

## 基于卷积神经网络的机械故障诊断方法综述\*

THE REVIEW OF MECHANICAL FAULT DIAGNOSIS METHODS  
BASED ON CONVOLUTIONAL NEURAL NETWORK

吴定海\*\* 任国全 王怀光 张云强

(陆军工程大学石家庄校区, 石家庄 050003)

WU DingHai REN GuoQuan WANG HuaiGuang ZHANG YunQiang

(Campus of Shijiazhuang, Army Engineering University, Shijiazhuang 050003, China)

**摘要** 深度学习善于从海量的数据中挖掘越来越抽象的特征并具有良好的泛化能力,受到了越来越多的研究人员的关注,而卷积神经网络(Convolutional Neural Network, CNN)则是其深度学习中一种经典而广泛应用的架构,在计算机视觉、目标检测、自然语言处理、语音识别等领域成效显著。在详细分析机械系统故障诊断的现状和需求的基础上,首先介绍了CNN的典型结构,然后从数据输入类型、网络结构设计、迁移学习等方面对CNN在机械故障领域的应用进行了归纳总结,研究CNN应用的深层次特征提取与可视化等问题,最后,分析机械故障诊断中存在的困难,并展望了CNN在机械故障诊断领域应用中待研究解决的若干问题。

**关键词** 深度学习 卷积神经网络 大数据 状态监测 故障诊断 迁移学习 特征提取

**中图分类号** TP277 TH17

**Abstract** Deep learning is good at abstract features from massive data and has good generalization ability, which has attracted more and more researchers' attention. The Convolutional Neural Network (CNN) is a classic structure of deep learning and which is being widely and successfully used in the fields of computer vision, target detection, natural language processing, and speech recognition. Based on a detailed analysis of the current status and needs of mechanical system fault diagnosis, this paper introduces the structure of CNN, and summarizes the application of CNN in the field of mechanical faults from the aspects of input data type, network structure design and migration learning. The problems of deep feature extraction and visualization are also discussed, and finally, the difficulties in mechanical fault diagnosis are analyzed and several problems to be solved in the field of mechanical fault diagnosis based on CNN are prospected.

**Key words** Deep learning; Convolutional neural network; Big data; Condition monitoring; Fault diagnosis; Transfer learning; Feature extraction

*Corresponding author: WU DingHai, E-mail: wudh81@163.com*

The project supported by the National Natural Science Foundation of China (No. 51305454).

Manuscript received 20190513, in revised form 20190916.

## 引言

机械故障诊断技术是监测、诊断和预示连续运行机械设备的状态和故障,保障机械设备安全运行的一门科学技术,对于保障设备安全运行意义重大<sup>[1]</sup>。机械设备一旦发生故障将导致巨大的经济损失,对设备实施实时的状态监测,能够保证设备安全运行、降低维护费用和预防重大事故的发生<sup>[2]</sup>。

许多学者对机电液系统故障检测和诊断开展了众多方法研究,可概括为三大类:基于模型的方法、基于知识推理的方法和基于数据驱动的方法

法<sup>[3]</sup>1735-1750<sup>[4]</sup> [5]1-17<sup>[6]</sup> [7]1-10<sup>[8]</sup> 5990-5998<sup>[9-10]</sup>。基于模型的方法通过构建数学模型来探寻对象运行规律,通过研究故障状态下动力学参数与响应征兆的内在联系,获取运行正常与异常关联信息的方法,适用于具备过程精确的定量数学模型。基于知识推理的方法不需要建立精确的系统模型,它根据系统原理知识、人们长期的实践经验和积累的故障信息进行计算推理和诊断,如基于故障树的推理、专家系统等。然而,装备越来越复杂,建立精确的数学模型变得非常困难,基于数据驱动的诊断方法在不需要了解系统的学习及物理模型的情况下,仅利用可测得的状态监测信号或结合历史数据

\* 20190513 收到初稿, 20190916 收到修改稿。国家自然科学基金项目(51305454)资助。

\*\* 吴定海, 男, 1981年生, 福建南靖人, 汉族, 陆军工程大学石家庄校区讲师, 博士, 主要从事装备状态监测与智能信号处理研究。

进行分析并提取特征信息,从而实现系统的故障诊断和性能评估。基于数据驱动的方法无需建立精确的复杂系统模型,也无需大量的领域专家知识和知识的表达推理机制,但是通常需要大量准确的数据。

现代状态监测技术已经能够实现对复杂装备多测点、全寿命的数据采集,进而获得海量的数据,致使机械健康监测进入了“大数据”时代<sup>[11]</sup>。而研究和利用先进的理论与方法,从机械装备大数据中挖掘信息,高效、准确地识别装备健康状态,成为机械装备大数据健康监测面临的新问题。从本质上看,故障诊断与性能退化评估是对系统故障模式和状态演化进行认知的过程,认知能力的好坏直接影响诊断评估的效果。在数据处理方面,2006年,HINTON G E等在《Science》上发表文章,首次提出了深度学习的概念<sup>[12]</sup>,掀起了新一轮人工智能及应用的研究热潮,深度学习理论被评为2013年十大突破性技术之首。微软、Google和百度等著名机构意将其成功应用在图像处理、语音识别、目标检测、信息检索、自然语言处理等领域,取得了突破性的进展<sup>[13]</sup>。深度学习旨在通过模拟大脑的学习过程,以层次化的信息表达并结合海量的训练数据,对更高阶的本质特征的信息提取,并逐层进化特征传递,实现信息的认知计算。基于深度学习的状态监测与诊断,就是利用大数据来学习特征,从而刻画数据丰富的内在信息,最终提升分类或预测精度。

