

改进交替方向乘子法求解冷水机组负荷分配群智能优化问题

于军琪¹, 陈时羽¹, 赵安军^{1†}, 冯增喜¹, 高之坤²

(1. 西安建筑科技大学 建筑设备科学与工程学院, 陕西 西安 710055;

2. 西安建筑科技大学 信息与控制工程学院, 陕西 西安 710055)

摘要: 群智能控制系统中的多台冷水机组负荷优化分配问题是一个多块优化问题, 传统分布式方法难以获得其收敛解。文中将交替方向乘子法(ADMM)引入冷水机组负荷分配群智能优化问题中, 并通过一种有效的高斯罚函数(GPF)更新策略改进了交替方向乘子法收敛特性。同时, 建立了一种基于ADMM-GPF-GBS双层分布式计算框架的冷水机组负荷优化分配模型, 该模型仅利用相邻节点间的局部信息传递, 即可求解得出最优运行策略。最后, 通过两个典型算例对比分析了所提优化方法的有效性, 并在实际硬件系统中进一步对该算法进行应用与验证。结果表明, 所提算法适用于群智能控制系统下的多台冷水机组系统, 且具有比传统分布式算法更好的寻优能力和收敛性, 可以取得显著的节能效果。

关键词: 中央空调系统; 群智能; 冷水机组; 负荷分配; 交替方向乘子法; 分布式优化

引用格式: 于军琪, 陈时羽, 赵安军, 等. 改进交替方向乘子法求解冷水机组负荷分配群智能优化问题. 控制理论与应用, 2021, 38(7): 947–962

DOI: 10.7641/CTA.2021.00625

Improved alternating direction method of multipliers for solving optimal chiller loading problem in swarm intelligent control system

YU Jun-qi¹, CHEN Shi-yu¹, ZHAO An-jun^{1†}, FENG Zeng-xi¹, GAO Zhi-kun²

(1. School of Building Services Science and Engineering,

Xi'an University of Architecture and Technology, Xi'an Shaanxi, 710055, China;

2. School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an Shaanxi, 710055, China)

Abstract: As a multi-block optimization problem, the optimal chiller loading (OCL) in the swarm intelligent control system is difficult to obtain a convergent solution by using the conventional distributed algorithm. To solve this problem, an improved alternating direction multiplier method (ADMM) was used in this article. In the method, the convergence characteristic was improved by an effective Gaussian penalty function (GPF) update strategy. An optimal chiller loading model based on ADMM-GPF-GBS double-layer distributed computing framework was established, and the global optimal solution can be obtained by parallel computing only by using the information transmission between adjacent nodes. The effectiveness of the proposed optimization method was compared and analyzed by two numerical examples, and the algorithm was further applied and verified in the actual hardware system. The results indicate that ADMM-GPF-GBS is suitable for the central air conditioning multi-chiller systems under the swarm intelligent control framework and has excellent optimization ability with good convergence. The energy-saving effect is remarkable.

Key words: air-conditioning system; swarm intelligent; multi-chiller systems; optimal chiller loading; alternating direction method of multipliers; distributed optimization

Citation: YU Junqi, CHEN Shiyu, ZHAO Anjun, et al. Improved alternating direction method of multipliers for solving optimal chiller loading problem in swarm intelligent control system. *Control Theory & Applications*, 2021, 38(7): 947–962

收稿日期: 2020–09–17; 录用日期: 2021–02–19.

†通信作者. E-mail: zhao_anjun@163.com; Tel.: +86 15829350164.

本文责任编辑: 陈皓勇.

国家重点研发计划项目“新型建筑智能化系统平台技术”(2017YFC0704100), 安徽建筑大学智能建筑与建筑节能安徽省重点实验室2018年度开放课题(IBES2018KF08)资助.

Supported by the National Key Research and Development Program of China (2017YFC0704100) and the Anhui Jianzhu University Intelligent Building and Building Energy Saving Anhui Key Laboratory Opening Project in 2018 (IBES2018KF08).

1 引言

多冷水机组系统的运行能耗约占中央空调系统总能耗的60%,其运行效率对中央空调系统的整体节能将会有较大影响.如何提高多冷水机组系统的运行效率是当代建筑节能的重要课题之一^[1].多冷水机组系统由不同性能和容量的冷水机组组成^[2].在满足负荷需求的前提下,各冷水机组部分负荷率(part load rate, PLR)的最优组合可以使空调系统运行能耗最低.因此,在不同负荷需求下,如何解决冷水机组负荷优化分配(optimal chiller loading, OCL)问题以达到系统节能的目的,已经引起了当今研究人员的广泛关注.

早期的大多数研究工作主要致力于采用不同的精确算法来解决OCL问题. Braun等人^[3]最早采用拉格朗日法(Lagrange method, LM)求解中央空调冷水机组经济调度问题(economic dispatch of chillers problem, EDCP).在此基础上, Chang^[4]采用LM对冷水机组负荷优化分配(OCL)问题进行求解,但该算法在系统冷量需求低时不能收敛. Chang^[5]提出了一种梯度法(gradient method, GM)来解决该问题,指出GM克服了LM只能在高需求下收敛的局限性,但其求解精度略低于LM.为了消除LM的局限性并寻求更高精度数值解,一系列元启发式算法相继被应用于求解该类优化问题. Chang^[6-7]分别将遗传算法(genetic algorithm, GA)和模拟退火(simulated annealing, SA)应用于多冷水机组系统的负荷优化分配问题上,GA算法和SA方法都能够克服LM的弊端,但GA算法增加了系统的能耗,而SA能进一步找到解决OCL问题的更优解.此外,粒子群算法(particle swarm optimization, PSO)^[8]、差分进化算法(differential evolution, DE)、改进萤火虫算法(improved firefly algorithm, IFA)^[2]、差分布谷鸟搜索算法(differential cuckoo search algorithm, DCSA)^[9]、基于教与学的算法(teaching-learning-based optimization, TLBO)^[10]、纹波蜂群优化(improved ripple bee swarm optimization, RBSO)^[11-12]、改进入侵杂草优化算法(improved invasive weed optimization, EIWO)^[13]、改进人工鱼群算法(improved artificial fish swarm algorithm, VAFSA)^[14]都被应用于冷水机组负荷优化分配问题,均能克服LM在低负荷需求下出现的算法发散问题,取得较好的节能效果.

上述优化算法均基于集中式控制系统架构,在实际工程中需逐例进行算法设计,计算时需要收集全局信息,对中央控制器的性能有很高的要求,一旦中央处理器发生故障,整个控制系统将处于瘫痪状态,高昂的计算成本和通信代价严重阻碍了这些算法在实际工程中的大规模应用.

与集中式系统架构不同,分布式优化框架中无需任何中心节点,与问题相关的节点数据分布存储在各个节点中,同时每个节点只与其邻居节点进行局部信

息交换,分布式计算单元将取代中央控制器分担沉重的计算负荷,减轻网络的通信代价,提高整体计算效率.在实际应用中,分布式优化框架由于其可扩展性和分布式的优点,可以很自然地与大规模网络或复杂系统集成.因此,分布式优化算法具有较强的鲁棒性和灵活性,能够更好地适应多代理结构的系统^[15].目前,存在一些暖通空调系统分布式优化控制方法^[16-18],需要一个主协调器代理进行集中式计算,计算后将子任务分配给次级控制器,以此实现分布式优化控制,如文献[18]建立了以能耗最小为目标的空调系统总体控制全局优化模型,采用适合于求解高维度优化问题的分解-协调法,获得了比直接搜索法更高的计算效率.文献[16]针对OCL问题提出的分布式分布混沌估计算法(distributed chaotic estimation of distribution algorithm, DCEDA),比集中式控制算法获得了更好的节能效果,但仍然需要一个主协调器进行计算,不能实现完全分布式优化控制.

清华大学建筑节能研究中心设计出一种基于分布式计算框架的无中心、扁平化的智能建筑自动化控制系统,称为群智能系统^[19].此系统无需协调器,各节点自组织、自协调实现分布式优化计算^[20].其中,计算节点(computing processing node, CPN)是该系统架构中的关键设备,也是构成并行计算网络骨架的硬件节点,其结构示意图如图1所示.每台CPN中都有一台微处理器,以储存本地和相邻CPN数据信息,相邻CPN之间通过数据接口进行有线数据交互,形成网络并行计算模式.此外,每台CPN设置了驱动单元(drive control unit, DCU)通信接口,以支持多种通信方式.




