

基于 SCAE-ACGAN 的直升机行星齿轮裂纹故障诊断*

孙灿飞^{1,2}, 王友仁², 夏裕彬¹

(1. 故障诊断与健康管理技术航空科技重点实验室 上海, 201601) (2. 南京航空航天大学自动化学院 南京, 211106)

摘要 直升机行星传动轮系结构复杂、工况多变,其振动信号受工况影响大,在故障样本较少的情况下导致行星齿轮箱故障诊断准确率不高,早期故障诊断困难。针对上述问题,提出将堆栈收缩自动编码网络(stacked contractive autoencoder, 简称 SCAE)与辅助分类生成式对抗网络(auxiliary classifier generative adversarial networks, 简称 ACGAN)相结合的 SCAE-ACGAN 故障诊断方法。ACGAN 的生成器产生与真实样本具有类似分布的生成样本,扩展训练样本集,并与真实样本一起输入至判别器进行训练。ACGAN 采用 SCAE 作为判别器,利用 SCAE 良好的抗数据波动能力,从扩展样本集中挖掘出有效的深度特征,并实现样本的真伪与类别的判定。ACGAN 的判别器和生成器在对抗学习训练机制下交替优化,提高方法的样本生成质量与故障判定能力。将 SCAE-ACGAN 应用于直升机行星轮裂纹故障诊断,结果表明,SCAE-ACGAN 的故障诊断性能好,在样本数量少与工况变化情况下具有较好的健壮性和适应性。

关键词 直升机; 行星齿轮箱; 裂纹; 故障诊断; 堆栈收缩自动编码器; 辅助分类生成式对抗网络
中图分类号 TH165+.3; V214.3+3; TP206

引 言

行星传动轮系作为直升机传动系统主减速器的最后一环,是整个主减速器的核心部件。相比于其他工业领域,恶劣的噪声环境、多变的工况条件使直升机行星传动轮系更容易发生齿面磨损及局部损伤等故障现象。因此,开展行星传动轮系故障诊断对提高直升机飞行安全与出勤率、减少维护费用等方面具有重要意义,是直升机健康和监测系统的重点和难点^[1]。

独特的行星结构使行星齿轮箱的振动信号成分复杂,具有强烈的非平稳性和耦合调制特征,增加了故障诊断的难度。目前,科研人员在行星齿轮箱的故障诊断上开展了基于数学模型、信号处理以及模式识别等方面的研究^[2]。基于模型的方法虽然表征了输出响应与模型参数之间的关系,有助于了解行星齿轮箱工作原理和故障机理,但由于存在许多假设与简约化,导致仿真数据与真实情况存在一定差距,故障诊断精度有待提高^[3-4]。基于信号处理的方法受制于行星齿轮箱复杂的振动信号,提取与判别出微弱的故障信息仍存在许多不确定因素,影响了

诊断的准确度^[5-6]。另外,基于传统的模式识别方法由于其浅层学习机制的限制,对工况波动、强噪声背景下的故障诊断鲁棒性与泛化能力不足^[7-8]。

近年来,深度学习广泛应用于旋转机械系统的特征提取与故障诊断。文献[9]采用深度置信网络(deep belief networks, 简称 DBN)融合多个传感器的有效信息,实现航空发动机及电力变压器故障诊断。文献[10]在堆栈自动编码器(stacked autoencoders, 简称 SAE)中融入去噪编码,结合多个编码器的诊断信息融合实现了行星齿轮箱故障诊断。文献[11]采用深度梯度提升模型逐层学习振动信号特征,对航空发动机 5 类轴承故障进行诊断,并与支持向量机、K-近邻及随机森林等机器学习方法对比验证了方法的健壮性。相比于浅层学习机制,深度学习通过建立深层模型来映射信号与故障状态之间复杂的内在关系,非常适合于大数据背景下多样性、非线性和高维数据的分析。在直升机行星传动轮系故障诊断中,应用深度学习进行故障诊断存在两方面困难:①深度学习模型的诊断精度依赖大量样本的训练,在样本较少的情况下诊断效果较差,而由于实验条件限制,直升机行星传动轮系很难获取大量样本的故障数据;②直升机行星传动轮系往往工作在

* 航空科学基金资助项目(KY-52-2018-0024)
收稿日期:2019-10-09;修回日期:2019-11-26

复杂的环境中,比如强烈的背景噪声和扰动的工况等,需要深度学习模型在样本数据波动情况下仍具有较好的健壮性和适应性。

为解决以上问题,笔者结合堆栈收缩自动编码器^[12](SCAE)与辅助分类生成式对抗网络^[13](ACGAN)提出了基于SCAE-ACGAN的直升机行星传动轮系故障诊断方法。SCAE可以从样本数据扰动情况下提取出更具鲁棒性的故障特征,提高了模型的健壮性;而ACGAN基于对抗学习方式,捕捉真实样本的内在分布,实现样本集的扩充,解决样本较少情况。因此,结合两者各自优势,SCAE-ACGAN方法利用ACGAN生成器产生与真实样本具有近似分布的生成样本,扩充样本数量;利用SCAE作为判别器,对扩充后的输入样本进行真伪判别与故障分类。基于对抗学习方式,对生成器与判别器交替优化,提高样本生成质量和故障识别能力,最终实现在样本数量不足和样本数据波动情况下的直升机行星传动轮系的故障诊断。

