

基于Nadam-TimeGAN和XGBoost的时序信号故障诊断方法

黑新宏^{1,2}, 高苗¹, 张宽¹, 费蓉^{1,2}, 邱原^{1,2}, 姬文江^{1,2}

(1. 西安理工大学计算机科学与工程学院, 陕西 西安 710048; 2. 陕西省网络计算与安全技术重点实验室, 陕西 西安 710048)

摘要: 为了提高故障诊断模型在数据不平衡场景下的诊断性能和模型泛化能力, 提出了一种基于Nadam-TimeGAN和XGBoost的时序信号故障诊断方法。首先对比基于LSTM和GRU的TimeGAN模型, 选取性能更优的GRU网络作为TimeGAN模型的组成单元, 然后采用Nadam优化算法对TimeGAN模型各组件进行优化, 即构建Nadam-TimeGAN模型用以数据扩充, 最后构建一个平衡的数据集输入XGBoost集成学习模型进行分类训练。实验选取转辙机动作电流数据集进行验证性实验, 选取MFPT轴承数据集和CWRU轴承数据集进行泛化性实验, 并与8种方法进行对比, 结果表明, 所提方法在准确率、召回率以及F1-score这3种评价指标上均高于其他方法, 从而验证了所提方法在不平衡数据故障诊断方面的有效性和泛化性。

关键词: 时间序列生成对抗网络; Nesterov加速自适应矩估计; 极致梯度提升; 故障诊断; 数据增强

中图分类号: TP18

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024081

Fault diagnosis method of timing signal based on Nadam-TimeGAN and XGBoost

HEI Xinhong^{1,2}, GAO Miao¹, ZHANG Kuan¹, FEI Rong^{1,2}, QIU Yuan^{1,2}, JI Wenjiang^{1,2}

1. School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China

2. Shaanxi Key Laboratory of Network Computing and Security Technology, Xi'an 710048, China

Abstract: In order to improve the diagnostic performance and model generalization ability of the fault diagnosis model in data imbalance scenarios, a time series signal fault diagnosis method based on Nadam-TimeGAN and XGBoost was proposed. Firstly, the TimeGAN model based on LSTM and GRU was compared, and the GRU network with better performance was selected as the component unit of the TimeGAN model. The Nadam optimization algorithm was used to optimize the components of the TimeGAN model, that was, the Nadam-TimeGAN model was constructed for data expansion. After data expansion, a balanced data set was constructed and input into the XGBoost integrated learning model for classification training. In the experiment, the action current data set of switch machine was selected for verification experiment, the MFPT bearing data set and the CWRU bearing data set were selected for generalization experiment, and compared with eight methods. The results show that the proposed method is higher than other methods in accuracy, recall and F1-score. The experimental results validate the effectiveness and generalization of the proposed method for imbalanced data fault diagnosis.

Keywords: TimeGAN, Nadam, XGBoost, fault diagnosis, data augmentation

收稿日期: 2023-12-07; 修回日期: 2024-03-12

基金项目: 国家自然科学基金资助项目(No. 62120106011, No. U20B2050); 国家重点研发计划基金资助项目(No. 2022YFB2602203)

Foundation Items: The National Natural Science Foundation of China (No. 62120106011, No. U20B2050), The National Key Research and Development Program of China (No. 2022YFB2602203)

0 引言

故障诊断在机器健康管理中起着至关重要的作用,随着人工智能的兴起与发展,故障诊断技术也由原始的人工主观判断向智能化、高效化的方向发展。故障诊断领域引入人工智能、机器学习等新技术,也有效提高了故障诊断的正确性。现有智能诊断模型的训练多采用深度自动编码器(DAE, deep auto-encoder)^[1-2]、深度卷积神经网络(DCNN, deep convolutional neural network)^[3]等深度学习技术,在一定程度上促进了故障诊断技术向智能化发展的进程。小样本及不平衡数据下的智能故障诊断技术是指使用有限的机器故障样本建立智能诊断模型以实现准确的故障识别。然而基于不平衡数据的传统分类算法在进行故障诊断时,对少数类样本的特征学习不充分,会导致分类准确率低、模型整体的分类性能差和泛化性低等问题。

数据增强技术已成为解决数据样本不平衡问题的主流方法,增加数据可以提高后续模型的分类型性能,并且是防止过度拟合的有用策略。合成少数过采样技术(SMOTE, synthetic minority oversampling technique)只能利用有限的故障信息,不能学习数据的整体分布规律,并且数据增强能力不足,无法满足故障诊断对训练数据的巨大需求^[4]。近年来,生成对抗网络(GAN, generative adversarial network)^[5]作为一种“生成+对抗”的学习方式,被广泛用于生成额外样本来解决不平衡样本问题,GAN可以生成与原始数据相同分布的新数据,基于GAN的数据增强方法大大提高了不平衡样本的诊断精度。文献[6]通过将CNN和GAN这2个网络协同优化,对非平衡数据集进行故障分类,GAN为CNN提供了更加平衡的数据集,CNN将故障诊断结果作为修正项输入GAN生成器的损失函数中,以提高GAN的性能。文献[7]提出一种基于动态仿真模型和Wasserstein梯度归一化生成对抗网络的智能故障诊断方法。文献[8]将注意力机制嵌入生成对抗网络中,以捕获输入的信息特征并改进特征表示,生成足够的故障样本从而进行后续分类操作。文献[9]利用深度卷积生成对抗网络生成故障样本,以平衡旋转电机故障诊断的数据集。

当前,时间序列生成对抗网络(TimeGAN, time-series generative adversarial network)^[10]以其良好的处理高维序列的能力而受到越来越多的关

注,生成的数据可以直接应用到下游的分类和预测任务中。TimeGAN生成的合成数据集更接近原始分布,更多样化,可以更密集、更合理地填补下游预测模型的空白,已在许多领域得到了利用。文献[11]提出一种基于注意力机制并融合时间卷积网络与长短期记忆(LSTM, long short term memory)网络的数据增强网络,以解决时间序列预测中的小样本问题。文献[12]利用TimeGAN学习原始数据样本的分布规律及其特征之间的时间相关性,然后利用这些样本生成新样本来增强训练集。文献[13]将带有梯度惩罚的Wasserstein距离纳入TimeGAN中,有效地解决了故障数据的稀缺性问题。然而对于时间序列,来自不同时间步长的输入数据之间存在强相关性,传统神经网络的输出完全独立于输入,彼此之间几乎没有相关性,无法深入探索时间序列的特征。门控循环单元(GRU, gate recurrent unit)引入了内存的概念,其中每个神经元具有一个额外的反馈输入,可以保存部分先前时间步的信息,并将其传递到当前时间步以参与计算。这种机制允许GRU在不同时间步长之间建立连接,并更好地捕获和利用序列中的长期依赖关系^[14]。因此,本文中TimeGAN模型的所有网络都由多层GRU网络单元构建以确保模型自回归。

深度学习已在众多领域中展现出了强大的能力。在训练网络时,参数设置和优化算法选择等因素会影响网络模型的训练精度,因此选择合适的优化函数至关重要。传统的优化函数如梯度下降和随机梯度下降等已经取得了一定的成功,但它们仍然存在一些局限性。例如,它们可能陷入局部最优解、收敛速度较慢,并且对初始参数的选择相对敏感。为了克服这些局限性,研究者们提出了一系列新的优化函数。其中,Nesterov加速自适应矩估计(Nadam, Nesterov-accelerated adaptive moment estimation)作为一种结合了Nesterov加速梯度(NAG, Nesterov accelerated gradient)和自适应矩估计的优化函数,在深度学习中得到了广泛的应用。Nadam优化函数通过引入Nesterov优化算法的概念,允许在训练过程中根据当前参数的位置和动量方向对下一个参数进行预测。这种特殊的动量更新方式使模型能够更快地收敛,并且在参数空间中更加稳定。此外,Nadam还结合了自适应矩估计的思想,即根据参数的历史梯度信息来调整学习率,从

