

人机协同中的交互式学习

喻纯 王重阳 陈伟浩 潘立航
清华大学

前言

当我们将机器比作一位求学的学徒时，它获取基本常识或专业领域知识的主要途径无非是自学和请教老师。近期广受关注的大语言模型(Large Language Model, LLM)基于大规模数据集的预训练过程，如同学徒的“读万卷书”；而基于人类反馈的强化学习(RLHF)^[1]，则相当于学徒在课堂上向老师请教。最终，学徒毕业进入职场，但在与客户的交互中发现，从书本上和那里学到的知识要么不够用，要么不适用，以至于无法理解客户的具体需求和观点。这一例子揭示了以LLM为代表的机器智能在垂直领域中面临的现实瓶颈：在真实应用场景中，机器仍缺乏有效的学习路径来获取垂直领域知识或者个性化知识。那么，能否从以人为核心的人机交互(HCI)视角出发，突破这一瓶颈呢？本文将探讨一种新的机器学习范式——交互式学习，其核心在于通过人机自然交互过程，实现知识从用户到机器的高效传递，从而解决上述问题。我们将从人机协同的角度论证为什么交互式学习是克服现有模型训练局限、迈向通用智能的重要途径。

LLM时代下的人机交互

LLM时代下HCI研究的新机遇

人机交互旨在解决人类与机器之间的信息交换

问题，通过交互让机器服务于人，实现人类能力的增强(Intelligence Augmentation, IA)。大语言模型的出现，对人机交互领域产生了深远的影响。在近期人机交互工作中，LLM成功扮演了一个拥有通用知识的大脑，实现了对用户多种自然输入的语义理解、意图推理和交互规划，驱动了一系列复杂场景下的人机协同任务。

LLM提供语义交互推理能力。以交互意图推理为例，针对特定的任务，以往研究人员根据情境和数据的特点，设计相应的计算模型。在LLM提供的语义表征和计算能力基础之上，研究人员得以更加便利地使用LLM执行这部分推理任务，并开始转向研究如何更好地使用LLM完成这些任务，由此出现了一系列由LLM驱动实现的此前难以完成的交互功能和应用。Wang等人探索了基于LLM的智能终端交互，通过特殊的提示方法(prompt)，利用LLM的强大推理能力，实现了LLM与终端在界面信息与用户操作语义上的对齐，使系统可以直接使用用户的自然语言输入进行用户意图分析和操作执行^[2]。

LLM提升人机交互的效率。提高交互效率是一个经典的HCI问题，近期有研究人员利用LLM构建了以自然语言为介质的抽象匹配机制，建立一个用户与复杂代码系统沟通的工具，将用户丰富的自然表达映射为系统的可执行路径，从而在交互层面帮助用户回避偏向底层的基础处理逻辑，减轻其使用时的认知负荷^[3]。另有研究人员通过与医生协作，搭建了一个基于大语言模型的临床

记录管理系统^[4]，与以往需要医生主动输入的方案不同，该系统可以从医患之间的对话中自主提取并记录关键信息，事后还可以根据医生的提问生成对应的参考信息，极大提高了医生完成每日工作记录的效率。

总的来看，LLM的出现给HCI带来了更加强大的智能推理能力，面向人机物融合场景中复杂的交互场景，这二者的结合将激活更加深入的人机协同，推动人机关系的进一步发展。

HCI驱动的LLM新发展阶段

LLM也得益于HCI的研究进展。LLM在训练时已经包含了大量的人机交互过程，比如在基于人类反馈的强化学习中，就需要雇佣人类专家对回复进行高质量的标注，实现与人类价值的对齐。针对普通用户与LLM的交互，人机交互工作已经开始关注人与LLM智能体协同中涌现出的多种研究问题。比如，如何利用LLM的自然表达能力提高交互透明度以增强人机互信^[5]，以及如何通过对LLM的文本输出进行交互界面改造以提高交互体验与效率^[6]。随着交互形式和内容的进一步丰富，人类参与机器智能进化的路径会更加通畅，下一阶段智能发展的主要驱动力或许就来自于此。

