

# 基于情景感知的制造组合服务自适应决策机制

任 磊<sup>1,2†</sup>, 任明仑<sup>2</sup>

(1. 南京审计大学 政府审计学院, 南京 211815; 2. 合肥工业大学 管理学院, 合肥 230009)

**摘 要:** 针对组合服务面临复杂、动态的业务需求和运行环境, 提出基于情景感知的自适应决策机制, 保证制造过程的顺利执行, 为用户持续稳定地提供高质量服务. 从智能制造单元个体视角, 构建制造组合服务自适应调整系统架构. 根据多变的应用场景, 充分考虑决策主体状态和情境因素对服务调整活动的影响, 设计情景感知、主体-情景-活动 (Subject-situation-action, SSA) 2 种自适应决策机制, 并通过多 Agent 技术搭建实验环境, 应用关联规则方法挖掘决策知识. 通过汽车制造云服务实例与现有事件驱动机制对比, 验证所提出的 2 类机制在不同场景下的效果, 并从决策准确率、时间和服务 QoS 两方面证明情景感知、SSA 机制的优势和可行性.

**关键词:** 组合服务; 自适应决策; 情景感知; 关联规则; 智能单元; 实时匹配

中图分类号: TP393

文献标志码: A

## Situation aware-adaptive decision-making mechanism of manufacturing composition service

REN Lei<sup>1,2†</sup>, REN Ming-lun<sup>2</sup>

(1. School of Government Audit, Nanjing Audit University, Nanjing 211815, China; 2. School of Management, Hefei University of Technology, Hefei 230009, China)

**Abstract:** In order to make rapid respond to the complex and dynamic business needs and operation environment of composite services, a situation aware-adaptive decision-making mechanism is proposed to ensure the smooth implementation of the manufacturing process and provide users with high quality services continuously and steadily. From the individual perspective of intelligent manufacturing cell, a adaptive adjustment system architecture for manufacturing composite service is constructed. According to the changing application scenarios, two adaptive decision-making mechanisms, including situation awareness and subject-situation-action (SSA), are designed respectively. Meanwhile, the decision experiment environment is built by using the multi-agent technology and the association rule method is used to mine decision knowledge. Through the experiment of automobile manufacturing cloud service, the effect of two kinds of mechanisms in different scenes is verified, and the advantages of situation awareness and SSA mechanism are proved from decision accuracy, time and service QoS.

**Keywords:** composition service; adaptive decision-making; situation awareness; association rule; intelligent cell; real time matching

## 0 引 言

智慧云平台整合了分布在全球各地的大量优质制造资源和能力, 为全社会用户提供全生命周期的一站式制造服务<sup>[1]</sup>. 不同市场主体可以自主、高效地在云平台上通过服务组合技术进行制造业务流程和价值链的构建, 以及拓展、优化原有的协同制造系统<sup>[2]</sup>. 但是, 在组合服务实际运营过程中, 面临着复杂、动态的运行环境, 如消费者需求的变动、服务的加入与退出、交互网络的异常等<sup>[3]</sup>. 同时, 由于制造环境、自身运行状态等变化, 独立的服务单元也会出现服务质量

恶化甚至故障现象<sup>[4]</sup>, 最终导致制造业务流程出现异常情形, 影响组合服务的执行绩效, 甚至任务失败. 因此, 需要组合服务具备自适应调整能力, 能够根据出现的异常事件, 采取有效的改善措施, 保障持续为用户提供稳定、高水平的制造服务.

当前研究主要关注制造系统规划设计阶段的服务组合优化方法<sup>[5-7]</sup>, 对执行过程中出现的异常情形如何调整涉及较少. 赵秋云等<sup>[8]</sup>针对设备服务出现的异常现象, 提出基于监控和捕获的异常响应框架, 设计了 7 类处理策略和流程; 马文龙等<sup>[9]</sup>将组合服

收稿日期: 2017-12-01; 修回日期: 2018-11-28.

基金项目: 国家自然科学基金项目 (71531008, 71271073).

†通讯作者. E-mail: renlei2005062134@aliyun.com.

务异常分为任务相关、资源相关和服务 QoS 相关 3 类,给出了异常处理自适应调整机制和算法; Barakat 等<sup>[10]</sup>将服务改变分为需要考虑和无需考虑两类,通过自适应行为建模,给出了基于图搜索的服务重选方法; Kuang 等<sup>[11]</sup>通过服务 QoS 与环境数据的关联学习,提出了基于上下文关联的服务自适应预测算法. 上述研究虽给出了自适应调整的策略和模型,但缺乏整体框架和调整机制. 闫永明等<sup>[12]</sup>提出了基于强化学习的云服务自适应调整框架,通过重复“执行-积累-学习-决策”过程实现系统优化; 江琦等<sup>[13]</sup>根据业务需求和网络环境的变化,提出了基于事件驱动的在线自适应优化策略; Cheng 等<sup>[14]</sup>针对物联网服务动态性,基于事件驱动的 SOA 框架,提出了情景感知的服务协调机制; Vlahakis 等<sup>[15]</sup>研究实时制造环境下自主情境感知与复杂事件处理,构建了事件驱动的制造执行系统; Boubeta 等<sup>[16-17]</sup>提出 SOA2.0 环境下基于模型驱动的实时决策方案,定义了统一的事件语言和协议,给出了基于有色 Petri 网的复杂事件处理方法. 现有研究大多采用事后调整思想,以事件驱动机制进行异常处理,能够满足服务系统应对特定事件的要求,应用于比较简单和规则清晰的场景. 同时,当前自适应调整方法均忽略了服务状态、环境等因素对事件理解和决策活动的影响,难以准确地识别当前情形,且当面临动态复杂决策场景时,容易出现多条 ECA 规则的融合冲突,耗费大量的计算推理资源,且准确率较低.