图1 CPN节点结构图

Fig. 1 Structure diagram of CPN node

目前已有学者基于此平台进行了研究. Wang等人^[21]针对并联水泵的优化问题,提出了一种基于局部交互博弈的分布式优化算法进行求解; Dai等人^[22]提出了一种适用于并联水泵和冷水机组优化运

行的分布式优化控制算法, 并且基于群智能平台对算法进行有效性验证, 结果表明, 与传统集中式控制方法相比, 基于群智能系统平台的分布式控制方法系统能效有所提升, 但是, 关于多冷水机组系统的节能研究还有较大提升空间。

Liu等人^[23]针对中央空调系统全局优化问题, 提出了一种基于罚函数方法的分散式优化算法, 首先采用变量分裂法实现变量的解耦, 再通过罚函数方法将原优化问题分解为多个子优化问题, 最后各设备仅通过与邻居设备的通信和求解子优化问题来获得整个优化问题的最优解。然而, 中央空调系统中解耦的多冷水机组负荷分配问题, 在分布式计算中通常属于两块及两块以上(N -Block, $N \geq 2$)的典型优化分配问题, 常规分布式算法在求解该类问题时通常难以收敛, 这成为基于群智能系统求解OCL问题的研究难点。

交替方向乘子法 (alternating direction method of multipliers, ADMM) 是一种被广泛应用于解决分布式框架优化问题的方法, 首次由Stephen Boyd等^[24]于2010年引入分布式优化问题中, 运用在统计学和机器学习领域。目前, ADMM在智能电力网络、传感器网络和计算机通信网络领域已经取得了很大的成功^[25-30]。ADMM有效地结合了对偶上升法 (dual ascent) 的可分解性和拉格朗日乘数法 (Lagrange multiplier method) 的收敛性, 能够将原本复杂的高维度问题转化为两个子问题分别进行求解, 并且具有较好的收敛性^[24, 31]。将ADMM推广至多块的优化问题上是非常合乎需要的, 在很多大规模分布式网络和多智能节点系统结构领域具有巨大应用价值。然而, Chen等人^[32]通过反例证明了多块ADMM的直接推广不一定保证收敛。He等人^[33-34]引入高斯回代校正步骤 (Gaussian back substitution procedure, GBS) 生成新的迭代来保证多块ADMM算法的收敛性。ADMM-GBS将原本复杂的高维度问题分而治之, 划分为3个及以上低维度子问题, 非常适用于解决基于分布式优化框架的问题^[29, 34], 同样适合作为分布式优化算法求解基于群智能系统的OCL问题, 求解多块优化问题的收敛性将得到保证。然而, ADMM-GBS需要采用递减步长来保证精确收敛到最优解, 其收敛速度十分依赖于具体参数的选择, 算法的快速收敛性难以保证。

针对上述问题, 文中提出了一种基于高斯罚函数的改进交替方向乘子法 (ADMM-GPF-GBS), 以增强算法的寻优能力与收敛速度, 从而实现群智能系统下多冷水机组负荷分配的完全分布式优化控制。本研究主要贡献在于: 1) 以满足一定约束条件的总能耗最小为目标, 将ADMM首次引入求解冷水机组负荷优化分配问题; 2) 所提 ADMM-GPF-GBS 在保留 ADMM-GBS 框架的基础上, 采用高斯模型改进罚函数实现非线性变化递减, 取得了更好的计算效果和收敛速度;

3) 基于两个典型算例和群智能系统仿真实验, 验证了所提方法在计算效果、收敛特性和鲁棒性能等方面的有效性和合理性, 以及与群智能系统的适配性。

2 中央空调冷水机组群智能优化控制问题

中央空调系统是一种高度复杂且非线性的多设备系统, 其中, 冷水机组系统的主要结构包括冷水机组、泵和冷却塔。传统自控系统中, 各类机电设备通过现场总线的形式与中央控制器相连, 以建立相互通信的关系, 如图2所示。




图2 集中式控制系统架构

Fig. 2 Centralized control system architecture

中央空调系统中典型OCL问题的优化目标通常为冷水机组的功率消耗, 具体而言, 是在找寻一组不超过运行限制条件的冷水机组部分负荷率 (PLR), 以最低冷水机组运行功耗满足中央空调末端冷负荷需求, 达到节能减排的目的。由于冷水机组的功率 P_{chiller} 与 PLR 相关, 所以 P_{chiller} 通常拟合成的多项式形式, 可以表示为如下凸函数^[7]:

$$P_{\text{chiller}} = a + b \times \text{PLR} + c \times \text{PLR}^2 + d \times \text{PLR}^3. \quad (1)$$

式中 a, b, c, d 为冷水机组的性能系数。由于冷水机组的最大出力是其设计容量, 将 PLR 值的上限设置为 1.0。若冷水机组出力过低, 则会出现运行不稳定的情况, 因而将 PLR 值的下限设置为 0.3。因此, 并联冷水机组系统负荷优化分配的目标函数和约束条件如式 (2) 所示。

$$\begin{aligned} \min \quad & P_{\text{total}} \\ \text{s.t.} \quad & 0.3 \leq \text{PLR}_i \leq 1 \text{ 或 } \text{PLR}_i = 0, \\ & \sum_{i=1}^N \text{PLR}_i \times Q_i^0 = Q_{\text{need}}, \quad i = 1, 2, \dots, N, \end{aligned} \quad (2)$$

式中: P_{total} 为并联冷水机组系统的总能耗, PLR_i 为第 i 台冷水机组的部分负荷率, Q_i^0 为第 i 台冷水机组的额定制冷量, Q_{need} 为系统末端负荷需求, N 为并联冷水机组的台数。上述数学模型建立在集中式架构下,

要求中央处理器具有全部系统信息. 不同于集中式控制系统架构, 在图3所示的群智能控制系统架构中, 冷水机组等机电设备在出厂之前, 通过内置CPN升级为智能机电设备. 在现场安装过程中, 根据实际的物理拓扑, 只需将所有CPN通过数据线连接起来, 即可组成群智能控制系统网络. 网络中的每个控制器节点都具有平等的地位, 能够随时加入和退出网络, 即插即用, 即联即通. 群智能控制系统网络拓扑搭建完成后, 将相同的分布式优化算法下载到所有CPN中, 通过相邻CPN间局部通信的方式进行全局协调优化控制, 从而满足系统的控制要求. 因此, 群智能控制系统架构下, 无需复杂的系统建模和算法开发, 大大简化了控制网络拓扑的现场配置, 系统具有更强的灵活性和扩展性; “去中心”的分布式优化计算架构不存在单点故障问题, 控制网络的鲁棒性也得以提高. 因此, 这种群智能控制系统架构是一种工程布置快、专业门槛低的控制架构, 更符合中央空调控制系统的发展方向.




图3 群智能控制系统架构

Fig. 3 Swarm intelligent control system architecture

在分布式优化框架中, 每一台更新的智能冷水机组设备无需获取全局信息, 仅仅基于本地和相邻节点信息即可完成冷水机组最优负荷分配任务. 此时, 每个智能冷水机组都将被拆分为一个集中式子模型, 每台冷水机组的处理器都内置完全一致的分布式算法, 其中, 每一个冷水机组控制器中的优化问题都是式(2)的次优化问题, 可定义为

$$\begin{aligned} \min P_i \\ \text{s.t. } 0.3 \leq \text{PLR}_i \leq 1 \text{ 或 } \text{PLR}_i = 0, \\ \sum_{i=1}^N \text{PLR}_i \times Q_i^0 = Q_{\text{need}}, i = 1, 2, \dots, N, \end{aligned} \quad (3)$$

式中 P_i 为第 i 台冷水机组的能耗. 式(3)为式(2)的一个子优化模型, 每台冷水机组的子优化模型及其能耗信息仅存储于本地控制器节点中. 因此, 设计仅使用直接通信链路的机制, 并通过控制器节点之间的局部信

息交互来实现全局优化, 成为解决分布式优化框架下多冷水机组负荷优化分配问题的关键. 文中引入ADMM对分布式优化框架下的问题(3)进行求解. 已知式(3)中存在非凸约束, ADMM直接求解非凸问题无法保证得到收敛解. 因此, 将约束松弛到目标函数中, 引入拉格朗日乘数和惩罚参数构建增广拉格朗日函数, 形成的凸优化模型可以表示为

$$\begin{aligned} \min L_\rho = P_i - \lambda^T \left(\sum_{i=1}^N \text{PLR}_i \times Q_i^0 - Q_{\text{need}} \right) + \\ \frac{\rho}{2} \left\| \sum_{i=1}^N \text{PLR}_i \times Q_i^0 - Q_{\text{need}} \right\|^2, \end{aligned} \quad (4)$$

$$\text{s.t. } 0.3 \leq \text{PLR}_i \leq 1 \text{ 或 } \text{PLR}_i = 0.$$

式中: L_ρ 为构造的增广拉格朗日函数, λ 为拉格朗日乘数, ρ 是惩罚参数. 惩罚函数是一个约束违背的度量, 使得当约束满足时取零, 约束违背时取非零. 文中引入惩罚参数使解个体在寻优过程中脱离不可行区域, 同时, 惩罚函数更新策略的改进将大大提高算法收敛速度并且改良计算效果. 文中将在第3部分讨论一种基于ADMM的惩罚函数的更新迭代策略.

