DOI: 10.3901/JME.2019.07.058

基于萤火虫优化的核自动编码器在中介轴承故障诊断中的应用*

王奉涛 刘晓飞 敦泊森 邓 刚 韩清凯 李宏坤
(大连理工大学振动工程研究所 大连 116024)

摘要: 随着科技进步与工业规模的快速壮大, 现代工业监测领域步入大数据时代, 如何自动地从大规模原始信号中提取故障特征并诊断是一个重要课题。为了提高深度自动编码网络处理非线性问题的能力, 提出一种基于核函数与去噪自动编码器(Denosing auto-encoder, DAE)的深度神经网络方法。采用径向基核函数改进传统的去噪自动编码器, 提出核去噪自动编码器(Kernel denosing auto-encoder, KDAE); 构建包含一个 KDAE 层与多个 AE 层的深度神经网络对故障特征进行层层提取, 并添加 softmax 分类层; 采用误差反向传播算法对网络参数进行微调, 并采用混沌萤火虫算法优化核参数与深度网络中的待定参数, 得到故障诊断模型。针对传统自动编码器泛化性较差的问题, 在目标函数中添加 L2 惩罚项。通过航空发动机中介轴承典型故障试验数据, 验证了所提方法与传统去噪自动编码网络相比能够得到更高的准确率。

关键词: 中介轴承; 故障诊断; 深度学习; 高斯核函数; 自动编码器

中图分类号: TH113; TN911

Application of Kernel Auto-encoder Based on Firefly Optimization in Intershaft Bearing Fault Diagnosis

WANG Fengtao LIU Xiaofei DUN Bosen DENG Gang HAN Qingkai LI Hongkun
(Institute of Vibration Engineering, Dalian University of Technology, Dalian 116024)

Abstract: With the rapid development of scientific technological progress and industrial scale, modern industrial monitoring field has entered the era of big data. It is an important task to automatically extract fault features from large scale raw vibration data and make fault diagnosis. In order to further improve the ability of the deep auto-encoder network to deal with the nonlinear problem, a deep neural network method based on kernel function and denoising auto-encoder (DAE) is proposed. The traditional denoising auto-encoder is improved by radial basis kernel function, and the kernel denoising auto-encoder (KDAE) is proposed. A deep neural network consisting of one KDAE layer and multiple AE layers is constructed to extract the fault features, and the softmax classification layer is added as classifier layer. The error back propagation algorithm is used to fine-tune the network parameters, and chaos firefly algorithm is used to optimize the undetermined parameters of the kernel parameters, then the fault diagnosis model is obtained. In response to the problem of poor generalization of traditional auto-encoder, L2 penalty items are added to the target function. It is verified that the proposed method is more accurate than the traditional denoising auto-encoder network through the typical failure test data of aero-engine intermediate bearing.

Key words: intershaft bearing; fault diagnosis; deep learning; Gaussian kernel function; auto-encoder

0 前言

轴承作为旋转机械必不可少的零件之一, 其健康状态直接影响机械设备整体的运行^[1]。中介轴承作为双转子发动机的关键部件, 润滑条件不易保证,

动载荷大, 容易出现故障^[2], 准确地对中介轴承部件产生的损伤做出评估与诊断至关重要^[3]。

随着人工智能技术的快速发展, 机器学习方法在轴承故障诊断中得到了广泛应用。LEI 等^[4]采用 EMD 分解与 WTP 变换作为预处理手段, 采用径向基神经网络进行诊断。ZHANG 等^[5]采用 EEMD 分解原始信号, 采用基于簇间距离优化的 SVM 进行诊断。但是传统的神经网络方法为人工选择特征,

