精准智能理论: 面向复杂动态对象的人工智能

郑志明^{1,2,3,4,5,6}, 吕金虎^{1,2,6,7}, 韦卫^{3,4,5,6}, 唐绍婷^{3,4,5,6*}

1. 北京航空航天大学人工智能研究院, 北京 100191
2. 软件开发环境国家重点实验室, 北京 100191
3. 北京航空航天大学数学科学学院, 北京 100191
4. 数学、信息与行为教育部重点实验室, 北京 100191
5. 鹏城实验室, 深圳 518055
6. 北京航空航天大学大数据科学与脑机智能高精尖创新中心, 北京 100191
7. 北京航空航天大学自动化科学与电气工程学院, 北京 100191

* 通信作者. E-mail: tangshaoting@buaa.edu.cn

收稿日期: 2020-06-02; 接受日期: 2020-06-18; 网络出版日期: 2021-03-16

国际合作重大项目 (批准号: 2010DFR00700)、国家自然科学基金重大项目 (批准号: 11290140) 和国防科工局 [2010]1754 号 (AMS 项目) 资助项目

摘要 新一轮科技革命和产业变革正在萌发, 以深度学习和大数据为基础, 以 AlphaGo 等为典型应用场景掀起了人工智能的第 3 次高潮. 传统的基于统计线性化动态建模的人工智能, 在处理复杂对象时遇到了可解释性、泛化性和可复现性等发展瓶颈, 迫切需要建立基于复杂性与多尺度分析的新一代人工智能理论, 我们称之为精准智能. 针对复杂系统的非线性特征, 精准智能构建内嵌领域知识和数学物理机理的系统学习理论, 包括复杂数据科学感知、复杂系统精准构建、复杂行为智能分析 3 个层次. 具体而言, 通过复杂数据科学感知建立内嵌时空特征与数理规律等具有可解释性的科学数据系统; 通过复杂系统精准构建反演具有非线性复杂逻辑关系的多层次、多尺度、可解释的人工智能动态学习模型; 通过对系统复杂行为智能分析建立面向系统行为演进和全局动态分析的可解释可调控人工智能新理论和新方法. 将上述精准智能理论应用于群体智能, 提出了群体熵方法, 实现了群体激发和汇聚行为复杂性度量与有效引导调控.

关键词 人工智能, 可解释性, 非线性, 复杂性, 精准智能

1 引言

众所周知, 人工智能的发展经历了 3 个历史阶段: 1956~1960 年的逻辑推理时期, 1970~1980 年的知识工程时期, 1990 年至今的机器学习时期. 特别的, 以图灵奖获得者 G. Hinton, Y. LeCun, Y. Bengio

引用格式: 郑志明, 吕金虎, 韦卫, 等. 精准智能理论: 面向复杂动态对象的人工智能. 中国科学: 信息科学, 2021, 51: 678–690, doi: 10.1360/SSI-2020-0158
Zheng Z M, Lü J H, Wei W, et al. Refined intelligence theory: artificial intelligence regarding complex dynamic objects (in Chinese). Sci Sin Inform, 2021, 51: 678–690, doi: 10.1360/SSI-2020-0158

等的主要工作^[1~3]为代表的深度学习技术引发了人工智能的蓬勃发展,广泛应用于图像处理、语音识别、自然语言处理等^[4],引领世界科技前沿的跨越式发展.从 AlphaGo 到 AlphaZero,从 OpenAI 到 OpenAI Five,大量人工智能的动态博弈对抗算法替代传统智能算法,以应对复杂对象的非线性智能决策的科学挑战^[5~8].过去十余年,人们围绕面向复杂对象的人工智能开展了深入探索,在某些方面取得了一些重要进展,如宽度学习、联邦学习等深度学习技术^[9,10],但这些核心技术都没有突破人工智能非线性瓶颈.

2018 年,挪威科学家 O. E. Gundersen 的调查表明:过去几年提出的 400 多种人工智能算法中有 94% 的算法“可复现”存疑^[11].同年, DARPA 启动“颠覆性机遇特别通知——物理人工智能”项目和下一代人工智能计划,探索内嵌物理、数学和先验知识的人工智能范式,以期突破人工智能可解释性瓶颈^[12].2019 年,CMU 提出了 DVIB 技术,从信息论视角给出解决深度学习可解释性问题的一种方案^[13].2017 年,国务院发布“新一代人工智能发展规划”,提出“实现具备高可解释性、强泛化能力的人工智能”目标.上述一系列人工智能理论与方法虽然在某些领域取得了关键突破,但这些方法仍然局限于传统的统计线性化动态建模框架.因此,这些方法在处理复杂对象时仍然遇到可解释性、泛化性和可复现性等发展瓶颈.

随着人工智能方法的广泛应用,深度学习等技术的局限性也逐渐暴露出来,难以处理如强干扰、强隐蔽、强欺骗等带来的信息不完备、边界不确定等诸多问题.相关研究表明,基于深度神经网络的智能算法,如人脸识别、自动驾驶、物体检测等都极易受到噪声的干扰产生不可预期的错误,甚至可能被误导产生严重的后果^[14].为保障智能算法在极端对抗环境下的可靠性与可生存性,迫切需要开展面向复杂动态对象的可解释精准智能理论方法研究,探索人工智能技术决策机制、脆弱性原理、评测体系、分析方法以及优化加固方法,发展复杂大数据的数理表征机理与范式、融合先验知识的复杂系统智能构建方法、面向复杂系统动态行为的人工智能学习方法等.因此,亟需创建基于复杂性与多尺度分析的新一代人工智能理论,我们称之为精准智能.精准智能的主要目标是建立基于大数据的深度表征,学习与识别新理论与新方法,突破现有人工智能可解释性瓶颈,发展一套高精度、高稳定、可信赖的智能模型与方法体系,主要包括复杂数据科学感知、复杂系统精准构建、复杂行为智能分析 3 个层次.

