

DOI: 10.19650/j.cnki.cjsi.J2514400

设备多通道振动信号缺失数据改进扩散模型插补和故障诊断应用*

乔心航, 何清波

(上海交通大学机械与动力工程学院 上海 200240)

摘要: 针对旋转设备多通道振动信号在实际采集过程中因传感器故障、通信中断或环境干扰等原因易出现数据缺失, 从而导致故障诊断精度下降的问题, 故提出一种面向缺失数据插补的改进扩散模型方法。该方法构建了一种基于掩码机制的多尺度条件扩散模型, 以去噪扩散概率模型为基础, 引入已观测数据作为条件信息, 指导缺失数据的逐步生成过程, 并对多通道振动信号的联合分布进行整体建模, 从而有效刻画通道之间的相关性。在模型结构设计方面, 采用 U-Net 作为骨干网络, 在编码器和解码器中堆叠多尺度卷积残差块和线性注意力模块, 以增强模型对振动信号时序依赖关系和多尺度特征的提取能力, 提高缺失数据插补的准确性和稳定性。通过在轴承和齿轮箱多通道振动数据集上开展随机点缺失和随机块缺失两种典型缺失场景下的对比实验。结果表明, 在不同缺失率条件下, 所提方法在均方根误差 (RMSE)、平均绝对误差 (MAE) 和对称平均绝对百分比误差 (SMAPE) 等指标上均优于多种传统方法和现有深度学习插补模型, 且插补后信号在时域和频域特征上与原始信号保持更高一致性。进一步将插补后的数据用于故障诊断任务, 在轴承和齿轮数据集上的分类精度分别达到 95.85% 和 94.85%, 验证了所提方法在提升多通道振动信号数据质量和保障故障诊断性能方面的有效性。

关键词: 设备; 多通道振动信号; 数据插补; 扩散模型; 故障诊断

中图分类号: TH133.3 TH132.4 **文献标识码:** A **国家标准学科分类代码:** 460.40

Missing data imputation by an improved diffusion model for multi-channel vibration signals of machinery and its application in fault diagnosis

Qiao Xinhang, He Qingbo

(School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: Missing data often occur in multi-channel vibration signals of rotating machinery due to sensor faults, communication interruptions, or environmental disturbances, which can degrade the performance of fault diagnosis models. To address this issue, this paper proposes an improved diffusion-model-based method for missing data imputation. A masked multi-scale conditional diffusion model is developed based on denoising diffusion probabilistic models, where observed data are incorporated as conditional information to guide the stepwise generation of missing values. The joint distribution of multi-channel vibration signals is modeled to effectively capture inter-channel correlations. Regarding network architecture, a U-Net backbone is employed, with multi-scale convolutional residual blocks and linear attention modules stacked in both the encoder and decoder. This design enhances the extraction of temporal dependencies and multi-scale features of vibration signals, improving the accuracy and stability of missing data imputation. Comparative experiments are conducted on bearing and gearbox multi-channel vibration datasets under random point missingness and random block missingness scenarios. The results demonstrate that, across different missing rates, the proposed method outperforms traditional imputation methods and existing deep learning models in terms of root mean square error (RMSE), mean absolute error (MAE), and symmetric mean absolute percentage error (SMAPE). Moreover, the imputed signals preserve temporal and frequency domain characteristics that are closer to the original signals. When applied to fault diagnosis tasks, the classification accuracies reach 95.85% and 94.85% on the bearing and gearbox datasets, respectively, validating the effectiveness of the proposed method in improving multi-channel vibration signal quality and ensuring reliable fault diagnosis performance.

Keywords: machinery; multi-channel vibration signals; data imputation; diffusion model; fault diagnosis

收稿日期: 2025-08-20 Received Date: 2025-08-20

* 基金项目: 上海市市级科技重大专项资助的课题项目 (2025KJB-QT-071501-6)、国家自然科学基金项目 (52275116) 资助

0 引言

旋转设备作为现代工业生产中的核心装备,其运行状态直接关系到生产系统的安全性与可靠性^[1]。轴承、齿轮等关键部件在长期承受交变应力和恶劣工况环境下,极易发生性能劣化甚至失效^[2]。研究表明,这类故障若未能及时诊断,可能引发连锁反应,导致严重的安全事故和重大经济损失^[3]。因此,开展针对旋转设备关键部件的智能故障诊断研究,对保障设备安全运行、降低维护成本具有重要意义^[4]。

基于振动信号分析的故障诊断技术被认为是最有效的预测性维护方法^[5]。通过在旋转设备关键部位部署多传感器监测网络,可以构建多通道时间序列(multi-channel time series, MTS)监测系统,从而更全面地捕捉设备的动态运行特性^[6]。与单通道时间序列相比,MTS能够揭示不同测点间的耦合关系及其潜在的物理关联,为深度故障诊断提供了更丰富的信息维度^[7]。然而,在实际工业场景中,受传感器故障、数据传输中断、环境干扰等因素影响,采集的MTS数据往往存在部分或连续缺失^[8]。这种数据缺失不仅破坏了时间序列的完整性和连续性,还会严重影响后续故障诊断模型的性能,导致特征提取失真、分类精度下降,甚至产生误诊^[9]。因此,在进行故障诊断前,如何对缺失的MTS数据进行高质量插补,恢复信号的原始动态特征,已成为亟待解决的关键问题。

传统的插补方法主要基于统计学原理,如均值填充、最近邻插补等^[10]。随后发展的机器学习方法,如K近邻(K-nearest neighbors, KNN)、矩阵分解等在一定程度上提升了插补性能^[11]。然而,这些方法在捕捉MTS数据中复杂的非线性时序依赖和变量间相互关系方面仍存在局限。近年来,深度学习的快速发展为解决多变量时间序列插补问题提供了新的思路。基于深度学习的插补方法能够自动学习数据中的时空依赖关系,生成更符合实际分布的插补值。根据处理机制的不同,现有方法可分为预测式和生成式两大类^[12]。

预测式方法将插补视为回归问题,主要包括基于循环神经网络(recurrent neural network, RNN)和注意力机制的模型。Che等^[13]在门控循环单元的基础上引入衰减机制来利用缺失模式对缺失值进行估计,Cao等^[14]基于RNN模型提出了双向循环时间序列插补网络(bidirectional recurrent imputation for time series, BRITS),采用双向RNN和可微重插补过程提升精度。然而,RNN类模型在处理长序列时固有的梯度消失或爆炸问题,以及其串行计算的特性,限制了其捕捉长期依赖的能力和训练效率^[15]。基于注意力机制的模型如基于自注意力

的时间序列插补方法(self-attention-based imputation for time series, SAITS)^[16]、ImputeFormer^[17],虽能有效捕捉长期依赖且可以并行计算,但其二次计算复杂度限制了在长序列中的应用。

生成式方法通过建模数据分布进行采样插补,主要包括变分自编码器(variational autoencoder, VAE)、生成对抗网络(generative adversarial network, GAN)和扩散模型(diffusion model, DM)。基于变分自编码器的方法通过编码器-解码器结构学习数据的潜在表示。Fortuin等^[18]在变分自编码器的潜在空间中引入高斯过程先验以捕捉时间序列的动态特性。但是变分自编码器在生成高质量样本方面表现通常不如生成对抗网络或者扩散模型。基于生成对抗网络的方法,通过一个生成器和一个判别器的对抗性博弈,来学习真实数据的分布并生成以假乱真的样本^[19]。Yoon等^[20]提出生成对抗插补网络(generative adversarial imputation nets, GAIN),在GAN框架中为判别器引入“提示矩阵”,使其能够关注特定位置的插补质量,从而提升了插补效果。尽管GAN在生成逼真数据方面表现出色,但其训练过程极不稳定,容易出现模式崩溃问题,且对超参数设置敏感,这给实际应用带来了困难^[21]。

近年来,扩散模型在生成任务中展现出卓越性能^[22-23],其通过前向加噪和反向去噪过程稳定地建模复杂分布。Tashiro等^[24]提出基于条件分数的扩散模型(conditional score-based diffusion models for probabilistic time series imputation, CSDI),将已观测到的数据点作为条件,来指导反向去噪过程,从而对缺失部分进行概率性插补。Zhou等^[25]在扩散模型中引入相邻窗口的相互一致性损失,在捕捉变量间相关性和生成与真实数据分布一致的插补值方面表现优异。但是,当前基于扩散模型的时间序列插补大多应用于医疗、金融等领域,将其应用于旋转设备振动信号插补任务的研究仍较少。与医疗金融等领域的信号不同,振动信号通常包含瞬态冲击和周期性成分^[26],具有很强的随机性,另外其采样频率较高、采样点数较多、序列较长,实现高质量插补的难度较大。扩散模型通过逐步建模数据的整体概率分布,在反向去噪过程中能够有效刻画振动信号中复杂的非线性结构和随机特性,从而弥补传统插补方法捕捉非线性时序依赖不足的问题。相比生成对抗网络等生成式模型,扩散模型在训练过程中更加稳定,不易出现模式崩溃现象,且对超参数的敏感性较低,更适合高采样率、长序列振动信号的建模与插补任务。

