

文章编号: 1671-251X(2024)02-0138-09

DOI: 10.13272/j.issn.1671-251x.2023110024

基于自适应多尺度注意力机制的 CNN-GRU 矿用电机健康状态评估

谭东贵, 袁逸萍, 樊盼盼

(新疆大学 智能制造现代产业学院, 新疆 乌鲁木齐 830017)

摘要: 利用多传感器信息融合技术进行电动机健康状态评估时, 矿用电机监测数据中存在异常值和缺失值, 而卷积神经网络和循环神经网络等深度学习模型在数据质量下降严重的情况下难以有效提取数据特征和更新网络权重, 导致梯度消失或爆炸等问题。针对上述问题, 提出了一种基于自适应多尺度注意力机制的 CNN-GRU(CNN-GRU-AMSA)模型, 用于评估矿用电机健康状态。首先, 对传感器采集的电动机运行数据进行填补、剔除和标准化处理, 并以环境温度变化作为依据对矿用电机运行数据进行工况划分。然后, 根据马氏距离计算出电动机电流、电动机三相绕组温度、电动机前端轴承温度和电动机后端轴承温度等健康评估指标的健康指数(HI), 采用 Savitzky-Golay 滤波器对指标 HI 进行降噪、平滑、归一化处理, 并结合主成分分析法计算的不同指标对矿用电机的贡献度, 对指标 HI 进行加权融合得到矿用电机 HI。最后, 将矿用电机 HI 输入 CNN-GRU-AMSA 模型中, 该模型通过动态调整注意力权重, 实现对不同尺度特征的信息融合, 从而准确输出电动机健康状态评估结果。实验结果表明, 与其他常见的深度学习模型 CNN, CNN-GRU, CNN-LSTM, CNN-LSTM-Attention 相比, CNN-GRU-AMSA 模型在均方根误差、平均绝对误差、准确率、Macro F1 及 Micro F1 等评价指标上更优, 且预测残差的波动范围更小, 稳定性更优。

关键词: 电动机健康状态评估; 自适应多尺度注意力机制; CNN-GRU; 多传感器信息融合; 主成分分析
中图分类号: TD614 文献标志码: A

Health status evaluation of CNN-GRU mine motor based on adaptive multi-scale attention mechanism

TAN Donggui, YUAN Yiping, FAN Panpan

(Intelligent Manufacturing Modern Industry College, Xinjiang University, Urumqi 830017, China)

Abstract: When using multi-sensor information fusion technology to evaluate the health status of motors, there are outliers and missing values in the monitoring data of mine motors. However, deep learning models such as convolutional neural networks and recurrent neural networks find it difficult to effectively extract data features and update network weights when the data quality is severely degraded, resulting in problems such as vanishing or exploding gradients. In order to solve the above problems, A CNN-GRU (CNN-GRU-AMSA) model based on adaptive multi-scale attention mechanism is proposed to evaluate the health status of mine motors. Firstly, the model fills in, removes, and standardizes the motor operation data collected by sensors, and classifies the operating conditions of mine motors based on environmental temperature changes. Secondly, based on the Mahalanobis distance, the health index (HI) of health evaluation indicators such as motor current, three-phase

收稿日期: 2023-11-08; 修回日期: 2024-02-25; 责任编辑: 盛男。

基金项目: 国家自然科学基金资助项目(72361032); 新疆维吾尔自治区重点研发资助项目(2021B01003)。

作者简介: 谭东贵(1997—), 男, 贵州毕节人, 硕士研究生, 主要研究方向为机械设备健康状态评估与预测性维护, E-mail: tan_0514@163.com。通信作者: 袁逸萍(1973—), 女, 新疆石河子人, 教授, 博士研究生导师, 主要研究方向为智能工厂/数字化车间、精益生产、预测性维护, E-mail: yipingyuan@163.com。

引用格式: 谭东贵, 袁逸萍, 樊盼盼. 基于自适应多尺度注意力机制的 CNN-GRU 矿用电机健康状态评估[J]. 工矿自动化, 2024, 50(2): 138-146.

TAN Donggui, YUAN Yiping, FAN Panpan. Health status evaluation of CNN-GRU mine motor based on adaptive multi-scale attention mechanism[J]. Journal of Mine Automation, 2024, 50(2): 138-146.



