks, FNN),由输入层、卷积层(convolutional layer)、池化层(pooling layer)、全连接层和输出层构成,卷积层和池化层交替连接形成深度结构。CNN具有共享权重、平移不变等特点,能够实现表征学习(representation learning),被广泛应用于计算机视觉、自然语言处理、图像识别等领域^[20]。

设输入变量为 x ,构造变化量序列作为输入向量,为了满足CNN的输入格式,设置时间窗长度为 $L = s \times s + 1$,得到变化量序列 $\{\Delta x_1, \Delta x_2, \dots, \Delta x_{s \times s}\}$,其中 $\Delta x_1 = x_2 - x_1$, x_1, x_2 为相邻时刻采样值,在输入CNN时只需将该序列由 $(L-1) \times 1$ 维变形为 $s \times s$ 维, s 代表为CNN设置的二维输入矩阵的维度。

Δx 的正负反映了数据的上升、下降状态及变化频率,其大小则反映了数据的波动幅度。本文通过计算时间窗口内 $\Delta x > 0, \Delta x < 0, \Delta x \approx 0$ 的数量 Q_a, Q_d, Q_s 和绝对值累加和 $V_a, V_d, V_s \approx 0$,综合加权并归一化处理得到每组时间序列的分类标签,进一步构造软分类标签向量 $\{P_a, P_d, P_s\}$ 用于CNN的训练及测试。其中:

$$P'_a = \omega_q \times \frac{Q_a}{Q_a + Q_d + Q_s} + \omega_v \times \frac{V_a}{V_a + V_d + V_s} \quad (1)$$

$$P'_d = \omega_q \times \frac{Q_d}{Q_a + Q_d + Q_s} + \omega_v \times \frac{V_d}{V_a + V_d + V_s} \quad (2)$$

$$P'_s = \frac{Q_s}{Q_a + Q_d + Q_s} \quad (3)$$

其中, P'_a, P'_d, P'_s 为基于数据变化情况加权计算得到的初步标签值,经归一化后得到最终的分类标签值 P_a, P_d, P_s :

$$P_a = \frac{P'_a}{P'_a + P'_d + P'_s} \quad (4)$$

$$P_d = \frac{P'_d}{P'_a + P'_d + P'_s} \quad (5)$$

$$P_s = \frac{P'_s}{P'_a + P'_d + P'_s} \quad (6)$$

其中, ω_q, ω_v ($\omega_q + \omega_v = 1$)是为平衡数据波动幅度与频率而设置的权值。

基于 CNN 分类得到的标签向量可用于对原采样数据进行状态划分后输入不同的子网络实现分类预测, 以提高模型在复杂工况环境下的适用性。

1.2 基于 LSTM-AM 的状态预测模型

1) 长短时记忆网络

长短时记忆网络是一种具有长期记忆能力的循环神经网络 (recurrent neural network, RNN), 由输入层、隐含层、输出层构成, 通过在隐含层中引入输入门、遗忘门、输出门 3 个门控开关, 有选择地保留、丢弃和传递时间序列中的信息, 从而解决原始 RNN 在随时间反向传播的过程中出现的梯度消失问题。

LSTM 在处理长距离依赖问题时具有突出优势, 因而在图像识别、自然语言处理、趋势预测等领域有广泛应用。本文利用 LSTM 网络搭建设备的状态预测模型^[21]。

LSTM 网络的隐含层输出既有由隐含层神经元个数决定的空间维度, 还有由时间步长决定的时间维度。因此, 隐含层到输出层连接可能出现多种模式, LSTM 网络的复杂程度也会相应受到影响。最常使用的方式是将各个时刻各隐含层神经元的输出全部展开, 与输出层的神经元进行全连接, 如前文所设, 若 LSTM 网络的输入时间窗口长度为 L , 隐含层神经元个数为 N_h , 输出层神经元个数为 N_o , 此时隐含层与输出层之间会出现 $(L \times N_h + 1) \times N_o$ 个需要在训练过程中完成寻优的参数, 若计划用增加隐藏层神经元数来提高网络预测精度, 会导致计算机负担过重, 从而影响运行速度。为此, 本文提出在 LSTM 网络的隐含层后引入一层注意力机制层 (如图 1 中虚线框所示)。

