

基于NSST4-SVD-DBN的带式输送机托辊 轴承故障诊断方法

胡坤^{1,2*} 陈卓² 韩信³ 蒋浩² 牛杰²

1. 安徽理工大学深部煤炭无人化开采数智技术全国重点实验室, 淮南, 232000

2. 安徽理工大学机电工程学院, 淮南, 232000

3. 淮南矿业有限责任公司顾桥煤矿, 淮南, 232000

摘要: 针对带式输送机托辊轴承故障所产生的特征信息难以提取, 以及故障诊断识别准确率低、鲁棒性差的问题, 将二重四阶同步压缩变换(NSST4)、奇异值分解(SVD)与深度置信网络(DBN)相结合, 提出一种带式输送机托辊轴承声信号故障诊断方法。利用逐次变分模态分解(SVMD)对声信号进行处理以增强故障特征的可辨识度。通过NSST4将处理后的一维信号转换为二维时频矩阵, 并将该矩阵作为特征矩阵输入。采用SVD技术对特征矩阵进行降维处理, 提取出能够表征托辊轴承状态的关键奇异值向量。这些奇异值向量随后被输入DBN中, DBN核心参数通过改进的麻雀搜索算法(ISSA)进行优化, 以提高模型的识别性能。通过模拟故障实验和现场实验进行了测试, 验证了所提方法的有效性。在托辊轴承的模拟故障实验中, 所提方法实现了97.91%的准确率。与其他5种方法对比发现, 所提方法准确率最高, 且平均绝对误差(MAE)最低。在现场实验中, 识别准确率可达96.57%。

关键词: 故障诊断; 声信号; 二重四阶同步压缩变换; 奇异值分解; 深度置信网络

中图分类号: TP133.3

DOI:10.3969/j.issn.1004-132X.2026.03.015

开放科学(资源服务)标识码(OSID):



Fault Diagnosis Method of Belt Conveyor Roller Bearings Based on NSST4-SVD-DBN

HU Kun^{1,2*} CHEN Zhuo² HAN Xin³ JIANG Hao² NIU Jie²

1. State Key Laboratory of Digital Intelligent Technology for Unmanned Coal Mining, Anhui University of Science and Technology, Huainan, Anhui, 232000

2. Faculty of Mechanical and Electrical Engineering, Anhui University of Science and Technology, Huainan, Anhui, 232000

3. Huainan Mining Company Limited Guqiao Coal Mine, Huainan, Anhui, 232000

Abstract: Aiming at the problems of difficulty in extracting feature information generated by belt conveyor roller bearing faults, as well as low accuracy and poor robustness of fault diagnosis and identification, NSST4, SVD and DBN methods were combined to propose a suitable method for belt conveyor roller bearing acoustic signal fault diagnosis. Firstly, sequential variational mode decomposition (SVMD) was used to process the acoustic signals to enhance the recognizability of fault features. Second, the processed one-dimensional signals were converted to a two-dimensional time-frequency matrix by NSST4, which was used as the inputs of the feature matrix. Subsequently, the feature matrix was downsized using SVD technique to extract the key singular value vectors that might characterize the status of the roll bearings. These singular value vectors were then input into DBN, and the DBN core parameters were optimized by the improved sparrow search algorithm (ISSA) to improve the recognition performance of the model. Finally, in order to further validate the effectiveness of the proposed method, it was tested by simulated fault experiments and field experiments. In the simulated fault experiments of the roller bearings, the accuracy rate of the proposed method reaches 97.91%. Compared with other 5 methods, the accuracy of the proposed method is the highest, and the mean absolute error (MAE) is the lowest. In the field experiments, the recognition accuracy reaches 96.57%.

Key words: fault diagnosis; acoustic signal; double fourth-order synchronous compression transform (NSST4); singular value decomposition (SVD); deep belief network(DBN)

收稿日期: 2025-04-25

基金项目: 国家自然科学基金(52274153, 51874004); 芜湖研究院研发专项基金(ALW2021YF10)

0 引言

带式输送机以其长距离输送、大运输量、连续作业和易于自动化控制等优势,已成为世界上使用范围最广、最为重要的散状物料连续运输设备之一,在煤炭、电力、物流和建材等多个关键经济领域中发挥着重要作用^[1]。特别是在煤炭行业中,带式输送机已成为高效矿井煤炭开采机电一体化系统中必不可少的核心装备^[2]。托辊作为带式输送机的核心部件,起着支撑传输带及物料,降低运输阻力的重要作用。而轴承是连接托辊筒体和中心轴的关键环节,其发生故障的概率在托辊损坏中占比较大^[3]。为了确保带式输送机的高效和安全运行,托辊轴承的故障检测尤为重要。

在带式输送机托辊轴承故障检测传统方法中,振动信号和红外图像检测虽被广泛应用,但存在检测精度不高、成本昂贵且对环境因素敏感等问题^[4-5]。相比之下,声信号检测具有非接触、适应性强和维护成本低等优势,尤其适用于高温、高腐蚀及难接触的工况环境,在工业应用中更具吸引力^[6-7]。目前,基于声信号,研究人员针对轴承故障特征提取提出了多种方法。王金瑞等^[8]提出了一种基于并行稀疏滤波的轴承故障诊断方法,通过增加归一化方向和权值归一化约束,实现更稀疏的特征提取。郝旺身等^[9]提出了一种基于递归 Hilbert 变换和一维卷积神经网络的轴承故障诊断方法,通过递归 Hilbert 变换增强信号特征,并利用卷积神经网络自动提取抽象特征,提高了故障诊断精度和效率。HEMMATI 等^[10]提出了一种基于小波包变换(WPT)的滚动轴承故障检测和尺寸估计方法,通过优化峭度与香农熵的比值选择最优带通滤波器,并利用 WPT 和包络检测提取特征频率,准确实现了故障检测和缺陷尺寸估计。然而,由于输送带具有较高弹性,托辊运行状态更加复杂,信号特征分散且难以提取,现有基于声音信号的处理方法在该领域应用中仍存在适应性不足的问题。

为此,本文提出了一种融合高阶同步压缩变换(SSTM)和多重同步压缩(NSST)的方法,构建多重高阶同步压缩变换(NSSTM)。在该框架下采用 NSST4 提高时频分析(TFA)分辨率,减少能量泄漏和模式混叠,更好地适应非平稳信号变化。但二重四阶同步压缩变换(NSST4)产生的时频矩阵维数较高、冗余信息较多,为简化后续处理过程,本文采用奇异值分解(singular value

decomposition, SVD)对其降维,通过保留最大奇异值对应的特征向量实现特征矩阵的有效简化^[11]。

目前传统轴承故障识别研究多采用反向传播(BP)神经网络和支持向量机(SVM)等浅层学习模型,难以准确挖掘信号特征与故障模式间的复杂映射关系,导致识别精度与鲁棒性不足^[12-13]。深度置信网络(deep belief network, DBN)由于具有较强的泛化性和映射能力受到广泛关注^[14-15]。该网络由多个受限玻尔兹曼机(RBM)堆叠而成,通过无监督逐层预训练和有监督微调实现多层次特征学习,在复杂高维问题中表现出强大的泛化能力^[16-18]。

基于以上分析,本文将 NSST4、SVD 及 DBN 相结合,提出了一种针对带式输送机托辊轴承故障识别的新方法。为了验证所提方法的优越性和有效性,本研究通过模拟信号分析、托辊故障模拟实验以及现场实验 3 个层面进行了全面测试。模拟信号分析展示了所提方法在处理复杂信号时的优越性;托辊故障模拟实验则在不同工况下验证了方法对不同故障类型的识别能力;现场实验则进一步证明了该方法在实际应用中的可行性和有效性。

