



(12)发明专利

(10)授权公告号 CN 106096726 B

(45)授权公告日 2018.12.18

(21)申请号 201610379138.6

(22)申请日 2016.05.31

(65)同一申请的已公布的文献号
申请公布号 CN 106096726 A

(43)申请公布日 2016.11.09

(73)专利权人 华北电力大学
地址 102206 北京市昌平区回龙观镇北农
路2号

(72)发明人 周晨轶 刘松 刘鹏

(74)专利代理机构 北京同达信恒知识产权代理
有限公司 11291

代理人 黄志华

(51)Int.Cl.

G06N 3/08(2006.01)

G06Q 50/06(2012.01)

(56)对比文件

CN 103295081 A,2013.09.11,

CN 105429135 A,2016.03.23,

JP H0619870 A,1994.01.28,

US 2015134583 A1,2015.05.14,

Hong-Tzer Yang et al..“Design a Neural Network for Features Selection in Non-intrusive Monitoring of Industrial Electrical Loads”.《IEEE》.2007,

张荣宝.“家庭用户端负载的非侵入式电能监测系统研究”.《机电元件》.2015,(第3期),

Hsueh-Hsien Chang et al..“A New Method for Load Identification of Nonintrusive Energy Management System in Smart Home”.《IEEE》.2010,

审查员 张丽娜

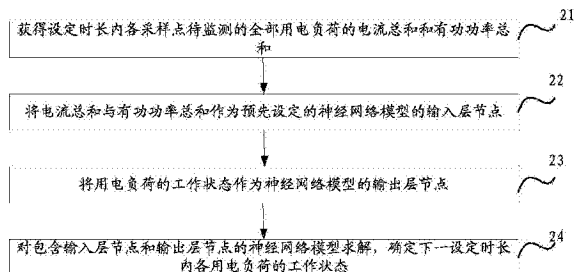
权利要求书2页 说明书10页 附图3页

(54)发明名称

一种非侵入式负荷监测方法及装置

(57)摘要

本发明公开了一种非侵入式负荷监测方法及装置,该方法包括:获得待监测用电负荷在设定时长内各采样点的电流总和和有功功率总和;将所述电流总和与有功功率总和作为神经网络模型的输入层节点;将用电负荷的工作状态作为神经网络模型的输出层节点;按照设定时间段内监测所得的采样数据对所述神经网络模型进行训练;通过训练完成的神经网络模型确定下一设定时长内各用电负荷的工作状态,用于解决现有非侵入式负荷监测方法对设备采样频率要求高、难以有效处理多工作模式负载投入使用的负荷监测问题。



1. 一种非侵入式负荷监测方法,其特征在于,包括:

获得待监测用电负荷在设定时长内各采样点的电流总和和有功功率总和;

将所述电流总和与所述有功功率总和作为神经网络模型的输入层节点;

将用电负荷的工作状态作为所述神经网络模型的输出层节点;

按照设定时间段内监测所得的采样数据对所述神经网络模型进行训练;并

通过训练完成的神经网络模型确定下一设定时长内所述待监测用电负荷中各用电负荷的工作状态;

其中,在将用电负荷的工作状态作为所述神经网络模型的输出层节点之前,还包括:

根据待监测用电负荷在设定时长内各采样点的电流总和,确定每个用电负荷在设定时长内的电流密度曲线;

在所述电流密度曲线中,确定有效峰值点,所述有效峰值点为具有左曲线斜率为正,右曲线斜率为负的预设曲线斜率的峰值点,同时在所述电流密度曲线中对应的电流幅值出现次数大于预设阈值的峰值点;

每个有效峰值点作为所述用电负荷的一种工作状态。

2. 如权利要求1所述的方法,其特征在于,还包括:

按照下述方式校正确定出的下一设定时长内各用电负荷的工作状态的准确率:

准确率 = 正确识别采样个数 / 总采样个数

其中所述正确识别的采样个数包括两类:用电负荷关闭,确定出的用电负荷也关闭;用电负荷工作,确定出用电负荷的工作状态。

3. 如权利要求1~2任一所述的方法,其特征在于,还包括:

按照下述公式确定各用电负荷所对应的能耗值:

$$W_{h-tot} = \frac{U \times \sum_{t=1+60(h-1)}^{t=60+60(h-1)} I_t^{peak} \times \rho}{1000 \times 60}$$

其中, W_{h-tot} 是各用电负荷所对应的每小时的能耗值, I_t^{peak} 第t个采样点估计的电流值,h为时间参数且 $h \in [1, 2, 3 \cdots 24]$,U是额定电压, ρ 为用电器的功率因素。

