

基于改进的 SqueezeNet 直升机 滚动轴承故障诊断

余志锋¹, 熊邦书¹, 李新民², 欧巧凤¹

(1. 南昌航空大学 图像处理与模式识别省重点实验室, 南昌 330063;

2. 中国航空工业集团有限公司 中国直升机设计研究所

直升机旋翼动力学重点实验室, 江西 景德镇 333001)

摘 要: 针对现有基于卷积神经网络的故障诊断方法存在模型参数量和计算量大的问题, 提出一种改进的 SqueezeNet 模型应用于直升机滚动轴承故障诊断。该模型借鉴 VGG16 模型的思想, 在经典的 SqueezeNet 基础上, 采用 3 个 3×3 卷积核代替 1 个 7×7 卷积核, 实现了在相同感知野条件下增加网络容量、增强非线性、减少网络参数量, 采用卷积层、池化层和 Fire 模块、池化层两大结构交替的方式组成模型特征提取层, 在保障特征提取能力的情况下, 进一步减少了网络参数量。通过轴承数据开展模型故障诊断实验, 结果表明该模型诊断精度达到 99.65%, 与传统卷积神经网络及经典的 SqueezeNet 模型相比诊断精度相当, 而计算量与参数量最大缩减约 6 倍和 36 倍。

关 键 词: 直升机滚动轴承; 卷积神经网络; VGG16 模型; 轻量化; SqueezeNet 模型

中图分类号: V233⁺5; TH133.33

文献标志码: A

Fault diagnosis of helicopter rolling bearing based on improved SqueezeNet

YU Zhifeng¹, XIONG Bangshu¹, LI Xinmin², OU Qiaofeng¹

(1. Provincial Key Laboratory of Image Processing and Pattern Recognition,

Nanchang Hangkong University, Nanchang 330063, China;

2. Science and Technology on Rotorcraft Aeromechanics Laboratory,

China Helicopter Research and Development Institute,

Aviation Industry Corporation of China, Limited, Jingdezhen Jiangxi 333001, China)

Abstract: In order to solve the problem of large amount of model parameters and calculations in the existing fault diagnosis methods based on convolutional neural networks, an improved SqueezeNet model was proposed to be applied to the fault diagnosis of helicopter rolling bearings. By drawing on the idea of the VGG16 model based on the classic SqueezeNet, the model used three sizes of 3×3 convolution kernels instead of one size of 7×7 convolution kernel, and realizes the increase of network capacity, enhancement of nonlinearity, reduction of network parameters amount under the same perceptual field conditions. To further reduce the amount of

收稿日期: 2021-06-22

基金项目: 国家自然科学基金(61866027); 航空科学基金(2016ZD56008; 20185756006)

作者简介: 余志锋(1995—), 男, 硕士生, 主要从事直升机自动倾斜器滚动轴承故障研究。

通信作者: 熊邦书(1968—), 男, 教授, 博士, 主要从事计算机视觉、直升机故障诊断研究。E-mail: xiongbbs@126.com

引用格式: 余志锋, 熊邦书, 李新民, 等. 基于改进的 SqueezeNet 直升机滚动轴承故障诊断[J]. 航空动力学报, 2022, 37(6): 1162-1170. YU Zhifeng, XIONG Bangshu, LI Xinmin, et al. Fault diagnosis of helicopter rolling bearing based on improved SqueezeNet[J]. Journal of Aerospace Power, 2022, 37(6): 1162-1170.

network parameters, the convolutional layer, pooling layer, Fire module and pooling layer were alternated to form the model feature extraction layer. While ensuring the feature extraction capability, the amount of network parameters was further reduced. The model faults diagnosis experiment was carried out through the bearing data onto the research group. The results showed that the diagnosis accuracy of the model reached 99.65%, which was comparable to the traditional convolutional neural network and the classic SqueezeNet model. The calculation amount and the parameter amount were reduced by about 6 times and 36 times.

