

# 绿色能源互补智能电厂云控制系统研究

夏元清<sup>1</sup> 高润泽<sup>1</sup> 林敏<sup>1</sup> 任延明<sup>2</sup> 闫策<sup>1</sup>

**摘要** 针对现代电力系统中设施庞杂、多源异构海量数据难以有效处理、“信息孤岛”长期存在以及整体优化调度管理能力不足等问题,基于云控制系统理论,以智能电厂为研究对象,本文提出了智能电厂云控制系统(Intelligent power plant cloud control system, IPPCCS)解决方案.基于智能电厂云控制系统,针对绿色能源发电波动性强、抗扰能力差的问题,利用机器学习算法对采集到的风电、光伏输出功率进行短时预测,获知未来风、光机组功率输出情况.在云端使用经济模型预测控制(Economic model predictive control, EMPC)算法,通过实时滚动优化得到水轮机组的功率预测调度策略,保证绿色能源互补发电的鲁棒性,充分消纳风、光两种能源,减少水轮机组启停和穿越振动区次数,在为用户清洁、稳定供电的同时降低了机组寿命损耗.最后,一个区域云数据中心的供电算例表明了本文方法的有效性.

**关键词** 绿色能源互补,智能电厂,云控制系统,机器学习,经济模型预测控制,滚动优化

**引用格式** 夏元清,高润泽,林敏,任延明,闫策.绿色能源互补智能电厂云控制系统研究.自动化学报,2020,46(9):1844-1868

**DOI** 10.16383/j.aas.c190581

## Green Energy Complementary Based on Intelligent Power Plant Cloud Control System

XIA Yuan-Qing<sup>1</sup> GAO Run-Ze<sup>1</sup> LIN Min<sup>1</sup> REN Yan-Ming<sup>2</sup> YAN Ce<sup>1</sup>

**Abstract** Based on the theory of cloud control system, an intelligent power plant cloud control system (IPCCS) is designed to overcome problems of complex objects, multi-sources heterogenous data, “information island” and the poor ability of overall optimization scheduling in modern electric power enterprise. To solve problems of strong fluctuation and poor disturbance resistance of green power generation, a machine learning method is used to obtain the short-term prediction value of wind and solar power based on their history data. Then in the cloud, the economic model predictive control (EMPC) algorithm is applied to provide the power predictive scheduling strategy of water turbines by real-time rolling optimization, to ensure the robustness of green energy complementary power generation, consume wind and solar power fully and reduce the frequency of starting/stopping and crossing the vibration zones of the turbines, which both provides clear and stable energy support for the users and protects the devices. The simulations show the effectiveness of the proposed method in an example of regional cloud data center.

**Key words** Green energy complementary, intelligent power plant, cloud control system (CCS), machine learning, economic model predictive control (EMPC), rolling optimization

**Citation** Xia Yuan-Qing, Gao Run-Ze, Lin Min, Ren Yan-Ming, Yan Ce. Green energy complementary based on intelligent power plant cloud control system. *Acta Automatica Sinica*, 2020, 46(9): 1844-1868

收稿日期 2019-08-13 录用日期 2020-02-23

Manuscript received August 13, 2019; accepted February 23, 2020

国家重点研发计划(2018YFB1003700),国家自然科学基金(61836001, 61803033),国家自然科学基金国际合作交流项目(61720106010),国家自然科学基金创新研究群体基金(61621063),北京市自然科学基金(4161001, Z170039)资助

Supported by National Key Research and Development Program of China (2018YFB1003700), National Natural Science Foundation of China (61836001, 61803033), National Natural Science Foundation Projects of International Cooperation and Exchanges (61720106010), Foundation for Innovative Research Groups of the National Natural Science Foundation of China (61621063), and Beijing Natural Science Foundation (4161001, Z170039)

本文责任编辑 孙秋野

Recommended by Associate Editor SUN Qiu-Ye

1. 北京理工大学自动化学院 北京 100081 2. 北京中水科水电科技开发有限公司 北京 100038

1. School of Automation, Beijing Institute of Technology, Beijing 100081 2. Beijing IWHR Hydro Power Technology Development Co. Ltd., Beijing 100038

近年来,网络技术取得显著发展,越来越多的网络技术应用用于控制系统<sup>[1-2]</sup>.为了满足日益复杂、规模日益扩大的控制任务需求,需要采集和存储的数据越来越多,控制系统必须能够处理这些海量数据.传统控制体系面临控制任务越来越复杂、计算能力和存储空间存在约束等严峻挑战,迫切需要具有智能计算、优化控制与决策能力的新一代控制系统<sup>[3-5]</sup>.云控制系统(Cloud control system, CCS)在传统控制系统中引入云计算、大数据处理技术以及人工智能算法,将各种传感器感知汇聚而成的海量数据,也即大数据,存储在云端;在云端利用人工智能算法实现系统的在线辨识与建模,应用任务的计划、规划、调度、预测、优化、决策和控制,结合自适应模型预测控制、数据驱动预测控制等先进控制方

法, 实现系统的自主智能控制, 即形成云控制<sup>[4-12]</sup>. 云计算具有强大的数据计算和存储能力, 边缘计算具有部署灵活、计算实时等特点, 在终端应用边缘控制, 借助网络交互信息, 形成云网边端协作机制, 提高复杂智能系统的实时性和可用性<sup>[13-14]</sup>. 智能电厂是典型的复杂智能系统, 业务规模庞大、种类复杂, 对计算能力和控制品质需求很高<sup>[15-17]</sup>. 集成计算、通信和控制的云控制系统可为智能电厂提供可行的解决方案和先进技术, 云控制平台接收到多种应用任务后, 将其分配给价格低廉、可动态配置的容器、虚拟机等云处理器资源池<sup>[18]</sup>, 与边缘场站和终端设备控制形成协作, 解决基于现代电厂电力大数据的整体协同计划、规划、调度、预测、优化、决策和控制等问题. 绿色能源互补是智能电厂和云控制系统融合的一个重要应用, 本文将利用人工智能和经济模型预测控制 (Economic model predictive control, EMPC), 实现风水光绿色能源互补发电滚动优化调度.

结合云控制系统理论和智能电厂实际场景及需求, 本文设计了智能电厂云控制系统 (Intelligent power plant cloud control system, IPPCCS) 和基于智能电厂云控制系统的绿色能源互补发电滚动优化方法. 如图 1 所示, 左侧表示云控制系统云网边端架构, 其中云控制平台层、边缘控制层、终端设备层与智能电厂的集控层、场站层、现地层相互对应.

同时, 云端与边缘、边缘与终端设备的交互协同不能离开网络, 因此网络传输层也是云控制系统架构的重要部分. 云控制系统和智能电厂相互融合, 形成智能电厂云控制系统. 在智能电厂云控制系统中, 现地层部署电厂具体功能和业务, 包括升压控制系统、巡检安防系统、机组发电系统和工业 IT 系统等, 通过线缆、WiFi、5G 等廉价、便利的通信方式连接、集成到分属场站上. 场站层设有边缘控制器 (Edge controller), 利用边缘计算 (如边缘 Kubernetes 系统) 易于部署、实时性好和可靠性高的特点, 对该场站终端设备进行监视以及精准、稳定的实时管控<sup>[19-20]</sup>. 场站层获取到终端设备的原始数据后, 根据任务类型, 对数据进行分类和预处理. 例如在绿色能源互补发电滚动优化中, 各场站采集到站内机组的原始数据后, 先挑选出风光输出功率预测所需数据, 再在场站对其进行预测, 最后将各场站机组输出功率预测结果发往云控制平台. 将部分任务放置在边缘, 既能充分利用场站的边缘算力, 也可避免所有终端数据直接发往云端, 导致通信成本和云端计算负担成倍增加<sup>[12, 20-21]</sup>.

智能电厂云控制平台部署包括云控制与决策、云存储、规则库和算法库以及孪生电厂等模块. 云控制与决策, 即数据计算和控制决策功能被部署在云端的服务器中, 其中涉及到的优化、管理、调度和

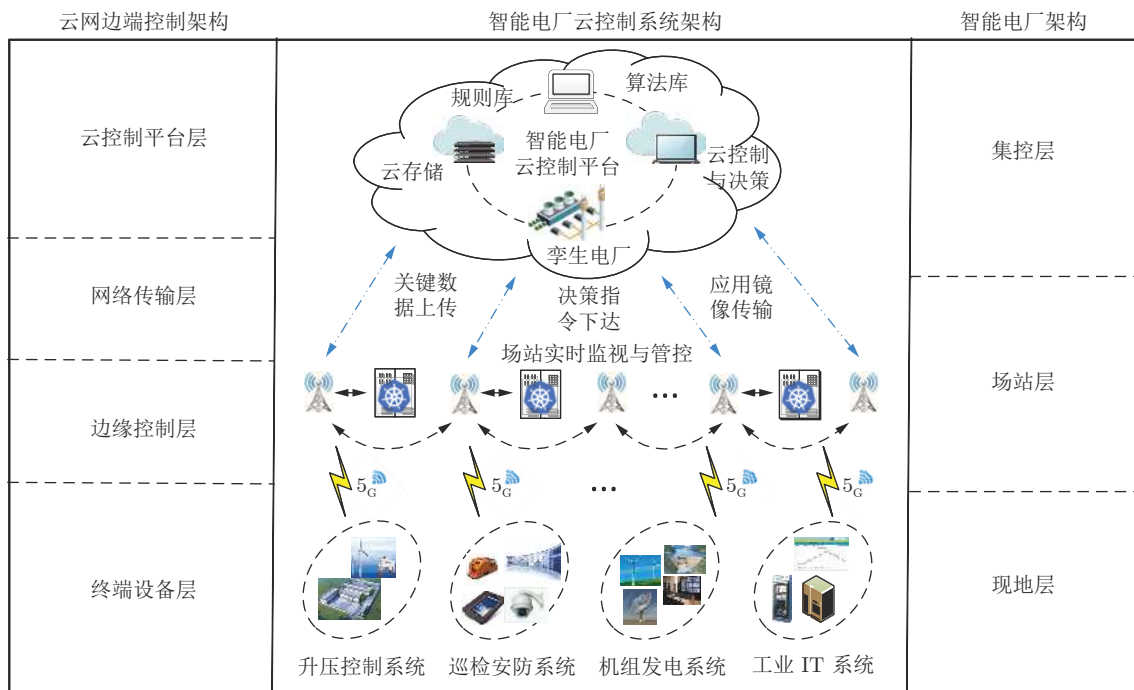


图 1 智能电厂云控制系统云网边端架构

Fig.1 Cloud-network-edge-terminal architecture of intelligent power plant cloud control system (IPPCCS)

控制等算法被集成为算法库; 电厂终端设备在物理空间遵守的规则被封装为规则库; 场站层关键业务、运维数据通过网络传到云端, 形成云存储. 规则库和云存储分别对应模型和数据, 通过二者融合和迭代更新, 在云控制与决策服务器中调用算法库中的方法, 一方面在孪生电厂中模拟运行结果、进行态势演判, 另一方面将得到的全局最优优化调度方案、指令发给各场站以至终端设备. 场站在上层指令指导与约束下, 对终端设备完成边缘控制, 经由云网边端四个层面协作互补, 形成对整个智能电厂系统的统一优化、管理、调度和控制.

在智能电厂云控制系统建立过程中, 计算和数据资源的整合共享处在核心位置. 云计算用网络连接大量计算资源, 统一调度和管理, 形成一个可动态配置的共享资源池<sup>[5-9]</sup>, 和边缘计算协作, 为智能电厂终端设备以及管理人员按需提供计算服务. 在数据共享方面, 建立由云计算、边缘计算、数据库等技术支持, 综合电厂集控、场站、现地三层业务运维信息采集、处理和应用的智能电厂信息云, 利用积压的历史数据, 形成共享资源池, 打破物理壁垒, 解决电厂“信息孤岛”问题. 文献[22]提出电力大数据信息资源库的设计方案, 旨在解决电厂数据无序、分散、滞涨等问题. 文献[23]设计了大数据场景下智能水电厂的新型架构, 将数据中心建设部署在核心位置. 文献[24]则分析了电厂生产环境中的实际数据类型、特点, 基于云计算、虚拟化技术设计了智能全息电厂信息平台架构. 目前, 主流电厂各生产环节都实现了成熟的自动化, 关键数据基本实现了自动采集、分类和整理. 例如四川大渡河流域发电公司充分接入生产环境各类数据, 结构化数据接入速度达到 4 MB/s, 非结构化数据达到 100 MB/s, 已具备智能电厂信息云建立的充分条件.

建立智能电厂信息云之后, 智能电厂云控制系统可以承载许多重要应用, 绿色能源互补发电即是其中之一<sup>[25]</sup>. 当前, 化石能源不断消耗并且破坏生态环境, 风能、水能和太阳能等绿色能源得到广泛的重视和开发利用. 如图 2 所示, 风、水、光三种绿色能源在时间和空间上具有很好的互补性, 但纯绿色能源的消纳受偶然因素影响较大, 导致风水光等纯绿色能源互补发电的鲁棒性不高, 因此目前的研究多集中于煤炭、油气等化石能源和一种或多种新能源, 即混合能源的互补优化<sup>[26-28]</sup>. 其次, 现有绿色能源或混合能源互补优化方法, 多采用单次优化求取策略的形式, 不能考虑绿色能源功率的变化, 单次优化存在偶然性较大的问题, 鲁棒性也因此受到

影响. 最后, 绿色能源互补优化问题面临许多约束, 如水轮机组的功率调节限制、爬坡率限制等, 一般控制算法不易处理多约束问题. 模型预测控制是一种基于模型的最优控制策略, 将控制问题转化为优化问题, 用滚动优化的方式求解最优预测控制序列, 由此具有较强的鲁棒性, 并且适合处理多约束问题. 但在许多实际场景中, 性能目标不能简单地设为对稳定点的跟踪. 经济模型预测控制 (EMPC) 不局限于标准的状态空间模型, 不要求代价函数的具体形式, 只强调模型的功能, 直接将经济目标作为优化函数, 因此特别适合绿色能源互补优化问题. 然而, 对于绿色能源互补优化问题, 没有可迭代的模型以供推演和求解优化问题, 即 EMPC 不能直接应用于本问题.




图 2 楚雄州风水光伏电站平均出力曲线

Fig.2 Average output of wind, hydro and solar power in Chuxiong state

另一方面, 智能电厂信息云中蕴含着丰富的风电、光电功率等历史数据, 这些数据暂未被充分利用. 本文综合以上问题, 基于智能电厂云控制系统, 设计了一种 LSTM-EMPC 方法. 该方法使用 EMPC 的框架, 先用长短期记忆网络 (Long-short term memory, LSTM) 预测未来风电、光电的功率输出情况, 消解不确定性, 填充完整原本不可迭代的绿色能源互补优化模型, 使其满足滚动优化的条件; 再用 EMPC 方法求解得到水轮机组的最优预测调度方案, 保证区域供电稳定, 减少水轮机组开停机次数, 降低功率波动对机组的损耗, 保证系统鲁棒性.

本文主要贡献如下: 1) 面向现代电厂控制业务发展的技术需求, 首次提出智能电厂云控制系统设计方案以及关键技术体系, 给出云控制系统在智能电厂领域的应用示例; 2) 针对智能电厂云控制系统中的绿色能源功率预测问题, 设计基于 LSTM 的风电、光伏输出功率智能预测机制, 短时预测精度分

别达到 92% 和 97%, 为绿色能源互补发电滚动优化提供数据基础; 3) 建立风水光互补发电的数学模型, 在云端设计基于 EMPC 的绿色能源互补发电滚动优化方法, 求解得到水轮机组的最优预测调度方案; 4) 针对区域新能源电厂和绿色数据中心联立运行应用场景, 进行了基于电厂实际数据的优化调度, 仿真结果表明了本方案的有效性.

### 1 智能电厂云控制系统的设计和建立

云控制系统集成了云计算、物联网技术、网络化控制理论以及其他最新研究成果<sup>[29-33]</sup>, 能够为智能电厂管控提供有力的支撑. 并且随着云计算、边缘计算和网络通讯等能力的提升, 智能电厂云控制系统处理计算任务的能力也将不断提高. 基于容器技术, 智能电厂云控制系统提供了一个可动态配置、获取计算资源与数据的镜像池<sup>[34]</sup>, 包含机组控制调度、故障分析、电力大数据存储与访问等业务. 集控层和场站层的业务执行者无需知道服务提供者的

物理位置和配置信息, 只需拉取镜像就可使用. 如图 3 所示, 将智能电厂管控需求和云控制闭环反馈以及边缘控制技术结合, 采用大数据智能分析、协同控制、资源调度等技术, 能够实现智能电厂的云端决策、云网边端协同控制、云端虚拟资源和终端物理资源的协调调度等. 通过云端智能控制决策等和基于边缘计算的终端闭环控制的交互协作, 实现智能电厂云控制系统的整体优化管控.