扫码移动阅读

temperature of motor winding, front bearing temperature of motor, and rear bearing temperature of motor are calculated. The Savitzky Golay filter is used to denoise, smooth, and normalize the HI indicator. Combining the contribution of different indicators calculated by principal component analysis method to mine motors, the weighted fusion of indicator HI is used to obtain the mine motor HI. Finally, the mine motor HI is input into the CNN-GRU-AMSA model, which dynamically adjusts attention weights to achieve information fusion of features at different scales, thereby accurately outputting the health status evaluation results of the motor. The experimental results show that compared with other common deep learning models such as CNN, CNN-GRU, CNN-LSTM, and CNN-LSTM Attention, the CNN-GRU-AMSA model performs better in evaluation metrics such as root mean square error, mean absolute error, accuracy, Macro F1, and MicroF1. The model has a smaller fluctuation range and better stability in predicting residuals.

Key words: health status evaluation of motors; adaptive multi-scale attention mechanism; CNN-GRU; multi sensor information fusion; principal component analysis

0 引言

矿用电动机因其良好的过载能力、调速性能、单位质量功率大等特点,用于驱动提升机、输送机 and 破碎机 etc 矿山装备。矿山环境恶劣、工况复杂,矿用电动机易受温度、振动、湿度^[1]等因素影响,导致电动机过热、机械磨损、绝缘降低等问题,加速电动机损坏,影响生产效率和成本。因此,实时准确评估矿用电动机健康状态对制定合理的维护计划、保障正常生产有重大现实意义。

传统的电动机健康状态评估方法主要依赖单一传感器来实施^[2],即利用单一类型的传感器(如温度、电流、振动等传感器)采集电动机运行数据,通过对数据进行分析 and 特征提取,评估电动机健康状态^[3]。但该方法存在一定的局限性,如对环境噪声敏感、特征提取不充分、评估精度不高等。为克服这些问题,多传感器信息融合技术成为电动机健康状态评估的研究热点。单增海等^[4]通过同时采集多个传感器的数据,利用多传感器信息融合以提供更全面、准确的设备健康状态信息。该方法可充分利用不同传感器的优势,提高监测的覆盖范围和准确性。然而,在实际工况中由于运行环境异常、人为因素干扰及采集设备故障等^[5],矿用电动机监测数据中混杂大量与健康状态无关的异常值且存在缺失值,导致数据质量下降,造成评估结果不稳定。此外,多传感器信息融合也带来了数据融合 and 处理的复杂性,需要高效的算法来处理大量 and 多样化的数据。为减少上述问题,可结合深度学习技术构建更高效、准确、鲁棒的矿用电动机健康状态评估模型。

近年来,深度学习技术在多领域取得了显著突破,其中卷积神经网络(Convolutional Neural Network, CNN)在图像 and 空间数据处理中表现出色^[6],循环神

经网络(Recurrent Neural Network, RNN)在序列数据建模方面非常强大^[7]。Yang Chao 等^[8]将 CNN 和 RNN 结合并提出了卷积循环神经网络(Convolutional Recurrent Neural Network, CRNN),可更好地捕捉时序性和空间信息。樊盼盼等^[9]在缺乏历史故障数据支撑的场景下,采用长短期记忆网络(Long Short-Term Memory, LSTM)构建风电动机组有功功率短期预测模型。袁逸萍等^[10]采用多尺度卷积神经网络(Multiscale Convolutional Neural Networks, MCNN)特征提取层 and 门控制循环单元(Gated Recurrent Unit, GRU)神经网络时间序列预测层搭建滚动轴承剩余寿命预测模型。上述模型在时间维度上展开计算,能很好地处理具有序列特征的数据,但对于数据质量下降严重的情况,上述模型难以有效提取数据特征并更新网络权重,导致容易出现梯度消失或爆炸等问题,影响模型性能。注意力机制可在一定程度上缓解该问题,被广泛应用于深度学习中^[11-12]。

因此,本文提出了一种基于自适应多尺度注意力机制(Adaptive Multi-Scale Attention Mechanism, AMSA)的 CNN-GRU 模型(以下简称 CNN-GRU-AMSA),可根据不同的输入数据自动调整注意力权重,以提高模型对关键信息的关注度,从而提高矿用电动机健康状态评估的准确性。

1 矿用电动机健康状态评估总体框架

矿用电动机健康状态评估总体框架如图 1 所示。首先对传感器采集的数据进行筛选、标准化、工况划分(根据数据的特征或规律将数据分为若干类别)等预处理;然后依据传感器参数的特点,选择能够有效反映矿用电动机健康状况的健康评估指标(电动机电流、电动机三相绕组温度、电动机前端轴承温度和电动机后端轴承温度),计算指标的健康指

数(Health Index, HI),并对 HI 进行降噪、平滑、归一化处理,同时根据指标对矿用电动机的贡献度设置初始权重系数,对各指标 HI 加权融合得到矿用电动机 HI;最后将 AMSA 引入 CNN-GRU 模型,并对模型进行训练和验证,由模型输出电动机健康状态评估结果。

