

# 滚珠丝杠副故障振动信号分析及智能诊断方法综述

马会杰<sup>1,2,3</sup>, 黄志强<sup>2</sup>, 邓四二<sup>1</sup>, 李开元<sup>2</sup>, 鞠飞<sup>3</sup>

(1. 河南科技大学 博士后科研流动站, 河南 洛阳 471000;

2. 无锡华洋滚动轴承有限公司博士后创新实践基地, 江苏 无锡 214101;

3. 南京林业大学 汽车与交通工程学院, 南京 210037)

**摘要:** 滚珠丝杠副作为一种旋转运动与直线运动相互转化的高精度部件, 被广泛应用于机床、汽车、航空航天等机械设备中, 其健康状态对设备的性能和质量具有重大影响; 针对滚珠丝杠副振动信号的特点, 系统综述了滚珠丝杠副故障振动信号处理及智能诊断方法; 介绍了滚珠丝杠副振动信号的特征分析方法, 包括时域分析和基展开方法; 讨论了滚珠丝杠副智能故障分类方法, 包括支持向量机、反向传播神经网络和卷积神经网络等; 对当前滚珠丝杠副振动信号处理方法及故障诊断的研究现状进行了总结, 并对未来潜在的发展方向进行了展望。

**关键词:** 滚珠丝杠副; 信号分析; 故障诊断; 人工智能; 模式识别

## Review of Vibration Signal Analysis and Intelligent Faults Diagnosis Methods for Ball Screw

MA Huijie<sup>1,2,3</sup>, HUANG Zhiqiang<sup>2</sup>, DENG Sier<sup>1</sup>, LI Kaiyuan<sup>2</sup>, JU Fei<sup>3</sup>

(1. Postdoctoral Research Center, Henan University of Science and Technology, Luoyang 471000, China;

2. Postdoctoral Innovation Practice Base, Wuxi Huayang Rolling Bearing Co., Ltd., Wuxi 214101, China;

3. College of Automobile and Traffic Engineering, Nanjing Forestry University, Nanjing 210037, China)

**Abstract:** Ball screw pairs, serving as high-precision components that converts rotary motion into linear motion and vice versa, are widely used in equipment such as machine tools, automobiles, aerospace, etc, its health status has a significant impact on the performance and quality of equipment. Focusing on the characteristics of the vibration signals of ball screw pairs, this paper summarizes the methods of processing vibration signals and intelligent diagnosis faults for ball screw pairs, and introduces the characteristic analysis methods for the vibration signals of ball screw pairs, including the time-domain analysis and basis expansion methods. The intelligent fault classification methods for the ball screw pairs are discussed, including the support vector machines, backpropagation neural networks, and convolutional neural networks. The current research status on the vibration signal processing methods and fault diagnosis of ball screw pairs is summarized, and the future direction is explored.

**Keywords:** ball screw pairs; signal analysis; fault diagnosis; artificial intelligence; pattern recognition

## 0 引言

滚珠丝杠副是一种由丝杠、螺母和滚珠组成的部件, 相对于滑动螺旋传动, 滚珠丝杠副采用滚动摩擦, 极大地降低了摩擦力矩, 从而提高了传动效率<sup>[1-3]</sup>。滚珠丝杠副在高端机械装备中广泛应用, 如机床的进给驱动系统以及飞机、导弹的高精度调平系统<sup>[4]</sup>。然而, 随着使用时间的增加, 滚珠丝杠副可能会出现多种故障,

包括疲劳剥落、预紧力丧失、断裂失效和润滑不良等<sup>[5-6]</sup>。这些故障轻则导致机械系统的传动精度、刚性和传动效率下降, 重则可能引发严重的人员安全事故, 造成巨大的经济损失。因此, 实时监测滚珠丝杠副的健康状态, 提前警示潜在故障具有重要意义。

尽管针对旋转部件如轴承和齿轮的振动信号分析及故障诊断方法在目前阶段已经非常有效且多种多样<sup>[7-10]</sup>, 但对于滚珠丝杠副而言, 由于其独特的运动形

收稿日期: 2023-11-19; 修回日期: 2024-01-05。

基金项目: 河南省博士后科研项目(13554013)。

作者简介: 马会杰(1994-), 男, 讲师。

引用格式: 马会杰, 黄志强, 邓四二, 等. 滚珠丝杠副故障振动信号分析及智能诊断方法综述[J]. 计算机测量与控制, 2025, 33(1): 1-8, 28.

式和复杂的结构，以及在运行过程中轴向刚度的变化和安装精度对振动的显著影响，确定滚珠丝杠副的故障位置和程度较为困难。此外，滚珠丝杠副具有多变的工作环境，其数据特征也异常复杂。截至目前，仍然缺乏详细的文献总结关于滚珠丝杠副的故障诊断方法。本文旨在对滚珠丝杠副故障振动信号分析及诊断方法进行系统的综述，为对滚珠丝杠副故障诊断方法感兴趣的研究人员提供参考。

### 1 基于振动信号的滚珠丝杠副故障诊断过程

基于振动信号的故障诊断方法通过分析滚珠丝杠副在工作过程中产生的振动信号，判断滚珠丝杠副是否存在故障，并进一步确定故障的类型和程度。基于振动信号的滚珠丝杠副故障诊断流程如图 1 所示。

