

基于深度学习的集成化装备故障诊断方法综述

邢砾文¹, 姚文凯¹, 黄莹²

(1. 武警工程大学 研究生大队, 西安 710086; 2. 武警工程大学 信息工程学院, 西安 710086)

摘要: 集成化装备的结构和功能日益复杂, 传统的故障诊断方法难以进行准确的特征提取, 而深度学习具有强大的学习能力, 能够有效挖掘特征, 适合于集成化装备的故障诊断; 为此, 首先按照应用领域的不同, 分别描述了国内外基于深度学习的故障诊断最新研究进展; 其次, 简要介绍了3种典型的深度学习故障诊断方法(深度置信网络、堆栈自编码机和卷积神经网络), 整理出已经取得的成果和存在的问题并做出总结; 而后将基于深度学习实现故障诊断面临的挑战总结为6种类型, 并根据前文总结出的研究成果提出了研究思路; 最后结合实际应用情况, 提出了4种发展方向。

关键词: 深度学习; 集成化装备; 故障诊断; 方法综述

Overview of Integrated Equipment Fault Diagnosis Methods Based on Deep Learning

Xing Liwen¹, Yao Wenkai¹, Huang Ying²

(1. Brigade of Post-graduate Students, Armed Police Engineering University, Xi'an 710086, China;

2. College of Information and Communication, Armed Police University, Xi'an 710086, China)

Abstract: The structure and function of the integrated equipment is increasingly complex, traditional fault diagnosis methods are difficult to extract accurate features. Deep learning has strong learning ability, which can effectively mine features and is suitable for fault diagnosis of integrated equipment. For this purpose, firstly, the latest research progress of fault diagnosis based on deep learning at home and abroad is described according to the different application fields; secondly, three typical fault diagnosis methods based on deep learning (deep belief networks, stacked auto-encoders and convolutional neural networks) are briefly described, the achievements and challenges are sorted out and summarizes are made; then, the challenges of fault diagnosis based on deep learning are summarized into six types, and the research ideas are proposed according to the research results summarized above; finally, combined with the actual application, four development directions are proposed.

Keywords: deep learning; integrated equipment; fault diagnosis; methods overview

0 引言

装备故障诊断通过分析装备状态的相关数据, 对装备运行状态和异常情况作出判断, 为装备故障恢复提供依据。随着科学技术的发展, 现代装备正朝着集成化方向发展, 系统之间交叉链接使系统的复杂性日益增加, 随着数据采集设备的增多和数字信息的推广, 装备故障诊断已经变得越来越大数据化。传统的人工分析方法难以适应这些变化, 需要计算机和人工智能的帮助才能进行准确的故障诊断, 对智能化的要求越来越高。

在传统的故障诊断方法中, 特征提取是最关键的步骤, 它直接决定了故障诊断的效果。经过多年的发展, 故障诊断具有许多特征, 如时域特征、频域特征、小波能量熵和经验模态分解等。然而, 这些特征大多是经过大量的实验和

经验得到的, 需要很长时间才能获得, 而且过分依赖专家经验知识。对于新的或特定的研究对象, 很难决定应该选择哪些特征, 影响故障诊断效果。

近年来, 深度学习在图像识别、语音处理和文本处理方面具有良好的表现。深度学习是人工智能的一个子域, 因其多隐层网络与自适应的特征提取能力而能够挖掘数据更深层次的本质的特征, 利用原始信号的所有特征, 不舍弃原始数据信息, 能精确地刻画故障数据从观测值到故障类别之间复杂的映射关系, 实现智能故障诊断。首先, 与传统的故障诊断方法相比, 深度学习具有较强的学习能力, 可以从大量数据中学习特征, 减少或消除了故障诊断对专家知识的依赖。其次, 深度学习具有表达复杂关系的能力, 可以准确地描述从传感器信号到设备健康状态的复杂映射。此外, 深度学习非常适用于大数据背景下设备系统的状态监测和故障诊断。最后, 深度学习具有迁移学习的能力, 能够从源域中学习知识, 并通过这些知识协助目标域的分类问题。因此, 具有这些优点的深度学习将被深入研究, 并在集成化装备故障诊断领域得到更广泛的应用。

本文按照应用领域的不同, 分析和总结了近年来国内外的研究现状, 介绍了几种典型的基于深度学习的故障诊

收稿日期: 2019-12-13; 修回日期: 2020-01-20。

基金项目: 国家自然科学基金(61573366)。

作者简介: 邢砾文(1997-), 女, 吉林长春人, 硕士生, 主要从事深度学习、故障诊断方向的研究。

黄莹(1978-), 女, 陕西西安人, 博士生, 教授, 主要从事卫星导航、卫星通信、智能控制、数据融合等方向的研究。

断方法:深度置信网络 (deep belief networks, DBN)、堆栈自编码器 (stacked auto-encoders, SAE)、卷积神经网络 (convolution neural networks, CNN), 并做出总结, 讨论了深度学习在集成化装备故障诊断领域面临的挑战与发展方向。