交互式学习的内涵

计算机的发展始终与人的需求互促共生，而大模型带来的智能涌现，意味着人类社会生活中更广泛的需求将可以被AI解决。过去人类用户与固定、模式化的应用(application)交互的模式，将逐渐转变为与智能体(agent)交互的新模式。这些智能体具有天然的交互通道、准确的意图理解和高效的服务提供能力，其核心在于拥有提供这种高质量服务的知识。这些知识从何而来？现在默认的技术途径是数据驱动的方法，在数据专家完成大量任务数据的采集、筛选以及必要的标注之后，微调或从头训练大模型，使其适用于

不同的任务场景。虽然这种方法对具有通用性和普遍性的场景是有用的，但在现实高度细分和个性化的场景下，用户需求各异且动态变化，导致数据变得稀疏、不可靠，使周期长、离线异步的数据集成方法难以胜任。为突破这种局限，我们提出“交互式学习”——在人机协同的过程中实现人向机器自然传递知识，完成机器智能的进化。这种知识传递方式伴随于普通用户使用智能服务的自然交互过程，在真实使用场景下发生。

交互式学习发生于人机协同完成任务中，包括以下基本方面。

1. 知识类型(what)。机器需要学习关于人机协作任务的知识，即任务要解决什么问题(任务定义)和如何解决问题(任务路径)。

• 任务定义：学习要完成什么任务，即用户要解决的问题的计算定义，具体而言，就是对任务的输入、输出和评价指标进行计算建模。这是交互式学习所面对的独特挑战。传统机器学习往往考虑专家定义好的任务集合，但在真实场景中，用户需求是开放、复杂、动态变化的，机器无法直接通过匹配预定义任务来满足用户需求。因此，机器需要足够的知识，从庞大的任务空间中搜索出最符合用户目标的计算任务，将非结构化需求转换为结构化任务。真实的用户需求对应的计算任务具有可组合、流程化的特征，往往可以拆分、归纳为良好定义的基本计算任务。因此，任务的基本构成、组合方式、变体及其对应语义，是需要学习的内容。

• 任务路径：学习如何执行任务，即在定义好的任务上学习解决问题的方法。这不仅包括模型的选择、数据的采集或筛选、训练方式等，也需要考虑真实场景下的可用资源(数据成本、算力、时效性等)，在约束条件下进行高效学习和更新。此外，人机协作的分工策略也是任务路径中的重要知识。在任务的动态执行过程中，机器可能会遇到不确定的问题情境，需要向用户实时获取决策知识，例如向用户请求输入信息的具体语义、寻求机器执行任务的结果反馈等。

2. 知识来源 (where)。机器学习的知识主要来自用户和环境。用户能够提供“任务定义”的知识和部分“任务路径”的知识。但用户知识隐含在用户的行为(例如动作、触摸、语气)和表达(自然语言)之中,具有模糊、不准确、不完备的特点。理解这些信息需要外部知识的辅助。因此,以用户知识作为牵引,机器需要进一步从外部环境补充知识,例如从互联网、专家知识库、物理环境中获取额外的情境信息。

3. 知识表征 (how)。数据、规则和模型学习方法相结合,对机器而言,知识的表征和存储需要面向其未来的高效调用。无论是通过规则结构显式表达(例如图谱),还是通过神经元隐式表达(例如深度模型),这些知识按照任务需求的分布以不同的形式存储在机器内,以保证推理阶段知识使用效率最优。

可以看到,可支撑用户服务的高质量知识存在于人机物融合下的一个个场景中,需要机器超越现有的离线数据驱动模式,从自然人机交互中高效获取。因此,交互式学习将是大模型时代中机器学习的一种新的主要模式。在这种模式下,不仅机器的智能形态会发生变化,人的角色和行为也会发生改变。传统意义上的应用开发者将逐渐消失,未来终端用户将有机会参与到机器智能体的构建和发展过程中,人作为“用户”与“开发者”的角色将逐渐融合。此外,人与机器的交互关系也将超越当下机器解码意图到呈递服务的简单线性关系,上升为人机多轮互动、互相影响促进的协同关系。交互式学习智能体在给用户提供服务或建议的同时,也从用户的反馈中适应情境的不断变化,人机在彼此“商量”中互相协调、共同进步。

交互式学习的进展和未来

交互式学习研究的更大目标是催生一种更高级的人工智能形态:它拥有广泛的世界知识,在面对复杂场景的未见任务时,它可以在与人类的自然交互过程中主动学习并更新自己的知识和能力。但在