在机械健康监测领域,深度学习的研究与应用尚处于起步阶段。相比传统的机器学习故障诊断方法,深度学习通过所建立的深层次模型能够以原始信号作为输入,实现端到端的故障诊断,克服了传统方法的以下不足:①在特征提取方面,需要复杂的信号处理技术和领域专家经验,提取的往往是浅层故障特征,受人为主观因素影响较大;②在模型训练方面,没有综合考虑特征提取和诊断环节,模型训练没有实现最优化;③传统方法面向有限数据样本,大数据背景下,模型的学习能力及泛化性能明显不足,难以满足需求。

CNN是深度学习中一个典型的网络,被广泛应用于视觉与语音处理,出现了如LeNet-5, AlexNet, VGG, ResNet, GoogleNet等经典网络<sup>[14][1904-1916][15]</sup>,尤其是采用CNN为核心技术的“人机围棋大战”——Google AlphaGo成功案例让人印象深刻。CNN在上述领域的成功运用,主要源于其模型结构和训练方式上的优势<sup>[16][17][1429-1445]</sup>:①以多层卷积变换为核心的多层次结构具有更强的非线性特征提取能力;②“特征学习”直接面向模式识别,实现特征提取、选择和分类器是联合优化的;③训练时,首先以大样本进行“逐层无监督贪婪学习”,以数据驱动进行参数的自适应调节,然后以小样本进行“整体有监督微调”,实现人类认知

对于网络学习的整体修正。

本文在介绍CNN的基本框架和工作原理的基础上,分析了CNN网络的特点和优势,总结了网络结构设计和网络训练方面的技巧,并且从模型数据输入方式、迁移学习和信息融合三个角度综述了目前CNN网络在机械故障诊断中的研究现状和应用情况,并进一步论述了CNN网络的深层次特征提取与可视化问题的实现方式,并探讨了未来CNN网络在实现机械系统故障诊断存在的困难和挑战,展望了该领域未来值得继续深入研究的方向。

## 1 CNN的网络结构与与设计

### 1.1 CNN基本网络结构

CNN是一个典型的深度前馈人工神经网络,受到生物学感受机制的启发,一般由卷积层、池化层和全连接层等组成,如图1所示。其实质是构建多个能够提取输入数据特征的滤波器,通过这些滤波器对输入数据进行逐层卷积及池化,逐级提取隐藏在数据之中的拓扑结构特征,随着网络结构层层深入,提取的特征也逐渐变得抽象,最终获得输入数据的平移、旋转及缩放不变的特征表示。其主要特征是结合稀疏连接、权重共享、空间或时间上的降采样。稀疏连接通过拓扑结构建立层与层之间非全连接空间关系来降低训练参数的数目;权重共享能够有效地避免算法过拟合;子采样充分利用数据本身包含的局部性等特征,减少数据维度,优化网络结构,且能保证在一定程度上位移不变性。因此非常适合海量数据的处理与学习。




图1 CNN的基本网络结构

Fig.1 The basic network structure of CNN

#### (1) 卷积层

卷积层是CNN的核心组成部分,卷积操作的公式表达如下

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} * \omega_{ij}^l + b_j^l\right) \quad (1)$$

式中,上标 $l$ 表示对应网络中的第 $l$ 层; $i, j$ 分别表示第 $l$ 层和第 $l-1$ 层中特征图的序号; $M_j$ 表示与第 $l$ 层第 $j$ 个特征图相连接的第 $l-1$ 层中的特征图; $\omega_{ij}^l$ 表示第 $l$ 层第 $j$ 个特征图对应第 $l-1$ 层第 $i$ 个特征图输入的卷积核参数; $b^l$ 表示偏置;\*表示卷积操作。

#### (2) 池化层

池化层一般位于连续的卷积层中间,池化层能够

逐渐减小表达空间的尺寸,降低网络参数和计算量,也能起到控制过拟合的作用。池化层包括最大池化和平均池化,近年来最大池化被普遍证明有更好的效果而被广泛采用

$$x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l) \quad (2)$$

式中,down( $\cdot$ )表示次抽样函数,主要为了缩小特征图的尺寸; $\beta_j^l$ 和 $b_j^l$ 表示第 $l$ 层中权重和偏置。

### (3) 激励层

激活层主要用于把卷积层输出结果做非线性映射,主要有 $\text{relu}$ 、 $\text{sigmoid}$ 、 $\text{tanh}$ 等函数,其中 $\text{relu}$ 整流线性单元,在神经网络中被广泛采用,具有非线性的特点,使得信息整合能力大大增强;在一定范围内又具有线性的特点,使得其训练简单、快速

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (3)$$

$$\text{relu}(z) = \begin{cases} 0 & z < 0 \\ z & z \geq 0 \end{cases} \quad (4)$$

式中, $z$ 表示神经元线性仿射变换结果。

### (4) 全连接层

全连接层通常位于CNN的尾部,是指两层之间所有神经元都有权重连接,也就是和传统的神经网络的连接是一样的。 $\text{Softmax}$ 通常应用于多分类问题的输出层,保证所有输出神经元之和为1,而每个输出对应的 $[0, 1]$ 区间的数值就是该输出的概率,在应用时取概率最大的输出作为最终的预测。

## 1.2 CNN 结构设计

CNN网络模型的构建可以通过卷积层、激活层、池化层和全连接层交叉堆叠而成,进而形成不同的诊断模型。增加模型的深度(层数)或者是其宽度(卷积核数或者神经元数)可以提高网络的性能,但容易出现以下问题:①在训练数据集有限条件下,参数太多容易导致过拟合;②网络越大,参数越多,计算量和复杂度越大,导致模型难以应用;③网络越深,容易出现梯度消失问题,模型难以优化。

然而,如何构建网络以及怎样实现网络的最优化,目前还没有成熟的方法,研究人员只能通过经验或试验的方式进行构建,具有以下特点:

(1)卷积层的使用。卷积层虽然显著减小网络中连接的数量,但是输出的特征图中神经元个数并没有明显减少,若直接连接全连接层,参数个数依然非常大,容易出现过拟合现象;卷积核的数量越多,产生的特征图越多,计算量越大。

