

基于预测与分解策略的大规模炼油过程生产调度算法

陈远东, 丁进良[†]

(东北大学 流程工业综合自动化国家重点实验室, 辽宁 沈阳 110819)

摘要: 炼油生产调度为混合整数规划问题, 随着规模的增大, 其求解时间随问题规模呈指数增加, 使得大规模长周期炼油生产调度问题难以在合理的时间内求解. 针对该问题, 本文提出了一种基于生产任务预测与分解策略的炼油生产调度算法, 该算法能在短时间内获得大规模调度问题的满意解. 所提算法将原问题沿时间轴分解为若干个调度时长相同的单时间段子问题, 并设计了基于深度学习的单时间段生产任务(组分油产量)预测模型, 用于协调子问题的求解. 其中, 生产任务预测模型通过易于获得的小规模问题的全局最优调度方案训练得到. 最后, 通过与商业求解器Cplex以及现有算法的对比, 实验结果表明了所提算法的有效性.

关键词: 分解算法; 深度学习; 大规模优化; 炼油生产; 调度

引用格式: 陈远东, 丁进良. 基于预测与分解策略的大规模炼油过程生产调度算法. 控制理论与应用, 2023, 40(5): 833–846

DOI: 10.7641/CTA.2021.10701

Production scheduling algorithm for large-scale refining process based on prediction and decomposition strategy

CHEN Yuan-dong, DING Jin-liang[†]

(State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang Liaoning 110819, China)

Abstract: Refinery production scheduling is a mixed integer programming problem. As the scale increases, its solution time increases exponentially with the problem size, making it difficult to solve large-scale long-period oil refining production scheduling problems in a reasonable time. Aiming at this problem, this paper proposes a refinery production scheduling algorithm based on production task prediction and decomposition strategy, which can obtain a satisfactory solution to large-scale scheduling problems in a short time. The proposed algorithm decomposes the original problem into several single-period sub-problems with the same duration along the time axis, and designs a single-period production task prediction model based on deep learning to coordinate the solution of the sub-problems. The production task prediction model is trained through the data from small-scale problems, of which the global optimal solution is easy to obtain. Finally, by comparing with the commercial solver Cplex and existing algorithms, the experimental results show the effectiveness of the proposed algorithm.

Key words: decomposition algorithm; deep learning; large-scale optimization; refinery; scheduling

Citation: CHEN Yuandong, DING Jinliang. Production scheduling algorithm for large-scale refining process based on prediction and decomposition strategy. *Control Theory & Applications*, 2023, 40(5): 833–846

1 引言

随着工业4.0战略的提出和各种新技术不断涌现, 如大数据、人工智能、5G、物联网和信息物理系统等^[1], 调度作为企业提高生产效率的重要工具之一, 由此面临着新的挑战, 如全厂调度、长周期调度和实

时调度等^[2]. 对于大规模的炼油生产调度问题, 变量和约束的数量可以超过1000万个, 导致传统的求解方法无法满足快速求解的需要^[3–4]. 为此, 需要研究快速求解大规模长周期炼油生产调度问题的方法.

炼油生产调度问题的决策变量包括连续变量(如

收稿日期: 2021–08–02; 录用日期: 2021–12–30.

[†]通信作者. E-mail: jlding@mail.neu.edu.cn.

本文责任编辑: 王凌.

国家重点研发计划项目(2018YFB1701104), 国家自然科学基金项目(61988101), 辽宁省兴辽计划项目(XLYC1808001), 辽宁省科技项目(2020JH2/10500001, 2020JH1/10100008)资助.

Supported by the National Key Research and Development Program of China (2018YFB1701104), the National Natural Science Foundation of China (61988101), the Xingliao Plan of Liaoning Province (XLYC1808001) and the Science Technology Program of Liaoning Province (2020JH2/10500001, 2020JH1/10100008).

进料流量、调和流量等)和离散变量(如操作模式等). 因此, 炼油生产调度通常是一个具有非确定性多项式(nondeterministic polynomial-hard, NPhard)时间求解特性的混合整数规划(mixed integer programming, M-IP)问题. 随着调度时长的扩大, 调度问题的规模呈指数增大, 使得现有的商业MIP求解器的计算时间呈指数增加, 甚至难以在合理的时间内找到可行解. 目前, 为了缩短大规模调度问题的求解时间, 一些学者提出了不同的基于分解策略的调度算法^[5-9]. 如在经典的Job-shop调度问题^[10-12]或炼钢调度问题^[13-15]中, 这种算法生成的子问题不再是NP-hard问题, 可以在多项式求解时间内求解, 如动态规划^[16-18]等. 因此, 在这两类问题中, 传统的拉格朗日分解算法^[5-7]和Bender分解算法都可以成功应用. 然而, 由于炼油生产中装置连接和操作规则的复杂性, 子问题求解时间较长^[18]. Shah和Ierapetritou^[19]提出了一种用于炼油生产调度的拉格朗日分解算法, 其性能优于经典的拉格朗日分解算法, 但求解时间仍然过长. 同时, 作者指出该算法的主要时间开销是子问题求解(约占90%). Tian等人^[20]提出了一种用于处理大规模化工全厂生产过程调度的分解算法. 该算法包含两个步骤. 第1步求解一个简化的整体模型; 第2步根据第1步的结果独立地求解子模型. 然而, 以上方法都是基于空间分解的方法, 当调度时长进一步扩大, 子问题的规模随调度时长变大, 其求解时间进一步增加, 导致分解算法性能的下降. 此外, 随着调度范围的扩大, 子问题和松弛变量的数量增加, 使得传统的分解算法难以收敛^[21-22].

进化算法也被用于炼油生产调度问题. Remteke和Srinivasan^[23]将图表示与遗传算法相结合, 求解大型炼油厂原油调度问题, 该方法大大减小了问题规模, 提高了求解精度. 然而, 对于大规模的问题, 该算法求解时间仍不理想. Zhang等^[24]针对炼油生产调度混合整数线性规划(mixed integer linear programming, MILP)问题, 设计了离散粒子群优化(discrete particle swarm optimization, DPSO)算法, 其离散变量的解空间由粒子群算法搜索, 连续变量由商业求解器Cplex求解. 显然, 该方法中, 解的搜索空间仍然随着问题的大小呈指数增长. 另外, 进化算法是随机算法, 在调度问题中由于约束较多, 存在可行解的获取耗时较长的问题.

对于大规模NP-hard问题, 目前还没有有效的求解方法^[25]. 为了在合理的时间内解决大规模问题, 启发式是一种有效的方法^[26]. Shah等^[27]提出了一种基于分解的启发式策略, 能够快速获得好的解. 该方法所考虑的生产系统比较简单, 没考虑实际的操作规则, 当调度时长进一步增大时, 子问题的求解也会出现组

合爆炸. Chen等^[28]提出了一种基于知识迁移的调度方法, 可以使大规模炼油生产调度问题在短时间内获得满意解. 然而该方法本质上是基于案例推理方法的, 受限于知识获取且泛化性弱. Harjunkski和Bauer^[29]详细分析了将启发式应用于调度问题的必要性, 并指出当前的启发式规则的缺点之一是没有考虑具体问题的结构.

目前, 对于大规模炼油生产调度问题, 现有算法的主要困难是当调度时长进一步扩大时, 其求解效率降低^[19]. 为此, 本文提出了一种基于预测与分解策略的算法(prediction and decomposition algorithm, PDA). 该算法将长周期大规模炼油生产调度问题沿时间轴分解为若干个子问题, 逐个求解子问题获得原问题的满意解. 由于子问题的规模较小, 其求解时间较短(10^{-1} 秒级), 使原问题求解耗时较少. 另一方面, 为了使它们的解能构成原问题的满意解, 本文构建了基于深度学习的子问题组分油产量预测模型. 通过让子问题的解尽可能达到组分油产量的预测值, 使各个子问题协调求解. 由于短周期小规模问题易于求得全局最优解, 该算法从短周期问题的全局最优解中学习子问题的组分油产量预测. 本文提出了基于订单流量的多个指标, 消除了订单信息描述中的时间因素, 使小规模案例的生产目标知识能迁移到大规模案例中.

用于组分油产量预测的模型是影响PDA求解精度的关键部分. 不同领域的研究表明, 卷积神经网络(convolutional neural network, CNN)结构比其他网络结构(如反向传播(back propagation, BP)神经网络)更能有效地学习事物的特征, 是目前建模领域最有效的方法之一^[30-31]. 例如, CNN已成功应用于软测量^[32]、故障诊断^[33-34]、控制器设计^[35]等工业领域. 由于炼油生产过程中的订单信息具有二维属性, 因此本文采用CNN来构建生产任务预测模型.

本文符号定义, 如表1所示.

表1 符号定义
Table 1 Symbol definition

1) 参数.

