

DOI: 10.11949/j.issn.0438-1157.20181357

基于深度置信网络的炼化空压机故障诊断方法

鲁春燕^{1,2,3}, 李炜^{1,2,3}

(¹ 兰州理工大学电气工程与信息工程学院, 甘肃 兰州 730050; ² 甘肃省工业过程先进控制重点实验室, 甘肃 兰州 730050; ³ 兰州理工大学国家级电气与控制工程实验教学中心, 甘肃 兰州 730050)

摘要: 针对炼化空压机故障诊断中故障机理复杂、先验知识欠缺, 且传统浅层神经网络诊断精度不高等问题, 结合深度置信网络 (DBN) 在特征提取和处理非线性数据等方面的优势, 提出一种基于 DBN 的炼化空压机故障诊断方法。该方法利用空压机状态监测实测数据, 实现训练网络的无监督特征学习和有监督微调, 构建空压机故障的深层网络模型, 从而实现对空压机故障类型的有效智能诊断。为评估该方法的有效性, 与传统的故障诊断方法进行了比较研究, 结果表明, 该方法的诊断精度优于传统的故障诊断方法, 且稳定性更好。

关键词: 空压机; 深度置信网络模型; 故障诊断; 稳定性

中图分类号: TP273

文献标志码: A

文章编号: 0438-1157 (2019) 02-0757-07

Fault diagnosis method of petrochemical air compressor based on deep belief network

LU Chunyan^{1,2,3}, LI Wei^{1,2,3}

(¹ College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, Gansu, China;

² Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou 730050, Gansu, China;

³ National Experimental Teaching Center of Electrical and Control Engineering, Lanzhou University of Technology, Lanzhou 730050, Gansu, China)

Abstract: According to the complexity of fault mechanism, the lack of prior knowledge, and the low diagnosis precision of traditional shallow layer neural network for the fault diagnosis of petrochemical air compressor, a kind of petrochemical air compressor fault diagnosis method is put forward based on the deep belief network because of its advantage in feature extraction and nonlinear data processing. By using state monitoring data of the air compressor, the method realizes the unsupervised characteristics learning and supervised fine-tuning of training network, constructs the deep network model of the air compressor fault, thus achieving the effective intelligent diagnosis for fault types of the air compressor. The effectiveness of the method is compared with the traditional fault diagnosis method. The results show that the diagnostic accuracy of the method is better than the traditional fault diagnosis method and the stability is better.

Key words: air compressor; deep belief network model; fault diagnosis; stability

收稿日期: 2018-11-16 修回日期: 2018-11-26

通信作者: 李炜 (1963—), 女, 博导, 教授, liwei@lut.cn

第一作者: 鲁春燕 (1976—), 女, 博士研究生, 副教授, luchunyan@sina.com

基金项目: 国家自然科学基金项目 (61364011, 61461028); 甘肃省先进控制重点实验室开放基金项目 (XJK201809)

引用本文: 鲁春燕, 李炜. 基于深度置信网络的炼化空压机故障诊断方法[J]. 化工学报, 2019, 70(2): 757–763

Citation: LU Chunyan, LI Wei. Fault diagnosis method of petrochemical air compressor based on deep belief network[J]. CIESC Journal, 2019, 70(2): 757–763

引 言

空压机作为炼化企业连续重整过程的关键设备,其能否稳定、可靠、安全、高效地运行,对整个连续重整过程起着举足轻重的作用,因此对空压机的状态监测与故障诊断是保证空压机安全运行的必要举措。状态监测是对空压机运行工况参数进行连续监测,从而对空压机运行状态做出实时评价;故障诊断是状态监测后的识别和判断,依据空压机状态监测所获得的数据,及时对空压机异常状态或者故障做出识别和诊断,为空压机的合理检修和健康管理提供科学依据。

由于空压机结构复杂,且工作过程烦琐,在空压机的状态监测与故障诊断过程中,考虑到检测变量数目庞大且变量之间存在高相关性、故障类型多且故障表现形式的多样性和重叠性的特点^[1],很难采用传统建模的方式构建数学模型。另外,随着实时历史数据库在炼化企业系统中的应用,存储了空压机等关键设备在不同工况下的海量监测数据,致使炼化设备的故障诊断与健康管理也进入了“大数据”时代^[2]。因此,研究和利用先进的理论与方法,从炼化设备大数据中及时发现故障征兆、提取故障特征信息并进行预警,高效、准确地识别空压机健康状况,将会成为空压机故障诊断领域面临的新问题。

