

轨道交通轴承故障诊断技术概述

轨道交通轴承故障诊断的核心是故障诊断的方法和技术,轴承故障振动分析法是现代轨道交通轴承故障诊断方法中最有效和最常用的方法。本章主要介绍轨道交通轴承振动信号采集和信号数据预处理技术,轨道交通轴承故障特征提取技术与特征选择技术,以及轨道交通轴承故障模式智能诊断技术。

3.1 轴承振动信号采集与预处理技术

3.1.1 轴承振动信号采集技术

轨道交通轴承振动信号的数据采集是轨道交通轴承故障诊断的前提。振动信号的幅值、频率、相位信息能够准确反映机械运行情况,可以被作为机械状态识别与故障诊断分析中的信息依据。通常通过振动传感器采集轨道交通滚动轴承振动信号,并通过信号采样将传感器采集到的电信号转换成诊断所需的数字信号。

1. 轴承振动信号采集原理

(1) 振动传感器工作原理

振动传感器是用于检测冲击力或者加速度的传感器,是滚动轴承监测诊断过程中最常用的一种传感器。振动传感器并不是直接将原始要测的机械量转变为电量,而是将原始要测的机械量作为振动传感器的输入量,然后由机械接收部分接收,形成另一个适用于变换的机械量,最后由机电变换部

分再将变换为电量。因此一个传感器的工作性能是由机械接收部分和机电变换部分的工作性能来决定的。振动传感器根据振动物理量分为位移传感器、速度传感器、加速度传感器三种,其中位移探头测量转轴与轴承座之间的相对振动,速度与加速度计反映了转轴与轴承之间相对作用力引起的轴承座的绝对振动,其中加速度计具有动态范围大、有效幅值以及频率范围宽、可靠性高、尺寸小、质量轻便等显著优点。

(2) 振动信号采样定理

传感器采集到的电信号具有连续的形式。为了信号能被计算机处理,需要将电信号转换成数字信号。这一转换过程是通过对电信号在各个离散的瞬间进行取样完成的,即将电信号的幅度数字化成一系列数字的过程。

采样过程所应遵循的规律称为采样定理,它是指如果电信号带宽小于奈奎斯特频率(即采样频率的二分之一),那么此时这些离散的采样点能够完全表示原信号。高于或处于奈奎斯特频率的频率分量会导致混叠现象。大多数应用都要求避免混叠,混叠问题的严重程度与这些混叠频率分量的相对强度有关。采样定理说明采样频率与信号频谱之间的关系,是连续信号离散化的基本依据。

2. 轴承振动信号采集方法

(1) 轴承振动传感器选择、安装部署

振动传感器的选择与安装直接影响采集信号的有效性和故障诊断的可靠性。

基于测量对象与测量环境,选择振动传感器时首先要考虑如下因素:传感器量程的大小、被测位置对传感器体积的要求、接触式还是非接触式测量、有线或无线通信等,然后确定传感器类型,考虑灵敏度、频率响应特性、线性范围和精度等具体性能指标。

振动传感器安装通常应选在轴承座上;对轴承座安装在内部的,传感器安装测点位置应在与轴承座连接刚性高的部分或基础上。测点有垂直、水平和轴向三个方向可供选择,每次测定的位置均不应变化,使前后不同时间内测得的数据具有可比性。

轴承在运转时,轨道接触面上的高低不平和局部缺陷所产生的冲击性振动,将以压缩波的形式从接触点出发呈半球波面向外传播,在信号传播的路径上如果遇到材料的转近处、尖角形状或两个零件的配合界面时,由于波的折射和反射将引起很大的能量损耗,因此振动传感器的具体安装位置应

使其接收方向指向滚道的负荷方向,并且要求轴承与传感器之间尽可能减少中间界面。

对于永久性轴承振动信号测试测点,传感器采取刚性的机械连接,例如黏结、夹紧,或用螺栓固定。必须保证连接的牢固,否则连接部位松动会产生虚假的振动信号。对于临时性轴承振动信号测试测点,最好配备永磁铁制成的磁座,用螺栓将传感器与磁座连为一体,测量时磁座吸附在被测物表面。

(2) 采样频率的选择

基于振动信号采用定理,针对频带为 F 的连续时域信号 $f(t)$ 可用一系列离散的采样值 $f(t_1), f(t_1 + \Delta t), f(t_1 + 2\Delta t), \dots$ 来表示,只要这些采样点的时间间隔 $\Delta t \leq 1/2F$,便可根据各采样值完全恢复原来的信号 $f(t)$ 。或者针对频谱受限的时域信号 $x(t)$,如果其最高频率分量为 ω_m (或 f_m),为了保留原信号的全部信息,或能无失真地恢复信号,在通过采样得到离散信号时,其采样频率应满足 $\omega_s \geq 2\omega_m$ (或 $f_s \geq 2f_m$)。通常把最低允许的采样频率 $\omega_s = 2\omega_m$ 称为奈奎斯特频率。

3.1.2 轴承振动信号数据预处理技术

轨道交通轴承振动信号预处理的效果直接关系到故障诊断的准确性,是故障诊断的一个重要内容,尤其对被严重噪声干燥的信号尤为重要。通常信号预处理方法包括去除趋势项、信号降噪处理、零均值化处理等。

1. 去除趋势项

趋势项是指样本记录中样本周期大于记录长度的频率成分,它通常是由测试系统本身引起的一种趋势误差。数据中的这种长周期趋势项,会造成低频时的谱估计失去真实性,所以从原始数据中去除趋势项是一项非常重要的数据预处理工作。

去除趋势项最常用的方法是最小二乘法,这种方法既能去除数字信号中的线性趋势项,又能去除非线性高阶多项式趋势项经验。应用最小二乘法去除趋势项的具体方法如下:

① 设采集到的振动信号数据为 $\{x(i)\}, (i=1, 2, \dots, N)$ 。构造一个 p 阶多项式来拟合振动信号数据:

$$f(i) = a_0 + a_1 i + a_2 i^2 + \dots + a_p i^p = \sum_{k=0}^p a_k i^k \quad (3.1)$$

② 根据最小二乘法原理,确定 $f(i)$ 中各个待定系数的值 a_k , 依据使 $f(i)$ 与数据 $x(i)$ 的误差平方和达到最小, 即

$$E = \sum_{i=1}^N [f(i) - x(i)]^2 = \sum_{i=1}^N \left[\sum_{k=0}^P a_k i^k - x(i) \right]^2 \quad (3.2)$$

为使 E 最小, 可令 E 对各阶系数的偏导数等于零, 即

$$\frac{\partial E}{\partial a_r} = 0 \quad (r=0, 1, 2, \dots, p) \quad (3.3)$$

可得到 $p+1$ 元的线性方程组:

$$\sum_{k=0}^p a_k \sum_{i=1}^N i^{k+r} = \sum_{i=1}^N x(i) i^r \quad (3.4)$$

给定需要拟合的单边点数 N , 多项式的阶次 P 以及待拟合的数据 $x(1), x(2), \dots, x(N)$, 就可求得待定系数 a_k 的值。

③ 将系数 a_k 代入多项式 $f(i)$ 中, 即可达到去除趋势项后的振动信号数据。

2. 信号降噪处理

经传感器采集到的轴承振动信号, 除包含有效的故障信号信息外, 还包含有噪声和许多与被测信号无关的信号, 这些信号一般具有非线性非平稳特征, 有时还会呈现出相互混叠现象, 此时直接进行特征分析并不能够准确提取振动信号的故障特征。传统的信号降噪方法通常采用滤波器设置不同的通带方法, 但这种方法仅适用于信号与噪声具有不同频带分布的情况。对于轴承振动信号来说, 由于存在与噪声信号在频带上相互混叠难以分类现象, 因此需要更好的降噪处理方法。振动信号降噪处理中常用的方法有小波变换方法、卡尔曼滤波方法等。

(1) 小波变换方法

小波变换的概念是由 J. Morlet 在 1974 年首先提出的, 它是一个去除噪声提取有用信号的有效工具。使用小波变换, 一个信号可以被分解成不同尺度, 每个尺度的子信号代表着原始信号的一部分分量。从这些分解出的各尺度子信号分量中, 可以分别提取有用振动信号和噪声信号。在小波变换应用中有三个关键参数: 小波母函数, 分解层级尺度数量和小波系数截取阈值。小波分解层级尺度数量会影响信号的分离效果, 小波分解层级尺度越多, 信号分离效果越好, 但同时意味着计算时间越长。