1 基本理论

1.1 特征矩阵构建

本文采用多重高阶同步压缩变换对声信号进行时频分析。

首先引出短时傅里叶变换(STFT):

$$STFT_x(t, f) = \int_{\mathbf{R}} x(\tau) g(t - \tau) e^{-j2\pi f\tau} d\tau \quad (1)$$

式中: t 为时间变量; f 为频率变量; $STFT_x(t, f)$ 为短时傅里叶变换; τ 为时间单位; \mathbf{R} 为实数域; $g(t - \tau)$ 为窗函数。

由于 STFT 无法同时兼顾时间与频率的分辨率,存在部分能量泄漏的情况,研究人员提出了同步压缩变换(synchrosqueezing transform, SST),将时频点能量压缩并沿频率轴重新分配,以减小能量发散,其瞬时频率计算如下:

$$\hat{\omega}_x(t, f) = \frac{1}{2\pi} \partial_t \arg(STFT_x(t, f)) = \operatorname{Re} \left(\frac{\partial_t STFT_x(t, f)}{2\pi STFT_x(t, f)} \right) \quad (2)$$

式中: $\operatorname{Re}()$ 为实数部分; ∂_t 为对时间 t 的偏导算子。

此时重新分配后的结果为

$$SST(t, f) = \frac{1}{g(0)} \int_{\mathbf{R}} STFT_x(t, f) \delta(\omega - \hat{\omega}_x(t, f)) df \quad (3)$$

$$\hat{\omega}_x(t, f) = \frac{\partial_t STFT_x(t, f)}{2\pi STFT_x(t, f)}$$

式中: $g(0)$ 为窗函数; δ 为脉冲函数; ω 为信号的瞬时角频率。

同步压缩变换在一定程度上改善了 STFT 的时频分辨率,但在处理强非平稳信号时仍存在瞬时频率估计误差。为提高瞬时频率估计精度,研究者提出了二阶同步压缩变换(SST2),其核心形式如下所示:

$$\left. \begin{aligned} \hat{q}(t, f) &= \frac{\partial_t \hat{\omega}_x(t, f)}{\partial_t \hat{t}_x(t, f)} \\ \hat{t}_x(t, f) &= t - \frac{\partial_j STFT_x(t, f)}{2\pi j T F T_x(t, f)} \end{aligned} \right\} \quad (4)$$

则二阶瞬时频率为

$$\hat{\omega}_{j,x}^{(2)}(t, f) = \hat{\omega}_x(t, f) + \hat{q}(t, f)(t - \hat{t}_x(t, f)) \quad (5)$$

所以信号的 SST2 表达式如下:

$$SST_2(t, f) = \frac{1}{g(0)} \int_{\mathbb{R}} STFT_x(t, f) \delta(\omega - \hat{\omega}_{j,x}^{(2)}(t, f)) df \quad (6)$$

SST2 将 STFT 的瞬时频率估计提高至二阶。为进一步提高对快速变化非平稳信号的适应性,研究者提出了更具通用性的 SSTM。

M 阶调制系数 $\hat{q}^{(k,M)}$ 为 SST 瞬时频率估计对时间的 $M-1$ 阶导数,其数学公式为

$$\text{Re}(\hat{q}^{(k,M)}) = \frac{\varphi^{(k)}(t)}{(k-1)!} \quad (7)$$

$$\hat{q}^{(j,M)} = y_j(t, f) - \sum_{k=j+1}^N x_{k,j}(t, f) \hat{q}^{(k,M)}(t, f) \quad (8)$$

$$k = 2, 3, \dots, M \quad j = 2, 3, \dots, M-1$$

式中: $\varphi^{(k)}(t)$ 为瞬时相位关于时间 t 的第 k 阶导数; $\hat{q}^{(k,M)}$ 为第 k 阶瞬时频率调制系数的估计值。

则 M 阶瞬时频率为

$$\hat{\omega}_{j,x}^{(M)}(t, f) = \tilde{\omega}_x(t, f) + \sum_{k=2}^M \hat{q}^{(k,M)} \left(-\frac{STFT_x^{t^{k-1}}(t, f)}{STFT_x(t, f)} \right) \quad (9)$$

式中: $\hat{\omega}_{j,x}^{(M)}(t, f)$ 为基于 M 阶相位模型的高阶瞬时角频率估计值; $\tilde{\omega}_x(t, f)$ 为 SST 的瞬时角频率估计值。

所以信号的 M 阶同步压缩变换如下:

$$SSTM(t, f) = \frac{1}{g(0)} \int_{\mathbb{R}} STFT_x(t, f) \delta(\omega - \hat{\omega}_{j,x}^{(M)}(t, f)) df \quad (10)$$

区别于 SSTM,针对快速时变信号,NSST 采用迭代方式逐步校正瞬时频率^[19]。在同步压缩过程中,频率初始值由 STFT 在频率轴上的峰值确定,记为

$$\hat{\omega}_1(t, f) = \text{Re} \left(\frac{\partial_t STFT(t, f)}{2\pi STFT(t, f)} \right) \quad (11)$$

该估值表示在时刻 t 、频率 f 附近,信号主要频

率的局部变化趋势。之后以 $\hat{\omega}_1(t, f)$ 为初始值迭代计算,可得第 N 次瞬时频率估计值:

$$\hat{\omega}_N(t, f) = f_0 + \frac{f_1^2}{1+f_1} (\hat{\omega}_{N-1}(t, f) - f_0) \quad (12)$$

式中: f_0 为初始频率估计值; f_1 为频率修正系数。

该递推结构可逐步增强频率轨迹聚焦性,提高频率分辨率与估计精度;尽管 $\hat{\omega}_1(t, f)$ 初始值可能影响收敛速度,但迭代过程能够有效修正误差,保证最终频率估计的准确性。

由此可以得到 N 重同步压缩的数学公式:

$$NSST(t, f) = \int_{\mathbb{R}} STFT_x(t, f) \delta(\omega - \hat{\omega}_N(t, f)) df \quad (13)$$

基于 SSTM 时频分析存在噪声鲁棒性较差、低信噪比(SNR)下时频图发散严重的问题,且基于 NSST 时频分析频率估计误差较大,本文将两种算法融合得到 NSSTM。

N 重一阶压缩变换表达式:

$$NSST_1(t, f) = \int_{\mathbb{R}} STFT_x(t, f) \delta(\omega - \hat{\omega}_N(t, f)) df \quad (14)$$

N 重 M 阶压缩变换表达式为

$$NSSTM(t, f) = \int_{\mathbb{R}} STFT_x(t, \varepsilon) \delta(f - NSST(t, NSST_2(t, \dots, NSSTM(t, \varepsilon)))) d\varepsilon \quad (15)$$

参考文献[20],在传感器采集信号过程中,实际获得的数据是离散时间序列。现假设离散时间序列 $x(iT)$, $X(n/MT)$ ($n=0, 1, \dots, N-1$) 是 $x(iT)$ 的离散傅里叶变换, T 是采样时间间隔,结合式(15),离散 NSSTM 的变换如下:

$$\left. \begin{aligned} NSSTM(iT, \frac{n}{MT}) &= \sum_{m=1}^{N-1} X(\frac{m+n}{nT}) g(r, k) \exp(\frac{-j2\pi mi}{n}) \\ NSSTM(iT, 0) &= \frac{1}{N} \sum_{m=1}^{N-1} X(\frac{m}{nT}) \end{aligned} \right\} \quad (16)$$

式中: $g(r, k)$ 为窗函数; $X(m/nT)$ 为 $x(n)$ 的离散时间序列。

原始信号经 NSSTM 时频域变换后得到的时频矩阵为二维复数矩阵,其每行数值代表频率值,而每列代表的是时间点,时频矩阵用复数形式可以表示为

$$NSSTM_{m \times n} = A_{m \times n} \exp(j\theta_{m \times n}) \quad (17)$$

式中: $A_{m \times n}$ 为 NSSTM _{$m \times n$} 的幅值矩阵; $\theta_{m \times n}$ 为 NSSTM _{$m \times n$} 的相位矩阵。