3 多冷水机组负荷分配群智能优化算法

3.1 ADMM-GBS算法

典型ADMM主要用来解决带有线性等式约束的两个目标函数之和最小化问题, 且在两个可分离算子下具有较好收敛性^[31-32]. 针对分布式优化框架下的多冷水机组系统, 文中考虑具有 $m(m \geq 3)$ 个可分离算子的凸优化问题(5), 目标为 m 个可分凸函数之和.

$$\min \left\{ \sum_{i=1}^m P_i(x_i) \mid \sum_{i=1}^m A_i x_i = b, x_i \in \chi_i \right\}, \quad (5)$$

式中: $\chi_i \subset \mathbb{R}^{n_i}$ 为凸集, $b \in \mathbb{R}^l$, $A_i \in \mathbb{R}^{l \times n_i}$, $P_i: \mathbb{R}^{n_i} \rightarrow (-\infty, +\infty]$ 是下半连续真凸函数. 假设式(5)的解集为非空, 其构建的增广拉格朗日函数可以表示为

$$\begin{aligned} L_\rho(x_1, x_2, \dots, x_m, \lambda) = \\ \sum_{i=1}^m P_i(x_i) - \lambda^T \left(\sum_{i=1}^m A_i x_i - b \right) + \frac{\rho}{2} \left\| \sum_{i=1}^m A_i x_i - b \right\|^2, \end{aligned} \quad (6)$$

式中: $\lambda \in \mathbb{R}^l$ 为拉格朗日乘数, $\rho > 0$ 是惩罚参数.

ADMM的 $m(m \geq 3)$ 个可分离算子算法的直接推广形式表示如下:

$$\begin{cases} x_1^{k+1} = \underset{x_1 \in \chi_1}{\operatorname{argmin}} L_\rho(x_1, x_2^k, \dots, x_m^k, \lambda^k), \\ \vdots \\ x_i^{k+1} = \underset{x_i \in \chi_i}{\operatorname{argmin}} L_\rho(x_1^{k+1}, \dots, x_{i-1}^{k+1}, x_i, \\ \quad x_{i+1}^k, \dots, x_m^k, \lambda^k), \\ \vdots \\ x_m^{k+1} = \underset{x_m \in \chi_m}{\operatorname{argmin}} L_\rho(x_1^{k+1}, \dots, x_{m-1}^{k+1}, x_m, \lambda^k), \\ \lambda^{k+1} = \lambda^k - \alpha_0 \rho (A_1 x_1^{k+1} + A_2 x_2^{k+1} + \\ \quad \dots + A_m x_m^{k+1} - b). \end{cases} \quad (7)$$

其中 α_0 称为迭代步长.

定义符号以简化分析, 假定 $v^{k+1} = \bar{v}^k$ 代表ADMM求解后的预测项, 其中

$$\begin{cases} v^{k+1} = (x_1^{k+1}, \dots, x_m^{k+1}, \lambda^{k+1}), \\ \bar{v}^k = (\bar{x}_1^k, \dots, \bar{x}_m^k, \bar{\rho}^k), \forall k \in \mathbb{N}. \end{cases} \quad (8)$$

已知ADMM在两个以上可分离算子问题上不具有收敛性^[32], 需要通过引入高斯回代校正步骤(GBS)生成新的迭代^[33], 来校正式(7)的输出, 以确保ADMM算法在两个以上可分离算子问题上的收敛性.

$$\begin{bmatrix} x_2^{k+1} \\ \vdots \\ x_{m-1}^{k+1} \\ x_m^{k+1} \\ \lambda^{k+1} \end{bmatrix} = \begin{bmatrix} x_2^k \\ \vdots \\ x_{m-1}^k \\ x_m^k \\ \lambda^k \end{bmatrix} + \alpha \begin{bmatrix} E-E & 0 & \cdots & 0 \\ 0 & \ddots & \ddots & \ddots \\ \vdots & \ddots & E & -E \\ 0 & \cdots & 0 & E \\ 0 & \cdots & 0 & 0 & E^\lambda \end{bmatrix} \begin{bmatrix} \bar{x}_2^k - x_2^k \\ \vdots \\ \bar{x}_{m-1}^k - x_{m-1}^k \\ \bar{x}_m^k - x_m^k \\ \bar{\lambda}^k - \lambda^k \end{bmatrix}, \quad (9)$$

式中: α 为校正因子, $\alpha \in (0.5, 1)$.

3.2 高斯罚函数改进ADMM-GBS算法

ADMM-GBS算法中惩罚参数 ρ 的选取对收敛速度有较大的影响, 其选取不当可能导致原始残差及对偶残差中某一项收敛速度远慢于另一项, 延长算法的计算时间. 因此, 改进惩罚参数对于改善ADMM-GBS迭代算法收敛速度有重要意义.

式(10)是一个典型的高斯函数(Gaussian function), 图4所示的为一个含双变量的高斯函数分布图, 从图中可以反映出高斯函数有如下特点: 函数值随矢量 $x = (x_1, x_2)$ 离中心点的距离增加而迅速下降为零.

$$G(x_1, x_2, \dots, x_n) = \exp\left[-\sum_{i=1}^n \frac{(x_i - e_i)^2}{h_i}\right]. \quad (10)$$




图4 含双变量的高斯函数图像

Fig. 4 Image of Gaussian function with two variables

若令

$$F(x) = f(x) + \nu G(x), \quad (11)$$

则在 $x = e$ 的邻域内, 由于叠加了高斯函数 $G(x)$ 的作用, $F(x)$ 的函数性质与 $f(x)$ 相差很大, $F(x)$ 明显高于 $f(x)$; 而在离 $x = e$ 较远的区域, $G(x)$ 迅速下降为零, 对 $F(x)$ 函数的性质几乎不起作用, $F(x)$ 与 $f(x)$ 基本重合^[35]. 相对而言, 在ADMM算法优化开始时, 可行解不多, 罚函数应该为一个较大的值, 可使搜索过程尽快进入可行区域中; 随着算法演化的进行, 罚函数应该相应减小, 这将使搜索过程从约束条件转向优化对象能耗值, 同时也可让可行域附近的解相互竞争, 提高算法稳定性. 由以上分析可得, ADMM的罚函数优化迭代近似为一个非线性递减过程, 与高斯函数特点相吻合.

文中在ADMM-GBS基础上提出一种加速罚函数更新策略, 将高斯函数(12)引入到式(6)增广拉格朗日函数中的二次罚函数中. 由此, 得到一种基于高斯罚函数非线性递减策略的快速ADMM-GBS方法(ADMM-GPF-GBS), 其中, 带高斯罚函数项的增广拉格朗日式如式(13)所示:

$$\rho(t) = \beta \exp\left[-\sum_{i=1}^n \frac{(t - \nu_d)^2}{\sigma}\right], \quad (12)$$

$$\begin{aligned} L_\rho(x_1, x_2, \dots, x_m, \lambda, t) = & \sum_{i=1}^m P_i(x_i) - \lambda^T \left(\sum_{i=1}^m A_i x_i - b \right) + \\ & \frac{\rho(t)}{2} \left\| \sum_{i=1}^m A_i x_i - b \right\|^2, \end{aligned} \quad (13)$$

式中: $\rho(t)$ 为高斯罚函数, β 为惩罚系数, σ 为邻域大小因子, ν 为邻域中心, $t \in [\nu_d, +\infty)$, ν_d 为常数.

高斯罚函数 $\rho(t)$ 中, 参数 ν 的取值决定了惩罚区域的位置, 当 $t \in [\nu_d, +\infty)$ 时, 罚函数 $\rho(t)$ 在迭代初期取值较大, 而且递减速度很快, 迭代后期 $\rho(t)$ 几乎不变, 表现出一定的局部特征. 参数 σ 表征了惩罚区域的大小, 取值不同得到不同下降效果, 由图5可见, 罚函数 $\rho(t)$ 的变化曲线近似服从正态分布, 当 $\sigma > 0.25$ 时, $\rho(t)$ 在整个迭代过程中的变化相对平缓; 当 $\sigma < 0.25$ 时, $\rho(t)$ 在迭代初期取值较大, 而且递减的速度很快, 迭代后期 $\rho(t)$ 几乎不变, 表现出一定的局部特性. 为利用 $\rho(t)$ 的这一特性, 文中将参数 σ 的取值设定为 $[0.05, 0.25]$.

此外, 惩罚系数 β 越大, 惩罚项的作用越大. β 的增大有利于将目标函数的极小值点惩罚至边界的整数解附近. 另一方面, β 取值过大会导致目标函数产生新的局部极小值点, 导致求解算法容易陷入局部极小值点, 因此取值应适中. 文中将在参数测试部分讨论高斯罚函数参数的取值对算法性能的影响.