小波降噪的基本思路是对含有噪声的振动信号选择适当的小波包基函

数和分解层数,将信号进行小波分解,再利用阈值函数对小波系数进行截取处理,最后将处理后的小波系数重构得到降噪信号。降噪的主要目的是滤除信号中的噪声,小波降噪的关键在于处理由噪声产生的小波系数,所以使用不同的阈值函数进行降噪会产生不同的降噪效果。

小波变换相关定义如下:

设函数 $f(t)$ 为一平方可积函数,记作 $f(t) \in L^2(R)$, $\phi(t)$ 为小波母函数,并满足条件:

$$C_\psi = \int_{-\infty}^{+\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (3.5)$$

式中, $\Psi(\omega)$ 是 $\phi(t)$ 的傅里叶变换。

设尺度参数 a 为伸缩因子,尺度参数 b 为平移因子,将小波母函数 $\phi(t)$ 进行伸缩和平移得到小波基函数 $\phi_{a,b}(t)$,它是小波母函数 $\phi(t)$ 经过一系列伸缩和平移后得到的函数族。

$$\phi_{a,b}(t) = \frac{1}{\sqrt{2}} \phi\left(\frac{t-b}{a}\right) \quad a > 0 \quad (3.6)$$

函数 $f(t)$ 的小波变换为

$$W_f(a,b) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{a}} \phi^*\left(\frac{t-b}{a}\right) dt \quad (3.7)$$

式中, $\phi^*(t)$ 为 $\phi(t)$ 的共轭。

函数 $f(t)$ 在小波基函数 $\phi_{a,b}(t)$ 下的展开,称为函数 $f(t)$ 的连续小波变换(Continue Wavelet Transform, CWT),定义如下:

$$f(t) = C_\psi^{-1} \iint_{R^2} W_f(a,b) \frac{1}{a^2} \phi_{a,b}(t) da db \quad (3.8)$$

连续小波变化的概念及其公式,更适用于理论的分析。若采用计算机技术进行小波变换,需要将小波变换进行离散化,以适用于数字计算机的处理。离散小波变换(Discrete Wavelet Transform, DWT)是相对于连续小波变换(CWT)的变换方法,本质上是对参数 a 和 b 进行离散化。

轴承振动信号中,多数有用的振动信号包含在低频分量中,少量的有用信号和噪声包含在高频分量中。虽然小波分析可以提取有用的信号,但它每次只对信号的低频部分进行分解。若要同时提取高频部分的有用信号,可进一步采用小波包分解的方法,能同时对信号低频和高频进行分解。

(2) 卡尔曼滤波方法

卡尔曼滤波是由 Kalman 于 1960 年提出的,是一种对系统的状态进行

估计来消除噪声的滤波方法。卡尔曼滤波的原理是利用前一时刻的估计值和当前时刻的观测值来对当前时刻系统状态进行最优估计。实际的测量信号受到过程噪声和测量噪声的影响,与预测输出存在差异。卡尔曼滤波实时更新系统状态估计的协方差矩阵,并利用上一时刻的滤波误差协方差和此时此刻的预测误差协方差计算出卡尔曼滤波中的卡尔曼增益,实现对当前时刻的状态变量进行最优估计。在不断递推系统滤波过程时,在每一步滤波中,都引入系统新的测量数据作为信息补充,在滤波迭代过程中,可以及时修正对系统状态的估计值,减小状态估计误差,卡尔曼滤波算法适用于计算平稳或非平稳随机系统。

卡尔曼滤波线性状态方程离散形式如下:

$$\mathbf{x}_{k+1} = \mathbf{A}\mathbf{x}_k + \mathbf{B}u_k + \mathbf{w}_k \quad (3.9)$$

$$y_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k \quad (3.10)$$

式中, $\mathbf{x}_k, \mathbf{x}_{k+1}$ 为 k 和 $k+1$ 时刻的状态向量; $\mathbf{w}_k$ 是 k 时刻的系统噪声向量; u_k 为 k 时刻的系统输入; y_k 为 k 时刻的系统输出,即观测值; $\mathbf{v}_k$ 为 k 时刻的测量噪声向量; $\mathbf{A}$ 为状态转移矩阵; $\mathbf{B}$ 为系统的输入矩阵; $\mathbf{H}$ 为系统的输出矩阵。 $\mathbf{w}_k$ 和 $\mathbf{v}_k$ 是由系统参数不确定性和传感器误差引起的,且互不相关。取两种噪声引起的误差协方差矩阵分别为 $\mathbf{Q}$ 和 $\mathbf{R}$ 。

卡尔曼滤波器的时间更新状态估计如下:

$$\hat{\mathbf{x}}_k^- = \mathbf{A}\hat{\mathbf{x}}_{k-1} + \mathbf{B}u_{k-1} \quad (3.11)$$

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \quad (3.12)$$

式中: $\hat{\mathbf{x}}_k^-$ 为 k 时刻的状态方程的先验状态估计,即在没有使用该时刻观测 y_k 得到的状态估计值; $\hat{\mathbf{x}}_{k-1}$ 为 $k-1$ 时刻的后验状态估计,即使用了该时刻观测 y_{k-1} 得到的状态估计值; $\mathbf{P}_k^-$ 为 k 时刻的先验状态估计的误差协方差矩阵, $\mathbf{P}_{k-1}$ 为 $k-1$ 时刻的后验状态估计的误差协方差矩阵。

卡尔曼滤波器的状态更新如下:

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}' (\mathbf{H} \mathbf{P}_k^- \mathbf{H}' + \mathbf{R})^{-1} \quad (3.13)$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{A}\mathbf{K}_k (y_k - \mathbf{H}\hat{\mathbf{x}}_k^-) \quad (3.14)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k^- \quad (3.15)$$

式中: $\mathbf{K}_k$ 为卡尔曼滤波增益; $\mathbf{I}$ 为相应维数的单位矩阵, $\hat{\mathbf{x}}_k$ 为 k 时刻的后验状态估计,即 k 时刻的滤波后的输出。

3. 零均值化处理

零均值化处理就是对数据序列中的每一个值减去其均值,使得到的新序列的均值为零。零均值化处理也叫中心化处理,零均值化处理对信号的低频段有特殊的意义。这是因为信号的非零均值相当于在此信号上叠加了一个直流分量,而直流分量的傅里叶变换是在零频率处的冲击函数,将在零频率处出现一个很大的谱峰,会影响在零频率左、右处的频谱曲线,使之产生较大的误差。零均值化处理的方法如下:

① 设采集到的振动信号数据为 $\{x(i)\}$, $(i=1,2,\cdots,N)$,计算其均值 μ 。

$$\mu = \frac{1}{N} \sum_{n=1}^N x(i) \quad (3.16)$$

② 通过零均值化处理,构建一个新的信号数据 $\{u(i)\}$, $n=1,2,\cdots,N$ 。

$$u(i) = x_i - \mu \quad (3.17)$$

对一些多维的样本数据,为提高样本数据分析的精度和加快数据分析寻求最优解的速度,通常会在零均值化处理的基础上再除以标准差,完成样本数据的标准化处理。

3.2 轨道交通轴承故障特征提取技术

故障特征提取是通过一系列的方法处理原始信号包含的所有信息,提取出有用信息,形成表现轴承设备运行状态的特征集合。而特征提取的方法需要根据信号的本质进行选取。

根据处理轨道交通轴承振动信号特征的不同,特征提取方法大致分为平稳信号分析方法和非平稳信号分析方法。平稳信号分析方法有时域特征提取和频域特征提取方法,非平稳信号分析方法有多种包络分析特征提取方法。

3.2.1 轴承振动信号故障时域特征提取方法

轴承振动信号时域特征提取方法为时域统计指标提取,主要是通过观测时域指标的变化,选取变化最明显的时域统计指标作为故障特征参数。时域统计指标又分为有量纲指标和无量纲指标。有量纲与无量纲指标的区别在于统计指标与单位是否相关。与单位有关的指标是有量纲指标,与单