制造服务具有线上线下融合、自适应性和自组织能力<sup>[18]</sup>,不仅能利用已有资源完成分配任务,还应该可以根据系统运行过程中的异常情形,作出及时的操作调整以保障执行效果. 现有的服务自适应调整模型无法满足复杂场景的应用需求. 情景感知作为前沿信息处理技术,能够挖掘事件之间存在的多种关联,分析动态环境对事件理解的影响,从而聚合成更高层次的决策态势信息<sup>[19-20]</sup>. 通过感知、解释、预测 3 个层次的信息融合实现情境感知过程,为实时决策提供理论基础<sup>[21-22]</sup>. 同时,决策主体状态并非一成不变,只根据当前关注情景采取相应行动,忽视了智能单元的权责范围、知识水平和能力的差异. 同一主体在不同状态下,可能对相同的情景采取不同的决策活动. 因此,设计服务自适应决策机制时,应进一步考虑决策主体的状态、知识、偏好等动态演化;

借鉴认知决策<sup>[23]</sup>、OODA loop<sup>[24]</sup>、自然决策模式<sup>[25]</sup>等,提出基于情景感知的服务自适应调整框架;从智能单元个体的角度,基于现有事件驱动机制分析,提出情景感知、基于主体-情景-行动 (Subject-Situation-Action, SSA) 的实时决策机制;运用智能 Agent 技术搭建决策实验平台,通过关联规则方法挖掘决策知识. 本文提出的实时决策机制充分融合了事件、环境和主体状态信息,能够获取更丰富的决策知识,匹配更精确及时的自适应调整活动,从而高效地解决异常情景带来的问题. 最后通过汽车零部件云制造仿真实验,从准确性、时间和服务 QoS 三个方面验证本文方法的有效性和优势.

## 1 动态环境下制造服务的自适应调整框架

### 1.1 自适应制造服务单元与异常场景

传统制造单元根据输入原材料类型进行工序执行,整个过程假定环境不变,一旦出现设备异常或故障,需要人为地事后修复和调整生产线,制造效率低、成本高,难以满足实时制造的要求. 实际的制造环境动态、复杂,各种异常情形均可能发生,影响服务执行质量,需要构建自适应的智能服务单元,通过感知理解当前情景,进行自主的实时决策.

运用 CPS 技术与物理制造单元连接,构建智能服务单元,从自适应决策角度分析服务单元结构<sup>[26]</sup>. 传统制造单元只有原材料输入、工序执行和产品输出 3 部分,  $TSU = \text{Input}(MA), KD, \text{Act}, \text{Output}(PD)$ , 其中 KD 为决策知识, Act 为操作活动, TSU 的 KD、Act 均较少. 而自适应制造单元还需输入环境、自身状态信息,具有感知、交互、推理、执行模块,  $ASU = \text{Input}(MA, EN, SB), KD, \text{Act}, \text{Output}(PD)$ , 其中 ASU 的 KD 数量较大且 Act 较多.

服务单元能实时感知当前所发生的情形,并作出及时应对. 根据决策主体的层次,将可能出现的异常分为高层次的网络化企业联盟所面临的场景和低层次的服务单元个体所面临的场景,如表 1 所示. 异常场景可以表示为  $AS = (\text{id}, \text{type}, \text{time}, \text{source}, v(a))$ . 其中: id 为异常标识符; type 为异常类型, 1 为联盟异常, 2 为个体异常; time 为发生时间; source 为发生来源,如任务需求变化、制造温度变化等;  $v(a)$  为属性值. 如,制造环境温度在  $t_0$  时刻 100 度为温度异常事件,可表示为  $as_1 = (123, 2, t_0, \text{温度异常}, 100 > 50)$ .

表1 制造服务联盟的异常情景

异常场景类型	来源	解释说明	可能影响	调整策略
联盟面临的	任务需求变化	产品结构、任务数量、时间等变化	原有业务流程绩效降低,甚至执行失败	改变业务过程,增添或替换新的服务
	任务终止	任务请求取消	流程终止,服务利益损失	向服务赔付违约金
	服务加入	云平台上加入新服务单元	业务过程绩效继续提升	替换更优质服务
	服务故障	由于出现故障而无法使用	任务执行中断或失败	维修、替换相似服务
	服务退出	提供者由于商业策略、法律法规等退出交易市场	任务中断或失败	重新组合优选,或替换相似服务
网络交互异常	服务间的通信、物流、合作平台环境出现异常	协作效率降低,影响任务整体执行绩效	投入维护网络环境,增强协同的可靠性	
服务单元面临的	制造环境异常	环境温度、电压、电力水平、任务类型等变化	影响服务质量水平	改变操作活动,同时修复环境状态
	物体状态异常	代加工产品的尺寸、温度等变化	影响服务质量水平和具体操作	改变操作活动,修改物体状态
	自身状态异常	设备运行速度、震动、温度等变化	影响服务质量和具体操作活动	改变操作活动,或停产维修
	操作不当	缺乏相应知识、执行不当的操作活动、误操作等	影响服务质量和最终输出	及时调整操作,再制造

1.2 智能制造单元自适应调整系统架构

智能制造单元具有自适应性、自学习性和自组织能力,根据系统运行过程中典型情景的出现,调整自身决策行为,以应对动态环境对业务过程的影响,增强服务质量和协同效率.参考IBM的自适应软件框架MAPE-K<sup>[27]</sup>,借鉴认知决策、情景感知等理论,本文提出基于情景感知的服务自适应调整系统架构(如图1),包括信息感知模块、分析判断模块、决策匹

配模块、执行学习模块和知识库模块.

1.2.1 信息感知器

通过物联网、CPS感知物体、环境信息,运用嵌入式设备收集自身状态信息,通过系统软件记录服务执行数据.对感知到的物体、环境、决策单元自身状态等数据,进行收据存储和预处理,分析数据之间的关联,构建数据网络和多尺度时序,为情景识别提供数据基础.

