



(12) 发明专利

(10) 授权公告号 CN 111610416 B

(45) 授权公告日 2021.12.07

(21) 申请号 202010452198.2

G06N 3/04 (2006.01)

(22) 申请日 2020.05.25

G06N 3/08 (2006.01)

(65) 同一申请的已公布的文献号

G06N 20/00 (2019.01)

申请公布号 CN 111610416 A

H02H 7/26 (2006.01)

(43) 申请公布日 2020.09.01

(56) 对比文件

(73) 专利权人 南京航空航天大学

CN 110376497 A, 2019.10.25

地址 211106 江苏省南京市江宁区胜太西路169号

CN 107064752 A, 2017.08.18

CN 110174602 A, 2019.08.27

(72) 发明人 江军 李威 文哲 张潮海

崔芮华 等. 基于峭度和间谐波分析的故障电弧识别方法.《电气传动》.2018,第48卷(第10期),79-84.

(74) 专利代理机构 青岛易维申知识产权代理事务所(普通合伙) 37310

审查员 冉祎

代理人 于正友

(51) Int. Cl.

G01R 31/12 (2006.01)

G06K 9/62 (2006.01)

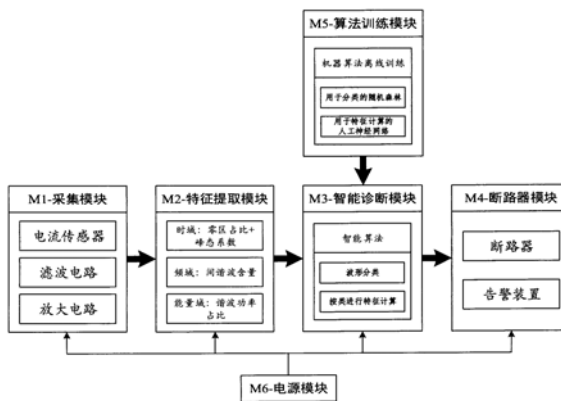
权利要求书2页 说明书7页 附图3页

(54) 发明名称

一种串联电弧故障智能断路器

(57) 摘要

本发明公开了一种基于机器学习算法的串联电弧故障智能断路器方案设计。该断路器用于居民及工商用单相低压供电线路。首先,用传感器采集电路的电流信号。然后从时域提取信号的零区占比和峰值系数特征,从频域提取信号的间谐波含量特征,从能量域提取信号的功率谱分布和谐波功率占比特征。接着根据峰态系数和特定间谐波含量对波形分类,对分类后的波形采用对应的智能算法计算提取到的特征,判断电路是否发生串联电弧故障并定位故障支路。智能算法及参数通过先以样本训练机器学习算法、后提取参数与算法结果之间的规律得到,固化于微处理器内。本方案提高了电弧故障断路器的判断准确率,可实现故障支路定位,避免电气火灾问题,具有实用价值。



1. 一种串联电弧故障智能断路器,其特征是,包括以下几个模块:

模块M1,采集模块,包括电流传感器、滤波电路和放大电路,实现电路电流波形的采集与调理,并送入模块M2中;

模块M2,特征提取模块,对模块M1输出的电流波形完成模-数转换,基于微处理器实现电流波形的时域、频域和能量域特征提取,并送入模块M3中;

模块M3,智能诊断模块,根据模块M2输出的特征,基于微处理器和智能算法判断电路串联电弧故障的发生与否以及定位故障支路,并下发跳闸指令;模块M3中的智能算法分为以下3个步骤:

1) 波形分类;基于峰态系数特征与5次间谐波含量特征,将波形归为线性与非线性两类;

2) 电弧故障检测;依据步骤1)的分类结果,基于零区占比及3~6次间谐波含量,判断电路拓扑中是否发生电弧故障;

3) 故障定位;基于2、10次间谐波含量及6~8次谐波功率占比,判断电路拓扑中发生电弧故障的具体支路位置;

模块M4,断路器模块,根据模块M3的指令跳闸和报警;

模块M5,算法训练模块,实现机器学习算法参数的离线训练和调整,提取输入参数与机器学习算法输出结果之间的关联关系,生成智能算法并固化于模块M3中的微处理器内;