* 国家自然科学基金资助项目(51875075, 51375067)。20180521 收到初稿, 20181102 收到修改稿

面对大量数据时处理效率低下^[6]，并且得到广泛应用的 ANN 与 SVM 属于浅层结构的监督学习模型，对故障特征缺少足够的表征能力^[7]。

面对现代工业数据规模的急速增长，深度学习^[9]成为研究大数据的首选方法。JIA 等^[8]采用去噪自动编码器构建深度学习模型，选取原始信号的傅里叶系数作为输入，对滚动轴承和齿轮故障进行了诊断。SHAO 等^[9]将压缩自动编码器与降噪自动编码器结合，并采用局部保持投影算法取得了很好的效果。CHEN 等^[10]采用稀疏自动编码器对多个传感器数据的特征融合，并采用 DBN 网络进一步对滚动轴承进行故障诊断。但是当原始信号中包含大量的噪声与非线性成分，标准深度自动编码器模型无法直接应用于轴承的原始数据中。为了更充分地发掘自动编码器网络的特征学习和非线性问题处理能力，核方法被应用到自动编码器中。核函数通过采用非线性变换将输入数据映射到高维空间，并在高维空间中采用隐式计算方法避免了维数灾难问题。

本文提出一种基于核去噪自动编码器的深度神经网络，采用核去噪自动编码器对原始信号进行第一层特征提取，并堆叠多个自动编码器构成深度网络，提取深层次特征。由于模型的泛化性是检验一个算法有效的重要标准，本文在模型训练中对模型参数进行限制，在目标函数中添加 L2 惩罚项。针对核参数与模型的其他待定参数选择困难问题，对传统萤火虫算法进行混沌改进，并以此作为模型的优化算法，完成网络参数的寻优。最终得到模型参数优化的深度神经网络实现中介轴承的故障诊断。

1 去噪自动编码器

典型的自动编码器由编码网络和解码网络构成，包含三个神经元层，输入层、隐藏层和输出层。

(1) 编码过程：给定包含 D 个数据的训练样本集 $\mathbf{x} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_D\}$ ，编码过程为将输入矢量表示为隐藏层矢量集 $\mathbf{h} = \{\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_D\}$ ，编码过程可用公式表示为

$$\mathbf{h} = s_f(\mathbf{W}\mathbf{x} + \mathbf{b}) \quad (1)$$

$$s_f(t) = 1 / (1 + e^{-t}) \quad (2)$$

式中， s_f 为编码网络的激活函数， $\mathbf{W}$ 为 $m \times n$ 维的编码权值矩阵， $\mathbf{b}$ 为 m 维的编码偏置矢量。

(2) 解码过程：将隐藏层矢量集 $\mathbf{h}$ 反向变换为与输入数据维数相同的重构数据集 $\mathbf{z} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_D\}$ ，解

码过程可用公式表示如下

$$\mathbf{z} = s_f(\mathbf{W}'\mathbf{h} + \mathbf{b}') \quad (3)$$

式中， $\mathbf{W}'$ 为 $n \times m$ 维的解码权值矩阵； $\mathbf{b}'$ 为 n 维的解码偏置矢量。

(3) 激活函数：自动编码器通过优化参数集 $\theta = \{\mathbf{W}, \mathbf{b}, \mathbf{W}', \mathbf{b}'\}$ 来最小化重构误差，均方误差一般用作自动编码器的损失函数

$$J_{AE}(\theta) = \frac{1}{m} \sum_{i=1}^m L_{MSE}(x_i, z_i) = \frac{1}{m} \sum_{i=1}^m \left(\frac{1}{2} \|z_i - x_i\|^2 \right) \quad (4)$$

去噪自动编码器通过从损坏的数据集 $\tilde{\mathbf{x}}$ 中重构原始数据 $\mathbf{x}$ 。添加噪声后的编码过程变为

$$\tilde{\mathbf{h}} = s_f(\mathbf{W}\tilde{\mathbf{x}} + \mathbf{b}) \quad (5)$$

式中， $\tilde{\mathbf{x}}$ 是原始输入 $\mathbf{x}$ 加噪后的样本。

2 基于 KDAE 的深度神经网络

自动编码器的编码过程是一种非线性计算方式。为了更好地处理原始信号中的非线性与噪声成分，提出核去噪自动编码器。

2.1 核去噪自动编码器

核函数特征空间中的内积由 $K(\mathbf{x}, \mathbf{y})$ 给出。高斯径向基函数取值仅仅依赖于 $\mathbf{x}, \mathbf{y}$ 距离的实值函数，有较好的抗干扰能力。在去噪自动编码器的编码网络前添加核函数映射层，核函数映射层表示为

$$\mathbf{k} = \begin{bmatrix} K(\mathbf{x}, \mathbf{x}_1) \\ \vdots \\ K(\mathbf{x}, \mathbf{x}_n) \end{bmatrix} \quad (6)$$