- U : 装置的集合;
- U_u : 连接到装置 u 的进料口的装置的集合;
- M_u : 装置 u 运行模式集合;
- Order/T: 订单/时间段的序列号的集合;
- S_u : 装置 u 的侧线集合;
- $S_{u',u}$: 装置 u' 上进入装置 u 的侧线集合;
- O/OC: 产品/组分油(或相应储罐)的集合;
- gO/gOC: 汽油的产品/组分油(或相应储罐)的集合;
- P/gP: 产品/汽油产品物性指标的集合;
- n_{Unit} : 生产装置的数量;
- $n_{\text{O}}/n_{\text{OC}}$: 产品/组分油种类的数量;

n_T/n_L : 时间段/订单的数量;
 $TT_{u,m,m'}$: 装置 u 从模式 m 到 m' 需要的过渡时间;
 $DS_{l,t}$: 如果订单 l 在时间段 t 内可用, $DS_{l,t} = 1$, 否则, $DS_{l,t} = 0$;
 $YM_{u,m,s}$: 装置 u 在运行模式 m 下侧线 s 的收率;
 $B_{u,t}$: 如果装置 u 在时间段 t 内处于模式转换状态, $B_{u,t} = 1$, 否则, $B_{u,t} = 0$;
 FO_{outMax} : 供应订单的最大流量;
 $PRO_{o,p}^{min}/PRO_{o,p}^{max}$: 产品 o 的物性指标 p 允许的最小/最大值;
 $r_{oc,o}^{min}/r_{oc,o}^{max}$: 组分油 oc 在产品 o 中占比的下/上限;
 PC_{ru} : 原油成本惩罚系数;
 $PO_{p,u,m}$: 装置 u 在模式 m 下的运行成本惩罚系数;
 $PInOC/PInO$: 组分油/产品库存的惩罚系数;
 PD : 组分油偏离预测产量的惩罚系数;
 POD : 订单脱销的惩罚系数;
 $Q_{oc,t}$: 单时间段子问题的组分油产量预测值;
 Fu_u^{min}/Fu_u^{max} : 装置 u 输入流量的上下限;
 $PRO_{oc,p}$: 组分油 oc 的物性 p 的值;
 $YM_{u,m,s}$: 装置 u 侧线 s 在操作模式 m 下的收率;
 H : 大 M 法描述中的大数;
 $DVleft_{l,o}$: 现时订单 l 中产品 o 的剩余需求量;
 RA_o^l : 订单 l 中产品 o 的需求量;
 RS^l : 订单 l 的开始时间;
 RT^l : 订单 l 的到期时间;
 BT_t : 时间段 t 的开始时间;

2) 变量.

$y_{u,m,t}$: 在时间间隔 t 内, 如果装置 u 处于工作模式 m , $y_{u,m,t} = 1$, 否则, $y_{u,m,t} = 0$.
 $INVO_{oc,t}/INVO_{o,t}$: 在时间段 t 结束时, 组分油 oc /产品 o 的库存量;
 $Fu_{u,m,t}$: 时间段 t 内设备 u 在模式 m 时的输入流量;
 $QO_{oc,t}$: 时间内 t 内生产的组分油 oc 流量;
 $D_{l,o,t}$: 时间内 t 内产品 o 供应订单 l 的流量;
 $Foco_{o,t}$: 时间段 t 内用于产品 o 的组分油 oc 的流量;
 $Opro_{o,p,t}$: 时间段 t 内产品 o 物性 p 的超额量;
 $Pout_{oc,t}$: 用于线性化的辅助变量;
 $SA_{o,t}^l$: 指在时间段 t 开始之前, 产品 o (订单 l)已完成的总的供应量;
 $PF_{o,t}^l/EPF_{o,t}^l$: 时间段 t 内, 产品 o (订单 l)的产品流量/使能产品流量;
 $SPF_{o,t}^l/SEPF_{o,t}^l$: 时间段 t 内, 产品 o (订单 l)的综合产品流量/综合使能产品流量.

行初次蒸馏, 将较轻的分馏油分离, 其塔底的重油进入减压塔(vacuum distillation unit, VDU), 以再次分离其中的轻质分馏油; 催化裂化装置(fluid catalytic cracking unit, FCCU)采用化学反应过程将VDU侧线重质油裂解为轻质油, 以增加炼油生产系统中轻质油的收率; 所获得的各类轻质分馏油进入二次提质阶段, 包含醚化装置(ethylene, ETH)、加氢脱离装置(hydrodesulfurization, HDS)、加氢精制装置(hydrorefining unit, HTU) HTU1和HTU2、甲基叔丁基醚生产装置(methyl tert-butyl ether, MTBE)和重整装置(reforming, RF)等. 分馏油(如图1中的常一线、减一线、Lsd(light straight-run diesel), HG(hydrodesulfurization gasoline), Ref(reforming gasoline)和EG(etherified gasoline))等直接进入下游装置而不经储存. 经过提质的分馏油称为组分油. 组分油存储在组分罐中; 炼油生产根据市场需求, 及时调和出所需的产品油. 各生产装置具有不同的操作模式, 在不同操作模式下, 生产装置的侧线收率和运行成本是不同的. 如表2给出装置的操作模式, G代表汽油模式, D代表柴油模式, M代表平和模式, H代表苛刻模式, GD代表汽油-柴油模式, 以此类推. 表中各操作模式后的数字代表该模式在对应装置上的模式编码.

表2 装置的操作模式(模式(代码))

Table 2 Operating modes of production units (mode (code))

ATM/VDU	FCCU/ETH/HDS	HTU1/HTU2
G(0)	GG(0)	M(0)
D(1)	GD(1)	H(1)
	DG(2)	
	DD(3)	

该炼油过程的操作规则包括: 1) 生产装置一次只能在一种模式下运行. 操作模式切换时, 生产装置需经历相应的固定时长的模式过渡过程; 2) FCCU, ETH和HDS等在操作模式切换启动时, 须处于相同的操作模式; 3) 产品的物性指标值应在规定的范围内; 4) 忽略产品混合时间; 5) 每种组分油或最终产品油储存在一个专用的储罐中.

2.2 炼油生产调度问题描述

一般地, 炼油生产调度是在给定客户订单、系统初始状态和操作规则的情况下, 通过调整所有装置在每个时刻的运行模式(离散变量)和进料流量(连续变量), 以及储罐的库存量, 以期达到炼油生产总成本最小的目标. 通常情况下, 炼油生产调度问题的优化目标为最小化生产成本, 包含原材料成本、操作成本、库存成本和缺货成本; 约束包括物料平衡、设备产能限制、产品物性指标限制、订单交货限制和操作规则等^[5-6].

2 炼油生产调度问题描述

2.1 炼油生产工艺描述

炼油是一个连续的生产过程, 如图1所示. 原油进入常压塔装置(atmospheric distillation unit, ATM)进

3 基于预测与分解策略的调度算法

本节首先介绍沿时间轴分解大规模调度问题的基础,即离散时间建模方法;其次,介绍本文所提算法的总体策略和算法的两个主要组成部分,单时间段模型和基于CNN的生产任务预测模型。

3.1 基于离散时间的建模方法

本文采用离散时间建模方法^[36]建立大规模炼油生产过程调度模型。该方法首先根据调度精度需求将整个调度区间划分为若干相等的时间段,其次假定操作只能在时间段的端点处改变,在每个时间段内部,

操作保持不变。例如图2展示了离散时间建模方法所获得的ATM,VDU和FCCU等装置的调度方案。在该方案中,首先,调度时间轴被分为5个时间段,每个时间段包含10个小时。其次,在时间段2内,ATM的进料流量和操作模式分别保持在240 t/h和M2不变;在时间段2的端点处,ATM的操作分别变为300 t/h和M1,并在时间段3内保持不变。基于该建模方法建立具体问题的调度模型,优化求解后可确定每个时间段上的操作,获得调度方案。本文基于该等长时间段的特点,提出了沿时间轴的分解算法,将大规模炼油生产调度问题分解为多个单时间段子问题来求解。

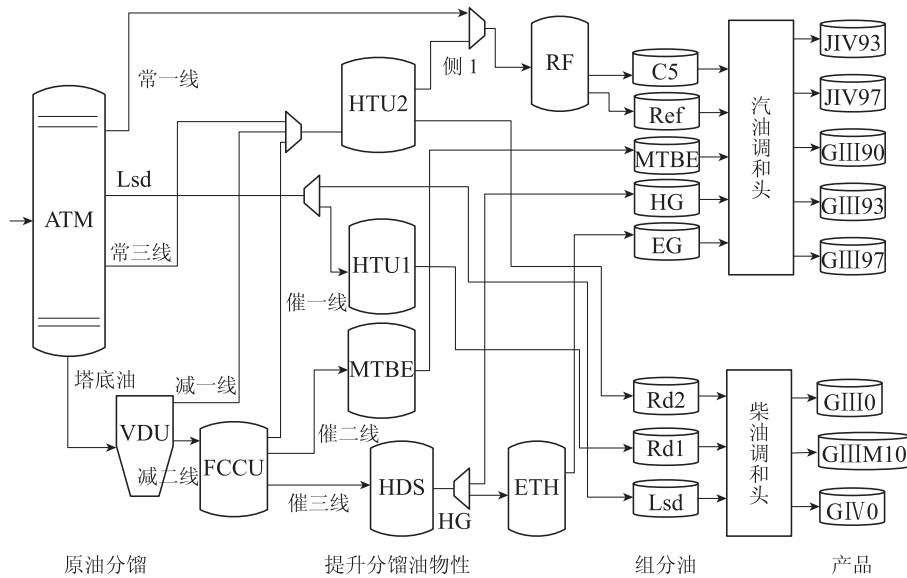


图1 炼油生产系统简化流程图^[36]