当前,深度学习在学术界和工业界发展迅猛^[3-17],其本质是通过模拟大脑的学习过程,利用海量的训练数据,构建多隐层的模型,去学习数据中隐含的特征,从而提高数据分类效果,提升识别或预测精度。深度置信网络(deep belief network, DBN)^[18]是一种典型的深度学习方法,凭借其强大的特征自动提取能力、优异的训练算法和处理高维、非线性大数据等方面的优势,已成功应用于手写体识别^[19-20]、目标识别^[21-22]、语音识别^[23]和图像识别^[24-25]等机器视觉领域。从现有文献检索可知,深度学习在故障诊断领域应用研究具有潜在的优势。Tamilselvan等^[26]第一次把DBN理论应用到飞机发动机的故障诊断,对飞机发动机结构健康状态进行识别。Tran等^[27]针对具有瞬态冲击和复杂背景噪声的振动信号,将DBN模型作为分类器实现了往复式压缩机阀门故障诊断,取得了较高的故障识别准确率。李巍华等^[28-29]分别利用DBN方法从原始数据出发,提取轴承故障特征,有效提高了轴承故障类型

识别和故障程度的识别精度。

因此,本文提出了基于DBN的炼化空压机故障诊断方法,该方法利用状态监测实测数据训练深度神经网络,通过构建深层模型,来自适应提取海量数据中隐含的故障特征,从而实现空压机故障类型的诊断和识别。经与BP和PNN方法进行比较,其诊断精度更优且稳定性更好。

1 深度置信网络原理

深度置信网络(DBN)是由多个无监督的受限玻尔兹曼机(restricted boltzmann machine, RBM)和一个有监督的反向传播网络(back propagation, BP)堆叠而成的深度神经网络,如图1所示。




图1 深度置信网络结构

Fig.1 Deep belief network architecture

DBN训练过程包含两个阶段:由低层到高层的前向无监督预训练阶段和由高层到低层的后向有监督微调阶段。第一阶段,利用贪婪算法无监督地单独训练每一个RBM,当低层RBM训练完成,将其隐藏层的输出作为高层RBM的输入,依次逐层传递,继而学习更高层特征,从而不断更新模型参数;第二阶段,采用有监督的方式训练最后一层BP网络,将训练误差从高到低反向传播到每一层RBM,并微调每层RBM之间的参数,直至达到最大的迭代次数,从而使DBN模型参数达到最优。其核心是用贪婪学习算法来逐层优化深度神经网络的连接权重,即首先使用无监督逐层训练的方式,有效地挖掘待诊断设备运行状态信号中的故障特征,然后在相应的分类器中,通过反向的有监督微调来优化DBN的故障诊断能力^[29]。

1.1 受限 Boltzmann 机及其预训练

RBM模型是基于能量的生成式随机神经网络,如图2所示,它是由可视层 v 和隐藏层 h 两层组成,

可视层单元和隐藏单元之间通过权值 ω 对称双向全连接,而相同层内的单元之间无连接。假设一个RBM有 n 个可视单元和 m 个隐藏单元,则其能量函数定义为

$$E(v, h; \theta) = -\sum_{i=1}^n b_i v_i - \sum_{j=1}^m a_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i \omega_{ij} h_j$$

式中, $\theta = \{\omega, b, a\}$ 为网络参数, v_i 为第 i 个可视单元的状态, h_j 为第 j 个隐藏单元的状态, b_i 为可视单元 i 的偏置, a_j 为隐藏单元 j 的偏置, ω_{ij} 为连接可视单元 i 和隐藏单元 j 的权值。




图2 受限 Boltzmann 机

Fig.2 Restricted Boltzmann machine

定义一个可视节点和隐藏节点的联合概率

$$P(v, h; \theta) = \frac{e^{-E(v, h; \theta)}}{\sum_{v, h} e^{-E(v, h; \theta)}} \quad (1)$$

因隐藏层内部和可视层内部均不存在连接,则隐藏层与可视层的条件概率为

$$P(h|v; \theta) = \frac{e^{-E(v, h; \theta)}}{\sum_h e^{-E(v, h; \theta)}} \quad (2)$$

$$P(v|h; \theta) = \frac{e^{-E(v, h; \theta)}}{\sum_v e^{-E(v, h; \theta)}} \quad (3)$$

