

面向复杂系统理解与管控的认知仿真方法

陶九阳^{1,2}, 吴琳¹, 胡晓峰¹, 贺筱媛¹

1. 国防大学联合作战学院, 北京 100091

2. 陆军工程大学指挥控制工程学院, 南京 210007

摘要 概述了复杂性科学的兴起与发展历程, 论述了复杂系统的主要研究方法, 以及复杂系统难以理解和管控的根源; 分析了认知智能的突破性进展与关键技术; 提出了面向复杂系统理解和管控的认知仿真方法, 以及认知仿真的基本理念; 指出了目前认知仿真研究中存在的问题和不足。

关键词 认知仿真; 深度强化学习; 复杂系统; 复杂性; 认知智能

1 复杂性科学的兴起与发展

自1928年奥地利生物学家Bertalanffy首次提出“复杂性”的概念, 复杂性科学的研究之路已经走了90年。近1个世纪的发展过程中, 复杂性科学研究融合了物理系统^[1-2]、生态系统^[3-5]、社会系统^[6-7]、经济系统^[8-9]、军事系统^[10-11]等众多领域, 成为理论研究与技术应用的前沿。著名物理学家霍金说: “21世纪是复杂性的世纪。”复杂性科学通常被认为是研究复杂系统的科学, 目前尚未形成统一的定义。复杂系统是相对于简单系统而言的, 但复杂系统不能像简单系统那样通过分解后再还原的方式来加以描述和研究, 即复杂系统是1加1不等于2的系统。

初期对复杂性科学研究主要集中于生命系统和物理系统。该时期涌现出大量的理论成果。Bertalanffy^[1]在研究生物有机体时运用协调性、目的性和有序性等概念, 提出了一般系统论, 用开放系统的概念来描述生

命体, 认为功能越强的系统复杂性越高。1969年, Prigogine^[12]建立了耗散结构理论, 引入熵的概念来解释系统从无序到有序的演化, 指出开放系统的有序结构需要消耗来自环境的负熵。耗散结构理论开创了宏观复杂系统自组织理论的先河, 然而无法解释系统微观层面的性质。1976年, Haken^[13]提出协同学, 对系统从无序到有序的演化规律进行了深入探讨, 将复杂系统的微观运动与宏观行为联系起来。1972年, 法国数学家Thom^[14]创立了突变论, 以纯数学的形式研究了复杂系统的相变与临界现象, 指出追求高度优化的系统设计很可能带来许多不理想的性质, 如适应性降低而导致“灾变”。

复杂性真正进入大众的视野源于洛伦兹发现的蝴蝶效应(图1)。洛伦兹在研究长期天气预报理论时发现, 即使只有3个变量的一阶微分方程组, 其描述的运动最终也会是一个不确定的、不规则的和不可预测的演化, 演化结果是形如蝴蝶翅膀的洛伦兹吸引子^[15]。蝴

收稿日期: 2018-04-03; 修回日期: 2018-05-11

基金项目: 军民共用重大研究计划联合基金项目(U1435218); 国家自然科学基金项目(61403400, 61403401)

作者简介: 陶九阳, 博士研究生, 研究方向为战争模拟、复杂系统、军事运筹与智能决策, 电子信箱: taojiuyang@126.com

引用格式: 陶九阳, 吴琳, 胡晓峰, 等. 面向复杂系统理解与管控的认知仿真方法[J]. 科技导报, 2018, 36(12): 55-65; doi: 10.3981/j.issn.1000-7857.2018.12.008

蝶效应是一种混沌现象,表现为确定性的系统经过长时间演化会产生随机的结果^[16]。之后很多科学家研究发现混沌普遍存在于复杂系统中,混沌理论从此成为复杂性科学研究的重要方向。




图1 洛伦兹吸引子:蝴蝶效应的理论基础

Fig. 1 Lorenz attractor: The theoretical basis of the butterfly effect

复杂性科学的初期研究,主要是对一系列生物和物理现象规律的总结,并进行理论模型的构建。Neumann^[17]认为真正的复杂系统应该能够再现现有生命系统的基本特征:自我繁衍和进化,随后提出了一种名为“元胞自动机”数学模型。元胞自动机的研究成为复杂系统仿真建模领域的热点得益于现代计算机的快速发展,Wolfram^[18]设计了一种二维网格上的生命游戏来仿真自动繁衍的规则,经过大量仿真实验总结出具有生命特征的元胞自动机演化的复杂特征,包括稳定态、周期态、混沌态和复杂态的4类演化^[19](图2)。元胞自动机的研究发现,即使在极为简单的规则下,系统的演化行为可以变得非常复杂,即简单规则可以导致复杂行为。




图2 无序初始状态下元胞自动机的演化

Fig. 2 Evolution of various cellular automata from disordered initial states

20世纪80年代中期,美国圣菲研究所(Santa Fe Institute, SFI)的成立,标志着复杂性科学领域的真正形成^[20]。Kauffman^[21]对复杂科学领域研究宗旨的描述为:探索兼具简单性和复杂性、规律性和与随机性、有序与无序的混合性事件。圣菲研究所的主要研究对象是复杂自适应系统(图3)^[22],其核心成员Holland^[23]提出了“适应性造就复杂性”的著名论断,将大量与人或智能相关的系统纳入到复杂性科学的研究范畴,如生态系统、经济系统、社会系统、军事系统等^[24]。为了建立可解释的复杂自适应系统理论,Holland等^[25-26]提出了“混沌边缘”的概念(图4),指出“复杂适应系统的最佳运行状态是介于有序和无序之间的一个中间状态”^[27-28]。圣菲研究所的研究人员建立了大量的计算机模型来仿真分析复杂适应性系统的自组织、自适应、自同步、混沌、演化等一系列问题。至今,复杂自适应系统仍然是复杂性科学最具活力的一个研究方向。

