

一种基于 TimeGAN 和 OCSVM 的多元退化设备 小子样数据增广方法

孙晨峰¹, 吕卫民¹, 戴洪德¹, 张浩晨²

(1. 海军航空大学岸防兵学院, 山东烟台 264000; 2. 西北工业大学机电学院, 陕西西安 710000)

摘 要: 工作在复杂环境下的多元退化设备面临失效数据少、多源信息融合准确度低和监督学习数据不平衡等问题, 对此本文提出一种基于时间序列生成对抗网络(Time-series Generative Adversarial Networks, TimeGAN)与单分类支持向量机(One-Class Support Vector Machine, OCSVM)组合模型的小子样数据增广方法. 方法引入了 TimeGAN 模型拟合真实数据时间序列相关性, 从而生成新的多元退化设备数据. 本文提出了一种基于最大均值差异改进方法的可信度判据, 避免强相关特征对生成数据质量评价的影响, 通过使用 T-分布随机邻近嵌入(T-distributed Stochastic Neighbor Embedding, T-SNE)和全局最大均值差异(Global Maximum Mean Discrepancy, GMMD)的组合方法, 定性定量地评价生成数据的质量水平. 基于训练后的 OCSVM 模型, 对生成数据进行异常检测与剔除, 进一步提高生成数据的质量. 以航空发动机数据集 C-MAPSS 为例进行方法验证分析, 通过与其他数据增强模型对比验证了所提方法的可行性和有效性.

关键词: 小子样数据; 数据增广; 多元退化设备; 时间序列生成对抗网络; 单分类支持向量机

中图分类号: TP206+3

文献标识码: A

文章编号: 0372-2112(2022)11-2678-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20220079

A Small Sample Data Augmentation Method for Multivariate Degradation Equipment Based on TimeGAN and OCSVM

SUN Chen-feng¹, LÜ Wei-min¹, DAI Hong-de¹, ZHANG Hao-chen²

(1. Coastal Defense College, Naval Aviation University, Yantai, Shandong 264000, China;

2. School of Mechatronics, Northwestern Polytechnical University, Xi'an, Shaanxi 710000, China)

Abstract: The multivariate degradation equipment working in complex environments faces the problems of small amount of failure data, the low accuracy of multi-source information fusion and imbalanced supervised learning dataset. For these problems, a small sample data augmentation method based on the combination model of time-series generative adversarial networks(TimeGAN) and one class support vector machine(OCSVM) is designed. TimeGAN is introduced to fit the time series correlation and generate the new degradation data. A new credibility criterion based on improved maximum mean discrepancy is proposed to avoid the strong correlation influence for the data quality evaluation. The combination method of t-distributed stochastic neighbor embedding(T-SNE) and global maximum mean discrepancy(GMMD) is applied to evaluate the quality of generation dataset qualitatively and quantitatively. The trained OCSVM is used to detect and remove the novelty data to further improve dataset quality. The comparison of the method and other data generation models on aircraft engine dataset C-MAPSS verifies its feasibility and effectiveness.

Key words: small sample data; data augmentation; multivariate degradation equipment; time-series generative adversarial networks; one-class support vector machine

1 引言

随着多学科技术方法在交叉领域的集成运用, 以

航空发动机为代表的多元退化设备预测与健康管
(Prognostics and Health Management, PMH)成为可靠性

工作者的热点研究问题。集机、电、液等多种技术于一体的多元退化设备往往具有高可靠性、长寿命、高价值的特征,其性能退化、故障状态与系统多个特征变量密切相关。因此基于多维传感器进行数据采集,通过数据挖掘与特征工程构建健康评价指标,从而实现设备状态评估、故障诊断和剩余寿命预测成为当前主流的方法之一^[1]。

然而在实际数据采集过程中,尤其对于军事装备来说,研究人员经常要面对数据采集成本高、数据量少(仅在装备测试与维修过程中可得到部分数据)及获得的数据呈现长尾趋势的问题;同时,现有研究对多元退化设备建立的数据驱动模型多是有监督的或是基于平衡数据集展开的,主流的机器学习方法^[2-4]在对航空发动机等多元退化设备进行剩余寿命预测时,往往采用热力学模型仿真得到的完整退化故障数据,但在部队实际维护过程中,定期部件更换与维修保障决定了正常数据往往远多于退化故障数据,实际情况下不平衡的数据输入导致模型泛化能力较差,故障诊断、寿命预测精度与仿真数据集效果相差很大、与实际情况相去甚远。因此开展小子样失效数据背景下的多元退化设备可靠性分析、故障诊断与剩余寿命预测研究成为迫切的工程实践需要。

目前,基于虚拟生成和重采样进行数据集增强成为处理小子样数据或不平衡数据集的常见策略^[5,6],但以 Bootstrap 为代表的抽样方法模拟生成的大量样本更贴合源样本的统计特征,而非其服从的总体特征^[7]。为进一步提高增广数据的准确性,许多学者从不同角度进行了有益探索:王明磊等基于二元 Wiener 过程,将极大似然估计、虚拟增广和 Bootstrap 等相结合增广电主轴数据,实现了模型参数和寿命函数的有效估计^[8];张晟斐等则提出了一种基于深度卷积生成对抗网络的数据生成方法,通过学习数据真实分布实现对传感器监测数据缺失的有效填充^[9];为消除不平衡数据集对模型训练的影响,韩淞宇提出了一种基于自适应权重单元进行特征判别的提升卷积神经网络,从均衡不同样本权重角度实现新的“平衡”^[5];MATHEW J 则从生成新的数据样本角度出发,提出了基于支持向量机的合成少数类过采样技术(Synthetic Minority Oversampling TEchnique, SMOTE),在根据 K 近邻确定样本类型的基础上,使用 SVM 合成新的样本^[10]。上述方法在不同程度上消弭了小子样数据的影响,然则多元设备退化作为一个连续变化过程,上述方法没有充分考虑多元时间序列数据的自相关性,也缺少对数据生成质量的评价和提高,从而在退化/故障数据扩充过程中存在准确度不够高的问题。因此研究一种适应小子样数据背景的数据增广方法,实现对考虑时序特点的多元数据进行

