

基于支持向量机的多载量小车实时调度

周炳海,徐佳惠

(同济大学 机械与能源工程学院,上海 201804)

摘要:为了有效地解决车辆装配系统中多载量小车的实时调度问题,提出了基于支持向量机的实时调度方法。首先对多载量小车的实时调度问题进行描述,同时建立以车辆装配线产量和物料搬运距离作为评价指标的目标函数。然后通过车辆装配线的物料搬运系统仿真生成样本离线训练支持向量机模型,在实时阶段利用支持向量机模型实现多载量小车“等待”或“搬运”的调度决策。试验结果表明,本文提出的方法明显优于最小批量法,其运行速度快、实时调度效果好,且对动态环境变化具有一定的自适应性,能够有效提升多载量小车的实时调度水平。

关键词:人工智能;多载量小车;支持向量机;实时调度;物料搬运

中图分类号:TP29 **文献标志码:**A **文章编号:**1671-5497(2016)06-2027-07

DOI:10.13229/j.cnki.jdxbgxb201606036

SVM-based real-time scheduling approach of multi-load carriers

ZHOU Bing-hai, XU Jia-hui

(School of Mechanical Engineering, Tongji University, Shanghai 201804, China)

Abstract: To tackle the real-time scheduling problem of multi-load carriers in automobile assembly lines, a real-time scheduling approach was proposed based on Support Vector Machine (SVM). First, the real-time scheduling problem of multi-load carriers is formally described, and an objective function of assembly line output and the delivery distance is set up. Then, samples are generated by the simulation of the assembly line with material handling system to train an SVM model offline. Finally, the trained SVM model is used in the real-time scheduling process to make “wait” or “deliver” decisions. Experimental results indicate that the proposed approach outperforms the Minimum Batch Size (MBS) approach. It runs fast, performs well and to some degree adapts to the changes in the dynamic environment. It can be effectively used to improve the real-time scheduling of multi-load carriers.

Key words: artificial intelligence; multiple-load carriers; support vector machine (SVM); real-time scheduling; material handling

0 引言

如今的汽车制造业多采用搬运能力较高的多

载量小车(Multiple-load carrier)^[1]进行物料搬运。由于车辆装配系统的复杂性,如何提升多载量小车的实时调度水平已成为实现汽车制造业提

收稿日期:2015-05-11.

基金项目:国家自然科学基金项目(71471135,61273035).

作者简介:周炳海(1965-),男,教授,博士生导师.研究方向:离散系统建模、调度与仿真.

E-mail: bhzhou@tongji.edu.cn

高效率、降低成本的重要手段。

物料搬运系统的调度问题通常具有动态性、随机性和多目标性等特征,而目前关于动态调度方法的研究成果主要集中于一般制造系统中基于单一或复杂规则的调度方法^[1]。如文献[2,3]分别采用了最短搬运时间先服务(STTF)规则和最长输出队列(MOQS)规则进行实时调度。Wu 等^[4]基于匈牙利算法来解决调度问题。一些学者通过仿真、改进型启发式算法、机器学习等方法对物料搬运系统的调度进行优化。如 Hsieh 等^[5]将物料搬运系统(MHS)分为若干非重叠的子系统,每个子系统都包含一定数量的自动导向车(Automated guided vehicle, AGV)小车,并运用仿真确定 AGV 小车的最优数量及资源分配。Godinho 等^[6]围绕调度问题、评价指标、解决方法等 6 个方面,对运用遗传算法解决 FMS 调度问题进行了研究。

随着对单载量搬运设备的研究日趋完善,对于多载量小车的研究也受到越来越多的重视^[7]。如朱琳等^[8]以物料搬运时间最短为目标,提出了一种改进的遗传算法,对 FMS 中 AGV 小车任务进行分配和排序。Chen 等^[9]基于神经网络和知识库,考虑到产品配比对多载量小车实时调度的影响,比较了不同的搬运任务选择和排序规则。Fathi 等^[10]以搬运次数和线边库存的最小化为目标,改进模拟退火算法来确定多载量小车搬运的零件种类和数量。上述文献主要研究了多载量小车的资源分配和任务排序问题^[11],而目前对于是否搬运、何时开始搬运的调度决策问题鲜有涉及。

本文引入支持向量机(Support vector machine, SVM),结合仿真技术,针对装配线中物料搬运的调度决策问题,提出了基于 SVM 的多载量小车实时调度方法,并以产量和物料搬运距离作为评价指标建立目标函数,评价调度性能。