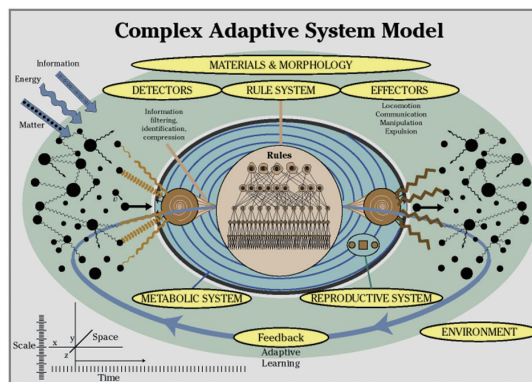


图3 复杂自适应系统模型

Fig. 3 Complex adaptive system model




图4 混沌的边缘:有序和无序的平衡

Fig. 4 Edge of chaos: The right balance between order and disorder

1998年,美国物理学家 Watts 和 Strogatz 提出了“小世界网络”模型^[29],该模型是一种介于规则网络和随机网络之间的网络结构,网络中大量的节点彼此并不相连,但绝大部分节点之间经过少数几步就可以到达。现实中的人际关系网络、生态网络等都是小世界网络。随后,Barabasi 与其博士生 Albert 于 1999 年提出了无标度网络模型^[30],发现了随机网络中标度的涌现,即网络的度分布近似或精确的遵循幂律。现实中因特网、演员的合作网络、蛋白质交互网络等都是无标度网络。无标度网络模型的生成机制类似于马太效应,即“好的愈好,坏的愈坏;多的更多,少的更少”的正反馈机制。小世界网络和无标度网络模型的提出,为复杂性科学的研究提供了新的工具,大量研究将系统抽象为复杂网络,通过研究网络结构、动力学、同步、演化等特性来理解和管理控制复杂系统。图 5 为人类肝脏的蛋白质之间的交互网络,是一种典型的无标度网络^[31]。




图5 人类肝脏的蛋白质交互网络

Fig. 5 Protein interaction network of the human liver

中国在复杂性科学的研究中也做出了贡献。20世纪80年代末,钱学森总结“两弹一星”等复杂系统工程经验,提出了开放的复杂巨系统概念和理论方法^[32]。20世纪90年代初,钱学森、于景元、戴汝为等^[33]在开放复杂巨系统的概念基础上,提出了定性与定量相结合的综合集成法,随后又发展为从定性到定量的综合集成法,并最终在1992提出人机结合、从定性到定量的综合集成体系。此外,王飞跃、戴汝为、张嗣瀛、陈国良等^[34]提出了人工系统、计算实验、平行系统等复杂系统的新方法和理论。

2 复杂系统难以理解和管控的根源

复杂系统普遍存在于人类生活的自然环境和经济

社会环境中,迫切需要深入理解和预测复杂系统的行为和演化方向,发展相关理论与技术方法,更好的管控复杂系统。然而,迄今为止对复杂系统深入理解和有效管控依然没有非常有效的方法,这是由于复杂系统具有不确定性、适应性、涌现性、预决性、演化性、开放性等诸多区别于简单系统的特性^[35-36],使现有的理论和方法无法奏效。

2.1 不确定性

复杂系统中的不确定性通常由两部分组成:一部分是复杂系统状态的不确定性,即某一个瞬间的状态“看不清”;另一部分是复杂系统的发展趋势的不确定性,即长远趋势的“看不准”^[37]。复杂系统的不确定性来源非常广泛^[38]。一部分来源于外在随机性,即由于外界的干扰对系统动力学特性造成的影响呈现出的随机特性。外在随机性是由于外在的随机项加载到复杂动态系统上引起系统的随机不规则运动,这种不确定性可以通过降低外在随机性来降低,例如战争系统中通过增加侦察力度获取外界环境更为精确的信息,经济系统中通过市场调查降低市场环境的不确定性。另一部分不确定性来源于内在随机性,即复杂系统。即使结构和初始条件都是确定的,自身也会产生随机性波动。内在随机性是混沌现象产生的主要原因,是确定性非线性系统固有的特征,也无法从根本上消除的不确定性。例如前面提到的“蝴蝶效应”、长时天气预报、股市预测和战争发展局势预测都存在这类不确定性。

由于不确定性的存在,使得人们对复杂系统的理解和认知蒙上了一层“迷雾”,很难看清复杂系统内部到底发生了什么,也很难预测复杂系统的变化趋势。这导致了对复杂系统的管理和控制非常困难。尤其是内在不确定性导致的混沌,使系统对初始条件高度敏感,使复杂系统的管理和控制也面临巨大风险。

2.2 自适应性

自适应性指系统中的主体能够与环境以及其他主体进行交互作用,主体在这种持续不断的交互作用的过程中“学习”或者“积累经验”以适应环境。圣菲研究所把复杂系统称为具有自适应能力的演化系统,并称这类系统为复杂自适应系统(complex adaptive system, CAS)。虽然复杂性的产生机理多种多样,但适应性无疑是复杂性产生的重要机制。

1) 不确定性是复杂系统适应性的内因。

复杂系统中的自适应性本质是主体与环境之间主

动的、反复不断的交互作用。主体通过不断学习来调整自身状态适应环境,来获取自身最大的生存和延续能力。主体在环境中往往没有通晓全局的能力,其主要通过不断的试错和纠错来学习,学习对抗系统中存在的不确定性,增加预测的准确性,进而增强自身的生存能力。主体行为的这种不可预见性,使得复杂系统在动态变化中更加难以预测和管控。

2) 适应性是系统演化的不竭动力。

自适应使得复杂系统不断重新组织,从结构到功能不断变化。例如狼群在捕猎驼鹿过程中,可以根据地形和驼鹿的状态适应性调整队形结构来增加捕猎效率(图6)。狼群这种自适应调整的能力是经过千百年演化的结果。适应性带来的系统演化还具有共同演化的特性。共同演化产生了相互适应、相互依存的适应性主体,例如蜜蜂以花蜜为食、花朵靠蜜蜂传播花粉来繁殖。共同演化是任何复杂适应系统突变和自组织的强大力量,将导向混沌的边缘,混沌的边缘是系统涌现的摇篮。



