

DOI: 10.19783/j.cnki.pspc.250222

基于条件变分自编码器与改进 ConvXGB 模型的 二次设备小样本故障诊断方法

张洪嘉, 戴志辉, 贺欲飞, 贾文超

(河北省分布式储能与微网重点实验室(华北电力大学), 河北 保定 071003)

摘要: 为解决在二次设备故障诊断过程中小样本数据对模型判别准确率存在较大影响的问题, 构建基于条件变分自编码器(conditional variational autoencoder, CVAE)与改进卷积极限梯度提升(convolutional extreme gradient boosting, ConvXGB)模型的二次设备小样本故障诊断方法。首先, 梳理二次设备故障类型与故障特征信息, 形成故障信息特征集。其次, 利用 CVAE 对特定小样本数据进行数据增强, 形成平衡数据集, 并通过主成分分析法与 t-SNE 算法对 CVAE 的潜在空间进行降维可视化处理。最后, 引入自注意力机制, 在 ConvXGB 模型激活函数层后添加压缩与激励网络模块, 对数据特征进行重新学习, 实现特征权重的自适应分配, 完成对故障信息的特征提取与故障类型的诊断。算例分析表明, 所提方法在不平衡数据集下, 训练集与测试集准确率分别为 98.86%和 97.75%, 能够很好地解决小样本数据的影响, 实现二次设备故障类型的快速准确诊断。

关键词: 二次设备; 故障诊断; 小样本学习; 数据增强; 深度学习

Small-sample fault diagnosis method for secondary equipment based on conditional variational autoencoder and improved ConvXGB model

ZHANG Hongjia, DAI Zhihui, HE Yufei, JIA Wenchao

(Hebei Key Laboratory of Distributed Energy Storage and Microgrid (North China Electric Power University), Baoding 071003, China)

Abstract: To address the significant impact of small-sample data on the diagnostic accuracy of models in secondary equipment fault diagnosis, a small-sample fault diagnosis method based on a conditional variational autoencoder (CVAE) and an improved convolutional extreme gradient boosting (ConvXGB) model is proposed. First, fault types and corresponding fault feature information of secondary equipment are systematically analyzed to form a fault information feature set. Second, a CVAE is used to perform data augmentation on specific small-sample datasets, generating a balanced dataset. Principal component analysis and t-SNE algorithm are then used to reduce the dimensionality of the CVAE latent space for visualization. Finally, a self-attention mechanism is introduced by adding a squeeze-and-excitation network module after the activation function layer of the ConvXGB model. This enables re-learning of data features and adaptive allocation of feature weights, thereby completing fault feature extraction and fault type diagnosis. Case studies show that, under unbalanced datasets, the proposed method achieves accuracy of 98.86 % and 97.75 % on the training and test sets, respectively, effectively mitigating the influence of small-sample data and enabling rapid and accurate diagnosis of secondary equipment fault types.

This work is supported by the National Natural Science Foundation of China (No. 51877084).

Key words: secondary equipment; fault diagnosis; small-sample learning; data augmentation; deep learning

0 引言

随着我国“双碳”目标的持续推进, 高比例新

能源不断涌入电网, 其较强的不稳定性与随机性给电网安全稳定运行提出更高的要求。智能变电站作为电网六大环节相互衔接的枢纽, 同时也是实现能源转化与控制的平台之一, 为太阳能、风能等新能源的稳定接入提供有力支撑^[1-2]。

基金项目: 国家自然科学基金项目资助(51877084)

二次设备作为智能变电站的核心设施, 其工作的可靠程度决定着智能变电站乃至整个电网的安全稳定运行^[3]。高比例新能源接入所带来的不稳定性与随机性, 要求二次设备在进行监视控制工作时需更加准确稳定, 进而要求调度对二次设备的故障进行更科学的分析和更迅速的处理。近年来, 随着人工智能与大数据技术的不断发展, 深度学习算法逐渐应用于二次设备故障诊断领域^[4-7]。文献[8]通过循环神经网络实现二次设备故障的准确定位; 文献[9]构建信息模型并通过搜索算法确定故障区域, 最终通过概率神经网络对故障区域元件实现准确定位; 文献[10]提出了一种基于门控循环单元的二次设备故障定位方法, 解决了二次设备故障机理复杂、故障特征变化规律难以挖掘的问题; 文献[11]通过 K-近邻算法将故障事件表示为图结构数据, 并基于图注意力网络实现二次设备的故障诊断; 文献[12]利用 Apriori 算法建立故障信号间的关系超图, 通过超图卷积神经网络与 Transformer 模型学习故障特征之间的高阶关系, 实现二次设备故障元件的准确定位与故障类型的准确诊断。深度学习算法能够学习数据之间的关联与特征, 很好地克服经验判断与人为因素的影响。但在现有研究中, 用于二次设备故障诊断的深度学习算法通常需要依赖大量数据样本来进行分析学习, 当某一标签类型数据量不足即为小样本数据时, 会影响算法对故障类型的识别准确度^[13]。因此需要通过小样本学习方法减少故障样本中小样本数据对模型准确率的影响。

小样本学习旨在通过较少的样本数量来实现模型的功能^[14]。在故障诊断领域, 小样本学习主要分为基于数据增强的方法和基于模型优化的方法^[15]。其中, 基于数据增强的方法主要是通过合成少数过采样技术(synthetic minority over-sampling technique, SMOTE)、变分自编码器、生成对抗网络等生成模型对小样本数据进行数据扩充或特征增强: 文献[16]通过对变分自编码器的改进, 克服数据生成的盲目性, 生成了特征上更加接近原始样本的新样本; 文献[17]提出了 CP-SMOTE 算法, 实现了少数类样本的分簇扩增; 文献[18]构建了双流生成对抗网络, 对数据集进行了特征增强, 为风电机组故障诊断提供了数据支撑。基于模型优化的方法主要包括迁移学习、元学习、正则化方法等, 对算法中的特征提取部分进行优化, 实现模型分类能力的提升; 文献[19]提出了基于强化学习的马田系统, 对小样本风力发电机齿轮箱故障进行高效可靠的检测; 文献[20]提出了最优源域模型选取方案, 实现了损耗的

快速求解与精准预测。基于模型优化的方法适用于目标域数据稀缺或训练时间受限的场景, 而基于数据增强的方法更适用于解决样本类别数量不平衡问题, 能够提高模型对小样本类别的识别能力。因此, 针对二次设备各类故障发生的概率不同, 导致收集到的故障样本为不平衡数据集这一问题, 本文选取基于数据增强的小样本学习方法降低小样本数据对二次设备故障诊断准确率的影响。

在故障诊断领域, 基于数据增强的小样本学习方法主要包括合成少数过采样技术、变分自编码器和生成对抗网络。其中, SMOTE 仅适用于合成简单小规模表格数据, 面对高维复杂数据时会生成无效样本, 影响数据增强的质量; 生成对抗网络虽然可以生成高保真度的故障样本, 但模型在对抗训练中易产生模式崩溃现象, 导致生成的样本多样性降低, 无法实现故障类型的全面覆盖, 同时生成对抗网络的隐式建模使得潜在空间难以解释评估, 可解释性方面存在一定的缺陷; 虽然变分自编码器的数据生成质量略逊于生成对抗网络, 但其通过似然最大化强制覆盖数据集的所有模式, 使得生成的样本具有良好的多样性和稳定性, 同时变分自编码器的潜在空间采用显式建模, 具备更强的可解释性和更丰富的任务扩展能力。综上, 本文综合考虑故障样本多样性与模型可解释性两方面需求, 选用变分自编码器作为基于数据增强的小样本学习模型。

