

文章编号:1000-8055(2020)06-1212-10

doi:10.13224/j.cnki.jasp.2020.06.011

基于 InfoLSGAN 和 AC 算法的 滚动轴承剩余寿命预测

于广滨^{1,2}, 卓 识^{1,2}, 于 军^{1,3}, 刘 可³

- (1. 哈尔滨理工大学 先进制造智能化技术教育部重点实验室, 哈尔滨 150080;
2. 哈尔滨理工大学 机械动力工程学院, 哈尔滨 150080;
3. 哈尔滨理工大学 自动化学院, 哈尔滨 150080)

摘 要: 为解决小样本和噪声干扰下滚动轴承剩余寿命(RUL)预测准确率低的问题,提出一种基于信息最小二乘生成对抗网络(information least squares generative adversarial network,InfoLSGAN)和行动者-评论家(actor-critic,AC)算法的滚动轴承剩余寿命预测方法。将堆叠降噪自动编码器、信息生成对抗网络 and 最小二乘生成对抗网络相结合,构建 InfoLSGAN,自动地从噪声数据中提取可解释的鲁棒特征,解决梯度消失问题;采用基于 AC 的训练算法训练 InfoLSGAN,减少训练时间,加快收敛速度;根据训练后的 InfoLSGAN,利用 softmax 分类器预测测试样本中滚动轴承的剩余寿命。通过滚动轴承加速疲劳寿命试验验证该方法的有效性。试验结果证明,当信噪比等于 0 时,该方法对滚动轴承测试样本的寿命预测准确率至少提高了 10%。在小样本情况下,滚动轴承剩余寿命预测的平均准确率达 95.84%。

关 键 词: 滚动轴承; 剩余寿命预测; 信息最小二乘; 生成对抗网络; 行动者-评论家算法; 堆叠降噪自动编码器

中图分类号: V232; TH17 文献标志码: A

Remaining useful life prediction of rolling bearings using InfoLSGAN and AC algorithm

YU Guangbin^{1,2}, ZHUO Shi^{1,2}, YU Jun^{1,3}, LIU Ke³

- (1. Key Laboratory of Advanced Manufacturing and Intelligent Technology, Ministry of Education,
Harbin University of Science and Technology, Harbin 150080, China;
2. School of Mechanical and Power Engineering,
Harbin University of Science and Technology, Harbin 150080, China;
3. School of Automation,
Harbin University of Science and Technology, Harbin 150080, China)

Abstract: In order to solve the problem of low remaining useful life (RUL) accuracy of rolling bearings under small samples and noise interference, a RUL prediction method of

收稿日期: 2019-12-23
基金项目: 国家重点基础研究发展计划(2019YFB2006400); 黑龙江省“百千万”工程科技重大专项(2019ZX03A02); 黑龙江省杰出青年基金(JC2014020)
作者简介: 于广滨(1978—),男,教授、博士生导师,博士,主要研究方向为机械动力学、人工智能技术等。
通信作者: 于军(1984—),男,讲师、硕士生导师,博士,主要研究方向为机械设备故障诊断与剩余寿命预测。
E-mail: shengda1302@126.com

引用格式: 于广滨,卓识,于军,等. 基于 InfoLSGAN 和 AC 算法的滚动轴承剩余寿命预测[J]. 航空动力学报,2020,35(6):1212-1221. YU Guangbin,ZHUO Shi,YU Jun,et al. Remaining useful life prediction of rolling bearings using InfoLSGAN and AC algorithm[J]. Journal of Aerospace Power,2020,35(6):1212-1221.

rolling bearings using information least squares generative adversarial network (InfoLSGAN) and actor-critic (AC) algorithm was proposed. Stacked denoising autoencoder, information generative adversarial network and least squares generative adversarial network were integrated to construct InfoLSGAN, which can automatically extract interpretable and robust features from noisy data, and solve the problem of vanishing gradients. The training algorithm based on AC was utilized to train the InfoLSGAN to reduce the training time and accelerate the convergence. According to the InfoLSGAN after training, a softmax classifier was used to predict the rolling bearing RUL in test samples. The effectiveness of the proposed method was validated through an accelerated fatigue life experiment of rolling bearings. The experimental results demonstrated that when the signal-to-noise ratio was equal to 0, the proposed method increased the RUL prediction accuracy of rolling bearing test samples by at least 10%. In the case of small samples, the average accuracy of the RUL prediction of rolling bearings was 95.84%.

Key words: rolling bearing; remaining useful life prediction; information least squares; generative adversarial network; actor-critic algorithm; stacked denoising autoencoder

近年来,滚动轴承在航空航天、轨道交通、海洋工程等高端装备中得到广泛应用^[1]。滚动轴承作为重大装备和主机产品的关键基础零件,正朝着高速度、高精度、高可靠性、长寿命等方面发展。然而,复杂恶劣的工作环境导致滚动轴承的故障率相对较高^[2]。对事关人身安全的飞机而言,任何难以预料的故障均会影响飞机的使用寿命,甚至导致飞行事故的发生^[3]。因此,滚动轴承的剩余寿命预测对延长飞机的使用寿命和避免飞行事故的发生具有十分重要的意义。

