doi:10.6041/j.issn.1000-1298.2025.02.050

谐波减速器 MDBO－CNN－LSTM 剩余使用寿命预测

兰月政[1,2]　刘　彪[1,2]　石　超[1,2]　郭世杰[1,2]　吕　贺[1,2]　唐术锋[1,2]

(1. 内蒙古工业大学机械工程学院, 呼和浩特 010051;
2. 内蒙古自治区机器人与智能装备技术重点实验室, 呼和浩特 010051)

摘要: 针对谐波减速器剩余使用寿命预测退化节点难以选取、退化指标与物理解释性差、预测效果偏差较大等问题,提出了一维堆叠卷积自编码器融合深度卷积嵌入式聚类(SCAE－DCEC)提取退化点,并结合改进蜣螂优化算法(DBO)优化 CNN－LSTM 的谐波减速器剩余使用寿命预测方法。对振动信号进行一维堆叠卷积自编码器与深度卷积嵌入式聚类,解决了退化节点难以选取、退化指标与预测网络契合度差等难题;构建了基于 SPM 混沌映射、自适应概率阈值和差分变异扰动的改进蜣螂优化算法,并对其性能进行评估。利用 MDBO 对 CNN－LSTM 超参数进行优化,形成 MDBO－CNN－LSTM 的剩余使用寿命预测模型。在搭建的谐波减速器实验台进行加速寿命实验及预测验证,实验结果表明 MDBO－CNN－LSTM 训练后预测模型拟合优度明显高于 CNN、LSTM、CNN－LSTM、DBO－CNN－LSTM 网络、直接退化全卷积、直接退化的贝叶斯优化 LSTM 的 RUL 预测方法,其预测精度达到 91.33%,且该方法对谐波减速器寿命后期退化趋势中的衰退特征具有较强的辨识能力。

关键词: 谐波减速器; 退化点; SCAE－DCEC; MDBO－CNN－LSTM; 剩余使用寿命

中图分类号: TH132.43; TP183　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)02-0533-11　　**OSID**:

Prediction of RUL of Harmonic Reducer Based on MDBO－CNN－LSTM Method

LAN Yuezheng[1,2]　LIU Biao[1,2]　SHI Chao[1,2]　GUO Shijie[1,2]　LÜ He[1,2]　TANG Shufeng[1,2]

(1. *College of Mechanical Engineering*, *Inner Mongolia University of Technology*, *Hohhot* 010051, *China*
2. *Inner Mongolia Key Laboratory of Robotics and Intelligent Equipment Technology*, *Hohhot* 010051, *China*)

Abstract: Aiming to address challenges in predicting the remaining useful life (RUL) of harmonic drives-such as difficulties in selecting degradation nodes, poor physical interpretability of degradation indicators, and large prediction deviations, a novel approach was proposed. The method combined a one-dimensional stacked convolutional autoencoder (SCAE) integrated with deep convolutional embedded clustering (DCEC) for degradation point extraction, along with an improved dung beetle optimization (DBO) algorithm to enhance the performance of a CNN－LSTM-based RUL prediction model. The vibration signals were processed by using the SCAE－DCEC framework to identify degradation nodes, addressing issues related to the difficulty of node selection and the low compatibility between degradation indicators and the predictive network. Secondly, a modified dung beetle optimization (MDBO) algorithm was developed, incorporating SPM chaotic mapping, adaptive probability thresholds, and differential mutation perturbations, with its performance rigorously evaluated. Thirdly, the MDBO algorithm was applied to optimize the hyperparameters of the CNN－LSTM model, forming the MDBO－CNN－LSTM RUL prediction model. An accelerated life test and validation experiment were conducted by using a harmonic drive test bench. The experimental results demonstrated that the MDBO－CNN－LSTM model significantly outperformed CNN, LSTM, CNN－LSTM, DBO－CNN－LSTM, fully convolutional networks, and Bayesian-optimized LSTM models in terms of goodness of fit. The proposed model achieved

收稿日期: 2024－09－10　修回日期: 2024－10－08

基金项目: 国家自然科学基金项目(52365064)、内蒙古关键技术攻关项目(2021GG0255)、内蒙古自治区高等学校创新团队发展计划项目(NMGIRT2213)、内蒙古自治区直属高校基本科研业务费项目(ZTY2023005、JY20230043)、内蒙古自然科学基金项目(2023LHMS05018、2023LHMS05017)、内蒙古自治区高等学校青年科技英才支持计划项目(NJYT23043)和内蒙古自治区“英才兴蒙”工程团队项目(2025TEL02)

作者简介: 兰月政(1985—),男,高级实验师,主要从事机电系统动力学研究,E-mail: lanyuezheng@imut.edu.cn

通信作者: 郭世杰(1985—),男,副教授,博士生导师,主要从事制造系统智能化研究,E-mail: zijianguoxjtu2015@163.com

a prediction accuracy of 91.33% and exhibited superior recognition capability for capturing the degradation trends during the late stages of the lifecycle of harmonic drive.

Key words: harmonic reducer; point of degradation; SCAE - DCEC; MDBO - CNN - LSTM; remaining useful life

0 引言

检测谐波减速器运行状态对保证机器人性能和可靠性至关重要[1]。随着人工智能与传感器技术发展,数据驱动旋转机构剩余使用寿命(RUL)成为切实可行的方法[2]。其中,基于深度学习的数据驱动可对数据进行深度特征提取[3],因此该方法在RUL预测中已经成为研究热点[4]。

划分退化状态可捕捉寿命各阶段特征变化,直接退化寿命标签为一条斜线[5]。固定退化点标定寿命标签是以相对恒定的速率或模式发生退化。二次函数寿命标签能描述一定的非线性退化趋势[6],但其退化过程较为平滑[7]。人为提取特征判断退化点构造寿命标签会引起特征选择不充分。LI等[8]提出了多尺度特征和卷积神经网络结合的RUL方法。YAO等[9]提出了改进一维卷积神经网络结合简单循环单元的滚动轴承寿命预测。YANG等[10]提出了退化时刻分类判断的双卷积神经网络RUL方法。ZHANG等[11]利用LSTM有效分析了轴承磨损和故障长期渐进过程。CHEN等[12]开展了门控递归单元(GRU)递归神经网络的航空发动机RUL预测。DONG等[13]提出了卷积自动编码器和Pearson系数的轴承故障判断方法,并建立了提取轴承退化的多尺度特征的多通道传输网络。文献[14-15]在混合网络的每个通道特征融合后添加了域自适应结构,使模型能够学习域不变特征。LIU等[16]利用CG-CGAN模型结合Bi-GRU来考虑前向和后向信息,提高了RUL预测的精度。XIAO等[17]提出了异构图表示驱动的多路聚合图神经网络用于轴承RUL预测方法。WU等[18]构建了最大相关峰度解卷积(MCKD)和互补系综经验模式分解(CEEMD)相结合的增强故障信息方法。JIA等[19]利用隐马尔可夫模型描述了谐波减速器在连续变化运行条件下的寿命动态规律。

谐波减速器整体退化呈现形式在初始的一段时间内保持微弱退化状态或健康状态,因此需要针对谐波减速器特征构建寿命标签设定方式和退化节点。此外,常规深度学习方法在捕捉具有明显全局、长时间序列、非线性特征的谐波传动时,选取退化点所依据的特征与后续预测网络所提取的特征并不吻合,且模型可解释性差[20]。针对上述问题,本文构建SCAE-DCEC和DBO优化的卷积神经网络结合长短期记忆神经网络的方法,对谐波减速器进行剩余寿命预测。

1 SCAE-DCEC特征提取聚类

1.1 深度卷积嵌入式聚类框架

针对谐波减速器并不是从开始运行就进入退化,而是在健康状态运行一段时间后才会进入退化阶段特征[16],使用直接退化方式并不能很好地体现谐波减速器退化机理问题。采用深度卷积嵌入聚类对采集的全寿命加速度信号进行无监督聚类(无标签二分类),考虑到后续进行寿命预测使用CNN-LSTM网络,深度卷积嵌入聚类用到卷积层提取特征进行聚类,更能符合后续CNN-LSTM的特征提取寿命预测。

