

DOI: 10.3901/JME.2023.14.001

复杂工况条件下多头注意力双向长短时记忆网络的风电机组缺失数据修复方法研究^{*}

余晓霞¹ 汤宝平¹ 王伟影² 吴宣勇¹ 李彪¹

(1. 重庆大学机械传动国家重点实验室 重庆 400044;

2. 中船重工龙江广瀚燃气轮机有限公司 哈尔滨 150078)

摘要: 针对变速变载条件下风电机组监测参量中包含大量缺失数据导致基于深度学习的状态监测模型预警精度低的难题, 提出一种多头注意力双向长短时记忆网络缺失数据修复方法(Multi-headed attention bidirectional long and short term memory network, MA-BiLSTM)。所提方法利用多头注意力机制抑制复杂工况条件下变速变载对神经网络特征提取时的干扰, 采用跨层连接残差单元增加模型的特征提取能力, 充分学习已有监测数据的隐藏特征以及多源参量间的关联关系; 采用双向长短时记忆网络同时对风电机组监测数据的复杂变化规律进行学习, 实现监测参量中缺失数据的预测修复。实例应用结果表明所提多头注意力双向长短时记忆网络能够抑制复杂工况条件下的变速变载干扰, 实现单变量或多变量中缺失数据的预测修复, 有效提升风电机组状态监测精度。

关键词: 风电机组; 缺失数据预测; 多头注意力机制; 双向长短时记忆网络

中图分类号: TH17

Repairing Deteriorated Data of Wind Turbines by Multi-head Attention Bi-directional Long Short Time Memory Networks under Complex Working Conditions

YU Xiaoxia¹ TANG Baoping¹ WANG Weiying² WU Xuanyong¹ LI Biao¹

(1. The State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044;

2. CSSC Longjiang Guanghan Gas Turbine Co., Ltd., Harbin 150078)

Abstract: To address the problem of low early warning accuracy of condition monitoring models due to a large number of missing data in wind turbine monitoring parameters under variable speed and variable load, multi-headed attention bidirectional long and short-term memory networks (MA-BiLSTM) is proposed for repair those data. The multi-headed attention machine is used to suppress the interference of variable loads on the neural network feature extraction under complex working conditions. In addition, the model feature extraction ability is increased by constructing a cross-layer of residual units, and the hidden features of existing monitoring data and the correlation between multi-source parameters are fully learned. The Bi-LSTM cells are used to simultaneously learn the law of the monitoring data of wind turbines to achieve the prediction and repair of incomplete data. The application results show that the proposed MA-BiLSTM networks can suppress the multivariate load disturbance under complex working conditions and realize the repair of incomplete data for improving fault detection accuracy of wind turbines.

Key words: wind turbine; deteriorated data repair; multi-headed attention mechanism; bi-directional long and short term memory network

^{*} 国家重点研发计划(2020YFB1709800)和重庆市自然科学基金(cstc2019jcyj-zdxmX0026)资助项目。20220125收到初稿, 20220718收到修改稿

0 前言

随着深度学习技术的普及,各大型风电公司逐步建立了风电机组大数据智能运维平台,并逐渐开发了基于深度学习风电机组的健康状态监测模型^[1]。现有的风电机组智能运维模型均需要完整且准确的监测数据^[2-3],当监测参量存在缺失数据时,智能运维模型对风电机组的状态监测、故障诊断以及剩余寿命预测精度将出现不同程度的下降^[4]。然而,由于传感器短时异常、网络数据包拥塞、数据传输链路不稳定、网络信道带宽窄变化等原因,风电机组监测系统中常会产生大量的缺失数据。所以研究缺失数据的修复方法,准确监测风电机组工作状态,对提升风电机组健康状态监测模型精度至关重要。

目前缺失数据主要采用填补的方式进行修复,方法主要包含基于统计学和基于数据驱动两大类^[5]。其中,基于统计学的方法主要利用了数据的统计特性对缺失数据进行填补;此类方法只适用于监测数据具有一定统计学规律且分布特性简单的数据,对复杂多变的数据修复较为困难^[6]。传统基于数据驱动的修复方法主要采用了多项式拟合、K 近邻^[7]以及 SVM^[8]等模型度量缺失数据与填补数据之间的距离,调整参数使这一偏差最小,进而实现对缺失数据的修复;此类方法没有学习已有监测数据的变化规律,难以利用监测数据的前后依赖关系,缺失数据修复精度还有进一步提升空间。随着人工智能的不断发展,基于深度学习的数据修复模型因其能够挖掘已有海量数据的隐藏特征,学习监测数据的变化规律,可以实现监测参量中缺失值的修复,从而被广泛应用于缺失数据的修复之中^[9]。

风电机组运行工况复杂多变,监测变量常包含大量的随机扰动。如何在变速变载条件下充分学习风电机组监测参量的变换规律实现缺失数据修复是一个具有挑战性的难题。ZHANG 等^[10]构建了包含 2 个 GRU 单元的 Dual-SSIM 编码模型,充分学习了缺失值前后的数据变化规律,实现了监测参量中缺失值的填补。张晟斐等^[11]利用生成对抗网络和非参数检验实现了缺失数据修复,有效提高了电池剩余寿命预测精度。AWAN 等^[12-13]提出了一种条件对抗生成网络,通过对已有数据的学习,在限定条件下实现了对缺失数据生成。LI 等^[14]基于深度自动编码器网络提出了 LSTM-AEs 模型,采用预测的方式对

