

刘佳明, 胡盛斌, 卢帅多, 等. 基于数据特征重构和迁移学习的滚动轴承故障诊断方法[J]. 智能计算机与应用, 2025, 15(4): 102–107. DOI: 10.20169/j.issn.2095–2163.250413

# 基于数据特征重构和迁移学习的滚动轴承故障诊断方法

刘佳明, 胡盛斌, 卢帅多, 杜振安

(上海工程技术大学 航空运输学院(飞行学院), 上海 201620)

**摘要:** 滚动轴承是工业设备中的重要零部件, 快速地对其进行故障诊断对设备安全来说至关重要, 为此提出了一种基于数据特征重构和迁移学习的故障诊断方法 WT–GoogleNet–BF, 并利用滚动轴承验证了该方法的可行性。首先, 利用连续小波变换将轴承振动的一维信号转换为二维尺度图; 其次, 将二维尺度图作为预训练的改进 GoogleNet 网络的输入; 最后, 利用凯斯西储大学的轴承数据集对提出的网络进行实验, 结果表明 WT–GoogleNet–BF 模型比其他网络的诊断效果更好, 诊断速度也较快。

**关键词:** 滚动轴承; 数据特征重构; 迁移学习; 故障诊断

中图分类号: TP183

文献标志码: A

文章编号: 2095–2163(2025)04–0102–06

## Rolling bearing fault diagnosis method based on data feature reconstruction and transfer learning

LIU Jiaming, HU Shengbin, LU Shuaiduo, DU Zhen'an

(School of Air Transportation and School of Flying, Shanghai University of Engineering Science, Shanghai 201620, China)

**Abstract:** Rolling bearing is an important part of industrial equipment, and its rapid fault diagnosis is critical to equipment safety. Therefore, a fault diagnosis method WT–GoogleNet–BF based on data feature reconstruction and migration learning is proposed, and the feasibility of this method is verified by rolling bearing. Firstly, the one-dimensional signal of bearing vibration is transformed into a two-dimensional scale image by using continuous wavelet transform. Secondly, the two-dimensional scale map is used as the input of the improved GoogleNet network for pre training. Finally, the WT–GoogleNet–BF model is tested with the bearing data set of Case Western Reserve University, and the results show that the WT–GoogleNet–BF model has better diagnostic effect and faster diagnostic speed than other networks.

**Key words:** rolling bearing; data feature reconstruction; transfer learning; fault diagnosis

## 0 引言

滚动轴承作为旋转机械的重要组成部件, 大量应用于各种机械设备中, 因此对其开展研究尤显重要。由于滚动轴承的结构特性和工作特点, 使其较为容易出现塑性变形、酸性液体腐蚀、安装不当以及磨损等问题, 这些情况都会导致滚动轴承失效, 进而引发整个设备的失效、甚至造成重大安全事故, 所以对滚动轴承故障进行诊断分类即已成为了学术界的技术研发重点。在滚动轴承的运行期间, 滚子以由滚动体数量、滚动体直径、轴承中径、滚动体接触角和轴承速度等多参数共同决定的频率通过缺陷处时, 会产生脉冲

振动信号, 而且由于缺陷所处位置的不同, 振动信号的特征也有所不同, 因此就可以基于振动信号检测技术来进行故障诊断分析。同时考虑到轴承特征信号的频带分布很宽, 在工业场景中极易受到噪声的干扰, 又由于滚动轴承的振动信号都是非线性、且不平稳, 所以对其进行特征提取就存在不小的难度。如何设计有效的特征提取方法并对滚动轴承进行故障诊断也仍然是近年来的领域研究热点。

目前, 大量的科研专家对滚动轴承故障诊断进行了深入研究, 并且取得了不少成果。Zhang 等学者<sup>[1]</sup>利用卷积神经网络(CNN)和模糊 C 均值(FCM)聚类算法, 提出了一种新的滚动轴承未标记数据的智能故障诊断方法。首先利用 CNN 对无标

**作者简介:** 刘佳明(1998—), 男, 硕士研究生, 主要研究方向: 滚动轴承故障诊断, 深度学习; 卢帅多(1997—), 男, 硕士研究生, 主要研究方向: 四旋翼无人机编队控制; 杜振安(1999—), 男, 硕士研究生, 主要研究方向: 四旋翼无人机编队控制。