图6 狼群捕猎驼鹿过程中的自适应

Fig. 6 Wolves' self-adaptation in the hunt for a moose

2.3 涌现性

涌现性是指系统中的个体遵循简单的规则,通过局部的相互作用构成一个整体时,一些新的属性或规律会突然在系统整体的层面出现^[39]。自然界中的“涌现”现象比比皆是,如水在0℃时会突然结冰,铁在一定的物理条件下会突然出现磁性,由细胞组成的人会突然出现思维和意识等高级特性。涌现性并不存在于单个要素当中,是复杂系统在低层次构成高层次时表现出来系统特性。

1) 涌现是复杂系统创造“新质”的源泉。

涌现性并没有破坏系统中个体的规则,但个体的

规则却没有办法解释系统整体表现出来的特性。复杂系统中将这种在高层次表现出来的特性理解为系统的整体大于部分之和。而大于的部分就被认为是涌现出来的“新质”。涌现创造“新质”的能力,加上系统不断适应性演化,是大千世界在差异中不断走向复杂的重要原因。图7中每条鱼都是按照几个简单的规则在移动,而鱼群却会从整体上涌现出鱼的形状^[40]。




图7 鱼群整体移动呈现的涌现现象

Fig. 7 Emergence of the overall movement of a school of fish

2) 复杂系统的涌现失控会产生有害“新质”。

涌现独特的“新质”创造能力,使其成为复杂系统最为神秘和令人着迷的一种特性。人类希望能够认识和利用涌现。圣菲研究所的Holland等通过总结大量的实验结果,证实了涌现在复杂系统中的普遍性,并且认为涌现是系统的适应性主体之间非线性相互作用的结果,但这些都建立在实验总结的基础上,涌现的机理无法证实,涌现就像幽灵一样飘荡在复杂系统的上空。实际复杂系统中很难找到合适的方法对涌现进行引导,使人们不断遭受有害涌现的困扰,如经济复杂系统中不时爆发的金融海啸和经济危机,就是有害“新质”涌现的例子。

2.4 方法与困境

人类为研究复杂系统发展了理论分析法、数值计算与模型分析法、模拟仿真法等技术和方法。

1) 理论分析法。

主要对复杂系统进行事前、事中和事后的分析。这类方法大多针对系统的前因后果进行推理式分析,是一种定性分析的方法,无法深入理解复杂系统内部到底发生了什么,因此也就难以建立完善的科学体系。

2) 数值计算与模型分析法。

是通过构建数学模型分析复杂系统。由此发展出了混沌动力学模型法^[41]、符号动力学方法^[42]、系统动力学方法^[43]、复杂适应系统方法^[44]、遗传算法^[45]、胞映射法^[46]等。然而,这类方法虽然从定量的角度阐释了复杂系统的共性规律,为人们认识复杂系统提供了技术手段,但其采用的大多是经过简化的模型和数学公式,很难建立与真实系统完全一致的模型。而复杂系统具有混沌特性和反馈特性,即使微小的差异也会带来巨大的失真。这也是为什么有那么多种理论方法可以分析复杂系统,但依然无法预测和阻止股灾的突然出现、经济危机的突然爆发、社会暴乱的突然出现等。事实证明,这些方法用于实际复杂系统的有效管控已经遇到了理论和技术天花板。

3) 模拟仿真法。

是用计算机对实际系统中的规则、数学模型进行仿真实验来分析复杂系统。由于可以控制仿真的速度、环境以及大规模仿真数据的产生,能够从微观到宏观更为细致的观察复杂系统如何适应环境、动态交互以及涌现新质。这无疑极大拓展了人类认识复杂系统的途径。仿真模拟的方法虽然能够更为高效和细致的研究和观察复杂系统,但大多数建模方法都依赖人类定义的规则,如圣菲研究所的技术方法也是通过“自底向上”的涌现法,即在底层建立简单规则,来观察这些简单规则导致的高层次的复杂涌现和其他行为。这类方法人为的割裂了复杂系统的整体性,降低了其本身存在的不确定性,因此,面对实际系统的理解和管控缺乏精确性和可靠性,没有人能够通过仿真模拟来对一场战争进行精确预测。关于复杂系统仿真建模的困惑和难点,国内领域专家曾举行过专门的学术沙龙进行深入讨论^[47]。

3 认知智能的突破催生复杂系统认知仿真新方法

3.1 认知智能的持续突破

人工智能从功能应用上可分为计算智能、感知智能和认知智能3个层次。计算智能解决“能存会算”的问题,重在快速计算和具备海量记忆存储能力;感知智能让机器“能听说、会读写”,重在视觉、听觉、触觉等感知能力,实现图像理解、语音识别、语言翻译、运动控制等为目的,被理解是人类能力的延伸;认知智能让机器

“能理解思考、会推理预测”,它以理解、推理和决策为发展目的,强调“会思考、能决策”等能力。

计算智能在很多方面已超越人类。近期深度学习的突破,使得感知智能也取得了重大进展,如科大讯飞公司的语音识别、北京旷世科技有限公司的人脸识别、谷歌公司的机器翻译等都已达到了商用水平。认知智能因其综合性更强,更接近人类智能,研究难度更大,长期以来一直进展缓慢,是目前最具有挑战性的一个领域。虽然在认知智能方面投入巨大,但多数项目并没有取得实质性突破,其主要的原因是计算机系统无法真正像人的大脑一样学习、思考,并做出正确的推理决策。如美国国防部高级研究计划局(Defense Advanced Research Projects Agency, DARPA)从2007年起开始支持一项名为“深绿”的项目^[48](图8),其核心部件为战场自动分析与决策的“水晶球”和“闪电战”,由于战场态势自动分析与指挥决策等认知智能技术一直无法取得突破,该项目2011年已经暂停。



