



## 基于深度学习的装备剩余寿命区间预测研究进展

陈闯 李先锋 史建涛

### Research progress on remaining useful life interval prediction of equipment based on deep learning

CHEN Chuang, LI Xianfeng, SHI Jiantao

引用本文:

陈闯, 李先锋, 史建涛. 基于深度学习的装备剩余寿命区间预测研究进展[J]. *工程科学学报*, 2024, 46(4): 723–734. doi: 10.13374/j.issn2095–9389.2023.06.19.003

CHEN Chuang, LI Xianfeng, SHI Jiantao. Research progress on remaining useful life interval prediction of equipment based on deep learning[J]. *Chinese Journal of Engineering*, 2024, 46(4): 723–734. doi: 10.13374/j.issn2095–9389.2023.06.19.003

在线阅读 View online: <https://doi.org/10.13374/j.issn2095–9389.2023.06.19.003>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### [基于集成神经网络的剩余寿命预测](#)

Remaining useful life prediction based on an integrated neural network

*工程科学学报*. 2020, 42(10): 1372 <https://doi.org/10.13374/j.issn2095–9389.2019.10.10.005>

#### [文本生成领域的深度强化学习研究进展](#)

Research progress of deep reinforcement learning applied to text generation

*工程科学学报*. 2020, 42(4): 399 <https://doi.org/10.13374/j.issn2095–9389.2019.06.16.030>

#### [基于CEEMDANLSTM组合的锂离子电池寿命预测方法](#)

Combined prediction method of lithium-ion battery life based on CEEMDANLSTM

*工程科学学报*. 2021, 43(7): 985 <https://doi.org/10.13374/j.issn2095–9389.2020.06.30.007>

#### [等效循环电池组剩余使用寿命预测](#)

Investigation of RUL prediction of lithium-ion battery equivalent cycle battery pack

*工程科学学报*. 2020, 42(6): 796 <https://doi.org/10.13374/j.issn2095–9389.2019.07.03.003>

#### [基于极限学习机\(ELM\)的连铸坯质量预测](#)

Quality prediction of the continuous casting bloom based on the extreme learning machine

*工程科学学报*. 2018, 40(7): 815 <https://doi.org/10.13374/j.issn2095–9389.2018.07.007>

#### [基于支持向量回归与极限学习机的高炉铁水温度预测](#)

Prediction of blast furnace hot metal temperature based on support vector regression and extreme learning machine

*工程科学学报*. 2021, 43(4): 569 <https://doi.org/10.13374/j.issn2095–9389.2020.05.28.001>

# 基于深度学习的装备剩余寿命区间预测研究进展

陈 闯, 李先锋, 史建涛<sup>✉</sup>

南京工业大学电气工程与控制科学学院, 南京 211816

✉通信作者, E-mail: [sjt11@tsinghua.org.cn](mailto:sjt11@tsinghua.org.cn)

**摘 要** 深度学习因其强大的特征提取能力, 在装备剩余寿命预测中得到了广泛应用. 然而, 深度学习的预测结果往往受到随机噪声、建模参数等因素影响, 极大降低了点预测的可信度, 进而引发甚至导致装备运行崩溃. 因此, 精确的剩余寿命区间预测对于理解装备退化过程的随机性以及进行可靠的风险分析和维护决策至关重要. 本文面向深度学习背景下装备剩余寿命预测建模中不确定性量化的现实需求, 重点介绍并归纳了自举深度学习、局部不确定性、随机过程深度学习、贝叶斯深度学习以及深度学习分位数回归 5 种先进剩余寿命区间预测模型的发展动态、优势和缺点, 进而探讨了基于深度学习的装备剩余寿命区间预测研究中面临的挑战性问题以及未来潜在的研究方向.

**关键词** 寿命预测; 区间预测; 不确定性; 深度学习; 维护决策

**分类号** TP183

## Research progress on remaining useful life interval prediction of equipment based on deep learning

CHEN Chuang, LI Xianfeng, SHI Jiantao<sup>✉</sup>

College of Electrical Engineering and Control Science, Nanjing Tech University, Nanjing 211816, China

✉Corresponding author, E-mail: [sjt11@tsinghua.org.cn](mailto:sjt11@tsinghua.org.cn)

**ABSTRACT** Deep learning has been extensively employed for predicting the remaining useful life (RUL) of equipment owing to the powerful feature extraction ability of deep learning. However, the deep learning prediction results are often affected by random noise, modeling parameters, and other factors, considerably reducing the credibility of point predictions. This reduction may lead to inappropriate decisions and sometimes even cause equipment operation collapse. Therefore, the key to ensuring the smooth progress of the entire industrial production process is accurately quantifying the uncertainties transmitted in the output of the RUL prediction model and forming an effective and reasonable maintenance decision plan. The prediction interval is a statistical measure used to quantify uncertainty in predictions. The prediction interval comprises the upper and lower prediction bounds between which an unknown value is expected with a specific probability. The option of prediction intervals enables decision-makers and operational planners to effectively quantify the uncertainty level associated with point predictions and consider multiple solutions for optimal and worst-case conditions. A wide prediction interval indicates a high degree of uncertainty in the underlying system operation. This information signals decision-makers to avoid choosing risky actions under uncertain conditions. By contrast, a narrow prediction interval implies that decisions can be made with more confidence and unexpected situations will be less in the future. The aim of this paper is to analyze and elaborate the basic ideas and development trends of current deep learning-based RUL interval prediction models to provide a good reference for exploring implementable deep learning-based RUL interval prediction model that is highly reliable, cost-efficient, and easy. Thus, while

收稿日期: 2023-06-19

**基金项目:** 国家自然科学基金资助项目(62303217, 62373184 和 61973288); 江苏省自然科学基金资助项目(BK20211502); 江苏省高等学校基础科学(自然科学)研究项目(23KJB510006)

facing the practical demand of uncertainty quantification in the modeling of equipment RUL based on deep learning, this paper first analyzes the sources of uncertainty in RUL prediction, such as data quality, model error, and changes in model parameters and the external environment. Subsequently, five popular deep learning-based RUL interval prediction models are presented: bootstrap deep learning, local uncertainty, stochastic process deep learning, Bayesian deep learning, and deep learning quantile regression. Through the model establishment process and current development status analysis, the advantages and disadvantages of the five RUL interval prediction models are summarized. Finally, the challenges encountered during the current research on the RUL interval prediction of equipment based on deep learning and potential future research directions are explored.

**KEY WORDS** remaining useful life prediction; interval prediction; uncertainty; deep learning; maintenance decision-making

在全球竞争日益激烈的当今时代,装备现代化和高端化已成为企业和国家保持核心竞争力的重要战略之一.随着经济的持续发展和科技的不断进步,各种新型材料、复杂工艺和创新性技术逐渐应用于航空发动机、大型飞机、高速列车和燃气轮机等重大工程,装备也朝着大型化、自动化和集成化方向发展<sup>[1-3]</sup>.为确保装备能够可靠、安全、稳定地执行其既定功能,装备运行性能成为了使用者、生产厂商以及设计者共同关注的核心问题.然而,在实际运行过程中,装备受到内部因素(疲劳、老化、磨损、功能缺陷等)和外部因素(振动、冲击、辐射、温度波动等)的综合影响,装备退化故障难以避免.装备故障的发生轻则降低其任务执行能力,重则造成严重的经济损失和人员伤亡等后果<sup>[4-6]</sup>.因此,在装备性能退化的早期,特别是在尚未造成严重危害之前,通过状态监测信息及时发现异常或定量评价装备的健康状况,并准确预测装备性能退化至主要功能丧失的时刻(即剩余寿命预测),从而对装备实施健康管理,是保障复杂装备安全、可靠和经济运行的重要手段<sup>[7]</sup>.

为解决上述问题,有关装备健康状态评估、剩余寿命预测和维护决策方向的研究得到了国内外学者的广泛关注,并在过去几十年内取得了长足发展.剩余寿命预测是连接装备运行状态信息感知与基于运行状态实现个性化精准健康管理的纽带和关键.装备剩余寿命预测主要技术方法包括机理模型方法、数据驱动方法和混合方法<sup>[8-10]</sup>.其中,数据驱动方法直接立足装备运行状态数据本身,而不过度依赖装备退化的失效机理且建模成本不高,能够很好适用复杂工程装备,是当前剩余寿命预测研究的主流方法<sup>[11-13]</sup>.喻勇等<sup>[14]</sup>系统综述了数据驱动的剩余寿命预测方法中基于协变量的方法,将基于协变量的方法分为固定协变量模型、时变协变量模型和随机协变量模型.裴洪等<sup>[15]</sup>系统综述了数据驱动的剩余寿命预测方法中基于机器学习的方法,根据机器学习模型结构的深度,

将其进一步分为基于浅层机器学习的方法和基于深度学习的方法.李银等<sup>[16]</sup>梳理了支持向量机、极限学习机、深度神经网络等 6 种数据驱动方法在锂离子电池剩余寿命预测应用中的研究现状,并归纳总结了优势和缺点.Wang 等<sup>[17]</sup>进一步综述了数据驱动的剩余寿命预测方法中基于深度学习的方法,归纳总结了自动编码器、深度置信网络、卷积神经网络、递归神经网络 4 个主要代表性的深度架构在剩余寿命预测中的研究进展.这些研究从各自的角度讨论了数据驱动的寿命预测发展,特别指出深度学习作为数据驱动方法的前沿技术实现了计算机自动学习模式特征,提高了在不同领域的适用性,然而剩余寿命预测过程中的不确定性并没有得到关注.

