

基于 SC-FVAE-GAN 的不平衡轴承数据的故障诊断方法

杜杰宾¹ 荆晓远^{2*} 谢胜灵¹ 刘飞² 廖珂² 朱冠华²
 DU Jiebin JING Xiaoyuan XIE Shengling LIU Fei LIAO Ke ZHU Guanhua

摘要

当前不平衡轴承故障诊断领域内,为考虑时域与频域数据的重要性,实现了一种基于改进 VAE-GAN 网络的不平衡轴承故障数据的数据增强方法。为解决不平衡数据对故障诊断模型的影响,基于改进 VAE-GAN 模型进行数据增强:首先基于傅里叶变换原理提出 FVAE 作为生成器,并提出时域频域的并行鉴别器来判别生成器生成的数据是否真实,对 FVAE 网络进行对抗训练;最后对生成的数据利用无量纲统计特征形成箱线图进行约束以提高数据质量。采用 CNN-LSTM 网络将增强后的平衡轴承数据样本进行故障诊断。该框架经实验验证,生成的样本质量高,且相对于其他经典模型本文提出的故障诊断框架具有很好的准确性。

关键词

类不平衡;变分自编码器-生成对抗网络(VAE-GAN);数据增强;故障诊断;时频融合

doi: 10.3969/j.issn.1672-9528.2025.05.041

0 引言

滚动轴承是大型机组机器中不可或缺的部件,故障常常会导致机器损坏乃至停机,其复杂的工作环境也使传统的故障诊断算法自适应性减弱^[1]。传统故障诊断方法在面对复杂工作环境和不平衡数据时,往往无法有效处理少数类别数据,会导致诊断模型精度较低^[2]。这种数据不平衡使得分类器难以有效学习多数与少数类别的判别边界,从而影响故障诊断结果的准确性。为解决这一问题,已有众多研究聚焦于处理类不平衡数据的故障诊断分类问题。

在算法层面,代价敏感学习和集成学习等不平衡数据处理方法通过调整样本的权重或组合多个分类器来改善模型性能,如 Liu 等人^[3]提出加权代价矩阵, Wang 等人^[4]提出代价敏感支持向量机。尽管这些方法能提升对少数类的关注,但合理设定权重比例是一大挑战。在数据层面,传统的数据增强方法主要包括过采样与欠采样方法,如 SMOTE (synthetic minority over-sampling technique) 技术^[5]可以通过从少数类创建合成样本。但这些方法可能会导致模型学习到噪声特征,影响最终的分类精度。

近年来,基于生成模型的深度学习方法逐渐成为解决数据不平衡问题的有效手段,如 Zhang 等人^[6]使用生成对抗网络 (generative adversarial networks, GAN) 学习噪声和真实机械振动数据之间的映射关系,生成额外的真实样本;廖珂等

人^[7]通过对 CGAN (conditional GAN) 引入振动信号特征学习真实数据样本分布来生成高质量的样本;Wang 等人^[8]则利用 VAE (variational autoencoder) 作为生成器与 GAN 结合并应用于滚动轴承的故障诊断。然而现有不平衡数据增强技术大多只关注时域特征忽略了频域信息,而频域特征在轴承故障诊断中至关重要。尽管已有研究通过对轴承时域信号进行短时傅里叶变换与 CNN 网络结合进行故障诊断^[9],但这些方法在数据不平衡领域内并未充分考虑频域特征,导致数据处理在多维特征的挖掘上存在不足。Wang 等人^[10]则提出类傅里叶变换 GAN (fourier-like transform GAN, FTGAN),其中类傅里叶变换器 (fourier-like transformer, FLT) 通过自编码器的结构模拟离散傅里叶变换与逆傅里叶变换,并在训练过程中学习时域与频域之间的通用映射。虽然能够在频域上生成更接近真实的信号但在数据增强过程中仍然存在一定的局限性。

因此,针对上述问题,本研究提出基于统计约束的类傅里叶变换变分自编码器对抗生成网络 (fourier-like VAE-GAN based on statistical constraints, SC-FVAE-GAN),该技术结合了类傅里叶变换的变分自编码器 (fourier-like VAE, FVAE) 和时域及频域的并行鉴别器。此外,为提高生成数据的质量,本研究采用箱线图统计约束方法,利用无量纲特征对数据进行统计约束使生成的数据质量更高。将该模型生成的平衡数据集结合 CNN-LSTM 网络进行训练,最后实现故障诊断分类。实验结果表明,本文所提的方法在西储大学 (CWRU) 轴承数据集上具有更好的鲁棒性与准确性。

