

DOI: 10.19650/j.cnki.cjsi.J2311777

基于卷积变分自编码和多头自注意力机制的 断路器剩余机械寿命预测*

孙曙光¹, 王泽伟¹, 陈静², 黄光临², 王景芹³

(1. 河北工业大学人工智能与数据科学学院 天津 300130; 2. 温州聚星科技股份有限公司 温州 325062;
3. 河北工业大学省部共建电工装备可靠性与智能化国家重点实验室 天津 300130)

摘要:针对万能式断路器退化过程的不确定性,考虑到振动信号对机械性能退化的完善表征,提出了一种基于卷积变分自编码(CVAE)和多头自注意力机制(MSA)的断路器分闸机械机构寿命预测方法。首先依据断路器不同的事件区间提取参数特征,再通过CVAE挖掘信号成分中的深度特征,将参数特征与深度特征融合得到完备退化特征,最后建立GRU-MSA的定量寿命预测模型,引入了多头自注意力机制,在多个不同表征子空间中捕捉信号的不同依赖关系,对重要的时间步赋予更大的权重。最后利用3台试品的振动信号测量数据对所提断路器分闸机械机构寿命预测方法进行测试,结果表明,所提出的方法在3个数据集中寿命预测均方根误差(RMSE)分别为141.46、128.75和134.16,平均绝对误差(MAE)分别为112.17、101.52和106.22,预测精度高且稳定性好,相对于其他混合预测模型更具优势。

关键词: 万能式断路器;卷积变分自编码;多头自注意力机制;剩余寿命预测

中图分类号: TM561 TH 165.3 文献标识码: A 国家标准学科分类代码: 470.40

Remaining mechanical useful life prediction for circuit breaker based on convolutional variational autoencoder and multi-head self-attention

Sun Shuguang¹, Wang Zewei¹, Chen Jing², Huang Guanglin², Wang Jingqin³

(1. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300130, China; 2. Wenzhou Juxing Technology Co., Ltd., Wenzhou 325062, China; 3. State Key Lab Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China)

Abstract: Arming at the uncertainty of the degradation of conventional circuit breakers and the perfect mechanical degradation characterization by vibration signals, an opening mechanical mechanism life prediction method based on CVAE and MSA mechanism is proposed. Firstly, the parametric features are extracted based on the different event intervals of the circuit breaker. Then, the depth features in the signal components are mined by CVAE, and the parametric features are fused with the depth features to obtain the complete degradation features. Finally, the quantitative life prediction model of the GRU-MSA is formulated, which introduces MSA to capture the different dependencies of signals in several different representation subspaces and assign greater weights to the important time steps. Finally, the proposed method is tested by using the vibration signal measurement data of three test samples. The results show that the proposed method has life prediction RMSE of 141.46, 128.75, and 134.16, and MAE of 112.17, 101.52, and 106.22, respectively. The prediction accuracy is high and the stability is good, which has more advantages compared with other hybrid prediction models.

Keywords: conventional circuit breaker; convolutional variational autoencoder; multi-head self-attention; remaining useful life prediction

0 引言

随着开关电器朝着智能化的方向发展,将智能感知

与先进检测技术运用到开关电器的健康管理中是十分重要的。低压万能式断路器作为低压电网运行系统中的关键设备,当配电系统出现短路、过载和欠压等故障时,断路器能够快速切断电路以保障电气设备的性能和安

全,因此对断路器剩余使用寿命预测,对提高断路器的运行可靠性具有重要意义。为贯彻党中央、国务院重大决策部署,落实“十四五”智能制造发展规划,由工业和信息化部等七部门联合制定的《智能检测装备产业发展行动计划(2023—2025年)》提出加强智能检测理论方法、先进检测技术研究,发展故障诊断、可靠性、寿命数据分析等研究方向^[1]。为推进质量强国建设,推动中国制造向中国创造转变,中共中央国务院印发《质量强国建设纲要》提出加强技术创新、加快大数据、网络、人工智能等新技术的深度应用^[2]。因此,基于人工智能的在线监测,预估设备的健康状态和剩余使用寿命既迎合了当今国家发展的需要,又能降低设备因故障失效而带来的经济影响和安全隐患^[3]。

在断路器数据获取方面,李家豪等^[4]通过常规机械特性测试仪采集断路器动触头位移和分合闸线圈电流计算出断路器的超程、开距、分闸时间、合闸时间、分闸速度、合闸速度、弹跳等指标。刑轩瑀等^[5]通过高速摄像机采集分闸过程中斥力阀的序列图像,经图像处理得到了触头分闸速度。杨秋玉等^[6]采集了断路器的触头超行程和分闸平均速度用于后续机械寿命评估。上述研究在一定程度上提取了断路器的退化特征量,但受到测量方式的制约,不利于实施在线测量分析。考虑到振动信号能够通过在线测量获得动作过程中丰富的机械状态信息。赵书涛等^[7]提出了一种通过自适应白噪声完整集合经验模态分解断路器整体振动信号,并将其去噪后与样本熵相结合的特征提取方法。万书亭等^[8]对整体振动信号进行经验小波变换,选择相关系数较大的内禀模态函数(intrinsic mode function, IMF)重构,提取重构信号的多尺度熵作为表征断路器状态的特征向量。Sun等^[9]进一步考虑了振动信号的有效成分,通过短时能量双门限法将有效振动信号区间进行标定,进而利用多通道卷积自编码器(multi-channel convolutional auto-encoder, MCCA)长短期记忆网络(long short-term memory, LSTM)处理断路器触头的振动信号,进行寿命预测。上述研究专注于断路器振动信号的波形特征,既包含参数化波形特征,也包含深度特征。但由于测量因素以及个体差异会造成断路器退化过程的不确定性,这种不确定性影响的消除,需要结合对宏观退化过程表征能力强的机械特性参数特征以及对微观退化过程表征能力强的波形特征进行综合分析。因此如何利用鲁棒性更强的特征提取器挖掘准确的振动信号深度波形特征以降低不确定性的影响,并在此基础上构建能够捕捉多重关系且计算效率更高的寿命预测模型以实现精准的RUL预测是两个急需解决的关键问题。

针对深层特征的挖掘,周兴康等^[10]引入残差学习机制训练一维卷积自编码(autoencoder, AE),实现了对齿

轮箱振动信号有效地特征提取。金晓航等^[11]通过稀疏AE学习风电机组高维数据中复杂的内在特征,得到了数据的降维表示。肖娜等^[12]提出了一种基于卷积AE网络的航空发动机轴承早期冲击故障特征提取方法。而自编码训练模型过于复杂会将训练集中存在的较多不确定因素的干扰过度拟合,从而导致在测试集上的表现不佳,学者们提出了变分自编码,通过在损失函数中增加正则化项以缓解过拟合问题,使模型具有更强的鲁棒性。任建亭等^[13]通过深度变分自编码网络(variational autoencoder, VAE)有效挖掘了风电机组齿轮箱正常运行状态下环境工况参数与齿轮箱运行状态参数之间复杂的数据结构特征和数据分布规则。张聪等^[14]通过建立变分图自编码模型,对汽轮机、风电转子等高关联耦合分布式系统的多维多态检测数据进行了特征提取。向刚等^[15]提出了一种基于改进的VAE算法,利用LSTM单元替换VAE中传统的神经元,提取了航天器测试数据间的时间依赖性和相关性等特征。

针对高效寿命定量预测模型,卷积神经网络(convolutional neural network, CNN)、LSTM、门控循环单元(gate recurrent unit, GRU)和注意力机制已被广泛应用^[16]。随着学者们不断对模型结构进行探索,结合注意力机制的多模型混合预测的方法逐渐兴起。Zhao等^[17]提出了一种多尺度集成深度自注意力网络,从多传感器数据中获得多尺度退化特征,并利用(bidirectional gate recurrent unit, BiGRU)和双向长短期记忆网络(BiLSTM)预测航空发动机的RUL。Sun等^[18]提出了双注意机制的LSTM方法,实现了交流接触器RUL的预测。姚德臣等^[19]提出了一种融合注意力机制的GRU算法,实现了轴承剩余寿命的预测。而注意力机制只能学习每个时间步与其他时间步的单一关系,多头自注意力机制可以并行学习时间步之间的多种相互作用关系,其表达能力相比于自注意力机制较强。陈保家等^[20]提出了一种基于多头自注意力机制(multi-head self-attention, MSA)的时间卷积网络,实现了轴承的RUL预测。聂磊等^[21]通过MSA对多个一维CNN-时序卷积神经网络的输出分别进行加权处理,拼接后经过全连接输出得到飞机发动机的RUL。周哲韬等^[22]通过MSA挖掘了输入特征与轴承RUL之间的复杂映射关系,解决了轴承RUL预测中序列过长而导致记忆力退化问题。