在实际应用中,随机噪声、模型偏差、环境扰动等多种不确定性始终穿插于剩余寿命预测过程,这大大降低了预测的可信度,并可能导致不适当的维护决策,甚至导致装备崩溃.因此,在深度学习背景下,装备剩余寿命预测不确定性研究至关重要.首先,不确定性研究有助于提高决策的质量.在决策制定过程中,仅仅依赖单一的寿命估计可能导致错误的决策.例如,在维护计划中,如果不考虑不确定性,可能会导致不必要的维护活动,浪费资源,或者在不及时维护的情况下,可能会发生设备故障,带来更大的损失.通过了解寿命预测的不确定性,决策者可以更好地权衡风险和成本,制定出更明智的决策<sup>[18]</sup>.其次,不确定性研究有助于提高装备的安全性.在一些如航空和核能行业,装备故障可能导致灾难性后果.通过研究剩余寿命预测的不确定性,可以提前发现可能的故障风险,并采取适当的措施来确保装备的安全性,这对于保护人员的生命和财产至关重要.此外,不确定性研究还有助于降低成本.维护和修理装备的成本往往非常高昂,但如果不确定性被忽略,可能会导致不必要的维护活动,浪费资源.通过了解不确定性,可以更精确地制定维护计划,以最大程度地

减少成本. 不确定性研究还可以用来评估数据质量. 如果不确定性很高, 可能是因为数据不足或不准确. 因此, 通过研究不确定性, 可以发现数据收集和处理中的问题, 并采取措施改进数据质量, 提高预测的准确性. 最后, 不确定性研究有助于改进预测模型. 通过分析不确定性, 可以识别模型在特定情况下的表现差异, 并指导模型改进方向, 这将有助于提高预测的准确性和可靠性. 因而, 装备剩余寿命预测不确定性研究的必要性在于提高决策质量、确保设备安全性、降低成本、改进数据质量和预测模型的性能, 这对于各种工业和军事应用中的装备管理至关重要, 将为企业和组织带来巨大益处.

预测区间是用于量化预测不确定性的统计度量, 通常由预测上界和预测下界组成, 并在预测上界和预测下界之间预期的未知值以指定概率存在<sup>[19]</sup>. 预测区间的可用性使决策者和运营规划者能够有效地量化与点预测相关的不确定性水平, 并考虑最佳和最差条件下的多种解决方案. 宽预测区间表示底层系统运行中存在高度不确定性, 这些信息可以指导决策者避免在不确定条件下选择有风险的行动; 窄预测区间意味着可以更自信地做出决定, 而在未来面对意外情况的机会更少. 本文动机在于分析和阐述当前基于深度学习的剩余寿命区间预测模型的基本思想和发展动态, 进而为探究一种具有高可靠性、低计算成本和易于实现的基于深度学习的剩余寿命区间预测模型提供良好借鉴. 本文分析了深度学习背景下剩余寿命预测不确定性的来源; 重点介绍并归纳了 5 种流行的基于深度学习的剩余寿命区间预测模型: 自举深度学习模型、局部不确定性模型、随机过程深度学习模型、贝叶斯深度学习模型、深度学习分位数回归模型及其优缺点; 探讨了基于深度学习的装备剩余寿命区间预测研究中面临的挑战性问题的未来潜在的研究方向.

## 1 剩余寿命预测不确定性的来源

随着工业物联网相关技术的不断发展, 工业系统中可获取的状态监测数据逐渐增多. 相较于浅层机器学习方法, 深度学习技术不再需要专业信号处理知识, 能够自动提取或构建有用信息以支持剩余寿命预测任务, 因此近年来备受研究者关注. 常用的深度学习网络结构有深度置信网络 (Deep belief network, DBN)<sup>[20-25]</sup>、卷积神经网络 (Convolutional neural network, CNN)<sup>[26-31]</sup> 和长短时

记忆神经网络 (Long short-term memory, LSTM)<sup>[32-37]</sup>. DBN 以受限玻尔兹曼机为基础, 通过运用多个受限玻尔兹曼机方式实现概率生成, 训练过程采用了贪婪逐层学习算法进行无监督预训练. 在无监督预训练完成后, DBN 利用反向传播微调操作对深层次网络进行优化, 从而获得更佳的性能. CNN 是由卷积、池化和全连接层组成的深度学习网络, 具备空间信息处理、特征自动学习, 并结合数据增强技术来改善模型泛化能力等优势, 被广泛应用于装备剩余寿命预测建模中. LSTM 是一种特殊类型的循环神经网络, 通过使用一些特定组件来解决传统循环神经网络中的梯度消失和梯度爆炸问题. 由于 LSTM 网络具备时序数据建模、长时依赖关系捕捉、抵御噪声干扰等优势, 使得 LSTM 成为一种非常有效的剩余寿命预测方法.

深度学习技术为处理复杂工程系统中的海量监测数据提供了一种有效的解决思路. 深度学习技术在装备剩余寿命预测中的应用具有巨大的优势: 首先, 相比于人为设计特征, 深度学习提出了一种让计算机自动学习模式特征的方法, 这可大大减轻工程师的负担并提高模型精度; 其次, 深度学习的深层网络结构使得它能够学习到更深层次的潜在特征, 从而提升预测精度. 深层网络可通过逐层训练学习到不同抽象层次的特征, 这些特征通常比单层网络学到的特征更加丰富和有用; 最后, 与传统机器学习算法相比, 深度学习技术在不同领域具有更好的适用性. 如, 在图像、语音和自然语言处理等领域, 深度学习已经取得了非常显著的成果. 因此, 在工程装备剩余寿命预测任务中采用深度学习技术具有巨大的优势, 可为实际应用提供更高效和可靠的解决方案.

对于一组  $N$  个数据样本  $\{(x_i, y_i)\}_{i=1}^N$ , 可通过带有真实参数集  $\theta$  的深度学习函数  $f(x_i, \theta)$  生成观测目标  $y_i$ :

$$y_i = f(x_i, \theta) + \varepsilon_i \quad (1)$$

式中,  $x_i$  表示输入空间的样本;  $\varepsilon_i$  是带有零均值的噪声. 点预测致力于逼近真实的预测模型  $f(x_i, \theta)$ , 其近似模型  $f(x_i, \hat{\theta})$  可被视为目标分布的平均值, 估计参数集  $\hat{\theta}$  可通过优化构建的损失函数 (如均方误差) 获得. 预测区间与概率分布  $P(y_i | f(x_i, \hat{\theta}))$  有关, 试图量化与观测目标  $y_i$  和预测值  $f(x_i, \hat{\theta})$  之间差异相关的不确定性<sup>[38]</sup>, 即:

$$y_i - f(x_i, \hat{\theta}) = [f(x_i, \theta) - f(x_i, \hat{\theta})] + \varepsilon_i \quad (2)$$

假设估计误差和噪声统计上独立, 总预测误差的方差  $\sigma^2(x_i)$  表示为:

$$\hat{\sigma}^2(x_i) = \hat{\sigma}_f^2(x_i) + \hat{\sigma}_\varepsilon^2(x_i) \quad (3)$$

式中,  $\hat{\sigma}_f^2(x_i)$  表示模型不确定性方差, 通常可归因于数据质量、模型偏差、模型参数变化等因素;  $\hat{\sigma}_\varepsilon^2(x_i)$  表示噪声方差, 通常由外部环境变化等因素造成. 图 1 描述了剩余寿命预测中的各种不确定性, 具体描述如下:

