

数据驱动下的半导体生产线动态调度方法

吴启迪, 马玉敏[†], 李 莉, 乔 非

(同济大学 电子与信息工程学院, 上海 201804)

摘要: 本文研究了一种数据驱动下的半导体生产线调度框架, 该框架基于调度优化数据样本, 应用机器学习算法, 获得动态调度模型, 通过该模型, 对于半导体生产线, 能够根据其当前的生产状态, 实时地定出近似最优的调度策略。在此基础上, 利用特征选择和分类算法, 提出一种生成动态调度模型的方法, 并且具体实现出一种混合式特征选择和分类算法的调度模型: 先采用过滤式特征选择方法对生产属性进行初步筛选, 然后再采用封装式特征选择和分类方法生成模型以提高模型生成的效率。最后, 在某实际半导体生产线上, 对在所提出的框架上采用6种不同算法实现的动态调度模型进行测试, 并对算法性能数据和生产线性能数据进行对比和分析。结果表明, 数据驱动下的动态调度方法优于单一的调度规则, 同时也能满足生产线调度实时性要求。在数据样本较多的情况下, 建议采用本文所提出的方法。

关键词: 半导体生产线; 动态调度; 数据驱动; 特征选择; 分类算法

中图分类号: TP273 文献标识码: A

Data-driven dynamic scheduling method for semiconductor production line

WU Qi-di, MA Yu-min[†], LI Li, QIAO Fei

(School of Electronics and Information, Tongji University, Shanghai 201804, China)

Abstract: This paper investigates a framework of data-driven scheduling method for semiconductor production line. Based on optimized scheduling data samples, this framework applies machine learning algorithm to obtain the dynamic scheduling model. Using this model, we determine the approximate optimal scheduling strategy for the production line under the current production status. On this basis, we propose a method based on feature selection and classification to generate a dynamic scheduling model, and provide a realization by means of a hybrid algorithm of feature selection and classification as such: production attributes are primarily selected by using a filter selection algorithm, and then the wrapped selection and classification algorithm is employed to produce the scheduling model. On a real semiconductor production line, the proposed framework is tested by using the dynamic scheduling models realized by 6 different algorithms. The performance data of algorithms and the production performance using different scheduling methods are compared and analyzed. The data shows that the data-driven dynamic scheduling methods are superior to the method with simple dispatching rule, and satisfy the real-time scheduling requirements for the production line. In the case with large size of sample data, the application of the proposed method is even preferable.

Key words: semiconductor production line; dynamic scheduling; data-driven; feature selection; classification method

1 引言(Introduction)

半导体生产线是一个动态系统, 存在着各种不确定因素(如机器损坏、紧急工件的插入、交货期变更等), 一旦产生扰动, 当前所使用的“最佳”调度策略就有可能失去时效, 这种因实时事件而发生的调度问题称作为“动态调度”^[1]。一般而言, 制造系统的动态调度可通过3种方式实现: 1) 遍历仿真, 即通过遍历仿真一组预先设定的调度规则, 选择其中能提供最优性

能的调度策略作为生产线调度策略^[2]; 2) 强化学习(reinforcement learning), 它是一种无导师的在线学习, 通过试探调度策略与制造系统环境直接交互来实现, 制造系统根据其提供调度策略产生的系统性能反馈相应的奖赏或惩罚, 动态调度模块评价反馈并对调度策略进行调整优化^[3-4]; 3) 数据驱动(基于数据的), 即采用数据挖掘方法, 从优化的调度样本学习调度知识, 应用该学习模型, 可根据实时系统状态获取适合

收稿日期: 2015-03-26; 录用日期: 2015-08-07。

[†]通信作者。E-mail: ymma@tongji.edu.cn; Tel.: +86 21-69588911-8630。

国家自然科学基金项目(610340004, 61273046, 51475334), 中央高校基本科研业务费专项资金资助。

Supported by National Natural Science Foundation of China (610340004, 61273046, 51475334) and Fundamental Research Funds for the Central Universities.

