

基于改进卷积胶囊网络的轴承故障诊断

李伟 华亮* 王栗

(南通大学电气工程学院 江苏 南通 226019)

摘要 针对轴承工作环境复杂,变工况下诊断性能低等问题,提出一种基于改进卷积胶囊网络的轴承故障诊断方法。采用 Inception 结构和通道、空间双重注意力模块,代替胶囊网络中的单层卷积核结构,对数据进行多尺度的关键信息的获取。通过胶囊网络结构,构建向量神经元,在动态路由算法的特征传递方式下,结合优化的损失函数,完成故障诊断。在单、变工况下的凯斯西储大学轴承数据集上进行实验,结果分析表明,该方法能有效地进行故障诊断。

关键词 轴承 Inception 注意力模块 胶囊网络 故障诊断

中图分类号 TP183 TP3 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2024.03.015

BEARING FAULT DIAGNOSIS BASED ON IMPROVED CONVOLUTIONAL CAPSULE NETWORK

Li Wei Hua Liang* Wang Li

(School of Electrical Engineering, Nantong University, Nantong 226019, Jiangsu, China)

Abstract Aimed at the problems of complicated bearing working environment and low diagnostic performance under variable working conditions, a bearing fault diagnosis method based on improved convolutional capsule network is proposed. The Inception structure and the channel and space double attention modules were used to replace the single-layer convolution kernel structure in the capsule network, and the multi-scale key information acquisition of data was performed. Through the structure of the capsule network, vector neurons were constructed. Under the feature transfer mode of the dynamic routing algorithm, combined with the optimized loss function, the fault diagnosis was completed. In order to verify the diagnostic effect of the model, experiments were carried out on the bearing data set of Case Western Reserve University under single and variable working conditions. The results analysis show that this method can effectively diagnose faults.

Keywords Bearing Inception Attention module Capsule network Fault diagnosis

0 引言

随着工业技术水平的提高,机械化设备在工业各个领域上的应用发展迅速。轴承作为其中重要的一环,它的平稳运行是设备运转中不可或缺的一部分。由于经常在工作强度大的环境下运转,轴承会发生锈蚀和磨损等故障,可能会造成设备故障和财产损失^[1]。因此,对轴承进行故障诊断,判断机械化设备是否发生

了损伤,并采取相应手段处理损伤十分重要。

传统的故障诊断方法是通过人工捕获信号数据中的特征,进而诊断轴承受到的损伤类型^[2]。例如,采用短时傅里叶变换、小波变换和经验模态分解等方法,对原始信号进行不同层面的特征捕获,并依据专家知识判断轴承是否发生故障以及发生故障损伤的程度与类型。伴随着机器学习在工业应用方面的发展,一些有用可靠的算法被应用在故障诊断方面^[3]。例如,采用支持向量机、贝叶斯统计和神经网络等算法,对信号数

据进行特征捕获,分析识别获取的特征,完成故障诊断。这些方法虽然对故障诊断都有着不错的效果,但是其特征捕获和识别分类的过程较为复杂,而且同种特征捕获方法在不同类型的故障上效果存在差异。因此,这些方法都十分依赖专家知识和人工干预。随着传感器获取的轴承振动信号数据量的增加,专家知识和人工研判很难胜任大量的精准故障诊断任务。

随着深度学习在工程应用领域的发展,语音识别、目标追踪、寿命预测等领域取得了飞跃性的进展,一些方法也被引用在故障诊断方面^[4]。其中以卷积神经网络模型为代表的深度学习模型,让故障诊断领域逐渐朝着智能化、自动化的方向发展。文献[5]提出一种基于一维卷积网络的模型,通过模型对一维振动信号进行直接处理,保留了大量重要的特征数据,在特征捕获和故障诊断方面效果出色。文献[6]提出一种将振动信号转化为振动图像的卷积神经网络的方法,实现了将数字信号转化为二维图像的故障诊断模式。虽然卷积神经网络能取得一定的效果,但是在特征捕获时,仍存在着标量神经元的细节捕获能力不足,池化层丢失空间有用信息等问题。在实际工程应用中,轴承的运行状态会随着机械系统的负载的变化而变化,传感器获取的轴承振动信号数据也会发生变化。卷积神经网络是通过对信号特征的捕获分析,完成不同类型故障的诊断分类。在负载变化的情况下,同种类型故障的相似特征会减少,这会导致卷积神经网络诊断性能变差,难以很好地完成变工况下的故障诊断任务。