1 理论基础

1.1 收缩自动编码器

自动编码器(autoencoder,简称AE)是一种具有3层对称结构的神经网络,由编码网络和解码网络所构成。编码网络将输入矢量映射为编码矢量,解码网络将编码矢量再映射为输出矢量。AE的目标是实现输出矢量对输入矢量的重构,在此过程中,编码矢量作为中间层实现了对输入矢量特征表达的提取。

对于原始样本数据集 $\{x^m\}_{m=1}^M$,编码网络将输入 x^m 映射为隐含层表达 h^m

$$\begin{cases} h^m = f_{\theta}(Wx^m + b) \\ \theta = \{W, b\} \end{cases} \quad (1)$$

其中: θ 为编码参数集; W 为编码权重矩阵; b 为编码偏置向量; $f(*)$ 为激活函数。

解码网络通过激活函数反向将 h^m 转换为输入向量的重构表达 \hat{x}^m

$$\begin{cases} \hat{x}^m = f_{\theta'}(W'h^m + b') \\ \theta' = \{W', b'\} \end{cases} \quad (2)$$

其中: θ' 为解码参数集; W' 为解码权重矩阵; b' 为解码偏置向量。

通过最小化代价函数,即原始样本输入 x^m 与重

构输出 \hat{x}^m 之间的误差 L ,进行自动编码器训练

$$\ell_{AE}(\theta, \theta') = \sum_{x^m \in \{x^m\}_{m=1}^M} L(x^m, \hat{x}^m) \quad (3)$$

为了提高编码学习的健壮性,收缩自动编码器(contractive autoencoder,简称CAE)在自动编码器基础上引入一个正则项,惩罚对输入样本扰动的敏感度,这样CAE的目标函数是重构误差和收缩罚项(正则项)的总和,通过最小化该目标函数使学习到的隐层表达尽量对输入扰动保持不变

$$\begin{cases} \ell_{CAE}(\theta, \theta') = \sum_{x^m \in \{x^m\}_{m=1}^M} L(x^m, \hat{x}^m) + \frac{1}{2} \lambda \|J(x^m)\|_F^2 \\ J(x^m) = \partial f_{\theta}(x^m) / \partial x^m \end{cases} \quad (4)$$

其中: $J(*)$ 为对编码函数相关偏导数的Jacobian矩阵。

参数 λ 用于权衡代价函数的鲁棒性和重构误差,在保证重构误差最小化的同时,由于惩罚项的限制,CAE对输入数据中的小扰动敏感性较小。

1.2 堆栈收缩自动编码器

为形成深度学习隐含层网络,将CAE层层堆叠,将前1个CAE的隐含层表达输入至下1个CAE,实现隐含层表达的层层提取,最后增加Softmax分类器构成输出层,构成堆栈收缩自动编码器SCAE,如图1所示。

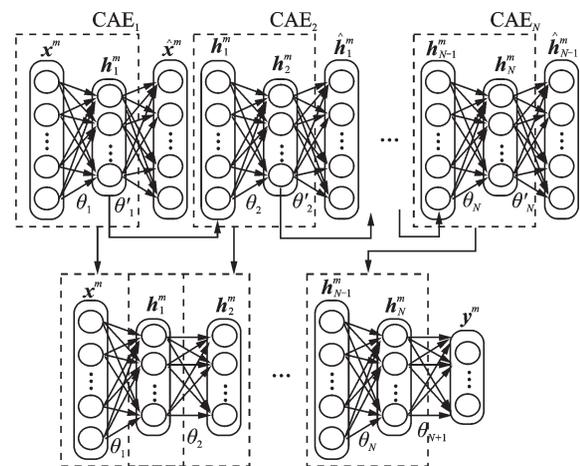


图1 SCAE组成示意图

Fig.1 Schematic diagram of SCAE structure

首先;CAE₁将输入样本 x^m 编码为 $h_1^m = f_{\theta_1}(W_1 x^m + b_1)$;其次,将 h_1^m 输入至CAE₂,编码为 h_2^m ;重复以上步骤,直至最后的CAE_N,此时输出隐层表达 $h_N^m = f_{\theta_N}(W_N h_{N-1}^m + b_N)$ 。

预训练阶段实现了多个CAE的层层连接,逐层提取隐含层表达作为特征向量。预训练结束后,在输出层增加 Softmax 分类器对样本分类,输出类别标签 y^m 为

$$y^m = g_{\theta_{N+1}}(h_N^m) \quad (5)$$

其中: θ_{N+1} 为分类层参数集; $g(*)$ 为分类层激活函数。

SCAE 基于交叉熵的代价函数为

$$\ell_{\text{SCAE}}(\theta) = -\frac{1}{M} \sum_{m=1}^M [c^m \ln y^m - (1 - c^m) \ln (1 - y^m)] \quad (6)$$

其中: $\theta = \{\theta_1, \theta_2, \dots, \theta_{N+1}\}$ 为 SCAE 参数集; c^m 为样本 x^m 的类别标签。