训练RBM的主要目的是求出网络参数 $\theta = \{\omega, b, a\}$, Hinton等^[30]提出利用对比散度(contrastive divergence, CD)算法,在保证诊断准确率的同时能快速提高收敛速度。

1.2 DBN的微调训练

DBN的预训练是利用贪婪算法无监督逐层训练RBM,实质上是对每层RBM权值优化来保障该层特征向量映射最优,但无法确保DBN模型参数最优。因此,当预训练结束以后,利用有监督BP算法进行特征向量分类,并微调整个DBN模型参数。具体反向微调是利用BP算法将实际分类结果与期望类别产生的误差逐层从高到低回传,并微调每层RBM之间的参数,从而微调DBN模型参数,使训练结果进一步得到优化。

DBN训练完成后,利用模型参数将可视层输入特征映射到高层,利用式(4)提取高层特征

$$y = f(v; \theta) \quad (4)$$

其中, y 为经过DBN映射后提取的高层特征。

2 基于DBN的炼化空压机故障诊断

炼化企业空压机在运行过程中,由于多种因素复合共同作用,其状态监测系统收集的海量监测数据中蕴含了空压机不同工况下丰富多变的故障信息,传统的以浅层模型为基础的故障诊断方法在面对多工况交替、多样性和相关性较强的海量信息时,很难提取反映故障的典型特征。而DBN方法具有强大的从大量数据中自动提取特征的能力,且通过建立深层模型,能够良好地表征状态变量与故障类型之间复杂的映射关系。因此,本文在分析DBN原理的基础上,结合空压机数据特点与DBN的优势,将DBN应用于空压机故障诊断,诊断流程如图3所示。




图3 空压机故障诊断流程

Fig.3 Flow chart of air compressor fault diagnosis

2.1 诊断步骤

基于DBN的炼化空压机故障诊断过程分为以下几个步骤。

(1) 获取空压机的不同运行工况状态数据,进行归一化预处理,确定训练样本和测试样本;

(2) 确定网络相关参数,包括学习率、迭代次数、网络层数和各层节点数等,其中输入层节点数取决于故障样本维数,输出层节点数取决于故障

类别数,隐含层节点数在综合考虑网络结构特性、算法稳定性和收敛速度的情况下,由多次试验调试确定;

(3)逐层训练,将训练样本作为 DBN 的底层输入,以无监督的方式逐层进行 N 个 RBM 训练,即将上一级 RBM 的隐藏层的输出作为下一级 RBM 的输入,直到完成 N 个 RBM 的训练;

(4)微调整个网络,利用有监督方式的 BP 算法反向微调 DBN 网络;

(5)利用训练好的 DBN 模型进行空压机故障诊断。

从以上步骤可以看出,DBN 方法实现了无监督逐层训练和有监督微调的有机结合,可同时完成海量数据故障特征自动提取和故障类型识别,克服了传统方法在特征提取与故障诊断中的局限性。

2.2 故障类型和数据样本

本文以某石化公司连续重整的空压机为研究对象,其中,压缩机和汽轮机用联轴器进行传动,汽轮机输出轴通过弹性联轴器与压缩机的主机直接联装在机架上,汽轮机作为动力源驱动压缩机正常工作。该石化公司通过对连续重整的空压机运行状况的长期监测,正在运行的实时数据库中存储了空压机在正常状态下以及在出现各种故障时的 40 个运行状态变量数据,每个测点数据采集频率为 5 min。考虑到空压机故障类型繁多,本文仅选取了其中的五种运行状态进行试验研究,分别是:正常状态、润滑系统故障、轴承故障、冷却水槽堵塞、级间转子不平衡。通过分析整理实时数据库,选取润滑油供油压力、汽轮机转速、压缩机入口压力、压缩机止推轴承温度、压缩机出口端轴承温度、汽轮机出口端轴承振动和汽轮机轴承位移 7 个运行状态变量作为测量变量。每种运行状态使用 400 个样本集,则空压机故障数据集为 2000 个,即每种故障类型有 2800 个样本,共计 14000 个数据样本。表 1 描述了数据样本信息。

表 1 空压机故障数据集描述

Table 1 Description of air compressor fault datasets

炼化空压机故障状况类型	样本个数	故障类别
正常	2800	1
润滑系统故障	2800	2
轴承故障	2800	3
冷却水槽堵塞	2800	4
级间转子不平衡	2800	5

