

万晓凡, 封士瑞, 张营. 基于深度学习的滚动轴承剩余使用寿命预测[J]. 智能计算机与应用, 2024, 14(9): 125-130. DOI: 10.20169/j.issn.2095-2163.240919

基于深度学习的滚动轴承剩余使用寿命预测

万晓凡, 封士瑞, 张营

(南京林业大学汽车与交通工程学院, 南京 210037)

摘要: 滚动轴承是机械传动设备的“关节点”, 对其进行剩余使用寿命预测对机械设备安全生产和维护有重要意义, 本文提出一种基于粒子群优化算法配合深度学习的滚动轴承剩余使用寿命预测模型。首先, 对滚动轴承振动信号进行时域、频域和时频域特征提取, 利用单调性和鲁棒性筛选出能够反映轴承退化过程的敏感特征; 其次, 基于高斯混合模型提取健康因子, 解决单一特征指标无法有效反映退化趋势的问题; 最后, 将粒子群优化后的网络结构参数输入模型中进行轴承的剩余使用寿命预测, 通过两组数据集的预测结果比较发现, 粒子群优化后双向长短时记忆神经网络模型预测精度比双向长短时记忆神经网络的模型提高约 10.6% 和 24.7%。

关键词: 滚动轴承; 剩余使用寿命; 深度学习

中图分类号: TB389.1

文献标志码: A

文章编号: 2095-2163(2024)09-0125-06

Prediction of remaining useful life of rolling bearing based on deep learning

WAN Xiaofan, FENG Shirui, ZHANG Ying

(College of Automotive and Transportation Engineering, Nanjing Forestry University, Nanjing 210037, China)

Abstract: Rolling bearings are the "joint points" of mechanical transmission equipment, and the prediction of their remaining service life is of great significance to the safe production and maintenance of mechanical equipment. In this paper, a prediction model for the remaining service life of rolling bearings based on deep learning is proposed. Firstly, the time-domain, frequency-domain and time-frequency domain features of the rolling bearing vibration signal were extracted, and the sensitive features that could reflect the bearing degradation process were screened out by using monotonicity and robustness. Secondly, the health factors were extracted based on the Gaussian mixture model to solve the problem that a single characteristic index could not effectively reflect the degradation trend. Finally, the network structure parameters of the particle swarm optimization are input into the model to predict the remaining service life of the bearing, and the prediction accuracy of the two-way long short-term memory neural network model after particle swarm optimization is about 10.6% and 24.7% higher than that of the two-way long short-term memory neural network model.

Key words: rolling bearing; remaining useful life; deep learning

0 引言

工业 4.0 时代下, 科技进步驱使机械设备向规模化、智能化方向发展, 这对机械部件的可靠性提出更严格的要求。因此故障预测与健康管理系统 (Prognostics Health Management, PHM) 被提出, 利用历史数据进行分析, 对机械设备进行剩余使用寿命 (Remaining Useful Life, RUL) 预测、辅助维修等^[1]。PHM 系统几十年的不断开发更新, 许多创新性的寿

命预测方法得到实际验证, 一些成熟的网络训练模型在某些重要领域得到应用, 大数据时代下的轴承寿命预测更科技化。滚动轴承 RUL 主要预测方法有基于物理的方法和基于机器学习的方法。

基于物理的方法就是采集机械装备的运行数据去构建数学模型, 通过机械设备的历史数据同失效退化公式结合的模式来预测设备的剩余使用寿命。刘晨辉等^[2]在提取出滚动轴承全寿命周期的振动信号特征后, 采用了果蝇优化算法 (Fruit fly

作者简介: 万晓凡 (1996-), 男, 硕士研究生, 主要研究方向: 载运工具状态监测与故障诊断; 封士瑞 (1995-), 男, 硕士研究生, 主要研究方向: 载运监测与诊断。

