

控制与决策

Control and Decision

基于W-DenseNet的减压阀不平衡样本故障诊断模型

张洪, 盛永健, 黄子龙, 刘晨, 曹毅

引用本文:

张洪, 盛永健, 黄子龙, 刘晨, 曹毅. 基于W-DenseNet的减压阀不平衡样本故障诊断模型[J]. 控制与决策, 2022, 37(6): 1513-1520.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1708>

您可能感兴趣的其他文章

Articles you may be interested in

基于条件生成对抗网络的不平衡学习研究

Research on imbalanced learning based on conditional generative adversarial networks

控制与决策. 2021, 36(3): 619-628 <https://doi.org/10.13195/j.kzyjc.2019.0522>

嵌入重采样技术的C4.5决策树集成分类算法的临床医学预测

Clinical prediction of C4.5 decision tree classification algorithm with embedded resampling technique

控制与决策. 2021, 36(6): 1342-1350 <https://doi.org/10.13195/j.kzyjc.2019.1247>

基于协同聚类和权重注意力稀疏自编码网络的变化检测方法

Change detection approach based on cooperative clustering and weighted-attention sparse autoencoder

控制与决策. 2021, 36(10): 2442-2450 <https://doi.org/10.13195/j.kzyjc.2019.1633>

改进集成深层自编码器在轴承故障诊断中的应用

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135-142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

不平衡电网电压下基于量子粒子群并网变流器功率/电流协调控制

Coordinate control of grid-connected converter based on QPSO under unbalanced grid voltage

控制与决策. 2021, 36(4): 901-908 <https://doi.org/10.13195/j.kzyjc.2019.0885>

基于 W-DenseNet 的减压阀不平衡样本故障诊断模型

张洪^{1,2†}, 盛永健¹, 黄子龙¹, 刘晨¹, 曹毅^{1,2}

(1. 江南大学机械工程学院, 江苏无锡 214122;

2. 江南大学江苏省食品先进制造装备技术重点实验室, 江苏无锡 214122)

摘要: 针对实际工况中被测对象大多处于正常状态而引起故障样本稀缺、故障数据间存在差异, 导致故障类别识别准确率不高的问题, 基于密集卷积神经网络 (DenseNet), 提出一种减压阀样本数据不平衡下的故障诊断模型——加权密集卷积神经网络 (W-DenseNet)。首先, 将原始一维压力信号数据重构后转换为二维灰度图, 作为模型的输入数据; 其次, 以 DenseNet 为基础框架搭建特征提取网络; 然后, 在损失函数中为不同类别样本添加惩罚系数以实现不平衡样本误差的加权平均; 最后, 为验证模型的有效性, 搭建减压阀数据采集系统并进行分类性能实验。实验结果表明: W-DenseNet 模型在不同平衡度的减压阀数据集下均有良好的分类效果, 且当各故障类间均存在样本不平衡现象时, 模型对 3 种故障类型的召回率仍分别高达 95.18%、95.47%、96.89%。

关键词: 减压阀; 密集卷积神经网络; 不平衡样本; 加权交叉熵损失函数; 故障诊断

中图分类号: TP277

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1708

引用格式: 张洪, 盛永健, 黄子龙, 等. 基于 W-DenseNet 的减压阀不平衡样本故障诊断模型 [J]. 控制与决策, 2022, 37(6): 1513-1520.

W-DenseNet-based fault diagnosis model of pressure-reducing valve with unbalanced samples

ZHANG Hong^{1,2†}, SHENG Yong-jian¹, HUANG Zi-long¹, LIU Chen¹, CAO Yi^{1,2}

(1. School of Mechanical Engineering, Jiangnan University, Wuxi 214122, China; 2. Jiangsu Key Laboratory of Advanced Food Manufacturing Equipment and Technology, Jiangnan University, Wuxi 214122, China)

Abstract: Considering the fact that most of the tested objects are in the normal state under practical working conditions can cause the scarcity of fault samples and differences within fault data, which further leads to low accuracy of fault classification, a DenseNet-based fault diagnosis model of unbalanced samples for the pressure-reducing valve is proposed, called weighted dense convolutional neural network (W-DenseNet). Firstly, the input data of the model is obtained by reconstructing original data of one-dimensional pressure signal and converting it into a two-dimensional grayscale image. Next, a feature extraction network is built based on the DenseNet. Then, to realize the weighted average of unbalanced sample errors, penalty coefficients are added to different types of samples in the loss function. Finally, the data acquisition system of the pressure-reducing valve is built and the classification performance experiment is carried out to validate the proposed model. The experimental results show that the W-DenseNet model exhibits good classification performance on data sets of pressure-reducing valves with different degrees of balance. When the sample imbalance occurs among each fault class, the recall rate of the model for the three fault types is still up to 95.18%, 95.47%, and 96.89%, respectively.

