第 50 卷 第 11 期：4990-5004 高电压技术 Vol.50, No.11: 4990-5004
2024 年 11 月 30 日 High Voltage Engineering November 30, 2024
DOI: 10.13336/j.1003-6520.hve.20231311

基于数据增强 SDAE-BiGRU 的交流接触器剩余电寿命预测

邢朝健，刘树鑫，高书豫，刘　洋，李　静，曹云东
（特种电机与高压电器重点实验室(沈阳工业大学电气工程学院)，沈阳 110870）

摘　要：针对目前交流接触器剩余电寿命存在单一特征预测精度低、未充分考虑开断前后的关联性和忽略了长时间序列特点的问题，该文提出基于数据增强堆叠降噪自动编码器-双向门控循环单元(stacked denoised autoencoder-bidirection gated recurrent unit，SDAE-BiGRU)的交流接触器剩余电寿命预测方法。首先，通过交流接触器全寿命试验提取特征参量，采用近邻成分分析(neighborhood component analysis，NCA)和斯皮尔曼等级相关系数选择最优特征子集，来有效表征电寿命退化信息。然后，对最优特征子集进行数据增强，充分考虑前后状态的关联性，并利用 SDAE 对增强后的特征信息进行融合来降低输入维度。最后，将交流接触器剩余电寿命视为长时序问题，通过 BiGRU 进行时序预测。实例分析表明，该模型比循环神经网络(recurrent neural network，RNN)、长短期记忆网络(long short-term memory，LSTM)、GRU、BiGRU 和 SDAE-BiGRU 模型预测效果好，平均有效精度达到 96.68%，有效证明了时序预测模型应用在电器设备剩余寿命预测领域中的可行性。

关键词：交流接触器；特征选择；数据增强；堆叠降噪自动编码器；双向门控循环单元

Remaining Electrical Life Prediction of AC Contactor Based on Data Augmentation SDAE-BiGRU

XING Chaojian, LIU Shuxin, GAO Shuyu, LIU Yang, LI Jing, CAO Yundong
(Key Laboratory of Special Electric Machine and High Voltage Apparatus (College of Electrical Engineering, Shenyang University of Technology), Shenyang 110870, China)

Abstract：To tackle the challenges, such as the low prediction accuracy of remaining electric life of AC contactor caused by single feature modeling, the insufficient consideration of correlation before and after opening, and disregarding the characteristics of long time series, we proposed a method for predicting the remaining electrical life of AC contactor using a data augmentation stacked denoised autoencoder-bidirectional gated recurrent unit (SDAE-BiGRU). First, the feature parameters were extracted from the AC contactor full-life test, and an optimal feature subset was selected using neighborhood component analysis (NCA) and Spearman rank correlation coefficient to characterize the degradation state of electrical life effectively. Then, the optimal feature subset was augmented to fully consider the correlation between the anterior and posterior states. The SDAE was employed to fuse and reconstruct the original feature information, in which the dimension was reduced and the computing speed was increased. Finally, the remaining electrical life of the AC contactor was treated as a long time series and predicted in time series prediction by BiGRU. The case analysis demonstrates that the model has better prediction accuracy than recurrent neural network (RNN), long short-term memory (LSTM), GRU, BiGRU and SDAE-BiGRU models, with an average effective accuracy of 96.68%. The feasibility of time series prediction model applied in the residual life prediction of electrical equipment is verified effectively.

Key words：AC contactor; feature selection; data augmentation; SDAE; BiGRU

0　引言

交流接触器主要负责大电流主回路的频繁通断，在低压电气控制中应用广泛[1-2]。随着在线监测技术不断成熟，交流接触器智能化发展趋势愈发明显[3-4]。通过对交流接触器运行参数在线采集和智能分析，能够给设备检修提供科学依据[5]。交流接触器剩余电寿命反映线路通断性能，若能在失效前及时预测，可以有效提高电力系统的可靠性，减少经济损失[6-7]。

基金资助项目：国家自然科学基金 (51977132)；辽宁省科技重大专项 (2020JH1/10100012)；沈阳中青年科技创新人才计划 (RC210354)。
Project supported by National Natural Science Foundation of China (51977132), Liaoning Provincial Key Research and Development Program (2020JH1/10100012), Shenyang Young and Middle-aged Scientific and Technological Innovation Talent Program (RC210354).

近年来，国内外学者对交流接触器剩余电寿命预测问题进行了深入研究。文献[8]提出了一种将触头材料损失与电负载应力联系起来的可靠性评估方法，描述了交流接触器的退化过程；文献[9]选取超程时间做为接触器的特征参量，建立了基于幂函数非线性 Wiener 预测模型；文献[10]提取了交流接触器在 3 种异常状态下的音频信号，建立神经网络预测模型用于预测剩余寿命；文献[11]利用交流接触器退化数据前后的关联性，采用长短期记忆网络(long short-term memory，LSTM)时间序列模型预测交流接触器剩余寿命；文献[12]采用添加双注意力机制的 LSTM 预测交流接触器的剩余寿命；文献[13]提出了一种基于卷积神经网络的门控循环单元的交流接触器剩余寿命预测方法。

上述对交流接触器剩余电寿命的预测方法以数据驱动为主。基于数据驱动的寿命预测方法，通过分析交流接触器的全寿命运行数据，利用传统算法进行建模，可实现剩余寿命的有效预测，具有一定的工业应用价值。但上述方法仍有 3 点需要进一步提升：1）传统预测模型中采用的特征参量较单一，需要获取更多表征交流接触器剩余寿命的特征参量，继而准确构建预测模型评估体系，提高预测结果准确性。2）由于交流接触器状态监测信号具有非线性和非平稳的特点，随着特征参量的增加，传统智能算法无法高效挖掘多特征参量与剩余电寿命之间的规律信息，因此有必要强化开断前后监测数据的关联性。3）交流接触器剩余寿命数据属于长时间序列，传统预测模型没有充分考虑到其剩余寿命是由当前状态和先前状态共同决定的，进而制约了预测精度的提高。

随着人工智能的兴起，深度学习在电气领域得到广泛应用。基于深度学习的电气设备退化建模分析，无需复杂的物理模型和统计模型[14]。自动编码器(autoencoder，AE)、降噪自动编码器(denoised autoencoder，DAE)、堆叠降噪自动编码器(stacked denoised autoencoder，SDAE)被广泛应用在变压器等电气设备的状态评估和寿命预测等领域[15]，SDAE 是由 AE 和 DAE 改进而来，适用于高维特征的数据融合。循环神经网络(recurrent neural network，RNN)通过节点连接隐含层来传递信息，实现数据的时序预测[16]。LSTM 通过引入“门”结构，改善 RNN 的梯度消失和梯度爆炸问题[17]。门控循环单元(gated recurrent unit，GRU)通过简化 LSTM 的“门”结构改进隐藏状态的计算方式，广泛应用于轴承、锂电池等的寿命预测领域[18]。双向 GRU (bidirection GRU, BiGRU)则是由单向且方向相反的 GRU 共同决定输出，能充分提取原始信号的特征[19]。然而，深度学习对输入数据的要求较高，且影响交流接触器的特征参量较多，冗余的特征会使得模型训练困难，出现过拟合现象，从而影响预测的准确性。

综上所述，本文构建基于数据增强 SDAE-BiGRU 的交流接触器剩余电寿命预测模型，该模型将交流接触器寿命状态视为时序退化，充分考虑多特征参量在时间维度上前后状态的关联性。通过近邻成分分析和斯皮尔曼等级相关系数选择最优特征子集。然后对最优特征子集进行数据增强，提高前后状态间的关联性，并采用 SDAE 进行特征融合来降低维度，从而减少模型计算量。最后，利用 BiGRU 神经网络对剩余电寿命进行时序预测。

1 基本原理

本文基本原理主要有近邻成分分析(neighborhood component analysis，NCA)、斯皮尔曼等级相关系数、数据增强技术、堆叠降噪自动编码器和双向门控循环神经网络。

1.1 近邻成分分析

影响交流接触器剩余寿命的特征参量较多，不同的特征参量对剩余寿命的重要度不同，删除重要度较低的特征参量，有利于提高预测精度。NCA 是一种嵌入式特征选择方法，基于马氏距离计算相似度，通过学习特征权重和最小化目标函数，随机选择近邻，并采用留一法对原始数据集进行交叉验证，实现特征选择[20]。NCA 特征选择的计算步骤如下：

1）设置转换矩阵 $\boldsymbol{A}$ 并计算特征间的马氏距离。对于数据集$\{\boldsymbol{X}_1, \boldsymbol{X}_2, \cdots, \boldsymbol{X}_m\}$共 m 个样本，样本 $\boldsymbol{X}_i$ 和 $\boldsymbol{X}_j$ 的马氏距离表示为：

$$d_{\mathrm{Mah}}(\boldsymbol{X}_i,\boldsymbol{X}_j)=\sqrt{(\boldsymbol{A}\boldsymbol{X}_i-\boldsymbol{A}\boldsymbol{X}_j)^{\mathrm{T}}(\boldsymbol{A}\boldsymbol{X}_i-\boldsymbol{A}\boldsymbol{X}_j)} \tag{1}$$

2）计算单个特征数据被正确分类的概率，表达式为：

$$P_{ij}=\frac{\exp(-\left\|\boldsymbol{A}\boldsymbol{X}_i-\boldsymbol{A}\boldsymbol{X}_j\right\|^2)}{\sum_{l\neq i}\exp(-\left\|\boldsymbol{A}\boldsymbol{X}_i-\boldsymbol{A}\boldsymbol{X}_l\right\|^2)},P_{ii}=0 \tag{2}$$

$$P_i=\sum_{j\in W_i}P_{ij} \tag{3}$$

式中：$\boldsymbol{X}_l$ 为不包括样本 $\boldsymbol{X}_i$ 的样本集合；P_{ij} 为样本

$\boldsymbol{X}_j$ 影响的概率；P_i 为样本 $\boldsymbol{X}_i$ 留一法的准确率；W_i 为与 $\boldsymbol{X}_i$ 属于同类别样本的下标集合。