位无关的指标是无量纲指标。

1. 有量纲指标

有量纲指标所定义的特征量取值大小通常会依据外界条件(如转速、负载等)的改变而变化。常用的有量纲指标有:最大值、最小值、峰峰值、均值、方差、均方值、均方根值、偏度、峭度。我们用 $x(t)$ 表示时域轴承振动信号, T 表示总的观测时间。

(1) 最大值。

$$X_{\max} = \max\{x(t)\}, \quad \max \text{ 表示最大值} \quad (3.18)$$

(2) 最小值。

$$X_{\min} = \min\{x(t)\}, \quad \min \text{ 表示最小值} \quad (3.19)$$

(3) 峰峰值。

$$X_{\text{ppv}} = X_{\max} - X_{\min} = \max\{x(t)\} - \min\{x(t)\} \quad (3.20)$$

信号的最大值和最小值给出了信号变化的范围,最大值即峰值反映了信号冲击的瞬时强度,常用来判断比较敏感表面损伤类故障;信号的峰峰值通常用来表示振动大小,即信号强度的变化,常用来判断冲击类故障。在工程实践中,通常将采集到的信号分成若干等分,分别求其峰峰值,然后再对若干峰峰值进行平均,以规避偶然因素对信号峰峰值的干扰。

(4) 均值。

$$\mu_x = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t) dt = \int_{-\infty}^{+\infty} x p(x) dx \quad (3.21)$$

其中, $p(x)$ 表示振动信号 $x(t)$ 的概率密度 $p(x) = \lim_{\Delta x \rightarrow 0} \frac{1}{\Delta x} \left(\lim_{T \rightarrow \infty} \frac{\Delta T}{T} \right)$, 式中 ΔT 表示信号 $x(t)$ 取值在区间 $(x, x + \Delta x)$ 内的总时间。

均值是信号幅值的算术平均值,体现了信号的中心趋势,反映了信号中的静态部分。

(5) 方差。

$$\sigma_x^2 = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T [x(t) - \mu_x]^2 dt = \int_{-\infty}^{+\infty} (x - \mu_x)^2 p(x) dx \quad (3.22)$$

方差反映的是信号中的动态分量,当轴承设备正常运转时,信号的方差比较小,所以可以借助方差来初步判断设备的运行情况。

(6) 均方值。

$$\psi_x^2 = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x^2(t) dt = \int_{-\infty}^{+\infty} x^2 p(x) dx \quad (3.23)$$

(7) 均方根值。

$$X_{\text{rms}} = \sqrt{\phi_x^2} = \sqrt{\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x^2(t) dt} = \sqrt{\int_{-\infty}^{+\infty} x^2 p(x) dx} \quad (3.24)$$

均方根值即有效值,幅值的平方具有能量的含义,均方值和均方根值都是表示动态信号强度的指标,具有很好的稳定性,但均方根值对早期故障不敏感,所以多用于稳态振动的情况,常用来诊断磨损类故障。

(8) 偏度。

$$\alpha = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x^3 dx = \int_{-\infty}^{+\infty} x^3 p(x) dx \quad (3.25)$$

(9) 峭度。

$$\beta = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x^4(t) dx = \int_{-\infty}^{+\infty} x^4 p(x) dx \quad (3.26)$$

信号的偏度和峭度指标常用来检验信号偏离正态分布的程度。信号概率分布的中心不对称程度越厉害,信号的偏度越大。峭度反映了信号概率密度函数峰顶的凸平度,对大幅度值非常敏感,当信号概率增加时,信号的峭度将迅速增大,非常适用于故障早期探测故障脉冲信息。

2. 无量纲指标

无量纲指标所定义的特征量对信号变化的频率和幅值不敏感,即与设备运行的工况无关,不会因为负载和转速等外界条件的变化而变化,故更适合作为轴承设备状态监测诊断参数。常用的无量纲指标有:波形指标、峰值指标、脉冲指标、裕度指标、峭度指标。

$$\text{波形指标: } k = \frac{X_{\text{rms}}}{|X|} = \frac{\text{均方根值}}{\text{绝对平均值}} \quad (3.27)$$

$$\text{峰值指标: } C = \frac{X_{\text{max}}}{X_{\text{rms}}} = \frac{\text{最大值}}{\text{均方根值}} \quad (3.28)$$

峰值指标既考虑了峰值又考虑了均方根值,是用来表征信号冲击的特征指标。

$$\text{脉冲指标: } I = \frac{X_{\text{max}}}{|X|} = \frac{\text{最大值}}{\text{绝对平均幅值}} \quad (3.29)$$

$$\text{裕度指标: } L = \frac{X_{\text{max}}}{X_r} = \frac{\text{最大值}}{\text{方根幅值}} \quad (3.30)$$

$$\text{峭度指标: } K_v = \frac{\beta}{X_{\text{rms}}^4} = \frac{\text{峭度}}{\text{均方根值}^4} \quad (3.31)$$

其中, 绝对平均幅值 $\overline{|X|} = \int_{-\infty}^{+\infty} |x| p(x) dx$, 方根幅值 $X_r = \left[\int_{-\infty}^{+\infty} \sqrt{|x|} p(x) dx \right]^2$

峭度指标对冲击信号非常敏感, 其值大小与轴承转速、尺寸和负载无关, 是点蚀类损伤故障常用的特征指标, 适用于轴承故障早期监测。但它对于磨损类故障不敏感。

无量纲指标仅对设备运行状态、故障和缺陷等敏感, 当设备运行状态发生变化时, 这些无量纲指标会有明显的变化。

3.2.2 轴承振动信号故障频域特征提取方法

轴承振动信号的时域特征只能反映信号幅值随时间的变化情况, 无法揭示信号频率构成及各频率分量的强弱。轴承正常工作时, 信号主要频率集中在低频段, 而故障时信号的主要频率则集中在高频段。随着轴承设备故障的发生, 其信号频率构成也会发生变化, 所以可以通过分析频率结构来判断故障信息。将振动信号的时域特征进行傅里叶变换得到频域特征, 然后通过频谱分析来进行故障诊断和预测。常用的轴承振动信号频域分析方法有: 幅度谱分析和功率谱分析。

幅度谱分析是对时域信号 $x(t)$ 进行傅里叶变换, 从而求得频率构成信息, 变换公式如下:

$$X(f) = \int_{-\infty}^{+\infty} x(t) e^{-j2\pi ft} dt \quad (3.32)$$

$X(f)$ 表示信号的频域, 即信号的幅度谱, 其中 f 表示信号的频率。其逆变换公式如下:

$$x(t) = \int_{-\infty}^{+\infty} X(f) e^{j2\pi ft} df \quad (3.33)$$

功率谱分析是提取信号中各频率成分的能量大小, 定义功率谱计算公式如下:

$$S(f) = \lim_{T \rightarrow \infty} \frac{1}{T} |X(f)|^2 \quad (3.34)$$

功率谱反映的是振动信号的频率成分以及各成分能量的相对强弱, 当信号中各频率成分的能量发生变化时, 功率谱主能量的谱峰位置将随之改变。当信号的频率成分增多时, 功率谱上能量分布会变得分散; 当信号的频率成分减少时, 功率谱上能量分布会变得集中。因此通过观测功率谱中主

频带位置变化和谱能量分布的分散程度,可以很好地描述信号频域特征的变化。

轴承振动信号故障频域分析常用特征提取指标有:重心频率、均方频率、均方根频率、频率方差和频率标准差。

重心频率

$$FC = \frac{\int_{-\infty}^{+\infty} fS(f)df}{\int_{-\infty}^{+\infty} S(f)df} \quad (3.35)$$

均方频率

$$MSF = \frac{\int_{-\infty}^{+\infty} f^2 S(f)df}{\int_{-\infty}^{+\infty} S(f)df} \quad (3.36)$$

均方根频率

$$RMSF = \sqrt{MSF} \quad (3.37)$$

频率方差

$$VF = \frac{\int_{-\infty}^{+\infty} (f - FC)^2 S(f)df}{\int_{-\infty}^{+\infty} S(f)df} \quad (3.38)$$

频率标准差

$$RVF = \sqrt{VF} \quad (3.39)$$

重心频率、均方频率和均方根频率通常用来描述功率谱主频位置的变化情况,频率方差和频率标准差用来描述谱能量的分散程度。

3.2.3 基于希尔伯特包络分析故障特征提取方法

希尔伯特包络分析是采用希尔伯特变换将给定连续信号变换成解析信号,解析信号的实部为信号本身,虚部为其希尔伯特变换,解析信号的幅值为信号的包络,即包络信号。通过对包络信号频谱分析进行特征提取。利用包络分析还可以从复杂的振动信号中提取出与故障相关的低频调制信号,通过观察频谱图并分析调制频率及它的倍频幅值的变化,来判断故障发生的部位以及故障程度。