Keywords: pressure reducing valve; dense convolution network; imbalanced sample; weighted cross entropy loss function; fault diagnosis

0 引言

近年来,我国天然气产业发展迅猛,天然气消费量逐年增多^[1],如何安全实现天然气的输送已成为该行业进一步发展急需攻克的重大课题。减压阀作为

当今城镇燃气输送的重要部件,通过阀膜内侧压力与弹簧之间力的平衡来实现下游压力的稳定输出,其在工作过程中的任何故障情况都可能导致易燃气体的泄露,从而产生难以估量的经济损失和人员伤

收稿日期: 2020-12-08; 录用日期: 2021-04-07.

基金项目: 江苏省“六大人才高峰”计划项目 (ZBZZ-012); 高等学校学科创新引智计划项目 (B18027); 江苏省高校优秀科技创新团队基金项目 (2019SJK07).

责任编辑: 姜斌.

†通讯作者. E-mail: zhanghong@jiangnan.edu.cn.

亡^[2]. 因此, 实现有效的减压阀故障诊断已成为天然气行业领域亟待解决的问题.

故障诊断技术依靠各种检测、识别方法来对工业系统的运行状态进行监测, 在识别故障种类的同时对故障位置、故障程度也做出检测^[3-4]. 减压阀处于工作状态时, 其出口压力的不正常波动往往包含丰富的故障信息, 因此, 以出口压力作为故障诊断的输入信号是当前使用最广泛且最切实可行的方法. 文献[5]基于CEEMDAN和特征聚类算法对减压阀3种典型的故障状态进行了分类; 文献[6]引入主成分分析和RBF神经网络技术, 使模型整体故障识别率得到了提高; 文献[7]利用支持向量机对特征向量进行约简, 实现了对目标样本的有效分类; 文献[8]将主成分分析与灰关联分析法相结合并应用到减压阀故障诊断中. 上述文献尽管已在减压阀故障诊断领域取得了成效, 但对信号的特征提取提出了较高要求且故障诊断效果不佳, 难以满足预期.

深度学习经过近年的发展, 已在机器视觉、语音识别、目标检测等多个领域展现出其他算法所无法比拟的优势^[9-10]. 随着工业系统故障诊断领域复杂度的提升, 已有不少学者从深度学习算法中寻求突破^[11]. 文献[12]使用深度置信网络来实现对模拟电路信号深度的特征提取; 文献[13]利用减谱法和短时傅里叶变换来增强振动信号的时频特征, 并以时频图作为卷积神经网络的输入(convolutional neural network, CNN), 实现对不同振动故障事件的分类; 文献[14]以长-短期记忆网络作为模型架构, 根据一个区域内多个轨道信号的时空相关性进行了故障诊断; 文献[15]结合堆叠稀疏自编码器和粒子群优化算法, 实现了齿轮箱有限样本数据下的故障诊断; 文献[16]将循环谱相干性与CNN相结合进行了轴承故障诊断. 上述文献尽管已将深度学习算法应用于平衡数据集的故障诊断中, 并取得了出色成果, 但对不平衡样本数据的泛化性能有所欠缺, 故障识别精度不高. 而实际工况中待诊断对象多处于正常工作状态, 故障情况偶有发生, 使得故障样本数量远小于正常状态样本数量, 且常见故障与稀有故障间也存在数据差异, 导致了整体数据集的不平衡性^[17]. 这种不平衡性的存在往往使模型为获取更高的分类准确率而偏向于正常状态样本, 从而出现整体分类准确率高而故障类别准确率低的现象^[18]. 而故障诊断的根本目的是通过检测算法来定位故障所在, 误报和漏报现象的发生都会导致难以估量的工业事故. 因此, 如何有效地解决样本数据不平衡的分类问题是实际工业系统故

障诊断领域的难题.

目前, 针对不平衡样本问题的处理多从样本数据和算法模型两方面入手, 其中前者是通过采样或增量方法使整体数据集趋于平衡, 而后者旨在改变算法模型使不平衡的样本类别具有相同的误差损失代价. 文献[19]将少数(异常)类过采样和多数(正常)类欠采样相结合, 获得性能更好的分类器; 文献[20]提出一种少数采样生成对抗网络, 从混合数据中生成故障样本, 恢复了数据集的平衡; 文献[21]提出一种深度归一化卷积神经网络框架, 并在3个不同不平衡度的数据集上取得了较好的结果; 文献[22]提出归一化卷积神经网络, 并结合指数移动平均技术使模型在不平衡数据下也具有较好的识别精度; 文献[23]将CNN与代价敏感损失函数相结合, 提高了少数类样本的识别准确率. 上述文献虽已在不平衡样本的故障诊断中获得了成功应用, 但不难看出: 数据层面的方法当数据维度较高时难以维持效率, 而且少数类样本的合成增大了类间重叠率; 另外, 算法层面的方法加大了模型参数设置的复杂度, 且输入信号的特征提取效果还有提升空间.

