

# 探索基于大规模语义网络 的认知算法

国内外人工智能跟帖留言  
(共86条跟帖)

## 点评：探索基于大规模语义网络的认知算法

陆首群

2022 年 4 月 8 日

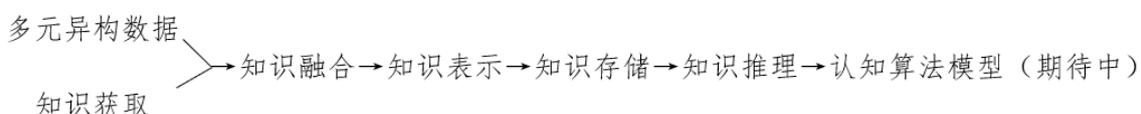
研发基于大规模语义网络（知识图谱）的认知算法尚在探索中。

由于目前大规模语义网络还存在短板：

(1) 未掌握知识推理逻辑，尚不能建立可理解、可解释的语义网络；

(2) 未能解决常识（和动机、决策）中的难点。

现将目前构建的知识图谱技术链简述如下：



很多人采用这条知识图谱技术链探求认知算法，但均未如愿以偿。因为目前构建的知识图谱尚不能起到两端（机器端与类脑智能体端）“对话”的作用。

类脑智能体并不识别机器语言（数据驱动或数据+知识两轮驱动），而机器也不识别类脑智能体语言（人类自然语言）；人们期望通过知识图谱中的“知识推理”环节，改变机器语言，赋予类脑智能体能够识别、理解，从而实现认知智能。

按传统思维、通用计算技术构建的知识图谱技术链存在着机制性

的缺陷，在其知识推理阶段，缺乏知识逻辑推理内涵（或引擎），在这里除了知识，还要有逻辑，而逻辑是核心！而逻辑推理机制是类脑神经拟态网络的主要特征。

这时要求知识图谱技术链向基于异步脉冲神经网络的神经拟态计算系统转轨，颠覆冯·诺依曼通用计算架构：从建立神经拟态芯片开始，在芯片集成的基础上，生成神经网络，赋予改造后的知识逻辑推理环节以“逻辑推理”机制支持其运转，建立神经拟态计算架构，最终赋能实现认知智能系统。

为了解决大规模语义网络中常识等短板问题，有人建议建设常识库。如 OpenAI 前后建立 GPT-1、2、3 预训练通用语言模型（含常识库），其中 GPT-3 巨型预训练通用语言模型具有 1750 亿参数，国内鹏城实验室建立“鹏程·盘古 a”中文预训练语言模型（含常识库），具有 2000 亿参数。

IBM 沃森健康（Watson Health）在研发医疗人工智能时曾遇到缺乏常识带来的困扰，他们提出“具人（embodiment）”概念，即要求从事研发工作的科学家与临床医生加强沟通，取得共识，统一行动，以弥补科学家常识之不足。但实际效果似乎不太理想。

去年 9 月 13 日我与语音大师 Daniel Povey 会晤，顺便讨论大规模语义网络与认知智能问题。

我提出：目前大规模语义网络（知识图谱）尚无力支持实现认知智

能，在目前全球的语义网络中缺乏逻辑推理，常识问题也是其短板，因此难以支持认知智能的实现，离解决还差最后一公里！Daniel 认为：恐怕不止最后一公里，离解决目标要走的路还很遥远！

# 国内外基于知识图谱的认知算法人工智能跟帖

(共 86 条)

1-30, 《IEEE Spectrum》2019 年 4 月号, 有人发表一篇质疑 IBM “沃森(Watson)健康” 在医疗人工智能方面研发的文章, 推荐大家一读并思考。

2-44, 我想谈谈人工智能认知阶段, 进入认知阶段, 类脑认知计算将具有人类自主思维、意念、理解、思考、创意和灵感方面的特征。

在人工智能感知阶段, 单纯依靠数据驱动的深度学习算法技术, 对于图形、图像、语音的识别, 做的是比对; 在人工智能的认知阶段, 有赖于与数学、脑科学等结合, 以实现底层理论的突破, 需要知识驱动和数据驱动相结合, 需要建立大规模的知识库, 研究知识表示, 以及如何把知识、推理和数据结合起来。

IBM Watson 通过 10 多年医疗人工智能的研究, 开始把知识驱动模式和数据驱动模式开发出来、结合起来, 开辟认知新阶段。

IBM 工程师说: 认知计算的目标是构建能学习并自然地与人交流的系统。Watson 通过 Jeopardy 比赛成功击败世界级对手, 就是这样做的, 这也证明了认知计算的能力。

3-60, 以知识驱动的认知计算同样含有知识工程, 上世纪 80 年代中期国内提出的知识工程是基于知识表达进行逻辑推理。新一代的知识工程关注于具身 (embodiment) 的人工智能, 即与身体场景有直接关系, 具身有一种思想可能改变规则使用权重, 可能形成人际间的共识, 这在医学中至关重要, 要让患者参与决策 (在医疗中如果患者不配合将十分麻烦)。两者知识工程不同, 在于具身的认

识，前者脱离人的认知环境，过去是从已知数据中获得已产生的规则，现在的知识工程从新产生的数据中挖掘、调整规则，以知识为基础的规则是创造性、跳跃式的。

**4-72**，IBM Watson 研发的以知识驱动的人工智能医疗实践，10 年来其效果在美国还存在很大争议（突出一点是人工智能理论和临床医生在处置上尚缺乏共识）。

**5-76**，计算智能、感知智能、认知智能、决策智能，反映机器的智能化水平的不同发展阶段。以基于数据驱动的深度学习为代表的感知智能水平，随着大数据红利的消失日益接近天花板。所谓认知智能指让机器能够像人一样思考，具备理解、解释、规划、推理、演绎、归纳的能力（达到人脑思维的高级境界），从感知智能到认知智能是人工智能发展中一次颠覆性的飞跃。认知智能的实现需要知识驱动或数据、知识双驱动。

**6-78**，近来我与 IBM “沃森 (Watson) 健康” 一位人工智能资深专家讨论他们在美国当地（准确地说是 IBM 与合作方安德森癌症中心）历时 7 年（2011-2017）的医疗效果。

当我谈到感知和认知时，令我惊讶的是那位专家说感知与认知没有高低之分，在不同场景应该有不同判断，做出判断时要小心一点！我当时对他说，你们 IBM 自己说过，从感知智能到认知智能是人工智能发展中一次颠覆性的飞跃，前者完全是数据驱动后者是知识驱动（或数据、知识双驱动），怎么能说感知与认知没有高低之分？！

从我们讨论 IBM “沃森健康” 以前 7 年人工智能的医疗实践来看，IBM 主要采用

的是感知的数据驱动的深度学习模式，至于认知的知识驱动模式尚处于开研前的准备阶段，未能付诸于试验实践！所以如果针对不同场景的需求采用不同人工智能模型以谋求最佳效果来看，确实感知和认知没有高低之分。

7-79，在“IEEESpectrum”2019年4月号上刊登一篇向IBM“沃森健康”在医疗人工智能实践方面提出质疑的文章，综合IBM、医疗合作方和第三方评论的意见：IBM研发布局，自2011年至2017年，与安德森癌症中心合作，研究25个课题，在癌症治疗建议方面有635个案例，尝试用基于大数据和深度学习的感知技术与医疗行业融合应用，最终未产生成功的建议和商用产品，未达到IBM原来设定的目标，2016年合作方在花掉6200万美元后终止与IBM沃森健康的合作。

究其原因，（1），数据资源十分有限。癌症病例数量有限，样本数据不足，可用于深度学习模型训练的成功案例更少。（2），沃森与合作医疗机构之间沟通不好。沃森的治疗建议与医院的临床实践差距很大（第三方认为IBM纵使有好的技术，但美国医疗行业偏于保守，沟通不好难于成功）。（3），过于迷信深度学习。深度学习是实现人工智能的路径之一，但也是有缺陷的：深度学习本质上是一项暗箱技术，其训练过程具有难以解释、不可控的特点，人工智能不适应应用复杂度、需求量的快速增长，超出人们理解和控制范围，过度依赖数据，采集数据在量和质上不满足需要，数据建模与真实生活间有差距，深度学习理论与现实医疗护理不匹配，深度学习无法独立地从医学文献最新进展及患者档案中提取有意义的信息。（4）IBM沃森健康在国外（韩国、泰国、智利）的医疗实践效果较好、成功率较高，受到欢迎。

**8-84**, 从 2012 年谷歌提出知识图谱以来, 知识图谱技术发展很快。所谓知识图谱是一种大规模语义网络。知识图谱作为一种技术体系, 指大数据时代知识工程的一系列代表性技术进展的总和。上世纪七、八十年代的知识表示与今天的知识图谱有着本质差别, 其显著的差别在于对一种语义网络在规模上的差别。知识图谱对机器实现人工智能十分重要, 我们分析知识图谱可实现机器认知智能的两个核心能力: “理解”和“解释”, 机器“理解”数据是建立起从数据到知识库中的知识要素(包括实体、概念和关系)映射的一个过程。另外, 有了知识图谱, 机器完全可以重现这种“理解”与“解释”过程, 并不难完成上述过程的数学建模。知识图谱让可解释人工智能成为可能, 并体现在知识引导下将成为解决机器人人工智能问题的主要方式。

**9-89**, 人类处理知识的能力更强, 计算机处理数据的能力更强, 发展人工智能由感知阶段数据驱动的深度学习算法跳到认知阶段的知识 and 数据双驱动的认知学习算法。

**10-91**, IBM 沃森(Watson)回答质疑, Watson 人工智能对医疗帮助是否有限? MD 安德森肿瘤中心终止了与 IBM 的合作, 引发了上述质疑(见今年 2 月 21 日美国《科学》杂志报导)。IBM 回应称, 项目已取得初步成效。

**11-92**, 美国健康界获悉了在 MD 安德森肿瘤中心终止与 IBM 合作后引发媒体对 IBM 质疑一事, IBM 发表的官方声明, 声明称, “质疑”报告所描述的结果是基于采购活动文件和(医院)工作人员的相关说辞。不应被视为对 Watson 项目现阶段

系统的科学基础或功能方面的评价”。 “Watson 在与世界上多个医疗机构合作的项目均显示出有效性”。

**12-93**, MD 安德森肿瘤中心与 IBM Watson 深度学习大数据项目始于 2013 年, 主题是“大数据人工智能应用将加速对癌症疾病的认知(?) 和完善癌症临床治疗”。

**13-94**, IBM (官方) 声明 (续): “美国 MD 安德森肿瘤中心的肿瘤学家和研究员评价 Watson 所给的建议治疗方案有 90% 的准确率。这种高准确率能帮助肿瘤科医学确保他们在做癌症诊疗与诊断时不会错失任何数据” (获该中心医生对 Watson 能力的认可)。

**14-95**, IBM(官方)声明(续): “IBM Watson 与世界上 10 多个医疗机构合作进行研究显示, Watson 能协助医生更有效率制定医疗决策并进而影响患者”。

**15-98**, 我也来谈谈知识工程发表浅见。有人说知识工程是基于知识表达进行逻辑推理。我认为上世纪七、八十年代提出的旧的知识工程, 脱离人的认知环境, 从已知数据中获得已产生的规则, 如今新提出的知识工程, 与身体场景有直接关系, 从新产生数据中挖掘、调整做规则, 新旧知识工程的差别也表现在旧的知识表示与新的知识图谱语义网络在规模上的差别。