近年来,滚动轴承的剩余寿命预测已受到大量学者的高度重视。众多具代表性的滚动轴承剩余寿命预测方法被相继提出^[4]。这些方法可分为模型法和数据驱动法。模型法通过建立基于失效机理的物理模型,描述滚动轴承的退化过程。与材料特性相关的模型参数可通过专门的试验或分析方法确定^[5]。尽管模型法可准确预测滚动轴承的剩余寿命,但难于建立精确的滚动轴承退化模型。确定模型参数还需要大量的试验和经验数据,从而限制了模型法的广泛应用。

数据驱动法通过统计模型或人工智能技术,学习滚动轴承退化过程,实现滚动轴承剩余寿命的预测。统计模型包括自适应回归模型^[6]、随机系数模型^[7]、Wiener 过程模型^[8]、全阶乘模型^[9]等。尽管随机变量的引入可改进统计模型的柔性,但其预测效果严重依赖历史数据,从而影响滚动轴承剩余寿命预测的准确率。并且,随机变量的概率分布需满足多种假设。常用的人工智能技

术包括人工神经网络^[10]、模糊逻辑系统^[11]、支持向量机^[12]、Gaussian 过程回归^[13]等。人工智能技术无需精确的解析模型,通过历史数据识别退化过程。然而,特征提取仍然是一个耗时的过程。提取的冗余特征很可能降低预测准确率。这些原因限制了人工智能技术在滚动轴承剩余寿命预测上的应用。

深度神经网络(deep neural networks, DNNs)因其强大的建模和表征能力,已被成功应用于滚动轴承的剩余寿命预测。Zhu 等^[14]提出了一种基于时频表示和多尺度卷积神经网络的轴承剩余寿命预测方法。Ren 等^[15]将深度自编码器和 DNNs 应用于轴承的剩余寿命预测。Xia 等^[16]开发了一种两级自动 DNNs,用于准确判断轴承剩余寿命。Li 等^[17]提出了一种基于分层门控循环单元神经网络的改进健康指标,用于轴承剩余寿命预测。与传统的数据驱动法相比,DNNs 无需额外的先验知识,模型参数可联合训练。因此,DNNs 在滚动轴承的剩余寿命预测方面具重要的应用价值。然而,由于齿轮啮合的干扰,采集到的滚动轴承振动信号通常被强烈的噪声所干扰。这会严重影响滚动轴承剩余寿命预测的效果。并且,滚动轴承加速疲劳寿命试验耗时且投入巨大,仅能获得有限的试验样本。为此,本文提出一种基于信息最小二乘生成对抗网络(information least squares generative adversarial network, InfoLSGAN)和行动者-评论家(actor-critic, AC)算法的滚动轴承剩余寿命预测方法。

构建 InfoLSGAN, 自动地从噪声数据中提取可解释的鲁棒特征, 解决梯度消失问题; 采用基于 AC 的训练算法训练 InfoLSGAN, 减少训练时间, 加快收敛速度; 根据训练后的 InfoLSGAN, 利用 softmax 分类器预测测试样本中滚动轴承的剩余寿命。

1 基本理论

1.1 堆叠降噪自动编码器

自动编码器 (autoencoder, AE) 是一种对称的非监督三层神经网络。它通过最小化重构误差, 复现输入数据。降噪自动编码器 (denoising autoencoder, DAE) 将降噪编码添加到 AE 中, 从而提高 AE 的抗噪能力。DAE 的基本思想是从特定的含噪输入中获得鲁棒特征。然而, 单隐层结构限制了 DAE 的特征提取能力。为提取深层次的特征, 将多个 DAE 堆叠形成多隐层深度学习模型, 即堆叠降噪自动编码器 (stacked denoising autoencoder, SDAE)^[18]。其模型结构如图 1 所示。SDAE 包含一个输入层、一个输出层和 n 个隐层。其训练过程包括预训练和微调两个环节。预训练环节是以无监督的方式实现分层表示学习。 $\{x^m\}_{m=1}^M$ 为输入样本集, 将随机噪声加入样本 x^m , 获得含噪样本 $\tilde{x}^m$, 含噪样本 $\tilde{x}^m$ 通过 DAE 映射为 h_1^m 。然后, h_1^m 映射为 h_2^m 。重复这个过程, 直到获得 h_n^m 。将 softmax 分类器用于输出层, 输出 c^m 定义为

$$c^m = g_{\theta_{n+1}}(h_n^m) \tag{1}$$

式中 θ_{n+1} 为输出层的参数集, $g(\cdot)$ 为 softmax 分类器的激活函数。SDAE 通过最小化交叉熵损失函数 L_{SDAE} 实现微调, 采用 Adam 优化算法^[18] 微调 SDAE 的参数集。

$$L_{\text{SDAE}} = \underset{\Theta}{\operatorname{argmin}} -$$

$$\frac{1}{M} \sum_{m=1}^M [y^m \ln c^m - (1 - y^m) \ln (1 - c^m)] \tag{2}$$

式中 M 为样本数, Θ 为 SDAE 的参数集, 且 $\Theta =$




图 1 SDAE 的模型结构
Fig. 1 Structure of SDAE model

$$\{\theta_1, \theta_1, \dots, \theta_{n+1}\}.$$

1.2 最小二乘生成对抗网络

GAN 是 2014 年由 Goodfellow 等提出的一种深度学习模型。GAN 并不是一个完整的网络模型, 而是一种网络训练框架。该框架仅由生成器和判别器组成。它的基本思想来源于博弈论中的零和博弈。生成器用于生成尽量服从真实数据分布的样本, 判别器用于判断输入样本是真实样本还是生成样本, 优化目标是通过对抗机制使两者达到纳什均衡。GAN 的模型结构如图 2 所示。输入随机噪声 z , 使生成器 G 生成尽量服从真实数据分布 $P_{\text{data}}(x)$ 的样本 $G(z)$ 。判别器 D 判断输入样本是真实数据 x 还是生成样本 $G(z)$ 。目标函数 $V(D, G)$ 为