1 问题描述

车辆装配线物料搬运系统将装配线分为若干个装配区域(见图 1),每个装配区域由若干辆多载量小车负责其所有工作站(Work station)的物料配送。

为有效说明此类调度问题,做如下基本假设:
①采用再订购点法(Reorder point policy, ROP)生成物料搬运任务;②搬运过程不可中断,即一旦进行物料搬运,必须完成所有任务;③不考虑多载

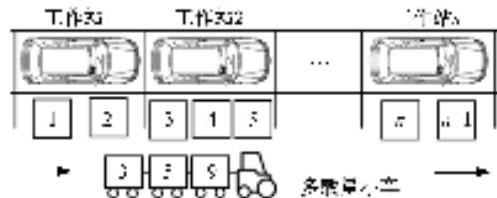


图 1 车辆装配线的一个装配区域

Fig. 1 A united layout of MHS in assembly line

量小车的失效情况;④多载量小车的行驶速度 V 恒定,无堵塞情况;⑤多载量小车每次最多配送 N_c 个料箱;⑥对于每种零件,多载量小车每次最多使用一个料箱;⑦一个料箱一次只能装载一种零件,且装载数量一定,记为 SPQ_i (Standard pack quantity);⑧多载量小车装载一个料箱的时间为 LT ,卸载时若剩余零件数量小于等于 SPQ_i 的 10%,卸料时间为 UT ,否则为 UT' , $UT' > UT$,且 LT 、 UT 和 UT' 为定值;⑨若同一时间的搬运任务数大于 N_c ,则采用 SSFP (Smallest slack-time first picked) 规则选取搬运任务,并根据 SDFD (Shortest distance first delivered) 规则完成相应的物料配送;⑩一个装配区域仅有一辆多载量小车。

为了深入分析问题,对物料搬运系统中的相关变量描述如下:装配区域设有工作站 S_j ($j = 1, 2, \dots, s$),可进行 M_1, M_2, \dots, M_N ($N \in N^+$) 种型号的车辆装配,其产品配比 $m = (\rho_1, \rho_2, \dots, \rho_N)$, $\rho_1 + \rho_2 + \dots + \rho_N = 1$ 。装配共需 p 种零件,即 P_i ($i = 1, 2, \dots, p$);线边的实时库存量为 BF_i ;平均消耗速度为 U_i ;再订购点为 R_i , $R_i = [(D_i + 2D_{\max})/V + N_c(LT + UT)] \times U_i$; D_i 、 D_{\max} 分别为搬运零件 P_i 的行驶距离及最远行驶距离。且考虑到装配线边零件缓存区的空间有限,若 $R_i > 0.5 \times SPQ_i$,则取 $R_i = 0.5 \times SPQ_i$ 。当 $BF_i \leq R_i$ 时,向调度系统发出补货需求。

令 T 为总的调度时长,调度系统的决策点 t_k ($k = 1, 2, \dots$) $\in T$ 。决策点是指在调度的实时阶段,调度系统受到某些事件的影响,如多载量小车由“忙”变为“空闲”、新增搬运任务等,触发调度系统选择让多载量小车“等待”或“搬运”的时刻。系统在每个决策点 t_k 的实时状态定义为:

$$\mathbf{X}_k = (BF_1, BF_2, \dots, BF_p, t_1^L, t_2^L, \dots, t_p^L) \quad (1)$$

式中: t_i^L 为若此刻不配送零件 P_i ,其剩余库存可维持的装配时间,即 P_i 将发生缺货的时间, t_i^L 的计算需要利用前瞻信息,即装配线在未来对该类

零件的需求信息。 BF_i 和 t_i^L 分别代表了系统当前和未来对零件 P_i 的需求程度。

调度系统在决策点 t_k 的调度决策记为 Y_k , 若“0”代表“等待”, “1”代表“搬运”, 则本文的多载量小车的实时调度问题可转化为一个“0-1”两类数据的分类问题, 即:

$$Y_k = W(\mathbf{X}_k) = \begin{cases} 0, \text{等待} \\ 1, \text{搬运} \end{cases} \quad (2)$$