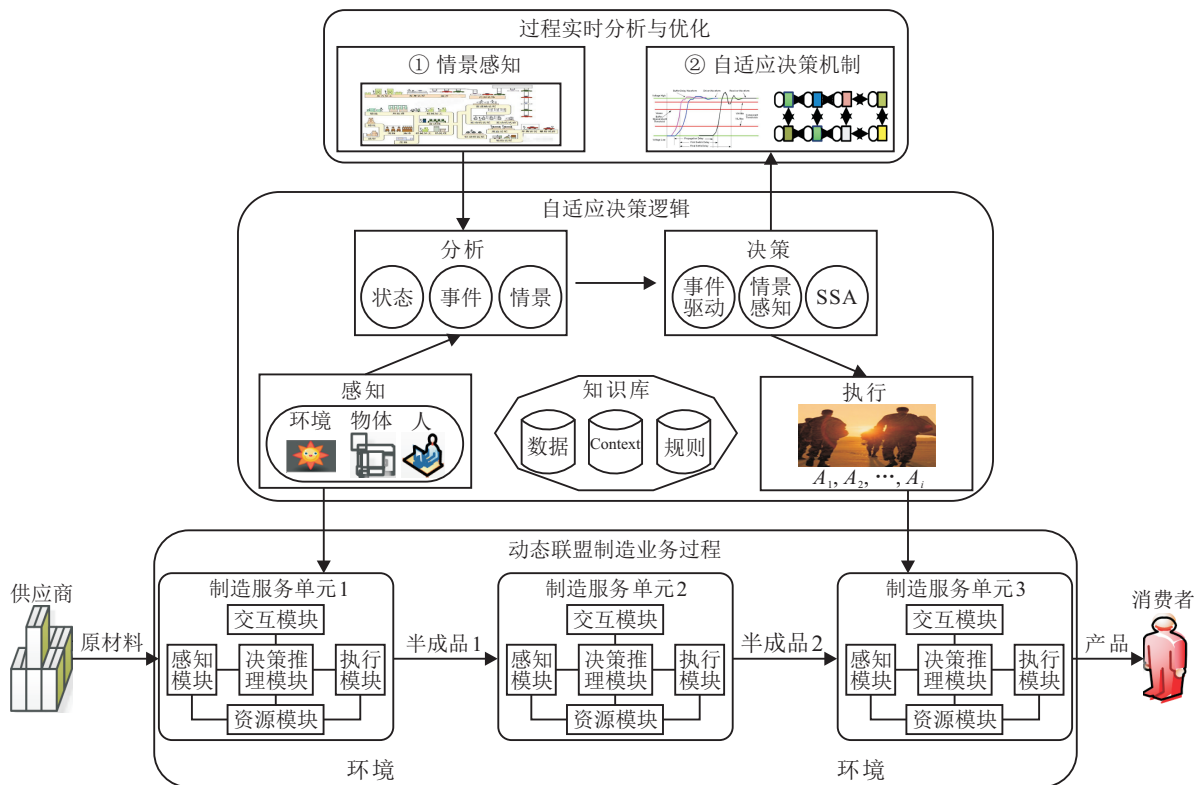


图1 自适应调整系统架构

### 1.2.2 分析判断器

分析当前的情境约束信息,识别物体状态和简单事件,发现复杂事件模式,构建制造情景模型,分析情景的演化模式和规律,并对未来情景进行预测,实现预测性制造.这些事件、情景识别需要的知识规则通过专家定义和线下的机器学习获取.

### 1.2.3 决策匹配器

在情景识别后,与知识库中规则进行匹配,并根据决策主体的状态,利用现有的知识结构(领域的操作规程、业务活动的约束、决策单元以往的经验等)对识别的制造情形采取最为合理的决策活动和响应,实现服务执行绩效最优.

### 1.2.4 执行器

负责实施决策匹配其所执行的操作活动,完成当前任务,并将执行结果进行反馈.如果未完成,则重新进行循环的实时调整过程.

### 1.2.5 知识库

包含情景识别知识和决策匹配知识,可通过专家定义和智能学习不断丰富和完善.当服务系统完成一次任务执行或调整后,对过程中数据进行记录,进一步学习以优化对信息的理解和决策活动的匹配,不断更新知识库.

## 2 智能服务单元自适应实时决策机制设计

情景识别后,智能服务单元需要根据已有的知识规则采取合理的调整策略和操作活动.整个决策系统包括决策主体(智能单元)、决策客体(关注的物体和事物)、决策环境(当前的情境约束)、决策活动(行动方案).现有的事件驱动机制只关注物体行为,忽视环境因素、主体状态对决策过程的影响.基于现有研究的不足,针对复杂制造应用场景,构造基于情景感知、基于主体-情景行为(SSA)2类实时决策机制,并给出具体过程和模型算法.3类实时决策机制见图2.

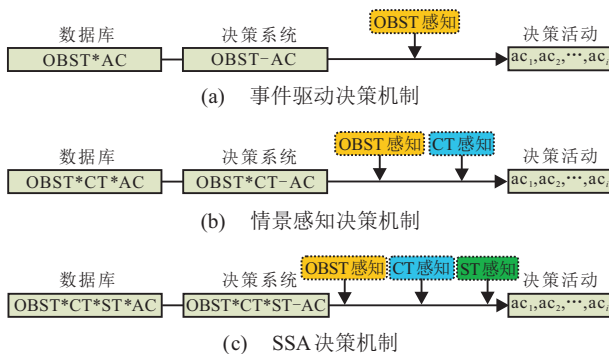


图2 3类实时决策机制

## 2.1 基于事件驱动的决策机制

现有智能决策系统主要依据于“刺激-反应”理论,假定周围环境固定不变,智能主体只需根据现有的知识和经验,通过实时感知物体状态,判别事件是否发生,从而触发响应活动.基于事件驱动的决策机制忽视了环境约束,适用于简单重复的应用场景.如图2(a)所示,  $OBST = (obst_1, obst_2, \dots, obst_m)$  为物体状态集合,也可理解为发生事件;  $AC = (ac_1, ac_2, \dots, ac_m)$  为其可执行的操作活动,如快速加工、慢速加工、停止等;  $OBST * AC$  为一个规则知识空间,描述不同事件对应的决策活动;  $OBST_{sen}$  为当前感知的物体状态.

