基于特征注意力机制的GRU-GAN航空发动机 剩余寿命预测

袁烨^{1,2,3*}, 黄虹¹, 程骋¹, 虞文武^{4,5}, 丁汉^{2,3}

1. 华中科技大学人工智能与自动化学院, 武汉 430074;

2. 华中科技大学机械科学与工程学院, 武汉 430074;

3. 华中科技大学数字制造装备与技术国家重点实验室, 武汉 430074;

4. 东南大学数学学院, 南京 210096;

5. 东南大学复杂工程系统测量与控制教育部重点实验室, 南京 210096

* E-mail: yye@hust.edu.cn

收稿日期: 2021-09-13; 接受日期: 2021-12-09; 网络版发表日期: 2021-12-28

国家重点研发计划(编号: 2018YFB1701202)和国家自然科学基金青年基金(批准号: 61873197, 51905197)资助项目

摘要 涡扇发动机作为航空航天领域的核心设备之一, 其健康状况决定了航空器能否稳定可靠地运行. 涡扇发动机的剩余寿命预测是航天器设备监测与维护的重要一环. 然而涡扇发动机的监测过程具有工况复杂、监测数据多样、时间跨度长等特点, 针对其数据类型多且体量大、数据冗余度较高、剩余寿命预测精度较低等问题, 本文通过将生成对抗网络(Generative adversarial network, GAN)的生成能力与门控循环单元(Gate recurrent unit, GRU)的预测能力相结合, 提出一种基于特征注意力机制的GAN和GRU融合模型. 为了对时序关系进行建模, 首先利用特征注意力机制和GRU分别提取空间和时间上的相关性, 然后将经过预训练的生成器附加到GRU之后得到整体模型. 具体来说, 本文采用预训练的GAN网络生成模块替代传统自编码器, 解决了由自编码器参数过多引起的GRU模块训练不充分的问题, 提升了时空相关特性的提取能力、提高了模型的泛化性能、提升了预测精度. 本文利用CMAPSS涡扇发动机数据来验证模型效果, 通过与不同机器学习方法进行对比, 实验结果显示, 该方法在均方根误差和指数型评价指标这两个评价指标上都有较高的预测精度.

关键词 航空航天, 剩余寿命预测, 生成对抗网络, 注意力机制, 特征提取

1 引言

近年来, 随着智能制造和工业互联网的快速发展, 状态监测(Condition monitoring, CM)技术被广泛应用于信息物理系统^[1]、电池健康管理系统^[2]、设备关键

零部件运维系统^[3]、电力系统^[4,5]等各种工程系统中. 状态监测技术对于故障预测和健康管理(Prognostics and health management, PHM)具有重要意义. 通过对状态监测数据的分析, 可以预测设备当前状态到失效状态的剩余寿命(Remaining useful life, RUL). 对涡扇发

引用格式: 袁烨, 黄虹, 程骋, 等. 基于特征注意力机制的GRU-GAN航空发动机剩余寿命预测. 中国科学: 技术科学, 2022, 52: 198–212

Yuan Y, Huang H, Cheng C, et al. Remaining useful life prediction of the aircraft engine based on the GRU-GAN network with a feature attention mechanism (in Chinese). Sci Sin Tech, 2022, 52: 198–212, doi: 10.1360/SST-2021-0434

动机^[6]、轴承^[3]等工业设备进行准确的RUL预测,可以早期预警机器故障,有效降低维护成本^[7]. 基于近期研究^[8-10],工业设备的RUL预测方法主要分为四类: 基于物理模型的方法^[11]、基于统计模型的方法^[12]、基于机器学习的方法^[13]和融合方法. 机器学习作为人工智能的核心,通过对获取的设备数据进行迭代训练,可以建立具有较高泛化性能、较强特征提取和数据处理能力的预测模型,因此该方法被广泛用于RUL预测. 与其他方法相比,基于机器学习的方法可以克服退化模型的机理未知问题.

近年来,深度学习算法被广泛用于从大规模数据中自动获取更深层次的抽象特征,在RUL预测问题上也取得了较好的进展. 常用的方法包括卷积神经网络(Convolutional neural network, CNN^[14])、循环神经网络(Recurrent neural network, RNN)及其变体长短期记忆神经网络(Long short-term memory, LSTM^[2])、门控循环单元(Gate recurrent unit, GRU^[15])等. CNN具有特殊的网络结构,可以同时处理序列数据和网格数据. 更重要的是,它可以在没有先验知识的情况下实现自动特征提取和识别. RNN主要用于处理具有相互依赖关系的时间序列数据^[2]. 由于其网络结构的优点,它可以保留隐藏层的状态信息. 然而, RNN由于其结构的限制,在处理长期序列方面效果不佳. 作为RNN的变体, LSTM^[16]和GRU被提出以解决长期序列预测问题. LSTM的三个门用于控制信息的流动,即输入门、遗忘门和输出门. 与LSTM相比, GRU的结构更简单,只包含更新门和重置门. 此外,一些研究表明^[15,17],与LSTM相比, GRU的计算成本更低. 最近随着生成对抗网络(Generative adversarial network, GAN)的发展, GAN通过引入对抗训练的机制,可以处理不同类型的数据,实现了对隐式特征的提取和降维^[18]. 然而,目前对GAN的研究主要集中在模型改进^[19,20],其应用领域主要集中在图像质量增强^[21]、图像分类等,很少被用于处理预测任务. 同时,在处理多特征数据时,大多数深度学习方法都没有有效的自适应加权输入特征的机制.