Sabour 等^[7]在2017年提出胶囊网络结构模型,弥补卷积神经网络在特征捕获方面的不足。该模型主要是将输入输出的特征由标量形式改变为向量形式,让输入输出的空间位置作为信息的一部分被网络结构保留使用,舍弃池化层结构,提升了模型的特征捕获性能。基础的胶囊网络仅采用单层卷积核捕获特征,还未能从输入输出数据中获得更多重要的信息,特征捕获性能还有提升空间。

本文将多尺度卷积核 Inception 结构和通道、空间双重注意力模块以及胶囊网络结构结合,提出一种基于改进卷积胶囊网络的轴承故障诊断方法。该方法可以从振动信号数据中获取多尺度的关键信息,结合优化的损失函数,提高特征捕获能力,提升模型诊断性能,并通过单、变工况下的实验,验证了该方法的有效性和适用性。

1 基础理论

1.1 卷积网络结构

卷积神经网络是一类包含卷积运算并具有深度结构的神经网络^[8]。网络结构包含卷积层和池化层等,能够对输入数据进行处理,完成数据的过滤和收集。网络结构采用尺寸大小为 $k \times k$ 卷积核时的公式为:

$$a_{i,j} = f\left(\sum_k \sum_n \omega_{m,n} \cdot x_{i+m,j+n} + b\right) \quad (1)$$

式中: $a_{i,j}$ 为输出值; $x_{i,j}$ 为第 i 行 j 列的元素; $\omega_{m,n}$ 为第 m 行 n 列的权重; b 为偏置项; f 为激活函数,常用的激活函数有 sigmoid、tanh 和 ReLU 等。

1.2 Inception 结构

随着卷积神经网络在图像处理方面的流行,许多优化的模型都被设计用来处理应用,大部分模型都是基于将卷积层结构改变得更多更宽,虽然一定程度上优化了模型准确度,但这会导致模型结构存在过拟合、计算量增加、梯度弥散等问题。在这种情况下,Inception 结构被提出用来优化卷积网络结构^[9]。Inception V1 结构如图 1 所示。




图1 Inception V1 结构

构成 Inception 结构为尺寸大小 1×1 、 3×3 以及 $n \times n$ 的卷积层以及 3×3 的池化层,通过采用多个卷积核,替代尺寸大小 $n \times n$ 的单层卷积层,拓展网络结构的宽度,改善网络结构的深度。这样的 Inception 结构可以一定程度上缓解过拟合等问题,同时还可以对输入数据的信息进行多尺度获取,提升模型特征捕获性能。

1.3 注意力模块

卷积块注意力模块(Convolutional Block Attention Module, CBAM)是一种简洁而有效的基于注意力模块的卷积神经网络^[10]。注意力模块分为通道和空间两种不同层面的结构。采用注意力模块可以增强网络结构对关键信息的关注,提升网络结构的特征捕获性能。注意力模块结构如图 2 所示。

