



(12)发明专利申请

(10)申请公布号 CN 108932499 A

(43)申请公布日 2018.12.04

(21)申请号 201810742624.9

(22)申请日 2018.07.09

(71)申请人 武汉科技大学

地址 430081 湖北省武汉市青山区和平大道947号

(72)发明人 蒋黎明 徐春玲 李友荣 徐增丙 周明乐 聂婉琴

(74)专利代理机构 武汉科皓知识产权代理事务所(特殊普通合伙) 42222

代理人 王琪

(51)Int.Cl.

G06K 9/00(2006.01)

G06K 9/46(2006.01)

G06K 9/62(2006.01)

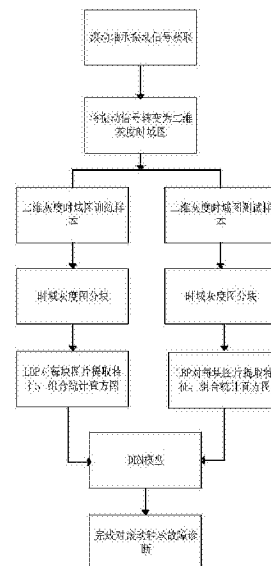
权利要求书5页 说明书13页 附图3页

(54)发明名称

一种基于局部二值模式和深度置信网络的滚动轴承预测方法和系统

(57)摘要

本发明提出一种基于局部二值模式和深度置信网络的滚动轴承预测方法和系统,首先提取一维滚动轴承振动信号,然后转换为二维时域灰度图片,并对二维时域灰度图片分块,将分块图分别利用LBP_{P,R}^{u,2}提取局部纹理特征,后将各分块图得到LBP_{P,R}^{u,2}的统计直方图进行组合并作为DBN的输入,DBN对统计直方图的深层特征进行自动提取,并通过DBN前向自学习和基于梯度下降的反向传播,调整整个DBN网络的模型参数,得到训练完成的DBN网络;最后,将未知状态的滚动轴承的振动信号二维灰度图经LBP_{P,R}^{u,2}的统计直方图特征作为输入,利用训练完成的DBN网络逐层提取能够反映本征信息的高层特征,再将逐层特征自提取的结果输入到顶层分类,实现滚动轴承在多负载和强噪声的情况下的故障识别。



1. 一种基于局部二值模式和深度置信网络的滚动轴承预测方法,其特征在于,包括如下步骤:

步骤一,对已知状态的一维滚动轴承的振动信号进行预处理,得到已知状态的滚动轴承的二维时域灰度图;

步骤二,将得到的已知状态的滚动轴承的二维时域灰度图像进行区域划分,划分原则为:分别取图像宽度和高度的公约数;

步骤三,将上述灰度图像划分区域使用基于统一局部二值模式LBP_{u,2,2}算子进行特征提取,得到各划分区域的统计直方图,再将各划分区域得到的统计直方图进行组合,得到整幅图的统计直方图,并对统计直方图进行归一化处理;

步骤四,将整幅图像的统计直方图输入到DBN网络(深度置信网络),并对DBN网络进行前向自学习处理和基于梯度下降的反向传播处理,调整DBN网络的模型参数,得到训练完成的DBN网络;

步骤五,在识别实际多负载滚动轴承故障模式时,首先对未知状态的滚动轴承的振动信号进行步骤一至三的处理,获得其对应的统计直方图,然后利用所得到的训练完成的DBN网络进行分类,从而确定实际滚动轴承的故障类型。

2. 根据权利要求1所述的一种基于局部二值模式和深度置信网络的滚动轴承预测方法,其特征在于:所述步骤一中,将对已知状态的一维滚动轴承的振动信号进行归一化处理,使其范围控制在[0,1]内,之后将归一化后的振动信号转换为二维灰度时域图,图片的幅值设置为[0-1];要求转化为二维灰度时域图的一维滚动轴承的振动信号长度应满足大于转轴转一圈传感器所采集数据点的个数;二维灰度图的分辨率具有相同的尺度。

3. 根据权利要求书1所述的一种基于局部二值模式和深度置信网络的滚动轴承预测方法,其特征在于:所述步骤二中,对已知状态的滚动轴承的二维时域灰度图像进行区域划分的具体原则为:根据二维灰度图的分辨率大小进行划分,若分辨率的宽度与高度均为n的倍数,则将二维灰度图分块成n×n;且分块越多会识别率越高,但运算时间将会增加。

4. 根据权利要求书1所述的一种基于局部二值模式和深度置信网络的滚动轴承预测方法,其特征在于:步骤四中所述DBN网络实质上是由多个受限玻尔兹曼机(RBM)和一层有监督的反向传播网络(BPNN)堆叠而成的多层感知神经网络,具体结构如下,

每个受限玻尔兹曼机均由可视层和隐藏层组成,层与层之间通过权值w连接,各层内部相互独立,当给定可见单元的状态时,各隐藏层激活状态之间是条件独立的,此时,第j个隐藏单元的激活概率为:

$$P(h_j = 1 | v, \theta) = \sigma \left(b_j + \sum_i v_i w_{ij} \right)$$

其中 $\sigma(x) = \frac{1}{1 + \exp(-x)}$ 为sigmoid激活函数, $\theta = \{w_{ij}, a_i, b_j\}$ 为RBM的参数, w_{ij} 表示可见单元i和隐藏单元j之间的连接权重, a_i 表示可视单元i的偏置, b_j 表示隐层单元j的偏置, h_j 是第j个隐藏单元状态, v_i 是第i个可见单元状态,它们的状态只有两种:0或1;由于RBM的结构是对称的,当给定隐藏单元的状态时,可见单元的激活条件也是条件独立的,即第i个可见单元的激活概率为:

$$P(v_i|h, \theta) = \sigma(a_i + \sum_j w_{ij} h_j)$$

RBM是一个激活函数为sigmoid函数的随机神经网络,通过迭代的方式进行训练得到参数 $\theta = \{w_{ij}, a_i, b_j\}$ 的结果,并与给定训练数据进行拟合,最优参数 θ^* 可以通过训练集上的极大对数似然函数得到即

$$\theta^* = \arg_{\theta} \max L(\theta) = \arg_{\theta} \max \sum_{t=1}^T \ln p(v^{(t)}|\theta)$$

为了快速计算RBM的对数似然梯度,可以采用对比散度的算法,得到权值和偏置的参数更新,表示为:

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

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

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

其中: ε 为预训练的学习率, $\langle \cdot \rangle_{\text{data}}$ 为训练数据所定义的数学期望, $\langle \cdot \rangle_{\text{recon}}$ 为重构的模型所定义的数学期望;

BP网络是一种有监督学习的分类器,可对RBM预训练得到的特征向量进行分类,并且起到微调整个DBN参数的作用,BP网络的训练分为前向传播和后向传播两个阶段;

前向传播阶段:输入特征向量被逐层传播到输出层,得到预测的分类结果;

反向微调阶段:将预测得到的分类结果与标准标注信息进行比较得到误差,将误差逐层向后回传,从而实现DBN参数的微调;

设DBN一共由1个RBM堆叠而成,初始样本 x ,最后一层输出向量为 $u^1(x)$,

$$u^l(x) = \frac{1}{1 + \exp(b^l + w^l u^{l-1}(x))}$$

其中, b^l 为第1层RBM的偏置, w^l 为第1层RBM的权重,第 i 个样本经前向1层堆叠RBM下学习后,属于类别 $y_i, y_i \in (1, 2, \dots, c)$ 的概率是

$$p(y_i = k | u^l(x_i), V^l, c^l) = \frac{e^{V_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{V_k^l u^l(x_i) + c^l}}$$

