

【神经符号 AI 讲座】神经符号推动工业机器人的具身实践

编者按: 神经符号人工智能社区首席科学家、英特尔中国研究院研究员王志刚博士在中国计算机学会 TF (技术前线) “具身智能机器人的大模型与应用研发”主题论坛上的演讲内容。尽管非具身智能 (如大模型) 已趋成熟, 但具身智能 (物理 AI) 的实际落地仍面临两大瓶颈: 机器人系统的可靠性问题、复杂物理任务的数据稀缺问题。为突破上述瓶颈, 提出将神经网络 (数据驱动学习) 与符号逻辑 (规则驱动推理) 融合, 构建神经符号具身智能框架。该混合方法利用神经网络实现感知与模式识别, 通过符号逻辑 (如 PDDL 等形式化语言) 确保规划可靠性与可验证性。

以移动单臂机器人拆卸废旧动力电池包的螺栓为例, 在任务规划方面, 用 PDDL (规划域定义语言) 定义动作原语、每个动作原语的前置条件与执行效果 (如“抓取”需满足“物体在可达范围内”), 先通过神经网络 (如大模型) 生成初始任务规划以提升效率, 再用符号逻辑验证计划正确性以增强可靠性。任务成功率从纯神经网络方案的<80% 提升至一次成功率 95.7%、经重规划验证后可以达到 100%。在运动规划方面, 采用结合模型方法 (如 MPC 精确控制) 与神经网络 (自适应学习) 的混合控制方案, 并强调了知识注入的好处。通过编码器-解码器架构将符号知识 (如运动学、静力学) 以可微模型形式注入神经网络, 能达到训练数据需求量较纯强化学习减少 1 万倍, 同时提升对真实世界噪声的泛化能力。。

对于当前阶段具身智能的一个基本判断是: 信息智能技术日趋成熟, 然而具身智能 (或称物理智能) 的发展仍远未完善。实际上, 制约具身智能落地的因素众多, 包括电池成本、应用场景等多方面问题, 所有从业者都在为解决这些问题而努力。本研究将重点关注其中两个关键挑战——**机器人系统的可靠性和复杂物理任务的数据稀缺性**, 并介绍我们提出的“神经符号具身智能”作为解决方案, 如图 1。

所谓“神经符号”, 是指将人工智能中基于神经网络的方法与基于逻辑符号的方法相融合, 取长补短, 以提升机器人系统的可靠性并缓解数据稀缺的问题。

在展开论述之前, 先简要介绍本研究的背景。我们采用的载体是一款移动单臂机器人, 应用场景为新能源领域, 具体聚焦于报废电池的拆解问题。目前, 该

系统已在多种实际条件下完成废旧动力电池包的螺栓拆解任务。我们的核心贡献是：提出了一个“神经符号具身智能框架”，如图 2。该框架包含三个组成部分：神经符号任务规划、神经符号运动规划与神经符号定义硬件。其中，前两个部分聚焦于智能系统构建，可类比为当前流行的“大小脑双系统”架构。任务规划作为“大脑”，负责推理决策，确定下一步操作，其执行节奏可以相对较慢；而运动规划则扮演“小脑”角色，负责快速计算并控制机器人完成具体任务，对实时性有严格要求。第三个部分——神经符号定义硬件，则侧重于机器人本体设计。我们希望通过理念创新，推动硬件层面的优化，共同应对可靠性低与数据不足的挑战。



图 1 什么是神经符号的方法。



图 2 神经符号具身 AI 框架：任务规划、运动规划、神经符号定义硬件。

1、神经符号任务规划

我们采用 PDDL（规划域定义语言）进行任务描述，该语言为 AI 规划提供一个规范且可靠的框架，如图 3。从描述方式可以看出，PDDL 源于逻辑符号学体系，其核心在于定义一系列动作原语，即机器人可执行的基本技能单元。不仅如此，PDDL 还通过谓词逻辑明确定义每个动作的前提条件与执行结果，这实际上是对环境中物体属性及其关系的一种符号抽象，而我们利用神经网络（即**神经谓词**）来实现其表征。

