第 50 卷 第 1 期：250-262 高电压技术 Vol.50, No.1: 250-262
2024 年 1 月 31 日 High Voltage Engineering January 31, 2024
DOI: 10.13336/j.1003-6520.hve.20230013

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

李家豪[1]，王青于[1]，范玥霖[1]，史石峰[1]，彭宗仁[1]，曹 培[2]，徐 鹏[2]
（1. 西安交通大学电工材料电气绝缘全国重点实验室，西安 710049;
2. 国网上海市电力公司电力科学研究院，上海 200080）

摘 要：低压断路器的安全可靠是电力系统能否稳定运行的关键一环，因此对断路器进行退化趋势预测和剩余寿命评估具有重要意义。基于鲸鱼优化算法(whale optimization algorithm，WOA)和双向长短期记忆神经网络(bidirectional long short-term memory，BiLSTM)提出了一种断路器操动机构剩余寿命的预测方法，首先采用 Pearson 相关系数法对获得的原始监测数据进行筛选，选择与断路器开断次数相关度较高的数据作为关键退化特征量，基于主成分分析法进行数据融合获得能够综合表征断路器运行状态的健康指数；随后使用滑动时间窗的方法对健康指数时间序列进行重构，再通过 WOA-BiLSTM 寻优获得的最佳模型对健康指数进行时间序列预测，从而获得断路器未来多步的退化趋势；最后再根据设定的失效阈值，确定断路器操动机构的剩余寿命。实例验证表明，该文提出的混合预测模型预测精度最高可达 96.43%，相比于其他传统预测模型显著提高，对于断路器的实际运维工作具有一定的指导意义。

关键词：低压断路器；退化趋势；剩余寿命；双向长短期记忆网络；鲸鱼优化

Research on Whale Optimization Algorithm-bidirectional Long-short-term Memory Neural Network for Prediction of Machinery Remaining Useful Life of Circuit Breaker

LI Jiahao[1], WANG Qingyu[1], FAN Yuelin[1], SHI Shifeng[1], PENG Zongren[1], CAO Pei[2], XU Peng[2]
(1. State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China;
2. Electric Power Science Research Institute of Shanghai Electric Power Company, Shanghai 200080, China)

Abstract: The safety and reliability of low-voltage circuit breakers are the key to the stable operation of power systems, so it is of great significance to predict the degradation trend and evaluate the remaining useful life of circuit breakers. In this paper, based on whale optimization algorithm (WOA) and bidirectional long short-term memory (Bi-LSTM) neural network, a method for predicting the remaining useful life of the circuit breaker operating mechanism is proposed. Firstly, the Pearson correlation coefficient method is used to screen the original monitoring data and the data with higher correlation with the number of circuit breaker openings were selected as the key degradation feature. The health index which can comprehensively characterize the running state of circuit breaker can be obtained by data fusion based on principal component analysis (PCA). The time series of health index is reconstructed by the method of sliding time window, and then the best model obtained by WOA-BiLSTM optimization is used to predict the time series of health index, so as to obtain the multi-step degradation trend of circuit breaker in the future. Finally, according to the set failure threshold, the remaining useful life of the operating mechanism of circuit breaker is determined. Example validation shows that the hybrid prediction model proposed in this paper has a prediction accuracy of up to 96.43%, which is significantly improved compared to other traditional prediction models. So it has certain guiding significance for the actual operation and maintenance of circuit breakers.

Key words: low voltage circuit breaker; degradation trend; remaining useful life; bidirectional long short-term memory network; whale optimization

基金资助项目：国网上海市电力公司研发项目 (520940230003)。
Project supported by Research and Development Project of State Grid Shanghai Electric Power Company (520940230003).

0 引言

随着国民经济的发展和人民生活水平的提高，低压断路器在电网中的装用量逐年提升。作为用量最大的电力设备之一，超期服役的断路器设备占比不断加重，故障风险累积致使电力系统的运维压力不断增大[1-5]。随着操作次数的增加，断路器操动机构的健康状态在运行中呈现逐渐衰退的趋势。当机械性能退化到一定阈值时，断路器将到达其寿命终点，无法执行正常的功能，进而严重威胁电力系统的安全可靠性[6]。对于断路器进行剩余寿命(remaining useful life，RUL)预测能够有效避免上述情况的发生，在断路器到达寿命终点之前提前预测并及时做出预防性维修决策，从而有效提升断路器设备本体和电力系统运行的安全可靠性[7-8]。

目前研究人员就断路器状态监测开展了大量工作。邵阳等提出了一种 AM-ReliefF 特征选择下的集成 SVM 方法，以断路器合闸过程的振动信号为输入可以实现断路器故障的有效诊断[9]。曹宇鹏等基于卷积神经网络和长短期记忆网络构建了混合神经网络，该方法用于断路器故障诊断时表现十分优异[10]。李奎[6]、赵成晨[11]、何志鹏[12]及孙曙光[13]等学者就开关设备的电寿命预测开展了系列研究，分别利用物理建模和数据驱动方法对断路器剩余寿命进行评估，均取得了不错的预测效果。但上述研究主要集中在机械故障诊断和电寿命预测方面，针对断路器机械剩余寿命预测的相关研究鲜有报道。

在 RUL 预测方面，目前的研究主要集中在滚动轴承[14]、刀具磨损[15]、航空发动机[16]以及锂离子电池[17]的寿命预测上。RUL 的预测方法一般可以分为基于物理模型和基于数据驱动的健康预测[18]。基于物理模型的预测方法很大程度上受限于单一研究对象的物理失效过程，模型的泛化能力较差。而基于数据驱动的预测方法主要利用反映设备退化状态的监测数据进行剩余寿命预测，能够很好地解决设备失效机理复杂以及难以建立精确模型等情况下的寿命预测问题。深度学习作为数据驱动预测方法的典型代表，近几年因其较强的适应能力在设备寿命预测领域得以广泛应用。深度学习可以直接提取和训练反映设备性能退化的传感器数据，模拟设备性能的退化演变规律及过程，进而根据实时数据预测设备的 RUL。

深度学习方法中的循环神经网络(recurrent neural network, RNN)具有处理和预测时序数据的功能，已经被广泛应用于设备的剩余寿命预测。但该方法容易出现梯度爆炸或梯度消失，导致记忆能力受限，在序列较长时预测效果较差。长短期记忆神经网络(long short-term memory，LSTM)通过引入门的结构，相比于传统的 RNN 可以有选择性地让信息进入到细胞状态，较好地解决了传统循环神经网络梯度消失或梯度爆炸的问题，使模型具有学习长期依赖信息的能力，因此在时序序列预测等领域具有广泛的应用。刘树鑫等基于试验获得的交流接触器的全寿命退化数据，先根据灰色关联分析和相关系数法剔除冗余信息，再利用长短期记忆神经网络建立预测模型，最终预测得到了交流接触器的剩余使用寿命[19]。何彦等建立 LSTM-CNN 模型对监测数据进行多维度特征提取，并利用线性回归实现了刀具磨损情况的实时监测[15]。车畅畅等先利用 1D-CNN 模型对于多变量时间序列进行回归分析并得到性能退化量化指标，再通过 LSTM 对性能退化量进行时间序列预测得到剩余寿命预测结果[16]。高德欣等融合卷积神经网络和双向长短期记忆神经网络的特点，设计了一种锂离子电池的剩余使用寿命预测方法[17]。

在多维特征提取方面，由于设备性能退化过程中监测得到的特征数据量较大，如果全部作为模型的输入很有可能导致信息冗余，出现模型训练困难和过拟合等问题，但选取单一或少数几个变量则可能导致信息丢失，上述两种情况都会导致最终的预测结果不准确。针对这一问题，研究人员常通过主成分分析(principal component analysis, PCA)的手段对于原始数据进行降维处理，在有效降低数据冗余程度的同时，能够最大程度地保留原始数据的有效信息。孙曙光等利用 PCA 法对断路器操动机构的关键退化特征进行融合得到了操动机构的健康指标，在实现多源信息互补的同时有效降低了特征的冗余程度[20]。

基于以上分析，本文首先采用 Pearson 相关系数法对试验得到的断路器各退化参量进行筛选，得到与断路器开断次数相关性较高的退化特征量，进而利用 PCA 法对筛选得到的退化特征量进行多元信息融合得到断路器操动机构的综合健康指标，再基于双向长短期记忆神经网络(bidirectional long short-term memory, Bi-LSTM)构建预测模型，对综合健康指标进行时间序列预测，从而得到断路器的机

械剩余使用寿命。为进一步克服传统依据经验选取参数而导致预测精度低的问题，笔者使用鲸鱼优化算法(whale optimization algorithm, WOA)针对Bi-LSTM模型的关键超参数(隐含层神经元个数m、滑动时间窗口w、初始学习率l)进行多目标寻优，根据优化后的参数建立的预测模型有效提升了预测的准确率。