基于上述分析,本文提出一种改进的扩散模型,设计了一种基于掩码的多尺度条件扩散模型,充分利用扩散模型在复杂振动信号建模与插补的优势。同时在U-Net网络架构中堆叠多尺度卷积残差块和线性注意力模块以

提升网络特征提取能力。通过在 CWRU 轴承数据集和齿轮箱试验数据集上的实验验证,证实了所提方法的有效性和优越性。

1 相关工作

1.1 扩散模型

去噪扩散概率模型(denoising diffusion probabilistic models, DDPM)^[22]是扩散模型中最具代表性和影响力的模型之一。其核心思想源于对物理扩散过程的模拟。它包含两个关键过程:前向加噪过程和反向去噪过程。

前向加噪过程是一个固定的、无需学习的马尔可夫链。它在 T 个时间步内,逐步地向原始清晰数据 \mathbf{x}_0 中添加高斯噪声,直至数据完全退化为服从标准高斯分布 $N(0, \mathbf{I})$ 的纯噪声。任意时刻 t 的加噪数据 \mathbf{x}_t 可以通过 \mathbf{x}_0 直接计算得出,如式(1)所示。

$$q(\mathbf{x}_t | \mathbf{x}_0) = N(\mathbf{x}_t; \sqrt{\bar{\alpha}_t} \mathbf{x}_0, (1 - \bar{\alpha}_t) \mathbf{I}) \quad (1)$$

其中, $\bar{\alpha}_t$ 是预先设定的噪声调度系数,控制了在规定时间内步 t 的噪声水平。

反向去噪过程是模型的核心学习部分。它从纯噪声 \mathbf{x}_T 出发,学习一个神经网络 ϵ_θ 来预测前向加噪过程中添加的噪声,从采样数据中逐步减去预测的噪声,最终重构出符合原始数据分布的清晰数据。在每个时间步 t ,该网络 $\epsilon_\theta(\mathbf{x}_t, t)$ 的任务是预测在前向过程中添加到 \mathbf{x}_t 中的噪声 ϵ_t 。模型的训练目标是 minimized 预测噪声与真实噪声之间的均方误差,其损失函数定义如式(2)所示。

$$L = E_{\mathbf{x}_0, \epsilon_t} [\| \epsilon_t - \epsilon_\theta(\mathbf{x}_t, t) \|^2] \quad (2)$$

通过优化这个损失函数,模型能够学习到从任意噪声水平的数据中恢复出清晰数据的能力,从而实现高质量的数据生成。

1.2 掩码机制

掩码机制的核心思想是构建一个与原始数据维度一致的二元掩码张量 $\mathbf{M} \in \{0, 1\}^{N \times D}$ 。对于长度为 N 、维度为 D 的多通道时间序列 $\mathbf{X}_0 \in \mathbb{R}^{N \times D}$ 。当掩码矩阵的元素 $M_{n,d} = 1$ 时,表示在长度 n ,通道 d 处的值是已观测的。当掩码矩阵的元素 $M_{n,d} = 0$ 时,表示在长度 n ,通道 d 处的值是缺失的。

基于掩码矩阵 \mathbf{M} ,可将完整数据 \mathbf{X}_0 分解为观测部分与缺失部分的互补组合,如式(3)和(4)所示。

$$\mathbf{X}_{\text{obs}} = \mathbf{X}_0 \odot \mathbf{M} \quad (3)$$

$$\mathbf{X}_{\text{miss}} = \mathbf{X}_0 \odot (1 - \mathbf{M}) \quad (4)$$

其中, \mathbf{X}_{obs} 表示已观测部分, \mathbf{X}_{miss} 表示缺失部分, \odot 表示逐元素乘法。 \mathbf{X}_{miss} 是利用扩散模型进行数据插补的目标。 \mathbf{X}_{obs} 可以作为条件信息引导扩散模型进行数据插补。通过引入掩码机制,能够为扩散模型提供条件信

息,为后续数据插补任务的完成奠定基础。

2 基于掩码的多尺度条件扩散模型

2.1 条件扩散模型原理

标准的 DDPM 是一个无条件的生成模型,它从纯噪声中生成随机样本。然而,在缺失数据插补任务中,缺失数据并非随机生成,而是要根据已有的观测数据来生成与之匹配的缺失数据。因此,需要将 DDPM 改造为一个条件生成模型,利用掩码机制引入观测数据作为生成过程的引导条件。

在模型前向过程中,与标准 DDPM 不同,噪声仅被逐步添加到数据的缺失部分。利用 1.2 节中定义的掩码矩阵 \mathbf{M} ,在任意时间步 t ,噪声化的缺失部分 $\mathbf{X}_t^{\text{miss}}$ 可由原始缺失部分 $\mathbf{X}_0^{\text{miss}}$ 计算,如式(5)所示。

$$\mathbf{X}_t^{\text{miss}} = \sqrt{\bar{\alpha}_t} \mathbf{X}_0^{\text{miss}} + \sqrt{1 - \bar{\alpha}_t} (\epsilon \odot (1 - \mathbf{M})) \quad (5)$$

其中, ϵ 是标准高斯噪声。

在反向去噪过程中,目标是训练一个神经网络 $\epsilon_\theta(\mathbf{X}_t^{\text{miss}}, t, \mathbf{X}_{\text{obs}}, \mathbf{M})$,使其根据噪声化的数据 $\mathbf{X}_t^{\text{miss}}$ 、时间步 t 、已观测数据 \mathbf{X}_{obs} 和掩码 \mathbf{M} ,预测前向过程中添加的噪声 ϵ_t 。模型的损失函数定义如式(6)所示。

$$L = E_{\mathbf{x}_0, \epsilon_t} [\| \epsilon_t - \epsilon_\theta(\mathbf{X}_t^{\text{miss}}, t, \mathbf{X}_{\text{obs}}, \mathbf{M}) \|^2] \quad (6)$$

通过最小化该损失函数,模型逐步学习在观测数据约束下,准确重建符合原始数据分布的缺失值。这种条件化设计既保留了 DDPM 的生成优势,又实现了针对缺失数据插补任务的定向优化。

需要指出的是,本文在扩散建模过程中并未将各通道振动信号视为相互独立的变量,而是对多通道振动信号的联合分布进行整体建模。使得模型在训练过程中能够同时学习时间维度上的依赖关系以及不同测点之间的统计相关性。

2.2 模型网络结构

为满足上述条件化去噪任务的需求,设计了基于 U-Net 架构的噪声预测网络 $\epsilon_\theta(\mathbf{X}_t^{\text{miss}}, t, \mathbf{X}_{\text{obs}}, \mathbf{M})$,其整体结构如图 1 所示。该网络采用编码器-解码器架构,并引入跨层连接机制。在输入处理方面,网络通过通道维度拼接的方式整合加噪数据 \mathbf{X}_t 、观测条件数据 \mathbf{X}_{obs} 以及掩码矩阵 \mathbf{M} ,构建多通道输入张量,以确保模型能够充分感知噪声水平、观测数据的数值及其位置信息。同时这种输入方式使得网络在特征提取过程中能够同时感知不同通道振动信号的变化趋势,从而在卷积和注意力计算过程中自适应地建模通道间的相关性,而非对各通道进行独立插补。此外,通过正弦位置编码和多层感知机对扩散时间步 t 进行嵌入处理,生成的时间步嵌入向量将与 U-Net 各残差块的特征融合。

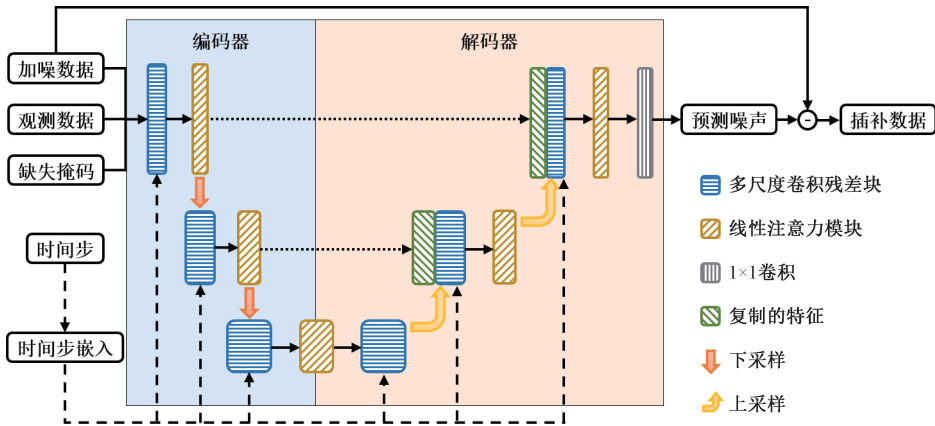


图 1 模型网络结构

Fig. 1 Network structure of the model

编码器部分由多级下采样模块构成,用于逐层提取特征并逐步压缩序列长度。每个下采样模块包含:1)多尺度卷积残差块;2)线性注意力模块;3)步长为 2 的卷积下采样层。在网络的瓶颈层,利用两个多尺度卷积残差块和一个线性注意力模块来捕捉深层特征信息。