4. 一种非侵入式负荷监测装置,其特征在于,包括:

获得模块,用于获得待监测用电负荷在设定时长内各采样点的电流总和和有功功率总和;

处理模块,用于将所述电流总和与所述有功功率总和作为预先设定的神经网络模型的输入层节点;将用电负荷的工作状态作为所述神经网络模型的输出层节点;按照设定时间段内监测所得的采样数据对所述神经网络模型进行训练;并

通过训练完成的神经网络模型确定下一设定时长内所述待监测用电负荷中各用电负荷的工作状态;

其中,所述处理模块,还用于根据待监测用电负荷在设定时长内的电流总和,确定每个用电负荷在设定时长内的电流密度曲线;在所述电流密度曲线中,确定有效峰值点,所述有效峰值点为具有左曲线斜率为正,右曲线斜率为负的预设曲线斜率的峰值点,同时在所述电流密度曲线中对应的电流幅值出现次数大于预设阈值的峰值点;每个有效峰值点作为所

述用电负荷的一种工作状态。

5. 如权利要求4所述的装置,其特征在于,所述处理模块,还用于按照下述方式校正确定出的下一设定时长内各用电负荷的工作状态的准确率:

准确率 = 正确识别采样个数 / 总采样个数

其中所述正确识别的采样个数包括两类:用电负荷关闭,确定出的用电负荷也关闭;用电负荷工作,确定出用电负荷的工作状态。

6. 如权利要求4~5任一所述的装置,其特征在于,所述处理模块,还用于按照下述公式确定各用电负荷所对应的能耗值:

$$W_{h-tot} = \frac{U \times \sum_{t=1+60(h-1)}^{t=60+60(h-1)} I_t^{peak} \times \rho}{1000 \times 60}$$

其中, W_{h-tot} 是各用电负荷所对应的每小时的能耗值, I_t^{peak} 第t个采样点估计的电流值,h为时间参数且 $h \in [1, 2, 3 \cdots 24]$,U是额定电压, ρ 为用电器的功率因素。

一种非侵入式负荷监测方法及装置

技术领域

[0001] 本发明涉及电力技术领域,尤其是涉及一种非侵入式负荷监测方法及装置。

背景技术

[0002] 居民用户是智能电网的重要消耗端,也是微电网的重要组成部分。负荷监测技术可以帮助用户了解家中电器使用情况,提高用户参与需求响应的意识,促进用户科学合理用电。此外,在电力需求侧管理、盗电监管、实时电价等多个智能电网的应用领域,负荷监测技术都扮演着关键的角色。

[0003] 目前,负荷监测技术主要分为侵入式负荷监测和非侵入式负荷监测两种。其中,侵入式负荷监测的方法需要在总负荷内部的每个用电器上都配备传感器,该方法虽然准确性高,但可靠性低,实施困难;非侵入式的方法只需在用户的用电入口处安装一个传感器,通过分析监测得到的总负荷数据,来获知用户各用电设备的工作状态和用电功率,该方法成本低,安装方便,是近年来负荷监测技术的研究重点。图1描述了非侵入式负荷监测(non-intrusive load monitoring, NILM)技术在需求响应系统中的作用。通过非侵入式负荷监测技术,能够确定出用户家中各电器的能耗及工作状态。当前NILM技术根据数据来源方式不同主要可分为两类:高频率采样和低频率采样(小于1HZ)。尽管高频率采样的分析方法能够获得更加丰富的电器信息,进而提升负荷辨识的准确率。然而,这类方法的实现需要监测设备具有极高的采样频率,而现有的常规电力设备都无法满足要求,使得这类方法实用性不强。

发明内容

[0004] 本发明提供了一种非侵入式负荷监测方法及装置,能够解决现有非侵入式负荷监测方法对设备采样频率要求高、难以有效处理多工作模式负载投入使用的负荷监测问题。

[0005] 一种非侵入式负荷监测方法,包括:获得待监测用电负荷在设定时长内各采样点的电流总和和有功功率总和;将所述电流总和与所述有功功率总和作为预先设定的神经网络模型的输入层节点;将用电负荷的工作状态作为所述神经网络模型的输出层节点;按照设定时间段内监测所得的采样数据对所述神经网络模型进行训练;并通过训练完成的神经网络模型确定下一设定时长内各用电负荷的工作状态。

[0006] 在将用电负荷的工作状态作为所述神经网络模型的输出层节点之前,还包括:根据待监测用电负荷在设定时长内的电流总和,确定各用电负荷在所述设定时长内各指定采样点对应的工作状态。