1 本文理论基础

本文所应用到的理论基础主要包括Pearson相关系数法、主成分分析、Bi-LSTM的基本结构和鲸鱼优化算法的实现原理。

1.1 Pearson相关系数

Pearson相关系数能计算两个参量A和B之间的相关性，广泛用于度量2个变量之间的相关程度，其值在–1~1之间。计算方法如下[21]：

设两种特征参量为$\boldsymbol{A}\{a_1,a_2,\cdots,a_q\}$，$\boldsymbol{B}\{b_1,b_2,\cdots,b_q\}$，$q$为特征参量的序列长度。则$\boldsymbol{A}$与$\boldsymbol{B}$间的Pearson相关系数为：

$$\rho_{\mathrm{AB}}=\frac{\sum_{i=1}^{q}\left(a_i-E(\boldsymbol{A})\right)\left(b_i-E(\boldsymbol{B})\right)}{\sqrt{\sum_{i=1}^{q}\left(a_i-E(\boldsymbol{A})\right)^2}\sqrt{\sum_{i=1}^{q}\left(b_i-E(\boldsymbol{B})\right)^2}} \tag{1}$$

式中：$E(\boldsymbol{A})$与$E(\boldsymbol{B})$分别为两种特征参量的平均值。

为排除偶然因素导致相关性系数过高的问题，一般采用T检验法对Pearson相关系数进行显著性检测，构造检验统计量T为：

$$T=\frac{\rho_{\mathrm{AB}}\sqrt{q-2}}{\sqrt{1-\rho_{\mathrm{AB}}^2}} \tag{2}$$

进一步根据T值在文献[22]查表确定显著性水平p。当$p<0.05$时，认为两变量之间存在一定相关性关系，当$p<0.01$时，认为两变量之间显著相关。变量之间的相关性强弱标准见表1[19]。

1.2 主成分分析

主成分分析的基本原理是寻找一组合适的正交基，通过对原始数据进行线性变换将原来的n维特征映射到k维($n>k$)，从而实现对高维数据的有效降维，所获得的新变量既能保留高维数据中的重要特征，又可以有效降低数据的冗余程度。计算的主要过程如下[23-25]：

假设原始特征数据矩阵为$\boldsymbol{X}_{n\times m}$，每个列向量为一个特征，共有$n$个特征样本，每个特征样本中有$m$个特征，即$\boldsymbol{X}=[\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_m]$，其中$\boldsymbol{X}_i=[x_i(1),x_i(2),\cdots,x_i(n)]$。

表1 皮尔逊相关系数关联度标准

Table 1 Pearson correlation coefficient correlation degree standard

相关性水平	相关系数绝对值
无相关性	0~0.2
弱相关性	0.2~0.5
较强相关性	0.5~0.8
强相关性	0.8~1.0

1）对于列向量进行标准归一化处理，其计算表达式为：

$$\boldsymbol{Y}_i=\frac{\boldsymbol{X}_i-E(\boldsymbol{X}_i)\cdot\boldsymbol{I}}{S(\boldsymbol{X}_i)} \tag{3}$$

式中：$\boldsymbol{Y}_i$为标准化之后的列向量；$E(\boldsymbol{X}_i)$为初始列向量的均值；$\boldsymbol{I}$为与$\boldsymbol{X}_i$等组度的全1列向量；$S(\boldsymbol{X}_i)$为初始列向量的标准差；$0<i\le n$。

2）计算标准化后数据矩阵的协方差矩阵$\boldsymbol{C}$。计算表达式如下：

$$\boldsymbol{C}=\begin{bmatrix}\mathrm{cov}(\boldsymbol{Y}_1,\boldsymbol{Y}_1) & \mathrm{cov}(\boldsymbol{Y}_2,\boldsymbol{Y}_1) & \cdots & \mathrm{cov}(\boldsymbol{Y}_m,\boldsymbol{Y}_1)\\ \mathrm{cov}(\boldsymbol{Y}_1,\boldsymbol{Y}_2) & \mathrm{cov}(\boldsymbol{Y}_2,\boldsymbol{Y}_2) & \cdots & \mathrm{cov}(\boldsymbol{Y}_m,\boldsymbol{Y}_2)\\ \vdots & \vdots & \ddots & \vdots\\ \mathrm{cov}(\boldsymbol{Y}_1,\boldsymbol{Y}_m) & \mathrm{cov}(\boldsymbol{Y}_2,\boldsymbol{Y}_m) & \cdots & \mathrm{cov}(\boldsymbol{Y}_m,\boldsymbol{Y}_m)\end{bmatrix} \tag{4}$$

式中：cov(M, N)表示取括号内变量M与N的协方差。

3)计算协方差矩阵的特征值λ_i以及相对应的单位正交化特征向量$\boldsymbol{e}_i$，并通过下式计算得到各主成分向量$\boldsymbol{F}_i$，$i=1,2,\cdots,m$。

$$\boldsymbol{F}_i=e_{i1}\boldsymbol{F}_1+e_{i2}\boldsymbol{F}_2+\cdots+e_{im}\boldsymbol{F}_m \tag{5}$$

4）将各个特征值由大到小排序，并依次计算各个主成分的贡献率η_i和累计贡献率$\eta_{\Sigma i}$：

$$\eta_i=\lambda_i/\sum_{i=1}^{n}\lambda_i \tag{6}$$

$$\eta_{\Sigma i}=\sum_{j=1}^{i}\eta_j \tag{7}$$

一般来说，当累计方差贡献率达到75%~95%时，就可以反映绝大部分数据中的信息，同时可以有效降低数据的冗余程度[25]。

1.3 Bi-LSTM网络模型

循环神经网络(RNN)结构具有自反馈功能，能够同时保留当前和先前时刻的信息，因此常用于处理和预测时间序列。LSTM是一种特殊的RNN，相比于传统的RNN，其神经元添加了特殊的“门”结构，有效解决了传统RNN在处理长时间序列时出现的梯度消失与梯度爆炸等问题[26]。由于LSTM网

络中的信息是单向流动的，其只能使用某一时间节点之前的信息进行预测。在此基础上，本文选择使用 Bi-LSTM，可以综合考虑当前时间节点前后的信息，进一步提升模型预测精度，同时降低模型过拟合的风险[27-28]。

Bi-LSTM 与 LSTM 内部节点的单元结构相同，图 1 为典型的 LSTM 网络结构图，对于当前 t 时刻的神经元结构，共存在 3 个输入值：上一时刻的神经元细胞状态 $\boldsymbol{c}_{t-1}$，上一时刻的神经元输出 $\boldsymbol{h}_{t-1}$ 和当前时刻的网络输入 $\boldsymbol{x}_t$；此外还有两个输出值，分别是当前时刻的神经元细胞状态 $\boldsymbol{c}_t$ 和当前的网络输出值 $\boldsymbol{h}_t$。每个 LSTM 神经元结构还包括 3 个门结构，遗忘门用来控制上一时刻神经元状态进入当前单元的多少；输入门用来控制当前时刻的网络输入进入单元的多少；输出门用来控制单元状态进入当前单元输出的多少[26]。

LSTM 网络单个神经元内部信息更新过程为：

1）计算遗忘门的值 $\boldsymbol{f}_t$

$$\boldsymbol{f}_t = \sigma(\boldsymbol{W}_{xf}\boldsymbol{x}_t + \boldsymbol{W}_{hf}\boldsymbol{h}_{t-1} + \boldsymbol{b}_f) \tag{8}$$

式中：$\boldsymbol{W}_{xf}$ 与 $\boldsymbol{W}_{hf}$ 均为权重矩阵；$\boldsymbol{b}_f$ 为偏置项；σ(*)为 sigmoid 函数。

2）计算输入门的值 $\boldsymbol{i}_t$

$$\boldsymbol{i}_t = \sigma\left(\boldsymbol{W}_{xi}\boldsymbol{x}_t + \boldsymbol{W}_{hi}\boldsymbol{h}_{t-1} + \boldsymbol{b}_i\right) \tag{9}$$

式中：$\boldsymbol{W}_{xi}$ 与 $\boldsymbol{W}_{hi}$ 为输入门与当前时刻输入 $\boldsymbol{x}_t$ 和上一时刻单元状态 $\boldsymbol{h}_{t-1}$ 之间的权重矩阵；$\boldsymbol{b}_i$ 为输入门的偏置项。

3）计算当前时刻单元的候选状态值 $\tilde{\boldsymbol{c}}_t$

$$\tilde{\boldsymbol{c}}_t = \tanh\left(\boldsymbol{W}_{xc}\boldsymbol{x}_t + \boldsymbol{W}_{hc}\boldsymbol{h}_{t-1} + \boldsymbol{b}_c\right) \tag{10}$$

式中：$\boldsymbol{W}_{xc}$ 与 $\boldsymbol{W}_{hc}$ 为当前单元与当前时刻输入 $\boldsymbol{x}_t$ 和上一时刻单元状态 h_{t-1} 之间的权重矩阵；$\boldsymbol{b}_c$ 为当前单元的偏置项；tanh(•)是双曲正切函数。

4）计算当前时刻的单元状态值 $\boldsymbol{c}_t$

$$\boldsymbol{c}_t = \boldsymbol{f}_t \otimes \boldsymbol{c}_{t-1} + \boldsymbol{i}_t \otimes \tilde{\boldsymbol{c}}_t \tag{11}$$

式中：符号 ⊗ 表示矩阵按元素相乘。

5）计算输出门的值 $\boldsymbol{o}_t$

$$\boldsymbol{o}_t = \sigma\left(\boldsymbol{W}_{xo}\boldsymbol{x}_t + \boldsymbol{W}_{ho}\boldsymbol{h}_{t-1} + \boldsymbol{b}_o\right) \tag{12}$$

