基于多粒度认知的智能计算研究

王国胤'傅顺"杨洁"郭毅可20,30

1)(重庆邮电大学计算智能重庆市重点实验室 重庆 400065)

2)(香港浸会大学计算机科学系 香港)

3)(英国帝国理工学院数据科学学院 伦敦 WP1PG 英国)

摘 要 在传统的机器学习研究中,数据空间与知识空间分离表达、计算机的信息处理过程与人脑的认知处理过程不一致,成为了当前人工智能研究需要解决的核心关键问题.本文从认知计算的角度,回顾分析了基于多粒度认知的智能计算研究的发展历史轨迹,介绍了该领域的研究现状,提出了多粒度认知计算、可解释的认知机器学习、脑认知的智能计算辅助等该领域的三个前沿研究方向,探讨了在多粒度认知启发下,这些智能计算研究的未来可能发展趋势.

关键词 粒计算;知识发现;认知计算;可解释机器学习;人工智能中图法分类号 TP18 **DOI**号 10.11897/SP. J. 1016. 2022. 01161

A Review of Research on Multi-Granularity Cognition Based Intelligent Computing

WANG Guo-Yin¹⁾ FU Shun¹⁾ YANG Jie¹⁾ GUO Yi-Ke^{2),3)}

1) (Chongqing Key Laboratory of Computational Intelligence, Chongqing University of Posts and Telecommunications, Chongqing 400065

2) (Department of Computer Science, Hong Kong Baptist University, Hong Kong)

3) (Data Science Institute, Imperial College London, London WP1PG, UK)

Granular computing (GrC) is a machine intelligence and cognitive computing methodology that uses granule as a processing object. It is a powerful tool for approximate solution of complex problems at multiple levels and scales. Its essence is to simulate the multi-granularity cognition mechanism of the human brain, and establish a set of theories and methods for information space transformation between the information processing mechanism of computer and the multi-granularity cognition process of the human brain. From the perspective of granular computing and cognitive computing, this paper analyzes several contradictory phenomena and problems existing in artificial intelligence research. The information processing mechanism of computer starts from samples on fine granule. It extracts knowledge from data based on the expression of data space. Nevertheless, the human cognition process maps and reasons between data and knowledge based on the expression of knowledge space. In traditional machine learning research, there exists the problem of separate expression of data space and knowledge space. The separate expression leads to the independence of data and knowledge. It is difficult to establish the mapping and reasoning from data to knowledge. In the process of image recognition, the computer algorithm processes from the pixel points rather than high-level semantic features or concepts of the image. However, the human visual cognition process starts with global topological features, and then gradually refined features. This contradictory

收稿日期:2021-07-10;在线发布日期:2022-01-25.本文得到国家自然科学基金(61936001,61772096,62066049)、重庆市自然科学基金(cstc2021ycjh-bgzxm0013,cstc2019jcyj-cxttX0002)、重庆市教委重点合作项目(HZ2021008)资助. 王国胤(通信作者),博士,教授,博士生导师,中国计算机学会(CCF)会士,长江学者,主要研究领域为粒计算、知识发现、认知计算、智能信息处理、大数据智能. E-mail: wanggy@cqupt. edu. cn. 傅 顺,博士研究生,中国计算机学会(CCF)学生会员,主要研究方向为粒计算、网络表示学习、数据挖掘、可解释机器学习. 杨 洁,博士,教授,主要研究方向为粗糙集、粒计算、数据挖掘、郭毅可,博士,教授,博士生导师,英国皇家工程院院士,主要研究领域为数据挖掘、表示学习、可解释机器学习.

phenomenon shows that the information processing mechanism of computer is not consistent with the cognition process of the human brain. This leads to a number of serious problems, such as the vulnerability and lack of interpretability of deep learning neural network models. For example, adding a small amount of specific noise to an image may seriously reduce the recognition performance of a deep neural network and generate a completely wrong recognition result. In addition, deep convolutional neural network models trained by ImageNet tend to rely more on fine-granular features such as texture for recognition (texture bias) than coarse-granular features such as shape. In this paper, the historical development trajectory of multi-granularity cognition based intelligent computing (MGCIC) is reviewed and the current research progress about the nine major issues of data-driven granular cognitive computing (DGCC) is introduced. Furthermore, the three frontier research directions such as multi-granularity cognitive computing, interpretable cognitive machine learning, and intelligent computing assistance for brain cognition are proposed. In detail, multi-granularity cognitive computing is based on granular computing, which integrates the problem-solving mechanism of the human brain into granular computing models. It integrates the cognition process of the human brain and the information processing mechanism of computers. Through collaboratively inspecting the knowledge implied in a multi-granularity knowledge space, these two seemingly opposite transformation processes could be studied in the same multigranularity space. The objective of interpretable cognitive machine learning is to find out the complex correlation between concepts distributed in a deep knowledge space generated from massive data and to establish the mapping between a deep knowledge expression space and a deep neural network feature space. The objective of intelligent computing assistance for brain cognition is to promote the research of brain science and cognition science with the help of intelligent computing models and methods based on the idea of computer simulation. This paper provides new ideas and inspirations for the intersection and fusion study of artificial intelligence and human (cognitive) intelligence.

Keywords granular computing; knowledge discovery; cognitive computing; interpretable machine learning; artificial intelligence

1 引 言

随着大数据时代的来临以及人工智能研究的兴起,认知计算逐渐成为人们关注的焦点.认知计算是认知科学、数据科学和一系列计算技术协同融合的新兴领域.粒计算(Granular Computing,GrC)是一种使用"粒"作为处理对象的一系列方法的机器智能及认知计算方法论[1].它是在多层次、多尺度上对复杂问题近似求解的有力工具.它的本质是模拟人脑的多粒度认知机理,并建立一套将计算机信息处理过程与人脑的多粒度认知过程进行信息空间变换的理论和方法.粒计算自美国工程院院士 Zadeh 教授在1979年提出以来[2],已有40余年的发展历史.在这期间,人们建立了多种实现多粒度认知的智能计算理论模型和方法[1.3-6],推动了人工智能的发展.

为了分析基于多粒度认知的智能计算(Multi-Granular Cognitive Intelligent Computing, MGCIC)的未来研究发展趋势,本文先讨论分析在相关研究工作中观察到的几个矛盾现象和问题.

首先,计算机的信息处理过程与人脑的认知处理过程并不一致.比如,近年来非常流行的深度学习模型在图像识别任务上的识别精度和速度已经达到甚至超越了人类.然而,如果在图片中加入少量特定噪声,却可能严重降低深度神经网络模型的识别性能,得到完全错误的识别结果.显然,对人类来说,这些微弱的噪声几乎不会造成任何干扰.图1所示的基于深度学习的反人脸识别实验结果说明了这一现象.如图1所示,左侧图片(原始图像)中,红色方框标识了可以被深度学习系统正确识别的人脸.然而在添加了中间图片中的噪声信息后,得到的右侧图片(添加噪声后的图像)中的人脸却不能被正确识



加入噪声后,原本可检测到的人脸比例从接近100%降到0.5%!

图 1 基于深度学习的反人脸识别[7]

别^[7]. 这说明深度学习模型的识别计算机理不同于人类的识别认知机理.

其次,深度学习模型对于图像的识别,会以纹理作为其识别的主要特征信息[8].比如,用 ImageNet训练的深度卷积神经网络模型,更趋向于依赖纹理进行识别,而非形状.这是深度学习图像识别模型的"纹理偏执"现象.如图 2 所示,人类会认为更像猫的图像,却被深度学习模型识别为象.这说明在图像识别机理上,深度学习模型与人类大脑并不一致.由于深度学习是一个黑箱模型,人们不禁要问,在进行图像识别的过程中,深度学习究竟依赖什么特征?目前,人们对这个问题的认知度并不够,深度学习模型至今依然缺乏可解释性.



图 2 纹理信息 vs. 轮廓信息[8]

另外,计算机科学的数学基础是离散数学和集合论. 计算机的信息处理是基于元素(样本)的,而不是基于上层抽象概念的. 例如,在图像处理过程中,计算机首先是对像素点进行扫描处理,然后才在各层次逐步对特征信息进行处理,这是一个由细粒度到粗粒度的处理过程. 在机器学习、知识发现和数据挖掘研究中,人们设计的模型方法总是尝试从数据中获取有价值的信息和知识,这也是一个由细粒度

到粗粒度的单向信息变换过程.

计算机从最细粒度的像素开始处理图像.与之相反,人类的视觉认知是从大范围的拓扑结构开始,然后逐步细化的.中国科学院生物物理研究所脑与认知科学国家重点实验室主任陈霖院士等人通过实验发现:人类认知具有"大范围首先"的规律,视觉系统对全局拓扑特性尤为敏感,计算机直接处理最细粒度的图像数据不符合人类的视觉认知规律^[9].在图3所示的图像中,人类视觉认知倾向于先发现大的字母"H"和字母"S",然后才发现大字母中包含的小"S"和小"H".这是一个由粗粒度到细粒度的认知处理过程.可见,人脑的认知处理过程与计算机的信息处理过程有很大差异,二者甚至是相反的.

