

DOI: 10.19650/j.cnki.cjsi.J1905122

# 深度学习在设备故障预测与健康中的应用\*

陈志强<sup>1,2</sup>, 陈旭东<sup>2</sup>, José Valente de Olivira<sup>4</sup>, 李川<sup>3,4</sup>

(1. 重庆工商大学 检测控制集成系统工程实验室 重庆 400067; 2. 重庆工商大学人工智能学院 重庆 400067;  
3. 重庆工商大学 国家智能制造服务国际科技合作基地 重庆 400067; 4. 葡萄牙阿尔加维大学 CEOT 中心 法鲁 葡萄牙)

**摘要:**在智能制造背景下,大数据驱动的设备故障预测与健康管日益受到各界重视。深度学习能够在层次结构的特征提取过程中发现更多的隐藏知识,在领域自适应方面具有良好的数据适应性,近年来逐渐成为设备故障预测与健康管理的热点,并在设备故障诊断和预测中得到了广泛的应用。通过系统回顾近年来深度学习在设备故障预测与健康管理中应用,总结、分类和解释关于这一热点主题的主要文献,讨论了各种体系结构和相关理论。在此基础上,阐述了深度学习在设备故障诊断和预测方面所取得的主要成果、面临的挑战、以及未来的发展趋势,为设备故障预测与健康领域选择、设计或实现深度学习架构,提供明确的方向。

**关键词:**深度学习;故障预测与健康(PHM);故障诊断;剩余寿命预测

中图分类号: TP206.3 TH165.3 文献标识码: A 国家标准学科分类代码: 520.20

## Application of deep learning in equipment prognostics and health management

Chen Zhiqiang<sup>1,2</sup>, Chen Xudong<sup>2</sup>, José Valente de Olivira<sup>4</sup>, Li Chuan<sup>3,4</sup>

(1. Chongqing Engineering Laboratory for Detection Control and Integrated System, Chongqing Technology and Business University, Chongqing 400067, China; 2. College of Artificial Intelligence, Chongqing Technology and Business University, Chongqing 400067, China; 3. National Research Base of Intelligent Manufacturing Service, Chongqing Technology and Business University, Chongqing 400067, China; 4. CEOT, Universidad do Algarve, Faro, Portugal)

**Abstract:** In intelligent manufacturing, the prognostics and health management of the equipment driven by big data has been paid much attention. In recent years, because it can capture more hidden knowledge in the process of feature extraction of hierarchical structure and has good data adaptability across a variety of domains, deep learning has become a hot topic in the field of equipment health management. It has been widely used in equipment fault diagnostics and prognostics. This paper systematically reviews emerging literatures on the application of deep learning in equipment health management. It summarizes, classifies and explains main publications on this trendy topic. Various architectures and related theories are also discussed. As a review, this paper expounds the achievements, challenges and future development trends of the deep learning in the field of equipment fault diagnostics and prognostics. It provides a clear direction for practitioners including the industry to select, design or implement deep learning architecture for the equipment health management.

**Keywords:** deep learning; prognostics health management(PHM); fault diagnostics; remaining useful life prognostics

## 0 引言

故障预测与健康管 (prognostics and health

management, PHM)是在设备故障发生前,对其故障进行预测,并结合各种可以利用的资源信息,提供一系列的维修保障措施,通常包括诊断和预防设备故障,预测设备核心组件的可靠性和剩余使用寿命<sup>[1]</sup>。在过去的几十年

收稿日期: 2019-05-10 Received Date: 2019-05-10

\* 基金项目: 国家自然科学基金(51775112)、国家重点研发计划(2016YFE0132200)、重庆市基础研究与前沿探索项目(cstc2018jcyjAX0057)、重庆市教委科学技术研究项目(KJQN201800814)资助

中,有关 PHM 的研究大幅增加,解决了元件和系统级别上发生的各种故障。随着现代设备系统产生的数据规模不断增大,装备运行环境日趋复杂,系统元件间的耦合关联导致各元件状态信息彼此相关。这可能产生在设备生命周期设计阶段没有预料到的故障,并最终导致诊断过程中出现更高层次的不确定性。在此情况下,需要新的方法来应对新的应用,做出更好的故障预测与健康决策。为了日趋复杂的设备健康管理,基于传统技术的诊断系统正被基于人工智能的诊断系统所取代,从而提高设备健康管理的效率<sup>[2-4]</sup>。

深度学习的出现归因于计算能力的提高,以及高效的神经网络深层结构训练方法的提出。2019年在图灵奖得主 Hinton 等人的努力下,深度学习取得了突破性进展,开启了具有深度架构的机器学习研究新时代,成为机器学习领域最具吸引力的研究方向之一<sup>[3,5]</sup>。深度学习体系结构旨在对数据的高层表示进行建模,并通过在层次结构中堆叠多层信息处理模块来对模式进行分类或者预测。经典的深度学习体系结构如卷积神经网络(convolutional neural network, CNN)、堆栈自编码器(stacked autoencoder, SAE)、深度信念网络(deep belief network, DBN)、深度玻尔兹曼机(deep boltzmann machine, DBM)和循环神经网络(recurrent neural network, RNN)等,已经成功地应用于计算机视觉、自然语言处理、图像处理、无人驾驶汽车等领域<sup>[1,3]</sup>。由于多层非线性数据处理单元的深层体系结构具备了对原始数据进行学习的能力,深度学习已成为设备智能健康管理的有效工具<sup>[6]</sup>。

2013年以来,基于深度学习的 PHM 技术日渐成为本领域的研究热点,深度学习在设备的故障诊断和预测中得到了广泛的应用。到目前为止,已经从最初的机械设备健康管理扩展到电力系统、电力装置和航空航天设备等的故障诊断和预测<sup>[1]</sup>。关于深度学习在 PHM 领域的应用这一主题的现有论文,主要聚焦于具体的研究领域<sup>[1-3]</sup>。由于有这么多不同的算法和健康监测解决方案,很难使这些信息化呈现。这是一个不断发展的研究领域,因此有必要研究其在 PHM 应用中的适用性,以提高系统的整体弹性或维护、维修和检修活动的潜在成本效益。

Samir 等<sup>[1]</sup>为 2013 年至 2017 年间报道的基于深度学习的故障诊断和预测论文做了一个总结,其中选择了 38 篇论文进行综述;Duy-tang 等<sup>[3]</sup>针对深度学习在轴承故障诊断领域的应用进行了综述;Rui 等<sup>[2]</sup>对深度学习在机器的状态监控领域进行了综述;在中文领域也出现了部分综述性文章<sup>[7]</sup>,产生了显著的影响,这些工作为撰写本文奠定了坚实的基础。本文通过系统地回顾深度学习在 PHM 领域中的应用的主要文献,对跨学科应用的设

备健康管理深度学习研究提供一个结构化和广泛的概述,力求为研究人员和工程师选择、设计或实现深度学习体系结构提供明确的方向。

## 1 PHM 技术

### 1.1 基本架构

PHM 技术最早由美国军方提出并发展起来,旨在提高装备的安全性和任务成功率,是提高保障效能和降低保障费用的重要手段。其研究内容包括:状态监测、故障诊断、故障预测、健康管理和决策、数据通信、传输和表达等。IEEE、ISO、MIMOSA、ARINC 等国际组织发布了一系列 PHM 相关标准。ISO 13374 标准为 PHM 系统整体功能模块的划分和软件模块的设计提供了指导。针对机器的状态监测和诊断,MIMOSA 中的 OSA-CBM 标准对 ISO 13374 标准进行了实现,所定义的 PHM 体系的功能模块如图 1 所示:数据采集(DA)、数据处理(DM)、状态检测(SD)、健康评估(HA)、预兆评估(PA)和提出建议(AG)<sup>[8]</sup>。

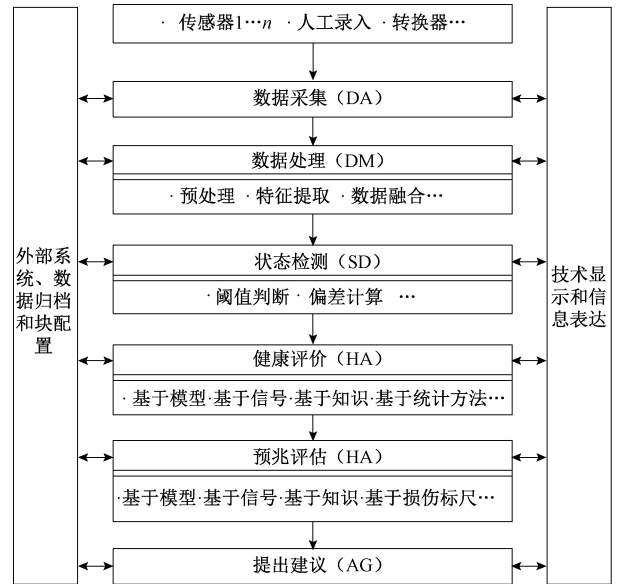


图1 OSA/CBM-ISO13374 数据处理与信息流

Fig.1 Data processing and information flow of OSA/CBM-ISO13374

图 1 所示 6 大功能模块自顶向下形成信息流。数据采集是从部署在装备系统上的各种传感器来源收集相关数据如振动、声发射、电流、速度、温度等信号。数据处理主要包括数据清洗等策略进行预处理;通过信号处理技术和降维策略,从原始信号中提取和选择故障敏感特征;对多传感器信号进行数据融合。状态检测模块通过监测到设备状态数据,进行阈值判断和偏差计算,进行异常检

测。基于前3个模块采集处理后的装备状态数据,结合历史数据,健康评价、预兆评估和提出建议3个功能模块,利用各种诊断和预测等算法对装备当前的健康状况进行评定<sup>[8]</sup>。

## 1.2 面临的挑战

PHM技术经过几十年的发展,在降低设备业务成本和增加正常运行时间方面,取得了长足的进步。但是,在面对复杂系统的健康管理,如何有效地识别已经发生和即将发生的故障,仍然是PHM技术发展面临的最突出的重大技术难题之一。

复杂系统的复杂性在于系统结构复杂,变量多,系统变量间耦合性强、存在高度非线性,且伴随时滞、时变性等特性。诸如飞机、冶金产线、风力发电机、大型电力变压器、核动力装置这样的复杂系统,由若干个子系统组成,每个系统又包含了各种元器件。要实现健康管理的对象众多,包含健康信息的状态信号复杂多样,既有动态的,也有静态的,既有连续的,也有离散的,通常需要多种故障诊断与预测技术相组合。系统的复杂性决定了PHM技术的复杂程度<sup>[4]</sup>。

复杂系统故障诊断与预测的另外一个挑战就是不确定性:复杂系统内部及外部环境具有许多未知或不确定的因素,包括参数和结构存在不确定性,恶劣工况和干扰对系统的影响相互耦合,有效表征已知系统信息中的认知不确定性与测量不确定性,以及信息传递时滞现象等。不确定性在故障诊断和预测是普遍存在。为了应对不确定性问题,不少研究者从不同途径进行了研究,孙强等<sup>[9]</sup>从随机性、模糊性、灰性及混合不确定性4个角度对相关方法进行了归纳:基于随机性的方法如自回归滑动平均模型、隐Markov和隐半Markov模型、Bayes估计理论以及证据理论等;基于模糊性的方法如模糊集理论和模糊神经网络等;基于灰性的方法如灰色理论等,这里的灰性指的是指信息不完全,即贫信息、缺乏经验知识的不确定性;基于混合不确定性的方法如自适应模糊神经推理系统与高阶粒子滤波结合的故障预测模型等,将随机性、模糊性、灰性3种不确定属性相互关联,结合不同理论的进行故障预测。尽管存在诸多努力,要应对普遍存在的不确定性,处理系统中的各类复杂特性,提高预测精度,降低报率低,准确定位故障,仍然需要研究者们不断探索和研究。

应对复杂系统,如何实施和实现OSA/CBM体系结构,组织对象和集成系统是亟待解决的问题<sup>[4]</sup>。这受到健康管理对象自身特殊应用场景限制,如飞机健康管理受机载的重量、空间和资源限制,只能分解成地面系统和机载系统两部分。冶金设备往往受到高温和多存限制,对数据采集的传感器部署影响非常大。

系统设备状态数据是宝贵的财富,含有丰富的健康

信息,是数据驱动的故障诊断和预测技术基石,其难点在于由历史数据得到的故障预测模型如何延拓,才能保证中长期故障预测的准确性。而健康信息的获取是PHM技术面临的另一难题。一些复杂系统,故障机理复杂甚至难以定位,针对不同的故障模式,如何选择传感器类型、组织传感网络、优化传感器布置,对采集获取的健康信息质量密切相关。过多的传感器,会给健康管理对象造成额外的负担,过多的传感器数据也会造成数据冗余,给特征提取和故障分析带来困难。对于一个大的传感器网络,数据量大也会给传输和处理带来巨大负担。

## 1.3 智能故障预测与诊断方法

PHM技术将维修保障措施从事后维修和定期维修推向了视情维修阶段,为了应对各种挑战,以智能推理和机器学习等技术为代表的智能故障预测与诊断方法被广泛应用于PHM领域,又有力推进了PHM技术的发展。智能故障预测与诊断方法总体上可以分为:1)模型驱动方法,如基于失效物理模型和基于数学模型等;2)知识驱动方法,包括专家系统和定性推理等;3)数据驱动方法,包括统计过程控制、神经网络等机器学习方法。图2所示展示了用于PHM的智能故障预测与诊断方法<sup>[1-4]</sup>。