1 国内外研究现状

正是由于深度学习的明显优势, 基于深度学习的故障诊断方法在机械、电子系统等领域得到了广泛应用, 并不断在新的领域尝试。

1.1 国内研究现状

在轴承领域, 文献 [1] 利用 DBN 完成特征提取, 结合支持向量数据描述方法 (support vector data description, SVDD) 实现异常数据检测。无需故障样本数据即可完成故障诊断, 但只能检测出异常, 不能判断故障类型。文献 [2] 通过网格搜索算法进行参数寻优, 改善手动调节参数没有依据的问题。搭建分布式并行计算平台解决该算法寻优时间过长的的问题。文献 [3] 利用 DBN 提取特征, 计算重构误差, 检测其趋势变化, 并将此作为故障判断准则。该方法能够实现故障诊断但不能对故障进行分类。文献 [4-6] 分别将深度编码网络、堆叠去噪自编码器与支持向量机 (support vector machine, SVM) 结合。首先利用神经网络提取特征, 然后利用 SVM 进行分类。文献 [6] 将频谱特征与时域特征相融合, 利用鲸鱼优化算法进行优化, 实现了不同工况下多种故障类型的可靠识别。文献 [7] 先利用滑动窗口重叠采样技术进行数据增强, 再通过堆叠去噪自编码器降噪, 然后通过反向传播算法 (back propagation, BP) 训练深度神经网络双层分类器, 识别出故障模式及故障程度, 最后用集成学习投票法提高识别准确率。文献 [8] 先采用经验模态分解方法分析信号, 然后利用堆叠稀疏自编码器进行故障诊断, 具有较高准确率。文献 [9] 改进了小波自编码器, 能识别出多种故障类型及故障程度。文献 [10] 将联合领域自适应算法与 CNN 结合, 解决了训练数据与测试数据来自不同概率分布的问题。文献 [11] 改进了深度全序列卷积神经网络, 利用它进行精确诊断。然后, 提出改进后 CDCGAN 方法, 实现由已知数据生成未知数据、由单一数据生成复合数据, 扩充了故障样本。文献 [12-15] 分别利用小波变换、同步挤压 S 变换、离散小波变换、短时傅里叶变换对采集到的时域振动信号进行处理, 得到时频图像或构造时频矩阵, 然后再将其输入 CNN 进行故障诊断。

在齿轮箱领域, 文献 [16] 将故障样本振动信号输入 DBN, 通过对状态变量进行编码和解码, 计算重构误差并将其作为状态检测量, 但该方法不能实现对故障的分类。文献 [17-18] 在多噪声干扰情况下, 提出了一种多样性故障特征提取与集成学习信息融合的故障诊断方法, 提高了故障识别能力和分类稳定性, 对噪声的鲁棒性强。在少故障样本信息情况下, 将堆叠去噪自编码器的去噪能力和生成式对抗网络 (generative adversarial nets, GAN) 的样本

生成能力结合起来, 解决故障样本少的问题。

在变压器领域, 文献 [19-20] 分别利用栈式降噪自编码器、栈式稀疏自编码器进行故障诊断。采取逐层贪婪编码的方式进行自适应的非监督式预训练, 实现高维深层故障特征的自适应提取和挖掘, 进而使用反向传播算法对模型进行监督式微调。最后利用 Softmax 分类器, 对故障进行分类输出。

在通信电台领域, 鞠建波^[21]等人使用去噪自动编码器搭建网络, 通过 BP 算法进行有监督微调, 提升故障分类的准确度。利用上述方法, 通过实验完成了某通信电台的模块级故障诊断。刘程^[22]等人利用深度堆栈自编码网络和 Softmax 分类器完成了短波发信机的故障诊断。

在其他领域^[23-42], 王新颖^[23]等人运用小波分析法提取特征参数, 利用 DAE 进行重构, 具有更高的稳定性和识别率。其中, 文献 [24] 将原始数据分割, 根据故障类型和故障程度设计多个 CNN, 实现分层故障诊断, 该方法负载发生变化时仍有较高识别率, 鲁棒性、泛化性较好。文献 [25] 基于特征学习对 LeNet 进行了改进, 提高了处理海量数据的能力以及泛化能力。吴魁^[26]等人对于多传感器信号, 通过构建测量数据帧进行卷积计算, 实现多通道数据的自然融合。解决了多传感器数据融合、特征提取困难等问题。文献 [27] 利用 Skip-gram 模型进行词向量训练, 并将词向量作为卷积神经网络输入。文献 [28] 先把原始数据制作为语音形式, 再将其转化为语谱图, 最后送入 VGG16 模型中。王应晨^[29]等人先通过堆叠去噪自编码器学习低层特征, 然后通过 DBN 学习深层特征, 最后输入 Softmax 分类器进行分类。李垣江^[30]等人将 GAN 与堆叠稀疏自编码器相结合, 增加数据集的多样性, 提高网络泛化能力。黄予春^[31]等人将云计算技术引入深度学习, 将海量故障数据切片, 再利用 DBN 进行分布式并行处理, 有效实现了大数据条件下的故障诊断。李川^[32]等人提出次优网络, 在传统 DBN 的基础上, 一方面提出预分类方法, 确定更好的网络结构, 另一方面采用精细分类方法, 提高分类的精度。文献 [39] 使用自适应算法优化 DBN, 实现学习速率的自适应变化。

1.2 国外研究现状

受文献 [43] 的启迪, 2006 年辛顿教授提出了深度学习理论^[44]。文献 [45] 首次将深度置信网络应用于飞机发动机故障诊断, 此后越来越多的学者将深度学习应用于故障诊断领域, 并取得了许多研究成果。

在轴承领域, 文献 [46] 通过设计多尺度卷积层, 减少了网络参数和训练时间, 提高了诊断精度和鲁棒性, 使运行更顺畅。文献 [47] 将迁移学习与 CNN 相结合, 将离线 CNN 的浅层迁移到在线 CNN, 实现进行在线故障诊断, 提高诊断的实时性及准确率。文献 [48] 也将迁移学习与 CNN 相结合, 解决了故障数据少、训练数据与实际数据来自不同分布的问题。文献 [49] 利用复 Morlet 小波的连续小波变换对采集到的时域振动信号进行处理, 得到时频图