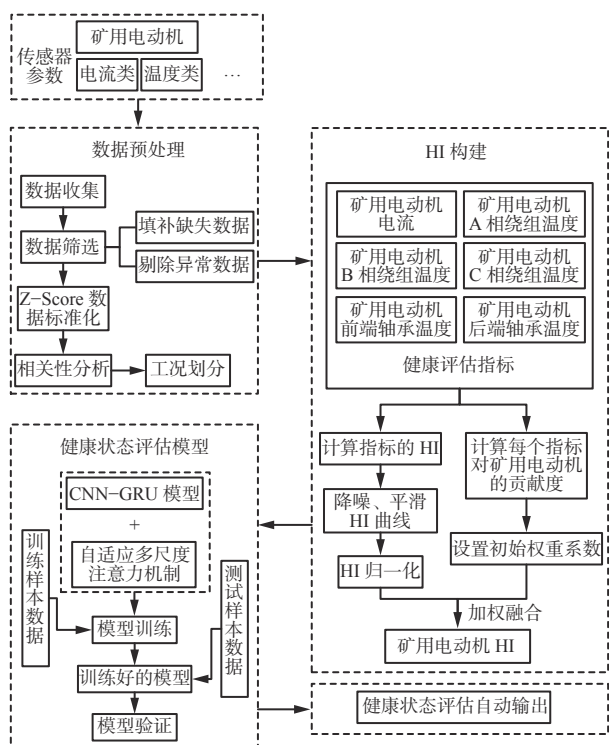


图 1 矿用电动机健康状态评估总体框架

Fig. 1 General framework of health state assessment of mine motor

2 数据预处理

矿用电动机运行工况复杂、环境恶劣、噪声大,易造成部分传感器监测数据异常大或异常小,不能真实反映矿用电动机运行情况。如果将传感器原始数据作为深度网络学习的输入数据,会增加网络规模和训练难度^[13]。为使网络获得更好的预测性能,应先对传感器原始数据进行预处理。

首先,采用牛顿插值法对缺失的数据进行填补^[14];其次,识别并除去异常值,剔除电流、温度小于 0 的数据,以及停机时的数据;然后,对不同传感器测量的数据进行标准化,本文使用常见的 Z-Score 数据标准化方法对输入数据进行缩放^[15],使所有传感器数据量纲统一;最后,对传感器数据与环境温度按斯皮尔曼相关系数法^[16]进行相关性分析,发现环境温度与矿用电动机三相绕组温度、轴承温度具有强相关性,因此,本文依据环境温度变化对矿用电动机运行数据进行工况划分。

3 HI 构建

使用主成分分析(Principal Component Analysis, PCA)算法构建矿用电动机 HI^[17],具体步骤如下。

1) 根据马氏距离^[18]计算健康评估指标的 HI:

$$f_{HI} = \exp(-\varphi \ln(d_{md} - d_{m0})) \quad (1)$$

式中: f_{HI} 为指标 HI; φ 为变化率; d_{md} 为马氏距离; d_{m0} 为基准值, $d_{md} > d_{m0}$ 。

2) 为选择高性能的 HI, 利用 PCA 算法计算不同指标对矿用电动机的贡献度, 按贡献度大小给定权重系数, 能够在保证传感器数据不失真的情况下降低特征维度并去除冗余数据。

3) 由于计算的指标 HI 包含明显噪声, 会对后续评估结果造成影响。Savitzky-Golay(S-G)滤波器^[19]是一种基于曲线局部特征的有效滤波方法, 因此利用 S-G 滤波器进行拟合降噪。为进一步获得平滑的 HI, 使用经验指数函数拟合去噪数据, 其表达式为

$$\lambda(t, K, \alpha, \beta, \gamma) = K \exp(\alpha(t - \beta)) + \gamma \quad (2)$$

式中: $\lambda(\cdot)$ 为随时间 t 变化的经验指数函数; K 为函数的初始值; α 为函数的增长率; β 为时间偏移量; γ 为函数的渐近线。

4) 为保持 HI 的尺度统一, 使用最小-最大归一化方法将 HI 缩放到 $[0, 1]$ 。

5) 根据权重系数对指标 HI 进行加权融合, 得到矿用电动机 HI。

$$W_k = w_k / \sum_{k=1}^l w_k \quad (3)$$

$$F_{HI} = \sum_{k=1}^l W_k A_k \quad (4)$$

式中: W_k 为权重系数; w_k 为指标 k 的贡献度; l 为指标个数; F_{HI} 为融合后的矿用电动机 HI; A_k 为指标 k 对应的全部数据。

4 CNN-GRU-AMSA 模型

4.1 CNN-GRU 模型

CNN-GRU 模型是一种结合 CNN 和 GRU 的深度神经网络模型, 用于处理时间序列数据。CNN 具有出色的分类和回归能力^[20], 可提取数据中的空间特征; GRU 通过引入重置门和更新门^[21], 有效解决标准 RNN 存在的梯度消失和长期依赖问题, 可捕捉数据中的时序关系, 实现对未来数据的预测或分类。CNN-GRU 模型结构如图 2 所示。CNN 层对输入数据进行特征提取, 将原始数据转换为更紧凑、更有信