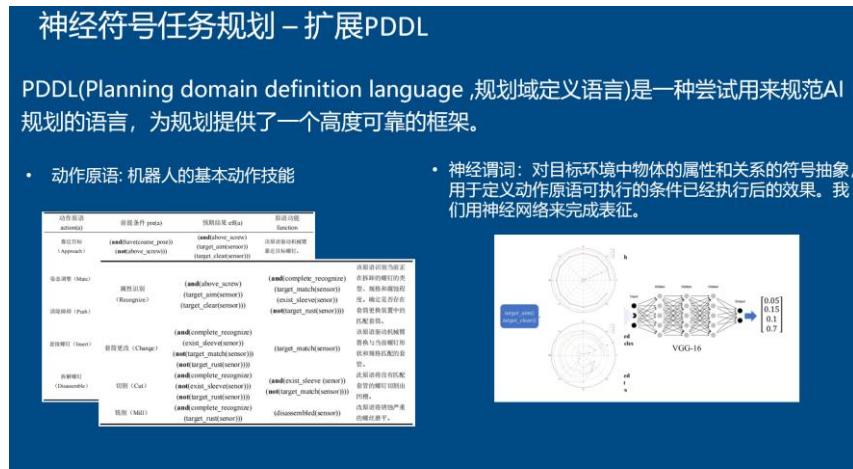


图 3 神经符号任务规划框架。

理论上，仅凭 PDDL 描述即可借助传统逻辑搜索方法完成任务规划，但这类方法通常效率较低。因此，我们引入大语言模型，借助其神经网络能力提升规划效率，如图 4。与此同时，并未完全抛弃 PDDL，而是以其逻辑系统对规划结果进行验证，从而实现神经与符号方法的优势互补，确保任务规划的可靠性。在 2023 年大模型技术初步成熟时，我们进行了对比实验：直接使用大模型进行任务规划的成功率不足 80%，而采用我们的方法，单次成功率可达 95.7%；若加入验证与重规划机制，成功率更能达到 100%。

需要解决的一个问题是：PDDL 等形式化描述是否必须依赖领域专家手动构建？答案是否定的。这类操作域的定义实际上可通过“示教学习”（learning from demonstration）自动完成，如图 5。从本质上看，**操作行为即是不断改变物体属性与关系的过程**。例如，抓取物体改变了手与物体的关系，移动物体改变了物体与桌面的关系，开启灯光则改变了照明属性。通过观察一系列示教操作，

我们可以重点关注物体属性与关系的变化节点，自动完成动作切分，并设计相应的神经谓词与动作原语。整个过程可实现自动化，并可通过动作合成、持续学习等方式进一步提升效率。

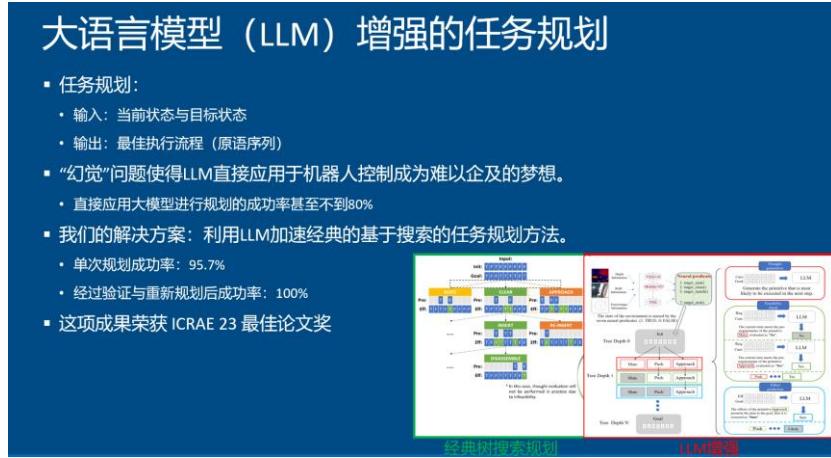


图 4 利用大语言模型提升规划效率。



图 5 操作域的定义可通过“示教学习”自动完成。

2、神经符号定义硬件

我们对具身智能的理解，较之当前主流观点略有拓展。现有研究多聚焦于本体智能的提升，即如何在智能系统中融入具身信息以增强智能水平；而我们则进一步思考：既然神经符号框架引入了一系列动作原语与谓词逻辑，能否以此反向指导硬件设计，从而加强具身与智能的协同？即神经符号框架定义机器人硬件的设计，如图 6。

以现场学习为例，这被认为是机器人系统的理想学习方式。然而，现有系统鲜有采用此方式，普遍依赖仿真环境或大规模数据采集进行模型训练，再将模型

部署至实际场景。这种“训练-推理”分离的模式，在认识论上属于“先知后行”，而非“知行合一”。若仿真或采集平台与实际部署环境存在差异，便会引发“sim2real”、“real2real”的差距问题。