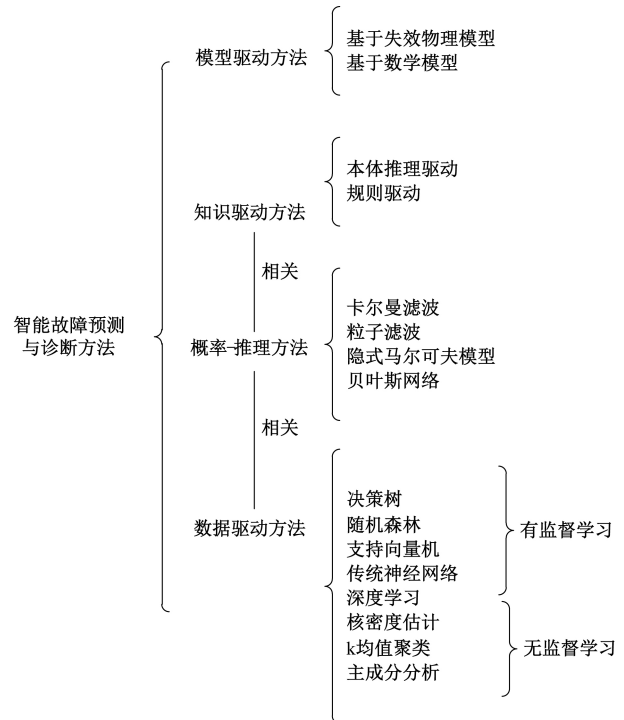


图2 智能故障预测与诊断方法

Fig.2 Intelligence fault prediction and diagnosis method

一般来说,如果可以开发出针对不同故障模型的数学模型,那么基于模型的方法是更准确和有效的<sup>[8]</sup>。但是,由于实际系统的复杂性和不确定性,很难找到明确的数学模型。基于失效物理模型的方法依赖于系统关键元

件的失效物理,如磨损、疲劳和老化等,不同元件的失效物理有不同的失效进程和规律,要掌握关键元件的磨损、疲劳和老化进程规律,耗资耗时。针对复杂系统的健康管理,模型驱动是重要组成,不可忽视但挑战甚多<sup>[10]</sup>。

知识驱动方法能否进行高效故障诊断与预测,取决于是否有完备的专家系统知识库,难以处理没有相关规则匹配的新故障。在运行过程中,专家系统不能从推理的实例中获得新的知识,并且对一些新奇的故障和系统设计的一些边缘问题求解具有很强的脆弱性。因此,基于知识的故障诊断与预测技术更适合于定性推理<sup>[10]</sup>。

设备状态数据包含了设备状态的丰富信息,包括设备组件间的关系、随机误差等,可以真实地刻画系统性能。实际工程中数学模型获得不经济甚至不可能,同时专家知识和经验难以有效的表达,在此情况下更多采用基于数据的技术。尤其是复杂系统,数据驱动的健康管理技术是一种非常实用的方法。其基于获取的设备运行状态数据,提取有意义的特征,在机器学习等算法帮助下,确定系统是否正常或是否有任何故障症状。通过对故障进行分类,进一步识别故障并确定其严重程度。数据驱动技术通常需要大量准确的历史数据。

近年来,开发了许多数据驱动的健康管理工具和技术。随着计算机处理器性能的提高及其成本的降低,专家系统、模糊系统和神经网络等人工智能技术逐渐发展起来。基于这些技术,针对设备健康管理领域,开发的人工智能解决方案的兴趣日益增加。与传统的诊断方法相比,基于智能技术的诊断可以最少的人工帮助提高性能,可以很容易地扩展和修改,并且可以根据新的数据进行调整。

在诸多智能技术中,机器学习算法有力推动了数据驱动的PHM技术发展。然而,传统机器学习算法的浅层结构对特征提取的非线性关系的学习能力非常有限。Samir等<sup>[1]</sup>对采用传统机器学习方法进行设备健康管理的局限性进行了总结:决策树(decision trees)利用先验知识进行训练,可能存在过拟合,且容易陷入局部最优困境,忽略属性之间的相关性,对于各类别样本数量不一致的数据,信息增益偏向于那些更多数值的特征;随机森林改进了决策树的性能,在训练速度上还优于支持向量机,但是偏倚增加,在解决回归问题时,并没有像它在分类中表现的那么好,对于小数据或者低维数据(特征较少的数据),可能不能产生很好的分类;贝叶斯网络(Bayesian networks)属于概率模型,减少了学习参数,容易可视化,存在依赖链,但是需要先验知识,学习未知结构是一个复杂的过程,朴素贝叶斯(naïve Bayes)算法简单,要求训练数据少,假设属性之间相互独立,需要知道先验概率,对输入数据的表达形式很敏感,无法处理基于特征组合所产生的变化结果;支持向量机故障识别精度

高,抗噪声能力较强,对规模较大数据集有效,属于有监督学习方式,需要先验知识,但是其核函数的选择不存在唯一的标准,需要不断试验;传统的神经网络或多层感知器,为了训练自适应系统,需要对少量的参数进行优化,易于过拟合,尚未有标准来确定网络结构;以k-means为代表的聚类算法,训练时间短,需要先验知识,即簇数k必须事先手动确定;自适应共振理论(adaptive resonance theory)具备非线性聚类建模能力,不太适合函数拟合,需要适当的数据预处理方案;自组织映射(self-organising maps)数据映射很容易解释,能够处理复杂数据集,但是难以确定将哪些输入权重设置为使用,要求邻近点具有相似特征;隐式马尔可夫模型属于统计模型,需要先验知识,建立精确模型需要大量的数据。综上所述,不存在一种可以解决所有问题的算法,要应对PHM领域的挑战,还需要研究者们开发新的解决办法,深度学习是一个深具潜力的工具<sup>[6]</sup>。

## 2 PHM领域的深度学习模型

深度学习又称深度神经网络(deep neural network, DNN),近年来引起了来自各个领域的研究者越来越多的关注。它采用多个神经层的层次结构,通过逐层处理从输入数据中提取信息,这种“深”层结构允许它学习具有多个抽象级别的复杂原始数据的表示。从原始输入开始,DNN自动发现大型数据集中复杂的结构,并逐层学习有用的特征。DNN得益于特征学习的特点,在视觉识别和语言理解中得到了广泛的应用,这种特征学习能力也成为它的关键优势。很明显,DNN特征学习能力的优势正好满足机械故障诊断中自适应特征提取方法的要求。利用DNN及其特征学习能力进行机械系统故障诊断具有很大的潜力和迫切的需要<sup>[5]</sup>。最近几年,基于深度学习的设备健康管理正成为本领域的研究热点。

本文就2013年1月至2019年4月期间,在Science direct、IeeeXplore和CNKI 3大数据库中,基于如下关键词检索到期刊杂志文献高达200余篇,会议论文高达400余篇:“deep learning”,“fault diagnosis”,“fault detection”,“condition monitoring”,“remaining useful life”,“深度学习”,“故障诊断”,“剩余寿命预测”。本文以检索到的208篇文献为研究对象,对深度学习在PHM领域中的应用进行综述。

如图3所示为2013年1月~2019年4月期间发表的学术期刊论文时间分布。2013年和2014年,分别只有1篇出版物。2015年,共计4篇出版物,开始应用CNN、DBN等模型到齿轮箱和轴承的故障诊断。2018年,是相关文献发表的高峰,高达114篇,进入2019年,热度未



减,本年度仅仅过了3个月,发表的文献高达76篇。在英文期刊中总计约57个杂志出版了相关论文;在中文期刊中,有超过29个刊物出版了相关学术论文。就深度学习在PHM的应用领域来看,出版物中,旋转机械的健康管理占据了主导:有57篇论文是关于轴承的健康管理,21篇论文是关于齿轮箱的健康管理,其他旋转机械的健康管理有17篇论文。但是,其应用领域正快速向其他领域扩展。风力涡轮机、电路故障诊断、航空动力系统、化工过程控制、机床刀具都是重要的应用领域,查阅的200余篇学术论文中,涉及到的领域超过40多种。因此,可以得出结论:在智能制造和工业4.0战略推进背景下,基于深度学习的设备健康管理,当前正处于研究的高峰,正受到各界重视。




图3 2013~2019年发表论文

Fig.3 Publications during 2013~2019

在PHM领域主要用到的深度学习模型有自编码器、深度波尔曼兹机、深度信念网、卷积神经网络和循环神经网络、深度残差网络(deep residual networks, DRN)以及其他一些深度学习模型,并基于这些模型开发出新的深度学习架构。其中基于卷积神经网络和自编码器开发出的PHM深度学习模型最多。这些基于深度学习的健康管理模型总体上可以分为采用信号处理对数据进行预处理的模型、无预处理端对端的黑箱模型、多种算法混合集成模型等类型,在解决自动提取特征、数据不平衡问题和训练模型与应用环境工况不一致等问题上卓有成效。下面将分别介绍各个深度学习模型的应用情况。

## 2.1 卷积神经网络(CNN)

CNN是深度学习模型的主要类型之一。文献[11]首先将CNN应用于设备健康管理。在多种工况下,采集了12种复合故障的齿轮箱振动信号,并对其进行频域和时域处理,形成一个长度为256的特征矢量,然后转化为一个 $16 \times 16$ 的矩阵,作为CNN的输入,通过CNN进行齿轮箱的故障诊断。在训练域和测试域保持一致情形下,达到了97.5%的故障识别准确率。CNN模型擅长从原始数据中学习特征。最初应用于图像处理,在各种计算

机视觉、自然语言处理和语音识别应用中的也取得了成功。就网络结构来看,经典的CNN由卷积层、池化层和全连接层组成,其结构如图4所示。网络层次的顺序通常为:输入-卷积层-池化层-卷积层-池化层-全连接层-输出。在统计的文献中,有约51篇文献是基于CNN及其变种开发的故障诊断与预测模型。在故障特征提取、故障诊断和设备剩余寿命预测等方面都有应用。在解决机械不平衡故障分类、端对端模型中的数据特征自动提取上卓有成效。




图4 典型的CNN结构

Fig.4 Classical CNN Network Architecture

常规的CNN模型需要二维格式的数据。受此启发,一些研究者将设备故障诊断问题转化为图像分类问题。Long等<sup>[12]</sup>采用时频技术,即S变换,将振动信号传递给图像,然后采用改进的CNN对图像进行分类。该团队还提出了一种新的基于LeNet-5神经网络的故障诊断方法<sup>[13]</sup>。该方法通过一种将信号转换为二维图像的方法,提取转换后的二维图像的特征,消除手工提取特征的影响。Zhu等<sup>[14]</sup>将胶囊网络(capsule network)和CNN相结合,采用短时傅立叶变换将信号转换为二维图形,将图形数据输入网络,利用两个卷积层提取更高的信息;然后,在输出特征映射中引入Inception模块,以改善胶囊的非线性。该模型的具有很好的泛化能力。Wang等<sup>[15]</sup>在多传感器数据融合基础上,将来自多个传感器的振动信号转换为图像,获得不同故障类型的特征图,然后利用优化的卷积神经网络进行特征提取,应用于风力试验台和离心泵试验台的实际诊断实例,分别得到了99.47%和97.32%的预测精度。

## 2.2 自编码器及其变种

自编码器是一种经过训练试图将其输入复制到其输出的神经网络,可以在没有输出或标签向量的帮助下学习数据的内在特性,属于无监督学习,典型的自编码器结构如图5所示。基本的自编码器模型有堆栈自编码器(stacked autoencoder)、降噪自编码器(denoise autoencoder, DAE)和稀疏自编码器(sparse autoencoder)。在调查的文献中,高达64篇文献采用了基于自编码器模型进行设备健康管理。

本文作者曾基于齿轮箱和滚动轴承实验平台,对经典的堆栈自编码器的性能进行了评估。在文献[16-17]




图 5 典型的自编码器结构

Fig.5 Classical AE network architecture

中,以 4 种数据作为自编码器的输入,经过 2 个隐藏层的自编码器特征学习,最后采用 SoftMax 分类器进行分类:分别是时序列的诊断信号原始数据,经过时域、频域和小波域预处理后的预处理数据。在训练域和测试域保持一致情形下,经过预处理后的 SAE 的故障识别正确率高达 99%。而没有处理的原始时序列数据,只有 15% 的正确率。Shen 等<sup>[18]</sup>利用傅里叶变换将原始信号转换为幅度谱,再作为堆叠的压缩自编码器网络的输入,进行了变速箱和轴承故障诊断实验,诊断正确率均接近 100%。