由于装配系统的动态性, 两个决策点之间的时间可能很短, 因此 BF_i 必须根据调度决策 Y_k 实时更新, 可得: $BF_i(t_k^+) = BF_i(t_k^-) + Y_k \times SPQ_i$ 。其中 $BF_i(t_k^-)$ 、 $BF_i(t_k^+)$ 分别为决策点 t_k 实行 Y_k 前、后的实时库存量。当系统运行至下一个决策点 t_{k+1} 时, 则 $BF_i(t_{k+1}) = BF_i(t_k^+)$, 结合 t_{k+1} 时刻的实时信息进行决策 Y_{k+1} , 实现多载量小车的实时调度。

选择车辆装配线产量和物料搬运距离作为评价指标建立目标函数, 并采用权重和的标量化方法将其转化为单目标函数, 即:

$$f(T) = Q\omega_Q + D\omega_D \quad (3)$$

式中: Q 为产量; D 为搬运距离; ω_Q 、 ω_D 分别为对应的权重因子, ω_Q 为单位产量价值, ω_D 为单位物料搬运成本, 一般 ω_Q 取正值, ω_D 取负值, 且 $|\omega_Q|$ 远大于 $|\omega_D|$, 即物料搬运系统应尽量满足制造系统对物料的需求。

显然, $f(T)$ 值越大, 表示物料搬运的调度性能越好。因此, 对于多载量小车的实时调度方法, 应该能够实现如式(3)所定义的目标函数的最大化。

2 实时调度方法

针对调度问题的动态性, 根据多载量小车的实时调度问题与数据分类之间的相似性, 提出了基于支持向量机的多载量小车实时调度方法, 其基本框架如图 2 所示, 主要包括离线 SVM 模型训练和基于 SVM 实时决策两个阶段。

2.1 离线 SVM 训练

在离线阶段, 调度系统通过仿真随机生成一组系统状态 $\mathbf{X}_k (k=1, 2, \dots)$, 并确定这些状态对应的最优调度决策 Y_k 。利用这组状态及其对应的最优调度决策作为训练样本进行 SVM 的训练。

2.1.1 生成训练样本

通过离散事件仿真不难获取系统的实时状态 \mathbf{X}_k , 但问题的关键在于如何确定某个实时状态下

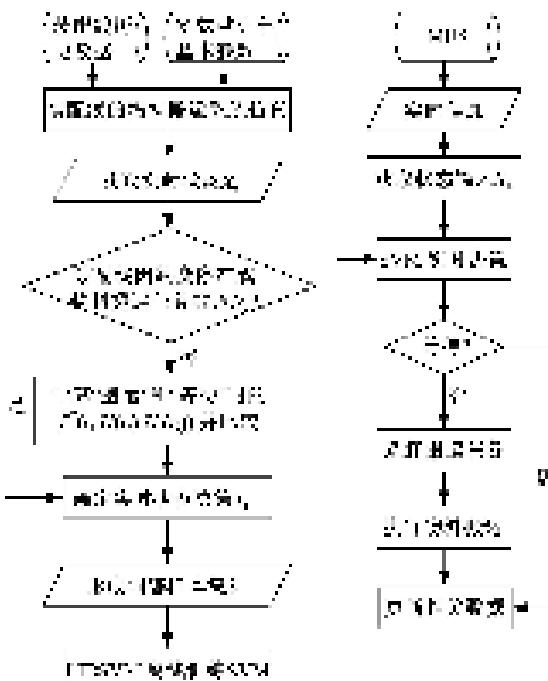


图 2 SVM 实时调度方法基本框架

Fig. 2 Framework of SVM-based scheduling approach

的最优决策 Y_k 。

为了确定调度系统在决策点 t_k 执行某个决策时对应的价值, 定义系统在 t_k 时所能获得的最高目标函数值为:

$$f^*(t_k, H(t_k), H'(t_k)) \quad (4)$$

式中: $H(t_k)$ 为 t_k 时刻已经生成的搬运任务; $H'(t_k)$ 为预计在区间 $(t_k, t_k + L]$ 内将生成的搬运任务, L 为前瞻时间。

在 t_k 时刻, 调度系统可以选择“等待”或“搬运”, 因此在决策点 t_k 处的最高目标函数值为分别选择“等待”或“搬运”之后所能获得的最高目标函数值的较大者, 即:

$$f^*(t_k, H(t_k), H'(t_k)) = \max\{g^*(t_k, H(t_k), H'(t_k)), f^*(t_k, H(t_k), H'(t_k))\} \quad (5)$$