图 6 神经符号定义硬件：神经符号框架反向指导机器人硬件的设计。

从硬件设计角度看，我们认为某些因素阻碍了机器人的现场学习。首先是缺乏低成本、高可靠的安全机制。若直接使用现有机器人进行探索性训练，极易导致设备损坏，轻则系统重启，重则返厂维修，使得现场学习成本高昂。相比之下，人类凭借覆盖全身的触觉感知（可转化为痛觉）能在危险时及时终止动作，避免受伤。若为机器人设计类似的全方位安全感知系统，成本将极为高昂。而在神经符号框架下，由于系统预知机器人将要执行的动作原语，我们无需构建全身保护机制，仅需针对性设置局部保护，即可避免自我损坏。

其次，现有系统在现场学习中缺乏有效的闭环反馈。神经符号体系因具备动作原语与执行流，可预测谓词的变化路径，并在此路径上引入多元神经谓词，通过交叉验证实现闭环反馈。相比强化学习仅在任务完成时进行反向传播，我们的方法效率更高。

此外，神经符号以原语形式组织动作单元，具有良好的可扩展性。硬件设计也需支持灵活切换与扩展机制。在此硬件支撑下，神经符号任务规划不仅能在执行流中最大化可靠性，也为现场学习提供了可能。

以下通过一个简单示例说明，如图 7：机器人需将螺钉从初始状态拆解至目标状态。基于神经网络的任务规划首轮生成了“移动-对准-插入-拆解”序列，每一步均有神经谓词验证执行状态。前几步执行正常，但在插入步骤出现意外，

验证系统发现未能成功插入。为确保系统可靠性，机器人暂停原定拆解任务，转入重规划状态，通过探索重新对齐、再次插入并完成拆解。但在这一过程中，由于有前述硬件系统的支持，环境中部署的多元传感器为神经谓词提供了实时数据支撑。当我们对该过程进行反向回溯时，发现在某一环节的实际状态与预期不符，表明执行该动作时前一步所输出的条件判断存在偏差。因此，我们对这一判断进行了翻转，进而确认视觉识别结果是不准确的。而在后续通过力觉传感器重新规划的过程中，系统能够获取到更接近真实的数值。由此，形成了一个可在现场自主确定正确位置的闭环系统，从而实现了在真实环境中逐步提升性能的目标。

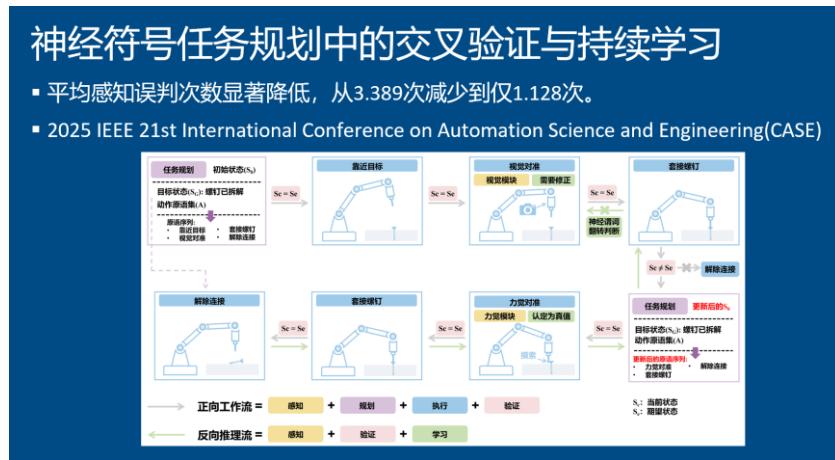


图 7 基于交叉验证闭环反馈的持续学习与性能提升。

综上所述，在神经符号定义硬件的支撑下，我们的任务规划架构虽与传统系统同样包含感知、规划与执行三部分，但因引入形式化语言而具备验证能力。验证过程中若发现问题，系统可及时重规划，并通过反向回溯实现持续学习，从而在“大脑”层面实现性能提升，如图 8。