模块M6,电源模块,为模块M1~M4提供电能。

2. 根据权利要求1所述的一种串联电弧故障智能断路器,其特征在于:对于给定的带支路拓扑的电路,电流传感器安装于主回路及各级子电路进线处。

3. 根据权利要求1所述的一种串联电弧故障智能断路器,其特征在于:模块M2中基于微处理器实现电流波形的特征提取;具体而言,包括如下特征:

时域特征:零区占比如(1)所示, x_i 为每个采样点的电流值, I_H 、 I_L 为上下限, n 为每组波形的总采样点数;

$$ZRP = \frac{\sum [(x_i < I_H) \cap (x_i > I_L)]}{n} \quad (1)$$

峰态系数如(2)所示, x_i 为每个采样点的电流值,为全部采样点的平均值, n 为每组波形的总采样点数;

$$K = \frac{\frac{1}{n} \sum (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum (x_i - \bar{x})^2\right)^2} - 3 \quad (2)$$

频域特征:各次间谐波含量,如(3)所示;所提取的间谐波频率为 $f = 25 \times (2n-1)$ Hz, n 为间谐波次数, A_n 为各间谐波的幅值, A_0 为工频基波的幅值, $H(n)$ 为求得的间谐波特征;

$$H(n) = \frac{A_n}{A_0} (n=1, 2, \dots, 10) \quad (3)$$

能量域特征:如(4)所示,其中 A_i 为谐波的幅值, i 为谐波次数,其取值为2~10次, P_i 为

各次谐波对应的功率, P_{sum} 为各次谐波功率总和, α_i 为第 i 次谐波的功率占比,

$$\begin{aligned} P_i &= A_i^2 \\ P_{sum} &= \sum P(i) \\ \alpha_i &= \frac{P_i}{P_{sum}} \end{aligned} \quad (4)$$

4. 根据权利要求1所述的一种串联电弧故障智能断路器,其特征是模块M5中的算法训练分为以下5个步骤:

1) 训练样本准备;通过实物实验或者计算机仿真的方式准备一批给定电路拓扑中的电流波形特征样本,包括仅单一负载正常运行、多负载正常运行、单一负载运行时发生电弧故障以及多负载运行时发生电弧故障时波形的时域、频域与能量域特征;

2) 用于波形分类的机器学习算法训练;通过步骤1)中的训练样本,完成对基于逻辑回归算法建立的波形分类模型的训练;

3) 用于电弧故障检测的机器学习算法训练;通过步骤1)中的训练样本,完成对基于深度神经网络的电弧检测模型的训练;

4) 用于电弧故障定位的机器学习算法训练;通过步骤1)中的训练样本,完成对基于深度神经网络的电弧故障定位模型的训练;

5) 智能算法提取;观察步骤3)~4)中样本特征与神经网络算法结果之间的变化趋势,选择零区占比及3~6次间谐波含量作为主要特征,用线性运算及分段函数近似表征它们与神经网络算法结果之间的关系;选取2、10次间谐波含量及6~8次谐波功率占比,用三次函数与幂函数的线性组合,近似表征它们与神经网络算法结果之间的关系。

5. 根据权利要求4所述的一种串联电弧故障智能断路器,其特征在于:步骤3)~4)中所用神经网络结构共五层,依次为输入层、三层隐藏层及输出层,并采用共轭梯度优化算法加速训练过程。

6. 根据权利要求4所述的一种串联电弧故障智能断路器,其特征在于:步骤5)中,按照(5)对特征进行权重计算,选取权重大于0.3的特征作为智能算法的计算用特征;其中 β_i 是每个特征的影响因子, ΔK_i 是每个特征的变化量, ΔRT_i 是对应的判断准确率的变化量, n 是特征总数, $E(\beta)$ 是影响因子的期望, γ_i 是每个特征因子的权重;

$$\begin{aligned} \beta_i &= \left| \frac{\Delta K_i}{\Delta RT_i} \right| \\ E(\beta) &= \frac{1}{n} \sum_1^n \beta_i \\ \gamma_i &= \frac{\beta_i - E(\beta)}{E(\beta)} \end{aligned} \quad (5)$$