Fig. 1 Simplified flow sheet of refinery systems^[36]




图2 炼油生产调度方案的离散时间表达(操作模式: M1/M2/M3, 进料流量: x (t/h) (吨/小时))

Fig. 2 The discrete-time representation of refinery scheduling scheme (operating mode: M1/M2/M3; feeding flowrate:

x t/h)

3.2 总体策略

所提算法的思路如下所述。首先,由于生产调度活动沿时间轴依次进行,因此可以利用离散时间建模方法等长时间段的特性,通过依次求解各个单时间段上的优化问题来求解生产调度问题;其次,对于同一个系统,相同的系统状态(包括内部和外部),对应相同的系统最优操作,因此可以从易于求解的小规模问题的全局最优解中学习单时间段上的操作知识(即生产任务),并将该知识用于快速获得难以求解的大规模问题

的一个满意解。

所提算法的总体策略结构如图3所示,原大规模长周期调度问题为基于离散时间方法建立的模型,因此将原问题按离散时间段分解为若干个子问题。由于时间段等长,每个时间段内的子问题可以采用统一结构的数学模型描述(除了部分输入模型参数不同)。由于子问题的规模较小,其求解时间较短(10^{-1} 秒级),因此原问题可以通过逐个求解子问题的方式在短时间内获得解。由于各个子问题单独求解,其解仅仅具

有局部的最优性. 本文通过给各个子问题分配生产任务来协调各个子问题在整个调度区间内的求解, 使各个子问题的解具有在全局范围内优化的特点. 由于本文忽略产品调合的时间, 因此调度的目标是组分油生产的协调, 即炼油厂可以通过组分油的产量协调整个调度区间内企业的生产. 因此, 将每个时间段上组分油产量作为单时间段上生产任务分配的内容. 为此,

本文构建了一个用于预测组分油产量的模型, 通过子问题的组分油产量尽可能达到其预测值, 使各个子问题协调求解. 另一方面, 由于短周期调度问题易于求得全局最优解, 本文通过短周期调度问题获得大量具有全局最优性的组分油产量分配数据, 用于训练该预测模型. 该方法虽然不能保证获得全局最优解, 但协调后的子问题的解具有在全局范围内优化的特点.

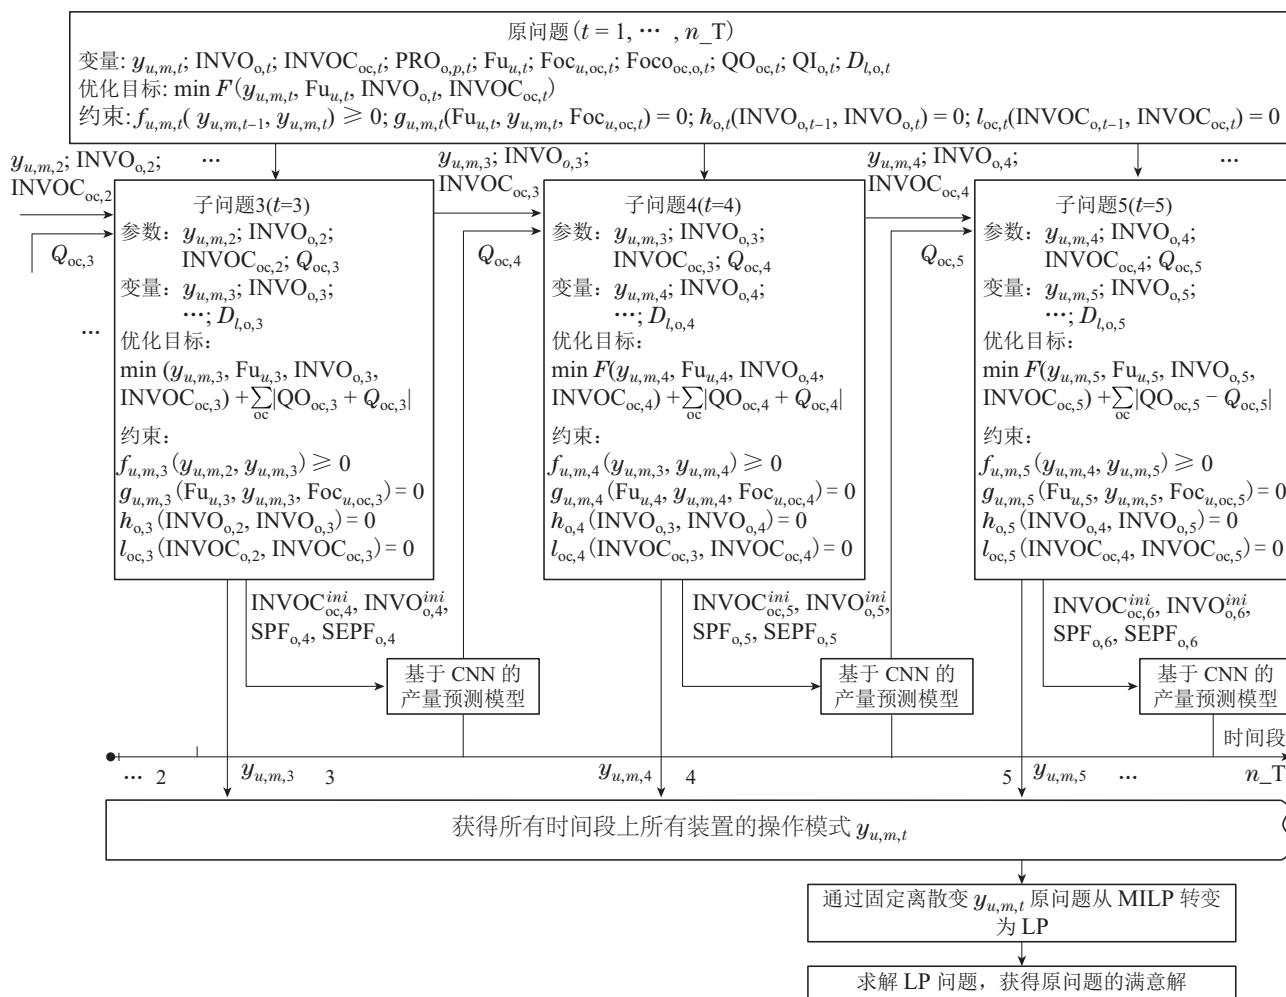


图 3 基于生产任务预测的分解算法的流程图

Fig. 3 Scheme of production task prediction based decomposition algorithm

通过依次求得所有子问题的解, 获得所有时间段上所有装置的操作模式 $y_{u,m,t}$, 从而确定原问题中所有离散变量的值. 原问题从难以求解 MILP 转化为易于求解的线性规划 (linear programming, LP) 问题. 通过求解该 LP 问题可获得原问题的一个满意解.

如上所述, 所提出的 PDA 算法的核心模块为单时间段子问题模型 (第 3.3 节) 和基于 CNN 的任务分配预测模型 (第 3.4 节).

3.3 单时间段子问题建模

在图 3 中, 时间段 t 的单时间段子问题称为子问题 t ($t \in [1, n_T]$). 每个子问题 t 只包含原问题在相应时间段内的变量. 同样, 每个子问题只包含原问题

在相应时间段上的约束. 对于子问题 t 的约束 $f_{u,m,t}(y_{u,m,t-1}, y_{u,m,t}) \geq 0$, 其中 $y_{u,m,t-1}$ 是子问题 t 的已知参数. 参数 $y_{u,m,t-1}$ 的值由子问题 $t-1$ 的解得到. $y_{u,m,t-1}$ 是原问题中的一个变量, 在子问题 t 中则成为一个已知参数. 通过这种方法, 可以处理不同时间段的约束条件, 从而不需要额外的处理就可以得到原问题的可行解. 子问题的目标不仅包含原问题所涉及的项目 (除了订单脱销惩罚), 而且还包含绝对值项 $|QO_{oc,t} - Q_{oc,t}|$, 这表示组分油的产量 $QO_{oc,t}$ 应尽量接近预测产量 $Q_{oc,t}$. $Q_{oc,t}$ 是子问题 t 的参数, 是 CNN 模型在时间段 t 时的输出, 用于协调子问题间的求解. 因此, 每个子问题都有相同的目标和约束, 除了一些

参数(即 $y_{u,m,t}$, $INVOC_{oc,t}$, $INVO_{o,t}$, $Q_{oc,t}$)的不同.