燃气轮机的监测数据进行了修复。目前国内外学者对缺失数据修复等相关问题已提出了一些深度学习模型,这些模型能够学习到监测参量的变化规律,可以用于稳定工况条件下的数据修复;但对于修复风电机组变速变载情况下的缺失数据,这些模型在特征提取时容易受到随机干扰,数据修复精度还有进一步提升空间。

多头注意力机制^[15-17]在机器翻译中能够提取语句中的关键信息,有效提升了机器翻译精度。多头注意力机制能够提取输入数据间的关联特征,使其深度学习模型能够充分学习监测参量的变化规律,有望克服复杂工况条件下的变速变载对特征提取的干扰,可以应用于风电机组缺失数据的修复。所以,本文提出了一种多头注意力双向长短时记忆网络的数据修复模型,利用多头注意力机制抑制变速变载对模型特征提取时干扰,并采用双向长短时记忆单元学习监测数据的变化规律,通过对缺失值预测实现风电机组缺失数据修复,进而提升风电机组模型监测精度。

1 风电机组缺失数据分析

1.1 风电机组缺失数据特点

在风电机组 SCADA 监测系统^[18]采集数据过程中,由于传感器短时异常和数据传输不稳定等故障,监测参量中存在一定量的缺失数据。某台风电机组实际部分原始监测参量结果如图 1 所示。




图 1 原始监测数据示例

由图 1 可知,风电机组的监测参量中都存在一定量的缺失值,其中监测参量存在单一参量缺失和多个参量在某一时刻同时缺失的情况。由于风电机组长期工作在变转速和变载荷的复杂工况条件下,所采集到的监测参量的变化具有一定的随机性,监测参量中的缺失数据变化规律也具有一定的不确定性。然而,现有的缺失数据修复方法对复杂工况下监测参量中的随机干扰抑制能力较弱,缺失数据修复精度还有一定提升空间。

1.2 风电机组缺失数据相关性分析

风电机组多监测参量间具有一定的相关性,采用具有较高相关性的参量进行同时修复,有利于提

高缺失数据预测精度^[5]。为更加有效预测风电机组监测参量中的缺失数据, 本文对所有监测参量进行相关性分析, 其相关系数计算方法为

$$\rho = \frac{E[(X_1 - \mu_{X_1})(X_2 - \mu_{X_2})]}{\sigma_{X_1} \cdot \sigma_{X_2}} \quad (1)$$

式中, X_1 与 X_2 表示风电机组中两个监测参量, μ_{X_1}, μ_{X_2} 与 $\sigma_{X_1}, \sigma_{X_2}$ 分别表示两个监测参量的均值与方差, $E(\cdot)$ 表示数学期望。

对风电机组 SCADA 监测系统的主要监测参量进行相关分析。首先收集风电机组的各个变量的历史监测数据, 然后利用式(1)分别计算两个监测变量的相关性, 最后计算所得各个监测变量相关性结果, 如图 2 所示。图中, x_1 为“有功功率”, x_2 为“变桨角度”, x_3 为“瞬时风速”, x_4 为“瞬时风向”, x_5 为“环境温度”, x_6 为“风轮转速”, x_7 为“油池温度”, x_8 为“冷却水温度”, x_9 为“进口油温”, x_{10} 为“绕组最高温度”, x_{11} 为“进口压力”, x_{12} 为“油泵出口压力”, x_{13} 为“机舱振动有效值”, x_{14} 为“机舱温度”, x_{15} 为“机舱 X 方向振动”。

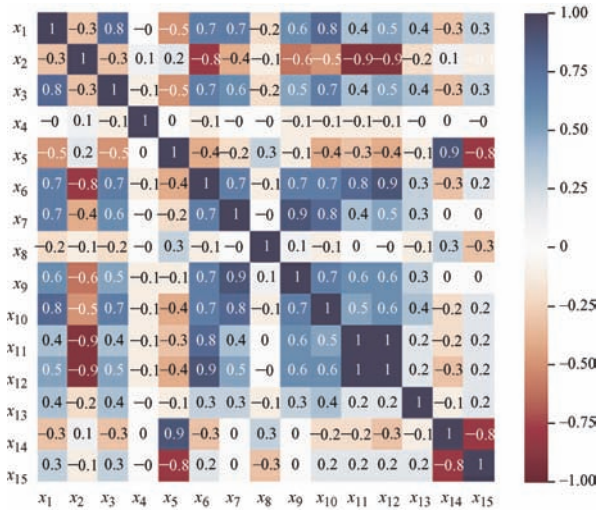


图 2 风电机组 SCADA 系统主要监测参量相关分析结果

由图 2 中的相关分析结果可知, 风电机组监测参量中的有功功率、变桨角度、瞬时风速、瞬时风向、环境温度、风轮转速、油池温度、冷却水温度、进口油温、绕组最高温度、进口压力以及油泵出口压力等参量间相关性较高。为进一步验证变量相关性计算结果的准确性, 对其进行了显著性检验。结果表明: 风电机组监测变量的相关性显著性检验结果 P 值均小于 0.01, 证明变量间的相关性存在, 而不是因为抽样误差所导致, 所得变量间的相关性分析结果符合变量间的实际关系。

当监测参量没有在同一时刻缺失时, 可以利用

参量间的相关性对缺失数据进行修复, 提高风电机组缺失数据修复精度。结合工程实践经验, 选取相关性最大的 12 个监测参量进行同时修复。为抑制复杂工况条件下变速变载对监测参量的随机干扰, 并充分利用监测参量间的相关信息, 提升风电机组缺失数据修复精度, 提出了一种多头注意力双向长短时记忆网络缺失数据修复方法。