息量的表示形式,为后续的 GRU 层提供输入;GRU 层对 CNN 层提取的特征进行时序建模,学习序列中的关系和动态变化,为最终的预测提供依据。




图2 CNN-GRU 模型
Fig. 2 CNN-GRU model

4.2 AMSA

GRU 层提取出时间特征后,模型会生成大量的高维时间特征,这些特征很难直观地区分和理解。注意力机制通过合理改变注意力程度来实现重要信息的提取^[22],当注意力机制应用于神经网络时,可使其从大量信息中快速锁定目标中的关键点,从而剔除无用信息,更高效地完成训练任务^[23]。由于矿用电动机涉及不同类型的传感器信号,所以采用 AMSA,根据输入特征的尺度和内容动态地调整注意力权重,从而关注最重要的特征。AMSA 结构如图 3 所示。

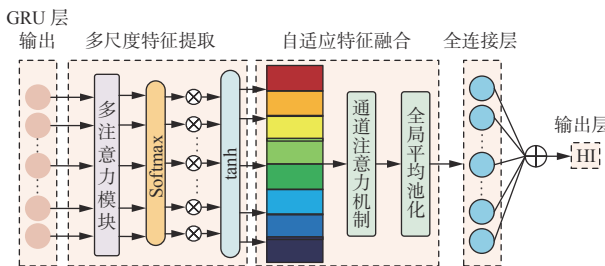


图3 AMSA 结构
Fig. 3 Structure of adaptive multi-scale attention mechanism

5 算例分析

本文选取新疆某大型露天煤矿地面生产系统 126 带式输送机的 1 号矿用电动机的传感器数据进行分析验证。第 1 个时间节点为 2021 年 1 月 16 日 17 时 14 分,采样时间间隔为 1 min,最后一个时间节点为 2021 年 12 月 31 日 19 时 12 分。对数据进行预处理后,数据记录共 38 万多条,将数据导入 PCA 模型中,计算出健康评估指标的个体贡献度与累计贡献度,见表 1。使用 S-G 滤波器对 PCA 处理后的主

成分 1—主成分 6 的 HI 进行降噪处理,得到的 HI 曲线如图 4 所示。借鉴文献^[24]的思想,结合得到的 HI,本文设置 4 个健康状态类别用于评估矿用电动机健康状态,见表 2。

表 1 健康评估指标的个体贡献度与累计贡献度

Table 1 Individual and cumulative contribution degree of health assessment index

主成分	个体贡献度	累计贡献度
主成分1	85.68	85.68
主成分2	12.86	98.54
主成分3	0.94	99.48
主成分4	0.26	99.74
主成分5	0.24	99.98
主成分6	0.02	100.00




图4 降噪处理后的 HI 曲线
Fig. 4 Health index curve after noise reduction

表 2 矿用电动机健康状态评估类别

Table 2 Mine motor health state assessment categories

状态	健康(S_1)	良好(S_2)	恶化(S_3)	故障(S_4)
HI	(0.8, 1.0]	(0.6, 0.8]	(0.3, 0.6]	[0, 0.3]

按式(2)、式(3)对主成分 1—主成分 6 的 HI 进行加权融合,并使用最小-最大归一化方法将 HI 缩放到区间 $[0, 1]$,得到矿用电动机 HI 曲线,如图 5 所示。




图5 矿用电动机 HI 曲线
Fig. 5 Health index curve of mine motor

由于在验证过程中存在随机性,且考虑到环境温度对温度类传感器参数的影响,将数据按环境温度变化(以每变化 5 °C 作为一个区间)划分为 8 个工况(即 8 个子数据集),并分别输入 CNN-GRU-AMSA 模型进行验证,每个子数据集选取其样本数据的 80% 用于训练,其余 20% 作为测试数据,将 HI 与各传感器的时间序列数据拼接,形成最终参与模型训练、预测的数据集。

将输入变量的初始历史时间步长设置为 1.5 h,即输入数据由过去 1.5 h 连续测量的传感器数据和 HI 组成。由于在 CNN-GRU 模型中融入了 AMSA,所以模型在训练过程中会动态调整时间步长与注意力权重,并使用 Adam 优化器以 0.001 的学习率训练模型,用于预测矿用电动机健康状态。