针对上述问题, 结合密集卷积神经网络和加权交叉熵损失函数, 本文提出W(weighted)-DenseNet故障诊断模型. W-DenseNet充分利用网络的特征自提取能力, 避免了复杂的特征工程, 且DenseNet的密集连接可以改善梯度消失问题, 有效提高准确率. 加权思想的引入缓解了因类不平衡而导致的故障识别困难问题. 模型以减压阀原始一维出口压力数据重构后所得的二维灰度图作为输入信号, 利用模型层与层之间的密集连接来加强特征的传播与重用, 以获取更优的特征提取效果; 通过加权交叉熵损失函数为不平衡数据样本赋予相同的误差损失代价, 提高故障样本的分类准确率. 最后, 基于不同平衡度的减压阀故障数据集开展分类实验, 并与当前多种算法进行对比, 从而验证W-DenseNet在减压阀不平衡数据分类下的优越性.

1 DenseNet和加权交叉熵损失函数

1.1 DenseNet网络

随着卷积神经网络模型复杂度的加深, 输入信号经过多层传递后不可避免地出现梯度消失和爆炸现象. 为解决这一问题, 同时实现网络各层之间的信息流最大化, DenseNet网络建立了前面所有层与后层之间的密集连接, 通过前馈方式令后层可以从前面每一层大小匹配的特征图中获取额外的输入信息^[24]. 因此, DenseNet并非从极深的网络中获取信

息,而是通过特征重用来挖掘网络的潜力,从而得到更易训练且参数高效利用的浓缩模型,这也使得其在应对本文的小样本数据集时表现出较好的抗过拟合性能^[25].

DenseNet网络由多个密集模块(Dense Block)以及块与块之间的过渡层组成,在单个Dense Block中,层与层之间包含批规范化(BN)、线性修正单元(ReLU)以及3×3卷积3个连接操作,且前面每一层的输出都会作为后层的输入,可表示为

$$x_i = H_i([x_0, x_1, \dots, x_{i-1}]). \quad (1)$$

其中: x_i 表示网络第*i*层的输出, $H_i(\cdot)$ 表示上述3个连接操作的复合函数, $[x_0, x_1, \dots, x_{i-1}]$ 表示0~*i*-1层网络输出特征图的拼接. 该种连接方式增强了模型训练时的原始特征,使得网络在参数和计算成本相对较少的情况下表现出比其他网络更为优秀的分类性能. 过渡层由一个1×1卷积层和一个2×2平均池化层组成. 其中:卷积层用于对前层拼接所导致的通道数过多进行降维处理;而池化层则在保证特征不变性的同时进行特征降维,减少网络参数.

1.2 加权交叉熵损失函数

每个样本在经过复杂网络的特征提取后会通过Softmax层输出*N*维数组,数组中每个维度对应不同故障类别,即*N*分类问题,可表示为

$$O = \begin{bmatrix} P(y = 1|x; \mathbf{W}_1, \mathbf{b}_1) \\ P(y = 2|x; \mathbf{W}_2, \mathbf{b}_2) \\ \vdots \\ P(y = N|x; \mathbf{W}_N, \mathbf{b}_N) \end{bmatrix} = \frac{1}{\sum_{n=1}^N \exp(\mathbf{W}_n x + \mathbf{b}_n)} \begin{bmatrix} \exp(\mathbf{W}_1 x + \mathbf{b}_1) \\ \exp(\mathbf{W}_2 x + \mathbf{b}_2) \\ \vdots \\ \exp(\mathbf{W}_N x + \mathbf{b}_N) \end{bmatrix}. \quad (2)$$

其中: O 为网络最终输出, $P(\cdot)$ 为输出结果与对应类别的匹配概率, n 为不同故障类别, \mathbf{W}_n 和 \mathbf{b}_n 分别为各类别的权值矩阵和偏置, $\exp(\cdot)$ 为指数函数.

网络通过交叉熵损失函数来判定实际输出与期望之间的差距,但其赋予每个样本等价的误差损失,对于所有样本一视同仁,同等对待. 但在实际工业检测系统中,故障样本的获取概率远小于正常样本,使得整体数据集呈现不平衡分布,模型为获得优秀的分类性能,往往会忽略少类别样本而专注于多数类别,从而出现整体准确率高但故障类别准确率低的现 象. 因此,为解决不平衡样本故障类别分类困难的问题,基于加权交叉熵损失函数,在原先损失函数的基

础上为不同类别的误差损失添加相应的惩罚系数,从而实现不同类别误差损失的加权平均. 惩罚系数可根据不同类别之间的平衡度设定,可表示为

$$c_n = \frac{\max\{a_n\}_{n=1}^N}{a_n}, \quad (3)$$

$$a_n = \sum_{i=1}^Q 1(y_i = n). \quad (4)$$

其中: c_n 为惩罚系数; a_n 为不同类别样本的数量; $\max\{\cdot\}_{n=1}^N$ 表示取*N*种待分类样本中数量最多者, Q 为样本总量, $1(\cdot)$ 为判断函数,括号内成立为1,反之为0; y_i 为模型实际输出; n 为实际类别. 结合式(2)、(3)、(4),最终可得加权交叉熵损失函数为

$$L = -\frac{1}{Q} \sum_{i=1}^Q \sum_{n=1}^N a_n 1\{y_i = n\} \log \left(\frac{\exp(\mathbf{W}_i x + b_i)}{\sum_{n=1}^N \exp(\mathbf{W}_n x + b_n)} \right). \quad (5)$$

2 W-DenseNet网络模型

2.1 W-DenseNet模型

基于密集卷积神经网络和加权交叉熵损失函数,本文提出W-DenseNet的减压阀不平衡样本故障诊断模型,其对特征信号具有优秀的自提取效果,同时,惩罚系数根据样本数量而定,如式(3)所示,避免了复杂的参数设置.