(2)激活层的使用。激活层一般置于卷积层之后,把卷积层输出结果做非线性映射,目前主要都是采用 $\text{relu}$ 函数,该函数很大程度的解决了优化神经网络时的梯度耗散问题。

(3)池化层的使用。池化层后通常加卷积层之后,用于降低特征维数,池化对特征图的每个局域进行下采样,作为这个区域的概括,减低参数的同时提高了局部不变性。

(4)使用更小的卷积核,如图像处理常用的 $3 \times 3$ 或 $1 \times 1$ 卷积核,CNN向更深的层次发展( $L > 50$ ),即增加层数而非增大卷积核的数量。

(5)卷积的操作越来越灵活,同时结合卷积步长的使用,使得池化的作用越来越小,卷积网络中池化层比例下降,甚至出现了全卷积网络。

## 1.3 CNN 网络学习训练技巧

要想获得理想的诊断效果,研究人员应掌握一些CNN的学习训练技巧。如构建网络时应遵循上述经验规则,选择特征时应选择具有代表意义的特征,避免重复性、干扰性和复杂性信息。选择合适的网络训练方式,如Adam、SGD、Momentum、NAG、Adagrad、Adadelta、Rmsprop等。训练网络时应防止过拟合,可运用增加数据量、正则化以及Dropout等方法。

### (1) 归一化

对于机械故障诊断,不同维度特征尺度一般相差很大,会导致代价函数的等高线狭长,梯度下降震荡进行,收敛速度变得很慢,因此,需要对输入数据和各层间的数据机械批量处理。常用的就是Batch normalization去均值,把输入数据各个维度都中心化;归一化是将幅值归一化到相同的范围,归一化的目的就是减少各维度数据取值范围的差异而带来的干扰,保证非线性和不同层相对独立,每一层可以专注解决本层的问题,每一层的值在有效的范围内传递下去,同时提高学习效率,避免梯度消失或溢出,加速收敛。

### (2) Dropout 技术

在CNN模型训练和测试时,针对某一CNN网络,当迭代次数增多时,常出现网络对训练集拟合的很好,但是对验证集拟合的程度很差的情况,这是该网络出现的过拟合现象。如图2所示,Dropout是一种防止CNN模型过拟合的技术,简单实用,其基本思想为训练时让每一层的神经元以一定的概率随机丢弃(Dropout)部分神经元,使其不被激活,将这个子网络作为此次更新的目标,因此,每次迭代更新,使用的子网络基本上不会重复,从而避免了某一个网络被过分的拟合到训练集上。这就可以让模型不太依赖某些局部特征,这样可以使模型更鲁棒。Dropout有的被放置在输入层,如文献[18],有的被放置在全连接层,都能够取得较好的效果。

### (3) 学习率

学习率是控制网络学习速率,控制梯度下降速度的一个关键参数。如果学习速率过小,则会导致收敛




图 2 Dropout 原理示意图

Fig.2 The schematic diagram of dropout

速度很慢。如果学习速率过大,则会阻碍网络训练收敛,即在极值点附近发生振荡,因此,通常会控制学习率使其在多次迭代后衰减,使得网络顺利收敛。

## 2 基于 CNN 的机械故障诊断方法

CNN 最初主要被用来处理二维图像,由于具有强大的认知计算能力,学者开始将其引入到机械故障诊断领域,能够很好地表征信号与机械健康状态之间复杂的映射关系,提高大数据背景下多样性、非线性、高维健康监测数据诊断分析能力<sup>[19-22]</sup>。

### 2.1 CNN 的数据输入类型

#### (1) 一维信号整合成二维矩阵

对于机械故障诊断,所采集的主要是一维的振动信号等,如何将一维的信号转换成二维信号,进而使用 CNN 来诊断便是许多学者研究的问题。WEN L 等<sup>[8]5990-5998[23]</sup>将所采集到的一维振动信号通过滑动窗的方式截取一段长度为  $1 \times M^2$  的数据样本,然后按顺序排列成  $M \times M$  的二维矩阵具体转化方法如图 3 所示。

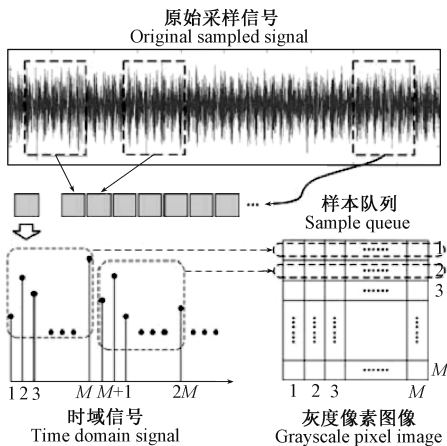


图 3 一维信号转化成二维图像矩阵

Fig.3 The conversion of one dimension signal to image

将一维数据转化成矩阵后,再按下列公式将其转化成为灰度,进而成为灰度图像,便可用常用的 CNN 进行分类识别了。

$$P(j, k) = \text{round} \left\{ \frac{L((j-1)M+k) - \min(L)}{\max(L) - \min(L)} \times 255 \right\} \quad (5)$$

这种数据预处理方法简单,计算量小,振动信号的峰值转化成每一行的灰度值,造成转换后的图像较为接近,很难区分,运用 CNN 进行训练时所需训练时间长,分类识别的精度有限。