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\log D(x)] + E_{z \sim P_z(z)} \{\log [1 - D(G(z))]\} \tag{3}$$

式中 $P_z(z)$ 表示先验噪声分布; $E_{x \sim P_{\text{data}}(x)} [\log D(x)]$ 表示将真实数据 x 输入判别器 D 获得是否为真实数据的概率; $E_{z \sim P_z(z)} \{\log [1 - D(G(z))]\}$ 表示随机噪声 z 输入生成器 G 产生的生成样本, 判别器 D 判别其为真实数据的概率。生成器 G 尝试最小化目标函数, 判别器 D 尝试最大化目标函数。当生成器 G 固定, 且式 (4) 中的 1 阶偏导数为 0 时, 可通过式 (5) 获得最优判别器 D 。

$$\frac{\partial F(D)}{\partial D(x)} = D(x)^{P_{\text{data}}(x)-1} [1 - D(x)]^{P_g(x)-1} \{P_{\text{data}}(x)[1 - D(x)] - P_g(x)D(x)\} \tag{4}$$

$$D^*(x) = \frac{P_{\text{data}}(x)}{P_{\text{data}}(x) + P_g(x)} \tag{5}$$

式中 $P_g(x)$ 为生成样本的数据分布。 $F(D)$ 为积分变量值。最优生成器 G 可由式 (6) 获得。

$$L(G) = E_{x \sim P_{\text{data}}(x)} [\log D^*(x)] + E_{z \sim P_z(z)} \{\log [1 - D^*(G(z))]\} = -\log(4) + 2D_{\text{JS}}(P_{\text{data}} \| P_g) \tag{6}$$

式中 $L(G)$ 为生成器 G 的成本函数。 $D_{\text{JS}}(\cdot)$ 为 Jensen-Shannon 散度。当 $P_{\text{data}} = P_g$ 时, Jensen-




图 2 GAN 的模型结构
Fig. 2 Structure of GAN model

Shannon 散度等于 0, 且 $L(G)$ 达到最小值。

原始 GAN 的判别器 D 采用 sigmoid 交叉熵损失函数, 生成器 G 采用极大极小损失函数和非饱和损失函数。然而, 这类损失函数可能导致梯度消失问题。为解决该问题, Mao 等^[19]提出了最小二乘生成对抗网络 (least squares generative adversarial network, LSGAN)。LSGAN 采用最小二乘损失函数代替交叉熵损失函数。判别器 D 采用 a - b 编码策略。LSGAN 的目标函数定义为

$$\begin{aligned} \min_D V_{\text{LSGAN}}(D) &= \frac{1}{2} E_{x \sim P_{\text{data}}(x)} [(D(x) - b)^2] + \\ &\quad \frac{1}{2} E_{z \sim P_z(z)} \{ [D(G(z)) - a]^2 \} \\ \min_G V_{\text{LSGAN}}(G) &= \frac{1}{2} E_{z \sim P_z(z)} \{ [D(G(z)) - c]^2 \} \end{aligned} \quad (7)$$

式中 a 和 b 分别为生成样本和真实数据的标签。 c 为生成器 G 希望判别器 D 相信生成样本的期望标签。当 $b - c = 1$ 且 $b - a = 2$ 时, $L(G)$ 被改变为

$$2L(G) = \int_{\mathcal{X}} \frac{\{2P_g(x) - [P_{\text{data}}(x) + P_g(x)]\}^2}{P_{\text{data}}(x) + P_g(x)} dx = \chi_{\text{Pearson}}^2(P_{\text{data}} + P_g \| 2P_g) \quad (9)$$

式中 χ_{Pearson}^2 为 Pearson χ^2 散度。所以, LSGAN 的成本函数致力于最小化 $P_{\text{data}} + P_g$ 和 $2P_g$ 的 Pearson χ^2 散度。

1.3 行动者-评论家算法

强化学习 (reinforcement learning, RL) 是一种从状态到动作映射的学习策略。RL 利用“尝试与失败”机制, 使智能体在与环境的交互中学习, 采用评价性的反馈信号实现决策的优化。RL 可用于解决智能体如何学习近似最优行为策略的问题。因此, RL 已在控制工程、信号处理和图像处理等领域取得了显著的成果。强化学习的过程是一个试探与评价的过程。当环境状态为 s_t 时, 智能体根据策略 π 执行一个动作 a_t , 获得一个奖励 r_t , 并将该奖励反馈给智能体。环境从而转移成一个新的状态 s_{t+1} 。为了最大化长期的累积奖励, 智能体选择一系列的后续动作。智能体从 t 时刻到 T 时刻的累积折扣奖励定义如下:

$$R_t = \sum_{t'=t}^T \gamma^{t'-t} r_{t'} \quad (10)$$

式中 $\gamma \in (0, 1]$ 为折扣因子, t' 为时间变量。动作值函数是指智能体在当前状态 s_t 下执行动作 a_t 所获得的期望回报, 其计算公式为

$$Q^\pi(s, a) = E[R_t | s_t = s, a_t = a] \quad (11)$$

强化学习算法可以分为基于值函数的学习算法和基于策略函数的学习算法。行动者-评论家 (actor-critic, AC) 算法将这两种算法相结合^[20]。行动者基于策略选择函数, 根据状态选择策略; 评论家对行动者当前的策略进行评价, 并指导行动者进行策略的改进。AC 算法的结构如图 3 所示。智能体在当前状态下根据策略 π 执行一个动作, 使环境迁移到下一个状态; 智能体采用时间差分 (temporal difference, TD) 误差来评价当前状态所采取动作的优劣性。TD 误差的计算公式为

$$\delta_t = \sum_{i=0}^{n-1} \gamma^i r_{t+i} + \gamma^n Q(s_{t+n}) - Q(s_t) \quad (12)$$

式中 r_{t+i} 为智能体在状态 s_{t+i} 根据策略 π 执行动作 a_{t+i} 所获得的立即奖励。 $Q(s_t)$ 为在状态 s_t 的期望回报。若 TD 误差大于零, 则智能体在后续状态中应积极执行动作 a_t ; 若 TD 误差小于零, 则智能体在后续状态中应降低执行动作 a_t 的概率。




图3 AC算法的结构框架

Fig. 3 AC algorithm framework

AC 算法将行动者和评论家独立出来, 对值函数和策略函数进行同步训练, 从而减少训练时间, 加快收敛速度。因此, AC 算法可用于训练深度神经网络, 其值函数梯度和策略函数梯度的计算公式分别为

$$d\theta^v = \partial [R - Q(s_t, \theta^v)]^2 / \partial \theta^v \quad (13)$$

$$d\theta^\pi = \nabla_{\theta^\pi} \log \pi(a_t | s_t, \theta^\pi) A(s_t, a_t, \theta^\pi, \theta^v) \quad (14)$$

式中 $A(s_t, a_t, \theta^\pi, \theta^v)$ 为优势函数, 其计算公式为

$$A(s_t, a_t, \theta^\pi, \theta^v) = \sum_{i=0}^{n-1} \gamma^i r_{t+i} + \gamma^n Q(s_{t+n}, \theta^v) - Q(s_t, \theta^v) \quad (15)$$

值函数参数 θ^v 和策略函数参数 θ^π 的更新公式分别为

$$d\theta_{t+1}^v = \partial [R - Q(s_t, \theta_t^v)]^2 / \partial \theta_t^v \quad (16)$$

$$d\theta_{i+1}^{\pi} = \nabla_{\theta_i^{\pi}} \log \pi(a_i | s_i, \theta_i^{\pi}) [(R - Q(s_i, \theta_i^v))] \quad (17)$$

式中 R 为状态 s_i 下智能体执行动作 a_i 的期望回报。

2 滚动轴承剩余寿命预测方法

2.1 信息最小二乘生成对抗网络

原始 GAN 采用一种简单连续的随机噪声,并未对随机噪声做任何限制。因此,生成器 G 产生的生成样本具有高度耦合的特点。这会导致随机噪声的每一维度与数据的语义特征不匹配。为解决该问题,Chen 等^[21]将 GAN 与信息论相结合,提出了信息生成对抗网络(information maximizing generative adversarial network, InfoGAN)。InfoGAN 将随机噪声分成不可压缩的噪声 z' 和隐变量编码 c 。隐变量编码 c 代表数据分布的结构化语义特征。如果隐变量编码 c 与生成样本 $G(z', c)$ 有更多的共同信息,那么两者的相关性更高,即互信息 $I[c, G(z', c)]$ 更高。因此,InfoGAN 的目标函数改为

$$\min_G \max_D V_{\text{InfoGAN}}(D, G) = V(D, G) - \lambda I[c, G(z', c)] \quad (18)$$

式中 λ 为超参数。由于后验概率分布 $P(c|x)$ 难于获得,互信息 $I[c, G(z', c)]$ 难以最大化。于是 InfoGAN 通过辅助分布 $Q(c|x)$ 近似后验概率分布 $P(c|x)$ 。通过变分下界 $L_I(G, Q)$ 估计互信息 $I[c, G(z', c)]$ 。所以,InfoGAN 的目标函数可由式(19)获得

$$\min_{G, Q} \max_D V_{\text{InfoGAN}}(D, G, Q) = V(D, G) - \lambda L_I(G, Q) \quad (19)$$

凭借堆叠结构,SDAE 能自动地从噪声数据中提取鲁棒特征。InfoGAN 引入隐变量编码与生成样本之间的互信息约束,提取有价值的可解释特征。LSGAN 采用最小二乘损失函数代替交叉熵损失函数,解决梯度消失问题。如果将 SDAE、InfoGAN 和 LSGAN 这三者相结合,构建一种深度学习模型,那么该模型将同时具备它们的优点。因此,本文开发一种信息最小二乘生成对抗网络(information least squares generative adversarial network, InfoLSGAN),其模型结构如图 4 所示。它由生成器 G 、判别器 D 和 softmax 分类器组成。真实数据 x 为输入样本。不可压缩的噪声 z' 和隐变量编码 c 为生成器 G 的输入。生成器 G 由一个 SDAE 构成。生成样本




