DOI:10.3969/j.issn.1674-3644.2019.01.007

基于深度置信网络和信息融合技术的轴承故障诊断

蒋黎明[1],李友荣[1],徐增丙[1,2],鲁光涛[1]

(1.武汉科技大学冶金装备及其控制教育部重点实验室,湖北 武汉,430081;
2.华中科技大学数字制造设备与技术国家重点实验室,湖北 武汉,430074)

摘要:提出一种基于深度置信网络(DBN)和信息融合技术的轴承故障诊断新方法。首先采用集合经验模式分解将轴承振动时域信号分解为若干个固有模态函数,并分别输入至若干个 DBN 中进行故障状态识别,然后通过简单投票法将每个 DBN 识别的结果进行决策层信息融合,从而得到轴承故障的最终诊断结果。通过对单负载和多负载下不同类型和不同损伤程度的滚动轴承故障诊断进行实例分析,验证了本文方法的有效性和精确性。

关键词:滚动轴承;故障诊断;深度置信网络;信息融合;集合经验模式分解;简单投票法

中图分类号:TH165^{+}.3;TH133.33　　**文献标志码**:A　　**文章编号**:1674-3644(2019)01-0040-05

滚动轴承是旋转机械中最常见和最关键的零部件之一,及时准确地掌握其故障损伤情况,对保障机械设备安全运行、避免经济损失和灾难性事故具有重要的意义。故障诊断的本质就是模式识别,而深度学习作为机器学习研究中的一个新领域,近年来已成功应用于计算机视觉[1]、语音识别[2]等模式识别领域。与一般的神经网络和机器学习模型相比,深度学习可以更精确、高效地解决复杂问题[3]。深度置信网络(deep belief network, DBN)是最具代表性的深度学习技术之一,在故障诊断中的应用越来越多。Tamilselvan 等[4]提出一种基于 DBN 的多传感器故障诊断方法,并运用于飞机发动机和电力变压器的故障诊断。Chen 等[5]将稀疏自动编码机(SAE)和 DBN 相结合进行轴承故障诊断,先从不同传感器振动信号中提取 15 种时域特征和 3 种频域特征,输入到 SAE 中进行特征融合,再利用得到的融合特征向量训练 DBN。陶洁等[6]提出基于 Teager 能量算子(TEO)和 DBN 的滚动轴承故障诊断方法,用 TEO 提取滚动轴承振动信号中的瞬时能量,输入到采用层次优化算法调整参数后的 DBN 模型中进行故障识别。张淑清等[7]提出基于双树复小波(DTCWT)和 DBN 的轴承故障诊断新方法,先用 DTCWT 将信号分解,进而提取能量熵作为故障特征,采用 DBN 小样本模型对故障进行分类。

虽然 DBN 已经广泛应用于故障诊断领域,但仍然存在以下两方面问题:①大多数研究仅将 DBN 作为一个分类器,且需要人工提取故障特征参数作为 DBN 的输入,因此未能充分利用 DBN 的特征提取能力;②利用 DBN 网络模型对信号进行表征分析时易忽略局部信息,从而导致故障识别率不高、诊断系统可靠性差等问题。

为此,本文提出一种基于深度置信网络和信息融合技术的滚动轴承故障识别方法。首先采用集合经验模式分解(EEMD)方法将单一传感器采集的轴承振动时域信号分解为若干个固有模态函数(IMF),并分别作为各 DBN 的输入,然后采用投票表决法将每个 DBN 识别的结果进行信息融合,从而获取最终的故障诊断结果。

1　基于 DBN 和信息融合技术的故障识别方法

1.1　方法概述

考虑到采用传统 DBN 方法进行诊断分析时

收稿日期:2018-09-05

基金项目:国家自然科学基金资助项目(51775391,51808417,51405353).