图8 深绿系统的作战概念图

Fig. 8 Operational concept for Deep Green

2016年出现的AlphaGo,是认知智能突破的里程碑事件^[49]。AlphaGo在围棋上的能力已经远远超越人类,显然它已经具备自主学习、理解、推理和决策等认知智能的能力。由于博弈类游戏需要在对抗环境下进行思考和决策,因此成为认知智能发展的试金石。AlphaGo之后认知智能持续出现突破:AlphaGo Zero在围棋领域能够不依赖人类的经验数据仅仅通过自博弈训练而打败人类^[50];AlphaZero采用一个框架就可以从零开始训练出能够在围棋、将棋和国际象棋都超越人类的多任务智能体^[51],DeepStack^[52]、Libratus^[53]等能够在一对一不限德州扑克博弈中击败人类顶级玩家,空战智能飞

行员 Alpha AI 击败了美国空军战术专家李上校^[54]。

纵观近来认知智能的技术突破,深度强化学习无疑是最耀眼的明珠,虽然并不是唯一的技术,如 Libratus 和 Alpha AI 并没有使用深度强化学习。深度强化学习是深度学习与强化学习两种技术的复合,兼顾了两者的优点。深度学习的概念来源于人工神经网络。传统上人们构建的神经网络都只含有一个隐含层,原因在于含有多个隐含层的神经网络会遇到训练数据匮乏、计算能力不足以及梯度弥散等长期得不到解决的问题。随着计算能力的不断增强及大数据等蓬勃发展,2006 年多伦多大学的 Hinton^[55]提出了采用逐层预训练的方式对神经网络参数进行初始化设置,大大降低了深层神经网络的优化难度。并把这种含有一个以上隐含层的神经网络训练问题称为深度学习。此后短短 10 年,各种深度学习模型不断涌现并进入应用领域,如堆栈自编码器^[56-57]、限制性玻尔兹曼机^[58-60]、深度信念网络^[61]、深度卷积神经网络^[62]、循环神经网络^[63]、长短时记忆网络^[64-65]等。深度学习能够通过多层的非线性运算单元自动地从大量训练数据中学习抽象的特征表示,以发现数据中隐藏的规律和分布特征。

强化学习是一种从环境状态映射动作的学习,目标是使智能体在与环境的交互过程中获得最大的累积奖赏^[66]。深度学习高度依赖于训练数据的样本容量和标记精度。虽然人类在很多应用领域积累了很多带有经验的数据,通过这些数据的学习也能够获取人类的经验,如 AlphaGo 用的策略网络就是用了人类的 16 万盘数据训练的。然而,事实证明,单纯依赖获取人类的经验,并不足以让认知智能产生质的突破,只用人类经验训练的 AlphaGo 策略网络与人对弈依然无法击败人类。因此,还要让智能自己“生产”经验,强化学习就是一种经验数据生成器。强化学习使得智能体能够在动态环境中学习,学习的数据来源于智能体与环境交互过程中观察到的环境的回馈。这类似于一个小孩在成长过程中的学习,一部分是来自于大人经验的传授,而大部分还是源于自身的经历和试错。强化学习就是在不断的试错过程中增长经验,其经典算法是基于马尔科夫决策过程的 Q-learning^[67]。

深度强化学习结合了深度学习的经验获取能力和强化学习与环境动态交互能力,被 AlphaGo 的发明者 David Silver 称为是走向通用人工智能的必经之路。强化学习通过不断与环境的交互产生带有经验的数据,

由于采取的动作或行动不同,交互的结果也会不同,深度神经网络就会从这些不同的回馈数据中进行学习,就像一个直觉和经验知识的采集器,“取其精华去其糟粕”,从而能够实现不断优化。深度强化学习最早见于 DeepMind 发明的深度 Q 网络,应用于 Atari 2600 平台中的各类 2D 视频游戏中(图 9)^[68-69]。新的深度强化学习算法不断被提出,如基于策略梯度的强化学习^[70]、基于搜索与监督的深度强化学习^[71]、分层深度强化学习^[72]、多任务迁移深度强化学习^[73]、多智能体深度强化学习^[74]、基于记忆与推理的深度强化学习^[75]等。目前,深度强化学习技术甚至被用来探索不完美信息博弈的星际争霸游戏^[76],这被认为是最接近复杂战争系统的游戏。当然,该技术用于星际争霸游戏还存在很大困难,在星际争霸人机对战中表现平凡(图 10)。



图 9 DeepMind 用 DQN 玩雅达利游戏
Fig. 9 DeepMind plays Atari games with DQN



图 10 DQN 玩星际争霸游戏
Fig. 10 Play StarCraft games with DQN

总之,认知智能突破的标志技术是深度强化学习,关键是找到了人类经验直觉等非形式化知识的捕捉建模方法,解决了以往人工智能无法处理隐性知识的难题。

3.2 复杂系统认知仿真的基本理念

围棋博弈是复杂系统中的对抗演化博弈。传统任何一种技术都未能实现对这种复杂系统的有效管控。对人类的“棋感”这类隐性知识,无论是符号逻辑系统还是专家系统,都无法进行有效的建模和处理。Alpha-Go采用深度学习技术,利用策略网络和价值网络成功捕获了围棋的经验和直觉棋感。通过强化学习“左右互搏”,在没有人的干预下,成功实现了经验直觉等隐性知识的自发现,在复杂的围棋博弈系统中实现了类人甚至超人的决策能力。这无疑启发了一种全新的复杂系统深度理解和管控的方法,我们称之为复杂系统认知仿真法。

认知仿真的核心工作就是对复杂系统进行认知建模。复杂系统认知建模的概念可以概括为:通过捕捉与复杂系统交互过程中产生的经验、直觉、想象、灵感等非形式化知识,与形式化知识一起,构建能够反映复杂系统特征的模型,实现对复杂系统的深度理解和仿真,进而实现对复杂系统的演化预测和管理控制。认知建模的本质是构建认知智能体,让智能体自动学习和获取复杂系统深层次的规律。

虽然AlphaGo的技术路线启发了我们如何构建认知模型,但认知仿真并不仅仅是一种技术,而是一种解决复杂系统理解和管控问题的方法论。为了更好的指导认知仿真建模的技术应用,本文总结了复杂系统认知仿真建模的3大理念。