#### (2) 信号变换实现二维图像的转换

为了研究更好地将机械振动信号转化成为二维图像,学者研究运用不同的信号处理方法对一维机械振动信号进行分解或变换。对于机械故障诊断,最为常用的分析方法是时频分布,通过时频变换的方法可以获得振动信号的二维时频分布图像,常用的时频分析方法有短时傅里叶变换、连续小波变换、S 变换、Hibert-Huang 变换、Wigner 分布等。例如 GUO S 等<sup>[17]1429-1445</sup>提出了一种基于 CWT 和 CNN 的机械故障诊断方法,首先对振动信号做连续小波时频分布,提取完整周期的时频图,然后再用训练多个 CNN 进行分类识别。Verstraete D 等<sup>[5]3-15</sup>运用短时傅里叶变换 STFT、HHT 和小波分析的方法获取了时频分布图像,并将时频分布图像整合成  $32 \times 32$ 、 $96 \times 96$  两种格式,分别测试了两种输入的诊断精度。

第二种方法是将信号分解成多个分量,然后再将这些分量组成图像矩阵,常用的方法有小波变换、VMD、EMD 等方法<sup>[3]1735-1750[7]1-10</sup>。SUN W F 等<sup>[24]</sup>将双树复小波分解后的多尺度小波系数组成图像,再用 CNN 进行分类。例如 LIU C 等<sup>[25]</sup>, LI Y 等<sup>[3]1735-1750</sup>利用变分模态分解 (Variational Mode Decomposition, VMD) 对行星齿轮箱振动信号进行分解,分解成具有中心频率的独立窄带宽的 4 个分量,然后再将其转化成频谱,进而再整合成矩阵作为 CNN 的输入。

上述通过信号变换的方式实现一维信号向二维图像的转换方法中,时频分布无疑是最为常用和有效的方法。时频分布能够提供时间域和频率域的联合分布信息,能够更好地凸显信号表征与机械健康状态的关系,有利于 CNN 的训练和识别,然而时频分布计算量大,图像分辨率高,输入 CNN 的数据量也大大增加,计算量大。利用小波变换、VMD 等对原始信号进行处理时,虽然能够对故障分量进行分离,并凸显故障特征,但分解过程中存在一定的频率混迭现象,中间处理过程难免造成了信息的丢失,均会对诊断精度造成一定的影响。

#### (3) 一维信号直接输入

机械信号一般只与时间有关系,而图像涉及二维空间位置关系,两者具有本质的区别。CNN 具有强大的信号处理分析功能,如果直接将测得的一维信号直接作为输入,则整合了传统的信号降噪、特征提取、特征选择和故障分类等流程,直接实现了点到点、端到端的故障诊断,最大程度地简化故障诊断的流程。

在 CNN 中要实现一维信号的输入,需要对 CNN 的网络结构进行改变,卷积核也应采用一维的卷积核。许多学者尝试了该方法,构建了一维 CNN 网络结构并运用于机械故障诊断,取得了不错的效果。JING L 等<sup>[26]</sup>以频谱信号作为 CNN 网络的输入,并运用于行星齿轮箱的故障诊断。ZHANG W 等<sup>[27]</sup><sup>439-453</sup>研究了变负载条件下的基于 CNN 的齿轮箱故障诊断,建立了一个含 6 卷积层的 14 层 CNN 网络。LIU R 等<sup>[28]</sup>针对机械故障诊断非平稳信号时间序列数据之间的相关性,对 CNN 增加了一个 Dislocate Layer,构建 DTS-CNN 模型,学习深层次故障特征,对变速过程的诊断也具有较好的效果。为了提高基于 CNN 的机械故障诊断效果,学者尝试采用对输入信号添加噪声干扰的方式,来提高 CNN 故障诊断模型的鲁棒性。

## 2.2 基于 CNN 的迁移学习故障诊断方法

### (1) 迁移学习的概念

传统机器学习可以通过大量有标记的数据样本进行训练,进而挖掘数据内部的规律,实现基于监督学习的数据分类和预测。首先,这个学习过程需要有大量已标注训练样本的支持,如果没有大量的标注样本,传统机器学习方法的研究与应用则无法开展;其次,传统机器学习假设训练数据与测试数据服从相同的数据分布。只有满足上述两个前提,传统机器学习方法才能有效的工作。然而,现实情况是在一些特定领域中,大量的训练数据非常难得到,训练与测试数据的同分布假设并不能得到满足,以及网络训练需要耗费大量的计算资源,需要有高性能的服务器平台。

针对上述困难,迁移学习提供了一种解决问题的新方法,它放宽了传统机器学习中的两个前提要求,允许迁移已有的知识来解决目标领域中仅有少量已标注样本数据的学习问题,也就是运用已有的知识对不同但相关领域问题进行求解。迁移学习(Transfer Learning)的目标就是将从一个环境中学到的知识用来帮助新环境中的学习任务<sup>[29]</sup>。迁移学习可定义为:给定一个源领域  $D_s$  和学习任务  $T_s$ , 一个目标领域  $D_T$  和学习任务  $T_T$ , 迁移学习的目的是使用  $D_s$  和  $T_s$  中的已有知识,其中  $D_s \neq D_T$  和  $T_s \neq T_T$ , 帮助提高目标领域  $D_T$  中目标预测函数  $f_T(\cdot)$  的学习。

### (2) CNN 网络的迁移学习

CNN 网络被成功应用于图像识别领域,出现了如 AlexNet 等许多经典网络模型,都需要使用大规模图像数据集进行训练,由于样本和参数的数量都十分庞大,即使使用 GPU 加速化也会花费较长的训练时间,这是研究人员所无法接受的。但 CNN 体系结构的另一个优势便是经过预训练的网络模型可以实现网络结构与参数信息的分离,并都以配置文件的方式进行保存,这

一特点极大地方便了广大研究者。只要网络结构一致,便可以利用已经训练好的权重参数构建并初始化网络,极大的节省了网络的学习时间。

基于迁移学习的理论,对上述几种经典 CNN 网络进行适应性改造,将学习得到的网络模型和参数应用到新任务的小样本数据集上,进行网络微调,便可得到一种新的深度图像卷积特征,该特征具有强大的语义表示能力,只需要线性分类器,即可对测试图像样本进行分类标注。LI Y 等<sup>[3]</sup><sup>1735-1750</sup>, WEN L 等<sup>[8]</sup><sup>5990-5998</sup>, TRA V 等<sup>[30]</sup>对行星齿轮箱的诊断以图像作为输入,采用 LeNet-5 进行迁移学习。