Key words: helicopter rolling bearings; convolutional neural network; VGG16 model; lightweight; SqueezeNet model

自动倾斜器滚动轴承是直升机旋翼中连接不动环和动环的桥梁,是旋翼的关键部件,在飞行过程中,承受着巨大的负载,易发生故障。因此,研究直升机滚动轴承故障诊断方法,对保障直升机旋翼的安全工作意义重大^[1]。

自Hinton等^[2]首次提出深度学习思想,已成功应用于图像识别^[3]、目标检测^[4]、计算机视觉^[5]等领域。近年来,在故障诊断领域,不少专家和学者开展了基于深度学习的故障诊断方法研究,取得不少成果^[6-8]。如杨平等^[9]提出一种基于卷积门控循环神经网络的轴承故障诊断方法,该方法在小样本数据集下依旧取得不错的效果。陈果等^[10]提出基于深度卷积神经网络的航空发动机不平衡故障部位诊断方法,解决了机匣测点的航空发动机不平衡故障部位识别问题。钟诗胜等^[11]结合深度置信网络、采样与集成技术,提出基于不均样本驱动的民航发动机故障诊断方法,取得不错的结果。

卷积神经网络的优点在于具有自动提取特征的能力,其识别准确率相比传统的人工设计特征方法有大幅提高,但现有基于卷积神经网络的故障诊断方法存在模型参数量和计算量大的问题^[12-13]。为解决此类问题,本文提出一种基于改进的SqueezeNet模型应用于直升机滚动轴承的轻量级故障诊断,该模型借鉴视觉几何群网络16 (visual geometry group network16, VGG16)模型的思想,在经典SqueezeNet模型基础上,采用3个 3×3 卷积核代替1个 7×7 卷积核,实现了在相同感知野条件下,增加网络容量、增强非线性、减少参数的目的,并由卷积层、池化层和Fire模块、池化层两大结构交替组成模型的特征提取层,从而使得模型具有较高的诊断精度且更加轻量化。

1 振动信号的图谱生成

1.1 振动信号的小波图谱生成

本文采用连续小波变换将轴承一维时域振动信号转为二维时频图谱,时频域特征描述了信号随时间的变化,丰富了特征信息。连续小波变换是一种时频域信号分析方法,其时间和频率分辨率随着尺度变化,在低频部分频率分辨率较高而时间分辨率较低;相反,高频部分时间分辨率较高而频率分辨率较低,符合低频信号变化缓慢,高频信号变化迅速的特点。因此,在振动信号分析中广泛使用。

设 $\phi(t) \in L^2(R)$, $\phi(t)$ 为基本小波或母小波,令

$$\phi_{a,b}(t) = \frac{1}{\sqrt{a}} \phi\left(\frac{t-b}{a}\right) \quad (1)$$

式中 a, b 分别为伸缩因子和平移因子,且 $a > 0$ 。

从式(1)中可知, $\phi(t)$ 经平移伸缩变换后得到函数 $\phi_{a,b}(t)$, a, b 不断的变化数值,可得到一组或多组函数 $\phi_{a,b}(t)$ 。若给定平方可积的信号 $x(t)$, $x(t) \in L^2(R)$,则 $x(t)$ 的小波变换定义如下:

$$W_x(a,b) = \frac{1}{\sqrt{a}} \int x(t) \phi\left(\frac{t-b}{a}\right) dt = \int x(t) \phi'_{a,b}(t) dt = \langle x(t), \phi_{a,b}(t) \rangle \quad (2)$$

式中信号 $x(t)$ 的小波变换 $W_x(a,b)$ 是 a, b 的函数,且 a, b 和 t 都是连续变量,故又称连续小波变换^[14]。

1.2 图谱的直方图均衡化增强

轴承一维振动信号经小波变换得到小波系数,并以时间、频率为横纵坐标,绘制小波图谱,如图1所示。为减少模型计算量,通常将小波图谱转为灰度图像,但将其直接转为灰度图像,特征不是很清晰,采用直方图均衡化的方法,能增加局部对比度凸显特征。




图1 本文数据小波图谱

Fig.1 Wavelet atlas of data in this article

直方图均衡化算法的变换函数为图像各灰度级概率的累积分布函数,能将原图像映射为灰度级分布较均匀的图像。其中,累积分布函数公式为

$$S_k = T(r_k) = \sum_{j=0}^k \frac{n_j}{n} = \sum_{j=0}^k p_r(r_j) \quad (3)$$

$$0 \leq r_j \leq 1; k = 1, 2, \dots, L-1$$

式中 S_k 为直方图均衡化后图像归一化灰度级, T 为变换关系式, r_j 为原图像归一化灰度级, n_j 为第 k 级灰度级的像素个数, n 为像素的总个数, $p_r(r_j)$ 为原图像取第 k 级灰度值的概率,也即原图像的灰度直方图。

