

文章编号: 2095-2163(2024)02-0144-06

中图分类号: TP393

文献标志码: A

基于全局搜索策略 WOA 优化 ELM 的 RUL 预测性维护

郑晓雨, 樊重俊

(上海理工大学 管理学院, 上海 200093)

摘要: 实时掌握设备的剩余使用寿命(RUL),有助于降低工业互联网制造业中事故成本。为提高预测性维护准确度,使用基于全局搜索策略的鲸鱼优化算法(Improved Whale Optimization Algorithm, IWOA)确定极限学习机(Extreme Learning Machine, ELM)的参数,提出一种新型剩余使用寿命预测模型(IWOA-ELM)。将该模型应用于膜过滤器剩余使用寿命的电子涂层超滤维护数据集,结果表明:与ELM、WOA-ELM预测模型相比,本文提出的IWOA-ELM模型极大地提高了预测精度,泛化能力更强,能有效地预测膜过滤器剩余使用寿命,以便提前计划维护。

关键词: 鲸鱼优化算法; 极限学习机; 预测性维护; 机器学习

Predictive maintenance of RUL based on global search strategy WOA optimized ELM

ZHENG Xiaoyu, FAN Chongjun

(Business school, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Real-time monitoring of equipment's remaining useful life (RUL) is crucial for reducing operational costs in the industrial Internet of Things manufacturing sector. To enhance the accuracy of predictive maintenance, we employ the Improved Whale Optimization Algorithm (IWOA), a global search strategy, to determine the parameters of the Extreme Learning Machine (ELM). This approach leads to the development of a novel RUL prediction model known as IWOA-ELM. We apply this proposed model to an electronic-coated ultrafiltration maintenance dataset for membrane filters' remaining useful life. The results demonstrate that, in comparison to ELM and WOA-ELM prediction models, the IWOA-ELM model significantly improves predictive accuracy, exhibits stronger generalization capabilities, and effectively forecasts the remaining useful life of membrane filters, facilitating proactive maintenance planning.

Key words: WOA; ELM; predictive maintenance; machine learning

0 引言

现代工业化发展趋势下,制造质量控制的应用和需求获得爆发式增长,设备安全运营和维护保障问题日益突出^[1]。为避免设备出现故障造成生产事故,需要对设备制定有效维护计划,以保证制造质量。如何准确地做好设备预测性维护,对于最大化发挥设备性能、减少安全隐患、降低设备维护成本、提高技术人员的作业效率、提升企业整体效益具有极为重要的现实意义。

机器学习在对象识别和图像分类等领域表现出卓越的性能,在金融等其他领域也越来越受欢迎,在这些领域中,时间序列数据起着重要作用。在预测性维护中,根据时间的推移收集数据以监控资产状

态,目的是找到预测故障,从而可以从某些机器学习算法中受益。机器学习能够处理多维数据,并能够在复杂和动态环境中提取数据之间的隐藏关系,在预测性维护中具有很好的应用前景^[2]。传统的预测性维护机器学习模型基于特征工程,存在提取特征能力不足、长期预测能力不足和难以表征非线性函数映射关系的问题。

针对上述问题,许多学者进行了研究与讨论,建立了一系列较为可靠的、适用于预测性维护的理论模型。Sheng等^[3]针对齿轮寿命预测问题,创新地提出了一种基于权值放大的长短时记忆神经网络,通过注意机制将隐藏层中的输入权重和递归权重放大到不同程度,对比实验表明该预测方法具有更高的预测精度;Ren等^[4]针对锂离子电池剩余使