由文献[20]知,矩阵 $A_{m \times n}$ 包含大量故障信息,作为特征矩阵。借鉴文献[21],本文使用 NSST4 对声信号进行时频分析,即 $N=2, M=4$ 。

1.2 时频矩阵降维

由上文可知,采用 NSST4 处理信号获得的时频矩阵存在维数过高、冗余信息过多等问题,若直

将其输入故障诊断算法,会由于特征过于复杂而出现识别误差,因此本文采用SVD对时频矩阵进行分解,其具体过程和表达式如下:

$$\left. \begin{aligned} & \text{对于矩阵 } H \in \mathbb{R}^{m \times n}, \text{ 其SVD定义为} \\ & H = USV^T \\ & S = [\text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k) \quad 0] \\ & \sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_k > 0 \end{aligned} \right\} \quad (18)$$

式中: U 为 $m \times m$ 矩阵; V^T 为 $n \times n$ 矩阵; $\sigma_1, \sigma_2, \dots, \sigma_k$ 为 $H_{m \times n}$ 的奇异值。

基于式(18)可知,矩阵 H 可表示为若干个由奇异向量构成的秩为1的分量矩阵的线性叠加形式,各分量对原矩阵的重要程度由对应奇异值的大小决定。因此,可通过舍弃较小奇异值对应分量,实现矩阵的低秩近似表示。奇异值由快速衰减到平缓的位置点可作为矩阵有用成分与无用成分的分界点。定义分界点的序号为 l , 则托辊故障信号时频矩阵经SVD降维后的特征矩阵为

$$A = \sum_{i=1}^l \sigma_i H_i \quad (c \leq l) \quad (19)$$

1.3 托辊轴承故障识别

本文采用DBN对托辊轴承故障进行识别。其基本原理和参数优化如下。

1.3.1 DBN 基本原理

DBN由输入层、隐藏层和可见层组成,分别对应数据输入和若干个RBM层。在进行分类任务时,神经元的输出值位于0到1之间,通常采用Sigmoid函数作为激活函数。DBN的训练过程可分为无监督预训练和有监督微调两个阶段:前期采用逐层训练的方式进行无监督学习,具体的参数更新公式如下:

$$\left. \begin{aligned} W(t) &= m_r W(t-1) + l_r \frac{1}{N} \sum_{k=1}^N (P(h_{kj}^{(0)}) - \\ & \quad 1|v_k^{(0)}v_{ki}^{(0)} - P(h_{kj}^{(1)} = 1|v_k^{(1)}v_{ki}^{(1)}) \\ a(t) &= m_r a(t-1) + l_r \frac{1}{N} \sum_{k=1}^N (v_{ki}^{(0)} - v_{ki}^{(1)}) \\ b(t) &= m_r b(t-1) + l_r \frac{1}{N} \sum_{k=1}^N (v_{kj}^{(0)} - v_{kj}^{(1)}) \end{aligned} \right\} \quad (20)$$

式中: $h^{(1)}, v^{(1)}$ 为经过一次迭代得到的对应位置的神经元; m_r 为动量, $m_r = 1$ 。

为加快学习速度并提高对样本数据的拟合能力,引入K-L算法进行优化。

1.3.2 ISSA 优化 DBN 参数

DBN的初始参数通常需人为设定,不合理的参数设置易导致识别精度下降或过拟合。麻雀搜索算法(sparrow search algorithm, SSA)具有结构简单、参数少、局部收敛速度快等优点,适用于DBN关键参数优化,但它在后期搜索阶段易陷入

局部最优,影响全局寻优性能。为此,本文提出ISSA,其主要改进策略如下:

1) 采用Logistic混沌映射来初始化种群。

2) 针对SSA过度依赖上一代位置、搜索范围受限的问题,本文引入鱼鹰算法(osprey algorithm, OAA)^[22] 第一阶段搜索策略替代发现者位置更新,以增强全局搜索能力。

3) 随着SSA迭代进行,种群多样性逐渐降低,易陷入局部最优。为此,本文引入透镜成像反向学习策略,对最优个体位置进行再更新,以提高算法的全局搜索能力^[23],如图1所示。




图1 透镜学习

Fig.1 Lens learning

将物体沿 X 方向投影,其物理高度为 h , X_{best} 为投影点,将其看作全局最优点。 X 轴上 a_j 和 b_j 为当前第 j 维解的最大值与最小值,将一块焦距为 f 的凸透镜放在 X 轴 O 点处,根据透镜成像原理,物体 P 经过透镜成像在 X 轴另一侧得到倒立的物体 P' , X'_{best} 即为方向最优点。

DBN的关键参数包括网络结构和学习率。本文将特征矩阵维数和故障类别数分别设为输入层和输出层节点数。综合模型性能与复杂度,DBN隐含层数设为3层,需优化的参数为隐含层节点数 m_1, m_2, m_3 和学习率 $\eta \in (0, 1)$ 。

建立ISSA-DBN模型的适应度函数:

$$F = \frac{N_r}{\sum_{i=1}^{N_r} (h_i - \hat{h}_i)^2} \quad (21)$$

式中: N_r 为实际故障类型; h_i 为实际故障类型; \hat{h}_i 为识别出的故障模型。

ISSA寻优DBN的过程如下:

1) 初始化ISSA种群个数、维度、最大值、最小值以及最大迭代次数。

2) 对麻雀种群进行划分并计算其位置。

3) 计算麻雀个体的适应度,得到最优麻雀个体。

4) 比较每个麻雀的适应度值,并更新麻雀种群。

5) 计算如果达到最大迭代次数,如果符合条件,则输出参数;否则返回步骤3)进行下一轮重新计算。

ISSA-DBN基本流程图见图2。

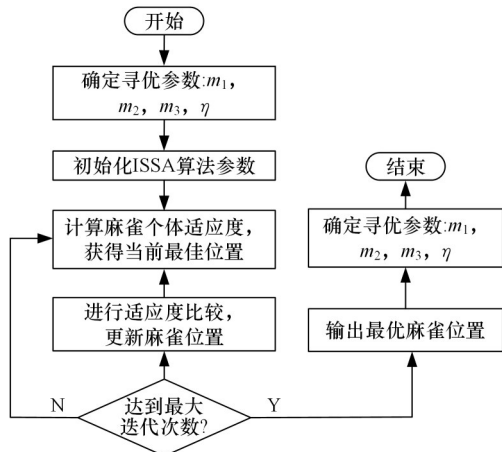


图2 ISSA-DBN流程图

Fig.2 ISSA-DBN flow chart

1.4 研究方法

鉴于原始声信号噪声成分较多,本文采用逐次变分模态分解(sequential variational mode decomposition, SVMD)对信号进行分解重构以增强故障特征的可辨识度。SVMD能有效处理时变频率分量的非平稳信号,并分离复杂频谱与瞬态特征。随后结合 NSST4、SVD 与 DBN 实现托辊故障诊断,基本流程如图3所示。

1)采集不同转速工况下托辊故障包括内圈故障、外圈故障、滚动体以及正常运行的声音信号,构建数据集。

2)使用SVD对训练集中的各个样本信号进行分解,选取相关系数和峭度两个判据筛选有效

分量进行重构。由文献[24]可知,相关系数低于0.2分量通常为背景噪声或无关模态,对目标特征贡献较小,因此本文选择相关系数大于0.2可有效识别出与原始信号变化趋势一致的主要模态,剔除相关性较低的冗余或噪声分量。由文献[25]可知,正常运转的轴承信号峭度值约等于3。峭度值越大表明信号中存在大量冲击成分,轴承的故障信息越明显。因此本文选择峭度大于3作为轴承故障的重要判据。随后采用NSST4将一维重构信号转换成二维复数矩阵。