V 为参数系数,选取最大概率所对应的类别即为Soft-max模型判定类别;

第1层误差函数表达式为

$$J(\lambda^l) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{k=1}^c 1\{y_i = k\} \log \frac{e^{V_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{V_k^l u^l(x_i) + c^l}} \right]$$

ρ 为权重衰减率, $\lambda^l = \{w^l, b^l, c^l, V^l\}$, $1\{y_i = k\}$ 为逻辑指示函数,当 $y_i = k$ 时,值为1,当 $y_i \neq k$ 时,值为0, m 为隐藏层的神经元个数, c 为类别个数;为求误差最小值,使用梯度上升法,对参数求偏导

$$\nabla_{\lambda^l} J(\lambda^l) = -\frac{1}{m} [u^l(\hat{x}_i) (1\{y_i = k\} - h^l(\hat{x}_i))]$$

微调参数

$$\lambda^l = \lambda^l - \alpha \nabla_{\lambda^l} J(\lambda^l)$$

a为学习率,以此类推,微调1到1层相关参数。

5. 一种基于局部二值模式和深度置信网络的滚动轴承预测系统,其特征在于,包括如下模块:

预处理模块,用于对已知状态的一维滚动轴承的振动信号进行预处理,得到已知状态的滚动轴承的二维时域灰度图;

图像划分模块,用于将得到的已知状态的滚动轴承的二维时域灰度图像进行区域划分,划分原则为:分别取图像宽度和高度的公约数;

$LBP_{P,R}^{u2}$ 特征提取模块,用于将上述灰度图像划分区域使用基于统一局部二值模式 $LBP_{P,R}^{u2}$ 算子进行特征提取,得到各划分区域的统计直方图,再将各划分区域得到的统计直方图进行组合,得到整幅图的统计直方图,并对统计直方图进行归一化处理;

DBN网络训练模块,用于将整幅图像的统计直方图输入到DBN网络(深度置信网络),并对DBN网络进行前向自学习处理和基于梯度下降的反向传播处理,调整DBN网络的模型参数,得到训练完成的DBN网络;

故障分类模块,用于在识别实际多负载滚动轴承故障模式时,首先对未知状态的滚动轴承的振动信号进行步骤一至三的处理,获得其对应的统计直方图,然后利用所得到的训练完成的DBN网络进行分类,从而确定实际滚动轴承的故障类型。

6. 根据权利要求5所述的一种基于局部二值模式和深度置信网络的滚动轴承预测系统,其特征在于:所述预处理模块中,将对已知状态的一维滚动轴承的振动信号进行归一化处理,使其范围控制在 $[0, 1]$ 内,之后将归一化后的振动信号转换为二维灰度时域图,图片的幅值设置为 $[0-1]$;要求转化为二维灰度时域图的一维滚动轴承的振动信号长度应满足大于转轴转一圈传感器所采集数据点的个数;二维灰度图的分辨率具有相同的尺度。

7. 根据权利要求书5所述的一种基于局部二值模式和深度置信网络的滚动轴承预测系统,其特征在于:所述图像划分模块中,对已知状态的滚动轴承的二维时域灰度图像进行区域划分的具体原则为:根据二维灰度图的分辨率大小进行划分,若分辨率的宽度与高度均为n的倍数,则将二维灰度图分块成 $n \times n$;且分块越多会识别率越高,但运算时间将会增加。

8. 根据权利要求书5所述的一种基于局部二值模式和深度置信网络的滚动轴承预测方法,其特征在于:DBN网络训练模块中所述DBN网络实质上是由多个受限玻尔兹曼机(RBM)和一层有监督的反向传播网络(BPNN)堆叠而成的多层感知神经网络,具体结构如下,

每个受限玻尔兹曼机均由可视层和隐藏层组成,层与层之间通过权值w连接,各层内部相互独立,当给定可见单元的状态时,各隐藏层激活状态之间是条件独立的,此时,第j个隐藏单元的激活概率为:

$$P(h_j = 1 | v, \theta) = \sigma \left(b_j + \sum_i v_i w_{ij} \right)$$

其中 $\sigma(x) = \frac{1}{1 + \exp(-x)}$ 为sigmoid激活函数, $\theta = \{w_{ij}, a_i, b_j\}$ 为RBM的参数, w_{ij} 表示可见单元i和隐藏单元j之间的连接权重, a_i 表示可视单元i的偏置, b_j 表示隐层单元j的偏置, h_j 是第j个隐藏单元状态, v_i 是第i个可见单元状态,它们的状态只有两种:0或1;由于RBM的结构是对称的,当给定隐藏单元的状态时,可见单元的激活条件也是条件独立的,即第i个可见单元的激活概率为:

$$P(v_i|h, \theta) = \sigma(a_i + \sum_j w_{ij} h_j)$$

RBM是一个激活函数为sigmoid函数的随机神经网络,通过迭代的方式进行训练得到参数 $\theta = \{w_{ij}, a_i, b_j\}$ 的结果,并与给定训练数据进行拟合,最优参数 θ^* 可以通过训练集上的极大对数似然函数得到即

$$\theta^* = \arg_{\theta} \max L(\theta) = \arg_{\theta} \max \sum_{t=1}^T \ln p(v^{(t)}|\theta)$$

为了快速计算RBM的对数似然梯度,可以采用对比散度的算法,得到权值和偏置的参数更新,表示为:

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

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

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

其中: ε 为预训练的学习率, $\langle \cdot \rangle_{\text{data}}$ 为训练数据所定义的数学期望, $\langle \cdot \rangle_{\text{recon}}$ 为重构的模型所定义的数学期望;

BP网络是一种有监督学习的分类器,可对RBM预训练得到的特征向量进行分类,并且起到微调整个DBN参数的作用,BP网络的训练分为前向传播和后向传播两个阶段;

前向传播阶段:输入特征向量被逐层传播到输出层,得到预测的分类结果;

反向微调阶段:将预测得到的分类结果与标准标注信息进行比较得到误差,将误差逐层向后回传,从而实现DBN参数的微调;

设DBN一共由1个RBM堆叠而成,初始样本 x ,最后一层输出向量为 $u^l(x)$,

$$u^l(x) = \frac{1}{1 + \exp(b^l + w^l u^{l-1}(x))}$$

其中, b^l 为第1层RBM的偏置, w^l 为第1层RBM的权重,第 i 个样本经前向1层堆叠RBM下学习后,属于类别 $y_i, y_i \in (1, 2, \dots, c)$ 的概率是

$$p(y_i = k | u^l(x_i), V^l, c^l) = \frac{e^{v_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{v_k^l u^l(x_i) + c^l}}$$

V 为参数系数,选取最大概率所对应的类别即为Soft-max模型判定类别;

第1层误差函数表达式为

$$J(\lambda^l) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{k=1}^c 1\{y_i = k\} \log \frac{e^{v_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{v_k^l u^l(x_i) + c^l}} \right]$$

ρ 为权重衰减率, $\lambda^l = \{w^l, b^l, c^l, V^l\}$, $1\{y_i = k\}$ 为逻辑指示函数,当 $y_i = k$ 时,值为1,当 $y_i \neq k$ 时,值为0, m 为隐藏层的神经元个数, c 为类别个数;为求误差最小值,使用梯度上升法,对参数求偏导

$$\nabla_{\lambda^l} J(\lambda^l) = -\frac{1}{m} [u^l(\hat{x}_i) (1\{y_i = k\} - h^l(\hat{x}_i))]$$