基金项目: 2020 教育部哲学社会科学重大课题攻关项目,2020-2023(20JZD010)。

作者简介: 郑晓雨(1999-),女,硕士研究生,主要研究方向:深度学习。

通讯作者: 樊重俊(1963-),男,博士,教授,博士生导师,主要研究方向:大数据技术。Email: fan.chongjun@163.com

收稿日期: 2023-02-28

用寿命预测问题,提出了一种将自动编码器与深度神经网络集成的学习方法,该方法可以独立于离线训练数据进行预测,可以提高预测电池剩余寿命的准确性;戴邵武等^[5]提出了一种基于时域特征和粒子群算法的支持向量机模型的滚动轴承性能退化趋势预测的方法,可以准确地预测滚动轴承全寿命故障周期;Zou等^[6]针对航空铅酸电池的剩余使用寿命预测问题,创新地提出了一种将基于遗传算法的混合粒子群算法应用于最小二乘支持向量机的参数优化和反向传播神经网络的初始权值选择的预测模型,改进后的最小二乘支持向量机模型更适合预测该类问题;Kim等^[7]提出了一种通过跟踪频率数据簇的中值来预测晶圆运输机器人故障的方法,减少噪音数据对聚类模型的影响,提升剩余寿命预测的准确性;Su等^[8]为检测数据中心将会发生的硬盘驱动器故障,开发了一个基于伯克利数据分析栈(Apache Spark)的实时预测维护系统,系统过程包括两个阶段:使用历史数据生成并训练随机森林模型和使用从终端用户设备收集的数据来进行实时预测,结果表明该系统方法的实时预测准确性达到85%;Kulkarni等^[9]针对早期制冷和冷藏系统故障的预测问题,将时间序列预测问题转化为一个分类问题,采用随机森林模型来预测,正确率能够达到89%;Chen等^[10]提出一种通用的剩余使用寿命预测两步解决方案:第一步,基于核主成分分析对输入数据进行非线性特征提取;第二步,基于门控循环单元对RUL进行预测,该方法训练时间少且预测精度高;Wu等^[11]提出了一种基于动态差分技术的长短期记忆网络模型对航空涡扇发动机的健康检测数据进行处理,该方法实现了较好的RUL预测。这些模型虽然具有一定的有效性与适用性,但存在模型参数难以确定、选择合适的核函数困难、数据输入顺序影响最终结果等问题,因此导致模型存在一定的局限性。

改进后的鲸鱼优化算法具有寻优能力强和全局搜索的优点,极限学习机模型在保证学习精度的前提下比传统的学习算法速度更快,本文将两者的优势融合,提出了一种基于算法的改进后鲸鱼优化极限学习机的预测性维护的综合分析方法。首先,对历史数据进行预处理,清除噪声等干扰,修正异常点,将预处理后的历史数据作为模型输入;其次,利用改进后的全局搜索策略的鲸鱼优化算法进行快速寻优,建立基于全局搜索策略的鲸鱼优化算法的极限学习机的预测性维护模型,可以更为可靠地掌握膜过滤器的剩余使用寿命,更有效地避免设备故障。

1 相关算法

1.1 鲸鱼优化算法

鲸鱼优化算法模拟了鲸鱼泡泡网觅食的方法,每头鲸鱼的位置代表一个可行解,座头鲸觅食的行动轨迹可以看作相应解的更新方式,将算法分为3步:包围捕食、螺旋更新、搜寻猎物。

1.1.1 包围捕食

鲸鱼寻找猎物的时候,需要整个鲸鱼群体通过不断地交流,向距离猎物最近的鲸鱼个体最优位置移动,并且目前离猎物最近的鲸鱼再以随机尝试的方式试图更加靠近猎物,从而使鲸鱼间接地不断靠近猎物。

设鲸鱼种群规模为 N ,第 i 只鲸鱼在 D 维空间的位置为 $X_i = (x_i^1, x_i^2, \dots, x_i^d)$ ($i = 1, 2, \dots, N$), 猎物位置表示问题的全局最优解。在鲸鱼优化算法中,座头鲸包围猎物时行动轨迹的数学表达如式(1)和式(2):

$$\begin{cases} D = |C \cdot X_p(t) - X(t)| \\ X(t+1) = X_p(t) - A \cdot D \end{cases} \quad (1)$$

$$\begin{cases} A = 2a \cdot r_1 - a \\ C = 2 \cdot r_2 \\ a(t) = 2 - \frac{2t}{\max_iter} \end{cases} \quad (2)$$

