



# 群体智能系统的动力学模型与群体熵度量

罗杰<sup>1\*</sup>, 姜鑫<sup>2,3,5</sup>, 郭炳晖<sup>2,3</sup>, 郑宏威<sup>4</sup>, 吴文峻<sup>1</sup>, 吕卫锋<sup>1</sup>

1. 软件开发环境国家重点实验室, 北京航空航天大学计算机学院, 北京 100191

2. 软件开发环境国家重点实验室, 大数据科学与脑机智能高精尖创新中心, 北京航空航天大学数学科学学院, 北京 100191

3. 鹏城实验室, 深圳 518055

4. 广州大学人工智能研究院, 广州 510006

5. 郑州航空港经济综合实验区空港人工智能研究院, 郑州 451162

\* 通信作者. E-mail: luojie@nlsde.buaa.edu.cn

收稿日期: 2020-06-29; 修回日期: 2020-09-11; 接受日期: 2020-11-17; 网络出版日期: 2022-01-05

科技创新 2030—“新一代人工智能”重大项目 (批准号: 2018AAA0102301) 资助

**摘要** 群体智能是自然界普遍存在的现象, 受到了国内外研究者的广泛关注. 网络和人工智能技术的高速发展, 使得大规模群体在网络上通过个体智慧激发和群体智慧汇聚形成超越个体能力的群体智能成为可能. 随之而来, 如何认知和形成这样的群体智能系统成为了研究的热点. 本文将在广义群体智能的概念体系之下, 探索群体智能系统的度量理论和方法, 以此来促进对群体智能形成机理的更深层认知. 本文提出了群体智能系统的基本特性以及其形成的激发汇聚建模, 指出群体智能系统实质上是一类复杂非线性动力学系统, 包含微观个体激发、宏观群体协作、全局群智汇聚 3 个核心动力学属性. 并以此为基础, 讨论了群体智能系统群体熵度量所应满足的基本性质. 最后以图的群体化搜索为例, 说明了群体的激发和汇聚过程, 以及在此过程中如何通过群体熵来度量群体行为的变化, 验证了本文提出的群体熵度量思想的有效性.

**关键词** 群体智能系统, 动力学模型, 群体熵, 度量, 激发, 汇聚

## 1 引言

群体智能 (swarm intelligence) 的概念最早在 1989 年由 Beni 和 Wang<sup>[1]</sup> 针对元胞自动机提出, 之后被用于泛指无智能或低智能的个体通过相互之间的简单合作所表现出来的智能行为, 如自然界广泛存在的蚁群觅食、鱼群避敌、鸟群迁徙等. 在这方面的研究工作被进一步扩展到研究其形成的机理, 形成相应的算法, 并将其用于无人系统集群等的控制中. 而针对具有高智能的个体 (通常指人) 在合作与竞争中涌现出来的智能, 通常被称为集体智能 (collective intelligence). 麻省理工学院 (Massachusetts Institute of Technology) 专门成立了集体智能研究中心专门研究人和计算机组成的群体的集体智能<sup>[2]</sup>.

**引用格式:** 罗杰, 姜鑫, 郭炳晖, 等. 群体智能系统的动力学模型与群体熵度量. 中国科学: 信息科学, 2022, 52: 99–110, doi: 10.1360/SSI-2020-0193

Luo J, Jiang X, Guo B H, et al. Dynamic model and crowd entropy measurement of crowd intelligence system (in Chinese). Sci Sin Inform, 2022, 52: 99–110, doi: 10.1360/SSI-2020-0193

随着网络和人工智能技术的高速发展, 联接处于不同时空结点的个体成为可能, 广泛互联的大规模人类群体和非人智能体开始形成, 这使得群体智能的概念在原本的群体智能和集体智能的基础上有了进一步扩展的可能. 李未等<sup>[3]</sup> 在中国新一代人工智能战略规划中将这种大规模复杂群体通过个体智慧激发和群体智慧汇聚涌现出的超越个体能力的智能称为群体智能 (crowd intelligence), 这一概念是对前人提出的 Swarm Intelligence 和 Collective Intelligence 的一种整合, 希望建立一个可以容纳低智能和高智能个体的群体智能统一研究框架, 并带动群体智能成为解决开放不确定环境中大规模复杂问题的一种新模式. 在这一研究框架下, 人群的软件创新、无人集群协同对抗等大规模复杂群体行为, 都可以视作一种通过社群化的组织结构来管理、协调和运行, 以竞争、合作等多种自主协同方式来共同完成挑战性任务, 并涌现出超越个体能力的群体智能.

与上述两组概念相对应, 群体智能的研究也主要针对非人类个体和人类个体构成的群体行为两条线展开. 一方面, 人们在生物群体的启发下进行仿生群体智能的研究, 主要包括: 生物群体模拟仿真, 如模拟鸟群行为的 Boids 模型<sup>[4]</sup>、自驱动粒子模型 (Vicsek 模型)<sup>[5]</sup> 等; 仿生的启发式算法, 如随机搜索算法<sup>[6]</sup>、进化算法<sup>[7]</sup>、蚁群优化算法<sup>[8]</sup>、粒子群优化算法等; 强化学习算法, 比如 Q-Learning<sup>[9]</sup>、多主体深度强化学习<sup>[10,11]</sup> 等; 机器人集群控制, 如移动多主体的协同<sup>[12]</sup> 等. 另一方面, 人们也针对人类群体开展群体行为模拟和预测, 以及利用人群知识的共享完成挑战性任务等研究, 主要包括: 人群行为模拟, 如 MASSIVE 人群仿真系统<sup>1)</sup> 等; 人群行为识别和预测, 如基于传感数据的行为预测<sup>[13]</sup> 等; 群体共识决策, 如 Google 流感预测<sup>[14]</sup>、reCAPTCHA 和维基百科<sup>[15]</sup> 等; 群体软件开发, 如开源软件社区<sup>2)3)4)</sup>、众包软件开发<sup>[16]</sup>、互联网协同软件开发<sup>[17]</sup> 等.