2 风电机组缺失数据修复方法

2.1 多头注意力双向长短时记忆网络数据修复模型

为实现高效准确的风电机组缺失数据修复, 提出了一种多头注意力双向长短时记忆网络。所提网络采用多头注意力机制在抑制风电机组复杂工况条件下变速变载的随机干扰, 同时充分学习监测参量中的耦合规律和隐藏特征。采用双向长短时记忆网络学习监测参量中缺失值前后数据的变化规律, 采用预测的方式对风电机组监测参量中的缺失值进行修复。所提模型如图 3 所示。

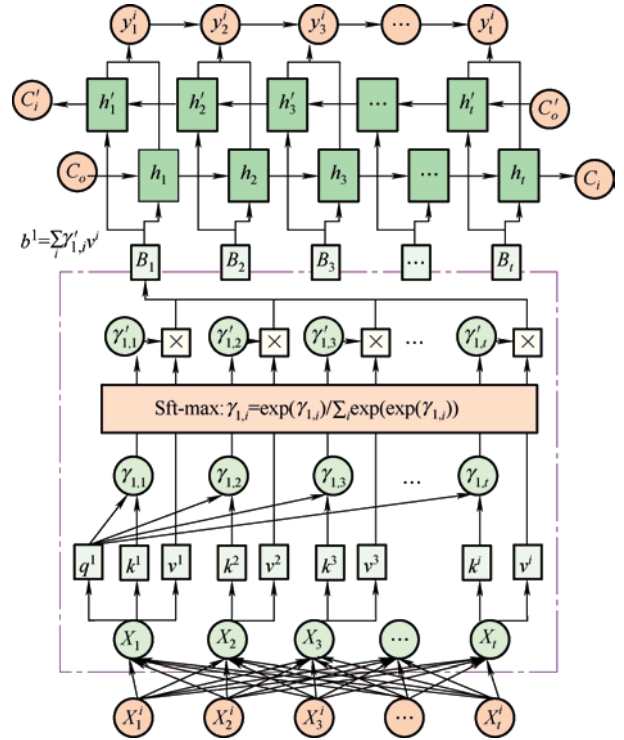


图 3 多头注意力双向长短时记忆网络缺失数据修复模型

图 3 中 x_i^t 与 y_i^t 分别表示所提网络的输入与输出特征, 其中 t 表示时刻, i 表示风电机组的第 i 个监测参量。 f_t 表示 t 时刻的所有参量。在训练过程中, 采用多头注意力机制对同一时刻的所有监测参量学习。当给定一个任务相关的查询向量 q , 通过计算与 k 的注意力分布并附加在 v 上, 然后再通过 softmax 得到自注意机制的输出。在注意力机制网络

中, q 为 $\text{query}(q^i = W^q x^i)$, 其矩阵形式为 $\mathbf{Q} = \mathbf{W}^q \mathbf{X}$; k 为 $\text{key}(k^i = W^k x^i)$, 其矩阵形式为 $\mathbf{K} = \mathbf{W}^k \mathbf{X}$; v 为 $\text{value}(v^i = W^v x^i)$, 其矩阵形式为 $\mathbf{V} = \mathbf{W}^v \mathbf{X}$ 。其中 \mathbf{X} 为自注意力机制层输入向量, $\mathbf{W}^q, \mathbf{W}^k, \mathbf{W}^v$ 为可训练权重参数。 $\gamma_{1,i}$ 为注意力分数, 用以表征 x^1 与 x^i 的相关性, 其计算方法如图 4 所示。




图 4 注意力分数计算方法

图 4 中 \bullet 表示 q 与 k 的点积(Dot-product)。通过计算输入特征两两之间的点积, 得到特征之间的注意力分数。然后, 对所有 $\gamma'_{1,i}$ 进行 $\text{softmax}(\gamma'_{1,i} = \exp(\gamma_{1,i}) / \sum_i \exp(\gamma_{1,i}))$ 。所以, 自注意力机制的特征输出结果为

$$\begin{aligned} O &= \gamma' \cdot \mathbf{V} = \text{soft max}(\gamma) \cdot \mathbf{V} = \\ &\text{soft max}(\mathbf{K}^T \cdot \mathbf{Q}) \cdot \mathbf{V} \end{aligned} \quad (2)$$

在进行实际风电机组的劣势数据预测过程中, 输入参量间存在多重相关性, 所以本文采用多头自注意力机制对其隐藏特征进行学习。

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(O_1, O_2, \dots, O_j) \mathbf{W}^o \quad (3)$$

式中, O_j 为单头注意力机制输出结果, \mathbf{W}^o 为可训练的权重参数。随着网络层数的增加, 所提网络特征提取能力出现一定退化。所以, 本文通过构造跨层连接的残差单元来解决这一问题。

$$\mathbf{B} = \text{Multihead}(\mathbf{X}) + \mathbf{X} \quad (4)$$

式中, \mathbf{X} 为输入特征矩阵, $\text{Multihead}(\mathbf{X})$ 为多头注意力机制输出结果, \mathbf{B} 为该层特征输出结果。