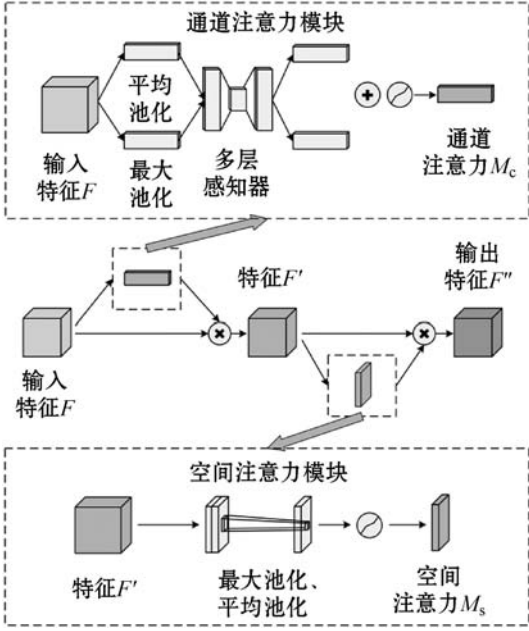


图2 注意力模块结构

假设卷积运算中的某个特征图 $F \in \mathbf{R}^{C \times H \times W}$ 作为输入,通过注意力模块生成通道特征图 $M_c \in \mathbf{R}^{C \times 1 \times 1}$ 和空间特征图 $M_s \in \mathbf{R}^{1 \times H \times W}$ 。注意力模块处理过程公式为:

$$F' \in M_c(F) \otimes F \quad (2)$$

$$F'' \in M_s(F') \otimes F' \quad (3)$$

式中: \otimes 表示逐个元素相乘; F' 是优化过程中的特征图; F'' 是优化后的特征图。

通道注意力模块将输入数据经过池化、感知机等过程生成通道特征图,其公式为:

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) = \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \quad (4)$$

式中: $W_0 \in \mathbf{R}^{C/r \times C}$; $W_1 \in \mathbf{R}^{C \times C/r}$; σ 为 sigmoid 函数; r 为减少率。

空间注意力模块将输入数据经过池化和卷积操作生成空间特征图,其公式为:

$$M_s(F) = \sigma(f^{7 \times 7}([AvgPool(F); MaxPool(F)])) = \sigma(f^{7 \times 7}([F_{avg}^s; F_{max}^s])) \quad (5)$$

式中: σ 为 sigmoid 函数; 7×7 为卷积核的大小。

1.4 胶囊网络结构

胶囊网络是一种基于向量神经元的网络结构^[11]。胶囊网络将输入输出的神经元从标量转换成向量,在空间位置上获取特征,减少特征信息的丢失,提升网络结构的特征捕获性能。胶囊网络结构如图3所示。




图3 胶囊网络结构

胶囊网络的运算过程可以分为四个阶段。在第一阶段,神经元与它对应的权重值相乘得到输出值,与传统的神经网络不同,神经元是向量,而不是标量。记第 i 个神经元为 x_i , w_{ij} 为 x_i 对应的权重矩阵, x_{ij} 为预测值,其公式为:

$$x_{ij} = w_{ij}x_i \quad (6)$$

在第二阶段,对预测值 x_{ij} 进行加权求和得到输出值 s_j ,其公式为:

$$s_i = \sum_j c_{ij}x_{ij} \quad (7)$$

式中: c_{ij} 为耦合函数。

在第三阶段,对输出值 s_j 进行非线性映射,获得输出值 z_j ,其公式为:

$$z_j = \frac{\|s_j^2\|}{1 + \|s_j^2\|} \frac{s_j}{\|s_j\|} \quad (8)$$

在第四阶段,由动态路由算法确定耦合系数 c_{ij} ,其公式为:

$$c_{ij} = \frac{e^{b_{ij}}}{\sum_k e^{b_{ik}}} \quad (9)$$

$$a_{ij} = a_{ij} + z_jx_{ij} \quad (10)$$

动态路由算法如图4所示。在每次前向传播时,将 a_{ij} 初始化为0,由式(9)计算出 c_{ij} 的初始化值,再计算出输出值 z_j 。由式(10)更新 a_{ij} 的数值,从而更新 c_{ij} 、 s_j 和 z_j 。通过动态路由算法不断地迭代更新,得到一组最优的耦合系数。