SCAE 通过最小化 $\ell_{\text{SCAE}}(\theta)$ 完成网络参数的微调。

1.3 辅助分类生成式对抗网络

生成式对抗网络^[14] (generative adversarial networks, 简称 GAN) 基于博弈论中双人零和博弈的启发, 由单个生成器和单个判别器构成。任意可微分的函数都可以用来表示 GAN 的生成器 D 和判别器 G, 其结构如图 2(a) 所示。其中: x^m 采样于原始数据样本; z^r 为生成器输入, 采样于随机噪声 (例如高斯随机噪声); $G(z^r)$ 为 G 生成的尽量服从原始数据分布的生成样本。

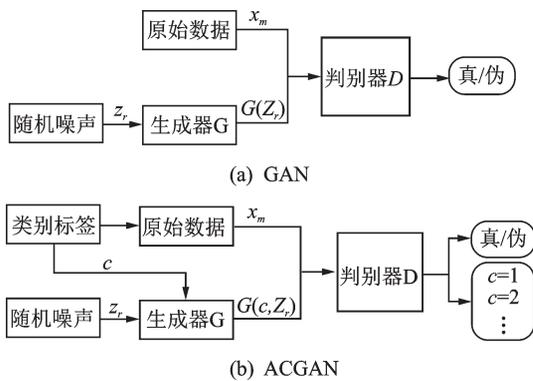


图2 GAN与ACGAN的结构框图

Fig.2 The structure diagram of GAN and ACGAN

GAN 的训练过程中, D 的目标是判别输入样本是真实样本 x^m 还是生成样本 $G(z^r)$; G 的目标是尽量捕捉真实样本的内在分布, 使生成的生成样本 $G(z^r)$ 在 D 上的表现与真实样本 x^m 一致。基于对抗学习方式, G 和 D 不断优化自身性能, 直至两者实现纳什均衡, 优化目标函数为

$$\min_G \max_D \{ f(D, G) = E[\log D(x^m)] + E[\log(1 - D(G(z^r)))] \} \quad (7)$$

GAN 的训练结束后, G 实现了对真实样本的内在分布的近似估计, 同时 D 提升了判别能力。

辅助分类生成式对抗网络 ACGAN 结构如图 2(b) 所示, 生成器 G 的输入除了噪声外还有指定的类别标签 c , 引导生成类条件样本 $G(c, z^r)$, 以增强现有的生成模型。判别器 D 除了分辨出样本的真伪的概率分布, 还通过一个 softmax 分类器具体给出属于类别标签的概率分布。在对抗过程中, 判别器目标是尽可能区分出真实数据和生成数据并且能准确对数据进行分类, 而生成器是生成数据能尽可能被判别为真实数据且能被有效分类。

2 基于SCAE-ACGAN故障诊断方法

2.1 方法流程

针对样本数量少、样本数据波动情况下直升机行星传动轮系故障诊断的难题, 笔者将 SCAE 与 ACGAN 相结合, 提出基于 SCAE-ACGAN 的直升机行星传动轮系故障诊断方法。方法采用 SCAE 作为判别器, BP 神经网络作为生成器, 如图 3 所示。

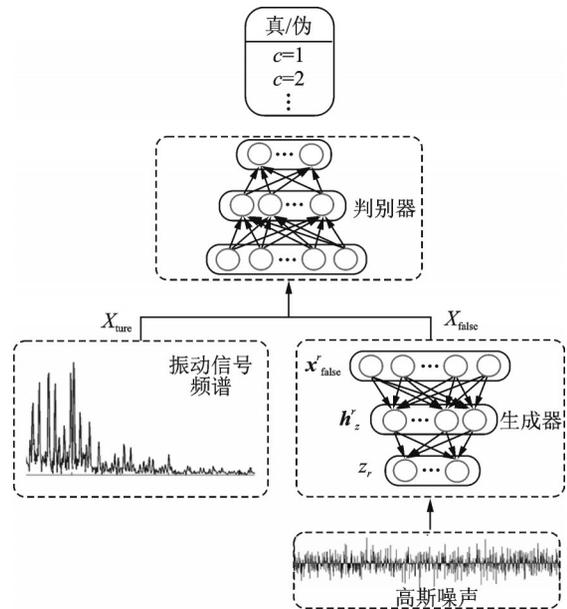


图3 SCAE-ACGAN故障诊断模型

Fig.3 Diagnostic model based on SCAE-ACGAN

随机采样高斯噪声得到的噪声向量 $\{z^r\}_{r=1}^R$, 生成网络将其映射为隐含层矢量 h_z^r , 形成生成样本 $\{x^r_{\text{false}}\}_{r=1}^R$, 对应的类别标签为 y^r_{false}

$$h_z^r = f_{\theta_z}(W_z z^r + b_z) \quad (8)$$

$$x_{\text{false}}^r = f_{\theta'_z}(W_z' h_z^r + b_z') \quad (9)$$

其中： θ_z, θ'_z 分别为生成网络的输入层与输出层的参数集，且 $\theta_z = \{W_z, b_z\}, \theta'_z = \{W_z', b_z'\}$ ； W_z 与 W_z' 为权重矩阵； b_z 与 b_z' 为偏置向量。

