



(12) 发明专利申请

(10) 申请公布号 CN 112541524 A

(43) 申请公布日 2021.03.23

(21) 申请号 202011294362.8

G01R 31/34 (2006.01)

(22) 申请日 2020.11.18

(71) 申请人 湖南大学

地址 410082 湖南省长沙市岳麓区麓山南路麓山门

(72) 发明人 唐瑶 张晓飞 龙卓 黄守道 宋殿义 秦国军 谢金平 饶志蒙 吴公平

(74) 专利代理机构 湖南兆弘专利事务所(普通合伙) 43008

代理人 谭武艺

(51) Int. Cl.

G06K 9/62 (2006.01)

G06F 17/16 (2006.01)

G06F 17/14 (2006.01)

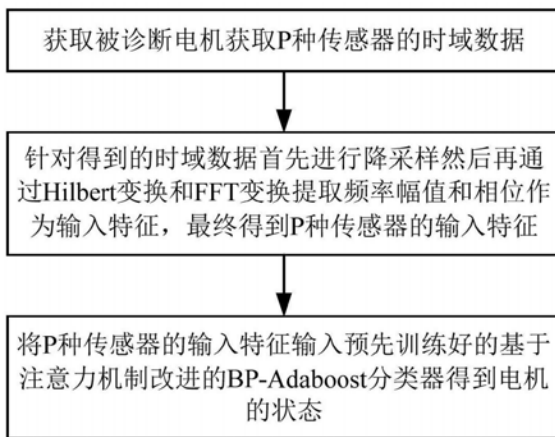
权利要求书4页 说明书16页 附图5页

(54) 发明名称

基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法

(57) 摘要

本发明公开了一种基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法,包括获取被诊断电机获取P种传感器的时域数据;进行降采样然后再通过Hilbert变换和FFT变换提取频率幅值和相位作为输入特征,将P种传感器的输入特征输入预先训练好的基于注意力机制改进的BP-Adaboost分类器得到电机的状态。本发明利用基于注意力机制改进的BP-Adaboost,对不同来源的数据信息进行单独学习训练,形成不同次级分类器的初步诊断,且通过注意力机制将故障诊断方法聚焦到重点测量手段信息,以此来提升信息筛选和判别的能力,并得到最终诊断结果,大大提高电机系统的故障诊断的稳定性和精度。



1. 一种基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法,其特征在于,包括:

1) 获取被诊断电机获取P种传感器的时域数据;

2) 针对得到的时域数据首先进行降采样然后再通过Hilbert变换和FFT变换提取频率幅值和相位作为输入特征,最终得到P种传感器的输入特征;

3) 将P种传感器的输入特征输入预先训练好的基于注意力机制改进的BP-Adaboost分类器得到电机的状态,所述基于注意力机制改进的BP-Adaboost分类器被预先训练建立了输入特征、电机的状态之间的映射关系。

2. 根据权利要求1所述的基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法,其特征在于,所述P种传感器的时域数据包括电机的三相定子电流和杂散电磁,所述电机的状态包括正常状态、转子断条状态、定子匝间短路状态以及轴承损坏故障状态。

3. 根据权利要求1所述的基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法,其特征在于,所述基于注意力机制改进的BP-Adaboost分类器包括P个BP-Adaboost分类器和一个基于注意力机制改进的最终强分类器,P个BP-Adaboost分类器和P种传感器一一对应,且其中任意第p个BP-Adaboost分类器包括指定数量T个基分类器 $h_1^p \sim h_T^p$ 和一个次分类器;所述基于注意力机制改进的BP-Adaboost分类器的训练步骤包括:

S1) 针对被诊断电机获取P种传感器的时域数据,时域数据覆盖任意工况x及状态y;

S2) 针对得到的时域数据首先进行降采样然后再通过Hilbert变换和FFT变换提取频率幅值和相位作为输入特征;针对P种传感器中任意传感器p对应的输入特征 $X^p$ ,分别生成数字标签 $Y^p$ 以及one-hot标签 $Z^p$ ,得到P个数据库;

S3) 针对任意工况x,从P个数据库中随机选择I组训练数据集 $(X_{train}^p, Y_{train}^p, Z_{train}^p)$ 以及J组测试数据集 $(X_{test}^p, Y_{test}^p, Z_{test}^p)$ ,其中任意第i组测试数据集为 $(x_{train}^p(i), y_{train}^p(i), z_{train}^p(i))$ ,任意第j组测试数据集为 $(x_{test}^p(j), y_{test}^p(j), z_{test}^p(j))$ ;

S4) 针对P个BP-Adaboost分类器中的任意第p个BP-Adaboost分类器:根据样本输入输出维度确定任意第p个BP-Adaboost分类器中T个基分类器 $h_1^p \sim h_T^p$ 的神经网络结构与参数,并初始化任意第i组测试数据的权重为 $D_0^p(i) = 1/I$ ,其中I为训练数据集的组数量;

S5) 针对P个BP-Adaboost分类器中的任意第p个BP-Adaboost分类器:通过测试数据集进行T轮训练其中T个基分类器 $h_1^p \sim h_T^p$ ,得到预测误差 $e_1^p \sim e_T^p$ ,根据预测误差 $e_1^p \sim e_T^p$ 分别计算T个基分类器 $h_1^p \sim h_T^p$ 的分类器权重 $\beta_1^p \sim \beta_T^p$ ;

S6) 结合P个BP-Adaboost分类器下基分类器预测的数字标签输出 $\hat{Y}_{train}^p$ ,得到各个基分类器的相似程度矩阵 $C_i^p$ ,通过注意力机制得到的注意力分配权重 $\alpha_i^p$ ;

S7) 针对经过T轮训练后P个BP-Adaboost分类器中任意第p个BP-Adaboost分类器中次分类器得到的BP-Adaboost线性组合输出 $H^p$ 以及输出one-hot标签矩阵 $\hat{Z}^p$ ,通过基于注意力机制改进的最终强分类器根据注意力分配权重 $\alpha_i^p$ 组合P个BP-Adaboost分类器的分类器 $H^p$ 得到基于注意力机制改进的最终强分类器的输出H及其输出故障标签结果 $\hat{Z}(i)$ ;

S8) 将J组测试数据集 $(X_{test}^p, Y_{test}^p, Z_{test}^p)$ 作为基于注意力机制改进的BP-Adaboost分类器的输入,将得到的预测的one-hot标签转换成数字预测结果与数字标签输出比较,统计基于注意力机制改进的BP-AdaBoost强分类器H的准确率。

4. 根据权利要求3所述的基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法,其特征在于,步骤S5)中通过测试数据集进行T轮训练其中T个基分类器 $h_1^p \sim h_T^p$ 时,得到第t个基分类器 $h_t^p$ 的预测误差 $e_t^p$ 的函数表达式为:

$$e_t^p = \sum_i D_t^p(i) \quad (\text{if } h_t^p(x_i^p) \neq z_i^p)$$

其中, $D_t^p(i)$ 为第p个BP-Adaboost分类器中第i组测试数据集在第t轮的权重, $h_t^p(x_i^p)$ 为基分类器 $h_t^p$ 针对输入特征 $x_i^p$ 预测的one-hot标签, $z_i^p$ 为输入特征 $x_i^p$ 对应的one-hot标签;

所述根据预测误差 $e_1^p \sim e_T^p$ 分别计算T个基分类器 $h_1^p \sim h_T^p$ 的分类器权重 $\beta_1^p \sim \beta_T^p$ 时,得到第t个基分类器 $h_t^p$ 的分类器权重 $\beta_t^p$ 的函数表达式为:

$$\beta_t^p = \frac{1}{2} \ln\left(\frac{1-e_t^p}{e_t^p}\right)$$

其中, $e_t^p$ 为第p个BP-Adaboost分类器中第t个基分类器的预测误差;

且每一轮训练中更新第t+1轮的权重 $D_{t+1}^p$ 的函数表达式为:

$$D_{t+1}^p = \frac{D_t^p(i)}{B_t^p} * \begin{cases} \exp(-\beta_t^p \tau_i^p), & \text{if } \operatorname{argmax}(\hat{y}_t^p(i)) = y_i^p(i) \\ \exp(\beta_t^p \tau_i^p), & \text{if } \operatorname{argmax}(\hat{y}_t^p(i)) \neq y_i^p(i) \end{cases}$$

其中, $D_t^p(i)$ 为第p个BP-Adaboost分类器中第i组测试数据集在第t轮的权重, $B_t^p$ 为第p个BP-Adaboost分类器的归一化因子, $\beta_t^p$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 的分类器权重, $\hat{y}_t^p(i)$ 为第p个BP-Adaboost分类器中基分类器 $h_t^p$ 针对第i组测试数据集中的输入特征 $x_i^p$ 预测的数字标签, $y_i^p(i)$ 为第p个BP-Adaboost分类器中第i组测试数据集中的输入特征 $x_i^p$ 对应的数字标签。

5. 根据权利要求3所述的基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法,其特征在于,步骤S6)中得到各个基分类器的相似程度矩阵 $C_t^p$ 的函数表达式为:

$$C_t^p = [c_t^p(1) \quad \cdots \quad c_t^p(k) \quad \cdots \quad c_t^p(K)]$$

其中, $c_t^p(1) \sim c_t^p(K)$ 分别为第p个BP-Adaboost分类器中第1~K种状态y对应的相似程度矩阵,其中任意第k种状态y对应的相似程度矩阵 $c_t^p(k)$ 的计算函数表达式为:

$$c_t^p(k) = \frac{\operatorname{sim}_t^p(k)}{N^p(k)}$$

其中, $N^p(k)$ 为第p个BP-Adaboost分类器中第k种状态y的样本统计数, $\operatorname{sim}_t^p$ 为余弦相似度,且余弦相似度 $\operatorname{sim}_t^p$ 的计算函数表达式为:

$$sim_t^p = \sum_{i=1}^I \frac{y_i^p(i) \cdot (\hat{y}_i^p(i))^T}{|y_i^p(i)| |\hat{y}_i^p(i)|}$$

其中, I为测试数据集的组数量,  $\hat{y}_i^p(i)$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 针对第i组测试数据集中的输入特征 $x_i^p$ 预测的数字标签,  $y_i^p(i)$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 在第i组测试数据集中的输入特征 $x_i^p$ 对应的数字标签。

所述通过注意力机制得到的注意力分配权重 $\alpha_t^p$ 时, 针对任意第k种状态y对应的注意力分配权重 $\alpha_t^p(k)$ 的计算函数表达式为:

$$\alpha_t^p(k) = \frac{\exp(c_t^p(k))}{\sum_{p=1}^P \exp(c_t^p(k))}$$

其中,  $\alpha_t^p(k)$ 表示第p个BP-Adaboost分类器中针对任意第k种状态y对应的注意力分配权重,  $c_t^p(k)$ 为第p个BP-Adaboost分类器中任意第k种状态y对应的相似程度矩阵, P为BP-Adaboost分类器的数量。