目前云计算体系有基础设施即服务 (Infrastructure as a service, IaaS)、平台即服务 (Platform as a service, PaaS) 和软件即服务 (Software as a service, SaaS) 三种服务模式<sup>[35]</sup>. 从控制角度分析, 智能电厂终端设备规模庞大、种类复杂, 应拆分成具体的业务单元, 而不是将其作为一个整体进行建模以及控制. 在本文云网边端架构中, 将电厂关键数据存储于云端, 计算任务运行时申请业务池中的镜像, 拉取容器快速实例化执行云端任务; 云端下发全局命令后, 场站层按相同方式从场站服务器中申

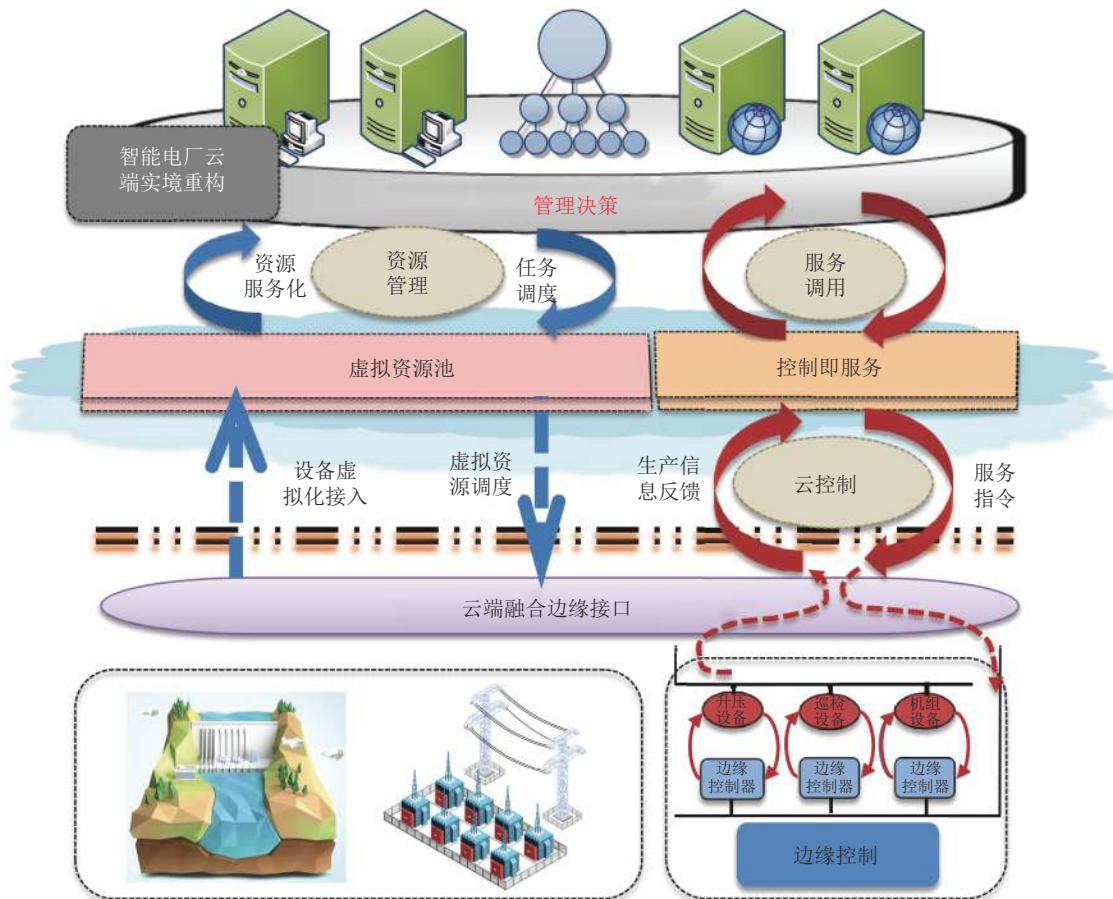


图 3 智能电厂云控制系统云边端协同控制架构

Fig. 3 Cloud-network-edge-terminal collaborative control architecture of IPPCCS

请资源执行边缘计算任务; 现地层维持终端设备的自稳运转, 接收到上层指令后执行动作完成边缘控制, 提高智能电厂整体管控的实时性和可用性. 因此, 可将控制封装为一种按需申请、随取即用的服务, 也就是控制即服务 (Control as a service, CaaS)<sup>[7-9]</sup>.

CaaS 面向智能电厂云控制云网边端服务应用以及系统操作、开发人员. 业务申请者和系统操作人员向服务提供者申请获得所需要的镜像和容器执行业务应用; 系统开发人员则创建、修改、删除镜像, 调试确定所需容器 CPU、内存和网络带宽等配置, 将其封装进业务镜像池中以供使用. CaaS 也可基于虚拟机开发, 为用户提供包含基础操作系统、专业控制软件、网络和存储等资源配置的控制开发平台. 基于容器的 CaaS 与基于虚拟机的 CaaS 相比, 部署速度更快、灵活性更高, 系统稳定性较弱, 但都具有极高的系统集成度、经济性和可复用性.

智能电厂的应用都可以通过网络来执行, 业务请求者只需要连接上网络, 通过接口平台或者 Web 界面就可以定制调用修改部署在云端的服务器, 免去高昂的硬件设备费用和底层控制算法的冗余开发开销. 终端设备采集业务和环境数据上传到云端, 云控制器通过计算求解得到和实际任务相适应的系统参数、控制指令, 返回边缘控制终端. 在智能电厂云控制系统中, 相关的优化、管理、调度和控制等服务被封装成 CaaS 的形式, 通过云端融合边缘接口提供给业务请求者, 其业务镜像池机制能够支撑智能电厂庞大的业务规模以及满足具体场景、任务下的定制化需求.

智能电厂云控制系统包括智能电厂边缘控制、数字孪生虚拟化、云端任务与资源匹配调度和云网

边端安全管控等关键技术, 技术体系如图 4 所示. 对于底层智能电厂终端设备, 使用边缘控制技术实现精准、自稳、基础性的本地控制, 保证边缘系统在独立条件下依然能够稳定运行, 同时充分利用本地计算资源, 降低云端的计算和通信负担; 云端任务与资源匹配技术与边缘控制技术配合, 通过合理分工, 信息、控制指令和应用镜像的传输, 共同协作, 优化智能电厂整体运行; 左侧云网边端安全管控技术从云端、网络、边缘和终端四个层次保障智能电厂系统的安全性和可靠性. 右侧为数字孪生虚拟化技术, 通过边缘、终端两层设施的映射, 在云端建立规则库、算法库以及孪生电厂, 再通过实时或关键数据的传输, 调度云资源池中的资源, 驱动孪生电厂更新运行, 得到全局优化管控方案. 智能电厂云控制系统的四项关键技术之间有着密切的联系, 互相协作驱动, 形成一个有机的整体.

### 1.1 智能电厂边缘控制技术

在智能电厂云控制系统框架中, 我们提出了边缘控制技术. 边缘控制充分利用边缘计算的优势, 基于 5G 时代云端算力下沉、终端算力上移的特点, 无需把底层数据全部上传至云端驱动决策, 只需在本地或小范围内对目标系统进行控制, 以保证终端设备控制的实时性、可用性以及经济性. 如图 5 所示, 云控制平台和终端设备及边缘控制器通过云端融合边缘接口相连接, 使用自适应智能网关技术实时调控网络流量, 通过边缘安全管控机制保护终端设备, 规避安全隐患. 在边缘层, 部署边缘控制、边缘计算和边缘感知模块, 与终端层的升压控制、智能机器人与无人机巡检安防和机组发电等设备相连实现精准、稳定实时控制; 对于服务器、PLC 板、控制柜等工业 IT 设备, 在边缘层设有数据接入与 I/O 接口, 实时收集、处理 IT 设备数据, 进行信息交互. 在自适应智能网关和边缘安全管控技术的保护下, 边缘层和终端层组成边缘-终端系统安全管控体系. 边缘层和终端层使用 WiFi、5G、缆线等多种灵活的方式连接, 其中 5G 传输速度可达每秒千兆位, 满足未来智能电厂云控制系统的实时性需求.

面向智能电厂云控制系统底层的边缘-终端安全管控系统, 其核心是基于电厂设备运行大数据的采集、处理、分析和对设备运行环境的实时感知, 利用边缘计算实现电厂设备具体的控制策略, 完成对终端设备的本地控制<sup>[12]</sup>. 通过设置 Kubernetes 资源调度集群, 建立小型、轻量化的容器计算节点, 提供边缘算力, 调度计算任务所需资源, 从而管理和控

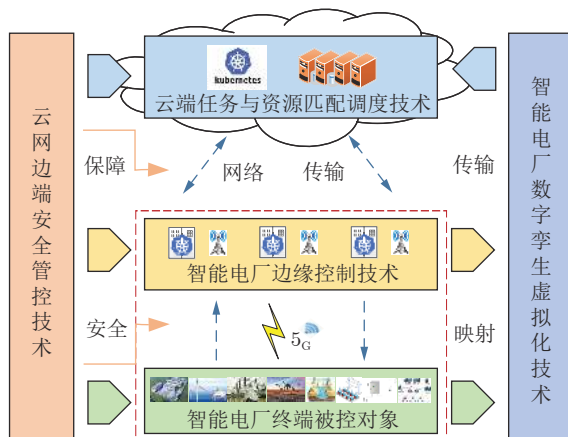


图 4 智能电厂云控制关键技术体系

Fig.4 Key technologies system of IPPCCS

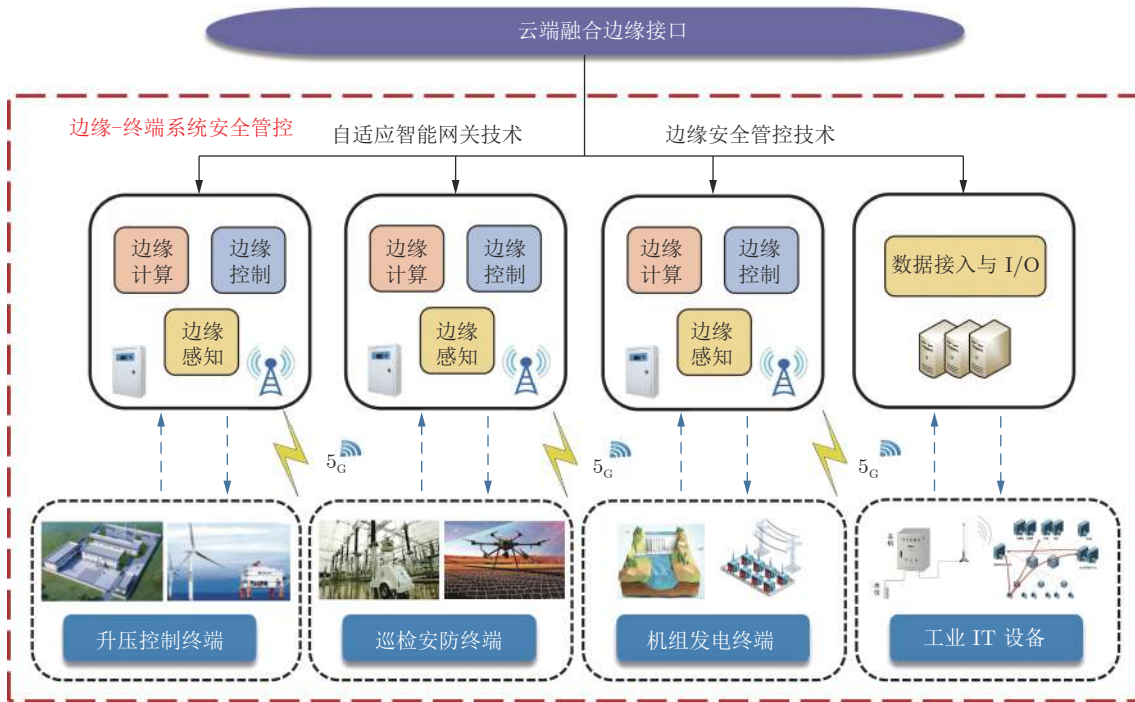


图 5 智能电厂云控制系统底层边缘控制

Fig.5 Edge control system in IPPCCS

制终端设备<sup>[36-37]</sup>. 将 Kubernetes 系统部署在边缘, 除了便于部署和管理, 提升受限条件下的资源利用率, 还可以有效地和云端相互协同<sup>[38]</sup>. 具体表现在:

1) 任务分工协同. 云端完成上层的计划、规划、调度、决策、控制后, 将具体任务分配给边缘计算资源, 由边缘计算集群分析、处理任务, 并调度计算资源, 完成应用任务的计算过程, 交由终端设备执行.

2) 镜像传输协同. 容器的工作模式是将一定任务的执行程序, 以及所需要的资源规格和运行环境打包, 封装成方便复制和传输的镜像. 在云端和不同边缘集群间有以下相互作用:

a) 将云端非关键程序的镜像卸载到边缘上, 由边缘设备启动镜像, 调度边缘计算集群的资源并执行;

b) 边缘发现难以处理某项计算任务, 将镜像上传到云端, 借助云端的丰富资源进行处理;

c) 对于功能相似但物理空间相距较远的边缘和终端, 则可以将已有任务的执行程序封装成镜像, 仅将镜像复制传输至目标边缘, 在目标边缘配置资源、启动容器即可, 从而降低系统的开发、运行成本.

由上所述, 边缘-终端系统在智能电厂云控制系统中为云端控制提供局部信息, 与云端控制系统相互协作, 是智能电厂云边端协同控制的重要组成部分<sup>[20-21]</sup>. 云端控制决策系统为参与业务的多个终

端设备提供全局控制策略, 统筹整个智能电厂设备网络, 通过云网边端协作保证智能电厂云控制系统良好运转.

### 1.2 智能电厂数字孪生虚拟化技术

智能电厂数字孪生虚拟化技术, 可将物理设备网络虚拟成多个虚拟子网络组成的虚拟设备网络<sup>[36]</sup>. 核心思想是应用虚拟化技术对电厂设备进行精细化虚拟, 虚拟设备具有轻量化、可复用、弱耦合的特点, 易于被自动化部署在虚拟空间中, 降低智能电厂开发、管控和运维的复杂度. 如图 6 所示, 智能电厂云控制网络相互耦合的整体架构可被拆分为云控制平台、虚拟化平台和物理应用平台三层架构.

云控制平台层包括云控制与决策、云存储、规则库和算法库以及孪生电厂等模块. 对规则库中的模型和云存储中的数据进行融合和更新, 在云控制与决策模块中调取算法库中的算法, 即业务池中的镜像, 在云资源池中启用容器, 驱动孪生电厂模拟运行、演判态势, 得到全局优化管控方案, 将控制调度指令发到各场站及终端设备, 完成云网边端协同. 孪生电厂为真实电厂提供了许多的扩展和可能性, 例如模拟真实电厂设备生命周期, 提前预判设备失效、故障时间并且更换设备避免影响电厂运行; 结合现场数据、孪生电厂运行结果判断故障原因; 为操作人员提供仿真培训环境; 以及作为伪系统蜜罐

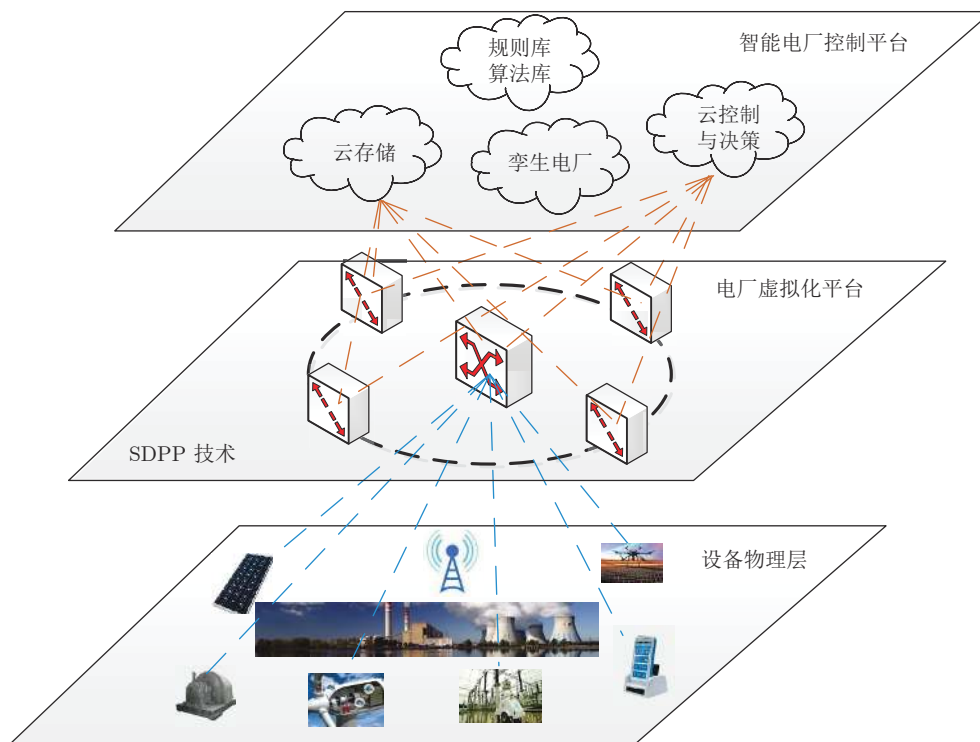


图 6 智能电厂云控制数字孪生虚拟化架构

Fig.6 Digital-twins virtualization structure in IPPCCS

防范网络攻击等.