**16-133**, 科学家实现生物间记忆移植。10 月, 《科学》杂志刊登得克萨斯大学西南医学中心科学家的研究成果, 通过使用光遗传学技术控制幼年斑胸草雀大脑与听觉经验学习相关的区域, 选择性地激活大脑中某些特定的神经元回

路，向幼年斑胸草雀的脑中有效地植入记忆（曲调），成功在无教导的情况下让幼鸟学会鸣唱之前未听过的简单歌曲。强大的记忆力是学习知识的捷径，人类也在对快速获取记忆从而获得知识、提高智能水平进行着不断的追求和探索，记忆移植无疑是一种最为快捷的途径。这一成果不仅为老年痴呆症、自闭症等疾病的彻底治愈带来了曙光，也使得机器人学习人类常识性知识成为可能。虽然距离实现真正的人类记忆移植还有很长的路要走，而且还存在这样那样的争议，但不论怎样，现阶段能够取得这样的成果都足以令人期待更加美好的未来。

#### 17-148, (5) 吴恩达团队盘点 2019 NLP 飞跃，语言模型变得精通语言：

早期由 Word2Vec 和 GloVe embeddings 支持的语言模型产生了令人困惑的聊天机器人、具有中学阅读理解能力的语法工具，以及勉强能看的翻译。但最新一代的语言模型变得如此之好，甚至有人认为它们很危险。

2019 年自然语言处理领域发生了什么呢？一个新的语言模型生成了新闻文章，读者评价其和《纽约时报》一样可信；同样的语言模型还为《纽约客》的一篇文章做出了贡献。令人欣慰的是，这些模型没有像人们担忧的那样散布大量虚假信息。2019 年，研究人员在让机器理解自然语言方面取得了飞跃。通过对巨大的、未标记的数据集进行预训练，新模型通常可以熟练掌握自然语言。然后，他们通过在专门语料库上进行微调来掌握给定的任务或主题。

早期的模型如 ULFiT(由 Jeremy Howard 和 Sebastian Ruder 提出)和 ELMo(来自艾伦人工智能研究所和华盛顿大学)展示了预训练潜力，而谷歌的 BERT 是这种方法的第一个突破性的成功。BERT 于 2018 年底发布，在 GLUE 阅读理解基准测试

中得分之高，以至于测试的组织者首次将模型的表现与人类的 baseline 分数进行了比较。今年 6 月，微软的 MT-DNN 模型首次击败了人类。

今年 2 月中旬，OpenAI 发布了 GPT-2，一个预训练的通用语言模型，其创建者甚至认为它太过危险而不能发布，因为它有能力生成令人信服的文章。GPT-2 使用 40GB 的 Reddit 评论进行了训练，并没有引发假新闻的大灾难，但确实为一部小说、一首前卫的歌词，以及《权力的游戏》的同人小说做出了贡献。OpenAI 最终在 11 月发布了完整版本的模型。

在这期间，来自百度、卡内基梅隆大学、谷歌大脑、Facebook 等其他机构的一系列模型依次超越了 NLP 基准。其中许多都基于 transformer 架构，并利用了 BERT 风格的双向编码。

新闻的背后：2018 年 7 月，就在 BERT 诞生前不久，DeepMind 研究员 Sebastian Ruder 预测了预训练对自然语言处理的影响。此外，他还预测，NLP 的突破将彻底改变整个人工智能。他的论点基于 2012 年前后预训练对计算机视觉模型的激发。许多业内人士将深度学习的爆炸式增长追溯到这一刻。

现状：尽管经过了一年的创新，语言模型仍然有很大的增长空间：即使是 1.5 万亿参数的 GPT-2 也经常吐出一堆令人费解的文字。至于最新的模型是否有能力用铺天盖地的虚假信息扰乱民主，即将到来的美国选举季将检验这一点。

**18-158, AI 工程：知识驱动，旧知识工程（上世纪七、八十年代）；驱动源：知识表示（由知识库提供资源或挖掘数据中的知识要素），或；输入知/数转换；算法、逻辑推理：感知学习算法或深度学习算法，小规模语义网络（数理逻辑推理，持续线性）；目标任务：实现机器人感知智能。**

19-159, AI 工程：知识驱动，新知识工程（2010 年至未来）；驱动源：知识图谱（由知识库提供资源）；算法、逻辑推理：认知学习算法，大规模语义网络（沿 NLP 及 BERT、MT-DNN、GPT2 语言模型训练或经语料库微调），沿语义网络/语言模型新的逻辑推理，呈非线性、跳跃；目标任务：实现机器人认知智能或实现人工智能（类脑）任务（具有可理解、可解释能力）。

20-160, 知识要素（实体、概念和关系，在运作时可转换为数据、代码）。

21-178, 知识图谱是实现认知智能的关键技术。知识图谱作为一种语义网络，是大数据时代知识表示的一种重要方式，知识图谱是大数据时代知识工程的代表性进展。

22-179, 知识图谱的发展轨迹：始于 20 世纪 50 年代，分三个发展阶段：

- ①第一阶段（1955 年至 1977 年）知识图谱起源阶段，引文网络分析。
- ②第二阶段（1977 年至 2012 年）知识图谱发展阶段，语义网络得到快速发展，开始对知识本体的研究，知识图谱吸收语义网、知识本体，在知识组织和表达方面的理念，使得知识更易在计算机之间与计算机和人之间交换、流通和加工。
- ③第三阶段（2012 年至今）知识图谱繁荣阶段，（2012 年谷歌提出 Google Knowledge Graph, 知识图谱才正式得名，谷歌通过知识图谱技术改善搜索引擎性能）。有了知识图谱，就能进行计算机建模。

知识图谱即大规模高级的 NLP，涉及知识抽取、表示、融合、推理、问答等关键问题，特别在理解、解释方面得到一定程度的解决和突破。

23-182, 机器理解数据的本质是建立从数据到知识库中的知识表示（实体、概念、关系）的映射或机器解释，现象的本质是利用知识库中实体、概念、关系来解释现象的过程。

24-189, 有了知识图谱就能进行计算机建模。

25-190, 认知计算是用来构建模拟人脑思维过程的系统，使人工智能进入可理解可解释的新阶段，大脑是理解模拟计算的，计算机是理解数字信号的，自然语言处理 NLP 就是要计算机理解自然语言，利用 NLP 的函数来训练，提高对智能体的理解及解释能力，知识图谱技术有希望成为大脑，它是实现认知智能的关键技术，知识图谱完成从数据到知识，最终服务于智能应用的转变过程。知识图谱就是一种大规模的语义网络或大规模的自然语言处理，知识图谱技术有希望成为大脑，它是实现认知智能的关键技术，知识图谱完成从数据到知识最终服务于智能应用的转变过程。

知识图谱的技术链：多元异构数据→知识获取（1. 从数据中提取知识要素如概念、实体及其关系等，2. 直接采集自然语言：语言、文字、词句、篇章、网络、语义等）→知识融合（完成数据与知识的融合、知识与实体的衔接）→知识表示→知识推理→知识赋能

NLP 的缺陷是不理解常识，要建立常识库，困难太大了，IBM 沃森医疗人工智能提出了具人（Embodiment）概念，与现场医生进行沟通以取得共识，来弥补缺乏常识的缺陷。

26-196, 从感知走向认知要解决业务问题，从单个业务场景、单点单向业务全流程

演进，要建立统一的知识图谱，来实现知识融合推进人工智能落地。

27-197，人工智能资深专家吴恩达认为 2019 年自然语言处理（NLP）取得飞跃。

Deep mind 研究员 Sebastian ruder：NLP 的突破以便让计算机理解，将彻底改变人工智能。

28-209，IBM 沃森健康与安德森癌症中心合作，从 2011 年至 2016 年（6 年间），在对癌症治疗提出建议方面有 635 个案例，尝试采用 AI 技术与医疗行业融合应用，但在医疗效果上出现了正负对立的评估，据安德森方面谈花掉了 6200 万美元，双方于 2016 年终止了合作。

查阅双方合作，没有采取通过知识驱动和数据驱动融合建立统一的知识图谱大数据语义网络来推进，希望在这方面达到认知水准的 AI 技术还处于预研阶段。只有通过知识获取、知识融合、知识表示、知识推理、数据与知识驱动结合，建立统一的知识图谱（大规模语义网络），才能高水平的推动 AI 应用落地。

需要指出，2019 年自然语言处理（NLP）在发展过程中出现飞跃，将语言模型变成精准语言，而且研究人员还研发人工智能知识增强的语义理解框架，可针对任务进行微调预训练（如百度的 ERNIE 模型、谷歌的 BERT 模型、微软的 MT-DNN 模型等）。NLP 虽然做了很大改进，但 NLP 的缺陷是机器无法识别常识问题，而要建立常识库非常困难，IBM 在建设知识工程时，要求研发人员和现场的临床医生（或现场操作人员）进行沟通取得共识，以补充解决机器，无法识别常识·问题使人工智能真正进入认知阶段。

**29-234**, 知识图谱是一个巨大的知识库（描绘在巨大的物理世界中的知识要素/实体、概念及其相互关系），构成一个巨大的网状的知识结构。

物理世界中的一切知识是未来人工智能的基石。

只有构建一个充分的网状知识图谱，储备足够的结构化的知识库，机器才有可能像人类一样，可以充分认识、理解和解释这个物理世界，而认识、理解和解释这个物理世界是人工智能发展到强人工智能阶段的前提。仅仅认识和理解这个世界、只停留在知识层面上还是不够的，机器要像人类一样充分认识、理解和解释这个世界除了知识还要有逻辑。对机器来说，一个词如“傻”，在不同语境中可能会有不同理解（或辱骂、或疼爱、或调情），知识结构再丰富的机器对此也会懵逼！这就要求机器通过知识图谱掌握逻辑，知识推理的逻辑（当然机器不能直接理解知识，不能直接掌握由知识推理的逻辑，必须通过知识图谱）。

**30-235**, 目前人工智能对常识、动机与决策问题中的难点解决办法不是很多，这是机器与人类智能（或人脑智能）差异最显著的地方，也是人工智能发展的瓶颈所在。让机器产生动机的一大难点在于动机是很难被表征的，机器存在展示动机的形成机制难以实现。常识，比较常见的有空间、时间、文化、物理常识，常识对我们日常生活很重要，建立大型常识库成本太高。决策机制分为理性、描述性、自然决策，当前解决难度太大。

**31-236**, 从 NLP 到知识图谱，谁执 AI 牛耳？

AI 最初是从模仿人的智能做起。神经网络技术就是模拟人的神经元处理信息的方式来实现更加智能的语义理解，大大促进了 AI 技术的发展。从处理信息的过程看，大致分为三部分：a，是信息识别，b，是信息理解，c，是信息决策。

所谓信息识别，主要分为文字、语音、图像等三种主流信息表达方式，来识别外部信息。在信息识别领域，包括语音识别、人脸识别、文字识别技术，AI 模仿人的看能比较成功（利用深度学习技术即可达到目的），在这方面 AI 甚至超越人的智能。

所谓信息理解，大脑需要通过阅读外部信息，理解其表达的真实含义，不光是单字、单词含义，而是理解整句、整段话的真实观点。自然语言处理（NLP）技术是 AI 理解信息的主流技术，只有具有语义的抽象概括能力，读出文字间的含义，才能说具有一定水平的人工智能。