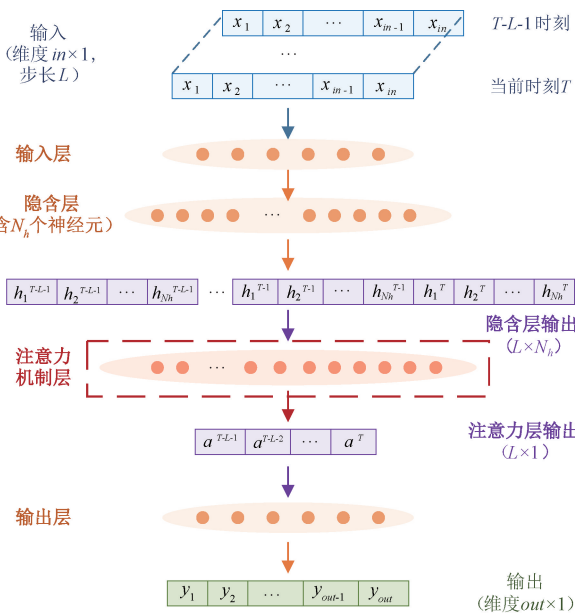


图 1 LSTM-AM 模型结构

Fig. 1 Architecture of the LSTM-AM model

2) LSTM-AM

注意力机制源于对人类视觉的研究, 在认知科学中, 由于信息处理的瓶颈, 人类会选择性地关注所有信息的一部分, 忽略其他可见的信息。一种非正式的说法是, 神经注意力机制可以使得神经网络具备专注于其输入 (或特征) 子集的能力, 在计算能力有限的情况下, 将资源分配给更重要的任务, 其本质是实现对信息的重要性评估和取舍。

为了在保留时间信息的同时, 减少网络参数, 降低计算负担, 提高计算速度, 本文基于注意力机制的原理, 在原 LSTM 网络的隐含层与输出层之间增设了一层全连接层, 目的是通过本层运算, 对各个时刻的多个隐含层神经元输出进行加权综合, 将输出维度降为 $L \times 1$ 后再与输出层相连, 其中, 每个时刻的输出值与注意力机制层的连接权重共享。假设注意力层神经元个数为 N_a , 此时需计算的参数数量为 $(N_h + 1) \times N_a + (L + 1) \times N_o$ 个, 增加隐含层神经元数对参数个数的影响大大减小, 有利于提高模型计算精度和效率。

2 CNN-LSTM-AM 模型动态集成预测方法

本文提出一种基于 CNN-LSTM-AM 的动态集成模型用于电站风机状态预测。其中, CNN 负责对采样数据进行动态分类, 基于 AM 改进的 LSTM 模型负责精确预测, 最后, 根据 CNN 输出的分类标签值, 叠加搜索算法得到的微小偏置值后, 对 LSTM-AM 子模型的输出进行加权综合, 得到集成预测值。模型训练过程如图 2 所示。

1) 分析设备历史运行数据, 选取能表征设备运行状态的变量作为特征变量用于状态分类。

2) 考虑 CNN 的输入特性和 LSTM 网络的预测需要, 根据式 (7) 确定输入序列的时间步长 L :

$$L = s \times s + 1 \quad (7)$$

式中: s 为正整数, 代表为 CNN 设置的二维输入矩阵的维度。

3) 计算时间窗口 L 内相邻采样时刻特征变量的变化量, 得到其变化量序列。沿时间轴滑动窗口, 得到一系列变化量序列。

4) 将计算得到的变化量序列由 $(L - 1) \times 1$ 维变形为 $s \times s$ 维, 作为 CNN 的输入数据。

5) 根据式 (1) ~ (6) 得到分类标签向量 $\{P_a, P_d, P_s\}$, 作为 CNN 训练及验证阶段的标签集, 完成 CNN 模型的训练及测试。