基于SCAE-DCEC的整体网络架构如图1所示,SCAE-DCEC包含两部分,1维堆叠卷积自编码器用于处理谐波减速器一维时间序列数据,从而构建无监督学习模型,其主要操作是将输入的一维时间序列数据通过3个卷积层进行特征提取。振动信号数据通过3个卷积层进行处理。每经过一个卷积层,会接有激活函数和池化层,以逐步减少数据维度,最终输出数量翻倍,尺寸减半。在解码过程中,通过反卷积或转置卷积层将全连接层的特征重构为原始的输入数据,尽可能准确地还原输入数据,从而进行无监督学习,最终重构出原始寿命信号曲线。通过卷积自编码器生成数据的低维嵌入空间,并在嵌入空间中执行聚类操作。在嵌入空间中应用K-means聚类算法,目标是根据嵌入特征进行数据分组。训练过程中不仅最小化重构误差,还需要最小化聚类损失实现联合优化。通过优化网络和聚类过程的联合目标函数,使得网络学习的特征能够有效地支持聚类任务。生成寿命标签过程如图1所示。

1.2 一维堆叠卷积自编码器(SCAE)

自动编码器是一种无监督神经网络模型,用于学习数据潜在特征,并利用这些特征重构原始数据。自动编码器由输入层、隐藏层和输出层组成,而卷积自编码器(CAE)则用卷积神经网络替代全连接层。特别是一维堆叠卷积自编码器(SCAE)由多个一维CAE堆叠而成,其中每个CAE的编码器输出作为下一个CAE的输入,第1个CAE的输入为预处理后

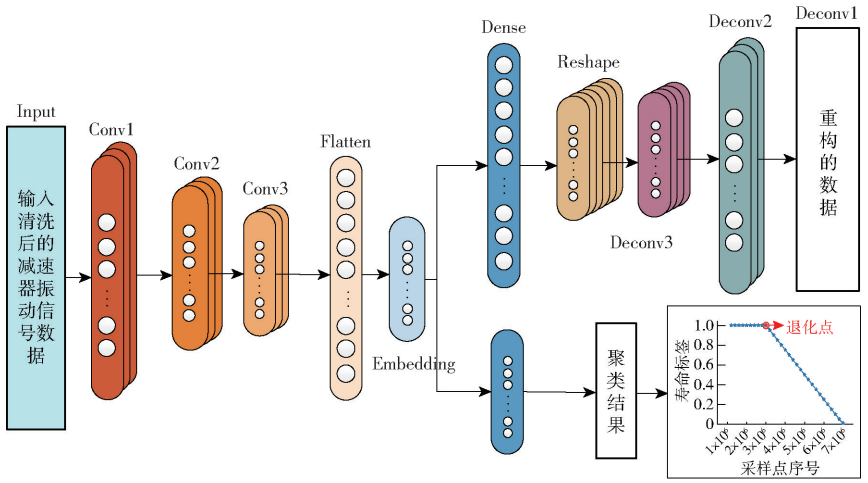

图 1　SCAE－DCEC 框架

Fig. 1　SCAE－DCEC

的数据。相比单层自动编码器，SCAE 通过深层结构提供更强的特征表示能力，能够生成鲁棒更强和更具区分性的特征。每个 CAE 的编码器映射输入数据，解码器将其反映回接近原数据，整个网络通过最小化重构误差进行训练。此外，卷积神经网络相比全连接网络在局部连接、参数共享、使用多个卷积核和池化方面具有优势，这些机制减少了参数量、计算量，提高了学习效率和模型容错性。图 2 为两个 CAE 堆叠形成的 SCAE 模型。

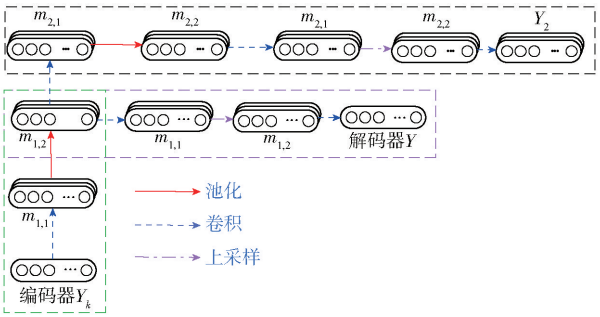

图 2　一维堆叠卷积自编码

Fig. 2　1-dimensional stacked convolutional autoencoder

由图 2 可知，一维堆叠卷积自编码器由 2 个 CAE 叠加而成，绿色虚线矩形中为输入大小为 X 的 CAE 编码器，其一次编码过程可由每一个卷积和池化进行表征，即

$$\begin{cases} m_{k,1} = l_g(S \otimes X_k + \boldsymbol{a}) \\ m_{k,2} = \text{Pooling}(m_{k,1}) \end{cases} \tag{1}$$

式中　l_g——激活函数

X_k——$m_{k-1,2}(k=1,2,\cdots,n)$ 的函数，且 k 为 1 时，$X_k = X$

$m_{k,1}$——第 k 个编码器中经过卷积⊗、池化操作后的数据

$m_{k,2}$——第 k 个编码器输出特征

S——数目为 j_n、大小为 $j_{n\times 1}$ 的卷积核

$\boldsymbol{a}$——偏置向量

图 2 中粉色虚线中表示经过 CAE 一次解码操作，即

$$\hat{m}_{k,1} = l_n(\hat{S}_{k,1} \otimes m_{k,2} + \hat{a}_{k,1}) \tag{2}$$

$$\hat{m}_{k,2} = \text{upsample}(\hat{m}_{k,1}) \tag{3}$$

$$\hat{Y}_k = l_k(\hat{S}_{k,2} \otimes \hat{m}_{k,2} + \hat{a}_{k,2}) \tag{4}$$

式中　$\hat{Y}_k$——输入 X_i 的重构值

l_n——

$\hat{a}_{k,1}$、$\hat{a}_{k,2}$——卷积自编码器 k 在解码过程中的两个卷积偏置

$\hat{S}_{k,1}$、$\hat{S}_{k,2}$——两次对应的卷积核，且 $\hat{S}_{k,2}$ 卷积核数量是 1，经过解码操作后得到特征为 $\hat{m}_{k,2}$

ReLU 函数是 l_g 解码器中的激活函数，模型目标损失函数 L 定义为输出最小值与重构后二者之间的偏差，即

$$L(Y_k, \hat{Y}_k) = \frac{1}{2n} \sum_{k=1}^{n} \| Y_k^n - \hat{Y}_k^n \|^2 \tag{5}$$

式中　n——数据训练过程中的输入样本总数

1.3　聚类层与卷积堆叠自编码联合优化

在完成一维卷积自编码器模型构建和训练后，引入展平层提升负荷数据在经过卷积自编码器降维后特征与聚类过程的融合效果。通过添加展平层，将从编码部分提取的特征展开，并通过嵌入层将降维后的深层特征输入到聚类层。DCEC 是在深度嵌入聚类（Deep embedded clustering，DEC）的基础上改进的[21]，DCEC 也利用卷积自编码器（Context auto encoder，CAE）的思想。DCEC 结构包括编码部分与解码部分[22]，编码部分包括 3 个卷积层、平铺层以及全连接层，解码部分则按照编码部分反向组成。

聚类层初始权重参数设定与 K－means 算法生成的初始聚类中心一致，然后通过优化损失函数来

对网络性能进行调整和完善,聚类层与卷积堆叠自编码联合优化网络目标函数为 L,计算式为

$$L = L_r + \gamma L_c \tag{6}$$

其中

$$L_r = |x - x'|_2^2 \tag{7}$$

$$L_c = K_L(p \parallel q) \tag{8}$$

式中 L_r、L_c为重构损失和聚类损失。当 γ 为 1 且 L_r 为 0 时,L 为 DEC 的目标函数,其值固定为 0.1。K_L 为散度。

$$L_c = K_L(p \parallel q) = \sum_i \sum_j p_{ij} \lg \frac{p_{ij}}{q_{ij}} \tag{9}$$