为实现更好的分类效果,对模型的Dense Block组数、BN-Relu-Conv个数以及第2层全连接层节点数进行对比实验,实验结果如表1所示.

表1 W-DenseNet模型下不同参数结构准确率对比

组别	Block组数	Conv个数	全连接节点数	准确率/%
①	2	4	256	97.18
②	3	4	256	98.04
③	4	4	256	98.02
④	3	3	256	97.74
⑤	3	5	256	97.81
⑥	3	4	128	97.74
⑦	3	4	512	97.68

表1中实验组别①②③、②④⑤以及②⑥⑦分别控制了W-DenseNet中单一变量Dense Block组数、BN-Relu-Conv个数以及全连接层节点数,以准确率作为确定模型参数结构的评价标准. 综上实验结果,最终模型参数结构确定为:3组Dense Block,单组Block中包含4个BN-Relu-Conv,最后一层全连接层节点数为256. 此时模型准确率最高,可达98.04%.

W-DenseNet模型首先以不同故障状态的减压阀出口压力作为输入信号,单个样本含有1 024个数据

点,转为二维图片后尺寸为 32×32 ;其次,搭建3层过渡层级联3个Dense Block,使得网络在支持特征重用、提高参数利用率的同时保证特征图维度统一;然

后,将第3层过渡层的输出展平并输入两层全连接层;最后,通过加权损失函数实现不平衡样本误差损失的加权平均,模型结构如图1所示。

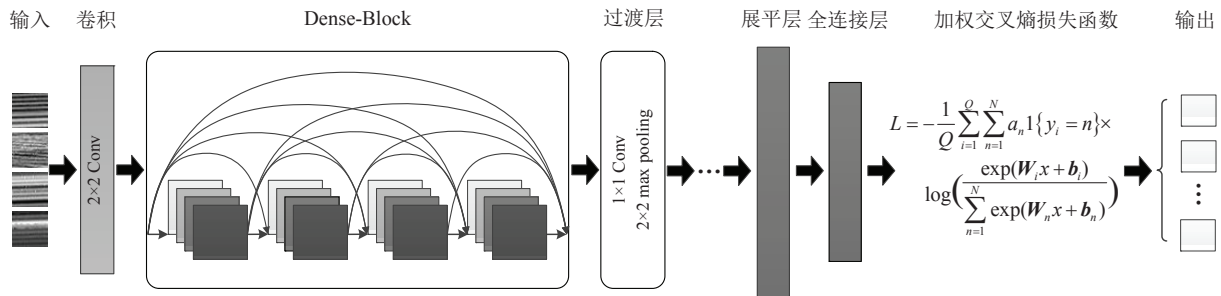


图1 W-DenseNet模型结构

2.2 W-DenseNet算法实现

本文所提出W-DenseNet算法的实现流程如图2所示。

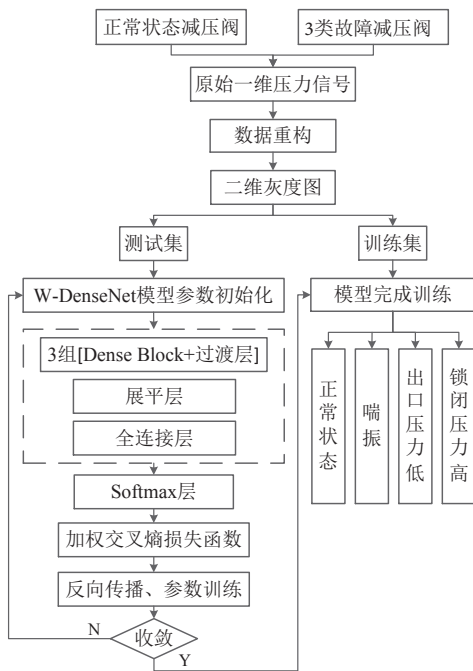


图2 W-DenseNet故障诊断算法流程

算法具体实现步骤如下。

step 1: 基于减压阀性能测试台搭建数据采集系统,获取正常状态与3种故障状态共4类样本;

step 2: 对原始一维压力信号进行数据重构,并将重构后各点压力数据归一化至 $0 \sim 255$ 之间,得到各类别样本的二维灰度图;

step 3: 将重构后所得灰度图进行数据划分,得到训练集与测试集;

step 4: 选取训练集图片,输入参数初始化后的W-DenseNet模型,经过搭建3层过渡层级联3个Dense Block的DenseNet网络后输出各类别的预测概率;

step 5: 加权交叉熵损失函数为各类别样本添加惩罚系数,并根据预测概率计算误差值,模型反向传播,参数训练;

step 6: 选取测试集图片,输入训练完成的W-DenseNet,模型输出当前图片的故障诊断结果。

3 实验验证

3.1 实验数据采集

基于减压阀性能测试台和NI采集卡搭建数据采集系统,如图3所示。转接端子板与出口压力传感器采用RSE单端接线方式相连。首先,使用压力传感器进行出口压力数据监测;然后,通过数据线将数据传输至主机中的NI采集卡;最后,通过Labview软件编写相关程序进行数据保存。