式中: $g^*(t_k, H(t_k), H'(t_k))$ 为调度系统在 t_k 时刻选择“搬运”的最大目标函数值, 即:

$$g^*(t_k, H(t_k), H'(t_k)) = f_m(H(t_k)) + f^*(t'_k, H(t'_k), H'(t'_k)) \quad (6)$$

式中: t'_k 为在 t_k 选择搬运并完成搬运任务后变成空闲状态的时刻; $f_m(H(t_k))$ 为在该次搬运过程中的系统目标函数值, 且:

$$f_m(H(t_k)) = \omega_Q \cdot \frac{t_w}{CT} + \omega_D \cdot d_H(H(t_k)) \quad (7)$$

式中: t_w 为期间装配线的实际装配时间; CT 为装

配周期; t_w/CT 为该段时间内的装配线产量; $d_H(H(t_k))$ 为本次搬运过程中的行驶距离。

根据式(5)(6)可得:

$$f^*(t_k, H(t_k), H'(t_k)) = \max\{f^*(t_{k+1}, H(t_{k+1}), H'(t_{k+1})), f_m(H(t_k)) + f^*(t'_k, H(t'_k), H'(t'_k))\} \quad (8)$$

由式(8)可知,调度系统在决策点 t_k 时,通过递归方法得到在时间段 $(t_k, t_k + L]$ 内的最高目标函数值 $f^*(t_k, H(t_k), H'(t_k))$ 及其对应的最优决策 Y_k 。值得注意的是,如果在决策点 t_k 时某零件缺货导致装配线暂停或已经生成的搬运任务数大于等于 N_c ,则 Y_k 只能为“1”,即必须立即让多载量小车执行已有的搬运任务。因此,通过仿真生成实时状态 \mathbf{X}_k ,结合以上递归运算得出最优决策 Y_k ,得到一个 SVM 训练样本 (\mathbf{X}_k, Y_k) 。 l 个样本形成训练样本集 $S = (\mathbf{X}, Y) = \{(\mathbf{X}_k, Y_k) | k = 1, 2, \dots, l\}$,其中, $\mathbf{X} \in \mathbf{R}^n$, $Y = \{0, 1\}$, n 为系统实时状态的特征量个数(即 SVM 有 n 个输入量,本文中 $n = 2p$)。但是,在实际操作过程中,很难获取关于装配线物料搬运过程完整的实时数据,因此,采用 eM-Plant 仿真软件来模拟真实的调度过程,收集相关样本数据。

2.1.2 训练 SVM

SVM 是一种新型机器学习方法,具有理论严密、适应性强、全局优化、训练效率高和泛化性能好等优点,并在一定程度上克服了维数灾难和过学习等传统困难。在多载量小车的实时调度过程中,调度系统只需判断在决策点时的最佳决策是“等待”或“搬运”,故采用 SVM 模型对多载量小车的实时状态进行“等待”或“搬运”决策。

SVM 模型的原始优化问题为:

$$\begin{cases} \min \frac{1}{2} \boldsymbol{\omega}^T \boldsymbol{\omega} + C \sum_{i=1}^l \xi_i \\ \text{s. t. } Y_i(\boldsymbol{\omega}^T \Phi(\mathbf{X}_i) + b) \geq 1 - \xi_i \\ \xi_i \geq 0, \forall i = 1, 2, \dots, l \end{cases} \quad (9)$$

式中: $\boldsymbol{\omega}$ 为多维分类面的法向量; b 为多维分类面与坐标原点之间的距离; ξ_i 为松弛变量。

其对偶形式为:

$$\begin{cases} \min \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l Y_i Y_j K(\mathbf{X}_i, \mathbf{X}_j) \boldsymbol{\alpha}_i \boldsymbol{\alpha}_j - \sum_{i=1}^l \boldsymbol{\alpha}_i \\ \text{s. t. } 0 \leq \boldsymbol{\alpha}_i \leq C, \forall i = 1, 2, \dots, l \end{cases} \quad (10)$$

式中: $K(\mathbf{X}_i, \mathbf{X}_j) = \Phi(\mathbf{X}_i)^T \Phi(\mathbf{X}_j)$ 为核函数,本文选用径向基核函数(Radical basic function,

RBF),即 $K(\mathbf{X}_i, \mathbf{X}_j) = \exp(-\gamma \| \mathbf{X}_i - \mathbf{X}_j \|^2)$; γ 为核参数,控制了核函数的径向作用范围,反映了训练样本集的特征; C 为惩罚系数,用于控制被最优分割平面错分的样本数,其平衡模型的计算复杂度和错误分类程度。

