

【神经符号 AI 讲座】关于神经符号人工智能及其关键技术

编者按：上海交通大学神经符号人工智能暑期学校开学典礼暨社区研讨会，于 2024 年 6 月 24-25 日在上海交通大学召开。英特尔中国研究院王志刚作了题为《神经符号人工智能及其关键技术》的主题报告，结合神经符号人工智能社区的研发工作，介绍了神经符号人工智能及其关键技术，强调了其在模拟人类思维模式中的重要性。尽管目前智能机器人领域已经取得了一定成就，但在整合能力上仍落后于人类。神经符号人工智能通过融合神经网络概率学习和逻辑符号推理，提高了机器人的自主性和学习能力，减少了对大量数据的依赖，并在迁移学习中展现出优势。未来神经符号人工智能将推动机器人技术的发展，使其能像人一样工作，并在实际应用中产生价值。

一、引言

神经符号人工智能社区专注于人工智能领域，坚信万物皆可计算、皆可智能化。基于此理念，我们深入探讨了该产业的投资价值与潜在突破点。我们观察到，尽管机器人在 AI 领域如视觉识别和场景理解等方面已超越人类，但整体技术仍显落后。机器人虽然具备超越人类的视觉和控制能力，但这些能力的综合表现却远不及人类。大多数机器人仍停留在自动化阶段，一旦离开定制的生产线，便难以适应。我们开发的机器人多局限于简单的挥手或对话等非消费性质工作，无法产生实际价值。因此，我们期望智能技术能有所提升。尽管 AI 取得了显著进步，但与人类之间仍存在巨大差异。

今日，我将分享我对神经符号人工智能的理解、关键技术，以及我们如何将这些技术应用于机器人，推动其发展。神经符号体系的起源可追溯至丹尼尔·卡尼曼的《思考，快与慢》。卡尼曼，诺贝尔经济学奖得主，提出了人类思维模式理论，将思维分为快系统和慢系统。快系统负责直觉性操作，如看见红绿灯踩刹车，无需特别分析即可无意识执行。慢系统则在陌生环境中发挥作用，如在宾馆面对不同的水管开关时，需分析和尝试，通过逻辑推理建立体系，迅速适应。这两个系统在陌生环境中通过逻辑分析和推理理解世界，确保不出错；在熟悉环境中则依赖直觉和习惯控制行为，快速工作。

将这种思维模式应用于机器人领域，我们认为熟练工人与陌生工人的操作截然不同。例如，生产线上的工人可闭着眼安装螺丝，这是快系统在工作。面对新部件时，他们必须认真分析如何操作。如何模拟此类人类系统？神经符号人工智能概念应运而生，将神经系统中的概率学习与基于符号的推理系统结合。以下是一些简单例子，说明它们如何融合。

二、神经符号人工智能

我们可通过神经网络识别数字，然后输入系统进行加法运算，得出结果，如图 1。与传统深度学习方法相比，数据量较小时，神经符号方法能更快达到近 80% 准确率；若数据量特别大，神经符号与深度学习方法无本质区别。在数据量小的场合中，神经符号方法表现更佳。这是因为神经符号系统中已包含加法知识，无需从原始数据开始学习。人类成熟的加法系统可直接应用，所需数据量大幅减少。此方法还使迁移学习变得更容易。例如，从一位数加法转向两位数加法时，传统深度学习方法需重新训练，而神经符号方法可直接达到 90% 以上精度，无需任何修改。




图 1 神经符号与深度学习方法在加法运算中的比较：神经符号更适合数据量小的情况、迁移学习更容易，因为神经符号系统中已包含了人类的加法知识。

浙江大学近期发表的论文 (LogicSeg: Parsing visual semantics with neural logic learning and reasoning)，如图 2，我将其工作作为例子展示。我们在传统识别和分割方面已取得不错成果，但实际上可做得更好，可引入对世界理解的知识。这里的知识是将物品进行分层次分割，如物体级别、类型级别等。通过这种方式，我们可进一步提高现有分割技术，提高约 10 个百分点，这是一个非常好的结果。