图5 $\nu = 0.5, \beta = 0.5$ 时的取值对罚函数的影响

Fig. 5 The influence of the value of on the penalty function $\rho(t)$ at $\nu = 0.5$ and $\beta = 0.5$

与原始增广拉格朗日函数中的非连续二次罚函数相比, 高斯罚函数不仅具有连续可微的优良性质, 还具有快速下降为零的特点, 且对于中心点周围函数值没有影响, 有利于寻优. ADMG-GPF-GBS算法(后简称为ADMGG)相比较ADMM-GBS算法在多块凸优化问题中的应用, 其在计算速度和精确度方面有明显优势.

3.3 基于ADMGG算法的冷水机组负荷优化分配

基于上述算法, 文中建立了一种 ADMGG 双层分布式计算框架. 首先, 由 ADMM-GPF 预测层求解 OCL问题最优解的预测项; 其次, 由GBS校正层进行高斯回代校正预测项, 保证算法的收敛性和优化结果的精确性. 基于ADMGG双层分布式计算框架的多冷水机组群智能控制系统CPN通信机制如图6所示. 其中 Φ^{k+1} 为节点间负责信息传递的边界矩阵, 存在于每一台冷水机组CPN节点中, 用于存储各设备的算子变量, 标准ADMM的算子变量为冷水机组部分负荷率PLR和拉格朗日乘数 λ , 算法改进后ADMGG的算子变量需增加高斯罚函数 ρ .

图6中每个圆形节点看作一个冷水机组设备CPN节点 $x_i (i = 1, 2, \dots, n)$, 定义冷机CPN节点 x_i 中有边界矩阵 Φ_i^{k+1} , 且

$$\Phi_i^{k+1} = [\text{PLR}_1^{k+1} \text{PLR}_2^{k+1} \dots \text{PLR}_i^{k+1} \text{PLR}_{i+1}^{k+1} \dots \text{PLR}_N^{k+1} \lambda^k \rho^k]_{1 \times (n+2)},$$

各冷水机组CPN节点边界矩阵 Φ^{k+1} 初始值相等, 当节点算子进行更新迭代时, 同时更新边界矩阵 Φ^{k+1} 中相对应的算子, 随后, 节点 x_i 将更新后的边界矩阵 Φ_i^{k+1} 传递给节点 x_{i+1} , 与此同时, 节点 x_{i+1} 更新迭代边界矩阵的值, 继续进行子问题优化求解. 图6中步骤

(1)为ADMGG中的ADMM-GPF预测层, 从冷水机组CPN节点 x_1 开始独立求解本地子优化问题, 更新边界矩阵 Φ_1^{k+1} , 并以正向顺序传递边界矩阵($x_1 \rightarrow x_2 \rightarrow \dots \rightarrow x_n$)至下一个设备节点 x_n 进行迭代更新, 直至节点完成子问题优化求解; 图6中步骤(2)为ADMGG中的GBS校正层, 从节点 x_n 开始以($x_n \rightarrow x_{n-1} \rightarrow \dots \rightarrow x_2 \rightarrow x_1$)反向顺序校正各冷水机组节点边界矩阵中的预测项, 并更新边界矩阵 Φ_i^{k+1} , 直至节点 x_n 完成边界矩阵的校正.




图6 基于ADMM-GPF-GBS双层分布式计算框架多冷水机组节点通信流程

Fig. 6 Node communication flow of multi-chillers based on ADMM-GPF-GBS double-layer distributed computing framework

基于ADMGG双层分布式计算框架的冷机负荷优化分配流程如图7所示, 针对 $N (N \geq 3)$ 台并联冷水机组系统的负荷优化分配问题, 其算法步骤如下.

3.3.1 算法初始化

首先, 将等式约束松弛到目标函数中, 建立 N 台并联冷水机组的增广拉格朗日函数(14), 每台冷水机组设备的功率分别作为一个子优化问题 $P_i(\text{PLR}_i)$ ($i = 1, 2, \dots, N$).

$$L_\rho(\text{PLR}_1, \text{PLR}_2, \dots, \text{PLR}_m, \lambda, \rho) = \sum_{i=1}^N P_i(\text{PLR}_i) - \lambda^T \left(\sum_{i=1}^N \text{PLR}_i \times Q_i^0 - Q_{\text{need}} \right) + \frac{\rho}{2} \left\| \sum_{i=1}^m \text{PLR}_i \times Q_i^0 - Q_{\text{need}} \right\|_2^2, \quad (14)$$

设置系统总功率 $P_{\text{total}} = 0$, 令各冷水机组节点 $\text{PLR}_i^k = \text{PLR}_{i,0}$, 拉格朗日乘数 $\lambda_i^k = \lambda_0$, 高斯罚函数 $\rho_i^k = \rho_0$, 边界矩阵 Φ_i^{k+1} 初始化

$$\Phi_0^{k+1} =$$

$$[\text{PLR}_{1,0} \text{PLR}_{2,0} \dots \text{PLR}_{N,0} \lambda_0 \rho_0]_{1 \times (N+2)},$$

其中: 各冷机节点初始值 $\text{PLR}_{i,0} = 0$, 拉格朗日乘数初始值 $\rho_0 = 1$, 高斯罚函数初始值 $\rho_0 = 0.5$.




图7 基于ADMGG双层分布式计算框架的冷机负荷优化分配流程图

Fig. 7 Algorithm flow of optimal chiller loading based on ADMGG double-layer distributed computing framework

3.3.2 ADMM正向预测

使用ADMGG中的ADMM-GPF预测层正向求解冷水机组节点子优化问题, N 台冷水机组设备算子进

行交替方向乘子法的迭代步骤如式(15)所示. 其中, 对增广拉格朗日函数(14)进行解耦, 得到冷水机组 x_1 至冷水机组 x_n 共 N 个节点子优化问题的增广拉格朗日

函数如式(16)所示:

$$\left\{ \begin{array}{l} \text{PLR}_1^{k+1} = \\ \arg\min L_\rho(\text{PLR}_1, \text{PLR}_2^k, \dots, \text{PLR}_N^k, \lambda^k, \rho^k), \\ \vdots \\ \text{PLR}_m^{k+1} = \\ \arg\min L_\rho(\text{PLR}_1^{k+1}, \dots, \text{PLR}_{m-1}^{k+1}, \text{PLR}_m, \\ \text{PLR}_{m+1}^k, \dots, \text{PLR}_N^k, \lambda^k, \rho^k), \\ \vdots \\ \text{PLR}_N^{k+1} = \\ \arg\min L_\rho(\text{PLR}_1^{k+1}, \dots, \text{PLR}_{N-1}^{k+1}, \text{PLR}_N, \\ \lambda^k, \rho^k), \\ \lambda^{k+1} = \lambda^k + \alpha_0 \rho^k (Q_1^0 \text{PLR}_1^{k+1} + Q_2^0 \text{PLR}_2^{k+1} + \\ \dots + Q_N^0 \text{PLR}_N^{k+1} - Q_{\text{need}}), \\ \rho^{k+1} = \beta \exp(-(\rho^k - \nu)^2 / \sigma). \end{array} \right. \quad (15)$$

$$\left\{ \begin{array}{l} L_1 = \\ P_1(\text{PLR}_1) + \rho^k (\text{PLR}_1 \times Q_1^0 + \sum_{i=2}^N \text{PLR}_i^k \times \\ Q_i^0 - Q_{\text{need}}) + \rho^k / 2 \left\| \text{PLR}_1 \times Q_1^0 + \sum_{i=2}^N \text{PLR}_i^k \times \right. \\ \left. Q_i^0 - Q_{\text{need}} \right\|_2^2, \\ \vdots \\ L_m = \\ P_m(\text{PLR}_m) + \rho^k \left(\sum_{i=2}^{m-1} \text{PLR}_i^{k+1} \times Q_i^0 + \right. \\ \left. \text{PLR}_m \times Q_m^0 + \sum_{i=m+1}^N \text{PLR}_i^k \times Q_i^0 - Q_{\text{need}} \right) + \\ \rho^k / 2 \left\| \sum_{i=2}^{m-1} \text{PLR}_i^{k+1} \times Q_i^0 + \text{PLR}_m \times Q_m^0 + \right. \\ \left. \sum_{i=m+1}^N \text{PLR}_i^k \times Q_i^0 - Q_{\text{need}} \right\|_2^2, \\ \vdots \\ L_N = P_N(\text{PLR}_N) + \rho^k \left(\sum_{i=1}^{N-1} \text{PLR}_i^{k+1} \times Q_i^0 + \right. \\ \left. \text{PLR}_N \times Q_N^0 - Q_{\text{need}} \right) + \\ \rho^k / 2 \left\| \sum_{i=1}^{N-1} \text{PLR}_i^{k+1} \times Q_i^0 + \right. \\ \left. \text{PLR}_N \times Q_N^0 - Q_{\text{need}} \right\|_2^2. \end{array} \right. \quad (16)$$