为了实现端对端的设备健康管理,从原始振动信号中自动学习有效特征,研究者们已经开发出了很多基于 AE 的深度学习设备健康管理模型<sup>[19-41]</sup>。其主要技术路线有:1) 与其他模型进行混合集成。文献[19-32]都属于将自编码器结合其他模型开发的混合集成模型。这些混合模型中,充分利用了自编码器优秀的特征学习能力。2) 加强局部特征学习。Jia 等<sup>[33]</sup>通过输入层、局部层、特征层和输出层来构造局部连接网络,从输入层的局部信号中局部学习各种有意义的特征,特征层中获得位移不变的特征,最后识别出输出层的机械健康状况。3) 采用优化算法对自编码器模型参数进行优化。Zhang 等<sup>[34]</sup>尝试采用粒子群算法分别对模型进行自适应的参数法调优;Shao 等<sup>[35]</sup>采用最大熵来设计新的深度自编码器损失函数,以增强测量的振动信号的特征学习,采用人工鱼群算法优化自编码器的关键参数。4) 优化模型,改进数据预处理技术。文献[36-39]进行了相关探索。

2.3 受限波尔兹曼机及变种

受限波尔兹曼机 (restricted Boltzmann machine, RBM) 是一种两层结构的特殊类型的马尔可夫随机神经网络,如图 6(a) 所示,包含一层可视层 ( $v$ ) 和一层隐藏层 ( $h$ )。在同一层的神经元之间是相互独立的,而在不同的网络层之间的神经元是相互连接的(双向连接),通常使用具有持久性马尔可夫链的对比分歧算法训练网络参数。基于受限波尔兹曼机,发展出了两种经典的深度学习神经网络,即深度信念网 (deep belief nets, DBN) 和深度波尔曼兹机 (deep Boltzmann machine, DBM)。如

图 6(b) 和 (c) 所示, DBN 是通过一次一个地训练 RBM,然后将它们堆叠在彼此之上,以便推断连续的隐藏层而形成的网络;DBM 将 DBN 转变为完整的无向图模型,将隐藏节点分组为几个隐藏层,约束条件是可见层仅连接到第一个隐藏层,然后每个隐藏层仅连接到其下方和上方的层,没有横向连接。基于 DBN 的设备健康管理模型,也是本领域最为活跃的模式之一,涉及的文献达 33 篇以上,在故障诊断和故障预测都有应用。而基于深度波尔兹曼机的健康管理模型只有文献 [42-45] 4 篇提及到。同自编码器及其变种相类似,沿着与其他模型进行混合集成、加强局部特征学习、采用优化算法对模型参数进行优化等方向,结合实际应用,开展了大量的工作。




图 6 RBM、DBN 和 DBM 结构

Fig.6 Classical network architecture of RBM, DBN and DBM

2.4 循环神经网络

循环神经网络是一种处理序列数据的深度学习框架,利用来自过去网络结果的信息来产生输出,每一步的隐藏状态取决于前一步的隐藏状态。由于其时间序列性质,使其成为设备健康管理系统的理想选择。基本的循环神经网络结构如图 7 所示,  $x_t$  表示时序列输入数据,  $h_t$  表示隐藏状态。注意箭头方向,序列化数据传给循环神经网络后,将其转化为隐藏状态序列。 $W, V$  和  $U$  分别表示网络参数。与其他深度学习体系结构一样,循环神经网络也可以扩展为具有多个隐藏层,该层可以将其隐藏状态连接到多个观测点,并沿序列传播信息。长短期记忆网络 (long short-term memory networks, LSTM) 和门控循环单元网络 (gated recurrent unit networks, GRUN) 是其中两种经典的循环神经网络。在调查的文献中,有 8 篇出版物是基于循环神经网络的设备健康管理,尤其是在剩余寿命预测方面,循环神经网络是有效工具。循环神

神经网络已经被应用于水下推进器故障检测与诊断<sup>[46]</sup>、铁路轨道线路故障的进行检测与识别<sup>[47]</sup>、刀具磨损预测<sup>[48]</sup>、齿轮箱故障诊断<sup>[49]</sup>、轴承早期故障检测<sup>[48]</sup>、光伏阵列故障诊断<sup>[49]</sup>、锂离子电池容量退化估计<sup>[50]</sup>、飞机涡扇发动机健康监测<sup>[51]</sup>等领域。




图7 基本的循环神经网络结构

Fig.7 Classical network architecture of RNN

## 2.5 深度残差网络

深度残差网络是2015年提出的深度卷积网络,在解决ImageNet挑战方面,斩获过图像分类、检测、定位3项的冠军。其核心动机是在在加深网络的情况下又解决梯度消失的问题。在调查的文献中,存在文献[52-54]3篇有关深度残差网络的应用。

Zhao等<sup>[53]</sup>开发了具有动态加权小波系数的深度残差网络,将各种频带上的一系列小波包系数作为输入。开发的深度学习架构中的动态加权层用于优化应用于各种频带上的小波系数的权重,以便探索特定频带上的一系列小波系数如何有助于区分变速箱的健康状态,并将其应用在行星齿轮箱的故障诊断。与传统的基于SVM和NN的故障诊断方法相比较,性能大幅提高。在Zhao等的另一项工作中<sup>[54]</sup>,在深度残差网络中的进行多个小波系数级联融合和多个小波系数最大化融合,并从小波系数的不同集合中获取特征信息用于故障诊断。通过行星齿轮箱故障诊断中的性能比较验证了所开发方法的有效性。汪久根等<sup>[52]</sup>将残差网络用于诊断RV减速器的故障,将一维信号样本转换为二维信号样本,作为残差网络输入,采用5折交叉验证,讨论了堆叠方式的改变对残差网络的分类准确率的影响,并进一步优化了残差网络的分类效果,通过数据增强优化训练集,提升了残差网络的分类性能。

## 2.6 其他深度学习模型

已有的一些论文运用了深度学习建模思想,但没有明确的说明基于那一种深度学习模型。部分工作是在多层感知器的基础上开发的深度学习模型,如文献[55-65],这里做一个简单综述。

Li等<sup>[55]</sup>开发了一种基于深度学习的机械设备故障分类和退化评估方法,通过小波包分集提取的原始特征作为输入,使用了多种数据驱动模型来发现故障信息。Kaoutar等<sup>[56]</sup>开发了一种基于多样化冗余概念的技术,构建了一个容错体系结构,以加强深度学习模型的安全性。

Liu等<sup>[61]</sup>提出了一种新的带域自适应的深度神经网络模型用于故障诊断,该模型能够在利用域自适应的同时增强原始数据的代表性信息,从而能够在目标域上获得较高的分类精度,并采用了优化策略来优化模型参数。Yang等<sup>[57]</sup>提出了一种基于深度学习的轴承故障自动分类方法。该方法具有故障信号自动聚类的能力,属于端对端的模型。算法的核心是对小维数据进行DNN训练,并根据训练后的DNN测试结果对样本标签进行调整。Wei等<sup>[58]</sup>提出了一种基于深度神经网络的直接驱动风力发电机组故障诊断方法。该方法结合风力发电机组的运行机制,消除了监测控制和数据采集中的异常值;采用传统的随机森林方法对目标变量相关变量的重要性进行评价;利用剔除异常值的历史健康数据训练深度神经网络;采用指数加权移动平均控制图确定故障阈值。将在线数据输入经过训练的健康状态下的风力机深度神经网络模型,将测试误差作为风力机故障报警的度量指标。李川等<sup>[62]</sup>提出了一种被称之为次优网络深度学习模型,并应用于3D打印机故障诊断,采用消费品级的姿态传感器采集打印机的健康状态数据。提出的次优网络深度学习在由预训练和精细调节组成的传统深度学习基础上,一方面提出预分类方法自适应确定次优的网络结构参数,另一方面采用精细分类方法进一步提高故障诊断分类的精度,弥补低成本硬件精度的不足。Miao等<sup>[63]</sup>提出了一种使用大型内存存储和检索深度神经网络,该解决方案可以自动提取自主学习故障特征并同时执行轴承故障诊断和严重性检测。通过最佳地选择输入时频矩阵的滑动框大小来确定网络的结构。Roozbeh等<sup>[64]</sup>针对标记样本的稀有性以及输入空间中过量的未标记样本等现实情况,采用半监督深度学习算法设计了一个混合框架,通过信息融合和决策组件进行故障诊断。Yang等<sup>[65]</sup>提出了深度网络分析仪,用于移动无线网络中的异常检测。

## 3 深度学习在故障特征提取方面的应用

特征提取在设备智能故障诊断与故障预测中都起着至关重要的作用。深度学习模型的关键优势在于能够从原始数据中挖掘出有代表性的信息和敏感特征。

文献[66]基于深度学习的特征学习,将深度学习在机械故障诊断中的应用可分为两个阶段,如图8所示。深度学习模型在早期工作中作为一种分类器或特征选择方法,与应用传统的机器学习方法进行设备故障诊断相类似:首先采用各种信号分析方法提取特征,提出的特征作为深度学习模型的输入,进一步提取的特征,最后进行分类识别。这种基于信号分析技术进行预处理,由于其自动化特征提取低,被称之为手动提取阶段。这样的过

程不仅是一项艰苦而耗时的工 作,而且对诊断结果也有很大影响。

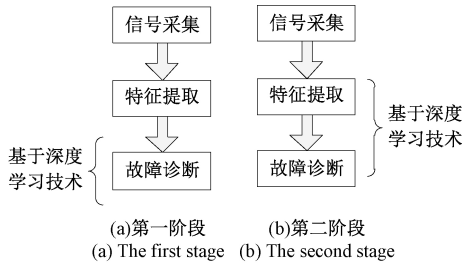


图 8 深度学习在设备健康管理领域应用的两个阶段

Fig.8 Two stages of the applications of deep learning in mechanical fault diagnosis

很多研究者们开始将研究的注意力转移到自动提取特征的方向上来,并取得了很大进展,即深度学习在设备健康管理领域应用的第 2 个阶段:利用深度学习模型强大的特征提取能力,自动提取特征的端对端模型。

无论是强大的卷积神经网络模型,还是自编码器、深度信念网等经典模型,直接从采集到的原始数据中提取特征,效果并不理想。Jing 等<sup>[66]</sup>重点考察了 CNN 的振动信号特征提取能力。从原始数据、频谱数据和组合时频数据 3 个角度来测试 CNN 的特征学习 的不同性能。考察的 4 种不同结构的 CNN 模型。结果表明,CNN 能够从频率数据中更好的自适应地学习特征,并能获得高达 98.67% 的诊断准确率。从原始数据中采用经典的 CNN 算法进行特征学习,只获得了 82.3% 的诊断准确率。作者团队的工作中<sup>[67]</sup>,采用深度信念网和深度波尔曼兹机进行齿轮箱的故障诊断,在有信号处理技术作预处理的前提下,训练域与测试域保持一致的情形下,其故障识别精度达到了 98% 以上。而直接从原始数据中提取特征,最终的故障识别精度非常低。

要实现从采集的原始数据自动提取特征,提高端对端的黑箱模型的诊断准确率,需要优化模型。很多研究者取得了卓有成效的工作。主要技术路线包括混合集成其他算法模型、采用优化算法优化模型参数、加强局部特征学习、优化深度学习模型、改进数据预处理技术等。开发出了很多自动从原始数据中进行特征学习的端对端深度学习模型,技术日渐成熟。

Han 等<sup>[68]</sup>提出了一种将时空模式网络 (spatiotemporal pattern network, STPN) 方法与卷积神经网络相结合的新框架 (STPN-CNN),如图 9 所示。该模型最大的特点是能有效地从不同类型的数据中提取时空特征。首先采用符号动力学滤波 (symbolic dynamics filtering, SDF) 将从不同传感器中采集的信号转换成符号序列;对于同域信号,采用 D-马尔可夫机 (D-Markov machine,

DMM) 生成状态转移概率矩阵,如图 9 中  $\Pi_{aa}$  所示;对于跨域信号,采用 XD-马尔可夫机 (XD-Markov machine, XDMM) 生成状态转移概率矩阵,如图 9 中  $\Pi_{ab}$  所示,为信号 a 和 b 间的状态转移概率关联矩阵;然后将生成的状态转移概率矩阵作为与 CNN 的输入,进行特征提取。所采用的 CNN 模型包括 3 个卷积层 ( $C_1$ 、 $C_2$  和  $C_3$ )、3 个池化层 ( $S_1$ 、 $S_2$  和  $S_3$ ) 和 3 个全连接层 ( $FC_1$ 、 $FC_2$  和  $FC_3$ )。应用 STPN 和 CNN 相结合的数据特征提取过程避免了人工特征提取,提高了方法的适应性。