2.1.1 判别器训练

将 $\{x_{\text{false}}^r\}_{r=1}^R$ 标注为0，真实样本 $\{x^m\}_{m=1}^M$ 标注为1，将真实样本与生成样本输入至SCAE进行真伪判定和故障识别，通过式(5)给出样本的真伪标签 $d_{\text{ture}}^m, d_{\text{false}}^r$ 以及类别标签 $c_{\text{ture}}^m, c_{\text{false}}^r$ 。

SCAE-ACGAN通过最小化真伪标签与类别标签的代价函数误差，完成判别器SCAE的训练。基于交叉熵代价函数 $\ell_{\text{SCAE-ACGAN,D}}$ 为

$$\ell_{\text{SCAE-ACGAN,D}} = \arg \min_{\Theta} (\ell_c + \ell_d) \quad (10)$$

其中： ℓ_c 为类别标签的交叉熵代价函数误差； ℓ_d 为真伪标签的交叉熵代价函数误差。

$$\ell_c = -\frac{1}{M} \sum_{m=1}^M [y^m \ln c_{\text{ture}}^m + (1 - y^m) \ln (1 - c_{\text{ture}}^m)] - \frac{1}{R} \sum_{r=1}^R [y_{\text{false}}^r \ln c_{\text{false}}^r + (1 - y_{\text{false}}^r) \ln (1 - c_{\text{false}}^r)] \quad (11)$$

$$\ell_d = -\frac{1}{M} \sum_{m=1}^M \ln d_{\text{ture}}^m - \frac{1}{R} \sum_{r=1}^R \ln (1 - d_{\text{false}}^r) \quad (12)$$

其中： Θ 为参数集， $\Theta = \{\theta_1, \theta_2, \dots, \theta_{N+1}\}$ 。

2.1.2 生成器训练

首先将 $\{x_{\text{false}}^r\}_{r=1}^R$ 标注为1，判别器SCAE对生成样本进行判别，输出结果为假时(输出的真伪标签结果为0)，说明生成器的生成样本无法成功欺骗判别器，然后通过式(13)对生成网络进行反馈调节

$$\ell_{\text{SCAE-ACGAN,G}} = \arg \min_{\Theta'} (\ell_c + \ell_g) \quad (13)$$

其中： $\ell_{\text{SCAE-ACGAN,G}}$ 为生成器的代价函数； ℓ_g 为真伪标签的交叉熵代价函数误差。

$$\ell_g = -\frac{1}{R} \sum_{r=1}^R \ln d_{\text{false}}^r \quad (14)$$

其中： Θ' 为参数集， $\Theta' = \{\theta_z, \theta'_z\}$ 。

2.1.3 对抗学习方式

当真实样本 $\{x^m\}_{m=1}^M$ 输入至SCAE-ACGAN时，判别器SCAE的目标是尽量使 d_{ture}^m 输出为1；当生成样本 $\{x_{\text{false}}^r\}_{r=1}^R$ 为输入时，判别器SCAE的目标是尽量使 d_{false}^r 输出为0。判别器的目标是正确判断出真实样本和生成样本，而生成器目标是“以假乱真”，通过生成样本使判别器输出 d_{false}^r 趋近于1。基于对抗学习方式，生成器与判别器都不断进行交替优化，直至两者实现纳什均衡，最终完成SCAE-ACGAN的训练。

2.2 方法实现

基于SCAE-ACGAN的直升机行星传动轮系故障诊断方法的实现流程见图4，具体步骤如下：

1) 采集直升机行星传动轮系振动信号，计算信号频谱，并将频谱分为训练样本与测试样本；

2) 将训练样本输入至参数设置后的SCAE-ACGAN故障诊断模型，基于对抗学习方式，不断交替优化SCAE-ACGAN的生成器与判别器，直至两者实现纳什均衡，最终完成SCAE-ACGAN的训练。