子问题采用离散时间方法建模, 其给定的时间段数量为1. 子问题 t 的输入参数为当前时间段的组分油产量 $Q_{oc,t}$ 、上一个时间段的生产装置操作模式 $y_{u,m,t-1}$ 、上一个时间段的库存量 $INVOC_{oc,t-1}$ 和 $INVO_{o,t-1}$. 其中 $Q_{oc,t}$ 为CNN模型的输出, 其他3个参数为上一个时间段子问题 $t-1$ 的输出. 子问题 t 的优化目标如下:

$$\begin{aligned} \min f = & \\ \min \sum_m (Fu_{1,m,t} PCru) + \sum_u \sum_m (Fu_{u,m,t} POp_{u,m}) + & \\ (PInOC \sum_{oc} INVOC_{oc,t} + PInO \sum_o INVO_{o,t}) + & \\ \sum_{oc} Pout_{oc,t} PD + \sum_o \sum_p Opro_{o,p} + & \\ \sum_l \sum_o (D_{l,o,t} POD \times RT^l). & \quad (1) \end{aligned}$$

在优化目标(1)中, 第1项表示最小化原材料成本; 第2项表示最小化操作成本; 第3项表示最小化库存成本. 前3项同样也是原问题的优化目标项. 单时间段子问题中没有原问题的缺货成本项, 因为在调度周期的中间, 不能判断订单是否缺货; 第4项表示组分油产量的实际值与预测值之间的偏差; 第5项表示最小化所有产品的物性指标超额量($Opro_{o,p}$); 第6项表示当两个订单都需要某一产品时, 提前到期的先供应.

子问题 t 的约束条件主要包括物料平衡、产能限制、订单供应和组分油生产约束等.

1) 装置进料流量约束.

$$\begin{aligned} y_{u,m,t} Fu_u^{\min} \leq Fu_{u,m,t} \leq y_{u,m,t} Fu_u^{\max} \\ u \in U, m \in M_u, \quad (2) \end{aligned}$$

式(2)描述了在当前时间段 t 中, 当装置 u 处于操作模式 m 时, 即 $y_{u,m,t} = 1$ 时, 则该模式下装置的进料流量 $Fu_{u,m,t}$ 为非零值; 否则, 当 $y_{u,m,t} = 0$ 时, $Fu_{u,m,t}$ 为零.

2) 生产装置间的物料平衡.

$$\begin{aligned} \sum_{m \in M_u} Fu_{u,m,t} = \\ \sum_{m \in M_{u'}} \sum_{u' \in U_u} \sum_{s \in S_{u,u'}} Fu_{u',m,t} YM_{u',m,s}, \forall u \in U, \quad (3) \end{aligned}$$

式(3)表示互连装置间的物料守恒.

3) 组分罐物料平衡.

$$\begin{aligned} INVOC_{oc,t} = \\ INVOC_{oc,t-1} + \sum_{m \in M_u} \sum_{u \in U_{oc}} \sum_{s \in S_{u,oc}} Fu_{u,m,t} YM_{u,m,s} - \\ \sum_o Foco_{oc,o,t}, \forall oc \in OC, \quad (4) \end{aligned}$$

式(4)描述了组分油 oc 的库存等于初始库存加上在该时间段 t 上的输入量, 减去用于调和产品的输出量. 其中, $INVOC_{oc,t-1}$ 是子问题 t 的组分油 oc 初始库存量,

等于子问题 $t-1$ 求得的库存量.

4) 产品调和约束.

$$\begin{aligned} \sum_{oc \in gOC} PRO_{oc,p} Foco_{oc,o,t} \geq PRO_{o,p}^{\min} \sum_{oc \in gOC} Foco_{oc,o,t}, \\ o \in gO, p \in gP, \quad (5) \end{aligned}$$

$$\begin{aligned} \sum_{oc \in gOC} PRO_{oc,p} Foco_{oc,o,t} - PRO_{o,p}^{\min} \sum_{oc \in gOC} Foco_{oc,o,t} \leq \\ Opro_{o,p}, \forall o \in gO, p \in gP, \quad (6) \end{aligned}$$

$$\begin{aligned} \sum_{oc \in gOC} PRO_{oc,p} Foco_{oc,o,t} \leq PRO_{o,p}^{\max} \sum_{oc \in gOC} Foco_{oc,o,t}, \\ o \in gO, p \in gP, \quad (7) \end{aligned}$$

$$\begin{aligned} PRO_{o,p}^{\max} \sum_{oc \in gOC} Foco_{oc,o,t} - \sum_{oc \in gOC} PRO_{oc,p} Foco_{oc,o,t} \leq \\ Opro_{o,p}, \forall o \in gO, p \in gP, \quad (8) \end{aligned}$$

$$\begin{aligned} r_{oc,o}^{\min} \sum_{oc \in gOC} Foco_{oc,o,t} \leq Foco_{oc,o,t} \leq \\ r_{oc,o}^{\max} \sum_{oc \in gOC} Foco_{oc,o,t}, \forall o \in gO, oc \in gOC, \quad (9) \end{aligned}$$

式(5)–(8)为汽油辛烷值(RON)、硫含量和倾点因子3个指标的上下限约束. 柴油具有类似的物性约束描述, 此处省略. 其中, $Opro_{o,p}$ 为产品物性指标的盈余量, 在目标函数中作为惩罚项, 以获得最小盈余. 式(9)描述了组分油在相应产品中的百分比限制.

5) 产品罐物料平衡.

$$\begin{aligned} INVO_{o,t} = \\ INVO_{o,t-1} + \sum_{oc \in OC} Foco_{oc,o,t} - \sum_{l \in Order} D_{o,l,t}, \\ \forall o \in gO, \quad (10) \end{aligned}$$

式(10)为产品罐的质量平衡. $INVO_{o,t-1}$ 表示子问题 t 的产品 o 初始的库存量, 等于子问题 $t-1$ 结束时产品罐 o 的库存量.

6) 订单供应约束.

$$D_{l,o,t} \leq DVleft_{l,o}, \quad \forall o \in O, l \in Order, \quad (11)$$

$$D_{l,o,t} \leq DS_{l,t} FOoutMax, \quad \forall o \in O, l \in Order. \quad (12)$$

式(11)描述系统供给订单的量必须在订单的剩余需求范围内. 式(12)描述对订单的供应必须在订单允许的期限内.

7) 操作模式限制.

$$\sum_{m \in M_u} y_{u,m,t} = 1, \quad \forall u \in U, \quad (13)$$

$$\begin{aligned} y_{Fccu,m,t} \geq y_{Eth,m,t-1} (1 - B_{Fccu,t}) - B_{Fccu,t} H, \\ m \in M_{Fccu}, \quad (14) \end{aligned}$$

$$\begin{aligned} y_{Fccu,m,t} \leq y_{Eth,m,t-1} (1 - B_{Fccu,t}) + B_{Fccu,t} H, \\ m \in M_{Fccu}. \quad (15) \end{aligned}$$

式(13)表示装置在一个时间段内只能运行一种模式. 式(14)–(15)描述了FCCU装置和ETH装置的模式转换过程必须从同一模式开始.

8) 不同时间段之间的操作规则约束.

$$y_{u,m,t} \geq y_{u,m,t-1}B_{u,t} - H(1 - B_{u,t}),$$

$$\forall u \in U, m \in M_u, \quad (16)$$

$$y_{u,m,t} \leq y_{u,m,t-1}B_{u,t} + H(1 - B_{u,t}),$$

$$\forall u \in U, m \in M_u, \quad (17)$$

式中 $y_{u,m,t-1}$ 是子问题 t 的参数. 式(16)–(17)为装置 u 在模式转换过程中, 当前时间段 t 的操作模式 $y_{u,m,t}$ 必须与以前时间段的操作模式 $y_{u,m,t-1}$ 相同. $B_{u,t}$ 是子问题 t 的参数, 其值取决于操作模式 $y_{u,m,t-2}$ 和 $y_{u,m,t-1}$, 即前后模式相同则不存在切换, 若不同则发生切换. $B_{u,t}$ 在每个子模型求解前确定, 不属于子模型求解的一部分, 它是多个0–1变量间逻辑关系的判断. H 是大 M 法中的大数(在本文案例中的取值为10).

9) 组分油产量控制.

为了使变量 $QO_{oc,t}$ 尽可能接近其预测值 $Q_{oc,t}$, 目标函数中产生了绝对值项, 即 $|QO_{oc,t} - Q_{oc,t}|$. 本文给出了一种线性化方法: 增设一个辅助变量 $Pout_{oc,t} \geq 0$, 则

$$\min \sum_{oc} |QO_{oc,t} - Q_{oc,t}|, \quad (18)$$

$$QO_{oc,t} \geq 0, Q_{oc,t} \geq 0, \forall oc \in OC, \quad (19)$$

可以表示为

$$\min \sum_{oc} Pout_{oc,t}, \quad (20)$$

$$|QO_{oc,t} - Q_{oc,t}| \leq Pout_{oc,t}, \forall oc \in OC, \quad (21)$$

$$QO_{oc,t} \geq 0, Q_{oc,t} \geq 0, Pout_{oc,t} \geq 0, \\ oc \in OC, \quad (22)$$

非线性式(21)可以线性化如下:

$$QO_{oc,t} - Pout_{oc,t} \leq Q_{oc,t}, \forall oc \in OC, \quad (23)$$

$$QO_{oc,t} + Pout_{oc,t} \geq Q_{oc,t}, \forall oc \in OC, \quad (24)$$

因此, 单时间段子问题的目标函数变为

$$\min f = \\ \min \sum_m (Fu_{1,m,t}PCru) + \sum_u \sum_m (Fu_{u,m,t}POp_{u,m}) + \\ (PInOC \sum_{oc} INVOC_{oc,t} + PInO \sum_o INVO_{o,t}) + \\ \sum_{oc} Pout_{oc,t}PD + \sum_o \sum_p Opro_{o,p} + \\ \sum_t \sum_o (D_{l,o,t}POD \times RT^l). \quad (25)$$

最后, 子问题的目标为式(25), 约束式包括式(1)–(17)(23)–(24).