的调度规则。数据驱动下的动态调度已有一些学者做相关研究,例如,Shiue等人^[5]提出一种基于自组织映射神经网络的调度规则实时选择机制;Tsai等人^[6]提出一种面向全自动半导体制造车间的基于RFID的实时调度系统,它对训练样本进行特征选择并建立了一个基于SVM的动态调度模型;Olafsson等人^[7]提出一种基于GA和决策树的动态调度策略选择方法;Li等人^[8]则采用BP神经网络、二元回归模型和粒子群算法学习样本,从而获得自适应调度规则的参数学习模型,以适应动态调度需要;Qiao^[9]和Ma等人^[10]分别采用BPSO-SVM和K-NN算法实现半导体生产线的动态调度。这些文献提出了各种有效的方法,但不难发现它们基于一个共同的框架,本文将就半导体动态调度框架展开研究,在此框架下研究多种调度算法的集成,用户可根据需求加以选择。

2 数据驱动下的半导体生产线动态调度框架(A framework of data-driven dynamic scheduling system for semiconductor production line)

半导体生产线调度问题可描述为 $\{P, D, F\}$,其中: P 为生产线性能指标的集合, F 为半导体生产线生产属性(特征)全集, D 为在生产状态 F 下满足 P 近似最优的调度策略集合(或调度参数组合)。由于半导体生产线复杂,生产属性繁多,在调度决策时,为了提高调度效率,只需考察关键的生产属性(特征),即以生产属性(特征)全集 F 为对象,通过特征选择,从 F 中选出合适的生产属性(特征)子集 SF ;然后应用数据挖掘算法,实现由 SF 到 D 的快速映射,即任意给定一组生产属性(特征)子集,将找到满足系统性能指标近似最优的调度策略。

根据此思想,所设计的数据驱动下的半导体生产线动态调度系统的框架如图1所示。

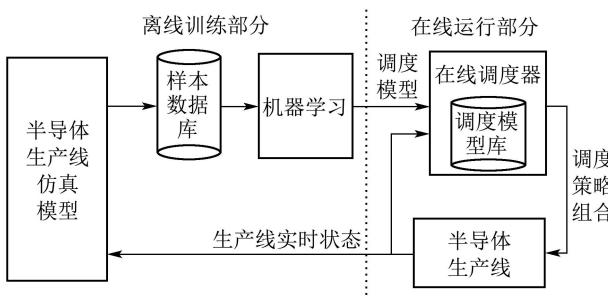


图1 数据驱动下的半导体生产线动态调度系统框架

Fig. 1 A framework of data-driven dynamic scheduling system for semiconductor production line

整个框架分为两部分:离线训练部分和在线运行部分,其中,离线训练部分包括生成样本数据的仿真模型、样本数据库和机器学习模块,用以生成在线调度器所使用的调度模型;在线运行部分则包括生产线

实时状态数据的采集和在线调度器。各部分的具体的功能分别为:

半导体生产线仿真模型: 它是一个面向对象的半导体生产线仿真模型,可根据MES中的数据动态生成,确保了模型中对象及其状态与实际生产线同步。运行仿真模型一个调度周期(如4 h或8 h)生成原始的数据样本 $\{F, D', P'\}$,其中: F 为生产线状态数据, D' 为生产线采用的候选调度策略组合, P' 为采用调度策略组合 D' 后生产线模型运行一个调度周期获得的各项性能指标,如:设备利用率、出片率、移动步数MOV, Turn等。根据调度目标,筛选出此目标下的最佳数据样本,从而形成学习样本 $\{F, D\}$ 。

机器学习: 动态调度算法属于分类算法,根据数据样本,通过机器学习生成调度分类模型(即调度模型),供生产线调度器使用。目前有很多机器学习算法可供使用,如人工神经网络(ANN)、K-NN近邻算法、支持向量机(SVM)、极限学习机(ELM)算法等。

在线调度器: 在线调度器包含了一个调度模型库,调度模型由机器学习获得。在线调度器根据调度目标(如:出片率最优、设备利用率最优或综合指标最优)选择相应的调度模型,得到当前生产线状态下近似最优的调度策略组合。

3 基于特征选择和分类算法的半导体生产线动态调度模型生成(Generation of scheduling model for semiconductor production line based on feature selection and classification methods)