扩充,对开展多元退化设备预测与健康管理具有重要意义。

为此,本文提出了一种基于 TimeGAN 和 OCSVM 的多元退化设备小子样数据增广方法,完整设计了包括数据生成、质量评估和生成数据异常检测处理的数据扩充流程,最后基于航空发动机 C-MAPSS 数据集单台样机数据,通过多种模型方法的对比,验证了方法的有效性。

2 基于 TimeGAN 的小子样数据生成算法

2.1 TimeGAN 模型基础理论

时间序列生成对抗网络(Time-series Generative Adversarial Networks, TimeGAN)是 Jinsung Yoon 等人于 2019 年提出的一种新的时间序列生成框架^[11],其将无监督学习的灵活性和有监督训练控制能力强的优点结合起来,基于 GAN 和自编码器联合训练,创新性地同时解决了目前数据增强模型在时间序列数据上的生成和自回归问题,从而在周期性、相关性、离散型等多维时间序列数据背景中展现出广阔的应用前景。

图 1 给出了典型的 TimeGAN 结构。时间序列生成对抗网络主要由自编码器和生成对抗网络共四个部分组成,包括嵌入网络(embedding network)、复现网络(recovery network)、生成器(generator)和判别器(discriminator)。

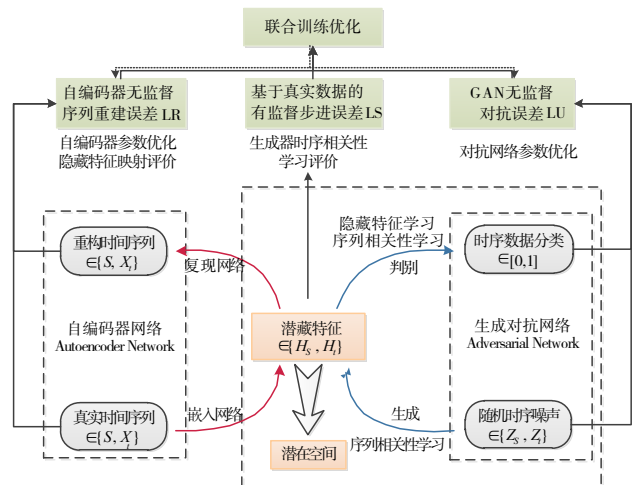


图 1 TimeGAN 模型结构框图

在图 1 中,自编码器嵌入网络将高维数据输入编码为隐层低维向量即潜在空间,从而得到高维向量中最有学习价值的特征信息;复现网络则将潜在空间还原至初始维度,二者在数据重构损失 L_R 最小目标下得到潜在空间的最优解。基于“即使是复杂系统的时间动态也往往是由较少且较低维的变化因素驱动的”这一事实^[11],生成对抗网络在嵌入空间中完成对生成器和判

别器的训练,既能对高维数据时序相关性进行拟合,也能够有效降低对抗模型训练的维数难度,从而表现出较好的学习训练效果.

从模型训练过程来看,首先基于真实时间序列数据在自编码器中进行数据重构,嵌入及复现函数可定义为

$$h_s = e_s(s), h_t = e_x(h_s, h_{t-1}, x_t) \quad (1)$$

$$\tilde{s} = r_s(h_s), \tilde{x}_t = r_x(h_t) \quad (2)$$

为满足多种数据格式处理的需要,公式中将数据类型定义为静态数据 S 和时间序列数据 X 两类; e, r 则分别表示相应变量的嵌入函数和复现函数; h_s 和 h_t 对应静态数据和时间序列数据的潜在空间; \tilde{s} 和 \tilde{x}_t 则为复现函数解码后的输入数据. 在对生成对抗网络进行设计时,生成函数与对抗函数可以定义为

$$\hat{h}_s = g_s(z_s), \hat{h}_t = g_x(\hat{h}_s, \hat{h}_{t-1}, z_t) \quad (3)$$

$$\tilde{y}_s = d_s(\hat{h}_s), \tilde{y}_t = d_x(\hat{u}_t, \hat{u}_t) \quad (4)$$

g, d 分别表示生成器函数和判别器函数, z 表示生成器两种初始噪声类型, \hat{h}_s 和 \hat{h}_t 则为经过生成器后的两种数据格式, \tilde{y}_s 和 \tilde{y}_t 对应数据的判别结果.

从联合训练角度来看,首先运用数据重构损失 L_R 实现对自编码器编码解码的优化,生成更高效的数据低维潜在表征;其次引入真实多元数据作为生成器的监督项,通过定义生成器与真实数据之间的有监督损失 L_S , 评价生成器对体现时序相关性的潜在表征和真实数据特征的学习能力;最后定义无监督 GAN 的对抗损失 L_U , 实现对生成器的反馈. 模型在各网络联合训练实现三大误差最小的基础上,完成对嵌入空间下序列相关性的学习,从而生成符合真实时序分布的生成数据,模型各误差损失公式如式(5)所示.

$$L_R = E_{s, x_t; T-p} [\|s - \tilde{s}\|_2 + \sum_t \|x_t - \tilde{x}_t\|_2]$$

$$L_U = E_{s, x_t; T-p} [\log y_s + \sum_t \log y_t] + E_{s, x_t; T-p} [\log(1 - \tilde{y}_s) + \sum_t \log(1 - \tilde{y}_t)] \quad (5)$$

$$L_S = E_{s, x_t; T-p} [\sum_t \|h_t - g_x(h_s, h_{t-1}, z_t)\|_2]$$

2.2 基于 T-分布随机邻近嵌入和改进最大均值差异的扩充数据质量评价

在对小子样真实数据进行数据扩充后,选取何种方法,形象、精确地展现高维生成数据十分重要,同时生成数据与真实数据在空间维度上的分布拟合置信度不仅关系到上述网络模型的有效性,也与后续多元退化设备状态描述、故障诊断和剩余寿命预测准确度息息相关. 本节提出使用 T-分布随机邻近嵌入 (T-distributed Stochastic Neighbor Embedding, T-SNE) 和改

进的全局最大均值差异 (Global Maximum Mean Discrepancy, GMMD) 的组合分析方法,定性定量地评价生成数据的拟合程度和可用置信度.