子问题 t 的主要输出如下:

- 1) 时间段 t 上所有生产装置的操作模式($y_{u,m,t}$);
- 2) 时间段 t 上所有组分油罐($INVOC_{oc,t}$)以及所

有产品油罐($INVO_{o,t}$)的库存量;

3) 时间段 t 向每个订单的供货量($D_{l,o,t}$).

根据当前时间段子问题 t 的输出可以确定下一个时间段 $t + 1$ 的系统状态, 并以此为输入, 通过CNN模型预测时间段 $t + 1$ 的子模型的关键参数, 即组分油产量 $Q_{oc,t+1}$, 它用于协调下一个时间段的生产. 在下一节中, 将介绍 $Q_{oc,t}$ 的预测过程.

3.4 基于CNN的组分油产量预测模型

在本节中, 首先说明使用CNN结构的原因, 然后详细说明CNN模型的输入, 以及为了实现知识迁移而提出的产品流量的相关定义, 最后总结CNN模型训练数据的结构及分析其可行性.

3.4.1 炼油生产过程系统状态的特点

订单信息是系统状态的重要组成部分. 如图4中的两个不同订单案例. 每个案例有4个订单. 假设每个订单只包含一种产品. 所有订单中产品的需求量和它的供应区间长度是相同的, 唯一的区别是供应区间的位置不同. 从图4可以看出, 该差异导致系统最优产量的显著变化, 即从(10,10,10,10)到(0,40,0,0). 因此, 可以发现, 系统操作不仅取决于订单本身的信息(横向信息), 还与不同订单之间的相对位置信息(纵向信息)有很大关系. 由此可见, 影响系统操作的订单信息具有二维特征, 因此利用CNN结构建立组分油产量预测模型.




图 4 仅由订单相对位置的不同所引起的系统操作的差异
Fig. 4 The different relative positions of orders cause the changes of system operations

3.4.2 CNN模型的输入

CNN模型的输入是当前系统状态信息, 输出为组分油产量. 由于CNN模型将从许多小规模(较短的调度时长)案例的全局最优解中学习关于组分油产量分配的知识, 并将其应用于大规模(较长调度时长)的问

题中. 因此, 知识需要在具有不同调度时长和订单信息的问题之间转移. 然而, 原始的订单信息无法完成知识转移的任务, 因此, 本节首先给出描述订单信息的一些基本概念定义, 然后描述当前系统状态和未来系统状态. 最后给出由这二者构成的系统状态描述.

1) 产品流量定义.

这里的产品指订单中的产品, 而非生产系统的产品. 一般来说, 在炼油调度问题的描述中, 系统状态的两个主要部分是库存信息和订单信息. 库存信息可以用它的原始数据来描述, 因为它有一个上限, 即储罐的容量上限. 订单信息包括订单数量(n_L)、订单(l)中产品(o)的需求量(RA_o^l)以及订单的供应期限[RS^l , RT^l]. 这三者的组合称为原始订单信息. 如果使用原始订单信息来表示, 则 RA_o^l 和 RT^l 在训练数据中通常值较小, 因为它是由小规模案例生成的; 在预测数据(由大规模案例产生的)中 RA_o^l 和 RT^l 则相对较大, 这意味着预测数据的值总是超出训练数据的范围. 因此, 利用原始订单信息进行预测的精度必然很低.

为了解决该问题, 本文采用了产品流量的概念^[28], 即在给定的时间段 t 内, 产品 o (订单 l)的剩余需求量与该产品的剩余时间的比值称为产品 o (订单 l)的产品流量, 记为 $PF_{o,t}^l$. $PF_{o,t}^l$ 计算公式如下:

$$PF_{o,t}^l = \frac{RT_o^l - SA_{o,t}^l}{RT^l - BT_t}, \quad o \in O, l \in \text{Order}, t \in T, \quad (26)$$

$$SA_{o,t}^l = \sum_{t'=1}^{t-1} D_{l,o,t'}, \quad o \in O, l \in \text{Order}, t \in T, \quad (27)$$

其中 t 指任意给定的时间段.

在订单需求合理的情况下, 无论调度周期多长, 订单的产品流量将始终在系统生产能力范围内. 这样, 系统环境状态的知识就可以在不同的调度时长的案例间迁移.

2) 使能产品流量.

使能产品流量(记为 $EPF_{o,t}^l$)描述产品是否可以在某个时间段内供应. 其定义如下:

$$EPF_{o,t}^l = \begin{cases} PF_{o,t}^l, & \text{若产品可在时间段} t \text{ 供应,} \\ 0, & \text{若产品不可在时间段} t \text{ 供应.} \end{cases} \quad (28)$$

3) 综合产品流量.

由于订单数量也随着调度周期的增加而增加, 为了消除订单数量这一因素, 将所有订单的相同产品的产品流量合成系统的综合产品流量, 记为 $SPF_{t,o}$, 即

$$SPF_{o,t} = \sum_l PF_{o,t}^l, \quad o \in O, l \in \text{Order}, t \in T. \quad (29)$$

4) 综合使能产品流量.

类似于 $SPF_{t,o}$, 综合使能产品流量(记为

$SEPF_{t,o}$)描述如下:

$$SEPF_{o,t} = \sum_l EPF_{o,t}^l, \quad o \in O, l \in \text{Order}, t \in T. \quad (30)$$

5) 当前与未来系统状态.

某一时间段的当前系统状态由两部分组成: 库存状态和订单状态, 如图5所示. 库存状态由库存量数据表示.

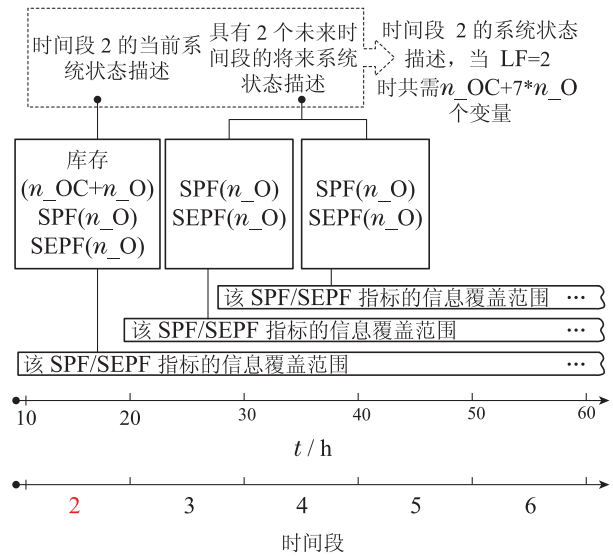


图5 时间段2的系统状态表达, 由当前系统状态和未来系统状态组成, 其中, $LF=2$. 括号内的参数代表指标所需的变量个数

Fig. 5 The representation of system state of slot 2 by current system state and future system state with $LF=2$. The parameters in brackets mean the number of variables used to represent the corresponding index

为了提高某一时间段内生产任务的预测精度, 采用相对于该时间段的多个未来时间段的未来系统状态, 来辅助描述该时间段的系统状态. 参数 LF 指涉及的未来时间段的数量, 如图5所示. 未来系统状态的描述仅采用未来时间段上的产品流量, 而不包含未来时间段上的库存状态.

在计算 $PF_{o,t}^l$ 时, 需要明确在时间段 t 开始前, 订单 l 中的产品 o 已完成的供应量 $SA_{o,t}^l$. 但当给定的时间段 t 是未来的时间段时, 产品供应还未实现, 因此 $SA_{o,t}^l$ 是未知的. 为此, 对未来时间段, 本文假设在所描述的当前时间段上, 产品的剩余需求量在其允许的未来时间段内是均衡供应的. 基于这个假设, 可以计算出未来时间段中的产品流量.

6) 系统状态.

时间段 t 的系统状态由两部分组成: 当前系统状态($INVO_{o,t}^{ini}$, $INVOC_{oc,t}^{ini}$, $SEPF_{o,t}$, $SPF_{o,t}$)和 LF 个未来系统状态($(SPF_{o,t+1}, SEPF_{o,t+1}), \dots, (SPF_{o,t+LF}, SEPF_{o,t+LF})$). 其中 $INVOC_{oc,t}^{ini}$ ($INVO_{o,t}^{ini}$)

由 $n_{OC}(n_O)$ 个变量描述. $SPF_{o,t}$ (或 $SEPF_{o,t}$) 由 n_O 个变量描述. 因此, 时间段 t 的系统状态由 $n_{OC} + n_O + (LF + 1) \times 2 \times n_O$ 个变量描述. 以图5中的时间段2为例, 其中 $LF = 2$, 时间段2的系统状态包括 $n_{OC} + 7 \times n_O$ 个变量.