从上述群体智能的研究中我们可以看到, 当前的研究工作主要以模拟自然界和人类社会的群智行为和应用群智的方式解决复杂问题为主, 对于如何认知群体智能、如何形成群体智能、如何实现群体智能的演化等关键性问题仍然有待进一步突破. 在我们构造的群体智能系统中常常出现“群而不智”等挑战, 系统中的群体行为主要基于预设, 而不是动态地根据环境和态势的变化来动态演化和适应. 而突破这一挑战性问题的核心在于如何对群体智能系统的能力或智能进行有效的度量, 以衡量该系统对于群体中的每一个体的能力或智能有效利用的程度, 并最终解决其目标任务. 为此, 部分学者开始从系统的角度出发, 对群体智能系统的行为和智能等指标进行度量.

群体智能系统是一类复杂动态演化系统, 系统中存在大量的随机与非线性因素, 如环境的改变、个体间的相互作用等. 实际上, 从数学角度来看, 动力学 (动力系统) 就是研究系统在各类复杂因素作用下演化规律的一门学科, 演化的稳定性和演化最终形成的系统结构是此学科大量研究的焦点. 其中, 演化的概念是时空意义下的, 对于时间而言, 可以是连续或离散的, 如微分方程定性行为, 对空间而言, 可以是对向量场或映射规则的扰动. 反观群体智能系统, 每个个体在系统中的行为也是在各类规则约束下不断演化的, 个体之间也存在相互作用和影响, 环境 (空间) 也提供了各种随机干扰因素, 这也对应了一种时空意义下的演化, 同时, 群体智能的形成, 恰恰对应系统形成了某类稳定的功能结构. 从这个意义上来说, 采用动力学的思想对此类复杂系统进行研究是十分必要的. 值得注意的是, 已有学者将动力学方法应用于其他复杂系统的研究. 如郑志明等<sup>[18,19]</sup> 基于动力系统对软件系统的可信性特征的度量进行了定性研究, 提出了一种新的软件系统可信性度量方法. 而熵最初作为描述热力学系统混乱程度的物理量, 在复杂系统的研究中也有着广泛的应用. 如在系统的熵度量方面, Kauffman<sup>[20]</sup> 提出了布尔网络模型 (Boolean network, BN), 该模型通过一个离散动力学过程刻画系统的状态演化及其中

1) MASSIVE. <http://massivesoftware.com/>.

2) GitHub. <http://github.com/>.

3) Trustie. <https://www.trustie.net/>.

4) CSDN. <https://www.csdn.net/>.

的自组织现象. Zhao 等<sup>[21]</sup>提出了部分互信息熵用于描述网络中的非线性关联关系. 在群体行为的熵度量方面, Corneel Casert 利用熵研究了群体运动行为中的涌现现象<sup>[22]</sup>. 郑志明等<sup>[23]</sup>构建了复杂动力学系统熵的多项式求根方法. 这些动力学系统的研究从系统演化的角度给出了部分复杂系统(如软件系统)演化的动力学机理和演化的最终形态, 为研究智能行为的动力学提供了丰富的理论基础. 但是, 大多数研究主要关注的是某个演化机制较为单一系统的行为, 对于群体智能这种可能内蕴多种演化机制的复杂系统, 还需要发展更加科学和全面的模型和方法论.

由于智能本身是一种抽象的实体, 难以对其进行直接的评估和度量. 而群体智能系统的行为是群体智能的外在表现形式, 是一种可以直接度量的现象, 所以可以从系统的动力学行为入手, 探索群体智能系统的度量理论和方法. 从当前的研究现状中, 我们知道对复杂非线性系统的度量的最典型工具之一就是熵, 因此本文将基于复杂非线性动力学系统的熵, 从系统行为的角度对群体智能系统进行度量. 由于群体智能系统是一个开放并且动态演化的系统, 本文将从两个方面来对群体智能系统进行度量, 基于结构熵来度量群体智能系统的随时间的动态变化, 基于测度熵和拓扑熵来度量群体在空间中的动态演化过程, 并基于此提出群体智能系统的群体熵 (crowd entropy) 度量理论, 为突破群体智能系统“群而不智”这一挑战性问题 and 实现群体智能系统的“群而增智”奠定理论基础, 并支撑对群体智能的认知、构建和演化等关键技术的研究.

本文主要包含 6 个小节. 第 2 节主要介绍群体智能的基本特性以及群体智能的激发汇聚模型. 第 3 节讨论群体行为持续的激发和汇聚迭代过程中演化出群体智能的动力学模型. 基于此模型, 本文在第 4 节中讨论群体智能行为度量需要满足的基本性质, 并引入群体熵的初步概念, 用于群体智能行为的度量. 在第 5 节以图搜索为例验证群体智能系统激发和汇聚过程中熵的变化趋势, 即激发过程熵增、汇聚过程熵减. 最后第 6 节给出本文的结论和未来的可能研究方向.

## 2 群体智能

群体智能是大规模复杂群体通过个体智慧和能力的激发, 以及群体智慧和能力的汇聚, 而涌现出超越个体能力的智能. 它通过社群化的组织结构来管理、协调和运行, 以竞争、合作、对抗等多种自主协同方式来共同完成挑战性任务. 群体智能的基本特性包括: 群体性、共识性、涌现性、演化性. 群体性定义了群体智能的基本形态, 共识性和涌现性共同刻画了群体智能的核心机理, 演化性反映了群体智能在涌现过程中的复杂变化和实现原理.

**(1) 群体性.** 智能体集合按照一定规则 (共识) 相互作用形成分布式系统. 这类系统广泛存在于自然界和人类社会之中, 例如, 细菌等微生物种群、真社会性昆虫群体、鱼群、鸟群等. 人们通过研究各种各样的群体系统的智能行为, 揭示群体智能的普遍科学原理, 指导大规模人工群体智能系统的设计和运行.

**(2) 共识性.** 智能群体在局部交互中, 按照一定规则形成全局性共识, 产生共识激励, 驱动群智涌现, 是群体智能的内在体现. 自然界和人类社会存在两大类型的群智共识形态, 一类是以蜂群、蚁群为代表的低智能体群智, 另一类是人类社群为代表的高智能体群智. 低智能体群智由智能受限个体组成, 个体行为模式简单, 只具备较简单的决策适应能力. 其共识机制以服从性共识为主, 个体受周围的生物激素、同伴运动的激励, 被动地模仿和趋同. 高智能体群智由具备自由意志的高智能个体组成, 行为模式复杂, 具备自主决策能力. 其共识机制以自主性共识为主, 个体根据内在的需要, 结合外在激励, 自主选择策略, 通过信息交互形成共识.