2.2.1 基于 T-SNE 的可视化评价方法

T-分布随机邻近嵌入是基于随机邻近嵌入 (Stochastic Neighbor Embedding, SNE) 发展而来的非线性机器学习降维算法,因其在二维或三维空间中优异的可视化效果,目前常用于高维数据的可视化展示. 上述算法从“高维空间中的相似点,映射在低维空间中也是邻近的”这一朴素思想出发,基于条件分布概率表示点在不同维度空间中的相似程度.

若以高维空间中数据点 x_i 为中心作高斯分布,以 $p_{i|j}$ 的条件概率选择 x_j 为其邻近点,则 $p_{i|j}$ 定义为

$$p_{i|j} = \frac{\exp(-\frac{\|x_i - x_j\|^2}{2\sigma_i^2})}{\sum_{k \neq i} \exp(-\frac{\|x_i - x_k\|^2}{2\sigma_i^2})} \quad (6)$$

其中, σ_i 表示以 x_i 为中心点的高斯分布的方差. 相应地,假设低维空间中对点为 x_i 和 y_j , 运用 t 分布长尾特点对小子样数据及异常值拟合的鲁棒性优势,可将低维空间点对间的分布概率 $q_{i|j}$ 定义为

$$q_{i|j} = \frac{(1 + \|y_i - y_j\|^2)^{-1}}{\sum_{k \neq i} (1 + \|y_k - y_i\|^2)^{-1}} \quad (7)$$

从而以 $p_{i|j}$ 与 $q_{i|j}$ 一致为目标,运用 KL 距离 (Kullback-Leibler divergence) 设计代价函数并运用随机梯度下降算法最小化,得到高维数据的可视化结果.

$$C = \sum_i \text{KL}(P_i // Q_i) = \sum_i \sum_j p_{j|i} \log \frac{p_{j|i}}{q_{j|i}} \quad (8)$$

2.2.2 基于 GMMD 的扩充数据可信度判据

在多元退化设备数据扩充分析中,利用 T-SNE 可以得到真实数据与生成数据在二维空间的可视化展示,进而对生成数据的分布拟合效果进行直观上的定性分析,若两组数据在低维空间的映射在形状和分布结构上仍保持某种临近相似关系,则基于上一节中的分析思想可以认为数据扩充是有效的. 在此基础上,本节提出基于 GMMD 的扩充数据可信度判据,在排除特征变量相关性影响下进一步定量评价生成数据的可用程度.

最大均值差异 (Maximum Mean Discrepancy, MMD) 是基于抽样数据度量两个分布间相似度的一种检验统计方法,通过求解待检测分布的样本在空间上某个连续函数 f 上函数值的均值,并将两均值作差得到两个分布对应于 f 的均值差异,基于连续函数 f 寻找平均差异

最大化,即为MMD.其公式定义为

$$\text{MMD}^2[F, p, q] = \left[\sup_{\|f\|_H \leq 1} (E_x[f(x)] - E_y[f(y)]) \right]^2 \quad (9)$$

其中, F 表示一个在样本空间上的连续函数集, p, q 表示待检验的分布, x, y 表示从分布中抽取的样本. 实际中通常选择高斯核函数作为函数 f , H 表示这个距离是由函数 f 将数据映射到再生希尔伯特空间 (Reproducing Kernel Hilbert Space, RKHS) 中进行度量的. 进一步则有

$$\text{MMD}[F, X, Y] = \left[\frac{1}{n^2} \sum_{i=1}^n k(x_i, x_i) - \frac{2}{n^2} \sum_{i=1}^n k(x_i, y_i) + \frac{1}{n^2} \sum_{i=1}^n k(y_i, y_i) \right]^{\frac{1}{2}} \quad (10)$$

其中, n 分别表示从分布中抽取的样本的数量, k 表示选取的高斯核函数.

MMD 分布相似度判别方法通常用于一元分布中, 本节在将其应用到多元退化设备小子样数据扩充时, 有可能扩大强相关性特征在生成数据评估中的影响. 因此本文重新定义全局最大均值差异具体公式如下:

$$\text{GMMD} = \frac{\sum_{i=1}^m \left[1 - \sum_{j=1}^m |\rho_{X_i, X_j}| \right] \times \text{MMD}_i}{m}, i \neq j \quad (11)$$

其中, 假定从两分布中抽取的样本量相同 (以 n 表示, 式中未展开), m 表示筛选后的数据特征量.

在得到多元分布的全局最大均值差异后, 可以采用假设检验的方法进行一定置信度下的有效推断. 若两个分布近似属于同一个分布, 则认为从两个分布中重复抽取多元数据计算的全局最大均值应相等, 全局最大均值差异应服从均值为零的正态分布, 考虑到抽样数据并不能代替真实总体分布的特征, 认为当全局最大均值差异小于 0.5 时, 即可认为其属于同一分布. 则在取显著性水平为 α 的条件下, 可提出如下待检验假设:

$$H_0: \mu_0 \leq 0.5, \quad H_1: \mu_0 > 0.5 \quad (12)$$

在正态分布方差 σ^2 不易确定的情况下, 我们通过重复抽取样本计算 GMMD 样本 S 代替 σ , 基于 t 检验法选择检验统计量:

$$t = \frac{\overline{\text{GMMD}} - \mu_0}{S/\sqrt{n}} \quad (13)$$

则当 H_0 为真而拒绝 H_0 时, 有

$$P_{\mu_0} \left\{ \left| \frac{\overline{\text{GMMD}} - \mu_0}{S/\sqrt{n}} \right| \geq k \right\} = \alpha \quad (14)$$

其拒绝域为

$$t = \frac{\overline{\text{GMMD}} - \mu_0}{S/\sqrt{n}} \geq t_{\alpha/2}(n-1) \quad (15)$$

3 基于 OCSVM 的扩充数据异常序列检测

TimeGAN 模型具有较好的高维数据生成能力, 但同时应该注意到, 可视化拟合中仍存在部分点偏离真实数据分布区域, 全局最大均值差异也存在一定偏差. 为进一步增强生成数据有效性, 提高多元退化设备问题分析的准确性, 对生成数据进行异常值检测是有必要. 基于真实数据对生成数据进行数据清洗, 本质上可以归类于异常检测中的单分类奇异值检测 (novelty detection) 问题: 即通过仅一类的数据构成输入空间, 对新发现的样本是否属于给定类别进行判断.