本文将剩余寿命预测转换为一个可以通过机器学习解决的时间序列预测问题,提出了一种新的具有自适应加权输入特征机制的预测模型,用于预测航空发动机的剩余寿命,实现对航空发动机不同引擎的精确、及时的RUL预测. 为了对时序关系进行建模,设

计了一种基于特征注意力的GRU-GAN模型,它将GAN的生成器附加到GRU的输出上,实现对隐式特征的提取和降维并挖掘长时间序列间的依赖关系. 具体来说, GAN的使用创新地解决了输入数据复杂且冗余的问题,并有效提高了GRU模型的输入数据质量和多样性. 最后,提出的特征注意机制直接应用于输入数据,利用一维卷积神经网络学习特征之间的相关性,在训练过程中动态地对更重要的特征给予更大的注意权重,从而提高预测性能.

本文使用CMAPSS数据集^[6]并使用均方根误差和指数型评分指标来衡量所提模型的有效性. 实验结果表明,本文模型可以在大的时间和空间尺度上进行有效的预测,并且优于传统模型.

本文的组织如下: 第二章阐述了剩余寿命预测问题并介绍了本文模型的背景. 第三章描述了预测模型的结构. 第四章详述了数据的各种评估实验结果,并对实验结果进行了定量讨论. 最后,第五章对文章进行了总结.

2 原理介绍

2.1 生成对抗网络(GAN)

作为一种无监督学习方法, GAN网络优势在于从输入数据中提取隐式特征和捕获目标的固有模式. 如图1所示, GAN由生成器 $G(\cdot)$ 和鉴别器 $D(\cdot)$ 组成,采用两者对抗的方式进行训练,本文使用的GAN网络的基础网络结构和DCGAN^[22]类似. 生成器包括编码器和解码器两部分,通过噪声数据生成假样本欺骗鉴别器,编码器通过对输入数据进行压缩来提取特征,解码器将这些特征进行解压以映射回高维用来生成假样本. 通过提取数据中最具有代表性的信息,缩减输入数据的信息量降低冗余. 总的来说,编码器和解码器类似于分解与合成. 因此,如果生成器仅使用某一类数据进行训练,则它会学习到该数据特有的分布. 相比之下,鉴别器旨在区分真实样本和假样本. 它采用和编码器相同的网络结构再加一层全连接层,通过与生成器交替训练达到平衡来学习输入数据的主要特征.

生成器从一组随机数据中生成样本($v \in \mathbb{R}^{T \times F}$). 本文使用 $z \sim p(z)$ 来表示输入随机噪声,生成器 $G(z)$ 将随机噪声映射到数据空间 $\mathbb{R}^{T \times F}$,其中 $v = G(z)$. v 的分布完

图 1 (网络版彩图) GAN网络结构图

Figure 1 (Color online) GAN network structure diagram.

全由 z 决定, 因此也称 z 为隐藏变量. 然后定义鉴别器 $D(x)$. D 的输入是真实样本 $x \sim p(x)$ 和 G 生成的假样本, D 的输出是0到1之间的标量. 生成器用来构造假样本, 鉴别器则用来做出正确的判断, 两者对抗训练以达到平衡. 首先通过生成器的编码和解码过程得到数据分布和潜在的特征表示, 然后通过鉴别器进行区分, GAN网络的损失函数写为如下形式:

$$\begin{aligned} \min_G \max_D V(D, G) \\ = E_{x \sim p(x)} [\log D(x)] + E_{z \sim p(z)} [\log (1 - D(G(z)))]. \end{aligned} \quad (1)$$

2.2 特征注意力机制(Feature attention, FA)

并非所有特征对RUL预测都有同等贡献. 为了对预测模型提供有效的输入特征, 本文使用了一种全新的特征注意机制对原始输入特征进行加权.

为了提高性能的同时又不过度增加模型复杂度, 本文使用一种用于提升CNN性能的轻量级特征注意力模块. 如图2所示, 它只涉及 k (本文将 k 设置为3)个参数, 但带来了明显的性能增益. 在没有降维的情况下, 首先通过全局平均池化得到每个时间段的均值信息, 然后考虑每个特征及其 k 个近邻特征, 来捕获本地跨通道的交互信息. 最后通过一维卷积和激活函数快速完成特征权重的计算. 其中卷积核大小 k 代表了局部跨特征交互的覆盖率, 即该特征周围的其他特征是否参与了该特征的注意力权重的计算, 该方法可以有效地增强特征的聚合程度.

特征注意力权重的计算公式为

$$g(X_f) = \frac{1}{T} X_f = \frac{1}{T} \sum_{t=1}^T x_t^f, \quad (2)$$

$$w = \sigma(\text{conv1d}_k(g(X))), \quad (3)$$

其中, $g(\cdot)$ 代表时间步长的全局平均池化(GAP), σ 是sigmoid激活函数. w 为计算出的特征注意力权重. 其中设 T 和 F 为一个注意力通道的高和宽, x_t^f 为第 f 个特征的第 t 个时间点的数据.

2.3 门控循环单元(Gate recurrent unit, GRU)

GRU已被证明可用于学习序列建模中的长期依赖关系, GRU和LSTM都克服了传统RNN梯度消失的问题, 并且GRU的结构更简单、高效. GRU的核心是由重置门和更新门组成^[23], 旨在从输入数据中保存和传递更多的隐藏信息. 一个典型的GRU网络结构如图3所示.

X 表示输入数据, h 表示GRU单元的输出. r 是重置门, z 是更新门. 更新门结合当前时刻的输入 x_t 和上一时刻GRU的输出 h_{t-1} 来决定上一时刻信息有多少得到保留. 计算公式如下:

$$z_t = \sigma(W_z x_t + U_z h_{t-1}), \quad (4)$$

式中, z_t 由 h_{t-1} 和 x_t 决定, σ 为sigmoid激活函数, W_z 和 U_z 是权重矩阵. 重置门则是结合 h_{t-1} 和 x_t 来控制忽略前一时刻的状态信息的程度:

图 2 (网络版彩图)特征注意力计算图

Figure 2 (Color online) Feature attention diagram.

