

Agent 在网格资源管理中的应用研究

李福芳¹, 谢冬青¹, 齐德昱², 郭四稳¹, 胡景林²

LI Fu-fang¹, XIE Dong-qing¹, QI De-yu², GUO Si-wen¹, HU Jing-lin²

1. 广州大学 计算机科学与教育软件学院, 广州 510006

2. 华南理工大学 计算机科学与工程学院, 广州 510640

1. School of Computer Science & Educational Software, Guangzhou University, Guangzhou 510006, China

2. School of Computer Science & Engineering, South China University of Technology, Guangzhou 510640, China

E-mail: lifuf@mail.csu.edu.cn

LI Fu-fang, XIE Dong-qing, QI De-yu, et al. Research on Agent-based grid resource management. Computer Engineering and Applications, 2009, 45(10): 30-33.

Abstract: Grid computing has been a hotspot in recent years. Facing geographically distributed, hybrid, autonomous and dynamic changing grid resources, how to manage and schedule them is a key problem, and is still far to be solved satisfactorily. This paper presents a novel grid resource management model based on Agent. In order to take full advantage of intelligence and adaptability of agents, dynamic fuzzy knowledgebase and relevant fuzzy Q learning algorithm are designed for the agents. The model and algorithm have largely met the needs of intelligence, flexibility, scalability and optimization for grid resource management and scheduling. Simulation experiments show that the proposed model and algorithm works soundly and efficiently.

Key words: grid computing; multi-agent system; grid resource management; fuzzy knowledgebase; fuzzy Q learning

摘 要: 由于网格资源的自治、分布、异构和动态变化等特性, 如何有效地管理和调度资源是网格计算领域中的一个关键问题, 至今仍未得到满意的解决。提出了一种基于 Agent 的网格资源管理模型, 为各类 Agent 设计了动态模糊知识库, 并研究了基于动态模糊知识的模糊 Q 学习算法。算法较好地满足了网格资源管理中的智能适应性、扩展性及调度优化的需要。通过模拟实验验证了所研究模型和算法的有效性和效率。

关键词: 网格计算; 多 Agent 系统; 网格资源管理; 模糊知识库; 模糊 Q 学习

DOI: 10.3778/j.issn.1002-8331.2009.10.010 **文章编号:** 1002-8331(2009)10-0030-04 **文献标识码:** A **中图分类号:** TP393

1 引言

近年来, 网格技术成为网络计算领域的一个研究热点。由于网格资源的动态分布和异构的特性, 如何将网格资源进行实时、有效的管理以便实现任务的合理调度, 是网格研究中的关键和难点问题之一, Agent 技术为解决类似网格资源管理这样的动态协同与合作问题提供了一种新的思路。提出了基于 Agent 的网格资源管理模型 GRMMA(Grid Resource Management Model based on Agent), 在 GRMMA 中, 利用 Agent 的智能性和适应性, 自主、灵活地对所辖网格资源进行实时动态管理。为了适应复杂多变且难以确定的网格环境, 为有关 Agent 设计了动态模糊知识库, 以及相应的模糊推理规则, 在此基础上, 提出了基于网格环境中动态模糊知识的模糊 Q 学习算法。由于利用知识库中的知识来指导 Agent 的动作选择, 大大缩小了 Agent 的动作状态空间, 该算法比同类算法收敛速度更快、效率

更高。通过学习, 各 Agent 不断充实和精化知识库中的相关知识, 提高了推理的精确性和合理有效性, 从而有效地管理和调度网格资源, 较好地满足了网格资源管理和调度的适应性、扩展性及调度优化的需要。

2 相关工作

资源管理和调度是网格研究的重点和难点, 在这方面已经做了大量卓有成效的工作。Globus^[1]是目前国际上最有影响的与网格计算相关的项目之一, 在其最新的 GT4 版本中, 引入了分布式层次结构的资源管理模式, 但是 GT4 其实并没有提供严格的资源管理部件, 而是把大部分具体的资源管理和调度任务交给了用户。其他资源管理系统, 如: Legion、Condor/Condor-G、NetSolve、Nimrod/G 等, 分别在特定的领域中得到了成功应用, 但是, 在如何确保对异构且动态变化的网格资源实施实时、

基金项目: 国家自然科学基金(the National Natural Science Foundation of China under Grant No.60475040); 粤港关键领域重点突破项目(the Guangdong & Hong Kong Breakthrough Project in Key Area under grant No.2005A10307007); 广州大学博士启动基金。