## 2.3 基于 CNN 的多传感器信息融合故障诊断

随着监测对象越来越复杂,状态监测信号呈现非线性、时变性、不确定性等特征,当系统发生故障时,常常表现出多种征兆,仅仅依靠单一的理论方法和信息就难以对故障做出精确的判断,出现令人难以接受的高几率虚警、漏报等现象。

多源信息融合(Multi-Source Information Fusion, MSIF)技术就是利用计算机技术,对来自多种信息源的多个传感器观测的信息,在一定准则下进行自动分析、综合,以获得单个或单类信息源所无法获得的有价值的综合信息处理技术<sup>[31-32]</sup>。多源信息融合技术的研究目标是利用多个传感器优化组合的优势,提高系统故障诊断精度,一般包括数据级融合,特征级融合和决策级融合三个方式。多传感器信息融合要求所采集的信号是同步采集,同时这些信号对所诊断的故障都具有关联性。

### (1) 数据级融合

数据级融合是直接对传感器的采集数据进行融合处理,然后基于 CNN 网络进行训练和故障诊断。数据层的融合主要是对 CNN 网络的输入信号进行处理,例如振动加速度信号、声发射信号、扭矩信号、瞬时转速信号等,对信号攫取相同长度的片段,然后采用并联或串联的方式进行排列。采用并联方式时,多个传感器信号被整合成一张图像,则以图像的方式作为 CNN 网络的输入,见文献<sup>[33]</sup>;采用串联方式时,多传感器信号被整合为一维信号,以一维信号作为网络的输入,见文献<sup>[34]</sup>。数据级融合的优点是数据量的损失最少,能够提供数据层中的细微信息,精度最高,但是计算量大。

### (2) 特征级融合

特征级融合属于中间层次的融合,采用信号处理方式对每个传感器信号先提取出各自的特征向量,然后 CNN 网络完成特征向量的融合处理。利用现有的信号处理方法提取时域、频域、时频域等多维特征,然后再组合成二维图像或一维信号,进而再使用 CNN 进行训练和分类识别,如文献<sup>[7]</sup><sup>1-10</sup>。特征级融合的优点

点在于实现了数据压缩,降低了计算量,有利于实时处理。但由于损失了一部分有用信息,与数据级融合相比,融合性能有所降低。

(3) 决策级融合

决策级融合是高层次的融合,构建多个 CNN 网络实现对每个传感器先作出决策,然后在融合中心完成局部决策的融合处理。该方法一般需要结合 D-S 证据理论来实现决策级的融合<sup>[35]</sup>。决策级融合的优点是具有很高的灵活性,抗干扰能力强,传感器可以是同质的也可以是异质的,当一个或几个传感器出现错误时,通过适当的融合,系统仍能获得正确结果。但是由于数据损失最多,融合精度较其他两级融合要低。

3 基于 CNN 的深层次特征提取与可视化问题

特征是机器学习系统的原材料,对模式识别结果的影响是毋庸置疑的。如果数据被很好的表达成了特征,通常线性模型就能达到满意的精度。传统的特征提取方法需要依靠专家的领域知识,专业性强,而深度学习可以从原始数据中自动学习良好的特征,而免去人工选取过程,具有良好的优势。

3.1 基于 CNN 的深层次特征提取

CNN 是如何提取特征以及提取什么样的特征呢?对于图片而言,像素级的特征根本不具备分类的价值。通过研究发现复杂图形往往由一些基本结构组成,一张图可以用 64 种正交边缘来线性表示,图片的特征表示是层次递进的,高层表达由底层表达的组合而成。不仅图像存在这个规律,声音也存在,研究人员发现语音信号可以由 20 种基本结构组成。

CNN 就是根据层次的特征构建,由浅入深。卷积层是 CNN 的核心,通过不同的卷积核,来获取不同层次次的图片特征。卷积核相当于一个滤波器,不同的滤波器提取不同特征。但每一层该有多少个特征呢?任何一种方法,特征越多,给出的参考信息就越多,准确性会得到提升。但特征多意味着计算复杂,探索的空间大,可以用来训练的数据在每个特征上就会稀疏,都会带来各种问题,并不一定特征越多越好。

一个 CNN 可能构建多个卷积层,每一个卷积层提取不同层次的特征,上一层的特征图由下一层的特征组合而来,也就是说随着 CNN 的层层深入,所提取的特征图更加结构化,更基础。而各层的特征图都是通过原始测试数据训练迭代的过程中进行学习得到。ZHANG W 等<sup>[27]</sup><sup>439-453</sup>利用西储大学的轴承试验数据对所建立的 CNN 模型进行训练,第一卷积核长度设置为 64,图中即为训练完毕后第一卷积层中卷积核提取的特征。然而,对于故障诊断而言,上述特征是否就是我们想要的特征或是轴承振动信号的基本构成还不能确定,对于 CNN 机械故障诊断网络,想要获得振动信号的基本构成,一是需要足够量的大数据进行训练作为前提,二是需要明确哪一层特征图具有最佳的表征能力。

3.2 CNN 可视化问题

基于 CNN 的故障诊断模型,其诊断过程就像是一个黑箱,给其输入数据,经过训练后可直接给出所要的分类识别结果。人们难以理解 CNN 内部运行的机制,可解释性差,故有许多学者研究 CNN 的可视化问题<sup>[14]</sup><sup>1904-1916</sup><sup>[36-37]</sup>。