事件驱动决策机制是通过计算当前  $OBST_{sen}$  与知识库中  $OBST_j$  的相似度,获取最为匹配的规则,根据规则选择对应的  $AC_j$ .由于物体状态属性具有数值、区间、布尔等多种数据类型,采用如下混合距离的相似度计算方法(文献[16]给出具体的改进方法):

$$\text{sim}(OBST_{sen}, OBST_j) = \sum_{i=1}^k w_i \text{sim}(ob_i).$$

其中:  $w_i$  为第  $i$  个物体状态属性的权重,  $ob_i$  为第  $i$  个物体状态属性.

事件驱动策略的具体算法如下.

**Input:**  $OBST * AC$  事件-决策活动的关联矩阵,即知识规则;当前感知的事件  $OBST$ .

**Output:** 匹配的规则和执行的活动  $ac_k$ .

**Step 1:** 感知当前物体运行状态;

**Step 2:** 分别计算  $OBST_{sen}$  与库中  $OBST_j$  的相似度;

**Step 3:** 获取最为匹配的 Top- $k$  条规则;

**Step 4:** 选择合适的决策活动  $ac_k$ .

## 2.2 基于情景感知的决策机制

制造过程中的任务、自然环境、电力水平等情境因素,制约物体状态及其关系的变化.智能制造单元需要自适应地对不同情境约束下的事件和复杂情形及时理解判断.在事件驱动的基础上融合环境信息,形成情景感知决策机制.如图2(b)所示,  $OBST = (obst_1, obst_2, \dots, obst_m)$  为物体状态集合;  $CT$  为物体运行的情境约束,如任务、时空、自然条件等;  $SA = (OBST, CT)$  为发生的情景;  $OBST * CT * AC$  为知识规则,描述了不同环境下事件所对应的决策活动;  $CT$  感知为当前感知的环境信息.情景感知的决策机制是通过计算当前  $OBST$  感知、 $CT$  感知与知识库中  $OBST_j$ 、 $CT_j$  的相似度,获取最为匹配的规则,然后

根据规则选择对应的 $AC_j$ . 相似度采用上节方法,即

$$\text{sim}(\text{OBST}_{\text{sen}}, \text{OBST}_j) = \sum_{i=1}^k w_i \text{sim}(\text{ob}_i).$$

事件驱动策略的具体算法如下.

**Input:**  $\text{OBST} * \text{AC}$  事件-决策活动的关联矩阵,即知识规则;当前感知的事件 $\text{OBST}_{\text{sen}}$ .

**Output:** 匹配的规则和执行的活动 $a_{c_k}$ .

**Step 1:** 感知当前物体运行状态、环境信息;

**Step 2:** 分别计算 $\text{OBST}_{\text{sen}}$ 、 $\text{CT}_{\text{sen}}$ 与知识库中 $\text{OBST}_j$ 、 $\text{CT}_j$ 的相似度;

**Step 3:** 综合获取 $\text{SA}_{\text{sen}}$ 与库中 $\text{SA}_j$ 的相似度;

**Step 4:** 匹配最为贴近的Top- $k$ 条规则;

**Step 5:** 选择合适的决策活动 $a_{c_k}$ .

### 2.3 基于主体-情景-行动的决策机制

智能主体的状态随着时间和任务执行不断变化,同一主体在不同的状态下对同一情景采取不同的决策活动. 情景感知决策认定主体状态、价值偏好等不变,难以匹配个性化的决策方案. 充分考虑主体状态和情境因素的影响,给出SSA决策机制. 如图2(c),  $\text{ST} = (\text{st}_1, \text{st}_2, \dots, \text{st}_n)$ 为主体状态集合(健康、资源条件等),  $\text{SC} = (\text{OBST}, \text{CT}, \text{ST})$ 为制造系统的态势;  $\text{OBST} * \text{CT} * \text{ST} * \text{AC}$ 为知识规则,描述不同主体状态下情景所关联的活动;  $\text{ST}$ 感知为当前感知主体状态.

SSA决策机制是通过计算当前 $\text{OBST}$ 感知、 $\text{CT}$ 感知与 $\text{ST}$ 感知知识库中 $\text{OBST}_j$ 、 $\text{CT}_j$ 、 $\text{ST}_j$ 的相似度,获取最为匹配的规则,然后根据规则关联对应的 $AC_j$ . 具体相似度计算方法如下:

$$\begin{aligned} \text{sim}(\text{SC}_{\text{sen}}, \text{SC}_j) = & \\ & \alpha \text{sim}(\text{OBST}_{\text{sen}}, \text{OBST}_j) + \\ & \beta \text{sim}(\text{CT}_{\text{sen}}, \text{CT}_j) + \chi(\text{ST}_{\text{sen}}, \text{ST}_j), \end{aligned}$$

其中 $\alpha$ 、 $\beta$ 、 $\lambda$ 分别为物体状态、环境信息、主体状态相似度的权重,且 $\alpha + \beta + \lambda = 1$ .

下面给出SSA决策机制的具体算法.