图3 减压阀出口压力采集系统

实际工况中,减压阀会存在皮膜破损、阀壁受损、弹簧疲劳、螺栓松动等多种故障,反映至出口压力则体现为喘振、出口压力低、锁闭压力高等3种故障。采用健康减压阀以及含有上述3种故障类型的减压阀分别进行实测,设定减压阀入口压力恒为 20 kPa ,通过调节测试台出口球阀开度来控制减压阀出口流量,实现对减压阀实际使用过程的模拟,得到单个样本的采样点数为1024,压力信号如图4所示。




图4 不同故障类型减压阀出口压力信号

3.2 维度对比实验

特征提取的主要目的是从大量原始数据中提取出有用的特征信息. 合理的输入方式将会大大提升特征提取的效果, 使得模型具有更高的分类准确率.

目前, 针对故障信号的输入维度众说纷纭. 文献[26]表明, 为保持信号的完整性, 一维信号采用一维神经网络较为合适, 且端到端的故障诊断可以最大限度地发挥深度学习从原始信号中特征自提取的优势; 文献[27-28]提出卷积神经网络是通过滤波器的扫描实现将图片的局部信息在更高层进行整合, 故以二维图片转换后输入网络可获得更好的分类效果. 综上所述, 故障诊断模型的输入维度并没有明确的优劣标定, 需要根据具体数据集具体分析.




图5 一维数据重构原理

为探索减压阀数据集不同维度对模型分类效果的影响, 本文首先进行维度对比实验. 图5所示为原始一维数据重构方式, 以原始数据每32个数据点进行切割, 并将切割后的数据条进行纵向堆叠, 最终将原始数据由原先的[1 024, 1]格式重构为[32, 32, 1].

为将转换后的图像进行可视化表达, 将重构所得二维数据归一化至0~255之间, 即灰度图像像素强度, 得到如图6所示不同故障状态的二维灰度图, 归一化公式可表示为

$$P(h, v) = \text{around} \left\{ \frac{T(M(h-1) + v) - \min(T)}{\max(T) - \min(T)} 255 \right\}. \quad (6)$$

其中: M 表示重构后的行列数; $P(h, v)$ 表示数据重构后第 h 行、第 v 列的灰度值, $h = 1, \dots, M, v = 1, \dots, M$; $\text{around}\{\cdot\}$ 表示对所得结果四舍五入取整; $T(i)$ 表示样本上第 i 点的值, $i = 1, 2, \dots, M^2$; \max 、 \min 分别表示取样本中最大、最小值.

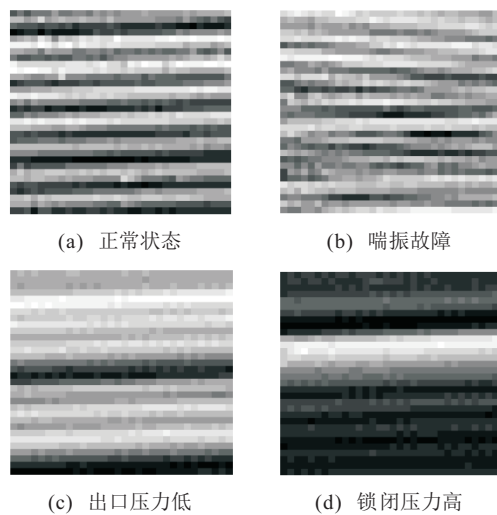


图6 不同故障状态二维灰度图

将原始一维数据和重构后的二维灰度图分别输入DenseNet模型进行分类实验研究. 为保证实验可靠性, 两组实验仅输入维度不同, 其模型参数、层数等均保持一致, 一维卷积核采用 1×9 , 保证同 3×3 卷积核等长. 基于减压阀平衡数据集, 即各故障类别比例为1:1:1:1, 分别进行了20组实验, 并将所得结果绘制如图7所示箱型图. 由图7可知:

1) 一维数据输入所得分类准确率具有较大的波动, 准确率集中在94.5%~96.8%之间, 平均准确率为95.49%, 最高准确率为98.4%;

2) 相较于一维的数据输入, 以二维灰度图输入方式所得的箱型图具有更小箱体, 准确率主要集中在97.2%~98.3%之间, 准确率波动较小, 模型更稳定, 平均准确率为97.57%, 最高准确率为99.3%.




