

文章编号: 1003-0077(2026)01-0176-12

基于解题思维机制的大语言模型多项选择阅读理解增强框架

苏艺淞¹, 张元哲², 廖祥文¹, 卫一帆³, 刘康², 赵军²

(1. 福州大学 计算机与大数据学院, 福建 福州 350108;

2. 中国科学院 自动化研究所 复杂系统认知与决策实验室, 北京 100190;

3. 北京航空航天大学 计算机学院, 北京 100088)

摘要: 多项选择阅读理解任务目标是要求模型基于给定的文章和问题从候选选项中选择正确答案。已有工作表明, 尽管大语言模型在该项任务上已经达到最好性能, 但其缺乏激活选项相关的思维方式, 难以正确感知到给定文章、问题和选项之间的深层联系并充分利用候选选项信息, 故未能达到预期的性能。为此, 该文提出一种基于解题思维机制的大语言模型多项选择阅读理解增强框架。具体地, 该文考虑两种解题思维: 按步分析和选项评估, 分别从按步骤求解以获取正确选项和深入验证选项正误两方面提升大语言模型对于多项选择阅读理解题型的解题能力。为了合理利用这两种解题思维, 该文进一步提出了自我激活和教师蒸馏两种提升策略, 进一步提升大模型的解题效果。实验结果表明, 该文所提方法相对于已有基准在六个多项选择阅读理解数据集上的平均准确率和平均严格准确率分别提升了 22.61% 和 28.95%。

关键词: 思维链; 多项选择阅读理解; 问答

中图分类号: TP391

文献标识码: A

Facilitating Large Language Model-based Multiple-choice Reading Comprehension with Question-solving Thought

SU Yisong¹, ZHANG Yuanzhe², LIAO Xiangwen¹, WEI Yifan³, LIU Kang², ZHAO Jun²

(1. College of Computer and Data Science, Fuzhou University, Fuzhou, Fujian 350108, China;

2. The State key Laboratory of Management and Control for Complex Systems,
Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China;

3. School of Computer Science and Engineering, Beihang University, Beijing 100088, China)

Abstract: The goal of the Multiple-Choice Reading Comprehension (MCRC) task is to require a model to select the correct answer from a set of candidate options based on the given paragraph and question. Related work shows that although large language models (LLM) have achieved state-of-the-art performance on this task, the failure to activate option-related thought prevents them from correctly perceiving the deep connections between the passage, question, and options. To this end, we propose a LLM enhancement framework for MCRC based on Question-Solving Thought (QST). Specifically, two types of mechanism are considered in our work: step-by-step and option-by-option. Two methods are further proposed to better utilize these QSTs: Self Activate (SA) and Distill from Teacher (DT), which further boost the question-solving of the model. Experimental results demonstrate that our proposed approaches increase average accuracy and average accuracy-hard by 22.61% and 28.95% respectively, compared to existing baselines across six multiple-choice reading comprehension datasets.

Keywords: chain-of-thought; multiple-choice reading comprehension; question answering

收稿日期: 2024-10-18 定稿日期: 2025-01-08

基金项目: 国家自然科学基金(62476060)

0 引言

多项选择阅读理解 (Multiple-Choice Reading Comprehension, MCRC)^[1] 是检验模型自然语言理解和推理能力的常用手段,旨在评估模型根据给定的文章和问题从候选选项中选择正确答案的能力。大语言模型 (Large Language Model, LLM, 以下简称大模型) 由于其强大的自然语言理解能力,通常被认为可以回答多项选择阅读理解任务,多项选择阅读理解也是评价大模型能力的主要手段,如 Meta-AI、Google 等公司均使用 RACE^[2] 数据集来展示其模型的优越性。最新版本的 GPT-4、Qwen2-72B^① 等大模型也超越了传统方法如 Megatron-BERT^② 的性能。然而,已有工作^[3-5] 表明一些大模型在多项阅读理解任务上仍然和传统方法存在较大性能差距。