定义

$$v^{k+1} = (\text{PLR}_1^{k+1} \text{PLR}_2^{k+1} \dots \text{PLR}_N^{k+1} \lambda^{k+1} \rho^{k+1}),$$

$$\text{令 } v^{k+1} = \bar{v}^k = (\bar{\text{PLR}}_1^{k+1} \bar{\text{PLR}}_2^{k+1} \dots \bar{\text{PLR}}_N^{k+1} \bar{\lambda}^{k+1} \bar{\rho}^{k+1}) \text{ 代表 ADMM-GPF 预测项.}$$

3.3.3 ADMGG 反向校正

使用 ADMGG 中的 GBS 校正层反向校正 ADMM-GPF 预测项. 式(17)为 N 台冷水机组设备算子进行高斯回代、校正预测值的步骤.

$$\left\{ \begin{array}{l} \lambda^{k+1} = \lambda^k + \alpha(\bar{\lambda}^k - \lambda^k), \\ \text{PLR}_N^{k+1} = \text{PLR}_N^k + \alpha(\bar{\text{PLR}}_N^k - \text{PLR}_N^k), \\ \vdots \\ \text{PLR}_m^{k+1} = \text{PLR}_m^k + \alpha[(\bar{\text{PLR}}_m^k - \text{PLR}_m^k) - \\ (\bar{\text{PLR}}_{m+1}^k - \text{PLR}_{m+1}^k)], \\ \vdots \\ \text{PLR}_1^{k+1} = \bar{\text{PLR}}_1^k. \end{array} \right. \quad (17)$$

定义 $v^{k+1} = (\text{PLR}_1^{k+1} \text{PLR}_2^{k+1} \dots \text{PLR}_N^{k+1} \lambda^{k+1} \rho^{k+1})$ 代表高斯回代算法校正项.

3.3.4 迭代停止条件

ADMGG 的原始残差体现了模型的不可行度, 对偶残差则可用于判断迭代是否收敛至最优解, 两者的变化趋势反映算法的收敛特性. 由文献[26]可知, 式(18)为对偶残差和原始残差的计算

$$\left\{ \begin{array}{l} \varepsilon_{\text{dual}}^{k+1} = \rho \sum_{i=1}^N \{ (Q_{N-m}^0)^T \sum_{i=N-m+1}^N Q_i^0 (\text{PLR}_i^k - \\ \text{PLR}_i^{k+1}) \}, \\ \varepsilon_{\text{pri}}^{k+1} = \sum_{i=1}^N Q_i^0 \text{PLR}_i^{k+1} - Q_{\text{need}}, \end{array} \right. \quad (18)$$

式中: $\varepsilon_{\text{dual}}^{k+1}$ 为对偶残差, $\varepsilon_{\text{pri}}^{k+1}$ 为原始残差.

由式(19)确定是否满足停止准则. 若计算结果满足停止准则, 则各冷水机组设备为当前控制器本地存储的最新部分负荷率 PLR_i 和功率 $P_i(\text{PLR}_i)$ ($i = 1, 2, \dots, N$), 以及系统总功率值 P_{total} ; 若计算结果不满足停止准则, 转到式(15)继续进一步迭代, 直至满足停止条件, 求出各冷水机组部分负荷率 PLR_i 、功率 $P_i(\text{PLR}_i)$ 以及系统总功率值 P_{total} , 并输出优化结果

$$\left\{ \begin{array}{l} \|\varepsilon_{\text{dual}}^k\|_2 \leq E_{\text{dual}}, \\ \|\varepsilon_{\text{pri}}^k\|_2 \leq E_{\text{pri}}, \end{array} \right. \quad (19)$$

式中: E_{pri} 为原始残差允许的偏差范围, E_{dual} 为对偶残差允许的偏差范围.

4 算例分析

4.1 算例研究

文中选取两个典型的并联冷水机组系统算例,验证分析所提算法求解OCL问题的能力.算例1^[2-4,6-14]是由3个制冷量为800 RT的冷水机组组成的并联冷水机组系统,算例2的并联冷水机组系统由4台制冷量1280 RT和两台制冷量1250 RT的冷水机组组成^[2,6-7,10,12-14],两个算例中的多冷水机组系统均位于台湾新洲科学园区的半导体工厂^[8].算例中,各冷水机组由于长时间运行,其设计温度、流量存在差异,导致冷水机组的特性曲线并不相同,各冷水机组的性能参数如表1所示.Chang^[8]等人最初提出该系统,并基于算例1、算例2先后对GA^[6],LM^[5]等算法的优化能力进行测试;近年来,这些算例相继被学者用于测试PSO^[8],DCSA^[9],EIWO^[13]和DCEDA^[16]等优化算法求解OCL问题的能力.

表1 并联冷水机组系统中各设备性能参数

Table 1 Performance parameters of each chiller in multi-chiller systems

	冷机	a_i	b_i	c_i	d_i	容量/RT
算例1	1	100.95	818.61	-973.43	788.55	800
	2	66.598	606.34	-380.58	275.95	800
	3	130.09	304.58	14.377	99.80	800
算例2	1	399.345	-122.12	770.46	—	1200
	2	287.116	80.04	700.48	—	1280
	3	-120.505	1525.99	-502.14	—	1280
	4	-19.121	898.76	-98.15	—	1280
	5	-95.029	1202.39	-352.16	—	1250
	6	191.750	224.86	524.04	—	1250

4.2 参数测试

为了找到ADMGG在求解多冷水机组系统负荷优化分配问题时的最佳参数,文中进行了大量的参数计算实验.选取算例1中末端负荷需求为2160RT和

960RT、算例2中末端负荷需求为6858RT和5334RT这4种工况进行算法参数分析实验.

文中选取高斯罚函数邻域中心 $\nu_d = 0.5$,分别对惩罚参数 β 和邻域大小因子 σ 进行最佳参数测试.首先,固定 $\nu_d = 0.5$, $\sigma = 0.25$,改变 β 的取值来求解算例2中末端负荷需求为5334RT的优化结果,由图8可得算法的收敛迭代次数与惩罚参数 β 的变化曲线, β 取值的过大或过小,都会造成迭代次数的增加,且当 $\beta = 0.5$ 时,算法获得最快收敛速度,因此,文中将惩罚参数 β 的取值设定为0.5.




图8 当 $\nu_d = 0.5$, $\beta = 0.25$ 时惩罚参数 β 对求解结果收敛迭代次数的影响

Fig. 8 The influence of penalty parameter β on the number of convergent iterations of the solution when $\nu_d = 0.5$, $\beta = 0.25$

其次,固定 $\nu_d = 0.5$, $\beta = 0.5$,选择高斯罚函数(11)中合适的 σ 值(σ 的取值范围为 $[0.05, 0.25]$).采用ADMGG分别优化上述4个算例,所得最优适值(best)和迭代次数(Iter)如表2所示.比较4组优化结果可以看出,当 $\sigma = 0.10$ 时,该算法的总体优化结果较小,为获得较好的性能,文中将 σ 值取为0.1.

表2 参数 σ 取不同值时ADMGG的优化结果

Table 2 Optimization results of ADMGG with different values of parameter σ

案例	结果	$\sigma = 0.05$	$\sigma = 0.10$	$\sigma = 0.15$	$\sigma = 0.20$	$\sigma = 0.25$
算例1 (2160 RT)	best	1583.83	1583.82	1583.81	1583.85	1583.86
	Iter	6	4	8	9	23
算例1 (960 RT)	best	692.43	692.41	692.41	692.43	692.42
	Iter	7	3	5	6	14
算例2 (6858 RT)	best	4738.59	4738.58	4738.59	4738.60	4738.60
	Iter	8	4	3	14	12
算例2 (5334 RT)	best	3546.43	3546.43	3546.43	3546.44	3546.44
	Iter	11	6	14	23	15

确定高斯罚函数参数设定值之后, 进行30次独立运行, 得到不同算法参数组的优化结果如表3所示.

表 3 4种工况下算法参数实验结果

Table 3 Experimental results of different algorithm parameters under four operating conditions

λ_0	α	ρ_0	算例1		算例2	
			2160 RT	960 RT	6850 RT	5334 RT
1.00	0.50	0.50	1583.82	692.43	4738.59	3546.43
3.00	0.90	0.50	1583.82	692.48	4738.58	3546.43
1.00	0.20	0.50	1583.82	692.51	4738.58	3546.43
1.00	0.50	0.50	1583.86	692.41	4738.58	3546.44
2.00	0.80	0.50	1583.83	692.42	4738.58	3546.45
1.00	0.20	0.50	1583.83	692.42	4738.60	3546.44
1.00	0.50	0.50	1583.83	692.42	4738.60	3546.44
2.00	0.90	0.50	1583.82	692.42	4738.59	3546.43
1.00	0.20	0.50	1583.84	692.49	4738.62	3546.44

在4个实验工况中, 拉格朗日乘数 λ_0 初始值为1.00, 高斯罚函数初始值 ρ_0 为0.50, 校正因子 α 为1.00, 迭代步长 α_0 为1.00的算法参数组的性能最优, 因此将该最佳参数组用于以下进一步的实验分析过程. 实验中所使用的ADMGG的参数值如表4所示.