单分类支持向量机是一种无监督单分类异常值检测模型, 其模型原理是运用非线性函数将训练数据映射到高维特征空间, 通过不断产生并确定支持向量, 求解空间最优分类超平面, 从而将样本数据与特征空间原点 (以之作为奇异点代表) 以最大间隔区分开, 超平面外的点即认为是检测到的异常值并进行剔除^[12], 后续待检测数据以落在超平面内外作为判断的依据. 模型数学描述如下^[13]:

设有训练数据集 $P = \{x_1, x_2, x_3, \dots, x_n\}$, 待检测数据集 $Q = \{y_1, y_2, y_3, \dots, y_n\}$, 其中 n 是从 P, Q 两个相同维度分布中抽取的样本数量, $\phi(x)$ 是将样本映射到高维空间 F 非线性函数, 超平面表达式为 $\omega^T x + b = 0$, 则分类器的优化目标为

$$\begin{aligned} \min_{\omega, b, \xi_i} & \frac{\|\omega\|^2}{2} + \frac{1}{vn} \sum_{i=1}^n \xi_i - b \\ \text{subject to} & \\ (\omega^T \cdot \phi(x_i)) & \geq b - \xi_i, \quad i = 1, 2, \dots, n \\ \xi_i & > 0, \quad i = 1, 2, \dots, n \end{aligned} \quad (16)$$

其中, ω, b 分别表示支持向量机的权重和阈值, ξ_i 表示样本数据对应的松弛变量, 控制错分比例参数 $v \in [0, 1]$ 确定样本中奇异点比例的上限和支持向量所占比例的下限, 通过使用拉格朗日算子并引入核函数进行数据点计算, 则其分类决策函数如式 (17) 所示, 进而可以通过计算待检测点的分类决策数进行异常值判断.

$$f(x) = \text{sgn}((\omega^T \cdot \phi(x_i)) - b) = \text{sgn}\left(\sum_{i=1}^n \alpha_i K(x, x_i) - b\right) \quad (17)$$

4 小子样数据增广方法步骤及流程

本文主要的思路是在多元数据生成的基础上, 从宏观分布总体角度定性定量评价生成数据的有效拟合程度; 从微观深入特征内部对单特征离群点进行检测剔除. 小子样数据增广方法的“数据生成—质量评价—

异常检测”流程如图2所示,具体包括:

(1) 数据预处理

基于多传感器组合测得的多元退化设备性能监测数据蕴含丰富的物理结构和故障特性信息,但样本数据量纲标度、激活函数值域限制等可能对模型训练造成影响。

因此,首先通过数据挖掘技术进行特征筛选,运用时间序列分布图、热力图选择独立性强、时序退化趋势明显的特征,从而降低模型训练难度和时间。通过线性函数归一化将数据映射到 $[0,1]$ 区间内,数据归一化在统一量纲的同时也保留了多元特征内部的时间序列关系,确保更好地在模型中拟合真实数据序列相关性,其具体公式为

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (18)$$

其中 X 表示原数据集, X' 表示归一化后的数据集, X_{\max} X_{\min} 分别表示各单特征序列中的最大最小值。

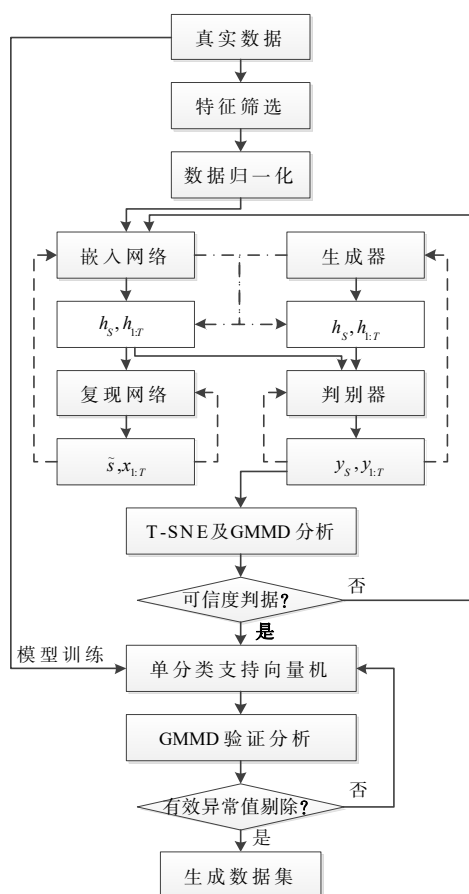


图2 小子样数据增广方法流程图

(2) 多元数据生成

将处理后的样本真实数据输入TimeGAN网络进行数据生成,利用自编码器嵌入网络创建映射空间,训练

生成对抗网络模型,通过联合误差训练不断调整模型参数,在数据生成训练过程中拟合真实数据序列相关性。

(3) 生成数据质量评价

将生成的数据通过T-SNE降至二维进行可视化,通过合成数据与真实数据形状拟合程度、离群点数量定性分析数据质量;将生成数据与真实数据各单特征分别进行MMD计算,最终结合其相关性求解全局最大平均差异GMMD,在给定置信水平下进行假设验证从而定量评价生成数据质量。

(4) 生成数据异常检测

TimeGAN对整个数据集进行固定时间步内的数据移位采样及生成,每次运行均可以获得该时间步下的多元生成数据。考虑到模型较好的数据扩充能力,在训练前结合定性定量分析结果,适当调整支持向量机中模型参数,从而使基于真实数据训练的支持向量机对新样本获得更精确的异常检测结果。对异常数据剔除后的生成数据重新进行GMMD计算,验证异常数据检测模型的有效性。

5 实例分析

作为现代制造业“皇冠上的明珠”,航空发动机是为航空器提供飞行动力的关键设备,更是一种结构精密、多学科集成的复杂多元退化设备,其各部件、分系统的异常会造成发动机推力下降,甚至导致空中停车等严重事故,直接影响飞行安全和任务可靠性水平。目前对航空发动机的性能监测与健康状态评估面临故障数据不平衡、测试成本高和个体装备真实数据匮乏的问题^[3],本文以单台航空发动机为例进行多元设备小子样数据增广,检验方法的有效性。

