

智能电网系统中费控服务的优化调度研究

史玉良^{1,2)} 张 坤^{1,2),3)} 荣以平⁴⁾ 朱伟义⁴⁾ 陈志勇¹⁾

¹⁾(山东大学软件学院 济南 250101)

²⁾(山大地纬软件股份有限公司 济南 250101)

³⁾(济南大学信息科学与工程学院 济南 250022)

⁴⁾(国网山东省电力公司 济南 250001)

摘 要 智能电网系统中,费控指令通过应用服务器集群被下发到前置服务器集群,再通过前置服务器集群被下发到终端,终端接收到指令后将指令下发到特定的智能电表。在这个过程中,应用服务器集群和前置服务器集群的可用资源不对等,导致负载不均衡,影响费控服务执行的效率和成功率;前置服务器集群中前置机与终端的固定匹配方式,容易导致前置服务器集群负载不均衡,延长了费控指令完成时间,降低了费控服务的执行效率。为此深入研究费控指令的下发过程,分析存在的问题和瓶颈,提出了一种基于负载预测和负载均衡的费控服务优化调度模型。该模型首先提出一种基于时间序列的负载预测方法,实现服务器负载的预测;基于预测负载,提出一种费控指令的均衡下发算法,为不同负载的服务器下发合适规模的费控指令,以提高指令下发的效率和成功率;针对前置服务器集群可能出现的负载不均衡,提出一种基于图聚类的终端均衡布局算法。实验结果表明,本文提出的费控服务优化调度模型,均衡了两个集群和终端之间的负载,有效提高了费控指令下发的效率和成功率。

关键词 智能电网;智能服务;调度优化;费控指令;资源管理

中图法分类号 TP391 DOI号 10.11897/SP.J.1016.2020.00272

Research on Optimized Scheduling for Cost Control Service in Smart Grid System

SHI Yu-Liang^{1,2)} ZHANG Kun^{1,2),3)} RONG Yi-Ping¹⁾ ZHU Wei-Yi⁴⁾ CHEN Zhi-Yong¹⁾

¹⁾(School of Software, Shandong University, Jinan 250101)

²⁾(Dareway Software Co., Ltd., Jinan 250101)

³⁾(School of Information Science and Engineering, University of Jinan, Jinan 250022)

⁴⁾(State Grid Shandong Electric Power Company, Jinan 250001)

Abstract The cost control instructions are generated and processed in the application server cluster, and then are sent to the front-end server cluster. The front-end server cluster receives the cost control instructions and then sends them to the specific terminals. After receiving these cost control instructions, the terminals send them to the specific smart electricity meter. The status information of smart electricity meters could also be collected and processed in the application server cluster. In this cost control instruction delivery process, the load imbalance issue becomes the influencing factor which affects the success rate and efficiency of cost control service delivery. The load imbalance caused by available resource inequality between application server cluster and

收稿日期:2018-06-05;在线出版日期:2019-05-05。本课题得到国家重点研究发展计划项目(2018YFB1003804)、山东省泰山产业领军人才工程专项经费(tscy20150305)、山东省重点研发计划(2016ZDJS01A09)、山东省自然科学基金重大基础研究项目(ZR2017ZB0419)资助。史玉良,博士,教授,中国计算机学会(CCF)会员,主要研究领域为服务计算、大数据、隐私保护。E-mail: shiyuliang@sdu.edu.cn。张 坤,博士,讲师,中国计算机学会(CCF)会员,主要研究方向为云计算、数据挖掘、隐私保护。荣以平,高级工程师,主要研究方向为电力市场营销、电力信息管理。朱伟义,高级工程师,主要研究方向为电力市场营销、电力信息管理。陈志勇,副教授,主要研究方向为云计算软件架构、服务计算、协同推荐。

front-end server cluster could affect the cost control instruction delivery process. It could lower the execution success rate and efficiency of cost control service delivery. In addition, the stationary mapping between front-end servers and terminals is not appropriate for the dynamic cost control instruction delivery environments. It could give rise to the imbalance in front-end server cluster. The cost control instructions would be sent to the front-end server with heavy load, in which could extend the execution time of cost control service and lower the cost control instruction delivery efficiency. For the above issues in the cost control instruction delivery process, this paper deeply examines and studies the process of cost control instruction delivery, analyzes the problems and bottlenecks of the delivery process. For the load imbalance in the cost control instruction delivery process, this paper proposes an optimized scheduling model at cost control service in smart grid system based on server loads prediction and load balancing, which could alleviate the load imbalance issue and improve the execution success rate and efficiency of cost control service. In this model, a load prediction approach based on time-series data is proposed to predict the server load of application server and front-end server. The accurate prediction of server load is the basis and premise of optimized scheduling for cost control instruction delivery service. Then cost control instruction balancing sending algorithm is proposed based on the predicted server load. It could select the appropriate set of cost control instructions and send them to the appropriate server according to the predicted load. This could improve the execution success rate of cost control service and the delivery efficiency. Considering the imbalance issue in front-end server cluster, a terminal balance distribution algorithm based on graph clustering is proposed. Combining the cost control instruction history and the present cost control instructions, the associations between terminals are analyzed. These terminals are then clustered. Then the association between front-end servers and terminals are dynamically adjusted to improve the success rate and efficiency of cost control instruction delivery. Experiments demonstrate that the proposed optimized scheduling model not only make balance between sever cluster and terminals, but also improve the success rate and efficiency of cost control service.

Keywords smart grid; intelligent service; scheduling optimization; cost control instruction; resource management

1 引言

随着国家电网公司用电系统信息化建设的逐步推进,智能电网时代悄然到来.智能用电是智能电网系统中最贴近用户的部分,直接关乎用户的使用体验.用电费用控制(简称费控)是智能电网系统与用户交互的一项重要服务.在用电过程中,智能电网系统中的终端设备每天将用户用电信息上送到服务端,服务端根据客户用电信息对客户电量、电费进行测算,根据测算结果对客户智能电表下发预警、停电、复电等控制指令.费控是智能电网的一项重要业务,要求必须具有极高的稳定性、可靠性和执行效率,尤其是复电指令,必须及时执行,避免用户投诉.

随着远程费控用户的不断增加,每天需下发的费控指令数量不断增多,如何确保费控指令的及时下发、提高费控指令的下发效率已经成为一个亟待解决的问题.

目前已有很多研究者针对费控指令下发效率问题展开研究.高鲁鑫等人^[1]针对费控过程中 GPRS 通信延迟较高、电力载波通信延迟以及失败率高的问题,提出了以“边收边发”的通讯模式代替原有“一问一答”的通讯模式,并给采集设备增加缓存费控命令的能力,以有效地提升费控执行效率和成功率.莫文昊等人^[2]提出通过改变状态字以及指令的方式定制新的远程费控流程以提高远程费控的成功率与可靠性.这些研究中通过优化费控流程提高费控效率的思想对本文研究有一定的参考价值,但是这些

方案一方面终端改造升级代价较大,另一方面没有考虑前置机负载不均衡导致的效率低下问题。

为此,本文提出了一种费控服务的优化调度模型,该模型能够基于原有的终端设备,考虑服务器未来的负载变化和负载均衡,充分利用服务器的资源下发费控指令,有效提高了费控指令下发服务的执行效率。本文的主要贡献如下:

(1) 提出一种基于时间序列的服务器负载预测方法。根据历史记录中的负载信息,建立负载时间序列,使用移动平均法对下一时间段服务器的负载进行预测,为费控指令服务的调度执行提供支撑。