这也表明，结合神经符号可为相关领域带来显著提升。

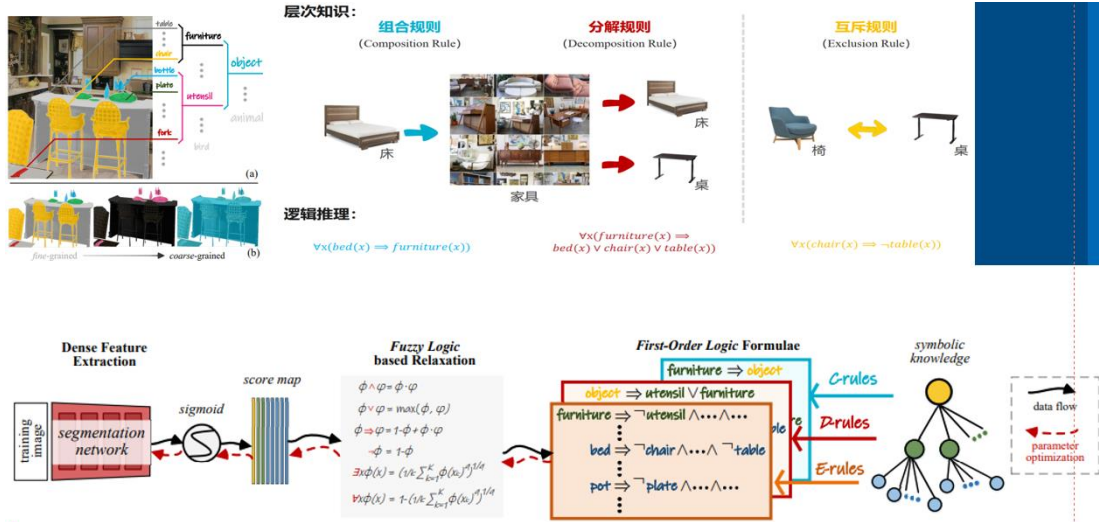


图 2 识别和分割中引入对世界理解的知识，可进一步提高分割效果（Li L, Wang W, Yang Y. Proceedings of ICCV, 2023）

在神经符号领域，2021 年有人提出新 AI 将是第三代人工智能。我们实际上晚了一年接触此技术，于 2022 年底开始接触并实施。当时，我们对这一领域还持怀疑态度，认为神经符号是否能成为新浪潮，因为深度学习仍是主流。但回顾今年发展，我们发现神经符号当之无愧地成为第三代浪潮。现在非常火热的 BERT、GPT 以及基于 ChatGPT 的 Wolfram Alpha，即智能体系统，都是基于神经符号思维构建的。另外，去年底在数学奥林匹克竞赛中首次超过人类冠军能力的 AlphaGeometry，也是一个基于神经符号的系统，通过快思维和慢思维相结合的系统实现。

三、我们在神经符号人工智能方面的工作

我们非常有幸赶上了人工智能的第三个浪潮。我想借此机会先展示一下我们过去一年所做的工作，我们称之为“BEAM-1”或“光束一号”，如图 3，它是电池拆卸复合型机器人的缩写。我们希望它能为绿色制造行业带来一束光，带来新鲜理念。我们采用了复合型机器人 AMR，即自主移动操作机器人。我们选择此系统是因为在观察拆解流水线与拆解工位方式时，发现流水线方式依赖于工艺装备，而拆解工位方式则是工人围着电池拆解。这样的方式对于适应不同的电池和环境具有优势。我期望未来能有这样的机器人，只需给它场地，它就能像人一样开始拆解工作。要像人一样工作，它需要具备几个能力，我们主要推动这几个能力的发展。



图 3 电池拆卸自主复合型机器人 BEAM-1

最重要的能力是自主性，即自动选择动作。人做很多操作时，无非是移动、抓取等一系列动作，但人的能力在于能将这些动作组合起来完成更复杂的事情。我们希望机器人也具备这样的能力。另一个是学习能力，即机器人在看到不同的对象时，可以学会适应，而不需要长时间的训练和工程师的重新开发。

我们的 BEAM-1 系统知道它在做什么（参考神经符号人工智能社区网站提供的视频，<https://www.nsaihome.org.cn>）。系统能够组合不同元素，目前已支持 12 种不同的拆卸动作，包括接近、插入、套接、拆卸等等。系统能通过触觉感知，基于感知选择执行相应的操作。操作序列是通过一系列操作组合来完成特定任务。例如，在执行“插入”这个动作时，视觉可能出现偏差，导致在执行“拆卸”动作时发现“套接”不成功。此时，人类会通过摸索来确认，我们正是通过这一机制来实现的。通过视觉，发现目标周围有障碍物，会采取最短路径，清除障碍物，然后，再次观察，通过”摸索“动作最终碰到螺钉并重新校准位置。人类在移动时需知道自身位置以获取物品对象，拆螺丝同理。视觉提供反馈，若视觉判断与实际操作不符，说明视觉判断有误。就会基于触觉进行调整，以产生机器人自身“正常的”视觉。有些视障人士仍能正常生活，因为他们根据自身动作进行调整。若以动作原语方式操作可能较慢，那么在熟悉环境中，是否可以重复已建立的逻辑关系来

