

控制与决策

Control and Decision

基于改进的胶囊网络的行星齿轮箱故障诊断方法

黎德才, 张冕, 王科盛, 向红标, 康天博, 王豫赣

引用本文:

黎德才, 张冕, 王科盛, 向红标, 康天博, 王豫赣. 基于改进的胶囊网络的行星齿轮箱故障诊断方法[J]. *控制与决策*, 2023, 38(3): 661–669.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1440>

您可能感兴趣的其他文章

Articles you may be interested in

基于改进SSA优化MDS-SVM的变压器故障诊断方法

Transformer fault diagnosis method based on improved SSA optimized MDS-SVM
控制与决策. 2023, 38(2): 459–467 <https://doi.org/10.13195/j.kzyjc.2021.1437>

基于径向基神经网络的新型齿轮故障诊断方法

Novel gear fault diagnosis method based on RBF neural network
控制与决策. 2022, 37(2): 409–416 <https://doi.org/10.13195/j.kzyjc.2020.0836>

基于W-DenseNet的减压阀不平衡样本故障诊断模型

W-DenseNet-based fault diagnosis model of pressure-reducing valve with unbalanced samples
控制与决策. 2022, 37(6): 1513–1520 <https://doi.org/10.13195/j.kzyjc.2020.1708>

基于CBAM-CNN的模拟电路故障诊断

CBAM-CNN based analog circuit fault diagnosis
控制与决策. 2022, 37(10): 2609–2618 <https://doi.org/10.13195/j.kzyjc.2021.1111>

基于广义主成分分析的重构故障子空间建模方法

Reconstructed fault subspace modelling method based on generalized principal component analysis
控制与决策. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

基于改进的胶囊网络的行星齿轮箱故障诊断方法

黎德才^{1,2}, 张冕^{1,2†}, 王科盛³, 向红标^{1,2}, 康天博^{1,2}, 王豫赣^{1,2}

1. 天津理工大学 天津市先进机电系统设计与智能控制重点实验室, 天津 300384;
2. 天津理工大学 机电工程国家级实验教学示范中心, 天津 300384;
3. 电子科技大学 机械与电气工程学院, 成都 611731)

摘要: 行星齿轮箱是大型机械装备的核心传动环节,其内部关键零部件故障发生的部位与形式多样,威胁机械装备的安全服役. 针对其不同部件的多类故障诊断问题,提出一种基于改进的胶囊网络 (enhanced capsule network, ECN) 的“端到端”智能故障诊断方法. ECN 充分发挥了卷积神经网络对故障特征的深度提取能力,同时具备胶囊结构量化挖掘特征空间信息的特点,可利用动态路由机制计算胶囊层之间的相关度,从而实现对故障特征的精准归类. 此外,建立的间隔损失函数与输入数据不断优化模型参数,实现了对故障的智能诊断. 对太阳轮、行星轮以及多类部件故障数据混合的情况分别开展分析,实验结果表明,ECN 相比传统卷积神经网络和胶囊网络均表现出更强的故障诊断能力.

关键词: 行星齿轮箱; 深度学习; 胶囊网络; 智能故障诊断; 不同部件多类故障

中图分类号: TH17

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1440

引用格式: 黎德才,张冕,王科盛,等. 基于改进的胶囊网络的行星齿轮箱故障诊断方法[J]. 控制与决策, 2023, 38(3): 661-669.

Fault diagnosis method of planetary gearbox based on enhanced capsule network

LI De-cai^{1,2}, ZHANG Mian^{1,2†}, WANG Ke-sheng³, XIANG Hong-biao^{1,2}, KANG Tian-bo^{1,2}, WANG Yu-gan^{1,2}

1. Tianjin Key Laboratory of Advanced Mechatronic System Design and Intelligent Control, Tianjin University of Technology, Tianjin 300384, China; 2. National Demonstration Center for Experimental Mechanical and Electrical Engineering Education, Tianjin University of Technology, Tianjin 300384, China; 3. School of Mechanical and Electrical Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: Planetary gearboxes (PGs) are the core transmission link of large-scale mechanical equipment. The fault of key components occurring inside a PG usually exhibits in various locations and types, therefore, threatens the security service of mechanical equipment. To this point, an end-to-end intelligent diagnosis strategy based on enhanced capsule network (ECN) is proposed to detect multiple fault types of different components in a PG. The ECN well merits the advantages of the convolution neural network (CNN) and the capsule network (CN), which fully retains spatial information while digging in-depth fault features. The dynamic routing algorithm is used to calculate the correlation between the different capsule layers so as to accurately recognize the fault feature. Furthermore, the ECN continuously optimizes model parameters by the established margin loss functions and the input data. The experimental studies are conducted to demonstrate the effectiveness of the proposed model. The experimental results show that the ECN featured stronger fault diagnosis capabilities than the traditional CNN and CN.

Keywords: planetary gearboxes; deep learning; capsule network; intelligent fault diagnosis; multiple faults of different components

0 引言

行星齿轮箱是大型机械设备的核心传动环节^[1-2],由于其服役环境的严酷性,如存在工况频繁变

化、重载、极端天气等诸多因素,行星齿轮系统内部关键部件极易发生故障,进而引发灾难性事故. 因此,开展行星齿轮箱的故障诊断研究,对于保障大型机械

收稿日期: 2021-08-16; 录用日期: 2021-12-09.