CNN-GRU-AMSA 模型在训练数据与测试数据上的损失值如图 6 所示。可看出训练损失值随着迭代次数的增加逐渐减小并趋于平稳,且测试损失值保持在一个较低的水平上,说明 CNN-GRU-AMSA 模型在训练过程中能够有效降低预测误差,且没有




图 6 CNN-GRU-AMSA 模型损失值

Fig. 6 Loss value of CNN-GRU-AMSA model

出现过拟合现象,具有较强的泛化能力。

各工况下 CNN-GRU-AMSA 模型预测结果的混淆矩阵如图 7 所示。可看出除了工况 5—工况 7 下出现个别分类误差相对较大的情况,整体分类结果较理想。




图 7 不同工况下 CNN-GRU-AMSA 模型预测结果的混淆矩阵

Fig. 7 Confusion matrix of CNN-GRU-AMSA model prediction results under different working conditions

为进一步验证 CNN-GRU-AMSA 模型对矿用电动机健康状态评估的性能,将其与常用的深度学习模型 CNN、CNN-GRU、CNN-LSTM 及 CNN-LSTM-Attention 进行对比,结果如图 8 所示。根据图 8 计算不同工况下各模型的评价指标,包括均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)、最大绝对误差(Maximum

Absolute Error, MAX)、准确率(Accuracy, ACC)、Macro F1 与 Micro F1。不同工况下各模型的评价指标对比结果分别见表 3—表 10。可看出 CNN-GRU-AMSA 模型相比于其他深度学习模型,其整体性能最优。

为了更加直观地对比 CNN-GRU-AMSA 模型的与其他深度学习模型,展示 8 个工况下不同模型

预测残差,如图9所示。可看出 CNN-GRU-AMSA 模型预测残差波动特别小,而其他模型预测残差存

在很大波动,说明 CNN-GRU-AMSA 模型的稳定性更优。




图8 不同模型的 HI 对比

Fig. 8 Health index comparison of different models

表3 工况1下不同模型性能比较

Table 3 Performance comparison of different models under working condition 1

模型	RMSE	MAE	MAX	ACC/%	Macro F1	Micro F1
CNN	0.033 2	0.023 5	0.263 9	88.58	0.564 8	0.584 0
CNN-GRU	0.038 6	0.027 5	0.265 6	89.29	0.600 3	0.637 4
CNN-LSTM	0.031 0	0.021 8	0.246 7	88.20	0.550 7	0.560 2
CNN-LSTM-Attention	0.031 2	0.021 9	0.239 1	87.95	0.541 5	0.544 2
CNN-GRU-AMSA	0.009 6	0.006 4	0.263 4	97.83	0.933 8	0.950 5

表4 工况2下不同模型性能比较

Table 4 Performance comparison of different models under working condition 2

模型	RMSE	MAE	MAX	ACC/%	Macro F1	Micro F1
CNN	0.030 0	0.022 9	0.328 7	89.96	0.713 4	0.786 7
CNN-GRU	0.052 7	0.034 9	0.367 1	85.49	0.612 8	0.644 3
CNN-LSTM	0.034 6	0.026 1	0.363 8	86.93	0.648 6	0.695 8
CNN-LSTM-Attention	0.037 1	0.027 6	0.387 4	86.57	0.640 5	0.682 2
CNN-GRU-AMSA	0.014 1	0.008 0	0.373 3	96.79	0.935 9	0.942 6

表5 工况3下不同模型性能比较

Table 5 Performance comparison of different models under working condition 3

模型	RMSE	MAE	MAX	ACC/%	Macro F1 _c	Micro F1
CNN	0.038 4	0.031 3	0.128 4	78.31	0.424 6	0.437 3
CNN-GRU	0.034 7	0.025 9	0.152 1	90.16	0.599 5	0.607 9
CNN-LSTM	0.038 7	0.029 3	0.133 6	76.82	0.397 9	0.395 6
CNN-LSTM-Attention	0.036 8	0.028 6	0.131 8	78.64	0.425 2	0.434 6
CNN-GRU-AMSA	0.008 0	0.005 7	0.062 2	97.38	0.956 7	0.969 8

表 6 工况 4 下不同模型性能比较

Table 6 Performance comparison of different models under working condition 4

模型	RMSE	MAE	MAX	ACC/%	Macro F1 _c	Micro F1
CNN	0.044 5	0.030 6	0.198 6	96.93	0.633 1	0.641 9
CNN-GRU	0.073 9	0.044 3	0.281 7	83.04	0.452 7	0.474 8
CNN-LSTM	0.050 8	0.033 7	0.216 4	95.66	0.617 7	0.629 9
CNN-LSTM-Attention	0.050 0	0.033 4	0.211 9	95.75	0.618 6	0.630 7
CNN-GRU-AMSA	0.025 0	0.012 9	0.142 8	97.69	0.965 0	0.823 2

