

# 集成参数自适应调整及隐含层降噪的深层 RBM 算法

张绍辉<sup>1</sup>

**摘要** 深度置信网络是由若干层无监督的限制玻尔兹曼机 (Restricted Boltzmann machines, RBM) 和一层有监督的反馈神经网络组成的深层结构, 该结构通过对低层输入的逐层抽象转化提取复杂输入及复杂分类数据的有效信息. 然而, 深度置信网络模型存在隐含层数及特征维数难以确定, 后向有监督过程存在“导数消亡”问题, 使得低层结构参数得不到有效的训练, 而且噪声干扰直接影响识别结果的问题. 针对以上问题, 提出以下解决方法: 每个隐含层位置构建当前层输出与样本标签之间的映射转换矩阵, 根据理论标签与实际标签之间的差异, 实现隐含层特征维数的自适应调整, 缓解“导数消亡”问题, 同时在第一隐含层位置进行特征空间降噪, 保证计算效率及提高诊断模型的识别效果. 复杂工况的齿轮箱故障模拟实验, 验证所提方法的有效性.

**关键词** 限制玻尔兹曼机, 特征提取, 降噪, 齿轮箱

**引用格式** 张绍辉. 集成参数自适应调整及隐含层降噪的深层 RBM 算法. 自动化学报, 2017, 43(5): 855–865

**DOI** 10.16383/j.aas.2017.c160375

## Deep RBM Algorithm with Adaptive Adjustment Parameters and De-noising in Hidden Layer

ZHANG Shao-Hui<sup>1</sup>

**Abstract** Deep belief nets consist of several-layered unsupervised restricted Boltzmann machines and one-layered supervised feedback neural network. It digs the inner structure and pattern of the complex input data through effective information abstraction layer by layer, which can well reflect the input mode. However, the hidden layer numbers and the feature dimension are difficult to determine. The feedback process exhibits the vanishing gradient problem, which results in ineffective structural parameters training for lower layers. Moreover, noise affects the recognition results directly. To aim at the problem, a transformation matrix between samples and labels is made for each layer to realize adaptive adjustment of the parameter of hidden layer, and the feature of the hidden layer is de-noised for improving recognition accuracy and calculation efficiency. Simulation experiments on fault diagnosis of a gearbox in complex working conditions have proved the effectiveness of the proposed method.

**Key words** Restricted Boltzmann machines (RBM), feature extraction, de-noising, gearbox

**Citation** Zhang Shao-Hui. Deep RBM algorithm with adaptive adjustment parameters and de-noising in hidden layer. *Acta Automatica Sinica*, 2017, 43(5): 855–865

齿轮箱是旋转机械系统的重要组成部分, 其运行状态的好坏直接影响到相应设备的工作状况, 因此, 国内外学者从机理、信号分析等方面对齿轮箱部件的故障诊断方法展开研究. 然而, 实际齿轮箱长时

间运行于变转速、变载荷的工况, 无论从机理方面还是信号处理方面对其进行诊断, 均需要专家学者长时间的经验积累, 且受到复杂环境的影响, 实际诊断正确率还“差强人意”. 随着人工智能诊断方法的引进, 由于算法可以指导建立故障诊断模型, 具有更好的稳定性, 受到研究人员的广泛关注. 现有的智能诊断算法, 如 PCA (Principal component analysis)、LPP (Locality preserving projections)、NPE (Neighborhood preserving embedding) 等已经应用于机械故障诊断, 并取得了一定的效果<sup>[1–3]</sup>. 然而, 从结构角度分析, 这些算法模型均属于“浅层结构”模式, 不能完整地描述输入信息的真实情况, 揭示复杂输入的内在规律, 而且在实际应用中, 需要对信号预先进行时域、频域及时频域的特征计算, 由于经验不同, 不同学者采用的特征计算方法及个数存在差别, 识别正确率与选择的计算特征“息息相关”.

收稿日期 2016-05-05 录用日期 2016-09-30  
Manuscript received May 5, 2016; accepted September 30, 2016  
国家自然科学基金 (51605406, 51475170, 51605405, 51405272), 厦门理工学院科研启动项目 (YKJ14042R), 福建省自然科学基金青年基金 (2014J05065), 广东高校青年创新人才项目 (2014KQNCX176) 资助

Supported by National Natural Science Foundation of China (51605406, 51475170, 51605405, 51405272), Scientific Research Project of Xiamen University of Technology (YKJ14042R), Natural Science Foundation of Fujian Province (2014J05065), Foundation for Distinguished Young Talents in Higher Education of Guangdong (2014KQNCX176)

本文责任编辑 夏元清  
Recommended by Associate Editor XIA Yuan-Qing

1. 厦门理工学院机械与汽车工程学院 厦门 361024  
1. School of Mechanical and Automotive Engineering, Xiamen University of Technology, Xiamen 361024

针对该问题, 加拿大多伦多大学 Hinton 教授提出一种“深层结构”的数据处理手段, 即深度学习算法 (Deep learning, DL)<sup>[4]</sup>, 受到机器学习、模式识别、数据挖掘以及商业领域研究人员的广泛关注<sup>[5-7]</sup>. 该算法的动机在于建立模拟人脑进行分析学习的神经网络结构, 通过学习一种深层非线性网络模型, 实现复杂函数的逼近, 展现了从少数样本集中学习数据集本质特征的强大能力. 从现有的检索资料显示, 以限制玻尔兹曼机 (Restricted Boltzmann machines, RBM) 为基础建立的深度置信网络模型已经被应用于机械故障诊断中. 如 Tamilselvan 等<sup>[8]</sup> 利用深度置信网络融合多传感器信息, 用于航空发动机及电力变压器的故障分类; Fu 等<sup>[9]</sup> 将深度置信网络用于切削设备的状态监测; Tran 等<sup>[10]</sup> 则利用深度置信网络融合振动、压力与电流等 3 种信号对往复压缩机阀门的故障进行分类识别; Gan 等<sup>[11]</sup> 构建基于深度置信网络的分层故障诊断模型用于轴承状态识别; 王宪保等<sup>[12]</sup> 将深度置信网络方法应用于太阳能电池片表面缺陷检测; 黄海波等<sup>[13]</sup> 将深度置信网络用于车辆悬架减震器异响的分类; Li 等<sup>[14]</sup> 将深度玻尔兹曼机用于齿轮箱故障诊断; 谢吉朋<sup>[15]</sup> 将深度置信网络用于列车走行部件的故障诊断. 然而, 现有的深度置信网络由若干层无监督 RBM 及最后一层反馈神经网络组成, 后向反馈过程存在“导数消亡”问题, 即, 利用高层得到的误差在向下逐层参数修正过程中, 会出现信息的泄露, 导致低层的结构参数无法得到更新, 这种情况受到噪声的干扰更为明显, 而深度玻尔兹曼机亦存在着深度层数及隐含层特征数难以确定的问题, 深度层数越多, 结构越复杂, 各隐含层的特征数越难匹配.

针对该问题, 提出构建参数自适应调整及隐含层降噪的深层 RBM 智能诊断模型, 该模型具有如下特点: 1) 每个隐含层位置利用映射转换矩阵构建高层输出与样本标签之间的对应关系, 实现每个隐含层结构参数的优化, 消除“导数消亡”问题; 2) 以识别正确率为目标, 实现隐含层特征维数的自适应调整, 确定深度层数及各隐含层的特征数; 3) 在第一隐含层的输出位置进行降噪处理, 保证计算效率及提高诊断模型的识别效果. 将复杂工况下采集到的齿轮箱故障信号作为输入, 对比浅层结构 RBM、PCA、LPP 等方法, 验证所提方法的有效性.

## 1 参数自适应调整及隐含层降噪 RBM 智能诊断模型构建过程

设样本  $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$  为原始高维空间的数据集, 样本数为  $n$ , 维数为  $m$ , 类别数为  $c$ ,  $\mathbf{C}$  为样本的标签信息, 维数为  $c$ ,  $\mathbf{Y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n)$  为降维后的数据集, 维数为  $d$ . 深层 RBM 的维数约简过程如图 1 所示, 其中  $H_i$  ( $i = 1, 2, \dots, k$ ) 代表各个隐含层数据集, 在每个隐含层位置, 通过对比此时样本的理论标签信息与实际标签信息之间的差别, 对隐含层特征数进行修正, 逐层实现维数的约简, 具体实现步骤如下.