3.2.1 由结构相似性转变为规律相似性的建模理念

系统仿真的理论基础是相似性^[7]。仿真的基本原则就是通过对实际系统进行建模,使仿真模型与实际系统的结构和功能具有相似性,通过仿真就可以研究实际系统的各种规律和性质。例如,火星探测之前都要进行仿真实验,来找出可能存在的问题以降低风险。系统仿真的这种相似性通常是一种弱相似,实际应用中很难构建与实际系统完全一样的仿真系统。然而对于复杂系统的仿真,采用结构和功能的相似性就会带来困难。第一,复杂系统的整体性使得很难看清内部结构和各部分的交互关系,只能根据了解的结构和简单规则来进行建模,这样做就可能丢失其中一些未知的关键要素;第二,复杂系统对初值具有敏感性,一个微小的扰动都可能导致与预期完全不同的演化方向,这也带来系统涌现的难以预测和引导。

从仿真建模的角度看,认知仿真模型使用的深度神经网络是典型的复杂自适应系统,它通过调整权重

来不断适应输入数据的特征,在这种动态调整过程中涌现出了对高层概念的理解。神经网络与复杂系统这种天然的相似性,使其成为复杂系统合适的建模方法。用深度神经网络这一复杂自适应系统来仿真复杂系统,建立的是对复杂系统的行为规律的认知,因此相似性不再是结构的相似性,而是规律行为的相似性。

3.2.2 经验直觉和理性推理的融合建模理念

复杂系统所具有的适应性、不确定性和涌现性,使传统方法一再遇到瓶颈,根本原因是缺乏非形式化知识的有效建模手段。经验、直觉、记忆、灵感和想象等非形式化隐性知识,无法用形式化的规则、公式、定理加以描述。以深度强化学习为代表的隐性知识建模在最近的游戏智能中取得的巨大突破,让我们认识到复杂系统建模必须考虑经验、直觉、想象、记忆、遗忘等一系列的认知模式,必须对人类引以为傲的“只可意会不可言传”的隐性知识用模型的方式表达出来。深度神经网络在这类非形式化知识的建模和表达中越来越成功。以此为契机,可以给出一条模拟仿真复杂系统隐性规律的建模理论方法:第一步,将客观规律转化为认知规律建模;第二步,将认知规律转化为深度强化学习建模;第三步,将深度强化学习模型转化为可执行的智能系统建模。由此建立的认知模型承载的不再是死板的人类定义好的规则,而是经验、直觉等人类都可能不知道的知识。如AlphaGo通过不断学习进化后使用的招数人类都无法理解。认知模型最大的优势在于其对复杂系统的强大探索能力,经验、直觉和想象等非形式化知识没有探索和经历就无法建模捕获。

然而,在实际的复杂系统管控实践中发现:在有些场合下,用经验和直觉的建模方法管控复杂系统确实能够收到很好的效果,但有时候反而形式化的推理规划模型更好。这是因为数学、物理等形式化的知识是千百年来人类先驱们通过不断探索得到的,反映描述了很多客观的具有普适意义的规律,要让机器通过学习的方法来获取这些知识,不仅需要耗费大量时间,而且构建一个模拟真实世界的机器学习虚拟环境难度极高。因此,复杂系统的认知建模需要将规划推理等显性知识和经验直觉等隐性知识融合起来才更加完备。

3.2.3 认知与复杂性协同演化的建模理念

深度强化学习模型作为认知的主要承载体,本身就具有典型的复杂自适应系统特征。首先,深度神经网络具有整体性,整个网络都是由结构完全相同的神经元组成的,单独来看每个神经元都无法理解网络整

体涌现出来的分类、排序等功能;其次,深度神经网络具有不确定性,由于神经元之间存在大量的非线性关联关系,使得神经网络对初值的输入非常敏感,随着网络层数的加深,这种敏感性增加,逐渐表现为混沌;再次,认知模型具有自适应进化的能力,通过与环境的交互而“知冷暖”,通过不断犯错和纠错而“明是非”,从而实现自身的不断进化,增强对环境的适应能力。

由于认知仿真的目的是对复杂系统的行为、规律进行理解和预测,进而实现管理和控制。因此,认知模型通常需要与复杂系统建立某种互动来观察复杂系统的反应。与此同时,复杂系统本身也具有适应性,必然也会对认知模型的“试探”做出适应性的响应。随着认知模型进化而不断改变自身的行为,复杂系统也会进行跟随式的改变。这就是复杂系统中的反身性。例如股市系统,人的认知马上就会导致其巨大震荡。再比如指挥员,即使他对战场态势只是认知了还未行动,此时战场系统就已经改变了,因为后续的状态、终态都改变了。复杂系统反身性的一个副作用就是会导致认知和复杂的螺旋上升,即认知能力的提升会使得系统变得更复杂。专门研究蚂蚁习性的生物学家弗兰克斯就说,像蚂蚁这类集体智能的产生机制依然是个迷,对它们的复杂社会结构了解越多,其社会组织的谜团就越多。

认知是一种智能行为,可以把认知复杂性的关系拓展到智能和复杂性的关系,得到如下结论:系统的适应性造就了复杂性,复杂性产生了智能性,智能性在不断适应的过程中又推动系统向更加复杂的方向演化。复杂性和智能性就像双子星座一样,在不断的缠绕中协同演化。更进一步,复杂系统3个主要特性——不确定性、适应性和涌现性都可以统一到这个协同演化的程式中来。系统的适应性是复杂性和智能性之间的桥梁,智能性的本质是复杂性的涌现,而不确定性意味着演化的方向和结果是不定的(会出现混沌),也意味着智能性的出现有偶然的因素。不是所有的复杂都会涌现智能,但所有的智能都来源于复杂的涌现。

