

DOI: 10.13382/j.jemi.B2206091

基于改进生成对抗网络与 ConvLSTM 的 航空发动机剩余寿命预测方法*

陈维兴 常东润 李宗帅

(中国民航大学电子信息与自动化学院 天津 300300)

摘要:针对航空发动机运行周期内故障数据难以采集而造成的数据失衡等问题,提出一种基于 Wasserstein 距离与梯度惩罚措施的条件生成对抗网络与卷积长短时记忆网络相结合的预测模型。首先,使用 WCGAN-GP 模型学习预处理后的时序数据的深层分布特征;然后,利用生成器生成故障样本并与真实样本混合,作为训练集输入到基于 ConvLSTM 网络的预测模型中进行训练。基于 C-MAPSS 数据集开展验证比较,结果表明:与单一真实样本训练预测模型相比,使用混合数据时性能指标 RMSE 和 Score 平均下降了 12.65% 和 48.95%。

关键词:航空发动机; Wasserstein 距离; 梯度惩罚项; 条件式生成对抗网络; 剩余寿命预测

中图分类号: TN0; TP183 **文献标识码:** A **国家标准学科分类代码:** 510.40

Aeroengine residual life prediction method based on improved generative adversarial network and ConvLSTM

Chen Weixing Chang Dongrun Li Zongshuai

(College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

Abstract: A prediction model based on Wasserstein conditional generative adversarial network-gradient penalty (WCGAN-GP) and convolution long and short-term memory network (ConvLSTM) is proposed to address the problem of unbalanced data caused by the difficulty of collecting fault data during the operating cycle of an aero-engine. First, a WCGAN-GP model is used to learn the deep distribution characteristics of the pre-processed time-series data; then, a generator is used to generate fault samples and mix them with real samples as a training set to input into the prediction model based on the ConvLSTM network for training. Through testing with C-MAPSS data set, the results show that compared with the single real sample training prediction model, the performance indexes RMSE and score of the model using mixed data are reduced by 12.65% and 48.95% on average.

Keywords: aeroengine; Wasserstein distance; gradient penalty; conditional generation of countermeasure network; remaining life prediction

0 引 言

剩余使用寿命 (remaining useful life, RUL) 预测作为故障预测和健康管理^[1] (prognostics and health management, PHM) 技术的重要部分近年来备受专家学者们关注。由于航空发动机在相对高强度、复杂工作环境下长期运行很容易发生不可避免故障,实现航空发动机准确 RUL 预测^[2],将对企业制定科学的维护计划、

减少无效定检具有极其重要的意义。

基于数据驱动的 RUL 预测方法与其他传统方法相比^[3],不再需要大量的先验知识以及繁杂的计算过程来完成建模,而且还可以解决退化模型的机理未知问题,仅需发动机系统的性能退化数据,即可获得较好结果。

深度学习方法由于其良好的自主特征提取能力及突出的复杂过程泛化能力,近年来被引入到数据驱动方法中来描述复杂非线性系统的退化趋势^[4]。长短时记忆网络 (long short term memory, LSTM) 作为 RNN 的变体与其

收稿日期: 2022-12-07 Received Date: 2022-12-07

* 基金项目: 国家自然科学基金委员会-中国民航联合研究基金(U1933107)、天津市教委自然科学基金(2018KJ237)、中央高校基本科研业务费民航大学专项(3122020025)项目资助

他网络结构^[5-8]相比,既解决了 RNN 在训练过程中梯度爆炸或梯度消失问题,又保留了其循环结构可以学习数据时间维度上的相关性,非常适合处理时间序列数据。Mei 等^[9]提出了基于 LSTM 网络的航空发动机 RUL 预测方法,首次将 LSTM 网络用于发动机 RUL 预测领域。刘文彪等^[10]提出使用 CNN 与 LSTM 融合模型,有效提高了轴承剩余寿命预测精度。但是由于 CNN 与 LSTM 的模型难以对时序数据时间与传感器维度特征进行融合,众多学者在其基础上进行研究改进,于是 Shi 等^[11]提出了一种新的 LSTM 变体网络—卷积长短时记忆网络 (ConvLSTM)。与 LSTM 相比,ConvLSTM 具有更少的网络参数,并且可以借助卷积操作来提高模型的非线性建模能力。

基于深度学习的 RUL 预测方法,数据集的选择和处理是决定其性能优劣的关键因素。航空发动机作为一种极为昂贵且精密的设备,其实际运行过程中故障率相对较低且故障状态很短暂。因此能够获得的故障样本与正常样本比例相差极大,同时也不能获得比例相对均衡的不同故障模式的故障样本。这样就存在严重的样本失衡问题,极大地限制了深度学习预测模型精度的提高。然而大多数现有研究忽略了数据集中故障样本极度缺少的情况,可能造成模型难以提取发动机故障特征的状况,从而导致模型预测精度过低。

为了解决数据集样本失衡问题,Goodfellow 等^[12]首次提出使用生成生成对抗网络 (generative adversarial nets, GAN) 学习训练数据的分布,并生成与之分布相似的合成数据。由于 GAN 缺乏相应的评估标准,所以在训练过程中可能会发生模型坍塌、梯度消失等问题,Cui 等^[13]引入了 Wasserstein 距离解决了原生 GAN 中 JS 散度因噪声数据和真实数据重合过少而模型难以训练的问题。薛振泽等^[14]使用 WGAN 网络解决轴承故障失衡问题极大地提高了轴承故障诊断精度。但是 GAN 在生成高维数据时,只能随机生成,无法生成指定的设备故障样本数据。条件式生成对抗网络 (conditional generative adversarial nets, CGAN) 将类别标签作为约束条件伴随随机噪声输入至生成模型,以生成所需要的指定数据。Sourajit 等^[15]较早将 CGAN 网络用于复杂设备预测领域解决数据集失衡问题以增强模型整体预测性能,并使用 C-MAPSS 数据集对所提方法有效性进行验证。然而 CGAN 仍然面临与 GAN 同样的问题,所以贺佳星等^[16]使用 WCGAN 网络解决数据集类不平衡问题,有效提高入侵检测效率。CWGAN 为保证判别器的 Lipschitz 性质,使用权重剪裁的方法将判别器的参数硬性限制在截断值内,导致判别器对生成数据的变化不再敏感而造成模型坍塌。Gulrajani 等^[17]提出 WGAN-GP 使用一个额外梯度惩罚项 (gradient penalty, GP) 代替权重剪裁法来满足