像或构造时频矩阵, 然后再将其输入 CNN 进行故障诊断。文献 [50] 提出了一种将信号转换为图像的新算法。文献 [51] 将迁移学习与堆叠稀疏自编码器相结合, 获得较高的诊断精度。文献 [52] 采用时变学习率的思想, 在保证迭代率的基础上, 减少了迭代过程中成本函数的振荡, 提取的特征更有利于故障分类。

在旋转机械领域, 文献 [53] 将振动信号的频域信息输入堆叠去噪自编码器, 采用 dropout 技术调整网络参数, 缓解过拟合的发生。文献 [54] 首先从传感器信号中提取时域、频域特征, 然后利用 SAE 进行特征融合, 最后利用 DBN 进一步分类。文献 [55] 采用非线性投影实现压缩采集, 然后通过堆叠稀疏自编码器进行故障诊断, 提供了处理海量数据的新策略。文献 [56] 将 SAE 与阶次跟踪相结合, 适应恒速和变速条件, 可以对故障类型和故障程度进行分类。文献 [57] 将 CNN 与多堆栈胶囊相结合, 能够有效地识别和解耦复合故障。

在电机领域, 文献 [58] 采用扩张卷积神经网络, 能够处理一维数据, 无需手工特征提取, 泛化性好。文献 [59] 将电机速度考虑在内, 将振动信号视为图像输入 CNN, 通过降低模型复杂性减少了过度拟合并提高了精度。

在齿轮箱领域, 文献 [60] 将故障样本振动信号输入 DBN, 增加了批量标准化, 降低过度拟合概率, 提高收敛速度。文献 [61] 使用多个噪声级别来训练 AE, 具有更好的鲁棒性, 更高的准确率。文献 [62] 提出了一种新的多尺度卷积神经网络结构, 可同时进行多尺度特征提取和分类。

文献 [63-69] 分别对航空发动机、感应电动机、风力发电机、液压设备、悬链支撑装置紧固件、无人机系统、航空发动机传感器进行故障诊断。其中, 文献 [64] 基于粒子群对网络进行了优化。文献 [67] 按从粗到精的方式级联 3 个基于深度卷积神经网络的检测阶段, 在复杂环境下具有较高的检测率、良好的适应性和鲁棒性。文献 [68] 利用线性二次调节控制器产生故障信号, 并将其转化为图像, 利用时频振幅图中的彩色图像进行故障分类。文献 [69] 利用主成分分析法进行降维, 提高算法效率。

2 典型深度学习模型及故障诊断方法

目前较为熟悉的深度学习模型主要包括以下 3 种: DBN、SAE、CNN。

2.1 基于 DBN 的故障诊断方法

DBN 由多个限制玻尔兹曼机 (restricted boltzmann machine, RBM) 堆叠而成, 其核心是用逐层贪婪学习算法去优化深度神经网络的连接权重, 即使用无监督学习方式逐层训练, 较低层的 DBN 可以提取低级特征, 而较高层用于表示输入数据的更抽象的特征。以图 1 为例, 本文的 DBN 由三层 RBM 堆叠而成, 每个 RBM 是一个双层能量模型, 由可见层与隐含层组成, 连接仅存在于输入层的可见单元和隐含层的隐藏单元之间。




图 1 DBN 结构

DBN 学习过程包括两个阶段: 第一阶段, 逐步预训练 RBM 层。将训练数据输入到可见层中, 训练第一层 RBM, 低层 RBM 的输出作为高一层 RBM 的输入, 重复该训练过程, 直到最后一层 RBM 训练完毕。第二阶段, 微调整个网络以调整参数实现理想的性能。在微调阶段, 为分类问题添加表示所需输出的最后一层变量, 并使用反向传播算法 (back propagation, BP) 优化整个权重和偏差。

DBN 有很多优势。首先, 它能够自适应地提取出故障特征, 不需要依赖于大量信号处理技术以及专家经验, 能够实现智能化的故障诊断; 其次, 它不需要时域信号具有周期性, 因此能广泛适用于诸多领域; 最后, 它能够处理高维、非线性数据, 适合大数据时代的集成化装备故障诊断。

基于 DBN 的故障诊断可以达到较高的精确度。针对故障数据少的问题, 可以通过仿真系统进行模拟, 产生大量故障信号。针对超参数设置对网络效果有较大影响的问题, 可以采用超参数自动优化方法, 如网格搜索、随机搜索算法、遗传算法、粒子群算法, 贝叶斯优化算法等。其中网格搜索与随机搜索最为简单实用, 但网格搜索适用于极少超参数的优化。网格搜索的计算复杂度会随着超参数数量增长而指数型增长, 随机搜索一定程度上避免了这个问题。针对网络训练时间长的问题, 可以搭建分布式并行计算平台。针对网络收敛速度慢, 可能发生过度拟合的问题, 可以增加批量标准化。为了确定网络结构参数、提高分类精度, 可以利用次优网络。此外, DBN 成功地与云计算相结合, 适合处理大数据背景下的故障诊断。

基于 DBN 的故障诊断还面临许多挑战。在搭建网络时, 还存在网络深度不够的问题。实验时需要设定很多参数, 这些参数对实验结果有非常大的影响, 如何设置参数也是一个值得研究的问题。实验数据与实际数据还存在很大差异, 如何利用实验得到的模型对实际运行中的数据进行高准确率故障诊断也是值得研究的方向。

2.2 基于 SAE 的故障诊断方法

堆栈自编码器由多个自编码器堆叠而成。自编码器

(autoencoder, AE) 是一个只有一个隐藏层的对称神经网络。AE 包含编码器网络和解码器网络。编码器网络将输入数据从高维空间转换为具有较低维度的特征空间, 而解码器网络可以从特征空间重建输入数据。由于 AE 可以在没有标签信息的帮助下重建输入信号, 因此它可以以无监督方式学习, 可用于提取原始数据的典型特征。AE 的基本结构如图 2 所示。