总之,认知的结果必然走向智能,而智能与复杂缠绕而生。不能因为认知模型导致系统更趋复杂而认为模型无效,而应该用协同演化的视角来看待复杂系统和认知模型之间的关系。

3.3 认知仿真方法依然存在的主要问题

虽然深度强化学习等认知仿真方法在管控复杂系

统中已经显露了巨大的潜力,但目前的理论和技术方法依然存在很多问题亟待解决。

1) 认知智能进化环境的模拟问题。

无论是AlphaGo还是德州扑克AI,其超越人类的关键是能够快速进化,而快速进化的基本条件是有有一个能够供其学习的虚拟环境,使其在很短的时间内探索广阔的策略空间。人类几千年下的棋,AlphaGo在短短几天内就超越了。探索的多了其发现和获取的规律必然就多。快速进化是认知智能超越人类的关键。然而很多环境本身的规则不像围棋或扑克等那样明确,构建这样一个虚拟的环境就会非常困难。

2) 目前认知模型普遍采用的深度学习依然是黑箱模型。

虽然利用深度学习已经能够让机器学会了交谈、开车,在游戏中击败人类冠军,甚至做梦、画画、创造诗词歌曲等,但目前并没有成熟的理论指导深度学习模型的构建,主要还是依赖于人的设计灵感和不厌其烦的调参。深度学习模型的内部到底发生了什么,系统内部的微小权重变化为什么会在宏观上出现完全不同的结果,这些问题本身就体现了复杂系统的不确定性和涌现性。深度学习模型的这种不可解释性对于某些复杂系统的理解和管控是不可接受的。例如,在战争复杂系统中,由于不知道认知模型到底怎么工作的,指挥员就不敢相信其对战局的预测,在出现与指挥员观点不同的决策时,指挥员也不敢使用机器推荐的方案。目前,虽然也发展了一些理论来解释深度学习的机理,如Tishby等提出的“信息瓶颈”理论^[78],但解释能力依然有限。目前对于深度学习的可解释性问题已经成为研究的热点。

3) 不完美与不完全信息问题。

像AlphaGo等棋类游戏都属于完美信息博弈,即博弈双方都能知道对方的每一个动作,对博弈的环境信息完全了解。而像战争复杂系统是典型的不完美且不完全信息博弈。信息的不完美体现在“战争迷雾”,看不清战场的态势,信息不完全主要体现在环境的回馈具有滞后性,例如发射了一枚导弹,对敌方的打击效果可能要很久才能反馈回来。深度强化学习需要依赖于环境状态作为输入,回馈值作为输出学习的依据,如果输入描述不准确,回馈值又无法实时获得,甚至不知道是哪个动作带来的回馈,基于深度强化学习的认知模型必然无法很好的工作。这也是为什么目前深度强化

学习在解决星际争霸等战争模拟游戏时表现很差的主要原因。

4 结论

复杂系统的深度理解和有效管控长期以来一直是复杂性科学研究的热点和难点。综述了复杂性科学的兴起过程,分析了复杂系统的不确定性、适应性和涌现性等带来的理解和管控困局。以人工智能近来取得的突破为基础,提出了认知仿真的方法,并阐述了认知仿真建模的3个基本理念,分析了目前认知仿真尚未解决的关键问题。认知仿真作为一种全新的复杂系统建模仿真方法,依然需要在未来的实践中不断发展和完善。后续的研究重点有2点:第一,认知仿真的理论基础,尤其是黑箱问题的可解释性问题研究;第二,认知仿真的应用案例研究,尤其是结合传统典型复杂系统研究行为的预测和涌现的引导,用来检验方法的可靠性。

参考文献 (References)

- [1] Kadomtsev B B. Tokamak plasma: A complex physical system [M]. London: Institute of Physics Pub, 1992.
- [2] Haken H. Information and self-organization: A macroscopic approach to complex systems[M]. New York: Springer Publishers, 2000.
- [3] Blasius B, Huppert A, Stone L. Complex dynamics and phase synchronization in spatially extended ecological systems[J]. Nature, 1999, 399(6734): 354-359.
- [4] Costanza R, Wainger L, Folke C, et al. Modeling complex ecological economic systems[J]. Bioscience, 1993, 43(8): 545-555.
- [5] Thrush S F, Schneider D C, Legendre P, et al. Scaling-up from experiments to complex ecological systems: Where to next?[J]. Journal of Experimental Marine Biology & Ecology, 1997, 216 (216): 243-254.
- [6] Cohen I R, Harel D. Explaining a complex living system: Dynamics, multi-scaling and emergence[J]. Journal of the Royal Society Interface, 2007, 4(13): 175-182.
- [7] Juarrero A. Dynamics in Action: Intentional behavior as a complex system[J]. Philosophical Review, 1999, 2(3): 24-57.
- [8] Diegues A C, Roselino J E. The Economy as an evolving complex system[J]. Oup Catalogue, 2005, 65(297): 796-800.
- [9] Buckley W. Society—A complex adaptive system: Essays in social theory[M]. London: Gordon and Breach Science Publishers, 1998.
- [10] 胡晓峰, 司光亚, 罗批, 等. 战争复杂系统与战争模拟研究[J]. 系统仿真学报, 2005, 17(11): 2769-2774.
- [11] Hu Xiaofeng, Si Guangya, Luo Pi, et al. Study on war complex system and war gaming and simulation[J]. Journal of System Simulation, 2005, 17(11): 2769-2774.
- [12] Prigogine I, Stengers I, Pagels H R. Order out of Chaos[J]. Physics Today, 1985, 38(1): 97-99
- [13] Haken H. Advanced synergetic[M]. New York: Springer-Verlag, 1983.
- [14] Thom R. Structural stability and morphogenesis[J]. Bulletin of Mathematical Biology, 1976, 8(1): 629-632.
- [15] Shenker S H, Stanford D. Black holes and the butterfly effect [J]. Journal of High Energy Physics, 2013, 2014(3): 1-25.
- [16] Karkuszewski Z P, Jarzynski C, Zurek W H. Quantum chaotic environments, the butterfly effect, and decoherence[J]. Physical Review Letters, 2002, 89(17): 170405.
- [17] Marchal P. John von Neumann: The founding father of artificial life[J]. Artificial Life, 1998, 4(3): 229-235.
- [18] Wolfram S, Mallinckrodt A J. Cellular automata and complexity[J]. Computers in Physics, 1995, 9(1): 55-62.
- [19] Wolfram S. Cellular automata as models of complexity[J]. Nature, 1984, 311(5985): 419-424.
- [20] Anderson P W. Complexity II: The Santa Fe Institute[J]. Physics Today, 1992, 45(6): 9-11.
- [21] Langton I C G, Taylor C, Farmer J D, et al. Santa Fe Institute studies in the sciences of complexity[M]. Oxford: Oxford University Press, 1992.
- [22] Holland J H. Complex adaptive systems[J]. Daedalus, 1992, 121(1):17-30.
- [23] Malina R F. Hidden Order: How adaptation builds complexity, by John H. Holland[J]. Artificial Life, 1996, 2(3): 333-335.
- [24] Lansing J S. Complex adaptive systems[J]. Annual Review of Anthropology, 2003, 32(4): 183-204.
- [25] Waldrop M M. Complexity: The emerging science at the edge of order and chaos[M]. New York: Simon & Schuster Publishers, 1992.
- [26] Waldrop M M, Lewin R. Complexity: The emerging science at the edge of order and chaos; Complexity: Life at the edge of chaos[J]. Science, 1992, 259(6): 387-388.
- [27] Gell-Mann M. The quark and the jaguar: Adventures in the simple and the complex[M]. San Francisco: W.H. Freeman Publishers, 1994.
- [28] Pauwelyn J. At the edge of chaos? Foreign investment law as a complex adaptive system, how it emerged and how it can be reformed[J]. Social Science Electronic Publishing, 2013, 29 (2): 372-418.
- [29] Watts D J, Strogatz S H. Collective dynamics of 'small-world' networks[J]. Nature, 1998, 393(6684): 440-442.