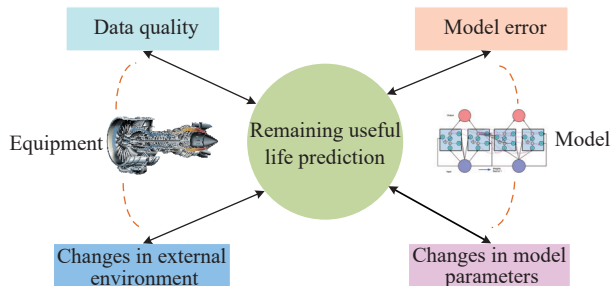


图 1 剩余寿命预测中的不确定性

Fig.1 Uncertainties in remaining useful life prediction

(1) 数据质量: 如果原始监测数据存在缺失值、样本数量不足或采样偏差等质量问题, 将会对剩余寿命预测造成不确定性。

(2) 模型偏差: 即使使用了最先进的模型, 也难免存在一定程度的偏差. 这些偏差可能源于模型本身的局限性, 例如过拟合或欠拟合等, 也可能来源于样本数量不足或训练数据不够充分。

(3) 模型参数变化: 剩余寿命预测模型通常是基于对过去数据的学习而构建, 因此, 如果未来数据与历史数据存在较大差异, 模型性能可能会受到影响. 这种变化可能是由于装备老化、部件替换或升级等原因引起。

(4) 外部环境变化: 工程装备剩余寿命预测往往受到如气候变化、数据传输、操作人员行为和使用环境等外部环境的干扰, 这些因素可能会影响装备的运行状态并导致不确定性。

以上这些不确定性极大地降低了点预测的可信度, 因此可能会做出不适当的决策(不适当的生产、库存或维护计划), 有时甚至可能导致装备崩溃. 为了实现精确的决策, 决策者应该意识到预测的不确定性. 重要的是要知道模型生成的预测与实际值的匹配程度, 以及不匹配风险有多大. 然而, 点预测没有任何可信度的指示, 也没有提供相关不确定性的信息. 基于这些原因, 需要精确量化剩余寿命预测过程中的不确定性, 从而为进一步实现装备运行的安全性、可靠性和经济性奠定基础。

## 2 基于深度学习的剩余寿命区间预测模型

基于深度学习的剩余寿命区间预测模型主要

涉及自举深度学习、局部不确定性、随机过程深度学习、贝叶斯深度学习以及深度学习分位数回归等。

### 2.1 自举深度学习模型

自举(Bootstrap)法是一种从给定训练集中有放回的均匀抽样, 也就是说, 每当选中的一个样本, 它等可能地被再次选中并被再次添加到训练集中<sup>[39]</sup>. 自举法不依赖于数据分布, 在理论上可减少预测值和回归平均值之间的偏差. 由于深度学习模型的泛化误差是在参数空间的不同子集上产生, 因此由深度学习集合产生的集体决策比任何单个深度学习模型做出的决策更可靠. 假设重采样原始数据得到  $B$  个训练数据集, 记为  $\{D\}_{b=1}^B$ , 自举深度学习通过建立  $B$  个深度学习模型来估计由于模型错误指定而产生的方差(误指定方差,  $\sigma_y^2$ ). 根据这一假设, 可平均  $B$  个模型的点预测实现真实回归的估计  $\hat{y}_i$ , 即:

$$\hat{y}_i = \frac{1}{B} \sum_{b=1}^B \hat{y}_i^b \quad (4)$$

式中,  $\hat{y}_i^b$  是由第  $b$  个自举模型生成的第  $i$  个样本的预测. 假设深度学习模型无偏, 则可使用  $B$  个模型结果的方差来估计模型的误指定方差, 即:

$$\hat{\sigma}_{\hat{y}_i}^2 = \frac{1}{B-1} \sum_{b=1}^B (\hat{y}_i^b - \hat{y}_i)^2 \quad (5)$$

需要指出的是,  $\hat{\sigma}_{\hat{y}_i}^2$  主要源于参数随机初始化以及使用不同数据集来训练神经网络。

根据式 (3), 需要估计误差的方差  $\hat{\sigma}_\varepsilon^2$  来构建预测区间:

$$\hat{\sigma}_\varepsilon^2 \approx E\{(y - \hat{y})^2\} - \hat{\sigma}_{\hat{y}}^2 \quad (6)$$

式中,  $E\{(y - \hat{y})^2\}$  表示  $(y - \hat{y})^2$  的数学期望;  $y$  表示观测值;  $\hat{y}$  表示预测值。

根据公式 (6), 可形成一组方差的平方残差  $r_i^2 = \max((y - \hat{y}_i)^2 - \hat{\sigma}_{\hat{y}_i}^2, 0)$ . 考虑到模型输入  $x_i$ , 可形成一个新的数据集  $D_{r^2} = \{(x_i, r_i^2)\}_{i=1}^N$ , 进而可构建一个预测模型用于噪声方差回归. 基于此, 剩余寿命估计的预测区间为:

$$\hat{y}_i \pm z_{1-\alpha/2} \sqrt{\hat{\sigma}_{\hat{y}_i}^2 + \hat{\sigma}_{\varepsilon_i}^2} \quad (7)$$

式中,  $\alpha$  表示显著性水平, 指估计总体参数落在某一区间时可能犯错的概率;  $z_{1-\alpha/2}$  是标准正态分布的临界值, 取决于预期置信水平  $(1 - \alpha) \times 100\%$ 。

对于使用自举法构建预测区间, 总共需要训练  $B+1$  个深度学习模型: 前  $B$  个自举深度学习模型

用于估计  $\hat{\sigma}_{y_i}^2$ , 第  $B+1$  个深度学习模型用于估计  $\hat{\sigma}_{\varepsilon}^2$ . Huang 等<sup>[40-41]</sup> 开发了一种自举深度 CNN 架构, 其包括两个主要部分: 首先, 采用深度 CNN-多层感知机双重网络同时提取时间序列和基于图像特征中的隐藏信息表示; 其次, 将所提出的双重网络嵌入到自举框架中, 量化剩余寿命预测区间. Liao 等<sup>[42]</sup> 构建了一种自举 LSTM 前馈神经网络, 实现对航空发动机的剩余寿命区间预测. 为进一步提升区间预测效果, Zhao 等<sup>[43]</sup> 提出了一种基于自举集成学习卷积简单循环单元方法来进行剩余寿命预测. She 等<sup>[44]</sup> 提出了一种基于自举的双向门控循环单元剩余寿命预测方法. 进一步地, Guo 等<sup>[45]</sup> 将自举法、CNN 和双向 LSTM 进行耦合, CNN 和双向 LSTM 用于提取滚动轴承的时空特征, 自举法用于不确定性量化.

自举深度学习为装备剩余寿命区间预测提供了重要技术支持. 自举深度学习在装备剩余寿命区间预测中的应用具备如下优点: (1) 自举深度学习在不同数据子集上训练多个模型进行预测, 因此可以有效避免过拟合现象; (2) 自举深度学习可通过融合多个模型的预测结果来提高模型泛化能力, 从而在测试集上获得更好的性能表现. 尽管如此, 自举深度学习需要训练多个模型并融合其预测结果, 其计算复杂度较高, 尤其是在数据集非常大时, 训练时间会变得非常长; 由于自举深度学习生成多个数据子集, 并在每个子集上训练模型, 因此可能会损失一部分原始数据信息; 自举深度学习依赖  $B$  个深度学习模型, 而有一些模型经常是有偏差的, 导致对公式 (5) 中  $\hat{\sigma}_{y_i}^2$  的估计不够准确.

## 2.2 局部不确定性模型

局部不确定性模型考虑了剩余寿命预测过程中的所有误差来源, 而不试图分解其各自来源的贡献, 通过构建样本输入与预测下界、预测上界之间的映射关系, 实现最优模型不确定性的估计<sup>[46]</sup>. 深度学习下剩余寿命预测不确定性主要来源于数据质量、模型偏差、模型参数变化、外部环境变化等因素, 因此观测目标  $y_i$  可以表示为:

$$y_i = f(x_i, \theta) + \varepsilon_x + \varepsilon_m + \varepsilon_{\theta} + \varepsilon_y \quad (8)$$

式中,  $\varepsilon_x$ 、 $\varepsilon_m$  和  $\varepsilon_{\theta}$  是关于数据质量、模型偏差和模型参数变化的误差,  $\varepsilon_y$  是关于外部环境变化等因素引起的误差. 在大多数实际情况下, 除非做出一些重要的假设, 否则很难估计公式 (8) 中的误差分量. 因此, 对总模型误差有贡献的不同分量通常被视为单个集中变量, 公式 (8) 可以重新表述为:

$$y_i = f(x_i, \hat{\theta}) + \varepsilon_{\text{total}} \quad (9)$$

式中,  $\varepsilon_{\text{total}}$  为总剩余误差 (残差). 为获得训练样本的预测下界和预测上界, 局部不确定性模型利用了数据聚类技术. 数据聚类可将多维的状态监测数据划分为几个离散的健康状态, 譬如正常状态、退化状态以及失效状态. 值得注意的是, 具有相同健康状态的样本将具有类似分布的误差. 在识别这些健康状态后, 可根据相应历史误差的经验分布确定每个健康状态的预测区间. 通常来说, 模型误差的分布取决于模型的输入和可能的状态变量, 包括观测响应变量的滞后变量. 在局部不确定性估计方法中, 模型误差的概率密度函数是通过经验分布估计, 因而无须对残差做出任何假设. 需要指出的是, 局部不确定性估计方法分析了由最优模型产生的历史模型残差 (在结构和参数方面), 其是基于最优性的概念, 而不是等价性.