作者简介: 李福芳(1968-), 男, 博士, 讲师, 主要研究领域为计算机网络、网络(分布式)计算; 谢冬青(1965-), 男, 博士, 教授, 博导, 主要研究领域为计算机网络、信息安全; 齐德昱(1959-), 男, 博士, 教授, 博导, 主要研究领域为计算机系统结构、计算机网络; 郭四稳, 副研究员, 博士, 主要研究领域为分布式计算; 胡景林, 男, 博士生, 主要研究领域为计算机网络。

收稿日期: 2008-12-05 **修回日期:** 2009-01-06

高效的管理方面, 仍然存在不足^[2]。

Agent 的理论和源于分布式人工智能, 从 20 世纪 80 年代末开始, Agent 理论和在许多领域得到了广泛的应用^[3]。由多个自治或半自治的 Agent 构成多 Agent 系统(Multi-Agent System, MAS), MAS 中的 Agent 相互交互、协调工作, 以完成某些任务或目标^[4]。在复杂多变、开放分布的 MAS 环境中, Agent 必须具备学习能力, 以便从经验中获得有利于实现自身目标的知识。在现有的 Agent 学习方法中, 强化学习(Reinforcement Learning)^[5]是一种能与环境进行交互、无需模型、无导师的在线学习方法, 具有适应动态不确定性环境的优势, 对于无法得到环境的精确模型或者动态环境信息的情况非常适用, 因而受到包括计算机科学、控制科学以及心理学等领域的众多学者的广泛关注, 成为机器学习研究中的一个重要分支, 并已广泛应用于智能控制、智能网络等众多领域。Q^[6-7]学习被誉为强化学习研究中的一个重要里程碑, 其策略是对“状态—动作对(s, a)”的值函数(即 Q 值)进行估计, 在 Q 学习过程中, Agent 将 Q 函数作为动作选择函数来进行下一步动作的选取, 其 Q 值的修正公式如下:

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha[r_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t)] \quad (1)$$

式中, 参数 α ($0 \leq \alpha < 1$) 称为学习率(或学习步长), γ ($0 \leq \gamma < 1$) 为学习折扣率或折扣因子。 Q 学习已得到广泛应用, 其收敛性也被严格证明^[7]。由于 Agent 的状态空间随 Agent 数目的增加而指数性增长, 当系统复杂或规模较大时, 其整体效率不尽理想, 且缺乏规模弹性, 因此, 众多研究者对其进行了深入研究和改进^[7]。

近年来, Agent 技术在网格中的应用也受到高度重视, 网格研究的先驱之一 C.Kesselman 在文献[8]中指出了 Agent 技术对网格资源管理和调度的重要意义, 文献[9]研究了基于 Agent 的网格资源管理, 但没有进一步研究在复杂多变的网格环境中 Agent 的学习问题。本文根据网格环境动态变化的特点, 提出了基于动态模糊知识的模糊 Q 学习算法(Fuzzy Q Learning Algorithm Based on Dynamic Fuzzy Knowledge, FQLA_BDFKB), 算法利用知识库中的知识来缩小 Agent 搜索的状态空间, 从而提高收敛速度和学习效率, 获得了较好的效果。

3 基于 Agent 的网格资源管理模型 GRMM_A

GRMM_A 是一个基于 Agent 的分布式层次模型, 它构建在网格基础平台之上, 从下到上依次是: 抽象网格资源层、网格资源(Agent)层、网格资源管理(Agent)层、网格资源信息数据库和知识库 5 个部分, 其逻辑框图如图 1 所示。在 GRMM_A 中, 下层是构建上层的基础并为上层提供服务; 上层利用下层的提供的支持接口实现本层的功能, 并为更上层提供服务; 网格资源信息数据库和知识库为各种 Agent 提供信息服务。




图1 基于 Agent 的网格资源管理模型

在图 1 中, 抽象网格资源层由部署在各网格节点上的各种各样的网格服务资源组成, 这些网格服务资源构成了网格资源的服务抽象; 网格资源(Agent)层是由代表抽象网格资源的 Agent 组成, 网格资源通过其 Agent 参与到网格资源管理系统中, 即 GRMM_A 通过资源 Agent 对网格资源进行管理, 网格资源 Agent 层由网格节点 Agent(Node Agent, NA)和网格资源 Agent(Grid Resource Agent, GRA)构成, 前者负责网格节点信息的收集、维护和管理, 后者负责网格资源及其信息的收集、维护和管理; 网格资源管理(Agent)层是由网格资源管理 Agent(Grid Resource Management Agent, GRMA)构成的虚拟层, 由各网格节点上的资源管理 Agent 构成; 网格资源信息数据库提供网格资源信息描述的数据结构及存储, 为各种 Agent 提供公共信息服务; 知识库则为各种 Agent 学习、决策提供知识资源, 是各类 Agent 具备智能性和适应性的基础。由于采用了 Agent 技术, GRMM_A 模型具有良好动态性、适应性、智能性、鲁棒性等特点。