**通信作者:** 胡盛斌(1973—), 男, 博士, 副教授, 主要研究方向: 四旋翼无人机编队控制, 多智能体, 故障诊断等。Email: 65740824@qq.com。

收稿日期: 2023–10–10

哈尔滨工业大学主办 ◆ 系统开发与应用

签数据集提取特征,再用 PCA 对特征进行降维,最后用 FCM 算法进行聚类分析,识别出滚动轴承的不同故障类型。黄宇斐等学者<sup>[2]</sup>提出了一种基于主成分分析与支持向量机的故障诊断算法,先运用主成分分析对原始数据进行降维,提取前 5 个主成分,再用支持向量机比较不同核函数的故障诊断准确度。Liu 等学者<sup>[3]</sup>在小样本情况下使用谐波算法优化支持向量机进行故障分类,并取得了预期结果。殷海双等学者<sup>[4]</sup>提出了一种基于轻量化深度卷积神经网络的电机轴承故障诊断,取得了良好的诊断效果,与机器学习的方法相比,此方法在进行故障诊断时,具有更高的诊断精度。

随着深度学习的不断发展,同时考虑到卷积神经网络强大的特征表示能力和提取能力,使得深度卷积网络现已广泛应用于故障诊断领域。Liu 等学者<sup>[5]</sup>提出了一种基于改进卷积神经网络的滚动轴承故障诊断方法,获得了很好的故障诊断效果。Liu 等学者<sup>[6]</sup>提出了一种基于优化深度残差网络 SE-RESNET-26 的列车运行部件滚动轴承故障诊断方法,实现高精度的智能故障诊断。王瑞东等学者<sup>[7]</sup>提出了一种基于多输出一维卷积神经网络的轴承故障诊断方法,显著提高了诊断的准确性和效率。

综上所述,基于机器学习或者基于深度卷积网络的故障诊断方法取得了优异的诊断结果,然而深度学习在小样本情况下学习的准确率比大样本要低,此时卷积神经网络进行特征提取的效果会受到影响。基于此,本文提出了一种基于小波变换数据特征重构和深度迁移学习的故障诊断方法。本文的内容安排如下。第 1 节介绍了需要用到的小波变换方法、预训练 GoogleNet 的迁移学习。第 2 节,用凯斯西储大学的轴承数据集为实验对象,验证了所提出方法的可靠性和优越性。在第 3 节,得出结论并提出对未来的展望。

## 1 理论基础

在本节中提出了一种基于数据特征重构和深度迁移学习的滚动轴承故障诊断的方法。该方法由 2 个部分组成:首先,通过连续小波变换提取滚动轴承原始振动信号的特征,将其构建成二维的标度图,用于深度神经网络的输入,并使用预训练的 GoogleNet 函数进行迁移学习收敛模型。接下来将对此展开研究论述。

### 1.1 数据特征重构

通常振动信号传感器收集的数据是一维信号,

而图像是一个二维数据矩阵<sup>[8]</sup>。相较于一维信号的模糊的内在特征,二维数据矩阵可以包含更丰富的特征信息,因此本文将原始的一维振动信号转换为二维尺度图作为神经网络的输入。此外,卷积神经网络的原理就是模仿了人类的视觉提取系统<sup>[9]</sup>,对于人类而言,从图像中而非抽象数据中学习特征更容易。这就意味着二维图像比一维的数据更适合作为卷积神经网络的输入。目前,短时傅里叶变换已广泛应用于将一维数据信号转换为二维图像过程中,但是短时傅里叶变换的窗口大小是不可变化的,而且还不具备自适应能力。小波变换克服了这些不足,在短时傅里叶变换的基础上加了一个尺度因子,通过时移因子与尺度因子的调节,动态地改变窗长,达到时间精度与频率精度的平衡,最终实现信号中的瞬时频率信息的提取,非常适合用于不稳定信号的分析。

若函数  $\psi(x) \in L^1 \cap L^2$ , 满足如下公式:

$$C_{\psi} = \int_{\mathbb{R}} \frac{|\hat{\psi}(\omega)|}{|\omega|} d\omega < \infty \quad (1)$$

由此可得:

$$\Psi_{a,b}(x) = |a|^{-\frac{1}{2}} \Psi\left(\frac{x-b}{a}\right) \quad (2)$$

函数  $f(x) \in L^2$  的小波变换的定义式为:

$$W_f(a,b) = (f, \Psi_{a,b}) = |a|^{-\frac{1}{2}} \int_{\mathbb{R}} f(x) \Psi\left(\frac{x-b}{a}\right) dx \quad (3)$$