C 和 γ 是训练 SVM 时的两个关键参数,对于 SVM 及参数说明详见文献[12]。在求解式(10)后构造决策函数进行数据分类,即:

$$f(\mathbf{X}) = \text{sgn}(\boldsymbol{\omega}^T \Phi(\mathbf{X}) + b) = \text{sgn}\left(\sum_{i=1}^l Y_i \boldsymbol{\alpha}_i K(\mathbf{X}_i, \mathbf{X}) + b\right) \quad (11)$$

综上所述,SVM 训练可分为以下 3 个步骤:

(1) 确定输入特征量个数 n 、收集训练样本集 S 、选择 SVM 模型;

(2) 通过 RBF 将 S 中的数据映射到高维特征空间(Hilbert 空间)中、选取 C 和 γ 、求解式(10)获得 $(\boldsymbol{\omega}, b)$ 及对应的支撑向量 $\boldsymbol{\alpha}$;

(3) 通过 $(\boldsymbol{\omega}, b)$ 及支撑向量 $\boldsymbol{\alpha}$ 建立多载量小车的实时调度决策模型。

本文采用 LIBSVM^[13] 训练 SVM,并应用到实时 SVM 决策中。

2.2 实时 SVM 调度决策

在实时阶段,调度系统不断从装配线的制造执行系统(Manufacturing execution system, MES) 获取实时信息,当到达决策点 t_k 时,构造一个用于 SVM 分类的实时状态作为 SVM 的输入,即 $\mathbf{X}_k = (BF_1, BF_2, \dots, BF_p, t_1^L, t_2^L, \dots, t_p^L)$ 。然后利用训练好的 SVM 确定该输入的分类 Y_k 为 0 或 1。若为“0”,则多载量小车继续等待,直至下一个决策点 t_{k+1} ;否则,调度系统分别根据 SSFP 和 SDFD 规则选择搬运任务并确定搬运次序,执行搬运任务,结束搬运后等待下一个决策点 t_{k+1} 。如此循环往复,实现多载量小车的实时调度。

3 仿真实验及分析

3.1 仿真实验案例参数

本案例来源于美国通用汽车公司某个汽车装配区域的实际数据。该汽车装配线共生产 3 种车型 M_1, M_2 和 M_3 ,且 $m = (0.2, 0.5, 0.3)$ 。仿真设 6 个装配工作站 $S_1 \sim S_6$,14 种零件 $P_1 \sim P_{14}$,表 1 列出了物料清单、SPQ_i 和零件库存区到各卸料点之间距离 D_i 。该装配线周期时间 CT 为 72 s,各工作站的工作时间服从最小值为 70 s、最大值为 75 s、众数为 72 s 的三角分布,且平均故障间

隔时间为 54 min, 平均恢复时间为 12 s。多载量小车的速度 $V=3.05 \text{ m/s}$, $N_c=3$, $LT=36.6 \text{ s}$, $UT=43.2 \text{ s}$, $UT'=103.2 \text{ s}$ 。使用 eM-Plant 软件建立仿真模型, 其布局如图 3 所示。

表 1 物料清单、 SPQ_i 及搬运距离Table 1 BOM, SPQ_i and delivery distance

P_i	M_1	M_2	M_3	SPQ_i	D_i / m
P_1	1	1	1	95	163
P_2	1	0	0	16	172
P_3	1	0	0	18	184
P_4	1	0	0	18	300
P_5	0	1	1	60	303
P_6	0	1	0	22	406
P_7	1	1	1	120	479
P_8	1	0	1	70	515
P_9	0	1	0	20	532
P_{10}	0	0	1	50	690
P_{11}	1	0	0	90	709
P_{12}	0	1	0	90	724
P_{13}	0	0	1	36	746
P_{14}	1	1	0	100	821

