

零部件循环取货越库物流系统关键因子研究^①

——仿真实验设计与分析方法

施文, 刘志学, 刘丹

(华中科技大学管理学院, 武汉 430074)

摘要: 汽车和物流产业是国家重点扶持的两大振兴产业. 在众多汽车制造企业产能扩大的背景下, 以零部件平均物流时间(cycle time, CT)为绩效评价指标, 深入研究了基于第三方物流的零部件循环取货越库物流模式(简称3PL-MRCD)的优化设计问题. 建立了符合企业实际运作的离散系统随机仿真模型, 即零部件循环取货与越库内部运作的集成模型. 与现有供应链仿真模型相比, 由于存在较多的仿真因子, 提出首先运用序贯分支法(sequential bifurcation, SB)筛选3PL-MRCD系统关键因子, 再应用响应面法(response surface methodology, RSM)找到关键因子最优运作水平的方法步骤(SB-RSM), 解决了大型仿真系统的优化设计问题. 基于调研的数据进行仿真实验, 结果表明SB-RSM可准确找出影响CT的关键因子最优取值, 该值使CT达到较为理想的水平. 对大型仿真系统的优化而言, SB-RSM比传统RSM更具实验效率与效力, SB-RSM为产能扩大3PL物流决策的制定提供了可靠的解决方案, 具有良好的应用价值.

关键词: 产能扩大; 零部件入厂物流; 越库配送; 仿真; 序贯分支法; 响应面元模型

中图分类号: F274 **文献标识码:** A **文章编号:** 1007-9807(2013)06-0022-13

0 引言

汽车零部件物流由入厂物流(供应物流或采购物流)、生产物流和出厂物流(售后物流)组成, 其中入厂物流是连接零部件供应商与装配企业之间物料供应活动的重要来源. 目前, 国内汽车制造企业零部件入厂物流大多采用基于3PL的循环取货越库配送(Milk-run Cross-docking, 3PL-MRCD)物流模式^[1]. 据预测, 国内汽车需求增长率在未来10年内将保持在10%左右^[2]. 在此利好形势下, 众多汽车制造商纷纷设立新厂, 包括武汉东风本田、神龙汽车和东风乘用车三大整车厂. 产能的扩大势必带来的零部件物流量的增加, 这对3PL物流运作提出更高的要求. 3PL是否需要调整影响3PL-MRCD物流绩效(零部件平均物

流时间, 见第2节)的所有因子, 即3PL-MRCD的各项物流环节, 如运输车辆数、越库中心库台数, 性能更优的装卸载设备等? 哪些因子对系统绩效起关键作用? 如何设计供应链以适应新的物流需求是其工作的一项重要任务.

1 文献综述

1.1 Milk-run 与 Cross-docking

国内外有关汽车零部件物流的研究多数集中于上游零部件Milk-run问题. 王旭等^[3]研究零部件Milk-run的最佳路径. 左晓露等^[1]探讨了基于3PL的汽车零部件物流Milk-run模式在国内的实施问题. Nemoto等^[4]对日本汽车制造厂在泰国的零部件Milk-run展开研究, 发现制造商有能力全

^① 收稿日期: 2011-09-12; 修订日期: 2012-04-21.

基金项目: 国家自然科学基金资助项目(71072034; 71003042).

作者简介: 施文(1981-), 男, 湖北武汉人, 博士生. Email: shi3wen@163.com

面控制整个采购流程. Kaneko 和 Nojiri^[5] 探讨日本汽车零部件“Just-in-time”配送物流的空间结构, 认为基于 3PL 的越库物流模式在小批量、高频率的零部件配送模式中极为重要, 但未提出任何理论模型. 有关越库的技术性研究始于上世纪 90 年代, Ross 和 Jayaraman^[6] 研究了越库作为供应链某一层级的网络选址问题. Ma 等^[7], Musa 等^[8] 分析了货物经越库转运或直接运输的网络设计问题. Lee 等^[9] 采用禁忌搜索算法研究了越库中心的车辆路径优化调度问题. Yu 和 Egbe-lu^[10], Chen 和 Lee^[11], Vahdani 和 Zandieh^[12] 研究了越库卸载区与装载区各一个库台(1对1)的单库台车辆调度模型, Chen 和 Song^[13] 在此基础上, 拓展到 1对2 或 2对1 的多库台模型.

3PL-MRCD 物流是零部件从供应商经 CDC 到厂边仓库的全过程. 现有文献多将 Milk-run 和 Cross-docking 分开研究, 尤其缺乏针对汽车行业两者运作的集成模型, 主要原因是两方面单独的许多问题已为 NP 难或 NP 完全, 需用启发式或元启发式算法求解, 两者集成后使得建模和求解都更为复杂. 此外, 所建模型大多为确定性的静态模型, 它难以反映主机厂产能扩大对系统绩效的动态影响变化, 使 3PL 难以从整个零部件实物流的角度获得全局的改进运作方案. 鉴于这两方面, 本文首先采用仿真的方法建立更符合 3PL-MRCD 实际运作的离散(随机动态)模型.

1.2 仿真实验设计与分析

对于复杂系统的设计问题, 计算实验(针对确定性仿真)^[14] 或仿真实验(针对随机性仿真)方法通常是获得可行解的唯一途径^[15]. 针对类似的随机仿真系统, Yalçınkaya 和 Mirac Bayhan^[16], Shang 等^[17], Kumar 和 Nottestad^[18], Shukla 等^[19], Noguera 和 Watson^[20] 通过仿真实验的统计数据采用基于响应面(RSM)元模型的仿真优化方法找到了输入因子的最佳组合, 解决了地铁、仓库、生产及供应链等系统的优化设计问题.

上述文献虽基于传统 RSM 优化设计了不同的系统, 但其模型中因子个数较少, 约为 5 个, 且都为直觉判断或事先给定的“关键因子”, 从而缺乏定量分析. 当面对更为复杂(因子数量较多且无法判定重要性)的系统时, 若仍直接采用 RSM, 仿真运行次数将成指数倍增加, 这将大大提高计

算机与仿真分析者的工作量. Pareto(80-20)原理和稀疏效应定理(sparsity-of-effects)^[21]表明: 系统中仅有少部分因子对绩效真正起作用. 对于 3PL-MRCD 系统而言, 关键因子是众多因子中对物流绩效改进起重要作用的因子, 它使得 3PL 只需优化改进关键因子对应的物流运作便可能达到主机厂的生产要求, 从而减轻 3PL 的工作负担.

综合以上两方面文献可知, 3PL-MRCD 系统是存在较多因子的复杂随机动态系统, 主机厂产能扩大后 3PL 的物流决策是复杂的管理问题. 本文基于零部件入厂物流建立了更符合实际运作的离散事件模型. 由于该模型是一类存在较多因子的随机仿真模型, 本文提出采用序贯分支(sequential bifurcation, SB)和响应面法(response surface methodology, RSM)相结合的方法(SB-RSM)筛选并优化模型中的关键因子, 分析比较产能扩大后 3PL 物流运作的最佳改进方案, 为 3PL 运作决策的调整提供可靠的解决思路.