Lipschitz 条件。

综上所述,为了实现对航空发动机 RUL 的精准预测,本文提出一种基于 Wasserstein 距离与梯度惩罚措施的条件生成对抗网络 (Wasserstein conditional generative adversarial network-gradient penalty, WCGAN-GP) 和 ConvLSTM 神经网络的预测模型,用于航空发动机剩余寿命预测。将 Wasserstein 距离和 GP 项引入至 CGAN 中,在避免模型坍塌的前提下学习发动机在不同操作条件和故障模式下的多传感器故障数据的底层分布以生成指定的发动机故障数据。然后,使用生成器生成故障数据,与数据集样本按比例混合后作为训练集输入至基于 ConvLSTM 的预测模型中,提取时序退化特征,映射状态数据与 RUL 之间的非线性关系。最后,使用测试集对预测模型进行性能评估并于最近研究成果比较发现,本文所提方法可以明显提高发动机 RUL 预测的准确性与稳定性。

1 理论方法

1.1 CGAN

CGAN 是有条件约束的 GAN 模型,通过给定约束条件使 GAN 生成需要的数据。与原生 GAN 类似,CGAN 由两个模型组成:生成模型 (G) 和判别模型 (D)。 G 用来学习目标数据的实际分布规律并生成与之尽可能相似的数据 $G(z|y)$ 。 D 负责将生成数据与真实数据进行区分。宏观上来说, D 关注全局特征, G 关注数据局部细节,两者通过对抗机制,相互“成就”。CGAN 架构如图 1 所示。

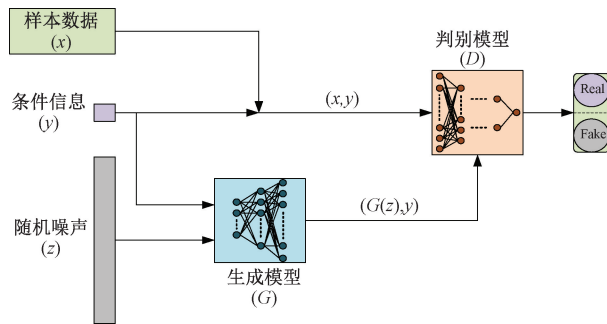


图 1 CGAN 架构

Fig. 1 CGAN architecture

首先,高斯随机噪声 z 和条件信息 y 一起输入至 G 中,输出生成数据 $G(z)$ 并输入到 D 使其相信 $G(z)$ 是真实数据。除此之外,样本数据 x 和条件信息 y 也输入至 D 中。然后 D 将生成数据与真实数据区分开。这种不断博弈过程可以显著提高 G 生成真实数据的能力和 D 辨别真假数据的能力。CGAN 最终的损失函数为:

$$\min_G \max_D L(G, D) = E_{x \sim P_r(\cdot)} [\log D(x, y)] + E_{z \sim P_g(\cdot)} [\log(1 - D(G(z, y)))] \quad (1)$$

式中: $P_r(\cdot)$ 表示真实样本数据分布, $P_g(\cdot)$ 表示生成网络分布; $D(\cdot)$ 、 $G(\cdot)$ 分别表示判别模型与生成模型对应的非线性函数。

1.2 Wasserstein 距离及 GP

当真实数据分布与生成数据分布不重叠时, JS 散度无法衡量分布之间的距离, 导致 GAN 训练不稳定的情况。因此, GAN 中引入了 Wasserstein 距离, 也叫做推土机距离 (earth-mover distance, EM 距离), 它表示从一个分布 p 到另一个分布 q 的最小代价, 公式为:

$$W(p, q) = \inf_{\rho \sim \prod(p, q)} E_{(x, y) \sim \rho} [\|x - y\|] \quad (2)$$

式中: $\inf\{\cdot\}$ 表示集合的下限集, $\prod(p, q)$ 表示分布 p 、 q 所有可能组合的联合分布集合。对每个可能的联合分布 $\rho \sim \prod(p, q)$, 计算采样自 ρ 的 (x, y) 之间距离 $\|x - y\|$ 的期望 E 。所有不同联合分布 ρ 中期望的最小值即为分布 p 、 q 的 Wasserstein 距离。

Lipschitz 条件要求判别器函数 $D(\cdot)$ 的梯度有界, 此处使用 GP 来满足此条件限制, 公式如下:

$$GP = (\|K - \nabla D(x)\|_2)^2 \quad (3)$$

式中: $\nabla_x D(x)$ 表示 $D(x)$ 对 x 求导; $\|\cdot\|_2$ 表示求 L2 范数; K 为常数表示 $D(\cdot)$ 的梯度界限, 通常设为 $1^{[17]}$; 当 $\nabla D(x) \neq 1$ 时, 进行惩罚, 且其与 1 距离越远, 则惩罚越重, 即梯度尽量为 1。

1.3 ConvLSTM 神经网络

与 LSTM 相比, ConvLSTM 不仅继承了卷积算法中稀疏连通性和参数共享的优点, 同时还保留了 LSTM 捕获数据长期依赖关系的优点。ConvLSTM 结构图如图 2 所示, 其公式如下所示:

$$\begin{aligned} g_f &= \sigma(W_f^* [h_{t-1}, x_t] + b_f) \\ g_i &= \sigma(W_i^* [h_{t-1}, x_t] + b_i) \\ g_o &= \sigma(W_o^* [h_{t-1}, x_t] + b_o) \\ \hat{c}_t &= \tan(W_c^* [h_{t-1}, x_t] + b_c) \\ c_t &= g_i \odot \hat{c}_t + g_f \odot c_{t-1} \\ h_t &= g_o \odot \text{tanc}_t \end{aligned} \quad (4)$$

式中: $*$ 表示卷积运算; g_f 、 g_i 和 g_o 分别为 ConvLSTM 中 3 个门控机制; (W_f, b_f) 、 (W_i, b_i) 、 (W_o, b_o) 代表对应门控机制卷积运算中的卷积核和偏差; σ 为 Sigmoid 激活函数; \tanh 为激活函数; x_t 表示 t 时间点的输入数据; c_t 、 h_{t-1} 、 h_t 分别表示当前时间点的内存向量、前一个时间点和当前时间点 ConvLSTM 单元的状态输出向量; \odot 表示矩阵逐元素相乘。