3 试验验证及结果分析

试验中,随机选取每种运行状态的 75% 作为训练样本,剩余 25% 作为测试样本。为了减少随机因素对试验结果的影响,每次试验重复进行 15 次。本文中 DBN 模型采用 4 层模型,每层神经元个数分别为 7、20、20 和 5,即该 DBN 的网络结构为:7-20-20-5,单元传递函数为 Sigmoid 函数,迭代次数为 600,学习率为 0.1。

3.1 不同迭代次数的诊断分析

在网络训练过程中,迭代次数规定了网络的训练次数,需要不断地反复计算来更新相关参数,从而减小训练误差,提高诊断结果的准确率。因此为了确定合适的迭代次数,训练迭代次数 100 ~ 1000 的故障诊断能力,其中准确率取平均值,具体诊断结果如图 4 所示。




图 4 不同迭代次数的诊断准确率

Fig.4 Diagnostic accuracy of different iterations

由图中诊断结果可以看出,故障诊断准确率随着迭代次数的增加而逐渐提高,因此要得到较高的诊断精度,就要增大迭代次数,但这会减小训练批处理量,延长迭代时间,从而修正模型参数的速度变得更加缓慢。当迭代次数为 600 时,准确率达到了 95.04%,从这之后基本趋于平稳。为了缩短网络训练时间,本文选取迭代次数为 600。

3.2 不同隐含层数的诊断分析

为了研究隐含层数对诊断精度的影响,构建 N ($N=1,2,3,4,5$) 层的 DBN 网络,每层神经元个数取 20,迭代次数取 600,用相同的训练和测试样本进行试验,将诊断准确率随隐含层数的变化绘制成误差棒图,如图 5 所示。

从图 5 可以发现,2 层网络具有最高的平均准确




图5 不同隐含层的诊断准确率

Fig.5 Diagnostic accuracy of different hidden layers

率,当隐含层数继续增加时,诊断准确率反而下降,5层网络诊断准确率最差。由此得出,与常规结论有所不同,利用DBN进行空压机故障诊断时,诊断精度并不是随着隐含层数的增加而持续提高。为了满足诊断精度,本文选取隐含层数为2层的网络结构。

3.3 基于DBN的空压机故障诊断方法性能分析

为验证DBN方法对空压机故障诊断的优势,本文利用相同结构的多隐层BP网络和具有非线性分类能力的PNN网络2种方法对空压机进行故障诊断,同样选用相同的数据集进行10次试验,其诊断结果如图6所示,并计算10次试验的平均准确率、准确率标准差以及平均训练时间,如表2所示。




图6 不同方法10次试验的诊断准确率

Fig.6 Diagnostic accuracy of different methods in 10 experiment

通过图6和表2发现,多隐含层BP网络虽然采用和DBN相同的4层结构,但未采用逐层贪婪预训练,难以有效训练这样的深度结构,诊断的平均准

表2 不同方法的诊断结果

Table 2 Diagnostic results with different methods

方法	平均准确率/%	准确率标准差/%	平均训练时间/s
多隐层BP	72.83	2.7113	45.759
PNN	81.50	1.8649	30.536
DBN	94.59	0.4239	52.342

准确率只有72.83%,且波动较大,同时准确率标准差为2.7113,相对较大,模型稳定性较差。PNN网络具有较强的非线性分析能力,有效克服了BP网络的局限性,提高了诊断精度,诊断平均准确率达到81.5%,准确率标准差也减小到了1.8649,模型稳定性有所改善,但因模型参数平滑因子的经验取值并不完全适合于实际工程问题,诊断结果仍不理想。相比较而言,DBN方法通过深层网络自适应地提取故障特征,并有监督地微调模型参数,从而实现了高效智能的空压机故障诊断,其诊断精度为94.59%,诊断结果也更为平稳,并且准确率标准差取得最小值0.4239,这验证了本文提出的基于DBN的空压机故障诊断方法具有良好的故障诊断性能,同时具有较高的稳定性。

此外,在3种算法中,PNN的训练所需时间最短,这是因为PNN网络属于局部逼近网络,所以较BP全局逼近网络学习速度快。DBN网络训练时间最长,这是因为网络复杂的深度结构需要进行逐层预训练和微调两阶段的训练,模型参数更新耗时明显高于其他算法。因此,对于非线性的离线故障诊断应用来说,为了获得更高的空压机故障诊断精度而折中考虑训练时间具有一定的实际意义。

