

面向区域级用户的非侵入式负荷监测技术应用方法

陈中¹, 方国权¹, 赵奇², 邢强¹, 徐晓¹

(1. 东南大学 电气工程学院, 江苏 南京 210096; 2. 国网江苏省电力有限公司苏州供电分公司, 江苏 苏州 215004)

摘要:非侵入式负荷监测是一种先进的负荷监测手段,但其现有的应用方案暴露出高能耗、施工复杂的缺点。为此,提出一种面向区域级用户的非侵入式负荷监测技术应用方法。基于现有的用电信息采集系统构建面向区域级用户的非侵入式负荷监测边缘计算模型,基于此,分析非侵入式负荷监测任务分配问题,并采用基于深度学习的任务分配策略生成方法对该问题进行求解,生成最优任务分配策略。某中等规模居民区的算例结果验证了所提方法的可行性,且其比现有应用方法具有更低的能效代价。

关键词:非侵入式负荷监测;边缘计算;任务分配策略;深度学习;用电信息采集系统

中图分类号:TM 714

文献标志码:A

DOI:10.16081/j.epae.202007004

0 引言

随着泛在电力物联网的建设与推广,未来电力用户将会与电网进行更友好紧密的互动^[1]。为了充分挖掘电力用户的互动潜力,需要更好地了解用户的用电特点及其潜在规律^[2],而这一切的基础是能够获得设备级的电力信息。负荷监测能给出用户各用电设备的具体用电信息,从而引导用户了解自身用电习惯、优化用电行为、节约用电成本。对于电网而言,负荷监测能够帮助电网细致地掌握负荷组成和用户的用电行为模式,为电网的规划、发电调度提供指导,为双向互动与智能用电服务提供数据基础^[3-4]。

非侵入式负荷监测 NILM (Non-Intrusive Load Monitoring) 是一种新型的负荷监测手段,目前主要应用于居民侧。与传统的侵入式负荷监测手段相比,其无需在设备侧添加额外的监测装置,仅监测用户总线处的电力信息,再结合不同负荷设备的特性对总负荷信息进行分解与识别,从而获取用户各负荷设备独立的用电情况^[5-6]。

目前在工程应用中,实现非侵入式负荷监测的方式是在智能电表内嵌入具有该功能的模块或是将整个分析过程上移至云平台。文献[7]基于智能电表采集的低频电力数据直接在智能电表内开发具有非侵入式负荷监测功能的计算模块;文献[8]采用树莓派 3B 作为开发平台研制了一种集合数据采集与分析计算功能的非侵入式负荷监测模块;文献[9-10]提出的非侵入式负荷监测实际应用方法均采用云计

算分析,所有电力用户的负荷信息传输至云平台,在云平台上运行算法后将分析结果反馈给用户。

上述2种方案都能满足非侵入式负荷监测技术在居民侧的实际应用要求,但在面向整个区域大量用户推广时也都存在一定缺点。对于内嵌模块的方案,每个智能电表都需要进行更新改装,因此该方案在实际应用时将耗费大量的人力施工与经济消耗;对于云计算的方案,在上传大量用户电力数据的过程中将会产生可观的传输能耗,同时该方案对用电信息采集系统的数据传输能力也提出了巨大挑战。针对这些问题,本文研究一种面向区域级用户的非侵入式负荷监测技术应用方法。首先,在现有用电信息采集系统的基础上结合边缘计算^[11]的概念构建一种服务于区域级用户非侵入式负荷监测的边缘计算模型;然后,研究该模型下的任务分配决策生成方法以优化能效代价。该方法将非侵入式负荷监测技术应用于面向泛在电力物联网的边缘计算框架,具有能效代价低、易于面向区域级用户实施的优点。