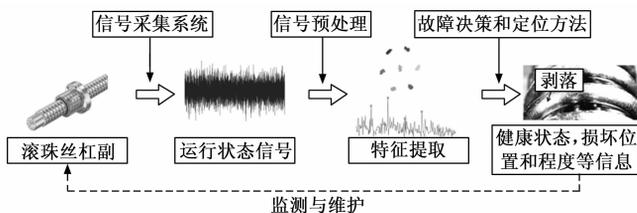


图 1 基于振动信号的滚珠丝杠副故障诊断流程

首先，将加速度传感器等设备安装在滚珠丝杠副的相关部位，以获取滚珠丝杠副在工作过程中产生的振动信号。其次，对采集的振动信号进行预处理，主要目的是去除杂散信号、滤除噪声和干扰等，从而得到更准确、可靠的振动信号数据。接下来，对预处理后的振动信号进行特征提取，特征提取是对振动信号中的有效信息进行选取和提取的过程。然后，对提取的特征进行故

障诊断，通过建立合适的样本集，对提取的特征进行分类和判别，以识别滚珠丝杠副的故障类型。最后，根据故障诊断的结果，判断滚珠丝杠副的故障是否存在、故障类型和程度，并根据实际情况采取相应的维修或更换措施。

由上述滚珠丝杠副的诊断流程可以看出，诊断过程的核心是对采集到的信号进行特征提取和故障分类，现阶段主要依靠振动信号分析和智能模式识别方法实现。

### 2 滚珠丝杠副故障振动信号分析方法

20 世纪 90 年代有日本学者对滚珠丝杠副的振动和声音特性进行了研究，指出滚珠丝杠副在使用过程中会产生内激振动，产生内激振动的主要因素是滚珠与返回器的接触<sup>[11-13]</sup>。因此，与滚动轴承故障诊断不同，在对滚珠丝杠副故障诊断时首先应该对采集到的振动信号进行分析，分离内激振动信号和噪声，同时提取故障特征信号。典型的滚珠丝杠副故障振动信号分析方法总结归纳如表 1 所示。

#### 2.1 时域分析

时域分析是通过传感器采集到的振动信号，对信号的构成和特征进行分析，并将这些信息在时间坐标轴上可视化呈现。本文主要介绍在滚珠丝杠副中运用比较广泛的经验模态分解和包络分析两种方法。

##### 2.1.1 经验模态分解

健康的滚珠丝杠副在工作中会产生内激振动，此外，还会受到环境噪声的干扰。经验模态分解 (EMD, empirical mode decomposition) 是在滚珠丝杠副振动信号时域分析中应用最广泛的方法，它是信号处理和数据

表 1 滚珠丝杠副故障振动信号分析方法对比

类别	方法	技术特点	优点	不足
时域分析	经验模态分解	将信号分解成一组本征模态函数 IMF, 这些 IMF 代表了信号在不同时间尺度上的局部振动或波动成分。	1. 适用于非线性和非平稳信号的分析。 2. 不需要先验信息。	1. 容易受到模态重构和端点效应的影响。 2. 在信号存在高频噪声时, 模态会受到不稳定的影响。
	包络分析	取信号中的振幅包络, 在处理调制信号时非常有效。	1. 用于提取信号的慢变化分量, 对于包络提取非常有效。 2. 可以用于故障诊断和分析非平稳信号。	1. 依赖于窗口函数的选择, 可能引入误差。 2. 对于高频噪声敏感, 不适用于一些高频特征的提取。
基展开方法	傅里叶变换	将信号表示为多个正弦函数的线性组合的形式。	1. 简单、直观, 适用于分析稳态信号的频谱特征。 2. 在线性系统和稳态信号的分析中具有很好的性能。	1. 对非平稳信号不够敏感。 2. 不能提供信号在时间上的局部信息。
	短时傅里叶变换	通过在时间上滑动窗口来计算信号的频谱。	1. 提供了信号在时频域上的局部信息。 2. 适用于非平稳信号的频谱分析。	1. 高时间分辨率和高频率分辨率不能同时实现。 2. 窗口函数选择对结果有一定影响。
	小波变换	将信号表示为多个不同尺度的小波函数的线性组合的形式。	1. 具有可变分辨率的能力, 适用于多尺度分析。 2. 可以提供在时频域上的局部信息。	1. 选取不同小波基会影响分析结果。 2. 计算复杂度相对较高。

分析的自适应技术, 最初于 1998 年提出<sup>[14]</sup>。通过 EMD 的分解和重构, 可以在一定程度上消除内激振动和噪声对滚珠丝杠副故障信号的干扰。

文献 [15] 使用经验模态分解方法提取出了滚珠通过反向器引起的振动信号, 该方法从采集到的振动信号中提取多个本征模态函数 (IMF, intrinsic mode function), 并对高频分量的 IMF 进行包络分析实现了内激振动信号的提取。文献 [16] 在 EMD 的基础上提出了集合经验模态分解 (EEMD, ensemble empirical mode decomposition), 通过加入多组白噪声, 分析受到噪声干扰的 3 种不同状态的滚珠丝杠副振动信号。文献 [17] 提出了一种将 EMD 与 MSE 相结合的信号处理算法用于预紧力丧失失效的特征提取, 分别运用希尔伯特变换和小波包变换能量提取算法对滚珠丝杠副点蚀失效与润滑不良失效进行特征提取, 得到了可以表征 3 种故障模式的特征向量集。文献 [18] 针对滚珠丝杠副故障信号的非线性和非平稳性特征, 引入 EMD 信号处理方法, 将原信号分解为有限个 IMF, 提取 IMF 分量的能量作为特征值, 利用 BP 神经网络进行故障类型识别。

EMD 的主要优点是它具有自适应性, 适用于不同类型的信号, 无需预先假设信号的数学模型。然而, EMD 也存在一些挑战, 如模态混叠和分解顺序的敏感性, 这些问题已经在其他旋转部件的诊断过程中得到了解决, 如快速独立成分分析<sup>[19]</sup> (FastICA) 和改进的 EMD 方法<sup>[20-22]</sup>。

