

基于改进深层极限学习机的故障诊断方法^{*}

李可¹, 熊檬¹, 宿磊¹, 卢立新¹, 陈森²

(1. 江南大学江苏省食品先进制造装备技术重点实验室 无锡, 214122)

(2. 上海才月科技有限公司 上海, 200050)

摘要 提出一种新的基于稀疏和近邻保持理论深层极限学习机(sparsity and neighborhood preserving deep extreme learning machines, 简称 SNP-DELM)的滚动轴承故障诊断方法。首先, 将极限学习机(extreme learning machine, 简称 ELM)与自编码器(autoencoder, 简称 AE)相结合, 提出一种 ELM-AE 的结构, 利用自编码器对极限学习机的隐含层进行分层; 其次, 将稀疏与近邻思想融入深层网络中, 在投影过程中, 通过稀疏表示保持数据的全局结构, 通过近邻表示保持数据的局部流形结构, 无监督地逐层提取数据的深层特征; 最后, 通过监督学习求解最小二乘进行分类诊断。将该方法用于风机滚动轴承故障诊断实验, 并与 ELM、堆叠降噪自编码器(stacked autoencoder, 简称 SAE)、深层极限学习机(deep extreme learning machine, 简称 DELM)、卷积神经网络(convolution neural network, 简称 CNN)等方法进行对比, 实验结果表明, SNP-DELM 算法相对于现有的几种算法具有更高的准确率和稳定性。

关键词 故障诊断; 深层极限学习机; 稀疏表示; 近邻表示; 滚动轴承

中图分类号 TH17

引言

滚动轴承被广泛用于石化、冶金和铁路等行业的重要设备上, 是旋转设备和交通工具中重要机械零件之一^[1-2]。由于滚动轴承承受冲击的能力差, 也是机器中最易损坏的零件之一。因此, 开展滚动轴承的状态监测和故障诊断具有重要意义^[3]。

多年来, 传统的神经网络(neural network, 简称 NN)、支持向量机(support vector machine, 简称 SVM)等方法已经被广泛应用到故障诊断领域。王元章等^[4]通过分析光伏阵列输出量变化规律, 选取了 4 个特征参量输入到神经网络中, 实验结果表明该方法可以有效地检测出光伏阵列的故障类型。石志标等^[5]采用混沌的生物地理学优化算法(biogeography-based optimization with chaos, 简称 CS-BBO)优化 SVM 得到最优参数, 并将方法运用于汽轮机转子故障诊断, 诊断结果验证了算法的有效性。然而上述方法存在训练速度慢、需要人为调整的参数多及参数确定困难等缺点。Huang 等^[6]提出的

极限学习机, 其隐藏层参数是随机生成的, 通过正则化最小二乘来获得输出权重, 因其不需通过反向传播更新权值, 相比于传统的 NN 和 SVM, ELM 算法训练速度更快, 且泛化能力强, 不易过拟合。Huang 等^[7]将极限学习机推广到无监督模式, 提出一种无监督极限学习机(unsupervised extreme learning machines, 简称 US-ELM), 将流形正则化的思想引入 ELM, 利用非线性映射将原始数据投影到低维空间中, 并保持数据样本的近邻结构, 提高分类准确率。苑津莎等^[8]将 ELM 运用于变压器故障诊断, 相比于传统方法, 训练时间短, 准确率更高。尹刚等^[9]将在线贯序极限学习机运用于滚动轴承故障诊断中, 取得了较好的效果。然而, ELM 因其输入权值和阈值随机生成, 且只有一个隐含层, 致使模型的鲁棒性较差。

近年来, 深度学习算法在故障诊断领域成为研究热点, 该算法可以摆脱传统浅层学习算法的缺点, 数据的浅层特征在底层得以学习, 之后被输入到下一层, 形成输入数据更复杂的表示, 数据的深层特征得以在深层结构学习。Hinton 等^[10]提出了一种深

^{*} 国家自然科学基金资助项目(51775243, 51705203); 江苏省重点研发计划资助项目(BE201702); 山东省泰山产业领军人才计划资助项目; 江苏省研究生科研与实践创新计划资助项目(KYCX18_1847)

收稿日期: 2018-10-13; 修回日期: 2019-01-10

层神经网络的概念及其训练方法,该算法将输入作为输出,采用无监督逐层贪婪训练法依次训练网络的每一层,进而通过 softmax 等分类器有监督训练最后一层,SAE 即采用此种方法进行训练。汤芳等^[11]将深度自编码网络用于滚动轴承故障,相比于传统的单层网络算法取得了较好的效果。王丽华等^[12]将异步电机电流信号与傅里叶变换后的振动频域信号拼接成样本输入堆叠降噪自编码网络,比传统电机诊断方法有较大的提升。但是由于网络层数的增加,这种深层网络的训练时间过长,且容易陷入局部最优解。

针对以上问题,笔者提出一种稀疏和近邻保持深层极限学习机(SNP-DELM)的方法用于滚动轴承故障诊断,将 ELM 与自编码器相结合,提出一种 ELM-AE 结构,并加入稀疏和近邻的思想,在投影过程中,通过稀疏表示保持数据的全局结构以及通过近邻表示保持数据的局部流形结构,无监督地逐层提取数据的压缩表示,最后通过有监督学习进行分类诊断。

1 极限学习机和深层极限学习机

1.1 极限学习机(ELM)