由于订单信息的二维性质, 本文将系统状态重新排列成一个矩阵. 变量 $SPF_{o,t}$ 和 $SEPF_{o,t}$ 分别位于两个不同的通道中. 例如, 当 $n_O = 8, n_{OC} = 10$ 和 $LF = 9$ 时, CNN模型的输入数据的形状如图6所示, 其中 $\text{ceil}(\cdot)$ 函数指向上取整. 需要注意的是, 两个通道的库存数据是相同的. 虚拟组分油储罐仅做占位使用. CNN网络结构如图7所示, 该结构包含3类卷积核, 第1类用于获取系统的整体信息, 因此其卷积核尺寸与通道尺寸一致; 第2类用于获得不同产品油需求量的对比信息; 第3类用于获得产品油本身的需求信息. 输出为所有组分油的产量, 即一个 n_{OC} 维的向量.

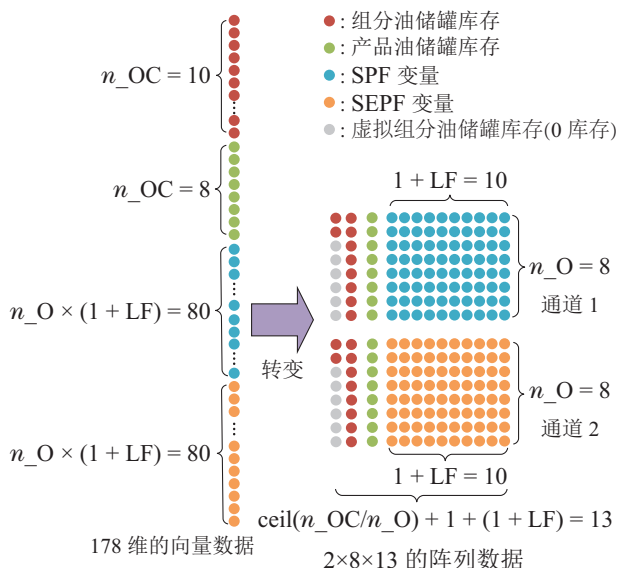


图6 将输入数据从向量形式转化为矩阵形式

Fig. 6 The input data is rearranged from a vector into a tensor




图7 基于订单信息的产品流量表达的炼油生产调度问题的CNN结构

Fig. 7 A tailored CNN structure for refinery scheduling problem with product flowrate representation of order information

3.4.3 训练数据

训练数据的特征为 $INVO_{o,t}^{ini}, INVOC_{oc,t}^{ini}, SPF_{o,t}, SEPF_{o,t}, \dots, SPF_{o,t+LF}, SEPF_{o,t+LF}$, 标签为变量 $Q_{oc,t}$. 这些变量的每个下标 t 构成了一个具体的完整样本. 随机生成 N 个具有 K 个时间段的原问题或其简化问题的小规模案例, 求解这些案例后可获得 $N \times K$ 个训练样本.

3.4.4 组分油产量预测的可行性分析

由产品流量的定义可知, 在每个当前时间段, 系统订单状态都是由其对应的整个未来时间段上的订单量所决定, 如图5所示, 描述系统订单信息的指标具有全局特性, 即包含未来整个调度时间轴的信息, 因此, 在每个时间段上可以获得具有全局优化性的操作. 另一方面, 每个时间段上的组分油产量分配知识是通过易于获得全局最优解的小规模案例学习获得, 因此分配知识具有全局优化性. 最后, 时间因素导致不同调度时长的订单信息无法统一数据值范围. 通过产品流量概念, 订单信息中调度时长因素被消除, 操作知识实现了小规模到大规模的转移.

4 实验研究

本节首先验证CNN结构的预测性能, 其次验证其在小规模案例下解的精确性, 最后在大规模案例下, 比较 PDA 与 Cplex 和现有算法 DPSO^[24] 和 KTA^[28] 的性能. 所有案例均使用 Intel Core i7-3770 CPU @ 3.40 GHz 3.40 GHz 32 GB 计算机, 采用 Windows 7 系统上的 Python 2.7 平台 paddle-paddle 1.8.4 深度学习包和 Cplex 12.6.0 求解器求解.

4.1 参数设置

本案例研究中所考虑的炼油生产系统如图1所示. 本文案例的调度时长采用与文献[28]相同的调度区间规模, 最大为200个时间段的大规模案例. 目前其他文献中最大的调度区间为30个时间段^[24]. 生产系统中组分油 (n_{OC})、产品 (n_O) 以及多模式装置 (n_{Unit}) 的数量分别为8, 8和5. 为了得到更详细的调度方案, 本文将离散时间段长度设为1 h. 在CNN预测模型中, 输入数据的维度为 $2 \times 8 \times 12$, 输出数据的维度为8. CNN模型的结构如下, 卷积核类型有7种, 大小分别为 $8 \times 12, 8 \times 1, 8 \times 3, 8 \times 5, 1 \times 3, 1 \times 4$ 和 1×5 . 这些卷积核的数目分别是100, 50, 50, 50, 50, 50和50. 所有池化层的大小为 1×1 , 所有池化层的步长为1. 随后是两个全连接层, 其分别含有100和50个隐层节点. CNN模型的训练数据由完整周期调度模型随机生成的4600个案例产生. 每个案例具有15个时间段(即每个案例包含15个样本). 所有案例均由Cplex求解器求解, 停止准则为相对间隙小于某个小值(例如0.001)或求解时间超过120 s. 前4000个案例的样本用于训练, 后400个的用于验证, 最后200个的用于测试. 训练

的目标函数为均方根误差,选择学习率为0.001的Adam优化器.

4.2 CNN模型的预测精度

本文采用单隐层神经网络(single hidden-layer algorithm, SDA)与本文设计的CNN模型做预测精度对比. SDA的输入维度为 $n_{OC}+n_O+(LF+1)\times 2\times n_O$,其中LF的取值为9,即SDA的输入维度是176,输出维度为 n_{OC} ,即8.对SDA设置3种具有不同隐藏层神经元数量(即120,80和50)的模型结构,相应的模型分别记为SDA120,SDA80和SDA50.它们的训练数据和优化器参数与PDA相同,且训练同样的轮数.从测试数据集中随机选取100个数据进行测试.结果如图8所示.由于测试样本的标签是一个8维向量,因此取标签数据的平均绝对值误差,即图7的垂直轴数值为 $\sigma = \sum_i |x_i - e_i|/8$,其中 x 是预测数据, e 是真实的数据.为提高预测精度将预测数据归一化处理.从图8可以看出,CNN模型的精度要优于SDA模型.




图8 4种不同网络结构的预测精度的比较

Fig. 8 The comparison of prediction accuracy of four different network structures

4.3 小规模案例的求解

PDA在小规模案例中没有明显的求解优势,在本小节中,主要研究在小规模案例中PDA的求解精度.计算结果如表3所示,其中共有3种调度长度,分别为13,15和17个时间段.每种调度时长包含3个具有不同订单数量的案例.案例1,4和7的订单需求较小,案例2,5和8的订单需求量中等,案例3,6和9的订单需求量较大.

表3 PDA, Cplex和随机求解在小规模问题上的比较

Table 3 Small-scale problem results comparison of PDA, Cplex, and Random solution

时间段数量	案例	PDA		Cplex			100个随机解		
		目标值	时间/s	目标值	时间/s	Gap/%	均值	最小值	最大值
13	1	1207197	1.3	1145122	3	5.7	1368054	1218413	1572161
				1142121	3600	2.3			
	2	1551771	1	1545207	3	28.3			
15	3			1539484	3600	1.9	2830496	1861310	4064548
		5058794	1.2	5058794	425	2.2			
			5058794	510	0				
17	4			1327869	5	6.3	1432593	1330439	1574731
				1324839	3600	4.4			
	5	1751749	1.5	1751661	15	14.7			
17	6			1749042	3600	4.6	2640373	1901051	3850919
		3925768	1.5	3893103	250	14.7			
			3885210	3600	0.03				
17	7			1564808	5	10.1	1750612	1575179	1889627
				1560647	3600	8.4			
	8	1999840	1.4	1864196	3	22.5			
17	9			1855521	3600	2.1	2751048	2188611	3909781
		2095563	1.6	2055603	3	29.1			
			2021465	3600	5.5				

虽然最优操作的知识是由15个时间段的案例产生的,但该最优操作知识针对一个时间段,因此,它可以用来解决任意调度长度的问题.

在表3中,针对每个案例产生100个随机解.在每个案例中,最好的随机解都比PDA的解要差.在具有3个订单的案例中(即案例1,4和7),由于订单需求量较小,这些案例的订单通过最小的原油进料流量即可完成,

意味着这些案例的原油成本基本相同,且不存在缺货惩罚.在目标函数中,原油成本和订单缺货惩罚是两个主要部分.因此,订单需求小的案例的目标值会彼此接近,意味着在这类型的案例中要找到优势明显的解比较困难.然而,PDA在这类案例中得到的解仍然比通过随机求解得到的最好解要好.在所有案例中,PDA算法的求解时间均小于2s,且得到的解接近

Cplex运行1 h后的解. 特别是在案例3中, 用PDA方法得到了最优解, 这表明从小规模问题中提取的操作知识可以将大规模问题的解引导到它们的最优解空间.