一种串联电弧故障智能断路器

技术领域

[0001] 本发明涉及一种民用低压开关电器(以下简称开关电器),特别是涉及一种串联电弧故障断路器。

背景技术

[0002] 电弧是一种伴随有强光和高热的气体放电现象,在特定情况下极易引起火灾乃至爆炸,严重威胁人身安全和用电设备安全。线路连接处、接插件或者开关电器中的电接触对接触不良时,有较大概率诱发接触对两个电极之间的放电燃弧现象,称之为串联电弧故障。低压开关电器如微型空气开关(以下简称空开)一般采用反时限电流保护原理,只有当线路电流满足过载条件时方才跳闸。然而串联电弧故障产生的故障电流较小,甚至低于线路正常运行时的负荷电流,因此普通开关电器如空开难以侦测及切除故障支路,从而造成用电安全事故尤其是电气火灾。

[0003] 串联电弧故障检测通常基于线路电流波形中蕴含的信息,针对阻性负载(电阻式电加热器等)和感应电机(台式风扇等)负载已经有较成熟的串联电弧故障检测方案及其产品。然而随着家用电器种类的丰富,其中的气体放电灯、开关电源等非线性负载对应的串联电弧故障波形复杂,其特征彼此间差异较大,既有的串联电弧故障断路器产品在此类负载工作时准确率不高、存在一定的误动率。因此亟需提高串联电弧故障断路器产品在复杂负载下的工作可靠性,以推动此类产品的市场推广,保障用户人民群众的生产生活用电安全。

[0004] 机器学习算法是一类通过输入大量数据进行程序参数调整、最终得到期望输出的人工智能算法,常见的算法如人工神经网络、支持向量机等。其优点是无需设计确定的算法逻辑、计算结果准确度高,特别适合特征显著性不强或特征复杂程度较高的数据处理场合。由于机器学习算法的上述优点,将其运用至串联电弧故障断路器中,将显著提高该设备在带非线性负载尤其是电力电子设备及气体放电灯时的工作可靠性,提高此类产品对电弧的检测准确率。然而目前既有的基于机器学习算法的串联电弧故障检测方案,均需要使用专业图形工作站实现机器学习算法,这使得该类算法无法应用于实际产品。因此,目前亟需一种基于微处理器实现基于机器学习算法的电弧检测方案。

发明内容

[0005] 发明目的:

[0006] 本发明的目的就在于解决上述问题,提供一种基于微处理器及机器学习算法的串联电弧故障断路器设计方案。

[0007] 技术方案:

[0008] 本发明为实现上述发明目的采用如下技术方案:

[0009] 一种串联电弧故障智能断路器包括采集模块M1,特征提取模块M2,智能诊断模块M3,断路器模块M4,算法训练模块M5及电源模块M6。所述采集模块M1包括电流传感器、滤波电路和放大电路,实现电路电流信号的采集与调理,并送入特征提取模块M2中。所述特征提

取模块M2,对采集模块M1输出的电流信号完成模-数转换,基于微处理器实现电流信号的时域、频域和能量域特征提取,并送入智能诊断模块M3中。所述智能诊断模块M3,根据特征提取模块M2输出的特征,基于微处理器和智能算法判断电路是否发生串联电弧故障,若有则定位故障支路,并下发跳闸指令。所述断路器模块M4,根据智能诊断模块M3的指令跳闸和报警。所述算法训练模块M5,实现机器学习算法参数的离线训练和调整,提取输入参数与机器学习算法输出结果之间的规律,生成智能算法并固化于智能诊断模块M3中的微处理器内。所述电源模块M6,为模块M1~M4提供电能。

[0010] 所述采集模块M1中,对于给定的带支路拓扑的电路,电流传感器安装于主回路及各级子电路进线处。

[0011] 所述特征提取模块M2中,基于微处理器实现电流波形的特征提取;具体而言,包括如下特征:

[0012] 时域特征:零区占比如(1)所示, x_i 为每个采样点的电流值, I_H 、 I_L 为上下限, n 为每组波形的总采样点数;

$$[0013] \quad ZRP = \frac{\sum [(x_i < I_H) \cap (x_i > I_L)]}{n} \quad (1)$$

[0014] 峰态系数如(2)所示, x_i 为每个采样点的电流值, \bar{x} 为全部采样点的平均值, n 为每组波形的总采样点数;

$$[0015] \quad K = \frac{\frac{1}{n} \sum (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum (x_i - \bar{x})^2\right)^2} - 3 \quad (2)$$

