

# 时间序列生成对抗网络架构下的分子泵退化数据生成研究\*

柏受军<sup>1</sup> 成志新<sup>1</sup> 袁啸林<sup>2</sup> 王 静<sup>3</sup> 左桂忠<sup>2</sup> 余耀伟<sup>2</sup>

(1. 安徽工程大学 高端装备先进感知与智能控制教育部重点实验室 芜湖 241000;

2. 中国科学院等离子体物理研究所 合肥 230031; 3. 巢湖学院 巢湖 238024)

**摘要:** 为了确保托卡马克实验的安全运行,对关键真空获取设备分子泵的可靠性评估至关重要。然而,有限的退化数据导致现有的预测方法准确性较低。针对这一挑战,提出了一种基于时间序列生成对抗网络(TGAN)的分子泵退化数据生成方法,旨在通过生成数据来扩充数据集,进而提高预测模型的准确性和可靠性。该方法创新性地结合了Transformer网络和TGAN,并通过引入威布尔分布提高了生成数据的质量,再利用长短期记忆网络对生成的退化数据进行退化预测。实验结果表明,TGAN-Transformer能有效生成满足分子泵退化预测需求的数据,显著提升了预测的准确性和可靠性,为分子泵的可靠性分析和安全运行提供了可靠支持。通过对比实验,TGAN-Transformer在均方根误差(RMSE)指标上相较于生成对抗网络(GAN)、深度卷积生成对抗网络(DCGAN)、递归条件生成对抗网络(RCGAN)、变分自编码器(VAE)和条件变分自编码器(CVAE)分别提升51%、48%、36%、40%、30%;在平均绝对误差(MAE)指标上,分别提升52%、49%、38%、42%、33%,证明了其在分子泵退化预测中的有效性。未来的研究可进一步优化生成网络结构,探索更多生成对抗网络的变种,以提高生成数据的多样性和真实性,从而进一步提升退化预测的准确性和可靠性。

**关键词:** 数据生成;分子泵;时间序列生成器对抗网络;退化预测

**中图分类号:** TN98 **文献标识码:** A **国家标准学科分类代码:** 510.50

## Research on molecular pump degradation data generation under time series generative adversarial network architecture

Bai Shoujun<sup>1</sup> Cheng Zhixin<sup>1</sup> Yuan Xiaolin<sup>2</sup> Wang Jing<sup>3</sup> Zuo Guizhong<sup>2</sup> Yu Yaowei<sup>2</sup>

(1. Key Laboratory of Advanced Perception and Intelligence Control of High-end Equipment, Anhui Polytechnic University,

Wuhu 241000, China; 2. Institute of Plasma Physics, Chinese Academy of Sciences, Hefei 230031, China;

3. Chaohu University, Chaohu 238024, China)

**Abstract:** To ensure the safe operation of Tokamak experiments, the reliability assessment of key vacuum acquisition equipment, specifically molecular pumps, is crucial. However, limited degradation data has resulted in low accuracy of existing predictive methods. To address this challenge, a degradation data generation method for molecular pumps based on time series generative adversarial networks (TGAN) has been proposed, aimed at augmenting the dataset through generated data to enhance the accuracy and reliability of predictive models. This method innovatively combines Transformer networks with TGAN and improves the quality of the generated data by incorporating Weibull distribution. Furthermore, long short-term memory networks are utilized for degradation prediction of the generated data. Experimental results demonstrate that TGAN-Transformer can effectively generate data that meets the needs of molecular pump degradation prediction, significantly enhancing prediction accuracy and reliability, thereby providing solid support for the reliability analysis and safe operation of molecular pumps. Through comparative experiments, TGAN Transformer has improved RMSE indicators by 51%, 48%, 36%, 40%, and 30% compared to GAN, DCGAN, RCGAN, VAE, and CVAE, respectively. On the MAE index, they

收稿日期: 2024-07-04 Received Date: 2024-07-04

\* 基金项目: 国家重点研发计划(2024YFE03250300)、中国国家自然科学基金(11905254)、安徽省自然科学基金(2108085QA38)、中国博士后科学基金(2021000278)、安徽省高等学校自然科学研究重点项目(2023AH052105)、安徽工程大学安徽省电力传动与控制重点实验室开放项目(DQKJ202207)、安徽省教育厅重点项目(2023AH050924)资助

increased by 52%, 49%, 38%, 42%, and 33% respectively, demonstrating their effectiveness in predicting molecular pump degradation. Future research may further optimize the structure of the generation network and explore more variants of generative adversarial networks to improve the diversity and authenticity of generated data, thereby further enhancing the accuracy and reliability of degradation predictions.

**Keywords:** data generation; molecular pump; time series generator adversarial network; degradation prediction

## 0 引言

先进超导托卡马克 (experimental advanced superconducting Tokamak, EAST) 是中国在世界上研制的首个全超导托卡马克核聚变实验装置, 标志着中国核聚变研究在工程和物理基础上的重要突破<sup>[1]</sup>。分子泵作为 EAST 装置中确保高真空环境的关键设备, 需要在长时间高强度运行条件下保持稳定。然而, 在这种高强度工作环境中, 分子泵的稳定性难以保证, 难以获取分子泵的健康状态以进行安全维护<sup>[2]</sup>。因此, 研究分子泵剩余使用寿命 (remaining useful life, RUL) 对保障 EAST 装置的安全运行具有重要意义。