为保证二次设备发生故障时, 智能变电站运维人员能够快速诊断并切除故障, 在模型搭建过程中, 应在确保准确率的前提下, 尽可能提升运算速度, 降低计算量; 同时, 在处理小样本数据时, 要克服样本生成的盲目性, 提高模型的运行效率。因此, 针对上述问题, 本文提出了基于条件变分自编码器(conditional variational autoencoder, CVAE)与改进卷积极限梯度提升(convolutional extreme gradient boosting, ConvXGB)模型的二次设备小样本故障诊断方法。通过 CVAE 对特定故障样本进行数据增强, 形成平衡数据集, 解决深度学习算法对小样本数据特征学习不充分的问题, 并通过主成分分析法(principal component analysis, PCA)与 t-SNE 算法对 CVAE 的潜在空间进行降维可视化处理, 验证模型生成新样本的能力; 引入自注意力机制, 利用压缩与激励网络模块(squeeze-and-excitation networks, SE)对 ConvXGB 模型进行改进, 对故障信息特征进行重新学习, 实现特征权重的自适应分配, 提高模型的泛化能力, 降低过拟合风险。最后, 以智能变电站典型线路间隔为例, 对 CVAE-SEConvXGB 模型

处理小样本数据及故障诊断的能力进行验证。

1 变电站二次设备故障信息

智能变电站二次设备包括保护装置、合并单元、智能终端、测控装置等,根据变电站实际故障案例与设备故障时的故障特征信息,本文将故障诊断的目标群体选定为故障成本更大、故障率更高的保护装置、合并单元与智能终端,将故障诊断的对象选定为设备的CPU插件、采集模块、I/O端口及相关的光纤链路^[8]。当选定的二次设备部分或整个装置发生故障时,通过对设备自身产生的告警信号,以及与之关联的设备辅助生成的告警信号进行梳理分析,即可诊断二次设备的故障类型,故障类型与故障特征信息如表1所示。

表1 故障类型与故障特征信息

Table 1 Fault types and fault characteristics information

故障类型	故障特征信息
CPU 插件故障	CPU 采样异常、存储器出错、设备 SV 总告警等
采集模块故障	CPU 采样异常、数据处理模块采样异常、设备 SV 总告警、设备 GOOSE 总告警等
I/O 端口故障	设备 SV 总告警、设备 GOOSE 总告警、设备 SV 采样链路中断、设备 GOOSE 链路中断等
光纤链路故障	设备 SV 总告警、设备 GOOSE 总告警、设备 GOOSE 链路中断、设备 SV 链路中断、关联设备 GOOSE 总告警等

根据设备故障断面中故障信息特征集 V 的数据类型不同,将故障信息分为模拟量故障信息与数字量故障信息,如式(1)所示。

$$V_i = \{V_{asi}, V_{dsi}\} \quad i=1,2,\dots,N \quad (1)$$

式中: V_i 为第 i 个故障事件的故障信息特征集; V_{asi} 为故障事件的模拟量故障信息集; V_{dsi} 为数字量故障信息集; N 为故障事件的总数量。

其中,模拟量故障信息主要包括保护装置双通道三相电压、电流采样值,如式(2)所示。

$$V_{asi} = \{\mathbf{S}_{U11}, \mathbf{S}_{U12}\} \quad (2)$$

$$\begin{cases} \mathbf{S}_{U11} = [U_{A1} \ U_{B1} \ U_{C1} \ I_{A1} \ I_{B1} \ I_{C1}] \\ \mathbf{S}_{U12} = [U_{A2} \ U_{B2} \ U_{C2} \ I_{A2} \ I_{B2} \ I_{C2}] \end{cases}$$

式中: \mathbf{S}_{U11} 为通道 1 采样值; \mathbf{S}_{U12} 为通道 2 采样值; U_A 、 U_B 、 U_C 为三相电压; I_A 、 I_B 、 I_C 为三相电流。

数字量故障信息主要由 0 和 1 构成,当后台监控主机监测到故障信息或收到报文时,该故障信息或报文对应位置的元素为 1,否则为 0,具体组成如式(3)所示。

$$V_{dsi} = \{X_{EAlf}, X_{STIf}, X_{ASIf}\} \quad i=1,2,\dots,N \quad (3)$$

式中: X_{EAlf} 为二次设备告警信息; X_{STIf} 表示设备自

检状态信息; X_{ASIf} 为 GOOSE/SV 通信状态信息。

二次设备告警信息包括设备异常告警信息和设备故障告警信息,可表示为

$$X_{EAlf} = \{\mathbf{E}_{Pd1}, \dots, \mathbf{E}_{Pda}, \mathbf{E}_{Mu1}, \dots, \mathbf{E}_{Mub}, \mathbf{E}_{It1}, \dots, \mathbf{E}_{Itc}\} \quad (4)$$

$$\begin{cases} \mathbf{E}_{Pda} = [E_{Pda-ea} \ E_{Pda-fa} \ \dots] \\ \mathbf{E}_{Mub} = [E_{Mub-ea} \ E_{Mub-fa} \ \dots] \\ \mathbf{E}_{Itc} = [E_{Itc-ea} \ E_{Itc-fa} \ \dots] \end{cases}$$

式中: a 、 b 、 c 分别表示保护装置、合并单元、智能终端的总数; \mathbf{E}_{Pda} 、 \mathbf{E}_{Mub} 、 \mathbf{E}_{Itc} 分别为第 a 个保护装置、第 b 个合并单元、第 c 个智能终端的设备告警信息;下标“ea”表示设备异常告警信息;下标“fa”表示设备故障告警信息。

二次设备自检状态信息包括保护装置、合并单元、智能终端的自检状态信息,可表示为

$$X_{STIf} = \{\mathbf{S}_{Pd1}, \dots, \mathbf{S}_{Pda}, \mathbf{S}_{Mu1}, \dots, \mathbf{S}_{Mub}, \mathbf{S}_{It1}, \dots, \mathbf{S}_{Itc}\} \quad (5)$$

$$\begin{cases} \mathbf{S}_{Pda} = [S_{Pda-me} \ S_{Pda-pe} \ S_{Pda-se} \ \dots] \\ \mathbf{S}_{Mub} = [S_{Mub-me} \ S_{Mub-pe} \ S_{Mub-se} \ \dots] \\ \mathbf{S}_{Itc} = [S_{Itc-me} \ S_{Itc-pe} \ S_{Itc-se} \ \dots] \end{cases}$$

式中: \mathbf{S}_{Pda} 、 \mathbf{S}_{Mub} 、 \mathbf{S}_{Itc} 分别表示第 a 个保护装置、第 b 个合并单元、第 c 个智能终端的自检状态信息;下标“me”表示设备存储器出错;下标“pe”表示设备程序出错;下标“se”表示设备 CPU 采样出错。

GOOSE/SV 通信状态信息包括二次设备之间报文的通信状态信息,如式(6)所示。

$$X_{ASIf} = \{\mathbf{M}_{GA}, \mathbf{M}_{G1}, \mathbf{M}_{G2}, \dots, \mathbf{M}_{Gd}, \mathbf{M}_{SA}, \mathbf{M}_{S1}, \mathbf{M}_{S2}, \dots, \mathbf{M}_{Se}\} \quad (6)$$

$$\begin{cases} \mathbf{M}_{Gd} = [M_{GR1} \ M_{GR2} \ \dots \ M_{GRf}] \\ \mathbf{M}_{Se} = [M_{SR1} \ M_{SR2} \ \dots \ M_{SRg}] \end{cases}$$

式中: d 和 e 分别为网络中 GOOSE 报文与 SV 报文的总数; \mathbf{M}_{GA} 表示 GOOSE 总告警; \mathbf{M}_{SA} 表示 SV 总告警; \mathbf{M}_{Gd} 表示第 d 条 GOOSE 报文的接收情况; M_{GRf} 表示第 f 个设备是否接收该 GOOSE 报文; \mathbf{M}_{Se} 为第 e 条 SV 报文的接收情况; M_{SRg} 表示第 g 个设备是否接收该 SV 报文;下标“R”表示设备对该报文的接收订阅状态。

综上,二次设备故障类型与故障信息特征集的关系可表示为

$$\mathbf{Y} = f(V_i) \quad (7)$$

式中: V_i 为故障信息特征集; \mathbf{Y} 表示故障类型; f 表示故障信息特征集与故障类型之间的非线性映射关系。

由于二次设备发生故障时产生的数据信息量庞大,数据之间关系复杂,因此该映射关系通常为非

线性映射, 需要通过合适的深度学习算法来对映射关系进行深层挖掘与构建。

2 二次设备故障样本数据增强

基于深度学习算法的模型在进行故障诊断时, 需要大量历史数据进行迭代学习。由于二次设备属于高可靠性设备, 且各类故障发生的频率不同, 导致收集到的故障样本呈现小样本、不平衡特征, 模型的诊断结果会偏向多数样本, 整体的诊断准确性会产生较大的误差。因此, 为减小不平衡数据集对模型可靠性的影响, 需对小样本数据进行数据增强, 平衡各类故障样本的数量, 为深度学习故障诊断模型提供数据支撑。