### 2.1.2 包络分析

滚珠丝杠副局部故障信号会被系统的固有频率调制, 包络分析是一种用于提取信号振幅变化随时间变化的方法, 通常应用于振动信号分析、故障检测、结构健康监测等领域。

希尔伯特包络是通过应用希尔伯特变换 (Hilbert Transform) 来获得信号的包络, 将实部信号与虚部信号合并为一个复数信号, 其中虚部信号是实部信号相位 90 度滞后的结果<sup>[23]</sup>。对于信号  $s(t)$ , 其希尔伯特变换表示为:

$$s(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{s(\tau)}{t-\tau} d\tau \quad (1)$$

其中:  $t$  是时间,  $\tau$  是时间延迟。希尔伯特包络可以提取信号的正交分量, 并且包括信号相位信息。希尔伯特包络已经成为共振解调技术中普遍使用的一种分析方法, 例如, 在滚珠丝杠副故障诊断中, 文献 [24] 结合 EMD 和希尔伯特包络成功提取了滚珠丝杠副疲劳点蚀失效的故障特征, 并将特征输入支持向量机实现了滚珠丝杠副点蚀失效的诊断。

## 2.2 基展开方法

基展开方法是一种具有广义概念的方法<sup>[25]</sup>, 其数

学表达形式为:

$$s = \mathbf{D}x + \epsilon \quad (2)$$

其中:  $s$  为采集到的振动信号,  $\mathbf{D}$  是字典, 由多个基函数组成,  $x$  为  $s$  被  $\mathbf{D}$  分解得到的系数,  $\epsilon$  为噪声。在此框架下, 傅里叶变换可以被认为是  $\mathbf{D}$  由傅里叶级数构成的字典, 小波分解可以看作是  $\mathbf{D}$  由小波基构成的字典, 即傅里叶变换和小波变换是基展开方法的特例形式。

### 2.2.1 傅里叶变换

傅里叶变换将信号表示为多个正弦函数的线性组合的形式, 它将信号分解为不同频率成分, 显示了每个频率在信号中的振幅和相位。傅里叶变换在频谱分析、滤波、信号合成、调制解调、图像处理和音频处理等领域都有广泛的应用。傅里叶变换的公式表达为:

$$F(\omega) = \int f(t)e^{-i\omega t} dt \quad (3)$$

其中:  $f(t)$  为原信号,  $F(\omega)$  为原信号的变换结果,  $e^{-i\omega t}$  为复指数函数,  $\omega$  为角频率。

在实际应用过程中, 往往通过 Cooley-Tukey、Radix-2 和 Radix-4 等算法加速傅立叶变换的计算过程, 这种算法被称作快速傅立叶变换 (FFT, fast fourier transform)<sup>[26]</sup>。在研究滚珠丝杠副的初期, FFT 被广泛使用, 在探究滚珠丝杠副的声音和振动特性时, 研究人员就采用了这种分析方法, 并成功分析出滚珠丝杠副的主要振源<sup>[27]</sup>。

随着对滚珠丝杠副振动研究的深入, FFT 已经不能满足滚珠丝杠副振动信号分析的需要, 为此, 研究人员提出了其他基展开方法。

### 2.2.2 短时傅里叶变换

短时傅里叶变换 (STFT, short-time fourier transform) 是傅里叶变换的一种变体, 它在时间上对信号进行局部分析。STFT 引入窗函数, 并通过调整时间窗口的大小调整时频分辨率, 从而灵活地适应信号的不同特性, 这在分析频率变化的信号时效果很好。

针对变转速工况, 文献 [28] 通过角速度的 Vold-Kalman 滤波阶次跟踪 (AV VKF-OT) 法检测出球的传球频率, 并提出了用 STFT 监测滚珠丝杠副进给系统中滚珠通过频率的变化确定预紧力损失起始点的方法。针对滚珠丝杠副丝杠滚道故障定位困难问题, 文献 [29] 对存在单一点蚀故障的滚珠丝杠副进行了研究, 提出了一种基于 STFT 的滚珠丝杠副丝杠滚道故障定位方法, 通过理论分析确定了滚珠丝杠副振动信号 STFT 理想的窗函数及其参数。

虽然 STFT 解决了 FFT 不能进行局部分析的问题, 但其使用固定长度的窗口来分析信号, 这可能导致在处理不同频率成分时出现频率分辨率单一的问题。此外,

时域和频域分辨率之间需要权衡,调整窗口长度可以改变这种平衡,但通常不能同时获得高时域和高频域分辨率。

### 2.2.3 小波变换

为了克服 STFT 仅有单一频率分辨率的缺点,小波变换 (WT, wavelet transform) 在 1984 年提出,之后广泛应用在包括旋转机械故障诊断的各个领域中<sup>[30]</sup>。通过选定小波函数并在时间和频率上进行尺度变换,可以处理非平稳信号以及捕捉信号中的局部特征。小波变换的公式表达为:

$$WT(\alpha, \tau) = \frac{1}{\sqrt{\alpha}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-\tau}{\alpha}\right) dt \quad (4)$$

其中:  $WT(\alpha, \tau)$  是原信号  $f(t)$  的小波变换结果,  $\psi\left(\frac{t-\tau}{\alpha}\right)$  是母小波函数,  $\alpha$  是尺度因子,  $\tau$  是平移量。