一个半导体生产线状态由诸多特征数据(状态数据)表示,为了减少不相干的特征数据的干扰并提高实际应用的学习效率,需要进行特征选择。特征选择可以采用优化算法,如遗传算法(GA)、二进制粒子群算法(BPSO)、模拟退火算法(SA)等。特征选择方法根据其与后续分类学习算法结合的方式,可分成3类:嵌入式(Embedded)、过滤式(Filter)和封装式(Wrapper)。其中,嵌入式特征选择方法将特征选择算法嵌入到分类算法中;过滤式特征选择方法独立于具体的分类学习算法,其评价标准直接由数据集求得;封装式特征选择方法将分类模型的分类精度作为特征选择评估标准。为此,本文提出了基于特征选择和分类算法的半导体生产线动态调度模型生成框架,如图2所示。

动态调度模型生成分为两部分:生产特征选择和调度策略分类。其中生产特征选择包含了过滤式特征选择方法(如:遗传算法+信息熵、微粒子群算法+互信息等)、封装式特征选择方法(如:遗传算法+极限学习机、微粒子群算法+支持向量机等)和混合式特征选择方法(即两种方法相结合),最终输出生产特征子集,如

采用封装式特征选择方法,还会输出分类算法中的一些算法参数;调度策略分类方法可选用各种分类学习方法,若选用封装式特征选择方法时,则应与特征选择方法中的分类方法一致,用户可以自由组合使用.

输入测试样本检测所得到的调度(分类)模型精度能否满足需求,若不满足,则需要重新调整算法参数或调整训练样本重新进行学习;如满足需求,则输出调度模型,应用于生产线在线调度器中.

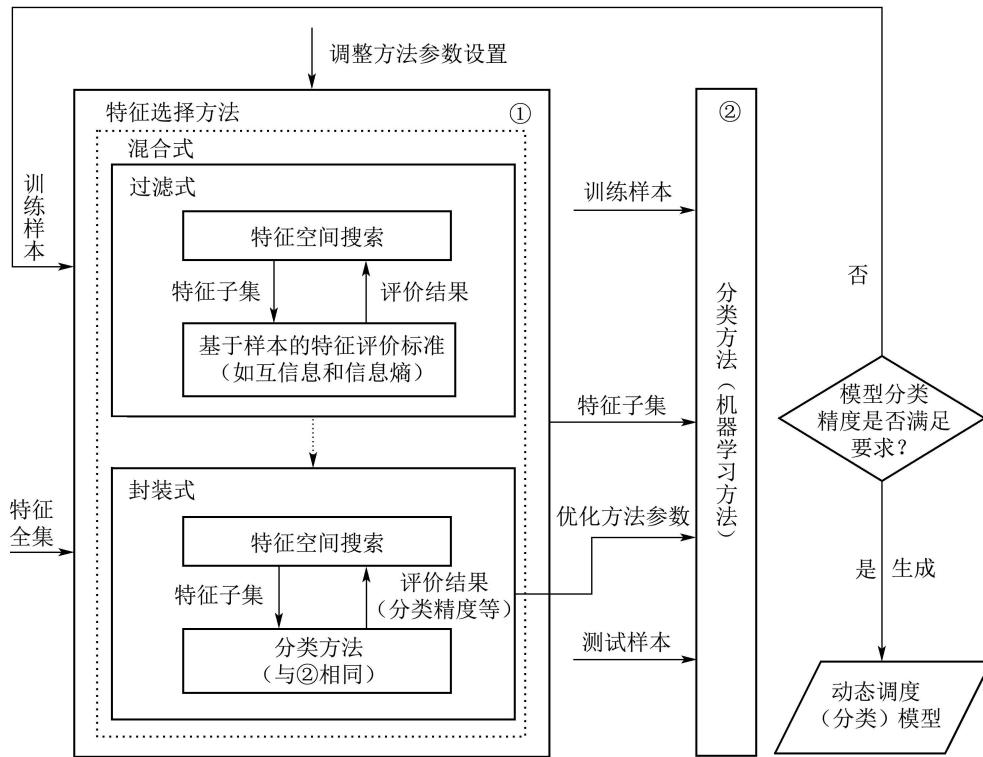


图2 基于特征选择和分类算法的半导体生产线动态调度模型生成

Fig. 2 Generation of a scheduling model for semiconductor production line based on feature selection and classification methods