图 2 ConvLSTM 单元示意图

Fig. 2 Schematic diagram of ConvLSTM cell

2 预测模型

本文所提 WCGAN-GP-ConvLSTM 预测模型的构建思想是: 首先, 为提高数据质量对发动机传感器状态信息进行预处理操作, 包括数据降维、归一化与滑动窗口处理; 然后, 针对故障信息难以采集造成的数据失衡问题, 使用 WCGAN-GP 学习航空发动机多维数据的底层分布, 将生成数据与真实数据按最优比例混合达到数据平衡和数据扩增的目的; 之后, 为了实现发动机 RUL 预测, 使用 ConvLSTM 网络提取混合数据集中发动机时序退化特征, 通过全连接神经网络 (fully-connected neural network, FNN) 映射出发动机状态信息与 RUL 的非线性关系; 最后, 使用训练后的预测模型对在线数据进行实时预测, 并输出对应 RUL 值。模型整体流程如图 3 所示。

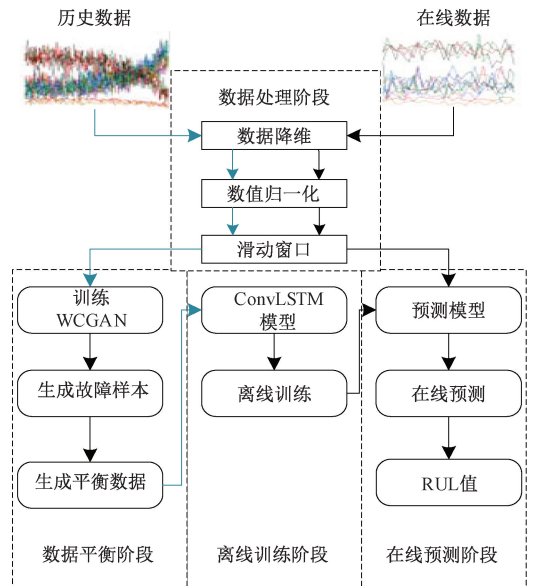


图 3 模型流程图

Fig. 3 Model flow chart

2.1 数据集介绍与处理

本研究主要使用由美国宇航局(NASA)开发的名为商用模块化航空推进系统仿真(commercial modular aeropropulsion system simulation, C-MAPSS)软件生成的数据集来验证模型的有效性。公开的 C-MAPSS 数据集被分为 4 个子数据集。每个子数据集由训练集、测试集和真实 RUL 数据集组成,分别记录了不同故障模式和运行工作条件下的发动机运行退化数据。其中训练集包含所有发动机单元从初始状态运行至失效的传感器监测数据,测试集中只包含各发动机单元全寿命周期前一段的数据。发动机故障包含两种故障模式-高压压气机故障和风扇故障。FD001 和 FD002 数据集中包含高压压气机故障一种故障模式,而 FD003 和 FD004 数据集中包含两种故障模式。飞行高度,马赫数和油门解析器角度为发动机 3 种运行条件参数,其可以被组合为 6 种对发动机运行性能有重大影响的运行条件。有关数据集信息如表 1 所示。

表 1 C-MAPSS 数据详情

Table 1 Details of C-MAPSS data

数据集	FD001	FD002	FD003	FD004
训练集单元	100	260	100	249
测试集单元	100	259	100	249
故障模式	1	1	2	2
运行条件	1	6	1	6

其中训练集包含所有发动机单元从初始状态运行至失效的全寿命运行数据,而测试集中只包含各发动机单元全寿命周期前一段的数据。由于航空发动机通常在复杂工况下工作,因此为了使实验更加具有说服力,选择数据集中运行条件更加复杂的 FD002 和 FD004 进行实验研究。

不是所有的传感器数据均包含有用的发动机退化信息。通过计算监测周期内传感器数值方差,发现部分传感器方差为 0 即其测量值基本不变。因此去除这些方差为 0 的传感器,最后保留 14 个有效传感器数据。传感器信息如表 2 所示,分布情况如图 4 所示。




图 4 发动机中的传感器分布

Fig. 4 Distribution of sensors in the engine

由于训练集并未提供真实 RUL 值,且在实际运行的早期,航空发动性能退化不明显,处于健康运行状态。因此,研究中选择分段线性退化函数来建立运行数据与 RUL 之间的映射关系。将航空发动机全寿命周期分为两个阶段:健康运行和性能退化阶段,如图 5 所示。健康运行阶段由于性能退化不明显到可以忽略不记,因此此阶段 RUL 为恒定值。本研究将早期代表航空发动机 RUL 的恒定值设为 125,即初始 RUL 值为 125 个发动机循环,若 $RUL \geq 125$,将其映射为 125; $RUL < 125$,则不做其他处理。分段线性函数如式(10)所示。

表 2 14 个有效传感器信息

Table 2 Information of 14 active sensors

序号	符号	名称	单位
1	T24	低压压气机温度	°R
2	T30	高压压气机温度	°R
3	T50	低压涡轮温度	°R
4	P30	高压压气机出口总压	psia
5	Nf	物理风扇转速	rpm
6	Nc	核心机物理转速	rpm
7	Ps30	高压压气机出口静压	psia
8	Phi	燃料流量与 Ps30 比值	pps/psi
9	NRF	风扇校正转速	rpm
10	NRc	核心机校正转速	rpm
11	BPR	涵道比	--
12	htBleed	引气涵值	--
13	W31	高压涡轮冷却剂流量	1 bm/s
14	W32	低压涡轮冷却剂流量	1 bm/s

$$RUL = \begin{cases} 125, RUL \geq 125 \\ RUL, 0 \leq RUL < 125 \end{cases} \quad (5)$$




图 5 RUL 退化曲线

Fig. 5 RUL degradation curve

由于传感器测量的物理量不同,导致航空发动机不同传感器数据的单位和数值范围均存在较大差异。数据归一化可以将状态数据缩放到一个很小的区间,将其转化为无量纲数据,有助于提高预测模型收敛速度和预测准确率。选择最大-最小归一化法对数据进行归一化计

算,公式为:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (6)$$

归一化后一个随机发动机单元 14 个传感器监测数据在其全寿命周期中的变化趋势如图 6 所示。




图 6 归一化后实验数据各传感器曲线

Fig. 6 Curve of each sensor after normalization of experimental data

此外,时间序列数据在不同时间维度上的依赖关系也会对模型的特征提取效果产生影响。对此,本文选用滑动时间窗口来捕获数据间在时间维度上的依赖关系,且可以实现数据样本扩充。每个时间窗口样本同属于一个发动机单元,窗口最后一个数据点的 RUL 标签作为当前窗口标签。历史数据与在线数据时间窗口大小及步长保持一致。

2.2 WCGAN-GP 模型

为了解决数据中故障样本缺乏,而导致的发动机故障信息难以提取问题,使用 WCGAN-GP 网络学习数据集各种操作条件和故障模式下的真实样本数据分布。然后通过训练后的生成器将随机噪声映射为符合条件信息的故障样本,并作为补充数据与训练集真实样本混合对神经网络预测模型进行训练。对抗网络具体结构如图 7 所示。