综上所述,本文提出了一种基于卷积变分自编码(convolutional variational autoencoder, CVAE)和MSA的断路器分闸机械机构寿命预测方法。该方法首先通过短时能量双门限法对振动事件进行分割,在不同的事件区间提取参数特征,同时通过CVAE挖掘振动信号成分中的深度特征,将参数特征与深度特征融合得到完备退化特征,最后建立GRU-MSA预测模型,引入多头自注意力

机制,在多个不同表征子空间中捕捉信号的不同依赖关系,提高寿命定量预测的精度。

1 断路器分闸机械机构寿命预测方法

考虑到分闸动作关系到断路器的分断能力,分闸迟缓或异常都会影响断路器的正常分断。且分闸过程涉及众多结构的联动和碰撞,冲击更强,产生的振动信号蕴含丰富的机械状态信息,有着非侵入式测量和易于捕捉的特点,适合用于寿命预测。因此本文所提出的分闸机械机构寿命预测方法由振动信号处理、综合特征提取和寿命预测模型构建3部分组成,整体流程如图1所示。

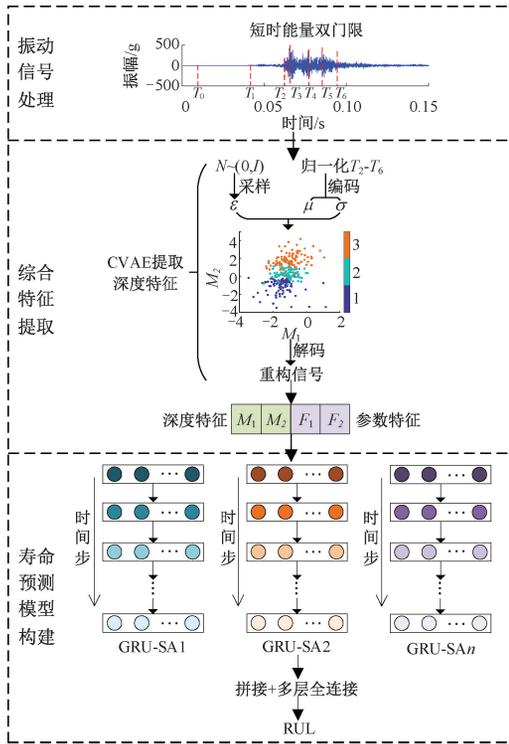


图1 RUL预测整体流程

Fig. 1 The overall process of RUL prediction

首先通过短时能量双门限法对振动事件进行分割,在不同的事件区间提取参数特征,并通过CVAE得到深度特征,将上述特征融合后得到综合特征,将综合特征输入到GRU-MSA预测模型中,通过MSA模块实现进一步加权,强化关键特征对预测结果的贡献,最后经过全连接层输出RUL预测结果。通过上述整体流程,可以实现由实时检测到的振动信号至以剩余操作次数表示的剩余寿命值的直接映射。

1.1 短时能量双门限法分割振动信号

考虑到振动信号包含不同的振动事件,因此需要进行区间分割。断路器分闸振动信号主要是由机构之间的

碰撞产生,不同振动事件的强度存在差异。考虑到短时能量法相比于短时过零率更适用于检测幅值变化大的信号,因此将振动信号进行分帧。计算每一帧的短时能量,再设定短时能量门限值,最后通过双门限法进行振动事件分割。短时能量为:

$$E(i) = \sum_{n=0}^{L-1} [\omega(n) \cdot y((i-1) \cdot inc + n)]^2 \quad (1)$$

式中: $E(i)$ 表示第 i 帧的能量; $\omega(n)$ 为汉宁窗函数^[9]; y 表示振动信号的幅值; $n = 1, 2, \dots, L$; $i = 1, 2, \dots, f_n$; L 为帧长; inc 为帧移长度; f_n 为分帧后的总帧数。分割得到的振动信号可进一步用于后续的综合特征的提取。

1.2 振动事件分析综合退化特征

1) 机械特性参数特征

振动信号中含有振动冲击事件,每个事件对应于断路器相应的机械动作,所以据此可以实现具有工程意义的机械动作参数特征检测,如机构动作时间 F_1 和分闸平均速度 F_2 。

$$\begin{cases} F_1 = T_2 - T_1 \\ F_2 = \frac{l}{T_3 - T_2} \end{cases} \quad (2)$$

式中: T_1 为分励脱扣器的推杆与触发机构碰撞时刻; T_2 为动静触头分离时刻; T_3 为动触头最大位移结束时刻; l 为动触头最大位移。

2) 卷积变分自编码器

利用VAE编码器对振动信号数据进行非线性变换将其映射到潜在空间中,从而学习到振动信号的深层抽象特征。此外VAE较之其他方法通过在损失函数中加入正则化项以缓解过拟合问题。VAE的原理具体如下。

VAE通过两个神经网络建立两个概率分布模型:(1)推断网络,用于原始输入数据的变分推断,生成隐变量的变分概率分布;(2)生成网络,根据隐变量的变分概率分布,还原生成原始数据的近似概率分布。VAE的模型结构示意图如图2所示,经过短时能量双门限法分割得到的振动信号 x 作为VAE模型的输入, Z 为隐藏层变量,生成模型表示为 $p(x|Z)$,推断模型为 $q(Z|x)$,隐藏层变量 Z 是由 $p(x)$ 和一个后验分布 $p(Z|x)$ 形成的。

$$p(z) = \int p(Z|x)p(x) \quad (3)$$

但后验分布 $p(Z|x)$ 无法直接计算。VAE通过变分推断的方法,通过推断模型 $q(Z|x)$ 去逼近 $p(Z|x)$,并用(Kullback-Leibler, KL)散度去衡量这两个分布之间的相似程度。

$$D_{KL}(q(Z|x^{(i)}) || p(Z|x^{(i)})) = E_{q(Z|x^{(i)})} [\log q(Z|x^{(i)}) - \log p(Z|x^{(i)})] \quad (4)$$

式中: D_{KL} 为KL散度; E 为数学期望函数; $x^{(i)}$ 表示振动信号 x 的第 i 个采样点数据。

KL 散度用来判断两个分布之间的相似程度, KL 散度越小, 则分布越相似; 反之, 则分布偏差大。对式(4)变形得到:

$$E_{q(Z|x^{(i)})} [\log p(x^{(i)} | Z)] - D_{KL}(q(Z|x^{(i)}) || p(Z)) =$$

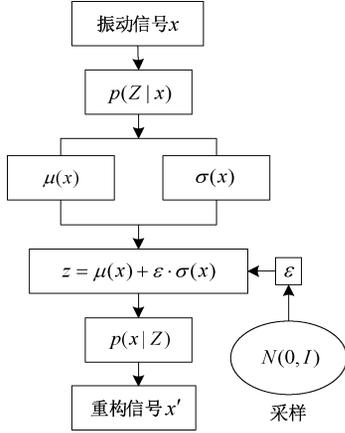


图2 变分自编码模型示意图

Fig.2 Schematic diagram of the VAE model

在给定振动信号 x 后, $\log p(x^{(i)})$ 是一个固定值, $E_{q(Z|x^{(i)})} [\log p(x^{(i)} | Z)]$ 是基于生成模型的数学期望, 通过推导, 优化目标可转化为极大化 VAE 的变分下界 (evidence lower bound, ELBO)。

$$ELBO = E_{q(Z|x^{(i)})} [\log p(x^{(i)} | Z)] - D_{KL}(q(Z|x^{(i)}) || p(Z)) \quad (6)$$

