DOI: 10.3901/JME.2020.01.069

基于拉普拉斯特征映射和深度置信网络的 半监督故障识别*

张 鑫^{1,2} 郭顺生^{1,2} 李益兵^{1,2} 江 丽^{1,2}

(1. 武汉理工大学机电工程学院 武汉 430070;

2. 武汉理工大学湖北省数字制造重点实验室 武汉 430070)

摘要: 针对机械设备故障诊断过程中有标签样本不足, 结合流形学习与深度学习的思想, 提出了基于拉普拉斯特征映射(Laplacian eigenmap, LE)和深度置信网络(Deep belief network, DBN)的半监督故障识别模型。该模型运用 LE 算法直接对原始高维振动信号进行特征提取, 将低维流形特征输入 DBN, 利用少量昂贵的有标签样本和大量廉价的无标签样本, 二次挖掘故障特征, 并构建 Soft-max 分类器最终识别出机械设备的故障模式。将该半监督模型应用于轴承故障和齿轮裂纹的识别中, 试验结果表明, LE 算法有效降低了模型的时间复杂度, 增强了特征提取的智能性, 提高了诊断效率; DBN 网络可以充分挖掘故障特性, 得到更好的特征表示, 提高了分类精度。此外, 该模型在不平衡的训练标签下也实现了很好的诊断效果, 且适用于多传感器特征融合的诊断, 具备实际应用的价值。

关键词: 拉普拉斯特征映射; 深度置信网络; 半监督; 故障诊断

中图分类号: TH133

Semi-supervised Fault Identification Based on Laplacian Eigenmap and Deep Belief Networks

ZHANG Xin^{1,2} GUO Shunsheng^{1,2} LI Yibing^{1,2} JIANG Li^{1,2}

(1. School of Mechanical and Electronic Engineering, Wuhan University of Technology, Wuhan 430070;

2. Hubei Digital Manufacturing Key Laboratory, Wuhan University of Technology, Wuhan 430070)

Abstract: Aiming at solving the problem of insufficient labeled samples in mechanical equipment fault diagnosis, a semi-supervised fault recognition model based on Laplace Eigenmap (LE) and Deep Belief Network (DBN) is presented by combining the idea of manifold learning and deep learning. The model utilizes LE algorithm to directly extract the features from the raw high-dimensional vibration signal, and inputs the low-dimensional manifold features into DBN. By using a few expensive labeled samples and lots of cheap unlabeled samples, it excavates fault features for a second time, and finally constructs the Soft-max classification to identify the fault mode of the mechanical equipment. The semi-supervised model is applied to the identification of bearing faults and gear cracks. The test results show that LE algorithm can effectively reduce the time complexity of the model, enhance the intelligence of feature extraction and improve the diagnostic efficiency. DBN network can fully mine fault characteristics, get better feature representation, and improve diagnostic accuracy. In addition, the model also achieves a good diagnosis effect with unbalanced training label, and is applicable to the diagnosis of multi-sensor feature fusion, which has practical application value.

Key words: Laplacian eigenmap; deep belief networks; semi-supervise; fault diagnosis

0 前言

生产安全与设备健康密切相关, 若能高效精准

地诊断出机械设备的运行状态, 对于保证生产系统的安全运行、提高产品质量将大有裨益。目前, 机械设备的故障诊断技术主要集中在信号分析和智能诊断两方面。而实际工况下的振动信号多呈现非平稳、非线性的特点, 故障特征常常被设备的工作频率、噪声等淹没, 传统的信号处理与分析技术很难取得较好的诊断结果^[1-2]。

在智能诊断方面, 应用相关机器学习的算法取

* 湖北省自然科学基金(2019CFB565)、中央高校基本科研业务费专项资金(2018IVA022)、国家自然科学基金(51705386, 51705385)和湖北省科技支撑计划(2015BAA063、2014BAA032)资助项目。20190210 收到初稿, 20190717 收到修改稿

得了不错的效果,主要有:支持向量机^[3](Support vector machines, SVM)、人工神经网络^[4](Artificial neural network, ANN)、核方法^[5](Kernel method)等模式识别的方法。这些算法在模型的训练过程中,通过已知的故障标签拟合模型参数,可以明显提高模型的诊断精度。然而少量的故障标签无法满足有监督训练的需要,获得大量的标签样本又不切实际。半监督学习则在少量标签样本的基础上,配合大量廉价的无标签样本完成模型训练,既避免了无监督学习精度不足的问题,又克服了标签样本匮乏的难题。如文献[6]采用半监督核边界 Fisher 判定算法,配合 K 最近邻(K-nearest neighbor, KNN)算法实现了对滚动轴承的诊断。文献[7]提出了半监督的线性判别分析(Linear discriminant analysis, LDA),利用有限的监督信息,对比传统的 LDA 取得了更好的识别效果。这些研究证明了半监督学习具有实际应用的价值。