基于希尔伯特包络分析故障特征提取方法的步骤如下:

(1) 给定轴承振动信号 $x(t)$, 进行希尔伯特变换, 公式如下所示:

$$\hat{x}(t) = \int_{-\infty}^{+\infty} \frac{x(t-\tau)}{\pi\tau} d\tau = x(t) \frac{1}{\pi\tau} \quad (3.40)$$

(2) 由 $x(t)$ 和 $\hat{x}(t)$ 构成的解析信号 $z(t)$, 公式如下:

$$z(t) = x(t) + j\hat{x}(t) = A(t)e^{j\phi(t)} \quad (3.41)$$

解析信号的幅值公式如下:

$$A(t) = \sqrt{x^2(t) + \hat{x}^2(t)} \quad (3.42)$$

解析信号的相位公式如下:

$$\phi(t) = \arctan \frac{\hat{x}(t)}{x(t)} \quad (3.43)$$

(3) 对包络信号进行包络分析, 可通过傅里叶变换进行轴承故障频域特征提取。

3.2.4 基于小波包包络分析故障特征提取方法

小波分析是一种有效的基于小波变换的时频分析方法, 但只对信号的低频部分进行分解, 不对信号的细节部分也就是高频部分进行分解。如果信号中包含具有高频特点的大量细节信息, 小波变换就不能很好地表征信号特征。在这种情况下, 对信号分析应是不仅对低频部分做精细划分, 而且也能对高频部分做更精细划分。为此, Colfman 等于 1992 年提出了小波包理论, 基于小波包变换可同时对信号在低频和高频部分进行分解, 更好地进行时频局部化分析。因此, 小波包包络分析特征提取具有更广泛的应用价值, 被广泛应用在故障诊断领域。

定义函数 $u_n(t)$ 满足下面的双尺度方程:

$$u_{2n}(t) = \sqrt{2} \sum_{k \in z} h_k u_n(2t - k) \quad (3.44)$$

$$u_{2n+1}(t) = \sqrt{2} \sum_{k \in z} g_k u_n(2t - k) \quad (3.45)$$

并令 $u_0(t) = \phi(t)$, $u_1(t) = \psi(t)$, 其中 $\phi(t)$ 和 $\psi(t)$ 分别尺度函数和小波函数, t 表示时间, k 表示时间平移因子, z 表示整数集, h_k 和 g_k 表示低通滤波器系数, 分别由尺度函数 $\phi(t)$ 和小波函数 $\psi(t)$ 决定, 即 $h_k = \langle \phi_{j,0}(t), \phi_{j-1,k}(t) \rangle$, $g_k = \langle \psi_{j,0}(t), \psi_{j-1,k}(t) \rangle$ 。 h_k 和 g_k 与具体尺度无关, 无论

对哪两个相邻级,其值都相同。其中 $\phi_{j,k}(t)$ 和 $\psi_{j,k}(t)$ 分别是尺度函数 $\phi(t)$ 和小波函数 $\psi(t)$ 经过整数平移 k 和尺度 j 上的伸缩得到的族,即 $\phi_{j,k}(t) := 2^{-j/2} \phi(2^{-j}t - k)$, $\psi_{j,k}(t) := 2^{-j/2} \psi(2^{-j}t - k)$ 。

以上定义的函数集合 $\{u_n(t)\}$ (其中 $n \in \mathbb{Z}$) 为由 $u_0(t) = \phi(t)$ 所确定的小波包,由此,小波包 $\{u_n(t)\}$ 是由尺度函数 $\phi(t)$ 和小波函数 $\psi(t)$ 在内的一个具有一定联系的函数的集合。

通过小波包分解,可以得到由尺度函数组成的子空间和小波函数组成的子空间。

基于小波包包络分析故障特征提取方法的步骤如下:

(1) 利用小波包对轴承振动信号进行分解。

首先,定义 $u_n(t)$ 的二进伸缩平移族为

$$u_{n,j,k}(t) := 2^{j/2} u_n(2^j t - k) \quad (k \in \mathbb{Z}, j \in \mathbb{Z}, n \in \mathbb{Z}^+) \quad (3.46)$$

再定义分解信号 $x(t)$ 对应小波包系数

$$d_{j+1,k}^n := \langle x(t), u_{n,j+1,k}(t) \rangle \quad (3.47)$$

则分解相邻级间小波包系数递推公式如下:

$$d_{j+1,k}^{2n} = \sum_l h_{2l-k} d_{j,l}^n \quad (3.48)$$

$$d_{j+1,k}^{2n+1} = \sum_l g_{2l-k} d_{j,l}^n \quad (3.49)$$

(2) 对含有轴承故障振动信息的固有共振频带信号进行小波包重构,滤除其中的干扰成分。小波包重构公式如下:

$$d_{j,l}^n = \sum_k [h_{l-2k} d_{j+1,k}^{2n} + g_{l-2k} d_{j+1,k}^{2n+1}] \quad (3.50)$$

(3) 对重构后的固有共振信号进行解调并得到包络信号,对包络信号进行包络分析,通过傅里叶变换进行轴承故障频域特征提取。

3.2.5 基于经验模态分解故障特征提取方法

经验模态分解 (Empirical Mode Decomposition, EMD) 是 1998 年由 Huang 等提出的时频域信号分析方法。该方法主要是将复杂的信号分解成若干固有模态函数 (IMF 分量) 和一个余项的和,并对 IMF 分量提取信号的特征。其中每个固有模态函数有相同的极值点和过零点,且上下包络均值均为零。

经验模态分解是一种基于数据本身的自适应处理非线性、非平稳信号

的分解方法。但存在模态混叠和端点效应等问题。模态混叠是指一个 IMF 分量中包含了尺度差异较大的信号,或是一个相似尺度的信号出现在不同的 IMF 分量中。

经验模态分解过程如下:

(1) 首先确定信号的所有的局部极值点,然后采用三次样条线将所有局部极大值点和极小值点连接起来,从而形成上包络线和下包络线。

(2) 上包络线和下包络线的均值记为 $m_1(t)$,然后计算信号 $x(t)$ 与均值 $m_1(t)$ 的差值 $h_1(t)$ 。

$$h_1(t) = x(t) - m_1(t) \quad (3.51)$$

(3) 如果 $h_1(t)$ 不满足固有模态函数条件,把 $h_1(t)$ 作为原始数据,并且重复步骤(1)和步骤(2),得到上下包络的均值 $m_{11}(t)$,则:

$$h_{11}(t) = h_1(t) - m_{11}(t) \quad (3.52)$$

若 $h_{11}(t)$ 仍不满足固有模态函数条件,则循环 k 次,直至 $h_{1k}(t)$ 满足条件。将信号 $x(t)$ 的第一个固有模态函数记为 $c_1(t)$,即:

$$c_1(t) = h_{1k}(t) \quad (3.53)$$

(4) 将 $c_1(t)$ 从 $x(t)$ 中分离出来,得到 $r_1(t)$:

$$r_1(t) = x(t) - c_1(t) \quad (3.54)$$

(5) 将 $r_1(t)$ 作为新的数据重复上述步骤,得到 $x(t)$ 的第二个固有模态函数 $c_2(t)$,重复 n 次得到 $r_n(t)$,直到不能从中提取出固有模态函数才结束。最终 $x(t)$ 可用 n 个固有模态函数(IMF 分量)和一个残余函数 $r_n(t)$ 表示,如式(3.55)所示。一般 $r_n(t)$ 不为零,它表示随机信号中存在线性项或缓慢变化的、周期大于记录长度的非线性项,通常代表信号的平均趋势。

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (3.55)$$

基于经验模态分解的故障特征提取就是针对轴承振动信号 $x(t)$ 进行 EMD 分解,分解后选择适当的 IMF 分量,再对 IMF 分量进行包络分析并提取轴承故障特征。