微调参数

$$\lambda^l = \lambda^l - \alpha \nabla_{\lambda^l} J(\lambda^l)$$

a为学习率,以此类推,微调1到1层相关参数。

一种基于局部二值模式和深度置信网络的滚动轴承预测方法和系统

技术领域

[0001] 本发明属于图像处理、机械设备健康检测领域,涉及局部二值模式算法,特别涉及一种基于局部二值模式和深度置信网络的滚动轴承预测方法和系统。

背景技术

[0002] 滚动轴承是旋转机械中最常见并且是很关键的机械部件,广泛应用于家庭和工业设备中。由于轴承通常在恶劣的工作环境中工作,因此它们在工作中很容易发生故障。如果不及时发现故障,可能会导致机器意外停机,甚至导致灾难性的损坏。因此,有必要采取一种检测方式检测滚动轴承的健康状态,识别是否发生故障,以及故障的类型和故障的严重程度,进而采取必要的措施,防止轴承的进一步损坏,确保设备及时的休整,安全的运行。

[0003] 近些年来随着机器学习和其他技术的发展,越来越多的研发者将神经网络、支持向量机、K-最近邻算法等机器学习技术运用到滚动轴承故障诊断上来。但是这些技术都需要人工提取滚动轴承振动信号的特征,这一过程不仅需要技术人员拥有相关的信号专业知识主观的去选择特征,并且消耗大量时间。深度置信网络(DBN)是Hinton于2006年引入的一种深度神经网络,它通过组合底层特征形成更加抽象的高层表示,已发现数据分布式特征表示,是一种可以直接从底层原始信号出发,逐层贪婪学习得到高层特征学习网络。与传统方法相比,深度置信网络通过构建多层网络自动组合底层特征形成更加抽象的高层表示,自动从底层到高层提取特征,进而提升分类和预测的准确性。

[0004] 在某些情况滚动轴承振动信号可以以二维时域图像格式的形式呈现。二维时域图可以反映信号幅值与时间的关系,比一维信号包含着更多的信息。从本质上讲,滚动轴承的故障诊断是一种故障模式识别过程,与图像识别过程非常相似。故障分类和图像识别都属于模式识别的范畴。因此,将图像处理领域的计算方法引入到滚动轴承的故障诊断中具有较高的可行性。然而直接将滚动轴承振动时域图像直接做DBN的输入,状态识别性能会下降。因为二维图的维数是巨大的,直接作为DBN的输入,会造成维数灾难,消耗大量的时间。并且DBN会忽略图像的局部特征,而滚动轴承的二维时域图的局部特征往往会包含着丰富的故障状况信息。因此需要将图像处理的方法和DBN自动提取特征高效的识别能力进行结合。目前大部分的图像方法如尺度不变特征变换(SIFT)需要人为的设定参数,而且对二维图像降维效果还有待于提高。

[0005] 有鉴于上述的缺陷,本发明提出一种基于局部二值模式和深度置信网络的滚动轴承预测方法,解决传统故障诊断方法的不足。

发明内容

[0006] 根据本发明实施例提供的技术方案解决的技术问题是传统轴承诊断方法和图像处理方法结合效果不好,难以对振动时域二维图进行较好的特征提取和降维,挖掘数据样本本质信息,分类精度受限和计算消耗较大的问题。

[0007] 本发明涉及到统一局部二值模式和深度置信网络,其基本原理如下:

[0008] 1.LBP(即Local Binary Pattern)最初是作为一种处理局部图像对比度的辅助方法。它具有对高维图像进行降维以及旋转不变性和灰度不变性等显著的优点,其作用区域为纹理特征的一小块局部特征,并且标记出像素级的特征。

[0009] LBP定义在 3×3 的任意半径和任意邻域点的邻域,记号为 $LBP_{P,R}$,P为邻域点数,R为邻域半径。LBP的基本处理方法是,对原始图像某个(不包括边缘像素点)像素点, p_c 和 p_c 周围的8个像素点($p_i, i=1, 2, \dots, 8$)所组成。以中心像素点 p_c 的灰度值为阈值,将 p_c 周围的相邻8个像素点的灰度值与阈值 p_c 依次进行比较,当邻域像素灰度值 $p_i \geq p_c$ 时,对应位置的编码为1,否则为0。然后按照顺时针方向读出8位二进制数(假设从 p_0 开始),即得到该中心像素点 p_c 的LBP值(范围是0-255)。以上描述用公式表示为:

$$[0010] \quad LBP_{P,R}(x_c, y_c) = \sum_{i=0}^{p-1} s(p_i - p_c) 2^i$$

$$[0011] \quad s(x) = \begin{cases} 1, & x \geq 1 \\ 0, & x < 1 \end{cases}$$

[0012] 其中,P和R表示相邻像素点的数量和邻域的半径, p_c 表示中心像素(x_c, y_c)的灰度值, p_i 并且表示邻域中第i个像素的灰度级。

[0013] 研究发现,只有少数部分模式描述图像纹理的重要模式,其出现的概率达到90%以上,这种模式就是“统一模式”。如果把二进制看成一个圆,统一模式就是串中从0到1和从1到0的转换不超过两次的模式,记号 $LBP_{P,R}^{u2}$ 。例如,模式00000000(0次转变)、01110000(2次转变)、11001111(2次转变)是统一模式,被称为一致LBP。而11001001(4次转变)、01010011(6次转变)不是统一模式,被称为非一致LBP。以 $P=8, R=1$ 为例, $LBP_{P,R}$ 的模式有256种,而 $LBP_{P,R}^{u2}$ 的模式最多仅有59种,如图3所示,尽管统一模式LBP仅仅是LBP输出的小部分,但它反映了绝大部分纹理信息,仍具有很强的描述能力。以上描述用公式表示为:

$$[0014] \quad U(LBP_{P,R}) = |s(p_{i-1} - p_c) - s(p_0 - p_c)| + \sum_{P=1}^{P-1} |s(p_i - p_c) - s(p_{i-1} - p_c)|$$

[0015] 其中,P和R表示相邻像素点的数量和邻域的半径, p_c 表示中心像素的灰度值, p_i 并且表示邻域中第i个像素的灰度级。

[0016] 2.深度置信网络

[0017] 深度置信网络实质上是由多个受限玻尔兹曼机(RBM)和一层有监督的反向传播网络(BPNN)堆叠而成的多层感知神经网络,每个受限玻尔兹曼机均由可视层和隐藏层组成,如图3所示的深度置信网络包括3层RBM。

[0018] 所述第一层:第一可视层 v^1 为初始输入数据,和第一隐藏层 h^1 组成第一个RBM(RBM1);

[0019] 所述第二层:第一隐藏层 h^1 作为第二可视层 v^2 ,并和第二隐藏层 h^2 组成第二个RBM(RBM2);

[0020] 所述第三次:第二隐藏层 h^2 作为第三可视层 v^3 ,并和第三层隐藏层 h^3 组成第三个RBM(RBM3)

[0021] 层与层之间通过权值w连接。各层内部相互独立,当给定可见单元的状态时,各隐

藏层激活状态之间是条件独立的,此时,第j个隐藏单元的激活概率为:

$$[0022] \quad P(h_j = 1|v, \theta) = \sigma\left(b_j + \sum_i v_i w_{ij}\right)$$