1 面向区域级用户的非侵入式负荷监测边缘计算模型

1.1 用电信息采集系统

用电信息采集系统主要由主站、通信信道和采集设备组成^[12]。其中采集设备是最近距离接触用户的,其主要包括智能电表、采集器与集中器。智能电表是最直接的采集设备,负责对用户电压、电流、功率等电力信息进行采集;采集器连接数个智能电表,起到用户数据集中采集和数据本地处理的功能;集中器负责与主站的数据通信,是连接采集器、智能电表与主站的枢纽。通信信道可以划分为本地通信信道和远程通信信道^[13],本地通信信道指智能电表、采集器和集中器之间的通信信道,主要包括低压电力载波通信、无线微功率通信和 RS-485 等;远程通信信道是指集中器与主站层之间的通信链路,包括无

收稿日期:2020-01-02;修回日期:2020-05-09

基金项目:国网江苏省电力有限公司科技资助项目 (SGJSJX00YJJS1800722)

Project supported by the Science and Technology Project of State Grid Jiangsu Electric Power Co., Ltd. (SGJSJX00YJJS1800722)

线专网、光纤等。

对于一个区域内大量居民用户的用电信息采集,常以公用配电变压器台区作为采集单位,集中器通过本地信道连接各楼宇、住宅表箱处的采集器,从而集中该台区内所有的智能电表,实现电力信息采集^[12]。

1.2 面向区域级用户的非侵入式负荷监测边缘计算模型

在用电信息采集系统的基础上结合边缘计算概念,构建一种服务于区域范围内大量居民用户的非侵入式负荷监测边缘计算模型。该模型由电力信息采集设备、本地计算设备、边缘计算设备、区域级云平台以及通信信道构成,模型物理架构如图1所示。




图1 非侵入式负荷监测边缘计算模型物理架构

Fig.1 Physical architecture of non-intrusive load monitoring edge calculation model

图1中本地计算设备是指装有非侵入式负荷监测模块的采集器,每个采集器与一个表箱内的多个智能电表通过本地通信信道保持数据通信,智能电表会以一定频率将对应居民用户的电力信息以报文的形式发送给采集器,因此在采集器处将形成服务于多个用户的非侵入式负荷监测任务队列。边缘计算设备是指部署于台区集中器处的边缘计算服务器,在模型中可将其看作边缘计算节点,其服务于一个台区对应的整个区域,同样具有非侵入式负荷监测的功能。相比于本地计算设备,边缘计算设备拥有更大的数据存储容量和更高的计算速率。

对于非侵入式负荷监测任务队列而言,队列内的每一个任务可以在本地计算设备中执行,也可以通过通信信道上传到边缘计算服务器中执行,这就需要区域级云平台制定合理的任务分配策略。定义能效代价 C 为执行完一个区域内所有任务的能耗与时延的权重之和,云平台在制定策略时应以优化能效代价为目标,同时也需要考虑计算设备的最大计

算能力、信道带宽等约束条件。

1.3 边缘计算模型下的任务分配策略

假设在一个居民区的公用配电变压器台区下共计有 N 台本地计算设备,用向量 $L=[l_1, l_2, \dots, l_N]$ 表示。若每台本地计算设备有 M 个待执行的计算任务,则可以用 $S=[s_{11}, s_{12}, \dots, s_{nm}, \dots, s_{NM}]$ 表示总的任务向量。同时假设第 n 台本地计算设备的第 m 个待执行任务的数据量为 d_{nm} ,则可以用 $d=[d_{11}, d_{12}, \dots, d_{nm}, \dots, d_{NM}]$ 表示总的任务数据量向量。对于每个任务,按照不同的任务分配策略可以在本地计算设备处执行,也可以在边缘计算节点处执行,因此用二进制向量 $x=[x_{11}, x_{12}, \dots, x_{nm}, \dots, x_{NM}]$ 表示区域内所有计算任务的分配策略。当 $x_{nm}=0$ 时,表示第 n 台本地计算设备任务队列中的第 m 个任务将在本地执行;当 $x_{nm}=1$ 时,则表示该任务将在边缘计算节点处执行。