小样本故障诊断方法主要分为基于数据增强的方法和基于模型优化的方法^[15], 本文采用 CVAE 进行样本数据的增强, 通过输入原始数据与数据标签, 生成大量与原始样本特征相似的特定新数据来辅助模型的训练与学习。

2.1 CVAE

CVAE 是一种半监督深度生成模型, 在变分自编码器的基础上, 通过在编码器的输入中加入二次设备故障信息特征集 V_i 与故障类型 \mathbf{Y} 构成的原始故障输入数据 \mathbf{X} , 控制潜在空间中模型生成二次设备故障样本数据的故障类型, 以解决传统变分自编码器无法生成特定类型样本数据的问题^[21], CVAE 结构如图 1 所示。

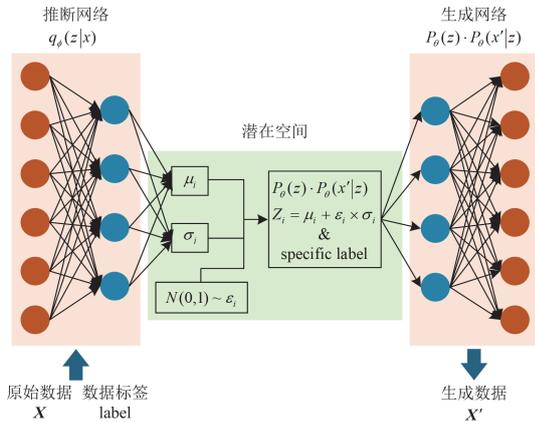


图 1 条件变分自编码器结构图

Fig. 1 Structural diagram of conditional variational autoencoder

CVAE 基于原始二次设备故障输入数据构建矩阵 \mathbf{X} , 通过推断网络的编码, 将矩阵压缩至低维潜在空间并形成潜在变量 \mathbf{Z} , 最后通过生成网络的变分概率分布进行解码, 生成与原始数据相似的生成数据矩阵 \mathbf{X}' 。为了使推断网络的识别模型与生成网络的真实后验分布近似一致, CVAE 通过 KL 散

度来评估两个概率分布的接近程度, 即

$$\phi, \theta = \arg \min D_{\text{KL}}(q_{\phi}(z|x) \| P_{\theta}(z|x)) = E_{q_{\phi}(z|x)}[\text{lb}q_{\phi}(z|x) - \text{lb}P_{\theta}(z|x)] + \text{lb}P_{\theta}(x) \quad (8)$$

式中: ϕ 表示推断网络的参数; θ 为生成网络的参数; $\arg \min$ 表示函数达到最小值时变量的取值; x 表示原始故障输入数据 \mathbf{X} 中的元素; D_{KL} 表示 KL 散度; $q_{\phi}(z|x)$ 表示推断网络的近似推断过程; $P_{\theta}(z|x)$ 表示真实后验分布; $E[\cdot]$ 表示期望; lb 表示对数边际似然。由式(8)可以推导得到输入数据 \mathbf{X} 对数边际似然 $\text{lb}P_{\theta}(x)$ 的变分下界函数 $L(\theta, \phi; \mathbf{X})$ 如式(9)所示。

$$L(\theta, \phi; \mathbf{X}) = E_{q_{\phi}(z|x)}[-\text{lb}q_{\phi}(z|x) + \text{lb}P_{\theta}(x, z)] \quad (9)$$

推断网络和生成网络的优化目标可以表示为

$$\phi, \theta = \arg \max_{\phi, \theta} L(\theta, \phi; \mathbf{X}) \quad (10)$$

式中: $\arg \max$ 表示函数达到最大值时变量的取值, 该式表示推断网络参数与生成网络参数共同优化, 以最大化变分下界 $L(\theta, \phi; \mathbf{X})$ 。因此 CVAE 的全局优化目标为最大化变分下界函数, 具体如式(11)所示。

$$L(\theta, \phi; x, y) = -D_{\text{KL}}(q_{\phi}(z|x, y) \| P_{\theta}(z|x, y)) + E_{q_{\phi}(z|x, y)} \text{lb}P_{\theta}(x'|z, y) \quad (11)$$

式中: y 为故障类型 \mathbf{Y} 中的元素; x' 表示生成数据 \mathbf{X}' 中的元素。

2.2 基于 CVAE 的故障样本数据增强

CVAE 将二次设备故障信息特征集 V_i 与故障类型 \mathbf{Y} 作为输入进行编码, 在解码的过程中可通过限定二次设备故障类型标签来控制 CVAE 生成特定类型故障的故障信息特征集, 以达到对小样本数据进行数据增强的目的。

在 CVAE 迭代训练的过程中, 可通过计算损失值来判断当前生成数据的质量。此外, 如图 2 所示, 还可通过观察原始数据与生成数据在潜在空间的分布情况来判断当前模型对数据集特征的学习情况。本文采用 PCA 算法与 t-SNE 算法分别将潜在空间的原始数据与生成数据降至二维平面, 形成潜在空间的可视化图像, 对模型的学习情况进行观察与分析。

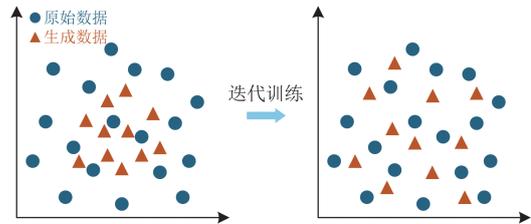


图 2 原始数据与生成数据的分布情况

Fig. 2 Distributional characteristics of raw data versus generated data

3 基于 CVAE-SEConvXGB 模型的二次设备故障诊断

二次设备运行过程中若发生故障,需要运维人员快速准确地定位故障位置,排查故障类型并对故障进行处理修复。因此,在实现小样本数据增强的基础上,构建深度学习模型对二次设备进行故障诊断,需要兼顾模型的运算速度与准确度。传统的深度学习模型如卷积神经网络(convolutional neural networks, CNN)、Transformer 等在迭代运算过程中运算量大、耗时较长,不利于故障类型的快速诊断,且当训练集样本数量不够多时,深度学习模型的诊断效率会受到影响。此外, CNN、Transformer 等“黑箱模型”的可解释性较差,不利于运维人员分析设备故障的主要原因。传统基于阈值和规则的方法在处理复杂多变的二次设备故障信息时准确率较低,因此在搭建模型时需考虑可解释性与准确性的平衡问题。同时,在处理数据增强后的平衡数据集时,需要模型更加关注故障信息的主要特征,而较少关

注次要特征,需要模型能够自适应地更新对故障信息特征的关注度。例如,判断合并单元数字信号处理(digital signal processing, DSP)模块是否发生故障,需重点关注是否产生“装置异常告警”“设备 SV 总告警”两种信号。因此,本文提出了一种基于自注意力机制改进 ConvXGB 模型的二次设备故障诊断模型,实现对故障类型的准确快速判断。

3.1 改进 ConvXGB 算法

ConvXGB 是 2021 年提出的一种结合了卷积神经网络与 XGBoost 的深度学习算法,相比于传统的卷积神经网络,ConvXGB 的卷积部分减少了池化层与全连接层,减小了提取特征时的计算量^[22]。此外,由于智能站内二次设备数量庞大,设备之间的关联关系复杂,提取的特征信息种类繁多,因此需体现重要特征的价值,降低次要特征的干扰。基于上述问题,本文在激活函数层之后引入 SE 模块,使得不同通道的权重能够自适应分配,提高模型的鲁棒性与泛化能力^[23]。改进 ConvXGB 算法的结构图如图 3 所示,该算法主要由特征学习与类别预测两部分构成。