[0023] 其中 $\sigma(x) = \frac{1}{1+\exp(-x)}$ 为sigmoid激活函数, $\theta = \{w_{ij}, a_i, b_j\}$ 为RBM的参数, w_{ij} 表示可见单元i和隐藏单元j之间的连接权重, a_i 表示可视单元i的偏置, b_j 表示隐层单元j的偏置, h_j 是第j个隐藏单元状态, v_i 是第i个可见单元状态,它们的状态只有两种:0或1。由于RBM的结构是对称的,当给定隐藏单元的状态时,可见单元的激活条件也是条件独立的,即第i个可见单元的激活概率为:

$$[0024] \quad P(v_i|h, \theta) = \sigma\left(a_i + \sum_j w_{ij} h_j\right)$$

[0025] RBM是一个激活函数为sigmoid函数的随机神经网络,通过迭代的方式进行训练得到参数 $\theta = \{w_{ij}, a_i, b_j\}$ 的结果,并与给定训练数据进行拟合。最优参数 θ^* 可以通过训练集上的极大对数似然函数得到,即

$$[0026] \quad \theta^* = \arg_{\theta} \max L(\theta) = \arg_{\theta} \max \sum_{t=1}^T \ln p(v^{(t)}|\theta)$$

[0027] 其中,t为迭代次数,T为最大迭代次数。

[0028] 为了快速计算RBM的对数似然梯度,可以采用对比散度的算法,得到权值和偏置的参数更新,表示为:

$$[0029] \quad \Delta w_{ij} = \varepsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}})$$

$$[0030] \quad \Delta a_i = \varepsilon (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}})$$

$$[0031] \quad \Delta b_j = \varepsilon (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}})$$

[0032] 其中: ε 为预训练的学习率, $\langle \cdot \rangle_{\text{data}}$ 为训练数据所定义的数学期望, $\langle \cdot \rangle_{\text{recon}}$ 为重构的模型所定义的数学期望。

[0033] BP网络是一种有监督学习的分类器,可对RBM预训练得到的特征向量进行分类,并且起到微调整个DBN参数的作用。BP网络的训练分为前向传播和后向传播两个阶段。

[0034] 前向传播阶段:输入特征向量被逐层传播到输出层,得到预测的分类结果。

[0035] 反向微调阶段:此过程是从DBN最后一层出发,利用已知标签逐步向底层微调模型参数,称为后向微调学习。网络最后一层由Soft-max作为分类器,Softmax模型实质上是多分类的逻辑回归模型。设DBN一共由l各RBM堆叠而成,初始样本x,最后一层输出向量为 $u^l(x)$

$$[0036] \quad u^l(x) = \frac{1}{1 + \exp(b^l + w^l u^{l-1}(x))}$$

[0037] 其中, b^l 为第l层RBM的偏置, w^l 为第l层RBM的权重,第i个样本经前向l层堆叠RBM下学习后,属于类别 $y_i, y_i \in (1, 2, \dots, c)$ 的概率是

$$[0038] \quad p(y_i = k|u^l(x_i), V^l, c^l) = \frac{e^{V_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{V_k^l u^l(x_i) + c^l}}$$

[0039] V为参数系数,选取最大概率所对应的类别即为Soft-max模型判定类别。

[0040] 第1层误差函数表达式为

$$[0041] \quad J(\lambda^l) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{k=1}^c 1\{y_i = k\} \log \frac{e^{V_k^l u^l(x_i) + c^l}}{\sum_k^c e^{V_k^l u^l(x_i) + c^l}} \right]$$

[0042] ρ 为权重衰减率, $\lambda^l = \{w^l, b^l, c^l, V^l\}$, $1\{y_i = k\}$ 为逻辑指示函数, 当 $y_i = k$ 时, 值为1。当 $y_i \neq k$ 时, 值为0, m 为隐藏层的神经元个数, c 为类别个数。为求误差最小值, 使用梯度上升法, 对参数求偏导

$$[0043] \quad \nabla_{\lambda^l} J(\lambda^l) = -\frac{1}{m} [u^l(\hat{x}_i)(1\{y_i = k\} - h^l(\hat{x}_i))]$$

[0044] 微调参数

$$[0045] \quad \lambda^l = \lambda^l - a \nabla_{\lambda^l} J(\lambda^l)$$

[0046] a 为学习率, 以此类推, 微调1到1层相关参数。

[0047] 根据上述发明构思, 本发明采用下述技术方案: 一种基于局部二值模式和深度置信网络的滚动轴承预测方法, 将局部二值模式和深度置信网络进行融合, 不但解决了图像处理 and DBN 结合效果不好的问题, 更直面解决了图像高维数据降维问题和滚动轴承二维振动时域特征提取难的问题, 具体步骤如下:

[0048] 步骤一, 对已知状态的一维滚动轴承的振动信号进行预处理, 得到已知状态的滚动轴承的二维时域灰度图;

[0049] 步骤二, 将得到的已知状态的滚动轴承的二维时域灰度图像进行区域划分, 划分原则为: 分别取图像宽度和高度的公约数;

[0050] 步骤三, 将上述灰度图像划分区域使用基于统一局部二值模式 $LBP_{P,R}^{u2}$ 算子进行特征提取, 得到各划分区域的统计直方图, 再将各划分区域得到的统计直方图进行组合, 得到整幅图的统计直方图, 并对统计直方图进行归一化处理;

[0051] 步骤四, 将整幅图像的统计直方图输入到DBN网络(深度置信网络), 并对DBN网络进行前向自学习处理和基于梯度下降的反向传播处理, 调整DBN网络的模型参数, 得到训练完成的DBN网络;

[0052] 步骤五, 在识别实际多负载滚动轴承故障模式时, 首先对未知状态的滚动轴承的振动信号进行步骤一至三的处理, 获得其对应的统计直方图, 然后利用所得到的训练完成的DBN网络进行分类, 从而确定实际滚动轴承的故障类型。

[0053] 进一步的, 所述步骤一中, 将对已知状态的一维滚动轴承的振动信号进行归一化处理, 使其范围控制在 $[0, 1]$ 内, 之后将归一化后的振动信号转换为二维灰度时域图, 图片的幅值设置为 $[0-1]$; 要求转化为二维灰度时域图的一维滚动轴承的振动信号长度应满足大于转轴转一圈传感器所采集数据点的个数; 二维灰度图的分辨率具有相同的尺度。

[0054] 进一步的, 所述步骤二中, 对已知状态的滚动轴承的二维时域灰度图像进行区域划分的具体原则为: 根据二维灰度图的分辨率大小进行划分, 若分辨率的宽度与高度均为 n 的倍数, 则将二维灰度图分块成 $n \times n$; 且分块越多会识别率越高, 但运算时间将会增加。

[0055] 进一步的, 步骤四中所述DBN网络实质上是由多个受限玻尔兹曼机(RBM)和一层有监督的反向传播网络(BPNN)堆叠而成的多层感知神经网络, 具体结构如下,

[0056] 每个受限玻尔兹曼机均由可视层和隐藏层组成, 层与层之间通过权值 w 连接, 各层

内部相互独立,当给定可见单元的状态时,各隐藏层激活状态之间是条件独立的,此时,第j个隐藏单元的激活概率为:

$$[0057] \quad P(h_j = 1 | v, \theta) = \sigma \left(b_j + \sum_i v_i w_{ij} \right)$$

[0058] 其中 $\sigma(x) = \frac{1}{1 + \exp(-x)}$ 为sigmoid激活函数, $\theta = \{w_{ij}, a_i, b_j\}$ 为RBM的参数, w_{ij} 表示可见单元i和隐藏单元j之间的连接权重, a_i 表示可见单元i的偏置, b_j 表示隐层单元j的偏置, h_j 是第j个隐藏单元状态, v_i 是第i个可见单元状态,它们的状态只有两种:0或1;由于RBM的结构是对称的,当给定隐藏单元的状态时,可见单元的激活条件也是条件独立的,即第i个可见单元的激活概率为:

$$[0059] \quad P(v_i | h, \theta) = \sigma(a_i + \sum_j w_{ij} h_j)$$

[0060] RBM是一个激活函数为sigmoid函数的随机神经网络,通过迭代的方式进行训练得到参数 $\theta = \{w_{ij}, a_i, b_j\}$ 的结果,并与给定训练数据进行拟合,最优参数 θ^* 可以通过训练集上的极大对数似然函数得到即

$$[0061] \quad \theta^* = \arg_{\theta} \max L(\theta) = \arg_{\theta} \max \sum_{t=1}^T \ln p(v^{(t)} | \theta)$$