传统的智能诊断算法多是在一到两层的模型结构中完成函数的拟合,均属于“浅层学习”的算法结构,没有充分挖掘数据内部蕴含的故障特性。深度学习^[8-9]是近年来兴起的一种“深层”的新型算法,在图像、语音识别等领域已经取得了辉煌的成果,在故障诊断领域的研究也呈上升趋势^[10-12]。深度信念网络(Deep belief network, DBN)是一种典型的深度学习网络,通过组合低层特征形成更加抽象的高层表示,以发现数据分布式特征表示,是一种可以深度挖掘数据特征信息的网络结构^[14]。然而 DBN 网络在应对高维度样本时,高维输入层与多隐层网络结构的训练将耗费大量的算力与时间。如文献[15]采用五层网络结构对滚动轴承的时域信号展开故障诊断,虽取得了较高的识别准确率,但模型训练缓慢。文献[16]采用双树复小波进行特征提取后再通过 DBN 网络进行分类,降低了模型的计算复杂度,但依旧没有摆脱传统信号处理技术对专家经验的依赖,且未充分利用 DBN 挖掘故障特性的能力。与传统的信号处理技术不同,拉普拉斯特征映射^[17](Laplacian eigenmap, LE)算法是一种经典的流形学习^[18-20]算法,能充分挖掘非线性高维数据的本质结构,并直接从原始振动信号构建的高维流形中找到有效的低维表征。

本文运用 LE 算法直接从原始高维振动信号中提取低维流形特征,降低了模型的计算复杂度,避免了人为选取特征的不确定性。采用半监督的方式,仅利用少量有标签样本和大量无标签样本完成 DBN 网络训练,将流形学习的结果输入 DBN 中进行特征的二次挖掘与故障分类。将该模型应用于轴

承故障和齿轮裂纹的诊断中,验证了该模型的有效性和优越性。

1 基于 LE 算法的特征提取

1.1 问题描述

给定高维空间 R^D 上的一组训练样本和一组测试样本,构成数据集 $X = \{x_1, x_2, \dots, x_m, \dots, x_{m+n}\}$, $x_i \in R^D$, 其中 m 为训练样本总数, n 为测试样本总数, $m+n$ 即为总样本数, D 为高维样本的维数。假设其在低维空间 R^d 上的低维嵌入为 $Y = \{y_1, y_2, \dots, y_m, \dots, y_{m+n}\}$, $y_i \in R^d$, d 为低维样本的维数且 $d \ll D$ 。

1.2 特征提取

LE 算法主要目的是挖掘潜藏在原始高维流形中的低维流形特征。其实质就是要获得一个平均意义上的数据点局部近邻信息。它的基本思想是,在高维空间上相距很近的点,在低维空间上的投影也应该距离很近。LE 算法所产生的映射可以看作是对几何流形的一种连续离散逼近的映射,通过构建数据点之间的邻域图来近似表示流形,并用 Laplace-Beltrami 算子近似标识邻域图的权值矩阵,实现高维流形的最优低维嵌入。其算法的流程如下。

(1) 构造近邻图 G 。计算高维空间上所有数据点对之间的欧式距离,根据 K 近邻法,确定每个样本点的 K 个近邻点。如果高维空间上的两点是近邻点,那么认为这两点之间有边连接,否则两点之间是断开的。

(2) 构造样本点间的权值矩阵。若两点连通,则 $W_{ij} = 1$, 否则 $W_{ij} = 0$ 。邻接权值定义如下

$$W_{ij} = \begin{cases} 1 & x_i \text{ 是 } x_j \text{ 的近邻点} \\ 0 & x_i \text{ 不是 } x_j \text{ 的近邻点} \end{cases} \quad (1)$$

(3) 计算低维嵌入

$$\min \sum_{i,j=1}^{m+n} W_{ij} \|y_i - y_j\| = 2Y(D-W)Y^T = 2YLY^T \quad (2)$$

其中, $D = [D_{ii}]_{N \times N} = \left[\sum_{i \neq j} W_{ij} \right]_{N \times N}$ 称为近邻图 G

的度矩阵(一个对角矩阵,对角线上的值代表该点的连接数), W 为图 G 的邻接矩阵(一个稀疏矩阵,样本点 x_i 、 x_j 间若有边相连则 $W_{ij} = 1$, 反之 $W_{ij} = 0$), L 为近邻图 G 的拉普拉斯矩阵, $L = D - W$; 上式可以转换成如下广义特征值分解问题,求得 $L\varepsilon = \lambda D\varepsilon$ 的最小特征值所对应的特征向量。高维数据集 X (维

数为 D) 的低维(维数为 d) 嵌入由 $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_d$ 组成, 即为 LE 算法特征提取的结果。

2 基于 LE 和 DBN 的故障诊断模型

2.1 DBN 网络基础理论

深度信念网络(DBN)是一种深度学习网络, 它由多个限制玻尔兹曼机^[21](Restricted Boltzmann machines, RBM)堆叠而成。图 1 为三个 RBM 堆叠而成的 DBN 网络, 每个 RBM 间通过权值 w 连接。每层 RBM 网络相互独立, 上一层 RBM 的输出即为下一层的输入, 将特征映射并逐层传递。各层 RBM 只需确保自身层内的权值对该层特征向量映射达到最优, 最终在高层形成比低层更抽象和更具有表征能力的特征表示。最后在高层采用 BP 反向传播算法将误差自顶向下的传播至每一个 RBM 内, 进行有监督的全局微调。

图 1 DBN 网络结构

DBN 网络的训练核心是通过逐层贪婪算法来进行网络参数值的优化, 采用层间预训练和反向微调两种训练方式充分挖掘原始数据的分布式特征。预训练采用无监督训练方式, 可利用大量廉价的无标签样本实现层间最小化重构误差, 充分挖掘输入信号中潜藏的故障特征。其关键的特征提取能力就在于逐层的无监督学习, 可以将数据由输入映射到输出, 构建一些高度复杂的非线性函数。反向微调充分利用少量有标签样本有监督的实现 DBN 网络的精准分类。本文 DBN 的训练采用无监督学习和监督学习相结合的方式, 使用大量无标签数据和少量标签数据进行训练, 是典型的半监督学习方式。