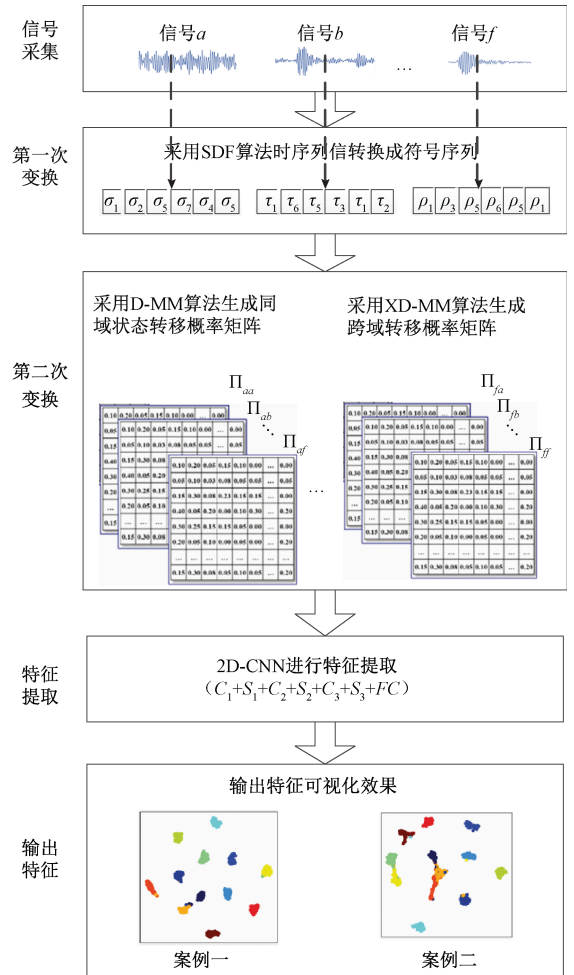


图 9 SPNN-CNN 框架

Fig.9 Framework of SPNN-CNN

除了 CNN 外,在深入学习技术中,自动编码器是机械信号自动特征提取的另一种潜在工具。然而,传统的自动编码器有两个缺点。1) 在特征提取中,他们可能会学到相似的特征。2) 学习到的特征具有变化的性质,导致对机械健康状况的错误分类。针对上述不足,Jia 等<sup>[69]</sup>提出了一种基于归一化稀疏自编码的局部连接网络 (local connection network constructed by normalized sparse autoencoder, NSAE-LCN),分别由归一化稀疏自编



码网络和局部连接网组成。与传统的稀疏自编码相比,NSAE有如下不同点:1) 激活函数采用的是 ReLU (rectified linear units); 2) 没有考虑偏置; 3) 采用 L1 范数 (L1 norm) 替代 KL 散度函数 (KL divergence function); 4) 为了学习到机械振动信号中的不同特征,代价函数增加了软正交约束项。在 NSAE 的训练过程中,它的权重矩阵实际上是通过软正交性约束进行归一化的。这就是该算法为什么被称规一化的稀疏自动编码器的原因。局部连接网用于学习样本中的局部特征,由输入层、局部层、特征层和输出层组成。如图 10 所示,采集到的信号首先被分割成不同的子集;分割后的子集,一部分被随机选择,构成局部特征训练集,用于训练 NSAE 网络。训练好的网络权重矩阵  $W_{loc}$  用作 LCN 网络中的输入层与特征层间的连接权值;样本中每个分割的片段作为 LCN 网络的输入。LCN 网络的输入层由  $l$  个子网组成,  $l$  指的是样本被分割的子集数。各样本子集经过在  $W_{loc}$  权值矩阵作用下,提取出局部特征,采取均值策略(各子集特征加权均值),获得样本特征  $f_m$ 。通过输入层、局部层、特征层和输出层来构造局部连接网络,从输入层的局部信号中局部学习各种有意义的特征,最后识别出输出层的机械健康状况。

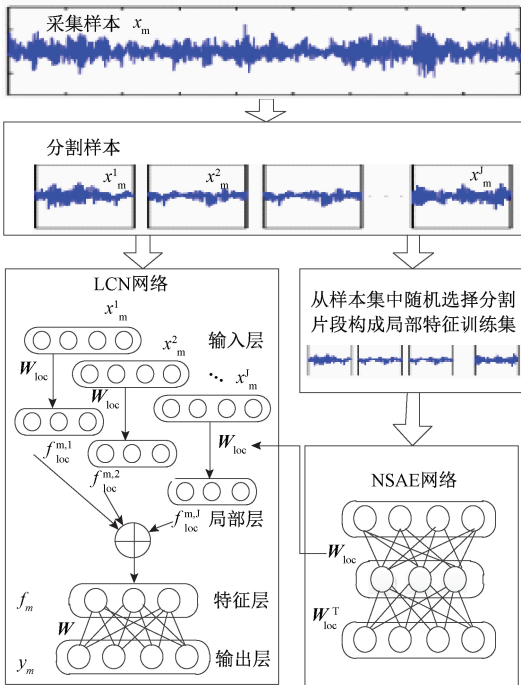


图 10 NSAE-LCN 框架

Fig.10 Framework of NSAE-LCN

在自动提取特征方面,除了上述两项代表性工作外,Long 等<sup>[70]</sup>还提出通过集成学习提高深度学习模型的泛化能力,开发了一种新的快照集合卷积神经网络 (SECNN),它能在面对新的数据集时自动找到合适的学

习范围。Zhang 等<sup>[34]</sup>尝试采用粒子群算法分别对模型进行自适应的参数调优,在自动学习特征方面都取得了非常好的效果。该工作将训练集分成若干子集,训练自编码器,并采用粒子群优化算法进行参数调优,有助于从不同的故障模式中学习判别特征,实现自动特征提取。Shao 等<sup>[71]</sup>采用最大熵来设计新的深度自编码器损失函数,以增强测量的振动信号的特征学习,采用人工鱼群算法来优化自编码器的关键参数。Zhao 等<sup>[72]</sup>为模拟电路故障诊断开发了不依赖于手动特征提取和选择的深度信念网模型。Tang 等<sup>[73]</sup>使用个体自适应学习速率方法来选择用于加速下降的合适步长,开发了一种结合 Nesterov 动量的自适应调制学习率的深度信念网络,并用于旋转机械故障诊断。Gao 等<sup>[74]</sup>将经典的深信度网络和量子启发神经网络相结合,集成二者有点构建一个新的模型,用于飞机燃油系统的故障诊断。Liu 等<sup>[75]</sup>开发了一种用于富电子模拟系统的高斯-伯努利深度信念网的新型故障诊断应用,可以更有效地捕获原始输出信号中的高阶语义特征,直接处理模拟电路的原始信号输出。Xie 等<sup>[76]</sup>基于 Nesterov 矩 (nesterov moment, NM) 优化的自适应 DBN 的端到端故障诊断模型,以频域信号作为模型输入,用于从旋转机械中提取深层代表特征,同时识别轴承故障的类型和程度。Zhang 等<sup>[77]</sup>提出了一种基于深度信念网的特征提取的新型模拟电路初始故障诊断方法。在诊断方案中,深度信念网被用于从测量的时间响应中提取特征,其中使用粒子群算法优化深度信念网的学习率,然后利用 SVM 的对不同的初始故障类进行分类。Mandal 等<sup>[78]</sup>基于深度信念网,开发了一种用于核电站的热电偶的在线故障检测和分类方法。Hu 等<sup>[42]</sup>将深度波尔兹曼机和多粒度扫描森林算法相结合,应用于基于大数据的工业故障诊断新方法。余博等<sup>[79]</sup>提出一种基于深度卷积变分自编码网络 (deep convolution variational autoencoder network, DCVAEN) 的特征提取方法,利用频谱数据训练深度神经网络,能减少特征提取对人工经验的依赖和信息的损失,在网络中加入了变化的噪声和调整学习率,使得网络隐层提取判别性的故障特征,能满足多故障和变工况的诊断。利用自吸式离心泵数据和西储大学轴承数据进行分析验证,实验结果表明,所提方法能更准确、更稳定地识别传动部件的各种故障,具有较强的泛化能力。

综上所述,基于自动提取数据特征的端对端学习模型,开发出了很多自动从原始数据中进行特征学习的设备健康管理模型,技术日渐成熟。

#### 4 深度学习在故障诊断方面的应用

某种意义上说,数据驱动的故障诊断本质上属于模

式识别范畴<sup>[80]</sup>,基于提取的设备状态数据特征,对故障类型进行分类识别。这也是深度学习在PHM领域中应用最多的环节。在统计的200余篇文献中,不同类型的故障的分类识别占据了主导地位。通常利用深度学习模型的特征提取优势,在深度学习模型最后一层,连接一个分类器如Softmax、随机森林、SVM等。以自编码器、深度波尔曼兹机、深度信念网、卷积神经网络、循环神经网络、深度多层感知器和深度残差网络为代表的深度模型,正迅速被应用于设备故障诊断,并在此基础上开发出了各种变种。

为了提高故障识别精度,一些优化算法被引入深度学习模型,优化模型参数。Ma等<sup>[81]</sup>基于判别深度信念网络(discriminative deep belief networks, DDBN)和蚁群优化(ant colony optimization, ACO)算法,开发出的新方法被用于预测机器的健康状态:DDBN结合深度信念网络的优势和反向传播策略的判别能力,通过多层堆叠受限波尔兹曼机进行贪婪的层层训练,在将特征从高维空间降维到低维空间时可以很好地保留信息;将ACO引入DDBN进行参数优化。通过优化,DDBN模型的结构在没有先验知识的情况下自动确定,并且性能得到增强。Shao等<sup>[82]</sup>提出了一种新的带局部线性嵌入的连续深信念网络方法,用于滚动轴承故障检测。首先,基于局部线性嵌入定义新的综合特征指数,以量化滚动轴承性能退化趋势。其次,基于一系列经过训练的连续受限波尔兹曼机构建连续深度信念网络(continuous deep belief network, CDBN)来模拟振动信号。最后,利用遗传算法(genetic algorithm, GA)优化连续深度置信网络的关键参数,以适应信号特征。除此之外,文献[83-86]的工作都利用了优化算法对模型参数进行优化。

#### 4.1 域自适应故障诊断深度学习模型

在早期研究中,并没有考虑域自适应问题。通常训练模型用的数据和测试用数据分布在同一工况下。数据分布处于同域中,尽管开发出的这些深度学习模型,在故障分类识别精度上可以高达99%,但是实际意义并不大。因为在实际操作中,设备的工作条件不一致,信号采集方法不同,工作载荷也不同,导致训练数据与测试数据存在不一致问题,从而带来了较低的诊断精度。

由历史数据得到的故障诊断模型如何延拓,才能保证中长期故障诊断的准确性,一些研究者已经着手解决类似问题。域自适应(domain adaptive, DA)技术就是解决路线之一,目的是通过学习在多个不同领域数据集中隐藏的不变知识来减少多个领域之间的差异。迁移学习技术是深具潜力的DA技术之一。迁移学习专门针对传统机器学习要求基于同分布假设,需要大量标注数据的缺陷,解决实际工作中数据分布差异,标注数据过期问题,充分利用之前标注好的数据(已有知识),保证在新

的任务上的模型精度。文献[87-92]分别将迁移学习技术引入到了故障诊断领域。

图11所示为Bin等<sup>[87]</sup>提出的基于特征的迁移学习故障诊断框架(feature-based transfer neural network, FTNN),并应用于滚动轴承智能故障诊断,将实验室机器中使用的轴承数据包含的故障知识,迁移到实际机器中的轴承故障诊断。包括4个步骤:域划分、特征提取、域自适应和故障识别。采集的数据域被分为源于和目标域,源域包含有标记的样本以提供诊断知识,而目标域中的未标记样本通过从源域获得的诊断知识进行分类。在特征提取方面,卷积神经网络被用来从源域和目标域的数据中提取可转移的特征。在此基础上,提出了多层域自适应和伪标记学习的正则化条件,对卷积神经网络的参数施加约束,以减小学习到的可转移特征的分布差异和类间距离。首先用一种称为最大平均差异(maximum mean discrepancy, MMD)的非参数距离度量来度量学习到的可转移特征的分布差异;然后,将所测得的可传递特征的分布差异作为向后传播的优化目标,对非线性特征映射的参数进行训练,最大限度地减小学习到的可转移特征的分布差异,从而获得具有较小的跨域差异的特征。在故障识别中,利用领域共享分类器,对目标域中的未标记样本进行正确的分类。通过两个实例验证了FTNN模型的有效性,即利用实验室使用的电机轴承和变速箱轴承的数据来识别机车轴承的健康状态。结果表明,在实际情况下,当没有标记数据时,FTNN模型能够识别真实环境下运行的轴承的健康状态。此外,与其他方法相比,该方法具有更高的分类精度和更好的传输性能。

此外,文献[93-95,61]还展示了其他的域自适应模型。但是这些方法更多的还停留在实验验证中。为了模拟跨域环境,往往通过改变转速和荷载来模拟各种工况,用A工况的数据来训练模型,用B工况的数据来测试模型。

#### 4.2 数据不平衡故障诊断深度学习模型

一般情况下,深度学习模型的成功很大程度上归因于海量有标记的数据,在实际情况下,装备在大部分运行阶段处于正常工作状态,在运行过程中很少发生故障。由于工作条件的复杂性,对监测数据进行标注需要花费大量的时间和经费。因此,不同健康状况下的数据样本呈长尾分布,即正常状态的数据样本丰富,而有故障的数据样本相对稀少。数据样本的不平衡分布迫使故障诊断模型偏向大多数健康状况。由此衍生了数据不平衡问题。

生成对抗性网络(generative adversarial networks, GANS)已被证明能够产生与真实数据相似的人工数据,并成功地应用于各种图像生成任务中,成为一种有用的