ELM 本质上是一个单隐层前馈神经网络,其结构如图 1 所示。给定一个包含 N 个不同数据样本 $(x_k, y_k) \in \mathbf{R}^l \times \mathbf{R}^s$ 的监督学习问题,其训练过程包含两个阶段:①根据隐藏层节点数,随机生成输入权重矩阵 \mathbf{W} 和阈值 b ,计算出隐含层输出;②根据数据标签求解最小二乘得到输出矩阵 β ,其模型为

$$\begin{cases} h_x = g(W_x x + b_x) \in \mathbf{R}^l \\ y = \beta h_x \in \mathbf{R}^s \end{cases} \quad (1)$$

其中: $g(\cdot)$ 为激活函数,常用的为 sigmoid 函数和 tanh 函数; h_x 为隐藏层输出; $\beta = [\beta_1, \beta_2, \dots, \beta_m]$ 为输出层权值。

本研究采用的是 sigmoid 函数,其表达式为

$$g(W_x x + b_x) = 1 / (1 + \exp(-W_x x - b_x)) \quad (2)$$

ELM 的输出矩阵 β 的求解模型可表示为

$$\min \frac{1}{2} \|\beta\|^2 + \frac{C}{2} \sum_{i=1}^N e_i^2 \quad (3)$$

(s. t. $y_i = \beta h_x + e_i; i = 1, 2, \dots, n$)

其中:目标函数第 1 部分为正则项;第 2 部分为误差; C 为惩罚因子。

1.2 深层极限学习机(DELM)

DELM 是一种将自编码的思想与 ELM 相结合

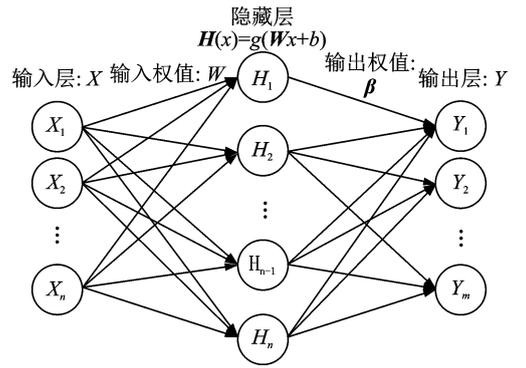


图 1 极限学习机网络结构图

Fig. 1 ELM network structure

产生的深层网络结构^[13],其结构如图 2 所示。DELM 将 ELM 的学习效率与 AE 的深层结构相融合,以获得更好的预测性能。由于经典 ELM 算法是一种有监督学习算法,而在 DELM 的深层结构中,数据在降维过程中是没有标签矩阵的,因此将其与自编码器相结合,通过最小化重构误差来逼近原始输入矩阵。DELM 的结构分为两部分:①无监督特征学习;②监督特征分类。第 1 部分是采用 ELM-AE 的结构来逐层获取数据的压缩表示,首先通过式 $\mathbf{H} = g(\mathbf{W}\mathbf{x} + b)$ 将输入数据 x 映射到隐藏层 \mathbf{H} ,其中: \mathbf{W} 为输入权重,通过随机生成产生; b 为偏置。

隐藏层参数通过求解式(4)获得

$$\min \|\mathbf{H}\beta - \mathbf{X}\|^2 + \|\beta\|_{l_1} \quad (4)$$

其中: \mathbf{H} 为输入层随机映射的输出; \mathbf{X} 为输入数据; β 为隐藏层输出权重; l_1 为范数,是为了使得隐藏节点数更少,以获得数据更紧凑的特征。

对于第 i 层 ELM-AE,其输出可表示为

$$\mathbf{L}_i = g(\mathbf{L}_{i-1}\beta_i) \quad (5)$$

第 2 部分是采用经典的 ELM 监督学习算法进行分类,ELM 算法能够充分利用样本的标签信息,从降维后的样本中提取出数据的隐藏信息,提高算法的分类性能。此处的自编码结构与传统的深度自编码网络并不相同,一旦提取了前 1 个隐藏层的特征,则该层的权重和参数都将固定,不需要如同深度自编码网络一样仍需通过反向传播进行微调。因此,DELM 的训练速度比 BPNN,DAE 等反向传播算法更加快速。

相比于单层 ELM,由于 DELM 自编码的逐层降维的训练方式,在面对高维数据时,往往能取得更好的测试效果。在故障诊断领域,以往的算法大多基于特征提取后的数据,通过专家经验从原始数据中提取出一些特征参量,然后对这些数据进行分类,但将算

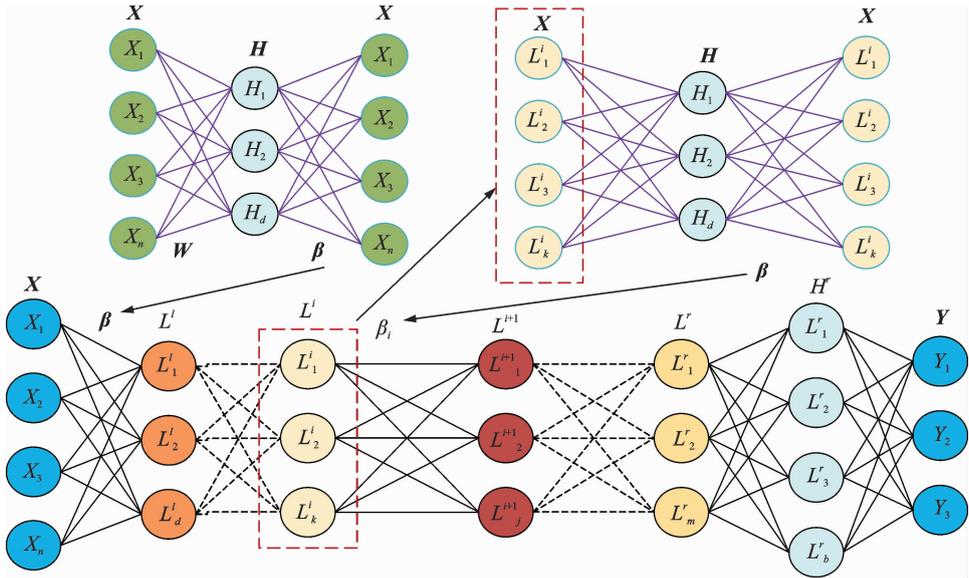


图2 深层极限学习机网络结构图

Fig. 2 Deep extreme learning machines network structure

法直接运用于原始数据时,分类效果往往不尽人意。DELM 能够从原始数据中无监督逐层提取出其压缩表示,并在最后一层有监督分类时充分利用数据的标签信息,以此能够获得更好的分类效果。

