

DOI:10.11918/202407047

样本不平衡下基于图卷积网络的化工过程故障诊断

钱强¹, 马萍², 王妮妮¹, 张宏立², 王聪², 李新凯¹

(1. 新疆大学 电气工程学院, 乌鲁木齐 830017; 2. 新疆大学 智能科学与技术学院, 乌鲁木齐 830017)

摘要:为解决实际化工过程故障样本匮乏, 现有故障诊断模型在数据分布不平衡下故障诊断准确率低的问题, 提出一种基于代价敏感多感受野时空图注意力网络(cost sensitive multireceptive fields spatio-temporal graph attention network, CSMRFST-GAT)故障诊断模型。该模型通过最大信息系数(maximal information coefficient, C_{MI})加权计算, 将化工过程采集的相关变量数据转换为拓扑图数据, 利用图卷积网络(graph convolution network, GCN)的故障诊断模型设计出了多感受野图卷积模块(multireceptive fields graph convolutional module, MRFGCM)和时空图注意力模块(space-time graph attention module, STGAM), 然后提出了混合边缘感知焦点损失函数(hybrid margin-aware focus loss, L_{HMF}), 用于对较难识别样本施加更多的惩罚。将所提模型应用于田纳西伊斯曼过程(Tennessee Eastman process, TEP)和三相流(three-phase flow, TPF)数据集中多个不平衡场景下评估其诊断性能。结果表明: 所提模型在 TPF 数据集中的分类精确率和 $F1$ 分数分别达到了 91% 和 92% 以上, 同时在 TEP 数据集中的分类召回率和 $F1$ 分数均突破了 99%; 相较于机器学习模型、深度学习模型以及图深度学习模型, 所提模型能更加有效地识别故障。所提模型在处理数据不平衡问题上具有优异的泛化性能, 能有效实现样本不平衡下化工过程故障诊断。

关键词: 化工过程; 故障诊断; 样本不平衡; 图深度学习; 混合边缘感知焦点损失函数

中图分类号: TP277

文献标志码: A

文章编号: 0367-6234(2025)09-0076-11

Graph convolutional network-based fault diagnosis of chemical process under sample imbalance

QIAN Qiang¹, MA Ping², WANG Nini¹, ZHANG Hongli², WANG Cong², LI Xinkai¹

(1. School of Electrical Engineering, Xinjiang University, Urumqi 830017, China;

2. School of Intelligence Science and Technology, Xinjiang University, Urumqi 830017, China)

Abstract: To solve the problem of low accuracy of existing fault diagnosis models under imbalanced data distribution caused by insufficiency of fault samples in practical chemical process, a fault diagnosis model based on cost sensitive multireceptive fields spatio-temporal graph attention network (CSMRFSTGAT) is proposed. This model converts the corresponding variable data collected from chemical process into topological graph data through maximum information coefficient (C_{MI}) weighted calculation. Using the fault diagnosis model of the graph convolutional network (GCN), multireceptive fields graph convolutional module (MRFGCM) and space-time graph attention module (STGAM) are designed. Then, a hybrid margin-aware focal loss function is proposed to impose more penalties on samples which are difficult to recognize. The proposed model is applied to evaluate its diagnostic performance in multiple imbalanced scenarios of the Tennessee Eastman process (TEP) and the three-phase flow (TPF) dataset. The results show that the proposed model achieves the classification precision and $F1$ score of more than 91% and 92% in the TPF dataset, and meanwhile the classification recall rate and $F1$ score in the TEP dataset both break through 99%, respectively; It can recognize faults more efficiently compared with the machine learning model, deep learning model and graph deep learning model. The proposed model has excellent generalization performance in dealing with the data imbalance problem, and can effectively realize chemical process fault diagnosis under sample imbalance.

Keywords: chemical process; fault diagnosis; sample imbalance; graph deep learning; hybrid margin-aware focus loss

随着中国化工技术的高速发展, 生产规模日趋大型化和复杂化, 对化工过程的安全稳定运行提出

了更高的要求。在现代化工厂中, 各种设备和工艺流程相互依赖、紧密联结, 任何一个环节的故障均可

收稿日期: 2024-07-15; 录用日期: 2024-08-24; 网络首发日期: 2025-04-25

网络首发地址: <https://link.cnki.net/urlid/23.1235.t.20250424.1807.002>

基金项目: 新疆维吾尔自治区自然科学基金(2022D01C367, 2023D01C187); “天山英才”培养计划(2023TSYCQNTJ0020, 2023TSYCCX0037)

作者简介: 钱强(1997—), 男, 硕士研究生; 马萍(1994—), 女, 副教授, 博士生导师; 张宏立(1972—), 男, 教授, 博士生导师

通信作者: 马萍, maping@xju.edu.cn

能导致生产效率下降,引发严重的安全事故和环境污染,甚至导致人员伤亡。为了有效应对这些挑战,化工过程的故障诊断研究显得尤为重要^[1]。由于智能制造和工业4.0概念的引入,化工过程中的数据采集量呈指数级增长,为基于深度学习的化工过程故障诊断方法提供了坚实的基础。

数据大爆发时代下,深度学习的方法被应用于故障诊断领域并取得了非常丰富的成果^[2]。基于自动编码器(autoencoder, AE)、深度置信网络(deep belief network, DBN)、卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural network, RNN)等深度学习方法在化工过程故障诊断中也得到了广泛应用。Wu等^[3]将原始过程数据转换成二维的特征图,然后设计一种包含卷积层、池化层、全连接层的深度卷积神经网络模型,实现了化工过程故障诊断;Liu等^[4]提出了一种融合多尺度残差卷积网络与长短时记忆网络的化工过程故障诊断方法,该方法通过前者提取过程数据的多尺度高维非线性空间特征,后者捕捉时序动态特征,实现时空特征的联合提取;He等^[5]利用过程机制将最相关的变量分配到子块中,然后利用多块时域卷积神经网络和一维卷积神经网络(one-dimensional convolutional neural network, 1DCNN)提取各子块变量的交叉相关性和时间相关性特征并将其用于化工过程故障诊断中。现有的深度学习方法在处理化工过程故障诊断问题时,基于变量时间常规序列或图像数据进行特征提取,尚未考虑各变量相互作用等关键信息特征^[6]。

图深度学习技术通过将深度学习方法与图信号处理相结合,在图结构数据上进行学习和推理,能够捕捉复杂的节点关系和拓扑信息。因此,图深度学习技术已逐渐应用于工业过程故障诊断领域。Zhang等^[7]利用变量之间的欧几里得空间距离关系将工业过程数据构建成K-近邻图,然后利用剪枝图卷积网络进行图数据的特征学习,进而从化工过程数据中提取故障特征信息以实现故障诊断;Wu等^[8]针对化工过程中的过程机制,将化工过程数据转换为固定拓扑图信号,然后将图卷积网络(graph convolution network, GCN)用于化工过程故障诊断,取得了良好的效果。以上方法验证了图深度学习技术在化工过程故障诊断中的有效性。当前,基于图深度学习的化工过程故障诊断研究仍面临重要挑战,其中首要解决的关键问题是如何构建能够精确表征多重故障信息的图信号结构。