4 基于GA-SAGA-ELM的动态调度模型的实现(Implementation of a dynamic scheduling model based on GA-SAGA-ELM)

由于半导体生产线复杂,特征描述多,这里,结合过滤式特征选择和封装式特征选择和分类方法实现动态调度模型,即先采用过滤式特征选择初步剔除大部分无关或冗余特征,保留一部分有效特征,再将筛选后的特征子集作为输入参数传递给封装式特征选择方法,进一步选择特征子集.通过这种方法既可以选择较优的子集,又加快了运算速度,适用于半导体生产线这类复杂的制造系统.由于采用遗传算法(GA)作为特征选择方法,可以从大量候选特征中搜索所有可能的最优特征子集^[11-12];为了避免获得局部最优解,将遗传算法与模拟退火算法(SA)相结合,以提高遗传算法局部搜索能力,而ELM又具有训练速度快、泛化性好等优点,因此,本文选用GA-SAGA-ELM混合式特征选择和分类算法来建立动态调度模型,其框架如图3所示.

该框架基于半导体生产线仿真模型,通过遍历仿真不同的调度策略,采集半导体生产线数据,从而建立调度模型学习所需要的样本,将样本分为训练样本集TE1和测试样本集TE2.其中,训练样本用于调度模型的训练,测试样本用于测试训练所得到的调度模型的分类精度.当调度模型的分类精度满足要求时,则确定所获得的调度模型是最终的调度模型.具体的算法如下:

输入: 动态调度模型的样本TE(包括生产属性集和调度策略), GA算法的参数—种群规模sizepop、交叉概率 P_c 、变异概率 P_m 和最大进化代数MaxGen; SAGA算法的参数—种群规模为sizepop'、交叉概率 P'_c 、变异概率为 P'_m 、最大进化代数为MaxGen'、退火初始温度为 T_0 、温度冷却系数为 k ; ELM算法参数—隐含层神经元个数N、隐含层神经元的激活函数 $g(x)$.

算法的输出为: 生产属性(特征)初选子集 SF^* 、最优生产属性(特征)子集 SF 、ELM分类模型输出层权值 V .