文献 [31] 结合小波变换和重组方法提出了同步压缩小波变换方法,该方法在小波变换的基础上,将中心频率附近任意区间的小波系数压缩到中心频率,得到同步压缩小波系数,提高了时频变换的分辨率。文献 [32] 利用小波变换对滚珠丝杠副缺陷信号进行时频域分析,利用该分析方法开发了故障诊断系统,并成功估计了故障的严重程度,并检测到了缺陷的位置。文献 [33] 提出基于 Symlets 小波滤波的滚珠丝杠副频响特性辨识方法,在高速、高加速度条件下降低了噪声对加速度信号的影响,实现了对进给系统频响特性更为精确的辨识。

小波变换在处理一些特殊类型的信号和应用中具有明显的优势,主观选择的小波函数对小波变换的性能有很大影响,因此在选择使用时需要考虑其相对复杂性和计算成本。

## 3 滚珠丝杠副智能诊断方法

与滚动轴承故障诊断不同,由于滚珠丝杠副结构复杂、工况多变,仅依靠振动信号分析方法无法得到准确和鲁棒的诊断结果,现阶段主要通过智能诊断学习方法实现滚珠丝杠副故障的模式识别。智能诊断方法无需专家经验,能够自适应地从时域或频域信号中提取故障特征,实现了端到端的故障诊断模式,且适用于当今大数据时代,因此成为近年来专家学者研究的重点。典型的滚珠丝杠副智能诊断方法总结归纳如表 2 所示,主要包括支持向量机、BP 神经网络、卷积神经网络、深度置信网络。

### 3.1 支持向量机

支持向量机 (SVM, support vector machine)<sup>[34]</sup> 是一种监督学习算法,通常用于分类和回归问题。它的主要目标是找到一个决策边界或超平面,将不同类别的数

表 2 滚珠丝杠副智能诊断方法对比

方法	技术特点	优点	不足
支持向量机	SVM 通过找到最大间隔超平面来进行分类。	1. 对于小样本数据和特征维度较高的数据集效果较好。 2. 在高维空间中具有较好的性能。	1. 对于大规模数据集,训练时间较长。 2. 对于多类别分类问题需要多次训练。 3. SVM 的结果受到超参数选择的影响,需要仔细调优。
BP 神经网络	使用反向传播算法训练网络,通过不断调整权重来减小误差。	1. 能够处理非线性问题,适用于各种领域。 2. 具有较好的泛化能力,可以应对新数据。	1. 需要大量的训练数据,对数据质量和量要求较高。 2. 容易过拟合,需要合适的正则化方法。 3. 训练过程可能会收敛到局部极小值,需要合适的初始化和优化方法。
卷积神经网络	通过卷积核捕捉局部特征,网络具有卷积层、池化层和全连接层。	1. 具有较好的局部特征捕捉能力,对平移和尺度变化鲁棒。 2. 能够处理大数据任务。	1. 需要大量的标记数据进行训练。 2. 模型训练和调优通常需要大量计算资源。
深度置信网络	无监督学习算法,由多个堆叠的受限玻尔兹曼机组成。	1. 能够学习数据的高级抽象特征,适用于大规模数据集。 2. 具有深层结构,可以用于多层特征表示。	1. 训练 DBN 需要大量数据和计算资源。 2. 调优和微调过程相对复杂。
迁移学习	允许在一个任务上学到的知识迁移到另一个相关任务上。利用源域的模型或特征,可以提高目标领域任务的性能。	1. 可以节省大量的训练时间和数据收集成本。 2. 提高了模型的泛化能力,尤其适用于相似任务。	1. 需要谨慎选择源域和迁移策略,否则可能会导致负迁移。 2. 迁移学习的性能高度依赖于领域相似度和数据质量。

据分开,并尽量使这个边界离最接近数据点(支持向量)的距离最大化。SVM 的目标函数为:

$$\operatorname{argmax}_{w, b} \left\{ \min_i (y_i (w^T x_i + b)) \frac{1}{\|w\|} \right\} \quad (5)$$

其中:  $w$  可以看做是高维空间中超平面的斜率,  $b$  可以看做是截距,  $x_i$  是数据向量,  $y_i$  是分类标记。

前文中的文献 [24] 将希尔伯特黄变换获得的振动信号并将其频谱图输入 SVM, 实现了正确率高达 95% 以上的滚珠丝杠副疲劳点蚀失效诊断。文献 [35] 提出了基于核主元分析 (KPCA, kernel principal component analysis) 和 SVM 的滚珠丝杠副润滑失效故障诊断模型, 通过 KPCA 降低了原始数据的维度, 从而提高了模型的诊断准确率。文献 [36] 提出了一种基于 SVM 对采集到的信号进行处理和进一步分类的嵌入式传感系

统, 用于精确测量滚珠丝杠副结构感兴趣点的加速度和温度, 并对不同的滚珠丝杠副预紧力进行诊断。文献 [37] 基于 SVM 开发了一种滚珠丝杠系统的故障诊断方法, 用于确定发生初始润滑退化的运行距离。文献 [38] 提出了一种系统的滚珠丝杠副预测方法, 在其框架中 SVM 作为分类器, 实现了故障诊断、早期诊断、健康评估和剩余使用寿命预测; 结果表明, 在滚珠丝杠系统的某些特定失效模式的分类上, 该方法取得了良好的效果。

SVM 的优点包括对高维数据的处理能力、较好的泛化性能、能够处理非线性问题。但是, SVM 也面对一些挑战, 如对大规模数据集的计算开销较大和核函数的选择问题。在实际应用中, 合理选择参数和核函数非常重要。