利用智能电厂虚拟化平台, 底层电厂设备在云端依据物理世界的规则库被抽象成多个逻辑实体. 智能电厂管理者看到的是虚拟化平台给出的数字孪生电厂. 这样云端服务可以和物理电厂设备解耦, 便于云端资源的灵活部署和快速优化决策. 随着信息世界和物理世界的深度融合互联, 软件定义技术开始向物理世界延伸. 在智能电厂云控制系统中, 我们提出软件定义电厂 (Software defined power plant, SDPP) 的概念, 利用软件可编程技术对智能电厂设备网络进行定义和映射, 用灵活度更高、可替代性更强、耦合性更弱、更易部署的虚拟资源来代替物理资源, 用软件为硬件赋能, 更易实现云端精细化管理和控制, 达到开放共享和互联互通的目的<sup>[37-38]</sup>. SDPP 技术的核心是电厂设备硬件资源虚拟化、管理对象和功能可编程实现. 传统电厂设备网络抽象为虚拟资源, 利用云端部署软件对虚拟电厂, 即数字孪生电厂进行计算和调度决策. 该技术可以实现电厂设备层和云端计算层的分离, 利用程序软件既能保证虚拟化映射的完整性和准确性, 又可满足电厂管控任务的多样性及动态需求<sup>[39-41]</sup>.

### 1.3 智能电厂云端任务和资源匹配调度技术

智能电厂系统中存在上千条控制策略的触发、

分析、回馈和流转, 其中不乏输入输出/数据密集型任务请求. 智能电厂云控制系统需要充分利用云平台的计算能力, 为任务最优化分配 CPU、内存、网络带宽等资源, 降低任务完成时间, 提高资源利用率, 以高效、低成本地处理智能电厂云端计算任务. 资源调度一般分为基于容器和基于虚拟机两种, 本节采用基于容器的方法<sup>[18, 42-43]</sup>.

如图 7 所示, 在智能电厂云端任务和资源匹配调度技术框架中, 任务首先被提交并被云端收集到, 然后对这些任务进行分类和预估, 确定所需申请的计算资源量. 智能电厂云控制系统平台由公有云和私有云 (或私有服务器) 集成, 由 Kubernetes 系统管理物理机和虚拟机的计算资源, 抽象成统一的混合资源池<sup>[44]</sup>. 智能电厂关键生产运维任务可部署在私有云中处理, 保障业务安全. 部分任务放在公有云中, 避免因可伸缩性不足导致资源请求过载或者浪费. 安全需求相对较低、计算量及资源请求量弹性较大的任务在公有云中运行, 实时申请到适额的计算资源, 保证系统稳定运行, 减少开销和资源浪费, 提升智能电厂业务处理的弹性和经济性.

任务经分类后被提交到调度器中, 由混合资源池提供资源的可选配置. 根据是否存在依赖关系, 任务请求被分为离散任务和云工作流, 其中云工作

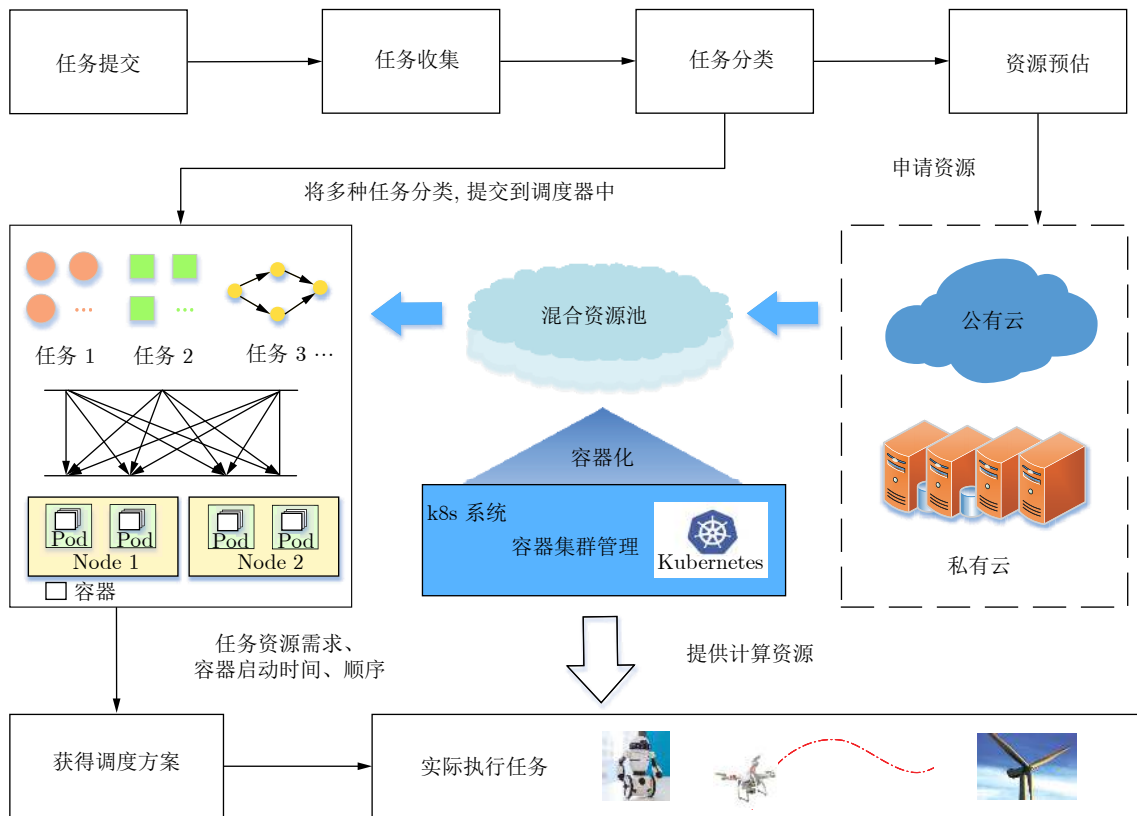


图 7 智能电厂云端任务和资源匹配调度技术框架

Fig.7 Cloud tasks and resources matching scheduling framework in IPPCCS

流是根据任务处理的实际逻辑关系形成的具有前后依赖的复杂任务. 针对不同场景、需求和任务种类, 调度器可采用考虑任务优先级、含截止时间/能耗约束、关键路径分析、任务群合并以及深度强化学习等算法实现最优调度策略的选取, 将任务匹配给生存在 Node 节点池中的容器列表<sup>[18, 45-47]</sup>. 获得调度方案即任务资源需求、容器启动时间和顺序后, 将需求交给 Kubernetes 系统, 后者提供资源建立和启动容器, 完成巡检机器人和无人机轨迹规划、新能源机组排产调度、电厂生产环境音视频直播数据分析处理等任务的处理.

#### 1.4 智能电厂云网边端安全管控技术

工业场景接入云计算不可避免的一个问题是云的安全性考量, 智能电厂也不例外<sup>[11, 48-49]</sup>. 云安全是智能电厂云控制系统必须关注的重大关键问题, 也是目前电力企业将业务接入云计算系统的主要顾虑. 如图 8 所示, 依据被攻击对象以及安全隐患发生阶段的不同, 智能电厂云控制系统安全问题可划分为云、网、边、端四个层面来考虑.

在云端面临的主要风险来自云平台, 包括云平

台自身的可靠性、外部信号对云平台的恶意攻击, 以及客户隐私数据对云服务商的透明性问题等. 针对这些问题, 在云平台层面, 智能电厂云控制系统设计安全可信云技术机制, 实现云服务合规性验证、云平台安全防护, 以及云数据隐私保护等保障功能<sup>[29, 50-51]</sup>, 保障云端控制决策系统安全、稳定运行. 在网络传输层面, 面临的则是从云到端通信故障以及数据隐私泄露的风险, 采用云端和边缘双向智能高效通信加密 SDK (Software development kit) 技术保证通信安全<sup>[52-53]</sup>.

智能电厂边缘控制系统和终端设备进行实时边缘控制的交互, 在边缘、终端双层安全系统的保护下, 形成边缘-终端系统安全管控体系. 具体而言, 边缘安全防护系统采用软硬件相结合的方式, 在软件方面使用边缘身份认证和自适应攻击防护等算法, 在硬件层面则设计智能网关、安全控制器、隔离装置、安全审计装置等智能电厂安全防护设备, 同时配套防火墙、入侵检测装置等系统, 将以上软件嵌入其中, 规避边缘设备管控的安全隐患<sup>[19]</sup>. 在终端设备一侧, 主要考虑操作者或者上层信号的真伪性问题, 针对种类不同、智能程度不同、重要性不同



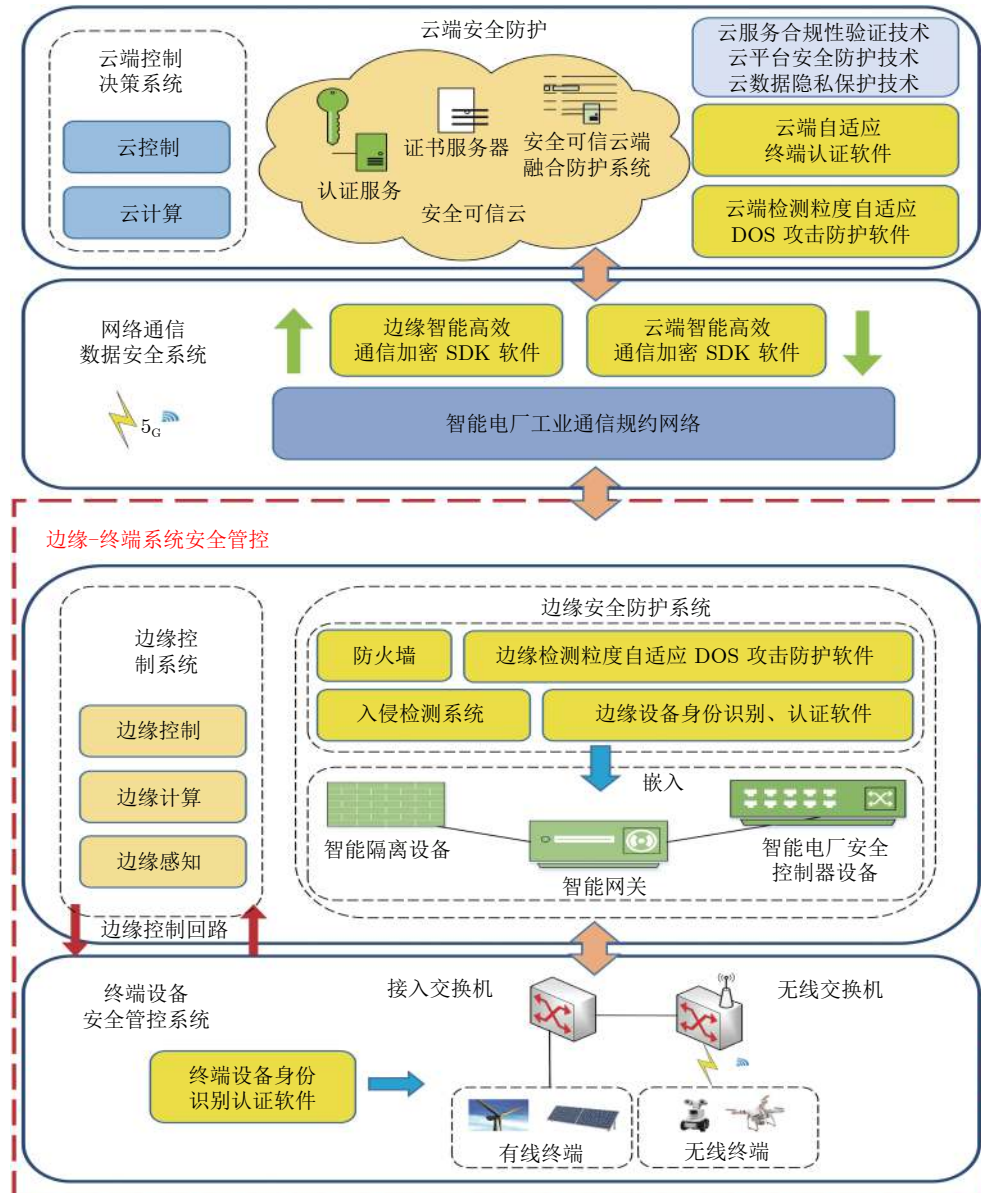


图 8 智能电厂云控制云网边端安全管控技术架构

Fig.8 Cloud-network-edge-terminal security management and control framework in IPPCCS

的各类底层设备,使用差异化的身份终端认证方法,保障云端调度优化指令、边缘控制命令等准确无误地执行下去<sup>[54]</sup>.智能电厂云控制系统通过云网边端四层安全管控机制,实现对电厂各层级软硬件及网络的可靠支持和保护.

特别地,区块链和5G作为两种新兴的技术,将为智能电厂,特别是在安全方面带来新的机遇和挑战.对区块链来说,基于其追溯机制和共识算法设计对网络攻击的检测与防御机制,基于安全加密机制进行云网边端数据可信采集与传输研究,利用去中心化特性研究云数据中心安全管控机制,利用非

对称加密机制进行数据通信和存储中的隐私防护<sup>[55-58]</sup>.

5G作为一种高效的通信手段,具有大带宽、低时延、高可靠性等优势,十分适合智能电厂云控制系统云网边端协作的应用场景.但是将其应用在智能电厂也相应地存在安全问题,并且呈现多样化的特点.主要解决手段包括<sup>[59]</sup>:在云平台、边缘场站和终端设备之间建立通信接入和双向认证机制,避免通信主体、内容信息被泄露;使用基于软件定义网络(Software defined network, SDN)的5G切片安全隔离技术,保障通信切片之间安全隔离,应对非

法访问和越权管理; 在密钥管理方面, 5G 设计管理面、控制面和用户面分离机制, 三者不能相互访问, 通过传输层协议对数据进行机密性/完整性保护, 设计多种密钥管理机制, 应对智能电厂内复杂的应用场景; 在 5G 网络提供服务接口时, 设计智能电厂定制的授权机制, 对潜在冲突策略进行检测, 控制相关权限和进行安全审查等。

### 1.5 云控制系统在智能电厂环境中的部署

集控中心是电厂集团级公司生产运营管理的专业化机构, 负责区域内电力场站、设备的生产运营管理, 借助网络打通分散式、扁平化的生产管理模式, 转向实现区域化、集约化的精益生产管理模式, 以期实现“无人值守、少人值守”的设计目的<sup>[19, 60]</sup>。目前集控中心仍存在数据处理能力不足、信息壁垒难以打破、精细化管理程度不够等系列问题, 但其设计理念和目标与智能电厂云控制系统有共同之处, 因此可以借助现有集控中心的设施框架, 将智能电厂云控制系统很好地嵌入其中, 降低部署难度和成本。

#### 1.5.1 云控制系统在智能电厂环境中的部署位置

以江西南昌集控中心为例, 网络设计基于成熟的工业以太网架构, 设计了“三层四分区”的网络和设施部署结构。从控制层级角度, 集控中心采用的是分层分布式网络, 分为负责边缘数据采集、处理和监控功能的现地层; 完成场站级数据采集、处理, 全场设备监视和控制, 统计运维数据的场站层; 以及负责所有接入场站的数据管理, 全局优化、调度、管理、决策和控制的集控层。

从系统安全分区的角度, 可划为四个区域网络, 分别是实时控制区(安全 I 区)、非控制生产区(安全 II 区)、生产管理区(安全 III 区)和信息管理区(安全 IV 区)。实时控制区和非控制生产区、生产管理区以及信息管理区之间用防火墙隔离, 非控制生产区和生产管理区用正反向隔离装置隔离。图 9 是其分区结构和业务分布示意图。其中, 安全 III 区汇总安全 I 区、II 区和自身 III 区的数据, 控制指令可达区域电厂的每个设施, 并且可通过安全 IV 区与外部网络相连, 向外部世界发布电厂生产经营信息, 同时便于系统开发、更新部署和管理运维, 是理想的企业云端控制系统部署位置。