6. 根据权利要求3所述的基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法, 其特征在于, 步骤S7)中得到的BP-Adaboost线性组合输出 $H^p$ 以及输出one-hot标签矩阵 $\hat{Z}^p$ 的函数表达式为:

$$H^p = \sum_{t=1}^T \beta_t^p h_t^p(X_i^p)$$

$$\hat{Z}^p(i) = \arg \max(H^p(x^p(i)))$$

其中,  $\beta_t^p$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 的分类器权重,  $h_t^p(X_i^p)$ 为第t个基分类器 $h_t^p$ 对输入特征 $X_i^p$ 的预测结果,  $\hat{Z}^p(i)$ 为第i组测试数据集对应的输出one-hot标签矩阵, T为任意第p个BP-Adaboost分类器包括的基分类器指定数量;

所述基于注意力机制改进的最终强分类器的输出H及其输出故障标签结果 $\hat{Z}(i)$ 的函数表达式为:

$$H = \sum_{p=1}^P \alpha_t \cdot H^p(X^p) = \sum_{p=1}^P \sum_{t=1}^T \alpha_t^p \cdot \beta_t^p h_t^p(X_i^p)$$

其中,  $\alpha_t$ 为P个BP-Adaboost分类器中第t个基分类器的注意力分配权重矩阵,  $H^p(X^p)$ 为第p个BP-Adaboost分类器中次分类器对输入特征 $X^p$ 的BP-Adaboost线性组合输出,  $\alpha_t^p$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 的对应的注意力分配权重,  $\beta_t^p$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 的分类器权重,  $h_t^p(X_i^p)$ 为第t个基分类器 $h_t^p$ 对输入特征 $X_i^p$ 的预测结果, P为BP-Adaboost分类器的数量, T为任意第p个BP-Adaboost分类器包括的基分类器指定数量。

7. 根据权利要求3所述的基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法, 其特征在于, 步骤S8)包括:

S8.1) 定义任意第p个BP-Adaboost分类器的错误分类数 $n^p$ , 初始化分类器编号p为1, 初始化错误分类数 $n^p$ 的值为0, 数据编号j=1;

S8.2) 获取第 $p$ 个BP-Adaboost分类器预测的one-hot标签 $\hat{Z}_{test}^p$ ,并将预测的one-hot标签 $\hat{Z}_{test}^p$ 转换为数字标签 $\hat{Y}_{test}^p$ ,并将数字标签 $\hat{Y}_{test}^p$ 的预测值和输入的数字标签 $Y_{test}^p$ 进行对比,若数字标签 $\hat{Y}_{test}^p$ 的第 $j$ 个预测值 $\hat{y}_{test}^p(j)$ 不等于输入的数字标签 $Y_{test}^p$ 中的第 $j$ 个数字标签 $y_{test}^p(j)$ ,则将错误分类数 $n^p$ 加1,否则不修改错误分类数 $n^p$ 的值;若数据编号 $j$ 小于测试数据集的组数 $J$ ,则将数据编号 $j$ 加1,并重复执行8.2),否则执行8.3);

S8.3) 根据 $k^p = n^p / J$ 统计第 $p$ 个BP-Adaboost分类器的错误率 $k^p$ ,其中 $n^p$ 为第 $p$ 个BP-Adaboost分类器的错误分类数, $J$ 为测试数据集的组数;若分类器编号 $p$ 小于BP-Adaboost分类器的数量 $P$ ,将分类器编号 $p$ 加1,并跳转到S8.2),否则, $P$ 个BP-Adaboost分类器的错误率 $k^p$ 计算完毕,跳转执行下一步;

S8.4) 初始化基于注意力机制改进的最终强分类器的错误预测数量 $n$ 为0,数据编号 $j$ 为1;

S8.5) 获得基于注意力机制改进的最终强分类器预测的one-hot标签 $\hat{Z}_{test}$ ,预测的one-hot标签 $\hat{Z}_{test}$ 转换为数字标签 $\hat{Y}_{test}$ ,并将数字标签 $\hat{Y}_{test}$ 和输入值进行对比,若数字标签 $\hat{Y}_{test}$ 的第 $j$ 个预测值 $\hat{y}_{test}(j)$ 不等于输入的数字标签 $Y_{test}$ 中的第 $j$ 个数字标签 $y_{test}(j)$ ,则将错误预测数量 $n$ 加1,否则保持错误预测数量 $n$ 不变;若数据编号 $j$ 小于测试数据集的组数 $J$ ,则将数据编号 $j$ 加1,并重复执行S8.5),否则执行S8.6);

S8.6) 根据 $k = n / J$ 计算得到基于注意力机制改进的最终强分类器的错误率 $k$ ,其中 $n$ 为错误预测数量, $J$ 为测试数据集的组数。

8. 根据权利要求3所述的基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法,其特征在于,步骤S1)中针对被诊断电机获取 $P$ 种传感器的时域数据时,时域数据覆盖某一种传感器的多种安装位置。

9. 一种基于注意力机制改进的BP-Adaboost多源信息电机故障诊断系统,包括相互连接的微处理器和存储器,其特征在于,所述微处理器被编程或配置以执行权利要求1~8中任意一项所述基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的步骤,或者所述存储器中存储有被编程或配置以执行权利要求1~8中任意一项所述基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的计算机程序。

10. 一种计算机存储介质,其特征在于,所述计算机存储介质中存储有被编程或配置以执行权利要求1~8中任意一项所述基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的计算机程序。

## 基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法

### 技术领域

[0001] 本发明涉及电气工程及故障检测技术领域,具体涉及一种基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法。

### 背景技术

[0002] 电机系统在工业生产与民生应用中发挥着重要作用。随着电机系统朝着高度自动化、集成化和大型化的方向发展的同时,其系统结构也越来越复杂化,系统发生故障的概率增大,维护难度日益剧增。近年来,针对电机故障诊断的信号处理技术和方法得到迅速发展,通过对电机相关信号进行相应的故障特征提取,对信号故障特征进行分析和分类,从而达到故障诊断的目的。电机系统存在故障种类繁多、结构复杂以及监测困难,依靠常规的信号检测手段和故障诊断方法具有很大的局限性,单一数据来源的信息已无法满足人们对于电机故障诊断的丰富度、准确性、实时性等方面的要求,因此,多参数融合故障诊断模型和方法也开始应用于电机故障诊断。但传统的多参数融合故障诊断方法大多存在一些不足:1)电机系统通过不同检测手段采集到的故障诊断信号具有异构性质,且易受工况交变、测量位置变化等影响,不同样本之间存在一些差异,会大大降低故障诊断模型的泛化能力。2)针对不同类型的故障,不同的检测手段有着不同的灵敏度,如机械故障采用振动方法测量得到的信号数据可能更为准确,而对电气故障采取电流信号得到的诊断正确率可能会更高,而传统的故障诊断方法大多并未对相关情况进行判别。

### 发明内容

[0003] 本发明要解决的技术问题:针对现有技术的上述问题,提供一种基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法,本发明利用基于注意力机制改进的BP-Adaboost,对不同来源的数据信息进行单独学习训练,形成不同次级分类器的初步诊断,且通过注意力机制将故障诊断方法聚焦到重点测量手段信息,以此来提升信息筛选和判别的能力,并得到最终诊断结果,大大提高电机系统的故障诊断的稳定性和精度。

[0004] 为了解决上述技术问题,本发明采用的技术方案为:

[0005] 一种基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法,包括:

[0006] 1) 获取被诊断电机获取P种传感器的时域数据;

[0007] 2) 针对得到的时域数据首先进行降采样然后再通过Hilbert变换和FFT变换提取频率幅值和相位作为输入特征,最终得到P种传感器的输入特征;

[0008] 3) 将P种传感器的输入特征输入预先训练好的基于注意力机制改进的BP-Adaboost分类器得到电机的状态,所述基于注意力机制改进的BP-Adaboost分类器被预先训练建立了输入特征、电机的状态之间的映射关系。

[0009] 可选地,所述P种传感器的时域数据包括电机的三相定子电流和杂散电磁,所述电机的状态包括正常状态、转子断条状态、定子匝间短路状态以及轴承损坏故障状态。

[0010] 可选地,所述基于注意力机制改进的BP-Adaboost分类器包括P个BP-Adaboost分类器和一个基于注意力机制改进的最终强分类器,P个BP-Adaboost分类器和P种传感器一一对应,且其中任意第p个BP-Adaboost分类器包括指定数量T个基分类器 $h_1^p \sim h_T^p$ 和一个次分类器;所述基于注意力机制改进的BP-Adaboost分类器的训练步骤包括:

[0011] S1) 针对被诊断电机获取P种传感器的时域数据,时域数据覆盖任意工况x及状态y;

[0012] S2) 针对得到的时域数据首先进行降采样然后再通过Hilbert变换和FFT变换提取频率幅值和相位作为输入特征;针对P种传感器中任意传感器p对应的输入特征 $X^p$ ,分别生成数字标签 $Y^p$ 以及one-hot标签 $Z^p$ ,得到P个数据库;

[0013] S3) 针对任意工况x,从P个数据库中随机选择I组训练数据集 $(X_{train}^p, Y_{train}^p, Z_{train}^p)$ 以及J组测试数据集 $(X_{test}^p, Y_{test}^p, Z_{test}^p)$ ,其中任意第i组测试数据集为 $(x_{train}^p(i), y_{train}^p(i), z_{train}^p(i))$ ,任意第j组测试数据集为 $(x_{test}^p(j), y_{test}^p(j), z_{test}^p(j))$ ;

[0014] S4) 针对P个BP-Adaboost分类器中的任意第p个BP-Adaboost分类器:根据样本输入输出维度确定任意第p个BP-Adaboost分类器中T个基分类器 $h_1^p \sim h_T^p$ 的神经网络结构与参数,并初始化任意第i组测试数据的权重为 $D_0^p(i) = 1/I$ ,其中I为训练数据集的组数量;

[0015] S5) 针对P个BP-Adaboost分类器中的任意第p个BP-Adaboost分类器:通过测试数据集进行T轮训练其中T个基分类器 $h_1^p \sim h_T^p$ ,得到预测误差 $e_1^p \sim e_T^p$ ,根据预测误差 $e_1^p \sim e_T^p$ 分别计算T个基分类器 $h_1^p \sim h_T^p$ 的分类器权重 $\beta_1^p \sim \beta_T^p$ ;