### 3.2 BP 神经网络

BP 神经网络, 全称为反向传播神经网络 (BP, back propagation neural network), 是一种基本的神经网络架构, 用于解决监督学习问题, 如分类和回归, 其典型的网络结构如图 2 所示。网络由输入层、隐藏层和输出层构成, 隐藏层可以包含一个或多个神经元层, 这些隐藏层的存在使得网络可以学习复杂的非线性关系。BP 神经网络是一种前馈神经网络, 信息从输入层经过隐藏层传递到输出层, 没有循环连接, 这意味着信息在网络中向前传递而不会循环。网络训练的核心是反向传播算法, 它通过计算模型的输出与实际目标之间的误差, 然后根据误差来调整网络权重, 以最小化误差。这一过程反复进行, 直到误差收敛或达到停止训练的条件。BP 神经网络中的神经元通常使用激活函数, 如 Sigmoid、ReLU (修正线性单元) 等, 来引入非线性性质, 从而使网络能够学习非线性关系。BP 神经网络的前向传播过程可表示为:

$$y = f(\omega^T x) \quad (6)$$

其中:  $x$  是输入向量,  $\omega$  是权值矩阵,  $y$  是输出的结果向量,  $f$  为激活函数。反向传播过程则通过梯度下降法进行迭代更新。

文献 [39] 将粗糙集理论与 BP 神经网络结合, 实

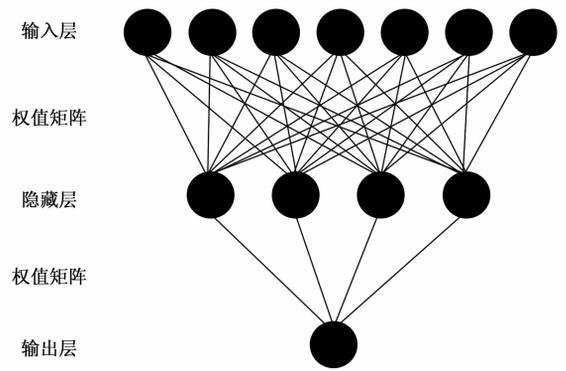


图 2 BP 神经网络的典型结构

现了多源信息融合的滚珠丝杠副的故障预测和诊断。文献 [40] 针对滚珠丝杠副预紧力失效诊断问题, 提出了变分模态分解和 BP 神经网络相结合的方法; 首先采用变分模态分解进行降噪, 然后将降噪后的信号人工提取出时频域数值特征, 最后用 BP 神经网络实现训练和测试。文献 [41] 提出基于改进 D-S 证据理论及 RBF 神经网络的滚珠丝杠副故障诊断方法, 其中 RBF 神经网络是一种与 BP 神经网络类似的网络结构, 主要特征是隐含层采用径向基函数作为神经元的激活函数。

尽管 BP 神经网络是一种强大的工具, 但它也有一些限制, 如对初始权重值敏感、容易过拟合、训练时间较长、需要大量的训练数据等。

### 3.3 卷积神经网络

卷积神经网络 (CNN, convolutional neural network) 最初是一种用于图像处理 and 识别任务的深度学习神经网络。CNN 的主要特点是它利用卷积操作来提取样本中的局部特征, 这使得它在处理大数据时非常强大。同时, CNN 也是滚珠丝杠副故障诊断中应用最多的方法, 因此, 对其进行更加详尽的介绍。

典型的卷积神经网络结构如图 3 所示。可以看出, 卷积神经网络的基本结构为: 卷积层, 池化层, 全连接层。卷积层利用多个卷积核, 对输入特性进行特征映射。池化层是以降低特征维数为主要目的的一种下采样操作。全连接 (FC, fully connection) 层是从输入到标签集的映射。卷积层可以看做是对信号的滤波, 卷积层

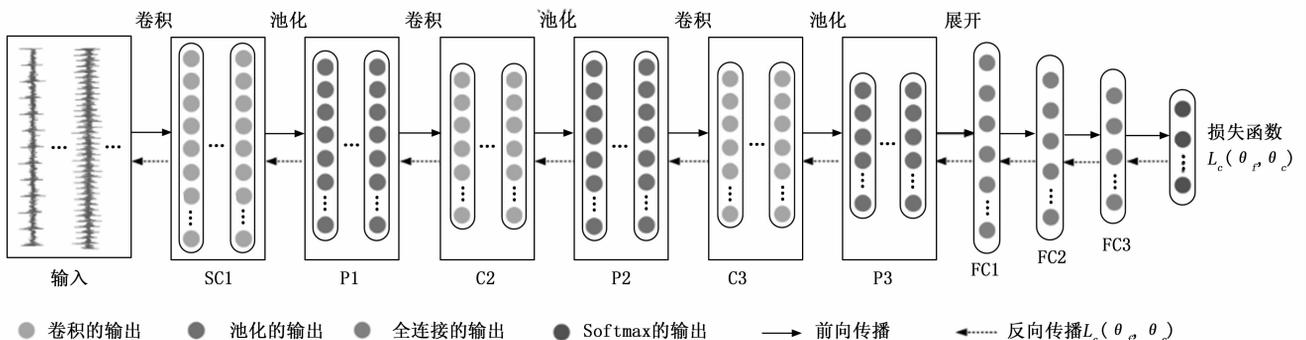


图 3 CNN 的典型结构

是由一系列可以通过学习得到的滤波器组成。这些滤波器组称作卷积核，类似于扫描数据的窗口，卷积核的宽度和高度都比较小，可以对数据局部依次进行观察。以信号  $x$  为例，设有  $N$  个二维卷积核  $W_n$  对信号进行特征提取，其前向传播过程为：

$$u_n = f_w(W_n * x + b_n) \quad (7)$$

式中， $u_n$  为经过卷积层提取到的特征， $f_w$  为非线性激活函数，可以实现非线性变换， $*$  为卷积操作符， $b_n$  为偏置。池化层一般接在每个卷积层之后，通过对卷积层得到的特征值进行降维操作，可以减小网络中的参数数量，减少计算资源，防止过拟合现象。池化操作较常见的有平均池化、最大池化和  $l_2$  范数池化。以最大池化为例，池化操作可表示为：

$$v_{i,j} = f_p\{u_{k:(i+1)k, jk:(j+1)k}\} \quad (8)$$

式中， $v_{i,j}$  为池化层提取到的特征， $f_p$  为池化操作， $k$  为池化区域的长宽。经过多个卷积层和池化层，CNN 一般采用全连接层对特征进行展开，其结构与普通的神经网络一致，即：

$$a_l = f_l(W_l v_{l-1} + b_l) \quad (9)$$

式中， $a_l$  为全连接层提取到的特征，共有  $l$  个全连接层， $f_l$  为全连接层的激活函数， $W_l$  为权值矩阵， $b_l$  为偏置。