图2给出了本文数据的小波灰度图谱和直方图均衡化增强后的图谱,可以看出相比灰度图,增强后的图谱,特征更加突出。

为了充分地验证直方图均衡化对图谱特征的增强效果。采用本文数据,在不同模型上开展实验,比较直方图均衡化算法增强前后对故障诊断效果的影响,实验结果如表1所示。





图2 本文数据灰度图和直方均衡化增强图

Fig.2 Grayscale image and histogram equalization enhancement image of data in this article

表1 增强前后的故障识别率

Table 1 Fault recognition rate before and after enhancement

方法	识别率/%	
	增强前	增强后
本文方法	99.24	99.65
经典SqueezeNet模型	99.10	99.57

从表1可以看出,采用直方图均衡化算法对本文数据集进行图像增强,2种模型的故障识别率都得到一定的提升,其中本文方法提升了0.41%,经典的SqueezeNet模型提升了0.47%。

2 基于改进的SqueezeNet直升机滚动轴承故障诊断

SqueezeNet是由Iandola等首次提出的一种轻量化网络模型。该模型参数是经典AlexNet模型的1/50,大小仅为4.8 MB,但网络识别精度与其相差很小^[15-17]。SqueezeNet模型结构如图3所示,模型参数如表2所示,其主要由8个Fire模块结合卷积网络中卷积层、池化层等结构组成。Fire模块由Squeeze和Expand两部分组成,如图4所示。Squeeze部分采用 1×1 卷积核能对输入特征图进行降维,减少网络参数量;Expand部分对Squeeze输出的特征图采用 1×1 和 3×3 卷积核并行处理,这种并行结构,增加了网络的宽度^[18]。

图4中 $H \times N$ 表示输入到网络模型的图片大小, M, s_1, e_1, e_3 表示通道数;Kerberl表示卷积核, n_k 表示卷积核的数量。




图 3 SqueezeNet模型结构图

Fig.3 SqueezeNet model structure diagram

表 2 经典的 SqueezeNet 模型参数

Table 2 Classical SqueezeNet model parameters

层名	输出数据大小	通道数	卷积核大小	卷积核数	池化方式和长度	激活函数
Conv1	25×25	96	7×7	96	最大值池化 2×2	ReLU
Fire1	25×25	128	(3×3)和(1×1)	16 和 64		ReLU
Fire2	25×25	128	(3×3)和(1×1)	16 和 64		ReLU
Fire3	12×12	256	(3×3)和(1×1)	32 和 128	最大值池化 2×2	ReLU
Fire4	12×12	256	(3×3)和(1×1)	32 和 128		ReLU
Fire5	12×12	384	(3×3)和(1×1)	48 和 192		ReLU
Fire6	12×12	384	(3×3)和(1×1)	48 和 192		ReLU
Fire7	6×6	512	(3×3)和(1×1)	64 和 256	最大值池化 2×2	ReLU
Fire8	6×6	512	(3×3)和(1×1)	64 和 256		ReLU
Conv2	6×6	4	(1×1)	4		ReLU
Global-avgpool	1×1	4			全局平均池化 6×6	
Softmax	4					




图 4 Fire 模块结构图

Fig.4 Fire module structure diagram

2.1 改进的 SqueezeNet 模型设计

表 2 给出了经典的 SqueezeNet 模型结构参数,首层卷积层采用 7×7 卷积核,但 7×7 卷积

核太大,增加网络的复杂度,采用更小的卷积核替代大尺寸卷积核,能保证网络精度基本不变,而减少模型参数量。在 VGG16 模型中,采用 3 个 3×3 卷积核代替 7×7 卷积核,在相同感知野的条件,提升了网络的深度,进而增强了网络容量^[19]。采用 3 个 3×3 卷积核代替 7×7 卷积核优点如下:

- 1) 3×3 卷积核是能够捕获像素八邻域信息的最小尺寸;
- 2) 通过小尺寸卷积层堆叠替代大尺寸卷积层,感受野大小不变;
- 3) 多层 3×3 卷积核的卷积堆叠,每层卷积都包含激活函数,与一个大尺寸卷积核的卷积相比,具有更多的非线性;
- 4) 多层 3×3 卷积核的卷积层,其参数相比于大尺寸卷积核的卷积层更少,若卷积层输入与输出特征图大小相同且为 c ,则 1 个 7×7 卷积核的卷积层参数为 $49c^2$,3 个 3×3 卷积核的卷积层参数个数为 $3 \times (3 \times 3 \times c \times c) = 27c^2$,相比参数