其中,  $f(x)$  表示原始信号;  $\Psi$  表示小波母函数;  $a$  表示尺度因子;  $b$  表示平移因子。 $a$  和  $b$  都是连续变量,所以称为连续小波变换。

### 1.2 基于迁移学习和改进 GoogleNet 的故障诊断方法

#### 1.2.1 GoogleNet

GoogleNet 是一种具有 22 层结构的深度卷积神经网络<sup>[10]</sup>,因其设计了一种名为 Inception 的独特模块单元,使得 GoogleNet 相较于传统的 AlexNet 和 LeNet 网络在具有更小的网络单元的同时,展现出更优越的性能。

Inception 模块如图 1 所示。该模块由  $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$  等 3 个常用卷积和  $3 \times 3$  池化组成。多尺度的卷积核在并行处理解决如下问题,即目标不管在图像中占据多大的位置,或是占据整个图像、一部分图像还是一小部分图像,总有一个尺度的卷积核可以捕捉到图像的特征,这是多尺度并行的 Inception 模块的思路<sup>[11]</sup>。另外,分析可知,  $1 \times 1$  卷积核不仅能够降低参数数量,而且还起到了跨通道信息交融、增

加网络非线性的作用。




图 1 Inception 模块  
Fig. 1 Inception module

GoogleNet 网络中还有一个全局平均池化层,该层的运用则使得进行迁移学习微调时将更加方便。当需要把 GoogleNet 迁移到其他的数据集时,用 Inception 模型作为基模型,需要将原来的分类层去掉换成其它的分层,再在数据集上只训练新加的这个分类层,此时使用全局平均池化的方法,就明显减少了全连接层参数数量。

1.2.2 基于改进 GoogleNet 的深度迁移学习

迁移学习是指将已经用大量数据训练好的模型泛化到其它的数据集,用来解决其它的问题。迁移学习可以让本次研究中仅用很少的数据来训练模型。迁移学习设计如图 2 所示。本文用到的 GoogleNet 是在图像网络数据集上事先预训练过的,以获得初始化的深度模型。




图 2 迁移学习  
Fig. 2 Transfer learning

2 模型的改进

为了使得 GoogleNet 模型在小样本情况下进行迁移学习的故障诊断准确率得到保证,需要对网络进行改进,让其准确率更高。改进的 GoogleNet 模型除了用到常规的卷积和 Inception 模块,还在分类层之前引入了 1×1 的卷积层和批归一化层,分类层则继续沿用全局平均池化层代替全连接层来融合学到的深度特性,从而达到汇聚各个通道的信息、增加模型深度、提高模型非线性表达能力和稳定性的效果,并且使得模型在样本较小时故障诊断准确率更高。

除了最后 3 层外,其余结构被转移到新的轴承数据集环境中,称为冻结层。最后 3 层包含一个全局平均池化层、一个 dropout 层、一个 loss3 - classifier、prob 和 output,可用于将网络提取的功能组合为类概率和标签信息。

2.1 批归一化层

在数据进入分类层前先进入批归一化层,将数据进行等效变换,变换到一个以 0 为均值、以 1 为方差的范围内,这样来统一规整的数据更容易让模型学习到数据之间的规律。BN 层的引入,降低了数据之间的绝对差异,还具有一个去相关的性质,更多地考虑了相对差异性,因此在分类任务上能取得更好的效果。

设输入数值集合  $B = \{x_1, x_2, \dots, x_m\}$ , 计算该数值集合的均值  $\mu_B$  和方差  $\sigma_B$ :

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \tag{4}$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \tag{5}$$

正则化的公式可表示为:

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \tag{6}$$

其中,  $\varepsilon$  表示偏置,设置为固定值。输出的公式具体如下:

$$y_i = \gamma \hat{x}_i + \beta \tag{7}$$

其中,  $\gamma$ 、 $\beta$  表示需要学习的参数。

2.2 故障诊断模型

GoogleNet 网络的问世是为了解决类似 ImageNet 这种大规模数据集的,该网络对多类别图像的分类效果尤为显著。本文将故障轴承的振动信号通过小波变换转换成二维图像并根据图像的特点,在原始 GoogleNet 的基础上设计了一个适用于滚动轴承故障分类的网络结构。面对滚动轴承故障分



