

基于深度置信网络的旋转机械在线故障诊断

郭俊杰^{1,2}, 郭正红³

1. 张家口职业技术学院 机电工程学院, 河北 张家口 075000;
2. 齐齐哈尔大学 机械工程学院, 黑龙江 齐齐哈尔 161006;
3. 河北北方学院 信息科学与工程学院, 河北 张家口 075000)

摘要: 针对现有旋转机械在线故障诊断算法所存在的数据遍历耗时长, 检测准确率低, 故障分类准确率低等不足, 提出一种基于深度置信网络的故障诊断算法; 先基于受限的玻尔兹曼机搭建深度置信网络框架, 利用数据标签在输入层和后端的受限玻尔兹曼机之间建立联系; 然后利用 k-means 算法压缩聚类处理数据集降低数据集的规模和复杂度; 最后在不同故障特征的分类诊断方面, 引入加入核函数的 SVM 分类算法, 提升对不同机械故障类型的分类精度; 实验结果显示, 提出的旋转机械故障在线诊断方案的迭代效率高, 数据遍历耗时少, 训练集和测试集 F_1 指标的分别为 97.9% 和 97.4%, 优于传统故障诊断算法。

关键词: 深度置信网络; 改进 k-means 算法; 受限的玻尔兹曼机; 核函数; SVM

On-line Fault Diagnosis of Rotating Machinery Based on Deep Confidence Network

GUO Junjie^{1,2}, GUO Zhenghong³

1. Department of Mechanical and Electrical Engineering, Zhangjiakou Vocational and Technical College, Zhangjiakou 075000, China;
2. School of Mechanical Engineering, Qiqihar University, Qiqihar 161006, China;
3. School of Information Science and Engineering, Hebei North University, Zhangjiakou 075000, China)

Abstract: Aiming at the shortcomings of existing online fault diagnosis algorithms for rotating machinery, such as long data traversal time, low detection accuracy, and low fault classification accuracy, a fault diagnosis algorithm based on deep confidence network is proposed. Firstly, the deep confidence network framework is built based on the constrained Boltzmann machine, and the connection between the input layer and the back end of the constrained Boltzmann machine is established by using data labels. Then, k-means algorithm is used to compress cluster processing data set to reduce the size and complexity of data set. Finally, in the classification and diagnosis of different fault characteristics, support vector machine (SVM) classification algorithm with kernel function is introduced to improve the classification accuracy of different mechanical fault types. Experimental results show that the proposed on-line diagnosis scheme for rotating machinery faults has the advantages of high iteration efficiency and less time consuming for data traversal. The F_1 indexes of training set and test set are 97.9% and 97.4%, respectively, and are superior to those of traditional fault diagnosis algorithms.

Keywords: deep confidence network; improved k-means algorithm; limited Boltzmann machine; kernel function; SVM

0 引言

旋转机械泛指通过旋转动作完成特定功能或实现能量转换的机械部件或机械设备^[1-2], 滚动轴承、机床主轴、齿轮箱、涡轮机、气轮机、电动机、压缩机、风机等都是典型的旋转机械。旋转机械在机械加工与制造领

域、能源领域、汽车领域、航空领域、电力领域等有着十分广泛的用途。随着科技的不断发展和进步, 用户对旋转机械的体积、精度、耐疲劳性等性能有着越来越高的要求, 因此旋转机械的设计、加工和制造也朝着高速化^[3]、智能化和复杂化的方向发展^[4]。在一条精密生产线或复杂的智能体中, 旋转机械通常是核心的部件或核

收稿日期: 2024-09-06; 修回日期: 2024-10-11。

作者简介: 郭俊杰(1981-), 女, 大学本科, 副教授。

郭正红(1977-), 女, 大学本科, 副教授。

引用格式: 郭俊杰, 郭正红. 基于深度置信网络的旋转机械在线故障诊断[J]. 计算机测量与控制, 2025, 33(1): 60-68.

心的设备, 如果旋转机械出现故障或存在故障隐患, 其结果是容易引发整个加工系统的非正常停机, 不仅给用户带来巨大的经济损失, 更重要的是设备异常停机可能给一线的操作者带来危险。可见旋转机械实施在线故障监控和诊断十分必要^[5], 通过在线自动化采集和监测旋转机械的工作状态数据^[6], 就能够判断旋转机械的工作状态并相对准确地评估设备的剩余使用寿命。

现阶段的旋转机械设计制造复杂度较高, 多采用组合式或嵌入式结构设计, 所采集到的旋转机械振动信号包含大量的系统噪声、环境噪声^[7], 而且用于旋转机械故障诊断的数据集规模较大, 这都给旋转机械故障的在线诊断带来一定难度。文献 [8] 提出一种基于经过改进的短时傅里叶变换的故障特征提取与诊断方法, 通过引入时频变换的窗函数, 计算出不同时刻的信号功率谱, 进而提取故障信号特征并实现对故障点的捕捉和在线诊断, 改善了传统傅里叶变换算法的补助。但经过改进的短期傅里叶变换在窗函数转换中损失了一定的时间分辨率, 从而降低了对关节特征的提取和诊断精度; 文献 [9] 提出一种经过优化的支持向量机的故障分类诊断方法, 支持向量机是模式识别和监督学习领域的一种经典机器学习方法, 通过调整超平面的方位来提升分类算法的泛化学习能力, 适用于高维非线性的故障样本在线检测。但支持向量机对样本的容量变化敏感, 随着样本规模增大或样本容量的提升, 其故障诊断精度会同步降低; 神经网络算法是近年来在故障检测领域应用较为广泛的检测方案, 文献 [10] 提出一种基于 ANN (Artificial Neural Network, 人工神经网络) 的旋转机械故障在线诊断算法, ANN 算法的优势是学习能力和数据训练能力均较强, 同时通过合理优化隐含层的数量和参数组合, 降低模型的资源占用和开销, ANN 模型还有较为强大的非线性数据处理能力和并行计算能力, 可以有效应对较为复杂的故障集。但经过改进的 ANN 算法作为一种前馈型神经网络模型, 其核心参数优选的难度仍然较大, 隐含层的数据计算与训练容易陷入局部最优解, 进而会影响到模型对故障点定位和故障类型分类判断的准确性。