当前大模型回答多项选择阅读理解任务主要通过两种机制: ① 直接回答: 根据输入的文章、问题和选项,大模型直接输出答案,这种形式的答题性能与内部知识强相关; ② 思维链^[6] (Chain-of-Thought, CoT): 通过特定的提示词,如“Let’s think step by step”等,指示大模型对题目进行逐步思考后再得到答案。如图 1 所示,大模型在面对输入的问题、文章和选项时,通过直接回答的方式选择了错误选项 A; 而通过思维链的方式,围绕 B 选项进行了思考,不再检视更合适的选项,选择了错误选项 B。从这个例子可以看出,这两种机制并不能保证大模型能够精准推理出正确答案,模型未能感知到文章、问题和选项之间的深层联系,更没有充分对比选项之间的相同处与差异处,故未达到预期的性能。




图1 直接回答与思维链提示在 MCRC 任务上的局限性

为此, 本文提出一种利用解题思维 (Question-Solving Thought, QST) 的大模型多项选择阅读理解增强框架, 即要求大模型求解出正确选项的同时, 根据给定的所有选项, 阐明当前选择的思维过程。不同于已有的 CoT, 本文根据人类做多项选择阅读理解时的思维过程, 将 QST 分为两种类型: 按步分析和选项评估。前者是直接求解正确选项的思考方式, 旨在关注最合适的选项, 而对其他选项进行了粗略的审阅; 而后者分别分析各个选项的正误, 通过对比得到最终答案。如图 2 所示, 大模型在面对给定文章、问题和选项时, 使用按步分析的 QST, 模型准确地概述了文章的大意, 结合问题, 选择正确选项

D, 并简要地与其他选项进行了对比; 而使用选项评估的 QST 时, 模型根据文章和问题深入分析了每个选项, 根据文章内容对 A、B、C、D 四个候选标题进行了评价, 也选择正确答案 D 作为最佳标题。

为了让大模型充分利用解题思维 QST, 本文提出了两种简单有效的方法: 自我激活 (Self Activate, SA) 和教师蒸馏 (Distill from Teacher, DT)。它们以不同的方式使用按步分析和选项评估的 QST: ① SA 方法是一种提示学习方法, 可以激

① Qwen2 于 2024 年 7 月发布。

② Megatron-BERT 是 Mohammad Shoeybi 和 NVIDIA 于 2019 年 9 月共同提出的模型。




图2 按步分析与选项评估两种 QST 的示例

活模型自身的 QST 能力,如零样本(zero-shot)/少样本(few-shot)的思维链,指示模型按照 QST 分析问题,适用于能力较强的大模型。②DT 方法是一种 CoT 蒸馏方法,可以引导大模型从更强大的模型中学习使用 QST 的能力,适用于能力较弱的大模型。

本文在六个常用的 MCRC 数据集(RACE-M、RACE-H^[2]、CosmosQA^[7]、ReClor^[8]、LogiQA^[9]、LogiQA 2.0^[10])上进行对比实验。实验结果表明,SA 和 DT 方法在六个 MCRC 数据集上的平均准确率和平均严格准确率分别提升了 22.61% 和 28.95%。

本文的贡献如下:

(1) 本文针对当前大模型在面向多项选择阅读理解时能力偏弱的问题,提出一种利用解题思维(QST,分为按步分析和选项评估)的大模型多项选择阅读理解增强框架。

(2) 为了帮助大模型使用解题思维,本文提出了两种简单且高效的方法:自我激活(SA)和教师蒸馏(DT),这两种方法适用于不同能力大模型的性能提升。

(3) 在六个 MCRC 数据集上实验表明,SA 和 DT 方法平均准确率和平均严格准确率分别提升了 22.61% 和 28.95%,验证了本文方法的有效性。

1 相关研究

1.1 基于自然语言处理的多项选择阅读理解

已有多项选择阅读理解方法的主要思路是通过设计特定的<文章,问题,选项>三元组的匹配模块,提升模型对三元组的深入感知能力^[4-5]。当前大模型面对多项选择阅读理解任务一般是通过直接回