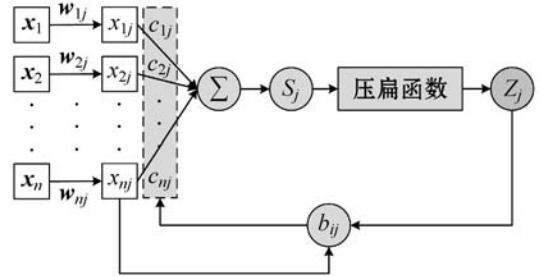


图4 动态路由算法

2 基于改进卷积胶囊网络的故障诊断

2.1 模型结构

为避免人工捕获特征,能从轴承振动信号中获取更多元更关键的特征信息,提高特征捕获能力,提升模型的诊断性能,能在变工况下的实际工程应用中完成故障诊断任务,本文将多尺度卷积核 Inception 结构和通道、空间双重注意力模块以及胶囊网络结构结合,提出一种基于改进卷积胶囊网络 IC-CN (Improved Convolutional Capsule Network) 模型,其模型结构如图5所示。

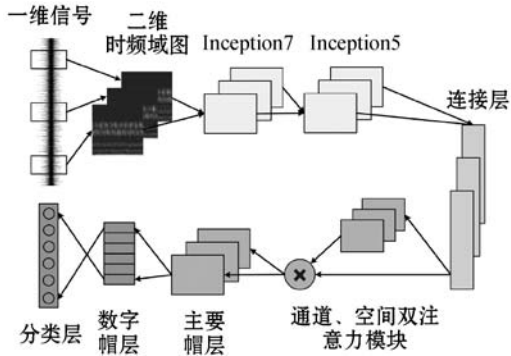


图 5 IC-CN 模型结构

IC-CN 模型输入数据为轴承振动信号经过小波变换获得的时频域图,相对于原始振动信号,时频域图包含更全面的特征信息。网络模型前端采用 Inception 结构和通道、空间双注意力模块,能够进行多尺度的关键信息的特征捕获。Inception7 和 Inception5 分别取图 1 中 $n = 7$ 和 $n = 5$ 时卷积核,构成对应的 InceptionV1 结构。网络模型后端采用胶囊网络结构,将神经元由标量形式构建成向量形式,通过动态路由算法和优化的损失函数,完成网络模型系数的迭代更新。模型选用 ReLU 函数。IC-CN 模型结构参数如表 1 所示。

表 1 IC-CN 模型结构参数

网络层	卷积核大小/通道	步长	输出
Inception7	7 × 7/32	2	32 × 32 × 32
Inceptoin5	5 × 5/32	2	16 × 16 × 32
连接层			16 × 16 × 32
注意力模块	7 × 7/32	1	16 × 16 × 32
主要帽层			64 × 128
数字帽层			10 × 16
分类层			10

2.2 损失函数

在模型的训练过程中,与参数对应的权重系数需要进行迭代更新以优化模型。损失函数能够将模型输出值与真实数据值进行对比,在训练中通过损失函数可以完成权重系数的迭代更新。损失函数的表达式为:

$$L_i = T_i \max(0, m^+ - p_i)^2 + \lambda (1 - T_i) \max(0, p_i - m^-)^2 \quad (11)$$

式中: L_i 为模型输出的不同分类概率值; T_i 为分类判定函数,假如输入数据与输出数据的类别一致,则 $T_i = 1$, 否则 $T_i = 0$; m^+ 为上限值; m^- 为下限值; λ 为比例系数,调整两项的比例。依据多次实验调整,选 $p_i = 0.9$ 和 $\lambda = 0.5$ 时,得到的效果较好。

2.3 故障诊断方法流程图

IC-CN 模型故障诊断方法流程分为数据集处理和

划分、模型训练以及模型测试三个部分。第一部分将原始信号转化为时频域图,并按恰当比例把数据集划分成训练和测试两个样本。第二部分建立 IC-CN 模型,通过数据的双向传播,更新模型参数,完成模型的训练。第三部分将测试样本输入 IC-CN 模型进行测试,完成故障诊断。IC-CN 模型诊断流程如图 6 所示。

