

基于SSAE的输入级弧齿锥齿轮自动特征提取及故障诊断

张鲁晋¹,陈广艳²,孙国栋¹,王友仁¹,赵亚磊¹,张岩¹

(1. 南京航空航天大学 自动化学院,江苏 南京 211106;

2. 中国航发湖南动力机械研究所 直升机传动技术国防科技重点实验室,湖南 株洲 412000)

摘要:航空用输入级弧齿锥齿轮常处于高速重载工况,获取的振动信号具有强非线性、非平稳特点,造成故障特征难提取。对此,运用堆栈稀疏自动编码器故障自动特征提取方法结合分类器对输入级弧齿锥齿轮故障诊断进行了研究。搭建输入级弧齿锥齿轮故障诊断模拟试验台,分别进行正常齿轮和故障齿轮运行的测试试验。将多个SAE层层堆叠形成SSAE,对弧齿锥齿轮故障特征层层提取,用多分类器完成故障诊断。结果表明:该方法输入级弧齿锥齿轮故障识别结果的有效率可达100%,为弧齿锥齿轮的故障分析提供了一种有效途径。

关键词:弧齿锥齿轮;堆栈稀疏自动编码器;特征提取;故障诊断

中图分类号:TH132.4; TP391 **文献标志码:**A **文章编号:**1671-5276(2021)02-0161-04

Automatic Feature Extraction and Fault Diagnosis of Input-stage Spiral Bevel Gear Based on SSAE

ZHANG Lujin¹, CHEN Guangyan², SUN Guodong¹, WANG Youren¹, ZHAO Yalei¹, ZHANG Zhai¹

(1. College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. Key Laboratory of National Defense Science and Technology of Helicopter Transmission Technology, Hunan Power Machinery Research Institute of Aviation Development, Zhuzhou 412000, China)

Abstract: As aviation input-stage spiral bevel gears are often in high-speed and heavy-load conditions, and the acquired vibration signals have strong nonlinear and non-stationary characteristics, it is difficult to extract fault characteristics. To overcome the difficulty, the fault diagnosis of input-stage spiral bevel gears is studied by the automatic feature extraction method of stack sparse autoencoder and the classifier. The input-level spiral bevel gear fault diagnosis simulation test bench was built, the normal and faulty gear functions were tested, multiple SAEs were stacked to form SSAE, spiral bevel gear fault characteristics were extracted layer by layer, and the multi-classifier was applied to complete fault diagnosis. The results show that the effective rate of the input-stage spiral bevel gear fault identification results of this method can reach 100%, which provides effective means for the failure analysis of spiral bevel gears.

Keywords: spiral bevel gears; stacked sparse autoencoder; feature extraction; fault diagnosis

0 引言

弧齿锥齿轮广泛应用于直升机主减速器输入级以及各类机械装置中。高速重载输入级弧齿锥故障齿轮和其他齿轮啮合会产生调幅和调频效应,轴承各部件间相对运动,齿轮故障会引起动态信号调制,与传感器相对位置的改变也会产生调制。重载下的载荷波动直接导致输入级弧齿锥齿轮的振动响应应具有明显的非平稳性。高速下的转速波动也会导致调频和调幅效应加剧,使得非平稳特征更加剧烈。如何从强非平稳性信号中提取有效的特征是输入级弧齿锥齿轮故障诊断的核心。

深度学习理论作为机器学习领域最新的研究成果,可

以实现故障特征自动提取,摆脱了对专家诊断经验的依赖,在图像处理、语音识别和健康监测等领域目前均取得了丰硕成果。近几年来,也已在旋转机械故障诊断领域得到推广应用。其中堆栈自动编码器(stacked autoencoder, SAE)、深度置信网络(deep belief network, DBN)和卷积神经网络(convolutional neural network, CNN)的应用最为广泛。GUO X J等^[1]在SAE上融入去噪编码,引入堆栈去噪自动编码器(stacked denoising autoencoders, SDAE),提高了模型的抗噪性能,能有效地诊断出强背景噪声下轴承与齿轮箱故障。AHMED H O A等^[2]用去噪自动编码器提取轴承故障特征,并利用分类器完成了轴承故障诊断。JIA F等^[3]将深度神经网络(deep neural network, DNN)应用于行星齿轮箱故障诊断,深度学习先以非监督学习方式