假设潜在变量 Z 服从标准正态分布, 推断模型 $q(Z|x)$ 服从均值为 μ , 方差为 σ^2 , 即:

$$p(Z) \sim N(0, I) \quad q(Z|x) \sim N(\mu, \sigma^2) \quad (7)$$

结合式(7)可以将式(6)化为:

$$D_{KL}(q(Z|x^{(i)}) || p(Z)) = \frac{1}{2} \sum_{j=1}^J ((\sigma^{(i)})^2 + (\mu^{(i)})^2 - \log((\sigma^{(i)})^2) - 1) \quad (8)$$

$$E_{q(Z|x^{(i)})} [\log p(x^{(i)} | Z)] = \sum_{i=1}^n x_i \log(x'_i) + (1 - x_i) \log(1 - x_i) \quad (9)$$

式中: J 为隐变量 Z 的维度; n 为振动信号 x 的长度; $\mu^{(i)}$ 和 $\sigma^{(i)}$ 为第 i 个采样点数据经过推断模型输出的均值和方差。

在 VAE 训练过程中, KL 散度的损失权重起到了调节重构损失和 KL 散度损失之间权衡的作用, 以确保模型在生成数据的多样性和真实性之间找到一个合适的平衡点, 当 KL 散度较小时, 模型更加关注重构损失, 反之则会更加关注 KL 散度损失, 使生成信号更加多样化。将最大化的优化目标 ELBO 重写为最小化损失函数形式, 则损失函数计算公式如下:

$$Loss = - \left[\sum_{i=1}^n x_i \log(x'_i) + (1 - x_i) \log(1 - x_i) \right] + \frac{1}{2} \alpha \cdot \sum_{j=1}^J ((\sigma^{(i)})^2 + (\mu^{(i)})^2 - \log((\sigma^{(i)})^2) - 1) \quad (10)$$

式中: α 表示 KL 散度的权重。该损失函数由两部分组成, 最小化带有权重的隐变量分布与正态分布之间 KL 散度值, 最小化生成数据集与原数据集的交叉熵损失。两式之和为该 VAE 模型训练时的损失函数。

在该变分自编码中, 由于使用了随机采样得到隐层变量 Z , 在网络训练时无法反向传播。本文采用了“重参数化技巧”, 通过从 $N(0, I)$ 的标准分布中随机采样一个 ε , 使用式(10) 结合近似后验分布计算出的均值 $\mu(x)$ 和方差 $\sigma^2(x)$, 进行隐藏层变量 Z 的计算, 由此解决该网络无法反向传播的问题。使用随机梯度下降算法进行优化, 即可对生成模型和推断模型的神经网络内参数进行更新:

$$Z = \mu(x) + \varepsilon \cdot \sigma(x) \quad (11)$$

通过以上分析可知, VAE 的“编码器”和“解码器”的输出都是受参数约束变量的概率密度分布, 而不是特定的数值, 因此得到的隐变量更具有表达意义。然而, 若单纯使用全连接的线性层将使得模型的训练参数和复杂度十分巨大, 而卷积神经网络具有参数共享和稀疏连接的特点, 使得模型中的参数数量大幅减少。因此本文选择将卷积神经网络应用在 VAE 的推断模型和生成模型中, 通过 CVAE 提取振动信号的深层特征。

1.3 多头自注意力机制

将 CVAE 提取的深度特征 $M = [M_1, M_2, \dots, M_A]$, 与参数特征 $F = [F_1, F_2, \dots, F_B]$ 融合, 得到综合退化特征 $T = [M_1, M_2, \dots, M_A, F_1, F_2, \dots, F_B]$, 其中 A 和 B 分别为深度特征和参数特征的个数, 进一步用于后续 RUL 预测模型的建立。

考虑到断路器振动信号具有时序性, GRU 非常适用于处理与时间序列高度相关的问题, 相比于传统 RNN 以及 LSTM, GRU 在 RNN 中加入了门控单元, 增加了网络对历史数据的记忆能力。同时, GRU 采用更新门和重置门代替了 LSTM 中的输入门、输出门和遗忘门, 在减少了模型参数量和模型复杂度的同时保证了模型的精度, 训练更加稳定。通过 GRU 可以得到各时间步的深层特征之间的长期依赖关系。

考虑到断路器分闸机械机构的复杂性以及动作过程的不确定性, 将多头自注意力机制模块置于 GRU 和输出层之间, 如图 3 所示。

多头自注意力机制可以并行计算每个时间步相对于其他时间步的多种关系, 计算效率更高, 更能准确地捕捉输入序列中的特征。假设 GRU 学习到的不同时间步信息可以表示为 $O = [O_1, O_2, \dots, O_T]^T$, 其中 T 表示返回的

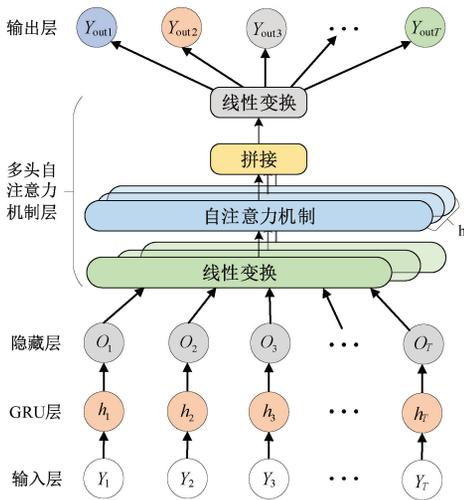


图3 GRU-MSA 结构

Fig.3 The structure of GRU-MSA

时间步数。MSA 基于 SA 针对不同的特征量分头学习, 矩阵 Q_i, K_i, V_i 公式如下:

$$\begin{cases} Q_i = OW_i^q \\ K_i = OW_i^k \\ V_i = OW_i^v \end{cases} \quad (12)$$

式中: W_i^q, W_i^k, W_i^v 分别表示在第 i 个注意力头的查询矩阵, 键矩阵和值矩阵。再计算每个头的不同时间步的重要性得分, 公式如下:

$$head_i = softmax\left(\frac{Q_i K_i^T}{\sqrt{d_{K_i}}}\right) V_i \quad (13)$$

式中: d_{K_i} 表示 K 矩阵的维度。将取得的结果进行拼接得到最终的注意力, 最后再通过全连接得到多头自注意力的输出 Y_{out} , 公式如下:

$$Y_{out} = Concat(head_1, head_2, \dots, head_h) W^p \quad (14)$$

式中: W^p 表示 MSA 的输出权重矩阵。通过权重矩阵可以将多个头的注意力结果进行加权合并, 得到一个更全面, 更丰富的向量。

2 应用实例与测试分析

2.1 断路器机械特性测试系统

断路器机械寿命为抗机械磨损能力, 以断路器在需要维护或者更换机械零件前所能正常运行的无载操作次数表示。断路器结构如图 4 所示, 其中给出了与分闸动作过程关联的主要机械部件, 本文是对上述部件组成的断路器主体机械结构进行寿命预测。其中断路器型号为 DW15-1600, 壳架等级额定电流为 1 600 A, 母线额定电流为 1 000 A, 该类型断路器的操作机构动作形式包括储

能、合闸、分闸 3 个过程。断路器寿命试验操作循环周期的时序控制图如图 5 所示, $t_1 \sim t_2$ 为储能阶段开始及结束时刻; $t_3 \sim t_4$ 为合闸阶段开始及结束时刻; $t_5 \sim t_6$ 为分闸阶段开始及结束时刻。



图4 断路器结构

Fig.4 Structure of a CCB

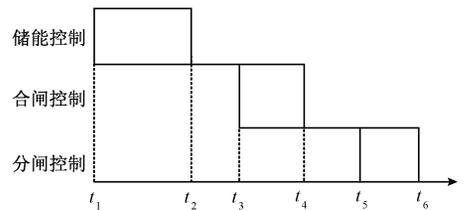


图5 机械寿命试验时序控制

Fig.5 Time sequence control of mechanical life test

在空载试验状态下, 依据断路器相关标准将试验操作频率定为 20 次/h, 每次试验都进行一次完整的电动储能、合闸、分闸操作。所构建的断路器机械特性测量系统, 如图 6 所示。振动传感器型号为 LC0159, 固定于断路器横梁处。针对单次分闸操作, 通过数据采集卡 USB-7648A 以 20 kHz 的采样频率检测触头换位电压信号、分励脱扣器线圈电流信号以及横梁处振动信号, 信号采样时长为 0.15 s, 每次采样 3 000 个数据点。