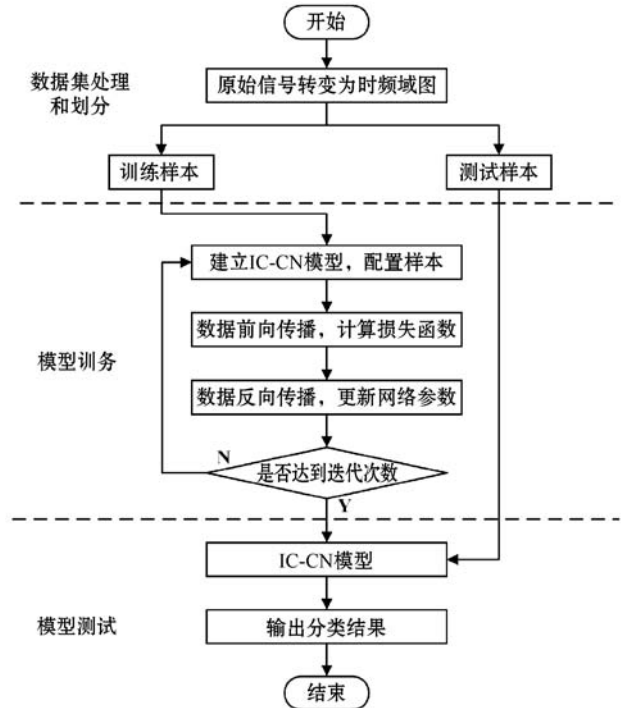


图 6 IC-CN 模型诊断流程

3 实验与结果分析

3.1 数据集

为验证 IC-CN 模型在故障诊断方面的适用性,选用凯斯西储大学轴承数据集作为实验数据集^[12]。数据采集系统如图 7 所示。数据采集系统中配置的故障轴承,是通过电火花方式,对正常轴承进行人为的不同类型故障的对应制造。故障类型分为正常以及内圈、外圈和滚动体三种故障。其中,每种均有 0.177 8、0.355 6 和 0.533 4 mm 三种不同尺寸的损伤,对应不同类型的故障。




图 7 数据采集系统

在深度学习中,通常需要大量的样本进行数据分析得出模型,样本过少会导致模型在训练过程中出现过拟合,影响模型的性能。因此本文采用重复采样的数据增强方式来扩充样本数据。重复采样示意图如图 8 所示。




图 8 重复采样示意图

从原始信号的起始点开始,依次选取 4 096 个点即样本长度。选取完成后,将选取点向后移动 290 个点即重复量,继续进行数据选取,直至原始信号的末尾点。选取后的数据进行小波时频域变换,由一维信号数据转化为时频域图^[13]。小波变换公式为:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (12)$$

式中: a 是控制函数伸缩的参数,即频率; b 是控制函数平移的参数,即时间。

将数据增强和转化后的信号数据汇总,构成实验数据集,如表 2 所示。数据集包含了正常和九种不同类型故障共十种。其中,每种数据类型均按 3:1 的比例划分,划分为 300 个训练样本和 100 个测试样本。每个数据样本都被打上标签,表示对应的故障类型。

表 2 实验数据集

故障类型	损伤/mm	故障标签	训练样本数	测试样本数
正常		0	300	100
内圈故障	0.177 8	1	300	100
	0.355 6	2	300	100
	0.533 4	3	300	100
外圈故障	0.177 8	4	300	100
	0.355 6	5	300	100
	0.533 4	6	300	100
滚动体故障	0.177 8	7	300	100
	0.355 6	8	300	100
	0.533 4	9	300	100

3.2 实验环境和参数

实验训练和测试的环境是在 NVIDIA GeForce RTX 2080Ti GPU 和 Intel Core i9-9900KF CPU 的硬件平台上配置的。IC-CN 模型是通过开源的软件库 TensorFlow 2.0

构建的。IC-CN 模型采用 Adam 优化参数,学习率定为 0.000 1,批处理次数 Batch 定为 100。同时采用 Dropout 来避免模型过拟合,比率设置为 20%。