[0016] S6) 结合P个BP-Adaboost分类器下基分类器预测的数字标签输出 $\hat{Y}_{train}^p$ ,得到各个基分类器的相似程度矩阵 $C_t^p$ ,通过注意力机制得到的注意力分配权重 $\alpha_t^p$ ;

[0017] S7) 针对经过T轮训练后P个BP-Adaboost分类器中任意第p个BP-Adaboost分类器中次分类器得到的BP-Adaboost线性组合输出 $H^p$ 以及输出one-hot标签矩阵 $\hat{Z}^p$ ,通过基于注意力机制改进的最终强分类器根据注意力分配权重 $\alpha_t^p$ 组合P个BP-Adaboost分类器的分类器 $H^p$ 得到基于注意力机制改进的最终强分类器的输出H及其输出故障标签结果 $\hat{Z}(i)$ ;

[0018] S8) 将J组测试数据集 $(X_{test}^p, Y_{test}^p, Z_{test}^p)$ 作为基于注意力机制改进的BP-Adaboost分类器的输入,将得到的预测的one-hot标签转换成数字预测结果与数字标签输出比较,统计基于注意力机制改进的BP-AdaBoost强分类器H的准确率。

[0019] 可选地,步骤S5)中通过测试数据集进行T轮训练其中T个基分类器 $h_1^p \sim h_T^p$ 时,得到第t个基分类器 $h_t^p$ 的预测误差 $e_t^p$ 的函数表达式为:

$$[0020] \quad e_t^p = \sum_i D_t^p(i) \quad (\text{if } h_t^p(x_i^p) \neq z_i^p)$$

[0021] 其中, $D_t^p(i)$ 为第p个BP-Adaboost分类器中第i组测试数据集在第t轮的权重, $h_t^p(x_i^p)$ 为基分类器 $h_t^p$ 针对输入特征 $x_i^p$ 预测的one-hot标签, $z_i^p$ 为输入特征 $x_i^p$ 对应的one-hot标签;

[0022] 所述根据预测误差  $e_1^p \sim e_t^p$  分别计算T个基分类器  $h_1^p \sim h_t^p$  的分类器权重  $\beta_1^p \sim \beta_t^p$  时,得到第t个基分类器  $h_t^p$  的分类器权重  $\beta_t^p$  的函数表达式为:

$$[0023] \quad \beta_t^p = \frac{1}{2} \ln\left(\frac{1-e_t^p}{e_t^p}\right)$$

[0024] 其中,  $e_t^p$  为第p个BP-Adaboost分类器中第t个基分类器的预测误差;

[0025] 且每一轮训练中更新第t+1轮的权重  $D_{t+1}^p$  的函数表达式为:

$$[0026] \quad D_{t+1}^p = \frac{D_t^p(i)}{B_t^p} * \begin{cases} \exp(-\beta_t^p \tau_t^p), & \text{if } \operatorname{argmax}(\hat{y}_t^p(i)) = y_t^p(i) \\ \exp(\beta_t^p \tau_t^p), & \text{if } \operatorname{argmax}(\hat{y}_t^p(i)) \neq y_t^p(i) \end{cases}$$

[0027] 其中,  $D_t^p(i)$  为第p个BP-Adaboost分类器中第i组测试数据集在第t轮的权重,  $B_t^p$  为第p个BP-Adaboost分类器的归一化因子,  $\beta_t^p$  为第p个BP-Adaboost分类器中第t个基分类器  $h_t^p$  的分类器权重,  $\hat{y}_t^p(i)$  为第p个BP-Adaboost分类器中基分类器  $h_t^p$  针对第i组测试数据集中的输入特征  $x_i^p$  预测的数字标签,  $y_t^p(i)$  为第p个BP-Adaboost分类器中第i组测试数据集中的输入特征  $x_i^p$  对应的数字标签。

[0028] 可选地,步骤S6)中得到各个基分类器的相似程度矩阵  $C_t^p$  的函数表达式为:

$$[0029] \quad C_t^p = [c_t^p(1) \quad \cdots \quad c_t^p(k) \quad \cdots \quad c_t^p(K)]$$

[0030] 其中,  $c_t^p(1) \sim c_t^p(K)$  分别为第p个BP-Adaboost分类器中第1~K种状态y对应的相似程度矩阵,其中任意第k种状态y对应的相似程度矩阵  $c_t^p(k)$  的计算函数表达式为:

$$[0031] \quad c_t^p(k) = \frac{\operatorname{sim}_t^p(k)}{N^p(k)}$$

[0032] 其中,  $N^p(k)$  为第p个BP-Adaboost分类器中第k种状态y的样本统计数,  $\operatorname{sim}_t^p$  为余弦相似度,且余弦相似度  $\operatorname{sim}_t^p$  的计算函数表达式为:

$$[0033] \quad \operatorname{sim}_t^p = \sum_{i=1}^I \frac{y_t^p(i) \cdot (\hat{y}_t^p(i))^T}{|y_t^p(i)| |\hat{y}_t^p(i)|}$$

[0034] 其中, I为测试数据集的组数量,  $\hat{y}_t^p(i)$  为第p个BP-Adaboost分类器中第t个基分类器  $h_t^p$  针对第i组测试数据集中的输入特征  $x_i^p$  预测的数字标签,  $y_t^p(i)$  为第p个BP-Adaboost分类器中第t个基分类器  $h_t^p$  在第i组测试数据集中的输入特征  $x_i^p$  对应的数字标签。

[0035] 所述通过注意力机制得到的注意力分配权重  $\alpha_t^p$  时,针对任意第k种状态y对应的注意力分配权重  $\alpha_t^p(k)$  的计算函数表达式为:

$$[0036] \quad \alpha_t^p(k) = \frac{\exp(c_t^p(k))}{\sum_{p=1}^P \exp(c_t^p(k))}$$

[0037] 其中,  $\alpha_t^p(k)$  表示第p个BP-Adaboost分类器中针对任意第k种状态y对应的注意力



分配权重,  $c_i^p(k)$  为第  $p$  个 BP-Adaboost 分类器中任意第  $k$  种状态  $y$  对应的相似程度矩阵,  $P$  为 BP-Adaboost 分类器的数量。

[0038] 可选地, 步骤 S7) 中得到的 BP-Adaboost 线性组合输出  $H^p$  以及输出 one-hot 标签矩阵  $\hat{Z}^p$  的函数表达式为:

$$[0039] \quad H^p = \sum_{t=1}^T \beta_t^p h_t^p(X_i^p)$$

$$[0040] \quad \hat{Z}^p(i) = \arg \max(H^p(x^p(i)))$$

[0041] 其中,  $\beta_t^p$  为第  $p$  个 BP-Adaboost 分类器中第  $t$  个基分类器  $h_t^p$  的分类器权重,  $h_t^p(X_i^p)$  为第  $t$  个基分类器  $h_t^p$  对输入特征  $X_i^p$  的预测结果,  $\hat{Z}^p(i)$  为第  $i$  组测试数据集对应的输出 one-hot 标签矩阵,  $T$  为任意第  $p$  个 BP-Adaboost 分类器包括的基分类器指定数量;

[0042] 所述基于注意力机制改进的最终强分类器的输出  $H$  及其输出故障标签结果  $\hat{Z}(i)$  的函数表达式为:

$$[0043] \quad H = \sum_{p=1}^P \alpha_t^p \cdot H^p(X^p) = \sum_{p=1}^P \sum_{t=1}^T \alpha_t^p \cdot \beta_t^p h_t^p(X_i^p)$$

[0044] 其中,  $\alpha_t^p$  为  $P$  个 BP-Adaboost 分类器中第  $t$  个基分类器的注意力分配权重矩阵,  $H^p(X^p)$  为第  $p$  个 BP-Adaboost 分类器中次分类器对输入特征  $X^p$  的 BP-Adaboost 线性组合输出,  $\alpha_t^p$  为第  $p$  个 BP-Adaboost 分类器中第  $t$  个基分类器  $h_t^p$  的对应的注意力分配权重,  $\beta_t^p$  为第  $p$  个 BP-Adaboost 分类器中第  $t$  个基分类器  $h_t^p$  的分类器权重,  $h_t^p(X_i^p)$  为第  $t$  个基分类器  $h_t^p$  对输入特征  $X_i^p$  的预测结果,  $P$  为 BP-Adaboost 分类器的数量,  $T$  为任意第  $p$  个 BP-Adaboost 分类器包括的基分类器指定数量。

[0045] 可选地, 步骤 S8) 包括:

[0046] S8.1) 定义任意第  $p$  个 BP-Adaboost 分类器的错误分类数  $n^p$ , 初始化分类器编号  $p$  为 1, 初始化错误分类数  $n^p$  的值为 0, 数据编号  $j=1$ ;

[0047] S8.2) 获取第  $p$  个 BP-Adaboost 分类器预测的 one-hot 标签  $\hat{Z}_{test}^p$ , 并将预测的 one-hot 标签  $\hat{Z}_{test}^p$  转换为数字标签  $\hat{Y}_{test}^p$ , 并将数字标签  $\hat{Y}_{test}^p$  的预测值和输入的数字标签  $Y_{test}^p$  进行对比, 若数字标签  $\hat{Y}_{test}^p$  的第  $j$  个预测值  $\hat{y}_{test}^p(j)$  不等于输入的数字标签  $Y_{test}^p$  中的第  $j$  个数字标签  $y_{test}^p(j)$ , 则将错误分类数  $n^p$  加 1 否则不修改错误分类数  $n^p$  的值; 若数据编号  $j$  小于测试数据集的组数  $J$ , 则将数据编号  $j$  加 1, 并重复执行 8.2), 否则执行 8.3);

[0048] S8.3) 根据  $k^p = n^p / J$  统计第  $p$  个 BP-Adaboost 分类器的错误率  $k^p$ , 其中  $n^p$  为第  $p$  个 BP-Adaboost 分类器的错误分类数,  $J$  为测试数据集的组数; 若分类器编号  $p$  小于 BP-Adaboost 分类器的数量  $P$ , 将分类器编号  $p$  加 1, 并跳转到 S8.2), 否则,  $P$  个 BP-Adaboost 分类器的错误率  $k^p$  计算完毕, 跳转执行下一步;

[0049] S8.4) 初始化基于注意力机制改进的最终强分类器的错误预测数量  $n$  为 0, 数据编号  $j$  为 1;

[0050] S8.5) 获得基于注意力机制改进的最终强分类器预测的 one-hot 标签  $\hat{Z}_{test}$ , 预测的

one-hot标签 $\hat{Z}_{test}$ 转换为数字标签 $\hat{Y}_{test}$ ,并将数字标签 $\hat{Y}_{test}$ 和输入值进行对比,若数字标签 $\hat{Y}_{test}$ 的第j个预测值 $\hat{y}_{test}(j)$ 不等于输入的数字标签 $Y_{test}$ 中的第j个数字标签 $y_{test}(j)$ ,则将错误预测数量n加1,否则保持错误预测数量n不变;若数据编号j小于测试数据集的组数J,则将数据编号j加1,并重复执行S8.5),否则执行S8.6);

