

数字孪生驱动的小样本旋转机械剩余寿命预测

张诚¹, 马梓玮^{2,3}, 刘斌³, 孙铮³, 徐俊^{2,3}

(1. 巴斯夫新材料有限公司研发部, 200137, 上海; 2. 西安交通大学未来技术学院, 710049, 西安;
3. 西安交通大学机械制造系统工程国家重点实验室, 710049, 西安)

摘要: 针对小样本数据下旋转机械剩余使用寿命难以准确预测的问题, 提出一种数字孪生驱动的旋转机械健康因子构建及剩余使用寿命预测方法。通过融合卷积自编码器与 Weibull 分布构建数据驱动的旋转机械退化行为模型。使用旋转机械早期退化信号训练卷积自编码器, 使其学习到早期退化信号模式; 使用卷积自编码器对测试信号进行重构并计算重构误差, 将重构误差映射到 $[0, 1]$ 区间作为健康因子, 根据健康因子拟合 Weibull 可靠度函数并预测旋转机械剩余使用寿命; 在旋转机械持续运行过程中基于实时数据重复上述步骤, 实现旋转机械剩余寿命的实时更新。在 PHM2012 公开数据集上的测试结果表明: 所提方法可以在不需要末期退化信号的前提下预测轴承剩余寿命, 预测结果明显高于现有报道的各类方法, 均方根误差和平均绝对百分比误差分别为 938.8 s 与 42.62%。在巴斯夫新材料有限公司某自动化测试系统数字孪生预测性维护平台的应用案例表明, 所提方法具有实际工业场景下小样本旋转机械寿命预测的可行性。

关键词: 数字孪生; 卷积自编码器; Weibull 分布; 旋转机械; 剩余寿命预测

中图分类号: TH17; TP29 **文献标志码:** A

DOI: 10.7652/xjtuxb202312017 **文章编号:** 0253-987X(2023)12-0168-11

Digital Twin Driven Few-Shot Prediction of Remaining Useful Life for Rotating Machinery

ZHANG Cheng¹, MA Ziwei^{2,3}, LIU Bin³, SUN Zheng³, XU Jun^{2,3}

(1. BASF Advanced Chemicals Co., Ltd., Shanghai 200137, China;

2. School of Future Technology, Xi'an Jiaotong University, Xi'an 710049, China;

3. State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Aiming at accurately predicting the remaining useful life of the rotating machinery with a small size of samples, a digital twin driven method for health index construction and remaining useful life prediction for rotating machinery was proposed. The degradation behavior model was constructed by combining convolutional autoencoder and Weibull distribution theory. Firstly, the convolutional autoencoder was trained with the early degradation signal of the rotating machinery to learn the early degradation signal pattern. Then, the convolutional autoencoder was used to reconstruct the test signal and calculate the reconstruction error, which was mapped into the $[0, 1]$ interval as the health index. Finally, the Weibull reliability function was fitted according to the

收稿日期: 2023-05-10。 作者简介: 张诚(1992—), 男, 工程师; 孙铮(通信作者), 男, 副研究员, 硕士生导师。 基金项目: 国家重点研发计划资助项目(2020YFB1708400)。

网络出版时间: 2023-07-25

网络出版地址: <https://kns.cnki.net/kcms2/detail/61.1069.T.20230724.1637.004.html>

health index to predict the remaining useful life of the rotating machinery. The above steps were repeated during the continuous operation of the rotating machinery based on real-time data. The validation results of PHM2012 public data set show that the proposed method can predict the remaining useful life of bearings without the failure degradation signal, and the predicted results are significantly superior to those predicted by existing methods, with the root mean square error of 938.8 and the mean absolute percentage error of 42.62%. The application of this method in an automated test system digital twin predictive maintenance platform of BASF Advanced Chemicals Co., Ltd. demonstrated the feasibility of the proposed method for few-shot life prediction of rotating machinery in practical industrial scenarios.

Keywords: digital twin; convolutional autoencoder; Weibull distribution; rotating machinery; remaining useful life prediction

旋转机械广泛应用于各种生产生活场景,并且随着生产需求与制造水平的提高,旋转机械的集成化、精密化程度也日益增长。旋转机械应用场景复杂,容易在可变重载、高温摩擦、周期性冲击等恶劣工况下产生退化乃至失效,轻则降低设备精度,影响加工质量,重则设备损坏,生产中断,造成巨大的经济损失和安全威胁。因此,研究旋转机械的剩余使用寿命预测方法有助于指导旋转机械的使用与维护,对保证旋转机械工作质量、提高生产效率有重大意义。

旋转机械剩余使用寿命预测方法主要包括两种:基于机理模型的预测方法与数据驱动的预测方法。前者利用失效机理、概率统计等方法分析旋转机械退化过程,通过理论分析、试验验证等方法构建退化机理模型并进行剩余寿命预测。例如,Cerrada等^[1]提取传感器信号的时域、频域、时频域特征,输入随机森林模型进行齿轮故障诊断。李乃鹏等^[2]融合多传感器数据建立 Wiener 过程模型,可有效预测铣刀剩余使用寿命。此外,小波变换^[3-4]、排列熵^[5-6]、变分模态分解(variational mode decomposition, VMD)^[7-8]等方法也被广泛应用于剩余寿命预测。数据驱动的剩余寿命预测则是基于各类预测算法构建传感器信号与旋转机械剩余使用寿命之间的端到端模型,在大数据支持下无需专家经验与领域知识即可进行旋转机械剩余寿命预测。宋亚等^[9]使用自编码器提取信号高维特征,将提取到的特征,输入双向长短时记忆神经网络进行预测得到剩余使用寿命。Kong 等^[10]和 Yu 等^[11]都结合 CNN 与 LSTM 网络构建时空融合网络来进行剩余使用寿命预测。康涛等^[12]和邓飞跃等^[13]通过向卷积神经网络引入多注意力机制和多尺度特征级联结构,在轴承剩余寿命预测问题上取得了比传统卷积网络更