1 故障诊断框架搭建

1.1 基于统计约束的 FVAE-GAN 数据增强网络

在不平衡轴承数据故障诊断领域,现有的研究如 VAE-GAN 及相关的变体并没有很好地将轴承数据中的时域与频域

1. 吉林化工学院信息与控制工程学院 吉林吉林 132000

2. 广东石油化工学院计算机学院 广东茂名 525000

[基金项目] 基于类不平衡深度特征学习的石化动设备故障信号分类研究 (62176069); 软件缺陷预测关键技术和新方法研究 (2023A1515012653)

进行综合考虑。FTGAN 网络虽然引入了 FLT 能够考虑真实数据的时频域分布，但是由于自编码器结构的不确定性映射与缺乏概率建模限制了其在复杂频域数据处理中的效果。

本文在 VAE-GAN 的框架上，提出基于统计约束的 FVAE-GAN 来生成新样本。在 FLT 结构下引入 VAE 作为对抗生成网络中的生成器，组成 FVAE。利用 FLT 学习信号的频域特性，并通过 VAE 框架生成具有类似特性的新数据。FVAE 在编码器和解码器中有效地模拟了傅里叶变换的特性，使得生成器网络能够捕捉到输入数据的时频特性，同时保持变分自编码器的特性，这样的结构既利用了 VAE 生成新数据的能力，又保留了处理时频数据特性的优势。




图 1 FVAE 结构图

图 1 为所提出的生成器 FVAE，其中编码器由一系列线性层组成，首先通过嵌入层将训练数据的类别标签转换成连续的向量表示，合并标签嵌入向量与输入数据后通过两个独立的全连接层来预测潜在空间中的均值方差。编码器将真实样本 x 转换成两个潜在空间表示即均值 μ 与对数方差 $\log(\sigma^2)$ ，空间中的潜在变量设为参数 z ：

$$\begin{aligned} \mu, \log(\sigma^2) &= f_{\text{encoder}}(x) \\ \mu_R &= W_R[x \oplus \text{emb}(\text{labels})] + b_R, \\ \log(\sigma_R^2) &= W_{\log(\sigma_R)}[x \oplus \text{emb}(\text{labels})] + b_{\log(\sigma_R)}, \\ \mu_I &= W_I[x \oplus \text{emb}(\text{labels})] + b_I, \\ \log(\sigma_I^2) &= W_{\log(\sigma_I)}[x \oplus \text{emb}(\text{labels})] + b_{\log(\sigma_I)} \end{aligned} \quad (1)$$

式中： $\oplus$ 表示合并操作； f_{encoder} 表示编码器网络，其中包括标签嵌入层 $\text{emb}(\text{labels})$ 。随后通过两个全连接层将 μ_R 、 μ_I 和 $\log(\sigma_R^2)$ 、 $\log(\sigma_I^2)$ ，输出为 z_R 和 z_I 。为便于反向传播并允许随机梯度下降优化，使用了重参数化技巧：

$$z = \mu + \sigma \odot \epsilon \quad (2)$$

式中： $\epsilon \sim N(0, I)$ 是从标准正态分布采样的噪声向量； $\odot$ 表示元素乘。编码器将输入转换为实部与虚部模拟傅里叶变换技术，以确保重构的数据不仅符合时域特征，而且与输入数据的频域特征很好地对齐。解码器利用转置卷积层的序列，递增地将潜在向量上采样到原始数据维度。解码器的输出 $\hat{x}$ 是输入 x 的重构，旨在最小化重构误差。

$$\hat{x} = f_{\text{decoder}}(z) = \frac{1}{N}(z_r \times C - z_i \times S) \quad (3)$$

式中： $\hat{x}$ 表示生成器生成的数据； f_{decoder} 表示解码器网络，解码器中使用潜在变量的线性组合与学习到的正弦与余弦变量相乘，模拟傅里叶逆变换的过程。

图 2 为基于 VAE-GAN 框架改进的数据增强方法的结构

图，本文在鉴别器结构上提出了时域鉴别器与频域鉴别器。时域鉴别器 (time discriminator, TD) 接收来自生成器的时域数据和真实的时域数据样本，通过其网络结构评估并输出真或假的判断结果。频域鉴别器 (frequency discriminator, FD) 将生成的数据实时通过短时傅里叶变换 (STFT) 得到增强的频域数据，然后进行真实性判断。