基金项目:直升机传动技术国防科技重点实验室基金项目(KY-52-2018-0024);航空科学基金项目(20183352031);江苏省研究生研究与实践创新计划项目(KYCX19_0171)

第一作者简介:张鲁晋(1997—),男,山东济宁人,硕士研究生,研究方向为航空设备故障诊断、旋转机械故障诊断。

通信作者简介:陈广艳(1984—),男,福建连江人,高级工程师,硕士,主要从事直升机传动设计技术研究。

逐层训练 DNN, 深入挖掘振动信号频谱中故障特征信息, 再以有监督学习方式反向微调 DNN, 进一步优化 DNN 对行星齿轮箱故障特征表示并使其具有检测诊断能力, 最终完成行星齿轮箱故障特征自适应提取及分类。LEI Y G 等^[4]将稀疏滤波理论融入 DNN, 从原始振动信号自适应提取稀疏特征, 利用 Softmax 分类器对轴承进行故障诊断, 具有更高的诊断精度。GAN M 等^[5]提出基于 DBN 的分层故障诊断网络, 不仅实现了轴承故障模式的准确识别, 而且对故障损伤程度进行了定量分析。GUO X J 等^[6]提出自适应深度卷积神经网络应用于轴承故障诊断, 利用梯度下降自适应选取学习率, 同时提高了模型的收敛速度和诊断精度。SHAO H D 等^[7]提出了一种改进型的卷积深度置信网络(CDBN), 利用压缩感知理论提取振动信号有效成分, 降低信号维度并提高信号分析效率; 采用高斯可见单元构建新的 CDBN 模型, 提高数据的特征学习能力; 采用指数移动平均技术对参数优化算法进行修改, 提高深层模型的收敛性和泛化性能, 将其应用于滚动轴承故障诊断, 提高了信号的分析效率和故障分类准确率。ZHANG W 等^[8]提出一种新的训练方式用来改善深度卷积神经网络, 通过在网络训练过程中融入 Dropout 和批量归一化操作, 加快了网络的抗噪能力和收敛速度, 可以在噪声环境和变负载情况下自适应地提取轴承故障特征并进行故障诊断。

本文针对输入级弧齿锥齿轮故障特征难提取问题, 建立了输入级弧齿锥齿轮故障诊断振动测试试验台, 分别进行了正常齿轮和故障齿轮运行的测试试验。结合具体研究对象, 运用堆栈稀疏自动编码器故障自动特征提取方法与分类器对输入级弧齿锥齿轮故障诊断进行了研究。

1 相关理论

1.1 自动编码器

自动编码器(autoencoder, AE)是一种对称的三层神经网络, 它通过隐藏层实现对输入数据的编码和重构。编码器结构如图1所示。

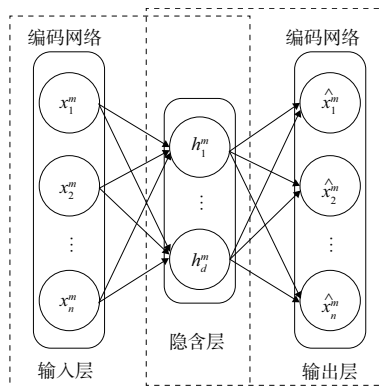


图1 自动编码器基本结构

编码网络通过 $f(X)$ 实现从 X 到 H 的非线性变换

$$H = f_{\theta}(X) = \sigma(WX + b) \quad (1)$$

式中: σ 表示激活函数; $\theta = \{W, b\}$; W 为权重矩阵; b 是隐

含层阈值。

解码网络通过 $g(\cdot)$ 使得 H 重构得到 Y

$$Y = g_{\theta'}(H) = \sigma(W'H + b') \quad (2)$$

式中: $\theta' = \{W', b'\}$; W' 为权重矩阵; b' 是输出层阈值。

因此, 自编码器可以通过最小化 X 和 Y 的均方误差, 求得编码矢量 H 。

$$J(W, b) = \sum (L(x, y)) = \sum \|y - x\|_2^2 \quad (3)$$

1.2 堆栈稀疏自动编码器

用多个“维数递减”的基本自编码器隐含层组成堆栈自动编码器。在训练隐含层比较多的堆栈自动编码器时, 容易发生“梯度弥散”现象。常用的解决思路为: 一是设置神经元的线性激活函数; 二是采用“预训练+精微调”训练方式; 三是选择“稀疏”的隐含层输出值。