3) 基于训练后的模型，测试样本输入至SCAE-ACGAN的判别器，进行行星传动轮系故障诊断，输出诊断结果。

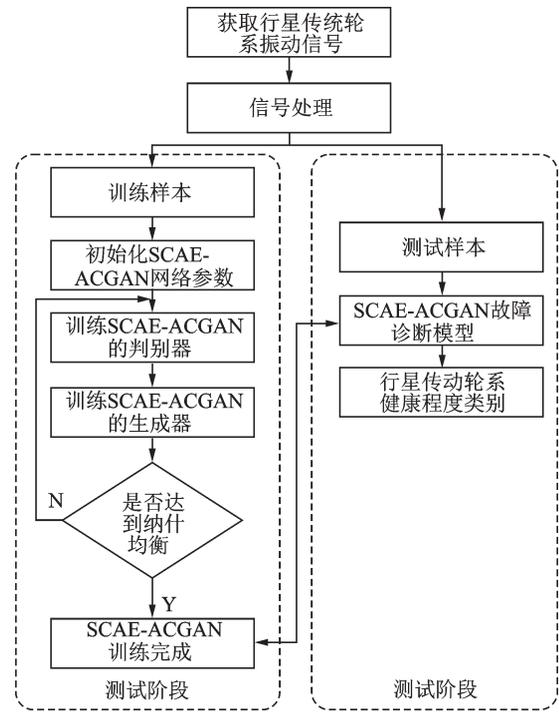


图4 SCAE-ACGAN故障诊断方法流程

Fig.4 Algorithm of fault diagnosis based on the SCAE-ACGAN

3 实验验证

3.1 实验设置

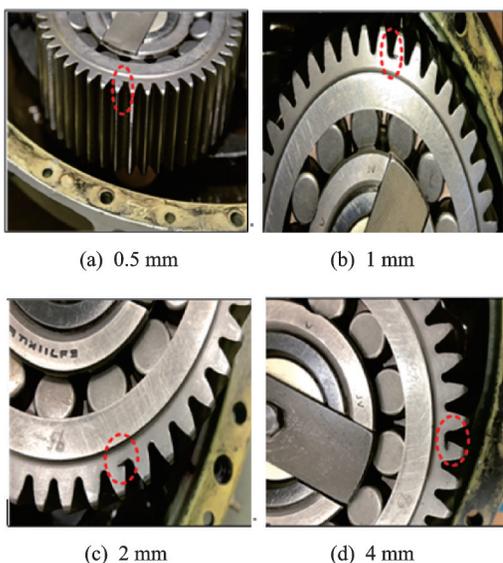
方法在直升机行星传动轮系实验平台进行验证，如图5所示，主要由大功率电机、直升机主减速器、负载以及采集设备等组成，其中主减速器含有1个单级行星传动轮系。

实验中设置了4种行星轮裂纹故障，分别为0.5, 1, 2, 4 mm齿根裂纹故障，如图6所示。在齿圈外部安装加速度传感器检测振动信号，采样频率为



图 5 直升机行星传动轮系实验验证平台

Fig.5 Helicopter planetary gear train experimental verification platform



(a) 0.5 mm (b) 1 mm (c) 2 mm (d) 4 mm

图 6 行星齿轮齿根裂纹故障

Fig.6 Planetary gear root crack fault models.

5 kHz, 时域波形如图 7 所示。

实验中,为与直升机实际情况一致,采用额定转速,并在正常与故障情况下设置了 4 种负载等级,分别为无负载和满负载的 25%, 50% 以及 75%。同时在采集的实验条件下振动信号加入标准的 NoiseX-92 舱内噪声,信号噪声比为 -5 dB,数据样本及分配情况如表 1 所示。

表 1 实验样本集

Tab.1 Experimental dataset

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	1 000	800	200	4
0.05 mm 裂纹	1 000	800	200	4
1 mm 裂纹	1 000	800	200	4
2 mm 裂纹	1 000	800	200	4
3 mm 裂纹	1 000	800	200	4

3.2 诊断结果分析

实验中,首先确定判别器 SCAE 的初始网络模

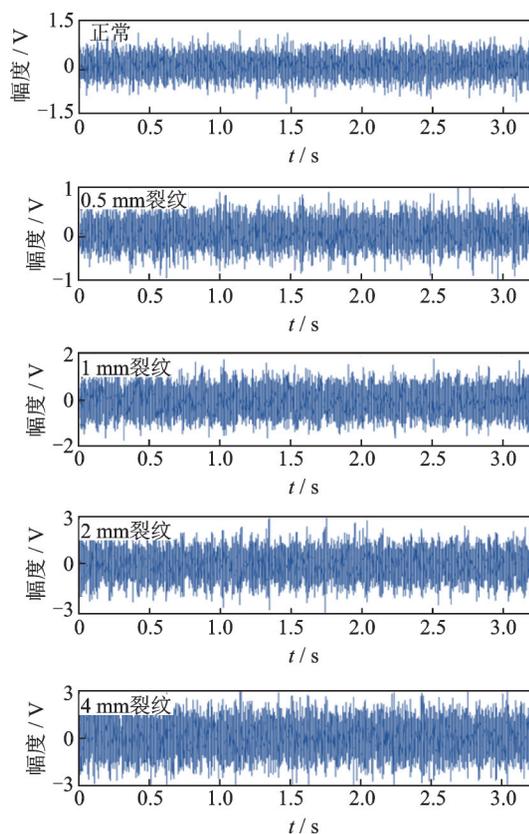


图 7 原始时域信号

Fig.7 The original signals

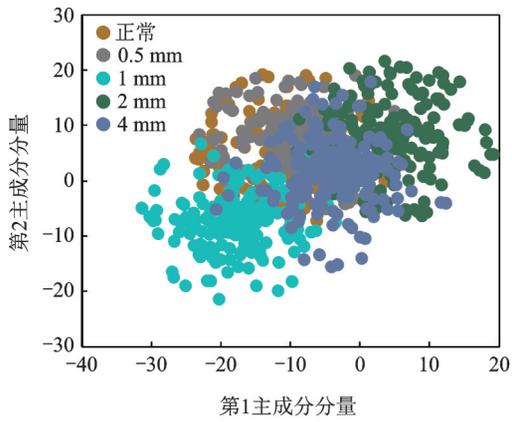
型参数。通过采用样本集对 SCAE 网络模型结构参数进行测试,以平均分类准确率最高的参数作为最终结果,确定 SCAE 网络模型结构为 1 000-300-25-5,即网络共有 4 层,每层神经元个数为 1 000, 300, 25 和 5。