5.1 数据集介绍与预处理

本节采用NASA发布的C-MAPSS航空发动机仿真实验数据集进行方法验证。该数据集记录了在不同运行环境和故障模式组合条件下,多台发动机样机从不同初始退化程度到故障的完整寿命周期的四组实验数据,具体体现为高/低压压缩机进气道总温度、涵道比等21个传感器重要参数和3项操作设置的完整时间序列^[14]。

本文选取FD001数据集中76号发动机部分数据进行小子样扩充。本文采用setting1~3、senor1~21表示数据集的相关特征量。考虑到发动机性能退化是连续的,其特征量也应在序列分布上表现出一定的趋势性变化,因此首先对所有数据绘制分布图如图3所示。

从图中可以看到,setting3、sensor1、sensor5~6、sensor10、sensor16、sensor18~19等特征量或参数对时序信号不敏感或为离散型变量,在进行特征工程如健康指

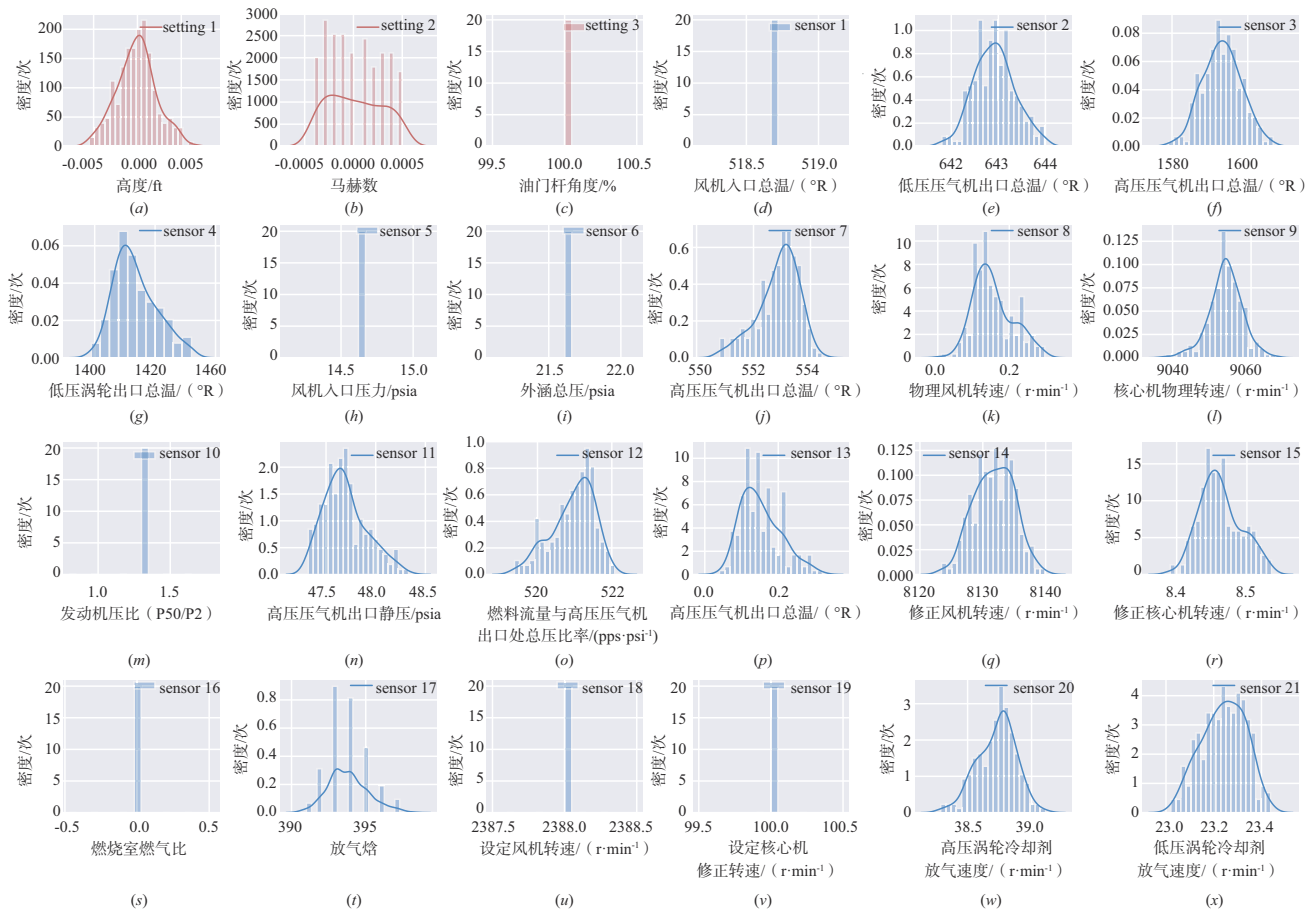


图3 发动机特征数据分布图

标构建时作用较小,对其进行小子样数据扩充意义不大,因此进行剔除.

此外从特征独立性上看,强相关性变量在特征表示上是重复的,近似的分布可能会放大相应数据对模型训练权重的影响、进一步扩大数据集的不平衡性. 发动机特征变量的热力图如图4所示,图中横纵轴为各特征变量,右侧的热力刻度中颜色的深浅代表特征的相关性水平,颜色越深表示变量正相关或负相关的程度越强.

从图4中可以看出,多数特征在数据分布上存在或强或弱的相关特性,本节将相关系数在0.9以上的特征视为强相关关系. sensor9核心机转速与sensor14修正核心机转速相关性为0.91,考虑到修正核心机转速对高压压气机状态参数的真实反映,此处保留sensor14;同时sensor11高压压气机出口静压量因与sensor15涵道比、sensor13修正风机转速、sensor12(燃料流量与高压压气机出口处总压比率)等多个特征均存在不弱的相关关系(大于0.8),故考虑剔除.

最终确定sensor2~4、sensor7、sensor8、sensor12~15、sensor17、sensor20、sensor21此12个特征作为发动机健康状态参数,对76号样机数据进行小子样扩充.