通讯作者: 张营 (1985-), 男, 博士, 副教授, 主要研究方向: 故障预测与健康管理系统。Email: zhangyingrms@163.com

收稿日期: 2023-06-05

Optimization Algorithms, FOA) 和极限梯度提升树 (Extreme Gradient Boosting, XGBoost) 的滚动轴承退化评估方法, 对轴承 RUL 预测的参数进行自动调节, 试验证明该方法相对于传统的轴承退化评估方法, RUL 预测性能提升超过 25%; 孟祥龙等^[3]在对轴承振动信号分解后, 将多种敏感特征输入变分自编码器进行融合降维, 来构建综合性能退化指标, 试验验证多特征融合的特征可以更深层次的表征轴承的退化趋势。但智能化发展的时代下, 设备的实时数据样本获取困难, 退化趋势难以掌握, 对研究员的知识储备更加严格, 极大限制了物理失效模型的发展。

机器学习是近年来比较流行的预测方法, 滚动轴承剩余寿命预测模型开始广泛添加各类机器学习算法。An 等^[4]提出一种剩余维护时间的方法, 利用信息熵提取鲁棒退化特征, 从退化特征中发现一些重要属性, 用于预测轴承的剩余使用寿命, 在 FEMTO-ST 公共数据集上预测精度提升了 10% 左右; 王哲等^[5]提出了一种基于深度学习理论的卷积神经网络模型, 对轴承剩余使用寿命进行预测, 该网络模型可以堆叠大量的卷积层从而抽取到丰富的语义特征。虽然机器学习先进的算法能够解决预测过程许多复杂的问题, 但长序列输入处理存在内存限制, 不利于训练样本批量处理, 且训练时样本间的关

联性不够, 造成早期训练数据丢失、影响预测精度、训练速度慢、准确度低等问题。

综上, 本文提出一种自注意力机制 (Self-Attention, SA)、卷积神经网络 (Convolutional Neural Networks, CNN)、粒子群优化 (Particle Swarm Optimization, PSO) 以及双向长短时记忆神经网络 (Bi-directional Long-Short Term Memory, BiLSTM) 组合的剩余使用寿命预测模型 SA-CNN-PSO-BiLSTM, 利用 PHM 2012 挑战赛的滚动轴承数据集 Bearing2-3 和 Bearing2-5 验证 SA-CNN-PSO-BiLSTM 模型的预测。

1 滚动轴承特征提取

1.1 时域、频域特征提取

时域特征是衡量信号特征的重要指标, 代表特征有均值、均方根和峭度, 如图 1 所示。频域特征也可以观察滚动轴承全寿命频率的组成以及各个组成部分幅值、能量大小的分布状况^[6], 代表特征有频域幅值平均值、信号面积和平均频率, 如图 2 所示。滚动轴承在运行过程中出现失效故障时, 振动信号的频率幅值大小和变化位置在有波动的情况下, 时域分析比较直观, 频域分析更为简便, 使用频域和时域共同分析问题已然成为趋势^[7]。




图 1 时域特征

Fig. 1 Time-domain features




图 2 频域特征

Fig. 2 Frequency-domain features

1.2 时频域特征提取

滚动轴承的工作环境通常是复杂且多变的,因此传感器测得的振动信号通常具有非平稳、随时间变化的特点。时域或频域无法观察非平稳振动信号的频率随时间变化的情况,不能局部分析振动信号。而借助时频域分析方法可以确定滚动轴承的健康状

况信息^[8]。

时频域代表特征为能量比和能量熵,需要对轴承原始振动信号使用变分模态分解 (Variational Mode Decomposition, VMD) 分解信号获得内涵模态分量 (Intrinsic Mode Functions, IMF), 如图 3 所示。通过计算 IMF 得到能量比和能量熵。




图 3 IMF1-IMF5 分量图

Fig. 3 IMF 1 to IMF 5 component plot

原始振动信号进行 VMD 分解后,需要计算 IMF 的能量比特征、能量熵。

能量比可以作为轴承退化特征的输入量,可以计算各个阶段 IMF 的能量占比状况:

$$R_m = \frac{E_m(t)}{\sum_m E_m(t)} \quad (1)$$

其中, $E_m(t)$ 为 IMF1 ~ IMF5 各个阶段 IMF 的能量。

能量熵可以有效提取轴承性能下降的特征,计算公式如下:


$$s_m = - \sum_{i=1}^N \sum_m R_m \quad (2)$$

其中, R_m 为能量比。

提取的能量比和能量熵如图 4 所示,可以看出两者的退化特征趋势不是很明显,无法作为预测模型的输入。

1.3 构建敏感退化特征集

选择与轴承退化趋势相关度高的特征参数,去除无效特征,不仅可以反映轴承的状态信息同时还可以减少模型的运算量。选用单调性 (Mon)、鲁棒性 (Rob) 和综合指标 ($Cori$) 对提取的特征进行筛选^[9]。