以下分析单个任务执行时的能耗与时延,当任务 s_{nm} 在本地计算设备执行时,用 t_{nm}^l 表示其计算时延:

$$t_{nm}^l = \frac{d_{nm}}{c_1} \quad (1)$$

其中, d_{nm} 为任务 s_{nm} 对应的数据量(bit); c_1 为本地计算设备的平均计算能力(bit/s)。

用 e_{nm}^l 表示任务 s_{nm} 在本地计算设备执行的能耗:

$$e_{nm}^l = t_{nm}^l p_1 \quad (2)$$

其中, p_1 为本地计算设备的平均计算功率(W/s)。

当任务 s_{nm} 在边缘计算节点处执行时,用 t_{nm}^e 表示其总时延, t_{nm}^e 由数据传输时延 t_{nm}^t 和计算时延 t_{nm}^c 组成:

$$t_{nm}^e = t_{nm}^t + t_{nm}^c = \frac{d_{nm}}{b_n} + \frac{d_{nm}}{c_e} \quad (3)$$

其中, b_n 为分配给第 n 台本地计算设备的带宽(bit/s); c_e 为边缘计算节点的计算能力(bit/s)。

同理考虑在边缘计算节点处执行任务 s_{nm} 的能耗:

$$e_{nm}^e = e_{nm}^l + e_{nm}^c = t_{nm}^l p_{up} + t_{nm}^c p_e \quad (4)$$

其中, p_{up} 为本地计算设备上传任务数据至边缘计算节点的平均传输功率; p_e 为边缘计算节点的平均计算功率。

基于上述定义,执行完所有任务所消耗的能量为:

$$E = \sum_{n=1}^N \left[\sum_{m=1}^M e_{nm}^l (1-x_{nm}) + e_{nm}^e x_{nm} \right] \quad (5)$$

由于同一个任务队列中的任务可以在本地设备

和边缘计算节点中并行执行,因此执行完任务队列 $[s_{n1}, s_{n2}, \dots, s_{nM}]$ 的时延 T_n 为:

$$T_n = \max \left\{ \sum_{m=1}^M t_{nm}^l (1 - x_{nm}), \sum_{m=1}^M t_{nm}^e x_{nm} \right\} \quad (6)$$

又由于整个区域内所有采集器处的任务队列间也存在并行执行的关系,因此执行所有任务的总时延 T 为:

$$T = \max \{ T_1, T_2, \dots, T_N \} \quad (7)$$

因此,总的能效代价为:

$$C = \sum_{n=1}^N \left[\sum_{m=1}^M e_{nm}^l (1 - x_{nm}) + e_{nm}^e x_{nm} \right] + \alpha \max \{ T_1, T_2, \dots, T_N \} \quad (8)$$

以能效代价为优化目标,并考虑带宽约束条件,则边缘计算模型下生成区域内所有非侵入式负荷监测任务的最优分配策略可以看作求解一个带约束的最优化问题,如式(9)所示。

$$\begin{cases} \min_{x,b} F(d, x, b) = \min_{x,b} (E + \alpha T) \\ \text{s.t.} & x_{nm} \in \{0, 1\} \\ & \sum_{n=1}^N b_n \leq B \\ & b_n \geq 0 \end{cases} \quad (9)$$

其中, x 为任务分配策略向量, b 为带宽分配策略向量,两者为待优化的参数; α 为优化目标中能耗与时延间的权重系数(J/s),其有单位但没有具体的物理意义,由区域云平台制定,当参数 α 取值为 1 J/s 时,表示云平台认为两优化目标同样重要,在具体应用中可以根据实际需求调整; B 为可供分配的信道带宽总和。

2 基于深度学习的非侵入式负荷监测任务分配策略生成方法

本文 1.3 节中描述的边缘计算模型下的非侵入式负荷监测任务分配以优化能效代价为目标,生成最优的分配策略。其在本质上属于混合整数非线性规划问题,且已被证明是一个 NP-Hard (Non-deterministic Polynomial-time Hardness) 问题^[14],因此有必要降低求解该问题的复杂度。本文依据文献[15-16]中的思想,将该问题分解为整数规划问题和非线性规划问题,综合采用深度学习方法与凸优化方法进行求解。在上述思路的基础上提出一种基于深度学习的区域级非侵入式负荷监测任务分配策略生成方法,如图 2 所示。