### 1.1 深层 RBM 算法原理

RBM 是一种可视层和隐含层单元相互连接 (同层内部相互独立) 的典型神经网络, 由可视层输入单元与隐含层激活单元之间的差异, 实现层间参数的更新.

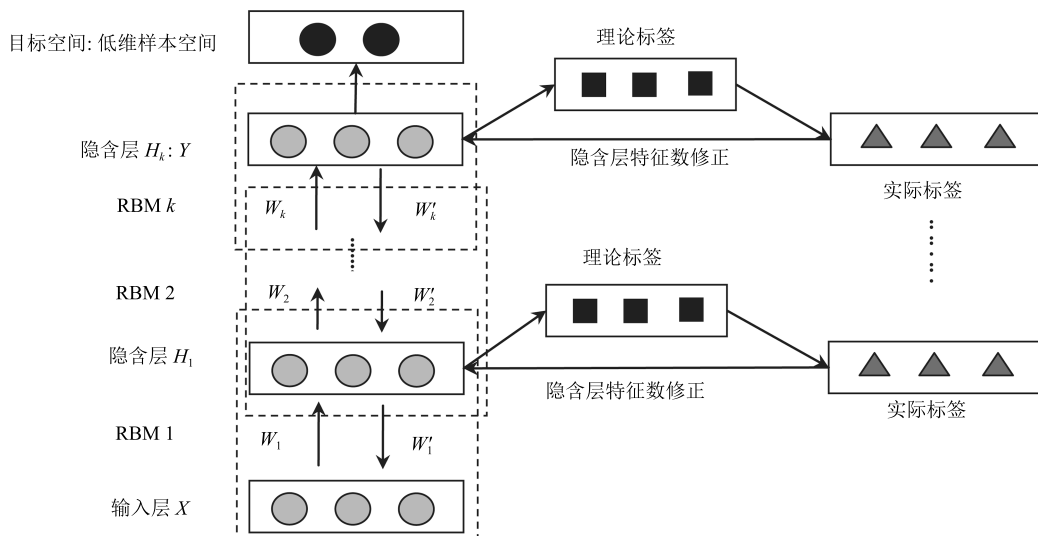


图 1 参数自适应调整深层 RBM 智能诊断模型

Fig. 1 Parameter self-adaptive adjustment of deep RBM intelligent diagnosis model

以图 1 中的第一个 RBM 建立过程为例, 此时 RBM 中有  $m$  个可视单元, 假设其有  $q$  个隐含单元, 用  $\mathbf{v}_1$  和  $\mathbf{h}_1$  分别表示第一个 RBM 的可视层和隐含层的状态,  $\mathbf{v}_1 = (v_{11}, v_{12} \cdots, v_{1m})$ ,  $\mathbf{h}_1 = (h_{11}, h_{12} \cdots, h_{1q})$ , 在 RBM 中所有的可视层单元和隐藏层单元只有激活和未激活两种状态, 用二进制的 0 和 1 表示.

在给定输入能量和网络参数  $\theta$  ( $\theta = \{W, \mathbf{a}, \mathbf{b}\}$ ) 时, RBM 系统的能量可由式 (1) 得到, 定义该 RBM 能量函数<sup>[16]</sup>

$$E(\mathbf{v}_1, \mathbf{h}_1) = - \sum_{i=1}^m a_i v_{1i} - \sum_{j=1}^q b_j h_{1j} - \sum_{i=1}^m \sum_{j=1}^q v_{1i} w_{ij} h_{1j} \quad (1)$$

当上述各个参数确定时, RBM 处于  $\mathbf{v}_1, \mathbf{h}_1$  的联合概率分布满足

$$P(\mathbf{v}_1, \mathbf{h}_1) = \frac{1}{Z} \exp(-E(\mathbf{v}_1, \mathbf{h}_1)) \quad (2)$$

式中,  $Z = \sum_{\mathbf{v}_1, \mathbf{h}_1} \exp(-E(\mathbf{v}_1, \mathbf{h}_1))$  称为配分函数.

因隐含层内部和显示层内部均不存在连接, 当给定可见单元状态时, 隐含层单元的激活状态之间是相互独立的, 其激活概率如式 (3) 所示, 同理, 当给定隐含单元状态时, 可视层单元的激活状态也是相互独立的, 其激活概率如式 (4) 所示

$$P(h_{1j} = 1 | \mathbf{v}_1) = \frac{\text{sigmoid}(-b_j - \sum_i v_{1i} w_{ij})}{1 + \exp(-b_j - \sum_i v_{1i} w_{ij})} \quad (3)$$

$$P(v_{1i} = 1 | \mathbf{h}_1) = \frac{\text{sigmoid}(-a_i - \sum_j w_{ij} h_{1j})}{1 + \exp(-a_i - \sum_j w_{ij} h_{1j})} \quad (4)$$

式中,  $v_{1i}$  为可视层第  $i$  个单元的状态,  $h_{1j}$  为隐含层第  $j$  个单元的状态,  $a_i$  为可视单元  $v_{1i}$  的偏置,  $b_j$  为隐含单元  $h_{1j}$  的偏置,  $w_{ij}$  为连接可视单元  $v_{1i}$  和隐含单元  $h_{1j}$  的权重.

为了获得参数  $\theta$ , 使用随机梯度下降法求取对数似然函数最大值, 对参数  $\theta$  求偏导得

$$\frac{\partial \ln P(\mathbf{v}_1)}{\partial \theta} = E_{P(\mathbf{h}_1 | \mathbf{v}_1)} \left[ - \frac{\partial E(\mathbf{v}_1, \mathbf{h}_1)}{\partial \theta} \right] - E_{P(\mathbf{v}_1, \mathbf{h}_1)} \left[ - \frac{\partial E(\mathbf{v}_1, \mathbf{h}_1)}{\partial \theta} \right] \quad (5)$$

式中, 第一项是指函数  $-\frac{\partial E(\mathbf{v}_1, \mathbf{h}_1)}{\partial \theta}$  在概率  $P(\mathbf{v}_1 | \mathbf{h}_1)$  下的期望, 其值容易求取; 式中第二项是

指  $-\frac{\partial E(\mathbf{v}_1, \mathbf{h}_1)}{\partial \theta}$  函数在概率  $P(\mathbf{v}_1, \mathbf{h}_1)$  下的期望, 其值不易求取. 为此, Hinton 等<sup>[4]</sup> 提出对比差异度 CD (Contrastive divergence) 快速算法, 该快速算法利用训练数据初始化可视层, 并利用式 (1) 计算所有隐含层单元状态, 当隐含层的状态确定之后再根据式 (2) 计算可视单元的状态, 此时相当于产生了对上一步可视层的一个重构. 因此, 使用梯度下降法最大化似然函数, 可以推导得到参数  $\theta = \{W, \mathbf{b}, \mathbf{a}\}$  的更新式为

$$\Delta w_{ij} = \varepsilon \left( \langle v_{1i} h_{1j} \rangle_{P(\mathbf{h}_1 | \mathbf{v}_1)} - \langle v_{1i} h_{1j} \rangle_{recon} \right) \quad (6)$$

$$\Delta b_i = \varepsilon \left( \langle v_{1i} \rangle_{P(\mathbf{h}_1 | \mathbf{v}_1)} - \langle v_{1i} \rangle_{recon} \right) \quad (7)$$

$$\Delta a_j = \varepsilon \left( \langle h_{1j} \rangle_{P(\mathbf{h}_1 | \mathbf{v}_1)} - \langle h_{1j} \rangle_{recon} \right) \quad (8)$$

式中,  $\varepsilon$  是学习率,  $\langle \cdot \rangle_{P(\mathbf{h}_1 | \mathbf{v}_1)}$  代表偏导函数在  $P(h_{1j} | v_{1i})$  分布下的期望,  $\langle \cdot \rangle_{recon}$  表示偏导函数在重构后模型分布下的期望.