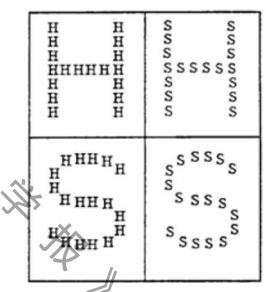


图 3 "大范围首先"的人类视觉认知机制[10]

总的来讲,在当前机器学习研究中,数据空间与知识空间的分离表达,导致数据与知识相互独立,无法建立从数据到知识的映射与推理. 计算机的信息处理过程从细粒度的样本出发,是基于数据空间的表达,是从数据中提取知识;而人类的认知过程是基于知识空间的表达,是进行数据与知识之间的映射与推理. 计算机的信息处理过程和人脑的认知过程并不一致. 这个矛盾要求人工智能研究者进一步弄清人脑的认知方式,要在人脑认知机制的启发下,进行智能计算模型方法研究. 本文结合脑认知科学中的多粒度认知规律,探讨基于多粒度认知的智能计算的未来研究问题. 希望借助人脑的多粒度认知规律,在多粒度认知计算、可解释的认知机器学习、脑认知的智能计算辅助等三个方面开展研究工作,以突破相关研究中的瓶颈问题.

2 多粒度认知计算

近代认知科学的发展,越来越多地得益于脑科学和信息科学.一方面,关于脑和神经系统的实验数据及新发现大量涌现;另一方面,物理的、计算的概念被越来越普遍地应用到认知过程的分析.毫无疑问,这些工作为理解"脑和认知关系"提供了空前的机遇[11].

人们认知世间万物都会使用归类、细分等思想. 人脑在认识处理事物时会首先对其进行抽象,并形成抽象概念^[12].在粒计算的思想中,每个事物都可被看成是一类"粒".不同类的"粒"会形成不同的聚合概念簇,这是粒计算的最本质特点.在认识一类"粒"簇的过程中,人脑会形成不同粒度的概念^[6].比如,"猫"和"狗"这两个概念,在细粒度层次上,二者是不同类的动物.但在"动物"这一更粗粒度层次上,它们同属于"四足哺乳动物",不同于"爬行动物"或"鸟类".从不同的角度观察数据,也可能得到不同的粒簇划分结果.粒计算是人们在人脑的多粒度认知与思维模式的启发下,研究和发展起来的一类智能计算模型理论和方法.

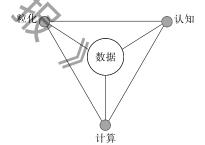
1997年,Zadeh 教授指出粒计算是模糊信息粒化、粗糙集理论和区间计算的超集,是粒数学的子集^[13]. 粒计算是在解决问题的过程中使用"粒度"的所有理论、方法、技术和工具的"标签"^[14]. 粒计算并不是一个具体的模型或方法,而是一种方法论. 在它的"大伞"之下,包含了很多具体的模型理论. 模糊集、粗糙集、商空间和云模型等就是粒计算的四个主要基础理论模型^[15].

本文提出的多粒度认知计算发轫于集合论和不确定性理论.集合论是由 Cantor 于 19 世纪建立的,被认为是现代数学的基础理论^[16]. 1904 年,德国哲学家 Frege 提出了集合边界区域的含糊不确定性问题^[17]. 1965 年,美国加州大学 Berkeley 分校的 Zadeh 院士用隶属度函数来描述这个不确定性,提出了模糊集理论^[18]. 波兰科学院的 Pawlak 院士另辟蹊径,用上近似和下近似这两个精确集合来刻画这个不确定性,并于 1982 年提出了粗糙集理论,建立了知识粒度的概念^[19]. 清华大学李德毅院士综合含糊不确定性与常见的随机不确定性,建立了定性概念与定量描述之间的不确定性转换,于 1995 年提出了云模型^[20]. 通过研究复杂问题的变粒度求解方法,清华大学张钹院士于 1992 年提出了商空间理

论^[21].这四个理论模型构成了多粒度计算的基础理论.著名认知科学家,陈霖院士研究人类知觉信息的基本表达问题,于 1982 年提出了"大范围首先"的视知觉拓扑结构和功能层次理论^[10].融合"大范围首先"的认知机理和多粒度计算机理,王国胤于2017 年提出了数据驱动的多粒度认知计算理论模型,阐释了其中的三方面九个科学问题^[22-23].多粒度认知计算成为了一种新的知识与数据双向驱动的智能计算模型^[5].

人脑认知是一个由粗到细的过程,而计算机信息处理的空间变换过程是一个由细到粗的过程.在人脑认知规律的启发下,多粒度认知计算以粒计算为基础,使粒计算更能反映人脑的问题求解模式.多粒度认知计算从多个粒层协同考察数据中隐含的知识.它的提出是为了融合这两个过程,将这两个看似相反的变换过程统一表达在同一个多粒度空间中.这是挑战,也是相关研究工作发展的必然方向.多粒度认知计算的目的是:用智能计算模型研究认知问题;同时,用人脑的认知规律启发智能计算模型的设计.

为了解决数据与知识的分离表达问题,2017年 王国胤提出了数据驱动的粒认知计算模型(Data-Driven Granular Cognitive Computing, DGCC)^[22]. 图 4 展示了数据驱动的粒认知计算模型的基本思想:"计算"强调数据科学,包括处理大数据的所有高



(a) 数据驱动下的计算、认知与粒化的三角结构关系

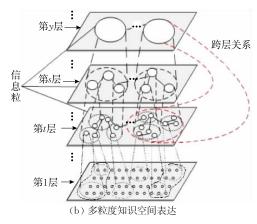


图 4 数据驱动的多粒度认知计算模型[22]

效计算模型和方法;"认知"强调对大数据的智能理解、强调用户与信息系统的智能交互;"粒化"强调多粒度的知识表达与问题求解思维模式.进一步地,对数据驱动的粒认知计算模型的实现,需要解决以下9大具体研究问题:

- (1)数据、信息与知识的多粒度表达模型;
- (2)人脑认知机制与计算机信息处理机制的融合;
- (3) 多粒度知识空间中的不确定性变换机制与 方法;
 - (4) 多粒度联合计算模型与问题求解机制;
 - (5) 多粒度知识空间的动态演化机制与方法;
 - (6) 变粒度渐进式计算机制与方法;
 - (7)智能计算前置机制与方法;
 - (8) 多粒度分布式机器学习模型与方法;
 - (9) 带遗忘的多粒度联想记忆机制.

在数据驱动的粒认知计算模型(DGCC)中,数 据被看作是知识在最细粒度的表示,而概念间的关 系包括同粒层关系和跨粒层关系. 不同粒层的信息 粒可以同时并行地起作用,而不仅仅是串行工作. DGCC 模型将知识与数据进行统一表达,数据处于 DGCC 模型的最底层,被视为是知识在最细粒度上 的表达形式;知识处于模型的最上层,被视为是数据 在粗粒度层次上的表达形式. 数据驱动的多粒度认 知计算模型结合了人类"大范围首先"的认知机制, 即"由粗到细"的认知过程,也结合了机器学习系统 "由细到粗"的信息处理机制. 它进一步阐明了机器 计算与人脑认知之间的联系和区别. 不同粒层之间 或者相同粒层的不同节点之间可以相互关联,也可 以并行工作. DGCC 模型为认知计算的研究提供了 新思路,它为解决"知识与数据分离"的问题奠定了 基础,力图达到"知识与数据统一"的研究目标.

深度神经网络模型是一个典型的多粒度认知计算模型.尽管其"知识黑箱问题"被人们所质疑,但它从多个粒度层次对数据中隐含的特征进行编码,就是多粒度认知计算思想的一种具体体现形式.

近年来,学术界已在 DGCC 模型的 9 大问题研究中进行了一些探索,取得了一定的进展. 在数据、信息与知识的多粒度表达模型研究方面, Clauset 等人^[24]提出了一种从网络数据中推断层次结构的知识表达模型——层次随机图模型(Hierarchical Random Graph, HRG),并将其用于预测网络中缺失的连接. 该模型将网络映射到一个树状的层次结构(树状图)中,树上的每个节点与网络中的节点一

一对应. 该模型赋予树状图的每个节点 r 一个概率 Pr, 如果一对节点的最低共同父节点是 r, 那么就用 独立的概率 Pr, 将这对节点连接起来. 通过在所有可能的树状图空间上进行蒙特卡洛采样, 并利用最大似然算法, 用层次结构模型来拟合现实网络的层次结构, 可以生成若干组新网络[25]. 这些新网络在细节上与原网络不同, 但却与原网络具有相似的层次结构. 它们的统计特性与原网络也非常吻合, 包括度分布、聚类系数和顶点对之间的最短路径长度分布等. 因此, 一个网络的层次结构似乎也能解释各种各样的其他网络特征. 也即作为一种多粒度表达模型, 层次随机图可以表达网络中不同类型的结构特征.