图9中给出了Cplex, PDA和随机求解3种求解方法在小规模案例上获得的详细调度方案(仅显示装置操作模式的执行方案). 在第1个时间段内, 由于初始系统环境相同, PDA获得了与Cplex相同的操作. 然而, 由于PDA的求解过程涉及CNN模型的预测误差和包含经验规则的单时间段子模型的求解, 因此, PDA的解逐渐偏离最优解, 如图9所示. 尽管如此, 在每个时间段中, PDA总是能为当前的时间段找到一个较好的操作, 最终找到一个较好的解决整个调度区间的方案.

4.4 大规模案例的求解

在本小节中, 通过几个大规模的案例说明PDA的求解效率. 由于现有的大多数分解算法对调度问题进行空间分解, 因此, 当调度时长进一步扩大时, 空间分解方法所得子问题仍然会发生组合爆炸, 导致空间分解算法在大规模长周期情况下的求解性能必然较差. 因此, 这里仅使用商业解算器Cplex和现有文献中的算法KTA(knowledge transfer algorithm)^[28]、DPSO(discrete particle swarm optimization)^[24]进行比较. 比较算法均以运行时间作为停止准则, 其详细的设置情况见表4. 由于停止标准为算法运行时间, 因此DPSO的种群规模设定为固定值20. DPSO的其他参数设置与文献[24]相同. KTA是一种基于知识迁移的启发式方

法, 其参数设置与文献[24]相同.

本文在本节中共设置了9种调度长度, 从50到200. 为了更好地说明所提出的PDA的性能, 针对每种调度长度设计了3种订单需求, 分别对应小、中和大. 由于篇幅限制, 本节部分案例的模型规模统计见表4所示.

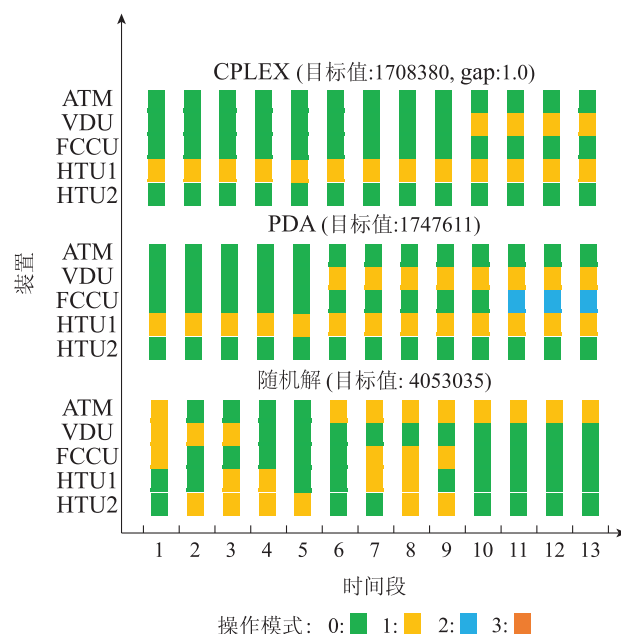


图 9 Cplex, PDA和随机求解的调度结果比较
Fig. 9 Comparison of the solutions of Cplex, PDA, and random solving

表 4 Cplex软件约简后的部分大规模案例的模型规模

Table 4 The reduced model sizes of some large-scale cases by Cplex

时间段数量	案例	约束数量	变量数量	离散变量数量	系数矩阵非0值数量
50	1	23126	14258	2504	70248
	2	23126	14538	2504	70808
	3	23150	14522	2504	70776
120	10	56644	41660	6144	185602
	11	56652	41484	6144	185250
	12	56660	41500	6144	185282
200	25	94812	66892	10304	305266
	26	94828	63404	10304	298290
	27	94852	64492	10304	300466

大规模案例的实验结果如表5所示. 表5中的差距由以下公式定义:

$$Gap = \frac{\text{solution} - \text{lowerbound}}{\text{solution}} \times 100\%. \quad (31)$$

间隙值Ga由Cplex给出. 式(31)中: solution指Cplex找到的当前最佳可行解, lowerbound指最优解的下界(对于极小化问题而言). Gap可以意味着解决方案有多好, 但并不代表解决方案有多坏.

对于采用传统数学方法的Cplex求解器, 从表4可

以看出, 当Cplex运行1 h, 在所有案例中, Cplex的解都差于PDA. 在所提的PDA方法中, 每个时间段的系统状态是包含整个调度周期内的信息的. 然而, 它仅仅由当前时间段和未来9个时间段的产品流量来描述的(如图4所示, 产品流量表示的信息范围是整个未来调度区间). 因此, 随着调度范围的扩大, 它表示精度有所下降, 导致PDA的性能下降. 同样, Cplex的性能也随着调度范围的增加而急剧下降. 尽管如此, 在大规模案例中, 所提出的PDA的性能要优于Cplex.

表5 PDA, KTA, Cplex和DPSO在大规模问题上的比较

Table 5 Result comparisons of PDA, KTA, Cplex and DPSO in large-scale problems

时间段数	案例	PDA		KTA		Cplex			DPSO (运行10次)	
		目标值	运行时间/s	目标值	运行时间/s	目标值	运行时间/s	Gap/%	均值	运行时间/s
50	1	4675492	6.5	4723711	9.7	4854782 4718517	3600 10800	13.8 11.3	4723756	100
	2	5542057	6.5	5533976	9.9	5681813 5565598	3600 10800	25.8 24.2	5579710	100
	3	6045812	7.7	6322416	10	7420069 7409255	3600 10800	40.5 37.9	7989362	100
70	4	7670199	9.1	7858674	12.6	7877157 7813005	3600 10800	24.5 22.6	7711694	140
	5	9303829	8.2	9392308	12.8	12489819 11424821	3600 10800	51.1 47.1	10397997	140
	6	8793371	9.6	7938448	13.2	10190385 8473354	3600 10800	42.7 25.9	8644784	140
100	7	10153147	13.6	10423449	21.9	10169900 9838196	3600 10800	19.2 15.9	10504983	200
	8	12014779	15.8	12151354	21.1	17362700 12934745	3600 10800	50.7 33.8	13378985	200
	9	12951232	14.1	15266410	21.6	33843168 28542155	3600 10800	74.7 70.1	17894629	200
120	10	15821153	15.5	15959069	24.1	16045809 16010601	3600 10800	37.9 37.7	15964259	260
	11	15526665	15.2	16289536	24.1	50544834 50544785	3600 10800	79.8 79.7	27525683	260
	12	15623251	14.7	18779604	24.3	50569701 50556239	3600 10800	79.7 79.5	28671115	260
140	13	16794608	15.3	16857378	28.6	41365956 41237900	3600 10800	71.4 71.3	20087710	320
	14	16557377	15.4	16612104	28.6	43942737 43743654	3600 10800	73.1 72.8	19577124	320
	15	17169750	16.4	17422713	28.9	43436783 41529366	3600 10800	72.5 71.2	25351892	320
160	16	17764745	18.8	18669299	32.8	20355035 18224859	3600 10800	34.1 26.2	17832990	380
	17	18490427	19.5	18910125	32.9	20371486 20102595	3600 10800	35.7 34	18759586	380
	18	19174377	19.6	19337311	35.3	21085578 20965329	3600 10800	36 35.4	19517243	380
180	19	18221512	21.2	18517840	39.5	20939038 20939038	3600 10800	28.6 28.6	18221597	440
	20	18610535	21.4	18615858	36.7	21626378 21563215	3600 10800	30.8 29.9	18701721	440
	21	24744501	21.8	24971814	37.6	47907988 36072802	3600 10800	63.9 52.1	27586063	440
190	22	18389803	23.3	19998096	39.5	21190300 21189809	3600 10800	25.9 25.7	18582118	470
	23	25190782	22.9	27131762	39.6	27187702 27187656	3600 10800	33.4 33.4	27245197	470
	24	25336446	22.4	25673649	39.9	39022398 33029486	3600 10800	53.7 45.3	25599338	470
200	25	18695749	24.9	19209830	42.3	21059621 21059621	3600 10800	21.5 21.5	18765369	500
	26	25007387	30.6	25255777	43	26796645 26782050	3600 10800	31.2 31	25330368	500
	27	26285143	25.7	32608939	43.3	109296000 98153797	3600 10800	84.5 82.6	30986128	500

对于进化算法DPSO, 由于它是一种随机方法, 本文对每个案例运行10次, 主要考察每个案例解的平均值. 由于搜索空间随模型大小呈指数增长, 在给定时间内, DPSO生成的所有案例解的平均值都比PDA差, 如表4所示. 因此, 在大规模问题中, DPSO的性能比PDA差. KTA算法本质上是案例推理, 使得其泛化能力较采用了CNN模型的PDA算法要差.

5 结论与展望

本文根据离散时间建模方法的等长时间段的特点, 针对大型长周期炼油生产调度问题, 提出了一种基于预测和分解策略的调度算法, 使得问题能在较短的时间内获得满意解. 通过与商用求解器Cplex、现有算法KTA、DPSO的对比实验表明, 所提算法可以在30 s内获得比Cplex运行1 h得到的解更好, 同时也优于现有算法KTA和DPSO. 在大规模问题求解上, 进化算法和数学规划方法都存在组合爆炸问题, 而本文所提的算法属于启发式方法, 是当前快速求解大规模问题的有效方法.