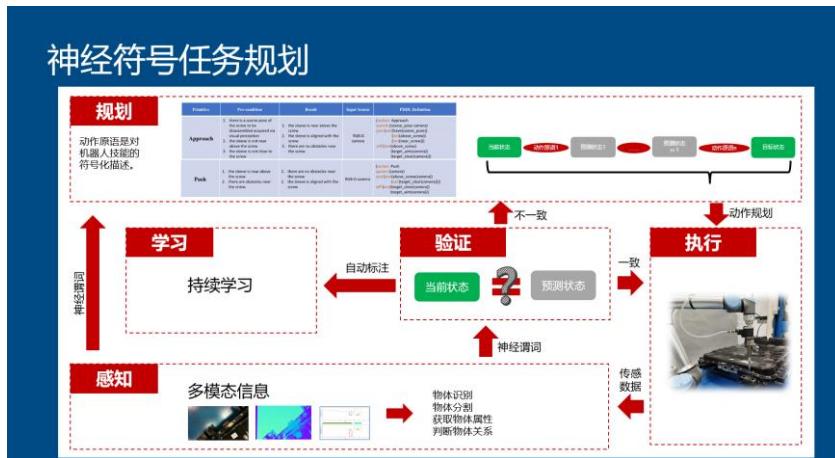


图 8 “神经符号定义硬件”支持下的任务规划架构，实现持续学习。

3、神经符号运动规划

神经符号运动规划负责决定如何具体执行任务。现有系统在发展过程中自然形成两类方法：一类是基于模型的预测控制（MPC），另一类是基于神经网络（NN）的强化学习或模仿学习，如图 9。这二者各有优劣。我们的解决思路是如何将二者桥接融合。



图 9 机器人运动规划途径：基于模型的方法（MPC）和基于学习的方法（NN）。

我们提出了一种基于编码器-解码器（encoder-decoder）的架构，如图 10。在神经网络领域，此类架构广泛应用于状态表征、高维映射及变分推断等任务。我们的创新在于：将解码器替换为基于 MPC 的模块，从而在联合训练过程中，将模型知识反向传播至编码器，实现“知识注入神经网络”。

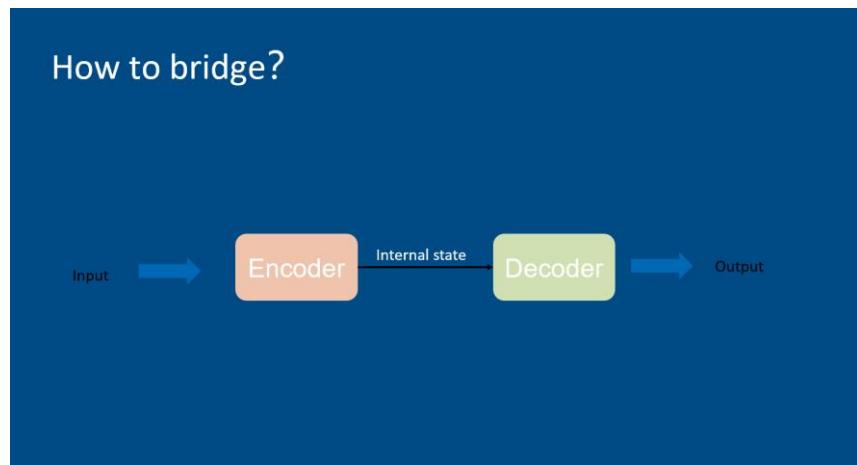


图 10 基于编码器-解码器（encoder-decoder）的运动规划架构。

如图 11，编码器部分（神经网络）将机器人目标转换为控制信号，但这仅完

成了编码过程。我们同时基于知识构建一个验证器，其作用类似于将数值代入方程检验。通过将输出值代入模型，我们可在模型层面评估其与预期值的偏差。若将此过程设计为可反向传播的系统，即可将偏差传回输出端，进而调整神经网络参数，实现知识的注入。

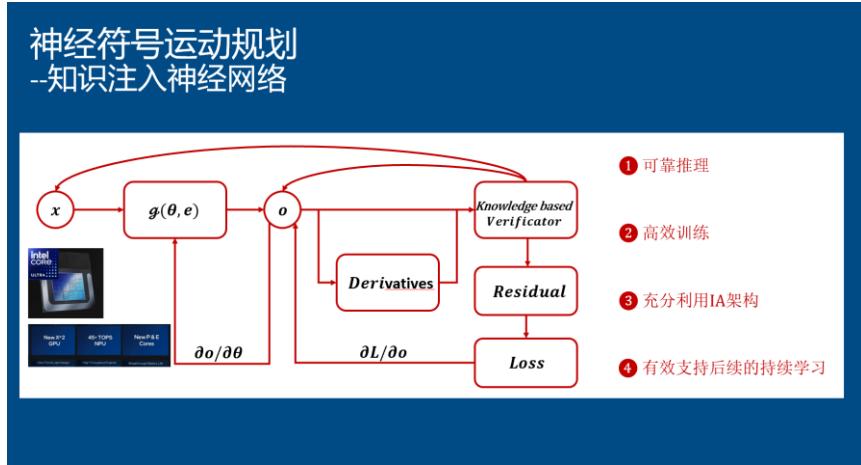


图 11 基于知识注入神经网络的神经符号运动规划。

该方法效率显著提升，原因在于每条数据均可基于知识偏差持续修正参数，指导网络如何调整以逼近正确值，形成“可靠推理、高效训练”的良性循环。值得一提的是，该架构中符号部分适用于 CPU 系统，神经网络部分适用于 GPU 系统，无需一味堆砌算力即可实现高效训练。