图 2 中,首先将输入的数据量向量 d 通过 K 个基于深度神经网络 DNN (Deep Neural Network) 的任务分配策略生成器生成 K 个候选任务分配策略;然后,计算每个候选策略的能效代价,将对应最低能耗




图2 基于深度学习的非侵入式负荷监测任务分配策略生成方法结构图

Fig.2 Architecture of NILM task allocation strategy generation method based on deep learning

代价的策略记为 x^* ;最后,将输出 x^* 与输入 d 结合,共同作为训练样本储存在样本队列中,用于训练 K 个 DNN。开始时,任务策略生成器生成的策略是随机的,此时的最优策略可以看作局部最优解;但通过后续对 DNN 的训练,策略生成器生成的策略逐步得到优化,最终近似生成全局最优解。综上,可以将该方法划分为任务分配策略生成和深度神经网络训练两部分。

2.1 任务分配策略生成

每个任务分配策略生成器的内部结构如图 3 所示。




图3 基于DNN的任务分配策略生成器

Fig.3 Task allocation strategy generator based on DNN

将任务数据量向量 d 作为输入传递给 DNN 的输入层,在经过中间层运算后,最终输出与 d 同维度的任务分配策略向量 x 。因此可以将 DNN 看作由 d 映射到 x 的函数,第 k 个 DNN 的映射函数为:

$$f_{\theta_k}(d) = x^k \quad (10)$$

其中, θ_k 为第 k 个 DNN 的参数; x^k 为其输出的任务分配策略。在给定任务分配策略向量 x^k 后,只需要在此基础上合理分配带宽资源,则原问题就被简化为一个非线性规划问题,如式(11)所示。

$$\begin{cases} \min_{b^k} F(d, x^k, b^k) = \min_{b^k} (E + \alpha T) \\ \text{s.t.} & b_n^k \geq 0 \\ & \sum_{n=1}^N b_n^k \leq B \end{cases} \quad (11)$$

根据文献[17-18],采用凸优化方法处理该非线性规划问题。最终,第 k 个任务分配策略生成器输出候选策略 $\mathbf{x}^k$ 及在该策略下的最优带宽分配,记为 $(\mathbf{x}^k, \mathbf{b}^k)$ 。

2.2 DNN 训练

图2中 K 个基于DNN的任务分配策略生成器均具有相同的结构,但由于其内部DNN的初始参数互不相同,因此对于同一个输入,将生成 K 个不同的候选任务分配策略及其对应的最优带宽分配。基于此,计算每种策略下的能效代价,从而选取 K 个候选策略中最优的任务分配策略,并记为 $\mathbf{x}^*$ 。

在获取 $\mathbf{x}^*$ 后,将 $\mathbf{x}^*$ 与 $\mathbf{d}$ 分别看作标签与数据,共同组成一条带标签的训练样本 $(\mathbf{d}, \mathbf{x}^*)$,并将其存储入一个有限长度的样本队列中。这些样本将用于训练 K 个DNN,使DNN通过对历史最优策略的学习,优化自身参数,从而使生成的策略能逐步得到优化。

在每一次的学习过程中,所有 K 个DNN将共享样本队列中所有的训练样本,但对于单个DNN个体而言,其一次不会学习所有的样本数据,而是随机从样本队列中选取部分样本作为训练数据集。由于DNN的输出为二进制向量,因此选取交叉熵作为损失函数,如式(12)所示。

$$L(\theta_k) = -\mathbf{x}_{tr}^T \log_2 f_{\theta_k}(\mathbf{d}_{tr}) - (1 - \mathbf{x}_{tr})^T \log_2 (1 - f_{\theta_k}(\mathbf{d}_{tr})) \quad (12)$$