其中

$$q_{ij} = \frac{(1 + \| z_i - \mu_j \|^2)^{-1}}{\sum_j (1 + \| z_i - \mu_j \|^2)^{-1}} \tag{10}$$

$$p_{ij} = \frac{q_{ij}^2 \Big/ \sum_i q_{ij}}{\sum_i \left(q_{ij}^2 \Big/ \sum_i q_{ij} \right)} \tag{11}$$

式中 q_{ij}——将样本 i 分配给聚类 j 的概率(即软分配)

$\| \ \|^2$——欧氏距离

p——辅助目标分布

在 DCEC 聚类得到退化点后,还需对寿命标签进行归一化处理,退化阶段寿命标签 y_i 公式为

$$y_i = \frac{h - m_i}{h} \tag{12}$$

式中 h——退化阶段数据数量

m_i——退化阶段的第 i 天,当 m_i 为 0 时认定此设备完全失效

谐波减速器数据集是无标签数据,谐波减速器数据类别无法预先定义。因此,需对其聚类指标进行聚类结果评价。在 DCEC 模型训练过程中,确定聚类数量非常关键。采用聚类算法中常用的评价指标戴维森堡丁指数(Davies - Bouldin index,DBI)来确定最佳聚类数量,*DBI* 用于度量类间离散度和类内离散度的聚类准则,其数值越小表示样本在类内的相似度越高、类间差异度越大,从而反映较好的聚类效果。其计算式为

$$DBI = \frac{1}{c} \sum_{i=1,\, j=1}^{c} \max \frac{s_i + s_j}{P_{ij}} \tag{13}$$

其中

$$s_i = \frac{1}{n_i} \sum_{k=1}^{n_i} x_k \tag{14}$$

$$P_{ij} = \| s_i - s_j \| \tag{15}$$

式中 c——聚类数量

s_i、s_j——第 i 个和第 j 个聚类中样本点与同一聚类簇中所有样本 x_k($1 \leqslant k \leqslant n_i$)平均值标准误差

n_i——第 i 个聚类中样本点数量

P_{ij}——s_i和 s_j距离

2 基于 MDBO - CNN - LSTM 的预测模型

2.1 DBO 算法

蜣螂优化算法是一种群智能优化算法,其通过蜣螂社会行为,即蜣螂滚球、跳舞、觅食、繁殖和偷窃行为受到启发。蜣螂种群分为滚球蜣螂、繁育球、小蜣螂和偷窃蜣螂。蜣螂优化算法中 4 个蜣螂种群分布比例没有规定,可根据实际应用问题进行设置,但其总数之和需与整个种群总数 N 相等。

(1)初始化网络参数。蜣螂优化算法种群数迭代次数,规定所优化参数的上下限,随机产生搜索空间中的若干候选解作为个体。

(2)计算适应度。通过不同种群不同行为进行最优搜索。

(3)滚球。滚球种群搜索形式分为有障碍物模式和无障碍物模式。无障碍物模式蜣螂利用太阳进行导航,位置更新公式为

$$x_i^{t+1} = x_i^t + ak x_i^{t-1} + b |x_i^t - x_{worst}^t| \tag{16}$$

其中

$$a = \begin{cases} 1 & \text{(无偏差)} \\ -1 & \text{(方向完全偏差)} \end{cases}$$

式中 t——当前迭代次数

x_i^t——种群中第 i 只蜣螂在 t 次迭代中的位置

k——偏转系数,取 0 ~ 0.2

b——常数,取 0 ~ 1

x_{worse}^t——当前种族最差位置

$|x_i^t - x_{worse}^t|$——光强变化值

有障碍模式蜣螂则通过跳舞改变方向,位置更新公式为

$$x_i^{t+1} = x_i^t + \tan\theta |x_i^t - x_i^{t-1}| \tag{17}$$

θ 为 0、π/2 或 π 时位置不会更新,其他值按式(16)更新位置。

(4)繁殖。繁殖组是基于边界选择策略对蜣螂产卵的区域进行仿真,即

$$\begin{cases} \mathrm{Lb1} = \max \left\{ x_{gbest}^t \left(1 - \dfrac{1-t}{T}\right), \mathrm{Lb} \right\} \\ \mathrm{Ub1} = \min \left\{ x_{gbest}^t \left(1 + \dfrac{1-t}{T}\right), \mathrm{Ub} \right\} \end{cases} \tag{18}$$

式中 T——最大迭代次数

Lb、Ub——需要优化卷积神经网络参数的上界和下界

x_{gbest}^t——繁殖组全局最优解

Lb1、Ub1——产卵区域上界和下界(随着迭代次数的变化不断变化)

基于蜣螂在仿真区域进行产卵,卵的位置更新公式为

$$x_i^{t+1}=x_{gbest}^{t}+\boldsymbol{b}_1(x_i^t-\mathrm{Lb1})+\boldsymbol{b}_2(x_i^t-\mathrm{Ub1}) \tag{19}$$

式中　x_i^{t+1}——繁殖组中雏球 i 在 t 次更新后的位置

$\boldsymbol{b}_1$、$\boldsymbol{b}_2$——$1\times D$ 的独立随机矩阵

(5)觅食。觅食组与繁殖组类似，小蜣螂的觅食区域为 Lb2，计算式为

$$\begin{cases}\mathrm{Lb2}=\max\left\{x_{lbest}^{t}\left(1-\dfrac{1-t}{T}\right),\mathrm{Lb}\right\}\\ \mathrm{Ub2}=\min\left\{x_{lbest}^{t}\left(1+\dfrac{1-t}{T}\right),\mathrm{Ub}\right\}\end{cases} \tag{20}$$

式中　Lb2、Ub2——觅食区域上界和下界(随着迭代次数的变化不断变化)

x_{lbest}^{t}——觅食组的全局最优

小蜣螂会在 Lb2 区域内寻找食物，位置更新公式为

$$x_i^{t+1}=x_i^t+c_1(x_i^t-\mathrm{Lb2})+\boldsymbol{c}_2(x_i^t-\mathrm{Ub2}) \tag{21}$$

式中　c_1——0 到 1 之间的服从正态分布的随机数

$\boldsymbol{c}_2$——$1\times D$ 在 0 到 1 之间的随机向量

(6)偷窃。偷窃组位置更新公式为

$$x_i^{t+1}=x_{lbest}^{t}+S_1\boldsymbol{g}(|x_i^t-x_{gbest}^{t}|+|x_i^t-x_{lbest}^{t}|) \tag{22}$$

式中　$\boldsymbol{g}$——$1\times D$ 服从正态分布随机向量

S_1——常数

2.2　混合策略改进 DBO 算法

蜣螂优化其全局探索能力与局部开发能力的平衡较差，容易陷入局部最优解。为克服这些不足，采用 SPM 混沌映射对蜣螂种群初始化，生成更加均匀分布的种群，以提高初始解的质量。对滚球蜣螂引入自适应概率阈值调整的搜索策略更新蜣螂遇到障碍后位置，扩大搜索范围。同时，加入差分变异扰动策略提高协调全局探索和局部开发平衡的能力。基于以上 3 种改进策略构建思路，提出改进的蜣螂优化算法(MDBO)。