表 4 算例研究中ADMGG参数设置

Table 4 Setting of ADMGG parameters in the example

符号	说明	取值
ν_d	高斯罚函数邻域中心	0.50
σ	高斯罚函数邻域大小因子	0.10
β	高斯罚函数惩罚参数	0.50
ρ_0	高斯罚函数初始值	0.50
λ_0	拉格朗日乘数初始值	1.00
α	校正因子	1.00
α_0	迭代步长	1.00
MaxIter	最大迭代次数	30.00
E_{dual}	对偶残差允许的偏差范围	0.001
E_{pri}	原始残差允许的偏差范围	0.001

4.3 结果分析

本研究对每个实验工况分别进行独立实验, 将从收敛特性、计算效果和鲁棒性能3个方面对所提算法的优化性能进行分析. 首先, 分别进行两个工况下标准ADMM, ADMM-GBS, LM^[9]和ADMGG收敛性的对比分析实验; 其次进行计算效果分析实验, 将算例1该算法的优化结果与集中式架构下的GA^[6], LM^[9]和分布式优化框架下的ADMM-GBS, DCEDA^[16]算法进行对比, 如表5所示.

表 5 算例1中GA, LM, DCEDA, ADMGG结果对比

Table 5 Comparison of the results of GA, LM, DCEDA and ADMGG in example 1

负荷需求	冷机编号	GA ^[10]		LM ^[9]		DCEDA ^[19]		ADMGG		相对节能量/kW		
		PLR	P/kW(A)	PLR	P/kW(B)	PLR	P/kW(C)	PLR	P/kW(D)	D-A	D-B	D-C
2160 (90%)	1	0.8050		0.7253		0.7265		0.7280				
	2	0.9323	1590.96	0.9747	1583.81	0.9735	1583.81	0.9721	1583.81	-7.14	0.00	0.00
	3	0.9631		1.0000		1.0000		0.9999				
1920 (80%)	1	0.7017		0.6590		0.6609		0.6598				
	2	0.7954	1406.02	0.8600	1403.20	0.8585	1403.20	0.8560	1403.20	-2.82	0.00	0.00
	3	0.9035		0.8825		0.8834		0.8826				
1680 (70%)	1	0.6900		0.5962		0.5942		0.5955				
	2	0.6784	1250.06	0.7450	1244.32	0.7455	1244.32	0.7445	1244.32	-5.74	0.00	0.00
	3	0.7318		0.7600		0.7588		0.7598				
1440 (60%)	1	0.5217		0.5303		0.0000		0.0000				
	2	0.7407	1107.75	0.6155	1102.26	0.8858	993.60	0.8856	993.60	-114.15	-108.66	0.00
	3	0.5381		0.6542		0.9142		0.9145				
1200 (50%)	1	0.4882		—		0.0000		0.0000				
	2	0.4437	971.21	—	—	0.7425	832.33	0.7465	832.33	-138.88	—	0.00
	3	0.5682		—		0.7570		0.7516				
960 (40%)	1	0.3055		—		0.0000		0.0000				
	2	0.3185	842.18	—	—	0.5683	692.25	0.5706	692.25	-149.93	—	0.00
	3	0.5764		—		0.6317		0.6294				

将算例2的优化结果与集中式架构下的GA^[6], DA^[19]算法优化结果进行对比, 如表6所示; 最后, 对于PSO^[8]和分布式优化框架下的ADMM-GBS, DCE-

该算法的鲁棒性能作以分析说明。

表6 算例2中GA, PSO, DCEDA, ADMGG结果对比

Table 6 Comparison of the results of GA, PSO, DCEDA and ADMGG in example 2

负荷需求	冷机编号	GA ^[10]		PSO ^[8]		DCEDA ^[19]		ADMGG		相对节能量/kW		
		PLR	P/kW(A)	PLR	P/kW(B)	PLR	P/kW(C)	PLR	P/kW(D)	D-A	D-B	D-C
6858 (90%)	1	0.7052		0.8026		0.8126		0.8155				
	2	0.7693		0.7799		0.7489		0.7502				
	3	0.9996	4766.33	0.9996	4739.53	1.0000	4738.58	1.0000	4738.56	-27.77	-0.97	-0.02
	4	0.9868		0.9998		1.0000		1.0000				
	5	0.9794		0.9999		1.0000		1.0000				
	6	0.8842		0.8183		0.8395		0.8351				
6477 (85%)	1	0.6207		0.7606		0.7280		0.7301				
	2	0.7742		0.6555		0.6564		0.6603				
	3	0.9927	4459.16	1.0000	4423.04	1.0000	4421.65	1.0000	4421.65	-37.51	-1.39	0.00
	4	0.9589		1.0000		1.0000		1.0000				
	5	0.9956		1.0000		1.0000		1.0000				
	6	0.7595		0.6835		0.7160		0.7098				
6096 (80%)	1	0.8099		0.6591		0.6431		0.6439				
	2	0.5474		0.5798		0.5622		0.5650				
	3	0.9878	4185.87	0.9991	4147.69	1.0000	4143.72	1.0000	4143.72	-42.15	-3.97	0.00
	4	0.9624		0.9979		1.0000		1.0000				
	5	0.9897		0.9921		1.0000		1.0000				
	6	0.5029		0.5710		0.5946		0.5920				
5717 (75%)	1	0.5797		0.7713		0.0000		0.0000				
	2	0.5621		0.7177		0.7144		0.7173				
	3	0.9428	3940.60	0.3000	3921.07	1.0000	3843.07	1.0000	3842.78	-97.82	-78.29	-0.29
	4	0.7908		0.9991		1.0000		1.0000				
	5	0.9951		1.0000		1.0000		1.0000				
	6	0.6339		0.7187		0.7941		0.7913				
5335 (70%)	1	0.5831		0.6418		0.0000		0.0000				
	2	0.5767		0.6621		0.5831		0.5832				
	3	0.5230	3706.22	0.3301	3642.55	1.0000	3546.48	1.0000	3546.43	-159.76	-96.12	-0.05
	4	0.9497		0.9906		1.0000		1.0000				
	5	0.9521		0.9990		1.0000		1.0000				
	6	0.6207		0.5806		0.6221		0.6220				

4.3.1 收敛特性分析

在收敛特性方面, 两个算例研究中ADMGG的部分负荷率PLR的迭代收敛曲线图分别如图9-10所示. 图9为算例1中3台冷水机组在负荷需求为80%的情况下, 算法在3代内快速收敛至最优解, 振荡过程较短; 图10为算例2中6台冷水机组在负荷需求为80%的情况下部分负荷率PLR的迭代收敛曲线图, 迭代过程中每台冷水机组的PLR值振荡时间较短, 算法仅在5-6代完成了迭代过程, 振荡幅值较小.

文中对ADMGG与直接推广的ADMM, ADMM-GBS, LM算法的收敛性进行了进一步的对比, 来验证

所提算法在收敛特性上的优势, 4种算法所得结果与负荷需求量的原始残差变化曲线如图11-12所示. 在收敛精度 $E_{\text{dual}} = 0.001$, $E_{\text{pri}} = 0.0001$ 的限制下, 算例1中需求量为1920RT时, 集中架构下的LM在第13代达到收敛, 而ADMGG在第8代即可完成收敛, 相比同样为分布优化框架下的ADMM-GBS, ADMM, 所提算法可以在更短的时间内使残差快速收敛为零; 在算例2中需求量为6096RT时, ADMGG算法在第7次迭代完成时, 残差已达到收敛条件, 而ADMM算法的残差无法收敛. 可见在3块及以上OCL问题的求解上, 直接推广的标准ADMM不一定收敛, 而所提算法有较好的收敛特性和收敛速度.




图9 算例1 80%负荷需求冷水机组PLR迭代变化

Fig. 9 PLR iterative variation of chillers with 80% load demand in example 1




图10 算例2 80%负荷需求冷水机组PLR迭代变化

Fig. 10 PLR iterative variation of chillers with 80% load demand in example 2




图11 算例1ADMGG、ADMM-GBS、ADMM、LM 4种算法下原始残差迭代收敛图

Fig. 11 The iterative convergence diagram of the original residual under the four algorithms of ADMGG, ADMM-GBS, ADMM and LM in example 1




图12 算例2ADMGG、ADMM-GBS、ADMM、LM 4种算法下原始残差迭代收敛图

Fig. 12 The iterative convergence diagram of the original residual under the four algorithms of ADMGG, ADMM-GBS, ADMM and LM in example 2

4.3.2 计算效果分析

在计算效果方面,在算例1中,与集中式架构下的GA算法相比,ADMGG在不同负荷需求下可以节能2.82~149.93 kW,如表5所示.此外,当负荷需求低于1440 RT时,ADMGG所得到的运行策略比GA算法节能超过100 kW.另外,ADMGG的计算结果与集中式架构下的LM相比,在1440 RT负荷需求下可以节能108.66 kW. Chang在文献[9]中提出,虽然LM方法得到了全局最优解,但当需求量低于50%时,就会出现不能收敛的问题,ADMGG解决了其不能收敛的问题,且获得了最优解;ADMGG的计算结果与分布式优化框架下的DCEDA算法在各负荷需求下的计算结果一致.

