



(12)发明专利申请

(10)申请公布号 CN 110647911 A

(43)申请公布日 2020.01.03

(21)申请号 201910744175.6

(22)申请日 2019.08.13

(71)申请人 南京航空航天大学

地址 210016 江苏省南京市秦淮区御道街
29号

(72)发明人 朱静 胡天真 侯益静 张鹏

(74)专利代理机构 南京瑞弘专利商标事务所
(普通合伙) 32249

代理人 石嘉蓉

(51) Int. Cl.

G06K 9/62(2006.01)

G01M 13/045(2019.01)

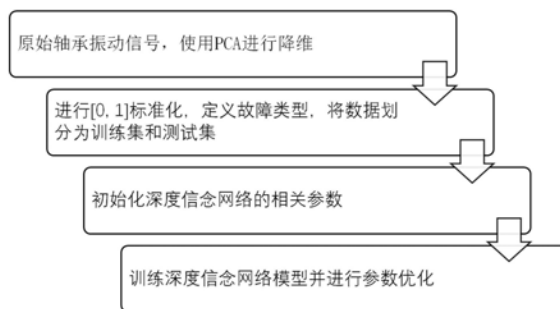
权利要求书2页 说明书6页 附图1页

(54)发明名称

一种基于主成分分析和深度信念网络的轴承故障诊断方法

(57)摘要

本发明公开了一种基于主成分分析和深度信念网络的轴承故障诊断方法,包括:1)在监测得到轴承振动信号后,使用主成分分析对原始振动信号数据进行降维处理;2)对降维后的轴承振动信号数据进行[0,1]标准化,定义故障类型,然后将数据按比例划分为训练集和测试集;3)初始化深度信念网络的相关参数;4)使用训练集训练深度信念网络模型,然后使用测试集对深度信念网络模型进行参数优化,最终建立轴承故障诊断的深度学习模型。本发明着眼于轴承故障诊断问题,基于主成分分析和深度信念网络展开研究,为解决大数据时代的轴承故障诊断问题提供行之有效的工具和方法。



1. 一种基于主成分分析和深度信念网络的轴承故障诊断方法,其特征在于,包括以下步骤:

- 1) 在监测得到轴承振动信号后,使用主成分分析对原始振动信号数据进行降维处理;
- 2) 对降维后的轴承振动信号数据进行 $[0,1]$ 标准化,定义故障类型,然后将数据按比例划分为训练集和测试集;
- 3) 初始化深度信念网络的相关参数;
- 4) 使用训练集训练深度信念网络模型,然后使用测试集对深度信念网络模型进行参数优化,训练及调优过程中使用dropout来减少过拟合,最终建立轴承故障诊断的深度学习模型。

2. 根据权利要求1所述的一种基于主成分分析和深度信念网络的轴承故障诊断方法,其特征在于,所述步骤1)具体包括:

1.1、给定轴承振动信号 $X \in \mathbb{R}^{N \times M}$,计算所有样本的平均向量值A:

$$A = \frac{1}{M} \sum_{i=1}^M x_i$$

式中, x_i 为矩阵X的第i列样本列向量;

1.2、计算协方差矩阵:

$$P = \frac{1}{M-1} \sum_{i=1}^M (x_i - A)(x_i - A)^T$$

并计算P的特征值 $\lambda_i, i=1, \dots, N$ 和特征向量 $v_i, i=1, \dots, N$;

1.3、将特征值从大到小排列,即 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N$,因此前r个主成分的累积贡献率 α 为:

$$\alpha = \sum_{i=1}^r \lambda_i / \sum_{i=1}^N \lambda_i$$

1.4、如果 $\alpha \geq 0.85$,构造由对应特征向量 $v_i, i=1, \dots, N$ 组成的矩阵 $E \in \mathbb{R}^{N \times r}$,即 $E = (v_1, v_2, \dots, v_r)$,进而通过矩阵E将原始数据映射为新的样本 X' :

$$X' = E^T X$$

3. 根据权利要求1所述的一种基于主成分分析和深度信念网络的轴承故障诊断方法,其特征在于,所述步骤2)中训练集和测试集的比例为3:1。

4. 根据权利要求1所述的一种基于主成分分析和深度信念网络的轴承故障诊断方法,其特征在于,所述步骤3)中DBM由多个RBM堆叠而成,其包含一个输入层、多个隐藏层和一个输出层,且参数初始化过程包括:

定义RBM的能量函数为:

$$E(v, h; \theta) = - \sum_{i=1}^{n_v} a_i v_i - \sum_{j=1}^{n_h} b_j h_j - \sum_{i=1}^{n_v} \sum_{j=1}^{n_h} h_j w_{ij} v_i$$

其中, v_i 和 h_j 分别是可见层和隐藏层的状态,对应偏置为 a_i, b_j ,对应节点数为 n_v 和 n_h , $\theta = \{w_{ij}, a_i, b_j\}$ 是RBM的参数;

隐藏层和可见层的联合概率为:

$$P(\mathbf{v}, \mathbf{h}; \theta) = \frac{e^{-E(\mathbf{v}, \mathbf{h}; \theta)}}{Z(\theta)}, Z(\theta) = \sum_{\mathbf{v}, \mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h}; \theta)}$$

其中 $Z(\theta)$ 是归一化因子,此外有

$$P(\mathbf{h}|\mathbf{v}) = \frac{e^{-E(\mathbf{v}, \mathbf{h})}}{\sum_{j=1}^{n_h} e^{-E(\mathbf{v}, \mathbf{h})}}$$

$$P(\mathbf{v}|\mathbf{h}) = \frac{e^{-E(\mathbf{v}, \mathbf{h})}}{\sum_{i=1}^{n_v} e^{-E(\mathbf{v}, \mathbf{h})}}$$

因为 $\mathbf{v}, \mathbf{h} \in \{0, 1\}$ 并且同层之间没有连接,所以神经元的激活函数为

$$P(h_j = 1|\mathbf{v}) = \frac{P(h_j = 1|\mathbf{v})}{P(h_j = 1|\mathbf{v}) + P(h_j = 0|\mathbf{v})} = \text{sigmoid}(b_j + \sum_{i=1}^{n_v} w_{ij}v_i)$$

$$P(v_i = 1|\mathbf{h}) = \frac{P(v_i = 1|\mathbf{h})}{P(v_i = 1|\mathbf{h}) + P(v_i = 0|\mathbf{h})} = \text{sigmoid}(a_i + \sum_{j=1}^{n_h} w_{ij}h_j)$$

RBM的训练目标是增加输入数据的概率分布 $P(\mathbf{v})$,参数更新规律为

$$\Delta W_{ij} = \eta (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}})$$

$$\Delta a_i = \eta (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}})$$

$$\Delta b_j = \eta (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}})$$

其中 η 是学习率, $\langle \cdot \rangle_{\text{data}}$ 指的是数据的期望, $\langle \cdot \rangle_{\text{recon}}$ 是重构数据的期望,使用对比散度算法来计算联合概率分布 $P(\mathbf{v}, \mathbf{h}; \theta)$,取采样次数 $k=1$ 。

一种基于主成分分析和深度信念网络的轴承故障诊断方法

技术领域

[0001] 本发明涉及一种基于主成分分析(Principal Component Analysis, PCA)和深度信念网络(Deep Belief Network, DBN)的轴承故障诊断方法,属于轴承故障诊断技术领域。

背景技术

[0002] 轴承是广泛使用于工业机器中的机械部件,它的工作状态很大程度上影响着机器的性能和使用寿命。据统计,我国每年的机械故障中,轴承故障占很大比例。如果未能及时监测轴承的故障,可能会导致机器的损伤甚至是人员伤亡。在提高生产力的前提下,机器的故障会影响到整条生产线,给工厂带来巨大的经济损失。因此在实际生产应用中,监测轴承的工作状态并对其进行故障诊断具有十分重要的意义。

[0003] 轴承运行过程中会产生相应的振动信号,通过监测振动信号可以判断轴承运行是否正常。充分运用监测数据,从振动信号中提取所需要的特征,特征提取的结果决定了对振动信号处理的结果,即决定了轴承故障诊断的正确率。及时并尽早地对轴承进行故障诊断,提前采取措施,可以有效地降低故障所带来的损失。监测、记录轴承故障过程中的数据,可以为事后分析故障原因提供有效数据,从而避免类似故障的发生。