[0007] 确定各用电负荷在所述设定时长内各指定采样点对应的工作状态,包括:根据所述电流总和,确定每个用电负荷在设定时长内的电流密度曲线;在所述电流密度曲线中,确定有效峰值点;每个峰值点作为所述用电负荷的一种工作状态。

[0008] 还包括:按照下述方式校正确定出的下一设定时长内各用电负荷的工作状态的准确率:准确率=正确识别采样个数/总采样个数其中所述正确识别的采样点包括两类:用电

负荷关闭,确定出的用电负荷也关闭;用电负荷工作,确定出用电负荷的工作状态。

[0009] 还包括:按照下述公式确定各用电负荷所对应的能耗值:

$$[0010] \quad W_{h-tot} = \frac{U \times \sum_{t=1+60(h-1)}^{t=60+60(h-1)} I_t^{peak} \times \rho}{1000 \times 60}$$

[0011] 其中, W_{h-tot} 是各用电负荷所对应的每小时的能耗值, I_t^{peak} 第t个采样点估计的电流值,h为时间参数且 $h \in [1, 2, 3 \cdots 24]$,U是额定电压, ρ 为用电器的功率因素。

[0012] 一种非侵入式负荷监测装置,包括:

[0013] 获得模块,获得待监测用电负荷在设定时长内各采样点的电流总和和有功功率总和;处理模块,用于将所述电流总和与所述有功功率总和作为预先设定的神经网络模型的输入层节点;将用电负荷的工作状态作为所述神经网络模型的输出层节点;按照设定时间段内监测所得的采样数据对所述神经网络模型进行训练;并通过训练完成的神经网络模型确定下一设定时长内各用电负荷的工作状态。

[0014] 所述处理模块,还用于根据待监测用电负荷在设定时长内的电流总和,确定各用电负荷在所述设定时长内各指定采样点对应的工作状态。

[0015] 所述处理模块,具体用于根据所述电流总和,确定每个用电负荷在设定时长内的电流密度曲线;在所述电流密度曲线中,确定有效峰值点;每个峰值点作为所述用电负荷的一种工作状态。

[0016] 所述处理模块,还用于按照下述方式校正确定出的下一设定时长内各用电负荷的工作状态的准确率:

[0017] 准确率=正确识别采样个数/总采样个数

[0018] 其中所述正确识别的采样点包括两类:用电负荷关闭,确定出的用电负荷也关闭;用电负荷工作,确定出用电负荷的工作状态。

[0019] 所述处理模块,还用于按照下述公式确定各用电负荷所对应的能耗值:

$$[0020] \quad W_{h-tot} = \frac{U \times \sum_{t=1+60(h-1)}^{t=60+60(h-1)} I_t^{peak} \times \rho}{1000 \times 60}$$

[0021] 其中, W_{h-tot} 是各用电负荷所对应的每小时的能耗值, I_t^{peak} 第t个采样点估计的电流值,h为时间参数且 $h \in [1, 2, 3 \cdots 24]$,U是额定电压, ρ 为用电器的功率因素。

[0022] 通过采用上述技术方案,获得待监测用电负荷在设定时长内各采样点的电流总和和有功功率总和,从而确定预先设定的神经网络模型的输入层节点和输出层节点;依据设定时间段内监测所得的采样数据对所述神经网络模型进行训练,进而利用训练好的神经网络模型确定下一设定时长内各用电负荷的工作状态,能够解决现有非侵入式负荷监测方法对设备采样频率要求高、难以有效处理多工作模式负载投入使用的负荷监测问题。

附图说明

[0023] 图1为通常情况中,NILM技术在需求响应系统中的作用;

[0024] 图2为本发明实施例中,提出的非侵入式负荷监测方法流程图;

- [0025] 图3为本发明实施例中,提出的NNPR模型的结构示意图;
- [0026] 图4为本发明实施例中,洗碗机电流密度曲线示意图;
- [0027] 图5为本发明实施例中,实验室搭建的用电数据采集系统示意图;
- [0028] 图6为本发明实施例中,NILM方法得到的实验室各用电器能耗(一个月)示意图;
- [0029] 图7为本发明实施例中,提出的非侵入式负荷监测装置结构组成示意图。