稀疏自动编码器作为自动编码器的一种改进结构, 能够提取具有良好表达能力的数据特征。为构造具有更强表达能力的函数, 可将多个稀疏自动编码器层层堆叠形成堆栈稀疏自动编码器(stacked sparse autoencoder, SSAE), 前一层编码器的输出作为后一层编码器的输入, 进行故障特征的层层提取, 再合并每个稀疏自动编码器的编码矢量构成一个多层的神经网络, 并用分类器构成输出层, 如图2所示。堆栈稀疏自动编码器包括输入层、 n 个隐含层和输出层, 每个隐含层即为每个稀疏自动编码器预训练提取的特征。




图2 SSAE 结构图

堆栈稀疏自动编码器采用逐层贪婪训练算法调整参数, 逐层贪婪的主要思路是每次只训练网络中的一层。在每一步中, 将已经训练好的前 $n-1$ 层的输出作为第 n 层的输入, 将逐层训练得到的网络权重作为 SSAE 的初始权重, 然后将所有网络堆叠起来并利用有标签数据对所有网络权重进行优化, 即对整个网络进行“微调”。堆栈稀疏自动编码器的算法流程如图3所示。

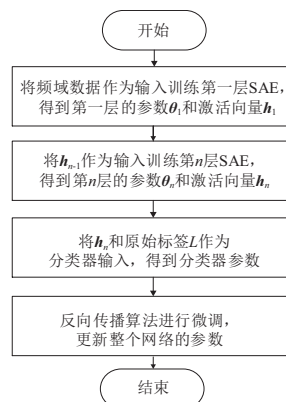


图3 SSAE 流程图

2 实验与结果分析

2.1 输入级弧齿锥齿轮故障模拟实验说明

锥齿轮故障模拟实验平台如图4所示,整个实验平台主要包括变速驱动电机、锥齿轮实验箱、控制器、磁粉制动器等。驱动电机作为动力源,控制器用来调节转速,磁粉制动器用于调整负载。锥齿轮实验箱由二级锥齿轮组成,锥齿轮故障模拟试验件安装在第一级锥齿轮中。

针对第一级锥齿轮中的小齿轮和输入级轴承设置了4种故障模式,分别是锥齿轮点蚀故障、锥齿轮裂纹故障、轴承内圈故障和轴承外圈故障。锥齿轮及轴承的故障模拟件实物如图5所示。




图4 锥齿轮故障模拟实验平台



图5 输入级锥齿轮及轴承的故障模拟试验件

2.2 实验结果分析

设计堆栈稀疏自动编码器的输入层节点数等于输入信号的数据长度,而堆栈稀疏自动编码器输入量的维数太高会导致网络训练过慢。因此,对7种状态下的每组时域振动信号进行快速傅里叶变换,将其转换到频域,截取频域信号的前2000点作为自编码器的输入数据集。堆栈稀疏自动编码器的网络结构设置为2000-1000-500-200-8-7,其拓扑结构如图6所示。所设计的堆栈稀疏编码器包括输入层、4个隐含层和输出层,输出层为分类器。先用训练样本数据对每个隐含层进行编码-解码预训练,再用训练样本数据对堆栈稀疏编码器参数进行微调。经

过微调后,堆栈稀疏编码器实现了输入级振动信号的逐层压缩特征提取。




图6 SSAE拓扑结构

利用堆栈稀疏自动编码器对7种状态分别提取360组8维特征数据,共得到2520组8维故障特征数据集。随机选取每种状态下270个样本作为训练集,剩余90个样本为测试集,训练集样本数为1890个,测试集样本数为630个。具体划分结果见表1。

表1 数据集划分

模式类型	样本个数	训练集个数	测试集个数	工况数
正常状态	360	270	90	4
锥齿轮裂纹	360	270	90	4
锥齿轮点蚀	360	270	90	4
轴承内圈故障	360	270	90	4
轴承外圈故障	360	270	90	4
锥齿轮裂纹+轴承内圈故障	360	270	90	4
锥齿轮点蚀+轴承外圈故障	360	270	90	4