3）优化转换矩阵 $\boldsymbol{A}$，并对目标函数 f 求导，计算式为：

$$f(\boldsymbol{A})=\sum_{i=1}^{m}P_i=\sum_{i=1}^{m}\sum_{j\in W_i}P_{ij} \tag{4}$$

$$\frac{\partial f(\boldsymbol{A})}{\partial \boldsymbol{A}}=-2\boldsymbol{A}\sum_{i}^{m}\sum_{j\in W_i}P_{ij}(\boldsymbol{X}_{ij}\boldsymbol{X}_{ij}^{\mathrm{T}}-\sum_{k}P_{ik}\boldsymbol{X}_{ik}\boldsymbol{X}_{ik}^{\mathrm{T}}) \tag{5}$$

4）利用优化后的转换矩阵对原始特征矩阵 $\boldsymbol{X}$ 进行筛选，特征子集 $\tilde{\boldsymbol{X}}$ 表示为：

$$\tilde{\boldsymbol{X}}=\boldsymbol{X}\boldsymbol{A} \tag{6}$$

1.2 斯皮尔曼等级相关系数

交流接触器特征参量之间相关性各异，相关性越大，说明特征信息越相似，但冗余特征信息会增加模型负担，剔除部分冗余度高的特征参量，有利于提高预测精度。斯皮尔曼等级相关系数可计算 2 个变量间秩次的相关程度，适用于衡量离散型数据、分类变量或等级变量之间的相关性[21]。特征变量 $\boldsymbol{X}_i$ 和 $\boldsymbol{Y}_i$ 中间的斯皮尔曼等级相关系数 r 可表示为：

$$r=1-\frac{6\sum_{i=1}^{m}D_i^2}{m(m^2-1)}=1-\frac{6\sum_{i=1}^{m}(R_i-S_i)^2}{m(m^2-1)} \tag{7}$$

式中：R_i、S_i 分别为 $\boldsymbol{X}_i$、$\boldsymbol{Y}_i$ 按大小排序后秩的大小；D_i 为两变量对应秩的差值。当 $0\le|r|<0.1$ 时，特征之间呈现无相关性；当 $0.1\le|r|<0.5$ 时，特征之间呈现弱相关性；当 $0.5\le|r|<0.8$ 时，特征之间呈现一般相关性；当 $0.8\le|r|\le1$ 时，特征之间呈现强相关性。

1.3 数据增强技术

交流接触器全寿命过程是一个长时间序列，历史信息数据在时间维度上密切联系，进一步增强数据间的时序性，能够提高模型预测的精度。数据增强技术通过增强历史数据间的时间序列关系，使数据更好地适应时序预测模型[22]。时间序列的数据增强方式主要分为变换、平均和统计采样，其中基于变换的窗口切片法(window slicing，WS)不仅能应用在训练集上，也可以应用在测试集上，标签保持性较好，对长时序数据的通用性较高[23]。

图 1 给出了交流接触器特征数据增强示意图。对于序列长度为 m，特征维度为 n 的数据，利用长度为 j 的窗口进行切割，将 1 到 j 的数据作为一次特征样本，2 到 j+1 的数据作为另一次特征样本，以此类推，此时重构数据集的时序性不仅存在整个长度为 m 的序列中，还存在于长度为 $j\times n$ 的每个特征样本中，加强了特征前后状态间的关联性。

1.4 堆叠降噪自动编码器

交流接触器特征子集经过数据增强后维度大幅提高，需降低其维度来减少模型输入量。SDAE 是在 DAE 的基础上构建多层降噪自动编码网络，实现特征融合来降低数据维度。DAE 是一种基于神经网络的自动编码器(AE)的改进，有助于提高其泛化能力[24]。图 2 给出了 AE/DAE/SDAE 原理示意图。

如图 2 所示，AE 具有三层结构，输入层 x、隐藏层 h 和输出层 $\tilde{x}$[25]。其中，输入层 x 经过编码器激活函数 $f(x)$映射到隐藏层 h，表达式可表示为：

$$h=f\left(\boldsymbol{W}_1\cdot x+\boldsymbol{b}_1\right) \tag{8}$$

式中：$\boldsymbol{W}_1$ 和 $\boldsymbol{b}_1$ 分别为输入层映射到隐藏层的权值矩阵和偏置项。隐藏层 h 再经过解码器激活函数 $g(f(x))$映射到重构的输出层 $\tilde{x}$，表达式可表示如下：

$$\tilde{x}=g\left(\boldsymbol{W}_2\cdot h+\boldsymbol{b}_2\right) \tag{9}$$

式中：$\boldsymbol{W}_2$ 和 $\boldsymbol{b}_2$ 分别是隐藏层映射到输出层的权值矩阵和偏置项。一般来说 x 不能被精确映射，因此为使输出数据特征能够最大程度表征原始数据特征，进而引入重构误差，在映射过程中使该误差最小，表达式如下：

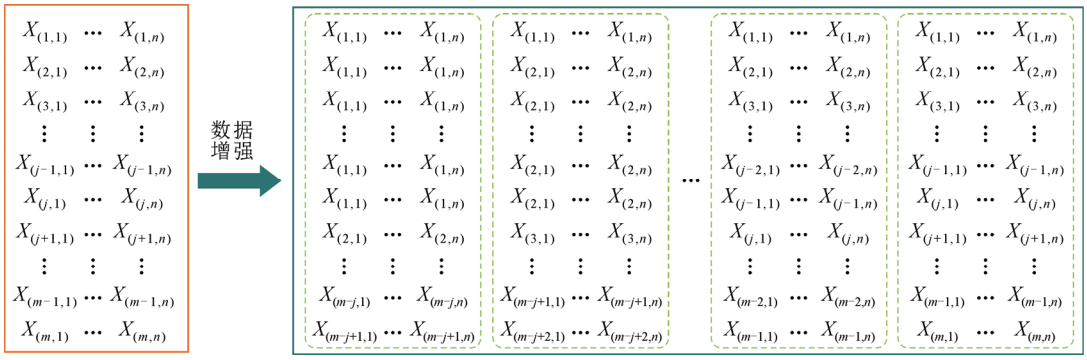


图 1 数据增强示意图

Fig.1 Schematic diagram of data augmentation

$$\min L(x,\tilde{x}) = \min L(x, g(f(x))) = \min \sum_{i=1}^{n} \| x_i - \tilde{x}_i \|^2 \tag{10}$$

当该误差最小时，则得到较好的权重矩阵 $\boldsymbol{W}$ 和偏置项 $\boldsymbol{b}$。

然而由于 AE 学习来的特征与输入数据特征唯一表示，当自动编码网络参数复杂时会出现过拟合情况，导致重构数据不具有较强的泛化能力和鲁棒性。因此，一种输入数据加入随机噪声的方法被提出，即以一定概率随机破坏输入数据，以加入噪声的输入数据 x'重构得到输入层 $\tilde{x}$，其权值矩阵的噪声更小，因此被称为降噪自动编码器(DAE)。SDAE 则是将若干个 DAE 堆叠形成一个具有深层非线性映射能力的深度架构，将前一个 DAE 学习得到的隐藏层 h 作为下一个 DAE 的输入层 x，以此类推直至训练到最后一层，其中 f_1 和 f_2 分别为隐藏层 h_1 和隐藏层 h_2 的激活函数。

1.5 双向门控循环单元

交流接触器剩余电寿命时序预测的关键在于对长时间历史特征信息的记忆，GRU 可以更好地捕捉序列时间步的依赖关系，兼顾考虑时序数据的关联性和非线性关系，实现交流接触器剩余寿命的预测。GRU 在 LSTM 的基础上，将输入门、遗忘门和输出门简化为更新门和重置门，修改了循环神经网络中隐藏状态的计算方式[26]。GRU 内部结构如图 3 所示。

GRU 中的重置门 r_t 和更新门 z_t 均为当前时间步输入 x_t 与上一步时间步隐藏状态 h_{t-1}，在 sigmoid 激活函数的全连接层中计算得到，计算式为：

$$r_t = \sigma\left(x_t W_{xr} + h_{t-1} W_{hr} + b_r\right) \tag{11}$$

$$z_t = \sigma\left(x_t W_{xz} + h_{t-1} W_{hc} + b_z\right) \tag{12}$$

更新门 z_t 越大，说明前一时刻的状态信息代入入到当前状态中的越多；重置门 r_t 越小，说明前一状态的信息被写入当前的候选集 $\tilde{h}_t$ 上的越少。

GRU 中的候选隐藏状态 $\tilde{h}_t$ 是将当前时间步重置门 r_t 的输出与上一时间步隐藏状态 h_{t-1} 做元素乘法。然后，在 tanh 激活函数的全连接层中，通过当前时间步 x_t 的输入与元素乘法的输出连接计算得到，计算式为：

$$\tilde{h}_t = \tanh\left(x_t W_{xh} + \left(r_t \odot h_{t-1}\right) W_{hh} + b_h\right) \tag{13}$$

GRU 中的隐藏状态 h_t 是利用更新门 z_t 来对上一时间步的隐藏状态 h_{t-1} 和当前时间步的候选隐藏状态 $\tilde{h}_t$ 组合计算得出，计算式如下：

$$h_t = z_t \odot h_{t-1} + \left(1 - z_t\right) \odot \tilde{h}_t \tag{14}$$

式(11)—式(14)中：W_{xr}、W_{xz}、W_{hr}、W_{hc}、W_{xh}、W_{hh} 为权重参数；b_r、b_z、b_h 为偏差参数。综上所述，GRU 神经网络的过程可简化表达为：