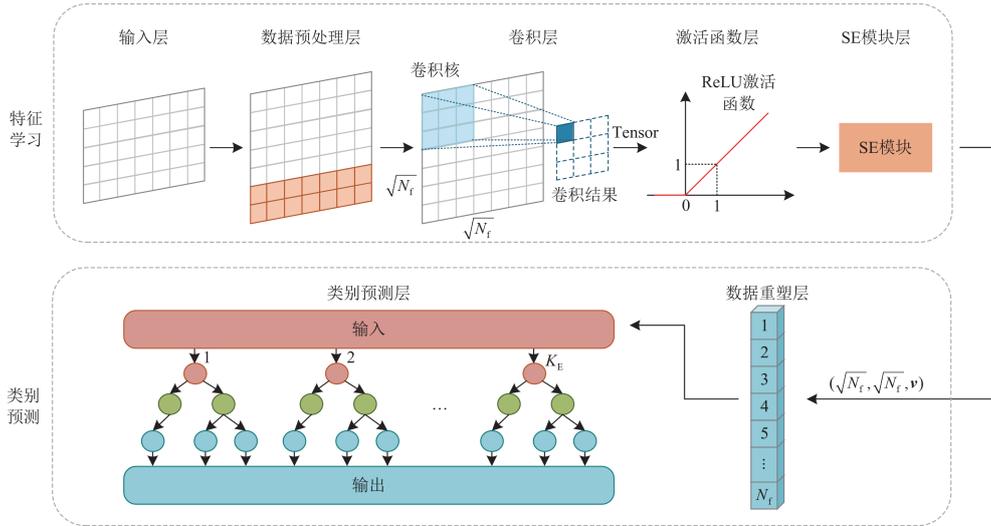


图 3 改进 ConvXGB 算法结构图

Fig. 3 Improved ConvXGB algorithm structure diagram

1) 特征学习部分

该部分主要由输入层、数据预处理层、卷积层、激活函数层和 SE 模块层构成。输入层负责将一组数据集 $S = \{(s_{D_j}, s_{L_j}) | 1 \leq j \leq M\}$ 输入到模型中,其中 s_{D_j} 表示维度为 $\sqrt{N_r} \times \sqrt{N_r}$ 的特征矩阵, s_{L_j} 为分配给 s_{D_j} 的类别标签, M 为数据集的大小。如果 s_{D_j} 的维度符合 $\sqrt{N_r} \times \sqrt{N_r}$ 的要求,矩阵将被直接传递给卷积层;如果维度不符合要求,则需要对数据预处理层通过添加必要的零点来填充数据,以生成平

方张量,填充方式如图 4 所示。

卷积层对输入向量进行卷积操作并添加偏置项。假设输入一个大小为 $W \times H$ 的数据 F ,则 F 可表示为

$$F = \{s(m, n) | 1 \leq m \leq W, 1 \leq n \leq H\} \quad (12)$$

式中: $s(m, n)$ 表示输入数据的值。

卷积层的输出如式(13)所示。

$$C_s^{(l)} = \Phi(B_s^{(l)} + \sum_{j=1}^{f^{(l-1)}} K_{s,j}^{(l)} \times C_j^{(l-1)}) \quad (13)$$

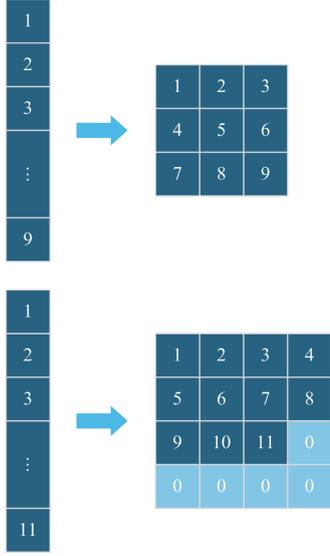


图4 数据预处理层数据填充方式

Fig. 4 Data filling method in the data preprocessing layer

式中: $C_s^{(l)}$ 表示第 l 层卷积层的第 s 个特征图的输出; $f^{(l-1)}$ 为第 $l-1$ 层卷积层的特征图; Φ 为 ReLU 激活函数; $B_s^{(l)}$ 表示第 l 层卷积层第 s 个特征图的偏置矩阵; $K_{s,j}^{(l)}$ 表示第 l 层卷积核的大小, 计算公式如式(14)所示。

$$K_{s,j}^{(l)} = 2w_k^{(l)} + 2h_k^{(l)} + 1 \quad (14)$$

式中: $w_k^{(l)}$ 、 $h_k^{(l)}$ 表示卷积核的尺寸。因此, 对于第 s 个特征图在 (m,n) 第 l 层卷积层的输出如式(15)所示。

$$\begin{aligned} (C_s^{(l)})_{m,n} &= \Phi((B_s^{(l)})_{m,n} + \sum_{j=1}^{f^{(l-1)}} (K_{s,j}^{(l)} \otimes C_j^{(l-1)})_{m,n}) = \\ &\Phi((B_s^{(l)})_{m,n} + \\ &\sum_{j=1}^{f^{(l-1)}} \sum_{u=-w_k^{(l)}}^{w_k^{(l)}} \sum_{v=-h_k^{(l)}}^{h_k^{(l)}} (K_{s,j}^{(l)})_{m,n} (C_j^{(l-1)})_{m+u,n+v}) \end{aligned} \quad (15)$$

式中: \otimes 表示克罗内克积运算; u 、 v 表示求和运算的起始值。

本文通过在激活函数层之后加入 SE 模块对 ConvXGB 模型进行改进。SE 模块是一种自注意力模块, 能够显式地在卷积特征通道之间建立相互依赖关系, 该模块由全局信息嵌入(squeeze)、自适应重新校正(excitation)以及重新加权(scale)3 部分组成, 具体流程图如图 5 所示。

SE 模块 3 部分具体计算公式如式(16)所示。

$$\begin{cases} \mathbf{v}_t = F_{\text{sq}}(\mathbf{u}_t) = \frac{1}{A \times B} \sum_{i'=1}^A \sum_{j'=1}^B \mathbf{u}_t(i', j') \\ \mathbf{S} = F_{\text{ex}}(\mathbf{v}, W) = \sigma(W_2 \delta(W_1 \mathbf{v})) \\ \mathbf{V} = F_{\text{scale}}(\mathbf{u}_t, \mathbf{s}_t) = \mathbf{s}_t \mathbf{u}_t \end{cases} \quad (16)$$

式中: \mathbf{u}_t 表示大小为 $A \times B \times C$ 的特征图 U 的第 t 个元素; \mathbf{v}_t 为压缩后特征向量 \mathbf{v} 的第 t 个元素; i' 和 j' 分别表示特征图在高度和宽度上的索引; F_{sq} 表示压缩操作, 对特征图执行全局平均池化; \mathbf{S} 表示输出权重; \mathbf{s}_t 表示 \mathbf{S} 中第 t 个元素; F_{ex} 表示激励操作; W 表示两个全连接层的权重参数集合; W_1 表示降维层权重; W_2 表示升维层权重; $\delta(\cdot)$ 为 ReLU 激活函数; $\sigma(\cdot)$ 为 Sigmoid 激活函数; \mathbf{V} 表示 SE 模块经过重新加权后的最终输出; F_{scale} 表示缩放操作。

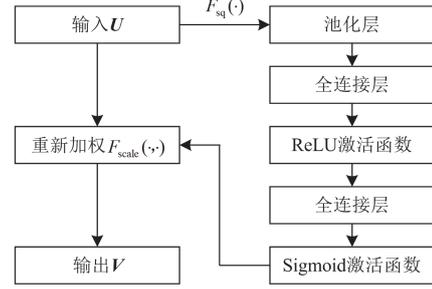


图5 SE 模块流程图

Fig. 5 SE module flowchart

加入基于自注意力机制的 SE 模块后, 模型网络能够重新学习当前数据特征, 对重要的故障信息特征进行强调, 对次要的故障信息特征进行抑制忽略, 提高了模型的鲁棒性与泛化能力。在计算量上, 虽然 SE 模块存在池化层和全连接层, 但与卷积神经网络的池化层和全链接层相比, 复杂度与计算量都相对较小, 因此对模型整体的计算量、计算速度不会有太大的影响。