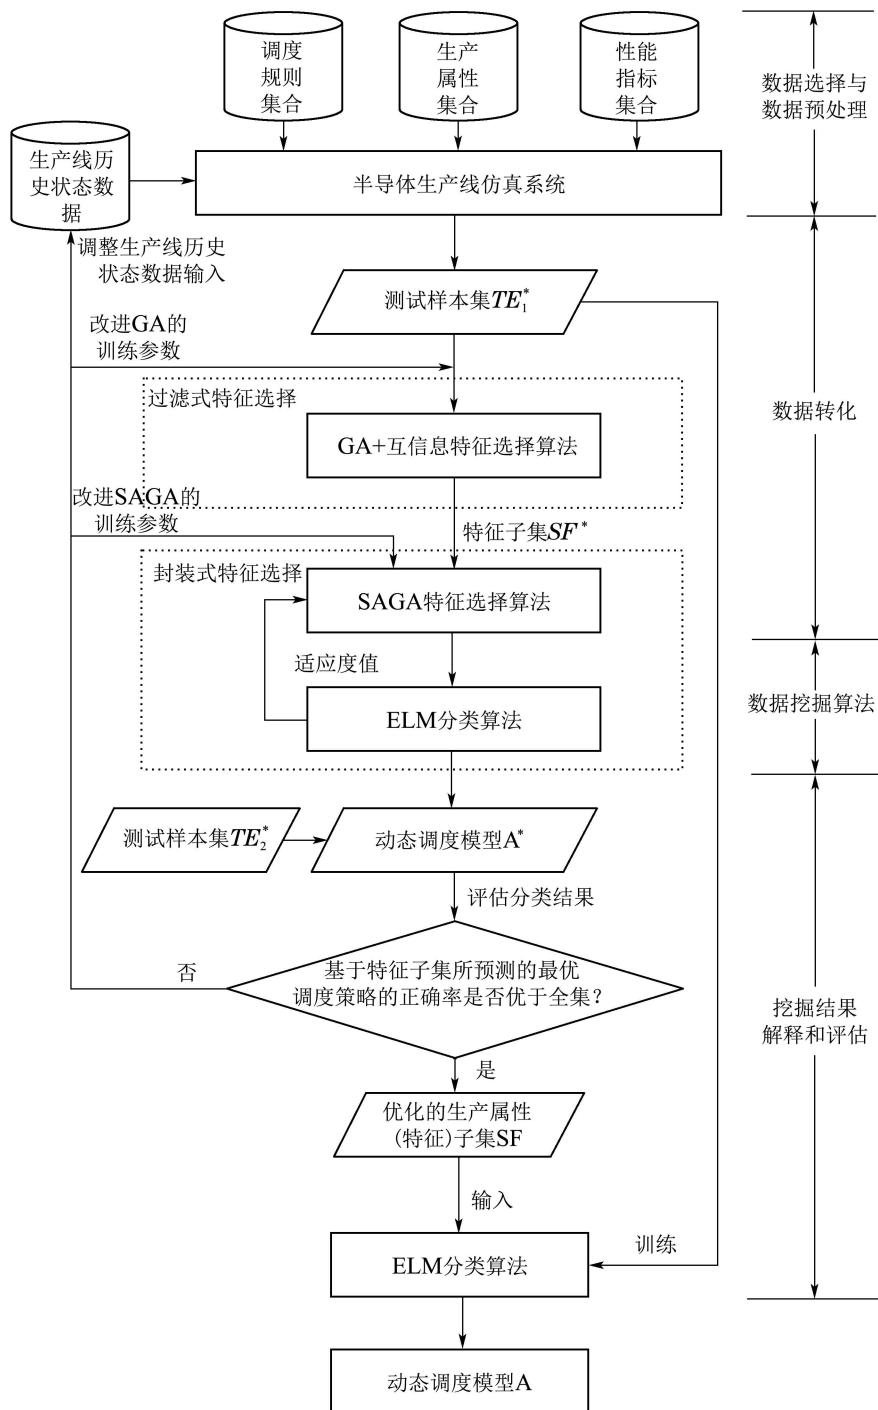


图3 基于GA-SAGA-ELM的半导体生产线动态调度模型生成框架

Fig. 3 A generation framework of scheduling model for semiconductor production line based on GA-SAGA-ELM

GA-SAGA-ELM算法流程如下：

- 1) 对生产属性(特征)集进行二进制编码(即“1”表示该生产属性被选中, 模型训练时将加以考虑, “0”则反之), 初始化GA种群;
- 2) 对种群中的个体(即染色体)进行解码, 根据生产属性(特征)子集得到初步约简的样本;
- 3) 通过计算互信息评价生产属性(特征)子集的优劣, 直到达到最大进化代MaxGen, 输出生产属

性(特征)初选子集 SF^* , 执行步骤4); 否则经过选择、交叉、变异形成新种群, 返回步骤2);

- 4) 将步骤3)获得的生产属性(特征)初选子集 SF^* 中的生产属性进行二进制编码, 初始化SAGA 算法, 包括种群规模为 $sizepop'$, 交叉概率 P'_c , 变异概率为 P'_m 等;

- 5) 对种群中的个体(即染色体)进行解码, 获得最优生产属性(特征)子集的候选解, 进一步约简样

本TE维数,然后将样本分为训练样本 TE_1 和测试样本 TE_2 ;

6) 初始化ELM算法,包括隐含层神经元个数 N ,隐含层神经元的激活函数 $g(x)$ 随机设置输入层与隐含层间的连接权值 ω 和隐含层神经元的偏置 θ ;

7) 将训练样本 TE_1 中的最优生产属性(特征)子集作为输入层变量,调度策略作为输出层变量。计算输出层权值 V ,形成ELM分类模型。测试样本 TE_2 评估每条染色体形成分类模型的分类精度,计算染色体的适应度值;