6) 利用相关分析法从设备监测参数中选择 LSTM-AM 模型的建模变量, 根据步长 L , 利用滑动窗口技术确定 LSTM-AM 模型的输入和输出数据。

7) 根据特征向量标签数据设置分类阈值, 从建模变量数据集中划分出上升占比高数据集 (代表设备运行时

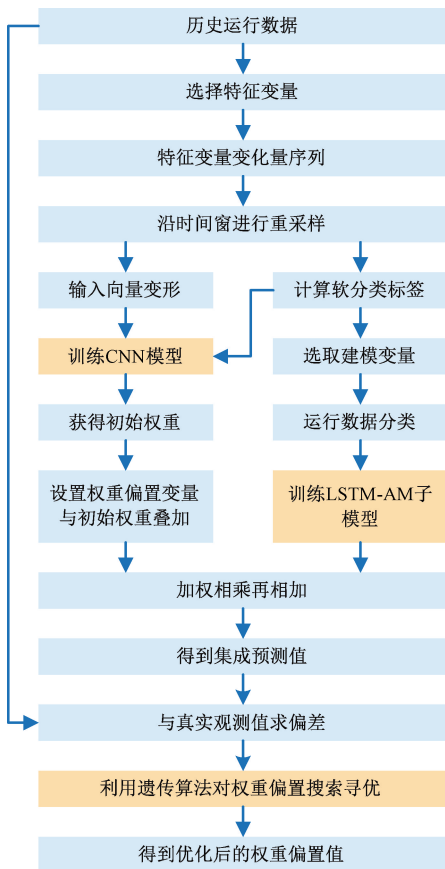


图2 CNN-LSTM-AM 模型构建

Fig. 2 The construction of the CNN-LSTM-AM model

负荷上升)、下降占比高(代表设备运行时负荷下降)数据集和平稳(代表设备运行时负荷平稳)数据集,分别代表3类设备状态,用于3个LSTM-AM子模型的训练及验证。

8) 将未经分类的建模变量数据重新输入到训练好的CNN模型和3组子LSTM-AM模型中,得到CNN输出的分类值 P_a, P_d, P_s 和3个LSTM-AM子模型输出的预测值 O_1, O_2, O_3 。

9) 将CNN输出的分类值作为权重向量基础值,即 $w_1 = P_a, w_2 = P_d, w_3 = P_s$ 。设置权重向量偏置变量 b_1, b_2, b_3 ,用于与基础值 w_1, w_2, w_3 叠加后得到 $\omega_1, \omega_2, \omega_3$ 作为优化权重值,即:

$$\omega_1 = w_1 + b_1 \quad (8)$$

$$\omega_2 = w_2 + b_2 \quad (9)$$

$$\omega_3 = w_3 + b_3 \quad (10)$$

10) 将权值与3个LSTM-AM子模型的输出值对应相乘再求和后得到集成预测值 O 的表达式:

$$O = \omega_1 \times O_1 + \omega_2 \times O_2 + \omega_3 \times O_3 \quad (11)$$

11) 将集成预测值与真实观测值的偏差最小作为目标函数,利用遗传算法对偏置值 b_1, b_2, b_3 进行搜索寻优。

基于上述步骤,最终可以得到训练好的CNN-LSTM-AM模型和优化后的权重偏置值。在实际运行时,将新得到的采样数据输入CNN-LSTM-AM模型,模型会将CNN输出的分类标签值作为初始权重,与训练过程搜索得到的最优偏置叠加后,再与LSTM-AM子模型的输出数据对应相乘再求和,得到集成预测值。

3 案例分析

本文选用某火电厂送风机在2021年2月6日14:00~2月12日22:00的8640组运行数据作为训练集和验证集,另外选取该送风机在2021年2月11日22:00~2月13日14:00的1440组数据作为测试集。上述数据的采样间隔为10s。采集到的送风机监测参数如表1所示。

表1 送风机监测参数说明

Table 1 Description of forced draft fan parameters

| 变量 | 说明 | 单位 |
|-------|-------------|----|
| i | 电机电流 | A |
| P | 电机功率 | kW |
| t_1 | 前轴承温度(3个) | °C |
| t_2 | 中轴承温度(3个) | °C |
| t_3 | 后轴承温度(3个) | °C |
| t_4 | 电机前轴承温度 | °C |
| t_5 | 电机后轴承温度 | °C |
| t_6 | 电动机绕组温度(6个) | °C |
| l_1 | 轴承水平振动 | mm |
| l_2 | 轴承垂直振动 | mm |

对采样数据进行清洗,剔除异常或缺失样本,对温度数据进行3取1或6取1去冗余处理,即从多组测点数据中任取1组参与后续建模分析过程。

3.1 变量选择与参数设置

1) CNN 参数设置

根据工程日志可知,电机电流会随着送风机的负荷变动而调整,因此,本文选用送风机电机电流作为衡量送风机运行状态的特征变量。设置时间步长 $L = 37 = 6 \times 6 + 1$,分类权重 $\omega_p = 0.3, \omega_s = 0.7$,卷积核大小为 3×3 ,数量为10,卷积步长为1,不进行0填充,池化核大小为 2×2 ,CNN全连接层神经元个数为100。