在机械设备的寿命预测中, 通常使用传感器采集设备运行时的振动信号, 提取相关特征并将性能指标回归到这些特征上<sup>[3-5]</sup>。为了避免过拟合并保持模型的泛化能力, 需要大量数据来训练神经网络<sup>[6-7]</sup>。然而, 对于分子泵这类在特殊高强度运行环境下工作的设备, 获取充足的退化数据面临着巨大挑战。一方面, 分子泵长时间高强度的运行工况对其稳定性产生较大影响, 使得获取其健康状态数据变得极为困难; 另一方面, 经济和时间成本的限制也使得大规模数据采集难以实现。这导致现有的基于小样本的退化预测方法在准确性方面存在明显不足, 难以满足实际工程中对分子泵可靠性和安全性评估的需求。

数据生成技术通过学习真实序列中的数据分布, 以创建逼真的生成数据, 被认为是丰富数据的前沿解决方案之一<sup>[8-10]</sup>。其中最广泛使用的技术是于 2014 年提出的生成对抗网络<sup>[11]</sup> (generative adversarial network, GAN)。GAN 包含一个生成器和一个鉴别器。生成器通过学习原始数据集生成数据集, 而鉴别器则负责区分真实数据和生成数据。在训练过程中, 通过生成器和鉴别器的博弈, 促使生成器不断提高生成数据的质量。尽管 GAN 在图像生成上已取得成功, 但在处理时间序列数据时生成的数据质量不高, 难以捕捉长期依赖关系, 且生成效果不尽理想<sup>[12-14]</sup>。为提高时间序列数据生成的有效性, Esteban 等<sup>[15]</sup>尝试将长短期记忆网络 (long short-term memory, LSTM) 替代原始 GAN 框架中的卷积神经网络 (convolutional neural network, CNN), 以生成医疗时间序列数据。Zhang 等<sup>[16]</sup>提出了一种卷积递归生成对抗网

络, 其生成器结合了卷积神经网络以捕捉局部信息和递归神经网络处理长期依赖关系的优点, 用于模拟设备的运行状态和剩余使用寿命的估计值。Yoon 等<sup>[17]</sup>提出了一种新的框架, 利用传统无监督 GAN 训练方法和更可控的监督学习方法的优势, 通过将无监督 GAN 网络与监督自回归模型结合, 旨在生成保留时间动态的时间序列数据。Zhao 等<sup>[18]</sup>提出了一种基于注意力机制的改进生成对抗网络, 在生成时间序列数据时, 通过注意力模块聚焦于数据中的关键特征和时间点, 增强了生成数据对复杂动态过程的表现力。Li 等<sup>[19]</sup>则尝试将变分自编码器 (variational autoencoder, VAE) 与生成对抗网络相结合, 构建了 VAE-GAN 混合架构用于时间序列数据生成。这种方法利用 VAE 的编码能力对数据进行初步的特征提取和压缩, 再由 GAN 进行数据生成, 在一定程度上提高了生成数据的稳定性和多样性。Wang 等<sup>[20]</sup>开发了一种分层式生成对抗网络, 将时间序列数据按照不同的时间尺度和特征层次进行分解和生成, 试图从多个层次还原数据的真实分布。在一些工业设备监测数据的生成实验中取得了较好的效果。

综上所述, 尽管前人在时间序列数据生成技术方面进行了大量研究, 但在分子泵退化数据生成上均未找到能有效平衡数据质量、多样性、计算效率, 且能准确捕捉分子泵退化过程独特特征的方法, 导致生成数据难以满足分子泵可靠性预测对数据准确性和可靠性的高要求。针对这些问题, 提出了一种利用 Transformer 改进的时间序列生成对抗网络方法 (Transformer-based time series GAN, TGAN-Transformer), 旨在生成更接近实际失效过程的退化数据。通过使用 Transformer 作为生成器的核心网络结构, 利用多头注意力机制捕捉时间序列中的局部和长期依赖关系。Transformer 的并行计算能力和自注意力机制使其在处理长序列数据时具有更高的效率和稳定性, 且可以从多个不同的角度捕捉时间序列中的信息, 从而生成更加多样和真实的数据。并引入威布尔分布 (Weibull distribution) 来改变噪声分布, 以准确地描述分子泵的退化过程。

## 1 时间序列生成对抗网络 (TGAN)

TGAN 是一种生成对抗网络, 专门用于生成时间序列数据。包含 4 个主要模块, 分别为嵌入函数、恢复函

数、生成器和鉴别器。嵌入函数用于将高维的时间序列数据映射到低维的潜在空间;恢复函数的作用是将嵌入函数生成的低维潜在表示映射回到高维的时间序列数据空间,可以视作嵌入函数的逆过程。嵌入函数和恢复函

数的组合使用,提高了网络的学习效率。生成器的主要任务是生成新的数据,时间特征由监督网络学习,而鉴别器的作用是区分生成数据和真实数据。TGAN-Transformer 的总体生成过程如图 1 所示。

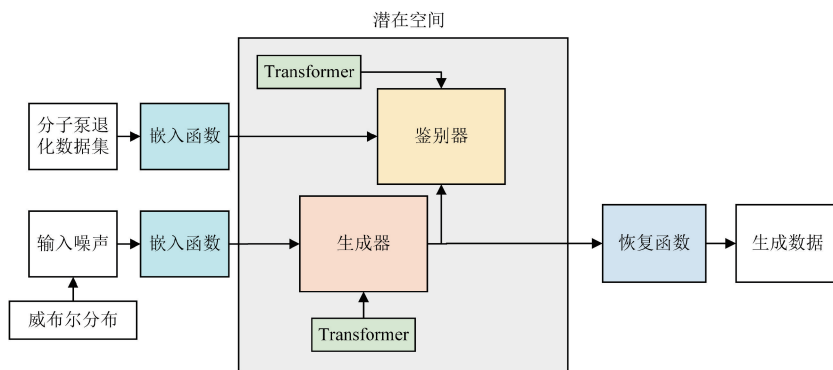


图 1 TGAN-Transformer 工作流程

Fig. 1 TGAN-Transformer workflow

将数据记录为  $D = \{X_{ij}; i \in I, j \in J_i\}$ , 其中  $I = \{1, 2, 3, \dots, m\}$  为分子泵数据记录时间;  $\{J_i = k_{1:n,1}, k_{1:n,2}, k_{1:n,3}, \dots, k_{1:n,i}\}$  为记录时间下的多元特征数据, 其中  $n$  为记录特征个数。  $X_{ij}$  为分子泵在运行过程中某一时间节点处的特征数据。TGAN-Transformer 的目标是使用训练集  $D$  来学习最接近  $P(X_{ij})$  的概率密度  $\hat{P}(X_{ij})$ 。