在核函数映射层 $\mathbf{k}$ 中添加噪声，编码过程为

$$\tilde{\mathbf{h}} = s_f[\mathbf{W}\tilde{\mathbf{k}} + \mathbf{b}] \quad (7)$$

式中， $\tilde{\mathbf{k}}$ 是加噪后的核函数映射层。本文选用随机将数据中部分点置 0 的方法，达到部分特征缺失的目的，对应的随机映射关系可以表示为

$$\tilde{\mathbf{k}} \sim p(\tilde{\mathbf{k}}|\mathbf{k}) \quad (8)$$

解码过程表示为

$$\tilde{\mathbf{k}} = s_f(\mathbf{W}'\tilde{\mathbf{h}} + \mathbf{b}') \quad (9)$$

KDAE 通过添加核函数映射，将原始信号中不可分量转化到高维空间，有效地减小数据缺失，提高特征表达的鲁棒性。

2.2 基于 KDAE 的深度网络模型

为提取信号的深层次特征，采用多个自动编码器叠加。提出一种深度网络模型，即选择 KDAE 网络作为第一层，后接多个自动编码器逐层对特征进

行提取,构成堆叠核去噪自动编码器(Stacked KDAE, SKDAE)。为防止训练中出现过拟合,在后接的自动编码器中加入了 L2 范数正则项限制模型的学习能力。

在训练过程中,首先采用无监督的方式预训练,调整编码器与解码器参数使得重构误差最小;其次在输出层添加分类器,采用梯度下降法进行监督训练来优化参数,更新过程可以表示为

$$W \leftarrow W - \eta \cdot \frac{\partial L(x, z)}{\partial W} \quad (10)$$

$$b \leftarrow b - \eta \cdot \frac{\partial L(x, z)}{\partial b} \quad (11)$$

式中, η 为学习率。

2.3 混沌萤火虫参数优化

RBF 核函数虽然只有一个待定参数,但是其性能表现直接依赖于核参数的选择^[11],因此该参数选择也直接影响 SKDAE 深度网络的特征处理能力,提出混沌萤火虫算法进行参数优化。

萤火虫算法是 YANG^[12]提出的一种智能寻优算法,吸引度与步长因子是两个重要的参数。标准萤火虫算法由于以上参数均设定为定值,导致收敛速度慢,陷于局部极值的问题。为了改善以上问题,利用混沌算法对萤火虫进行优化改进。

(1) 初始位置混沌优化。

选用 Kent 混沌映射产生初始种群, Kent 种群在(0, 1)区间内具有更加优秀的遍历均匀性。其数学表达式为

$$x_{n+1} = \begin{cases} x_n / \beta & 0 < x_n \leq \beta \\ (1 - x_n) / (1 - \beta) & \beta < x_n < 1 \end{cases} \quad (12)$$

(2) 最大吸引度混沌优化。

最大吸引度 β_0 采用高斯混沌映射时,可以获得最好的结果,其高斯混沌表达式为

$$\beta_0(t+1) = \begin{cases} 0 & \beta_0(t) = 0 \\ 1 / \beta_0(t) \bmod(1) & \beta_0(t) \neq 0 \end{cases} \quad (13)$$

$$1 / \beta_0(t) \bmod(1) = \frac{1}{\beta_0(t)} - \left\lfloor \frac{1}{\beta_0(t)} \right\rfloor \quad (14)$$

(3) 步长因子自适应优化。

本文选用文献[13]的方法对 α 进行自适应优化

$$\alpha(t+1) = \left(\frac{1}{2k_{\max}} \right)^{1/k_{\max}} \alpha(t) \quad (15)$$

式中, $k_{\max}$ 表示最大的迭代次数。

2.4 基于混沌萤火虫的优化算法流程

采用混沌萤火虫优化 KDAE 模型具体步骤如图 1 所示,其中萤火虫算法流程图如图 2 所示。

图 1 KDAE 方法流程图

图 2 混沌萤火虫优化流程

- (1) 获取轴承原始振动信号, 并进行样本划分。
- (2) 初始化萤火虫参数, 包括: 种群规模 n , 迭代次数 N , 步长因子 α , 最大吸引度 β_0 , 光吸收系数 γ , 采用 Kent 混沌映射产生初始种群。
- (3) 以初始化的萤火虫参数训练基于 KDAE 的深度网络模型。