图 2 FVAE-GAN 结构图

对于所提出的对抗生成网络框架，在训练过程中，使用生成器与鉴别器交替训练的策略：固定生成器，更新两个鉴别器的参数，使其更好地区分真实数据和生成数据，通过最小化鉴别器的损失 L_D ，提高鉴别器在时域和频域上区分真实与生成数据的能力；固定鉴别器，通过最小化生成器损失 L_G 更新生成器的参数，生成器通过对抗性损失 L_{adv} 接收反馈，调整参数以生成更逼真的数据。

鉴别器的训练过程是通过频域鉴别器和时域鉴别器的联合反馈，利用二进制交叉熵损失函数 (BCE) 即 L_{BCE} 来量化鉴别器在判断生成数据 $x_{\text{fake}}(\hat{x})$ 与真实数据 x_{real} 时的能力。如式 (4) 所示，对于一组真实标签 y 和鉴别器输出的预测值 $\hat{y}$ ，训练过程中，真实数据的标签 $y_{\text{real}}=1$ ，增强数据的标签为 $y_{\text{fake}}=0$ 。最后通过最小化 L_D 鉴别器能够提高其判别真实数据与生成数据的能力：

$$\begin{aligned} L_{\text{BCE}}(y, \hat{y}) &= -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \\ L_{\text{TD}} &= \frac{1}{2} (L_{\text{BCE}}(1, D_{\text{TD}}(x_{\text{real}})) + L_{\text{BCE}}(0, D_{\text{TD}}(x_{\text{fake}}))) \\ L_{\text{FD}} &= \frac{1}{2} (L_{\text{BCE}}(1, D_{\text{FD}}(\text{STFT}(x_{\text{real}}))) + L_{\text{BCE}}(0, D_{\text{FD}}(\text{STFT}(x_{\text{fake}})))) \\ L_D &= \frac{1}{2} (L_{\text{TD}} + L_{\text{FD}}) \end{aligned} \quad (4)$$

式中： D_{TD} 与 D_{FD} 分别表示时域与频域鉴别器； $\text{STFT}(\cdot)$ 表示短时傅里叶变换； L_{TD} 与 L_{FD} 分别表示时域与频域鉴别器的损失。生成器 FVAE 的训练则根据鉴别器的反馈，通过反向传播调整其参数，目的是生成更逼真的数据，以降低被鉴别器识别为“假数据”的概率。在训练的过程中，生成器的损失根据重构误差与鉴别器的判别结果计算，最后在损失最低时保存生成器用于数据扩充，从而得到更为平衡的生成数据。

这种双重判别机制使得生成器能够生成更为真实且符合时域和频域特征的数据，提升生成数据的质量。

FVAE 使用重建损失和 KL 散度的组合进行训练，FVAE 生成器训练的总损失函数：

$$L_G = L_{\text{recon}}(x, \hat{x}) + \beta L_{\text{KL}}(\mu, \sigma) + \lambda L_{\text{adv}} \quad (5)$$

式中： L_{recon} 是重建损失，选择均方误差（MSE）作为损失函数； L_{KL} 则是学习的潜在分布和先验分布之间的 KL 散度，其通常被假设为标准正态分布 $N(0, I)$ ； L_{adv} 是生成器在时域和频域鉴别器上的对抗性损失即 L_{TDadv} 与 L_{FDadv} ，具体表示为：

$$\begin{aligned} L_{\text{adv}} &= L_{\text{TDadv}} + L_{\text{FDadv}} \\ &= L_{\text{BCE}}(1, D_{\text{TD}}(\hat{x})) + L_{\text{BCE}}(1, D_{\text{FD}}(\text{STFT}(\hat{x}))) \end{aligned} \quad (6)$$

式中： β 与 λ 则为 L_G 的超参数，用于平衡不同损失项的权重。

1.2 基于无量纲特征的统计约束方法

箱线图^[11]能有效地揭示数据的中位数、四分位数和异常值，该方法一般通过设置上、下异常值截断点 η_u 、 η_l 进行异常值检测，计算公式为：

$$\begin{aligned} \text{IQR} &= (Q_3 - Q_1) \\ \eta_u &= Q_3 + \lambda \times \text{IQR}; \\ \eta_l &= Q_1 - \lambda \times \text{IQR} \end{aligned} \quad (7)$$