目前基于 CNN 网络的可视化研究主要基于三个方面。一是查看各层激活情况。根据 CNN 网络的架构,为了提高非线性分析能力而增加了激活层,通过函数命令则可查看各激活层的神经元状态,对于一个被良好训练的 CNN 网络,其各层的神经元应具有更多的被激活的神经元,这使得该网络可以用更多的神经元来描述输入的信号。二是 CNN 各卷积层所提取的特征。CNN 经过大数据的训练后能够有效地分析信号规律,通过不同的卷积层来层次化表征数据特征,研究人员可以直接提取任一卷积层的特征并进行可视化,特征的数量根据所设置的卷积核的数量而定。三是特征分布情况的可视化。虽然 CNN 的各层都能够提取信号特征,实现深层次的特征表达,但是哪一层的特征才是最优的并具有可分类性,这就需要用到 t-SNE 工具,t-SNE 是基于主元分析的方法对各层的特征进行降维,如图 4 所示,可以实现 2 维或 3 维的方式进行直观的显示,有利于研究人员对所构建的 CNN 网络性能

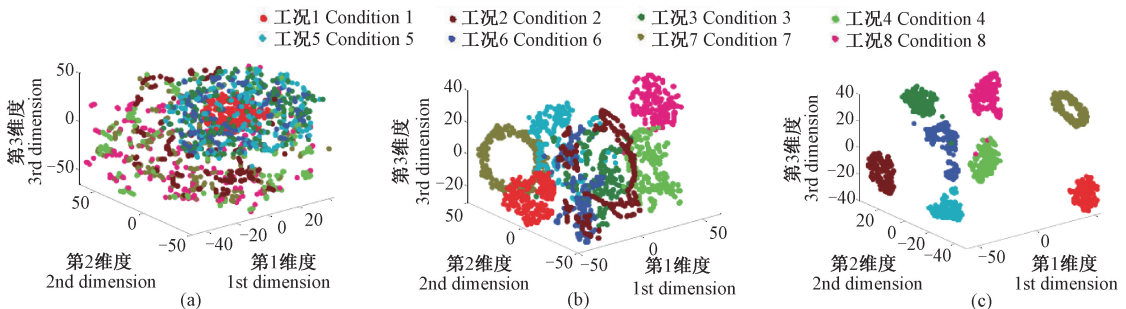


图 4 基于 t-SNE 的各层特征可视化

Fig.4 The feature visualization based on CNN and t-SNE

分析和特征选择。

## 4 基于 CNN 的机械故障诊断所面临的困难和挑战

### 4.1 机械故障诊断存在的困难

CNN 作为深度学习中最为重要、典型的网络之一,被引入到机械故障诊断领域,虽处于起步阶段,但研究和应用已初见成效,然而机械故障诊断领域有其自身的特点和困难:①机械系统呈现大型化和复杂化,一般由多个子系统、部件、零件组成,形成功能、故障和征兆具有不同的层次性;②故障状态呈现多样性,单一故障与复合故障并存,一种故障可能对应多个征兆,一种征兆可能对应多个故障;③故障信号呈现复杂性,由于传递路径复杂,信号呈非线性、非平稳、故障特征微弱等特点;④正常工况数据海量而故障数据缺乏和故障模式不完备等问题并存;⑤故障数据呈不确定性。测试数据容易受测试环境影响、背景噪声干扰,使得系统故障和征兆具有随机性、模糊性和不确定性等特点。基于上述的机械故障诊断领域所面临的难点问题,研究人员需要继续深入研究机械系统故障机理,探索 CNN 在机械故障诊断领域的适应性。

### 4.2 基于 CNN 的机械故障诊断展望

随着信息化技术的发展,状态监测系统已经能够实现大型复杂机械系统进行多测点、高采样频率的全寿命数据采集,进而获取海量的状态监测数据。仅依靠专业技术人员和诊断专家来手动分析很不现实,需要研究智能方法进行自动分析。基于 CNN 的机械系统故障诊断还有很多问题亟待研究和解决。

#### (1) 基于数据不平衡问题的 CNN 故障诊断

深度学习是以“大数据”为基础,从而实现“见多识广”的能力。拥有“海量”的状态监测数据是研究基于 CNN 机械系统故障诊断的前提<sup>[38]</sup>。目前,在故障诊断研究领域,基于试验台的测试数据多,基于工业系统的实测数据少;实验室模拟的故障数据多,实际发生的故障数据少;机械状态监测普遍存在这样一个难题,在对机械系统进行状态监测时,可以容易地获得海量的正常工况状态监测数据,而故障工况数据难以获取和捕捉,从而导致数据样本的极度不平衡,给机械系统故障诊断带来困难。因此,需要基于上述的现实情况,研究基于 CNN 的故障诊断模型来解决故障数据不平衡情况下的机械系统故障诊断。而 CNN 网络又需要大量的训练样本,两者看似不可调和的矛盾,笔者认为,可以用两种办法来解决,一是研究基于 CNN 网络的机械系统异常监测,即分两步走,实现检测与运行状态的异常,在积累一定故障数据量后采用增量学习的方法来提升 CNN 诊断系统实现故障模式的识别;二是

采用强化学习的方法,对目前少量的故障数据进行强化学习。

#### (2) 基于半监督学习的 CNN 故障诊断网络

在现代测试技术条件下,海量的状态监测数据容易获取,然而数据标记则需要专家知识,费时费力且代价高昂,因此获取高质量的标记数据往往非常有限,容易得到的通常是大量正常数据和少量异常数据混杂在一起的不纯净数据集,因此如何在数据集不纯净的条件下提升故障诊断性能成为该领域亟需解决的问题。如何利用大量的未标识样本来改善分类器的性能是当前机器学习研究中最受关注的问题之一。半监督学习是介于监督学习和无监督学习之间的学习模型,能够同时利用少量标识样本和大量未标注样本信息,从而获得更好的分类性能。因此,在现有条件下,充分利用未标记数据样本,研究基于半监督的 CNN 故障诊断方法,是今后基于 CNN 的机械故障诊断研究的一个方向。