[0004] 随着工业智能化的不断加强,各个领域的设备运行变得越来越复杂,监测所得到的数据越来越大,维度也越来越高,给轴承运行状态的监测和故障诊断带来了巨大挑战。监测得到的轴承振动信号,具有复杂、非线性和非平稳性等特点。传统的轴承故障诊断技术需要工作人员拥有大量的信号处理知识和经验,对振动信号进行分析处理后再进行故障诊断。传统的故障诊断技术通常是浅层网络模型,当面对大量高维的轴承振动信号数据时,无法得出数据的深层特征,难以及时有效地进行轴承故障诊断,也给轴承故障诊断的识别正确率带来了极大的影响。

[0005] 深度学习是一种根据数据学习特征的方法。深度学习方法可分为无监督学习和有监督学习。深度学习的强大非线性处理能力使得它在计算机视觉、语音识别、手写识别等领域内大放异彩。和浅层网络模型相比,深度学习可以根据轴承振动信号的内在特征,更容易地自动学习和识别出故障类型。然而国内深度学习理论在故障诊断领域的研究和应用还处于起步阶段,在处理大量高维的样本时,还需要大量的人工工作去处理振动信号,进行手动提取特征,增加了工作量和故障诊断复杂度。此外,神经元数量的增加也给深度学习模型的训练带来了一定的难度。

发明内容

[0006] 发明目的:本发明着眼于轴承故障诊断问题,基于主成分分析和深度信念网络展开研究,为解决大数据时代的轴承故障诊断问题提供行之有效的工具和方法。

[0007] 技术方案:为实现上述目的,本发明采用的技术方案为:

[0008] 一种基于主成分分析和深度信念网络的轴承故障诊断方法,包括以下步骤:

[0009] 1) 在监测得到轴承振动信号后,使用主成分分析对原始振动信号数据进行降维处

理；

[0010] 2) 对降维后的轴承振动信号数据进行 $[0, 1]$ 标准化, 定义故障类型, 然后将数据按比例划分为训练集和测试集;

[0011] 3) 初始化深度信念网络的相关参数;

[0012] 4) 使用训练集训练深度信念网络模型, 然后使用测试集对深度信念网络模型进行参数优化(训练及调优过程中使用dropout来减少过拟合), 最终建立轴承故障诊断的深度学习模型。

[0013] 进一步的, 所述步骤1) 具体包括:

[0014] 1.1、给定轴承振动信号 $X \in \mathbb{R}^{N \times M}$ (即 X 为 N 行 M 列的样本矩阵, 矩阵每一列为一个样本, 每一行为一个测量), 计算所有样本的平均向量值 A :

$$[0015] \quad A = \frac{1}{M} \sum_{i=1}^M x_i$$

[0016] 式中, x_i 为矩阵 X 的第 i 列样本列向量;

[0017] 1.2、计算协方差矩阵:

$$[0018] \quad P = \frac{1}{M-1} \sum_{i=1}^M (x_i - A)(x_i - A)^T$$

[0019] 值得指出的是因为 $P \in \mathbb{R}^{N \times N}$, P 中有 N 个特征向量, 因此计算 P 的特征值 $\lambda_i, i=1, \dots, N$ 和特征向量 $v_i, i=1, \dots, N$;

[0020] 1.3、将特征值从大到小排列, 即 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N$, 因此前 r 个主成分的累积贡献率为:

$$[0021] \quad \alpha = \sum_{i=1}^r \lambda_i / \sum_{i=1}^N \lambda_i$$

[0022] 1.4、如果 $\alpha \geq 0.85$, 构造由对应特征向量 $v_i, i=1, \dots, N$ 组成的矩阵 $E \in \mathbb{R}^{N \times r}$, 即 $E = (v_1, v_2, \dots, v_r)$, 进而通过矩阵 E 将原始数据映射为新的样本 X' :

$$[0023] \quad X' = E^T X$$

[0024] 其中 $X' \in \mathbb{R}^{r \times M}$ 。至此, 和原始数据相比, 新的样本在保留了主要信息的同时又降低了数据的维度。

[0025] 进一步的, 所述步骤2) 中训练集和测试集的比例优选为3:1。

[0026] 进一步的, 所述步骤3) 中DBM由多个RBM堆叠而成, 其包含一个输入层、多个隐藏层和一个输出层, 且参数初始化过程包括:

[0027] 定义RBM的能量函数为:

$$[0028] \quad E(v, h; \theta) = - \sum_{i=1}^{n_v} a_i v_i - \sum_{j=1}^{n_h} b_j h_j - \sum_{i=1}^{n_v} \sum_{j=1}^{n_h} h_j w_{ij} v_i$$