① 采用振动数据训练 KDAE, 并将其输出作为下一层 AE 的输入。

② 以无监督的方式层层训练 N 个 AE, 将每个 AE 的隐藏层作为下一个 AE 的输入, 直至最后一层。

③ 添加分类器输出层, 采用误差反向传播算法微调网络参数。

(4) 以分类的准确率作为萤火虫的目标, 得到每个萤火虫亮度并排序, 计算每个萤火虫的吸引度。

(5) 采用优化算法, 更新得到下一步更新的萤火虫位置。

(6) 检查是否到达最大的迭代次数, 当到达最大迭代次数时, 输出结果。

3 航空发动机中介轴承试验台验证

3.1 试验台描述

为了验证基于高斯核函数与深度自动编码网络对航空发动机中介轴承故障的诊断效果, 利用双转子中介轴承试验台模拟中介轴承的不同故障类型, 并采集振动信号进行分析, 试验台结构如图 3 所示。

图 3 试验台的装置示意图

1. 高压端电动机 2. 加速度传感器 3. 中介轴承
4. 低压端电动机 5. 高压轴 6. 低压轴

中介轴承安装在高压轴与低压轴连接处, 连接高压端电动机与低压端电动机, 其外环与高压端轴相连, 内环与低压端轴相连。选用四个加速度传感器分别安装在高、低压轴支撑轴承座上采集振动信号。硬件采集系统选用 NI9234 采集卡, 采样频率为 25.6 kHz。在试验过程中, 分别模拟高、低压电动机相对转动、高压电动机单转、低压电动机单转三种不同的工况, 高、低压电动机在转动过程中转速均为 20 Hz。选用正常轴承、内环故障、外环故障、滚动体故障四种不同的状态模拟中介轴承故障, 故障切槽采用电火花在轴承上进行加工, 如图 4 所示。

图 4 故障轴承示意图

正常轴承状态只在内外环同时相向转动的工况下, 其他三种状态分别在环转动、外环转动、内外环同时相向转动三种工况下进行试验, 共十种不同状态。试验在相同的条件下进行四次, 每次采集 10 s 的数据, 将每次采集数据分为 200 组, 每组 1 200 点, 随机选择其中的四分之三作为训练集, 剩下的四分之一作为测试集, 数据的详细介绍如表 1 所示。

表 1 中介轴承状态描述

中介轴承状态	训练样本/ 测试样本	标签
内环故障(内环转动)	150/50	1
内环故障(外环转动)	150/50	2
内环故障(内外环相向转动)	150/50	3
外环故障(内环转动)	150/50	4
外环故障(外环转动)	150/50	5
外环故障(内外环相向转动)	150/50	6
滚动体故障(内环转动)	150/50	7
滚动体故障(外环转动)	150/50	8
滚动体故障(内外环相向转动)	150/50	9
正常状态(内外环相向转动)	150/50	10

由于传感器安装位置距离中介轴承较远, 中介轴承信号在传递过程中会衰减并且会包含较多的噪声信息, 因此文中选用距离中介轴承最近的高压轴支撑座上竖直方向加速度传感器的振动数据作为试验处理信号。

3.2 试验结果分析

为了对比论证本方法的有效性, 选择添加 L2 惩罚项的堆叠去噪自动编码网络(L2-SDAE)、不添加 L2 惩罚项的堆叠核自动编码网络(SKAE)和传统浅层神经网络 BPNN 进行比较。除此之外, 选择采用核方法的诊断模型 SVM、核极限学习机(KELM)进行对比。4 次试验的对比结果如图 5 所示, 具体诊断准确率及平均准确率如表 2 所示, 采用所提出方法第 2 次试验的诊断结果混淆矩阵如图 6 所示。