8) 如果达到最大迭代代数MaxGen',输出最优生产属性(特征)子集 SF ,否则用模拟退火法的状态转移操作产生新种群,经过选择、交叉、变异,返回步骤5),直到满足终止条件为止。

5 数据对比分析(Data analysis)

5.1 实验问题集的选取(Selection of problem sets)

实验对象是上海某硅片制造公司的一条5,6吋硅片混合生产线,共有800多台设备、平均WIP数达8万片以上。本文从生产线属性和加工区属性的角度选出67个生产属性进行分析研究^[13],重点对氧化扩散区和光刻区调度策略组合进行考察,这里,对各区域候选的调度规则集设定如下:

1) 氧化扩散区: GR(企业经验调度规则)、LB(负载均衡调度规则);

2) 光刻区: GR(企业经验调度规则)、最短工序时间优先调度(SPT)、最小松弛时间优先调度(LS)。

调度目标:

同时综合考虑以下4个性能指标: 硅片总移动量(MOV_All)、出片率(TP)、硅片平均移动量(Turn)、设备总体利用率(OEE)。

动态调度方法包括本文中所设计的GA-SAGA-ELM动态调度方法和课题组已发表的两种方法,包括:

1) 基于特征全集的动态调度方法: ELM, KNN^[9], SVM^[10];

2) 基于特征子集的动态调度方法: GA-SAGA-ELM, GA-KNN^[9], BPSO-SVM^[10]。

5.2 实验参数设置(Setting of experiments parameters)

1) ELM和GA-SAGA-ELM算法参数设置。

GA和SAGA的种群规模为50个,交叉概率为0.8,变异概率为0.05,最大进化代数为50代; SA的冷却系数为0.912,初始温度为100; ELM隐含层神经元个数为20个,激活函数为Sigmoidal函数。

2) KNN和GA-KNN算法参数设置。

GA的种群规模为50个,交叉概率为0.8,变异概率为0.05,最大进化代数为60代; KNN中参数 $K=7$ 。

3) SVM和BPSO-SVM算法参数设置。

粒子群算法(BPSO)的初始种群为50个,初始化粒子速度范围 $[-10, 10]$,权重 $\omega_a = 0.8$, $\omega_f = 0.2$,最大进化代数为15次; 支持向量机(SVM)训练参数 C , γ 极值为 $C_{\max} = 500$, $C_{\min} = 0$, $\gamma_{\max} = 1$, $\gamma_{\min} = 0$ 。

5.3 数据结果分析(Results analysis)

1) 生产线性能指标。

用6种动态调度方法和6种启发式组合方法共12种方法对生产线上WIP数大于83000片的20条数据样本(生产状态)进行仿真测试,采集调度周期内的性能指标,表1是20条样本数在这种方法作用下,生产线性能指标平均值比较。

表1 6种动态调度方法与6种启发式组合调度方法在生产线性能指标平均值比较

Table 1 Comparison of average performance indexes under 6 dynamic scheduling methods and 6 combined heuristic scheduling methods

调度方法	MOV_All/步	Turn/(步·片 ⁻¹)	TP/%	OEE
ELM	96218.50	1.106	0.99	0.3262
GA-SAGA-ELM	96368.55	1.106	0.98	0.3265
KNN	96235.25	1.106	0.99	0.3263
GA-KNN	96336.55	1.107	0.99	0.3263
SVM	96234.85	1.106	0.98	0.3265
BPSO-SVM	96170.75	1.106	0.99	0.3264
GR_GR	92028.60	1.059	0.93	0.3161
GR_SPT	93117.55	1.070	0.92	0.3213
GR_LS	94368.55	1.085	0.94	0.3222
LB_GR	96136.90	1.105	0.95	0.3265
LB_SPT	95088.20	1.093	0.95	0.3254
LB_LS	96336.55	1.107	0.99	0.3263
最佳性能指标值	97411.80	1.163	1.00	0.3336
最差性能指标值	91930.30	1.036	0.86	0.3179