(2) 提出一种基于负载预测结果的费控指令均衡下发算法。基于应用服务器和前置机的负载预测结果以及待下发指令集的情况,合理选择指令进行下发以达到指令下发总耗时最小的目的。

(3) 提出一种基于图聚类的终端均衡布局算法。根据历史指令信息,结合待下发指令集的情况,分析终端间的关联度,使用图聚类算法将终端聚类,根据聚类结果,动态调整前置机与终端的连接关系,实现前置机集群负载均衡,提高费控指令下发的效率和成功率。

本文第 2 节分析总结相关工作;第 3 节给出费控服务优化调度的问题定义及模型;第 4 节介绍基于时间序列的服务器负载预测方法;第 5 节介绍基于负载预测结果的指令均衡下发算法;第 6 节介绍基于图聚类的终端均衡布局算法;第 7 节进行实验;最后对本文进行总结。

2 相关研究

费控作为智能电网的重要组成部分,受到国内外工业界和学术界的广泛关注。

在国内,电网管理智能化、远程费控管理成为未来电力公司管理电费的发展方向。从 2010 年起,在国家电网的号召下,各供电公司朝着“全采集、全覆盖、全费控”的目标前进,目前主要采用的模式仍然以“后付费”为主,大多采取本地费控的方式,不能满足多样化费控业务的需求,无法实现费控的自动化和智能化。在国外,很多电力公司,如美国德克萨斯电力公司、法国电力集团公司、以色列电力公司等,尝试从“后付费”模式转到“预付费”模式,以期降低成本、方便客户等。若费控指令无法及时下发,尤

其是复位指令,会造成电力用户满意度下降,这对费控指令的下发提出了更高的要求和挑战。

针对该问题,有研究者通过对设备的升级、对通讯协议的改进等方法提高费控指令下发的效率。高鲁鑫等人^[1],提出以“边收边发”的通讯模式代替原有“一问一答”的通讯模式,增加采集设备缓存费控命令的能力,在一定程度上提高了费控执行效率以及成功率。莫文昊等人^[2]通过定制新的远程费控流程以提高远程费控的成功率与可靠性。这些研究都是基于对费控智能终端以及通讯协议的优化,这些优化虽然能在一定程度上提高了费控效率以及成功率,但是需要对已部署好的终端进行升级改造,改造代价太高。

另一方面,也有研究者从服务器资源利用的角度出发,通过负载预测和负载均衡,有效提高费控指令的下发效率。

在服务器负载预测方面,很多研究者对该问题进行了研究并提出了一些有效的解决方案。文献[3]针对云中负载预测问题,提出一种新的调整支持向量回归(TSVR)方案,通过混合遗传算法和粒子群优化方法仔细选择三个 SVR 参数。该算法设计了混沌序列,以提高预测精度,同时避免过早收敛。文献[4]同样针对云中负载预测问题,设计了基于贝叶斯模型的预测方法,以预测长期时间间隔内的平均负荷以及连续未来时间间隔的平均负荷。文献[5]中的负载预测方案使用自动编码器作为回波状态网络的预先特征层,目的是基于 Google 集群使用数据集来预测未来间隔中的主机负载。文献[6]提出了一种新的方法来对虚拟机进行主机过载检测的资源需求进行长期预测。文献[7]针对云服务中心的资源分配提出了灰色波形预测算法。文献[8]提出了基于神经网络的负载预测算法。这些研究提出的预测算法,虽然能有效地进行预测,但是,一方面有些算法时间复杂度太高,计算代价太大;另一方面,没有考虑负载变化过程中存在的周期性规律。为此,本文提出了基于横向时间序列(时序性)和纵向时间序列(周期性)的负载预测模型。

负载均衡的目标是减少服务的执行时间,负载均衡技术在计算机领域用途广泛,相关的研究也有很多。现有的负载均衡技术根据其实现方式不同,主要分为静态负载均衡和动态负载均衡两种。静态负载均衡根据服务器现有任务情况和负载特性,通过

调度算法预先制定一个分配策略来分配、执行任务^[9-10]。动态负载均衡需要在系统运行过程中实时监测负载信息,动态地计算负载情况并根据负载进行任务调度,以达到整个系统的负载平衡。动态负载均衡算法中常用的两种负载均衡算法是最小连接调度算法和轮转算法。最小连接调度算法在把新的连接请求分配到当前连接数最小的服务器,有时还可能加入权值来表示服务器的处理性能并可以动态地调整其权值,此时称为加权最小连接调度算法^[11-12]。加权轮转调度算法采用相应的权值表示服务器的处理性能,考虑到集群中各服务器处理能力之间的差异,为每个服务器分配指定权重的连接^[13]。通过这种权值与轮询相结合的方式使高性能的服务器优先收到访问请求,从而获得较多的连接。但该算法仍是一种无状态调度,在集群服务器具有较大处理时长的情况下,依然会负载失衡。CAN^[14]和Chord^[15]系统在均衡负载时,假设了节点能力以及每个资源带来的负载是相同的,CFS^[16]使用虚拟服务器来解决负载均衡,考虑了节点能力差异。文献^[17]提出了三种负载均衡算法:一对一、一对多、多对多,算法基本思想是将过载节点的压力平衡给非过载节点。然而,上述负载均衡算法的前提都是请求可以在任意服务器上进行处理,而本文中指令只能由前置服务器集群中特定的一台前置机处理,两者情况略有不同。为此,本文提出了基于图聚类的终端均衡布局方案解决前置机负载均衡问题。

综上所述,已有研究成果虽然已经提出了很多方法,但是这些方法并不能直接解决本文的问题。因此,本文参考这些研究成果,基于实际的环境提出了一种基于负载预测和负载均衡的费控指令服务优化调度模型。该模型不仅提高了费控指令下发效率和成功率,同时也提高了集群的资源利用率。

3 费控服务优化调度模型

3.1 问题描述

智能电网系统的架构可以分为三个层次:应用服务器集群、前置服务器集群以及智能用电设备,其架构及费控指令下发的主要流程如图1所示。应用服务器集群负责执行用户提交的各种计算任务(如数据采集任务、数据计算任务、费控指令下发任务等),费控指令下发任务只是应用服务器集群需要提

供的服务之一,该任务需要依托数据采集任务、数据计算任务等其他任务的输出结果。前置服务器集群由大量的通信前置机组成,每台前置机连接一定数量的智能终端,负责与智能终端的直接交互。智能用电设备包括智能终端和智能电表,每个智能终端对应多块智能电表,负责采集相应电表的用电信息以及向电表下发费控指令,智能电表可以记录每个用户的各种用电信息并具有预警功能。

智能电网系统中,终端采集电表数据,然后上送到前置机,前置机将上送的用电信息写入到智能电网系统的数据库中。应用服务器集群根据采集到的用电信息进行用电量、电费等计算,得到需要下发的预警、停电、复电等费控指令,基于指令下发调度算法将这些指令下发给前置服务器集群。前置机负载均衡器根据终端-前置机对应关系将指令分发到特定的前置机,并由前置机负责将指令下发到特定的智能终端。终端-前置机对应关系可以根据需要动态调整。智能终端接收到指令后通过穿透将指令下发给特定的智能电表。

在费控指令下发的过程中,以下环节会影响费控指令的下发效率和成功率:

(1)应用服务器集群负责费控指令的生成和分发,同时还承担其他任务执行的职责。为此,费控指令下发需要考虑集群在不同时间点的负载情况,在保证指令下发效率的同时兼顾其他任务的执行效率。

(2)根据前置机与智能终端的对应关系,应用服务器集群将费控指令下发到对应的前置机,前置机将费控指令下发到相应的终端。前置服务器的负载不均衡可能会导致指令下发任务的总时间增长。为此,费控指令下发需要考虑前置服务器的负载均衡,以确保费控指令的下发效率。

(3)智能终端接收到指令后通过穿透将指令下发给特定的智能电表。终端与其下挂接的电表是通过广播进行通讯的,多个同时下发的指令和响应会相互干扰导致数据异常,因此每次只能向一台智能电表下发指令,违背此原则将导致下发成功率大大地降低。

为此,本文对费控指令的下发过程进行优化,提出了基于负载预测与均衡的费控指令下发过程优化模型,能够有效均衡服务器集群和终端的负载,提高费控指令下发的效率和成功率。

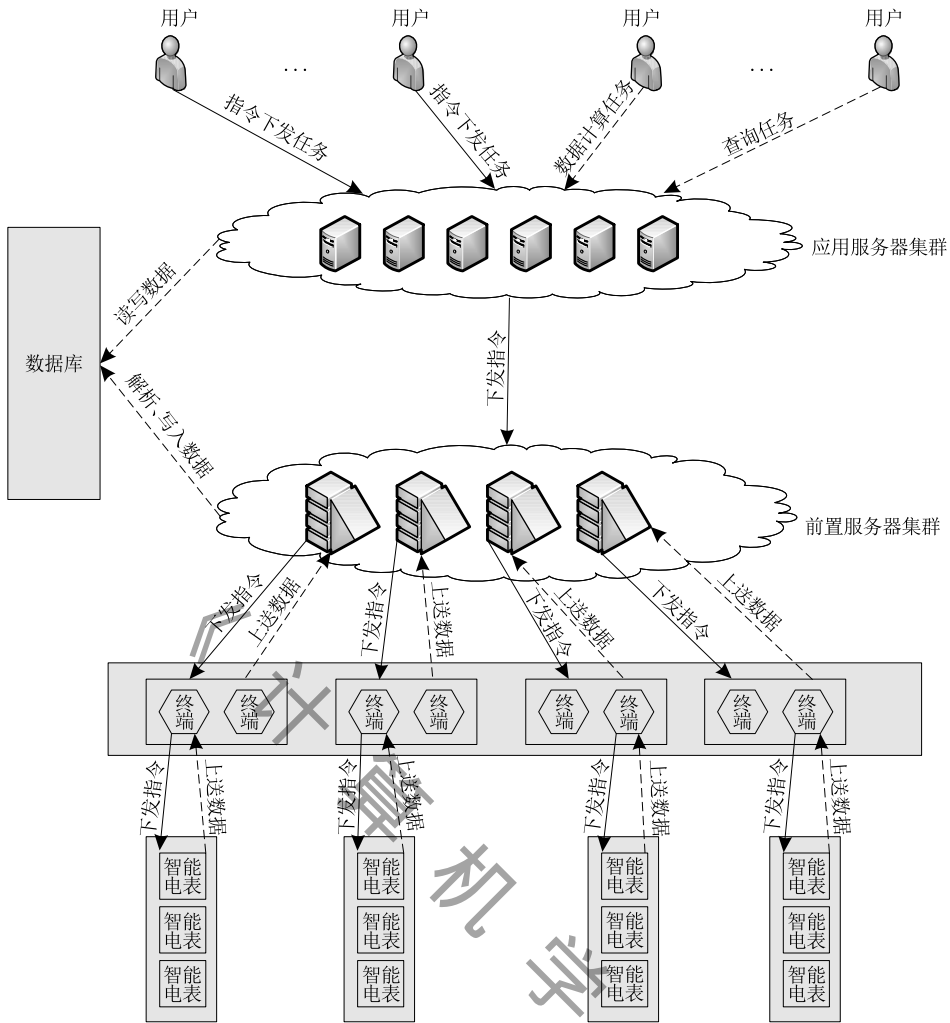


图 1 费控指令下发流程

3.2 基础定义

为更加清楚地描述基于负载预测和均衡的费控指令下发过程优化模型,给出一些基础的定义。

定义 1. 待下发指令集:根据用户的电费测算结果,系统自动生成远程费控用户的费控指令(如预警、拉闸、合闸等),并将这些指令下发到相应的用户电表上,这些所有要下发的指令集合称为待下发指令集,用符号表示为 $CMD = \{cmd_1, cmd_2, \dots, cmd_n\}$ 。

对于费控指令,重点关注其类型、目标终端、目标电表等信息.因此对于待下发指令集中的任意一条费控指令 cmd_i ,可以描述为 $cmd_i = \{type, terminalID, electricityMeterID\}$.其中 $type$ 代表指令类型, $terminalID$ 代表指令目标终端的唯一标识, $electricityMeterID$ 代表指令目标电表的唯一标识。

定义 2. 应用服务器集群:对于应用服务器集群,使用集合 $AS = \{as_1, as_2, \dots, as_n\}$ 来描述,其中 n 为应用服务器集群中的服务器个数。

定义 3. 应用服务器集群可用资源数(Server Available Resources, SAR):对应用服务器集群可用资源进行量化,分别使用可用于费控指令下发的 CPU 和内存资源数在应用服务器集群总 CPU 和总内存资源中的占比来表示应用服务器集群可用资源,表示为 $SAR = \{SAC, SAM\}$,其中 SAC(Server Available CPU)代表应用服务器集群中可用 CPU 占 CPU 总数的百分比, SAM(Server Available Memory)表示应用服务器集群中可用内存占内存总数的百分比。

定义 4. 前置服务器集群:对于前置服务器集群,使用集合 $FCU = \{fcu_1, fcu_2, \dots, fcu_m\}$ 来描述,其中 m 为前置服务器集群中的前置机个数。

定义 5. 前置机集群可用资源数:前置机集群可用资源数可以用 $FAC = \{fac_1, fac_2, \dots, fac_m\}$ 来描述,其中 fac_i 表示前置机 fcu_i 的可用资源数;前置机资源用线程数来表示, fac_i 表示该前置机可用于费控指令下发的线程数。

定义 6. 资源消耗模型:费控指令下发资源消耗模型可以描述为 $CMDCost = \{SC, SM, FS\}$, 其中 SC 代表消耗的应用服务器集群的 CPU 数占应用服务器集群 CPU 总数的百分比, SM 表示消耗的应用服务器集群的内存数占应用服务器集群内存总数的百分比, FS 为消耗的前置机线程数。

由于终端和前置机的对应关系是确定的, 因此基于终端-前置机对应关系可以对待下发指令集合进行分类, 分类后集合可以描述为 $CMD = \{fcmd_1, fcmd_2, \dots, fcmd_m\}$, 其中 $fcmd_i$ 表示需要前置机

fcm_i 下发的指令集合, $|fcmd_i|$ 表示指令集中的指令数量. 基于终端是否需要定时上传数据, $fcmd_i$ 可以表示为 $fcmd_i = \{utcmd_i, nutcmd_i\}$, 其中 $utcmd_i$ 表示需要定时数据上传的终端对应的指令集合, $nutcmd_i$ 表示不需要定时数据上传的终端对应的指令集合。