2 稀疏和近邻保持深层极限学习机

稀疏表示和近邻表示的思想已经被验证在数据降维上有较好的效果^[14-15]。为进一步提高 DELM 算法的性能,笔者将稀疏和近邻思想与深层极限学习机相结合,提出一种稀疏和近邻保持深层极限学习机,该方法能使数据在逐层投影的过程中保持其在原始空间中的近邻和稀疏结构,以提高分类正确率。

2.1 近邻表示和稀疏表示

近邻表示:近邻保持算法旨在保持数据的局部邻居结构,对于一个数据集,首先构造每个点之间的权重矩阵;对于每个数据点,它能够表达为它近邻的点的线性组合;线性组合的系数由权重矩阵指定,在样本集 $\mathbf{X} = [x_1, x_2, \dots, x_n] \in \mathbf{R}^{m \times n}$ 中,对于每个样本 x_i ,用其 k 个近邻样本对 x_i 进行线性重构,其目标函数为

$$\min \left\| x_i - \sum_{x_j \in N_k(x_i)} w_{ij} x_j \right\| \quad (6)$$

其中: $N_k(x_i)$ 为 x_i 的 k 个近邻,可以通过计算样本相互间欧式距离获得; w_{ij} 为近邻表示系数,对于 $x_j \notin N_k(x_i)$, $w_{ij} = 0$ 。

稀疏表示:在样本集 $\mathbf{X} = [x_1, x_2, \dots, x_n] \in \mathbf{R}^{m \times n}$ 中,稀疏表示希望每个样本 x_i 能由整个空间 \mathbf{X}

中尽可能少的向量进行线性重构。由于实际中样本存在噪声的干扰以及数学求解的问题,引入重构误差 ϵ ,其目标函数为

$$\begin{cases} \min \|s_i\|_0 \\ s_i \\ \text{s. t. } \|x_i - \mathbf{X}s_i\|_2 < \epsilon \\ \mathbf{1} = \mathbf{I}^T s_i \end{cases} \quad (7)$$

其中: $s_i \in \mathbf{R}^n$ 为稀疏重构向量; \mathbf{I} 为元素为 1 的列向量。

求解上述问题,采用正交匹配追踪(orthogonal matching pursuit,简称 OMP)算法,其步骤如下:

1) 初始化残余信号 $r = x_i$,非零元素集合 $\Lambda = \{\}$,迭代次数 $i = 0$;

2) 对数据集 \mathbf{X} 中的所有信号进行搜索,找到与残余信号 r 相关性最大的信号的坐标 k_c 。

$$k_c = \arg \max_{k=1,2,\dots,N} |\mathbf{X}_k r| \quad (8)$$

3) 将找到的 k_c 合并到非零元素对应的坐标集合 $\Lambda = \Lambda \cup \{k_c\}$ 中;

4) 将原始的观测信号 x_i 向当前的非零元素组成的集合进行正交投影,计算投影系数

$$z_\Lambda = \arg \min_{z_\Lambda} \|x_i - \mathbf{X}_\Lambda z_\Lambda\|_2^2 \quad (9)$$

其中: \mathbf{X}_Λ 表示由集合 Λ 中的坐标所对应的原数据集中的信号的集合; s_Λ 为当前非零元素。

5) 更新残余信号

$$r = x_i - \mathbf{X}_\Lambda s_\Lambda \quad (10)$$

其中:迭代次数 $i = i + 1$ 。

经过上述步骤的迭代,当所有 K_s 个非零元素都找到后,坐标集合 Λ 就表示 K_s 个非零元素的位置,

元素的值对应为投影系数。由于 s_i 中的非零元素大部分对应于同类别的样本,这说明在没有类别标签信息的情况下, s_i 包含了自然的判别信息。

2.2 稀疏和近邻保持极限学习机

在深层极限学习机的 ELM-AE 结构中,将输入作为输出构成一个传统单隐层前馈神经网络的结构,将无监督学习转变为监督学习模式,由上述稀疏表示和近邻表示可得到,对于训练集 $\mathbf{X} = [x_1, x_2, \dots, x_n] \in \mathbf{R}^{m \times n}$ 中的任一 x_i , 均有近邻表示系数向量 $\mathbf{w}_i = [0, \dots, \omega_{i,1}, \dots, \omega_{i,2}, \dots, \omega_{i,k}, \dots, 0]$ 及稀疏表示向量 $\mathbf{s}_i = [s_{i,1}, \dots, s_{i,i-1}, 0, s_{i,i+1}, \dots, s_{i,n}]$ 满足

$$\mathbf{x}_i = \omega_{i,1}x_{k,1} + \omega_{i,2}x_{k,2} + \dots + \omega_{i,k}x_{k,k} \quad (11)$$

$$\mathbf{x}_i = s_{i,1}x_1 + \dots + s_{i,i-1}x_{i-1} + s_{i,i+1}x_{i+1} + \dots + s_{i,n}x_n \quad (12)$$

