

# 基于 S 变换和卷积神经网络的滚动轴承故障诊断

王庆荣, 杨磊\*, 王松松

兰州交通大学电子与信息工程学院, 甘肃 兰州 730070

**摘要** 针对传统方法在机械故障诊断时存在特征提取困难、分类器训练复杂等问题, 提出了一种基于 S 变换和卷积神经网络(CNN)的滚动轴承故障诊断方法。首先, 将轴承的原始数据经过 S 变换得到时频图, 再通过 CNN 进行二次特征提取。然后, 通过分类器对故障进行分类, 并对滚动轴承进行故障诊断。实验结果表明, 相比长短时记忆网络、CNN 和支持向量机, 该方法的诊断准确率更高且稳定性也较好。

**关键词** 信号处理; S 变换; 卷积神经网络; 长短时记忆网络; 支持向量机; 故障诊断

中图分类号 TP183

文献标志码 A

doi: 10.3788/LOP202158.2207001

## Fault Diagnosis of Rolling Bearing Based on S-Transform and Convolutional Neural Network

Wang Qingrong, Yang Lei\*, Wang Songsong

College of Electrical and Information Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China

**Abstract** To address the issues associated with traditional methods for mechanical fault diagnosis, such as difficulties in feature extraction and complex classifier training, we proposed a rolling bearing fault diagnosis method based on S-transform and the convolutional neural network (CNN). First, the original data of the bearing were subjected to S-transform to obtain a time-frequency image. Then, secondary feature extraction was performed using the CNN. Next, fault classification was conducted using the classifier and the fault diagnosis of the rolling bearing was performed. Experimental results show that compared with long short-term memory networks, CNN, and support vector machine, the proposed method achieves higher diagnostic accuracy and better stability.

**Key words** signal processing; S-transform; convolutional neural network; long short-term memory network; fault diagnosis

**OCIS codes** 070.2025; 060.3735; 070.1060

## 1 引言

滚动轴承作为机械传动装置的关键组件之一, 运行环境特别恶劣, 且会严重影响机械设备的使用周期, 对机械设备的正常和可靠运行起着至关重要的作用。滚动轴承也是机械传动组件中最容易发生故障的部件之一, 原因是滚动轴承在机械传动时起着承受负荷、减少摩擦的作用, 其运行状态会直接影响整台设备的性能<sup>[1-2]</sup>。

滚动轴承在设备运行时所处的环境复杂, 其振动信号包含噪声且具有非线性和非平稳性的特点, 容易存在提取特征不充分的问题, 进一步增大了故障识别的难度<sup>[3]</sup>。因此, 提取到更充分的故障特征尤为重要。通常用传统的时域分析法提取振动信号的特征量, 但信号的特征在时域和频域都有所体现, 而时域分析法在频域中的分辨率为 0, 无法充分提取信号的故障特征<sup>[4]</sup>。傅里叶变换法对平稳信号的处理效果较好, 但该方法无法处理振动信号<sup>[5]</sup>。小

收稿日期: 2020-11-30; 修回日期: 2021-01-08; 录用日期: 2021-01-21

基金项目: 教育部人文社会科学研究规划基金(15XJAZH002, 18YJAZH148)、甘肃省自然科学基金(18JR3RA125)

通信作者: \*1285412275@qq.com

波变换法存在选取基本小波困难和数据冗余度大的问题<sup>[6]</sup>。S 变换结合了傅里叶变换和小波变换的优点,具有良好的时频性,在处理非平稳信号和非线性信号时能充分提取到信号特征量<sup>[7]</sup>。深度学习<sup>[8]</sup>能自适应提取到更有价值的信号特征量,得到了人们的广泛研究。吴春志等<sup>[9]</sup>直接将轴承的原始振动信号输入一维卷积神经网络(CNN)中学习特征并进行故障识别,虽然特征提取效果较好<sup>[10]</sup>,但存在特征冗余问题<sup>[11]</sup>。陈伟等<sup>[12]</sup>直接将轴承的原始振动数据作为深层长短时记忆(LSTM)网络的输入,充分利用了 LSTM 网络对时间序列优异的处理能力。但单纯从时域角度提取故障特征的方式容易丢失频域信息的特征,导致提取的特征不充分。李恒等<sup>[13]</sup>对于噪声干扰情况下的非平稳非线性轴承信号提出了一种基于短时傅里叶变换和 CNN 的故障诊断方法,识别精度较高。时培明等<sup>[14]</sup>将原始数据通过 S 变换得到特征矩阵,再将特征向量输入到稀疏自动编码器中进一步提取特征,最终通过神经网络实现分类,识别效果较好。但通过 S 变换得到的是二维高阶矩阵,计算量极大。