答,或者使用思维链(CoT)提示的形式激发大模型思考,这两种方法并不能像已有多项选择阅读理解方法一样深入感知文章,问题和选项三者之间的深层关系,故未能达到预期的性能。Laskar 等人^[3]对 ChatGPT 进行了各项能力的评估,其在 RACE-M 和 RACE-H 上的性能未达之前 Tay 等人提出的 UL2^[4]和 Jiang 等人提出的 ConvBERT^[5]。本文旨在利用 QST 来帮助大模型提升在多项选择阅读理解任务上的性能。

1.2 基于提示学习的大模型问答方法

在复杂推理领域,已有多人用基于提示学习的方法来激活大模型的思考能力:Yao 等人^[11]提出的思维树(Tree of thought, ToT)通过将思维链拓展成树状的形式,要求大模型在每次思考时生成多个候选思考步骤,形成树状的思考路径,从而搜索到最优的解答;Besta 等人提出的思维图(Graph of thought, GoT)^[12]则是在思维树的基础上再聚集了思考路径,得到了更加准确的答案。这些方法在如 GSM8K、MATH^[13]和 C-eval^[14]数据集上通过零样本/少样本提示词实现了自我增强。这些结果证明了大模型中自生成的思考过程对提升大模型问答性能的有效性。本文中提出的自我激活(SA),也是通过提示语学习,激活大模型在多项选择阅读理解任务上的相关思维,根据对应的 QST 描述及其数据进行思考,得到更加正确的答案。不同于一般的 CoT、ToT 以及 GoT,本文提出的 QST 主要针对多项选择阅读理解任务设计,通过 QST 使得大模型深入考量文章,问题和选项三者的关系,通过选项之间的对比来精确回答问题。

1.3 面向思维链的蒸馏方法

思维链^[6]提示允许生成式语言模型在预测答案之前先进行思考,然后再进行回答,从而提高模型的预测性能。思维链在大模型如 ChatGPT、GPT-4、Claude-2、PaLM-540B 等上表现出色,这些模型的思维能力可以蒸馏到中小型模型中,使这些模型也具备思维链能力。Chung 等人^[15]利用 ChatGPT 构造了思维链数据,对能力较弱的模型进行微调,使之具备思考能力;Ho 等人^[16]提出了思维链数据生成-筛选-训练框架,使用高质量的思维链数据训练,多个能力较弱的模型在多个数据集上的性能与当前主流模型不相上下;Shridhar 等人^[17]则对思维链本身进行了行为拆解,即拆分为问题分解和思考解答两个部分,并根据此分类利用 ChatGPT 构造相应的数据,微调得到负责问题分解以及思考解答的两个模型,使得整体的答题性能得到提升。这些研究表明,能力强大的模型生成的复杂思维对能力较弱的模型是有用的。本文中蒸馏其他模型的 QST 数据,允许大模型在作答之前为

多项选择阅读理解任务生成特定的思考过程。与之前的思维链蒸馏方法不同,本文提出的 DT 方法不蒸馏强大的大模型直接回答问题的能力,而是蒸馏强大的大模型的中间思考过程,避免潜在的答题性能的损耗。

2 方法

2.1 方法架构

本文方法主要包含三个模块:数据构造、自我激活(SA)和教师蒸馏(DT),如图3所示:①数据构造:利用 ChatGPT 和 GPT-4 生成相应的 QST 数据,以用于后续两种方法。②自我激活(SA):利用零样本提示的方法,或利用①中生成的 QST 数据作为样例,用少样本提示的方法引导大模型用 QST 回答问题,是对模型自身能力的激活。③教师蒸馏(DT):利用 CoT 蒸馏方法让大模型从更强大的大模型中直接蒸馏进行 QST 的能力,使大模型具备其原来没有的深入分析多项选择阅读理解的能力。