而进一步提高优化的效果。在实际应用中, Nadam 优化函数已经在多个深度学习任务中展现出了卓越的性能^[15-17]。

因此, 本文创新性地提出基于 Nadam 优化算法的时间序列生成对抗网络和极致梯度提升 (XGBoost, extreme gradient boosting)^[18]的时序故障诊断方法。在预处理后的原始故障数据集上提取特征后, 分别使用 GRU 和 LSTM 网络^[19]作为 TimeGAN 模型的组成单元对原始数据进行增强, 选取效果较优的 GRU 网络单元作为 TimeGAN 模型的最终组成部分, 之后采用 Nadam 优化算法优化 TimeGAN 网络的各组件, 即采用 Nadam-TimeGAN 作为数据增强方法, 对导致数据不平衡的少数类样本进行数据扩充, 避免因数据样本不均衡而导致过拟合现象。在得到一套高质量合成样本之后, 采用 XGBoost 算法在扩充后的平衡数据集上训练分类器, 以提高在不平衡数据集上的故障分类准确率。最后通过转辙机动作电流数据集进行验证性实验、机械故障预防技术协会 (MFPT, society for machinery failure prevention technology) 轴承数据集和凯斯西储大学 (CWRU, case western reserve university) 滚动轴承数据集进行泛化性实验。为了进一步验证该方法的有效性, 还比较了梯度提升决策树 (GBDT, gradient boosting decision tree)、LightGBM 以及深度卷积生成对抗网络 (DCGAN, deep convolution generative adversarial network)-CNN^[20-21]等 8 种方法。在验证性实验上, 所提方法的准确率、召回率和 F1-score 这 3 种评价指标较原始不平衡数据提高了 4.30%、4.66% 和 0.045 9; 在泛化性实验上, 所提方法较原始不平衡数据的准确率和召回率均提高了约 4%, F1-score 提高了约 0.04。实验结果表明, 本文方法分类效果最优。本文的主要贡献可以总结如下。

1) 针对不平衡时序数据集设计了一种基于 Nadam-TimeGAN 和 XGBoost 的故障诊断方法。Nadam-TimeGAN 通过生成低维潜在表示, 从原始数据学习样本分布规律以及特征之间的时间相关性, 通过对抗训练生成新样本以增强原始数据集, 构建平衡数据集并基于 XGBoost 算法训练分类器。在自采数据集和 2 个公开数据集上进行验证, 证明了本文方法的有效性。

2) 将基于 GRU 的 TimeGAN 模型作为时序信号

故障数据集的数据扩充方法。由多层 GRU 网络单元构建 TimeGAN 模型各网络结构, 加快模型训练和数据生成, 减少过拟合风险, 增强模型泛化能力, 深度挖掘时间序列数据中的长期依赖关系, 提升时间序列生成模型的性能和效率。

3) 结合 Nadam 算法构建 Nadam-TimeGAN 模型。该模型通过使用 Nadam 算法优化 TimeGAN 模型各网络参数, 加快模型收敛速度, 提升模型稳定性和鲁棒性, 解决数据不平衡缺点, 提高故障分类精度。

1 相关理论

1.1 GRU 模型

GRU 是循环神经网络 (RNN, recurrent neural network) 的一种, 是 LSTM 的变体, 但比 LSTM 更易于训练, 在很大程度上提高了训练效率。GRU 的整体结构如图 1 所示。GRU 不再使用单独的记忆细胞存储记忆信息, 而是直接利用隐藏单元记录历史状态且只包含重置门和更新门, 有效克服了短期记忆的缺陷, 缓解了梯度消失问题^[22]。通过重置门 r_t 控制上一个时间步的隐藏状态 h_{t-1} 的遗忘程度, 如式(1)所示; 通过更新门 z_t 控制当前隐藏状态 h_{t-1} 的新信息, 如式(2)所示; 候选隐藏状态 \tilde{h}_t 和隐藏状态 h_t 如式(3)和式(4)所示。




图1 GRU 的整体结构

$$r_t = \sigma(W_r[h_{t-1}, x_t]) \quad (1)$$

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (2)$$

$$\tilde{h}_t = \tanh(W[h_r, h_{t-1}, x_t]) \quad (3)$$

$$h_t = (1 - z_t)h_{t-1} + z_t\tilde{h}_t \quad (4)$$

其中, W_r 、 W_z 和 W 分别是重置门、更新门和候选状态的权重矩阵; x_t 为当前时间步的输入。

1.2 TimeGAN 模型基础理论

生成对抗网络使用生成网络和判别网络联合对抗训练, 在多次训练后, 生成网络和判别网络达到

平衡状态,生成网络生成与真实数据相似甚至更高质量的合成数据,判别网络无法有效地区分生成数据和真实数据,即生成网络在学习过程中逐渐接近真实数据的分布,使判别网络难以准确识别出合成数据。TimeGAN是Yoon等^[10]于2019年提出的一种新型时间序列生成框架,将无监督学习的灵活性和有监督训练的控制能力强的优点结合起来,通过潜在空间进行对抗和联合训练,经证明可以有效生成高质量数据。TimeGAN在原始GAN的基础上,添加了自回归模型中监督训练提供的控制,以提升网络性能,主要由自编码网络和生成对抗网络组成,包括嵌入网络、恢复网络、生成网络和判别网络。TimeGAN相比已有的数据生成模型,更好地保留了时间序列的动态性并生成了高质量样本。TimeGAN基本网络结构如图2所示。

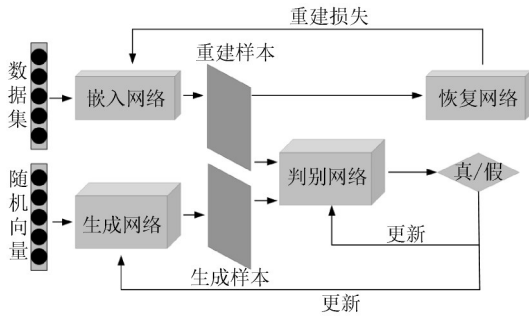


图2 TimeGAN基本网络结构

1.2.1 嵌入网络和恢复网络

嵌入网络和恢复网络构成了TimeGAN中的自编码器结构,实现了特征空间与潜在空间之间的可逆映射。嵌入网络提供了原始高维数据特征到低维潜在空间的映射,通过低维表示高维向量中最有价值的特征信息。与嵌入网络相反,恢复网络将潜在空间还原至初始维度,提供了静态和时态特征到原始特征空间的映射。嵌入网络和恢复网络可表示为

$$h_s = e_s(s), h_t = e_x(h_s, h_{t-1}, x_t) \quad (5)$$

$$\tilde{s} = r_s(h_s), \tilde{x}_t = r_x(h_t) \quad (6)$$

其中, S 和 X 分别表示静态特征和时态特征; e 和 r 分别表示相应变量的嵌入函数和恢复函数; h_s 和 h_t 分别表示映射后的低维静态特征和第 t 时刻低维动态特征; \tilde{s} 和 \tilde{x}_t 分别表示恢复后的高维静态特征和第 t 时刻高维动态特征。

1.2.2 生成网络和判别网络

生成网络和判别网络构成了TimeGAN中的生

成对抗网络,在嵌入空间中完成对生成网络和判别网络的训练。生成网络的输出结果与嵌入网络的输出结果经过联合编码作为判别网络的输入;判别网络用于区分原始数据和合成数据,由一个具有前馈输出层的双向递归网络来实现。生成网络和判别网络可表示为

$$\hat{h}_s = g_s(z_s), \hat{h}_t = g_x(\hat{h}_s, \hat{h}_{t-1}, z_t) \quad (7)$$

$$\tilde{y}_s = d_s(\tilde{h}_s), \tilde{y}_t = d_x(\tilde{u}_t, \tilde{u}_t) \quad (8)$$

其中, g 和 d 分别表示生成网络函数和判别网络函数; \hat{h}_s 和 \hat{h}_t 分别表示生成的静态特征和动态特征; \tilde{y}_s 和 \tilde{y}_t 分别表示静态特征的判别结果和第 t 时刻动态特征的判别结果; \tilde{u}_t 和 \tilde{u}_t 分别表示2个方向的隐藏状态序列。

1.3 Nadam优化算法

自适应矩估计使梯度方向在不变的维度上,参数更新变快,当梯度有所改变时,参数更新变慢,这样能加快收敛并且减少振荡。NAG优化算法根据之前累积的梯度方向模拟下一步参数更新的值,然后将模拟后位置处的梯度替换动量方法中当前位置的梯度。均方根传递(RMSprop, root mean square propagation)优化算法使用梯度平方的移动平均来调整学习率。Adam优化算法是动量和RMSprop的结合。

Nadam优化算法的快速收敛性非常好,是Adam和NAG优化算法的结合。式(9)~式(13)为Adam更新规则,用当前动量矢量 \hat{m}_t 的偏置校正估计取代之前时间步长 \hat{m}_{t-1} 的动量矢量的偏置校正估计,得到Nadam更新规则,如式(14)所示。

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (9)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (10)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (11)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (12)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \varepsilon} \hat{m}_t =$$

$$\theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \varepsilon} \left(\frac{\beta_1 m_{t-1}}{1 - \beta_1^t} + \frac{(1 - \beta_1) g_t}{1 - \beta_1^t} \right) =$$

$$\theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \varepsilon} \left(\beta_1 \hat{m}_{t-1} + \frac{(1 - \beta_1) g_t}{1 - \beta_1^t} \right) \quad (13)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \varepsilon} \left(\beta_1 \hat{m}_t + \frac{(1 - \beta_1) g_t}{1 - \beta_1^t} \right) \quad (14)$$