综上所述,通过时频分析和深度学习相结合的方法能充分提取更详细的故障特征,进而对不同故障进行识别,达到很好的识别效果。S 变换相比其他典型的时频分析方法具有更好的时频性,而 CNN 作为深度学习领域的神经网络<sup>[15]</sup>可以直接对二维图像进行处理,在图像处理方面得到了广泛的应用,并取得了较多的研究成果。该网络通过简单的非线性模型从原始图像中提取出更加抽象的特征,且在整个过程中只需少量的人工参与。因此,本文采用 CNN 对 S 变换后的时频特征向量进行二次特征提取和分类,在 S 变换处理非平稳和非线

性信号的基础上提出了一种新的滚动轴承故障诊断方法。首先通过 S 变换进行时频分析得到特征图,再将特征图输入 CNN 中进行二次特征提取,最后将二次提取的特征输入到分类器中实现滚动轴承不同故障类别的识别,从而完成滚动轴承的故障诊断。

## 2 相关理论

### 2.1 S 变换

S 变换改善了短时傅里叶变换和连续小波变换的缺点并继承了两者的优点,采用高斯窗函数(窗宽与频率成反比)避免了窗函数选择和窗宽固定的不足,其时频表示中各频率分量的相位谱与原始信号有直接联系,可适用于非平稳信号的处理<sup>[16-17]</sup>。信号  $x(t)$  的连续 S 变换可表示为

$$S(\tau, f) = \int_{-\infty}^{+\infty} x(t)\omega(t-\tau)\exp(-i \cdot 2\pi ft)dt, \quad (1)$$

$$\omega(t-\tau, f) = \frac{|f|}{\sqrt{2\pi}} \exp [f^2(t-\tau)/2], \quad (2)$$

式中,  $\omega(t-\tau, f)$  为高斯窗函数,  $\tau$  为平移因子,可控制高斯窗在时间  $t$  轴上的位置,  $f$  为信号的频率。可以发现, S 变换的窗函数与短时傅里叶变换不同,其使用的高斯窗函数为  $\sigma = 1/|f|$ , 窗宽与频率成反比,随频率的变化而变化,从而改善短时傅里叶变换窗口高度和宽度一致的缺点。令

$$\tau = mT, \quad (3)$$

$$f = n/(NT), \quad (4)$$

式中,  $T$  为采样周期,  $N$  为采样点数,  $m$  和  $n$  分别为时间采样点序号和频率采样点序号,取值均为自然数  $0, \dots, N-1$ 。根据(1)式得到 S 变换的离散形式为

$$\begin{cases} S\left(mT, \frac{n}{NT}\right) = \sum_{k=0}^{N-1} X\left(\frac{k+n}{NT}\right) \exp(-2\pi^2 k^2/n) \exp(i \cdot 2\pi mk/N), & n \neq 0 \\ S(mT, 0) = \frac{1}{N} \sum_{m=0}^{N-1} x(mT), & n = 0 \end{cases}, \quad (5)$$

$$X(k) = \frac{1}{N} \sum_{m=1}^{N-1} x(m) \exp(-i \cdot 2\pi km/N), \quad (6)$$

式中,  $k$  为频谱的频点,取自然数  $0, \dots, N-1$ ,  $X(k)$  为时间序列  $x(m)$  的离散傅里叶变换。对信号进行离散 S 变换,结果为一个二维矩阵  $\mathbf{A}$ , 其中,横坐标为时间,纵坐标为频率,  $\mathbf{A}$  中的元素为复数,可表示为

$$\mathbf{A} = S[x(t)] = \begin{bmatrix} t_1 f_n & \cdots & f_m f_n \\ \vdots & & \vdots \\ t_1 f_1 & \cdots & t_m f_1 \end{bmatrix}, \quad (7)$$

式中,  $S$  为 Stockwell 变换,  $t_k f_j$  为二维矩阵的幅值,  $k \in (1, m), j \in (1, n)$ 。

## 2.2 卷积神经网络

CNN<sup>[18]</sup> 是一种前馈神经网络,其结构如图 1 所示。其中,C 表示卷积层,S 表示下采样层,F 表示




图 1 CNN 的结构

Fig. 1 Structure of the CNN

### 2.2.1 卷积层

卷积层由卷积核组成,卷积核可起到滤波器的作用,提取输入的局部特征,然后通过卷积核在输入特征图谱上的滑动得到全局信息。卷积层具有稀疏连接和局部权值共享两大点。这种操作可减少网络需要训练的参数量,加快网络的收敛速度。卷积层的数学模型可表示为

$$\mathbf{X}_j^l = f\left(\sum_{i \in M_j} \mathbf{X}_i^{l-1} \cdot \mathbf{w}_{ij}^l + \mathbf{b}_j^l\right), \quad (8)$$

式中, $\mathbf{X}$  为卷积层的输入, $M_j$  为  $l-1$  层输出特征图集合, $\mathbf{w}$  为对应卷积核的权重矩阵, $\mathbf{b}$  为偏置项, $l$  为卷积层数, $i$  和  $j$  为两个相连的神经元, $f$  为激活函数,可提高网络的非线性表达能力。CNN 常用的激活函数为线性整流单元(ReLU),可表示为

$$f(x) = \max\{0, \log[1 + \exp(x)]\}. \quad (9)$$

可以发现,当输入小于 0 时,函数对神经元有抑制作用,在反向传播时不会更新神经元的权值。因此,采用 Leaky\_ReLU 代替 ReLU 函数<sup>[19-20]</sup>,可表示为

$$f(x) = \begin{cases} x, & x > 0 \\ \sigma x, & x \leq 0 \end{cases}, \sigma \in (0, 1), \quad (10)$$