由表1可以看出,相比于启发式调度方法,6种动态调度方法能在给定的4种性能指标上都获得较优的结果,且优势较为明显。其中在MOV_All和OEE方面,GA-SAGA-ELM算法最优,而在Turn方面,GA-KNN算法最优,TP方面,则BPSO-SVM算法性能最优。从而可以看出6种动态调度方法均能较好地指导生产线调度,而基于特征子集的调度方法又优越于基于特征全集的调度方法。

另一方面从训练模型时间、预测时间等方面来

考察这6种方法。表2是对10组训练样本为75条时6种调度方法学习性能统计,表3是对10组训练样本

为350条时6种调度方法学习性能统计。不难看出,6种方法均能满足生产线调度的实时性要求。

表2 6种动态调度方法学习性能统计(训练样本为75条)

Table 2 Learning performance statistics of 6 dynamic scheduling methods(training sample size=75)

算法	生产属性 子集规模	平均预 测精度	平均预测精 度比较/%	平均训练 模型时间/s	平均预测 时间/ ms
ELM	67	0.49	—	0.16	4
GA-SAGA-ELM	6	0.45	-8.16	186	2.25
KNN	67	0.44	—	0.09	4
GA-KNN	10	0.45	2.27	1.75	4
SVM	67	0.44	—	0.09	4
BPSO-SVM	25	0.46	4.55	877	2

表3 6种动态调度方法学习性能统计(训练样本为350条)

Table 3 Learning performance statistics of 6 dynamic scheduling methods (training sample size=350)

算法	生产属性 子集规模	平均预 测精度	平均预测精 度比较/%	平均训练 模型时间/s	平均预测 时间/ ms
ELM	67	0.59	—	0.65	4
GA-SAGA-ELM	5	0.64	8.47	2505	4
KNN	67	0.45	—	0.68	4
GA-KNN	8	0.56	24.44	368	4
SVM	67	0.50	—	0.623	58
BPSO-SVM	32	0.57	14	1965	45

生产属性(特征)经过特征选择后,特征数量均大幅度减少,其中,GA-SAGA-ELM特征数量减少最为明显,虽然BPSO-SVM算法对特征数量的减少程度不及其他两种算法,但已经在很大程度上降低了样本的冗余程度。

从训练样本数量上看,样本较少时各种方法的预测精度均低于样本较多时得到的预测精度,但耗费的学习时间大大降低。而在样本较少时,特征选择的优势并不明显,基于特征全集的调度方法与基于子集的调度方法得到的预测精度相近。例如,KNN调度方法的预测精度是0.44,经过特征选择的GA-KNN调度模型的预测精度为0.45;而ELM调度方法的预测精度是0.49,经过特征选择的GA-SAGA-KNN调度模型的预测精度为0.45,还有所下降。样本较多时,采用ELM,KNN和SVM3种分类算法,基于特征子集的方法比基于特征全集的方法在预测精度上分别提高了8.47%,24.44%和14%。

从模型学习的时间上看,GA-KNN算法优于BPSO-SVM算法,即采用过滤式特征选择与分类算法(GA-KNN)的动态调度模型学习时间最短,但其预测精度最低;采用封装式特征选择与分类算法

(BPSO-SVM)动态调度模型预测精度较好,但其模型学习较长;二者相结合的GA-SAGA-KNN的预测精度最好,但模型学习包含两个阶段,学习时间更长。因此,建议:

- 1) 在训练样本较少的情况下,建议使用基于特征全集的动态调度方法;
- 2) 在训练样本较多的情况下,建议采用使用基于特征子集的方法,混合式的特征选择与分类算法优于封装式特征选择与分类算法,而封装式则优于过滤式特征选择与分类算法。

6 结论(Conclusions)

本文研究了一种数据驱动下的半导体生产线动态调度框架,可集成各种基于机器学习的动态调度方法,以此为基础,设计了一种基于特征选择和分类算法的调度模型生成方法,给出了具体方法实现和算法集成流程,实现了动态调度的单目标和多目标调度的统一及多种动态调度方法的统一,提高了方法的适用性和扩展性。

本文所提出的框架结合课题组提出的6种调度方法在上海某半导体制造企业的5,6吋硅片生产线上进行有效性和可行性实验,实验表明:

1) 该框架能集成各种数据驱动下的动态调度方法;

2) 数据驱动下的动态调度方法, 较单一的调度规则而言, 能有效地提高生产线运行性能指标, 也能很好地满足了调度实时性.