$$h_t = \mathrm{GRU}\left(x_t, h_{t-1}\right) \tag{15}$$

GRU 的循环结构如图 4 所示，通过多个 GRU 单元延长信息，实现长时间序列的预测。BiGRU 模

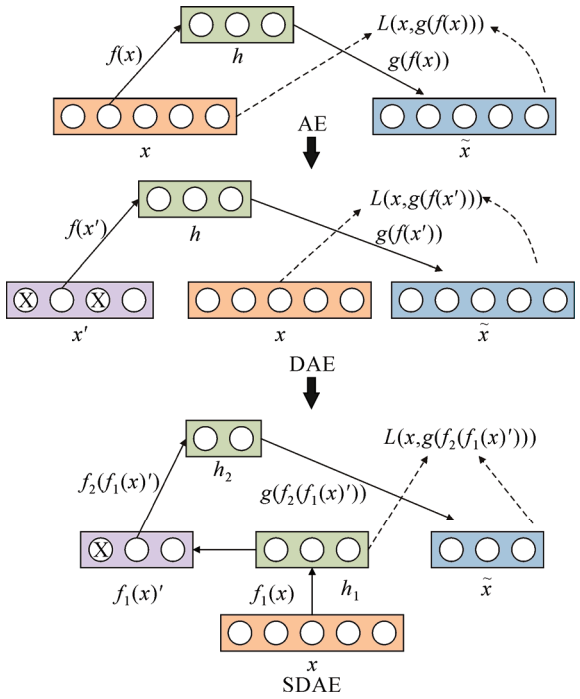


图 2 AE/DAE/SDAE 的原理示意图

Fig.2 Structure diagram of AE/DAE/SDAE

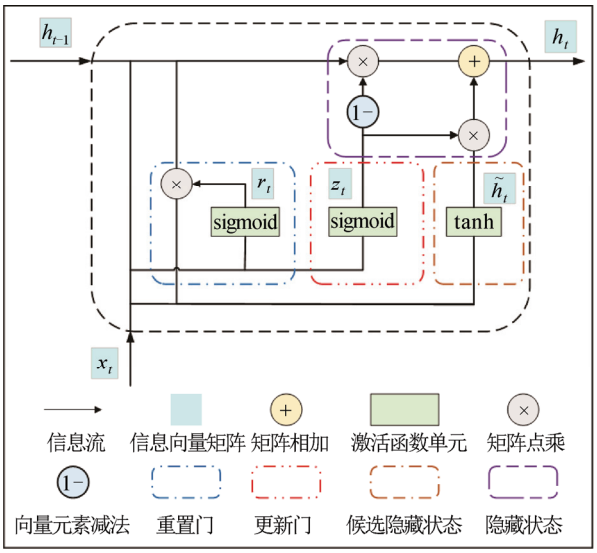


图 3 GRU 内部结构图

Fig.3 Internal structure diagram of GRU

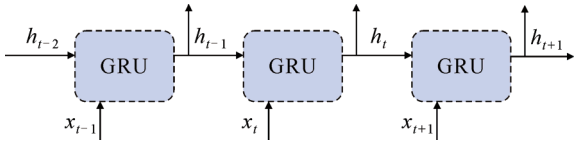


图 4 GRU 循环结构

Fig.4 Circular structure of GRU

型结合前向 GRU 和反向 GRU，考虑了时间序列的双向信息流，可以有效地兼顾历史数据与下一阶段数据对此刻数据的影响，学习交流接触器退化特征的动态变化规律。表达式如下：

$$\begin{cases} \vec{h}_t = \mathrm{GRU}\left(x_t, \vec{h}_{t-1}\right) \\ \overleftarrow{h}_t = \mathrm{GRU}\left(x_t, \overleftarrow{h}_{t-1}\right) \\ h_t = \vec{h}_t \oplus \overleftarrow{h}_t = w_t \vec{h}_t + v_t \overleftarrow{h}_t + b_t \end{cases} \tag{16}$$

式中：w_t 和 v_t 分别为 t 时刻时间序列的前隐藏层和后隐藏层的输出权重；$\vec{h}_t$ 和 $\overleftarrow{h}_t$ 分别为 t 时刻的前向和后向 GRU 的输出状态；b_t 为 t 时刻的偏差参数。图 5 给出了 BiGRU 的结构图，由单向、方向相反的 GRU 构成，能进一步提高信息记忆能力和长时间序列预测的精度。

2 预测模型搭建

2.1 预测模型概述

针对交流接触器剩余电寿命存在单一特征预测精度低、未充分考虑开断前后的关联性和忽略了长时间序列特点的问题，本文构建基于数据增强 SDAE-BiGRU 的交流接触器剩余电寿命预测模型，模型结构如图 6 所示，其中 X 表示原始数据集，x 表示原始数据集经 SDAE 融合后的数据集。

首先将 NCA 和斯皮尔曼等级相关系数组合筛选的交流接触器最优特征子集通过窗口切片法进行时序增强，增强后的特征矩阵不仅有效表征退化信息，还在时间维度上强化前后状态的关联性，更有效反映出交流接触器的实际运行状态。然后，SDAE 对数据增强后的高维特征矩阵进行去噪、堆叠和融合，进而降低特征维度，避免“维度灾难”。之后将融合后的特征向量输入 BiGRU 神经网络。BiGRU 神经网络能充分考虑状态前后的关联性，捕捉序列长时间步依赖关系，对长时间历史特征信息进行记忆，通过全连接层输出预测结果。

2.2 模型损失函数及评价指标

在预测模型训练过程中，为提高模型收敛速度

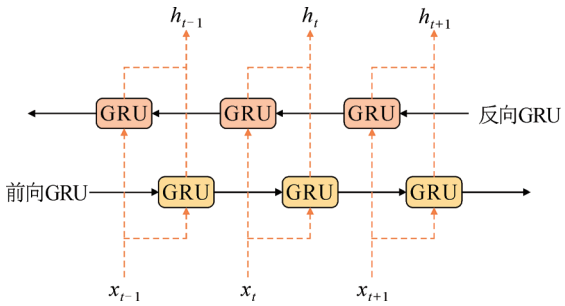


图 5 BiGRU 结构原理图

Fig.5 Structural schematic diagram of BiGRU

和获得最优网络参数[27]，本文利用自适应矩估计优化器(Adam)和网格搜索(Grid Search)对模型参数进行优化。预测模型采用均方误差函数(mean squared error，MSE)作为损失函数 L，即：

$$L = \frac{1}{m}\sum_{t=1}^{m}\left(y_t - \hat{y}_t\right)^2 \tag{17}$$

式中：y_t 为实际值；$\hat{y}_t$ 为模型的预测输出值。同时，为评价预测结果的优劣，选取均方根误差(root mean square error，RMSE)、平均绝对误差(mean absolute error，MAE)和拟合优度(R^2)进行评价，计算式如下所示：

$$R_{\mathrm{MSE}} = \sqrt{\frac{1}{m}\sum_{t=1}^{m}\left(\hat{y}_t - y_t\right)^2} \tag{18}$$

$$M_{\mathrm{AE}} = \frac{1}{m}\sum_{t=1}^{m}\left|\hat{y}_t - y_t\right| \tag{19}$$

$$R^2 = \frac{\sum_{t=1}^{m}\left(\hat{y}_t - \bar{y}\right)^2}{\sum_{t=1}^{m}\left(y_t - \bar{y}\right)^2} = 1 - \frac{\sum_{t=1}^{m}\left(y_t - \hat{y}_t\right)^2}{\sum_{t=1}^{m}\left(y_t - \bar{y}\right)^2} \tag{20}$$

式中：$\bar{y}$ 为实际值的平均值；R_{MSE} 表示均方根误差，反映数据偏离真实值的程度；M_{AE} 表示平均绝对误差，体现误差的大小；R^2 表示自变量对因变量的解释程度。R_{MSE} 和 M_{AE} 越小，R^2 越高，说明预测效果越好，模型性能越优越。

2.3 在线评估方法

结合本文提出的基于数据增强 SDAE-BiGRU 的交流接触器剩余电寿命预测方法，在线评估具体流程如图 7 所示。

首先，对某一型号交流接触器在不同工况下进行全生命周期数据采集并提取其特征参量，数据预处理后用于交流接触器剩余电寿命预测模型的训练和参数优化。然后，采用训练好的预测模型用于该型号交流接触器的在线监测。将其实时数据经预处

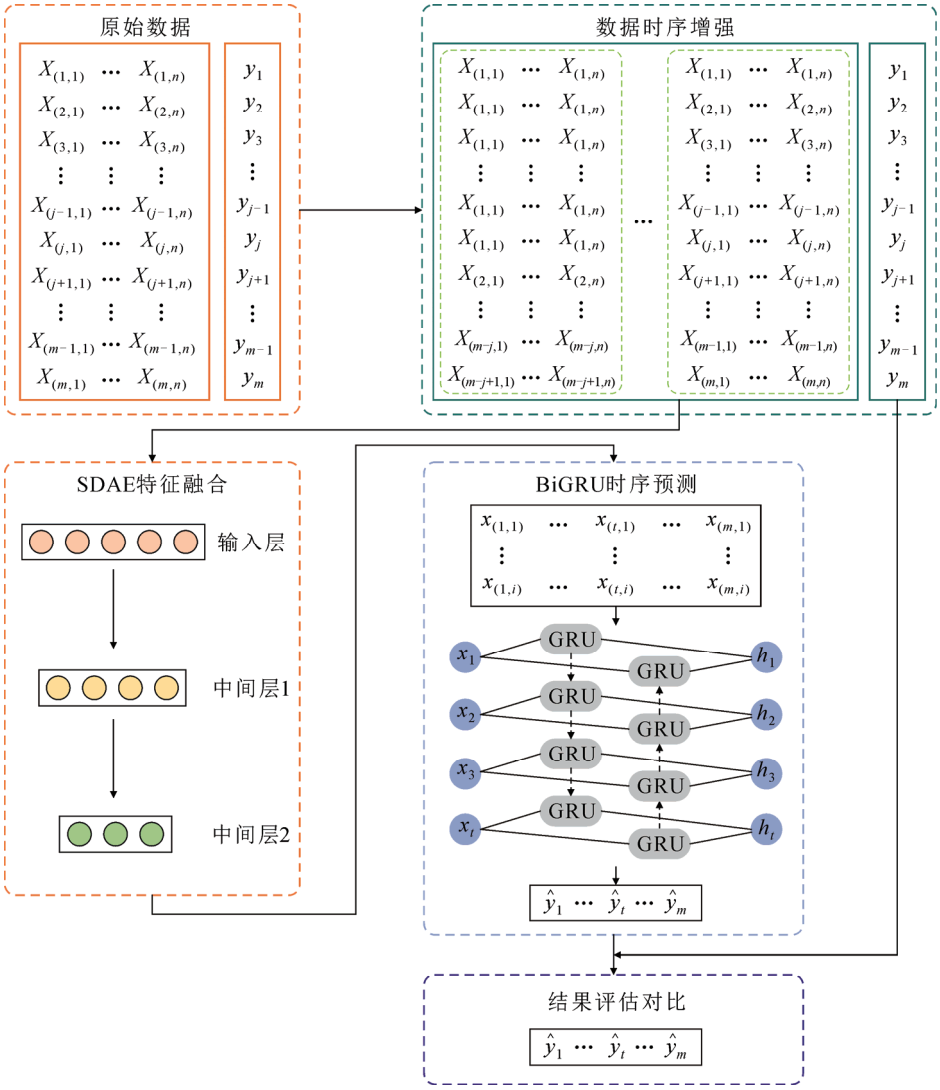


图 6　模型结构示意图

Fig.6　Schematic diagram of model structure

理后作为预测模型的输入，预测模型会根据输入数据的特征和参数进行计算，进而输出交流接触器剩余电寿命预测结果。

3　试验平台设计及参数提取

3.1　试验平台搭建

交流接触器全寿命试验根据 GB14048.4—2020 中规定的通断试验要求搭建平台并试验。实际应用中，交流接触器主要运行在 AC-4 工作条件下，即以 1 倍额定电压和 6 倍额定电流接通分断电路来模拟实际工况下的运行方式。在 AC-4 条件下，交流接触器触头烧蚀严重，性能退化趋势明显，极大地缩短了测试时间并能准确地反应交流接触器寿命特性的重要信息，所以本试验选用 AC-4 的试验条件，具体参数如表 1 所示。