式中, $\sigma$  为根据实际经验选取的参数,取 0~0.5 时的效果最佳<sup>[19]</sup>。

### 2.2.2 池化层

池化层也被称为下采样层,主要是对输入进行压缩降维,以减少网络的参数,提高网络的训练速度。池化层只进行了降维操作,没有参数,不需要进行权值更新,可表示为

$$\mathbf{y} = p[X_{\text{down}}(\mathbf{x}_i^{l-1}) + \mathbf{b}_j^l], \quad (11)$$

式中, $\mathbf{y}$  为池化层输出, $X_{\text{down}}$  为下采样函数, $\mathbf{x}$  为输入。

全连接层。此外,CNN 还包括一个输入层和一个输出层,相比其他深度神经网络,CNN 还具有局部感受野、权值共享以及池化特点。

### 2.2.3 全连接层

网络输出层之前为全连接层。全连接层的本质是一个全连接网络,即网络中的每个神经元都与不同层数的其他神经元相连接,在整个网络中的参数最多。其数学模型可表示为

$$\mathbf{y} = f(\mathbf{w} \cdot \mathbf{x} + \mathbf{b}), \quad (12)$$

式中, $\mathbf{y}$  为输出矩阵, $\mathbf{x}$  为输入矩阵, $f$  为激活函数,在多分类任务中,通常选用 Softmax 函数。

### 2.2.4 反向传播更新参数

先计算损失函数<sup>[21]</sup>对每一层中每个参数的一阶偏导数,并用梯度下降算法逐层更新网络的权值和偏置,直到损失函数收敛或达到设定的迭代次数。通常选择最小均方误差函数作为损失函数,可表示为

$$E = \frac{1}{2} \sum_{k=1}^n (t_k^n - y_k^n)^2 = \frac{1}{2} \|\mathbf{t}^n - \mathbf{y}^n\|^2, \quad (13)$$

式中, $E$  为损失函数, $n$  为样本数, $t_k$  为第  $k$  次实际输出值, $y_k$  为第  $k$  次的预测值, $\mathbf{t}$  为网络实际输出值, $\mathbf{y}$  为网络期望输出值。梯度下降过程可表示为

$$\begin{cases} \mathbf{w}' = \mathbf{w} - \alpha \frac{\partial E}{\partial \mathbf{w}} \\ \mathbf{b}' = \mathbf{b} - \alpha \frac{\partial E}{\partial \mathbf{b}} \end{cases}, \quad (14)$$

式中, $\mathbf{w}'$  和  $\mathbf{b}'$  为迭代一次后的权值和偏置, $\mathbf{w}$  和  $\mathbf{b}$  为前一次的权值和偏置, $\alpha$  为学习率,可决定参数更新过程的步长。

## 3 基于 S 变换和改进 CNN 的滚动轴承故障诊断模型

本模型的流程如图 2 所示。故障诊断步骤:

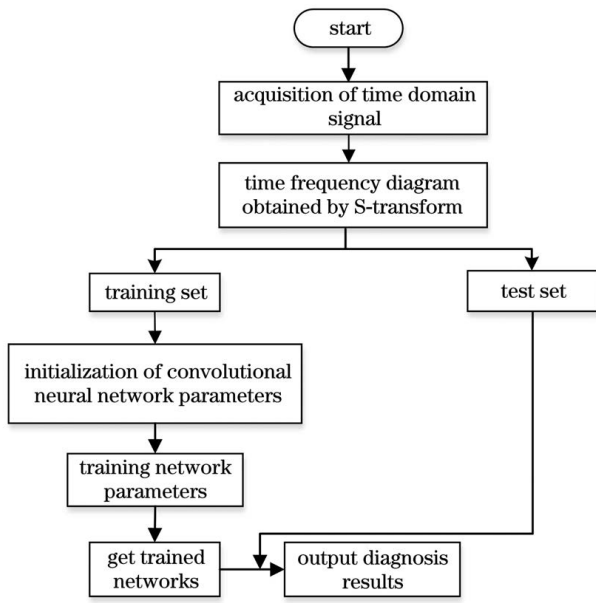


图 2 模型流程图

Fig. 2 Flow chart of the model

- 1) 选取不同故障的原始振动信号进行故障分类;
- 2) 对原始时域信号进行 S 变换, 得到二维时频图, 并将对应时频图调整到合适的尺寸;
- 3) 将得到的二维时频图随机按一定比例分为训练集和测试集;
- 4) 搭建 CNN 模型, 并初始化网络参数;
- 5) 利用训练集训练 CNN, 通过梯度下降法更新网络的权重和偏置, 直到损失函数收敛;
- 6) 用测试集验证训练好的网络性能;
- 7) 得到网络的识别结果。