4 网格环境中 Agent 基于动态模糊知识的模糊 Q 学习算法

4.1 各类 Agent 的知识库及推理规则的设计

GRMM_A 中有三类 Agent, 即: 节点 Agent(NA)、网格资源 Agent(GRA)和网格资源管理 Agent(GRMA), 与之相对应, GRMM_A 中的知识库由三个子知识库构成, 即: 与 NA 相对应的节点 Agent 知识库 KB_NA(Knowledge Base for NA, 简称节点知识库)、与 GRA 相对应的网格资源 Agent 知识库 KB_GRA(Knowledge Base for GRA, 简称资源知识库)以及与 GRMA 相对应的网格资源管理 Agent 知识库 KB_GRMA(Knowledge Base for GRMA, 简称资源管理知识库), 三个子知识库分别为三种类型 Agent 服务, 构成一个分布式层次知识体系, 其组成结构如图 2 所示。




图2 GRMM_A 模型中 Agent 知识库的组成结构

4.1.1 节点知识库(KB_NA)及其推理规则

如图 2 所示, KB_NA 由节点事实知识、节点推理知识组成, 它们均以表的形式存储于关系数据库中, 便于更新和查询。节点事实知识主要包括节点相关的状态信息、通过学习所得的经验判断等精确的或者模糊的事实知识, 比如节点处理器的情况、节点被调用的情况、节点即将被调用的趋势等(见表 1)。精确或模糊事实知识均用谓词逻辑表示, 前者表示为: 谓词名(对象, 属性, 数值, 可信度), 后者表示为: 谓词名(对象, 属性, 模糊描述, 程度值, 可信度), 其数据库表的结构分别如表 1、表 2 所示, 其中 Fact_Id 字段为事实索引编号, 其他字段的含义如前所述。

表1 精确知识表的结构

Fact_Id	Obj	Prop	Val	Conf
001	节点 <i>i</i>	处理器	4	1

表2 模糊知识表的结构

Fact_Id	Obj	Prop	Desc	Deg	Conf
001	节点 <i>i</i>	繁忙程度	很繁忙	0.90	0.95

节点推理知识即 Agent 进行决策推理时使用的推理规则,一般具有“IF 前件 THEN 后件”的形式,推理知识用产生式规则表示。对于基于精确知识的推理,可以直接应用产生式规则表示,而对于基于模糊知识的推理,则需要做适当改进。为了提高推理效率,加快算法的收敛速度,当进行模糊推理时,对模糊推理规则增加一个适用阈值,只有规则前件的可信度大于该阈值时该模糊推理规则才能适用,即推理继续进行;否则,该模糊推理规则不能适用,即基于该模糊推理规则的推理不再进行,这样可以剔除不必要的无效推理,从而改善系统性能和效率。基于模糊知识的推理规则可以表示成“IF 前件(模糊知识) THEN 后件(模糊结论或知识)(可信度)(δ)”,($0 < \delta \leq 1$),例如关于节点响应慢的原因的模糊推理规则:Rule(IF“(节点响应慢,0.85,0.80)”THEN“(网络拥塞,0.70,0.75)(0.65)(0.60)”),它表示的推理规则为:如果节点有 0.85 程度的慢(信度 0.80),则网络拥塞的程度为 0.70(信度 0.75),其可信度有 0.65,当规则的前件可信度不低于 0.60 时该规则适用。模糊推理知识的数据库表的结构如表 3 所示,其中,Rule_Id 是规则编号,其余字段的含义如上所述。

表3 推理知识表的结构

Rule_Id	Cond	Conc	Conf	Limit_Conf	Used_No
001	节点响应慢,0.85,0.80	网络拥塞,0.70,0.75	0.65	0.60	3

为了简化,KB_NA 中的精确推理知识的表结构与表 3 相同,其与模糊推理知识的区别在于精确推理知识的信度值为 1,其推理机制也与模糊推理类似。

4.1.2 资源知识库(KB_GRA)和资源管理知识库(KB_GR-MA)及其推理规则

KB_GRA 是供网格资源 Agent 学习、推理、决策的知识库,由事实知识和推理知识组成(参见图 2)。在 GRMM_A 模型中,网格资源即各节点上的网格服务资源,KB_GRA 的事实知识主要包括与网格服务资源相关的事实信息,如资源规模、功能描述、活动状态、调用参数等资源本身的属性,以及通过学习获得的经验、判断等知识,如资源的服务性能、可靠性、使用频次、成功(失败)调用率、可用性趋势等。KB_GRMA 是资源管理 Agent 管理和调度自治域内网格资源所使用的知识库(参见图 2),KB_GRMA 也由事实知识和推理知识构成。KB_GRMA 的事实知识包括所管辖范围内网格资源的有关状态(事实)信息,如所管理资源的规模、可靠性、资源累计被调用次数、成功(失败)调用次数等。KB_GRA 和 KB_GRMA 的事实知识也有精确知识和模糊知识之分,它们在关系数据库中的表示方法分别与表 1、表 2 类似。