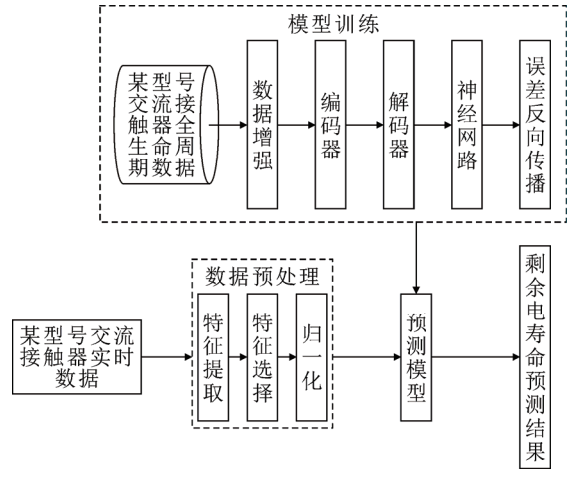


图 7　在线评估方法示意图

Fig.7　Schematic diagram of online evaluation method

表 1 中，I 是接通电流，I_e 是额定工作电流，U

是外施电压，U_e 额定工作电压，I_c 是分断电流，U_r 是工频恢复电压。

交流接触器全寿命试验平台的搭建主要包括硬件电路设计和软件程序设计。通过 NI 公司的 X 系列 USB6356 数据采集卡和莱姆公司的电压电流传感器，采集交流接触器分合闸过程中的三相主触头电压、三相主触头电流和线圈电压电流。更高的采样频率可提高表征交流接触器运行特征参量提取的准确率，根据奈奎斯特-香农采样定理，采样频率选取该数据采集卡的最高采样频率 1 MHz。软件程序设计主要通过通讯串口将 NI 数据采集卡与 LabVIEW 相结合，实现运行数据在线采集。交流接触器全寿命试验平台实物原理示意图见图 8。

表 1 AC-4 试验参数

Table 1 Parameters of AC-4 experiment

参数	数值	参数	数值
试验条件	AC-4	负载类型	阻感负载
负载电压	380 V	负载电流	222 A
线圈电压	220 V	功率因数 $\cos\varphi$	0.35
接通条件	I/I_e=6, U/U_e=1	分断条件	I_c/I_e=6, U_r/U_e=1
开断频率	300 次/h	采样频率	1 MHz

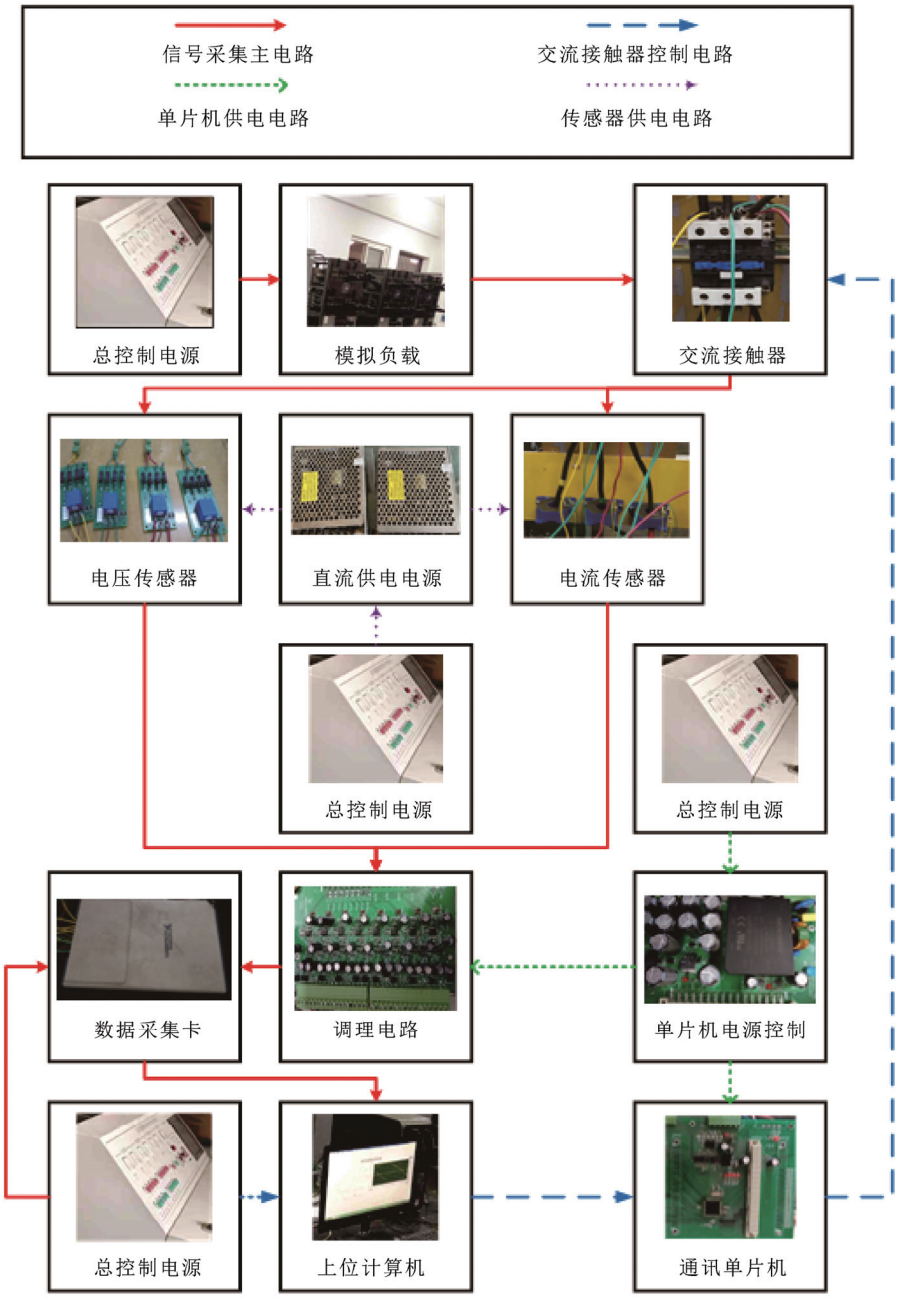


图 8 测试平台原理示意图

Fig.8 Schematic diagram of the test platform

3.2 特征参量提取

通过 LabVIEW 前端控制面板采集交流接触器的开断波形，可以提取特征参量和判断设备状态的变化，交流接触器分合闸的波形图如图 9 所示，t_a 为线圈得电时刻；t_b 为触头初次吸合时刻；t_c 为触头吸合达到稳定时刻；t_d 为线圈断电时刻；t_e 电弧产生时刻；t_f 电弧熄灭时刻。交流接触器的特征参量定义如表 2 所示[28]。

表 2 中，u_l 为触点电压；i_l 为触点电流；Δt 为采样间隔时间；f_s 为采样频率。在电寿命试验中，触头接通时其端间电压降大于 10%触头回路开路电压，或者触头断开时触头间的电压小于触头回路开路电压的 90%，如果出现以上情况之一，且累计出现次数超过 20 或者连续 5 次，则判定该交流接触器电寿命达到失效标准[29]。

3.3 特征参量计算

试验选取 CJX2-8011 型号交流接触器进行验证，从整批次全寿命测试样品中任选 3 台进行分析，并以测试 1 进行展示，测试 2 和测试 3 进行验证对比。试验样品 1 根据表 3 计算的特征参量的原始序列及其变化趋势如图 10 所示。

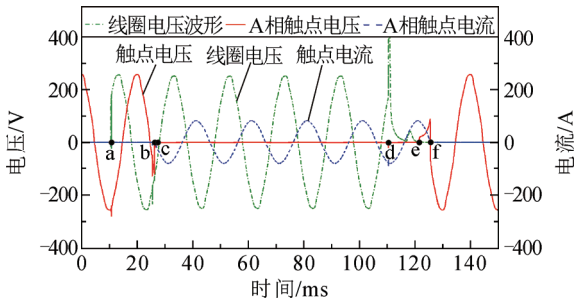


图 9 交流接触器波形

Fig.9 Normal waveforms of AC contactor

表 2 特征参量定义表

Table 2 Definition table of feature parameters

序号	特征名称	计算式
1	接触电阻 R	$R=\frac{\sqrt{\frac{1}{m}\sum_{l=1}^{m}u_l^2}}{\sqrt{\frac{1}{m}\sum_{l=1}^{m}i_l^2}}=\sqrt{\frac{\sum_{l=1}^{m}u_l^2}{\sum_{l=1}^{m}i_l^2}}$
2	吸合时间 t_x	$t_x=t_b-t_a$
3	弹跳时间 t_t	$t_t=t_c-t_b$
4	燃弧时间 t_{arc}	$t_{arc}=t_f-t_e$
5	燃弧能量 E	$E=\sum_{l=e}^{f}u_l\cdot i_l\cdot\Delta t=\frac{\sum_{l=e}^{f}u_l\cdot i_l}{f_s}$
6	平均燃弧功率 P	$P=\frac{E}{\Delta t\cdot m}=\frac{\sum_{l=e}^{f}u_l\cdot i_l}{m}$
7	释放时间 t_s	$t_s=t_e-t_d$