[0062] 为了快速计算RBM的对数似然梯度,可以采用对比散度的算法,得到权值和偏置的参数更新,表示为:

$$[0063] \quad \Delta w_{ij} = \varepsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}})$$

$$[0064] \quad \Delta a_i = \varepsilon (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}})$$

$$[0065] \quad \Delta b_j = \varepsilon (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}})$$

[0066] 其中: ε 为预训练的学习率, $\langle \cdot \rangle_{\text{data}}$ 为训练数据所定义的数学期望, $\langle \cdot \rangle_{\text{recon}}$ 为重构的模型所定义的数学期望;

[0067] BP网络是一种有监督学习的分类器,可对RBM预训练得到的特征向量进行分类,并且起到微调整个DBN参数的作用,BP网络的训练分为前向传播和后向传播两个阶段;

[0068] 前向传播阶段:输入特征向量被逐层传播到输出层,得到预测的分类结果;

[0069] 反向微调阶段:将预测得到的分类结果与标准标注信息进行比较得到误差,将误差逐层向后回传,从而实现DBN参数的微调;

[0070] 设DBN一共由l个RBM堆叠而成,初始样本x,最后一层输出向量为 $u^l(x)$,

$$[0071] \quad u^l(x) = \frac{1}{1 + \exp(b^l + w^l u^{l-1}(x))}$$

[0072] 其中, b^l 为第l层RBM的偏置, w^l 为第l层RBM的权重,第i个样本经前向l层堆叠RBM下学习后,属于类别 $y_i, y_i \in (1, 2, \dots, c)$ 的概率是

$$[0073] \quad p(y_i = k | u^l(x_i), V^l, c^l) = \frac{e^{V_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{V_k^l u^l(x_i) + c^l}}$$

[0074] V为参数系数,选取最大概率所对应的类别即为Soft-max模型判定类别;

[0075] 第l层误差函数表达式为

$$[0076] \quad J(\lambda^l) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{k=1}^c 1\{y_i = k\} \log \frac{e^{v_k^l u^l(x_i) + c^l}}{\sum_k e^{v_k^l u^l(x_i) + c^l}} \right]$$

[0077] ρ 为权重衰减率, $\lambda^l = \{w^l, b^l, c^l, v^l\}$, $1\{y_i = k\}$ 为逻辑指示函数, 当 $y_i = k$ 时, 值为1, 当 $y_i \neq k$ 时, 值为0, m 为隐藏层的神经元个数, c 为类别个数; 为求误差最小值, 使用梯度上升法, 对参数求偏导

$$[0078] \quad \nabla_{\lambda^l} J(\lambda^l) = -\frac{1}{m} [u^l(\hat{x}_i)(1\{y_i = k\} - h^l(\hat{x}_i))]$$

[0079] 微调参数

$$[0080] \quad \lambda^l = \lambda^l - \alpha \nabla_{\lambda^l} J(\lambda^l)$$

[0081] α 为学习率, 以此类推, 微调1到1层相关参数。

[0082] 此外, 本发明提供一种基于局部二值模式和深度置信网络的滚动轴承预测系统, 包括如下模块:

[0083] 预处理模块, 用于对已知状态的一维滚动轴承的振动信号进行预处理, 得到已知状态的滚动轴承的二维时域灰度图;

[0084] 图像划分模块, 用于将得到的已知状态的滚动轴承的二维时域灰度图像进行区域划分, 划分原则为: 分别取图像宽度和高度的公约数;

[0085] LBP_{PR}^{u2} 特征提取模块, 用于将上述灰度图像划分区域使用基于统一局部二值模式 LBP_{PR}^{u2} 算子进行特征提取, 得到各划分区域的统计直方图, 再将各划分区域得到的统计直方图进行组合, 得到整幅图的统计直方图, 并对统计直方图进行归一化处理;

[0086] DBN网络训练模块, 用于将整幅图像的统计直方图输入到DBN网络(深度置信网络), 并对DBN网络进行前向自学习处理和基于梯度下降的反向传播处理, 调整DBN网络的模型参数, 得到训练完成的DBN网络;

[0087] 故障分类模块, 用于在识别实际多负载滚动轴承故障模式时, 首先对未知状态的滚动轴承的振动信号进行步骤一至三的处理, 获得其对应的统计直方图, 然后利用所得到的训练完成的DBN网络进行分类, 从而确定实际滚动轴承的故障类型。

[0088] 进一步的, 所述预处理模块中, 将对已知状态的一维滚动轴承的振动信号进行归一化处理, 使其范围控制在 $[0, 1]$ 内, 之后将归一化后的振动信号转换为二维灰度时域图, 图片的幅值设置为 $[0-1]$; 要求转化为二维灰度时域图的一维滚动轴承的振动信号长度应满足大于转轴转一圈传感器所采集数据点的个数; 二维灰度图的分辨率具有相同的尺度。

[0089] 进一步的, 所述图像划分模块中, 对已知状态的滚动轴承的二维时域灰度图像进行区域划分的具体原则为: 根据二维灰度图的分辨率大小进行划分, 若分辨率的宽度与高度均为 n 的倍数, 则将二维灰度图分块成 $n \times n$; 且分块越多会识别率越高, 但运算时间将会增加。

[0090] 进一步的, DBN网络训练模块中所述DBN网络实质上是由多个受限玻尔兹曼机(RBM)和一层有监督的反向传播网络(BPNN)堆叠而成的多层感知神经网络, 具体结构如下,

[0091] 每个受限玻尔兹曼机均由可视层和隐藏层组成, 层与层之间通过权值 w 连接, 各层内部相互独立, 当给定可见单元的状态时, 各隐藏层激活状态之间是条件独立的, 此时, 第 j 个隐藏单元的激活概率为:

$$[0092] \quad P(h_j = 1|v, \theta) = \sigma\left(b_j + \sum_i v_i w_{ij}\right)$$

[0093] 其中 $\sigma(x) = \frac{1}{1+\exp(-x)}$ 为sigmoid激活函数, $\theta = \{w_{ij}, a_i, b_j\}$ 为RBM的参数, w_{ij} 表示可见单元*i*和隐藏单元*j*之间的连接权重, a_i 表示可视单元*i*的偏置, b_j 表示隐层单元*j*的偏置, h_j 是第*j*个隐藏单元状态, v_i 是第*i*个可见单元状态, 它们的状态只有两种:0或1; 由于RBM的结构是对称的, 当给定隐藏单元的状态时, 可见单元的激活条件也是条件独立的, 即第*i*个可见单元的激活概率为:

$$[0094] \quad P(v_i|h, \theta) = \sigma\left(a_i + \sum_j w_{ij} h_j\right)$$

[0095] RBM是一个激活函数为sigmoid函数的随机神经网络, 通过迭代的方式进行训练得到参数 $\theta = \{w_{ij}, a_i, b_j\}$ 的结果, 并与给定训练数据进行拟合, 最优参数 θ^* 可以通过训练集上的极大对数似然函数得到即

$$[0096] \quad \theta^* = \arg_{\theta} \max L(\theta) = \arg_{\theta} \max \sum_{t=1}^T \ln p(v^{(t)}|\theta)$$