## 4 实例分析

凯斯西储大学(CWRU)轴承中心数据采集系统由风扇端轴承、功率为 1.5 kW 的电动机、驱动端

轴承、扭矩传感器/译码器、测功器五大部分组成, 如图 3 所示。采集轴承数据时一般选用风扇端和驱动端轴承, 驱动端轴承为 SKF6205, 采样频率为 12 kHz 和 48 kHz; 风扇端轴承为 SKF6203, 采样频率为 12 kHz。实验选取驱动端轴承作为采集故障数据的对象, 利用加速度传感器测量轴承的振动加速度信号。




图 3 CWRU 滚动轴承数据采集系统<sup>[22]</sup>

Fig. 3 CWRU rolling bearing data acquisition system<sup>[22]</sup>

### 4.1 实验数据

实验数据为 CWRU 采集的滚动轴承数据, 主要对实际轴承故障诊断中常见的内圈、外圈和滚动体故障信号进行分析。振动信号的采样频率为 12 kHz, 负载为 1.49 kW, 选取 0.1778、0.3556、0.5334 mm 故障下的正常信号(Norm)、内圈(IR)、外圈(OR)、滚动体(B)故障共 10 种故障类型作为实验数据, 数据集包括 20000 个样本数据。其中, 每种故障状态包含 2000 个样本, 每个样本由 1024 个采样点组成。随机选取 80% 的数据作为训练集, 剩下 20% 的数据作为测试集, 故障数据如表 1 所示。对滚动轴承故障采用独热(One-hot)编码方法, 如表 2 所示。

表 1 实验数据

Table 1 Experimental data

Type	Bearing condition	Fault diameter /mm	Data length	Number of samples	Load	Speed / (r · min <sup>-1</sup> )
1	norm	0	1024	2000	2	1797
2	slight damage to inner ring	0.1778	1024	2000	2	1797
3	moderate damage of inner ring	0.3556	1024	2000	2	1797
4	severe damage of inner ring	0.5334	1024	2000	2	1797
5	slight damage of rolling element	0.1778	1024	2000	2	1797
6	moderate damage of rolling element	0.3556	1024	2000	2	1797
7	rolling weight injury	0.5334	1024	2000	2	1797
8	slight damage of outer ring	0.1778	1024	2000	2	1797
9	slight damage of outer ring	0.3556	1024	2000	2	1797
10	slight damage of outer ring	0.5334	1024	2000	2	1797

表 2 故障编码  
Table 2 Fault code

Fault location	Fault diameter /mm	Code name	Label
None	0	a	100000000
Rolling element+inner ring	0.1778	b	010000000
Rolling element+outer ring	0.3556	c	001000000
Rolling element+outer ring	0.5334	d	001000000
Inner ring	0.1778	e	000100000
Inner ring	0.3556	f	000010000
Inner ring	0.5334	g	000001000
Outer ring	0.1778	i	000000100
Outer ring	0.3556	j	000000010
Outer ring	0.5334	k	000000001

基于 Windows 操作系统, Intel i7、3.6 GHz 处理器, 利用 Matlab7.0 正式版 v7.0 仿真平台对采集的故障数据进行数据预处理, 在 TensorFlow2.0 框架下利用 Python 语言搭建 CNN 模型。对 10 种故障状态进行仿真, 得到不同状态下的时域振动信号, 正常信号、内圈、外圈、滚动体故障的时域信号图如图 4 所示。可以发现, 10 种时域信号只能反映时域

角度下的故障特征, 从中提取的特征不能完全表达滚动轴承的故障特征。因此, 选取 S 变换对时域信号进行处理, 得到对应的时频图如图 5 所示。可以发现, 时域信号经 S 变换后得到的二维特征矩阵包含不同故障的全部故障信息, 为故障分类提供了充分的特征。对 10 种时频图进行灰度化处理后的结果如图 6 所示。