图 4 InfoLSGAN 的模型结构

Fig. 4 Structure of InfoLSGAN model

$G(z', c)$ 应服从真实数据 x 的分布 $P_{\text{data}}(x)$ 。判别器 D 判断输入样本是真实数据 x 还是生成样本 $G(z', c)$ 。判别器 D 由一个 SDAE 构成。softmax 分类器是一种基于概率的多类回归模型。它使用交叉熵构造损失函数,从而便于参数集的更新迭代。所以,将 softmax 分类器的输出看作预测结果。该结果用于计算奖励 r ,并反馈给生成器 G 。InfoLSGAN 的目标函数定义为

$$\min_D V_{\text{InfoLSGAN}}(D, G, Q) = V_{\text{LSGAN}}(D) - \lambda L_I(G, Q) \quad (20)$$

$$\min_G V_{\text{InfoLSGAN}}(D, G, Q) = V_{\text{LSGAN}}(G) - \lambda L_I(G, Q) \quad (21)$$

2.2 基于 AC 的训练算法

AC 算法将行动者和评论家独立出来,能对值函数和策略函数进行同步训练,策略变化较为平滑,时间复杂度低,求得的策略较为精确,不会因为某一次的更新使得策略有较大幅度的改变。因此,可利用 AC 算法寻找最优动作集。如果将剩余寿命预测问题看作智能体的决策过程,那么该智能体可根据目标导向政策采取行动,减少训练时间,加快收敛速度,以取得最佳长期回报。所以,在 AC 算法的基础上,提出一种基于 AC 的 InfoLSGAN 训练算法,主要步骤概括如下:

Step 1 设置噪声比例、折扣因子 γ ,并初始化状态 s_0 和动作 a_0 ;

Step 2 执行动作 a_0 ,观察环境新状态 s_{i+1} ,根据式(10)计算累积折扣奖励;

Step 3 根据式(20)和式(21),分别训练 InfoLSGAN 的判别器 D 和生成器 G ;

Step 4 根据式(16)和式(17),更新 InfoLSGAN 的值函数参数 θ^v 和策略函数参数 θ^{π} ;

Step 5 对下一时刻重复 Step 2 到 Step 4,直至判别器 D 和生成器 G 达到纳什均衡。

2.3 滚动轴承剩余寿命预测框架

将 SDAE、InfoGAN 和 LSGAN 相结合的

InfoLSGAN 利用 SDAE 自动地从噪声数据中提取鲁棒特征;采用 InfoGAN 提取有价值的可解释特征;采用 LSGAN 中的最小二乘损失函数代替交叉熵损失函数,解决训练过程中的梯度消失问题。此外,InfoLSGAN 还利用 GAN 的生成对抗机制,生成新样本,从而解决小样本情况下滚动轴承的剩余寿命预测问题。AC 算法将行动者和评论家独立出来,对值函数和策略函数进行同步训练,策略变化较为平滑,时间复杂度低。这很自然地让人联想到,可将滚动轴承的剩余寿命预测问题看作智能体的决策过程,根据目标导向政策采取行动,以取得最佳长期回报。因此,提出一种基于 InfoLSGAN 和 AC 算法的滚动轴承剩余寿命预测方法,方法框架如图 5 所示。构建 InfoLSGAN,自动地从噪声数据中提取可解释的鲁棒特征,解决梯度消失问题;采用基于 AC 的训练算法训练 InfoLSGAN,减少训练时间,加快收敛速度;根据训练后的 InfoLSGAN,利用 softmax 分类器预测测试样本中滚动轴承的剩余寿命。




图 5 滚动轴承剩余寿命预测框架

Fig. 5 RUL prediction framework of rolling bearings

3 试验与分析

3.1 试验说明

为了验证所提方法的有效性,进行了滚动轴承的加速疲劳寿命试验,图 6 为滚动轴承加速疲劳寿命试验台。它主要由驱动电动机、两个对称放置的行星齿轮箱与磁粉制动器组成。行星齿轮箱高速轴滚动轴承为 6206-2RS 深沟球轴承。试验中通过磁粉制动器产生 3 种负载,驱动电动机的输出 3 种转速。滚动轴承的 3 种运行状态如表 1 所示。利用加速度传感器采集行星齿轮箱高速轴滚动轴承全寿命周期振动信号,采样间隔为 10 s,采样频率为 25.6 kHz,采样时间为 0.4 s,每次采样的样本点数为 10 240。当振动加速度信号

幅值超过 20g 时,停止试验。每种滚动轴承运行状态采集 6 个样本,3 种运行状态下可获得 18 个样本。它们分别命名为滚动轴承 1_1-滚动轴承 1_6,滚动轴承 2_1-滚动轴承 2_6,以及滚动轴承 3_1-滚动轴承 3_6。本试验将每种运行状态中的前 2 个样本用作训练样本,剩下的 4 个样本看作测试样本。图 7 为滚动轴承 1_1 的全寿命周期振动信号,图中 a 为加速度幅值。