图4 发动机特征热力图

5.2 多元数据生成

发动机数据集以传感器数据测量周期作为发动机寿命度量指标,当测量周期达到最大时表示发动机故障停机,相对应的其每一行数据默认表示测量时间序列中新的时间步长. 将处理后的数据输入到TimeGAN模型中进

行数据生成. TimeGAN模型部分参数设置如表1所示.

表1 TimeGAN模型参数表

AutoEncoder	参数	GAN模型	参数
采样时间步长	24	生成器噪声层数	32
特征维数	12	GAN隐藏层	24
隐藏层层数	1	隐层激活函数	Leaky ReLU
学习率	0.0005	判别器真实损失	1

在模型迭代次数10000次后,对发动机特征生成数据进行采样时间步上的图像生成,具体如图5所示,横轴表示时间步长,纵轴表示相应的归一化量.从短时变化趋势来看,生成数据与真实数据变化虽不严格保持一致,但具备一定趋势,能够保留真实数据时序相关性和瞬态分布特性;从具体数值上说,在前期归一化的基础上,生成数据与真实数据的差异性有效拓展了数据集,增强了数据的多样性.

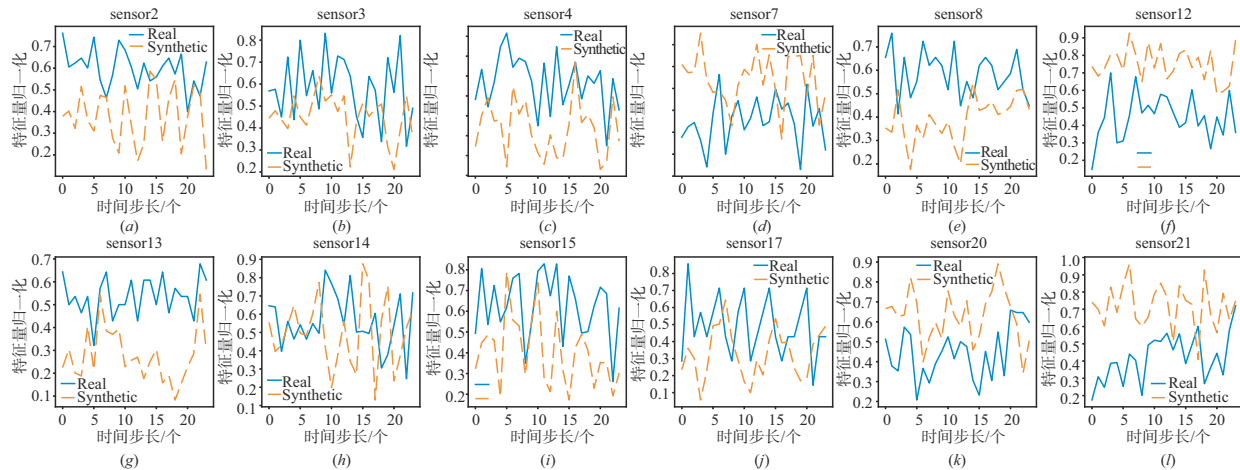


图5 发动机时间步生成数据图

5.3 生成数据质量评估

考虑到短时趋势变化信息不能从多维分布整体角度分析生成数据的有效性,进一步通过T-SNE对数据降维分析,可视化结果如图6所示.




图6 发动机两类数据可视化TSNE图

图中红色点群为TimeGAN生成的发动机小子样数据,灰色点群为发动机真实数据.从拟合效果来看,生成数据与真实数据特征类群层次分明、外部拟合边界清晰、内部数据散布均匀,但也存在一少分离群点,加之生成数据大部分分布在特征类群内部,并没有严格沿边界轮廓分布,可以推断出生成数据整体结果稳定但偏保守,但同时也具备一定的可用性,这也解释了图5中数据变化未能严格趋同的原因.

从定量分析角度来看,发动机各特征生成数据与真实数据的最大均值差异如表2所示.从表中可以看到各特征生成数据与真实数据最大均值差异较小,改进后的生成数据质量评价指标,更能从发动机独立性角度体现生成数据的有效性.

表2 生成数据各特征最大均值差异表

特征	MMD	特征	MMD	特征	MMD	GMMD
Sensor2	1.1816	Sensor8	0.7846	Sensor15	0.6838	0.457
Sensor3	0.6211	Sensor12	1.2198	Sensor17	0.9967	
Sensor4	0.8921	Sensor13	1.2692	Sensor20	1.0949	
Sensor7	0.8894	Sensor14	0.5119	Sensor21	0.5922	

进一步地,本节对生成数据建立如式(12)的检验假设,并取显著性水平 $\alpha=0.05$,对真实数据进行9次新样本生成,相应计算新生成数据与真实数据的全局最大均值差异及其样本方差如表3所示,计算得到 $t=2.18 \leq t_{0.025}$ (8).由于结果没有落在拒绝域中,因此接受原假设,认为这九批生成数据满足置信度为0.95下的可信度判据要求,生成数据质量较好,满足使用要求.

5.4 异常值检测与剔除

在生成数据满足最低置信度水平后,将真实数据带入初始OCSVM模型,通过调整支持向量比例等参数,优化模型异常检测效果,完成单分类支持向量机对76号发动机从不同初始磨损状态到故障停机的退化状

表3 不同生成批次的GMMD 分析表

生成批次	GMMD	生成批次	GMMD	生成批次	GMMD	S
Batch1	0.457	Batch4	0.546	Batch7	0.539	0.0373
Batch2	0.534	Batch5	0.561	Batch8	0.548	
Batch3	0.471	Batch6	0.557	Batch9	0.531	

态单目标的学习训练. 进一步利用训练好的模型对前述生成的状态数据进行检测, 异常检测结果如图7所示, 其中横轴表示生成数据点的序列排布, 纵轴表征相应特征量相较于原始数据的归一化量值.

分析图7可以得出, 异常结果从总体分布来看, 能较好收敛映射到相同时间步下的生成数据, 异常数量不高于设定的参数阈值(强制设定的异常检测比例);

从检测出的具体异常值来看, 高维异常生成数据虽并不是在每个特征中均呈现出离群孤立特点, 但大都为多数特征或独立重要特征中偏离训练样本散布趋势或退化特征的数据, 符合对奇异值概念的异常规律分析和工程实际认知.