4 实例分析

特征参数越多，越能有效反映交流接触器的实际退化过程，但高维度往往会影响预测模型的性能和效率。因此，需要对特征参量进行处理以获得预测模型最佳输入，具体如图 11 所示。

首先，通过交流接触器全寿命试验平台采集电压电流信号，从中提取特征参量。然后，利用 NCA 特征重要性分析和斯皮尔曼相关性分析选择最优特征子集。之后，对最优特征子集进行数据增强，归一化处理后输入 SADE 中进行降维处理。接着，将剩余开断次数作为预测标签，构造并划分数据集。最后，将数据集输入 BiGRU 神经网络进行时序预测，经过反归一化后输出预测结果。

4.1 特征参量选择

过多的特征参量会包含大量冗余信息，不仅增加模型计算的复杂度，还会影响剩余电寿命预测的准确性。因此，本文综合考虑特征之间的相关性以及特征参量与剩余电寿命之间的相关性，使用 NCA 特征重要度分析与斯皮尔曼等级相关系数优势互补，选择最优特征子集。图 12 分析了不同特征参量对剩余电寿命的重要度。图 13 给出了不同特征参量间的斯皮尔曼等级相关系数。

根据 NCA 特征重要性分析，平均燃弧功率对剩余电寿命的重要度最低，应该剔除。通过热力图可以看出，燃弧时间和燃弧能量呈强相关性，特征信息相似度极高，结合重要性分析结果，保留燃弧时间。综上所述，为保留有效信息，避免冗余计算，本文选择接触电阻、燃弧时间、释放时间、吸合时间和弹跳时间作为模型输入的最优特征子集。

4.2 特征融合

基于变换的窗口切片法，滑动窗口在序列数据上进行动态采样，得到高维的时间序列参量。为了降低时间预测模型训练难度和计算量，利用 SDAE 对数据增强后的高维数据进行降维处理。

图 14 给出了不同特征融合维度下，输出层与输入层之间的相对误差。将增强后的时间序列数据分别融合至 5 维、4 维、3 维、2 维和 1 维，输入层与输出层误差分别是 0.043 5、 0.048 7、0.049 9、0.1145、0.186 6。可见，融合至 5 维、4 维和 3 维误差值类似，而融合至 2 维和 1 维误差显然增大。由于低维数据能够减少冗余信息，提高预测模型的精