3.3 优化模型

为提高应用服务器和前置服务器的资源利用率, 缩短费控指令下发的总耗时, 本文设计了基于负载预测和均衡的费控服务优化调度模型, 如图 2 所示。

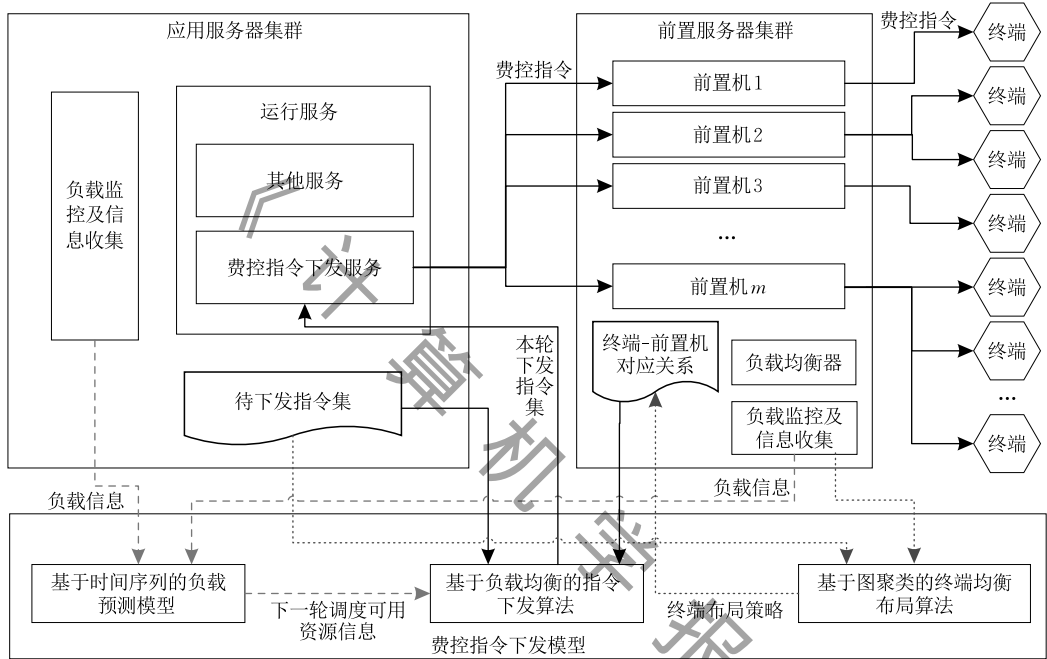


图 2 费控指令下发过程优化模型

基于负载预测和均衡的费控指令下发过程优化模型共分为三个部分: 基于时间序列的服务器负载预测模型、基于服务器负载预测的指令均衡下发算法以及基于图聚类的终端均衡布局算法。

针对待下发的费控指令集, 本模型采用轮次下发的方式进行指令下发, 下发的过程主要分为三个阶段。

(1) 基于时间序列的服务器负载预测

收集应用服务器集群和前置服务器集群中除费控指令外其他服务的历史负载情况, 使用基于时间序列的负载预测模型对下一轮次费控指令下发时服务器的负载情况进行预测, 根据预测结果得到下一轮次费控指令下发服务可用资源。

(2) 基于负载预测结果的指令均衡下发

根据负载预测结果和本轮调度中终端-前置机对应关系, 指令均衡下发算法计算能够充分利用集群资

源的下发指令集合以及每台前置机需要下发的指令集合, 并根据指令类型优先级选取指令进行下发。

(3) 基于图聚类的终端均衡布局

系统运行过程中, 基于图聚类的终端均衡布局匹配算法每隔时间周期 T , 便收集一次前置机负载信息以及待下发指令集信息, 计算前置机的负载均衡情况, 并对该周期内的负载均衡情况进行评估, 若前置机集群负载处于不均衡状态, 则对终端的布局状况进行调整和优化。

4 基于时间序列的服务器负载预测

由于费控指令下发服务与其他业务服务共享应用服务器集群和前置服务器集群中的资源, 为最大化利用服务器资源、提高费控指令下发效率, 在不影响其他业务和服务正常执行的情况下应为费控指令

下发服务分配尽可能多的资源. 为此, 根据其他业务服务对集群资源的历史使用记录, 建立负载预测模型, 对未来服务器资源的使用情况做出预测, 根据负载预测结果为费控指令下发服务分配资源.

智能电网系统中服务器负载的变化是周期性的, 与时间有很强的相关性, 是一种典型的时间序列问题, 因此可以构建基于时间序列的负载预测模型.

任何时间序列经合理的函数变换后都可以认为是由趋势项部分、周期项部分和随机噪声项部分叠加而成, 本文在进行服务器负载预测时仅考虑趋势项部分和周期项部分, 即服务器负载预测模型为

$$y_t = \alpha x_t + (1 - \alpha) s_t \quad (1)$$

其中, y_t 为预测结果, x_t 为趋势项部分, s_t 为周期项部分.

为了对服务器负载进行预测, 本文分别用横向时间序列 $(x_1, x_2, \dots, x_t, \dots)$ 和纵向时间序列 $(s_1, s_2, \dots, s_t, \dots)$ 来进行趋势项部分和周期项部分的预测, 其中横向时间序列为同一周期内不同时间段的负载按时间先后排序而成的数列, 而纵向时间序列为不同周期同一时间段的负载按时间先后排序而成的数列.

对于任意时间序列 $x_1, x_2, \dots, x_t, \dots$, 根据移动平均法有

$$\bar{x}_t = \frac{x_t + x_{t-1} + \dots + x_{t-n+1}}{n} \quad (2)$$

其中, n 为移动平均的周期数. \bar{x}_t 为时间序列的移动平均序列, 记为 $\{x_t, t \geq n\}$.

与原始序列相比, 移动平均序列更加平滑, 更能显示序列的趋势变化. 按趋势递推原理, 以 \bar{x}_t 作为 $(t+1)$ 期的预测值, 即 $x_{t+1} = \bar{x}_t$, 可得预测模型

$$x_{t+1} = \frac{x_t + x_{t-1} + \dots + x_{t-n+1}}{n} \quad (t \geq n) \quad (3)$$

综上, 对于服务器负载预测模型中的趋势项部分和周期项部分, 其预测模型为

$$x_t = \frac{x_{t-1} + x_{t-2} + \dots + x_{t-n}}{n} \quad (t > n) \quad (4)$$

$$s_t = \frac{s_{t-1} + s_{t-2} + \dots + s_{t-n}}{n} \quad (t > n) \quad (5)$$

服务器一天内的负载变化有三种类型: 稳定阶段、负载增加阶段和负载降低阶段. 当服务器负载变化为负载增加阶段和负载降低阶段时, 服务器负载时间序列会呈现增长或减少趋势, 此时采用移动平均法将会产生滞后现象. 因此, 需要对于趋势项部分的预测模型进行修正.

为对趋势项部分的预测模型进行修正, 首先对

滞后产生的原因进行分析.

根据对负载历史记录的分析结果, 处于增加阶段和降低阶段的时间序列呈线性增长或减少的趋势, 假设其线性方程为

$$x_t = a + bt \quad (6)$$

当 t 增加至 $(t+n)$ 时, 序列值为

$$x_{t+n} = a + b(t+n) = a + bt + bn.$$

但是采用移动平均法进行计算时, 序列值为

$$\begin{aligned} x_{t+n} &= \frac{x_{t+n-1} + x_{t+n-2} + \dots + x_t}{n} \\ &= \frac{na + b(t+n-1+t+n-2+\dots+t)}{n} \\ &= a + bt + bn - \frac{n+1}{2}b. \end{aligned}$$

二者之差为 $\frac{n+1}{2}b$, 故在 $(t+n)$ 期, 基于移动平均法的预测值滞后了 $\frac{n+1}{2}b$.