式中： Q_1 、 Q_3 分别是下四分位数和上四分位数；IQR（四分位距）衡量的是数据的散布范围； λ 是调整异常值检测敏感性的因子。当数据大于 η_u 或小于 η_l 时，则被认为是异常值，最后将异常值截断点划为 $[\eta_u, \eta_l]$ 约束区域。

传统的故障诊断技术主要依赖于计算故障时域信号的特征参数，通过计算时域信号的量纲特征进行故障诊断。相比于有量纲特征，无量纲指标能够排除设备的运行状态并有效地从轴承的振动信号中保持故障敏感性并提取关键信息^[12]。因此，本文选取波形因子、偏度因子、脉冲因子、峭度因子和脉冲因子 5 个无量纲指标作为约束条件，用以确保生成的样本符合原始样本的统计特性。其计算公式如表 1 所示，对真实样本进行计算，得到 5 个无量纲指标值对应的 $[\eta_u, \eta_l]$ 约束区域，即检测生成样本的 5 个无量纲值是否处于上述区域内，如果是则保留该样本。最后检测约束过后的数据集是否达到平衡要求，否则循环并继续生成数据，以此得到最终的平衡数据集。

表 1 无量纲指标计算公式

无量纲指标	计算公式
波形因子	$\text{SF}_i = \frac{\sqrt{\frac{1}{N} \sum_{j=1}^N x_{ij}^2}}{\frac{1}{N} \sum_{j=1}^N x_{ij} }$
脉冲因子	$\text{PF}_i = \frac{\text{Max}(x_{ij})}{\frac{1}{N} \sum_{j=1}^N x_{ij} }$

表 1 (续)

无量纲指标	计算公式
峭度	$K_i = \sqrt{\frac{N}{24} \left[\frac{1}{N} \sum_{j=1}^N \left(\frac{x_{ij} - M_i}{\text{Std}_i} \right)^4 - 3 \right]}$
偏度	$S_i = \sqrt{\frac{1}{6N} \sum_{j=1}^N \left(\frac{x_{ij} - M_i}{\text{Std}_i} \right)^3}$
峰值因子	$\text{CF}_i = \frac{\text{Max}(x_{ij})}{\sqrt{\frac{1}{N} \sum_{j=1}^N x_{ij}^2}}$

1.3 基于 SC-FVAE-GAN 故障诊断框架

为了实现轴承故障诊断分类，该框架引入 CNN-LSTM 混合深度神经网络结构。该网络不仅能有效处理时序数据中的时序特征，还能提高故障预测的精度和鲁棒性，其结构包括几个关键组成部分：

CNN-LSTM 网络结构由多个卷积层块构成，这些层通过不同数量的卷积核提取振动信号的局部特征，并使用归一化和 ReLU 激活函数来增强学习效率和稳定性。最大池化层用于降低特征图维度，减少计算负担。特征提取后，网络包含两层 LSTM 层，分别有 128 和 64 个单元，用于捕捉时间依赖性和挖掘时间序列模式。最后通过一个与诊断类别数相同的输出层并采用 softmax 激活函数，将特征转换为故障概率分布，实现多类别的准确分类诊断。该网络结合了卷积层的特征提取能力与 LSTM 层的时间序列建模优势，确保了轴承故障诊断的高精度和鲁棒性。

该故障诊断网络的训练采用小批次训练方式，整体故障诊断框架如图 3 所示。




图 3 基于 SC-FVAE-GAN 的故障诊断框架

通过 SC-FVAE-GAN 网络与无量纲特征约束方法，生成高质量的平衡轴承数据集，利用平衡后的数据集可以显著提升故障诊断模型的准确性和鲁棒性，从而有效解决不平衡数据对故障诊断性能的负面影响。

2 实验及结果分析

2.1 实验数据集设置

为实现大型机组中存在的轴承时域信号不平衡条件下的故障诊断，本文使用轴承故障诊断领域内具有权威性的 CWRU 公共数据集进行实验验证。

本文选取 12 kHz 采样频率收集到的轴承数据作为训练数据，为更好地实现不平衡轴承数据对故障诊断信号的影

响，本文将轴承数据集总共分为 9 种故障类型。其中故障部位分为内圈故障、外圈故障和滚动体故障，并且每一部位的轴承 0.213 cm、0.427 cm 和 0.640 cm 三种损伤尺寸。该数据集中时域数据总数量为 20 000 条，以 3:7 的比例分成测试集与训练集，其中测试集为 6 000 条。为模拟不平衡轴承数据，将训练数据当中的每一类故障数据分别按照故障数据与正常数据的不均衡比例分成 4 组数据，该比例数值分别为“1:2”“1:5”“1:10”“1:20”，最后删除多余的数据。整体训练数据集的具体构成如表 2 所示。