表 7 工况 5 下不同模型性能比较

Table 7 Performance comparison of different models under working condition 5

模型	RMSE	MAE	MAX	ACC/%	Macro F1	Micro F1
CNN	0.028 8	0.024 5	0.115 2	91.01	0.516 6	0.552 1
CNN-GRU	0.030 5	0.023 8	0.147 2	92.51	0.640 1	0.665 6
CNN-LSTM	0.026 1	0.021 8	0.110 7	91.80	0.533 6	0.566 7
CNN-LSTM-Attention	0.026 3	0.022 2	0.115 3	91.77	0.532 2	0.565 9
CNN-GRU-AMSA	0.007 5	0.005 4	0.090 5	97.52	0.768 7	0.815 3

表 8 工况 6 下不同模型性能比较

Table 8 Performance comparison of different models under working condition 6

模型	RMSE	MAE	MAX	ACC/%	Macro F1	Micro F1
CNN	0.025 3	0.021 0	0.247 5	95.22	0.472 5	0.521 3
CNN-GRU	0.030 1	0.024 4	0.242 1	95.28	0.475 0	0.523 8
CNN-LSTM	0.022 0	0.018 7	0.242 6	95.13	0.468 9	0.517 4
CNN-LSTM-Attention	0.022 8	0.019 5	0.242 8	95.28	0.475 0	0.523 8
CNN-GRU-AMSA	0.008 5	0.005 3	0.272 2	98.81	0.624 2	0.639 5

表 9 工况 7 下不同模型性能比较

Table 9 Performance comparison of different models under working condition 7

模型	RMSE	MAE	MAX	ACC/%	Macro F1	Micro F1
CNN	0.029 0	0.020 0	0.378 3	87.87	0.411 5	0.439 4
CNN-GRU	0.033 2	0.022 6	0.360 5	86.27	0.388 0	0.400 4
CNN-LSTM	0.025 5	0.017 7	0.347 0	88.80	0.452 0	0.502 9
CNN-LSTM-Attention	0.029 1	0.020 6	0.356 8	86.62	0.384 6	0.402 3
CNN-GRU-AMSA	0.009 1	0.006 4	0.263 4	95.03	0.608 1	0.644 6

表 10 工况 8 下不同模型性能比较

Table 10 Performance comparison of different models under working condition 8

模型	RMSE	MAE	MAX	ACC/%	Macro F1	Micro F1
CNN	0.037 8	0.028 4	0.271 0	85.00	0.587 9	0.572 4
CNN-GRU	0.046 4	0.033 4	0.274 5	83.75	0.575 6	0.563 4
CNN-LSTM	0.035 8	0.024 1	0.255 3	93.94	0.639 4	0.631 3
CNN-LSTM-Attention	0.034 8	0.023 6	0.264 5	93.22	0.635 2	0.626 5
CNN-GRU-AMSA	0.014 0	0.009 0	0.273 3	96.18	0.944 7	0.942 1