2 问题描述

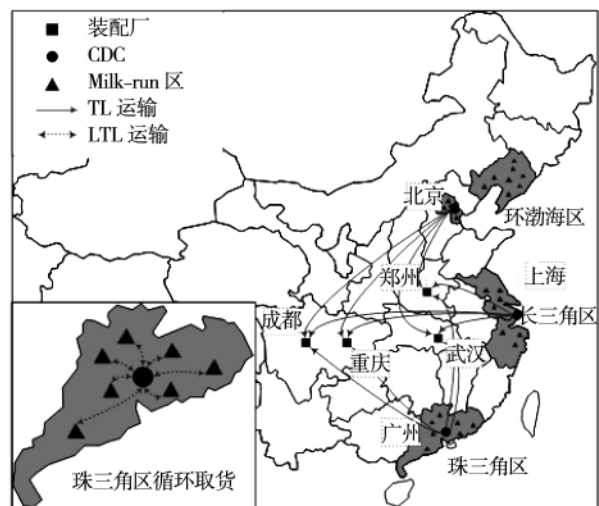


图1 国内汽车零部件物流

Fig. 1 Parts logistics in China

图1展示了整个 3PL-MRCD 零部件物流流程. 国内多数零部件供应商(图中“▲”)分布于长三角、珠三角、环渤海湾三大区域, 而某些主机厂(装配厂)位于距离较远的中西部地区, 见图1“■”, 如武汉的东风本田、东风神龙以及重庆的长安福特等, 它们通过合资的方式成立了为其服

务的第三方物流企业(3PL),如:东本储运、东风-捷富凯、长安民生等.由于运输距离较长,基于规模经济的角度考虑,3PL在汽车三大产业带设立区域越库中心(cross-docking center, CDC),见图1“●”.汽车制造商、零部件供应商和3PL事先签订合作协议,委托3PL实施零部件采购物流的Milk-run(见图1左下角小图),即根据零部件的补货频率、补货数量、供应商的分布和需求特征等因素,划分若干Milk-run区.一般情况下,从单个Milk-run区取货的零部件数量小于整车(less-than-truckload, LTL),因此该车将LTL零部件先支线运输至区域CDC.在CDC内经过一定时间的集并后,再整车(truckload, TL)干线运输至主机厂附近的厂边仓库.

图2中间部分展示了CDC内部的基本结构. CDC两端分别是卸载区和装载区,库台是其最重要的组成部分,一般地,单个库台仅容纳一辆货车.当LTL车辆抵达CDC(图2中左边卡车),CDC调度室视卸货区库台的占用状态决定该车下一步的位置.若有库台空闲,LTL车辆则任一分配至其中一库台;反之,若库台已全部占用,LTL车辆需先到车辆等候区排队,直到有空闲库台.

LTL车辆停靠在库台时,零部件下一步路线取决于装载区TL车辆的达到情况:(1)若此时有未装满的TL车辆停靠在装载区库台,则通过传送设备将零部件直接送至该TL车辆所在库台,其中,卸载区库台与传送设备始端及装载区库台与传送设备末端的两段运输由叉车或拖车完成;(2)若装载区库台未有可用的LTL车辆,则先由叉车将零部件转移至暂存区,待LTL车辆到达后,再由叉车运至该LTL车辆所在的库台.由于经过暂存区的零部件已有一定的存储时间,故TL车辆优先装载(2)的零部件.TL车辆在装载区满载后立即干线运输至厂边仓库.

主机厂一般要求零部件供应商配合其实施JIT生产,保证JIT配送^[1].因此,本文以零部件平均物流时间(cycle time, CT)作为绩效指标,CT是衡量系统作业效率高低的标准,部分越库文献也将此作为研究目标^[10-13].由于3PL-MRCD模型同时集成了CDC的内外部运作,即零部件物流路径涵盖Milk-run取货、支线运输、CDC内部转移和干线运输,因此本研究中的CT实际上包括了零部件的Milk-run取货时间、支线运输时间、CDC内的作业时间和干线运输时间四部分.

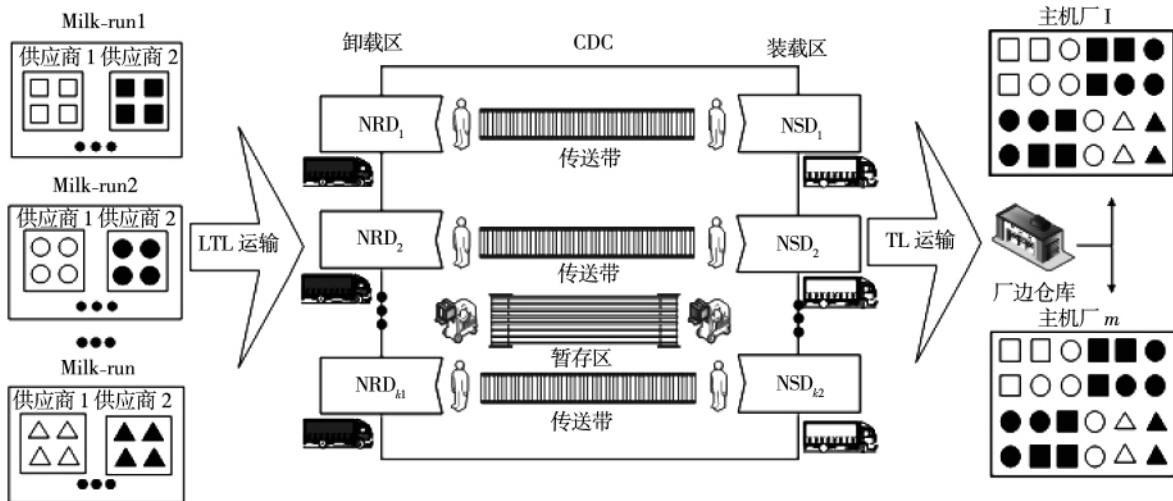


图2 3PL-MRCD 零部件物流
Fig. 2 Parts logistics of 3PL-MRCD

3 仿真模型

3.1 逻辑模型

本文选择 Rockwell 公司开发的离散/连续系统仿真软件包 ARENA 13.0 作为仿真工具^[22]. ARENA

特别适合于模拟生产、供应链等离散物流系统^[23, 24].为了建模和测试的顺利进行,本文将3PL-MRCD模型分割为九个相互联系的子模型(Submodel),各个子模型以粗线条连接,见图3所示.

子模型1 支线运输模型 LTL 车辆为3PL-MRCD模型中支线运输资源,在一个生产周

期内车辆数为固定值 $TQ_{M,C}$ ，下标大写 M 和 C 分别代表 Milk-run 和 CDC。LTL 车辆有忙和闲两种状态，忙态从该车接到取货指令开始，到取完货并在 CDC 卸载区将零部件卸载完毕结束；闲态的 LTL 车辆停靠在 CDC 等待下一次循环取货指令。若发出取货指令时处于闲态 LTL 车辆数 > 1 ，则优先选择闲态时间最长的车辆。CDC 与第 i 个 Milk-run 的距离为 $D_{M(i),C}$ ， $i \in \{1, 2, \dots, I\}$ ， I 为 3PL 事先划分的 Milk-run 数量（空车或载货的）LTL 车辆支线运输平均速度为 $V_{M,C}$ 。

子模型 2 循环取货模型

CDC 对第 i 个 Milk-run 发出循环取货指令的平均间隔时间 $BT_{M(i)}$ 服从均值为 $\mu_{BT_{M(i)}}$ 的指数分布。第 i 个 Milk-run 供应商数量为 $S_{M(i)} = \{S_{M(1)}, \dots, S_{M(I)}\}$ ， $S = \sum_{i=1}^I S_{M(i)}$ 代表供应商总数。第 i 个 Milk-run 单次循环取货的供应商所占比例为 α ，即

