

文章编号:1006-1355(2021)02-0089-04+124

# 改进的生成对抗网络在轴承故障诊断中的应用

刘 杰, 王昌达, 武秋敏, 胡兵兵

(西安理工大学 印刷包装与数字媒体学院, 西安 710048)

**摘 要:** 研究一种基于改进的生成对抗网络的滚动轴承故障诊断方法。针对传统的生成对抗网络模型无法进行故障诊断的问题, 对其进行改进, 在生成对抗网络基础上加入额外条件信息, 并且在输出层添加辅助输出层, 将生成对抗网络从无监督学习的生成模型改进为监督学习的分类模型。然后, 利用西储大学轴承数据集对改进后的生成对抗网络进行实验验证。结果表明, 改进后的生成对抗网络模型能够有效识别滚动轴承故障类型, 相比于相同结构的人工神经网络故障诊断准确率提高 5.83 %, 达到 99.86 %, 并且可在训练过程中降低对于样本数据长度的依赖性, 有关结论可为生成对抗网络在智能故障诊断中的应用提供理论指导和技术支持。

**关键词:** 故障诊断; 生成对抗网络; 轴承; 智能故障诊断; 监督学习; 分类模型

**中图分类号:** TH133.3; TH165+.3

**文献标志码:** A

**DOI编码:** 10.3969/j.issn.1006-1355.2021.02.014

## Application of Improved Generative Confrontation Network in Bearing Fault Diagnoses

LIU Jie, WANG Changda, WU Qiumin, HU Bingbing

(School of Printing, Packaging and Digital Media, Xi'an University of Technology,  
Xi'an 710048, China)

**Abstract :** An improved method for fault diagnosis of rolling bearings based on generative adversarial networks is proposed. The additional condition information is added to the generative adversarial network, and an auxiliary output layer is added to the main output layer to improve the generative adversarial network. Then, the unsupervised learning generative model is changed to a supervised learning Classification model. Experiments show that the improved generative adversarial network model can effectively identify the type of rolling bearing's faults. Compared with the artificial neural network with the same structure, this method has higher fault diagnosis accuracy and can reduce the dependence on the sample data length during the training process. Conclusion of this work may provide a theoretical guidance and technical support for the application of the generative confrontation network in intelligent fault diagnoses.

**Key words :** fault diagnosis; generative adversarial network; bearing; intelligent fault diagnosis; supervised learning; classification model

滚动轴承作为重要部件被广泛应用于几乎所有类型的旋转机械中。在工业生产的过程中, 高速旋转的机械设备容易造成滚动轴承的故障, 给企业带来巨大的经济损失<sup>[1-2]</sup>。为减少轴承故障带来的

经济损失, 研究一种有效的轴承故障诊断方法是极为必要的。传统故障诊断方法诊断滚动轴承故障的过程主要分为故障特征的提取和分类<sup>[3-4]</sup>, 这些过程都是通过人工提取特征实现, 结果取决于信号处理技术和诊断专家的先验知识。

随着人工智能技术的发展, 机器学习以及深度学习技术已逐渐应用于故障诊断领域, 这些故障诊断方法不再依赖人工提取信号特征, 大大减少了故障诊断的时间以及对信号处理技术的依赖。国内外学者提出了人工神经网络(artificial neural network, ANN)<sup>[5]</sup>、支持向量机(support vector machine, SVM)<sup>[6]</sup>等故障诊断方法。但是 ANN 方法训练时间过长, 收

收稿日期: 2020-05-09

基金项目: 国家自然科学基金资助项目(51905422); 陕西省自然科学基金基础研究计划资助项目(2020JQ-630); 中国博士后科学基金资助项目

作者简介: 王昌达(1993-), 男, 山西省临汾市人, 硕士研究生, 主要研究方向为故障诊断。

通信作者: 刘杰, 男, 博士, 讲师, 主要研究方向为故障诊断、非线性系统辨识和多体动力学。

E-mail: jieliu@xaut.edu.cn

敛速度慢,且易发生过拟合现象<sup>[7-8]</sup>;SVM可以避免神经网络结构选择和局部极小值点问题,但是对非线性问题没有通用的解决方案,并且上述方法均属于浅层机器学习方法,学习能力有限,诊断准确率达到一定高度时很难再有大的提高。造成这一问题的关键因素便是样本数据的大小以及样本的准确性和完备程度。