其中, m_t 和 v_t 分别是梯度的第一阶矩 (均值) 和第二阶矩 (非中心方差); β_1 和 β_2 分别是一阶矩和二阶矩的指数衰减率; η 是学习率。

1.4 XGBoost集成学习算法

集成学习即分类器集成, 是一种机器学习范式, 通过构建并结合多个学习器来完成学习任务。一般结构是先通过学习生成一组“个体学习器”, 再用某种策略将它们结合起来。提升决策树 (BDT, boosting decision tree) 是以分类与回归树 (CART, classification and regression tree) [23] 为基学习器的一种加法模型和前向分布算法的集成学习方法, 而GBDT在BDT的基础上将负梯度作为残差进行拟合。XGBoost是一种基于分类回归树的集成学习算法, 通过使用泰勒二阶展开式求解目标函数, 常用于分类、预测、回归等问题。

XGBoost算法在执行特征分割时不断向树中添加树, 使树增长以更好地拟合上一次预测的残差。它重写并优化了GBDT的原始目标函数, 执行泰勒二阶展开式以提高残差拟合的精度, 使算法更快地收敛并获得最优解。XGBoost算法使用自适应训练方法进行目标函数优化。因此, 优化过程中的每一步都取决于前一步的结果, XGBoost算法的目标函数由两部分组成: 一部分是损失函数 l , 通常是均方误差; 另一部分是正则化项 Ω , 表示每棵树的复杂度总和, 用于控制分类算法的复杂性并防止模型过拟合[24]。XGBoost的目标函数如式(15)所示。

$$\text{Obj}(\theta) = \sum_{i=1}^N l(y_i, \hat{y}_i) + \sum_j \Omega(f_j) \quad (15)$$

其中, 前半部分表示每次迭代的残差和, 后半部分表示 m 棵树的复杂度之和。因此目标函数可简化为

$$\text{Obj}(\theta) = \sum_{i=1}^N l(y_i, \hat{y}_i^{m-1} + f_m(x_i)) + \Omega(f_m) \quad (16)$$

然后对前半部分进行泰勒二阶展开并删除对于第 m 轮迭代来说的常数项, 将目标函数简化为

$$\text{Obj}^m = \sum_{i=1}^N \left(g_i f_m(x_i) + \frac{1}{2} h_i f_m^2(x_i) \right) + \Omega(f_m) \quad (17)$$

XGBoost中正则项用来衡量树的复杂度, 可以表示为树的叶子节点数量 T 和节点分数 w 的平方和, 因此将目标函数中的 Ω 表示为

$$\Omega(f_m) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (18)$$

通过上述目标函数的优化进行决策树的构建, 得到 N 棵决策树, 通过加法策略得到最终的强学习器。

2 时序信号故障诊断方法

2.1 整体架构

本文针对不平衡数据导致的故障分类准确率低的问题, 提出了一种基于Nadam-TimeGAN和XGBoost的故障分类方法, 以提升在不平衡条件下的故障分类准确率。该方法结构主要分为数据预处理、数据生成、数据评估以及训练故障分类器4个部分。数据预处理是将原始故障信号通过时域特征提取得到新的特征矢量用于数据增强和分类模型的训练; 数据生成是基于Nadam-TimeGAN模型对少数类样本进行训练, 并生成故障样本用于平衡故障数据集; 数据评估是对生成数据的质量进行定性和定量评价; 训练故障分类器是采用集成学习算法XGBoost对新的故障数据集进行训练, 得到故障分类器。整体框架如图3所示。

算法输入为原始故障数据集, 使用统计方法对时序数据特征进行提取以更好地理解 and 描述数据, 减少数据维度以及提供有用的特征用于建模和分析。本文提取原始少量多类别故障样本的均值、标准差、方差、最小值、最大值、峰值、偏度以及峰度8个特征。之后将上述故障数据的特征向量输入TimeGAN模型进行对抗训练, 通过对基于GRU和LSTM的TimeGAN模型生成的样本进行评价, 选取效果较优的GRU网络单元生成合成样本, 在此基础上对TimeGAN模型的优化算法进行改进, 采用Nadam优化算法, 构建Nadam-TimeGAN模型, 将合成数据添加到原始样本中作为新的数据集。最后将新的数据集输入分类任务中, 本文采用集成学习算法XGBoost训练分类模型, 实现故障分类任务, 主要思想为基于前向分布算法先训练多个弱学习器, 再组合成最终的强学习器进行分类, 实现故障诊断任务。

本文方法的步骤如算法1所示。其中步骤2)~步骤5)表示Nadam-TimeGAN迭代训练过程, 步骤6)~步骤7)表示构建平衡数据集过程, 步骤8)~步骤14)表示XGBoost模型构建过程。

算法1 基于改进TimeGAN和XGBoost的时序信号故障诊断方法

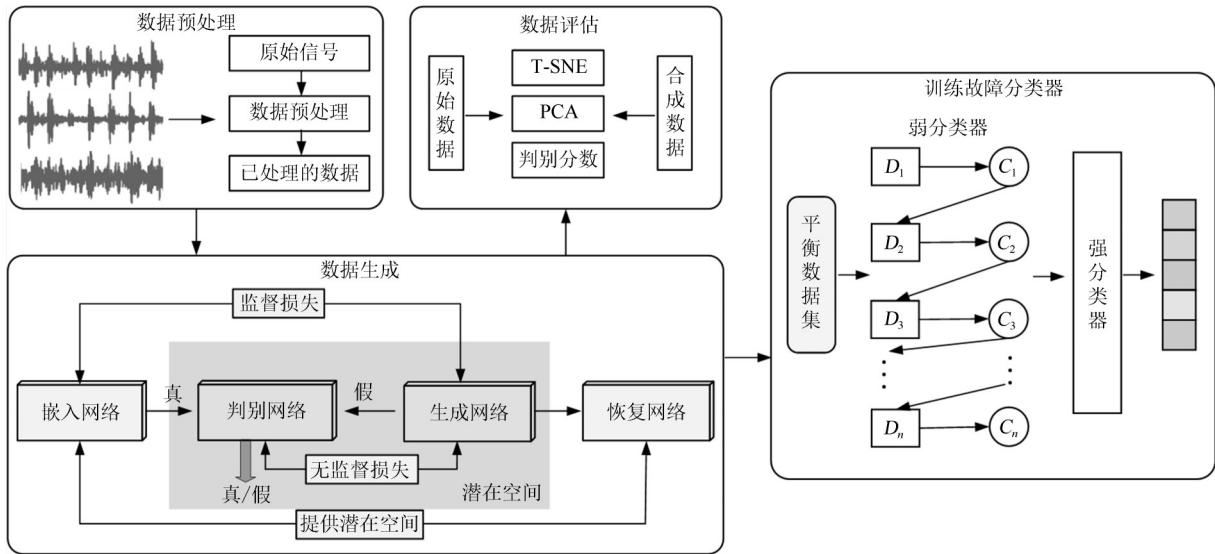


图3 本文提出的故障诊断整体框架

定义原始数据集 $D = \{C_0, C_1, \dots, C_n\}$ 包括正常状态数据样本, 其中 C_i 表示故障类型数据, n 表示故障类型个数

- 1) 对原始数据集 D 进行预处理;
- 2) for i to n do:
- 3) 生成合成数据;
- 4) 计算判别网络损失;
- 5) end for
- 6) 通过 Nadam-TimeGAN 模型生成合成数据;
- 7) 构建平衡数据集 $D_E = \{D_0, D_1, \dots, D_i\}$, 其中 D_i 表示子数据集;
- 8) 初始预测每个样本;
- 9) for t to T do:
- 10) 计算导数;
- 11) 训练多个弱学习器;
- 12) 计算新的样本预测值;
- 13) end for
- 14) 组合强学习器, 对样本进行最终预测;
- 15) 输出分类结果。

2.2 基于 Nadam-TimeGAN 的数据增强

Nadam 算法具有出色的收敛性, 能加速模型的收敛过程, 是对 SGD、NAG、AdaGrad 等方法的改进和替代, 与普通的 Adam 相比, 增加了 NAG 算法作为补充, 是 Adam 算法和 NAG 算法的结合。Adam 算法利用自适应学习率和动量的概念, 能在参数空间中更快地搜索最优解。NAG 算法则通过预测参数的下一个位置, 引入了一种更准确的梯度

估计方法。将 Nadam 优化算法引入 TimeGAN 模型, 加快网络收敛速度, 减少训练时间和成本, 优化网络参数, 提高数据增强的质量和效率, 流程如算法 2 所示。算法输入为噪声 Z 和原始数据 D , 通过损失函数和 Nadam 优化函数迭代更新生成网络、判别网络以及自编码网络。嵌入网络和恢复网络将原始样本进行自编码, 生成网络输入为随机噪声, 输出为与原始样本相似的合成样本。将原始样本与合成样本同时输入判别网络中, 由判别网络判断输入样本是否为原始样本, 判别结果用于更新生成对抗组件, 通过多次迭代更新, 该模型可以有效生成高质量的故障样本用于增强原始数据集, 相比原始 TimeGAN 模型数据增强效果更显著。