图 2 AE 结构

由于 AE 的固有特性是提取原始信号的有意义的特征, 并在输出层恢复它们, 因此应避免简单地从输入层复制到隐含层。AE 的许多变种可以弥补这个缺点, 例如去噪自动编码器 (denoising autoencoder, DAE) 和稀疏自动编码器 (sparse autoencoder, SAE)。它们堆叠起来就是堆叠去噪自动编码器 (stacked denoising autoencoder, SDAE) 和堆叠稀疏自动编码器 (stacked sparse autoencoder, SSAE)。DAE 为了提高 AE 的鲁棒性, 给输入数据附加额外噪声的污染, 训练自动编码器模型以重建完整的无噪声数据。SAE 是通过惩罚隐含层单元的偏差来学习相对稀疏特征的经典变体之一。它提高了传统 AE 的性能, 展现了更多的实际应用价值。

在预训练阶段, 采用逐层贪婪算法由低到高单独训练每个 AE, 低层 AE 的隐含层输出作为高层 AE 的输入, 直至完成所有 AE 的训练。而后利用 BP 算法、梯度下降算法等进行微调, 最后输出结果。

堆栈自编码器有很多优点。首先, 它具有很强的表达能力, 可以减少冗余数据, 降低维数, 适合处理高维稀疏数据。同时, 它可以降低噪声的影响, 无需对信号进行降噪处理。最后, 它使用少量数据进行训练, 再加上适当的分类技术就可以实现高效的故障诊断, 体现了强大的特征提取能力和鲁棒性。

基于 SAE 的故障诊断不仅可以判断故障类型, 还可以有效识别故障程度。堆栈自编码器与 DBN 相结合, 可以进行进一步故障分类; 与滑动窗口重叠采样技术相结合, 可以对数据进行增强; 与迁移学习相结合, 可以解决训练集与测试集来自不同分布的问题; 与阶次跟踪相结合, 可以在恒速和变速条件下自动进行旋转机械故障诊断; 与集成学习信息融合, 可以进

一步提高故障识别能力和分类稳定性; 与 GAN 相结合, 可以生成故障数据, 解决故障数据不足的问题; 与非线性投影相结合, 进行压缩采集, 可以有效处理海量数据。

虽然 SAE 已经成功应用于很多领域, 但还有很多问题需要研究: 如何合理设置网络的隐藏层层数、节点数; 如何对梯度下降法进行改进, 从而获得更好的局部极值点, 甚至是全局最优值; 如何判断所学特征的优劣, 并且如何做以解释; 如何在大数据、高维、多样化的数据背景下进行故障诊断等等。

2.3 基于 CNN 的故障诊断方法

卷积神经网络由 Yann LeCun 提出, 是第一个成功训练多层网络的算法, 也是最广泛使用的深度学习模型之一, 具有强大的特征提取能力。典型的卷积神经网络 LeNet-5 的结构如图 3 所示。网络分为输入层、卷积层、子采样层、全连接层和输出层。

卷积层也称为特征提取层, 卷积层通过不同的卷积核卷积前一层, 每个卷积核对应于一个提取的特征, 与前一层的感受野连接。卷积核共享网络权重, 每个卷积核提取有限的信息, 因此通常使用多个卷积内核来获取更多信息。子采样层也称为特征映射层, 对从卷积层提取的特征进行子采样。通过子采样, 大大减少节点数量, 有效减少了网络连接数量和网络计算的复杂性。全连接层中的所有神经元节点都与前一层节点互连。

用于解决分类问题的卷积神经网络包括两个过程: 训练和测试。训练集用于训练网络, 然后将测试集中的样本输入到训练的网络以测试网络的分类效果。训练过程需要前向和反向传播, 而测试过程只需要前向传播。模型训练结束后, 即可用于分类。

CNN 有很多优点。它具有良好的容错能力、并行处理能力和自学习能力, 可以处理环境信息复杂、背景知识不清楚、推理规则不明确情况下的问题, 允许样品有较大的破损、畸变, 运行速度快, 自适应性好。与传统的神经网络相比, CNN 引入了权值共享和感受野的概念, 减少了需要学习的参数量, 拥有更强的学习能力, 适合处理高维数据, 能够学习海量数据中的特征。CNN 不仅可以处理一维数据, 还擅长处理二维数据。

基于 CNN 的故障诊断有很多成功的经验: 将联合领域

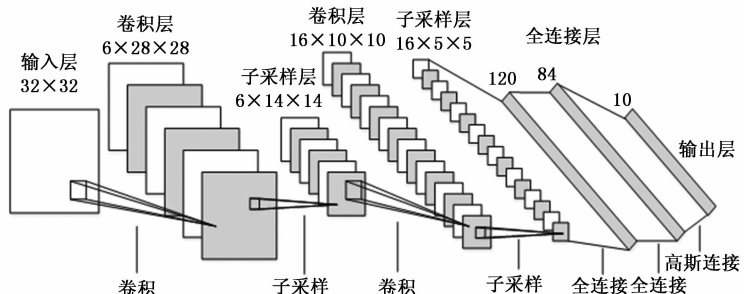


图 3 LeNet-5 结构

自适应算法与 CNN 结合, 可以解决训练数据与测试数据来自不同概率分布的情况下诊断准确率的问题; 将 CGAN 与 DCGAN 结合, 提出 CDCGAN, 可以实现从单一故障和部分复合故障样本, 生成指定类别复合故障样本, 解决了故障数据少的问题; 把原始数据分段, 设计多个 CNN, 可以实现分层故障诊断, 诊断出故障类别和程度; 利用深度解耦卷积神经网络可以有效识别、解耦复合故障; 通过构建测量数据帧进行卷积计算可以将多传感器数据进行融合; CNN 与主成分分析法相结合可以进行降维, 提高效率。