式中：$\boldsymbol{W}_{xo}$ 与 $\boldsymbol{W}_{ho}$ 为输出门与当前时刻输入 $\boldsymbol{x}_t$ 和上一时刻单元状态 $\boldsymbol{h}_{t-1}$ 之间的权重矩阵；$\boldsymbol{b}_o$ 为输出门的偏置项。

6）计算当前单元的输出值 $\boldsymbol{h}_t$

$$\boldsymbol{h}_t = \boldsymbol{o}_t \otimes \tanh\left(\boldsymbol{c}_t\right) \tag{13}$$

Bi-LSTM 网络由两个传播方向相反的 LSTM 网络组成，其网络结构见图 2。前向的 LSTM 网络可以学习输入序列的历史数据信息，后向的 LSTM 网络可以学习输入序列的未来数据信息，两者会根据各自的学习结果分别产生输出。网络的最终输出是前向网络和后向网络输出结果的结合。网络在 t 时刻的最终输出结果 $\boldsymbol{y}_t$ 的计算过程如下：

$$\boldsymbol{h}_t^R = f\left(\boldsymbol{w}_1\boldsymbol{x}_t + \boldsymbol{w}_2\boldsymbol{h}_{t-1}^R\right) \tag{14}$$

$$\boldsymbol{h}_t^L = f\left(\boldsymbol{w}_3\boldsymbol{x}_t + \boldsymbol{w}_4\boldsymbol{h}_{t+1}^L\right) \tag{15}$$

$$\boldsymbol{y}_t = g\left(\boldsymbol{w}_5\boldsymbol{h}_t^R + \boldsymbol{w}_6\boldsymbol{h}_t^L\right) \tag{16}$$

式中：$\boldsymbol{h}_t^R$ 和 $\boldsymbol{h}_t^L$ 分别为 t 时刻前向层和后向层的输出结果；$\boldsymbol{w}_1$、$\boldsymbol{w}_3$ 分别为输入层与前向层、后向层之间的权重矩阵；$\boldsymbol{w}_2$ 为上一时刻前向传播单元与当前单元之间的权重矩阵；$\boldsymbol{w}_4$ 下一时刻后向传播单元与当前单元之间的权重矩阵；$\boldsymbol{w}_5$、$\boldsymbol{w}_6$ 分别为前向层、后向层与输出层之间的权重矩阵；f(*)表示神经元内部的计算过程；g(*)表示神经元内部前后向传播结果进行拼接的计算过程。

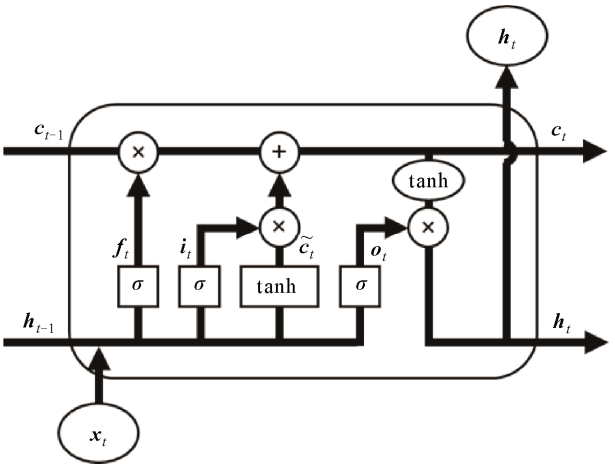


图 1　LSTM 单元结构图

Fig.1　LSTM unit structure diagram

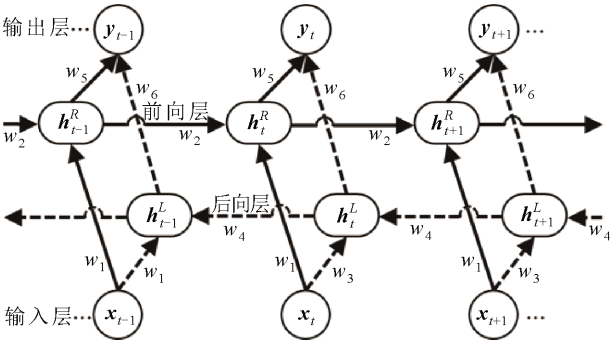


图 2　BiLSTM 网络结构图

Fig.2　BiLSTM network structure diagram

1.4 鲸鱼优化算法

鲸鱼优化算法于 2016 年由澳大利亚人 Mirjalili 提出，是一种较为新颖的群体智能优化算法[29]。该算法模拟座头鲸的气泡网狩猎策略，具有原理简单、参数设置方便、搜索能力强和收敛速度快等优点[30]。本文主要利用该算法对 Bi-LSTM 的模型参数进行优化，以获得最优的参数组合，提高预测模型的精度。

上述算法寻优的具体过程如下[30-31]。

1）包围猎物

座头鲸在捕食时首先会识别猎物的位置，然后通过不断调整自己的位置逐渐包围猎物。在包围过程中，以当前距离猎物目标最近的搜索代理位置为当前的最优个体位置，其他的座头鲸通过更新位置逐步向最优个体位置逼近，从而达到包围目标猎物的目的。

$$\boldsymbol{D}=\left|\boldsymbol{C}\boldsymbol{X}^{*}(t_{\text{iter}})-\boldsymbol{X}(t_{\text{iter}})\right| \tag{17}$$

$$\boldsymbol{X}(t_{\text{iter}}+1)=\boldsymbol{X}^{*}(t_{\text{iter}})-\boldsymbol{A}\boldsymbol{D} \tag{18}$$

式中：$\boldsymbol{D}$ 为当前个体位置与最优个体位置之间的距离；$\boldsymbol{X}^{*}(t_{\text{iter}})$ 为最优个体的位置向量；$\boldsymbol{X}(t_{\text{iter}})$ 为当前个体的位置向量；t_{iter} 为当前的迭代次数；$\boldsymbol{A}$ 和 $\boldsymbol{C}$ 均为参数向量，两者的表达式分别为：

$$\boldsymbol{A}=a\cdot\left(2\boldsymbol{r}_1-1\right) \tag{19}$$

$$\boldsymbol{C}=2\boldsymbol{r}_2 \tag{20}$$

式中：$\boldsymbol{r}_1$ 与 $\boldsymbol{r}_2$ 均为 0~1 之间的随机向量；a 随迭代次数的增加从 2 线性减小至 0，表达式如下：

$$a=2\cdot\left(1-t_{\text{iter}}/t_{\text{max_iter}}\right) \tag{21}$$

式中：$t_{\text{max_iter}}$ 为最大迭代次数。

2）螺旋泡泡式捕猎

座头鲸在围捕猎物时以螺旋运动的方式前进，与此同时还要逐步缩小包围圈。假设鲸鱼在进行螺旋泡泡式捕猎过程中，分别有 P_i 的概率选择收缩包围和 $1-P_i$ 的概率选择螺旋前进，这一同步选择的数学模型表达式如下：

$$\boldsymbol{X}(t_{\text{iter}}+1)=\begin{cases}\boldsymbol{X}^{*}(t_{\text{iter}})-\boldsymbol{A}\boldsymbol{D}, & P<P_i\\ \boldsymbol{X}^{*}(t_{\text{iter}})+\boldsymbol{D}'\mathrm{e}^{bl}\cos(2\pi l), & P\geq P_i\end{cases} \tag{22}$$

式中：P 为 0~1 之间的随机数；$l\subseteq(-1,1)$；$\boldsymbol{D}'=\left|\boldsymbol{X}(t_{\text{iter}})-\boldsymbol{X}^{*}(t_{\text{iter}})\right|$ 为当前每个个体与最优个体之间的距离；b 为常数，用来描述螺旋形状；P_i 一般取 0.5。

由式(21)可知，随着迭代次数的增加，a 会线性减小，与此同时 $\boldsymbol{A}$ 中各个元素值在[–a, a]之间波动；当 $a\leq1$ 时，鲸鱼个体的下一个位置是鲸鱼个体当前位置与猎物之间的任意位置。算法设定当 $\boldsymbol{A}$ 中的各个元素值的绝对值小于 1 时，鲸鱼会向猎物发动攻击。

3）搜索猎物

在搜索猎物时，会根据 $\boldsymbol{A}$ 中的各个元素值的绝对值决定鲸鱼个体寻找猎物搜索机制。当 $\boldsymbol{A}$ 中的各个元素的绝对值小于 1 时，会根据最优鲸鱼个体位置进行位置更新，此时执行局部搜索。当 $\boldsymbol{A}$ 中的各个元素值的绝对值大于 1 时，会迫使鲸鱼个体远离当前的最优个体位置，根据随机选中的鲸鱼位置进行位置更新，此时执行全局搜索。$\boldsymbol{A}$ 中的各个元素值的绝对值大于 1 时执行全局搜索的数学模型为：

$$\boldsymbol{D}=\left|\boldsymbol{C}\boldsymbol{X}_{\text{rand}}(t_{\text{iter}})-\boldsymbol{X}(t_{\text{iter}})\right| \tag{23}$$

$$\boldsymbol{X}(t_{\text{iter}}+1)=\boldsymbol{X}_{\text{rand}}(t_{\text{iter}})-\boldsymbol{A}\boldsymbol{D} \tag{24}$$