每次循环取货的供应商数为 $\alpha * S_{M(i)}$ 。单个供应商零部件取货时间 $P_s T_s$ 服从参数为 $(a_{P_s T_s}, b_{P_s T_s})$ 的均匀分布，供应商单位零部件装载时间 LT_s 服从参数为 $(a_{LT_s}, b_{LT_s}, f_{LT_s})$ 的三角分布。取完货后 LTL 零部件零部件装载量 $Q_{LTL} = \min\{LTL_{max}, \max[\text{Norm}(\mu_{LTL}, \sigma_{LTL}^2), LTL_{min}]\}$ 服从改进的正态分布，其中 LTL_{max} 为 LTL 车辆的容量， LTL_{min} 为单次循环取货应达到的最小装载量。

子模型 3 卸载区模型

LTL 车辆到达 CDC 触发卸载区事件。卸载区库台数为 NRD_C （下标大写 C 表示 CDC），若 LTL 车辆到达时库台占用数等于 NRD_C ，则该车先到车辆等候区排队等待直到某一库台空闲，等待区为先到先服务（FIFO）排队规则。每一库台配备足够规模的人力资源，单位数量零部件卸货时间 UT_C 服从参数为 $(a_{UT_C}, b_{UT_C}, f_{UT_C})$ 的三角分布。因此某 LTL 车辆的卸货时间为 $UT_C * Q_{LTL}$ 。

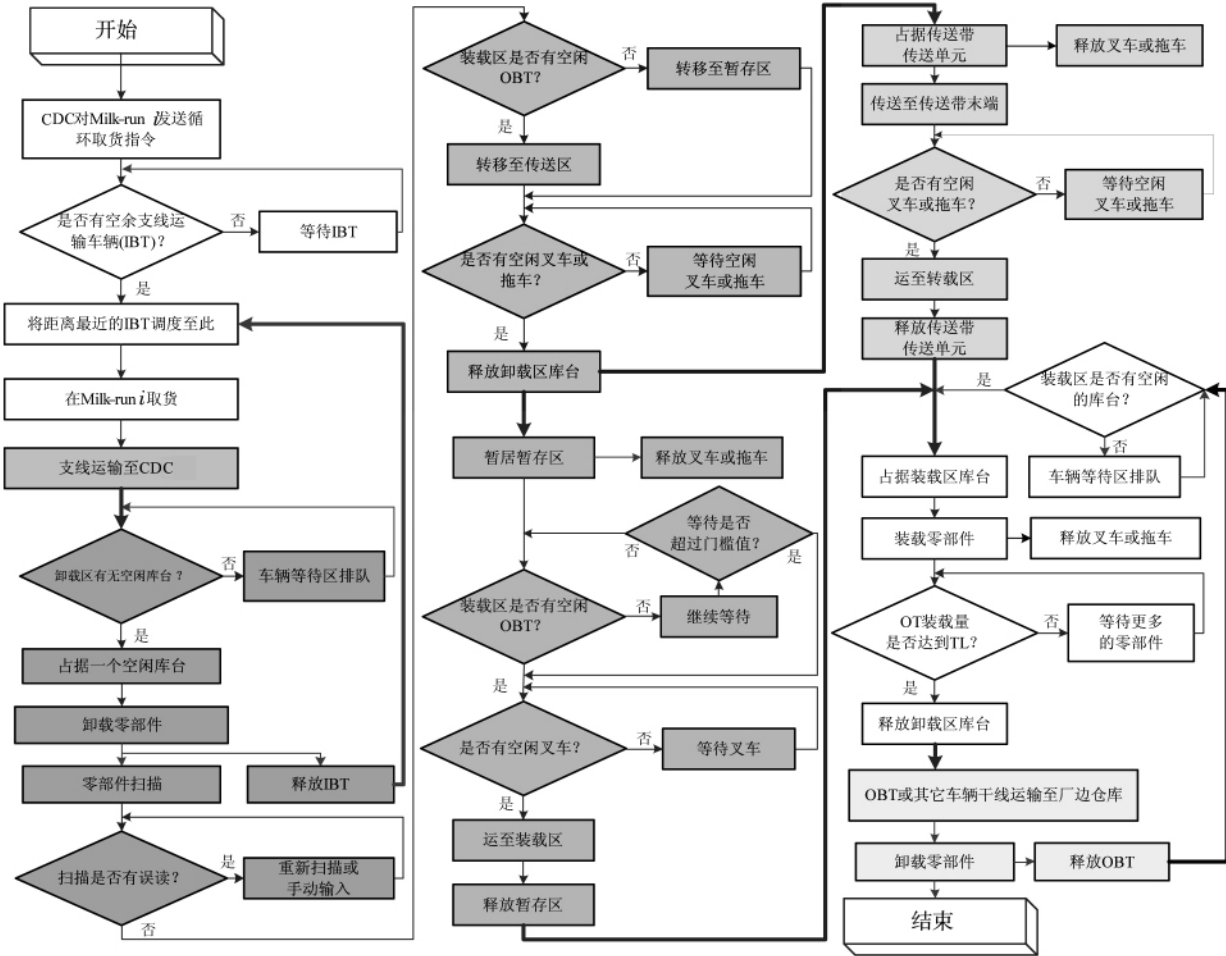


图 3 3PL-MRCD 物流逻辑流程
Fig. 3 Logical flow of 3PL-MRCD logistic

扫描与卸货在卸载区库台同步完成,标签损坏或朝向错误时有发生,需要工人二次扫描或手动输入条码,一次扫描通过率为 β ,单位数量零部件扫描时间服从均匀分布,参数为 (a_{STC}, b_{STC}) . 零部件下一步路线取决于卸载区库台是否停靠有可用的 TL 车辆,若有,零部件则直接由传送设备送至该 TL 车辆所在库台,否则进入暂存区存储.

子模型 4 传送区模型

传送带为不可聚集式输送设备,即传送带上被输送的零部件空间间隔不会改变. 传送区传送带数量为 NC_C ,传送带的长度均为 CL_C ,传送速度为 CV_C . 传送带由许多不断移动的等长单元组成,该单元容纳不多于一个单位的零部件,假设零部件平均单元大小为 CS_C ,故单位零部件在传送带上所占的平均尺寸为 CS_C .

子模型 5 暂存区模型

若装载区未停靠 TL 车辆,零部件则先转移到暂存区直到 TL 车辆到达,暂存区的固定容量为 CC ,暂存区中的零部件服从 FIFO 排队规则,即优先装载存储时间较长的零部件. 若零部件在暂存区的逗留时间超过阈值 TT ,而此时仍无到达的 TL 车辆,这些零件由额外的车辆直接运至主机厂(非厂边仓库),额外的车辆为 3PL 再外包的运输车辆,该部分零部件不计入系统绩效. 此外,暂存区的零部件比传送区的具有更高的优先级,即 TL 车辆优先装载暂存区零部件.

子模型 6 叉车与拖车模型

叉车和拖车是 CDC 内部的两种运输资源,负责零部件在卸货区、传送区、暂存区和装载区四个站点间的物流,站点间的距离等于 $D_{C(x,y)}$,其中 $x \neq y = r, s, t, \rho$, r 为卸货区, s 为装载区, ρ 为传送区, t 为暂存区. 叉车和拖车数量分别为 NF_C 和 NT_C ,运输速度为 FV_C 和 TV_C ,每车运输容量为 FC_C 和 TC_C . 叉车和拖车在运输能力上有所差别,故优先选择叉车作业,且 $D_{C(r,t)}$ 和 $D_{C(t,s)}$ 较远,这两段运输仅能用叉车完成.

子模型 7 装载区模型

装载区库台数为 NSD_C ,若 TL 车辆到达时,装载区无空闲库台,则车辆到卸货区车辆等待区排队等待. 默认情况下等候区排队规则为 FIFO. 库台配备相应数量的操作工人,整车 TL 车辆的零部

件装载量为 Q_{TL} ,单位数量零部件装载时间 LT_C 服从参数为 $(a_{LT_C}, b_{LT_C}, \rho_{LT_C})$ 的三角分布,因此,每辆 TL 车辆的装载时间为 $LT_C * Q_{TL}$.