构建局部不确定性模型的基本步骤<sup>[47]</sup>:

- (1) 构建深度学习点预测模型, 计算模型输出和实际观测的残差;
- (2) 使用数据聚类算法对训练样本进行聚类;
- (3) 根据残差按升序方式排列训练样本, 然后计算每个聚类的预测下界和上界;
- (4) 根据每个聚类的预测下界和上界, 计算每个样本的预测下界和上界;
- (5) 根据每个样本的预测下界和上界, 构建双输出深度学习模型 (第一个输出用于输出预测下界, 第二个样本用于输出预测上界), 即:

$$[\text{PL}^L, \text{PL}^U] = g(x, \hat{\theta}) \quad (10)$$

式中,  $\text{PL}^L$  和  $\text{PL}^U$  分别表示样本预测下界和上界,  $g(x, \hat{\theta})$  表示估计预测边界的映射函数,  $\hat{\theta}$  是函数参数.

局部不确定性模型自提出以来, 在水文领域一直备受关注<sup>[48-50]</sup>. Solomatine 等<sup>[48]</sup> 针对不同水文情况单独估计了模型误差的概率分布, 将表征该分布的参数聚合并用作输出目标值形成模型训练集. Dogulu 等<sup>[49]</sup> 基于局部误差和聚类的局部不确定性模型测试了英国的几个集水区获得了良好预测效果. Rahmati 等<sup>[50]</sup> 利用局部不确定性模型研究了地下水硝酸盐污染建模过程中的模型不确定性. 相较而言, 关于局部不确定性模型在装备剩余寿命预测领域中的应用成果较少, 需要进一步探索. Chen 等<sup>[51]</sup> 提出了一种基于双向 LSTM 的航空发动机剩余寿命区间预测方法. 该方法在离线阶段利用一种增强的模糊 C-均值算法, 将航空发动机的健康状态划分为几个离散状态; 在标记每个采

样点的健康状态后, 根据残差按升序方式排列样本, 计算每个聚类和每个样本的预测上界和下界; 在在线阶段, 采用双向 LSTM 构建局部不确定性模型, 估计了剩余寿命的上预测边界和下预测边界, 实现了区间预测. 进一步地, Chen 等<sup>[52]</sup> 根据高斯分布假设将构建的剩余寿命预测区间转换为剩余寿命概率分布, 形成了以维护时间为变量的维护成本率函数, 通过最小化维护成本率函数, 实现了航空发动机的最优维护决策.

局部不确定性模型在剩余寿命区间预测中的应用具备如下优点: (1) 局部不确定性模型考虑了剩余寿命预测过程中的所有误差来源, 而不试图分解其各自来源的贡献, 因此, 无须对残差做出任何假设; (2) 局部不确定性模型通过构建样本输入与预测下界、预测上界之间的映射关系, 实现最优模型不确定性的估计, 因而计算复杂度不是很高. 然而, 局部不确定性涉及数据聚类技术, 需要提前指定聚类数目, 如果聚类数目选择不当, 将会影响到模型的预测能力. 此外, 局部不确定性模型使用黑盒模型构建样本输入与预测下界、预测上界之间的映射关系, 内部机制和特征表示难以进行解释.

### 2.3 随机过程深度学习模型

随机过程 (Stochastic process) 是一连串随机事件动态关系的定量描述<sup>[53]</sup>. 设  $T$  是一无限实数集, 将依赖于参数  $t \in T$  的一族 (无限多个) 随机变量称为随机过程, 记为  $\{X(t), t \in T\}$ .  $X(t)$  是随机变量,  $T$  叫做参数集.  $X(t_1) = x$  称为  $t_1$  时刻的状态, 全体  $X(t)$  的可能取值称为随机过程的状态空间. 对随机过程  $\{X(t), t \in T\}$  进行一次试验, 其结果是  $t$  的函数, 记为  $x(t), t \in T$ , 称为随机过程的一个样本函数或样本曲线. 随机过程每次试验得到的样本函数可能都不一样. 随机过程可依其在任一时刻的状态是连续型随机变量或离散型随机变量而分成连续型随机过程和离散型随机过程. 其中, 以伽玛 (Gamma) 过程<sup>[54-56]</sup>、维纳 (Wiener) 过程<sup>[57-59]</sup> 为典型代表的连续型退化过程模型在装备剩余寿命预测中得到了广泛应用. 此连续型退化过程模型可根据装备退化轨迹估计出退化模型参数, 推导出剩余寿命的解析概率分布, 实现不确定性量化.

随机过程深度学习模型是一种基于深度学习和退化过程模型的融合技术, 首先利用深度学习自动提取装备状态监测数据中的特征信息, 而后基于随机过程模型推导装备剩余寿命的解析概率分布. 假设深度学习技术提取装备状态监测数据下的退化特征为  $D(t)$ ,  $t$  表示当前时刻,  $D(0)$  表示装

备在初始时刻的退化特征量. 以维纳过程为例, 其退化模型可以表示为:

$$D(t) = D(0) + \eta t + \gamma C(t) \quad (11)$$

式中,  $\eta$  表示漂移系数,  $\gamma$  表示扩散系数,  $C(t)$  表示标准布朗运动. 基于首达时间的概念, 装备在  $t$  时刻的剩余寿命  $R_t$  通常可以表示为首次达到预先设定失效阈值  $\kappa$  的时间, 即  $R_t = \inf\{r_t : D(t+r_t) \geq \kappa | D(t) < \kappa\}$ . 剩余寿命的概率密度分布可表示为<sup>[60]</sup>:

$$f_{R_t}(r_t) = \frac{\kappa - D(t)}{\sqrt{2\pi r_t^3 \gamma^2}} \exp\left\{-\frac{(\kappa - D(t) - \eta r_t)^2}{2r_t \gamma^2}\right\} \quad (12)$$

以上通过构建随机过程深度学习模型, 获得了不同装备的剩余寿命概率密度函数. 进一步采用试探法<sup>[61]</sup> 以获得最优剩余寿命预测区间, 其基本步骤为: 根据剩余寿命概率分布, 找出一个区间, 使该区间的累积概率大于或等于置信度  $(1-\alpha) \times 100\%$ ; 其次, 在所有符合条件的区间里, 逐个计算区间宽度; 最后, 挑出宽度最小的区间作为该剩余寿命预测值的预测区间.

基于随机过程深度学习实现不确定性表征和量化框架下, Hu 等<sup>[62]</sup> 利用 DBN 提取轴承监测信号背后的深层隐藏特征, 然后筛选出趋势较高的特征作为局部线性嵌入的输入, 通过确定轴承健康指数, 构建一个基于扩散过程的健康指数演化模型, 并在首达时间意义下推导了剩余寿命概率密度函数. Li 等<sup>[63]</sup> 构建了一个堆叠降噪自编码器从海量数据中提取健康指标, 采用维纳过程对提取的健康指标进行建模, 接着构建以预测性能最小化为核心的优化目标函数, 并基于目标函数反向优化调整模型参数形成复合特征指标提取与随机退化建模的反馈闭环. 周涛等<sup>[64]</sup> 构建了一种基于多维自注意力时间卷积网络和线性维纳过程的剩余寿命预测方法, 形成数模联动的剩余寿命预测方法. Zhang 等<sup>[65]</sup> 提出了一种基于粒子滤波器和时间注意机制双向门控递归单元的数模联动的剩余使用寿命预测方法. Chen 等<sup>[66]</sup> 利用经验模态分解方法提取电池的退化趋势, 基于迁移学习对 LSTM 神经网络的参数进行在线更新, 同时通过最大似然估计获得了基于维纳过程的退化模型的扩散系数, 进而以闭合形式导出剩余寿命概率密度函数的解析表达式.