图7 不同维度在DenseNet下准确率箱型图

综上,以二维灰度图作为模型输入可以获得更高、更稳定的分类准确率。

3.3 不同平衡度分类实验

为验证W-DenseNet模型在不同平衡度减压阀数据集下的分类效果,进行3组分类实验:中度不平衡对比、重度不平衡对比、各故障类别间不平衡对比,实验样本比例如表2所示。

表2 不同实验样本数量及比例

实验名称	正常:喘振:出口压力低:锁闭压力高
中度不平衡	800 : 80 : 80 : 80 (10 : 1 : 1 : 1)
重度不平衡	1 600 : 80 : 80 : 80 (20 : 1 : 1 : 1)
类间不平衡	720 : 180 : 90 : 45 (16 : 4 : 2 : 1)

3.3.1 中度不平衡实验

实验中,故障类别样本与正常状态样本数量之间相差了一个数量级。为验证模型的优越性,选取目前主流机器学习算法、深度学习算法以及不平衡故障诊断算法进行对比,各算法具体参数设置如下。

1) SVM:以原始一维压力数据输入,核函数选择RBF高斯径向基,惩罚因子为50,核函数半径为0.25。

2) LeNet5:以二维灰度图输入,2个卷积、池化层,2个全连接层,1个输出层。

3) VGG6:4个卷积层,由2个连续的3×3卷积替代5×5卷积,2个池化层,2个全连接层。

4) DenseNet:3组Dense Block,单个Dense Block包含了4组1×1卷积、3×3卷积。

5) NCNN^[22]:卷积层与激活层之间加入BN层,损失函数引入L₂正则项,使用指数衰减学习率,初始学习率为0.05,衰减速率为0.95。

6) CSCNN^[23]:基于LeNet5模型,加入代价敏感损失函数。

为避免偶然性,采用N折交叉验证,结果如表3、表4所示,其中类别N(normal)、S(surge)、LO(low-outlet)、HC(high-close)分别表示正常状态、喘振故障、出口压力低故障和锁闭压力高故障。

表3 中度不平衡下不同算法召回率 %

算法	N	S	LO	HC	时间/s	收敛/次
SVM	86.25	83.12	81.33	88.34	2.26	100
LeNet5	97.46	81.04	76.81	93.14	245.81	100
VGG6	97.26	82.08	77.36	94.30	206.23	100
DenseNet	98.12	81.46	78.27	94.20	173.38	30
NCNN ^[22]	97.89	86.54	88.04	96.06	250.24	100
CSCNN ^[23]	95.56	90.27	90.33	97.65	246.16	100
W-DenseNet	97.64	91.20	90.35	98.25	175.52	30

表4 中度不平衡下不同算法F1-score %

算法	N	S	LO	HC
SVM	86.12	84.54	83.60	87.15
LeNet5	97.06	86.50	84.06	94.11
VGG6	97.28	87.12	84.90	94.53
DenseNet	97.82	87.54	86.56	94.80
NCNN ^[22]	97.06	89.98	90.22	95.26
CSCNN ^[23]	96.88	92.18	92.04	95.93
W-DenseNet	97.78	93.34	92.54	96.56

由表3和表4可知:

1) 当正常样本与故障样本数量为10:1时,SVM受不平衡样本的影响较小,对4类故障的分类效果近似,但均不太理想;LeNet5、VGG6和DenseNet对故障类别的分类效果相较于正常类别已有明显降低,尤其是喘振故障和出口压力低故障。

2)相较于前4种模型而言,NCNN、CSCNN以及W-DenseNet在该样本比例下各类故障仍具有良好的分类效果,且W-DenseNet的密集连接加强了特征信息的重用,故召回率和F1-score均高于其他两种算法。

3)上述对比算法中:SVM所需的训练时间最短,LeNet5、VGG6、NCNN、CSCNN因模型层数较浅,单次迭代所需时间较短,但迭代次数约需100时模型才趋于收敛;DenseNet和W-DenseNet模型层数较深,单次迭代时间较长,但因网络的特征重用,加快了收敛速度,迭代次数约为30时模型收敛,整体训练时间相较其他算法更短。

3.3.2 重度不平衡实验

表5、表6为该样本比例下各模型分类情况。

重度不平衡实验下的正常状态、喘振故障、出口压力低故障和锁闭压力高故障的样本比例为20 : 1 : 1 : 1,考虑了实际工况样本的严重不平衡情况。由表5和表6可知:

表5 重度不平衡下不同算法召回率 %

算法	N	S	LO	HC	时间/s	收敛/次
SVM	84.41	76.58	70.33	87.50	3.87	100
LeNet5	97.76	60.82	65.75	85.44	421.83	100
VGG6	97.96	61.58	67.04	87.34	371.72	100
DenseNet	98.14	64.09	62.91	91.99	300.11	30
NCNN ^[22]	96.94	77.92	82.50	92.79	430.18	100
CSCNN ^[23]	95.83	76.78	86.39	88.49	423.44	100
W-DenseNet	97.61	80.76	86.81	95.35	303.24	30

表6 重度不平衡下不同算法F1-score %

算法	N	S	LO	HC
SVM	86.68	79.64	76.12	85.17
LeNet5	96.00	71.16	74.36	89.48
VGG6	96.58	72.12	75.06	90.91
DenseNet	97.02	74.46	74.34	92.50
NCNN ^[22]	95.92	84.94	87.14	93.12
CSCNN ^[23]	95.08	83.70	90.04	90.46
W-DenseNet	96.66	86.44	90.74	94.28