本文第 1 节简述人工智能发展的历史、当前遇到的瓶颈以及精准智能研究的科学必要性;第 2 节从可解释性、系统非线性和复杂性角度阐述当前人工智能面临的科学挑战;第 3 节介绍本团队在面向复杂动态对象人工智能方向的研究成果;第 4 节从面向复杂对象的数据科学感知、系统精准建模、智能行为分析 3 个层次详细介绍精准智能的目标、内涵与关键技术;第 5 节将精准智能理论应用于群体智能并提出群体熵方法;第 6 节简要地总结与展望.

2 人工智能面临的科学挑战

人工智能方法发展至今,其取得的一系列重要突破归根溯源为挖掘并应用了大量蕴含人类知识的数据库.然而,针对很多典型应用,实际可采集数据的数量与质量都无法满足深度学习任务的需求,导致在学习实际复杂系统关键行为时的模型往往不具备可解释性.近年来,深度学习推动了人工智能的跨越式发展,但技术上由于所构造的神经网络参数众多、层级结构复杂、参数间深度耦合,导致神经网络的训练学习过程、网络层的构造机制、参数的特征属性等可靠性存疑.人工智能的目标是从数据中学习复杂系统隐含的内在规律,因此对人工智能方法的可解释性、泛化性能、可重复性等深入研究是当前人工智能发展的核心关键科学问题.

现有人工智能是基于先验经验和统计模型进行数据预处理和建模分析的, 其数学本质是基于统计的线性化动态建模与分析, 大数据分析和人工智能学习过程是通过统计模型或线性化动态模型的演化与优化, 刻画或逼近原复杂系统的性质和行为. 传统人工智能发展的瓶颈根源于其基本理论框架是基于统计与动态线性化的建模思想, 如机器学习、深度学习等技术都属于这一范畴, 很多针对非线性的探索虽然取得了一些进展, 但没有突破上述框架. 面向复杂动态对象的人工智能遇到了复杂性瓶颈, 根源在于复杂系统的基本要素之间是非线性关联耦合且可能具有随机动态行为特征, 但传统人工智能主要是基于统计与动态线性化框架, 不能反演复杂对象的真实规律. 系统基本要素及其之间的关联是决定面向复杂动态对象人工智能的性态和行为的本质特征, 但由于上述基本要素的功能和行为往往具有显著差异性, 因此传统人工智能方法遇到了可解释性、泛化性能、可复现性等瓶颈. 基于统计和动态线性的研究框架难以对复杂系统基本要素间的非线性关系准确刻画, 非线性问题的线性近似导致问题的数理机理发生本质性变化. 因此, 推动人工智能发展亟需重大理论创新, 建立基于非线性科学、内嵌数学物理机理的智能学习方法, 以克服现有人工智能所面临的瓶颈问题.

当前人工智能对复杂性缺乏深入认知, 其数理根源是非线性问题, 非线性导致了不可解释性, 表现为复杂系统学习结果的不唯一性和不稳定性, 系统动态行为发现的不可重复性和不确定性. 建立精准智能理论和方法, 面临非线性导致的复杂性挑战, 具体表现为: 大数据的高维、多源、异构等形态导致的科学描述复杂性, 复杂系统主要因素间非线性关联导致的结构复杂性, 复杂系统行为难以预期调控导致的演化复杂性.

总之, 以深度学习方法为代表的人工智能可解释性已成为制约当前人工智能发展的核心关键科学问题, 这一瓶颈根源于复杂系统基本要素之间的非线性关联关系, 传统的统计与动态线性化框架无法准确有效捕获问题的数理本质, 由非线性所导致的科学描述复杂性、结构复杂性与演化复杂性是当前人工智能发展的科学挑战.

3 面向复杂动态对象人工智能

过去十余年来, 本团队在面向复杂动态对象人工智能方面开展了复杂数据科学感知、复杂系统精准构建、复杂行为智能分析等方面的深入研究, 形成了如下系列研究成果^[15~51].

复杂数据科学感知. 大数据一般都是在复杂环境中产生的, 又在与环境的关联中存在、活动和演化. 数据之间、数据集之间、层次间、数据与系统环境之间错综复杂的耦合作用, 以及新的数据产生和交换等严重制约着数据质量和数据分析结果. 本团队针对动态大数据系统, 从动力学角度将多源异构数据高效解耦和重建, 通过嵌入数理规律实现有效、精准的降复杂系统维数、降大数据样本数, 通过复杂数据的科学感知研究挖掘出数据内在的科学规律, 建立系统主变量、主因素之间的非线性关系科学模式, 得到了从海量数据中智能学习提取关键事件数据、形成科学大数据的普适性方法.

例如, 在面向 AMS-02 空间暗物质探测的海量多源动态异构探测数据高效精准重建中, 由于原始数据是由探测数据、飞行数据、仪器状态数据高度耦合而成的, 如何从复杂多变的原始数据中准确“解耦”出科学探测数据变得异常困难. 与传统统计方法不同, 该研究将多源动态异构数据系统理解为由多个动态异构数据子系统耦合而成的, 通过逐个分析子系统的动力学行为和扬弃干扰子系统, 发现了蕴含原始数据中科学探测数据具有各向同态扩散的非线性性质, 从而确保了精准重建数据系统的高质量性. 团队开发了一套用于 AMS-02 计算中心的数据生产系统, 设计智能算法实现了流水线式智能自动处理, 数据重建速度比数据采集速度提升两个数量级, 在 P 级数据中快速准确发现含有暗物质信息的 K 到 M 级数据, 错误率低于万分之一^[15~17].