[0097] 为了快速计算RBM的对数似然梯度, 可以采用对比散度的算法, 得到权值和偏置的参数更新, 表示为:

$$[0098] \quad \Delta w_{ij} = \varepsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}})$$

$$[0099] \quad \Delta a_i = \varepsilon (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}})$$

$$[0100] \quad \Delta b_j = \varepsilon (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}})$$

[0101] 其中: ε 为预训练的学习率, $\langle \cdot \rangle_{\text{data}}$ 为训练数据所定义的数学期望, $\langle \cdot \rangle_{\text{recon}}$ 为重构的模型所定义的数学期望;

[0102] BP网络是一种有监督学习的分类器, 可对RBM预训练得到的特征向量进行分类, 并且起到微调整个DBN参数的作用, BP网络的训练分为前向传播和后向传播两个阶段;

[0103] 前向传播阶段: 输入特征向量被逐层传播到输出层, 得到预测的分类结果;

[0104] 反向微调阶段: 将预测得到的分类结果与标准标注信息进行比较得到误差, 将误差逐层向后回传, 从而实现DBN参数的微调;

[0105] 设DBN一共由*l*个RBM堆叠而成, 初始样本*x*, 最后一层输出向量为 $u^l(x)$,

$$[0106] \quad u^l(x) = \frac{1}{1 + \exp(b^l + w^l u^{l-1}(x))}$$

[0107] 其中, b^l 为第*l*层RBM的偏置, w^l 为第*l*层RBM的权重, 第*i*个样本经前向*l*层堆叠RBM下学习后, 属于类别 $y_i, y_i \in (1, 2, \dots, c)$ 的概率是

$$[0108] \quad p(y_i = k|u^l(x_i), V^l, c^l) = \frac{e^{V_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{V_k^l u^l(x_i) + c^l}}$$

[0109] V 为参数系数, 选取最大概率所对应的类别即为Soft-max模型判定类别;

[0110] 第*l*层误差函数表达式为

$$[0111] \quad J(\lambda^l) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{k=1}^c 1\{y_i = k\} \log \frac{e^{V_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{V_k^l u^l(x_i) + c^l}} \right]$$

[0112] ρ 为权重衰减率, $\lambda^l = \{w^l, b^l, c^l, v^l\}$, $1\{y_i = k\}$ 为逻辑指示函数, 当 $y_i = k$ 时, 值为1, 当 $y_i \neq k$ 时, 值为0, m 为隐藏层的神经元个数, c 为类别个数; 为求误差最小值, 使用梯度上升法, 对参数求偏导

$$[0113] \quad \nabla_{\lambda^l} J(\lambda^l) = -\frac{1}{m} [u^l(\hat{x}_i)(1\{y_i = k\} - h^l(\hat{x}_i))]$$

[0114] 微调参数

$$[0115] \quad \lambda^l = \lambda^l - a \nabla_{\lambda^l} J(\lambda^l)$$

[0116] a 为学习率, 以此类推, 微调1到1层相关参数。

[0117] 本发明与现有传统滚动轴承故障诊断技术相比较, 具有如下效果:

[0118] 本发明将图像处理技术的局部二值模式和深度学习中的深度置信网络相结合并应用在滚动轴承故障诊断中, 更够对滚动轴承的二维振动时域图进行降维并从局部纹理中提取出有用的特征, 并利用DBN自学习能力进行进一步特征提取并得到较高的故障识别率, 强化故障诊断对多负载情况鲁棒性, 并降低计算资源消耗。

附图说明

[0119] 图1为本发明方法流程图;

[0120] 图2为本发明实施例中LBP算法流程图;

[0121] 图3为本发明实施例中已知状态的二维振动时域灰度图分块及得到统计直方图示意图;

[0122] 图4为本发明实施例中分块统计直方图组合后的新的统计直方图;

[0123] 图5为本发明实施例中DBN网络模型框架图;

[0124] 图6为本发明实施例提供的试验台示意图。

具体实施方式

[0125] 以下结合附图对本发明的优选实施例进行详细说明, 应当理解, 以下所说明的优选实施例仅用于说明和解释发明, 并不用于限定本发明。

[0126] 图1是本发明实施例提供的基于局部二值模式和深度置信网络的滚动轴承故障模式识别方法框图, 如图1所示, 步骤包括:

[0127] 步骤一, 对已知状态的一维滚动轴承的振动信号进行处理, 得到已知状态的滚动轴承的二维时域灰度图。首先将一维滚动轴承的振动信号归一化, 将其幅值限制在 $[0, 1]$, 之后按照一定长度将振动信号分为多个样本, 分别将样本转变为相同尺寸大小的灰度, 图中的幅值限定在 $[0-1]$ 。

[0128] 步骤二, 将所述得到的已知状态的滚动轴承的二维时域灰度图像进行区域划分(如图3所示, 分为 2×2 块), 由于若二维时域灰度图较大, 直接对图片进行LBP处理, 则不能很好的提取图片种的局部问题特征。我们可以将整幅图进行分块, 若图片尺寸的宽度与高度均为2的倍数, 则可将二维灰度图分块成 2×2 (如图3所示); 若分辨率的宽度与高度均为3的倍数, 则可将二维灰度图分块成 3×3 , ...以此类推。分块越多会使识别率越高, 但相应的运算时间将会增加。

[0129] 步骤三, 将上述灰度图像划分区域使用基于统一局部二值模式 $LBP_{P,R}^{u2}$ 算子进行特

征提取得到各划分区域的统计直方图,再将各划分区域得到的统计直方图进行组合,并将组合后的统计直方图进行归一化处理,使其范围控制在 $[0, 1]$ 内,得到整幅图的统计直方图(如图4)。

[0130] LBP最初用具处理局部图象对比度,由于拥有理论简单易懂,运算速度快,编码易实现的优点。请参见附图2,令图像种某像素为 p_i ,与其周围的8邻域(p_1-p_8)组成一个模板。将8邻域像素值分别与中心像素 p_i 比较,若差值大于0,则令差值状态为1,若小于0,则令差值状态为0。根据一定的方法将所获得的二值化特征转化为十进制,即此中心像素的LBP特征。研究发现,只有少数部分模式描述图像纹理的重要模式,其出现的概率达到90%以上,这种模式就是“统一模式”。如果把二进制看成一个圆,统一模式就是串中从0到1和从1到0的转换不超过两次的模式,记号 $LBP_{P,R}^{u_2}$ 。例如,模式00000000(0次转变)、01110000(2次转变)、11001111(2次转变)是统一模式,被称为一致LBP。而11001001(4次转变)、01010011(6次转变)不是统一模式,被称为非一致LBP。以 $P=8, R=1$ 为例, $LBP_{P,R}$ 的模式有256种,而 $LBP_{P,R}^{u_2}$ 的模式最多仅有59种。由此 $LBP_{P,R}^{u_2}$ 不但保存了二维振动时域灰度图中的故障信息,并进一步降维。

[0131] 步骤四,将所述统计直方图输入到DBN网络,并通过所述DBN网络进行前向自学习处理和基于梯度下降的反向传播处理,调整所示DBN网络的模型参数,得到训练完成的DBN网络,DBN网络模型如图2所示。深度置信网络实质上是由多个受限玻尔兹曼机(RBM)和一层有监督的反向传播网络(BPNN)堆叠而成的多层感知神经网络,每个受限玻尔兹曼机均由可视层和隐藏层组成,本实施例中包含3层RBM,每一层的参数如下。

[0132] 所述第一层:第一可视层 v^1 为初始输入数据,和第一隐藏层 h^1 组成第一个RBM(RBM1);

[0133] 所述第二层:第一隐藏层 h^1 作为第二可视层 v^2 ,并和第二隐藏层 h^2 组成第二个RBM(RBM2);