加快拆卸动作的速度？这是目前正在做的工作。

四、神经符号人工智能的关键技术与挑战

接下来，我将更深入地分析神经符号人工智能中的一些关键技术。神经符号人工智能的关键技术可分为四部分：知识对齐、可微计算、持续学习与具身智能、高效运算，如图 4，核心是知识对齐。将新知识与符号知识结合，说起来容易，实则不易。因为输出信息是高维向量。我们需要将其解释为人类能理解的形式，这需要进行对齐。只有知识对齐后，信息才能被系统处理，未来的知识指示或纠正工作也能反馈到系统中。知识对齐是核心，对齐后可衍生出持续学习的过程，使机器人能够持续学习。持续学习在 AI 领域，尤其是具身智能领域，已经成为一个非常热门的话题。具身智能指的是机器人拥有自己的智能，这种智能不是通过工程师的编程来实现的，而是机器人自身能够进行学习和适应。为了实现这一点，机器人需要具备两个关键能力：可微计算和高效计算。这两个部分是支撑具身智能发展的基础。




图 4 神经符号人工智能的关键技术

4.1 知识对齐

最容易理解的是显式知识对齐，如大模型的知识对齐。GPT 处理的是人类为交流产生的各种各样的符号。GPT 根据输入预测输出，如输入“这家店真不错，好评”，然后预测接下来的输出。其对齐方式是确保输入与输出对齐。GPT 直接预测后续话语，而 BERT 则已知前后语，预测中间部分。这些都是显式的对齐，因为已明确输入与输出。零样本学习，即 zero shot 学习，实际上是在进行一种对齐工程。它通过将数据集中的图像编码成一系列的特征向量，同时将相应的文字

描述也编码成类似的向量。其核心在于确保如果图像描述的是一只狗，那么图像编码必须与文字中“狗”的编码高度相似，这种相似性通过相似性矩阵来衡量。只有在大量数据集中进行学习后，系统才能实现图像与文字的对齐。这正是当前流行的视觉大模型，例如 CLIP（Contrastive Language-Image Pretraining）的做法。

我们的工作中也有显式的知识对齐，如基于属性的紧固件识别方法（如图 5）。我们不像大模型那样进行大维度对齐，但在工业领域做了一些简单的对齐工作。在工业领域，我们进行了一些简单的对齐工作。例如识别螺钉，螺钉是标准件，人看一眼就知道用什么工具，但它有属性，如外形、内槽、腐蚀情况、尺寸大小等，这些都是属性。当我们从物体获取信息后，我们实际上能得到一个图像的编码。我们将其编程为对应属性的一些信息。这些信息输入后，我们通过一个合成的过程，就可以得知螺钉的型号，例如 M8 的外六角螺钉。螺钉的编码事实上都是有标准的。完成对齐后，我们在一定范围内，就可以扩展到更多工作中去。




图 5 基于属性的紧固件识别方法框架

知识对齐中还有一种方法，称为隐式知识对齐。为了说明这一点，我举了一个 AlphaGeometry 的例子。这个系统在数学竞赛中超越了人类冠军，特别是在几何领域。几何题的难点在于证明时需要添加辅助线，而传统的逻辑系统难以处理这一点。因此，AlphaGeometry 采用了一种新的方法：训练神经网络来生成辅助线。例如，通过训练，神经网络可以识别出两条边相等时，其对应角也相等。这种方法不需要显式的知识对齐，而是通过隐式的推理过程，自然地产生辅助线，如连接中点，从而使后续的逻辑推理变得顺畅。




图 6 AlphaGeometry 几何证明过程中的隐式知识对齐 (*Nature* 625, 476–482, 2024)

我们也在类似的项目中应用了这种对齐方式。例如，在拆螺钉的任务中，我们使用复合型机器人并通过神经网络在连续空间内推理出最佳的移动位置，如图 7，并确保这些参数既能满足任务规划的全局约束，又能显著提升后续运动规划的效率。这种方法不仅提高了执行效率，还使数据利用更加有效。最终，我们的方法比随机采样快了 30 多倍，显著提升了任务的完成速度和准确性。