(a) 能量比 (b) 能量熵

图 4 能量比和能量熵特征

Fig. 4 Energy ratio characteristics and energy entropy characteristics

$$Mon = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (3)$$

$$Rob = \frac{1}{N} \sum_{n=1}^N \exp\left(-\left|\frac{x_i - x_i^T}{x_i}\right|\right) \quad (4)$$

$$Cori = w_1 Mon + w_2 Rob \quad (5)$$

其中, d_i 是两个变量排名之间的差; n 是数据点数量; N 为序列总长度; x_i 是样本对应的特征值; x_i^T 是样本经过平滑后得到的平均趋势特征值; w_1 、 w_2 为权重指数,一般都取 0.5。

时域、频域、时频域特征计算的综合指标统计如图 5 所示,排名越靠前说明与滚动轴承寿命越相关,本文选取综合指标排名前 10 的特征作为预测模型的输入,不仅能提高预测精度还可减少模型的计算时

间。




图5 特征综合评价指标统计

Fig. 5 Statistics of comprehensive evaluation index of characteristics

2 特征融合

为解决单一特征指标无法有效反映滚动轴承的退化趋势问题,本文提出基于高斯混合模型(Gaussian Mixture Model, GMM)提取健康因子以及运用贝叶斯推断距离(Bayesian Inference-based Distance, BID)去测试数据与健康状态高斯模型的距离作为反应滚动轴承退化程度的定量指标,即GMM-BID模型。BID值是由分量概率 $p(C_k | x_t)$ 和分量距离 $D_{C_k}(x_t)$ 相乘得出,分量概率 $p(C_k | x_t)$ 计算公式如下:

$$p(C_k | x_t) = \frac{\alpha_k p(x_t | C_k)}{p(x_t)} = \frac{\alpha_k p(x_t | C_k)}{\sum_{i=1}^K \alpha_i p(x_t | C_i)} \quad (6)$$

其中, C_k 为 K 个高斯分量中的第 k 个分量; α_k 为 C_k 出现的概率,可由建模数据求得; x_t 为测试数据的测试点。

$p(x_t | C_k)$ 是先验概率,计算公式如下:

$$p(x_t | C_k) = \frac{1}{(2\pi)^{\frac{1}{2}} |S_k|^{\frac{1}{2}}} \exp\left[-\frac{1}{2}(x_t - \mu_k)^T S_k^{-1}(x_t - \mu_k)\right] \quad (7)$$

其中, μ_k 为第 k 个高斯分量的均值, S_k 为协方差矩阵。

定义到每个分量 C_k 的距离,即求分量距离 $D_{C_k}(x_t)$,计算公式如下:

$$D_{C_k}(x_t) = (x_t - \mu_k)^T S_k^{-1}(x_t - \mu_k) \quad (8)$$

最后,将测试点 x_t 的每个分量的距离进行加权求和,求得贝叶斯推断距离,即BID值,计算公式如下:

$$BID = \sum_{k=1}^K p(C_k | x_t) D_{C_k}(x_t) \quad (9)$$

通过GMM-BID模型提取健康因子进行特征融合后得到的BID值,可以直观看出滚动轴承的退化

趋势,如图6所示。本文使用2012 PHM挑战赛公开的滚动轴承失效数据集 Bearing,大赛定义轴承失效时的振幅为 $20g$ ^[9]。从图6可以看出5组Bearing在BID值达到30时,轴承退化曲线垂直于时间坐标,且无振幅变化,稳定在 $20g$,说明样本轴承数据集在失效时对应的BID值就为30。