基金项目: 国家自然科学基金项目(52005370); 天津市自然科学基金项目(20JCYBJC00790).

†通讯作者. E-mail: zoommian@foxmail.com.

设备安全稳定运行、避免人民生命财产损失具有重要意义。

自20世纪60年代以来,我国机械故障诊断技术迅速发展^[3-5]。行星齿轮箱的故障诊断模式经历了人工提取故障特征、基于机器学习和深度学习方法诊断的3个阶段。早期基于人工提取特征的方法,如利用希尔伯特-黄变换^[6]、短时傅里叶变换^[7]、经验模态分解^[8]、小波变换^[9]等,虽然可以实现故障识别,但手动提取特征的过程依赖专家经验知识^[10],特别是同一设备不同部件的故障特性往往不尽相同,因此检测过程十分棘手耗时。随着人工智能与计算机技术的发展,相继涌现出以支持向量机^[11]、神经网络^[12]等为代表的机器学习方法,不仅替代了传统人工提取特征的过程,同时取得了不错的诊断效果,极大地推动了机械设备诊断模式的革新。但是,浅层网络结构其自身学习能力十分有限,且数据的预处理与模型参数的设置仍依赖于专家经验知识,难以实现对机械设备真正意义上的智能诊断。

深度学习^[13]自被提出以来,展现出了强大的特征自动学习与提取能力,已被广泛运用于图像识别、自然语言处理、语音识别、故障诊断等领域^[14-15]。典型的深度学习方法,如卷积神经网络(convolution neural network, CNN)^[16]、生成对抗网络(generative adversarial networks, GAN)^[17]、深度信念网络(deep belief network, DBN)^[18]等,逐步拓展至行星齿轮箱的故障诊断方法之中:Jing等^[19]通过CNN模型对7种不同健康状态的行星轮故障进行诊断,识别准确率达到98.67%;Jiao等^[20]利用多元编码器提取了原始信号特征并输入至CNN模型,对10种行星轮故障的诊断准确率达到97.35%;Wang等^[21]提出了一种采用堆叠降噪自动编码器作为判别器的GAN诊断模型,对5种不同健康状态的太阳轮诊断准确率达到99.8%,在少量样本与噪声条件下呈现出较强的诊断能力;Gai等^[22]基于蝗虫算法提出了一种参数优化的DBN方法,对单个齿轮的4种故障类型识别准确率达到99.5%。当前,以深度学习算法为核心的诊断模式正得到学者们的广泛关注,然而当前研究大多围绕单类齿轮部件的不同故障开展。鉴于行星齿轮箱中齿轮故障发生部位与形式多样,仅开展单类齿轮的故障诊断难以全面保障机械设备的安全运行。特别是以CNN为核心的深度学习模型,虽然对单一部件的故障识别取得了不错的效果,但应用于包含不同部件的

故障数据时,恐难保证较好的诊断能力。

Sabour等^[23]首次提出胶囊网络(capsule network, CN)模型,突破了传统标量神经元传递信息的片面性,以向量作为网络的输入和输出,进一步挖掘出特征的空间信息。近年来,胶囊网络展现出强大的细节特征提取能力,已在机械设备故障诊断领域中初露锋芒^[24-25]。然而,当前国内外少有研究人员将胶囊网络应用于行星齿轮箱的故障诊断之中。

本文提出一种基于改进的胶囊网络(ECN)的“端到端”智能故障诊断方法,用于诊断行星齿轮箱不同部件的多类故障。首先,获取多类故障振动信号构建样本集;然后,利用卷积池化结构实现故障特征的自动提取与降维;进而,通过胶囊结构矢量化表示特征并传递信息,同时采用动态路由机制计算不同胶囊层向量之间的相关度;最后,通过间隔损失函数与输入数据不断优化模型参数,实现对不同部件故障的精准智能诊断。通过与经典CNN模型、CN模型进行实验对比,验证了ECN的优越性。

1 相关理论

1.1 卷积池化结构

LeCun等^[16]首次提出CNN模型,引入卷积与池化两个全新概念,用以提取数据中的深度特征信息。CNN算法的核心,由卷积层和池化层构成的卷积池化结构如图1所示。

卷积层通过卷积运算与激活函数实现了对输入数据的特征提取:首先,通过多个维度相同的卷积核对输入数据进行卷积运算,同时附加偏置项得到卷积结果;然后,利用激活函数进行非线性映射,输出多个特征矩阵。卷积过程的表达式为

$$O_j^n = f\left(\sum_{i \in M_j} X_i \times w_i^n + b_n\right). \quad (1)$$

其中: O_j^n 为卷积层输出第 n 个特征矩阵的第 j 个元素; M_j 为输入数据的第 j 个卷积区域; X_i 为 M_j 的第 i 个元素; w_i^n 为第 n 个卷积核的权值矩阵; b_n 为第 n 个卷积核对应的偏置项; $f(\cdot)$ 表示激活函数,以ReLU(rectified linear unit)函数为例,其表达式为

$$f(x) = \max(0, x), \quad (2)$$

$f(x)$ 为激活函数的输出值, x 为输入值。

池化层通过池化运算实现了对特征矩阵的降维过程:将卷积层的输出数据无重叠、等宽度地划分为




图1 卷积池化结构

q 个池化单元, 对每个单元内的元素进行池化运算, 得到池化层的输出特征矩阵. 以最大池化为例, 其表达式为

$$Y_q^n = \max(D_q^n). \quad (3)$$

其中: Y_q^n 为池化层输出第 n 个特征矩阵中的第 q 个元素; D_q^n 为池化层输入第 n 个特征矩阵的第 q 个池化单元, $(O_{j-w+1}^n, \dots, O_j^n) \in D_q^n$, W 为池化单元宽度.

