



(12) 发明专利申请

(10) 申请公布号 CN 102570392 A

(43) 申请公布日 2012. 07. 11

(21) 申请号 201210013154. 5

(22) 申请日 2012. 01. 17

(71) 申请人 上海电力学院

地址 200090 上海市杨浦区平凉路 2103 号

(72) 发明人 杨旭红 许行

(74) 专利代理机构 上海申汇专利代理有限公司

31001

代理人 吴宝根

(51) Int. Cl.

H02H 7/045(2006. 01)

G06F 17/50(2006. 01)

G06N 3/02(2006. 01)


权利要求书 1 页 说明书 7 页 附图 2 页

(54) 发明名称

基于改进概率神经网络的变压器励磁涌流鉴别方法

(57) 摘要

本发明涉及一种基于改进概率神经网络的变压器励磁涌流鉴别方法,采用遗传算法对概率神经网络的平滑因子进行优化,通过在 Matlab/Simulink 中搭建的模型仿真获得电流波形,将励磁涌流和内部故障电流的小波变换能量作为网络输入,进行故障模式识别。把智能技术运用到励磁涌流的判别上,此方法大大提高了励磁涌流故障识别能力。



1. 一种基于改进概率神经网络的变压器励磁涌流鉴别方法,其特征在于,具体包括如下步骤:

1) 建模仿真变压器励磁涌流和短路电流的波形:采用 Matlab/Simulink 中的 SimPowerSystems 模块库,参数为系统默认,获得励磁涌流和短路两种电流波形;

2) 分别对励磁涌流和短路电流进行小波分析,提取能量特征:设定采样频率,对采样的电流信号进行四次小波,分解取各高频段的能量形成特征向量:

$T = [E_1, E_2, E_3, E_4]$, 对特征向量进行归一化: $T = [E_1, E_2, E_3, E_4] / \sum_{j=1}^4 E_j$, 识别励磁涌流和短

路电流的特征向量,形成了由归一化后的特征向量组成的样本空间;

3) 遗传算法优化概率神经网络的平滑因子 σ :在有限的样本空间中提炼出能反映整个样本空间的平滑因子,利用遗传算法优化后获得平滑因子的最优值;

4) 基于人工神经网络的变压器差动保护方案:将励磁涌流和内部故障电流经小波分解后的能量作为特征向量输入,对优化后的神经网络进行训练和测试,以进行模式识别。

2. 根据权利要求 1 所述基于改进概率神经网络的变压器励磁涌流鉴别方法,其特征在于,所述遗传算法优化平滑因子主要有以下几个步骤:

A: 设定平滑因子的取值范围,随即产生初始 N 条染色体形成初始种群, $\sigma = \{\sigma_1, \sigma_2, \sigma_3, \dots, \sigma_N\}$, 并设当前代数 $t=1$;

B: 根据由所有染色体得到的平滑因子,构建 PNN 网络,计算分类正确的个数 t 及误差函数 J_m , m 为训练样本的数量,即计算染色体的适应度函数;

C: 选择优胜的个体,进行交叉、变异操作,得到下代种群;

D: 设当前代数 $t=t+1$;

E: 检查 t 和误差函数 J_m , 若 $t=T$ 或 $J_m=0$, 停止, 否则返回步骤 B。

基于改进概率神经网络的变压器励磁涌流鉴别方法

技术领域

[0001] 本发明涉及一种变压器生产检测技术,特别涉及一种基于改进概率神经网络的变压器励磁涌流鉴别方法。

背景技术

[0002] 电力变压器作为电力系统中的重要组成部分和关键设备之一,担负着电能传输和电压变换的重要作用,其运行状态直接影响到整个电力系统的安全性和稳定性。目前我国的电力工业飞速发展,电力系统正朝着更大的输电容量和更高的电压等级发展,电力变压器也朝着大容量、高电压的方向发展。然而容量越大,等级越高,使电力变压器的故障率也越高,同时由于电力变压器内部结构复杂,运行环境特殊,在电力变压器长时期的运行当中,发生故障是无法避免的。如果处于电力系统中枢地位的大型电力变压器发生故障,会严重影响社会的生产和人民生命财产的安全,会大大制约国民经济的发展,造成严重的经济损失,因此对要求变压器的继电保护具有较高的可靠性。