子模型 8 干线运输模型

CDC 距厂边仓库的距离为 $D_{C,F}$,下标 F 表示厂边仓库(factory warehouse),干线运输的平均速度为 $V_{C,F}$. 与 LTL 车辆相同,TL 车辆有忙与闲两种状态,忙态由 TL 车辆接到 CDC 调度指令开始,到厂边仓库卸货完毕时结束;闲态的 TL 车辆载着空容器回到 CDC 等待下一调度,其中 TL 车辆数量为 $TQ_{C,F}$. 厂边仓库单位零部件卸货时间 UT_F 服从参数为 $(a_{UT_F}, b_{UT_F}, \rho_{UT_F})$ 的三角分布,因此,TL 车辆厂边仓库卸货时间等于 $Q_{TL} * UT_F$.

子模型 9 控制逻辑模型

在这个子模型中,实体没有相应的物理意义,它们被用来实现模型中的某种逻辑或改变系统状态. 由于第 i 个 Milk run 每次取货的数量 Q_{LTL} 服从随机分布,采用控制逻辑将每次随机产生的 Q_{LTL} 打包赋予 LTL 车辆. 此外,每隔 1 分钟,仿真系统自动查找暂存区中逗留时间超过阈值 TT 的零部件,并将符合该条件的零部件清理出暂存区,即通过额外 TL 车辆装载离开.

3.2 模型参数与假设

本文模型为终态(terminating)仿真模型,表 1 为系统的主要参数设置,其数据来源为调研的武汉某汽车 3PL 企业. 该汽车制造企业以 30 天为一个计划生产周期,因此,共有 30 个仿真日,另有 5 个仿真日的系统 Warm-up 时间. 由于是随机性仿真,为了提高仿真输出的精确度和实验设计的效率,每个仿真场景的重复次数为 10.

本模型的基本假设包括以下几点:

- 1) 每日工作 12 小时 8:00—20:00;
- 2) 支线运输与干线运输交通状况良好;
- 3) CDC 暂存区容量无限;
- 4) 任一卸载区库台至装载区库台距离为一固定值;
- 5) CDC 内部操作工人数量足以满足库内零部件操作需求;
- 6) 卸载区(装载区)库台同质,即卸载区(装载区)每一库台的卸载时间(装载时间)服从相同的参数分布;
- 7) 汽车零部件在供应商处已完成包装,CDC

内无包装流程;

在 CDC;

8) 需求在该计划周期内处于恒定状态;

10) 整个供应链完全信息共享,因此主机厂

9) 初始时刻 LTL 车辆与 TL 车辆停靠

发送采购指令后,3PL 立即发车循环取货.

表 1 仿真系统部分参数设置

Table 1 Partial parameters of simulated system

参数类别	参数	说明	默认值	单位
循环取货	I	所划分的 Milk-run 数量	5	个
	S	供应商总数	60	个
	$BT_{M(i)}$	第 i 个 Milk-run 循环取货间隔时间	EXPO{ 4.5 , 3.75 , 3 , 5 , 3.2 }	h
	$P_s T_s$	单个供应商取货时间	UNIF(10 , 15)	min
	LT_s	单位数量零部件供应商装载时间	TRIA(1 2 3)	min
	$S_{M(i)}$	第 i 个 Milk-run 供应商数量	{ 10 , 12 , 15 , 9 , 14 }	个
	α	循环取货的供应商所占比例	40%	—
支线运输	$TQ_{M,C}$	支线运输车辆数	30	辆
	Q_{LTL}	LTL 车辆零部件装载量	$\min\{40, \max[\text{NORM}(25, 5^2), 10]\}$	件
	$D_{M(i),C}$	第 i 个 Milk-run 到 CDC 的距离	{ 150 250 , 120 , 130 200 }	km
	$V_{M,C}$	支线运输的平均速度	75	km/h
越库运作	NRD_C	CDC 卸载区库台数	10	个
	NSD_C	CDC 装载区库台数	10	个
	UT_C	单位数量零部件卸货时间	TRIA(1 2 3)	min
	ST_C	单位数量零部件扫描时间	EXPO(20)	s
	CV_C	传送带传送速度	12	s/min
	CS_C	传送带零部件单位大小	1	—
	TT	暂存区存储时间阈值	24	h
	LT_C	单位数量零部件装货时间	TRIA(2 3 4)	min
	NF_C	CDC 叉车数	15	个
	FV_C	叉车运输速度	20	km/h
	FC_C	叉车平均容量	1	件
	TV_C	拖车运输速度	10	m/min
	$D_{C(r,s)}$	卸载区至装载区的距离	100	m
	$D_{C(r,t)}$	卸载区至传送区的距离	15	m
	Q_{TL}	TL 车辆的零部件装载量	40	件
干线运输	$D_{C,F}$	CDC 到厂边仓库的距离	1 069	km
	$V_{C,F}$	干线运输平均速度	75	km/h
	$TQ_{C,F}$	干线运输车辆数	50	辆
	UT_F	厂边仓库单位零部件卸货时间	TRIA(1.5 2.5 3.5)	min

4 因子筛选及仿真优化

上述 3PL-MRCD 仿真模型仅是一种实验手段,并未给出长期时间内 3PL 的最佳改进方案.仿

真优化(simulation optimization) 是基于仿真的目标优化问题,即基于模型仿真给出的输入(因子) 输出(响应, 统计学术语) 关系通过优化算法得到最佳的输入量^[25]. 本模型中影响系统绩效因子共有 58 个,其中可变因子 21 个(不可变因子包括: I 、

$S, S_{M(i)}, D_{M(i)}, M(j), D_{M(i)}, \ell$ 等供应链结构既定值), 具有“高维性”。因此, 本文采用 SB-RSM 集成的方法筛选并优化 3PL-MRCD 的关键因子。SB 和 RSM 都是包含一系列步骤的序贯方法。SB 类似于计算机领域著名的二叉搜索, 它不仅评估哪个因子是最重要的, 而且评估它们的重要程度。相比其它计算机筛选技术, SB 法更为高效^[26]。目前, 该方法已应用于生态仿真、热动力等领域, 然而较少用于解决复杂的供应链管理问题且与(随机)仿真优化结合较少。

4.1 SB 筛选关键因子

21 个可控因子高低水平见表 2 所示, 本文定义单个因子从低水平变为高水平不会减少仿真输出的期望, 如第 9 号因子 NRD_C (收货区库台数) 由 20(低水平) 变为 10(高水平) 的过程中, CT 单调不降(非严格单调递增), 这符合现实情形。高低水平的判断源于 3PL 企业和分析员的先验知识, 对无法判定的因子需个别处理。

首先将 21 个因子聚合到一个大的因子组, 检测该因子组是否有显著效应。若有, 转入下一步; 否则, 表明 21 个因子对 CT 无显著影响, 停止 SB。下一步将 21 个因子分为两个子组, 即分支(bifurcation), 检测两个子组的显著性。依次步骤, 将重要的因子组不断分割为两个更小的子组, 放弃检验出不重要的子组, 最终筛选出关键因子。

