**网络首发地址**：http://kns.cnki.net/kcms/detail/42.1755.TJ.20200427.1714.008.html **期刊网址**：www.ship-research.com

**引用格式**：仲国强，贾宝柱，肖峰，等. 基于深度信念网络的船舶柴油机智能故障诊断[J]. 中国舰船研究，2020，15(3)：136-142，184.

ZHONG G Q, JIA B Z, XIAO F, et al. Intelligent fault diagnosis of marine diesel engine based on deep belief network [J]. Chinese Journal of Ship Research，2020，15(3)：136-142，184.

# 基于深度信念网络的船舶柴油机智能故障诊断

扫码阅读全文

仲国强[1]，贾宝柱[*2]，肖峰[1]，王怀宇[1]

1 大连海事大学 轮机工程学院，辽宁 大连 116026

2 广东海洋大学 海运学院，广东 湛江 524088

**摘 要**：[**目的**] 为了提高船舶柴油机智能故障诊断的精度，引入深度学习方法，提出一种基于深度信念网络(DBN)的船用柴油机智能故障诊断方法。[**方法**] 采用多层限制性玻尔兹曼机(RBM)堆叠成DBN，并采用对比散度方法对模型参数进行求解。通过无监督预训练和有监督微调的训练方法，从故障样本数据中提取深层次的隐性特征并获得较好的初始化参数。[**结果**] 基于AVL BOOST船舶柴油机故障仿真实验进行样本数据分析，结果表明：DBN对训练样本集和测试样本集的故障识别率分别为98.26%和98.61%，比BP神经网络(BPNN)和支持向量机(SVM)具有更高的故障识别准确率和更好的泛化性能，可以避免浅层神经网络因随机初始化权值而陷入局部最小值和精度较低等问题。[**结论**] 与BPNN和SVM相比，DBN更适用于船舶柴油机的智能故障诊断应用。

**关键词**：船舶柴油机；故障分析；深度信念网络；深度学习

**中图分类号**：U664.121 **文献标志码**：A **DOI**：10.19693/j.issn.1673-3185. 01551

# Intelligent fault diagnosis of marine diesel engine based on deep belief network

*ZHONG Guoqiang*[1], *JIA Baozhu*[*2], *XIAO Feng*[1], *WANG Huaiyu*[1]

1 Marine Engineering College, Dalian Maritime University, Dalian 116026, China

2 Maritime College, Guangdong Ocean University, Zhanjiang 524088, China

**Abstract**: [**Objectives**] In order to improve the accuracy of intelligent fault diagnosis of marine diesel engine, the deep learning is introduced, and a method based on deep belief network (DBN) for intelligent fault diagnosis of marine diesel engine is proposed. [**Methods**] The multilayer restricted Boltzmann machine (RBM) was used to stack DBN, and the parameters of the model were solved by contrast divergence method. This method adopted a new training mode including unsupervised pre-training and supervised fine-tuning, which could learn and extract deep hidden features from the fault sample data automatically, and obtain better initialization weights. [**Results**] After the analysis of the sample data collected from the experiment of fault simulation for marine diesel engine based on AVL BOOST, the results show that the recognition rate of DBN to training sample set and test sample set is 98.26% and 98.61% respectively, so DBN has higher fault identification accuracy and higher generalization performance than BP neural network (BPNN) and support vector machine (SVM), and can avoid the shortcomings of the shallow neural network due to randomly initialized weights, such as local minima and low precision. [**Conclusions**] Compared with BPNN and SVM, DBN is more suitable for intelligent fault diagnosis of marine diesel engine.

**Key words**: marine diesel engine; fault analysis; deep belief network (DBN); deep learning

**收稿日期**：2019-03-25 **修回日期**：2019-06-11 **网络首发时间**：2020-4-28 11:12

**基金项目**：国家自然科学基金资助项目(83114032)

**作者简介**：仲国强，男，1994年生，硕士生。研究方向：故障诊断。E-mail：1843204521@qq.com

贾宝柱，男，1974年生，博士，副教授。研究方向：轮机自动化与智能化。E-mail：skysky@dlmu.edu.cn

肖峰，男，1994年生，硕士生。研究方向：故障诊断。E-mail：512780808@qq.com

王怀宇，男，1994年生，硕士生。研究方向：船舶柴油机建模仿真。E-mail：nepu2017@126.com

***通信作者**：贾宝柱

## 0 引 言

船舶大型中、低速柴油机的运动形式和系统结构较为复杂,部分运动部件的机械负荷和热负荷较高,其中润滑、冷却不良及热应力过大等问题极易引发故障,从而影响柴油机的正常运转,为船舶安全航行带来隐患。目前,船舶柴油机的故障诊断主要依赖于人为经验。然而,随着船舶智能化的发展,基于数据驱动的智能故障诊断方法可在一定程度上避免建立复杂的对象模型或过度依赖专家经验等缺点,所以受到了日益广泛的关注[1-2]。

柴油机智能故障诊断一般采用基于小样本数据训练的思路,故需先通过特征提取算法来获取故障信号特征,然后采用支持向量机(support vector machine, SVM)、BP神经网络(back propagation neural network,BPNN)、极限学习机(extreme learning machine,ELM)等机器学习方法,建立故障诊断模型。贺立敏等[3]利用随机森林对柴油机的热工参数进行了特征提取,并通过SVM算法诊断了柴油机的常见故障。Zhang等[4]利用一种新的时间尺度分解方法提取了振动信号,并采用粒子群优化算法对SVM参数进行了优化,可用于柴油机故障诊断。Xi等[5]采用t-SNE算法对特征信号进行了特征提取和可视化处理,并建立了ELM分类器,可用于识别船舶柴油机的故障隐患。