生成对抗网络(Generative Adversarial Networks, GAN)<sup>[9]</sup>是一种新的人工智能技术,它独特的对抗思想使其在众多的生成器模型中脱颖而出,在图片生成、数据增强等领域都有广泛的应用。在生成对抗网络中,生成器的存在使得样本的大小、完备性等不再成为影响整个网络判别准确率的关键因素。但是在故障诊断中,由于传统的生成对抗网络仍属于无监督学习的生成模型,其判别器仅能判别生成样本的真伪,而不能进行故障类型的识别。因此本文对生成对抗网络模型进行了改进,在原始生成对抗网络基础上添加额外标签信息,并且在输出层添加辅助输出层,使其成为一种监督学习的网络模型,能够在判别样本真伪的同时也能实现样本故障类型的诊断。通过实验验证,改进后的生成对抗网络能够对滚动轴承不同故障进行识别,并且与ANN、SVM以及LSTM相比,改进后的生成对抗网络在采样信号更短的情况下,仍然保持有更高的故障诊断准确率。

## 1 生成对抗网络

2014年,Goodfellow等提出了一种名为生成对抗网络的神经网络模型,其利用对抗的思想,提高了生成图像的分辨率,使得网络能够无监督地学习到数据的概率分布。通过交替训练一个生成器 $G$ 和判别器 $D$ ,生成对抗网络使生成器能够生成以假乱真的样本,而判别器能够对真实和生成的样本进行二分类:真实的样本经过判别器输出趋向于1,而生成器生成的样本输入判别器,得到的结果趋向于0,其模型结构见图1,生成器的输入是随机生成的噪声矢量。生成器通过逐步学习从而生成与训练样本分布相同的数据。判别器的输入是生成的数据或原始数据,其必须区分输入数据是真实的还是生成的。训练生成器和判别器不断更新参数,直到生成器能够反映原始数据的分布。生成对抗网络总体的损失函数 $V(D, G)$ 为

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\log(D(x))] + \dots + E_{z \sim P_z(z)} [\log(1 - D(G(Z)))] \quad (1)$$

其中: $E$ 表示期望值, $P_{\text{data}}$ 表示目标数据的数据分布; $P_z$ 是基底信号的数据分布; $G(Z)$ 表示生成模型生

成的数据; $D(x)$ 表示真实样本通过判别模型后的输出; $D(G(Z))$ 表示生成样本通过判别模型后的输出。

生成对抗网络判别器的损失函数 $J_D$ 表示为

$$J_D = -E_{x \sim P_{\text{data}}(x)} [\log D(x)] - E_{Z \sim P_z(z)} \log [1 - \dots - (G(Z))] \quad (2)$$

生成对抗网络生成器的损失函数 $J_G$ 表示为

$$J_G = -J_D \quad (3)$$

在对生成对抗网络进行训练的过程中,对生成器 $G$ 和判别器 $D$ 交替进行优化,使得生成器的生成样本分布不断趋向于原始样本分布,而判别器通过不断对抗生成器来不断优化自身的判别模型,其模型如图1所示。

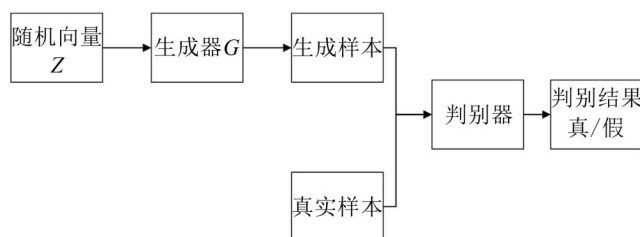


图1 生成对抗网络模型

## 2 生成对抗网络的改进

传统的生成对抗网络模型通过生成器与判别器之间的对抗来优化生成器与判别器中的模型参数,它在图像生成、风格迁移等领域被广泛应用。但是传统的生成对抗网络作为生成模型只能判别生成数据的真伪,不能实现分类。为了在对滚动轴承的故障诊断中,生成对抗网络能够在判别样本真伪的同时对故障准确分类,首先在原始的生成对抗网络的基础上添加标签信息<sup>[10-11]</sup>,其中标签信息来自于真实样本的标签,使得生成对抗网络成为一个监督学习模型,再对生成对抗网络中的判别器模型进行改进,在判别器的输出层中增加一个额外的辅助分类器,从而使得改进后的生成对抗网络成为一个监督学习的分类模型。

在本文改进后的生成对抗网络模型中,判别器含有两个不同的输出层,一层输出层为判别样本真伪的输出层,一层输出层则为输出滚动轴承故障类别的输出层。构建后的整体模型如图2所示。

## 3 构建故障诊断模型

### 3.1 网络结构

本文所提出的改进的生成对抗网络的总体结构如图3所示。其由两个部分组成,分别为生成器部分和判别器部分。在生成器部分包含1个输入层、3个隐层以及1个输出层。在判别器部分包含2个