[0134] 所述第三次:第二隐藏层 h^2 作为第三可视层 v^3 ,并和第三层隐藏层 h^3 组成第三个RBM(RBM3)

[0135] 层与层之间通过权值 w 连接,各层内部相互独立,当给定可见单元的状态时,各隐藏层激活状态之间是条件独立的,此时,第 j 个隐藏单元的激活概率为:

$$[0136] \quad P(h_j = 1 | v, \theta) = \sigma \left(b_j + \sum_i v_i w_{ij} \right)$$

[0137] 其中 $\sigma(x) = \frac{1}{1 + \exp(-x)}$ 为sigmoid激活函数, $\theta = \{w_{ij}, a_i, b_j\}$ 为RBM的参数, w_{ij} 表示可见单元 i 和隐藏单元 j 之间的连接权重, a_i 表示可视单元 i 的偏置, b_j 表示隐层单元 j 的偏置, h_j 是第 j 个隐藏单元状态, v_i 是第 i 个可见单元状态,它们的状态只有两种:0或1。由于RBM的结构是对称的,当给定隐藏单元的状态时,可见单元的激活条件也是条件独立的,即第 i 个可视单元的激活概率为:

$$[0138] \quad P(v_i | h, \theta) = \sigma \left(a_i + \sum_j w_{ij} h_j \right)$$

[0139] RBM是一个激活函数为sigmoid函数的随机神经网络,通过迭代的方式进行训练得到参数 $\theta = \{w_{ij}, a_i, b_j\}$ 的结果,并与给定训练数据进行拟合。最优参数 θ^* 可以通过训练集上

的极大对数似然函数得到即

$$[0140] \quad \theta^* = \arg_{\theta} \max L(\theta) = \arg_{\theta} \max \sum_{t=1}^T \ln p(v^{(t)}|\theta)$$

[0141] 为了快速计算RBM的对数似然梯度,可以采用对比散度的算法,得到权值和偏置的参数更新,表示为:

$$[0142] \quad \Delta \omega_{ij} = \varepsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}})$$

$$[0143] \quad \Delta a_i = \varepsilon (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}})$$

$$[0144] \quad \Delta b_j = \varepsilon (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}})$$

[0145] 其中: ε 为预训练的学习率, $\langle \cdot \rangle_{\text{data}}$ 为训练数据所定义的数学期望, $\langle \cdot \rangle_{\text{recon}}$ 为重构的模型所定义的数学期望。

[0146] BP网络是一种有监督学习的分类器,可对RBM预训练得到的特征向量进行分类,并且起到微调整个DBN参数的作用。BP网络的训练分为前向传播和后向传播两个阶段。

[0147] 前向传播阶段:输入特征向量被逐层传播到输出层,得到预测的分类结果。

[0148] 反向微调阶段:将预测得到的分类结果与标准标注信息进行比较得到误差,将误差逐层向后回传,从而实现DBN参数的微调。

[0149] 设DBN一共由1个RBM堆叠而成,初始样本 x ,最后一层输出向量为 $u^1(x)$

$$[0150] \quad u^l(x) = \frac{1}{1 + \exp(b^l + w^l u^{l-1}(x))}$$

[0151] 其中, b^l 为第1层RBM的偏置, w^l 为第1层RBM的权重,第 i 个样本经前向1层堆叠RBM下学习后,属于类别 y_i , $y_i \in (1, 2, \dots, c)$ 的概率是

$$[0152] \quad p(y_i = k | u^l(x_i), V^l, c^l) = \frac{e^{V_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{V_k^l u^l(x_i) + c^l}}$$

[0153] V 为参数系数,选取最大概率所对应的类别即为Soft-max模型判定类别。

[0154] 第1层误差函数表达式为

$$[0155] \quad J(\lambda^l) = -1m \left[\sum_{i=1}^m \sum_{k=1}^c 1\{y_i = k\} \log \frac{e^{V_k^l u^l(x_i) + c^l}}{\sum_{k=1}^c e^{V_k^l u^l(x_i) + c^l}} \right]$$

[0156] ρ 为权重衰减率, $\lambda^l = \{w^l, b^l, c^l, V^l\}$, $1\{y_i = k\}$ 为逻辑指示函数,当 $y_i = k$ 时,值为1。当 $y_i \neq k$ 时,值为0, m 为隐藏层的神经元个数, c 为类别个数。为求误差最小值,使用梯度上升法,对参数求偏导

$$[0157] \quad \nabla_{\lambda^l} J(\lambda^l) = -\frac{1}{m} [u^l(\hat{x}_i)(1\{y_i = k\} - h^l(\hat{x}_i))]$$

[0158] 微调参数

$$[0159] \quad \lambda^l = \lambda^l - a \nabla_{\lambda^l} J(\lambda^l)$$

[0160] a 为学习率,以此类推,微调1到1层相关参数。

[0161] 步骤五,在识别实际多负载滚动轴承故障模式时,利用所得到的训练完成的DBN网络,对未知状态的滚动轴承的振动信号与上述已知状态做相同处理,即对应的二维时域灰度图的 $LBP_{P,R}^{u_2}$ 统计直方图进行处理,从而确定实际滚动轴承的故障类型。

[0162] 具体实施时,本发明技术方案可基于计算机软件技术实现自动运行流程,也可采用模块化方式实现相应系统。本发明实施例提供一种基于局部二值模式和深度置信网络的滚动轴承预测系统,包括如下模块:

[0163] 预处理模块,用于对已知状态的一维滚动轴承的振动信号进行预处理,得到已知状态的滚动轴承的二维时域灰度图;

[0164] 图像划分模块,用于将得到的已知状态的滚动轴承的二维时域灰度图像进行区域划分,划分原则为:分别取图像宽度和高度的公约数;

[0165] $LBP_{P,R}^{u_2}$ 特征提取模块,用于将上述灰度图像划分区域使用基于统一局部二值模式 $LBP_{P,R}^{u_2}$ 算子进行特征提取,得到各划分区域的统计直方图,再将各划分区域得到的统计直方图进行组合,得到整幅图的统计直方图,并对统计直方图进行归一化处理;

[0166] DBN网络训练模块,用于将整幅图像的统计直方图输入到DBN网络(深度置信网络),并对DBN网络进行前向自学习处理和基于梯度下降的反向传播处理,调整DBN网络的模型参数,得到训练完成的DBN网络;

[0167] 故障分类模块,用于在识别实际多负载滚动轴承故障模式时,首先对未知状态的滚动轴承的振动信号进行步骤一至三的处理,获得其对应的统计直方图,然后利用所得到的训练完成的DBN网络进行分类,从而确定实际滚动轴承的故障类型。

[0168] 各模块具体实现可参见相应步骤,本发明不予撰述。

[0169] 实施例

[0170] 1、原始数据准备

[0171] 本实施例以美国西储大学轴承数据为例,说明基于局部二值模式和深度置信网络的滚动轴承故障诊断实现方法。

[0172] 该滚动轴承试验平台包括一个2马力的电机(左侧)(1hp=746w),一个转矩传感器(中间),一个功率计和电子控制设备。使用电火花加工技术在滚动轴承上的内圈、外圈和滚动体上分别布置单点故障,故障直径分别0.007、0.014、0.021英寸。使用的轴承四SKF轴承。该实验台包括驱动端轴承和风扇端轴承,加速的传感器分别安装在电机壳体和驱动端和风扇端12点钟的位置。振动信号是通用6通道的DAT记录器采集的,数字信号的采样频率为每秒钟12000个点,驱动端轴承故障数据采样速度为每秒钟48000个点,试验台示意图如图6所示。