由于 3PL-MRCD 模型因子间存在交互作用(interaction effect), 如 TL 车辆对 CT 的影响与 LTL 车辆数有关, 故一个有效元模型(metamodel)是具有二阶交互作用和噪声的一阶多项式^[26]

$$y_{CT} = \beta_0 + \beta_1 x_1 + \dots + \beta_{21} x_{21} + \beta_{1;2} x_1 x_2 + \dots + \beta_{20;21} x_{20} x_{21} + \varepsilon \quad (1)$$

$$x_j = \frac{z_j - (h_j + l_j) / 2}{(h_j - l_j) / 2} \quad (2)$$

其中 y_{CT} 表示元模型响应的预测值, β_j 为因子 j 的主效应(main effect) ($j = 1, \dots, 21$), $\beta_{j';j}$ 为因子 j' 与 j 间的交互作用 ($1 \leq j' < j \leq 21$), 噪声 ε 是随机仿真模型产生的随机误差项, x_j 是通过式(2)标准化后的值 ($j = 1, \dots, 21$), 即 $[-1, 1]$ 标准化

意味着因子可以按主效应大小排序, 即最重要的因子的主效应值最大, 最不重要的因子效应值接近于 0^[25]。式(2)中 z_j 为 x_j 的原始值, h_j 和 l_j 对应 z_j 的上下限, 即表 2 中因子的高低水平。

为了便于表述, 本文采用以下符号及定义:

$w_{j;r}$, 第 1 到 j 号因子处于高水平, 第 $j + 1$ 到 21 号因子处于低水平的因子组合在第 r 次仿真重复(replicates 或 replications) 时获得的 CT 观测值;

表 2 3PL-MRCD 系统影响因子(参数分布见表 1)

Table 2 The affecting factors of the 3PL-MRCD system

序号	参数	低水平	高水平	CT
1	$P_s T_s$	(10, 15)	(15, 20)	单调不降
2	LT_M	(1, 2, 3)	(2, 3, 4)	单调不降
3	UT_C	(1, 2, 3)	(3, 4, 5)	单调不降
4	ST_C	(20)	(30)	单调不降
5	LT_C	(2, 3, 4)	(4, 5, 6)	单调不降
6	UT_F	(1.5, 2.5, 3.5)	(2.5, 3.5, 4.5)	单调不降
7	α	40%	60%	单调不降
8	β	1%	2%	单调不降
9	NRD_C	20	10	单调不降
10	NSD_C	20	10	单调不降
11	NF_C	20	10	单调不降
12	$TQ_{M,\ell}$	40	20	单调不降
13	$TQ_{C,F}$	70	50	单调不降
14	TT	24	36	单调不降
15	LTL 车辆排队规则	SPT	FIFO	单调不降
16	FV_C	30	20	单调不降
17	$V_{M,\ell}$	100	75	单调不降
18	$V_{C,F}$	100	75	单调不降
19	TV_C	5	10	单调不降
20	NT_C	20	10	单调不降
21	CV_C	24	12	单调不降

$w_{-j;r}$, 第 1 到 j 号因子处于低水平, $j + 1$ 到 21 号因子处于高水平的因子组合在第 r 次仿真重复时获得的 CT 观测值;

$\beta_{j'-j}$, 第 j' 到 j 号因子的主效应之和或群组响

应值, 即 $\beta_{j'-j} = \sum_{h=j'}^j \beta_h$;

根据式(1)及上述定义可知, 第 r 次仿真重复的群组效应和单个因子效应的一个无偏估计量分

别为式(3)和(4).进行 m 次重复仿真,从而得到群组效应的均值 $\hat{\beta}_{j'-j}$ 和标准差 $s(\hat{\beta}_{j'-j})$,见式(5).同理可得出每个估计效应的均值 $\hat{\beta}_j$ 和标准差 $s(\hat{\beta}_j)$,见式(6).最后通过 t -test 检验效应的显著性.

$$\hat{\beta}_{j'-j,r} = \frac{[w_{j',r} - w_{-(j);r}] - [w_{(j'-1);r} - w_{-(j-1);r}]}{4} \quad (3)$$

$$\hat{\beta}_{j,r} = \frac{[w_{j,r} - w_{-(j);r}] - [w_{(j-1);r} - w_{-(j-1);r}]}{4} \quad (4)$$

$$\bar{\hat{\beta}}_{j'-j} = \frac{\sum_{r=1}^m \hat{\beta}_{j'-j,r}}{m} \quad s(\bar{\hat{\beta}}_{j'-j}) = \sqrt{\frac{\sum_{r=1}^m (\hat{\beta}_{j'-j,r} - \bar{\hat{\beta}}_{j'-j})^2}{m(m-1)}} \quad (5)$$

$$\bar{\hat{\beta}}_j = \frac{\sum_{r=1}^m \hat{\beta}_{j,r}}{m} \quad s(\bar{\hat{\beta}}_j) = \sqrt{\frac{\sum_{r=1}^m (\hat{\beta}_{j,r} - \bar{\hat{\beta}}_j)^2}{m(m-1)}} \quad (6)$$

由于 3PL-MRCD 是随机性仿真系统,故对每个因子组合进行 $m = 5$ 次重复仿真实验.表 3 给出了前四个因子组合(场景)的 CT 观测值及计算所

得的群组效应值,即场景一 21 个因子都置于低水平,此时 CT 最小;场景二 21 个因子都处于高水平,此时 CT 最大;场景三,首次分支后 1-16 号因子处于低水平,17-21 号因子置于高水平的因子组合;场景四,首次分支后 1-16 号因子处于高水平,17-21 号因子置于低水平.表中数据显示:场景一时,CT 的平均值为 $\bar{w}(0) = 18.856$;场景二时 $\bar{w}(21) = 95.092$.因此,1-21 号因子群组效应估计量由式(3)获得 $\hat{\beta}_{1-21} = 38.118$,该群组效应的标准差 $s(\hat{\beta}_{1-21}) = 2.550$,可见群组效应显著.第 2 步,将当前群组的 21 个因子分成 2 个子组,其中,第一个子组放入 16 (2^4) 个因子,第 2 个子组放入剩余的 5 个因子.由表 3 可见,场景三 $\bar{w}(-16) = 33.415$;场景四 $\bar{w}(16) = 85.437$,得到 1-16 号因子和 17-21 号因子两个子群效应估计值及标准差为 $\hat{\beta}_{1-16} = 32.064$ $s(\hat{\beta}_{1-16}) = 1.787$ $\hat{\beta}_{17-21} = 6.053$ $s(\hat{\beta}_{17-21}) = 2.949$,说明 1-16 号群组为较重要的子组,关键因子的确定需进一步分支筛选.

表 3 3PL-MRCD 仿真中前四个场景重复 5 次的仿真 CT 观测值及计算结果

Table 3 First four scenarios replicated five times simulated in SB for the 3PL-MRCD model

重复	$\bar{w}(0)$	$\bar{w}(-16)$	$\bar{w}(16)$	$\bar{w}(21)$	$\bar{\hat{\beta}}_{1-16}$	$\bar{\hat{\beta}}_{17-21}$	$\bar{\hat{\beta}}_{1-21}$
1	18.875	33.307	74.807	97.779	30.101	9.350	39.452
2	18.834	28.823	93.009	88.611	33.490	1.397	34.888
3	18.917	38.115	88.496	98.945	32.602	7.411	40.013
4	18.831	38.134	87.414	90.545	30.248	5.608	35.856
5	18.821	28.696	83.460	99.579	33.880	6.498	40.379
均值	18.856	33.415	85.437	95.092	32.064	6.053	38.118
标准差	0.040	4.683	6.846	5.120	1.787	2.949	2.550

图 4 展示了 SB 的整个步骤计算结果,当子组主效应检验不显著为正时,停止进一步的分支.3PL-MRCD 模型 SB 过程停止在第 13 步,共进行了 $23 \times 5 = 115$ 次仿真运行获得的 4 个关键因子,图 4 中以填充模块标识,其中 23 为实验点数,5 为每一实验点的重复次数.最重要的因子的排序为 $TQ_{CF} > TQ_{MC} > NRD_C > V_{CF}$.由 SB 筛选的结果可知,干线运输车辆数 TQ_{CF} 是影响 CT 的最关键

物流运作.随着主机厂产能扩大,干线运输将首先出现运力不足的问题,这将导致零部件在 CDC 内的过度积压,延长零部件在暂存区内的等待时间,从而增加在制品库存,这不利于主机厂 JIT 生产的实施.因此,3PL 应首先增加 TQ_{CF} ,保证干线运输的运能.此外,适当增加支线运输车辆数、CDC 卸载区库台数和更换性能跟更好的车辆对 CT 改进也将有较为显著的帮助.