解码器部分采用与编码器对称的结构设计,通过跨层连接机制融合编码器各层级的特征图,有效保留了低层次细节信息。每个上采样模块依次包含:1)特征拼接层;2)多尺度卷积残差块;3)线性注意力模块;4)转置卷积上采样层。最终,解码器输出的特征图经过末端残差块和卷积层的处理后,生成与原始信号维度一致的预测噪声 ϵ_θ 。

多尺度卷积残差块详细结构如图 2 所示。




图 2 多尺度卷积残差块

Fig. 2 Multi-scale convolutional residual block

该模块采用并行多分支结构,通过设置卷积核尺寸分别为 3×3 、 5×5 和 7×7 的 3 个并行卷积层,实现不同感受野下的多尺度特征提取。各分支输出的特征图在通道维度进行拼接,形成具有丰富尺度信息的宽特征图。随后,通过 1×1 卷积层实现跨通道信息融合与维度调整,并采用 RMSNorm 归一化层和 SiLU 激活函数进行非线性变换。该模块采用双重堆叠结构,将两个相同的多尺度处理单元进行串联并引入残差连接来避免深层网络中的梯度消失问题。多尺度卷积残差块通过不同感受野的并行

卷积操作,不仅能够捕捉单通道信号在不同时间尺度上的特征,还能够在通道维度上实现特征融合,有助于挖掘多通道振动信号之间的耦合关系。

线性注意力模块详细结构如图 3 所示。




图 3 线性注意力模块

Fig. 3 Linear attention module

首先对输入信号 X 并行依次计算 1×1 卷积和 3×1 卷积得到 Q, K, V 矩阵。之后通过 ReLU 函数解耦注意力计算,计算过程如式 (7) 所示。

$$\text{Attention}(Q, K, V) = \text{ReLU}(Q) (\text{ReLU}(K))^T V \quad (7)$$

其中, $\text{ReLU}(Q) = \max(0, Q)$, $\text{ReLU}(K) = \max(0, K)$ 。通过先计算 $(\text{ReLU}(K))^T V$, 将键和值矩阵的交互提前完成,生成一个与序列长度无关的中间表示,从而实现线性复杂度。最终,注意力输出经过缩放投影层和残差连接,与原始输入 X 相加,生成模块输出。通过引入线性注意力模块,能够让模型自动聚焦较为重要的特征,使模型在插补过程中更加关注与缺失位置高度相关的通道特征。

2.3 模型训练与插补流程

训练过程遵循扩散模型训练流程,利用未损坏的数据生成噪声化输入,通过多尺度条件扩散模型预测噪声并优化模型参数。模型训练的目标是优化噪声预测网络 ϵ_θ , 使其能够准确预测噪声化输入中的噪声分量。训练过程从未损坏的数据集中采样数据,生成随机缺失掩码,构造噪声化输入,并在每一时间步通过损失函数优化模型参数。模型训练算法如算法 1 所示。

算法 1: 模型训练

输入 训练数据集 D , 扩散总步数 T , 训练轮数 E_{\max}

- 1 初始化模型参数 θ
- 2 循环: 对于 $epoch = 1$ 到 E_{\max} , 执行以下步骤:
- 3 从 D 中随机采样一批原始数据 X_0
- 4 生成随机缺失掩码矩阵 M
- 5 计算观测数据 $X_{\text{obs}} \leftarrow X_0 \odot M$
- 6 随机采样时间步 $t \sim \text{Uniform}(1, \dots, T)$
- 7 随机采样高斯噪声 $\epsilon \sim N(0, I)$
- 8 计算噪声化的缺失部分 $X_t^{\text{miss}} \leftarrow \sqrt{\alpha_t}(X_0 \odot (1 - M)) + \sqrt{1 - \alpha_t}(\epsilon \odot (1 - M))$
- 9 计算损失 $L = E_{X_0, \epsilon, t} [\| \epsilon_t - \epsilon_{\theta}(X_t^{\text{miss}}, t, X_{\text{obs}}, M) \|^2]$
- 10 根据损失 L 更新模型参数 θ
- 11 结束循环
- 12 输出训练好的噪声预测网络 ϵ_{θ}

当模型训练完成后,即可进行数据插补。插补过程是一个反向去噪的迭代采样过程,针对数据缺失部分,从一个完全随机的高斯噪声 X_T^{imp} 开始,逐步利用训练好的噪声预测网络 ϵ_{θ} 预测并去除噪声,直至恢复出清晰的数据 $X_0^{\text{imp}}, X_0^{\text{imp}}$ 即为缺失位置的插补数据。缺失数据插补算法如算法 2 所示。

算法 2: 缺失数据插补

输入 训练好的噪声预测网络 ϵ_{θ} , 已观测数据 X_{obs} , 掩码矩阵 M , 总扩散步数 T

- 1 从标准高斯分布中采样初始噪声 $\epsilon \sim N(0, I)$
- 2 构造初始噪声输入数据 $X_T^{\text{imp}} \leftarrow \epsilon \odot (1 - M)$
- 3 循环: 对于 $t = T$ 到 1, 执行以下步骤:
- 4 采样随机噪声 $z \sim N(0, I)$, 如果 $t = 1$ 则 $z = 0$
- 5 用模型预测噪声 $\epsilon_{\text{pred}} \leftarrow \epsilon_{\theta}(X_t^{\text{miss}}, t, X_{\text{obs}}, M)$
- 6 计算前一步 X_{t-1} 的均值

$$\mu_{\text{pred}}(X_t, t) \leftarrow \frac{1}{\sqrt{\alpha_t}} \left(X_t - \frac{\beta_t}{\sqrt{1 - \alpha_t}} \epsilon_{\text{pred}} \right)$$

- 7 采样生成前一步数据 $X_{t-1}^{\text{imp}} \leftarrow \mu_{\text{pred}}(X_t, t) + \sqrt{\beta_t} z$
- 8 结束循环
- 9 输出插补后的数据 X_0^{imp}

3 多通道振动信号缺失实验与分析

3.1 多通道信号缺失情况模拟及插补质量评价

为了检验模型在不同数据缺失场景下的鲁棒性和有效性,模拟了两种典型的多通道时间序列数据缺失模式,

分别是随机块缺失和随机点缺失。其中,随机块缺失模拟所有通道的信号在某一段连续时间内同时丢失,如同设备短暂断电或通讯中断。通过设置不同的缺失率(20%、40%、60%、80%)来控制连续缺失片段的长度。这种模式旨在评估模型利用时间相关性来进行缺失数据插补的能力。随机点缺失模拟传感器信号中出现零星、间歇性的数据丢包或损坏,每个通道的数据点都以一定的概率随机独立地被置为缺失。同样设置不同的缺失率(20%、40%、60%、80%),以模拟不同程度的信号干扰。这种模式旨在评估模型综合利用时间相关性和通道相关性进行时间序列插补的性能。通过在多样化的缺失模拟场景下进行实验,可以更可靠地评估模型在各种复杂条件下的插补性能。

为客观、定量地评估模型的插补质量,采用了3个在时间序列插补领域被广泛使用的评价指标:均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)和对称平均绝对百分比误差(symmetric mean absolute percentage error, SMAPE)。评价指标的计算公式如式(8)所示。

$$\begin{cases} RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \\ MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \\ SMAPE = \frac{100\%}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{|y_i| + |\hat{y}_i| + \varepsilon} \end{cases} \quad (8)$$

其中,真实值为 y_i , 模型插补值为 \hat{y}_i , 缺失数据点的数量为 N , 为了避免 SMAPE 除 0 错误,分母引入 $\varepsilon = 10^{-4}$ 。这3个指标越低,证明插补质量越高。

振动信号的时域和频域特征是传统故障诊断任务的基础,保证插补后信号的时域和频域特征与插补前尽量一致有重要意义,因此额外设置 $T_1 \sim T_6$ 这6个时域指标和 $F_1 \sim F_6$ 这6个频域指标,计算公式如式(9)和(10)所示。

$$\begin{cases} T_1 = \frac{1}{N} \sum_{i=1}^N x_i \\ T_2 = \left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|} \right)^2 \\ T_3 = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \\ T_4 = \frac{1}{N} \sum_{i=1}^N |x_i| \\ T_5 = \frac{T_3}{T_4} \\ T_6 = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - T_1}{T_3} \right)^3 \end{cases} \quad (9)$$

$$\left. \begin{aligned}
 F_1 &= \frac{1}{N} \sum_{i=1}^N y_i \\
 F_2 &= \sum_{i=1}^N (y_i - F_1)^2 \\
 F_3 &= \frac{\sum_{i=1}^N (y_i - F_1)^3}{N \times \sqrt{F_2^3}} \\
 F_4 &= \frac{\sum_{i=1}^N (y_i - F_1)^4}{N \times F_2^2} \\
 F_5 &= \frac{\sum_{i=1}^N f_i y_i}{\sum_{i=1}^N y_i} \\
 F_6 &= \sqrt{\frac{\sum_{i=1}^N [(f_i - F_5)^2 \cdot y_i]}{N}}
 \end{aligned} \right\} \quad (10)$$