3)使用SVD分解步骤2)中获得的时频特征矩阵,将有效奇异值构建成为特征向量集。

4)将特征集输入ISSA-DBN中进行训练;对测试集中的样本信号重复步骤2)和步骤3),将提取特征输入参数已调整的ISSA-DBN中实现托辊轴承不同状态下的故障识别。

2 模拟信号仿真

为验证本文所提方法的优越性,利用滚动轴承的信号故障模型来模拟托辊轴承的内圈故障,并添加白噪声来模拟实际工况所采集的声音信号:

$$\left. \begin{aligned} s_1(t) &= \sin(2\pi(50t + 10\sin(1.5t))) \\ s_2(t) &= \sin(2\pi(t^3 - 8t^2 + 20t)) \\ s &= s_1(t) + s_2(t) + r(t) \end{aligned} \right\} \quad (22)$$

式中: $s_1(t)$ 、 $s_2(t)$ 为调频分量; $r(t)$ 为均值为0,方差为1的高斯白噪声。

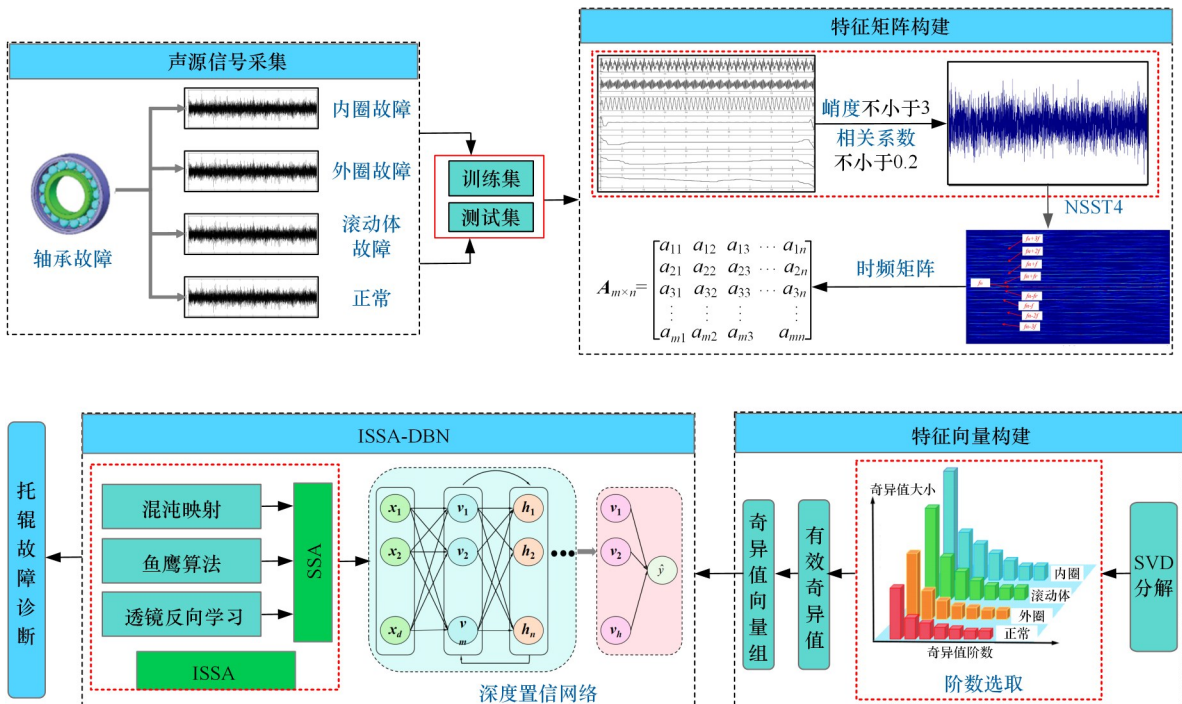


图3 算法流程图

Fig.3 Algorithm flow chart

采样频率选择 500 Hz, 采样时间 5 s, 其信号的时域图以及频域图见图 4、图 5。从图中观察到, 信号的瞬时频率随着时间快速变化, 各分量的瞬时频率淹没在噪声中, 信号的频率特征难以识别。




图 4 信号时域波形图

Fig.4 Time-domain waveform of the signal




图 5 信号频域图

Fig.5 Frequency spectrum of the signal

分别采用 STFT、SST、SST2、SST4 以及 NSST4 对信号进行时频分析, 结果如图 6 所示。由图 6a、图 6b 可见, STFT 时频图受噪声干扰明显, 能量发散严重, 无法看出分量信号瞬时频率的变化。图 6c~图 6h 表明, 随着压缩阶数提高, 噪声干扰逐渐减小, 时频能量发散减弱, 能量锐度增大。由图 6i、图 6j 可见, NSST4 相较于 SST2 和 SST4 在噪声抑制和时频能量锐度方面表现更优。

为了比较不同时频方法抗干扰的情况, 分别在公式中添加信噪比为 0~20 dB 的高斯白噪声, 并计算在不同信噪比条件下的 Rényi 熵。Rényi 熵用于评价时频分布能量锐度, Rényi 熵值越小, 代表该时频方法处理结果的时频能量更集中。

Rényi 熵数学计算公式为

$$H_{\alpha}(x) = \frac{1}{1-\alpha} \ln \left(\sum_{i=1}^n p(i)^{\alpha} \right) \quad (23)$$

式中: x 为随机变量; $H_{\alpha}(x)$ 为 Rényi 熵; α 为 Rényi 熵参数, $\alpha \in [(0, 1) \cup (1, +\infty)]$; $p(i)$ 为 $x=x_i$ 的概率值。

分别对信号进行 STFT、SST2、SST4、NSST4 的时频分析, 得到图 7。可以看出, 随着信噪比的不断增大, 信号的 Rényi 熵呈逐渐下降趋势。这一现象表明, 随着信噪比的增大, 信号的能量发散加剧。然而, 在所有的分析方法中。NSST4 的 Rényi 熵始终保持最低, 这表明 NSST4 在处理信号时具有更强的抗干扰能力。

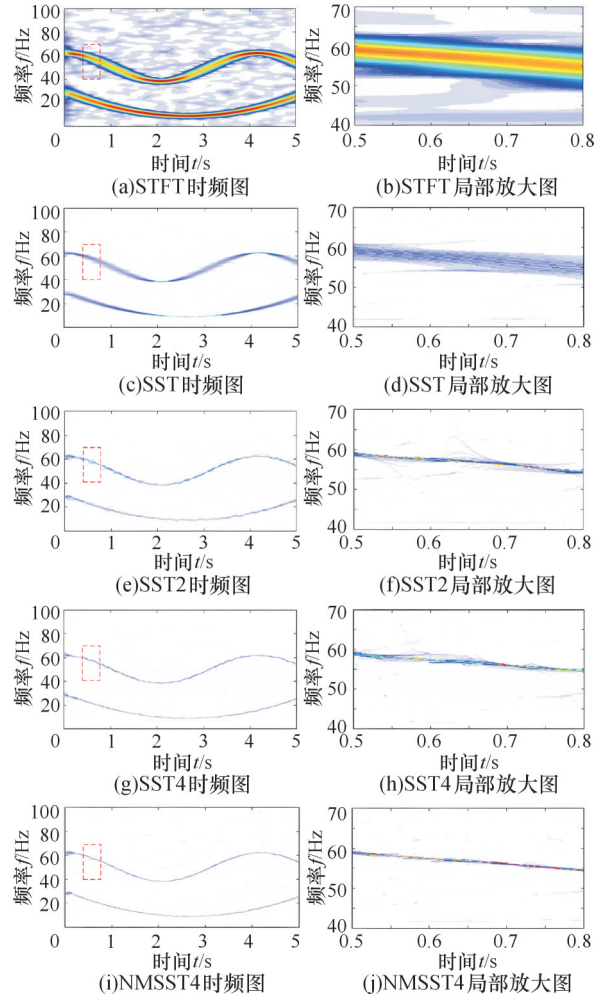


图 6 时频分析图及局部放大图

Fig.6 TFA diagram and local amplification diagram




图 7 时频分析在不同信噪比下的 Rényi 熵

Fig.7 Rényi entropy of TFA under different SNR

3 托辊模拟故障实验

3.1 数据集构建

为了验证所提方法用于诊断托辊故障的可行性, 本文搭建了托辊模拟实验台, 如图 8 所示。通过改变电机转速, 分别采集带速为 1, 1.5, 2 m/s 时托辊不同故障的声信号, 采集频率选择 8000 Hz, 采样点数为 4000。