6 结论

1) 在 CNN-GRU 模型中引入 AMSA, 从而根据

不同尺度特征的重要性动态分配注意力权重, 实现对不同尺度特征的加权融合, 以提高模型的泛化性和鲁棒性。

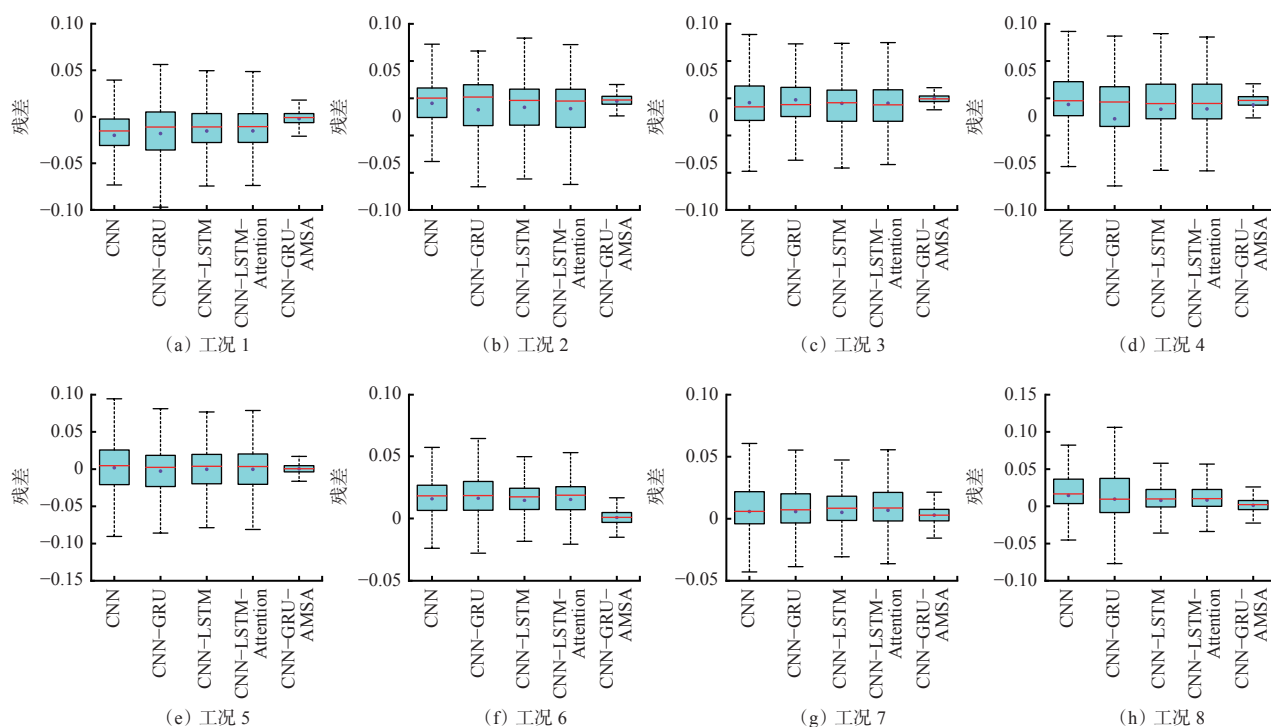


图9 不同模型的预测残差对比

Fig. 9 Comparison of predicted residuals of different models

2) 首先通过多种传感器采集矿用电动机运行数据并进行预处理; 然后根据马氏距离计算健康评估指标的 HI, 再利用 S-G 滤波器对 HI 进行降噪拟合, 结合 PCA 算法确定的每个指标对矿用电动机的贡献度, 通过加权融合得到矿用电动机 HI; 最后使用 CNN-GRU-AMSA 模型对矿用电动机健康状态进行评估。

3) CNN-GRU-AMSA 模型在 RMSE, MAE, ACC, Macro F1, Micro F1 等评价指标上均优于其他模型, 预测残差的波动范围更小, 稳定性更优。

参考文献(References):

- [1] SIDDIQUI K M, SAHAY K, GIRI V K, et al. Health monitoring and fault diagnosis in induction motor-a review[J]. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 2014, 3(1): 6549-6565.
- [2] MEHALA N. Condition monitoring and fault diagnosis of induction motor using motor current signature analysis[D]. Kurushetra: National Institute of Technology, 2010.
- [3] HOU Liqun, BERGMANN N W. Novel industrial wireless sensor networks for machine condition monitoring and fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2012, 61(10): 2787-2798.
- [4] 单增海, 李志远, 张旭, 等. 基于多传感器信息融合和多粒度级联森林模型的液压泵健康状态评估[J]. *中国*

机械工程, 2021, 32(19): 2374-2382.

- SHAN Zenghai, LI Zhiyuan, ZHANG Xu, et al. Health status assessment of hydraulic pumps based on multi-sensor information fusion and multi-grained cascade forest model[J]. *China Mechanical Engineering*, 2021, 32(19): 2374-2382.
- [5] 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.
- [6] HU Weijun, ZHANG Yan, LI Lijie. Study of the application of deep convolutional neural networks (CNNs) in processing sensor data and biomedical images[J]. *Sensors*, 2019, 19(16). DOI: [10.3390/s19163584](https://doi.org/10.3390/s19163584).
- [7] LIPTON Z C, BERKOWITZ J, ELKAN C. A critical review of recurrent neural networks for sequence learning[J]. *Computer Science*, 2015. DOI: [10.48550/arXiv.1506.00019](https://doi.org/10.48550/arXiv.1506.00019).
- [8] YANG Chao, JIANG Wenxiang, GUO Zhongwen. Time series data classification based on dual path CNN-RNN cascade network[J]. *IEEE Access*, 2019, 7: 155304-155312.
- [9] 樊盼盼, 袁逸萍, 孙文磊, 等. 融合多时段 SCADA 数据的风电机组风险态势预测[J]. *计算机集成制造系统*, 2021, 27(7): 1993-2004.
- FAN Panpan, YUAN Yiping, SUN Wenlei, et al. Risk