1.2 胶囊网络

胶囊网络的创新思想在于将矢量作为网络的输入和输出, 挖掘并保留了特征的空间信息. 胶囊可看作由多个神经元集成的矢量, 其矢量模长表示特征存在的概率, 矢量的方向可表示特征的实例化参数, 例如特征的位置、大小和方向等. 胶囊网络通过动态路由机制实现不同胶囊层之间的信息传递, 胶囊结构如图2所示.

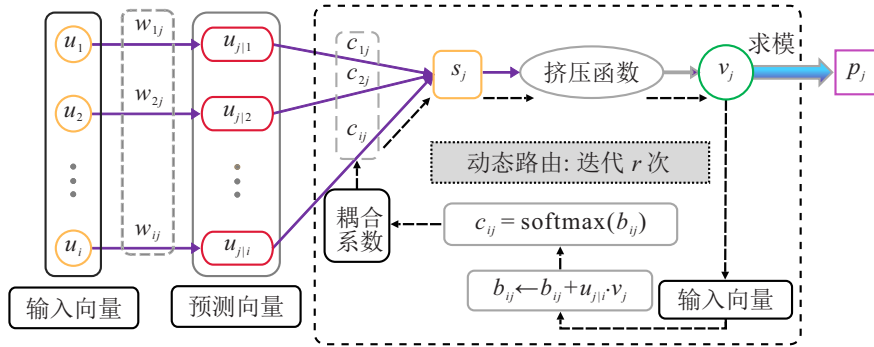


图2 胶囊结构

胶囊结构的运算过程如下:

step 1: 输入向量 u_i 与权值矩阵 w_{ij} 相乘得到预测向量 $u_{j|i}$, 可表示为

$$u_{j|i} = w_{ij}u_i. \quad (4)$$

step 2: 预测向量 $u_{j|i}$ 与耦合系数 c_{ij} 加权求和, 得到深层特征向量 s_j . 其中耦合系数 c_{ij} 可通过更新中间变量 b_{ij} 运算获得, 即

$$c_{ij} = \text{softmax}(b_{ij}) = \frac{\exp(b_{ij})}{\sum_{1 \leq k \leq j} \exp(b_{ik})}, \quad (5)$$

$$s_j = \sum_i c_{ij}u_{j|i}. \quad (6)$$

step 3: 利用 Squash 激活函数压缩深层特征向量 s_j , 可以保留特征向量的空间信息, 同时将向量模长压缩至 $0 \sim 1$ 之间, 得到输出向量

$$v_j = \text{squash}(s_j) = \frac{\|s_j\|^2}{1 + \|s_j\|^2} \frac{s_j}{\|s_j\|}. \quad (7)$$

step 4: 利用动态路由由算法迭代更新不同胶囊层之间的参数以优化输出向量: 首先通过内积计算 $u_{j|i}$ 与 v_j 的相关性, 优化 b_{ij} , 即

$$b_{ij} \leftarrow b_{ij} + u_{j|i}v_j, \quad (8)$$

进而根据式(5)更新 c_{ij} 。若两向量相关度高,则增大 c_{ij} 值,反之减小。随后利用式(6)和(7)依次优化 s_j 和 v_j 。动态路由共迭代 r 次,最后得到最优输出向量 v_j ,其方向可表示为某特征类别,模长则表示识别为该类别的概率 p_j ,有