3.2.6 基于局部均值分解故障特征提取方法

局部均值分解(Local Mean Decomposition, LMD)是 Jonathan S. Smith 于 2005 年提出的一种自适应时频分析方法。局部均值分解主要是首先将源信号分离出包络信号和纯调频信号,再进一步将包络信号和调频信号进行

相乘,从而得到 PF 分量。所以局部均值分解的过程实际上就是一连串的 PF 分量。

局部均值分解 LMD 的运算步骤如下:

(1) 首先求出原始信号 $x(t)$ 所有的局部极值 n_i , 然后计算出 n_i 和 n_{i+1} 的平均值 m_i , 即

$$m_i = \frac{n_i + n_{i+1}}{2} \quad (3.56)$$

再将临近的极值点的平均值 m_i 连接起来进行平滑处理, 得到局部均值函数 $m_{11}(t)$ 。

(2) 利用局部极值点 n_i , 计算包络估计值 a_i , 公式如下:

$$a_i = \frac{n_i - n_{i+1}}{2} \quad (3.57)$$

同样也将所有临近的两个包络估计值 a_i 用直线连接起来进行平滑处理, 得到包络估计函数 $a_{11}(t)$ 。

(3) 将局部均值函数 $m_{11}(t)$ 从原始信号分离出来, 得到:

$$h_{11}(t) = x(t) - m_{11}(t) \quad (3.58)$$

(4) 用 $h_{11}(t)$ 除以包络估计函数 $a_{11}(t)$ 来进行解调, 得到:

$$s_{11}(t) = h_{11}(t) / a_{11}(t) \quad (3.59)$$

对 $s_{11}(t)$ 重复上述步骤, 得到 $s_{11}(t)$ 的包络估计函数 $a_{12}(t)$ 。若 $a_{12}(t)$ 不等于 1, 说明 $s_{11}(t)$ 不是一个纯调频信号, 需要重复上述迭代过程, 直到得到一个纯调频信号 $s_{1n}(t)$, 即 $s_{1n}(t)$ 的包络估计函数满足 $a_{1(n+1)}(t) = 1$ 。

(5) 将所有包络估计函数相乘得到包络信号:

$$a_1(t) = a_{11}(t) a_{12}(t) \cdots a_{1n}(t) = \prod_{q=1}^n a_{1q}(t) \quad (3.60)$$

用包络信号 $a_1(t)$ 乘以纯调频信号 $s_{1n}(t)$, 得到的乘积则为原始信号的第一个 PF 分量:

$$PF_1(t) = a_1(t) s_{1n}(t) \quad (3.61)$$

(6) 将首个 PF 分量 $PF_1(t)$ 从 $x(t)$ 里分离出来得到一个新的信号 $u_1(t)$, 将 $u_1(t)$ 作为原始数据进行 k 次迭代计算, 直至 $u_k(t)$ 成为第一个单调函数才停止。

(7) 最后, 将原始信号 $x(t)$ 分解为 k 个 PF 分量和一个单调函数 $u_k(t)$ 之和, 即

$$x(t) = \sum_{p=1}^k \text{PF}_p(t) + u_k(t) \quad (3.62)$$

(8) 再对所得到的 PF 分量进行包络分析。

基于局部均值分解的故障特征提取就是针对轴承振动信号 $x(t)$ 进行 LMD 分解, 分解后选择适当的 PF 分量, 再对 PF 分量进行包络分析并提取轴承故障特征。

3.2.7 基于变分模态分解故障特征提取方法

变分模态分解 (Variational Mode Decomposition, VMD) 是 Dragomiretskiy 等于 2014 年提出的一种自适应的信号分解方法, 是对经验模态分解的优化, 该方法在分解过程中通过循环迭代求取约束变分问题的最优解来确定分解得到的固有模态函数 (IMF 分量) 的频率中心及带宽, 实现信号各频率成分的有效分离。与经验模态分解和局部均值分解方法相比, 该方法具有较高的运算效率及良好的噪声鲁棒性。

在变分模态分解方法中, 假设振动信号 $x(t)$ 由 K 个有限带宽的 IMF 分量组成, 其中第 K 个 IMF 分量 $c_k(t)$ 可表示为一个调幅调频函数的形式: $c_k(t) = A_k(t) \cos(\varphi_k(t))$ 。其中 $A_k(t)$ 和 $\varphi_k(t)$ 分别表示 $c_k(t)$ 的瞬时振幅和瞬时相位函数。 $c_k(t)$ 的瞬时频率 $\omega_k(t)$ 为: $\omega_k(t) = \frac{d\varphi_k(t)}{dt}$ 。

建立带约束的变分优化问题:

$$\min_{\{c_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * c_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (3.63)$$

$$\text{s. t.} \quad x(t) = \sum_{k=1}^K c_k(t) \quad (3.64)$$

式中, $\delta(t)$ 为单位脉冲信号, j 是复数中虚数单位。

为求取上述约束变分问题的最优解, 引入惩罚因子 α 和 Lagrangian 乘子 λ , 其增广 Lagrangian 函数表示如下:

$$\begin{aligned} & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * c_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| x(t) - \sum_{k=1}^K c_k(t) \right\|_2^2 + \langle \lambda(t), x(t) - \sum_{k=1}^K c_k(t) \rangle \end{aligned} \quad (3.65)$$

利用交替方向乘子法求取上述 Lagrangian 函数的鞍点, 即为上述约束

变分优化问题的最优解,从而将 $x(t)$ 分解为 K 个窄带 IMF 分量。

变分模态分解 VMD 的运算步骤如下:

(1) 初始化 $\{\hat{c}_k^1\}$, $\{\omega_k^1\}$ 和 $\hat{\lambda}^1$, $n=0$ 。其中 $\hat{c}_k, \hat{\lambda}$ 是 $c_k(t), \lambda(t)$ 的傅里叶变换。

(2) 使 $n=n+1$, 开始执行迭代循环。

(3) 使 $k=k+1$, 按照下面公式, 更新对 $\hat{c}_k^{n+1}$ 和 ω_k^{n+1} , 直至 $k=K$ 。

$$\hat{c}_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{i=1, i \neq k}^K \hat{c}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (3.66)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{c}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{c}_k^{n+1}(\omega)|^2 d\omega} \quad (3.67)$$

(4) 对 λ 进行更新, 其中 τ 为步长因子, 更新的公式如下:

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau \left[\hat{x}(\omega) - \sum_{k=1}^K \hat{c}_k^{n+1}(\omega) \right] \quad (3.68)$$

其中 $\hat{x}(\omega)$ 是 $x(t)$ 的傅里叶变换。

(5) 重复步骤(2)~步骤(4), 直到满足下面停止条件, 或达到迭代最大步长 n 。其中 ϵ 为迭代停止标准阈值。

$$\sum_{k=1}^K \|\hat{c}_k^{n+1} - \hat{c}_k^n\|_2^2 / \|\hat{c}_k^n\|_2^2 < \epsilon \quad (3.69)$$

结束迭代循环, 得到 K 个 IMF 分量, 满足其带宽总和最小。

基于变分模态分解的故障特征提取就是针对轴承振动信号 $x(t)$ 进行 VMD 分解, 分解后选择适当的 IMF 分量, 再对 IMF 分量进行包络分析并提取轴承故障特征。

3.3 轨道交通轴承故障特征选择技术

从给定的特征集合中选择或投影变换出与故障紧密相关的特征子集的过程, 称为特征选择。轨道交通轴承故障特征选择的目的是去除与故障诊断不相关的特征或者去除冗余特征, 这样往往会降低故障诊断任务的计算开销、提升故障分类性能。具体特征选择过程如图 3.1 所示。

通常特征选择过程是一个循环反复、多次迭代的过程, 对特征选择后得




图 3.1 特征选择过程

到的子集 S 要进行特征评价,依据代价函数 $J(S)$ 对应的评价分值或其他评价条件确定特征选择过程是否结束。常用的特征选择方法有基于主成分分析的特征选择方法,基于线性判别分析的特征选择方法,基于信息熵的特征选择方法,以及基于自编码等的特征选择方法等。

3.3.1 基于主成分分析的特征选择方法

主成分分析(Principal Components Analysis, PCA)是 Karl 和 Pearson 于 1901 年提出的一种无监督降维算法,可以用于故障特征选择。该方法的核心原理是找到一个投影面,使得数据投影在投影面上尽可能地保留原始数据的特征。通常该投影面满足:①所有数据点到投平面的距离足够近;②所有样本点到投平面的投影可以尽可能分开。