算法 2 Nadam-TimeGAN 算法

定义随机噪声 Z 和原始故障数据 D ;

- 1) 数据预处理, 包括归一化等;
- 2) 训练嵌入网络;
- 3) 训练恢复网络;
- 4) for i to n do:
- 5) 训练生成网络;
- 6) 训练判别网络;
- 7) 计算损失 $Loss = L_1 + L_2$, L_1 和 L_2 分别表示自编码器重建损失和生成对抗组件损失;
- 8) 使用损失函数和 Nadam 优化函数优化各网络组件;
- 9) end for

10) 使用训练好的TimeGAN模型生成故障数据样本。

算法2步骤8)使用Nadam优化函数优化TimeGAN的网络结构,具体如算法3所示。

算法3 Nadam优化算法

定义指数衰减率 $\beta_1, \beta_2 \in [0, 1)$, 第一阶矩(均值) $m_0 = 0$, 第二阶矩(非中心方差) $v_0 = 0$, 时间步长 $t = 0$, 学习率 η , 随机目标函数 $f(\theta_t)$:

- 1) while θ_t 不收敛 do
- 2) 更新时间 $t = t + 1$;
- 3) 更新梯度 g_t ;
- 4) 更新第一阶矩 $m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t$;
- 5) 更新第二阶矩 $v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$;
- 6) 偏差校正第一阶矩 $\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$;
- 7) 偏差校正第二阶矩 $\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$;
- 8) 更新 $\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t$;
- 9) end while
- 10) 用当前动量矢量 \hat{m}_t 的偏置校正估计取代之
前时间步长 \hat{m}_{t-1} 的偏置校正估计。

本文使用基于GRU的Nadam-TimeGAN模型对原始数据进行训练和生成, Nadam-TimeGAN模型的4个网络(嵌入网络、恢复网络、生成网络和判别网络)结构主要由GRU组成,具体如表1所示。其中,训练迭代次数为10 000,使用Nadam优化器,初始学习率为0.001。

层数	名称	隐藏神经元个数	激活函数
0(4个网络)	输入层	dim×1	—
1~3(4个网络)	GRU	dim×24	tanh
4(判别网络)	全连接层	dim×24	—
4(其他3个网络)	全连接层	dim×24	sigmoid

2.3 基于XGBoost的分类模型

通过Nadam-TimeGAN网络模型对原始数据增强,得到一套高质量的合成样本数据集,使用XGBoost算法训练分类模型。XGBoost是GBDT的改进,其目标函数的正则项中加入了决策树模型的复杂度,避免了模型过拟合,在泛化能力上比GBDT效果更佳。GBDT在模型训练中仅引入了一阶导数

的信息,而XGBoost则对目标函数进行泰勒二阶展开,同时使用了一阶和二阶导数的信息,大大提高了模型的优化速度。XGBoost作为一种集成学习算法,主要原理是通过构建若干个简单的弱分类器,组合成性能更高的强分类器。XGBoost训练过程如图4所示。

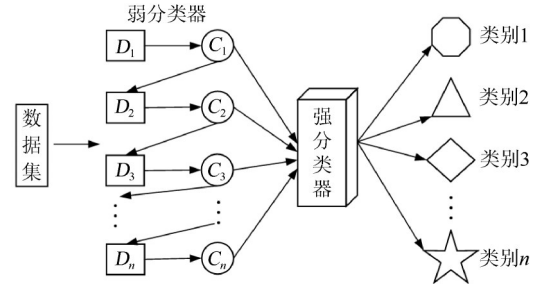


图4 XGBoost训练过程

2.4 模型的有效性检验

2.4.1 分类评价指标

混淆矩阵是评判分类模型的指标,用于统计分类器的准确度和误差。假设只有正类和负类,定义关注的类为正类,其他类为负类。混淆矩阵结构如表2所示。

真实标签	预测标签	
	正类	负类
正类	TP(true positive)	FN(false negative)
负类	FP(false positive)	TN(true negative)

准确率:模型预测正确的样本数量所占样本总量的比例,计算式为

$$accuracy = \frac{TP + TN}{TP + FN + TN + FP} \quad (19)$$

召回率:模型预测为正样本的数量在实际正样本数量中所占的百分比,计算式为

$$recall = \frac{TP}{TP + FN} \quad (20)$$

F1-score:精确率和召回率的加权调和平均,常用于评价分类模型的好坏,计算式为

$$F1-score = \frac{2 \times precision \times recall}{precision + recall} \quad (21)$$

$$precision = \frac{TP}{TP + FP} \quad (22)$$

2.4.2 Nadam-TimeGAN评价指标

可视化是在原始数据集和合成数据集上应用t-SNE和PCA分析使时间维度扁平化。通过可视化

真实样本与合成样本在二维空间中分布，给出定性评估。

判别分数 post-hoc RNN 是一种基于循环神经网络的事后处理过程。通过构建一个事后时间序列分类模型来区分原始数据集和生成数据集序列。首先，将每个原始序列标记为实序列，将每个合成序列标记为非实序列。然后，训练一个 2 层 LSTM 分类器作为标准监督任务来区分这 2 个类，判别分数的取值为|分类准确率-0.5|，如式(23)所示。判别分数越低，表明真实数据集和合成数据集之间的相似性越高，即数据合成效果更好。具体流程如算法 4 所示。

$$\text{discriminative_score} = |\text{accuracy} - 0.5| = \left| \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FN} + \text{TN} + \text{FP}} - 0.5 \right| \quad (23)$$

算法 4 判别分数算法

- 定义随机噪声 Z 和原始故障数据 D;
- 1) 初始化原始数据和合成数据;
- 2) 构建一个 post-hoc RNN 判别器;
- 3) 原始数据调用判别器;
- 4) 合成数据调用判别器;
- 5) for *i* to *n* do:
- 6) 训练判别器;
- 7) 计算损失;
- 8) 使用 Nadam 优化函数进行优化;
- 9) end for
- 10) 在测试集上评估判别器性能，得到真实数据和生成数据的预测输出;
- 11) 预测分类准确率;
- 12) 输出判别分数，取值为|分类准确率-0.5|。

3 实验与分析

本文选取 3 个不同的故障数据集分别进行验证性实验和泛化性实验，以证明所提方法的有效性和泛化性。为了降低由偶然因素或随机性引起的实验结果波动，所有的实验均重复多次，并将这些实验结果的平均值作为最终的实验结果。

3.1 数据来源

本文使用了 3 个时序故障数据集：转辙机动作电流数据集、MFPT 轴承数据集和 CWRU 轴承数据集，3 个故障数据集分别来自自采数据集以及公开标准数据集，数据形式均是一维时间序列信号。本文在转辙机动作电流数据集上进行了验证性实验，

在 MFPT 和 CWRU 数据集上进行了泛化性实验。

3.1.1 转辙机动作电流数据集

该数据集数据来自某铁路站点记录的 ZD7 号道岔电流数据，采样精度为 0.000 1，采样频率为 512 Hz。以转辙机动作电流信号为研究对象，使用了单机牵引道岔的 6 类典型故障，选用包括正常模式在内的 7 类，标签分别记为 0~6，其中 6 表示正常模式的数据，每类故障数据样本数为 500 条，正常数据样本数为 5 034 条。

3.1.2 MFPT 轴承数据集

该数据集包括轴承试验台的数据（标准轴承数据、各种载荷下的外圈故障和各种载荷下的内圈故障）和 3 个真实世界的故障数据。其中，3 个标准数据集分别以 97 656 Hz 采样 6 s；7 个外圈故障数据集分别以 48 828 Hz 采样 3 s；7 个内圈故障数据集分别以 48 828 Hz 采样 3 s。本文根据载荷不同，将一个健康状态轴承和包括内圈故障和滚动体故障在内的 2 个故障轴承分为 7 类（1 个健康状态和 6 个故障状态），具体情况如表 3 所示，其中 1 磅=0.453 592 4 kg。实验对该数据集的每类数据使用滑动窗口截取信号，窗口为 500，步长为 200，得到每类故障数据样本数为 730 条，正常数据样本数为 2 928 条。

表 3 MFPT 轴承数据集具体情况

数据类型	负载类型/磅	标签
内圈	50	0
	100	1
	150	2
外圈	50	3
	100	4
	300	5
正常数据	270	6

3.1.3 CWRU 轴承数据集

该数据集在 4 种不同的电机负载下，采集了正常轴承和单点缺陷损坏轴承在 12 kHz 和 48 kHz 的振动信号。每种工况下包含了滚动体故障、内圈故障和外圈故障，其中外圈故障又分为 3 个不同位置，分别为 3 点钟、6 点钟、12 点钟。每个故障部位数据中又区分了不同的故障直径（0.007 英寸、0.014 英寸、0.021 英寸以及 0.028 英寸），每个故障直径根据不同的电机负载情况划分了 0 马力、1 马力、2 马力、3 马力负载下的数据，其中 1 英寸=