3.2.1 特征可视化分析

为验证 SCAE-ACGAN 从输入信号样本中提取深度特征的有效性,利用主成分分析 (principal component analysis, 简称 PCA) 从中提取两个主成分,并与原始频谱特征提取的两个主成分进行可视化对比,形成的散点图如图 8 所示。从图中可知,在进入 SCAE-ACGAN 模型前,振动信号的原始频谱特征交叉重叠,难以区分。经过 SCAE-ACGAN 提取深度特征后,行星轮的不同裂纹故障可有效地被区分开,而同一裂纹故障很好地聚集在一起,显示了 SCAE-ACGAN 提取的深度特征的有效性。

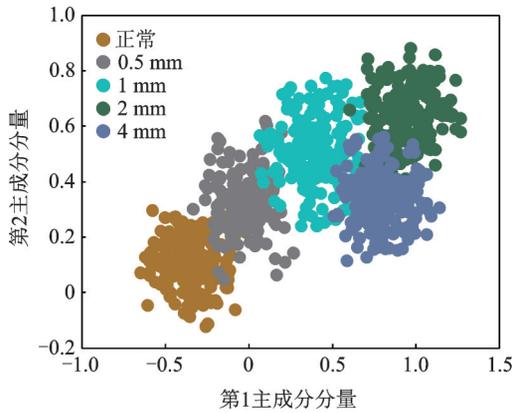
3.2.2 诊断准确率分析

图 9 为 SCAE-ACGAN 在不同负载等级下对正常以及裂纹故障模式下的诊断结果。从图中可以看出,误判主要发生在 0.05 mm 裂纹故障与正常状态之间,主要因为微弱的初始裂纹故障由于振动信号幅值较小,在复杂信号背景下容易受到干扰,尤其是



(a) 振动信号原始频谱特征PCA可视化

(a) PCA visualization of frequency domain features of original vibration signals



(b) SCAE-ACGAN方法提取特征PCA可视化

(b) PCA visualization of features extracted by SCAE-ACGAN

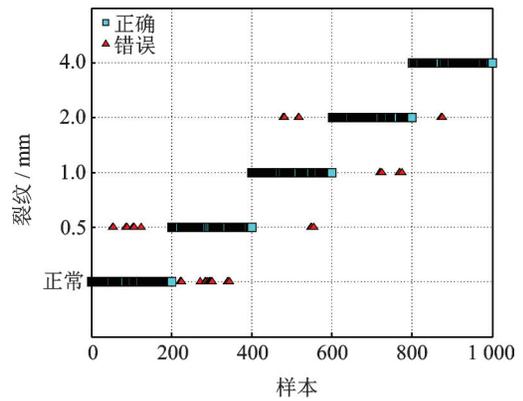
图8 两种方法提取特征的PCA可视化对比结果

Fig.8 PCA visualization results of features extracted by two methods

在低载情况下;但随着负载增大,故障行星齿轮与太阳轮、齿圈啮合过程产生的振动幅值增加,出现误判的样本减少。在相邻裂纹故障之间也出现了少量误判,由于都是裂纹故障,不同裂纹长度引起的振动幅值在复杂信号背景下微弱的幅值差异容易引起混淆,在不同负载等级下这种情况都存在。但整体而言,在4种负载条件下,SCAE-ACGAN的平均诊断准确率达到98.15%。

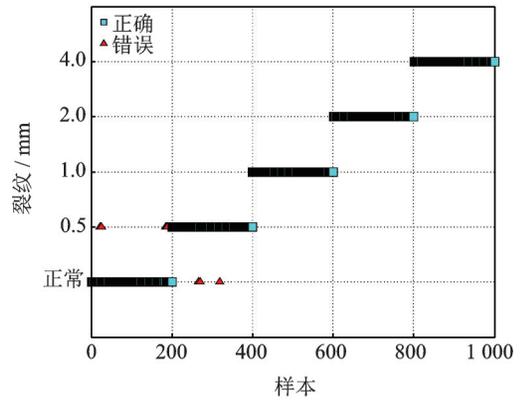
3.3 对比分析

应用深度学习进行直升机行星传动轮系故障诊断面临着样本数量少、样本数据波动两方面的困难,为了突出SCAE-ACGAN在这两种条件下的诊断性能,引入SCAE,SAE与DBN深度学习模型进行对比实验分析。其中,各深度学习模型主要的网络参数与SCAE-ACGAN相同。为减少随机因素的



(a) 空载

(a) Null load



(b) 75%满载

(b) 75% full load

图9 不同负载等级下SCAE-ACGAN故障诊断结果

Fig.9 The diagnosis results of the SCAE-ACGAN under different load levels

影响,实验重复运行5次取平均结果进行对比。

在直升机健康管理系统中衡量故障诊断性能需同时考虑漏警率 P_{MAR} 和虚警率 Q_{FAR} ,因此,笔者采用 F_1 ^[15](无量纲)来综合评价不同方法的故障诊断能力, F_1 越接近1,说明分类器对不同状态模式的诊断能力越强,其计算公式为

$$F_1 = 2 \times \frac{(1 - P_{MAR})(1 - Q_{FAR})}{(1 - P_{MAR}) + (1 - Q_{FAR})} \quad (17)$$