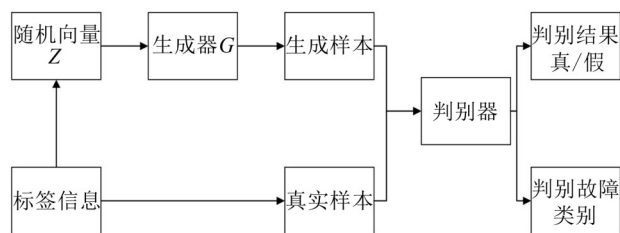


图2 改进后生成对抗网络模型

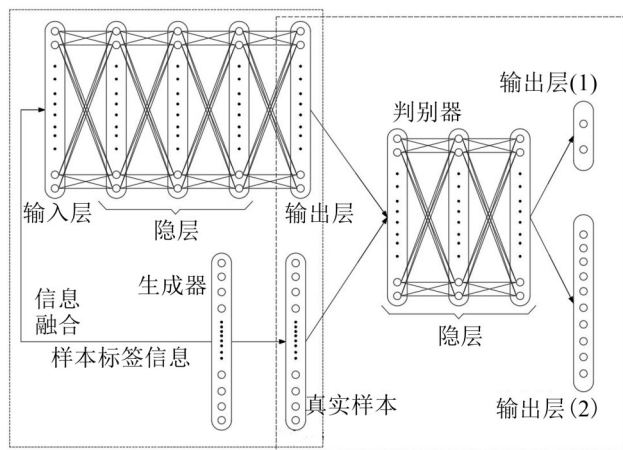


图3 改进后的生成对抗网络结构

输入层、3个隐层以及2个输出层。生成器的输出层与判别器的输入层相连接,共同构成了改进的生成对抗网络结构。

### 3.2 模型的输入输出

文中利用真实样本的标签信息与具有高斯分布的噪声信号融合后的数据作为生成器模型的输入层,经过3个全连接隐层后连接到输出层。其中输入层为100维度的向量,输出层有784个神经元,并且将输出层作为判别器的输入层输入到判别器中。

在判别器模型中输入层分为两部分,一部分为生成器生成的样本数据,即784个神经元的全连接层;另一部分输入层则由真实样本信息与真实标签信息组成的784个神经元的全连接层,将其连接到判别器的隐层。在判别器输出层处判别器的输出层被分为两部分,一部分为判断样本真假的输出层(1);另一部分为诊断滚动轴承故障类别的输出层(2)。

在对生成对抗网络进行训练的过程中,判别器通过输出层(1)的损失函数不断更新判别器中各层权重值,从而与生成器形成对抗,使得生成器的生成样本分布趋向于真实样本分布,而生成器的不断更新同样也使得判别器模型得到优化;同时,判别器通过输出层(2)的损失函数对判别器模型进行故障诊断优化,从而不断提高故障分类的精度。

### 3.3 模型超参数的确定

生成对抗网络模型中的超参数主要包括模型结

构参数和迭代次数等,这些参数的取值会直接影响最终的信号生成结果。

本文使用的改进的生成对抗网络模型中,生成器含有3个隐层,且3个隐层均为全连接层,神经元个数分别为256、512和1024;判别器含有3个隐层,且3个隐层均为全连接层,其中神经元个数分别为512、256和128。在生成器的输出层使用tanh函数作为激活函数;在判别器的输出层(1)中使用sigmoid激活函数,输出层(2)中使用softmax激活函数。在其余每层神经元之间激活函数均使用LeakyRelu函数,学习率均设置为0.2。训练过程中使用批次样本训练的方法,每次选取256个样本进行训练,每个样本的信号长度为784,优化函数使用Adam优化算法。

## 4 基于改进生成对抗网络的轴承故障诊断

### 4.1 实验方案

本文使用的实验数据为凯斯西储大学(Case Western Reserve University, CWRU)轴承数据库的滚动轴承振动加速度数据<sup>[12]</sup>。该滚动轴承故障诊断实验装置由一个扭矩仪、一个功率计、一个三相异步电动机等组成,如图4所示。样本数据包含了采样频率为12 kHz时的3种不同故障类型信号以及1种正常振动信号,对应的4种状态分别为:正常状态、内圈故障、外圈故障、滚动体故障。每种故障类型按不同的故障直径又分为3类,故障直径分别为0.18 mm、0.36 mm和0.54 mm,即数据集总共包含9类故障数据和1类正常数据。

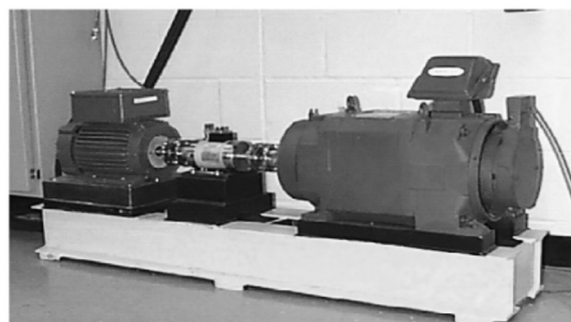


图4 实验装置照片

数据集总共包含20 000个样本,每类故障有2 000个样本及标签信息。将样本数据集划分为用以训练生成对抗网络模型的14 000个样本组成的训练集和用来测试模型中判别器的准确率的6 000个样本组成的测试集。