好的抗噪性能和预测精度。部分学者也尝试构建机理模型与数据驱动模型结合的预测方法,如郑小霞等^[14]利用改进 VMD 方法构建高维故障特征向量并输入深度置信网络进行故障诊断。张弘斌等^[15]使用连续小波变换提取信号时频域特征构造多通道样本,使用多通道样本训练深度卷积神经网络进行剩余寿命预测。Zhao 等^[16]将不同频率的小波包系数输入深度残差神经网络,达到向神经网络引入领域知识的目的,可有效提高预测准确率。

受到应用场景、使用工况、工作时间等因素的影响,旋转机械的剩余寿命通常是动态演化的,上述方法只能预测旋转机械在设计阶段或者使用过程中某一特定时刻的静态平均寿命,无法描述旋转机械的动态退化过程,难以实现剩余寿命的实时在线预测。

数字孪生概念由 Michael Grieves 在 2002 年提出,其核心在于构建实体对象几何、物理、行为、规则等多维度、多领域特征的孪生模型,反应实体对象的运作规律。随着数字孪生概念在工业场景中应用的深入,用户已不满足只通过几何模型反应实体设备运动这类表象型应用,而是希望通过实时数据交互挖掘数据潜在特征,实现孪生模型对物理实体全生命周期的精准映射^[17-18]。使用数字孪生技术可以模拟机械设备的动态退化过程,为剩余寿命精准实时预测提供新方法。Ren 等^[19]提出一种机器学习与数字孪生结合的复杂设备全生命周期数字孪生管理系统框架。许敏俊等^[20]融合钻削毛刺机理模型与循环神经网络,实现对钻削过程的实时仿真监测。付洋等^[21]分析航空发动机涡轮盘损伤机理,使用动态贝叶斯网络与粒子滤波算法建立涡轮盘数字孪生模型,并基于实时采集传感器数据对孪生模型进行动态更新,解决了涡轮盘剩余寿命的在线预测问题。Wang 等^[22]提出一种基于参数灵敏度分析的旋转机

械数字孪生模型修正方案并应用于转子不平衡故障预测问题,预测误差低于5%。

旋转机械通常具有退化周期长、数据密度大、采集成本高的特点,难以采集到大量全生命周期退化信号去构建和训练机理预测模型或数据驱动预测模型,因此传统模型难以在小样本场景下准确预测旋转机械剩余使用寿命。张西宁等^[23]基于迁移学习技术使用数据量充足的源域样本训练神经网络,将神经网络结构和参数迁移到样本不足的目标域进行预测,在小样本下轴承故障诊断任务中取得了较好效果,但是本质上仍然需要源域上大量数据样本的支撑。然而,使用数字孪生技术可以构建旋转机械退化模型以监测退化趋势并预测剩余寿命,同时根据采集到的实时信号迭代更新退化模型,通过退化模型与旋转机械的交互实现旋转机械剩余寿命的动态预测,是解决小样本旋转机械寿命预测难题的有效方法。

基于上述分析,本文提出一种 Weibull 可靠性理论与卷积自编码器(convolutional autoencoder, CAE)结合的数字孪生驱动的旋转机械剩余寿命预测方法 Weibull-CAE。将旋转机械视作实体模型,选择 Weibull 可靠度函数作为旋转机械的退化行为模型。在训练阶段仅需要使用旋转机械早期退化信号训练卷积自编码器。预测阶段将从旋转机械实体模型中获取的实时数据经重构误差计算与映射后得到健康因子,根据健康因子对退化行为模型进行实时迭代更新以反映旋转机械实体模型的实时退化趋势,通过实体模型与退化行为模型的虚实交互实现旋转机械的剩余使用寿命预测。公开数据集上的验证结果与实际应用表明,本文方法具有在小样本旋转机械剩余使用寿命预测问题中的可行性与有效性,为数字孪生技术在旋转机械设备监测运维领域的应用提供了新思路。

1 卷积自编码器

卷积自编码器是一种无监督神经网络算法,由编码器和解码器两个子模块构成,编码器对输入信号进行编码获得输入信号的高阶特征信号,解码器接收高阶特征信号并对其进行解码得到重构信号。卷积自编码器网络结构如图1所示。

给定输入信号 x , CAE 首先将 x 编码为高阶特征 h , 然后将 h 解码为重构信号 $\bar{x}$, 公式表达如下

$$h = f\left(\sum_{i=1}^M x * \omega_i^e + b_i^e\right) \quad (1)$$




图1 一维卷积自编码器结构

Fig. 1 One-dimensional convolutional self-encoder structure

$$\bar{x} = g\left(\sum_{i=1}^N h * \omega_i^d + b_i^d\right) \quad (2)$$

式中: f, g 为非线性激活函数; $*$ 为卷积运算符; ω_i^e, ω_i^d 为卷积编码器、卷积解码器第 i 个通道的卷积核权重; b_i^e, b_i^d 为卷积编码器、卷积解码器第 i 个通道的卷积层偏置。