基于主成分分析的特征选择方法具体步骤如下:

(1) 原始数据去中心化处理。采用下式对原始数据进行去中心化处理,使得处理后的数据均值为 0,标准差为 1。

$$x_i^* = \frac{x_i - \mu}{\sigma} \quad (3.70)$$

其中, μ 为总体样本数据的均值, σ 为标准差, x_i 为原始数据。

(2) 确定最优化投影方差函数。对数据 x_i^* 进行线性变换 $U^T x_i^*$, 其线性变换后的协方差矩阵为:

$$\frac{1}{n} \sum_{i=1}^n (U^T x_i^*)^2 = \frac{1}{n} \sum_{i=1}^n U^T x_i^* (x_i^*)^T U \quad (3.71)$$

其中, $\frac{1}{n} \sum_{i=1}^n x_i^* (x_i^*)^T$ 为原始数据的协方差矩阵,用 S 表示,则最优化投影方差函数可表示为:

$$\max_{u_1} U^T S U \quad (3.72)$$

$$\text{s. t. } \|U\|_2^2 = 1 \quad (3.73)$$

(3) 使用 Lagrangian 乘子法求解最优化投影方差函数,按照所需维度

确定最优化矩阵。对优化函数使用 Lagrangian 乘子法可得:

$$SU = \lambda U \quad (3.74)$$

对协方差矩阵进行特征分解,将求出的特征值 λ_i 按大小进行排序,将相应的特征向量进行排列,可取前 k 个特征向量形成最优化矩阵 $U = (u_1, u_2, \dots, u_k)$ 。

(4) 最优化矩阵 U 乘以全体原始数据 X 就得到特征选择后的数据 Y 。

3.3.2 基于线性判别分析的特征选择方法

线性判别分析 (Linear Discriminant Analysis, LDA) 是 Fisher 于 1936 年提出的一种有监督降维算法,其目标是将数据投影到低维空间来避免维度灾难引起的过拟合,可以用于故障特征选择。LDA 方法与 PCA 方法十分相似,都是通过计算投影面上的方差来进行降维的,但不同于 PCA 的是 LDA 的降维标准是找到的最佳投影面使得投影后数据类内方差尽可能小,而类间方差尽可能大。

基于线性判别分析的特征选择方法的具体步骤如下:

(1) 确定类内散度 S 和类间散度 S' 。设给定的数据集为 $D = \{(x_i, l_i)\}$, 其中 x_i 表示第 i 个数据, $i = 1, 2, \dots, n$ 。 l_i 为第 i 个数据的标签, $l_i = 1, 2, \dots, m$, 共有 m 个类别的标签。 X_j 表示标签为第 j 类所有的数据, 其个数用 n_j 表示, 有 $n_1 + n_2 + \dots + n_j + \dots + n_m = n$ 。用 u_j 表示第 j 类内均值向量, 所有类内均值向量用 u 表示。

则类内散度矩阵定义为

$$S = \sum_{j=1}^m \sum_{x_i \in X_j} (x_i - u_j)(x_i - u_j)^T \quad (3.75)$$

类间散度矩阵为

$$S' = \sum_{j=1}^m n_j (u_j - u)(u_j - u)^T \quad (3.76)$$

(2) 构建最优代价函数。将数据 x_i 投影到由正交基向量构成的新坐标系 α 上, 即对数据 x_i 作线性变换 $\alpha^T x_i$ 。为了得到最优的投影面, 构建如下最优化函数, 即代价函数

$$\min J(\alpha) = \frac{\alpha^T S \alpha}{\alpha^T S' \alpha} \quad (3.77)$$

通过 Lagrangian 函数求解得:

$$\alpha S' = \lambda \alpha S \quad (3.78)$$

经整理得协方差矩阵:

$$\lambda = S^{-1} S' \quad (3.79)$$

(3) 确定最优投影矩阵。将求出的特征值 λ_i 按大小进行排序, 将相应的特征向量进行排列。可取前 p 个特征向量构成最优投影矩阵 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_p)$ 。

(4) 最优投影矩阵 α 乘以全体原始数据 X 就得到特征选择后的数据 Y 。

3.3.3 基于信息熵的量化特征选择方法

信息熵是香农(Shannon)于 1948 年提出的, 香农将热力学中熵的概念引入到信息论中, 采用数值形式表达随机变量取值的不确定性程度。

假定样本集合 D 中, X 是一个含有 n 个离散值的类别随机变量, 变量 X 取值为 x_i 的概率为: $P(X=x_i) = p_i, i=1, 2, \dots, n$, 那么在样本集合 D 中类别随机变量 X 的信息熵定义为

$$H_D(X) = - \sum_{i=1}^n p_i \log p_i \quad (3.80)$$

信息熵越低不确定性越低, 表明所包含的信息越少, 信息熵可用于解决信息的量化问题。由于信息熵能很好地量化特征相对于类别的不确定性程度, 用它可以很好判定其包含的分类信息含量, 因此它经常被应用在特征选择方法中。

基于信息熵的量化特征选择方法的具体步骤如下:

(1) 由信息熵的定义公式计算样本集合 D 中类别随机变量 X 的信息熵。依据信息熵定义可知, 信息熵 $H_D(X)$ 只与随机变量 X 的概率分布有关, 而与其具体取值无关。信息熵越大, 所代表的不确定程度越高, 消除或减少这一不确定性时所需的信息量也越多。

(2) 确定待特征选择随机变量的条件熵。条件熵是指已知一个特征随机变量 Y 的条件下, 类别随机变量 X 的不确定性程度, 其公式定义如下:

$$H_D(X | Y) = - \sum_{j=1}^V \frac{|D_j|}{|D|} H_{D_j}(X) \quad (3.81)$$

式中, V 是特征选择随机变量 Y 的可能取值个数, D_j 为变量 Y 的第 j 个取值的样本集合, 有 $D_1 + D_2 + \dots + D_V = D$ 。由定义可知, 若 X 完全依赖于 Y , 那么 $H_D(X|Y) = 0$, 表示 Y 已包含了 X 的信息; 反之, $H_D(X|Y) =$

$H_D(X)$, 意味着这两个变量是相互无关或独立的, 即 X 的不确定性程度不依赖于 Y 。条件熵取值大小表明了类别随机变量依赖于特征随机变量的强弱程度。

(3) 计算特征随机变量 Y 所获得的信息增益。定义随机变量 Y 所获得的信息增益为

$$G_D(X | Y) = H_D(X) - H_D(X | Y) \quad (3.82)$$

特征随机变量 Y 的信息增益越大, 则意味着使用特征随机变量 Y 对类别随机变量不确定性程度的降低贡献越大, 亦即特征中所包含有助于分类的信息就越多。

(4) 按特征随机变量的信息增益的大小排序, 依次选择具有较大信息增益的特征随机变量, 完成选取所需数量的特征选择。因此, 基于信息熵的量化特征选择就是选择具有较大信息增益的特征随机变量。

3.3.4 基于自编码器的特征选择方法

自编码器(AutoEncode)是 Rumelhart 于 1986 年提出的概念, 它是一种非监督的人工神经网络, 它分为编码器(Encoder)和解码器(Decoder)两部分, 其原理是将输入的数据通过编码器编码提取特征, 再通过解码器对提取好的特征进行解码操作, 得到解码后的数据与原数据进行对比求出预测误差, 再进行误差反向传递逐步提升自编码的准确性。自编码器可用于故障特征选择及数据降维等应用。

自编码器的结构如图 3.2 所示, 通过调节网络权值和偏置使得输入数据




图 3.2 自编码器的结构

X 与解码后的数据 X' 尽可能相同。

基于自编码器的特征选择方法的具体步骤如下:

(1) 编码器编码。输入轴承振动信号数据为 $\{X_N\}$, N 为数据维度。通过编码器得到特征数据 $\{Y_P\}$, P 为编码后的维度, 编码过程中数据减少的维度是 $N-P$ 维, 其编码过程的激活函数可表示为

$$Y = f(wX + b) \quad (3.83)$$

(2) 解码器解码。以特征数据 $\{Y_P\}$ 为输入端, 通过解码器得到解码后的数据 $\{X'_N\}$, 其激活函数可表示为

$$X' = g(w'X' + b') \quad (3.84)$$

(3) 反向误差传递调参。将解码后的数据 $\{X'_N\}$ 与输入的原始数据 $\{X_N\}$ 对比求出预测误差:

$$\min_{\{w, b\}, \{w', b'\}} E(X, X') = \min \|X - X'\| \quad (3.85)$$

其中, $\{w, b\}$ 分别表示为自编码器网络的权值和偏置, 通过反向传递不断调节网络的权值和偏置, 得到最优的 $\{w, b\}$ 。再对所有的输入数据 X , 提取其最佳特征值 Y 。