[0003] 长期以来,纵联差动保护一直被认为是电力变压器最完善的主保护,它是基于基尔霍夫电流定律(KCL)的,利用故障时产生的不平衡电流来动作,具有选择性好、灵敏度高的特点。但是,变压器差动保护的正确动作率一直不高,远远达不到现代电力继电保护的要求。根据相关文献的统计数据,1996~2005年十年间,220kV及以上变压器差动保护总动作次数为2247次,其中正确动作次数为1673次,不正确动作574次,平均正确动作率为74.45%。

[0004] 变压器的保护发展还比较落后,其保护准确动作率还是相当低的,远远低于电力系统中其他主设备,如发电机保护、输电线路保护等。造成现在这种结果,有工作人员的操作问题(设计,制造,整定调试,运行维护诸方面的失误),也有管理监督方面的不足,但究其根本原因,是电力变压器差动保护方案的原理上不足。差动保护在纯电路设备如发电机、输电线路上的应用比较简单,效果比较理想,但是作为电力变压器的主保护性能不是很好,如何防止由不平衡电流引起的差动保护误动作成为不得不面临的最关键问题。差动保护的理论依据是基尔霍夫电流定理,但变压器内部采用闭合铁芯,实质上是一个非线性元件,因此基尔霍夫电流定理本质上已不再适用。

[0005] 变压器的励磁电流是差动保护不平衡电流的一种主要来源。变压器正常运行时,其励磁电流一般为额定电流的1%~3%,可以忽略不计,通过整定适当的门槛值,差动保护就可以准确区分变压器的内部故障与外部故障。但当变压器空载合闸,或者外部故障切除后端电压突然恢复时,励磁涌流的数值很大,有时可能与短路电流相比拟,如果没有别的保护措施,这么大的不平衡电流必然导致差动保护误动作。因此,当前变压器差动保护的主要矛盾集中在如何快速、准确的区分变压器励磁涌流和内部故障电流,只有及时准确地切除内部故障电流,才能避免更大的电力损失,保证电力供应的可靠性。为此,国内外学者进行了大量的探索,提出了许多新原理、新方法用于差动保护,主要包括二次谐波制动原理、间断角原理、波形对称原理和磁通特性制动原理等。目前,在系统中配置的变压器保护,主要

是采用二次谐波制动原理和电流间断角原理来识别励磁涌流的存在。由于间断角原理对硬件要求高,在微机变压器差动保护中,采用二次谐波制动原理较多。该原理通过比较差动电流中的二次谐波与基波之比值的的大小来决定是否闭锁差动保护,但是由于励磁涌流中二次谐波的含量由多个参数决定且变化很大,所以很难适当选择制动系数。特别是随着现代大型变压器的大量使用,变压器的励磁特性发生很大的变化,导致励磁涌流中二次谐波的含量减小,而大容量变压器和远距离输电的发展,又使得内部故障时暂态电流中的二次谐波增加,从而造成谐波制动原理识别困难,经常出现误动作。

[0006] 因此,运用新的原理和方法实现变压器励磁涌流的判别具有现实迫切性,以提高变压器差动保护的准确性和性能。从九十年代开始,我国的继电保护技术已进入了微机保护的时代微机的应用引起了继电保护领域的深刻变革,也带来了继电保护技术发展的新机遇。在识别变压器励磁涌流技术方面,已经提出了许多新的原理和解决方法。这些方法中有很多是综合了人工智能领域的最新成果而提出的。比如小波理论,模糊数学,神经网络等等,这些技术的飞速发展为变压器的智能保护的出現和突破提供了坚实的基础。

发明内容

[0007] 本发明是针对变压器的励磁电流对提高变压器品质的重要性的问题,提出了一种基于改进概率神经网络的变压器励磁涌流鉴别方法,采用概率神经网络(Probability Neural Network, PNN)作为核心分类器,来鉴别电力变压器的励磁涌流和内部故障电流,把智能技术运用到励磁涌流的判别上,并且取得了不错的成果。

[0008] 本发明的技术方案为:一种基于改进概率神经网络的变压器励磁涌流鉴别方法,具体包括如下步骤:

1) 建模仿真变压器励磁涌流和短路电流的波形:采用 Matlab/Simulink 中的 SimPowerSystems 模块库,参数为系统默认,获得励磁涌流和短路两种电流波形;

2) 分别对励磁涌流和短路电流进行小波分析,提取能量特征:设定采样频率,对采样的电流信号进行四次小波,分解取各高频段的能量形成特征向量:

$T = [E_1, E_2, E_3, E_4]$, 对特征向量进行归一化: $T = [E_1, E_2, E_3, E_4] / \sum_{j=1}^4 E_j$, 识别励磁涌流和短

路电流的特征向量,形成了由归一化后的特征向量组成的样本空间;

3) 遗传算法优化概率神经网络的平滑因子 σ : 在有限的样本空间中提炼出能反映整个样本空间的平滑因子,利用遗传算法优化后获得平滑因子的最优值;

4) 基于人工神经网络的变压器差动保护方案:将励磁涌流和内部故障电流经小波分解后的能量作为特征向量输入,对优化后的神经网络进行训练和测试,以进行模式识别。

[0009] 所述遗传算法优化平滑因子主要有以下几个步骤:

A: 设定平滑因子的取值范围,随即产生初始 N 条染色体形成初始种群, $\sigma = \{\sigma_1, \sigma_2, \sigma_3, \dots, \sigma_N\}$, 并设当前代数 $t=1$;

B: 根据由所有染色体得到的平滑因子,构建 PNN 网络,计算分类正确的个数 t 及误差函数 J_m , m 为训练样本的数量,即计算染色体的适应度函数;

C: 选择优胜的个体,进行交叉、变异操作,得到下代种群;

D: 设当前代数 $t=t+1$;

E: 检查 t 和误差函数 J_m , 若 $t=T$ 或 $J_m=0$, 停止, 否则返回步骤 B。

[0010] 本发明的有益效果在于: 本发明基于改进概率神经网络的变压器励磁涌流鉴别方法, 把智能技术运用到励磁涌流的判别上, 此方法大大提高了励磁涌流故障识别能力。

附图说明

[0011] 图 1 为概率神经网络(PNN) 结构图;

图 2 为单电源电力系统图;

图 3 为三相变压器空载合闸时的励磁涌流波形图;

图 4 为三相变压器短路电流波形图;

图 5 为本发明基于改进概率神经网络的变压器励磁涌流鉴别方法设计的变压器差动保护系统示意图。

具体实施方式

[0012] 采用遗传算法对概率神经网络的平滑因子进行优化, 通过在 Matlab/Simulink 中搭建的模型仿真获得电流波形, 将励磁涌流和内部故障电流的小波变换能量作为网络输入, 进行故障模式识别。

[0013] 概率神经网络是一种前馈神经网络。概率神经网络结构是一种根据 Parzen 参数概率密度函数 (probability density function, pdf) 估计和贝叶斯分类规则的神经网络。概率神经网络标准的训练程序应包含所有模式的训练集。这一特点使概率神经网络相比前馈反向传播神经网络的训练速度更快。概率神经网络唯一的缺点是必需大量存储训练模式。随着计算机内存已变得非常便宜又有效, 如今大容量存储的成本和空间大小都已不成为问题。概率神经网络被广泛用于模式识别、非线性映射、故障检测和分类等领域。

[0014] 概率神经网络的结构如图 1 所示。它是一个四层前向反馈神经网络, 第 I 层为输入层, 第 II 层为求知层, 第 III 层为模式层, 第 IV 层为输出层, 可以作为一个最优的分类器。在概率神经网络中, 高斯函数由于其性能良好且易于计算, 通常作为激活函数。概率神经网络的激活函数是根据训练样本得到的概率密度函数来获得的, 具体步骤如下:

设 $X \in R^d$ 为 d 维训练样本向量, 归属于第 i 类, 其中 $i \in (S_1, S_2, S_3, \dots, S_k)$, k 为所有类别的数目。根据贝叶斯分类准则, 后验概率 $P(S_i/x)$ 可以这样计算得到:

$$P(S_i/x) = \frac{P(x/S_i)P(S_i)}{P(x)} \quad (1)$$

其中, $P(x/S_i), i=1, 2, 3, \dots, k$, 为隶属于某类的条件概率密度函数, $P(S_i)$ 为先验概率, $P(x)$ 是输入向量的概率密度函数。