基于 CD 算法的 RBM 训练过程如下所示:

**输入.** 训练样本  $\mathbf{X}$ , 学习率  $\varepsilon$ , 隐含层数  $k$ ;

**初始化.** 可视层初始状态  $\mathbf{v}_1 = \mathbf{X}$ , 以随机最小值初始化可见层和隐含层之间的连接权重  $W$ 、可视层偏置  $\mathbf{a}$ 、隐含层偏置  $\mathbf{b}$ ,  $\mathbf{v}_2$  和  $\mathbf{h}_2$  分别代表第二个 RBM 的可视层和隐含层.

**步骤 1.** 由式 (1) 计算  $P(h_{1j} = 1 | \mathbf{v}_1)$ , 并从中采样  $h_{1j} \in \{0, 1\}$ ;

**步骤 2.** 由式 (2) 计算  $P(v_{2j} = 1 | \mathbf{h}_1)$ , 并从中采样  $v_{2j} \in \{0, 1\}$ ;

**步骤 3.** 由式 (1) 计算  $P(h_{2i} = 1 | \mathbf{v}_2)$ , 并按照下式更新参数.

$$W \leftarrow W + \varepsilon (\mathbf{h}_1 \mathbf{v}_1^T - P(\mathbf{h}_2 = 1 | \mathbf{v}_2) \mathbf{v}_2^T)$$

$$\mathbf{a} \leftarrow \mathbf{a} + \varepsilon (\mathbf{v}_1 - \mathbf{v}_2)$$

$$\mathbf{b} \leftarrow \mathbf{b} + \varepsilon (\mathbf{h}_1 - P(\mathbf{h}_2 = 1 | \mathbf{v}_2))$$

深度置信网络 DBN 算法是在堆叠上述 RBM 结构的基础上, 在顶层根据输出样本标签与实际样本标签之间的差异, 增加有监督的后向微调过程, 然而, 顶层标签的差异在后向传递过程存在信号的衰减问题, 即“导数消亡”问题, 导致低层参数无法得到修正, 影响最终的识别效果, 针对该问题, 提出逐层监督学习, 优化隐含层的特征数, 缓解“导数消亡”问题, 提高识别效果.

## 1.2 参数自适应调整 RBM 方法

为了确定深度层数及各隐含层的最优特征数, 将训练样本均分为  $\mathbf{X}_1$  与  $\mathbf{X}_2$  两部分,  $\mathbf{X}_2$  作为测试部分, 用于确定最优层数及特征数. 相应的标签信息为  $\mathbf{C}_1$  和  $\mathbf{C}_2$ , 对于第一层 RBM, 由 RBM 训练过程

可以得到相应的隐含层状态  $\mathbf{h}_1$  及连接可视层与隐含层的权重参数, 假设存在映射转换矩阵  $A \in \mathbf{R}^{q \times c}$  使得隐含层状态  $\mathbf{h}_1$  与样本标签信息  $\mathbf{Y}_1$  一一对应, 即

$$\mathbf{h}_1 A = \mathbf{C}_1 \quad (9)$$

对式 (9) 两边同时乘  $\mathbf{h}_1$  的转置矩阵  $\mathbf{h}_1^T$ , 得到

$$\mathbf{h}_1^T \mathbf{h}_1 A = \mathbf{h}_1^T \mathbf{C}_1 \quad (10)$$

$\mathbf{h}_1^T \mathbf{h}_1$  为  $q \times q$  的方阵, 对其取逆可得映射转换矩阵的表达式

$$A = (\mathbf{h}_1^T \mathbf{h}_1)^{-1} \mathbf{h}_1^T \mathbf{C}_1 \quad (11)$$

对于测试样本  $\mathbf{X}_2$ , 根据可视层与隐含层的连接参数  $\theta = \{W, \mathbf{a}, \mathbf{b}\}$ , 可获得其隐含层输出为  $\mathbf{H}$ , 结合隐含层与样本标签信息之间的映射转换矩阵, 可以得到测试样本的理论样本标签为  $\mathbf{C}_h = \mathbf{H} \times A$ .

此时根据样本理论标签  $\mathbf{C}_h$  与实际标签  $\mathbf{C}_2$  可以计算识别错误率,

$$error = \frac{\sum_{i=1}^{\text{num}(\mathbf{C}_2)} |\mathbf{C}_h^i - \mathbf{C}_2^i|}{\text{num}(\mathbf{C}_2)} \quad (12)$$

式中,  $\mathbf{C}_h^i, \mathbf{C}_2^i$  分别代表样本  $i$  的理论标签和实际标签,  $\text{num}(\mathbf{C}_2)$  为样本标签的总个数,  $|\mathbf{C}_h^i - \mathbf{C}_2^i| \in \{0, 1\}$  即当理论标签和实际标签相同时取 0, 否则取 1. 通过控制识别错误率  $error$  的大小, 修正隐含层的特征数, 从而获得该隐含层的最优特征数.

将该隐含层的输出  $\mathbf{H}$  作为后续 RBM 模型的输入, 依次对各个 RBM 模型进行训练并得到各个隐含层的最优特征数, 由此构建参数自适应调整的深层 RBM 模型, 实现维数的逐层约简.

### 1.3 隐含层特征空间降噪分析

从设备上采集到代表设备状态的信号, 不可避免地带有噪声成分, 而噪声成分不可能在深层 RBM 模型的转化过程中自动消亡, 而是逐层转化最终依然以噪声的形式叠加在高层输出上. 将输入层的  $\mathbf{X}$  表示为:  $\mathbf{X} = \mathbf{X}' + \Delta\mathbf{X}$ , 其中  $\mathbf{X}'$  为理论无噪声波形,  $\Delta\mathbf{X}$  代表加性噪声成分, 假设深层 RBM 模型由  $k$  个 RBM 叠加而成, 则低层输入  $\mathbf{X}$  经深层 RBM 过程得到的输出为  $\mathbf{Y}$ :

$$\begin{aligned} \mathbf{Y} &= \mathbf{X} \times W_1 \times W_2 \times \cdots \times W_k = \\ &\mathbf{X}' \times W_1 \times W_2 \times \cdots \times W_k + \\ &\Delta\mathbf{X} \times W_1 \times W_2 \times \cdots \times W_k = \\ &\mathbf{Y}' + \Delta\mathbf{Y} \end{aligned} \quad (13)$$

式中,  $W_i (i = 1, 2, \cdots, k)$  为第  $i$  层 RBM 模型连接可视层与隐含层的权重参数, 从式中可见, 噪声  $\Delta\mathbf{X}$

逐层转化到高层输出信息  $\mathbf{Y}$  中, 以加性噪声  $\Delta\mathbf{Y}$  的形式存在, 而高层的噪声将直接影响着样本的识别及聚类效果, 因此, 需要通过降噪的方式提高模型的诊断效果. 然而, 增加降噪过程将会增加相应的计算量. 针对该问题, 提出在第一层 RBM 的输出位置进行特征空间降噪, 因为所提深层 RBM 诊断模型是逐层降维过程, 第一层 RBM 输出的样本矩阵 ( $n \times q$  维) 已远小于输入样本矩阵 ( $n \times m$  维), 即此时所需要的降噪点数为原始输入的  $q/m$  倍 ( $q \ll m$ ), 因此, 对第一隐含层进行降噪, 可以较好地提高计算效率, 并保证后续隐层的抽象转化效果.

具体隐含层特征空间降噪步骤如下:

1) 将  $\mathbf{X}$  输入第一层 RBM 得到第一个隐含层输出, 对隐层输出的每个特征进行相空间重构实现信噪分离, 接着对重构好的相空间  $M$  进行奇异值分解,  $M = U\Sigma V^T$ ,  $U$  和  $V$  为正交矩阵,  $\Sigma$  为对角矩阵, 对角线的值为  $M$  的奇异值, 值越大表明噪声越小, 反之表示噪声越大. 保留几个较大的奇异值, 而把较小的奇异值置 0 可以有效地提高信噪比, 得到新的对角矩阵  $\Sigma'$ ;

2) 重新计算相空间矩阵  $M' = U\Sigma'V^T$ , 返回降噪后的隐含层输出, 作为第二个 RBM 的输入, 具体算法流程如图 2 所示.