#### (3) 基于 CNN 的深层次特征提取稳定性研究

目前的机械故障方法大多是基于单一运行工况(稳态或恒速)条件的假设。复杂的机械系统的故障诊断往往容易受到其复杂运行工况的影响,若不考虑复杂工况,将会极大地降低故障诊断或性能评估的准确性。因此,挖掘机械系统运行工况与状态监测信号之间的内在联系,寻求故障特征的稳定有效表征方法,是机械故障诊断领域未解决的难题。基于 CNN 网络,研究人员已经构建出图像和语音的基本构成元素,而针对机械故障诊断的特点,结合海量的机械状态监测数据,运用 CNN 研究机械故障诊断深层次稳定性特征提取,是今后值得深入研究的课题。

#### (4) CNN 与基于知识的推理相结合

基于 CNN 故障诊断是基于数据驱动的方法,以海量数据样本的学习为基础,而在实际工程应用中,正常样本多而故障样本少,测试的数据不可能囊括所有的故障模式。所监测对象往往具有复杂的结构、多子系统或部件,相互之间具有层次性和关联性,要想实现全面的状态监测需面临多测点、多数据类型和复杂的关联性,实现全系统故障诊断难度大。在这种情况下,基于数据驱动的 CNN 故障诊断模型使用必将受限。而设备在设计之后,具有该机械设备的构造、组成、基本工作原理和可靠性分析等领域的专家知识,结合适当的测试数据,便能够实现基于知识推理的故障诊断。CNN 模型的可视化和可解释性差,而基于语义分析的 LSTM 网络诊断能力不足,因此,若能够将数据驱动和知识推理相结合,将深度学习中的基于数据推理的 CNN 网络和基于语义分析的 LSTM 等网络相结合,发挥混合模型的优势,必将大大提高机械故障诊断的性

能和智能化水平。

#### (5) 基于 BIT 的小型低功耗 CNN 故障诊断模型

CNN 网络虽然在图像、视频、语音等领域得到成功应用,但是其需要海量的数据规模,需要的计算资源较多,动辄就是云计算和高性能的服务器,对硬件要求高,计算资源消耗大,在一定程度上影响了深度学习在工业在线监测中的应用。基于 CNN 的故障诊断系统,存在“移动设备算不好、嵌入式设备算不了、服务器算不起”的尴尬局面。显然,这种状态离工程应用还有很长的一段路要走,需要深入研究人脑智能的认知计算原理,对 CNN 网络进一步的优化设计以及参数的优化调整,摒弃暴力计算,基于“乌鸦”模式,解决“小数据、大任务”的在线学习自主智能,研究一种适合于嵌入式状态检测和低功耗硬件平台的 CNN 诊断模型,提升在线状态监测和故障诊断的适用性。

#### (6) CNN 诊断系统在同类型设备的迁移应用

传统的基于机械学习的机械故障诊断系统一般适合于特定对象,严重制约了故障诊断系统的推广应用。CNN 故障诊断系统的成功运用,需要经过充足的故障样本数据的训练。对每一台设备都开展大量的故障试验显然不现实。因此,为实现 CNN 故障诊断系统在同类型或相似机械装备之间的有效利用,需深入研究迁移学习的基本理论,开展相同类型或相似机械设备之间故障诊断模型或故障数据的可迁移性分析。为实现故障数据的有效利用,分析数据可迁移性,研究如何基于已有设备大量故障样本数据和相似设备有限样本数据条件下,通过相互重构,映射到某个共享特征空间,实现样本数据缺失设备的故障模式自主认知。分析故障诊断模型的可迁移性,通过训练后的 CNN 故障诊断模型与少量同类型或相似设备的故障数据的迁移训练学习,实现 CNN 故障诊断系统在机械故障诊断领域的推广应用。

## 5 结论

CNN 作为一种典型的深度学习网络,以深度学习理论为代表的从人脑信息处理机制去研究高级认知的方法,在机械故障诊断领域的研究和应用越来越受重视,CNN 通过多层多个卷积核的方式实现对输入信号的滤波和特征提取,多个卷积核增加了特征的多样性,多层卷积的方式提高了特征提取的深度和稳定性,结合权值共享的运算简化和激活函数的非线性处理能力,能够很好地处理 2-D 图像和 1-D 时间序列信号,在机械系统的故障诊断领域具有良好的运用前景。然而,CNN 纵然有很多优点,但是它是基于海量数据的训练学习,带来的问题就是特征维度和计算量剧增,针对机械系统故障诊断的特点,基于 CNN 的机械故障诊