Chen 等人[26] 提出多层次网络表示模型,对网 络中的多粒度结构特征进行表示学习. 模型将较小 的图结构近似地作为节点的初始表示,还包含一个 元策略用于改善表示学习模型的效果. 针对深度神 经网络在计算机视觉任务中容易受到对抗性扰动的 问题, Zhang 等人[27]引入一种多层次特征对齐方 法,逐步提高从正常图像域和对抗性图像域学到的 特征表示之间的相似度,防止对抗性扰动对深度网 络的分层特征的修改. 在基于自动编码器的分类和 决策过程中,为了平衡误分类成本和时间成本, Zhang 等人[28]提出一种序贯三支决策模型,并构建 了一个多粒度的特征结构.模型最终以最低的总成 本达到了最佳的粒度水平. 针对有向图数据, Xu等 人[29]提出了基于非自反关系的粗糙集模型,通过使 有向图与二元关系相互表达,实现了面向有向图的 多粒度表达.

在人脑认知机制与计算机信息处理机制的融合研究方面,王继成^[30]以认知科学、神经科学、脑科学的研究成果为指导,提出一种自适应机器学习方法.该方法多粒度、层次化地模拟了人脑的学习过程.根据该方法开发的知识自动获取系统模拟了心电图专家的认知心理过程.他首先提出了人脑的自适应学习理论,认为人脑在三个粒度层次上(微观、介观和宏观)均有相应的机制来控制和指导整个自适应学习过程.在微观层次上,神经元的状态有正常、临界、兴奋、抑制、病态、死亡等.在介观层次上(功能核团、功能区),神经网络的自适应学习过程表现在:多目标神经网络结构优化以及选择合适的神经网络学习函数.神经网络的学习函数可表示为

$$\delta_{ik} = g(y_{ik}) \times (t_{ik} - y_{ik}) \tag{1}$$

其中, $g(y_{ik})$ 在神经网络的不同阶段,可根据需要取 $\cos(y)$, $\cosh(y)$, $1-y^2$, $\tanh(y)$, $\sin(y)$ 等,以提

高神经网络学习时的收敛速度; t_{ik} 为神经元i 在模式k 时的期望输出; y_{ik} 为神经元i 在输入模式k 时的实际输出. 多目标神经网络结构优化的目标是最小化多目标误差能量函数 E:

$$E=W_1(0.5\sum_p\sum_iO_{pi}-d_{pi})^2+W_2(0.5\sum_j\left(\frac{\partial E_f}{\partial I_j}\right)^2\right)+W_3(\sum_l\sum_k|W_{lk}|)$$
 (2) 其中,在输入模式 p 下, O_{pi} 为输出层第 i 节点的实际输出值, d_{pi} 为输出层第 i 节点的期望输出值, $\frac{\partial E_f}{\partial I_j}$ 是 E_f 关于输入层中第 i 节点的导数, W_{lk} 是第 l 节点与第 k 节点间的联接权重.神经网络在宏观上的自适应学习能力主要表现在:为获得最佳的学习方法和自适应学习能力主要表现在:为获得最佳的学习方法和学习方式 [30].受人类认知智能的启发,Xu 等人 [31] 提出了不确定性概念的内涵和外延之间的双向认知识为对学习方式 [30].受人类认知智能的启发,Xu 等人 [31] 提出了不确定性概念的内涵和外延之间的双向认知,特别的认知变换;利用后向云变换算法实现从概念外延到内涵的认知变换;他们以不确定性概念的认知变换;他们以不确定性概念的认知学习计算过程,如固定样本的模拟实验,模拟了人类的认知过程,如固定样本的模拟实验,模拟了人类的认知过程,如固定样本的认知学习计算过程、人与人之间传递概念的认知理机制,对学习计算过程等。曾毅等人 [32] 认为,从脑信息处理脑启发并借鉴大脑的工作机制,而不是完全地模仿。近年来,新兴的非易失存储器件被用于神经启发式计算,Yu [33] 提出一种器件。电路-算法的编码方法,并将其用于评估非理想器件效应对系统级性能(如学习精度)的影响。

在多粒度知识空间中的不确定性变换机制与方法研究方面,Yang等人[34]从知识距离的角度,分析了分层递阶的多粒度知识空间上的几何特征.针对多粒度知识空间的构建问题,建立了具有强区分能力和强扩展性的知识距离框架.结合人脑的多粒度认知机理,通过研究层次商空间内部的层次性,揭示了层次商空间中任意两个商空间的知识距离等于它们之间的粒度差异.通过知识距离刻画了不同层次商空间结构之间粒度同构、分类同构和细分同构等几种关系.该框架表达了层次商空间中粒度层次具有线性可加性的结构特征,从模糊等价关系的角度实现了不确定性数据的内在层次结构的多粒度建模.为了定量评价目标位置和方向关系这两种不确定性,徐丰等人[35]构建了基于知识含量的近似精度

和粗糙度. Zhi 等人[36] 将属性引起的原子粒作为更复杂的粒构建模块,分别讨论了基于积极属性和消极属性的粒描述. 从积极属性和消极属性的角度对可定义粒进行简洁描述,提升了粒描述的效率.

在多粒度联合计算模型与问题求解机制研究方 面:Li 等人[37]提出分层多粒度深度时空视频表达模 型,用于识别视频中的特定动作.视频中的一个动作 往往跨越不同粒度的层次结构,比如,由细到粗的单 帧、连续帧(运动)、一个短片,再到整个视频.大多数 现有的方法都忽略了视频内容的内在层次结构.而 这个工作将视频进行多粒度分解,按照单帧、连续 帧、片段、视频来分别学习分层的多粒度深度时空视 频表示向量,最终提高了模型在视频动作识别任务 上的性能.模型通过二维(帧和运动流)或三维(片段 和视频流) 卷积神经网络(CNN) 将每个粒度上的内 容建模为一个数据流,为了利用长期的时间动态信 息,该模型在帧、运动和片段流上采用了长短期记忆 (LSTM)网络. 然后在每个信息流上加入了 softmax 层以预测每个组件(如图 5). 通过线性融合所有组 件的预测分数而得到最终的动作识别结果.

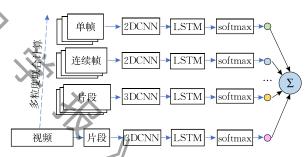


图 5 深度多粒度时空视频表达的动作识别模型[37]

针对图像中人体结构识别问题,Wang等人[38] 讨论了人体层次结构的三种推理过程,即直接推理、 由细到粗推理以及由粗到细推理,然后提出一个组 合式信息融合框架,以条件判断的方式组装来自三 个推理过程的信息,从而提升模型的识别精度. He 等人[39]提出一个基于多粒度图自编码器 (Multi-Granular Graph Auto-Encoder)的主动学习模型,通 过感知拓扑和内容信息,最大限度地减少了标签的 数量,模型对噪声具有良好的鲁棒性. Yu等人[40]提 出了一个基于注意力机制的多粒度双向长短期记忆 模型. 该模型将注意力机制与多粒度词分割机制相 结合,在多粒度层次上协同处理语义信息. 模型在中 文问答系统中得到应用. Xia等人[41]基于粒球理论 发展出了粒球支持向量机 (GBSVM) 和粒球 kNN 分类器 (GBkNN). 在大规模数据处理上,模型具有 明显的效率优势. Liu 等人^[42]提出一种在线社交网络的多粒度集体行为分析方法. 该方法是一种多粒度联合的社交分析模型,它描述了节点层面、邻居层面、社区层面和社会层面的集体行为. 深度学习模型的基础——多层感知机模型^[43]是一个典型的多粒度联合计算模型. 数据的多粒度特征在该模型中被由细到粗地逐层处理,最后得出分类结果. 可以说,近年来出现的许多基于深度学习模型的研究都可被纳入多粒度联合计算模型与问题求解机制的研究领域. 如 GAN^[44]、GCN^[45]、ResNet^[46]等.