文献 [42] 使用卷积神经网络对数控机床滚珠丝杠副故障信号进行识别，并通过实验证明卷积神经网络在多源信息的处理上具有更高的准确率。文献 [43] 针对滚珠丝杠副故障信号弱、易受干扰的问题，利用小波卷积结构对网络进行改进，提高了信号时域和频域特征的挖掘能力，针对滚珠丝杠副传感器安装位置受限的问题，提出了一种迁移学习方法，该方法采用区域自适应方法作为联合分布式自适应，通过提取滚珠丝杠副不同位置的诊断知识，实现对测量位置的迁移诊断。文献 [44] 提出了一维卷积神经网络 (1-D CNN) 的滚珠丝杠副早期故障诊断模型，采用基于正交设计的方法，获得了一维 CNN 的最优参数。文献 [45] 提出了一种残差孪生卷积神经网络 (ResT-CNN) 用于滚珠丝杠副的故障诊断中，将一维和二维 CNN 结合在并行学习中，提高了特征提取能力。

通过以上分析可知，CNN 在应对滚珠丝杠副早期故障诊断和多源信息融合方面有着较好的效果，这得益于 CNN 可以从大量数据中学习更具判别性的特征。但是，CNN 同样受到一些限制，如通常需要大量的标记训练数据，尤其是在深度 CNN 模型中；深度 CNN 模型通常包含大量的参数，导致计算复杂性增加；训练和推断深度 CNN 可能需要大量的计算资源，如 GPU 或 TPU；这也使得它在移动设备和嵌入式系统上的应用受到一定的限制。

### 3.4 深度置信网络

深度置信网络 (DBN, deep belief network) 由多个受限玻尔兹曼机 (RBM, restricted boltzmann machines) 构成，它的训练主要包括两个关键步骤：预训练和微调。在预训练阶段，逐层进行数据向量的推断，构建一个逐渐串联的 DBN，其中每个 RBM 的隐层成为下一个 RBM 的显层，上一个 RBM 的输出则作为下一个 RBM 的输入。随后，在微调阶段，采用有监督学习来训练最后一层 BP 网络，逐层传播误差，微调整个 DBN 网络的权值。图 4 为 DBN 结构的示意图。玻尔兹曼机的训练目标是最大化概率：

$$P(v) = \frac{\sum_h e^{-E(v,h)}}{\sum_{u,g} e^{-E(u,g)}} \quad (10)$$

其中： $E(v, h)$  是玻尔兹曼机的网络能量， $v$  是可视神经元， $h$  是隐藏神经元。

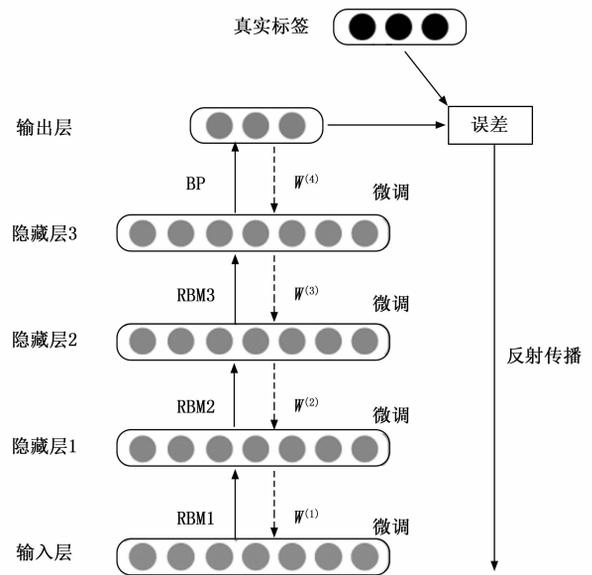


图 4 DBN 的典型结构

文献 [46] 提出了一种基于深度置信网络和多传感器数据融合的智能滚珠丝杠副退化识别方法，该方法能够自适应地从融合频谱中挖掘出固有特征，具有较高的识别精度。

虽然 DBN 在滚珠丝杠副的性能退化识别和故障诊断中应用较少，但可行性已经得到了充分验证，具有广阔的应用前景。在之后的研究中，应着重解决 DBN 的权重初始化、结构设计和过拟合等问题，从而更好地利用 DBN 的潜力。

### 3.5 迁移学习

迁移学习是一种机器学习方法，旨在利用从一个任务中学到的知识来改善另一个相关任务的性能。在迁移学习中，有两个或多个任务，通常被称为源任务 (source task) 和目标任务 (target task)。源任务是在

源域上的任务, 可能是已经解决的任务, 而目标任务是希望改进性能的任务。这两个任务之间可能存在相关性, 例如共享相似的特征空间或某种概念上的联系。迁移学习可以解决变工况、样本不平衡、跨设备和多源知识融合等故障诊断问题, 近几年在滚珠丝杠副的故障诊断中已开始应用。