在利用多头注意力机制学习到监测参量间的耦合规律和隐藏特征之后, 采用双向的 LSTM 单元同时学习缺失数据前后的变化规律。其中, C_i, C'_i 与 C_o, C'_o 为双向的 LSTM 单元中细胞中的输入与输出状态, h_t 表示 LSTM 单元, 其遗忘门、输入门、输出门、循环状态以及单元输出的计算方法分别为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (6)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (7)$$

$$C_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (8)$$

$$h_t = o_t * \tanh(f_t * C_{t-1} + i_t * C_t) \quad (9)$$

式中, x_t 表示 t 时刻的 LSTM 单元的输入特征, h_{t-1}, h_t 分别表示 $t-1$ 与 t 时刻的 LSTM 单元的输出, W_f, W_i, W_o, W_c 和 b_f, b_i, b_o, b_c 分别表示遗忘门、输入门、输出门以及循环状态中权重和偏置。所以缺失数据预测结果可以表示为

$$y_t = \sigma(w h_t + w' h'_t) \quad (10)$$

式中, h_t 与 h'_t 表示正反双向 LSTM 单元的输出结果, w, w' 表示可训练权重, $\sigma(\cdot)$ 表示激活函数。在所提模型充分学习到缺失值前后数据变化规律之后, 采用预测的方式对监测参量中放入缺失数据进行修复。

2.2 缺失数据修复流程

利用已有完整数据对多头注意力双向长短时记忆网络进行训练与验证, 然后利用训练完成的模型进行缺失数据修复。

如图 5 所示, 通过对风电机组 SCADA 系统中的监测参量进行相关性分析, 筛选出监测变量中相关性较高且没有缺失数据的完整数据; 将所筛选出的完整数据划分为模型训练数据和验证数据。利用训练数据对所提多头注意力双向长短时记忆网进行训练, 然后利用验证数据对其模型进行验证。当模型通过验证后, 将筛选出的缺失数据段输入到已通过验证后的模型之中, 实现缺失数据的修复。最后, 将已经修复好的数据输入到风电机组状态监测模型中, 用于提高风电机组状态监测精度。

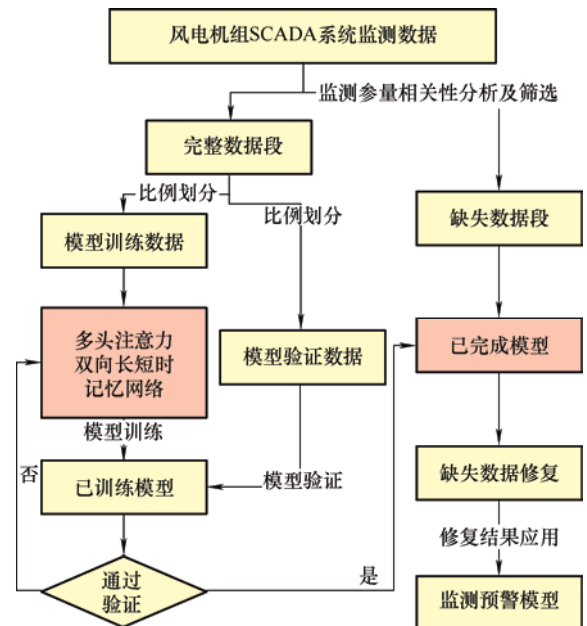


图 5 风电机组缺失数据修复流程

2.3 缺失数据修复结果评价指标

为定量分析所提方法对缺失数据修复的有效性, 利用已有风电机组完整数据对模型进行验证。在对模型进行验证时, 采用平均绝对误差(Mean absolute error, MAE)、方均误差(Mean square error, MSE)以及归一化方均根误差(Normalized root mean square error, NRMSE)三个指标对预测修复结果进行定量评价。

$$MAE = \frac{1}{n} \sum_{i=1}^n |x^i - y^i| \quad (11)$$

$$MSE = \frac{1}{n} \left(\sum_{i=1}^n (x^i - y^i)^2 \right)^{\frac{1}{2}} \quad (12)$$

$$NRMSE = \frac{\left(\sum_{i=1}^n (x^i - y^i)^2 \right)^{\frac{1}{2}}}{\sum_{i=1}^n y^i} \quad (13)$$

式中, n 为缺失值点数, x^i 和 y^i 表示分别第 i 个监测参量的真实值和修复值。

3 实例应用验证

3.1 数据筛选

为验证所提方法的有效性, 采用了某风场 2 台风电机组 SCADA 监测数据对其进行试验验证。所选的监测参量的采样频率为 1 次/min, 采样总时长约 2 年。其中筛选了 30 000 条完整数据用于模型训练, 1 000 条完整数据用于模型验证, 1 000 条缺失数据进行预测修复。

3.2 模型训练

为验证所提模型对风电机组缺失数据预测修复的有效性, 采用 LSTM, BiLSTM, A-BiLSTM 共 3 个模型与所提方法进行对比。所有模型的训练样本和测试样本数据均相同, 训练样本数量为 30 000×12, 测试样本为 1 000×12。所选监测参量均为完整数据, 在测试时假设测试样本为缺失数据, 并利用预测修复值和真实值间的三个指标对各模型进行定量评价。所有模型的优化器为 Adam, 损失函数为 MSE, 学习率为 0.000 1, Batch size 为 64, Epochs 为 300, LSTM 单元数为 12。其中所提模型的多头注意力机制为 12 头, 注意力机制的输入输出

均为包含 12 个神经元的全连接层。所有模型代码都运行在 tensorflow 2.0.0 和 keras 2.2.4 版本的深度学习框架下, 硬件环境为 Intel(R)Core(TM) i7-6700 CPU at 3.40 GHz, Nvidia GeForce GTX 1080, and 64 GBRAM。