在算例2中,与集中式架构下的GA算法和PSO算

法相比,ADMGG在不同负荷需求下可节能约0.95~159.79 kW,当负荷需求小于5717 RT时,其节能效果尤为明显,如表6所示.与分布式优化框架下的DCEDA算法相比,当负荷需求高于6096 RT时,算法所得优化结果与DCEDA算法相一致;且当负荷需求小于5717 RT时,ADMGG获得了比DCEDA算法节能约0.05~0.25 kW的全局最优解.为了进一步验证ADMGG算法相对于DCEDA算法的优势,文中采用迭代次数(Iter)、累计时间(Time)和精度(Acc)作为评估标准来检验计算复杂度.如表7所示,由4次实验结果可得,ADMGG算法在迭代次数和累计时间上都明显快于DCEDA算法,并且能够保持最优的精度,充分展现出所提算法求解并联冷水机组系统负荷优化分配问题时在计算复杂度方面的优势.

表7 ADMGG和DCEDA的算法计算复杂度比较
Table 7 Comparison of computational complexity between ADMGG algorithm and DCEDA algorithm

案例	ADMGG		DCEDA	
	Iter/Time/s	Acc/%	Iter/Time/s	Acc/%
算例1 (2160 RT)	4/0.137273	99.976	46/79.6553	98.328
算例1 (960 RT)	3/0.710075	99.412	24/48.1224	97.020
算例2 (6858 RT)	4/0.405164	97.502	92/101.264	96.475
算例2 (5334 RT)	6/0.394272	98.996	56/88.9605	97.011

4.3.3 鲁棒性能分析

为找到ADMGG在求解OCL问题时的最佳参数,文中对拉格朗日乘数初始值、高斯罚函数初始值、校正因子这三个参数进行了大量的参数计算实验,得到了不同算法参数组的优化结果,如表3所示.其中,拉格朗日乘数的偏差在1,校正因子的最大偏差在0.2,高斯罚函数初始值的偏差在0.3,算例1所得算法结果的最大偏差在0.1,算例2算法结果的最大偏差在0.04.因此,实验结果表明,同一实验工况下不同参数组的优化结果几乎相同,相同参数组下优化结果的最终值相同.这说明ADMGG拥有精确算法良好的鲁棒性和较强的稳定性.故综合考虑算法的计算效果、收敛特性和鲁棒性能,可以得出所提算法在解决并联冷水机组负荷分配问题上拥有精确算法的准确性、优越的收敛性和良好的鲁棒性,算法具备优秀的综合性能.

本节基于两个典型算例,利用ADMGG双层分布式计算框架对多冷水机组负荷分配问题进行MATLAB软件仿真,并与其他算法优化结果进行分析比较.下一节,文中将该计算框架应用于建筑群智能系统仿真平台上进行硬件实验,从而验证ADMGG与分布式优化框架的适配性.


5 群智能实验系统与算法仿真

为进一步验证算法在实际系统中的性能,将该计算框架应用于建筑群智能系统仿真平台上进行实验.该平台是一种半物理综合仿真测试与验证平台,如图13所示,包括了CPN的分布式控制系统和在PC端运行的仿真软件,用于监控每个智能节点的工作状态并模拟终端系统.在图13的左侧,选中的每个CPN节点都被写入冷水机组模型,每个CPN节点可以作为一个智能冷水机组来测试分布式优化算法,CPN节点通过以太网通信接口与其相邻节点相连,其CPN节点整

体拓扑网络结构如图14所示;图13右侧在PC端模拟终端系统,开发了群智能仿真软件来模拟冷水机组进出口温度传感器,通过数据线或是无线通信方式向CPN节点发送信号,也可以从每个CPN节点收集信息,从而监控每个CPN节点的工作状态.



(a) 群智能控制系统CPN节点



(b) 末端监控系统

图13 建筑群智能系统仿真实验平台

Fig. 13 The experimental platform of swarm intelligent building system




图14 空调冷站系统CPN智能节点拓扑结构图

Fig. 14 Topological structure diagram of CPN intelligent node in air conditioning cold station system

已知文献[22]在该实验平台利用传统集中式控制方法和分布式优化控制方法对4台并联冷水机组进行测试,该组多冷水机组系统包括3台容量为544 RT的冷水机组1和一台容量为300 RT的冷水机组2,其性能参数如表8所示. 实验中,常规集中式控制方法由系统负荷作为切换点来采用不同的分配策略,即系统负荷50%对应于4台运行冷水机组,40%对应于3台运行

冷水机组,30%对应于2台运行冷水机组,在实际应用中通过比较冷水机组的PLR和蒸发器出水温度来确定冷水机组的台数. 文献[22]中所采用的分布式优化控制方法通过交换相邻冷水机组之间的冷却负荷需求差值和相对效率,将每个冷水机组的工作点移至接近最高效率点,从找到一个最优化的运行冷水机组台数组合.

表 8 并联冷水机组系统中各设备性能参数
Table 8 Performance parameters of each chiller in multi-chiller systems

冷机	e_1	e_2	e_3	e_4	e_5	e_6	e_7	e_8	e_9	e_{10}	额定制冷量/RT
1	14.438	9.586	0.403	-0.540	-12.018	0.014	0.003	-0.092	0.219	-0.009	544
2	9.618	15.823	0.524	-0.586	-11.687	0.006	0.006	0.049	0.071	-0.013	300

为连续模拟多冷水机组群智能控制系统,将冷水机组蒸发器出水温度设定为7℃,进入冷凝器的水温为30℃,各冷水机组的冷水流量恒为额定值. 如实例研究所示,控制算法的输入变量为终端冷水机组的总冷负荷需求. 因此,在这个结合了多个单一案例研究的连续模拟中,采用了一天实际建筑物运行状况下的典型制冷负荷变化曲线,设置控制周期为10 min,即控制算法每10 min运行一次,该冷水机组系统的工作时间为12小时,由此得到的冷负荷变化曲线包括72个工况.

文中将ADMGG双层分布式计算框架应用于群智能建筑自动化系统平台上,与集中式控制方法、传统分布式优化算法进行对比,其结果如图15所示.




图 15 冷水机组控制的连续仿真结果

Fig. 15 Continuous simulation results of multi-chiller systems control

优化结果表明ADMGG优化算法的功率整体略低于传统分布式算法的功率. 其中,ADMGG算法与传统分布式算法的冷机台数开启状况一致,在某些工况下,多冷水机组部分负荷率分配不同导致ADMGG算法与传统分布式算法下冷机运行功耗不同. 例如,在第38种工况下,ADMGG优化算法的三大一小冷机部分负荷率分别为0.9864, 0.9643, 0.7432, 0.7654, 其冷

机运行功率是964.7 kW,而传统分布式算法和集中式控制方法的运行功率为984.2 kW. ADMGG算法相比于传统分布式算法,冷机整体运行功率约降低2.81%,且每种工况下迭代过程的计算时间都小于1 s,可以快速满足实际应用中的控制要求. 连续仿真结果表明,ADMGG算法是一种与群智能建筑自动化系统平台匹配度很高的分布式优化算法,比传统分布式算法在计算效果方面更胜一筹.

6 结论

文中针对群智能控制系统中的多冷水机组负荷优化分配(OCL)问题,提出一种高斯罚函数更新策略改进的交替方向乘子法(ADMGG),并建立了一种基于ADMM-GPF-GBS双层分布式计算框架的冷水机组负荷优化分配模型,这是首次将ADMM运用于求解中央空调系统OCL问题.

在此基础上,文中基于OCL问题的两个著名实例进行算法测试,并在群智能建筑自动化系统平台上进行验证. 软件测试中,与集中式框架下的精确型LM,元启发式GA, PSO算法,以及分布式优化框架下的DCEDA算法进行了比较. 通过算法参数测试,确定了改进ADMGG在求解该负荷优化分配问题时的最优参数. 两个算例的计算结果表明,ADMGG在解决OCL问题上不受多冷水机组系统规模大小的限制,具有优于精确算法的通用性. 相对于集中式LM,ADMGG最大的优势在于其能够充分利用多冷水机组控制系统的可分解性,对目标函数中的多变量进行交替优化,具备更加优越的寻优能力和收敛能力;与元启发式算法DCEDA相比,ADMGG拥有更简单的计算复杂度,在优化结果上能够找到高精度更优解;与ADMM-GBS相比,ADMGG算法具有更快的收敛速度. 硬件平台验证中,ADMGG算法相比于传统分布式算法,取得了更好的节能效果.