其中, $\mathbf{d}_{tr}$ 为训练集样本数据; $\mathbf{x}_{tr}$ 为训练集样本标签。采用梯度下降方法对参数 θ_k 进行优化。

为了避免无效训练,当训练样本数不够充足时,DNN将不会进行训练,只有当样本队列中有足够多的样本后才会触发训练过程。而随着最优分配策略的生成,新的训练样本不断进入队列,旧的训练样本将会溢出,这使得用于训练的样本在整体上也不断被优化更新。综上所述,本文提出的基于深度学习的区域级非侵入式负荷监测任务分配策略生成方法流程如图4所示。

在上述流程中,任务分配策略生成与DNN训练不断交替进行,同时供训练的样本也被不断优化。

3 算例分析

本节将通过算例验证在面向区域级用户时,基于边缘计算的非侵入式负荷监测技术应用方法相较于现有应用方法的优越性,并对本文方法中的边缘计算模型及其求解方法进行性能评估。算例运行于Intel i5-8250 1.8 GHz、8 GB RAM的计算机,采用Tensorflow搭建模型并求解。

本算例模拟一个中型居民区,假设在该居民区公用配电变压器台区的集中器下共有10个采集器,每个采集器下连接10个智能电表,智能电表与采集器之间通过RS-485进行数据传输,采集器与集中器




图4 基于深度学习的非侵入式负荷监测任务分配策略生成方法流程图

Fig.4 Flowchart of NILM task allocation strategy generation method based on deep learning

之间通过宽带载波进行数据传输。在每个采集器处安装具有非侵入式负荷监测功能的计算模块作为本地计算设备,其平均计算能力为 5×10^{-7} bit/s,计算能耗率为 3.5×10^{-7} J/bit;在集中器处安装同样具有非侵入式负荷监测功能的服务器作为边缘计算节点,其计算能力为 5×10^{-6} bit/s,计算能耗率为 1.5×10^{-6} J/bit。进一步假设经各智能电表采集用于非侵入式负荷监测的电力数据量满足均值 $\mu = 30$ Mbit、标准差 $\sigma = 5$ Mbit的正态分布^[19],本地设备向边缘计算节点传输数据时的传输能耗率为 2×10^{-7} J/bit,总通信信道最大带宽为200 Mbit/s^[20]。

将本文方法与2种现有方法进行比较:文献[7-8]所提方法直接在智能电表嵌入计算模块,在本算例情境下对应所有非侵入式监测任务都在本地设备执行的策略(记为全本地节点策略);文献[9-10]所提云端计算方法,在本文算例情境下可以看成所有任务都上传到边缘计算服务器中执行的策略(记为全边缘节点策略)。在本文方法中,非侵入式负荷监测任务的执行策略更为灵活,其既可以在本地执行也可以在边缘计算节点执行,采用基于深度学习的策略生成方法生成最优任务分配策略。

引入穷举法作为基准算法,该算法将遍历所有可能的 2^M 个任务分配策略,计算其对应的能效代价并挑选出最优策略。该算法是一种不计计算成本的方法,但通过其获得的最优策略一定是全局最优策略。定义优化相似度OS(Optimization Similarity)表示待比较策略对应的能效代价与全局最优策略对应的能效代价的相似程度:

$$F_{os} = \frac{C_e^*}{C} \times 100\% \quad (13)$$

其中, F_{os} 为优化相似度; C^* 为由待比较策略计算所得能效代价; C_e^* 为根据穷举法得到的最优分配策略计算所得能效代价。相似度越接近于1,说明待比较的分配策略越接近于全局最优策略,在该策略下分配非侵入式负荷监测任务对应的能效代价越小。