作者简介:蒋黎明(1993-),男,武汉科技大学硕士生.E-mail:370641388@qq.com

通讯作者:徐增丙(1981-),男,武汉科技大学副教授,博士.E-mail:xuzengbing@163.com

主要是针对信号的全局信息，而未能充分利用其局部信息特征，因此本文建立基于 DBN 和信息融合技术的故障诊断模型，其故障识别过程如图 1 所示。

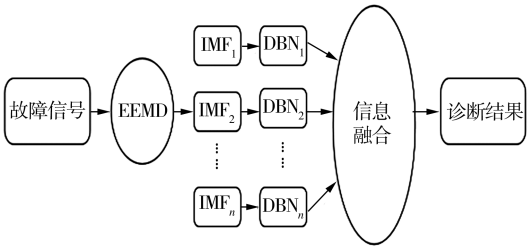

图 1　故障识别过程

Fig. 1 Process of fault recognition

具体步骤如下：

(1)获取滚动轴承的故障振动信号，对其进行 EEMD 分解得到若干 IMF。

(2)选取前 n 个 IMF，分别作为 n 个 DBN 的输入。

(3)设定 DBN 中隐藏层数 N 和学习率 ε，并以无监督学习的方式逐层训练；再利用反向传播神经网络(BPNN)的误差反向传播原则进行权值和偏置的微调。

(4)将 n 个 DBN 的识别结果采用投票法进行处理，得到信息融合后的故障诊断结果。

1.2　采用 EEMD 的信号处理

经验模式分解(EMD)是针对非线性信号的时频信号分析方法，可以自适应分解数据并获得一系列 IMF。EMD 算法非常适合于分析具有非平稳特性的滚动轴承振动信号。然而在实际应用中发现，EMD 分解过程中存在模式混合的问题[8]，也就是说，一个 IMF 中包含不同的频率分量，或者相同的频率分量被分解为不同的 IMF。为了解决这一问题，研究人员又提出了 EEMD 算法[9]，该算法的核心是先通过引入具有频率均匀分布特性的高斯白噪声来抑制模态混频的出现，再利用 EMD 方法对原始信号进行重复分解，将原始振动数据分解为一系列具有不同尺度和连续特性的 IMF。

1.3　DBN 的基本构架和训练过程

1.3.1　DBN 的基本构架

DBN 是由多层受限玻尔兹曼机(RBM)和 BPNN 构成的深层神经网络，图 2 所示为一个由 3 个 RBM 堆叠而成的 DBN 网络结构模型。多层体系结构确保 DBN 可以通过自下而上的学习方式在 RBM 序列中进行训练，并通过 BPNN 进行自上而下的后向微调学习[10]。

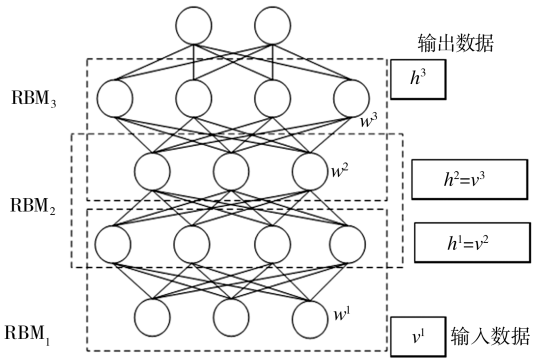

图 2　DBN 结构示意图

Fig. 2 Structural diagram of DBN

RBM 由两层网络组成，即可见层(v)和隐藏层(h)，可见层和隐藏层之间通过权值 w 连接，层内之间相互独立无连接。在 DBN 中，输入数据经过底层 RBM 学习后，底层 RBM 的隐藏层成为下一个 RBM 的可见层，依次逐层传递。DBN 通过堆叠 RBM 建立了逐层贪婪学习的连续层次结构[11]。

在 RBM 中，可见单元和隐藏单元分别用 v_i 和 h_j 表示。可见单元 v_i 和隐藏单元 h_j 之间连接的权重用 w_{ij} 表示。c_i 表示可见单元 v_i 的偏置，b_j 表示隐藏单元 h_j 的偏置。所有 RBM 的参数 b_j、c_i 和 w_{ij} 构成 DBN 中的数据集 θ。DBN 的能量函数为：

$$E(v,h)=-\sum_{i=1}^{m}v_ic_i-\sum_{j=1}^{n}h_jb_j-\sum_{i=1}^{m}\sum_{j=1}^{n}v_ih_jw_{ij} \tag{1}$$

DBN 训练的最终目的是寻找最佳参数 θ，以最小化模型能量误差并使模型处于平衡状态。因此，利用能量函数来定义 v 和 h 之间的联合概率分布如下：

$$P(v,h|\theta)=\frac{1}{Z(\theta)}\mathrm{e}^{-E(v,h|\theta)},$$
$$Z(\theta)=\sum_{v,h}\mathrm{e}^{-E(v,h|\theta)} \tag{2}$$