此之前,研究人员对交互式学习的探索还会面临诸多挑战。本文从理论上分析交互式学习领域的一些重要研究问题。

学习行为的发起

学习行为的发起即机器决定发起一个向人学习知识的交互时,其依据是什么?一种可能是对用户输入的不确定性度量,这里不确定性的来源,既可以是用户表达的自然语言中语义或意图的模糊,让机器无法依据当前既有知识完成下一步的针对性交互,亦可以是机器对用户非语言行为(如对某些应用的使用或已知习惯行为的突然改变等)背后意图的不理解。利用上述不确定性作为驱动,机器的知识学习过程便显得有迹可循。

研究案例 在这一方面,笔者团队发表于CHI 2022(人机交互领域最重要的国际会议)的工作^[7]探究了机器如何主动发起人机之间的信息交换来弥补自身能力的不足,解决用户自然语言指令难以被准确理解的问题,如图1所示。将用户指令映射到某个已知任务是自然语言界面正确处理用户输入的基础。然而,机器依赖于给定的语料、规则和模型,其自然语言指令理解的能力受限在某一预设范围之内;而用户的自然语言表达具有显著的灵活性和多样性,经常超出机器的能力范围。为了解决这一问题,文献[7]的工作提出了一种基于人机之间额外信息交换的、构建和提升指令理解能力的方法。在接收到用户指令之后,机器计算用户指令和所有候选任务间的语义相似度。相似度的分布表征了机器内部不确定性的分布:某一任务的相似度显著高于其他任务,意味着机器内部具有较低的不确定性;反之则意味着机器内部存在较高的不确定性。在这种情况下,机器会主动向用户提问,根据用户回答中包含的额外信息降低内部的不确定性。该工作使用信息熵理论将对话轮数降到最低,以减轻用户的交互负担:计算系统枚举所有可能的问题,估计用户对这些问题的答案能够带来的信息增益,并总是选取预期信息增益最大的答案。在正确完成指令理解之后,机器也会学习人机之间额外的对话过

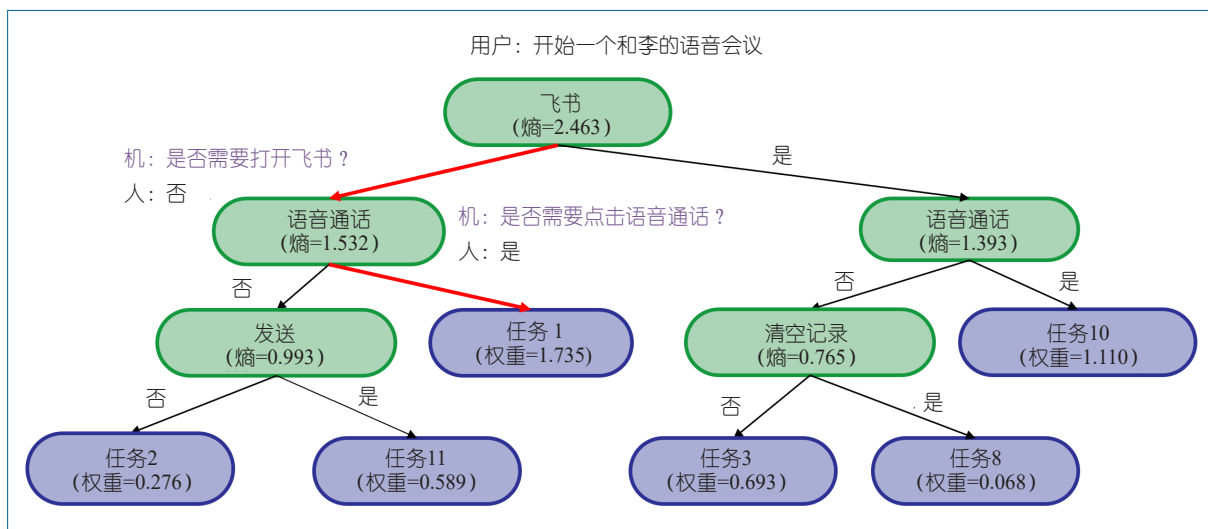


图1 语音助手场景中的交互式学习案例^[7]