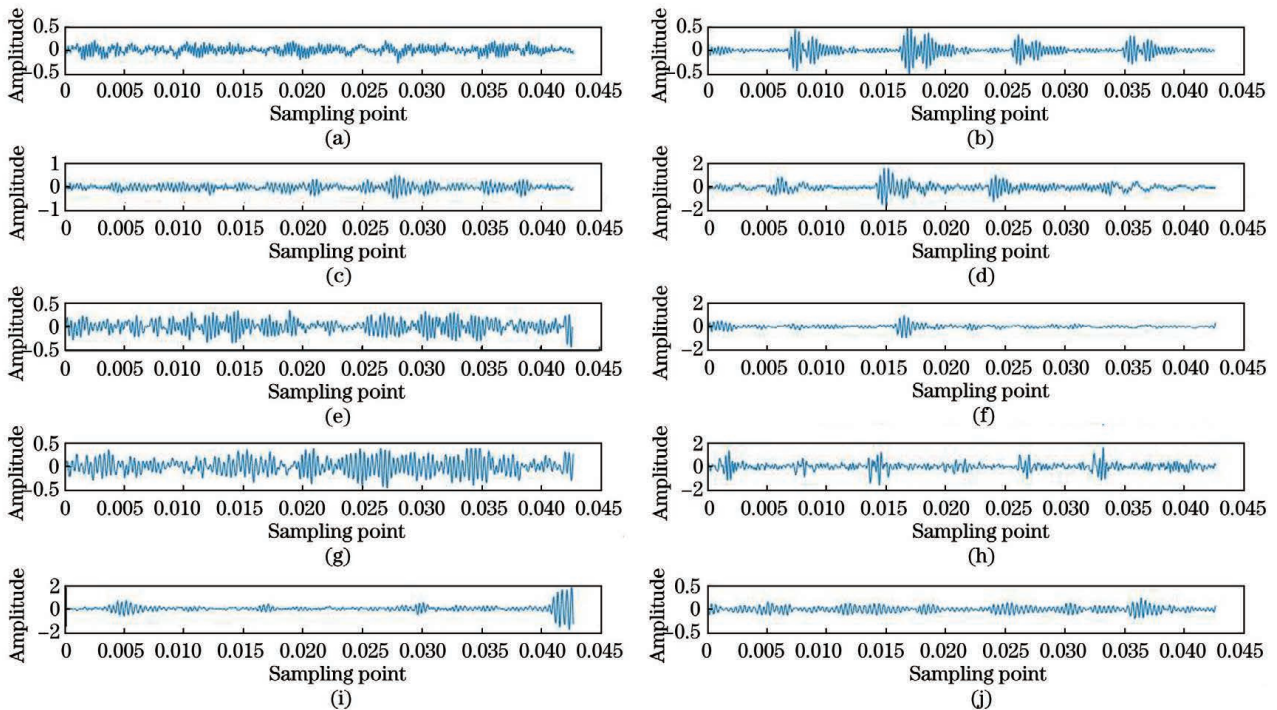


图 4 10 种仿真信号。(a)正常信号;(b)OR 0.1778 nm;(c)OR 0.3556 mm;(d)OR 0.5334 mm;(e)B 0.1778 nm;  
(f)B 0.3556 mm;(g)B 0.5334 mm;(h)IR 0.1778 nm;(i)IR 0.3556 mm;(j)IR 0.5334 mm

Fig. 4 Ten kinds of simulation signal diagrams. (a) Normal signal; (b) OR 0.1778 nm; (c) OR 0.3556 mm; (d) OR 0.5334 mm; (e) B 0.1778 nm; (f) B 0.3556 mm; (g) B 0.5334 mm; (h) IR 0.1778 nm; (i) IR 0.3556 mm; (j) IR 0.5334 mm




图 5 10 种时域信号的时频变换结果。(a)正常信号;(b)OR 0.1778 nm;(c)OR 0.3556 mm;(d)OR 0.5334 mm;  
(e)B 0.1778 nm;(f)B 0.3556 mm;(g)B 0.5334 mm;(h)IR 0.1778 nm;(i)IR 0.3556 mm;(j)IR 0.5334 mm

Fig. 5 Time frequency transformation results of 10 kinds of time domain signals. (a) Normal signal; (b) OR 0.1778 nm; (c) OR 0.3556 mm; (d) OR 0.5334 mm; (e) B 0.1778 nm; (f) B 0.3556 mm; (g) B 0.5334 mm; (h) IR 0.1778 nm; (i) IR 0.3556 mm; (j) IR 0.5334 mm




图 6 10 种时频图的灰度化结果。(a)正常信号;(b)OR 0.1778 nm;(c)OR 0.3556 mm;(d)OR 0.5334 mm;(e)B 0.1778 nm;  
(f)B 0.3556 mm;(g)B 0.5334 mm;(h)IR 0.1778 nm;(i)IR 0.3556 mm;(j)IR 0.5334 mm

Fig. 6 Graying results of 10 kinds of frequency images. (a) Normal signal; (b) OR 0.1778 nm; (c) OR 0.3556 mm; (d) OR 0.5334 mm; (e) B 0.1778 nm; (f) B 0.3556 mm; (g) B 0.5334 mm; (h) IR 0.1778 nm; (i) IR 0.3556 mm; (j) IR 0.5334 mm

## 4.2 卷积神经网络的参数

CNN 的参数选取对网络的诊断性能有很大的影响,网络参数既包含训练的参数,也包含人为设定的超参数。因此,需要综合考虑准确率<sup>[23]</sup>和程序运行时间选取网络的参数。准确率是正确样本占总样本个数的比例,能直观衡量分类性能好坏,可表示为

$$X_{\text{Accuracy}} = \frac{X_{\text{TP}}}{X_{\text{TP}} + X_{\text{FP}}}, \quad (15)$$