[0051] S8.6) 根据 $k=n/J$ 计算得到基于注意力机制改进的最终强分类器的错误率k,其中n为错误预测数量,J为测试数据集的组数。

[0052] 可选地,步骤S1)中针对被诊断电机获取P种传感器的时域数据时,时域数据覆盖某一种传感器的多种安装位置。

[0053] 此外,本发明还提供一种基于注意力机制改进的BP-Adaboost多源信息电机故障诊断系统,包括相互连接的微处理器和存储器,所述微处理器被编程或配置以执行前述基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的步骤,或者所述存储器中存储有被编程或配置以执行前述基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的计算机程序。

[0054] 此外,本发明还提供一种计算机存储介质,所述计算机存储介质中存储有被编程或配置以执行前述基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的计算机程序。

[0055] 和现有技术相比,本发明具有下述优点:

[0056] 1、本发明通过利用多源信息进行故障检测,研究一种改进BP-Adaboost多分类模型,引入one-hot向量,在向量化的基础上改进传统Adaboost结构算法。对不同来源的数据信息进行单独学习训练,形成不同的次级分类器,减少采用高级学习模型的复杂度,节约网络训练的资源,提高故障诊断模型的泛化能力。

[0057] 2、针对不同类型的故障,不同的检测手段有着不同的灵敏度,提出了基于注意力机制的异构信息Adaboost次级分类器动态加权融合以提高数据重建能力和鲁棒性。通过将注意力聚焦到重点测量手段信息来提升信息获取的能力,大大提高电机系统的故障诊断的稳定性和精度。

## 附图说明

[0058] 图1为本发明实施例方法的基本流程示意图。

[0059] 图2为本发明实施例中提取输入特征的原理示意图。

[0060] 图3为本发明实施例中的基本训练流程示意图。

[0061] 图4为本发明实施例中的基于注意力机制改进的BP-Adaboost分类器训练流程图。

[0062] 图5为本发明实施例中的BP-Adaboost分类器训练部分的流程示意图。

[0063] 图6为本发明实施例中的注意力机制的流程图。

[0064] 图7为本发明实施例中的训练数据精确度统计流程图。

[0065] 图8为本发明实施例中的电流、磁通测量原理图。

## 具体实施方式

[0066] 下面结合实施例对本发明做进一步说明,但不应该理解为本发明上述主题范围仅

限于下述实施例。在不脱离本发明上述思想的情况下,根据本领域普通知识和惯用手段,做出各种替换和变更,均应包括在本发明的保护范围内。

[0067] 如图1,本实施例基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法包括:

[0068] 1) 获取被诊断电机获取P种传感器的时域数据;

[0069] 2) 参见图2,针对得到的时域数据首先进行降采样然后再通过Hilbert变换和FFT变换提取频率幅值和相位作为输入特征,最终得到P种传感器的输入特征;

[0070] 3) 将P种传感器的输入特征输入预先训练好的基于注意力机制改进的BP-Adaboost分类器得到电机的状态,基于注意力机制改进的BP-Adaboost分类器被预先训练建立了输入特征、电机的状态之间的映射关系。

[0071] 本实施例中,基于注意力机制改进的BP-Adaboost分类器可实现多种工况x下任意多种传感器数据(多源信息)与电机的多种状态y之间的映射,P种传感器的时域数据包含但不限于电流、电磁、振动、热成像以及超声波等手段采集的数据,状态y包含但不限于正常状态、转子断条状态、定子匝间短路状态、以及轴承损坏故障状态;工况x包括空载工况、半载工况以及满载工况。作为一种特定的实施方式举例,本实施例中,P种传感器的时域数据包括电机的三相定子电流和杂散电磁,电机的状态包括正常状态、转子断条状态、定子匝间短路状态以及轴承损坏故障状态。

[0072] 如图3和图4所示,基于注意力机制改进的BP-Adaboost分类器包括P个BP-Adaboost分类器和一个基于注意力机制改进的最终强分类器,P个BP-Adaboost分类器和P种传感器一一对应,且其中任意第p个BP-Adaboost分类器包括指定数量T个基分类器 $h_1^p \sim h_T^p$ 和一个次分类器;基于注意力机制改进的BP-Adaboost分类器的训练步骤包括:

[0073] S1) 针对被诊断电机获取P种传感器的时域数据,时域数据覆盖任意工况x及状态y;

[0074] S2) 针对得到的时域数据首先进行降采样然后再通过Hilbert变换和FFT变换提取频率幅值 $A_x^y$ 和相位 $f_x^y$ 作为输入特征;针对P种传感器中任意传感器p对应的输入特征 $X^p$ ,分别生成数字标签 $Y^p$ 以及one-hot标签 $Z^p$ ,得到P个数据库;

[0075] S3) 针对任意工况x,从P个数据库中随机选择I组训练数据集 $(X_{train}^p, Y_{train}^p, Z_{train}^p)$ 以及J组测试数据集 $(X_{test}^p, Y_{test}^p, Z_{test}^p)$ ,其中任意第i组测试数据集为 $(x_{train}^p(i), y_{train}^p(i), z_{train}^p(i))$ ,任意第j组测试数据集为 $(x_{test}^p(j), y_{test}^p(j), z_{test}^p(j))$ ;

[0076] S4) 针对P个BP-Adaboost分类器中的任意第p个BP-Adaboost分类器:根据样本输入输出维度确定任意第p个BP-Adaboost分类器中T个基分类器 $h_1^p \sim h_T^p$ 的神经网络结构与参数,并初始化任意第i组测试数据的权重为 $D_0^p(i) = 1/I$ ,其中I为训练数据集的组数量;

[0077] S5) 针对P个BP-Adaboost分类器中的任意第p个BP-Adaboost分类器:通过测试数据集进行T轮训练其中T个基分类器 $h_1^p \sim h_T^p$ ,得到预测误差 $e_1^p \sim e_T^p$ ,根据预测误差 $e_1^p \sim e_T^p$ 分别计算T个基分类器 $h_1^p \sim h_T^p$ 的分类器权重 $\beta_1^p \sim \beta_T^p$ ;

[0078] S6) 结合P个BP-Adaboost分类器下基分类器预测的数字标签输出 $\hat{Y}_{train}^p$ ,得到各个

基分类器的相似程度矩阵 $C_i^p$ ,通过注意力机制得到的注意力分配权重 $\alpha_i^p$ ;

[0079] S7) 针对经过T轮训练后P个BP-Adaboost分类器中任意第p个BP-Adaboost分类器中次分类器得到的BP-Adaboost线性组合输出 $H^p$ 以及输出one-hot标签矩阵 $\hat{Z}^p$ ,通过基于注意力机制改进的最终强分类器根据注意力分配权重 $\alpha_i^p$ 组合P个BP-Adaboost分类器的分类器 $H^p$ 得到基于注意力机制改进的最终强分类器的输出H及其输出故障标签结果 $\hat{Z}(i)$ ;

[0080] S8) 将J组测试数据集 $(X_{test}^p, Y_{test}^p, Z_{test}^p)$ 作为基于注意力机制改进的BP-Adaboost分类器的输入,将得到的预测的one-hot标签转换成数字预测结果与数字标签输出比较,统计基于注意力机制改进的BP-AdaBoost强分类器H的准确率。

[0081] 本实施例中,步骤S2)中包括:

[0082] S2.1) 获取状态y电机 $M_y$ 在工况x对应的多源数据,且将电机状态变量y为1~4分别对应正常状态、转子断条状态、定子匝间短路状态、以及轴承损坏故障状态,分别获得对应的四类时域数据集;

[0083] S2.2) 针对每类数据集进行希尔伯特黄变换以及傅里叶变换,得到电机 $M_y$ 在工况x下,对应状态y的频域特征信息矩阵 $F_x^y$ 。将电机状态以数字1,2,3,4表示,得到与矩阵所指示电机状态对应的数字标签矩阵 $L_x^y$ ;

[0084] S2.3) 引入多分类故障one-hot向量空间模型对故障类型进行描述,对应数字标签矩阵 $L_x^y$ ,one-hot向量标签表示 $O_x^y$ 为一个 $R^K \times 1$ 的向量,该故障分类在映射表中索引的位置是1,其他位置都是0,K是映射表的大小,K=4。

[0085] 其中 $O_x^y(n)$ 对应状态n下的one-hot向量标签矩阵如下所示:

$$[0086] \quad O_x^y(1) = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \quad O_x^y(2) = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix}, \quad O_x^y(3) = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix}, \quad O_x^y(4) = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix}$$

[0087] S2.4) 将状态y下的特征矩阵 $F_x^y$ ,对应其标签矩阵 $L_x^y$ 和one-hot标签矩阵 $O_x^y$ ,生成多类来源数据总样本特征矩阵 $X^p = \{F_x^1, F_x^2, F_x^3, F_x^4\}$ ,数字标签矩阵 $Y^p = \{L_x^1, L_x^2, L_x^3, L_x^4\}$ ,one-hot标签矩阵 $Z^p = \{O_x^1, O_x^2, O_x^3, O_x^4\}$ ,其中, $x \in (0, 1, 2)$ , $p \in (1, P)$ 。可知各个矩阵中依次包含y=1,2,3,4四种状态数据,并包含了x=0,1,2三种电机工况。

[0088] 本实施例中,步骤S5)中通过测试数据集进行T轮训练其中T个基分类器 $h_1^p \sim h_T^p$ 时,得到第t个基分类器 $h_t^p$ 的预测误差 $e_t^p$ 的函数表达式为:

$$[0089] \quad e_t^p = \sum_i D_i^p(i) \quad (\text{if } h_t^p(x_i^p) \neq z_i^p)$$

[0090] 其中, $D_i^p(i)$ 为第p个BP-Adaboost分类器中第i组测试数据集在第t轮的权重, $h_t^p(x_i^p)$ 为基分类器 $h_t^p$ 针对输入特征 $x_i^p$ 预测的one-hot标签, $z_i^p$ 为输入特征 $x_i^p$ 对应的one-hot标签;

[0091] 根据预测误差  $e_t^p \sim e_t^p$  分别计算T个基分类器  $h_t^p \sim h_t^p$  的分类器权重  $\beta_t^p \sim \beta_t^p$  时,得到第t个基分类器  $h_t^p$  的分类器权重  $\beta_t^p$  的函数表达式为:

$$[0092] \quad \beta_t^p = \frac{1}{2} \ln\left(\frac{1-e_t^p}{e_t^p}\right)$$

[0093] 其中,  $e_t^p$  为第p个BP-Adaboost分类器中第t个基分类器的预测误差;