CAE 对输入信号 x 的重构误差 E 可以用输入信号 x 与重构信号 $\bar{x}$ 之差的欧几里得范数表示

$$E(x, \bar{x}) = \|x - \bar{x}\|_2 \quad (3)$$

CAE 的训练目标是 minimized 训练信号的重构误差。训练后重构误差较小说明 CAE 学习到了训练信号的特征模式,可以在不需要额外信息的前提下提取训练信号的高阶特征。

基于旋转机械早期退化信号训练的 CAE 可以学习到早期退化信号模式,对早期退化信号的重构误差接近 0。随着工作时间的增长和退化程度的加剧,旋转机械的退化信号模式也会逐渐发生变化。由于 CAE 只学习了早期退化信号模式,所以 CAE 对其他退化时期信号的重构误差会随着退化程度的增大而增大,可以利用 CAE 对输入信号的重构误差来判断输入信号对应的旋转机械退化程度。

2 Weibull 退化行为模型

数字孪生技术驱动旋转机械剩余寿命预测的关键在于构建能够准确描述旋转机械退化规律的退化行为模型,并根据旋转机械实时信号对退化行为模型进行迭代更新,使其准确实时地反映旋转机械的当前健康状态、剩余使用寿命以及未来退化趋势。Weibull 分布是可靠性理论中的经典分布,具有灵活性高、可解释性强的优点,广泛应用于各类机械零部件的可靠性建模^[24],适合作为旋转机械的退化行为模型。

典型三参数 Weibull 概率密度函数表达式如下

$$f(t) = \frac{\beta}{\eta} \left(\frac{t-\gamma}{\eta} \right)^{\beta-1} e^{-\left(\frac{t-\gamma}{\eta}\right)^{\beta}} \quad (4)$$

式中: t 为设备已工作时间; η 为尺度参数; β 为形状参数; γ 为位置参数。

实际应用中,通常不考虑位置参数,即默认位置参数为 0,此时三参数 Weibull 分布简化为两参数 Weibull 分布。对两参数 Weibull 概率密度函数积分可得两参数 Weibull 累积分布函数,也称 Weibull 不可靠度,表达式如下

$$F(t) = 1 - e^{-\left(\frac{t}{\eta}\right)^{\beta}} \quad (5)$$

式中: F 表征设备的不可靠度, $F(t) = 1$ 表示设备已经失效, $F(t) = 0$ 表示设备还未开始退化。考虑计算使用的方便性,实际应用中更常用到的是 Weibull 可靠度函数

$$R(t) = 1 - F(t) = e^{-\left(\frac{t}{\eta}\right)^{\beta}} \quad (6)$$

式(6)描述了随着工作时间 t 的增加,设备可靠度的下降趋势。给定 $[0, 1]$ 区间上的可靠度 r_0 ,代入式(6),即可求得设备从初始时刻退化到可靠度等于 r_0 时的理论工作时间 T_0 ,表达式如下

$$T_0 = \eta (-\ln r_0)^{1/\beta} \quad (7)$$

若给定失效阈值可靠度 r_f ,则可根据式(7)计算设备的理论寿命 T_f ,进而计算出当设备可靠度为 r_0 时的剩余使用寿命 T_{rul}

$$T_{rul} = \eta [(-\ln r_f)^{1/\beta} - (-\ln r_0)^{1/\beta}] \quad (8)$$

旋转机械的退化行为模型应当根据实时信号进行模型更新,以保持与旋转机械实体的状态同步,因此需要基于实时数据对 Weibull 可靠度函数进行参数更新。Weibull 可靠度函数是非线性函数,通常使用梯度下降法进行参数更新。

考虑 $t = \{t_1, t_2, \dots, t_N\}$ 时刻根据实时数据计算得到的可靠度 $r = \{r_1, r_2, \dots, r_N\}$,选择平方差作为损失函数。此时,Weibull 可靠度函数的拟合误差为

$$J(r, R(t)) = \sum_{i=1}^N \left(e^{-\left(\frac{t_i}{\eta}\right)^{\beta}} - r_i \right)^2 \quad (9)$$

拟合误差对形状参数与尺度参数的偏导数分别为

$$\frac{\partial J}{\partial \beta} = 2 \sum_{i=1}^N \ln \left(\frac{t_i}{\eta} \right) e^{-\left(\frac{t_i}{\eta}\right)^{\beta}} (r_i - e^{-\left(\frac{t_i}{\eta}\right)^{\beta}}) \left(\frac{t_i}{\eta} \right)^{\beta} \quad (10)$$

$$\frac{\partial J}{\partial \eta} = -2 \sum_{i=1}^N \frac{\beta t_i e^{-\left(\frac{t_i}{\eta}\right)^{\beta}} (r_i - e^{-\left(\frac{t_i}{\eta}\right)^{\beta}})}{\eta^2} \left(\frac{t_i}{\eta} \right)^{\beta-1} \quad (11)$$

给定学习率 α ,对形状参数与尺度参数进行

更新

$$\beta_{t+1} = \beta_t - \alpha \frac{\partial J}{\partial \beta} \quad (12)$$

$$\eta_{t+1} = \eta_t - \alpha \frac{\partial J}{\partial \eta} \quad (13)$$

3 Weibull-CAE 剩余寿命预测方法

3.1 健康因子映射

旋转机械有多种退化失效模式,不同失效情况对应的 CAE 重构误差范围不同,为统一不同失效情况,本文提出映射函数将 $[0, +\infty)$ 区间上的重构误差映射为 $[0, 1]$ 区间上的健康因子(HI)。HI 用于定量描述旋转机械的健康状态,HI 为 1 表示设备还没有开始退化,HI 为 0 表示设备已经完全退化失效。根据重构误差、健康因子的定义与旋转机械的退化规律可知,映射函数应当满足以下要求:

(1)定义域为 $[0, +\infty)$,值域为 $[0, 1]$;

(2)在定义域上单调递减且平滑可导,方便计算;

(3)具有饱和性,在自变量趋近于 0 时函数值趋近于 1,自变量趋近于 $+\infty$ 时函数值趋近于 0。

神经网络中常用的 Sigmoid 函数具有单调性与饱和性

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (14)$$

但是,Sigmoid 函数是单调递增函数,且定义域为 $(-\infty, +\infty)$,值域为 $(0, 1)$ 。为了使 Sigmoid 函数满足上述要求,改进 Sigmoid 函数得到指数映射函数

$$h(E(x, \bar{x})) = \frac{1}{1 + e^{kE(x, \bar{x}) - b}} \quad (15)$$

式中: h 表示重构误差与 HI 的指数映射函数; k 为形状系数; b 为偏置常数

偏置常数 b 保证重构误差较小时 HI 趋近于 1,形状系数 k 用于调节映射函数的递减速率。

健康因子与可靠度定义相同,均为表征旋转机械健康状态的指标,可以互换使用。此外由式(6)可知,可靠度与健康因子的分布区间一致,都为 $[0, 1]$ 。因此,使用式(15)中计算得到的健康因子直接替换可靠度,代入 Weibull 可靠度函数进行相应的拟合构建和参数更新。

3.2 Weibull-CAE 整体结构

本文提出的 Weibull-CAE 剩余寿命预测模型基于 CAE 计算信号重构误差,并通过映射函数将重构误差映射为健康因子,把健康因子作为可靠度

代入 Weibull 退化行为模型进行参数拟合与更新,进而利用式(8)预测剩余使用寿命。数字孪生驱动的 Weibull-CAE 剩余寿命预测模型整体框架如图 2 所示。




图 2 数字孪生驱动的 Weibull-CAE 预测方法架构

Fig. 2 Structure of digital twin-driven Weibull-CAE model

方法架构包括 CAE 与 Weibull 可靠度函数两个部分。CAE 的作用是计算输入信号的重构误差用于后续的健康因子构建,在构建、训练 CAE 时的目标是使 CAE 较好地学习到旋转机械早期退化信号模式。CAE 模型的网络结构参数决定 CAE 的模型复杂度,复杂度过低时 CAE 无法完整反映早期退化信号模式,复杂度过高时 CAE 会记住包含噪声和冗余信息在内的早期退化信号所有特征,两者都会导致 CAE 无法有效学习旋转机械早期退化信号模式,不能准确重构早期退化信号。

考虑到用于 CAE 训练的早期退化信号数据量较小,CAE 模型复杂度不宜太高,因此本文将 CAE 中的解码器和编码器网络都设置为包含两个卷积层的小网络。其中,编码器的两个卷积层由一个最大池化层连接,第二个卷积层后使用非线性激活函数 ReLu 输出高阶特征。解码器中的两个转置卷积层由一个反池化层连接,第二个转置卷积层后同样使用 ReLu 函数作为激活函数,输出由高阶特征还原出的重构信号 $\bar{x}$ 。

Weibull 可靠度函数部分接收 CAE 计算的实时信号重构误差,将重构误差经指数映射函数映射为健康因子后代入 Weibull 可靠度函数进行参数更新,进而预测当前剩余使用寿命。总体预测流程如图 3 所示。

图 3 中剩余寿命预测分为模型训练和实时预测两个阶段。训练阶段具体步骤如下:

(1)采集旋转机械早期退化信号,进行降噪、有效信号截取、归一化等预处理操作;

(2)将预处理后的早期退化信号输入 CAE,计算原始信号与重构信号之间的重构误差;

(3)反向传播重构误差,更新 CAE 网络参数;

(4)重复步骤(2)、(3),直至 CAE 网络收敛。

实时预测阶段具体步骤如下:

(1)采集旋转机械实时振动信号,进行降噪、有效信号截取、归一化等预处理操作;

(2)将预处理后的振动信号输入 CAE,计算原始信号与重构信号之间的重构误差;

(3)使用式(15)将重构误差映射为健康因子;

(4)根据健康因子,使用式(9)~(13)更新 Weibull 可靠度函数参数;

(5)使用式(8)更新当前旋转机械剩余可使用寿命。




图 3 数字孪生驱动的 Weibull-CAE 方法预测流程

Fig. 3 Predict process of digital twin-driven Weibull-CAE model

4 轴承试验台数据验证

4.1 数据集

验证数据选择法国勃艮第-弗朗什孔泰大学 FEMTO 研究所基于 PRO-NOSTIA 轴承加速退化试验台制作的 PHM2012 轴承数据集^[25]。试验台结构如图 4 所示。研究人员在 PRO-NOSTIA 试验台上通过加速寿命试验使滚动轴承在短时间内快速退化失效,在轴承水平和垂直两个方向上布置加速度传感器采集轴承振动信号,采样频率为 25 600 Hz,每隔 10 s 采集一次信号,每次采集 0.1 s 信号,每组采样数据包含 2 560 个数据点。




图 4 PRO-NOSTIA 轴承加速退化试验台

Fig. 4 PRO-NOSTIA bearings accelerated degradation tests platform

PHM2012 数据集包括 3 种工况共 17 组滚动轴承的全生命周期退化信号,每种工况都有 2 组轴承数据作为训练集,其余均为测试集。PHM2012 数据集详细信息如表 1 所示。