所谓信息决策，即运用自己掌握的知识，对外部复杂的信息做出合理的决策，这才是智能的核心体现。AI 主要依靠知识图谱来模仿人（脑）的智能，知识图谱将海量的信息分类整理，梳理出它们之间的关系。NLP、知识图谱等 AI 技术不是互相替代，而是相互依赖、相辅相成。NLP 的任务是读的懂，知识图谱则是合理决策。如果没有一个科学的知识图谱的帮助，NLP 技术很难理解句子中不同词义之间的逻辑关系，就不能更好地理解句子、段落的主要含义。在知识图谱里信息推导路径复杂，必须加以重视！

### 32-237，建立可理解、可解释的人工智能模型

#### 知识图谱的作业流程

- 1) 从数据库和知识库中分别获取数据资源和知识资源，并传送至知识图谱平台。
- 2) 在知识图谱平台上（在其上配置数据获取、知识表示、知识存储、本体构造、知识计算、测试评估等工具），对数据资源和知识资源进行测试、评估和分类，将分类的数据资源和知识资源分别传送至基于表格的存储体中和基于图结构的存

储体中。

3) 建立大规模的语义网络，提取在表/图存储结构体中的数据/和识资源，通过语义网络进行融合、转化（数据→知识），在资源融合、转化时要建立知识表示（确定基于符号/基于向量的知识表示）、知识推理和知识建模（不同意有些专家提出的分数据驱动、知识驱动两路并进形成多模态信息处理方式）。

4) 将知识建模传送到行业应用（第三方应用知识库），通过大规模语义网络（NLP的发展）建立知识图谱语义理解，并补充建立常识图谱和行业（领域）应用知识图谱。在建立知识图谱过程中，充分利用图挖掘和知识计算技术。

5) 从而生成可理解、可解释的 AI 模型，把人工智能从数据驱动以深度学习技术为代表的感知智能阶段推向到知识驱动以知识图谱/语义网络技术为代表的认知智能阶段。

### **33-238, IBM 沃森健康 (Watson) 探索医疗人工智能的历程**

据 IBM 称：IBM Watson 正在探索的医疗人工智能的基础理论研究和临床实践，期望将由数据驱动以深度学习技术为代表的 AI 感知阶段，推进到由知识驱动以知识图谱/大规模语义网络技术为代表的 AI 认知阶段，经历 6 年的研究与实践进展如何呢？

自 2011 年至 2016 年，IBM Watson (IBM 投资 10 亿美之建立 Watson 医疗人工智能事业部和研究团队)，与安德森癌症中心合作，进行医疗人工智能的基础理论研究和临床实践。

6 年来，IBM 开展了 25 个研究课题，并对 635 个病例向临床医生提出诊治的咨询建议，花掉了医院方提供的 6200 万美元研究经费，医院方于 2016 年提出终止双

方合作的建议。对于医疗效果的评估双方分歧很大！

IBM 研究方认为，对人工智能最重要的能力是知识而非数据，他们探索知识表示和知识推理，以期将医疗人工智能从不可理解、不可解释的感知智能阶段推向可理解、可解释的认知智能阶段。

但事实上，IBM 在这次长达 6 年的医疗人工智能的探索中，他们采用的是保守的、停留在感知阶段、单纯依靠数据驱动的深度学习技术，至于他们口头上说的、依靠知识驱动的认知模式尚处于研前的理论准备阶段，并未付诸于实践！

可以说，IBM 对认知智能只是嘴上说的，对感知智能则是动手干的！

### **34-239，自然语言处理（NLP）面临挑战**

近年来，自然语言处理取得了丰硕成果，但迄今远没有达到像人一样理解语言的程度，面临的主要挑战有：

#### 1) 如何解决缺乏有效的知识表示和利用手段问题

这里所说的知识，包括常识、领域（或行业）知识、专家的经验 and 语言学知识等，对于大多数语言学知识和部分领域知识在一定程度上可从大规模训练样本中学习，但很多常识和专家经验往往超出训练样本范围。常识对人而言，这些知识是常备的，对机器而言，却难以从样本归纳学习出来。

有些专家认为，面对知识驱动、知识建模、建设可解释性人工智能模型的情况，首先要引伸自然语言处理（NLP）的概念和内涵，变成建设大规模语义网络，助力于提升知识图谱的功能；面对建立常识库难度很大的情况，他们提出了具人（embodiment）的概念要求研究专家与临床医生多接触交流，在防治问题上取得共识，以此补充缺乏常识和部分领域知识之不足。

## 2) 缺乏未知语言现象的处理能力

对任何一个自然语言处理系统来说，总会遇到未知的词汇、语言结构和语义表达，所谓“未知”，在训练样本中未曾出现过，在语音识别或 OCR 处理后含有大量噪声，一个实用的 NLP 系统必须具有较好的对未知语言和噪声的处理能力，即鲁棒性。

有些专家指出，近来在处理语音识别中消除噪声方面取得很大成效，在处理未知语言方面也有进展。

## 3) 模型是否具有可解释性？

采用数据驱动深度学习/机器学习模型，暗箱操作，这样的模型不具备可解释性，专家们提出，不必再留恋这样的模型会对可解释性产生什么转变；如果突破深度学习，采用知识图谱/大规模语义网络模型，才有可能解决可解释性问题（国外已有人在这方面进行探索）。

## 4) 是否跳出单一模态信息处理的局限性？

有的专家说，目前自然语言处理研究通常指以文本为处理对象的研究领域，一般不涉及其他模型（如语音、图像和视频等）信息处理，事实上各模块之间是独立的，处理过程是脱节的，这严重违背了“类人智能”的前提。也有专家主张采用数据驱动、知识驱动双驱方式，或采用认知计算、感知计算并存方式。

也有一些专家认为，从数据驱动融合转向到知识驱动，以认知计算代替感知计算，可在知识图谱/大规模语义网络上，发展以知识表示的多模态协同信息处理。

最终要解决机器对人类语言理解问题，探索如何构建更加精确、可解释、可理解、可计算的语义表征和计算方法的知识图谱/大规模语义网络，是必须迈出的第一步。

### 35-245, 知识、知识图谱和人工智能

知识是人工智能的基石。

知识对于人工智能的价值在于让机器具备认知能力和理解能力。

构建知识图谱就是让机器形成认知能力理解世界。

知识图谱的图存储在图数据库中，图数据库以图论为理论基础，图论中图的基本元素是节点和边。

知识图谱用节点和边（关系）组成图谱，为真实世界的各个场景直观地建模。

知识图谱主要技术：

①知识建模，②知识获取，③知识融合，④知识存储，⑤知识计算，⑥图挖掘和图计算，⑦可视化技术。

### 36-249, 知识图谱(Knowledge Graph)是为建立大规模知识应用的人工智能技术。

2012年由谷歌提出知识图谱的概念和内涵。

常见的知识图谱主要包含三个节点：实体、概念、属性。

知识图谱以结构化的形式描述客观世界中概念、实体及其之间关系，将（互联网的）信息表达成更近人类认知世界的形式。

知识工程是将知识集成到计算机系统，从而完成只有特定领域专家才能完成的复杂任务，知识图谱技术属于知识工程的一部分。

构建知识图谱就是让机器具有可理解和可计算的知识的能力。

知识图谱技术分：知识表示与建模、知识获取、知识融合、知识图谱查询和推理计算、知识应用技术等。

### 37-262, 自然语言处理的新突破

NLP→NLU

自然语言处理(NLP, 属感知)即语义网络(感知)→大规模语义网络(IBM Watson: 支持认知智能)

或

自然语言处理(NLP, 感知)→自然语言理解(NLU, 认知)→大规模语义理解网络(Facebook: 认知)。

**38-263**, 深度学习是纯粹基于数据的方法, 属于归纳的范畴, 并不具有可解释性, 只能停留在感知阶段未能到达认知。

知识图谱/大规模语义网络是基于知识(或知识和数据)的方法, 属于理解的范畴, 具有可解释性, 可突破感知进入认知阶段。

数据获得(包括结构化、半结构化、非结构化数据)→基于表结构的数据库→(数据驱动)→基于人工神经网络 ANN 的深度学习算法→完成感知环境内、应用场景中、不可理解和不可解释的计算任务。

知识获得(由图像、视频、数据构成知识表示: 节点/实体、边/实体间关系)→基于图结构的知识库→(知识驱动)→基于类脑图神经网络或递归神经网络 RNN 的知识图谱(与大规模语义理解网络融合)算法→完成认知环境内、应用场景中、可理解可解释的计算任务。

另一种方案: 也可将纯粹数据驱动表结构数据库中的数据, 通过数据驱动传送(与知识驱动并行传送)到知识图谱/大规模语义网络中。

如何理解诸如含糊不清、共同引用和常识性推理等复杂问题? 如果构建常识数据

库一时有困难，可采用 IBM Watson 的做法，建立具人概念（embodiment），理论研究者与现场工作人员广泛接触、取得共识、统一行动，以弥补常识的缺失！

**39-265**，BERT 和 GPT-2 分别是谷歌于 2018 年、OpenAI 于 2019 年发布的预训练通用语言模型，具有数十亿参数。有关企业在互联网上几乎所有文本都采用这些模型来训练，以提高其自然语言处理任务的技术水平，在训练后的自然语言生成模型可在多种应用程序中实现自动转化。

微软得益于硬件和软件的突破，2 月 11 日发布了参数量巨大的语言模型（Turing-NLG），该模型有 170 亿参数量，为此前最大的语言模型英伟达（NVIDIA）的“威震天（Megatron）”的两倍，是 OpenAI 模型 GPT-2 的 10 多倍。

业界共识是：任何超过 13 亿参数的训练模型，单靠一个 GPU（即使是一个有 32GB 内存的 GPU）是不可能训练

**40-267**，人工智能从感知智能向认知智能演进！

2020 年 1 月 2 日，阿里巴巴发布《达摩院 2020 十大科技趋势》，把“感知智能向认知智能演进”排在“十大趋势”之首，并决定开展重点研发，期望获得关键突破。

他们认为，人工智能迄今已经在“听、说、看”等感知智能领域达到或超越人类水准，但从感知智能到认知智能（人工智能 2.0）尚待关键突破，或者说对于未来几十年人类社会走进智能社会有所期待！

他们谈到“认知智能可以帮助机器跨越模态理解数据，学习到最接近人脑认知的一般表达，获得类似于人脑的多模感知能力，有望带来颠覆性的产业价值。认知智能的出现使得 AI 系统主动了解事物发展的背后规律和因果关系，而不再只是

简单的统计拟合，从而进一步推动实现下一代具有认知能力的 AI 系统”。为此人工智能需要在两个方面取得进展，一个是算力和协同上，一个是从认知心理学、脑科学以及人类社会的发展历史中汲取更多的灵感，并结合跨领域知识图谱、因果推理、持续学习等研究领域的发展进行突破。

阿里并强调：“认知智能将结合人脑推理过程，进一步解决复杂的阅读理解问题和小样本的知识图谱推理问题，同结构化的推理过程和非结构化的语义理解，以及多模态训练问题。

#### **41-273, 人工智能与人脑智能**

近年来人工智能取得了巨大进步，受人脑神经元调节机制启发的人工智能新颖算法层出不穷！但人工智能离人脑智能（或称人类智能）还差得很远，而人脑（神经元）自身的开发远未充分！