[0094] 且每一轮训练中更新第t+1轮的权重  $D_{t+1}^p$  的函数表达式为:

$$[0095] \quad D_{t+1}^p = \frac{D_t^p(i)}{B_t^p} * \begin{cases} \exp(-\beta_t^p \tau_t^p), & \text{if } \operatorname{argmax}(\hat{y}_t^p(i)) = y_t^p(i) \\ \exp(\beta_t^p \tau_t^p), & \text{if } \operatorname{argmax}(\hat{y}_t^p(i)) \neq y_t^p(i) \end{cases}$$

[0096] 其中,  $D_t^p(i)$  为第p个BP-Adaboost分类器中第i组测试数据集在第t轮的权重,  $B_t^p$  为第p个BP-Adaboost分类器的归一化因子,  $\beta_t^p$  为第p个BP-Adaboost分类器中第t个基分类器  $h_t^p$  的分类器权重,  $\hat{y}_t^p(i)$  为第p个BP-Adaboost分类器中基分类器  $h_t^p$  针对第i组测试数据集中的输入特征  $x_i^p$  预测的数字标签,  $y_t^p(i)$  为第p个BP-Adaboost分类器中第i组测试数据集中的输入特征  $x_i^p$  对应的数字标签。

[0097] 如图5所示,步骤S5)中BP-Adaboost分类器的训练流程包括:将训练数据集  $(X_{train}^p, Y_{train}^p, Z_{train}^p)$  平均分为T组子训练数据集  $(X_t^p, Y_t^p, Z_t^p)$  作为T个弱分类器的输入,其中  $t \in (1, T)$ 。作为基分类器输入进行训练,并依次得到T个弱分类器的预测结果  $\hat{Z}_t^p$ 。根据测试数据的分布权值,得到第t个基分类器的预测误差  $e_t^p$  以及分类器权重  $\beta_t^p$ 。注意,测试数据分布权值  $D_0^p$  已在步骤S4)中初始化,  $D_0^p(i) = 1/I$ 。5.3)更新训练数据权重  $D_{t+1}^p$ ,若  $t < T$ ,则进行更新,其中  $B_t^p$  归一化因子,并使  $t = t+1$ ,跳到步骤5.2)对  $e_t^p$ 、 $\beta_t^p$  进行更新;若  $t = T$ ,则全部权重  $D_t^p$ 、 $e_t^p$ 、 $\beta_t^p$  迭代完毕。

[0098] 参见图6,本实施例步骤S6)中得到各个基分类器的相似程度矩阵  $C_t^p$  的函数表达式为:

$$[0099] \quad C_t^p = [c_t^p(1) \quad \cdots \quad c_t^p(k) \quad \cdots \quad c_t^p(K)]$$

[0100] 其中,  $c_t^p(1) \sim c_t^p(K)$  分别为第p个BP-Adaboost分类器中第1~K种状态y对应的相似程度矩阵,其中任意第k种状态y对应的相似程度矩阵  $c_t^p(k)$  的计算函数表达式为:

$$[0101] \quad c_t^p(k) = \frac{\operatorname{sim}_t^p(k)}{N^p(k)}$$

[0102] 其中,  $N^p(k)$  为第p个BP-Adaboost分类器中第k种状态y的样本统计数,  $\operatorname{sim}_t^p$  为余弦相似度,且余弦相似度  $\operatorname{sim}_t^p$  的计算函数表达式为:

$$[0103] \quad \operatorname{sim}_t^p = \sum_{i=1}^I \frac{y_t^p(i) \cdot (\hat{y}_t^p(i))^T}{|y_t^p(i)| |\hat{y}_t^p(i)|}$$

[0104] 其中, I为测试数据集的组数量,  $\hat{y}_t^p(i)$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 针对第i组测试数据集中的输入特征 $x_i^p$ 预测的数字标签,  $y_t^p(i)$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 在第i组测试数据集中的输入特征 $x_i^p$ 对应的数字标签。

[0105] 通过注意力机制得到的注意力分配权重 $\alpha_t^p$ 时, 针对任意第k种状态y对应的注意力分配权重 $\alpha_t^p(k)$ 的计算函数表达式为:

$$[0106] \quad \alpha_t^p(k) = \frac{\exp(c_t^p(k))}{\sum_{p=1}^P \exp(c_t^p(k))}$$

[0107] 其中,  $\alpha_t^p(k)$ 表示第p个BP-Adaboost分类器中针对任意第k种状态y对应的注意力分配权重,  $c_t^p(k)$ 为第p个BP-Adaboost分类器中任意第k种状态y对应的相似程度矩阵, P为BP-Adaboost分类器的数量。

[0108] 本实施例中, 步骤S7)中得到的BP-Adaboost线性组合输出 $H^p$ 以及输出one-hot标签矩阵 $\hat{Z}^p$ 的函数表达式为:

$$[0109] \quad H^p = \sum_{t=1}^T \beta_t^p h_t^p(X_t^p)$$

$$[0110] \quad \hat{Z}^p(i) = \arg \max(H^p(x^p(i)))$$

[0111] 其中,  $\beta_t^p$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 的分类器权重,  $h_t^p(X_t^p)$ 为第t个基分类器 $h_t^p$ 对输入特征 $X_t^p$ 的预测结果,  $\hat{Z}^p(i)$ 为第i组测试数据集对应的输出one-hot标签矩阵, T为任意第p个BP-Adaboost分类器包括的基分类器指定数量;

[0112] 基于注意力机制改进的最终强分类器的输出H及其输出故障标签结果 $\hat{Z}(i)$ 的函数表达式为:

$$[0113] \quad H = \sum_{p=1}^P \alpha_t^p \cdot H^p(X^p) = \sum_{p=1}^P \sum_{t=1}^T \alpha_t^p \cdot \beta_t^p h_t^p(X_t^p)$$

[0114] 其中,  $\alpha_t^p$ 为P个BP-Adaboost分类器中第t个基分类器的注意力分配权重矩阵,  $H^p(X^p)$ 为第p个BP-Adaboost分类器中次分类器对输入特征 $X^p$ 的BP-Adaboost线性组合输出,  $\alpha_t^p$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 的对应的注意力分配权重,  $\beta_t^p$ 为第p个BP-Adaboost分类器中第t个基分类器 $h_t^p$ 的分类器权重,  $h_t^p(X_t^p)$ 为第t个基分类器 $h_t^p$ 对输入特征 $X_t^p$ 的预测结果, P为BP-Adaboost分类器的数量, T为任意第p个BP-Adaboost分类器包括的基分类器指定数量。

[0115] 如图7所示, 本实施例中步骤S8)包括:

[0116] S8.1) 定义任意第p个BP-Adaboost分类器的错误分类数 $n^p$ , 初始化分类器编号p为1, 初始化错误分类数 $n^p$ 的值为0, 数据编号j=1;

[0117] S8.2) 获取第p个BP-Adaboost分类器预测的one-hot标签 $\hat{Z}_{test}^p$ , 并将预测的one-hot标签 $\hat{Z}_{test}^p$ 转换为数字标签 $\hat{Y}_{test}^p$ , 并将数字标签 $\hat{Y}_{test}^p$ 的预测值和输入的数字标签 $Y_{test}^p$ 进行对比, 若数字标签 $\hat{Y}_{test}^p$ 的第j个预测值 $\hat{y}_{test}^p(j)$ 不等于输入的数字标签 $Y_{test}^p$ 中的第j个数字标签 $y_{test}^p(j)$ ,

则将错误分类数 $n^p$ 加1否则不修改错误分类数 $n^p$ 的值;若数据编号 $j$ 小于测试数据集的组数 $J$ ,则将数据编号 $j$ 加1,并重复执行8.2),否则执行8.3);

[0118] S8.3) 根据 $k^p = n^p / J$ 统计第 $p$ 个BP-Adaboost分类器的错误率 $k^p$ ,其中 $n^p$ 为第 $p$ 个BP-Adaboost分类器的错误分类数, $J$ 为测试数据集的组数;若分类器编号 $p$ 小于BP-Adaboost分类器的数量 $P$ ,将分类器编号 $p$ 加1,并跳转到S8.2),否则, $P$ 个BP-Adaboost分类器的错误率 $k^p$ 计算完毕,跳转执行下一步;

[0119] S8.4) 初始化基于注意力机制改进的最终强分类器的错误预测数量 $n$ 为0,数据编号 $j$ 为1;

[0120] S8.5) 获得基于注意力机制改进的最终强分类器预测的one-hot标签 $\hat{Z}_{test}$ ,预测的one-hot标签 $\hat{Z}_{test}$ 转换为数字标签 $\hat{Y}_{test}$ ,并将数字标签 $\hat{Y}_{test}$ 和输入值进行对比,若数字标签 $\hat{Y}_{test}$ 的第 $j$ 个预测值 $\hat{y}_{test}(j)$ 不等于输入的数字标签 $Y_{test}$ 中的第 $j$ 个数字标签 $y_{test}(j)$ ,则将错误预测数量 $n$ 加1,否则保持错误预测数量 $n$ 不变;若数据编号 $j$ 小于测试数据集的组数 $J$ ,则将数据编号 $j$ 加1,并重复执行S8.5),否则执行S8.6);

[0121] S8.6) 根据 $k = n / J$ 计算得到基于注意力机制改进的最终强分类器的错误率 $k$ ,其中 $n$ 为错误预测数量, $J$ 为测试数据集的组数。

[0122] 本实施例中,步骤S1)中针对被诊断电机获取 $P$ 种传感器的时域数据时,时域数据覆盖某一种传感器的多种安装位置,从而可以适应于某一种传感器的多种安装位置的故障诊断,提高本实施例方法的通用性。

[0123] 作为一种可选的实施方式,步骤S1)中的多源数据采集对象以及安装位置包括:对于电流测量,分别使用三个霍尔电流传感器获取电机定子电流;对于电磁测量,使用磁场测量线圈,对电机径向杂散磁通进行检测,其中,探头安装角度 $\alpha$ 为 $45^\circ$ ;对于振动数据采集,采用三轴压电式加速度传感器,对在电机主体上轴向安装。对于热成像采集,采用热成像仪获取电机主体径向或轴向发热分布图象。对于超声波数据采集,采用超声检测仪检测电机径向超声信号。作为一种可选的实施方式,对于共 $P$ 类的多源数据,为得到与之对应的BP-Adaboost分类器以及最终的多源数据融合分类器,对于每种数据源样本,都需要进行步骤5)~步骤9),进行 $P$ 次,其中,各个分类器相关参数由训练数据集得到,验证部分由测试数据集完成。作为一种可选的实施方式, $K$ 个基分类器以及强分类器的输入数字标签以及one-hot标签需要保持一致,即:  $Y_{train}^1 = Y_{train}^2 = \dots = Y_{train}^P$ ,  $Z_{train}^1 = Z_{train}^2 = \dots = Z_{train}^P$ ,

$$Y_{test}^1 = Y_{test}^2 = \dots = Y_{test}^P, \quad Z_{test}^1 = Z_{test}^2 = \dots = Z_{test}^P。$$