2) 类别预测部分

类别预测部分主要由数据重塑层与类别预测层两部分构成。数据重塑层将卷积层输出的张量转化为下一层所需的向量形式, 类别预测层则通过 XGBoost 算法实现对数据集的分类。XGBoost 算法基于梯度提升决策树框架, 通过迭代添加新的树模型来减少前一轮模型的残差, 最终实现数据的分类, 其主要计算公式如式(17)—式(21)所示。

$$w_{j^*}^* = - \frac{\sum_{i^* \in I_{j^*}} g_{i^*}}{\sum_{i^* \in I_{j^*}} h_{i^*} + \lambda} \quad (17)$$

$$D_{j^*} = \{i^* \mid q(x_{i^*}) = j^*\} \quad (18)$$

$$\begin{cases} g_{i^*} = \frac{\partial L(\hat{y}_{i^*}^{(l-1)}, y_{i^*})}{\partial \hat{y}_{i^*}^{(l-1)}} \\ h_{i^*} = \frac{\partial^2 L(\hat{y}_{i^*}^{(l-1)}, y_{i^*})}{[\partial \hat{y}_{i^*}^{(l-1)}]^2} \end{cases} \quad (19)$$

$$\tilde{L}^{(t)}(q) = -\frac{1}{2} \frac{\left(\sum_{i^* \in D_{j^*}} g_{i^*} \right)^2}{\sum_{i^* \in D_{j^*}} h_{i^*} + \lambda} + \gamma T \quad (20)$$

$$L_{\text{split}} = \frac{1}{2} \left[\frac{\left(\sum_{i^* \in D_L} g_{i^*} \right)^2}{\sum_{i^* \in D_L} h_{i^*} + \lambda} + \frac{\left(\sum_{i^* \in D_R} g_{i^*} \right)^2}{\sum_{i^* \in D_R} h_{i^*} + \lambda} + \frac{\left(\sum_{i^* \in D} g_{i^*} \right)^2}{\sum_{i^* \in D} h_{i^*} + \lambda} \right] - \gamma \quad (21)$$

式中： $w_{j^*}^*$ 表示最佳决策树结构的最优叶权重； D_{j^*} 为第 j^* 个树叶的实例集； $\hat{y}_{i^*}^{(t-1)}$ 表示第 $t-1$ 棵树的累积预测值； g_{i^*} 和 h_{i^*} 分别为损失函数 L 第 i^* 个样本的一阶、二阶梯度统计量； γ 和 λ 为控制正则化程度的参数； T 为决策树中的叶子数； $\tilde{L}^{(t)}(q)$ 为决策树 q 结构质量的得分函数； L_{split} 表示最佳分裂点； D_L 和 D_R 分别表示分裂后左子节点和右子节点的样本集合，且 $D = D_L \cup D_R$ 。

XGBoost模型的目标函数中由于正则项的存

在，可以很好地防止过拟合现象的发生；同时，正则项也起到惩罚作用，当为了提高准确率决策树增加叶子层数时，会对目标函数的收敛速度产生影响。因此，XGBoost模型的迭代过程本质上是准确率与计算量权衡的过程，在保证准确率的前提下尽可能减少计算量，提高运算速度。

3.2 CVAE-SEConvXGB 二次设备故障诊断模型

基于CVAE-SEConvXGB二次设备故障诊断模型的诊断流程图如图6所示，具体步骤如下：

- 1) 获取智能变电站二次设备历史故障信息，形成故障信息特征集 V_i ，并与故障类型 Y 一一对应，筛选出小样本故障类型进行数据增强；
- 2) 将故障信息特征集 V_i 与故障类型 Y 合并输入条件变分自编码器中，通过控制潜在空间的类别标签对小样本数据进行数据增强，形成平衡数据集；
- 3) 将平衡数据集输入故障诊断模型的特征学习部分，提取数据特征并通过SE模块进行特征权重重构；
- 4) 将重构后的特征信息输入模型的类别预测部分进行故障类型的判别，输出二次设备故障诊断结果。

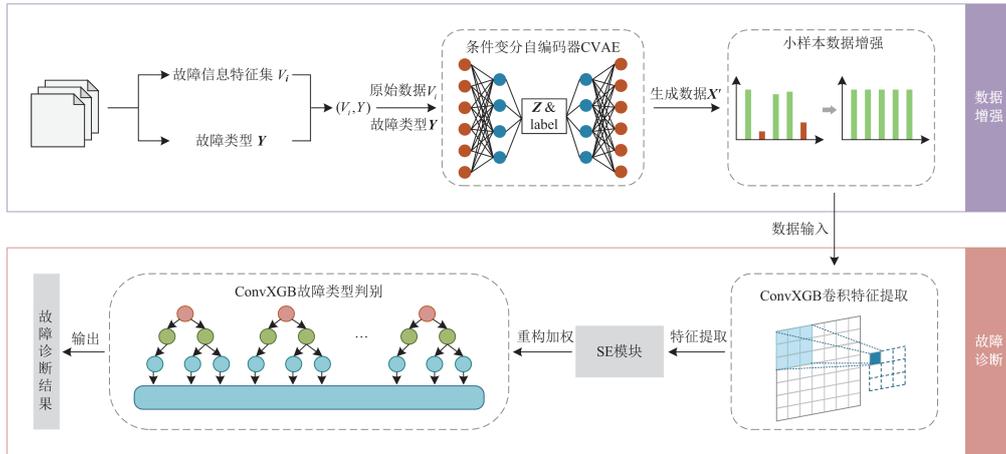


图6 基于CVAE-SEConvXGB二次设备故障诊断模型的诊断流程

Fig. 6 Diagnostic process of secondary equipment fault diagnosis model based on CVAE-SEConvXGB

关于模型参数的设置，需要将故障信息特征集 V_i 与故障类型 Y 一并输入CVAE中，因此设置输入层神经元数为13，输出层神经元数为5；CVAE的编码器与解码器均由多层感知机(multilayer perceptron, MLP)网络结构构成，编码器的激活函数设置为ReLU函数，解码器的激活函数为ReLU函数与Sigmoid函数，潜在空间维数设置为20，批处理参数设置为128，优化器设置为Adam优化器；卷积神经网络激活函数选择ReLU函数，选择随机梯度下降作为优化器，学习率设置为0.001，动量设置为0.9。

4 算例分析

本文在Jupyter Notebook平台进行编程与计算，深度学习框架为PyTorch 2.4.1，计算机硬件配置为CPU Intel(R) Core(TM) i9-14900HX，显卡为RTX4060，内存为32 GB。

以某智能变电站实际运行的线路间隔为例，验证CVAE-SEConvXGB二次设备故障诊断模型的可行性与有效性。该线路间隔的拓扑结构如图7所示，报文传输的信息流如表2所示，线路间隔具体故障类型如表3所示。

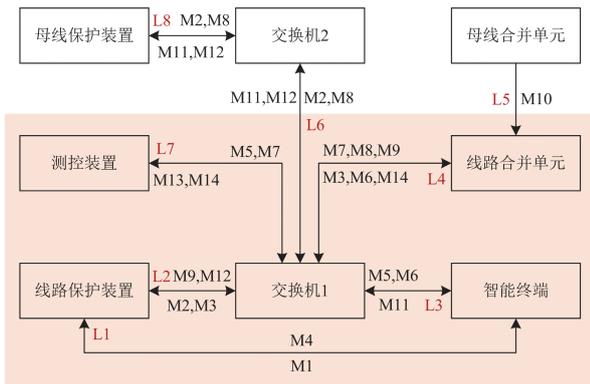


图 7 智能变电站线路间隔拓扑图

Fig. 7 Topology diagram of line intervals in smart substations

表 2 线路间隔报文传输的信息流

Table 2 Message transmission information flow of line intervals

编号	发布端口	接收端口	传输方式
M1	线路保护	智能终端	点对点 GOOSE
M2	线路保护	母线保护	组网 GOOSE
M3	线路保护	线路合并单元	组网 SV
M4	智能终端	线路保护	点对点 GOOSE
M5	智能终端	测控装置	组网 GOOSE
M6	智能终端	线路合并单元	组网 GOOSE
M7	线路合并单元	测控装置	组网 SV
M8	线路合并单元	母线保护	组网 SV
M9	线路合并单元	线路保护	组网 SV
M10	母线合并单元	线路合并单元	点对点 SV
M11	母线保护	智能终端	组网 GOOSE
M12	母线保护	线路保护	组网 GOOSE
M13	测控装置	智能终端	组网 GOOSE
M14	测控装置	线路合并单元	组网 SV