### 1.1 嵌入函数和恢复函数

首先,嵌入和恢复函数提供特征和潜在空间之间的映射,允许对抗网络通过低维表示学习数据的潜在时间动态。基于包含静态特征和时态特征的映射函数  $f_E^M$  和  $f_E^K$ , 利用嵌入网络将原始特征空间映射到包含静态特征和时态特征的潜在空间,从而提高网络计算的时效性。映射过程如式(1)所示。

$$\begin{cases} h_M = f_E^M(M) \\ h_k = f_E^K(h_M, h_{k-1}, x_k) \end{cases} \quad (1)$$

式中:  $h_M$  和  $h_k$  是嵌入函数映射后的低维数据表达;  $M$  是原始数据的一个静态部分;  $x_k$  是原始时间序列中的第  $K$  条序列。

嵌入函数主要是对输入数据降维,同时还需要进行从低维到高维的恢复。恢复网络学习映射函数  $f_R^M$  和  $f_R^K$  来恢复原始特征。逆映射过程为:

$$\begin{cases} \hat{h}_M = f_R^M(M) \\ \hat{h}_k = f_R^K(h_k) \end{cases} \quad (2)$$

式中:  $\hat{h}_M$  和  $\hat{h}_k$  是恢复函数逆映射的数据表达。

### 1.2 生成器和鉴别器

在潜在空间中,使用生成器生成数据。生成器的输入数据为噪声向量,输出为生成数据。基于生成函数

$f_G^M, f_G^K$ , 静态特征输入噪声  $Z_M$  和时间特征输入噪声  $Z_K$ , 生成的静态特征的低维表示  $h'_M$ , 生成的第  $K$  条序列的低维表示为  $h'_k$ , 如式(3)所示。

$$\begin{cases} h'_M = f_G^M(Z_M) \\ h'_k = f_G^K(h'_M, h'_{k-1}, Z_K) \end{cases} \quad (3)$$

式中:  $Z_M$  服从均匀分布,  $Z_K$  服从随机过程。使用威布尔分布描述  $Z_K$ 。

威布尔分布是一种的连续概率分布,在可靠性工程和寿命数据分析中广泛应用。它可以用来建模机械设备和组件的寿命和退化过程,并能适应不同的故障行为模式。其概率分布表达式如式(4)所示。

$$f(x; \alpha, \beta) = \begin{cases} \frac{\beta}{\alpha} \left(\frac{x}{\alpha}\right)^{\beta-1} e^{-\left(\frac{x}{\alpha}\right)^\beta}, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4)$$

式中:  $x$  是随机变量;  $\alpha > 0$  是尺度参数,决定了分布的尺度大小;  $\beta > 0$  是形状参数,决定了分布的形状。威布尔分布的形状参数可以灵活地调整分布的形状,使其适应多种退化模式。当  $\beta < 1$  时,表示早期故障阶段,故障率随时间增加而降低;当  $\beta = 1$  时,表示恒定故障率阶段,故障率不随时间变化;当  $\beta > 1$  时,表示磨损故障阶段,故障率随时间增加而增加。通过对实际分子泵退化数据进行统计分析,发现  $\beta = 1.5$  能够较好地拟合数据的退化模式,尤其是非线性特征,更接近实际退化过程中的早期和磨损阶段。威布尔分布的尺度参数可以调整分布的尺度大小,使得生成的数据在时间尺度上更接近实际数据。选择  $\alpha = 130$  是基于对实际分子泵退化数据的统计分析。这一参数设置确保了生成的数据在时间尺度上与实际退化数据相符,从而提高了生成数据的准确性。由于分子泵的退化过程具有非线性特征,威布尔分布能够更准确



地捕捉这些特征,生成的数据更贴近实际情况,从而进一步提高预测模型的性能。

鉴别器主要用于区分真实样本和生成样本。采用双向递归网络识别时域特征  $h'_k$ ,并在两个方向上进行区分。对两类分类器进行真实数据或生成数据的标签判断。鉴别器的输出为:

$$\begin{cases} \tilde{y}_M = D_M(h'_M) \\ \tilde{y}_k = D_K(\overleftarrow{u}_k, \overrightarrow{u}_k) \end{cases} \quad (5)$$

式中:  $\overleftarrow{u}_k$  正向递归函数的输出,  $\overleftarrow{u}_k = \overleftarrow{R}_X(\tilde{h}_M, \tilde{h}_K, \overleftarrow{u}_{k+1})$ ,  $\overrightarrow{u}_k$  反向递归函数的输出,  $\overrightarrow{u}_k = \overrightarrow{R}_X(\tilde{h}_M, \tilde{h}_K, \overrightarrow{u}_{k-1})$ ,  $\overleftarrow{R}_X$  和  $\overrightarrow{R}_X$  分别表示正向递归函数和反向递归函数;  $\tilde{y}_M$  是对生成的静态特征的判别结果;  $\tilde{y}_k$  是对生成的时间特征的判别结果;  $D_M$  为鉴别器的静态特征判别函数;  $D_K$  为鉴别器的时间特征判别函数。