[0016] 频域特征:部分间谐波幅值与工频基波幅值之比,如(3)所示;所提取的间谐波频率为 $f = 25 \times (2n-1)$ Hz, n 为间谐波次数, A_n 为各间谐波的幅值, A_0 为工频基波的幅值, $H(n)$ 为求得的间谐波特征;

$$[0017] \quad H(n) = \frac{A_n}{A_0} (n=1, 2, \dots, 10) \quad (3)$$

[0018] 能量域特征:如(4)所示。其中 $A(i)$ 为谐波的幅值, i 为谐波次数(2~10次), $P(i)$ 为各次谐波对应的功率, P_{sum} 为各次谐波功率总和, α_i 为第 i 次谐波的功率占比。

$$[0019] \quad \begin{aligned} P_i &= A_i^2 \\ P_{sum} &= \sum P(i) \\ \alpha_i &= \frac{P_i}{P_{sum}} \end{aligned} \quad (4)$$

[0020] 进一步,所述智能诊断模块M3中的智能算法分为以下3个步骤:

[0021] 步骤1,波形分类;基于峰态系数特征与5次间谐波含量特征,将波形归为线性与非线性两类;

[0022] 步骤2,电弧故障检测;依据步骤S1的分类结果,基于零区占比及3~6次间谐波含量,判断电路拓扑中是否发生电弧故障;

[0023] 步骤3,故障定位;基于2、10次间谐波含量及6~8次谐波功率占比,判断电路拓扑中发生电弧故障的具体支路位置。

[0024] 进一步,所述算法训练模块M5中的算法训练分为以下5个步骤:

[0025] 步骤1,训练样本准备;通过实物实验或者计算机仿真的方式准备一批给定电路拓扑中的电流波形特征样本,包括仅单一负载正常运行、多负载正常运行、单一负载运行时发生电弧故障以及多负载运行时发生电弧故障时波形的时域、频域与能量域特征;

[0026] 步骤2,用于波形分类的机器学习算法训练;通过步骤1中的训练样本,完成对基于逻辑回归算法建立的波形分类模型的训练;

[0027] 步骤3,用于电弧故障检测的机器学习算法训练;通过步骤1中的训练样本,完成对基于深度神经网络电弧检测模型的训练;

[0028] 步骤4,用于电弧故障定位的机器学习算法训练;通过步骤1中的训练样本,完成对基于深度神经网络电弧故障定位模型的训练;

[0029] 步骤5,智能算法提取;观察步骤3~4中样本特征与神经网络算法结果之间的变化趋势,选择零区占比及3~6次间谐波含量作为主要特征,用线性运算及分段函数近似表征它们与神经网络算法结果之间的关系;选取2、10次间谐波含量及6~8次谐波功率占比,用三次函数与幂函数的线性组合,近似表征它们与神经网络算法结果之间的关系。

[0030] 进一步,所述算法训练模块M5中的步骤3~4中所用神经网络结构共五层,依次为输入层、三层隐藏层及输出层,并采用共轭梯度优化算法加速训练过程。

[0031] 进一步,所述算法训练模块M5中的步骤5中,按照(5)对特征进行权重计算,选取权重大于0.3的特征作为智能算法的计算用特征;其中 β_i 是每个特征的影响因子, ΔK_i 是每个特征的变化量, ΔRT_i 是对应的判断准确率的变化量, n 是特征总数, $E(\beta)$ 是影响因子的期望, γ_i 是每个特征因子的权重。

$$\beta_i = \left| \frac{\Delta K_i}{\Delta RT_i} \right|$$

$$[0032] \quad E(\beta) = \frac{1}{n} \sum_{i=1}^n \beta_i \quad (5)$$

$$\gamma_i = \frac{\beta_i - E(\beta)}{E(\beta)}$$

[0033] 与现有技术相比,本发明的有益效果是:

[0034] (1) 本发明不仅实现了电路电弧故障的检测,还实现了给定电路结构下电弧故障支路的定位;

[0035] (2) 同时实现了基于微处理器和机器学习算法的串联电弧故障检测,大幅提高了检测准确率,增强了此类产品的可靠性和实用性。

附图说明

[0036] 附图1为本发明原理框图;