3.3.1 不同样本数量下性能对比

由图10可知,深度学习方法的故障诊断性能随着样本数的增加而逐步提升,而浅层学习方法的故障诊断性能没有出现变化,依旧维持在较低的诊断水平。这表明深度学习通过大量数据样本的训练,能挖掘出频谱信号中隐含的故障敏感信息,实现高质量的故障诊断。另一方面,相比于其他深度学习方法,由于SCAE-ACGAN有机地结合生成器的生成能力与判别器的分类能力,在生成对抗过程中提

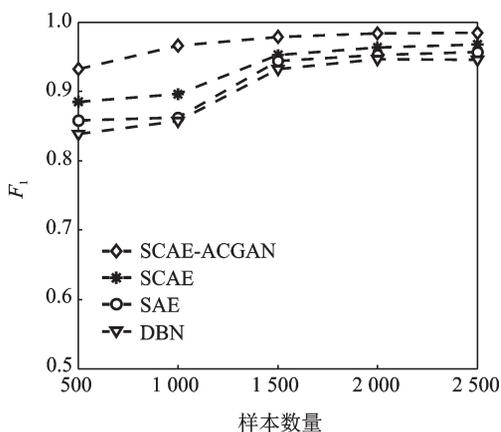


图10 不同样本数量下的诊断结果

Fig.10 The diagnosis results under different sample sizes

升了整个模型的质量,因此在面对样本量较少的情况下,依然可以获得较高的诊断性能。

3.3.2 样本数据波动条件下性能对比

样本数据波动主要来自工况条件的变化:①背景噪声变化;②负载的波动。为了更好地验证方法诊断性能,实验分别在不同的信噪比条件下以及负载波动条件下进行对比分析。

1) 不同信噪比条件下性能对比。为了模拟直升机行星传动轮系运行的噪声环境,在采集的振动信号中加入标准的NoiseX-92舱内噪声,形成不同信噪比进行实验分析,结果如图11所示。信噪比在0 dB及以上,基于深度学习的诊断模型具有较为优异的诊断性能,原因在于深层的无监督学习网络结构对输入数据与故障类别之间的复杂非线性映射具有更强的学习能力。随着信噪比的进一步降低,各方法的诊断性能均有所降低,而相比于SAE与DBN,由于SCAE增加收缩惩罚项,使特征提取函数能抵抗输入扰动,并通过深度学习把握了数据的

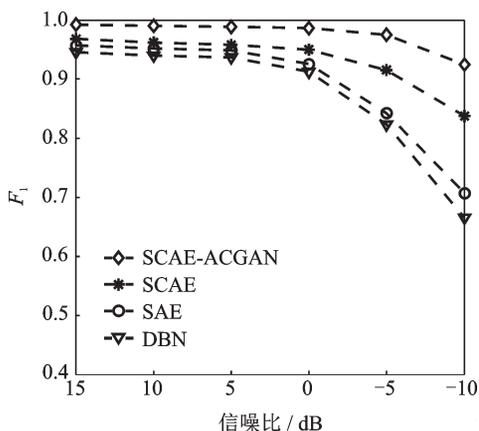


图11 不同信噪比下的诊断结果

Fig.11 The fault diagnosis results under different signal-to-noise ratios

流行结构,在信噪比变化情况下依然维持较高的诊断性能。另外,相比于单独的SCAE,SCAE-ACGAN通过生成对抗学习,进一步增强了SCAE模型的稳定性,挖掘出更具鲁棒性的深度特征,因此获得更优的诊断性能。

2) 负载波动情况下性能对比。用原数据集中50%满负载下的样本训练各学习模型,然后在40%,45%,50%,55%,60%满负载下重新采集测试样本对各方法进行测试,实验结果如图12所示。从图中得知,无论从单个 F_1 结果还是整体数据稳定性,SCAE-ACGAN都优于其他的学习模型。说明通过收缩自动编码,提高了深度模型的抗扰动能力,同时利用生成器生成与真实样本不同但分布相似的生成样本,与真实样本同时输入至判别器进行分类,并基于对抗学习的训练机制,交替迭代优化训练生成器与分类器,加强了模型的泛化能力,提高了诊断性能。

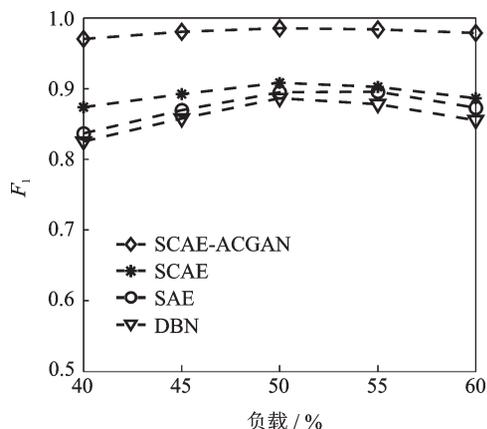


图12 负载波动下的诊断结果

Fig.12 The diagnosis result under load fluctuation

4 结束语

提出了基于SCAE-ACGAN的直升机行星传动轮系裂纹故障诊断方法。SCAE-ACGAN有效利用了判别器SCAE的抗数据扰动能力,提取到了具有优异鲁棒性的深度特征,提高了方法的健壮性和适应性。同时通过ACGAN生成与真实样本具有近似分布的生成样本,扩充了训练样本集。生成器与判别器基于对抗学习方式交替优化,逐步提高了模型的故障诊断性能与泛化能力。在真实的直升机传动轮系实验平台注入了5种裂纹故障模式,在模拟真实运行环境情况下,对SCAE-ACGAN的诊断性能进行了验证,并与浅层学习模型和其他深度学习模型进行了对比分析,验证了SCAE-ACGAN在样本数量少及样本数据波动等情况下相比于其他方法