程，包括：(1) 总结正则表达式模板，以便直接匹配用户指令；(2) 更新任务的语义建模，进而更加准确地计算用户指令和候选任务之间的语义相似度，更加准确地估计不同问题能够带来的信息增益。该工作支持主动发起人机对话来提高计算能力，使计算系统可以准确处理现实场景中任何超出预设能力范围的难题。

交互式学习中的用户门槛

交互式学习的发起没有功利性。换言之，机器发起交互式学习不是为了给一定存量的数据样本打上人为的标签信息，而更像是日常生活中人与人之间互相解答疑惑那样的简单、单一的自然行为。因此，交互式学习的发起，需要建立交互需求与用户认知负荷的平衡。这要求机器一方面能够像一个主动学习智能体那样，准确定位需要学习的内容并降低交互冗余，另一方面预测交互给用户带来的潜在负担。这里提到的负担，可能是用户在理解机器需求时的难度（人不明白机器的提问），也可能是用户提供特定形态知识的效率（人无法简单用语言回答机器）。对此，李飞飞团队探索了一种融入社交网络空间的交互式学习方法^[8]，与普通的众包标注方式不同，其训练的智能体能够在社交平台针对未见数据发布合适的问题，由此普通用户可方便地同其

互动并提供知识。实验结果表明，一个由自然交互赋能的社交式智能体，能够通过与普通用户的交互更高效地获取新知识。由此可见，如何降低普通用户的参与成本，建立更加高效的交互机制，是确保交互式学习高效进行的另一个基石。

通过人类的自然交互行为向机器传递知识

另一个可能对交互式学习效率造成影响的是机器对用户自然输入数据到机器可处理数据的转换。当前机器对于用户一般自然语言输入下的语义、知识提取和存储工作已经相当成熟，但在自然交互中，用户的输入形式和需求任务是非常丰富的，包括但不限于与智能终端界面交互时留下的交互行为（触控、键盘输入、应用或服务的使用习惯等），用户非语言通道下表达的动作、手势、眼动，甚至面部表情等。由于交互自然性是交互式学习需要重点考虑的因素，对以上用户自然表达行为中的意图和知识提取工作，以及利用多轮交互形成机器-用户的认知对齐，将有可能再次回到人机交互领域的舞台中央，对接下来交互式学习的高效建立起到关键作用。

研究案例 笔者团队发表于 UIST 2023(ACM 用户界面软件与技术研讨会)的工作^[9]探究了如

何利用机器感知的情境信息对用户自然语言表达做语义补充，解决了人机物融合场景下的个性化服务推荐问题。为克服用户、场景和设备差异及实际运行中的变化需求，机器必须支持终端用户参与个性化系统的构建。然而，在感知和理解情境，并形成有针对性的服务上，人机之间往往存在交流鸿沟：一般用户难以用语言准确、完整地表达自身需求，机器也难以将其需求转化为可计算的步骤。为解决这一问题，文献 [9] 提出一种基于交互式学习的方法 LangAware，允许终端用户在即时情境 (in-situ) 里通过自然语言对话建立情境 - 服务规则。如图 2 所示，当用户在操场跑步时，由于新消息提醒总是打断耳机里的音乐，用户可以对智能助手说 (见图 2 左侧)：“不要再打扰我。” 用户无须完整表达需求，LangAware 便会综合设备能感知到的情境信息 (例如时间、地点、运动状态、消息通知、外接设备等)，推理用户语言背后的隐含意思 (见图 2 中间)。这种交互式学习在交互效率上贡献的核心是，提出人机共享情境概念 (shared contextual concepts)，利用 LLM 将低级传感信息与高级语言概念进行语义上的连接。因此，系统可以推测出用户想要在“清晨跑步”“戴耳机听音乐”等多个条件下自动开启勿扰模式这一需求。在为用户提供可理解的自然语言反馈的同时，系统生成可供机器执行的规则代码 (见图 2 右侧)。在机器提供建议后，用户还可进一步对话或在图形界面上修改，以在协同中

构建最符合个性化需求的情境自动化服务。该工作让用户在少言甚至无言的情境下构建个性化服务，在保证用户对话体验的同时提升了交互式学习的效率。

综上所述，交互式学习中的机器学习行为既可以是主动的，也可以是被动的。除了交互过程中机器被动接收用户传递的信息外，机器应当自主发现自身知识与用户输入匹配下的不确定性，主动发起与用户的交互以寻求知识更新。而在交互的发起上，机器需要在合适的时机、以合适的形式请用户介入，同时必须在考虑知识收益最大化的基础上，最大程度地降低用户参与交互的成本。