将经过预处理后的发动机剩余寿命值作为条件信息 y 经过 Embedding 操作转化为与相乘向量等长的向量。

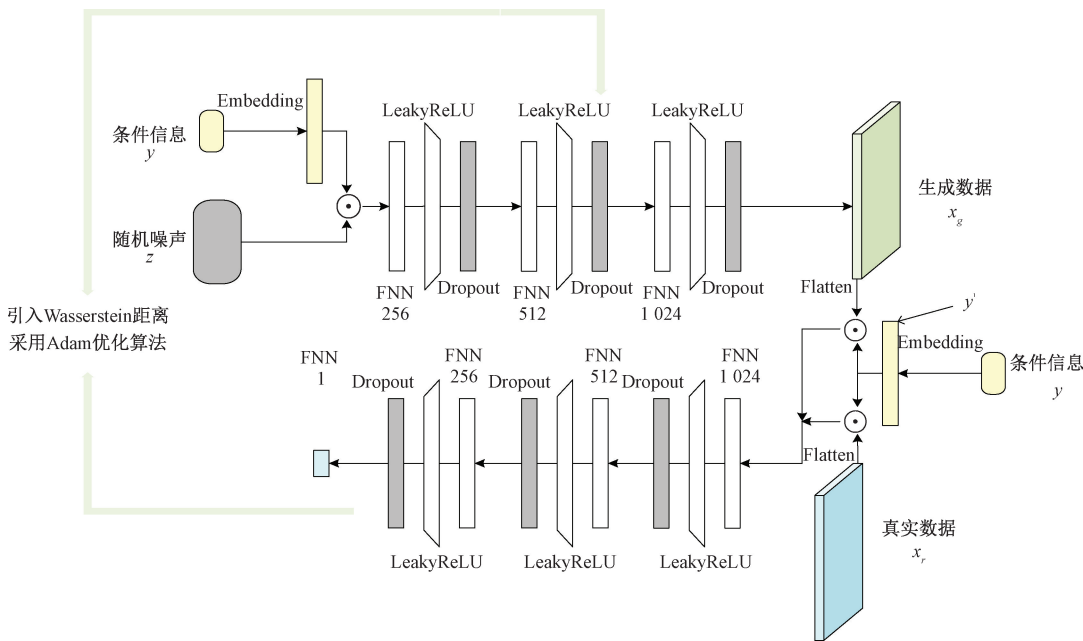


图 7 WCGAN-GP 结构图

Fig. 7 WCGAN-GP structure chart

历史数据经过时间窗操作后,每个窗口样本作为真实数据 x_r 与生成数据 x_g 经过展平层,且两种数据分别与条件信息 y^l 逐元素相乘输入至判别器中。生成器网络主体由 4 层 FNN 组成;

前 3 层 FNN 使用泄露系数为 0.2 的 LeakyReLU 激活函数。与 ReLU 相比,在输入 $x \leq 0$ 时 LeakyReLU 函数会返回 x 与泄露系数 α 的积,很好地解决了 ReLU 函数在输入小于 0 时梯度信息消失问题。从而有利于生成器

与判别器更容易训练以尽快达到纳什均衡状态。FNN 经过激活后使用 Dropout 层可以加快模型收敛,预防因梯度消失引起的模型坍塌。Dropout 层系数均为 0.3,在训练过程中发现,该系数过大或过小都会导致对抗网络模型难以达到纳什均衡状态。第 4 层 FNN 激活函数选择 ReLU 函数,生成 $[0, 1]$ 范围内数据。

判别器主体也由 4 层 FNN 组成,前 3 层 FNN 使用与生成器相同泄露系数的 LeakyReLU 激活函数,且使用系

数为 0.4 的 Dropout 层加快模型收敛。一般的 CGAN 判别器输出层需要使用 Sigmoid 激活函数,由于本文将 EM 距离引入判别器,其目标是最小化两个数据分布之间的 EM 距离,因此最后一层 FNN 不需要激活函数。

在 CGAN 模型的基础上引入 Wasserstein 距离、梯度惩罚项改进措施后形成的 WCGAN-GP 模型,其目标函数重新定义如下:

判别器 D 的目标函数为:

$$\max_D L(G, D) = \underbrace{E_{x \sim P_r(\cdot)} [D(x, y)] - E_{z \sim P_g(\cdot)} [D(G(z, y))]}_{EM \text{ 距离}} - \lambda E_{x \sim P_r(\cdot)} (1 - \|\nabla_x D(\hat{x})\|)^2 \quad (7)$$

式中: λ 为梯度惩罚项的常系数,判别器 D 的目标是最大化上述误差,即迫使 EM 距离尽可能大,梯度 $\nabla_x D(\hat{x})$ 逼近于 1; \hat{x} 来自于每一批次的真实数据 x_r 与生成数据的 x_g 的随机线性混合, t 服从 $[0, 1]$, 公式如下:

$$\hat{x} = tx_r + (1 - t)x_g, t \in [0, 1] \quad (8)$$

生成器 G 的目标函数为:

$$\min_G L(G, D) = E_{x \sim P_r(\cdot)} [D(x_r)] - E_{z \sim P_g(\cdot)} [D(G(z, y))] \quad (9)$$

G 的目标是最小化误差,要求 EM 距离越小越好。由于 $E_{x \sim P_r(\cdot)} [D(x_r)]$ 项只与判别器有关,因此 G 的目标

函数可以简写为:

$$\min_G L(G, D) = - E_{z \sim P_g(\cdot)} [D(G(z, y))] \quad (10)$$

与其他解决数据失衡的融合模型相比, WCGAN-GP 模型不仅可以得到指定的发动机故障样本,还通过引入 EM 距离和 GP 项解决了对抗网络数据重合过少难以训练和数据过于敏感问题,使模型能在更少的训练批次内达到纳什均衡。

WCGAN-GP 模型训练步骤如下:

- 1) 使用历史数据训练判别器模型。固定生成器参数,使用 Adam 算法优化判别器参数,得到判别器 D_1 。
- 2) 根据判别器调整生成器参数。固定判别器 D_1 参数,使用 Adam 算法优化生成器参数,得到生成器 G_1 。
- 3) 循环执行 1)、2),交替训练优化生成器模型与判别器模型参数。经过 n 轮训练生成器与判别器最终达到纳什均衡,训练完毕保存模型参数。