深度神经网络是机器学习和人工智能发展的高级阶段^[11-12], 本文在经典深度神经网络模型中引入了玻尔兹曼机, 并以玻尔兹曼机为基础构建了一种深度置信网络模型。深度置信网络模型由可视层和多个隐含层组成, 其中隐含层和隐含层之间相互连接, 最后一个隐含层与可视层连接, 输出最终的分类诊断结果。深度置信网络模型的结构设计更加完整, 数据的训练能力较强, 但深度置信网络存在一定的过拟合情况, 会影响到模型的预测和诊断精度, 尤其在无监督的环境下由于数据规模较大或数据样本较多, 会进一步影响到模型性能的发挥。

针对于旋转机械而言, 原始故障集中包含大量的重复数据, 为此本文在深度置信网络框架下将 k-means (k 均值聚类算法) 与深度置信网络相融合, 利用 k-means 算法处理待提取特征的故障集, 通过 k 均值聚类分配样本降低数据集的复杂度同时提升深度置信网络特征提取的效率和精度。

1 旋转机械故障集的降噪预处理

基于传感器采集到的旋转机械振动信号, 由受到系统噪声、环境噪声影响往往拥有较低的信噪比^[13-14], 一些有价值的信号会被湮没在噪声之中, 在分析处理故障数据集前需要对采集到的故障信号做降噪预处理, 以提升信号的可用性。通常情况下旋转机械振动信号频谱包括 2 000 Hz 以下低频部分和 2 000~6 000 Hz 的高频部分, 高频部分包含较多的信息且高频部分的特征提取难度较小。在旋转机械故障信号采集、降噪和预处理环节, 本文选用了小波包算法, 具体处理流程如图 1 所示。




图 1 原始信号的处理流程

如果在 t 时刻的原始信号为 $s(t)$, 其由两部分构成即有用的振动信号和噪声:

$$s(t) = x(t) + n(t) \quad (1)$$

式中, $x(t)$ 为剔除噪声的纯信号, $n(t)$ 为噪声信号。小波基函数信号分解的基本原理是, 将信号分解成为多个不同频率的小波基函数的组合, 小波基函数具有良好的局部性质, 并将原始信号分解成多个不同频率的子信号, 同时保留原始信号的特征。基于小波包做信号分解先选取适合的小波函数并计算小波系数, 阈值的选取与小波系数相关, 可以根据信号特征和频率范围选择阈值化处理的方式, 通过小波变换降低噪声并通过小波逆变换重构信号, 得到最终的纯净高频信号^[15]。根据旋转机械工作中的振动特点, 本文选择了 Morlet 函数 $\varphi(t)$ 作为小波基函数:

$$\varphi(t) = \exp(f_c t) \exp\left(-\frac{t^2}{2}\right) \quad (2)$$

式中, f_c 表示信号的中心频率^[16]。基于小波基函数对原始信号 $s(t)$ 进行分解, 最大分解层数 J 的分解过程如下:

$$J = \left\{ \max \left| J < \log_2 \left(\frac{1}{4} \cdot \frac{f_1}{f_2} \right) \right. \right\} \quad (3)$$

式中, \max 表示最大值函数, 当满足条件 $J < \log_2 \left(\frac{1}{4} \cdot \frac{f_1}{f_2} \right)$ 时分解层数 J 达到最大值, f_1 和 f_2 分别为采

样信号频率和故障信号频率，根据信号的频率、强弱、数据集规模和与阈值范围将原始信号分解为低频信号和 高频信号，根据最大分解层数进行 J 次分解。阈值化的过程中选择软阈值函数对采集到的数据集做阈值化处理，软阈值在 $[-\lambda, \lambda]$ 具有良好的连续性，有助于产生更好的吉布斯信号降噪效应，基于软阈值函数 $\eta(\omega)$ 表示如下：

$$\eta(\omega) = \begin{cases} \text{sgn}(\omega) \cdot (|\omega| - \lambda), & |\omega| \geq \lambda \\ 0, & |\omega| < \lambda \end{cases} \quad (4)$$

式中， ω 表示小波系数，最后将提出低频噪声信号的信号重组形成一组高频信号，即为剔除噪声的纯净信号。

2 深度置信网络模型的构建与优化

2.1 深度置信网络模型构建

深度置信网络是一种特殊的深度神经网络，由多个受限的玻尔兹曼机堆叠而成，受限的玻尔兹曼机可以视为一种由隐含层和可视层构成的一种小型神经网络，无论是隐含层还是可视层，其神经元节点都相互独立，不同层之间的神经元按照不同权重比例相互连接，受限的玻尔兹曼机结构，如图 2 所示。