2) LSTM 建模变量选取

通过相关分析发现,送风机前、中、后轴承温度之间,送风机电机前轴承温度、后轴承温度、电动机绕组温度之间的线性相关系数极高,所以可认为送风机前、中、后轴

承温度、送风机电机前轴承温度、后轴承温度、电动机绕组温度互为冗余变量,因此本文在构造 3 个 LSTM-AM 子模型时选用送风机电机电流 i 、电机功率 P 、前轴承温度 t_1 、电机前轴承温度 t_4 、轴承水平振动 l_1 、轴承垂直振动 l_2 作为输入变量。

由于步长 $L = 37$, 所以 LSTM-AM 子模型设置为利用 37 个采样时刻的数据作输入, 预测 10 个采样时刻即 100 s 之后的监测参数取值。

3) LSTM 数据集构造及参数设置

设置分类阈值为 0.8, 若 $P_a > 0.8$, 则该组采样数据归入上升占比高(负荷上升) LSTM-AM₁ 子模型, 若 $P_d > 0.8$, 则归入下降占比高(负荷下降) LSTM-AM₂ 子模型, 若 $P_s > 0.8$, 则归入平稳(负荷平稳) LSTM-AM₃ 子模型。上升和下降类数据波动幅度较大, 会对相应子 LSTM 网络的训练精度产生影响, 而平稳类数据不会影响数据波动特性, 可以起到平滑连接和过渡的作用, 有利于 LSTM 网络捕捉数据变化规律。因此, 将上升和下降占比高这两类数据的分类阈值降为 0.5, 使相关数据集纳入部分平稳类数据, 经测试发现, 相应网络的预测稳定性确实得到改善。

分类完成后, 3 个 LSTM-AM 子模型的训练集与验证集规模如表 2 所示。

表 2 LSTM-AM 子模型训练集与测试集设置

Table 2 The scale of training set and test set of the LSTM-AM model

| 模块 | 训练集 | 验证集 |
|-------------------|-------|-------|
| LSTM ₁ | 3 500 | 1 125 |
| LSTM ₂ | 2 500 | 872 |
| LSTM ₃ | 2 000 | 641 |

3 个 LSTM-AM 子模型包含 1 个隐含层和 1 个注意力机制层, 分别由 50 个隐含层神经元和 36 个全连接神经元构成, 初始学习率为 0.015, 采用 Adam 算法实现反向传播。

4) 权重偏置值寻优

利用遗传算法中的单目标优化算法, 将集成预测值与实际观测值的均方差最小作为目标函数, 输入变量为 3 个权重偏置值, 搜索范围设置为 $[0, 0.1]$, 种群规模为 50。寻优过程如图 3 所示, 可以看出, 搜索 13 代后, 目标函数达到最小值, 得到权重偏置的最优值为 $[0, 0.01345, 0]$ 。

3.2 模型测试

将测试集数据分别输入本文提出的 CNN-LSTM-AM 模型与单一 LSTM-AM 模型进行预测, 为保证对比结果的可靠性, 单一 LSTM-AM 模型在训练时的参数设置与上文

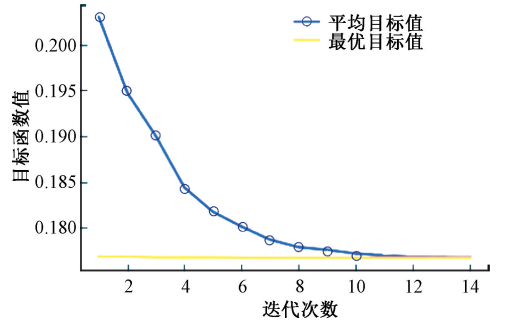


图 3 遗传算法寻优过程

Fig. 3 Optimization process of the genetic algorithm

所述 3 个 LSTM-AM 子模型相同, 包括训练集与验证集大小也控制在相同范围内。采用均方根误差 (root mean square error, RMSE)、相对平方误差 (relative squared error, RSE) 和平均绝对误差 (mean absolute error, MAE) 作为评估指标, 本文所提到的 LSTM₁、LSTM₂、LSTM₃ 子模型、CNN-LSTM-AM 模型及单一 LSTM-AM 模型预测结果如表 3 和图 4 所示。