在多粒度知识空间的动态演化机制与方法研究 方面:在对数据流的聚类问题中,快速处理不断新增 的数据和对任意形状的类簇进行聚类是两个关键的 挑战. 为了同时应对这两个挑战, Xu 等人[47] 提出了 基于密度峰值聚类(DPClust)算法的胖节点引领树 模型. 密度峰值聚类算法将数据点的密度和数据点 间的距离作为考察对象. 若一个数据点的密度相对 较大、它与高密度点的距离更远,则它被认为是聚类 中心点的概率就越大. 聚类中心选定以后,其他的点 按照其密度高低被划分到不同粒度层级上. 对于一 个处于较低层的数据点,总能找到比它密度略高却 离它更近的点作为其父节点. 当数据空间中的每个 点都完成父节点分配以后,一棵引领树结构即构建 完成. 新传入的数据点可以被快速地融入原引领树 结构中,这使得引领树结构可以实时的快速生长.通 过这种方式,他们实现了无标签高速数据流中演化 概念的识别和实时聚类. Gou 等人[48] 提出在不完全 有序决策系统中的增量式更新近似的方法 CDRSA, 讨论了增量式更新近似的原理,同时研究了属性集 的变化机制和对象子集的联合机制,设计了相应的 增量算法,实验结果表明,所提出的增量算法可以 有效地提高增量式更新近似的性能,最终提高计算 效率.

在变粒度渐进式计算机制与方法研究方面: Zheng 等人^[49]提出了一个渐进式注意力卷积神经网络(Progressive-Attention Convolutional Neural Network, PA-CNN)模型,该模型可逐步定位图像中多个粒度上的识别目标. PA-CNN 包含一个部件提议网络(Part Proposal Network, PPN)和一个部件矫正网络(Part Rectification Network, PRN),它分两步对目标进行定位. 先由部件提议网络生成多个局部注意力图,再由部件矫正网络从每个部件提议中学习目标部件的具体特征,并为 PPN 提供更精确的零件位置. PPN 和 PRN 的这种配合使二者可

以互相优化,最终改善目标定位精度.在模型优化过 程中,较细粒度的卷积网络参数可以从较粗粒度的 网络模型中继承,使模型可以以堆叠的方式学习丰 富的目标层次结构信息(例如,位于鸟类头部的眼睛 和喙). 在细粒度图像识别实验中,这种方式取得了 更精确的识别结果. Duan 等人[50] 提出了一个保留 层内结构和层间结构的网络表示学习方法. 通过网 络粒化构建由细到粗的多粒度网络,再由粗到细地 进行表示学习,让较细粒度的表示可继承较粗粒 度的表示,从而获得了层内结构和层次社区结构的 多粒度表示结果. Yang 等人[51] 构建了序贯三支决 策粗糙模糊集模型,结合代价敏感理论,实现了对 模糊概念的渐进式计算决策,模型能够在约束条件 下获得当前最优知识空间. 为了缓解"维度灾难"问 题,Wang 等人[52]提出了一种基于互信息和谱粒化 (ML-OSMI)的渐进式多标签流特征选择算法. Zhang等人[53]提出动态信息的渐进式三支决策模 型,通过属性值的变化渐进地计算决策模型的阈值, 最终实现对所有对象的分类. Wang 等人[54]提出基 于信息熵的渐进式流特征选择方法,该方法用条件 信息熵(CIE)来指导不确定性的度量. 基于该方法, 他们提出了一个基于粗糙集理论中不确定性度量的 在线流式特征选择框架(OSFS).

在智能计算前置机制与方法研究方面: Xia 等 人[41]提出一种粒球计算机器学习方法,实现了一个 多粒度分类器.通过将粒化操作进行前置,使分类器 模型的输入不再是最细粒度的点,而是粒度大小可 调的通用性特征.模型中使用超球体作为"粒"来表 示该通用特征. 超球体仅仅需要两个量来表征,即中 心和半径. 首先,将数据空间进行粗粒度层次上的划 分,初始粒球即被划分为两个较小的粒球,划分方法 可以使用 k-means 方法,一旦划分完成,新的粒球的 中心可以通过数据点的均值进行计算;粒球半径可 以通过中心到粒球内部各点的距离的平均值进行计 算. 通过不断的粒球分解, 当终止条件达成时, 数据 的分类界面得以自然形成. 在高维数据处理中, 粒球 计算方法可以获得明显的效率提升. Hu 等人[55] 在 网络传播理论的研究中指出,传统的从全局信息出 发进行传播力评估的方式有时不可行,他们首先根 据局部结构信息对节点的传播力进行量化,然后在 更大范围内对节点的传播力进行评估. 他们发现,不 需要全局信息,仅依赖局部结构信息就可以量化网 络节点的传播力.

在多粒度分布式机器学习模型与方法研究方

面:陈剑[56]提出了一种多粒度并行深度学习优化方 法,实现并行化操作不同类型的硬件资源,在任务调 度、负载均衡及通信开销等三方面优化卷积神经网 络的训练过程中,提高了资源的利用效率.首先在分 布式集群中进行粗粒度的并行计算,利用 MapReduce 将训练集拆分成若干个数据块,并将它们分发 到各个任务节点中. 每个任务节点由相同的卷积神 经网络模型构成.其中,Map 任务进行前向传播和 反向传播计算,获得各个权值和偏置的局部变化值. 再利用 Reduce 任务汇总每个权值和偏置的局部变 化值,从而得到最终的全局变化值.采用基于 GPU 的多粒度并行化方案. 粗粒度上的网络密集型计算 被分布式集群分解处理;细粒度上的计算密集型计 算被分配到 GPU 上进行并行计算. 为了高效进行 任务调度,采用任务调度线程池进行任务管理,降低 线程的创建开销和销毁频率. 系统中的任务执行情 况由负载均衡器监控,可对计算节点中剩余的计算 资源和提交请求进行实时优化和决策 为了优化 通信时间开销,用计算时间来掩盖数据传输时间,从 而减小数据传输时间对训练时间的影响. 近年来在 自然语言处理领域应用非常广泛的 transformer 模 型[57],其本质是一个带有自注意力(self-attention) 机制的序列到序列(seq2seq)模型.通过编码器将句 子信息转变为特征信息,再通过解码器将学习到的 特征信息转化为相应的句子. 序列到序列模型的优 点之一在于其可以高效地并行化. Transformer 模 型可被视作是近年来多粒度分布式机器学习模型研 究领域的代表性成果.

3 可解释的认知机器学习

深度学习能够从数据中抽取特征,并建立一个多层次的特征空间结构,这符合多粒度认知计算的思想.但是,对于特征空间中所蕴含的知识,深度学习对它们的提取和建模不够充分.这导致隐含在模型内部的知识对人类而言是无法理解的,模型缺乏可解释性.所以,如何建立深度学习特征空间和知识表达空间的映射,成为目前认知计算领域亟待解决的问题.由于天然的"知识黑箱"属性,深度学习模型生成的决策存在不可靠、不可控、不可信的问题.在具有高可靠性要求的场景中,深度学习模型变得不适用.

研究可解释的认知机器学习,需要从高维海量数据中找出分布在深度结构知识空间中不同层次的

聚合概念及概念之间的复杂关联关系,需要实现形成概念及其相互关联的深度结构知识表达,需要实现从数据到知识的概念间动态演化及关联推理,需要建立深度知识结构表达空间与深度神经网络特征空间的映射.

传统的不确定性计算理论,比如粗糙集、模糊集与云模型等,以刻画物理世界与认知过程的不确定性为基本出发点.云模型将概率统计与模糊数学相结合,建立了数据(物理世界观察)与语义(认知理解)之间的关系,创建了数据与语义之间的相互关联,形成了一套认知物理学研究方法.由此,云模型奠定了研究数据驱动与知识驱动相融合的新的深度学习模型和算法的基础,为深度学习可解释性问题的研究开辟了新的途径.如图 6 所示,本文认为,要实现将不可解释的机器学习转变到可解释的机器学习,需建立从隐变量特征空间到知识空间的映射,让隐变量显身,让数据在概念维度投影.知识空间中的概念通过概念维度嵌入,变成特征空间中的隐变量;反过来,特征空间中的隐变量通过概念维度投影,变成概念空间中的语义概念.

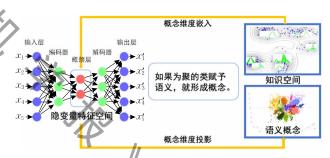


图 6 可解释机器学习特征空间和知识表达空间的映射

在概念嵌入的可解释机器学习研究中,需针对数据与知识分离表达的问题,建立"数据-概念-概念树-概念森林"的知识表达模型,形成概念森林知识空间的动态演化和迁移推理机制.将跨粒度变换算子和贝叶斯云模型学习算法相结合,在概念树上进行多粒度知识更新.原数据在云模型和粗糙集等粒计算工具的帮助下,变换成概念的多粒度表示,再通过粒度变换、层次聚类等操作,提取生成概念树.在数据场的作用下,从概念树开始,逐渐形成概念森林.针对深度特征表达缺乏语义的问题,在传统变分编码器基础上实现概念嵌入,可以建立特征空间和知识空间的映射.将概念的层次性和概念树、数据场的统计学性质相结合,可以建立概念树、数据场的统计学性质相结合,可以建立概念树、数据场的统计学性质相结合,可以建立概念树、数据场和隐变量的联系.针对无语义性导致机器学习缺乏可解释性和鲁棒性的问题,可以建立概念嵌入支持的

融入语义的认知机器学习方法. 利用概念森林的高维语义特征,结合迁移学习机制,可以实现基于概念森林的零/少样本学习、生成对抗学习以及深度强化学习.