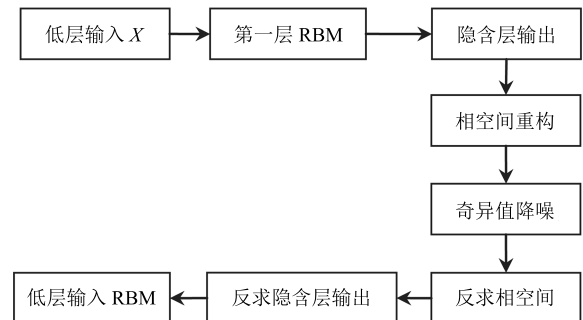


图 2 隐含层特征空间降噪流程

Fig. 2 De-noising of hidden layer feature

### 1.4 参数自适应调整及隐含层降噪的深层 RBM 智能诊断模型

设置目标识别错误率、迭代次数及初始维数, 在迭代过程中, 当识别错误率小于设定值且维数大于设定值时, 将输出样本作为下一轮的输入, 同时记录此时的隐含层特征数; 当迭代次数高于设定值时, 退出循环, 由此确定深层 RBM 智能诊断模型的层数及各隐含层的特征数, 具体实现流程如图 3 所示. 为消除噪声对识别正确率的影响, 同时保证计算效率提高模型的泛化性, 在第一隐含层的位置对样本进行降噪处理, 由于此时的样本维数远远小于输入维数, 因此可以提高计算效率, 消除噪声之后可以保证后面各层样本特征抽象的准确性.

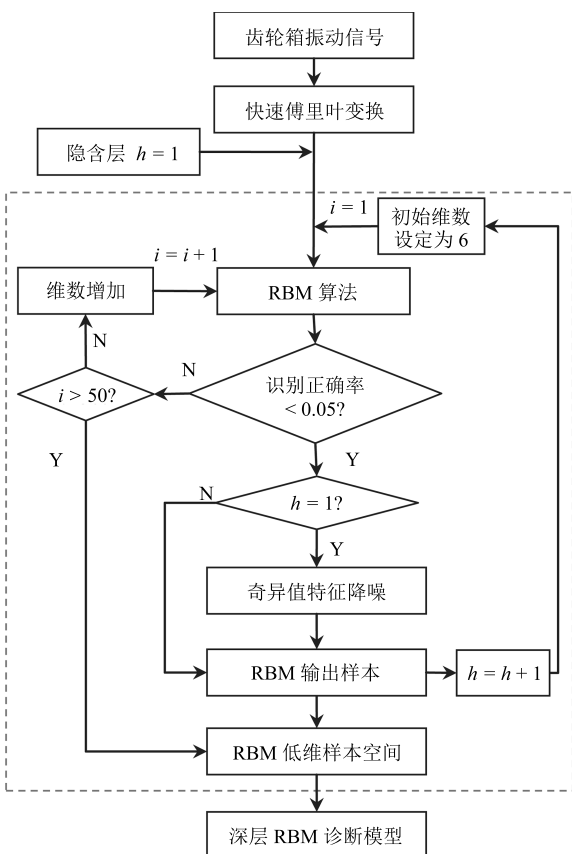


图 3 集成参数自适应调整及隐含层降噪的深层 RBM 智能诊断模型

Fig. 3 Deep RBM intelligent diagnosis model based on adaptive adjustment parameters and de-noising in hidden layer

## 2 实验分析

图 4 为实验传动路线图, 拖动电机模拟汽车的发动机, 转矩转速传感器用于测定输入测试变速箱的转速及载荷, 加载电机用于提供测试变速箱的载荷. 齿轮箱实物及传递路线结构如图 5 所示, 二挡传递路线为: 输入轴—齿轮 26—齿轮 38—齿轮 20—齿轮 41—输出轴, 图 5 中的数字为齿轮齿数; 五挡传递路线为: 输入轴—齿轮 26—齿轮 38—齿轮 42—齿轮 22—输出轴, 故障轴承均放在输出轴位置. 图 6 为具体故障齿轮和轴承, 实验齿轮箱状态设置分为: 1) 正常状态—五档; 2) 单一故障状态: 内圈故障 0.2 mm—五档、二挡剥落 (齿轮 41 剥落)、五档断齿 (齿轮 22 断齿); 3) 复合故障状态: 内圈故障 2 mm + 二挡剥落 (齿轮 41 剥落)、内圈故障 2 mm + 五档断齿 (齿轮 22 断齿), 共 6 种齿轮箱状态, 即数据样本的类别数为 6. 通过振动加速度传感器采集这些状态在转速为 1000 rpm 和 1250 rpm, 载荷为 0 N·m 和 50 N·m 四个工况下的时域信号 (具体如表 1 所示), 采样频率为 24 kHz, 采样时间为 0.5 s,

即采样点数为 12 288.