其中: $x_{k,1}, x_{k,2}, \dots, x_{k,k}$ 为 x_i 的 k 个近邻; $\omega_{i,1}, \omega_{i,2}, \dots, \omega_{i,k}$ 为对应的权重系数。

为了将原始高维空间中的稀疏重构关系与近邻关系保持到投影后的低维子空间中,提出一种 SNP-ELM-AE 的结构,其目标函数为

$$\min_{\beta} \frac{1}{2} \|\beta\|_F^2 + \frac{\lambda}{2} \sum_{i=1}^n \left\| (h(x_i)\beta)^T - (\mathbf{H}(\mathbf{X})\beta)^T (\alpha\mathbf{w}_i + \gamma\mathbf{s}_i) \right\|_2^2 + \frac{C}{2} \|\mathbf{Y} - \mathbf{H}(\mathbf{X})\beta\|_2^2 \quad (13)$$

其中: $\mathbf{H}(\mathbf{X})$ 为隐藏层输出; $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_n]$ 为近邻表示矩阵, \mathbf{w}_i 为 x_i 对应的近邻表示系数; $\mathbf{S} = [s_1, s_2, \dots, s_n]$ 为稀疏表示矩阵, s_i 为 x_i 的稀疏表示系数; α, γ 分别为近邻和稀疏的权重系数; \mathbf{Y} 为数据的标签矩阵,在 ELM-AE 的结构中,标签由输入 \mathbf{X} 代替。

第2项的目的是使得经过 ELM 投影后,数据的稀疏与近邻结构依旧能够保持。

求解式(13),令 $\mathbf{Z} = \alpha\mathbf{W} + \gamma\mathbf{S}$, 通过代数运算可得到

$$\sum_{i=1}^n \left\| (h(x_i)\beta)^T - (\mathbf{H}(\mathbf{X})\beta)^T \mathbf{z}_i \right\|_2^2 = \text{tr}(\beta^T (\sum_{i=1}^n (h(x_i))^T - \mathbf{H}(\mathbf{X})^T \mathbf{z}_i) \cdot (h(x_i))^T - \mathbf{H}(\mathbf{X})^T \mathbf{z}_i)^T \beta) \quad (14)$$

设 \mathbf{e}_i 为 n 维单位向量,则可得

$$\text{tr}(\beta^T (\sum_{i=1}^n (\mathbf{H}(\mathbf{X}))^T \mathbf{e}_i - \mathbf{H}(\mathbf{X})^T \mathbf{z}_i) \cdot (\mathbf{H}(\mathbf{X})^T \mathbf{e}_i - \mathbf{H}(\mathbf{X})^T \mathbf{z}_i)^T \beta) = \text{tr}(\beta^T \mathbf{H}(\mathbf{X})^T (\sum_{i=1}^n (\mathbf{e}_i - \mathbf{z}_i) (\mathbf{e}_i - \mathbf{z}_i)^T) \cdot$$

$$\mathbf{H}(\mathbf{X})\beta) = \text{tr}(\beta^T \mathbf{H}(\mathbf{X})^T \cdot (\sum_{i=1}^n (\mathbf{e}_i \mathbf{e}_i^T - \mathbf{z}_i \mathbf{e}_i^T - \mathbf{e}_i \mathbf{z}_i^T + \mathbf{z}_i \mathbf{z}_i^T)) \cdot$$

$$\mathbf{H}(\mathbf{X})\beta) = \text{tr}(\beta^T \mathbf{H}(\mathbf{X})^T \cdot (\mathbf{I} - \mathbf{Z} - \mathbf{Z}^T + \mathbf{Z}^T \mathbf{Z}) \mathbf{H}(\mathbf{X})\beta) \quad (15)$$

上述模型变为

$$\min_{\beta} \frac{1}{2} \|\beta\|_F^2 + \frac{\lambda}{2} \text{tr}(\beta^T \mathbf{H}(\mathbf{X})^T \cdot (\mathbf{I} - \mathbf{Z} - \mathbf{Z}^T + \mathbf{Z}^T \mathbf{Z}) \mathbf{H}(\mathbf{X})\beta) + \frac{C}{2} \|\mathbf{X} - \mathbf{H}(\mathbf{X})\beta\|_2^2 \quad (16)$$

令 $\mathbf{A} = (\mathbf{I} - \mathbf{Z} - \mathbf{Z}^T + \mathbf{Z}^T \mathbf{Z})$, 将目标函数对 β 求偏导,可得到

$$\nabla = \beta + \lambda \mathbf{H}(\mathbf{X})^T \mathbf{A} \mathbf{H}(\mathbf{X}) \beta + \mathbf{C} \mathbf{H}(\mathbf{X})^T (\mathbf{X} - \mathbf{H}(\mathbf{X})\beta) \quad (17)$$

令 $\nabla = 0$, 有

$$\beta^* = (\mathbf{I} + \lambda \mathbf{H}(\mathbf{X})^T \mathbf{A} \mathbf{H}(\mathbf{X}) + \mathbf{C} \mathbf{H}(\mathbf{X})^T \mathbf{H}(\mathbf{X}))^{-1} \mathbf{C} \mathbf{H}^T \mathbf{X} \quad (18)$$

当样本数据的数量少于隐藏神经元的数量时, $\mathbf{H}(\mathbf{X})$ 的行数大于列,这样会产生欠定最小二乘的问题, β 将具有无数个解。对此,令 $\beta = \mathbf{H}(\mathbf{X})^T \delta$, 在式 $\nabla = 0$ 左右两边各乘以 $(\mathbf{H}(\mathbf{X})\mathbf{H}(\mathbf{X})^T)^{-1} \mathbf{H}(\mathbf{X})$, 可求解得到

$$\beta^* = \mathbf{H}(\mathbf{X})^T \delta = \mathbf{H}(\mathbf{X})^T (\mathbf{I} + \mathbf{C} \mathbf{H}(\mathbf{X}) \cdot \mathbf{H}(\mathbf{X})^T + \lambda \mathbf{A} \mathbf{H}(\mathbf{X}) \mathbf{H}(\mathbf{X})^T)^{-1} \mathbf{C} \mathbf{X} \quad (19)$$