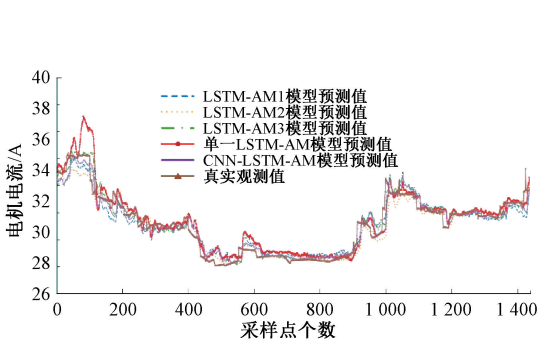
表 3 模型预测结果
Table 3 Prediction results

| 模型 | 变量 | i | P | t_1 | t_4 | l_1 | l_2 |
|----------------------|------|-------|-------|-------|-------|-------|-------|
| LSTM-AM ₁ | RMSE | 0.563 | 8.482 | 0.067 | 0.183 | 0.031 | 0.020 |
| | RSE | 0.092 | 0.095 | 0.010 | 0.004 | 0.206 | 0.539 |
| | MAE | 0.435 | 6.799 | 0.054 | 0.134 | 0.024 | 0.015 |
| LSTM-AM ₂ | RMSE | 0.551 | 7.902 | 0.063 | 0.299 | 0.029 | 0.020 |
| | RSE | 0.088 | 0.083 | 0.009 | 0.011 | 0.188 | 0.514 |
| | MAE | 0.341 | 4.896 | 0.045 | 0.224 | 0.023 | 0.015 |
| LSTM-AM ₃ | RMSE | 0.510 | 7.404 | 0.094 | 0.349 | 0.030 | 0.020 |
| | RSE | 0.075 | 0.072 | 0.020 | 0.015 | 0.191 | 0.539 |
| | MAE | 0.347 | 5.202 | 0.076 | 0.300 | 0.023 | 0.015 |
| CNN-LSTM-AM | RMSE | 0.496 | 7.301 | 0.059 | 0.234 | 0.028 | 0.019 |
| | RSE | 0.072 | 0.071 | 0.008 | 0.007 | 0.178 | 0.517 |
| | MAE | 0.338 | 5.056 | 0.048 | 0.195 | 0.022 | 0.015 |
| 单一 LSTM-AM | RMSE | 0.719 | 9.482 | 0.070 | 0.268 | 0.034 | 0.021 |
| | RSE | 0.150 | 0.112 | 0.011 | 0.009 | 0.256 | 0.567 |
| | MAE | 0.486 | 6.296 | 0.060 | 0.200 | 0.025 | 0.015 |


$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{est} - y_{obv})^2} \quad (12)$$

$$RSE = \frac{\sum_{i=1}^n (y_{est} - y_{obv})^2}{\sum_{i=1}^n (y_{obv} - \bar{y}_{obv})^2} \quad (13)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{est} - y_{obv}| \quad (14)$$




(a) 送风机电机电流
(a) Motor current of the forced draft fan




(b) 送风机电机功率
(b) Motor power of the forced draft fan




(c) 送风机前轴承温度
(c) Front bearing temperature of the forced draft fan



(d) 送风机电机前轴承温度
(d) Front bearing temperature of the forced draft fan motor



(e) 送风机轴承水平振动
(e) Horizontal vibration of the forced draft fan bearing



(f) 送风机轴承垂直振动
(f) Vertical vibration of the forced draft fan bearing

图4 CNN-LSTM-AM模型预测结果

Fig. 4 Prediction results of the CNN-LSTM-AM model

其中, u 为样本数量, y_{est} 为变量的模型输出预测值, y_{obs} 为变量的真实观测值。

以送风机前轴承温度 t_1 为例, 从表3可以看出, 本文所提出的 CNN-LSTM-AM 模型预测值与真实值的均方根误差较 LSTM-AM₁、LSTM-AM₂、LSTM-AM₃ 子模型和单一 LSTM-AM 模型分别提升了 11.9%、6.3%、37.2% 和 15.7%, 相对平方误差分别提升了 20.0%、11.1%、60% 和 27.3%, 平均绝对误差分别提升了 11.1%、-6.6%、36.8% 和 25.0%。其他各组参数基于 CNN-LSTM-AM 模型的预测准确性也得到了不同程度的提高, 且通过对比 3 个 LSTM-AM 子模型与单一 LSTM-AM 模型的预测结果可以发现, 经过 CNN 分类后建立的 LSTM-AM₁ 和 LSTM-AM₂ 子模型由于训练时输入数据的数值分布特征明显且集中, 有利于 LSTM 网络更好的捕获数据变化规律, 因而较单一 LSTM-AM 模型有更好的预测精度, 而 LSTM-AM₃ 子模型的预测精度较低则可能是因为相应类别的训练数据较少且波动程度较大, 因而模型未能很好地学习到数据特征。综上, 本文提出的 CNN-LSTM-AM 模型通过引入 CNN 分类确实能够起到改善模型预测精度的效果。