表 3 线路间隔故障类型

Table 3 Line interval fault types

序号	类型编码	故障类型
1	00001	线路保护装置 CPU 插件故障
2	00010	线路保护装置采集模块故障
3	00011	线路保护 I/O 端口故障(L1)
4	00100	线路保护 I/O 端口故障(L2)
5	00101	L1 光纤断链
6	00110	L2 光纤断链
7	00111	智能终端 CPU 插件故障
8	01000	智能终端采集模块故障
9	01001	智能终端 I/O 端口故障(L1)
10	01010	智能终端 I/O 端口故障(L3)
11	01011	L3 光纤断链
12	01100	线路合并单元数据处理模块故障
13	01101	线路合并单元采集模块故障
14	01110	线路合并单元 I/O 端口故障(L4)
15	01111	线路合并单元 I/O 端口故障(L5)
16	10000	L4 光纤断链
17	10001	L5 光纤断链

变电站二次设备各个故障类型样本数量如表 4 所示,可以看出“线路保护装置 CPU 插件故障”“智能终端 CPU 插件故障”“线路合并单元采样模块故障”“线路合并单元 I/O 端口故障(L5)”样本数量明显少于其他故障类型的样本数量,可确定这 4 类故障样本为小样本数据,需要对其进行数据增强,形成二次设备故障类型平衡数据集。

表 4 故障类型样本数量

Table 4 Sample size per failure type

故障类型编号	样本数量	是否为小样本数据
1	134	√
2	859	
3	782	
4	864	
5	674	
6	849	
7	202	√
8	793	
9	892	
10	847	
11	772	
12	882	
13	163	√
14	795	
15	261	√
16	811	
17	873	

设置迭代次数为 100 次,学习率分别为 0.1、0.01、0.001、0.0001,比较不同学习率下 CVAE 的损失值变化情况,如图 8 所示。由图 8 可知,学习率为 0.001 时 CVAE 损失函数损失值最小,因此本文设置 CVAE 模型的学习率为 0.001。将迭代次数设置为 500,并在学习率为 0.001 的条件下,观察并记录损失值的变化,部分迭代次数的损失值如表 5 所示,CVAE 损失值变化趋势如图 9 所示,CVAE 损失值在第 494 次迭代时数值最小,此时损失值为

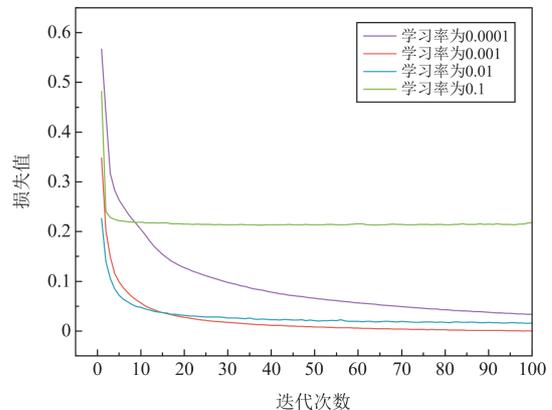


图 8 不同学习率下 CVAE 损失值变化情况

Fig. 8 Variation of CVAE loss values at different learning rates

表 5 CVAE 不同迭代次数损失值

Table 5 Loss values of CVAE at different iterations

迭代次数	损失值	是否最小
1	0.814 935	
⋮	⋮	
100	0.01965	
⋮	⋮	
490	$7.574 13 \times 10^{-4}$	
491	$5.318 87 \times 10^{-4}$	
492	1.15×10^{-3}	
493	$5.014 68 \times 10^{-4}$	
494	$2.783 95 \times 10^{-5}$	√
495	7.5206×10^{-4}	
496	8.8837×10^{-4}	
497	1.14×10^{-3}	
498	1.02×10^{-3}	
499	$7.017 94 \times 10^{-4}$	
500	$6.828 23 \times 10^{-4}$	

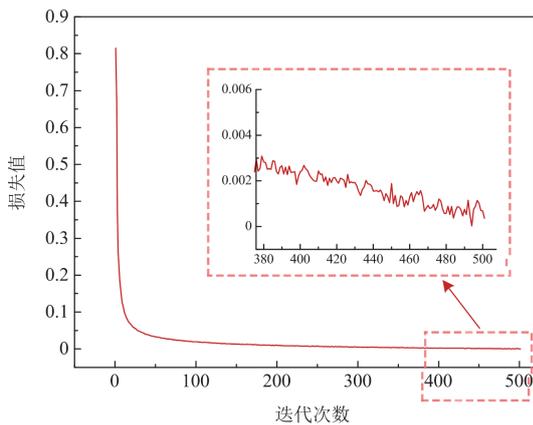


图 9 学习率为 0.001 时 CVAE 损失值随迭代次数的变化情况
Fig. 9 Variation of CVAE loss values with iteration number at a learning rate of 0.001

2.7840×10^{-5} , 记录下此时的 μ_{494} 和 σ_{494} 用于后续解码器的数据生成。

将所有故障样本及对应的故障类型输入条件变分自编码器中, 并设置潜在空间的特定标签为“00001”“00111”“01101”“01111”, 使得解码器生成这 4 类故障样本数据, 同时利用 PCA 算法对潜在空间进行数据降维, 生成二维可视化图像, 如图 10 所示。

其中, 图 10(a)为第 1 次迭代后原始故障样本与生成故障样本的潜在空间分布图, 图 10(b)为第 494 次迭代后潜在空间的分布图。将两图对比可以看出, 随着网络迭代训练, 损失值逐渐减小, 生成样本的分布逐渐接近原始样本的分布, 说明模型具有较强

的数据特征学习能力, 生成的样本在特征上与原始样本相似, 可以用作后续的二次设备故障诊断。

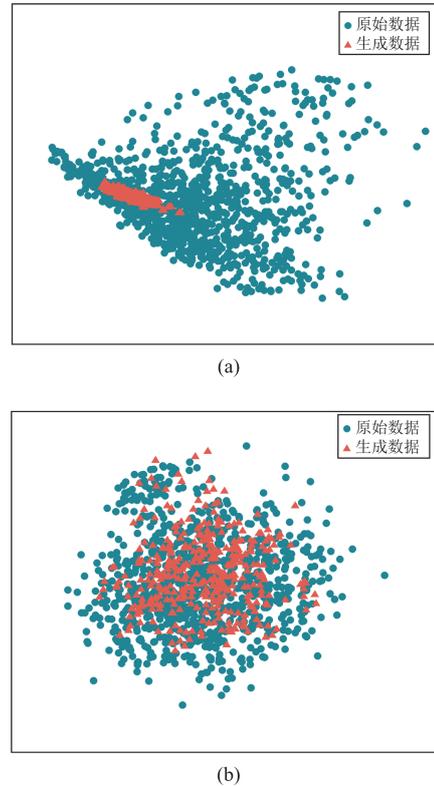


图 10 原始数据与生成数据在第 1 次与第 494 次迭代时的潜在空间二维分布图

Fig. 10 Two-dimensional distribution of latent space for original and generated data at the 1st and 494th iterations

在确认生成样本与原始样本特征相似后, 使用 t-SNE 算法对第 494 次迭代的潜在空间进行可视化处理, 如图 11 所示, 迭代训练后的 4 种样本在潜在空间具有明显的分类边界, 且同一类型的样本具有良好的聚集性。综上, 表明该模型对特定小样本数据具备良好的数据增强能力。

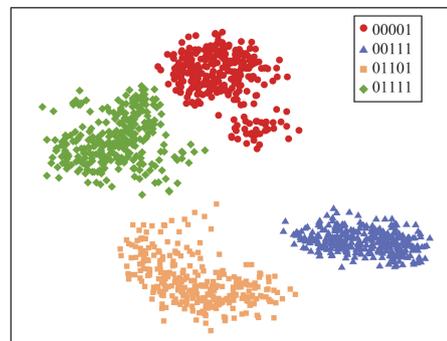


图 11 t-SNE 数据降维后各类型样本潜在空间分布图
Fig. 11 t-SNE algorithm-based dimensionality reduction and latent space distribution of different sample types