2.2.1　基于 SPM 混沌映射种群初始化

由于蜣螂种群初始位置存在个体位置分布不均匀的缺陷，这明显降低了蜣螂种群多样性。采用混沌映射策略对其种群初始化阶段进行改进。SPM 映射作为混沌映射的代表性表达方式被广泛应用，其具有混沌分布均匀、参数简单等优点。其数学表达式为

$$x(i+1)=\begin{cases}\mathrm{mod}\left(\dfrac{x(i)}{\eta}+\mu\sin(\pi x(i))+r,1\right) & (0\leqslant x(i)<\eta)\\ \mathrm{mod}\left(\dfrac{x(i)}{\eta(0.5-\eta)}+\mu\sin(\pi x(i))+r,1\right) & (\eta\leqslant x(i)<0.5)\\ \mathrm{mod}\left(\dfrac{1-x(i)}{\eta(0.5-\eta)}+\mu\sin(\pi(1-x(i)))+r,1\right) & (0.5\leqslant x(i)<1-\eta)\\ \mathrm{mod}\left(\dfrac{1-x(i)}{\eta}+\mu\sin(\pi(1-x(i)))+r,1\right) & (1-\eta\leqslant x(i)<1)\end{cases} \tag{23}$$

式中 r 为 0～1 之间的随机数，当 $n\in(0,1)$ 且 $\mu\in(0,1)$ 时，该函数处于混沌状态。实验表明当 $n=0.4$ 且 $\mu=0.3$ 时 SPM 映射产生的序列具有更好的遍历性和随机性。其混沌轨道状态值范围为 0～1。为了检验 SPM 混沌映射是否具备分布均匀性优势，进行基于 SPM 策略、Chebyshev 策略以及随机分布策略的 1 000 个随机种群的随机生成，分区区间为 −1～1。3 个策略生成的频数分布如图 3 所示。

由图 3 可知，SPM 策略生成的种群与随机分布和 Chebyshev 映射方式相比，前者在各分布区间更加均匀，表现出更好的遍历性，因此，利用 SPM 策略迭代搜索可提供良好的初始种群质量保证。

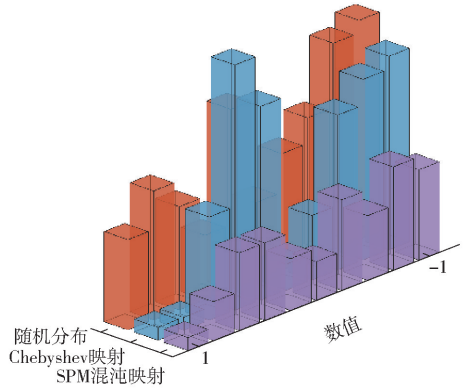

图 3　不同分布策略频数分布

Fig. 3　Frequency distribution of different distribution strategies

2.2.2　自适应概率阈值调整

为使得搜索阶段时能在不同的搜索阶段和数据分布下提供更合适的调整策略，增强算法适应性。利用自适应参数替换原有概率阈值。通过自适应参数根据算法的进展和搜索策略的效果动态调整，从而提高蜣螂算法搜索效率，实现在不同阶段下更大的概率选择适合当前群体捕食策略。有助于平衡算法的全局探索和局部开发能力，实现寻优算法稳步收敛。其数学表达式为

$$\mathrm{adaptive_p}=1-\left[\frac{1}{1+\lambda}\left(\lambda\frac{t^{\lambda}}{w^{\lambda}}+\mu\frac{t^{u}}{w^{u}}\right)\right] \tag{24}$$

式中：自适应概率阈值变化区间为(0,1]，t 为当前迭代次数；w 为最大迭代次数；λ、u 为控制参数，取 $\lambda=3$，$u=2$。因此，蜣螂狩猎行为计算式为

$$X(t+1)=\begin{cases}X^*(t)-AD & (p<\text{adaptive_p})\\ D'e^{bl}\cos(2\pi l)+X^*(t) & (p\geqslant\text{adaptive_p})\end{cases}\tag{25}$$

式中 A——位置系数,取 0 ~ 1

D——更新位置次数

D'——蜣螂与目标之间的距离阈值系数,取 0 ~ 1

l——随机数,取 -1 ~ 1

由式(25)可知,自适应阈值在初始迭代阶段具有较大数值,这导致蜣螂个体在选择收缩包围机制上具有较大的概率。在算法末期执行过程中,随着自适应阈值缩减,蜣螂在选择更新上更大几率趋于随机位置。通过迭代过程中先实施收缩包围,然后进行全局范围的位置更新,使蜣螂更快地接近目标物,进而提高了蜣螂算法收敛速度。

2.2.3 差分变异扰动策略

算法迭代过程中蜣螂不断靠近最优目标个体,同时存在陷入局部最优解的概率。为处理上述缺陷,可通过丰富种群多样性避免迭代在局部最优解停止,对此可在蜣螂收缩包围过程引入随机差分变异策略,即以一定概率进行变异,生成新变异个体,并与蜣螂个体进行交叉,从而增加蜣螂种群在后期迭代阶段多样性。差分变异策略是一种差分进化算法中独特的变异策略,其具体实现方式是对种群中两个随机个体的差异向量进行缩放,然后与第 3 个个体结合形成一个新的个体,其具体数学表达式为

$$X_{i,j}(t+1)=X_{r1,j}(t)+F(X_{r2,j}(t)-X_{r3,j}(t))\tag{26}$$

式中 i——种群个体序号

j——该个体变量序号

$X_{r1,j}(t)$、$X_{r2,j}(t)$、$X_{r3,j}(t)$——该种群 3 个不同的随机个体

$X_{i,j}(t+1)$——新生成个体

F——缩放因子,取 0 ~ 2

蜣螂优化算法利用差分变异策略生成一个新变异个体,在蜣螂个体上引入该新变异个体实现交叉,收缩包围阶段经过改进的蜣螂个体位置更新为

$$\boldsymbol{X}(t+1)=\begin{cases}\boldsymbol{X}(t)+F(\boldsymbol{X}_{rand}(t)-\boldsymbol{X}(t)) & (p_2<C_R)\\ \boldsymbol{X}^*(t)-\omega\boldsymbol{AD} & (p_2\geqslant C_R)\end{cases}\tag{27}$$

式中缩放因子 F 取 0.6,采取差分变异策略概率 C_R 取 0.8,ω 为差分变异随机差子,取 0 ~ 1。

2.3 MDBO - CNN - LSTM 网络预测模型

卷积神经网络可以实现特征提取,但存在对时间序列的长依赖特征不敏感。对序列数据和时序信息处理能力较弱的缺陷。另一方面,长短期记忆神经网络是在循环神经网络的基础上改进的,可以有效地解决循环神经网络梯度消失和梯度爆炸问题,LSTM 能够学习长期依赖关系,适用于处理序列数据和时序信息[27]。

结合两者优点对谐波减速器进行寿命预测。优化参数包括学习率、批量大小、卷积层层数、卷积核数量、LSTM 层隐藏层神经元数量和第 1 层全连接层隐藏层神经元数量。所构建的谐波减速器寿命预测方法流程如图 4 所示。

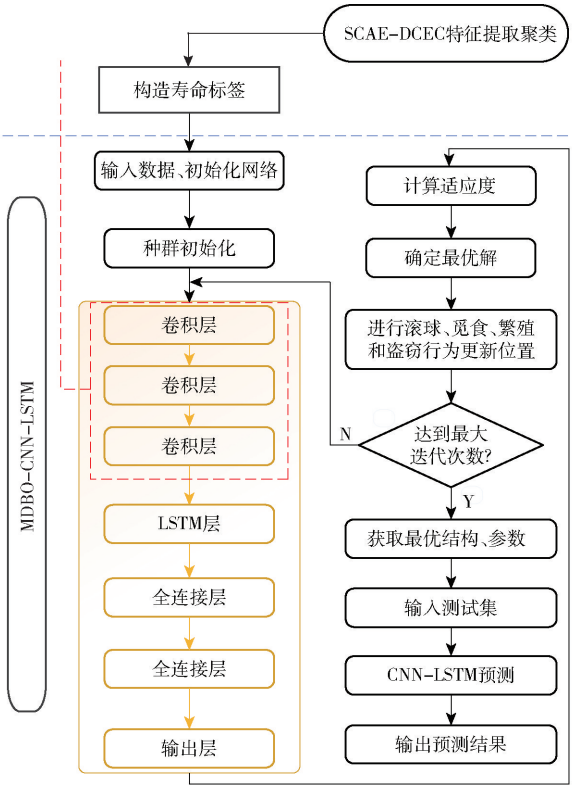

图 4 SCAE - DCEC 聚类的 MDBO - CNN - LSTM 寿命预测流程

Fig. 4 Process of RUL of MDBO - CNN - LSTM based on SCAE - DCEC clustering

使用 MDBO 对 CNN - LSTM 网络结构参数进行自动寻优。蜣螂优化算法在全局搜索过程和局部开发阶段都具备较好的收敛效率、较高的求解精度等优点[23]。应用 MDBO 进行寻优可以提升 CNN - LSTM 预测精度。基于 MDBO - CNN - LSTM 的具体实施步骤为:

(1)建立谐波减速器全寿命振动信号参数矩阵,对其进行归一化处理,定义数据测试集、训练集。

(2)根据式(18)对种群进行初始化,定义种群数量、种群搜索空间、觅食最大迭代次数。

(3)对 CNN - LSTM 中的隐藏层基数、最大训练循环时间、批处理尺寸、训练效率和超参数进行初始

化处理，并确定参数区间。

(4)量化初始超参数下蜣螂最佳、最劣适应度，并确定其位置。

(5)利用式(17)、(18)、(21)、(22)分别对蜣螂的滚球活动、繁殖活动、觅食特征和偷窃活动的个体位置予以更新，同时确定更新后相应个体位置的适应度，依据适应度判别位置和最优个体。

(6)判别是否已达最大迭代次数，如符合则将优化后的参数引入分类器；反之，跳转至步骤(5)。

(7)利用构建的 MDBO－CNN－LSTM 预测模型进行谐波减速器剩余寿命预测。

最终通过上述步骤的多次循环迭代，以测试集 RMSE 为目标，寻找得到 CNN－LSTM 网络参数的最优值，完成优化。RMSE 计算式为

$$y_i = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(Y_i - YP_i)^2} \tag{28}$$

式中　N——样本数据量

Y_i——第 i 个数据真实寿命值

YP_i——第 i 个数据预测寿命值

因为谐波减速器寿命较长，考虑时间成本[24]，寿命计算式为

$$y = y_0\left(\frac{V_0}{V}\right)^m\left(\frac{P_0}{P}\right)^n \tag{29}$$

式中　y——寿命

V、P——输入转速、输出转矩

m、n——待估参数，取 3 和 1

y_0——额定寿命

V_0、P_0——当前转速和转矩

3　验证与分析

根据检测原理与所选的元器件，构建了谐波齿轮传动特性综合检测系统，其机械部分如图 5 所示，包括驱动电机、转矩转速传感器、振动传感器、被测谐波减速器、输出端扭矩传感器和磁粉制动器。各器件之间通过联轴器、联结轴或法兰进行前后连接。

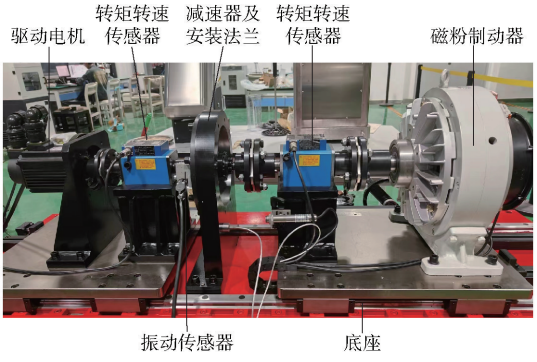

图 5　实验台测试现场

Fig. 5　Experimental site

对谐波减速器进行加速寿命实验，使用的谐波减速器参数额定转速为 2 000 r/min、转矩为 40 N·m，减速比为 100。设计的加速寿命实验为转速下 3 倍负载，即转速为 2 000 r/min、转矩为 120 N·m。采集装置中加速度传感器采集振动信号频率为 10 kHz，设定采用间隔 60 s。

实验过程共采集 3 个谐波减速器全寿命振动信号，将 2 组数据作为训练测试数据验证所提方法的有效性。取 1 号和 2 号谐波减速器三轴向全寿命振动信号以及 3 号谐波减速器 X、Y 轴全寿命振动信号作为网络模型训练集，将 3 号谐波减速器 Z 轴全寿命振动信号作为测试集。振动信号时域图如图 6 所示。

由图 6 可知，随着运行时间的增加，加速度信号在谐波减速器的全生命周期中变化幅度明显，并呈较强的单调性，这种变化趋势有利于退化过程健康度指标构建，适用于谐波减速器剩余寿命预测。因此，将得到的谐波减速器加速寿命实验信号进行 SCAE－DCEC 无监督聚类，作为验证集的第 3 个谐波减速器聚类结果，如图 7 所示。

在谐波减速器运行周期达到或超过临界阈值时，RUL 将保持不变，当运行周期低于该临界阈值时，RUL 将随着每次运行周期增加而持续减少。对于谐波减速器运行过程特定的数据集，DBI 与聚类数值函数映射曲线如图 7b 所示。由图 7 可知，DBI 随着聚类值增加而下降，前期呈指数级下降趋势，在聚类值达到 30 时，DBI 呈较小波动且无明显下降。此时聚类数据显示，谐波减速器明显退化点为 358，但是在健康阶段之内存在被聚类为退化阶段的点，原因是在健康阶段谐波减速器振动幅值在较大影响了聚类判断，通过计算退化点设置为 358 时，错误聚类数占比小于 10%，因此可以认定 358 为退化点。实验过程得到每个实验谐波减速器的退化节点，结果如表 1 所示。

依据第 1 节的 SCAE－DCEC 特征提取聚类方法，对采集到的信号按照表 1 所示的退化点施加寿命标签，将其输入至所构建的网络中，网络优化结构参数结果如表 2 所示。

利用加速度信号反映减速器的振动特性和故障状态变化的特点，即谐波减速器内部零部件磨损、疲劳或老化时，其振动信号中加速度幅值和频谱特征会随时间发生显著变化。通过对大量数据进行训练，利用所构建的网络模型可以学习加速度信号的特征变化与剩余使用寿命之间的关系，从而实现对设备寿命预测。谐波减速器剩余使用寿命预测结果如图 8 所示。