基于OCSVM 的无监督异常检测方法具有对大量无标签数据局部结构、局部与整体之间的关系进行自动挖掘的强大优势, 对发动机等多元退化设备能快速实现异常状态识别, 但同时因为没有标签, 很难对其识别准确性进行直接判断. 对于检测到的异常值, 考虑到已有发动机真实数据作为训练依据; 且TimeGAN 模型每一次运行均可生成设定时间步下的退化数据. 因此本文对检测到的异常数据进行剔除, 通过重复生成弥补数据量的损失.

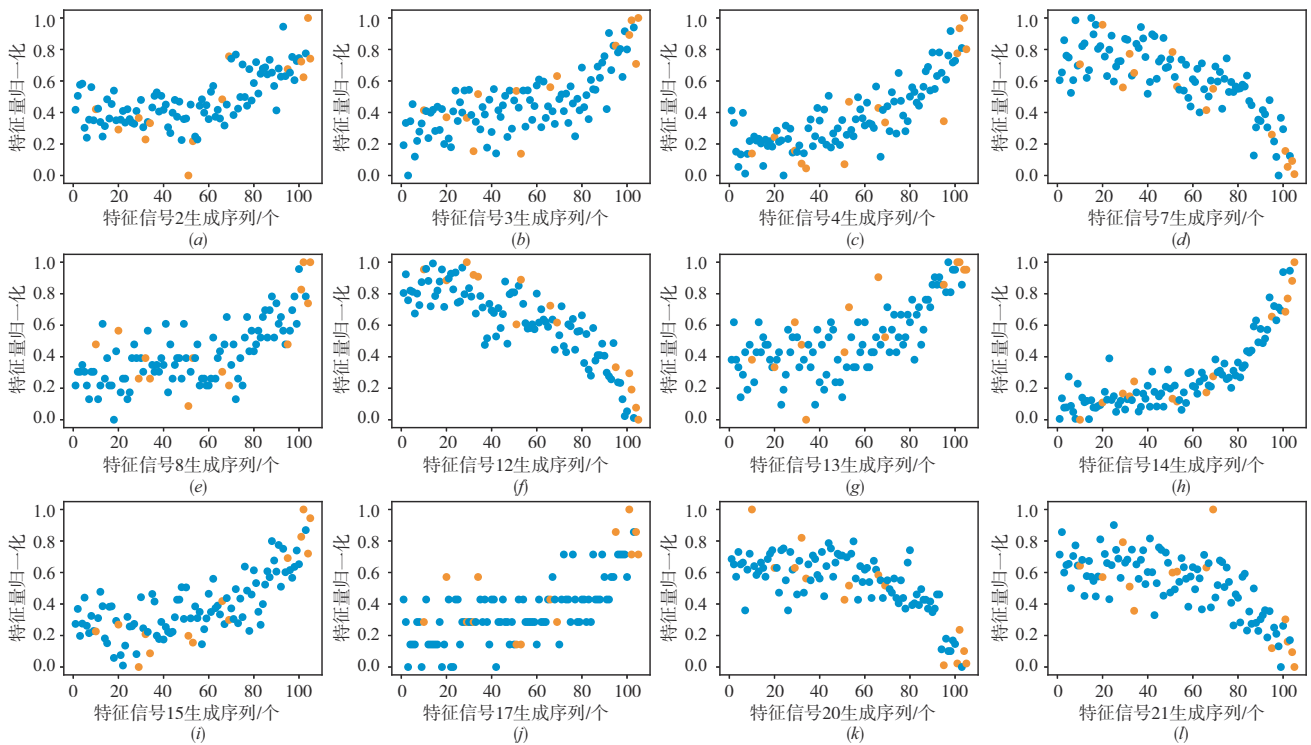


图7 发动机生成数据异常检测结果图

为验证异常检测的有效性, 本文提出对异常值剔除前后的生成数据GMMD 指标进行对比, 如若剔除异常值后的两个数据集分布拟合度高于剔除前的, 可侧面说明异常检测的有效性. 并通过进一步增加 Boot-

strap 方法和孤立森林异常检测方法在K-S 等非参数检验指标下的对比, 说明本文所提TimeGAN-OCSVM 模型方法与思路流程对多元退化设备小子样数据生成的有效性, 对比分析如表4所示.

表4 不同方法下的小子样数据生成评价分析

小子样增广方法	运算时间	最少真实数据量	模型精度	GMMD 指标	K-S 检验	Kruskal-Wallis H 检验
Bootstrap	较快	极小子样以上	较高	0.5524	0.395	1.55
TimeGAN	慢	小子样以上	较高	0.5271(9次均值)	0.368	0.207
TimeGAN-孤立森林	慢	小子样以上	较高	0.5239	0.351	0.194
TimeGAN-OCSVM	慢	小子样以上	高	0.5220	0.347	0.196

分析表4可知,TimeGAN网络相比经典重采样方法,在多个指标上具有相对较好的数据生成效果,其指标精度在异常检测剔除后得到进一步提高,验证了异常检测的有效性;同时,运用真实数据进行单分类模型训练的OCSVM异常检测方法比孤立森林“离群异常检测”概念更适用于本文模型.本文方法在拟合时间序列基础上,也增加了数据生成的时间成本,因此在运算时间上相对较慢.

6 结论

小子样增殖方法对于解决装备退化失效数据少、监督学习数据不平衡和模型泛化能力不够等问题具有重要意义.本文提出了一种基于TimeGAN-OCSVM的多元退化设备小子样数据增殖方法,从宏观微观两个角度完整设计了“数据生成-质量评估-异常检测”的数据生成评估流程:首先基于时间序列生成对抗网络生成小样本数据,进一步基于T-SNE和GMMD定性定量评估数据生成质量,最后通过训练后的单分类支持向量机模型进行生成数据异常检测.通过对航空发动机进行数据生成及分析,并与其他常用方法进行对比,验证了本文方法的有效性.