式中：$\boldsymbol{X}_{\text{rand}}$ 为随机选中的鲸鱼个体的位置向量。

本文采用 WOA 算法优化 Bi-LSTM 中的隐含层神经元个数、滑动时间窗口宽度以及初始学习率的大小，从而获得最优的参数组合。

2 断路器剩余机械寿命预测模型

2.1 预测模型框架

本文所提出的 PCA-WOA-BiLSTM 组合预测模型流程图如图 3 所示。模型的预测流程可分为筛选关键退化特征量、PCA 法生成健康指数、建立 WOA-BiLSTM 预测模型、退化趋势预测及剩余寿命评估 4 个部分，整体的技术路线如图 3 所示。

2.2 预测实施流程

基于以上模型框架，预测模型的具体实施步骤如下：

1）通过信息采集系统获取断路器的机械特征参数，包括触头超行程、触头开距、分闸时间、分闸三相不同期、合闸时间、合闸三相不同期、分闸速度、合闸速度、分闸反弹时间、合闸反弹时间和分闸反弹过冲共 11 种原始监测数据。

2）针对采集得到的原始监测数据，首先根据各种数据的失效阈值判定断路器机械操动机构的寿命终点。选择从试验开始到寿命终点之间的监测数据作为断路器全生命周期的机械特征参数。

3）利用 Pearson 相关系数法根据表 1 对原始监测数据进行筛选，保留与断路器累积开断次数之间呈显著强相关的特征参数作为断路器机械操动机构

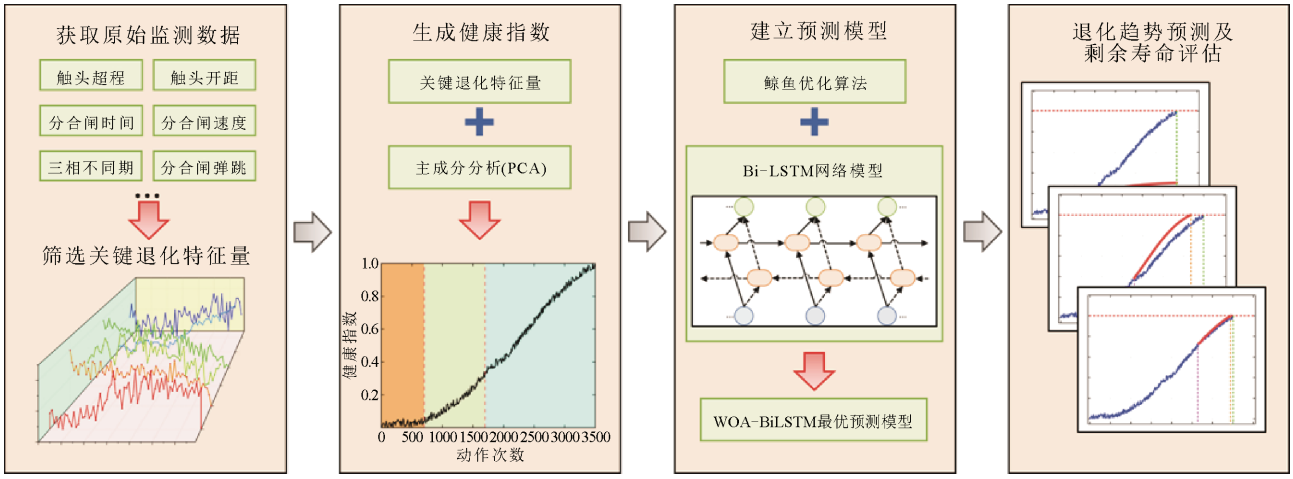


图 3　剩余寿命预测模型框架

Fig.3　Remaining useful life prediction model framework

的退化特征量，并对这些特征量进行最大最小值归一化处理，计算方法如下：

$$x_t' = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}} \tag{25}$$

式中：x_t' 为归一化处理后 t 时刻对应的值；x_t 为原序列中 t 时刻对应的值；$x_{\max}$ 与 $x_{\min}$ 分别为序列中的最大值与最小值。

4）使用 PCA 法对归一化后的有效特征参量进行特征融合，将累积方差贡献率作为指标选取主成分，作为生成断路器机械操动机构的健康指数，再次进行最大最小值归一化处理，将健康指数映射到 0~1 之间。为降低传感器测量误差可能带给健康指数的随机性，引入指数加权平均值算法对健康指数进行处理，在消除局部随机性的同时保持了其生命周期健康状态固有的变化趋势。

5）采用图 4 所示方法构建 WOA- BiLSTM 预测网络，将平滑处理后得到的健康指数作为预测网络的原始输入。根据时间窗口宽度 w 对原始数据进行处理，一般认为当前时刻的值可以由这一时刻之前的 w 个时刻的值分析得到，据此原理生成预测模型所需要的时间序列。如图 5 所示为 w=4 时的时间序列样本生成示意图，图中 S1—S6 分别为初始时间序列当中的元素，依次从初始序列当中取出 5 个元素形成新的序列，新序列的当中的前 4 个元素为输入值，第 5 个元素为输出值。利用 WOA 对 Bi-LSTM 网络中的关键超参数(隐含层神经元个数 m、时间窗口宽度 w 和初始学习率 l)进行优化，获得最优的参数组合，进而构建最优的预测模型。

6）利用步骤 5）搭建的最优预测模型向前进行

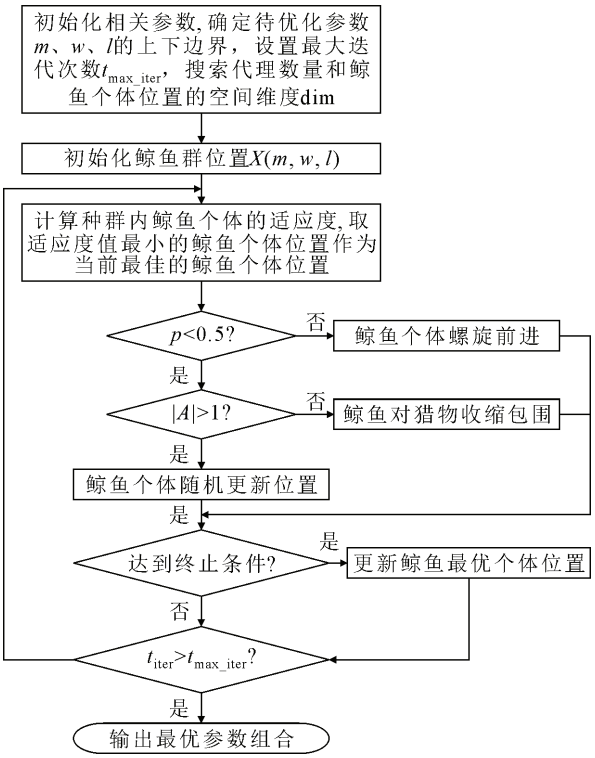


图 4　WOA 优化 Bi-LSTM 模型参数流程图

Fig.4　Flow chart of Bi-LSTM model parameters optimized by WOA

多步预测，将预测得到的结果纳入新的输入样本中进行迭代预测。

7）判断当前时间步的预测结果是否达到寿命阈值(健康指数为 1)。如果是，则可以根据当前时刻的预测步数和信息采集步长计算断路器机械操动机构的剩余寿命；如果不是，则重复步骤 5）。

2.3　模型评价指标

为评估模型的预测精度，本文选取平均绝对误

差 E_{MAE} 和均方根误差 E_{RMSE} 作为模型评价指标，计算式如下：

$$E_{MAE}=\frac{1}{n}\sum_{i=1}^{n}\frac{\left|y_i^p-y_i^r\right|}{y_i^r} \tag{26}$$

$$E_{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i^p-y_i^r)^2} \tag{27}$$

式中：n 为样本容量；y_i^p 为第 i 个时间步的健康指数预测值；y_i^r 为第 i 个时间步的健康指数实际值。

此外，本研究选用预测模型的 E_{RMSE} 作为 WOA 寻优过程中最优个体的适应度函数。

3 实例验证

3.1 试验平台与数据获取

本文使用的断路器机械特性测试系统架构如图 6 所示。被测试品选用某生产厂商制造的 VD4M1212-25 型真空断路器。试验平台选择使用 GKC-Y 型断路器机械特性测试仪，可测量的位移量程为 50.0 mm，分辨率为 0.1 mm；可测量的电流量程为 20.00 A，分辨率为 0.01 A；可测量的时间量程为 16 000.0 ms，分辨率为 0.1 ms；可测量的速度量程为 20.00 m/s，分辨率为 0.01 m/s。位移传感器选用 TS-0050 型直线位移传感器，量程为 50.00 mm，分辨率为 0.01 mm，用于采集分合闸时的动触头位移曲线。电流传感器选用 CHB-50SF 型霍尔电流传感器，可测量量程为–80~80 A，主要用于采集分闸线圈电流、合闸线圈电流、储能电机电流和断路器的 ABC 三相导通电流。PLC 控制器是测试平台的控制核心，用于按照预设程序对断路器发出分、合闸及储能指令，连续进行 10 次分断后，会自动将控制回路停止，同时在控制面板上发出进行机械测试的指令。控制回路由接触器、继电器组成，用于执行 PLC 发出的控制指令，从而对断路器进行分合闸操作。

进行测试时，由操作人员在控制面板上发出指令，经由 PLC 控制器和控制回路对断路器发出控制信号，断路器接收到信号后会连续进行 10 次开断动作，待动作完成之后将状态反馈至控制面板，由操作人员决定是否进行机械特性测试，同时通过接触器的组合切换，控制回路会将老化测试回路切换为机械特性测试回路。进行断路器机械特性测试时，主要由机械特性测试仪执行工作，采集断路器在分合闸时的位移行程曲线和三相导通电流(各曲线之