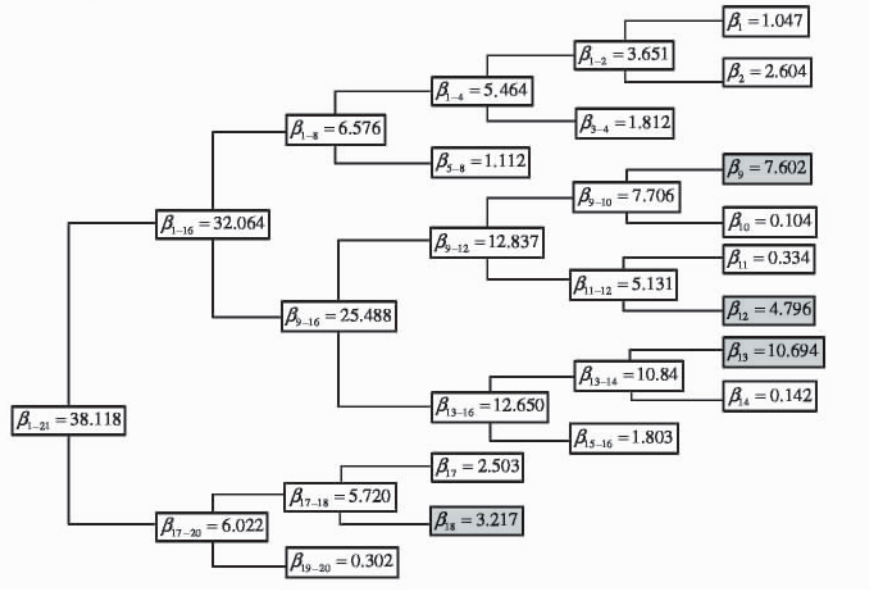


图4 3PL-MRCD模型SB步骤

Fig. 4 SB procedures of 3PL-MRCD model

4.2 RSM 优化关键因子

SB 虽筛选出模型中的关键因子,但企业盲目地调整关键因子将可能造成资源的浪费,其最优取值需由优化算法确定.由于关键因子中 $V_{C,F}$ 的低水平值已为边界值,故优化中仅分析 $TQ_{C,F}$, $TQ_{M,C}$ 和 NRD_C 剩余三个因子.通过进一步的灵敏度分析发现,关键因子参数水平{70 40 20}仍未是能最小化 CT 时的最佳取值,表4中参数组合{80 70 30}和{100 100 50}的CT平均值明显优于{70 40 20}的结果,即 $\overline{CT_5} = 23.765 < 27.789$.{80 70 30}和{100 100 50}在随机仿真模型中5次重复运行观测结果一致是因为为了提高比较的精度,对不同因子组合使用了公共随机数(common random number, CRN)^[24].仿真结果的重复说明此时系统中关键因子已有闲置资源,该组合下的绩效值($\overline{CT_5} = 23.765$)为关键因子能使CT达到的最小值,因此关键因子最佳的参数组合取值界于[{70 40 20} {80 70 30}]之间.

对该区域建立 RSM 元模型,它是一种通过估计参数组合,使给定目标函数达到最小的启发式优化方法.与其它仿真优化方法相比,RSM 需要相对较少的仿真重复和因子组合^[21],并且与昂贵仿真(单次仿真运行需要大量时间)运行所需的时间相比,RSM 启发式搜索所需的数学和统计计算可以忽略^[25].

表4 关键因子三组参数组合

Table 4 Simulated results of three input combinations

组合 重复	{70 40 20}	{80 70 30} {100 100 50}
1	27.884	23.837
2	27.851	23.746
3	27.794	23.791
4	27.650	23.764
5	27.766	23.688
平均值	27.789	23.765
标准差	0.090	0.054

响应(CT)和自变量(关键因子)之间的关系形式是未知的,RSM的第一步就是寻求响应 y_{CT} 和自变量集合 $\{x_1, x_2, x_3\}$ (代表 $\{TQ_{C,F}, TQ_{M,C}, NRD_C\}$) 之间真实函数的一个合适的逼近式.当远离最优点时,通常假定在 x 的一个小区域范围内是真实模型曲面的合适近似,一般采用全析因设计或分式析因设计方法,若CT适合关键因子的线性接近式建模,则近似一阶多项式元模型为

$$y_{CT}(x) = \beta_0 + \sum_{i=1}^3 \beta_i x_i + \sum_{i=1}^3 \sum_{i' \neq i}^3 \beta_{i,i'} x_i x_{i'} + \varepsilon \quad (7)$$

式中 $\beta_0, \beta_i, \beta_{i,i'}$ 是未知参数,通过仿真实验的观测数据由最小二乘法估计, ε 为模型的随机误差项.为确定下一步因子的方向,RSM 将式中拟合的梯

度用到最速下降法之中到达最优点区域,若最优点位置方差分析显示系统有曲度出现,则改用更高阶的多项式,一般为中心复合设计拟合的二阶元模型:

$$y_{CR}(x) = \beta_0 + \sum_{i=1}^3 \beta_i x_i + \sum_{i=1}^3 \sum_{i' \neq i}^3 \beta_{ii'} x_i x_{i'} + \sum_{i=1}^3 \beta_{ii} x_i^2 + \varepsilon \quad (8)$$

最后 RSM 对式(8)应用规范分析检查最优区域的外形并用数学规划求得极值,见式(9)

$$\begin{aligned} \min E [(y_{CR} | x_i)] (i = 1, 2, 3) \\ \text{s. t. } \begin{cases} 70 \leq x_1 \leq 80 \\ 40 \leq x_2 \leq 70 \\ 20 \leq x_3 \leq 30 \end{cases} \quad (9) \end{aligned}$$

采用全析因设计方法拟合三因子一阶响应面元模型,拟合结果见式(10).由于模型存在曲度,故将一阶模型替换(7)为二阶模型(8).对该区域采用3因子中心复合设计,包括 2^3 组全析因设计,6组轴点设计及1组中心点设计,其中,非中心点仿真重复次数为5,中心点仿真重复次数为10,总的实验次数为 $8 * 5 + 6 * 5 + 10 = 80$,最终拟合的二阶响应面方程为式(11).决定系数 $R^2 = 0.976$ 和调整的 $R_{adj}^2 = 0.959$ 说明式(11)能够极好地代表3PL-MRCD仿真系统,由式(9)和(11)求得最优的因子组合{80 62 23},此时 $\widehat{CT}^* = 23.695$.

$$\begin{aligned} y_{\widehat{CT}} = & 62.266 - 0.394x_1 - 0.391x_2 - 0.649x_3 + \\ & (3.446E-003)x_1x_2 + (6.703E-003)x_1x_3 + \\ & (2.182E-003)x_2x_3 \quad (10) \end{aligned}$$

$$\begin{aligned} y_{\widehat{CT}} = & 119.710 - 1.476x_1 - 0.864x_2 - 1.002x_3 + \\ & (3.446E-003)x_1x_2 + (6.703E-003)x_1x_3 + \\ & (2.182E-003)x_2x_3 + (7.213E-003)x_1^2 + \\ & (4.171E-003)x_2^2 + (7.062E-003)x_3^2 \quad (11) \end{aligned}$$

5 仿真实验比较

5.1 不同运作方案比较

图5展示了产能扩大后,3PL的四种运作方案的比较结果,它们为四种因子在不同水平下进行25次独立仿真实验后得到的系统绩效指标值,每

一组仍使用 CRN.