2.3 预测模型

数据集拥有足够的故障样本后,需要预测模型提取其深层退化特征,以及捕获长时间依赖关系。本文构造 ConvLSTM 预测网络,通过不断地训练来学习混合数据集中发动机各阶段的数据分布,预测模型结构如图 8 所示。

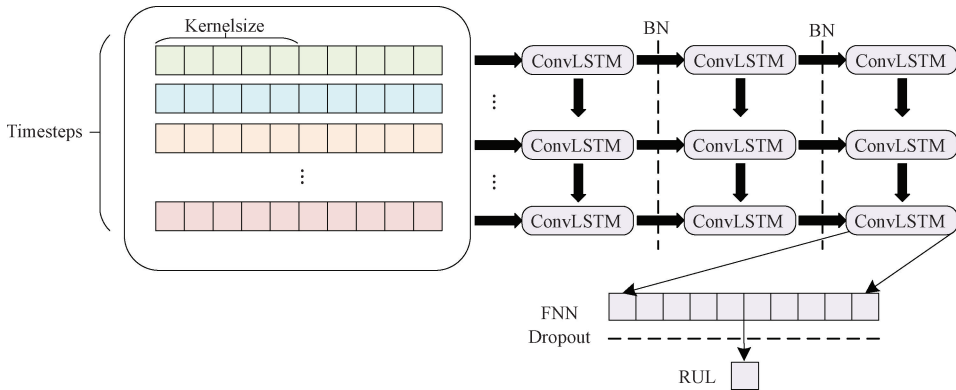


图 8 ConvLSTM 预测模型结构

Fig. 8 Structure of ConvLSTM prediction model

预测模型网络层数为 8 层,包含 3 层 ConvLSTM 层, 2 层 BatchNorm 层,1 层 Dropout 层和 2 层 FNN。前两层 ConvLSTM 作为模型网络的输入层和第 2 层需要承担更多学习短时局部特征任务,所以卷积核范围应比第 3 层网络卷积核更大。对每个每层网络之间设置 BN 层有助于加快网络收敛,抑制过拟合。最后一层 ConvLSTM 的输出后面连接 2 层 FNN,且最后一层神经元数为 1,输出 RUL 预测值。在全连接层中添加 Dropout 层,既能提升网络的泛化性和鲁棒性,又可以防止过拟合。

研究中选择 MAE 做损失函数,因其不会将误差过度

放大从而使得模型收敛速度加快,参数训练过程更加平稳。MAE 公式如下所示:

$$MAE = \frac{1}{n} \sum_{i=1}^n |RUL_i^{pre} - RUL_i^{act}| \quad (11)$$

式中: RUL_i^{pre} 、 RUL_i^{act} 分别代表模型输出的 RUL 预测值与发动机实际 RUL 值。

与未考虑数据失衡的已有预测模型相比,本文中的预测模型部分使用 LSTM 的变体——ConvLSTM 网络。区别于 LSTM 其他变体网络,ConvLSTM 不仅可以获取数据间的时间依赖关系,同时还能通过卷积运算提取数据

退化特征,并将两者紧联系起来得到更精确的 RUL 预测值。

模型优化完成后,模型在线预测阶段是必不可少的环节。该阶段主要包括两个功能:

1) 测试集在线数据经过与历史数据相同操作的数据预处理操作后,输入至优化后的预测模型中,对每个时间点进行 RUL 预测,然后根据预测结果有助于制定发动机合理运维策略。

2) 同时预测值用来与标准 RUL 值进行对比计算出模型性能指标数据,验证预测模型的性能优越性。

3 实验验证与分析

实验所用计算机设备配置如下:GPU 为 NVIDIA GeForce GTX 2080Ti,CPU 为 Intel Core i9-9900k,内存为 32 GB;操作系统为 Windows10 (64 位);程序语言为 Python3.6,基于 TensorFlow-GPU 2.5.0 深度学习框架实现。

3.1 模型评价指标

研究主要使用两个指标来评价方法的性能,即均方根误差 (RMSE) 和 Score 指标。Score 指标是由 NASA 针对 C-MAPSS 数据集提出的预测性能指标。由于当模型预测 RUL 值高于实际 RUL 值时,可能会导致发动机出现严重损坏从而造成无法挽回的损失,所以该指标对预测高于实际值的惩罚比对低于实际剩余使用寿命值的惩罚更加严格。RMSE 由于可以反应数据集的离散程度而被广泛用为 RUL 预测领域的性能评价指标。其公式如下所示,

$$d_i = RUL_i^{pre} - RUL_i^{act} \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n d_i^2} \quad (13)$$

$$Score = \begin{cases} \sum_{i=1}^n e^{-\frac{d_i}{15}} - 1, d_i \leq 0 \\ \sum_{i=1}^n e^{\frac{d_i}{10}} - 1, d_i > 0 \end{cases} \quad (14)$$

式中: n 表示数据集中发动机总数; d_i 是第 i 个发动机的预测 RUL 值与实际 RUL 值的差。总体而言,低 RMSE 值与低 Score 值意味着预测模型的高性能。

3.2 超参数设置

研究中 WCGAN-GP 模型生成器与判别器网络结构相对灵活,可以根据具体情况进行改变。以学习 FD002 数据分布的网络参数为例,研究方法中生成器 G 由 4 层 FNN 组成,两个隐藏层分别由 512 和 1 024 个神经元构成;判别器 D 也由 4 层 FNN 构成,隐藏层神经元个数均为 512,参数设置如表 3 所示。对抗网络模型训练的批次

大小为 64,使用 Adam 优化算法,并将初始学习率设为 0.000 5。ConvLSTM 网络预测模型各层数设置如表 4 所示。两个模型其他超参数设置如表 5 所示。

表 3 WCGAN-GP 结构参数

Table 3 WCGAN-GP structure parameters

网络层	生成器 G		判别器 D	
	神经元数	激活函数	神经元数	激活函数
FNN_1	256	LeakyReLU	512	LeakyReLU
FNN_2	512	LeakyReLU	512	LeakyReLU
FNN_3	1 024	LeakyReLU	512	LeakyReLU
FNN_4	300	ReLU	1	--

表 4 ConvLSTM 预测网络结构参数

Table 4 ConvLSTM prediction network structure parameters

网络层	卷积核		
	数量	尺寸	步长
ConvLSTM_1	64	3×1	1
ConvLSTM_2	20	3×1	1
ConvLSTM_3	1	1×1	1
FNN_1	-	100×1	-
FNN_2	-	1×1	-