[0037] 附图2为电流传感器安装位置示意图;

[0038] 附图3为滤波电路图;

[0039] 附图4为放大电路图;

[0040] 附图5为神经网络结构图。

具体实施方式

[0041] 为使本申请的上述目的、特征和优点能够更加明显易懂,下面结合附图对本申请的具体实施方式做详细的说明。

[0042] 本发明各功能模块与工作原理如图1所示。

[0043] 采集模块M1中的电流传感器安装于主回路及各级子电路进线处,一种典型的电路拓扑及其电流传感器安装位置如图2所示。图中B0~B11为全部的支路,其中支路B2~B5组成子电路S1,支路B9~B11组成子电路S3,支路B6~B8与子电路S3组成子电路S2。电流传感器安装于支路B0、B2、B6及B9处。

[0044] 采集模块M1中的滤波电路系抗混叠滤波器,用来滤除高频噪音。由于后续模块要进行A/D(模/数)转换,而ADC(模/数转换器)的采样频率是有限的,因此根据奈奎斯特定理需要采用抗混叠滤波器对信号频率范围进行限定。典型原理如图3所示,图中OP₁为单个运放,IN为信号输入端,OUT为信号输出端。图3所示电路系无限增益负反馈二阶低通滤波器,其优点是通过负反馈防止出现系统振荡,且仅基于单个运放模块即可实现。该滤波器的转移函数计算公式如(6)所示,基于此滤波器及巴特沃斯逼近函数可保证通带内具有最平响应,避免滤波后时域信号幅值失真。

$$[0045] \quad H(s) = \frac{1}{R_1 R_3 C_1 C_2} \frac{1}{s^2 + s \left(\frac{1}{R_1} + \frac{1}{R_2} + \frac{1}{R_3} \right) \frac{1}{C_1} + \frac{1}{R_2 R_3 C_1 C_2}} \quad (6)$$

[0046] 采集模块M1中的放大电路需实现对信号的放大与直流偏置,因为普通ADC(模/数转换器)尤其是集成于嵌入式芯片中者只能对0~VDD(VDD是嵌入式芯片的供电电压)范围内的电压信号进行转换,因此需要对纯交流信号叠加一定幅值的直流电压信号,将其幅值变换至ADC(模/数转换器)可接受的输入电压范围内。实现上述功能的典型放大电路如图4所示,IN为信号输入端,AD0~AD2为后续ADC(模/数转换器)的输入端,VDC为直流基准电压,幅值为0.5×VDD。以C₃、R₄、R₅、R₆和OP₂构成的反相放大电路为例,运算放大器OP₂的同相输入端通过平衡电阻R₆(典型值为10kΩ)外接至VDC(典型值为+1.5V),由此对既有电流信号添加了一个0.5×VDD(VDD典型范围为+3~3.3V)的直流分量,保证了放大电路输出波形不出现失真。图4中,C₃、R₄、R₅、R₆和OP₂构成增益40dB的放大电路,C₄、R₇、R₈、R₉和OP₃构成增益20dB的放大电路,C₅、R₁₀、R₁₁、R₁₂和OP₄构成增益0dB的放大电路,可根据需要选择所需的放大增益。

[0047] 特征提取模块M2对采集模块M1输出的信号提取特征,典型的实现方案是基于微处理器如DSP、ARM等对采集模块M1输出的信号分别提取时域、频域和能量域特征。

[0048] 时域特征包括零区占比及峰态系数,其中零区占比ZRP如(7)所示,x_i为每个采样点的电流值,I_H、I_L为上下限,n为每组波形的总采样点数;

$$[0049] \quad ZRP = \frac{\sum [(x_i < I_H) \cap (x_i > I_L)]}{n} \quad (7)$$

[0050] 峰态系数K如(8)所示,x_i为每个采样点的电流值, \bar{x} 为全部采样点的平均值,n为每组波形的总采样点数。

$$[0051] \quad K = \frac{\frac{1}{n} \sum (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum (x_i - \bar{x})^2\right)^2} - 3 \quad (8)$$

[0052] 频域特征提取首先进行频谱计算,采用离散傅里叶变换求取电流的频谱信息,计算公式如(9)所示;

$$[0053] \quad X(k) = \sum_0^{N-1} x(n) e^{-j\frac{2\pi}{N}kn} \quad k = (0, 1, \dots, N-1) \quad (9)$$