在已有的可解释认知机器学习研究中,人们尝 试用人类的先验知识来指导模型的结构设计,或是 尝试对模型的输出结果进行解释. 例如 Jang 等 人[58]提出自适应网络的模糊推理系统,通过设置模 糊的 if-then 规则来完成神经网络的输入与输出之 间的映射. Wang 等人[59]提出三值和多值逻辑神经 网络,模拟人类的逻辑语义规则,解决传统神经网络 无法处理的异或问题. 随着深度学习模型的兴起,近 些年一些研究者使用先验知识指导深度神经网络架 构设计,提出了一系列工作[60-62]. 在对模型的输出特 征进行特征表达的可解释研究方面,一些研究工作 尝试对传统机器学习所获取的隐变量空间进行解 释.比如,Jiang 等人[63]通过在变分自编码器(VAE) 框架内引入生成聚类方法,从而解释隐空间中的特 征表达. Ding 等人[64] 通过引入指导信息,对 VAE 的潜在变量进行解耦,尝试指导潜在变量,来学习 可解释的表达向量,提高隐空间的表达能力.针对图 节点的表示向量的可解释问题, Idahl 等人[65]提出 从图节点表示到概念语义空间的映射方法,以期 在图节点表示中寻找出潜在的可解释语义空间. 为 了在概念系统中进行概念分类和动态增量学习,Shi 等人[66] 提出 CCLM (Concept-Cognitive Learning Model)算法,将所有的样本映射到不同的概念空间 中,并将 CCLM 算法用于决策形式背景下的增量概 念分类. 可见, 在对认知机器学习的过程和结果的可 解释性研究中,多粒度认知的智能计算思想已经取 得一定程度的成功,在未来还将发挥更大的作用.

4 脑认知的智能计算辅助

尽管深度学习模型取得了巨大的成功,但它在模型训练时依赖的样本量巨大、在面对噪声和信息缺失时鲁棒性明显不足;而人脑在小样本泛化性、自适应性、鲁棒性方面却表现出明显的优势.然而,目前人们对人脑的认识还相当粗浅,认知计算的研究急需从脑认知科学中寻求辅助方法和新的借鉴.多粒度认知计算在脑认知的智能计算辅助研究中,同样发挥着重要作用.

人类大脑包含 1000 亿个神经元,且含有 100 万亿以上的突触连接.作为人类的智力中枢,人脑具有

强大的信息处理与决策能力. 脑科学研究人、动物和机器的认知与智能的本质与规律,是一个多学科汇聚的交叉研究领域^[67]. 脑科学研究的核心问题是认知、智能和创造性的本质以及意识的起源:包括较为低级的感觉、知觉等,也包括较为高级的情绪、注意、记忆、决策、语言、学习、思维与意识等各个认知层面的脑功能^[68-69]. 脑科学和类脑智能领域近年来受到广泛关注,在记忆操控、脑联结图谱绘制以及类脑智能等研究中,相关的重大突破多次被列入《科学》(Science)、《自然》(Nature)等杂志的年度十大突破^[70]. 人类用多粒度的结构对人脑的各功能要素之间的关系进行理解分析. 脑认知科学家建立了图7所示的多粒度的理解结构,用它对人脑中神经元细胞及突触构成关系进行描述.

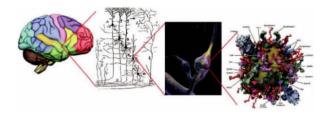


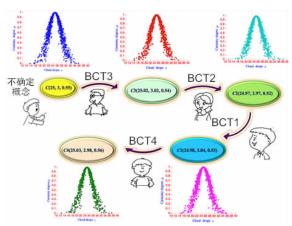
图 7 人脑中神经元细胞及突触构成关系[67]

目前,人们对人脑智能的研究还并不充分,这制 约着人工智能的研究发展. 人们研究脑活动的主要 途径是无损伤地实时测量和研究脑内活动和变化, 主要通过三类方法对大脑活动进行观测. 第一类是 通过大脑结构的断层扫描获得静态图像信息,比如 通过 CT 和磁共振成像. 第二类是通过观测大脑对 信息处理的反应面获得脑的动态信息,比如通过脑 电图(EEG)和脑磁图(MEG)进行观测. 第三类是通 过大脑功能活动时的代谢活动图像获得脑动态信 息,比如功能磁共振成像(fMRI)和正电子发射断层 扫描(PET)[71]. 历史上,人工智能研究在脑认知研 究的启发下取得了几次重要的理论研究突破.例如, 1890年,美国心理学家 James 在其《心理学》一书中 研究了神经元的激活状态,这启发了由 Rosenblatt 在 1958 年提出的感知机模型[72]. 1960 年, Hubel 对 猫视觉感受野的研究,启发了 LeCun 在 1990 年提 出的卷积神经网络模型[73]. 1989 年, Albin 对脑基 底神经节的研究,启发了 Bengio 在 2004 年有关类 脑强化学习的研究[74]. 2002 年, Buxhoeveden 对脑 皮层微柱结构的研究,启发了 2017 年 Hinton 提出 的胶囊网络模型[75].

脑认知研究成果可以启发和指导人工智能领域的研究.反过来,人工智能领域的智能计算模型方法

等研究成果也可以用于辅助开展脑认知的研究.人工智能研究人员,除了借鉴人类智能研究成果来开展研究,也需要将人工智能的研究成果,比如智能计算模型与方法,用于帮助脑科学和认知科学的研究.实际上,智能计算的研究可以为脑功能与脑科学研究提供仿真计算手段,比如提供仿真系统与平台,以验证相关研究的科学假设.认知智能计算的研究成果可在脑认知研究领域产生广泛的应用前景[67].

在实现人脑的概念内涵处理模式与计算机的概 念外延计算模式之间进行认知转换方面,受脑认知 规律启发,基于云模型的双向认知计算,Liu 等人[76] 构建了概念内涵与外延之间的双向认知计算模型. 该模型通过前向云变换,实现从概念的内涵到外延 的映射;反之,通过逆向云变换将概念外延映射到内 涵. 通过双向认知的概念学习实验,模拟实现人类认 知过程中的反复学习、增长学习、概念传递、多粒度 概念学习等过程[77-78]. 这些探索和尝试是在脑认知 科学的启发下,对人类认知过程的智能计算模拟,是 为解决人脑认知过程与机器信息处理过程之间的不 一致问题所做的努力.图8展示了用云模型模拟一 个定性概念被一遍又一遍地传给另一个人的概念传 递(学习)过程,在传递的过程中,概念存在一定的 "漂移"现象[79]. 作为多粒度认知计算的一个内容补 充,近年来出现的多粒度认知概念学习[80],从认知 的角度揭示概念在决策中的作用. 它通过公理化的 方法对概念特征进行描述,研究多粒度概念学习,设 计认知计算系统来寻找复合的认知概念,还利用集 合近似的思想来模拟概念的认知过程.



注: BCT1、BCT2、BCT3和BCT4分別是4种不同的逆向 云变换算法(Backward Cloud Transformation, BCT)^[81]

图 8 概念传递:模拟人类概念传递的认知过程[79]

为了对脑神经元活动进行动态观测,戴琼海院 士团队在多维多尺度高分辨率计算摄像显微仪器 研制和生命科学观测领域开展研究,利用实时超宽 场高分辨率成像显微镜(RUSH, Real-Time, Ultra-Large-Scale, Imaging at High-Resolution Macroscope)对生物动态进行视频帧率下厘米尺度、微米 分辨率的生物动态成像[82]. 该研究对帮助脑科学家 认清脑认知原理具有重要意义. 通过"清醒小鼠在体 全脑皮层成像"等生命科学实验,以宽场高分辨动态 成像为基础,对脑动态网络结构、神经血管耦合机 制、癫痫病理等进行了探索. 大脑皮层在大多数高级 认知功能中起着关键作用,如思考、记忆、计划、 感知、语言和注意力等[83]. 谷歌和哈佛大学联合的 Lichtman 实验室利用从外科手术中获得的人脑组 织对大脑神经连接结构进行研究. 他们通过连续切 片电子显微镜,对一立方毫米的皮层组织进行 4 nm 分辨率的显微成像,并利用自动计算技术进行神经 连接网络的重建和注释,以初步了解人类皮层的突 触网络连接结构[84]. 在这项研究中, 机器学习算法 被应用于从显微图像中多粒度地识别和表征突触、 分类子区域(如轴突、树突或细胞体)、识别特定结构 (如髓磷脂和纤毛)等.借助智能计算研究成果来对 大脑组织的神经连接结构和功能进行研究,对揭示 大脑奥秘具有重要的意义.