#### 1.5.2 云控制系统在智能电厂环境中的通信部署

上述部署方式具有较为完善的通信功能, 能够进一步实现整体的资源优化以及信息共享, 具备高

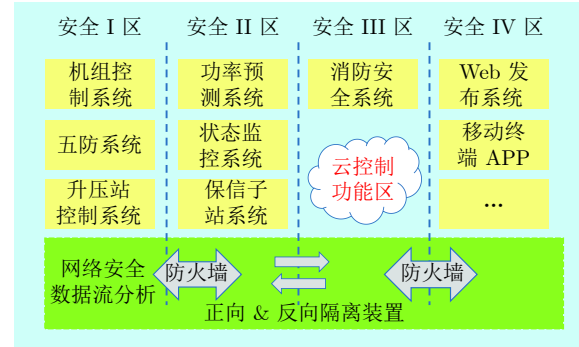


图 9 集控中心层网络安全分区业务分布图

Fig.9 Services distribution in centralized control center for network security

效、实时处理的基本能力。智能电厂云控制系统的通信包括云端集控层和场站层以及包括现地层在内的场站层一侧通信。在电力系统中, 为保证数据通信系统有效、可靠地通信, 规定双方遵守一定的通信规约, 包括数据格式、顺序速率、链路管理等。WiFi、5G 等相当于消息管道, 也经由标准的规约进行通信。云端集控和场站层之间一般用统一的 Kafka 或 IEC104 规约进行通信; 而场站和现地层之间的通信接口和规约比较庞杂, 通常不使用标准规约。数据采集频率和控制命令的响应速度是重要的考量指标。

如图 10 所示, 云控制系统在智能电厂环境中的通信部署还必须考虑安全问题。根据云网边缘四层安全管控架构, 在云端与外界环境存在交互, 因此需注重云平台自身安全的防护, 在对外发布时需考虑核心数据的筛选评判, 同时对云服务商建立数据隐私保护机制。在云端集控中心和场站层信息的交互中, 使用自适应攻击防护、场站身份认证、通信数据加密等机制, 通过智能网关和部署在场站的安全控制组件来保障云端和场站接收到的信息是安全、可信的。在场站-现地一侧, 因为场站层到现地层是一种较低层次的网络传输, 还未到达边缘终端, 所以也需使用网络安全防护机制。在现地层, 采取终端身份识别和认证机制, 对接入网络的终端进行多尺度、细粒度的身份识别和认证, 确定接入终端的安全属性身份, 保障边缘控制精准施行、不受干扰。

#### 1.5.3 云控制系统在智能电厂环境中的工作方式

智能电厂云控制系统的基础在于智能电厂信息云的建立, 因此如何在边缘和云端建立数据的稳定存储结构和通信方式是十分重要的。如图 11 所示, 首先在安全 I 区和安全 II 区上以 MongoDB 的形式

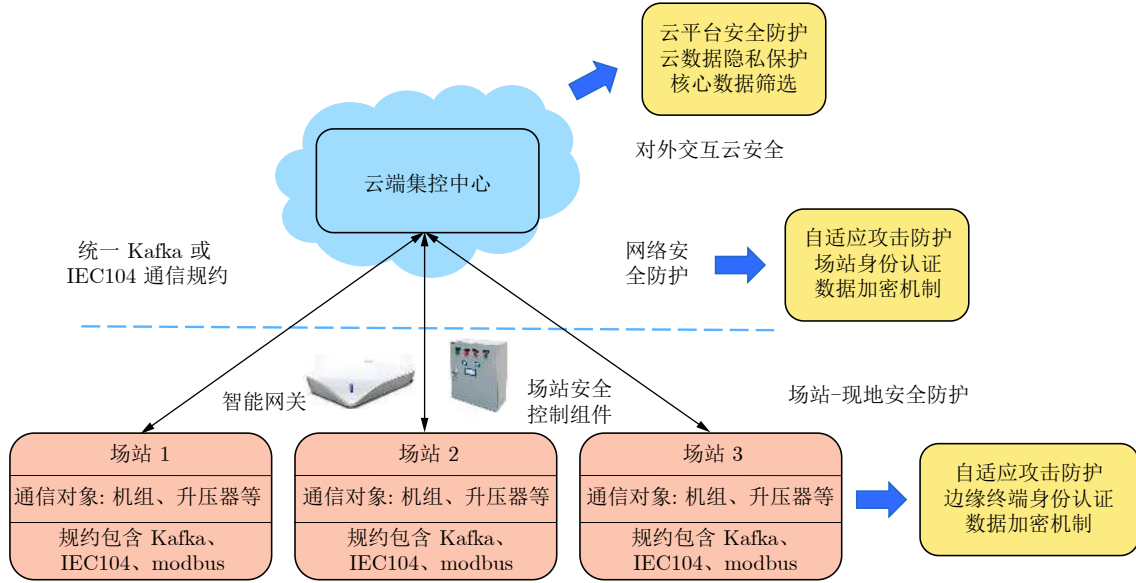


图 10 含安全防护机制的云端集控中心与场站现地通信和规约方式

Fig.10 Cloud-local communication and protocol mode with security protection mechanism

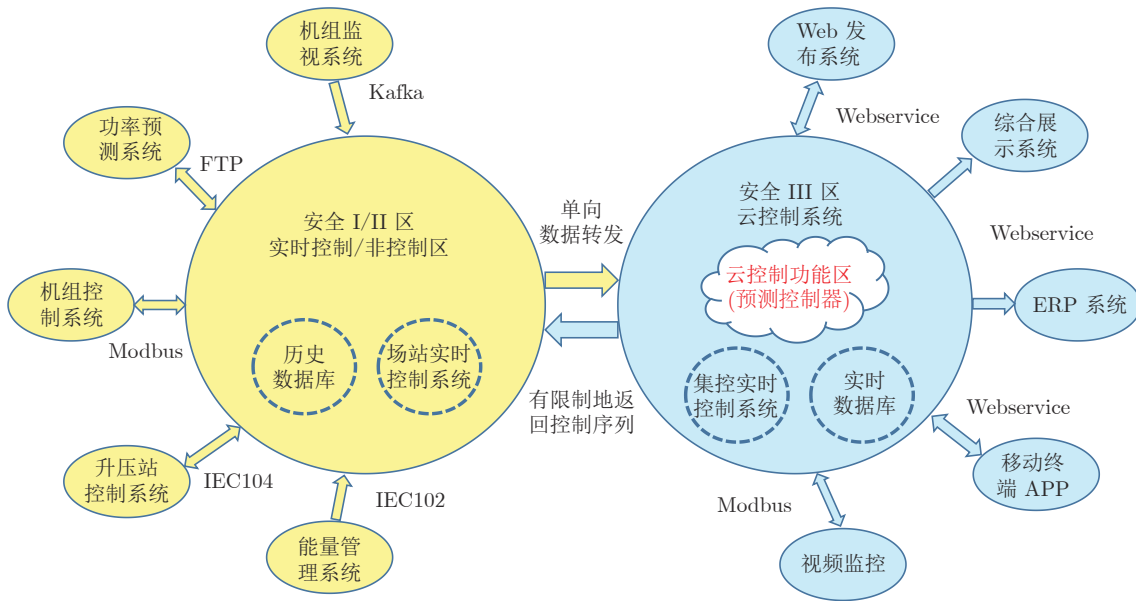


图 11 智能电厂云控制系统工作拓扑图

Fig.11 Work topology of IPPCCS

部署历史数据库. MongoDB 以单个对象在某一时段的数据作为文档单元进行存储, 时间尺度为 1 分钟/1 小时/1 天不等. 历史数据库直接和场站相连, 与机组控制系统、功率预测系统等交互信息. 历史数据库将数据单向转发到实时数据库中.

云控制功能区和实时数据库部署在安全 III 区上. 公有云和私有云集成混合云平台, 在其上进行开发形成智能电厂云控制功能区, 即云控制平台层. 在实时数据库中, 每个数据对象的实时值或状

态属性按秒级刷新, 数据集大小不随时间变化而增大. 实时数据库与视频监控、综合展示等系统相连. 完成数据处理后, 将全局指令返回场站及现地系统中, 完成智能电厂云控制系统云网边端协同应用任务.

以绿色能源互补优化调度为例, 整个智能电厂云控制系统的运转可归纳为: 部署在本地的风力、光伏等新能源机组和监控系统将现场数据和基于历史数据的未来输出功率预测结果实时上传到安全

I 区和安全 II 区的历史数据库中, 由历史数据库将数据单向转发到安全 III 区的实时数据库中. 云控制功能区根据实时数据库中的数据计算出最优控制调度策略, 将控制调度策略按相反路径返回本地, 从而实现各系统数据在云控制平台上的统一管理和最优控制调度. 这一新型的智能电厂控制架构在现代电厂中引入了云控制系统, 提高了现代电厂共享经验、信息、数据和智能化处理海量数据的能力, 实现了智能电厂云网边端协同优化、管理、控制和调度等功能.

## 2 预备知识

在本文中, 涉及到的基础理论有长短期记忆时序预测网络、经济模型预测控制和风、光、水发电系统模型等, 以下将分别介绍.

### 2.1 长短期记忆时间序列预测网络

长短期记忆网络 (LSTM) 是一种时间递归神经网络. 在普通的深度神经网络中, 每层的节点都是无连接的. 当问题的当前状态和之前状态有关联时, 容易导致处理结果不佳. 循环神经网络 (Recurrent neural network, RNN) 可以通过在隐含层神经元增加递归的边, 使神经网络有记忆性来解决这个问题. 但普通 RNN 网络很难处理序列的长时间依赖问题, 而且当序列长度超过一定阈值时, RNN 网络会变得不稳定, 在训练时会出现梯度消失或梯度爆炸. LSTM 网络弥补了 RNN 网络的缺陷<sup>[61]</sup>, 成为当前比较流行的循环神经网络, 其内部结构如图 12 所示.

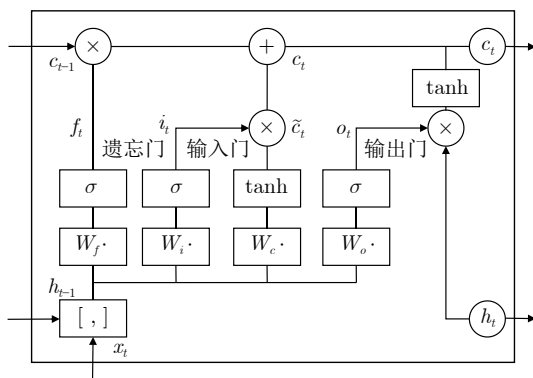


图 12 LSTM 神经网络细胞结构

Fig.12 Cell structure of LSTM neural network

前向传播公式如下:

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \quad (3)$$

$$c_t = f_t \times c_{t-1} + i_t \times \tilde{c}_t \quad (4)$$

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(c_t) \quad (6)$$

其中,  $f_t$  表示遗忘门,  $i_t$  表示输入门,  $o_t$  表示输出门,  $W_f$ 、 $W_i$  和  $W_o$  分别代表它们的权重,  $b_f$ 、 $b_i$  和  $b_o$  是它们的偏置,  $h_t$  表示  $t$  时刻的输出,  $c_t$  表示  $t$  时刻单元状态,  $\sigma$  表示 sigmoid 激活函数,  $\tanh$  表示双曲正切激活函数.

### 2.2 经济模型预测控制

模型预测控制 (Model predictive control, MPC) 是一种基于模型的最优控制策略, 通过最优化某一涉及到系统未来行为的性能指标, 同时满足系统约束, 从而确定系统未来的控制输入<sup>[62]</sup>. 而性能指标中涉及到系统未来的行为, 根据预测模型由未来控制目标决定. 在某一采样时刻  $t$ , 控制器以系统当前时刻的状态作为初始状态, 通过系统模型预测在  $[t, t + N]$  时间段内系统的动态行为; 同时, 按照给定的性能指标及约束求解一个最优问题, 确定  $[t, t + p]$  时间段内的控制行为. 到下一采样时刻, 获得系统最新的实际输出, 将预测时域  $N$  和控制时域  $p$  同时向前推进, 进行下一步的在线优化. 模型预测控制的优化不是一次离线完成的, 而是反复在线优化计算的, 因此模型预测控制又称为滚动时域控制.

在许多工业场景中, 性能目标不能简单地设定为控制问题中对稳态点的跟踪. 经济模型预测控制 (Economic MPC, EMPC) 不拘泥于模型的具体形式, 不要求代价函数关于平衡点的正定性, 只强调模型的功能, 即只要有预测功能的模型均可作为预测模型, 直接将经济目标作为优化函数<sup>[63-64]</sup>. 经济模型预测控制在保证控制性能、经济效益的同时, 具有能够有效处理多约束、多变量实际问题的特点. 基于此, 本文设计了针对绿色能源互补发电的滚动优化预测调度方法. 经济模型预测控制问题通常表示如下:

考虑如下离散时间非线性系统模型

$$\begin{aligned} x(t+1) &= f(x(t), u(t)) \\ y(t) &= g(x(t), u(t)) \end{aligned} \quad (7)$$

其中,  $x(t) \in \mathbf{R}^n$ ,  $u(t) \in \mathbf{R}^m$ ,  $y(t) \in \mathbf{R}^p$ ,  $t \in \mathbf{N}$  分别代表系统的状态量、控制量、输出量和时间节点.

该系统满足以下形式的状态和输入约束:

$$x(t) \in \mathcal{X}, u(t) \in \mathcal{U} \quad (8)$$

其中,  $\mathcal{X} \subseteq \mathbf{R}^n$  和  $\mathcal{U} \subseteq \mathbf{R}^m$  代表状态变量  $x(t)$  和控制变量  $u(t)$  的约束集合.

优化目标描述为

$$J_N(t) = \sum_{i=0}^{N-1} L(x(t+i|t), u(t+i|t)) \quad (9)$$

对于含约束系统 (7) 和 (8), 在采样时刻  $t$ , 给定状态  $x(t)$ , 可将经济模型预测控制问题表述为如下的优化问题:

$$\min_{u(t+i|t), i=0,1,\dots,N-1} J_N(t) \quad (10)$$

$$\text{s.t. } x(t+1) = f(x(t), u(t)), i = 0, 1, \dots, N-2 \quad (11)$$

$$x(t|t) = x(t) \quad (12)$$

$$x(t+i|t) \in \mathcal{X}, i = 1, 2, \dots, N-1 \quad (13)$$

$$u(t+i|t) \in \mathcal{U}, i = 0, 1, \dots, N-1 \quad (14)$$

其中,  $U(t+i|t) \in \mathcal{U}, i = 0, 1, \dots, N-1$  是优化问题的决策变量. 在当前采样时刻  $t$ , 如果优化问题 (10) ~ (14) 可行, 可以求解并得到最优控制输入序列  $u_f^*(t) = \{u^*(t|t), u^*(t+1|t), \dots, u^*(t+N-1|t)\}$ , 对应的最优评价函数记为  $J_N^*(t)$ . 选择  $u_f^*(t)$  中的第 1 个元素  $u^*(t|t)$  作为输入量, 将其作用到被控系统上, 并保持到下一个采样时刻  $t+1$ ; 在下一采样时刻  $t+1$ , 用系统状态量  $x(t+1)$  更新问题 (10) ~ (14) 的初始条件并且重新求解优化问题. 通过在线滚动地求解优化问题, 最终得到一个最优实际控制输入量

$$u^*(t) = u^*(t|t) \quad (15)$$

## 2.3 风力、光伏、水轮机组发电模型

### 2.3.1 风力发电模型

风机是一种将风的动能转换为机械能的机械装置, 其输出功率的大小取决于风速. 实验表明, 风机的输出功率与风速的关系为<sup>[65]</sup>

$$P_w = \begin{cases} 0, & 0 \leq V < V_{ci}, V \geq V_{co} \\ f(V), & V_{ci} \leq V < V_R \\ P_R, & V_R \leq V < V_{co} \end{cases} \quad (16)$$

其中,  $P_R$  是风力发电机组的额定功率;  $V_{ci}$ 、 $V_{co}$  和  $V_R$  是机组切入、切出和额定风速;  $f(V)$  是风速到输出功率的函数.

### 2.3.2 光伏发电模型

光伏系统是将太阳能转换为电能的静态装置, 该电能以直流电的形式输出, 其输出功率取决于太阳辐射及温度条件. 光伏系统的输出功率为<sup>[65]</sup>

$$P_s = f_s Y_s \left( \frac{I_T}{I_S} \right) \quad (17)$$

其中,  $f_s$  和  $V_s$  是光伏降额因子和光伏阵列容量;  $I_T$  是光伏阵列上的实时太阳能辐照水平;  $I_S$  是用来衡量光伏模块容量的标准太阳能辐照量, 一般取  $I_S = 1 \text{ kW/m}^2$ .