3.3 对比模型

为验证 IC-CN 模型性能,将卷积神经网络 CNN (Convolutional Neural Network) 以及卷积胶囊网络 C-CN (Convolutional Capsule Network) 两种深度学习模型进行对比^[14]。

(1) CNN 模型采用 3×3 大小的卷积核,构建 5 层卷积池化层,获取输入数据的信息,并通过全连接层进行信息整合,采用 softmax 函数对整合信息识别分类。

(2) C-CN 模型采用 7×7 和 5×5 两个大小的卷积核,构建 2 层卷积池化层,获取输入数据的信息,并通过胶囊网络结构将信息整合识别分类。

3.4 单工况下的故障诊断性能分析

探究模型的诊断性能,设置在单工况下的实验是常用途径。按照表 2 实验数据集构建的方式,分别选取 0、1、2、3 hp 负荷工况下的数据构建单工况下的数据集。模型迭代次数 Epoch 定为 300。为减少诊断实验的偶然性,每个模型均在不同单工况上重复诊断三次,取平均值作为模型诊断的准确度。单工况下的准确度实验结果如表 3 所示。

表 3 单工况下的准确度实验结果 (%)

模型	准确度				
	0 hp	1 hp	2 hp	3 hp	平均
CNN	99.07	99.53	99.53	99.67	99.45
C-CN	99.60	99.93	100.00	100.00	99.88
IC-CN	99.70	100.00	100.00	100.00	99.91

从表 3 中可以得出,三种模型的准确度均超过 96%,说明深度学习模型对故障识别分类有较好的适用性。其中,IC-CN 模型在四种不同单工况下的准确度均高于 CNN,在 0 hp 和 1 hp 单工况下的准确度高于 C-CN 模型。在不同单工况下的平均准确度上,IC-CN 模型比 CNN 和 C-CN 模型分别提高 0.46 个百分点和 0.03 百分点。这说明 IC-CN 模型在单工况下诊断性能更加优异。

3.5 变工况下的故障诊断性能分析

(1) 变工况问题描述。在工程应用中,机械系统不会总是处于单工况下运转,一般会随着工业的需要而改变所处的负荷和工况。机械化设备所处的负荷和工况改变,内部零件的运转转速也会随着改变,这会影

传感器获取的信号数据。损伤尺寸大小为 0.533 4 mm 的外圈故障在不同负荷工况下运转的信号数据如图 9 所示。




图 9 1 hp、2 hp 和 3 hp 负荷工况下的信号数据

可以得出,信号在不同负荷工况下的加速度数据是有区别的,幅值和相位是不一样的。通过专家知识无法清楚准确地判断出不同负荷工况下的信号是否同属一种类型的故障。深度学习是通过对信号数据的捕获分析,完成不同类型故障的诊断分类。在负荷变化的情况下,同种类型故障的相似特征会相应地减少,这会导致深度学习在不同负荷工况下的诊断性能变差。

(2) 变工况下的故障诊断实验。为验证 IC-CN 模型在变工况下的诊断性能,参照表 2 构建数据集,所用的训练和测试集均采用不同负荷工况下的数据。变工况相对于单工况,样本数据增多,模型训练过程变复杂,为了让模型更好地训练数据,增大迭代次数,将 Epoch 定为 500。变工况下实验结果如图 10 - 图 11 所示。图 10 - 图 11 中的 12-3 表示使用 1 hp 和 2 hp 负荷下的数据作为训练集,使用 3 hp 负荷下的数据作为测试集。13-2 与 23-1 和 12-3 数据集构建方式相同。图 10 和图 11 分别将准确度和 F1 分数作为模型性能优劣的评价指标。




图 10 变工况下的准确度实验结果




图 11 变工况下的 F1 分数实验结果

从图 10 中可以得出,对比单工况下的实验结果,当负荷发生变化时,三种方法的准确度均不同程度地发生了降低。虽然诊断性能发生了下降,但是 IC-CN 模型与其他两种模型相比,诊断性能下降的幅度小,在三种变工况下的准确度均高于 CNN 和 C-CN 模型。在三种变工况下的平均准确度上,相对于 CNN 和 C-CN 模型,IC-CN 模型分别提高了 8.24 个百分点和 3.42 个百分点。从图 11 中可以得出,IC-CN 模型在三种变工况下的 F1 分数均高于其他两种模型。在三种变工况下的平均 F1 分数上,IC-CN 模型相当于其他两种模型分别提高了 10.2% 和 3.65%。这些说明 IC-CN 模型在变工况下诊断性能更加优异。