减少约 1.8 倍。

为此,本文将 7×7 卷积核替换为 3 个 3×3 的卷积核,采用卷积层、池化层和 Fire 模块、池化层两大结构交替的方式组成模型的特征提取层。

改进的 SqueezeNet 模型主要应用于样本数据较少的情况,网络层数无需过多,故交替次数为 2 次,该模型结构如图 5 所示,模型参数如表 3 所示。




图 5 本文改进的 SqueezeNet 模型结构图

Fig.5 Structure diagram of the improved SqueezeNet model in this article

表 3 本文 SqueezeNet 模型参数

Table 3 Parameter of the SqueezeNet model in this article

层名	输出数据大小	通道数	卷积核大小	卷积核数	池化方式和长度	激活函数
Conv1	50×50	32	3×3	32	最大值池化 2×2	ReLU
Fire1	25×25	32	(3×3) 和 (1×1)	8 和 16	最大值池化 2×2	ReLU
Conv2	13×13	64	3×3	64	最大值池化 2×2	ReLU
Fire2	7×7	64	(3×3) 和 (1×1)	16 和 32	最大值池化 2×2	ReLU
Conv3	4×4	128	3×3	128	最大值池化 2×2	ReLU
Conv4	4×4	4	1×1	4		ReLU
Global-avgpool	1×1	4			全局平均池化 4×4	
Softmax	4					

2.2 基于改进的 SqueezeNet 模型的故障诊断流程

本文提出一种改进 SqueezeNet 模型应用于直升机滚动轴承故障诊断中,解决了传统的卷积神经网络(convolutional neural networks,CNN)模型不够轻量化的问题。

具体诊断步骤如下。

步骤 1 振动信号采集。采集直升机滚动轴承 4 种状态:正常状态、内圈故障、外圈故障、滚珠故障的振动信号。

步骤 2 振动信号的小波图谱生成。采用 Morlet 小波基将一维轴承振动信号,进行连续小波变换转为大小为 100×100 的二维小波图谱,并将其采用直方图均衡化增强特征。

步骤 3 数据集生成。将小波图谱数据集划分成训练集、测试集和验证集,其中测试集用于网络模型的调优;而验证集用于验证最优模型的故障识别效果,其不参与模型训练。

步骤 4 改进的 SqueezeNet 模型设计。采用

3 个 3×3 卷积核代替 1 个 7×7 卷积核,并将卷积层、池化层和 Fire 模块、池化层两大结构,采用交替的方式组成模型特征提取层。

步骤 5 模型的训练与验证。将小波图谱训练集数据作为网络输入,对应故障类型的编码作为标签,进行有监督训练,利用测试集数据进行网络调优,并保存最优网络模型,将验证集样本导入保存的模型中,验证网络故障识别效果。

3 实验结果与分析

为验证本文方法的有效性,在本文数据集(实验室在洛阳 LYC 轴承有限公司采集的直升机自动倾斜器滚动轴承数据)上进行验证。验证网络模型的计算机配置:ROG STRIX-GTX1080TI-显卡、Intel(R) Xeon(R) 4114 处理器、Samsung DDR4-32G 内存、ATA SaDiskSD9TB8W1-2TB。

3.1 本文数据集实验结果与分析

首先在本文数据集上开展诊断实验,训练样本为 5 732 张、测试样本为 1 936 张、验证样本为

1 914 张。实验结果如图 6、图 7、表 4 所示,模型参数量和计算量对比如表 5 所示。

图 6 给出本文方法和经典的 SqueezeNet 模型的测试精度曲线,可以看出本文方法的曲线略高于经典的 SqueezeNet 模型的曲线,且波动幅度较小。图 7 给出两个方法的验证精度曲线,验证精度是由未参与网络训练的数据,导入已完成训练




图 6 数据测试集正确率

Fig.6 Accuracy of the data test set




图 7 数据验证集准确率

Fig.7 Accuracy of the data verification set

表 4 本文数据集平均诊断精度

Table 4 Average diagnostic accuracy of data set in this paper

参数	网络模型	
	本文方法	经典的 SqueezeNet
平均测试集精度/%	99.63	98.64
平均验证集精度/%	99.65	99.57
测试精度方差	0.116 4	0.184 5
验证精度方差	0.009 8	0.011 9