然而,在实际工程应用中,基于小样本数据训练的方法无法独立完成深层次的特征提取,一旦训练样本较多或特征较复杂时,将易出现陷入局部最优解、识别精度较低和泛化能力较弱等问题[6]。

深度信念网络(deep belief network, DBN)是深度学习框架下常用的一种概率生成模型,其在大量数据样本下更容易捕捉数据特征,具有较强的自主提取特征能力和较高的目标识别精度。与卷积神经网络算法相比,DBN具有训练样本量小、操作灵活简单、与其他算法兼容性好等优点[7]。车畅畅等[8]和李本威等[9]采用DBN对涡扇发动机的状态监测参数进行了处理,诊断了发动机部件的性能衰退故障。贾继德等[10]利用连续小波变换和DBN对柴油机缸盖振动信号进行了特征提取和模型训练,实现了柴油机的失火故障识别。李军亮等[11]利用DBN预测了发动机状态参数,可为可靠性分析和预防性维护工作提供数据支持。

通过结合无监督学习和有监督学习的特点,DBN算法可以从样本数据中自主学习并提取隐性特征,同时获取较优的初始化权值,从而避免浅层神经网络因随机初始化权值而陷入局部最小值和计算精度较低等问题。为此,本文拟提出一种基于深度信念网络的船舶柴油机故障诊断方法,并将开展故障仿真实验,从而评估对比不同算法的计算精度和泛化性能,用以为柴油机智能故障诊断提供参考。

## 1 深度信念网络的原理

### 1.1 限制性玻尔兹曼机(RBM)

深度信念网络由多层限制性玻尔兹曼机(restricted Boltzmann machine, RBM)堆叠而成,每层RBM通过调整神经元之间的权值,即可使整个神经网络按照最大概率来生成训练数据[11],从而进行特征提取和目标识别。典型的RBM结构是由1个可见层$\boldsymbol{v}$和1个隐含层$\boldsymbol{h}$组成的双层网络,如图1所示。可见层用于接收输入数据,隐含层用于提取数据特征,可见层神经元与隐含层神经元相互连接,而各层内的神经元则相互独立。

图1中:$\boldsymbol{v}=[v_1, v_2, \ldots, v_n]$,为可见层单元的$n$个输入节点;$\boldsymbol{h}=[h_1, h_2, \ldots, h_m]$,为隐含层单元的$m$个输出节点;$\boldsymbol{w}=[w_{ij}]_{n\times m}$,为输入层到输出层的连接权值矩阵,其中$i=1,2,\cdots,n$且$j=1,2,\cdots,m$;$\boldsymbol{A}=[a_1, a_2, \ldots, a_n]$,其中$a_i$为第$i$个可见单元$v_i$的偏置;$\boldsymbol{B}=[b_1, b_2, \ldots, b_m]$,其中$b_j$为第$j$个隐含单元$h_j$的偏置。

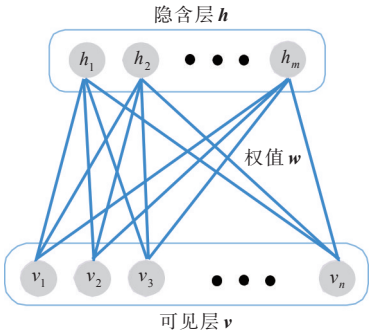


图1　限制性玻尔兹曼机的结构

Fig.1　Structure of restricted Boltzmann machine

对于给定的可见层输入$\boldsymbol{v}$和隐含层输出$\boldsymbol{h}$,限制性玻尔兹曼机的能量函数$E(\boldsymbol{v},\boldsymbol{h}|\theta)$为

$$E(\boldsymbol{v},\boldsymbol{h}|\theta)=-\sum_{i=1}^{n}a_iv_i-\sum_{j=1}^{m}b_jh_j-\sum_{i=1}^{n}\sum_{j=1}^{m}v_iw_{ij}h_j \quad (1)$$

式中,$\theta=\{w_{ij}, a_i, b_j\}$,为RBM模型的参数集合。

能量函数$E(\boldsymbol{v},\boldsymbol{h}|\theta)$可以视为在当前可见层和隐含层的节点分布状态下,每个可见节点和隐含节点之间的能量值。假设可见层和隐含层的每个节点均有0和1这2种状态,所以可见层和隐含层节点可以组成$t=2^{n+m}$种状态对。对能量函数进

行指数化和正则化处理，即可得到可见层和隐含层节点集合 $\{\boldsymbol{v},\boldsymbol{h}\}$ 分别处于某一种状态对下的联合概率分布 $P(\boldsymbol{v},\boldsymbol{h}|\theta)$，得

$$P(\boldsymbol{v},\boldsymbol{h}|\theta)=\frac{\exp(-E(\boldsymbol{v},\boldsymbol{h}|\theta))}{Z} \tag{2}$$

式中，$Z=\sum_{\{\boldsymbol{v},\boldsymbol{h}\}_1}^{\{\boldsymbol{v},\boldsymbol{h}\}_t}\exp(-E(\boldsymbol{v},\boldsymbol{h}|\theta))$，为归一化因子（也称为配分函数），表示可见层和隐含层节点中所有可能状态对的总和。