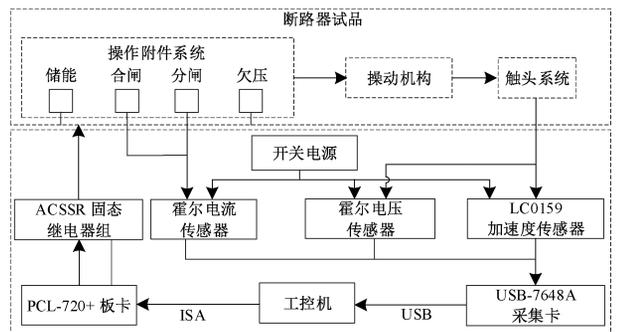


图6 断路器测试系统

Fig.6 Circuit breaker test system

利用3台试品的振动信号测量数据对所提断路器分闸机械机构寿命预测方法进行测试,考虑到分闸平均速度过低将直接导致断路器拒分现象,所以选取分闸平均速度作为机械寿命失效判据,分闸平均速度阈值设定为5 m/s。断路器#1,断路器#2和断路器#3的分闸机械机构寿命操作次数分别为4 354,3 522和3 946次。确定好机械寿命总操作次数后,文中所指剩余寿命即为断路器当前操作次数下对应的剩余操作次数,即总操作次数与当前操作次数的差值。

2.2 基于短时能量双门限法标定动作事件

图7所示为断路器触头换位电压信号,分励脱扣器线圈电流信号,横梁处振动信号。结合图4的断路器的分闸机械机构进行动作过程分析。

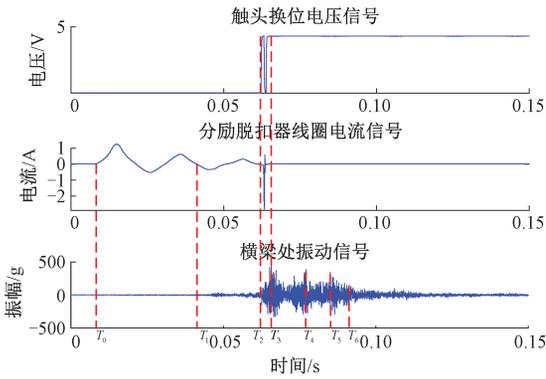


图7 分闸过程测量信号

Fig. 7 Measurement signals for the opening process

T_0 时刻,分励脱扣器线圈开始通电,线圈产生电流,动铁芯带动推杆运动。 T_1 时刻,推杆与触发机构相碰撞,产生了第1次振动,此后操作机构中的脱扣半轴旋转。 T_2 时刻,分闸弹簧的约束被解除,弹簧释能,在分闸弹簧的作用下,动静触头分开。 T_3 时刻,动触头到最大位移处,产生强烈的振动并通过连接机构传递给主轴和止停销等支撑和缓冲机构,在反力的作用下,动触头发生回弹。 T_4 和 T_5 时刻,动触头再次撞击止停销,并发生第2次和第3次回弹。 T_6 时刻振幅逐渐衰减至最小,以该时刻作为分闸动作结束标志。

根据不同的振动事件,通过短时能量双门限法将振动信号划分成不同区间,增强其特征表达,其中窗长选50,帧移选10。再对比不同时刻的短时能量值,设定双门限法的门限值。 T_0 为分闸开始时刻,将短时能量的最小值设为该事件的门限值。 T_1 时刻振动较为微弱,综合多次测量结果将对应门限值设为 $500 g^2$ 。 T_2 时刻动静触头分开,短时能量值较小,将 $5 \times 10^4 g^2$ 设为门限值。而 T_3 、 T_4 和 T_5 时刻依次出现能量的峰值,将能量的最大值设为的 T_3 门限值,将 $6.7 \times 10^5 g^2$ 和 $4.4 \times 10^5 g^2$ 分别设为

T_4 和 T_5 门限值, T_6 时刻振幅逐渐变小,将对应门限值设为 $1.6 \times 10^5 g^2$ 。图8(a)~(f)分别对应图7的 T_1 、 T_2 、 T_3 、 T_4 、 T_5 和 T_6 时刻。至此,可以获取与分闸动作直接相关的振动事件区间。

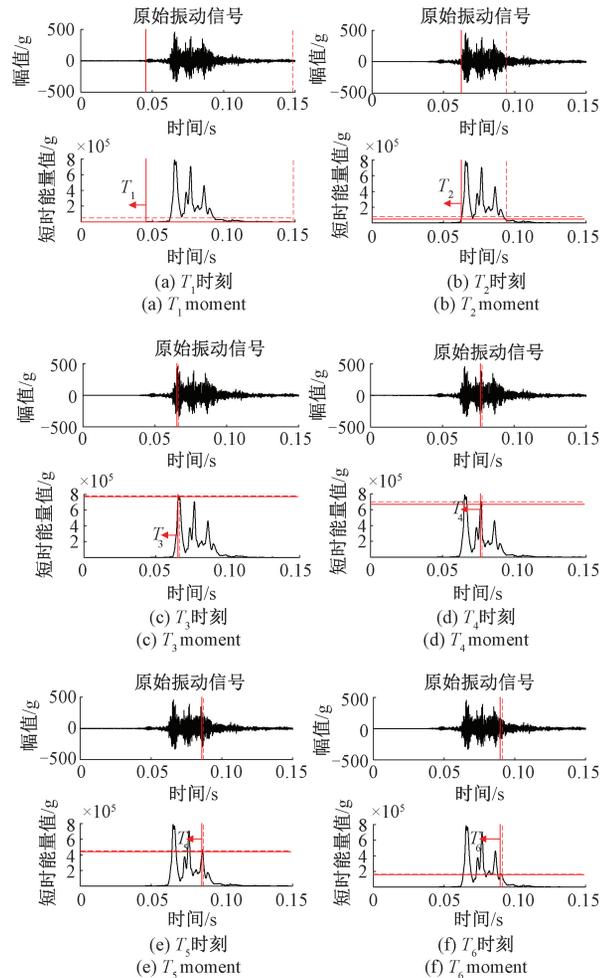


图8 振动信号的事件分割

Fig. 8 Event segmentation of vibration signals

2.3 综合退化特征的提取

1) 机械特性参数特征的提取

利用 T_1 和 T_2 时刻的检测即可获得 F_1 ,利用 T_2 和 T_3 时刻即可获得 F_2 。以上两个参数具有工程意义,是对分闸动作性能的直接体现。断路器#1参数特征随动作次数的变化趋势如图9所示。

F_1 随操作次数的增加呈上升趋势,这是由于分励脱扣器的触发机构以及脱扣半轴在长期磨损下卡涩逐渐加剧导致的。 F_2 呈下降趋势,各断路器分闸机械机构寿命区间由该参数阈值界定。

2) 深度特征提取必要性分析

通过提取参数化指标,可以在宏观层面对设备的退化过程以及健康状态进行分析,为断路器健康状态的判

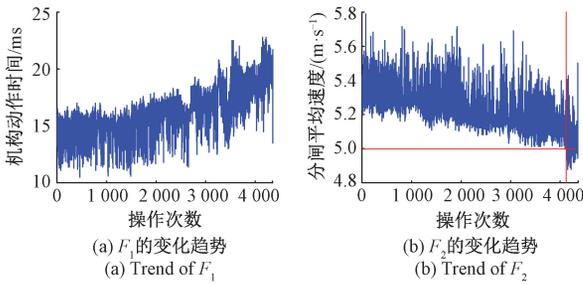


图9 断路器#1 参数特征随操作次数的变化趋势
Fig. 9 Trend of breaker #1 parameter characteristics with the number of operations

断起到至关重要的作用。但需要考虑不确定性以及由性能退化引发的强冲击性振动信号时间序列之间的附加冲击度量问题。

对于不确定性问题,一方面在工程实际中,由于环境、使用条件以及非理想测量仪器等因素的影响,使得对

设备的测量信号产生差异;并且不同因素的作用可能是复杂的、多变的,而且会相互影响;上述因素使得测量得到的退化数据不可避免地受到影响,造成退化过程的不确定性,进而影响寿命预测结果的精度^[6]。另一方面,由于断路器机械结构较为复杂,在设计、生产以及制造过程中因公差产生的不确定性因素,会导致同型号设备个体之间存在差异性。上述两个方面使得不同断路器个体在相同退化阶段所采集到的振动信号波形存在着微观上的差异;造成了断路器的退化过程,除了由参数化特征所体现的宏观显性趋势之外,还存在微观隐含性和不确定性。