(1) 预训练

RBM 是一种基于能量的模型, 模型认定能量最

小化时则达到理想状态, 而网络训练的目的就是要最小化这个能量函数。其神经元分为显层和隐层, 显层用于表示数据的输入与输出, 隐层则被理解为数据的内在表达。同一层神经元之间相互独立, 且只有未激活与激活两种状态, 可分别用二进制 0 与 1 表示。RBM 的可见层需要对输入数据进行二值化处理, 基本思路为先将输入数据归一化至(0,1)区间内, 再与随机数进行大小比较, 将输入数据转换为 0-1 二值。

图 2 RBM 模型

假设一个 RBM 中存在 n 个可见层单元和 m 个隐藏层单元, $v = (v_1, v_2, \dots, v_n)$ 、 $h = (h_1, h_2, \dots, h_m)$ 分别代表可见层和隐含层的神经元状态分布, $\theta = \{a, b, w\}$ 为模型的参数集, 则定义 RBM 的能量函数^[22]如下

$$E(v, h) = -\sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m w_{ij} v_i h_j \quad (3)$$

其中, a_i 、 b_j 分别为显层和隐层的神经元偏置, w_{ij} 为显隐层神经元之间的连接权值。用上述能量函数定义显层节点和隐层节点的联合概率分布如下式, 其中 $Z(\theta)$ 为配分函数, 用来实现归一化操作。

$$P(v, h | \theta) = \frac{1}{Z(\theta)} e^{-E(v, h | \theta)} \quad (4)$$

$$Z(\theta) = \sum_{v, h} e^{-E(v, h | \theta)} \quad (5)$$

可见层能量分布可以通过累加所有隐含层而得到

$$P(v | \theta) = \sum_h P(v, h | \theta) = \frac{1}{Z(\theta)} \sum_h e^{-E(v, h | \theta)} \quad (6)$$

由于同一层之间没有联系, 所有的可见层节点之间相互独立, 故 $v_i = 1$ 的概率为

$$P(v_i = 1 | h) = \text{Sigmoid}(a_i + \sum_{j=1}^m h_j w_{ij}) \quad (7)$$

$$\text{Sigmoid}(x) = 1 / (1 + e^{-x}) \quad (8)$$

其中 Sigmoid(x) 为常见的激活函数, 同理可得

$$P(h_j = 1 | v) = \text{Sigmoid}(b_j + \sum_{i=1}^n v_i w_{ij}) \quad (9)$$

RBM 训练的目的就是要得到模型参数集 θ 的最优解, 来拟合训练数据, 使节点样本统计概率与模型生成概率尽量相等。通过求解训练集上的极大对数似然函数可以得到 θ , 即

$$\theta^* = \operatorname{argmax} \sum_{t=1}^T \ln p(v^t) \quad (10)$$

其中, T 为训练样本的个数。RBM 的训练多采用对比散度(Contrastive divergence, CD)算法^[23], 通过 1 次 Gibbs 采样来得到 RBM 分布的近似值, 其参数集 θ 的更新规则如下, 其中 σ 为学习率, λ 为动量。

$$w_n \leftarrow \lambda w_{n-1} + \sigma(<v_i h_j>_{data} - <v_i h_j>_{recon}) \quad (11)$$

$$a_n \leftarrow \lambda a_{n-1} + \sigma(<v_i>_{data} - <v_i>_{recon}) \quad (12)$$

$$b_n \leftarrow \lambda b_{n-1} + \sigma(<h_j>_{data} - <h_j>_{recon}) \quad (13)$$

其中, σ 为学习率, $<\bullet>_{data}$ 和 $<\bullet>_{recon}$ 分别为当前模型的分布与重构模型的分布期望。

(2) 全局微调。

预训练是一种无监督的学习, 而全局微调则是一种有监督学习方式。将预训练得到的模型参数来初始化有监督学习, 这相当于为有监督学习输入了数据的先验知识。全局微调从 DBN 网络的最后一层出发, 利用少许标签样本逐层向低层微调模型参数, 对模型的拟合效果进一步优化。在网络的最后级联 Soft-max 模型作为分类器, 选择 BP 算法对参数进行微调。假设 DBN 网络共 l 个 RBM, 在可见层 V1 输入的样本长度为 d , 则网络最高隐层的输出为

$$u^l(x) = \operatorname{Sigmoid}(a^l + w^l u^{l-1}(x)) \quad (14)$$

Soft-max 分类层对 DBN 网络的输出进行判定, 最大概率所对应的类别即为模型的预测类别。由式(14)可知连接权值 w 是影响网络输出的重要参数, 通过 BP 算法对参数 w 进行优化, 使得 DBN 网络的输出更接近于真实的分类结果。