根据式(2)，理论上可以获得任意一种状态下的联合概率分布 $P(\boldsymbol{v},\boldsymbol{h})$，然而 $Z$ 的计算难度非常大，所以一般通过吉布斯采样的方法来近似求解联合概率分布。通过对隐含层 $\boldsymbol{h}$ 中 $m$ 个节点的所有二值状态进行求和，即可获得可见层 $\boldsymbol{v}$ 节点集合的边缘概率分布 $P(\boldsymbol{v})$，即

$$P(\boldsymbol{v})=\frac{1}{Z}\sum_{i=1}^{n}\exp(a_i v_i)\prod_{j=1}^{m}\left(1+\exp\left(b_j+\sum_{i=1}^{n}v_i w_{ij}\right)\right) \tag{3}$$

同理，隐含层 $\boldsymbol{h}$ 的边缘概率分布 $P(\boldsymbol{h})$ 为

$$P(\boldsymbol{h})=\frac{1}{Z}\sum_{j=1}^{m}\exp(b_j h_j)\prod_{i=1}^{n}\left(1+\exp\left(a_i+\sum_{j=1}^{m}h_j w_{ij}\right)\right) \tag{4}$$

边缘分布往往被称为似然函数，例如 $P(\boldsymbol{h})$ 隐含层节点集合处于某一种状态分布下的概率。根据 $P(\boldsymbol{h})$，即可求得可见层的条件概率分布 $P(\boldsymbol{v}|\boldsymbol{h})$：

$$P(\boldsymbol{v}|\boldsymbol{h})=\frac{P(\boldsymbol{v},\boldsymbol{h})}{P(\boldsymbol{h})}=\frac{\exp(-E(\boldsymbol{v},\boldsymbol{h}|\theta))}{\sum_{\boldsymbol{v}}\exp(-E(\boldsymbol{v},\boldsymbol{h}|\theta))} \tag{5}$$

同理，隐含层的条件概率分布 $P(\boldsymbol{h}|\boldsymbol{v})$ 为

$$P(\boldsymbol{h}|\boldsymbol{v})=\frac{P(\boldsymbol{v},\boldsymbol{h})}{P(\boldsymbol{v})}=\frac{\exp(-E(\boldsymbol{v},\boldsymbol{h}|\theta))}{\sum_{\boldsymbol{h}}\exp(-E(\boldsymbol{v},\boldsymbol{h}|\theta))} \tag{6}$$

根据RBM层内无连接、层间全连接的结构特点，对于给定的可见单元状态 $\boldsymbol{v}$，通过隐含层的条件概率分布函数 $P(\boldsymbol{h}|\boldsymbol{v})$，即可得出第 $j$ 个隐含单元的激活概率 $P\left(h_j=1|\boldsymbol{v}\right)$：

$$P\left(h_j=1|\boldsymbol{v}\right)=\frac{P(\boldsymbol{v},h_j=1)}{P(\boldsymbol{v})}=\sigma\left(b_j+\sum_i w_{ij}v_i\right) \tag{7}$$

式中，$\sigma(x)=\frac{1}{1+\exp(x)}$，为sigmoid函数。

对于给定的隐含单元状态 $\boldsymbol{h}$，第 $i$ 个可见单元的激活概率为 $P\left(v_i=1|\boldsymbol{h}\right)$：

$$P\left(v_i=1|\boldsymbol{h}\right)=\frac{P(v_i=1,\boldsymbol{h})}{P(\boldsymbol{h})}=\sigma\left(a_i+\sum_j w_{ij}h_j\right) \tag{8}$$

### 1.2 RBM模型参数的求解

求解RBM模型时，需要确定2部分参数：一是可见层和隐含层的节点数量，二是模型参数 $\theta$。可见层的节点数量即为输入数据样本矩阵的维数，隐含层的节点数量一般根据实际工况而定。至于模型参数 $\theta$，当给定训练样本 $\boldsymbol{v}=[v_1,v_2,\ldots,v_n]$ 之后，训练一个RBM模型的意义就在于不断调整模型参数 $\theta$，从而使RBM可见层节点的概率分布尽可能与输入数据相吻合[12]。

在数学领域，求解最优问题时，往往引入似然函数（边缘概率分布 $P(\boldsymbol{v})$）求导的方法。

由式(6)可知，能量 $E$ 和概率 $P(\boldsymbol{v})$ 成反比，所以通过求解最大化 $P(\boldsymbol{v})$，即可令能量 $E$ 最小。最大化似然函数一般采用梯度上升法，故可以按照以下公式调整模型参数 $\theta$，即

$$\theta'=\theta+\mu\frac{\partial\ln P(\boldsymbol{v})}{\partial\theta} \tag{9}$$

式中：$\theta'$ 为调整更新之后的 $\theta$ 参数值；$\mu$ 为学习率。

采用对比散度（CD-$k$）方法来近似求解参数梯度[13]，具体流程如下：

步骤1：输入训练样本 $\boldsymbol{v}_i$，设置学习率 $\mu$、训练次数 $T$ 和允许的重构误差阈值 $R$，同时对参数 $\theta=\{w_{ij},a_i,b_j\}$ 进行初始化处理。

步骤2：选取1个训练样本 $\boldsymbol{v}_i$，采用式(7)计算 $P(h_j=1|\boldsymbol{v})$，并根据该分布采样1个隐含层向量 $\boldsymbol{h}$，然后计算正向梯度 $<\boldsymbol{v}_i\boldsymbol{h}>$。

步骤3：基于隐含层向量 $\boldsymbol{h}$，采用式(8)计算 $P(v_i=1|\boldsymbol{h})$，并根据该分布采样重构的可见层训练样本，记作 $\boldsymbol{v}_{i1}$。

步骤4：基于 $\boldsymbol{v}_{i1}$ 重复步骤2，获得新的隐含层向量 $\boldsymbol{h}$，记作 $\boldsymbol{h}_1$，然后计算反向梯度 $<\boldsymbol{v}_{i1}\boldsymbol{h}_1>$。