具体实施方式

[0030] 针对现有非侵入式负荷监测方法对设备采样频率要求高、难以有效处理多工作模式负载投入使用的问题,本发明提出技术方案中,利用市面上通用的智能电表搜集用电数据,构建基于神经网络模式识别(neural network pattern recognition, NNPR)的负荷分解模型,在考虑负荷本身特征(电流,有功功率等)的同时,还充分利用了历史监测数据中隐藏的用电信息,用于解决现有非侵入式负荷监测方法对设备采样频率要求高、难以有效处理多工作模式负载投入使用的问题。

[0031] 下面将结合各个附图对本发明实施例技术方案的主要实现原理、具体实施方式及其对应能够达到的有益效果进行详细地阐述。

[0032] 本发明实施例提出一种非侵入式负荷监测方法,针对非侵入式负荷监测问题,如图2所示,其具体处理流程如下述:

[0033] 步骤21,获得待监测用电负荷在设定时长内各采样点的电流总和和有功功率总和。

[0034] 步骤22,将电流总和与有功功率总和作为预先设定的神经网络模型的输入层节点。

[0035] NNPR是近年来模式识别领域一个全新的研究方向,具有鲁棒性、容错性、很强的自学习型等诸多优点。与传统模式识别不同,神经网络模式识别更擅长提取模式之间的隐藏关联。通常来讲,一个完整的神经网络结构可以被划分成三部分,分别是输入层、隐含层和输出层。上下层之间的神经元实现全连接,而同一层的神经元之间无连接。

[0036] 在本发明实施例提出的技术方案中,神经网络模型的输入层节点包含总负荷的特征参数信息。一种较佳地实施方式,神经网络模型的输入层节点包括监测得到的电流总和和有功功率总和。

[0037] 步骤23,将用电负荷的工作状态作为神经网络模型的输出层节点。

[0038] 在本发明实施例提出的技术方案中,神经网络模型的输出层节点是用电负荷的工作状态,输出层节点个数与负荷的工作状态种类相关,具体如下述表1所示。

[0039] 表1

负荷工作状态	输出节点个数(对应关系)
2	1 (0-s ₀ , 1-s ₁)
3	2 (如 01-s ₀ , 10-s ₁ , 11-s ₂)
4	2 (00-s ₀ , 01-s ₁ , 10-s ₂ , 11-s ₃)

[0040]

[0041]	5 3 (如 001-s ₀ , 010-s ₁ , 011-s ₂ , 100-s ₃ , 101-s ₄)
	2 ⁿ⁻¹ +1 至 2 ⁿ n

[0042] 在上述表1中,中s_i代表电器的具体工作模式,n个输出神经元最多可以表示2ⁿ种工作模式。通常家用的用电负荷的工作状态不会超过8种,也就是说神经网络输出节点的个数一般不会超过3。

[0043] 步骤24,按照设定时间段内监测所得的采样数据对所述神经网络模型进行训练;并通过训练完成的神经网络模型确定下一设定时长内各用电负荷的工作状态。

[0044] 在神经网络模式中,通过隐藏层,将输入层和输入层连接,针对隐藏层节点的个数,经验上一般取为输入神经元个数和输出神经元个数的总和。

[0045] 在本发明实施例提出的技术方案中,利用MATLAB建立一个两层前馈神经网络模式识别模型,隐藏层神经元(即隐藏层节点)和输出层神经元(即输出层节点)都使用连续可微的Sigmoid函数进行激励,可表示为:

$$[0046] \quad f\left(\text{net}_j^n(l)\right) = a_j^n(l) = \frac{1}{1 + \exp^{-\text{net}_j^n(l)}} \quad \text{公式 1}$$

[0047] 在上述公式1中, $f\left(\text{net}_j^n(l)\right)$ 表示神经网络第n层的第j个神经元,在第1次训练下的Sigmoid激励函数。其中该神经元的值由下式计算得出:

$$[0048] \quad \text{net}_j^n(l) = \left(\sum_i w_{ij}(l) \cdot a_i^{n-1}(l) \right) - b_j(l) \quad \text{公式 2}$$

[0049] w_{ij}表示节点j到节点i的权值,b_j表示节点j的偏置,l为训练算法迭代次数。

[0050] 举一例进行详细阐述:

[0051] 如图3所示是一个输入层节点个数为2,隐含层节点个数为3,输出层节点个数为1的NNPR模型结构。在本发明实施例提出的技术方案中,对神经网络模型的训练算法采用量化共轭梯度法(scaled conjugate gradient,SCG),将均方误差(mean sum of squares,MSE)作为训练的性能目标,其中MSE计算公式为:

$$[0052] \quad MSE(l) = \frac{1}{2} \sum (t_j(l) - a_j(l))^2 \quad \text{公式 3}$$

[0053] 其中t_j为第j个神经元实际(期望)输出,a_j为网络输出,l为训练算法迭代次数。

[0054] 可选地,在上述步骤23之前,还可以包括:

[0055] 根据待监测用电负荷在设定时长内的电流总和,确定各用电负荷在设定时长内各指定采样点对应的工作状态。

[0056] 根据电流总和,确定每个用电负荷在设定时长内的电流密度曲线,在电流密度曲线中,确定有效峰值点,每个峰值点作为所述用电负荷的一种工作状态。

[0057] NNPR模型输出层神经元个数与符合工作状态的种类密切相关,因此,如何根据历

史监测数据确定待识别负荷的工作状态的种类非常重要。由于电流不会受到供电电压波动的影响,因而相比于有功功率,利用监测得到的电流数据更能够准确的判断出负荷的工作状态。

[0058] 举一例进行详细阐述:

[0059] 为确定待辨识负荷的工作状态的种类,依据得到的历史监测数据,做出各负荷的电流密度曲线。曲线横纵坐标:

[0060] 1) 横坐标为在一个较长监测周期内,对负荷监测得到的所有电流值。

[0061] 2) 纵坐标为各个监测电流值出现的次数。

[0062] 如图4所示,为AMPds数据中洗碗机的电流密度曲线(总采样点个数为524544)。由图4可以快速确定洗碗机有四种工作状态。也就是说,电流密度曲线中每个有效峰值点对应着洗碗机的一种工作状态。

[0063] 具体地,一个有效的峰值点需要满足以下两个条件:

[0064] 第一个条件:峰值点左边曲线斜率为正,右边为负。

[0065] 第二个条件:为确保小峰值点(噪声)不被错误的辨识为一种负荷的工作状态,有效峰值点所对应的纵坐标(电流幅值出现次数)应大于某一阈值。阈值大小不固定,可正确辨识出负荷的工作状态即可。

[0066] 每个有效峰值点所对应的电流值称为用电器在该工作状态下的最大可能电流值(I^{peak})。由于实际监测得到的电流值存在波动,即同一电器在同一状态下监测得到的电流值并不会完全相同。因此,在对训练数据进行标记时,规定了一个20%的真值区间(Ground Truth)。以洗碗机电流数据为例,若监测得到的电流值在0.96与1.44之间($1.2 \pm 20\%$),将洗碗机的工作状态标记为S2。

[0067] 由于低采样频率下负荷的开关事件很难被检测,因而采用非事件触发(non-event based)的监测方法收集用电数据。在本发明实施例提出的技术方案中,通过两组数据来验证所提出NILM方法的有效性。

[0068] 第一组数据是实验室监测得到的用电数据;第二组数据是公开用于NILM研究的数据库(AMPds)数据。第一组数据和第二组数据的共同点有:1) 低频率采样(采样频率1/60HZ);2) 包含电器电流、有功功率、总能耗等用电信息。下面分别进行详细阐述:

[0069] 第一组数据:实验室监测得到的用电数据。

[0070] 为验证所提出NILM方法的有效性,如图4所示,在实验室搭建一个长期有效的用电数据采集系统。每个用电负荷都通过转换插头与一个基于ZigBee协议的智能电表相连,获取各用电负荷的用电数据。如下述表2所示,列取了智能电表能够测量到的所有用电参数。在采样频率为1/60HZ的情况下(每隔1min返回一次信息),采集了5种典型家用电器(即用电负荷)一个月(2015年12月18日至2016年1月18日)的用电数据,包括饮水机,电冰箱,微波炉,空气净化器和电热水壶。这些电器在实验室的工作原则与实际家庭中类似。例如,饮水机和电冰箱一般会连续运行一整天,空气净化器在空气质量不好的情况下工作频率更高。

[0071] 表2

[0072]

名称	单位
电压(V)	V

电流 (I)	A
频率 (f)	Hz
功率因素	ratio
有功功率 (P)	W
视在功率 (S)	VA
总耗电量 (W)	kWh

[0073] 此外,在电脑上安装了两个相关的软件,分别是MySQL和用电信息演示系统 (Power Management System, PMS)。前者 (即MySQL) 是一个数据库管理工具,用于存储和管理搜集到的历史数据。用电信息演示系统是一个用电数据演示系统,能够实时地显示各用电器的用电信息,进而方便确认各个智能电表是否都处于正常的工作状态。