- situation prediction of wind turbine based on multi-period SCADA data[J]. *Computer Integrated Manufacturing Systems*, 2021, 27(7): 1993-2004.
- [10] 袁逸萍, 樊盼盼, 马占伟. 基于 EEMD-MCNN-GRU 的滚动轴承剩余使用寿命预测方法: CN202010290930.0[P]. 2022-07-12.
- YUAN Yiping, FAN Panpan, MA Zhanwei. Prediction method of remaining service life of rolling bearing based on EEMD-MCNN-GRU: CN202010290930.0[P]. 2022-07-12.
- [11] 赵小强, 张亚洲. 利用改进卷积神经网络的滚动轴承变工况故障诊断方法[J]. *西安交通大学学报*, 2021, 55(12): 108-118.
- ZHAO Xiaoqiang, ZHANG Yazhou. Improved CNN-based fault diagnosis method for rolling bearings under variable working conditions[J]. *Journal of Xi'an Jiaotong University*, 2021, 55(12): 108-118.
- [12] 康涛, 段蓉凯, 杨磊, 等. 融合多注意力机制的卷积神经网络轴承故障诊断方法[J]. *西安交通大学学报*, 2022, 56(12): 68-77.
- KANG Tao, DUAN Rongkai, YANG Lei, et al. Bearing fault diagnosis using convolutional neural network based on a multi-attention mechanism[J]. *Journal of Xi'an Jiaotong University*, 2022, 56(12): 68-77.
- [13] DING Yifei, JIA Minping, MIAO Qiuhua, et al. Remaining useful life estimation using deep metric transfer learning for kernel regression[J]. *Reliability Engineering & System Safety*, 2021, 212. DOI: [10.1016/j.ress.2021.107583](https://doi.org/10.1016/j.ress.2021.107583).
- [14] 谢丽蓉, 王斌, 包洪印, 等. 基于 EEMD-WOA-LSSVM 的超短期风电功率预测[J]. *太阳能学报*, 2021, 42(7): 290-296.
- XIE Lirong, WANG Bin, BAO Hongyin, et al. Super-short-term wind power forecasting based on EEMD-WOA-LSSVM[J]. *Acta Energiæ Solaris Sinica*, 2021, 42(7): 290-296.
- [15] MIAO Huihui, LI Bing, SUN Chuang, et al. Joint learning of degradation assessment and RUL prediction for aeroengines via dual-task deep LSTM networks[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(9): 5023-5032.
- [16] HAUKE J, KOSSOWSKI T. Comparison of values of Pearson's and Spearman's correlation coefficients on the same sets of data[J]. *Quaestiones Geographicae*, 2011, 30(2): 87-93.
- [17] ZHANG Yong, XIN Yuqi, LIU Zhiwei, et al. Health status assessment and remaining useful life prediction of aero-engine based on BiGRU and MMoE[J]. *Reliability Engineering & System Safety*, 2022, 220. DOI: [10.1016/j.ress.2021.108263](https://doi.org/10.1016/j.ress.2021.108263).
- [18] LIN Jinshan, CHEN Qian. Fault diagnosis of rolling bearings based on multifractal detrended fluctuation analysis and Mahalanobis distance criterion[J]. *Mechanical Systems and Signal Processing*, 2013, 38(2): 515-533.
- [19] SAVITZKY A, GOLAY M J E. Smoothing and differentiation of data by simplified least squares procedures[J]. *Analytical Chemistry*, 1964, 36(8): 1627-1639.
- [20] HARBOLA S, COORS V. One dimensional convolutional neural network architectures for wind prediction[J]. *Energy Conversion and Management*, 2019, 195: 70-75.
- [21] LIU Mingde, DING Lin, BAI Yulong. Application of hybrid model based on empirical mode decomposition, novel recurrent neural networks and the ARIMA to wind speed prediction[J]. *Energy Conversion and Management*, 2021, 233. DOI: [10.1016/j.enconman.2021.113917](https://doi.org/10.1016/j.enconman.2021.113917).
- [22] NIU Dongxiao, YU Min, SUN Lijie, et al. Short-term multi-energy load forecasting for integrated energy systems based on CNN-BiGRU optimized by attention mechanism[J]. *Applied Energy*, 2022, 313. DOI: [10.1016/j.apenergy.2022.118801](https://doi.org/10.1016/j.apenergy.2022.118801).
- [23] SUN Heng, CHEN Miaomiao, WENG Jian, et al. Anomaly detection for in-vehicle network using CNN-LSTM with attention mechanism[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(10): 10880-10893.
- [24] KIM T S, SOHN S Y. Multitask learning for health condition identification and remaining useful life prediction: deep convolutional neural network approach[J]. *Journal of Intelligent Manufacturing*, 2021, 32(8): 2169-2179.