步骤5：按照以下公式更新各项参数，记作 $w'_{ij}$，$a'_i$，$b'_j$：

$$w'_{ij}=w_{ij}+\mu\left(<\boldsymbol{v}_i\boldsymbol{h}>-<\boldsymbol{v}_{i1}\boldsymbol{h}_1>\right) \tag{10}$$

$$a'_i=a_i+\mu|\boldsymbol{v}_i-\boldsymbol{v}_{i1}| \tag{11}$$

$$b'_j=b_j+\mu|\boldsymbol{h}-\boldsymbol{h}_1| \tag{12}$$

步骤6：重复以上步骤，计算新的训练样本 $\boldsymbol{v}_{i2}$，$\boldsymbol{v}_{i3}$，…，$\boldsymbol{v}_{iT}$ 和新的隐含层向量 $\boldsymbol{h}_2$，$\boldsymbol{h}_3$，…，$\boldsymbol{h}_T$，其中 $T$ 为当前的训练次数，然后计算重构误差 $r=\|\boldsymbol{v}_{iT}-\boldsymbol{v}_i\|$。当 $T$ 达到最大训练次数 $T_{\max}$ 或 $r$ 小于重构误差阈值 $R$ 时，即可将隐含层向量 $\boldsymbol{h}_T$ 作为下一层RBM的可见层 $\boldsymbol{v}$，并开展新一轮训练。

## 2 深度信念网络训练

深度信念网络一般采用逐层训练方法进行学习，分为预训练和微调2个阶段[13]，其过程如图2所示。在预训练阶段，可以采用自下而上的逐层无监督学习方式，在每层都需要进行参数初始化

和样本数据特征提取;在微调阶段,可以根据预训练阶段所提取的特征,采用BP神经网络算法对初始化参数进行微调。

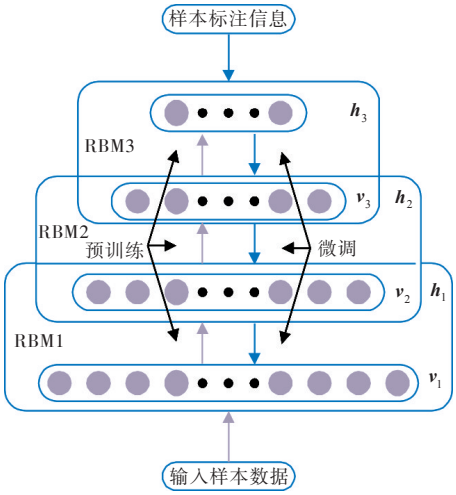


图2　深度信念网络的训练过程

Fig.2　The training process of deep belief network

## 3　故障诊断流程

基于深度信念网络的船舶柴油机故障诊断方法主要包括离线学习和在线识别2个阶段,具体步骤如图3所示。

步骤1:故障样本的数据预处理。该项工作包括数据标准化处理和故障类型编码,并划分为训练样本集和测试样本集。

步骤2:创建基于DBN的故障诊断模型,设置RBM层数和每层RBM的节点数。

步骤3:模型预训练。将训练样本集导入模型中,从下而上逐层训练各层RBM,按照式(10)~式(12),获得各层RBM的初始化参数$w_{ij}$,$a_i$,$b_j$。

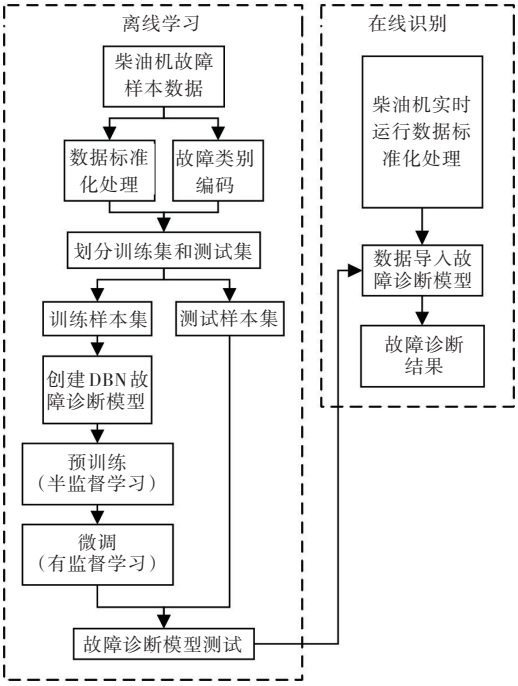


图3　船舶柴油机的故障诊断流程

Fig.3　Fault diagnosis process of marine diesel engine

步骤4:模型微调。采用BP神经网络算法反向调整预训练参数,得到最终的DBN模型。

步骤5:测试柴油机故障诊断模型的性能。将测试样本集传入诊断模型,进行故障预测和实船工况对比,从而评估该故障诊断模型的性能。

步骤6:在线故障识别。将柴油机实时运行数据进行预处理,然后导入故障诊断模型,进行故障识别。

## 4　实　例

以某型船舶柴油机为研究对象,采用AVL BOOST软件建立故障仿真模型,并开展故障仿真实验以获取相关的热工性能参数[14-15]。在100%,90%,80%负荷工况下,分别设置单缸供油量不均($d_1$)、增压器效率低下($d_2$)、空冷器效率低下($d_3$)、喷油过晚($d_4$)、喷油过早($d_5$)和正常状态($d_6$)这6种运行状态。同时,设置增压器出口(MP1)、空冷器出口(MP2)、排气总管(MP3)及涡轮出口(MP4)这4个测量点,并选取各测量点的气体压力、温度和流速以及主机的输出功率$P$、输出扭矩$N$、最高爆发压力$P_{max}$等15个热工性能参数[3,8-10,14-15]。在100%工况下的6种运行状态原始数据如表1所示。根据故障仿真实验,可以获得规模为690×15的训练集和规模为360×15的测试集。训练样本与测试样本是在同等故障模式下的不同样本,训练样本可用于评估其训练效果,测试样本可用于评估模型的泛化能力。