文献 [47] 提出了一种基于深度学习的跨域滚珠丝杠副故障诊断方法, 利用卷积神经网络提取特征, 并利用最大均值差测度优化训练过程中不同工况的数据分布, 最终实现变工况滚珠丝杠副的故障诊断。文献 [48] 提出了一种基于卷积神经网络的领域自适应方法, 该方法最小化了领域之间高级表示的最大平均差异, 并利用新的并行数据来实现类级对齐。

目前, 迁移学习在滚动轴承和齿轮箱等旋转部件的故障诊断中得到了非常广泛的应用<sup>[49-51]</sup>, 但是在滚珠丝杠副中还未得到充分的应用。鉴于迁移学习强大的特征学习和迁移能力, 预计可以解决滚珠丝杠副复杂工况和小样本下的诊断问题。

#### 4 未来发展方向

现阶段滚珠丝杠副故障诊断技术相比于最前沿的诊断技术较为落后, 采用的方法较为传统。在未来, 针对现存的问题和难点, 滚珠丝杠副故障振动信号分析及智能诊断领域存在许多潜在的研究方向和机会。

1) 在振动信号分析中, 针对滚珠丝杠副变转速下的非稳态问题, 采用更加先进和更准确的时频分辨率变换方法, 例如同步挤压变换等时频域分析方法对故障特征进行提取。

2) 在智能诊断中, 针对滚珠丝杠副复杂工况和非完备数据的问题, 进一步探索深度学习和神经网络在振动信号分析中的应用, 例如采用循环神经网络、深度迁移学习和元学习等方法为滚珠丝杠副故障诊断领域带来更安全、可靠和高效的解决方案。

3) 结合来自不同传感器的数据, 包括振动、声音、温度、预紧力等多模态信息, 以提高系统的全面性和鲁棒性。

4) 促进实验数据集的共享, 以推动算法和模型的和验证, 共享标准化的数据集有助于推动滚珠丝杠副故障诊断领域的研究进展。

5) 结合物理模型和数字孪生技术, 建立滚珠丝杠副的精确数学模型, 并通过与实测振动信号进行比较, 提高故障诊断的可信度。

#### 5 结束语

近 20 年来, 滚珠丝杠副故障振动信号分析及智能诊断方法的研究取得了重要的成果, 提出了各种信号处理和深度学习方法, 对现有方法进行了系统的回顾, 并

对滚珠丝杠副故障诊断技术的未来发展方向做出展望。

综合滚珠丝杠副故障诊断研究可以看出, 在技术上, 随着传感技术的发展, 并引入机器学习方法, 滚珠丝杠副的故障分类和识别更加准确可靠, 但仍然有较大的进步空间。在应用上, 研究成果正逐步转化为实际的监测和维护工具, 一些先进的在线监测系统逐渐投入使用, 实现了对滚珠丝杠副状态的实时监测和诊断。在方法上, 逐渐向多模态融合和数据驱动方向发展。总体而言, 滚珠丝杠副故障诊断领域在技术、应用和方法上都呈现出积极向前的发展趋势。

#### 参考文献:

- [1] 冯虎田. 滚珠丝杠副动力学与设计基础 [Z]. 滚珠丝杠副动力学与设计基础, 2015.
- [2] NGUYEN T L, RO S-K, PARK J-K. Study of ball screw system preload monitoring during operation based on the motor current and screw-nut vibration [J]. Mechanical Systems and Signal Processing, 2019, 131: 18 - 32.
- [3] DENG Y, SHICHANG D, SHIYAO J, et al. Prognostic study of ball screws by ensemble data-driven particle filters [J]. Journal of Manufacturing Systems, 2020, 56: 359 - 372.
- [4] LI C, XU M, SONG W, et al. A review of static and dynamic analysis of ball screw feed drives, recirculating linear guideway, and ball screw [J]. International Journal of Machine Tools and Manufacture, 2023, 188: 21 - 83.
- [5] QI B B, CHENG Q, LI S L, et al. Precision loss of ball screw mechanism under sliding-rolling mixed motion behavior [J]. Journal of Central South University, 2021, 28 (5): 1357 - 1376.
- [6] YANG Q, LI X, WANG Y, et al. Fault diagnosis of ball screw in industrial robots using non-stationary motor current signals [J]. Procedia Manufacturing, 2020, 48: 1102 - 1108.
- [7] JIANG X, SONG Q, WANG H, et al. Central frequency mode decomposition and its applications to the fault diagnosis of rotating machines [J]. Mechanism and Machine Theory, 2022, 174: 104919.
- [8] JIANG X, WANG J, SHEN C, et al. An adaptive and efficient variational mode decomposition and its application for bearing fault diagnosis [J]. Structural Health Monitoring, 2021, 20 (5): 2708 - 2725.
- [9] ZHANG Z, LI S, LU J, et al. A novel intelligent fault diagnosis method based on fast intrinsic component filtering and pseudo-normalization [J]. Mechanical Systems and Signal Processing, 2020, 145: 106923.
- [10] LU J, JIA B, LI S, et al. A noise reduction method of rolling bearing based on empirical wavelet transform and adaptive time frequency peak filtering [J]. Measurement