本文断路器#1 为厂家 1 生产,断路器#2 和断路器#3 为厂家 2 生产。对两个不同个体在同一退化阶段的振动信号进行对比,如图 10 所示。对于附加冲击度量问题,可利用欧氏距离将 2 组寿命前期邻近的振动信号序列、1 组末期振动信号序列各自经变分模态分解 (variational mode decomposition, VMD) 得到的 6 个 IMF 进行差异性量化分析。

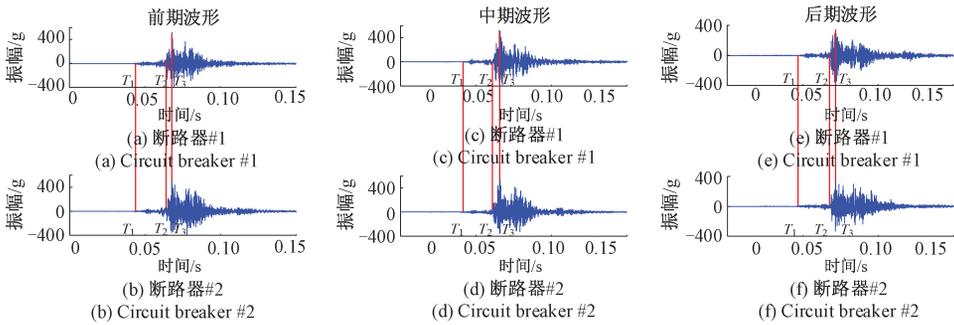
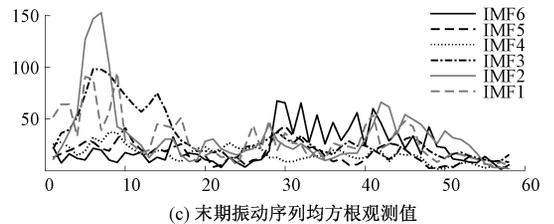


图 10 不同断路器在同一退化阶段振动信号对比

Fig. 10 Comparison of vibration signals of different circuit breakers at the same stage

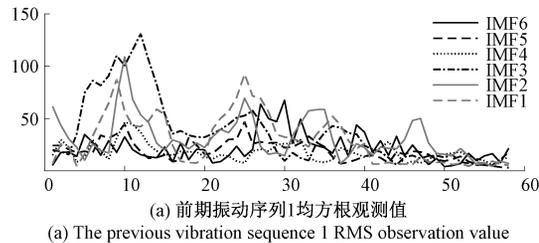
将分解得到的 IMF 分割成多个片段,每个片段长度为 10 个采样点,取其均方根值作为该片段的观测值,利用观测值将各模态离散为矢量,即可计算各矢量之间的欧氏距离作为模态之间差异性的量化指标,结果如图 11 与表 1 所示。



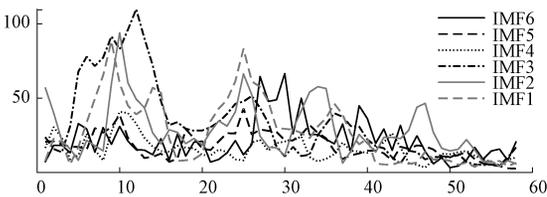
(c) The final vibration sequence RMS observation value

图 11 振动信号序列均方根观测值

Fig. 11 Root-mean-square observation of vibration signal sequence



(a) The previous vibration sequence 1 RMS observation value



(b) The previous vibration sequence 2 RMS observation value

由图 11 可以看出,寿命前期、后期振动信号序列各模态片段观测值差异比较明显,由表 1 也可以发现,序列各模态间欧氏距离差距较大,恰恰体现了机械性能退化在强冲击振动中造成的附加冲击成分。而前期两个振动序列各模态片段观测值差异不明显,欧氏距离小,表明此时相对于正常情况性能退化附加冲击成分宏观占比小,不宜采用常规监测量表征附加冲击成分的差异。

表 1 振动信号序列间欧氏距离

Table 1 Euclidean distance between vibration signal sequence

模态分量	前后期欧氏距离	前期欧氏距离
IMF1	1 238. 63	159. 01
IMF2	1 503. 90	160. 49
IMF3	855. 28	278. 55
IMF4	475. 84	133. 36
IMF5	521. 26	91. 99
IMF6	699. 92	52. 54

综上考虑在提取参数特征的同时,挖掘触头动作过程中的振动序列深度特征,以期提取不同断路器间具有的共性特征以及凸显振动序列间的微弱附加冲击,从而提高寿命预测的精度。

3) 基于 CVAE 深度特征的提取

$T_2 \sim T_6$ 区间内振动强烈,信号成分更丰富,包含更多的机械特性退化信息,选取 $T_2 \sim T_6$ 振动信号片段提取深度特征。采用短时能量双门限法对振动信号进行区间分割处理,并截取该区间的前 580 个采样点,使此片段振动信号长度统一,并将其幅值进行归一化。将该区间振动信号送入 CVAE 中,其各层参数如表 2 所示。主要使用了 1×3 的卷积核进行卷积操作,表 2 中 k 是卷积核的大小, d 是卷积核的数量, s 是步长。该神经网络的中间部分激活函数使用 ReLU 函数,生成网络最后一个非线性层需要考虑到生成信号在 $[0, 1]$,使用 Sigmoid 函数。

选择 Adam 算法进行网络参数的优化,学习速率设置为 0.001,每次训练的样本批次大小设置为 50。将训练迭代次数设置为 150,其中前 50 次 KL 散度的权重 α 设置为 0.001,随后 50 次的 α 设置为 0.01,最后 50 次的 α 设置为 0.1。为了直观展示 CVAE 模型的效果,将 CVAE 解码信号与 AE 和 VAE 的解码信号进行对比,其中,AE 和 VAE 的输入与超参数都与 CVAE 相同,训练迭代总次数都为 150 次。3 种模型解码信号对比如图 12 所示。

可以看出 CVAE 模型已基本将原始振动信号解码还原。再引入均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE)对 3 台断路器试样振动信号重构前后进行评估。RMSE 和 MAE 的定义如下:

$$RMSE = \sqrt{\frac{1}{Q} \sum_{j=1}^Q \sum_{i=1}^{580} (M_{ij}^{de} - M_{ij}^{key})^2} \quad (15)$$

$$MAE = \frac{1}{Q} \sum_{j=1}^Q \sum_{i=1}^{580} |M_{ij}^{de} - M_{ij}^{key}| \quad (16)$$

表 2 卷积变分自编码的结构及参数

Table 2 Structure and parameters of CVAE

网络层	参数信息	输出维度
Reshape	-	(580, 1)
Conv1D+ReLU	$k = 1 \times 3; d = 4; s = 1$	(580, 4)
Maxpooling	$k = 1 \times 2; s = 2$	(290, 4)
Conv1D+ReLU	$k = 1 \times 3; d = 2; s = 1$	(290, 2)
Maxpooling	$k = 1 \times 2; s = 2$	(145, 2)
Conv1D+ReLU	$k = 1 \times 3; d = 1; s = 1$	(145, 1)
Flatten	-	(145)
Linear+ReLU	Get μ and σ	(2)
Reparameterization	Get z	(2)
Linear+ReLU	Fully Connected	(145)
Reshape	-	(145, 1)
Conv1D+ReLU	$k = 1 \times 3; d = 2; s = 1$	(145, 2)
Upsampling	$k = 1 \times 2; s = 2$	(290, 2)
Conv1D+ReLU	$k = 1 \times 3; d = 4; s = 1$	(290, 4)
Upsampling	$k = 1 \times 2; s = 2$	(580, 4)
Conv1D+Sigmoid	$k = 1 \times 3; d = 1; s = 1$	(580, 1)
Reshape	-	(580)