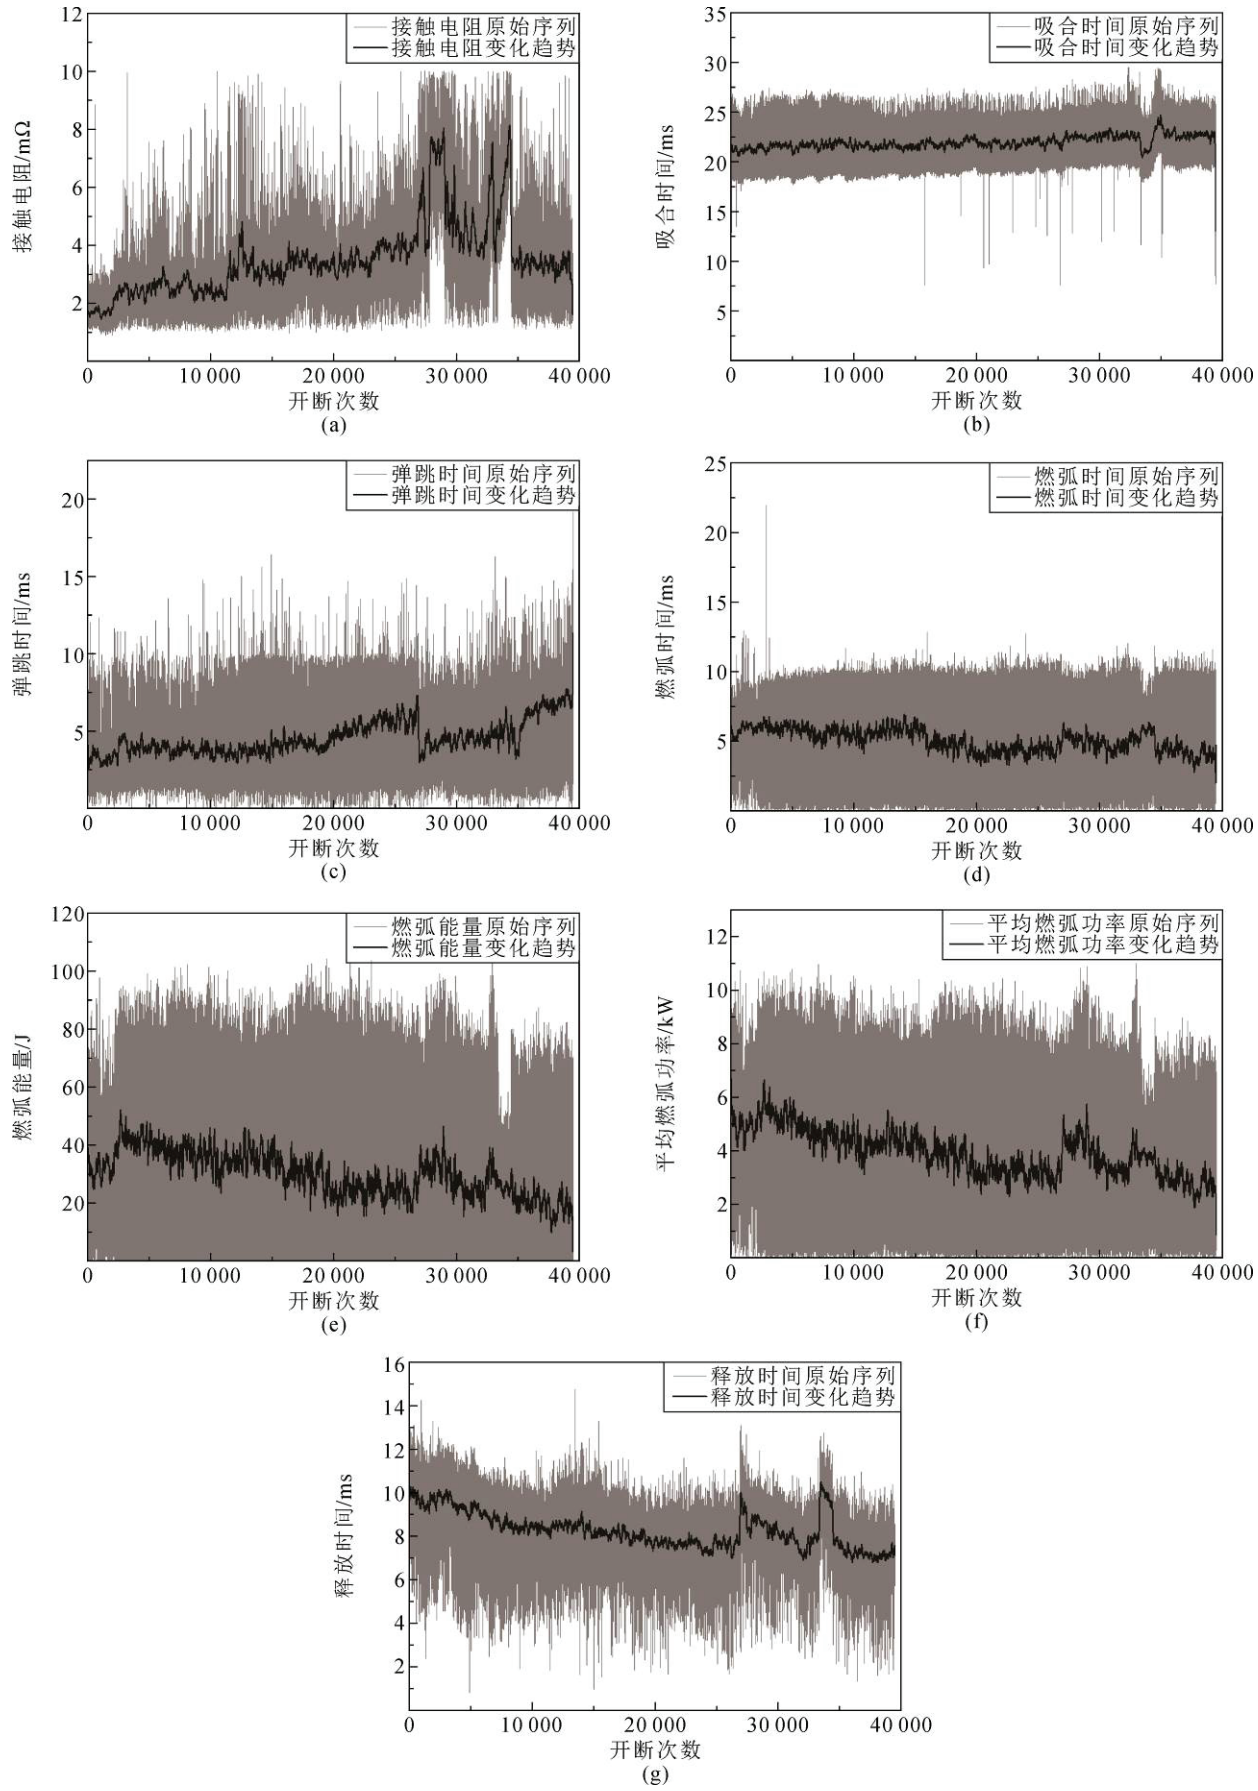


图 10 特征趋势变化图

Fig.10 Diagram of characteristic trend change

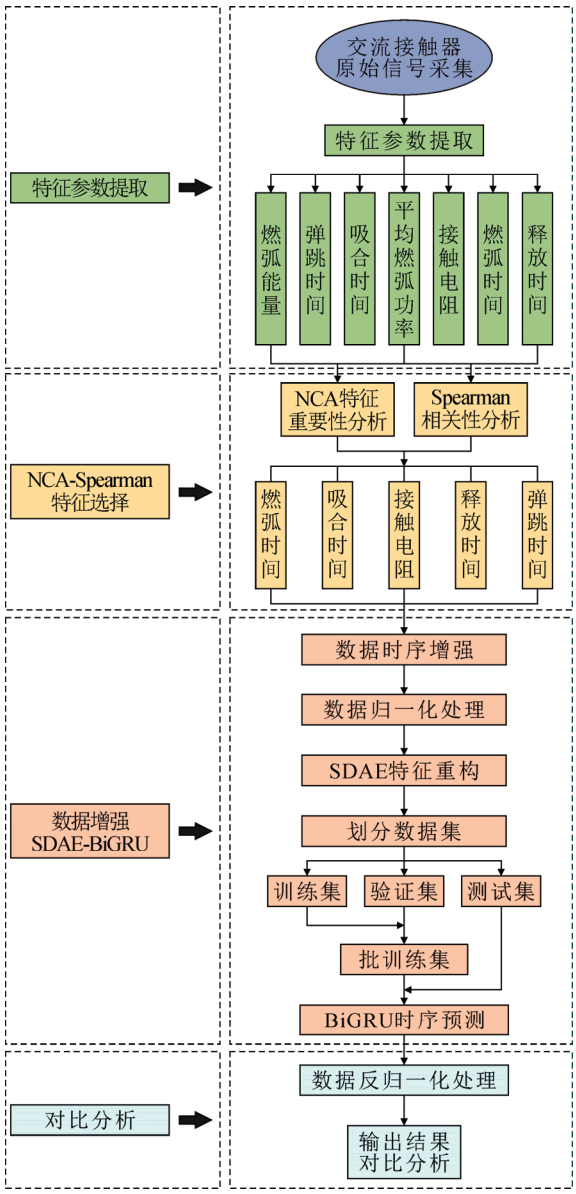


图 11　交流接触器寿命预测流程图

Fig.11　Flow chart of AC contactor life prediction

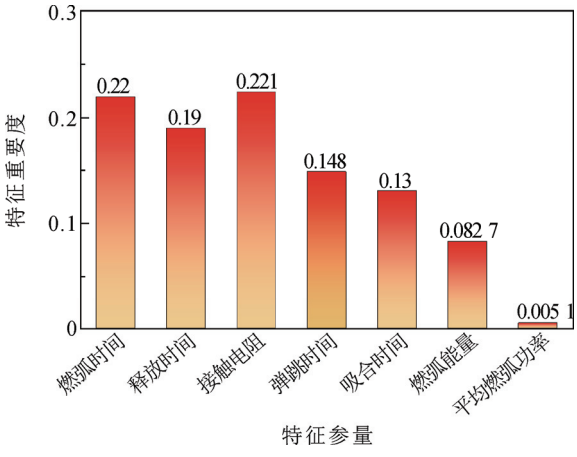


图 12　NCA 特征重要度分析

Fig.12　Significance analysis of NCA features

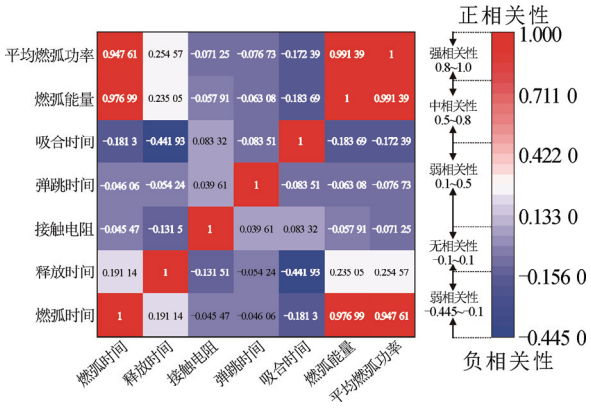


图 13　相关系数热力图

Fig.13　Correlation coefficient thermal diagram

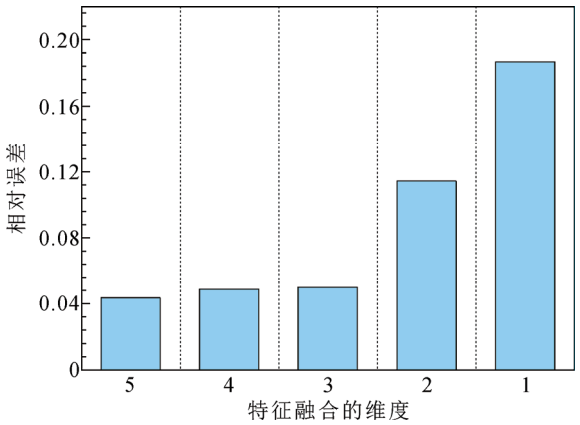


图 14　各维度误差值

Fig.14　Error value of each dimension

度，因此在 5 维、4 维和 3 维误差值相差较小的情况下选择融合至 3 维。DAE 中间层只有一层，学习特征的能力有限，而 SDAE 为 DAE 堆叠构建而成。在本文中分别构建了 1 层 DAE、2 层 DAE 和 3 层 DAE，其输入层与输出层误差分别为 0.049 9、0.026 6 和 0.039 8，当构建 2 层 DAE 时误差最小，因此本文采用的 SDAE 中间层数为 2 层。

4.3　模型训练

结合实际情况，模型依序选取 70%为训练集，20%为验证集，10%为测试集。模型训练的损失函数如图 15 所示。

当迭代次数在 35 前，训练集和验证集损失函数曲线呈下降趋势；当迭代至 35 后，损失函数完全收敛，之后验证集损失函数并未出现上升趋势，没有出现过拟合，模型训练效果达到最优。

4.4　预测结果对比

表 3 给出了特征选择前后 RNN、LSTM 和 GRU

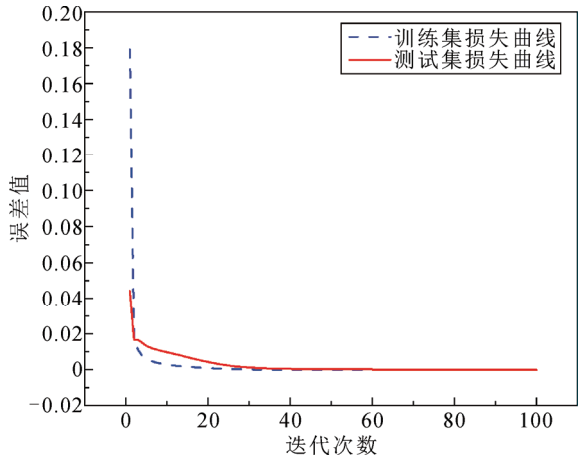


图 15 损失函数图

Fig.15 Diagram of loss function

表 3 特征选择前后 RNN、LSTM、GRU 预测结果对比

Table 3 Comparison of RNN、LSTM and GRU prediction results before and after feature selection

参量维度	参数	RNN	LSTM	GRU
7 特征参量	RMSE	3 510.08	2 935.07	2 834.26
	MAE	1 093.13	455.61	352.75
	R^2	0.53	0.79	0.82
	最大误差	5 991.21	4 837.08	4 458.51
	有效精度	84.82%	88.75%	88.95%
5 特征参量	RMSE	3 254.86	3 107.03	2 856.14
	MAE	973.62	617.71	423.39
	R^2	0.64	0.75	0.83
	最大误差	5 591.95	3 649.69	3 495.65
	有效精度	85.83%	90.75%	91.17%

的预测准确率和评价指标。本文利用 NCA 与斯皮尔曼等级相关系数，将试验数据提取到的 7 个特征参量剔除 2 个特征参量，得到由 5 个特征参量构成的最优特征子集。可以发现利用经本文分析后选择的最优特征子集作为预测模型的输入，其准确率更高。同时，LSTM 与 GRU 的准确率相近且均优于 RNN，但在相同平台下 LSTM 计算时间为 81.44 s，GRU 计算时间为 73.44 s，可见 GRU 的计算时间更少，这是由于 GRU 预测模型相比于 LSTM 更加简化。因此本文在后续模型比较时，均在 GRU 的基础上改进。

表 4 和表 5 给出了不同预测模型的定量分析和

表 4 预测结果对比表

Table 4 Comparison table of predicted results

测试编号	参数	BiGRU	SDAE-BiGRU	数据增强 SDAE-BiGRU
测试 1	RMSE	2 925.37	2 850.01	2 720.81
	MAE	406.57	322.44	175.28
	R^2	0.87	0.92	0.97
	最大误差	2 832.07	2 488.99	1 235.56
	有效精度	92.82%	93.69%	96.87%
测试 2	RMSE	3 102.24	2 795.69	2 488.66
	MAE	644.34	289.84	160.81
	R^2	0.68	0.91	0.97
	最大误差	2 911.41	2 726.24	1 364.91
	有效精度	92.62%	93.09%	96.54%
测试 3	RMSE	2 795.69	2 618.14	2 453.24
	MAE	289.84	151.66	187.02
	R^2	0.91	0.97	0.96
	最大误差	2 815.61	2 476.66	1 711.31
	有效精度	92.86%	93.72%	96.55%

表 5 多个样本预测平均有效精度

Table 5 Average effective accuracy of large sample prediction

预测模型	RNN	LSTM	GRU	BiGRU	SDAE-BiGRU	数据增强 SDAE-BiGRU
平均有效精度/%	85.12	90.65	91.16	92.78	93.51	96.68

整批大量试验样品的平均有效精度。对测试 2 和测试 3 进行剩余电寿命预测，并与测试 1 预测结果进行对比验证，其中测试 1 有效开断 39 486 次，测试 2 有效开断 39 465 次，测试 3 有效开断 39 502 次。

根据实例分析中测试 1、测试 2 和测试 3 的模型定量分析可知，基于数据增强 SDAE-BiGRU 的模型预测结果相比于对比模型的预测结果，RMSE、MAE 和最大绝对误差最小，具有较高的准确率，R^2 最高，可解释性最强，模型优势明显。以测试 1 为例在整批次大样本试验的情况下，基于数据增强 SDAE-BiGRU 的模型整体预测精度相比于时序预测模型中的 RNN 模型，预测效果提升显著。

为体现本文模型的优越性，以测试 1 的 39 486 组试验数据为例，将本文提出的时序预测模型与其他时序预测模型对比，预测结果如图 16 所示，可以发现本文提出的基于数据增强 SDAE-BiGRU 模型预测结果的曲线与实际寿命曲线一致性较好，整体波动幅度最小。