Xu等^[9]利用皮尔逊相关系数将时间序列转换为具有节点和边的图结构,在GCN的基础上,设计

出一个具有抗噪能力的切比雪夫收缩图卷积网络来提取图结构的特征信息,在化工过程数据集上实现了精确诊断;Wu等^[10]结合化工过程拓扑知识构建拓扑图信号,提出了多通道动态图卷积网络,该网络从图数据中提取来自不同层面的故障动态信息,进一步增强了模型的故障诊断能力。上述常规图深度学习模型往往考虑提取图数据的空间特征,忽略了图数据上节点的时间特征。同时,在实际化工过程中面临故障样本不平衡的情况,深度学习模型难以有效挖掘少数类样本的故障特征,从而造成诊断精度下降^[11]。

近年来,研究人员主要从数据采样和分类算法两个层面解决不平衡分类问题。数据采样层面的方法主要通过对数据的过采样与欠采样来改变训练集的样本分布,降低不平衡程度,从而提高模型的分类能力。Peng等^[12]提出利用平衡生成对抗网络生成具有区分度的故障样本,利用主动学习选择信息量最大的样本,实现样本扩充以实现样本不平衡故障诊断;骆耀谱等^[13]提出利用条件卷积生成对抗网络扩充小样本不平衡数据,利用ResNet34深度网络进行一维振动信号的小样本不平衡故障诊断和分类。然而,上述方法会改变原始数据的分布,容易增加训练时间及丢失重要样本的信息,从而产生过拟合现象。分类算法层面主要利用集成学习、提升学习算法来提升模型对不平衡数据分类效果,通过对分类器的组合和算法的改进实现不平衡数据集的重新分类以提高对少数类样本的诊断率。潘海洋等^[14]提出利用双加权不平衡矩阵分类器调节样本权重和分配核范数的奇异值权重,从而提高了机械故障诊断在样本不平衡情景下的精度与泛用性。然而,此类方法需预先定义一个成本矩阵,但精确设置该矩阵却很难。如何提升样本不平衡条件下的故障诊断性能,成为一个迫切需要解决且具有挑战性的问题。

针对上述问题,本文提出一种代价敏感多感受野时空图注意力网络(cost sensitive multireceptive fields spatio-temporal graph attention network, CSMRFSTGAT)故障诊断模型。首先,为了有效表征变量之间的关系,从节点与节点之间关系角度出发,提出一种加权最大信息图信号。该信号引入最大信息系数(maximal information coefficient, C_{MI})表示变量之间的相关性,利用 C_{MI} 将多变量时间序列转换成加权拓扑图信号。其次,通过改进GCN构建多感受野图卷积模块(multireceptive fields graph convolutional module, MRFGCM)在不同尺度聚合邻居节点的特征信息,同时设计时空图注意力模块(space-time graph attention module, STGAM)以捕捉

图结构中的局部特征和全局关系。最后,提出混合边缘感知焦点损失函数(hybrid margin-aware focus loss, L_{HMF}),从样本和类两个角度实现对少样本的关注,从而提升数据不平衡下整体分类性能。选取两个不平衡分布情况的数据集进行系统性实验以验证所提模型的有效性。

1 加权最大信息图信号构建

1.1 互信息

互信息(mutual information, I_M)^[15]是评价两个变量相关性的指标,两个变量之间的关联性越大,则 I_M 值越大。设变量 $A = \{a_i\} (i = 1, 2, \dots, n_a)$, 变量 $B = \{b_j\} (j = 1, 2, \dots, m_b)$, 其中 n_a, m_b 为变量 A, B 中元素的个数。则变量 A 和 B 的 I_M 计算式为

$$I_M = \sum_{a \in A} \sum_{b \in B} p_{(a,b)} \log_2 \frac{p_{(a,b)}}{p_a \times p_b} \quad (1)$$

式中: $p_{(a,b)}$ 为变量的联合概率, p_a, p_b 分别为变量 a, b 的边缘概率密度。

将变量 A 的值域等分 x_a 份, B 的值域等分 y_b 份。变量 A 和 B 之间 C_{MI} 的计算式为

$$C_{MI} = \max_{x_a \times y_b < J} \left\{ \frac{I_M}{\log_2 \min\{x_a, y_b\}} \right\} \quad (2)$$

式中 J 为网格上限。

1.2 基于加权最大信息图信号构建

图是一种常见的数据结构,由节点和边构成。加权图是在图的连边上赋予权重,利用权重表达距离、成本等度量信息。假设某个工业过程测量数据中包含 n 个变量,即 $S_1 \sim S_n$, 将每个变量视为图中的节点,则 1 个图数据有 n 个节点。测量数据中的所有两两变量组合,计算其间的 C_{MI} , 并将该系数作为节点之间边的权重。然后,通过引入阈值来控制图数据结构的复杂性。当节点之间的 C_{MI} 值超过该阈值时,则在这两个节点之间建立连边;当 C_{MI} 值低于阈值时,则不在两个节点之间建立连边。图信号构建过程如图 1 所示。

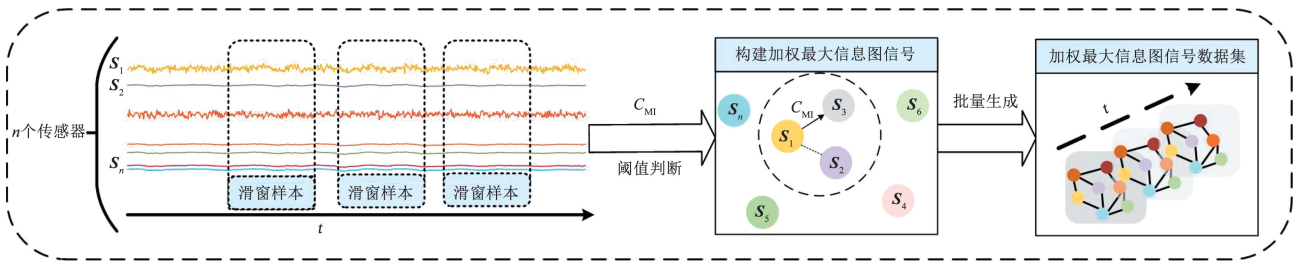


图 1 加权最大信息图信号构建过程

Fig. 1 Weighted maximum information graph signal construction process

2 代价敏感多感受野时空图注意力网络

2.1 多感受野图卷积模块

GCN 基于 CNN 思想,将卷积运算扩展至图结构中。GCN 主要用于学习图数据中节点的图数据任务,如点分类、图分类、链接预测等^[16]。GCN 在谱域中表达式为

$$\mathbf{G}_{CN} = G_C(\mathbf{X}, \mathbf{H}) = \mathbf{U} \times ((\mathbf{U}^T \times \mathbf{H}) \odot (\mathbf{U}^T)) \quad (3)$$

式中: \mathbf{G}_{CN} 为图卷积网络输出特征, $G_C(\cdot)$ 为图卷积操作, \mathbf{X} 为输入图信号, \mathbf{H} 为卷积核, \mathbf{U} 为特征向量矩阵, \odot 为哈德玛积。

Defferrard 等^[17]提出利用切比雪夫多项式代替谱域的卷积核,则式(3)变为

$$\mathbf{G}_{CN} = G_C(\mathbf{X}, \mathbf{H}) = \sum_{k=0}^{K-1} \theta_k \times T_k(\tilde{\mathbf{L}}) \times \mathbf{X} \quad (4)$$

$$\tilde{\mathbf{L}} = \frac{2\mathbf{L}}{\lambda_{\max}} - \mathbf{I}_N \quad (5)$$