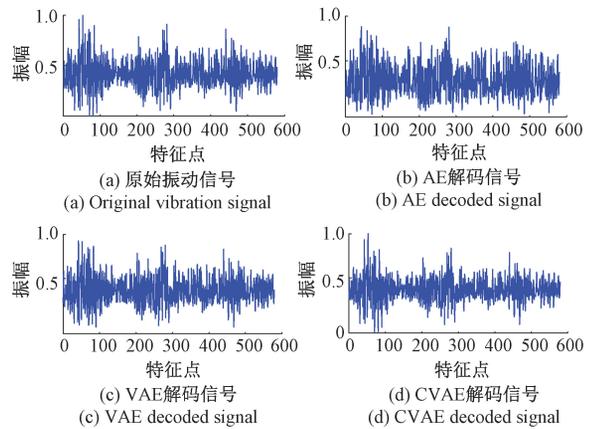


图 12 解码信号对比结果

Fig. 12 Decoded signal comparison results

式中: Q 表示断路器的总操作次数; M_{ij}^{de} 表示解码振动信号特征点; M_{ij}^{key} 表示原始振动信号的特征点。3 个数据集的重构误差对比结果如表 3 所示,可以看出每个数据集 CVAE 模型重构的 RMSE 和 MAE 都是最小的,其重构能力更为优秀,因此 CVAE 鲁棒性更强,提取的深度特征更有代表性。

为了进一步直观体现 CVAE 提取的深度特征,取断路器试样 3 个不同时期的振动信号,分别为 201~300 次, 1 301~1 400 次, 3 401~3 500 次,将其输入到 CVAE 中,

表3 重构误差对比结果

Table 3 Reconstruction error comparison results

模型	指标	数据集		
		#1	#2	#3
AE	RMSE	10.61	9.16	13.89
	MAE	8.85	7.23	11.63
VAE	RMSE	8.44	8.58	9.37
	MAE	6.60	6.91	7.72
CVAE	RMSE	6.72	5.79	4.98
	MAE	5.54	4.64	3.97

取深度特征为2维,编码结果可视化如图13(a)和(b)所示,可以看出,同一试品在不同时期的深度特征存在差异。再取3个试品都在第2个时期的振动信号,将其输入到CVAE中,如图13(c)所示,可以看出不同试品在同一时期,其深度特征也存在差异,实现了对图10、11所阐述的退化微观信息以及附加冲击差异的有效表征,弥补了单纯采用机械特性参数特征对退化过程表征不足的问题,也证明了提取深度特征的必要性。

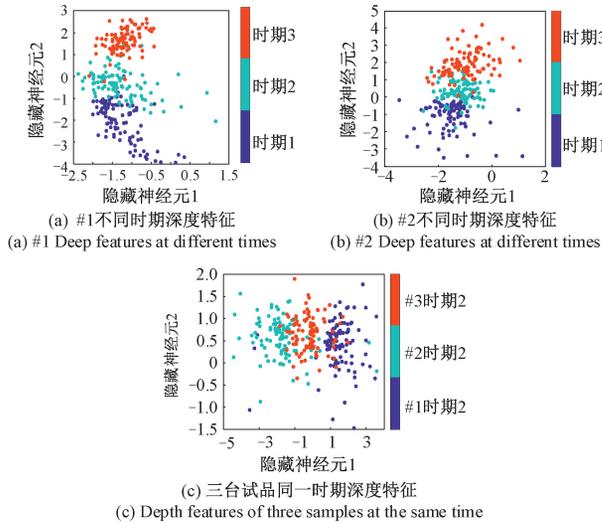


图13 CVAE 编码信号对比结果

Fig. 13 Encoded signal comparison results of CVAE

通过CVAE提取的深度特征为 $\mathbf{M} = (M_1, M_2)$,通过式(2)提取参数特征归一化为 $\mathbf{F} = (F'_1, F'_2)$ 。将参数特征与深度特征拼接得到融合特征 $\mathbf{T} = (M_1, M_2, F'_1, F'_2)$ 。该融合特征用于后续RUL预测模型的建立。

2.4 GRU-MSA模型的构建及评价指标

为了深入挖掘时间序列样本的规律,本文采用滑动窗口方法生成数据集样本。滑动窗口方法有以下优点。一方面,它保留了时间序列相邻元素之间的相关性;另一方面克服了单步预测精度低的问题。设一台断路器的总操

作次数为 Q ,窗口大小为 W ,步长为 S 。每个输入样本可表示为 $X = W \times D$,其中 D 为特征的数量,输出样本RUL标签可表示为 $R_{true} = Q - W - (j - 1) \times S$ 。为了获得更多样本,本文选取 $W = 5, S = 1$,则样本总数为 $C = Q - 4$ 个。训练模型的样本可以描述为 $((X_1, R_1^{true}), (X_2, R_2^{true}), \dots, (X_j, R_j^{true}), \dots, (X_C, R_C^{true}))$,损失函数为均方误差(MSE)如下:

$$MSE = \frac{1}{C} \sum_{j=1}^C (R_j^{pre} - R_j^{true})^2 \quad (17)$$

其中第 j 组RUL输出的预测值为 R_j^{pre} 。本文预测模型包含两个GRU,一个MSA层和两个全连接层。GRU的隐藏单元数分别设置为64和32,两个全连接层的隐藏单元分别设置为50和1。此外,在每个网络层后面加入批归一化(batch normalization, BN),可以减少神经网络中的内部协变量偏移,使训练深层网络模型更加容易和稳定,增强了模型的非线性表达能力,最终加快训练速度。在训练过程中,通过正向传播计算预测值 R_j^{pre} 和真实值 R_j^{true} 之间的MSE,并利用优化器Adam对各层参数进行反向传播(back propagation, BP),优化学习率设置为0.001,批次大小设置为50,epochs设置为100。该工作是在64位计算机上实现的,编程工具是“python 3.7”,使用“TensorFlow 2.0.0”作为后端。

采用RMSE和MAE对断路器寿命预测结果进行评价。RMSE和MAE越小,预测精度越高。不同的是RMSE更能反映异常波动,而MAE更能反映预测的实际情况。RMSE和MAE的定义如下:

$$RMSE = \sqrt{\frac{1}{C} \sum_{j=1}^C (R_j^{pre} - R_j^{true})^2} \quad (18)$$

$$MAE = \frac{1}{C} \sum_{j=1}^C |R_j^{pre} - R_j^{true}| \quad (19)$$

2.5 不同注意力头数的实验结果与分析

注意力头数作为一个重要参数,对预测模型的精度有很大影响。以断路器#1为训练集,断路器#2和断路器#3为测试集,通过GRU-MSA进行RUL预测,其中注意力头数设置为1~10,模型的输入都是融合特征 \mathbf{T} ,结果如表4和图14所示。

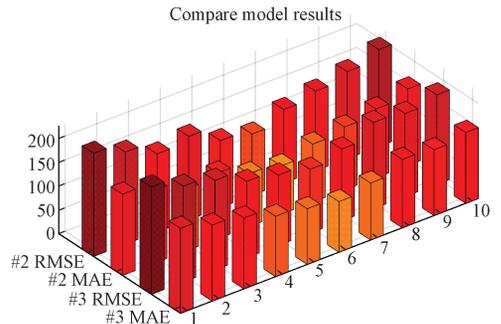


图14 #2和#3预测误差

Fig. 14 #2 and #3 prediction errors

表 4 不同头数的误差结果

Table 4 Error results for different number of heads

头数	评价指标	数据集		
		#1	#2	#3
1	RMSE	243.86	216.30	225.39
	MAE	193.37	170.55	178.44
2	RMSE	231.78	193.13	201.24
	MAE	183.79	152.28	159.32
3	RMSE	203.71	163.86	187.83
	MAE	161.53	129.21	148.70
4	RMSE	181.88	174.95	160.08
	MAE	144.22	137.95	126.74
5	RMSE	158.50	140.46	147.58
	MAE	125.69	110.75	116.84
6	RMSE	141.46	128.75	134.16
	MAE	112.17	101.52	106.22
7	RMSE	165.35	154.50	151.00
	MAE	131.11	121.82	119.55
8	RMSE	148.54	167.38	181.12
	MAE	117.78	131.98	143.39
9	RMSE	176.83	182.83	174.41
	MAE	140.22	144.16	138.08
10	RMSE	198.05	203.43	187.83
	MAE	157.04	160.40	148.70

当注意力头数为 1 时,模型为单头自注意力机制,模型只能学习每个时间步与其他时间步的单一关系,表达能力较差,而注意力头数过多时,计算负担较大,且会导致过拟合,网络模型的性能开始下降。由表 4 的定量结果可以发现,当注意力头数为 6 时,模型预测效果最好,因此将多头注意力机制的头数设置为 6。