[0015] 某一类的后验概率最大, 则样本属于该类别。对所有的 $j \neq i$, 有

$$P(x/S_i)P(S_i) > P(x/S_j)P(S_j) \quad (2)$$

1962 年 Parzen 提出了一种从已知随机样本中估计概率密度函数的方法, 只要样本数

目足够多,该方法所获得的函数可以连续平滑地逼近原概率密度函数。由 Parzen 方法得到的 PDF 估计式为:

$$P(x/S_i) = \frac{1}{(2\pi)^{d/2} \sigma_i^d m} \sum_{j=1}^{x_i} \exp\left[-\frac{(x-x_j)^T(x-x_j)}{2\sigma_i^2}\right] \quad (3)$$

其中, x_j^i 为 i 类中第 j 个训练样本; m 为训练样本的数量; σ_i 为平滑因子。

[0016] 与 BP 网络不同,概率神经网络的学习算法在训练过程中不调整神经元之间的连接权值,网络的学习完全取决于数据样本,只需要确定平滑参数。在输入样本确定的情况下,正确选择扩展系数或平滑因子,可以有效地改善概率神经网络的分类性能。通常,人们会对平滑因子进行经验式统计的估计,但是这样增加了计算量,且选取过程复杂,难以获得最优的平滑因子参数。因此,本文选取优化能力极强的遗传算法确定平滑因子,以期达到良好的分类效果。

[0017] 遗传算法是(Genetic Algorithm, GA)一种基于自然选择和基因遗传学原理的优化搜索方法。它将“优胜劣汰,适者生存”的生物进化原理引入待优化参数形成的编码串群体中,按照一定的适配值函数及一系列遗传操作对个体进行筛选,从而使适配值高的个体被保留下来,组成新的群体,新群体包含上一代的大量信息,并且引入了新的优于上一代的个体。这样周而复始,群体中个体的适应度不断提高,直至满足一定的条件为止。

[0018] 利用遗传算法进行优化时,首先对平滑因子 σ 进行编码构成染色体。本文采用实数编码,因为实数编码较二进制编码具有更短的编码长度,且避免了解码过程,精度较高。每次遗传操作完成后,根据不同个体构建 PNN 网络,计算神经网络的误差函数,确定每个个体的适应度函数。误差函数可以设定为:

$$J_m = \sum_{k=1}^q \sum_{i=1}^s (\hat{y}(k) - y_i(k))^2 \quad (4)$$

其中, $\hat{y}(k)$ 为对应与训练集样本的期望输出, $y_i(k)$ 为由染色体获得的概率神经网络训练后的当前输出, q 为训练样本集的个数, s 为故障类型个数。计算每个染色体的适应度值,用以衡量每个染色体性能的好坏,从而选出性能良好的染色体,经过多次迭代后,最终获得平滑因子的最优值。

[0019] 本发明中,作者利用 Matlab/Simulink 中的电力系统工具箱(SPS)建立仿真系统模型,图 2 所示的为单向供电电力系统。它由一个 110kV 的三相电压源(额定容量为 250MVA)、三相双绕组变压器(40MVA, Y_g/Δ , 110/11 kV)和三相负荷组成。需要指出的是,一次侧和二次侧的电流互感器的接线形式为星形,两侧电流的相位问题可以通过继电器内部软件计算校正。

[0020] 在所有的变压器的故障类型中,内部匝间短路故障所占的比例相当大,也直接决定了差动继电器的性能。仿真过程中,将发生匝间短路的双绕组变压器的二次侧绕组等效成三绕组,来仿真匝间短路故障。本文主要对以下几种情况进行了仿真:

(1)改变合闸初相角和剩磁来产生励磁涌流。合闸角的变化范围为 $0 \sim 360$,步长为 30 度。铁芯剩磁为额定电压时漏磁峰值的 $0\% \sim 80\%$ 。