### 4.1　柴油机故障诊断模型

采用DBN算法建立柴油机故障诊断模型时,需对网络结构参数进行设定。根据经验,第1层和最后1层RBM的节点数量应与输入数据样本的属性维数和类别数对应。本文将RBM的初始学习率设为0.01,训练数据批处理量设为50,RBM的激活函数设为sigmoid函数。为了选取相对较好的网络结构,避免因网络层数过多而导致训练成本较大的问题,通过多次实验,计算不同层数的DBN平均性能,其对比结果如表2所示。

重构误差是DBN在预训练阶段对样本数据进行特征提取的效果评价指标,重构误差越小,表示学习效果越好,其提取特征更具有代表性。从表2可以看出,随着网络层数增加,耗时随之增加,重构误差逐渐降低到一定程度后略有波动,而网络的准确率先增加后减小,这是由于网络层数

表1 在不同状态下船舶柴油机的原始状态数据

Table 1 The original state data of marine diesel engine in different states

| 参数 | 6种运行状态下的参数值 | | | | | |
|---|---|---|---|---|---|---|
| | $d_1$ | $d_2$ | $d_3$ | $d_4$ | $d_5$ | $d_6$ |
| $P$/W | $2.642\ 63\times10^7$ | $2.681\ 61\times10^7$ | $2.720\ 99\times10^7$ | $2.652\ 96\times10^7$ | $2.850\ 92\times10^7$ | $2.773\ 49\times10^7$ |
| $N$/(N·m$^{-1}$) | $2.102\ 93\times10^6$ | $2.133\ 95\times10^6$ | $2.165\ 3\times10^6$ | $2.111\ 16\times10^6$ | $2.268\ 69\times10^6$ | $2.207\ 07\times10^6$ |
| $P_{max}$ /Pa | $1.471\ 48\times10^7$ | $1.492\ 3\times10^7$ | $1.468\ 75\times10^7$ | $1.278\ 49\times10^7$ | $1.716\ 6\times10^7$ | $1.487\ 3\times10^7$ |
| MP1压力/Pa | 280 197 | 281 461 | 281 109 | 280 005 | 280 146 | 280 066 |
| MP1温度/K | 427.366 | 526.955 | 427.742 | 427.287 | 427.345 | 427.312 |
| MP1流速/(m·s$^{-1}$) | 107.977 | 114.385 | 104.284 | 108.732 | 108.18 | 108.496 |
| MP2压力/Pa | 272 606 | 275 414 | 273 825 | 272 308 | 272 530 | 272 402 |
| MP2温度/K | 317.7 | 324.973 | 352.031 | 317.681 | 317.699 | 317.688 |
| MP2流速/(m·s$^{-1}$) | 41.963 7 | 36.637 5 | 44.812 2 | 42.278 5 | 42.043 7 | 42.179 7 |
| MP3压力/Pa | 228 703 | 290 078 | 209 994 | 215 240 | 227 593 | 221 557 |
| MP3温度/K | 780.669 | 870.192 | 835.712 | 814.528 | 780.716 | 796.779 |
| MP3流速/(m·s$^{-1}$) | 133.315 | 101.249 | 150.419 | 148.835 | 134.025 | 140.834 |
| MP4压力/Pa | 98 035.2 | 98 026.8 | 98 032.8 | 98 036 | 98 034.2 | 98 034.4 |
| MP4温度/K | 648.482 | 653.213 | 706.56 | 683.979 | 649.266 | 665.758 |
| MP4流速/(m·s$^{-1}$) | 210.989 | 183.143 | 222.728 | 224.281 | 211.336 | 217.275 |

表2 不同结构的DBN性能对比

Table 2 Comparison of DBN performance with different structures

| 网络层数 | 重构误差 | 准确率/% | 耗时/s |
|---|---|---|---|
| 1 | 11.02 | 94.84 | 4.15 |
| 2 | 0.50 | 97.35 | 6.94 |
| 3 | 0.24 | 98.35 | 9.27 |
| 4 | 0.21 | 96.01 | 10.92 |
| 5 | 0.25 | 90.71 | 13.09 |

增加到一定数值后，复杂网络将出现过拟合的问题。综合考虑重构误差、准确率和耗时3种性能指标，本文选择3层RBM作为DBN，并选择网络节点为15-3-11-9-6的3层RBM进行训练。图4所示为在预训练阶段，3层RBM的重构误差随重构次数的变化曲线。由图4可知，每层RBM的重构误差均随重构次数的增加而不断减小，其中第3层RBM的重构误差在第56次重构训练时已降至最小值0.244 9。因此，经过3层RBM学习之后，即可从原始样本集中提取代表性较强的特征，同时对网络参数进行初始化处理。

在预训练阶段所提取的特征和初始化参数，将作为下一步微调阶段输入量和网络参数的初始值。在微调阶段，设置BP神经网络算法的最大训练次数为8 000次，学习率为0.8。为了考察不同激活函数对训练效果的影响，对不同激活函数softmax，sigmoid，linear的准确率进行测试，其对比结果如表3所示。