其中, N 为信号点数, i 为信号索引, x 为时间序列, y 为频域幅值序列, f 为频率序列。

3.2 轴承数据缺失下故障诊断

1) 数据集介绍

CWRU (Case Western Reserve University) 轴承数据集是由美国凯斯西储大学轴承数据中心发布的滚动轴承故障数据集。其实验台结构如图 4 所示, 通过在电机壳体的驱动端、风扇端和基座安装加速度传感器, 来采集轴承在不同状态下的振动信号。




图 4 CWRU 轴承实验台

Fig. 4 CWRU bearing test rig

实验数据涵盖了 4 种轴承健康状态: 正常状态以及 3 种不同位置的单点故障状态, 分别是内圈故障、外圈故障和滚动体故障。所有故障均通过电火花加工技术人为植入, 并设置了 0.007、0.014 和 0.021 英寸等不同程度的损伤直径。数据采集覆盖了从 0~3 马力的 4 种不同电机负载, 对应的转速范围为 1 730~1 797 rpm。

在本实验中, 为模拟多振动传感器监测的场景, 选取了采样频率为 12 kHz、2 马力负载情况下的驱动端、风扇端

和基座的 9 种不同故障位置和故障程度的振动信号, 由于健康样本缺少基座加速度传感器数据, 在本实验中将其剔除。将原始信号划分为 300 个样本, 长度为 1 024, 维度为 3, 其中 100 个样本用于缺失数据插补任务训练, 100 个样本用于缺失数据插补任务测试, 并将这 100 个样本插补结果用于故障诊断分类任务训练, 剩余的 100 个样本用于故障诊断分类任务测试。数据集详细设置如表 1 所示。

表 1 CWRU 数据集设置
Table 1 CWRU dataset settings

故障类型	故障大小 / 英寸	样本量 / 个			标签
		插补训练	插补测试	分类测试	
内圈故障	0.007	100	100	100	1
	0.014	100	100	100	2
	0.021	100	100	100	3
外圈故障	0.007	100	100	100	4
	0.014	100	100	100	5
	0.021	100	100	100	6
滚动体故障	0.007	100	100	100	7
	0.014	100	100	100	8
	0.021	100	100	100	9

2) 多通道振动信号相关性分析

多通道振动信号来源于设备不同测点, 在设备运行过程中, 各测点往往受到相同系统动力学特性的影响, 因此在频谱结构上会具有一定的相关性。为定量分析 CWRU 轴承数据集中不同测点振动信号之间的相关关系, 采用 Pearson 相关系数对多通道信号进行分析。

以 CWRU 数据集中滚动体故障 (故障尺寸 0.014 英寸) 信号为例, 对各通道信号进行 FFT 计算得到频谱, 计算各通道频谱 Pearson 相关关系, 绘制热力图如图 5 所示。

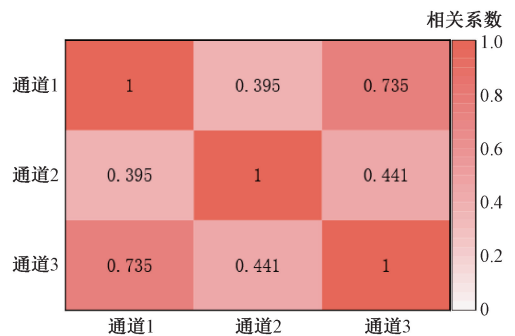


图 5 各通道相关系数

Fig. 5 Correlation coefficients of each channel

结果表明, 不同通道之间具有一定的相关性, 尤其是通道 1 和通道 3, 这种相关性为多通道联合建模提供了依

据,也表明在缺失数据插补过程中,如果能有效利用通道间相关关系,将有助于提升插补精度。

3) 插补实验结果与分析

以 CWRU 数据集中滚动体故障(故障尺寸 0.014 英寸)信号为例,通过网格搜索方法确定模型主要超参数,超参数搜索结果如表 2 所示。

为验证模型的有效性,将本文模型和 4 种插补方法进行对比。选取 KNN 作为机器学习方法的代表^[27],选取 BRITS 作为长短时记忆网络的代表^[14],选取 GAIN 作为生成对抗网络的代表^[20],选取 CSDI 作为扩散模型的代表^[24]。上述方法及本文所提方法在各种缺失情况下的插补结果如表 3 所示。

为更直观地分析插补性能,对随机点缺失和随机块

表 2 模型超参数设置

Table 2 Model hyperparameter settings

超参数	值
U-Net 层数	3
U-Net 通道数	64
扩散时间步 T	1 000
训练批量大小	16
学习率	1×10^{-4}
训练步数	10 000
Adam 优化器参数	(0.9, 0.99)

缺失两种情形分别绘制误差变化曲线如图 6 所示,其中,随机点缺失情况下的结果如图 6(a)、(b)和(c)所示,随机块缺失情况下的结果如图 6(d)、(e)和(f)所示。

表 3 CWRU 数据集不同方法插补误差对比

Table 3 Comparison of imputation error of different methods on the CWRU dataset

缺失类型	缺失率/%	KNN			BRITS			GAIN			CSDI			本文方法		
		RMSE	MAE	SMAPE	RMSE	MAE	SMAPE	RMSE	MAE	SMAPE	RMSE	MAE	SMAPE	RMSE	MAE	SMAPE
随机点缺失	20	0.171 1	0.133 8	42.45	0.127 4	0.098 9	34.38	0.110 2	0.085 2	31.11	0.090 7	0.070 0	27.44	0.078 9	0.060 0	24.66
	40	0.197 2	0.154 7	46.94	0.148 1	0.114 9	38.04	0.133 9	0.103 5	35.49	0.122 6	0.095 2	33.82	0.102 0	0.079 0	29.76
	60	0.233 7	0.183 1	53.47	0.190 0	0.147 8	47.30	0.160 9	0.124 7	40.07	0.152 2	0.117 8	39.05	0.139 5	0.107 9	36.98
	80	0.283 6	0.222 3	59.75	0.248 7	0.193 9	55.19	0.213 7	0.165 9	48.13	0.205 9	0.159 1	47.58	0.190 3	0.146 8	45.58
随机块缺失	20	0.354 4	0.283 3	68.63	0.332 8	0.263 7	63.66	0.331 8	0.262 1	62.80	0.254 1	0.200 3	54.33	0.234 8	0.184 0	50.82
	40	0.365 9	0.290 9	68.17	0.370 7	0.294 0	66.83	0.359 7	0.284 0	65.73	0.312 2	0.245 4	61.41	0.247 1	0.193 1	53.80
	60	0.360 2	0.286 0	68.58	0.368 8	0.290 7	67.09	0.367 3	0.289 0	66.40	0.332 1	0.259 9	63.57	0.266 0	0.207 1	56.21
	80	0.370 9	0.294 6	69.30	0.364 6	0.287 4	67.01	0.372 1	0.293 2	67.18	0.341 7	0.267 9	64.85	0.300 3	0.232 7	59.92

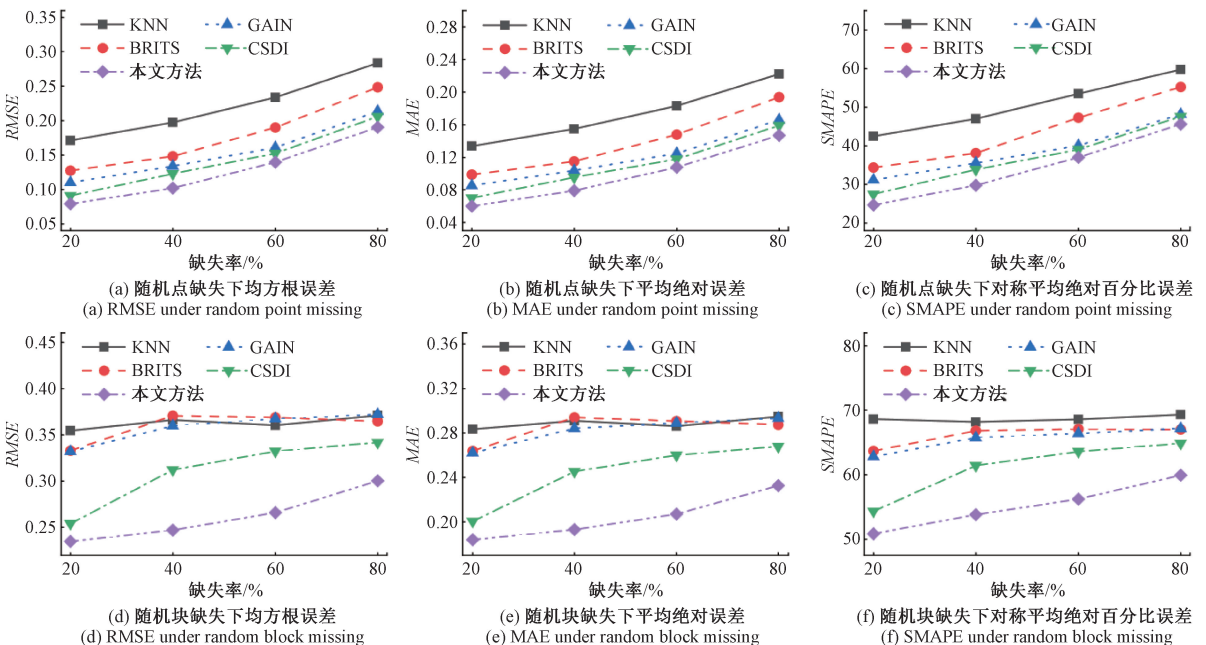


图 6 不同缺失情况下插补结果对比

Fig. 6 Comparison of imputation results under different missing data patterns

可以看出,随着缺失率的增加,不同模型插补的误差也在不断增大,这是由于观测值的减少导致可以利用的信息减少,模型需要利用更少的信息做出更多的推测,因此误差也会不断增大。相同缺失率的情况下随机点缺失的插补误差小于随机块缺失的插补误差,这是因为随机点缺失时可以利用周围时间点数据以及其他通道数据重建缺失点数据,而随机块缺失由于在一个时间段内所有的通道数据都缺失,数据插补难度较大。