图 3 (网络版彩图) GRU内部结构图

Figure 3 (Color online) GRU structure diagram.

$$r_t = \sigma(W_r x_t + U_r h_{t-1}), \quad (5)$$

W_r 和 U_r 是权重矩阵. 基于重置门生成新的记忆信息 $\tilde{h}_t$:

$$\tilde{h}_t = \tanh(W_h x_t + U_h(h_{t-1} \cdot r_t)), \quad (6)$$

W_h 和 U_h 是权重矩阵. 当前时刻的输出 h_t 为

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t. \quad (7)$$

具体来说, GRU通过上一时刻的状态 h_{t-1} 和当前节点的输入 x_t 来获取两个门控状态. 对于实际预测中的CM序列数据, GRU可以捕获时间步长中隐藏的设备退化信息.

3 涡扇发动机剩余寿命预测算法

3.1 问题描述

航空发动机的剩余寿命是指当前时刻到运行失效时刻之间的时间距离, 本文将传感器采集的监测数据定义为 $X = \{X_i\}_{i=1}^N$, N 代表样本数量, 并将其划分为训

练集 X_{train} 和测试集 X_{test} , 然后进行分析建立非线性映射 $f_H(\cdot)$ 来预测设备的剩余寿命 $\hat{Y}$:

$$\hat{Y}_{\text{train}} = f_H(X_{\text{train}}). \quad (8)$$

对于 X , 其中 N 为样本总数量, 它与时间窗口长度的选择有关, X_i 表示每一个时间窗口的样本数据, 是一个二维矩阵, 包括 F 个特征和 T 个时间点.

$$X_i = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^F \\ x_2^1 & x_2^2 & \cdots & x_2^F \\ \vdots & \vdots & \ddots & \vdots \\ x_T^1 & x_T^2 & \cdots & x_T^F \end{bmatrix} \in \mathbb{R}^{T \times F}, i = [1, 2, \dots, N], \quad (9)$$

其中, x_T^F 表示第 F 个特征的第 T 个数据点.

在测试阶段, 其对应的剩余寿命值是未知的, 因此, 需要对其用前面训练好的 $f_H(\cdot)$ 进行预测:

$$\hat{Y}_{\text{test}} = f_H(X_{\text{test}}). \quad (10)$$

最终通过最小化损失函数 $\min_{f_H} L_f(Y_{\text{train}}, \hat{Y}_{\text{train}})$ 来提高预测精度.

3.2 算法设计

本研究提出的算法流程图如图4所示, 大致分为两个阶段, 即训练阶段和测试阶段. 此外, 它们共享一些共同的步骤, 例如特征选择和数据归一化. 在训练阶段, 主要任务是分阶段训练和建立神经网络模型, 并利用历史数据训练模型. 测试阶段, 目标是根据训练好的模型和处理后的数据预测RUL值, 然后将相关结果进行反馈并辅助制定运维策略.

本文提出了一种基于特征注意力机制的GRU-GAN模型来进行航空发动机的剩余寿命预测, 算法流程如图5所示, 网络的整体结构如图5所示. 该模型结合了GAN的生成能力和GRU的时序数据提取特征的能力, GAN的使用能有效降低数据中冗余信息, 提高预测精度. 此外, 由于并不是所有的特征都对RUL预测有相同的重要性, 加入的特征注意力机制通过对不同特征进行重要性选取, 对于重要的特征赋予更高的权重以增强特征的聚合程度, 有效地提高模型的性能.

对于传感器采集的输入数据, 希望能对其进行深度解析以便推出后续的退化趋势及剩余寿命. 因此为了提取数据中的隐藏特征, 使用GRU网络读取前 T 个

图4 (网络版彩图)模型流程图

Figure 4 (Color online) Model flow chart.

表1 算法流程图

Table 1 Algorithm flow chart

算法1 基于特征注意力机制的GRU-GAN模型

输入: 数据集 $(X_{\text{train}}, Y_{\text{train}})$ 、 $(X_{\text{test}}, Y_{\text{test}})$, 超参数 $(T_1, T_2, \lambda, \text{最大迭代次数})$

输出: RUL预测值 $\hat{Y}_{\text{test}}$

1. 数据预处理: 特征选择、数据归一化、滑窗得到 $X_{\text{train}}^1, X_{\text{train}}^2$;
2. 训练阶段1 (GAN网络):
3. 前向传播:
4. do
5. step1: 利用噪声数据 z 训练生成器 G , 得到输出 $G(z)$, 如公式(12)
6. step2: 用 X_{train}^1 和 $G(z)$ 训练鉴别器, 如公式(13).
7. end;
8. 反向传播 使用Adam优化器更新网络参数.
9. 模型训练 重复步骤1和2, 直到 L_G 和 L_D 收敛, 如公式(1).
10. 训练阶段2(整体训练):
11. 模型构建: 截取训练阶段1的生成器 G 加到GRU网络后面得到最终的预测模型.
12. repeat
13. 前向传播:
14. do
15. step3: 由公式(2)和(3)计算特征注意力权重FA.
16. step4: GRU网络通过公式(4)~(7)处理step3的数据, 得到输出 $\text{GRU}(X_{\text{train}}^2)$.
17. step5: 将step4的输出输入到生成器, 得到RUL预测值 $\hat{Y}_{\text{train}}$
18. end;
19. 反向传播: 如公式(17), $L_{f(H)}$ 函数用于计算RUL预测值和真实值之间的误差, Adam优化器更新网络参数.
20. until: 最大迭代次数.
21. 测试阶段: 利用阶段2训练好的模型GRU-GAN在测试集上进行测试并返回测试结果 $\hat{Y}_{\text{test}}$

时间步长的输入数据, 并得到具有退化信息的固定维向量表示. 然后将该向量作为生成器的输入, 这样生成器通过对这些隐藏向量的解析来生成最后的预测结果. GAN网络的作用是利用其生成能力对GRU提取的这些隐藏特征生成最后的预测结果.