考虑到在大多数情况下非侵入式负荷监测的分析结果对实时性的要求不高,而更看重整个分析过程消耗的能量,因此在综合考虑常见情况与特殊情况下优化目标中能耗与时延比重的基础上,限定优化目标权重参数 α 取值范围为 $0 \sim 1.5 \text{ J/s}$:当 $\alpha=0$ 时,优化策略完全不考虑时延;当 $0 < \alpha < 1 \text{ J/s}$ 时,优化策略受能耗影响更大;当 $1 \text{ J/s} < \alpha \leq 1.5 \text{ J/s}$ 时,优化策略受时延影响更大;当 $\alpha=1 \text{ J/s}$ 时,能耗与时延在优化中被同权重考虑。在不同的 α 取值下,分别计算3种任务分配策略相对全局最优策略的优化相似度,如图5所示。




图5 不同 α 取值下3种任务分配策略的优化相似度
Fig.5 Optimization similarity of three task allocation strategies with different values of α

由图5可以看出,当权重参数满足 $0 \leq \alpha \leq 1.5 \text{ J/s}$ 时,DNN生成的任务分配策略的能效代价均低于现有方法所对应策略的能效代价,且与全局最优策略间的相似度均能维持在0.9以上。同时随着权重 α 的增大,2种现有方法所对应的任务分配策略效果均大幅受到影响,全本地节点策略的优化相似度从0.88下降至0.6以下,全边缘节点策略的优化相似度从0.9下降至0.7,而由DNN生成的任务分配策略的优化相似度仅由0.96下降至0.9。由此可以得出,本文方法相较于现有方法能取得更小的能效代价,且对于优化目标的不同权重参数具有较好的鲁棒性。

接下来讨论不同模型参数对本文方法的影响。模型参数包括梯度下降算法的学习率 r 、用于储存训练样本的样本队列长度 L 和DNN的数量 K 。

图6展示了不同的学习率对优化相似度的影响。




图6 不同学习率下的优化相似度

Fig.6 Optimization similarity for different learning rates

由图6可知,当学习率取0.00001时,优化相似度的收敛速度较为缓慢,随着学习率的增大,收敛速度也随之加快,且最终基本能收敛于0.95以上;但若学习率取值过高(0.1),则将出现策略陷入局部最优的情况,该情况下优化相似度经过波动后下降至0.85。

图7展示了不同的训练样本队列长度对优化相似度的影响。




图7 不同训练样本队列长度下的优化相似度

Fig.7 Optimization similarity for different lengths of training sample queue

由图7可知,在一定范围内不同的训练样本队列长度并不会影响生成任务分配策略的最终优化相似度,而只会影响收敛速度,样本队列越长,收敛速度越慢。

本文算例共计需要对100个非侵入式负荷监测任务进行分配,即任务规模 $S=100$,根据任务规模按一定比例(1%、3%、5%、10%和20%)设定任务分配策略生成方法中DNN数量 K 的取值,并分别在不同 K 值下生成任务分配策略。图8展示了DNN数量 K 对优化相似度的影响。

如图8所示,当DNN数量为1时,优化相似度无法收敛,最优任务分配策略并不能取得较理想的效




图8 不同DNN数量下的优化相似度

Fig.8 Optimization similarity for different numbers of DNN

果,其优化相似度在0.8上下波动,这说明1个DNN无法从训练样本数据中学习有助于生成更优策略的信息。而当DNN数量为3、5、10和20时,经过约2 500步的训练后,优化相似度均能收敛至0.95以上,且优化相似度随DNN数量增多而提高。

本文算例同时分析了不同 K 取值下生成任务分配策略所需消耗的时间。当DNN数量分别为1、3、5、10、20时,对应的任务分配策略生成时间分别为3.1、4.2、4.9、6.1、10.6 s。基于上述实验结果,综合考虑优化效果和优化过程所消耗的时间,DNN数量 K 取值选取任务规模的5%和10%为宜。