在所有对比方法中,基于 KNN 的方法插补精度最差,这是由于其插补只利用临近点数据,不能很好地学习到数据的分布。基于深度学习的方法展现出了较好的插补精度,BRITS 能够捕捉数据的长期依赖关系,但是对于振动信号这种长序列信号的处理能力稍显不足。生成式方法可以学习到数据的复杂分布,插补结果更加接近真实数据分布。基于扩散模型的方法在所有对比方法中取得了最好的效果,验证了扩散模型在振动信号缺失数据

插补任务中的优越性。尤其是在随机块缺失的情况下,KNN、BRITS 和 GAIN 方法插补质量均较差,而基于扩散模型的方法在该情况下有不错的表现。在相同缺失情况下,本文提出模型的误差相比其他模型的误差更小,说明提出的模型能够更好地拟合数据分布,从而对缺失数据进行高质量插补。

4) 故障诊断结果与分析

信号的时域和频域特征对于故障诊断任务有重要意义,因此进一步研究不同模型插补后信号和原始信号的时域和频域特征差异。以 CWRU 数据集中滚动体故障(故障尺寸 0.014 英寸)随机点缺失 40% 信号为例,根据表 1 公式,分别计算未缺失原始信号以及不同模型插补后信号的时域和频域特征,结果如表 4 所示。可以看出,本文方法相比于其他模型插补后的信号时域和频域特征与原始信号更加接近,从而证明了提出方法更能够还原故障诊断任务需要的统计特征。

表 4 插补信号时域和频域特征对比

Table 4 Comparison of time domain and frequency domain features of interpolated signals

信号特征	T_1/g	T_2/g	T_3/g	T_4/g	T_5	T_6	F_1/g	F_2/g^2	F_3	F_4	F_5/Hz	F_6/Hz
原始信号	-0.027 1	0.157 3	0.245 8	0.188 5	1.310 3	0.075 8	4.178 8	54.967 0	6.214 1	75.516 0	2 394. 6	1 312. 2
KNN	-0.037 7	0.148 9	0.231 6	0.178 3	1.301 9	0.044 4	5.177 2	36.373 0	6.745 8	89.365 0	2 713. 1	1 600. 1
BRITS	-0.028 8	0.141 7	0.221 4	0.169 6	1.310 5	0.084 8	3.986 7	43.761 0	6.940 3	89.028 0	2 498. 8	1 437. 8
GAIN	-0.021 9	0.159 0	0.245 7	0.190 0	1.296 4	0.065 1	5.181 6	44.435 0	6.538 9	82.626 0	2 614. 1	1 547. 9
CSDI	-0.028 0	0.155 6	0.241 6	0.186 1	1.303 2	0.041 9	4.453 8	50.693 0	6.726 2	86.019 0	2 503. 3	1 447. 1
本文方法	-0.026 6	0.155 2	0.242 5	0.186 0	1.310 0	0.069 2	4.108 8	53.779 0	6.313 8	77.047 0	2 410. 4	1 332. 0

在完成缺失数据插补实验之后,进一步评估了不同模型的插补结果对故障分类任务的影响。实验设置了 9 种故障类型如表 1 所示,以随机点缺失 40% 的情况为例进行分析。具体流程为:首先,利用训练好的模型对缺失数据进行插补,每种故障类型生成 100 个插补样本;随后,基于这些插补样本训练神经网络完成故障诊断分类任务,并通过分类精度比较不同模型的性能。该神经网络包含三层一维卷积层(输出通道分别为 16、32、64),每层后接 ReLU 激活和最大池化,特征经展平后通过两个全连接层(128 个神经元和 9 个输出类别)进行分类。为全面评估插补效果,实验中还引入了零填充和未缺失作为基准参考。

验证不同模型在随机点缺失 40% 情况下生成的插补数据在故障分类任务中的精度表现,故障诊断结果如图 7 所示。结果显示,零填充方法的诊断精度仅为 68.63%,而所有插补模型的精度均显著高于零填充,证明了数据插补对提升故障诊断性能的重要性。此外,插补质量与诊断精度呈正相关关系,即插补质量越高,诊断




图 7 不同模型故障诊断结果

Fig. 7 Fault diagnosis results of different models

精度也越高。值得注意的是,基于深度学习的方法的诊断精度均超过 90%,凸显了深度学习在数据插补任务中的优势。其中,本文提出的模型在所有对比模型中表现最优,其诊断精度最高,进一步验证了该模型在部分数据

点缺失场景下的优异插补效果及其对下游故障诊断任务的重要意义。

进一步绘制分类结果的可视化特征,不同模型的 t 分布随机邻域嵌入 (t-distributed stochastic neighbor

embedding, t-SNE) 图如图 8 所示。图 8 中可见,本文模型生成的插补数据在特征空间中具有更清晰的类别边界,也从侧面表明其插补结果更接近真实数据的分布特性。

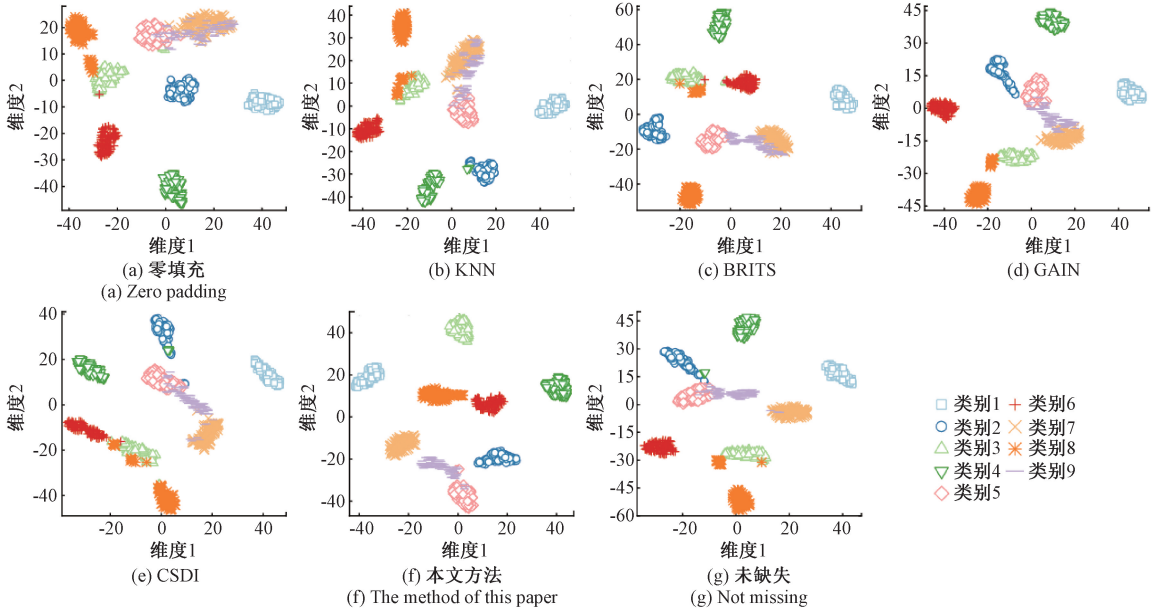


图 8 不同模型分类的 t-SNE 图

Fig. 8 t-SNE of different model classifications

本文提出模型在不同缺失情况下的故障诊断结果如表 5 所示,可以看出随着缺失率的增加,故障诊断精度逐渐下降,在缺失率为 20%、40%、60% 的情况下,本文提出模型故障诊断精度均保持在 90% 以上,在缺失率为 80% 的极端缺失情况下,也保持了较高的诊断精度,显示出提出模型插补后数据用于故障诊断的鲁棒性。

在随机点缺失 40% 的情况下,首先利用上述不同模型对缺失数据进行插补,然后将插补后的数据用于故障诊断分类任务,通过分类精度对比各模型性能。消融实验结果如表 6 所示。

表 5 不同缺失情况下故障诊断结果

Table 5 Fault diagnosis results of different missing data patterns (%)

指标	缺失率(随机点缺失)				缺失率(随机块缺失)			
	20	40	60	80	20	40	60	80
精度	95.74	95.58	93.86	88.69	94.60	93.33	91.01	89.12