表 1 所示为本文选取的实验数据集, A、B、C 工况各选取 200 个样本 (包括正常托辊和 3 种典型故障状态托辊各 50 个样本), 共 600 个样本, 其中训练集 360 个样本、测试集 240 个样本。




图8 托辊模拟实验台

Fig.8 Roller simulation test bench

表1 数据集构建

Tab.1 Dataset construction

工况	带速/ (m·s ⁻¹)	内圈故障		外圈故障		滚动体故障		正常	
		训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
A	1.0	30	20	30	20	30	20	30	20
B	1.5	30	20	30	20	30	20	30	20
C	2.0	30	20	30	20	30	20	30	20

3.2 托辊轴承典型状态时频特征分析

选取工况B的一组数据,包括托辊正常运行、托辊轴承内圈故障、外圈故障以及滚动体故障声信号,使用SVMD算法对信号重构,结果如图9所示。分别使用STFT、SST4以及NSST4对重构信号进行时频分析,结果如图10所示。

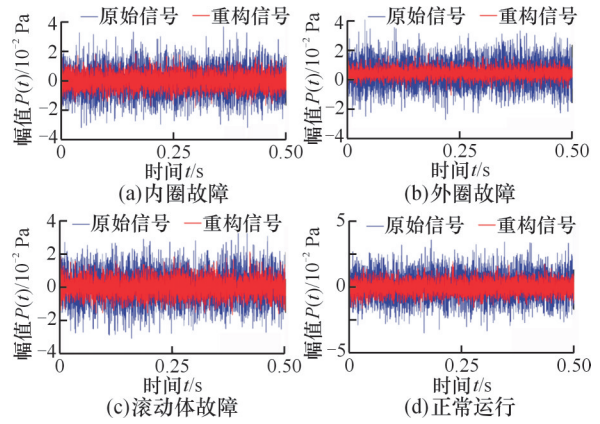


图9 信号重构前后对比图

Fig.9 Comparison diagram before and after signal reconstruction

计算得到托辊转速频率为19 Hz,内圈故障频率为90.44 Hz,外圈故障频率为61.56 Hz,滚动体故障频率为73.25 Hz。如图10a所示,使用ST-FT处理得到的时频图像分辨率差,能量泄漏严重;而当使用SST4处理时,如图10b所示,分别在3500 Hz(轴承共振频率)两侧找到内圈故障频率、滚动体频率,以及在2000 Hz(轴承外圈固有频率)两侧发现外圈故障频率,但受噪声影响,冲击

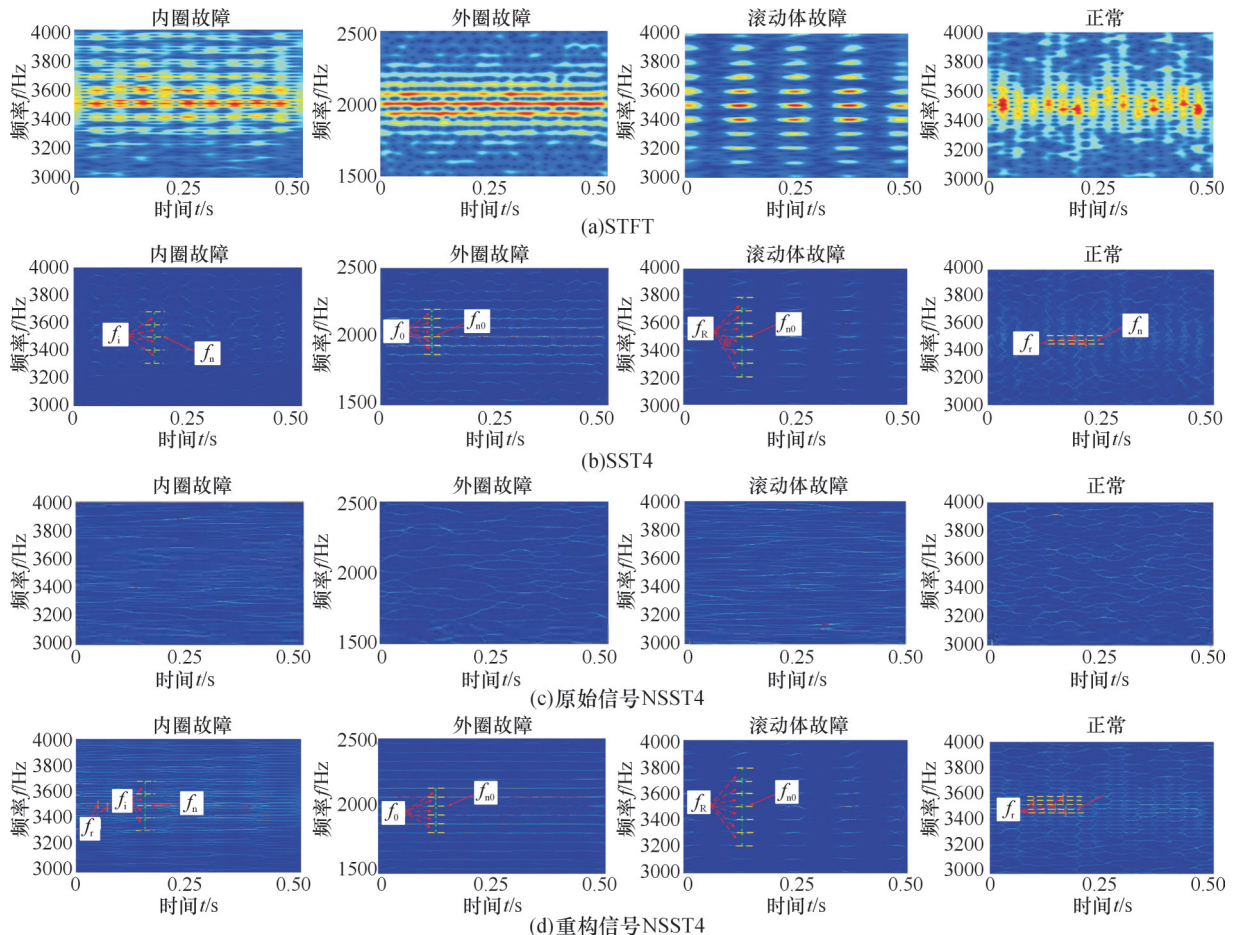


图10 时频分析对比图(模拟实验)

Fig.10 TFA comparison diagram (simulation test)

信号的成分分辨率较低;对原始信号使用NSST4处理,如图10c所示,可以观察到故障谱线淹没在噪声谱线中。如图10d所示,使用NSST4进行时频分析时,在内圈故障时频图3500 Hz两侧清晰找到内圈故障频率及倍频,包括分布在内圈频率两侧的转频;外圈时频图中,可以在2000 Hz两侧清晰找到外圈频率及倍频;在滚动体时频图中,可以在3500 Hz处发现滚动体的故障频率及倍频,在正常信号时频中,发现3500 Hz找到转频及倍频,无故障冲击成分。