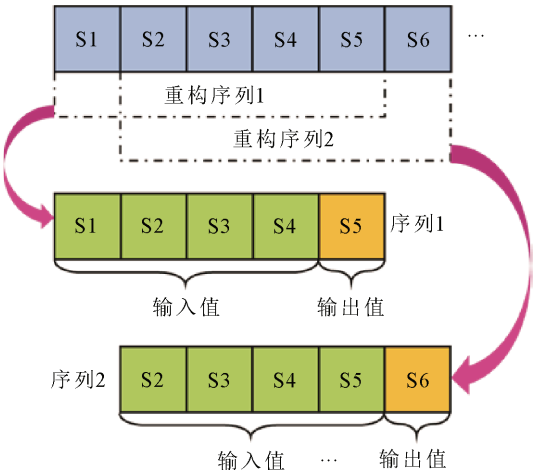


图 5 时间序列样本生成示意图(w=4)

Fig.5 Schematic diagram of time series sample generation (w=4)

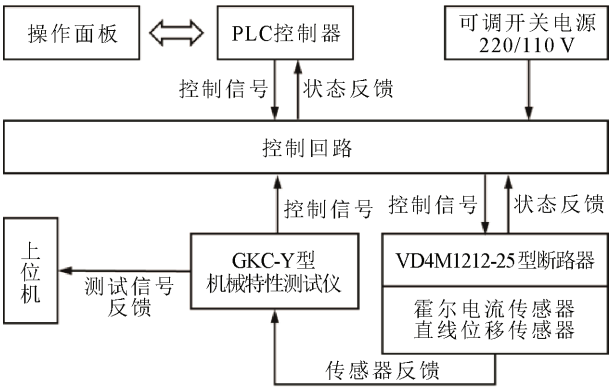


图 6 断路器机械特性测试系统架构

Fig.6 Structure of circuit breaker mechanical characteristic test system

间的对应关系详见文献[32])，进而可由机械特性测试仪直接计算断路器的超程、开距、分闸时间、合闸时间、分闸速度、合闸速度、弹跳等指标。

各指标的定义与计算方法[32-33]如下：

(1) 超程：合闸操作时，从所有相触头都接触开始到合闸稳定位置为止的触头位移；

(2) 开距：断路器处在分闸位置时，动静触头之间的距离；

(3) 平均合闸速度：触头在合闸全行程中最后 6 mm 与完成该段距离所用时间的比值；

(4) 平均分闸速度：触头在分闸全行程中最后 6 mm 与完成该段距离所用时间的比值；

(5) 合闸时间：从接到合闸指令瞬间起到所有极触头都接触瞬间为止的时间间隔；

(6) 合闸三相不同期：从首极合开始到所有极

触头都合为止的时间之差；

(7) 分闸时间：从接到分闸指令瞬间起到所有极触头都分离瞬间为止的时间间隔；

(8) 分闸三相不同期：从首极开始分到所有极触头都分为止的时间之差；

(9) 合闸弹跳时间：在合闸过程中从动静触头接触开始，到经过反复弹跳后最终达到稳定的这段时间；

(10) 分闸反弹(幅值)：分闸过程中，由于缓冲器的作用，动触头存在惯性，还会运动到最高点，而后返回到平衡点，形成一个振荡过程，最大振幅为分闸反弹(幅值)；

(11) 分闸过冲：在分闸操作过程中，从动触头达到分闸位置开始，动触头继续向远离静触头方向运动的最大距离。

制造厂商对 VD4M1212-25 型号断路器各机械特征参数的正常工作范围进行了规定。正常条件下触头分闸三相不同期≤2 ms，平均合闸速度为 0.8~1.1 m/s，分闸时间为 33~45 ms，当上述特征参数超过这一工作范围时，认为断路器失效。图 7 分别展示了试验过程中分闸时间、分闸三相不同期和平均合闸速度随开断次数增加变化的曲线，当开断次数达到 3500 左右时，断路器的平均合闸速度、分闸时间、分闸三相不同期均达到其失效阈值，此时认为断路器操动机构达到其寿命终点。因此，本文得到的断路器操动机构的全寿命周期为 0~3500 次，每 10 次采集一次数据，共得到 351 组不同开断次数的机械特征数据。

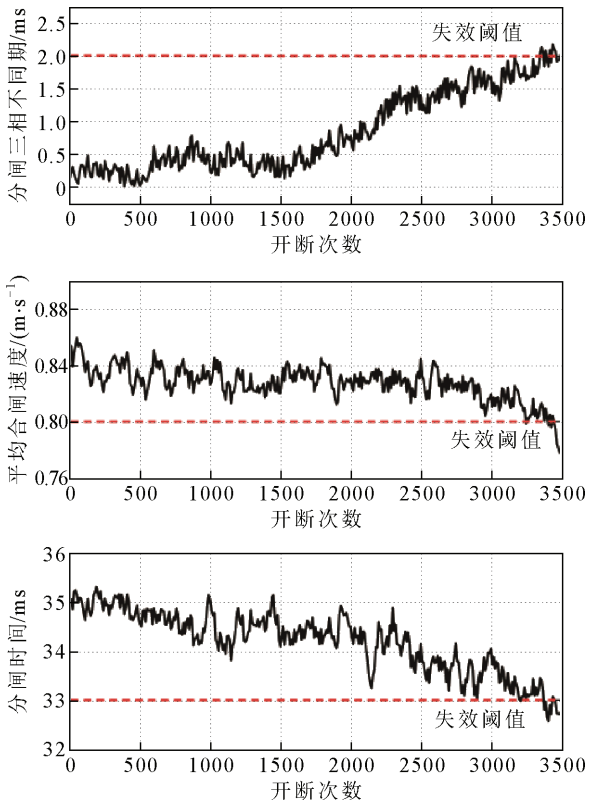


图 7 典型机械参量随开断次数变化曲线

Fig.7 Variation trend of typical mechanical parameters with breaking times

3.2 关键特征退化量选取

所获得的断路器全寿命周期机械特征数据中存在很多冗余信息，这些信息对于后续生成断路器健康指数会造成不良影响，不能正确反映断路器机械性能的正常退化趋势，直接影响断路器剩余寿命的预测精度。因此，本文选用 Pearson 相关系数法对原始监测数据中的有效信息进行筛选，计算各特征量与断路器开断次数之间的相关系数，选择与断路器开断次数之间呈现显著强相关的机械特征量作为表征断路器机械性能退化的关键特征量。

相关性的计算结果如图 8 所示，断路器触头超程、开距、平均合闸速度、合闸时间、分闸时间、分闸三相不同期、分闸反弹与断路器累积开断次数之间的相关性系数绝对值均大于 0.6，说明上述变量与断路器累积开断次数之间呈现较强的相关性。为

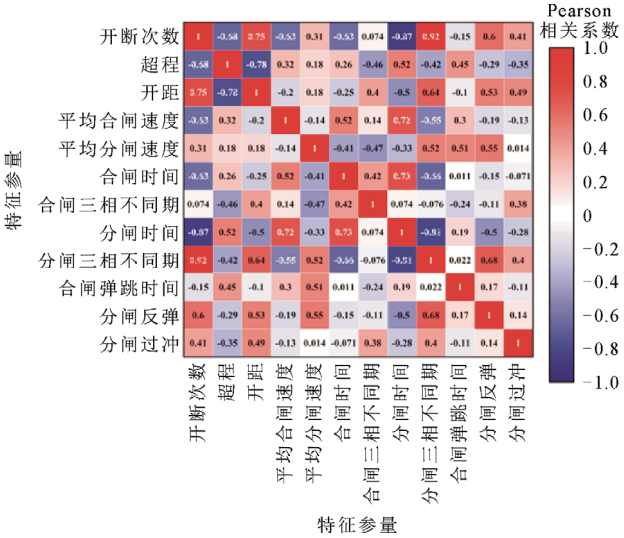


图 8 Pearson 相关性系数热图

Fig.8 Pearson correlation coefficient heat map

进一步检验上述计算得到的相关性关系是否具有统计学意义，利用式(2)构造 T 变量，查表得到相应的 p 值均小于 0.01，表明上述变量与断路器累积开断次数之间显著强相关。图 8 还展示了各机械变量之

间的相关性系数，触头超程与开距之间的相关系数为–0.78，且显著性水平 p<0.01，表明两变量之间呈显著强相关。另外，由于触头超程相较于开距受断路器累积开断次数的影响较弱，所以本文舍弃触头超程数据以进一步减少数据冗余。综上所述，最终选择触头开距、平均合闸速度、合闸时间、分闸时间、分闸三相不同期和分闸反弹 6 个特征变量作为关键特征退化量继续进行后续研究。