[0074] 第二组数据:用于NILM研究的数据库 (AMPds) 数据。

[0075] 如下述表3所示,不同算法对家庭能源数据的总结。

[0076] 表3

名称	周期	用户数量	采样间隔或频率
REED	3-19 天	6	1 秒与 15kHz
AMPds	1 年	1	1 分钟
Tracebase	N/A	15	N/A
BLUED	8 天	1	12 kHz
ECO	8 个月	6	1 秒

[0077] [0078] 选取AMPds数据进行算法验证的主要原因有:1) 监测周期长 (1年)、数据量大 (每个电表含524544个读数)。短期的监测数据会因为人为、天气等因素的影响,不能够完全真实的反映出家庭能源消耗情况,不利于评判NILM方法的有效性;2) 监测得到的用电信息丰富。AMPds中不仅包含了电器的功率信息,还含有电器的电压、电流、功率因素、总能耗等信息;3) 采样频率低 (1/60HZ)。

[0079] 按照下述方式校正确定出的下一设定时长内各用电负荷的工作状态的准确率:

[0080] 准确率 = 正确识别采样个数 / 总采样个数

[0081] 其中正确识别的采样点包括两类:用电负荷关闭,确定出的用电负荷也关闭;用电负荷工作,确定出用电负荷的工作状态。

[0082] 评估NILM方法有效性的指标有很多,最被广泛使用的是准确率 (accuracy) 和F值 (f-measure)。虽然F值能更精确的衡量NILM方法的性能,但它仅仅适用于简单开关类负荷。由于验证数据中包含多工作模式负载,因此本发明实施例提出的技术方案中,采用识别准确率去测试所提出方法性能。

[0083] 在本发明实施例提出的技术方案中,能够让用户知晓家中主要用电器的具体耗电情况。要想知道各用电器的耗电量。每个采样时刻电器的电流或功率情况。若第t个采样时刻电器工作状态被判断为Si,我们用电器在Si状态下的最大可能电流值表示该时刻电器的真实电流值。因此,电器每个小时的耗电量 (kWh) 可表示为 (采样间隔1分钟)。

[0084] 按照下述公式确定各用电负荷所对应的能耗值：

$$W_{h-tot} = \frac{U \times \sum_{t=1+60(h-1)}^{t=60+60(h-1)} I_t^{peak} \times \rho}{1000 \times 60}$$

[0086] 其中， W_{h-tot} 是各用电负荷所对应的每小时的能耗值， I_t^{peak} 第t个采样点估计的电流值，h为时间参数且 $h \in [1, 2, 3 \dots 24]$ ，U是额定电压， ρ 为用电器的功率因素。

[0087] 在本发明实施例提出的技术方案中，采用表2所示的两组数据进行算法验证。训练时将总数据的70%作为训练集，15%的数据作为验证集，15%的数据作为测试集。训练算法根据训练集中的数据在模型中的均方误差不断修正各个节点的权重和偏置。验证集数据用于测量模型的泛化性能。测试集数据用于评估训练中及训练后神经网络模型的性能，对训练过程没有影响。三种情况可以使训练停止：一是算法的迭代次数达到设定值，二是模型的泛化性能停止增长，三是训练模型的均方误差小于 10^{-6} 。所有的算法验证程序都是基于MATLAB2013a设计的，在拥有2.2GHz CPU和1GB内存的电脑上运行。神经网络训练算法迭代次数最大值设为1000。

[0088] 利用实验室监测得到的用电数据（每个电表含42866个有效数据），结合上述步骤，表4得出了参与实验的5种家用电器的的工作状态详情。分析表4可知，饮水机、电冰箱、微波炉、空气净化器和电热水壶的工作状态种类分别为2、2、4、3和2。

[0089] 表5为算法验证结果，对于参与验证的5种家用电器，本发明实施例提出的技术方案的识别准确率在95%以上。

[0090] 表4

用电器	状态	最大可能电流
饮水机	加热	1 A
	保温	0 A
电冰箱	开	0.5 A
	关	0 A
微波炉	模式 1	5.3 A
	模式 2	3.7 A
	模式 3	0.2 A
	关	0 A
空气净化器	模式 1	0.3 A
	模式 2	0.2 A
	关	0 A
电热水壶	开	7.7 A
	关	0 A

[0091] 表5

用电器	负荷识别准确率 (%)			
	训练集	验证集	测试集	全体
电热水壶	100%	100%	100%	100%
[0093] 电冰箱	95.2%	94.8%	95%	95.1%
饮水机	99.3%	99.4%	99.3%	99.4%
微波炉	99.9%	99.9%	99.9%	99.9%
空气净化器	97.8%	97.7%	97.7%	97.7%