**42-285,** OpenAI 于 2019 年 11 月公布用于生成自然语言处理（NLP）的神经网络 GPT2（1.5B）版本。该版本神经网络在生成 NLP 文本时具有惊人能力，并使 NLP 成为迄今为止最强的迭代。

**43-286,** 据美股研究社 2020 年 3 月 3 日消息，在全球自然语言处理领域顶级赛事 Glue benchmark 中，阿里巴巴达摩院以平均 90.3 分刷新了自然语言理解技术世界记录，获第一名。

自然语言理解是人工智能的核心技术之一，而 Gluebenchmark 比赛排名是衡量自然语言理解技术水平的重要指标。

在此次比赛中，与阿里达摩院同台竞技的还有来自谷歌、微软、脸书、斯坦福大

学等企业和高校的团队。

谷歌于 2018 年推出 BERT 模型是业界广泛使用的自然语言训练模型，达摩院 NLP 团队在 BERT 基础上提出优化模型 StructBERT，能让机器更好地掌握人类语法，加深对自然语言的理解（大大提高机器对词语、句子以及语言整体的理解力）。

#### 44-296，也谈 IBM Watson 研发的认知学习

自《评人工智能如何走向新阶段》一文发表后，大量跟贴留言不期而至，现已近 300 条。其中对 IBM 沃森研发的 AI 的讨论尤其热烈，有赞扬，有抨击，有质疑。在跟贴中有人赞扬：IBM 沃森真正把知识推理和数据结合起来，取得认知学习重大成果；有跟贴中有人抨击：七年多来沃森的医疗 AI 攻关以失败告终。

本人一直关注这些讨论，近来我看到一则谈论 IBM 沃森超级计算机的文章，摘要与大家共享：

该超级计算机利用深度自然语言处理技术（理解深度人类语言和语义）模拟大脑思考，展现了人工智能的强大能力，并具有强大的深度学习能力，IBM 与苹果公司合作，收集、分析来自苹果的大量数据，沃森的 AI 研发适合于医疗领域，可为病人提供治疗方案。

文中指出，这标志着 IBM Watson 人工智能的新进展。

#### 45-304，也来讨论构建模拟人类思维过程的认知计算机制

好像这个问题迄今尚未获得解决。

我们先从输入的信息类型说起：一类是语言输入（包括词、句、文本），第二类是图像输入（包括图像、视频），第三类是数据输入（包括结构化数据、半结构化数据、非结构化数据）。从语言输入中提炼知识要素（概念、对象及概念间的关系），

进而抵达知识表示（节点、边和关联）图像输入要通过图神经网络转化为知识表示。这时以知识表示的语言输入和图像输入将进入知识存储——基于图结构存储中，而数据输入将进入知识存储——基于表结构存储中。随后语言输入、图像输入、数据输入都将直抵知识表示（节点、边和关联），而数据输入将通过知识融合转化为知识表示。以知识表示的上述三类输入在合成后进入知识推理（知识工程的逻辑系统，含因果推理），再进入知识建模（构建模拟大脑思维过程的系统，即构建归纳、抽象、创意等仿脑的认知计算机制）。自进入知识存储直至知识建模一直依托知识图谱（含机器学习/深度学习、大规模语义网络、因果推理、人机交互等）为平台。

现在的问题是：构建模拟大脑思维过程的系统，即构建归纳、抽象、创意等仿脑的认知计算机制尚未获得解决，对于 IBM Watson 推荐的大规模语义网络，似乎还不足以支持机器获得推理能力，让机器做一个“人类”，模仿人脑思考方式建立新的神经网络赋予其足够的表达能力！

#### **46-319，通过人工智能算法模仿人类大脑**

DeepMind 研究多巴胺系统向通用人工智能进军

DeepMind 正在学习、研究人脑中的多巴胺神经递质系统：如何激活大脑，如何理解在神经元连接中的大脑运行方式，如何生成意念、动机、欲望、创意等感觉，建立新的神经网络，开发类脑算法，迈向通用人工智能。

#### **47-322，英特尔康奈尔科学家共建人工智能生物嗅觉系统**

英特尔 AI 科学家 Nabil Imam 研究团队在康奈尔大学研究动物嗅觉系统的科学家帮助下共同构建一种方法：让神经拟态芯片 Loihi 通过样本训练掌握 10 种危险

品不同气味的神经长征，找到一种智能的、可靠的和快速的化学传感处理系统。搭载神经拟态芯片的新方案比 Loihi 此前的传统方案，展现出更加出色的识别准确率。该系统还可应用于医疗系统、机场安检区域（以识别危险物品）。

#### 48-335, 2019NLP 飞跃（让机器在理解自然语言方面取得飞跃）!

百度研发人工智能知识增强的语义理解框架 ERNIE 在 2019 年世界语义评测竞赛（SemEval）中夺冠!

人工智能知识增强语义理解发挥三大作用：

- ①对语义信息搜寻，
- ②对语义模型训练，
- ③通过在专门语料库上进行微调来修正语义网络模型。

知识增强语义框架是补充修正语义网络，建设知识图谱的必要环节。

人工智能知识增强语义理解框架的早期模型 ULMFIT 和 ELM 展示了对语义网络（或 NLP）进行预训练的潜力；2018 年谷歌发布 BERT 模型、微软发布 MT-DNN 模型，BERT 在世界语义评测竞赛中夺冠；2019 年百度研发的 ERNIE 模型在世界语义评测竞赛中超越 BERT、MT-DNN 及 OpenAI 发布的 GPT-2 夺冠。

#### 49-350, 评说 IBM Watson 的 AI 医疗

IBM 在 2011 年成立独立的“沃森健康（Watson Health）”部门，进行 AI 医疗咨询研究工作，建立一个 AI 医疗咨询工具（Watson for oncology），培育“AI 医生”。IBM Watson 推动知识表示、知识推理和数据结合，依托自然语言处理（NLP），构建并进入人工智能认知计算（模拟人脑思维过程的系统），总结患者电子健康记录，并透过其背后强大的数据库的支持，由 Watson 的“AI 医生”出面提供医

疗咨询建议。

自 2011 年至 2016 年，IBM Watson 与 MD 安德森癌症中心合作，研究提出 AI 医疗咨询，6 年来开展了 25 个研究课题，并对 635 个病例提出诊治咨询建议，花掉了医院方提供的 6200 万美元研究经费，最后 2016 年由医院方提出终止双方的合作建议。对医疗效果的评估双方分歧很大，医院方的意见是 Watson “AI 医生”的建议与医院临床医生的诊断出入太大（一致率很低）。

我们来看看第三方的评估：

- ① IBM Watson Health 当时要裁员 70%，是否表示 Watson AI 医疗泡沫化。
- ② Watson 展示的突破性技术是其理解 NLP 的能力，但事实上 NLP 不足以支持 Watson 迈进认知计算。
- ③ Watson “首败”，试图创造一位 “AI 医生” 是一件极其困难的工作。
- ④ IBM 的医疗产品没有成功实现商业化。
- ⑤ 国内一位 AI 专家说 IBM Watson 真正把知识推理和数据结合起来了。

我们还是看看当年图灵奖得主、AI 资深专家 YoshuaBengio 对此事是如何评论的：IBM 对医疗保健系统中不同参与者进行了数量惊人的调查，希望 AI 可以透过分析海量的数据集做出决策支持，扩大 Watson 的 “认知” 能力，但 NLP 虽然取得较大进步，但与人类相差还甚远。

在医学文本方面，AI 系统无法消歧，也无法找到人类医生注意到的细微线索。虽然 AI 系统不需要充分了解也可以帮助医疗，但确实还没有一个 “AI 医生” 能与人类医生的理解和洞察力相匹配。

## 50-351, 人工智能从感知智能向认知智能演进

(阿里达摩院发布 2020 十大科技趋势并解读, 这是之一)

编者按: 人工智能的核心应该是知识表示和不确定性推理, 模拟人脑思考过程, 这正是人工智能从感知智能向认知智能演进有待解决的任务, 欲达此目的还是一个漫长过程, 现录下一则跟贴 (351) 达摩院对此解读:

人工智能在听、说、看等感知智能领域已达到或超越人类水准, 但在需要外部知识、逻辑推理或者领域迁移的认知智能领域还处于初级阶段。

实现认知智能是当下人工智能研究的核心, 也是未来人工智能热潮进一步打开天花板、形成更大产业规模的关键。

认知智能将结合人脑推理过程, 进一步解决复杂的阅读理解问题和少样本的知识图谱推理问题, 协同结构化的推理过程和非结构化的语义理解, 以及多模态预训练问题。

认知智能的出现使得 AI 系统主动了解事物发展的背后规律和因果关系, 而不再只是简单的统计拟合, 从而进一步推动下一代具有自主意识的 AI 系统。

## 51-353, 创造具有类人脑的技术一直都是人工智能创新的源泉

(nature (2019.11) 类脑智能与脉冲神经网络前沿一文摘要一)

从前科学家一直认为人脑中的信息是通过不同的通道(channels)和频率传递的, 如今他们认为人脑就像一台计算机。随着神经网络的发展, 今天计算机已在多个认知任务中展现出非凡能力。

人脑能够执行惊人的任务(例如同时识别多个目标、推理、控制和移动), 而能耗只有近 2W, 相比之下, 标准计算机仅识别 1000 种不同的特体能耗就需要 250w。

尽管人脑尚未被探索穷尽，但人脑非凡能力归结于三个基本观察：广泛的连通性，结构和功能化的组织层次，以及时间依赖(time dependent)的神经元突触连接。神经元(neurons)是人脑的计算原始元素，它通过离散动作电位(discrete action potentials)或“脉冲”交换和传递信息。突触(synapses)是记忆和学习的基本存储元素。

人脑拥有数十亿个神经网络，通过数万亿个突触相互连接。基于脉冲的时间处理机制使得稀疏而有效的信息在人脑中传递。

目前最先进的人工智能总体使用的是这种受到人脑层次结构和神经突触框架启发的神经网络。现代深度学习网络(DLNs)本质上是层级结构的人造物，像人脑一样用多个层级表征潜在特征，经过转换形成的。像人脑层次结构那样，各种硅基计算单元以层级方式排列，以实现高效的数据交换。尽管两者在表面上有相似之处，但人脑和硅基计算机计算原理之间存在鲜明区别：①计算机中计算(处理单元)和存储(存储单元)是分离的，不同于人脑中计算(神经元)和存储(突触)是一体的，②受限于二维连接的计算机硬件，人脑中大量存在的三维连通性目前无法在硅基技术上模拟，③晶体管主要为了构建确定性布尔(数字)电路开关，和人脑基于脉冲的事件驱动型随机计算不同。

但是，使得“通用智能”(包括基于云服务器到边缘设备)无法实现的主要瓶颈是巨大能耗和吞吐量需求。

在人脑指引下，通过脉冲驱动通信从而实现了神经元-突触计算的硬件系统将可以实现节能型机器智能。神经形态计算始于20世纪80年代晶体管仿照神经元和突触的功能动作，之后迅速演化到包括事件驱动的计算本质(离散的“脉冲”人造物)，最终在21世纪初期这种研究努力促进了大规模神经形态芯片的出现。