2.54 cm, 1 马力=0.735 kW。本文使用的是驱动端轴承故障数据, 采样频率为 12 kHz、电机载荷为 0 马力, 具体情况如表 4 所示。使用滑动窗口的方法对故障数据进行截取, 窗口和步长大小分别为 500 和 200, 得到每类故障数据样本数为 608 条, 正常数据样本数为 1 218 条。

表4 CWRU 轴承数据集具体情况

数据类型	故障直径/英寸	标签
内圈	0.007	0
	0.014	1
	0.021	2
滚动体	0.007	3
	0.014	4
	0.021	5
外圈(6点钟)	0.007	6
	0.014	7
正常数据	0.021	8
	无	9

3.2 数据处理

在输入 TimeGAN 模型之前, 需对数据集进行预处理, 包括缺失值填充、去噪和异常值处理。在上述处理后进行样本特征提取。对故障信号进行特征提取在提高故障分类准确率中至关重要, 本文使用基于统计方法的特征提取, 提取数据信号的波形特征作为新的特征矢量用于模型训练任务。该方法通过对数据的整体统计分析和特征提取, 可反映信号在一段时间内的整体特点和变化趋势。实验选取时域的基本统计特征, 包括均值、标准差、方差、最小值、最大值、峰值、偏度以及峰度。其中偏度可以用来度量随机变量概率分布的不对称性, 取值范围为 $(-\infty, +\infty)$, 当偏度小于 0 时, 概率分布图左偏; 当偏度等于 0 时, 表示数据相对均匀地分布在平均值两侧, 但不一定是绝对的对称分布; 当偏度大于 0 时, 概率分布图右偏。偏度具体定义式为

$$S = \frac{1}{n} \sum_{i=1}^n \left[\left(\frac{x_i - \mu}{\sigma} \right)^3 \right] \quad (24)$$

其中, μ 表示均值, σ 表示标准值。峰度可以用来度量随机变量概率分布的陡峭程度, 取值范围为 $[1, +\infty)$, 完全服从正态分布的数据的峰度值为 3, 峰度值越大, 概率分布图越高尖, 峰度值越小, 概率分布图越矮胖。峰度具体定义式为

$$K = \frac{1}{n} \sum_{i=1}^n \left[\left(\frac{x_i - \mu}{\sigma} \right)^4 \right] \quad (25)$$

3.3 实验环境

本文的实验环境配置如表 5 所示。

表5 实验环境配置

名称	配置信息
操作系统	Windows10
处理器	Intel(R) Core(TM) i7-10700F CPU
内存	16.00GB
开发语言	Python3.7
开发依赖	Numpy1.21.6, Tensorflow2.10.0
开发环境	Pycharm

3.4 验证性实验

3.4.1 基于Nadam-TimeGAN的合成样本实验

本节通过相关故障数据集来验证所提方法在不平衡数据集故障诊断中的有效性。使用 ZD7 型转辙机动作电流数据集, 首先对原始数据样本进行预处理, 即提取时域特征参数作为新的特征向量。然后将故障数据的特征输入 TimeGAN 模型中并扩充至一定数量, TimeGAN 分别基于 GRU 与 LSTM 网络单元生成数据样本并通过可视化和判别分数进行评价。最后选取较优的 GRU 网络单元作为 TimeGAN 的组成部分。在此基础上, 采用 Nadam 优化函数对 TimeGAN 模型进行改进, 之后将原始不平衡故障数据输入 Nadam-TimeGAN 中进行合成样本实验。实验分别使用了 2 种网络对标签为 0~5 的 6 类故障数据进行对抗训练并生成, 同时对生成的样本进行评价。在原始 TimeGAN 的训练过程中, 每类样本的批处理大小固定为 10, 迭代次数设置为 10 000。经过训练后, 该数据增强模型为 6 类故障各生成 4 890 个新样本。表 6 为转辙机动作电流信号数据集样本数。

表6 转辙机动作电流信号数据集样本数

数据 标签	原始 样本数	合成 样本数	实验 a、b 和 c 样本数	实验 d 样本数	实验 e 和 f 样本数
0	500	4 890	5 000	200	500
1	500	4 890	5 000	450	500
2	500	4 890	5 000	500	500
3	500	4 890	5 000	300	500
4	500	4 890	5 000	350	500
5	500	4 890	5 000	400	500
6	5 034	—	5 000	4 500	500

表7是基于GRU和LSTM的TimeGAN生成数据的判别分数对比。由表7可知，基于GRU网络的TimeGAN生成数据的判别分数低于基于LSTM网络的TimeGAN生成数据的判别分数，即在转辙机动作电流数据集上，GRU网络的生成数据效果高于LSTM网络。因此，本文在故障分类模型的训练中选取使用基于GRU的TimeGAN生成的故障样本作为扩充数据。

表7 基于GRU和LSTM的TimeGAN生成数据的判别分数对比

数据标签	TimeGAN-GRU	TimeGAN-LSTM
0	0.266	0.358
1	0.244	0.497
2	0.322	0.372
3	0.252	0.267
4	0.336	0.384
5	0.218	0.375


在选取基于GRU的网络单元作为TimeGAN模型各网络的组成部件后，使用2.2节提到的Nadam优化方法对原始TimeGAN结构进行优化，使用优化后的Nadam-TimeGAN对6类故障数据重新进行合成样本实验。表8是所提模型和原始TimeGAN采用GRU网络单元的判别分数对比。判别分数越低，表示生成的新数据与原始数据更相似，由表8可知，所提模型在标签为0、1、2、3、4的故障类别上的判别分数低于原始TimeGAN模型，即所提模型较原始模型生成新数据的质量更好，进一步证明了Nadam-TimeGAN的有效性。

表8 所提模型和原始TimeGAN采用GRU网络单元的判别分数对比


数据标签	Nadam-TimeGAN	TimeGAN
0	0.207	0.266
1	0.203	0.244
2	0.192	0.322
3	0.200	0.252
4	0.185	0.336
5	0.254	0.218

图5是转辙机动作电流数据集下标签0使用基于GRU的Nadam-TimeGAN生成的合成样本与原始样本的PCA和t-SNE可视化效果。从图5中可以看出，由Nadam-TimeGAN生成的合成样本与真实样本在PCA和t-SNE可视化后都近乎同步，从分布形态和位置2个方面可见，低维度下两簇重合效果

好，两簇关键特征的相似性在图中显示为两簇位置重合。数据生成结果表明，基于Nadam-TimeGAN的数据增强方法在故障数据生成上是可行的。



(a) 标签0的PCA可视化结果



(b) 标签0的t-SNE可视化结果

图5 转辙机动作电流数据集可视化结果

3.4.2 基于XGBoost的分类实验

经过上述数据增强后，得到了一套高质量的合成样本，结合原始样本，构建一个平衡的正常/故障样本数据集，实验数据类别为6类故障数据（标签为0~5）以及正常数据（标签为6）共7类。将数据集80%的样本作为训练集，20%的样本作为测试集，输入XGBoost集成学习算法进行训练得到分类模型。

XGBoost中的参数为通用参数、提升参数以及学习任务参数。其中通用参数用于设置XGBoost模型的整体功能，提升参数用于选择每次的弱分类器，学习任务参数用于指导优化任务的执行。实验中为了选择效果更好的XGBoost，使用sklearn提供的GridSearchCV方法对模型的主要参数进行调优，结果如表9所示。

表 9 XGBoost 主要参数选择

参数名称	参数描述	参数取值
max_depth	树的最大深度	8
min_child_weight	设置孩子节点中的最小样本权重和	1
gamma	叶节点进行分支所需损失减小的最小值	0.4
subsample	对训练集的二次抽样比例,防止过拟合	0.8
colsample_bytree	构建每棵树的子抽样比例	0.8
learning_rate	指定学习率	0.2

使用调优后的 XGBoost 模型对平衡数据集进行训练分类,图 6 显示了训练集和测试集的学习曲线。从学习曲线上可以看到,训练集和测试集的损失随着迭代次数的增加而逐渐减小,趋于平稳且最后收敛到一个稳定的值,表明模型的训练效果较好。测试集和训练集的损失在趋于平稳后接近,表明模型在测试数据集上的泛化性能较好。




图 6 训练集和测试集的学习曲线

转辙机动作电流数据集分类混淆矩阵如图 7 所示,图中对角线位置表示预测标签与真实标签相同,对角线上的数值越大,表示分类准确率越高。由图 7 可知,本文所提方法分类效果良好,在 7 类数据上的准确率均达到了 98% 以上,在标签 0、5、6 上更是达到了 100%,进一步证明了本文所提方法的有效性。