图 2 受限的玻尔兹曼机结构

无论是隐含层还是可视层，其本层内的节点互不相连，而与对应临近层的节点相互连接，隐含层和可视层之间的节点连接权重矩阵为 W_{ij} (h_i 和 v_j 分别对应隐含层和可视层的任一节点)， i 和 j 对应的偏置系数分别为 b_i 和 c_j ，计算受限玻尔兹曼机当前时刻的能量 E ：

$$E(h_i, v_j, \omega, b_i, c_j) = - \sum_{i=1}^n h_i b_i - \sum_{j=1}^n v_j c_j - \sum_{i=1}^n \sum_{j=1}^n W_{ij} v_j h_i \quad (5)$$

利用受限的玻尔兹曼机内部节点能量分布情况，得出可视层和隐含层节点的权重联合分布概率：

$$p(h_i, v_j, \omega, b_i, c_j) = \frac{e^{-E(h_i, v_j, \omega, b_i, c_j)}}{\sum_{i=1}^n \sum_{j=1}^n e^{-E(h_i, v_j, \omega, b_i, c_j)}} \quad (6)$$

受限的玻尔兹曼机也是一种小型的神经网络，为此

选择 sigmoid 函数作为神经网络模型的激活函数^[17-18]，在公式 (6) 的概率下，受限的玻尔兹曼机隐含层和可视层中节点被激活的概率 p_v 和 p_h 如下：

$$\begin{cases} p_h = \text{sigmoid}(\sum_{i=1}^n W_{ij} h_i + b_i) \\ p_v = \text{sigmoid}(\sum_{i=1}^n W_{ij} v_i + c_i) \end{cases} \quad (7)$$

2.2 深度置信网络结构优化

深度置信网络由若干个受限的玻尔兹曼机堆叠而成，模型数量取决于输入集的规模，则一个包含 m 个受限玻尔兹曼机的深度置信网络模型，如图 3 所示。




图 3 深度置信网络模型结构图

由于深度置信网络的结构更加复杂，但层数不断增加时隐含层与输入层之间的联系紧密程度降低，表现在样本训练时出现特征提取失真的情况，为此对深度置信网络的结构进行优化，并对输入样本设定标签，通过样本标签使输入层与每个受限的玻尔兹曼机都能建立对应的联系，这样做的优势是即使深度置信网络的结构较为复杂，也可以通过样本标签使当前隐含层和输入层之间的建立联系，改进后的优化结果，如图 4 所示。




图 4 改进后增加标签样本的深度置信网络

通过神经网络模型结构上的优化，使输入层和远端的受限玻尔兹曼机之间的联系更加紧密，有助于提升模型的训练能力和数据处理能力。但对于旋转机械而言产生的故障数据集规模过大，而且数据集中存在大量充分冗余的故障数据^[19-20]，如果将这些数据全都输入到深度置信网络之中，仍旧会给模型带来巨大的计算压力。为此本文在模型的输入层对深度置信网络

进行第二次优化, 即利用 k-means 聚类算法处理输入层的数据, 进步缩小输入模型数据集的规模, 降低数据训练的压力。

2.3 深度置信网络输入集优化

通过数据聚类的方法将传感器采集并预处理的旋转机械的故障数据集进行二次聚类处理, 相同类别或相近类别数据在聚类后可降低复杂并去除冗余项, 每一个被聚合类别中的个体元素包含了相同或相近的特征, 而不同的聚合类之间的特性差别较大。聚类的过程相当于一个粗分类的过程。当数据集的规模较大时, 其训练和去冗余的难度更大, 由多个受限的玻尔兹曼机构成的深度置信网络结构本就较为复杂, 如果数据集的规模较大即使采用了样本标签标定的方式, 其故障识别的精度同样会降低, 且数据训练的代价增大。数据聚类过程先将具有显著同类个性的数据归类, 对数据大类的分析难度低于对每个个体数据的分析难度。聚类分析可以在有监督的环境性进行, 也可以在无监督的环境下进行, 本文选择 k-means 聚类算法能够无监督学习的环境性对数据集进行迭代训练和聚类处理, 因此具有较强的泛化学习能力。k-means 聚类算法是一种基于距离度量样本关系的聚类算法, 在聚类的初始阶段先随机选择 q 个数据作为初始的多个簇的中心, 分别计算中心数据点到其周围临近数据点的欧式距离, 在分簇时坚持距离最短原则能够使一簇内的数据尽量聚集。若 $x(t)$ 表示簇内一个随机的数据, 该簇的数据中心为 $C(t)$, 此时通过欧式距离的计算, 求解样本均方误差和 μ :

$$\mu = \sum_{i=1}^N \sum_{k=1}^q (x(t) - C(t))^2 \quad (8)$$

对于每个簇而言通过其中任一数据点到中心的距离, 判断其是否能够被归入其他的簇。当稳定低形成了 q 个簇以后, 设定最大迭代次数和一个科学合理的收敛阈值, 通过不断地迭代形成新簇直达到全局的最优解。k-means 聚类算法在聚类效率方面有待提升, 利用样本均方误差和 μ , 基于启发优化的视角来提升 k-means 聚类算法的效率。k-means 聚类算法能够根据实时测量的欧式距离划分数据簇, 但无法主动感知簇内的数据密度, 簇内数据密度也会对数据聚类, 并最终影响到利用深度置信网络进行数据的训练、特征提取和分类检测。引入一种数据密度感知算法, 用于识别簇内的数据密度, 使启发式 k-means 聚类算法数据聚类的均衡度更好。设点 A 和点 B 为簇内的两个任意数据点, 两者之间的距离表示为 $d(A, B)$, 如果点 B 是距离点 A 第 χ 距离的一个点, 表示如下:

$$d_{\chi}(A) = d(A, B) \quad (9)$$

式中, $d_{\chi}(A)$ 对应的邻域空间表示为 $\zeta_{\chi}(A)$, 表示与

$d_{\chi}(A)$ 相关的且在第 χ 距离之内的所有的数据点。此时点 A 到点 B 的可达距离 $d_{\chi}(A)_{\max}$ 表示为:

$$d_{\chi}(A)_{\max} = \max\{A, B, \dots\} \quad (10)$$

在第 χ 距离之内, 点 A 到包括点 B 在内的所有点距离的最大值。那么在邻域空间 $\zeta_{\chi}(A)$ 范围内, 可达密度 $\rho_{\chi}(A)$ 表示如下:

$$\rho_{\chi}(A) = \frac{\zeta_{\chi}(A)}{\sum_{\chi} d_{\chi}(A)} \quad (11)$$

将可达密度值与最优的簇内数据密度阈值进行对比, 若 $\rho_{\chi}(A)$ 大于密度阈值证明点 B 位于该簇的概率较大, 反之若 $\rho_{\chi}(A)$ 小于密度阈值证明点 B 位于该簇的概率值较小, 大概率为离群点。利用可达密度值主动感知簇内数据密度情况, 并与启发式 k-means 聚类算法配合, 以达到更好的数据聚类的目的。利用启发式算法和可达密度值对比对经典的 k-means 聚类算法进行了 2 次改进, 提升了 k-means 聚类算法的聚类功能, 两次优化的基本流程如图 5 所示。

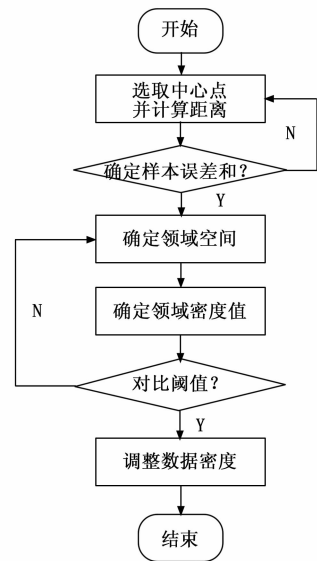


图 5 k-means 聚类算法的优化流程

先随机选取簇内位于中心区域位置的数据点作为样本中心, 通过计算样本点之间的欧式距离及样本均方误差和, 相对准确地将数据点划分为不同的簇。应用密度感知算法确定邻域空间和邻域密度值, 提升各个簇内数据的密度和均衡度, 以便于更好地剔除数据冗余及降低输入数据集的复杂度。

利用受限的玻尔兹曼机堆叠形成深度置信网络并通过样本标签进行网络结构上的优化, 强化输入层与后端隐含层的联系; 再通过 k-means 聚类算法压缩和整理输入集, 减轻深度置信网络的数据训练压力、特征输出和故障特征分类诊断的压力。

3 旋转机械在线故障诊断的实现

3.1 故障的在线诊断流程

以深度置信网络作为旋转机械故障数据集的训练器和分类器具体包括两个训练过程，第一个过程，在无监督的环境下利用受限玻尔兹曼机对数据集进行训练；第二个过程在半监督或有监督的环境下，优化模型的参数集以提升最终训练能力和分类能力。训练中根据单个的受限玻尔兹曼机可视层和隐含层节点被激活的概率 p_o 和 p_n ，判断进入数据集概率是否为最大值，通过结果比较输出为最大值时证明被激活，当输出值不是最大值时表明未被激活。第一个无监督过程的步骤如下：

1) 根据 k-means 聚类算法处理后的数据集规模确定深度置信网络受限玻尔兹曼机的数量，同时选择对应的数据标签。

2) 确定受限玻尔兹曼机隐含层和可视层的节点数量及权重矩阵。

3) 初始化模型的参数包括 $h_i, v_j, \omega, b_i, c_j$ ，并输入待训练的样本集合。利用公式 (6) 计算可视层和隐含层节点的权重联合分布概率。

4) 开始迭代训练，计算第 $i+1$ 和 $j+1$ 的节点被激活概率，如下：

$$\begin{cases} p_{h+1} = \text{sigmoid}(\sum_{i=1}^n W_{h+1,j+1} h_{i+1} + b_{h+1}) \\ p_{v+1} = \text{sigmoid}(\sum_{i=1}^n W_{h+1,j+1} v_{i+1} + c_{h+1}) \end{cases} \quad (12)$$

5) 更新受限玻尔兹曼机每个权重和偏置，是参数值始终处于最新的状态。

6) 重复 3) ~ 5) 的步骤，直到完成迭代实现第一环境的训练任务。

在半监督或有监督的环境下通过反向微调整，让参数值的组合更加合理，具体的过程如图 6 所示。

确定了受限的玻尔兹曼机数量后，深度置信网络的堆叠结构和规模即确定，先确定样本标签，并将数据集输入到模型之中，同步确定对应的权重参数 W_{ij} 、 b_i 和 c_i 。