52-357, “超级大脑”芯片/忆阻点积

nature (2019.11) 类脑智能与脉冲神经网络前沿一文摘要五

“超级大脑”芯片

“超级大脑”芯片的特点是整合了百万计的神经元和突触，神经元和突触提供了脉冲计算的能力。Neurogrid 和 TrueNorth 分别是基于混合信号模拟电路和数字电路的两种模型芯片。Neurogrid 使用数字电路，因为模拟电路容易积累错误，且芯片制造过程中错误影响也较大。设计神经网络旨在帮助科学家模拟大脑活动，通过复杂的神经元运作机制—比如离子通道的开启和关闭，以及突触特有的生物行为。相比而言，TrueNorth 作为一款神经芯片，目的是用于重要商业任务，例如使用 SNN 分类识别任务；而且 TrueNorth 是基于简化的神经元突触原型来设计的。

以 TrueNorth 为例，主要特征如下：

异步地址事件表示 (Asynchronous address event representation)：首先异步地址事件表示不同于传统的芯片设计（所有的计算都按照全局时钟进行），但是因为 SNN 是稀疏的，仅当脉冲产生时才要进行计算，所以异步事件驱动的计算模式更适合进行脉冲计算。

芯片网络 (networks-on-chip, NOCs) 可以用于脉冲通信，NOCs 就是芯片上的路由器网络，通过时分复用技术用总线收发数据包。大规模芯片必须使用 NOC，是因为在硅片加工过程中，连接主要是二维的，在第三维度灵活程度有限。因此尽管使用了 NOC，芯片的联通程度仍然不能和大脑中的三维连通相比。包括 TrueNorth 在内的大规模数字神经芯片，如 Loihi，已经展示除了 SNN 技术以外的应用效果。使得我们能更加接近生物仿真技术。不过，有限的连通性，NOC 总

线带宽的限制，和全数字方法仍然需要进一步研究。

## 忆阻点积

作为模拟计算的一个实例，忆阻点积 (Memristive dot products) 是实现原位神经形态计算的一种有前景的方法。可是表示点积的忆阻阵列中产生的电流既有空间依赖性又有数据依赖性，这使得交叉开关电路分析成为一个非常复杂的问题。研究交叉开关电路非理想状态的影响，探索减轻点积不准确影响的训练方法的研究并不多，而且这些工作大部分集中在深度神经网络而不是 SNN 中。然而我们可以合理假设，在这些工作中开发出的基本器件和电路的见解也能用于 SNN 的实现。现有工作需要精致的设备一通路模拟运行，必须与训练算法紧密耦合，以减少精度损失。基于最新设备的交叉开关阵列的理论模型，以及为点积误差建立理论边界的努力，都将引起人们的关注。这将使算法设计者无需耗时、设计迭代设备一通路一算法模拟，就能探索新的训练算法，同时也能解决硬件不一致的问题。

## 53-380, NLP 领域最有应用价值的子任务之一——文本信息抽取与结构化

目前自然语言处理 (NLP) 将自然语言转化为一种计算机能理解的形式。这一点在知识图谱、信息抽取、文本摘要这些任务中格外明显。

文本抽取与结构化，在 NLP 中是非常有用和有难度的技术。如何将一些“自然”的文本转化为结构化的文本？如何从大规模的语料中提取出感兴趣的内容？任何需要从文本中提取信息的场景或像知识图谱这种需要大规模信息抽取的场景，都需要这样的技术，这是一个 NLP 算法工程师必须要做的事情。

## 54-387, 半小时训练亿级规模知识图谱，亚马逊研发的 AI 框架要火！

随着社交网络、推荐系统、自然语言处理等典型的图数据场景的发展，知识图谱

（包括知识图谱嵌入表示）的规模也在不断增长。知识图谱嵌入表示是一种从知识图谱结构中生成无监督节点的特征，而生成的特征可用于各种机器学习任务上。在工业界真实的场景中，常常需要面对千万级、甚至亿万级节点的大规模知识图谱数据。如何快速、高效地在大规模知识图谱上进行嵌入式表示的训练，是当前的一个挑战。近日亚马逊团队开发了一款专门针对大规模知识图谱嵌入表示的开源训练框架 DGL-KE，以便方便、快速地在大规模知识数据集上进行机器学习训练任务，在业内火了一把！

**55-392**，自然语言处理（NLP）是人工智能的核心问题，旨在让计算机理解语言，实现人与计算机之间用自然语言通信。

但在跟贴 210 条有人指出：机器最大的问题是缺乏常识，而建立常识库又非常困难，这个问题仍然阻碍机器对自然语言的理解。

**56-400**，最新自然语言处理算法已在医疗业务中率先应用。

基于 NLP 构建医疗知识图谱。

近日，自然语言处理领域国际顶级会议 ACL2020 (Association for Computational Linguistics) 论文接收结果公布，中科院自动化所 3 篇论文入选：

在医疗对话的自动信息抽取，国际疾病分类（ICD）自动编码，ICD 自动编码可解释性。这些最新 NLP 算法将为后续研究提供极具价值的经验和方向。

NLP 的医疗业务应用，在电子病历方面：

电子病历已成为现代医疗的重要组成部分，但目前书写电子病历费时费力，已成为医生沉重负担。

通过面向医患对话文本的信息抽取系统，可从对话中抽取出症状、检查、手术一

般信息及其相应状态，这些 NLP 抽取出的信息将有助于医生在书写病历时减轻负担，或进一步用于病历自动生成。

在临床医学决策方面：

为缓解人工编码耗时费力容易出错的问题，开始研究利用机器进行自动的 ICD 编码，中科院自动化所语言与知识计算联合实验室的研究团队通过结合中文的语言特点，提出了一种基于空洞卷积和 N-gram 语言模型的 ICD 自动编码方法，利用空洞卷积捕获非严格匹配的语义片段证据，和利用 N-gram 捕获严格匹配的语义片段证据，进而二者结合使用，提升预测结果的可解释性，而可解释的结果对临床医学决策具有重要意义。

在构建医疗知识图谱方面：

中科院自动化所语言与知识计算联合实验室基于 NLP 技术构建的医疗知识图谱已储备约 50 万医学概念，超过 169 万医学术语和 398 万医学关系库（涵盖绝大部分药品、疾病、科室与检查，规模达国际领先水平），并在语音病历、病历生成、病历质控、辅助诊断系统等具体应用。

**57-404**，使用自然语言处理技术提升创新效率。

近日美国 Lux research 发布《人工智能和机器学习改善创新前端》的白皮书。

Lux research 数字产品副总裁凯文-西恩博士指出，有效利用机器学习可快速挖掘数据，减少全面分析时间，使用机器学习来提升创新速度和技术包容性，在定义成熟的人工智能和机器学习策略时需要加权考虑一些关键技术点：是否需要构建新的技术框架，使用哪些数据源，如何定义和解释技术。

该书指出：使用自然语言处理（NLP）技术提升创新效率（但目前尚未得到充分开

发利用)。

目前产业界正在研发人工智能利用数据的高效方法，尤其关注 NLP。通过 NLP 和主题建模，可使技术优化、竞争分析和微弱信号检测等流程得到改善，可加快海量文本数据分析。NLP 带来的增速是由主题建模实现的，主题建模从文本中提取重要概念，同时大量消除与之相关的人工假设及数据偏差，关于 NLP 中的知识建模可使分类法来定义特定主题下关键创新领域的技术发展趋势。

58-410, AI 神经科学研究下一波的热点会是记忆痕迹 (engram) 吗?

看到跟贴 408: AI 下一波研究热点会是图神经网络吗? 我也转引神经科学资深专家对下一波研究热点的预测。

2020 年 1 月 3 日诺奖获得者 Susumu Tonegawa(利根川进)教授和 Sheena Josselyn 教授在《Science》上发表题为“Memory Engram: Recalling the past and imagining the future”的报告，诠释：记忆的基本单位是 Engram(记忆痕迹)，报告者也证明 Engram 是大脑中的基本计算单位。

报告指出，一种经验可以激活一群神经元，这些神经元会经历持续的化学或物理变化，成为一个 Engram。随后通过经验时可用的线索重新激活记忆，会诱导记忆提取。从细胞整体水平来说，内在兴奋性和突触可塑性的增强共同作用形成了 Engram。

不久前马兰院士、刘星副教授在《Nature Neuroscience》上发表题为“AVentral CA1 tonucleus accumbens core engram circuit mediate conditioned place preference for cocaine”的有关 Engram 的研究。

在神经科学研究中，人类记忆理论中的记忆痕迹 (Engram) 会是下一波研究热点

较好的选择，但由于神经科学的特殊性，实验动物的选择，实验操作的繁琐复杂等原因，要成为神经科学下一波研究热点可能还需较长时间。

**59-442**，人工智能与人脑愈来愈远还是愈来愈近？

神经网络之父 Hinton 的反思。

1986 年 Geoffrey Hinton 写了一篇论文《Learning representations by backpropagation errors》，将反向传播算法首次被引入到多层神经网络的训练中去，其重大意义更是为人工智能在最近十年的发展奠定了基础。

当下面对人工智能的局限性，面对人类大脑尚有很多未知的运作机制，Hinton 提出反思和质疑。

反思：我们是否需要放弃反向传播算法，重新开辟一条新路径？

质疑：人工智能与人类大脑愈走愈远还是愈来愈近？

国内 AI 专家黄铁军教授认为：人类大脑结构是亿万年“优胜劣汰”进化过程造就的。反向传播是人工智能的训练手段。

**60-447 (三)**，从知识表示、驱动、推理，建设大规模语义网络出发

业内人工智能专家欢呼：2019 年自然语言处理（NLP）取得重大突破！

这条知识工程之路从感知智能奔向认知智能。上世纪 80 年代中期启动了知识工程，本世纪初又更新为新知识工程。新知识工程的重点是建设大规模语义网络（以提升知识图谱）。语义网络的发展过程是从自然语言处理系统到自然语言理解系统，再到大规模语义网络。IBM 沃森主张在以知识表示、驱动、推理的路上，由大规模语义网络支持的认知智能目标得以实现。

早年间，IBM “WatsonHealth” 搞医疗人工智能走的就是这条路。IBM 认为，对人工智能最重要的能力是知识而非数据。他们探索知识表示、驱动、推理，以期医疗人工智能从不可理解、不可解释的感知智能阶段推向可理解、可解释的认知智能阶段。但 IBM 走的这条路是失败的。

IBM 的失败，其中主要原因之一是大规模语义网络还不够完善，还没有能力支持认知智能的实现。这里我们引用图灵奖得主、人工智能大师 YoshuaBengio 对此评论中的一段话：“NLP 虽然取得较大进步，但与人类相差还甚远”。

必须指出，对于常识、专业知识、专家经验，机器是很难识别的。IBM 提出具人（embodiment）概念，强调人工智能专家必须与临床医生结合，在疾病诊断时要取得共识。还有达到人类智能的另一道难题是：背景知识，这在学习和训练时是不可或缺的。

所以对于走这条路，未来是非常有前途的，但当下还不成熟，路还很长。

**61-456**，麻省理工学院研究人员探索如何训练机器更准确识别现实世界。

麻省理工学院的研究人员探索人工智能模型在其想象的照片中物体或与动物姿势或与颜色的关联是否可能举一反三？研究人员指出，电脑对世界的理解，往往是它们所训练的数据决定的，如果它们看到的只是红色消防车的图片，它们很难想象出其他颜色的东西属于同类。为了给计算机视觉模型一个更完整、更富想象力的视图，研究人员试着为它们提供更多不同的图像。有些人尝试从奇特角度和不寻常的位置拍摄物体，以便更好地传达真实世界的复杂性。其他人则要求模型使用称为生成对抗网络的人工智能技术来生成自己的图片。在这两种情况下，其目的都是为了填补图像数据集的空白，以更好地反映三维世界，并减少面部和物