参考文献(References):

- [1] MOUELHI-CHIBANI W, PIERREVAL H. Training a neural network to select dispatching rules in real time [J]. *Computers & Industrial Engineering*, 2010, 58(2): 249 – 256.
- [2] PRIORE P, GOMEZ A, PINO R, et al. Dynamic scheduling of manufacturing systems using machine learning: An updated review [J]. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 2014, 8(1): 83 – 97.
- [3] KIM Y D, SHIM S O, CHOI B, et al. Simplification methods for accelerating simulation-based real-time scheduling in a semiconductor wafer fabrication facility [J]. *IEEE Transactions on Semiconductor Manufacturing*, 2003, 16(2): 290 – 298.
- [4] PARK Y J, HWANG H R. A rule-based simulation approach to scheduling problem in semiconductor photolithography process [C] //The 2013 8th International Conference on Intelligent Systems: Theories and Applications (SITA). Morocco: IEEE, 2013: 1 – 4.
- [5] SHIUE Y R, GUH R S, TSENG T Y. Study on shop floor control system in semiconductor fabrication by self-organizing map-based intelligent multi-controller [J]. *Computers & Industrial Engineering*, 2012, 62(4): 1119 – 1129.
- [6] TSAI C J, HUANG H P. A real-time scheduling and rescheduling system based on RFID for semiconductor foundry FABs [J]. *Journal of the Chinese Institute of Industrial Engineers*, 2007, 24(6): 437 – 445.
- [7] OLAFSSON S, LI X N. Learning effective new single machine dispatching rules from optimal scheduling data [J]. *International Journal of Production Economics*, 2010, 128(1): 118 – 126.
- [8] LI L, SUN Z J, NI J C, et al. Data-based scheduling framework and adaptive dispatching rule of complex manufacturing systems [J].
- [9] QIAO F, MA Y M, GU X. Attribute selection algorithm of data-based scheduling strategy for semiconductor manufacturing [C] //IEEE International Conference on Automation Science and Engineering. USA: IEEE, 2013, 8: 410 – 413.
- [10] MA Y M, CHEN X, QIAO F, et al. The research and application of a dynamic dispatching strategy selection approach based on bps-SVM for semiconductor production line [C] //The 11th IEEE International Conference on Networking, Sensing and Control (ICNSC2014). Miami Florida, USA: IEEE, 2014, 4: 74 – 79.
- [11] 张莉, 陈恭和. 一种适合大规模数据集的特征选择方法 [J]. 计算机工程, 2007, 33(4): 184 – 186.
(ZHANG Li, CHEN Gonghe. A feature selection method fitting for large data set [J]. *Computer Engineering*, 2007, 33(4): 184 – 186.)
- [12] YU E, CHO S. Ensemble based on GA wrapper feature selection [J]. *Computers & Industrial Engineering*, 2006, 51(1): 111 – 116.
- [13] 马玉敏, 乔非, 陈曦, 等. 基于支持向量机的半导体生产线动态调度方法 [J]. 计算机集成制造系统—CIMS, 2015, 21(3): 733 – 739.
(MA Yumin, QIAO Fei, CHEN Xi, et al. Dynamic scheduling approach based on SVM for semiconductor production line [J]. *Computer Integrated Manufacturing Systems*, 2015, 21(3): 733 – 739.)

作者简介:

吴启迪 (1947–), 女, 教授, 主要研究方向为复杂制造系统调度、系统工程、管理工程和智能控制, E-mail: wuqidi@moe.edu.cn;

马玉敏 (1971–), 女, 副研究员, 主要研究方向为复杂制造系统调度、建模仿真, E-mail: ymma@tongji.edu.cn;

李 莉 (1975–), 女, 教授, 主要研究方向为复杂制造系统调度和智能自动化, E-mail: lili@tongji.edu.cn;

乔 非 (1967–), 女, 研究员, 主要研究方向为复杂制造系统调度、系统工程、先进制造技术和管理工程, E-mail: fqiao@tongji.edu.cn.