KB_GRA 和 KB_GRMA 的推理知识分别是资源 Agent 和资源管理 Agent 进行决策推理时使用的推理规则,由相关的领域知识、专家知识以及通过强化学习获得的推理知识(规则)组成,这些知识均具有“IF 前件 THEN 后件”的一般形式,而且也

有精确与模糊之分,在数据库中的存储形式如表 3 所示,其推理机制也与节点 Agent 的推理机制一致。

4.2 基于动态模糊知识的模糊 Q 学习算法

为了改进和提高 Q 学习效率,提出了基于动态模糊知识的模糊 Q 学习算法 FQLADFKB(Fuzzy Q Learning Algorithm based on Dynamic Fuzzy KnowledgeBase),其策略是:利用知识库中的精确或模糊的动态知识来指导 Agent 的动作选择,从而有效地缩小了 Agent 搜索的状态空间、加快算法的收敛速度,使学习效率得以大大提高。FQLADFKB 的原理图如图 3。




图3 FQLADFKB 算法原理

FQLADFKB 主要在以下两个方面做了改进:(1)在动作选择阶段,Agent 首先搜索知识库中的(精确或模糊的)知识,如果有相匹配的知识,则根据知识指导选择新的动作,否则根据 Boltzmann 分布的概率方法选择下一步动作;(2)执行新的动作之后,在获取环境奖赏的同时,根据奖赏值更新知识库中的知识,使知识库中的知识保持最新。算法 FQLADFKB 的伪码描述如下:

算法 1 基于动态模糊知识的模糊 Q 学习算法 FQLADFKB
Step1:for(all (s, a)) { initialize $Q(s, a)$;
Step2:for(all S_t) {
Step2.1:select a state S_t ,traversal the knowledgebase;
Step2.2:If(there exist valid guiding knowledge)
then chose the action a_t according to the guiding knowledge;
else chose the action a_t according to Boltzmann distribution;
Step2.3:do action a_t ,observe the new state s_{t+1} ,and get the re-ward r_{t+1} ;
Step2.4:update the knowledgebase according to r_{t+1} ;
Step2.5:adjust the value of Q by formula (1);
Step2.6: $S_t \leftarrow s_{t+1}$;
Step2.7:if(s_{t+1} meets the goal) { learning finished;
}
Step3:End.

5 模拟实验及分析

为了考察算法 FQLADFKB 在网格资源管理和调度中的具体效果,通过模拟实验来进行验证。由于还没有能够同时模拟 Agent 和网格环境的仿真平台,因此采用简化的实验方案,即模拟实验在典型 Agent 平台 Aglets 上进行,实验时设计了 FQLADFKB 算法所需要的三种 Agent,此外专门设计一种具有网格资源特征的 Agent 来代替实际的网格资源。实验中,依次按照表 4 所示的 7 组资源和任务数目进行模拟,将任务调度到对应的网格资源上执行,每种情况模拟 15 次,然后取平均值,实验结果如图 4、图 5 所示。为了便于比较,将 Agent 不进行学习(No Learning,NL)和采用基本 Q 学习(Basic Q Learning,BQL)算法时的调度结果,在图 4、图 5 并列列出,其中,图 4 是

调度长度(makespan),图5是失败调度比率(%)。

表4 所模拟的资源 and 任务数

编号	1	2	3	4	5	6	7
资源数	15	30	45	60	75	90	105
任务数	100	200	450	650	900	1 200	1 600




图4 调度长度(makespan)




图5 失败调度比率

从图4、图5可以看出,在资源和任务规模较小时,三种情况的调度长度和失败调度比率无明显差别,甚至采用 FQLADFKB 算法时调度长度还要稍差一些;当资源和任务规模较大时,采用 FQLADFKB 算法的调度长度和失败调度比率明显优于其它两种情况,而且随着资源和任务规模的增大,优势更加明显。这是由于,当资源和任务规模较小时,FQLADFKB 中的 Agent 进行学习需要耗费一定的资源,其协作智能性和适应性等优势未能充分体现,导致其调度长度反而不理想;而当规模较大时,FQLADFKB 算法中 Agent 学习的智能适应性、可扩展性和鲁棒性优势得以发挥,因此调度长度和失败调度比率均表现较好,从而达到调度优化的目的,而且,随着资源和任务规模