式中,  $X_{\text{TP}}$  为正样本个数,  $X_{\text{FP}}$  为负样本个数。

### 4.2.1 学习率的选取

表 3 为不同学习率下网络的准确率,可以发现,学习率过大或过小都会影响网络的性能。学习率过大时,会提升初期收敛速度,但当损失达到一定值时会错过最优点。学习率过小时,网络的收敛速度变低,容易陷入局部最优。综合考虑后,实验选择的学习率为 0.005。

表 3 不同学习率对网络性能的影响

Table 3 Effects of different learning rates on network performance

Learning rate	Accuracy /%	Training time /s
1	69.64	134
0.1	34.42	128
0.05	73.03	132
0.005	99.87	127
0.001	91.01	144

#### 4.2.2 Batchsize 的选取

Batchsize 为一次输入样本的数量,一次输入较多的样本数量虽然可以缩短训练时间,但诊断准确率会有明显降低;反之,网络可以学习到更详细的故障特征,但训练时间较长。因此,过多或过少的 Batchsize 对网络的整体性能都有很大的影响。表 4 为不同 Batchsize 对网络性能的影响,可以发现,选用的 Batchsize 为 16 时,网络的性能最好。

表 4 不同 Batchsize 对网络性能的影响

Table 4 Effects of different Batchsize on network performance

Batchsize	Accuracy /%	Training time /s
8	99.81	226
16	99.62	141
32	91.38	237
64	88.76	124
128	80.52	138

#### 4.2.3 卷积核的选取

实验设置的卷积核数量为 8,采样宽度为  $2 \times 2$ 。表 5 为不同卷积核尺寸对网络性能的影响,可以发现,网络的准确率随卷积核尺寸的增大逐渐变小,综

表 6 CNN 的结构参数

Table 6 Structural parameters of the CNN

Network layer type	Specific parameter	Network layer output
Input	input of time-frequency diagram	$32 \times 32$
C1	$3 \times 3$ convolution kernels(32), in steps of 1	$30 \times 30 \times 32$
S1	maximum pool $2 \times 2$ cores, in steps of 1	$15 \times 15 \times 32$
C2	$3 \times 3$ convolution kernels(32), in steps of 2	$13 \times 13 \times 32$
S2	maximum pool $2 \times 2$ cores, in steps of 2	$7 \times 7 \times 32$
FC	1568 nodes	$1 \times 1568$
Softmax	10-classification	$1 \times 10$

表 5 不同卷积核对网络性能的影响

Table 5 Effects of different convolution kernel on network performance

Convolution kernel size	Accuracy /%	Training time /s
$3 \times 3$	98.7	84
$5 \times 5$	93.2	98
$8 \times 8$	92.4	79
$12 \times 12$	91.8	77

合考虑后选取的卷积核尺寸为  $3 \times 3$ 。

#### 4.2.4 激活函数的选取

对传统 CNN 的激活函数进行改进,将常用的 ReLU 函数替换为 Leaky\_ReLU,当参数  $\sigma$  为 0.3 时,两种激活函数的对比结果如图 7 所示。可以发现,使用 Leaky\_ReLU 时网络的收敛速度和稳定性都具有明显优势。

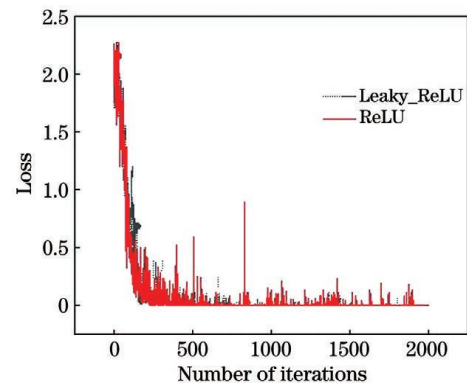


图 7 两种激活函数的实验结果

Fig. 7 Experimental results of two activation functions

### 4.3 卷积神经网络的结构

网络训练时设置的学习率为 0.05, Batchsize 的大小为 16,卷积核的数量为 32 个,卷积核的尺寸为  $3 \times 3$ ,采样尺寸为  $2 \times 2$ ,激活函数为 Leaky\_ReLU,建立的 CNN 结构如表 6 所示。

#### 4.4 网络的性能验证

图 8 为结合 S 变化和 CNN(S-transform-CNN) 以及单独 CNN 的性能,可以发现,结合 S 变化和 CNN 的最高准确率能达到 99.7%,且网络的稳定性较高,而直接将一维时域信号输入 CNN 的准确率只有 81.07%。