表 2 训练数据集结构表

数据集	数据类型及样本数量（每类故障分为 0.213 cm、0.427 cm 和 0.640 cm 的故障直径）				不平衡比例
	正常	内圈	外圈	滚动体	
A	1 400	700/700/ 700	700/700/ 700	700/700/ 700	1:2
B	1 400	280/280/ 280	280/280/ 280	280/280/ 280	1:5
C	1 400	140/140/ 140	140/140/ 140	140/140/ 140	1:10
D	1 400	70/70/70	70/70/70	70/70/70	1:20
测试	600	600/600/ 600	600/600/ 600	600/600/ 600	1:1

2.2 实验流程

基于上述所提出的不平衡数据故障诊断框架，本论文的相关实验流程如图 3 所示，其中关键步骤如下：

- (1) 对不平衡轴承时域数据进行处理并划分为训练数据和测试数据。
- (2) 搭建 SC-FVAE-GAN 生成网络，其中使用 FVAE 作为生成器，并用时域与频域并行鉴别器同时对增强数据进行鉴别。当鉴别器无法对增强的数据鉴别是否真实则表示训练完毕，将此时生成的样本作为待训练样本。
- (3) 将原始样本通过无量纲指标得到箱线图对待训练样本进行约束，并判断最终的样本是否平衡，若没有达到平衡条件则再使用生成器进行生成数据，直至达到平衡。
- (4) 将最终增强的时域数据与原来的类不平衡数据集结合成平衡数据集，并作为训练数据对 CNN-LSTM 分类网络进行训练，使用测试集进行测试。

2.3 实验结果验证

为分析 SC-FVAE-GAN 的数据增强算法在故障诊断上的效果，使用数据集 D 训练 CNN-LSTM 的故障诊断框架，并采用混淆矩阵和 T-SNE 可视化工具，进一步验证 SC-FVAE-GAN 算法的效果。混淆矩阵展示了分类模型对各个故障类别的诊断精确度和敏感度。从图 4 中可以得出本文提出的算法能提升对少数类样本的识别效果，且特征聚类效果更为明显。为表明本文所提出的方法的有效性，本文对比了不平衡数据增强领域内的一些经典及改进的不平衡故障诊断框架，分别为：SMOTE+CNN^[13]、VAEGAN+CNN^[14]、SCDCGAN+CNN。本研究引入了 F_1 分数和 AUC 值，与准确

率（accuracy, Acc）一同用于评估，以全面分析模型对多种故障类型的识别能力。表 3 为对比实验表，可以得出本文所提方法在多个数据集上均显示出优异的性能，具有更好的稳定性且能够有效识别少数类故障数据，提高不平衡情况下的诊断能力。




图 4 平衡数据验证效果

表 3 对比实验表

	模型	Acc	F_1	AUC
A	VAEGAN+CNN	0.915	0.923	0.959
	SMOTE+CNN	0.848	0.765	0.783
	SC-DCGAN+CNN	0.968	0.945	0.983
	本文所提框架	0.989	0.969	0.994
B	VAEGAN+CNN	0.795	0.783	0.886
	SMOTE+CNN	0.820	0.852	0.772
	SC-DCGAN+CNN	0.967	0.883	0.922
	本文所提框架	0.953	0.953	0.973
C	VAEGAN+CNN	0.707	0.728	0.784
	SMOTE+CNN	0.783	0.766	0.745
	SC-DCGAN+CNN	0.907	0.908	0.884
	本文所提框架	0.912	0.921	0.899
D	VAEGAN+CNN	0.674	0.730	0.774
	SMOTE+CNN	0.691	0.677	0.663
	SC-DCGAN+CNN	0.852	0.862	0.834
	本文所提框架	0.836	0.836	0.909

此外,本研究在故障诊断模型中采用了CNN-LSTM网络,该网络能更准确地对平衡后的数据集进行诊断,其性能也优于卷积神经网络,这表明其结构和机制在处理多种类型数据时都非常有效。