**(3) 涌现性.** 群体共识水平决定群体智能的涌现强度, 是群体智能的外在体现. 比如, 虫/鸟群由

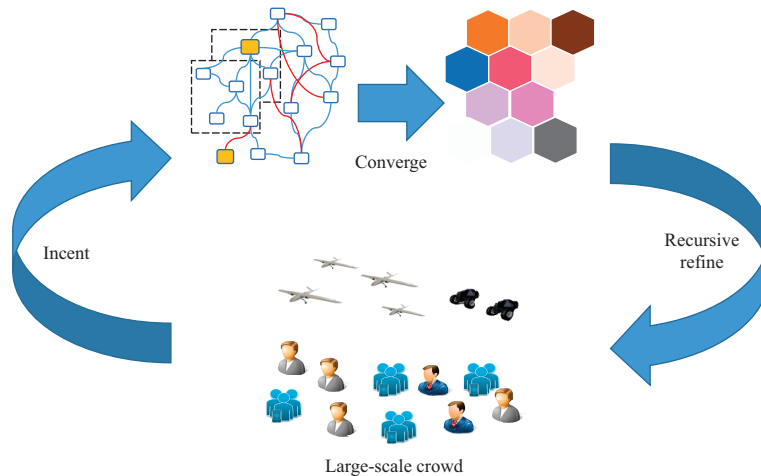


图 1 (网络版彩图) 群体智能的形成过程

Figure 1 (Color online) The formation of crowd intelligence

于只具有简单的共识机制, 其群体智能涌现强度低, 只能通过局部交互相互影响, 趋同呈现一种或几种运动模式. 而人类群智形态, 例如开源社区群智, 具有高度复杂的认知共识机制, 其群体智能涌现强度高, 可以通过多模态协同交互, 充分发挥个体多样化的创新能力.

**(4) 演化性.** 智能群体在涌现过程中不断演化其行为, 以适应动态变化的环境, 群体智能的演化性是描述群智涌现过程的复杂形态, 即涌现是如何实现的.

群体智能的涌现过程往往要经历初始态、变化态、稳定态及其相变, 这些演化形态需要通过群体之间的动态交互网络呈现. 群体智能的涌现是群体智能系统在变化态和稳定态反复迭代演化的结果, 变化态对应于个体的激发, 而稳定态则对应于群体的汇聚.

基于群体智能的基本特性, 本文将群体智能的涌现过程刻画为图 1, 它是一个激发和汇聚交替精化迭代的过程.

**个体激发.** 激发过程主要涉及吸引和引导大量的人类参与者或非人智能体按照一定的组织方式来探索挑战性任务的完成路径或给出挑战性任务不同子任务的解决方案, 其基本的思路是通过大量的个体并行地依据不同的途径探索和实现任务的分解和求解. 在这一过程中, 强调的是激发出不同个体的差异性和创造性, 以确保不同的个体的能力都得到充分的发挥, 为任务的完成作出最大的贡献. 因此, 这一过程中群体里的个体行为或状态将从稳定到变化, 对应于熵增.

**群体汇聚.** 汇聚过程则主要将激发过程中获得的差异化分解和求解方案进行评估和汇聚, 找出通往完成最终任务这一目标的优化路径以及此过程中需要解决的不同子任务的解决方案. 在这一过程中, 重点则在于如何确保不同个体的工作成果能够有效地进行融合汇聚, 是从众多个体的创造成果或完成结果中筛选出匹配任务目标的部分, 进行融合汇聚, 以实现预期的任务目标. 这一过程中我们从群体中筛选出了有效的个体, 使得群体中的个体从变化向稳定有序进行转变, 对应于熵减.

在每一轮迭代完成之后, 基于本轮迭代激发过程试错探索的结果精化下一轮迭代激发的策略, 使得群体中每一个体的智慧和能力在这样持续迭代的过程中以完成挑战性任务为目标持续激发和稳态汇聚, 涌现出超越个体能力的群体智能.

在这样一个群体智能的形成过程中, 我们需要对每一个激发和汇聚过程进行度量, 一方面可以作为下一轮迭代精化的依据, 另一方面也便于对群体智能本身的特性进行分析评估. 由于群体的智能主

要通过其行为外在表现出来,通过对群体智能行为的度量可以在某种程度反映群体的智能.因此,本文将主要讨论如何对群体智能行为进行系统性的度量.由于群体智能形成的过程是一个激发和汇聚交替迭代驱动智能演化的过程,激发或者汇聚本质上是一种不断作用在个体上的一种系统机理,此机理会不断将个体行为从一种状态转化为另一种状态,这可以用映射的思想加以刻画.这样,大量的个体行为状态就可以看作是系统的相空间,而激发和汇聚的机理就可以看作是定义在相空间上的映射,这就构成了一个广义的动力系统.同时,在实际中,相空间通常是带有某种结构的,因此需要考虑保持此类的映射,比如测度空间和保测映射、距离空间和等距映射等.一个实际的群体智能系统中,如无人机群系统,无人机的行为需要协同飞行时的距离不变性结构,这就需要保距映射的作用.这都是数学中动力学理论研究的内容,因此,可以采用数学中的动力学系统理论来进行描述和建模,所以将在第 3 节构建群体智能行为的动力学模型,以此作为群体智能行为度量的基础.

### 3 群体智能的动力学模型

大规模复杂群体行为是以随机、非线性和动态为基本特征的演化过程,如人群的软件创新、无人集群协同对抗、开源知识协作平台等,都是在社群化组织复杂的结构框架规则下通过不断的动态迭代实现智能演化的.群体智能的两个关键要素是多模态群智的长效激励机制与稳态汇聚规程.如何形成长期高效的个体智能激发和动态调控,实现群智的稳定有序汇聚策略,是群智行为动力学建模的主要目标.本文提出复杂群体智能行为需要从表示模型和演化模型两个方面进行深入研究,不仅需要给出群体行为在不同尺度、不同层次上的表示模型,还需要揭示个体以及个体之间在复杂的非线性和随机因素的作用下不断演化的动力学规律和特征.