经 CVAE 模型进行数据增强后的样本平衡数据集如表 6 所示, 将平衡数据集按 8:2 的比例划分训练集与测试集, 对模型进行迭代训练与测试。

表 6 故障样本平衡数据集

Table 6 Balancing fault sample dataset and partitioning

故障类型编号	样本数量	训练集数量	测试集数量
1	824	660	164
2	859	687	172
3	782	626	156
4	864	691	173
5	674	539	135
6	849	679	170
7	856	685	171
8	793	634	159
9	892	714	178
10	847	678	169
11	772	618	154
12	882	706	176
13	789	631	158
14	795	636	159
15	843	674	169
16	811	649	162
17	873	698	175

将数据增强后的平衡数据集输入 SEConvXGB 模型中进行二次设备故障诊断, 训练集诊断结果混淆矩阵如图 12 所示, 测试集混淆矩阵如图 13 所示。经计算可得, 训练集故障诊断准确率为 98.86%, 测试集故障诊断准确率为 97.75%。

为验证本文所提 CVAE-SEConvXGB 模型的性能, 将原始不平衡数据集分别输入到 CVAE-SEConvXGB、CGAN-SEConvXGB、SEConvXGB、

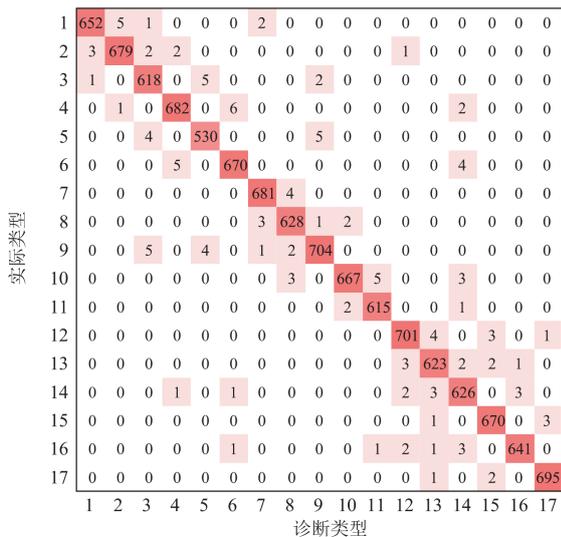


图 12 平衡数据集下训练集诊断结果混淆矩阵

Fig. 12 Confusion matrix of diagnostic results in training set under balanced dataset

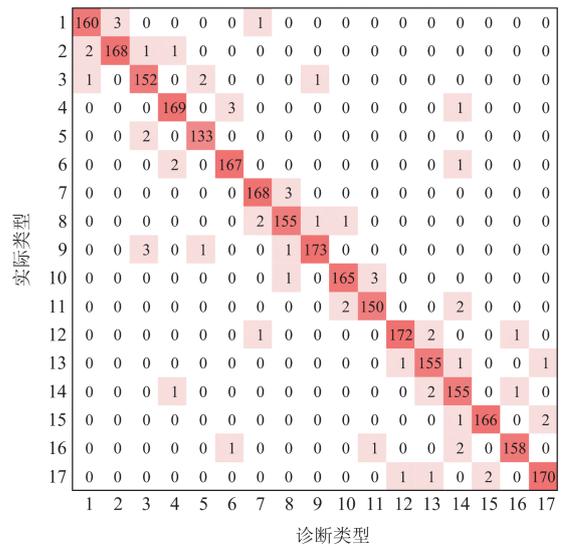


图 13 平衡数据集下测试集诊断结果混淆矩阵

Fig. 13 Confusion matrix of diagnostic results in text set under balanced datasets

Transformer、卷积神经网络、ConvXGB 及 BP 神经网络中, 通过各个模型分类准确率来衡量模型处理小样本数据的能力及故障诊断的性能。各模型在训练集与测试集的准确度及运行时间如表 7 所示。

表 7 两种数据集准确率及模型运行时间

Table 7 Two datasets accuracy and model running time

模型	训练集准确率/%	测试集准确率/%	运行时间/s
CVAE-SEConvXGB	98.86	97.75	0.19
CGAN-SEConvXGB	98.04	96.93	0.25
SEConvXGB	93.17	90.95	0.17
Transformer	93.66	89.73	0.27
CNN	92.85	89.46	0.29
ConvXGB	92.64	88.71	0.15
BP	86.77	79.16	0.33

从表 7 可以看出, 当故障样本中存在小样本数据时, 由于 SEConvXGB、Transformer 等模型对小样本数据特征学习不充分, 导致过拟合现象发生, 测试集准确率会明显降低。本文提出的 CVAE-SEConvXGB 模型对小样本数据进行数据增强形成平衡数据集后, 模型能够对各个故障类型的数据特征进行充分学习, 因此模型对训练集与测试集的准确率都有较大的提升。且可以看出本文模型相较于其他模型训练集准确率提高 5.69% 以上, 测试集准确率提高 6.8% 以上。此外, 由于模型轻量化设计, 本文所提 CVAE-ConvXGB 模型在运行时间上比其他深度学习模型短。

在二次设备故障数据收集和传输的过程中, 受通信设备及网络状况的影响, 易出现“假告警”、“漏

报”的情况，使得收集到的二次设备故障样本集的数据存在噪声，影响模型对二次设备故障诊断的准确率。针对上述问题，本文选取部分故障样本数据并通过随机删除部分告警信息，以模拟二次设备故障数据中存在的噪声，将处理后的故障样本加入样本集进行训练^[9]。随后，从测试集中选取 100 种故障样本进行故障信息的随机删除，并测试模型的诊断准确率，结果如表 8 所示。

表 8 噪声问题下不同模型的容错性能

Table 8 Fault tolerance performance of various models under noisy conditions

模型	训练集准确率/%	测试集准确率/%
CVAE-SEConvXGB	96.47	94.83
SEConvXGB	91.33	88.41
Transformer	92.52	89.16
CNN	91.01	87.94
BP	83.79	80.24

由表 8 可知，在二次设备故障数据存在噪声的情况下，本文提出 CVAE-SEConvXGB 模型对二次设备故障类型的诊断准确率较高，具有良好的容错性能，在故障发生时能够快速准确地诊断具体故障类型，为运维工作提供理论支撑。

5 结论

针对智能变电站二次设备故障诊断过程中存在的小样本数据，导致模型诊断准确率降低这一问题，本文提出了一种基于条件变分自编码器与改进 ConvXGB 的二次设备小样本故障诊断方法，得到如下结论。

1) 分析二次设备故障时的告警信号与故障信息，形成设备故障信息特征集，从模拟量故障信息与数字量故障信息两个维度对故障断面进行描述。

2) 利用 CVAE 对故障样本数据集中的小样本数据进行数据增强，形成平衡数据集，解决深度学习算法对小样本数据特征学习不充分的问题。通过迭代学习确定学习率与生成样本所需的参数，并使用 PCA 算法与 t-SNE 算法对 CVAE 的潜在空间进行降维可视化处理。通过分析图像可知，生成样本分布逐渐接近原始样本，且各个类型之间具有良好的分类边界，说明模型具有较强的数据特征学习能力，生成的故障样本可用于设备的故障诊断。

3) 利用 SE 模块改进 ConvXGB 模型，提高模型的泛化能力，形成 CVAE-SEConvXGB 模型，将不平衡故障样本数据集输入 CVAE-SEConvXGB 模型并与其他深度学习模型进行对比。经迭代计算，本文提出的 CVAE-SEConvXGB 模型训练集准确率为

为 98.86%，测试集准确率为 97.75%，运行时间为 0.19 s，相较其他模型准确率及运算速度均有所提高，由此可见，本文提出的 CVAE-SEConvXGB 模型能够快速准确地处理小样本数据影响下二次设备的故障诊断问题。

参考文献

[1] 舒印彪, 张正陵, 汤涌, 等. 新型电力系统构建的若干基本问题[J]. 中国电机工程学报, 2024, 44(21): 8327-8341. SHU Yinbiao, ZHANG Zhengling, TANG Yong, et al. Fundamental issues of new-type power system construction[J]. Proceedings of the CSEE, 2024, 44(21): 8327-8341.