### 2.3.3 水轮机组发电模型

水轮机组利用不同高度水的势能差实现发电. 水轮机组的输出功率由水口流量、水位以及能量损耗决定, 其中能量损耗取决于水轮发电机的效率, 其值为<sup>[65]</sup>

$$P_h = \rho \eta Q H \quad (18)$$

其中,  $\rho$  是当地的重力加速度;  $\eta$  是水轮机组的效率;  $Q$  是测量到的单位时间内通过涡轮入口的水流量;  $H$  是水位.

## 3 风水光互补发电预测调度方法设计

基于智能电厂云控制系统云网边端协同控制架构, 本节设计了 LSTM-EMPC 绿色能源互补发电预测调度方法, 算法框架及流程如图 13 所示. 方法具体步骤如下:

**步骤 1.** 设计基于 LSTM 的风电、光伏机组输出功率预测方法, 为绿色能源互补发电提供预测数据, 使其满足 EMPC 滚动优化的条件;

**步骤 2.** 在优先消纳风、光能源的基础上, 考虑耗水量最小、穿越振动区次数最少等优化目标, 结合一系列水轮机组调控约束条件, 建立绿色能源互补发电问题的数学模型;

**步骤 3.** 在绿色能源互补发电数学模型的基础上, 设计了一套优化互补机制, 即基于 EMPC 方法的滚动优化调度方法, 求解得到水轮机组最优预测调度策略, 保证系统的鲁棒性.

### 3.1 基于 LSTM 的风电机组和光伏逆变器输出功率预测方法

由于风力和光照自然条件短时间内波动较大, 互补发电的效果受到严重影响. 为解决这个问题, 本节设计了一个预测模型来模拟输出功率的变化, 从而使水轮机组更好地补偿功率缺口. 传统时间序列预测方法包括自回归、线性回归和正态分布模型等, 但它们依赖平稳数据集, 不能解决非平稳变化的输出功率预测问题. 并且, 现有的多数方法 (如自回归综合移动平均、ARIMA (Autoregressive integrated moving average model) 等) 都需要计算自相

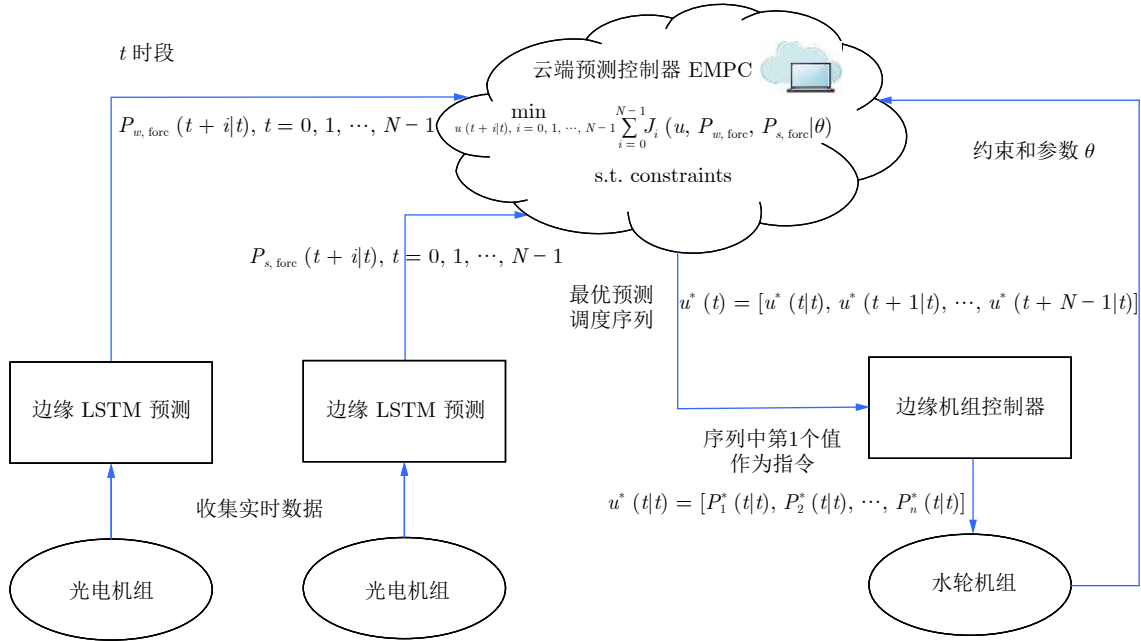


图 13 LSTM-EMPC 算法框架及流程图  
Fig.13 Framework and flow chart of LSTM-EMPC

关函数和部分自相关函数来确定模型参数, 给输出功率预测带来额外的计算开销。

为了能够准确地估计输出功率, 本文使用 LSTM 网络来预测输出功率随时间的变化, 其优点是可以学习并自动提取输出功率变化的非线性特征. 仿真使用的风电、光电数据分别来自江西基隆樟电厂和乐平电厂, 时段单位为分钟. 使用如图 12 所示的模型结构, 以连续 18 个时段机组功率作为输入, 未来 3 个时段功率作为输出, 经训练得到未来功率与历史功率的时序关系. 设置超参数如下: LSTM 输入层维数为 18, 隐含层维数为 108 (光伏功率预测隐含层维数为 80), 输出层维数为 3, 训练批次大小  $batchsize$  为 80, 训练次数  $n_{iter}$  为 500. 以 2018 年 11 月 15 日数据作为样本, 预测结果如第 4.2 节所示.

### 3.2 建立风水光互补发电优化问题

智能电厂云控制系统的建立使得当前和历史数据中蕴含的信息能被充分地发掘出来并加以利用, 电厂 AGC (Automatic generation control) 能够根据新能源优先消纳和电网的安全稳定原则, 制定合理的发电计划, 对参与调节的机组下发功率调度指令.

#### 3.2.1 建立最优化控制目标

水电可以通过调节导叶开度调控机组发电功

率, 一定程度上可以起到存储和削峰填谷的作用. 但风电和光电的不可调控性强, 波动性强, 并且不能存储, 因此可用水电来补偿风电和光电的波动, 满足区域用户的电力需求. 本文所述绿色能源互补发电的目的是尽可能消耗不可再生的风电和光电, 在其不能满足调度指令的情况下, 启用水电补偿. 出于环保要求, 水力发电追求耗水量最少. 同时, 出于经济效益角度, 要求水轮机组在振动区工作的时间尽可能少, 减少机组折旧成本. 因此, 可在当前  $t$  时段建立如下优化目标<sup>[9]</sup>:

#### 1) 子优化目标 1: 水轮机组的耗水量最小

水电站在风水光互补发电系统中的主要作用是补偿调度下发值和新能源有功出力的差值, 水轮机组间合理的负荷分配可以减少耗水量, 从而节省水能以保证水电的能量储备. 水电的耗水量来源于机组出力的耗水量和开停机的耗水量.

$$\begin{cases} W(T) = \\ \min \sum_{t=1}^T \sum_{i=1}^n [WF(P_i(t), H, t) + WC(i, t)] \\ WF(P_{hi}, H, t) = \\ \min \sum_{t=1}^T \sum_{i=1}^n Q(P_i(t), H, t)T(t) \end{cases} \quad (19)$$

其中,  $P_i(t)$  是决策变量, 代表第  $i$  台水轮机组在  $t$  时刻的输出功率;  $n$  代表水轮机组的数量;  $W(T)$  为水

电厂的耗水量;  $WF(P_i(t), H, t)$  为第  $i$  台机组在  $H$  水口下的实发有功所对应的耗水量;  $WC(i, t)$  为第  $i$  台机组的开停机耗水量;  $Q(P_i(t), H, t)$  为第  $i$  台机组在  $H$  水口下的流量.

## 2) 子优化目标 2: 水轮机组的折旧成本最小

水轮机组的折旧成本主要包括水轮机组跨越振动区和机组的启停机次数较多带来的设备磨损维修成本, 以及不合理的启停机条件导致多台机组在低效率区运转所带来的附加成本. 水轮机组要尽可能减少跨越振动区的次数. 水轮机组运行在振动区时使机组的振动和摆度加大, 造成机械部件的磨损加重, 严重影响机组的使用寿命<sup>[65]</sup>, 所以本文主要考虑振动区对水电厂经济运行的影响.

$$\left\{ \begin{array}{l} N(T) = \\ \min \sum_{t=1}^T \sum_{i=1}^N \left[ \frac{1-SPAN1_{i,t}}{2} + \frac{1-SPAN2_{i,t}}{2} \right] \\ SPAN1(i, t) = \\ \frac{[P_i(t) - P_{i,1}][P_i(t-1) - P_{i,1}]}{|P_i(t) - P_{i,1}||P_i(t-1) - P_{i,1}|} \\ SPAN2(i, t) = \\ \frac{[P_i(t) - P_{i,2}][P_i(t-1) - P_{i,2}]}{|P_i(t) - P_{i,2}||P_i(t-1) - P_{i,2}|} \\ P_{i,1}, P_{i,2} \in \\ (P_{iDown1}, P_{iUp1}) \cup (P_{iDown2}, P_{iUp2}) \\ P_i(t), P_i(t-1) \notin \\ (P_{iDown1}, P_{iUp1}) \cup (P_{iDown2}, P_{iUp2}) \end{array} \right. \quad (20)$$

式 (20) 代表水轮机组穿越振动区总次数. 其中,  $T$  和  $t$  表示时段,  $n$  表示水电机组的个数;  $N(T)$  为全场  $T$  时间段内机组穿越振动区的次数;  $P_{iDown1}$  为第  $i$  台水电机组第 1 个振动区的下限;  $P_{iUp1}$  为第  $i$  台水电机组第 1 个振动区的上限;  $P_{iDown2}$  为第  $i$  台水轮机组第 2 个振动区的下限;  $P_{iUp2}$  为第  $i$  台水轮机组第 2 个振动区的上限. 综合上述两个子优化目标, 可在智能电厂云控制系统中建立 AGC 控制目标函数

$$\min J = C_1 W(T) + C_2 N(T) \quad (21)$$

其中,  $C_1$  为水电耗水量的加权系数 (水电发电成本),  $C_2$  为水轮机组穿越振动区次数的加权系数 (机组折旧成本),  $\Delta P_h$  为水电补偿风、光能源波动的功率.

### 3.2.2 建立约束条件

#### 1) 负荷约束

智能电厂发电功率, 包括风电功率  $P_w$ 、光电功率  $P_s$ 、水电功率  $P_h$ , 应该大于等于用电负荷  $P_{load}$ ,

即在风电、光电及用户需求动态变化的情况下, 调节水轮机组功率, 满足用户的用电需求

$$P_w + P_s + P_h \geq P_{load} \quad (22)$$

即

$$P_w + P_s + \sum_{i=1}^n P_i(t) \geq P_{load} \quad (23)$$

#### 2) 水轮机组功率约束

水轮机组功率不能超过调节限制, 不能超出调节能力的上下限值

$$P_{iMin} \leq P_i \leq P_{iMax} \quad (24)$$

其中,  $P_i$  为第  $i$  台水轮机组运行时的功率.

#### 3) 水电振动区约束

$$P_i \notin (P_{iDown1}, P_{iUp1}) \cup (P_{iDown2}, P_{iUp2}) \quad (25)$$

#### 4) 调节死区约束

设置调节死区可以避免微小的功率波动带来机组调节的频繁动作, 死区设定值一般为 1% ~ 2% 机组额定功率值, 这里取调节死区为 1% 的机组额定功率值, 即有功下发增量绝对值大于 1% 的机组额定功率值  $P_{specified}$  时, 机组才动作

$$|\Delta P_i| > 0.01 P_{specified} \quad (26)$$

#### 5) 爬坡率约束

$$R_{iDown} < R_{it} < R_{iUp} \quad (27)$$

其中,  $R_{it}$  为第  $i$  台机组  $t$  时段的爬坡率,  $R_{idown}$ ,  $R_{iup}$  分别代表第  $i$  台机组在自动控制时可达到最大功率减少及增加速度 (kW/min).

### 3.2.3 水轮机组开停机条件

由于新能源的单机装机容量不大、机组台数众多, 在少弃风弃光的情况下, 水轮机组的开停机可能会比较频繁. 为了减少机组不必要的启动、停机次数, 最优分配各个机组的有功功率, 本文设计了一套开停机机制, 根据功率补偿需求, 确定预测时域内水轮机组开停机状态. 同时, 受到 AGC 调节时间的限制, 需要在短时间内快速做出决策, 本文设定了各机组的启动优先级, 大大缩减了所需要的计算时间.

#### 1) 水轮机组开机条件

$$P_{load} - (P_{w,forc} + P_{s,forc}) + P_b > \sum P_T \quad (28)$$

其中,  $P_b$  为水电厂的旋转备用容量,  $\sum P_T$  是已投入水电 AGC 的并网机组的可调节容量,  $P_{w,forc}$  和  $P_{s,forc}$  为风电、光电的功率预测值, 仅包含开机的机组. 同时, 计算水轮机组开机台数

$$N_{h,open} = 1 + \frac{P_{load} - P_{w,forc} - P_{s,forc} + P_b - \sum P_T}{P_m} \quad (29)$$

其中,  $P_m$  为水轮机组单机最大容量.

## 2) 水轮机组停机条件

$$\sum P_T - (P_{load} - P_{w,forc} - P_{s,forc} + P_b) > P_m \quad (30)$$

同时, 计算水轮机组停机台数

$$N_{h,close} = \frac{\sum P_T - (P_{load} - P_{w,forc} - P_{s,forc} + P_b)}{P_m} \quad (31)$$

### 3.3 基于经济模型预测控制的优化调度律

在  $t$  时段, 有了上述优化目标和约束条件后, 只要获取到风电、光电未来预测功率和水轮机组的数量、性能参数等, 就可以求解相应的滚动优化问题. 设定预测控制变量为

$$u(t+t'|t) = [P_1(t+t'|t), P_2(t+t'|t), \dots, P_n(t+t'|t)]^T \quad t' = 0, 1, \dots, T-1 \quad (32)$$

其中,  $T$  为整数的预测时域, 下标  $t|t+t'$  代表从当前  $t$  时段预测到之后的第  $t'$  个时段,  $N$  为水轮机组台数,  $P_i(t+t'|t), i = 1, 2, \dots, N$  代表第  $i$  台水轮机组从  $t$  时段开始计算未来的第  $t'$  个时段的预测控制调度功率. 设定预测控制序列为

$$u_f(t) = [u(t|t), u(t+1|t), \dots, u(t+T-1|t)] \quad (33)$$

即在  $t$  时段对未来一个预测周期内的控制序列. 以  $P_i(t+t'|t), i = 1, 2, \dots, N, t' = 0, 1, \dots, T-1$  为优化变量求解上述问题, 即可得到最优预测控制序列  $u_f^*(t)$ .

在  $t$  时段, 智能电厂云控制系统将最优预测调度序列  $u_f^*(t)$  发往各水轮机组, 取序列中第 1 个时段的调度变量, 作为施加到各水轮机组的动作, 即控制调度功率, 调整机组状态. 由于风电、光伏机组的数据和预测功率分别被实时上传到场站数据库和云端数据库中, 智能电厂云控制系统根据更新的数据刷新最优化目标函数及约束, 重复上述步骤.

如图 14 所示, 每次智能电厂云控制系统下发调度指令时, 都会收集风、光机组实际发电功率数据, 预测未来短时输出功率数值, 预测结果与水电站的参数一同上传至云端, 由云端控制器滚动求解优化问题, 并在调度周期内, 将最优控制序列传回本地, 本地机组采用控制序列的第 1 个值调节水轮机组的发电状态. 这种方法相当于引入了预测、反馈和滚动优化, 增强了系统鲁棒性, 可以有效预知绿色能源发电出力的未来状态, 改善绿色能源互补

发电方法应对波动性和偶然因素能力差的问题.

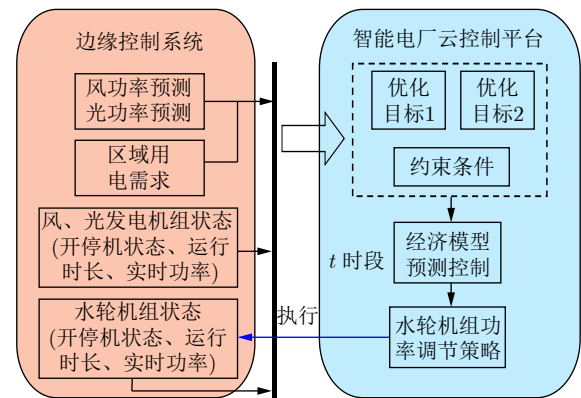


图 14 云端-边缘预测控制算法流程图

Fig. 14 Flow chart of cloud-edge predictive control algorithm

## 4 案例仿真

### 4.1 仿真场景

本案例选取区域中小型集中式云数据中心作为用电需求方. 因云时代到来而出现的现代化数据中心, 其最大的特点就是高能耗, 在计算节点上对数据的处理以及空调散热上对电能需求极大, 而且对于电能消耗具有很大的波动性, 存在很大的峰谷差. 例如, 一座具有 500 台服务器的中小型云数据中心, 满载时电力能耗约为 2 000 kW, 空闲时电力能耗为 1000 kW, 峰谷差达到 1000 kW 左右. 而在新能源电厂中也有许多计算任务要处理, 这些任务全放在本地计算是困难的, 也是没有必要的. 如本文所述, 新能源电厂必须借助云端管控系统的强大处理能力. 因此, 在中小型规模区域中, 新能源智能电厂和绿色数据中心的运行与设计具有天然的互补性.