式中: K 为切比雪夫多项式的阶数, θ_k 为切比雪夫多项式系数, \mathbf{L} 为拉普拉斯矩阵, $T_k(\tilde{\mathbf{L}})$ 为以 \mathbf{L} 为基本形式的切比雪夫多项式, \mathbf{I}_N 为单位矩阵, λ_{\max} 为对 \mathbf{L} 进行特征分解的最大特征值。

在切比雪夫图卷积网络的基础上,令 $\lambda_{\max} = 2$, $K = 2$, $\theta_0 = -\theta_1 = 1$, 式(4)可进一步变为

$$\mathbf{G}_{CN} = G_C(\mathbf{X}, \mathbf{H}) = (\mathbf{I}_N + \mathbf{D}^{-\frac{1}{2}} \times \mathbf{A}_d \times \mathbf{D}^{-\frac{1}{2}}) \times \mathbf{X} \quad (6)$$

式中: \mathbf{A}_d 为邻接矩阵, \mathbf{D} 为度矩阵。

将式(6)中 $\mathbf{I}_N + \mathbf{D}^{-\frac{1}{2}} \times \mathbf{A}_d \times \mathbf{D}^{-\frac{1}{2}}$ 归一化为 $\tilde{\mathbf{D}}^{-\frac{1}{2}} \times \tilde{\mathbf{A}} \times \tilde{\mathbf{D}}^{-\frac{1}{2}}$, 其中 $\tilde{\mathbf{D}}$ 和 $\tilde{\mathbf{A}}$ 分别为归一化后的度矩阵和邻接矩阵。令 $\hat{\mathbf{A}} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \times \tilde{\mathbf{A}} \times \tilde{\mathbf{D}}^{-\frac{1}{2}}$, GCN 表达式简化为

$$\mathbf{H}^l = \sigma(\hat{\mathbf{A}} \times \mathbf{H}^{(l-1)} \times \mathbf{W}^l) \quad (7)$$

式中: \mathbf{H}^l 和 $\mathbf{H}^{(l-1)}$ 分别为 GCN 第 l 层和第 $l-1$ 层输

出, W^l 为 GCN 中的权重矩阵, $\sigma(\cdot)$ 为激活函数。

目前,大多数 GCN 都是在未加权的图上构建的,并假设所有邻居节点的重要性相同,这与实际情况不完全符合。此外,GCN 的感受野是固定的,这限制了 GCN 在特征表示方面的有效性。谱域中的图滤波器可以用 K 阶切比雪夫多项式表示,即拉普拉斯矩阵亦为 K 阶,参数 K 即为感受野大小。当频域滤波器为 K 阶多项式时,等价于 K -hop 邻域滤波^[18]。然而,切比雪夫多项式的阶数是固定的,这意味着切比雪夫图卷积网络模块的感受野也是固定的,导致传统的图卷积层无法学习多域信息^[19]。因此,为了聚合来自不同感受野的信息,本文设计了一个 MRFGCM。其核心思想在于聚合来自多个不同邻域的信息,并将特征融合为更强大的特征表示。图数据中的节点定义为 $\tilde{X} = [\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n]$, 对应的多感受野图卷积表达式为

$$H_M = \left[\sum_{k_1=0}^{K_1-1} \theta'_{k_1} \times T_{k_1}(L) \times \tilde{X}, \sum_{k_2=0}^{K_2-1} \theta'_{k_2} \times T_{k_2}(L) \times \tilde{X}, \dots, \sum_{k_o=0}^{K_o-1} \theta'_{k_o} \times T_{k_o}(L) \times \tilde{X} \right] \quad (8)$$

式中: H_M 为经过多感受野特征提取后的节点特征, $[\cdot]$ 为串联运算符, o 为感受野的数量, K_1, K_2, K_o 为所提多感受野图卷积表达式中不同感受野的大小, k_1, k_2, k_o 为 k 阶多项式的顺序, $\theta'_{k_1}, \theta'_{k_2}, \theta'_{k_o}$ 为不同感受野多项式的切比雪夫系数。

在实践中,邻接矩阵和图节点特征通常用作 GCN 的输入。因此,式(8)可简化为

$$H_M = [A^{K_1-1} \times \tilde{X} \times W_0, A^{K_2-1} \times \tilde{X} \times W_1, \dots, A^{K_o-1} \times \tilde{X} \times W_o] \quad (9)$$

式中: W_0, W_1 和 W_o 为每个感受野图卷积网络的权重矩阵, A^{K_1-1}, A^{K_2-1} 和 A^{K_o-1} 为每个感受野图卷积网络的邻接矩阵。

如前所述,感受野与 K 的取值有关。本文实际应用的 MRFGCM 包含 3 个不同感受野的切比雪夫图卷积网络层,这些切比雪夫图卷积网络层分别提取了不同阶邻居节点中的重要信息。当 $K_1 = 1$ 时,聚合的节点特征来自节点本身,提取的特征为 $[t_1, t_2, \dots, t_n]^T$; 当 $K_2 = 2$ 时,聚合特征是 1 阶邻居节点的特征,提取的特征为 $[m_1, m_2, \dots, m_n]^T$; 当 $K_3 = 3$ 时,聚合的节点特征来自 2 阶邻居节点的特征,提取的特征为 $[r_1, r_2, \dots, r_n]^T$ 。MRFGCM 结构如图 2 所示。




图 2 MRFGCM 结构

Fig. 2 MRFGCM structure

2.2 时空图注意力模块

图注意力网络(graph attention network, GAT)被视为是对 GCN 的一种改进,其核心原理是将注意力机制引入图结构数据处理中^[20]。在 GAT 中,注意力机制决定了邻居节点对当前节点的贡献程度,从而使得模型能够动态地调整邻居节点的影响力。图注意力系数和节点更新表达式分别为:

$$\alpha_{ij} = \frac{\exp(L_r(\vec{a}^T \times ([WX_i \parallel WX_j])))}{\sum_{k \in N_i} \exp(L_r(\vec{a}^T \times ([WX_i \parallel WX_k])))} \quad (10)$$

$$Z_i = \parallel_{Z=1}^Z \sigma \times \left(\sum_{j \in N_i} \alpha_{ij}^Z \times W^Z \times X_j \right) \quad (11)$$

式中: α_{ij} 为图注意力系数, α_{ij}^Z 为不同注意力头的注意力系数, \vec{a}^T 为转置后可学习的参数向量, \parallel 表示拼接操作, N_i 为中心节点 i 的邻居集合, X_i, X_j 分别为节点 i, j 的特征, Z_i 为 i 节点经过 GAT 聚合后的特征, Z 为注意力头数, $L_r(\cdot)$ 为 LeakyReLU 激活函数, W 为 GAT 中的权重矩阵, W^Z 为不同注意力头中的权重矩阵。

图 3 为 GAT 与 STGAM 结构。其中,图 3(a) 为 GAT ($Z = 3$) 示意图,Head 表示多头注意力机制中的一个独立注意力头,Softmax 表示归一化操作。每个独立注意力头会计算不同的注意力权重,帮助模型从多角度捕捉节点与其邻居的关系。注意力系数主要用于聚合邻居节点的权重,以便更有效地建模图结构和挖掘图特征。尽管 GAT 在捕捉图结构数据的空间依赖性方面表现优异,但难以提取图数据上节点的时间特征。为了克服这一不足,本文引入了时间卷积网络(temporal convolutional network, TCN),其能够通过膨胀因果卷积有效捕捉长时间跨度的依赖性。TCN 利用卷积操作对时间序列进行处理,确保时间的前后顺序一致性,并通过扩展卷积核覆盖更长的时间范围,从而增强对时间依赖特征的建模能力。通过结合 GAT 和 TCN,STGAM 能够同时捕捉数据中的空间和时间特征,从而提高模型在处理时空数据时的整体性能。STGAM 结构如图 3(b) 所示。