为了进一步直观体现 MSA 的效果,以断路器#1 的第 200 次振动信号为例,将 MSA 计算的每个时间步与其他时间步的权重关系可视化如图 15 所示。每个头的注意力对不同时间步的关注程度不同,第 1 个和第 6 个注意力更关注第 5 个时间步,第 2 个和第 3 个注意力更关注第 3 个和第 4 个时间步,第 4 个和第 5 个注意力更关注第 2 个时间步,由此看出,MSA 捕捉到了振动信号的不同依赖关系,解决了自注意力机制表征能力不足的问题,也证明了使用 MSA 的必要性。

2.6 消融实验结果与分析

采用交叉验证的方式对 3 台断路器试品进行 RUL 实验,为了验证提取参数特征、深度特征和 MSA 3 个模块的有效性,进行了消融实验。对比 GRU、参数特征-

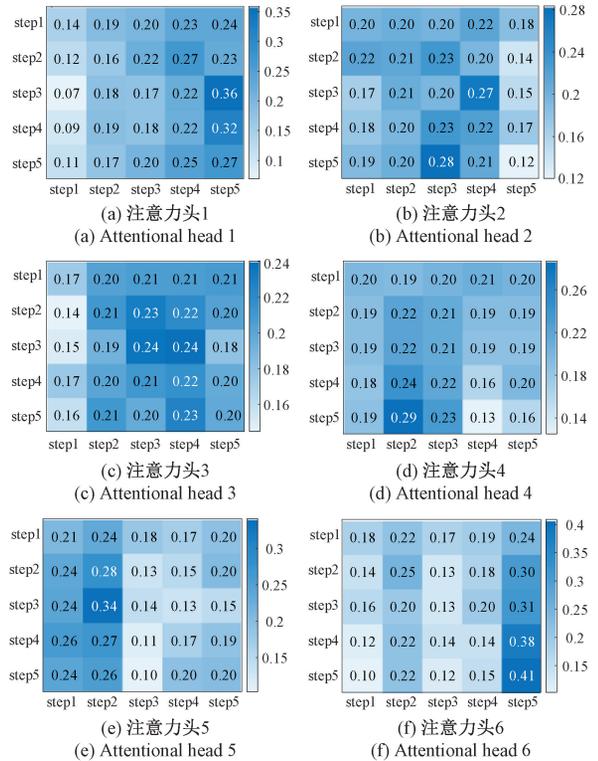
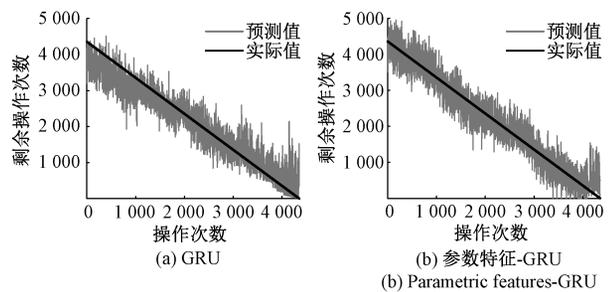


图 15 #1 MSA 权重可视化结果

Fig. 15 #1 MSA weight visualization results

GRU、深度特征-GRU、GRU-MSA 和所提方法五种模型的预测效果,其中 GRU 的参数设置一致,模型的输入都是 $T_2 \sim T_6$ 区间的振动信号。

上述模型在断路器#1 的预测效果如图 16 所示,训练集为断路器#2。可以看出,与实际剩余寿命曲线相比,GRU 的拟合效果最差,参数特征-GRU 的预测结果受退化不确定性的影响,波动性较大且存在较多异常数据,深度特征-GRU 一定程度上克服了不确定性的影响,波动性较小,GRU-MSA 拟合效果较好,但仍有一定波动性,所提方法拟合效果最好,波动小且异常数据少。消融实验结果如表 5 所示,可以发现,所提方法相对于其他预测方法在断路器#1 的 RMSE 分别降低了 63.42%、55.13%、49.92% 和 30.40%, MAE 降低了 62.62%、54.39%、49.58% 和 30.18%。可以看出每个模块都发挥了至关重要的作用。



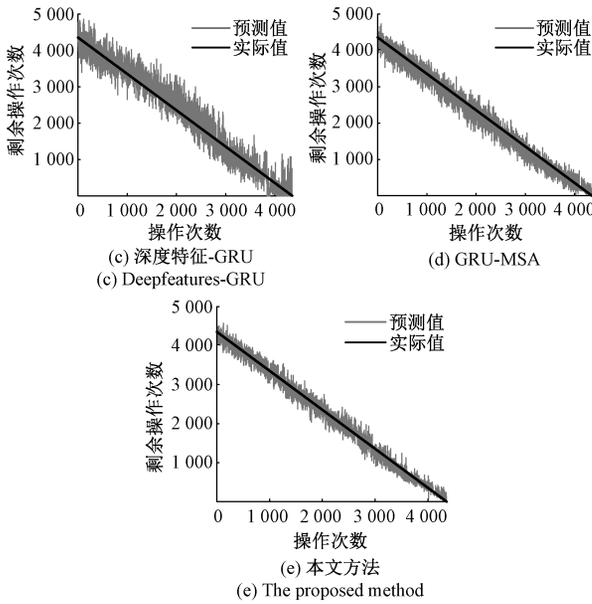


图 16 #1 消融预测结果

Fig. 16 Ablation prediction results of #1

表 5 消融实验结果

Table 5 Results of ablation experiments

模型	评价指标	数据集		
		#1	#2	#3
GRU	RMSE	386.70	341.34	351.67
	MAE	300.08	269.25	271.52
参数特征-GRU	RMSE	315.27	271.00	299.92
	MAE	245.94	212.11	234.43
深度特征-GRU	RMSE	282.48	237.74	267.04
	MAE	222.46	185.97	208.68
GRU-MSA	RMSE	203.26	194.02	214.94
	MAE	160.66	153.47	170.26
Proposed	RMSE	141.46	128.75	134.16
	MAE	112.17	101.52	106.22

3 结 论

本文着眼于综合退化特征的提取以及寿命定量预测模型的构建,得出如下结论。

一方面,针对性的提取机械特性参数特征并利用 CVAE 获取深度特征,参数特征体现了断路器整体退化的宏观显性趋势,深度特征表征了退化的微观隐性信息,有助于克服退化不确定性影响以及凸显附加冲击成分,从而获得了兼顾振动信号事件信息以及波形特征的综合

特征,为断路器分闸机械机构寿命预测提供了较为完善特征提取方法。另一方面,所建立的 GRU-MSA 定量预测模型,增强了时间序列中重要信息对预测结果的权重,有效减少了不确定性的影响。最终所提 CVAE 和 GRU-MSA 方法在 3 个数据集中寿命预测 RMSE 分别为 141.46、128.75 和 134.16,MAE 分别为 112.17、101.52 和 106.22,表明该模型具有一定的优势,也证明了所提方法能够针对性的解决万能式断路器的 RUL 预测任务。

未来随着实验条件以及测试的不断完善与深入,需要更加深入地挖掘敏感退化特征以及采用迁移学习的方法提升本文方法的适应性,使预测模型具有更好的泛化能力。

参考文献

[1] 智能检测装备产业发展行动计划(2023~2025 年)[J]. 中小企业管理与科技,2023 (4):1-6.
Intelligent testing equipment industry development action plan[J]. Management and Technology of Small and Medium-sized Enterprise, 2023 (4): 1-6.

[2] 中共中央国务院印发《质量强国建设纲要》[N]. 人民日报,2023-02-07(1).
The CPC Central Committee and the State Council issued the Outline of the construction of a strong quality country[N]. People's Daily, 2023-02-07(1).

[3] ZHAO S, MAKIS V, CHEN S, et al. Health assessment method for electronic components subject to condition monitoring and hard failure[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(1): 138-150.

[4] 李家豪,王青于,范玥霖,等. 鲸鱼优化算法-双向长短期记忆神经网络用于断路器机械剩余寿命的预测研究[J/OL]. 高电压技术;1-13. <https://doi.org/10.13336/j.1003-6520.hve.20230013>.