- [30] Barabasi A L, Albert R. Emergence of scaling in random networks[J]. *Science*, 1999, 286(5439): 509–512.
- [31] Wang J, Huo K, Ma L, et al. Toward an understanding of the protein interaction network of the human liver[J]. *Molecular Systems Biology*, 2011, 7(1): 536–536.
- [32] 钱学森. 一个科学新领域——开放的复杂巨系统及其方法论[J]. *上海理工大学学报*, 2011, 12(6): 526–532.
Qian Xuesen. A new field of science: The open complex giant system and its methodology[J]. *Journal of Shanghai polytechnic university*, 2011, 12(6): 526–532.
- [33] 于景元. 钱学森关于开放的复杂巨系统的研究[J]. *系统工程理论与实践*, 1992, 12(5): 8–12.
Yu Jingyuan. Qian Xuesen's research on the open complex giant system[J]. *Systems Engineering—Theory & Practice*, 1992, 12(5): 8–12.
- [34] 王飞跃, 戴汝为, 张嗣瀛, 等. 关于城市交通、物流、生态综合发展的复杂系统研究方法[J]. *复杂系统与复杂性科学*, 2004, 1(2): 60–69.
Wang Feiyue, Dai Ruwei, Zhang Siying, et al. A Complex system approach for studying sustainable and integrated development of metropolitan transportation, logistics and ecosystems [J]. *Complex Systems and Complexity Science*, 2004, 1(2): 60–69.
- [35] Kobayashi N, Kuninaka H, Wakita J I, et al. Statistical features of complex systems—Toward establishing sociological physics[J]. *Journal of the Physical Society of Japan*, 2011, 80(7): 785–791.
- [36] Bar-Yam Y. *General features of complex systems*[R]. Cambridge: Eolss Publishers, 2002.
- [37] McDaniel R R, Driebe D J. *Uncertainty and surprise in complex systems*[M]. Berlin: Springer Berlin Heidelberg Publishers, 2005.
- [38] Parry G W. The characterization of uncertainty in probabilistic risk assessments of complex systems[J]. *Reliability Engineering & System Safety*, 1996, 54(2): 119–126.
- [39] Holland J H. *Complex Adaptive Systems and Spontaneous Emergence*[C]//Curzio A Q, Fortis M. *Complexity and industrial clusters*. Physica-Verlag HD, 2002: 25–34.
- [40] Toroczkai Z. *Complexity: A guided tour*[J]. *Physics Today*, 2010, 63(2): 47–48.
- [41] Farmer J D. Chaotic attractors of an infinite-dimensional dynamical system[J]. *Physica D Nonlinear Phenomena*, 1982, 4(3): 366–393.
- [42] Kitchens B P. *Symbolic Dynamics*[M]. Berlin: Springer Berlin Heidelberg Publishers, 1998.
- [43] Sauer P W, Pai M A. *Power system dynamics and stability* [M]. New Jersey: Prentice Hall, 1998.
- [44] Lansing J S. *Complex adaptive systems*[J]. *Annual Review of Anthropology*, 2003, 32(4): 183–204.
- [45] Galletly J. *Evolutionary algorithms in theory and practice: Evolution strategies, evolutionary programming, genetic algorithm* [M]. Oxford: Oxford University Press, 1998.
- [46] Hsu C S. A theory of cell-to-cell mapping dynamical systems [J]. *Journal of Applied Mechanics*, 1980, 47(4): 931–939.
- [47] 中国科协学会学术部. *复杂系统建模仿真中的困惑和思考* [M]. 北京: 中国科学技术出版社, 2012.
Department of Societies and Academic, China Association for Science and Technology. *Bewilderment and thinking for complex system modeling and simulation*[M]. Beijing: China Science and Technology Press, 2012.
- [48] Surdu J R, Kittka K. *The Deep Green concept*[C]//Association for Computing Machinery. *Spring simulation multicongress*, Ottawa, 2008: 623–631.
- [49] Silver D, Huang A, Maddison C J, et al. Mastering the game of Go with deep neural networks and tree search[J]. *Nature*, 2016, 529(7587): 484–489.
- [50] Silver D, Schrittwieser J, Simonyan K, et al. Mastering the game of Go without human knowledge[J]. *Nature*, 2017, 550(7676): 354–359.
- [51] Silver D, Hubert T, Schrittwieser J, et al. Mastering chess and shogi by self-play with a general reinforcement learning algorithm[J]. arXiv: 1712.01815v1, 2017.
- [52] Moravčík M, Schmid M, Burch N, et al. Deep Stack: Expert-level artificial intelligence in heads-up no-limit poker[J]. *Science*, 2017, 356(6337): 508–513.
- [53] Brown N, Sandholm T. *The superhuman AI for No-Limit poker*[C]//IJCAI. *Twenty-sixth international joint conference on artificial intelligence*, Melbourne, 2017: 5226–5228.
- [54] Nicholas E, David C, Corey S, et al. Genetic fuzzy based artificial intelligence for unmanned combat aerial[J]. *Journal of Defense Management*, 2016, 6(1): 1–7.
- [55] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. *Neural Computation*, 2006, 18(7): 1527–1554.
- [56] Vincent P, Larochelle H, Bengio Y, et al. Extracting and composing robust features with denoising autoencoders[C]//Association for Computing Machinery. *International Conference on Machine Learning*, 2008: 1096–1103.
- [57] Vincent P, Larochelle H, Lajoie I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. *Journal of Machine Learning Research*, 2010, 11(6): 3371–3408.
- [58] Sutskever I, Hinton G, Taylor G. The recurrent temporal restricted boltzmann machine[C]//Association for Computing Machinery. *International Conference on Neural Information Processing Systems*. British Columbia, 2008: 1601–1608.
- [59] Hinton G E. A practical guide to training restricted boltzmann machines[J]. *Momentum*, 2012, 9(1): 599–619.
- [60] Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines[C]//Association for Computing Machinery. *International Conference on International Conference on Machine Learning*. Omnipress, 2010: 807–814.
- [61] Ranzato M A, Boureau Y L, Lecun Y. Sparse feature learning for deep belief networks[C]//Association for Computing Ma-