SNP-DELM 算法训练中,输入为训练数据样本 \mathbf{X} 、样本标签 \mathbf{Y} 及测试样本 \mathbf{X}' ; 输出为测试样本的预测标签 \mathbf{Y}' 。其步骤如下:

- 1) 确定深层网络整体网络结构,即网络层数 m 、各隐藏层神经元数量以及各层参数 $k, \alpha, \gamma, \lambda$ 及 C ;
- 2) 对训练数据和测试数据归一化;
- 3) 对第1层至 $(m-1)$ 层初始化输入权值,将输入作为输出,根据式(6)、式(7)计算各层稀疏和近邻矩阵,通过式(18)或式(19)计算输出权重矩阵 β ;
- 4) 对第 m 层,根据标签矩阵,通过求解最小二乘求出最后1层输出权值;
- 5) 计算测试样本的预测标签 \mathbf{Y}' 。

3 实验验证

为了验证本研究所提方法的性能,分别在几组 UCI(university of californiaIrvine)数据集和滚动轴承故障诊断实验平台采集的实验数据进行测试。

3.1 UCI 数据集分类效果

实验采用的 UCI 数据集为 Breast Cancer, Ban-

knote 和 SEED,数据集基本信息如表 1 所示。将所提出的 SNP-DELM 算法与 DELM 和 ELM 进行对比,测试样本的分类准确率如表 2 所示。为了更好地对分类结果进行可视化,采用主成分分析法(principal components analysis,简称 PCA)对 3 个数据集进行降维,提取出其前 2 个主成分分量(principal components,简称 PC),对数据进行二维可视化,分类结果如图 3~5 所示。从图中可看出:在 Breast Cancer 数据上,DELM 和 ELM 两种方法的错分点分别为 21 和 15 个,SNP-DELM 算法的错分点降低到 3 个,正确率为 98.67%;在 Banknote 数据集上,DELM 和 ELM 的错分点分别为 14 和 17 个,SNP-DELM 将错分点降低到 2 个,正确率为 99.6%;在 Seed 数据集上,3 种算法的正确率分别为 97.14%,95.23%和 94.76%,DELM 和 ELM 的错分点为 11 和 10 个,SNP-DELM 将错误降低到 6 个。从上述实验结果可以看出,SNP-DELM 算法相比于其他两种方法,有更好的分类效果。

表 1 UCI 数据集介绍

Tab. 1 UCI data set introduction

数据集	样本数	属性数	分类数
Breast Cancer	683	10	2
Banknote	1 372	5	2
Seed	210	7	3

表 2 UCI 诊断结果

Tab. 2 UCI diagnosis results of different methods %

数据集	SNP-DELM	DELM	ELM
Breast Cancer	98.67	95.00	93.00
Banknote	99.60	97.20	96.60
Seed	97.14	95.23	94.76