[0054] 所提取的间谐波频率为 $f = 25 \times (2n-1)$ Hz, n 为间谐波次数;选择的频域特征为部分间谐波的幅值与基波幅值的比值,计算公式如(10)所示; A_n 为各间谐波的幅值, A_0 为工频基波的幅值, $H(n)$ 为求得的间谐波特征。

$$[0055] \quad H(n) = \frac{A_n}{A_0} (n=1, 2, \dots, 10) \quad (10)$$

[0056] 能量域特征选择部分谐波的功率占比。首先计算2~10次谐波中各次谐波对应的功率,计算公式如(11)所示。其中 $A(i)$ 为第 i 次谐波的幅值, $P(i)$ 为各次谐波对应的功率;

$$[0057] \quad P_i = A_i^2 \quad (11)$$

[0058] 将各次谐波功率相加,得到为各次谐波功率总和 P_{sum} ,如(12)所示;

$$[0059] \quad P_{sum} = \sum P(i) \quad (12)$$

[0060] 第 i 次谐波的功率与各次谐波功率总和之比 α_i 即为第 i 次谐波的功率占比,如(13)所示。

$$[0061] \quad \alpha_i = \frac{P_i}{P_{sum}} \quad (13)$$

[0062] 算法训练模块M5通过机器学习算法挖掘输入特征与算法输出结果的定量关系,从而得到智能算法,并固化于智能诊断模块M3中的微处理器内。

[0063] 之所以采用这种方案,是基于平衡成本与性能的考虑。目前已公开的工业界电弧故障断路器设计方案中,均采用时频域与能量域特征中的一种或数种进行判断,暂无采用机器学习算法在线检测的方案。单纯凭借上述若干种特征进行判断,难以在种类繁多的负载中保证电弧故障判断的高准确率和低误报率。比如当白炽灯负载所在支路发生串联电弧故障时,零区占比显著上升;然而当开关电源所在支路发生同类故障时,零区占比的数值变化并不显著。因此若以零区占比的变化程度作为判据判断串联电弧发生与否,则容易导致开关电源类负载所在支路出现较高的漏报率。若引入多种特征使用简单逻辑进行电弧故障判断,也难以避免上述缺点。而学术界公开的电弧故障检测方案多在图形工作站上借助机器学习算法尤其是神经网络实现,显然无法直接应用于实际。若设法在微处理器如STM32、DSP和FPGA上实现神经网络,则对微处理器的性能要求很高,产品成本企业难以接受。因此需要将机器学习算法与微处理器结合,通过线下的机器学习算法挖掘输入特征与算法输出结果的定量关系,以减轻微处理器计算负担:

[0064] 以下结合图2,简要介绍智能诊断模块M3的工作过程。首先基于峰态系数特征与5次间谐波含量特征,将支路B0、B2、B6及B9处的波形归为线性与非线性两类。然后依据分类结果,基于零区占比及3~6次间谐波含量,判断这些波形中是否存在串联电弧故障波形。假

定现认定仅支路B6波形属于电弧故障波形,说明故障仅存在于支路B7~B8中;则基于2、10次间谐波含量及6~8次谐波功率占比特征计算,最终判断支路B7发生串联电弧故障。

[0065] 智能诊断模块M3的可靠性取决于算法训练模块M5中提取的智能算法,因此以下简要介绍算法训练模块M5的工作过程。

[0066] 首先需要准备机器学习算法训练样本,具体而言通过实物实验或者计算机仿真的方式准备一批给定电路拓扑中的电流波形,包括仅单一负载正常运行、多负载正常运行、单一负载运行时发生电弧故障以及多负载运行时发生电弧故障;接着按照特征提取模块M2中的算法提取波形的时域、频域与能量域特征。

[0067] 然后基于准备好的训练样本训练机器学习算法,具体而言需要完成基于逻辑回归算法建立的波形分类模型的训练、基于深度神经网络电弧检测模型的训练,以及基于深度神经网络电弧故障定位模型的训练。一种用于电弧检测模型的深度神经网络模型结构如图5所示,该模型共五层,依次为输入层、三层隐藏层及输出层,采用共轭梯度优化算法加速训练过程。