其中, t 表示当前迭代次数; $X(t)$ 表示个体位置; $X_p(t)$ 表示猎物位置,即当前最优解; r_1 和 r_2 为 $0 \sim 1$ 之间的随机数; A 与 C 为系数向量;收敛因子 a 随着 t 的增加由数值2线性递减为0; \max_iter 表示最大迭代次数。

1.1.2 螺旋更新

发现猎物时,鲸鱼会以猎物为中心通过螺旋方式逼近猎物,达到捕获猎物的目的。算法螺旋更新阶段模仿鲸鱼逼近猎物的数学表达式(3):

$$\begin{cases} D = |C \cdot X_p(t) - X(t)| \\ X(t+1) = D \cdot e^{bl} \cdot \cos(2\pi l) + X_p(t) \end{cases} \quad (3)$$

其中, b 表示对数螺旋形状的常数; l 表示 $-1 \sim 1$ 之间的随机数,当 $l = -1$ 时,鲸鱼与猎物距离最近,当 $l = 1$ 时,鲸鱼与猎物距离最远。

假设鲸鱼个体均以0.5的概率选择收缩包围机制和螺旋更新机制,则其数学模型为式(4):

$$X(t+1) = \begin{cases} X_p(t) - A \cdot D, & p < 0.5 \\ D \cdot e^{bl} \cdot \cos(2\pi l) + X_p(t), & p \geq 0.5 \end{cases} \quad (4)$$

1.1.3 搜寻猎物

为了扩大搜索范围,鲸鱼不再根据最优猎物的位

置来更新自己的位置,而是根据随机选取的鲸鱼位置进行更新。通过 $|A|$ 的值来确定进入搜寻猎物阶段还是进入包围捕食阶段,当 $|A| \geq 1$ 时,算法模拟鲸鱼扩大搜索范围来增强全局搜索能力,其数学表达式(5):

$$\begin{cases} D = |C \cdot X_{rand}(t) - X(t)| \\ X(t+1) = X_{rand}(t) - A \cdot D \end{cases} \quad (5)$$

其中, $X_{rand}(t)$ 表示当前随机选取的鲸鱼个体的位置向量。

1.2 改进后的鲸鱼优化算法

由于鲸鱼优化算法容易出现局部最优、收敛速度和求解精度低的问题,为解决这些问题,对模型进行改进。改进后的算法通过准反向学习法进行种群初始化,提高种群的多样性;其次,将线性的收敛因子改为非线性,平衡全局搜索和局部开发能力;最后,引入自适应权重来改进算法的局部搜索能力,提高收敛精度,并通过随机差分变异策略及时调整算法,避免出现局部最优的问题。

1.2.1 准反向学习初始化种群

基本鲸鱼优化算法的种群初始化采用纯随机策略,即已知某一项基因的上下限,初始化是在上下限之间进行随机取值,最终结果不能保证初始种群的多样性和收敛速度。为克服这些缺点,采用准反向学习初始化种群策略,使用准反向点代替实际的反向点,其中反向点是指关于中心点的对称点,准反向点是指反向点和中心点之间产生的随机点。

设种群中有 N 个鲸鱼,第 i 只鲸鱼在 D 维空间中的位置为 $X_i = (x_i^1, x_i^2, \dots, x_i^D)$,其中 $i = 1, 2, \dots, N$, $x_i^j \in [a_i^j, b_i^j]$ ($j = 1, 2, \dots, D$), a_i^j 和 b_i^j 分别表示 x_i^j 的下界和上界,其对应反向点可由式(6)计算:

$$\hat{x}_i^j = a_i^j + b_i^j - x_i^j \quad (6)$$

为得到更好的效果,采用其对应准反向点可由式(7)计算:

$$\hat{x}_i^j = \begin{cases} rand(\text{avg}_i^j, \hat{x}_i^j), x_i^j \leq \text{avg}_i^j \\ rand(\hat{x}_i^j, \text{avg}_i^j), x_i^j > \text{avg}_i^j \end{cases}, \text{avg}_i^j = \frac{b_i^j - a_i^j}{2} \quad (7)$$