基于 CNN 的故障诊断还面临着很多挑战: 如何对数据进行预处理, 以避免神经元被过度激活, 出现收敛失败的现象; 如何合理设置网络参数, 达到最佳诊断效果; 如何寻找合适的策略对参数进行优化; 如何提高模型的可扩展性, 实现对新故障的识别; 如何提高 CNN 提取泛化特征的能力; 如何使实验结果更贴近于实际条件, 提高模型的稳健性; CNN 适合对哪些领域进行故障诊断等等。

2.4 基于深度学习的故障诊断方法小结

1) 典型深度学习算法直接应用。深度学习应用于一些新的领域, 还未进一步发展, 或典型深度学习算法已能达到较好诊断效果时, 一般可以直接应用。

2) 深度学习算法之间的结合。DBN、SAE、CNN 之间相互结合或同种算法的结合, 可以应用于不同诊断阶段, 按照从粗到精的顺序实现分层故障诊断, 诊断出故障类别及程度, 或者一个用作特征提取, 另一个用作分类器。同时, 典型神经网络还可以与 GAN 相结合, 利用 GAN 的样本生成能力解决故障数据不足的问题。

3) 深度学习算法与浅层学习算法的结合。浅层学习算法主要有 BP 算法、SVM、Boosting、最大熵方法等。浅层学习算法网络层数少, 特征提取能力有限, 难以解决复杂分类问题。其中, BP 算法被广泛应用于微调网络参数, SVM 也与深度学习成功结合, 可以利用深度神经网络进行特征提取, 利用 SVM 进行分类。传统 SVM 只能进行二分类, 改进后可以实现多分类。

4) 深度学习算法与信号处理方法的结合。可以利用小波变换、傅里叶变换、S 变换、经验模态分解等方式对信号进行处理, 或利用 Skip-gram 模型进行词向量训练, 也可以把原始数据制作为语谱图, 再输入神经网络。通过信号处理, 可以充分展现故障特征, 提高故障诊断效果。

5) 深度学习算法与其他机器学习算法的结合。

(1) 与模糊聚类方法相结合。模糊聚类方法属于无监督学习, 常用算法有模糊 C 均值聚类、可能性 C 均值聚类等, 能够根据数据的相似性进行故障分类, 可以提高分类效果或用于未知故障的学习。

(2) 与迁移学习相结合能够解决实验数据与实际数据来自不同概率分布条件下故障诊断准确率的问题。

(3) 与主成分分析法相结合, 可以对数据进行降维, 提高诊断效率, 适用于海量数据的故障诊断。

6) 深度学习算法与其他技术的融合

(1) 与云计算相结合适用于大数据背景下的故障诊断。

(2) 与数据融合技术相结合。故障诊断的数据可能来自不同传感器, 具有不同的数据类型, 需要进行数据融合后再利用深度学习进行故障诊断。

3 深度学习在集成化装备故障诊断领域的挑战与研究思路

根据以上分析, 可以将面临的挑战划分为以下 6 种类型, 提出了几种可行的研究思路:

3.1 故障数据样本不足

深度学习的方法是建立在大数据基础上的, 然而, 集成化装备通常具有大量正常运行数据和少量有效的故障数据, 如何从大量正常数据中识别出小样本的故障数据是一个值得研究的问题。同时, 故障样本的种类有限, 难以涵盖所有类型, 对于装备运行中出现的新故障类型难以进行有效诊断。

首先, 对于小样本故障数据识别的问题, 可以利用深度学习网络提取特征, 正常数据与异常数据的特征会有较大偏差, 利用基于 SVDD 的异常检测器就可以检测出异常。同时, 对于故障数据数量、种类少的问题, 可以利用仿真软件进行模拟, 获取故障数据样本, 或者将深度学习网络与 GAN 相结合, 扩张故障数据集, 利用已知单一故障样本和复合故障样本生成未知复合故障样本。

3.2 训练数据类型不同

为了全面地监测集成化装备的运行状态, 可能使用多种类型的传感器采集不同信号, 如: 声音、振动、电压、温度等。各传感器数据类型不统一, 给集成化装备的故障诊断带来了困扰。

可以通过数据融合, 将所有传感器信号转化为同一类型的数据, 有利于信号的存储和处理, 从而实现基于深度学习的集成化装备故障诊断。

3.3 大数据背景增大难度

随着集成化装备信号采集设备的增多和运行时间的积累, 最终会获得海量数据, 故障诊断已经变得越来越大数据化。

CNN 具有强大的特征提取能力, 可以输入一维或二维数据, 非常适合处理海量数据。可以将同时段的各设备采集到的信号设计为二维矩阵, 构建成测量数据帧, 再输入 CNN, 从而有效实现故障诊断。同时, 还可以利用非线性投影实现压缩采集, 处理海量数据。或者, 将云计算与深度学习相结合, 利用 MapReduce 框架, 将海量故障数据进行切片处理, 再输入深度学习网络, 进行大数据背景下的集成化装备故障诊断。

3.4 复合故障难以诊断

集成化装备由多个系统组成, 每个系统又由不同的部件、元件组成, 每一部分都可能发生故障, 由于系统之间的密切联系, 故障也可能发生传播, 因此可能短时间内同

时发生多种故障,提高了诊断难度。

对于这个问题,可以将多堆栈胶囊设计为解耦分类器,实现复合故障的解耦。解耦分类器和 Softmax 分类器的主要区别在于分类器可以输出的标签数量。Softmax 分类器只能输出单个标签,而解耦分类器可以输出单个或多个标签,从而能够准确识别和分离复合故障。同时,增加故障样本的种类也可以增多可以诊断出的故障类型。