图 7 复合型机器人最佳移动位置的推测网络 RPSN

4.2 持续学习与具身智能

在具备了这些基础之后，我们可以进一步探讨持续学习的能力。设想一个场景，机器人通过观察和学习，能够识别并处理它曾经遇到过的任务。传统的做法是，机器人每次面对新任务时，都需要从头开始计算和推理每一个步骤。然而，通过持续学习，机器人能够识别出熟悉的场景，并跳过繁琐的推理过程，直接调用已知的解决方案。这种能力不仅加快了操作速度，还提高了效率。对于机器人来说，识别熟悉场景的关键在于如何判断场景的熟悉度。这涉及到长距离判断、障碍物识别等多种技术手段。通过这些手段，机器人能够持续提升自己的能力。一旦机器人进入一个熟悉的场景，它就可以利用之前成功处理该场景时积累的轨迹和位置信息，快速做出反应。这种方式实际上就是我们所说的具身智能，它不

仅仅是建立机器人的智能，更是构建一种以行为为导向的智能系统。虽然这个概念听起来有些笼统，但我的理解是，它旨在让机器人能够像人类一样，通过不断的实践和学习，形成自己的智能和行为模式。

以行为为导向的智能，是指智能体通过实际行为和经验来学习和理解世界，而不是仅仅依赖于预设的规则或第三方的标注。我们通过一个简单的例子来说明这一点：

假设有一扇门，它的状态是关闭的，如图 8。对于人类来说，如果门是关闭的，我们通常会认为它是不可通过的。然而，对于狗来说，关闭的门并不构成障碍，它们可以随时通过。因此，门是否可通行的属性并不是由外部标准决定的，而是需要智能体自己去尝试和判断。



图 8 以行为为导向的智能

再比如，水龙头的开关，虽然人们可能会标注哪一边是热水，哪一边是冷水，但也有很多情况下是没有标注的。这时，智能体就需要通过有意识地尝试来学习这些信息。只有通过不断的尝试和持续学习，智能体才能真正掌握这些知识。

在这个过程中，持续学习和反向推理是关键。反向推理是指智能体通过操作的成功与否来验证其假设是否成立。例如，如果智能体基于某个假设进行操作，

但操作失败了，那么它就需要调整假设，并通过进一步的尝试来验证新的假设。这种反向推理的能力，使得智能体能够不断优化其行为和决策过程。

因此，以行为为导向的智能，强调的是智能体通过实际行为和经验来构建和完善其认知系统，而不是仅仅依赖于预设的规则或第三方的标注。这种智能体能够通过不断的尝试和学习，逐步形成自己的行为模式和决策逻辑，从而更好地适应和应对复杂多变的环境。

4.3 可微计算

可微计算时，我们需要做的是将逻辑系统和神经系统串起来执行，而不是分开。如果将信息从神经系统中拿出来，转成一个逻辑系统去做，会导致数据不可训练，那么持续学习和反向推理这些工作就没有意义。可微计算中通常需要做的是检查系统是否可微。如果是的话，后面的一些步骤可以不做。典型的可微系统，例如我们进行的操作，是对准和不对准，套接成功和不套接成功，都是 0 和 1 的关系。在许多系统中，这都有这样 0 和 1 的关系，是一个跳跃的函数，是不可微的。因此，我们的逻辑系统使用的是模糊逻辑系统。“与”转化成点积、“或”转化成 $\max$ 等一系列运算。另外，也有一些可微算子，例如，在进行位置预测时遇到了这样的函数。该函数在此位置是不可微的，因为会出现无穷值。于是，我们寻找是否存在某个位置，沿切线设定一个最大值，该值在我们的系统中，尤其是机器人系统中，不会达到如此极限的情况。将所有大于某值的元素放入一个函数中，这个函数变成了一个分段函数。改成可微系统后还存在一个问题，即 loss 函数的设计会转化为多目标优化问题。尽管我们的机器人仍显笨拙，但其后续的研究点仍非常值得探究。