为了更好地量化各种时频方法的性能,分别计算其Rényi熵,结果如图11所示。可以看到,NSST4处理托辊轴承的各种典型信号得到Rényi熵最小,说明处理后的时频能量发散最小,NSST4处理信号的抗干扰性更为优越。




图11 典型信号时频分析 Rényi熵
Fig.11 Rényi entropy of typical signal TFA

基于以上分析,NSST4相较于传统时频分析方法处理托辊故障声音信号,在时频分辨率以及抗噪性方面具有显著的优越性,且NSST4时频矩阵中包含冲击信号特征信息。

3.3 基于NSST4-SVD的特征提取

采用NSST4对实验数据集进行时频分析,使用SVD分解得到时频矩阵,图12为实验集SVD分解后奇异值曲线图。




图12 典型信号SVD分解结果(模拟实验)
Fig.12 Typical signal SVD decomposition results (simulation test)

由图12可知,托辊轴承声音信号经NSST4-SVD特征提取后,其奇异值向量一致性及稳定性较好,内圈故障、外圈故障、滚动体故障及正常信号的特征都可以使用21个奇异值组成的向量表示。另外,每个状态的奇异值差异明显,故障状态下的奇异值远大于正常运行的奇异值,说明奇异

值向量组可以区分托辊轴承不同状态,便于后续DBN的准确识别。

3.4 参数敏感性分析

为合理设定所提方法中的关键参数,本文分别对SSA和DBN进行了参数敏感性分析。在SSA参数敏感性分析中,分别选取种群规模为10,20,30,40,50,其余参数保持不变。

由图13可知,种群数量为10时,收敛过程波动较大,易陷入局部最优,优化效果较差;种群数量为30,40,50时收敛速度变慢,计算效率较低;相比之下,种群数量为20时收敛又快又稳,在较少的迭代次数内就能得到较好的结果,整体效果最好。




图13 不同种群数量下的寻优曲线
Fig.13 Optimisation curves for different population sizes

为分析DBN参数敏感性,本文对不同隐含层节点数组合进行了对比,结果如表2所示。可知,随着隐含层规模增大,DBN识别性能先升后降,表明适当增加网络规模有助于提高识别精度,而过大的结构规模会削弱模型的泛化能力,从而降低识别效果。综合分析并参考文献[26],本文将每层隐含节点数的取值范围设定为(10,500)。

表2 不同隐含层节点数下DBN识别性能变化

Tab.2 Variation of DBN recognition performance with different number of hidden layer nodes

隐含层数节点数	准确率/%	MAE
30-16-8	94.85	0.073
64-32-16	96.10	0.060
128-64-32	97.25	0.046
256-128-64	97.20	0.050
400-200-100	96.05	0.058

3.5 基于ISSA-DBN的托辊故障识别

ISSA训练DBN结构时,初始化ISSA算法参数并设置DBN结构,其中输入层节点数为21,输出层节点数为4,学习率区间为(0.001,1),隐含层节点范围为(10,500),麻雀种群数量设为20,最大迭代次数为50。在上述参数条件下对DBN模型进行优化,其适应度变化如图14所示。由图14

可观察到,ISSA算法在第7次迭代时收敛,而SSA算法在第17次迭代时收敛,表明ISSA算法收敛速度更快且不易陷入局部最优。




图14 DBN参数寻优曲线(模拟实验)

Fig.14 DBN parameter optimization curve (simulation test)

ISSA算法寻优得到的DBN最优网络参数如表3所示,测试集样本的识别结果如图15所示,其中标签1、2、3、4分别表示正常信号、内圈故障、外圈故障和滚动体故障。由图15可知,测试样本中出现5个误识别,识别准确率为97.91%。产生误识别的原因主要是托辊内外圈故障耦合性增强,使内圈与外圈信号特征相似,进而导致识别错误。

为了验证本文所提方法的有效性和优越性,分别采用以下方法进行对比:

表3 DBN参数寻优结果(模拟实验)

Tab.3 DBN parameter optimization results (simulation test)

参数	数值
输入层神经元数目	21
输出层神经元数目	4
RBM层数	3
每层RBM迭代次数	30
第一层隐藏神经元数目	185
第二层隐藏神经元数目	75
第三层隐藏神经元数目	144
DBN学习率	0.0023

表4 不同方法对比

Tab.4 Comparison of different methods

诊断模型	错误数	正常	内圈	外圈	滚动体	测试精度/%	MAE
NSST4+SVD+SSA+DBN	8	2	3	3	2	96.67	0.061
SST4+SVD+ISSA+DBN	13	0	4	3	3	94.58	0.124
MFCC+DBN	15	3	5	6	4	93.75	0.162
NSST4+SVD+SVM	10	2	3	3	2	95.83	0.157
NSST4+SVD+BP	12	2	4	4	2	95	0.176
本文方法	5	0	2	3	0	97.91	0.042

4 实验分析

4.1 实验验证

为了验证本方法的有效性,本课题组搭建了




图15 DBN诊断结果(模拟实验)

Fig.15 DBN diagnosis result (simulation test)

(1)NSST4+SVD+SSA+DBN。该方法在特征构建阶段与本文方法一致,均采用NSST4提取时频特征并通过SVD降维,不同之处在于使用SSA对DBN结构参数进行优化。

(2)SST4+SVD+ISSA+DBN。将NSST4替换为SST4,其余流程保持一致。

(3)变分模态分解(variational mode decomposition, VMD)+梅尔倒频谱系数(Mel frequency cepstrum coefficient, MFCC)+DBN。首先采用VMD对信号进行分解,对得到的变分模态分量采用与本文方法一致的相关系数与峭度进行筛选,选取有效分量进行特征提取。随后对筛选后的信号提取梅尔频率倒谱系数特征,并对特征向量进行归一化处理输入DBN进行识别。

(4)NSST4+SVD+SVM。该方法的特征提取流程与本文方法保持一致,区别在于将特征向量输入SVM模型中识别。

(5)NSST4+SVD+BP。该方法的特征提取流程与本文方法保持一致,区别在于将特征向量输入BP模型中进行识别。

采用上述方法对多转速工况下的托辊故障进行识别,并以MAE评价模型稳定性。实验结果如表4所示,所提方法在识别率和MAE指标上均表现最优,表明其在多转速工况下具有较高的识别精度和良好的鲁棒性。

带式输送机综合实验平台进行现场实验,采用CRY2110工业级别噪声传感器对声音信号进行采集。实验平台及现场实验情况如图16所示。托辊轴承直径为43.55 mm、节径为11.5 mm、接




图16 现场实验
Fig.16 Field test

触角为 0° 、滚动体个数为8。

分别采集带速为1, 1.5, 2 m/s时托辊不同故障的声信号, 采集频率选择8000 Hz, 采样点数为4000, 数据集构建如表1所示。取其中1组数据, 包括托辊正常运行声音信号、轴承内圈故障、外圈故障以及滚动体故障声音信号, 使用SVMD算法重构信号, 使用NSST4对重构信号进行时频分析, 分析结果如图17所示。