生成器和鉴别器均采用了 Transformer 网络结构,Transformer 网络通过自注意力机制能够同时关注不同时间点的数据特征,从而更好地学习时间序列数据的长期依赖关系。这对于分子泵退化数据的生成和预测尤为重要,因为退化过程通常是一个长期且复杂的过程。与传统的循环神经网络(recurrent neural network, RNN)和 LSTM 相比,Transformer 能够并行处理数据,大大提高了训练效率。这对于处理大规模时间序列数据来说是一个显著的优势,这种机制使得 Transformer 在处理长序列数据时更为高效和准确。

### 1.3 损失和优化

对于损失函数,使用无监督损失用于训练鉴别器和生成器,以确保生成的数据能够欺骗鉴别器;使用监督损失用于训练生成器,以确保生成的数据在潜在空间中尽可能接近真实数据;使用重建损失用于训练生成器和递归网络,以确保生成的数据在重建过程中尽可能接近原始数据。

作为特征和潜在空间之间的可逆映射,恢复函数应该能够从原始数据的潜在表示中精确地重建原始数据。因此本文的第 1 个目标函数是重建损失:

$$L_R = E_{M, x_1: k-p} [\|M - \hat{M}\|_2 + \sum_k \|x_k - \hat{x}_k\|_2] \quad (6)$$

重建损失包括了两部分:1)用于评估整个数据片段  $M$  与恢复片段  $\hat{M}$  之间的差异;2)逐个点评估  $x_k$  与  $\hat{x}_k$  之间的差异。重建损失函数有助于确保生成的潜在表示能够尽可能准确地保留原始数据的细节信息,确保生成数据能够准确重建。

作为区分真实样本和生成样本的网络,鉴别器要求生成器生成的数据  $h'_k$  尽可能接近真实数据,并尽可能远

离生成数据,即  $\log h_k$  与  $\log(1 - h'_k)$  和越大,鉴别器效果越好。因此,无监督损失的损失函数为:

$$L_U = E_{M, x_1: k-p} [\log(y_M) + \sum_k \log(y_k)] + E_{M, x_1: k-p} [\log(1 - \tilde{y}_M) + \sum_k \log(1 - \tilde{y}_k)] \quad (7)$$

式中:  $E_{M, x_1: k-p}$  表示从真实数据分布中抽取样本  $x$  的期望;  $p$  表示真实数据的分布;  $\tilde{p}$  表示由生成器生成的数据的分布。对于来自真实数据分布  $p$  的  $M$  和  $x_1: k, y_M$  和  $y_k$  分别表示鉴别器评估这些样本为真实的概率;相反,对于来自生成数据分布  $\tilde{p}$  的  $M$  和  $x_1: k, \tilde{y}_M$  和  $\tilde{y}_k$  分别表示鉴别器评估这些样本为假的概率。无监督损失  $L_U$  的目标是通过最大化鉴别器能够正确区分真实与生成样本的概率和最大化生成样本被错误地判断为真实的概率,来提升生成器和鉴别器的性能。

仅仅依靠鉴别器的二元对抗性反馈可能不足以激励生成器捕获数据中的逐步条件分布。为了更有效地实现这一目标,我们使用监督损失通过直接比较生成器生成的潜在表示和真实数据的潜在表示,确保生成器能够学习到时间序列数据的时间依赖性,如式(8)所示。

$$L_S = E_{M, x_1: k-p} [\sum_k \|h_k - f_G^k(h_M, h_{k-1}, z_k)\|_2] \quad (8)$$

对于损失函数的优化,设  $\theta_e, \theta_r, \theta_g, \theta_d$  分别表示嵌入网络、恢复网络、生成网络和鉴别网络的参数优化。恢复网络和嵌入网络主要是建立一个潜在空间,对抗网络对潜在空间中的样本进行判别。然后,  $\theta_g$  使生成数据的特征尽可能接近真实数据。学习过程的目的是优化时间序列生成对抗网络中的模型参数  $\theta_e, \theta_r, \theta_g, \theta_d$ 。其中  $\theta_e, \theta_r$  是在重建和监督损失上进行训练的,公式如式(9)所示。

$$\min_{\theta_e, \theta_r} (\lambda L_S + L_R) \quad (9)$$

$\theta_g, \theta_d$  的目的是使鉴别器中真实样本与生成样本之间的距离最大化,而生成器生成的样本与真实样本之间的距离最小。因此,构造式(10)来优化鉴别器和生成器网络。

$$\min_{\theta_e, \theta_r} (\lambda L_S + L_R) \quad (10)$$

其中,  $\lambda, \eta \geq 0$  是时间序列生成对抗网络中的超参数。

## 2 时间序列生成对抗网络生成数据流程与评价

数据生成的原理是通过时间序列生成对抗网络学习样本数据集的近似密度分布,并通过输入随机噪声,使模型学习如何将随机噪声转换为符合真实数据分布的样本,从而生成新的数据集。随后,利用 LSTM 对生成的数据进行预测验证;采用不同的误差公式计算预测误差,以验证生成退化数据的有效性。整体数据生成流程如图 2 所示。