1) 由于DenseNet自身模型层数较深以及数据不平衡的存在,其正常状态的召回率和F1-score高于其他算法;

2) 当数据集处于重度不平衡时,SVM、LeNet5、VGG6和DenseNet对于3种故障样本均表现出很差的分类效果;

3)W-DenseNet在不降低整体准确率的前提下,大幅提高了故障类别的召回率和F1-score,且相较于NCNN,3种故障召回率分别提高了2.84%、4.31%、2.56%,F1-score分别提高了1.50%、3.6%、1.16%。

3.3.3 故障类间不平衡实验

减压阀实际工况中,由于所处工作环境的不同,减压阀各个部件的磨损程度也不尽相同,从而导致各故障类间也存在样本数量的不平衡现象。

故障类间不平衡分类实验基于上述正常状态与故障状态样本数量存在不平衡现象的基础之上,进一步考虑了故障状态各自间也存在样本数量的不平衡问题。实验中,4种类别的样本比例为16:4:2:1,即正常状态与故障状态、故障类别之间均存在不平衡问题,表7、表8为具体实验结果。

表7 类间不平衡下不同算法召回率 %

算法	N	S	LO	HC	时间/s	收敛/次
SVM	88.20	83.41	85.22	88.90	2.31	100
LeNet5	98.46	86.58	78.81	89.96	235.82	100
VGG6	98.66	86.32	77.85	89.98	207.76	100
DenseNet	98.25	87.80	84.30	89.04	174.58	30
NCNN ^[22]	96.77	90.92	88.50	92.37	240.49	100
CSCNN ^[23]	96.44	94.58	91.24	94.13	233.76	100
W-DenseNet	98.07	95.18	95.47	96.89	172.36	30

表8 类间不平衡下不同算法F1-score %

算法	N	S	LO	HC
SVM	87.67	85.23	86.17	88.01
LeNet5	96.28	89.22	85.86	90.11
VGG6	96.52	90.20	85.60	91.90
DenseNet	96.92	89.78	88.46	91.38
NCNN ^[22]	96.26	92.24	91.14	93.42
CSCNN ^[23]	96.02	95.10	92.68	94.86
W-DenseNet	97.04	95.46	95.62	96.36

由表7和表8可知:

1) 类间不平衡实验中,W-DenseNet对于3类故障类别的召回率和F1-score均为对比算法中最高的;

2) 相较于CSCNN,W-DenseNet对于3类故障的召回率分别提高了0.6%、4.23%、2.76%,F1-score分别提高了0.36%、2.94%、1.5%;

4 结论

结合DenseNet网络和加权交叉熵损失函数,本文提出了W-DenseNet不平衡样本故障诊断模型。在不同平衡度的减压阀故障数据集下进行了故障分类实验,实验结果表明:1)相较于原始一维数据的直接输入,二维灰度图的输入方式能使模型表现出更好的分类效果;2)W-DenseNet在不降低整体准确率的前提下能够显著提升模型对故障样本的识别效果。本文为工业化故障诊断系统中存在的样本不平衡问题提供了切实可行的方案。

需要指出的是,W-DenseNet模型对于图片、音频等分类问题中存在的样本不平衡现象同样有效,但其仍存在不足之处:模型单轮迭代所需时间相较于浅层模型更长;模型中参数的选择需要通过多次对比实验最终确定。因此,设计更优的训练方案以减少模型训练时间以及设计自适应的参数寻优算法都将是未来研究工作的重点。

参考文献(References)

[1] Li J, She Y Q, Gao Y, et al. Natural gas industry in China: Development situation and prospect[J]. Natural Gas Industry, 2020, 40(4): 133-142.

[2] Zafer N, Luecke G R. Stability of gas pressure regulators[J]. Applied Mathematical Modelling, 2008, 32(1): 61-82.

[3] 何潇,郭亚琦,张召,等.动态系统的主动故障诊断技术[J].自动化学报,2020,46(8): 1557-1570. (He X, Guo Y Q, Zhang Z, et al. Active fault diagnosis for dynamic systems[J]. Acta Automatica Sinica, 2020, 46(8): 1557-1570.)

[4] 周东华,纪洪泉,何潇.高速列车信息控制系统的故障诊断技术[J].自动化学报,2018,44(7): 1153-1164. (Zhou D H, Ji H Q, He X. Fault diagnosis techniques for