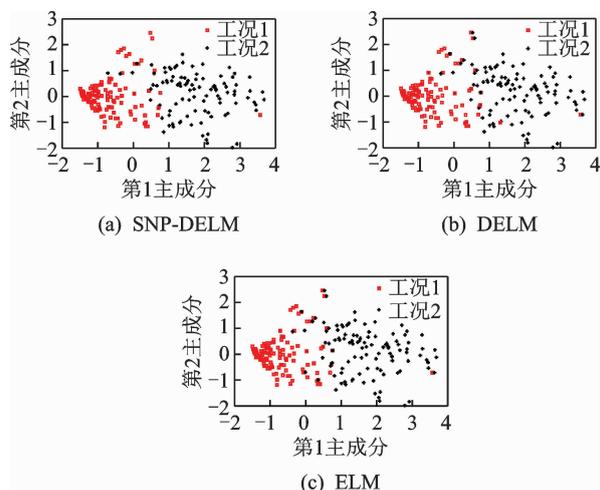


图 3 Breast Cancer 数据集分类效果可视化图

Fig. 3 Breast cancer data set classification effect visualization

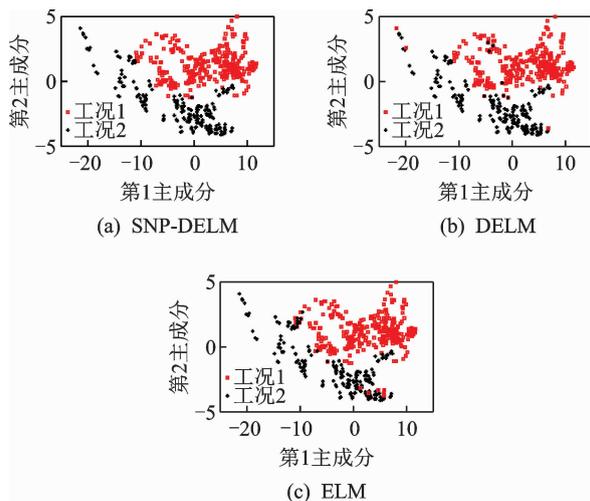


图 4 Banknote 数据集分类效果可视化图

Fig. 4 Banknote data set classification effect visualization

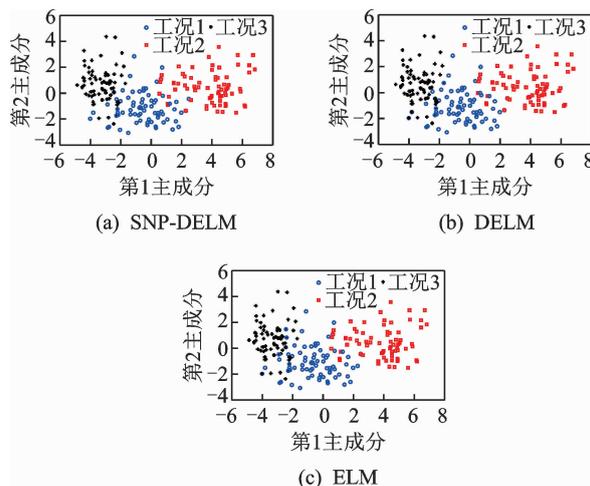


图 5 SEED 数据集分类效果可视化图

Fig. 5 Seed data set classification effect visualization

3.2 实验设置

为进一步验证笔者所提诊断方法在滚动轴承故障诊断中的性能,将算法运用于风机的滚动轴承故障诊断实验中。实验数据采集于如图 6 所示的风机实验平台,加速度传感器型号为 PCB MA352A60,输出带宽为 5 Hz~60 kHz,灵敏度为 10 mV/g,测点在垂直方向。采集的信号通过传感器信号调节器(PCB ICO Model 480C02)放大后传输至信号记录仪(Scope Coder DL750)。转速恒定为 1 kr/min,采样频率为 50 kHz,采样时间为 10s,轴承的各项参数如表 3 所示。轴承的故障是人为通过线切割技术分别在轴承内圈、外圈、滚动体上加工出 0.25 mm×0.3 mm(宽×深)的微小伤痕,如图 7 所示。



图 6 滚动轴承故障诊断实验平台

Fig. 6 Experimental platform of roller bearing fault diagnosis

表 3 轴承参数

Tab. 3 Parameter of bearing mm

参数	数值
轴承外径	52
轴承内径	25
轴承宽度	15
外圈缺陷	0.25×0.3
内圈缺陷	0.25×0.3
滚动体缺陷	0.25×0.3



图 7 滚动轴承故障类型

Fig. 7 The type of bearing fault

笔者将故障原始信号用于测试,选取每种数据的前 450 000 个数据点作为实验数据,数据波形如图 8 所示。对数据作归一化,将每种状态数据分为 150 个样本,每个样本 3 000 个数据点,共 600 组数据,各种状态取 100 组作为训练数据,50 组作为测试数据,即共有 400 个训练数据,200 个测试数据。诊断流程如图 9 所示。

3.3 算法性能分析

为了更好地说明稀疏和近邻保持深度极限学习机算法的诊断性能,笔者将其与单层 ELM、普通 DELM、堆叠降噪自编码网络 SAE 以及卷积神经网络 CNN 等方法进行了对比,在上述实验数据上验证各个算法性能。验证采用的计算机配置为 intel 酷睿 i5-7400 3.00 GHz,8G 内存。算法在 Matlab 2016a 上运行。

目前关于深层网络的参数设定没有系统性的方法来确定,大多通过经验采取交叉验证来获取最优

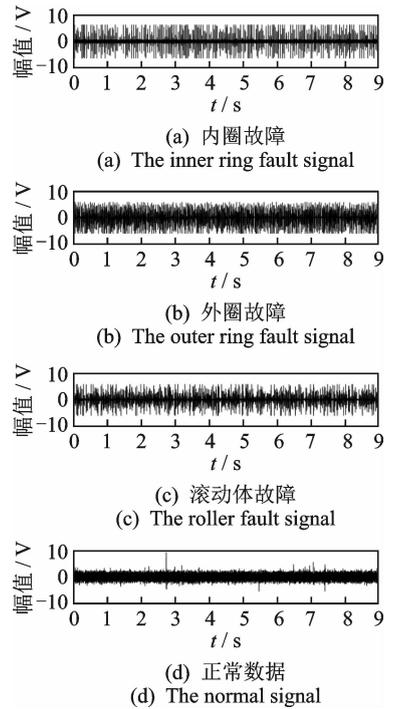


图 8 数据波形图

Fig. 8 Raw waveforms

参数,笔者采用 n-fold 交叉验证方法。本研究的 SNP-DELM 采用 5 层网络结构,具体维数为 3 000-1 500-500-100-4(4 为标签矩阵的维度),激活函数采用 sigmoid 函数,隐含层参数为: $\alpha=0.6, \gamma=0.4, \lambda=10^{-5}, C=10^{-8}, k=15$ 。普通深层 DELM 隐藏层参数也设置为 3 000-1 500-500-100-4,激活函数为 sigmoid 函数,DELM 的 C 设置为 10^{-8} 。单层 ELM 网络结构设定为 3 000-100-4,C 设定为 10^{-8} 。SAE 的网络维数也为 3 000-1 500-500-100-4,激活函数为 sigmoid 函数,学习率为 0.5,批次为 20,迭代次数为 100,分类器为 softmax。CNN 第 1 个卷积层共有 7 个 11×11 卷积核,第 1 个池化层池化核为 5×5 ;第 2 个卷积层共有 18 个 5×5 卷积核,第 2 个池化层池化核为 2×2 ,学习率为 0.5,批次为 20,迭代次数为 100,分类器为 softmax。为减少随机初始权值对分类效果的影响,共作 10 次测试,诊断结果如表 4 所示,其准确率如图 10 所示,所提出算法 10 次运算结果混淆矩阵如图 11 所示。