由于 DBN 层内无连接，可见节点和隐藏节点的条件概率分布可通过下式计算：

$$P(v_i|h)=\frac{1}{1+\exp(-c_i-\sum_j h_jw_{ij})} \tag{3}$$

$$P(h_j|v)=\frac{1}{1+\exp(-b_j-\sum_i v_iw_{ij})} \tag{4}$$

1.3.2　DBN 的训练过程

一般来说，DBN 训练过程包括两部分：预训练和微调。

(1)预训练是一种无监督的学习过程，它使用未标记的数据来训练单个 RBM。DBN 可以通过

自下而上的学习方式在 RBM 序列中进行训练，可从原始的信号数据中提取到较为抽象和高层次的表达。在预训练中，RBM 中的权重和阈值被持续更新，直到最大迭代次数，关于 RBM 网络的更新规则参见文献[12]。

(2)微调是一种监督学习过程，它利用反向传播进一步降低训练误差，提高 DBN 的分类精度。由于 BPNN 是监督学习，因此微调使用标签数据进行 DBN 训练。与 DBN 中的无监督训练一次仅处理一个 RBM 不同，BPNN 同时训练 DBN 中的所有层。通过模型输出和标签数据来计算 BPNN 的训练误差。反向传播学习持续进行，经过多次调整即可达到整个 DBN 最优。

1.4 基于简单投票法的信息融合

最直接的信息融合方法是简单投票法(simple voting)，也称为多数投票法(majority voting)[13]。如同选举投票一样，分为被选举者和选举者。投票规则是，每一选举者都为确定的被选举者投上一票且仅此一票，得票最多的被选举者胜出。

2 应用实例分析

2.1 实验数据

为了验证本文方法的有效性，采用美国凯斯西储大学电气工程实验室提供的滚动轴承振动信号数据进行分析(http://www.eecs.case.edu/laboratory/bearing/download.htm)。实验装置主要包括 1.47 kW 电机、扭矩传感器、测力器、电气控制等部件。实验轴承为 SKF 公司生产的 6205-2RS 深沟球轴承，轴承安装在电机的驱动端，轴承振动信号在 3 种不同大小的负载下采集得到，采样频率为 12 kHz。

实验系统模拟了轴承的正常工作状态以及发生外圈故障、内圈故障和滚动体故障时的工作状态，并且每种故障类型都有 3 种损伤程度。用 N 表示轴承正常状态；用 IR1、IR2 和 IR3 分别表示滚动轴承内圈轻、中、重度损伤，对应于内圈损伤点直径为 0.18、0.36、0.53 mm。依此类推，OR1、OR2 和 OR3 分别表示滚动轴承外圈轻、中、重度损伤状态；BE1、BE2 和 BE3 分别表示滚动体轻、中、重度损伤状态。

根据 0～1.47 kW 区间 3 种负载下的实验数据，分别构造数据集 A、B 和 C，每个数据集均包含轴承正常状态和 9 种故障类别。每个时域样本的采样点数为 500，每种状态类别可以得到 200 个样本。考虑实际情况，每一种故障可能会对应多种负载，因此综合数据集 A、B 和 C，得到数据集 D，其包含 600 个样本。

2.2 轴承振动信号分解

EEMD 算法中有两个重要参数，分别为白噪声的幅值 k 和总体平均次数 M，参照文献[9]，取 $k=0.1$，$M=100$。以滚动轴承在 IR1 故障状态下的原始时域信号为例，经 EEMD 处理后得到若干 IMF 分量，其中前 10 个如图 3 所示。

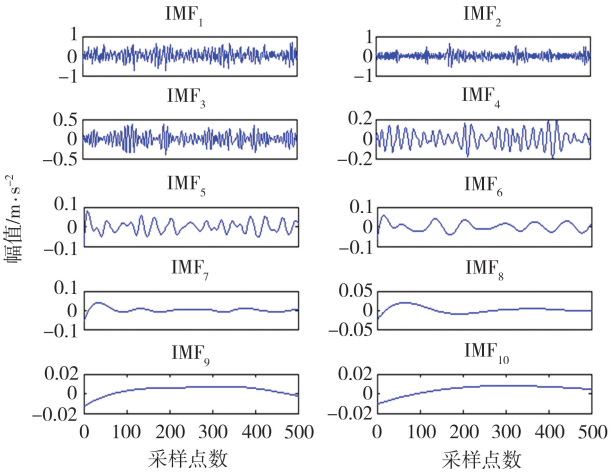

图 3 IR1 故障振动信号的 EEMD 分解

Fig. 3 EEMD decomposition of IR1 fault vibration signals

2.3 故障诊断结果与分析

由于通过 EEMD 得到的 IMF 中存在对故障不敏感的分量，本文选取前 t 个 IMF 分别作为输入数据带入 DBN，得到 t 个 DBN 识别结果，再将这 t 个识别结果通过简单投票法处理，得出信息融合后的故障诊断结果。对于 DBN 结构参数的选取，目前尚无成熟理论，理论上来说，隐藏层的网络层数和节点数越多就越容易挖掘出原始数据特征，但同时又会出现过拟合问题，计算成本也会增加[14]。本文中 DBN 模型采用经典的 4 层结构，各层节点数分别为 500、100、100、10，学习率 $\varepsilon=0.0001$，最终结果取 10 次实验所得的平均值。随机选取每个故障类别样本的 60%为训练样本，剩余作为测试样本。