图 6 滚动轴承加速疲劳寿命试验台

Fig. 6 Accelerated fatigue life experiment rig of rolling bearings

表 1 滚动轴承的 3 种运行状态

Table 1 Three operating conditions of rolling bearings

运行状态	磁粉制动器产生的负载/(N·m)	驱动电动机的输出转速/(r/m)
1	5	1 200
2	10	800
3	20	400




图 7 滚动轴承 1_1 的全寿命周期振动信号

Fig. 7 Full life cycle vibration signal of rolling bearing1_1

在轴承性能衰退评估中,选择一个恰当的评价指标非常关键。时频域特征方均根(root mean square,RMS,量符号记为 S_{rms})值随轴承故障的发展呈现出良好的上升趋势,能真实地反映轴承运行过程中的状态变化。所以,将 RMS 值看作滚动轴承的性能衰退评估指标,其计算公式为

$$x_{\text{rms}} = \sqrt{\frac{1}{M} \sum_{k=1}^M [x(k)]^2}$$

(22)

式中 $x(k)$ 为信号序列, $k=1,2,\cdots,M$ 为序列点数。RMS 对个体差异较敏感,需对其进行标准化和滑移平均处理,获得相对方均根(Relative root mean square,RRMS,量符号记为 S_{rm})值。滚动轴承 1_1 的 RRMS 值随时间变化曲线如图 8 所示。设退化阈值和失效阈值分别为 1.05 和 3.2。正常阶段滚动轴承的 RRMS 没有明显波动。所以,仅开展退化阶段滚动轴承的剩余寿命预测。




图 8 滚动轴承 1_1 的 RRMS 值随时间变化曲线
Fig.8 RRMS curve of rolling bearing1_1 varying with time

3.2 预测结果

使用的程序开发框架为 Tensorflow1.1.0, 编程语言为 Python 3.5。计算机配置为 8 核 i7-6700 处理器,16 GB 内存。构建用于滚动轴承剩余寿命预测的 InfoLSGAN。它由生成器 G 、判别器 D 和 softmax 分类器组成。生成器 G 和判别器 D 均由具有 2 个隐层的 SDAE 构成。SDAE 的隐层神经元数目设为 100。输入为 62×62 矩阵。通过基于 AC 的训练算法,采用训练样本训练 InfoLSGAN。噪声比例设为 0.3,折扣因子 γ 设为 0.9,并初始化状态 s_0 和动作 a_0 。根据训练后的 InfoLSGAN,利用 softmax 分类器预测测试样本中滚动轴承的剩余寿命。滚动轴承的剩余寿命预测准确率用于评估本文提出方法的效果,其计算公式为

$$A_p = 1 - e_{RMSE} = 1 - \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2}$$

(23)

式中 e_{RMSE} 为方均根误差, y_i 和 $\hat{y}_i$ 分别为第 i 个检查点剩余寿命的真实值和预测值, N 为检查点个数。预测准确率如表 2 所示。从表 2 可以看出,负载越大,转速越低,预测效果越好。这是由于负载越大,脉冲响应的幅值越高,故障特征越明显。转速越低,冲击脉冲响应的衰减时间与冲击间隔

相差越大,从而避免了混叠现象的发生。并且,在小样本情况下每种运行状态的测试样本准确率均超过 92%。因此,该方法能在小样本情况下准确地预测滚动轴承的剩余寿命。

表 2 滚动轴承剩余寿命预测准确率
Table 2 RUL prediction accuracy of rolling bearings

参数	运行状态		
	1	2	3
训练与测试样本数之比	1 : 2	1 : 2	1 : 2
训练样本准确率/%	100	100	100
测试样本准确率/%	92.31	93.83	95.12
平均准确率/%	94.87	95.89	96.75

3.3 比较分析

为了研究神经元数目对测试样本准确率的影响,调整第一个 SDAE 隐层神经元数目,且第二个 SDAE 隐层神经元数目为第一层的一半。第一个 SDAE 隐层神经元不同数目下的预测结果如图 9 所示。从图 9 中可以看出,训练样本准确率可达 100%,测试样本准确率超过 92%。但随着神经元数目的增加,训练时间逐渐延长,而训练时间未出现剧烈增长。这是由于 InfoLSGAN 的计算复杂度逐渐增加,延长了训练时间。而 InfoLSGAN 采用最小二乘损失函数,解决梯度消失问题,使训练过程更加稳定。当神经元数目超过 200 时,测试样本准确率基本不变,而训练时间有所增加。综合考虑测试样本准确率和训练时间后,将第一个 GRU(gated recurrent unit)层神经元数目设定为 200,第二个 GRU 层神经元数目设定为 100。

为研究信噪比(signal-to-noise ratio,SNR,量符




图 9 第一个 SDAE 隐层神经元不同数目下的预测结果
Fig.9 Prediction results with different neuron numbers of the first hidden layer in SDAE