从表 4 可以看出,4 种深层网络相比于单层网络,正确率都有较大的提升。其中,相比于 ELM 和 DELM,所提出的 SNP-DELM 虽然训练时间较长,但是准确率较高。相比于 DELM,ELM 算法 94.25%和 53%的准确率,SNP-DELM 能够达到 98.2%的准确率,说明通过保持数据的近邻与稀疏结构能够提高算法的降维性能及诊断正确率。同

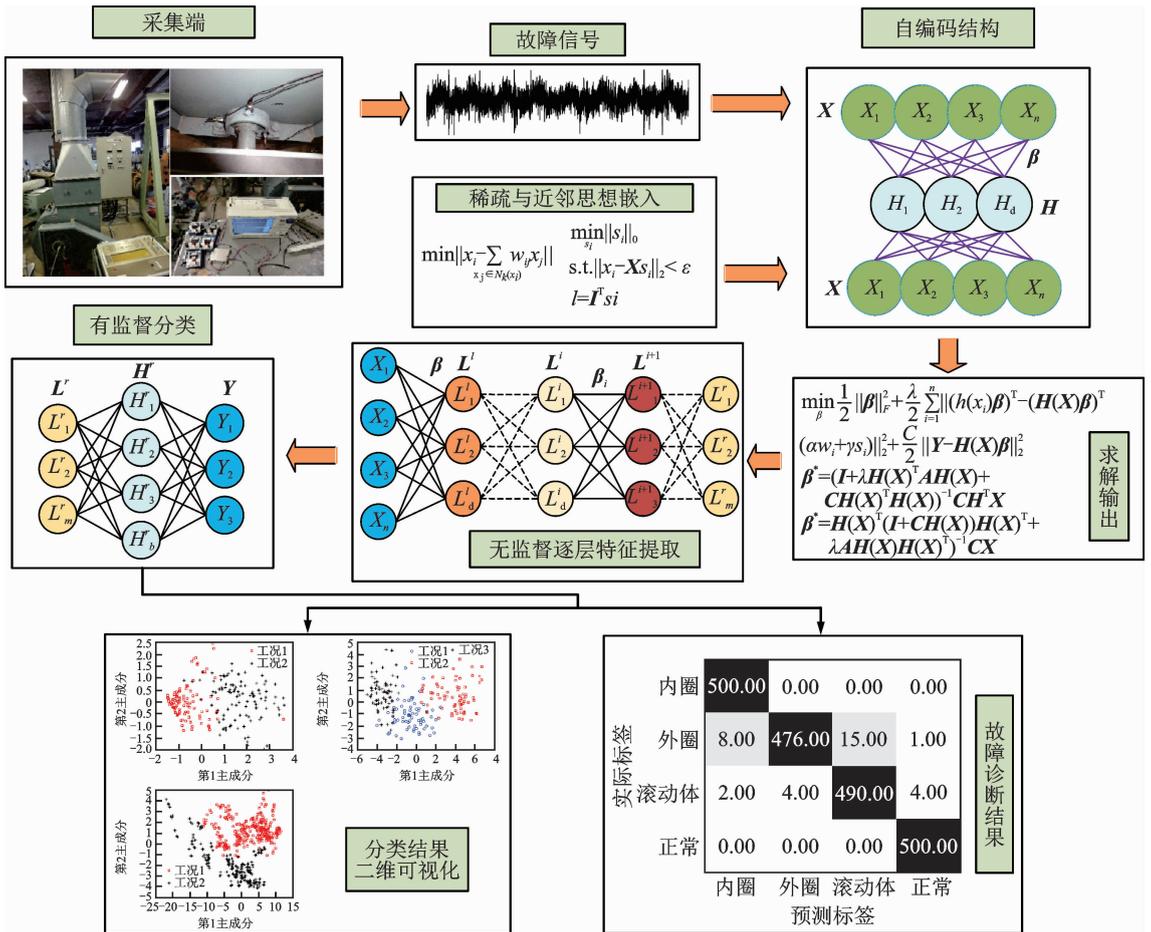


Fig. 9 Diagnostic flowchart

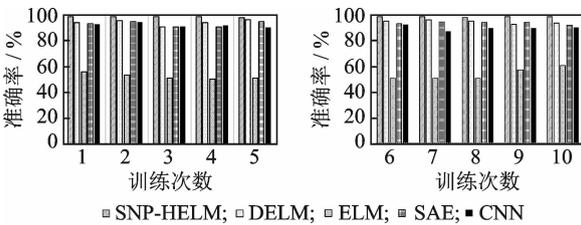


Fig. 10 Accuracy rate histogram

内圈	500.00	0.00	0.00	0.00
外圈	8.00	476.00	15.00	1.00
滚动体	2.00	4.00	490.00	4.00
正常	0.00	0.00	0.00	500.00
	内圈	外圈	滚动体	正常
	预测标签			

图 11 分类结果混淆矩阵

Fig. 11 Confusion matrix of the diagnosis results

内圈	500.00	0.00	0.00	0.00
外圈	8.00	476.00	15.00	1.00
滚动体	2.00	4.00	490.00	4.00
正常	0.00	0.00	0.00	500.00
	内圈	外圈	滚动体	正常
	预测标签			

故障诊断结果

表 4 轴承实验诊断结果

Tab. 4 Bearing diagnosis results of different methods

数据集	平均准确 率/%	准确率标 准差/%	训练 时间/s
ELM	53.00	3.605 6	0.049 9
SAE	93.20	1.456 8	591.250 2
CNN	90.85	2.028 3	457.512 0
DELM	94.25	1.602 9	11.568 8
SNP-DELM	98.20	0.586 9	25.619 3