为了更准确地验证分类结果,使用基于 GRU 的 Nadam-TimeGAN (实验 a)、基于 GRU 的 TimeGAN (实验 b)、基于 LSTM 的 TimeGAN (实验 c)、原始不平衡数据集 (实验 d)、原始平衡数据集 (实验 e) 以及与原始平衡数据集样本个数相同的基于 GRU 的 Nadam-TimeGAN (实验 f) 6 种方法对原始数据进行处理,之后分别和 XGBoost、GBDT 以及 LightGBM 这 3 种集成学习算法训练分类模型并使用相关评价指标对实验结果进行定量评

估。6 类实验所采用的数据集样本数如表 6 所示,对样本进行等距采样,使实验中所用到的样本在时间上均匀分布,获取时间序列数据全面且平衡的代表性样本集。其中,实验 a、b、c 个数相同,实验 d 为原始不平衡数据,实验 e 和 f 个数相同。表 10 展示了 6 类实验的所提方法与其他方法对比结果,表中相关评价指标均为多次实验后所有类别的平均准确率、平均召回率和平均 F1-score,这些平均指标提供了一个整体性能评估,考虑了所有类别的贡献,并为不平衡数据集提供了更公平的评估。




图 7 转辙机动作电流数据集分类混淆矩阵

表 10 6 类实验的所提方法与其他方法对比结果

实验	方法	准确率	召回率	F1-score	
a	Nadam-TimeGAN	XGBoost	99.21%	99.21%	0.992 2
	LightGBM	98.81%	98.81%	0.988 2	
	GBDT	98.74%	98.74%	0.987 5	
b	TimeGAN-GRU	XGBoost	98.67%	98.67%	0.986 3
		LightGBM	97.91%	97.90%	0.979 2
		GBDT	98.04%	98.03%	0.980 5
c	TimeGAN-LSTM	XGBoost	93.21%	93.21%	0.932 2
		LightGBM	92.29%	92.27%	0.922 8
		GBDT	92.67%	92.67%	0.926 3
d	原始不平衡数据集	XGBoost	94.91%	94.55%	0.946 4
		LightGBM	94.66%	93.63%	0.944 2
		GBDT	94.25%	93.91%	0.943 2
e	原始平衡数据集	XGBoost	96.76%	96.19%	0.961 5
		LightGBM	96.09%	96.30%	0.962 8
		GBDT	95.43%	95.66%	0.956 0
f	Nadam-TimeGAN	XGBoost	95.43%	95.78%	0.957 6
		LightGBM	95.84%	95.08%	0.951 7
		GBDT	95.38%	95.30%	0.953 3

分析表 10 可知, 实验 a 数据增强后的分类结果均高于实验 b 和 c 数据增强后的分类结果, 且实验 b 数据增强后的分类结果均高于实验 c 数据增强后的分类结果。对实验 d 直接使用 XGBoost、LightGBM 和 GBDT 这 3 种分类算法进行故障诊断的结果均较差, 表明对原始不平衡数据集进行数据增强非常有必要。对实验 e 直接使用 XGBoost、LightGBM 和 GBDT 这 3 种分类算法进行故障诊断的结果较实验 d 结果好, 表明不平衡数据集中类别样本数量存在显著差异, 会对模型的性能产生影响, 需要构建平衡数据集。实验 f 对原始故障进行数据增强后, 选取样本数与实验 e 相同的个数进行诊断实验, 结果表明实验 e 和实验 f 结果接近, 但均低于实验 a 的结果, 进一步说明所提方法对不平衡数据进行数据增强的可行性。在上述 6 种情况下, XGBoost 算法的结果较另外 2 种算法均更高, 表明本文所提方法的有效性与优越性。

本节在使用 Nadam-TimeGAN 数据生成后, 将合成数据与原始数据合并训练分类模型, 在测试集上测试分类效果, 充分体现出数据增强对不平衡数据故障诊断的意义。实验结果表明, 本文使用基于 GRU 的 Nadam-TimeGAN 扩充后的数据集通过 XGBoost 算法分类的效果都表现良好。3.5 节将基于 MPFT 轴承数据集和 CWRU 轴承数据集对本文方法进行泛化性验证。

3.5 泛化性实验

3.5.1 使用 MFPT 轴承数据集的故障诊断实验

本节采用机械故障预防学会的轴承数据集, 在该数据集上对本文方法进行泛化性验证, 数据集组成如 3.1.2 节所示。根据本文方法首先对原始数据进行预处理并提取时域特征作为新的特征。将故障数据的特征输入 Nadam-TimeGAN 模型中, 为 6 类故障各生成 7 190 个样本。表 11 为 MFPT 轴承数据集样本数。

表 12 为使用所提模型和分别基于 GRU 和 LSTM 的 TimeGAN 模型生成数据的定量评价指标结果对比。由表 12 中 3、4 列数据可以看出, 该数据集上 6 类故障数据在使用 LSTM 的 TimeGAN 的判别分数都高于使用 GRU 的 TimeGAN, 表明使用 GRU 网络单元的 TimeGAN 生成样本的质量更好, 更接近原始样本。由表 12 中 2、3 列数据可以看出, 所提 Nadam-TimeGAN 模型的判别分数在标签 0、

2、3、4、5 上均低于使用 GRU 作为原始 TimeGAN 模型组成单元的判别分数, 表明所提方法的可行性。

表 11 MFPT 轴承数据集样本数

数据 标签	原始 样本数	合成 样本数	实验 a、b 和 c 样本数	实验 d 样本数	实验 e 和 f 样本数
0	730	7 190	2 500	700	730
1	730	7 190	2 500	400	730
2	730	7 190	2 500	650	730
3	730	7 190	2 500	550	730
4	730	7 190	2 500	600	730
5	730	7 190	2 500	350	730
6	2 928	—	2 500	2 500	730

表 12 使用所提模型和分别基于 GRU 和 LSTM 的 TimeGAN 模型生成数据的定量评价指标结果对比

数据标签	Nadam- TimeGAN	TimeGAN-GRU	TimeGAN- LSTM
0	0.297	0.301	0.337
1	0.327	0.318	0.362
2	0.243	0.243	0.326
3	0.227	0.329	0.362
4	0.254	0.287	0.336
5	0.202	0.303	0.344

图 8 为 MFPT 数据集标签为 3 的故障数据使用所提方法合成数据的 PCA 和 t-SNE 可视化结果。从图 8 中可以看出, 由 Nadam-TimeGAN 生成的合成数据与原始数据可视化后的重叠性都较高, 说明了通过所提模型生成的样本与原始故障样本相似性较高, 可以用于原始故障数据集的扩充, 也证明了基于 GRU 的 Nadam-TimeGAN 模型可以用于生成高质量数据对原始不平衡数据进行增强。图 8 中 2 类样本在二维空间上分布一致但又不完全相同, 说明通过生成对抗网络生成的样本点在保留了原始样本特征的同时, 还增加了故障样本信息的多样性。

数据样本生成后, 实验将原始数据样本和生成的数据样本进行合并得到新的数据集, 以 8 : 2 划分训练集和测试集, 输入 XGBoost 集成学习算法中训练分类器。使用 GridSearchCV 方法对 XGBoost 中的参数进行优化, 在对模型参数调整后, 使用优化后的 XGBoost 模型训练分类器, 得到 MFPT 轴承数据集分类混淆矩阵如图 9 所示, 标签 1、2、5、6 的分类准确率达到 98% 以上。

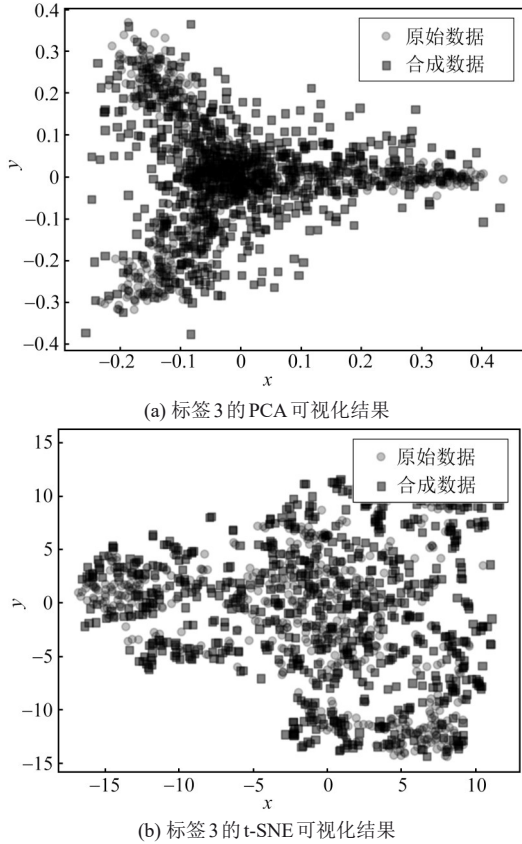


图 8 MFPT 轴承数据集可视化结果




图 9 MFPT 轴承数据集分类混淆矩阵

为了更准确地验证分类结果,在该数据集上也分别使用所提方法(实验 a)、基于 GRU 和 LSTM 的 TimeGAN (实验 b、c) 进行数据增强,原始不平衡数据集(实验 d)和原始平衡数据集(实验 e),与实验 e 样本数一致的基于 GRU 的 Nadam-TimeGAN (实验 f) 共 6 种数据处理方法进行数据增强,之后输入 XGBoost、GBDT 以及 LightGBM 这 3 种集成学习算法训练分类模型并使用相关评价