[0124] 本实施例诊断对象为异步感应电机,针对电机 $M_y$ 通过查阅电机铭牌及相关资料,可确定异步感应电机型号及电机参数。各种电机状态 $y$ 包括正常状态、转子断条状态、定子匝间短路状态、以及轴承损坏故障状态。工况 $x$ 取值1、2、3分别表示工作在空载、半载以及满载工况下;电机状态 $y$ 取值1、2、3、4分别表示电机正常状态、转子断条、定子匝间短路、以及轴承损坏故障。 $P$ 种数据来源有两类包含三相定子电流、径向杂散电磁数据;其中,径向杂散电磁数据测量点 $z$ 分别取值1、2、3来代表电机前端、中端、后端三个位置。所以在本实例中,采样的时域原始数据共来源于 $3*4*3=36$ 种情况,在每种情况下,都获取了同步的电流、电磁数据,均为 $10000004*1$ 的矩阵。

[0125] 步骤S2)中针对x工况y状态电机的原始电流或电磁时域信号数据,去趋势项并将其归一化,并对处理后时域数据进行降采样,减少冗余数据以减轻训练计算负担,并将大数据样本分成小样本组,本实例中数据样本组 $c=125$ ,每个样本组内包含的样本数据点 $N=8000$ ;将每个样本组的数据前后进行Hilbert变换,傅里叶变换,将前500个点作为预处理后的输入特征,将S1)中所述36种情况下的原始时域信息,均按2.1)进行处理,得到36种情况下的电流、电磁输入特征矩阵,维度均为 $125*500$ ;由于故障诊断需要分类的是电机状态y,将36种情况下来源于同一状态的特征矩阵整合到同一矩阵中,每种状态包含对应9种情况,故每类状态矩阵维度为 $1125*500$ ;针对状态 $y=1,2,3,4$ ,创建与之对应的维度为 $1125*1$ 的标签矩阵 $Y_y$ ,矩阵内的元素与状态对应,全部都为1、2、3、4;引入one-hot向量,创建与之对应的维度为 $1125*4$ 的标签矩阵 $Z_y$ ,矩阵内的每行元素都是相同的,与状态对应,依次分别为:

$$[0126] \quad O_x^y(1) = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \quad O_x^y(2) = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix}, \quad O_x^y(3) = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix}, \quad O_x^y(4) = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix}$$

[0127] 针对电流、电磁信号,将输入特征矩阵和标签矩阵、one-hot标签矩阵按对应顺序整合为包含所有状态的输入特征矩阵 $X^p$  ( $4500*500$ ) 和标签矩阵 $Y^p$  ( $4500*1$ )、one-hot标签矩阵 $Z^p$  ( $4500*4$ )。

[0128] 步骤S3)中从以上矩阵中随机选择 $I=3200$ 组作为训练数据,分别为: $X_{train}^p$  ( $3200*500$ ),  $Y_{train}^p$  ( $3200*1$ ),  $Z_{train}^p$  ( $3200*4$ ); $J=250$ 组作为测试数据,分别为: $X_{test}^p$  ( $250*500$ ),  $Y_{test}^p$  ( $250*1$ ),  $Z_{test}^p$  ( $250*4$ ),其中 $p=1,2$ ,分别表示电流信号和电磁信号,至此,生成了训练数据集,以及测试数据集。

[0129] 步骤S4)BP-Adaboost的基分类器为BP神经网络,针对每类数据库,各构造T个基分类器 $H_t$ ,本例中 $T=5$ , $t \in (1,5)$ ,采取的基分类器为BP神经网络,采取单隐层结构,根据样本输入输出维度确定BP神经网络结构与参数,每层结点数为512-32-4,并初始化训练数据的分布权值 $D_0^p(i)=1/I=1/3200$ 。

[0130] 步骤S5)将电流、电磁训练数据集( $X_{train}^p, Y_{train}^p, Z_{train}^p$ )分别作为两类BP-AdaBoost基分类器的输入,依次训练5个基分类器 $h_t^p(X_{train}^p)$ ,得到训练数据的预测输出 $\hat{Z}_{train}^p$ ,并根据 $D_t^p$ 得到预测误差 $e_t^p$ ,基分类器的权重 $\beta_t^p$ ,进而调整下一轮训练样本权重 $D_{t+1}^p$ ,再得到下一轮的 $e_{t+1}^p$ 、 $\beta_{t+1}^p$ ,直到5个基分类器相关参数都完成迭代,具体流程可参考图5。

[0131] 步骤S5)通过BP神经网络基分类器,将I组训练数据集( $X_{train}^p, Z_{train}^p$ )作为基分类器输入进行训练,并依次得到5个弱分类器的预测结果 $\hat{Z}_t^p$ 。根据训练数据的分布权值 $D_0^p=1/3200$ ,得到第t个基分类器的预测误差 $e_t^p$ 以及分类器权重 $\beta_t^p$ 。本实施例中, $D_t^p$ 为训练数据权重,维度为 $6*3200$ ;  $e_t^p$ 为基分类器的预测误差,维度为 $1*5$ ,  $\beta_t^p$ 为分类器权重,维度为 $1*5$ 。针对电流、电磁信号的5个基分类器的相关参数 $D_t^p$ 、 $e_t^p$ 、 $\beta_t^p$ 如下表所示。



[0132] 表1:电流、电磁信号的训练数据权重 $D_i^p$ 。

[0133]	电流 $D^1$	$D_0^1$	0.0003125	0.0003125	0.0003125	0.0003125	0.0003125	...
		$D_1^1$	0.00037594	0.00014302	0.0002038	0.0002	0.0001842	...
		$D_2^1$	0.0003804	9.77E-05	0.0001356	0.0001678	0.0001264	...
		$D_3^1$	0.00059745	7.26E-05	8.48E-05	0.0001274	9.07E-05	...
		$D_4^1$	0.00056307	6.04E-05	7.15E-05	0.0001105	7.68E-05	...
		$D_5^1$	0.00049479	4.17E-05	4.66E-05	8.41E-05	5.94E-05	...
电磁 $D^2$	$D_{20}$	0.0003125	0.0003125	0.0003125	0.0003125	0.0003125	...	
	$D_{21}$	0.00030448	0.00022508	0.0001889	0.0003105	0.0007369	...	
[0134]		$D_{22}$	0.00023456	0.00014113	0.0001437	0.0005782	0.0012104	...
		$D_{23}$	0.00020904	0.00011229	0.0001176	0.0005274	0.001127	...
		$D_{24}$	0.00030849	7.80E-05	8.21E-05	0.0004535	0.0009346	...
		$D_{25}$	0.00023146	5.21E-05	5.46E-05	0.0003716	0.001403	...

[0135] 表2:基分类器的预测误差 $e^p$ 。

[0136]		$e_{p1}$	$e_{p2}$	$e_{p3}$	$e_{p4}$	$e_{p5}$
	电流 $e^1$	0.0528125	0.19658061	0.2383717	0.38114035	0.27998218
	电磁 $e^2$	0.1165625	0.19524335	0.3324588	0.25529797	0.22599427

[0137] 表3:基分类器的预测误差 $\beta^p$

[0138]		$\beta_{p1}$	$\beta_{p2}$	$\beta_{p3}$	$\beta_{p4}$	$\beta_{p5}$
	电流 $\beta^1$	0.41925405	0.204461	0.1687077	0.07039648	0.13718075
	电磁 $\beta^2$	0.31448277	0.21990786	0.1082364	0.16622474	0.19114819

[0139] 步骤S6) 结合电流、电磁测量方式下的基分类器训练数据输出,得到各个分类器的相似程度矩阵 $C_i^p$ ,通过注意力机制得到的注意力分配权重 $\alpha_i^p$ 向量,具体流程可参考图6。步骤S6) 获取3200组训练样本的基分类器输入标签矩阵 $Y_t^p$ ,以及5个基分类器产生的预测输出标签 $\hat{Y}_i^p$ 。输入标签矩阵,以及预测输出标签如下表所示。

[0140] 表4:电流、电磁信号的输入标签和预测标签矩阵。

样本组编号		1	2	3	4	5	...		
[0141]	电流 p=1	输入标签	1	4	3	3	3	...	
		预测 标签	$\hat{Y}_1^1$	1	4	3	3	3	...
			$\hat{Y}_2^1$	1	4	3	3	3	...
			$\hat{Y}_3^1$	2	4	3	3	3	...
			$\hat{Y}_4^1$	1	4	3	3	3	...
			$\hat{Y}_5^1$	1	4	3	3	3	...
[0142]	电磁 p=2	输入标签	1	4	3	3	3	...	
		预测 标签	$\hat{Y}_1^2$	1	4	3	3	1	...
			$\hat{Y}_2^2$	1	4	3	1	1	...
			$\hat{Y}_3^2$	1	4	3	3	3	...
			$\hat{Y}_4^2$	3	4	3	3	3	...
			$\hat{Y}_5^2$	1	4	3	3	1	...

[0143] 最终得到的注意力分配权重 $\alpha_i^p$ 如下表所示。

[0144] 表5: 电流、电磁信号的注意力分配权重 $\alpha_i^p$ 的标签矩阵。

[0145]	电 流	y	$\alpha_1^1$	$\alpha_2^1$	$\alpha_3^1$	$\alpha_4^1$	$\alpha_5^1$
		1	0.600309	0.497431	0.553905	0.449132	0.463156
		2	0.635673	0.49545	0.564482	0.436273	0.46799
		3	0.627835	0.517723	0.565892	0.43393	0.472714
		4	0.574181	0.499893	0.547434	0.435186	0.471156
[0145]	电 磁	y	$\alpha_1^2$	$\alpha_2^2$	$\alpha_3^2$	$\alpha_4^2$	$\alpha_5^2$
		1	0.399691	0.502569	0.446095	0.550868	0.536844
		2	0.364327	0.50455	0.435518	0.563727	0.53201
		3	0.372165	0.482277	0.434108	0.56607	0.527286
		4	0.425819	0.500107	0.452566	0.564814	0.528844

[0146] 步骤S7) 得到分类器各个权重参数分配后, 将J=250组训练数据作为输入, 经过5轮训练后得到5组基分类器 $h_i^p(X_i^p)$ , 由5组基分类器得到该测量手段下的次分类函数 $H^p(X^p)$ , 以及输出标签类型 $\hat{Y}^p(i)$ , 融合P=2种测量手段的次分类器组合得到最终强分类器

$H(X)=\sum_{p=1,t=1}^{P=2,T=5} \alpha_t^p \cdot h_t^p(X^p)$ , 及其输出故障标签结果  $\hat{Y}(i)$ , 如图4所示; 下表分别为电流BP-AdaBoost、电磁BP-AdaBoost、基于注意力机制的多源融合BP-AdaBoost分类器的输出以及预测结果, 其中输出由4\*1向量组成, 可以转化为one-hot标签形式, 预测结果将其转换成与y相对应的数字。

[0147] 表6: 电流、电磁、改进BP-AdaBoost预测结果及标签。

样本组编号		1	2	3	4	5	...
[0148]	$\hat{Z}^1$	0.61634	1.08271	0.34991	-0.187	0.84001	...
		0.0082	-0.0542	0.04742	0.96152	0.08424	...
		-0.1345	-0.0443	-0.0418	0.05982	-0.0161	...
		0.29995	-0.0249	0.72473	0.13267	0.08025	...
	$\hat{Y}^1$	1	1	4	2	1	...
	$\hat{Z}^2$	1.00154	0.86417	0.12229	0.10719	0.77543	...
-0.0379		-0.0887	-0.0602	0.90149	-0.0871	...	