图 5 四次诊断结果图

图 6 SKDAE 第二次试验混淆矩阵图

对比试验研究的重点可以总结如下。

(1) 试验方案采用中介轴承原始时域数据, 所有模型的信号输入均为原始未预处理的时域信号。

(2) 对于深度神经网络模型、SVM 与 KELM, 所有的输入数据点数均为 1 200。

(3) 对于浅层神经网络 BPNN, 采用两种输入方案, 方案一为 1 200 点原始数据, 方案二为采用 KPCA 约简原始数据后的特征作为输入。

(4) 对于 SVM、KELM、KPCA 的待定核参数均选择混沌萤火虫算法进行参数寻优。

由表 2 与图 5 可以得到, 采用 SKDAE 网络在四次的诊断结果分别为: 96%, 97.8%, 94.8% 及 95.2%, 平均准确率为 95.95%, 高于 L2-SDAE 深度网络模型的 70.9%, 多层 BPNN 神经网络准确率只有 23%, SKAE 深度网络模型的平均准确率为 86.75%, 说明采用去噪自动编码器与 L2 惩罚项可以增加模型鲁棒性与泛化性, 得到更好的诊断结果。

表 2 诊断平均准确率与标准差

名称	诊断准确率(%)				平均准确率
	试验 1	试验 2	试验 3	试验 4	
SKDAE	96	97.8	94.8	95.2	95.95±1.15
SKAE	88.2	90.4	83.6	84.8	86.75±2.70
L2-SDAE	71	72.6	70.2	69.8	70.9±1.07
BPNN	22	25.4	21.6	23	23±1.48
KPCA-BPNN	60.8	64	62.4	58.8	61.5±1.93
SVM	59.8	62	61.4	62.6	61.45±1.26
KELM	63.4	60.6	63.2	63.8	62.75±1.04

深度学习模型可以从原始数据中学习得到比浅层结构更优秀的特征表达, 核方法对于处理非线性数据具有更好的优势。在所提出的 SKDAE 方法中, 模型结构为 1200-500-100-20, 本章借鉴文献[8]的方法来构建堆叠自动编码器的网络层数与节点数目, 并且通过多次试验确定。网络参数中学习率为 0.3,

训练迭代次数为 50, 动量项 0.5。高斯核参数 18.030 7, 噪声比例 0.370 6, L2 惩罚项系数 0.004 7。为对比改进前后萤火虫算法的参数寻优能力, 选择改进前后的 FA 方法对 SKDAE 进行寻优对比, 结果如图 7 所示。

图 7 改进前后萤火虫算法优化结果对比

其他模型的参数设置如下。

SKAE 网络结构为 1200-800-100-20, 其他参数与 SKDAE 相同, 核参数选择结果为 26.40。

L2-SDAE 网络的模型结构为 1200-500-100-20, 学习率为 0.3, 训练迭代次数为 50, 动量项 0.5, 噪声比例 0.368 3, L2 惩罚项系数 0.002 3。

BPNN 网络采用两层神经网络, 隐层节点均为 600, 学习率为 0.3, 迭代次数为 100, 动量项 0.5。

KPCA-BPNN 网络采用两层神经网络, 隐层节点均为 600, 学习率为 0.3, 训练迭代次数为 100, 动量项 0.5, KPCA 中的核参数为 21.718 2, 累计贡献率为 0.670 8。

SVM 采用高斯 RBF 核函数, IFA 优化得到惩罚系数 C 为 82.486 7, 核参数为 40.208 4。

KELM 采用高斯 RBF 核函数, IFA 优化得到核参数为 13.441 9。

对比采用混沌萤火虫优化的参数寻优能力, 选择改进前的萤火虫算法与改进后的进行对比。两种方法的参数设置相同, 其中种群规模为 40, 迭代次数为 50, 光吸收系数为 1。改进前设置的步长因子为 0.5, 最大吸引度为 1。核参数的优化区间为 1.00~100.00, 去噪比例优化区间为 0.001~1.00, 惩罚项系数优化区间为 0.001~1.00。

表 3 改进前后萤火虫算法诊断平均准确率与标准差

方法	诊断准确率(%)				平均值
	试验 1	试验 2	试验 3	试验 4	
IFA	96	97.8	94.8	95.2	95.95±1.15
FA	94.2	94.4	90.8	92.4	92.95±1.47