3.3 分阶段训练

通常, 神经网络使用所有训练数据作为一个整体进行训练. 实际上, 这种训练方案可能会遇到两个问题. 对于含大量参数的模型, 选择好的初始值极其困难^[24], 初始值的选择极大地影响了训练模型的性能. 由于所有模型参数同时更新, 算法需要迭代很多次才能收敛. 此外, 如果给定一个大型数据集, 每个循环都需要长时间的迭代才能完成一次完整的数据扫描. 如果只使用GRU来训练原始数据, 原始数据的冗余也会导致很难找到潜在规律. 因此可以引入自编码器来提取特征, 缓解冗余, 但存在以下问题: 按照传统方式一起训练, 由于生成器的神经元数量多于GRU网络, 生

图 5 (网络版彩图)模型整体框架

Figure 5 (Color online) The overall framework of the model.

成器将发挥主要作用, 那么训练过程的目标则变成了生成更逼真的数据, 而不是发现序列数据的退化规律.

因此本文提出了一种两阶段训练方案, 在训练的第一阶段, 使用真实的传感器数据集来训练GAN模型, 希望GAN网络生成器的输出尽可能地逼近真实样本. 将训练好的GAN网络的生成器取出, 作为带有先验信息预训练的自编码器模型, 加到带有特征注意力机制的GRU模型之后组成第二阶段的预测模型. 第一阶段训练后, 本文提出的预测模型通过更新较少的变量和每次使用较少的数据, 可以很好地初始化第二阶段整体训练的模型参数并有效降低总计算成本.

第二阶段训练使用的数据集与第一阶段相同, 仅时间步长不同, GRU的输入是通过滑窗之后的时间窗序列数据. 具体来说, GRU网络训练产生的特征向量应与GAN网络生成器输入具有相同维度. 模型整体通过GRU捕获包含有关数据退化信息的隐藏特征, 然后生成器学习这些隐藏特征以给出最终预测结果. 整体而言, 第二阶段对第一阶段的预训练模型进行全局优化, 进一步提升模型性能. 训练阶段都使用Adam^[25]优化器通过反向传播进行更新.

3.4 损失函数

第一阶段和第二阶段的输入分别为时间窗长度为 T_1 和 T_2 的样本数据:

$$X_{\text{train}}^1 = [\tilde{X}_1, \tilde{X}_2, \tilde{X}_3, \dots, \tilde{X}_i, \dots, \tilde{X}_{N_1}] \in \mathbb{R}^{T_1 \times F \times N_1}, \quad (11)$$

$$X_{\text{train}}^2 = [X_1, X_2, X_3, \dots, X_j, \dots, X_{N_2}] \in \mathbb{R}^{T_2 \times F \times N_2}. \quad (12)$$

GAN网络单独训练的生成器和鉴别器优化的目标函数如下.

生成器 G :

$$L_G = \frac{1}{N_1} \sum_{i=1}^{N_1} \left[\|\tilde{X}_i - G(\tilde{X}_i)\|_2 + \log(1 - D(G(\tilde{X}_i))) \right. \\ \left. + \|GE(\tilde{X}_i) - DE(G(\tilde{X}_i))\|_2 \right]. \quad (13)$$

鉴别器 D :

$$L_D = \frac{1}{N_1} \sum_{i=1}^{N_1} \left[\log D(\tilde{X}_i) + \log(1 - D(G(\tilde{X}_i))) \right]. \quad (14)$$

剩余寿命预测作为典型的回归问题, 应采用均方误差作为需要优化的损失函数, 但是本文采用分阶段训练法, 在第二阶段训练中生成器的输入特征分布应

与第一阶段GAN网络的输入分布类似, 生成器才能起到生成的效果, 因此本文在均方误差之后引入潜在误差来表征这两者的差异。

均方误差(L_m): 用来度量预测值和真实值之间的差异。令 $Y = [y_1, y_2, y_3, \dots, y_j, \dots, y_{N_2}]$ 表示训练集对应的真实剩余寿命值, 其中, y_j 对应第 j 个训练序列最后一个样本对应的实际RUL值。令 $\hat{Y} = [\hat{y}_1, \hat{y}_2, \hat{y}_3, \dots, \hat{y}_j, \dots, \hat{y}_{N_2}]$ 表示预测的RUL值, 因此均方误差可定义为

$$L_m = \frac{1}{N_2} \sum_{j=1}^{N_2} (y_j - \hat{y}_j)^2. \quad (15)$$

潜在误差(L_a): 除了均方误差之外, 还定义了潜在损失以最小化第一阶段真实样本与第二阶段通过GRU模型后的潜在特征之间的距离。这种损失可以帮助减小两者之间的数据分布的差异性, 可避免从头开始训练编码器, 以减少训练成本, 能让模型更关注于GRU网络达到最优的性能。定义如下:

$$L_a = \frac{1}{N_2} \|X_{\text{train}}^1 - \text{GRU}(X_{\text{train}}^2)\|_2. \quad (16)$$

本文使用潜在误差与均方误差的加权和作为模型最终的损失函数。定义如下:

$$L_{f(H)} = (1 - \lambda) * L_m + \lambda * L_a, \quad (17)$$

其中, λ 为权重调节因子。

4 模型验证与分析

4.1 数据集介绍

本文采用NASA卓越故障预测研究中心(Prognostics Center of Excellence, PCoE)提供的飞机发动机仿真状态监测公开数据集——CMAPSS^[6]。