如图 15 所示, 数据中心的能耗主要来自网络传输、服务器耗电和空调水冷用电等, 由新能源智能电厂以能量流的形式提供. 新能源智能电厂边缘端的监控管理由场站控制器执行, 而关键任务的分析、管理、决策与控制服务则借助信息流的交换统一交给数据中心中的云控制平台进行处理. 同时, 区域内也有其他的民用、工业智能服务, 如智能家居、智能工厂、网购物流等应用, 这些应用也存在信息流交互和能量流提供的需求, 与新能源智能电厂、绿色数据中心构成了一个有机融合并且自洽的整体. 当区域内荷侧负载过高, 源侧无法满足时, 则通过外部电网的输入平抑内部需求<sup>[66-67]</sup>.

案例假设了区域内绿色数据中心和智能应用的负载需求曲线, 研究负载波动时本文所提机制的有



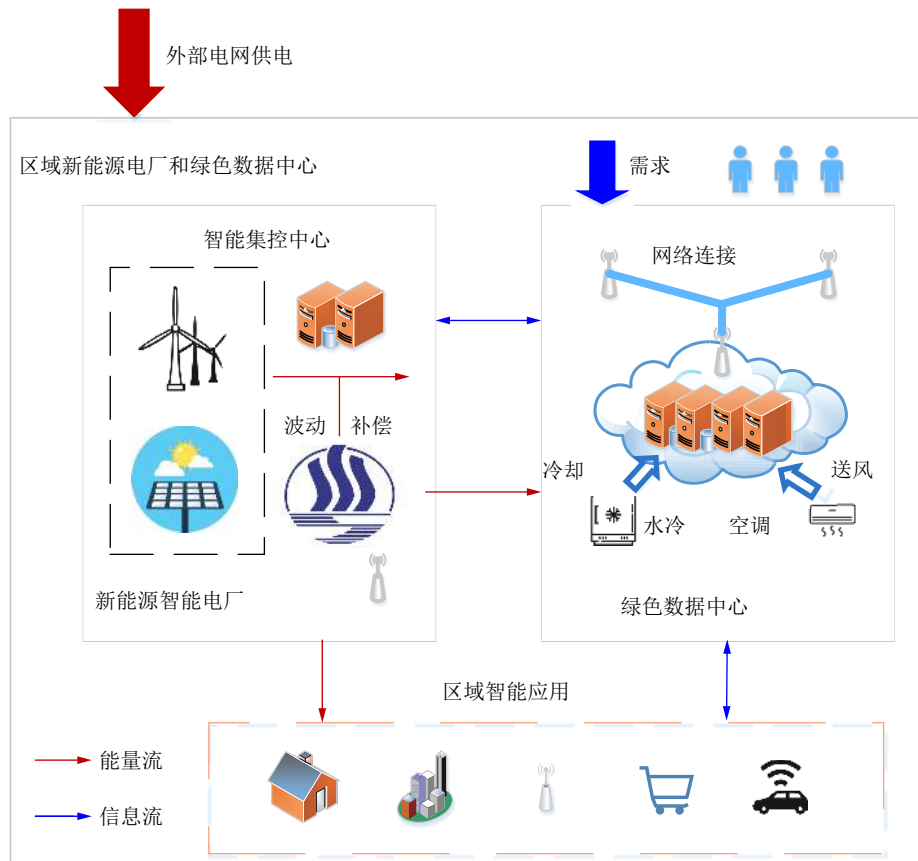


图 15 区域新能源电厂和绿色数据中心联合运行示意图

Fig. 15 Schematic diagram of joint operation of regional new energy power plant and green data center

效率。风力、光伏出力数据来自江西基隆樟和乐平电厂，水轮机组参数参考大渡河流域发电有限公司。在本文的场景中，部署了风电机组、光伏逆变器各 5 台，水轮机组 6 台。

#### 4.2 风电、光电输出功率预测结果

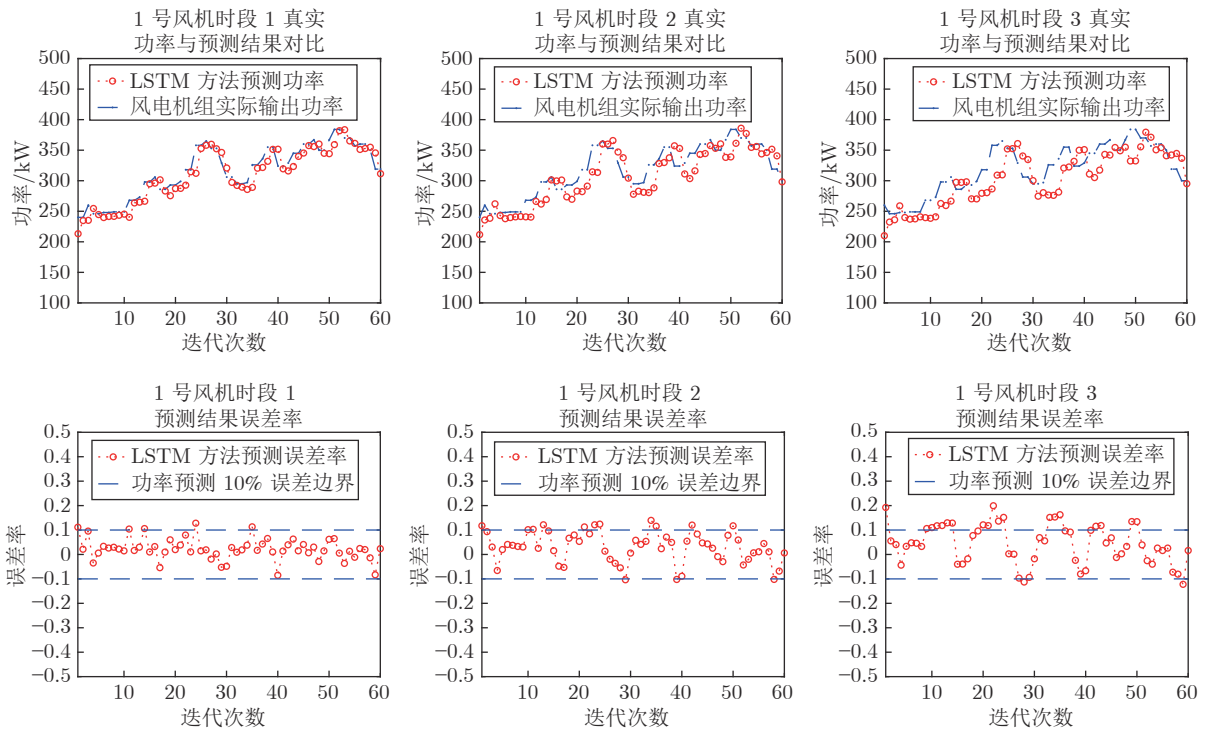
选取 2018 年 11 月 15 日江西基隆樟电厂的风电出力功率和乐平电厂的光伏电出力功率数据作为样本。以该日 0:00~14:00, 5 台风机各 840 组数据作为训练集, 14:00~15:00, 60 组数据作为测试集; 以该日 8:00~14:00, 5 台光伏逆变器各 360 组数据作为训练集, 14:00~15:00, 60 组数据作为测试集, 设置连续 18 个时段机组功率作为输入, 未来 3 个时段机组功率作为输出, 得到以下结果。

如图 16(a), 以 1 号风机为例, 未来 3 个时段的平均误差分别为 12.2974 kW, 19.3473 kW 和 26.2758 kW, 相对单台风机输出几百至一千千瓦的功率值范围很小, 平均误差率分别为 4.16%, 6.49% 和 8.78%, 小于 10% (见表 1)。图 16(a) 的第 1 行是 1 号风机 3 个预测时段中对输出功率的估计

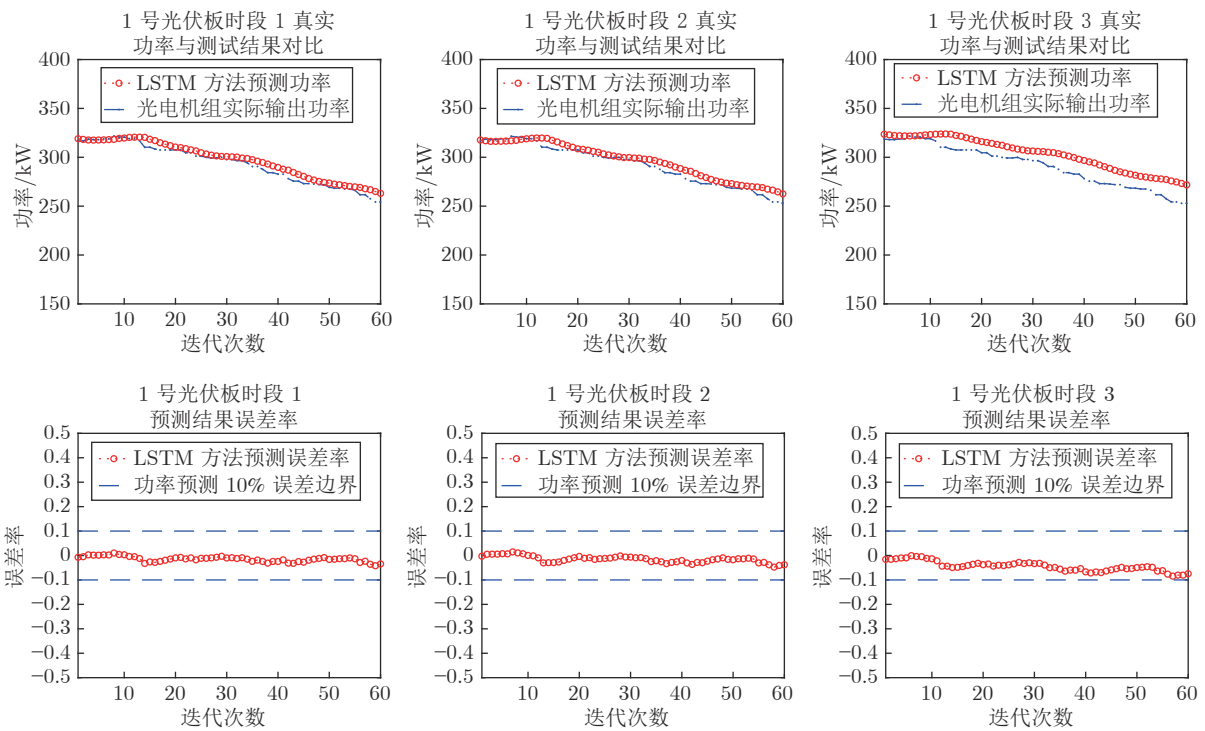
和真实值的对比, 可以看到, 未来时段 1 预测功率准确地跟踪上了真实功率, 未来时段 2 和 3 也保持了较高的跟踪精度。从图 16(a) 的第 2 行平均误差率来看, 未来时段 1 的误差基本在 8% 以内, 未来时段 2 和 3 的误差则在 10% 以内。考虑到风机输出功率的不确定性较大, 该精度已经满足了水轮机组补偿调度的需求。同时, 随着预测时间增长, 预测精度降低, 为了保证后续调度优化的精确性, 我们将预测步长设为 3 个时段。如图 16(b) 所示, 对 1 号光机来说, 因为光照强度的变化缓慢, 所以预测精度更高, 平均误差在 10 kW 左右, 平均误差率在 1% 到 4% 以内。表 2 和表 3 反映了其余风机和光机的预测均方根误差 (Root mean squared error, EMSE) 和平均误差结果。从表 4 来看, 所有风机和光机未来时段 1 的平均误差率分别是 7.13% 和 2.52%, 满足调度需求。

#### 4.3 经济模型预测调度结果

得到未来时段 5 台风机和 5 台光机的输出功率预测后, 通过求解第 3 节给出的优化问题, 可以得到水轮机组应输出功率的调度分配方案。图 17 为



(a) 1号风机输出功率预测结果和误差率  
(a) Prediction result and error rate of No.1 wind generator



(b) 1号光伏输出功率预测结果和误差率  
(b) Prediction result and error rate of No.1 solar generator

图 16 基于 LSTM 网络的机组输出功率预测效果

Fig.16 Prediction results and error rates of generators output power based on LSTM network

该区域内所有负载功率的变化曲线, 可以看到在 1 个小时以内, 负载功率从 5 000 kW 左右升至

5 500 kW 左右, 峰值接近 5 700 kW, 主要变化区间在 15 至 40 分钟内, 该变化波动是剧烈的, 可以

表 1 1 号风机与 1 号光机未来时段预测结果  
 Table 1 Prediction results of No.1 wind generator and No.1 solar generator

预测时段	1号风机			1号光机		
	时段1	时段2	时段3	时段1	时段2	时段3
RMSE	17.383	25.569	32.469	10.703	12.787	13.645
平均误差	12.2974	19.3473	26.2758	6.2836	9.2977	11.2038
平均误差率	0.0416	0.0649	0.0878	0.0197	0.0292	0.0354

表 2 2~5 号风机未来时段预测结果  
 Table 2 Prediction results of No. 2~5 wind generators

预测时段	2号风机			3号风机		
	时段1	时段2	时段3	时段1	时段2	时段3
RMSE	22.869	30.357	34.298	22.842	31.128	34.999
平均误差	16.4035	23.7910	27.1607	16.4035	23.7910	27.1607
平均误差率	0.0870	0.1290	0.1489	0.0813	0.1209	0.1291

预测时段	4号风机			5号风机		
	时段1	时段2	时段3	时段1	时段2	时段3
RMSE	25.314	37.057	41.635	28.273	37.187	44.354
平均误差	22.0610	27.7490	33.7304	20.1751	28.2186	33.6929
平均误差率	0.0770	0.0954	0.1169	0.0696	0.0974	0.1138

表 3 2~5 号光机未来时段预测结果  
 Table 3 Prediction results of No. 2~5 solar generators

预测时段	2号光机			3号光机		
	时段1	时段2	时段3	时段1	时段2	时段3
RMSE	6.778	14.388	19.350	9.624	11.194	14.049
平均误差	5.5040	13.3298	16.5947	10.3386	11.2576	13.0231
平均误差率	0.0187	0.0454	0.0566	0.0333	0.0365	0.0424

预测时段	4号光机			5号光机		
	时段1	时段2	时段3	时段1	时段2	时段3
RMSE	9.467	9.549	14.924	7.149	8.264	17.235
平均误差	7.6231	12.4947	15.6101	8.6143	7.6891	9.6818
平均误差率	0.0242	0.0398	0.0500	0.0301	0.0272	0.0344

表 4 风机与光机未来时段预测平均结果  
 Table 4 Average results of wind and solar generators

预测时段	1~5 号风机			1~5 号光机		
	时段1	时段2	时段3	时段1	时段2	时段3
平均RMSE	23.336	32.260	37.551	8.744	11.236	15.841
平均误差	17.5651	24.8910	29.6411	7.6727	10.8138	13.2227
平均误差率	0.0713	0.1015	0.1193	0.0252	0.0356	0.0438

验证算法应对偶然因素的鲁棒性. 应对不同自然条件, 本节做了多个场景的仿真实验.

4.3.1 场景 1: 春季, 多风期, 晴天

场景 1 选择春季, 多风期, 晴天, 特点是风电出




图 17 联合运行区域负载功率变化曲线

Fig. 17 Load power change curve of joint operation area

力和光伏出力都比较大. 在此场景下得到仿真结果如下: 如图 18 所示, 最上端曲线代表负载功率变化情况; 中部圆圈代表实际风力和光伏总的预测发电功率, 实心点代表风力和光伏总实际发电功率, 可以看到拟合效果良好; 下部叉形 (“x”) 代表负载功率和风光总出力的差值, 也就是分配给水轮机组的应发电需求, 三角形代表水轮机组实际调度总发电功率, 除少许时刻高于应发电需求外, 其余时刻补偿效果良好, 说明在该场景下, 方案取得了应有的效果.