[0149]	$\hat{Y}^2$	0.01973	0.18876	0.06387	-0.0177	0.13099	...
		0.08671	-0.1975	0.98756	0.02135	0.13688	...
	$\hat{Y}^2$	1	1	4	2	1	...
	$\hat{Z}$	0.8104	1.00371	0.2557	-0.0655	0.82581	...
		-0.0056	-0.064	0.00507	0.95836	0.01645	...
		-0.0817	0.07126	0.02155	0.03126	0.0534	...
		0.19826	-0.1163	0.85513	0.08677	0.10371	...
	$\hat{Y}$	1	1	4	2	1	...

[0150] 步骤S8) 将800组测试数据集的输入标签  $Y_{test}$  与预测结果  $\hat{Y}^1$ 、 $\hat{Y}^2$ 、 $\hat{Y}$  比较, 验证算法准确率, 具体流程可参考图7。在此例中, 各分类器的预测准确率如下表。

[0151] 表7 电流、电磁、改进BP-AdaBoost及其基分类器准确率。

准确率 (%)		$h_1^p$	$h_2^p$	$h_3^p$	$h_4^p$	$h_5^p$	
[0152]	电流	BP	90.75	86.88	89.12	87.38	91.13
	$p=1$	BP-AdaBoost	92.87				
	电磁	BP	82.63	83	81.63	81.37	87.38
	$p=2$	BP-AdaBoost	88.5				
基于注意力机制改进的BP-Adaboost 分类器		95.63					

[0153] 参见上表可知,对于电流、电磁信号,采取BP-Adaboost分类器相比于基分类器,分别最高提升5.99%、7.13%;基于注意力机制改进的BP-Adaboost分类器相比于传统的BP-AdaBoost分类器,分别提升2.76%,7.13%,整个过程最高提升14.26%,因此本实施例基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的有效性得到验证。

[0154] 综上所述,本实施例基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法是一种利用多源数据融合进行故障检测并考虑BP-Adaboost和注意力机制的方法,对不同来源的数据信息进行单独学习训练,减少采用高级学习模型的复杂度,节约网络训练的资源。将注意力聚焦到重点测量手段信息来提升信息获取的能力,大大提高电机系统的故障诊断的稳定性和精度。

[0155] 此外,本实施例还提供一种基于注意力机制改进的BP-Adaboost多源信息电机故障诊断系统,包括相互连接的微处理器和存储器,微处理器被编程或配置以执行前述基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的步骤,或者存储器中存储有被编程或配置以执行前述基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的计算机程序。

[0156] 进一步的,如图7所示,本实施例的基于注意力机制改进的BP-Adaboost的多源信息电机故障诊断系统还包括:异步感应电机、电流传感器(如图中标号1所示)、径向杂散磁通测量线圈(如图中标号2所示)、电机负载、放大及滤波器以及数据采集板。异步感应电机通过电源获得动力,并驱动电机负载进行试验运行,电流传感器安装于定子线圈侧,径向杂散磁通测量线圈安装于异步感应电机径向侧,测得信号通过放大及滤波器后送入数据采集板,并传输至计算机运用软件进行相应故障诊断处理分析。

[0157] 此外,本实施例还提供一种计算机存储介质,计算机存储介质中存储有被编程或配置以执行前述基于注意力机制改进的BP-Adaboost多源信息电机故障诊断方法的计算机程序。

[0158] 本领域内的技术人员应明白,本申请的实施例可提供为方法、系统、或计算机程序产品。因此,本申请可采用完全硬件实施例、完全软件实施例、或结合软件和硬件方面的实施例的形式。而且,本申请可采用在一个或多个其中包含有计算机可用程序代码的计算机可读存储介质(包括但不限于磁盘存储器、CD-ROM、光学存储器等)上实施的计算机程序产品的形式。本申请是参照根据本申请实施例的方法、设备(系统)、和计算机程序产品的流程图和/的处理器执行的指令产生用于实现在流程图一个流程或多个流程和/或方框图一个方框或多个方框中指定的功能的装置。这些计算机程序指令也可存储在能引导计算机或其他可编程数据处理设备以特定方式工作的计算机可读存储器中,使得存储在该计算机可读存储器中的指令产生包括指令装置的制品,该指令装置实现在流程图一个流程或多个流程和/或方框图一个方框或多个方框中指定的功能。这些计算机程序指令也可装载到计算机或其他可编程数据处理设备上,使得在计算机或其他可编程设备上执行一系列操作步骤以产生计算机实现的处理,从而在计算机或其他可编程设备上执行的指令提供用于实现在流程图一个流程或多个流程和/或方框图一个方框或多个方框中指定的功能的步骤。

[0159] 以上所述仅是本发明的优选实施方式,本发明的保护范围并不仅局限于上述实施例,凡属于本发明思路下的技术方案均属于本发明的保护范围。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前提下的若干改进和润饰,这些改进和润饰也