[2] 戴志辉, 张富泽, 韩笑. 基于同源录波数据比对的继电保护采样回路异常检测方法[J]. 电力系统保护与控制, 2025, 53(1): 147-159. DAI Zhihui, ZHANG Fuze, HAN Xiao. Anomaly detection method for a relay protection sampling circuit based on homologous waveform data comparison[J]. Power System Protection and Control, 2025, 53(1): 147-159.

[3] 李明节, 刘宇, 舒治淮, 等. 中国变电站二次系统技术发展形势分析[J]. 电网技术, 2024, 48(1): 1-12. LI Mingjie, LIU Yu, SHU Zhihuai, et al. Development trend of secondary system technology in China's substations[J]. Power System Technology, 2024, 48(1): 1-12.

[4] 张烈, 郭鹏, 李仲青, 等. 适应新型电力系统的继电保护综合评价方法[J]. 电网技术, 2024, 48(4): 1633-1645. ZHANG Lie, GUO Peng, LI Zhongqing, et al. A comprehensive evaluation method for relay protection adapted to new electric power system[J]. Power System Technology, 2024, 48(4): 1633-1645.

[5] 李卓, 谢耀滨, 吴茜琼, 等. 基于深度学习的电力系统虚假数据注入攻击检测综述[J]. 电力系统保护与控制, 2024, 52(19): 175-187. LI Zhuo, XIE Yaobin, WU Qianqiong, et al. Review of deep learning-based false data injection attack detection in power systems[J]. Power System Protection and Control, 2024, 52(19): 175-187.

[6] 戴志辉, 耿宏贤, 韩健硕, 等. 基于矩阵算法和 BP 神经网络的智能站二次系统故障定位方法[J]. 华北电力大学学报(自然科学版), 2022, 49(6): 1-10. DAI Zhihui, GENG Hongxian, HAN Jianshuo, et al. Fault location method of secondary system in smart substation based on matrix algorithm and BP neural network[J]. Journal of North China Electric Power University (Natural Science Edition), 2022, 49(6): 1-10.

[7] ZHOU Kequan, WANG Tao, CHEN Xiaotian, et al. A fault diagnosis method for power systems based on temporal tissue-like P systems[J]. Protection and Control of Modern Power Systems, 2024, 9(2): 101-114.

[8] 任博, 郑永康, 王永福, 等. 基于深度学习的智能变电站二次设备故障定位研究[J]. 电网技术, 2021, 45(2):

- 713-721.
REN Bo, ZHENG Yongkang, WANG Yongfu, et al. Fault location of secondary equipment in smart substation based on deep learning[J]. Power System Technology, 2021, 45(2): 713-721.
- [9] 宗鹏. 面向智能变电站的二次系统故障定位方法研究[D]. 济南: 山东大学, 2022.
ZONG Peng. Research on fault location method of secondary system for intelligent substation[D]. Jinan: Shandong University, 2022.
- [10] 王洪彬, 李智, 童晓阳, 等. 基于 GRU 的智能变电站二次设备故障定位研究[J]. 电测与仪表, 2025, 62(7): 200-208.
WANG Hongbin, LI Zhi, TONG Xiaoyang, et al. Fault location of secondary equipment in smart substation based on GRU[J]. Electrical Measurement & Instrumentation, 2025, 62(7): 200-208.
- [11] XIANG X, DONG X, HE J, et al. A study on the fault location of secondary equipment in smart substation based on the graph attention network[J]. Sensors, 2023, 23(23): 9384-9406.
- [12] 周海成, 石恒初, 曾令森, 等. 基于关系超图增强 Transformer 的智能站二次设备故障诊断研究[J]. 电力系统保护与控制, 2024, 52(12): 123-132.
ZHOU Haicheng, SHI Hengchu, ZENG Lingsen, et al. Fault diagnosis of an intelligent substation secondary device based on a relational hypergraph-enhanced Transformer[J]. Power System Protection and Control, 2024, 52(12): 123-132.
- [13] 金亮, 闫银刚, 杨庆新, 等. 小样本条件下永磁同步电机深度迁移学习性能预测方法[J]. 电工技术学报, 2023, 38(18): 4921-4931.
JIN Liang, YAN Yingang, YANG Qingxin, et al. Prediction method of deep transfer learning performance of permanent magnet synchronous motor under the condition of few-shot[J]. Transactions of China Electrotechnical Society, 2023, 38(18): 4921-4931.
- [14] 赵凯琳, 靳小龙, 王元卓. 小样本学习研究综述[J]. 软件学报, 2021, 32(2): 349-369.
ZHAO Kailin, JIN Xiaolong, WANG Yuanzhuo. Survey on few-shot learning[J]. Journal of Software, 2021, 32(2): 349-369.
- [15] 司伟伟, 岑健, 伍银波, 等. 小样本轴承故障诊断研究综述[J]. 计算机工程与应用, 2023, 59(6): 45-56.
SI Weiwei, CEN Jian, WU Yinbo, et al. Review of research on bearing fault diagnosis with small samples[J]. Computer Engineering and Applications, 2023, 59(6): 45-56.
- [16] 李平, 胡根铭. 基于数据增强型一维改进卷积神经网络的变压器故障诊断方法[J]. 电网技术, 2023, 47(7): 2957-2967.
LI Ping, HU Genming. Transformer fault diagnosis based on data enhanced one-dimensional improved convolutional neural network[J]. Power System Technology, 2023, 47(7): 2957-2967.
- [17] 周萱, 吴伟丽. 基于改进 SMOTE 不平衡样本处理和 IHPO-DBN 的变压器故障诊断方法研究[J]. 电力系统保护与控制, 2024, 52(11): 21-30.
ZHOU Xuan, WU Weili. Transformer fault diagnosis method based on improved SMOTE unbalanced sample processing and IHPO-DBN[J]. Power System Protection and Control, 2024, 52(11): 21-30.
- [18] 李东泽, 齐咏生, 刘利强, 等. 基于双流生成对抗网络数据增强的风电机组智能故障诊断[J]. 电力自动化设备, 2024, 44(11): 94-102.
LI Dongze, QI Yongsheng, LIU Liqiang, et al. Intelligent fault diagnosis of wind turbine unit based on dual-stream generative adversarial network data augmentation[J]. Electric Power Automation Equipment, 2024, 44(11): 94-102.
- [19] 茅婷, 程龙生, 张月义, 等. 基于 RLMTS 的小样本风力发电机齿轮箱故障检测[J]. 电力系统保护与控制, 2025, 53(10): 117-129.
MAO Ting, CHENG Longsheng, ZHANG Yueyi, et al. Fault detection of small-sample wind turbine gearboxes based on RLMTS[J]. Power System Protection and Control, 2025, 53(10): 117-129.
- [20] 刘占磊, 祝令瑜, 占草, 等. 基于 CNN-BiLSTM 的铁氧体磁芯损耗精确模型和小样本迁移学习预测方法[J]. 高电压技术, 2024, 50(10): 4487-4498.
LIU Zhanlei, ZHU Lingyu, ZHAN Cao, et al. Accurate ferrite core loss model based on CNN-BiLSTM and few-shot transfer learning prediction method[J]. High Voltage Engineering, 2024, 50(10): 4487-4498.
- [21] 翟正利, 梁振明, 周炜, 等. 变分自编码器模型综述[J]. 计算机工程与应用, 2019, 55(3): 1-9.
ZHAI Zhengli, LIANG Zhenming, ZHOU Wei, et al. Research overview of variational auto-encoders models[J]. Computer Engineering and Applications, 2019, 55(3): 1-9.
- [22] SETTHANUN T, SAICHON J, ANANTACHAI P, et al. ConvXGB: a new deep learning model for classification problems based on CNN and XGBoost[J]. Nuclear Engineering and Technology, 2021, 53(2): 522-531.
- [23] JIE H, LI S, SAMUEL A, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.

收稿日期: 2025-03-05; 修回日期: 2025-07-01

作者简介:

张洪嘉(1999—), 男, 硕士研究生, 研究方向为电力系统保护与控制; E-mail: zhanghjncepu@163.com

戴志辉(1980—), 男, 通信作者, 博士, 教授, 研究方向为电力系统保护与控制。E-mail: daihuadian@163.com

(编辑 许威)