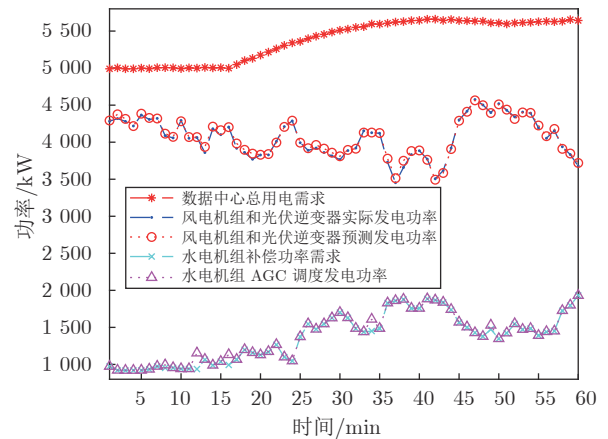


图 18 场景 1 的水电输出功率补偿效果

Fig. 18 Compensation effect of hydro power in Scenario 1

图 19 是各台水轮机组调度输出功率结果. 圆圈代表使用本文方法 (LSTM-EMPC) 的输出功率, 菱形代表负载使用平均分配方法的调度结果, 虚线分别表示水轮机组启动和运行过程中经过的两个振动区. 在整个补偿过程中, LSTM-EMPC 方法只启动了 3 台机器, 输出功率基本都在第二振动区上部,

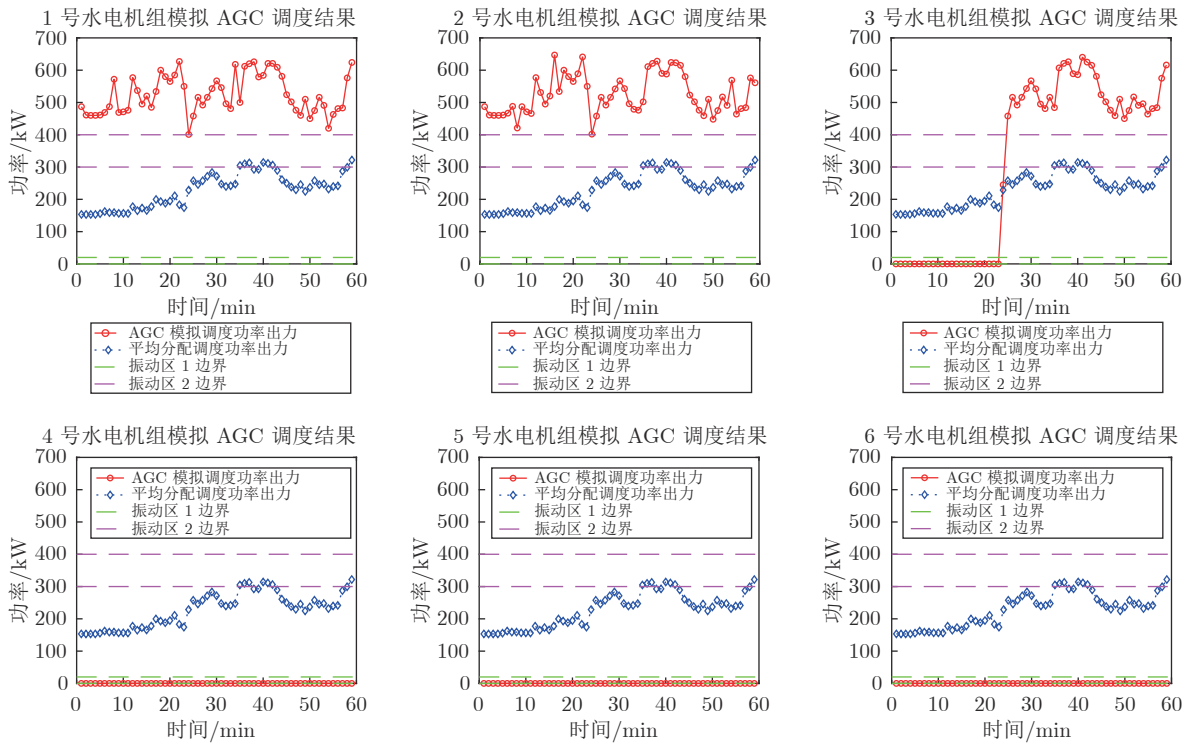


图 19 场景 1 的各水发电机组输出功率调度方案

Fig.19 Scheduling plan of hydro generators in Scenario 1

有时接近但不会在振动区上下波动, 而平均分配算法则启动了所有 6 台机组, 并且输出功率波动较多, 对机组损坏较大. 具体启停次数和穿越振动区次数如表 5 所示.

表 5 开停机和穿越振动区次数对比

Table 5 Comparison of times of on/off and crossing vibration areas

调度方式	开停机次数	穿越振动区次数
平均分配调度	6	30
AGC模拟调度	3	4

4.3.2 场景 2: 春季, 多风期, 阴天

场景 2 选择春季, 多风期, 阴天, 特点是风电出力较大, 光伏出力较少. 如图 20 所示, 本组仿真风力和光伏的总输出功率明显小于第 1 组, 在 2 500 ~ 3 500 kW 的范围内, 对应水轮机组的补偿需求在 2 000 ~ 3 000 kW 范围内波动, 并且相较第 1 组波动更加频繁、剧烈. 图 20 表示水轮机组总输出功率很好地跟踪了区域负载功率的波动. 图 21 则反映了各台水轮机组调度输出功率结果: LSTM-EMPC 方法共启动了 5 台机组, 其中第 5 台经历了先启动后关闭然后再启动的过程, 这反映了负载需求的快速波动性. LSTM-EMPC 方法的输出功率曲线基本都在第二振动区上方, 对机组的伤害比较小.




图 20 场景 2 的水电输出功率补偿效果

Fig.20 Compensation effect of hydro power in Scenario 2

而平均分配方法则频繁穿越振动区, 对机组损伤较大.

4.3.3 场景 3: 冬季, 少风期, 晴天

场景 3 选择冬季, 少风期, 晴天, 特点是风电出力较小, 光伏出力较多. 因为光伏发电变化平缓, 且风电出力较小不足以影响总输出功率, 所以总出力变化波动性较小. 在此场景下得到图 22 所示的仿真结果. 如图 23 所示, 水轮机组总输出功率依然很好地补偿了区域用电需求. 但图 22 显示采用

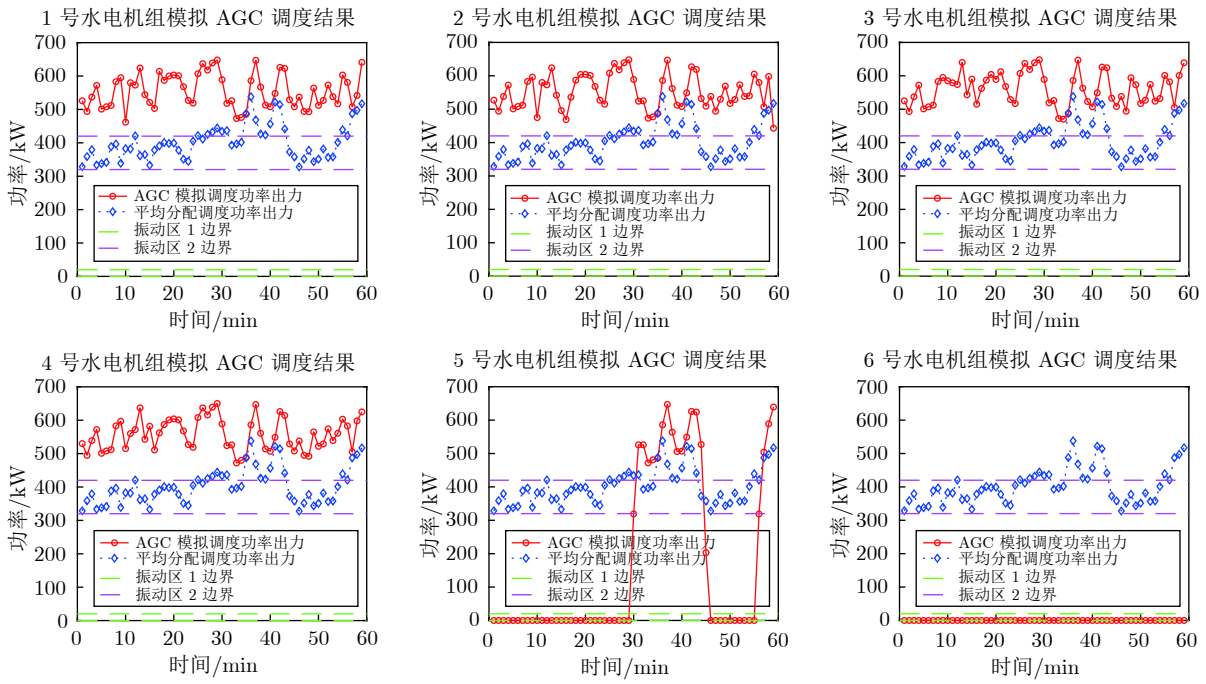


图 21 场景 2 的各水发电机组输出功率调度方案

Fig. 21 Scheduling plan of hydro generators in Scenario 2

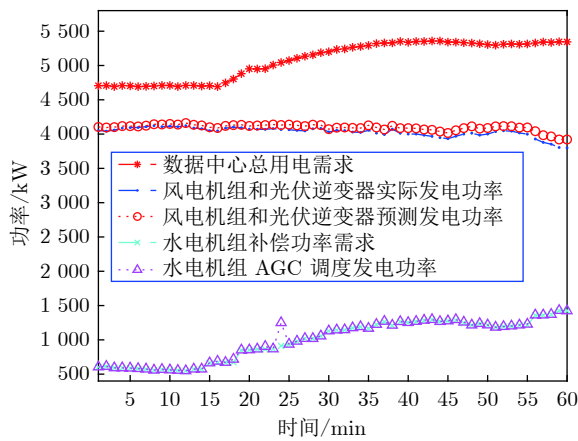


图 22 场景 3 的水电输出功率补偿效果

Fig. 22 Compensation effect of hydro power in Scenario 3

LSTM-EMPC 方法的各台水轮机组穿越振动区的总次数多于平均分配方法. 原因在于此时水轮机组应补偿功率较小, 且变化比较平稳, 平均分配方法在这个总功率需求区间内表现良好. 即便如此, LSTM-EMPC 方法穿越振动区的次数也很少, 只有 8 次, 并且只启动了 3 台机组, 少于平均分配方法的 6 台, 降低了操作和运行成本. 由此仿真实例可知, 本文提出算法还有提高空间, 应在智能电厂云控制系统中心上部署含规则过滤和筛选的多种智能算法, 在云端形成完备的规则库和算法库, 才能更好地应对复杂多变的实际情况, 以取得更好的经

济和实施效果.

### 5 结束语

本文设计了智能电厂云控制系统的整体结构, 并对关键技术进行了详细分析, 将云控制推广到智能电厂系统中, 研究了其在智能电厂系统中的应用模式, 给出了具体的部署方案. 在绿色能源领域, 本文设计了基于 LSTM 网络和经济模型预测控制的风水光互补发电滚动优化方法, 利用电力系统风机、光机历史输出功率数据, 预测未来风光机组出力波动情况. 针对绿色能源互补发电最优问题, 滚动优化得到水轮机组最优预测调度策略, 提前消解不确定性, 改善绿色能源互补应对偶然因素差、鲁棒性差的问题, 同时最小化耗水量和穿越振动区次数, 保障机组设备运行安全. 功率智能预测算法和优化调度算法分别在边缘和云端运行, 充分利用边缘和云端算力, 实现智能电厂云控制系统云网边端协同控制, 规避传统电厂业务计算存储能力的局限, 节约智能电厂建设和运维成本. 事实上, 目前云控制系统理论和技术还在发展阶段, 本文提出的智能电厂云控制系统是云控制的初步应用, 如何实现从大数据采集、处理到云网边端协同安全管控的智能电厂全流程业务, 将云控制封装成一种随取即用、按需申请的服务, 实现现代电厂全业务环境控制策略的实时触发、分析、回馈和流转, 得到最优的实际

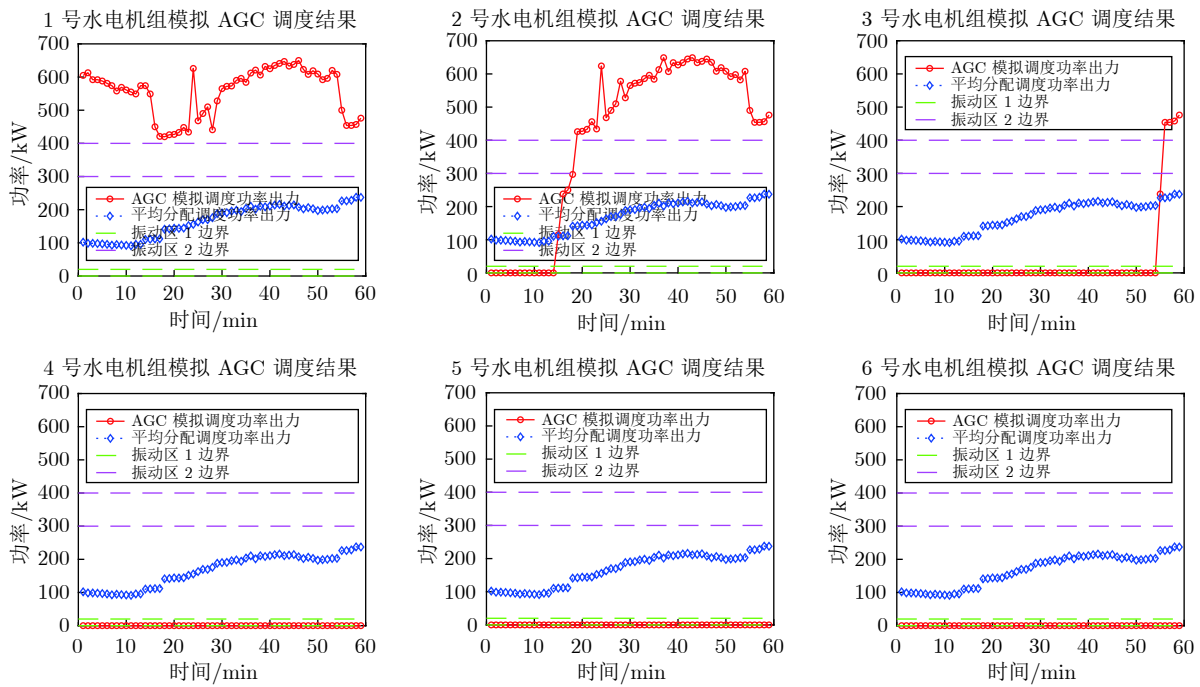


图 23 场景 3 的各水发电机组输出功率调度方案

Fig. 23 Scheduling plan of hydro generators in Scenario 3

电厂系统云控制解决方案, 仍然是智能电厂云控制系统的未来发展方向和需要解决的技术难点。

## References

- Xia Y Q, Gao Y L, Yan L P, Fu M Y. Recent progress in networked control systems—a survey. *International Journal of Automation and Computing*, 2015, **12**(4): 343–367
- Zhang X M, Han Q L, Yu X H. Survey on recent advances in networked control systems. *IEEE Transactions on Industrial Informatics*, 2016, **12**(5): 1740–1752
- Wang S Y, Wan J F, Zhang D Q, Li D, Zhang C H. Towards smart factory for industry 4.0: A self-organized multi-agent system with big data based feedback and coordination. *Computer Networks*, 2016, **101**: 158–168
- Hegazy T, Hefeeda M. Industrial automation as a cloud service. *IEEE Transactions on Parallel and Distributed Systems*, 2015, **26**(10): 2750–2763
- Xia Y Q. From networked control systems to cloud control systems. In: Proceedings of the 31st Chinese Control Conference. Hefei, China: IEEE, 2012. 5878–5883
- Xia Y Q. Cloud control systems. *IEEE/CAA Journal of Automatica Sinica*, 2015, **2**(2): 134–142
- Xia Y Q, Qin Y M, Zhai D H, Chai S C. Further results on cloud control systems. *Science China Information Sciences*, 2016, **59**(7): 1–5
- Xia Yuan-Qing. Cloud control systems and their challenges. *Acta Automatica Sinica*, 2016, **42**(1): 1–12 (夏元清. 云控制系统及其面临的挑战. *自动化学报*, 2016, **42**(1): 1–12)
- Xia Yuan-Qing, Mahmoud M S, Li Hui-Fang, Zhang Jin-Hui. The interaction between control and computing theories: Cloud control system. *Journal of Command and Control*, 2017, **3**(2): 99–118 (夏元清, Mahmoud M S, 李慧芳, 张金会. 控制与计算理论的交互: 云控制. *指挥与控制学报*, 2017, **3**(2): 99–118)
- Gao R Z, Xia Y Q, Ma L. A new approach of cloud control systems: CCSs based on data-driven predictive control. In: Proceedings of the 5th Chinese Automation Congress (CAC). Jinan, China: IEEE, 2017. 3419–3422
- Ali Y, Xia Y Q, Ma L, Hammad A. Secure design for cloud control system against distributed denial of service attack. *Control Theory and Technology*, 2018, **16**(1): 14–24
- Xia Yuan-Qing, Yan Ce, Wang Xiao-Jing, Song Xiang-Hui. Intelligent transportation cyber-physical cloud control systems. *Acta Automatica Sinica*, 2019, **45**(1): 132–142 (夏元清, 闫策, 王笑京, 宋向辉. 智能交通信息物理融合云控制系统. *自动化学报*, 2019, **45**(1): 132–142)
- Botta A, De Donato W, Persico V, Pescapé A. Integration of cloud computing and internet of things: A survey. *Future Generation Computer Systems*, 2016, **56**: 684–700
- Shi W S, Cao J, Zhang Q, Li Y, Xu L Y. Edge computing: Vision and challenges. *IEEE Internet of Things Journal*, 2016, **3**(5): 637–646
- Thounthong P, Luksanasakul A, Koseyaporn P, Davat B. Intelligent model-based control of a standalone photovoltaic/fuel cell power plant with supercapacitor energy storage. *IEEE Transactions on Sustainable Energy*, 2013, **4**(1): 240–249
- Liu Ji-Zhen, Hu Yong, Zeng De-Liang, Xia Ming, Cui Qing-Ru. Architecture and feature of smart power generation. *Proceedings of the CSEE*, 2017, **37**(22): 6463–6470