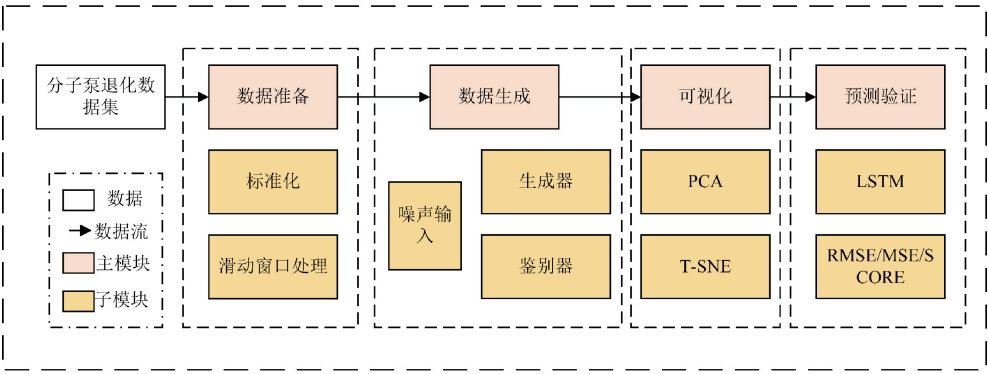


图 2 数据生成流程

Fig. 2 Data generation process

其中 LSTM 网络是循环神经网络一种变体。它通过引入门控机制解决了传统 RNN 的梯度消失和梯度爆炸问题。LSTM 可以有效地学习长期依赖关系,使其在处理时间序列数据时具有显著优势。使用 LSTM 网络对生成的数据进行预测,具体网络参数如表 1 所示。

表 1 本文所用网络参数

网络	超参数	值	激活函数
时间序列生成对抗网络	优化器	Adam	Sigmoid
	滑动时间窗口	24	
	迭代次数	1 000	
	批量大小	32	
	层数	3	
	隐藏维度	9	Sigmoid
	生成网络 1	GRU	
	鉴别网络 1	GRU	
	生成网络 2	LSTM	
	鉴别网络 2	LSTM	
LSTM	生成网络 3	Transformer	Tanh
	鉴别网络 3	Transformer	
	LSTM 层	3	
	全连接层	3	ReLU
	损失函数	MAE	
	输出	1	
	优化器	Adam	

对于预测效果的评价,使用均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE)、分数 (Score),表达式如 (11) ~ (13) 所示。

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

(11)

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

(12)

$$Score = \begin{cases} \sum_1^N \left( \exp \left( \frac{y_i - \hat{y}_i}{13} \right) - 1 \right), y_i \leq \hat{y}_i \\ \sum_1^N \left( \exp \left( \frac{y_i - \hat{y}_i}{10} \right) - 1 \right), y_i \geq \hat{y}_i \end{cases}$$

(13)

式中:  $\hat{y}_i$  为预测值;  $y_i$  为真实值;  $N$  为样本总数。

3 实验结果及分析

基于 TGAN-Transformer 生成数据集,网络结构使用表 1 参数构建。生成器和鉴别器分别采用门控循环单元(gated recurrent unit, GRU)、LSTM 和 Transformer 进行构建。对原始数据集和生成数据集进行了 T-SNE<sup>[21]</sup> (T-distributed stochastic neighbor embedding) 和主成分分析<sup>[22]</sup> (principal component analysis, PCA)。其中,PCA 通过线性变换将原始数据转换到新的坐标系统中,这些新坐标按照方差递减的顺序排列。PCA 有助于描述数据中的线性关系和总体结构。

另一方面,T-SNE 适用于高维数据的可视化,在低维空间中对高维数据的相似性进行建模,擅长保持局部数据结构。通过 T-SNE 分析,可以更好地描述数据中的聚类和群组关系,并直观地展示生成样本与原始样本在二维空间中的分布差异。

不同方法生成数据的 T-SNE 和 PCA 对比结果分别如图 3 所示,其中蓝色散点为样本数据,红色散点为生成数据。由图 3(a)、(c)、(e) 可以看出,使用 Transformer 生成的数据更加集中且更接近于原始数据的分布。这表明 Transformer 生成的数据在高维空间中的局部结构与真实数据相似。而 LSTM 与 GRU 生成的数据生成的数据分布较为分散,与原始数据的相似度较低。由图 3(b)、(d)、(f) 可以看出,Transformer 生成的数据在主成分空间中的分布与真实数据更加接近,这表明 Transformer 生成的数据在全局特征上与真实数据相似。通过 T-SNE 和