通过最大化种群多样性筛选机制,在初始群体随机产生的 N 个个体和准反向学习获得的 N 个个体合并成的 $2N$ 个个体,选择能够使种群多样性最大的 N 个个体。该筛选机制也能够使种群较快收敛到全局最优解,其数学模型如式(8)所示:

$$fit(X) > fit(\tilde{X})? X, \tilde{X} \quad (8)$$

其中, $fit(X)$ 为适应度函数; X 和 \tilde{X} 分别表示随机产生的个体和准反向学习获得的个体。

1.2.2 非线性收敛因子

在基本鲸鱼优化算法中,参数 $|A|$ 影响鲸鱼是进入全局搜索阶段还是进入局部搜索阶段,当参数 $|A| \geq 1$ 时,鲸鱼个体可能远离猎物,算法以0.5的概率保持较好的全局搜索能力;当 $|A| < 1$ 时,鲸鱼个体向最优鲸鱼的位置移动,提高寻优精度和局部开发能力。基本算法中的线性收敛因子 α 使得算法收敛速度过慢,不能很好地调节全局搜索和局部开发能力。为了加快算法收敛速度,提高寻优精度,本文使用如式(9)所示的非线性收敛因子:

$$\alpha = 2 - 2\sin\left(\mu \frac{t}{\text{max_iter}}\pi + \varphi\right) \quad (9)$$

其中, max_iter 为最大迭代次数; t 为当前迭代次数;相关参数 μ 和 φ 取值为 $\mu = \frac{1}{2}, \varphi = 0$ 。

1.2.3 自适应权重与随机差分法变异策略

在基本鲸鱼优化算法中,前期线性部分的权重较小,可以使鲸鱼个体与最佳鲸鱼位置保持一定的搜索距离,避免出现早熟收敛现象;但在算法后期线性部分的权重和距离最佳鲸鱼位置较近的鲸鱼个体自适应部分的权重均逐渐增大,使得算法在局部开发时易陷入局部最优。为了使算法能够更好地随机探索搜索空间,并能够及时跳出局部最优,本文采用一种自适应权重和随机差分变异策略。

自适应权重策略数学表达式(10)和式(11):

$$\begin{cases} \omega = 1 - \frac{\frac{t}{\text{emax_iter}} - 1}{e - 1} \\ X(t+1) = \omega \cdot X_p - A \cdot D \end{cases} \quad (10)$$

$$X(t+1) = \omega \cdot X_p(t) + D \cdot e^{bl} \cdot \cos(2\pi l) \quad (11)$$

随机差分变异策略如式(12)所示:

$$X(t+1) = r_1 \times (X_p(t) - X(t)) + r_2 \times (X'(t) - X(t)) \quad (12)$$

其中, r_1 和 r_2 均为0~1之间的随机数, $X'(t)$ 为随机选取的个体。

个体采用自适应权重策略去包围捕食或螺旋更新位置,通过随机差分变异策略对其进行再次更新,取其变化前后的最优位置。这种改进方法不仅加快了收敛速度,还能够有效防止陷入局部最优,具有更好的寻优效果。

1.3 极限学习机(ELM)

极限学习机是在单隐藏层前馈神经网络的基础上改进的一种以风险最小化为目标的新型智能学习模型。该模型由输入层、隐藏层和输出层组成,没有

负反馈等过多迭代产生的复杂运算,通过产生权值和偏差,并在训练过程中保持不变,极大地提高了训练速度,同时满足了隐藏层进行非线性运算的需求。极限学习机模型基本结构如图 1 所示。