复杂群体智能行为的表示模型需要基于行为是“行为主体为达到目标所执行的动作序列”这一认知,对个体、个体间交互和群体层面建立层次化的智能行为表示模型.具体而言,针对群体中的单个个体,个体行为表示模型的构建包括结合动作序列和目标驱动因素,刻画具有一定激发属性的个体在与随机环境和其他个体相互作用下的行为轨迹,其一般具有时间意义下的复杂性和不确定性.进一步,在个体行为描述的基础上,具有一定自由度的个体间会产生交互作用关系,其特征可以概括为局部有限、全局可达的交互范围以及包含合作、竞争、对抗等类型在内的非线性交互行为,可以通过领域知识指导的机器学习模型参数初始化、模型结构设计、识别结果约束等技术实现对个体以及个体间非线性交互行为的准确描述.最后,群体层面的行为描述则需建立在个体行为、个体交互、环境因素融合的基础上,个体之间组成相互关联的众多子群体与随机变化的异质资源进行交互演化,构成了群体层面行为的复杂特征,其要素包括子群的协调合作、群体结构与资源的优化配置、群体系统对环境变化的调整适应、大规模任务的协作完成等方面.

复杂群体智能行为的演化模型则是在表示模型的基础上,进一步增加基于群体行为机制的智能群体关联动态演化行为建模,构建能够融合个体与群体互动行为演化的综合模型.该模型应涵盖对智能个体的感知、交互和运动特性等的动力学描述模型,同时考虑行为随机性、环境影响、个体差异性、非线性交互等因素在模型中的体现.因此,群体行为演化的时空聚集性、运动的有序性、环境的适应性等特征是重点考虑的对象.群体行为的演化特性,包含个体、群体、环境中各要素相互协调适应的演化规律:个体组成的子系统间不是孤立地起作用,而是相互关联,相互影响的;群体系统的特性也是动态的,这种动态关联性不但涉及子系统与子系统之间的相互适应与调整,也包括系统与环境间的相互作用引起的宏观结构的动态变化;由内部子系统之间相互作用或者环境突发变化引起的随机因素影响共存于子系统间的适应与群体组织过程之中.因此,微观个体和宏观整体之间形成一种关联网络演化模

型, 群体系统的组织结构、交互机制等关系体现为网络的自组织机制与演化迭代机制, 外在则表现为蜂拥、目标集合聚集、对抗博弈、合作汇聚等群体行为模式。

事实上, 随机、非线性和动态融合作用下的群体行为, 从数学上可以抽象为一类非线性随机动力学系统. 要研究群体行为的智能特征, 需要首先刻画群体行为对应系统的复杂性特征, 进而, 群体行为的智能性可以由复杂性程度进行刻画. 由于不同智能模式驱动下系统的复杂性特征是不一样的, 需要对群体行为复杂性的类型进行基本的判别, 并在分类基础上对复杂程度和复杂程度判据进行研究, 从而为群体行为的智能优化和工程决策作出科学的指导. 基于此, 本文认为群体行为的复杂性是衡量群体智能的有效指标, 在群体智能的激发阶段, 由于多样性个体行为的出现和加入, 群体行为在时间和空间上均呈现复杂性激增的无序状态, 而在群体智能的汇聚阶段, 随着目标导向机制的逐步建立, 随机和非线性关系导致的不确定性逐渐消退, 群体行为出现协同有序的状态, 复杂性逐渐保持稳定。

熵 (entropy) 作为复杂性度量的深刻科学概念, 可以有效度量群体智能的复杂性. 本文提出群体熵的概念, 通过度量群体行为的动力学复杂性对群体智能进行刻画, 它不仅度量群体行为和关联结构在统计意义下的混乱程度和不确定性, 更要度量在群体智能形成过程中的动态复杂性特征和结构复杂度, 以及对演化最终形态的复杂性判定。

从数学角度看, 群体熵是群体行为演化形成的类动力系统的一种拓扑熵的概念, 它是群体行为演化系统的一个不变量, 也是一个关于系统不确定性的度量. 它不仅描述了群体行为随时间演化的隐藏信息产生率, 也控制着群体行为的遍历性, 即是否能达到时间和空间的均匀混乱. 显然, 在群智的激发阶段, 系统更希望多样性个体和异质资源的大量涌入, 导致群体熵的增加, 而在群智的汇聚阶段, 系统的动态随机性被逐步控制, 导致群体熵的稳定或者减小. 针对群体智能的动力学复杂性分析, 需要深入研究大规模复杂群体在形成智能过程中的微观个体激发、宏观群体协作、全局群智汇聚 3 个核心属性的动力学特征, 从而有效地描述群体智能的复杂性内涵。

**微观个体激发行为对应系统不同初值和不同系统参数条件下的轨道.** 个体激发过程可以模型化地描述为不同类型的个体在一定自由度范围内实现主动演化的行为, 一组个体行为其本质上可以对应非线性动力学系统在不同初值或边界条件下形成的一簇轨道, 而激发条件则对应于非线性动力学系统的系统参数. 同时, 对于多个微观个体而言不同个体可能处于不同的子系统中, 其行为演化的复杂性可以由个体在多初值条件和多子系统中反应出的轨道演化形态所刻画。

**宏观群体协作过程对应动力学系统形成的轨道集合及其结构复杂性问题.** 群体行为可以模型化地由不同类型的个体在一定关联规则 (非线性关系) 的作用下演化形成的动态轨道集合来描述. 其中, 个体行为的随机和非线性必将导致群体轨道结构的复杂性. 因此, 度量群体行为的动态复杂性可以转化为对相应的动力学系统轨道复杂性进行度量. 例如, 非线性系统经典的 Lorentz 吸引子都具有稠密周期轨道集合, 其动态复杂性表现为混沌和分形特征。