3.3 数据融合生成健康指数

本节使用 PCA 法对筛选出的关键特征退化量继续进行数据降维和特征融合，表 2 展示了各主成分的特征值、方差贡献率及累计贡献率。第一主成分 Z_1 的贡献率为 85.9501%，第二主成分 Z_2 的贡献率为 9.2856%，此时前两个主成分的累计贡献率为 95.2357%。根据 1.2 节选取主成分的标准可以认为主成分 Z_1 和 Z_2 已经基本包含 6 个关键特征退化量中的主要信息。如图 9 所示，对比主成分 Z_1 和 Z_2 随开断次数增加的变化趋势，第一主成分 Z_1 随开断次数的增加单调增加，而第二主成分 Z_2 随着开断次数的增加出现“减小–增加–减小增加”的多重变化趋势。随着开断次数的增加，断路器的操动机构会发生不可逆的磨损劣化，第一主成分 Z_1 的变化趋势具有明显的时间相关性和单调性，能够很好地表征断路器操动机构的性能退化过程。因此选取第一主成分 Z_1 作为融合指标，并将最大最小值归一化之后的 Z_1 作为最终的健康指数。

健康指数的数学表达式如下：

$$H(i)=\mathrm{MAXMIN}(-0.3643h_1(i)+0.3743h_2(i)+0.3871h_3(i)+0.4579h_4(i)-0.4636h_5(i)-0.3910h_6(i)) \quad (28)$$

式中：$H(i)$为第 i 个时间步的健康指数；$h_1(i)$—$h_6(i)$分别对应第 i 个时间步的 6 个关键特征退化量；MAXMIN(•) 表示最大最小值归一化处理，详见式(25)。

图 10(a)、(b)分别展示了断路器操动机构全寿命周期的健康指数及其变化率情况。由图 10 可知，开断次数 0~700 这一区段内的健康指数及其变化率均近似为零(较为平稳)，可以认为这一阶段的断路器性能未发生退化，即处于断路器设备状态处于健康期。在开断次数达到 700~1700 时，健康指数逐渐增大，这是由断路器内部各机械零部件之间磨损导致的正常现象。在这一时期内，断路器健康指数的变化率同样具有逐渐增大的趋势，表明断路器机械性能的退化速率逐渐加快，认为断路器此时处于退化初期。在动作次数达 1700 之后，断路器进入稳定退化期，此时健康指数的变化速率趋于稳定，表明断路器性能以相对稳定的速率发生劣化，直至到达其寿命终点。在断路器到达寿命终点时健康指数为 1，因此在后续的寿命预测中也将 $H=1$ 作为判断断路器是否到达寿命终点的依据。

表 2 PCA 分析结果

Table 2 PCA analysis result

主成分变量	特征值	方差贡献率/%	累积贡献率/%
Z_1	4.4370	85.9501	85.9501
Z_2	0.6771	9.2856	95.2357
Z_3	0.6290	2.2635	97.4992
Z_4	0.1358	1.4830	98.9822
Z_5	0.0829	0.6363	99.6185
Z_6	0.0382	0.3815	100

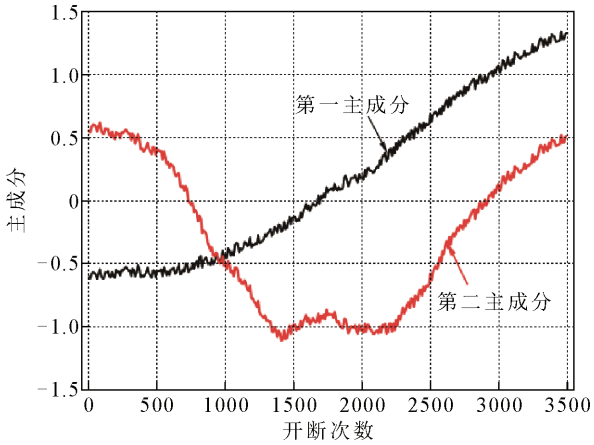


图 9 主成分 Z_1 与 Z_2 对比图

Fig.9 Comparison of principal component Z_1 and Z_2

3.4 断路器操动机构剩余寿命预测

本文建立的 Bi-LSTM 预测网络模型包括输入层、隐含层、全连接层、回归层和输出层。为防止过拟合现象发生，在隐含层中添加随机失活层对其中的神经元进行随机失活处理，本文将随机失活的概率值设置为 0.2。迭代次数设置为 200，梯度阈值设置为 1，隐含层的神经元个数 m 和初始学习率 l 均由通过 WOA 寻优获得。3.3 节中获得的健康指数共 351 个，基于 WOA 寻优通过滑动时间窗的方法得到最佳时间窗口宽度 w，对健康指数序列进行重构。表 3 展示了隐含层神经元个数 m、初始学习率 l 以及滑动时间窗口 w 在寻优过程中的上下边界，并选用重构后序列中前 80%数据作为训练集，后 20%数据作为测试集时得到的最优参数组合。

WOA 寻优过程的最优个体适应度数值变化过程如图 11 所示，由图 11 收敛曲线可知，鲸鱼优化

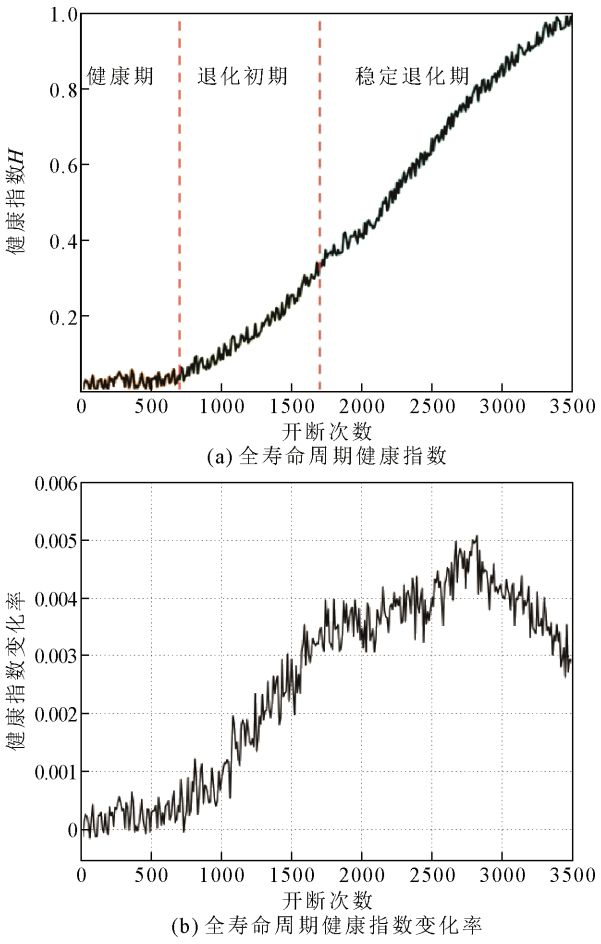


图 10　断路器全寿命周期健康指数变化

Fig.10　Change of health index in the whole life cycle of circuit breaker

算法在第 30 次迭代时适应度值达到最低，为 0.023。此时所搜寻到的超参数组合为最优参数组合.在之后的 170 次迭代中，适应度值与最优参数组合均未再发生变化。

为验证 WOA-BiLSTM 预测模型的有效性，选用 LSTM、反向传播神经网络(BPNN)及支持向量回归预测(SVR)等传统回归预测模型分别对断路器机械操动机构的退化趋势进行单步预测。

各预测模型均采用相同的训练集与测试集，均采用多次试验或网格搜索的方法确定各预测模型的最优超参数组合。LSTM 的隐含层神经元个数为 64，初始学习率设置为 0.001，激活函数使用迭代次数为 200；BP 神经网络的隐含层神经元个数设置为 12，初始学习率设置为 0.001，激活函数使用 Relu 函数，迭代次数为 200；SVR 模型选择径向基核函数，惩罚因子 C=4，核参数 $\sigma=0.0221$ 。各模型的预测结果如图 12 所示，预测误差详见表 4。WOA-BiLSTM

表 3　优化参数寻优范围及最终结果

Table 3　Parameter optimization range and final results

优化参数	寻优范围	最优值
隐含层神经元个数 m	[2,256]	128
初始学习率 l	[0.001,0.05]	0.005
滑动时间窗口 w	[1,30]	12

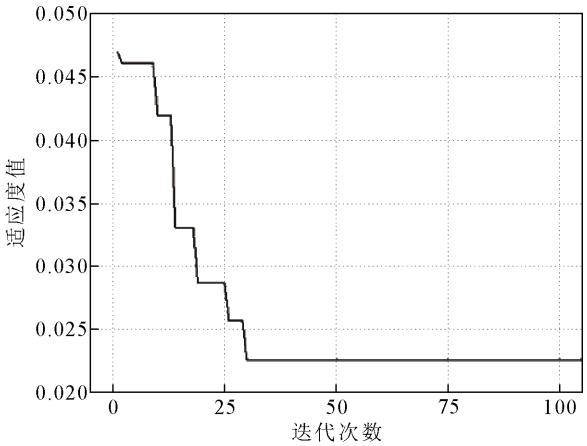


图 11　WOA 寻优过程中适应度变化情况

Fig.11　Fitness changes in WOA optimization process

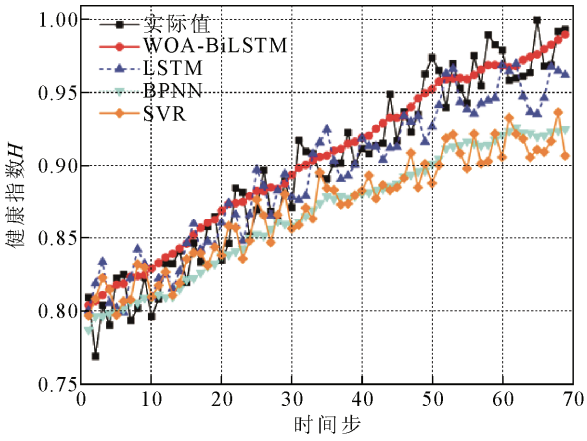


图 12　不同预测模型单步预测结果对比

Fig.12　Comparison of single step prediction results of different prediction models