3.5 参数设置缺乏方法

深度学习神经网络的层数、每层节点数等参数的设置,对于神经网络来说至关重要,而在这方面的研究很少,没有一套系统的方法。

对于参数的初始化,大多数情况下都是通过前人的经验进行参数设置,或者通过初始化算法进行参数的随机初始化,或者在实验中调整参数、不断尝试。对于参数的优化,可以采用网格搜索、随机搜索算法、遗传算法、粒子群算法、贝叶斯优化算法、鲸鱼算法等,随着算法的发展,会出现更多新的算法,但使用时要注意平衡和训练时间之间的关系。

3.6 训练数据与实际数据诊断效果不一致

由于训练数据是在实验环境下采集的,而装备实际使用过程中可能受到多种噪声干扰或硬件干扰,与实验数据会有较大偏差,或者发生未知故障,在这种情况下,利用实验数据训练的网络,对实际装备进行故障诊断时很难获得较好的效果。

为了解决噪声干扰问题,可以使用基于去噪自编码器的神经网络,通过重构含有噪声的样本,使模型具有更高的抗干扰性、鲁棒性。为了解决实际数据与实验数据来自不同分布的问题,可以将迁移学习与深度学习神经网络相结合。迁移学习从源域中学习,利用学到的知识解决目标域的问题,可以有效解决源数据与目标数据来自不同分布的情况下的故障诊断问题。

4 深度学习在集成化装备故障诊断领域应用的发展方向

在实际应用中,还有以下 4 种发展方向。

4.1 装备在硬件上做出相应的改变

基于深度学习的故障诊断在机械等领域得到了广泛应用,如轴承、齿轮箱、电机等等,在这些机械中能够通过传感器等设备快速采集到信号,实现实时状态监测。但是装备上其他单元可能需要使用示波器、频谱仪等仪器,从电路板上的一些测量点获取信号,而一些测量点的信号可能没有被引出机箱,目前获取信号还需要开箱检测,难以实现实时的状态监测,为故障诊断带来了不便,为了将基于深度学习的故障诊断应用于更多领域,需要装备在硬件上做出改变,将相应测量点信号引出机箱。

4.2 基于深度学习的故障诊断系统与状态监测系统的结合

目前集成化装备已有状态监测系统,能够时刻监测各部分状态,粗略判断是否发生故障,但大部分系统却不能

判断故障种类。而基于深度学习的故障诊断系统则能够判断出故障类型。因此,将基于深度学习的故障诊断系统与原有系统进行硬件或软件上的结合,提高其兼容性,充分保留两者的优势是一种发展方向。

4.3 基于深度学习的故障诊断系统与专家经验的结合

基于深度学习的故障诊断能够实现精确的故障定位,将故障定位到板级、模块级等等,但装备系统庞大,需要分层进行故障诊断,先通过状态监测系统、专家经验等方式将故障定位到具体的单元,而后再利用深度学习进一步诊断故障。目前,状态监测系统已能实现粗略的故障定位,但还需维修人员再次明确,将故障定位到具体单元。对于这个步骤,厂家和维修人员根据诊断经验,从故障现象出发,将诊断过程整理成详细的诊断树,维修人员按照诊断树一步步排查即可将故障定位到具体的单元,既充分利用了专家经验,又减轻了诊断难度,维修人员只需掌握简单的知识即可实现单元级的故障诊断。

4.4 嵌入式集成化装备故障诊断系统的构建

现有的大部分研究仅停留在算法层面,而算法研究的最终目的是为了解决实际问题,因此,构建嵌入式集成化装备故障诊断系统是非常重要的。同时,嵌入式系统还可以增加系统的可移动性,系统出现问题可以快速更换。由于集成化装备的结构具有层次性,因此,需要针对不同系统、不同层次的特性,构建嵌入式故障诊断系统,通过采集到的信号直接判断故障类型,高效完成故障诊断。

5 结束语

基于深度学习的集成化装备故障诊断的最终目的是准确判断装备的状态,以确定装备是否需要维修。与传统方法相比,深度学习方法在故障诊断中有更高的准确率、更快的速度,因此,利用深度学习进行集成化装备故障诊断是非常有意义的。本文首先总结了国内外研究现状,然后介绍了深度学习 3 种主要模型的基本理论,包括有效的方法和面对的问题,总结出故障诊断方法,最后指出了在集成化装备故障诊断方面的挑战与研究思路,并提出了在应用中的发展方向。

参考文献:

- [1] 吴魁,王仙勇,孙洁,等. 基于深度学习的故障检测方法[J]. 计算机测量与控制, 2017, 25 (10): 43-47.
- [2] 张士强. 基于深度学习的故障诊断技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2018.
- [3] 赵洪山,刘辉海. 基于深度学习网络的风电机组主轴轴承故障检测[J]. 太阳能学报, 2018, 39 (3): 588-595.
- [4] 袁文军,刘飞,王晓峰,等. 基于深度自编码网络的轴承故障诊断[J]. 噪声与振动控制, 2018, 38 (5): 208-214.
- [5] 张庆磊,张枫. 基于 SDAE-SVM 的压力机轴承故障诊断方法[J]. 数字制造科学, 2018, 16 (3): 203-208.
- [6] 赵春华,胡恒星,陈保家,等. 基于深度学习特征提取和 WOA-SVM 状态识别的轴承故障诊断[J]. 振动与冲击, 2019, 38