体识别模型的偏差。在国际学习表示会议上的一项新项研究中，麻省理工学院研究人员提出一种创造力测试，以了解 GAN 可以对给定图像进行细化处理。他们将模型应用到照片的主体中，并要求其在明亮的光线下，在空中旋转或以不同颜色绘制特写的物体和动物。研究人员说，数据推断和以新颖的发明方式形象化世界的的能力而引起了情报研究人员的注意。他们可以拍摄照片，然后将其转换成文艺复兴时期风格的肖像。但是，尽管 GAN 能够自己学习令人惊讶的细节，例如如何将风景分成云朵和树木，或生成人们脑海中的图像，但它们仍然非常依据于原始数据。GAN 的创作反映了成千上万摄影师的偏见，无论是他们选择拍摄的东西还是构图的方式。

## 62-457，常识推理攻关进展。

人工智能要变得像人一样聪明常识推理能力是必备的。机器缺乏常识推理，何时到了破局的时候？！这是迄今为止一直困扰人工智能 50 多年的难题。

OpenAI 于去年发布 GPT-2，它是一个具有 15 亿参数的通用语言模型，该模型生成的句子流畅惊人，几乎可以假乱真，在语言模仿上有较大进展，但它缺乏基本常识。常识是无法穷尽不成文的规则，是一种广泛可重复使用的背景知识，几乎人人都有，大多数常识知识是隐性的，建立常识库（把现实世界的事实记录下来）以此实现自动化常识推理第一步，但做起来困难之大难以想象。

一般解决常识推理有两条路：符号推理和深度学习。关于符号推理，研究人员尝试将常识翻译成计算机语言—逻辑，期望在常识推理上带来突破，花了不少力气取得极其有限进展。另一条路，研究人员使用神经网络进行深度学习，模拟生物大脑中相互连接的神经元层，在不需要程序员事先指定的情况下学习模式。纯粹

以知识为基础的符号推理方法并不真正为常识推理问题带来突破；而基于神经网络的深度学习方法又如何呢？在过去几十年间经过大量数据训练的越来越复杂的神经网络，已经变革了计算机视觉和自然语言处理领域的研究，然而虽然神经网络具有较强的智能能力以及灵活性，但这些系统仍会犯很多常识性错误。

艾伦人工智能研究所研究员、华盛顿大学计算科学家叶锦才 (YejinChoi) 及其同事提出了自动知识图谱构建模型 COMET (CommonsenseTransformers)，融合了 GOfAI 式的符号推理和深度学习两种人工智能方法。COMET 在处理超出其内置常识以外（即覆盖性）有不错表现，在解决脆弱性问题上也可圈可点。但深度学习有一个根本性限制：统计不等于理解。要想让计算机建立真正的常识，需要利用语言本身以外的媒介，如视觉感知或具象感觉。另外还要挖掘神经语言模型的潜力。补充一点：计算机同样也需要常识，一般而言，没有常识计算机就无法完全理解自然语言，也无法进行视觉和规划任务。

**63-475**, GitHub 上最火的 NLP 项目做机器翻译了！

HuggingFace 发布了 1008 种机器翻译模型，该模型 (26.9K-Transformer 项目) 涵盖 140 种不同的语言组合（中翻英、英译法、法语翻阿拉伯语……，还能够一对多翻译）。该模型是研究人员使用无监督学习和 Opus 数据集训练的 (Opus 项目来自赫尔辛基大学及其全球合作伙伴，旨在收集和开源各种语言数据集，尤其是低资源、小语种语言数据集)。

据 HuggingFace 创始人 ClementDelangue 谈，全世界有那么多人在使用 GitHub 上的开源项目，越来越多使用不同语言的人聚集在 NLP 社区，让我们意识到应该在模型中提供更多语言的接入，同时也提供翻译。

64-530, 如何通过知识工程实现可解释的人工智能。

目前, 通过知识工程尚难实现可解释的人工智能 (或者说, 机器还不能实现像人类那样的认知智能)。

最后一公里短板在哪里? 短板在知识图谱或大规模语义网络。

知识图谱即为一种大规模语义网络。

大规模语义网络是在大数据时代体现新知识工程的核心技术。

自然语言处理 (NLP) 取得很大进步, 人工智能资深专家吴恩达说, 2019 年是自然语言处理飞跃的一年。

我们来看一下自然语言研究的发展轨迹: 自然语言处理 (NLP) 系统——>自然语言理解系统 (具备一定的理解和解释的能力) 或语义网络——>大规模语义网络 (包括语言建模和训练模式)。

迄今大规模语义网络还不够完善。人工智能大师 YoshuaBeno 认为, NLP 虽然取得较大进步, 但与人类的认知能力相差还甚远。让大规模语义网络来支持实现可解释的人工智能其能力尚嫌不足。

在跟贴 84 中, 谈到如何完善大规模语义网络, 如何提升其中的理解和解释两个核心能力 (从现有一定的基础上提升)。

还有不少知识是大规模语义网络所不能概括的, 如常识, 常识是难以定义、表达、表征的, 目前的大规模语义网络尚不包括常识。除常识外, 还有背景知识、专业知识、专家经验、隐性知识等, 也不能被大规模语义网络所概括。

跟贴 457 主要谈到华盛顿大学叶锦才研发团队关于常识推理攻关研究的进展。

IBM Watson 在人工智能医疗诊断中, 提出具人 (embodiment) 的概念, 要求医学科学家与临床医生沟通, 取得共识, 以此来克服缺乏常识的困难。

65-535 (三), 从知识工程、大规模语义网络出发

如何通过新知识工程实现可解释的人工智能? 目前通过知识工程尚难实现可解释的人工智能, 还差最后一公里。最后一公里的短板是大规模语义网络(知识图谱)能力不足(图灵奖得主、人工智能大师 YoshuaBengio 就指出 IBM Watson 的大规模语义网络能力不足), 需要进一步提升其中的理解和解释两个核心能力, 另外要得决大规模语义网络尚不能概括进来的常识等推理攻关问题。

66-557, 解决最后一公里短板, 提升语义网络内涵, 使之具有实现可解释人工智能(或实现认知智能)的能力, 尚待努力!

在跟贴 263、521 中, 谈到提升语义网络内涵的解决之道, 要坚持数据(第二代人工智能)、知识(第一代人工智能)融合统一的双驱动。

在谈到语义网络建设中未及攻克的难关时, 跟贴 530 指出, 不少知识是目前语义网络还不能概括的, 如常识, 常识是难以定义、表达、表征的, 目前的大规模语义网络尚不包括常识, 如常识外, 还有背景知识、专业知识、专家经验、隐性知识等, 也不能被大规模语义网络所概括。

跟贴 457 也指出, 常识是无法穷尽不成文的规则, 是一种广泛可重复使用的背景知识。建立常识库, 以此实现自动化常识推理第一步, 但做起来难度之大到难以想象!

在跟贴 457 中也谈到: 人工智能要变得像人一样聪明, 常识推理能力是必备的, 背景知识在学习和训练时是不可或缺的, 对于常识、专业知识、专家经验, 机器是很难识别的。机器缺去常识推理, 何时到了破局的时候?!

在 1-551 条跟贴中, 不少专家致力于研发大规模语义网络(知识图谱)中可理解、

可解释的内涵。以跟贴 457 为例：

OpenAI 于 2019 年公布 GPT-2：具有 15 亿参数的通用语言模型，这在语言模仿上有较大进展，但它还是缺乏基本常识。

跟贴 457 推荐华盛顿大学叶锦才（YejinchoYejinchoj）研发团队关于常识推理攻关研究进展。他们提出了自动知识图谱构建模型 COMET，融合了 GOFAI 式的符号推理和深度学习（知识和数据双驱动）两种人工智能方法。

近年来，大规模语义网络（将人类语言转化为机器可理解的内容）有很大进展，同时建设大型常识库也有不少探索，如果有人要查阅这方面的资料，推荐查阅跟贴 1-556。

**67-584，答李院士问六：自然语言问题———王迪兴**

问六：自然语言是人类思维活动的载体，如果自然语言是第一语言，数学语言是第二语言，计算机语言是第三语言，后一个比前一个更严格、更狭义。数学自身难以完全自治，数学的形式化借助于自然语言，计算机语言的形式化要借助于数学语言。因此，人工智能怎么可以反过来要用数学语言或计算机语言去形式化人类的自然语言呢？

答：自然语言、数学语言、计算机语言必须基于某种同构性才能建立，互相翻译、代偿、转换。没有同构性任何语言都无法相互沟通与交流，更不会产生有效认知结果。各种语言都是准完备的，都要符合逻辑一致性，基于逻辑一致性进行内涵和外延拓展，才会体现语言的有效性。任何广义语言都不能单一发挥作用，一定要有各种表达方式互补，如语言必须与文字、图形甚至手势互补发挥作用。语言不存在谁形式化谁的问题，都是基于同构互补发挥作用。

计算机语言是基于自然语言派生的，但基于机器语言不能派生自然语言，因为计算机本身不具创造语言的功能，其语言不具主体地位，也没有自主社会化交流的需求，不存在计算机语言形式化自然语言的问题！

68-589, 将上下文融合到常识推理的知识图谱中 (Fusing context into knowledge graph for common sense reasoning)

——YichongXu, ChenguangZhu, RuochenXu, YangLiu, MichaelZeng, XuedongHuang  
微软认知服务研究组

人工智能的一个关键方面是基于观察和知识对日常事务进行推理的能力。通常，大多数人都将这种功能作为与世界交流和互动的主要基础。因此常识推理成为自然语言理解中的重要任务。在这一领域已提出了各种数据集和模型。尽管诸如 BERT 和 RoBERTa 之类的大规模预训练模型在语言理解方面很有效，但它们缺乏明确处理知识和常识的模块。而且与结构化数据相比，本文在表示常识方面的效率要低得多。因此存在各种方法将语言模型与各种形式的知识图耦合以进行常识推理，包括知识库、关系路径、图关系网络和异构图。这些方法结合了语言建模和结构知识信息的优点，并提高了常识推理的性能。但是这些模型与人类的智能之间仍在不可忽略的差距。一个原因是，尽管知识图谱可以在概念之间编码拓扑信息，但它缺乏丰富的上下文信息。另一方面我们可以从外部来源获得精确定义。因此要生成可以无缝集成到语言模型中的结构化数据的表示形式，我们需要在知识图谱中提供每个概念的全景视图，包括其相邻概念，与之的关系以及对其的明确描述。

因此作者提出了 DEKCOR 模型，即用于常识推理的描述性知识。给定一个常识性

问题和选择，首先提取所包含的概念。然后在 ConceptNet 中提取问题概念和选择概念之间的边界。如果不存在这样的边缘，作者将为每个包含选择概念的三元组（节点、边缘节点）计算相关性得分，并选择最高的得分。接下来通过各种文本即匹配条件从维基词典中检索这些概念的定义。最后，将问题选择的三元组和定义输入语言模型 AIbert 中，并且相关性分数由附加的注意层和 Soft max 层生成。作者在 Common sense QA 数据集上评估了我们的模型，并且 DEKCOR 在测试集中的表现优于之前的最新结果 1.2%（单个模型）和 3.8%（整体模型）成为第一个超过 80% 的准确模型。