表 5 其他超参数设置

Table 5 Other hyperparameter settings

名称	WCGAN-GP	ConvLSTM
迭代次数	1 000	200
批次大小	64	512
Dropout 层	0.3 (G)、0.4 (D)	0.2
优化算法	Adam	Adam
初始学习率	0.000 5	0.001

3.3 模型训练

为了验证 WCGAN-GP 网络解决数据失衡问题的可行性,将未经过任何数据增强的训练集输入至 ConvLSTM 网络进行训练,记录使用测试集 RUL 预测时模型的 RMSE 和 Score 平均值如表 6 所示。

表 6 非平衡数据集训练预测网络的平均 RMSE 及 Score 值

Table 6 Average RMSE and Score values of the prediction network trained on the unbalanced data sets

数据集	RMSE	Score	R ²
FD002	22.21	1 610	0.71
FD004	24.48	2 892	0.66

随后,使用 WCGAN-GP 经过 1 000 次迭代学习数据集样本数据底层分布,生成器与判别器对抗 Loss 曲线如图 9 所示。判别器损失最终在 0 附近反复振荡,且生成器损失逐渐趋于稳定值,说明已达到纳什均衡状态。由式(2)、(14)可知当此时,判别器 Loss 趋于 0 说明生成样

本与真实样本之间的 EM 距离很小,两类样本相似度很高。最终生成器可以生成足够真实数据为航空发动机寿命预测提供大量的故障样本数据。

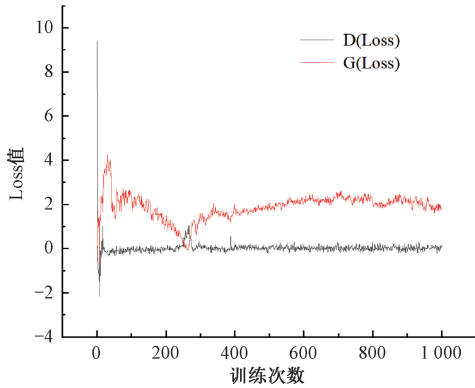


图 9 对抗训练 Loss 曲线

Fig. 9 Confrontation training Loss curve

以少数样本(即故障样本,研究中将 RUL 处于 [0, 25] 区间的样本数据定义为故障样本)的 RUL 值为条件生成大量故障数据。研究中发现不同比例的故障样本与正常样本混合之后对预测模型性能的优化效果不同,具体如图 10 所示。

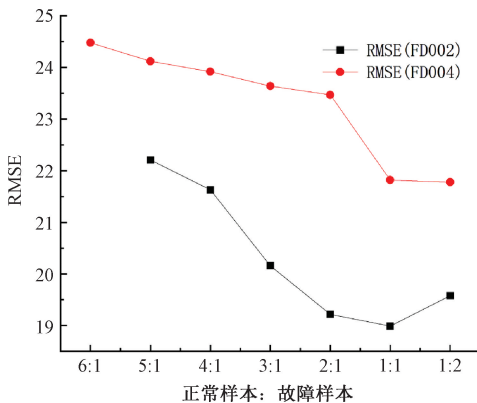


图 10 不同比例混合样本 RMSE 对比

Fig. 10 Comparison of RMSE of mixed samples with different ratios

预测模型使用 FD002 及 FD004 的不同比例混合样本训练后,对其 RMSE 性能进行对比研究。FD002 数据集原始样本比例为 5 : 1;FD004 由于故障模式不同,其原始比例为 6 : 1。由图中可以明显看出 FD002 数据集样本比例在 1 : 1 时, RMSE 值最低,意味模型在此性能最优、稳定性最好;FD004 数据集样本比例在 1 : 2 时, RMSE 值最低。虽然此时性能最优但是增强有限且计算成本较上一个最优比例增加了近一半。综上所述,研究中选择正常样本与故障样本比例为 1 : 1 进行混合增强实验效果最好,从而训练得到最优性能模型。

从 FD002 与 FD004 测试集中随机抽取一个发动机进行 RUL 预测,结果如图 11 所示。

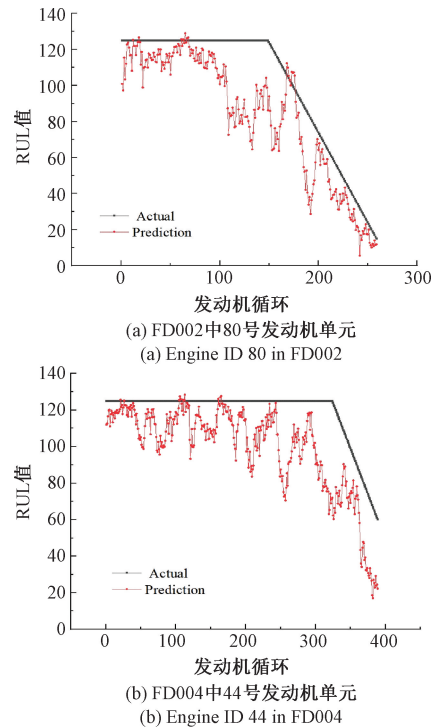


图 11 测试集发动机 RUL 预测

Fig. 11 Test set engine RUL prediction

在发动机运行前期,RUL 预测值在真实值附近波动;发动机运行中后期,RUL 预测值随着真实值开始线性变化,且全程基本小于真实值,即实现提前预测。这样可以对发动机故障进行提前预警,符合文章研究的预期。

3.4 模型性能验证

以 FD004 数据集为例,将测试集发动机按照实际 RUL 值进行升序排列。将本文研究方法与当前公开的发动机先进预测方法(LSTM、DCNN、CNN+LSTM)进行比较,结果如图 12 左图所示。

横轴为排序后的 100 个独立发动机单元,纵轴为各个发动机单元的 RUL 值。图中距离真实 RUL 值越近说明该算法预测效果越好;在距离相同的前提下,真实 RUL 值下方代表提前预测,意味着模型性能更好。图 12 右图为阴影部分中 40 个发动机单元预测 RUL 值与真实 RUL 值之差,且各个方法的平均差值分别为 -4.78、-14.354、-9.079、-21.057、-14.492。以上可以明显看出文章研究方法更加贴近发动机真实 RUL 曲线,说明所选算法在准确性上优于其他算法。

预测结果的误差范围一定程度上可以体现预测模型的稳定性。研究针以数据增强为变量使用 FD002 和 FD004 数据计算 ConvLSTM 预测模型误差范围。结果如图 13 所示。