的增大,其优势更加明显。

6 结论

Agent 技术对网格资源管理和调度具有重要意义,它有望较好地解决动态分布、复杂多变的网格环境中资源管理和调度的难题。探讨了基于 Agent 的网格资源管理模型及基于动态模糊知识的模糊 Q 学习算法,利用 Agent 的智能学习和适应特性,自主、灵活、高效地对网格资源进行实时动态管理,较好地解决了网格资源管理和调度的适应性、扩展性、鲁棒性等调度优化问题。

参考文献:

- [1] Foster I, Kesselman C. Globus: A metacomputing infrastructure toolkit[J]. Intl J Supercomputer Applications, 1997, 11(2): 115-128.
- [2] Wei Jie, Terence H, Turner S J, et al. Architecture model for information service in large scale grid environments [C]//Sixth IEEE International Symposium on Cluster Computing and the Grid 2006, CCGRID 06, 16-19 May 2006, 1: 107-114.
- [3] Wooldridge M, Jennings N R. Intelligent agents: theory and practice[J]. Knowledge Engineering Review, 1995, 10(2): 115-152.
- [4] Corchado J M, Lees B, Fyfe C. Project monitoring intelligent agent system[C]//IEE Colloquium on Intelligent World Wide Web Agents, London, 1997.
- [5] Sutton R S, Barto A G. Reinforcement learning: an introduction[M]. Cambridge, USA: MIT Press, 1998.
- [6] Watkins H, Dayan P. Q-learning[J]. Machine Learning, 1992(8): 279-292.
- [7] Gu P, Maddox A. A framework for distributed reinforcement learning[M]//Adaption and Learning in Multi-agent Systems. Berlin, Germany: Springer-Verlag, 1996: 97-102.
- [8] Kesselman C. Applications of intelligent agent technology to the grid[C]//Proceedings of IAT 2004, IEEE/WIC/ACM 2004 International Conference on Intelligent Agent Technology, 2004.
- [9] 曾正军, 舒万能. 基于移动 Agent 的网格计算资源管理模型设计[J]. 计算机工程与应用, 2008, 44(21): 138-141.

(上接 29 页)

- [29] Morsdorf F, Meier E, Kotz B, et al. Lidar based geometric reconstruction of boreal type forest stands at single tree level for forest and wildland fire management[J]. Remote Sensing of Environment, 2004, 92: 353-362.
- [30] Weinacker H, Koch B, Weinacker R. TREESVIS—a software system for simultaneous 3D-real-time visualization of DTM, DSM, laser raw data, multispectral data, simple tree and building models[J]. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2004, XXXVI-8/W2: 90-95.
- [31] Decaudin P, Neyret F. Rendering forest scenes in real-time[C]//Eurographics Symposium on Rendering, 2004: 92-102.
- [32] Cohen F, Decaudin P, Neyret F. GPU-based lighting and shadowing of complex natural scenes[C]//International Conference on Computer Graphics and Interactive Techniques, 2004: 91.
- [33] Colditz C, Coconu L, Deussen O, et al. Real-time rendering of complex photorealistic landscapes using hybrid level-of-detail approaches[C]//Proceedings at Anhalt University of Applied Sci-

ences, 2005: 1-11.

- [34] Roettger S. NDVI-based vegetation rendering[J]. Proceeding (553) Computer Graphics and Imaging, 2007, 010.
- [35] Soler C, Sillion F X, Blaise F, et al. An efficient instantiation algorithm for simulating radiant energy transfer in plant models[J]. ACM Transactions on Graphics, 2000, 5: 1-32.
- [36] Qin Wen-han, Gerstl S A W. 3-D scene modeling of semidesert vegetation cover and its radiation regime[J]. Remote Sens Environ, 2000, 74: 145-162.
- [37] Qin Wen-han, Gerstl S A W, Deering D W, et al. Characterizing leaf geometry for grass and crop canopies from hotspot observations: A simulation study[J]. Remote Sens Environ, 2002, 80: 100-113.
- [38] Disney M, Lewis P, Saich P. 3D modeling of forest canopy structure for remote sensing simulations in the optical and microwave domains[J]. Remote Sens Environ, 2006, 100: 114-132.
- [39] Castel T, Caraglio Y, Beaudoin A, et al. Using SIR-C SAR data and the AMAP model for forest attributes retrieval and 3-D stand simulation[J]. Remote Sens Environ, 2001, 75: 279-290.