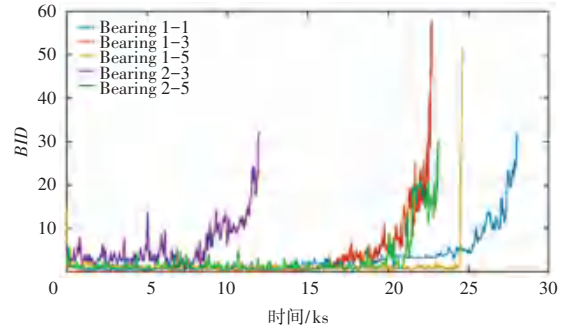


图6 基于GMM-BID的轴承退化曲线

Fig. 6 Bearing degradation curve based on GMM-BID

3 基于SA-CNN-PSO-BiLSTM的滚动轴承剩余使用寿命预测

3.1 预测模型搭建

卷积神经网络(Convolutional Neural Networks, CNN)配合自注意力机制(Self-Attention, SA),即SA-CNN是深度学习的典型算法之一。CNN主要由卷积层、池化层、全连接层构成。卷积层(Convolutional Layer)是CNN的基本结构层,由若干卷积核组成,其作用是进行特征参数提取^[10];池化层(Pooling Layer)可以将重要的特征信息筛选出来^[11]。自注意力原理为产生权重系数对输入加权求和,可以从输入中提取重要值以减少计算的参数,从而减少模型计算量^[12]。

双向长短时记忆神经网络(Bi-directional Long-Short Term Memory, BiLSTM)核心思想就是让所有的输入序列从正反两向都进行循环神经网络训练,这样可以将过去的信息和未来的信息完整提供给输出层^[13]。

粒子群优化算法(Particle Swarm Optimization, PSO)是模拟鸟类觅食的一种进化计算方法,粒子需要记住目前搜索到的最佳位置,粒子飞行寻找最佳位置的距离和方向由粒子自身的速度决定,粒子速度、位置更新公式如下:

$$v_{am}^k = wv_{am}^{k-1} + c_1r_1(Pbest_{am} - x_{am}^{k-1}) + c_2r_2(Gbest_{am} - x_{am}^{k-1}) \quad (10)$$

$$x_{am}^k = x_{am}^{k-1} + v_{am}^k \quad (11)$$

其中, v_{am}^k 是第 k 次迭代粒子 a 飞行速度矢量的

第 m 维分量; x_{am}^k 是第 k 次迭代粒子 a 位置矢量的第 m 维分量; c_1 和 c_2 是影响因子,分别表示粒子和全局对其的影响程度; r 是随机数,防止出现局部最优; w 是惯性权重; $Pbest_{am}$ 是粒子经历过最好的位置; $Gbest_{am}$ 为粒子群最佳位置。

PSO 粒子寻优其实就是网络参数寻优,通过公

式(10)、(11)更新粒子的速度和位置,迭代寻优直至找到最优值,以最优超参数作为 BiLSTM 模型的处理批次大小和隐藏层单元数目,从而完成模型的优化,将自注意力配合卷积神经网络(SA-CNN)提取特征输入模型中完成剩余使用寿命预测,具体预测步骤如图7所示。

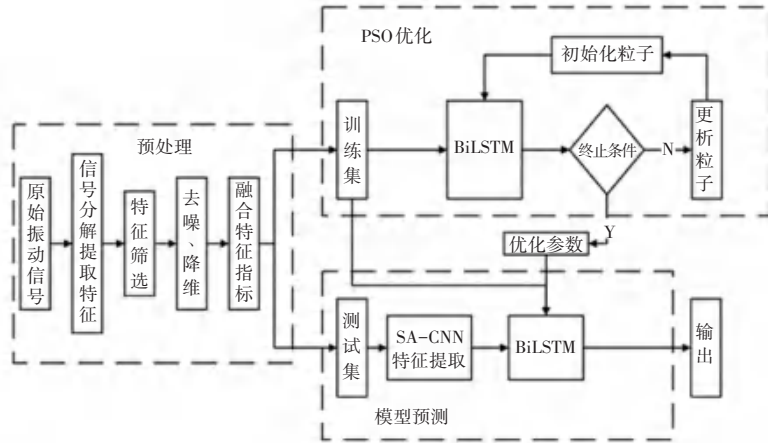


图7 基于SA-CNN-PSO-BiLSTM的剩余使用寿命预测步骤

Fig. 7 Remaining useful life prediction steps based on SA-CNN-PSO-BiLSTM

预测步骤如下:

(1)提取滚动轴承时域、频域特征信号,计算其能量比和能量特征,经过趋势性和单调性评价构建退化趋势特征集。在信号特征融合阶段,采用 GMM-BID 进行多特征融合得到健康指标;

(2)将 BiLSTM 中的批量处理大小、隐藏层单元数和学习率进行优化。SA-CNN 进行特征提取, PSO 初始化粒子对照 BiLSTM 模型结构参数,为了验证优化后的参数是否为适应 BiLSTM 最佳参数,需要进行适应度计算,适应度函数计算公式如下:

$$f = \frac{1}{N} \sum_{m=1}^N \frac{\hat{y}_m - y_m}{y_m} \quad (12)$$

其中, \hat{y}_m 是第 m 个标签量; y_m 则是对应预测量; N 为样本总量。

(3)如若 PSO 模块终止更新,则代表达到 PSO 寻优的最大迭代数,即得到 BiLSTM 结构参数最优解,将得到最优参数输回 BiLSTM 模型,将 SA-CNN 特征输入模型进行训练和 RUL 预测。

PSO 参数设置为: c_1 和 c_2 取 1.5, 惯性权重为 0.5, 种群规模为 15, 最大迭代数为 100。优化参数范围为:学习率是[0.001, 0.008], 隐藏层单元数在 [20, 100], 训练批次为 [10, 100], 丢弃率为 [0.1, 0.5]。PSO 优化的参数分别为:学习率 0.005, 隐藏

层单元数为 60, 训练批次为 50, 丢弃率为 0.3。

3.2 试验验证

本文选用试验数据为 PHM2012 挑战赛的滚动轴承数据集 Bearing2-3 与 Bearing2-5, 因为两者的退化趋势较为明显, 利于对不同预测模型的结果进行比较。本次预测配置为 Corei5-10300H, 8-GB RAM, NVIDIA GTX 1650 GPU, 操作系统为 Windows 10, 仿真软件为 Matlab 2022b。当预测结果 BID 值达到 30, 滚动轴承的寿命到期, 此时模型预测完成。

本文选择 SA-CNN-PSO-BiLSTM 和 SA-CNN-BiLSTM 两种预测模型, 两者的结构很相似, 但前者增加了 PSO 模块, 目的是验证有粒子群优化 BiLSTM 参数的预测模型预测结果。

(1) SA-CNN-PSO-BiLSTM 的初始学习率为 0.005, 在训练至 125 轮后乘 0.2, 训练轮数 200, 优化器为 Adam, 隐藏层单元数设为 60, 丢弃率为 0.2, 训练批次为 60。

(2) SA-CNN-BiLSTM 的学习率为 0.001, 训练轮数 200 轮, 隐藏层单元数 20, 丢弃率设为 0.1, 优化器为 Adam, 训练批次为 50。

SA-CNN-BiLSTM 模型利用数据集 Bearing2-3 的预测结果如图 8 所示, 预测起始时间为第 10 810 s, 实际失效时间第 12 030 s, 实际 RUL 为 1 220 s。根据预测结果, 预测失效点第 12 280 s, 预