BP 算法包括前向传播和反向传播两个过程, 前向传播过程中, 输入被逐层映射到输出, 在最终的分层中得到各类别的概率 $u^l = (u_1^l, u_2^l, \dots, u_k^l)$ 。反向传播过程依据已知的类别标签 $y^l = (y_1^l, y_2^l, \dots, y_k^l)$, 同预测的类别比较后得到均方误差 E_{MS} 。误差从最后一层进行反向传播, 并利用梯度下降算法逐层微调 DBN 的权值参数。

$$E_{MS} = \frac{1}{2} \sum_{j=1}^k (u_j^l - y_j^l)^2 \quad (15)$$

$$\Delta w_{ij} = -\sigma \frac{\partial E_l}{\partial w_{ij}} \quad (16)$$

$$w_{ij} \leftarrow w_{ij} + \Delta w_{ij} \quad (17)$$

同理可对参数集 θ 中的其他参数进行调整, 得到最终的 DBN 网络模型, 该模型在特征挖掘和样本分类方面有着良好的表现。

2.2 故障识别模型

本文提出了一种基于 LE 算法和 DBN 网络的故障诊断模型, 如图 3 所示。其基本思路如下: 基于流形学习的思想, 采用 LE 算法对原始信号进行特征提取, 实现高维空间的维数约简。而后, 充分发挥 DBN 网络特征挖掘的能力, 将经过提取后的低维流形特征输入 DBN 网络中进行深度学习, 得到分类结果。该模型一方面充分发挥了 DBN 网络在特征挖掘方面的优势, 另一方面又大大降低了计算成本, 摆脱了传统信号处理技术对专家经验的依赖。同单一的 DBN 网络相比, 本文提出的组合算法充分吸收了流形学习降维灵活的优点, 对 DBN 网络的可见层输入贡献了更高的自由度, 避免了“维数灾难”的难题。算法诊断流程如下。

(1) 构建原始高维模式空间。

通过传感器对故障设备进行数据采集, 采用 min-max 标准化法对时域振动信号进行归一化处理, 从而得到一个原始振动时间序列构建的高维模式空间。

(2) LE 算法特征提取。

通过 LE 算法对高维故障数据进行流形学习, 提取表征故障本质的低维流形特征, 实现维度约减。

(3) DBN 网络故障诊断。

将流形学习的结果进行二值化处理, 再输入到 DBN 网络中进行深度挖掘, 通过网络输出层的 Soft-max 分类器得到故障诊断的结果。

图 3 基于 LE 和 DBN 的故障识别模型

3 轴承故障试验验证

在第 3.1 和 3.2 节中, 作为算法验证的试验数据来自于美国 Case Western Reserve University 电气工

程实验室的滚动轴承故障数据^[24], 滚动轴承实验台由一个 1 491.4 W 的三相电动机、1 个扭矩传感器和 1 个加载电机组成。试验轴承(型号为 6205-2RS JEM SKF)安装于电动机的驱动端, 加速度传感器粘贴于驱动端正上方的机壳。采用的试验数据均在以下工作参数下测得: 电动机负载功率区间 0~3 hp, 对应转速分别为 1 797 r/min、1 772 r/min、1 750 r/min 以及 1 730 r/min。数据记录仪(16 通道)采样频率为 12 kHz。依托于上述试验条件, 验证算法模型对不同负载条件下的故障识别效果, 进行以下两组试验: 第一组试验在同一故障尺寸下, 验证本文算法对故障类别的识别效果; 第二组试验在同种故障类型下, 验证不同受损程度的分类效果。本文所有试验均在 MATLAB R2014a 下进行, 处理器为 INTEL CORE I7 8550U, 16G RAM。

3.1 轴承故障类型诊断试验

轴承的早期故障信号一般都比较微弱, 故障特征很难提取, 滚动轴承早期故障的发现和诊断对保障整台机器的可靠运行和延长整台机器的使用寿命至关重要。选择滚动轴承在三种载荷条件(0 hp、1 hp、2 hp)下的三种故障(IR₁₋₃-内圈故障、B₁₋₃-球体故障、OR₁₋₃-外圈故障), 结合健康状态(N-正常)样本, 组成 10 类样本, 验证本文算法对轴承故障类型的分类性能。而在机械装备实际的运维情景下, 历史数据中含有大量廉价的无标签样本和少量的有标签样本^[25]。鉴于此, 对每种故障类型分别构建 100 组样本, 每组样本含有 1 024 个采样点, 其中 10 组有标签样本和 60 组无标签样本组成训练集, 另外 30 组作为测试集, 以此模拟真实的故障诊断背景。训练集中的数据全部参与对每层 RBM 的重构训练, 而在微调过程中, 仅需有标签数据参与。

设想通过流形学习算法约减 95% 的维度, 故确认 LE 算法的低维嵌入维数为 $d = 50$, 输入层神经元个数为 50。隐藏层神经元个数与输入层保持一致, 输出层神经元区分 10 类故障, DBN 网络隐含层节点数为 50-50-50。预训练和反向微调中 learning rate $\sigma = 0.1$, 动量参数为 0.9。初步设置迭代次数为 200, 每组试验进行 10 次, 对测试结果求平均值。

对算法模型进行训练, 图 4 为均方误差 E_{MS} 随迭代次数增长的变化趋势。可以看出, 模型在训练前期以很快的速度削减误差, 而后寻优陷入了停滞。随着迭代次数的增加, 模型参数的不断优化, 均方误差进一步降低。到 140 代时, 就达到了较小的训练误差, 在 150 代时误差趋于收敛, 误差值小于

0.01。这说明算法模型在训练集上取得了很好的拟合效果, 选择合适的迭代次数使模型达到收敛, 有助于提高模型的训练速度。

图4 均方误差随迭代次数变化趋势

模型训练完成后, 在测试集上进行效果验证。采用主成分分析(Principal component analysis, PCA)方法提取原始时域信号的三个主成分进行可视化, 图5为样本集原始特征可视化图。图中 10 类样本数据在三维空间上堆叠环绕, 难以进行区分, 也说明 PCA 算法难以直接从原始振动信号中提取典型的故障特征。