表 1 PHM2012 数据集工况信息

Table 1 PHM2012 dataset operating conditions

工况	训练 样本数	测试 样本数	转速/ ($r \cdot \min^{-1}$)	载荷/ N
1	2	5	1 800	4 000
2	2	5	1 650	4 200
3	2	1	1 500	5 000

由于试验中仅给轴承施加水平径向载荷,因此使用水平方向振动信号进行后续分析预测。3 种工况下轴承水平方向振动时域信号如图 5 所示。




图 5 PHM2012 数据集各工况时域信号

Fig. 5 Time domain signals of each operating conditions in PHM2012 dataset

4.2 训练参数设置

原始信号中每组数据包含 2 560 个样本点,为减小 CAE 网络复杂度与计算量,考虑到每组数据都包含至少两个旋转周期的信号,因此只选取前 1 280 个样本点作为输入信号。将每个训练集轴承样本全生命周期前 15% 时间内信号作为早期退化数据。

CAE 模型中:卷积层、转置卷积层的卷积核大小设置为 5,步长设置为 2;池化层与反池化层的池化大小与步长均设置为 4;训练网络时批尺寸大小为 64,训练轮数为 50,学习率设置为 0.001。根据指数映射函数的定义,考虑到偏置常数的作用是使重构误差较小时的 HI 近似为 1,将偏置常数设为 5,此时 $h(0)=0.993$,满足定义。CAE 重构误差为 1 时说明输入信号与早期退化信号有一定差异,旋转机械已处于退化中期或晚期,即 $h(1)<0.5$ 。结合式(15)可得 $k>5$,因此将形状参数 k 设置为 5。Weibull 失效可靠度阈值设定为 0.05,即轴承健康因子小于 0.05 时认为轴承失效。

4.3 模型训练

采用均方根误差(RMSE)与平均绝对百分比误差(MAPE)作为评价指标来衡量模型预测结果,公式分别为


$$E_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (T_i^{\text{true}} - T_i^{\text{pred}})^2} \quad (16)$$

$$E_{\text{MAPE}} = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{T_i^{\text{true}} - T_i^{\text{pred}}}{T_i^{\text{true}}} \right| \quad (17)$$


式中: N 为轴承样本数; T_i^{true} 、 T_i^{pred} 分别为第 i 个轴承样本的实际剩余使用寿命与预测使用寿命。

预测方法的目标是尽可能减小剩余使用寿命真实值与预测值之间的误差,使得 E_{RMSE} 、 E_{MAPE} 趋近于 0。

使用 3.2 小节中的参数训练 CAE 网络,训练集工况 1 中第一个轴承样本(以“1_1”的形式表示)的第一组与最后一组振动信号的重构结果如图 6 所示。可以看出,使用早期退化数据训练的 CAE 能够以较高精度重构早期退化信号,但是无法重构退化末期信号。



(a) 退化早期信号



(b)退化末期信号

图 6 轴承 1_1 振动信号与重构信号对比

Fig. 6 Comparison of 1_1 bearing sample's vibration signal and reconstructed signal

使用训练好的 CAE 网络对训练集中轴承样本 1_1、2_1、3_2 进行重构并分别计算重构误差,结果如图 7 所示。可以看出,3 个轴承样本的重构误差均是前期缓慢上升或保持稳定,后期剧烈上升,符合轴承实际退化规律。




图 7 训练集轴承信号重构误差

Fig. 7 Signal reconstruction error of bearings in train dataset

将图 7 中的振动信号重构误差映射为健康因子,随后进行 Weibull 可靠度函数参数拟合,得到 3 个轴承健康状态变化趋势及对应的 Weibull 可靠度曲线,如图 8 所示。可以看出,各个轴承样本在退化早期、中期的 Weibull 可靠度函数拟合误差偏大,而




图 8 训练集轴承健康因子及 Weibull 可靠度函数曲线

Fig. 8 HI and Weibull reliability function curve of bearings in train dataset

在退化晚期时的拟合误差则较小。这是因为轴承工作时间越长,对应的健康因子数量越多,因此可靠度函数曲线的拟合效果越好,越能更加精确地反映轴承退化趋势。上述结果也验证了使用 Weibull 可靠度函数描述轴承退化趋势的可行性。

4.4 结果对比与分析

使用同样方法对测试集轴承样本进行信号重构与重构误差计算、健康因子映射、Weibull 可靠度函数参数更新。以测试集轴承样本 1_3 为例,其重构误差如图 9 所示。




图 9 测试集轴承 1_3 重构误差

Fig. 9 Signal reconstruction error of 1_3 bearing sample

从图 9 可知,轴承样本 1_3 前 12 500 s 内的重构误差在 0.3~0.4 范围内保持稳定,从 13 000 s 开始重构误差开始随工作时间增加而快速上升,说明此时轴承 1_3 已经进入快速退化阶段。

轴承样本 1_3 测试集包含轴承全生命周期内前 18 010 s 信号,选择前 2 700 s 信号作为 CAE 训练数据,此后每隔 1 000 s 更新一次 Weibull 可靠度函数并预测当前轴承剩余寿命,结果如图 10 所示。可以看出,随着实时数据的累积与 Weibull 可靠度函数参数的迭代更新,Weibull-CAE 预测方法的预测退化趋势与旋转机械实际退化趋势的误差逐渐减小,剩余寿命预测精度也逐渐提高, E_{MAPE} 从 60% 逐渐下降到 20%。