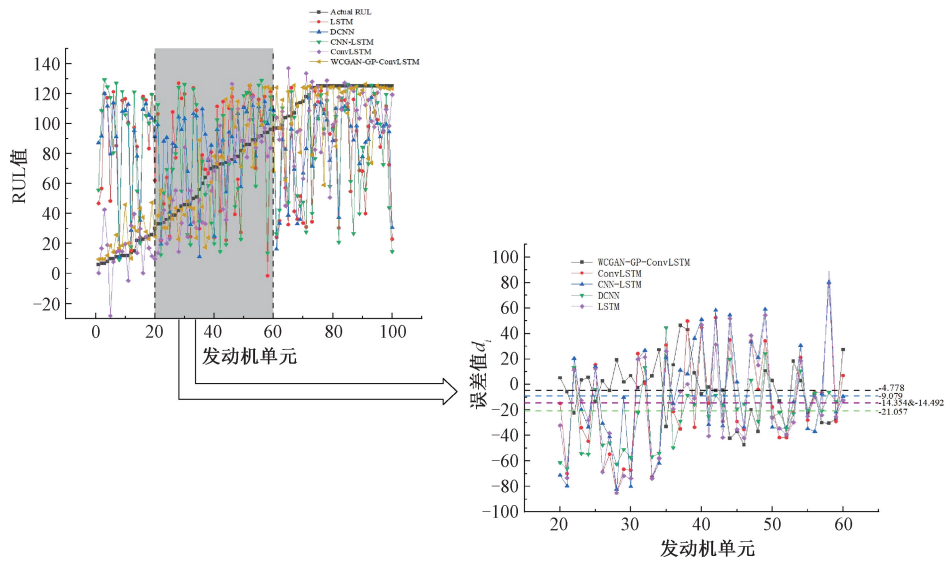


图 12 不同方法对 FD004 测试集发动机单元的 RUL 预测值对比及预测差值

Fig. 12 Comparison of RUL prediction values and prediction differences for FD004 test set engine units by different methods

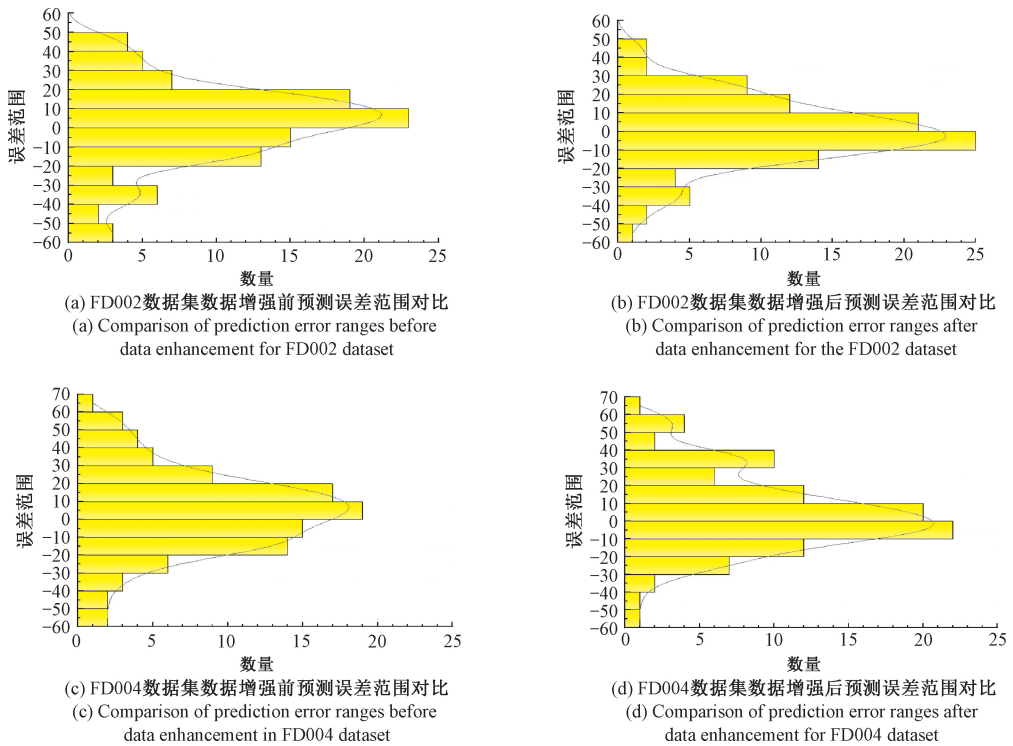


图 13 预测误差范围对比

Fig. 13 Comparison of prediction error range

纵坐标表示预测值与真实值的差值,横坐标表示相应差值范围内的数量。差值数值小于 0 时,说明预测值小于真实值,意味提前预测;反之,值大于 0 代表滞后预测。由图可知,数据增强前后,预测误差均集中在 0 附近。经过对比可知,数据增强前,模型对两个数据集的预测结果误差与数据增强后相比更加分散,表明其预

测精度总体更低。由此分析可知使用 WGAN-GP 进行数据增强后训练的发动机 RUL 预测模型拥有更好的稳定性与更高的精确度。

最后,将本文研究算法与其他神经网络算法和传统机器学习算法(支持向量回归(SVR)、随机森林算法(RF))的性能评价指标 Score 与 RMSE 进行比较。选用

拥有更复杂运行条件和故障模式的 FD002 和 FD004 数据集进行多次实验取平均值对比。对比结果如表 7 所示。

表 7 性能评价指标对比

Table 7 Performance evaluation index comparison

方法	FD002		FD004	
	RMSE	Score	RMSE	Score
SVR ^[18]	30.29	13 570	29.16	7 886
RF ^[19]	29.59	70 460	31.12	46 560
LSTM ^[8]	24.49	4 450	27.42	4 255
DCNN ^[4]	23.29	1 902	31.21	3 624
CNN+LSTM ^[20]	25.22	2 442	27.29	3 392
ConvLSTM	22.21	1 610	24.48	2 892
WCGAN-GP-ConvLSTM	18.99	822	21.82	1474

对比结果表明,本文研究方法的 RMSE 和 Score 值均为最低。由表中可以看出,ConvLSTM 预测模型在不会发生过拟合的情况下,其性能指标均低于其他算法,说明本文所提预测模型具有更强大的特征提取能力及非线性映射能力。且与最优结果相比,所提方法使用 FD002 数据集的性能指标 RMSE 和 Score 分别下降了 14.5% 和 48.9%,使用 FD004 数据集的性能指标 RMSE 和 Score 分别下降了 10.8% 和 49%。本文所提方法的性能指标 RMSE 和 Score 平均下降了 12.65% 和 48.95%,原因是 WCGAN-GP 通过学习数据底层分布生成大量的故障样本。与单一样本数据相比,混合数据虽然离线训练预测模型占用的计算机资源相对较多,计算时间有所加长,但是,其充分扩展了数据集中的故障信息,为预测模型提取发动机有效退化信息起到了至关重要的作用。综上所述,WCGAN-GP-ConvLSTM 算法可以有效提高航空发动机在复杂环境下的 RUL 预测精度以及预测的稳定性。