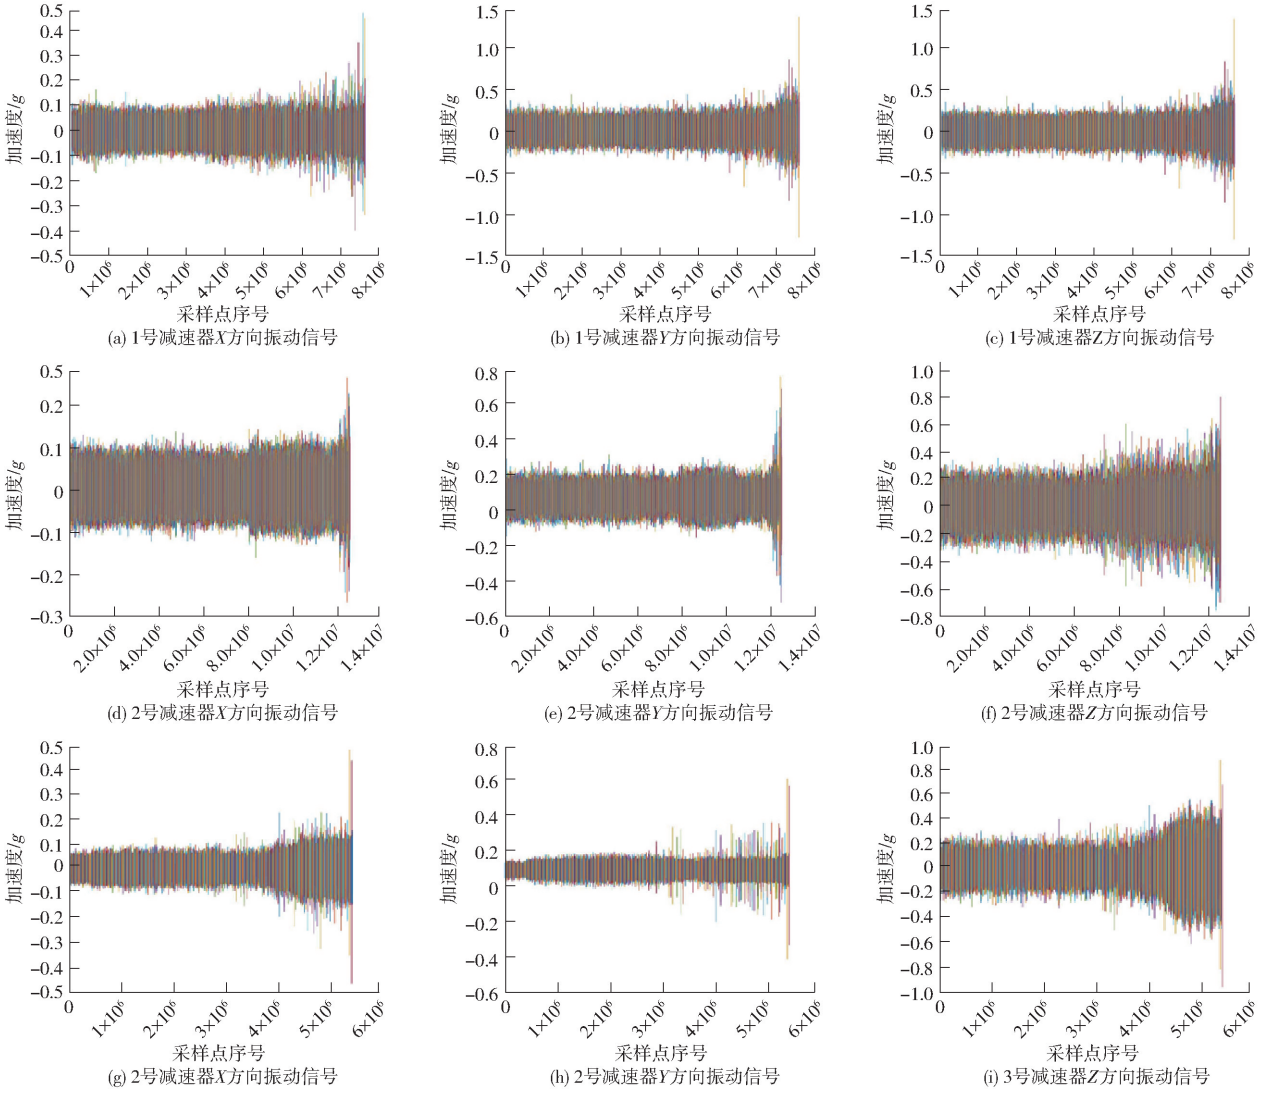

图 6 谐波减速器时域信号图

Fig. 6 Harmonic reducer time domain signal diagrams

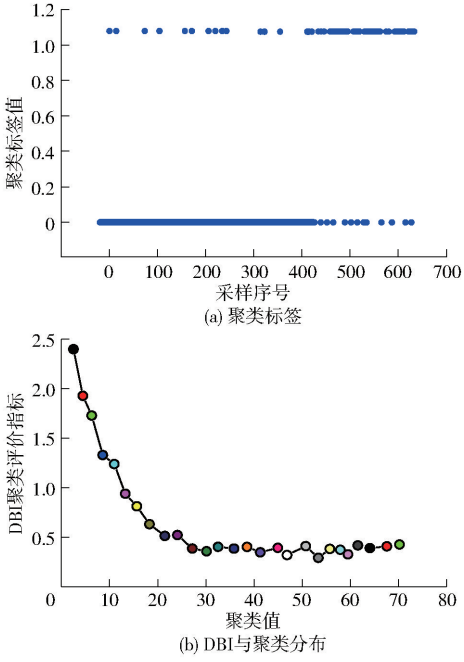

图 7 聚类结果与 DBI 量化评价

Fig. 7 Clustering results and DBI quantitative evaluation

表 1 谐波减速器退化点

Tab. 1 Harmonic reducer degradation point

谐波减速器实验组	采集次数	退化节点
1	760	595
2	1 253	792
3	539	358

如图 8 所示，预测得到谐波减速器整体呈退化趋势，但是产生了局部振荡现象，因此采用 S－G 滤波器[24]对预测寿命曲线平滑处理解决该问题。平滑处理后寿命曲线较好地反映了谐波减速器随时间推移而逐渐退化的过程，具有明显趋势性和单调性，适用于谐波减速器剩余寿命预测。此外，由图 8 可知，预测结果在真实结果 ±0.4 的范围内波动，RUL 预测曲线总体趋势与真实寿命相符合，预测值与真实值相距较为紧密，即使用 MDBO－CNN－LSTM 模型能够准确地预测出谐波减速器 RUL，其预测 RUL 不仅与实际 RUL 有着相同下降趋势，在 RUL 值上也能够吻合真实值。同时注意到谐波减速器 1 号

表 2　结构参数优化结果

Tab. 2　Optimization of structural parameters

优化项	优化范围	优化结果	优化项	优化范围	优化结果
卷积层数	1～4	3	第 4 层卷积核数量	1～200	
第 1 层卷积核数量	1～200	152	学习率	0.001～0.01	0.005 383 382
第 2 层卷积核数量	1～200	78	批大小	1～64	12
第 3 层卷积核数量	1～200	141	LSTM 层	1～200	88