复杂系统精准构建. 大数据的聚变、网络拓扑无限拓展是复杂系统构建面临的新挑战, 如何解释由随机与非线性关联作用影响的结构复杂性与动态演化的形态一直是信息科学基础理论研究的热点与难点, 我们从动力学角度发现了系统核心架构与全局突发涌现的科学规律, 提出了开放动态环境中的高效智能搜索方法, 实现了系统结构演化过程的精准引导与全局突发涌现.

例如, 如何在动态、开放的真实网络环境中寻找网络架构的关键节点, 也就是超级传播子是 NP 难问题. 困境在于, 一是真实网络系统的准确重构十分困难, 二是难以在动态开放系统中寻求全局最优解, 因此, 已有的基于传播模型的节点影响力快速发现方法难以推广到真实网络系统中. 我们提出了一种基于局部拓扑的超级传播子精准定位方法, 并发展了内嵌局部拓扑形态特征的全局结构学习理论^[18~20]. *MIT Technology Review* 以“超级传播子新兴科学”为题对项目成果进行了长篇专题报道, 称“完成了真实网络世界中超级传播子研究的首个工作 (first study)”. 此外, 针对系统架构演化中的全局突发涌现, 发展了非线性爆炸性渗流理论, 给出了内嵌渗流系统的分支形态和连续与非连续相变机制, 用于精准预测系统全局爆发节点, 形成了基于系统结构和演化的时空耦合性方法, 并提出抑制和控制策略^[23~26].

复杂行为智能分析. 复杂系统的行为特征, 本质上是研究系统基本要素所呈现的随机非线性关系在演化过程中所起的关键作用, 揭示系统全局演化的固有规律, 使得系统动能更加高效、实时协同与可靠. 如何刻画复杂性, 并得到逼近和调控方法是进行系统动态行为分析的重要突破口.

针对系统行为复杂性, 通常采用 McAndrew 的拓扑熵、Mandebrot 分维或 Lyapunov 指数等统计分析方法. 但是对复杂系统而言, 这些方法的局限性在于, 一是没有给出确定系统复杂性特征的可计算不变量, 二是没有提出如何自适应逼近该复杂系统的策略. 针对复杂系统均具有无穷多周期轨道的特性, 我们率先证明了无穷多周期轨道中存在有限基本周期轨道集合 (确定复杂性的可计算不变量), 系统的复杂性由该集合确定, 并且系统复杂度可由有限“基本周期轨道”构成的代数方程严格求解, 由此形成了对系统动态行为与结构动态复杂性的智能可计算分析理论, 其内在原理可量化为

$$1 + \sum_{p_{l_j} \in P, i_1+i_2+\dots+i_k \leq m, p_{l_1} \neq p_{l_2} \neq \dots \neq p_{l_k}} (-1)^k \left| \lambda_{p_{l_1}}^S \lambda_{p_{l_2}}^S \dots \lambda_{p_{l_k}}^S \right|^{D_H^{(m)}-1} = 0, \quad (1)$$

其中, m 是系统演化时间, $p_{l_1}, p_{l_2}, \dots, p_{l_k}$ 是周期 $\leq m$ 的所有基本周期轨道的周期, $\lambda_{p_{l_1}}^S, \lambda_{p_{l_2}}^S, \dots, \lambda_{p_{l_k}}^S$ 是稳定收缩方向的特征值, D_H 是 Hausdorff 分维数. 并依此建立了基于基本周期轨道的自适应逼近复杂系统的有效途径^[27].

通过一系列相关研究的深入开展, 我们发现系统非线性问题在大量面向复杂动态对象人工智能中是一类共性关键科学问题, 上述相关的研究方法思想对于解决这一关键科学问题具有普适性, 迫切需要建立和发展全新的面向复杂动态对象人工智能理论体系.

4 精准智能理论

经过十多年的研究, 我们探索出了一条面向复杂动态对象人工智能研究的科学范式, 称之为精准智能. 精准智能理论的核心是面向系统要素间的非线性随机性关联关系, 融合统计、分析、代数、几何、动力系统等理论, 围绕数据 (知识) – 模型 (系统) – 算法 (学习) 这一智能基本架构, 聚焦人工智能可解释性问题, 通过研究复杂系统的多层次、多尺度关联耦合机制以及时空动态结构, 发展内嵌底层逻辑和数学物理内涵、融合非线性分析和复杂性科学的智能理论体系, 从复杂数据科学感知、复杂系统精准构建、复杂行为智能分析 3 个层次建立大数据的准确认知和智能学习方法.

具体而言, 精准智能研究基于时空特征与数理规律的科学数据描述范式、基于复杂数据系统耦合解耦方法的数理系统重建方法、复杂系统内在和动态特征的复杂性分类、基于局部形态特征的全局结构分析和基于阈值分析 (分支) 的系统突变等基础科学问题, 从系统科学角度建立大数据的准确认知理论和快速挖掘方法. 精准智能与深度学习的区别在于: 精准智能在数据表征方面关注高维演化大数据的数理表征, 在系统建模方面研究融合先验知识的非线性多数据场耦合系统建模, 在行为演化方面通过演化与涌现机理分析进行智能算法模型精准智能调控.

精准智能从复杂性科学的视角出发, 基于复杂系统的逻辑关系构建可解释人工智能的新理论框架, 旨在从大数据的科学描述复杂性、数据系统结构复杂性及系统行为演化复杂性等角度揭示复杂系统多变量主因素的非线性关系, 通过多层次、多尺度耦合关联建模阐释其内在规律, 重点关注系统中多尺度机制和效应对系统的影响, 精准动态识别系统的复杂性特征行为模式, 形成可解释人工智能的方法体系. 研究方向主要包括以单元数据构建整体数据的复杂数据科学感知, 以数据系统构建智能学习模型的复杂系统精准构建, 以学习模型分析系统特征演化的复杂行为智能分析.