- (10): 31-48.
- [7] 马辉,车迪,牛强,等.基于深度神经网络的提升机轴承故障诊断研究[J].计算机工程与应用,2019,55(16):123-129,184.
- [8] 王奉涛,邓刚,王洪涛,等.基于EMD和SSAE的滚动轴承故障诊断方法[J].振动工程学报,2019,32(2):368-376.
- [9] 杜小磊,陈志刚,许旭,等.改进深层小波自编码器的轴承故障诊断方法[J].计算机工程与应用,2020,56(5):263-269.
- [10] 韩树发,于颖,唐堂,等.基于联合领域自适应卷积神经网络的多工况故障诊断[J].微型电脑应用,2019,35(1):4-9.
- [11] 陈伟.深度学习在滚动轴承故障诊断中的应用研究[D].四川:西南交通大学,2018.
- [12] 张应军,江永全,杨燕,等.基于深度卷积神经网络的未知复合故障诊断[J].中国科技论文,2019,14(2):204-209.
- [13] 杜小磊,陈志刚,张楠,等.基于同步挤压S变换和深度学习的轴承故障诊断[J].组合机床与自动化加工技术,2019(5):90-97.
- [14] 陈仁祥,黄鑫,杨黎霞,等.基于卷积神经网络和离散小波变换的滚动轴承故障诊断[J].振动工程学报,2018,31(5):883-891.
- [15] 李恒,张氢,秦仙蓉,等.基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J].振动与冲击,2018,37(19):124-131.
- [16] 刘辉海,赵星宇,赵洪山,等.基于深度自编码网络模型的风电机组齿轮箱故障检测[J].电工技术学报,2017,32(17):156-163.
- [17] 王俊.基于深度学习的行星齿轮箱故障诊断技术研究[D].江苏:南京航空航天大学,2018.
- [18] 金棋,王友仁,王俊.基于深度学习多样性特征提取与信息融合的行星齿轮箱故障诊断方法[J].中国机械工程,2019,30(2):196-204.
- [19] 许倩文,吉兴全,张玉振,等.栈式降噪自编码网络在变压器故障诊断中的应用[J].电测与仪表,2018,55(17):62-67.
- [20] 许倩文,吉兴全,张玉振,等.基于栈式稀疏自编码器的矿用变压器故障诊断[J].工矿自动化,2018,44(10):33-37.
- [21] 鞠建波,胡胜林,祝超,等.基于深度学习的装备故障诊断方法[J].光电与控制,2018,25(2):103-106.
- [22] 刘程,陈斌,瞿珊瑚,等.基于深度学习的短波发信机故障诊断应用[J].通信技术,2018,51(12):3033-3037.
- [23] 王新颖,宋兴帅,杨泰旺.深度学习神经网络在管道故障诊断中的应用研究[J].安全与环境工程,2018,25(1):137-148.
- [24] 曲建岭,余路,袁涛,等.基于卷积神经网络的层级化智能故障诊断算法[J].控制与决策,2019,34(2):2619-2626.
- [25] 乔林翰.基于卷积神经网络的电机故障诊断方法研究[D].兰州:兰州理工大学,2018.
- [26] 吴魁,王仙勇,孙洁,等.基于深度卷积网络的多传感器信号故障诊断方法研究[J].计算机测量与控制,2018,26(1):18-21.
- [27] 李西戎.基于卷积神经网络的网络故障诊断模型[J].软件导刊,2017,16(12):40-43.
- [28] 易灵芝,肖伟红,于文新,等.基于深度学习的模拟电路故障诊断算法[J].计算机工程与应用,2018,54(24):143-148.
- [29] 王应晨,段修生,单甘霖.模拟电路故障的深度学习融合模型诊断方法[J].现代防御技术,2018,46(5):122-128.
- [30] 李垣江,张周磊,李梦含,等.采用深度学习的永磁同步电机匝间短路故障诊断方法[J].电机与控制学报,2008:1-8 [2020-06-23]. <http://kns.cnki.net/kcms/detail/23.1408.TM.20181018.1422.004.html>.
- [31] 黄予春,曹成涛,顾海.基于云计算和深度学习的电力电容器故障诊断和识别[J].电力电容器与无功补偿,2018,39(4):71-75.
- [32] 李川,张绍辉, José Valente de Oliveira.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.
- [33] 唐启东,刘清平,刘文娟.基于深度学习的飞机故障诊断系统关键技术研究[J].航空维修与工程,2018,54-56.
- [34] 彭军,郭晨阳,张勇,等.基于深度学习的航空发动机部件故障诊断[J].系统仿真技术,2018,14(1):20-24.
- [35] 陈俊.基于深度置信网络和支持向量机的计量自动化终端故障诊断方法[J].广西电力,2018,41(5):16-19.
- [36] 陈自强,程健,季文强,等.基于深度置信网络风电机组变桨系统的故障诊断[J].测控技术,2019,38(5):18-22.
- [37] 孙鑫,陈海松,王清.基于深度置信网络的移动电站发电机故障诊断[J].装备制造技术,2019(3):168-182.
- [38] 李炜,雷雪,蒋栋年.基于深度置信网络的车载电源故障诊断方法[J].兰州理工大学学报,2019,45(2):78-83.
- [39] 刘冰尧,庞腾,雷菊阳.基于深度信念网络的变压器故障诊断[J].化工自动化及仪表,2018,45(11):873-878.
- [40] 旷天亮.基于深度神经网络的复杂化工过程故障检测研究[D].广州:华南理工大学,2018.
- [41] 徐继伟,宋保业,公茂法.基于深度神经网络的多电平逆变器故障诊断[J].电测与仪表,2019,56(2):123-128.
- [42] 李炜,崔佳佳.基于深度学习的无人机故障诊断方法研究[J].计算机与数字工程,2019(5):1249-1253.
- [43] Lee T, Mumford D. Hierarchical Bayesian inference in visual cortex[J]. Optical Society of America, 2003, 20(7): 1434-1448.
- [44] Hinton G E. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313: 504-507.
- [45] Tamilselvan P, Wang P. Failure diagnosis using deep belief learning based health state classification[J]. Reliability Engineering & System Safety, 2013, 115: 124-135.
- [46] Zilong Z, Wei Q. Intelligent fault diagnosis of rolling bearing using one-dimensional multi-scale deep convolutional neural network based health state classification[A]. 2018 IEEE 15th International Conference on Networking, Sensing and Control (ICNSC) [C]. Washington, DC, USA: IEEE Computer Society, 2018: 1-6.