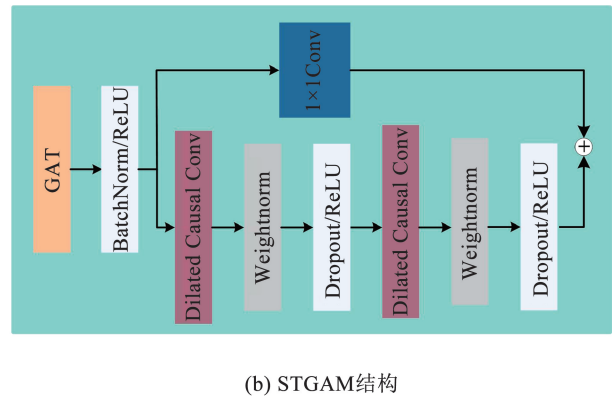
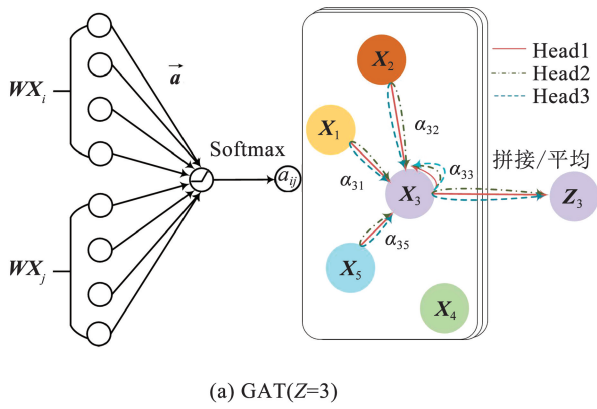


图 3 GAT 与 STGAM 结构

Fig. 3 GAT and STGAM structure

2.3 混合边缘感知焦点损失函数

近年来,焦点损失函数(focal loss, L_F)作为一种有效的方法被广泛应用于处理不平衡数据分类问题。 L_F 可以使模型更加聚焦于那些难以分类的样本,提升模型对于困难样本的学习效果^[21]。假设不平衡数据有 C 个类别,每个样本的标签以 C 维的独热编码向量表示其所属类别,而模型的输出则通常为一个 C 维向量,描述了对每个类别的预测概率。对于第 q 个样本和第 s 个类别, L_F 的表达式为

$$L_F = -\frac{1}{n_f} \sum_{q=1}^{n_f} \sum_{s=1}^C [\alpha_f \times (1 - Y'_{qs})^{\gamma_f} \times Y_{qs} \times \ln Y'_{qs}] \quad (12)$$

式中: n_f 为样本总数量, Y_{qs} 为第 q 个样本的真实标签, Y'_{qs} 为第 q 个样本预测为 s 的概率, α_f 为 L_F 的平衡参数, γ_f 为 L_F 的聚焦参数。

L_F 未能从数据类别间分类边界考虑,导致在不平衡数据集上效果不佳。而标签分布感知边际损失函数(label distribution aware margin loss, L_{LDAM})可解决类别不平衡问题,通过将边际距离与标签分布信息结合,使模型能够更加专注于那些在标签分布上边际距离较大的样本,从而提高模型对类别不平衡的适应能力^[22]。设 x_D 为一个特定的样本, y_D 为 x_D 的相应标签, $f(\cdot)$ 为模型, $z_{y_D} = f(x_D)$, y_D 为模型对该特定样本的输出,样本所属类别边际值 $\Delta_{y_D} = \frac{C_D}{n_{y_D}^{1/4}}$,

其中 C_D 为常数, n_{y_D} 为 y_D 类别中的样本数。则 L_{LDAM} 表达式为

$$L_{LDAM}((x_D, y_D), z_{y_D}) = -\log \frac{e^{z_{y_D} - \Delta_{y_D}}}{e^{z_{y_D} - \Delta_{y_D}} + \sum_{j_D \neq y_D} e^{z_{j_D}}} \quad (13)$$

重加权(delay re-weight, DRW)是一种用于处理类不平衡数据集的训练技术。重加权标签分布感知边缘损失(delay re-weight and label distribution aware margin loss, $L_{DRW-LDAM}$)利用 L_{LDAM} 训练前 T 个 epoch,然后对学习率进行退火,最后在第 T 个训练轮数后下调学习率并对损失函数赋予权重,部署具有较小学习率的重新加权 L_{LDAM} 。

综合考虑难以分类的样本和类不平衡数据的学习问题,结合 L_F 和 $L_{DRW-LDAM}$ 优势,本文提出融合 L_F 与 $L_{DRW-LDAM}$ 的 L_{HMF} 。 L_{HMF} 利用 L_F 机制重视模型难以分类的样本;此外,其充分发挥了 $L_{DRW-LDAM}$ 的作用,即考虑数据集的类别分布,使得少数类样本更容易被正确分类。双重机制的设计使得 L_{HMF} 能够从样本级别和类别级别两个维度出发,更全面地提升对于少数类样本的关注。 L_{HMF} 的表达式为

$$L_{HMF} = \gamma L_{DRW-LDAM} + \beta L_F \quad (14)$$

式中 γ 和 β 为可调整的超参数。

2.4 CSMRFSTGAT 模型结构

CSMRFSTGAT 模型由 STGAM、MRFGCM、全连接层、激活函数以及 L_{HMF} 等组成。模型中的 STGAM 主要用于提取节点中的非欧几里得空间特征,引入注意力机制有效提取不同邻居节点的特征,并结合 TCN 提取图数据中每个节点上的时间特征;MRFGCM 用于从具有不同感受野的邻居节点中提取节点特征; L_{HMF} 用于增强对少数类样本的关注。总体而言,CSMRFSTGAT 结构的设计旨在提高其对工业过程中复杂数据的处理能力,具体参数见表 1。

表1 CSMRFSTGAT 参数
Tab.1 CSMRFSTGAT parameters

网络层	网络层类型	网络层参数	核
特征提取器	STGAM	GATConv1	Sample length × 200
		BatchNorm	
		ReLU	
	MRFGCM	TCN	Kernel_size = 3, Stride = 1, Padding = 2, Dropout = 0.2
		MRFGCM	
		GATConv1	
STGAM	BatchNorm	200 × 200	
	ReLU		
	TCN		
特征分类器	全连接层	FC Layer1	14 024 × 1 024
		ReLU	
		FC Layer2	
		Softmax	

3 基于 CSMRFSTGAT 的化工过程故障诊断流程

利用 CSMRFSTGAT 进行样本不平衡下化工过程故障诊断的框架如图 4 所示, 主要包括以下几个部分。

1) 采集原始数据, 然后对原始数据进行归一化, 以消除不同变量之间量纲的差异, 防止某些变量在训练过程中因取值范围较大而主导模型。采用滑动窗口技术将时间序列数据分割成固定长度的窗口, 以捕捉短期动态特征。

2) 计算处理后的数据中变量之间的 C_{MI} , 以衡量变量之间的相关性。基于计算得到的 C_{MI} , 构建图信号。其中每个节点代表一个变量, 边的权重为对应的 C_{MI} , 得到加权最大信息图信号。