图 1 极限学习机模型

Fig. 1 Extreme learning machine model

对于 N 个不同的训练样本,当隐藏层有 L 个神经元时,则 ELM 的输出函数可以表示为式(13):

$$y_j = y(x_j) = \sum_{i=1}^L \beta_i h(\omega_i \times x_j + b_i), j = 1, 2, \dots, N \quad (13)$$

其中, x_j 表示第 j 个样本的输入向量; β_i 为隐藏层与输出层之间的权重矩阵; $h(\cdot)$ 表示隐藏层的激活函数; ω_i 表示输入层与隐藏层之间的连接权值; b_i 表示神经元阈值。

ELM 的损失函数为式(14):

$$E = \sum_{j=1}^N \epsilon_j, \epsilon_j = \sum_{i=1}^L \beta_i h(\omega_i \times x_j + b_i) - y_j, \quad j = 1, 2, \dots, N \quad (14)$$

其中, ϵ_j 表示第 j 个样本的误差向量。

通常采用梯度下降法,但存在陷入局部最优解的问题,ELM 求解目标函数最小值则是通过寻找网络最优参数。

式(13)的行列式形式为式(15):

$$Y = HB \quad (15)$$

其中, H 表示隐藏层的输出矩阵, Y 表示目标期望的输出矩阵。

则输出权值矩阵,式(16):

$$\beta = H^{-1}Y \quad (16)$$

ELM 训练过程就是通过不断寻找非线性最优解,最终求得使目标函数最小化的最小二乘解 β 的过程。

ELM 将输入向量映射到具有随机设置和非线性激活函数的随机特征空间中,比训练参数的映射效率更高;ELM 在隐藏层中使用随机参数连接权值和阈值,并在训练过程中保持不变,学习速度快,实现方式简单;ELM 具有非线性分段连续激活函数,具有普遍的逼近能力和泛化能力,适合应用于各种分类、回归预测问题。

1.4 组合模型

由于初始化的权值和阈值对训练结果存在较大影响,为降低极限学习机参数选择的随机性,提高预测的准确性,本文将改进的鲸鱼优化方法与极限学习机相结合构建 IWOA-ELM 模型。在历史数据预处理的基础上,通过改进后的鲸鱼算法优化极限学习机的权值和阈值。IWOA 的适应度函数,式(17):

$$fit(X) = \min \left[\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \right] \quad (17)$$

其中, x_i 表示实际值; \hat{x}_i 表示预测值; N 表示样本容量。

IWOA-ELM 的模型流程如图 2 所示。

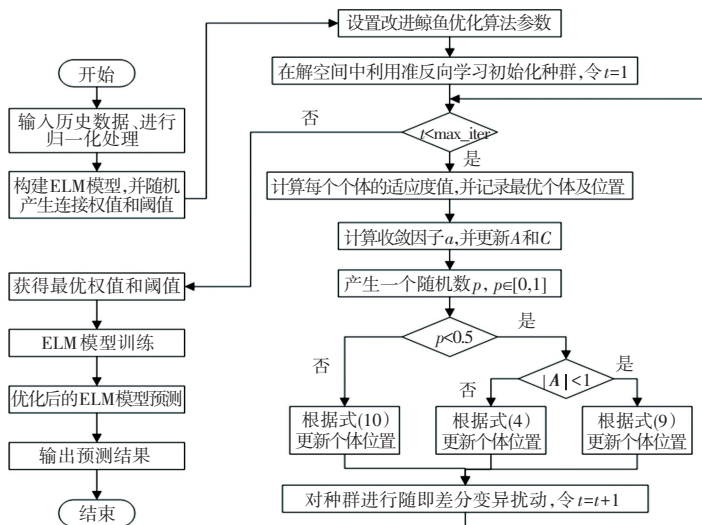


图 2 IWOA-ELM 的模型流程图

Fig. 2 Model flowchart of IWOA-ELM

1.5 模型评价指标

为了验证 IWOA-ELM 模型的预测性能,用均方根误差(RMSE)、平均绝对误差(MAE)和拟合优度(R^2)对预测结果进行评价,计算如式(18)~式(20):