在训练集中每类故障有700个样本,每个样本包含784个采样点,共7 000个总样本。训练集的详

细信息如表1所示。

表1 样本训练集数据

轴承状态	故障直径/mm	用于测试的样本数目	分类标签
正常(NL)	0	700	0
外圈故障	0.18	700	1
外圈故障	0.36	700	2
外圈故障	0.54	700	3
内圈故障	0.18	700	4
内圈故障	0.36	700	5
内圈故障	0.54	700	6
滚珠故障	0.18	700	7
滚珠故障	0.36	700	8
滚珠故障	0.54	700	9

将处理后的样本输入到改进后的生成对抗网络中进行网络模型的训练,设置迭代次数为5 000次,生成器和判别器在迭代过程中互相对抗学习,以此提高判别器的故障诊断准确率,最后得到训练完毕后改进的生成对抗网络模型及该模型的准确率。

## 4.2 实验结果

本文构建了与生成对抗网络中判别器相同模型的人工神经网络(ANN),并且通过使用支持向量机(SVM)以及长短期记忆神经网络(LSTM)对相同的数据集进行故障诊断测试,对比结果如表2所示。

表2 对于相同测试集不同方法测试结果对比

方法	采样点数/个	准确率/(%)
改进GAN	784	99.86
ANN	784	94.03
SVM <sup>[13]</sup>	6 000	85.71
LSTM <sup>[13]</sup>	1 200	93.05

从表2可以看出,改进后的生成对抗网络在进行故障诊断时准确率可以达到99.86%,这表明改进后的生成对抗网络可以进行故障类别的诊断,并且在滚动轴承故障诊断中达到了较高的准确率。

对比改进后的生成对抗网络和人工神经网络,改进后生成对抗网络中的判别器与人工神经网络有着相同的3层全连接层神经网络,并且有相同的神经元以及各超参数,在相同的数据集下,样本采样点数均设置为784个,但是从表2可以看出,改进后的生成对抗网络的故障类别诊断准确率相比人工神经网络的故障类别诊断准确率有较大的提升,这正是由于改进后生成对抗网络中判别器通过与生成器不断对抗,经过多次的相互迭代优化,最终使得判别器的诊断效果达到更优。

从表2还可以看出,支持向量机所使用的采样点数为6 000个,其对应的准确率为85.71%,长短期记忆神经网络所使用的采样点数为1 200个,其对应的准确率为93.05%,然而,本文所提出的生成对抗网络却能在较少的采样点下达到更高的故障诊断准确率,这表明改进的生成对抗网络与传统机器学习方法相比在进行轴承故障诊断时对样本数据长度依赖性更小,且仍然保持有较高的故障诊断准确率。

改进后的生成对抗网络模型在轴承故障诊断中的准确率对比人工神经网络、支持向量机以及长短期记忆神经网络均有不同程度的提升,但是仍未能达到百分之百的准确率,存在一定误差,这是由于在改进后生成对抗网络训练过程中所生成样本里可能存在异常样本,从而产生了一定的误差。

## 5 结语

(1) 本文通过对传统的生成对抗网络进行改进,在传统生成对抗网络中添加条件信息以及在输出层增加辅助分类层,使其从原来的无监督生成模型转向监督学习的分类模型,从而使得生成对抗网络能够应用于轴承故障诊断中。

(2) 使用美国凯斯西储大学的轴承数据集进行实验,实验结果表明改进后的生成对抗网络模型能够实现对滚动轴承不同故障的分类,并且故障诊断的准确率有较大的提高。

(3) 与传统的支持向量机、长短期记忆神经网络进行实验对比,发现改进后的生成对抗网络在保持更高故障诊断准确率的同时,减少了对样本信号长度的依赖,在一定程度上减少了对样本数量的需求。

参考文献:

- [1] JIANG L, SHI T, XUAN J. Fault diagnosis of rolling bearings based on Marginal Fisher analysis[J]. Journal of Vibration and Control, 2014, 20(3): 470-480.
- [2] BRANDON VAN HECKE. Bearing fault diagnosis based on a new acoustic emission sensor technique[J]. Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability, 2015, 229(2): 105-118.
- [3] 赵晨. 基于VMD的滚动轴承故障诊断研究[D]. 兰州: 兰州交通大学, 2017.
- [4] 庄雨璇, 李奇, 杨冰如, 等. 基于LSTM的轴承故障诊断端到端方法[J]. 噪声与振动控制, 2019, 39(6): 187-193.
- [5] GAUTAM C, RAVI V. Counter propagation auto-associative neural network based data imputation[J]. Information Sciences, 2015, 325: 288-299.

(下转第124页)