- (刘吉臻, 胡勇, 曾德良, 夏明, 崔青汝. 智能发电厂的架构及特征. 中国电机工程学报, 2017, **37**(22): 6463–6470)
- 17 Adhya S, Saha D, Das A, Jana J, Saha H. An IoT based smart solar photovoltaic remote monitoring and control unit. In: Proceedings of the 2nd International Conference on Control, Instrumentation, Energy and Communication (CIEC). Kolkata, India: IEEE, 2016. 432–436
  - 18 Zhan Z H, Liu X F, Gong Y J, Zhang J, Chung H S H, Li Y. Cloud computing resource scheduling and a survey of its evolutionary approaches. *ACM Computing Surveys*, 2015, **47**(4): Article No. 63
  - 19 Qin Q F, Poularakis K, Iosifidis G, Tassulas L. SDN controller placement at the edge: Optimizing delay and overheads. In: Proceedings of the 37th Conference on Computer Communications. Honolulu, USA: IEEE, 2018. 684–692
  - 20 Hu L, Miao Y M, Wu G X, Hassan M, Humar I. iRobot-Factory: An intelligent robot factory based on cognitive manufacturing and edge computing. *Future Generation Computer Systems*, 2019, **90**: 569–577
  - 21 Ren Yan-Ming. Network Design and Cloud Control Implementation of New Energy Centralized Control Center [Master thesis], Beijing Institute of Technology, China, 2018.  
(任延明. 新能源集控中心网络设计及云控制实现 [硕士学位论文], 北京理工大学, 中国, 2018.)
  - 22 Ma Yan-Yan. Research and application of big data integration platform in power plant. *World Telecommunications*, 2017, **30**(4): 64–71  
(马岩岩. 大数据一体化平台在电厂中的研究与应用. 世界电信, 2017, **30**(4): 64–71)
  - 23 Geng Qing-Hua. Construction of the intelligent hydropower plant based on big data technology. *Hydropower and New Energy*, 2018, **32**(10): 33–35  
(耿清华. 浅谈基于大数据的智慧水电厂建设. 水电与新能源, 2018, **32**(10): 33–35)
  - 24 Yu Min-Hua. Research and design of intelligent comprehensive analysis power plant information platform. *Power and Energy*, 2018, **39**(3): 392–396, 408  
(喻敏华. 智慧全析电厂信息平台研究与设计. 电力与能源, 2018, **39**(3): 392–396, 408)
  - 25 Khan F A, Pal N, Saeed S H. Review of solar photovoltaic and wind hybrid energy systems for sizing strategies optimization techniques and cost analysis methodologies. *Renewable and Sustainable Energy Reviews*, 2018, **92**: 937–947
  - 26 Ai Qian, Hao Ran. Key technologies and challenges for multi-energy complementarity and optimization of integrated energy system. *Automation of Electric Power Systems*, 2018, **42**(4): 2–10, 46  
(艾芊, 郝然. 多能互补、集成优化能源系统关键技术及挑战. 电力系统自动化, 2018, **42**(4): 2–10, 46)
  - 27 Zhao Ze. Research on the AGC of Complementary Power Generation Pattern of Wind Power, Solar Power and Hydropower [Master thesis], China Institute of Water Resources and Hydropower Research, China, 2018.  
(赵泽. 风光水互补发电系统有功控制问题研究 [硕士学位论文]. 中国水利水电科学研究院, 中国, 2018.)
  - 28 Chen Li-Yuan, Chen Jun-Wen, Li Zhi-Yi, Zhuang Xiao-Dan. Scheduling strategy of wind-photovoltaic-hydro hybrid generation system. *Electric Power Construction*, 2013, **34**(12): 1–6  
(陈丽媛, 陈俊文, 李知艺, 庄晓丹. “风光水”互补发电系统的调度策略. 电力建设, 2013, **34**(12): 1–6)
  - 29 Taleb T, Samdanis K, Mada B, Flinck H, Dutta S, Sabella D. On multi-access edge computing: A survey of the emerging 5G network edge cloud architecture and orchestration. *IEEE Communications Surveys and Tutorials*, 2017, **19**(3): 1657–1681
  - 30 Xavier M G, Neves M V, Rossi F D, Ferreto T C, Lange T, De Rose C A F. Performance evaluation of container-based virtualization for high performance computing environments. In: Proceedings of the 21st Euromicro International Conference on Parallel, Distributed, and Network-Based Processing. Belfast, United Kingdom: IEEE, 2013. 233–240
  - 31 Liu G P. Predictive control of networked multiagent systems via cloud computing. *IEEE Transactions on Cybernetics*, 2017, **47**(8): 1852–1859
  - 32 He X, Ju Y M, Liu Y, Zhang B C. Cloud-based fault tolerant control for a DC motor system. *Journal of Control Science and Engineering*, 2017, **2017**(3): Article ID 5670849
  - 33 Li L, Wang X J, Xia Y Q, Yang H J. Predictive cloud control for multiagent systems with stochastic event-triggered schedule. *ISA Transactions*, 2019, **94**: 70–79
  - 34 Peinl R, Holzschuher F, Pfitzer F. Docker cluster management for the cloud-survey results and own solution. *Journal of Grid Computing*, 2016, **14**(2): 265–282
  - 35 Luo Jun-Zhou, Jin Jia-Hui, Song Ai-Bo, Dong Fang. Cloud computing: Architecture and key technologies. *Journal on Communications*, 2011, **32**(7): 3–21  
(罗军舟, 金嘉晖, 宋爱波, 东方. 云计算: 体系架构与关键技术. 通信学报, 2011, **32**(7): 3–21)
  - 36 Xiong Y, Sun Y L, Xing L, Huang Y. Extend cloud to edge with KubeEdge. In: Proceedings of the 2018 IEEE/ACM Symposium on Edge Computing (SEC). Seattle, WA, USA: IEEE, 2018. 373–377
  - 37 Haja D, Szalay M, Sonkoly B, Pongracz G, Toka L. Sharpening Kubernetes for the edge. In: Proceedings of the ACM SIGCOMM 2019 Conference Posters and Demos. Beijing, China: ACM, 2019. 136–137
  - 38 Majeed A A, Kilpatrick P, Spence I, Varghese B. Performance estimation of container-based cloud-to-fog offloading. arXiv: 1909.04945, 2019.
  - 39 Tao F, Cheng J F, Qi Q L, Zhang M, Zhang H, Sui F Y. Digital twin-driven product design, manufacturing and service with big data. *The International Journal of Advanced Manufacturing Technology*, 2018, **94**(9-12): 3563–3576
  - 40 Wan J F, Tang S L, Shu Z G, Li D, Wang S Y, Imran M, et al. Software-defined industrial internet of things in the context of industry 4.0. *IEEE Sensors Journal*, 2016, **16**(20): 7373–7380
  - 41 Wu D, Arkhipov D I, Asmare E, Qin Z J, McCann J A. UbiFlow: Mobility management in urban-scale software defined IoT. In: Proceedings of the 34th IEEE Conference on Computer Communications. Hong Kong, China: IEEE, 2015. 208–216
  - 42 Chung A, Park J W, Ganger G R. Stratus: Cost-aware container scheduling in the public cloud. In: Proceedings of the 9th ACM Symposium on Cloud Computing. Carlsbad, USA: ACM, 2018. 121–134

- 43 Zhang Q, Zhani M F, Boutaba R, Hellerstein J L. Dynamic heterogeneity-aware resource provisioning in the cloud. *IEEE Transactions on Cloud Computing*, 2014, **2**(1): 14–28
- 44 Bernstein D. Containers and cloud: From LXC to docker to kubernetes. *IEEE Cloud Computing*, 2014, **1**(3): 81–84
- 45 Zhu J, Li X P, Ruiz R, Xu X L. Scheduling stochastic multi-stage jobs to elastic hybrid cloud resources. *IEEE Transactions on Parallel and Distributed Systems*, 2018, **29**(6): 1401–1415
- 46 Malawski M, Juve G, Deelman E, Nabrzyski J. Algorithms for cost- and deadline-constrained provisioning for scientific workflow ensembles in IaaS clouds. *Future Generation Computer Systems*, 2015, **48**: 1–18
- 47 Mao H Z, Alizadeh M, Menache I, Kandula S. Resource management with deep reinforcement learning. In: Proceedings of the 15th ACM Workshop on Hot Topics in Networks. Atlanta, USA: ACM, 2016. 50–56
- 48 Yuan H H, Xia Y Q, Zhang J H, Yang H J, Mahmoud M S. Stackelberg-game-based defense analysis against advanced persistent threats on cloud control system. *IEEE Transactions on Industrial Informatics*, 2020, **16**(3): 1571–1580
- 49 Zhou J, Cao Z F, Dong X L, Vasilakos A V. Security and privacy for cloud-based IoT: Challenges. *IEEE Communications Magazine*, 2017, **55**(1): 26–33
- 50 Manuel P. A trust model of cloud computing based on quality of service. *Annals of Operations Research*, 2015, **233**(1): 281–292
- 51 Li P, Li J, Huang Z G, Li T, Gao C Z, Yiu S M, et al. Multi-key privacy-preserving deep learning in cloud computing. *Future Generation Computer Systems*, 2017, **74**: 76–85
- 52 Habib M A, Ahmad M, Jabbar S, Ahmed S H, Rodrigues J J P C. Speeding up the internet of things: LEAIoT: A lightweight encryption algorithm toward low-latency communication for the internet of things. *IEEE Consumer Electronics Magazine*, 2018, **7**(6): 31–37
- 53 Dragomir D, Gheorghe L, Costea S, Radovici A. A survey on secure communication protocols for IoT systems. In: Proceedings of the 5th International Workshop on Secure Internet of Things (SIoT). Heraklion, Greece: IEEE, 2016. 47–62
- 54 Kumari S, Karupiah M, Das A K, Li X, Wu F, Kumar N. A secure authentication scheme based on elliptic curve cryptography for IoT and cloud servers. *The Journal of Supercomputing*, 2018, **74**(12): 6428–6453
- 55 Han Xuan, Yuan Yong, Wang Fei-Yue. Security problems on blockchain: The state of the art and future trends. *Acta Automatica Sinica*, 2019, **45**(1): 206–225  
(韩璇, 袁勇, 王飞跃. 区块链安全问题: 研究现状与展望. *自动化学报*, 2019, **45**(1): 206–225)
- 56 Park J, Park J. Blockchain security in cloud computing: Use cases, challenges, and solutions. *Symmetry*, 2017, **9**(8): 164
- 57 Khan M A, Salah K. IoT security: Review, blockchain solutions, and open challenges. *Future Generation Computer Systems*, 2018, **82**: 395–411
- 58 Bahga A, Madiseti V K. Blockchain platform for industrial internet of things. *Journal of Software Engineering and Applications*, 2016, **9**(10): 533–546
- 59 Ahmad I, Kumar T, Liyanage M, Okwuibe J, Ylianttila M, Gurtov A. Overview of 5G security challenges and solutions. *IEEE Communications Standards Magazine*, 2018, **2**(1): 36–43
- 60 Jin Fen-Lan, Wang Hao, Fan Guang-Min, Yu Jian-Ming, Mi Wei-Min. Design of centralized substation monitoring functions for smart grid dispatching and control systems. *Automation of Electric Power Systems*, 2015, **39**(1): 241–247  
(金芬兰, 王昊, 范广民, 余建明, 米为民. 智能电网调度控制系统的变电站集中监控功能设计. *电力系统自动化*, 2015, **39**(1): 241–247)
- 61 Zaytar M A, El Amrani C. Sequence to sequence weather forecasting with long short-term memory recurrent neural networks. *International Journal of Computer Applications*, 2016, **143**(11): 7–11
- 62 Rossiter J. *Model-Based Predictive Control: A Practical Approach*. Boca Raton: CRC Press, 2017. 52–74
- 63 Müller M, Grüne L. Economic model predictive control without terminal constraints for optimal periodic behavior. *Automatica*, 2016, **70**: 128–139
- 64 Zong Y, Böning G M, Santos R M, You S, Hu J J, Han X. Challenges of implementing economic model predictive control strategy for buildings interacting with smart energy systems. *Applied Thermal Engineering*, 2017, **114**: 1476–1486
- 65 Qiao Liang-Liang, Li Chen-Kun, Fu Liang, Tang Wei-Ping. Vibration zone division of a 250MW hydropower unit and application of AGC vibration avoidance method. *Water Resources and Power*, 2018, **36**(9): 152–154  
(乔亮亮, 李晨坤, 付亮, 唐卫平. 某 250MW 水电机组振动区划分及 AGC 避振方法应用. *水电能源科学*, 2018, **36**(9): 152–154)
- 66 Deng Wei, Liu Fang-Ming, Jin Hai, Li Dan. Leveraging renewable energy in cloud computing datacenters: State of the art and future research. *Chinese Journal of Computers*, 2013, **36**(3): 582–598  
(邓维, 刘方明, 金海, 李丹. 云计算数据中心的新能源应用: 研究现状与趋势. *计算机学报*, 2013, **36**(3): 582–598)
- 67 Wen Zheng-Nan, Liu Ji-Chun. A optimal scheduling method for hybrid wind-solar-hydro power generation system with data center in demand side. *Power System Technology*, 2019, **43**(7): 2449–2459  
(温正楠, 刘继春. 风光水互补发电系统与需求侧数据中心联动的优化调度方法. *电网技术*, 2019, **43**(7): 2449–2459)



**夏元清** 北京理工大学自动化学院教授。主要研究方向为云控制系统, 云数据中心调度管理, 智能电厂, 智能交通, 模型预测控制, 自抗扰控制, 飞行器控制和空天地一体化控制。本文通信作者。

E-mail: xia\_yuanqing@bit.edu.cn

**(XIA Yuan-Qing** Professor at the School of Automation, Beijing Institute of Technology. His research interest covers cloud control, cloud data center optimization scheduling and management, intelligent power plant, intelligent transportation, model predictive control, active disturbance rejection control, flight control, and networked cooperative control for integration of space, air and earth. Corresponding author of this paper.)






**高润泽** 北京理工大学自动化学院博士研究生. 主要研究方向为云控制系统, 智能电厂, 云 workflow 调度管理, 深度强化学习.

E-mail: gaorunze0558@163.com

(**GAO Run-Ze** Ph.D. candidate at the School of Automation, Beijing

Institute of Technology. His research interest covers cloud control system, intelligent power plant, cloud workflow scheduling and management, and deep reinforcement learning.)



**林 敏** 北京理工大学自动化学院博士研究生. 主要研究方向为云控制系统, 移动机器人控制与协同.

E-mail: brucesimpsonlm@gmail.com

(**LIN Min** Ph.D. candidate at the School of Automation, Beijing Institute of Technology. His research interest

covers cloud control and mobile robot control and collaboration.)




**任延明** 北京中水科水电科技开发有限公司工程师. 主要从事水电站和新能源计算机监控系统的项目管理和系统集成工作.

E-mail: rym\_bite@163.com

(**REN Yan-Ming** Engineer at Beijing IWHR Hydro Power Technology Development Co., Ltd.. He works on project

management and system integration of hydropower station and new energy computer monitoring system.)



**闫 策** 北京理工大学自动化学院博士研究生. 主要研究方向为云控制系统, 智能交通, 云 workflow 调度管理, 执行器饱和控制, Delta 算子, 有限频域.

E-mail: yancemc@163.com

(**YAN Ce** Ph.D. candidate at the School of Automation, Beijing Institute of Technology. His research interest

covers cloud control system, intelligent power plant, cloud workflow scheduling and management, actuator saturation, delta operator, and finite frequency.)