以第二次试验数据作为样本, 经 50 次迭代后,

基于混沌改进后 FA 优化后的高斯核参数, 噪声比例, L2 惩罚项系数分别为[18.030 7, 0.370 6, 0.004 7], 标准 FA 优化结果为[21.765 2, 0.286 9, 0.367 6]。分别以此参数进行训练, 4 次诊断结果如图 7 所示。由表 3 可以得到, 采用标准 FA 结果可以得到 92.95% 的平均准确率, 而标准差为 1.47, 低于采用 IFA 的 95.95% 平均准确率与 1.15 的标准差。以上结果说明采用混沌改进的萤火虫算法可以获得更准确的诊断结果, 并且结果的波动更小。

进一步分析采用 SKDAE 对原始信号的特征提取能力, 采用流行学习方法对故障特征进行降维与可视化处理。局部保持投影(Locality preserving projections, LPP)算法具备流形学习方法和线性降维方法的优点, 可以保留数据内在的非线性结构和数据子空间的局部特性, 因此采用 LPP 方法分别提取原始信号与 SKDAE 最后一层神经元的前三个分量, 绘制其散点图, 结果如图 8、9 所示。

图 8 原始数据可视化映射图

图 9 SKDAE 特征可视化映射图

由图 9 中可以看出, 采用 SKDAE 方法可以提取得到有效的故障特征, 相同类别的故障很好地聚集在一起, 并且汇聚中心明显, 不同类别的故障可以明显地区分, 并且在特征提取结果较好的同时, 测试准确率较高。将图 9 与图 6 结合分析可以得到, 在第二次试验中, 故障误分类最多的类别为正常轴承, 其误分类个数占总体误分类比例的 7/11, 散点图中可以看出, 正常轴承的特征散点与其他几类故障间隔较小, 并有个别点出现重叠, 因此导致正常状态中出现误分类的情况。

4 结论

(1) 针对中介轴承原始信号的特点, 提出了一种结合高斯核函数与去噪自动编码器的神经网络。

(2) 通过构建基于 KDAE 的深度网络模型, 直接从原始信号中提取故障特征并进行诊断, 摆脱了对信号处理与特征提取技术的依赖, 取得了较高的诊断准确率。

(3) 采用混沌萤火虫算法优化深度模型中的待定参数, 快速准确地得到模型的最优参数, 相对于传统方法, 可以自动准确地获得更好的优化效果。

参 考 文 献

- [1] CUI L, WU N, MA C, et al. Quantitative fault analysis of roller bearings based on a novel matching pursuit method with a new step-impulse dictionary[J]. Mechanical Systems & Signal Processing, 2016, 68: 1.
- [2] 廖明夫, 马振国, 刘永泉, 等. 航空发动机中介轴承的故障特征与诊断方法[J]. 航空动力学报, 2013, 28(12): 2752-2758.
LIAO Mingfu, MA Zhenguo, LIU Yongquan, et al. Fault characteristics and diagnosis method of intershaft bearing in aero-engine[J]. Journal of Aerospace Power, 2013, 28(12): 2752-2758.
- [3] LEI Y G, HE Z J, ZI Y Y. Application of an intelligent classification method to mechanical fault diagnosis[J]. Expert Syst. Appl., 2009, 36: 9941-9948.
- [4] LEI Y, HE Z, ZI Y. Application of an intelligent classification method to mechanical fault diagnosis[J]. Expert Systems with Applications 2009, 36(6): 9941-9948.
- [5] ZHANG X, LIANG Y, ZHOU J, et al. A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM[J]. Measurement, 2015, 69: 164-179.
- [6] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.
LEI Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.
- [7] 孙文珺, 邵思羽, 严如强. 基于稀疏自动编码深度神经网络的感应电动机故障诊断[J]. 机械工程学报, 2016, 52(9): 65-71.
SUN Wenjun, SHAO Siyu, YAN Ruqiang. Induction motor fault diagnosis based on deep neural network of