应视为本发明的保护范围。

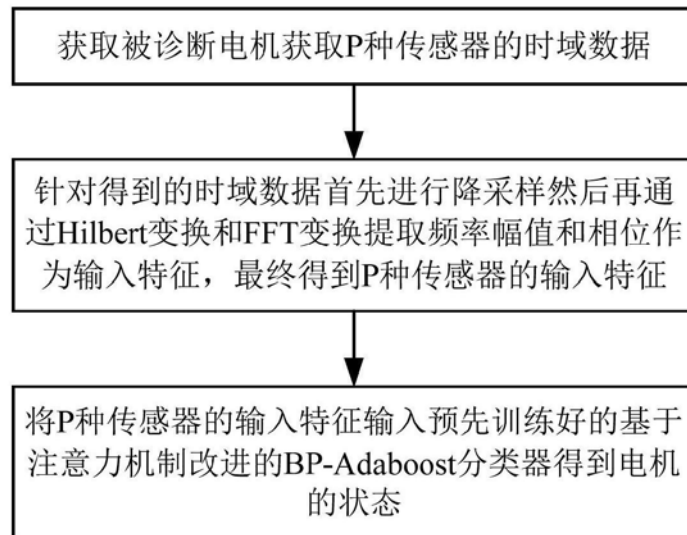


图1




图2

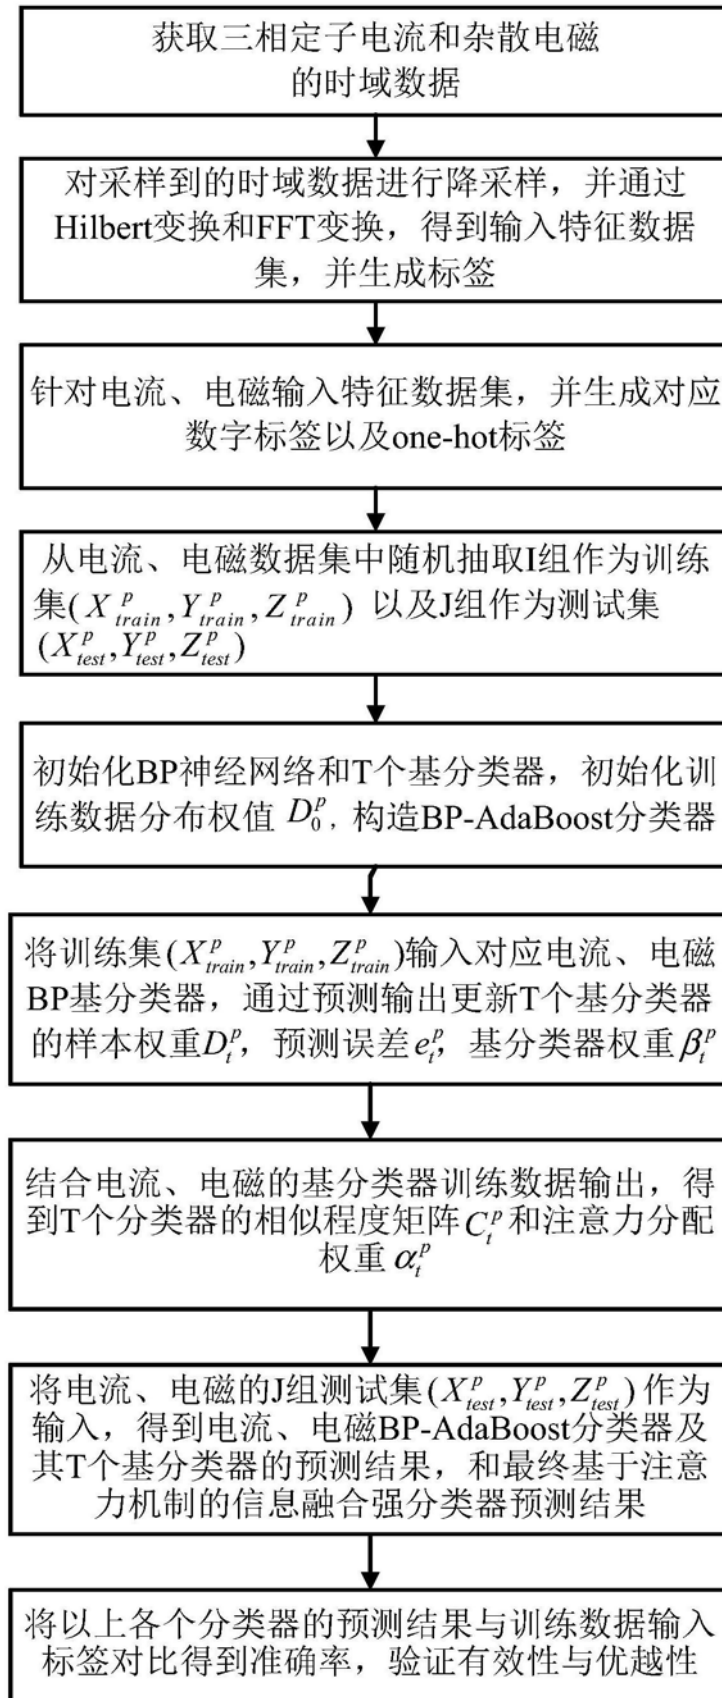


图3

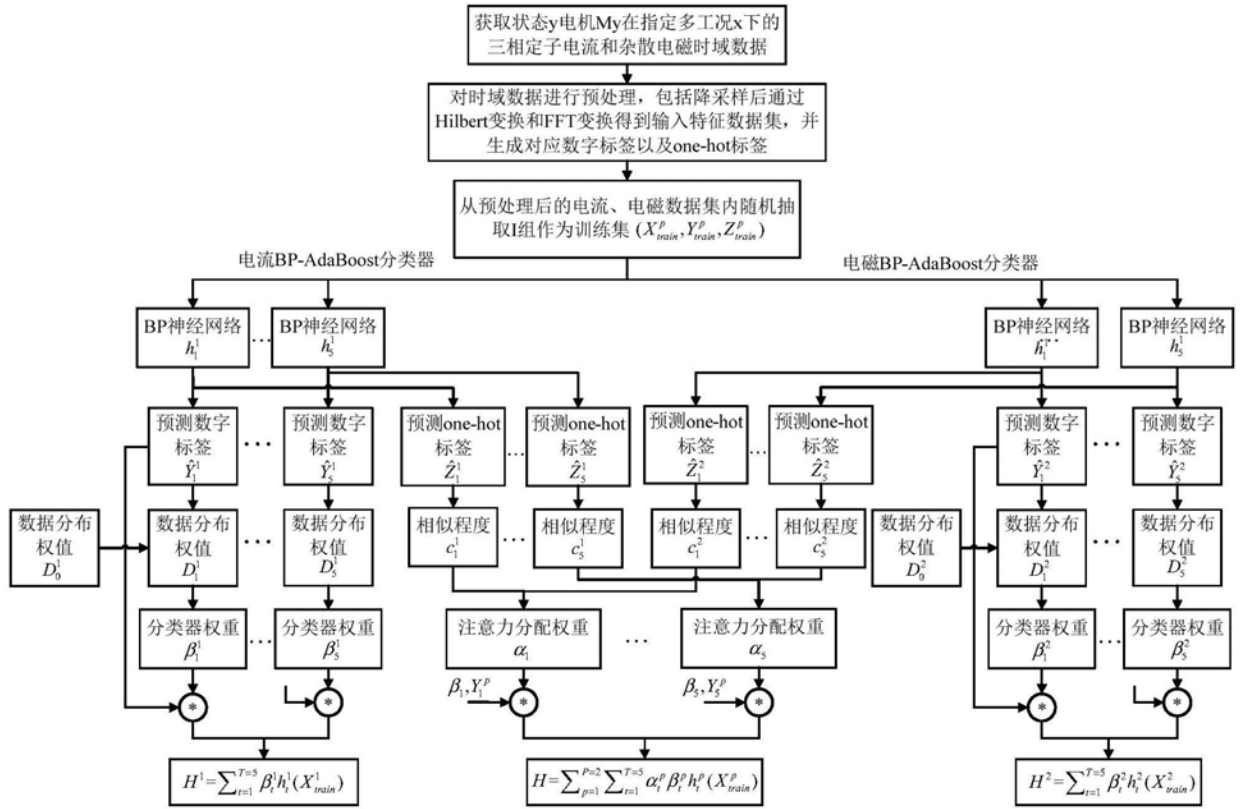


图4



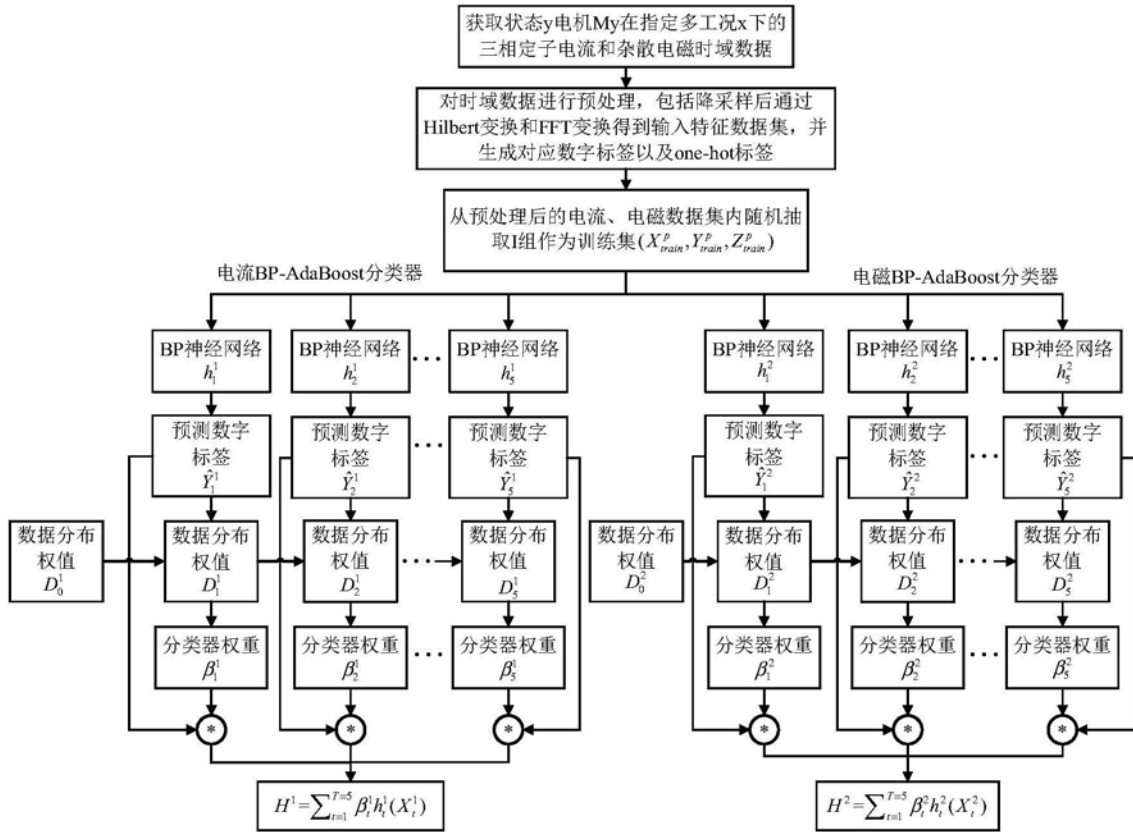


图5

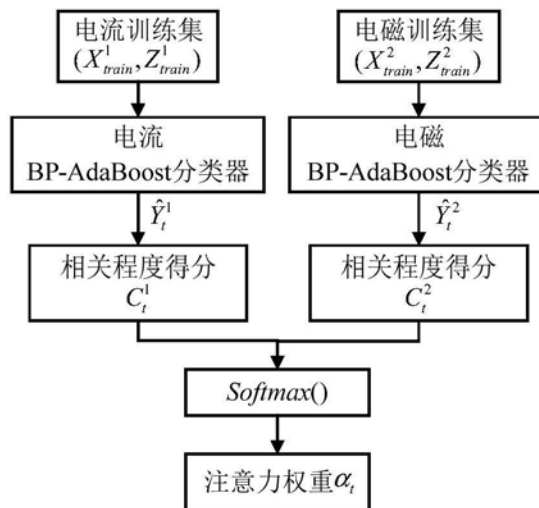


图6

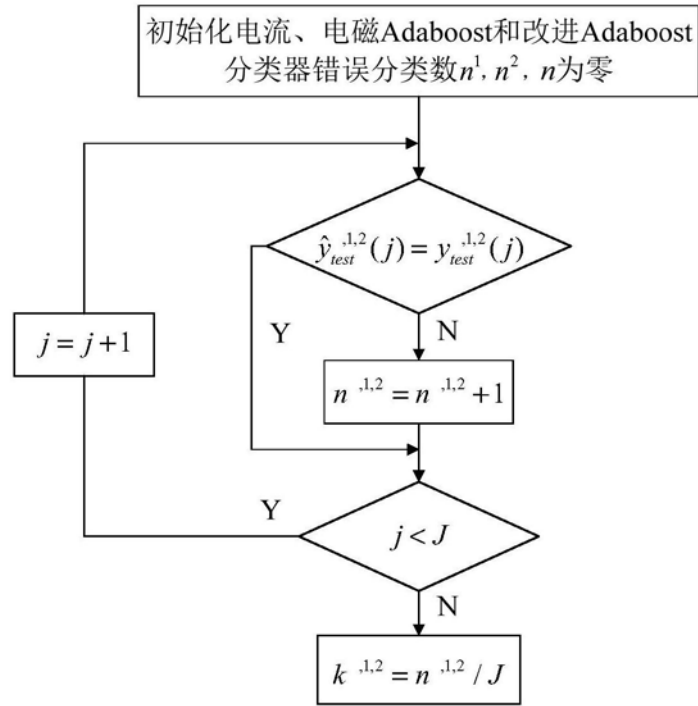


图7

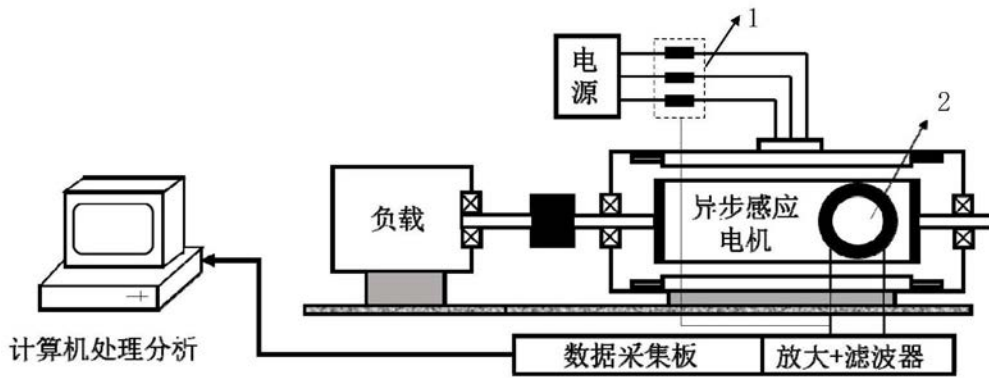


图8