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2} \quad (18)$$

$$MAE = \frac{1}{N} \sum_{n=1}^N |y_n - \hat{y}_n| \quad (19)$$

$$R^2 = 1 - \frac{\sum_{n=1}^N (y_n - \hat{y}_n)^2}{\sum_{n=1}^N (y_n - \bar{y}_n)^2} \quad (20)$$

其中, y_n 、 \hat{y}_n 、 \bar{y}_n 分别表示真实值、预测值和真实值的平均值, N 为样本数量。

2 实验分析

2.1 样本数据预处理

由电泳涂装厂工业物联网系统中采集到的数据,在2013年9月16日至2020年1月7日的110 641条电子涂层超滤维护数据集中选取前50 000条作为研究样本,所有数据特征均为制造过程中的健康指标。经过剔除冗余数据、插值补全数据、插值数据二次修正、特征提取,并在预测前对数据进行归一化处理,式(21):

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (21)$$

其中, x_{\min} 、 x_{\max} 分别表示样本数据的最小值和最大值。

2.2 网络参数设置

对样本数据归一化处理,取数据中前80%作为模型的训练集,剩余的20%作为测试集。输入变量为超滤子系统的输入压力 PE1、超滤子系统的输出压力 PE2、循环子系统的输入压力 PE3、循环子系统的输出压力 PE4、油漆罐体温度 TP1、Unix 时间,输出变量为超滤子系统膜过滤器剩余使用寿命 FM1。输入层节点个数设置为5,输出层节点个数设置为1。通常,隐藏层数越多其非线性拟合能力越强,但隐藏层节点数过大,就会出现过拟合现象,进而影响预测结果。经过多次模型训练,发现当隐藏层节点数设置为10可以获得较好的性能,所以 IWOA-ELM 模型的网络拓扑结构为5-10-1,其中 IWOA 算法的鲸鱼种群数量为20,最大迭代次数为200;ELM 隐藏层的激活函数为 sigmoid 函数。

2.3 预测结果对比分析

为验证 IWOA-ELM 模型在剩余使用寿命预测性维护中的可靠性和有效性,对原始样本数据分别建立 ELM 模型和 WOA-ELM 模型,并对3种模型的预测结果进行分析。WOA 与 IWOA 优化模型预测的迭代过程如图3所示,ELM、WOA-ELM 与 IWOA-ELM 模型的预测结果如图4所示。

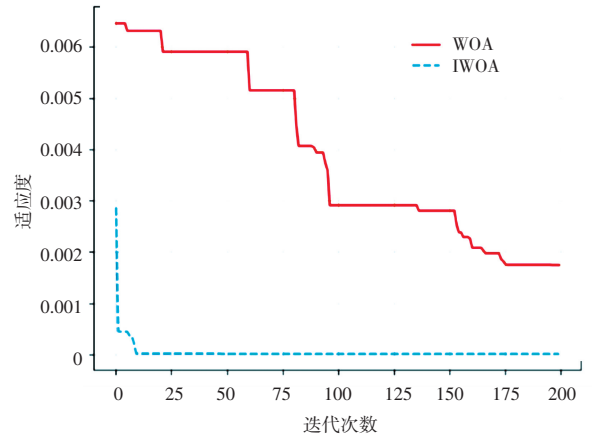


图3 不同模型的迭代过程曲线对比

Fig. 3 Comparison of iterative process curves of different models




图4 膜过滤器剩余使用寿命预测结果对比

Fig. 4 Comparison of predicted results of remaining service life of membrane filter

本文以均方误差最低作为适应度值,由图3可知,IWOA-ELM 的适应度值比 WOA-ELM 小,说明 IWOA 比 WOA 具有更强的跳出局部最优的能力,即 IWOA 的全局搜索性能更好,并且相较于使用 WOA-ELM 模型,使用 IWOA-ELM 模型的收敛速度更快,收敛效率更高。由图4可知,点虚线与实线基本重合,即 IWOA-ELM 模型的预测值与真实值基本重合,说明在相同的条件下,IWOA-ELM 模型预测精度更高。