[0068] 接着需要筛选智能算法所需的特征。首先按(14)计算每个特征的影响因子 β_i ,其中 ΔK_i 是每个特征的变化量, ΔRT_i 是对应的判断准确率的变化量;

$$[0069] \quad \beta_i = \left| \frac{\Delta K_i}{\Delta RT_i} \right| \quad (14)$$

[0070] 然后按(15)计算全部特征的影响因子期望 $E(\beta)$;

$$[0071] \quad E(\beta) = \frac{1}{n} \sum_1^n \beta_i \quad (15)$$

[0072] 再根据(16)可求得每个特征的权重 γ_i 。选取权重大于0.3的特征作为智能算法的计算用特征,具体而言选取选择零区占比及3~6次间谐波含量用于故障判断,2、10次间谐波含量及6~8次谐波功率占比用于故障支路定位;

$$[0073] \quad \gamma_i = \frac{\beta_i - E(\beta)}{E(\beta)} \quad (16)$$

[0074] 最后观察已选取得样本特征与神经网络算法结果之间的变化趋势,选取选择零区占比及3~6次间谐波含量作为主要特征,用线性运算及分段函数近似表征它们与神经网络算法结果之间的关系;选取2、10次间谐波含量及6~8次谐波功率占比,用三次函数与幂函数的线性组合,近似表征它们与神经网络算法结果之间的关系,由此得到适用于微处理器的智能算法。

[0075] 断路器模块M4在发生串联电弧故障时根据智能诊断模块M3的指令跳闸,并发出声光报警信号。

[0076] 电源模块M6向模块M1~M4提供所需的电能。

[0077] 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用存储介质(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。

[0078] 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/或方框图来描述的。应理解可由计算机程序指令实现流程图和/或方框图中的每一流程和/或方框、以及流程图和/或方框图中的流程和/或方框的结合。可提供这些计算机程序指令到通用计算机、专用计算机、嵌入式处理机或其他可编程数据处理设备的处理器以产生一个机器,使得通过计算机或其他可编程数据处理设备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。

[0079] 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造品,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。

[0080] 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。

[0081] 最后应当说明的是:以上实施例仅用以说明本发明的技术方案而非对其限制,尽管参照上述实施例对本发明进行了详细的说明,所属领域的普通技术人员应当理解:依然可以对本发明的具体实施方式进行修改或者等同替换,而未脱离本发明精神和范围的任何修改或者等同替换,其均应涵盖在本发明的权利要求保护范围之内。