注:“平均测试集精度”行中为测试集列表中后 10 个测试精度值的平均精度。

的模型中得到精度。图 7 可以看出,两种方法的验证精度都很高,但本文方法更为稳定。表 4 给出两种方法具体的精度信息,看出本文方法的平均测试精度和验证精度都略高于经典的 SqueezeNet 模型。

表 5 给出两种方法的计算量和参数量对比,可以看出本文方法的参数量相比经典的 SqueezeNet 模型缩减约 36 倍,计算量缩减 6 倍,训练时间缩短了约 48 s。在两种方法故障诊断精度相差不大的情况下,本文方法在轻量化方面优势明显。

表 5 网络模型计算量和参数量对比表

Table 5 Comparison table of network model calculation amount and parameter amount

网络模型	浮点 计算量/ 10^8	参数量/ 10^5	训练 时间/s
本文方法	0.47	1.01	88.4
经典 SqueezeNet 模型	2.57	7.28	136.33

3.2 小样本下网络的性能

本文提出的改进 SqueezeNet 模型在本文数据集上的实验表明了该模型的有效性及其优越性。为验证模型在样本数据不足时的故障诊断识别率,开展小样本数据下的故障诊断实验。

目前本文数据集中,训练集总共 5 732 个样本,其中内圈故障 1 634 个样本,外圈故障 1 439 个样本,滚珠故障 2 118 个样本以及正常 541 个样本;测试集总共 1 936 个样本,其中内圈故障 592 个样本,外圈故障 493 个样本,滚珠故障 702 个样本以及正常 149 个样本;验证集总共 1 914 个样本,其中内圈故障 588 个样本,外圈故障 590 个样本,滚珠故障 586 个样本以及正常 150 个样本。由于本文数据的每一种故障类型有 3 种损伤程度,且由 6 种方向、7 种负载下采集得到,若只是从现有的每种故障中随机抽样,得到小样本数据集,会导致某些情况下的故障数据遗漏不够全面,不利于网络的训练。因此,本文按如下步骤获取小样本:

1) 获取小样本。将正常状态每一种负载下的振动信号,以 75 000 间距截断,5 000 个采样点为一个样本,随机截取两个样本;同理,3 种故障类型按相同的截取方法,共得到小样本 1 050 段,并将剩余振动信号作为验证集,共 6 618 段。

2) 构造小波图谱。将 1 050 段样本数据经

小波变换得到二维图谱,并通过直方图均衡化方法增强特征,同时压缩成 100×100 尺寸的图谱,共得到图谱1 050张;验证集共得6 618张。

3) 划分训练集、测试集以及验证集。按4:1的比例随机将数据集分成训练集和测试集,得训练样本823张,测试样本227张;其余作为验证集共6 618张。

为了验证本文方法在样本数据不足时,故障诊断效果依旧具有良好的优越性,与经典的SqueezeNet模型、CNN模型、基于K最近邻(K-nearest neighbor,KNN)改进的CNN模型(CNN-KNN),3种方法开展对比实验,实验采用的数据为本文数据。各模型的参数如表2、表3、表6、表7所示,实验结果如图8、图9和表8所示。

表 6 CNN模型参数

Table 6 Parameters of CNN model

层名	输出数据大小	通道数	卷积核大小	卷积核数	池化方式和长度	激活函数
Conv1	50×50	32	3×3	32	最大值池化 2×2	ReLU
Conv2	25×25	64	3×3	64	最大值池化 2×2	ReLU
Conv3	13×13	128	3×3	128	最大值池化 2×2	ReLU
Conv4	7×7	256	3×3	256	最大值池化 2×2	ReLU
FC1	256	1				ReLU
FC2	4	1				
Softmax	4					

表 7 CNN-KNN模型参数

Table 7 Parameters of CNN-KNN model

层名	输出数据大小	通道数	卷积核大小	卷积核数	池化方式和长度	激活函数
Conv1	50×50	32	3×3	32	最大值池化 2×2	ReLU
Conv2	25×25	64	3×3	64	最大值池化 2×2	ReLU
Conv3	13×13	128	3×3	128	最大值池化 2×2	ReLU
Conv4	7×7	256	3×3	256	最大值池化 2×2	ReLU
FC1	256	1				ReLU
FC2	4	1				
KNN分类器	4					