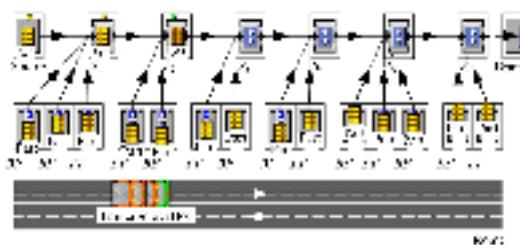


图 3 车辆装配线仿真布局

Fig. 3 Layout of an assembly line simulation

3.2 SVM 训练及验证

通过仿生成训练样本 $S=(\mathbf{X}, Y)=\{(\mathbf{X}_k, Y_k) | k=1, 2, \dots, 6000\}$, LIBSVM 默认惩罚系数 $C=1$, 核参数 $\gamma=1/n$, 选用 RBF, 运用 LIBSVM 训练 SVM。为了验证 SVM 分类模型的性能, 进行 K-CV 交叉验证(K-fold cross validation), 可有效地避免过学习和欠学习状态的发生, 经 K-CV 可得分类准确率达 88.7159%。对于该 6000 个样本数据, 取其中的 4000 个作为训练集训练模型, 2000 个作为验证集进行验证, 此时分类准确性达 93.5665%。运用训练好的 SVM 进行多载量小车的实时调度, 单次调度决策所需时间约为 0.016545 s。因此, 无论是准确度还是响应速度, 本文方法都适用于实际的生产调度。

3.3 调度性能比较

为了有效地评价本文方法性能, 以目标函数值作为评价指标, 通过试验与最小批量法 (Minimum batch size, MBS)^[14] 性能进行比较。 x 为最小批量, 根据 MBS- x 规则, 如果当前需要处理的搬运任务数少于 x , 那么多载量小车继续等待; 否则开始搬运。

分别取 $x=1, 2, 3$, 即共有 4 种调度方法, 每种方法进行 20 次仿真, 每次仿真时间为 240 h, 其中包括 24 h 的预热时间。

3.3.1 默认参数设置下的性能比较

取 $\omega_Q=1, \omega_D=-0.00262$, 按照 3.1 节中参数进行仿真。表 2 为分别使用 SVM、MBS-1、MBS-2 和 MBS-3 方法的仿真结果。由表 2 可知, 随着最小批量 x 的增大, MBS- x 方法得到的产量和搬运距离均逐渐减少, 目标函数值变大。SVM 方法与最佳的 MBS-3 方法在物料搬运距离上相差较少, 但产量却提高了 3.79%, 因此目标函数最大。与 MBS-1、MBS-2、MBS-3 方法相比, SVM 方法的性能分别提高了 14.30%、4.58% 以及 3.34%。

表 2 不同调度方法的性能比较

Table 2 Performance of different approaches

调度方法	产量		搬运距离		目标函数值	
	均值/个	差距/%	均值/m	差距/%	均值	差距/%
SVM	11703	0.03	690047	6.10	9895.08	0
MBS-1	11706	0	1163708	44.32	8657.09	14.30
MBS-2	11519	1.62	785161	17.48	9461.88	4.58
MBS-3	11273	3.84	647936	0	9575.41	3.34

3.3.2 不同 R_i 设置下的性能比较

由于所有的调度方法都根据再订购点法生成补货需求, 考虑到不同的 R_i 设置可能对调度方法的性能产生影响, 因此通过设定不同的再订购点进行仿真, 从而更充分地评价 SVM 方法性能。如表 3 所示, 本次仿真试验共设定 10 组不同的再订购点 R_i 。

试验结果如图 4 所示, 从图 4 可以看出: 这 4 种调度方法的目标函数值都随着 R_i 的变化发生较大变化。如 SVM 方法在第 1 组 R_i 设置下目标函数值为 8509.56, 在第 6 组时为 9895.08, 两者相差 16.3%。随着 R_i 增大, 目标函数值均显著增大, 当达到第 6 组(即默认的 R_i 设置)及以后, 目标函数值波动较小, 且 SVM 方法的目标函数值均远大于 MBS-1、MBS-2 和 MBS-3 方法。因此, 即使采用不同的 R_i 设置, 本文所提出的基于 SVM

表 3 不同的 R_i 设置Table 3 Different setting of R_i

P_i	试验组别									
	1	2	3	4	5	6	7	8	9	10
P_1	2	4	6	8	10	12	14	16	18	20
P_2	2	4	6	8	8	8	8	8	8	8
P_3	2	4	6	8	9	9	9	9	9	9
P_4	3	4	7	8	9	9	9	9	9	9
P_5	3	4	7	8	9	12	14	16	18	20
P_6	4	5	7	9	9	11	11	11	11	11
P_7	4	5	7	9	9	13	15	16	18	20
P_8	4	6	8	9	10	13	15	17	18	21
P_9	4	6	8	9	10	10	10	10	10	10
P_{10}	5	7	8	10	11	14	16	17	19	21
P_{11}	5	7	8	10	11	14	16	17	19	21
P_{12}	5	7	8	10	11	14	16	17	19	21
P_{13}	6	8	9	11	12	14	17	18	18	18
P_{14}	6	8	9	11	12	15	17	18	19	22