从机器学习演变潮流看交互式学习：以人为中心的基本逻辑

接下来我们回顾机器智能过去几十年的发展历程，分析人机交互与机器学习结合下的交互式学习所蕴含的巨大潜力。机器学习作为人工智能领域的一个重要分支，经历了快速的发展和演变。从最初的符号学习到后来的统计学习，再到现在越来越多地关注从人的学习过程中汲取灵感的深度学习范式，我们见证了机器学习技术的一次次跨越。

模仿人类大脑的学习机制

在符号学习阶段，AI 研究集中在如何让计算机使用规则和逻辑模拟人类的决策过程。这种方



图2 用户使用LangAware^[9]的临境交互案例

法的优点在于透明度高，便于理解和解释，缺点是依赖大量的人工输入和规则设定，缺乏灵活性和泛化能力。随着计算能力的提升和数据量的增加，统计学习方法开始崭露头角，包括支持向量机（Support Vector Machines, SVMs）和随机森林（random forests）等算法。这些方法能够自动从数据中学习规律，具有更好的泛化能力。但它们在处理非结构化数据（如图像和自然语言）时仍面临挑战。作为现代统计学习的一个重要分支，深度学习通过使用模拟人脑生理结构的深度神经网络（Deep Neural Networks, DNNs）处理和学习大量非结构化数据。深度学习在图像识别、语音识别和自然语言处理等领域取得了巨大成功，但它的黑箱性质和对大量标注数据的依赖成为其主要缺点。

从人类用户获取知识

机器学习的演变逻辑反映了一个核心思路：如何更有效地模拟和利用人类智能。随着技术的发展，研究人员开始更多地关注人类是如何学习的，以及如何让人类特别是普通用户更好地教会机器学习。这种从人的学习过程中汲取灵感并让机器直接向人类学习知识的方法，旨在克服传统机器学习方法的局限性、提高学习效率、减少对标注数据的依赖、提高模型的解释性和离线训练后的在线进化能力。例如，在人类学习的启发下，研究人员提出了元学习方法^[10]，模仿人类利用已有知识学习新事物的能力，使机器学习模型能够通过少量的示例快速适应新任务。又如半监督式学习方法，强调让机器在处理大量未标注数据时，有效地利用少量有标签数据进行学习和推理。更有研究者近期从婴儿探索世界的过程中获得灵感，利用一个脖戴设备采集幼儿视角下的空间语义数据，并以此引导机器从简单的逻辑角度出发，由浅入深地学习物理世界知识^[11]。

像人类一样主动发问

除了优化机器在已有数据中学习知识的能力，研究人员开始转向让机器主动从人类本身获取知识，

其中的代表之一是主动学习（active learning）^[12-14]，让模型从未标注的数据中发掘最有价值的样本并让人类标注。早期工作一般期待专家用户（oracle）给出专业且逼近真值的标签，在人可以参与的形式上较为简单。随后有研究探索了面向普通用户的主动学习^[15]，以及基于自然语言的主动学习^[16, 17]，在交互自然性上有了显著提升。除了围绕标签信息补充的主动学习研究之外，近两年有一批工作让人类用户以自然语言形式参与机器人或一般智能体的任务执行过程^[18, 19]。特别地，人类用户提供的离散语义信息需要被进一步分析处理后才能得到机器所需的知识。这些是机器学习在自然交互上的重要进展。

从人工智能领域的发展过程中，我们不难看出，人类参与机器智能提升的方式在不断进化，从仅由专家提供知识到让普通用户参与，从简单的监督信号到自然语言反馈，总体上朝着自然交互和机器智能自主进化的方向发展。面向未来，交互式学习作为人机协同中的关键技术，将充分发挥现有机器学习方法的优势，并以自然交互方法建立机器智能与人类智能的广泛连接，推动 IA 和 AI 的共同发展。 ■