注:“KNN分类器”中的参数取默认值5。




图 8 测试数据对比曲线图

Fig.8 Comparative graph of test data




图 9 验证数据对比曲线图

Fig.9 Comparative graph of the verified data comparison

表 8 本文小样本数据下各模型的平均诊断精度

Table 8 Average diagnostic accuracy of each model under the small sample data in this paper

网络模型	平均测试集精度/%	平均验证集精度/%	测试精度方差	验证精度方差
本文方法	98.50	98.96	0.087 5	0.014 2
经典的 SqueezeNet	94.79	96.18	0.149 1	0.025 6
传统的 CNN	97.57	98.44	0.056 5	0.013 3
CNN-KNN 模型	98.15	98.68	0.025 5	0

注:“平均测试集精度”列中为测试集列表中后 10 个测试精度值的平均精度。

图 8 给出 4 种网络模型的测试精度曲线,可以看出本文方法的收敛速度较快且测试精度是最高的。由表 8 可知平均测试精度达 98.50%,相较于最低的精度高出 3.71%。图 9 给出 4 种网络模型的验证精度曲线,可以看出本文方法的验证精度曲线高于对比模型。由表 8 可知平均验证精度达 98.96%,是所有模型中取得精度最高,高出最低精度 2.78%,说明网络泛化性最好。

为验证本文提出的模型在轻量化方面的优势,给出 4 种网络模型的计算量、参数量及训练时间如表 9 所示。表中的训练时间是各模型训练本文小样本数据集耗费的时间。

表 9 四种网络模型计算量和参数量对比表

Table 9 Comparison of calculation amount and parameter amount of four network models

网络模型	浮点计算量/ 10^8	参数量/ 10^5	训练时间/s
本文方法	0.47	1.01	79.96
经典 SqueezeNet 模型	2.57	7.28	128.06
传统的 CNN 模型	3.05	36.00	106.75
CNN-KNN 模型	3.05	36.00	111.61

注:由于 CNN-KNN 模型在特征提取方面和传统 CNN 一致,故模型参数和传统 CNN 相同。

从表 9 可以看出,本文采用的模型的计算量与参数量最小且训练时间也是最短的。其中,模型计算量分别为经典 SqueezeNet 模型、传统的 CNN 模型的 1/5 和 1/6;模型参数量分别为经典 SqueezeNet 模型、传统 CNN 模型的 1/7 和 1/36。训练同样一个数据集,相比用时最长的模型时间缩短 48.1 s。

化层两大结构,采用交替的方式组成模型特征提取层,减少了模型参数量与计算量,有效地实现了直升机滚动轴承的轻量化故障诊断。

3) 提出方法不仅在减少模型参数量和计算量上效果突出,在样本数据不足时依旧取得较好的故障诊断精度且高于对比模型,进一步验证了本文方法的优越性。

4 结 论

文章针对现有基于卷积神经网络的故障诊断方法存在参数量大、计算量高的问题,提出了一种改进的 SqueezeNet 模型,经实验验证了方法的有效性,结果表明:

1) 提出方法采用 3 个 3×3 卷积核代替 1 个 7×7 卷积核,保证了感受野大小不变,增加了网络容量、增强了非线性,从而提高了直升机滚动轴承故障数据不足时的诊断精度。

2) 提出方法采用多个小尺寸卷积核代替大尺寸卷积核,并将卷积层、池化层和 Fire 模块、池

参考文献:

[1] 万齐杨,熊邦书,李新民,等.基于 DCAE-CNN 的自动倾斜器滚动轴承故障诊断[J].振动与冲击,2020,39(11):273-279.

WAN Qiyang, XIONG Bangshu, LI Xinmin, et al. Fault diagnosis of automatic tilter rolling bearing based on DCAE-CNN[J].Journal of Vibration and Shock, 2020, 39(11):273-279.(in Chinese)

[2] HINTON G E, SALAKHUTDINOV R R.Reducing the dimensionality of data with neural networks[J].Science, 2006, 313(5786):504-507.