指标对实验结果进行定量评估。

表 13 展示了所提方法与其他方法在 MFPT 数据集对比结果。由表 13 可看出,实验 b 数据增强后的分类结果均高于实验 c 的分类结果,且实验 a 数据增强后的分类结果均高于上述 2 种情况。在 3 种情况下,XGBoost 算法的结果较另外 2 种算法均更高,在本文所提分类模型中 3 种指标分别达到 97.99%、97.99% 和 0.979 8。实验结果再次表明,基于 Nadam-TimeGAN 和 XGBoost 的方法在小样本不平衡数据集上表现较好。使用实验 d 直接采用 3 种集成学习算法进行分类,其准确率、召回率和 F1-score 均最低,再次表明对不平衡数据进行数据增强的必要性。实验 e 和实验 f 使用同样样本集数量,分别构建原始平衡数据集和本文所提方法进行数据增强后的平衡数据集,使用 3 种集成学习算法进行分类后,3 种评价指标均接近,且 XGBoost 算法较 LightGBM 和 GBDT 较优,进一步表明本文所提方法的有效性。实验 a 相比实验 e 的结果较优,再次证明对原始不平衡数据进行数据增强的必要性以及所提方法的优越性。

表 13 所提方法与其他方法在 MFPT 数据集对比结果

实验	方法	准确率	召回率	F1-score	
a	Nadam-TimeGAN	XGBoost	97.99%	97.99%	0.979 8
		LightGBM	97.91%	97.89%	0.978 9
		GBDT	97.38%	97.36%	0.973 6
b	TimeGAN-GRU	XGBoost	97.81%	97.81%	0.978 6
		LightGBM	97.24%	97.30%	0.973 1
		GBDT	96.22%	96.19%	0.962 0
c	TimeGAN-LSTM	XGBoost	96.95%	96.95%	0.970 0
		LightGBM	96.80%	96.73%	0.967 4
		GBDT	96.12%	96.09%	0.960 4
d	原始不平衡数据集	XGBoost	93.54%	93.53%	0.935 2
		LightGBM	93.15%	93.22%	0.932 1
		GBDT	92.95%	92.95%	0.929 3
e	原始平衡数据集	XGBoost	97.19%	97.07%	0.970 8
		LightGBM	97.06%	96.94%	0.969 5
		GBDT	96.35%	96.11%	0.962 6
f	Nadam-TimeGAN	XGBoost	96.92%	95.37%	0.953 0
		LightGBM	96.62%	96.46%	0.964 9
		GBDT	96.22%	96.07%	0.960 8

3.5.2 使用 CWRU 轴承数据集的故障诊断实验

本节采用了 CWRU 轴承数据中心提供的滚动轴承振动数据集,并在该数据集上对本文提出的方

法进行泛化性研究。将 9 类故障数据的特征输入 Nadam-TimeGAN 模型中各合成 5 960 个左右新样本。表 14 为 CWRU 轴承数据集样本数。

表 14 CWRU 轴承数据集样本数


数据标签	原始样本数	合成样本数	实验 a、b、f、g、h 和 i 样本数	实验 c 样本数	实验 d 和 e 样本数
0	604	5 930	1 218	600	600
1	607	5 960	1 218	480	600
2	609	5 980	1 218	300	600
3	611	6 000	1 218	500	600
4	607	5 960	1 218	350	600
5	608	5 970	1 218	400	600
6	608	5 970	1 218	550	600
7	607	5 960	1 218	500	600
8	610	5 990	1 218	610	600
9	1 218	—	1 218	1 200	600

表 15 显示了使用 2 种网络单元的 TimeGAN 和所提 Nadam-TimeGAN 模型生成数据的定量评价指标结果对比。在该数据集上，使用 GRU 网络的生成数据效果同样好于 LSTM 网络，且所提模型生成数据的效果在 9 类故障数据上依旧表现最优，再次表明使用 GRU 网络单元的 Nadam-TimeGAN 能生成质量较优的样本。


表 15 使用 2 种网络单元的 TimeGAN 和所提 Nadam-TimeGAN 模型生成数据的定量评价指标结果对比

数据标签	Nadam-TimeGAN	TimeGAN-GRU	TimeGAN-LSTM
0	0.168	0.277	0.332
1	0.220	0.307	0.419
2	0.297	0.283	0.334
3	0.242	0.319	0.360
4	0.239	0.238	0.317
5	0.313	0.268	0.375
6	0.219	0.260	0.427
7	0.173	0.259	0.309
8	0.216	0.263	0.313

图 10 为 CWRU 数据集标签为 4 的故障数据使用基于 GRU 的 Nadam-TimeGAN 模型扩充后的 PCA 和 t-SNE 可视化结果。从图 10 中可以看出，由基于 GRU 的 Nadam-TimeGAN 生成的合成数据集使用 PCA 和 t-SNE 进行可视化后与原始数据的重叠都表现较好，再次表明使用所提方法进行数据增强的可行性。



(a) 标签 4 的 PCA 可视化结果



(b) 标签 4 的 t-SNE 可视化结果

图 10 MFPT 轴承数据集可视化结果

数据样本生成后，实验将原始数据样本和生成的数据样本进行合并得到新的平衡数据集。最后将平衡数据集按 8 : 2 划分为训练集和测试集，输入 XGBoost 集成学习算法中进行分类训练。

为了进一步验证本文所提方法在不平衡数据集下故障诊断的高效性，设计了 9 种不同的实验，不同分类方法在 CWRU 数据集上对比结果如表 16 所示。除本文所提方法，包括在原始不平衡数据（实验 c）、原始平衡数据集（实验 d）之下的各类集成学习算法的分类结果，以及在 TimeGAN（实验 b）、与实验 d 同样本数的 Nadam-TimeGAN（实验 e）、SMOTE（实验 f）等模型进行数据增强后，使用 XGBoost、GBDT 和 LightGBM 这 3 种集成学习算法进行分类。同时加入了 DCGAN-CNN（实验 g）、MLP（实验 h）以及 FCN（实验 i）等分类方法的对比。其中，实验 a、b、f、g、h 和 i 采样样本数量一致，实验 d 和 e 采样样本数量一致。MLP 通过叠加 3 个全连接层，每个全连接层设定 500 个神经元，遵循 2 个设计规则：在每层的输入处使用 dropout

来提高泛化能力;使用修正线性单元(ReLU, rectified linear unit)作为激活函数,防止网络深度时梯度饱和。该网络以一个softmax层结束。FCN的基本块是一个卷积层,然后是一个批处理归一化层和一个ReLU激活层,最终输出仍然来自softmax层。

表16 不同分类方法在CWRU数据集上对比结果

实验	方法	准确率	召回率	F1-score	
a	Nadam-TimeGAN	XGBoost	96.34%	96.50%	0.965 6
		LightGBM	96.04%	96.19%	0.962 9
		GBDT	95.83%	95.87%	0.958 5
b	TimeGAN	XGBoost	95.99%	96.13%	0.960 7
		LightGBM	95.47%	95.61%	0.955 7
		GBDT	94.66%	94.84%	0.947 4
c	原始不平衡数据集	XGBoost	92.56%	92.60%	0.925 8
		LightGBM	91.50%	91.53%	0.915 0
		GBDT	91.08%	91.08%	0.908 6
d	原始平衡数据集	XGBoost	95.08%	95.13%	0.951 0
		LightGBM	94.49%	94.41%	0.942 8
		GBDT	94.49%	94.19%	0.941 3
e	Nadam-TimeGAN	XGBoost	94.74%	94.54%	0.941 9
		LightGBM	94.33%	94.13%	0.941 0
		GBDT	94.22%	93.21%	0.933 7
f	SMOTE	XGBoost	92.71%	92.72%	0.927 4
		LightGBM	91.68%	91.74%	0.917 4
		GBDT	92.07%	92.04%	0.920 1
g	DCGAN-CNN	93.98%	93.94%	0.939 1	
h	MLP	89.55%	89.63%	0.895 5	
i	FCN	87.69%	86.07%	0.837 6	

从表16可以看出,在CWRU轴承数据集上,直接使用实验c并采用3种集成学习算法进行分类的结果均较差,再次表明数据增强以及构建平衡数据集的重要性。在原始数据集上构建实验d再输入XGBoost、LightGBM以及GBDT中进行训练和分类,其结果较实验c优。通过本文所提方法对原始数据进行增强,构建与实验d样本数相同的实验e后训练分类器进行分类,其结果较实验d略低但接近,并且实验d和实验e的结果均低于实验a的结果,再次表明使用Nadam-TimeGAN进行数据增强的可行性和优越性。使用实验f进行数据生成后通过3种集成学习的方法训练分类模型得到的结果低于本文方法,SMOTE是在少数类样本及其邻近的样本之间进行插值,并未克服非平衡数据集的数据分布问题,加大了分类算法进行分类的难度。使用GRU作为原始TimeGAN基本单元的实验b进行数据增强后,在3种集成学习算法上的分类指标均优于在实验c上直接分类和使用实验f数据增强后分