[0094] 对实验室5种电器一个月的耗电量进行计算,结果如图6所示。

[0095] 分析图6可知:若以传统用电信息演示系统监测(侵入式负荷监测)得到的用电数据数据为基准,本发明实施例提出的NILM方法对总能耗估算的误差为 $e\% = |(56.424 - 58.630)| / 56.424 \times 100\% = 3.736\%$ 。

[0096] 以AMPds数据为例,构建用于NILM系统的NNPR模型。分析表6可知,除洗衣机外,本发明实施例提出的技术方案与传统方法相比,能够获得更高的负荷识别准确率。

[0097] 表6

ID	负载	负荷识别准确率	
		本文	文献 [16]
CDE	干衣机	99.7%	97.9%
CWE	洗衣机	94.6%	97.4%
[0098] DWE	洗碗机	98.3%	97.3%
FGE	冰箱	85.2%	55.0%
FRE	暖通空调	86.8%	33.8%
HPE	热泵	93.1%	84.7%
TVE	电视机	62.9%	57.0%
WOE	微波炉	99.7%	99.5%

[0099] 本发明实施例上述提出的技术方案中,对监测设备采样频率要求低、模型简单、可准确分解多工作模式电器的用电负荷。首先,在负荷特征选取时,同时考虑了负载的稳态电流和有功功率;通过改变NNPR模型输出层节点个数,有效解决了多工作模式电器的识别问题。而后利用监测得到的历史用电数据,提出电流密度曲线的概念,确定了负载工作模式种类以及每种工作模式下对应的电流值,并依此对训练数据进行标记(Label)。

[0100] 相应地,本发明实施例还提出一种非侵入式负荷监测装置,如图7所示,包括:

[0101] 获得模块701,用于获得待监测用电负荷在设定时长内各采样点的电流总和和有功功率总和。

[0102] 处理模块702,用于将所述电流总和与所述有功功率总和作为预先设定的神经网络

络模型的输入层节点;将用电负荷的工作状态作为所述神经网络模型的输出层节点;按照设定时间段内监测所得的采样数据对所述神经网络模型进行训练;并通过训练完成的神经网络模型依据设定时间段内监测所得的采样数据对所述神经网络模型进行训练,进而利用训练好的神经网络模型确定下一设定时长内各用电负荷的工作状态。

[0103] 可选地,上述处理模块702,还用于根据待监测用电负荷在设定时长内的电流总和,确定各用电负荷在所述设定时长内各指定采样点对应的工作状态。

[0104] 具体地,上述处理模块702,具体用于根据所述电流总和,确定每个用电负荷在设定时长内的电流密度曲线;在所述电流密度曲线中,确定有效峰值点;每个峰值点作为所述用电负荷的一种工作状态。

[0105] 可选地,上述处理模块702,还用于按照下述方式校正确定出的下一设定时长内各用电负荷的工作状态的准确率:

[0106] 准确率=正确识别采样个数/总采样个数

[0107] 其中所述正确识别的采样点包括两类:用电负荷关闭,确定出的用电负荷也关闭;用电负荷工作,确定出用电负荷的工作状态。

[0108] 可选地,上述处理模块702,还用于按照下述公式确定各用电负荷所对应的能耗值:

$$[0109] \quad W_{h-tot} = \frac{U \times \sum_{t=1+60(h-1)}^{t=60+60(h-1)} I_t^{peak} \times \rho}{1000 \times 60}$$

[0110] 其中, W_{h-tot} 是各用电负荷所对应的每小时的能耗值, I_t^{peak} 第t个采样点估计的电流值,h为时间参数且 $h \in [1, 2, 3 \cdots 24]$,U是额定电压, ρ 为用电器的功率因素。

[0111] 本发明实施例上述提出的技术方案,首先,不仅考虑了负载的自身特性(稳态电流和有功功率),还充分利用到历史监测数据中涵盖的隐藏用电信息。通过构建适用于负荷分解的NNPR模型,可有效提取历史监测数据中的隐藏信息。利用实验室数据和AMPds数据进行算法验证,证明了有效性和准确性。

[0112] 其次,待识别负荷工作状态的类时,充分利用监测所得历史数据,通过建立起各家用电器的电流密度曲线,可快速准确的确定负荷的工作状态种类及各种状态下对应的电流幅值,进而对训练数据进行标记。

[0113] 再次,给出了一种全新的非侵入式负荷能耗估计方法,并与传统侵入式负荷监测方法进行比较,证明了方法的可行性和有效性。

[0114] 最后,所需用电数据可直接由市面上通用的智能电表获得,降低了硬件成本,提高了用户参与需求响应的积极性。此外,由于居民电力负荷组成最为复杂,本发明方法也适用于工业和商业负荷的监测与分解。