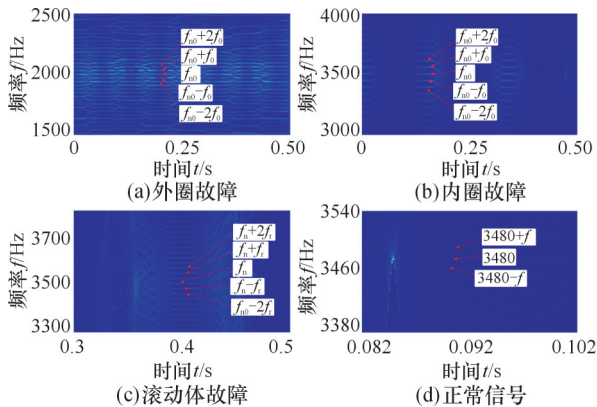


图17 时频分析对比图(现场实验)
Fig.17 Time-frequency analysis comparison diagram (field test)

图17a为轴承外圈故障的时频图。在轴承外圈固有频率两侧可以清晰看到外圈频率及倍频谱线; 图17b中可以看到在轴承共振频率两侧分布着轴承内圈频率及倍频谱线; 图17c中可以看到在轴承共振频率两侧分布轴承滚动体频率及倍频谱线; 图17d为轴承正常信号时频图, 在3480 Hz附近观察到转频及倍频谱线, 无故障频率谱线。

对实验样本进行时频分析, 将得到的时频矩阵进行SVD分解, 获得特征矩阵的奇异值向量, 结果如图18所示, 可以看到当阶数达到28时, 4种状态的奇异值大小便趋于稳定, 由此选择前28个奇异值作为特征向量。

使用ISSA寻优DBN参数, 初始参数同上文。ISSA-DBN的适应度变化如图19所示。ISSA算法在迭代到第13次达到收敛, 而SSA算法




图18 典型信号SVD分解结果图(现场实验)

在第18次收敛, 说明ISSA算法依然具有优越的收敛速度。DBN参数如表5所示。




图19 DBN参数寻优曲线(现场实验)

Fig.19 DBN parameter optimization (field test)

表5 DBN参数寻优结果(现场实验)

Tab.5 DBN parameter optimization results (field test)

参数	数值
输入层神经元数目	28
输出层神经元数目	4
RBM层数	3
每层RBM迭代次数	30
第一层隐藏神经元数目	220
第二层隐藏神经元数目	110
第三层隐藏神经元数目	155
DBN学习率	0.0015

将测试集样本输入DBN模型中, 识别结果如图20所示。可以观察到, 采用本文所提方法对托辊故障进行诊断时, 测试样本中出现8个错误识别, 识别准确率为96.57%。




图20 DBN诊断结果(现场实验)

Fig.20 DBN diagnosis result (field test)

4.2 噪声工况下实验研究

由于带式输送机工作环境较为复杂, 实际采集托辊轴承的声信号容易受到噪声干扰。为验证所提方法的抗噪性能, 参考文献[27], 本文在原始信号中加入不同信噪比的高斯白噪声, 构建多信噪比测试环境, 以检验本文方法在噪声干扰下的故障诊断能力。实验结果如图21所示。




图21 不同噪声环境下的模型诊断结果

Fig.21 Model diagnosis results under different noise environments

由图21可知,在-6 dB至0 dB的噪声环境下,本文方法的识别准确率整体保持在95%以上,且随信噪比变化表现平稳;即便在-6 dB的极端噪声条件下,识别准确率仍达到95.87%,表明该方法具有良好的抗噪能力。

5 结论

本文针对带式输送机托辊轴承特征信息难以提取,以及识别准确率低、鲁棒性差的问题,提出了一种结合NSST4、SVD以及DBN的方法来识别托辊轴承的状态模式。主要结论如下:

1)构造了快速时变信号,分别采用STFT、SST、SST2、SST4以及NSST4对重构信号时频分析,同时开展了抗噪性仿真,结果表明NSST4相较于其他时频分析方法具有更高的时频分辨率以及抗干扰性。

2)使用NSST4和SVD对托辊轴承的3种典型状态进行特征提取。分别使用托辊模拟实验以及现场实验获得的声信号进行分析,结果表明该方法获得的奇异值向量一致性及稳定性较好,各状态的奇异值差异明显,故障状态下的奇异值要高于正常运行的奇异值,因此该奇异值向量能够作为托辊轴承不同状态下的特征参数。

3)采用ISSA算法寻优DBN参数,将模拟托辊故障中的实验样本放入训练,将其与其他故障诊断方法进行比较,所提方法识别率达到97.91%,并与模型NSST4+SVD+SSA+DBN、SST4+SVD+ISSA+DBN、MFCC+DBN、NSST4+SVD+SVM、NSST4+SVD+BP进行对比,准确率分别提高了1.24%、3.33%、4.16%、2.08%、2.91%,且MAE值最小。最后在模拟故障实验中,所提出的方法实现了97.91%的识别准确率。在带式输送机综合实验平台现场实验中,识别准确率可达到96.57%。综上可知,本文

所提的故障诊断方法可以有效提高托辊轴承故障诊断的识别精度且具有良好的鲁棒性。

参考文献:

- [1] 周坪,马国庆,周公博,等. 智能化带式输送机健康监测技术研究综述[J]. 仪器仪表学报, 2023, 44(12): 1-21. ZHOU Ping, MA Guoqing, ZHOU Gongbo, et al. Health Monitoring Technology for the Intelligent Belt Conveyor: a Review [J]. Chinese Journal of Scientific Instrument, 2023, 44(12): 1-21.
- [2] 王海军,王洪磊. 带式输送机智能化关键技术现状与展望[J]. 煤炭科学技术, 2022, 50(12): 225-239. WANG Haijun, WANG Honglei. Status and Prospect of Intelligent Key Technologies of Belt Conveyor [J]. Coal Science and Technology, 2022, 50(12): 225-239.
- [3] LIN Nanying, ZHANG Xiangzhen, YAN Shengming, et al. The Structure and Performance Analysis of Ejector Dust-removing Nozzle [J]. Fluid Machinery, 1998, 26(12): 28-30.
- [4] 冯思茜,王家序,张新,等. 基于共振解调新方法的滚动轴承故障诊断[J]. 中国机械工程, 2025, 36(9): 2022-2031. FENG Siqian, WANG Jiayu, ZHANG Xin, et al. Rolling Bearing Fault Diagnosis Using a New Resonance Demodulation Method [J]. China Mechanical Engineering, 2025, 36(9): 2022-2031.
- [5] 郭砚秋,苗长云,刘意. 基于热红外图像的带式输送机托辊故障检测研究[J]. 工矿自动化, 2023, 49(10): 52-60. GUO Yanqiu, MIAO Changyun, LIU Yi. Research on Fault Detection of Belt Conveyor Roller Based on Thermal Infrared Image [J]. Industry and Mine Automation, 2023, 49(10): 52-60.
- [6] PENG Chen, LI Zhipeng, YANG Minjing, et al. An Audio-based Intelligent Fault Diagnosis Method for Belt Conveyor Rollers in Sand Carrier [J]. Control Engineering Practice, 2020, 105: 104650.
- [7] 陈剑,严明辉,陈品. 基于贝叶斯优化多尺度DenseNet的离心泵声信号故障诊断方法[J]. 中国机械工程, 2025, 36(9): 2032-2038. CHEN Jian, YAN Minghui, CHEN Pin. Acoustic Signal Fault Diagnosis Method of Centrifugal Pumps Based on Bayesian Optimization Multiscale DenseNet [J]. China Mechanical Engineering, 2025, 36(9): 2032-2038.
- [8] 王金瑞,季珊珊,张宗振,等. 并行稀疏滤波在轴承声信号下的故障诊断[J]. 航空学报, 2023, 44(4): 288-298. WANG Jinrui, JI Shanshan, ZHANG Zongzhen, et al. Parallel Sparse Filtering for Fault Diagnosis under Bearing Acoustic Signal [J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(4): 288-298.
- [9] 郝旺身,李继康,董辛旻,等. 基于声信号递归Hilbert变换的轴承故障诊断研究[J]. 机床与液压, 2024, 52(4): 195-199. HAO Wangshen, LI Jikang, DONG Xinmin, et al. Research on Bearing Fault Diagnosis Based on Acoustic Signal Recursive Hilbert Transform [J]. Machine Tool & Hydraulics, 2024, 52(4): 195-199.
- [10] HEMMATI F, ORFALI W, GADALA M S. Roller Bearing Acoustic Signature Extraction by Wavelet Packet Transform, Applications in Fault Detection and Size Estimation [J]. Applied Acoustics, 2016, 104: 101-118.
- [11] 赵学智,叶邦彦. 多分辨SVD包理论及其在信号处理中的应用[J]. 电子学报, 2012, 40(10): 2039-2046. ZHAO Xuezhi, YE Bangyan. Multi-resolution SVD Pack-