[0029] 其中, v_i 和 h_j 分别是可见层和隐藏层的状态, 对应偏置为 a_i, b_j , 对应节点数为 n_v 和 n_h , $\theta = \{w_{ij}, a_i, b_j\}$ 是RBM的参数;

[0030] 隐藏层和可见层的联合概率为:

$$[0031] \quad P(v, h; \theta) = \frac{e^{-E(v, h; \theta)}}{Z(\theta)}, Z(\theta) = \sum_{v, h} e^{-E(v, h; \theta)}$$

[0032] 其中 $Z(\theta)$ 是归一化因子,此外有

$$[0033] \quad P(h|v) = \frac{e^{-E(v, h)}}{\sum_{j=1}^{n_h} e^{-E(v, h)}}$$

$$[0034] \quad P(v|h) = \frac{e^{-E(v, h)}}{\sum_{i=1}^{n_v} e^{-E(v, h)}}$$

[0035] 因为 $v, h \in \{0, 1\}$ 并且同层之间没有连接,所以神经元的激活函数为

$$[0036] \quad P(h_j = 1|v) = \frac{P(h_j = 1|v)}{P(h_j = 1|v) + P(h_j = 0|v)} = \text{sigmoid}(b_j + \sum_{i=1}^{n_v} w_{ij}v_i)$$

$$[0037] \quad P(v_i = 1|h) = \frac{P(v_i = 1|h)}{P(v_i = 1|h) + P(v_i = 0|h)} = \text{sigmoid}(a_i + \sum_{j=1}^{n_h} w_{ij}h_j)$$

[0038] RBM的训练目标是增加输入数据的概率分布 $P(v)$,参数更新规律为

$$[0039] \quad \Delta W_{ij} = \eta (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}})$$

$$[0040] \quad \Delta a_i = \eta (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}})$$

$$[0041] \quad \Delta b_j = \eta (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}})$$

[0042] 其中 η 是学习率, $\langle \cdot \rangle_{\text{data}}$ 指的是数据的期望, $\langle \cdot \rangle_{\text{recon}}$ 是重构数据的期望,因为 $Z(\theta)$ 的存在,使得计算联合概率分布 $P(v, h; \theta)$ 变得非常困难,因此可以使用对比散度算法来计算,在实际应用中,取 $k=1$ 就可以取得很好的效果。根据实际情况确定轴承故障种类数目,确定输入层和输出层节点数,输出层节点数由故障种类决定。

[0043] 有益效果:本发明提供了一种基于主成分分析和深度信念网络的轴承故障诊断方法,相对于现有技术,具有以下优点:一方面,本发明通过主成分分析对大量高维轴承振动信号数据进行处理,无需信号处理的经验和知识,大大降低了样本数据的维度,有效提高了后续深度学习模型的训练效率;另一方面,本发明使用的深度信念网络模型,针对处理大量的轴承振动信号样本数据十分有效,十分适用于对产生大量轴承振动信号的情况进行故障诊断。

附图说明

[0044] 图1为本发明的整体流程示意图;

[0045] 图2为本发明实施例中主成分分析(PCA)的流程示意图;

[0046] 图3为本发明实施例中采用的深度信念网络模型图。

具体实施方式

[0047] 下面结合附图及具体实施例对本发明作更进一步的说明。

[0048] 如图1所示为一种基于主成分分析和深度信念网络的轴承故障诊断方法,包括:

[0049] 1) 在监测得到轴承振动信号后,使用主成分分析对原始振动信号数据进行降维处

理；

[0050] 2) 对降维后的轴承振动信号数据进行 $[0, 1]$ 标准化, 定义故障类型, 然后将数据按比例划分为训练集和测试集;

[0051] 3) 初始化深度信念网络的相关参数;

[0052] 4) 使用训练集训练深度信念网络模型, 然后使用测试集对深度信念网络模型进行参数优化(训练及调优过程中使用dropout来减少过拟合), 最终建立轴承故障诊断的深度学习模型。

[0053] 步骤1) 使用主成分分析(PCA)进行降维

[0054] 如图2所示, 通过PCA将数据的 n 维特征映射到 k 维上, 即将原始数据映射到新的特征空间上, 具体包括:

[0055] 1.1、给定轴承振动信号 $X \in \mathbb{R}^{N \times M}$ (即 X 为 N 行 M 列的样本矩阵, 矩阵每一列为一个样本, 每一行为一个测量), 计算所有样本的平均向量值 A :

$$[0056] \quad A = \frac{1}{M} \sum_{i=1}^M x_i$$

[0057] 式中, x_i 为矩阵 X 的第 i 列样本列向量;

[0058] 1.2、计算协方差矩阵:

$$[0059] \quad P = \frac{1}{M-1} \sum_{i=1}^M (x_i - A)(x_i - A)^T$$

[0060] 值得指出的是因为 $P \in \mathbb{R}^{N \times N}$, P 中有 N 个特征向量, 因此计算 P 的特征值 $\lambda_i, i=1, \dots, N$ 和特征向量 $v_i, i=1, \dots, N$;

[0061] 1.3、将特征值从大到小排列, 即 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N$, 因此前 r 个主成分的累积贡献率 α 为:

$$[0062] \quad \alpha = \sum_{i=1}^r \lambda_i / \sum_{i=1}^N \lambda_i$$

[0063] 1.4、如果 $\alpha \geq 0.85$, 构造由对应特征向量 $v_i, i=1, \dots, N$ 组成的矩阵 $E \in \mathbb{R}^{N \times r}$, 即 $E = (v_1, v_2, \dots, v_r)$, 进而通过矩阵 E 将原始数据映射为新的样本 X' :

$$[0064] \quad X' = E^T X$$

[0065] 其中 $X' \in \mathbb{R}^{r \times M}$ 。至此, 和原始数据相比, 新的样本在保留了主要信息的同时又降低了数据的维度。

[0066] 步骤2) 数据归一化以及样本的划分

[0067] 将步骤1) 得到的样本 X' 进行 $[0, 1]$ 标准化处理, 然后根据具体情况按比例划分训练集和测试集, 训练集样本数目比测试集样本数目要多多一些, 以便后续的深度学习模型的训练。

[0068] 步骤3) 初始化DBN的相关参数

[0069] DBM由多个RBM堆叠而成, 通常包含一个输入层、多个隐藏层和一个输出层。

[0070] 定义RBM的能量函数为:

$$[0071] \quad E(v, h; \theta) = - \sum_{i=1}^{n_v} a_i v_i - \sum_{j=1}^{n_h} b_j h_j - \sum_{i=1}^{n_v} \sum_{j=1}^{n_h} h_j w_{ij} v_i$$

[0072] 其中, v_i 和 h_j 分别是可见层和隐藏层的状态, 对应偏置为 a_i 、 b_j , 对应节点数为 n_v 和 n_h , $\theta = \{w_{ij}, a_i, b_j\}$ 是RBM的参数;

[0073] 隐藏层和可见层的联合概率为:

$$[0074] \quad P(v, h; \theta) = \frac{e^{-E(v, h; \theta)}}{Z(\theta)}, Z(\theta) = \sum_{v, h} e^{-E(v, h; \theta)}$$

[0075] 其中 $Z(\theta)$ 是归一化因子, 此外有

$$[0076] \quad P(h|v) = \frac{e^{-E(v, h)}}{\sum_{j=1}^{n_h} e^{-E(v, h)}}$$

$$[0077] \quad P(v|h) = \frac{e^{-E(v, h)}}{\sum_{i=1}^{n_v} e^{-E(v, h)}}$$

[0078] 因为 $v, h \in \{0, 1\}$ 并且同层之间没有连接, 所以神经元的激活函数为

$$[0079] \quad P(h_j = 1|v) = \frac{P(h_j = 1|v)}{P(h_j = 1|v) + P(h_j = 0|v)} = \text{sigmoid}(b_j + \sum_{i=1}^{n_v} w_{ij} v_i)$$

$$[0080] \quad P(v_i = 1|h) = \frac{P(v_i = 1|h)}{P(v_i = 1|h) + P(v_i = 0|h)} = \text{sigmoid}(a_i + \sum_{j=1}^{n_h} w_{ij} h_j)$$

[0081] RBM的训练目标是增加输入数据的概率分布 $P(v)$, 参数更新规律为

$$[0082] \quad \Delta w_{ij} = \eta (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}})$$

$$[0083] \quad \Delta a_i = \eta (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}})$$

$$[0084] \quad \Delta b_j = \eta (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}})$$