为探究 IC-CN 模型在变工况下的诊断分类详情,绘制了在负荷工况下的混淆矩阵,如图 12 所示。

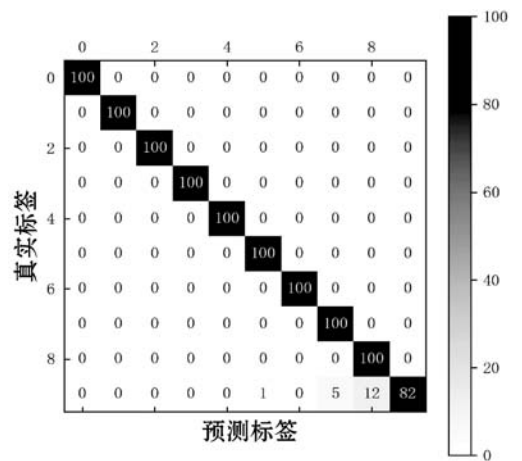


图 12 在负荷工况下的混淆矩阵

可以得出,在 IC-CN 模型的诊断分类下,标签为 0 - 8 的故障类型诊断准确度均达到了 100%,标签为 9 的故障类型诊断准确度为 82%。这主要是由于 IC-CN 模型将标签 9 与标签 5、7、8 的故障类型混淆。在负荷工况下的混淆矩阵说明 IC-CN 模型诊断性能总体优异,能够完成诊断分类。

4 结 语

针对轴承工作环境复杂,变工况下诊断性能低等

问题,本文提出了一种基于改进卷积胶囊网络 IC-CN 模型,在单、变工况下对轴承故障诊断性能进行实验,实验结果表明:

(1) 与单工况下的实验结果对比,变工况下的工作环境对轴承振动信号数据以及深度学习模型的故障诊断性能均有影响。

(2) IC-CN 模型采用 Inception 结构和通道、空间双注意力模块,与卷积层结构相比,能够对输入输出数据进行多尺度的关键信息的获取,提升模型的特征捕获性能。

(3) IC-CN 模型在单工况和变工况下的故障诊断性能均优于其他模型,验证了该模型在轴承故障诊断方面的有效性。

(4) IC-CN 模型在变工况下的故障诊断性能上还有提升空间,未来的工作是进一步优化网络模型结构,提升模型诊断性能。

参 考 文 献

- [1] Lee J H, Pack J H, Lee I S. Fault diagnosis of induction motor using convolutional neural network [J]. Applied Sciences-Basel, 2019, 9(15) : 2950.
- [2] 陈是扞,彭志科,周鹏. 信号分解及其在机械故障诊断中的应用研究综述 [J]. 机械工程学报, 2020, 56(17) : 91 - 107.
- [3] 郭一帆,唐家银. 基于机器学习算法的寿命预测与故障诊断技术的发展综述 [J]. 计算机测量与控制, 2019, 27(3) : 7 - 13.
- [4] 余萍,曹洁. 深度学习在故障诊断与预测中的应用 [J]. 计算机工程与应用, 2020, 56(3) : 1 - 18.
- [5] Liu X C, Zhou Q C, Shen H. Real-time fault diagnosis of rotating machinery using 1-D convolutional neural network [C] // 5th International Conference on Soft Computing & Machine Intelligence, 2018 : 104 - 108.
- [6] Oh J W, Jeong J. Convolutional neural network and 2-D image based fault diagnosis of bearing without retraining [C] // 3rd International Conference on Compute and Data Analysis, 2019 : 134 - 138.
- [7] Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules [C] // 31st International Conference on Neural Information Processing System, 2017 : 3859 - 3869.
- [8] 闫河,王鹏,董莺艳,等. 改进的卷积神经网络图片分类识别方法 [J]. 计算机应用与软件, 2018, 35(12) : 193 - 198.
- [9] 朱浩,宁芊,雷印杰,等. 基于注意力机制-Inception-CNN 模型的滚动轴承故障分类 [J]. 振动与冲击, 2020, 39(19) : 84 - 93.
- [10] Woo S, Park J C, Lee J Y, et al. CBAM: Convolutional block attention module [C] // 15th European Conference on