作为脑认知的智能计算辅助研究的一个重要应 用,脑联网研究近年来也受到很大关注. 在脑联网的 研究中,多粒度认知计算的思想同样得到广泛应用, 人们在不同粒度层次上构建脑机之间的联系与连 接.比如,从多粒度认知计算的角度看,目前通信网 络中传输的是信息编码数据比特流,这是最细粒度 层次(数据层)的信息传输,即数据通信.信息编码数 据中所包含的语义,是需要信息发送者和接收者各 自进行理解的. 也就是说,数据通信系统中传输的信 息编码数据是不包含对数据的语义解释的. 未来,如 果将信息编码数据进行语义编码,形成带语义的知 识(粗粒度编码),实现在通信网络中传输带语义的 粗粒度层次的知识流(即实现带语义的知识通信), 就有可能突破香农极限的约束. 这样,既可以解决通 信网络带宽容量极限问题,又有助于实现带语义的 知识通信,建立知识通信系统,实现知识层次的粗粒 度互联.

1998年,亚特兰大埃默里大学(Emory University)的研究人员在 Philip Kennedy 和 Roy Bakay的带领下,首次在人体中植入了一种大脑植入物.它能产生足以模拟控制肌肉运动的高质量信号.他们

的病人 Johnny Ray 在 1997 年脑干中风后患上了"闭锁综合症". Ray 在植人物的帮助下,最终学会了控制电脑光标^[85]. 图 9 展示了 Philip Kennedy 教 Johnny Ray 控制光标的场景. 2019 年,浙江大学求是高等研究院"脑机接口"团队通过植入脑电极,帮助一位高位截瘫患者借助"意念"控制机械臂拿起可乐并喝下. 这是中国首例植入式脑机接口临床转化研究^①. 他们通过手术将 Utah 阵列电极的一端植入患者控制右侧上肢运动的运动神经皮层,将电极另一端连接到内置了鲁棒在线解码器和反馈式学习系统的计算机. 该学习系统能够实时记录大脑的神经信号,并将其转化为机械臂的动作指令,最终形成一个"双向互适应的闭环脑机接口系统"^[86].



图 9 Philip Kennedy 教 Johnny Ray 控制光标[85]

以上两个研究都是将脑联网神经信号应用在细粒度上的控制. 在更粗粒度的控制和预测上,也出现了一些代表性的研究. 2020 年,美国 Neurallink 公司展示了一项小猪脑机接口实验. 通过脑机接口设备,可读取出猪脑在受到食物和触碰时所作出的应激反应,以及详细的脑活动状态. 通过进一步分析脑电信号,可以预测小猪的运动步伐和模式[87].

近年来,人们已经逐步实现猴子与猴子之间、人与人之间的意念控制^[88-89].相关研究成果可改善知觉障碍人士的动作和触觉反馈. 2014 年,美国食品药品管理局(FDA)批准了首例受大脑控制的假肢Deka的上市.另外,人们还成功研制了一批模拟人脑的电子器件,比如 SyNAPSE 类脑芯片^[90]、高输入数模拟神经网络^[91]、"神经网格"电路板^[92]、脉冲神经网络芯片^[93]、深度神经网络架构芯片^[94]等.人类对脑功能的认识不断深入,提出了一批脑功能模拟模型,如大鼠躯体感觉皮层神经回路的数字模型^[95]、小型啮齿动物大脑人工模拟^[96]等. 以生物脑智能为基础的人工智能正在逐步实现. 随着脑电信

号输入和输出的实现,未来,通过互联网络将多个生物脑连接起来的"脑联网(Internet-of-Brain, IOB)"将成为现实,更加复杂有效的混合增强智能系统将会诞生(如图 10).

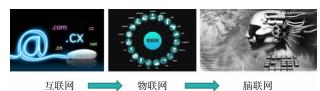


图 10 从互联网到脑联网的发展演变

脑联网系统包括了人脑与人脑、人脑与机器系统、机器系统与机器系统之间的联接,也包括了人脑中嵌入机器系统的混合系统与其他系统之间的联接.在掌握了人脑多粒度功能结构的基础上,结合多粒度认知计算模型,研究建立脑联网的多粒度认知计算结构模型,实现基于脑联网的混合增强智能,也将是未来人工智能研究的关键科学问题.

5 结 语

本文首先指出认知智能研究领域的三个矛盾问 题. 从这三个矛盾问题出发,本文分析指出计算机处 理问题过程跟人脑处理问题过程之间并不一致,这 个不一致是导致大数据计算处理的结果达不到人类 认知要求的原因. 在此基础上,本文探讨了粒计算与 知识发现研究领域的未来发展方向,介绍了相关的 研究工作和研究思路. 比如,数据驱动的多粒度认知 计算模型、概念嵌入的可解释认知机器学习模型、概 念内涵与外延的双向认知计算模型、脑认知的智能 计算辅助研究、脑联网的混合增强智能等.其中,数 据驱动的多粒度认知计算模型是基于多粒度认知的 智能计算的基础理论模型.可解释的认知机器学习、 脑认知的智能计算辅助研究可以在数据驱动的多粒 度认知计算模型的基础上进一步开展,本文的分析 为人工智能与人类(认知)智能交叉融合研究提供了 新的研究思路和启发.

参考文献

[1] Liang Ji-Ye, Qian Yu-Hua, Li De-Yu, Hu Qing-Hua. Theory and method of granular computing for big data mining. SCIENCE CHINA Information Sciences, 2015, 45(11): 1355-1369(in Chinese)

① 人机合——中国首例植入式脑机接口临床转化研究是这 么回事. https://zj. zjol. com. cn/news. html?id=1367352, 2020. 4. 8

- (梁吉业,钱宇华,李德玉,胡清华. 大数据挖掘的粒计算理 论与方法. 中国科学:信息科学,2015,45(11):1355-1369)
- [2] Zadeh L A. Fuzzy sets and information granularity. Advances in Fuzzy Set Theory and Applications, 1979, 11: 3-18
- [3] Zhang Qing-Hua, Wang Guo-Yin, Hu Jun. Multi-Granularity Knowledge Acquisition and Uncertainty Measurement. Beijing: Science Press, 2013(in Chinese)
 (张清华,王国胤,胡军. 多粒度知识获取与不确定性度量. 北京:科学出版社,2013)
- [4] Xu Ji, Wang Guo-Yin, Yu Hong. Review of big data processing based on granular computing. Chinese Journal of Computers, 2015, 38(8): 1497-1517(in Chinese)
 (徐计,王国胤,于洪. 基于粒计算的大数据处理. 计算机学报,2015,38(8): 1497-1517)
- [5] Wang Guo-Yin, Yu Hong. Multi-granularity cognitive computing—A new model for intelligent computing of big data. Frontiers of Data and Computing Development, 2019, 1(2): 75-85(in Chinese)
 (王国胤,于洪. 多粒度认知计算———种大数据智能计算的新模型. 数据与计算发展前沿, 2019, 1(2): 75-85)
- [6] Yao Y, Zhong N. Granular Computing//Wah B W ed. Wiley Encyclopedia of Computer Science and Engineering. Canada: Wiley Press, 2007: 1-7
- [7] Bose A J, Aarabi P. Adversarial attacks on face defectors using neural net based constrained optimization//Proceedings of the 2018 IEEE 20th International Workshop on Multimedia Signal Processing. Vancouver, Canada, 2018; 31-36
- [8] Geirhos R, Rubisch P, Michaelis C, et al. ImageNet-trained CNNs are biased towards texture; increasing shape bias improves accuracy and robustness//Proceedings of the International Conference on Learning Representations. Vancouver, Canada, 2018: 201-221
- [9] Chen L. Topological structure in visual perception. Science, 1982, 218(4573); 699-700
- [10] Han Shi-Hui, Chen Lin. The relationship between the global nature and the local nature-global precedence. Dynamics of Psychology, 1996, 4(1): 36-41(in Chinese)
 (韩世辉,陈霖. 整体性质和局部性质的关系——大范围优先性,心理学动态,1996,4(1): 36-41)
- [11] Chen Lin. The three cornerstones of cognitive science. Science Foundation in China, 2017, 31(3): 209-210(in Chinese) (陈霖. 认知科学的三大基石. 中国科学基金, 2017, 31(3): 209-210)
- [12] Pulvermüller F. How neurons make meaning: Brain mechanisms for embodied and abstract-symbolic semantics. Trends in Cognitive Sciences, 2013, 17(9): 458-470
- Zadeh L A. Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic. Fuzzy Sets and Systems, 1997, 90(2): 111-127
- [14] Yao Y Y. Granular computing: Basic issues and possible solutions//Proceedings of the 5th Joint Conference on Information Sciences. NJ, USA, 2000, 1: 186-189