PCA 分析,可以直观地看出 Transformer 生成的数据在分布上更接近实际样本数据。表明 Transformer 生成的数据

在预测性能上具有显著优势。

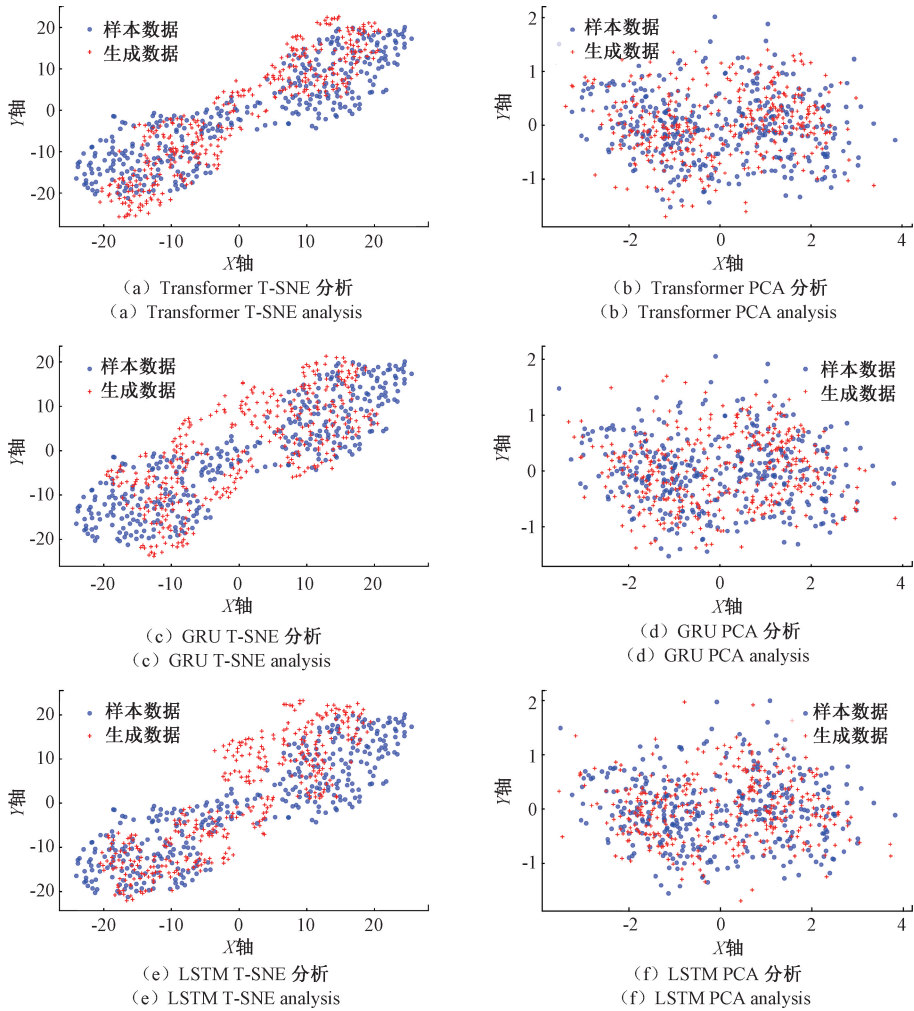


图 3 基于不同生成器网络的时间序列生成对抗网络的可视化比较

Fig. 3 Visual comparison of Time series generative adversarial network based on different generator networks

通过设置超参数(表 1),使用提出的算法对时间序列生成对抗网络进行训练,可以得到损失函数的收敛结果,如图 4 所示。由图 4 可以看出,随着迭代次数的增加,生成器和鉴别器的损失函数逐渐收敛,表明网络训练过程取得了良好的效果。图 4 中蓝色线表示无监督损失,橙色线表示监督损失,而绿色线则表示重建损失。可以看到,各类损失在训练过程中逐渐减小,最终趋于稳定,说明 TGAN-Transformer 模型训练成功。

为了验证生成数据的实际使用效果,通过结合生成数据与样本数据作为训练集,通过设置超参数(表 1),训练 LSTM 预测模型,并使用验证集进行验证,预测效果如图 5 所示,红色线表示噪声添加威布尔分布生成数据的预测结果,浅蓝色实线表示噪声添加高斯分布生成数据的预测结果,蓝色实线代表真实的剩余寿命。可以看出,威布尔分布生成的数据预测曲线更接近真实的剩余寿




图 4 TGAN-Transformer 的损耗结果

Fig. 4 Loss results of TGAN Transformer

命,且在退化后半段,预测精度显著更高。这表明威布尔分布能够更准确地捕捉分子泵的退化过程。而高斯分布预测曲线与真实剩余寿命的差距较大,尤其是在退化后

半段。这验证了添加威布尔分布在分子泵退化数据生成上的优越性。

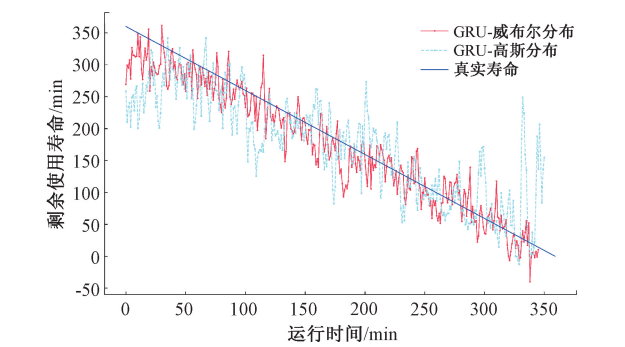


图5 使用高斯分布与威布尔分布生成数据预测效果对比

Fig. 5 Generate a comparison chart of data prediction performance using Gaussian distribution and Weibull distribution

表2为两者的评价指标对比。结果表明,噪声添加威布尔分布生成的数据预测结果在RMSE和MAE上均有提升。并且在 $t$ 检验上, $p<0.05$ ,因此将噪声分布改为威布尔分布可以显著提高分子泵退化数据集的预测效果。

生成器与鉴别器分别使用GRU、LSTM和Transformer的预测效果实验对比如图6所示。其中,红色线表示生成器与鉴别器使用Transformer的预测结果,

浅蓝色实线表示使用GRU的预测结果,棕色实线表示使用LSTM的预测结果。从图6可以看出,红色线更接近真实寿命,这表明Transformer生成的数据能够更好地捕捉分子泵的退化过程;验证了TGAN-Transformer的有效性。




图6 时间序列生成对抗网络使用不同生成器生成数据预测效果对比

Fig. 6 Comparison chart of data prediction performance generated by Time series generative adversarial network using different generators

进一步地,在表2的预测评价指标中,生成器与鉴别器使用Transformer的RMSE和MAE均达到了最优结果。与其他3种方法相比,TGAN-Transformer在RMSE上分别提高了82%、43%和55%。