表 6 消融实验结果

Table 6 Results of ablation experiments

模型	精度/%
模型 1	91.32
模型 2	93.77
模型 3	90.62
本文方法	95.58

5) 消融实验

为进一步验证本文提出模型中多尺度卷积残差块和线性注意力模块对故障诊断任务的贡献,在 CWRU 轴承数据集上设计了消融实验。消融实验共设置 4 种模型结构,分别是:将多尺度卷积残差块替换成单尺度的模型(模型 1)、去除线性注意力机制的模型(模型 2)、同时将多尺度卷积残差块替换为单尺度并去除线性注意力模块的模型(模型 3)、完整保留多尺度卷积残差块和线性注意力模块的模型(本文方法)。

从实验结果可以看出,将多尺度卷积残差块替换为单尺度后,故障诊断精度出现明显下降,表明多尺度卷积对于复杂振动信号的特征提取有重要作用。当去除线性注意力模块时,模型性能同样出现下降,原因是注意力机制在多通道振动信号中能够自适应地突出与缺失位置高度相关的特征。进一步地,当同时移除多尺度结构和线性注意力模块时,模型性能下降最为明显,验证了上述两个模块在模型中的互补性和必要性。完整模型在故障诊断精度上取得了最优性能,说明多尺度卷积残差块与线性注

意力模块的协同作用能够有效提升插补数据质量进而提升故障诊断精度。

3.3 齿轮数据缺失下故障诊断

1) 数据集介绍

本实验采用的齿轮箱故障诊断测试平台如图 9 所示。该平台由控制器、电机、加速度传感器、齿轮箱及磁粉制动器组成,可实现齿轮的故障模拟与信号采集。



图 9 齿轮箱故障测试台
Fig. 9 Gearbox fault test rig

为全面监测齿轮箱振动特性,在箱体表面布置 3 个三轴加速度传感器,共计 9 个测量通道。实验针对平行轴齿轮副设置了 6 种故障类型,包括:健康、点蚀、间隔磨损、裂纹、全齿磨损、缺齿。实验在转速 3 000 rpm 和负载 10 N·m 条件下进行,采样频率为 10 kHz。按 1 024 个采样点的长度划分样本,每种故障类型各得到 300 个样本。每个样本包含 9 维特征,最终构建的详细数据集如表 7 所示。

2) 多通道振动信号相关性分析

齿轮箱振动信号由多个测点和多个方向的传感器同时采集。为分析齿轮箱多通道振动信号之间的相关关系,以裂纹故障信号为例,对 9 个测量通道的振动信号计算频域 Pearson 相关系数,结果如图 10 所示。结果表明,不同通道之间有较强的相关性,进一步验证了利用多通

表 7 齿轮箱数据集设置

Table 7 Gearbox dataset settings

故障类型	样本量/个			标签
	插补训练	插补测试	分类测试	
健康	100	100	100	0
点蚀	100	100	100	1
间隔磨损	100	100	100	2
裂纹	100	100	100	3
全齿磨损	100	100	100	4
缺齿	100	100	100	5




图 10 各通道相关系数

Fig. 10 Correlation coefficients of each channel

道联合建模对于缺失数据插补的合理性。

3) 插补实验结果与分析

为验证模型的泛化性能,本文在齿轮箱数据集上对比了所提模型与其他方法的性能差异。以裂纹故障信号为例,分别针对随机点缺失和随机块缺失两种模式,设置 20%、40%、60% 和 80% 4 种缺失率进行实验,插补实验结果如表 8 所示。不同缺失情况下插补结果对比如图 11 所示。

表 8 齿轮箱数据集不同方法插补误差对比

Table 8 Comparison of imputation error of different methods on the gearbox dataset

缺失类型	缺失率/%	KNN			BRITS			GAIN			CSDI			本文方法		
		RMSE	MAE	SMAPE	RMSE	MAE	SMAPE	RMSE	MAE	SMAPE	RMSE	MAE	SMAPE	RMSE	MAE	SMAPE
随机点缺失	20	0.154 1	0.121 9	39.91	0.127 1	0.100 5	34.81	0.110 2	0.087 2	31.57	0.093 9	0.074 2	27.78	0.081 9	0.064 5	24.78
	40	0.173 4	0.137 2	43.18	0.141 4	0.111 7	37.42	0.124 6	0.098 3	34.39	0.113 0	0.088 8	31.75	0.107 2	0.084 6	30.16
	60	0.207 9	0.164 5	49.29	0.167 7	0.132 6	42.30	0.151 9	0.119 9	39.52	0.141 9	0.112 9	37.09	0.134 2	0.105 8	35.14
	80	0.258 9	0.205 7	56.52	0.236 0	0.186 6	53.88	0.202 4	0.160 6	48.41	0.189 4	0.149 4	45.54	0.171 3	0.135 1	41.28
随机块缺失	20	0.366 8	0.292 0	65.24	0.338 6	0.268 9	60.47	0.305 2	0.242 0	57.41	0.272 5	0.215 9	54.38	0.260 3	0.206 2	51.91
	40	0.391 0	0.311 6	67.88	0.385 0	0.305 0	65.38	0.359 4	0.284 0	64.06	0.346 6	0.273 1	62.98	0.337 9	0.265 8	62.09
	60	0.396 8	0.315 8	68.91	0.393 8	0.312 5	67.04	0.383 8	0.303 4	66.28	0.363 7	0.287 2	64.9	0.350 3	0.276 3	63.38
	80	0.386 1	0.307 7	69.57	0.394 9	0.313 2	67.83	0.384 4	0.303 9	67.22	0.373 3	0.295 0	66.63	0.360 7	0.284 4	64.81

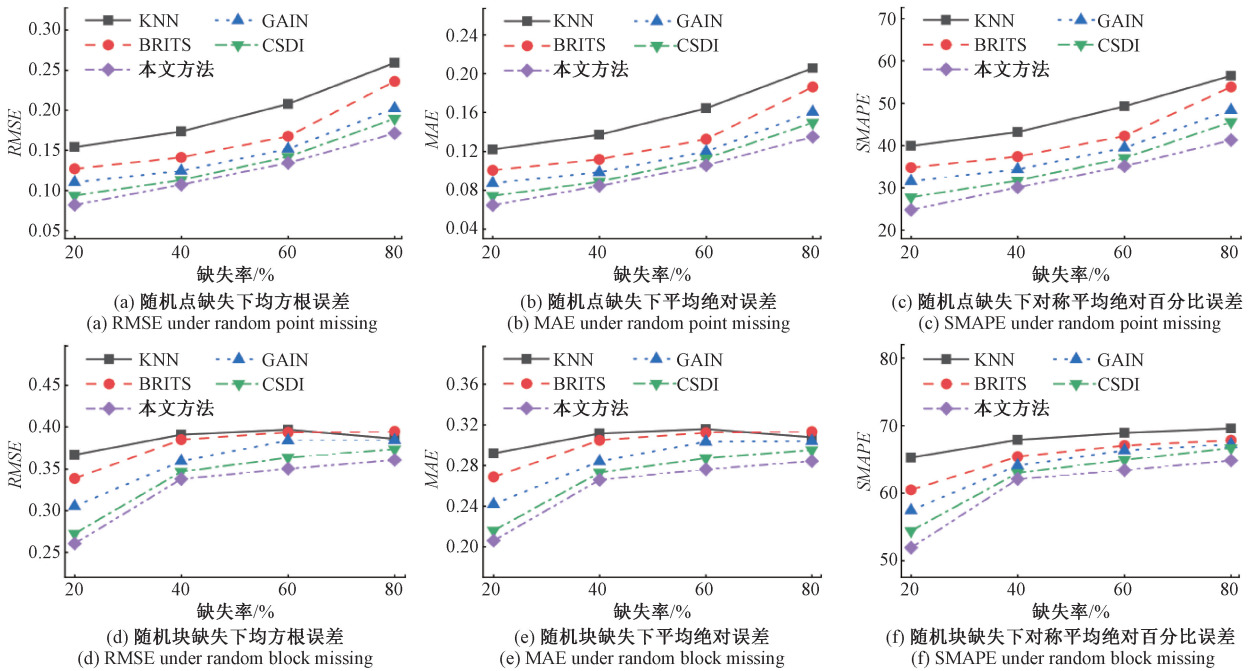


图 11 不同缺失情况下插补结果对比

Fig. 11 Comparison of imputation results under different missing data patterns

其中随机点缺失情况下的插补结果如图 11(a)、(b)和(c)所示,随机块缺失情况下的插补结果如图 11(d)、(e)和(f)所示。

实验结果显示:在随机点缺失情况下,各模型的插补误差均较 CWRU 数据集有所降低。这一现象可归因于该齿轮箱数据集具有更高的维度,使得模型在部分数据点缺失时能够充分利用多通道间的相关性信息进行更准确的插补。特别是在高缺失率条件下,插补误差的下降幅度更为明显。

然而,在随机块缺失场景下,实验结果呈现出相反的趋势:各模型的插补误差较 CWRU 数据集普遍升高。分析认为,这是由于高维数据在块缺失时会出现多通道同时缺失的情况,模型需要同时重建 9 个维度的数据,插补难度显著增加,从而导致误差上升。值得注意的是,尽管