**Input:**  $\text{OBST} * \text{CT} * \text{ST} * \text{AC}$  事件-环境-主体状态-决策活动的关联规则、 $\text{OBST}_{\text{sen}}$ 、 $\text{CT}_{\text{sen}}$ 和 $\text{ST}_{\text{sen}}$ ;

**Output:** 匹配的规则和执行的活动 $a_{c_k}$ .

**Step 1:** 感知物体状态、环境和主体状态信息;

**Step 2:** 分别计算 $\text{OBST}_{\text{sen}}$ 、 $\text{CT}_{\text{sen}}$ 、 $\text{ST}_{\text{sen}}$ 与知识库中 $\text{OBST}_j$ 、 $\text{CT}_j$ 、 $\text{ST}_j$ 的相似度;

**Step 3:** 综合得到当前态势 $\text{SC}_{\text{sen}}$ 与知识库中 $\text{SC}_j$ 的相似度;

**Step 4:** 匹配最为贴近的Top- $k$ 条规则;

**Step 5:** 选择合适的决策活动 $a_{c_k}$ .

## 3 基于多Agent决策场景构建与知识学习

面向智慧制造的实时决策过程包含了智能制造单元、物体、环境及网络等多个实体,对于每一个物理实体,通过CPS技术构建一个与之相联系的Agent,从而能够实时感知整个制造过程的运营状态和环境信息. 本节从智能服务单元的角度,重点关注零部件加工过程中,智能主体(设备)状态、情境约束等对物体运行状态判断和决策的影响. 运用Agent构建面向智能设备应用的多实体行为模型和决策平台,为3类决策机制提供基础条件和实验环境,同时运用关联规则方法对执行数据学习.

### 3.1 决策场景模型构建

1) 物体Agent模型. 智能设备所关注的物体为代加工的产品,产品的类型、尺寸、温度等均是影响其决策活动的关键状态属性,是智能设备需实时感知分析的主要内容,可用Object Agent = (id, name, POP, OBST)表示,POP为物体的特征,OBST为物体的运行状态.

Object Agent的特征是智能主体选择何种决策活动的基础,在物体运行过程中处于不变状态,面向零部件加工的物体特征包括类型、尺寸、几何结构、位置等. Object Agent的运行状态随着时间发生连续变化,需要智能设备不断调整控制活动,物体的状态属性包括温度、震动频率、表面光度、硬度等. 所有决策主体关注的信息,即物体属性.

2) 环境Agent模型. 物体的运行状态和行为受到环境因素的影响,物体属性值在不同环境下具有不同的分布特征、波动规律,其状态变化模式也存在差异,智能主体需要综合环境信息以对物体状态进行精准判断,从而采取最为合理的决策活动. 可用Environment Agent = (id, time, Loc, CT)表示,Loc为当前位置,CT为环境状态. 智能主体所感知关注的环境信息CT包括电力水平、任务类型、时间、室内自然条件等.

特定环境约束下,发生的主体感兴趣、有意义的多个关联事件,形成能够触发决策推理的复杂事件或情景 $\text{SA} = (\text{CT}, \text{OBST}, F)$ ,CT为事件发生的情境约束,OBST为物体状态事件, $F$ 为事件关联算子(包括聚合、协同、时间等). 如在加工部件任务Task1,电力较低EL2的环境下,出现设备震动大于800的异常事件E11和速度大于500的异常事件E21,则当前情景表示为 $\text{SA}_1 = (\text{Task1}, \text{EL2}, \text{E11}, \text{E21}, \text{U})$ ,即设备异常.

3) 智能主体Agent模型. 智能主体是整个决策系

统的核心,按照操作规程、组织制度以及经验来匹配实施活动,通过类比、增强学习不断提升决策水平.可用  $\text{Subject Agent} = (\text{id}, \text{type}, \text{ST}, \text{SA}, \text{OA}, \text{DM}, \text{AC})$  描述智能主体信息结构,制约决策活动选择的主体状态  $\text{ST}$  的特征属性包括知识水平、资源条件、角色权限以及健康状态等.如,智能设备单元1在时刻  $t_1$  的角色为  $r_1$ ,拥有资源充足  $rs_2$ ,具备高水平操作能力  $as_2$ ,则此时其状态描述为  $\text{ST}_1 = (M1, (r_1, rs_2, as_2))$ ;智能主体感知的信息还包括物体状态  $\text{OBST}$ 、环境信息  $\text{CT}$  以及其他智能主体的情形  $\text{OA}$ .  $\text{Subject Agent}$  根据不同的应用场景制定了3类决策机制  $\text{DM}$ ,  $\text{DM}$  中还包含了不同机制下的知识规则  $\text{Decision rule} = (\text{ST} * \text{SA} * \text{AC}) = (\text{dr}_1, \text{dr}_2, \dots, \text{dr}_m)$ ;智能主体依据  $\text{DM}$  对外部刺激所采取的不同决策活动集合为  $\text{AC} = (\text{ac}_1, \text{ac}_2, \dots, \text{ac}_m)$ .

### 3.2 基于关联规则的知识学习

知识规则是本文提出  $\text{SSA}$  机制的核心,表明一个智能单元如何在当前物体、环境变化情景下实施具体决策行动的知识水平,可以从历史记录数据中线下挖掘,从而实现线上的实时决策匹配.上节已经构建了多  $\text{Agent}$  的决策平台,系统能够存储物体状态  $\text{OBST}$ 、环境状态  $\text{CT}$ 、主体状态  $\text{ST}$ 、执行活动  $\text{AC}$  及最终绩效  $\text{PF}$  的数据.本节应用关联规则方法挖掘主体决策知识,主要包括初始数据集的构建与数据预处理、状态与情景识别并构建新的数据集、关联知识的发现3个步骤(如图3),从而形成决策知识库  $\text{DM} = (\text{dm}_1, \text{dm}_2, \dots, \text{dm}_n) = (\text{OBST} * \text{CT} * \text{ST} * \text{AC})$ .