4.4 高效计算

最后，我想简要提一下高效计算这个领域，特别是如何高效地处理可微逻辑系统和可微神经符号系统的计算。逻辑系统通常擅长 CPU 的一些操作，而神经符号系统则更擅长 GPU 或 TPU 等市场。因此，理论上，XPU（如英特尔的 AI PC）这样的概念可能更适合这种系统。当然，这还不是最终的解决方案。我认为，像“天机”（如图 9，异构融合类脑计算芯片）或英特尔的 Loihi 这样的类脑计算芯片可能更合适。这些系统能够以神经元的方式完成 ANN 和 CNN 的计算，更具体地说，是通过求和后的不同激活函数和神经元的脉冲计算方式来实现。从计

算系统的角度来看，理想的系统应该能够无缝地表征神经和符号这两种典型的应用，这才是最适合的系统。




图 9 ANN 神经元和 SNN 神经元模型实现与比较

五、神经符号人工智能是一种范式

图 10 是我们整个神经符号人工智能系统的一个框架。




图 10 面向拆解的神经符号人工智能系统框架

通过逐步完善框架，我们开发出了 BEAM-1。它最初只在仿真器中，然后在固定工位的协作机器人上，最后应用到了自主移动复合机器人上。我们强调的是感知、规划、执行到验证、学习的无缝过程。感知部分，我们将图像和传感器数据转化为系统状态。我们引入了一个叫做神经谓词的概念，建立了符号化的世界状态表征。在符号化状态中，系统可以进行推理，确定要执行的动作序列。有了动作序列后，系统就可以执行。由于这是一个符号化的推理过程，系统知道每一步的预期。在这个过程中，系统可以边执行边验证是否与预期一致。如果一致，

就继续执行；如果不一致，就重新规划。当不一致时，说明神经谓词或动作存在问题，需要持续学习改进。整个系统是一个持续学习、不断改进的过程。神经符号人工智能更是一种思想，不仅仅是指这个框架或特定符号。

实际上，我们可以看到，在处理神经谓词的过程中，这是一个显式的知识对齐过程。同样，刚才提到的基于属性的紧固件识别，也是一个显式的知识对齐过程。此外，我们还规划了基于神经谓词的任务，并且可以使用 LLM 模型来增强任务规划，这涉及到了隐式的知识对齐。在持续学习的过程中，我们还能够进行反向推理，这也是一个隐式的知识对齐过程。最后，我们有基于直觉的位置和轨迹预测的工作，这也是通过知识对齐来实现的。因此，不仅在最顶层设计中可以使用神经符号的操作，而且在底层每一个细节中都可以进行相应的处理。未来，可以根据自己的需求来判断哪种方式更为合适。

六、结束语

最后，有一件事情可能是我想强调的。即使我不说，研究生或老师们也可能会有疑问。现在大模型非常流行，在这样的世界里，如果不做大模型，就仿佛没有站在科技的前沿。在机器人领域里，也有很多这样的讨论。其本质就是关于 scaling law 的可扩展性，我能否通过更多的数据和算力，通过训练让机器人变得更智能？在语言和图像领域，这都已经可以实现。再反观我们现在所做的工作，我们很多时候是讲数据。例如，在紧固件的领域里，我们继续做知识对齐。我的回答是，我们不应该抵触使用更大的模型和算力去做，但应该脚踏实地，一步一步前进。我提两点，即开放和躬行。在做轨迹规划时，我们也引入了一点大模型来做这件事情。我们并不应该把 Neuro-symbolic AI 和大模型对立起来，不要想着说一定要收集大量的数据，一定要训练一个特别大的模型去做。大模型的本质是在做一些知识的对齐。但是，在 AI 领域，需要投入大量的资源，而且在机器人领域，数据并不像互联网领域那样容易获得，还需要去操作和模拟很多事情。所需要的经费可能超出我们的承受能力，但我们可以开放地去看别人的技术能否为我们所用。

为了实现基于属性的紧固件识别任务，我们实际上采用了 CLIP (Contrastive Language-Image Pretraining) 模型作为对比。然而，当我们尝试直接向模型输入一个外部为六边形、内部为十字形的紧固件图片时，模型却无法正确识别。这是

因为该模型并未在包含此类特定描述的数据集上进行过训练。所以，我们应该把大模型的思想有效地应用到这个领域中去。我们还要去做，我们做的时候保持一个开放的眼光，不停地去接受它。现在很多人都在讨论人形机器人的事情，我们是否要上？其实，就是看它是否实用，我们能否在现有的投入下，把这个事情做好。

神经符号AI，赋能绿色制造的人工智能引擎
<https://www.nsaihome.org.cn>



NSAiHome
神经符号人工智能社区

（责任编辑 曹晓舟，审核 刘永光）