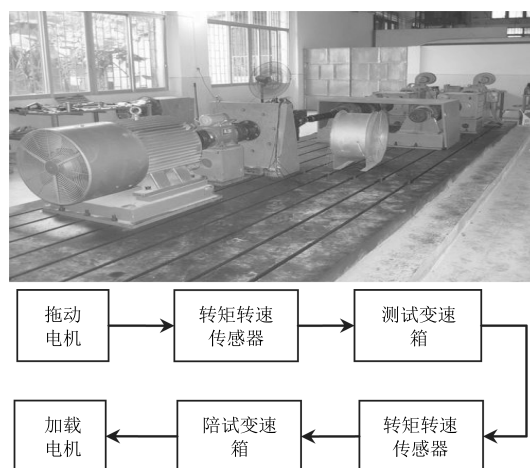


图 4 齿轮箱传动试验台及传动路线结构  
Fig. 4 Transmission test-bed of gearbox





图 5 齿轮箱实物及传递路线结构

Fig. 5 Gearbox real product and the transmission


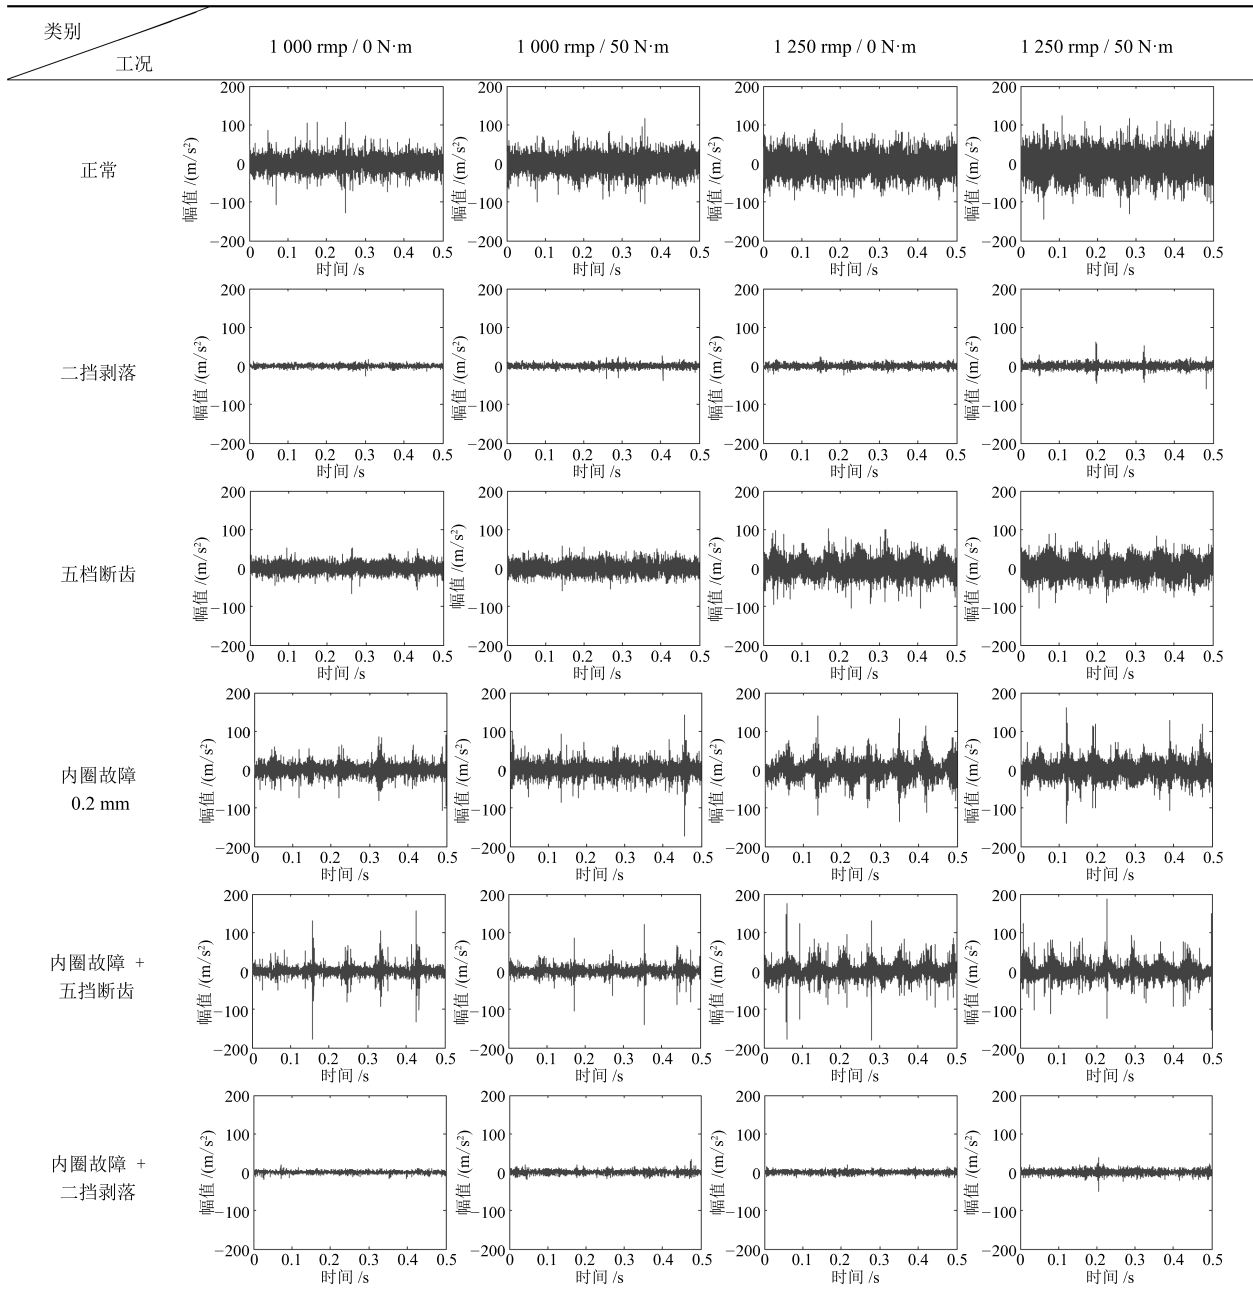


图 6 齿轮箱故障轴承及齿轮实物

Fig. 6 The fault bearing and gear real products

表 1 6种齿轮箱状态在4种工况下的时域波形

Table 1 The time waveform of 6 states of gear box under four conditions



对比表 1 中的振动波形图可见, 当故障状态中存在齿轮剥落时, 样本振动信号的幅值较小, 当故障为内圈故障、断齿及内圈与断齿复合故障时, 振动信号的幅值较大, 且存在相应的冲击成分, 不同转速及载荷下的振动情况有所不同. 面对复杂工况及多种故障模式的样本数据, 传统的诊断方法需要依靠专家经验根据具体工况进行判断, 泛化性能及实时性较差.

采集每种工况 120 次, 则每类齿轮箱状态的样本数为 480 (每类齿轮箱状态有 4 种工况). 因此, 共

得到齿轮箱状态样本数据矩阵为  $2880 \times 12288$ , 其中 2880 为样本数, 12288 为样本维数. 随机选取 25% 的样本作为训练样本, 即:  $720 \times 12288$ , 构建深层 RBM 智能诊断模型, 随机选取训练样本数的 50%、75%、100%、125%、150%、175%、200% 作为测试样本 (测试样本与训练样本不重叠), 计算样本的识别正确率及聚类效果评价指标  $Jc^{[17]}$ , 验证模型的识别及聚类效果.

预先对样本状态信号计算时域 (均方值、峭度、均值、方差、偏斜度、峰值、均方根幅值、波性指

标、峰值指标、脉冲指标、裕度指标)、频域(四档齿轮啮合频率、五档齿轮啮合频率、轴承外圈故障频率、内圈故障频率、滚动体故障频率、保持架故障频率)等共 18 个指标,即得到  $2280 \times 18$  的样本矩阵,其中 2280 为样本数,18 为样本维数.同理,随机选取 25% 的样本作为训练样本,构建 PCA、LPP 及 NPE 诊断模型,随机选取训练样本数的 50%、75%、100%、125%、150%、175%、200% 作为测试样本(测试样本与训练样本不重叠),计算样本的识别正确率及聚类效果评价指标  $J_c$ ,对比这些算法对该数据集的识别效果.设定低维维数为样本的类别数,即维数为 6,所得识别及聚类指标  $J_c$  值为 15 次随机的平均值,具体为:深层 RBM 智能诊断模型、浅层 RBM、PCA、LPP 及 NPE 与实际齿轮箱振动信号结合的流程如图 7 所示.

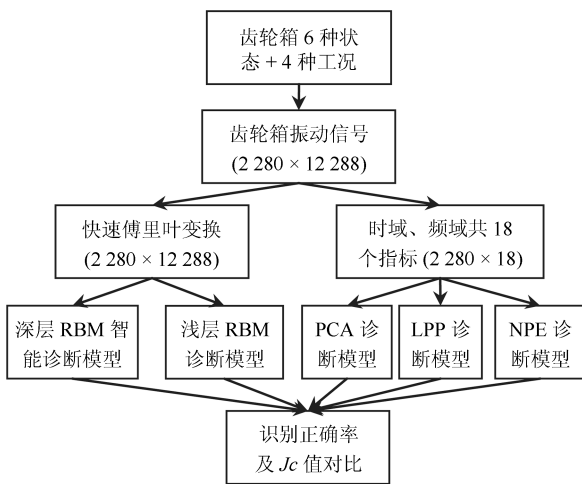


图 7 齿轮箱振动信号与各诊断模型结合的流程

Fig. 7 Combined the gearbox vibration signals with the diagnosis model

### 2.1 识别正确率及聚类评价曲线图

图 8 为 7 种算法的识别正确率曲线及聚类评价指标  $J_c$  值,对比识别正确率曲线图可见,在 7 种测试样本数下,自适应调整 RBM 和自适应调整 RBM + Denoising 的识别正确率最高,两者均大于 93%,表明采用自适应调整 RBM 方法能得到更好的识别正确性,且具有较好的稳定性,而且,采用降噪技术可以有效地消除噪声的干扰,进一步提高识别效果,此时的识别正确率均大于 95% (除测试样本比例为 50% 外,此时为 94.24%),为 6 种算法中最大.尽管 PCA、LPP 和 NPE 算法的识别正确率趋近于 90%,然而,这 3 种算法均需要预先计算数据特征,算法的泛化性能较差,浅层 RBM 算法由于结构的浅层性质,且没有人为预先提取特征,因此,识别正确率最低.