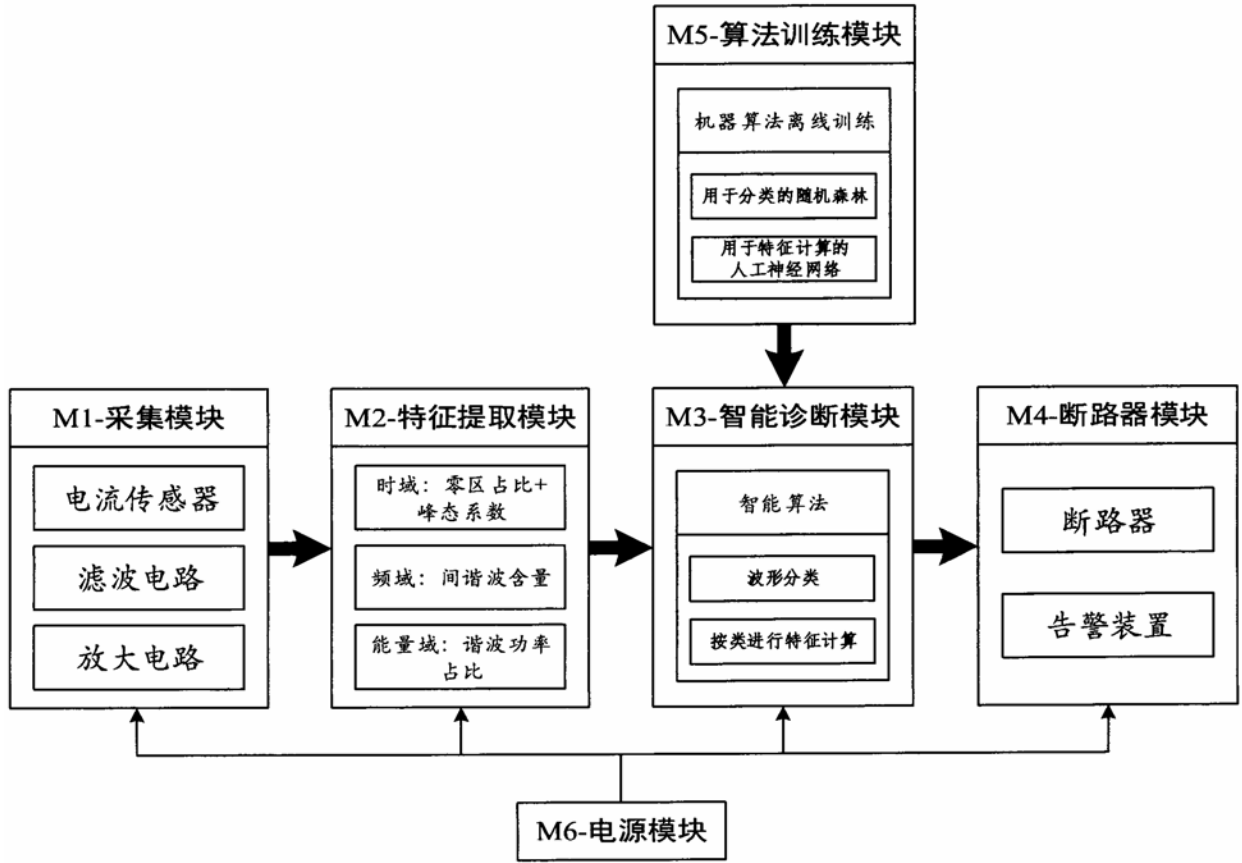


图1

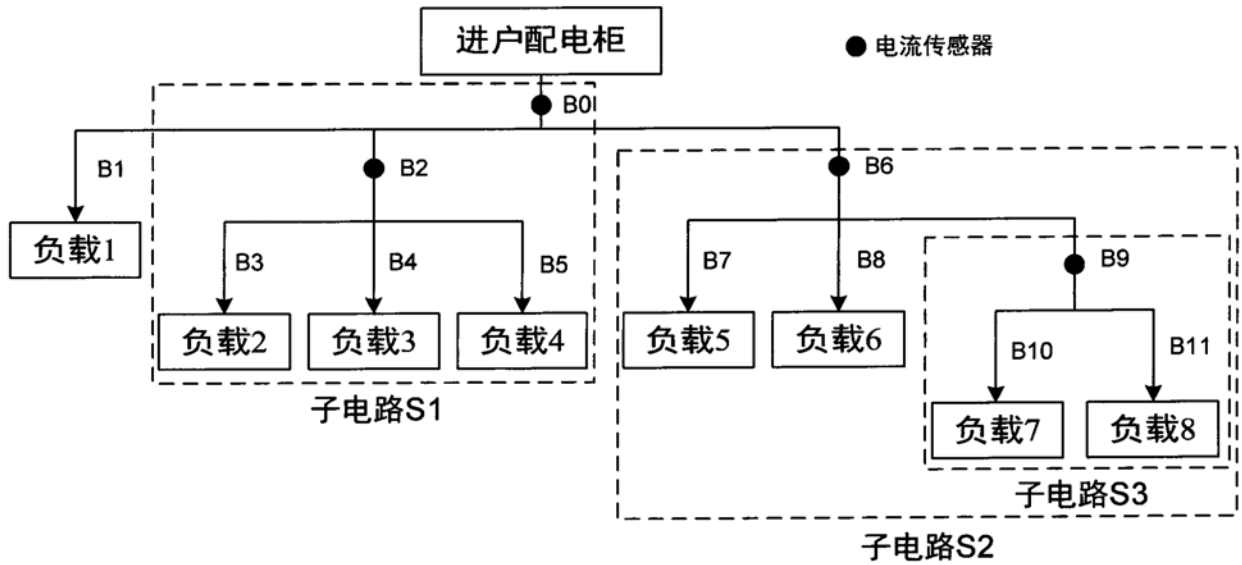


图2




图3




图4




图5