在不同数据集上存在性能差异,但各模型的性能排序与 CWRU 数据集保持一致。具体表现为:基于深度学习的方法优于传统 KNN 方法;而基于扩散模型的方法则展现出更优的性能。特别地,本文提出的模型在所有对比方法中取得了最优的插补精度,其 RMSE、MAE 和 SMAPE 指标均低于其他方法,验证了模型在不同数据集上的先进性和稳定性。

4) 故障诊断结果与分析

以齿轮箱数据集中裂纹故障随机块缺失 40% 信号为例,分别计算未缺失原始信号以及不同模型插补后信号的时域和频域特征,结果如表 9 所示。可以看出,本文方法相比于其他模型插补后的信号时域和频域特征与原始信号更加接近,进一步验证了提出方法能够还原故障诊断任务需要的统计特征。

表 9 插补信号时域和频域特征对比

Table 9 Comparison of time domain and frequency domain features of interpolated signals

信号特征	T_1/g	T_2/g	T_3/g	T_4/g	T_5	T_6	F_1/g	F_2/g^2	F_3	F_4	F_5/Hz	F_6/Hz
原始信号	-0.036 7	0.207 6	0.311 2	0.246 4	1.264 2	0.100 0	5.171 0	79.685 0	6.423 1	57.830 0	2 147.6	1 231.1
KNN	-0.029 8	0.199 0	0.296 9	0.235 6	1.260 9	0.086 1	5.402 6	68.327 0	5.684 9	48.969 0	2 119.3	1 247.2
BRITS	-0.022 8	0.212 5	0.316 9	0.251 7	1.259 8	0.127 4	5.377 2	81.144 0	6.120 4	53.131 0	2 125.6	1 245.8
GAIN	-0.023 8	0.210 0	0.313 0	0.249 3	1.262 5	0.094 3	5.275 1	77.147 0	6.130 4	54.966 0	2 142.4	1 244.8
CSDI	-0.030 3	0.204 5	0.307 0	0.243 0	1.263 9	0.106 4	5.126 1	77.332 0	6.205 0	54.068 0	2 144.8	1 243.7
本文方法	-0.032 8	0.204 9	0.307 9	0.244 1	1.264 0	0.104 6	5.130 4	79.253 0	6.233 4	55.795 0	2 148.7	1 241.4

研究不同模型的插补数据对故障诊断任务的影响,以随机块缺失 40% 的工况为例。针对 6 种故障类型的振动信号,分别采用各模型进行数据插补,每种故障类型生成 100 个插补样本,共计 600 个样本作为分类器的训练集,其中分类器设置与 CWRU 轴承数据集保持一致,并基于表 7 中的测试集评估分类性能,不同模型故障诊断结果和 t-SNE 图如图 12 和 13 所示。

分析实验结果,发现各模型故障诊断的相对精度排序和 CWRU 数据集保持一致。不同插补方法均能在一定程度上提升故障诊断的精度。零填充的分类精度较低,特征图混叠也较为严重。KNN 方法精度较零填充有不小提升,但是特征图也存在一定程度的混叠。基于深度学习的方法分类精度较高,特征图分类边界较为清晰。本文提出模型在 4 种对比方法中取得了最高的诊断精




图 12 不同模型故障诊断结果
Fig. 12 Fault diagnosis result of different models

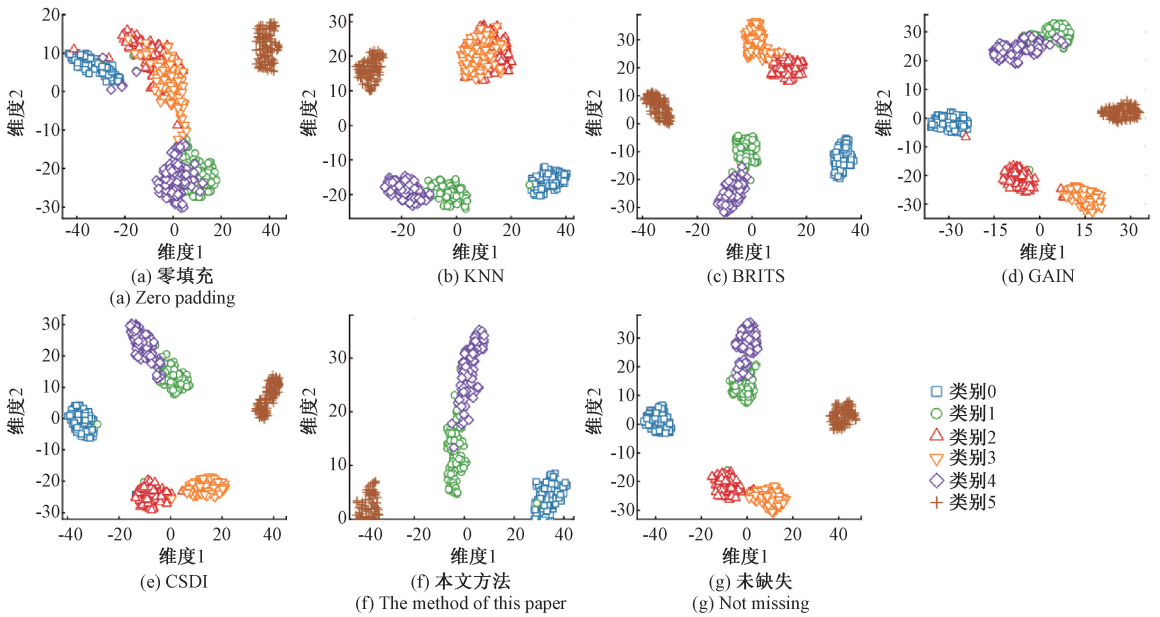


图 13 不同模型分类的 t-SNE 图
Fig. 13 t-SNE of different model classifications

本文提出模型在不同缺失情况下的故障诊断结果如表 10 所示,随着缺失率的上升,故障诊断精度也随之下降,但是在不同缺失情况下的故障诊断精度均达到了 90% 以上,验证了模型在不同数据集上的鲁棒性。

表 10 不同缺失情况下故障诊断结果

Table 10 Fault diagnosis results of different missing data patterns (%)

指标	缺失率(随机点缺失)				缺失率(随机块缺失)			
	20	40	60	80	20	40	60	80
精度	96.27	96.23	93.67	93.52	97.10	94.85	93.23	90.19

5) 消融实验
在齿轮箱数据集上开展消融实验。实验设置与 CWRU 轴承数据集保持一致,以随机块缺失 40% 数据为例,消融实验结果如表 11 所示。

表 11 消融实验结果

Table 11 Results of ablation experiments

模型	精度/%
模型 1	90.18
模型 2	93.29
模型 3	88.43
本文方法	94.85

从齿轮箱数据集的消融实验结果可以看出,各消融模型的性能排序与CWRU轴承数据集一致,但在随机块缺失场景下,多尺度卷积残差块和注意力模块被替换或者去除之后性能下降更为明显,原因是随机块缺失插补难度较大,对于网络的要求更高,多尺度卷积残差块和线性注意力模块能够有效提高对振动信号的特征提取能力,因此去掉或者替换掉对应的模块后网络性能有比较大的下降。消融实验结果也进一步验证了多尺度卷积残差块和线性注意力模块在齿轮箱振动信号插补上的有效性和泛化能力。

6) 变转速工况下效果验证

在实际工业应用中,旋转机械设备往往运行于变转速工况,变转速工况下振动信号会出现明显的非平稳特性,这对缺失数据插补模型的时序建模能力提出了更高的要求。为验证模型在变转速工况下的插补性能和插补后的信号用于故障诊断的效果,设计变转速实验,变转速范围设置为1 200~3 000 rpm,其他实验设置及参数和3.3节第1部分保持一致,按照表7设置数据集,数据缺失模式选取为随机点缺失40%,利用各个模型插补缺失数据,并用插补后的数据训练分类器完成故障诊断任务,故障诊断和插补结果如图14所示。其中柱状图表示故障诊断精度,折线图表示模型插补后数据的均方误差。




图14 变转速工况结果

Fig. 14 Results under variable-speed operating conditions

从实验结果可以看出,在变转速工况下,各对比方法的插补误差整体较恒定工况有所增加,表明工况变化确实会加大缺失数据插补任务的难度。这主要是由于变转速运行导致振动信号的时频特征随时间发生变化,削弱了信号在时间维度上的相关性,从而增加了模型对噪声分布建模的复杂度。尽管如此,所提出的模型在该工况下仍取得了相对较低的插补误差, RMSE 值优于对比的传统插补方法和深度学习模型,表明该模型在一定程度上具备对非平稳振动信号的建模能力。

进一步地,将插补后的振动信号输入故障诊断模型进行分类验证。可以观察到,基于本文方法插补后的数

据在故障识别准确率方面同样保持了优势,说明较高质量的数据插补有助于缓解信号缺失对故障诊断性能的负面影响。然而,与恒定工况实验结果相比,变转速条件下的诊断精度仍存在一定差距,表明当前模型在非平稳工况下的特征提取能力仍有进一步提升空间。