[3] WANG Huaqing, LI Shi, SONG Liuyang, et al.A novel convolutional neural network based fault recognition method via

- image fusion of multi-vibration-signals[J]. Computers in Industry, 2019, 105(1):182-190.
- [4] DENG Zhipeng, SUN Hao, ZHOU Shilin, et al. Multi-scale object detection in remote sensing imagery with convolutional neural networks[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 145(4):3-22.
- [5] PANG Shuchao, LUACES O, YU Zhezhou, et al. Deep learning to frame objects for visual target tracking[J]. Engineering Applications of Artificial Intelligence, 2017, 65(1):406-420.
- [6] ZHAO Rui, YAN Ruqiang, CHEN Zhenghua, et al. Deep learning and its applications to machine health monitoring[J]. Mechanical Systems and Signal Processing, 2019, 115:213-237.
- [7] YANG Bin, LEI Yaguo, JIA Feng, et al. An intelligent fault diagnosis approach based on transfer learning from laboratory bearings to locomotive bearings[J]. Mechanical Systems and Signal Processing, 2019, 122:692-706.
- [8] ZHU Jun, CHEN Nan, PENG Weiwen. Estimation of bearing remaining useful life based on multiscale convolutional neural network[J]. IEEE Transactions on Industrial Electronics, 2019, 66(4):3208-3216.
- [9] 杨平, 苏燕辰. 基于卷积门控循环网络的滚动轴承故障诊断[J]. 航空动力学报, 2019, 34(11):2432-2439.
- YANG Ping, SU Yanchen. Fault diagnosis of rolling bearing based on convolution gated recurrent network[J]. Journal of Aerospace Power, 2019, 34(11):2432-2439. (in Chinese)
- [10] 陈果, 杨默晗, 于平超. 基于深度学习的航空发动机不平衡故障部位识别[J]. 航空动力学报, 2020, 35(12):2602-2615.
- CHEN Guo, YANG Mohan, YU Pingchao. Recognition of aero-engine imbalance fault location based on deep learning[J]. Journal of Aerospace Power, 2020, 35(12):2602-2615. (in Chinese)
- [11] 钟诗胜, 李旭, 张永健. 基于DBN的不均衡样本驱动民航发动机故障诊断[J]. 航空动力学报, 2019, 34(3):708-716.
- ZHONG Shisheng, LI Xu, ZHANG Yongjian. Fault diagnosis of civil aviation engine driven by unbalanced samples based on DBN[J]. Journal of Aerospace Power, 2019, 34(3):708-716. (in Chinese)
- [12] 李坤伦, 魏泽发, 宋焕生. 基于SqueezeNet卷积神经网络的车辆颜色识别[J]. 长安大学学报(自然科学版), 2020, 40(4):109-116.
- LI Kunlun, WEI Zefa, SONG Huansheng. Vehicle color recognition based on SqueezeNet convolutional neural network[J]. Journal of Chang'an University (Natural Science Edition), 2020, 40(4):109-116. (in Chinese)
- [13] BOUVRIE J. Notes on convolutional neural networks[J]. Neural Nets, 2006, 10(6):43-51.
- [14] 余志锋, 熊邦书, 熊天旸, 等. 基于VMD-CWT和改进CNN的直升机轴承故障诊断[J]. 航空动力学报, 2021, 36(5):948-958.
- YU Zhifeng, XIONG Bangshu, XIONG Tianyang, et al. Fault diagnosis of helicopter bearings based on VMD-CWT and improved CNN[J]. Journal of Aerospace Power, 2021, 36(5):948-958. (in Chinese)
- [15] SUN Wei, ZHANG Zhenhao, HUANG Jie. RobNet: real-time road-object 3D point cloud segmentation based on SqueezeNet and cyclic CRF[J]. Soft Computing, 2020, 24(8):5805-5818.
- [16] ZHOU Guoxu, ZHAO Qibin, ZHANG Yu, et al. Linked component analysis from matrices to high-order tensors: applications to biomedical data[J]. Proceedings of the IEEE, 2016, 104(2):310-331.
- [17] ALHICHRI H, BAZI Y, ALAJLAN N, et al. Helping the visually impaired see via image multi-labeling based on squeezeNet CNN[J]. Applied Sciences-Basel, 2019, 9(21):1-20.
- [18] 霍爱清, 张文乐, 李浩平. 基于深度残差网络和GRU的SqueezeNet模型的交通路标识别[J]. 计算机工程与科学, 2020, 42(11):2030-2036.
- HUO Aiqing, ZHANG Wenle, LI Haoping. Traffic sign recognition based on SqueezeNet model of deep residual network and GRU[J]. Computer Engineering and Science, 2020, 42(11):2030-2036. (in Chinese)
- [19] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. [2021-06-01]. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.740.6937&rep=rep1&type=pdf>.

(编辑:陈越)