仍以送风机电机前轴承温度 t_1 为例, 从图4(c)中可以看出, 在温度变化连续阶段, 如图中第 1 000 ~ 1 400 采样点, 5 个模型均具有较好的预测效果, 预测值曲线与真实值曲线贴合紧密。然而, 在温度发生突变时, 如图中第 600 ~ 650 采样点, 温度先由下降变为上升, 大约 300 s 后又开始下降, 此时单一 LSTM-AM 模型无法准确及时地跟随温度真实值做出调整, 出现较大的预测误差; LSTM-AM₁ 和 LSTM-AM₃ 子模型能够较快地跟随温度真实值变化; LSTM-AM₂ 子模型和本文所提出的 CNN-LSTM-AM 模型则能够准确地预测温度真实值的变化, 其预测曲线几乎与真实值曲线重合。LSTM-AM₂ 子模型之所以具有如此高的预测精度, 是因为该

子模型在训练时采用了平稳的数据类别,而平滑数据的特性明显且容易捕捉,建立出的 LSTM 子模型相较于变化数据建立的 LSTM-AM₁ 和 LSTM-AM₃ 子模型更加稳固,具有更好的鲁棒性。综合图 4 中所有变量的预测结果,相较 LSTM-AM₂ 子模型,本文所提出的 CNN-LSTM-AM 模型在面对数据波动即负荷变化情况时表现地更加稳定,不会产生预测值接近真实值曲线,却整体低于真实值的情况,能够紧密及时地捕捉到数值的微小变化,具有更好的预测稳定性。

虽然本文所提出的 CNN-LSTM-AM 模型的预测精度较普通模型来说只是有略有提高,但本文所提出基于 CNN 分类和利用 AM 优化 LSTM 网络预测结果的方法,仍具有以下意义:1) 基于 CNN 状态分类能够提高后续 LSTM 预测模型的针对性,分类结果还可以帮助运维人员了解设备所处的具体运行状态,相应做出调整,因而具有实际的工程意义;2) 从整个模型来看,由于整体复杂度有所增加,在训练阶段会需要更长的时间。但从模型的每个组成部分来看,所用的数据、计算原理和过程都十分简单清晰。例如,本文设置的 CNN 状态分类模型,输入数据和标签数据都是提前设置好的,CNN 只需要从数据挖掘信息实现分类,计算过程简单明确,实际训练速度较快;在增加了 AM 层后,LSTM 网络的预测精度提高,在超参数寻优时可以节约部分的时间,AM 的引入还使得 LSTM 网络能够更好地组合隐含层神经元在每一个输入时刻学习到的信息,强化网络对于时间序列关联信息的挖掘和表达,且在隐含层神经元数量较多时,可以很大程度上减少 LSTM 网络的训练参数数量;此外,本文所述的 CNN 模型和 LSTM-AM 子模型在训练时互不干扰,是可以同时进行的。

综上,将样本数据进行分类后建立的 3 个 LSTM-AM 子模型由于有针对性地学习了数据变化特性,预测效果较未分类的 LSTM 模型均得到了改善。本文所提出的 CNN-LSTM-AM 动态集成模型融和了 3 个 LSTM-AM 子模型的输出,既考虑了时间序列内的数值分布规律的差异,又综合了风机状态变化过程的动态特性,在处理频繁变化的样本时,能够更全面地挖掘输入数据中的有用信息,预测精度进一步提高,在工业应用中具有更好的适用性和鲁棒性。

4 结 论

本文提出了一种基于 CNN-LSTM-AM 模型的电站风机动态集成状态预测方法。首先,基于设备历史运行数

据选出能表征设备运行状态的参数作为特征变量,依据特征变量在时间窗口内的变化情况,构造风机状态分类向量,完成 CNN 模型的搭建。基于分类后的数据,完成 LSTM 子模型的构建,同时引入注意力机制改进 LSTM 模型的结构。将 CNN 输出的分类值与搜索算法得到的偏置值相结合,作为权重与 LSTM-AM 子模型的输出值对应相乘再求和,得到集成预测值。