3.4 轨道交通轴承故障智能诊断技术

轨道交通滚动轴承故障智能诊断技术就是利用人工智能技术进行基于数据驱动的轴承故障诊断, 这种方法的优点是可以充分挖掘故障数据的特征, 可以挖掘出传统的专家系统无法涵盖到的特征。基于数据驱动的轴承故障智能诊断方法大致可以分为两类: 轴承故障数据挖掘智能诊断方法和轴承故障深度学习智能诊断方法。数据挖掘主要利用人工神经网络、支持向量机和决策树等传统机器学习算法搭建诊断模型, 适合对传统小规模数据集进行学习, 而深度学习方法主要利用卷积神经网络、深度信念网络、循环神经网络等深度神经网络方法搭建诊断模型, 适合对大规模数据集进行学习。

3.4.1 人工神经网络

人工神经网络(Artificial Neural Network, ANN)是指由神经元模型连接而成的拓扑网络结构, 如图 3.3 所示, 通常包括输入层, 隐藏层(有时简称隐层或中间层)和输出层三层网络结构, 最初神经元模型(简称 M-P 神经元

模型)是由心理学家 W. S. McCulloch 和数理逻辑学家 W. Pittes 于 1943 年提出的用于模仿生物学的神经元。Rumelhart 等于 1985 年提出了误差反向传播 BP 算法(Error Back Propagation),使含有隐藏层的人工神经网络的训练成为可能,大大加快了人工神经网络的发展。人工神经网络模型是机器学习数据挖掘中的一种常见模型,它是基于数据结构对生物神经网络信息处理状态的模仿来达到自主学习的功能,在故障模式诊断中应用极广。




图 3.3 三层人工神经网络的拓扑结构

人工神经网络建模流程如下所示:

(1) 构建合适的人工神经网络,包括含多个神经元模型的输入层,隐藏层和输出层网络结构。

(2) 数据输入经由隐藏层传播。具体过程为数据经由输入层输入,乘以权重后相加,再通过与阈值相减,最后通过激活函数处理向下继续传播。设输入信号为 x_i ,对应权重为 w_i ,阈值为 θ ,激活函数为 f ,输出为 y ,则 y 可用如下输出公式表示:

$$y = f\left(\sum_i w_i x_i - \theta\right) \quad (3.86)$$

(3) 数据传递到最后会产生预测结果,将其与训练集真实值进行对比,得出计算误差,判断误差是否满足要求。若不满足,则使用误差反向传播 BP 算法反向更新参数,以求减少误差,更新完成后再次进行训练,直到误差满足条件,停止循环,完成人工神经网络模型的构建。

人工神经网络建模流程中涉及的误差反向传播 BP 算法描述如下:

(1) 我们采用 Sigmoid 函数,即 $f(x) = \frac{1}{1 + e^{-x}}$ 作为激活函数 f ,对输出层单元 j ,误差 Err_j 可用下式计算:

$$\text{Err}_j = O_j(1 - O_j)(T_j - O_j) \quad (3.87)$$

其中, O_j 是单元 j 的实际输出, T_j 是单元 j 的真实值。

对隐藏层单元 j 的误差用下式计算:

$$\text{Err}_j = O_j(1 - O_j) \sum_k \text{Err}_k w_{jk} \quad (3.88)$$

其中, w_{jk} 是单元 j 到其下一层单元 k 的连接权重, Err_k 是单元 k 的误差。

(2) 对权值 w_{ij} 和阈值 θ_j 的更新用下式计算:

$$w_{ij} = w_{ij} + \Delta w_{ij} = w_{ij} + l \text{Err}_j O_i \quad (3.89)$$

$$\theta_j = \theta_j + \Delta \theta_j = \theta_j + l \text{Err}_j \quad (3.90)$$

其中, O_i 是上一层单元 i 的输出, l 是学习率, 通常取值在 0-1 之间。

3.4.2 支持向量机

支持向量机(Support Vector Machine, SVM)是 Vapnik 于 1995 年提出的, 是一种有监督机器学习数据挖掘方法, 它是一种利用超平面将线性或非线性数据进行分类的方法, SVM 使用支持向量和边缘来发现几何间隔最大的分离超平面, 这种方法常用于故障诊断分类模型应用中。

如图 3.4 所示, 平面 $\mathbf{w}^T \mathbf{x} + b = 0$ 即为能够正确划分图中数据集 D 并且距离边缘几何间隔最大的分离超平面, 其中 $\mathbf{w}$ 为决定超平面方向的法向量; b 为决定超平面与原点距离的位移项, $\mathbf{w}^T \mathbf{x} + b = 1$ 和 $\mathbf{w}^T \mathbf{x} + b = -1$ 为几何间隔最大的两个边缘, 边缘上的样本点被称为支持向量。两个边缘的间隔 d 为

$$d = \frac{2}{\|\mathbf{w}\|} \quad (3.91)$$

寻找最大间隔的分离超平面, 就是要找到满足条件的 $\mathbf{w}$ 和 b 使得 d 最大化, 即

$$\max_{\mathbf{w}, b} \frac{2}{\|\mathbf{w}\|} \quad (3.92)$$

$$\text{s. t. } y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad i = 1, 2, \dots, n \quad (3.93)$$

最大化 $\frac{2}{\|\mathbf{w}\|}$ 就相当于最小化 $\frac{\|\mathbf{w}\|}{2}$, 即

$$\min_{\mathbf{w}, b} \frac{\|\mathbf{w}\|^2}{2} \quad (3.94)$$




图 3.4 SVM 最大分离超平面

$$\text{s. t. } y_i (\mathbf{w}^T x_i + b) \geq 1 \quad i = 1, 2, \dots, n \quad (3.95)$$

其中, $y_i \in \{-1, +1\}$, 对应数据 x_i 的类别。

支持向量机建模流程如下所示:

(1) 输入样本数据, 分析数据样本是否是线性可分。对非线性可分的数据, 可选择核函数, 这样可以在高维空间将样本划分。核函数的作用就是将样本从原始空间映射到一个更高维的特征空间, 使样本在这个特征空间线性可分。通常要根据实际情况选用适合的核函数, 以下给出几种常用核函数。

线性核: $\kappa(x_i, x_j) = \mathbf{x}_i^T \mathbf{x}_j$

多项式核: $\kappa(x_i, x_j) = (\mathbf{x}_i^T \mathbf{x}_j)^d$, $d \geq 1$ 为多项式的次数

高斯径向基函数核: $\kappa(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$, $\sigma > 0$ 为高斯核

的带宽

拉普拉斯核: $\kappa(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|}{\sigma}\right)$, $\sigma > 0$

S 形核: $\kappa(x_i, x_j) = \tanh(\beta \mathbf{x}_i^T \mathbf{x}_j - \theta) \tanh$, 为双曲正切函数, $\beta > 0, \theta > 0$

(2) 针对实际应用中很难找到合适的核函数将样本精准划分, 所以通常在选择最大分隔面的同时, 允许某些样本不满足约束, 但不满足约束的样本应尽可能少。为此可利用替代损失函数, 构建软间隔 SVM。通过引入样本松弛

变量来表征不满足约束的程度,构建软间隔支持向量机模型,如下所示:

$$\min_{w,b,\xi_i} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i \quad (3.96)$$

$$\text{s. t. } y_i(w^T x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, i = 1, 2, \dots, m \quad (3.97)$$

(3) 通过 Lagrangian 乘子法结合软间隔 SVM 公式得到其对偶问题。

该问题的 Lagrangian 函数可表示为

$$L(w, b, \alpha, \mu, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i + \sum_{i=1}^m \alpha_i (1 - \xi_i - y_i (w^T x_i + b)) - \sum_{i=1}^m \mu_i \xi_i \quad (3.98)$$