此外，知识注入后的网络还能克服传统基于知识的方法在噪声处理、建模不准及参数估计偏差等方面的局限。结合持续学习机制，现场采集的数据可有效支持模型迭代。实验结果表明（如图 12），该方法性能较传统模型方法提升 12 倍（因无需随机采样求解雅可比方程）；与传统强化学习相比，数据效率提升尤为显著，后者数据需求量高达我们的万倍以上，这为现场学习提供了重要支持。

目前，我们正尝试将静力学、动力学、臂型角、冗余角、运动去噪、支撑刚度等传统模型控制方法注入神经网络，以应对多样化任务。同时，探索与 VLA（视觉语言动作模型）及 RL（强化学习）的融合，进一步提升系统泛化能力。技术挑战主要在于构建可微系统，确保知识顺利注入神经网络。

回到拆解螺栓的应用场景，该任务对精度要求极高：距离误差需控制在毫米级，角度误差不超过 5°（角度）。我们的系统已能顺利完成此过程，其中的移动操作即基于运动学知识注入的神经网络实现快速决策。针对报废动力电池中因锈

蚀、腐蚀等需破坏性切割的情况，系统还集成了切割任务，通过静力学知识注入实现精准力控。

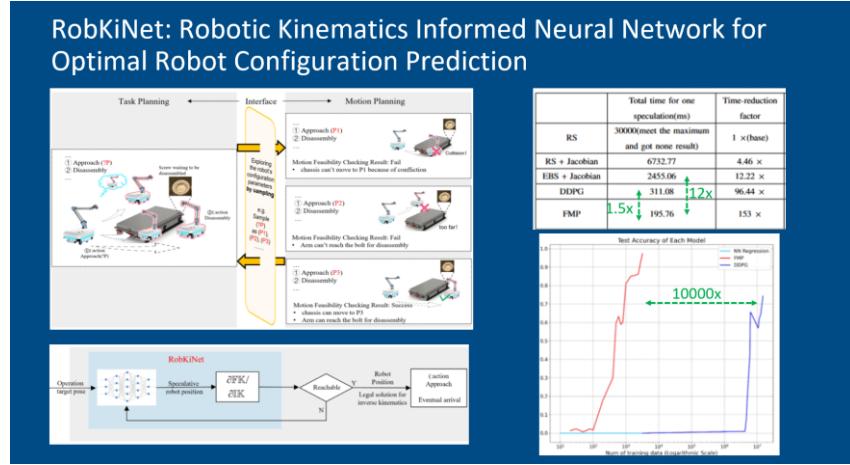


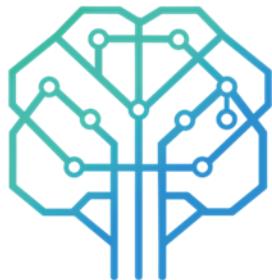
图 12 基于知识注入神经网络的机器人运动学——RobKiNet。

此外，系统支持多机器人协作拆解。在锈蚀场景中，若螺栓无法拆卸，则需先切割改造其形态（如改为一字槽），再行拆解。神经符号任务规划的可扩展性使其自然延伸至多机协同场景。目前，我们正进一步尝试引入人形机器人完成电池拆解后的卡扣、线束等操作，预计不久即可见到人形机器人应用于电池拆解产线。

结束语

神经符号系统虽有其优缺点，但与端到端大模型方法并不冲突。在通用智能尚未无所不能的当前阶段，神经符号有助于在真实环境中实现可靠、高效的部署，推动数据、本体与算法的闭环演进。极端而言，即便未来通用人工智能如瑞士军刀般集成多种工具，针对特定场景的专用工具（如剪刀、螺丝刀）仍不可替代。同样，通过规范化场景规划使机器人高效工作的神经符号技术，将持续助力机器人技术的进步。

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

(撰文 王志刚 英特尔中国研究院，责任编辑 曹晓舟，审核 刘永光)