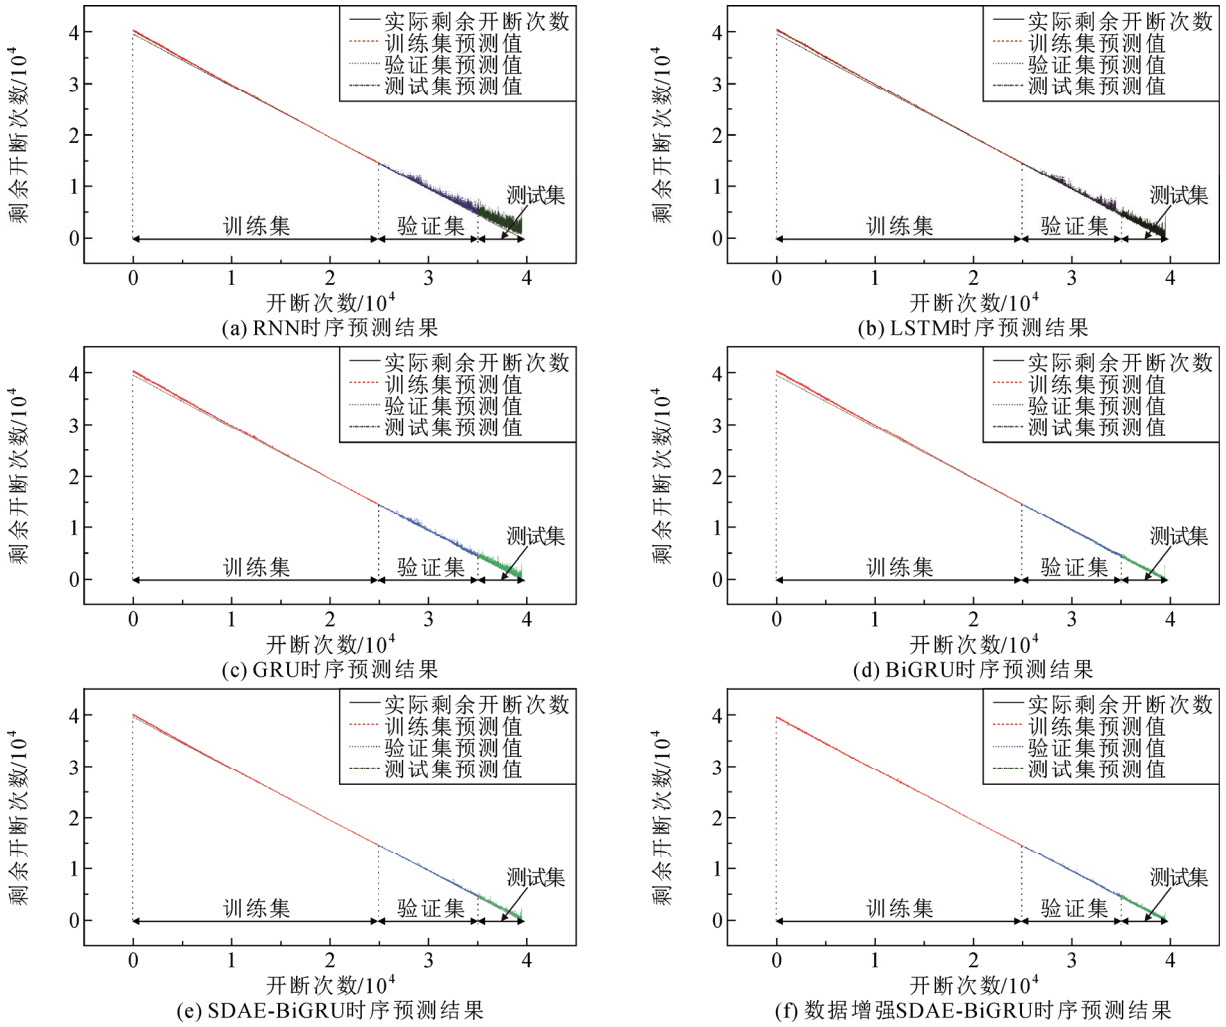


图 16　预测结果对比图

Fig.16　Comparison diagram of prediction results

同时，本文对各个模型测试集预测结果的误差率进行对比分析，误差率对比如图 17 所示。

本文方法预测误差率为 3.13%，对比可知其误差率最小，稳定性最高。

本文对测试集预测结果随机抽取部分进行对比，对比结果如图 18 所示。可以明显比较出，本文预测的结果与实际值最接近，优势明显。

综上所述，基于数据增强 SDAE-BiGRU 的交流接触器剩余电寿命预测模型具有较高的准确度与鲁棒性，能够满足实际工程需要，应用前景广泛。

5　结论

本文提出一种基于数据增强 SDAE-BiGRU 的交流接触器剩余电寿命预测方法，并以 CJX2-8011 型号交流接触器为例进行验证分析，得到结论如下：

1）通过组合使用 NCA 和斯皮尔曼等级相关系数，综合考虑特征参量对电寿命的重要度和特征参量间的相关程度，选择最优特征子集，并对最优特征子集进行数据时序增强，强化前后状态间的关联性，有效表征交流接触器的实际退化信息。

2）利用 SDAE 进行特征向量提取和降维压缩处理，降低模型过拟合的风险。同时，BiGRU 将时序退化的概念引入交流接触器剩余电寿命的预测中，充分记忆长时间历史特征信息前后状态的关联性，实现剩余电寿命的时序精准预测。

3）利用本文提出的交流接触器剩余电寿命预测模型对 AC-4 工作条件下的 CJX2-8011 型号交流接触器剩余电寿命预测，平均有效精度为 96.68%，验证了此模型的可行性、有效性和准确性。在不同工况条件下，表征交流接触器电寿命特征参量的变化趋势不同，在模型训练过程中，基于输入数据的时序变化规律和预测准确率，SDAE-BiGRU 模型中

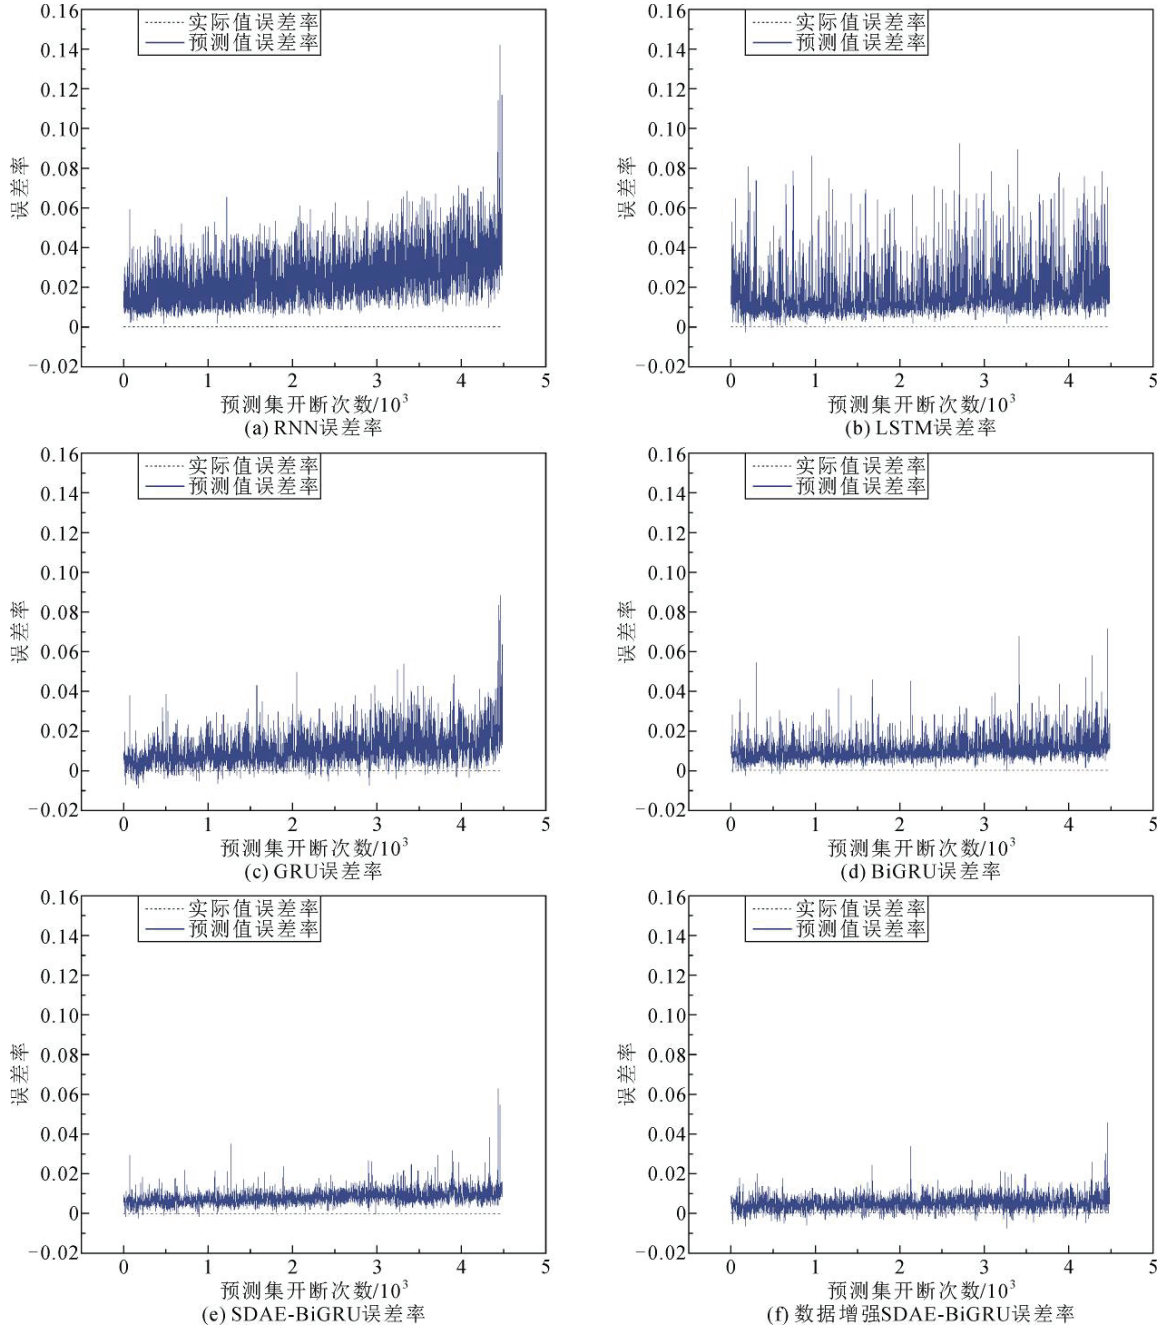


图 17 模型误差对比图

Fig.17 Comparison diagram of model errors

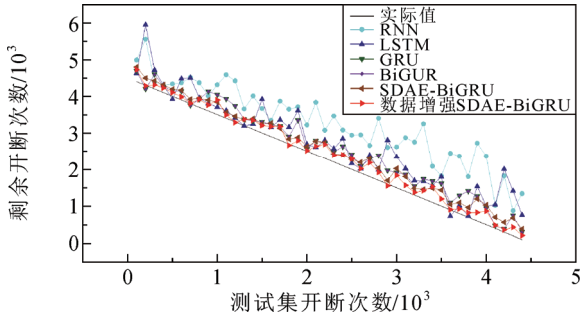


图 18 预测抽样对比图

Fig.18 Comparison chart of predictive sampling

的 Adam 和 Grid Search 会对模型参数进行优化，最终获得具有最佳参数的预测模型，为开关电器设备剩余电寿命预测问题提供了新思路。

参考文献 References

[1] 韩翔宇，纽春萍，何海龙，等. 电磁式断路器状态监测与智能评估技术综述[J]. 电工技术学报，2023，38(8)：2191-2210.
HAN Xiangyu, NIU Chunping, HE Hailong, et al. Review of condition monitoring and intelligent assessment of electromagnetic circuit breaker[J]. Transactions of China Electrotechnical Society, 2023, 38(8):