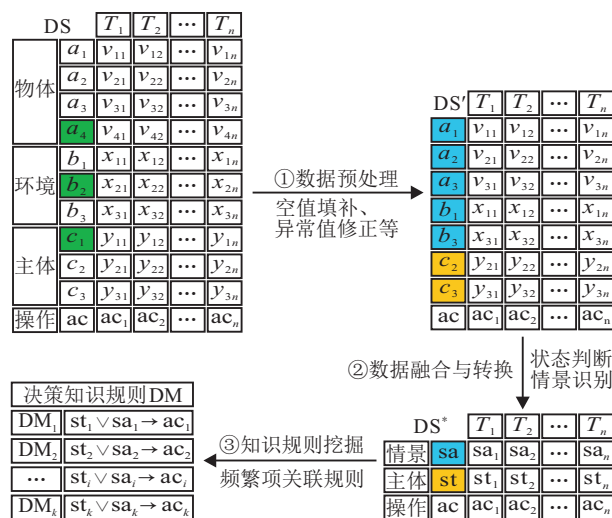


图3 决策知识规则挖掘过程

1) 数据集的构建与预处理. 智能单元在  $t_1$  时刻,主体状态为  $(v(a_1), v(a_2), \dots, v(a_m))$ ,物体状态为  $(v(b_1), v(b_2), \dots, v(b_n))$ ,环境状态为  $(v(c_1), v(c_2), \dots, v(c_k))$ ,操作活动为  $(\text{ac}_i, \text{pf}_1)$ ,从而形成一条数据

记录  $\text{ds}_1$ . 从  $t_1$  到  $t_n$  时刻,形成数据库  $\text{DS} = (\text{ds}_1, \text{ds}_2, \dots, \text{ds}_n)$ . 首先对空缺、异常值进行补充和修正,进一步运用特征选择方法对属性进行筛选,提出对决策影响小的属性.经过预处理,从而将原有数据库  $\text{DS}$  转变为新的数据库  $\text{DS}'$ .

2) 基于状态、情景识别的数据集转换. 数据库  $\text{DS}'$  中的很多属性值为连续型,需要离散化转换.同时,  $\text{DS}'$  中的变量较多,造成关联规则的复杂度高,且可能形成没有实际意义的规则.因此,本节拟运用文献[28]中的方法对主体状态、当前情景进行识别,将  $\text{DS}'$  转换为只包含  $\text{ST}$ 、 $\text{SA}$  和  $\text{AC}$  三个状态属性的新数据库  $\text{DS}^*$ .

3) 主体-情景-行为关联规则挖掘. 给定智能单元根据自身状态在不同情景  $\text{SA}$  下的操作执行数据集  $\text{DS}^* = (\text{ds}_1^*, \text{ds}_2^*, \dots, \text{ds}_n^*)$ ,其中  $\text{ds}_i^* = (\text{st}_i, \text{sa}_i, \text{ac}_i)$ ,即在主体状态为  $\text{st}_i$ 、当前情景为  $\text{sa}_i$  时,执行  $\text{at}_i$ .应用频繁项学习<sup>[29]</sup>,得到智能单元的决策模式  $\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i$ .通过支持度和置信度分析,判别包含项是否可转化为知识.包含项  $\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i$  在数据集  $\text{DS}^*$  中的支持度为集合中包含该包含项的数据条数占总数据的比例,即

$$\text{sup}(\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i) = \frac{|\text{DS}^*(\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i)|}{|\text{DS}^*(\text{ac}_i)|}$$

包含项  $\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i$  在数据集  $\text{DS}^*$  中的置信度为集合中包含该包含项的数据条数与包含  $\text{at}_i$  数据条数的比例,即

$$\text{conf}(\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i) = \frac{|\text{DS}^*(\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i)|}{|\text{DS}^*|}$$

对于包含项  $\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i$ ,若  $\text{sup}(\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i) \geq \min(\text{sup})$ ,  $0 \leq \min(\text{sup}) \leq 1$  是设定支持阈值,则其为频繁项;若  $\text{conf}(\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i) \geq \min(\text{conf})$ ,  $0 \leq \min(\text{conf}) \leq 1$  是可信度阈值,则其为可信包含项;若  $\{\text{sup}(\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i) \geq \min(\text{sup})\} \wedge \{\text{conf}(\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i) \geq \min(\text{conf})\}$ ,设定的支持度与可信度阈值均满足要求,则包含项  $\text{st}_i \vee \text{sa}_i \rightarrow \text{ac}_i$  可以看作智能单元  $\text{SU}$  的一条决策知识规则  $\text{dm}_i$ .通过关联挖掘,获取如下  $k$  条规则,并不断更新知识库:

- if  $[x_1 \text{ is } \text{st}_1]$  and  $[x_2 \text{ is } \text{sa}_1]$ , then  $[y \text{ is } \text{ac}_1]$ ;
- if  $[x_1 \text{ is } \text{st}_2]$  and  $[x_2 \text{ is } \text{sa}_2]$ , then  $[y \text{ is } \text{ac}_2]$ ;
- ⋮
- if  $[x_1 \text{ is } \text{st}_k]$  and  $[x_2 \text{ is } \text{sa}_k]$ , then  $[y \text{ is } \text{ac}_k]$ .

大数据环境下,智能单元以知识结构为基础,基于  $\text{SSA}$  决策机制进行自适应响应,从而提升制造过程中的决策控制水平,增强任务执行绩效.

### 4 实验分析

汽车零部件加工是典型的实时决策过程,智能设备根据物料、环境、自身状态高频度生产.以奇瑞、捷豹、路虎汽车的智能化车间的某一零部件加工工序为原型,通过Agent工具和仿真平台搭建实时决策的实验环境,对比不同场景下决策机制的效果.

#### 4.1 实验设计

针对某一零部件加工工序场景下可能面临的决策情景建模实验,分析智能设备如何在复杂动态的环境下

境下在线实时决策.智能设备1关注的事件为代加工产品是否到达以及设备的运行状态,其所处的情境约束包括加工任务类型、电力水平、室内温度.根据实际情况,实验设置3个场景.其中:场景1设定环境变化缓慢,智能设备信息固定不变,物体状态随着时间不断波动;场景2设定环境动态变化,智能设备信息固定不变,物体状态随着时间不断波动;场景3设定环境、智能设备、物体状态均随着时间不断演化.同时,根据每一个场景设置相应的实例数值和决策规则库,实验中的相关变量设置如表2所示.