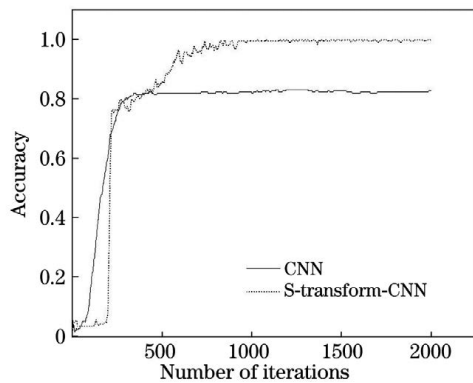


图 8 不同网络的实验结果

Fig. 8 Experimental results of different networks

将本模型的性能与相同条件下的 3 种传统网络模型进行对比,包括 CNN 模型(输入为时域信号)、LSTM 网络模型(含有两层结构,每层结构包括 64 个单元,全连接层神经元的数量为 64 个,输入为时域信号)以及支持向量机(SVM)模型(采用 RBF 核函数,提取故障信号的能量比、峭度、能量算子、波峰因子等 10 个常用特征作为输入)。在相同条件下进行 15 次实验,结果如图 9 所示。可以发现,本模型的准确率明显高于其他模型,最高可达到 99.8%;且网络稳定性也明显优于其他模型。此外,CNN 模型的准确率最高为 81.2%,稳定性相对较低;LSTM 网络模型的准确率最高为 83.7%,稳定性较差,原因是故障数据是人为损伤后在实验平台进行数据采集的,每个时间段的数据相关性不大,而 LSTM 网络依赖于之前的记忆;SVM 模型的诊断




图 9 4 种网络的性能对比

Fig. 9 Performance comparison of 4 types of networks

准确率最高达到 87.04%,且稳定性较差。综上所述,相比其他 3 种方法,本方法在诊断准确率和诊断稳定性上均有一定的优势。

## 5 结 论

提出了一种基于 S 变换和 CNN 的滚动轴承故障诊断方法。实例分析结果表明,在处理非平稳以及非线性的振动信号时,S 变换能够充分提取故障信号在时域和频域的所有信息。结合 CNN 对提取特征进行降维,并通过分类器准确判断出滚动轴承的不同故障类型,可使模型对不同故障有很好的分辨能力,且相比传统方法具有更高的诊断精度。但实验使用的数据故障种类较少,很难识别出新的故障类型,因此,还需进一步研究该模型存在的缺陷。

## 参 考 文 献

- [1] Hu Q Z, Zhang S L, Yang S. Variable condition bearing fault diagnosis based on time-domain and artificial intelligence [J]. Applied Mechanics and Materials, 2012, 203: 329-333.
- [2] Chen Y, An W Y, Liu H L, et al. Detection method using FBG sensing signal to diagnose rolling bearing fault[J]. Chinese Journal of Lasers, 2020, 47(11): 1104004.  
陈勇, 安汪悦, 刘焕淋, 等. 利用 FBG 传感信号诊断滚动轴承故障的检测方法[J]. 中国激光, 2020, 47(11): 1104004.
- [3] Chen Y, Chen Y W, Liu Z Q, et al. A gear fault detection method based on a fiber Bragg grating sensor[J]. Chinese Journal of Lasers, 2020, 47(3): 0304007.  
陈勇, 陈亚武, 刘志强, 等. 基于光纤布拉格光栅传感的齿轮故障检测方法[J]. 中国激光, 2020, 47(3): 0304007.
- [4] Wu T, Yuan S C, Meng X, et al. Vibrating diagnosis of rolling bearings based on self-organizing feature map neural network[J]. Machinery Design & Manufacture, 2010(1): 198-200.  
吴涛, 原思聪, 孟欣, 等. 滚动轴承振动诊断的 SOM 神经网络方法[J]. 机械设计与制造, 2010(1): 198-200.
- [5] Chen Z, Hu Y Q, Tian S Q, et al. Non-stationary signal combined analysis based fault diagnosis method [J]. Journal on Communications, 2020, 41(5): 187-195.  
陈哲, 胡玉其, 田世庆, 等. 基于非平稳信号组合分析的故障诊断方法[J]. 通信学报, 2020, 41(5):