- [15] Yao Y. Perspectives of granular computing//Proceedings of the 2005 IEEE International Conference on Granular Computing. Beijing, China, 2005, 1: 85-90
- [16] Edwards H M. Kronecker's views on the foundations of mathematics//Proceedings of the Symposium on the History of Modern Mathematics. New York, USA, 1989: 65-77
- [17] Grattan-Guinness I. The Search for Mathematical Roots, 1870-1940: Logics, Set Theories and the Foundations of Mathematics from Cantor Through Russell to Gödel. New Jersey, USA: Princeton University Press, 2000
- [18] Zadeh L A. Fuzzy sets. Information and Control, 1965, 8(3): 338-353
- [19] Palawk Z. Rough sets. International Journal of Computer and Information Science, 1982, 11: 341-356
- [20] Li De-Yi, Meng Hai-Jun, Shi Xue-Mei. Membership clouds and membership cloud generators. Journal of Computer Research and Development, 1995, 32(6): 15-20(in Chinese) (李德毅, 孟海军, 史雪梅. 隶属云和隶属云发生器. 计算机 研究与发展, 1995, 32(6): 15-20)
- [21] Zhang B, Zhang L. Theory and Applications of Problem Solving. New York, USA: Elsevier Science Inc, 1992
- [22] Wang G. DGCC: Data-driven granular cognitive computing. Granular Computing, 2017, 2(4): 343-355
- [23] Wang G. Data-driven granular cognitive computing//Proceedings of the International Joint Conference on Rough Sets. Olsztyn, Poland, 2017: 13-24
- [24] Clauset A, Moore C, Newman M E J. Hierarchical structure and the prediction of missing links in networks. Nature, 2008, 453: 98
- [25] Fountain F. Lapata M. Taxonomy induction using hierarchical random graphs//Proceedings of the 2012 Conference of the North American Chapter of the Association for Computational Linguistics: Human/Language Technologies. Montreal, Canada, 2012; 466-476
- [26] Chen H, Perozzi B, Hu Y, Skiena S. Harp: Hierarchical representation learning for networks//Proceedings of the AAAI Conference on Artificial Intelligence. New Orleans, USA, 2018: 2127-2134
- [27] Zhang X, Wang J, Wang T, et al. Robust feature learning for adversarial defense via hierarchical feature alignment. Information Sciences, 2021, 560; 256-270
- [28] Zhang L, Li H, Zhou X, Huang B. Sequential three-way decision based on multi-granular autoencoder features.

 Information Sciences, 2020, 507: 630-643
- [29] Xu T, Wang G. Finding strongly connected components of simple digraphs based on generalized rough sets theory. Knowledge-Based Systems, 2018, 149: 88-98
- [30] Wang Ji-Cheng. Research on the adaptive machine learning algorithms based on cognitive simulation. Journal of Software, 2001, 12(8): 1205-1211(in Chinese) (王继成. 基于认知模拟的自适应机器学习算法研究. 软件学报, 2001, 12(8): 1205-1211)

- [31] Xu C, Wang G. Bidirectional cognitive computing model for uncertain concepts. Cognitive Computation, 2019, 11(5): 613-629
- [32] Zeng Yi, Liu Cheng-Lin, Tan Tie-Niu, et al. Review and prospects of brain-like intelligence research. Chinese Journal of Computers, 2016, 39(1): 212-222(in Chinese) (曾毅,刘成林,谭铁牛等. 类脑智能研究的回顾与展望. 计算机学报, 2016, 39(1): 212-222)
- [33] Yu S. Neuro-inspired computing with emerging nonvolatile memorys. Proceedings of the IEEE, 2018, 106(2): 260-285
- [34] Yang J, Wang G, Zhang Q. Knowledge distance measure in multigranulation spaces of fuzzy equivalence relations.

 Information Sciences, 2018, 448-449: 18-35
- [35] Xu Feng, Niu Ji-Qiang, Li Zhuo-Fan. A quantitative evaluation model for uncertainty of multi-granularity spatial orientation relations based on coarse sets. Journal of Wuhan University: Information Science Edition, 2017, 42(6): 756-761, 781(in Chinese)
 (徐丰,牛继强,李卓凡. 基于粗集的多粒度空间方向关系不确定性定量评价模型. 武汉大学学报: 信息科学版, 2017, 42(6):756-761, 781)
- Zhi H, Li J. Granule description based on positive and negative attributes. Granular Computing, 2019, 4(3): 337-350
- [37] Li Q, Qiu Z, Yao T, et al. Action recognition by learning deep multi-granular spatio-temporal video representation// Proceedings of the 2016 ACM International Conference on Multimedia Retrieval. New York, USA, 2016: 159-166
- [38] Wang W, Zhou T, Qi S, et al. Hierarchical human semantic parsing with comprehensive part-relation modeling. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, (1): 1
- [39] He Y, Yuan X, Tzeng N-F, Wu X. Active learning with multi-granular graph auto-encoder//Proceedings of the 2020 IEEE International Conference on Data Mining (ICDM). Sorrento, Italy, 2020: 1058-1063
- [40] Yu X, Feng W, Wang H, et al. An attention mechanism and multi-granularity-based Bi-LSTM model for Chinese Q&A system. Soft Computing, 2020, 24(8): 5831-5845
- [41] Xia S, Liu Y, Ding X, et al. Granular ball computing classifiers for efficient, scalable and robust learning. Information Sciences, 2019, 483; 136-152
- [42] Liu Q, Liu Q, Yang L, Wang G. A multi-granularity collective behavior analysis approach for online social networks. Granular Computing, 2018, 3(4): 333-343
- [43] White B W, Rosenblatt F. Principles of neurodynamics: Perceptrons and the theory of brain mechanisms. The American Journal of Psychology, 1963, 76(4): 705
- [44] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks. Communications of the ACM, 2020, 63(11): 139-144
- [45] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks. arXiv preprint arXiv: 1609. 02907, 2016

- [46] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 770-778
- [47] Xu J, Wang G, Li T, et al. Fat node leading tree for data stream clustering with density peaks. Knowledge-Based Systems, 2017, 120: 99-117
- [48] Gou G, Wang G. Incremental approximation computation in incomplete ordered decision systems. International Journal of Computational Intelligence Systems, 2017, 10(1): 540-554
- [49] Zheng H, Fu J, Zha Z-J, et al. Learning rich part hierarchies with progressive attention networks for fine-grained image recognition. IEEE Transactions on Image Processing, 2020, 29: 476-488
- [50] Duan Z, Sun X, Zhao S, et al. Hierarchical community structure preserving approach for network embedding.

 Information Sciences, 2021, 546; 1084-1096
- [51] Yang J, Wang G, Zhang Q, et al. Optimal granularity selection based on cost-sensitive sequential three-way decisions with rough fuzzy sets. Knowledge-Based Systems, 2019, 163: 131-144
- [52] Wang H, Yu D, Li Y, et al. Multi-label online streaming feature selection based on spectral granulation and mutual information//Proceedings of the International Joint Conference on Rough Sets. Quy Nhon, Vietnam, 2018; 215-228
- [53] Zhang Q, Lv G, Chen Y, et al. A dynamic three-way decision model based on the updating of attribute values. Knowledge-Based Systems, 2018, 142: 71-84
- [54] Wang H. Wang G, Zeng X, et al. Online streaming feature selection based on conditional information entropy//Proceedings of the 2017 IEEE International Conference on Big Knowledge (ICBK). Hefei, China, 2017; 230-235
- [55] Hu Y, Ji S, Jin Y, et al. Local structure can identify and quantify influential global spreaders in large scale social networks. Proceedings of the National Academy of Sciences, 2018, 115(29): 7468-7472
- [56] Chen Jian. Research on Multi-Granularity Parallel Optimization of Convolutional Neural Networks [Ph. D. dissertation]. Wuhan University, Wuhan, 2017(in Chinese) (陈剑. 卷积神经网络的多粒度并行优化研究[博士学位论文]. 武汉大学,武汉,2017)
- [57] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need//Proceedings of the 31st Conference on Neural Information Processing Systems. Long Beach, USA, 2017: 1-11
- [58] Jang J-S. ANFIS: Adaptive-network-based fuzzy inference system. IEEE Transactions on Systems, Man, and Cybernetics, 1993, 23(3): 665-685
- [59] Wang G, Shi H. TMLNN: Triple-valued or multiple-valued logic neural network. IEEE Transactions on Neural Networks, 1998, 9(6): 1099-1117
- [60] Zhang J, Ghanem B. ISTA-Net: Interpretable optimization-