4.1 面向复杂对象的数据科学感知

在复杂对象的数据科学感知层次, 探索大数据蕴含的物理机制和逻辑关系复杂性, 融合先验知识以构建科学数据系统. 基于对系统的物理背景研究和多源高维大数据处理技术, 探索大数据中的多层次、多尺度耦合关联结构, 发展内嵌先验知识的数据表示范式, 提出科学标注理论与方法, 建立内嵌时空特征与数理等规律的具有可解释性的科学数据系统.

复杂对象的数据感知面临大数据的高维、多源、异构等复杂数据形态以及数据采集过程中发生的数据缺失、冗余、重复、偏差和错误等诸多问题, 这些问题产生的数据噪声降低了大数据的信噪比, 阻碍了智能学习方法精准还原系统本征属性. 因此建立精准智能理论首先要发展基于大数据内在物理机制和逻辑关系的科学数据表示方法, 探索内嵌时空特征等先天科学结构的数据表述范式和基于多层次、多尺度、非线性耦合关联关系的数理精准表征. 基于所研究的具体问题, 融合先验知识和数学物理规律开展缺失数据的修补, 错误、偏差数据的重构, 冗余数据的清洗以及科学标注工作; 发展基于数据表述范式和物理结构的数据系统建模方法, 将高维、多源、异构复杂大数据重构为标准化科学数据系统, 对其中蕴含的真实系统信息进行精准高效识别, 为精准智能方法提供坚实可靠数据基础.

例如, 图 1 给出了一个数据先验知识/数理规律对函数拟合逼近影响的例子, 由于 Logistic 回归、神经网络等人工智能算法本质上都是对数据蕴含的系统规律的拟合逼近, 图 1 中的数据来自于一个受轻微干扰 (高斯 (Gauss) 白噪声 $N(0, 0.05)$) 的简单信号系统,

$$y = \sin x + \cos 2x + N(0, 0.05). \quad (2)$$

如果脱离了这个数据来源的先验知识和数理规律, 使用幂级数逼近 (绿色线) 在坐标原点附近可以较好拟合,

$$\tilde{y} = 1 + x - 2x^2 - \frac{x^3}{6} + \frac{2x^4}{3} + \frac{x^5}{120} - \frac{4x^6}{45} - \frac{x^7}{5040}. \quad (3)$$

尽管拟合精度已经高达 7 阶, 但是远离原点位置的逼近误差仍然十分巨大, 需要大幅度提升模型复杂度 (阶数) 才有可能在更大范围内拟合逼近; 然而如果充分利用好先验知识和数理规律, 利用 Fourier 级数形式逼近, 则仅需要 2 项就可以充分拟合原数据系统.

4.2 面向复杂对象的系统精准建模

在复杂对象的系统精准建模层次, 基于非线性的复杂逻辑关系, 探索融合先验知识的数据系统的

图 1 (网络版彩图) 数据先验知识/数理规律对函数拟合逼近的影响. 图中蓝色点型数据为原始数据, 是由 $y = 2\sin(\frac{\pi}{4} - \frac{x}{2})\cos(\frac{3x}{2} - \frac{\pi}{4}) + N(0, 0.05) = \sin x + \cos 2x + N(0, 0.05)$ 生成的带高斯白噪声 $N(0, 0.05)$ 的数据. 红色曲线为利用 Fourier 级数拟合逼近的效果, 即 $y = \sin x + \cos 2x$. 绿色曲线为利用幂级数拟合逼近的效果, 保留了 7 阶多项式 $\tilde{y} = 1 + x - 2x^2 - \frac{x^3}{6} + \frac{2x^4}{3} + \frac{x^5}{120} - \frac{4x^6}{45} - \frac{x^7}{5040}$

Figure 1 (Color online) The influence of data prior knowledge/mathematical and physical laws on function fitting approximation. The blue-dotted data is the original data, which is produced by $y = 2\sin(\frac{\pi}{4} - \frac{x}{2})\cos(\frac{3x}{2} - \frac{\pi}{4}) + N(0, 0.05) = \sin x + \cos 2x + N(0, 0.05)$, where $N(0, 0.05)$ is Gaussian noise. The red curve is the result of approximation by Fourier series fitting, i.e., $y = \sin x + \cos 2x$. The green curve retains the 7th order polynomial for the approximation effect of power series fitting, i.e., $\tilde{y} = 1 + x - 2x^2 - \frac{x^3}{6} + \frac{2x^4}{3} + \frac{x^5}{120} - \frac{4x^6}{45} - \frac{x^7}{5040}$

智能学习模型及其建模方法. 分析影响复杂数据系统时空多尺度动态结构的相互作用机制, 探索不同尺度中多种调控机制在竞争中协调的物理机理对智能学习模型的影响, 基于耦合解耦方法、多目标变分等方法研究各层次、多尺度耦合关系及其优化策略, 构建具有可解释性的人工智能动态学习模型.

复杂对象的系统建模主要面临系统内部主要要素间的全局、多模态、非线性关联关系挑战. 传统人工智能方法主要依赖统计和线性分析方法对复杂系统进行逼近, 而精准智能方法旨在从非线性角度挖掘其内部的数理规律, 实现对系统各个要素间关系的精准描述. 通过构建内嵌先验科学知识的系统架构, 分析系统各要素间多尺度、多模态时空关联关系的耦合解耦机制, 基于多目标变分及微观协同的多数据场耦合机理对系统进行科学解耦, 发展面向非线性耦合多数据场系统建模方法. 针对解耦得到的单数据场进行层次划分分析, 从微观和介观层次上发展基于局部形态特征的单数据场全局复杂结构分析方法. 融合单数据场结构特征分析和系统的多模态耦合机制, 对隐藏在复杂多数据场中的物理机理进行研究. 此外还应当着重发展复杂多数据场耦合结构正确性的判定技术, 以确保重构系统能够还原原系统要素间的复杂关联关系精准还原.