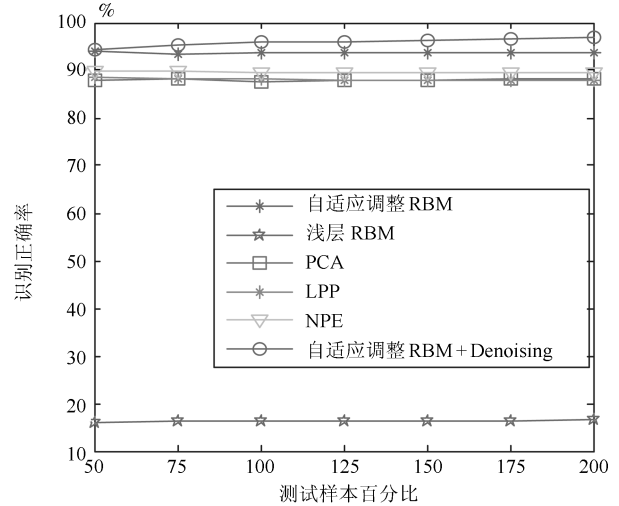


图 8 对比算法的识别正确率及聚类评价指标

Fig. 8 The recognition accuracy and  $J_c$  index




图 8

Fig. 8

对比相应的聚类评价指标  $J_c$  值可见,自适应调整 RBM、及自适应调整 RBM + Denoising 方法得到的聚类评价在 6 种测试样本数下均在 0.70 以上,明显大于浅层 RBM、PCA、LPP 和 NPE 方法,说明即使不采取预先计算样本指标的方式,利用自适应调整 RBM 及自适应调整 RBM + Denoising 算法的特征提取方式也可以得到好的聚类效果.在 7 种测试样本数下,自适应调整 RBM + Denoising 的  $J_c$  值均在 0.75 以上,为所有算法中最大,且随着测试样本数的增加,  $J_c$  值单调上升,表明经过该方法能够得到较好的聚类效果,浅层 RBM 由于结构的局限性,其聚类效果最差.综合比较识别正确率及聚类评价指标可见,自适应调整 RBM 且增加降噪功能诊断模型的特征提取效果最优,自适应调整 RBM 次之.