图5 样本集原始特征可视化

图6为 LE-DBN 模型中 DBN 各层输出特征的可视化效果。可以看出, 经过对输入特征的逐层挖掘, 故障样本的聚类效果也越来越好。例如图 6a 中 IR₂ 和 OR₂ 两类样本还存在重叠现象, 而在图 6b 中已经完全分离开来。图 6c 中第三隐层的输出特征已经达到了故障诊断的精度要求, 再经级联的 soft-max 分类器进行故障分类。在图 6d 的分类层可视化中, 同类故障几乎聚集在一点, 不同故障也明显分离开来, 证明 LE-DBN 模型对故障类型有很好的识别效果。

图6 DBN输出特征可视化

分别与 KPCA+KNN、LE+KNN、DBN 三种模型进行对比。其中, 根据文献[26], LE 算法的低维嵌入维度为 $d=C-1$ (C 为类别数目), 故确定 $d=9$ 。KNN 算法的近邻点数设置为 8, 核主成分分析(Kernel PCA, KPCA)算法的最佳核宽度为 10。参考文献[27], 设置 DBN 网络的隐藏层分别为 1024-1 024-1 024, 输出层神经元个数为 10, 其他参数同本文算法。四种算法的准确度见表 1, 可以看出本文提出的 LE-DBN 算法模型明显优于其他三种。

算法的时间消耗也是考查算法性能优劣的重要指标之一, 因而在同一处理器下进行各阶段的耗时测试, 设置 DBN 的迭代次数为 100。表 1 中包含了四种模型各阶段耗时的对比。可以看出, 单 DBN 网络的计算时间(85.28 s)是本文提出的 LE-DBN 组合模型(1.49 s)的 57 倍左右, 这表明 LE 算法能有效降低 LE-DBN 组合模型的时间复杂度。另外, 对故障检测效率要求比较高的在线监测设备来说, 单 DBN 网络算法可能会影响在线监测系统的实时性, 因而具有一定的局限性。综上所述, 相对于其他三种故障诊

断算法, 本文提出的 LE-DBN 组合模型算法, 在保证高准确率的同时, 又大大节约了时间成本。

表1 试验1方法对比

算法对比	KPCA	LE	DBN	LE-DBN
降维	0.13	0.38	—	0.62
预训练	—	—	5.41	0.080
耗时/s	—	—	79.51	0.75
测试	0.017	0.016	0.36	0.044
总耗时	0.147	0.379	85.28	1.49
准确率(%)	79.00	92.00	88.67	100.00

3.2 滚动体受损程度诊断试验

本节选取轴承滚动体的四种故障尺寸(0.18 mm, 0.36 mm, 0.53 mm, 0.72 mm), 在 2 种载荷条件(Ball₁₋₄: 0 hp, Ball₅₋₈: 1 hp)下, 同健康样本(N-正常)组成 9 类样本, 验证本文算法对滚动体受损程度的分类效果。

模型参数设置与第 3.1 小节相同, 图 7 为模型训练过程中均方误差 E_{MS} 随迭代次数增长的变化趋势。模型迭代初期均方误差以极快的速度在降低,

而后陷入了学习停滞。经过梯度下降算法的进一步学习,模型在 40 代以后以较快的速度进行寻优。迭代到 140 代时,均方误差已经小于 0.01,模型在 180 代时实现了收敛。

图 7 均方误差随迭代次数变化趋势

对测试集原始特征进行可视化, 9 类故障样本

无法区分, 如图 8 所示。

图 8 样本集原始特征可视化

图 9 为 LE-DBN 模型中 DBN 各层输出特征的可视化图。其中, 图 9a、9b 中已经大体区分了 9 类故障, 但有少数异类样本距离较近, 没有实现很好的分离。经过逐层挖掘, 图 9c 中样本的聚类效果大大提升, 经分类器分类后, 可以得到准确的故障诊断结果。

(a) 第一隐层

(b) 第二隐层

(c) 第三隐层

(d) 分类层

图 9 DBN 输出特征可视化

四类模型的准确率与耗时对比如表 2 所示, 可见本文模型对故障尺寸的分类效果明显优于其他三类。LE、KPCA 虽在耗时上优于 LE-DBN, 但准确率远远不及后者。同时考虑准确率与耗时的双重指标, LE-DBN 模型显然是最佳的选择。

表 2 试验 2 方法对比

算法对比	KPCA	LE	DBN	LE-DBN
降维	0.15	0.36	—	0.64
预训练	—	—	5.62	0.085
耗时/s	—	—	80.15	0.89
测试	0.018	0.019	0.38	0.042
总耗时	0.168	0.379	86.15	1.657
准确率(%)	75.93	85.93	89.67	99.33

图 10 轴承仿真故障信号幅值谱

对每类故障的时域振动信号截取 200 个样本点, 每个样本由 1 024 个连续采样点构成。其中有标签和无标签的训练样本数目皆为 50, 其余 100 个样本用于测试。选择 PCA、KPCA、LE 三种算法进行对比, 算法参数设置与第 3.1 节相同, 每组试验分别进行 10 次并取平均值。

三种对比算法的正确率分别为 52.25%、68.25%、89.5%, 而本文提出的 LE-DBN 算法准确率高达 99.5%。图 11、12 分别是 LE 算法和 LE-DBN 算法对上述故障信号的分类混淆矩阵。图 11 中 LE 算法无法精准判定 RF、BF 两类故障, 有 30 个 BF 故障样本被错判为 RF, 12 个 RF 故障样本被错判为 BF。而在图 12 中, 仅有 2 例 BF 样本被错误判定,