3) 得到加权最大信息图信号数据集, 并将数据集按不同不平衡比例划分为训练集和测试集。

4) 采用训练集对 CSMRFSTGAT 模型进行训练, 采用 Adam 优化算法, 训练过程中需监控训练损失, 以防止过拟合。

5) 将测试集输入诊断模型中并输出诊断结果, 采用召回率 (R)、精确率 (P)、F1 分数 (F_{1-S}) 性能指标对模型性能进行综合评估。上述指标计算式分别为:

$$R = \frac{T_p}{T_p + F_N} \quad (15)$$

$$P = \frac{T_p}{F_p + T_N} \quad (16)$$

$$F_{1-S} = \frac{2 \times P \times R}{P + R} \quad (17)$$

式中: T_p 为实例是正类并被预测为正类的个数, F_N 为实例是正类被预测为负类的个数, F_p 为实例是负类被预测为正类的个数, T_N 为实例是负类被预测为负类的个数。 R 、 P 和 F_{1-S} 数值越大, 模型性能越优。

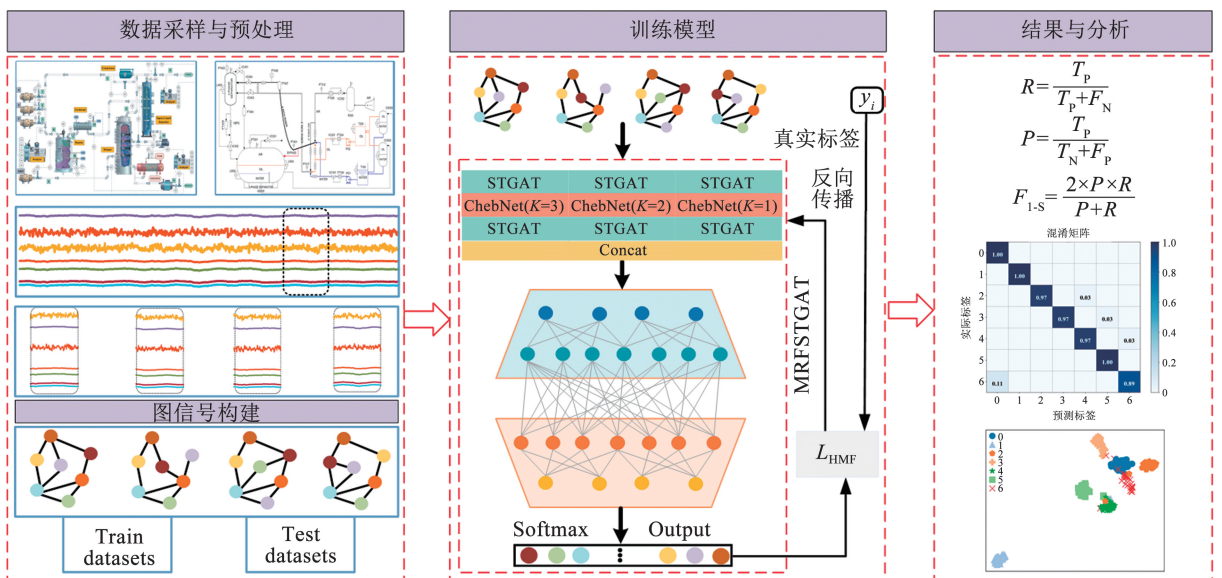


图4 基于 CSMRFSTGAT 工业过程故障诊断框架

Fig.4 Framework diagram for industrial process fault diagnosis based on CSMRFSTGAT

4 实验结果与分析

4.1 三相流数据集实验分析

4.1.1 数据集介绍及预处理

三相流数据集(three-phase flow, TPF)仿真系统是由 Cranfield 大学设计开发的,旨在为加压系统提供受控和测量的油、水和空气流量。整个系统的数据以 1 Hz 的采样率进行捕获,并始终在 0.1 MPa 的环境下运行^[23]。TPF 过程数据包含 24 个过程变量,模拟了 6 种典型故障及系统正常运行的状态,具体描述见表 2。对归一化后的 TPF 数据进行滑窗处理,并计算滑窗数据中两两变量之间的 C_{MI} ,以此构建图信号。

本实验在 PyTorch 框架上实现,硬件配置包括 CPU(Intel i9-12900H @ 2.30 GHz)、GPU(NVIDIA GeForce RTX 3070Ti)以及运行内存(16 GB)。模型训练的超参数设置如下:批量大小为 32,学习率为

3×10^{-4} , epoch 为 40。为验证所提模型在处理不平衡数据集时的分类效果,实验将训练集中的 7 类数据分别按照平衡分布及两种极端不平衡分布进行划分,具体分布情况见表 3。实验中训练集选取正常样本数为 160,其他故障样本数分别依据表 3 中不同比例进行选取。其中,正常样本与故障 1 样本数比值高达 10:1。

表 2 TPF 故障类型描述

Tab.2 Description of TPF fault types

类型	描述
故障 1	空气管堵塞
故障 2	水管堵塞
故障 3	二相分离器输入堵塞
故障 4	支路打开
故障 5	段塞流
故障 6	管线 2 加压

表 3 TPF 平衡与不平衡数据集具体分布情况

Tab.3 Specific data distribution of TPF-balanced and imbalanced datasets

比例类型	故障 0	故障 1	故障 2	故障 3	故障 4	故障 5	故障 6
平衡比例	1.0	1.0	1.0	1.0	1.0	1.0	1.0
不平衡比例 1	1.0	0.1	0.3	0.4	0.2	0.7	1.0
不平衡比例 2	1.0	0.1	0.2	0.3	0.4	0.5	1.0

4.1.2 L_{HMF} 有效性分析

为了验证所提 L_{HMF} 的有效性,将交叉熵损失函数(cross-entropy loss, L_{CE})、 L_F 、均衡焦点损失函数(equalized focal loss, L_{EF})、 L_{LDAM} 、 $L_{DRW-LDAM}$ 分别与剥离 L_{HMF} 后的 CSMRFSTGAT 相结合,然后与 CSMRFSTGAT 进行对比,并应用于表 3 所示的 3 种不同数据分布情况下的 TPF 数据诊断中。每组实验运行 10 次,分别计算 P 和 F_{1-S} 的平均值,实验结果见表 4。由表 4 可知:在平衡比例数据分布情况下,各损失函数结合所提模型的 P 和 F_{1-S} 均达到了 97.42% 和 97.53% 及以上,说明在各样本数量均衡情况下,以上损失函数仍具备良好的分类性能。在不平衡比例 1 情况下, L_{HMF} 的 P 和 F_{1-S} 分别为

94.34% 和 94.66%, 高于 L_{CE} 、 L_F 和 L_{LDAM} 等损失函数,说明 L_{HMF} 能够更有效地处理不平衡数据,显著提升了模型对少数类别的分类准确率。在不平衡比例 2 情况下,尽管 L_{HMF} 的 P 和 F_{1-S} 相比不平衡比例 1 的情况有所下降,但仍保持在所有损失函数中的最高水平。 L_{CE} 在正常情况下表现优异,但在不平衡比例情况下,其性能显著下降,这是由于 L_{CE} 未考虑类别之间的不平衡,导致对少数类样本的预测性能下降。以上实验结果说明,在不同程度的数据不平衡情况下, L_{HMF} 均能取得最好的诊断效果,证明了 CSMRFSTGAT 在数据不平衡情况下良好的泛化性和优越性。