该数据集一般作为RUL预测问题中的基准数据集, 发动机的结构主要包括发动机风扇、燃烧室、低压涡轮、低压压气机、高压涡轮、高压压气机等。

该数据集包括四个子数据集, 每个子数据集是在不同的工况和故障类型下采集而成, 其中训练集包含了所有样本从初始状态至发生失效的全部数据, 而测试集中只提供了生命周期前一段的数据。本文选用FD001和FD004来做模型的训练与验证。FD001数据集仅有一种运行工况和故障模式, 而FD004数据集运行

环境最为复杂, 是在6种运行工况下采集得到的, 同时拥有两种故障模式。数据集的具体描述如表2所示。

4.2 模型结构及参数介绍

本文使用Adam^[25]优化器优化模型参数, 初始学习率 $lr=1e^{-4}$, 在PyTorch中实现, 其中, GAN网络的详细网络架构如表3所示。此外考虑到预测结果可能受参数初始化、随机丢弃率、优化等多种因素的影响, 每个结果都是多次重复实验的平均值。对于批量大小、丢弃率、训练时期和时间步长等超参数的选择, 本文使用了网格搜索方法以得到超参数的最优数值, 具体如表4所示。

4.3 数据预处理

4.3.1 特征选择

并非所有传感器测量值都能提供有用的退化信息。为了选择包含退化信息较多的传感器特征, 本文通过对不同传感器数据的分析发现, 部分传感器数据的方差非常小, 表明这些传感器测量值在整个监测周期内没有显示出显著的变化, 不能提供有效的退化信息, 需要删除。因此, 本文最后保留了14个有用的传感器数据用于后续工作。图6显示了所选的14个传感器数据, 其中每个子图表示该特征下不同引擎的数据分布。该图中横坐标表示发动机运转开始到结束的时间点, 纵坐标表示数据分布值。即蓝点表示数据退化趋势, 红点表示发动机的失效点。有关传感器的更多详细信息, 请参见文献[6]。

4.3.2 归一化和滑窗

通常, 不同传感器的数据往往具有不同的维度和单位, 这可能会影响RUL预测的结果。为了消除不同传感器特性之间的影响, 本文将数据标准化以实现不

表2 CMAPSS数据集描述

Table 2 Description of CMAPSS dataset

数据集	CMAPSS	
	FD001	FD004
训练集引擎数	100	249
测试集引擎数	100	248
工况环境	1	6
故障种类	1	2

表 3 GAN网络结构

Table 3 GAN network structure

	Layer	ks/s
Encoder	Conv1 (LeakyRelu/Batchnorm)	4/1
	Conv2 (LeakyRelu/Batchnorm)	4/2
	Conv3	2/1
Decoder	ConvTran1d (LeakyReLU/Batchnorm)	2/1
	ConvTran1d (LeakyReLU/Batchnorm)	4/2
	ConvTran1d (Tanh)	4/1
Discriminator (D)	Conv1 (LeakyRelu/Batchnorm)	4/1
	Conv2 (LeakyRelu/Batchnorm)	4/2
	Conv3	2/1
	FC1	20
	FC2 (sigmoid)	1

表 4 超参数选择

Table 4 Hyperparameter selection

参数	描述	给定值
Batch size	一次前向/后向传递中的训练样本数	32
Dropout	GRU网络中随机丢弃神经元的概率	0.2
λ	损失函数权重调节因子	0.5
T_1	第一阶段训练数据时间步长	1
T_2	第二阶段训练数据时间步长	30
Stage1 epoch	第一阶段单次训练迭代数	3000
Stage2 epoch	第二阶段单次训练迭代数	50

同特性之间的可比性. 以下公式是归一化方法:

$$x_{t_{norm}}^f = \frac{x_t^f - x_{\min}^f}{x_{\max}^f - x_{\min}^f}, \quad (18)$$

其中, x_t^f 是原始数据, $x_{t_{norm}}^f$ 是经过标准化之后的数据, f 代表第 f 个传感器, t 代表第 t 个数据点, $x_{\max}^f$ 和 $x_{\min}^f$ 分别代表第 f 个特征的最大值和最小值.

时间维度上不同数据点之间的依赖关系对于时间序列数据处理至关重要. 因此对于较长的时间序列数据, 为了捕捉数据之间的时间相关性, 通常采用滑动窗口对相邻时间点的数据进行分段和封装^[26], 将时间窗口最后一个数据点的RUL作为时间窗口的RUL, 如图7所示.

4.4 模型评价指标

本文使用两个标准来评估模型性能. 第一个是均方根误差(RMSE), 它被广泛地应用于回归任务中, 它主要用来衡量预测值与真实值之间的差距. 二是指数型评分指标(score)^[6], 它在2008年PHM数据挑战赛中作为评价指标被提出, 是公认的权威指标, 因此在RUL预测中得到广泛应用. 对于指数型评分指标, 它对晚期预测的度量值比早期预测的惩罚更多. 其值越低, 则代表预测方法的性能越好.

总的来说, 低RMSE和低score意味着高模型性能. 这两个评价指标的公式计算如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (19)$$

图 6 (网络版彩图)特征展示图. 本研究选择的14个用于RUL预测特征, 其中蓝点表示退化趋势, 红点表示发动机出现故障

Figure 6 (Color online) Selected feature points. 14 features are selected for RUL prediction, where blue dots indicate the degradation trends, and red dots indicate the engine failure.

图 7 (网络版彩图)时间窗口图

Figure 7 (Color online) Time window diagram.

$$\text{score} = \begin{cases} \sum_{i=1}^n e^{\frac{d_i}{a_1}} - 1, & d_i < 0, \\ \sum_{i=1}^n e^{\frac{d_i}{a_2}} - 1, & d_i \geq 0, \end{cases} \quad (20)$$

其中, y_i 代表剩余寿命的真实值, $\hat{y}_i$ 代表预测值,

$d_i = \hat{y}_i - y_i$, $a_1=13$, $a_2=10$, a_1 , a_2 为计算分数指标时官方指定值.