3.3 轴承仿真故障信号验证

为了更好地检验 LE-DBN 算法对滚动轴承故障模式的辨识效果, 建立具有周期性和脉动性的滚动轴承故障信号仿真模型。

$$x(n) = \sum_{n=0}^{N-1} e^{-BnT_1} \times \sin(2\pi f_1 nT) + \varphi(t) \quad (18)$$

式中, $T_1 = \text{mod}(nT, 1/f_2)$; B 为衰减阻尼; N 表示对应仿真故障信号的脉冲总数; f_1 和 f_2 分别表示共振频率与对应故障的特征频率; $\varphi(t)$ 为一随机高斯白噪声。采样频率 $f_s = 10 \text{ kHz}$, 共振频率 $f_1 = 2 500 \text{ Hz}$, 通过选取不同的故障特征频率 f_2 来构建外圈故障(OF)、内圈故障(IF)、保持架故障(RF)、滚动体故障(BF)四类故障信号对所提算法进行验证, 四类故障信号的幅值谱如图 10 所示。

说明 LE-DBN 算法对滚动轴承的故障识别有着很高的正确率。

OF	100	0	0	0
IF	0	100	0	0
RF	0	0	88	12
BF	0	0	30	70
	OF	IF	RF	BF

图 11 LE 的分类混淆矩阵

图 12 LE-DBN 的分类混淆矩阵

4 齿轮故障试验验证

为进一步验证本文 LE-DBN 算法模型的有效性，采用齿轮状态监测平台^[12]测得的故障数据集进行试验验证。如图 13 所示，该平台包括一级减速齿轮箱、伺服电动机、扭矩传感器、电磁制动器和制动控制器。

图 13 一级齿轮箱试验平台

三个三轴加速度传感器(PCB-356A16)分别如图 14 安装在试验台的基座、主动轮轴承端、被动轮轴承端。减速箱主从动齿轮的相关参数如表 3 所示，通过线切割的方式构造主动轮齿轮的 4 种裂纹状态(图 15)：无裂纹、1/4 裂纹、1/2 裂纹、3/4 裂纹，裂纹长度 $L=i \times (R_{b1}-r_1)/4$ ， $i=0, 1, 2, 3$ 。其中 R_{b1} 、 r_1

图 14 加速度传感器安装位置

分别为主动轮齿根圆半径(27.5 mm)与中心孔半径(47.5 mm)。

表 3 齿轮箱参数

齿轮参数	齿数	模数/mm	齿宽/mm
主动轮	50	2	20
从动轮	80	2	20

图 15 加速度传感器安装位置

为探究算法在不同工况下对齿轮不同裂纹程度的诊断能力，对每种齿轮裂纹严重程度分别选择 10 种工况条件(5 种输入轴转速、2 种负载)的样本，详见表 4。本试验所用数据采集卡型号为 NI PXI-1042，频率为 5 000 Hz，选择 900 个采样点构成一个高维样本。在每种工况条件下，分别构建 50 个同类故障样本，因而，对每种齿轮故障而言，共有 500 个样本点。构建样本集时，采用 Kennard-stone(KS)算法进行两次样本选取。第一次在全部样本中选取样本训练集，其余样本为测试集；第二次在训练集中选择少量有标签样本，其他为无标签样本。从而产生了不同工况下样本数目不平衡、不同故障类型的有标签样本数目不平衡的训练集，以探究算法模型在不平衡数据背景下的故障诊断能力。

表 4 多工况下试验参数设置

试验参数	数值
裂纹长度/mm	0.5,10,15
输入轴转速/(r/min)	300,600,900,1 200,1 500
负载/(N·m)	0.4
样本点数	2 000
样本维度	900

由于单一传感器测得的信号很难全面地反映齿

轮的故障状态,本试验采用融合多传感器特征的方式实现对齿轮的故障诊断。分别对三个传感器9个轴的振动信号采用LE算法进行流形学习,每个轴得到30维的低维流形特征。融合多传感器特征后得到总共270维的低维特征,输入到DBN网络中进行二次特征挖掘,充分发挥深度网络分布式提取特征的能力。因而确定DBN网络的输入端神经元数目为270,隐藏层神经元个数为270-270-270,Soft-max分类层神经元个数为4。其他DBN网络参数设置同章节3。

为验证有标签样本数目对故障分类精度的影响,通过KS算法分别选取不同数目的有标签样本进行试验。为避免样本选取和模型训练的偶然性,同条件下分别进行10次试验,得到每次试验的准确率区间。图16中,对于训练集样本,识别率始终保持在100%,说明模型可以很好的拟合训练数据。对于测试集样本,随有标记样本数目增加,模型识别准确率逐步上升,当有标记样本总数为60时,模型准确率已经达到90%以上;当有标记样本总数达到180以上时,模型准确率达到了100%。图中所示训练时间为算法迭代100次所需耗时,可以看出,当标记样本增多,训练时间也相应地增加。因而,在实际应用中,要权衡算法耗时与准确率的关系,选择合适数量的训练样本。

为研究不同的降维算法及嵌入维度对模型分类精度的影响。分别选择PCA、KPCA、LE三种降维算法,选取不同的嵌入维度,对原始信号进行特征提取,再将输出特征作为DBN网络的输入实现诊断。其中,各算法参数设置同章节3,通过KS算法选择200个有标签样本,1200个无标签样本,其余为测试样本。每组试验进行10次,取其均值。图17中,横坐标为各降维算法的嵌入维度。双纵坐标分别为准确率与DBN每训练100次的平均耗时。