- 187-195.
- [6] Kankar P K, Sharma S C, Harsha S P. Rolling element bearing fault diagnosis using wavelet transform [J]. *Neurocomputing*, 2011, 74 (10): 1638-1645.
- [7] Stockwell R G, Mansinha L, Lowe R P. Localization of the complex spectrum: the S transform [J]. *IEEE Transactions on Signal Processing*, 1996, 44 (4): 998-1001.
- [8] Liu D, Li Y C. Quality assessment of remote sensing images based on deep learning and human visual system [J]. *Laser & Optoelectronics Progress*, 2019, 56(6): 061101.  
刘迪, 李迎春. 基于深度学习和人眼视觉系统的遥感图像质量评价 [J]. *激光与光电子学进展*, 2019, 56 (6): 061101.
- [9] Wu C Z, Jiang P C, Feng F Z, et al. Faults diagnosis method for gearboxes based on a 1-D convolutional neural network [J]. *Journal of Vibration and Shock*, 2018, 37(22): 51-56.  
吴春志, 江鹏程, 冯辅周, 等. 基于一维卷积神经网络的齿轮箱故障诊断 [J]. *振动与冲击*, 2018, 37 (22): 51-56.
- [10] Chen R X, Huang X, Yang L X, et al. Rolling bearing fault identification based on convolution neural network and discrete wavelet transform [J]. *Journal of Vibration Engineering*, 2018, 31(5): 883-891.  
陈仁祥, 黄鑫, 杨黎霞, 等. 基于卷积神经网络和离散小波变换的滚动轴承故障诊断 [J]. *振动工程学报*, 2018, 31(5): 883-891.
- [11] Yang T. Study on dynamic characteristics of new marine RV gearbox [D]. Harbin: Harbin Institute of Technology, 2016: 20-28.  
杨通. 船用新型 RV 传动齿轮箱动力学特性研究 [D]. 哈尔滨: 哈尔滨工业大学, 2016: 20-28.
- [12] Chen W, Chen J X, Jiang Y Q, et al. Fault identification of rolling bearing based on RS-LSTM [J]. *China Sciencepaper*, 2018, 13(10): 1134-1141.  
陈伟, 陈锦雄, 江永全, 等. 基于 RS-LSTM 的滚动轴承故障识别 [J]. *中国科技论文*, 2018, 13(10): 1134-1141.
- [13] Li H, Zhang Q, Qin X R, et al. Fault diagnosis method for rolling bearings based on short-time Fourier transform and convolution neural network [J]. *Journal of Vibration and Shock*, 2018, 37(19): 124-131.  
李恒, 张氢, 秦仙蓉, 等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法 [J]. *振动与冲击*, 2018, 37(19): 124-131.
- [14] Shi P M, Su G H, Yin X D. Research on rolling bearing fault diagnosis method based on combination of S transform and deep learning [J]. *Modern Manufacturing Engineering*, 2019(7): 125-130.  
时培明, 苏冠华, 殷晓迪. 基于 S 变换与深度学习相结合的滚动轴承故障诊断方法研究 [J]. *现代制造工程*, 2019(7): 125-130.
- [15] Tang Q, Wang Y N, Guo S Y, et al. Power quality disturbance detection based on S-transform and PNN [J]. *Chinese Journal of Scientific Instrument*, 2009, 30(8): 1668-1673.  
唐求, 王耀南, 郭斯羽, 等. 基于 S 变换与 PNN 的电能质量多扰动检测 [J]. *仪器仪表学报*, 2009, 30 (8): 1668-1673.
- [16] Liu H Y, Tian G, Shi Z J. The comparison of time-frequency analysis methods and their applications [J]. *Computerized Tomography Theory and Applications*, 2015, 24(2): 199-208.  
刘海燕, 田钢, 石战结. 几种时频分析方法的比较和实际应用 [J]. *CT 理论与应用研究*, 2015, 24(2): 199-208.
- [17] Liu J W, Liu Y, Luo X L. Research and development on deep learning [J]. *Application Research of Computers*, 2014, 31(7): 1921-1930, 1942.  
刘建伟, 刘媛, 罗雄麟. 深度学习研究进展 [J]. *计算机应用研究*, 2014, 31(7): 1921-1930, 1942.
- [18] He Z C, Zhao L Z, Chen C. Convolution neural network with multi-resolution feature fusion for facial expression recognition [J]. *Laser & Optoelectronics Progress*, 2018, 55(7): 071503.  
何志超, 赵龙章, 陈闯. 用于人脸表情识别的多分辨率特征融合卷积神经网络 [J]. *激光与光电子学进展*, 2018, 55(7): 071503.
- [19] Haykin S, Kosko B. Gradient-based learning applied to document recognition [M]. New York: IEEE Press, 2001: 306-351.
- [20] Wang J X, Lei Z C. A convolutional neural network based on feature fusion for face recognition [J]. *Laser & Optoelectronics Progress*, 2020, 57 (10): 101508.  
王嘉欣, 雷志春. 一种基于特征融合的卷积神经网络人脸识别算法 [J]. *激光与光电子学进展*, 2020, 57 (10): 101508.
- [21] Guo Y F, Quan W M, Wang W Y, et al. Crack diagnosis method of wind turbine blade based on convolution neural network with 3D vibration information fusion [J]. *Acta Optica Sinica*, 2020, 40 (22): 2212004.  
郭迎福, 全伟铭, 王文韞, 等. 基于三维振动信息融合的卷积神经网络风力机叶片裂纹诊断方法 [J]. *光学学报*, 2020, 40(22): 2212004.
- [22] Zhang W F, Zhou J. Fault diagnosis method of

rolling bearing based on Dropout-CNN [J]. Light Industry Machinery, 2019, 37(2): 62-67.

张文风, 周俊. 基于 Dropout-CNN 的滚动轴承故障诊断研究[J]. 轻工机械, 2019, 37(2): 62-67.

[23] Meng Z Q, Dong S J, Pan X J, et al. Fault diagnosis of bolling bearing based on improved convolutional

neural network [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020(2): 79-83.

蒙志强, 董绍江, 潘雪娇, 等. 基于改进卷积神经网络的滚动轴承故障诊断[J]. 组合机床与自动化加工技术, 2020(2): 79-83.