例如, 图 2 给出了一个现代城市交通网络层次结构示意图, 从整体上看城市公共交通网络是典型的复杂系统, 规模庞大、运输方式多样且系统各个部分的动态关联关系繁杂, 难以对其结构和动力学行为进行科学有效分析. 通过内嵌城市交通先验知识, 按照不同运输模式对该复杂系统进行解耦分析, 将交通网络划分为代表地面公共交通的 α 层和代表地下轨道交通的 β 层, 对城市交通网络结构进行逐层分析和耦合重构, 实现对城市立体交通网络架构的精准还原, 明确其中的关键枢纽节点, 有利于对整个交通网络上的流量进行科学预测和精准疏导.

图 2 (网络版彩图) 城市立体交通网络层次结构示意图. 图中 α 层代表城市地面公共交通网络, β 层代表地下轨道交通网络. 绿色节点 (如节点 j) 代表普通站点, 红色节点 (如节点 i) 代表地面公交与地下轨道交通的换乘枢纽

Figure 2 (Color online) The hierarchical structure of three-dimensional urban traffic network. In the figure, the α layer represents the urban surface public transport network, and the β layer represents the underground rail transit network. The green node (such as node j) represents the ordinary station, and the red node (such as node i) represents the transfer hub between the ground bus and the underground rail transit

4.3 面向复杂对象的智能行为分析

在复杂对象的智能行为分析层次, 主要研究复杂行为演化复杂性和基于行为演化的动态调控策略. 提出基于系统特征的精准分析方法, 探索智能模型行为演化的系统稳定性, 发展基于局部特征的全局性动态分析架构, 揭示基于相变和涌现机制的系统突变行为模式和基于多尺度分析的系统突变机理, 建立具有可解释性与可调控性的人工智能方法.

复杂对象的智能行为分析受复杂系统的行为演化复杂性影响, 直接导致了系统的整体行为难以理解、预期和调控. 传统人工智能方法主要是基于线性模型的参数调节对系统整体行为进行模拟, 难以对系统的长期演化模式进行准确预测、动态调控. 精准智能理论融合了先验知识、非线性科学、动力学系统和统计物理相关理论, 挖掘系统行为演化内在机理, 发展面向系统动态非线性行为的演化学习方法和基于局部特征的全局性动态分析方法. 针对复杂系统的突发行为, 建立基于阈值分析和相变涌现的系统相变模式分析理论, 研究非线性条件下系统由非平衡态通向平衡态的演化路径, 基于多尺度分析研究系统的整体演进方向和稳态模式, 以及系统行为突变等关键现象进行准确预测, 为面向系统行为实施精准调控提供理论基础.

例如, Logistic 映射是系统科学中一个非常典型的模型, 可以用来模拟生物种群的生长行为,

$$y = ax(1 - x), \quad 0 \leq a \leq 4, \quad 0 \leq x \leq 1. \quad (4)$$

表 1 给出了利用 100 个神经元组成全连接神经网络逼近 Logistic 映射的残差, 从结果可以看出, 单纯从函数逼近的角度, 无论是层数较少 (3 层) 还是层数较多 (10 层) 的学习都可以达到高精度逼近的效果, 神经网络方法可以很好地逼近给定函数. 图 3 给出了该神经网络逼近与原二次函数的迭代行为动力学比较, $a = 1.5, a = 3.4$ 是 Logistic 映射动力学行为的简单情况并不复杂, 从而该神经网络不仅能够很好地逼近对应的二次函数, 而且能够很好地逼近对应的动力学行为; 而根据 Logistic 映射动力学行为理论知道, 当 $1 + \sqrt{6} < a < 4$ 时该二次函数系统的迭代行为发生混沌^[52], 此时对应 ($a = 3.7, 3.9$) 的逼近神经网络已经无法逼近原系统的行为. 实际上, 这与动力系统理论是吻合的, 原系统与逼近系统的微小误差在混沌行为发生时都会被随意拉伸或放大, 由于拉伸, 非线性导致了系统对初值的敏感

表 1 神经网络逼近 $y = ax(1 - x)$ 的残差
Table 1 Neural network approximation residuals for $y = ax(1 - x)$

Neural network layers/values of a	1.5	3.4	3.7	3.9
3 layers	0.00668	0.00026	0.00285	0.00032
10 layers	0.00682	0.00165	0.00038	0.00017

图 3 (网络版彩图) 系统的迭代行为与神经网络拟合的迭代行为比较. 图中黑色曲线为函数 $y = ax(1 - x)$ 的迭代动力学曲线, 参数 a 分别等于 1.5, 3.4, 3.7, 3.9. 红色曲线为 3 层全连接神经网络 (100 个神经元, 3 层分别有 10, 80, 10 个神经元) 的迭代动力学曲线, 该神经网络用于逼近对应参数值下的 $y = ax(1 - x)$ 函数. 绿色曲线为 10 层全连接神经网络 (100 个神经元, 各层分别有 2, 4, 8, 12, 36, 14, 10, 8, 4, 2 个神经元) 的迭代动力学曲线, 该神经网络用于逼近对应参数值下的 $y = ax(1 - x)$ 函数

Figure 3 (Color online) The iterative behavior of the system is compared with that of neural network fitting. The black curve in the figure is the iterative dynamic curve of the function $y = ax(1 - x)$. The parameter a is equal to 1.5, 3.4, 3.7 and 3.9, respectively. The red curve is the iterative dynamic curve of three-layer fully connected neural network (100 neurons, three layers with 10, 80 and 10 neurons respectively). The neural network is used to approximate the function of $y = ax(1 - x)$ under the corresponding parameter values. The green curve is an iterative dynamic curve of 10 layer fully connected neural network (100 neurons, each layer has 2, 4, 8, 12, 36, 14, 10, 8, 4, 2 neurons). The neural network is used to approximate the function of $y = ax(1 - x)$ under the corresponding parameter values

性被放大, 使得系统行为难以学习.