4 结 论

本文选择将 WCGAN-GP 应用于航空发动机 RUL 预测领域。通过对抗训练学习并生成多维设备退化数据,并将生成数据与真实样本混合共同训练预测网络模型。预测模型使用 ConvLSTM 网络既可以处理数据长时间依赖关系,又因为卷积运算可以减少网络冗余,提高网络非线性建模能力。因此,模型拥有更高的预测精度、更稳定的预测性能和更好的泛化性能。使用 C-MPASS 数据集进行实验验证,得到了以下结论:

1) 与其他公开方法相比,文章使用的模型拥有更低的 RMSE 和 Score 值,意味着其预测性能优于现有公开方法。

2) 解决数据失衡问题后,ConvLSTM 预测模型拥有

更低的 RMSE 和 Score,说明解决数据失衡问题,可以整体提升模型的预测能力。这在航空发动机领域乃至整个复杂设备领域 RUL 预测领域具有可观的发展潜力。

在未来工作,将尝试领域专业知识与深度学习模型融合的方法,研究不同传感器数据的加权影响问题,以进一步提高模型预测性能。

参考文献

- [1] LIN Y, LI X, HU Y. Deep diagnostics and prognostics: An integrated hierarchical learning framework in PHM applications[J]. Applied Soft Computing, 2018, 72: 555-564.
- [2] XU J, WANG Y, XU L. PHM-oriented integrated fusion prognostics for aircraft engines based on sensor data[J]. IEEE Sensors Journal, 2013, 14(4): 1124-1132.
- [3] 苗强,蒋京,张恒,等.工业大数据背景下的航空智能发动机:机遇与挑战[J].仪器仪表学报,2019,40(7):1-12.
- MIAO Q, JIANG J, ZHANG H, et al. Development of aviation intelligent engine under industrial big data: Chances and challenges[J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 1-12.
- [4] LI X, DING Q, SUN J Q. Remaining useful life estimation in prognostics using deep convolution neural networks[J]. Reliability Engineering & System Safety, 2018, 172: 1-11.
- [5] LI X, JIANG H, WANG R, et al. Rolling bearing fault diagnosis using optimal ensemble deep transfer network[J]. Knowledge-Based Systems, 2021, 213: 106695.
- [6] SHAO H D, DING Z Y, CHENG J SH, et al. Intelligent fault diagnosis among different rotating machines using novel stacked transfer auto-encoder optimized by PSO[J]. ISA Transactions, 2020, 105: 308-319.
- [7] PAN Y, HONG R, CHEN J, et al. A hybrid DBN-SOM-PF-based prognostic approach of remaining useful life for wind turbine gearbox[J]. Renewable Energy, 2020, 152: 138-154.
- [8] LI X, JIANG H, LIU S, et al. A unified framework incorporating predictive generative denoising autoencoder and deep Coral network for rolling bearing fault diagnosis with unbalanced data [J]. Measurement, 2021, 178: 109345.
- [9] MEI Y, WU Y T, LIN L. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network[C]. 2016 IEEE International Conference on Aircraft Utility Systems (AUS). IEEE, 2016: 135-140.
- [10] 刘文彪,段礼祥,耿帆,等.基于 CNN-BLSTM 网络的轴承性能退化预测[J].电子测量与仪器学报,2021,

- 35(2):80-86.
- LIU W B, DUAN L X, GENG F, et al. Bearing performance degradation prognosis based on CNN-BLSTM network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2):80-86.
- [11] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [J]. Advances in Neural Information Processing Systems, 2015, 28.
- [12] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets in advances in neural information processing systems (NIPS) [J]. Curran Associates, Inc. Red Hook, NY, USA, 2014: 2672-2680.
- [13] CUI S, YONG J. Effective Lipschitz constraint enforcement for Wasserstein GAN training[C]. 2017 2nd IEEE International Conference on Computational Intelligence and Applications (ICICIA). IEEE, 2017.
- [14] 薛振泽, 满君丰, 彭成, 等. 数据失衡下基于 WGAN 和 GAPCNN 的轴承故障诊断研究[J]. 计算机应用研究, 2020, 37(12):3681-3685.
- XUE ZH Z, MAN J F, PENG CH, et al. Research on bearing fault diagnosis based on WGAN and GAPCNN under imbalance of data [J]. Application Research of Computers, 2020, 37(12):3681-3685.
- [15] SOURAJIT B, RAJIV M. Generative adversarial networks based remaining useful life estimation for IoT [J]. Computers & Electrical Engineering, 2021, 92: 107195.
- [16] 贺佳星, 王晓丹, 宋亚飞, 等. CWGAN-DNN: 一种条件 Wasserstein 生成对抗网络入侵检测方法[J]. 空军工程大学学报(自然科学版), 2021, 22(5):67-74.
- HE J X, WANG X D, SONG Y F, et al. CWFAN-DNN: An intrusion detection method based on conditional Wasserstein generative adversarial network [J]. Journal of Air Force Engineering University (Natural Science Edition), 2021, 22(5):67-74.
- [17] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein gans [J]. Advances in Neural Information Processing Systems, 2017, 30.
- [18] LOUTAS T H, ROULIAS D, GEORGOULAS G. Remaining useful life estimation in rolling bearings utilizing data-driven probabilistic E-support vectors regression [J]. IEEE Transactions on Reliability, 2013, 62(4):821-832.
- [19] ZHANG C, LIM P, QIN A K, et al. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics [J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28(10):2306-2318.
- [20] LIU H, LIU Z, JIA W, et al. Remaining useful life prediction using a novel feature-attention-based end-to-end approach [J]. IEEE Transactions on Industrial Informatics, 2020, 17(2):1197-1207.

作者简介



陈维兴, 2003 年于东北大学获得学士学位, 2006 年于东北大学获得硕士学位, 现为中国民航大学电子信息与自动化学院副教授, 主要研究方向为工业 AI、物联系统和智慧民航。

E-mail: cw007x130@163.com

Chen Weixing received his B. Sc. degree from Northeastern University in 2003, M. Sc. degree from Northeastern University in 2006, respectively. Now he is an associate professor in College of Electronic Information and Automation, Civil Aviation University of China. His main research interests include industrial AI, IoT systems and smart civil aviation.