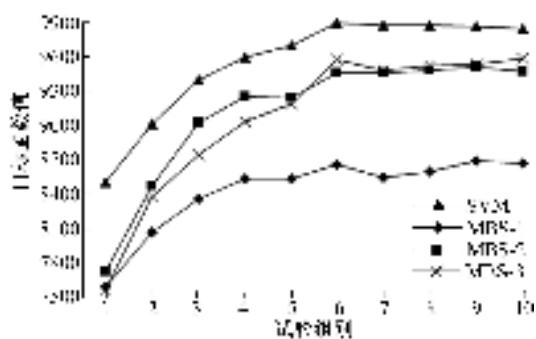
图 4 不同 R_i 设置下的目标函数值比较

Fig. 4 Comparison of performances with different R_i 的实时调度方法优于 MBS- x 调度方法。

3.3.3 动态环境中的调度性能比较

为了验证本文方法能够适应动态环境的调度需求,本节将比较这些方法在不同的产品配比 m 和调度目标权重 ω_Q, ω_D 设定下的性能。

(1) 改变产品配比 m

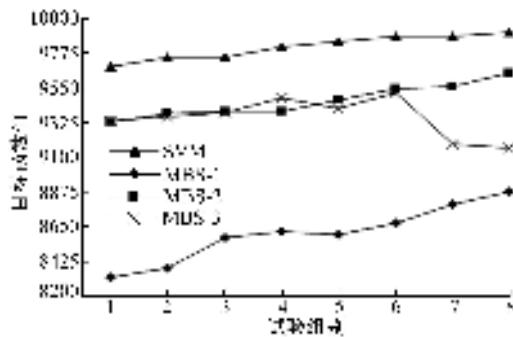
如表 4 所示,共设定 8 组不同的 m ,试验结果如图 5 所示。随着 m 的变化,各调度方法的目标函数值均发生变化,SVM 方法的目标函数值整体高于 MBS- x 方法。因此,与 MBS- x 方法相比,SVM 方法对产品配比(即对实际的市场需求)变化的适应性较好。

(2) 改变调度目标权重 ω_Q, ω_D

为便于比较,设定 $\omega_Q = 1$ 保持不变, ω_D 从 0 到 -0.009 17 取 8 个不同的值进行试验,试验结

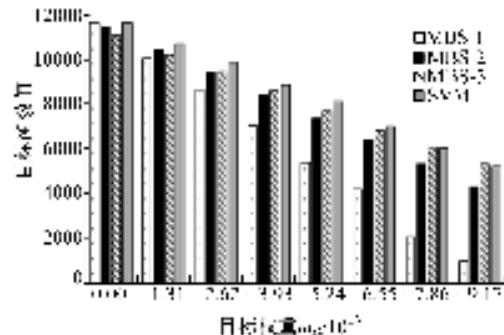
表 4 不同的 m 设置Table 4 Different setting of m

M_i	试验组别							
	1	2	3	4	5	6	7	8
M_1	0.1	0.1	0.2	0.2	0.3	0.3	0.4	0.4
M_2	0.8	0.7	0.6	0.5	0.4	0.3	0.2	0.1
M_3	0.1	0.2	0.2	0.3	0.3	0.4	0.4	0.5

图 5 不同 m 设置下的目标函数值比较Fig. 5 Comparison of performances with different m

果如图 6 所示。由图 6 可知,各个调度方法的目标函数值都随着 ω_D 的变化而变化。当 $|\omega_D|$ 较大(ω_D 较小)时,即每单位搬运距离对应的搬运成本增加,目标函数值都较低,相反则较高。在这 8 组不同的调度目标权重设置中,SVM 方法的目标函数值整体优于其他方法。但是,当 ω_D 较小时,即单位物料搬运成本对调度目标影响较大时,SVM 方法的目标函数值略低于 MBS-3 方法;当 $\omega_D = 0$,即只考虑产量时,SVM 的目标函数值略低于 MBS-1 方法。因此,当某一调度目标的权重远大于其他调度目标权重时,SVM 方法仍有待进一步优化以提高物料搬运调度的性能。