随机过程深度学习模型在剩余寿命区间预测中的应用具备如下优点: (1) 随机过程深度学习模型在进行剩余寿命预测时, 需要考虑初始状态、负载条件、使用环境等诸多因素, 而随机过程能够很

好地将这些因素融合在模型中,并且能够分析它们对系统行为的影响;(2)随机过程深度学习模型能够对未来剩余寿命建立概率分布模型,具有较好的预测能力,可以根据当前数据实时更新预测结果.尽管如此,在随机过程深度学习建模中,需要选择合适的随机过程模型,例如伽玛过程、维纳过程、逆高斯过程等,但是这些模型的选择并不容易,需要一定的领域知识和经验;其次,在随机过程深度学习建模中,需要同时考虑深度学习和随机过程两个方面的模型复杂度,因此可能会导致模型计算量非常大.此外,随机过程需要对其模型参数进行估计,其中某些参数可能无法直接观测到,需要依赖其他手段进行估计,这增加了模型建立的难度和误差.

## 2.4 贝叶斯深度学习模型

贝叶斯估计(Bayesian estimation)是利用贝叶斯定理结合新的证据及以前的先验概率,来得到新的概率<sup>[67]</sup>.经典深度学习的剩余寿命预测通常构建一个基于神经网络的回归模型 $y = f(x, \theta)$ 将状态监测数据和生命周期结束时间联系起来.贝叶斯深度学习模型本质是经典深度学习模型在概率上的扩展,一方面保留了经典深度学习模型的网络拓扑结构,以便继承经典深度神经网络的模块化和可扩展性;另一方面将经典模型的模型参数替换为随机变量,以便通过概率分布实现不确定性量化.贝叶斯深度学习是贝叶斯估计和深度学习的融合学习过程,即采用贝叶斯定理更新深度学习模型参数的概率分布过程.

给定训练样本 $X$ 和 $Y$ ,贝叶斯神经网络 $y = f(x, \theta)$ 可由参数空间上的先验分布 $p(\theta)$ 以及贝叶斯回归的似然函数 $L(Y|X, \theta) = \prod_{i=1}^N l(y_i|f(x_i, \theta))$ 构成,一般情况下可使用高斯分布 $l(y_i|f(x_i, \theta))$ .模型参数 $\theta$ 独立于训练输入样本 $X$ ,通过联合学习 $X$ 和 $Y$ 可对贝叶斯深度学习模型进行训练.由贝叶斯定理,模型参数的后验分布为:

$$p(\theta|X, Y) = \frac{p(\theta) \prod_{i=1}^N l(y_i|f(x_i, \theta))}{\int p(\theta) \prod_{i=1}^N l(y_i|f(x_i, \theta)) d\theta} \quad (13)$$

基于 $p(\theta|X, Y)$ ,贝叶斯深度学习模型 $y = f(x, \theta)$ 可用于不确定性量化的后续推理,假设某一时刻获得在役装备的状态监测数据为 $\hat{x}$ ,则装备终止时间 $\hat{y}$ 可通过 $p(\hat{y}|\hat{x}, X, Y) = \int l(\hat{y}|f(\hat{x}, \theta)) p(\theta|X, Y) d\theta$ 进行预测.

基于现有深度学习模型,不难构建用于剩余

寿命预测的贝叶斯深度学习模型,但是贝叶斯深度学习的推理过程较为复杂,所以一般采用近似技术<sup>[68]</sup>.常用的近似技术是马尔可夫链蒙特卡洛和变分推断方法.马尔可夫链蒙特卡洛方法利用采样技术从分布中取得样本,计算这些样本的均值、方差等各种统计量,通过核密度估计求得近似分布,从而避免处理涉及后验的棘手计算.变分推断方法则是通过假设一个简单分布来对真实后验分布进行近似,以此来减少计算.Peng等<sup>[69]</sup>将深度学习模型扩展到贝叶斯神经网络中,提出了一种基于变分推理的贝叶斯神经网络学习和推理方法.Gal等<sup>[70]</sup>认为神经网络中的随机失活等价于贝叶斯估计的变分推断过程,并进行了理论证明,同时提出一种蒙特卡洛随机失活来近似获得预测模型的不确定性.Benker等<sup>[71]</sup>将贝叶斯深度学习模型应用于涡轮风扇发动机的剩余寿命预测任务,提出利用哈密顿蒙特卡洛和变分推断进行推理.Chen等<sup>[72]</sup>提出了一种基于贝叶斯深度学习的二阶段滚动轴承剩余寿命区间预测方法:在第一阶段,识别轴承的状态变化,确定首次预测时刻;在第二阶段,根据新的贝叶斯深度学习模型进行剩余寿命点估计和区间预测.

贝叶斯方法在处理不确定性时具有天然的优越性,因而贝叶斯和深度学习的结合得到了学者们的青睐<sup>[73-81]</sup>.贝叶斯深度学习模型的主要优点在于:(1)贝叶斯深度学习使用先验分布来约束模型参数,从而可避免过拟合现象;(2)贝叶斯深度学习利用深度学习优势来提取丰富特征,并利用贝叶斯方法来对模型进行建模和推断,因而贝叶斯深度学习能够处理复杂度高的任务;(3)贝叶斯深度学习通过对模型参数的后验分布进行采样,从而可得到预测结果的概率分布.尽管如此,贝叶斯深度学习对模型参数的后验分布进行采样通常需要较大的计算成本,特别是当数据集非常大时,贝叶斯深度学习的训练和推断时间可能会变得非常长;贝叶斯深度学习中使用的先验分布通常是基于领域知识或经验得出,而如果先验分布与真实分布存在偏差,可能会影响模型的预测能力;贝叶斯深度学习中需要选择先验分布、采样方法和模型结构等不同超参数,因而选择合适的超参数需要一定的经验和知识,并且可能会面临困难和不确定性.

## 2.5 深度学习分位数回归模型

分位数回归(Quantile regression)研究自变量与因变量的条件分位数之间的关系,相应得到的回



归模型可由自变量估计因变量的条件分位数<sup>[82]</sup>. 相较于传统回归分析仅能得到因变量的中央趋势, 分位数回归可以进一步推论因变量的条件概率分布. 将深度学习模型和分位数回归相结合, 能有效反映解释变量  $x$  在不同分位点下对被解释变量  $y$  的影响, 表达式为:

$$Q_y(\tau|x) = f(x|\theta(\tau)) \quad (14)$$

式中,  $Q_y$  表示被解释变量  $y$  在解释变量  $x$  给定下的条件分位数;  $\tau \in (0, 1)$  表示分位点,  $f(x|\theta(\tau))$  表示带有参数  $\theta(\tau)$  的深度学习模型.

给定训练数据值时, 通过式 (14) 可求出不同分位点下的深度学习模型参数  $\theta(\tau)$ , 其求解过程可转换为如式 (15) 所示的最小损失函数:

$$\text{Loss}(\tau) = \min_{\theta(\tau)} \left\{ \sum_{i, y_i \geq Q_{y_i}(\tau|x)} \tau (y_i - Q_{y_i}(\tau|x)) + \sum_{i, y_i < Q_{y_i}(\tau|x)} (1 - \tau) (Q_{y_i}(\tau|x) - y_i) \right\} \quad (15)$$

当得到最佳权重项的估计值  $\hat{\theta}(\tau)$  时, 因变量的条件分位数为:

$$\hat{Q}_y(\tau|x) = f(x|\hat{\theta}(\tau)) \quad (16)$$

根据条件分位数理论,  $Q_y$  的分位数曲线是指当  $\tau$  属于  $(0, 1)$  时的分布函数, 然后将获得的分位数函数作为核密度估计的输入, 即可得剩余寿命的概率密度函数<sup>[83-85]</sup>. 基于获得的剩余寿命概率密度函数, 类似于随机过程深度学习, 可采用试探法获得最优预测区间.

基于分位数回归思想, Chen 等<sup>[86]</sup> 开发了锂离子电池容量预测不确定性量化模型, 使用一维 CNN 提取隐藏在原始测量信号中的深层代表性特征, 而后应用双向 LSTM 网络估计电池容量, 同时将分位数回归层嵌入到双向 LSTM 网络构建中, 获得不同分位数的电池容量, 最后, 利用核密度估计技术推导出每个电池循环阶段预测点的概率密度. Zhang 等<sup>[87]</sup> 提出了一种分布式基于深度神经网络分位数回归的剩余寿命预测方法, 通过累积分布函数识别置信区间量化剩余寿命预测的不确定性. Tian 等<sup>[88]</sup> 结合时间卷积网络和分位数回归算法, 实现了基于预测值条件分布的核密度估计的任何时间的概率密度预测. Wang 等<sup>[89]</sup> 开发了一种用于多传感器信号融合和剩余寿命预测的门控图卷积网络. 首先, 从多传感器信号中构建时空图, 作为预测模型的输入; 接着, 建立门控图卷积层, 通过

同时建模多传感器信号中的时间和空间相关性来准确提取退化特征; 最后, 将提取的特征输入分位数回归层, 进而估计剩余寿命预测区间. 所提方法在模拟图形数据集、真实风电场的轴承数据集、涡扇发动机数据集以及工具磨损数据集上运行效果良好.