- chinery. International conference on neural information processing systems. British Columbia, 2007: 1185–1192.
- [62] Zeiler M D, Fergus R. Visualizing and understanding convolutional networks[C]//Springer. European conference on computer vision. Cham, 2014: 818–833.
- [63] Graves A, Mohamed A R, Hinton G. Speech recognition with deep recurrent neural networks[C]//IEEE. IEEE International conference on acoustics, speech and signal processing. 2013: 6645–6649.
- [64] Sundermeyer M, Schlüter R, Ney H. LSTM Neural Networks for Language Modeling[C]//Conference of the international speech communication association, Portland, 2012: 601–608.
- [65] Greff K, Srivastava R K, Koutnik J, et al. LSTM: A search space odyssey[J]. IEEE Transactions on Neural Networks & Learning Systems, 2017, 28(10): 2222–2232.
- [66] Sutton R S, Barto A G. Reinforcement Learning: An Introduction, Bradford Book[J]. IEEE Transactions on Neural Networks, 2005, 16(1): 285–286.
- [67] Watkins C J C H, Dayan P. Q-learning[C]//International conference on machine learning, Aberdeen, 1992: 279–292.
- [68] Mnih V, Kavukcuoglu K, Silver D, et al. Playing atari with deep reinforcement learning[J]. Computer Science. arXiv: 1312.5602v1, 2013.
- [69] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning[J]. Nature, 2015, 518 (7540): 529–533.
- [70] Williams R J. Simple statistical gradient-following algorithms for connectionist reinforcement learning[J]. Machine Learning, 1992, 8(3/4): 229–256.
- [71] Coulom R. Efficient selectivity and backup operators in monte-carlo tree search[J]. Lecture Notes in Computer Science, 2006, 4630: 72–83.
- [72] Kulkarni T D, Narasimhan K R, Saeedi A, et al. Hierarchical deep reinforcement learning: Integrating temporal abstraction and intrinsic motivation[C]//Proceedings of the Conference on Neural Information Processing Systems. Barcelona, 2016: 3675–3683
- [73] Taylor M E, Stone P. Behavior transfer for value-function-based reinforcement learning[C]//International joint conference on autonomous agents and multiagent systems. ACM, 2005: 53–59.
- [74] Tampuu A, Matiisen T, Kodelja D, et al. Multi-Agent cooperation and competition with deep reinforcement learning. arXiv: 1511.08779, 2015.
- [75] Oh J, Chockalingam V, Singh S, et al. Control of memory, active perception, and action in Minecraft[C]//Proceedings of the International Conference on Machine Learning. New York, 2016: 2790–2799.
- [76] Vinyals O, Ewalds T, Bartunov S, et al. StarCraft II: A new challenge for reinforcement learning[J]. arXiv: 1708.04782v1, 2017.
- [77] Wen C. Exploration and study on similarity theory[J]. Journal of Systems Engineering & Electronics, 1992, 3(1): 9–20.
- [78] Shwartz-Ziv R, Tishby N. Opening the black box of deep neural networks via Information[J]. arXiv: 1703.00810, 2017.

Cognitive simulation for complex system understanding and management

TAO Jiuyang^{1,2}, Wu Lin¹, HU Xiaofeng¹, HE Xiaoyuan¹

1. Joint Operations College, National Defense University, Beijing 100091, China

2. Command and Control Engineering College, Army Engineering University of PLA, Nanjing 210007, China

Abstract The rise and the development of the complexity science are reviewed. The concepts of the uncertainty, the adaptability and the emergence of the complex systems are analyzed, as well as the main research methods, and the source of difficulties in their understanding and control. The breakthroughs and the key technologies of the cognitive intelligence are summarized, together with the basic concepts of the cognitive simulation. Finally, the existing problems and shortcomings of the cognitive simulation are outlined.

Keywords cognitive simulation; deep reinforcement learning; complex systems; complexity; cognitive intelligence ●



(责任编辑 卫夏雯)