断仍存在许多问题待研究解决,进而提高其在机械故障诊断领域的适应性。

## 参考文献 (References)

- [ 1 ] 王国防,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 GuoBiao, HE ZhengJia, CHEN XueFeng, et al. Basic research on machinery fault diagnosis-what is the prescription [J]. Journal of Mechanical Engineering, 2013, 49 (1): 63-72 (In Chinese).
- [ 2 ] KHAN S, YAIRI T. A review on the application of deep learning in system health management [J]. Mechanical Systems and Signal Processing, 2018: 241-265.
- [ 3 ] LI Y, CHENG G, PANG Y, et al. Planetary gear fault diagnosis via feature image extraction based on multi central frequencies and vibration signal frequency spectrum [J]. Sensors, 2018, 18 (6): 1735-1750.
- [ 4 ] LIU R, YANG B, Enrico Z, et al. Artificial intelligence for fault diagnosis of rotating machinery: A review [J]. Mechanical Systems and Signal Processing, 2018: 33-47.
- [ 5 ] VERSTRAETE D, FERRADA A, DROGUETT E L, et al. Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings [J]. Shock and Vibration, 2017: 1-17.
- [ 6 ] MORHAIN A, MBA D. Bearing defect diagnosis and acoustic emission [J]. Proceedings of the Institution of Mechanical Engineers Part J-Journal of Engineering Tribology, 2003, 217 (4): 257-272.
- [ 7 ] CHEN ZhiQiang, LI Chuan, SANCHEZ R V. Gearbox fault identification and classification with convolutional neural networks [J]. Shock and Vibration, 2015(4): 1-10.
- [ 8 ] WEN L, LI X, Liang G, et al. A new convolutional neural network-based data-driven fault diagnosis method [J]. IEEE Transactions on Industrial Electronics, 2018 (7): 5990-5998.
- [ 9 ] WANG S, XIANG J W, ZHONG Y T, et al. Convolutional neural network-based hidden Markov models for rolling element bearing fault identification [J]. Knowledge-Based Systems, 2018: 65-76.
- [ 10 ] TAHA M R, NOURELDIN A, LUCERO J L, et al. Wavelet transform for structural health monitoring: A compendium of uses and features [J]. Structural Health Monitoring International Journal, 2006, 5 (3): 267-295.
- [ 11 ] 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 YaGuo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data [J]. Journal of Mechanical Engineering, 2015, 51 (21): 49-56 (In Chinese).
- [ 12 ] CUN Y L, Gio Y B, HINTON G E. Deep learning [J]. Nature, 2015, 521 (7553): 436-444.
- [ 13 ] SCHMID H J. Deep learning in neural networks: An overview [J]. Neural Networks, 2015(61): 85-117.
- [ 14 ] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37 (9): 1904-1916.
- [ 15 ] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Image net classification with deep convolutional neural networks [J].



- Communications of the Acm, 2017, 60 (6): 84-90.
- [16] JIANG G, HE H, YAN J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox [J]. IEEE Transactions on Industrial Electronics, 2018(99): 1-12.
- [17] GUO S, YANG T, GAO W, et al. A novel fault diagnosis method for rotating machinery based on a convolutional neural network [J]. Sensors, 2018(18): 1429-1445.
- [18] ZHANG W, PENG G L, LI C H. Rolling element bearings fault intelligent diagnosis based on convolutional neural networks using raw sensing signal[J]. Advances in Intelligent Information Hiding and Multimedia Signal Processing, 2017(2): 77-84.
- [19] KIRANYAZ S, GASTLI A, BRAHIM L B, et al. Real-time fault detection and identification for mmc using 1d convolutional neural networks [J]. IEEE Transactions on Industrial Electronics, 2018 (1): 10-21.
- [20] EREN L, INCE T, KIRANYAZ S. A generic intelligent bearing fault diagnosis system using compact adaptive 1d cnn classifier [J]. Journal of Signal Processing Systems, 2018: 179-189.
- [21] ABDELJABER O, AVCI O, KIRANYAZ M S, et al. 1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data[J]. Neurocomputing, 2018: 1308-1317.
- [22] EREN L. Bearing fault detection by one-dimensional convolutional neural networks [J]. Mathematical Problems in Engineering, 2017 (8): 1-9.
- [23] HE T, HUANG W L, YU Q, et al. Text-attentional convolutional neural network for scene text detection [J]. IEEE Trans Image Process, 2016(6): 2529-2541.
- [24] SUN W F, YAO B, ZENG N Y, et al. An intelligent gear fault diagnosis methodology using a complex wavelet enhanced convolutional neural network [J]. Materials, 2017(10): 790-808.
- [25] LIU C, CHENG G, CHEN X, et al. Planetary gears feature extraction and fault diagnosis method based on VMD and CNN [J]. Sensors, 2018, 18(5): 1523-1543.
- [26] JING L, 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.
- [27] ZHANG W, LI C H, PENG G L, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load [J]. Mechanical Systems and Signal Processing, 2018(100): 439-453.
- [28] LIU R, MENG G T, YANG B Y, et al. Dislocated time series convolutional neural architecture: An intelligent fault diagnosis approach for electric machine [J]. IEEE Transactions on Industrial Informatics, 2017, 13(3): 1310-1320.
- [29] HU F, XIA G S, HU J W, et al. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery [J]. Remote Sensing, 2015, 7 (11): 14680-14707.
- [30] TRA V, KIM J, KHAN S A, et al. Bearing fault diagnosis under variable speed using convolutional neural networks and the stochastic diagonal levenberg-marquardt algorithm [J]. Sensors, 2017, 17 (12): 2834-2850.
- [31] LIU Y, CHEN X, PENG Z F, et al. Multi-focus image fusion with a deep convolutional neural network [J]. Information Fusion, 2017 (36): 191-207.
- [32] XU X D, LI W Q, RAN Q, et al. Multisource remote sensing data classification based on convolutional neural network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56 (2): 937-949.
- [33] XIA M, LI T, XU L, et al. Fault diagnosis for rotating machinery using multiple sensors and convolutional neural networks [J]. IEEE/ASME Transactions on Mechatronics, 2018, 23(1): 101-110.
- [34] JING L Y, WANG T Y, ZHAO M, et al. An adaptive multi-sensor data fusion method based on deep convolutional neural networks for fault diagnosis of planetary gearbox [J]. Sensors, 2017, 17(2): 414-429.
- [35] LI S B, LIU G K, TANG X H, et al. An ensemble deep convolutional neural network model with improved D-S evidence fusion for bearing fault diagnosis [J]. Sensors, 2017, 17(8): 1729-1748.
- [36] MAHENDRAN A, VEDALDI A. Visualizing deep convolutional neural networks using natural pre-images [J]. International Journal of Computer Vision, 2016, 120 (3): 233-255.
- [37] SCHIRRMESTER R T, SPRINGENBERG J T, FIEDERER D J, et al. Deep learning with convolutional neural networks for eeg decoding and visualization [J]. Human Brain Mapping, 2017, 38 (11): 5391-5420.
- [38] 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(15): 349-367.