- the information control system of high-speed trains[J]. *Acta Automatica Sinica*, 2018, 44(7): 1153-1164.)
- [5] Tian S, Bian X Y, Tang Z P, et al. Fault diagnosis of gas pressure regulators based on CEEMDAN and feature clustering[J]. *IEEE Access*, 2019, 7: 132492-132502.
- [6] Wang Y H, Zhang F C, Chen F W. The gas regulator fault diagnosis based on PCA-RBF neural network[C]. *The 20th International Conference on Electrical Machines and Systems (ICEMS)*. Sydney, 2017: 1-6.
- [7] Zhi X Y, Wang Y H, An Y. Gas pressure regulator fault diagnosis model based on support vector machine[C]. *Chinese Control and Decision Conference (CCDC)*. Nanchang, 2019: 2019-2022.
- [8] Li S N, Wang H X, Wang Y H. The gas regulator fault diagnosis based on PCA-GRA combined algorithm[C]. *Chinese Control and Decision Conference (CCDC)*. Hefei, 2020: 140-143.
- [9] 尹宏鹏, 陈波, 柴毅, 等. 基于视觉的目标检测与跟踪综述[J]. *自动化学报*, 2016, 42(10): 1466-1489.
(Yin H P, Chen B, Chai Y, et al. Vision-based object detection and tracking: A review[J]. *Acta Automatica Sinica*, 2016, 42(10): 1466-1489.)
- [10] Han J W, Zhang D W, Cheng G, et al. Advanced deep-learning techniques for salient and category-specific object detection: A survey[J]. *IEEE Signal Processing Magazine*, 2018, 35(1): 84-100.
- [11] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战[J]. *控制与决策*, 2017, 32(8): 1345-1358.
(Ren H, Qu J F, Chai Y, et al. Deep learning for fault diagnosis: The state of the art and challenge[J]. *Control and Decision*, 2017, 32(8): 1345-1358.)
- [12] Zhang C L, He Y G, Du B L. Analog circuit incipient fault diagnosis method based on DBN feature extraction[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(10): 112-119.
- [13] Xu C J, Guan J J, Bao M, et al. Pattern recognition based on time-frequency analysis and convolutional neural networks for vibrational events in φ -OTDR[J]. *Optical Engineering*, 2018, 57(1): 1.
- [14] de Bruin T, Verbert K, Babuka R. Railway track circuit fault diagnosis using recurrent neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(3): 523-533.
- [15] Saufi S R, Ahmad Z A B, Leong M S, et al. Gearbox fault diagnosis using a deep learning model with limited data sample[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(10): 6263-6271.
- [16] Chen Z Y, Mauricio A, Li W H, et al. A deep learning method for bearing fault diagnosis based on cyclic spectral coherence and convolutional neural networks[J]. *Mechanical Systems and Signal Processing*, 2020, 140: 106683.
- [17] Buda M, Maki A, Mazurowski M A. A systematic study of the class imbalance problem in convolutional neural networks[J]. *Neural Networks*, 2018, 106: 249-259.
- [18] Mao W T, He L, Yan Y J, et al. Online sequential prediction of bearings imbalanced fault diagnosis by extreme learning machine[J]. *Mechanical Systems and Signal Processing*, 2017, 83: 450-473.
- [19] Chawla N V, Bowyer K W, Hall L O, et al. SMOTE: Synthetic minority over-sampling technique[J]. *Journal of Artificial Intelligence Research*, 2002, 16: 321-357.
- [20] Zareapoor M, Shamsolmoali P, Yang J. Oversampling adversarial network for class-imbalanced fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2021, 149: 107175.
- [21] Jia F, Lei Y G, Lu N, et al. Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization[J]. *Mechanical Systems and Signal Processing*, 2018, 110: 349-367.
- [22] Zhao B, Zhang X M, Li H, et al. Intelligent fault diagnosis of rolling bearings based on normalized CNN considering data imbalance and variable working conditions[J]. *Knowledge-Based Systems*, 2020, 199: 105971.
- [23] Dong X, Guo L, Gao H L, et al. Cost sensitive convolutional neural network: A classification method for imbalanced data of mechanical fault[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(12): 205-213.
- [24] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, 2017: 2261-2269.
- [25] Wang T Y, Gong L M, Wang P, et al. A fault diagnosis model of rotating machinery based on KD-DenseNet[J]. *Journal of Vibration and Shock*, 2020, 39(16): 39-45.
- [26] Wu C Z, Jiang P C, Feng F Z, et al. Faults diagnosis method for gearboxes based on a 1-D convolutional neural network[J]. *Journal of Vibration and Shock*, 2018, 37(22): 51-56.
- [27] Wen L, Li X Y, Gao L, et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(7): 5990-5998.
- [28] Chen Z Q, Li C, Sanchez R V. Gearbox fault identification and classification with convolutional neural networks[J]. *Shock and Vibration*, 2015, 2015: 1-10.

作者简介

张洪(1966—), 男, 副教授, 博士, 从事信号处理、机电检测与控制等研究, E-mail: zhanghong@jiangnan.edu.cn;

盛永健(1996—), 男, 硕士生, 从事故障诊断、深度学习的研究, E-mail: 824420863@qq.com;

黄子龙(1996—), 男, 硕士生, 从事深度学习、音频分类的研究, E-mail: 1936482824@qq.com;

刘晨(1996—), 男, 硕士生, 从事深度学习、行为识别的研究, E-mail: 2462220931@qq.com;

曹毅(1974—), 男, 教授, 博士, 从事机器人、深度学习等研究, E-mail: caoyi@jiangnan.edu.cn.

(责任编辑: 李君玲)