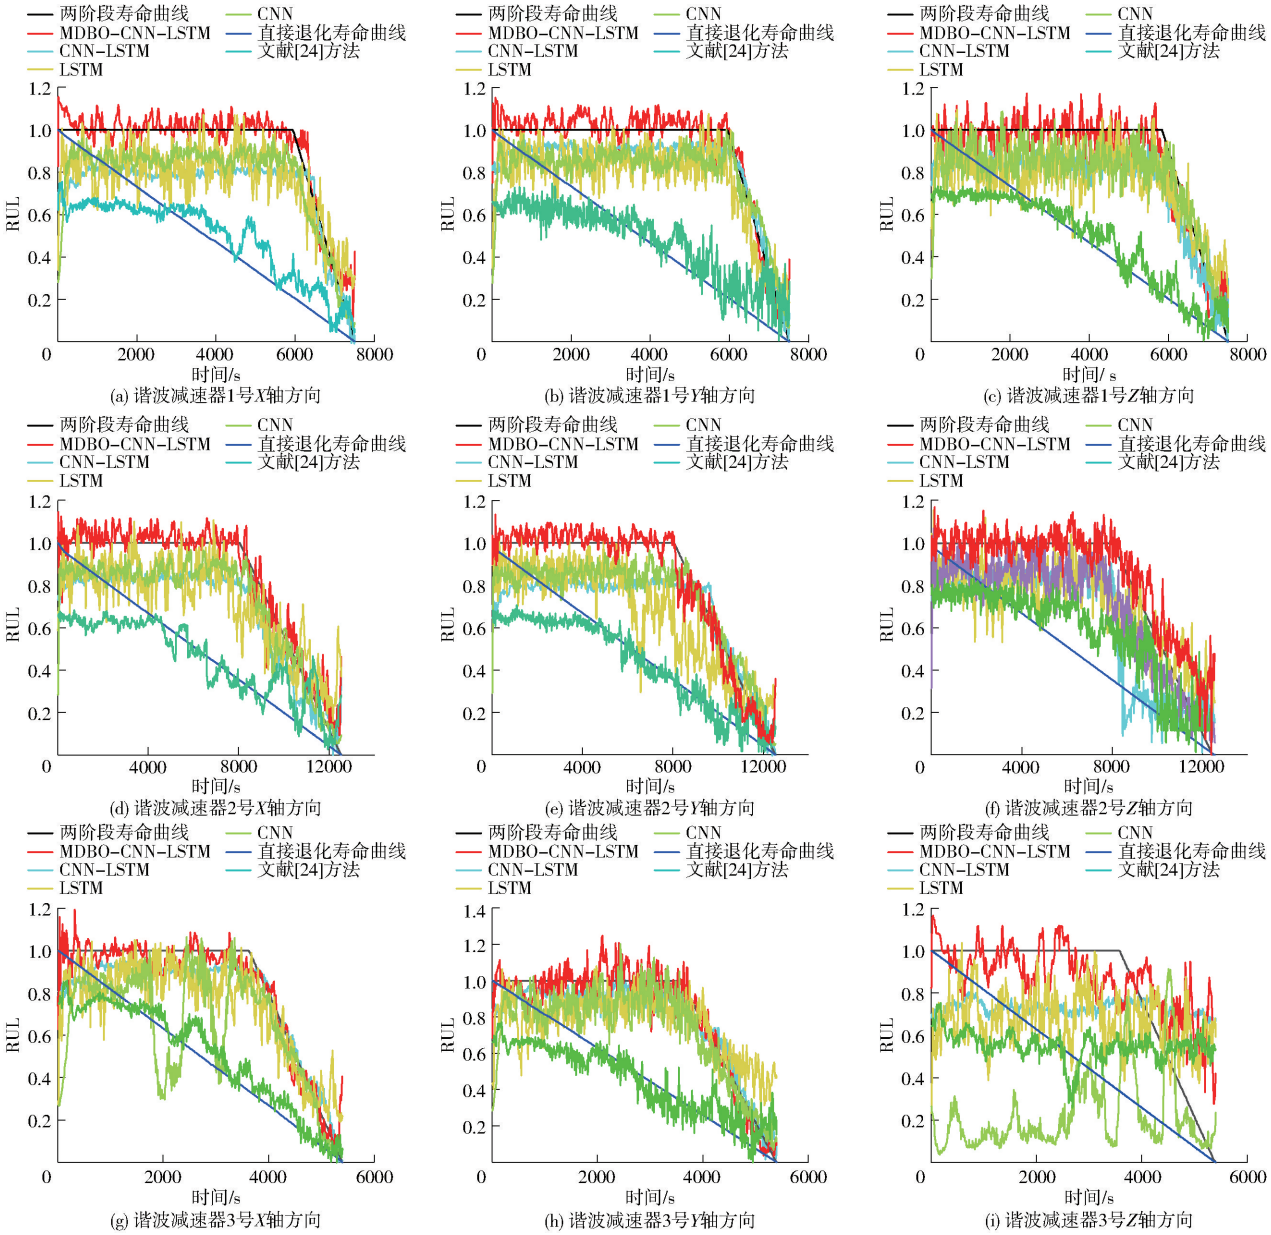

图 8　训练集与预测集预测结果

Fig. 8　Prediction results for test set and training set

3 个方向和谐波减速器 2 号 Y 轴方向以及谐波减速器 3 号 X 轴方向预测的末端存在一个“翘脚”现象，这是由于采集的谐波减速器振动信号末端只有个别数据达到了较大幅值，大部分数值仍在与之前幅值相差不大的水平，因此在预测时导致较大的预测误差。此外，由图 8 可知，由不同预测起止点结果可知，当预测位置与失效阈值接近时，其预测精度越高，这表明模型对于寿命后期退化趋势中的退化数据具有较强的辨识能力。

为定量分析寿命预测模型性能，在对比 SCAE－DCEC 退化点选取基础上的 CNN、LSTM、CNN－LSTM、DBO－CNN－LSTM 网络和以 150 为退化点的 DBO－CNN－LSTM 网络（DBO－CNN－LSTM＊）的预测效果，使用均方根误差（RMSE）、平均绝对误

差(MAE)、决定系数(R^2)以及均方根对数误差(RMSLE)、评分函数 SF、预测能力 η 等 6 项量化数值对 5 种网络的预测效果进行评估,其中 RMSE、MAE 和 RMSLE 越小效果越好,R^2 越大越接近 1 效果越好。对于谐波减速器这类既有柔性变形,又需啮合传动的复杂设备,预防性维护欠缺导致的质量损失将超过过度预防性维修的成本。选用评分函数对高估的 RUL 进行非对称抑制处理。SF 越低表明预测方法性能越好。

利用 CNN、LSTM、CNN - LSTM、MDBO - CNN - LSTM 网络和以 150 为退化点的 DBO - CNN - LSTM 以及直接退化全卷积 RUL 方法[25]和直接退化的贝叶斯优化 LSTM 的 RUL 方法[26]拟合优度如表 3 所示。

表 3 不同预测方法拟合优度

Tab. 3 Residuals of predictions

数据集	评价指标	CNN	LSTM	CNN - LSTM[27]	MDBO - CNN - LSTM	文献[25]方法	文献[26]方法
测试集	RMSE	0.604 73	0.327 52	0.417 60	0.230 99	0.256 83	0.278 75
	MAE	0.549 39	0.292 70	0.353 23	0.171 91	0.224 35	0.219 91
	R^2	-3.348 02	-0.273 08	-1.069 7	0.926 73	0.208 46	0.710 23
	RMSLE	0.377 65	0.196 82	0.261 38	0.150 21	0.181 48	0.188 88
	SF	0.874 33	0.652 91	0.648 83	0.100 69	0.380 21	0.521 04
	η	0.791 94	0.682 35	0.649 07	0.901 80	0.693 11	0.734 31
训练集	RMSE	0.217 34	0.148 78	0.171 38	0.092 841	0.116 64	0.095 654
	MAE	0.166 65	0.126 02	0.143 38	0.070 643	0.090 796	0.072 663
	R^2	0.408 27	0.722 70	0.632 07	0.932 02	0.836 75	0.885 380
	RMSLE	0.128 09	0.086 764	0.100 98	0.057 28	0.076 698	0.058 209
	SF	0.919 09	0.761 90	0.872 67	0.112 51	0.434 46	0.610 99
	η	0.803 47	0.734 58	0.618 97	0.913 36	0.876 54	0.692 80

由表 3 可知,使用 MDBO - CNN - LSTM 模型的预测模型,其 RMSE 为 0.230 99,MAE 为 0.171 91,MDBO - CNN - LSTM 模型训练后的预测模型 RMSE 为 0.092 841,MAE 为 0.070 643,预测指标 RMSE 与 MAE 越小说明预测 RUL 的误差越小,更加吻合减速器的真实 RUL,该值越小其预测精度越好。R^2 为 0.932 32,模型的拟合优度指标对比表明,MDBO - CNN - LSTM 模型 RMSE、MAE、R^2、RMSLE、SF、η 中,RMSE、MAE 和 RMSLE 小于 CNN、LSTM、CNN - LSTM、文献[25]所述方法以及文献[26]所述方法。MDBO - CNN - LSTM 模型 R^2 更接近 1,RMSE 最小的模型为本文所提出的预测模型,误差训练集与测试集 RMSE 平均值为 0.163 322,在所有方法中误差最低,相较于文献[25]和文献[26],误差分别降低 12.5% 和 12.8%,提出的模型预测准确率达到 91.33%,即 MDBO - CNN - LSTM 模型的预测模型真实值和预测值之间的预测异常性、数据分布规律和单调性等较好,与传统机器学习方法相比,该方法较 CNN 和 LSTM 的预测误差相对较小。综上,DCEC 结合 DBO - CNN - LSTM 网络在谐波减速器剩余使用寿命具备较高的预测性能,且具有很好的迁移性。

4 结论

(1)将谐波减速器振动信号加速度特征与一维卷积神经网络相结合,利用寿命信号特征参数生成时域上具有物理意义的深层特征,将一维卷积重构和聚类更新过程转化为寿命退化的特征点识别过程,用于微弱退化(健康)和快速退化阈值点的提取及寿命标签的设定,具有较好的物理阐释性。

(2)建立了 MDBO - CNN - LSTM 网络预测模型,使用蜣螂优化算法对 CNN - LSTM 网络的卷积层数、卷积层个数等结构参数进行优化,有效解决了 CNN - LSTM 网络过拟合和局部最优问题,实现更高精度剩余使用寿命预测。