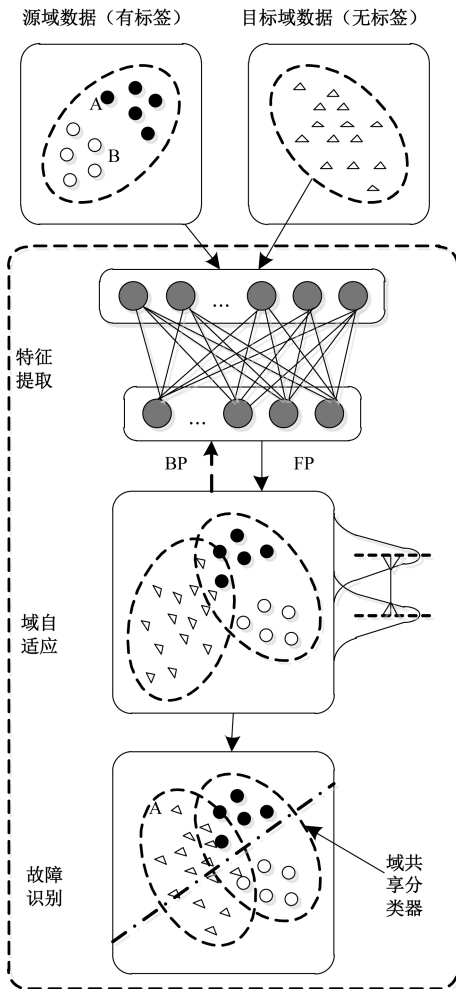


图 11 基于特征的迁移学习故障诊断框架  
 Fig.11 Feature-based transfer learning fault diagnosis framework

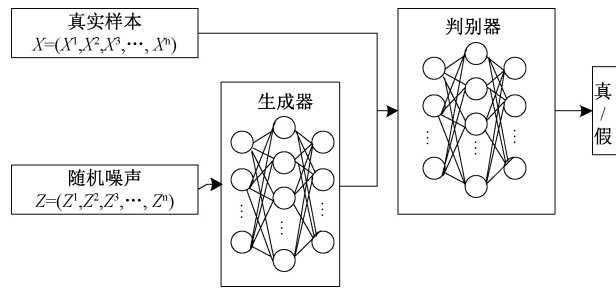


图 12 生成对抗网络原理  
 Fig.12 Schematic of GAN

障诊断方法,具有良好的抗噪声能力,应用于行星变速箱故障诊断,在小样本情况下具有较好的故障诊断性能。Shao 等<sup>[98]</sup>也采用卷积神经网络构造生成器和判别器,对生成样本质量的统计特性进行评估,并利用感应电机振动信号数据集验证了该框架的有效性。Liu 等<sup>[30]</sup>提出了一种对抗性自动编码器,并应用于滚动轴承故障诊断。该方法在环境噪声和电机负载变化时具有良好的性能和较高的聚类指标,具有较强的鲁棒性。

除了采用对抗学习来改善样本分布状况外, Wang 等<sup>[97]</sup>针对化工故障诊断中的数据不平衡问题,提出了一种改进型的深度神经网络,被称之为 Incremental-IMDNN (incremental imbalance modified deep neural network), 采用了动态增量学习策略,以促进对数据流不平衡的故障诊断。该模型的主要贡献如下:1) 为将不平衡数据问题转化为平衡分类问题,将主动学习和过采用方法相结合,改进故障样本的选择和生成方案,动态优化样本生成过程;2) 采用增量模型实现了不平衡数据中的原始知识的传递,进一步简化了复杂的学习任务。Incremental-IMDNN 模型的流程框架如图 13 所示。图 13 中 IM-SMOTE 算法的核心思想是对于少数类样本  $a$ , 随机选择一个最近邻的样本  $b$ , 然后从  $a$  与  $b$  的连线上随机选取一个点  $c$  作为新的少数类样本,通过增加少数类样本,达到数据平衡;动态反馈主动学习策略是从诊断模型的角度挖掘出信息最丰富的样本,并与 IM-SMOTE 相结合,进一步提高数据集质量;所使用的 DNN 模型为 SADE 模型,进行数据特征提取;增量学习的 DNN 模型动机如下:在运行过程中,会有新的故障不断产生,为了适应故障模式的动态增加, DNN 模型进行增量学习, FCM (fuzzy C-means) 技术被用来实现 DNN 模型的增量学习。与传统的在静态数据基础上静态学习的模型相比,此模型继承现有知识和网络层次结构,通过故障的相似性来扩展诊断模型,适应诊断场景的动态变化。该模型被基于伊斯曼过程 (Tennessee Eastman process, TEP) 仿真平台产生的数据集进行了验证,在化学不平衡数据分类方面,具有显著优势,优于传统的技术方法。

数据增强工具。GANS 的原理如图 12 所示,由一个生成模型 (generator) 和一个判别模型 (discriminator) 构成。生成模型捕捉真实数据样本的潜在分布,并生成新的数据样本,它的目的就是使得自己造样本的能力尽可能强,强到判别网络没法判断生成的样本是真样本还是假样本;判别模型是一个二分类器,判别输入是真实数据还是生成的样本。生成器和判别器二者进行博弈,优化过程是一个极大极小博弈问题,优化目标是达到纳什均衡,二者都可以采用深度神经网络。为了解决数据不平衡问题,一些研究者尝试用生成对抗性网络生成故障样本,扩大样本的大小。文献[96-99]和[30]将对抗学习技术引入,分别构造了不同的深度学习模型。

Han 等<sup>[96]</sup>采用卷积神经网络构造生成器和判别器,开发一种对抗深度学习框架,比较研究两种机械故障数据集的模型,证明了该方法的适用性和优越性; Wang 等<sup>[97]</sup>提出了一种将生成对抗性网络和堆栈去噪自动编码器 (stacked denoising auto encoder, SDAE) 相结合的故



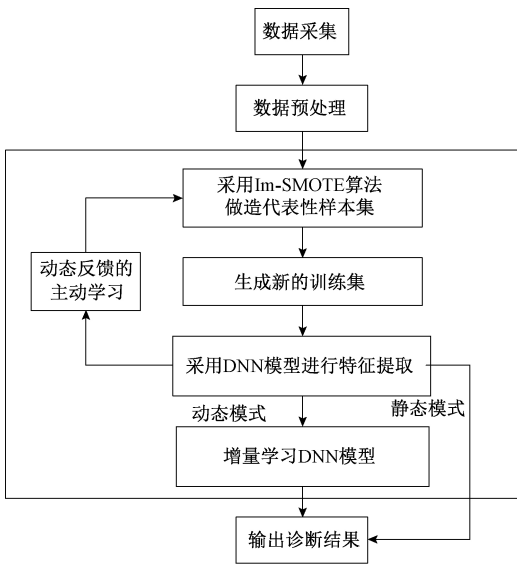


图 13 Incremental-IMDNN 模型流程

Fig.13 Flow chart of incremental-IMDNN model

在上述解决数据不平衡问题方案之外, Jia 等<sup>[101]</sup>提出了一种用于机械故障不平衡分类的深度归一化卷积神经网络(DNCNN)框架,以解决机械健康状况的不平衡分布问题。在该框架下,采用关系图和权值归一化策略构造归一化层,改进训练过程,并针对不平衡分类问题提出了加权最大损失法。利用 3 个不同不平衡度的轴承数据集对所提出的 DNCNN 进行了验证。分类结果表明, DNCNN 不仅比常用的 CNN 学习更好的特征,而且更有效地解决了不平衡的分类问题。Zhang 等<sup>[83]</sup>提出了一种用于不平衡分类的进化成本敏感(evolutionary cost-sensitive)的深度置信网络(ECS-DBN)。ECS-DBN 使用自适应差分进化来优化错误分类,将评估测量(即 G 均值)结合到目标函数中。在 58 个基准数据集和实际数据集上明显优于其他竞争技术。ECS-DBN 可以通过一些在线学习策略进一步扩展到在线不平衡分类问题。所提出的方法也可以应用于其他深度学习模型。

### 5 深度学习在故障预测的应用

具有故障预测功能,是 PHM 系统与传统设备诊断方法最大的不同点。与针对已有故障现象进行诊断得故障诊断相比,故障预测指的是利用已有的知识,采用预测推理的方法对可能发生的故障做出判断<sup>[80]</sup>。故障预测与故障模式的特性有关,就其实现难度来说,对可能发生的故障预测要高于对已有故障现象进行诊断,尤其是针对突变类故障,现有方法还很难预测。数据驱动的故障预测技术,利用已掌握的系统故障知识,对运行期间的状态动态特性数据进行实时监测,将实际运行状态同历史数

据、相关模型相结合,利用预测方法预计一定时间之后的参数和性能变化趋势。最终准确、快速地提供故障预测信息。因此,对可能发生的故障预测内容包括<sup>[102]</sup>:对于无故障征兆的情况,根据总体寿命期望值对装备的剩余寿命预测(remaining useful life prognostics, RUL)进行预测,即退化趋势的预测;对于有故障征兆的情况,通过分析系统内部关系来确定影响因素和容易导致的故障。

剩余寿命预测是深度学习在故障预测领域的应用重心。卷积神经网络、深度信念网、循环神经网络等深度学习模型已经被用于设备的剩余寿命预测。Al-dulaimi 等<sup>[103]</sup>提出了一个混合深度神经网络模型(hybrid deep neural network, HDNN),如图 14 所示,用于商用航空发动机的剩余使用寿命预测。CNN 和长短时记忆神经网络(long short-term memory neural network, LSTM)是构成 HDNN 模型的两个基本模型。输入数据分别由两条路径并行提取特征:一条路径是经由 LSTM 网络提取,由 3 个 LSTM 分别叠加而成,前两层 LSTM 由 32 个单元构成,后一个 LSTM 由 64 个单元构成,专注于时序列特征特征提取。另一条路径是经由 CNN 提取空间特征,由 3 个卷积层和两个池化层组成,最后通过 3 层全连接层,对上述两条路径提取的特征进行融合,来形成剩余寿命预测目标。同 4 个其他模型相比较,在 C-MAPSS 数据的寿命预测方面,具有显著优势。

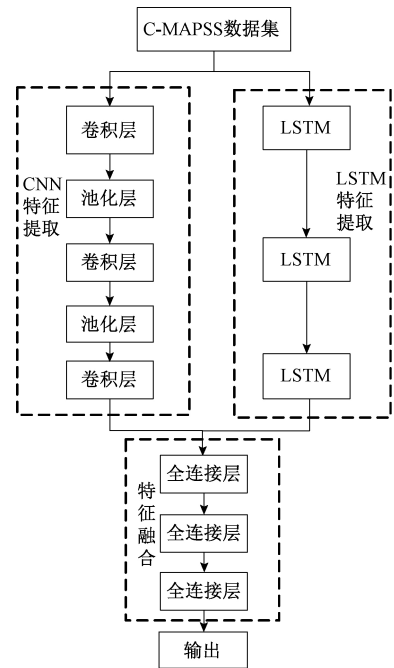


图 14 HDNN 网络框架

Fig.14 Framework of HDNN

Zhang 等<sup>[86]</sup>提出了一种多目标优化的深度信念集成网络(multiobjective deep belief networks ensemble,

MODBNE)模型。该模型中,采用对比散度算法和BP相结合的传统训练技术逐层贪婪训练DBN。优化DBN模型参数包括DBN隐藏层的神经元个数、网络连接权值以及学习率。以DBN模型预测准确性和DBN模型学习的多样性为优化目标。多目标进化算法被用来优化DBN模型。最后将通过多目标进化后选择的多个最优DBN模型相结合,建立一个集成DBN模型,用于装备的寿命预测。集成模型中,每一个DBN的权重系数通过差分进化算法进行了优化。美国宇航局商用模块化航空推进系统仿真数据(C-MAPSS-Data)被用来进行测试验证该模型。实验结果显示,经过优化集成DBN模型性能大幅提高。

Jason等<sup>[84]</sup>开发的DBN-FNN算法各自利用了DBN的学习能力和反馈神经网络(feedback neural networks, FNN)的预测能力优势。首先训练DBN网络,然后用训练好的DBN网络权值初始化FNN网络权重,再采用BP算法训练FNN网络。该模型被用于NASA Glenn螺旋锥齿轮测试设备的预测剩余寿命。Liao等<sup>[45]</sup>提出了一种改进的带正则化项的受限玻尔兹曼机,用于旋转机械的寿命预测,其正则化项试图最大限度地提高输出特征的趋势性。Zhao等<sup>[48]</sup>提出了基于局部特征的循环神经网络(local feature-based gated recurrent unit networks, LFGRU),并用于刀具磨损预测、齿轮箱故障诊断和轴承早期故障检测。Zhang等<sup>[50]</sup>采用长短时记忆(long short-term memory, LSTM)循环神经网络(recurrent neural network, RNN)学习锂离子电池容量退化之间的长期依赖关系。采用弹性均方反向传播方法对LSTM神经网络进行自适应优化,并采用漏出技术对其进行寻优过度拟合的问题。所开发的LSTM RNN能够捕获退化能力之间潜在的长期依赖关系,并构造一个显式的面向能力的RUL预测器。Chen等<sup>[51]</sup>也以C-MAPSS数据为研究对象,开发了一种基于GRU网络和核主成分分析法(kernel principle component analysis, KPCA)的剩余使用寿命预测模型,该模型包括两个阶段:1)将核主元分析(KPCA)应用于非线性特征提取;2)利用新开发的被称之为门控递归单元的递归神经网络对RUL进行估计。