4 结论与展望

随着非侵入式负荷监测技术在居民侧的进一步推广,现有的技术应用方案存在施工复杂、高经济成本或高能耗的缺点。为了解决这些在应用中可能出现的问题,本文提出一种基于边缘计算模型的非侵入式负荷监测技术应用方法,该方法中非侵入式负荷监测任务可以灵活地在本地或边缘节点处执行。本文基于DNN,以优化所有任务执行完所需的能效代价为目标生成任务分配策略。算例分析了不同模型参数对策略生成模型收敛效果的影响,对参数选取给出了指导意见。经算例验证可以得出以下结论:本文方法相较于现有方法具有更低的能效代价;本文方法对于优化目标权重参数的改变鲁棒性更强,因此更适用于非侵入式负荷监测技术面向大规模用户的应用场景。

如何进一步结合工程实际,将本文方法应用于更复杂、更庞大的区域级用户场景,以及如何进一步精细化边缘计算模型,在实际应用场景下生成更具体的任务分配方案,以验证本文方法的实际可行性和有效性,将在后续研究中进一步完善。

参考文献:

[1] 王守相,葛磊蛟,王凯. 智能配电系统的内涵及其关键技术[J]. 电力自动化设备,2016,36(6):1-6.
WANG Shouxiang, GE Leijiao, WANG Kai. Main contents and

key technologies of smart distribution system[J]. Electric Power Automation Equipment, 2016, 36(6): 1-6.

[2] 李俊雄,黎灿兵,曹一家,等. 面向智能电网的互动式节能调度初探[J]. 电力系统自动化,2013,37(8):20-25.

LI Junxiong, LI Canbing, CAO Yijia, et al. Preliminary investigation on interactive energy-saving dispatch oriented to smart grid[J]. Automation of Electric Power Systems, 2013, 37(8): 20-25.

[3] 程祥,李林芝,吴浩,等. 非侵入式负荷监测与分解研究综述[J]. 电网技术,2016,40(10):3108-3117.

CHENG Xiang, LI Linzhi, WU Hao, et al. A survey of the research on non-intrusive load monitoring and disaggregation[J]. Power System Technology, 2016, 40(10): 3108-3117.

[4] 涂京,周明,宋旭帆,等. 基于监督学习的非侵入式负荷监测算法比较[J]. 电力自动化设备,2018,38(12):128-134.

TU Jing, ZHOU Ming, SONG Xufan, et al. Comparison of supervised learning-based non-intrusive load monitoring algorithms[J]. Electric Power Automation Equipment, 2018, 38(12): 128-134.

[5] 刘兴杰,曹美晗,许月娟. 基于改进鸡群算法的非侵入式负荷监测[J]. 电力自动化设备,2018,38(5):235-240.

LIU Xingjie, CAO Meihan, XU Yuejuan. Non-intrusive load monitoring based on improved chicken swarm optimization algorithm[J]. Electric Power Automation Equipment, 2018, 38(5): 235-240.

[6] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.

[7] 蔡志强. 基于智能电表的非侵入式负荷识别算法研究[D]. 天津:天津大学,2017.

CAI Zhiqiang. Research on non-intrusive load identification algorithm based on smart meter[D]. Tianjin: Tianjin University, 2017.

[8] 吴恒. 面向非侵入式负荷监测的电器运行数据采集系统[D]. 武汉:华中科技大学,2018.

WU Heng. Electrical operating data acquisition for non-intrusive load monitoring[D]. Wuhan: Huazhong University of Science and Technology, 2018.

[9] KONG W C, DONG Z Y, MA J, et al. An extensible approach for non-intrusive load disaggregation with smart meter data[J]. IEEE Transactions on Smart Grid, 2018, 9(4): 3362-3372.

[10] MENGISTU M A, GIRMAY A A, CAMARDA C, et al. A cloud-based on-line disaggregation algorithm for home appliance loads[J]. IEEE Transactions on Smart Grid, 2019, 10(3): 3430-3439.

[11] 刘思放,邓春宇,张国宾,等. 面向居民智能用电的边缘计算协同架构研究[J]. 电力建设,2018,39(11):60-68.

LIU Sifang, DENG Chunyu, ZHANG Guobin, et al. Research on collaborative architecture for edge computing of residential intelligent usage of electricity[J]. Electric Power Construction, 2018, 39(11): 60-68.