近年来, 强化学习算法在训练决策器方面具有很好的性能, 而所提方法本质上是提出了一个单时间段调度决策器. 因此, 可以将该决策器视为一个用于调度的智能体, 置于强化学习框架下, 对其决策性能进行进一步优化. 未来将对这一方面的工作做进一步研究.

参考文献:

- [1] CHAI Tianyou. Development directions of industrial artificial intelligence. *Acta Automatica Sinica*, 2020, 46(10): 2005 – 2012. (柴天佑. 工业人工智能发展方向. *自动化学报*, 2020, 46(10): 2005 – 2012.)
- [2] QIAN Feng, DU Wenli, ZHONG Weimin, et al. Problems and challenges of smart optimization manufacturing in petrochemical industries. *Acta Automatica Sinica*, 2017, 43(6): 893 – 901. (钱锋, 杜文莉, 钟伟民, 等. 石油和化工行业智能优化制造若干问题及挑战. *自动化学报*, 2017, 43(6): 893 – 901.)
- [3] GROSSMANN I. Enterprise-wide optimization: A new frontier in process systems engineering. *AIChE Journal*, 2005, 51(7): 1846 – 1857.
- [4] DING Jinliang, YANG Cuie, CHEN Yuandong, et al. Research progress and prospects of intelligent optimization decision making in complex industrial process. *Acta Automatica Sinica*, 2018, 44(11): 1931 – 1943. (丁进良, 杨翠娥, 陈远东, 等. 复杂工业过程智能优化决策系统的现状与展望. *自动化学报*, 2018, 44(11): 1931 – 1943.)
- [5] SHI L, JIANG Y, WANG L, et al. Efficient lagrangian decomposition approach for solving refinery production scheduling problems involving operational transitions of mode switching. *Industrial & Engineering Chemistry Research*, 2015, 54(25): 6508 – 6526.
- [6] MOURET S, GROSSMANN I E, PESTIAUX P. A new Lagrangian decomposition approach applied to the integration of refinery planning and crudeoil scheduling. *Computers & Chemical Engineering*, 2011, 35(12): 2750 – 2766.
- [7] SHAH N K, SAHAY N, IERAPETRITOU M G. Efficient decomposition approach for large-scale refinery scheduling. *Industrial & Engineering Chemistry Research*, 2015, 54(41): 9964 – 9991.
- [8] SUN X, LUH P B, BRAGIN M A, et al. A Novel decomposition and coordination approach for large day-ahead unit commitment with combined cycle units. *IEEE Transactions on Power System*, 2018, 33(5): 5297 – 5308.
- [9] YAN B, LUN P B, LITVINOV E, et al. A systematical approach to tighten unit commitment formulations. *IEEE Power & Energy Society General Meeting*. Portland, USA: IEEE, 2018, 1 – 5.
- [10] WANG K, LUO H, LIU F, et al. Permutation flow shop scheduling with batch delivery to multiple customers in supply chains. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2018, 48(10): 1826 – 1837.
- [11] PANWALKAR S S, KOULAMAS C. Analysis of flow shop scheduling anomalies. *European Journal of Operational Research*, 2019, 280(1): 25 – 33.
- [12] SCHALLER J, VALENTE JMS. Minimizing total earliness and tardiness in a nowait flow shop. *International Journal of Production Economics*, 2020, 224: 107542.
- [13] YU S, CHAI T, TANG Y. An effective heuristic rescheduling method for steelmaking and continuous casting production process with multirefining modes. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, 46(12): 1675 – 1688.
- [14] CUI H, LUO X. An improved Lagrangian relaxation approach to scheduling steelmaking-continuous casting process. *Computers & Chemical Engineering*, 2017, 106: 133–146.
- [15] MAO K, PAN Q K, PANG X, et al. An effective Lagrangian relaxation approach for rescheduling a steelmaking-continuous casting process. *Control Engineering Practice*, 2014, 30: 67 – 77.
- [16] MAO K, PAN Q K, PANG X, et al. A novel Lagrangian relaxation approach for a hybrid flowshop scheduling problem in the steelmaking-continuous casting process. *European Journal of Operational Research*, 2014, 236(1): 51 – 60.
- [17] JIANG S, LIU M, HAO J. A two-phase soft optimization method for the uncertain scheduling problem in the steelmaking industry. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2017, 47(3): 416 – 431.
- [18] SHI L, JIANG Y, WANG L, et al. A novel two-stage Lagrangian decomposition approach for refinery production scheduling with operational transitions in mode switching. *Chinese Journal Chemical Engineering*, 2015, 23(11): 1793 – 1800.
- [19] SHAH N K, IERAPETRITOU M G. Lagrangian decomposition approach to scheduling large-scale refinery operations. *Computers & Chemical Engineering*, 2015, 79(4): 1 – 29.
- [20] TIAN M, GAO X, JIANG Y, et al. Decomposition algorithm for the scheduling of typical polyvinyl chloride production by calcium carbide method. *Industrial & Engineering Chemistry Research*, 2016, 55(47): 12256 – 12267.
- [21] LUH P B, HOITOMT D J. Scheduling of manufacturing systems using the Lagrangian relaxation technique. *IEEE Transactions on Automatic Control*, 1993, 38(7): 1066 – 1079.
- [22] BRAGIN M A, LUH P B, YAN J H, et al. Convergence of the surrogate Lagrangian relaxation method. *Journal of Optimization Theory and Applications*, 2014, 164: 173 – 201.
- [23] RAMTEKE M, SRINIVASAN R. Large-scale refinery crude oil scheduling by integrating graph representation and genetic algorithm. *Industrial & Engineering Chemistry Research*, 2012, 51(14): 5256 – 5272.
- [24] ZHANG L, JIANG Y, GAO X, et al. Efficient two-level hybrid algorithm for the refinery production scheduling problem involving operational transitions. *Industrial & Engineering Chemistry Research*, 2016, 55(28): 7768 – 7781.

- [25] O'KANE J M, SHELL D A. Concise planning and filtering: Hardness and algorithms. *IEEE Transactions on Automation Science and Engineering*, 2017, 14(4): 1666 – 1681.
- [26] NAZEEM A, REVELIOTIS S. A practical approach for maximally permissive liveness-enforcing supervision of complex resource allocation systems. *IEEE Transactions on Automation Science and Engineering*, 2011, 8(4): 766 – 779.
- [27] SHAH N K, SAHARIDIS G K, JIA Z, et al. Centralized-decentralized optimization for refinery scheduling. *Computers & Chemical Engineering*, 2009, 57(6): 1570 – 1584.
- [28] CHEN Y, DING J, CHAI T. A knowledge transfer based scheduling algorithm for large-scale refinery production. *IEEE Transactions on Industrial Informatics*, 2022, 18(2): 869 – 879.
- [29] HARJUNKOSKI I, BAUER R. Industrial scheduling solution based on flexible heuristics. *Computers & Chemical Engineering*, 2017, 106(2): 883 – 891.
- [30] SILVER D, HUANG A, MADDISON C J, et al. Mastering the game of go with deep neural networks and tree search. *Nature*, 2016, 529(7578): 484 – 489.
- [31] YASEEN M U, ANJUM A, RANA O, et al. Deep learning hyperparameter optimization for video analytics in clouds. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2019, 49(1): 253 – 264.
- [32] YUAN X, HUANG B, WANG Y, et al. Deep learning-based feature representation and its application for soft sensor modeling with variable-wise weighted SAE. *IEEE Transactions on Industrial Informatics*, 2018, 14(7): 3235 – 3243.
- [33] DING S X, YIN S, PENG K, et al. A novel scheme for key performance indicator prediction and diagnosis with application to an industrial hot strip mill. *IEEE Transactions on Industrial Informatics*, 2013, 9(4): 2239 – 2247.
- [34] WU Gaochang, LIU Qiang, CHAI Tianyou, et al. Abnormal condition diagnosis through deep learning of image sequences for fused magnesium furnaces. *Acta Automatica Sinica*, 2019, 45(8): 1475 – 1485.
(吴高昌, 刘强, 柴天佑, 等. 基于时序图像深度学习的电熔镁炉异常工况诊断. *自动化学报*, 2019, 45(8): 1475 – 1485.)
- [35] WU Z, WU Y, CHAI T, et al. Data-driven abnormal condition identification and self-healing control system for fused magnesium furnace. *IEEE Transactions on Industrial Electronics*, 2015, 62(3): 1703 – 1715.
- [36] SHI L, JIANG Y, WANG L, et al. Refinery production scheduling involving operational transitions of mode switching under predictive control system. *Industrial & Engineering Chemistry Research*, 2014, 53(13): 8155 – 8170.

作者简介:

陈远东 博士研究生, 目前研究方向为炼油生产调度优化, E-mail: chenyd49@qq.com;

丁进良 教授, 目前研究方向为复杂工业过程控制与优化, E-mail: jlding@mail.neu.edu.cn.