可以看出,LE算法的特征提取能力要远远强于线性的PCA算法和非线性的KPCA算法,且在选择合适的参数范围时准确率可达100%。为兼顾分类精度与识别效率,选取嵌入维度为24~30,可以使得LE-DBN模型的整体效果最优。

上述试验可以得出,对比算法中KPCA表现明显优于PCA。因此,分别选用KPCA与LE算法对单个传感器的信号进行特征提取,DBN输入维度为90。图18中,实线所示的LE算法保持了很高的准确率,对三个传感器信号特征提取的效果都优于KPCA算法。这说明,无论是针对多传感器信号还是单一传感器信号,本文的LE-DBN模型都有着更好的诊断效果。此外,对比图18可以得出,多个传感器特征融合后的诊断效果要优于对单个传感器的信号诊断。

卷积神经网络(Convolutional neural network, CNN)也是一种应用普遍的深度学习网络,它可以通过多层卷积、池化等操作来逐层提取故障特征^[28]。因此,选取CNN网络构建LE-CNN模型作为对比,来探究LE-DBN故障诊断模型中DBN网络特征提

取与故障分类的效果。分别对三个传感器 9 个轴的振动信号进行流形学习, 对每个轴提取 30 维的故障特征, 并组合为 270 维的低维特征向量作为两种深度学习网络的输入。CNN 网络的参数设置如表 5 所示, 各符号含义为 C—卷积层、S—池化层、FC—全连接层。

表 5 CNN 网络参数设置

参数设置	名称	大小	输出尺寸
输入层	—	—	270×1
C1	卷积核	3×1×32	270×1×32
S2	最大池化核	3×1	90×1×32
C3	卷积核	3×1×16	90×1×16
S4	最大池化核	3×1	30×1×16
FC5	—	—	480×1
FC6	权值矩阵	480×100	100×1
输出层	输出层	100×4	4×1

样本集与图 15 所进行的试验相同, 其中训练集分为有标签样本和无标签样本两部分。随机选取不同数目的有标签样本, 探究 DBN、CNN 两种算法在不同数据背景下的分类效果。每种样本条件下分别进行 10 次试验, 两种算法的准确率均值如表 6 所示, δ 为两算法准确率的差值。

表 6 不同有标签样本数目下两种算法的准确率对比

数目	60	80	100	120	140	160	180	200
CNN	85.83	87.50	90.50	91.67	95.83	98.17	98.87	99.08
DBN	93.34	94.37	96.29	97.11	96.84	98.11	100	100
δ	-7.51	-6.87	-5.79	-5.44	-1.01	0.06	-1.13	-0.92

由二者准确率差值可知, 在有标签样本不足(数目 60~120)的样本条件下, DBN 网络的故障分类效果明显优于 CNN 网络。这得益于 DBN 网络可以利用海量无标签数据进行无监督的层间预训练, 因此模型精度要高于仅依靠少量有标签样本完成训练的 CNN 网络。随着有标签样本数目的增加, 二者的分类准确率已无太大差距。但从整体来看, LE-DBN 模型在有标签样本不足时有着更好的准确率表现, 更加适用于实际的故障诊断背景。

经上述试验验证, LE-DBN 模型在识别轴承故障和齿轮裂纹的试验中, 都取得了很高的分类精度和不错的识别效率。特别地, 本文模型不需要大量有标签样本支持模型训练, 只需少量标签样本配合海量的无标签样本进行半监督的学习, 即可达成很好的训练效果。该模型克服了样本标签少、标签种类不平衡等现实难题, 对来源于多个工况条件的几类故障进行了有效的划分, 在实际应用中也有很好的效果。

5 结论

本文结合流形学习和深度学习各自的优势, 提出了一种面向原始时域信号的特征提取和故障诊断方法。该方法利用 LE 算法直接对原始高维故障信号进行流形学习, 将提取的低维流形特征输入深度置信网络进行逐层挖掘, 最终得到故障诊断的结果。其中, LE 算法降低了模型的时间复杂度, 提取关键的故障流形特征, 通过 DBN 网络更加充分地表征样本的故障特性, 再采用 Soft-max 分类器得出诊断结果。与传统的智能诊断方法相比, 本文提出的 LE-DBN 模型在轴承、齿轮的故障诊断中都取得了更好的识别效果。而模型所采用的半监督学习方式, 适用于不平衡的数据背景, 克服了有标签样本不足导致的精度下降问题。此外, LE-DBN 模型可以更加方便地解决多传感器特征融合问题, 避免了依赖单一传感器信号进行诊断的不确定性。最后, 本文模型参数的选取大多依据文献和实际经验, 如何进行参数的标准化选取, 协调模型分类精度和训练效率的关系, 仍待后期研究。

参 考 文 献

- [1] EL-THALJI I, JANTUNEN E. A summary of fault modelling and predictive health monitoring of rolling element bearings[J]. Mechanical Systems & Signal Processing, 2015, 60–61(1): 252-272.
- [2] BIN Guangfu, GAO Jinji, LI Xuejun, et al. Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decomposition feature extraction and neural network [J]. Mechanical Systems & Signal Processing, 2012, 27(1): 696-711.
- [3] 孙斌, 薛广鑫. 基于等距特征映射和支持矢量机的转子故障诊断方法[J]. 机械工程学报, 2012, 48(9): 129-135. SUN Bin, XUE Guangxin. Method of rotor fault diagnosis based on isometric feature mapping and support vector machine[J]. Journal of Mechanical Engineering, 2012, 48(9): 129-135.
- [4] ZHANG Xinhai, LEI Yong. Application of bp neural network in mechanical fault diagnosis[J]. Noise & Vibration Control, 2008, 23(23): 182-184.
- [5] 李巍华, 史铁林, 杨叔子. 基于核函数估计的转子故障诊断方法[J]. 机械工程学报, 2006, 42(9): 76-82. LI Weihua, SHI Tielin, YANG Shuzi. Rotor fault diagnosis method based on kernel function estimation[J].