为消除移动平均预测法产生的滞后, 应在移动平均法预测值的基础上, 以 $\frac{n+1}{2}b$ 为修正量对移动平均预测模型进行修正, 修正后趋势项的修正移动平均预测模型为

$$x_t = \frac{x_{t-1} + x_{t-2} + \dots + x_{t-n}}{n} + \frac{n+1}{2}b \quad (t > n) \quad (7)$$

其中 b 的值按线性回归公式计算, 即:

$$b = \frac{n\bar{x}\bar{y} - \sum x_i \sum y_i}{n\bar{x}^2 - \sum x_i^2} \quad (8)$$

综上, 服务器负载预测模型为

$$\begin{aligned} y_t &= \alpha \left(\frac{x_{t-1} + x_{t-2} + \dots + x_{t-n}}{n} + \frac{n+1}{2}b \right) + \\ &\quad (1 - \alpha) \frac{s_{t-1} + s_{t-2} + \dots + s_{t-n}}{n} \quad (9) \end{aligned}$$

当服务器负载处于增加阶段和减少阶段时分别按上述线性回归公式对 b 取值, 为不失一般性, 当负载处于平稳阶段时 $b=0$.

5 基于负载预测结果的指令均衡下发

基于负载预测模型, 可以预测应用服务器集群及前置机集群中服务器未来的负载情况, 得到费控指令下发时应用服务器集群的可用资源数 $\{SAC, SAM\}$ 以及前置机集群的可用资源数 $\{fac_1, fac_2, \dots, fac_m\}$.

通过分析费控指令下发情况的监控记录, 得到费控指令下发时单条指令的资源耗费模型 $CMDCost = \{SC, SM, FS\}$, 其中 SC 代表单条指令下发时使用

的应用服务器集群 CPU 资源占应用服务器集群 CPU 总数的百分比, SM 表示单条指令下发时使用的应用服务器集群内存资源占应用服务器集群内存总数的百分比, FS 表示单条指令下发时使用的前置机的线程数。

基于费控指令下发资源耗费模型以及应用服务器集群可用资源数, 可以计算当前应用服务器可以下发的最大费控指令数量, 计算公式如下:

$$SN = \min(SAC/SC, SAM/SM) \quad (10)$$

基于费控指令下发资源耗费模型以及前置机集群可用资源数, 可以计算每台前置机可以接受的最大指令数量, 计算公式如下:

$$FMN_i = fac_i/FS \quad (11)$$

使用 FAN_i 表示需要前置机 fcu_i 下发的指令集合 $fcmd_i$ 中可并行执行的指令数, 则当前时刻前置机 fcu_i 实际可接受的指令数为

$$FN_i = \min(FMN_i, FAN_i) \quad (12)$$

基于上述定义及公式, 给出了算法 1: 基于负载预测结果的指令均衡下发算法。

算法 1. 基于负载预测结果的指令均衡下发算法。

输入: 应用服务器集群可用资源数 $\{SAC, SAM\}$
前置机集群可用资源数 $\{fac_1, fac_2, \dots, fac_m\}$
待下发指令集合 CMD

输出: 本轮下发指令集合 $SEMD$

1. Divide all command CMD to $fcmd_i$
2. Divide $fcmd_i$ into $utcmd_i$ and $nutcmd_i$
3. $FMN_i = fac_i/FS$
4. $FN_i = \min(FMN_i, FAN_i)$
5. $FN = \sum_{i=1}^m FN_i$
6. $SN = \min(SAC/SC, SAM/SM)$
7. $CN = \min(FN, SN)$
8. IF ($CN == FN$)
9. $FACN_i = FN_i$
10. ELSE
11. $FACN_i = FN_i * (SN/FN)$
12. IF (time to upload)
13. FOR (each $fcmd_i$ in CMD)
14. $S = \text{select } FACN_i \text{ command from } utcmd_i$
15. $SEMD = SEMD + S$
16. ELSE
17. FOR (each $fcmd_i$ in CMD)
18. $S = \text{select } FACN_i \text{ command from } nutcmd_i$
19. $SEMD = SEMD + S$
20. Return $SEMD$

首先根据终端-前置机对应关系将所有待下发

指令划分得到每个前置机要下发的指令集合(行 1), 然后将每个前置机要下发的指令根据终端是否需要定时上送数据将指令再次划分成两部分(行 2), 然后计算所有前置机共可下发的指令数 FN (行 3~5) 以及应用服务器可下发的指令数 SN (行 6) 并由此计算本轮要下发的指令数 CN (行 7), 若 CN 等于 FN , 说明当前指令瓶颈下发瓶颈在前置机端, 每台前置机要接受的指令数 $FACN_i$ 为 FN_i ; 否则说明当前的指令下发瓶颈在服务器端, 每台前置机要接受的指令数 $FACN_i$ 为 $FN_i * (SN/FN)$ (行 8~11), 最后在 $fcmd_i$ 中选择 $FACN_i$ 条不同终端的指令加入下发指令集合. 若当前时间在定时数据上送时间段内, 优先在 $utcmd_i$ 中选择指令(行 13~15), 否则优先在 $nutcmd_i$ 中选择指令(行 17~19)。

6 基于图聚类的终端均衡布局

基于负载预测结果的指令均衡下发算法, 可以在指令下发的每一轮中最大化利用集群的计算资源, 在每轮下发中下发尽可能多的指令, 提高了费控指令下发的效率和成功率. 但是由于现有的前置机-终端对应关系的负载均衡策略是基于终端数量的负载均衡, 即要求每台前置机对应的终端数量大致相同, 没有考虑前置机需下发的费控指令数量的不同, 这可能会导致前置机集群负载处于不均衡状态, 有的前置机负载较重, 而有些前置机则处于空闲状态, 大大降低了费控指令下发效率。

针对上述情况, 本文设计了一种新的负载均衡算法, 当检测到前置机集群负载不均衡时通过调整终端布局策略, 将部分终端和前置机进行重连以将未来需要下发的指令均衡分配到各个前置机, 实现前置机集群的负载均衡, 提高费控指令下发效率。

为解决前置机集群负载均衡问题, 首先对前置机负载状况进行评估. 前置机集群负载主要包括两个部分: 费控指令下发负载以及其他任务负载。

对于任意前置机 fcu_i , 首先通过集群监控信息得到该前置机当前被其他服务占用的线程数 fso_i 以及需要该前置机下发的费控指令总数 $|fcmd_i|$. 则该前置机的负载可用如下公式计算:

$$load_i = fso_i + |fcmd_i| * FS \quad (13)$$

根据每台前置机的负载信息, 计算前置机集群的平均负载为

$$\overline{load} = \frac{1}{m} \sum_{i=1}^m load_i \quad (14)$$

本文使用所有前置机负载的标准差作为衡量前置机集群负载均衡指数的标准,该前置机集群的负载均衡指数为

$$lb = \sqrt{\frac{1}{m} \sum_{i=1}^m (load_i - \overline{load})^2} \quad (15)$$

在一个负载均衡周期 T 内,选取多个时间点计算前置机的负载均衡指数,最终取多次计算的平均值 \overline{lb} 作为该负载均衡周期内前置机集群的负载均衡指数.当 \overline{lb} 的值大于设定的阈值时,认为前置机集群负载处于不均衡状态.