号记为 R_{sn})对预测效果的影响,将该方法与 BPNN (back propagation neural network)、SVM(support vector machine)、SDAE、InfoGAN 和 LSGAN 进行对比。采用 MATLAB 2016a 中的工具箱,实现基于 BPNN 或 SVM 的滚动轴承的剩余寿命。BPNN 包含 2 个隐层,隐层单元数设为 200,通过最小化预定误差目标值的方式,采用 Levenberg-Marquardt 优化算法训练 BPNN。将径向基数核看作 SVM 的核函数,并采用 cross-validation 算法优化核函数参数和惩罚因子。采用 EEMD(ensemble empirical mode decomposition)方法提取样本中的时域特征和频域特征^[22],可提取 24 个特征用作 BPNN 和 SVM 的输入。SDAE、InfoGAN 和 LSGAN 的结构和训练过程如前所述。不同 SNR 下 6 种方法的剩余寿命预测结果如图 10 所示,图中 S 表示原始信号。从图 10 中可以看出,对原始信号而言,6 种方法的测试样本准确率接近 100%。然而,随着 SNR 的减小,测试样本准确率急剧降低。当 SNR 等于 0 时,BPNN、SVM 和 SDAE 的测试样本准确率均低于 75%,而该方法的测试样本准确率超过 85%。这是由于该方法利用 SDAE 的堆叠结构和 GAN 的生成对抗机制,自动地从小样本的噪声数据中提取鲁棒特征。与 LSGAN 和 InfoGAN 相比,该方法仍然获得较高的测试样本准确率。主要原因在于 InfoLSGAN 将 LSGAN 与 InfoGAN 相结合,不但能解决梯度消失问题,还能提取可解释的特征。因此,该方法无需任何降噪处理,能自动地从噪声数据中提取可解释的鲁棒特征,具有较强的噪声适应能力。




图 10 不同 SNR 下 6 种方法的剩余寿命预测结果
Fig. 10 RUL prediction results of six methods under different SNRs

为研究该方法的收敛性,分别采用 Adam 优化算法、Q 学习 (Q-learning, QL) 算法、策略梯度 (policy gradient, PG) 算法和基于 AC 的训练算法训练 InfoLSGAN。在 Adam 优化算法中,学习率 α 设为 0.001,两个矩估计指数衰减率 β_1 和 β_2 分别设为 0.9 和 0.99,数值稳定常数 ϵ 设为

10^{-8} 。InfoLSGAN 的模型结构和基于 AC 的训练算法的参数设置如前所述。Q 学习算法和策略梯度算法的参数设置与基于 AC 的训练算法的相似。测试样本准确率与迭代次数之间的关系曲线如图 11 所示。从图 11 可以看出,当迭代次数超过 1800 时,基于 AC 的训练算法的测试样本准确率趋于稳定。与其他算法相比,该算法的测试样本准确率最先达到稳定状态。主要原因在于该算法将行动者和评论家独立出来,能对值函数和策略函数进行同步训练,策略变化较为平滑,时间复杂度低。所以,该算法能明显地减少训练时间,加快收敛速度。




图 11 测试样本准确率与迭代次数之间的关系曲线
Fig. 11 Relation curves between the accuracy of test samples and iteration number

为了进一步验证该方法对滚动轴承剩余寿命预测的效果,将开发的 InfoLSGAN 与 SDAE、LSGAN 和 InfoGAN 相对比。均采用基于 AC 的训练算法训练这 4 种深度学习模型。训练与测试样本数之比分别为 1:5、1:2、1:1 和 2:1,4 种深度学习模型的剩余寿命预测结果如图 12 所示。随着训练与测试样本数之比的提高,测试样本准确率逐渐提高。原因在于训练样本越多,模型训练得越充分。在各种比例下,InfoLSGAN 均取得最高的测试样本准确率。这是由于 InfoLS-




图 12 4 种深度学习模型的剩余寿命预测结果
Fig. 12 RUL prediction results of four deep learning models

GAN 将 SDAE、InfoGAN 和 LSGAN 这三者相结合,自动地从噪声数据中提取可解释的鲁棒特征,并解决梯度消失问题。所以,InfoLSGAN 能取得最高的测试样本准确率。

为了进一步验证所提方法的优越性,分别采用朴素贝叶斯(naive Bayesian,NB)分类器、多元线性回归(multiple linear regression,MLR)分类器、softmax 分类器作为 InfoLSGAN 的输出层,均采用基于 AC 的训练算法训练 InfoLSGAN。训练与测试样本数之比分别为 1 : 5、1 : 2 和 1 : 1,3 种分类器下 InfoLSGAN 的剩余寿命预测结果如图 13 所示。在 3 种比例下,采用 softmax 分类器作为输出层的 InfoLSGAN 获得最高的测试样本准确率。原因在于 softmax 分类器采用交叉熵构造损失函数,便于参数集的更新迭代。它不但能给出轴承所处状态的概率大小,还能反映各状态间的互斥关系。




图 13 3 种分类器下 InfoLSGAN 的剩余寿命预测结果
Fig. 13 RUL prediction results of InfoLSGAN under three classifiers

4 结 论

- 1) 本文开发的 InfoLSGAN 利用堆叠结构和互信息约束,自动地从噪声数据中提取可解释的鲁棒特征;采用最小二乘损失函数,解决梯度消失问题。因此,该模型在小样本和噪声干扰下取得出色的剩余寿命预测效果。
- 2) 提出的基于 AC 的 InfoLSGAN 训练算法将行动者和评论家独立出来,对值函数和策略函数进行同步训练,策略变化较为平滑,时间复杂度低。所以,该算法能明显地减少训练时间,加快收敛速度。

参考文献:

[1] ZHOU Linghao,DUAN Fang,CORSAR M,et al. A study

on helicopter main gearbox planetary bearing fault diagnosis[J]. Applied Acoustics,2019,147:4-14.

[2] KUNDU P,DARPE A K,KULKARNI M S. Weibull accelerated failure time regression model for remaining useful life prediction of bearing working under multiple operating conditions[J]. Mechanical Systems and Signal Processing,2019,134:106302. 1-106302. 19.