$$p_j = \|v_j\|, \quad (9)$$

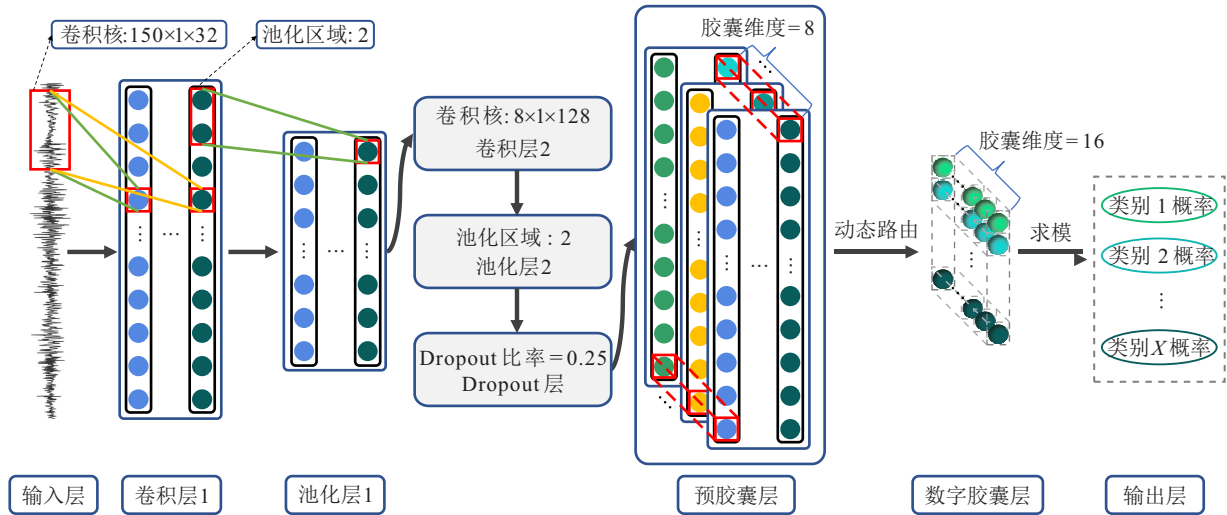


图3 ECN网络结构

ECN模型结构共包含9层:1个输入层、2个卷积层、2个池化层、1个Dropout层、1个预胶囊层、1个数字胶囊层和1个输出层。首先,将原始数据经过 z -score 标准化处理后作为ECN网络输入数据, z -score 标准化公式为

$$Y_i = \frac{X_i - \bar{X}}{\sigma}. \quad (10)$$

其中: Y_i 为标准化后的数据, X_i 为原始数据, \bar{X} 为原始数据均值, σ 为原始数据方差。

卷积层1采用宽卷积核提取输入特征,用以降低噪声的影响;卷积层2采用大量窄卷积核,充分提取特征的底层特性;为了降低模型训练参数,提高训练速度,每个卷积层后均附有一池化层;Dropout层舍弃部分神经元以防止训练阶段过拟合;预胶囊层包含卷积运算,同时将卷积结果以矢量形式构建胶囊作为数字胶囊层的输入;数字胶囊层通过动态路由机制计算胶囊层之间的相关度实现对故障特征的精确归类;输出层对输出向量进行二范数求解,得到不同故障类型的概率分布。

2.2 构建模型损失函数

神经网络算法通常基于损失函数来度量预测值与实际值的差异,从而对模型参数进行优化,实现误差的反向传播过程。在训练过程中,间隔损失函数

p_j 值越大表明分类越准确。

2 基于改进的胶囊网络的故障诊断方法

2.1 模型的提出

本文结合卷积神经网络与胶囊网络提出一种改进的胶囊网络(ECN),以实现行星齿轮箱不同部件的多类故障智能诊断。ECN结构如图3所示。

(Margin Loss)^[26]使得胶囊网络倾向于输出一个长向量和若干个短向量,向量的长度代表胶囊存在的概率。因此,ECN模型采用间隔损失函数,其表达式为

$$L_k = T_k \max(0, m^+ - \|v_k\|)^2 + \lambda(1 - T_k) \max(0, \|v_k\| - m^-)^2. \quad (11)$$

其中:下标 k 表示故障类别; L_k 表示类别 k 的间隔损失; T_k 表示分类指示函数(分类正确取1,否则取0); $\|v_k\|$ 表示识别为故障类别的概率; m^+ 为上界,取0.9; m^- 为下界,取0.1; λ 为比例系数,取0.5。总损失为各样例损失之和。

2.3 故障诊断流程

本文结合CNN和CN构建一种可用于齿轮箱故障诊断的深度学习网络,其诊断流程如图4所示。

基于改进的胶囊网络的故障诊断具体步骤如下:

- 1) 获取实验数据;
- 2) z -score 标准化处理;
- 3) 将数据集划分为训练样本集和测试样本集;
- 4) 根据实验需求,采用留出法或十折交叉验证法进一步划分训练样本集为训练集和验证集;
- 5) 设计模型结构并初始化参数;
- 6) 使用训练集训练模型,验证集优化模型参数;
- 7) 使用测试集验证训练后的模型,得出诊断结

果.

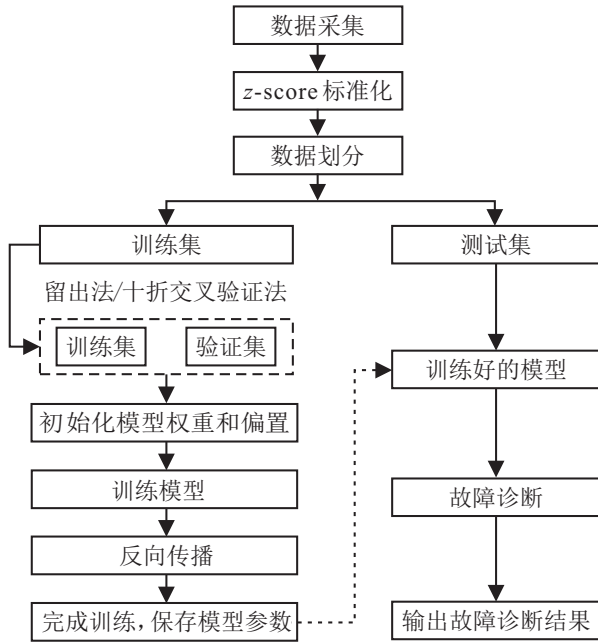


图4 ECN模型的故障诊断流程

3 实验验证

3.1 实验数据介绍

为验证ECN的诊断效果, 本文在电子科技大学设备监控与健康管理局的动力故障与故障传动实验台(dynamci drivetrian simulator, DDS)^[27-28]开展实验, DDS实验台整体结构如图5所示.