5 精准智能在群体智能中的典型应用

智能群体是一种典型的人工智能复杂系统, 其核心问题在于对群体中个体或子群体的行为进行动态精准引导和调控, 以确保群体智能向稳定有序的方向演进并完成共同任务目标. 群体熵方法是精准智能理论在群体智能领域的典型应用, 是基于精准智能的行为演进复杂性度量方法, 分析非线性协作

结构在动态演化中的稳定性与有序性问题, 构建高维度异构数据下的多模态异质群体度量和智能群体行为模式精化迭代体系, 实现对群智汇聚过程的有效引导. 具体而言, 结合熵度量特征, 挖掘复杂多变环境下的显示或隐藏的知识, 研究群体智能系统中个体的交互融合与协同服务的基本特征与复杂耦合特征, 基于系统演化动力学分支理论及稳定性理论实现对群体智能行为的多尺度多模态群智汇聚调控优化方法, 实现群智汇聚过程由稳定有序向稳定有序演化.

$$H(t) = - \sum_{i \in I(t)} \sum_j \frac{A_{ij}}{k_i} \ln \frac{A_{ij}}{k_i}. \quad (5)$$

上式为复杂网络结构上的搜索任务场景下的群体熵定义, 以此来诠释群体熵在智能行为动态精准引导和调控中的应用. 其中 $I(t)$ 为 t 时刻网络上正在执行任务的个体集合, A_{ij} 为节点 i 与 j 对应的图邻接矩阵 A 的相应元素, k_i 为节点 i 的度. 群体熵 $H(t)$ 可以作为激发和汇聚这两类群体智能行为的有效度量¹⁾.

6 应用与展望

许多实际应用大数据, 例如地学大数据、交通大数据、气象大数据等具有典型的时空连贯性、各类物理特征明确等特征, 基于多参量融合的数据分析方法难以准确描述系统的数学物理规律, 特别是面向地学灾害、交通事故、气象灾害等关键事件的分析处理时, 往往效果欠佳. 许多现有的工程或科学问题都带有很强的非线性特征, 现有神经网络学习系统的结构复杂性主要源于内部神经元规模和网络深度的高度不确定性, 针对特定问题神经网络的规模和深度选择通常依赖于经验进行选择和优化, 神经网络内部结构和参数取决于模型对系统参数的训练结果, 呈现出高度的不确定性, 直接导致了当前人工智能算法的可解释性瓶颈. 如何内嵌数学物理规律开展系统学习, 引入非线性分析机制突破现有的人工智能方法瓶颈、提升算法的泛化性能, 形成精准可靠的人工智能新方法具有重要理论和应用意义.

伴随着人工智能的深入发展, 可解释性人工智能、低复杂度人工智能等都成为国际上非常重要的前沿研究方向, 通过信息科学与数学、物理学等基础学科的深度交叉融合, 从复杂性与多尺度视角探索人工智能基础理论与方法, 突破现有的人工智能可解释性瓶颈, 推动动态、稳健与可信的智能模型与方法体系的构建, 建立一套高精度、高稳定、可信赖的精准智能理论方法体系成为理论和应用的发展必需. 精准智能从突破人工智能复杂性认知出发, 实现理论突破、形成精准智能范式, 使智能模型更稳定可靠. 建立可信安全精准算法体系, 以典型应用为牵引形成普适性和辐射性方法, 所产生的技术方法可以广泛应用于交通事故、地质灾害、网络舆情、疾病传播等领域数据处理和人工智能研究, 对于发展和完善新一代人工智能基础理论、提升我国信息学科国际竞争力、占领人工智能国际科技竞争制高点具有重要推动作用.

参考文献

- 1 Rumelhart D E, Hinton G E, Williams R J. Learning internal representations by error propagation. California Univ San Diego La Jolla Inst for Cognitive Science, 1985
- 2 Yang L C, Bengio Y. Convolutional networks for images, speech, and time series. Handbook Brain Theory Neural Netw, 1995, 3361: 1995
- 3 Bengio Y. Learning deep architectures for AI. FNT Mach Learn, 2009, 2: 1-127
- 4 Pannu A, Student M T. Artificial intelligence and its application in different areas. Artif Intell, 2015, 4: 79-84