- sparse auto-encoder[J]. Journal of Mechanical Engineering, 2016, 52(9): 65-71.
- [8] JIA F, LEI Y, ZHOU X, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mechanical Systems & Signal Processing, 2016, 72-73: 303-315.
- [9] SHAO H, JIANG H, ZHAO H, et al. An enhancement deep feature fusion method for rotating machinery fault diagnosis[J]. Knowledge-Based Systems, 2016, 119: 1.
- [10] CHEN Z, LI W. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network[J]. IEEE Transactions on Instrumentation & Measurement, 2017, 66(7): 1693-1702.
- [11] XU Z, DAI M, MENG D. Fast and efficient strategies for model selection of Gaussian support vector machine[J]. IEEE Transactions on Systems Man & Cybernetics Part B Cybernetics A Publication of the IEEE Systems Man & Cybernetics Society, 2009, 39(5): 1292-307.
- [12] YANG X S. Nature-inspired metaheuristic algorithms[M]. Beckington: Luniver Press, 2008.
- [13] KAVOUSHI-FARD A, SAMET H, MARZBANI F. A new hybrid modified firefly algorithm and support vector regression model for accurate short term load forecasting[J]. Expert Systems with Applications, 2014, 41(13): 6047-6056.
- 作者简介: 王奉涛, 男, 1974 年出生, 博士, 副教授。主要研究方向为机械系统信号处理、故障诊断与寿命预测。
E-mail: wangft@dlut.edu.cn
李宏坤(通信作者), 男, 1974 年出生, 博士, 教授, 博士研究生导师。主要研究方向为旋转机械信号处理与故障诊断, 振动与噪声。
E-mail: lihk@dlut.edu.cn

第 8 届上银优秀机械博士论文奖——特别奖

Ti6Al4V 钛合金切削加工表面残余应力的研究

作 者: 孟龙晖

毕业学校: 南京航空航天大学

指导教师: 何宁

Ti6Al4V 钛合金由于诸多方面的优点, 在航空航天领域运用广泛。其表面由于切削加工所形成的残余应力层会严重影响零件的静力强度、疲劳强度以及抗腐蚀等诸多性能, 进而影响到零件的使用寿命, 不仅如此, 零件几何尺寸的稳定性同样也会受到影响。因此, 深入研究和控制表面残余应力对提高被加工件的质量和使用寿命显得至关重要。

本文从理论推导、实际试验以及物理仿真等方面, 对 Ti6Al4V 钛合金切削加工表面残余应力进行了较为深入的研究。主要研究工作包括以下几点。

(1) Ti6Al4V 薄壁回转体零件切削加工表面残余应力的分析。提出基于应变变化的内壁残余应力和基于 FEM 修正的外壁残余应力测量方法, 分别测量了切削加工内壁和外壁表面残余应力的分布, 在此基础上通过实际试验分析了各切削参数对于表面残余应力分布的影响。

(2) Ti6Al4V 薄壁零件铣削加工表面残余应力的分析。有限元分析表明, 零件表面残余应力在平衡状态前后分布差别较大, 最终平衡后的应力分布会受到零件刚度的影响。为去除零件刚度的影响以正确评估相应的表面残余应力的分布, 文章基于腐蚀剥层和反推法测量了相应的残余应力在平衡状态前的分布。

(3) 基于等效残余应力测量的零件变形的预测。表面残余应力具体分布的测量步骤繁琐, 工作大, 以变形预测为目的, 提出基于应变变化的等效残余应力的测量方法。相应的试验表明, 该方法在大幅度减少测量步骤和工作量的同时, 对不同刚度的零件的变形预测有较高的精度。

(4) 切削加工 Ti6Al4V 钛合金表面残余应力物理仿真的研究。基于二维正交切削模型研究了切削参数和刀具几何参数对表面残余应力的影响, 以正交压痕模型分析了每转进给量和刀尖圆弧半径对于表面残余应力的影响, 最终结果表明, 正交切削模型结合正交压痕模型能够较好地预测三维切削加工所引起的表面残余应力并分析各切削参数的影响。

(5) Ti6Al4V 钛合金蠕变性质的研究。采用纳米压痕法测量了 Ti6Al4V 钛合金室温下的蠕变应力指数。通过保载后期压痕位移的变化率和材料硬度之间的关系, 最终得到了 Ti6Al4V 钛合金室温下的蠕变应力指数。另外, 以被铣削加工件为研究对象, 测量了相应的表面残余应力在不同温度下引起的零件的蠕变变形随时间的变化关系, 为进一步评估不同温度下表面残余应力所引起的零件蠕变变形提供了相应的依据。