**69-610, 语义和解释：为什么反事实的解释会在深度神经网络中产生对抗性示例**  
Kieran Browne, Ben Swift research school of Humanities & the Arts  
Australian National University

如果不首先解决语义的稀缺性，将无法解释深度神经网络。已经存在计算方法来产生模型不可知的解释。当将这些方法应用于 DNN 常见的模棱两可或低级表示时，它们根本不能作为解释。这不仅仅是对现有解释方法的限制，而是没有语义就不可能有任何解释。由于深度学习通常对“原始数据”进行操作，几乎没有语义内容（例如像素和字符），因此这种实现有助于阐明可解释性的挑战，我们要么找到一种方法来提取假定存在于网络的隐藏层中的语义，要么承认失败。

最近在可解释人工智能（XAI）中的论文已经确定了该领域的理论基础存在的问题。该领域通常仅凭直觉来解释什么是解释，与人类解释和理解解释的方式不同，有人建议 XAI 根据心理学和社会科学研究的一系列原则采用“日常解释”。有的学者另外指定一种产生反事实解释的方法。认为反事实的解释、表演，与模型无

关，可自动计算，并且对外行人员易于理解。作者认为，这些反事实的解释为向任何人解释复杂的算法系统提供了途径。但是，自 2014 年以来，等效计算已用于深度学习研究中，尽管没有给出解释。相反，在深度学习研究的背景下，反事实计算会产生“对抗性示例”，潜移默化地修改了输入，导致网络莫名其妙地分类错误。

这应该让我们思考：同一方法怎么可能一方面代表一种有前途的新方法向任何人解释深度神经网络的决策，另一方面又代表同一决策过程中令人困惑的脆弱性？我们称这种现象为解释性分歧。作者认为这种鸿沟揭示了 XAI 研究在语义上的盲点。

#### 70-612, 大规模语义网络支持实现认知智能

从跟贴 186、190、210、217、234、235、236、237、238、239、245、249、263、265、277……中，谈到人工智能研究的难点是如何解决对认知的解释与建构，或者说，依托大规模语义网络的支持，以破解认知智能的解决方案，还差最后一公里。

大规模语义网络或知识图谱有希望成为大脑（即类脑），它是实现认知智能的关键技术，但目前大规模语义网络存在的缺陷：①自然语言从大脑思维的模拟讯号向机器能够识别/理解的数字讯号转变的精准度不足，难以推动计算机建模或难以实现认知智能，②目前大规模语义网络最大的问题是缺乏常识（及缺乏行业知识、专家经验和语言学知识等），或者说机器最大的问题是缺乏常识。这样，大规模语义网络尚无力支持智能体提高其对认知的理解和解释能力，还差最后一公里。应该指出，2019 年大规模语义网络取得了飞跃式发展，提高了语言转变（如从模

拟讯号转变为数字讯号)的精确度,建立常识库困难太大,但也有人不畏繁琐和艰险尝试着在做。

## 71-638, 谷歌开发语言可解释性工具 LIT

——Jeff Dean

为了更好地理解语言模型的行为,谷歌 2020 年开发了语言可解释性工具(LIT),这是一个可以更好地解释语言模型的工具包,使得交互式探索和分析语言模型的决策成为可能。

## 72-713, QuatDE: 用于知识图谱补全的动态四元数嵌入

电子科技大学 2021. 5. 19

近年来科研工作者对知识图谱完成方法,尤其是通过图嵌入方法学习实体和关系的低维表示来预测缺失的事实进行了广泛的研究。这些模型通常将关系向量视为实体对之间的平移(TransE)或旋转(rotatE和QuatE),从而享有简单性和效率优势。但是QuatE存在两个主要问题:①用于捕获实体与关系之间的表示以及特征交互的能力的模型相对较弱,②尽管模型可以处理各种关系模式,包括对称、反对称、反演和组合,但是不考虑关系的映射属性,例如一对多,多对一和多对多。本文提出了一种新颖的模型QuatDE,具有动态映射策略,可以显式捕获多种关系模式,从而增强三元组元素之间的特征交互能力。实验表明,QuatDE在三个完善的知识图完成基准上均达到了先进的性能。MR评估在WN18上相对增加了26%,在WN18RR上增加了15%,这证明了QuatDE的普遍性。

**73-717**, 从自然语言文本中提取因果关系的调查, 2021. 1. 16

悉尼大学 Jie Yang, Soyeon Caren, Josiah Poon

作为人类认知的重要组成部分, 因果关系频繁出现在文本中, 从文本中提取因果关系有助于为预测任务建立因果网络。现有的因果关系提取技术包括基于知识的、基于统计机器学习的和基于深度学习的方法。每种方法都有其优缺点。例如基于知识的方法是可以理解的, 但是需要大量的手动领域知识, 并且具有较差的跨领域适用性。由于自然语言处理 (NLP) 工具包, 统计机器学习方法更加自动化。然而, 特征工程是劳动密集型的, 工具包可能导致错误传播。近年来, 深度学习技术因其强大的表征学习能力和计算资源的快速增长而引起了自然语言处理研究者的极大关注。它们的局限性包括高计算成本和缺乏足够的带注释的训练数据。本文对因果关系抽取进行了全面的综述。我们首先介绍了因果提取中存在的主要形式: 显性句内因果关系、隐性因果关系和句间因果关系。接下来, 我们列出用于因果关系提取的基准数据集和建模评估方法。然后, 给出了这三种技术及其代表系统的结构化概述。最后, 我们重点介绍了现有的开放挑战及其潜在方向。

**74-727**, 端到端 NLP 知识图谱构建

微软印度研究院/IBM 欧洲研究院, 2021. 6. 2

本文研究了从科学论文中端到端构建 NLP 知识图 (KG)。作者们专注于提取四种类型的关系: 任务和数据集之间的评估, 任务和评估指标之间的评估, 以及同类型实体之间的相关和相关关系。例如 “F1 分数” 与 “F-measure” 的互相指代。作者们为这些关系类型中的每一种引入了新方法, 并将作者们最终框架 (SciNLP-KG) 应用于来自 ACL Anthology 的 30, 000 篇 NLP 论文, 并构建一个大规模的

KG，这有助于为 NLP 社区自动构建科学排行榜。作者们的实验结果表明，生成的 KG 包含高质量的信息。

**75-737, OKGIT: 具有隐式类型的开放知识图谱链接预测**

印度科学研究所, 2021. 6. 24

开放知识图谱 (OpenKG) 是指使用 OpenIE 工具从语料库中提取的一组 (头名词短语、关系短语、尾名词短语) 三元组, 例如 (特斯拉、返回、纽约)。虽然 OpenKG 很容易为域引导, 但它们非常稀疏, 还远不足以直接用于最终任务。因此, 在本文理解、问答和网络搜索查询推荐等下游任务中使用这些图时, 预测新事实的任务, 即链接预测, 成为重要的一步。

OpenKG 的链接预测任务一直是一个相对未开发的研究领域, 其学习嵌入是一种最近受到一些关注的链接预测方法。以前关于 OpenKG 嵌入的工作主要集中在改进或合并 NP 规范化信息上, 经过仔细检查, 作者发现当前的 OpenKG 链接预测算法通常会针对给定的名词和关系短语预测具有不兼容类型的名词短语 (NPs)。

本文作者在这项工作中解决了这个问题, 使用来自 BERT 的隐式类型信息来改进 OpenKG 链接预测并提出了 OKGIT。它使用新颖的类型兼容性分散和类型正则化来改进 OpenKG 链接预测。通过对多个数据集的大量实验, 作者表明所提出的方法实现了最先进的性能, 同时在链接预测任务中产生了类型兼容的 NPs。

**76-749, KG4vis, 一种基于知识图谱的可视化推荐方法**

新加坡管理大学, 香港科技大学 2021. 7. 27

可视化推荐或自动可视化生成可以显著降低一般用户快速创建有效数据可视化的障碍, 尤其是对于没有数据可视化背景的用户。然而, 现有的基于规则的方法

需要可视化专家对可视化规则进行繁琐的手动规范。其他基于机器学习的方法通常像黑盒一样工作，并且难以理解为什么推荐特定的可视化，从而限制了这些方法的更广泛的采用。本文通过介绍 KG4Vis 填补了这一空白。KG4Vis 是一种基于知识图谱 (KG) 的可视化推荐方法。它不需要手动指定可视化规则，也可以保证良好的可解释性。具体来说，本文作者提出了一个构建知识图谱的框架，由三种类型的实体（即数据特征、数据列和可视化设计选择）和它们之间的关系组成，以对数据和有效可视化之间的映射规则进行建模。采用基于 TransE 的嵌入技术从现有的数据集-可视化对中学习实体的嵌入和知识图谱的关系。这种嵌入本质上是对理想的可视化规则进行建模。然后，给定一个新的数据集，可以从具有语义意义规则的知识图谱中推断出有效的可视化。本文作者进行了广泛的测试以评估提出的方法，包括定量比较、案例研究和专家访谈。结果证明了本文方法的有效性。

在未来的工作中，作者计划探索如何在不增加计算能力的情况下在 KG 中加入跨列特征。并且，本文作者想进一步研究如何结合不同的用户需求和偏好来实现对不同用户的个性化可视化推荐。此外，还会关注将提出的基于 KG 的可视化推荐方法扩展到其他类型的可视化。

## 77-760, 使用逆 HopfFibration 的知识图谱表示学习

海得拉巴印度理工学院, 德国 CereuceGmbH、Zerotha 研究所、亚琛工业大学, 美国代顿大学, 德国高盛

最近, 已经设计有几种知识图谱嵌入 (KGE) 方法来表示密集向量空间中的实体和关系, 并用于下游任务, 例如链接预测。一些 KGE 技术解决了可解释性问题,

即将关系的连接模式（即对称/不对称、逆和组合）映射到几何解释，例如旋转。其他方法对更高维空间中的表示进行建模，例如四维空间（4D），以增强推断连接模式（即表达能力）的能力。然而，在 4D 空间中建模关系和实体通常以可解释性为代价。

本文提出了 HopfE，这是一种新颖的 KGE 方法，旨在实现四维空间中推断关系的可解释性。作者首先对 3D 欧几里得空间中的结构嵌入进行建模，并将关系算子视为  $SO(3)$  旋转。接下来，使用逆 Hopf Fibration 将实体嵌入向量从 3D 空间映射到 4D 超球面，其中作者嵌入了来自 KG 本体的语义信息。因此，HopfE 在不失去表达性和可解释性的情况下考虑了实体的结构和语义属性。作者在四个著名基准上的实证结果实现了 KG 完成任务的最先进性能。

关于未来研究方向，本文的结果开辟了重要的研究问题：1) 在四个维度的空间中，如何更优化地利用语义属性对链接预测性能产生积极影响，并诱导出语义类层次结构。2) 如何利用属性（或描述逻辑）上的逻辑来进行 4D 中 KGE 模型的细粒度推理和逻辑可解释性。

**78-763**，知识库上问答的生成关系连接

IBM 研究所 2021.8.16

关系链接对于在知识库上回答问题至关重要。尽管有各种各样的努力来提高关系链接性能，但目前最先进的方法并没有达到最佳效果，因此，对整体端到端问答性能产生了负面影响。在这项工作中，我们提出了一种新的关系链接方法，将其作为一个生成问题来构建，以便于使用预先训练好的序列到序列模型。我们将这种序列模型扩展到序列模型，其思想是注入来自目标知识库的结构化数据，主要