对于有一定故障征兆的情况,对其故障预测本质上仍然是一个模式识别问题,适用于故障诊断的深度学习模型,同样适用于运行中装备的故障预测。在风机齿轮带断裂故障预测的研究中,曹渝昆等<sup>[104]</sup>提出一种基于LSTM深度学习神经网络的故障预测方法,并应用基于某风电厂实际运行数据集的故障预测,能够有效提高风机齿轮带断裂故障预测的精度。Wu等<sup>[105]</sup>利用普通LSTM神经网络,在复杂的操作工况、模型退化、强噪声等情况下,充分利用长短时记忆能力,提出了一种动态差分技术,从原始健康监测数据中提取新的特征,应用于飞

机涡扇发动机健康监测。Olivier等<sup>[106]</sup>将深度学习模型应用于旋转机械的红外线视频状态监控中,在机械故障检测和油位预测的工作中,能够非常准确地检测旋转机械中的多个工况。

在有一定故障征兆的情况下对故障的预测,深度学习算法是一个强有力的工具,然而在突变类故障预测方面,还未见有深度学习的应用,无论是采用传统的方法还是深度学习算法,这都是一个具有挑战性的工作,有待研究者在未来的工作中来解决。

## 6 深度学习在复杂系统健康管理中的应用

面向复杂装备系统的健康管理是PHM系统面临的主要挑战。尽管以齿轮箱和滚动轴承为代表的旋转机械为应用对象的研究居多,但是一些研究者已经开始将深度学习应用于风力涡轮机、航空动力系统、化工过程控制等代表的复杂系统健康管理。除此之外,在水下推进器、数据不完整的废水处理、电源系统、光伏阵列等领域也能见到深度学习技术的应用。

对于复杂系统健康管理的研究者来说,健康信息的获取一直是困扰。美国宇航局商用模块化航空推进系统仿真数据(C-MAPSS-Data)为PHM技术在航空系统领域的应用提供了研究基础。在该领域的研究中,前文所述的Ali等<sup>[103]</sup>、Zhang等<sup>[86]</sup>以及Chen等<sup>[51]</sup>研究团队,以C-MAPSS数据为研究对象,在航空发动机寿命预测方面开发出具有优异的性能模型。3个团队开发的模型都属于混合模型,证明了混合模型是故障诊断和预测的一个重要发展趋势。Ali等<sup>[103]</sup>开发的HDNN模型特点是将LSTM和CNN并行提取的特征相融合,在由几种工作条件和故障模式组成的复杂数据集上有优势,在处理高附加噪声率(低信噪比值)方面还需要提高;Zhang等<sup>[86]</sup>开发的多目标进化集成学习方法(MODBNE),将多目标进化优化算法引入对DBN模型进行参数优化后,集成多个最优DBN模型,这为未来的研究者挖掘单一的深度学习模型潜力提供了一个很好的思路。Chen等<sup>[51]</sup>开发的两阶段模型,在训练时间和预测精度上均优于LSTM,能够为复杂系统的非线性恶化过程提供更好的RUL预测。3种方案都具有代表性,为非线性退化过程的RUL预测提供了一个有效的的解决途径。

在复杂的工业过程控制领域,依据实际化工反应过程,美国Eastman化学公司开发了具有开放性和挑战性的化工模型仿真平台——TEP仿真平台,其产生的数据具有时变、强耦合和非线性特征,已广泛用于测试复杂工业过程的控制和故障诊断模型。Hu等<sup>[42]</sup>提出了一种新的基于大数据的工业故障诊断方法,将深度波尔兹曼机(DBM)与多粒度级联森林(multi-grained scanning forest)

相结合,有效地处理工业故障诊断。在该模型中包括3个阶段:1)DBM首先被用来将原始数据转换成二进制的特征数据;2)通过多粒度扫描算法进一步进行特征提取,多粒度扫描其实是引用了类似CNN的一个滑动窗口,提取的特征与原始特征向量相比,变换后的特征向量具有更高的维数和更广的特征表示;3)采用级联森(cascade forest)算法,经过多个森林多层级联得出预测结果。该算法被应用于TEP故障诊断数据集的分类问题,并同SVM,RF和KNN3个经典的浅层模型相比,具有明显优势。和DBN算法相比较,也有非常强的竞争力。在训练时间方面,所提出的方法是介于RF和DBN之间。图13所示的Incremental-IMDNN模型,也是专门针对化工过程中的数据不平衡问题提供了解决方案。此外,Wu等<sup>[107]</sup>将卷积神经网络应用于化工过程故障诊断,也基于TEP数据集进行了验证。

风力涡轮机也属于典型的复杂系统。调查的200余篇文献中,有约10篇文献是关于风电系统的故障诊断。Lei等<sup>[108]</sup>提出了一种基于端对端的LSTM故障诊断框架模型,直接从多变量时间序列数据中学习特征并捕获长期依赖关系。该模型应用在风力涡轮机的故障诊断中,能够有效地从原始时间序列信号中进行故障分类,并且有良好的鲁棒性。Jiang等<sup>[109]</sup>针对风力发电机的变速箱振动信号固有的多尺度特性,提出了一种新的多尺度卷积神经网络(multiscale convolutional neural networks, MSCNN)结构,用于同时进行多尺度特征提取和分类。Cheng等<sup>[31]</sup>提出了一种基于电机转子电流信号分析的风力发电机传动系变速箱故障诊断方法,构建了由堆叠式自动编码器和支持向量机组成的深层结构,在双馈异步发电机风力发电机传动系试验台上验证了该方法的有效性。Zhao等<sup>[19]</sup>提出了一种基于深度自动编码器的风电机组运行监控深度学习模型。在实际运行中,由于风速的剧烈变化和扰动,计算出的检测指标总是具有极强分布,容易引起误报。针对该问题,文献[19]提出了一种由极值理论确定的自适应阈值,并将其作为异常判断的准则。该方法不仅可以实现故障分量的早期预警,而且可以利用深度自动编码器残差推断出故障分量的物理位置。最后,通过对某风电机组部件故障实例的分析,验证了该方法的有效性。

在其它复杂装备系统健康管理研究中,Gao等<sup>[74]</sup>针对飞机燃油系统,将经典的深信念网络和量子启发神经网络结合,开发了一种改进的深度量子神经网络,用于飞机燃油系统故障诊断。Ki等<sup>[110]</sup>在半导体制造过程的故障检测与分类(FDC)领域,对传感器信号对制造结果的预测进行了研究,提出了一种卷积神经网络模型,利用多变量传感器信号沿时间轴滑动的接收场提取故障特征,使第一卷积层的输出与原始数据的结构意义相关联,从

而能够定位表示进程故障的变量和时间信息。在一个化学气相沉积过程的实验中进行了验证。Wang等<sup>[15]</sup>提出了一种基于多传感器数据融合和瓶颈层优化卷积神经网络,应用于离心泵的故障诊断。Han等<sup>[68]</sup>提出了一种将时空模式网络与卷积神经网络相结合的新诊断框架,应用于复杂系统,形成了适应不同工况和不同故障严重程度的自适应分类。Li等<sup>[111]</sup>结合卷积神经网络在特征提取和自编码器分类方面的强大能力,提出了一种混合故障诊断模型,对脱丙烷精馏过程进行了实例研究。Yan等<sup>[112]</sup>提出了设备心电图的概念,开发了一种基于去噪自动编码器和回归运算的工业设备剩余使用寿命预测算法。Wang等<sup>[113]</sup>利用变分自编码器建立了一个不确定非线性过程的监测框架,应用于工业造纸机故障诊断。在约束条件下,所学习的潜在变量相互独立。该方法提供了隐变量和残差的密度估计。利用密度函数设计合适的监测指标。

## 7 评价与讨论

### 7.1 优势和不足

随着社会的自动化和技术效率的提高,在工业4.0背景开展的智能制造,实施更有效的健康监测维护变得非常重要。浏览近年数百篇关于深度学习方法在PHM领域的应用,确实提供了足够令人信服的结果,这使其更具吸引力。

与传统的机器学习方法相比,深度学习模型因为深层次的体系结构,逐层学习有用特征的学习方式,可以自动发现大型数据集中蕴含的故障模式特征,从而实现自动学习特征,不需要专门的特征提取器。在故障诊断与预测的精度方面,要优于KNN、贝叶斯网络、支持向量机和传统人工神经网络为代表的经典方法。在某些应用场景,支持向量机和传统人工神经网络的故障诊断与预测精度能够达到与深度学习模型相当的精度,但是在噪声环境下的鲁棒性方面,深度学习模型要优于前者。除此之外,传统人工神经网络容易陷入梯度爆炸和过拟合陷阱,深度学习模型可以有效避免类似问题。但是在计算速度方面,由于深度学习模型的计算复杂性高于支持向量机和传统人工神经网络,训练的时间方面要多于后者。深度学习模型本质上是从传统的神经网络发展起来,与传统的神经网络类似,深度学习模型被视为“黑匣子”,因此在学习到的特征的物理意义不如KNN和贝叶斯网络。由于深度学习模型的训练需要大量的数据,因此在训练样本方面,深度需要海量样本数据,如何应对小样本情况,这是未来深度学习模型在PHM领域需要面对的问题。

就自编码器、深度波尔曼兹机、深度信念网、卷积神

神经网络和循环神经网络代表的几种深度学习模型来看,卷积神经网络具备强大的特征学习能力,适合多维数据的特征提取,在故障模式特征学习方面具备优势,但是计算复杂度较高,就训练时间来看,深度信念网和自编码器家族又优于卷积神经网络家族;深度信念网和深度波尔曼兹机都是基于受限波尔曼兹机发展起来的。受限波尔曼兹机本身可视为一种深度学习模型,擅长处理无标签数据,可以从输入提取重要特征,在降维方面比PCA更有效。深度信念网擅长处理一维数据,特征学习能力强,能够稳定的从原始数据中学习故障特征;深度波尔曼兹机可以作为很好的生成模型,所有层的参数可以联合优化,保留了模糊输入包含的不确定信息,较深度信念网而言,训练时间要慢一些;自编码器简单,易于实现,可多层堆叠,为无监督学习。为了更丰富的特征信息表示,自编码器易于修改,基于自编码器,开发出来很多种变种模型,是PHM领域应用最多的深度学习模型之一。缺点是每一层都需要被贪婪地训练,要求大量的训练数据,无法确定学习到的特征是否是相关的;循环神经网络及其变种因为其在时序数据处理方面的优势,在故障部件的剩余寿命预测方面应用最多。

关于在故障诊断和预测中普遍存在不确定性问题,在笔者调查的文献中,针对用于训练模型的数据(源域)和在运行环境中实现故障诊断和预测的目标域数据分布不一致问题,领域自适应(DA)技术已经被引入深度学习模型,用来解决或缓解数据的不稳定性问题。引入了生成性对抗性网络的深度对抗学习模型和引入了迁移学习的深度迁移学习模型,在解决源域和目标域数据分布一致的问题上卓有成效。除此之外,为了应对复杂工况,提高模型泛化能力,加强局部特征学习、采用优化算法对模型参数进行优化、改进数据预处理技术、多模态数据融合、以及多种模型混合集成等技术路线不断融入深度学习框架,有力提升了模型的泛化能效。随着各种技术的引入,不可避免会增加模型的计算复杂性。关于不确定性问题的研究,已经有很多工作存在,模糊神经网络为此类问题提供了一定解决方案。在具体应用中深度学习模型在如何避免神经网络类在该类问题中存在的缺陷,还需要进一步深入研究。

## 7.2 未来的发展方向

围绕深度学习模型,在这一领域有几个未来的发展方向。

1) 开发泛化能力强的模型。大多数应用都是在实验环境下采集数据。实际情况要复杂得多,不确定性因素也很多。由历史数据训练获得故障预测与诊断模型如何延拓,才能保证中长期故障预测与诊断的准确性,是当前面临的一大挑战。为了提高模型的泛化能力,迁移学习技术已经被引入,分别构造了不同的域自适应深度学习

模型,在训练数据上也尽可能模拟不同工况,然而针对实际运用,模型的泛化能力仍然有待加强。

2) 为数据不平衡、数据不完整问题提供有效解决方案。装备系统在大部分运行阶段处于正常工作状态,在运行过程中很少发生故障。因此,设备故障的数据样本比正常情况下的数据样本更难以采集。因此,不同健康状况下的数据样本呈长尾分布,即正常状态的数据样本丰富,而含有故障的数据样本相对稀少。数据样本的不平衡分布迫使故障诊断模型偏向大多数健康状态。针对类似问题,文献[96-99]和[30]将对抗学习技术引入,分别构造了不同的深度学习模型,还有其他少量文献([100-101]和[83])尝试解决,结合实际应用,还需要加强研究。

3) 开发针对小样本的深度学习模型。一般意义上,深度学习模型的训练需要海量数据。然而,实际运行的复杂装备系统的健康信息的获取,并不是一件很轻松的事情。由于历史原因,存在的样本数据往往偏少甚至没有,而运行中的设备,大部分运行时间都处于正常工作状态,可以采集到的故障样本数据也是少量。如何针对小样本,开发出相应的深度学习模型,在笔者调查的文献中,没有针对此问题进行专门研究,是难点,但无法回避。

4) 基于深度学习模型的PHM技术的工程化。OSA-CBM体系结构对PHM技术工程化具有指导意义。随着各种新技术、新算法的应用,PHM系统所需的各种资源也是不断更新和完善的,应采用怎样的系统结构以适应这一要求也是需要解决的。目前基于深度学习模型的PHM技术,更多还是停留在实验环境下进行验证,少有应用在真正的工程应用中,对算法的复杂度,架构的训练所需的时间、计算能力和可能的处理成本缺乏考虑,将深度学习模型应用于运行环境中的设备故障预测与健康的管理,当属未来发展方向。