4 结 论

本文针对旋转设备多通道振动信号缺失数据插补问题,提出了一种基于掩码的多尺度条件扩散模型。在CWRU轴承数据集和齿轮箱试验数据集上验证了所提方法的有效性。主要结论为:

1) 通过对轴承数据集和齿轮箱数据集的多通道相关性分析,验证了不同测点振动信号之间的相关性,为多通道联合建模提供了依据。

2) 在多种缺失模式和不同缺失率条件下的插补实验结果表明,所提出的模型能够有效降低插补误差,其插补结果在时域和频域特征上均与原始信号保持较高一致性,优于多种传统方法和对比深度学习模型。

3) 将插补后的振动信号应用于故障诊断任务,实验结果表明,高质量的插补数据能够有效提升故障诊断精度。消融实验结果验证了多尺度卷积残差块和线性注意力模块在提升故障诊断精度方面的有效性。

尽管本文方法在多种实验场景中取得了较好的效果,但仍存在一定的局限性。一方面,模型对于非平稳工况的适应能力仍有待进一步提升;另一方面,模型训练依赖于完整无缺失的历史数据,而在实际工业环境中获取大量高质量完整数据仍具有一定难度。未来研究将结合更加复杂的变工况实验数据,对模型在非平稳场景下的适用性进行深入研究,并探索基于部分缺失数据的鲁棒训练策略,或引入迁移学习与领域自适应方法,以进一步提升模型在实际工程应用中的泛化能力和实用价值。

参考文献

- [1] 肖扬,王华庆,李华,等. 基于精细复合缩放多尺度加权排列熵的跨域故障诊断方法[J]. 机械工程学报, 2025, 61(16): 28-39.
- XIAO Y, WANG H Q, LI H, et al. Cross-domain fault diagnosis method based on refined composite multiscale weighted permutation entropy[J]. Journal of Mechanical Engineering, 2025, 61(16): 28-39.
- [2] LI Y, ZHANG L J, LIANG P F, et al. Semi-supervised meta-path space extended graph convolution network for intelligent fault diagnosis of rotating machinery under time-varying speeds[J]. Reliability Engineering & System Safety, 2024, 251: 110363.

- [3] SHI H F, MIAO Y H, LI CH H, et al. A novel bearing intelligent fault diagnosis method based on spectrum sparse deep deconvolution[J]. *Engineering Applications of Artificial Intelligence*, 2024, 133: 108102.
- [4] 李晔,杨京礼,高天宇,等. 基于个性化联邦域泛化框架的旋转机械故障诊断方法[J]. *仪器仪表学报*, 2025,46(8):75-86.
- LI Y, YANG J L, GAO T Y, et al. Rotating machinery fault diagnosis method based on personalized federated domain generalization framework[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(8): 75-86.
- [5] TAMA B A, VANIA M, LEE S, et al. Recent advances in the application of deep learning for fault diagnosis of rotating machinery using vibration signals[J]. *Artificial Intelligence Review*, 2023, 56(5): 4667-4709.
- [6] 栾孝驰,白天,赵俊豪,等. 多通道振动信号与滑油屑末信息融合的滚动轴承状态监控方法[J]. *仪器仪表学报*,2025,46(1):298-310.
- LUAN X CH, BAI T, ZHAO J H, et al. Condition monitoring method for rolling bearing based on multi-channel vibration signal and lubricating oil debris information fusion[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(1): 298-310.
- [7] XU X F, BAO SH, SHAO H D, et al. A multi-sensor fused incremental broad learning with D-S theory for online fault diagnosis of rotating machinery[J]. *Advanced Engineering Informatics*, 2024, 60: 102419.
- [8] 詹兆康,胡旭光,赵浩然,等. 基于多变量时空融合网络的风机数据缺失值插补研究[J]. *自动化学报*, 2024,50(6):1171-1184.
- ZHAN ZH K, HU X G, ZHAO H R, et al. Missing value imputation of wind turbine data based on multivariate spatial-temporal fusion network [J]. *Acta Automatica Sinica*, 2024, 50(6): 1171-1184.
- [9] YANG ZH Q, DONG H H, ZHANG H P, et al. Conditional time series diffusion model for high-speed train multi-sensor signals imputation [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2025, 26(8): 12518-12531.
- [10] 张晟斐,李天梅,胡昌华,等. 基于 WGAN 的多维数据生成方法及其在 RUL 预测中的应用[J]. *机械工程学报*,2025,61(16):70-82.
- ZHANG SH F, LI T M, HU CH H, et al. Multidimensional data generation method based on WGAN and its application in RUL prediction[J]. *Journal of Mechanical Engineering*, 2025, 61(16): 70-82.
- [11] FAIZIN R N, RIASETIWAN M, ASHARI A. A review of missing sensor data imputation methods[C]. 2019 5th International Conference on Science and Technology, 2019: 1-6.
- [12] WANG J, DU W J, YANG Y Y, et al. Deep learning for multivariate time series imputation: A survey[J]. *ArXiv preprint arXiv: 2402.04059*, 2025.
- [13] CHE ZH P, PURUSHOTHAM S, CHO K, et al. Recurrent neural networks for multivariate time series with missing values [J]. *Scientific Reports*, 2018, 8(1): 6085.
- [14] CAO W, WANG D, LI J, et al. BRITS: Bidirectional recurrent imputation for time series[J]. *ArXiv preprint arXiv:1805.10572*, 2018.
- [15] 邹筱瑜,胡亮,王福利,等. 基于信号分解深度网络的轴承剩余寿命预测[J]. *仪器仪表学报*,2024,45(8):45-57.
- ZOU X Y, HU L, WANG F L, et al. Bearing remaining useful life prediction based on signal decomposition deep network[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(8): 45-57.
- [16] DU W J, CÔTÉ D, LIU Y. SAITS: Self-attention-based imputation for time series [J]. *Expert Systems with Applications*, 2023, 219: 119619.
- [17] NIE T, QIN G Y, MA W, et al. ImputeFormer: Low rankness-induced transformers for generalizable spatio-temporal imputation[C]. 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 2024: 2260-2271.
- [18] FORTUIN V, BARANCHUK D, RÄTSCH G, et al. GP-VAE: Deep probabilistic multivariate time series imputation [J]. *ArXiv preprint arXiv: 1970.04155*, 2020.
- [19] 高学金,吴浩宁,高慧慧,等. 基于一致损失生成对抗网络的冷水机组故障诊断[J]. *仪器仪表学报*,2025,46(1):285-297.
- GAO X J, WU H N, GAO H H, et al. Fault diagnosis of chiller based on consistency loss generative adversarial network[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(1): 285-297.

- [20] YOON J, JORDON J, VAN DER SCHAAR M. GAIN: Missing data imputation using generative adversarial nets[C]. 35th International Conference on Machine Learning, 2018; 9042-9052.
- [21] WANG Y SH, XU X H, HU L, et al. A time series continuous missing values imputation method based on generative adversarial networks [J]. Knowledge-Based Systems, 2024, 283; 111215.
- [22] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models [J]. Arxiv preprint arXiv: 2006. 11239, 2020.
- [23] DHARIWAL P, NICHOL A. Diffusion models beat GANs on image synthesis [J]. Arxiv preprint arXiv: 2015. 05233, 2021.
- [24] TASHIRO Y, SONG J M, SONG Y, et al. CSDI: Conditional score-based diffusion models for probabilistic time series imputation [J]. Arxiv preprint arXiv: 2017. 03502, 2021.
- [25] ZHOU J P, LI J H, ZHENG G J, et al. MTSCI: A conditional diffusion model for multivariate time series consistent imputation[C]. 33th ACM International Conference on Information and Knowledge Management, 2024; 3474-3483.
- [26] RAI A, UPADHYAY S H. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings [J]. Tribology International, 2016, 96; 289-306.
- [27] PAN L Q, LI J ZH. K-nearest neighbor based missing data estimation algorithm in wireless sensor networks [J]. Wireless Sensor Network, 2010, 2(2): 115-122.

作者简介



乔心航, 2024年于上海交通大学获得学士学位, 现为上海交通大学硕士研究生, 主要研究方向为智能故障诊断与寿命预测。

E-mail: bertqiao@sjtu.edu.cn

Qiao Xinhang received his B. Sc. degree from Shanghai Jiao Tong University in 2024. He is currently a M. Sc. candidate at Shanghai Jiao Tong University. His main research interests include intelligent fault diagnosis and life prediction.



何清波(通信作者), 分别在2002年和2007年于中国科学技术大学获得学士学位和博士学位, 现为上海交通大学特聘教授、博士生导师, 主要研究方向为机械装备动态监测、故障诊断与智能运维。

E-mail: qbhe@sjtu.edu.cn

He Qingbo (Corresponding author) received his B. Sc. degree and Ph. D. degree both from University of Science and Technology of China in 2002 and 2007, respectively. He is currently a distinguished professor and Ph. D. advisor at Shanghai Jiao Tong University. His main research interests include dynamic monitoring, fault diagnosis and intelligent maintenance of mechanical equipments.