是使这些模型能够处理知识库的细微差别。此外，我们训练模型的目的是生成由参数关系对列表组成的结构化输出，从而实现知识验证步骤。我们将我们的方法与来自 DBpedia 和 Wikidata 的四个不同数据集上的现有关系链接系统进行了比较。我们的方法报告了与最新技术相比的巨大改进，同时使用了一个更简单的模型，可以轻松地适应不同的知识库。

### 79-773, 具有动态知识图谱的交互式机器理解

加拿大蒙特利尔微软研究院, 柏林自由大学, 2021. 8. 31

交互式机器阅读理解 (iMRC) 是一种机器理解任务, 其中知识源是部分可观察的。代理必须按顺序与环境交互以收集必要的知识以回答问题。本文作者假设图表示是很好的归纳偏差, 可以在 iMRC 任务中作为代理的记忆机制。作者探索了四种不同类别的图, 研究了可以在不同级别捕获文本信息的不同类别的图结构。作者描述了在信息收集期间动态构建和更新这些图的方法, 以及在 RL 代理中编码图表示的神经模型。iSQuAD 上的大量实验表明, 图形表示提供了跨设置的一致改进, 可以显著提高 RL 代理的性能。

### 80-774, 将特定领域的异构知识整合到统一表示中的预训练语言模型

清华大学, 华为诺亚方舟实验室, 2021. 9. 2

现有技术从不同的角度扩展了 BERT, 例如设计不同的预训练任务、不同的语义粒度和不同的模型架构。很少有模型考虑从不同的文本格式扩展 BERT。在本文中, 作者们提出了一个异构知识语言模型 (HKLM), 一个统一的预训练语言模型 (PLM), 适用于所有形式的文本, 包括非结构化文本、半结构化文本和结构良好的文本。为了捕捉这些多格式知识之间的对应关系, 作者们的方法使用掩码语言

模型目标来学习单词知识，使用三重分类目标和标题匹配目标分别学习实体知识和主题知识。为了获得上述多格式文本，作者们在旅游领域构建了一个语料库，并在 5 个旅游 NLP 数据集上进行了实验。结果表明，作者们的方法优于仅使用 1/4 数据的纯文本预训练。作者们将发布代码、数据集、语料库和相关知识图谱。

### 81-777, 强化学习在时态知识图谱预测中的应用

华中科技大学、慕尼黑大学、西门子公司, 2021.9.9

时间知识图谱 (TKG) 推理是近年来引起越来越多研究兴趣的一项关键任务。现有的大多数方法都侧重于对过去时间戳进行推理以完成缺失的事实，而在已知 TKG 上进行推理以预测未来事实的工作很少。与完成任务相比，预测任务更难，面临两个主要挑战：(1) 如何有效地对时间信息进行建模以处理未来的时间戳？(2) 如何进行归纳推理来处理随时间出现的先前看不见的实体？为了应对这些挑战，作者们提出了第一种用于预测的强化学习方法。具体来说，代理在历史知识图谱快照上旅行以搜索答案。作者们的方法定义了一个相对时间编码函数来捕获时间跨度信息，作者们设计了一种基于狄利克雷分布的新颖的时间形奖励来指导模型学习。此外，作者们为看不见的实体提出了一种新的表示方法，以提高模型的归纳推理能力。作者们在未来的时间戳评估作者们用于此链接预测任务的方法。与现有的最先进方法相比，在四个基准数据集上的大量实验证明了显著的性能改进，同时具有更高的可解释性、更少的计算和更少的参数。

### 82-778, 陆首群&Daniel 议论语音识别 Kaldi 新版

2021 年 9 月 13 日, COPU 听取小米集团首席语音科学家 Daniel Povey 关于语音识别 Kaldi 新版的报告, 并就 Kaldi 及其未来发展远景进行讨论。

COPU 陆主席首先指出，Daniel，你是语音科学大师，你率领的团队研发的语音识别 Kaldi 最近发布新版，首先我向你祝贺！并请你简要介绍 Kaldi 这几年在国内外发行及应用情况，请你谈一下 Kaldi 与其他语音识别技术相比，有什么特点和优势？以及 Kaldi 发展远景是什么？Daniel 谈，Kaldi 是开源的语音识别工具，集成了各种语音识别模型，包括隐马尔可夫和深度学习神经网络，被认为世界语音识别框架的基石。新版 Kaldi 由 Lhotse（训练数据准备部分，设计通用灵活的接口，以适应语音识别、文本转语音等任务，引入 AudioCuts 概念，降低数据存储空间）、Icefall（训练脚本集合，降低用户学习成本）、K2（新版 Kaldi 核心，将加权有限状态转换器和相关算法集成到 PyTorch 和 TensorFlow）三部分组成，服务于小米的“手机+AIoT 双引擎战略”。

陆问：据说 Kaldi 识别准确率可达 95%~97%，是否过高？！Daniel 认为，准确率与原始数据有关（不同数据有不同准确率）。陆谈：Kaldi 新版是基于 PyTorch 框架的，PyTorch 创始人 Soumith Chintala 曾指出，2020 年 AI 社区将用更多度量指标衡量 AI 模型的性能，而不仅仅是准确率和原始数据，Kaldi 新版是否也有如此改进？Daniel 认为，新版 kaldi 用在小爱云端（服务器端），注重于改进模型性能：多通道、低功耗。

陆问：新版 Kaldi 是否考虑更高效使用 GPU 及如何针对新硬件执行自动编译？

Daniel：太对了！我们考虑使用 GPU 包括与非监督学习。

Daniel 希望帮助抓好新版落实，陆说：给你找两个伙伴帮助抓落实：一是小米集团，你们已经做了，要求 Kaldi 新版服务于小米的“手机+AIoT 双引擎战略”语音识别技术，请小米集团副总裁崔宝秋帮助落实！二是建议与 CSDN 合作，请 CSDN 创始人蒋涛（基于程序员资源及搜索引擎）帮助落实（在请你写的文章中 CSDN 就

可向你提供搜索资料)。

### 83-781, 生物启发的语音情感识别

Reza Lotfidereshgi 等, Sherbrooke 大学, 2021. 11. 15

传统的基于特征的分类方法不能很好地应用于语音情感的自动识别, 主要是因为识别说话人情感状态所需的精确的光谱和韵律特征集尚未确定。

本文提出了一种直接对语音信号进行处理的方法, 从而避免了特征提取的困难步骤。此外, 该方法结合了人类语音产生的经典源滤波器模型和最近引入的液态机 (LSM) 的优点, 后者是一种受生物启发的尖峰神经网络 (SNN)。首先分离语音信号的源和声道分量, 并将其转换为感知相关的频谱表示。然后由两个神经元库分别处理这些表示。该方法在柏林情感语音数据库 (Emo-DB) 上具有很好的分类性能。

### 84-788, A survey on knowledge graphs: representation, acquisition and applications

Shaoxiong Ji 等, 2021. 11. 28

内容: 这属于一篇比较新的知识图谱类的综述文章, 主要贡献是对近期前沿的图谱研究工作有一个全局性的总览, 并且调整了图谱研究工作的分类, 并以分类为纲对前沿的主要研究技术进行总结, 对未来知识相关的应用趋势进行了前瞻预测。本文按照知识图谱的调研和总结、按照新的分类来对知识图谱领域的研究内容进行划分、前沿技术的分析、对未来的研究方向领域的预测这四个部分来进行论述。本文按照当前知识图谱的重点研究工作的分类, 分别是知识图谱表示学习 (KRL, 也称为图谱嵌入)、知识获取和补全、时序知识图谱、知识感知

应用。

### 知识图谱表示学习

- 表示空间：主要是四类包括实数点向空间、复杂空间、高斯分布空间、流形和群。
- 评分函数：包括基于距离和基于语义两种。
- 编码空间：主要是论述了线性/非线性模型、张量模型、神经网络三种。
- 辅助信息：图谱嵌入表示过程中，为了最小化语义损失，会将更多的图谱信息进行嵌入，这些信息包括文本描述、实体/关系类别信息、可视信息（如图片等）、实体/关系的属性、关系路径、逻辑规则。

### 知识获取和补全

- 图谱补全
- 实体发现：包括实体识别、实体分类、实体消歧、实体对齐。
- 关系抽取：主要是 DNN、GCN、CNN 的结合。

### 时序知识图谱

- 总结了相关的几篇文献。

### 知识感知应用

- 自然语言理解
- 问题回答
- 推荐系统

85-792, 人工智能驱动的移动网络：从认知到决策

Guiyang Luo 等, 2021. 12. 8,

简介：移动网络（MN）预计将提供前所未有的机会，实现互联体验的新世界，并从根本上改变人们与一切事物互动的方式。在日益复杂的配置问题和不断增长的新服务需求的推动下，MN 变得越来越复杂。这种复杂性给部署、管理、操作、优化和维护带来了重大挑战，因为它们需要对 MN 有全面的理解和认知。人工智能（AI）处理计算机中智能行为的模拟，在许多应用领域已显示出巨大的成功，表明其在认知 MN 状态和做出智能决策方面的潜力。在本文中，我们首先提出了一种人工智能驱动的移动网络体系结构，并讨论了认知复杂性、高维行动空间决策和系统动态自适应方面的挑战。然后，讨论了与人工智能相关的潜在解决方案。最后，我们提出了一种深度学习方法，将认知与决策相结合，直接将 MN 的状态映射到感知的 QoS。我们提出的方法有助于运营商做出更智能的决策，以保证 QoS。同时，我们提出的方法的有效性和优势在一个真实的数据集上得到了验证，该数据集在 5 天内涉及 77 个站点的 31261 个用户。

### 86-798, 使用图摘要技术改进知识图谱上的问答系统

Sirui Li, 澳大利亚默多克大学, 2021. 12. 5

内容：知识图谱（KG）（KGQA）上的问答（QA）系统使用 KG 中包含的三元组自动回答自然语言问题。关键思想是将 KG 的问题和实体表示为低维嵌入。以前的 KGQA 曾尝试使用知识图嵌入（KGE）和深度学习（DL）方法来表示实体。然而，KGEs 太浅，无法捕捉表达特征，DL 方法独立处理每个三元组。最近，图卷积网络（GCN）在提供实体嵌入方面表现出色。然而，将 GCN 用于 KGQA 是低效的，因为 GCN 在聚合邻域时平等对待所有关系。此外，在使用以前的 KGQA 时可能会出现一个问题：在大多数情况下，问题的答案通常是不确定的。为了解决上述

问题，我们提出了一种使用循环卷积神经网络（RCNN）和 GCN 的图摘要技术。GCN 和 RCNN 的组合确保嵌入与与问题相关的关系一起传播，从而获得更好的答案。所提出的图摘要技术可用于解决 KGQA 无法回答答案数量不确定的问题。在本文中，我们在最常见的问题类型（单关系问题）上演示了所提出的技术。实验表明，与 GCN 相比，所提出的使用 RCNN 和 GCN 的图摘要技术可以提供更好的结果。当问题的答案数量不确定时，所提出的图摘要技术显著提高了对实际答案的回忆。



敬请关注联盟微信公众号  
COPU开源联盟



扫描二维码  
获取往期资料

---

中国开源软件推进联盟秘书处

电话：+86 010-88558999

联盟公共邮箱：[office@copu.org.cn](mailto:office@copu.org.cn)

联盟官网：<http://www.copu.org.cn>

地址：北京市海淀区紫竹院路66号赛迪大厦18层