图 10 测试集轴承 1_3 剩余寿命实时迭代预测结果

Fig. 10 Iterative RUL prediction result of 1_3 bearing sample

图 11 为使用 Weibull-CAE 方法预测轴承 1_3 样本剩余寿命时对应的健康因子及 Weibull 可靠度函数。可以看出,此时实时信号的重构误差为 0.75,对应可靠度为 0.845。迭代更新得到的 Weibull 可靠度函数尺度参数 $\eta=21\ 865$,形状参数 $\beta=8.86$,根据式(8)可得此时剩余寿命为 6 876 s,实际剩余寿命为 5 730 s,预测 E_{MAPE} 为 20%。




图 11 测试集轴承 1_3 剩余寿命预测结果

对其余各测试集轴承样本进行相同操作预测剩余使用寿命,计算 E_{RMSE} 、 E_{MAPE} ,与其他常用传统方法进行对比,结果如表 2 所示。可以看出,本文 Weibull-CAE 预测方法的 E_{RMSE} 、 E_{MAPE} 指标都好于其余两种方法, E_{MAPE} 指标相比于 RNN-HI、SOM-HI 方法分别提升 4.15%、10.62%, E_{RMSE} 指标则分别提升了 30.1%、34.4%,并且本文方法的剩余寿命预测偏差方差较小,预测结果更稳定。这是因为本文 Weibull-CAE 预测方法引入 Weibull 可靠度函数描述轴承退化趋势,并基于数字孪生技术使用实时数据对 Weibull 可靠度函数进行迭代更新,能够实时准确反映轴承退化趋势,从而使得预测结果具有更高精度。同时,本文数字孪生驱动的 Weibull-CAE 预测方法仅需少量早期退化数据用于模型训练,能够在小样本情况下预测旋转机械剩余使用寿命并通过与实时数据的交互进行模型迭代更新,使预测精度随着设备工作时间的增加和数据量的累积而提高。

Fig. 11 RUL prediction result of 1_3 bearing sample

表 2 PHM2012 数据集不同方法预测结果对比

Table 2 Comparison of prediction results of different algorithms on the PHM2012 dataset

轴承	已使用时间/s	实际剩余寿命/s	本文方法预测 剩余寿命/s	本文方法		RNN-HI ^[26]		SOM-HI ^[27]	
				$E_{\text{MAPE}}/\%$	E_{RMSE}/s	$E_{\text{MAPE}}/\%$	E_{RMSE}/s	$E_{\text{MAPE}}/\%$	E_{RMSE}/s
1_3	18 010	5 730	6 876	20.00	1 146.0	43.28	2 480.0	1.05	60.0
1_4	11 380	339	356	5.01	17.0	224.48	761.0	20.94	71.0
1_5	23 010	1 610	862	46.46	748.0	22.98	370.0	278.26	4 480.0
1_6	23 010	1 460	899	38.42	561.0	21.23	310.0	19.18	280.0
1_7	15 010	7 570	6 842	9.62	728.0	17.83	1 350.0	7.13	540.0
2_3	12 010	7 530	5 996	20.37	1 534.0	37.85	2 850.0	10.49	790.0
2_4	6 110	1 390	2 768	99.14	1 378.0	19.42	270.0	51.80	720.0
2_5	20 010	3 090	3 220	4.21	130.0	54.37	1 680.0	28.80	890.0
2_6	5 710	1 290	2 786	115.97	1 496.0	13.95	180.0	20.93	270.0
2_7	1 710	580	745	28.45	165.0	55.17	320.0	44.83	260.0
3_3	3 510	820	1 486	81.22	666.0	3.66	30.0	3.66	30.0
平均值				42.62	938.8	46.75	1 346.3	53.24	1 430.9

注:表中加粗数据为最优值。

5 工程应用

本文数字孪生驱动的 Weibull-CAE 剩余寿命预测方法目前已在上海巴斯夫新材料有限公司某实验室自动化测试系统数字孪生预测性维护平台上部署。该数字孪生预测性维护平台旨在融合自动化测

试系统的几何、物理、行为、规则多维模型构建测试系统孪生模型,方便实验人员与运维人员通过孪生模型进行测试过程的远程监测与运维。Weibull-CAE 剩余寿命预测方法以图 12 所示自动化测试平台中某试验机构联轴器为应用对象,构建联轴器退化行为模型以预测其健康状态与剩余使用寿命,并

将预测结果实时展示在数字孪生预测性维护平台中。




图 12 自动化测试系统某试验机构三维模型

Fig. 12 3D model of a test mechanism in automatic test system

联轴器工作时的力矩信号可以反映联轴器的健康状态,健康状态下的力矩信号如图 13 所示。




图 13 自动化测试系统联轴器对应力矩信号

Fig. 13 Torque signals of coupling in automatic test system

由于该自动化测试系统搭建完成后投入使用时间较短且联轴器的工作寿命较长,因此缺少联轴器的全生命周期退化数据,传统剩余寿命预测方法无法用于预测联轴器剩余使用寿命,使用本文方法则可以解决这一问题。根据历史情况及专家经验给定一个合适的联轴器初始 Weibull 可靠度函数,既可以在早期退化数据不足时作为对退化趋势的事先预估为现场人员提供参考,也可以使 Weibull 可靠度函数更快更准确地逼近旋转机械真实退化趋势。通过截取联轴器工作时的力矩信号,使用本文数字孪生驱动的 Weibull-CAE 方法对给定的初始 Weibull 可靠度函数进行基于实时数据的参数迭代更新,实时预测联轴器当前的剩余使用寿命以及健康状态变化趋势,最终预测结果如图 14 所示。