深度学习分位数回归模型的主要优点在于: (1) 深度学习分位数回归模型具有很好的鲁棒性, 能够很好地处理异常数据、离群值或噪声; (2) 深度学习分位数回归模型的网络结构非常灵活, 可以根据实际需求进行扩展和改进; (3) 深度学习分位数回归模型可结合核密度估计技术实现概率预测. 尽管如此, 深度学习分位数回归模型需要计算不同分位点下的深度学习模型参数, 因而计算复杂度较高. 此外, 深度学习分位数回归模型的分位数预测值有可能交叉, 影响概率预测的合理性.

## 2.6 基于深度学习的剩余寿命区间预测模型对比

为直观比较, 表 1 归纳了 5 种基于深度学习的剩余寿命区间预测模型的优缺点. 从表 1 中可以看出, 随机过程深度学习模型、贝叶斯深度学习模型和深度学习分位数回归模型可实现装备剩余寿命的概率预测, 而当需要构建预测区间时, 可利用试探法从剩余寿命概率分布中获得最优预测区间. 相比于自举深度学习模型、贝叶斯深度学习模型以及深度学习分位数回归模型, 局部不确定性模型和随机过程深度学习模型的计算复杂度相对较低. 因此, 在进行基于深度学习的装备剩余寿命区间预测时, 需要权衡不同区间预测模型的优缺点, 并选择合适的方法和技术以满足实际需求.

## 3 总结与展望

预测区间量化了与剩余寿命预测相关的不确定性, 在构建可靠的装备运行维护系统中发挥着关键作用. 本文面向深度学习背景下装备剩余寿命预测中不确定性量化的现实需求, 重点介绍了自举深度学习、局部不确定性、随机过程深度学习、贝叶斯深度学习以及深度学习分位数回归等剩余寿命区间预测模型的发展动态, 探讨了模型各自的优缺点. 然而基于深度学习的装备剩余寿命区间预测研究仍处于起步阶段, 存在一些明显的挑战性问题亟待解决:

(1) 深度学习区间预测模型的复杂性问题. 虽然基于深度学习的装备剩余寿命区间预测研究已取得了一些成果, 但当前大多数研究在构建区间预测模型上计算量偏大. 如自举法需要构建  $B+1$

表 1 基于深度学习的装备剩余寿命区间预测模型优缺点

Table 1 Advantages and disadvantages of remaining useful life interval prediction models for equipment based on deep learning

Interval prediction model	Refs.	Advantage	Disadvantage
Bootstrap deep learning	[40–45]	Prevention of overfitting; Improvement of generalization ability	High computational complexity; Possible loss of some information; Bias in estimating the variance of model uncertainty
Local uncertainty	[46–52]	Low computational complexity; No need to make any assumptions about residuals	Need for selecting an appropriate number of clusters; Model's lack of interpretability
Stochastic process deep learning	[62–66]	Consideration of multiple influencing factors; Probability prediction ability; Real-time update based on current data	Difficulty in selecting appropriate stochastic process models; Complexity in model building; High requirement for estimation of model parameters
Bayesian deep learning	[71–81]	Prevention of overfitting; Handling high complexity tasks; Probability prediction ability	High computational complexity; Deviation of prior distribution from true distribution; Difficulty in selecting hyper-parameters
Deep learning quantile regression	[83–89]	Strong robustness; Strong scalability; Probability prediction ability	High computational complexity; Crossover of quantile predictions

个深度学习模型, 贝叶斯深度学习的推理过程较为复杂, 分位数回归则需要训练多个分位点下的深度学习回归模型. 因而在后续研究中, 需要优化现有模型的复杂度抑或探索新的剩余寿命区间预测方法, 以进一步提升区间预测模型的计算效率.

(2) 非理想数据下的剩余寿命区间预测问题. 数据是开展基于深度学习的剩余寿命区间预测研究的基础, 数据质量很大程度决定了剩余寿命区间预测的质量. 然而, 现代工程装备的监测数据往往呈现非理想状态, 具体表现为大而非平衡、局部缺失、不完备等特点, 这将导致基于这些数据建立的剩余寿命预测模型泛化能力不足, 局限于某一特定条件. 因而在后续研究中, 结合数据增强、迁移学习等技术将有望改善数据质量从而提升剩余寿命区间预测效果.

(3) 剩余寿命区间预测和维护决策的联合研究问题. 剩余寿命区间预测与维护决策是一个有机整体, 它为降低装备停机时间、提升装备可靠性以及保障装备运行维护经济性提供了一套切实可行的完整方案. 由于综合考虑系统安全运行全过程的研究是一项非常庞大而复杂的工作, 且在现有研究成果中较少定量分析各阶段输入及输出之间的相互影响, 使得剩余寿命区间预测和维护决策的整体联合研究进展较为缓慢. 因而在后续研究中, 需要准确刻画它们之间的定量关系, 并充分考虑多目标、多决策变量的优化问题.

## 参 考 文 献

- [1] Lu N Y, Chen C, Jiang B, et al. Latest progress on maintenance strategy of complex system: From condition-based maintenance to predictive maintenance. *Acta Autom Sin*, 2021, 47(1): 1  
(陆宁云, 陈闯, 姜斌, 等. 复杂系统维护策略最新研究进展: 从视情维护到预测性维护. *自动化学报*, 2021, 47(1): 1)
- [2] Hu C H, Zhang H, Yu Y, et al. Deep learning-based RUL prediction of complex degradation systems: State of the art and challenges. *Electron Opt Contr*, 2021, 28(2): 1  
(胡昌华, 张浩, 喻勇, 等. 基于深度学习的复杂退化系统剩余寿命预测研究现状与挑战. *电光与控制*, 2021, 28(2): 1)
- [3] Zhou D H, Wei M H, Si X S. A survey on anomaly detection, life prediction and maintenance decision for industrial processes. *Acta Autom Sin*, 2013, 39(6): 711  
(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. *自动化学报*, 2013, 39(6): 711)
- [4] Chen C, Lu N Y, Jiang B, et al. A risk-averse remaining useful life estimation for predictive maintenance. *IEEE/CAA J Autom Sin*, 2021, 8(2): 412
- [5] Chen C, Zhu Z H, Shi J T, et al. Dynamic predictive maintenance scheduling using deep learning ensemble for system health prognostics. *IEEE Sens J*, 2021, 21(23): 26878
- [6] Chen C, Lu N Y, Jiang B, et al. Condition-based maintenance optimization for continuously monitored degrading systems under imperfect maintenance actions. *J Syst Eng Electron*, 2020, 31(4): 841
- [7] Yuan Y, Zhang Y, Ding H. Research on key technology of industrial artificial intelligence and its application in predictive maintenance. *Acta Autom Sin*, 2020, 46(10): 2013  
(袁烨, 张永, 丁汉. 工业人工智能的关键技术及其在预测性维护中的应用现状. *自动化学报*, 2020, 46(10): 2013)
- [8] Ma M, Mao Z. Deep-convolution-based LSTM network for remaining useful life prediction. *IEEE Trans Ind Inform*, 2021, 17(3): 1658
- [9] Wang C S, Lu N Y, Cheng Y H, et al. A data-driven aero-engine degradation prognostic strategy. *IEEE Trans Cybern*, 2021, 51(3): 1531
- [10] Wu J, Hu K, Cheng Y W, et al. Data-driven remaining useful life prediction via multiple sensor signals and deep long short-term memory neural network. *ISA Trans*, 2020, 97: 241
- [11] Zhang Y F, Lu Z Q. Remaining useful life prediction based on an integrated neural network. *Chin J Eng*, 2020, 42(10): 1372  
(张永峰, 陆志强. 基于集成神经网络的剩余寿命预测. *工程科*