实际运行时通过时间窗口的滑动实现动态数据的在线分类,利用 LSTM-AM 子模型的输出值加权得到集成预测值。实例测试表明,本文所提出的 CNN-LSTM-AM 动态集成状态预测模型具有较好的鲁棒性,在频繁变工况时也能够实现对电站风机监测参数的准确预测。

参考文献

- [1] 刘吉臻,曾德良,田亮,等. 新能源电力消纳与燃煤电厂弹性运行控制策略[J]. 中国电机工程学报, 2015, 35(21): 5385-5394.
LIU J ZH, ZENG D L, TIAN L, et al. Control strategy for operating flexibility of coal-fired power plants in alternate electrical power systems[J]. Proceedings of the CSEE, 2015, 35(21): 5385-5394.
- [2] 雷萌,吕游,魏玮,等. 基于 LSTM 神经网络与贝叶斯优化的电站风机故障预警[J]. 热能动力工程, 2022, 37(8): 213-220.
LEI M, LYU Y, WEI W, et al. Fault warning of power plant fans based on long short-term memory network and bayesian optimization [J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(8): 213-220.
- [3] 张玉杰,彭宇,刘大同. 飞机机电系统部件数据驱动健康状态在线估计方法综述[J]. 仪器仪表学报, 2022, 43(6): 118-130.
ZHANG Y J, PENG Y, LIU D T. Review on data-driven health state on-line estimation methods for aircraft electromechanical system components [J]. Chinese Journal of Scientific Instrument, 2022, 43 (6): 118-130.
- [4] 年夫顺. 关于故障预测与健康管理的几点认识[J]. 仪器仪表学报, 2018, 39(8): 1-14.
NIAN F SH. Viewpoints about the prognostic and health management [J]. Chinese Journal of Scientific Instrument, 2018, 39(8): 1-14.
- [5] 陈志强,陈旭东,OLIVIRA J V,等. 深度学习在设备故障预测与健康中的应用[J]. 仪器仪表学报,