4.5 模型结果

4.5.1 模型比较

为了验证模型的有效性, 本小节进行了多组对比实验. 表5对比了GAN网络加上不同循环神经网络(RNN, LSTM, GRU)的训练效果, 还对比了是否引入注意力机制和引入不同种类的注意力机制(SA: Self-Attention, 自注意力机制; FA: Feature-Attention, 特征注意力机制)的模型效果. 由表3可以发现, 对比上述四种方法, 本文方法的RMSE和score两个评价指标都有较明显的下降, 由于GRU在处理时序数据方面的优良性能, 使得在本文问题中, 其相较于RNN和LSTM有较好的效果. 特征注意力机制可以对不同的特征进行重要性采样, 它的加入也使得模型精度有了进一步提升. 最后对比了是否改进损失函数, 由于改进的损失函数(LA)是通过减小数据间的分布差异以降低训练成本来减少误差, 因此改进后效果更好.

进一步分析可发现, 对于FD001数据集, RMSE=13.12, 对比其他方法, 整体误差平均降低了约

表 5 本文模型与其他模型结果对比

Table 5 Comparison results of the model in this study and other models

模型方法	FD001			FD004		
	RMSE	score	Time (s)	RMSE	score	Time (s)
RNN+GAN	14.04	324.79	433	23.64	7266.92	1218
LSTM+GAN	13.87	292.34	412	27.99	6891.16	1254
SA+GRU+GAN	13.54	294.52	483	25.36	4456.04	1473
FA+GRU+GAN	13.28	279.22	475	23.40	5627.35	1555
FA+GRU+GAN+LA (本文)	13.12	249.32	430	21.86	3361.14	1358

4%; score=249.32, 整体误差平均降低约10%。对于FD004数据集, RMSE=21.86, score=3361.14, 与其他几种方法相比, 两个评价指标的平均整体误差分别降低了约12%和40%, 因此, 从数据对比可以得出, 本方法具有更优的准确性和泛化性。为了进一步直观展示结果, 本文选取了FD001数据中比较有代表性的四个引擎(#34, #56, #76, #81)作为展示, 如图8所示, 将上述五种方法在所选四个引擎的剩余寿命退化趋势做了可视化, 图8(a)~(e)分别对应表5的五种方法, 可以发现随着方法的不断深入, 预测RUL与真实RUL拟合程度越高。同时还发现, 当涡扇发动机处于正常状态时, 其剩余寿命处于平稳阶段, 当它开始退化时, 剩余寿命曲线逐渐下降, 发动机运行早期的预测误差大于运行后期的预测误差, 这是因为随着故障的临近, 数据值中包含的退化信息越来越多, 从而导致后期的预测精度较高。并且随着方法的加深, 剩余寿命预测的整体精度越高。

通过对比表5中的五种方法, 以及相关模块的加入与改进, 由最后的实验结果可表明, 所提出的方法在FD001和FD004数据集上的RUL预测效果更好。

4.5.2 其他方法比较

表5从不同的模块比较了不同的方法, 为了进一步评估本模型在RUL预测中与其他方法比较的效果, 本部分将重点对所提出的方法与一些传统的机器学习方法和深度学习方法进行比较, 包括MLP, SVR, RF, RNN, LSTM, CNN等。

如表6所示, 对比发现, 深度学习方法普遍优于传统机器学习方法, 在RMSE和score这两个评价指标上都有显著的下降。这是由于传统机器学习方法依赖于

手工特征的提取, 而深度学习方法具有强大的特征提取和数据处理能力, 因此预测效果更好。

此外, 所提出的方法在循环神经网络后创新性地加入GAN网络, 通过对比表6的LSTM和表5中LSTM+GAN可以发现, 加入GAN网络后, FD001数据的RMSE和score分别下降约11%和28%, FD004数据的RMSE和score更是下降约4%和45%, 两个数据集中score都有明显降低, 主要原因在于GAN网络的加入有效降低了数据的冗余, 并且能从循环神经网络提取的序列信息中找到更准确的数据退化趋势, 达到预测精度更优的效果。通过在表6中横向对比传统机器学习和深度学习方法发现, 本方法在此数据集上以更低的RMSE和score显著优于其他方法。

4.5.3 可视化分析

为了进一步探究本方法的有效性, 本节对模型的特征数据进行了t-SNE降维可视化。如图9所示, 对于一种工况下采集的FD001数据, 其剩余寿命分布有着整体一致的退化趋势, 而对于六种工况下采集的FD004数据集, 其剩余寿命分布分成六簇, 每一簇也都有其特定的退化趋势, 因此对于这两个数据集分别包括了单工况和多工况的剩余寿命预测。

本小节还对不同数据集以及不同引擎的预测结果进行了可视化分析。如图10所示, 展示了在FD001数据集中100个引擎和FD004数据集中248个引擎上的预测结果, 从图中可以发现, 对于这两个数据集, 真实值和预测值均非常接近, 这也表明了本文模型的有效性。由于FD001数据集是单工况环境, FD004数据集是多工况环境, 前者相对于后者比较简单, 因此对于FD001的预测性能也优于FD004。该结果也表明所提方法对于

图8 (网络版彩图)不同方法对4个不同引擎剩余寿命预测结果图。(a) RNN+GAN方法; (b) LSTM+GAN方法; (c) SA+GRU+GAN方法; (d) FA+GRU+GAN方法; (e) FA+GRU+GAN+LA(本文方法)

Figure 8 (Color online) The remaining useful life prediction results of different engines. (a) RNN+GAN; (b) LSTM+GAN; (c) SA+GRU+GAN; (d) FA+GRU+GAN; (e) FA+GRU+GAN+LA (method of this article).