3.3 模型验证

针对单一变量缺失数据的修复问题, 本文选取了风电机组中关键性监测参量有功功率进行验证。将所有训练样本分别输入到四个模型之中进行训练, 待训练完成后将测试数据输入到已训练的模型之中进行模型验证。其两台风电机组各模型的测试数据预测结果如图 6 和图 7 所示。

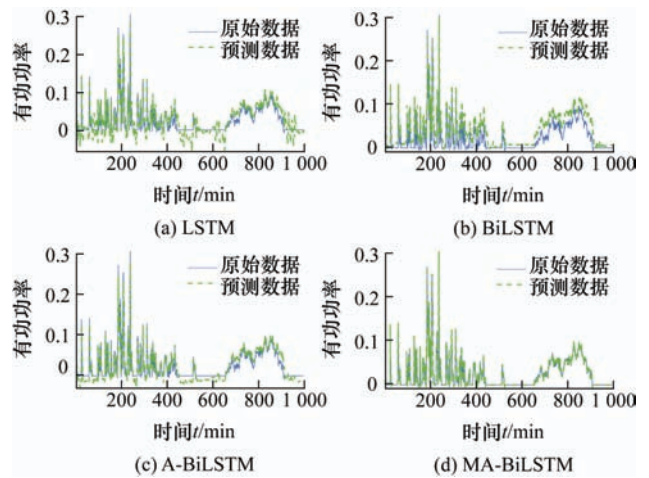


图 6 1 号风机有功功率预测结果




图 7 2 号风机有功功率预测结果

由图 6 和图 7 可知, 相比于 LSTM, BiLSTM, A-BiLSTM 三个模型, 所提方法能够更加有效地预测风电机组监测参量中的有功功率。针对 2 风电机组的有功功率, BiLSTM 模型的预测结修复

结果优于 LSTM，A-BiLSTM 模型又优于 BiLSTM，而所提模型的预测修复结果最好。为定量分析四个模型数据预测的准确性，采用 MAE、MAE、NRMSE 三个评价指标预测修复结果进行定量评价。

由表 1 可知，所提模型对缺失数据预测的结果最好。1 号风机的 MAE、MAE、NRMSE 三个评价指标分别为 5.003×10^{-7} 、 3.347×10^{-8} 、 1.402×10^{-6} ，2 号风机分别为 6.854×10^{-7} 、 4.881×10^{-8} 、 1.566×10^{-6} 。两台风电机组的预测结果 3 评价指标均远小于对比

表 1 单参量缺失数据预测定量评价结果

方法	评价指标	1 号风机	2 号风机
LSTM	MAE	1.309×10^{-2}	5.236×10^{-2}
	MAE	5.180×10^{-3}	2.092×10^{-3}
	NRMSE	2.171×10^{-2}	6.712×10^{-2}
BiLSTM	MAE	9.181×10^{-3}	4.206×10^{-2}
	MSE	0.342×10^{-3}	1.590×10^{-3}
	NRMSE	1.431×10^{-2}	5.102×10^{-2}
A-BiLSTM	MAE	9.606×10^{-3}	1.089×10^{-2}
	MSE	0.382×10^{-3}	4.619×10^{-2}
	NRMSE	3.216×10^{-4}	1.482×10^{-2}
MA-BiLSTM	MAE	5.003×10^{-7}	6.854×10^{-7}
	MSE	3.347×10^{-8}	4.881×10^{-8}
	NRMSE	1.402×10^{-6}	1.566×10^{-6}

模型。产生现象的原因是：首先所提方法采用多头注意力机制不仅充分提取了输入数据中的隐含特征，还学习到了输入参量间的相关信息；在抑制复杂工况条件下变速变载干扰的同时，利用了已有的其他相关参量实现缺失参量的预测修复，其次所提方法采用双向的 LSTM 单元能够同时学习缺失值前后数据的变化规律，可以更加准确地预测缺失值；所以所提方法的预测结果远好于对比模型。

针对风电机组监测参量在同一时刻所有参量均有缺失值的问题，所提模型采用多头注意力机制同时学习 12 监测参量，并采用双向 GRU 单元对 12 个缺失值进行预测修复。其 4 个模型对两台风电机组的缺失数据预测修复结果如图 8 与图 9 所示。

由图 8 与图 9 可知，所提模型对 2 台风电机组监测参量中的缺失数据预测修复结果均优于 LSTM，BiLSTM，A-BiLSTM 三个模型。对比模型中的 LSTM 与 BiLSTM 对于 2 台风机中的各个参量的预测值与真实值差异较大，而 A-BiLSTM 模型在通过添加对 BiLSTM 添加了注意力机制之后，预测结果有一定的提升效果。为定量分析 4 个模型对 2 台风机 12 个参量中的缺失数据预测效果，采用 MAE、MAE、NRMSE 三个评价指标对预测修复结果进行评价，结果如表 2 所示(其表中结果均为各个参量的指标加权平均所得)。