- Science and Technology, 2023, 34 (12): 125146.
- [11] IGARASHI T, TOKUNAGA Y, OOKUMA K. Studies on the Sound and Vibration of a Ball Screw (1st Report, Sound Characteristics of a Ball Screw) [J]. Nippon Kikai Gakkai Ronbunshu, C Hen/Transactions of the Japan Society of Mechanical Engineers, Part C, 1988, 54 (499): 617 - 622.
- [12] 张佐营, 杨根喜, 姜洪奎. 高速滚珠丝杠副的碰撞噪声控制 [J]. 噪声与振动控制, 2014, 34 (3): 215 - 218.
- [13] 汤文成, 徐楠楠. 滚珠丝杠副发展及研究现状 [J]. 机械设计与制造工程, 2016, 45 (4): 11 - 14.
- [14] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for non-linear and non-stationary time series analysis [J]. Proceedings Mathematical Physical & Engineering Sciences, 1998, 454 (1971): 903 - 995.
- [15] 陈勇将, 汤文成. 端块式滚珠丝杠副振动特性分析 [J]. 机械传动, 2016, 40 (12): 117 - 122.
- [16] 李 惠, 陈蔚芳, 商苏成. 基于 EEMD\_BP 网络的滚珠丝杠副故障模式识别 [J]. 机械与电子, 2018, 36 (4): 28 - 32.
- [17] 王志荣, 王禹林, 陈超宇, 等. 基于振动特征的滚珠丝杠副预紧力丧失诊断研究 [J]. 振动与冲击, 2018, 37 (12): 201 - 206.
- [18] 温国强, 文 妍, 谭继文. 基于 EMD 与神经网络的滚珠丝杠故障诊断 [J]. 机床与液压, 2013, 41 (21): 164 - 167.
- [19] JING Y B, LIU C W, BI F R, et al. Diesel engine valve clearance fault diagnosis based on features extraction techniques and FastICA-SVM [J]. Chinese Journal of Mechanical Engineering, 2017, 30 (4): 991 - 1007.
- [20] JIANG H, LI C, LI H. An improved EEMD with multi-wavelet packet for rotating machinery multi-fault diagnosis [J]. Mechanical Systems and Signal Processing, 2013, 36 (2): 225 - 239.
- [21] ZHENG J, PAN H. Mean-optimized mode decomposition: An improved EMD approach for non-stationary signal processing [J]. ISA transactions, 2020, 106: 392 - 401.
- [22] ZHENG J, CHENG J, YANG Y. A rolling bearing fault diagnosis approach based on LCD and fuzzy entropy [J]. Mechanism and Machine Theory, 2013, 70: 441 - 453.
- [23] FELDMAN M. Hilbert transform in vibration analysis [J]. Mechanical Systems and Signal Processing, 2011, 25 (3): 735 - 802.
- [24] 聂从辉, 周长光, 刘迪一, 等. HHT-SVM 在滚珠丝杠副疲劳点蚀失效诊断中的应用 [J]. 组合机床与自动化加工技术, 2020 (12): 80 - 84.
- [25] FENG Z, ZHOU Y, ZUO M J, et al. Atomic decomposition and sparse representation for complex signal analysis in machinery fault diagnosis: A review with examples [J]. Measurement, 2017, 103: 106 - 132.
- [26] RAO K R, KIM D N, HWANG J J. Fast Fourier transform: algorithms and applications [M]. 32. Springer, 2010.
- [27] IGARASHI T, TOKUNAGA Y, KAMIMURA N. Studies on the sound and vibration of a ball screw (5th Report, Sound Caused by Random Waviness on Flank Surfaces) [J]. Transactions of the Japan Society of Mechanical Engineers, 1995, 61 (588): 3369 - 3374.
- [28] TSAI P C, CHENG C C, HWANG Y C. Ball screw preload loss detection using ball pass frequency [J]. Mechanical Systems & Signal Processing, 2014, 48 (1/2): 77 - 91.
- [29] 张子锋, 胡建中. 基于短时傅里叶变换的滚珠丝杠副丝杠滚道故障定位研究 [J]. 机电工程, 2015, 32 (4): 484 - 487.
- [30] ZHANG D, ZHANG D. Wavelet transform [J]. Fundamentals of image data mining: Analysis, Features, Classification and Retrieval, 2019: 35 - 44.
- [31] DAUBECHIES I, LU J, WU H T. Synchrosqueezed wavelet transforms: An empirical mode decomposition-like tool [J]. Applied and Computational Harmonic Analysis, 2011, 30 (2): 243 - 261.
- [32] WON GI LEE J W L, MIN SUNG HONG, SUNG-HO NAM. Failure diagnosis system for a Ball-Screw by using vibration signals [J]. Shock and Vibration, 2015: 1 - 9.
- [33] 刘 栋, 梅雪松, 冯 斌, 等. 基于 Symlets 小波滤波的滚珠丝杠伺服进给系统频响特性辨识 [J]. 机械工程学报, 2011, 47 (13): 153 - 159.
- [34] NOBLE W S. What is a support vector machine? [J]. Nature Biotechnology, 2006, 24 (12): 1565 - 1567.
- [35] 张向东, 周长光, 冯虎田, 等. 基于 KPCA 和 SVM 的滚珠丝杠副润滑失效故障诊断 [J]. 组合机床与自动化加工技术, 2021 (5): 153 - 159.
- [36] FENG G H, PAN Y L. Establishing a cost-effective sensing system and signal processing method to diagnose preload levels of ball screws [J]. Mechanical Systems and Signal Processing, 2012, 28 (Apr.): 78 - 88.
- [37] CHANG-FU H, HE-QING H, CHIN-CHUNG W, et al. Techniques developed for fault diagnosis of long-range running ball screw drive machine to evaluate lubrication condition [J]. Measurement, 2018, 126: 274 - 288.
- [38] LI P, JIA X, FENG J, et al. Prognosability study of ball screw degradation using systematic methodology [J]. Mechanical Systems & Signal Processing, 2018, 109 (SEP.): 45 - 57.
- [39] 吴丽媛. 基于粗糙集神经网络的数控机床滚珠丝杠副故障诊断研究 [D]. 青岛: 青岛理工大学, 2012.

(下转第 28 页)