3.2 旋转机械故障特征分类诊断的实现

在分类器的选择方面本文选择了泛化学习能力更强的智能 SVM (支持向量机) 模型，通过构成超平面的方式实现对不同类别旋转机械故障的分类。经过深度置信网络训练并同步提取故障特征的数据集是典型的非线性数据集，最终选择的智能 SVM 分类器需要具备样本升维功能，为此在 SVM 分类器的超平面构造时引入了具有升维功能的核函数 $K(x_l, x_H)$ ：

$$K(x_l, x_H) = \varphi(x_l)^T \varphi(x_H) \quad (13)$$

式中， x_l 和 x_H 表示待分类的两类故障特征， φ 表示核函

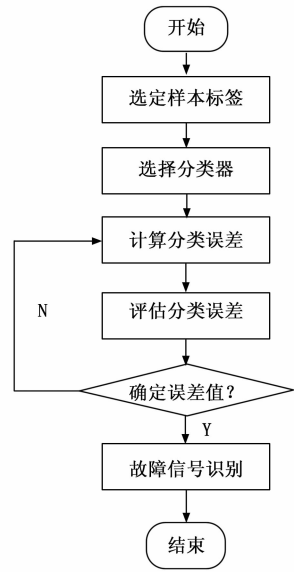


图 6 参数调整与分类的流程

数的升维映射关系，选择 RBF 径向基函数作为函数的升维映射：

$$K(x_l, x_H) = \exp\{-\gamma |x_l - x_H|^2\}, \gamma > 0 \quad (14)$$

在特征数据升维的过程中应用拉格朗日中值定理结合 RBF 径向基函数，得出最终的最优分类函数 $F(y)$ ：

$$F(y) = \text{sgn}[\omega^* \cdot y + b^*] = \text{sgn} \sum_{i=1} [a^* y_i \xi \tau K(x_l, x_H) + b^*] \quad (15)$$

式中， ω^* 和 b^* 分别表示智能 SVM 模型的分类超平面的最优斜率项和最优截距项， a^* 为得到的最优解， ξ 和 τ 分别为模型的松弛变量 (为一个大于 0 的自然数) 和惩罚因子 (取值范围为 $[0-1]$)，在经过融合核函数的超平面的分类后，可能还会存在个别的离群点，此时引入松弛变量提升升维的效率，而惩罚因子作为调整核函数的一种重要参数，通过降低惩罚因子的取值而提升分类器的性能。利用深度置信网络主要是提升对故障集的训练能力，到受限了数据集的规模和深度置信网络的特点，需要利用经过改进和优化的 k-means 聚类算法压缩输入数据集的规模，最后将深度置信网络输出的特征数据作为智能 SVM 模型的输入项，以便于更精确地区分旋转机械工作中产生不同的故障类型。

4 实验结果与分析

4.1 实验环境构造与数据集的采集

本文实验选择的旋转机械为机动车传动系统中的变速器齿轮箱，实验场所选择本市一所高校实验室的旋转机械实验台。齿轮箱故障在线诊断实验的硬件环境为：CPU intel core i7 12700 最高主频 4.9 GHz，RAM 16 GB，ROM 1 TB，软件操作系统选择 Windows10 专业版，编程语言为 JAVA。与深度网络算法相关的参数

设置, 如表 1 所示。

表 1 深度网络相关参数设定

序号	参数	参数值
1	隐含层数量	5
2	最大迭代次数	200
3	小波阈值范围	$[-5, 5]$
4	激活函数	Sigmoid 函数
5	ξ	2.6
6	τ	$[0, 1]$

齿轮箱的主要故障类型包括表面微裂纹、异常磨损、缺齿和轴偏心, 本文使用的齿轮箱包括上述 4 种故障类型, 采集的故障集中包含了训练集和测试值, 两者的比例为 5 : 1, 为提升故障检测难度, 齿轮箱的 4 种故障类型均为轻微故障, 也符合实际工作的真实场景, 采集完成的故障训练集和测试集的数据分布情况, 如表 2 所示。

表 2 故障集分布情况

序号	故障类型	训练集	测试集
1	表面微裂纹	370	74
2	异常磨损	525	105
3	缺齿	410	82
4	轴偏心	385	77
5	正常数据	8 310	1 662
合计	—	10 000	2 000

4.2 模型的迭代能力与工作效率测试

在实验中为了使测试结果更加直观且有可比性, 引入文献 [8], 文献 [9] 和文献 [10] 3 种传统的旋转机械故障在线诊断方法, 其中文献 [8] 中的故障信号时频变换参数, 文献 [9] 支持向量机参数和文献 [10] 神经网络算法的相关参数均与本文诊断算法相同, 确保各算法在最优参数环境下进行实验。

4.2.1 迭代效率与检测时间的对比

迭代效率是评价神经网络性能的重要指标之一, 先验证本文构建的深度置信网络模型的迭代效率, 引入文献 [10] ANN 神经网络模型参与对比, 对比结果如图 8 所示。之后再引入文献 [8]、文献 [9] 和文献 [10] 等 3 种传统的在线故障检测方法, 遍历训练集和故障集观测完成检测的总耗时, 对比结果如图 7 所示。

图 7 的训练集和测试集结果显示, 深度置信网络的迭代效率优势较为明显, 分别在在第 90 次和第 71 次完成的迭代, 这表明受限的玻尔兹曼机的数据训练能力要强于普通的神经元, 如果数据规模较大且能够较好地控制输入集的复杂度, 深度置信的网络的优势可以得到进一步发挥。通过消融实验验证深度网络各参数值的变化