Computer Vision, 2018 : 3 - 19.

- [11] 杨平,苏燕辰,张振. 基于卷积胶囊网络的滚动轴承故障诊断研究 [J]. 振动与冲击, 2020, 39(4) : 55 - 62, 68.
- [12] Case western reserve university. Bearing Data Center [EB/OL]. [2021 - 01 - 12]. <https://engineering.case.edu/bearingdatacenter>.
- [13] 何东中,贡丽霞,白艳萍. 小波变换和神经网络的电路故障诊断 [J]. 现代电子技术, 2020, 43(10) : 30 - 32, 37.
- [14] 孙岩,彭高亮. 改进胶囊网络的滚动轴承故障诊断方法 [J]. 哈尔滨工业大学学报, 2021, 53(1) : 23 - 28.

(上接第 27 页)

参 考 文 献

- [1] Smith C J. Food safety and health-past problems and future solutions [J]. Engineering, 2020, 6(4) : 384 - 388.
- [2] 梁森,刘锐,苏荣欣,等. 面向食品安全分析的核酸适配体传感技术 [J]. 化学进展, 2012, 24(7) : 1378 - 1387.
- [3] 卓婧,王静,陈小霞,等. 食品中合成色素快速检测仪器的研制 [J]. 分析化学, 2011, 39(2) : 283 - 287.
- [4] 余从田. 食品企业质量安全追溯与监管平台的建设与应用 [J]. 食品工业, 2014, 35(7) : 229 - 235.
- [5] 王超,金志刚,王健俊,等. 面向食品安全的电子追溯国家平台设计 [J]. 食品安全导刊, 2018(21) : 168 - 169.
- [6] 魏同洋,杨勇,李敏. 农业可追溯平台的设计与应用研究 [J]. 安徽农业科学, 2019, 47(3) : 245 - 247.
- [7] 李玉娜. RFID 技术在食品安全追溯平台中的应用研究 [J]. 微型机与应用, 2015, 34(7) : 90 - 94.
- [8] 张亦凡. 食品安全追溯系统的研究现状 [J]. 食品安全导刊, 2020(24) : 27.
- [9] 李幸芝,韩蓓,李国杰,等. 基于分区数据协商与异常共识机制的配电网去中心化状态估计 [J]. 中国电机工程学报, 2021, 41(3) : 868 - 879.
- [10] 张宁熙. 区块链技术发展综述及其政务领域应用研究 [J]. 信息安全研究, 2020, 6(10) : 910 - 918.
- [11] 王昊,吴天昊,朱孔林,等. 交叉场景下基于区块链技术的匿名车辆身份认证方案 [J]. 网络与信息安全学报, 2020, 6(5) : 27 - 35.
- [12] 姜铁涵,李勇,朱岩. ACT:可审计的机密交易方案 [J]. 计算机研究与发展, 2020, 57(10) : 2232 - 2240.
- [13] 王壹铭,初剑峰,王永军,等. 基于有向无环图的高效区块链共识算法 [J]. 吉林大学学报(理学版), 2020, 58(5) : 1167 - 1172.
- [14] 徐慧馨,生吉萍,徐红. 基于供应链风险管理的食品流通数据库研究 [J]. 食品安全质量检测学报, 2020, 11(18) : 6475 - 6481.
- [15] 沈政启. 基于区块链的食品溯源系统的存储设计 [J]. 通讯世界, 2019, 26(2) : 304 - 305.