表 4　不同预测模型单步预测结果对比

Table 4　Comparison of single step prediction results of different prediction models

预测模型	E_{RMSE}	E_{MAE}
WOA-BiLSTM	0.0226	0.0194
LSTM	0.0298	0.0263
BPNN	0.0439	0.0392
SVR	0.0685	0.0528

的 E_{RMSE} 为 0.0226，E_{MAE} 为 0.0194，相比于本文选用的其他预测模型，表现最好的 LSTM 模型，其

E_{RMSE} 与 E_{MAE} 分别下降 24.16%与 26.24%。因此 WOA-BiLSTM 对于断路器机械操动机构退化趋势的预测效果最好。

对于断路器机械剩余寿命的预测，根据前文所述方法首先利用已有数据对断路器健康指数的退化趋势进行迭代预测，当某次迭代的健康指数超出预设阈值时，则认为断路器操动机构到达寿命终点，此时根据预测步数与信息采集步长即可计算断路器剩余使用寿命。

图 13(a)、(b)、(c)分别显示了使用 PCA- WOA-BiLSTM 预测模型以 1100 次、1800 次和 2660 次为预测起点时对断路器进行机械操动机构剩余寿命预测结果。随着提供原始数据样本量的增加，预测模型的学习效果变好，获得了更理想的预测结果。对比不同预测时刻机械性能的预测退化曲线与实际退化曲线，以动作次数为 1100 为预测起点进行预测时，预测的 RUL 存在较大误差。因为在断路器较早退化阶段进行预测时，训练数据样本量较少，模型对于断路器退化趋势无法进行整体学习，无法对断路器剩余寿命做出有效评估。随着预测起始时刻进入断路器生命周期的稳定退化期，预测模型开始展示出良好的性能跟踪和 RUL 预测效果。当预测起点取 1800 次时，预测得到的断路器操动机构剩余使用寿命为 1430 次，实际的剩余使用寿命为 1700 次，预测的相对误差为 15.88%；当预测起点进一步推移至 2660 次时，预测得到的断路器操动机构剩余使用寿命为 810 次，实际的剩余使用寿命为 840 次，断路器剩余寿命的预测误差进一步减少至 3.57%。综合以上，本文提出的预测方法能够对断路器剩余使用寿命做出有效评估，具有一定的实际工程应用意义。

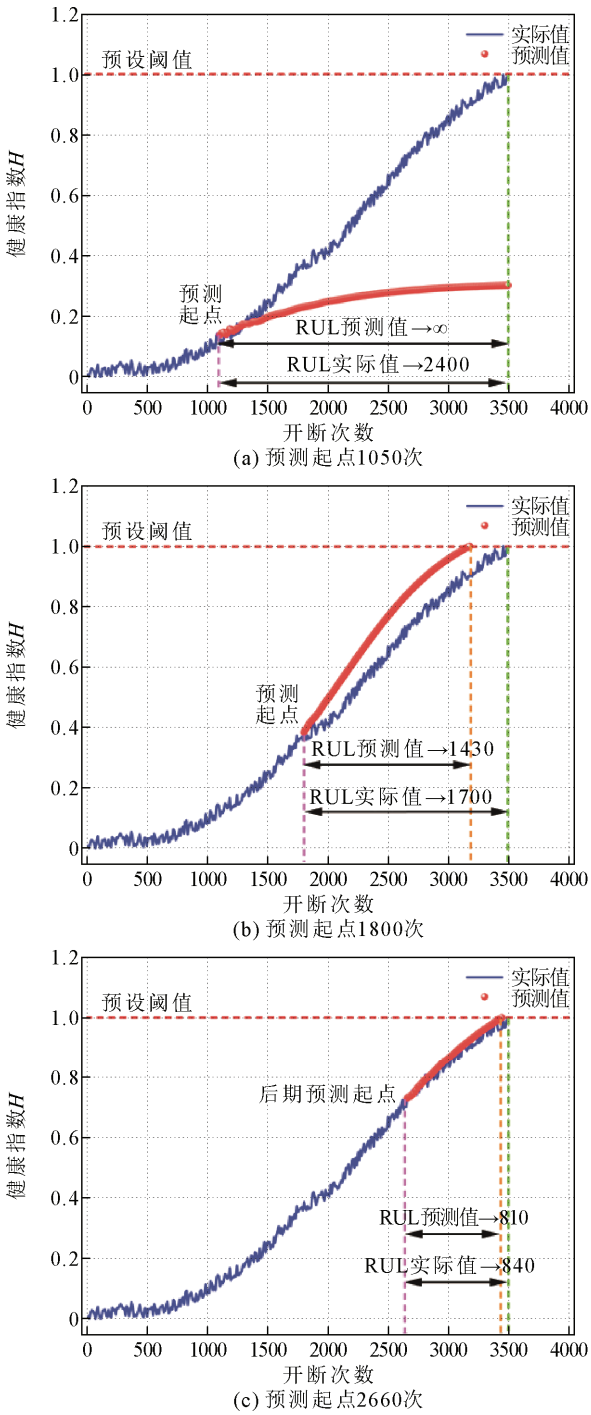


图 13 不同时期断路器操动机构剩余寿命预测结果

Fig.13 Prediction results of remaining life of circuit breaker operating mechanism in different periods

4 结论

1）针对单一变量输入无法全部反映断路器运行状态，多变量输入导致数据冗余的问题，本文利用皮尔逊相关系数算法筛选关键退化特征量，并基于主成分分析法进行数据融合，生成了能够全面反映断路器运行状态的健康指数。

2）利用 WOA 对 Bi-LSTM 网络模型的时间窗口宽度 w、隐含层神经元个数 m 和模型初始学习率 l 进行优化，使用最优超参数组合预测进一步提升了模型的预测精度。

3）实例验证表明，本文所提出的预测方法能够有效预测断路器操动机构的退化趋势，预测精度可达 96.43%，相比其他传统回归预测模型更高，显示出其在断路器退化趋势预测上的有效性和实用性，对制定断路器运维策略具有一定的指导意义。

参考文献 References

[1] 钟建英，陈 刚，谭盛武，等. 高压开关设备关键技术及发展趋势

[J]. 高电压技术，2021，47(8)：2769-2782.
ZHONG Jianying, CHEN Gang, TAN Shengwu, et al. Key technology and development trend of high-voltage switchgear[J]. High Voltage Engineering, 2021, 47(8): 2769-2782.

[2] 卢　扬，李永丽. 基于实时状态评估与剩余寿命计算的高压断路器预测性维护策略[J]. 高电压技术，2022，48(7)：2716-2726.
LU Yang, LI Yongli. Predictive maintenance policy for high-voltage circuit breakers based on real-time state estimation and remanent useful life calculation[J]. High Voltage Engineering, 2022, 48(7): 2716-2726.

[3] 刘帼巾，李　想，王　泽，等. 基于 Wiener 过程电子式漏电断路器的剩余寿命预测[J]. 电工技术学报，2022，37(2)：528-536.
LIU Guojin, LI Xiang, WANG Ze, et al. Remaining life prediction of electronic residual current circuit breaker based on wiener process[J]. Transactions of China Electrotechnical Society, 2022, 37(2): 528-536.

[4] 孙曙光，张　伟，王景芹，等. 基于动作过程振动检测的低压断路器机械寿命预测[J]. 仪器仪表学报，2020，41(12)：146-157.
SUN Shuguang, ZHANG Wei, WANG Jingqin, et al. Mechanical life prediction of low-voltage circuit breaker based on vibration detection during operation[J]. Chinese Journal of Scientific Instrument, 2020, 41(12): 146-157.

[5] CHEN W J, ZENG R, HE J J, et al. Development and prospect of direct-current circuit breaker in China[J]. High Voltage, 2021, 6(1): 1-15.

[6] 李　奎，李晓倍，郑淑梅，等. 基于 BP 神经网络的交流接触器剩余电寿命预测[J]. 电工技术学报，2017，32(15)：120-127.
LI Kui, LI Xiaobei, ZHENG Shumei, et al. Residual electrical life prediction for AC contactor based on BP neural network[J]. Transactions of China Electrotechnical Society, 2017, 32(15): 120-127.

[7] 孙玉伟，罗林根，陈敬德，等. 含噪背景下基于盲源分离与 NSVDD 的断路器机械故障诊断方法[J]. 高电压技术，2022，48(3)：1104-1112.
SUN Yuwei, LUO Lingen, CHEN Jingde, et al. Mechanical fault diagnosis method of circuit breaker based on blind source separation and NSVDD under noisy background[J]. High Voltage Engineering, 2022, 48(3): 1104-1112.

[8] 刘会兰，许文杰，赵书涛，等. 基于能量轨迹熵的高压断路器操动机构状态特征提取方法[J]. 高电压技术，2022，48(8)：2945-2951.
LIU Huilan, XU Wenjie, ZHAO Shutao, et al. Feature extraction method of operating mechanism state of high voltage circuit breaker based on energy trajectory entropy[J]. High Voltage Engineering, 2022, 48(8): 2945-2951.