把堆栈稀疏编码器提取的故障振动特征作为3种故障诊断分类器Softmax、ELM、PSO-SVM的输入,进行3种分类器的故障诊断实验结果分析,并采用t-SNE进行特征的可视化分析,结果如图7所示。




图7 SSAE提取特征的t-SNE可视化散点图

由图7的SSAE提取的特征散点图可以明显地看出,各模式的特征聚集度很高,不同状态模式之间距离明显,聚集模式具有规律性和区域性。

图8显示Softmax分类器对稀疏自编码器提取的故障特征数据集的整体故障诊断率达99.5%。除内圈故障的故障诊断率为96.7%外,其余6种模式的故障诊断率均达到100%。图9表明ELM算法对堆栈稀疏自动编码器提取的故障特征数据集的整体故障诊断率达99.7%。内圈故障的故障诊断率为97.8%,其余6种模式的故障诊断率均为100%。图10表明PSO-SVM算法对堆栈稀疏自编

码器提取的故障特征数据集有极好的故障诊断效果,故障诊断率达100%。

Output Class	1	2	3	4	5	6	7	
1	90 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	90 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	90 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	87 13.8%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	3 0.5%	90 14.3%	0 0.0%	0 0.0%	96.8% 3.2%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90 14.3%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90 14.3%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	96.7% 3.3%	100% 0.0%	100% 0.0%	100% 0.0%	99.5% 0.5%
	1	2	3	4	5	6	7	

图8 Softmax 的分类结果

Output Class	1	2	3	4	5	6	7	
1	90 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	90 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	90 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	88 14.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	2 0.0%	90 14.3%	0 0.0%	0 0.0%	97.8% 2.2%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90 14.3%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90 14.3%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	97.8% 2.2%	100% 0.0%	100% 0.0%	100% 0.0%	99.7% 0.3%
	1	2	3	4	5	6	7	

图9 ELM 的分类结果

Output Class	1	2	3	4	5	6	7	
1	90 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	90 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	90 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	90 14.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90 14.3%	0 0.0%	0 0.0%	100% 0.0%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90 14.3%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90 14.3%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
	1	2	3	4	5	6	7	

图10 PSO-SVM 的分类结果

3 结语

针对高速重载输入级弧齿锥齿轮故障特征难提取的问题,采用堆栈稀疏自动编码器故障自动特征提取方法并结合多个分类器完成其诊断。

1) 将多个稀疏自动编码器层层堆叠形成堆栈稀疏自动编码器,构造了具有更强表征能力的深度学习模型,进而达到捕获复杂和非平稳振动信号的特征,实现故障特征的自动提取。

2) 3种故障诊断模型对SSAE自动提取特征均有较好的故障识别效果。Softmax与ELM的故障识别效果相差不多,故障诊断率达99%以上,但极限学习机具有更快的故障诊断速度。Softmax与ELM对齿轮故障的故障诊断率高于轴承故障,均将部分内圈故障样本识别为外圈故障。PSO-SVM算法的故障诊断结果最优,故障诊断率为100%。

参考文献:

- [1] GUO X J, SHEN C Q, CHEN L. Deep fault recognizer; an integrated model to denoise and extract features for fault diagnosis in rotating machinery [J]. Applied Sciences, 2016, 7(1):41.
- [2] AHMED H O A, DENNIS WONG M L, NANDI A K. Effects of deep neural network parameters on classification of bearing faults[C]//IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society. Florence, Italy: IEEE, 2016:6329-6334.
- [3] JIA F, LEI Y G, LIN J, et al. Deep neural networks; a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data [J]. Mechanical Systems and Signal Processing, 2016, 72/73:303-315.
- [4] LEI Y G, JIA F, LIN J, et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data [J]. IEEE Transactions on Industrial Electronics, 2016, 63(5):3137-3147.
- [5] 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 [J]. Mechanical Systems and Signal Processing, 2016, 72/73:92-104.
- [6] GUO X J, CHEN L, SHEN C Q. Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis [J]. Measurement, 2016, 93:490-502.
- [7] SHAO H D, JIANG H K, ZHANG H Z, et al. Rolling bearing fault feature learning using improved convolutional deep belief network with compressed sensing [J]. Mechanical Systems and Signal Processing, 2018, 100:743-765.
- [8] ZHANG W, LI C H, PENG G L, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load [J]. Mechanical Systems and Signal Processing, 2018, 100:439-453.

收稿日期:2021-01-13