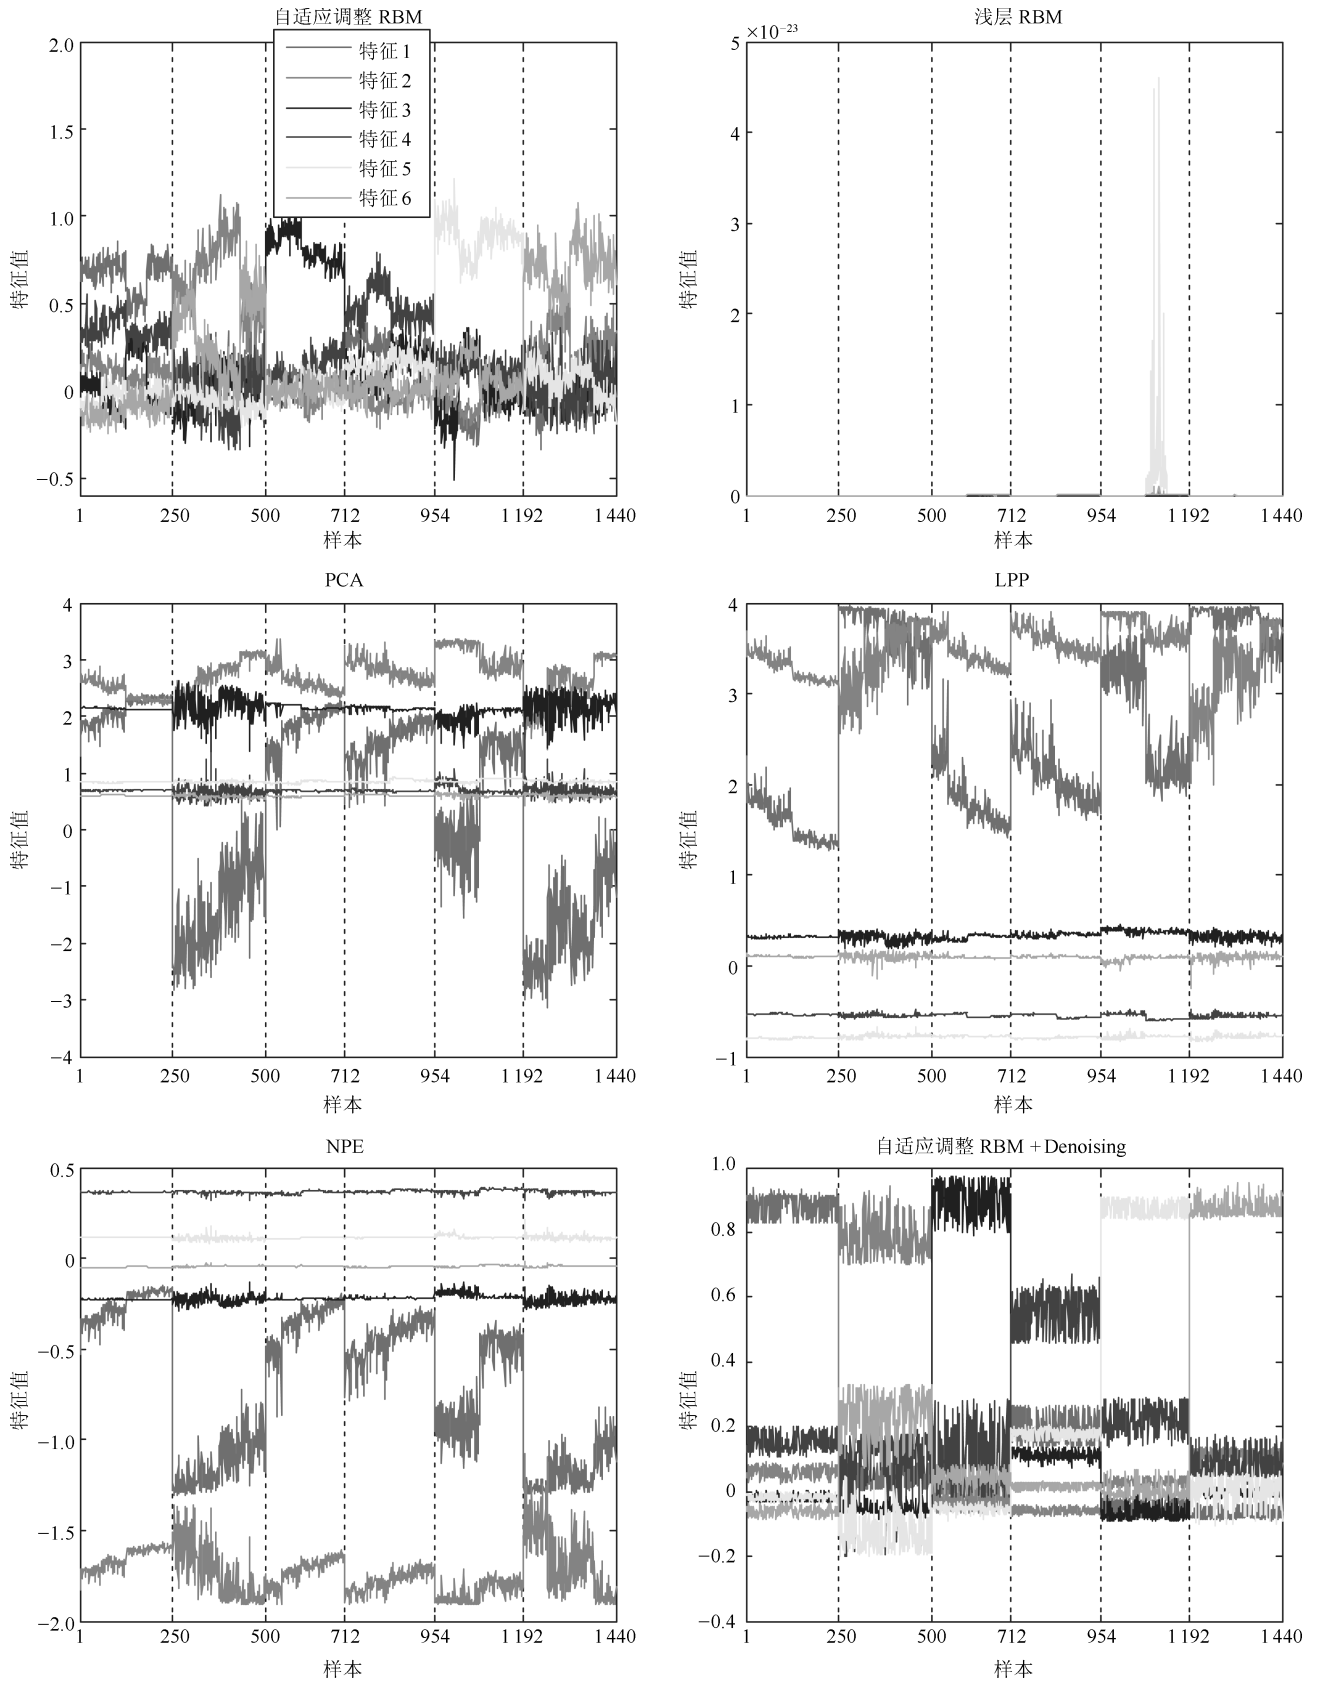


图9 6种算法提取的特征曲线图

Fig.9 The plots of extract features by six diagnosis models

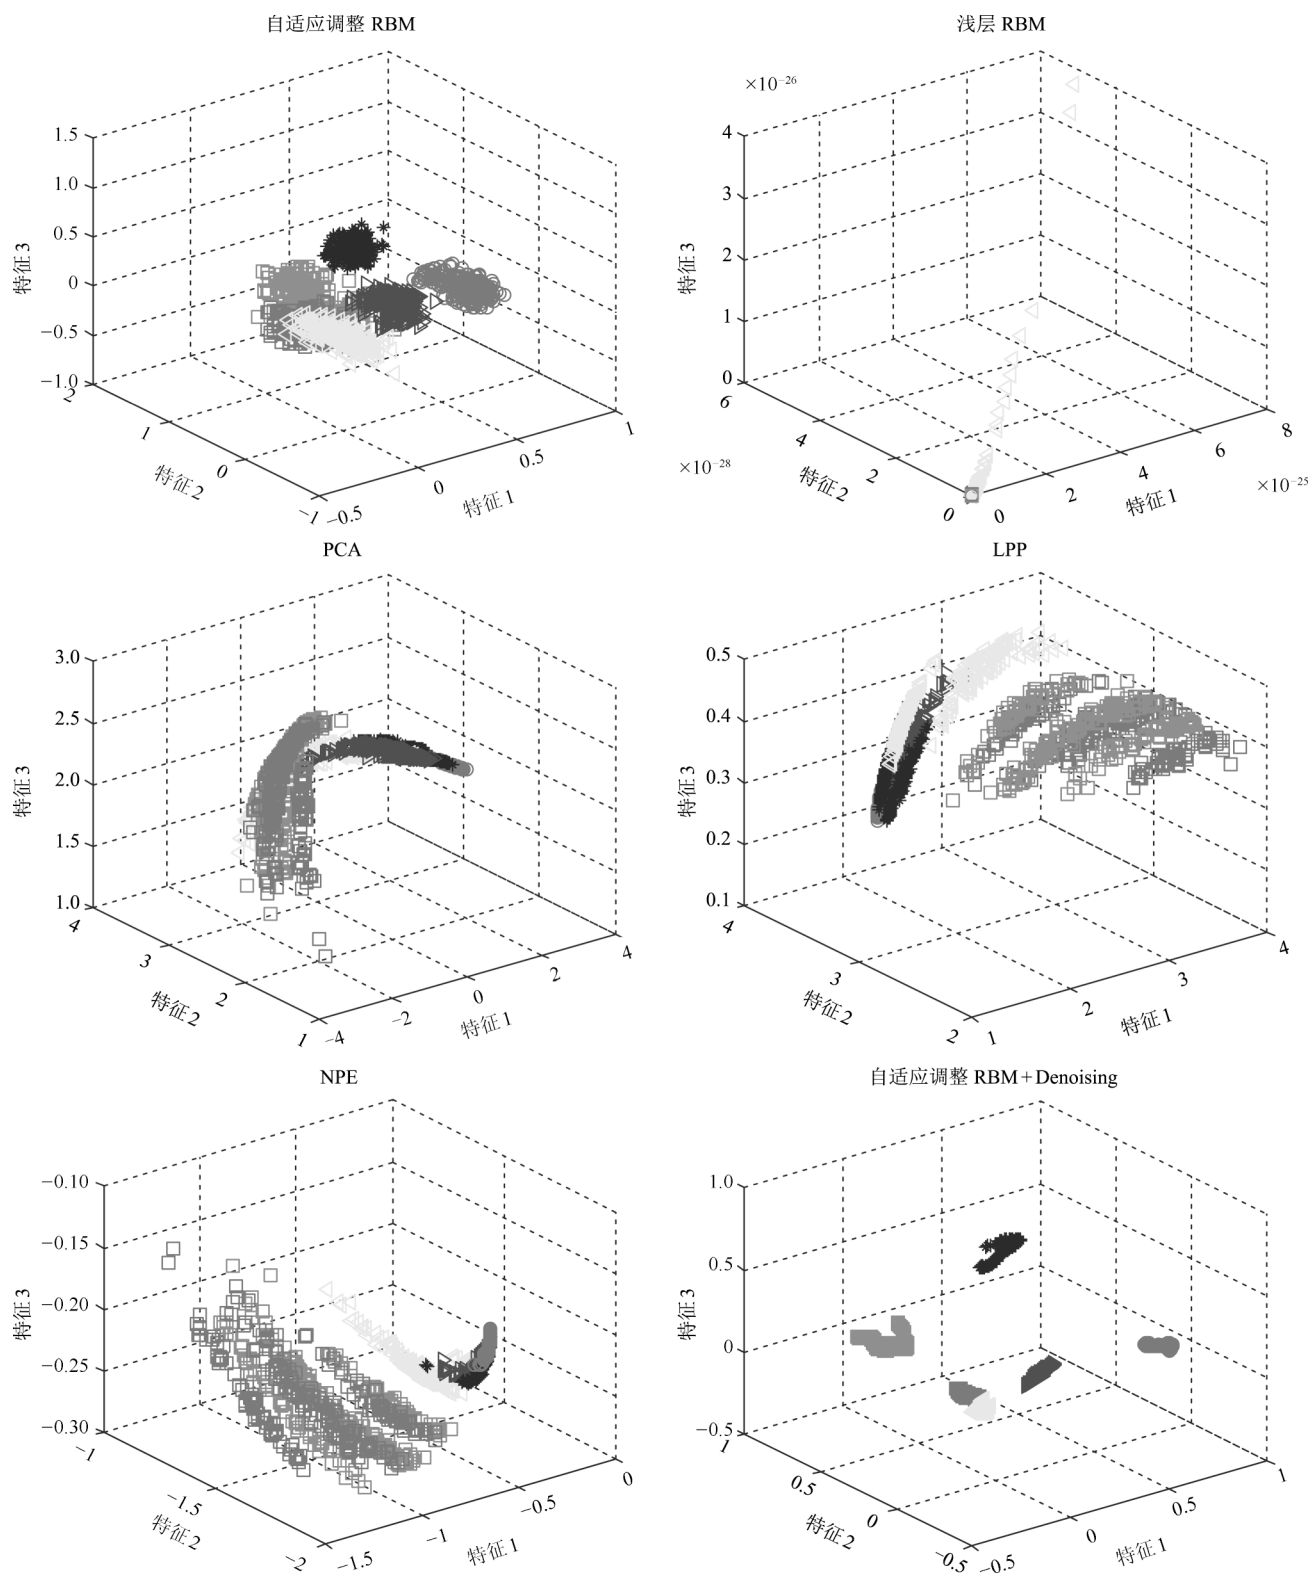


图 10 6 种算法提取特征的散点图  
Fig. 10 The scatter plots of extract features

## 2.2 特征曲线及聚类效果图

取测试样本数为 200% 时的低维特征作曲线图及三维聚类图, 如图 9 及图 10 所示. 对比特征曲线图可见, 由于 PCA、LPP 和 NPE 本身为浅层结构模型, 无法有效地提取复杂输入及复杂分类问题, 其得到的特征曲线存在异类样本之间明显混叠, 如从最主要的特征 1 曲线可见, 不同样本之间的特征值相近, 导致样本叠加在一起, 无法有效地分离, 且从 6 个特征曲线可以看出, 能够用于样本聚类的仅有特征曲线 1 和 2. 浅层 RBM 由于没有预先计算样本的特征指标且为浅层结构, 导致特征曲线出现混叠, 无法区分不同类别样本. 对比自适应调整 RBM 和集成自适应调整与降噪 RBM 模型可见, 这两种算法提取的特征能够明显地分离异类样本, 且提取的 6 个特征在样本聚类方面均能起到作用, 然而, 对比同类样本的聚集程度可见, 自适应调整 RBM 得到的同类样本的集合程度较差, 如主要特征曲线 1 可见, 同类样本内出现明显的 2 个或 3 个的小集合, 即同类样本内的再分类, 这是由于同类样本内存在不同运行工况的影响, 弱化同类样本的集合度. 集成自适应调整与降噪 RBM 模型由于增加降噪过程, 消除噪声及运行工况的影响, 有效地提高同类样本的聚集性及异类样本的分离.