[9] 邵　阳，武建文，马速良，等. 用于高压断路器机械故障诊断的 AM-ReliefF 特征选择下集成 SVM 方法[J]. 中国电机工程学报，2021，41(8)：2890-2900.
SHAO Yang, WU Jianwen, MA Suliang, et al. Integrated SVM method with AM-ReliefF feature selection for mechanical fault diagnosis of high voltage circuit breakers[J]. Proceedings of the CSEE, 2021, 41(8): 2890-2900.

[10] 曹宇鹏，罗　林，王　乔，等. 基于卷积深度网络的高压真空断路器机械故障诊断方法[J]. 电力系统保护与控制，2021，49(3)：39-47.
CAO Yupeng, LUO Lin, WANG Qiao, et al. Fault diagnosis of high-voltage vacuum circuit breaker with a convolutional deep network[J]. Power System Protection and Control, 2021, 49(3): 39-47.

[11] 赵成晨，李　奎，胡博凯，等. 变应力条件下低压断路器剩余电寿命预测[J]. 中国电机工程学报，2022，42(21)：8004-8015.
ZHAO Chengchen, LI Kui, HU Bokai, et al. Residual electrical life prediction of low-voltage circuit breakers under varied stress[J]. Proceedings of the CSEE, 2022, 42(21): 8004-8015.

[12] 何志鹏，赵　虎. 微型断路器电寿命评估[J]. 电工技术学报，2022，37(4)：1031-1040.
HE Zhipeng, ZHAO Hu. Electrical lifespan evaluation of miniature circuit breakers[J]. Transactions of China Electrotechnical Society, 2022, 37(4): 1031-1040.

[13] 孙曙光，邵　旭，王景芹，等. 基于振电信号分析与二元维纳的断路器附件机械寿命预测[J/OL]. 高电压技术，2022：1-11. https://doi.org/10.13336/j. 1003-6520. hve. 20221244.
SUN Shuguang, SHAO Xu, WANG Jingqin, et al. Remaining mechanical useful life prediction of circuit breaker accessory based on joint analysis of vibro-electrical signals and binary wiener[J/OL]. High Voltage Engineering, 2022: 1-11. https://doi.org/10.13336/j.1003-6520.hve.20221244.

[14] 申彦斌，张小丽，夏　勇，等. Bi-LSTM 神经网络用于轴承剩余使用寿命预测研究[J]. 振动工程学报，2021，34(2)：411-420.
SHEN Yanbin, ZHANG Xiaoli, XIA Yong, et al. Bi-LSTM neural network for remaining useful life prediction of bearing[J]. Journal of Vibration Engineering, 2021, 34(2): 411-420.

[15] 何　彦，凌俊杰，王禹林，等. 基于长短时记忆卷积神经网络的刀具磨损在线监测模型[J]. 中国机械工程，2020，31(16)：1959-1967.
HE Yan, LING Junjie, WANG Yulin, et al. In-process tool wear monitoring model based on LSTM-CNN[J]. China Mechanical Engineering, 2020, 31(16): 1959-1967.

[16] 车畅畅，王华伟，倪晓梅，等. 基于 1D-CNN 和 Bi-LSTM 的航空发动机剩余寿命预测[J]. 机械工程学报，2021，57(14)：304-312.
CHE Changchang, WANG Huawei, NI Xiaomei, et al. Residual life prediction of aeroengine based on 1D-CNN and Bi-LSTM[J]. Journal of Mechanical Engineering, 2021, 57(14): 304-312.

[17] 高德欣，刘　欣，杨　清. 基于卷积神经网络与双向长短时融合的锂离子电池剩余使用寿命预测[J]. 信息与控制，2022，51(3)：318-329，360.
GAO Dexin, LIU Xin, YANG Qing. Remaining useful life prediction of lithium-ion battery based on CNN and BiLSTM fusion[J]. Information and Control, 2022, 51(3): 318-329, 360.

[18] 裴　洪，胡昌华，司小胜，等. 基于机器学习的设备剩余寿命预测方法综述[J]. 机械工程学报，2019，55(8)：1-13.
PEI Hong, HU Changhua, SI Xiaosheng, et al. Review of machine learning based remaining useful life prediction methods for equipment[J]. Journal of Mechanical Engineering, 2019, 55(8): 1-13.

[19] 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.

[20] 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.

[21] 张志劲，张　翼，蒋兴良，等. 自然环境不同年限复合绝缘子硅橡胶材料老化特性表征方法研究[J]. 电工技术学报，2020，35(6)：1368-1376.
ZHANG Zhijin, ZHANG Yi, JIANG Xingliang, et al. Study on aging characterization methods of composite insulators aging in natural environment for different years[J]. Transactions of China Electrotechnical Society, 2020, 35(6): 1368-1376.

[22] 贾俊平. 统计学基础[M]. 北京：中国人民大学出版社，2014.
JIA Junping. Fundamental statistics[M]. Beijing, China: China Renmin University Press, 2014.

[23] 邵辰彤，王景霖，徐　智，等. 基于 PCA-LSTM 的轴承退化趋势预测[J]. 测控技术，2021，40(11)：138-143.
SHAO Chentong, WANG Jinglin, XU Zhi, et al. Prediction of bearing degradation trend based on PCA-LSTM[J]. Measurement & Control Technology, 2021, 40(11): 138-143.

[24] 王依宁，解　大，王西田，等. 基于 PCA-LSTM 模型的风电机网相互作用预测[J]. 中国电机工程学报，2019，39(14)：4070-4080.
WANG Yining, XIE Da, WANG Xitian, et al. Prediction of interaction between grid and wind farms based on PCA-LSTM model[J]. Proceedings of the CSEE, 2019, 39(14): 4070-4080.

[25] 李泽文，胡　让，刘　湘，等. 基于 PCA-DBILSTM 的多因素短期负荷预测模型[J]. 电力系统及其自动化学报，2020，32(12)：32-39.
LI Zewen, HU Rang, LIU Xiang, et al. Multi-factor short-term load prediction model based on PCA-DBILSTM[J]. Proceedings of the CSU-EPSA, 2020, 32(12): 32-39.

[26] 朱乔木，李弘毅，王子琪，等. 基于长短期记忆网络的风电场发电功率超短期预测[J]. 电网技术，2017，41(12)：3797-3802.
ZHU Qiaomu, LI Hongyi, WANG Ziqi, et al. Short-term wind power forecasting based on LSTM[J]. Power System Technology, 2017, 41(12): 3797-3802.

[27] 李玉志，刘晓亮，邢方方，等. 基于 Bi-LSTM 和特征关联性分析的日尖峰负荷预测[J]. 电网技术，2021，45(7)：2719-2730.
LI Yuzhi, LIU Xiaoliang, XING Fangfang, et al. Daily peak load prediction based on correlation analysis and Bi-directional long short-term memory network[J]. Power System Technology, 2021, 45(7): 2719-2730.

[28] 康守强，周　月，王玉静，等. 基于改进 SAE 和双向 LSTM 的滚动轴承 RUL 预测方法[J]. 自动化学报，2022，48(9)：2327-2336.
KANG Shouqiang, ZHOU Yue, WANG Yujing, et al. RUL prediction method of a rolling bearing based on improved SAE and Bi-LSTM[J]. Acta Automatica Sinica, 2022, 48(9): 2327-2336.

[29] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.

[30] 郑　直，张华钦，潘　月. 基于改进鲸鱼算法优化 LSTM 的滚动轴承故障诊断[J]. 振动与冲击，2021，40(7)：274-280.
ZHENG Zhi, ZHANG Huaqin, PAN Yue. Rolling bearing fault diagnosis based on IWOA-LSTM[J]. Journal of Vibration and Shock, 2021, 40(7): 274-280.

[31] 于永进，姜雅男，李长云. 基于鲸鱼优化–长短期记忆网络模型的机–热老化绝缘纸剩余寿命预测方法[J]. 电工技术学报，2022，37(12)：3162-3171.
YU Yongjin, JIANG Yanan, LI Changyun. Prediction method of insulation paper remaining life with mechanical-thermal synergy based on whale optimization algorithm-long-short term memory model[J]. Transactions of China Electrotechnical Society, 2022, 37(12): 3162-3171.

[32] 孙江涛. 基于 ATmega16 的断路器机械特性测试仪的研制[D]. 大连：大连理工大学，2009.
SUN Jiangtao. Development of mechanical characteristics instrument for circuit breaker based on ATmega16[D]. Dalian, China: Dalian University of Technology, 2009.

[33] 李　超. 高压开关机械特性测试技术研究[D]. 沈阳：沈阳工业大学，2012.
LI Chao. Mechanical properties of high-voltage switch's test technology study[D]. Shenyang, China: Shenyang University of Technology, 2012.



李家豪
1999—，男，博士生
主要从事高电压与绝缘技术、电力设备状态评估与电力设备快速计算方法研究等方面的工作
E-mail: 2868259710@qq.com

LI Jiahao
Ph.D. candidate



王青于(通信作者)
1991—，女，博士，助理教授，硕导
主要从事高端交直流套管关键技术、绝缘结构优化设计及多物理场仿真计算、电力设备状态评估与剩余寿命预测等方面的工作
E-mail: wqy.1991624@xjtu.edu.cn

WANG Qingyu
Ph.D.
Associate professor
Corresponding author

收稿日期　2023-01-03　修回日期　2023-03-03　　编辑　卫李静