类问题时,为了使网络能够更细致地提取振动信号特征,模型就要具备一定的深度来使模型的表达能力得到增强<sup>[12]</sup>,而 GoogleNet 具有 22 层网络结构,同时利用了 9 个 Inception 模块来增加网络的宽度和深度,因此适合用来解决这个问题。为了解决工业场景下提取信号含有大量噪声的问题,本文还对原有网络进行了改进。改进模型在最后一个 Inception 模块的输出后使用 1×1 的卷积汇聚各个通道的信息,并且进行降维,在 1×1 卷积和分类层之间添加了批归一化层,降低了数据之间的绝对差异,同时还辅以一个去相关的性质,更多地考虑相对差异性。分类层则由一个全局平均池化层、一个 dropout 层、一个 loss3-classifier、prob 和 output。为了使网络收敛速度更快、更稳定,故障诊断准确率更高,将原来的 dropout 层的概率由 0.4 调整为 0.6,增加随机性、防止过拟合,又将原来全连接层的权重学习率因子和偏差学习率因子改为 5,学习率改为 0.000 1。将改进后的网络命名为 WT-GoogleNet-BF,并将其作为滚动轴承故障诊断的网络。

### 3 实验和结果分析

为了验证所提出 WT-GoogleNet-BF 模型的有效性和优越性,本文选择凯斯西储大学轴承故障诊断数据集作为实验对象,并以诊断准确度 (Acc) 作为测试指标用于评价 WT-GoogleNet-BF 模型的性能。

#### 3.1 实验设置和数据描述

本文选择的是凯斯西储大学公共轴承状况数据集。该数据集所用的实验设备由感应电机、扭矩传感器/编码器和测力计等主要部分组成。待测轴承分别为驱动端轴承和风扇端轴承。本文的研究对象是驱动端轴承。分别对轴承在正常和故障状态下进行测试,包括正常、内圈故障、球缺陷和外圈故障。本文考虑了 11 种状况下的故障分类,详见表 1。具体而言,就是在 12 kHz 和 48 kHz 的采样频率的设置场景中,在 4 种负载条件下采集振动信号。

把轴承数据归类为:12k Drive End Bearing Fault Data-0.007、12k Drive End Bearing Fault Data-0.021、48k Drive End Bearing Fault Data-0.007、48k Drive End Bearing Fault Data-0.021 和 Normal Baseline Data。前 4 个文件夹包含 20 条数据,最后 1 个文件夹包含 4 条数据,每条数据含有:基座振动数据、驱动端轴承振动数据、风扇端轴承振动数据。选取驱动端数据,其余舍去。这样选出 84 条数据,对应分为 11 类,即:B007; B021; I007; I021; O071;

O072; O073; O211; O212; O213; NORM。最后,将这些数据进行 5 等分分割,变成 420 条数据。

表 1 轴承状况分类表

| Table 1 Classification table of bearing conditions |      |      |
|----------------------------------------------------|------|------|
| 健康状况                                               | 类别名  | 分类标签 |
| 正常                                                 | NORM | 0    |
|                                                    | B007 | 1    |
| 球缺陷                                                | B021 | 2    |
|                                                    | I007 | 3    |
| 内圈故障                                               | I021 | 4    |
|                                                    | O071 | 5    |
| 外圈故障                                               | O072 | 6    |
|                                                    | O073 | 7    |
|                                                    | O211 | 8    |
|                                                    | O212 | 9    |
|                                                    | O213 | 10   |

#### 3.2 模型评估指标

通常故障诊断算法的性能需要用到 Acc 评估指标来进行判断,评估指标的使用对于数据分析来说具有重要意义。在故障诊断领域,准确度 Acc 是最常用的评估指标。Acc 的值越接近 1,即总样本中的正确预测的比率越大<sup>[13]</sup>,分类器的性能越好。Acc 的定义为:

$$Acc = \frac{TP + TN}{TP + TN + FN + FP}$$

(8)

其中,TP 表示分类中的真阳性;TN 表示分类中的真阴性;FP 表示分类中的假阳性;FN 表示分类中的假阴性。

在此基础上,为使评估指标趋于严谨与全面,本文还选用了混淆矩阵来评估分类器的性能。混淆矩阵达到以下效果,即真阳性条件下判断测试是否为阳性、真阴性条件下判断测试是否为阴性、真阴性条件下判断测试是否为阳性和真阳性条件下判断测试是否为阴性。如此即可准确计算出模型正确判断了多少样本以及错误判断了多少样本。