对比聚类效果图 10 可以看出, PCA、LPP 及 NPE 算法的聚类图中不仅出现同类样本由于工况的不同而明显地分离, 同时异类样本之间混叠严重, 浅层 RBM 的聚类效果最差. 自适应调整 RBM 算法得到的聚类图可见, 同类样本的聚集程度较好, 受工况干扰的影响较小, 异类样本之间分离, 但受到噪声的干扰, 同类样本的聚集程度较差, 增加隐含层特征降噪得到的聚类效果图 (自适应调整 RBM + Denoising 聚类图) 可见, 同类样本聚集, 而且异类样本之间分离明显, 在 6 种方法中聚类效果最好.

## 3 结论

通过构建各隐含层输出与样本标签信息之间的转换矩阵, 以控制识别正确率为目标, 逐层建立隐含层数及特征数确定的深层 RBM 智能诊断模型. 为消除噪声干扰并保证计算效率, 对隐含层特征空间进行降噪. 复杂工况的齿轮箱故障模拟实验证明, 相比于浅层 RBM、PCA、LPP 及 NPE 方法, 所提方法能够得到更高的识别正确率, 经过降噪之后的样本具有更好的聚类效果, 同类样本聚集, 异类样本明显分离, 算法的泛化能力更优.

展望: 直接将时域或者频域作为低层输入信息构建深度学习故障诊断模型, 可以有效地削弱人为

因素的干扰, 进一步提高人工智能在机械故障诊断的发展. 由于频域成分可以较好地地区分机械设备不同状态类型, 因此, 所提算法采用频域信号作为低层输入, 然而, 为了保证分析频率及频率分辨率, 频域信号的数据长度较大, 导致模型的计算效率降低, 因此, 后续工作将从此处入手, 研究进一步提高所提学习模型的诊断效率.

## References

- 1 Kung S Y, Diamantaras K I. A neural network learning algorithm for adaptive principal component extraction (APEX). In: Proceedings of the 1990 International Conference on Acoustics, Speech, and Signal Processing. Albuquerque, New Mexico, USA: IEEE, 1990. 861–864
- 2 Yu J B. A nonlinear probabilistic method and contribution analysis for machine condition monitoring. *Mechanical Systems and Signal Processing*, 2013, **37**(1–2): 293–314
- 3 Gui J, Sun Z N, Jia W, Hu R X, Lei Y K, Ji S W. Discriminant sparse neighborhood preserving embedding for face recognition. *Pattern Recognition*, 2012, **45**(8): 2884–2893
- 4 Hinton G E. Training products of experts by minimizing contrastive divergence. *Neural Computation*, 2002, **14**(8): 1771–1800
- 5 Zhou Feng-Yu, Yin Jian-Qin, Yang Yang, Zhang Hai-Ting, Yuan Xian-Feng. Online recognition of human actions based on temporal deep belief neural network. *Acta Automatica Sinica*, 2016, **42**(7): 1030–1039  
(周凤余, 尹建芹, 杨阳, 张海婷, 袁宪锋. 基于时序深度置信网络的在线人体动作识别. *自动化学报*, 2016, **42**(7): 1030–1039)
- 6 Li F, Tran L, Thung K H, Ji S William, Shen D G, Li J. Robust deep learning for improved classification of AD/MCI patients. In: Proceedings of the 5th International Workshop on Machine Learning in Medical Imaging, Lecture Notes in Computer Science. Boston, MA, USA: Springer International Publishing, 2014, **8679**: 240–247
- 7 Tang Chao-Hui, Zhu Qing-Xin, Hong Chao-Qun, Zhu William. Multi-label feature selection with autoencoders and hypergraph learning. *Acta Automatica Sinica*, 2016, **42**(7): 1014–1021  
(唐朝辉, 朱清新, 洪朝群, 祝峰. 基于自编码器及超图学习的多标签特征提取. *自动化学报*, 2016, **42**(7): 1014–1021)
- 8 Tamilselvan P, Wang P F. Failure diagnosis using deep belief learning based health state classification. *Reliability Engineering and System Safety*, 2013, **115**: 124–135
- 9 Fu Y, Zhang Y, Qiao H Y, Li D Q, Zhou H M, Leopold J. Analysis of feature extracting ability for cutting state monitoring using deep belief networks. In: Proceedings of the 15th Conference on Modelling of Machining Operations. Karlsruhe, Germany: Elsevier, 2015. 29–34
- 10 Tran V T, Athobiani F, Ball A. An approach to fault diagnosis of reciprocating compressor valves using Teager-Kaiser energy operator and deep belief networks. *Expert Systems with Applications*, 2014, **41**(9): 4113–4122

- 11 Gan M, Wang C, Zhu C A. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings. *Mechanical Systems and Signal Processing*, 2016, **72–73**: 92–104
- 12 Wang Xian-Bao, Li Jie, Yao Ming-Hai, He Wen-Xiu, Qian Yun-Tao. Solar cells surface defects detection based on deep learning. *Pattern Recognition and Artificial Intelligence*, 2014, **27**(6): 517–523  
(王宪保, 李洁, 姚明海, 何文秀, 钱运涛. 基于深度学习的太阳能电池片表面缺陷检测方法. 模式识别与人工智能, 2014, **27**(6): 517–523)
- 13 Huang Hai-Bo, Li Ren-Xian, Yang Qi, Ding Wei-Ping, Yang Ming-Liang. Identifying abnormal noise of vehicle suspension shock absorber based on deep belief networks. *Journal of Southwest Jiaotong University*, 2015, **50**(5): 776–782  
(黄海波, 李人宪, 杨琪, 丁渭平, 杨明亮. 基于 DBNs 的车辆悬架减振器异响鉴别方法. 西南交通大学学报, 2015, **50**(5): 776–782)
- 14 Li C, Sanchez R V, Zurita G, Cerrada M, Cabrera D, Vásquez R E. Gearbox fault diagnosis based on deep random forest fusion of acoustic and vibratory signals. *Mechanical Systems and Signal Processing*, 2016, **76–77**: 283–293
- 15 Xie Ji-Peng. Research on Fault Diagnosis of High Speed Running Gear based on Deep Learning under Cloud Platform [Master dissertation], Southwest Jiaotong University, China, 2015  
(谢吉朋. 云平台下基于深度学习的高速列车走行部故障诊断技术研究 [硕士学位论文], 西南交通大学, 中国, 2015)
- 16 Hinton G E. A practical guide to training restricted Boltzmann machines. *Neural Networks: Tricks of the Trade* (Second edition). Berlin Heidelberg: Springer, 2012. 599–619
- 17 Zhang Shao-Hui, Li Wei-Hua. Variable nearest neighbor locally linear embedding and applications in bearing condition recognition. *Journal of Mechanical Engineering*, 2013, **49**(1): 81–87  
(张绍辉, 李巍华. 可变近邻参数的局部线性嵌入算法及其在轴承状态识别中的应用. 机械工程学报, 2013, **49**(1): 81–87)



张绍辉 厦门理工学院机械与汽车工程学院讲师. 2014 年获得华南理工大学博士学位. 主要研究方向为信号处理与机器学习.

E-mail: zhangshaohui@xmut.edu.cn

(ZHANG Shao-Hui Lecturer at the School of Mechanical and Automotive Engineering, Xiamen University of

Technology. He received his Ph.D. degree from South China University of Technology in 2014. His research interest covers dynamic signal processing and machine learning.)