图 7 检测算法的迭代性能

是否对算法的迭代性能产生影响, 小波阈值的取值选择 -3 和 2, 在 $[-5, 5]$ 区间范围内, τ 参数取值为 0.3 和 0.7, 在 $[0, 1]$ 区间范围内通过调整参数变化, 观测是否对迭代次数产生影响, 消融实验的过程如表 3 所示。

表 3 训练集消融实验

参数组合		迭代次数	
阈值范围	τ	深度置信	ANN
-3	0.3	91	145
2	0.3	95	148
-3	0.7	89	150
2	0.7	88	149

表 4 测试集消融实验

参数组合		迭代次数	
阈值范围	τ	深度置信	ANN
-3	0.3	70	115
2	0.3	68	110
-3	0.7	75	120
2	0.7	75	116

消融实验结果显示随着核心参数的调整和替代, 迭代次数的结果与实验结果相近, 并未出过大的波动, 证明了实验参数设置的合理性和稳定性。

4.2.2 完成对故障集和测试集诊断的时间

对齿轮箱训练集和故障集的故障在线诊断的时间对比, 如图 8 所示。

从各算法在训练集和测试集的故障诊断时间来看,




图 8 各检测算法的在线故障诊断时间对比

本文在深度置信网络框架下设计了基于改进 k-means 聚类算法的故障诊断时间最短, 分别为 207 s 和 51 s, 显著低于 3 种传统齿轮箱故障检测算法。

4.3 故障在线诊断的指标选择

本文选择齿轮箱故障诊断的指标有查准率 PR , 查全率 RF , 综合 PR 和 RF 的指标 F_1 , 及分类准确率 CA , 各指标的计算过程如下:

$$PR = \frac{TP}{TP + FP} \times 100\% \quad (16)$$

$$RF = \frac{TP}{TP + FN} \times 100\% \quad (17)$$

$$F_1 = \frac{2PR \cdot RF}{PR + RF} \quad (18)$$

$$CA = \frac{SCC}{TP + FP} \times 100\% \quad (19)$$

其中: TP 为被判定为正值的样本, 实际上也为正值; TN 为被判定为正值的样本, 实际上为负值; TP 是判定为正值, 实际上为负值的样本; FN 是实际上为负值被判定为正值的样本; SCC 为被正确分类的样本数量。分别选择齿轮箱的训练集和测试集作为实验对象并基于 4 种检测方法在所有样本中识别故障, 并实现对故障的精确分类。由于训练集的规模较大, 因此随机将训练集划分为 5 个子集便于故障的定位和检测。

4.4 故障诊断精度与分类诊断结果对比

4.4.1 查准率 PR 指标数据对比

分别基于本文算法和文献 [8]、文献 [9] 和文献 [10] 3 种传统算法对实验用齿轮箱的训练集和测试集进行检测实验, 结果如表 5 和表 6 所示。

本文算法下, PR 指标的训练集各子集均值为 98.8%, 测试集为 98.7%, 优于传统的 3 种故障检测算法。

表 5 训练集的 PR 指标数据对比

序号	样本数量	齿轮箱检测算法/%			
		本文算法	文献[8]	文献[9]	文献[10]
1	2 000	98.4	97.1	96.5	96.2
2	2 000	99.1	96.5	95.7	95.1
3	2 000	98.7	96.3	96.0	94.5
4	2 000	98.8	95.2	95.7	93.8
5	2 000	99.2	96.4	94.8	94.2
均值	2 000	98.8	96.3	95.7	94.8

表 6 测试集的 PR 指标数据对比

序号	样本数量	齿轮箱检测算法			
		本文算法	文献[8]	文献[9]	文献[10]
—	2 000	98.7	95.5	94.9	94.7

4.4.2 查全率 RF 指标数据对比

仍旧基于本文算法和文献 [8]、文献 [9] 和文献 [10] 3 种传统算法, 对实验用齿轮箱的训练集和测试集进行检测实验, RF 指标数据对比结果, 如表 7 和表 8 所示。

表 7 训练集的 RF 指标数据对比

序号	样本数量	齿轮箱检测算法			
		本文算法	文献[8]	文献[9]	文献[10]
1	2 000	97.2	92.5	92.8	93.2
2	2 000	96.3	92.3	92.7	93.1
3	2 000	96.1	93.1	90.9	92.4
4	2 000	97.5	93.2	91.2	90.8
5	2 000	97.4	92.0	92.5	90.5
均值	2 000	96.9	92.6	92.0	92.0

表 8 测试集的 RF 指标数据对比

序号	样本数量	齿轮箱检测算法			
		本文算法	文献[8]	文献[9]	文献[10]
—	2 000	96.2	92.0	91.5	91.7

在本文检测算法下, RF 指标的训练集各子集均值为 98.8%, 测试集为 98.7%, 同样优于传统的 3 种故障检测算法。

4.4.3 F_1 综合指标数据对比

F_1 指标是一种综合性评估指标, 能够平衡查准率和查全率评价指标, 降低数据遗漏产生的不良影响。综合 PR 指标和 RF 指标, 得出 F_1 综合指标对比数据, 如表 9 和表 10 所示。

表 9 训练集的 F_1 指标数据对比

序号	样本数量	齿轮箱检测算法			
		本文算法	文献[8]	文献[9]	文献[10]
1	2 000	97.8	94.7	94.6	94.7
2	2 000	97.7	94.4	94.2	94.1
3	2 000	97.4	94.7	93.4	93.4
4	2 000	98.1	94.2	93.4	92.3
5	2 000	98.3	94.1	93.6	92.3
均值	2 000	97.9	94.4	93.8	93.4