## 8 结 论

本文对设备健康管理深度学习的相关研究进行了综述,从文献回顾中认识到,在系统健康监测中应用深度学习体系结构的兴趣越来越大。深度学习已经是设备智能健康管理领域的研究热点,尤其是在中国范围内,有超过60所机构的研究团队在开展相关研究工作,应用在包括旋转机械在内的42个以上的领域。自编码器、深度波尔曼兹机、深度信念网、卷积神经网络和循环神经网络、深度多层感知器、深度残差网络等深度学习架构都已经广泛应用于设备健康管理,并基于不同的应用开发出来新的深度学习架构。自动提取数据特征的端对端学习模型已取得显著成功,域自适应技术被用来解决或缓解数据的不稳定性问题,迁移学习和生成对抗网络已经被用来

解决域自适应问题,并取得一定进展,研究者们开始尝试开发解决数据不平衡问题的深度学习模型。针对不确定性问题、模型的泛化能力问题,尽管已经在尝试解决,但仍然有很大的空间。本文介绍了业界的一些需求和最新进展,但作者无法完整评估这些方法的有效性。尽管如此,相信深度学习目前仍然是设备智能健康管理领域的学术前沿方向。

## 参考文献

- [1] SAMIR K, TAKEHISA Y. A review on the application of deep learning in system health management [J]. *Mechanical Systems and Signal Processing*, 2018, 107: 241-265.
- [2] ZHAO R, YAN R Q, CHEN ZH H, et al. Deep learning and its applications to machine health monitoring [J]. *Mechanical Systems and Signal Processing*, 2019, 115: 213-237.
- [3] DUY-TANG H, HEE-JUN K. A survey on deep learning based bearing fault diagnosis [J]. *Neurocomputing*, 2019, 335: 327-335.
- [4] 年夫顺. 关于故障预测与健康管理技术的几点认识[J]. *仪器仪表学报*, 2018, 39(8): 1-14.  
NIAN F SH. Viewpoints about the prognostic and health management [J]. *Chinese Journal of Scientific Instrument*, 2018, 39(8): 1-14.
- [5] GEOFFREY E.H, SIMON O, YEE-WHYE THE. A fast learning algorithm for deep belief nets, *Neural Comput*, 2006, 18(7): 1527-1554.
- [6] JIA F, LEI Y G, LIN J, et al. Deep neural networks: a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data, *Mech. Syst. Signal Process*, 2016, 72-73: 303-315.
- [7] 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.
- [8] 蒋觉义, 李璠, 曾照洋. 故障预测与健康管理体系研究 [J]. *测控技术*, 2013, 32(11): 1-9.  
JIANG J Y, LI F, ZENG ZH Y. Research on standard architecture of prognostics and health management [J]. *Measurement and Control Technology*, 2013, 32(11): 1-9.
- [9] 孙强, 岳继光. 基于不确定性的故障预测方法综述 [J]. *控制与决策*, 2014, 29(5): 769-778.  
SUN Q, YUE J G. Review on fault prognostic methods based on uncertainty [J]. *Control and Decision*, 2014, 29(5): 769-778.
- [10] 王少萍. 大型飞机机载系统预测与健康关键管理技术 [J]. *航空学报*, 2014, 35(6): 1459-1472.  
WANG SH P. Prognostics and health management key technology of aircraft airborne system [J]. *Acta Aeronautica et Astronautica Sinica*, 2014, 35(6): 1459-1472.
- [11] CHEN ZH Q, LI CH, RENÉ-VINICIO S. Gearbox fault identification and classification with convolutional neural networks [J]. *Shock and Vibration*, 2015, 2015(2): 1-10.
- [12] LONG W, LIANG G, LI X Y, et al. A Jointed Signal Analysis and Convolutional Neural Network Method for Fault Diagnosis [C]. *51st CIRP Conference on Manufacturing Systems*, 2018, 72: 1084-1087.
- [13] LONG W, LI X Y, LIANG G, et al. A new convolutional neural network-based data-driven fault diagnosis method [J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(7): 5990-5998.
- [14] ZHU ZH Y, PENG G L, CHEN Y H, et al. A convolutional neural network based on a capsule network with strong generalization for bearing fault diagnosis [J]. *Neurocomputing*, 2019, 323: 62-75.
- [15] WANG H Q, LI SH, SONG L Y, et al. A novel convolutional neural network based fault recognition method via image fusion of multi vibration signals [J]. *Computers in Industry*, 2019, 105: 182-190.
- [16] CHEN ZH Q, DENG SH C, CHEN X D, et al. Deep neural networks-based rolling bearing fault diagnosis [J]. *Microelectronics Reliability*, 2017, 75: 327-333.
- [17] CHEN ZH Q, CHEN X D, LI CH, et al. Vibration-based gearbox fault diagnosis using deep neural networks [J]. *Journal of Vibroengineering*, 2017, 19(4): 2475-2496.
- [18] SHEN CH Q, QI Y M, WANG J, et al. An automatic and robust features learning method for rotating machinery fault diagnosis based on contractive autoencoder [J]. *Engineering Applications of Artificial Intelligence*, 2018, 76: 170-184.
- [19] ZHAO H SH, LIU H H, HU W J, et al. Anomaly detection and fault analysis of wind turbine components based on deep learning network [J]. *Renewable Energy*, 2018, 127: 825-834.
- [20] WANG J R, LI SH M, AN Z H, et al. Batch-normalized

- deep neural networks for achieving fast intelligent fault diagnosis of machines[J]. *Neurocomputing*, 2019, 329: 53-65.
- [21] REN L, SUN Y Q, CUI J, et al. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks[J]. *Journal of Manufacturing Systems*, 2018, 48:71-77.
- [22] ZHANG SH H, SUN ZH ZH, LONG J Y, et al. Dynamic condition monitoring for 3D printers by using error fusion of multiple sparse auto-encoders [J]. *Computers in Industry*, 2019, 105: 164-176.
- [23] MA S, CHU F L. Ensemble deep learning-based fault diagnosis of rotor bearing systems [J]. *Computers in Industry*, 2019, 105: 143-152.
- [24] GAO Z H, MA C B, LUO Y G, et al. IMA health state evaluation using deep feature learning with quantum neural network[J]. *Engineering Applications of Artificial Intelligence*, 2018, 76: 119-129.
- [25] AHMED HOA, WONG MLD, NANDI AK. Intelligent condition monitoring method for bearing faults from highly compressed measurements using sparse over-complete features[J]. *Mechanical Systems and Signal Processing*, 2018, 99: 459-477.
- [26] SHAO H D, JIANG H K, LI X Q, et al. Intelligent fault diagnosis of rolling bearing using deep wavelet auto-encoder with extreme learning machine[J]. *Knowledge-Based Systems*, 2018, 140:1-14.
- [27] XU L, CAO M Y, SONG B Y, et al. Open-circuit fault diagnosis of power rectifier using sparse autoencoder based deep neural network[J]. *Neurocomputing*, 2018, 311:1-10.
- [28] FAN XU, TSE P W, TSE L Y, et al. Roller bearing fault diagnosis using stacked denoising autoencoder in deep learning and gath - geva clustering algorithm without principal component analysis and data label[J]. *Applied Soft Computing Journal*, 2018, 73:898-913.
- [29] LI Y, CHENG G, LIU CH, et al. Study on planetary gear fault diagnosis based on variational mode decomposition and deep neural networks [J]. *Measurement*, 2018, 130:94-104.
- [30] LIU H, ZHOU J ZH, XU Y H, et al. Unsupervised fault diagnosis of rolling bear-ings using a deep neural network based on generative adversarial networks [J]. *Neurocomputing*, 2018, 315: 412-424.
- [31] CHENG F ZH, WANG J, QU L Y, et al. Rotor-current-based fault diagnosis for DFIG wind turbine drivetrain gearboxes using frequency analysis and a deep classifier[J]. *IEEE Transactions on Industry Applications*, 2018, 54(2): 1062-1071.
- [32] SUN J D, YAN CH H, WEN J T, et al. Intelligent bearing fault diagnosis method combining compressed data acquisition and deep learning[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67 ( 1 ): 185-195.
- [33] JIA F, LEI Y G, GUO L, et al. A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines [J]. *Neurocomputing*, 2018, 272:619-628.
- [34] ZHANG Y Y, LI X Y, GAO L, et al. A new subset based deep feature learning method for intelligent fault diagnosis of bearing [J]. *Expert Systems With Applications*, 2018, 110:125-142.
- [35] SHAO H D, JIANG H K, ZHAO H W, et al. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2017, 95: 187-204.
- [36] MENG Z, ZHAN X Y, LI J, et al. An enhancement denoising autoencoder for rolling bearing fault diagnosis[J]. *Measurement*, 2018, 130:448-454.
- [37] ZHANG Y Y, LI X Y, GAO L, et al. Imbalanced data fault diagnosis of rotating machinery using synthetic oversampling and feature learning [J]. *Journal of Manufacturing Systems*, 2018, 48:34-50.
- [38] WEN L, GAO L, LI X Y, et al. A new deep transfer learning based on sparse auto-encoder for fault diagnosis[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2019, 49(1):136-144.
- [39] QI Y M, SHEN CH Q, WANG D, et al. Stacked sparse autoencoder-based deep network for fault diagnosis of rotating machinery[J]. *IEEE Access*, 2017, 5:15066-15079.
- [40] 袁莉芬, 宁曙光, 何怡刚, 等. 基于改进 SAE-SOFTMAX 的模拟电路故障诊断方法[J]. *电子测量与仪器学报*, 2018, 32(7):36-45.
- YUAN L F, NING SH G, HE Y G, et al. Fault diagnosis method for analog circuit based on improved SAE-SOFTMAX[J]. *Journal of Electronic Measurement and Instrumentation*, 2018, 32 ( 7 ):36-45.
- [41] 蒋爱国, 符培伦, 谷明, 等. 基于多模态堆叠自动编码器的感应电机故障诊断[J]. *电子测量与仪器学报*,

- 2018, 32(8):17-23.
- JIANG A G, FU P L, GU M, et al. Induction motor fault diagnosis based on multimodal stacked auto-encoder[J]. *Journal of Electronic Measurement and Instrumentation*, 2018, 32(8):17-23.
- [42] HU G ZH, LI H F, XIA Y Q, et al. A deep Boltzmann machine and multi-grained scanning forest ensemble collaborative method and its application to industrial fault diagnosis [J]. *Computers in Industry*, 2018, 100: 287-296.
- [43] LI CH, RENE-VINICIO S, GROVER Z, et al. Gearbox fault diagnosis based on deep random forest fusion of acoustic and vibratory signals[J]. *Mechanical Systems and Signal Processing*, 2018, 76-77: 283-293.
- [44] LI CH, RENE-VINICIO S, GROVER Z, et al. Multimodal deep support vector classification with homologous features and its application to gearbox fault diagnosis[J]. *Neurocomputing*, 2015, 168:119-127.
- [45] LIAO L X, JIN W J. Enhanced restricted boltzmann machine with prognosability regularization for prognostics and health assessment [J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(11):7076-7083.
- [46] SAMY N, MATIAS V T. Modeling and soft-fault diagnosis of underwater thrusters with recurrent neural networks[J]. *IFAC PapersOnLine*, 2018, 51-29:80-85.
- [47] TIM D B, KIM V, ROBERT B. Railway track circuit fault diagnosis using recurrent neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(3): 523-533.
- [48] ZHAO R, WANG D ZH, YAN R Q, et al. Machine health monitoring using local feature-based gated recurrent unit networks [J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(2):1539-1548.
- [49] ALBERT Y A, ZHANG X H, BEN B K A, et al. Long short-term memory networks based automatic feature extraction for photovoltaic array fault diagnosis[J]. *IEEE Access*, 2019, 7: 30089-30101.
- [50] ZHANG Y ZH, XIONG R, HE H W, et al. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(7): 5695-5705.
- [51] CHEN J L, JING H J, CHANG Y H, et al. Gated recurrent unit based recurrent neural network for remaining useful life prediction of nonlinear deterioration process[J]. *Reliability Engineering and System Safety*, 2019, 185:372-382.
- [52] 汪久根,柯梁亮.基于残差网络的RV减速器故障诊断[J].*机械工程学报*, 2019, 55(3):73-80.
- WANG J G, KE L L. Fault diagnosis for RV reducer based on residual network [J]. *Journal Of Mechanical Engineering*, 2019, 55(3):73-80.
- [53] ZHAO M H, MYEONGSU K, TANG B P, et al. Deep residual networks with dynamically weighted wavelet coefficients for fault diagnosis of planetary gearboxes[J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(5):4290-4300.
- [54] ZHAO M H, MYEONGSU K, TANG B P, et al. Multiple wavelet coefficients fusion in deep residual networks for fault diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66:4696-4706.
- [55] LI ZH, WANG Y, WANG K SH. A deep learning driven method for fault classification and degradation assessment in mechanical equipment [J]. *Computers in Industry*, 2019, 104:1-10.
- [56] KAOUTAR R, BENJAMIN L, WALTER S, et al. Fault tolerant deep neural networks for detection of unrecognizable situations [J]. *IFAC Papers OnLine*, 2018, 51-24:31-37.
- [57] YANG Y L, FU P Y, HE Y CH. Bearing fault automatic classification based on deep learning[J]. *IEEE Access*, 2018, 6:71540-71554.
- [58] WEI T, HAO CH, XIAN D, et al. DNN-based approach for fault detection in a direct drive wind turbine[J]. *IET Renewable Power Generation*, 2018, 12(10): 1164-1171.
- [59] ZHAO L, WANG X. A deep feature optimization fusion method for extracting bearing degradation features [J]. *IEEE Access*, 2018, 6:19640-19653.
- [60] LEI R, LI Z, SHENG H, et al. Remaining useful life prediction for lithium-ion battery: A deep learning approach[J]. *IEEE Access*, 2018, 6:50587-50598.
- [61] LIU W N, LIANG B, CHENG Y, et al. Deep model based domain adaptation for fault diagnosis [J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(3): 2296-2305.
- [62] 李川,张绍辉,JOSE V D O.基于次优网络深度学习的3D打印机故障诊断[J].*机械工程学报*, 2019, 55(7):73-80.
- LI CH, ZHANG SH H, JOSE V D O. Fault diagnosis for