表2 不同生成方法的预测误差比较结果

Table 2 Comparison results of prediction errors for different generation methods					
生成方法	噪声分布	RMSE	MAE	Score	$t$ 检验 (与生成器为Transformer对比)
GRU	高斯分布	0.122	0.087	2.75	$t=12.602\ 572\ p=2.352\ 912\times10^{-36}<0.05$
GRU		0.096	0.071	2.266	$t=-12.162\ 256\ p=5.580\ 356\times10^{-34}<0.05$
LSTM	威布尔分布	0.104	0.072	2.23	$t=-11.303\ 96\ p=1.374\ 817\times10^{-29}<0.05$
Transformer		0.067	0.048	2.8	

最后,利用LSTM网络分别预测了利用深度卷积生成对抗网络(deep convolutional generative adversarial networks, DCGAN)、GAN、递归条件生成对抗网络(recurrent conditional GAN,RCGAN)网络以及VAE、条件变分自编码器(conditional variational autoencoder, CVAE)网络,以及TGAN-Transformer生成数据的预测实验对比。预测结果如图7所示。可以明显看出,的预测结果更接近实际数据,证明了TGAN-Transformer的优越性。

为验证TGAN-Transformer的有效性,基于式(11)~(13)的预测误差对比结果如表3所示。本文方法的RMSE和MAE均达到了最优结果。与GAN、DCGAN、RCGAN、VAE、CVAE相比,TGAN-Transformer在RMSE指标上分别提高了51%、48%、36%、40%、30%;在MAE指标上,分别提升52%、49%、38%、42%、33%。

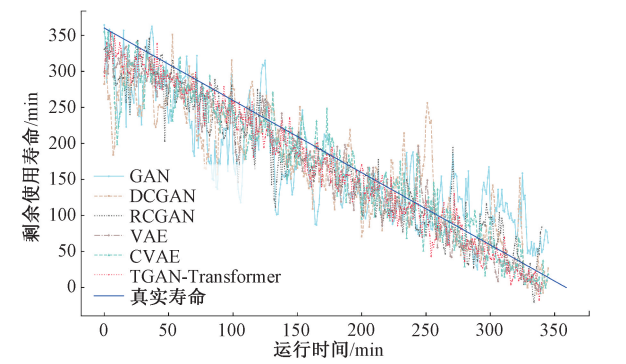


图7 TGAN-Transformer与其他GAN网络生成数据预测效果对比

Fig. 7 Comparison of data prediction performance between TGAN Transformer and other GAN networks



表 3 不同生成方法的预测误差比较结果  
Table 3 Comparison results of prediction errors  
for different generation methods

生成方法	噪声分布	RMSE	MAE	Score
GAN	威布尔分布	0.138	0.099	3.07
DCGAN	威布尔分布	0.129	0.094	2.97
RCGAN	威布尔分布	0.104	0.077	2.47
VAE	威布尔分布	0.111	0.083	2.51
CVAE	威布尔分布	0.096	0.072	2.64
TGAN-Transformer	威布尔分布	0.067	0.048	2.8

实验证明 TGAN-Transformer 生成的退化数据更接近实际退化过程,有效地扩展了数据集,并且可以通过 LSTM 网络准确地学习分子泵的退化过程。

4 结 论

本文通过深入研究分子泵退化数据生成及预测问题,提出了一种创新的 TGAN 与 Transformer 相结合的方法——TGAN-Transformer。面对分子泵退化数据有限且难以获取的现状,本文旨在通过生成高质量的退化数据来扩充数据集,进而提高退化预测模型的准确性和可靠性,确保 EAST 装置的安全运行。为此,研究创新性地将 Transformer 网络引入时间序列生成对抗网络,利用其多头注意力机制高效捕捉时间序列中的局部和长期依赖关系,生成更贴近实际退化过程的数据。同时,引入威布尔分布改变噪声分布,准确描述分子泵的非线性退化过程,使生成数据更贴合实际失效情况。此外,采用 LSTM 对生成数据进行预测,充分发挥其处理时间序列数据时学习长期依赖关系的优势,有效提升预测可靠性。研究的难点在于如何平衡生成数据的质量、多样性和计算效率,同时准确捕捉分子泵退化过程的独特特征。为此,本文不仅在生成对抗网络中引入了 Transformer,还通过引入威布尔分布优化了噪声分布,确保生成的数据在时间尺度和退化模式上与实际数据高度一致。实验结果表明, TGAN-Transformer 在 RMSE 和 MAE 等评价指标上表现出色,显著提升了退化预测的准确性和可靠性,为分子泵的可靠性分析和安全运行提供了有力支持。更重要的是,本文研究为其他工业设备的寿命预测提供了新的思路和技术参考,展示了生成对抗网络在时间序列数据生成领域的广阔应用前景。未来的研究将进一步优化生成网络结构,探索更多生成对抗网络的变种,以提高生成数据的多样性和真实性,从而进一步提升退化预测的准确性和可靠性。此外,还将探讨如何将生成的数据应用于更多的实际场景,例如故障诊断和预防性维护,为工业设备的安全运行提供更加全面的支持。同时,研究也将继

续深入挖掘 Transformer 和其他深度学习技术在时间序列数据分析中的潜力,推动相关领域的发展。总之,本文研究不仅解决了当前分子泵退化预测中的难题,也为未来的研究奠定了坚实的基础,具有重要的理论和实践意义。

参考文献

[ 1 ] YUAN X L, KAI J, CHEN Y, et al. A support vector machine framework for fault detection in Molecular pump[J]. Journal of Nuclear Science and Technology, 2023, 60(1): 72-82.

[ 2 ] ZHOU Y, JIANG M, YUAN X L, et al. Fault prediction of molecular pump based on DE-Bi-LSTM [ J ]. Fusion Science and Technology, 2024, 80(8): 1001-1011.

[ 3 ] LEI Y, LI N, GUO L, et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction [ J ]. Mechanical Systems and Signal Processing, 2018, 104: 799-834.