表 10 测试集的 F_1 指标数据对比

序号	样本数量	齿轮箱检测算法			
		本文算法	文献[8]	文献[9]	文献[10]
—	2 000	97.4	93.7	93.2	93.2

F_1 指标的训练集各子集均值为 97.9%, 测试集为 97.4%, 训练集和测试集相对于文献 [8]、文献 [9] 和文献 [10] 分别提升了 3.70%、4.37%、4.82, 和 3.95%、4.50% 和 4.50%, F_1 指标对于故障诊断精度的评估更加全面和科学。

4.4.4 分类准确率 CA 指标数据对比

最后, 验证各算法针对于表面微裂纹、异常磨损、缺齿和轴偏心等 4 种故障的分类准确率, 统计结果如表 11 和表 12 所示。

表 11 训练集的 CA 指标数据对比

序号	故障类型	齿轮箱检测算法/%			
		本文算法	文献[8]	文献[9]	文献[10]
1	表面微裂纹	99.2	97.1	96.2	93.7
2	异常磨损	99.1	98.0	95.3	95.8
3	齿轮缺齿	99.3	97.4	95.7	94.2
4	轴偏心	98.9	97.5	94.4	94.0
均值	—	99.1	97.5	95.4	94.4

表 12 测试集的 CA 指标数据对比

序号	故障类型	齿轮箱检测算法/%			
		本文算法	文献[8]	文献[9]	文献[10]
1	表面微裂纹	99.1	95.2	94.1	95.1
2	异常磨损	98.7	94.2	94.7	95.5
3	齿轮缺齿	98.9	95.1	95.0	94.8
4	轴偏心	99.0	95.4	95.2	94.9
均值	—	98.9	95.0	94.8	95.1

统计数据结果显示, 在训练集和测试集的 CA 指标对比方面, 本文提出检测算法也具有一定优势, 这主要是由于模型引入了非线性数据分类训练的 SVM 分类器, 而且引入了核函数, 从一定程度上提升了故障集中不同故障类别的分类精度。

4.4.5 消融实验

分析聚类过程中玻尔兹曼机数量选择对 CA 指标的影响, 玻尔兹曼机的数量分别选择为 2、3、4、5, 统计结果如表 13 所示。

表 13 玻尔兹曼机数量对 CA 指标的影响 %

玻尔兹曼机数量	表面微裂纹	异常磨损	齿轮缺齿	轴偏心
2	98.3	98.4	98.2	98.0
3	99.1	98.7	98.9	99.0
4	98.1	97.2	97.7	98.2
5	97.4	97.3	98.5	97.9

从测试的结果可知, 当玻尔兹曼机的数量选择为 3 时, CA 指标能够达到最优的状态, 本文算法下所选择的玻尔兹曼机数量为 3, 当玻尔兹曼机数量为 2、4、5 时 CA 指标会出现小幅度的降低, 由于模型训练能力不足或代价过大而导致。

4.5 损失函数对比

本文选择的损失函数为 MSE (Means Square Error) 函数, 用于在神经网络训练过程中实际值与期望值之间的差距, 在数据训练中各算法的损失函数曲线变化如图 9 所示。




图 9 MSE 损失函数值对比

MSE 值的统计结果显示, 本文检测算法下 MSE 值最低点高于 3 种传统算法, 证明本文监测的损失值小于其他监测算法。

5 结束语

旋转机械是工业和智能制造等领域应用极为广泛的关键零部件和关键设备, 对旋转机械实施在线故障诊断, 能够有效避免停机事故的发生。本文在深度置信网络框架下, 设计了一种基于改进 k-means 聚类算法的旋转机械在线故障诊断方案。先利用受限的玻尔兹曼机搭建深度置信网络框架, 同时利用样本设定的标签优化了网络结构; 在输入数据集的预处理方面利用 k-means 聚类算法剔除冗余, 及压缩数据集的复杂度; 最后利用带有核函数的 SVM 模型实现对不同类型故障数据的分类, 实验结果也证明了提出故障数据处理算法的有效性和适用性。深度神经网络是当下处理机械在线故障诊断问题的核心方法之一, 以深度置信网络为代表的深度神经网络具有强大的数据训练能力和特征提取能力, 但随着神经网络隐含层数量的增加和整体结构复杂度的增加, 参数选择难度增大并最终会影响到模型的性能。因此, 如何有效处理和压缩输入数据集, 及如何通过神经网络模型的优化和改进提升模型的效率, 将成为未来该研究领域的主要方向之一。

参考文献:

[1] 苏树智, 张茂岩, 方贤进, 等. 基于全局-局部欧拉弹性

- 判别投影的旋转机械故障诊断方法 [J]. 振动与冲击, 2023, 42 (11): 65-74.
- [2] 史红梅, 郑畅畅, 司瑾, 等. 基于动态加权的多尺度残差网络旋转机械故障诊断算法 [J]. 振动与冲击, 2022, 41 (23): 67-74.
- [3] 卢太武, 马洪波, 王先芝, 等. 时变工况下基于精细复合多尺度散度熵的旋转机械故障诊断方法 [J]. 振动与冲击, 2023, 42 (21): 211-218.
- [4] CHEN L, MA Y, WANG H, et al. A novel deep convolutional neural network and its application to fault diagnosis of the squirrel-cage asynchronous motor under noisy environment [J]. IOP Publishing Ltd, 2023.
- [5] 张志成. 面向无标签数据的旋转机械故障诊断方法研究 [J]. 吉林大学学报: 工学版, 2022, 52 (11): 2514-2522.
- [6] 周俊, 谢文松, 伍星, 等. 基于时频脊线提取与改进稀疏分量分析的 RV 减速器复合故障盲分离 [J]. 农业工程学报, 2023, 39 (22): 18-26.
- [7] 任海军, 韦冲, 谭志强, 等. 基于 CEEMDAN-IAWT 方法的滚动轴承振动信号降噪 [J]. 振动与冲击, 2023, 42 (13): 199-207.
- [8] 邓向武, 孙国玺, 梁松, 等. 基于同步提取变换的旋转机械振动信号时频分析 [J]. 机床与液压, 2022, 50 (7): 181-186.
- [9] 赵楠, 赵荣珍. 面向不平衡数据的云模型旋转机械故障识别方法 [J]. 振动与冲击, 2022, 41 (22): 70-77.
- [10] 姚家琪, 荆华, 赵春晖. 一种面向噪声环境中旋转机械故障诊断的多模态耦合输入神经网络 [J]. 控制与决策, 2023, 38 (7): 1918-1926.
- [11] 黄尧韦, 代平, 刘万张池. 基于 MAJDA 无监督迁移的旋转机械跨工况故障诊断 [J]. 组合机床与自动化加工技术, 2022 (10): 144-149.
- [12] 姚家琪, 荆华, 赵春晖. 一种面向噪声环境中旋转机械故障诊断的多模态耦合输入神经网络 [J]. 控制与决策, 2023, 38 (7): 1918-1926.
- [13] 任海军, 韦冲, 谭志强, 等. 基于 CEEMDAN-IAWT 方法的滚动轴承振动信号降噪 [J]. 振动与冲击, 2023, 42 (13): 199-207.
- [14] 张伟涛, 张东江, 纪晓凡, 等. 基于 CCA 和多通道循环维纳滤波的滚动轴承故障源分析 [J]. 振动与冲击, 2023, 42 (24): 317-325.
- [15] 王鼎, 尹洁昕, 郑娜娥, 等. 信号传播速度未知下基于运动单站到达频率的定位新方法 [J]. 电子学报, 2022, 50 (5): 1181-1191.
- [16] 姚佳旭, 夏春明, 章含阳, 等. 肌音信号的采样率与截止频率对识别率影响研究 [J]. 现代电子技术, 2022, 45 (17): 54-59.
- [17] 杜圣杰, 贾晓芬, 黄友锐, 等. 面向 CNN 模型图像分类任务的高效激活函数设计 [J]. 红外与激光工程, 2022, 54 (3): 17-18.
- [18] XU Z X Y. A novel adaptive and fast deep convolutional neural network for bearing fault diagnosis under different working conditions [J]. Proceedings of the Institution of Mechanical Engineers, Part D. Journal of Automobile Engineering, 2020, 23 (4): 115-131.
- [19] AMINI N, ZHU Q. Fault detection and diagnosis with a novel source-aware autoencoder and deep residual neural network [J]. Neurocomputing, 2022 (11): 483-488.
- [20] 何杏宇, 赵丹, 杨桂松, 等. 基于数据冗余控制的移动群智感知任务分配方法 [J]. 计算机应用研究, 2022, 39 (8): 2381-2387.
- [11] TAO F, QI Q. Make more digital twins [J]. Nature, 2019, 573 (7775): 490-491.
- [12] TAO F, SUI F, LIU A, et al. Digital twin-driven product design framework [J]. International Journal of Production Research, 2019, 57 (12): 3935-3953.
- [13] ZHUANG C, LIU J, XIONG H. Digital twin-based smart production management and control framework for the complex product assembly shop-floor [J]. The International Journal of Advanced Manufacturing Technology, 2018, 96 (4): 1149-1163.
- [14] 陶飞, 刘蔚然, 刘检华, 等. 数字孪生及其应用探索 [J]. 计算机集成制造系统, 2018, 24 (1): 1-18.
- [15] 崔玉福, 刘质佳, 王靖. 数字孪生卫星技术与工程实践 [J]. 航天器工程, 2021, 30 (6): 62-69.
- [16] MADNI A M, MADNI C C, LUCERO S D. Leveraging digital twin technology in model-based systems engineering [J]. Systems, 2019, 7 (1): 7-20.
- [17] QI Q, TAO F, ZUO Y, et al. Digital twin service towards smart manufacturing [J]. Procedia Cirp, 2018, 72 (1): 237-242.
- [18] LI C, MAHADEVAN S, LING Y, et al. Dynamic Bayesian-network for aircraft wing health monitoring digital twin [J]. AIAA Journal, 2017, 55 (3): 930-941.
- [19] 龚佩, 李天昀, 章昕亮, 等. 利用联合特征参数的卫星单一混信号调制识别 [J]. 系统工程与电子技术, 2023, 45 (2): 589-596.
- [20] ZHOU Y J, SHI Z. Design of SOC electric meter based on protocols DLMS/COSEM and DL/T [J]. Electrical Measurement & Instrumentation, 2011, 48 (4): 78-79.
- [21] SPANGELO S C, KASLOW D, DELP C, et al. Applying model based systems engineering (MBSE) to a standard CubeSat [C] //Montana: 2012 IEEE Aerospace Conference, 2012: 1-20.

(上接第 59 页)