[0085] 其中 η 是学习率, $\langle \cdot \rangle_{\text{data}}$ 指的是数据的期望, $\langle \cdot \rangle_{\text{recon}}$ 是重构数据的期望, 因为 $Z(\theta)$ 的存在, 使得计算联合概率分布 $P(v, h; \theta)$ 变得非常困难, 因此可以使用对比散度算法来计算, 在实际应用中, 取 $k=1$ 就可以取得很好的效果。

[0086] 根据实际情况确定轴承故障种类数目, 确定输入层和输出层节点数, 输出层节点数由故障种类决定, 合理选择隐藏层节点数和层数。本发明实施例使用含有两个RBM的DBM模型, 如图3所示。

[0087] 步骤4) MATLAB仿真训练

[0088] 取西储大学轴承中心网站中驱动端轴承故障数据, 分为正常、直径为0.1778mm、0.3556mm、0.5334mm的内圈故障、直径为0.1778mm、0.3556mm、0.5334mm的外圈故障、直径为0.1778mm、0.3556mm、0.5334mm的滚珠故障共十种情况。

[0089] 数据共包含12120个样本, 每个样本的维数是400维。使用主成分分析 (PCA) 对轴承振动信号数据进行降维处理, 取累计贡献率为95%, 得到降维后的数据维数为123维。

[0090] 将降维后的数据进行 $[0, 1]$ 标准化处理, 接着划分训练集和测试集, 训练集包含9090个样本, 测试集包含303个样本。

[0091] 初始化深度信念网络 (DBN) 的参数,输入层为123个节点,两个隐藏层的层数都为100层,输出层为10个节点,前向学习率设置为0.1,动量设置为0.9,dropout参数设置为0.1。

[0092] 将训练集的输入到DBN网络中训练深度学习模型,然后使用测试集对模型进行参数优化,即调参,训练及调优过程中使用dropout来减少过拟合。经MATLAB仿真后得到训练集轴承故障诊断正确率为99.6%,测试集的轴承故障诊断正确率为91.16%。

[0093] 以上所述仅是本发明的优选实施方式,应当指出:对于本技术领域的普通技术人员来说,在不脱离本发明原理的前提下,还可以做出若干改进和润饰,这些改进和润饰也应视为本发明的保护范围。

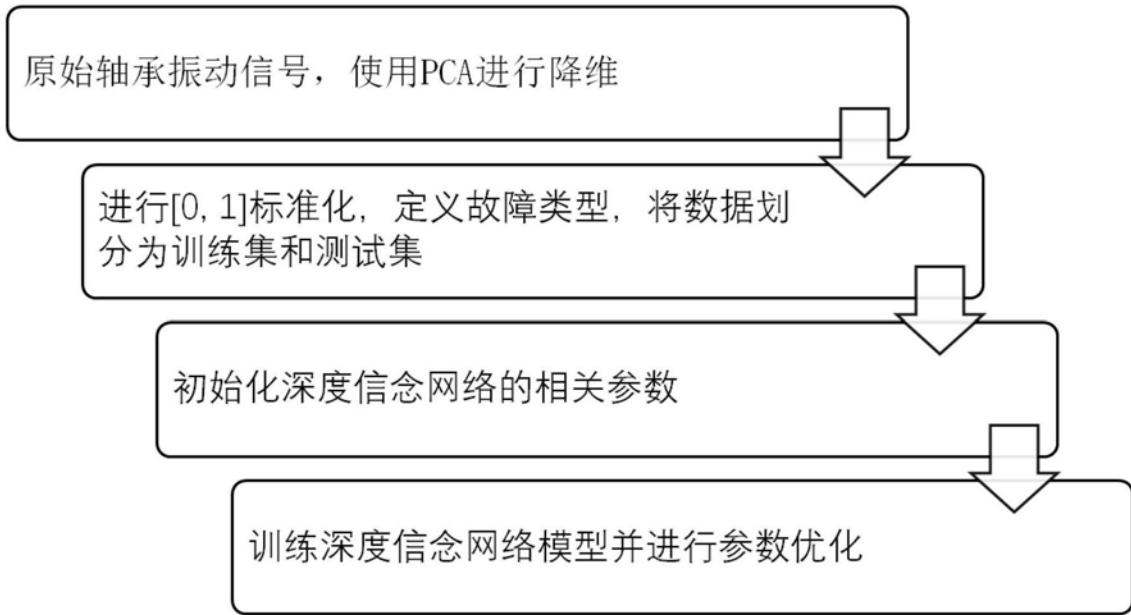


图1




图2




图3