[0115] 本领域的技术人员应明白,本发明的实施例可提供为方法、装置(设备)、或计算机程序产品。因此,本发明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,本发明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、只读光盘、光学存储器等)上实施的计算机程序产品的形式。

[0116] 本发明是参照根据本发明实施例的方法、装置(设备)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。

[0117] 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。

[0118] 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。

[0119] 尽管已描述了本发明的优选实施例,但本领域内的技术人员一旦得知了基本创造性概念,则可对这些实施例作出另外的变更和修改。所以,所附权利要求意欲解释为包括优选实施例以及落入本发明范围的所有变更和修改。

[0120] 显然,本领域的技术人员可以对本发明进行各种改动和变型而不脱离本发明的精神和范围。这样,倘若本发明的这些修改和变型属于本发明权利要求及其等同技术的范围之内,则本发明也意图包含这些改动和变型在内。

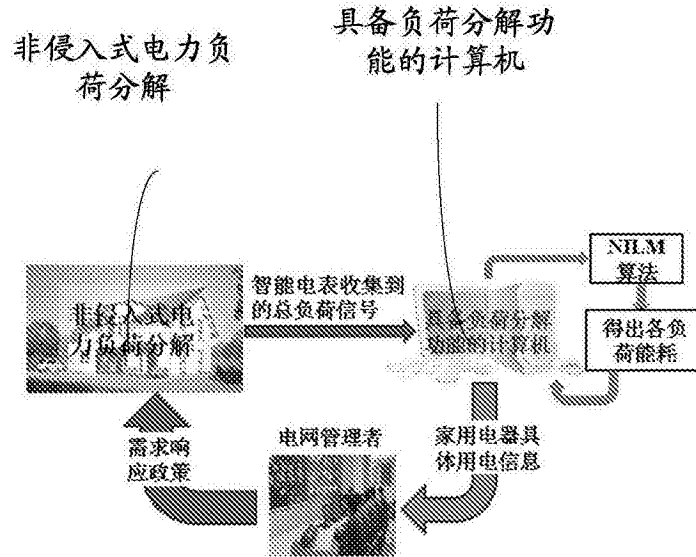


图1

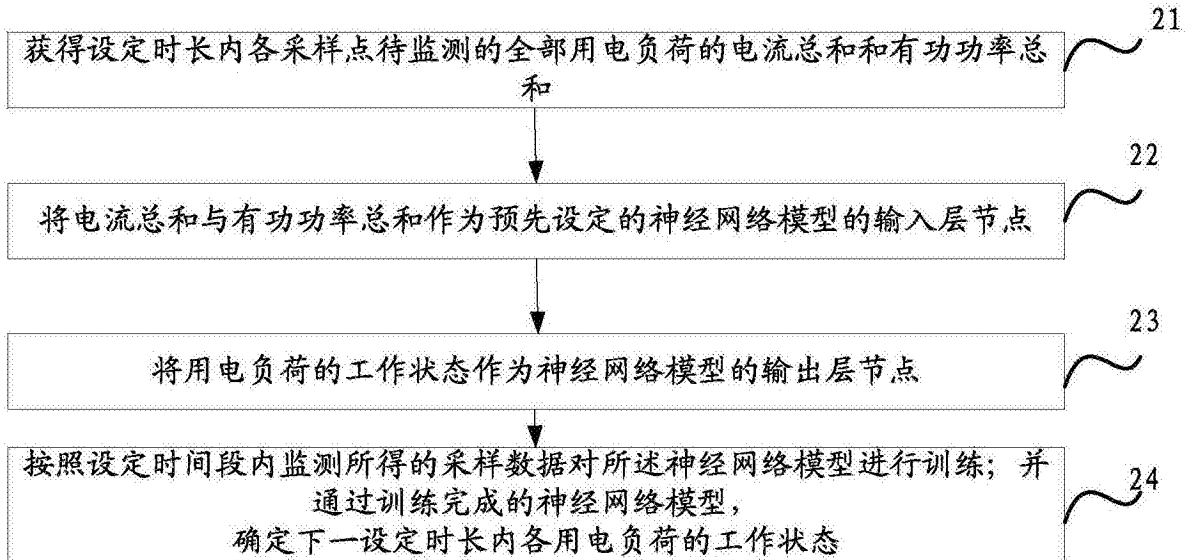


图2




图3




图4




图5




图6




图7