参考文献

- [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[J]. 机械工程学报, 2019, 55(8): 1-13.
PEI Hong, HU Chang-hua, SI Xiao-sheng, et al. Review of machine learning based remaining useful life prediction methods for equipment[J]. Journal of Mechanical Engineering, 2019, 47(12): 2449-2456. (in Chinese)
- [2] 车畅畅, 王华伟, 倪晓梅, 等. 基于1D-CNN和Bi-LSTM的航空发动机剩余寿命预测[J]. 机械工程学报, 2021, 57(14): 304-312.
CHE Chang-chang, WANG Hua-wei, NI Xiao-mei, et al. Residual life prediction of aeroengine based on 1D-CNN and Bi-LSTM[J]. Journal of Mechanical Engineering, 2021, 57(14): 304-312. (in Chinese)
- [3] 牟含笑, 郑建飞, 胡昌华, 等. 基于CDBN与BiLSTM的多元退化设备剩余寿命预测[J]. 航空学报, 2022, 43(7): 325403.
MOU Han-xiao, ZHENG Jian-fei, HU Chang-hua, et al. Remaining useful life prediction of multivariate degradation equipment based on CDBN and BiLSTM[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(7): 325403. (in Chinese)
- [4] 于倩影, 李娟, 戴洪德, 等. 基于Lasso变量选择的航空发动机相似性剩余寿命预测[J/OL]. 航空动力学报. DOI: 10.13224/j.cnki.jasp.20210516.
- [5] YU Qian-ying, LI Juan, DAI Hong-de, et al. Lasso based variable selection for similarity remaining useful life prediction of aero-engine[J/OL]. Journal of Aerospace Power. DOI:10.13224/j.cnki.jasp.20210516. (in Chinese)
- [5] 韩淞宇, 邵海东, 姜洪开, 等. 基于提升卷积神经网络的航空发动机高速轴承智能故障诊断[J]. 航空学报, 2022, 43(9): 625479.
HAN Song-yu, SHAO Hai-dong, JIANG Hong-kai, et al. Intelligent fault diagnosis of aero-engine high-speed bearing using enhanced convolutional neural network[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(9): 625479. (in Chinese)
- [6] 张云, 于广, 王立平, 等. 基于性能退化数据的数控转台单子样可靠性分析[J]. 清华大学学报, 2020, 60(04): 299-305.
ZHANG Yun, YU Guang, WANG Li-ping, et al. Performance degradation data based NC rotary table reliability predictions using a single sample[J]. Journal of Tsinghua University, 2020, 60(04): 299-305. (in Chinese)
- [7] 叶伟, 李亚平, 陈顶, 等. 基于小样本的复杂装备“虚拟总体”生成与检验模型[J]. 中国管理科学, 2015, 23(S1): 240-244.
YE Wei, LI Ya-ping, CHEN Ding, et al. Model for virtual overall producing and quality inspection of complex equipment based on small sample[J]. Chinese Journal of Management Science, 2015, 23(S1): 240-244. (in Chinese)
- [8] 王明磊, 原大宁, 刘宏昭. 二元Wiener过程下的小样本电主轴可靠性分析[J]. 机械科学与技术, 2017, 36(02): 279-285.
WANG Ming-lei, YUAN Da-ning, LIU Hong-zhao. Reliability analysis of motorized spindle with small sample based on two-dimensional Wiener process[J]. Mechanical Science and Technology for Aerospace Engineering, 2017, 36(02): 279-285. (in Chinese)
- [9] 张晟斐, 李天梅, 胡昌华, 等. 基于深度卷积生成对抗网络的缺失数据生成方法及其在剩余寿命预测中的应用[J]. 航空学报, 2022, 43(8): 225708.
ZHANG Sheng-fei, LI Tian-mei, HU Chang-hua, et al. Deep convolutional generative adversarial networks based missing data generation method and its application in remaining useful life prediction[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(8): 225708. (in Chinese)
- [10] JOSEY M, PANG C K, LUO M, et al. Classification of imbalanced data by oversampling in kernel space of support vector machines[J]. IEEE Transactions on Neural


Networks and Learning System, 2018, 29(9): 4065-4076.

- [11] JINSUNG Y, DANIEL J, MIHAELA S. Time-series generative adversarial networks[C]//Proceedings of the 2019 Conference and Workshop on Neural Information Processing Systems. Vancouver: NeurIPS, 2019: 5508-5518.
- [12] 吴定海, 张培林, 任国全, 等. 基于支持向量的单类分类方法综述[J]. 计算机工程, 2011, 37(05): 187-189.
WU Ding-hai, ZHANG Pei-lin, REN Guo-quan, et al. Review of one-class classification method based on support vector[J]. Computer Engineering, 2011, 37(5): 187-189. (in Chinese)
- [13] 张庆朔, 何强, 张长伦, 等. 模糊多核一类支持向量机[J]. 北京建筑大学学报, 2020, 36(01): 82-90.
ZHANG Qing-shuo, HE Qiang, ZHANG Chang-lun, et al. Fuzzy multiple kernel one-class support vector machine[J]. Journal of Beijing University of Civil Engineering and Architecture, 2020, 36(01): 82-90. (in Chinese)
- [14] SAXENA A, GOEBEL K, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation[C]//Proceedings of the 2008 International Conference on Prognostics and Health Management. Denver: IEEE, 2008: 1-9.
- [15] 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[J]. 电子学报, 2022, 50(3): 619-624.
ZHANG Hao, HU Chang-hua, DU Dang-bo, et al. Remaining useful life prediction method of lithium-ion battery based on Bi-LSTM network under multi-state influence[J]. Acta Electronica Sinica, 2022, 50(3): 619-624. (in Chinese)



戴洪德 男, 1981年11月出生于湖南省邵阳市. 现为海军航空大学副教授. 主要研究方向为惯性导航、滤波估计、故障诊断以及智能信息处理技术.

E-mail: 13954559561@126.com



张浩晨 男, 1998年8月出生于陕西省西安市. 现为西北工业大学机电学院硕士研究生. 主要研究方向为数字化制造及数据驱动下的智能制造.

E-mail: zhanghaochen817@163.com

作者简介



孙晨峰 男, 1998年3月出生于山东省莱阳市. 现为海军航空大学硕士研究生.

E-mail: scf326228@163.com



吕卫民(通讯作者) 男, 1970年7月出生于山东省莱州市. 现为海军航空大学教授、博士生导师. 主要研究方向为装备系统工程.

E-mail: 13963826998@139.com