[3] 田晶,李有儒,艾延廷. 一种基于 Deep-GBM 的航空发动机中介轴承故障诊断方法[J]. 航空动力学报,2019,34(4): 756-763.

TIAN Jing,LI Youru,AI Yanting. Fault diagnosis of aero-engine inter-shaft based on Deep-GBM[J]. Journal of Aerospace Power,2019,34(4):756-763. (in Chinese)

[4] LEI Yaguo,LI Naipeng,GUO Liang,et al. Machinery health prognostics:a systematic review from data acquisition to RUL prediction[J]. Mechanical Systems and Signal Processing,2018,104:799-834.

[5] 张杰毅,陈果,谢阶栋,等. 球轴承接触疲劳寿命预估的损伤力学-有限元法[J]. 航空动力学报,2019,34(10):2246-2255.

ZHANG Jieyi,CHEN Guo,XIE Jiedong,et al. Damage mechanics-finite element method for contact fatigue life prediction of ball bearing[J]. Journal of Aerospace Power, 2019,34(10):2246-2255. (in Chinese)

[6] AHMAD W,KHAN S A,KIM J M. A hybrid prognostics technique for rolling element bearings using adaptive predictive models[J]. IEEE Transactions on Industrial Electronics,2018,65(2):1577-1584.

[7] LIU Xiongjun,SONG Ping,YANG Cheng,et al. Prognostics and health management of bearings based on logarithmic linear recursive least-squares and recursive maximum likelihood estimation[J]. IEEE Transactions on Industrial Electronics,2018,65(2):1549-1558.

[8] HU Yaogang,LI Hui,SHI Pingping,et al. A prediction method for the real-time remaining useful life of wind turbine bearings based on the Wiener process[J]. Renewable Energy,2018,127:452-460.

[9] BOUMAHDJ M,RECHAK S,HANINI S. Analysis and prediction of defect size and remaining useful life of thrust ball bearings:modelling and experiment procedures [J]. Arabian Journal for Science and Engineering,2017,42(11):4535-4546.

[10] ELFORJANI M,SHANBR S. Prognosis of bearing acoustic emission signals using supervised machine learning[J]. IEEE Transactions on Industrial Electronics,2018,65(7): 5864-5871.

[11] AHMAD W,KHAN S A,KIM J M. Enhanced particle filtering for bearing remaining useful life prediction of wind turbine drivetrain gearboxes[J]. IEEE Transactions on Industrial Electronics,2019,66(6):4738-4748.

[12] SAIDI L,ALI J B,BECHHOFFER E,et al. Wind turbine high-speed shaft bearings health prognosis through a spectral Kurtosis-derived indices and SVR[J]. Applied Acoustics,2017,120:1-8.

[13] AYE S A,HEYNS P S. An integrated Gaussian process

regression for prediction of remaining useful life of slow speed bearings based on acoustic emission[J]. Mechanical Systems and Signal Processing, 2017, 84: 485-498.

[14] ZHU Jun, CHEN Nan, PENG Weiwen. Estimation of bearing remaining useful life based on multiscale convolutional neural network[J]. IEEE Transactions on Industrial Electronics, 2019, 66(4): 3208-3216.

[15] REN Lei, SUN Yaqiang, CUI Jin, et al. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks[J]. Journal of Manufacturing Systems, 2018, 48: 71-77.

[16] XIA Min, LI Teng, SHU Tongxin, et al. A two-stage approach for the remaining useful life prediction of bearings using deep neural networks[J]. IEEE Transactions Informatics, 2019, 15(6): 3703-3711.

[17] LI Xingqiu, JIANG Hongkai, XIONG Xiong, et al. Rolling bearing health prognosis using a modified health index based hierarchical gated recurrent unit network[J]. Mechanism and Machine Theory, 2019, 133: 229-249.

[18] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11: 3371-3408.

[19] MAO Xudong, LI Qing, XIE Haoran, et al. Least squares generative adversarial networks[C] // Proceedings of the 16th IEEE International Conference on Computer Vision. Venice, Italy: IEEE Computer Society, 2017: 2813-2821.

[20] KONDA V R, TSITSIKLIS J N, Actor-critic algorithms [C] // Proceedings of the 13th Annual Neural Information Processing Systems. Denver, USA: Neural Information Processing Systems Foundation, 2000: 1008-1014.

[21] CHEN Xi, DUAN Yan, HOUTHOOFT R, et al. InfoGAN: interpretable representation learning by information maximizing generative adversarial nets[C] // Proceedings of the 30th Annual Conference on Neural Information Processing Systems. Barcelona, Spain: Neural Information Processing Systems Foundation, 2016: 2172-2180.

[22] 田晶, 王英杰, 刘丽丽, 等. 基于 Birge-Massart 阈值降噪与 EEMD 谱峭度的滚动轴承故障特征提取[J]. 航空动力学报, 2019, 34(6): 1339-1408.

TIAN Jing, WANG Yingjie, LIU Lili, et al. Fault feature extraction of rolling bearing using Birge-Massart threshold denoising with EEMD and spectral kurtosis[J]. Journal of Aerospace Power, 2019, 34(6): 1339-1408. (in Chinese)

(编辑: 叶 青、王碧琚)