表 4 各损失函数在 TPF 平衡与不平衡数据集上的分类效果

Tab.4 Classification performance of various loss functions on TPF-balanced and imbalanced datasets

损失函数	平衡比例		不平衡比例 1		不平衡比例 2		%
	P	F_{1-S}	P	F_{1-S}	P	F_{1-S}	
L_{CE}	97.42	97.53	86.96	87.47	86.89	88.30	
L_F	97.84	97.67	90.34	91.94	89.49	90.17	
L_{EF}	98.32	98.28	89.48	91.02	88.70	90.49	
L_{LDAM}	98.17	97.80	90.79	92.56	87.30	88.98	
$L_{DRW-LDAM}$	98.37	98.21	89.74	91.69	90.20	91.78	
L_{HMF}	98.59	98.52	94.34	94.66	91.50	92.91	

4.1.3 模型诊断性能评估

为验证所提模型在故障诊断中的分类能力,将所提模型与机器学习模型、深度学习模型和图深度学习模型进行对比。机器学习模型为基于主成分分析的支持向量机 (PCA-SVM),深度学习模型包括

1DCNN、CNN、TCN 和卷积神经网络-长短期记忆网络 (CNN-LSTM),谱域图深度学习模型有 GCN 和 MRFGCN,空域图深度学习模型为 GAT。在 3 种不同数据分布情况下,分别运行上述模型 10 次,并分别计算其 P 和 $F_{1,s}$ 的平均值,结果见表 5。

表 5 各模型在 TPF 平衡与不平衡数据集上的分类效果

Tab.5 Classification performance of various models on TPF-balanced and imbalanced datasets

模型	平衡比例		不平衡比例 1		不平衡比例 2	
	P	$F_{1,s}$	P	$F_{1,s}$	P	$F_{1,s}$
1DCNN	90.93	88.05	63.82	43.18	38.96	34.75
PCA-SVM	84.90	84.32	21.40	18.29	31.40	17.94
CNN	88.42	90.18	57.77	47.83	51.08	41.08
CNN-LSTM	88.21	89.73	68.39	66.95	57.58	57.79
TCN	89.65	91.31	76.07	75.65	72.66	71.21
GCN	94.52	93.67	79.92	79.92	77.45	75.29
MRFGCN	96.90	96.29	89.78	89.74	87.12	84.45
GAT	96.25	96.23	86.94	88.57	85.76	87.35
CSMRFSTGAT	98.59	98.52	94.34	94.66	91.50	92.91

由表 5 可知:在数据平衡比例分布情况下,CSMRFSTGAT 的 P 和 $F_{1,s}$ 分别达到 98.59% 和 98.52%,与 GAT、MRFGCN、TCN、GCN 相比,分别提高了 1.69% ~ 13.69% 和 2.23% ~ 14.20%,表明同时提取化工过程数据中的复杂时空特征能够提高模型的性能,CSMRFSTGAT 能更加关注少数类样本信息,有效克服了数据不平衡对故障诊断性能的影响。在不平衡比例 1 情况下,CSMRFSTGAT 的 $F_{1,s}$ 和 P 明显优于对比模型。在不平衡比例 2 情况下,CSMRFSTGAT 的 $F_{1,s}$ 和 P 分别为 92.91% 和 91.50%,所有对比模型中表现最优。在两种不平衡比例数据分布情况下,图深度学习模型受不平衡数据分布的影响也明显小于传统深度学习模型,这主要得益于图深度学习模型能够有效提取非欧几里得空间特征。综上所述,CSMRFSTGAT 在进行故障分类时表现出卓越的分类性能,不仅在平衡比例数据分布情况下表现优异,而且在面对高度不平衡的数

据分布时依然能够保持较高的 P 和 $F_{1,s}$ 。

上述分析表明,CSMRFSTGAT 不仅可以通过成本敏感的方法挖掘不平衡信息,还可以通过图神经网络从多传感器数据中挖掘结构信息,从而促进不平衡数据分布故障诊断。图 5 为 CSMRFSTGAT 在数据平衡情况下的混淆矩阵和分类器输出特征的 t 分布随机近邻嵌入 (t -distributed stochastic neighbor embedding, t -SNE) 特征可视化结果。由图 5 (a) 可知,尽管 CSMRFSTGAT 对故障 6 的故障准确率为 89.00%,但对绝大多数故障的准确率均达到了 97.00% 以上,验证了其在故障识别方面的优越性能。图 5 (b) 中的每个点代表一个图信号样本,不同故障的图信号样本采用不同的形状加以区分。经过 CSMRFSTGAT 模型特征提取后,仅有个别数据与所属类别的样本不同,大部分故障特征已得到有效分离,分类效果显著。

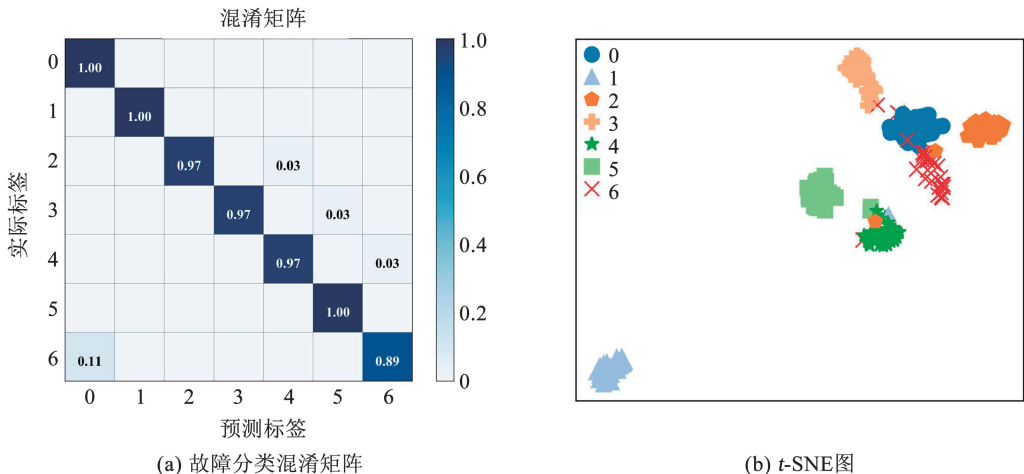


图 5 CSMRFSTGAT 输出混淆矩阵以及 t -SNE 图

Fig.5 CSMRFSTGAT output confusion matrix and t -SNE plot

4.2 田纳西伊斯曼过程数据集实验分析

4.2.1 数据集介绍及预处理

田纳西伊斯曼过程(Tennessee Eastman process, TEP)是美国 Tennessee Eastman 化学公司提出的一个实际化工过程的仿真数据集,被广泛用于化工过程故障诊断的模拟研究验证^[24]。TEP 主要分为反应器、冷凝器、压缩机、分离器和汽提塔 5 个单元,包括 A~H 共 8 种主要成分,有 41 个测量变量和 11 个控制变量,预设 21 类故障。对于多分类不平衡故障诊断,随机选择正常数据、故障 4、故障 5 和故障 14 进行分析,故障描述见表 6。