图 14 联轴器剩余寿命预测结果

Fig. 14 RUL prediction result of coupling

6 结 论

针对旋转机械剩余使用寿命中存在的退化数据少、失效模式多等问题,本文提出一种数字孪生驱动的卷积自编码器与 Weibull 分布结合的 Weibull-CAE 预测方法来建立旋转机械退化行为模型,本文主要结论如下。

(1) 本文所提方法根据旋转机械的早期退化信号,在无全生命周期训练数据集的情况下使用卷积自编码器评估旋转机械当前信号与早期信号的差异,基于该差异构建健康因子并拟合 Weibull 可靠度函数以描述旋转机械动态退化过程并实时预测当前设备剩余使用寿命。试验结果表明,该方法仅需要早期退化数据即可预测剩余寿命,并且随着实时数据的增多,预测精度也会逐渐提高,具有较高的实用性。

(2) 在 PHM2012 轴承公开数据集上的剩余寿命预测对比试验中,对于无全生命周期数据测试集,本文方法的 E_{MAPE} 、 E_{RMSE} 两个指标分别为 42.62%、938.8 s,优于其他现有预测方法,具有更好的预测精度。考虑到实际应用中通常会进行提前设备维护以避免对生产运行造成影响,本文方法能够反映设备大体退化趋势,其预测结果也能够一定程度上作为维护更换时间的辅助决策依据。

(3) 在缺乏全生命周期退化数据的情况下对某自动化测试系统中的联轴器部件进行退化趋势与剩余使用寿命预测,验证了本文方法在小样本情况下对旋转机械剩余寿命预测的可行性与有效性。

(4) 下一步工作是在已有方法基础上研究不同失效模式下 CAE 重构误差的变化规律,以期建立更加准确的重构误差与健康因子映射关系。

参考文献:

- [1] CERRADA M, ZURITA G, CABRERA D, et al. Fault diagnosis in spur gears based on genetic algorithm and random forest [J]. *Mechanical Systems and Signal Processing*, 2016, 70-71: 87-103.
- [2] 李乃鹏, 蔡潇, 雷亚国, 等. 一种融合多传感器数据的数模联动机械剩余寿命预测方法 [J]. *机械工程学报*, 2021, 57(20): 29-37, 46.
- LI Naipeng, CAI Xiao, LEI Yaguo, et al. A model-data-fusion remaining useful life prediction method with multi-sensor fusion for machinery [J]. *Journal of Mechanical Engineering*, 2021, 57(20): 29-37, 46.
- [3] 李宏坤, 刘洪轶, 徐福健, 等. 连续小波最优重构尺度确定方法与故障早期识别 [J]. *机械工程学报*, 2014, 50(17): 69-76.
- LI Hongkun, LIU Hongyi, XU Fujian, et al. Method for the optimal continuous wavelet reconstruction scale determination and early fault classification [J]. *Journal of Mechanical Engineering*, 2014, 50(17): 69-76.
- [4] WANG Dong, ZHAO Yang, YI Cai, et al. Sparsity guided empirical wavelet transform for fault diagnosis of rolling element bearings [J]. *Mechanical Systems and Signal Processing*, 2018, 101: 292-308.
- [5] 冯辅周, 司爱威, 江鹏程. 小波相关排列熵和 HMM 在故障预测中的应用 [J]. *振动工程学报*, 2013, 26(2): 269-276.
- FENG Fuzhou, SI Aiwei, JIANG Pengcheng. Application of wavelet correlation permutation entropy and hidden Markov model to fault prognostic [J]. *Journal of Vibration Engineering*, 2013, 26(2): 269-276.
- [6] 贾峰, 武兵, 熊晓燕, 等. 基于多维度排列熵与支持向量机的轴承早期故障诊断方法 [J]. *计算机集成制造系统*, 2014, 20(9): 2275-2282.
- JIA Feng, WU Bing, XIONG Xiaoyan, et al. Early fault diagnosis of bearing based on multi-dimension permutation entropy and SVM [J]. *Computer Integrated Manufacturing Systems*, 2014, 20(9): 2275-2282.
- [7] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用 [J]. *西安交通大学学报*, 2015, 49(5): 73-81.
- TANG Guiji, WANG Xiaolong. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of rolling bearing [J]. *Journal of Xi'an Jiaotong University*, 2015, 49(5): 73-81.
- [8] 杨润贤, 郭林炆, 周正平, 等. 基于 EVMD 和 SODN 的滚动轴承故障识别研究 [J]. *机电工程*, 2021, 38(10): 1221-1229.
- YANG Runxian, GUO Linyang, ZHOU Zhengping, et al. Fault identification of rolling bearing based on EVMD & SODN [J]. *Journal of Mechanical & Electrical Engineering*, 2021, 38(10): 1221-1229.
- [9] 宋亚, 夏唐斌, 郑宇, 等. 基于 Autoencoder-BLSTM 的涡扇发动机剩余寿命预测 [J]. *计算机集成制造系统*, 2019, 25(7): 1611-1619.
- SONG Ya, XIA Tangbin, ZHENG Yu, et al. Remaining useful life prediction of turbofan engine based on autoencoder-BLSTM [J]. *Computer Integrated Manufacturing Systems*, 2019, 25(7): 1611-1619.
- [10] KONG Zhengmin, CUI Yande, XIA Zhou, et al. Convolution and long short-term memory hybrid deep neural networks for remaining useful life prognostics [J]. *Applied Sciences*, 2019, 9(19): 4156.
- [11] YU Shuyang, WU Zhenyu, ZHU Xinning, et al. A domain adaptive convolutional LSTM model for prognostic remaining useful life estimation under variant conditions [C]//2019 Prognostics and System Health Management Conference (PHM-Paris). Piscataway, NJ, USA: IEEE, 2019: 130-137.
- [12] 康涛, 段蓉凯, 杨磊, 等. 融合多注意力机制的卷积神经网络轴承故障诊断方法 [J]. *西安交通大学学报*, 2022, 56(12): 68-77.
- KANG Tao, DUAN Rongkai, YANG Lei, et al. Bearing fault diagnosis using convolutional neural network based on a multi-attention mechanism [J]. *Journal of Xi'an Jiaotong University*, 2022, 56(12): 68-77.
- [13] 邓飞跃, 丁浩, 郝如江. 基于多尺度特征融合残差神经网络的旋转机械故障诊断 [J]. *振动与冲击*, 2021, 40(24): 22-28, 35.
- DENG Feiyue, DING Hao, HAO Rujiang. Fault diagnosis of rotating machinery based on residual neural network with multi-scale feature fusion [J]. *Journal of Vibration and Shock*, 2021, 40(24): 22-28, 35.
- [14] 郑小霞, 陈广宁, 任浩瀚, 等. 基于改进 VMD 和深度置信网络的风机易损部件故障预警 [J]. *振动与冲击*, 2019, 38(8): 153-160, 179.
- ZHENG Xiaoxia, CHEN Guangning, REN Haohan, et al. Fault detection of vulnerable units of wind turbine based on improved VMD and DBN [J]. *Journal of Vibration and Shock*, 2019, 38(8): 153-160, 179.
- [15] 张弘斌, 袁奇, 赵炳锡, 等. 采用多通道样本和深度卷积神经网络的轴承故障诊断方法 [J]. *西安交通大学学报*, 2020, 54(8): 58-66.
- ZHANG Hongbin, YUAN Qi, ZHAO Bingxi, et al. Bearing fault diagnosis with multi-channel sample and deep convolutional neural network [J]. *Journal of Xi'*