- 3D Printers using suboptimal networked deep learning[J]. *Journal of Mechanical Engineering*, 2019, 55(7):73-80.
- [63] MIAO H, DAVID H. Simultaneous bearing fault diagnosis and severity detection using a LAMSTAR network-based approach[J]. *IET Science, Measurement & Technology*, 2018, 12(7):893-901.
- [64] ROOZBEH R F, EHSAN H, MARYAM F Z, et al. Information fusion and semi-supervised deep learning scheme for diagnosing gear faults in induction machine systems[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(8): 6331-6342.
- [65] YANG K, LIU R, SUN Y, et al. Deep network analyzer (DNA): A big data analytics platform for cellular networks[J]. *IEEE Internet of Things Journal*, 2017, 4(6):2019-2027.
- [66] 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.
- [67] CHEN ZH Q, LI CH, RENE-VINICIO S, et al. Multi-layer neural network with deep belief network for gearbox fault diagnosis [J]. *Journal of Vibroengineering*, 2015, 17(5):2379-2392.
- [68] HAN T, LIU CH, WU L J, et al. An adaptive spatiotemporal feature learning approach for fault diagnosis in complex systems[J]. *Mechanical Systems and Signal Processing*, 2019, 117: 170-187.
- [69] JIA F, LEI Y G, GUO L, et al. A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines [J]. *Neurocomputing*, 2018, 272:619-628.
- [70] LONG W, LIANG G, XINYU L, et al. A New Snapshot Ensemble Convolutional Neural Network for Fault Diagnosis[J]. *IEEE Access*, 2019, 7:32037-32047.
- [71] SHAO H D, JIANG H K, ZHAO H W, et al. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2017, 95: 187-204.
- [72] ZHAO G Q, LIU X Y, ZHANG B, et al. A novel approach for analog circuit fault diagnosis based on Deep Belief Network [J]. *Measurement*, 2018, 121:170-178.
- [73] TANG SH H, SHEN CH Q, WANG D, et al. Adaptive deep feature learning network with Nesterov momentum and its application to rotating machinery fault diagnosis[J]. *Neurocomputing*, 2018, 305: 1-14.
- [74] GAO Z H, MA C B, SONG D, et al. Deep quantum inspired neural network with application to aircraft fuel system fault diagnosis[J]. *Neurocomputing*, 2017, 238: 13-23.
- [75] LIU ZH B, JIA ZH, CHI-MAN V, et al. Capturing high-discriminative fault features for electronics-rich analog system via deep learning [J]. *IEEE Transactions on Industrial Informatics*, 2017, 13(3):1213-1226.
- [76] XIE J Q, DU G F, SHEN CH Q, et al. An end-to-end model based on improved adaptive deep belief network and its application to bearing fault diagnosis[J]. *IEEE Access*, 2018, 6: 63584-63596.
- [77] ZHANG CH L, HE Y G, YANG L F, et al. Analog circuit incipient fault diagnosis method using DBN Based features extraction [J]. *IEEE Access*, 2018, 6:23053-23064.
- [78] MANDAL S, SANTHI B, SRIDHAR S, et al. Nuclear power plant thermocouple sensor-fault detection and classification using deep learning and generalized likelihood ratio test[J]. *IEEE Transactions on Nuclear Science*, 2017, 64(6): 1526-1534.
- [79] 余博, 田福庆, 梁伟阁. 基于深度卷积变分自编码网络的故障诊断方法 [J]. *仪器仪表学报*, 2018, 39(10):27-35.
- SHE B, TIAN F Q, LIANG W G. Fault diagnosis based on a deep convolution variational auto-encoder network[J]. *Chinese Journal of Scientific Instrument*, 2018, 39(10): 27-35.
- [80] 吴立金, 夏冉, 詹红燕, 等. 基于深度学习的故障预测技术研究[J]. *计算机测量与控制*, 2018, 26(2):9-12.
- WU L, XIA R, ZHAN H Y, et al. Fault prediction technology based on deep learning [J]. *Computer Measurement & Control*, 2018, 26(2):9-12.
- [81] MA M, SUN CH, CHEN X F. Discriminative deep belief networks with ant colony optimization for health status assessment of machine [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(12): 3115-3125.
- [82] SHAO H D, JIANG H K, LI X Q, et al. Rolling bearing fault detection using continuous deep belief network with locally linear embedding [J]. *Computers in Industry*, 2018, 96:27-39.
- [83] ZHANG CH, KAI CH T, LI H ZH, et al. A cost-sensitive deep belief network for imbalanced

- classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(1): 109-122.
- [84] JASON D, DAVID H. Using deep learning-based approach to predict remaining useful life of rotating components[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2018, 48(1):11-20.
- [85] ZHANG CH L, HE Y G, YUAN L F, et al. Analog circuit incipient fault diagnosis method using DBN Based features extraction [J]. *IEEE Access*, 2018, 6:23053-23064.
- [86] ZHANG CH, LIM P, QIN A K, et al. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(10): 2306-2318.
- [87] BIN Y, YAGUO L, FENG J, 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.
- [88] XU Y, SUN Y M, LIU X L, et al. A Digital-twin-assisted fault diagnosis using deep transfer learning[J]. *IEEE Access*, 2019, 7: 19990-19999.
- [89] CAO P, ZHANG SH L, TANG J. Preprocessing-free gear fault diagnosis using small datasets with deep convolutional neural network-based transfer learning[J]. *IEEE Access*, 2018, 6:26241-26253.
- [90] ZHANG B, LI W, LI X L, et al. Intelligent fault diagnosis under varying working conditions based on domain adaptive convolutional neural networks[J]. *IEEE Access*, 2018, 6:66367-66384.
- [91] SUN CH, MA M, ZHAO ZH B, et al. Deep transfer learning based on sparse auto-encoder for remaining useful life prediction of tool in manufacturing[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(4): 2416-2425.
- [92] HASAN M J, ISLAM M M M, KIM J M. Acoustic spectral imaging and transfer learning for reliable bearing fault diagnosis under variable speed conditions [J]. *Measurement*, 2019, 138: 620-631.
- [93] LI X, ZHANG W, DING Q. A robust intelligent fault diagnosis method for rolling element bearings based on deep distance metric learning [J]. *Neurocomputing*, 2018, 310:77-95.
- [94] LI X, ZHANG W, DING Q, et al. Multi-Layer domain adaptation method for rolling bearing fault diagnosis[J]. *Signal Processing*, 2019, 157: 180-197.
- [95] LI X, ZHANG W, DING Q. Cross-domain fault diagnosis of rolling element bearings using deep generative neural networks [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(7): 5525-5534.
- [96] HAN T, LIU CH, YANG W G, et al. A novel adversarial learning framework in deep convolutional neural network for intelligent diagnosis of mechanical faults[J]. *Knowledge-Based Systems*, 2019, 165:474-487.
- [97] 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.
- [98] SHAO S Y, WANG P, YAN R Q. Generative adversarial networks for data augmentation in machine fault diagnosis[J]. *Computers in Industry*, 2019, 106:85-93.
- [99] MAO W T, LIU Y M, DING L, et al. Imbalanced fault diagnosis of rolling bearing based on generative adversarial network: A comparative study [J]. *IEEE Access*, 2019, 7:9515-9530.
- [100] HU ZH X, JIANG P. An imbalance modified deep neural network with dynamical incremental learning for chemical fault diagnosis [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(1):540-550.
- [101] 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.
- [102] 郭建, 徐宗昌, 张文俊. 基于状态的装备故障预测技术综述[J]. *火炮发射与控制学报*, 2019, 40(2): 103-108.  
GUO J, XU Z C, ZHANG W J. An overview of the equipment fault prediction technique based on condition[J]. *Journal of Gun Launch & Control*, 2019, 40(2):103-108.
- [103] AL-DULAIMI A, ZABIHI S, ASIF A. A multimodal and hybrid deep neural network model for Remaining Useful Life estimation[J]. *Computers in Industry*, 2019, 108: 186-196.
- [104] 曹渝昆, 巢俊乙, 王晓飞. 基于 LSTM 神经网络的风机齿轮带断裂故障预测[J]. *电气自动化*, 2019, 41(4):

92-95.

CAO Y K, CHAO J Y, WANG X F. Prediction of wind turbine gear belt breakage based on the LSTM Neural network[J]. *Electrical Automation*, 2019, 41(4): 92-95.

- [105] WU Y T, YUAN M, DONG SH P, et al. Remaining useful life estimation of engineered systems using vanilla LSTM neural networks[J]. *Neurocomputing*, 2018, 275: 167-179.
- [106] OLIVIER J, RIK V D W, MIA L, et al. Deep learning for infrared thermal image based machine health monitoring [ J ]. *IEEE/ASME Transactions on Mechatronics*, 2018, 23(1):151-159.
- [107] WU H, ZHAO J S. Deep convolutional neural network model based chemical process fault diagnosis [ J ]. *Computers and Chemical Engineering*, 2018, 115: 185-197.
- [108] LEI J H, LIU CH, JIANG D X. Fault diagnosis of wind turbine based on long short-term memory networks[J]. *Renewable Energy*, 2019, 133:422-432.
- [109] JIANG G Q, HE H B, YAN J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox [ J ]. *IEEE Transactions on Industrial Electronics*, 2019, 66(4): 3196-3207.
- [110] KI B L, SEJUNE C, CHANG O K. A convolutional neural network for fault classification and diagnosis in semiconductor manufacturing processes [ J ]. *IEEE Transactions on Semiconductor Manufacturing*, 2017, 30(2):135-142.
- [111] LI CH K, ZHAO D F, MU SH J, et al. Fault diagnosis for distillation process based on CNN-DAE[J]. *Chinese Journal of Chemical Engineering*, 2019, 27(3): 598-604.
- [112] YAN H H, WAN J F, ZHANG CHU H, et al. Industrial big data analytics for prediction of remaining useful life based on deep learning [ J ]. *IEEE Access*, 2018, 6: 17190-17197.
- [113] WANG K, FORBES M G, GOPALUNI B, et al.

Systematic development of a new variational autoencoder model based on uncertain data for monitoring nonlinear processes[J]. *IEEE Access*, 2019, 7:22554-22565.

## 作者简介



陈志强,2001年于武汉水利电力大学获得学士学位,2004年于重庆大学获得硕士学位,2011年于日本国立福井大学获得博士学位,现为重庆工商大学人工智能学院教授,主要研究方向为人工智能及其应用、设备智能健康管理、群智能及其应用。

E-mail: czq@ctbu.edu.cn

**Chen Zhiqiang** received his B.Sc. degree in 2001 from WuHan University of Water-Conservancy and Electric Power, WuHan, China, received his M.Sc. degree in 2004 from ChongQing University, received his(her) Ph. D. degree in 2011 from Fukui University, Japan, now he is Professor in Chongqing Technology and Business University. His main research interests include artificial intelligent and its application, machinery healthy maintenance and intelligent system.



José Valente de Oliveira,分别在1992年和1996年于葡萄牙里斯本技术大学电气和计算机工程学院获得博士和硕士学位。现任职于阿尔加维大学,也是CEOT的成员。先后在艾伯特大学(2005年)、洛罗·塞伊大学(2005年)、卡内基·梅隆大学(2012年)、塞阿拉联邦大学(2013年)和厄瓜多尔普罗梅特奥大学担任客座教员,主要研究方向为智能计算与故障诊断。

**José Valente de Oliveira** received the Ph. D. (1996), M. Sc. (1992), and the “Licenciado” (five-years) degree in Electrical and Computer Engineering, all from the IST, Technical University of Lisbon. Currently he is a Faculty at the University of Algarve and a member of CEOT with research interests in interdisciplinary areas of computational intelligence and machine learning. He was a visiting Faculty at University of Alberta (2005), Universidade Nacional de Timor Loro Sae (2005), Carnegie Mellon University (2012), Universidade Federal do Ceará (2013), and an Ecuador Prometeo Researcher at UPS (2015). His main research interests include intelligent computing and fault diagnostics.