**群智汇聚过程可以模型化为动力学系统的“分支理论”.** 如果把群体系统受到的激发条件、环境的随机因素等表示为系统的控制参量, 那么群体行为演化所确定的动力学系统的整体演化状态会在控制参量的某些分支值 (bifurcation values) 处发生结构性变化. 这就可以通过度量群体行为轨道复杂性的“群体熵” (拓扑熵) 来刻画. 群体熵的不断增大意味着系统越复杂越呈现随机性质, 即个体行为的轨道过于稠密而导致分辨个体行为的复杂度不断升高, 使得系统发展的趋势难以确定. 为了使得群智朝可控可解释方面发展, 就需要实现带有目标约束条件的个体主动演化和关联规则演化的复合优化过程, 调节系统的控制参量, 满足适当的分支值. 目前, 人们往往从技术层面上通过施加约束条件来达到局部智能, 而真正的群体智能问题, 本质上是研究群体系统基本要素所呈现的非线性关系在复杂系统规律性变化上所起的关键作用, 通过揭示群体行为全局演化的固有规律, 使得群体行为的演化更加协

同、高效、可信和实时智能。

#### 4 群体熵的基本性质

大规模复杂群体在相互作用机制基础上进行演化的过程,本质上就是在产生智能的博弈基础上不断优化个体行为对应于实现整体目标的序关系。也就是说,群体智能的涌现过程是一个由无序到有序、由有序到优序的复杂演化过程。熵作为热力学中描述系统组成个体有序程度的度量单位,能够很好衡量系统中大量个体在统计学意义上的序水平,即群体智能行为激发汇聚水平。

因此,面向大规模复杂群体智能系统的群体熵可以定义为描述群体智能行为演化涌现模式的类熵度量,用于度量和分析群体智能激发汇聚过程中统计意义上的有序优化程度。群体熵是系统结构演化熵与个体相互作用信息熵的复合函数,内层熵度量函数表示群体中个体序优化过程中微观状态有序性的概率测度,外层熵度量函数表示群体智能行为在宏观层面涌现过程中系统结构复杂性演化动力学的统计度量。

动力学模型主要面向随时间演化的系统行为,群体智能系统随时间演化的行为可以自然地使用动力学模型描述,而且群体智能系统的智能行为涌现是一种典型的动力学演化行为,因此比较契合动力学模型的研究特点。研究动力学系统的结论如演化行为测度、系统相变和稳定性分析等结论都可以很好地描述群体智能系统的动力学行为度量,特别是实现对系统体现智能水平的状态演化有着很好的适用性。群体智能行为是由大量个体相互作用过程中复杂群体行为的某种涌现形式,因此复杂性度量是群体智能行为水平和涌现模式的重要度量指标。结构熵是系统总体演化行为复杂程度的总体度量,其涵盖了系统的整体行为属性。而信息熵是衡量个体演化行为状态的子度量,如果信息熵描述的是自洽封闭系统的行为则计算入内层熵,如果信息熵描述的是开放系统的行为则与外界的交互行为计算入外层熵。实际上熵是衡量系统复杂程度的度量指标,由于群体智能系统既有整体系统结构演化(结构熵),又有个体交互行为(信息熵),因此形成了两个层次的综合熵度量体系。群体熵具有两方面的性质。

一方面,内层熵函数的自变量是微观个体间的相互作用状态统计值,即通过计算微观个体及其关联的交互信息熵实现统计学意义下大规模复杂群体智能涌现过程中瞬态特征的序优化程度。复杂群体系统中个体间的互信息熵用于衡量任意个体之间的耦合程度,其熵值大小衡量了群体智能涌现过程中个体之间的耦合协作行为有序程度。互信息熵的计算原理是衡量在序优化过程中个体之间交互耦合程度和条件不确定性的基础上,通过统计指标度量基于群体协作行为模式的个体竞争合作行为演化复杂度。当系统的全局状态未知而局部状态已知时,可以用部分交互信息熵替代交互信息熵。

另一方面,外层熵函数的自变量是内层熵函数和系统结构演化复杂性,即通过计算不同序优化水平状态概率序列的拓扑结构熵度量大规模群体中群体智能行为的结构复杂性差异和智能涌现水平。复杂群体系统的拓扑结构熵用于衡量系统整体有序作用结构在演化过程中的结构复杂性变化规律,其熵值大小衡量了群体智能行为在时间尺度上的演化波动性。带有时间参量的拓扑结构熵的计算原理是在衡量系统内部个体序优化关联结构的基础上,通过系统演化特征谱指标度量系统作为整体的智能涌现复杂度。

综上所述,当群体熵值不断增加时,大规模群体对象中组分个体在微观尺度条件下处于普遍潜力激发和交互耦合状态;当群体熵值不断减小时,大规模群体整体的系统向着低能量状态的优序结构演进;当群体熵值不断波动时,系统处于智能涌现博弈并会反复产生群体智能的激发汇聚循环。

群体熵可以表示为瞬态熵函数与过程熵函数复合的形式,在不同的群体智能系统中函数的形式可以根据实际情况调整。例如对于有明确个体和群体行为关系的大规模群体智能行为,群体熵可以写成

$E = F \circ G(\ln[\Omega])$ , 其中  $F \circ G$  表示反映个体构型瞬态熵的演化函数  $G$  与反映系统整体协同关联水平过程熵的演化函数  $F$  形成的复合运算,  $\ln[\Omega]$  表示对于某时刻大规模群体行为中个体的统计学意义熵.

## 5 群体智能的度量: 以图搜索为例

我们通过一个在复杂图结构上的搜索任务场景诠释群体熵在度量群体智能行为激发和汇聚过程中的变化过程. 此场景设定的任务为个体 (agent) 在给定图结构上通过游走策略发现未知节点, 若所有未知节点都被发现, 则任务完成. 个体在执行任务的过程中会得到奖励 (reward), 奖励与个体发现的新未知节点数和游走的总步数有关. 初始时只有单个体在执行任务, 但随着奖励数值的增加, 会激发 (incent) 新的个体加入任务, 之后随着任务难度增加 (可供新发现的节点数量减少), 个体间开始共享信息以便更高效地完成任务获得更多奖励, 呈现智能汇聚 (converge) 的模式.