- an Jiaotong University, 2020, 54(8): 58-66.
- [16] ZHAO Minghang, KANG M, TANG Baoping, et al. Deep residual networks with dynamically weighted wavelet coefficients for fault diagnosis of planetary gearboxes [J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4290-4300.
- [17] 陶飞, 刘蔚然, 张萌, 等. 数字孪生五维模型及十大领域应用 [J]. 计算机集成制造系统, 2019, 25(1): 1-18.
- TAO Fei, LIU Weiran, ZHANG Meng, et al. Five-dimension digital twin model and its ten applications [J]. Computer Integrated Manufacturing Systems, 2019, 25(1): 1-18.
- [18] 陶飞, 张贺, 戚庆林, 等. 数字孪生模型构建理论及应用 [J]. 计算机集成制造系统, 2021, 27(1): 1-15.
- TAO Fei, ZHANG He, QI Qinglin, et al. Theory of digital twin modeling and its application [J]. Computer Integrated Manufacturing Systems, 2021, 27(1): 1-15.
- [19] REN Zijie, WAN Jiafu, DENG Pan. Machine-learning-driven digital twin for lifecycle management of complex equipment [J]. IEEE Transactions on Emerging Topics in Computing, 2022, 10(1): 9-22.
- [20] 许敏俊, 刘世民, 沈慧, 等. 数字孪生驱动下的弱刚性钻削毛刺控制 [J]. 计算机集成制造系统, 2023, 29(4): 1115-1126.
- XU Minjun, LIU Shimin, SHEN Hui, et al. Burr control of weak rigid drilling process driven by digital twin [J]. Computer Integrated Manufacturing Systems, 2023, 29(4): 1115-1126.
- [21] 付洋, 曹宏瑞, 郜伟强, 等. 数字孪生驱动的航空发动机涡轮盘剩余寿命预测 [J]. 机械工程学报, 2021, 57(22): 106-113.
- FU Yang, CAO Hongrui, GAO Weiqiang, et al. Digital twin driven remaining useful life prediction for aero-engine Turbine discs [J]. Journal of Mechanical Engineering, 2021, 57(22): 106-113.
- [22] WANG Jinjiang, YE Lunkuan, GAO R X, et al. Digital Twin for rotating machinery fault diagnosis in smart manufacturing [J]. International Journal of Production Research, 2019, 57(12): 3920-3934.
- [23] 张西宁, 余迪, 刘书语. 基于迁移学习的小样本轴承故障诊断方法研究 [J]. 西安交通大学学报, 2021, 55(10): 30-37.
- ZHANG Xining, YU Di, LIU Shuyu. Fault diagnosis method for small sample bearing based on transfer learning [J]. Journal of Xi'an Jiaotong University, 2021, 55(10): 30-37.
- [24] WEIBULL W. A statistical distribution function of wide applicability [J]. Journal of Applied Mechanics, 1951, 18(3): 293-297.
- [25] NECTOUX P, GOURIVEAU R, MEDJAHHER K, et al. PRONOSTIA : an experimental platform for bearings accelerated degradation tests [C]//IEEE International Conference on Prognostics and Health Management (PHM2012). Piscataway, NJ, USA: IEEE, 2012: 1-8.
- [26] GUO Liang, LI Naipeng, JIA Feng, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings [J]. Neurocomputing, 2017, 240: 98-109.
- [27] HONG Sheng, ZHOU Zheng, ZIO E, et al. Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method [J]. Digital Signal Processing, 2014, 27: 159-166.

(编辑 陶晴)