为证实本论文所提方法的有效性,本文以CNN-LSTM作为故障诊断分类网络并逐个判断不平衡数据增强的效果作为本论文的消融实验。其中数据增强的模型分别使用FLT生成器;FVAE生成器;VAE-GAN的对抗生成网络;FVAE-GAN对抗生成网络;SC-FVAE-GAN为本文所提的最终方案即引入基于无量纲指标的箱线图统计约束以提高数据质量。如图5所示,其中SC-FVAE-GAN部分为本文提出的最终方案,该方案通过此模型得到的平衡数据集与CNN-LSTM进行诊断分类。




图5 消融实验结果

从图5分析可以看出,FVAE生成器在原始的FLT模型加入潜在空间并没有显著提升性能,其效果相比于原模型有所下降。然而,通过在FVAE中引入时域和频域的双重鉴别器,可看出诊断性能显著提高,且其效果明显优于传统的VAE-GAN模型。特别是在数据集D的结果中,可以清楚地看到本文最终提出的SC-FVAE-GAN模型表现出了更优异的性能,表明该故障诊断框架能够有效地解决在不平衡数据环境下的轴承故障诊断问题。

3 结论

本文提出了基于SC-FVAE-GAN的不平衡轴承数据故障诊断框架,在不同不平衡比例的数据集下进行多轮对比实验与消融实验,从结果可得出本研究方法在不平衡数据增强领域优于传统以及相关改进方法,展现出显著的提升趋势。该方法结合了傅里叶变换原理与时频并行鉴别器,能够同时处理时域与频域信号,精准捕捉轴承故障的周期性和频率特性。此外,利用无量纲指标约束提高样本质量,解决了不平衡数据导致的模型不稳定和准确率偏向问题,显著提升了模型的鲁棒性和识别能力。SC-FVAE-GAN与CNN-LSTM故障诊断框架增强了数据生成的逼真性和多样性,优化了数据分布,缓解了样本不平衡带来的挑战。综上,本文所提出的方法在轴承故障诊断中展现出卓越性能,为不平衡数据问题提供了有效的解决方案。

参考文献:

- [1] 曲建岭,余路,袁涛,等.基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J].仪器仪表学报,2018,39(7):134-143.
- [2] 张皓,谷立臣,郭子辰.基于双向生成对抗网络的滚动轴承智能诊断方法(英文)[J].Journal of measurement science and instrumentation,2024,15(2):264-275.
- [3] LIU Z, LIU Q. Studying cost-sensitive learning for multi-class imbalance in Internet traffic classification[J].The journal of China Universities of posts and telecommunications, 2012,19(6):63-72.
- [4] WANG Q, PAN Z W, LIU N. An ensemble and cost-sensitive learning-based root cause diagnosis scheme for wireless networks with spatially imbalanced user data distribution[J]. Science China(information sciences),2024,67(7):331-332.
- [5] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: synthetic minority over-sampling technique[J]. Journal of artificial intelligence research, 2002, 16: 321-357.
- [6] ZHANG W, LI X, JIA X D, et al. Machinery fault diagnosis with imbalanced data using deep generative adversarial networks[J]. Measurement, 2020, 152: 107377.
- [7] 廖珂,荆晓远,李双远,等.基于SC-DCGAN的不平衡数

据轴承故障诊断[J]. 机床与液压,2024,52(24):208-231.

[8] WANG X, JIANG H K, WU Z H, et al. Adaptive variational autoencoding generative adversarial networks for rolling bearing fault diagnosis[J]. Advanced engineering informatics, 2023, 56: 102027.

[9] 李恒, 张氢, 秦仙蓉, 等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J]. 振动与冲击, 2018, 37(19): 124-131.

[10] WANG H Y, LI P, LANG X, et al. FTGAN: a novel GAN-based data augmentation method coupled time-frequency domain for imbalanced bearing fault diagnosis[J/OL]. IEEE transactions on instrumentation and measurement, 2023[2024-11-03]. <https://ieeexplore.ieee.org/document/10012400>. DOI: 10.1109/TIM.2023.3234095.

[11] BENJAMINI Y. Opening the box of a boxplot[J]. The American Statistician, 1988, 42(4): 257-262

[12] 周凌孟, 张清华, 邓飞其, 等. 无量纲与 SVM 的石化机组旋转机械故障诊断方法[J]. 噪声与振动控制, 2024, 44(1): 119-125.