考虑一个无向图结构  $G(N, E)$ ,  $N$  为节点总数量,  $E$  为边集合. 个体的搜索策略设定为离散时间随机游走模式 (random walk), 即某个体  $i$  在某时刻  $t = 0, 1, 2, 3, \dots$ , 从当前节点  $a$  转移到下一个节点  $b$  的概率:

$$P_{ab}(t) = A_{ab}/K_a,$$

这里  $A_{ab}$  是与节点  $a$  与  $b$  对应的图邻接矩阵  $A$  的相应元素,  $K_a$  是个体位于节点  $a$  上时可选择的邻居节点的数目. 在个体的行为汇聚之前, 所有个体的游走策略均设定为一般性无记忆随机游走 (global random walk, GRW), 即  $K_a = k_a$ ,  $k_a = \sum_b A_{ab}$  为节点  $a$  的度. 个体以等概率的方式随机选取一个邻居节点进行下一步搜索,  $P_{ab}(t)$  给出了个体在时刻  $t$  不确定搜索行为的概率度量. 参考经典信息论中对信息熵的定义, 可以首先对此行为的不确定性进行度量, 即个体选择任意一个邻居节点的行为是相互独立的, 无论选择哪个邻居节点, 都对应一种行为的不确定性, 用  $-\ln P_{ab}$  刻画, 为了考虑这个个体所有可能行为的平均不确定性, 取单个行为的统计平均值作为行为熵的定义. 即若个体  $i$  在时刻  $t$  位于节点  $a$ , 则此时刻个体  $i$  的智能搜索行为熵  $h_i(t)$  可定义如下:

$$h_i(t) = - \sum_b P_{ab} \ln P_{ab}. \quad (1)$$

记  $S^i(t)$  为个体  $i$  在时刻  $t$  已完成的搜索步数,  $\text{New}^i(t)$  为个体  $i$  在时刻  $t$  已发现的节点总数, 显然对任何  $t$ , 均有  $\text{New}^i(t) \leq S^i(t)$  成立. 图 2 阐释了单个个体在执行某次搜索任务时的任务完成情况与搜索的行为熵随时间的变化关系, 可以看到, 随着时间的推移, 个体发现新节点的速率在逐渐降低. 由于个体在随机图上做随机搜索, 根据行为熵的定义, 此时每一步的行为熵等于节点度的自然对数, 因此行为熵保持在一定范围内波动, 服从泊松分布.

为了引入群体智能的激发机制, 我们设计个体  $i$  在搜索过程中会得到奖励, 简单来说, 由于搜索任务的目的是为了找到更多新的节点, 这里新的节点的含义是此节点之前从未被其他任何个体探索到过. 因此, 个体  $i$  截至时刻  $t$  发现的新节点总数  $\text{New}^i(t)$  是度量个体  $i$  搜索行为的收入函数. 但是, 由于个体在搜索过程中不可能每次都能发现新节点, 如果碰到已经被搜索过的节点, 则此次搜索无收入, 但是由于任何一次搜索都消耗了时间, 这都被认为是消耗了成本, 所以可以定义个体  $i$  在  $t$  时刻执行的总步数  $S^i(t)$  为成本函数. 根据经济学原理, 可以定义搜索的奖励 (收益函数) 为收入  $\text{New}^i(t)$  和成本  $S^i(t)$  的差值. 为了计量的合理性, 可以引入权重因子对收入和成本进行加权, 得到的奖励函数 (reward function) 如下:

$$\text{Reward}^i(t) = \alpha \text{New}^i(t) - \beta S^i(t), \quad (2)$$






图 2 (网络版彩图) 单个个体执行某次随机搜索时新发现节点数与行为熵变化情况图. 图模型为 E-R 随机图模型<sup>[24]</sup>, 节点数  $N = 5000$ , 连边概率  $p = 0.3$ , 搜索总次数  $T = 2 \times 10^4$

**Figure 2** (Color online) Searching behavior and corresponding entropy of a single agent. The network structure is generated by the classic Erdős-Rényi model<sup>[24]</sup> (E-R model). The number of nodes  $N$  is set to be 5000 and the averaged connection probability of each edge  $p$  is set to be 0.3. The total searching steps  $T = 2 \times 10^4$

其中  $\alpha$  为激励因子, 体现对个体发现新节点的奖励因素, 而  $\beta$  为惩罚因子, 体现在搜索过程中由于重复探索导致的成本消耗. 当总的奖励数额超过一定数量时, 就会吸引新的个体加入搜索任务, 从而使奖励总数进一步增长, 进而吸引更多的个体加入, 形成简单的步进激励机制. 具体的, 我们设计如下群体智能激发模式: 设当前时刻  $t$  的奖励总数  $\text{REW}(t) = \sum_{i \in I(t)} \text{Reward}^i(t)$ ,  $I(t)$  为  $t$  时刻正在执行任务的个体集合. 设定奖励阶段阈值序列  $T_1, T_2, \dots, T_M$ ,  $\text{REW}(t)$  在增长过程中每超过一个阈值  $T_j, j = 1, 2, \dots, M$ , 则会有一个新的智能个体加入任务, 至多会有  $M$  个个体加入到群体搜索任务中. 当任务进行到一定程度后, 个体们探索到新节点的几率减少, 为了更有效地获取奖励, 个体间会共享已搜索区域的信息, 从而减少盲目的随机搜索, 这对应了群体智能行为的汇聚. 基于此, 我们设计当  $t$  时刻已经探索出的节点集合  $\text{Total}(t)$  数量大于  $N/2$  时, 个体搜索策略从开始的一般性无记忆随机搜索转换为共享信息后的有偏搜索. 即, 共享信息后, 个体下一步等概率地向从未被探索的邻居节点搜索, 而不考虑已探索过的邻居节点, 但若所有邻居节点都被探索过, 则仍进行随机探索, 直到所有节点均被探测到, 任务结束. 基于以上的规则, 我们考察整个系统中所有个体智能行为的群体熵随时间变化的情况:

$$\text{Entropy}(t) = \sum_{i \in I(t)} h_i(t). \quad (3)$$

图 3 阐释了多个个体在激发和汇聚的机制下任务完成情况和搜索行为的群体熵变化情况. 如图所示, 在系统的奖励总数达到设定的阈值后, 会有新的个体加入搜索任务, 进而加快任务的完成. 与此同时, 奖励总数进一步增加, 激发更多个体加入. 图中共展示了 4 次激发过程, 导致总共有 5 个个体进行了群体搜索行为. 在激发过程中, 随个体数增多, 对应的搜索行为熵也在不断增加, 之后, 个体进行了一段时间的随机搜索, 这段时间新发现的节点数仍在不断增加, 但行为熵保持稳定, 直到搜索任务过半 (新发现节点数大于  $N/2$ ), 个体之间开始交换信息, 搜索开始避免访问已搜索过的节点. 此过程, 各个