图 5 不同因子水平的仿真结果比较

Fig. 5 Simulated results of different factor combinations

“方案1”曲线表示主机厂产能增大后,3PL未做任何物流调整时CT呈现出的趋势,由该曲线可看出,CT的期望值较大,波动较为明显,系统处于极不稳定的状态,说明此时零部件物流绩效已严重违背了主机厂JIT的生产要求,3PL物流运作急需改进。“方案2”曲线表示仅调整关键因子的绩效值,由该图可知CT有明显的改善,其期望值大幅度缩减,波动也较小,系统状态相对稳定.这说明找出影响系统绩效的关键物流运作是3PL解决产能扩大问题的关键.“方案3”时,系统绩效仍有一定的改进幅度,CT期望值与标准差进一步向3PL期望的方向变化,此时为关键因子所能发挥的最大效用.“方案1”与“方案3”曲线间的差值为关键因子的绩效改进的最大贡献值,本模型中该值达到了93.4%.由此可见,3PL只优化少数关键的物流运作,便可使绩效恢复到较为理想的水平,这将大大减少3PL的工作量.“方案4”曲线表示改进所有物流运作得到的绩效,该组绩效值为四种组合下的最优值,但3PL所需改进的运作内容也最多,耗费的成本与资源也最大,“方案3”与“方案4”曲线间的差值为非关键因子的绩效改进贡献值.本模型中,非关键因子贡献值约为6.5%.

由上述分析可知,在主机厂产能扩大的过程中,3PL首先应重点改进关键的物流运作,使其效用最大化.企业盲目地调整物流运作可能会增加

成本的投入,造成资源的浪费.如本文中增加装载区库台数对绩效改进贡献不大.若关键运作最优水平的绩效仍无法满足主机厂的 JIT 生产要求,则再按图 4 中因子重要性逐步改进其它的物流运作,使系统逐步达到最佳绩效.以上计算分析结果充分显示,提出的数学模型和方法是可靠且实用的,具有较高的操作性和可行性.

5.2 SB-RSM 与 RSM 比较

为了比较所提 SB-RSM 方法与传统 RSM(以下表示成 RSM_C) 两种优化方法的实验效率与统计效力,本文基于 1.2 节中 Yalçınkaya 和 Mirac Bayhan^[16] 等方法,采用分辨率为 V 的最小化中心复合设计对 21 个因子直接拟合响应面,该设计虽精简了大量的实验点,但 21 个因子仍需 506 个实验点来拟合式(8).由于实验点过多,每一实验点仅进行 $m = 1$ 次仿真重复.显然 RSM_C 的最优解的绩效为图 6 中的“方案 4”曲线($\bar{CT} = 18.8815$).因此,本文最终比较 SB-RSM 最优组合和能使传统 RSM 达到 SB-RSM 最优绩效时的因子组合.

表 5 第 1 列展示了 SB-RSM 与 RSM_C 比较的几

个维度.由该表可知,SB-RSM 所需实验点(因子组合)数 $23 + 15(= 38)$ 远小于 RSM_C 所需的 506 个;即使 SB-RSM 对每个实验点进行至少 5 次的仿真重复,其总的仿真次数 $115 + 80 = 195$ 仍低于 RSM_C 所需的一半.因此,对因子数目较多的大型复杂的仿真模型优化设计而言,SB-RSM 可以更快速地找到系统的最佳运作方案,即 SB-RSM 的实验效率远高于 RSM.另一方面,表 5 也展示了 RSM_C 近似达到 SB-RSM 最优绩效目标($\hat{y}_{CT}^* = 23.695$) 时因子组合,以及该组合得出的 \hat{y}_{CT} , \bar{w}_{CT} 和 $\text{var}(\bar{w}_{CT})$.虽然 SB-RSM 元模型的预测值大于 RSM_C 的结果,即 $23.695 > 22.844$,但验证性实验显示 $|\bar{w}_{SB-RSM} - \bar{y}_{SB-RSM}| = |23.812 - 23.695| < |\bar{w}_{RSM_C} - \bar{y}_{RSM_C}| = |24.468 - 22.844|$,这说明 SB-RSM 具有更高的预测精度.此外,SB-RSM 最优解的稳定性也优于 RSM_C , $1.439 < 2.354$,这主要因为 RSM_C 实验点过多,导致每个实验点仅进行了一次仿真重复,从而忽视了 3PL-MRCD 仿真模型中的随机误差干扰.

表 5 SB-RSM 与 RSM 的比较

Table 5 Comparisons of SB-RSM and RSM

性质	SB-RSM		RSM_C
	SB	$RSM_{\text{关键因子}}$	
所需实验点(因子组合)数	23	15	506
单个实验点仿真重复次数	5	非中心点 5, 中心点 10	1
所需仿真运行总次数	115	80	506
因子组合	(80, 62, 23)		(15, 99, 2, 26, 2, 03, 22, 94, 4, 62, 2, 9, 0, 57, 0, 11, 21, 13, 19, 59, 78, 35, FIFO, 25, 96, 14, 96, 75, 15, 97, 11, 89, 15, 71)
系统绩效预测值 \hat{y}_{CT}	23.695		22.844
25 次验证实验 \bar{w}_{CT}	23.812		24.468
25 次验证实验 $\text{var}(\bar{w}_{CT})$	1.439		2.354

注: 粗体为 RSM_C 对应 SB-RSM 关键因子的取值,如 TQC_F 在 SB-RSM 和 RSM_C 取值分别为 80 和 78.

6 结束语

为分析国内汽车需求持续增长环境下,主机厂产能扩大对汽车零部件物流产生的影响,以及 3PL 企业如何优化配置其物流运作以满足新的物流需求,首先构建从供应商到越库再到主机厂边仓库的 3PL-MRCD 随机仿真模型,该模型可辅助

决策者进行零部件实物流的仿真实验,采集不同模型参数下的运行数据,统计与跟踪各项性能指标的变化趋势.由于该模型较为复杂,存在数量较多的仿真因子,提出采用序贯分支和响应面法相结合的方法(SB-RSM)筛选并优化对系统绩效起重要影响的关键因子,得到系统绩效最优时的关键因子资源配置.通过比较不同物流运作的因子组合,发现在主机厂产能增大的过程中,3PL 集中

调整零部件关键因子对应的物流运作,使其效用最大化可极大改进系统绩效并维持正常的零部件供应.此外,仿真实验显示SB-RSM比传统RSM更具效率和效力.

本文所建立的仿真模型及提出的仿真实验与优化方法能辅助汽车行业3PL企业决策者设置最优运作参数,为企业决策的制定和绩效的改进提供一定的理论基础和决策依据.当然,本研究也尚存不足,拟从以下诸方面进一步改进:(1)

3PL-MRCD模型考虑更多的实际因素,如支线和干线运输速度变化、越库内部操作资源故障、工人的调度和轮班制度等;(2)考虑多维绩效评价指标,如零部件流量和成本等;(3)建立加入供给、需求等不确定性因素的响应面元模型进行稳健仿真优化(robust simulation optimization),该问题是仿真优化的热点^[27,28].(4)比较RSM与其它元模型拟合的优劣,如神经网络或Kriging等.