文中所提算法在保留分布式ADMM框架结构的基础上, 采用高斯罚函数实现快速非线性变化递减, 取得了更好的搜索性能. 此外, ADMGG双层分布式计算框架是一种群智能系统平台的新型计算架构, 下一步的研究方向是将其用于求解整个中央空调系统的群智能优化问题.

参考文献:

- [1] WANG Z, DONG Y, LIU W, et al. A novel fault diagnosis approach for chillers based on 1-D convolutional neural network and gated recurrent unit. *Sensors*, 2020, 20(9): 2458.
- [2] COELHO L D, MARIANI V C. Improved firefly algorithm approach applied to chiller loading for energy conservation. *Energy and Buildings*, 2013, 59: 273 – 278.
- [3] BRAUN J E, KLEIN S A, MITCEL J W, et al. Applications of optimal control to chilled water systems without storage. *Ashrae Transactions*, 1989, 95(1): 663 – 675.
- [4] CHANG Y. A novel energy conservation method—optimal chiller loading. *Electric Power Systems Research*, 2004, 69(2): 221 – 226.
- [5] CHANG Y, CHAN T, LEE W, et al. Economic dispatch of chiller plant by gradient method for saving energy. *Applied Energy*, 2010, 87(4): 1096 – 1101.
- [6] CHANG Y. Genetic algorithm based optimal chiller loading for energy conservation. *Applied Thermal Engineering*, 2005, 25(17): 2800 – 2815.
- [7] CHANG Y. An innovative approach for demand side management optimal chiller loading by simulated annealing. *Energy*, 2006, 31(12): 1883 – 1896.
- [8] ARDAKANI A J, ARDAKANI F F, HOSSEINIAN S H, et al. A novel approach for optimal chiller loading using particle swarm optimization. *Energy and Buildings*, 2008, 40(12): 2177 – 2187.
- [9] COELHO L D, KLEIN C E, SABAT S L, et al. Optimal chiller loading for energy conservation using a new differential cuckoo search approach. *Energy*, 2014, 75(1): 237 – 243.
- [10] DUAN P, LI J, WANG Y, et al. Solving chiller loading optimization problems using an improved teaching learning based optimization algorithm. *Optimal Control Applications & Methods*, 2018, 39(1): 65 – 77.
- [11] CHEN C, CHANG Y, CHAN T, et al. Applying smart models for energy saving in optimal chiller loading. *Energy and Buildings*, 2014, 68(A): 364 – 371.
- [12] LO C, TSAI S, LIN B, et al. Economic dispatch of chiller plant by improved ripple bee swarm optimization algorithm for saving energy. *Applied Thermal Engineering*, 2016, 100: 1140 – 1148.
- [13] ZHENG Z, LI J. Optimal chiller loading by improved invasive weed optimization algorithm for reducing energy consumption. *Energy and Buildings*, 2018, 161: 80 – 88.
- [14] ZHENG Z, LI J, DUAN P, et al. Optimal chiller loading by improved artificial fish swarm algorithm for energy saving. *Mathematics and Computers in Simulation*, 2019, 155: 227 – 243.
- [15] YANG T, YI X L, WU J F, et al. A survey of distributed optimization. *Annual Reviews in Control*, 2019, 47: 278 – 305.
- [16] YU J, LIU Q, ZHAO A, et al. Optimal chiller loading in HVAC system using a novel algorithm based on the distributed framework. *Journal of Building Engineering*, 2019, 28: 101044.
- [17] YAO Y, CHEN J. Global optimization of a central air-conditioning system using decomposition-coordination method. *Energy and Buildings*, 2010, 42(5): 570 – 583.
- [18] JIANG Z Y, DAI Y C. A decentralized, flat-structured building automation system. *Energy Procedia*, 2017, 122: 68 – 73.
- [19] YU Junqi, ZHANG Rui, ZHAO Anjun, et al. Energy saving optimization insect intelligent control algorithm for parallel pumps in central air-conditioning system. *Control Theory & Applications*, 2020, 37(10): 86 – 93.
(于军琪, 张瑞, 赵安军, 等. 中央空调系统并联水泵节能优化群智能控制算法. *控制理论与应用*, 2020, 37(10): 86 – 93.)
- [20] COELHO L D, KLEIN C E, SABAT S L, et al. Optimal chiller loading for energy conservation using a new differential cuckoo search approach. *Energy*, 2014, 75(1): 237 – 243.
- [21] WANG S, XING J, JIANG Z, et al. Decentralized optimization algorithms for variable speed pumps operation based on local interaction game. *Journal of Control Science and Engineering*, 2018, 5468398:1 – 5468398:12.
- [22] DAI Y, JIANG Z, SHEN Q, et al. A decentralized algorithm for optimal distribution in HVAC systems. *Building and Environment*, 2016, 95: 21 – 31.
- [23] LIU Zhe, CHEN Xi, GUAN Xiaohong. Decentralized optimization for energy savings for a HVAC chiller plant. *Journal of Tsinghua University (Science and Technology)*, 2014, 54(12): 1560 – 1565.
(柳哲, 陈曦, 管晓宏. HVAC冷站分散式节能优化. *清华大学学报(自然科学版)*, 2014, 54(12): 1560 – 1565.)
- [24] BOYD S, PARIKH N, CHU E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers. *Foundations & Trends in Machine Learning*, 2010, 3(1): 1 – 122.
- [25] MATEOS G, BAZERQUE J A, GIANNAKIS G B, et al. Distributed sparse linear regression. *IEEE Transactions on Signal Processing*, 2010, 58(10): 5262 – 5276.
- [26] YANG L, HONG Y. Adaptive penalized splines for data smoothing. *Computational Statistics & Data Analysis*, 2017, 108: 70 – 83.
- [27] KEKATOS V, GIANNAKIS G B. Distributed robust power system state estimation. *IEEE Transactions on Power Systems*, 2013, 28(2): 1617 – 1626.
- [28] CHEN G, LI J. A fully distributed ADMM-based dispatch approach for virtual power plant problems. *Applied Mathematical Modelling*, 2017, 58: 300 – 312.
- [29] CHEN Jian, LIN Ziliang, ZHAO Haoran, et al. Optimization method for resilience of integrated electric–gas system with consideration of cyber coupling. *Proceedings of the CSEE*, 2020, 40(21): 6854 – 6864.
(陈健, 林咨良, 赵浩然, 等. 考虑信息耦合的电—气综合能源系统韧性优化方法. *中国电机工程学报*, 2020, 40(21): 6854 – 6864.)
- [30] LI W, LIU Y, TIAN Z, et al. Communication-censored linearized ADMM for decentralized consensus optimization. *IEEE Transactions on Signal Processing*, 2019, 6(1): 18 – 33.
- [31] WANG J J, SONG W. An algorithm twisted from generalized ADMM for multi-block separable convex minimization models. *Journal of Computational and Applied Mathematics*, 2017, 309: 342 – 358.
- [32] CHEN C, HE B, YE Y, et al. The direct extension of ADMM for multi-block convex minimization problems is not necessarily convergent. *Mathematical Programming*, 2016, 155(1): 57 – 79.
- [33] HE B, TAO M, YUAN X, et al. Alternating direction method with Gaussian back substitution for separable convex programming. *SIAM Journal on Optimization*, 2012, 22(2): 313 – 340.

- [34] CHEN Yunjie, GE Weidong, SUN Le. A novel linear hyperspectral unmixing method based on collaborative sparsity and total variation. *Acta Automatica Sinica*, 2018, 44(1): 116 – 128.
(陈允杰, 葛魏东, 孙乐. 一种基于协同稀疏和全变差的高光谱线性解混方法. 自动化学报, 2018, 44(1): 116 – 128.)
- [35] LI Zhigang, WU Wenchuan, ZHANG Boming, et al. A large-scale reactive power optimization method based on Gaussian penalty function with discrete control variables. *Proceedings of the Chinese Society for Electrical Engineering*, 2013, 33(4): 68 – 76.
(李志刚, 吴文传, 张伯明, 等. 一种基于高斯罚函数的大规模无功优化离散变量处理方法. 中国电机工程学报, 2013, 33(4): 68 – 76.)

作者简介:

于军琪 博士, 教授, 目前研究方向为建筑智能与节能控制技

术、建筑能耗监测与信息管理系统、智能化系统及应用, E-mail: junqiyu@126.com;

陈时羽 硕士研究生, 目前研究方向为建筑智能与节能控制技术、智能化系统及应用, E-mail: chensy1527@163.com;

赵安军 博士, 副教授, 目前研究方向为建筑物联网及大数据分析、智能建筑暖通空调控制与优化、大型公建能耗监测与节能分析、智能建筑检测技术, E-mail: zhao_anjun@163.com;

冯增喜 博士, 目前研究方向为智能建筑和建筑设备自动化, E-mail: fengzengxi2000@163.com;

高之坤 硕士研究生, 目前研究方向为智能化系统及应用, E-mail: kunzhigao@126.com.