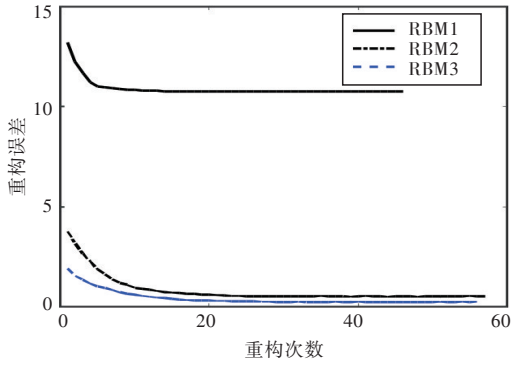


图4 3层RBM的重构误差随重构次数的变化曲线

Fig.4 The variation of the reconstruction error of the three-layer RBM with the number of reconstructions

从表3可以看出，softmax激活函数的准确率最高，sigmoid次之，linear最低，因此本文选择softmax作为DBN微调阶段的激活函数。在训练过程中，为了防止深度信念网络的过拟合问题，在微调阶段添加了dropout算法，并将dropout系数设为0.5。图5所示为微调阶段DBN的训练误差。经过训练样本集和测试样本集验证，该DBN模型的故障识别率分别为98.26%和98.61%。

表3 不同激活函数的准确率

Table 3 Accuracy of different activation functions

| 激活函数 | 准确率/% |
|---|---|
| softmax | 98.35 |
| sigmoid | 93.59 |
| linear | 90.20 |

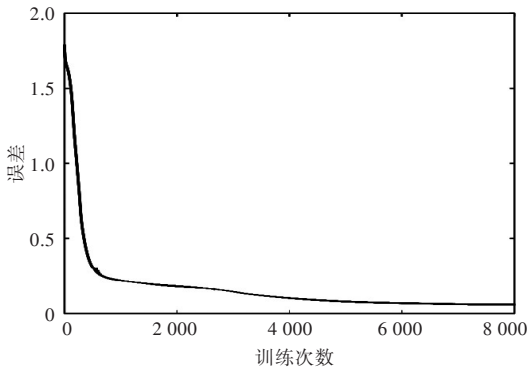


图5　微调阶段DBN的训练误差变化曲线

Fig.5　Curves of DBN training error in fine tuning

## 4.2　对比分析

为了进行对比分析,将DBN算法所采用的数据集分别用于BPNN和SVM算法训练。BP神经网络采用单隐含层,网络节点数为15-13-6,学习率为0.8,最大迭代次数为8 000,训练目标最小误差为0.001,并采用logsig激活函数和traingdx训练函数。SVM算法的惩罚系数$C$设为1,核函数选择RBF函数。计算机配置为:Intel(R)Core(TM)i7-4790 CPU,主频3.60 GHz,内存12 G,运行Matlab仿真软件。

3种算法对训练集和测试集样本的训练时间及识别率如表4所示,可以看出,DBN算法的耗时最长,但对训练样本集和测试样本集的识别率较高,这反映了该模型的学习训练效果和泛化能力较好。这是因为DBN具有相对复杂的网络结构,可以从原始训练样本集中提取更深层次的代表性隐含特征,并且在进行BP神经网络算法训练之前就获取了较好的初始化参数,故其在微调阶段网络训练的效果更好,从而提高了诊断模型的精度。

**表4　3种算法故障诊断精度的对比结果**

**Table 4　Comparison of fault diagnosis accuracy of three algorithms**

| 算法 | 训练时间/s | 训练集识别率/% | 测试集识别率/% |
|---|---|---|---|
| DBN | 10.15 | 98.26 | 98.61 |
| SVM | 0.13 | 96.52 | 96.94 |
| BPNN | 6.64 | 93.62 | 94.72 |

图6所示为3种算法对训练样本集识别结果的混淆矩阵。由图6(a)可以看出,对于船舶柴油机100%工况下的6种运行状态$d_1 \sim d_6$,采用DBN算法训练之后,可以准确识别的各类别训练样本数量为$d_1$(116/120),$d_2$(120/120),$d_3$(120/120),$d_4$(120/120),$d_5$(120/120),$d_6$(82/90)。由图6(b)和图6(c)可以看出,采用BPNN和SVM算法训练之后,可以准确识别的各类别训练样本数量为$d_1$(110/120),$d_2$(120/120),$d_3$(120/120),$d_4$(120/120),$d_5$(120/120),$d_6$(56/90)和$d_1$(110/120),$d_2$(120/120),$d_3$(120/120),$d_4$(120/120),$d_5$(120/120),$d_6$(76/90)。由此可知,3种算法都可以准确识别运行状态$d_2 \sim d_5$的训练样本,但易错误识别$d_1$和$d_6$这2种状态的样本;其中DBN算法的识别错误率最低,对故障状态$d_1$和正常状态$d_6$的识别错误分别为4个和8个,低于BPNN和SVM算法。