2191-2210.

[2] 蒋幸伟，曹云东，刘　洋，等. 基于多特征增强融合的交流接触器状态表征[J]. 高电压技术，2024，50(1)：282-291.
JIANG Xingwei, CAO Yundong, LIU Yang, et al. State characterization of AC contactor based on multi-feature enhanced fusion[J]. High Voltage Engineering, 2024, 50(1): 282-291.

[3] 张长坤，许志红. 基于磁链反馈的智能交流接触器串级控制策略[J]. 中国电机工程学报，2020，40(4)：1329-1338.
ZHANG Changkun, XU Zhihong. A cascade control strategy for intelligent AC contactors based on flux linkage feedback[J]. Proceedings of the CSEE, 2020, 40(4): 1329-1338.

[4] 王建华，张国钢，耿英三，等. 智能电器最新技术研究及应用发展前景[J]. 电工技术学报，2015，30(9)：1-11.
WANG Jianhua, ZHANG Guogang, GENG Yingsan, et al. The latest technology research and application prospects of the intelligent electrical apparatus[J]. Transactions of China Electrotechnical Society, 2015, 30(9): 1-11.

[5] 刘　洋，曹云东，刘树鑫. 基于改进 Kruskal-Wallis 检验的低压开关电器状态表征参数选择[J]. 高电压技术，2024，50(2)：537-544.
LIU Yang, CAO Yundong, LIU Shuxin. Selection of state characterization parameters for a low-voltage switching device based on improved Kruskal-Wallis test[J]. High Voltage Engineering, 2024, 50(2): 537-544.

[6] 刘子春. 基于数据驱动的交流接触器全寿命状态评估研究[D]. 沈阳：沈阳工业大学，2019.
LIU Zichun. Research on life-cycle state assessment of AC contactor based on data-driven[D]. Shenyang, China: Shenyang University of Technology, 2019.

[7] 刘树鑫，周　柱，刘　洋，等. 基于振动信号的交流接触器触头系统退化阶段划分[J]. 高电压技术，2023，49(12)：4971-4981.
LIU Shuxin, ZHOU Zhu, LIU Yang, et al. Degradation phase division of AC contactor contact system based on vibration signal[J]. High Voltage Engineering, 2023, 49(12): 4971-4981.

[8] LI K, ZHAO C C, NIU F, et al. Electrical performance degradation model and residual electrical life prediction for AC contactor[J]. IEEE Transactions on Components, Packaging and Manufacturing Technology, 2020, 10(3): 400-417.

[9] SU J Z. Research on electrical life trace prediction of contact based on SG-BP algorithm[J]. Journal of Physics: Conference Series, 2021, 1952: 032035.

[10] 游颖敏，王景芹，舒　亮，等. 基于音频特征的交流接触器电寿命预测方法[J]. 电工技术学报，2021，36(9)：1986-1998.
YOU Yingmin, WANG Jingqin, SHU Liang, et al. The method of electrical life prediction considering the audio characteristics of AC contactor[J]. Transactions of China Electrotechnical Society, 2021, 36(9): 1986-1998.

[11] 刘树鑫，高士珍，刘　洋，等. 基于 LSTM 的交流接触器剩余寿命预测[J]. 高电压技术，2022，48(8)：3210-3220.
LIU Shuxin, GAO Shizhen, LIU Yang, et al. Residual life prediction of AC contactor based on long short-term memory[J]. High Voltage Engineering, 2022, 48(8): 3210-3220.

[12] SUN S G, LIU J F, WANG J Q, 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: 9004513.

[13] LIU S X, GAO S Y, PENG S D, et al. Residual-electrical-endurance prediction of AC contactor based on CNN-GRU[J]. Machines, 2022, 10(11): 1067.

[14] ABIRAMI S, RUTHVIK S, ALI M S, et al. AC contactor electrical health estimator model[J]. IOP Conference Series: Materials Science and Engineering, 2021, 1145: 012070.

[15] 赵冬冬. 基于深度学习的动车组轴承状态评估与剩余使用寿命预测方法研究[D]. 北京：北京交通大学，2022.
ZHAO Dongdong. Research on EMUs bearing condition assessment and remaining useful life prediction method based on deep learning[D]. Beijing, China: Beijing Jiaotong University, 2022.

[16] LIU K Y, MAO W T, SHI H D, et al. A new unsupervised online early fault detection framework of rolling bearings based on granular feature forecasting[J]. IEEE Access, 2021, 9: 159684-159698.

[17] QIU X H, REN Y, SUGANTHAN P N, et al. Empirical mode decomposition based ensemble deep learning for load demand time series forecasting[J]. Applied Soft Computing, 2017, 54: 246-255.

[18] SHEN C P. A transdisciplinary review of deep learning research and its relevance for water resources scientists[J]. Water Resources Research, 2018, 54(11): 8558-8593.

[19] YANG S D, YU X Y, ZHOU Y. LSTM and GRU neural network performance comparison study: taking yelp review dataset as an example[C]//Proceedings of 2020 International Workshop on Electronic Communication and Artificial Intelligence. Shanghai, China: IEEE, 2020: 98-101.

[20] 李雅欣，侯慧娟，张立静，等. 近邻成分分析和 k 近邻学习融合的变压器不平衡样本故障诊断[J]. 高电压技术，2021，47(2)：472-479.
LI Yaxin, HOU Huijuan, ZHANG Lijing, et al. Transformer fault diagnosis with unbalanced samples based on neighborhood component analysis and k-nearest neighbors[J]. High Voltage Engineering, 2021, 47(2): 472-479.

[21] 孙曙光，唐　尧，王景芹，等. 基于多信号特征融合的断路器操作机构寿命预测[J]. 高电压技术，2022，48(11)：4455-4468.
SUN Shuguang, TANG Yao, WANG Jingqin, et al. Life prediction of operating mechanism for circuit breaker based on multiple signal feature fusion[J]. High Voltage Engineering, 2022, 48(11): 4455-4468.

[22] 乔　颖，孙荣富，丁　然，等. 基于数据增强的分布式光伏电站群短期功率预测(一)：方法框架与数据增强[J]. 电网技术，2021，45(5)：1799-1808.
QIAO Ying, SUN Rongfu, DING Ran, et al. Distributed photovoltaic station cluster gridding short-term power forecasting. part I: methodology and data augmentation[J]. Power System Technology, 2021, 45(5): 1799-1808.

[23] 葛轶洲，许　翔，杨锁荣，等. 序列数据的数据增强方法综述[J]. 计算机科学与探索，2021，15(7)：1207-1219.
GE Yizhou, XU Xiang, YANG Suorong, et al. Survey on sequence data augmentation[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(7): 1207-1219.

[24] LIU Y, MA Z, WANG F, et al. Operating performance assessment based on stacked performance-relevant enhanced denoising auto-encoder for industrial processes[J]. The Canadian Journal of Chemical Engineering, 2024, 102(4): 1509-1521.

[25] JIA N, CHENG Y, LIU Y Y, et al. Intelligent fault diagnosis of rotating machines based on wavelet time-frequency diagram and optimized stacked denoising auto-encoder[J]. IEEE Sensors Journal, 2022,

22(17): 17139-17150.

[26] HELMY I, TARAFDER P, CHOI W. LSTM-GRU model-based channel prediction for one-bit massive MIMO system[J]. IEEE Transactions on Vehicular Technology, 2023, 72(8): 11053-11057.

[27] BARAKAT A, BIANCHI P. Convergence and dynamical behavior of the ADAM algorithm for nonconvex stochastic optimization[J]. SIAM Journal on Optimization, 2021, 31(1): 244-274.

[28] 刘 洋，刘树鑫，曹云东. 基于模态相似性度量的开关电器状态表征研究[J]. 中国电机工程学报，2022，42(2)：844-852.
LIU Yang, LIU Shuxin, CAO Yundong. Research on state characterization of switching device based on modal similarity measurement[J]. Proceedings of the CSEE, 2022, 42(2): 844-852.

[29] 中华人民共和国国家质量监督检验检疫总局，中国国家标准化管理委员会. 小容量交流接触器可靠性试验方法：GB/Z 22200—2016[S]. 北京：中国标准出版社，2016.
General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic of China. Reliability test method for lower capacity alternating current contactors: GB/Z 22200—2016[S]. Beijing, China: Standards Press of China, 2016.



邢朝健
1995—，男，博士生
主要从事电器智能化及其控制的研究工作
E-mail: xcj318172267@smail.sut.edu.com

XING Chaojian
Ph.D. candidate



刘树鑫(通信作者)
1982—，男，博士，副教授，博导
主要从事电器智能化及其控制的研究工作
E-mail: liushuxin@sut.edu.cn

LIU Shuxin
Ph.D.
Associate professor
Corresponding author

收稿日期 2023-07-21 修回日期 2024-03-15 编辑 卫李静