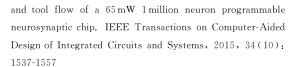
- inspired deep network for image compressive sensing// Proceedings of the 2018 IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA, 2018: 1828-1837
- [61] Yang Y, Sun J, Li H, et al. ADMM-CSNet: A deep learning approach for image compressive sensing. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(3): 521-538
- [62] Yang Y, Sun J, Li H, et al. Deep ADMM-Net for compressive sensing MRI//Advances in Neural Information Processing Systems 29: Annual Conference on Neural Information Processing Systems. Barcelona, Spain, 2016: 10-18
- [63] Jiang Z, Zheng Y, Tan H, et al. Variational deep embedding: An unsupervised and generative approach to clustering// Proceedings of the 26th International Joint Conference on Artificial Intelligence. Melbourne, Australia, 2017: 1965-1972
- [64] Ding Z, Xu Y, Xu W, et al. Guided variational autoencoder for disentanglement learning//Proceedings of the 2020 IEEE Conference on Computer Vision and Pattern Recognition. Seattle, USA, 2020: 7917-7926
- [65] Idahl M, Khosla M, Anand A. Finding interpretable concept spaces in node embeddings using knowledge bases//Proceedings of the Machine Learning and Knowledge Discovery in Databases-International Workshops of ECML PKDD. Würzburg, Germany, 2019, 1167; 229-240
- [66] Shi Y, Mi Y, Li J, et al. Concept-cognitive learning model for incremental concept learning. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 51(2): 809-821
- [67] Wang Li-Wei, Xu Li, Xu Ping, et al. Brain science and brain-like intelligence research in Chinese Academy of Sciences. Bulletin of the Chinese Academy of Sciences, 2016, 31(7): 747-754(in Chinese)

 (王力为,许丽,徐萍等. 面向未来的中国科学院脑科学与类脑智能研究——强化基础研究,推进深度融合. 中国科学院院刊,2016,31(7): 747-754)
- [68] Abbott A. Neuroscience: Solving the brain. Nature, 2013, 499(7458): 272-274
- [69] Wilson R A, Keil F C. The MIT Encyclopedia of the Cognitive Sciences. Boston, USA: MIT press, 2001
- [70] Han Xue, Ruan Mei-Hua, Wang Hui-Yuan, et al. Neuroscience and brain-inspired artificial intelligence: Challenges and opportunities. Chinese Bulletin of Life Sciences, 2016, 28(11): 1295-1307(in Chinese)
 (韩雪,阮梅花,王慧媛等.神经科学和类脑人工智能发展: 机遇与挑战.生命科学,2016,28(11): 1295-1307)
- Zhang Fang-Feng, Zheng Zhi-Gang. Research on complex brain networks: Status and challenges. Journal of Shanghai University of Technology, 2012, 34(2): 138-153(in Chinese) (张方风,郑志刚. 复杂脑网络研究: 现状与挑战. 上海理工大学学报, 2012, 34(2): 138-153)

- [72] Rosenblatt F. The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review, 1958, 65(6): 386
- [73] LeCun Y, Boser B, Denker J, et al. Handwritten digit recognition with a back-propagation network. Advances in Neural Information Processing Systems, 1989, 2: 396-404
- [74] Rivest F, Bengio Y, Kalaska J. Brain inspired reinforcement learning//Advances in Neural Information Processing Systems. Vancouver, Canada, 2005; 1129-1136
- [75] Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules. arXiv preprint arXiv:1710.09829, 2017
- [76] Liu Y, Li D, He W, et al. Granular computing based on Gaussian cloud transformation. Fundamenta Informaticae, 2013, 127(1-4): 385-398
- [77] Li W, Zhao J, Xiao B. Multimodal medical image fusion by cloud model theory. Signal, Image and Video Processing, 2018, 12(3): 437-444
- [78] Qin K, Xu K, Du Y, et al. An image segmentation approach based on histogram analysis utilizing cloud model//Proceedings of the 7th International Conference on Fuzzy Systems and Knowledge Discovery. Yantai, China, 2010, 2: 524-528
- [79] Xu Chang-Lin, Wang Guo-Yin. Excursive measurement and analysis of normal cloud concept. Computer Science, 2014, 41(7): 9-14(in Chinese)

 (许昌林,王国胤. 正态云概念的漂移性度量及分析. 计算机科学, 2014, 41(7): 9-14)
- [80] Li J, Huang C, Qi J, et al. Three-way cognitive concept learning via multi-granularity. Information Sciences, 2017, 378: 244-263
- [81] Wang G, Xu C, Li D. Generic normal cloud model. Information Sciences, 2014, 280: 1-15
- [82] Fan J, Suo J, Wu J, et al. Video-rate imaging of biological dynamics at centimetre scale and micrometre resolution. Nature Photonics, 2019, 13(11): 809-816
- [83] Fuster J M. The cognit: A network model of cortical representation. International Journal of Psychophysiology, 2006, 60(2): 125-132
- [84] Shapson-Coe A, Januszewski M, Berger D R, et al. A connectomic study of a petascale fragment of human cerebral cortex. bioRxiv Preprint, 2021
- [85] Kennedy P R, Bakay R A. Restoration of neural output from a paralyzed patient by a direct brain connection. Neuroreport, 1998, 9(8): 1707-1711
- [86] Zhao Q, Shi X, Zhu X, et al. Large field of view correction by using conjugate adaptive optics with multiple guide stars. Journal of Biophotonics, 2019, 12(2): e201800225
- [87] Fiani B, Reardon T, Ayres B, et al. An examination of prospective uses and future directions of neuralink: The brain-machine interface. Cureus, 2021, 13(3): 1-4
- [88] Shanechi M M, Hu R C, Williams Z M. A cortical-spinal prosthesis for targeted limb movement in paralysed primate avatars. Nature Communications, 2014, 5(1): 1-9

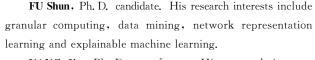
- [89] Rao R P, Stocco A, Bryan M, et al. A direct brain-to-brain interface in humans. PLoS One, 2014, 9(11): e111332
- [90] Merolla P A, Arthur J V, Alvarez-Icaza R, et al. A million spiking-neuron integrated circuit with a scalable communication network and interface. Science, 2014, 345(6197): 668-673
- [91] Aamir S A, Müller P, Hartel A, et al. A highly tunable 65-nm CMOS LIF neuron for a large scale neuromorphic system//Proceedings of the 42nd European Solid-State Circuits Conference. Lausanne, Switzerland, 2016; 71-74
- [92] Benjamin B V, Gao P, McQuinn E, et al. Neurogrid: A mixed-analog-digital multichip system for large-scale neural simulations. Proceedings of the IEEE, 2014, 102(5): 699-716
- [93] Akopyan F, Sawada J, Cassidy A, et al. TrueNorth: Design



- [94] Prezioso M, Merrikh-Bayat F, Hoskins B, et al. Training and operation of an integrated neuromorphic network based on metal-oxide memristors. Nature, 2015, 521(7550): 61-64
- [95] Markram H, Muller E, Ramaswamy S, et al. Reconstruction and simulation of neocortical microcircuitry. Cell, 2015, 163 (2): 456-492
- [96] DeBole M V, Taba B, Amir A, et al. TrueNorth: Accelerating from zero to 64 million neurons in 10 years. Computer, 2019, 52(5): 20-29



WANG Guo-Yin, Ph. D., professor, Ph. D. supervisor. His research interests include granular computing, cognitive computation, intelligent information processing, and big data intelligence.



YANG Jie, Ph. D., professor. His research interests include rough set, granular computing, and data mining.

GUO Yi-Ke, Ph. D., professor, Ph. D. supervisor. His research interests include data mining, representation learning, and explainable machine learning.

Background

Granular computing (GrC) and knowledge discovery (KD) were introduced in 1979 and 1989 respectively. Granular computing simulates the multi-granular cognition mechanism of human brains and has become a powerful tool for approximating solutions to complex problems at multiple levels and scales. Knowledge discovery is the extraction of valid and novel potentially useful knowledge from raw data. In this paper, the researches of multi-granularity cognition based intelligent computing are reviewed, and its future research trends are discussed. Several paradoxical phenomena and problems happened in researches are presented, such as the information processing process of computers is inconsistent with the cognition process of human brains, and the unex-

plainability problem of deep learning. Based on analysis of these problems, three frontier research directions in this field are proposed, that is, multi-granularity cognitive computing, interpretable cognitive machine learning and intelligent computation assisted brain cognition. Some issues to be further investigated in these directions are explored.

This work is partially supported by the National Natural Science Foundation of China (Nos. 61936001, 61772096, and 62066049), the Natural Science Foundation of Chongqing (Nos. cstc2021ycjh-bgzxm0013 and cstc2019jcyj-cxttX0002), the Key Cooperation Project of Chongqing Municipal Education Commission (No. HZ2021008).