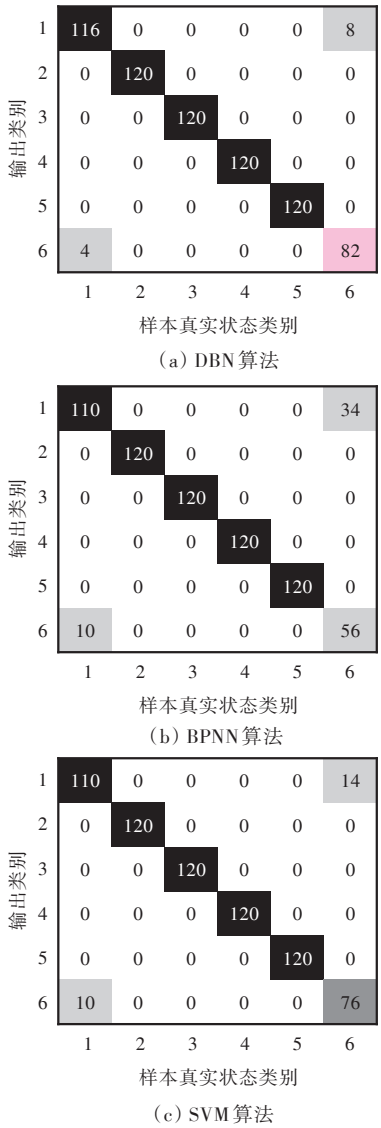


图6　3种算法对训练样本集识别结果的混淆矩阵

Fig.6　Confusion matrix of recognition results of training sample sets by three algorithms

图7所示为3种算法对测试样本集识别结果的混淆矩阵。由图7可以看出,3种算法都可以准确识别运行状态$d_2 \sim d_5$的测试样本,但对$d_1$和$d_6$的识别存在一定误差;其中DBN的识别误差为$d_1$(1/60)和$d_6$(4/60),而BPNN和SVM的识别误差分别为$d_1$(2/60),$d_6$(17/60)和$d_1$(4/60),$d_6$(7/60),其错误率均高于DBN。由此可见,基于DBN算法的故障

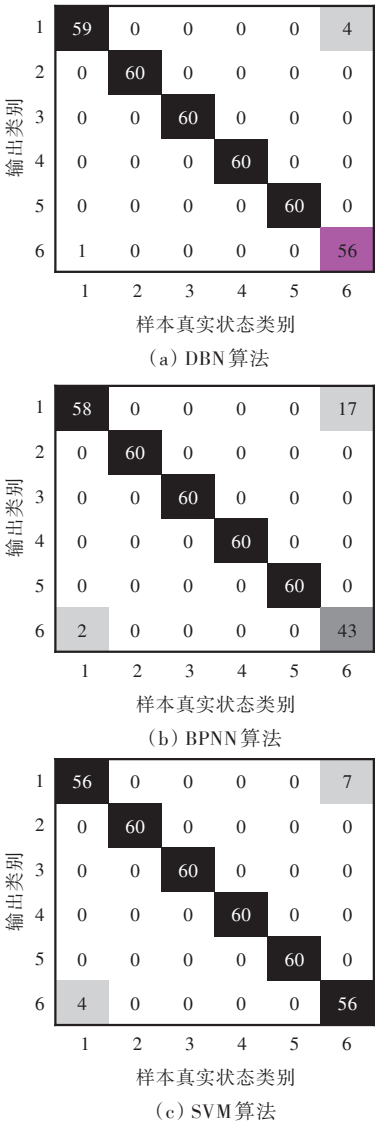


图7 3种算法对测试样本集识别结果的混淆矩阵

Fig.7 Confusion matrix of recognition results of test sample sets by three algorithms

诊断方法具有较强的泛化能力。

## 5 结 语

本文将深度信念网络应用于船舶柴油机故障诊断,实现了原始故障样本数据的深层次隐含特征提取和神经网络参数初始化,提升了故障诊断模型的精度和泛化性能。根据某型船用柴油机故障仿真的样本验证结果:基于DBN的船用柴油机故障诊断方法具有较高的识别精度(高达98.26%);DBN算法的故障诊断精度优于BPNN算法和SVM算法。需注意的是,与其他机器学习方法类似,DBN算法也是通过对样本库数据进行学习而成,因此目前无法识别新的故障状态。此外,调整DBN的网络结构和训练次数时,需要依靠一定程度的人为经验,这有待进一步深入研究。

**参考文献:**

[1] 裴大茗,王建峰,周鹏太,等. 船舶PHM技术综述[J]. 电子测量与仪器学报,2016,30(9):1289-1297.
PEI D M, WANG J F, ZHOU P T, et al. Survey on PHM technology in marine system[J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(9): 1289-1297 (in Chinese).

[2] 贾宝柱,贾志涛,赵祥. 基于信息融合的船舶中央冷却系统运行状态评估[J]. 大连海事大学学报,2017,43(4):89-96.
JIA B Z, JIA Z T, ZHAO X. Operating condition evaluation of ship central cooling system based on information fusion[J]. Journal of Dalian Maritime University, 2017, 43(4): 89-96 (in Chinese).

[3] 贺立敏,王岘昕,韩冰. 基于随机森林和支持向量机的船舶柴油机故障诊断[J]. 中国航海,2017,40(2):29-33.
HE L M, WANG X X, HAN B. Fault diagnosis of marine diesel engine based on random forest and support vector machine[J]. Navigation of China, 2017, 40(2): 29-33 (in Chinese).

[4] ZHANG J H, LIU Y. Application of complete ensemble intrinsic time-scale decomposition and least-square SVM optimized using hybrid DE and PSO to fault diagnosis of diesel engines[J]. Frontiers of Information Technology & Electronic Engineering, 2017, 18(2): 272-286.

[5] XI W K, LI Z X, TIAN Z, et al. A feature extraction and visualization method for fault detection of marine diesel engines[J]. Measurement, 2018, 116: 429-437.

[6] 雷亚国,贾峰,孔德同,等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报,2018,54(5):94-104.
LEI Y G, JIA F, KONG D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104 (in Chinese).

[7] TAMILSELVAN P, WANG P F. Failure diagnosis using deep belief learning based health state classification[J]. Reliability Engineering & System Safety, 2013, 115: 124-135.