- [47] Xu G, Liu M, Jiang Z, Shen W, et al. Online fault diagnosis method based on transfer convolutional neural networks [J]. *IEEE Transactions on Instrumentation and Measurement*, 2019, 10: 1109/TIM. 2019. 2902003.
- [48] Guo L, Lei Y, Xing S, et al. Deep convolutional transfer learning network: a new method for intelligent fault diagnosis of machines with unlabeled data [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66 (9): 7316–7325.
- [49] Gao D, Zhu Y, Wang X, et al. A fault diagnosis method of rolling bearing based on complex Morlet CWT and CNN [A]. 2018 Prognostics and System Health Management Conference (PHM—Chongqing) [C]. Washington, DC, USA: IEEE Computer Society, 2018; 1101–1105.
- [50] Wen L, Gao L, Li X, et al. A new data—driven intelligent fault diagnosis by using convolutional neural network [A]. 2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM) [C]. Washington, DC, USA: IEEE Computer Society, 2017; 813–817.
- [51] Wen L, Gao L, Li X. A new deep transfer learning based on sparse auto—encoder for fault diagnosis [J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 2019, 49 (1): 136–144.
- [52] Zhou F, Yang S, Wen C, et al. Improved DAE and application in fault diagnosis [A]. 2018 Chinese Control And Decision Conference (CCDC) [C]. Washington, DC, USA: IEEE Computer Society, 2018; 1801–1806.
- [53] Chen Z, Li Z. Research on fault diagnosis method of rotating machinery based on deep learning [A]. 2017 Prognostics and System Health Management Conference (PHM—Harbin) [C]. Washington, DC, USA: IEEE Computer Society, 2017; 1–4.
- [54] Chen Z, Li W. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66 (7): 1693–1702.
- [55] Sun J, Yan C, Wen J. Intelligent bearing fault diagnosis method combining compressed data acquisition and deep learning [J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67 (1): 185–195.
- [56] Rao M, Zuo M J. A new strategy for rotating machinery fault diagnosis under varying speed conditions based on deep neural networks and order tracking [A]. 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA) [C]. Washington, DC, USA: IEEE Computer Society, 2018; 1214–1218.
- [57] Huang R, Liao Y, Zhang S, et al. Deep decoupling convolutional neural network for intelligent compound fault diagnosis [J]. *IEEE Access*, 2019, 7: 1848–1858.
- [58] Khan M A, Kim Y, Choo J. Intelligent fault detection via dilated convolutional neural networks [A]. 2018 IEEE International Conference on Big Data and Smart Computing (Big-Comp) [C]. Washington, DC, USA: IEEE Computer Society, 2018; 729–731.
- [59] Han J, Choi D, Hong S, et al. Motor fault diagnosis using CNN based deep learning algorithm considering motor rotating speed [A]. 2019 IEEE 6th International Conference on Industrial Engineering and Applications (ICIEA) [C]. Washington, DC, USA: IEEE Computer Society, 2019; 440–445.
- [60] Liu X L, et al. Fault diagnosis method of wind turbine gearbox based on deep belief network and vibration signal [A]. 2018 57th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE) [C]. Washington, DC, USA: IEEE Computer Society, 2018; 1699–1704.
- [61] Jiang G, He H, Xie P, et al. Stacked multilevel—denoising autoencoders; a new representation learning approach for wind turbine gearbox fault diagnosis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66 (9): 2391–2402.
- [62] 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*, 2019, 66 (4): 3196–3207.
- [63] Jiang H, Shao H, Chen X, et al. Aircraft fault diagnosis based on deep belief network [A]. 2017 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC) [C]. Washington, DC, USA: IEEE Computer Society, 2017; 123–127.
- [64] Wang J, Sun C, Zhao Z, et al. Feature ensemble learning using stacked denoising autoencoders for induction motor fault diagnosis [A]. 2017 Prognostics and System Health Management Conference (PHM—Harbin) [C]. Washington, DC, USA: IEEE Computer Society, 2017; 1–6.
- [65] Jiang G, Xie P, He H, et al. Wind turbine fault detection using a denoising autoencoder with temporal information [J]. *IEEE/ASME Transactions on Mechatronics*, 2018, 23 (1): 89–100.
- [66] Jing L, Yankai L, Shanshan C, et al. Application of deep learning in the hydraulic equipment fault diagnosis [A]. 2018 IEEE International Conference on Smart Manufacturing, Industrial & Logistics Engineering (SMILE) [C]. Washington, DC, USA: IEEE Computer Society, 2018; 12–16.
- [67] Chen J, Liu Z, Wang H, et al. Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network [J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67 (2): 257–269.
- [68] Olyaei M H, Jalali H, Noori A, et al. Fault detection and identification on UAV system with CITFA algorithm based on deep learning [A]. *Electrical Engineering (ICEE)* [C]. Washington, DC, USA: IEEE Computer Society, 2018; 988–993.
- [69] Li J, Qu W. Aero—engine sensor fault diagnosis based on convolutional neural network [A]. 2018 37th Chinese Control Conference (CCC) [C]. Washington, DC, USA: IEEE Computer Society, 2018; 6049–6054.