当前置机集群负载处于不均衡状态时,可以看到,负载较重的前置机会收到过多的费控指令形成指令阻塞现象,拖慢整体的下发效率,而负载较轻的前置机则会出现长时间空闲的情况,因此需要对终端与前置机的对应关系进行调整.为此,根据终端间的关联关系,引入基于力学模型图聚类的终端均衡布局算法,对终端布局策略进行动态调整.

首先对终端指令下发历史信息进行分析,分析终端间的关联程度(即同时下发指令的次数),然后将分析结果绘制为一张有权无向图 $G(V, E)$,其中 V 是终端的集合, E 是终端间的关联关系.若两个终端 V_i 和 V_j 有同时下发指令的记录,则 V_i 和 V_j 间存在一条边 (i, j) ,边的权重代表两个终端同时下发指令的次数.

为了对图 G 中的终端进行聚类,首先在 G 中选择 k 个离散的没有关联边的点 (P_1, P_2, \dots, P_k) 作为初始聚类中心点.然后使用力学模型模拟终端在图中受到其他终端的引力和斥力,如图 3 所示.本文中只考虑聚类中心点对终端的引力和终端附近节点对终端的斥力,受力规则为:当终端与聚类中心点之间有边时终端受到聚类中心点的引力 F_y ,引力大小与边的权重成正比(如图 3 中,终端 P 受到来自于聚类中心点 P_2, P_4, P_7 的引力 F_1, F_2, F_3);在距离终端半径 R 的范围内,若存在终端与该终端之间没有边,则终端间会相互产生斥力 F_c ,斥力大小与终端距离成反比(如图 3 中,终端 P 受到来自于附近点 R_1, R_2 的斥力 F_4, F_5).根据终端受到的所有引力和斥力的方向和大小,按照正交分解法计算终端在各个聚类中心点方向的力大小.

如图 3 所示,每次计算每个终端受到各个聚类中心点的引力的大小,然后选择引力最大的中心点方向作为终端的移动方向,终端向该中心点移动一定的距离,移动距离与引力大小成正比.经多次迭代后,按终端离聚类中心点的距离确定终端的聚类结果,当终端离多个聚类中心点距离相同无法直接确

定属于哪个簇时,随机选择一个作为其所属簇.




图 3 终端受力模型图

按照上述方式完成对终端的聚类后,为保证终端的均衡布局,需要结合前置机负载预测,将每个簇内的终端平均分到各个前置机.由于终端重连将影响终端在线率统计,应最小化重连终端的个数,因此在分配每个簇中的终端时应保证将终端首先分配给其当前连接的前置机.

基于上文描述,给出了算法 2:基于图聚类的终端均衡布局算法.

算法 2. 基于图聚类的终端均衡布局算法.

输入:周期 T 内的指令下发记录 CHR

当前终端布局策略 $CTLs$

迭代次数 N

聚类簇个数 k

输出:调整后的终端布局策略 $NTLS$

1. Compute correlation between terminals by CHR
2. Create $G(V, E)$
3. Select k cluster center P_1, P_2, \dots, P_k
4. FOR (int $j=0; j < N; j++$)
5. FOR each vertex p in V
6. get all the attraction and repulsion force of p
7. Initialize Force $F=0$;
8. Initialize Direction $P=0$;
9. FOR (int $i=1; i \leq k; i++$)
10. $F_i =$ resultant force in P_i direction
11. IF($F_i > F$)
12. $F = F_i$;
13. $P = P_i$
14. Move F distance to P direction
15. Get clustering results CR
16. Initialize $NTLS$
17. FOR (int $i=0; i < k; i++$)
18. partition the terminals in cluster CR_i into n front servers with minimum reconnections with $CTLs$
19. update $NTLS$
20. Return $NTLS$

在上述算法中,首先根据历史记录计算终端间的关联度(行 1),根据计算结果生成有权无向图 G

(V, E) (行 2), 将该图各节点随机映射到二维空间中, 图中节点的位置为相应的二维坐标. 在图中选择 k 个初始聚类中心点(行 3), 然后对于 G 中的每个节点根据力学模型进行 N 次迭代移动(行 4~14), 每次迭代时首先计算节点受到的所有力(行 6), 然后计算节点受到各个聚类中心点的引力大小并选取引力最大的中心点(行 7~13), 最后让节点向引力最大的中心点方向移动(行 14), 其中力学模型中的半径 R 根据实际情况设置. 经 N 次迭代后根据节点与每个聚类中心点的距离确定聚类结果(行 15), 最后根据聚类结果进行均衡布局并将结果输出(行 16~20). 在实际应用中, 可根据经验指定 k 值为 100.

7 实验与分析

7.1 实验环境

将基于负载预测和负载均衡的费控服务优化调度模型以山东省电力集团的智能电网系统的数据与运行环境为参考进行测试实验. 山东省电力集团公司的智能电网体系覆盖用户 4000 余万户, 费控用户近 3000 万户, 接入终端 340 余万台, 接入电表近 4300 余万台, 数据日增长量 1 TB. 山东省电网的智能电网系统的应用服务器集群是由 6 台服务器组成的服务器集群, 前置机集群由 50 台前置机组成, 其中应用服务器配置为 CPU 64 核、内存 128GB, 前置机配置为 CPU 32 核、内存 64GB, 集群内部为千兆宽带. 应用服务器集群中除了费控指令下发服务外还部署了数据采集服务、终端在线率统计服务等一系列服务. 前置机集群除了费控指令下发外还承担其他指令下发、数据招测、数据巡测、接受终端上送数据等一系列的任务.

7.2 分析

(1) 基于时间序列的服务器负载预测

对负载预测模型预测结果的准确性进行评估. 以一天为一个周期, 划分为 12 个时间段, 每个时间段为 2 h, 对于智能电网系统中的服务器, 预测了连续 2 个周期共 24 个时间段的负载值, 并对实际负载值进行监控, 基于时间序列的服务器负载预测中移动平均的期数 n 取值 12. 预测结果与真实负载值的对比如图 4 所示, 服务器的真实负载随机波动较大, 而预测值变化则比较平稳, 本文提出的负载预测模型预测结果与真实负载十分接近, 预测模型的准确度较高, 预测结果基本能够代表真实负载情况.




图 4 预测结果与真实结果对比图

为评估预测模型的有效性, 对使用预测模型前后的服务性能进行了比较. 为了体现比较结果, 采用归一化方法对性能进行量化, 以资源利用率为例, 假设使用预测模型前后资源利用率分别为 60% 和 80%, 使用归一化方法量化后值分别为 0.75 和 1.0. 本次实验主要是对使用预测模型前后指令下发效率、其他服务性能以及服务器资源利用率进行对比, 实验结果如图 5 所示, 使用预测模型后, 指令下发效率有了极大的提高, 集群资源利用率有了明显的增加. 其原因是, 最初的指令下发流程中不关注集群负载情况, 每次下发固定数量的指令, 这种方法不能充分利用集群资源, 使集群中存在部分闲置资源, 而使用预测模型后, 每次根据集群负载情况确定下发数量, 集群资源得到充分利用, 每轮下发时下发的指令数量也有所增加, 因而指令下发效率和集群资源利用率都有所增加. 而其他服务性能与使用预测模型前略有下降, 但是下降不明显, 这是由于预测模型的预测结果与真实负载之间的误差造成的, 当预测结果小于真实负载时, 分配给其他服务的资源过少, 从而导致性能下降, 但是由于预测结果与真实负载十分接近, 因而其他服务的性能下降不是很明显.