4 结 论

本文研究了一种基于DBN网络的故障诊断方法,将深度学习应用于炼化空压机故障诊断,通过试验验证了方法的有效性,结果表明:

(1)基于DBN的故障诊断方法能够自适应提取表征空压机故障的特征,克服了传统方法对大量复杂信号处理技术和实际诊断经验的依赖,并获得较高的诊断准确率;

(2)DBN的网络结构与具体应用有关,对于炼化空压机故障诊断,最优结构为2个隐含层结构;DBN的诊断精度受迭代次数的影响,随着迭代次数的增加诊断精度不断提高,但训练时间会延长;

(3)得益于深层结构和网络权值微调机制,DBN

算法具有比BP算法和PNN算法更高的准确性和更好的稳定性,但同时延长了训练时间,降低了诊断的快速性。

由于深度网络结构复杂、参数较多,在进一步的研究中,为提高诊断精度,缩短训练时间,还需要对隐含层节点数以及权值调整算法等进行更加深入的探讨。

参考文献

- [1] 许世勇. 基于主元分析的空气压缩机故障诊断研究[D]. 吉林: 长春工业大学, 2012.
Xu S Y. Research of the fault diagnosis of air compressor based on principal component analysis[D]. Jilin: Changchun University of Technology, 2012.
- [2] Graham-rowe D, Goldston D, Doctorow C, et al. Big data: science in the petabyte era[J]. *Nature*, 2008, **455**(7209): 8–9.
- [3] 刘帅师, 程曦, 郭文燕, 等. 深度学习方法研究新进展[J]. *智能系统学报*, 2016, **11**(5): 567–576.
Liu S S, Cheng X, Guo W Y, et al. Progress report on new research in deep learning[J]. *CAAI Transactions on Intelligent Systems*, 2016, **11**(5): 567–576.
- [4] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据监控监测方法[J]. *机械工程学报*, 2015, **51**(21): 49–56.
Lei Y G, Jia F, Zhou X, et al. A deep learning-based method for machinery health monitoring with big data[J]. *Journal of Mechanical Engineering*, 2015, **51**(21): 49–56.
- [5] 段艳杰, 吕宜生, 张杰, 等. 深度学习在控制领域的研究现状与展望[J]. *自动化学报*, 2016, **42**(5): 643–654.
Duan Y J, Lyu Y S, Zhang J, et al. Deep learning for control: the state of the art and prospects[J]. *Acta Automatica Sinica*, 2016, **42**(5): 643–654.
- [6] 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.
- [7] Carlos A, André L D R, Fábio H A V, et al. Deep learning for biological image classification[J]. *Expert Systems with Applications*, 2017, **85**: 114–122.
- [8] 伍锡如, 黄国明, 孙立宁. 基于深度学习的工业分拣机器人快速视觉识别与定位算法[J]. *机器人*, 2016, **38**(6): 711–719.
Wu X R, Huang G M, Sun L N. Fast visual identification and location algorithm for industrial sorting robots based on deep learning[J]. *Robot*, 2016, **38**(6): 711–719.
- [9] 吴志勇, 丁香乾, 许晓伟, 等. 基于深度学习和模糊C均值的心电信号分类方法[J]. *自动化学报*, 2018, **44**(8): 1913–1920.
Wu Z Y, Ding X Q, Xu X W, et al. A method for ECG classification using deep learning and fuzzy C-means[J]. *Acta Automatica Sinica*, 2018, **44**(10): 1913–1920.
- [10] Guo D F, Zhong M Y, Ji H Q, et al. A hybrid feature model and deep learning based fault diagnosis for unmanned aerial vehicle sensors[J]. *Neurocomputing*, 2018, **319**: 155–163.
- [11] Guo Y B, Tan Z H, Chen H X, et al. Deep learning-based fault diagnosis of variable refrigerant flow air-conditioning system for building energy saving[J]. *Applied Energy*, 2018, **225**: 732–745.
- [12] 时培明, 梁凯, 赵娜, 等. 基于深度学习特征提取和粒子群支持向量机状态识别的齿轮智能故障诊断[J]. *中国机械工程*, 2017, **28**(9): 1056–1068.
Shi P M, Liang K, Zhao N, et al. Intelligent fault diagnosis for gears based on deep learning feature extraction and particle swarm optimization SVM state identification[J]. *Chinese Journal of Mechanical Engineering*, 2017, **28**(9): 1056–1068.
- [13] Feng D L, Xiao M Q, Liu Y X, et al. Finite-sensor fault-diagnosis simulation study of gas turbine engine using information entropy and deep belief networks[J]. *Frontiers of Information Technology & Electronic Engineering*, 2016, **17**(12): 1287–1304.
- [14] Georg H, Matthias R. Deep learning for fault detection in wind turbines[J]. *Renewable and Sustainable Energy Reviews*, 2018, **98**: 189–198.
- [15] Cao C S, Liu F, Tan H. Deep learning and its applications in biomedicine[J]. *Genomics, Proteomics & Bioinformatics*, 2018, **16**(1): 17–32.
- [16] 王康成, 尚超, 柯文思, 等. 化工过程深度神经网络软测量的结构与参数自动调整方法[J]. *化工学报*, 2018, **69**(3): 900–906.
Wang K C, Shang C, Ke W S, et al. Automatic structure and parameters tuning method for deep neural network soft sensor in chemical industries[J]. *CIESC Journal*, 2018, **69**(3): 900–906.
- [17] 王功明, 李文静, 乔俊飞. 基于PLSR自适应深度信念网络的出水总磷预测[J]. *化工学报*, 2017, **68**(5): 1987–1997.
Wang G M, Li W J, Qiao J F. Prediction of effluent total phosphorus using PLSR-based adaptive deep belief network[J]. *CIESC Journal*, 2017, **68**(5): 1987–1997.
- [18] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, **313**(5786): 504–507.
- [19] Lee H, Grosse R, Ranganath R, et al. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations[C]//Proceedings of the International Conference on Machine Learning. USA: ACM, 2009: 609–616.
- [20] 金连文, 钟卓耀, 杨钊, 等. 深度学习在手写汉字识别中的应用综述[J]. *自动化学报*, 2016, **42**(8): 1125–1141.
Jin L W, Zhong Z Y, Yang Z, et al. Applications of deep learning for handwritten Chinese character recognition: a review[J]. *Acta Automatica Sinica*, 2016, **42**(8): 1125–1141.
- [21] Bengio Y, Courville A, Vincent P. Representation learning: a review and new perspectives[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, **35**(8): 1798–1828.
- [22] 管皓, 薛向阳, 安志勇. 深度学习在视频目标跟踪中的应用进展与展望[J]. *自动化学报*, 2016, **42**(6): 834–847.
Guan H, Xue X Y, An Z Y. Advances on application of deep learning for video object tracking[J]. *Acta Automatica Sinica*, 2016, **42**(6): 834–847.