- 学学报, 2020, 42(10): 1372)
- [12] Liu H, Liu Z Y, Jia W Q, et al. Remaining useful life prediction using a novel feature-attention-based end-to-end approach. *IEEE Trans Ind Inform*, 2021, 17(2): 1197
- [13] Wei M, Wang Q, Ye M, et al. An indirect remaining useful life prediction of lithium-ion batteries based on a NARX dynamic neural network. *Chin J Eng*, 2022, 44(3): 380  
(魏孟, 王桥, 叶敏, 等. 基于 NARX 动态神经网络的锂离子电池剩余寿命间接预测. *工程科学学报*, 2022, 44(3): 380)
- [14] Yu Y, Si X S, Hu C H, et al. Data driven reliability assessment and life-time prognostics: A review on covariate models. *Acta Autom Sin*, 2018, 44(2): 216  
(喻勇, 司小胜, 胡昌华, 等. 数据驱动的可可靠性评估与寿命预测研究进展: 基于协变量的方法. *自动化学报*, 2018, 44(2): 216)
- [15] Pei H, Hu C H, Si X S, et al. Review of machine learning based remaining useful life prediction methods for equipment. *J Mech Eng*, 2019, 55(8): 1  
(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. *机械工程学报*, 2019, 55(8): 1)
- [16] Li Y, Wang J F, Mo W Q, et al. A review of remaining useful life prediction for lithium-ion batteries based on data-driven. *J Power Supply*, <https://kns.cnki.net/kcms/detail/12.1420.TM.20230613.1715.002.html>  
(李银, 王建峰, 莫伟权, 等. 基于数据驱动的锂离子电池剩余寿命预测综述. *电源学报*, <https://kns.cnki.net/kcms/detail/12.1420.TM.20230613.1715.002.html>)
- [17] Wang Y D, Zhao Y F, Addepalli S. Remaining useful life prediction using deep learning approaches: A review. *Procedia Manuf*, 2020, 49: 81
- [18] Li T M, Si X S, Liu X, et al. Data-model interactive remaining useful life prediction technologies for stochastic degrading devices with big data. *Acta Autom Sin*, 2022, 48(9): 2119  
(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. *自动化学报*, 2022, 48(9): 2119)
- [19] Khosravi A, Nahavandi S, Creighton D, et al. Comprehensive review of neural network-based prediction intervals and new advances. *IEEE Trans Neural Netw*, 2011, 22(9): 1341
- [20] Li J F, Chen Y X, Xiang H C, et al. Remaining useful life prediction for aircraft engine based on LSTM-DBN. *Syst Eng Electron*, 2020, 42(7): 1637  
(李京峰, 陈云翔, 项华春, 等. 基于 LSTM-DBN 的航空发动机剩余寿命预测. *系统工程与电子技术*, 2020, 42(7): 1637)
- [21] Liao L X, Jin W J, Pavel R. Enhanced restricted Boltzmann machine with prognosability regularization for prognostics and health assessment. *IEEE Trans Ind Electron*, 2016, 63(11): 7076
- [22] Zhang C, Lim P, Qin A K, et al. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics. *IEEE Trans Neural Netw Learn Syst*, 2017, 28(10): 2306
- [23] Ma M, Sun C, Chen X F. Discriminative deep belief networks with ant colony optimization for health status assessment of machine. *IEEE Trans Instrum Meas*, 2017, 66(12): 3115
- [24] Deutsch J, He D. Using deep learning-based approach to predict remaining useful life of rotating components. *IEEE Trans Syst Man Cybern*, 2018, 48(1): 11
- [25] Deutsch J, He M A, He D. Remaining useful life prediction of hybrid ceramic bearings using an integrated deep learning and particle filter approach. *Appl Sci*, 2017, 7(7): 649
- [26] Guo H, Ren B C, Yan X G, et al. Research on dynamic prediction of tool life based on deep convolutional neural network. *Contr Decis*, 2022, 37(8): 2119  
(郭宏, 任必聪, 闫献国, 等. 基于深度卷积神经网络的刀具寿命动态预测研究. *控制与决策*, 2022, 37(8): 2119)
- [27] Kara A. Multi-scale deep neural network approach with attention mechanism for remaining useful life estimation. *Comput Ind Eng*, 2022, 169: 108211
- [28] Xu X W, Li X, Ming W W, et al. A novel multi-scale CNN and attention mechanism method with multi-sensor signal for remaining useful life prediction. *Comput Ind Eng*, 2022, 169: 108204
- [29] Zhu J, Chen N, Peng W W. Estimation of bearing remaining useful life based on multiscale convolutional neural network. *IEEE Trans Ind Electron*, 2019, 66(4): 3208
- [30] Yang B Y, Liu R N, Zio E. Remaining useful life prediction based on a double-convolutional neural network architecture. *IEEE Trans Ind Electron*, 2019, 66(12): 9521
- [31] Kim T S, Sohn S Y. Multitask learning for health condition identification and remaining useful life prediction: Deep convolutional neural network approach. *J Intell Manuf*, 2021, 32(8): 2169
- [32] Shi Y S, Shi M Z, Ding E S, et al. Combined prediction method of lithium-ion battery life based on CEEMDAN-LSTM. *Chin J Eng*, 2021, 43(7): 985  
(史永胜, 施梦琢, 丁恩松, 等. 基于 CEEMDAN-LSTM 组合的锂离子电池寿命预测方法. *工程科学学报*, 2021, 43(7): 985)
- [33] Zhu X Y, Zhang P, Xie M. A joint long shortterm memory and adaBoost regression approach with application to remaining useful life estimation. *Measurement*, 2021, 170: 108707
- [34] Wu J Y, Wu M, Chen Z H, et al. Degradation-aware remaining useful life prediction with LSTM autoencoder. *IEEE Trans Instrum Meas*, 2021, 70: 1
- [35] Xiang S, Qin Y, Luo J, et al. Multicellular LSTM-based deep learning model for aero-engine remaining useful life prediction. *Reliab Eng Syst Saf*, 2021, 216: 107927
- [36] Jin R B, Chen Z H, Wu K Y, et al. Bi-LSTM-based two-stream network for machine remaining useful life prediction. *IEEE Trans Instrum Meas*, 2022, 71: 1
- [37] Sun S G, Liu J F, Wang J Q, et al. Remaining useful life prediction for AC contactor based on MMPE and LSTM with dual attention mechanism. *IEEE Trans Instrum Meas*, 2022, 71: 1
- [38] Shrivastava N A, Khosravi A, Panigrahi B K. Prediction interval estimation of electricity prices using PSO-tuned support vector machines. *IEEE Trans Ind Inform*, 2015, 11(2): 322