- 2019, 40(9): 206-226.
- CHEN ZH Q, CHEN X D, OLIVIRA J V, et al. Application of deep learning in equipment prognostics and health management [J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 206-226.
- [6] 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 and soft fuzzy clustering [J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 138-146.
- [7] 朱霄珣, 韩中合. 基于 PSO 参数优化的 LS-SVM 风速预测方法研究[J]. 中国电机工程学报, 2016, 36(23): 6337-6342, 6598.
- ZHU X X, HAN ZH H. Research on LS-SVM wind speed prediction method based on PSO[J]. Proceedings of the CSEE, 2016, 36(23): 6337-6342, 6598.
- [8] 乔石, 王磊, 张鹏超, 等. 基于时间模式注意力机制的 GRU 短期负荷预测[J/OL]. 电力系统及其自动化学报: 1-9 [2023-04-28]. DOI: 10.19635/j.cnki.csu-epsa.001179.
- QIAO SH, WANG L, ZHANG P CH, et al. Short-term prediction of GRU based on temporal pattern attention mechanism[J/OL]. Proceedings of the CSU-EPSA: 1-9 [2023-04-28]. DOI: 10.19635/j.cnki.csu-epsa.001179.
- [9] LING X, PENG H W, XIN Y, et al. Fault detection of wind turbine based on SCADA data analysis using CNN and LSTM with attention mechanism[J]. Measurement, 2021: 175, 109094.
- [10] 段巍, 韩旭, 马良玉, 等. 基于 Elman 神经网络的风力机风轮子系统故障预警[J]. 太阳能学报, 2021, 42(12): 157-162.
- DUAN W, HAN X, MA L Y, et al. Fault prediction of wind turbine wheel subsystem based on Elman neural network [J]. Acta Energetica Solaris Sinica, 2021, 42(12): 157-162.
- [11] 任建亭, 汤宝平, 雍彬, 等. 基于深度变分自编码网络融合 SCADA 数据的风电齿轮箱故障预警[J]. 太阳能学报, 2021, 42(4): 403-408.
- REN J T, TANG B P, YONG B, et al. Wind turbine gearbox fault warning based on depth variational autoencoders network fusion SCADA data [J]. Acta Energetica Solaris Sinica, 2021, 42(4): 403-408.
- [12] 李晓彬, 牛玉广, 葛维春, 等. 基于改进堆叠自编码网络的电站辅机故障预警[J]. 仪器仪表学报, 2019, 40(6): 39-47.
- LI X B, NIU Y G, GE W CH, et al. Early fault warning of power plant auxiliary engine based on improved stacked autoencoder neural network [J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 39-47.
- [13] SMITH W. Time series forecasting: Analysis of LSTM neural networks to predict exchange rates of currencies[J]. Instrumentation, 2020, 7(4): 25-39.
- [14] 谭峰, 李成南, 萧红, 等. 基于 LSTM 循环神经网络的数控机床热误差预测方法[J]. 仪器仪表学报, 2020, 41(9): 79-87.
- TAN F, LI CH N, XIAO H, et al. A thermal error prediction method for CNC machine tool based on LSTM recurrent neural network [J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 79-87.
- [15] 郑太雄, 贺吉, 张良斌. 基于 LSTM 神经网络的混合燃料 HCCI 发动机复杂工况下燃烧正时估计[J]. 仪器仪表学报, 2020, 41(10): 100-110.
- ZHENG T X, HE J, ZHANG L B. Combustion timing estimation of the HCCI engine with mixed fuel under complex operating conditions based on LSTM neural network[J]. Chinese Journal of Scientific Instrument, 2020, 41(10): 100-110.
- [16] SHU T X. Sensory data prediction using spatiotemporal correlation and lstm recurrent neural network [J]. Instrumentation, 2019, 6(3): 10-17.
- [17] 魏书荣, 张鑫, 符杨, 等. 基于 GRA-LSTM-Stacking 模型的海上双馈风力发电机早期故障预警与诊断[J]. 中国电机工程学报, 2021, 41(7): 2373-2383.
- WEI SH R, ZHANG X, FU Y, et al. Early fault warning and diagnosis of offshore wind DFIG based on GRA-LSTM-Stacking model [J]. Proceedings of the CSEE, 2021, 41(7): 2373-2383.
- [18] 张成, 白建波, 兰康, 等. 基于数据挖掘和遗传小波神经网络的光伏电站发电量预测[J]. 太阳能学报, 2021, 42(3): 375-382.

ZHANG CH, BAI J B, LAN K, et al. Photovoltaic power generation prediction based on data mining and genetic wavelet neural network[J]. Acta Energetica Sinica, 2021, 42(3): 375-382.

- [19] 徐卓飞, 李旭东, 张婵婵, 等. 基于孪生网络的小样本滚动轴承故障诊断研究[J]. 仪器仪表学报, 2022, 43(10): 241-251.

XU ZH F, LI X D, ZHANG CH CH, et al. Fault identification for rolling bearing by self-calibrated convolutional neural network under small samples conditions[J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 241-251.

- [20] 雷春丽, 夏奔锋, 薛林林, 等. 小样本下自校正卷积神经网络的滚动轴承故障识别方法[J]. 仪器仪表学报, 2022, 43(9): 122-130.

LEI CH L, XIA B F, XUE L L, et al. Fault identification for rolling bearing by self-calibrated convolutional neural network under small samples conditions[J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 122-130.

- [21] 董静怡, 庞景月, 彭宇, 等. 集成 LSTM 的航天器遥测数据异常检测方法[J]. 仪器仪表学报, 2019, 40(7): 22-29.

DONG J Y, PANG J Y, PENG Y, et al. Spacecraft telemetry data anomaly detection method based on ensemble LSTM [J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 22-29.

作者简介



魏玮, 2020 年于华北电力大学获得学士学位, 主要研究方向为基于深度信息电站设备状态预测及故障预警方法。

E-mail: weiwei_ncepu@163.com

Wei Wei received her B.Sc. degree from North China Electric Power University in 2020. Her main research interests include state estimation and early fault warning method for power station equipment.



吕游 (通信作者), 2009 年于华北电力大学获得学士学位, 2014 年于华北电力大学获得博士学位, 主要研究方向为能源系统建模、优化及设备状态监测方法。

E-mail: you.lv@ncepu.edu.cn

Lyu You (Corresponding author) received his B.Sc. degree from North China Electric Power University in 2009, and received his Ph.D. degree from North China Electric Power University in 2014. His main research interests include energy system modeling, optimization, and condition monitoring methods.