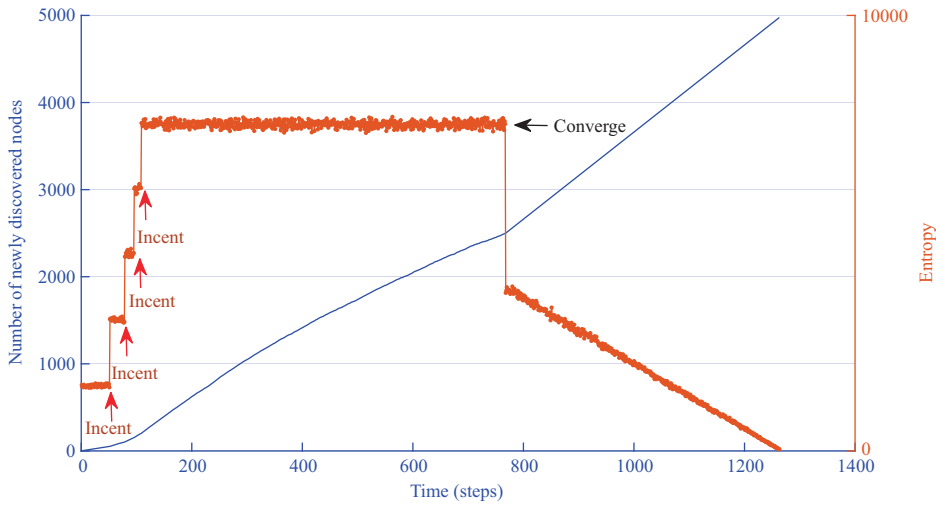


图 3 (网络版彩图) 多个体执行某次搜索任务时群智激发与汇聚过程中新发现节点数与群体熵变化情况图. 图模型为 E-R 随机图模型, 节点数  $N = 5000$ , 连边概率  $p = 0.3$ , 搜索  $T = 1264$  次数后任务完成. 奖励阶段阈值序列  $T_1 = 0.05 \times N, T_2 = 0.1 \times N, T_3 = 0.15 \times N, T_4 = 0.2 \times N$

**Figure 3** (Color online) Searching behavior and corresponding entropy of multi-agent during the incentive and convergence process of the crowd intelligence. The network structure is generated by the classic E-R model. The number of nodes  $N$  is set to be 5000 and the averaged connection probability of each edge  $p$  is set to be 0.3. The searching task is completed after  $T = 1264$  steps. The four corresponding reward values are  $T_1 = 0.05 \times N, T_2 = 0.1 \times N, T_3 = 0.15 \times N, T_4 = 0.2 \times N$ , respectively

体的搜索行为开始变得更加确定有序, 一方面促使了搜索效率的提升, 另一方面体现为搜索行为熵的减少, 对应了群智的汇聚阶段.

本文选择图搜索这一案例的目的在于其问题定义明确简单, 能够直观地反映群体熵在激发汇聚过程中的变化, 更加有利于理解本文所提出的群体熵度量概念. 实际上在无人集群协同控制、开源软件开发等群体智能激发汇聚的典型场景中, 群体熵度量也可以发挥衡量群体智能行为演化的作用.

在无人机集群系统的协同控制场景下, 其核心目的是确保无人机集群能够迅速并准确地形成作战编队, 同时还需要使得集群的行为保持一定的复杂性和随机性以应对环境的不确定性和敌方的攻击. 从无人机集群系统的本质特征来看, 它可以视为一种非线性复杂动力系统. 因此, 无人机集群系统协同控制中具备使用群体熵度量的基础. 无人机集群的协同控制涌现群体智能的前提是集群中个体的行为能够保持一定的复杂性和随机性, 这对应于群体智能系统的激发过程, 而复杂的程度则可以通过群体熵进行度量, 用来衡量集群行为是否容易被敌方预测, 是否具备群智涌现的基础. 这也将支持我们探索不确定环境下多模态智能协同控制与群体智能演化. 类似的, 无人集群系统的编队形成对应于群体智能系统的汇聚过程, 要实现大规模集群系统的自适应分群与变拓扑控制和事件驱动激励和反应式威胁规避控制等, 也可以采用基于群体熵的汇聚效能度量指标来度量协同控制效果.

在无人机群体智能行为模式中, 无人机个体对应自然界具有一定基本智能的个体, 通过个体之间的信息交互传递实现群体智能的涌现. 而这样的群智行为涌现可以分为两个层次进行复杂程度的度量: 第 1 个层次通过交互信息熵度量个体状态序列之间的耦合程度表征内在圈层的个体智能激发交互程度; 第 2 个层次通过整体系统结构熵的变化过程度量智能涌现的不同模态. 由于熵度量计算中系统行为序参数对演化行为的贡献程度不同, 可以通过调节相应的序参数使得对应的群体智能激发汇聚行为更加有序可控.

## 6 结论

本文分析了群体智能系统的基本性质,并在此基础上将群体智能的涌现过程刻画为激发和汇聚交替精化迭代.在此基础上,本文提出了群体智能系统的动力学模型和群体熵概念,并提出了利用群体熵来对群体智能系统的动力学特征进行刻画的方法.随后,本文对群体熵所应满足的基本性质进行了分析.最后,本文以图的群体化搜索为例,通过实验模拟了群体熵在激发和汇聚过程中的变化情况,验证了群体熵作为激发和汇聚这两类群体智能系统动力学特征的度量的有效性.

未来我们将进一步把群体熵的概念应用于无人集群、群体软件开发等更为复杂的群体活动中,验证群体熵作为这些复杂群体智能行为的度量的有效性.在此基础上,我们将进一步探索群体熵的统一数学模型和理论,建立一般化的群体智能行为群体熵度量理论.