其中,每条约束中添加的 α_i 为 Lagrangian 乘子。

令 $L(w, b, \alpha, \mu, \xi)$ 分别对 w, b 和 ξ_i 偏导为 0 可得:

$$w = \sum_{i=1}^m \alpha_i y_i x_i \quad (3.99)$$

$$\sum_{i=1}^m \alpha_i y_i = 0 \quad (3.100)$$

$$\alpha_i + \mu_i = C \quad (3.101)$$

将上述各式代入软间隔支持向量机模型,可得其对偶问题

$$\max_{\alpha} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (3.102)$$

$$\text{s. t. } \sum_{i=1}^m \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C, i = 1, 2, \dots, m \quad (3.103)$$

(4) 通过 SMO 算法求解上式对偶问题。

SMO 算法是由 John C. Platt 在 1998 年提出的,通过 SMO 算法求解对偶最问题的具体方法如下:先根据约束条件随机给 Lagrangian 乘子 α 赋值,然后每次选取两个 α ,调节两个 α 使得目标函数最小,然后再选取两个 α 重复上面的步骤,以此类推直到取得最佳的 α^* 使得目标函数达到最优。

(5) 将 Lagrangian 乘子 α 代入,可求出 w 和 b ,进而得到最大间隔超平面。通过该最大间隔超平面可得到数据样本分类结果。

3.4.3 决策树

决策树模型构建方法是一种有监督机器学习分类方法。如图 3.5 所示,

决策树中的内部节点表示在一个属性上的测试,每个分支代表一个测试输出,每个树叶节点存放一个分类标号,树的最顶层节点是根节点。决策树模型构建过程实际上就是一个不断选择最优划分属性进行数据样本分类的过程,决策树建模方法的关键就在于如何选择最优划分属性。常用的最优划分属性的度量标准有信息增益、增益率和基尼指数等。决策树分类方法可应用于轴承故障诊断中。




图 3.5 决策树示意图

决策树建模流程如下所示。

(1) 针对输入数据样本,决策树采用贪婪方法,依据最优划分属性的度量标准来选择将数据最好划分成不同类的属性。信息增益是最优划分属性的度量标准中最常用的一种指标。信息增益越大,则意味着使用该属性划分数据集所获得的纯度提升越大。常用的决策树算法有 ID3, C4.5 和 CART 等,其中基于信息增益的 ID3 算法最早由 J. Ross Quinlan 于 1975 年提出。ID3 算法就是使用信息增益最大的属性作为划分属性。由于信息增益会偏好取值数目较多的属性,为克服这种偏倚,C4.5 算法使用增益率来选择最优划分属性。

(2) 决策树构建采用自顶向下方法,不断选择当前最优划分属性,将数据集划分为较小的子集,直至当前节点包含的数据样本属于同一类别,决策树生成。

(3) 决策树剪枝处理。在决策树学习过程中,为了尽可能正确分类数据样本,会不断地根据属性划分节点,有时会造成决策树分支过多,带来过拟合的风险。为了解决过拟合的问题需要决策树剪枝处理。剪枝处理分为预剪枝和后剪枝两种。但预剪枝决策树有造成欠拟合的风险,可利用后剪枝方法,对决策树进行剪枝处理,提高决策树模型泛化性。

3.4.4 卷积神经网络

卷积神经网络(Convolutional Neural Networks,CNN)由 Yann LeCun 等于 1989 年提出,是一类包含卷积计算且具有深度结构的前馈神经网络(Feedforward Neural Networks),它可以有效地进行监督学习和非监督学习,被应用于计算机视觉、自然语言处理、设备故障诊断等领域,是深度学习最重要的代表方法之一。

卷积神经网络模型结构如图 3.6 所示,其由输入层(Input layer)、卷积层(Convolutional layer)、池化层(Pooling layer)、全连接层(Fully connected layers)和输出层(Output layer)组成。通过增加卷积层和池化层,还可以得到更深层次的网络结构,其后的全连接层也可以采用多层结构。输出层可以通过 Softmax 函数对数据样本进行分类。




图 3.6 卷积神经网络结构

卷积神经网络建模流程如下所示。

- (1) 数据样本进入卷积层,经过卷积处理,提取特征生成特征图。
- (2) 特征图进入池化层,池化层对特征图进行特征选择和信息过滤,使用池化函数将特征图的单点替换为相邻区域统计量。
- (3) 全连接层对数据特征进行拼接合并,计算误差是否满足条件。满足则输出,不满足则使用 BP 算法对网络参数进行更新。
- (4) BP 算法更新完成后重新进行第一步,不断循环直至满足要求。

3.4.5 深度信念网络

深度信念网络(Deep Belief Network,DBN)由 Geoffrey Hinton 于 2006 年提出,这是一种采用逐层训练方式训练的深度神经网络,逐层训练的基本思想是每次训练一层节点,把上层节点的输出作为本层节点的输入,把本层节点的输出当作下层节点的输入,当全部节点训练完成后再对整个网络进

行微调训练。DBN 既可以用于非监督学习,类似于一个自编码器;也可以用于监督学习,作为分类器来使用,用于设备故障诊断等领域。

深度信念网络模型结构如图 3.7 所示,其由多层的受限玻尔兹曼机(Restricted Boltzmann Machine,RBM)组成的。RBM 包含两个层,可见层(visible layer)和隐藏层(hidden layer),并且层内无连接,层间全连接,可见层单元用来描述观察数据的一方面或一个特征,而隐藏层用来表示特征提取。




图 3.7 深度信念网络结构

深度信念网络建模流程如下所示:

(1) DBN 预训练。数据样本通过输入层,分别单独无监督地训练每一层 RBM 网络。RBM 网络是一种基于能量的模型,可以把网络的状态定义为能量,当能量达到最小时,网络状态最佳,RBM 网络训练过程就是使能量函数达到最小化的过程,可使用 Hinton 提出的对比散度算法(Contrastive Divergence,CD)更新训练 RBM 参数。通过层层训练,确保特征向量映射到不同特征空间时,都尽可能多地保留特征信息。

(2) DBN 微调。在 DBN 的最后一层设置 BP 网络,有监督地训练最后分类结果,通过计算误差评定,若不满足条件则采用反向传播网络将误差信息自顶向下传播至每一层 RBM,微调整个 DBN 网络。

(3) 通过不断重复训练,直至误差满足要求,输出结果。

3.4.6 循环神经网络

循环神经网络(Recurrent Neural Network,RNN)是一类以序列数据为

输入,在序列的演进方向进行递归且所有节点(循环单元)按链式连接的递归神经网络。第一个全连接的循环神经网络在1990年被Jeffrey Elman提出,即Elman网络。循环神经网络经过多年的发展完善,现已发展为深度学习中的一类重要方法,其中双向循环神经网络(Bidirectional RNN, Bi-RNN),长短期记忆网络(Long Short-Term Memory networks, LSTM)和门限循环单元网络(Gated Recurrent Unit networks, GRU)是目前最常见的循环神经网络。循环神经网络对序列的非线性特征的学习具有一定优势,被广泛应用在语音识别、机器翻译、时间序列设备故障诊断和预测等领域。

循环神经网络模型结构如图3.8所示,其可以看作是一个全连接神经网络引入了循环机制,由若干循环单元连接组成,当前循环单元输出值不仅受到当前输入影响,也受到以前输入的影响。RNN输入序列通常为时间序列,序列的演进方向被称为时间步,用 t 表示。循环单元都通过权重 W 连接。从图中我们可以看出,输出 o_t 由隐藏层 s_t 和权重 V 决定,而 s_t 又由输入 x_t 和权重 U 以及前一刻隐藏层 s_{t-1} 及权重 W 共同决定,它也体现了RNN记忆性与参数共享的特点。




图 3.8 循环神经网络结构

循环神经网络建模流程如下所示。

- (1) 输入数据样本进入循环单元,经循环单元计算后输出。
- (2) 计算输出数据的误差,若误差不满足结束条件,使用时间反向传播BPTT(Back-Propagation Through Time)算法更新循环单元参数,BPTT算法的本质是沿时间传播的BP算法,其步骤与BP算法基本相同,前向计算每个神经元的输出值,反向计算每个神经元的误差值,通过计算每个权重梯度,用随机梯度下降算法更新权重。

- (3) 通过不断重复训练,循环进行神经网络学习,直至满足条件结束。