[0021] (2)不同匝间短路比时($5\% \sim 50\%$)的内部故障短路,改变短路类型:单相接地短

路、两相接地短路、两相短路和三相接地短路。

[0022] 图 3 所示为典型的励磁涌流波形,图 4 为三相变压器故障电流波形。

[0023] 从图中可以明显地看出,故障电流和励磁电流有明显的差别,故障电流是连续的不存在间断角,而且波形是对称的正弦波。经 FFT 分析之后,会发现励磁涌流除含有大量的基波和非周期分量外,含有大量的高次谐波,其中以二次谐波为主,而内部故障电流主要以基波为主,高次谐波含量低。正是由于励磁涌流和内部故障电流所包含的各次谐波的含量不同,将电流信号经小波分解后,分布在各高频段的能量不同。

[0024] 根据巴什瓦(Parseval)定理,在信号处理中,信号在时间频域中的能量与频率域中的能量是守恒的。因此,信号经小波多层分解后,原始信号的能量可以表示为:

$$\int_{\mathbb{R}} |f(t)|^2 dt = \sum_{k \in \mathbb{Z}} |c_k^j|^2 + \sum_{j=1}^J \sum_{k \in \mathbb{Z}} |d_k^j|^2 \quad (5)$$

其中, c_k^j 、 d_k^j 分别为小波分解后各尺度下的近似信号系数和细节信号系数。即将信号 $f(t)$ 小波分解后,其近似信号系数与细节信号系数的平方和等于原始信号在时域上的能量。

[0025] 为了方便计算,本文选取细节部分的能量作为尺度函数。对离散信号,通过二进小波变换得到在各尺度下的小波系数 $d_{j,k}$ 。定义细节能量函数:

$$E(j) = \log_2 \left(\sum_{k \in \mathbb{Z}} |d_{j,k}|^2 \right) \quad (6)$$

构造能量特征向量: $T = [E_1, E_2, E_3, \dots, E_m]$, m 为尺度。对特征向量进行归一化:

$T = [E_1, E_2, E_3, E_4] / \sum_{j=1}^4 E_j$, 则 T 即为归一化后由特征向量生成的特征空间,可以作为识别励

磁涌流和短路电流的特征向量。

[0026] 励磁涌流中,除基波和非同期分量外,含有大量的高次谐波电流,其中以二次谐波为主,有时也会有部分三次谐波,而内部短路电流主要以基波为主,高次谐波的含量比较低。正是由于励磁涌流和内部短路电流所包含的各次谐波不同,将电流信号进行小波分解后,分布在各高频段的能量也不同。

[0027] 步骤 1:建模仿真变压器励磁涌流和短路电流的波形:

仿真模型各个模块直接采用 Matlab/Simulink 中的 SimPowerSystems 模块库,参数基本为系统默认,获得如图 3 和 4 的两种电流波形。

[0028] 对比图 3 种变压器励磁涌流的波形和图 4 中短路故障电流,可以明显地发现,励磁涌流有以下几个特点:

(1) 励磁涌流为尖顶波,其中含有相当成分的非周期分量和高次谐波分量。高次谐波中以二次和三次谐波为主,二次谐波分量的比例十分显著,而且随着时间的推移,其所占比例反而有所增加,且至少有一相二次谐波分量很大,可能超过基波分量的 60%。并且最初几个周期内可能完全偏于时间轴的一侧;

(2) 励磁涌流的幅值与变压器空载投入时的电压初相角有关;

(3) 励磁涌流在最初几个周期内波形是间断的,每个周期内有 $80^\circ \sim 100^\circ$ 间断角;

(4) 励磁涌流对于额定电流幅值的倍数与变压器的容量大小有关。变压器容量越大,励磁涌流对额定电流幅值的倍数越小;

(5) 励磁涌流衰减的时间常数与变压器至电源间阻抗的大小、变压器容量和铁芯材料等因素有关。一般情况下,变压器的容量越大,或越靠近电源,其衰减时间越长。铁芯越饱和,电抗值越小,衰减越快。

[0029] 步骤 2:分别对励磁涌流和短路电流进行小波分析,提取能量特征:

本发明选择的采样频率为 1kHz,为了使各次谐波能够单独地分布到各高频段上,需对信号进行四次小波分解。小波基的选取对测试结果也有一定的影响,经过多次仿真,作者选取性能更好的 sym4 小波函数。