4 结 论

时,与其他 2 种深度学习 SAE 和 CNN 相比较,所提出方法也有一定的准确率提升,并且训练时间更短。

1) 提出一种新的深层极限学习机结构,通过采用自编码将输入作为输出,产生深层网络的结构,无

监督逐层进行特征提取,最后通过经典极限学习机进行分类。

2) 将稀疏与近邻思想融入深层极限学习机中,通过优化求解模型使得在逐层特征提取过程中能够保持数据的空间流形结构,以此改善深层极限学习机的降维性能,提高了算法诊断正确率。

3) 将提出的方法分别用于风机轴承故障诊断以及3组UCI数据集的分类,并与单层ELM、普通DELIM、堆叠降噪自编码网络SAE及卷积神经网络CNN等方法进行对比,结果表明,所提出的方法相对于其他几种方法具有更高的准确率和稳定性。

参 考 文 献

- [1] CUI L L, GONG X Y, ZHANG J Y, et al. Double-dictionary matching pursuit for fault extent evaluation of rolling bearing based on the Lempel-Ziv complexity [J]. *Journal of Sound and Vibration*, 2016, 385: 372-388.
- [2] ZHU X T, XIONG J B. Fault diagnosis of rotation machinery based on support vector machine optimized by quantum genetic algorithm [J]. *IEEE Access*, 2018, 6: 33583-33588.
- [3] 冯辅周, 司爱威, 饶国强, 等. 基于小波相关排列熵的轴承早期故障诊断技术 [J]. *机械工程学报*, 2012, 48(13): 73-79.
FENG Fuzhou, SI Aiwei, RAO Guoqiang, et al. Early fault diagnosis technology for bearing based on wavelet correlation permutation entropy [J]. *Journal of Mechanical Engineering*, 2012, 48(13): 73-79. (in Chinese)
- [4] 王元章, 吴春华, 周笛青, 等. 基于BP神经网络的光伏阵列故障诊断研究 [J]. *电力系统保护与控制*, 2013, 41(16): 108-114.
WANG Yuanzhang, WU Chunhua, ZHOU Diqing, et al. A survey of fault diagnosis for PV array based on BP neural network [J]. *Power System Protection and Control*, 2013, 41(16): 108-114. (in Chinese)
- [5] 石志标, 葛春雪. 基于CS-BBO优化SVM的汽轮机转子故障诊断 [J]. *振动、测试与诊断*, 2018, 38(3): 619-626.
SHI Zhibiao, GE Chunxue. Fault diagnosis for steam turbine rotor by using support vector machine based on CS-BBO optimization [J]. *Journal of Vibration, Measurement & Diagnosis*, 2018, 38(3): 619-626. (in Chinese)
- [6] HUANG G B, ZHOU H, DING X, et al. Extreme learning machine for regression and multiclass classification [J]. *IEEE Transactions on Systems, Man and Cybernetics*, 2012, 42(2): 513-529.
- [7] HUANG G, SONG S, JATINDER N D, et al. Semi-supervised and unsupervised extreme learning machines [J]. *IEEE Transactions on Cybernetics*, 2014, 44(12): 2405-2417.
- [8] 苑津莎, 张利伟, 王瑜, 等. 基于极限学习机的变压器故障诊断方法研究 [J]. *电测与仪表*, 2013, 50(12): 21-26.
YUAN Jinsha, ZHANG Liwei, WANG Yu, et al. Study of transformers fault diagnosis based on extreme learning machine [J]. *Electrical Measurement & Instrumentation*, 2013, 50(12): 21-26. (in Chinese)
- [9] 尹刚, 张英堂, 李志宁, 等. 运用在线贯序极限学习机的故障诊断方法 [J]. *振动、测试与诊断*, 2013, 33(2): 325-329.
YIN Gang, ZHANG Yingtang, LI Zhining, et al. Fault diagnosis based on online sequential extreme learning machine [J]. *Journal of Vibration, Measurement & Diagnosis*, 2013, 33(2): 325-329. (in Chinese)
- [10] HINTON G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [11] 汤芳, 刘义伦, 龙慧. 稀疏自编码深度神经网络及其在滚动轴承故障诊断中的应用 [J]. *机械科学与技术*, 2018, 37(3): 352-357.
TANG Fang, LIU Yilun, LONG Hui. Deep neural network of sparse auto-encoder and its applications in rolling bearing fault diagnosis [J]. *Mechanical Science and Technology for Aerospace Engineering*, 2018, 37(3): 352-357. (in Chinese)
- [12] 王丽华, 谢阳阳, 张永宏, 等. 采用深度学习的异步电机故障诊断方法 [J]. *西安交通大学学报*, 2017, 51(10): 128-134.
WANG Lihua, XIE Yangyang, ZHANG Yonghong, et al. A fault diagnosis method for asynchronous motor using deep learning [J]. *Journal of Xi'an Jiaotong University*, 2017, 51(10): 128-134. (in Chinese)
- [13] TANG J, DENG C, HUANG G B. Extreme learning machine for multilayer perceptron [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(4): 809-821.
- [14] QIAO L S, CHEN S C, TAN X Y. Sparsity preserving projections with application to face recognition [J]. *Pattern Recognition*, 2010, 43(1): 331-341.
- [15] HE X F, CAI D, YAN S, et al. Neighborhood preserving embedding [C] // *Proceedings of the International Conference on Computer Vision*. Beijing, China: IEEE, 2005: 1-6.



第一作者简介:李可,男,1978年1月生,博士、教授。主要研究方向为故障诊断与振动分析、智能控制技术等。曾发表《Intelligent method for diagnosing structural faults of rotating machinery using ant colony optimization》《Sensors》2011, Vol. 11, No. 4)等论文。
E-mail: like@jiangnan.edu.cn