图 5 预测模型对性能的影响

(2) 基于负载预测结果的指令均衡下发

对基于负载预测结果的指令均衡下发算法的性能进行测试,通过费控指令下发任务的执行时间以及费控指令下发成功率来对算法性能进行评估.为测试算法的有效性,对比原有指令下发算法(original)、使用负载预测模型的原有下发算法(LFM)以及基于负载预测结果的指令均衡下发算法(LFBM)三种费控指令下发算法的性能,并使用均衡数据、同比例不均衡数据、同数量不均衡数据三种不同类型的数据进行测试.

首先,先使用均衡数据对三种算法的性能进行测试.均衡数据即每台前置机需处理的费控指令数量与该前置机处理能力的比值相同.通过实验获得不同费控指令数量下三种算法的执行时间以及下发成功率,实验结果如图 6 和图 7 所示.

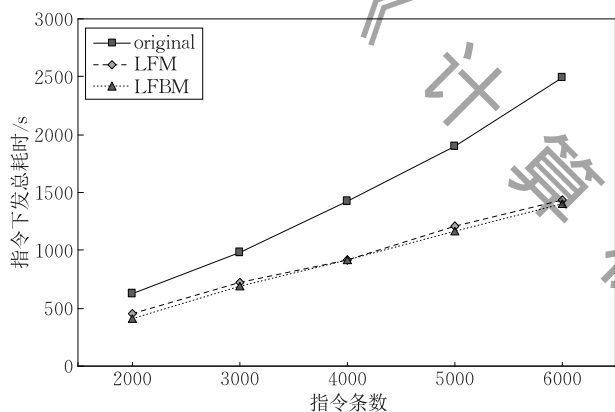


图 6 均衡数据时下发时间与指令数量(条数)的关系




图 7 均衡数据时下发成功率与指令数量(条数)的关系

根据实验结果可以看到,随着数据量的变大,三种算法都是费控指令下发时间变长,基本成线性关系,而下发成功率则随指令数量的增加变化不大.但 LFBM 算法的性能无论是从指令下发时间来看还是从下发成功率来看,相比原有算法都有了显著的提升.由于数据是均衡数据的原因,LFM 算法与

LFBM 算法在下发时间上相差不大,但是由于 LFM 算法下发时没有考虑数据上等送等情况,下发成功率与原有下发算法相似,与 LFBM 算法相差很多.

其次,使用同比例不均衡数据对算法性能进行测试.同比例不均衡数据即随着待下发指令数量的增加,前置机负载均衡指数相对稳定.式(13)定义了前置机 fcu_i 的负载 $load_i$,使用 $load_max_i$ 表示该前置机支持的最大线程数,即最大负载,令 $lr_i = load_i / load_max_i$,表示前置机 fcu_i 的负载率,若 $lr_i > 80\%$,表示前置机负载过重,若 $lr_i < 20\%$,表示前置机负载过轻,其他表示前置机负载正常.本次模拟实验中,令 1/3 的前置机负载过重,1/3 部分前置机负载过轻,1/3 的前置机负载正常.当费控指令数量增大时通过人为设置调整前置机中运行的服务,确保负载过重的前置机、负载过轻的前置机、负载正常前置机三者的比例相对不变.在这种情况下通过实验测试随费控指令数量变化三种算法的执行时间以及下发成功率的变化情况,实验结果如图 8 和图 9 所示.

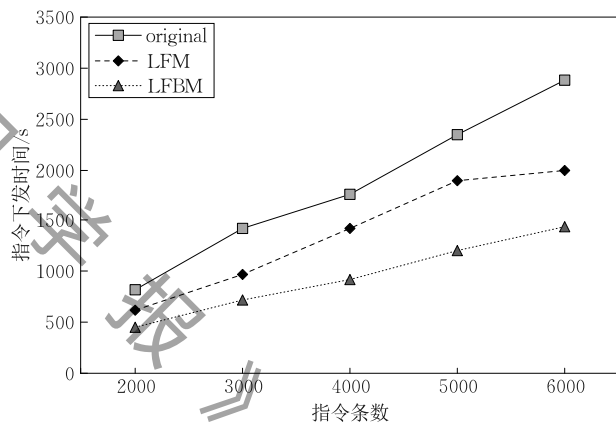


图 8 同比例不均衡数据下发时间与指令数量的关系




图 9 同比例不均衡数据下发成功率与指令数量的关系

根据实验结果可以看到,随着数据量的变大,三种算法费控指令下发时间都变长,下发成功率保持

不变.从三种算法的下发效率和下发成功率上来看同样是本文提出的 LFBM 算法性能最好.由于数据是不均衡的,LFM 算法的下发效率虽然优于原有的指令下发算法,但是因为没有对不均衡数据做出合理的处理,因而下发效率较 LFBM 而言相差很多.下发成功率方面与使用均衡数据实验时结果相似,此处不再过多描述.

最后,使用同数量不均衡数据对算法性能进行测试.同数量不均衡数据即待下发指令数量不变,测试时前置机负载均衡指数不同下三种算法的执行性能.选择 6000 条指令用来实验,前置机集群负载均衡指数分别为:0、0.25、0.5、0.75、1.0、1.5、2.0 实验结果如图 10、图 11 所示.




图 10 指令下发效率与负载均衡指数关系




图 11 下发成功率与负载均衡指数关系

根据实验结果可以看到,随着负载均衡指数的变大,三种算法的下发耗时都有所增加,但是本文提出的 LFBM 算法受负载均衡指数的影响不大,下发耗时增加不多,而原有算法和 LFM 算法则受负载均衡指数的影响较大,LFM 算法虽然在下发效率上明显优于原有算法且前期下发效率与 LFBM 算法相差无几,但是随着负载均衡指数的增加,LFM 算

法的下发效率与 LFBM 算法相差越来越大.下发成功率方面其他两种算法的下发成功率也受负载均衡指数影响略有降低,而 LFBM 算法由于对同终端指令下发以及终端数据上送的影响做了有效应对,因而下发成功率基本维持在一个恒定的水平.

(3) 基于图聚类的终端均衡布局

系统运行过程中,基于图聚类的终端均衡布局算法每隔时间周期 $T(2\text{h})$,便收集一次前置机负载信息以及待下发指令集信息,计算前置机的负载均衡情况,并对该周期内的负载均衡情况进行评估,若前置机集群负载处于不均衡状态,则对终端的布局状况进行调整和优化.

测试终端均衡布局策略对前置机负载均衡指数的影响,测试时选择使用终端均衡布局策略前后 12 个连续时间段内的负载均衡指数进行对比,实验结果如图 12 所示,使用终端均衡布局策略前负载均衡指数一直在不断地变化且波动范围较大,终端均衡指数数值也较大,而使用均衡布局策略后,负载均衡指数基本维持在一个恒定的接近于 0 的较小数值.因此,从实验结果可以看出负载均衡指数能有效地解决前置机负载均衡问题.




图 12 终端均衡布局策略对负载均衡指数的影响

综上,本文提出的费控服务优化调度模型,不仅均衡了两个集群和终端之间的负载,而且提高了指令下发的效率和成功率.