综上所述,SVM 方法能够根据动态制造环境中的产品配比、调度目标权重等因素的变化,通过

图 6 不同 ω_Q, ω_D 下的目标函数值比较Fig. 6 Comparison of performances with different ω_Q and ω_D

SVM的机器学习做出相同状态下的最佳决策,具有一定的自适应性。

4 结束语

针对车辆装配系统中物料搬运系统的特点,提出了基于支持向量机的多载量小车实时调度方法。在离线阶段建立装配线物料搬运系统的仿真模型,生成样本训练SVM模型;在实时调度阶段利用SVM确定多载量小车等待或搬运的决策。试验结果表明:本文提出的实时调度方法准确率高,调度效果好;在实时阶段运行快速,符合实时调度需求,且对动态环境变化具有一定的自适应性。但是,本文仅对单个多载量小车的实时调度方法进行了探讨,今后将针对一个物流区域同时使用多个搬运设备及多个物流区域间相互关联的情况对多载量小车的实时调度进行深入探究。

参考文献:

- [1] Chang Q, Pan C, Xiao G, et al. Integrated modeling of automotive assembly line with material handling [J]. Journal of Manufacturing Science and Engineering, 2013, 135(1):011018.
- [2] Egbelu P J, Tanchoco J M A. Characterization of automatic guided vehicle dispatching rules[J]. International Journal of Production Research, 1984, 22(3):359-374.
- [3] Sabuncuoglu I. A study of scheduling rules of flexible manufacturing systems: a simulation approach [J]. International Journal of Production Research, 1998, 36(2):527-546.
- [4] Wu L H, Mok P Y, Zhang J. An adaptive multi-parameter based dispatching strategy for single-loop interbay material handling systems[J]. Computers in Industry, 2011, 62(2):175-186.
- [5] Hsieh C H, Cho C, Yang T, et al. Simulation study for a proposed segmented automated material handling system design for 300-mm semiconductor fabs [J]. Simulation Modelling Practice and Theory, 2012, 29(1):18-31.
- [6] Godinho F M, Barco C F, Neto R F T. Using genetic algorithms to solve scheduling problems on flexible manufacturing systems (FMS): a literature survey, classification and analysis [J]. Flexible Services and Manufacturing Journal, 2014, 26(3): 408-431.
- [7] Ho Y, Liu H, Yih Y. A multiple-attribute method for concurrently solving the pickup-dispatching problem and the load-selection problem of multiple-load AGVs[J]. Journal of Manufacturing Systems, 2012, 31(3): 288-300.
- [8] 朱琳,范秀敏,何其昌.柔性生产系统配料区多自动导航小车调度优化[J].计算机集成制造系统,2012,18(6):1168-1175.
Zhu Lin, Fan Xiu-min, He Qi-chang. Scheduling optimization for multi-AGVs in batching area of flexible production system[J]. Computer Integrated Manufacturing Systems, 2013, 18(6):1168-1175.
- [9] Chen C, Xi L F, Zhou B H, et al. A multiple-criteria real-time scheduling approach for multiple-load carriers subject to LIFO loading constraints[J]. International Journal of Production Research, 2011, 49(16): 4787-4806.
- [10] Fathi M, Alvarez M J, Hassani M F, et al. A multiobjective optimization algorithm to solve the part feeding problem in mixed-model assembly lines[J]. Mathematical Problems in Engineering, 2014, 2014: 654053.
- [11] 赵芳,马玉磊.自训练半监督加权球结构支持向量机多分类方法[J].重庆邮电大学学报:自然科学版,2014,26(3):404-408.
Zhao Fang, Ma Yu-lei. Multi-class classification based on self-training semi-supervised weighted sphere structured support vector machine[J]. Journal of Chongqing University of Posts and Telecommunications(Natural Science Edition), 2014, 26(3): 404-408.
- [12] 邓乃扬,田英杰.支持向量机——理论、算法与拓展[M].北京:科学出版社,2009.
- [13] Chang C C, Lin C J. LIBSVM:a library for support vector machines [DB/OL]. [2015-04-25]. <http://www.csie.ntu.edu.tw/~cjlin/papers/libsvm.pdf>.
- [14] Neust M F. A general class of bulk queues with Poisson input[J]. The Annals of Mathematical Statistics, 1967, 38(3): 759-770.