图5 电子科技大学DDS实验台

DDS实验台包括一台伺服驱动电机, 一个输入扭矩编码器, 一个输出扭矩编码器, 一台行星齿轮箱, 水平、垂直两个方向的加速度传感器(100 mv/g), 一台定轴齿轮箱以及一台可编程磁力制动器. 行星齿轮箱装配齿轮参数如表1所示.

表1 行星齿轮箱参数

	太阳轮齿数	行星轮齿数	齿圈齿数	行星轮数
数值	28	36	100	4

通过安装在行星齿轮箱箱体水平方向的加速度

传感器获取振动信号, 分别采集正常数据、4类太阳轮故障数据和3类行星轮故障数据, 其故障实物图分别如图6、图7所示.



图6 太阳轮故障实物图



图7 行星轮故障实物图

在电动机转速为1 800 RPM和3 000 RPM两种工况下, 分别采集8类齿轮健康状态的振动数据, 采集时间为22 s, 采样频率设置为10 240 Hz. 将获取的振动信号以长度为1 024个数据点截取为一个样本, 其时域信号如图8所示, 按照7:3的比例划分训练集和测试集, 数据分布如表2所示.

表2 数据分布

序号	健康状况类型	转速/(RPM)			
		1 800		3 000	
		训练	测试	训练	测试
C ₁	正常	154	66	154	66
C ₂	太阳轮齿根裂纹	154	66	154	66
C ₃	太阳轮断齿	154	66	154	66
C ₄	太阳轮缺齿	154	66	154	66
C ₅	太阳轮齿面磨损	154	66	154	66
C ₆	行星轮齿根裂纹	154	66	154	66
C ₇	行星轮断齿	154	66	154	66
C ₈	行星轮缺齿	154	66	154	66

数据集的标签采用“独热(one-hot)”的编码方式: 对于X种类别的故障诊断, 将标签转化为X维的向量, 并且其中一个值为1, 其余均为0, 每类故障标签互异.

本节共开展3类实验分析, 分别对太阳轮(C₁ ~ C₅)、行星轮(C₁, C₆ ~ C₈)以及两类齿轮部件(C₁ ~ C₈)故障数据混合情况下的故障进行诊断.