[13] 罗毅, 郝伟琪. 一种基于 SMOTE 的 CNN 风电机组故障诊断方法[J]. 计算机仿真, 2024, 41(2): 91-94.

[14] FAN Z H, WANG Y, MENG L H, et al. Unsupervised anomaly detection method for bearing based on VAE-GAN and time-series data correlation enhancement (June 2023)[J]. IEEE sensors journal, 2023, 23(23): 29345 - 29356.

【作者简介】

杜杰宾(2000—), 男, 广东深圳人, 硕士研究生, 研究方向: 故障诊断、类不平衡, email:dujiebin_29@126.com.

荆晓远(1971—), 通信作者(email: jingxy_2000@126.com), 男, 江苏南京人, 博士, 教授、博士生导师, 研究方向: 模式识别、计算机视觉、故障诊断。

谢胜灵(1999—), 男, 湖南长沙人, 硕士, 研究方向: 故障诊断、类不平衡。

刘飞(1999—), 男, 湖南衡阳县人, 硕士, 研究方向: 故障诊断、类不平衡。

廖珂(1997—), 男, 湖南茶陵人, 硕士, 研究方向: 故障诊断、类不平衡。

朱冠华(1979—), 男, 广东韶关人, 硕士, 研究方向: 故障诊断。

(收稿日期: 2025-01-07 修回日期: 2025-04-14)

(上接第 177 页)

为验证断电保护功能, 分别在数据传输、Flash 清擦及 Flash 写入过程中手动断电。结果表明, 在数据传输时断电, 由于还未进行数据校验, 未对 Flash 数据进行任何更改。在清擦及写入过程断电后, FPGA 程序 Flash 中 UPDATE 区域被擦除, 上电后能够自动跳转至 GOLDEN 区域启动并具备再次加载能力, 保证了异常情况下的容错能力。

5 结语

本文设计了一种基于 RS422 接口的 FPGA 程序及参数读写技术, 完成了总体方案、工作流程及 FPGA 功能实现, 并搭建测试系统进行了充分验证。结果表明, 本方案能够使用 FPGA 器件完成自身程序及参数的在线烧写与回读, 有效提高程序烧写效率, 对硬件资源的要求较低, 满足未来产品集成化、小型化、低成本设计要求, 具有较高的工程化应用价值。

参考文献:

[1] 焦李成, 孙其功, 杨育婷, 等. 深度神经网络 FPGA 设计进展、实现与展望[J]. 计算机学报, 2022, 45(3): 441-471.

[2] 丁晓彤, 徐佩, 任鹏举. 一种基于 FPGA 的卷积神经网络模型设计[J]. 航空兵器, 2019, 26(2): 15-20.

[3] 朱道山. 远程在线更新 FPGA 多版本程序的方法[J]. 单片机与嵌入式系统应用, 2023, 23(6): 4-7.

[4] 李霄, 徐思远, 胡瑾贤. 基于 FPGA 的远程快速在线升级技术研究[J]. 舰船电子对抗, 2023, 46(4): 98-102.

[5] 姜艳娜, 许彦章, 李媛媛, 等. 一种弹载设备快速软件在线升级设计与实现[J]. 电子技术应用, 2023, 49(6): 109-113.

[6] 孟宪华, 李健铎. 基于超声系统的 FPGA 在线升级方案[J]. 科技创新, 2022(7): 37-40.

[7] 赵飞. 一种基于 DSP+FPGA 架构的软件在线升级实现[J]. 现代导航, 2021, 12(6): 462-465.

[8] 张秀宁, 刘斌, 李澎, 等. 基于反熔丝型 FPGA 的有效载荷可重构技术[J]. 遥测遥控, 2021, 42(6): 65-70.

[9] 胡家晖. 一种 SPI 总线的 FPGA 快速在线升级方法[J]. 电子制作, 2024, 32(20): 42-46.

[10] 王琳, 宋丫, 曹艳梅, 等. 基于 RS422 的高可靠性串行通信接口设计[J]. 山西电子技术, 2024(4): 71-72.

[11] 宋志毕, 方芳. 基于 Quickboot 技术的 FPGA 在线升级[J]. 单片机与嵌入式系统应用, 2023, 23(6): 40-44.

【作者简介】

郭向楠(1988—), 男, 河南洛阳人, 硕士, 工程师, 研究方向: 嵌入式软件设计与测试。

(收稿日期: 2025-01-22 修回日期: 2025-04-29)