表 6 TEP 故障类型描述

Tab. 6 Description of TEP fault types

编号	故障类型	故障描述
4	阶跃	反应器冷却水入口温度发生变化
5	阶跃	冷凝器冷却水入口温度发生变化
14	黏滞	反应器冷却水阀门

实验模型、环境配置等与 4.1 节一致。对归一化处理后的数据进行滑窗处理,然后将处理得到的滑窗数据构成图数据。数据集中的 4 类数据按平衡与两种极端不平衡数据分布,具体分布情况见表 7。在训练集中选取正常样本数据 100 个,其他故障样本数分别依据表 7 中的比例进行选取。在不平衡比例 1 中,正常样本数与故障 14 样本数比值及在不平衡比例 2 中正常样本数与故障 4 样本数比值均高

表 8 各损失函数在 TEP 平衡与不平衡数据集上的分类效果

Tab. 8 Classification performance of various loss functions on TEP-balanced and imbalanced datasets

损失函数	平衡比例		不平衡比例 1		不平衡比例 2	
	R	F_{1-S}	R	F_{1-S}	R	F_{1-S}
L_{CE}	97.67	99.28	94.34	95.76	94.73	96.16
L_F	100.00	100.00	97.64	98.03	98.31	98.32
L_{EF}	100.00	100.00	96.43	97.67	97.12	98.02
L_{LDAM}	97.07	98.58	94.82	96.47	97.44	98.29
$L_{DRW-LDAM}$	99.40	99.60	96.17	97.36	99.41	99.31
L_{HMF}	100.00	100.00	99.73	99.28	100.00	100.00

4.2.3 模型诊断性能评估

为了验证所提模型在 TEP 数据集上的诊断性能,将其与 4.1 节中的对比模型进行对比分析。对比模型与 4.1 实验中所采用的模型参数只在模型的输入层和输出全连接层略有不同,其他均保持不变。在 3 种不同数据分布情况下,模型运行 10 次,计算 R 和 F_{1-S} 的平均值,结果见表 9。

由表 9 可知:在平衡比例数据分布情况下,CSMRFSTGAT 的 F_{1-S} 和 R 分别比 MRFGCN、GAT、

达 10:1。

表 7 TEP 平衡与不平衡数据集具体分布情况

Tab. 7 Specific data distribution of TEP-balanced and imbalanced datasets

比例类型	故障 0	故障 4	故障 5	故障 14
平衡比例	1.0	1.0	1.0	1.0
不平衡比例 1	1.0	0.2	0.3	0.1
不平衡比例 2	1.0	0.1	0.2	0.3

4.2.2 L_{HMF} 的有效性分析

为了进一步验证损失函数对模型的影响,将 4.1 节中 5 种不同的损失函数与 L_{HMF} 进行对比,结果见表 8。由表 8 可知:在数据平衡比例分布情况下,各种损失函数均表现出良好的效果, L_{HMF} 的 R 和 F_{1-S} 均达到了 100%。当数据处于不平衡情况下时, L_F 与 L_{EF} 的 R 与 F_{1-S} 均下降。在两种不平衡比例数据分布情况下,基于 L_{CE} 的模型 R 和 F_{1-S} 分别为 94.34%、94.73% 和 95.76%、96.16%,表现最差。此外, $L_{DRW-LDAM}$ 通过关注类边际距离结合延迟加权的方式,在面对两种不平衡数据分布情况下,模型的 R 和 F_{1-S} 分别为 96.17%、99.41% 和 97.36%、99.31%,表明其能有效地关注少数类样本。 L_{HMF} 通过综合考虑样本与类分布,加强对少数类样本的关注,在不平衡比例 1 数据分布情况下的 R 和 F_{1-S} 分别为 99.73% 和 99.28%;在不平衡比例 2 数据分布情况下,模型的诊断效果几乎不受任何影响。

TCN、GCN 提升了 0%~3.20% 和 0%~4.76%,这主要得益于所提模型能够同时提取数据的多感受野时空特征。在平衡比例和不平衡比例 2 数据分布情况下,CSMRFSTGAT 的 R 与 F_{1-S} 达到 100%,对所有故障类型数据均分类成功。在不平衡比例 1 情况下, R 与 F_{1-S} 分别为 99.73% 和 99.28%,说明诊断效果显著。在平衡比例数据分布情况中,GAT 模型利用注意力机制捕捉重要节点特征, R 与 F_{1-S} 同样达到了 100%。在两种数据不平衡比例分布情况下,

相较于传统深度学习模型,普通图深度学习模型表现出了显著优势,其 $F_{1,S}$ 和 R 分别提高 18.17% ~ 59.31%、17.88% ~ 59.62% 和 15.43% ~ 50.91%、15.5% ~ 54.7%。面对不平衡样本时,深度学习模型诊断能力显著降低,而图深度学习模型因强大的时空特征提取能力,仍保持良好的诊断能力。

图 6 为 CSMRFSTGAT 模型的输出混淆矩阵与

特征可视化结果。由图 6 (a) 可以看出,CSMRFSTGAT 模型对所有故障均分类正确,具有非常好的故障识别效果。由图 6 (b) 可知,经过 CSMRFSTGAT 模型特征提取和分类后,所有故障特征均已有效分离,进一步证明了其在故障分类任务中的优越性能。

表 9 各模型在 TEP 平衡与不平衡数据集上的分类效果

Tab. 9 Classification performance of various models on TEP-balanced and imbalanced datasets

模型	平衡比例		不平衡比例 1		不平衡比例 2	
	R	$F_{1,S}$	R	$F_{1,S}$	R	$F_{1,S}$
1DCNN	87.98	89.89	41.77	35.31	40.76	34.75
PCA-SVM	85.95	85.94	28.01	13.24	26.53	11.30
CNN	91.57	92.30	66.37	58.85	67.76	60.32
CNN-LSTM	93.57	94.34	72.21	68.11	73.37	69.45
TCN	95.24	96.80	72.86	71.84	74.08	73.73
GCN	96.59	97.69	88.29	90.10	89.58	91.61
MRFGCN	98.49	98.99	91.67	93.68	95.46	94.37
GAT	100.00	100.00	92.68	94.62	92.50	94.44
CSMRFSTGAT	100.00	100.00	99.73	99.28	100.00	100.00




图 6 CSMRFSTGAT 输出混淆矩阵以及 t -SNE 图

Fig. 6 CSMRFSTGAT output confusion matrix and t -SNE plot

5 结论

本文提出了样本不平衡下基于 CSMRFSTGAT 的化工过程故障诊断模型,通过两个数据集验证了所提模型的有效性。主要结论如下:

1) 通过挖掘化工过程多传感器信号之间的互信息构建加权最大信息图信号,有效地表征了变量之间的内在关系,并结合图深度学习削弱了数据分布不平衡对故障诊断的影响。

2) 提出了 L_{HMF} , 该损失函数利用 L_F 机制重视难以分类的样本,利用 L_{LDAM} 解决类别不平衡问题。在

处理样本不平衡数据集时,相较于其他损失函数,该损失函数表现出较优的性能。

3) 所提出的 CSMRFSTGAT 模型,通过 MRFGCN 和 STGAM 提取了节点不同尺度的特征信息,有效捕捉了图信号中节点上的时间演变。所提模型在不平衡比例数据集集中的 $F_{1,S}$ 均在 92.91% 及以上, R 均在 99.73% 及以上, P 在 91.50% 及以上。对比实验结果表明,在样本不平衡下的化工过程故障诊断中,相较于传统深度学习和图深度学习模型,所提模型具有更高的准确性和泛化性。