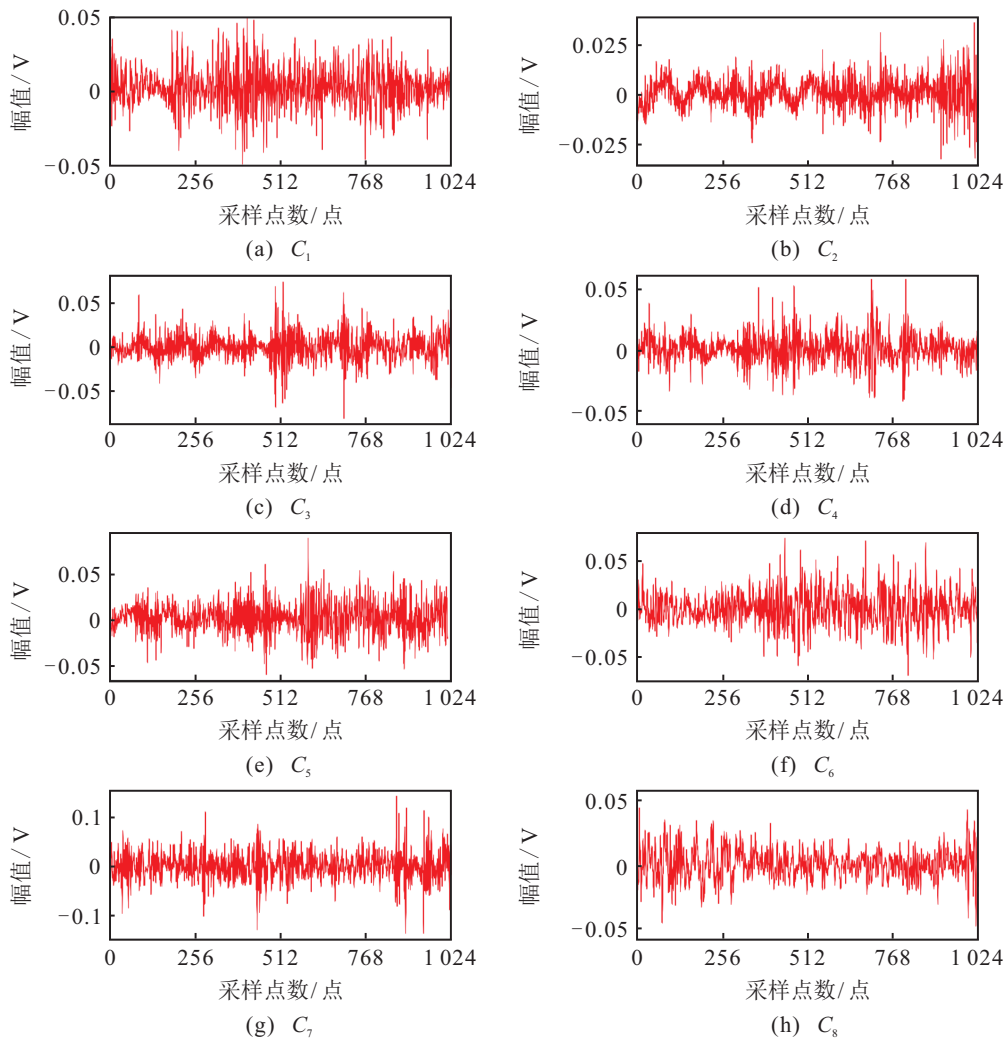


图8 时域信号

3.2 模型参数设置

ECN模型的输入样本维度为 1024×1 ,输出维度为故障类型数量. 激活函数采用ReLU函数, 损失函数采用Margin Loss函数. 模型具体结构参数设置如

表3所示. 其中: C 为卷积核大小, n 为卷积核数量, S 为滑动步长, P 为卷积过程是否像素填充, W 为池化单元宽度, DC 为胶囊维度, NC 为胶囊通道数, X 为故障类型数量, R 为动态路由次数.

表3 ECN模型结构参数设置

层数	类型	参数	输出
0	输入层	—	(1024, 1)
1	卷积层	$C = (150 \times 1); n = 32; S = 2; P = \text{no}$	(438, 1, 32)
2	池化层	$W = 2$	(219, 1, 32)
3	卷积层	$C = (8 \times 1); n = 128; S = 2; P = \text{yes}$	(110, 1, 128)
4	池化层	$W = 2$	(55, 1, 128)
5	Dropout层	比率:0.25	(55, 1, 128)
6	预胶囊层	$C = 12; DC = 8; NC = 12; S = 2; P = \text{yes}$	(264, 8)
7	数字胶囊层	$DC = 16; NC = X; R = 3$	(X , 16)
8	输出层	—	(X , 1)

对比的CN模型共6层,首层和后4层与ECN模型一致.第2层为卷积层,参数设置为 $C = (150 \times 1), n = 128, S = 2, P = \text{no}$.激活、损失函数与ECN相

同.

对比的CNN模型共8层:前6层与ECN模型一致,后2层为全连接层,神经元数分别为150和 X .

CNN模型中间层的激活函数选用ReLU函数,输出层选用Softmax函数,损失函数选用交叉熵损失函数。

3.3 单一部件故障诊断

将训练集按9:1的比例划分为训练集和验证集,两类网络设置单次处理数据量batch-size为10,共训练50个epoch,采用Adam(adaptive moment estimation)优化函数,学习率 r 设置为0.001。图9给出了在电动机转速为1800 RPM工况下,ECN模型对太阳轮5类故障类型进行故障诊断的训练和验证过程。




图9 ECN训练和验证过程

将两种工况下太阳轮和行星轮的故障数据分别输入CNN、CN、ECN模型,测试准确率取前5次结果的平均值,如图10所示。

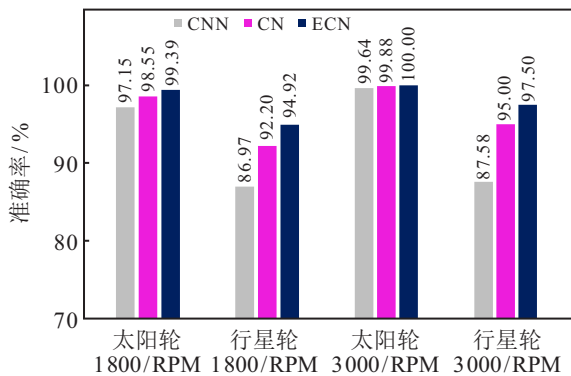


图10 单一部件故障测试准确率

由图10所示,两种工况下,3类模型对于太阳轮故障数据均取得了较高的测试准确率。行星轮故障数据诊断难度较高,电动机转速为1800 RPM工况下,3类模型测试准确率分别为86.97%、92.20%、94.92%;电动机转速为3000 RPM工况下,3类模型测试准确率分别为87.58%、95.00%、97.50%。单一部件故障诊断实验结果表明,ECN相比于传统的CNN与CN具有更强的诊断能力。

3.4 不同齿轮部件多类故障诊断

为使实验结果更具信服力,对比实验采用10次十折交叉验证的训练方式,将训练集等分为10份,每次不重复地选用9份用于训练,1份用于验证。设置单次训练数据量batch-size为10,每次训练5

个epochs,10次共训练50个epoch。两类模型均采用Adam算法对模型参数进行优化,学习率 r 设置为0.001。将测试集准确率作为对比依据,取前5次结果的平均值,3类模型的诊断结果如表4所示。

表4 不同齿轮部件多类故障测试准确率 %

转速	模型	第1次	第2次	第3次	第4次	第5次	均值
1800/RPM	CNN	94.89	97.35	94.89	94.89	93.37	95.08
	CN	90.15	93.18	91.86	92.80	93.18	92.23
	ECN	97.73	96.78	97.16	98.11	96.97	97.35
3000/RPM	CNN	86.74	94.89	89.96	93.75	96.78	92.42
	CN	94.70	96.02	95.45	94.13	94.51	94.96
	ECN	98.67	99.24	98.86	98.48	99.05	98.86