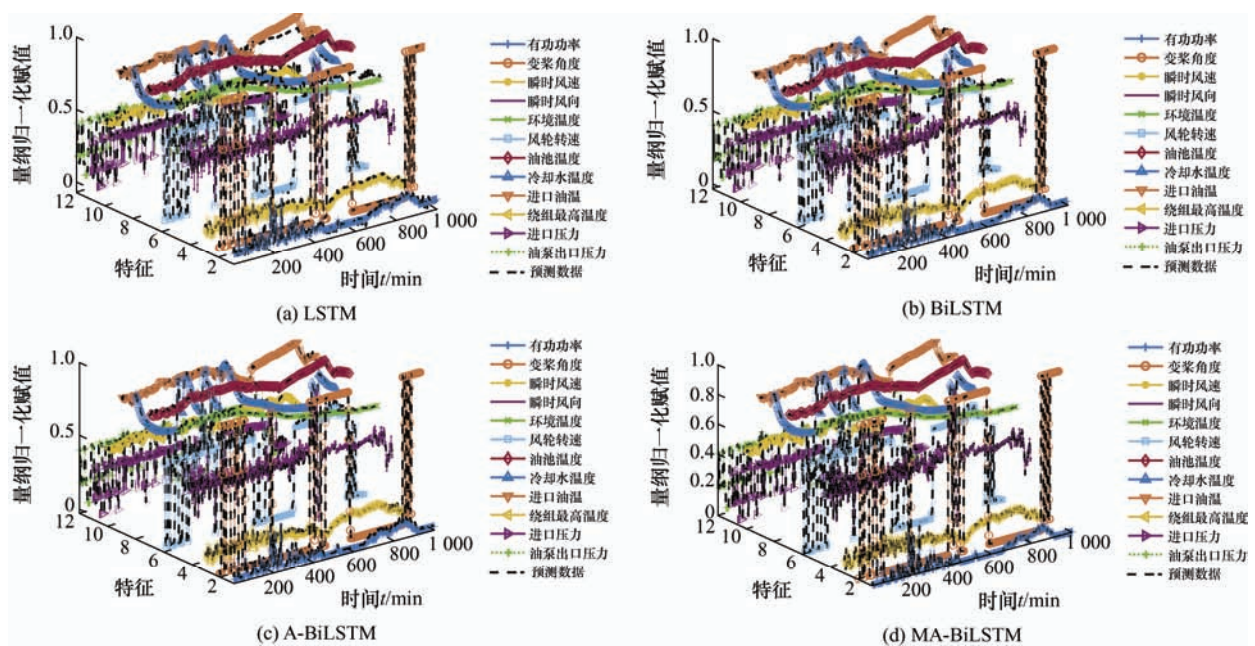


图 8 1 号风机所有参量预测结果

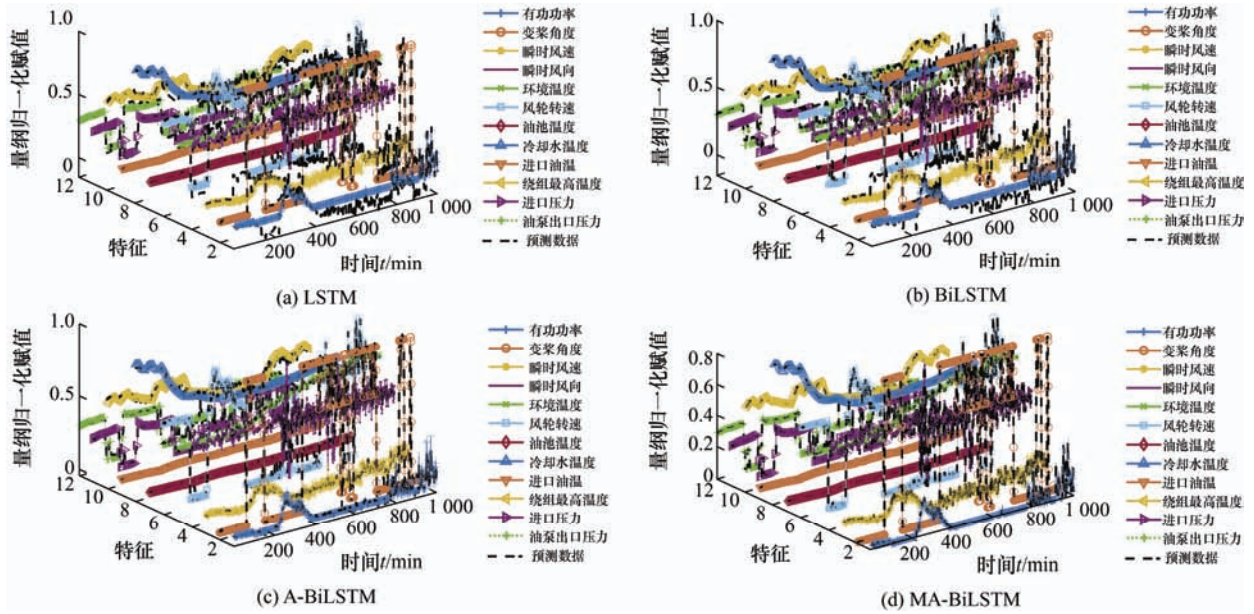


图9 2号风机所有参量预测结果

表2 所有参量缺失数据预测量评价结果

方法	评价指标	1号风机	2号风机
LSTM	MAE	0.304	0.478
	MSE	0.012	0.019
	NRMSE	0.060	0.168
BiLSTM	MAE	0.149	0.367
	MSE	0.006	0.015
	NRMSE	0.034	0.133
A-BiLSTM	MAE	9.973×10^{-3}	1.704×10^{-2}
	MSE	4.045×10^{-3}	7.385×10^{-3}
	NRMSE	1.561×10^{-2}	4.679×10^{-2}
MA-BiLSTM	MAE	1.095×10^{-4}	7.299×10^{-5}
	MSE	4.305×10^{-6}	3.025×10^{-6}
	NRMSE	1.049×10^{-5}	1.124×10^{-5}