类的结果,进一步证明使用TimeGAN进行小样本不平衡数据扩增的必要性。实验g是在使用二维灰度图作为训练集,该方法在模型性能上表现不佳。实验h和实验i的分类结果均较差,这主要是因为神经网络具有强大的非线性拟合能力,但网络隐含层的神经元数量过多,需要较多的训练样本,同时原始故障样本存在不平衡性,上述综合因素导致分类准确率下降。使用本文所提Nadam-TimeGAN模型进行数据增强后通过3种集成学习方法进行分类,其结果均优于表16中其他方法,其中,使用XGBoost进行分类的3种评价指标最优。该泛化性实验结果表明,通过本文所提方法能够对故障样本的整体分布规律进行充分学习,并根据原始故障数据的特征对不平衡数据集加以扩充,有效地克服在原始故障诊断中由数据不平衡造成的分类性能不足的问题。该方法在其他数据集上也有良好特性,具有较高的泛化性,因此可以进行相关故障诊断研究。

4 结束语

本文提出了基于Nadam-TimeGAN和XGBoost不平衡时序信号的故障诊断方法,通过生成高质量的故障数据来克服故障诊断的困难。实验从3个不同的数据集上展开,分别使用了基于GRU和LSTM的TimeGAN对故障数据进行增强,选取了生成效果更佳的GRU网络,基于此使用Nadam优化函数对原始TimeGAN模型各网络进行优化,在得到平衡数据集后,采用XGBoost训练分类模型。实验中还选取了原始不平衡数据集、原始平衡数据集、SMOTE等方法进行对比,结果表明,本文所提方法在不平衡故障数据集上具有有效性与优越性。

本文仅使用了时序信号的时域特征,可能存在特征信息单一导致模型训练困难的问题。TimeGAN模型作为一种较新的生成对抗网络模型,笔者使用该模型对故障数据增强的研究可能不够深入,在今后的工作中需要对时序信号的特征提取以及TimeGAN模型训练进一步研究。

参考文献:

- [1] 来杰,王晓丹,向前,等. 自编码器及其应用综述[J]. 通信学报, 2021, 42(9): 218-230.
- LA I J, WANG X D, XIANG Q, et al. Review on autoencoder and its ap-

- plication[J]. Journal on Communications, 2021, 42(9): 218-230.
- [2] FEI R, WAN Y X, HU B, et al. A novel network core structure extraction algorithm utilized variational autoencoder for community detection[J]. Expert Systems with Applications, 2023, 222: 119775.
- [3] COULIBALY S, KAMSU-FOGUEM B, KAMISSOKO D, et al. Deep convolution neural network sharing for the multi-label images classification[J]. Machine Learning with Applications, 2022, 10: 100422.
- [4] GHOFRANI F, SUN H Y, HE Q. Analyzing risk of service failures in heavy haul rail lines: a hybrid approach for imbalanced data[J]. Risk Analysis, 2022, 42(8): 1852-1871.
- [5] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. Advances in Neural Information Processing Systems, 2014, 27: 1-9.
- [6] RUAN D W, SONG X Z, GÜHMANN C, et al. Collaborative optimization of CNN and GAN for bearing fault diagnosis under unbalanced datasets[J]. Lubricants, 2021, 9(10): 105.
- [7] MA J Q, JIANG X X, HAN B K, et al. Dynamic simulation model-driven fault diagnosis method for bearing under missing fault-type samples[J]. Applied Sciences, 2023, 13(5): 2857.
- [8] WANG R G, CHEN Z Y, ZHANG S H, et al. Dual-attention generative adversarial networks for fault diagnosis under the class-imbalanced conditions[J]. IEEE Sensors Journal, 2022, 22(2): 1474-1485.
- [9] WANG R G, ZHANG S H, CHEN Z Y, et al. Enhanced generative adversarial network for extremely imbalanced fault diagnosis of rotating machine[J]. Measurement, 2021, 180: 109467.
- [10] YOON J, JARRETT D, SCHAAR M. Time-series generative adversarial networks[J]. Advances in Neural Information Processing Systems, 2019, 32: 1-11.
- [11] 黄开远, 罗娜. 基于 Attention 机制改进 TimeGAN 的小样本时间序列预测方法[J]. 华东理工大学学报(自然科学版), 2023, 49(6): 890-899.
- HUANG K Y, LUO N. Improved TimeGAN based on Attention for time series prediction method with few shot[J]. Journal of East China University of Science and Technology, 2023, 49(6): 890-899.
- [12] ZHONG S P, WANG X M, XU B, et al. Hybrid network model based on data enhancement for short-term power prediction of new PV plants[J]. Journal of Modern Power Systems and Clean Energy, 2024, 12(1): 77-88.
- [13] SHI Y L, LI J C, LI H G, et al. An imbalanced data augmentation and assessment method for industrial process fault classification with application in air compressors[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3521510.
- [14] SHI H B, XU Y P, DING B D, et al. Long-term solar power time-series data generation method based on generative adversarial networks and sunrise - sunset time correction[J]. Sustainability, 2023, 15(20): 14920.
- [15] LU J, LIU Z L, ZHANG W J, et al. Pressure prediction study of coal mining working face based on nadam-LSTM[J]. IEEE Access, 2023, 11: 83867-83880.
- [16] SUN X L, XIE M K, ZHOU F, et al. Hierarchical evolutionary construction of neural network models for an Atkinson cycle engine with double injection strategy based on the PSO-Nadam algorithm[J]. Fuel, 2023, 333: 126531.
- [17] QIAO M Y, TANG X X, SHI J K, et al. Bearing fault diagnosis based on natural adaptive moment estimation algorithm and improved octave convolution[J]. IEEE Access, 2020, 8: 196790-196803.
- [18] 李占山, 刘兆庚. 基于 XGBoost 的特征选择算法[J]. 通信学报, 2019, 40(10): 101-108.
- LI Z S, LIU Z G. Feature selection algorithm based on XGBoost[J]. Journal on Communications, 2019, 40(10): 101-108.
- [19] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [20] FANG W, ZHANG F H, SHENG V S, et al. A method for improving CNN-based image recognition using DCGAN[J]. Computers, Materials & Continua, 2018, 57(1): 167-178.
- [21] 司念文, 张文林, 屈丹, 等. 卷积神经网络表征可视化研究综述[J]. 自动化学报, 2022, 48(8): 1890-1920.
- SI N W, ZHANG W L, QU D, et al. Representation visualization of convolutional neural networks: a survey[J]. Acta Automatica Sinica, 2022, 48(8): 1890-1920.
- [22] 周翰逊, 陈晨, 冯润泽, 等. 基于值导数 GRU 的移动恶意软件流量检测方法[J]. 通信学报, 2020, 41(1): 102-113.
- ZHOU H X, CHEN C, FENG R Z, et al. Mobile malware traffic detection approach based on value-derivative GRU[J]. Journal on Communications, 2020, 41(1): 102-113.
- [23] DANG B L, NGUYEN-XUAN H, WAHAB M A. An effective approach for VARANS-VOF modelling interactions of wave and perforated breakwater using gradient boosting decision tree algorithm[J]. Ocean Engineering, 2023, 268: 113398.
- [24] 朱晓荣, 张佩佩. 基于 GAN 的异构无线网络故障检测与诊断算法[J]. 通信学报, 2020, 41(8): 110-119.
- ZHU X R, ZHANG P P. Fault detection and diagnosis method for heterogeneous wireless network based on GAN[J]. Journal on Communications, 2020, 41(8): 110-119.

[作者简介]



黑新宏 (1976-), 男, 陕西延安人, 博士, 西安理工大学教授、博士生导师, 主要研究方向为智能系统与安全关键系统、人工智能、大数据及其在轨道交通等系统中的应用。

高苗 (2000-), 女, 陕西宝鸡人, 西安理工大学硕士生, 主要研究方向为故障诊断。

张宽 (1998-), 男, 陕西西安人, 西安理工大学硕士生, 主要研究方向为故障诊断。

费蓉 (1980-), 女, 陕西西安人, 博士, 西安理工大学教授、博士生导师, 主要研究方向为社区发现、随机优化算法、故障诊断。

邱原 (1983-), 男, 陕西西安人, 博士, 西安理工大学讲师, 主要研究方向为时空数据检索、数据挖掘和自动语音识别。

姬文江 (1984-), 男, 陕西延安人, 博士, 西安理工大学副教授、博士生导师, 主要研究方向为智能交通系统、智能和安全关键系统。