单工况的预测任务有着较优的预测精度, 而对于多工况的预测, 本模型也能实现不同工况间的知识共享, 实现信息的融合, 从而提取到不同工况的数据特征以

取得优异的性能, 具有良好的泛化性能。

以上实验结果表明, 特征注意力机制可以在训练过程中捕获更重要的退化信息, 动态地对输入特征进行

表 6 本文方法与其他方法对比

Table 6 Comparison of the method in this study and other methods

数据集 /方法	评价指标	机器学习			深度学习			本文方法
		MLP ^[27]	SVR ^[27]	RF ^[28]	CNN ^[27]	LSTM ^[29]	DBN ^[27]	
FD001	RMSE	37.56	20.96	17.91	18.45	15.42	15.21	13.12
	score	17972	1381.5	479.75	1286.70	410.60	417.59	249.32
FD004	RMSE	77.37	45.35	31.12	29.16	29.12	29.88	21.86
	score	5616600	26509	46567.63	7886.4	12551.44	7954.51	3361.14

图 9 (网络版彩图)数据RUL分布图. (a) FD001在一种工况下的退化趋势分布; (b) FD004在六种工况下的退化趋势

Figure 9 (Color online) Data RUL distribution map. (a) The degradation trend distribution of FD001 under one operating condition; (b) the degradation trend distribution of FD004 under six operating conditions.

图 10 (网络版彩图)真实值和预测值对比图. (a) FD001真实RUL与预测RUL对比图; (b) FD004真实RUL与预测RUL对比图

Figure 10 (Color online) Comparison of true and predicted values. (a) FD001 real RUL and predicted RUL comparison chart; (b) FD004 real RUL and predicted RUL comparison chart.

加权,这有助于预测模型专注于重要特征,它的加入也有助于提高神经网络模型的预测性能.图11显示了模型在两个数据集上的3种运行状态和14个输入特征的平均注意力权重.在这两个数据集集中的所有注意力权重都大于0.5,这也证明本文选取的所有特征在预测模型中都是有用的.同时这里只是选取了某一时刻的特征注意力权重作为展示,因为特征注意力机制是根据

不同时间步的数据来动态地调整权重,因此不会给输入特征赋予固定的权重,不同时刻输入特征的权重可能不同.

5 结论

本文提出了一种基于特征注意的端到端GRU-

图 11 (网络版彩图) 本文所选特征权重分布图

Figure 11 (Color online) The weight distribution map of the selected feature in this study.

GAN方法(FA-GRU-GAN), 用于涡扇发动机的RUL预测. 首先, 本文提出的特征注意力机制, 旨在动态加权不同的输入特征. 借助特征注意力机制更多地关注重要特征, 从而提高预测性能. 训练分为两个阶段, 第一阶段用原始数据训练GAN网络, 得到训练好的生成器模型. 第二阶段训练GRU从加权输入数据中提取长期依赖关系, 然后使用生成器编码和解码上述隐藏特征以预测RUL值. 本文的贡献主要包括: (1) 在端到端的神经网络模型中实现了自动特征加权, 无需人工干预就可以获得更重要的特征信息; (2) 巧妙地结合GAN

网络的生成能力和GRU的时序数据的特征提取能力并最后将两者进行了汇总, GAN网络的引入有效地解决了数据冗余和工况种类繁多的问题, 在不同的数据集上都有较好的泛化能力; (3) 两阶段训练有效地降低了训练成本. 最后, 所提出的方法在CMAPSS涡扇发动机数据集上得到了验证, 并获得了较好的结果. 实验结果表明, 所提出的方法明显优于目前先进的方法. 另外还进行了不同模型和方法的对比、可视化分析. 未来, 我们将尝试将不同领域知识融入深度学习模型中, 进一步提高预测性能.

参考文献

- 1 Yuan Y, Tang X, Zhou W, et al. Data driven discovery of cyber physical systems. *Nature Commun*, 2019, 10: 1–9
- 2 Zhang Y, Xiong R, He H, et al. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries. *IEEE Trans Veh Technol*, 2018, 67: 5695–5705
- 3 Li X, Zhang W, Ding Q. Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. *Reliability Eng Syst Safety*, 2019, 182: 208–218
- 4 Sun M, Zhang T, Wang Y, et al. Using Bayesian deep learning to capture uncertainty for residential net load forecasting. *IEEE Trans Power Syst*, 2019, 35: 188–201
- 5 Sun M, Konstantelos I, Strbac G. A deep learning-based feature extraction framework for system security assessment. *IEEE Trans Smart Grid*, 2018, 10: 5007–5020
- 6 Saxena A, Goebel K, Simon D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation. In: *Proceedings of 2008 International Conference on Prognostics and Health Management*. IEEE, 2008. 1–9
- 7 Huang S D, Liu H Y, Cao G Z, et al. Modeling of the rapid lifetime assessment system with multiple stresses for LED devices using adaptive genetic algorithm (in Chinese). *Sci Sin Tech*, 2016, 46: 940–949 [黄苏丹, 刘淮源, 曹广忠, 等. 基于自适应遗传算法的LED器件多应力条件下寿命快速评估系统模型. *中国科学: 技术科学*, 2016, 46: 940–949]
- 8 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: 2013–2030 [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: 2013–2030]