喻纯

CCF 杰出会员、人机交互专委会副主任。清华大学长聘副教授。主要研究方向为人机交互、普适计算。
chunyu@tsinghua.edu.cn



王重阳

CCF 专业会员。清华大学博士后。主要研究方向为人机交互与普适计算驱动的交互式智慧医疗，以及基于移动多模态机器人的交互式具身智能。
wangchongyang@tsinghua.edu.cn



陈伟浩

CCF 学生会员。清华大学计算机系博士生。主要研究方向为人机交互、人智协同。
chenwh20@mails.tsinghua.edu.cn

其他作者：潘立航

参考文献

- [1] CHRISTIANO PF, LEIKE J, BROWN T, et al. Deep reinforcement learning from human preferences[C]// Advances in Neural Information Processing Systems. 2017, 30: 1-9.
- [2] WANG B, LI G, LI Y. Enabling conversational interaction with mobile UI using large language models[C]// Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems. 2023: 1-17.
- [3] LIU MX, SARKAR A, NEGREANU C, et al. “What It Wants Me To Say” : Bridging the Abstraction Gap Between End-User Programmers and Code-Generating Large Language Models[C]// Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems. 2023: 1-31.
- [4] HAN J, PARK J, HUH J, et al. AscleAI: A LLM-based Clinical Note Management System for Enhancing Clinician Productivity[C]// Extended Abstracts of the CHI Conference on Human Factors in Computing Systems. 2024: 1-7.
- [5] WU T, TERRY M, CAI CJ. Ai chains: Transparent and controllable human-AI interaction by chaining large language model prompts[C]// Proceedings of the 2022 CHI Conference on Human Factors in Computing Systems. 2022: 1-22.
- [6] JIANG P, RAYAN J, DOW SP, et al. Graphologue: Exploring Large Language Model Responses with Interactive Diagrams[C]// Proceedings of the 36th Annual ACM Symposium on User Interface Software and Technology. 2023.
- [7] PAN L, YU C, LI J, et al. Automatically generating and improving voice command interface from operation sequences on smartphones[C]// Proceedings of the 2022 CHI Conference on Human Factors in Computing Systems. 2022.
- [8] KRISHNA R, LEE D, FEI-FEI L, et al. Socially situated artificial intelligence enables learning from human interaction[J]. Proceedings of the National Academy of Sciences, 2022, 119(39): e2115730119.
- [9] CHEN W, YU C, WANG H, Et al. From Gap to Synergy: Enhancing Contextual Understanding through Human-Machine Collaboration in Personalized Systems[C]// Proceedings of the 36th Annual ACM Symposium on User Interface Software and Technology. 2023.
- [10] HOSPEDALES T, ANTONIOU A, MICAELLI P, et al. Meta-learning in neural networks: A survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 44(9): 5149-5169.
- [11] VONG W, WANG W, ORHAN AE, et al. Grounded language acquisition through the eyes and ears of a single child[J]. Science, 2024, 383(6682): 504-511.
- [12] KAPOOR A, GRAUMAN K, URTASUN R, et al. Active learning with Gaussian processes for object categorization[C]// 2007 IEEE 11th International Conference on Computer Vision. 2007: 1-8.
- [13] LI X, GUO Y. Adaptive active learning for image classification[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2013: 859-866.
- [14] JOSHI AJ, PORIKLI F, PAPANIKOLOPOULOS N. Multi-class active learning for image classification[C]// 2009 IEEE Conference on Computer Vision and Pattern Recognition. 2009: 2372-2379.
- [15] ADAIMI R, THOMAZ E. Leveraging active learning and conditional mutual information to minimize data annotation in human activity recognition[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2019, 3(3): 1-23.
- [16] MISRA I, GIRSHICK R, FERGUS R, et al. Learning by asking questions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 11-20.
- [17] KRISHNA R, LEE D, FEI-FEI L, et al. Socially situated artificial intelligence enables learning from human interaction[J]. Proceedings of the National Academy of Sciences, 2022, 119(39): e2115730119.
- [18] NGUYEN KX, BISK Y, DAUMÉ H. A framework for learning to request rich and contextually useful information from humans[C]// International Conference on Machine Learning. 2022: 16553-16568.
- [19] SUMERS T, HAWKINS R, HO MK, et al. How to talk so AI will learn: Instructions, descriptions, and autonomy[C]// Advances in Neural Information Processing Systems. 2022, 35: 34762-34775.