- [39] Lins I D, Droguett E L, das Chagas Moura M, et al. Computing confidence and prediction intervals of industrial equipment degradation by bootstrapped support vector regression. *Reliab Eng Syst Saf*, 2015, 137: 120
- [40] Huang C G, Huang H Z, Li Y F, et al. A novel deep convolutional neural network-bootstrap integrated method for RUL prediction of rolling bearing. *J Manuf Syst*, 2021, 61: 757
- [41] Huang C G, Huang H Z, Li Y F, et al. Fault prognosis using deep convolutional neural network and bootstrap-based method // 2020 *IEEE 18th International Conference on Industrial Informatics (INDIN)*. Warwick, 2021: 742
- [42] Liao Y, Zhang L X, Liu C D. Uncertainty prediction of remaining useful life using long short-term memory network based on bootstrap method // 2018 *IEEE International Conference on Prognostics and Health Management (ICPHM)*. Seattle, 2018: 1
- [43] Zhao C Y, Huang X Z, Liu H Z, et al. A novel bootstrap ensemble learning convolutional simple recurrent unit method for remaining useful life interval prediction of turbofan engines. *Meas Sci Technol*, 2022, 33(12): 125004
- [44] She D M, Jia M P. A BiGRU method for remaining useful life prediction of machinery. *Measurement*, 2021, 167: 108277
- [45] Guo J Y, Wang J, Wang Z Y, et al. A CNN-BiLSTM-Bootstrap integrated method for remaining useful life prediction of rolling bearings. *Qual Reliab Eng Int*, 2023, 39(5): 1796
- [46] Shrestha D L, Solomatine D P. Machine learning approaches for estimation of prediction interval for the model output. *Neural Netw*, 2006, 19(2): 225
- [47] Zhang Z D, Qin H, Yao L Q, et al. Interval prediction method based on long-short term memory networks for system integrated of hydro, wind and solar power. *Energy Procedia*, 2019, 158: 6176
- [48] Solomatine D P, Shrestha D L. A novel method to estimate model uncertainty using machine learning techniques. *Water Resour Res*, 2009, 45(12): W00B11
- [49] Dogulu N, López López P, Solomatine D P, et al. Estimation of predictive hydrologic uncertainty using the quantile regression and UNEEC methods and their comparison on contrasting catchments. *Hydrol Earth Syst Sci*, 2015, 19(7): 3181
- [50] Rahmati O, Choubin B, Fathabadi A, et al. Predicting uncertainty of machine learning models for modelling nitrate pollution of groundwater using quantile regression and UNEEC methods. *Sci Total Environ*, 2019, 688: 855
- [51] Chen C, Lu N Y, Jiang B, et al. Prediction interval estimation of aeroengine remaining useful life based on bidirectional long short-term memory network. *IEEE Trans Instrum Meas*, 2021, 70: 1
- [52] Chen C, Shi J T, Lu N Y, et al. Data-driven predictive maintenance strategy considering the uncertainty in remaining useful life prediction. *Neurocomputing*, 2022, 494: 79
- [53] Ross S M. *Stochastic Processes*. Hoboken: John Wiley & Sons, 1995
- [54] Song K, Cui L R. A common random effect induced bivariate gamma degradation process with application to remaining useful life prediction. *Reliab Eng Syst Saf*, 2022, 219: 108200
- [55] Wang H, Liao H T, Ma X B, et al. Remaining useful life prediction and optimal maintenance time determination for a single unit using isotonic regression and gamma process model. *Reliab Eng Syst Saf*, 2021, 210: 107504
- [56] Ling M H, Ng H K T, Tsui K L. Bayesian and likelihood inferences on remaining useful life in two-phase degradation models under gamma process. *Reliab Eng Syst Saf*, 2019, 184: 77
- [57] Zhang S Y, Zhai Q Q, Shi X, et al. A Wiener process model with dynamic covariate for degradation modeling and remaining useful life prediction. *IEEE Trans Reliab*, 2023, 72(1): 214
- [58] Yu W N, Shao Y M, Xu J, et al. An adaptive and generalized Wiener process model with a recursive filtering algorithm for remaining useful life estimation. *Reliab Eng Syst Saf*, 2022, 217: 108099
- [59] Li N P, Lei Y G, Yan T, et al. A Wiener-process-model-based method for remaining useful life prediction considering unit-to-unit variability. *IEEE Trans Ind Electron*, 2019, 66(3): 2092
- [60] Mehr C B, McFadden J A. Certain properties of Gaussian processes and their first-passage times. *J R Stat Soc*, 1965, 27(3): 505
- [61] Yang X, Chen B C, Zhu L, et al. Short-term public building load probability density prediction based on correlation analysis and long- and short-term memory network quantile regression. *Power Syst Technol*, 2019, 43(9): 3061  
(杨秀, 陈斌超, 朱兰, 等. 基于相关性分析和长短期记忆网络分位数回归的短期公共楼宇负荷概率密度预测. 电网技术, 2019, 43(9): 3061)
- [62] Hu C H, Pei H, Si X S, et al. A prognostic model based on DBN and diffusion process for degrading bearing. *IEEE Trans Ind Electron*, 2020, 67(10): 8767
- [63] Li T M, Pei H, Si X S, et al. Prognosis for stochastic degrading systems with massive data: A data-model interactive perspective. *Reliab Eng Syst Saf*, 2023, 237: 109344
- [64] Zhou T, Wang Y C, Zhang X J, et al. Data-model interactive remaining useful life prediction of stochastic degrading devices based on deep feature fusion network. *Comput Integr Manuf Syst*, 2022, 28(12): 3937  
(周涛, 汪永超, 张栩静, 等. 基于深度特征融合网络的数模联动随机退化设备剩余寿命预测. 计算机集成制造系统, 2022, 28(12): 3937)
- [65] Zhang J S, Huang C S, Chow M Y, et al. A data-model interactive remaining useful life prediction approach of lithium-ion batteries based on PF-BiGRU-TSAM. *IEEE Trans Ind Inform*, 2023, PP(99): 1
- [66] Chen X W, Liu Z. A long short-term memory neural network-based Wiener process model for remaining useful life prediction. *Reliab Eng Syst Saf*, 2022, 226: 108651
- [67] Bernardo J M, Smith A F M. *Bayesian Theory*. Hoboken: Wiley & Sons, 2009
- [68] Ji W Q. *Research on Data-driven Remaining Useful Life*

- Prediction Method Based on Deep Learning and Uncertainty Quantification* [Dissertation]. Hefei: University of Science and Technology of China, 2020  
(季文强. 基于深度学习和不确定性量化的数据驱动剩余寿命预测方法研究 [学位论文]. 合肥: 中国科学技术大学, 2020)
- [69] Peng W W, Ye Z S, Chen N. Bayesian deep-learning-based health prognostics toward prognostics uncertainty. *IEEE Trans Ind Electron*, 2020, 67(3): 2283
- [70] Gal Y, Ghahramani Z. Dropout as a Bayesian approximation: Representing model uncertainty in deep learning // *Proceedings of International Conference on Machine Learning*. New York, 2016: 1050
- [71] Benker M, Furtner L, Semm T, et al. Utilizing uncertainty information in remaining useful life estimation via Bayesian neural networks and Hamiltonian Monte Carlo. *J Manuf Syst*, 2021, 61: 799
- [72] Chen K J, Liu J N, Guo W W, et al. A two-stage approach based on Bayesian deep learning for predicting remaining useful life of rolling element bearings. *Comput Electr Eng*, 2023, 109: 108745
- [73] Kim M, Liu K B. A Bayesian deep learning framework for interval estimation of remaining useful life in complex systems by incorporating general degradation characteristics. *IISE Trans*, 2021, 53(3): 326
- [74] Kraus M, Feuerriegel S. Forecasting remaining useful life: Interpretable deep learning approach via variational Bayesian inferences. *Decis Support Syst*, 2019, 125: 113100
- [75] Huang D S, Bai R, Zhao S, et al. A hybrid Bayesian deep learning model for remaining useful life prognostics and uncertainty quantification // *2021 IEEE International Conference on Prognostics and Health Management (ICPHM)*. Detroit (Romulus), 2021: 1
- [76] Caceres J, Gonzalez D, Zhou T T, et al. A probabilistic Bayesian recurrent neural network for remaining useful life prognostics considering epistemic and aleatory uncertainties. *Struct Contr Health Monit*, 2021, 28(10): e2811
- [77] Mazaev G, Crevecoeur G, Van Hoescke S. Bayesian convolutional neural networks for remaining useful life prognostics of solenoid valves with uncertainty estimations. *IEEE Trans Ind Inform*, 2021, 17(12): 8418
- [78] Zhu R, Chen Y, Peng W W, et al. Bayesian deep-learning for RUL prediction: An active learning perspective. *Reliab Eng Syst Saf*, 2022, 228: 108758
- [79] Zhuang L L, Xu A C, Wang X L. A prognostic driven predictive maintenance framework based on Bayesian deep learning. *Reliab Eng Syst Saf*, 2023, 234: 109181
- [80] Zhang S X, Liu Z T, Su H Y. A Bayesian mixture neural network for remaining useful life prediction of lithium-ion batteries. *IEEE Trans Transp Electrif*, 2022, 8(4): 4708
- [81] Zhang H, Hu C H, Du D B, et al. Remaining useful life prediction method of lithium-ion battery based on Bi-LSTM network under multi-state influence. *Acta Electron Sin*, 2022, 50(3): 619  
(张浩, 胡昌华, 杜党波, 等. 多状态影响下基于 Bi-LSTM 网络的锂电池剩余寿命预测方法. *电子学报*, 2022, 50(3): 619)
- [82] Koenker R. *Quantile Regression*. Cambridge: Cambridge University Press, 2005
- [83] Liu Z, Zhang C, Qi L, et al. Prediction of probability density of remaining useful life of lithium ion battery based on CNN-BiLSTM. *Chin J Power Sources*, 2023, 47(1): 57  
(刘泽, 张闯, 齐磊, 等. 基于 CNN-BiLSTM 的锂电池剩余使用寿命概率密度预测. *电源技术*, 2023, 47(1): 57)
- [84] Borrè A, Seman L O, Camponogara E, et al. Machine fault detection using a hybrid CNN-LSTM attention-based model. *Sensors*, 2023, 23(9): 4512
- [85] Chen C, Shi J T, Shen M Q, et al. A predictive maintenance strategy using deep learning quantile regression and kernel density estimation for failure prediction. *IEEE Trans Instrum Meas*, 2023, 72: 1
- [86] Chen C, Tao G Y, Shi J T, et al. A lithium-ion battery degradation prediction model with uncertainty quantification for its predictive maintenance. *IEEE Trans Ind Electron*, 2024, 71(4): 3650
- [87] Zhang M, Wang D, Amaitik N, et al. A distributional perspective on remaining useful life prediction with deep learning and quantile regression. *IEEE Open J Instrum Meas*, 2022, 1: 1
- [88] Tian Q P, Wang H L. Predicting remaining useful life of rolling bearings based on reliable degradation indicator and temporal convolution network with the quantile regression. *Appl Sci*, 2021, 11(11): 4773
- [89] Wang L, Cao H R, Xu H, et al. A gated graph convolutional network with multi-sensor signals for remaining useful life prediction. *Knowl Based Syst*, 2022, 252: 109340