参考文献

- [1] 李国友, 张新魁, 才士文, 等. 基于改进 KFDA 与 DE 优化 SOM 的故障诊断模型及其化工过程诊断[J]. 化工进展, 2022, 41(4): 1793
LI Guoyou, ZHANG Xinkui, CAI Shiwen, et al. Study on fault diagnosis model and chemical process fault diagnosis based on improved KFDA and DE optimized SOM[J]. Chemical Industry and Engineering Progress, 2022, 41(4): 1793. DOI:10.16085/j.issn.1000-6613.2021-0821
- [2] 魏文军, 张轩铭, 杨立本. 基于模糊聚类和改进 Densenet 网络的小样本轴承故障诊断[J]. 哈尔滨工业大学学报, 2024, 56(3): 154
WEI Wenjun, ZHANG Xuanming, YANG Liben. Fault diagnosis of small sample bearings based on fuzzy clustering and improved Densenet network[J]. Journal of Harbin Institute of Technology, 2024, 56(3): 154. DOI:10.11918/202206075
- [3] WU Hao, ZHAO Jinsong. Deep convolutional neural network model based chemical process fault diagnosis[J]. Computers and Chemical Engineering, 2018, 115: 185. DOI: 10.1016/j.compchemeng.2018.04.009
- [4] LIU Kai, LU Ningyun, WU Feng, et al. Model fusion and multiscale feature learning for fault diagnosis of industrial processes[J]. IEEE Transactions on Cybernetics, 2022, 53(10): 6465. DOI:10.1109/TCYB.2022.3176475
- [5] HE Yumin, SHI Hongbo, TAN Shuai, et al. Multiblock temporal convolution network-based temporal-correlated feature learning for fault diagnosis of multivariate processes[J]. Journal of the Taiwan Institute of Chemical Engineers, 2021, 122: 78. DOI: 10.1016/j.jtice.2021.04.062
- [6] 陈红花, 岑健, 刘溪, 等. 深度学习在化学流程工业故障诊断的研究进展[J]. 计算机工程与应用, 2022, 58(13): 48
CHEN Honghua, CEN Jian, LIU Xi, et al. Research progress of deep learning in fault diagnosis of chemical process industry[J]. Computer Engineering and Applications, 2022, 58(13): 48. DOI: 10.3778/j.issn.1002-8331.2111-0368
- [7] ZHANG Yue, YU Jianbo. Pruning graph convolutional network-based feature learning for fault diagnosis of industrial processes[J]. Journal of Process Control, 2022, 113: 101. DOI: 10.1016/j.jprocont.2022.03.010
- [8] WU Deyang, ZHAO Jinsong. Process topology convolutional network model for chemical process fault diagnosis[J]. Process Safety and Environmental Protection, 2021, 150: 93. DOI: 10.1016/j.psep.2021.03.052
- [9] XU Yuan, ZOU Xun, KE Wei, et al. A graph convolutional shrinkage network-based fault diagnosis method for industrial process [C]//Proceedings of 2023 IEEE 12th Data Driven Control and Learning Systems Conference. Xiangtan: IEEE, 2023: 1069. DOI: 10.1109/DDCLS58216.2023.10165809
- [10] WU Ping, WANG Yixuan, GAO Jinfeng, et al. Multichannel dynamic graph convolutional network based fault diagnosis and its application in blast furnace ironmaking process[J]. IEEE Sensors Journal, 2023, 23(23): 29293. DOI: 10.1109/JSEN.2023.3325353
- [11] LYU Dingyang, XU Zhengjia, ZHANG Jinghui, et al. Imbalanced node classification with graph neural networks: a unified approach leveraging homophily and label information [J]. Applied Soft Computing, 2023, 149: 110985. DOI: 10.1016/j.asoc.2023.110985
- [12] PENG Peng, ZHANG Hanrong, WANG Xinyue, et al. Imbalanced chemical process fault diagnosis using balancing GAN with active sample selection [J]. IEEE Sensors Journal, 2023, 23(13): 14826. DOI:10.1109/JSEN.2023.3270896
- [13] 骆耀谱, 王衍学, 李孟. 基于 CCGAN 和 ResNet34 的滚动轴承故障诊断方法[J]. 机电工程, 2023, 40(6): 852
LUO Yaopu, WANG Yanxue, LI Meng. Rolling bearing fault diagnosis method based on CCGAN and ResNet34[J]. Journal of Mechanical & Electrical Engineering, 2023, 40(6): 852. DOI: 10.3969/j.issn.1001-4551.2023.06.006
- [14] 潘海洋, 徐海峰, 郑近德, 等. 基于双加权不平衡矩阵分类器的机械故障诊断方法[J]. 机械工程学报, 2024, 60(3): 170
PAN Haiyang, XU Haifeng, ZHENG Jinde, et al. Mechanical fault diagnosis method based on twin weighted imbalanced matrix classifier[J]. Journal of Mechanical Engineering, 2024, 60(3): 170. DOI:10.3901/JME.2024.03.170
- [15] JIANG Yalan, LI Chaoshun, YANG Zhixin, et al. Remaining useful life estimation combining two-step maximal information coefficient and temporal convolutional network with attention mechanism[J]. IEEE Access, 2023, 9: 16323. DOI:10.1109/ACCESS.2021.3052305
- [16] LI Xiao, SUN Li, LING Mengjie, et al. A survey of graph neural network based recommendation in social networks [J]. Neurocomputing, 2023, 549: 126441. DOI:10.1016/j.neucom.2023.126441
- [17] DEFFERRARD M, BRESSON X, VANDERGEYNS P. Convolutional neural networks on graphs with fast localized spectral filtering[C]//Proceedings of the 30th Annual Conference on Neural Information Processing Systems. Barcelona: NIPS, 2016: 3844
- [18] SHUMAN D I, NARANG S K, FROSSARD P. The emerging field of signal processing on graphs: extending high-dimensional data analysis to networks and other irregular domains[J]. IEEE Signal Processing Magazine, 2013, 30(3): 83. DOI: 10.1109/MSP.2012.2235192
- [19] ABU-EL-HAIJA S, PEROZZI B, KAPOOR A, et al. Mixhop: higher-order graph convolutional architectures via sparsified neighborhood mixing [C]//Proceedings of the 36th International Conference on Machine Learning. Long Beach: IMLS, 2019: 32
- [20] 陈柘, 刘嘉华, 赵斌, 等. 基于 GCN 和 TCN 的多因素城市路网出租车需求预测[J]. 控制与决策, 2023, 38(4): 1031
CHEN Zhe, LIU Jiahua, ZHAO Bin, et al. Multi-factor taxi demand forecasting for urban road network based on GCN and TCN [J]. Control and Decision, 2023, 38(4): 1031. DOI:10.13195/j.kzyjc.2021.0814
- [21] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318. DOI:10.1109/TPAMI.2018.2858826
- [22] YANG Wei, HU Zhentao, ZHOU Lin, et al. Protein secondary structure prediction using a lightweight convolutional network and label distribution aware margin loss[J]. Knowledge-Based Systems, 2022, 237: 107771. DOI:10.1016/j.knsys.2021.107771
- [23] RUIZ-CÁRCEL C, CAO Y, MBA D, et al. Statistical process monitoring of a multiphase flow facility [J]. Control Engineering Practice, 2015, 42: 74. DOI:10.1016/j.conengprac.2015.04.012
- [24] MELO A, CÂMARA M M, CLAVIJO N, et al. Open benchmarks for assessment of process monitoring and fault diagnosis techniques: a review and critical analysis [J]. Computers and Chemical Engineering, 2022, 165: 107964. DOI:10.1016/j.compchemeng.2022.107964