由于篇幅所限，本文仅给出针对单负载数据集 A 和多负载数据集 D 的分析结果。对于单负载数据集，DBN 的迭代次数设为 3000；对于多负载数据集，DBN 的迭代次数设为 6000；其余参数均相同。故障识别结果如图 4 和图 5 所示，其中柱状图表示第 t 个 IMF 单独输入 DBN 后的识别率，折线图表示前 t 个 IMF 输入 t 个 DBN 后，将 t 个识别结果信息融合后的最终识别率。

从图 4、图 5 可见，原始振动单负载数据集 A 和多负载数据集D经EEMD分解后得到不同频

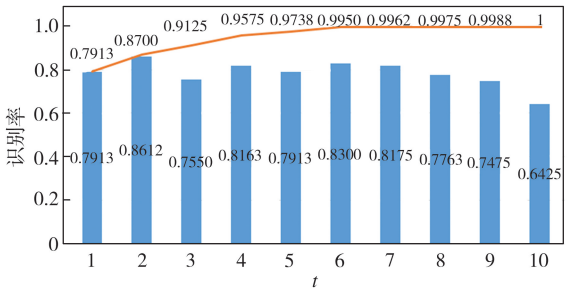

图 4　数据集 A 的识别结果

Fig. 4 Recognition results of Dataset A

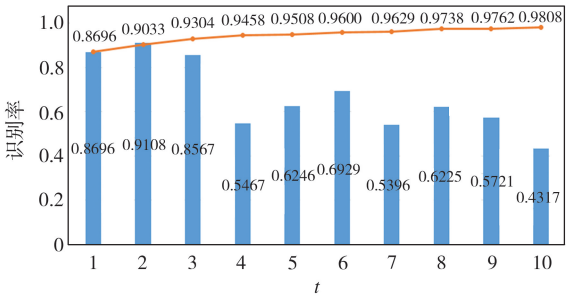

图 5　数据集 D 的识别结果

Fig. 5 Recognition results of Dataset D

率段的 IMF，将它们分别作为 DBN 输入数据进行故障状态识别的准确率除个别数据外均低于 87%。但运用简单投票法将前 t 个 DBN 识别的结果进行信息融合后，识别率随着 t 的增加而不断提高，并且当 $t=10$ 时单负载和多负载下的故障状态识别率分别达到 100% 和 98.08%。因此本文提出的故障识别模型不仅可以在单一负载条件下进行高精度识别，也能够在多种负载共存时进行故障提取与识别。

为了进一步评估本文方法对轴承故障的识别能力，将其与传统 DBN 故障诊断方法和文献[6]提出的 TEO-DBN 故障诊断方法进行对比，结果如表 1 和表 2 所示。由表 1 可见，与 TEO-DBN 方法相比，本文方法不需要任何特征提取过程，直接将振动时域信号作为 DBN 的输入，在单负载时的故障识别率更高。结合表 1 和表 2 可知，与未进行信息融合的传统 DBN 方法相比，本文方法不仅在单负载条件下故障识别率较高，而且针对更接近实际工况的多负载情况进行测试时获得高达 98.08%的平均故障识别率，充分验证了该方法在轴承故障诊断中的有效性和精确性。

表 1　不同数据集的识别结果对比

Table 1 Comparison of recognition results of different datasets

方法	故障识别率/%			
	数据集 A	数据集 B	数据集 C	数据集 D
TEO-DBN[6]	94.67	—	—	—
DBN	79.13	81.13	78.83	86.96
本文方法	100	100	100	98.08

表 2　多负载下不同故障类别的识别结果对比

Table 2 Comparison of recognition results of different fault categories under multi-load conditon

故障类别	故障识别率/%	
	本文方法	DBN
N	100	96.25
IR1	97.50	92.92
IR2	100	83.75
IR3	96.67	86.67
OR1	100	80.00
OR2	98.33	93.75
OR3	95.83	65.42
BE1	96.25	80.83
BE2	97.08	94.58
BE3	99.17	95.42
平均	98.08	86.96