由表2可知,所提模型对两台风机多参量的预测效果最好。第一台风机的MAE、MSE、NRMSE分别为 1.095×10^{-4} 、 4.305×10^{-6} 、 1.049×10^{-5} ,第二台风机分别为 7.299×10^{-5} 、 3.025×10^{-6} 、 1.124×10^{-5} ,两台风机各参量预测结果均远小于对比模型。产生现象的原因主要是:①所提模型采用多头注意力机制通过对大量训练样本的充分学习,提取了监测参量的隐藏特征与关联关系,抑制了复杂工况条件下多变载荷的干扰;②所提模型中包含双向的LSTM单元,可以同时学习缺失值前后的数据变化规律,充分利用训练数据中的相似数据,进一步提高了缺失数据的预测修复精度。

3.4 缺失值修复

在验证所提模型数据修复准确性后,利用已训练好的模型对缺失数据段进行修复。最终两台风电机组的监测参量修复结果如图10所示。

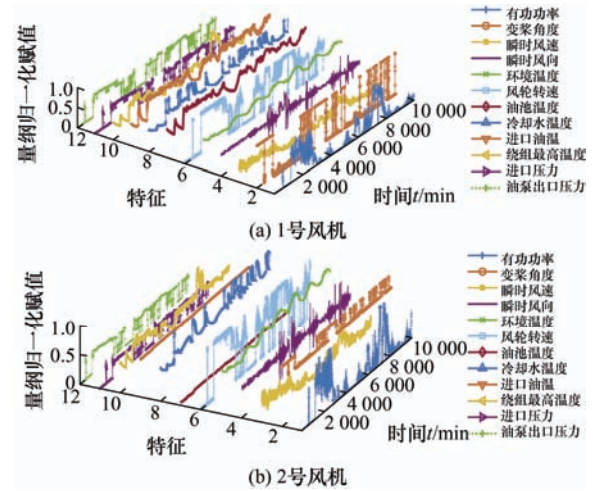


图10 两台风电机组所有参量数据修复结果

如图10所示,所提模型能够准确修复风电机组监测数据。所提方法通过多头注意力机制抑制复杂工况条件下多变载荷对双向长短时记忆单元特征提取时的干扰,充分学习了已有监测数据的隐藏特征以及多源参量间的关联关系,对风电机组监测数据复杂的变化规律进行了学习,实现了监测参量中缺失数据的修复,有效地提升了风电机组监测参量的数据完整性。

3.5 修复后数据应用

在对风电机组SCADA监测数据修复后,采用Auto-Encoder(AE)^[19]对风电机组进行状态监测预警。本文中采用的AE网络结构为8层全连接网络,编码层神经元个数分别为12、8、4、4,解码层神经元个数分别为4、4、8、12。在模型训练完成后,采用模型的输入与输出间的重构误差对风电机组进行健康状态监测。当重构误差超过上限预警值

(UCL), 则认为机组发生了故障。其中, UCL 依据 3σ 原则^[20]确定, 即当某时刻的重构误差大于其均值加上三倍标准差时则认为风电机组已经发生故障。

选择两台风电机组故障发生前的缺失数据进行修复; 在完成数据修复后, 将两台风电机组的修复前后的数据输入到 AE 模型中, 最终监测对比结果如图 11 和图 12 所示。




图 11 1 号风机数据修复前后监测对比结果




图 12 2 号风机数据修复前后监测对比结果

由图 11 和图 12 可知, 对 2 台风电机组监测数据进行修复能够有效提升风电机组状态监测精度。在监测数据未修复时, 监测模型对两台风电机组发生多次错误报警。这是由于在数据未修复时, AE 模型会频繁检测出数据异常, 进而导致重构误差增大, 监测模型频繁错误报警。而当对监测数据进行修复后, 模型只会监测到由于风电机组故障产生的异常数据, 从而实现准确报警。所以所提数据修复模型能够有效提高数据质量, 提升了风电机组健康监测精度。

3.6 模型应用方案

在实际工程应用过程中, 采用历史数据对数据修复模型进行训练, 在训练完成后对其进行封装和部署, 进而实现缺失值修复。

如图 13 所示, 在数据修复模型的使用过程中, 首先需要利用历史数据对数据修复模型进行训练, 在训练完成后保存权重数值文件, 同时编写模型调用接口并对其封装。在模型封装完成后, 通过容器化部署方案将其封装好的模型发布到风电机组大数据监测平台之上。最后接入实时数据进行修复, 并将其修复结果输入到监测预警模型之中, 实现风电机组健康状态监测。

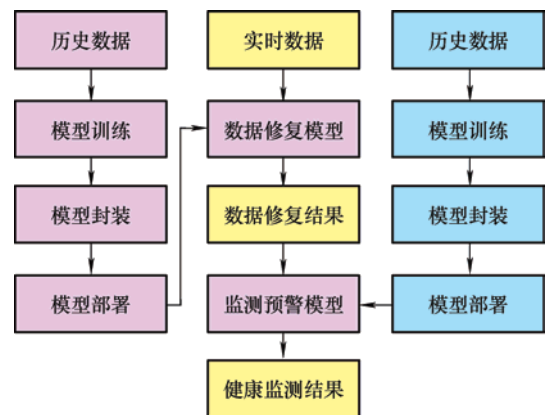


图 13 数据修复模型工程应用实施方案

4 结论

针对风电机组监测数据在复杂工况条件下缺失数据难以修复的问题, 提出了一种多头注意力双向长短时记忆网络缺失数据预测修复模型。所提模型利用多头注意力机制在抑制了变速变载对特征提取的干扰, 充分提取了风电机组监测参量中的隐藏特征与参量间的关联关系, 并采用双向 LSTM 单元对缺失值前后数据的变化规律进行了学习, 实现了风电机组缺失数据的预测修复, 提升了风电机组状态