[12] 汪宗达. 智能电表数据采集系统的应用研究[D]. 天津:天津大学,2015.

WANG Zongda. Applied research of smart meter data acquisition system[D]. Tianjin: Tianjin University, 2015.

[13] 陆俊,李子,朱炎平,等. 智能配用电信息采集业务通信带宽预测[J]. 电网技术,2016,40(4):1277-1282.

LU Jun, LI Zi, ZHU Yanping, et al. Communication bandwidth prediction for information gathering services in power distribution and utilization of smart grid[J]. Power System Technology, 2016, 40(4): 1277-1282.

[14] 董浩,张海平,李忠金,等. 移动边缘计算环境下服务工作流的

- 计算卸载[J]. 计算机工程与应用, 2019, 55(2): 36-43.
- DONG Hao, ZHANG Haiping, LI Zhongjin, et al. Computation off-loading for service workflow in mobile edge computing[J]. Computer Engineering and Applications, 2019, 55(2): 36-43.
- [15] YOU C S, HUANG K B, CHAE H, et al. Energy-efficient resource allocation for mobile-edge computation offloading[J]. IEEE Transactions on Wireless Communications, 2017, 16(3): 1397-1411.
- [16] XU D, LI Q, ZHU H B. Energy-saving computation offloading by joint data compression and resource allocation for mobile-edge computing[J]. IEEE Communications Letters, 2019, 23(4): 704-707.
- [17] CHEN X, JIAO L, LI W Z, et al. Efficient multi-user computation offloading for mobile-edge cloud computing[J]. ACM Transactions on Networking, 2016, 24(5): 2795-2808.
- [18] WANG S Q, TUOR T, SALONIDIS T, et al. Adaptive federated learning in resource constrained edge computing systems[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(6): 1205-1221.
- [19] TRAN T X, POMPILI D. Joint task offloading and resource allocation for multi-server mobile-edge computing networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(1): 856-868.
- [20] 李靖波, 刘晓忠. 低压电力用户用电信息采集本地通信方式比较[J]. 电力系统通信, 2010, 31(8): 61-65.
- LI Jingbo, LIU Xiaozhong. Comparison of three local communication modes used by low-voltage power consumption information collection system[J]. Telecommunications for Electric Power System, 2010, 31(8): 61-65.

作者简介:



陈 中

陈 中(1975—),男,江苏丹阳人,研究员,博士,主要研究方向为电力系统稳定运行与控制、FACTS的应用、新能源并网(E-mail: zhongchen@seu.edu.cn);

方国权(1994—),男,江苏南通人,硕士研究生,通信作者,主要研究方向为人工智能在电力系统中的应用(E-mail: 220172691@seu.edu.cn);

赵 奇(1989—),男,江苏苏州人,工程师,主要研究方向为电力系统自动化(E-mail: qzhao1989@163.com)。

(编辑 王锦秀)

Application method of non-intrusive load monitoring technology for region-level users

CHEN Zhong¹, FANG Guoquan¹, ZHAO Qi², XING Qiang¹, XU Xiao¹

(1. School of Electrical Engineering, Southeast University, Nanjing 210096, China;

2. Suzhou Power Supply Company of State Grid Jiangsu Electric Power Co., Ltd., Suzhou 215004, China)

Abstract: Non-intrusive load monitoring is an advanced means of load monitoring, but the existing application schemes expose the disadvantages of high energy consumption and complex construction, for which, an application method of non-intrusive load monitoring technology for region-level users is proposed. An edge calculation model of non-intrusive load monitoring based on the existing power information collection system is built for regional-level users. On this basis, the task allocation problem of non-intrusive load monitoring is analyzed, a task allocation strategy generation method based on deep learning is used to solve the problem, and the optimal task allocation strategy is generated. The results of a case with a medium-sized residential area verify the feasibility of the proposed method, and it has lower energy efficiency cost than the existing application methods.

Key words: non-intrusive load monitoring; edge computing; task allocation strategy; deep learning; electricity information collection system