表2 变量设置

类型	属性	解释说明
智能设备	型号	说明设备的主要功能和工艺参数约束
	智能操作水平	决定设备实施不同操作活动的能力
	资源数量	表明设备是否拥有足够的资源数量实施某一决策活动,数值分布在[0, 100]
	健康状态	设备当前的运行状态,通过设备温度、运转速度、震动频率等识别,数值分布为[0, 100]、[0, 2000]、[0, 800]
物体	类型	包含两类待加工品 $p_1$ 、 $p_2$ ,需要不同的加工工艺
	温度	温度状态,需要不同的加工操作,数值分布为[0, 80]
	震动	震动波动状态,需有针对性地采取不同操作,数值分布为[0, 2000]
环境	任务	包含两类任务 $ts_1$ 、 $ts_2$ ,分别加工 $p_1$ 、 $p_2$ ,需要不同的加工工艺
	电力	不同电力情况,影响对物体的加工操作,数值分布为[0, 300]
	室内温度	室内温度水平,影响物体的运行状态,数值分布为[-5, 60]
决策评估	准确性	匹配正确的决策活动数与所有活动数的比值
	时间	决策过程所需要的计算时间
	QoS	决策执行后的设备单元运行的服务质量

#### 4.2 实验结果分析

针对3个不同的制造场景,分别应用事件驱动机制、情景感知机制和SSA机制进行实验,结果如图4~图6所示.




图4 场景1中3种决策机制的准确性和时间




图5 场景2中3种决策机制的准确性和时间

通过分析图4可知,场景1中3种决策机制的准确性均较高、无差异,主要由于环境和设备信息对物体状态的判断和决策影响极小,知识规则简单,相应的决策时间为[0.2, 1.0]s.图5中场景2事件驱动决策




图6 场景3中3种决策机制的准确性和时间

机制的准确性较低,情景感知、SSA机制的准确率差别不大且明显高于事件驱动型,说明环境信息对物体状态的判断和决策影响较大.图6中场景3事件驱动决策机制的准确性最低,情景感知次之,SSA机制的准确率最高,且三者差别较大,说明了环境信息和主体状态对物体事件的判断和决策影响较大.场景2和场景3中的决策时间SSA最高、情景感知次之、事件驱动最低,但都在实时性要求范围内[0.2, 1.0]s.综合考量,SSA在3种场景下均表现优异,在复杂制造环境下具有最优绩效.

进一步对比3类决策机制在不同制造场景下的

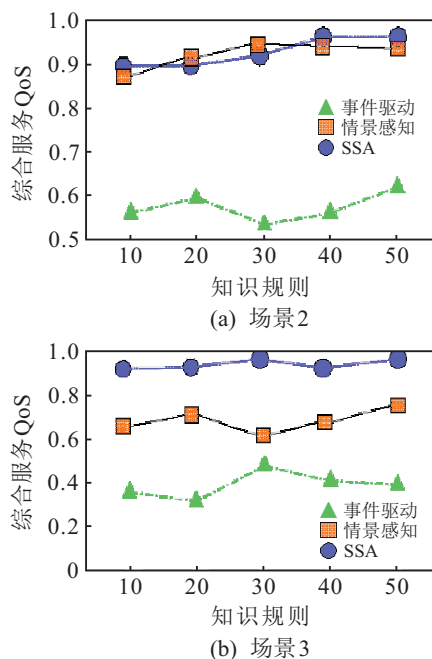


图7 不同场景下的3类决策机制的效果

实际执行绩效,即服务质量QoS,如图7所示.由于场景1中环境和设备信息变化较小,对服务QoS影响忽略不计,故不进行实验分析.分析图7(a)可知,场景2中事件驱动决策机制的QoS较低,情景感知、SSA机制的QoS相似且明显大于事件驱动型,表明服务QoS受环境变化的影响较大.图7(b)中事件驱动的QoS最低,情景感知次之,SSA机制的QoS最高,且三者差别较大,表明服务QoS同时受环境事件和主体状态的影响较大,应及时调整活动以应对异常事件.

### 5 结论

为了应对开放、动态的外部环境以及服务自身的不确定性,本文运用CPS、人工智能等方法构建智能服务单元,通过实时感知过程状态、设备状态、环境信息等进行实时决策活动,实现任务执行的自适应调整.从智能单元个体角度,构建基于感知-分析-决策-执行的组合服务自适应调整架构来解决制造过程中异常情景产生的不良问题.基于现有事件驱动机制的不足,根据当前复杂时变场景的应用需求,设计了情景感知、基于SSA的2类决策机制,并运用智能Agent构建实验环境.

本文提出的方法综合考虑了环境因素、主体状态等对决策过程的影响,提高了服务自适应调整活动的有效性,在准确性、时间和服务QoS指标上均优于现有的自适应决策机制.本文只从单个制造服务单元出发,然而,实际上一个情景决策涉及多个主体,不同层次主体从各自职权范围出发,对同一情景采取不同的决策行动,未来应构建多粒度情景感知决策机制以解决多主体参与的情景决策问题.

### 参考文献(References)

- [1] Ren L, Zhang L, Wang L, et al. Cloud manufacturing: Key characteristics and applications[J]. Int J of Computer Integrated Manufacturing, 2017, 30(6): 501-515.
- [2] Xue X, Wang S, Lu B. Manufacturing service composition method based on networked collaboration mode[J]. J of Network and Computer Applications, 2015, 59: 28-38.
- [3] Lopez F, Saez M, Shao Y, et al. Categorization of anomalies in smart manufacturing systems to support the selection of detection mechanisms[J]. IEEE Robotics and Automation Letters, 2017, 2(4): 1885-1892.
- [4] Xu X. Cloud manufacturing service composition based on QoS with geo-perspective transportation using an improved artificial bee colony optimisation algorithm[J]. Int J of Production Research, 2015, 53(14): 4380-4404.
- [5] Liu B, Zhang Z. QoS-aware service composition for cloud manufacturing based on the optimal construction of synergistic elementary service groups[J]. Int J of