的优异性能。

参 考 文 献

- [1] 孙灿飞, 王友仁. 直升机行星传动轮系故障诊断研究进展[J]. 航空学报, 2017, 38(7): 106-119.
SUN Canfei, WANG Youren. Advance in the study on fault diagnosis of helicopter planetary gears[J]. Chinese Journal of Aeronautics, 2017, 38(7): 106-119.(in Chinese)
- [2] LEI Y G, LIN J, ZUO M J, et al. Condition monitoring and fault diagnosis of planetary gearboxes: a review[J]. Measurement, 2014, 48:292-305.
- [3] HE G L, DING K, WU X M, et al. Dynamics modeling and vibration modulation signal analysis of wind turbine planetary gearbox with a floating sun gear [J]. Renewable Energy, 2019, 139: 718-729.
- [4] 杨文广, 蒋东翔. 行星齿轮典型断齿故障的动力学仿真[J]. 振动、测试与诊断, 2017, 37(4):756-762.
YANG Wenguang, JIANG Dongxiang. Study of the dynamics of the planetary gear with typical tooth break faults [J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(4): 756-762.(in Chinese)
- [5] 孙灿飞, 王友仁, 沈勇, 等. 基于参数自适应变分模态分解的行星齿轮箱故障诊断[J]. 航空动力学报, 2018, 33(11): 205-214.
SUN Canfei, WANG Youren, SHEN Yong, et al. Fault diagnosis of planetary gearbox based on adaptive parameter variational mode decomposition[J]. Journal of Aerospace Power, 2018, 33(11): 205-214.(in Chinese)
- [6] 赵磊, 郭瑜, 伍星. 基于包络加窗同步平均的行星齿轮箱特征提取[J]. 振动、测试与诊断, 2019, 39(2): 320-326.
ZHAO Lei, GUO Yu, WU Xing. Fault feature extraction of planetary gearboxes based on angle domain windowed synchronous average of the envelope signal[J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(2): 320-326.(in Chinese)
- [7] WANG L M, SHAO Y M. Crack fault classification for planetary gearbox based on feature selection technique and k-means clustering method [J]. Chinese Journal of Mechanical Engineering, 2018, 31 (1) : 242-252.
- [8] LI D D, ZHOU W L, ZHENG X X, et al. Diagnosis and research of wind turbine planetary gearbox faults based on multifractal spectrum support vector machine (SVM) [J]. Power System Protection & Control, 2017, 45(11):43-48.
- [9] TAMILSELVAN P, WANG P F. Failure diagnosis using deep belief learning based health state classification [J]. Reliability Engineering and System Safety, 2013, 115: 124-135.
- [10] 金棋, 王友仁, 王俊. 基于深度学习多样性特征提取与信息融合的行星齿轮箱故障诊断方法[J]. 中国机械工程, 2019, 30(2):74-82.
JIN Qi, WANG Youren, WANG Jun. Planetary gearbox fault diagnosis based on multiple feature extraction and information fusion combined with deep learning[J]. China Mechanical Engineering, 2019, 30(2):74-82.(in Chinese)
- [11] 田晶, 李有儒, 艾延廷. 一种基于Deep-GBM的航空发动机中介轴承故障诊断方法[J]. 航空动力学报, 2019, 34(4):756-763.
TIAN Jin, LI Youru, AI Yanting. Fault diagnosis of aero-engine inter-shaft bearing based on Deep-GBM[J]. Journal of Aerospace Power, 2019, 34(4) : 756-763. (in Chinese)
- [12] RIFAI S, VINCENT P, MULLER X, et al. Contractive auto-encoders: explicit invariance during feature extraction [C] //Proceedings of the International Conference on Machine Learning (ICML).Bellevue, Washington, USA:[s.n.],2011:833-840.
- [13] ODENA A, OLAH C, SHLENS J. Conditional image synthesis with auxiliary classifier GANs[C]// Proceedings of the 34th International Conference on Machine Learning. Sydney, Australia:[s.n.],2017:2642-2651.
- [14] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [15] HUANG Y J, POWERS R, MONTELIONE G T. Protein NMR recall, precision, and F-measure scores (RPF scores) : structure quality assessment measures based on information retrieval statistics[J]. Journal of the American Chemical Society, 2005, 127(6):1665-1674.



第一作者简介:孙灿飞,男,1979年3月生,博士生。主要研究方向为航空装备故障诊断与健康监测。曾发表《直升机行星传动轮系故障诊断研究进展》(《航空学报》2017年第38卷第7期)等论文。
E-mail: suncanfei@samri.com.cn

通信作者简介:王友仁,男,1963年7月生,教授、博士生导师。主要研究方向为检测技术与信号处理、机载设备健康监测及航空设备健康预报技术。
E-mail: wangyurac@nuaa.edu.cn