[ 4 ] 车鲁阳, 高军伟, 付惠琛. 基于多通道融合的滚动轴承剩余寿命预测 [ J ]. 电子测量与仪器学报, 2023, 37(12): 225-233.

CHE L Y, GAO J W, FU H CH. Residual life prediction of rolling bearings based on multi-channel fusion [ C ]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 225-233.

[ 5 ] DING Y, JIA M. Convolutional Transformer: An enhanced attention mechanism architecture for remaining useful life estimation of bearings [ J ]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-10.

[ 6 ] HE J W, ZHANG X, ZHANG X CH, et al. Remaining useful life prediction for bearing based on automatic feature combination extraction and residual multi-head attention GRU network [ J ]. Measurement Science and Technology, 2023, 35(3): 036003.

[ 7 ] 郭敏, 张浩. 基于改进 Bi-LSTM 网络下的多时变状态锂电池剩余寿命预测方法 [ J ]. 国外电子测量技术, 2023, 42(10): 59-68.

GUO M, ZHANG H. A method for predicting the remaining lifespan of lithium batteries with multiple time-varying states based on an improved Bi-LSTM network [ J ]. Foreign Electronic Measurement Technology, 2023, 42(10): 59-68.

[ 8 ] 陈维兴, 常东润, 李宗帅. 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 [ J ]. 电子测量与仪器学报, 2023, 37(3): 211-221.

CHEN W X, CHANG D R, LI Z SH. Residual life prediction method for aircraft engines using improved generative adversarial networks and ConvLSTM [ J ]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 211-221.



- [9] 李川, 伍依凡, 杨帅. 不平衡分布的数据驱动故障诊断的研究进展[J]. 仪器仪表学报, 2023, 44(8): 181-197.
- LI CH, WU Y F, YANG SH. Research progress on data-driven fault diagnosis of imbalanced distribution [J]. Chinese Journal of Scientific Instrument, 2023, 44(8): 181-197.
- [10] 宁云志, 宁静, 李艳萍, 等. 基于数据不平衡下的高速列车小幅蛇行预测方法[J]. 电子测量技术, 2022, 45(6): 149-154.
- NING Y ZH, NING N, LI Y P, et al. A small snake prediction method for high-speed trains based on data imbalance [J]. Electronic Measurement Technology, 2022, 45(6): 149-154.
- [11] JI H K, MIRZAEI M, LAI S H, et al. Implementing generative adversarial network (GAN) as a data-driven multi-site stochastic weather generator for flood frequency estimation [J]. Environmental Modelling & Software, 2024, 172: 105896.
- [12] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [13] ZHENG T, SONG L, WANG J, et al. Data synthesis using dual discriminator conditional generative adversarial networks for imbalanced fault diagnosis of rolling bearings [J]. Measurement, 2020, 158: 107741.
- [14] TAKAHASHI S, CHEN Y, TANAKA-ISHII K. Modeling financial time-series with generative adversarial networks[J]. Physica A: Statistical Mechanics and Its Applications, 2019, 527: 121261.
- [15] ESTEBAN C, HYLAND S L, RÄTSCH G. Real-valued ( medical ) time series generation with recurrent conditional gans [ J ]. ArXiv preprint arXiv: 1706.02633, 2017.
- [16] ZHANG X, QIN Y, YUEN C, et al. Time-series regeneration with convolutional recurrent generative adversarial network for remaining useful life estimation[J]. IEEE Transactions on Industrial Informatics, 2020, 17(10): 6820-6831.
- [17] YOON J, JARRETT D, VAN DER SCHAAR M. Time-series generative adversarial networks[C]. Advances in Neural Information Processing Systems, 2019.
- [18] ZHAO X, ZHANG Y, LI H. An attention-based improved GAN for time series data generation [ J ].

Journal of Advanced Data Science and Analytics, 2022, 15(3): 123-135.

- [19] LI M, WANG J, CHEN Q. VAE-GAN hybrid architecture for time series data generation [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 22(4): 567-578.
- [20] WANG Y, LIU Z, ZHANG X. Hierarchical GAN for time series data generation and its application in industrial equipment monitoring [J]. International Journal of Intelligent Systems, 2023, 30(2): 345-356.
- [21] ARORA S, HU W, KOTHARI P K. An analysis of the t-SNE algorithm for data visualization[C]. Conference on Learning Theory, 2018: 1455-1462.
- [22] VERBANCK M, JOSSE J, HUSSON F. Regularised PCA to denoise and visualise data [J]. Statistics and Computing, 2015, 25(2): 471-486.

## 作者简介



**柏受军** (通信作者), 现为安徽工程大学副教授, 硕士生导师, 主要从事智能检测技术和智能制造控制系统方面的教学和研究。

E-mail: baishoujun@ahpu.edu.cn

**Bai Shoujun** (Corresponding author) is now an associate professor and M. Sc. supervisor at Anhui University of Engineering. His main research interests include intelligent detection technology and intelligent manufacturing control systems.



**成志新**, 现为安徽工程大学硕士研究生, 主要研究方向为真空设备的寿命预测。

E-mail: 1277128628@qq.com

**Cheng Zhixin** now is a M. Sc. candidate at Anhui University of Engineering. His main research interest includes the life prediction of vacuum equipment.



**袁啸林**, 2018年于中国科学技术大学获得博士学位, 主要研究方向为磁约束聚变装置真空系统、系统故障诊断及预测性维护。

E-mail: xlyuan@ipp.ac.cn

**Yuan Xiaolin** received his Ph. D. degree from University of Science and Technology of China in 2018. His main research interests include vacuum system of magnetic confinement fusion device and system fault diagnosis and predictive maintenance.