- Chinese Journal of Mechanical Engineering, 2006, 42(9): 76-82.
- [6] JIANG Li, XUAN Jianping, SHI Tielin. Feature extraction based on semi-supervised kernel Marginal Fisher analysis and its application in bearing fault diagnosis[J]. Mechanical Systems & Signal Processing, 2013, 41(1-2): 113-126.
- [7] WANG Sheng, LU Jianfeng, GU Xingjian, et al. Semi-supervised linear discriminant analysis for dimension reduction and classification[J]. Pattern Recognition, 2016, 57(C): 179-189.
- [8] HINTON G, SALAKHUTDINOV R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [9] 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 Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era [J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [10] CHEN Zhiqiang, DENG Shengcai, CHEN Xudong, et al. Deep neural networks-based rolling bearing fault diagnosis[J]. Microelectronics Reliability, 2017, 75: 327-333.
- [11] SHAO Haidong, JIANG Hongkai, ZHANG Haizhou, et al. Electric locomotive bearing fault diagnosis using a novel convolutional deep belief Network[J]. IEEE Transactions on Industrial Electronics, 2017, 65(3): 2727-2736.
- [12] LIU Jie, HU Youmin, WANG Yan, et al. An integrated multi-sensor fusion-based deep feature learning approach for rotating machinery diagnosis[J]. Measurement Science & Technology, 2018, 29(5).
- [13] SHAO Haidong, JIANG Hongkai, LI Xingqiu, et al. Intelligent fault diagnosis of rolling bearing using deep wavelet auto-encoder with extreme learning machine [J]. Knowledge-based Systems, 2018, 140: 1-14.
- [14] HINTON G. Deep belief networks[J]. Scholarpedia, 2009, 4(6): 5947.
- [15] 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 Guangquan, GE Qiangqiang, LIU Xiaoyong, et al. Fault feature extraction and diagnosis method based on deep belief network[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1946-1953.
- [16] 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.
- ZHANG Shuqing, HU Yongtao, JIANG Anqi, et al. Bearing fault diagnosis based on DTCWT and DBN[J]. China Mechanical Engineering, 2017, 28(5): 532-536.
- [17] JIANG QuanSheng, JIA Minping, HU Jianzhong, et al. Machinery fault diagnosis using supervised manifold learning[J]. Mechanical Systems & Signal Processing, 2009, 23(7): 2301-2311.
- [18] RADUCANU B, DORNAIKA F. A supervised non-linear dimensionality reduction approach for manifold learning[J]. Pattern Recognition, 2012, 45(6): 2432-2444.
- [19] ZHANG Yun, LI Benwei, WANG Wen, et al. Supervised locally tangent space alignment for machine fault diagnosis[J]. Journal of Mechanical Science & Technology, 2014, 28(8): 2971-2977.
- [20] LUNGA D, PRASAD S, CRAWFORD M, et al. Manifold learning based feature extraction for classification of hyperspectral data[J]. IEEE Signal Processing Magazine, 2014, 31(1): 55-66.
- [21] NICOLAS L R, YOSHUA B. Representational power of restricted boltzmann machines and deep belief networks[J]. Neural Computation, 2008, 20(6): 1631-1649.
- [22] 陶洁, 刘义伦, 杨大炼, 等. 基于细菌觅食决策和深度置信网络的滚动轴承故障诊断[J]. 振动与冲击, 2017, 36(23): 68-74.
- TAO Jie, LIU Yilun, YANG Dalian, et al. Rolling bearing fault diagnosis based on bacterial foraging algorithm and deep belief network[J]. Journal of Vibration and Shock, 2017, 36(23): 68-74.
- [23] HINTON G. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002, 14(8): 1771-1800.
- [24] LOPARO K A. Bearings vibration data set[DB/OL]. Cleveland, Ohio: Case Western Reserve University. [2014-10-28]. <http://csegroups.case.edu/bearingdatacenter/home>.
- [25] 江丽, 郭顺生. 基于半监督拉普拉斯特征映射的故障诊断[J]. 中国机械工程, 2016, 27(14): 1911-1916.
- JIANG Li, GUO Shunsheng. Fault diagnosis based on semi-supervised laplacian eigenmaps[J]. China Mechanical Engineering, 2016, 27(14): 1911-1916.
- [26] HE Qingbo. Time-frequency manifold for nonlinear feature extraction in machinery fault diagnosis[J]. Mechanical Systems & Signal Processing, 2013, 35(1-2):

- 200-218.
- [27] 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 Weihua, SHAN Waiping, ZENG Xueqiong. Bearing fault classification and identification based on deep belief networks[J]. Journal of Vibration Engineering, 2016, 29(2): 340-347.
- [28] GUO Liang, LEI Yaguo, LI Naipeng, et al. Machinery

health indicator construction based on convolutional neural networks considering trend burr[J]. Neurocomputing, 2018, 292: 142-150.

作者简介: 张鑫, 男, 1994 年出生。主要研究方向为故障诊断。

E-mail: gzzdzhangxin@163.com

江丽(通信作者), 女, 1980 年生, 博士, 讲师, 硕士研究生导师。主要研究方向为机械设备状态监测与故障诊断、模式识别。

E-mail: happyjl0929@163.com