- [23] Hinton G, Deng L, Yu D, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups[J]. IEEE Signal Processing Magazine, 2012, **29**(6): 82–97.
- [24] Tang Y C, Elasmith C. Deep networks for robust visual recognition[C]//Proceedings of IEEE International Conference on Machine Learning. 2010:1055–1062.
- [25] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]//Proceeding of Advances in Neural Information Processing Systems. Nevada, USA: MIT Press, 2012: 1097–1105.
- [26] Tamilselvan P, Wang P. Failure diagnosis using deep belief learning based health state classification[J]. Reliability Engineering & System Safety, 2013, **115**(7): 124–135.
- [27] Tran V T, Althobiani F, Ball A. An approach to fault diagnosis of reciprocating compressor valves using Teager–Kaiser energy operator and deep belief networks[J]. Expert Systems with Applications, 2014, **41**(9): 4113–4122.
- [28] 李巍华, 单外平, 曾雪琼. 基于深度信念网络的轴承故障分类识别[J]. 振动工程学报, 2016, **29**(2): 340–347.
- Li W H, Shai W P, Zeng X Q. Bearing fault identification based on deep belief network[J]. Journal of Vibration Engineering, 2016, **29**(2): 340–347.
- [29] 赵光权, 葛强强, 刘小勇, 等. 基于DBN的故障特征提取及诊断方法研究[J]. 仪器仪表学报, 2016, **37**(9): 1946–1953.
- Zhao G Q, Ge Q Q, Liu X Y, et al. Fault feature extraction and diagnosis method based on deep belief network[J]. Chinese Journal of Scientific Instrument, 2016, **37**(9): 1946–1953.
- [30] Hinton G, Osindero S, Teh Y. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, **18**(7): 1527–1554.