#### 3.3 所提出方法中超参数的选择

基于深度学习的故障诊断模型受模型中超参数的影响很大。然而,到目前为止,还没有普适性的方法来确定合适的超参数使得模型性能更优。本文基于经验和实验结果,对模型中超参数的选择进行研究。

本文选择的第一个超参数是小波函数移动窗口的初始大小。如果移动窗口的尺寸太小,所包含的数据点就太少,捕获故障的特征分布的能力就弱。如果移动窗口的尺寸太大,样本的数量就会变少,该深度学习网络就会产生过拟合的现象。为了选择合适的初始窗长,将初始窗长大小设置为 100、500、1 000 和 1 500。不同初始窗长下模型的准确率见表 2,当初始窗长大小为 1 000 时,测试精度最高。因

此,本文将初始窗长设置为 1 000。

表 2 不同初始窗长下模型的准确率

Table 2 The accuracy of the model under different initial window

| 初始窗长  | 100   | 500   | 1 000  | 1 500 |
|-------|-------|-------|--------|-------|
| 准确率/% | 97.62 | 98.81 | 100.00 | 96.42 |

本文选择的第 2 个超参数是小波基函数的类型。当使用小波变换进行信号处理时,选择不同的小波基函数得到的处理结果会有一些细微的不同,而这些细微的不同在输入后面的神经网络时往往会对输出产生影响。然而,目前,小波基函数的选择不是严格定量的,通常涉及到正交性、紧支性、对称性、正则性和高阶消失矩之间的比较。在本文中,通过比较 3 种常用的小波基函数的结果,研究了小波基函数对测试精度的影响。表 3 显示了在 Haar、sym4、Morlet、Coif5 和 bior3.7 下所提出的 WT-GoogleNet-BF 模型的测试精度。从表 3 中可以看出,当使用 Coif5 基函数时,WT-GoogleNet-BF 模型诊断结果最好。

表 3 选用不同小波基函数的模型准确率

Table 3 Model accuracy using different wavelet basis functions

| 小波基函数 | Haar  | sym4  | Morlet | Coif5  | bior3.7 |
|-------|-------|-------|--------|--------|---------|
| 准确率/% | 96.43 | 97.62 | 96.73  | 100.00 | 98.81   |

3.4 数据集与数据特征重构

由实验可知,使用 Coif5 小波基函数时故障诊断的准确率最高,所以本文用 Morlet 函数做小波基,将轴承的原始振动信号转换为比例图,如此即可更好地提取时频特征,而后再将提取的时频特征作为深度学习的输入。将训练集和测试集的所有信号进行小波变换,获取轴承正常状态、外圈故障、内圈故障和球缺陷的时频图,如图 3(a)~(d)所示。





图 3 4 种故障的时频图

Fig. 3 Time frequency diagrams of four types of faults

3.5 故障诊断

不同的神经网络模型在训练同一样本时分类的效果不同,为了显示建立的 WT-GoogleNet-BF 模型的优越性,本文使用未改进的 GoogleNet、SqueezeNet、ResNet18 和 Xception 网络进行迁移学习。

由于这些网络都是用图像网络数据集进行预训练过的,在应用到轴承数据集时需要根据输出分类差异对网络进行微调。因此,需要将网络中最后一个可学习的卷积层的滤波器数量等同于类的数量,本文设定的 11,接着需要替换原始的输出层,删除原始分类层并替换新层。

为了加快训练速度,将 GoogleNet、Xception 和 SqueezeNet 的优化器设置为 sgdm,ResNet18 的优化器设置为 adam;为了更加便于确定迁移层的学习率,将 GoogleNet、SqueezeNet、ResNet18 和 Xception 的初始学习率设为 0.000 1。

本文针对 5 种网络进行了实验,每种方法的诊断效果如图 4 所示。值得注意的是,本文提出的 WT-GoogleNet-BF 诊断准确度达到 100%,这与其他 4 种网络相比具有显著的优越性。

不同的 5 个网络用于轴承故障诊断的准确率和网络运行时间见表 4。由表 4 中可以看出,本文建立的 WT-GoogleNet-BF 模型相比于其他的网络有更高的预测准确率,达到了 100%;相比于 GoogleNet、SqueezeNet、ResNet18 和 Xception 网络准确率提高了 1.19%、10.71%、1.19% 和 5.95%。在运行时间方面,WT-GoogleNet-BF 模型虽然不是最快速的,但是仍然达到了比较快速的水平。