- Advanced Manufacturing Technology, 2017, 88(9): 2757-2771.
- [6] 张萌, 李国喜. 基于区间的制造服务组合多目标优化方法[J]. 计算机集成制造系统, 2017, 23(8): 1787-1796.  
(Zhang M, Li G X. Multi-objective optimization of manufacturing service composition with interval numbers[J]. Computer Integrated Manufacturing System, 2017, 23(8): 1787-1796.)
- [7] Ren L, Zhang L, Wang L, et al. Cloud manufacturing: key characteristics and applications[J]. Int J of Computer Integrated Manufacturing, 2017, 30(6): 501-515.
- [8] 赵秋云, 魏乐, 舒红平. 云制造环境下制造设备云服务异常处理模型[J]. 图学学报, 2014, 35(6): 840-846.  
(Zhao Q Y, Wei L, Shu H P, et al. Exception handling model of manufacturing equipment cloud service for cloud manufacturing environment[J]. J of Graphics, 2014, 35(6): 840-846.)
- [9] 马文龙, 赵燕伟, 王万良. 制造云服务组合异常自适应调整方法[J]. 中国机械工程, 2016, 27(6): 778-784.  
(Ma W L, Zhao Y W, Wang W L. An adaptive adjustment method of composition exception for manufacturing cloud service[J]. China Mechanical Engineering, 2016, 27(6): 778-784.)
- [10] Barakat L, Miles S, Luck M. Adaptive composition in dynamic service environments[J]. Future Generation Computer Systems, 2018, 20: 215-228.
- [11] Kuang L, Liao Z, Feng W, et al. Multimedia services quality prediction based on the association mining between context and QoS properties[J]. Signal Processing, 2016, 120(C): 767-776.
- [12] 闫永明, 张斌, 郭军, 等. 基于强化学习的SBS云应用自适应性能优化方法[J]. 计算机学报, 2017, 40(2): 464-480.  
(Yan Y M, Zhang B, Guo J, et al. A reinforcement learning-based self-adaptation performance optimization approach for SBS cloud application[J]. Chinese J of Computer, 2017, 40(2): 464-480.)
- [13] 江琦, 奚宏生, 殷保群. 事件驱动的动态服务组合策略在线自适应优化[J]. 控制理论与应用, 2011, 28(8): 1049-1055.  
(Jiang Q, Xi H S, Yin B Q. Online adaptive optimization for event-driven dynamic service composition[J]. Control Theory & Applications, 2011, 28(8): 1049-1055.)
- [14] Cheng B, Zhu D, Zhao S, et al. Situation-aware IoT service coordination using the event-driven SOA paradigm[J]. IEEE Trans on Network and Service Management, 2016, 13(2): 349-361.
- [15] Vlahakis G, Apostolou D, Kopanaki E. Enabling situation awareness with supply chain event management[J]. Expert Systems with Applications, 2018, 93(3): 86-103.
- [16] Boubeta-Puig J, Ortiz G, Medina-Bulo I. MEdit4CEP: A model-driven solution for real-time decision making in SOA 2.0[J]. Knowledge-Based Systems, 2015, 89: 97-112.
- [17] Boubeta-Puig J, Díaz G, Macià H, et al. MEdit4CEP-CPN: An approach for complex event processing modeling by prioritized colored petri nets[J]. Information Systems, 2019, 81(C): 267-289.
- [18] Liukkonen M, Tsai T N. Toward decentralized intelligence in manufacturing: Recent trends in automatic identification of things[J]. Int J of Advanced Manufacturing Technology, 2016, 87(9): 2509-2531.
- [19] Alexopoulos K, Makris S, Xanthakis V, et al. A concept for context-aware computing in manufacturing: The white goods case[J]. Int J of Computer Integrated Manufacturing, 2016, 29(8): 839-849.
- [20] Endsley M R. Toward a theory of situation awareness in dynamic systems[J]. Human Factors, 1995, 37(1): 32-64.
- [21] Naderpour M, Lu J, Zhang G. An intelligent situation awareness support system for safety-critical environments[J]. Decision Support Systems, 2014, 59(1): 325-340.
- [22] Naderpour M, Lu J, Zhang G. A safety-critical decision support system evaluation using situation awareness and workload measures[J]. Reliability Engineering and System Safety, 2016, 150: 147-159.
- [23] Ji Y, Massanari R M, Ager J, et al. A fuzzy logic-based computational recognition-primed decision model[J]. Information Sciences, 2007, 177(20): 4338-4353.
- [24] Bryant D J. Rethinking OODA: Toward a modern cognitive framework of command decision making[J]. Military Psychology, 2006, 18(3): 183-206.
- [25] Macquet A C, Fleurance P. Naturalistic decision-making in expert badminton players[J]. Ergonomics, 2007, 50(9): 1433-1450.
- [26] Quintanilla F G, Cardin O, L'anton A, et al. A modeling framework for manufacturing services in service-oriented holonic manufacturing systems[J]. Engineering Applications of Artificial Intelligence, 2016, 55: 26-36.
- [27] Iglesia D G D L, Weyns D. MAPE-K formal templates to rigorously design behaviors for self-adaptive systems[J]. Acm Trans on Autonomous and Adaptive Systems, 2015, 10(3): 1-31.
- [28] 任磊, 任明仑. 复杂事件处理的自适应制造情景识别方法[J]. 哈尔滨工业大学学报, 2017(11): 171-177.  
(Ren L, Ren M L. Adaptive context based situation identification based on complex event processing[J]. J of Harbin Institute of Technology, 2017(11): 171-177.)
- [29] Soysal O M. Association rule mining with mostly associated sequential patterns[J]. Expert Systems with Applications, 2015, 42(5): 2582-2592.

## 作者简介

任磊(1988—), 男, 讲师, 博士, 从事智能服务、数据驱动决策的研究, E-mail: renlei2005062134@aliyun.com;

任明仑(1969—), 男, 教授, 博士生导师, 从事智慧制造、人工智能等研究, E-mail: renml@hfut.edu.cn.