测 RUL 为 1 470 s, 预测失效点与实际误差为 250 s。SA-CNN-PSO-BiLSTM 模型利用数据集 Bearing2-3 的预测结果如图 9 所示, 预测点为第 12 150 s, 预测的剩余使用寿命为 1 220 s, 误差约 120 s。SA-CNN-PSO-BiLSTM 预测值比 SA-CNN-BiLSTM 约少 130 s, 精度提高了约 10.7%。SA-CNN-BiLSTM 和 SA-CNN-PSO-BiLSTM 利用数据集 Bearing2-5 的预测结果如图 10 和图 11 所示, 该轴承的预测起始点第 21 220 s, 失效时间是第 23 110 s, 实际 RUL 为 1 890 s, 目测看出 SA-CNN-BiLSTM 的预测点离失效时间点更远, 说明后者的预测效果更佳。SA-CNN-BiLSTM 预测失效时间是第 24 750, 预测 RUL 为 3 530 s, 误差为 1 640 s。SA-CNN-PSO-BiLSTM 预测失效时间是第 24 270 s, 预测的剩余寿命为 3 050 s, 误差为 1 160 s, 预测精度提高约 24.6%。




图 8 基于 SA-CNN-BiLSTM 的预测结果

Fig. 8 Prediction results based on SA-CNN-BiLSTM




图 9 基于 SA-CNN-PSO-BiLSTM 的预测结果

Fig. 9 Predictions based on SA-CNN-PSO-BiLSTM




图 10 SA-CNN-BiLSTM 的预测结果分布

Fig. 10 Distribution of results for SA-CNN-BiLSTM




图 11 SA-CNN-PSO-BiLSTM 的预测结果分布

Fig. 11 Distribution of results for SA-CNN-PSO-BiLSTM

4 结束语

本文主要针对传统滚动轴承剩余使用寿命预测精度不足的问题提出了基于粒子群优化网络参数的深度学习预测模型。首先对滚动轴承振动信号进行特征提取并筛选高敏感特征作为预测模型输入, 将贝叶斯推断距离作为轴承健康值; 其次, 通过 SA-CNN 提取输入特征, PSO 优化 BiLSTM 网络结构参数后进行训练; 最后, 通过试验对比验证 SA-CNN-PSO-BiLSTM 模型预测的精度更高。

参考文献

- [1] 雷亚国, 韩天宇, 王彪, 等. XJTU-SY 滚动轴承加速寿命试验数据集解读[J]. 机械工程学报, 2019, 55(16): 1-6.
- [2] 刘晨辉, 温广瑞, 苏宇, 等. 基于混合域相对特征和 FOA-XGBoost 滚动轴承退化评估[J]. 振动·测试与诊断, 2021, 41(5): 880-887, 1031.
- [3] 孟祥龙, 丁华, 吕彦宝, 等. 基于离散小波变换和变分自编码器的滚动轴承剩余使用寿命预测[J]. 轴承, 2022, 513(8): 55-63.
- [4] AN D, CHOI J H, KIM N H. Remaining useful life prediction of rolling element bearings using degradation feature based on amplitude decrease at specific frequencies[J]. Structural Health Monitoring, 2018, 17(5): 1095-1109.
- [5] 王哲, 刘学平. 基于 ResNeXt 网络的滚动轴承剩余使用寿命预测[J]. 制造业自动化, 2022, 44(6): 17-19.
- [6] 刘宇航, 石宇强, 王俊佳. 基于 FCM-LSTM 的滚动轴承多阶段寿命预测[J]. 机械设计, 2023, 40(5): 43-50.
- [7] 李海浪, 刘永志, 邹益胜, 等. 一种基于 TC-CAE 的轴承寿命预测方法[J]. 振动与冲击, 2022, 41(14): 105-113, 189.
- [8] 尹柏鑫, 袁小芳, 杨育辉, 等. 基于堆叠 GRU 的伺服电机滚动轴承剩余寿命预测[J]. 机床与液压, 2022, 50(12): 153-158.
- [9] 王奉涛. 基于长短期记忆网络的滚动轴承寿命预测方法[J]. 振动测试与诊断, 2020, 40(2): 303-309, 419.
- [10] 张营. 滚动轴承磨损区域静电监测技术及寿命预测方法研究[D]. 南京: 南京航空航天大学, 2013.
- [11] 杜泽厚. 基于深度学习的轴承健康因子构建及寿命预测研究[D]. 青岛: 青岛科技大学, 2022.
- [12] 于忠斌, 张林, 李硕, 等. 基于特征融合技术的滚动轴承退化预测方法研究[J]. 阀门, 2021(6): 323-328.
- [13] 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.