图 4 不同网络的故障诊断准确度

Fig. 4 Accuracy of fault diagnosis for different networks

表 4 性能指标结果

Table 4 Performance indicator results

| 网络              | 准确率/%  | 运行时间/s |
|-----------------|--------|--------|
| WT-GoogleNet-BF | 100.00 | 87     |
| GoogleNet       | 98.81  | 92     |
| Xception        | 89.29  | 642    |
| SqueezeNet      | 98.81  | 36     |
| ResNet18        | 94.05  | 100    |

WT-GoogleNet-BF 模型的混淆矩阵如图 5 所示。由图 5 可看到故障诊断样本为 0, 证明本文所提出的 WT-GoogleNet-BF 模型在准确诊断上有着较好的可靠性。




图 5 混淆矩阵

Fig. 5 Confusion matrix

4 结束语

本文以滚动轴承为实验对象, 对其进行故障诊断研究。提出了一种基于数据特征重构和迁移学习的故障诊断模型 WT-GoogleNet-BF。为了可以使用先进的卷积神经网络, 本文将故障轴承原始的一维振动信号通过小波变换转换为二维时频图, 作为卷积神经网络的输入。

同时, 本文采用了迁移学习的方法, 在 GoogleNet 网络的基础上进行改进, 添加了 1×1 的卷积层和批归

一化层, 提出了 WT-GoogleNet-BF 故障诊断模型, 并进行了实验, 证明了该模型的可行性和优越性。  
本文所提出的方法还有一些局限性, 对在噪声环境下提取的轴承信号的故障分类效果还未臻致理想, 在这方面还有待后续的改进与提升。

参考文献

[1] ZHANG Dan, CHEN Yongyi, GUO Fanghong, et al. A new interpretable learning method for fault diagnosis of rolling bearings [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3507010.

[2] 黄宇斐, 石新发, 贺石中, 等. 一种基于主成分分析与支持向量机的风电齿轮箱故障诊断方法[J]. 热能动力工程, 2022, 37(10): 175-181.

[3] LIU Lin, SHA Yun, ZHANG Qingfei. Bearing fault diagnosis analysis based on improved adaptive search algorithms and SVMs [C]//Proceedings of the 5<sup>th</sup> International Conference on Automation, Control and Robotics Engineering. Piscataway, NJ: IEEE, 2020: 680-684.

[4] 殷海双, 牛智楷. 基于轻量化深度卷积神经网络的电机轴承故障诊断[J]. 组合机床与自动化加工技术, 2022(11): 97-100.

[5] LIU X, XIA X, SONG J. Research on fault diagnosis method of rolling bearing based on improved convolutional neural network [C]//Proceedings of the 11<sup>th</sup> International Conference of Information and Communication Technology. Piscataway, NJ: IEEE, 2022: 214-218.

[6] LIU Chenyu, HE Daqiang, CHEN Yanjun, et al. Rolling bearing fault diagnosis of train running gear based on optimized deep residual network [C]//Proceedings of the 5<sup>th</sup> International Conference on Automation, Control and Robots. Nanning, China: Guangxi University, 2021: 168-172.

[7] 王瑞东, 王永强, 李敏. 基于多输出一维卷积神经网络的轴承故障诊断[J]. 信息技术与信息化, 2022(9): 185-188.

[8] WANG Zongyao, WEI Shangguan, CONG Peng, et al. A fault diagnosis method based on data feature reconstruction and deep transfer learning [C]//Proceeding of IEEE Asia - Pacific Conference on Image Processing, Electronics and Computers. Piscataway, NJ: IEEE, 2022: 1-5.

[9] FU Yang, ZHANG Yun, GAO Yuan, et al. Machining vibration states monitoring based on image representation using convolutional neural networks [J]. Engineering Applications of Artificial Intelligence, 2017, 65: 240-251.

[10] AL-QIZWINI M, BARIJASTEH I, AL-QASSAB H, et al. Deep learning algorithm for autonomous driving using GoogLeNet [C]//Proceedings of IEEE Intelligent Vehicles Symposium. Piscataway, NJ: IEEE, 2017: 89-96.

[11] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2015: 1-9.

[12] 宋晨勇, 白皓然, 孙伟浩, 等. 基于 GoogLeNet 改进模型的苹果叶病诊断系统设计[J]. 中国农机化学报, 2021, 42(7): 148-155.

[13] ZHANG Kai, TANG Baoping, DENG Lei, et al. A hybrid attention improved ResNet based fault diagnosis method of wind turbines gearbox [J]. Measurement, 2021, 179: 109491.