监测精度, 满足了实际工程应用需求。

参 考 文 献

- [1] 张帆, 刘德顺, 戴巨川, 等. 一种基于 SCADA 参数关系的风电机组运行状态识别方法[J]. 机械工程学报, 2019, 55(4): 1-9.
ZHANG Fan, LIU Deshun, DAI Juchuan, et al. An operating condition recognition method of wind turbine based on SCADA parameter relations[J]. Journal of Mechanical Engineering, 2019, 55(4): 1-9.
- [2] WANG Jinjiang, LIANG Yuanyuan, ZHENG Yinghao, et al. An integrated fault diagnosis and prognosis approach for predictive maintenance of wind turbine bearing with limited samples[J]. Renewable Energy, 2020, 145: 642-650.
- [3] TENG Wei, DING Xian, CHENG Hao, et al. Compound faults diagnosis and analysis for a wind turbine gearbox via a novel vibration model and empirical wavelet transform[J]. Renewable Energy, 2019, 136: 393-402.
- [4] 雷亚国, 许学方, 蔡潇, 等. 面向机械装备健康监测的数据质量保障方法研究[J]. 机械工程学报, 2021, 57(4): 1-9.
LEI Yaguo, XU Xuefang, CAI Xiao, et al. Research on data quality assurance for health condition monitoring of machinery[J]. Journal of Mechanical Engineering, 2021, 57(4): 1-9.
- [5] VELASCO-GALLEGO C, LAZAKIS I. Real-time data-driven missing data imputation for short-term sensor data of marine systems. A comparative study[J]. Ocean Engineering, 2020, 218: 108261.
- [6] KAISER J. Dealing with missing values in data[J]. Journal of Systems Integration, 2014, 5(1): 42-51.
- [7] LI D, DEOGUN J, SPAULDING W, et al. Towards missing data imputation: a study of fuzzy k-means clustering method[C]//International Conference on Rough Sets and Current Trends in Computing. Springer, Berlin, Heidelberg, 2004: 573-579.
- [8] WANG Guanjin, LU Jie, CHOI K, et al. A transfer-based additive LS-SVM classifier for handling missing data[J]. IEEE Transactions on Cybernetics, 2018, 50(2): 739-752.
- [9] HOU K, XIA D, LI Q, et al. A two-stage ensemble of diverse models for recognition of abnormal data in raw wind data[C]//2016 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC). IEEE, 2016: 880-884.
- [10] ZHANG Y, THORBURN P. A dual-head attention model for time series data imputation[J]. Computers and Electronics in Agriculture, 2021, 189: 106377.
- [11] 张晟斐, 李天梅, 胡昌华, 等. 基于深度卷积生成对抗网络的缺失数据生成方法及其在剩余寿命预测中的应用[J]. 航空学报, 2021, 42(6): 625708.
ZHANG Shengfei, LI Tianmei, HU Changhua, et al. Deep convolutional generative adversarial network based missing data generation method and its application in remaining useful life prediction[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(6): 625708.
- [12] AWAN S E, BENNAMOUN M, SOHEL F, et al. Imputation of missing data with class imbalance using conditional generative adversarial networks[J]. Neurocomputing, 2021, 453: 164-171.
- [13] QU Fuming, LIU Jinhai, MA Yanjuan, et al. A novel wind turbine data imputation method with multiple optimizations based on GANs[J]. Mechanical Systems and Signal Processing, 2020, 139: 106610.
- [14] LI Dong, LI Linhao, LI Xianling, et al. A spatio-temporal deep model for multiple time-series missing imputation[J]. Neurocomputing, 2020, 411: 351-363.
- [15] FURFARI F A. The transformer[J]. IEEE Industry Applications Magazine, 2002, 8: 8-15.
- [16] TAY Y, DEHGHANI M, BAHRI D, et al. Efficient transformers: A survey[J]. ACM Computing Surveys, 2020, 55(6): 1-28.
- [17] WANG Zhiwei, MA Yao, LIU Zitao, et al. R-transformer: Recurrent neural network enhanced transformer[J]. arXiv preprint arXiv, 2019: 1-11.
- [18] AZEVEDO H D M, ARAÚJO A M, BOUCHONNEAU N. A review of wind turbine bearing condition monitoring: State of the art and challenges[J]. Renewable and Sustainable Energy Reviews, 2016, 56: 368-379.
- [19] RENSTRÖM N, BANGALORE P, HIGHCOCK E. System-wide anomaly detection in wind turbines using deep autoencoders[J]. Renewable Energy, 2020, 157: 647-659.
- [20] WANG S, ZHANG Z, WANG P, et al. Failure warning of gearbox for wind turbine based on 3σ -median criterion and NSET[J]. Energy Reports, 2021, 7: 1182-1197.

作者简介: 余晓霞, 男, 1993 年出生, 博士研究生。主要研究方向为旋转机械的健康监测、退化趋势预测以及故障识别等。

E-mail: xiaoxiayull@hotmail.com

汤宝平(通信作者), 男, 1971 年出生, 博士, 教授, 博士研究生导师。主要研究方向为机电装备安全服役与退化趋势、测试计量技术及仪器、无线传感器网络等。

E-mail: bptang@cqu.edu.cn