1) 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. 已录用, 2020

- 5 Schraudolph N N, Dayan P, Sejnowski T J. Temporal difference learning of position evaluation in the game of Go. In: Proceedings of Advances in Neural Information Processing Systems, Denver, 1994. 817–824
- 6 Ferrucci D, Levas A, Bagchi S, et al. Watson: beyond jeopardy! *Artif Intell*, 2013, 199–200: 93–105
- 7 Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks. *Science*, 2006, 313: 504–507
- 8 Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks. In: Proceedings of Advances in Neural Information Processing Systems, Lake Tahoe, 2012
- 9 Konečný J, McMahan H B, Yu F X, et al. Federated learning: strategies for improving communication efficiency. 2019. ArXiv: 1610.05492
- 10 Chen C L P, Liu Z. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture. *IEEE Trans Neural Netw Learn Syst*, 2018, 29: 10–24
- 11 Gundersen O E, Kjensmo S. State of the art: reproducibility in artificial intelligence. In: Proceedings of AAAI, New Orleans, 2018
- 12 David G. Broad Agency Announcement, Explainable Artificial Intelligence (XAI). DARPA/I2O, 2018
- 13 Alexander A A, Ian F, Joshua V D, et al. Deep variational information bottleneck. 2019. ArXiv: 1612.00410
- 14 Zolfagharian A, Noshadi A, Khosravani M R, et al. Unwanted noise and vibration control using finite element analysis and artificial intelligence. *Appl Math Model*, 2014, 38: 2435–2453
- 15 Aguilar M, Alberti G, Alpat B, et al. First result from the Alpha magnetic spectrometer on the international space station: precision measurement of the positron fraction in primary cosmic rays of 0.5–350 GeV. *Phys Rev Lett*, 2013, 110: 141102
- 16 Accardo L, Aguilar M, Aisa D, et al. High statistics measurement of the positron fraction in primary cosmic rays of 0.5–500 GeV with the Alpha magnetic spectrometer on the international space station. *Phys Rev Lett*, 2014, 113: 121101
- 17 Aguilar M, Aisa D, Alpat B, et al. Precision measurement of the proton flux in primary cosmic rays from rigidity 1 GV to 1.8 TV with the Alpha magnetic spectrometer on the international space station. *Phys Rev Lett*, 2015, 114: 171103
- 18 Pei S, Muchnik L, Tang S T, et al. Exploring the complex pattern of information spreading in online blog communities. *Plos One*, 2015, 10: e0126894
- 19 Pei S, Tang S T, Zheng Z M. Detecting the influence of spreading in social networks with excitable sensor networks. *Plos One*, 2015, 10: e0124848
- 20 Pei S, Muchnik L, Jose S, et al. Searching for superspreaders of information in real-world social media. *Sci Rep*, 2015, 4: 5547
- 21 Li W, Bradshaw A E, Clary C B, et al. A three-degree horizon of peace in the military alliance network. *Sci Adv*, 2017, 3: e1601895
- 22 Li W, Aste T, Caccioli F, et al. Early coauthorship with top scientists predicts success in academic careers. *Nat Commun*, 2019, 10: 5170
- 23 Chen W, D'Souza R M. Explosive percolation with multiple giant components. *Phys Rev Lett*, 2011, 106: 115701
- 24 Chen W, Nagler J, Cheng X, et al. Phase transitions in supercritical explosive percolation. *Phys Rev E*, 2013, 87: 052130
- 25 Jiang S J, Tang S T, Pei S, et al. Low dimensional behavior of explosive synchronization on star graphs. *J Stat Mech*, 2015, P10007, 069903
- 26 Zhang Y, Wei W, Guo B H, et al. Formation mechanism and size features of multiple giant clusters in generic percolation processes. *Phys Rev E*, 2012, 86: 051103
- 27 Franceschini V, Giberti C, Zheng Z M. Characterization of the Lorentz attractor by unstable periodic orbits. *Nonlinearity*, 1993, 6: 251–258
- 28 Wei W, Zhang R Q, Niu B L, et al. Organization mechanism and counting algorithm on vertex-cover solutions. *J Stat Mech*, 2015, P04002
- 29 Liu L Z, Wang X, Zheng Y, et al. Homogeneity trend on social networks changes evolutionary advantage in competitive information diffusion. *New J Phys*, 2020, 22: 013019
- 30 Lü J H, Tan S L. Games and Evolutionary Dynamics on Complex Networks. Beijing: Higher Education Press, 2019

- [吕金虎, 谭少林. 复杂网络上的博弈及其演化动力学. 北京: 高等教育出版社, 2019]
- 31 Ning S C, Ma S L, Kwek K H, et al. A cubic system with eight small-amplitude limit cycles. *Appl Math Lett*, 1994, 7: 23–27
 - 32 Zheng Z M. On the abundance of chaotic behavior for generic one-parameter families of maps. *Acta Math Sin*, 1996, 12: 398–412
 - 33 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
 - 34 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
 - 35 Wei W, Guo B H, Zheng Z M. Statistical and algebraic analysis of a family of random Boolean equations. *J Stat Mech*, 2009, 2009: P02010
 - 36 Sun Y F, Guo B H, Wei W, et al. On the thresholds in linear and nonlinear Boolean equations. *Eur Phys J B*, 2010, 76: 123–146
 - 37 Guo B H, Wei W, Sun Y, et al. Algebraic characteristics and satisfiability threshold of random Boolean equations. *Phys Rev E*, 2010, 81: 031122
 - 38 Jiang X, Wang H L, Tang S T, et al. A new approach to shortest paths on networks based on the quantum bosonic mechanism. *New J Phys*, 2011, 13: 013022
 - 39 Wei W, Zhang R Q, Guo B H, et al. Detecting the solution space of vertex cover by mutual determinations and backbones. *Phys Rev E*, 2012, 86: 016112
 - 40 Wei W, Zhang Y J, Wang T, et al. Research on solution space of bipartite graph vertex-cover by maximum matchings. *J Stat Mech*, 2015, 2015: P11027
 - 41 Pei S, Tang S T, Yan S, et al. How to enhance the dynamic range of excitatory-inhibitory excitable networks. *Phys Rev E*, 2012, 86: 021909
 - 42 Guo Q T, Lei Y J, Jiang X, et al. Epidemic spreading with activity-driven awareness diffusion on multiplex network. *Chaos*, 2016, 26: 043110
 - 43 Yan S, Tang S T, Pei S, et al. Dynamical immunization strategy for seasonal epidemics. *Phys Rev E*, 2014, 90: 022808
 - 44 Li W H, Tang S T, Fang W Y, et al. How multiple social networks affect user awareness: The information diffusion process in multiplex networks. *Phys Rev E*, 2015, 92: 042810
 - 45 Yan S, Tang S T, Fang W Y, et al. Global and local targeted immunization in networks with community structure. *J Stat Mech-Theory E*, 2015, 2015: P08010
 - 46 Guo Q T, Lei Y J, Xia C Y, et al. The role of node heterogeneity in the coupled spreading of epidemics and awareness. *Plos One*, 2016, 11: e0161037
 - 47 Pei S, Shaman J. Counteracting structural errors in ensemble forecast of influenza outbreaks. *Nat Commun*, 2017, 8: 925
 - 48 Tang S T, Teng X, Pei S, et al. Identification of highly susceptible individuals in complex networks. *Phys A*, 2015, 432: 363–372
 - 49 Wang X, Li W H, Liu L Z, et al. Promoting information diffusion through interlayer recovery processes in multiplex networks. *Phys Rev E*, 2017, 96: 032304
 - 50 Pei S, Kandula S, Wan Y, et al. Forecasting the spatial transmission of influenza in the United States. *Proc Natl Acad Sci USA*, 2018, 115: 2752–2757
 - 51 Li R Y, Pei S, Chen B, et al. Substantial undocumented infection facilitates the rapid dissemination of novel coronavirus (SARS-CoV-2). *Science*, 2020, 368: 489–493
 - 52 Zhang Z F, Li C Z, Zheng Z M, et al. Bifurcation Theory Basis of Vector Field. Beijing: Higher Education Press, 1997 [张芷芬, 李承治, 郑志明, 等. 向量场的分岔理论基础. 北京: 高等教育出版社, 1997]