如表4所示,在电动机转速为1800 RPM工况下,ECN模型测试准确率达到97.35%,优于CN模型的92.23%与CNN模型的95.08%;在电动机转速为3000 RPM工况下,ECN模型达到了98.86%的测试准确率,分别高于CN模型3.9%与CNN模型6.44%。实验结果表明,ECN网络对于单类以及不同齿轮部件的多类故障具有更高的识别精度。

3.5 增加的实验

实验数据来自东南大学的行星齿轮箱、轴承数据集,所用动力故障与故障传动(DDS)实验台整体结构如图11所示,实验台参数的详细介绍参见文献[29]。数据集包含两种工作状态的数据,即转速系统负载分别为20 Hz-0 V、30 Hz-2 V。故障类型包括:1种健康状态、4种齿轮故障类型和4种轴承故障类型,共9种。每类故障各有220个样本,样本长度为1024个数据点,样本集划分规则与3.1节相同,数据分布如表5所示。




图11 东南大学DDS实验台

对比模型与模型参数均与3.1节描述一致,本节对两种转速-负载下的齿轮、轴承共9种故障类型展开诊断研究。表6给出了前5次测试准确率及其平均值。

表5 齿轮-轴承实验样本分布

序号	部件	健康状况类型	训练集	测试集
1	—	正常	154	66
2	齿轮	齿面裂纹	154	66
3		缺齿	154	66
4		齿根裂纹	154	66
5		齿面磨损	154	66
6	轴承	球体裂纹	154	66
7		内环裂纹	154	66
8		外环裂纹	154	66
9		内外环均出现裂纹	154	66

表6 齿轮-轴承数据分类结果

转速-负载	模型	第1次	第2次	第3次	第4次	第5次	均值
20 Hz-0 V	CNN	98.99	99.16	91.08	93.94	97.98	96.23
	CN	99.66	99.16	98.65	99.16	98.15	98.96
	ECN	99.83	100.0	100.0	99.33	100.0	99.83
30 Hz-2 V	CNN	51.52	63.80	51.01	48.99	43.10	51.68
	CN	84.34	85.19	86.53	85.02	88.22	85.86
	ECN	98.48	96.67	96.30	98.82	96.13	97.28

如表6所示,在转速系统负载为20 Hz-0 V工况下,ECN平均测试准确率为99.83%。在转速系统负载为30 Hz-2 V工况下,ECN平均测试准确率为97.28,与传统的CN和CNN相比,分别提高了11.42%、45.6%。实验结果表明,本文所提模型具有更稳定的诊断性能,对于不同部件的多类故障具有良好的分类效果。

4 结论

本文针对行星齿轮箱不同部件的多类故障诊断问题,提出了一种改进的胶囊网络的智能诊断模型,实现了从原始数据到故障类别的“端到端”自动诊断;ECN模型结合了卷积池化结构对故障特征的深度提取能力,以及胶囊结构矢量化挖掘特征空间信息的特点,实现了对行星齿轮箱故障的精确智能诊断。实验结果表明,相比于传统的CNN与CN网络,本文提出的ECN网络对单类部件多故障、多类部件在多故障数据混合条件下具有更高的诊断准确率,具有良好的应用前景。

当前方法依旧存在下述问题:1)所提模型的可调参数大多通过试验得到;2)所提模型采用全连接版本的动态路由,引入了大量的计算消耗。对此,下一步将研究针对不同数据集的模型参数选取规则,以及采用权值共享策略以减少模型参数和计算消耗。

参考文献(References)

- [1] 张冕. 行星齿轮箱关键零部件故障诊断[D]. 成都: 电子科技大学机械工程学院, 2019: 1-3.
(Zhang M. Fault diagnosis of key components in planetary gearboxes[D]. Chengdu: School of Mechanical Engineering, University of Electronic Science and Technology of China, 2019: 1-3.)
- [2] Zhang M, Li D C, Zuo M J, et al. An improved phenomenological model of vibrations for planetary gearboxes[J]. Journal of Sound and Vibration, 2021, 496: 115919.
- [3] 王国彪, 何正嘉, 陈雪峰, 等. 机械故障诊断基础研究“何去何从”[J]. 机械工程学报, 2013, 49(1): 63-72.
(Wang G B, He Z J, Chen X F, et al. Basic research on machinery fault diagnosis—What is the prescription[J]. Journal of Mechanical Engineering, 2013, 49(1): 63-72.)
- [4] Zhang M, Wang K S, Wei D D, et al. Amplitudes of characteristic frequencies for fault diagnosis of planetary gearbox[J]. Journal of Sound and Vibration, 2018, 432: 119-132.
- [5] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9.
(Li H, Xiao D Y. Survey on data driven fault diagnosis methods[J]. Control and Decision, 2011, 26(1): 1-9.)
- [6] 李辉, 潘宏侠, 郑海起. Hilbert-Huang变换在行星齿轮箱故障诊断中的应用[J]. 测试技术学报, 2006, 20(2): 144-149.
(Li H, Pan H X, Zheng H Q. Application of Hilbert-Huang transform to faults diagnosis of planetary gearbox[J]. Journal of Test and Measurement Technology, 2006, 20(2): 144-149.)
- [7] 张东, 冯志鹏. 迭代广义短时Fourier变换在行星齿轮箱故障诊断中的应用[J]. 工程科学学报, 2017, 39(4): 604-610.
(Zhang D, Feng Z P. Application of iterative generalized short-time Fourier transform to fault diagnosis of planetary gearboxes[J]. Chinese Journal of Engineering, 2017, 39(4): 604-610.)
- [8] Teng W, Wang F, Zhang K L, et al. Pitting fault detection of a wind turbine gearbox using empirical mode decomposition[J]. Strojnik Vestnik — Journal of Mechanical Engineering, 2014, 60(1): 12-20.
- [9] 程耕国, 周凤星. 一种基于小波分析的故障检测与诊断[J]. 控制与决策, 2001, 16(S1): 828-830.
(Cheng G G, Zhou F X. A fault-detection method based on wavelet analysis[J]. Control and Decision, 2001, 16(S1): 828-830.)
- [10] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.