- et Theory and Its Application to Signal Processing[J]. Acta Electronica Sinica, 2012, 40(10): 2039-2046.
- [12] 刘俊锋, 董宝营, 俞翔, 等. 基于 FSC-MPE 与 BP 神经网络的滚动轴承故障诊断方法[J]. 中国舰船研究, 2021, 16(6): 183-190.
LIU Junfeng, DONG Baoying, YU Xiang, et al. Rolling Bearing Fault Diagnosis Method Based on FSC-MPE and BP Neural Network[J]. Chinese Journal of Ship Research, 2021, 16(6): 183-190.
- [13] 刘运航, 宋宇博, 朱大鹏. 中心修正投影结合 IGWO-SVM 的滚动轴承故障分类方法[J]. 振动与冲击, 2023, 42(24): 267-275.
LIU Yunhang, SONG Yubo, ZHU Dapeng. A Rolling Bearing Fault Classification Method Based on IGWO-SVM Combined with Center Correction Projection[J]. Journal of Vibration and Shock, 2023, 42(24): 267-275.
- [14] JIAO Jian, ZHENG Xuejiao. Fault Diagnosis Method for Industrial Robots Based on DBN Joint Information Fusion Technology[J]. Computational Intelligence and Neuroscience, 2022, 2022(1): 4340817.
- [15] NASKATH J, SIVAKAMASUNDARI G, BEGUM A A S. A Study on Different Deep Learning Algorithms Used in Deep Neural Nets: MLP SOM and DBN[J]. Wireless Personal Communications, 2023, 128(4): 2913-2936.
- [16] XUE Jiankai, SHEN Bo. A Survey on Sparrow Search Algorithms and Their Applications[J]. International Journal of Systems Science, 2024, 55(4): 814-832.
- [17] 刘帼巾, 刘达明, 缪建华, 等. 基于变分模态分解和改进灰狼算法优化深度置信网络的自动转换开关故障识别[J]. 电工技术学报, 2024, 39(4): 1221-1233.
LIU Guojin, LIU Daming, MIAO Jianhua, et al. Fault Identification of Automatic Transfer Switching Equipment Based on VMD-WPE and IGWO Optimized DBN[J]. Transactions of China Electrotechnical Society, 2024, 39(4): 1221-1233.
- [18] 刘杰, 付雪娇, 孙兴伟. 基于 PSO-DBN 的风电机齿箱运行状态识别[J]. 传感技术学报, 2023, 36(3): 434-440.
LIU Jie, FU Xuejiao, SUN Xingwei. Operating State Identification of Wind Turbine Gearbox Based on PSO-DBN[J]. Chinese Journal of Sensors and Actuators, 2023, 36(3): 434-440.
- [19] 魏东, 刘侃, 丁荣军, 等. 基于多重同步压缩变换的永磁同步电机初期匝间短路故障检测[J]. 电工技术学报, 2022, 37(18): 4651-4663.
WEI Dong, LIU Kan, DING Rongjun, et al. A Multi-synchrosqueezing Transformation Based Early Stage Detection of Inter-turn Short Circuit Fault in Permanent Magnet Synchronous Machine[J]. Transactions of China Electrotechnical Society, 2022, 37(18): 4651-4663.
- [20] 郭凤仪, 高洪鑫, 王智勇, 等. 基于 ST-SVD-PCA 的串联故障电弧特征提取方法[J]. 煤炭学报, 2018, 43(3): 888-896.
GUO Fengyi, GAO Hongxin, WANG Zhiyong, et al. Feature Extraction Method of Series Fault Arc Based on ST-SVD-PCA[J]. Journal of China Coal Society, 2018, 43(3): 888-896.
- [21] 张郑武, 冯志鹏, 陈小旺. 基于高阶同步压缩变换的行星齿轮箱声音信号共振频带特征提取[J]. 工程科学学报, 2020, 42(8): 1048-1054.
ZHANG Zhengwu, FENG Zhipeng, CHEN Xiaowang. Acoustic Signal Analysis of the Resonance Frequency Region for Planetary Gearbox Fault Diagnosis Based on High-order Synchrosqueezing Transform[J]. Chinese Journal of Engineering, 2020, 42(8): 1048-1054.
- [22] DEHGHANI M, TROJOVSKÝ P. Osprey Optimization Algorithm: a New Bio-inspired Metaheuristic Algorithm for Solving Engineering Optimization Problems[J]. Frontiers in Mechanical Engineering, 2023, 8: 1126450.
- [23] 陈功, 曾国辉, 黄勃, 等. 融合互利共生和透镜成像学习的 HHO 算法[J]. 计算机工程与应用, 2022, 58(10): 76-86.
CHEN Gong, ZENG Guohui, HUANG Bo, et al. HHO Algorithm Combining Mutualism and Lens Imaging Learning[J]. Computer Engineering and Applications, 2022, 58(10): 76-86.
- [24] 许同乐. 旋转机械故障信号处理与诊断方法[M]. 北京: 高等教育出版社, 2020.
XU Tongle. Methods for Signal Processing and Fault Diagnosis of Rotating Machinery[M]. Beijing: Higher Education Press, 2020.
- [25] 任良, 甄龙信, 赵云, 等. 基于 SSA-VMD-MCKD 的强背景噪声环境下滚动轴承故障诊断[J]. 振动与冲击, 2023, 42(3): 217-226.
REN Liang, ZHEN Longxin, ZHAO Yun, et al. Fault Diagnosis of Rolling Bearing under Strong Background Noise Based on SSA-VMD-MCKD[J]. Journal of Vibration and Shock, 2023, 42(3): 217-226.
- [26] 邵思羽. 基于深度学习的旋转机械故障诊断方法研究[D]. 南京: 东南大学, 2019.
SHAO Siyu. Methodologies for Fault Diagnosis of Rotary Machine Based on Deep Learning[D]. Nanjing: Southeast University, 2019.
- [27] 陈闯, 李先锋, 史建涛, 等. 基于柔性残差神经网络的滚动轴承智能故障诊断方法[J]. 工程科学学报, 2025, 47(3): 480-488.
CHEN Chuang, LI Xianfeng, SHI Jiantao, et al. Intelligent Fault Diagnosis Method for Rolling Bearings Based on Flexible Residual Neural Network[J]. Chinese Journal of Engineering, 2025, 47(3): 480-488.

(编辑 王旻玥)

作者简介: 胡坤^{*}(通信作者), 男, 1981年生, 教授、博士研究生导师。研究方向为带式输送机故障诊断。E-mail: hk924@126.com。

本文引用格式:

胡坤, 陈卓, 韩信, 等. 基于 NSST4-SVD-DBN 的带式输送机托辊轴承故障诊断方法[J]. 中国机械工程, 2026, 37(3): 656-667.
HU Kun, CHEN Zhuo, HAN Xin, et al. Fault Diagnosis Method of Belt Conveyor Roller Bearings Based on NSST4-SVD-DBN[J]. China Mechanical Engineering, 2026, 37(3): 656-667.