Refined intelligence theory: artificial intelligence regarding complex dynamic objects

Zhiming ZHENG^{1,2,3,4,5,6}, Jinhu LÜ^{1,2,6,7}, Wei WEI^{3,4,5,6} & Shaoting TANG^{3,4,5,6*}

1. *Institute of Artificial Intelligence, Beihang University, Beijing 100191, China;*

2. *State Key Laboratory of Software Development Environment, Beijing 100191, China;*

3. *School of Mathematical Sciences, Beihang University, Beijing 100191, China;*

4. *Key Laboratory of Mathematics Informatics Behavioral Semantics, Ministry of Education, Beijing 100191, China;*

5. *Peng Cheng Laboratory, Shenzhen 518055, China;*

6. *Beijing Advanced Innovation Center for Big Data and Brain Computing, Beihang University, Beijing 100191, China;*

7. *School of Automation Science and Electrical Engineering, Beihang University, Beijing 100191, China*

* Corresponding author. E-mail: tangshaoting@buaa.edu.cn

Abstract A new round of scientific and technological change and industrial transformation is emerging. Based on deep learning and big data, a third achievement of artificial intelligence is represented by AlphaGo and other typical application scenarios. When dealing with complex dynamic objects, the traditional artificial intelligence based on statistical linear dynamic modeling experiences bottlenecks related to interpretability, generalization, and reproducibility. It is urgent that a new generation of artificial intelligence theory be established that is based on complexity and multi-scale analysis, which we refer to as refined intelligence. To deal with the non-linearity of complex systems, we constructed a systems learning theory of embedded domain knowledge and a mathematical physical mechanism that is accurate and intelligent at three performance levels: complex data perception, complex system refined construction, and complex intelligent behavior analysis. Specifically, we built a scientific data system with interpretability, including embedded spatiotemporal characteristics and mathematical laws, through complex data perception. We also built a multi-level, multi-scale, and interpretable artificial intelligence dynamic learning model that can deal with the nonlinear relationship of complex logic based on complex system-defined construction. We developed a new theory and method for interpreting and controlling the evolution of artificial-intelligence-oriented behavior and global dynamic analysis based on complex intelligent-behavior analysis. We applied the above refined intelligence theory to the proposed method for crowd intelligence with crowd entropy, and found that it can measure complexity and provide effective guidance regarding system stimulation and aggregation behavior.

Keywords artificial intelligence, interpretability, nonlinearity, complexity, refined intelligence

Zhiming ZHENG was born in 1953. He received his Ph.D. degree in mathematics from the School of Mathematical Sciences, Peking University, Beijing, China, in 1987. Currently, he is a professor at the Institute of Artificial Intelligence, Beihang University, Beijing, China. He is a member of Chinese Academy of Sciences. His research interests include refined intelligence theory, information security, and complex information systems.

Jinhu LÜ was born in 1974. He received his Ph.D. degree in applied mathematics from the Academy of Mathematics and Systems Science, Chinese Academy of Sciences, Beijing, China, in 2002. Currently, he is a professor at the School of Automation Science and Electrical Engineering, Beihang University, Beijing, China. He is a fellow of IEEE and CAA. His current research interests include complex networks, cooperation control, and AI.

Wei WEI was born in 1981. He received his Ph.D. degree in mathematics from the School of Mathematical Sciences, Peking University, Beijing, China, in 2009. He is currently an associate professor at the School of Mathematical Sciences, Beihang University, Beijing, China. His research interests include dynamical system and complexity, complex network, and artificial intelligence.

Shaoting TANG was born in 1983. She received her Ph.D. degree in mathematics from the School of Mathematical Sciences, Beihang University, Beijing, China, in 2011. Currently, she is a professor at the Institute of Artificial Intelligence, Beihang University, Beijing, China. Her research interests include complex information systems and brain-inspired artificial intelligence.