3　结语

本文提出一种基于 DBN 和信息融合技术的轴承故障诊断新方法，其将原始滚动轴承振动时域信号进行 EEMD 分解，得到多个 IMF，分别作为 DBN 的输入，再将多个 DBN 的识别结果进行信息融合。通过对单负载和多负载下轴承故障状态的识别证明了该方法的有效性。本文方法的优点在于：①能从 IMF 中逐层提取信号特征，不需要提取时域或频域特征；②运用多个 DBN 网络模型，可充分发挥 DBN 特征提取的能力，获得较高的故障识别率；③不仅适用于轴承的单负载工况，也适用于接近工程实际的多负载工况。

参　考　文　献

[1]　Doulamis N, Doulamis A. Fast and adaptive deep fusion learning for detecting visual objects[C]// Computer Vision: ECCV 2012. Workshops and Demonstrations. Springer-Verlag, Berlin, Heidelberg, 2012:345-354.

[2]　Zhang Z X, Geiger J, Pohjalainen J, et al. Deep learning for environmentally robust speech recognition: an overview of recent developments[J]. ACM Transactions on Intelligent Systems and Technology, 2017, 9(5). DOI: 10.1145/3178115.

[3]　LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521:436-444.

[4]　Tamilselvan P, Wang P F. Failure diagnosis using deep belief learning based health state classification [J]. Reliability Engineering and System Safety, 2013, 115(7):124-135.

[5]　Chen Z Y, Li W H. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network[J]. IEEE Transactions on In-

strumentation and Measurement, 2017,66(7):1693-1702.

[6] 陶洁,刘义伦,付卓,等.基于 Teager 能量算子和深度置信网络的滚动轴承故障诊断[J].中南大学学报:自然科学版,2017,48(1):61-68.

[7] 张淑清,胡永涛,姜安琦,等.基于双树复小波和深度信念网络的轴承故障诊断[J].中国机械工程,2017,28(5):532-536,543.

[8] Huang N E, Wu M-L C, Long S R, et al. A confidence limit for the empirical mode decomposition and Hilbert spectral analysis[J]. Proceedings: Mathematical, Physical and Engineering Sciences, 2003, 459:2317-2345.

[9] Wu Z H, Huang N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2008, 1(1):1-41.

[10] Hinton G E, Osindero S, Teh Y-W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006,18(7):1527-1554.

[11] Bengio Y, Lamblin P, Popovici D, et al. Greedy layer-wise training of deep networks[J]. Advances in Neural Information Processing Systems, 2007, 19:153-160.

[12] Hinton G E. A practical guide to training restricted Boltzmann machines[M]//Montavon G, Orr G B, Müller K R. Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science. Springer-Verlag, Berlin, Heidelberg, 2012:599-619.

[13] Chan P K, Stolfo S J. A comparative evaluation of voting and meta-learning on partitioned data[C]// Proceedings of the Twelfth International Conference on Machine Learning. Tahoe City, California, July 9-12, 1995:90-98.

[14] Larochelle H, Bengio Y, Louradour J, et al. Exploring strategies for training deep neural networks [J]. Journal of Machine Learning Research, 2009, 10(1):1-40.

Bearing fault diagnosis based on deep belief network and information fusion

Jiang Liming[1], *Li Yourong*[1], *Xu Zengbing*[1,2], *Lu Guangtao*[1]

(1. Key Laboratory of Metallurgical Equipment and Control Technology of Ministry of Education, Wuhan University of Science and Technology, Wuhan 430081, China; 2. State Key Laboratory of Digital Manufacturing Equipment and Technology, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: A novel method for bearing fault diagnosis was presented on the basis of deep belief network (DBN) and information fusion technology. Firstly, ensemble empirical mode decomposition was applied to decompose the time domain signal of bearing vibration into several intrinsic mode functions which were separately input to DBNs for fault state identification. Then for the purpose of information fusion at decision level, the simple voting method was used to combine the diagnostic results by each DBN and obtain the final classification of bearing faults. Vibration signal datasets of rolling bearings with different fault types and damage degrees under single load and multi-load conditions were collected for algorithm validation. The fault recognition results verified the effectiveness and accuracy of the proposed method.

Key words: rolling bearing; fault diagnosis; deep belief network; information fusion; ensemble empirical mode decomposition; simple voting

[责任编辑 尚 晶]