为了验证 IWOA-ELM 模型的预测精度,与 ELM 模型、WOA-ELM 模型进行比较对比实验。采用均方根误差、平均绝对误差和拟合优度作为评判指标,结果见表 1。由表 1 可知,IWOA-ELM 模型的均方根误差和平均绝对误差分别为 0.000 4 和 0.000 04,优于其他模型;另外,该预测模型的拟合优度达到 99%,比 ELM 模型的和 WOA-ELM 模型的 R^2 更接近于 1,反映出 IWOA-ELM 模型拟合度更高,预测精度更好,证明 IWOA 成功地优化了 ELM 的参数。

表 1 各模型评价指标结果

Table 1 Evaluation index results of each model

模型	均方根误差	平均绝对误差	拟合优度
ELM	0.144 9	0.107 8	0.760 13
WOA-ELM	0.050 6	0.035 9	0.951 4
IWOA-ELM	0.000 4	0.000 04	0.999 99

3 结束语

本文提出了一种 IWOA-ELM 模型用于剩余使用寿命的预测性维护。利用电子涂层超滤维护数据集来验证以上模型的性能。根据实验对比结果,总结如下:

(1)使用 IWOA 算法对 ELM 的参数进行寻优,能够解决 ELM 参数选取的随机性、盲目性、容易陷入局部最优、收敛速度慢等问题,能够提高模型的学习能力和泛化能力,使得预测值更加贴近于真实值;

(2)应用实例的结果表明,IWOA-ELM 模型的各项评价指标均优于 ELM 和 WOA-ELM 模型,可以明显地降低预测误差,为剩余使用寿命预测性维护提供了一种更为可行的新思路。

参考文献

- [1] 周东华,魏慕恒,司小胜. 工业过程异常检测、寿命预测与维修决策的研究进展[J]. 自动化学报,2013,39(6):711-722.
- [2] 李杰其,胡良兵. 基于机器学习的设备预测性维护方法综述[J]. 计算机工程与应用,2020,56(21):11-19.
- [3] XIANG S, QIN Y, ZHU C, et al. Long short-term memory neural network with weight amplification and its application into gear remaining useful life prediction[J]. Engineering Applications of Artificial Intelligence, 2020, 91: 103587.
- [4] LEI R, LI Z, SHENG H, et al. Remaining useful life prediction for lithiumion battery: a deep learning approach[J]. IEEE Access, 2018, 6:50587-50598.
- [5] 戴邵武,陈强强,丁宇. 基于时域特征的滚动轴承寿命预测[J]. 计算机测量与控制,2019,27(10):60-63.
- [6] ZOU T, YANG D, YANG H. Residual life prediction of aviation battery [C]//Proceedings of the 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), Electronic Network. 2020:1757-1760.
- [7] KIM H G, YOON H S, YOO J H, et al. Development of predictive maintenance technology for wafer transfer robot using clustering algorithm [C]//Proceedings of 2019 International Conference on Electronics, Information, and Communication (ICEIC). IEEE, 2019: 1-4.
- [8] SU C J, HUANG S F. Real-time big data analytics for hard disk drive predictive maintenance [J]. Computers and Electrical Engineering, 2018, 71:93-101.
- [9] KULKARNI K, DEVI U, SIRIGHEE A, et al. Predictive maintenance for supermarket refrigeration systems using only case temperature data [C]//Proceedings of 2018 Annual American Control Conference (ACC). IEEE, 2018: 4640-4645.
- [10] CHEN J, JING H, CHANG Y, et al. Gated recurrent unit based recurrent neural network for remaining useful life prediction of nonlinear deterioration process [J]. Reliability Engineering & System Safety, 2019, 185: 372-382.
- [11] WU Y, YUAN M, DONG S, et al. Remaining useful life estimation of engineered systems using vanilla LSTM neural networks[J]. Neurocomputing, 2018, 275: 167-179.