[8] 车畅畅,王华伟,倪晓梅,等. 基于深度学习的航空发动机故障融合诊断[J]. 北京航空航天大学学报,2018,44(3):621-628.
CHE C C, WANG H W, NI X M, et al. Fault fusion diagnosis of aero-engine based on deep learning[J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(3): 621-628 (in Chinese).

(下转第184页)

Journal of Ship Research, 2008, 3(3): 71-73 (in Chinese).

[2] 肖贺, 管海兵, 宦飞. 工业以太网冗余技术分析[J]. 信息安全与通信保密, 2012(3): 59-63, 67.
XIAO H, GUAN H B, HUAN F. Analysis of redundancy technology for industrial Ethernet[J]. China Information Security, 2012(3): 59-63, 67 (in Chinese).

[3] 邹传智. 基于多串口转以太网的数据采集及分析系统设计[D]. 济南: 东华大学, 2017.
ZOU C Z. The design of data acquisition and analysis system based on multi-serial port turn to Ethernet[D]. Ji'nan: Donghua University, 2017 (in Chinese).

[4] 张高明, 李维波, 华逸飞, 等. 基于W5200的双冗余以太网通信系统应用研究[J]. 中国舰船研究, 2018, 13(1): 127-132.
ZHANG G M, LI W B, HUA Y F, et al. Study of dual redundant Ethernet communication system centered on W5200 IC [J]. Chinese Journal of Ship Research, 2018, 13(1): 127-132 (in Chinese).

[5] 任康健. 综合舰桥系统多总线网关的设计与实现[D]. 哈尔滨: 哈尔滨工程大学, 2013.
REN K J. Design and realization of multi-bus gateway for integrated bridge system[D]. Harbin: Harbin Engineering University, 2013 (in Chinese).

[6] 邓红德, 李阳, 吴佳楠. 基于RL-ARM的嵌入式以太网与串口通信系统设计[J]. 测控技术, 2012, 31(8): 75-79.
DENG H D, LI Y, WU J N. Design of embedded communication system between multi-channel UART and Ethernet based on RL-ARM library[J]. Measurement & Control Technology, 2012, 31(8): 75-79 (in Chinese).

[7] 李丙伟. 工业以太网通信技术研究与嵌入式TCP/IP协议栈开发[D]. 上海: 华东理工大学, 2012.
LI B W. Research on industrial Ethernet and development of the embedded TCP/IP stack[D]. Shanghai: East China University of Science and Technology, 2012 (in Chinese).

[8] 王文, 郑建生. 基于FPGA的TCP/IP网络通信系统的设计与实现[J]. 现代电子技术, 2018, 41(8): 5-9.
WANG W, ZHENG J S. Design and implementation of TCP/IP network communication system based on FPGA [J]. Modern Electronics Technique, 2018, 41(8): 5-9 (in Chinese).

[9] 刘承, 刘向东, 李黎. RS-422串口通信在DSP中的设计与应用[J]. 工业控制计算机, 2006, 19(3): 33-34, 55.
LIU C, LIU X D, LI L. Design and application of serial communication about RS-422 for DSP[J]. Industrial Control Computer, 2006, 19(3): 33-34, 55 (in Chinese).

[10] 范鹏飞, 崔锡奎, 王祥宝, 等. 数控系统模块间RS-422串行通信协议的设计[J]. 科技视界, 2015(19): 116-117, 160.
FAN P F, CUI X K, WANG X B, et al. Design of RS-422 serial communication protocol between numerical control modules[J]. Science & Technology Vision, 2015(19): 116-117, 160 (in Chinese).

(上接第142页)

[9] 李本威, 林学森, 杨欣毅, 等. 深度置信网络在发动机气路部件性能衰退故障诊断中的应用研究[J]. 推进技术, 2016, 37(11): 2173-2180.
LI B W, LIN X S, YANG X Y, et al. Research on application of deep belief networks on engine gas path component performance degradation defect diagnostics [J]. Journal of Propulsion Technology, 2016, 37(11): 2173-2180 (in Chinese).

[10] 贾继德, 贾翔宇, 梅检民, 等. 基于小波与深度置信网络的柴油机失火故障诊断[J]. 汽车工程, 2018, 40(7): 838-843.
JIA J D, JIA X Y, MEI J M, et al. Misfire fault diagnosis of diesel engine based on wavelet and deep belief network[J]. Automotive Engineering, 2018, 40(7): 838-843 (in Chinese).

[11] 李军亮, 滕克难, 夏菲. 基于深度学习的军用飞机部件状态参数预测[J]. 振动与冲击, 2018, 37(6): 61-67, 85.
LI J L, TENG K N, XIA F. Military aircraft components state parameters prediction using the deep belief learning [J]. Journal of Vibration and Shock, 2018, 37(6): 61-67, 85 (in Chinese).

[12] HINTON G E. A practical guide to training restricted Boltzmann machines [M]//MONTAVON G, ORR G B, MULLER K R. Neural networks: tricks of the trade. [S.l. :s.n. ], 2012: 599-619.

[13] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527-1554.

[14] 王忠巍, 袁志国, 马修真, 等. 一种不依赖特征样本的柴油机故障诊断方法研究[J]. 哈尔滨工程大学学报, 2017, 38(6): 881-886.
WANG Z W, YUAN Z G, MA X Z, et al. A diesel engine fault diagnosis method independent of feature samples[J]. Journal of Harbin Engineering University, 2017, 38(6): 881-886 (in Chinese).

[15] RUBIO J A P, VERA G F, GRAU J H, et al. Marine diesel engine failure simulator based on thermodynamic model[J]. Applied Thermal Engineering, 2018, 144: 982-995.