8 总 结

本文针对智能电网系统中的费控服务的下发效率问题展开研究,提出了优化方案.首先通过对服务器历史负载信息的收集和分析,提出一种基于时间序列的服务器负载预测方法,对应用服务器集群和前置机集群的负载进行预测;然后基于预测结果,提出一种费控指令均衡下发算法,以提高指令下发效

率和成功率;最后针对前置服务器集群与终端间的负载不均衡问题,提出一种基于图聚类的终端均衡布局算法.实验结果证明本文提出的费控指令下发优化模型可以有效地提高费控指令下发的效率和成功率.

参 考 文 献

- [1] Gao Lu-Xin, Wang Jun, Tao Xiao-Feng, et al. Research and optimization of fee control efficiency in electric energy data acquiring system. *Smart Grid*, 2014, 2(12): 55-59 (in Chinese)
(高鲁鑫, 王军, 陶晓峰等. 用电采集系统费控效率研究与优化. *智能电网*, 2014, 2(12): 55-59)
- [2] Mo Wen-Hao, Chao Yu-Qiang, Huo Bao-Lun. Technical research on optimization application in remote charge control system. *Electronic Technology & Software Engineering*, 2016(15): 141-142(in Chinese)
(莫文昊, 巢玉强, 霍保仑. 远程费控在采集系统中优化应用的技术研究. *电子技术与软件工程*, 2016(15): 141-142)
- [3] Barati M, Sharifian S. A hybrid heuristic-based tuned support vector regression model for cloud load prediction. *The Journal of Supercomputing*, 2015, 71(11): 4235-4259
- [4] Di S, Kondo D, Cirne W. Host load prediction in a Google compute cloud with a Bayesian model//Proceedings of the SC Conference on High Performance Computing Networking, Storage and Analysis. Salt Lake City, USA, 2012: 21
- [5] Yang Q, Zhou Y, Yu Y, et al. Multi-step-ahead host load prediction using autoencoder and echo state networks in cloud computing. *The Journal of Supercomputing*, 2015, 71(8): 3037-3053
- [6] Minarolli D, Mazrekaj A, Freisleben B. Tackling uncertainty in long-term predictions for host overload and underload detection in cloud computing. *Journal of Cloud Computing*, 2017, 6(1): 4
- [7] Cao Jie, Zeng Guo-Sun, Kuang Gui-Juan, et al. On-Demand physical resource allocation method for cloud virtual machine to support random service requests. *Journal of Software*, 2017, 28(2): 457-472(in Chinese)
(曹洁, 曾国荪, 匡桂娟等. 支持随机服务请求的云虚拟机按需物理资源分配方法. *软件学报*, 2017, 28(2): 457-472)
- [8] Khwaja A S, Naeem M, Anpalagan A, et al. Improved short-term load forecasting using bagged neural networks. *Electric Power Systems Research*, 2015, 125: 109-115
- [9] Zheng Hong-Yuan, Zhou Liang, Wu Jia-Qi. Design and implementation of load balancing in WEB server cluster system. *Transactions of Nanjing University of Aeronautics & Astronautics*, 2006, 38(3): 348-349(in Chinese)
(郑洪源, 周良, 吴家祺. WEB服务器集群系统中负载均衡的设计与实现. *南京航空航天大学学报*, 2006, 38(3): 348-349)
- [10] Cai Song, Zhang Jian-Ming, Chen Ji-Ming, et al. Load balancing technology based on Naive Bayesian algorithm in cloud computing environment. *Journal of Computer Applications*, 2014, 34(2): 360-364(in Chinese)
(蔡嵩, 张建明, 陈继明等. 云环境中基于朴素贝叶斯算法的负载均衡技术. *计算机应用*, 2014, 34(2): 360-364)
- [11] Mai Jing-Jing, Gong Hong-Yan, Song Chun-He. Dynamic feedback load balancing strategy in cluster system. *Computer Engineering*, 2008, 34(16): 114-115, 118(in Chinese)
(买京京, 龚红艳, 宋纯贺. 集群系统中的动态反馈负载均衡策略. *计算机工程*, 2008, 34(16): 114-115, 118)
- [12] Liu Dao-Pu, Tu Hai-Ning, Gu Jia. Research on load balancing scheduling algorithm for power information system. *Large Electric Machine and Hydraulic Turbine*, 2015, 3: 60-64(in Chinese)
(刘道谱, 涂海宁, 顾嘉. 电力信息系统负载均衡调度算法的研究. *大电机技术*, 2015, 3: 60-64)
- [13] Luo Yong-Jun, Li Xiao-Le, Sun Ru-Xiang. Overview of load balancing algorithm. *Sci-Tech Information Development & Economy*, 2008, 18(23): 134-136(in Chinese)
(罗拥军, 李晓乐, 孙如祥. 负载均衡算法综述. *科技情报开发与经济*, 2008, 18(23): 134-136)
- [14] Rätinasamy S P. A scalable content-addressable network. University of California, Berkeley, 2002
- [15] Stoica I, Morris R, Karger D, et al. Chord: A scalable peer to peer lookup service for internet application//Proceedings of the 2001 Conference on Applications, Technologies, Architectures, and Protocols for Computer Communications. San Diego, USA, 2001: 149-160
- [16] Dabek F, Kaashoek M F, Karger D, et al. Wide-area cooperative storage with CFS//Proceedings of the 18th ACM Symposium on Operating System Principles. Alberta, Canada, 2001: 202-215
- [17] Godfrey B, Lakshminarayanan K, Surana S, et al. Load balancing in structured P2P systems//Proceedings of the IEEE INFOCOM 2004, the 23rd Annual Joint Conference of the IEEE Computer and Communications Societies. Hong Kong, China, 2004: 2253-2262



SHI Yu-Liang, Ph. D., professor. His research interests include service computing, big data, and privacy protection.

ZHANG Kun, Ph. D., lecturer. His research interests include cloud computing, data mining, and privacy protection.

RONG Yi-Ping, senior engineer. His main research interests include electricity marketing and power information management.

ZHU Wei-Yi, senior engineer. His main research interests include electricity marketing and power information management.

CHEN Zhi-Yong, associate professor. His main research interests include software architecture in cloud computing, service computing, and collaborative recommendation.

Background

The topic studied in this paper belongs to dynamic resource provision and management in cloud environment. For now, this is a research hot topic. This paper focuses this topic on the cost control service in smart grid systems. To solve the bottleneck of cost control instruction sending, this paper proposes an optimized scheduling solution to cost control service based on load forecasting and balancing. This work is motivated by practical matters in smart grid system. In this solution, a load forecasting model based on time-series data is proposed to predict the server load. Then cost control instruction sending algorithm is proposed based on the predicted server load, which could make a balance between application server cluster and front-end server cluster and improve the success rate of charge control service. At last, a terminal balance distribution algorithm based on graph clustering is proposed to solve the imbalance issue in front-end

server cluster. The solution proposed in this paper was successfully applied in the State Grid Shandong Electric Power Company and achieved good results.

Authors have done research in this research topic. AdaptScale is proposed for improving the multiple performance requirements in clouds. Data replica placement strategy and MapReduce job optimization are also our research issue.

The research work in this paper is supported by the National Key Research and Development Plan under Grant No. 2018YFB1003804, the TaiShan Industrial Experts Program of Shandong Province under Grant No. tscy20150305, the Key Research & Development Plan of Shandong Province under Grant No. 2016ZDJS01A09, and the Major Basic Research Project of Natural Science Foundation of Shandong Province under Grant No. ZR2017ZB0419.

计算机学报