## 参考文献

- 1 Beni G, Wang J. Swarm intelligence in cellular robotic systems. In: *Robots and Biological Systems: Towards a New Bionics*. Berlin: Springer, 1989. 703–712
- 2 Malone T W, Bernstein M S. *Handbook of Collective Intelligence*. Cambridge: The MIT Press, 2015
- 3 Li W, Wu W-J, Wang H-M, et al. Crowd intelligence in AI 2.0 era. *Front Inf Technol Electron Eng*, 2017, 18: 15–43
- 4 Reynolds C W. Flocks, herds and schools: a distributed behavioral model. In: *Proceedings of the 14th Annual Conference on Computer Graphics and Interactive Techniques*, 1987. 25–34
- 5 Vicsek T, Czirók A, Ben-Jacob E, et al. Novel type of phase transition in a system of self-driven particles. *Phys Rev Lett*, 1995, 75: 1226–1229
- 6 Bishop J M. Stochastic searching networks. In: *Proceedings of the 1st IEEE International Conference on Artificial Neural Networks*, London, 1989. 329–331
- 7 Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Trans Evol Computat*, 2002, 6: 182–197
- 8 Dorigo M, Blum C. Ant colony optimization theory: a survey. *Theor Comput Sci*, 2005, 344: 243–278
- 9 Watkins C J C H. Learning from delayed rewards. Dissertation for Ph.D. Degree. Cambridge: University of Cambridge, 1989
- 10 Foerster J, Assael Y M, de Freitas N, et al. Learning to communicate with deep multi-agent reinforcement learning. In: *Proceedings of the 30th International Conference on Neural Information Processing Systems*, 2016. 2145–2153
- 11 Hernandez-Leal P, Kartal B, Taylor M E. A survey and critique of multiagent deep reinforcement learning. *Auton Agent Multi-Agent Syst*, 2019, 33: 750–797
- 12 Jadbabaie A, Lin J, Morse A S. Coordination of groups of mobile autonomous agents using nearest neighbor rules. *IEEE Trans Automat Contr*, 2003, 48: 988–1001
- 13 Minor B D, Doppa J R, Cook D J. Learning activity predictors from sensor data: algorithms, evaluation, and applications. *IEEE Trans Knowl Data Eng*, 2017, 29: 2744–2757
- 14 Lazer D, Kennedy R, King G, et al. The parable of Google flu: traps in big data analysis. *Science*, 2014, 343: 1203–1205
- 15 Michelucci P, Dickinson J L. The power of crowds. *Science*, 2016, 351: 32–33
- 16 Li W, Huhns M N, Tsai W-T, et al. *Crowdsourcing: Cloud-Based Software Development*. Berlin: Springer, 2015
- 17 Wang H M, Yin G, Xie B, et al. Research on network-based large-scale collaborative development and evolution of trustworthy software. *Sci Sin Inform*, 2014, 44: 1–19
- 18 Zheng Z M, Ma S L, Li W, et al. Complexity of software trustworthiness and its dynamical statistical analysis methods. *Sci China Ser F-Inf Sci*, 2009, 52: 1651–1657
- 19 Zheng Z M, Ma S L, Li W, et al. Dynamical characteristics of software trustworthiness and their evolutionary complexity. *Sci China Ser F-Inf Sci*, 2009, 52: 1328–1334
- 20 Kauffman S A. *The Origins of Order: Self-organization and Selection in Evolution*. Oxford: Oxford University Press, 1993

- 21 Zhao J, Zhou Y W, Zhang X J, et al. Part mutual information for quantifying direct associations in networks. *Proc Natl Acad Sci USA*, 2016, 113: 5130–5135
- 22 Casert C. Emergent collective motion from local interactions. Dissertation for Ph.D. Degree. Ghent: Ghent University, 2017
- 23 Franceschini V, Giberti C, Zheng Z M. Characterization of the Lorentz attractor by unstable periodic orbits. *Nonlinearity*, 1993, 6: 251–258
- 24 Erdős P, Rényi A. On the evolution of random graphs. *Publ Math Inst Hung Acad Sci*, 1960, 5: 17–60

## Dynamic model and crowd entropy measurement of crowd intelligence system

Jie LUO<sup>1\*</sup>, Xin JIANG<sup>2,3,5</sup>, Binghui GUO<sup>2,3</sup>, Hongwei ZHENG<sup>4</sup>, Wenjun WU<sup>1</sup> & Weifeng LV<sup>1</sup>

1. *State Key Laboratory of Software Development Environment, School of Computer Science and Engineering, Beihang University, Beijing 100191, China;*
2. *State Key Laboratory of Software Development Environment, Beijing Advanced Innovation Center for Big Data and Brain Computing, School of Mathematics, Beihang University, Beijing 100191, China;*
3. *Peng Cheng Laboratory, Shenzhen 518055, China;*
4. *Institute of Artificial Intelligence, Guangzhou University, Guangzhou 510006, China;*
5. *Zhengzhou Artificial Intelligence Research Institute of Airport Economic Zone, Zhengzhou 451162, China*

\* Corresponding author. E-mail: luojie@nlsde.buaa.edu.cn

**Abstract** The phenomenon of crowd intelligence widely existing in nature has attracted extensive attention from researchers worldwide. Along with the fast development of network and artificial intelligence techniques, it enables that the crowd intelligence can be formed by stimulating the intelligence of individuals and converging the intelligence of the crowd. As a result, how to recognize and construct such a crowd intelligence system becomes a hot topic. This paper explores the theory and method for measuring crowd intelligent systems, so as to enrich the understanding of forming mechanisms for crowd intelligence systems. We propose the basic properties of the crowd intelligence system and the incentive-convergence model for its forming. Actually, the crowd intelligence system is considered to be a complex nonlinear dynamic system, which includes three core dynamic attributes: micro individual excitation, macro group collaboration, and global group intelligence convergence. Based on this model, we demonstrate the basic properties of crowd entropy which is a measurement for the crowd intelligence system. Finally, we perform a case study on crowd-based graph search and demonstrate the incentive and convergence processes of the crowd. During these two processes, the crowd entropy effectively reflects the change of crowd intelligence behaviors, which verifies the effectiveness of crowd entropy as the metric for crowd intelligence behaviors.

**Keywords** crowd intelligence system, dynamic model, crowd entropy, measurement, incentive, convergence