[0173] 本实施例以驱动端(DE)轴承为研究对象,选择故障直径为7mils、14mils和21mils。将IR07、IR14、IR21表示滚动轴承内圈损伤直径7mils、14mils和21mils的故障状况;依次类推OR07、OR14和OR21分别代表滚动轴承外圈损伤直径7mils、14mils和21mils的故障状况;B07、B14和B21分别代表滚动轴承滚动体损伤直径7mils、14mils和21mils的故障状况;N代表正常状态。每种状态有0hp、1hp和2hp三种负载。以3种负载下,构造3种数据集A、B和C每个数据集包含10种故障类别,每个故障类别可以得到50个样本,每个样本长度为2048。考虑到实际情况,同一种故障类别可能对应多种负载,综合A-C得到数据集D,随机选取每个故障类别样本的60%作为训练,剩下的作为测试。具体轴承数据可参考表1:

[0174] 表1轴承数据

[0175]

故障类别	故障深度(mils)	单负载数据集 A/B/C	多负载数据集 D	故障标签
N	0	50	150	1
OR07	7	50	150	2
OR14	14	50	150	3
OR21	21	50	150	4
IR07	7	50	150	5
IR14	14	50	150	6

[0176]

IR21	21	50	150	7
B07	7	50	150	8
B14	14	50	150	9
B21	21	50	150	10

[0177] $LBP_{P,R}^{u2}$ 模型的主要参数如表2所示, DBN模型参数如表3所示, 不同分块数测试结果如表4;

[0178] 表2 $LBP_{P,R}^{u2}$ 模型参数

[0179]

灰度图片尺寸	分块 ($i=1, 2, 4, 5$)	P相邻像素点数	R邻域半径
560×420	$i \times i$	8	1

[0180] 表3 DBN模型参数

[0181]

隐藏层节点数	学习率	动量	迭代次数
100-100	0.0001	0.9	3000

[0182] 表4不同分块数识别情况

[0183]

分块数		1×1	2×2	4×4	5×5
数据集 A	准确率(%)	89.50	97.12	99.80	99.90
	时间(s)	70.58	65.67	98.56	158.81
数据集 D	准确率(%)	84.25	96.50	98.50	98.52
	时间(s)	213.82	173.35	268.37	382.86

[0184] 由表4可知, 随着分块数的增加, 识别精确率随之提高, 但运行时间也随之增加。为了验证本发明的方法在精度方面的有效性, 采用了两种广泛使用的分类算法进行比较, 即

反向传播网络 (BPNN) 和支持向量机 (SVM)。此外,为了突出DBN的有效性,我们用相同结构的BPNN或SVM替换DBN以进行类似结构的识别。BPNN包含3个隐藏层,每个层包含10个神经元。支持向量机的核函数采用径向基函数,核函数和惩罚因子由交叉验证方法自动选择。考虑表4中分块数、识别率和运行所需时间的诊断结果,选取分块数为 4×4 ,其余参数与上述相同,测试结果如表5所示:

[0185] 表5 $LBP_{P,R}^{u_2}+DBN$ 模型对比诊断结果列表

[0186]

方法	数据集 A (%)	数据集 B (%)	数据集 C (%)	数据集 D (%)
$LBP_{P,R}^{u_2}+SVM$	97.6	96.5	96.8	86.8
$LBP_{P,R}^{u_2}+BPNN$	95	95.2	94.6	85.9
$LBP_{P,R}^{u_2}+DBN$	99.8	99.9	100	98.5

[0187] 分析本发明方法案例的实验结果,可以得到以下结论:

[0188] 通过LBP对二维振动时域灰度图的特征提取,可以获得二维振动时域灰度图的有用的纹理特征,并对图像进行降维。通过实验可以发现,提取出的局部纹理特征使得DBN可以在多负载下依然保持较高的诊断精度。

[0189] 本发明提供一种基于统一模式局部二值模式和深度置信网络的滚动轴承预测方法,首先将一维滚动轴承振动时域信号转变为二维时域灰度图,可适当将图片分块,分块后分别利用统一局部二值模式的方法,对二维时域灰度图进行局部纹理特征提取,并将图像进行降维。将得到的统计直方图进行融合,之后作为DBN的输入,经过DBN进一步的自学习、特征提取并进行故障类别分类,经过实验结果对比,验证了此方法不但对单负载下滚动轴承的故障状态有精确的识别,并且同样适用于多负载的情况,更符合实际的工作情况。

[0190] 本文中所描述的具体实施例仅仅是对本发明精神作举例说明。本发明所属技术领域的技术人员可以对所描述的具体实施例做各种各样的修改或补充或采用类似的方式替代,但并不会偏离本发明的精神或者超越所附权利要求书所定义的范围。

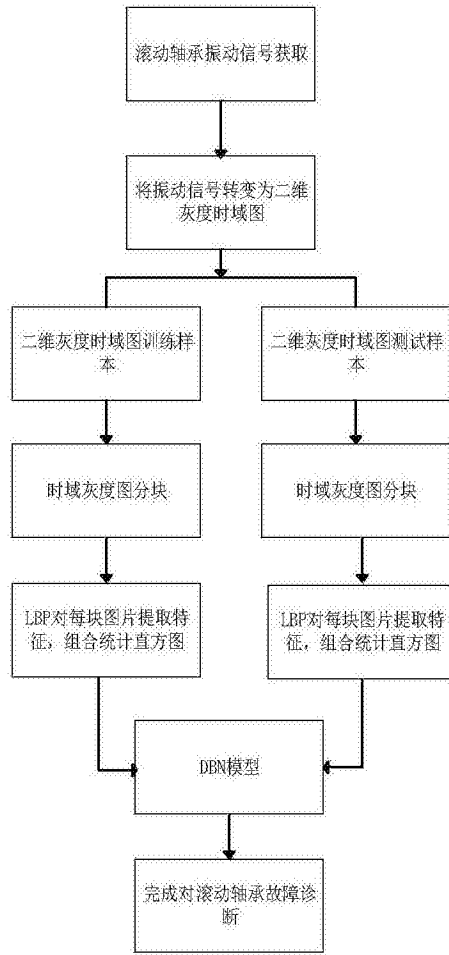


图1

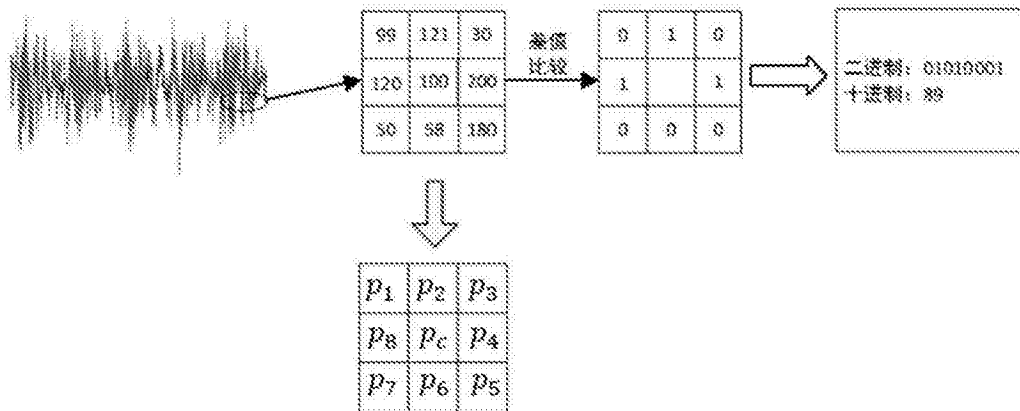


图2




图3




图4




图5




图6