- 9 Yuan Y, Ma G, Cheng C, et al. A general end-to-end diagnosis framework for manufacturing systems. *Natl Sci Rev*, 2020, 7: 418–429
- 10 Cheng C, Ma G, Zhang Y, et al. A deep learning-based remaining useful life prediction approach for bearings. *IEEE/ASME Trans Mechatron*, 2020, 25: 1243–1254
- 11 Wang H K, Li Y F, Liu Y, et al. Remaining useful life estimation under degradation and shock damage. *Proceed Inst Mech Eng Part O: J Risk Reliability*, 2015, 229: 200–208
- 12 Huang Z, Xu Z, Ke X, et al. Remaining useful life prediction for an adaptive skew-Wiener process model. *Mech Syst Signal Processing*, 2017, 87: 294–306
- 13 Wang Y, Zhao Y, Addepalli S. Remaining useful life prediction using deep learning approaches: A review. *Procedia Manufacturing*, 2020, 49: 81–88
- 14 Babu G S, Zhao P, Li X L. Deep convolutional neural network based regression approach for estimation of remaining useful life. In: *Proceedings of International Conference on Database Systems for Advanced Applications*. Cham: Springer, 2016. 214–228
- 15 Chung J, Gulcehre C, Cho K, et al. Gated feedback recurrent neural networks. In: *Proceedings of International Conference on Machine Learning*. Lille, France, 2015. 2067–2075
- 16 Chen D W, Wu J, Wang L P, et al. A method for predicting spindle rotation accuracy using vibration (in Chinese). *Sci Sin Tech*, 2020, 50: 819–828 [陈代伟, 吴军, 王立平, 等. 基于振动信号的电主轴回转精度预测方法. 中国科学: 技术科学, 2020, 50: 819–828]
- 17 Wu Y, Yuan M, Dong S, et al. Remaining useful life estimation of engineered systems using vanilla LSTM neural networks. *Neurocomputing*, 2018, 275: 167–179
- 18 Feizi S, Farnia F, Ginart T, et al. Understanding gans: The lqg setting. arXiv preprint, arXiv: [1710.10793](https://arxiv.org/abs/1710.10793), 2017
- 19 Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. arXiv preprint, arXiv: [1511.06434](https://arxiv.org/abs/1511.06434), 2015
- 20 Gulrajani I, Ahmed F, Arjovsky M, et al. Improved training of wasserstein gans. arXiv preprint, arXiv: [1704.00028](https://arxiv.org/abs/1704.00028), 2017
- 21 Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network. In: *Proceedings of 30th IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu: IEEE, 2017. 4681–4690
- 22 Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. arXiv preprint, arXiv: [1511.06434](https://arxiv.org/abs/1511.06434), 2015
- 23 Sun Y W, Wang Y L, Fu K, et al. Interactive gated recurrent unit and its application for estimated time of arrival (in Chinese). *Sci Sin Inf*, 2021, 51: 822–833 [孙翊文, 王宇璐, 傅昆, 等. 交互门控循环单元及其在到达时间估计中的应用. 中国科学: 信息科学, 2021, 51: 822–833]
- 24 Thimm G, Fiesler E. Neural network initialization. In: *Proceedings of International Workshop on Artificial Neural Networks*. Berlin, Heidelberg: Springer, 1995. 535–542
- 25 Kingma D P, Ba J. Adam: A method for stochastic optimization. arXiv preprint, arXiv: [1412.6980](https://arxiv.org/abs/1412.6980), 2014
- 26 Huang C G, Huang H Z, Li Y F. A bidirectional LSTM prognostics method under multiple operational conditions. *IEEE Trans Ind Electron*, 2019, 66: 8792–8802
- 27 Babu G S, Zhao P, Li X L. Deep convolutional neural network based regression approach for estimation of remaining useful life. In: *Proceedings of International Conference on Database Systems for Advanced Applications*. Cham: Springer, 2016. 214–228
- 28 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 Learning Syst*, 2016, 28: 2306–2318
- 29 Zhang J, Wang P, Yan R, et al. Long short-term memory for machine remaining life prediction. *J Manufacturing Syst*, 2018, 48: 78–86

Remaining useful life prediction of the aircraft engine based on the GRU-GAN network with a feature attention mechanism

YUAN Ye^{1,2,3}, HUANG Hong¹, CHENG Cheng¹, YU WenWu^{4,5} & DING Han^{2,3}

¹ School of Artificial Intelligence and Automation, Huazhong University of Science and Technology, Wuhan 430074, China;

² School of Mechanical Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;

³ State Key Laboratory of Digital Manufacturing Equipment and Technology, Huazhong University of Science and Technology, Wuhan 430074, China;

⁴ School of Mathematics, Southeast University, Nanjing 210096, China;

⁵ Key Laboratory of Measurement and Control of Complex Systems of Engineering, Ministry of Education, Southeast University, Nanjing 210096, China

The turbofan engine is an important piece of equipment in the aerospace industry, and its health directly affects the aircraft's stability and reliability. The remaining useful life of the turbofan engine is an important factor for aircraft monitoring and maintenance. However, the existing monitoring method has a number of shortcomings, such as complex operating conditions, redundant and large-scale volume data, and a long time span, all of which contribute to a less accurate estimate of the remaining useful life. This paper proposes a fusion of Generative Adversarial Networks (GAN) and Gated Recurrent Units (GRU) based on the mechanism of feature attention, combining the generation capability of GAN with the predictive capability of GRU. To develop the time-series prediction model, feature attention mechanism and GRU modules are used to extract spatial and temporal correlations. The final prediction is made using a pre-trained GAN generator connected to the GRU's output. Specifically, substituting the typical encoder-decoder network with a GAN resolves the complicated and redundant data problem, significantly boosting the model's prediction precision and generalization performance. This article verifies the model effect using CMAPSS turbofan engine data and compares it to machine learning methods. The experimental results indicate that the method has good predictive accuracy for two evaluation indicators: the root mean square error and the score.

aerospace, remaining useful life prediction, generative adversarial network, attention mechanism, feature extraction

doi: [10.1360/SST-2021-0434](https://doi.org/10.1360/SST-2021-0434)