参考文献:

- [1]左晓露,刘志学,郑长征.汽车零部件循环取货物流模式的分析与优化[J].汽车工程,2011,33(1):79-84.
Zuo Xiaolu, Liu Zhixue, Zheng Changzheng. Analysis and optimization of Milk-run mode for auto parts logistics [J]. Automotive Engineering, 2011, 33(1): 79-84. (in Chinese)
- [2]国务院发展研究中心产业经济研究部,中国汽车工程学会,大众汽车集团(中国).中国汽车行业发展报告(汽车蓝皮书)[R].北京:社会科学文献出版社,2010.
Research Department of Industrial Economy of Development Research Center of The State Council, Society of Automotive Engineers of China, Volkswagenwerk (China). Annual Report on Automotive Industry in China [R]. Beijing: Social Sciences Academic Press (China), 2010. (in Chinese)
- [3]王旭,陈栋,王振锋.汽车零部件Milk-run车辆调度优化模型和算法[J].计算机应用,2011,31(4):1125-1128.
Wang Xu, Chen Dong, Wang Zhenfeng. Scheduling optimization model and algorithm for Milk-run auto parts [J]. Journal of Computer Application, 2011, 31(4): 1125-1128. (in Chinese)
- [4]Nemoto T, Hayashi K, Hashimoto M. Milk-run logistics by Japanese automobile manufacturers in Thailand [J]. Procedia-Social and Behavioral Sciences, 2010, 2(3): 5980-5989.
- [5]Kaneko J, Nojiri W. The logistics of Just-in-Time between parts suppliers and car assemblers in Japan [J]. Journal of Transport Geography, 2008, 16(3): 155-173.
- [6]Ross A, Jayaraman V. An evaluation of new heuristics for the location of cross-docks distribution centers in supply chain network design [J]. Computers & Industrial Engineering, 2008, 55(1): 64-79.
- [7]Ma H, Miao Z, Lim A, et al. Crossdocking distribution networks with setup cost and time window constraint [J]. Omega, 2011, 39(1): 64-72.
- [8]Musa R, Arnaout J P, Jung H. Ant colony optimization algorithm to solve for the transportation problem of cross-docking network [J]. Computers & Industrial Engineering, 2010, 59(1): 85-92.
- [9]Lee Y H, Jung J W, Lee K M. Vehicle routing scheduling for cross-docking in the supply chain [J]. Computers & Industrial Engineering, 2006, 51(2): 247-256.
- [10]Yu W, Egbelu P J. Scheduling of inbound and outbound trucks in cross docking systems with temporary storage [J]. European Journal of Operational Research, 2008, 184(1): 377-396.
- [11]Chen F, Lee C Y. Minimizing the makespan in a two-machine cross-docking flow shop problem [J]. European Journal of Operational Research, 2009, 193(1): 59-72.
- [12]Vahdani B, Zandieh M. Scheduling trucks in cross-docking systems: Robust meta-heuristics [J]. Computers & Industrial Engineering, 2010, 58(1): 12-24.
- [13]Chen F, Song K L. Minimizing makespan in two-stage hybrid cross docking scheduling problem [J]. Computers & Operations Research, 2009, 36(6): 2066-2073.
- [14]盛昭瀚,张维.管理科学研究中的计算实验方法[J].管理科学学报,2011,14(5):1-10.
Sheng Zhaohan, Zhang Wei. Computational experiments in management science and research [J]. Journal of Management Sciences in China, 2011, 14(5): 1-10. (in Chinese)

- [15]Chen V C P , Tsui K L , Barton R R , et al. A review on design , modeling and applications of computer experiments [J]. IIE Transactions , 2006 , 38(4) : 273 – 291.
- [16]Yalçınkaya O , Mirac Bayhan G. Modelling and optimization of average travel time for a metro line by simulation and response surface methodology [J]. European Journal of Operational Research , 2009 , 196(1) : 225 – 233.
- [17]Shang J , Li S , Tadikamalla P. Operational design of a supply chain system using the Taguchi method , response surface methodology , simulation , and optimization [J]. International Journal of Production Research , 2004 , 42(18) : 3823 – 3849.
- [18]Kumar S , Nottestad D A. Capacity design: An application using discrete-event simulation and designed experiments [J]. IIE Transactions , 2006 , 38(9) : 729 – 736.
- [19]Shukla S K , Tiwari M K , Wan H D , et al. Optimization of the supply chain network: Simulation , Taguchi , and Psychological algorithm embedded approach [J]. Computers & Industrial Engineering , 2010 , 58(1) : 29 – 39.
- [20]Noguera J H , Watson E F. Response surface analysis of a multi-product batch processing facility using a simulation meta-model [J]. International Journal of Production Economics , 2006 , 102(2) : 333 – 343.
- [21]Myers R H , Montgomery D C , Anderson-Cook C M. Response Surface Methodology: Process and Product Optimization Using Designed Experiments [M]. New York: John Wiley & Sons , 2009.
- [22]Kelton W D , Sadowski R P , Sturrock D T. Simulation with ARENA [M]. 4th ed. New York: McGraw-Hill; 2007.
- [23]Banks J , Carson J S , Nelson B L. Discrete-event simulation [M]. 4th ed. Upper Saddle River , NJ: Prentice-Hall , 2005.
- [24]Law A M. Simulation Modeling and Analysis [M]. 4th ed. Boston: McGraw-Hill , 2007.
- [25]Kleijnen J P C. Design and analysis of simulation experiments [M]. New York: Springer , 2008.
- [26]Wan H , Ankenman B E , Nelson B L. Controlled sequential bifurcation: A new factor-screening method for discrete-event simulation [J]. Operations Research , 2006 , 54(4) : 743 – 755.
- [27]Dellino G , Kleijnen J P C , Meloni C. Robust optimization in simulation: Taguchi and response surface methodology [J]. International Journal of Production Economics , 2010 , 125(1) : 52 – 59.
- [28]Dellino G , Kleijnen J P C , Meloni C. Robust optimization in simulation: Taguchi and krige combined [J]. INFORMS Journal on Computing , 2012 , 24(3) : 471 – 484.

Key factors of parts logistics for milk-run and cross-docking system: Design and analysis of simulation experiments method

SHI Wen , LIU Zhi-xue , LIU Dan

School of Management , Huazhong University of Science and Technology , Wuhan 430074 , China

Abstract: Automobile and logistics are the two critical restructuring and invigorating industries in China. In the context of assembly plant capacity expansion , with the purpose of improving the system performance , this paper elaborates on the optimal design of key operations in the logistics mode of auto parts milk run and cross dock dealt with by a 3PL company. We build a simulation model which integrated the operations of milk run and cross-docking based on practical research data. Further , we propose an optimization algorithm that uses sequential bifurcation and Response surface methodology (SB-RSM) of the design and analysis of simulation experiments theory. The results of specified simulation design and runs indicate that the logistics performances are greatly improved if the 3PL simply optimizes the key operations , which helps to reduce the workload of the 3PL. The proposed SB-RSM shows higher efficiency and efficacy than classical RSM. This study contributes to decision making concerning supporting automobile parts 3PL Company when the automobile assembly plant capacity expands , and guides to solve the optimization issue of complex simulated system.

Key words: capacity expansion; auto parts logistics; cross-docking; simulation; sequential bifurcation; response surface meta-model