LI J H, WANG Q Y, FAN Y L, et al. Research on whale optimization algorithm-bidirectional long-short-term memory neural network for prediction of machinery remaining useful life of circuit breaker[J/OL]. High Voltage Engineering; 1-13. <https://doi.org/10.13336/j.1003-6520.hve.20230013>.

[5] 邢轩瑀,陈培军,孙鹏,等. 基于序列图像的高压断路器分闸速度检测[J]. 广东电力,2021,34(12):55-61.
XING X Y, CHEN P J, SUN P, et al. Detection of opening speed of high-voltage circuit breakers based on

- sequence images[J]. *Guangdong Electric Power*, 2021, 34(12): 55-61.
- [6] 杨秋玉,彭彦卿,庄志坚,等. 基于随机模糊理论的高压断路器剩余机械寿命评估[J]. *高压电器*, 2016, 52(8): 161-165, 171.
- YANG Q Y, PENG Y Q, ZHUANG ZH J, et al. Residual mechanical life evaluation for high voltage circuit breaker based on random fuzzy theory[J]. *High Voltage Apparatus*, 2016, 52(8): 161-165, 171.
- [7] 赵书涛,马莉,朱继鹏,等. 基于 CEEMDAN 样本熵与 FWA-SVM 的高压断路器机械故障诊断[J]. *电力自动化设备*, 2020, 40(3): 181-186.
- ZHAO SH T, MA L, ZHU J P, et al. Mechanical fault diagnosis of high voltage circuit breaker based on CEEMDAN sample entropy and FWA-SVM[J]. *Electric Power Automation Equipment*, 2020, 40(3): 181-186.
- [8] 万书亭,豆龙江,刘荣海,等. 基于 EWT 和多尺度熵的高压断路器故障诊断[J]. *振动. 测试与诊断*, 2018, 38(4): 672-678, 867.
- WAN SH T, DOU L J, LIU R H, et al. Fault diagnosis for high voltage circuit breakers based on EWT and Multi-scale Entropy [J]. *Journal of Vibration, Measurement and Diagnosis*, 2018, 38(4): 672-678+867.
- [9] SUN S, WEN Z, DU T, et al. Remaining life prediction of conventional low-voltage circuit breaker contact system based on effective vibration signal segment detection and MCCA-E-LSTM [J]. *IEEE Sensors Journal*, 2021, 21(19): 21862-21871.
- [10] 周兴康,余建波. 基于深度一维残差卷积自编码网络的齿轮箱故障诊断[J]. *机械工程学报*, 2020, 56(7): 96-108.
- ZHOU X K, YU J B. Gearbox fault diagnosis based on one-dimension residual convolutional auto-encoder [J]. *Journal of Mechanical Engineering*, 2020, 56(7): 96-108.
- [11] 金晓航,许壮伟,孙毅,等. 基于 SCADA 数据分析和稀疏自编码神经网络的风电机组在线运行状态监测[J]. *太阳能学报*, 2021, 42(6): 321-328.
- JIN X H, XU ZH W, SUN Y, et al. Online condition monitoring for wind turbines based on scada data analysis and sparse auto-encoder neural network [J]. *Acta Energetica Solaris Sinica*, 2021, 42(6): 321-328.
- [12] 肖娜,周孟申. 基于卷积自编码神经网络的航空发动机轴承故障诊断方法研究[J]. *计算机测量与控制*, 2021, 29(12): 84-88, 119.
- XIAO N, ZHOU M SH. Research on aero-engine bearing fault diagnosis method based on convolutional auto-encoding neural network[J]. *Computer Measurement and Control*, 2021, 29(12): 84-88, 119.
- [13] 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.
- [14] 张聪,朱永生,杨敏燕,等. 采用多变量耦合网络与变分图自编码器的机械设备异常检测方法[J]. *西安交通大学学报*, 2021, 55(4): 20-28.
- ZHANG C, ZHU Y SH, YANG M Y, et al. Anomaly detection method with multivariable coupling network and variational graph autoencoder [J]. *Journal of Xi'an Jiaotong University*, 2021, 55(4): 20-28.
- [15] 向刚,陶然,屈辰,等. 改进型变分自编码器及其在航天器故障检测中的应用[J]. *西北工业大学学报*, 2020, 38(S1): 90-95.
- XIANG G, TAO R, QU CH, et al. An improved variational autoencoder and its applications on fault detection of aerospace craft [J]. *Journal of Northwestern Polytechnical University*, 2020, 38(S1): 90-95.
- [16] 刘林青,马红明,李鹏,等. 基于边缘计算的智能电表能耗与寿命优化方法[J]. *电测与仪表*, 2023, 60(5): 173-179.
- LIU L Q, MA H M, LI P, et al. Energy consumption and life optimization method of smart meter based on edge computing [J]. *Electrical Measurement and Instrumentation*, 2023, 60(5): 173-179.
- [17] ZHAO K, JIA Z, JIA F, et al. Multi-scale integrated deep self-attention network for predicting remaining useful life of aero-engine [J]. *Engineering Applications of Artificial Intelligence*, 2023, 120: 105860-105869.
- [18] SUN S, LIU J, WANG J, et al. Remaining useful life prediction for AC contactor based on MMPE and LSTM with dual attention mechanism [J]. *IEEE Transactions on*

Instrumentation and Measurement, 2022, 71: 1-13.

- [19] 姚德臣,李博阳,刘恒畅,等. 基于注意力GRU算法的滚动轴承剩余寿命预测[J]. 振动与冲击, 2021, 40(17): 116-123.

YAO D CH, LI B Y, LIU H CH, et al. Residual life prediction of rolling bearing based on attention GRU algorithm[J]. Journal of Vibration and Shock, 2021, 40(17): 116-123.

- [20] 陈保家,陈正坤,陈学良,等. 基于注意力TCN的滚动轴承剩余使用寿命预测方法[J]. 电子测量技术, 2021, 44(24): 153-160.

CHEN B J, CHEN ZH K, CHEN X L, et al. Prediction method of remaining useful life of rolling bearing based on attentional temporal convolutional network[J]. Electronic Measurement Technology, 2021, 44(24): 153-160.

- [21] 聂磊,徐诗奕,张吕凡,等. 基于多头注意力机制的飞机发动机寿命预测研究[J/OL]. 推进技术: 1-11. <https://doi.org/10.13675/j.cnki.tjjs.2204040>.

NIE L, XU SH Y, ZHANG L F, et al. Remaining useful life prediction of aeroengine based on multi-head attention [J/OL]. Journal of Propulsion Technology: 1-11. <https://doi.org/10.13675/j.cnki.tjjs.2204040>.

- [22] 周哲韬,刘路,宋晓,等. 基于Transformer模型的滚动轴承剩余使用寿命预测方法[J]. 北京航空航天大学学报, 2023, 49(2): 430-443.

ZHOU ZH T, LIU L, SONG X, et al. Remaining useful life prediction method of rolling bearing based on transformer model[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(2): 430-443.

作者简介



孙曙光, 分别在2002年、2005年和2009年于河北工业大学获得学士学位、硕士学位和博士学位, 现为河北工业大学副教授, 主要研究方向为智能检测与故障诊断。

E-mail: sunshuguang_2000@163.com

Sun Shuguang received his B. Sc. degree, M. Sc. degree, and Ph. D. degree all from Hebei University of Technology in 2002, 2005, and 2009, respectively. He is currently an associate professor at Hebei University of Technology. His main research interests include intelligent detection and fault diagnosis.



陈静, 现任温州聚星电接触科技有限公司董事长及总经理, 主要研究方向为电接触材料、电触头和电接触元件的研发。

E-mail: jxcj@China-juxing.cn

Chen Jing is currently the chairman and the general manager at Wenzhou Juxing Technology Co., Ltd. His main research interests include the development of electrical contact materials, electrical contacts, and electrical contact components.



王景芹(通信作者), 分别在1984年、1986年和1997年于河北工业大学获得学士学位、硕士学位和博士学位, 现为河北工业大学教授, 主要研究方向为电接触和可靠性。

E-mail: jqwang@hebut.edu.cn

Wang Jingqin (Corresponding author) received her B. Sc. degree, M. Sc. degree, and Ph. D. degree all from Hebei University of Technology in 1984, 1986, and 1997, respectively. She is currently a professor at Hebei University of Technology. Her main research interests include electrical contact and reliability.