(3)通过谐波减速器实验平台对所述方法进行验证,同 CNN 模型、LSTM 模型、CNN - LSTM 模型和传统的卷积层神经网络模型对比,结果显示本文提出的模型预测准确率达到 91.33%,对谐波减速器实验数据集故障信息反应更快、精度更高。

参 考 文 献

[1] 王田苗,陶永. 我国工业机器人技术现状与产业化发展战略[J]. 机械工程学报,2014,50(9):1 - 13.
WANG Tianmiao, TAO Yong. Research status and industrialization development strategy of Chinese industrial robot[J]. Journal of Mechanical Engineering, 2014, 50(9):1 - 13. (in Chinese)

[2] 葛阳,郭兰中,牛曙光,等. 基于 t - SNE 和 LSTM 的旋转机械剩余寿命预测[J]. 振动与冲击, 2020, 39(7):223 - 231,273.
GE Yang, GUO Lanzhong, NIU Shuguang, et al. Prediction of remaining useful life based on t - SNE and LSTM for rotating

machinery[J]. Journal of Vibration and Shock, 2020, 39(7):223－231,273. (in Chinese)
[3] 李天梅,司小胜,刘翔,等. 大数据下数模联动的随机退化设备剩余寿命预测技术[J]. 自动化学报,2022,48(9):2119－2141.
LI Tianmei, SI Xiaosheng, LIU Xiang, et al. Data-model inter active remaining useful life prediction technologies for stochastic degrading devices with big data[J]. Acta Automatica Sinica, 2022, 48(9):2119－2141. (in Chinese)
[4] 刘小峰,冯伟,柏林. 考虑退化轨迹差异性与相似性的轴承 RUL 预测[J]. 控制与决策, 2021, 36(11):2833－2840.
LIU Xiaofeng,FENG Wei,BO Lin. Prediction of bearing remaining useful life involving difference and similarity of degradation trajectories[J]. Control and Decision, 2021,36(11):2833－2840. (in Chinese)
[5] 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 Zhetao, LIU Lu, SONG Xiao, 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. (in Chinese)
[6] 刘昕宇,姜长泓,刘一铮,等. 基于空洞 CNN 和 LSTM 的滚动轴承剩余使用寿命预测[J]. 现代制造工程,2023(4):130－135,102.
LIU Xinyu, JIANG Changhong, LIU Yizheng, et al. Remaining useful life prediction of rolling bearings based on dilated CNN and LSTM[J]. Modern Manufacturing Engineering,2023(4):130－135,102. (in Chinese)
[7] 肖家丰,董绍江,汤宝平,等. 基于 PEDCC 性能退化指标及 MCRNN 的滚动轴承寿命状态识别方法[J]. 振动与冲击,2022,41(24):176－183,233.
XIAO Jiafeng, DONG Shaojiang, TANG Baoping, et al. Rolling bearing life state recognition based on a PEDCC performance degradation indicator and MCRNN[J]. Journal of Vibration and Shock, 2022, 41(24):176－183,233. (in Chinese)
[8] LI X, ZHANG W, DING Q. Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction [J]. Reliability Engineering and System Safety, 2019, 182:208－218.
[9] YAO D C, LI B Y, LIU H C, et al. Remaining useful life prediction of roller bearings based on improved 1D－CNN and simple recurrent unit[J]. Measurement, 2021, 175:1－14.
[10] YANG B Y,LIU R N,ZIO E. Remaining useful life prediction based on a double-convolutional neural network architecture [J]. IEEE Trans. Industrial Electronics, 2019, 66(12):9521－9530.
[11] ZHANG H X,XI X P,PAN R. A two-stage data-driven approach to remaining useful life prediction via long short-term memory networks[J]. Reliability Engineering and System Safety, 2023, 237:1－17.
[12] CHEN J L, JINGH J, CHANG Y H, et al. Gated recurrent unit based recurrent neural network for remaining useful life prediction of nonlinear deterioration process[J]. Reliability Engineering and System Safety, 2019, 185:372－382.
[13] DONG S J, XIAO J F, HU X L, et al. Deep transfer learning based on Bi－LSTM and attention for remaining useful life prediction of rolling bearing[J]. Reliability Engineering and System Safety,2023,230:1－12.
[14] WAN S K, LI X H, ZHANG Y F, et al. Bearing remaining useful life prediction with convolutional long short-term memory fusion networks[J]. Reliability Engineering and System Safety, 2022, 224:1－13.
[15] ZHAN G K,LIU Y T,ZOU Y S,et al. Degradation trend feature generation improved rotating machines RUL prognosis method with limited run-to-failure data[J]. Measurement Science and Technology, 2023, 34(7):1－15.
[16] LIU Yang, DUAN Binbin, YI Cancan, et al. Similarity indicator and CG－CGAN prediction model for remaining useful life of rolling bearings[J]. Measurement Science and Technology, 2024, 35(8): 086107.
[17] XIAO Y, LIU D, CUI L, et al. Heterogeneous graph representation-driven multiplex aggregation graph neural network for remaining useful life prediction of bearings[J]. Mechanical Systems and Signal Processing, 2024, 220:111679.
[18] WU J, JIANG L, LI J, et al. Discovering new prognostic features for the harmonic reducer in remaining useful life prediction [J]. Shock and Vibration, 2023(1): 2381638.
[19] JIA Y, LI Y, XU M, et al. A fault diagnosis scheme for harmonic reducer under practical operating conditions[J]. Measurement, 2024, 227: 114234.
[20] 杜柳青,李宝钏,余永维. 基于混沌表示和特征注意力机制的机床两轴动态误差预测[J]. 农业机械学报,2023,54(11):451－458.
DU Liuqing, LI Baochuan, YU Yongwei. Dynamic error prediction of machine tool two-axis based on chaotic representation and feature attention mechanism[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(11):451－458. (in Chinese)
[21] GUO X F,LIU X W,ZHU E, et al. Deep clustering with convolutional autoencoders[C]//Proceedings of the 24th International Conference on Neural Information Processing,2017:373－382.
[22] 陈久朋,陈治帆,伞红军,等. 基于卷积神经网络的移动机器人自适应光照增强单目视觉 SLAM 算法[J]. 农业机械学报,2024,55(12):383－391,403.
CHEN Jiupeng, CHEN Zhifan, SAN Hongjun, et al. Adaptive illumination enhanced monocular vision SLAM algorithm for mobile robots based on convolutional neural networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(12):383－391,403. (in Chinese)
[23] XUE J K,SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Super Computing, 2022, 79(7):7305－7336.
[24] LEE J H, CHO Y H, KIM D S, et al. Lifetime estimation of harmonic reducer for manufacturing robot using accelerated life test[J]. Journal of Mechanical Science and Technology, 2022, 36:2879－2887.
[25] 张继冬,邹益胜,邓佳林,等. 基于全卷积层神经网络的轴承剩余寿命预测[J]. 中国机械工程,2019,30(18):2231－2235.
ZHANG Jidong, ZOU Yisheng, DENG Jialin, et al. Bearing remaining life prediction based on full convolutional layer neural networks[J]. China Mechanical Engineering, 2019, 30(18):2231－2235. (in Chinese)
[26] 林亮行,马国政,孙建芳,等. 基于 VMD－EEMD－LSTM 的涂层型关节轴承剩余使用寿命预测方法[J]. 机械工程学报,2023,59(9):125－136.
LIN Liangxing, MA Guozheng, SUN Jianfang, et al. Remaining useful life prediction method of coated spherical plain bearing based on VMD－EEMD－LSTM[J]. Journal of Mechanical Engineering, 2023, 59(9):125－136. (in Chinese)
[27] 陈英义,方晓敏,梅思远,等. 基于 WT－CNN－LSTM 的溶解氧含量预测模型[J]. 农业机械学报,2020,51(10):284－291.
CHEN Yingyi, FANG Xiaomin, MEI Siyuan, et al. Dissolved oxygen prediction model based on WT－CNN－LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(10):284－291. (in Chinese)