[0030] 取各高频段的能量形成特征向量: $T = [E_1, E_2, E_3, E_4]$ 。对特征向量进行归一化:

$T = [E_1, E_2, E_3, E_4] / \sum_{j=1}^4 E_j$, 则形成了由归一化后的特征向量组成的样本空间。

[0031] 步骤 3:遗传算法优化概率神经网络的平滑因子:

在有限的模式样本中提炼出能反映整个样本空间的平滑因子,而目前的平滑因子估计都基于经验估计或很有限样本聚类的方法,并不能将空间的概率特性很完整地表达出来。而遗传算法可以在没有任何先验知识的情况下发现系统潜在知识,并在函数最优化、自动控制、图像识别和机器学习等方面获得了广泛的成功。

[0032] 通过遗传算法优化平滑因子主要有以下几个步骤:

(1) 设定平滑因子的取值范围,随即产生初始 N 条染色体形成初始种群, $\sigma = \{\sigma_1, \sigma_2, \sigma_3, \dots, \sigma_M\}$, 并设当前代数 $t=1$;

(2) 根据由所有染色体得到的平滑因子,构建 PNN 网络,计算分类正确的个数及误差,即计算染色体的适应度函数;

(3) 选择优胜的个体,进行交叉、变异操作,得到下代种群;

(4) 设当前代数 $t=t+1$;

(5) 检查 t 和 J_{max} , 若 $t=T$ 或 $=0$, 停止, 否则返回(2)。

[0033] 步骤 4:基于人工神经网络的变压器差动保护方案:

提出了一种新的变压器差动保护方案,首先利用遗传算法对概率神经网络的平滑因子进行优化,将励磁涌流和内部故障电流经小波分解后的能量作为特征向量输入,对神经网络进行训练和测试,以进行模式识别。

[0034] 图 5 所示为基于人工神经网络的变压器差动保护方案,用来识别励磁涌流和内部故障电流。变压器二次侧采集到的电流值 1 由小波分解 2 后,经过归一化处理,形成样本空间。由各个网络提取其特征量,按照相应的拓扑结构和学习规则,进行训练,然后对测试样本做出相应的故障模式判断。为了与经过优化后的概率神经网络 5 的分类效果进行比较,本文还选取了概率神经网络 4 和 BP 神经网络 3。由以上分析可知,三种网络的输入节点数是相同的,即为各高频段的能量特征向量个数,输出节点数为 1,即网络诊断结果 6,包括励磁电流 7、匝间短路 8、单相接地 9、两相接地 10、两相短路 11 和三相接地 12 六项结果。经过大量的调试后,三种神经网络的分类效果如表 1 所示三种神经网络的分类错误个数,后面的数字代表测试样本的总数目。

[0035]

网络类别	各种故障及其分类错误个数					
	励磁涌流	匝间短路	单相接地	两相接地	两相短路	三相接地
$\sigma = 0.5$	5/90	8/75	10/60	15/81	17/81	9/60
$\sigma = 0.4$	5/90	7/75	9/60	13/81	12/81	8/60
$\sigma = 0.3$	4/90	7/75	8/60	10/81	11/81	6/60
$\sigma = 0.2$	3/90	5/75	5/60	7/81	8/81	5/60
$\sigma = 0.1$	2/90	5/75	4/60	5/81	6/81	4/60
BP	4/90	5/75	5/60	9/81	7/81	6/60
GA-PNN	0/90	3/75	2/60	3/81	4/81	2/60

对比各种网络的分类准确率,可以发现,虽然 BP 神经网络也有不错的表现,但是要经过不断地实验才能确定网络结构,且要经过大量迭代次数后才能训练完毕;概率神经网络的训练过程一次完成,不需要进行权值调整,相比于传统的 BP 神经网络具有更好的泛化能力,收敛速度更快,选择适当的平滑因子可以改善概率神经网络的性能;经过优化后的概率神经网络,具有一定的自适应学习能力,可以根据不同情况选择最优的平滑参数,大大提高了网络的故障识别能力。




图 1




图 2




图 3




图 4




图 5