- (Lei Y G, Jia F, Zhou X, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.)
- [11] 许建华, 张学工, 李衍达. 支持向量机的新发展[J]. 控制与决策, 2004, 19(5): 481-484.
(Xu J H, Zhang X G, Li Y D. Advances in support vector machines[J]. Control and Decision, 2004, 19(5): 481-484.)
- [12] Samanta B, Al-Balushi K R. Artificial neural network based fault diagnostics of rolling element bearings using time-domain features[J]. Mechanical Systems and Signal Processing, 2003, 17(2): 317-328.
- [13] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [14] Khan S, Yairi T. A review on the application of deep learning in system health management[J]. Mechanical Systems and Signal Processing, 2018, 107: 241-265.
- [15] 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.)
- [16] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [17] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [18] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [19] Jing L Y, Zhao M, Li P, et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox[J]. Measurement, 2017, 111: 1-10.
- [20] Jiao J Y, Zhao M, Lin J, et al. A multivariate encoder information based convolutional neural network for intelligent fault diagnosis of planetary gearboxes[J]. Knowledge-Based Systems, 2018, 160: 237-250.
- [21] Wang Z R, Wang J, Wang Y R. An intelligent diagnosis scheme based on generative adversarial learning deep neural networks and its application to planetary gearbox fault pattern recognition[J]. Neurocomputing, 2018, 310: 213-222.
- [22] Gai J B, Shen J X, Wang H, et al. A parameter-optimized DBN using GOA and its application in fault diagnosis of gearbox[J]. Shock and Vibration, 2020, 2020: 4294095.
- [23] Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules[J/OL]. 2017, arXiv: 1710.09829.
- [24] Huang R Y, Li J P, Li W H, et al. Deep ensemble capsule network for intelligent compound fault diagnosis using multisensory data[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(5): 2304-2314.
- [25] Wang Y, Ning D J, Feng S L. A novel capsule network based on wide convolution and multi-scale convolution for fault diagnosis[J]. Applied Sciences, 2020, 10(10): 3659.
- [26] 赵小强, 张和慧. 基于交叉熵的改进NPE间歇过程故障检测算法[J]. 控制与决策, 2021, 36(2): 411-417.
(Zhao X Q, Zhang H H. Improved NPE batch process fault detection algorithm based on cross entropy[J]. Control and Decision, 2021, 36(2): 411-417.)
- [27] 张冕, 王科盛, 李亚鑫. 行星齿轮箱太阳轮故障动态啮合周期特性[J]. 振动与冲击, 2020, 39(6): 263-270.
(Zhang M, Wang K S, Li Y X. Motion period characteristics of Sun gear fault meshing behaviours[J]. Journal of Vibration and Shock, 2020, 39(6): 263-270.)
- [28] Zhang M, Li D C, Wang K S, et al. An adaptive order-band energy ratio method for the fault diagnosis of planetary gearboxes[J]. Mechanical Systems and Signal Processing, 2022, 165: 108336.
- [29] Shao S Y, McAleer S, Yan R Q, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. IEEE Transactions on Industrial Informatics, 2019, 15(4): 2446-2455.

作者简介

黎德才(1998—), 男, 硕士生, 从事故障诊断、深度学习的研究, E-mail: decaili98@163.com;

张冕(1990—), 男, 讲师, 博士, 从事机械设备健康管理、深度学习等研究, E-mail: zoommian@foxmail.com;

王科盛(1978—), 男, 副教授, 博士, 从事健康管理、寿命预测等研究, E-mail: keshengwang@uestc.edu.cn;

向红标(1982—), 男, 副教授, 博士, 从事控制技术、测试计量技术及仪器等研究, E-mail: xhb@tju.edu.cn;

康天博(1998—), 男, 硕士生, 从事机器学习、设备可靠性的研究, E-mail: 18722263860@163.com;

王豫赣(2003—), 女, 本科生, 从事行星齿轮箱故障诊断的研究, E-mail: 3303772446@qq.com.

(责任编辑: 齐 霖)