图3 自我激活(SA)和教师蒸馏(DT)方法的架构^①

① 原数据集为英文,为了方便阅读,本文将其翻译为中文展示。

本文从 RACE、CosmosQA、ReClor、LogiQA 和 LogiQA-2.0 的训练集构造实验所需的 QST 数据,如图 4 所示。上方灰色部分用于构造按步分析 QST 数据,通过使用预先设计好的提示词,让 ChatGPT 生成按步分析 QST 数据;下方灰色部分则用于构造选项评估的 QST 数据。由于选项评估 QST 更为复杂,单靠 ChatGPT 难以生成足够准确的思维过程数据,本文先用了 GPT-4 构造样例,再以此使用少样本指令指示 ChatGPT 进行生成,确保选项评估 QST 的质量和精确性。这种方法既充分利用了 GPT-4 的强大生成能力,又避免了直接使用 GPT-4 生成所有数据带来的高额开销。数据构造方法使用的提示词如表 1 所示。




图 4 数据创建流程图

表 1 生成按步分析和选项评估解题思维数据的提示词

解题思维类型	提示词
Step-by-step	Give a multiple-choice reading comprehension and its correct answer, I need you make an explanation for why choose the correct answer.
按步分析	给出一道阅读理解多项选择题及其正确答案,我需要解释为什么选择正确答案。
Option-by-option	Given a paragraph and multiple-choice options, provide an in-depth explanation analyzing each option's validity based on the passage. Identify the correct answer and explain why, while also detailing why the other options are incorrect. Here are five positive example:
选项评估	给定一个段落和多项选择选项,根据段落提供深入的解释,分析每个选项的有效性。找出正确答案并解释原因,同时详细说明为什么其他选项不正确。这里有五个正面的例子:

首先,对于按步分析 QST,本文要求 ChatGPT 基于问题和文章进行顺序思考,求解出正确答案的同时粗略审阅其他选项。为了保证按步分析 QST 数据的正确性,本文要求 ChatGPT 根据问题的标准答案进行反向推理,学习问题的解题思路。本文通过提供明确的提示词,确保 ChatGPT 在生成 QST 数据时严格按照步骤进行推理。具体的 QST 数据生成公式如式(1)所示。

$$X_{\text{QST-STEP}} = \underset{x}{\operatorname{argmax}} \prod_{i=0}^n p(x_i | P, Q, O, A, I_{\text{step}}, x_{<i}) \quad (1)$$

其中, P 是文章, Q 是问题, $O = \{o_1, o_2, \dots, o_i\}$ 是问题对应的选项, A 是样例的正确选项, I_{step} 是表 1 中按步分析的提示词, n 是 QST 生成的总长度, x_i 表示 QST 数据在顺序生成过程中的第 i 个 token, $x_{<i}$ 则表示已生成的前 $i-1$ 个 token, $X_{\text{QST-STEP}}$ 是根据该题目生成的按步分析 QST 数据。

其次,对于选项评估的 QST,本文要求 ChatGPT 分析各个选项并进行详细的判断,通过对比以确定正确选项。由于描述生成选项评估 QST 数据的指令过于复杂,零样本设置下 ChatGPT 生成的 QST 数据往往不能满足性能要求,因此本文采用少样本提示的生成策略。通过少样本提示的方法,引导 ChatGPT 生成更符合要求的选项评估 QST 数据。

首先,在零样本设置下利用 GPT-4 生成一部分高质量 QST 数据作为样例,并将这批数据称为集合 D_{shot} ,其中, $D_{\text{shot}} = \{P_{\text{shot}}^{(i)}, Q_{\text{shot}}^{(i)}, O_{\text{shot}}^{(i)}, A_{\text{shot}}^{(i)}\}_{i=1}^{N_{\text{shot}}}$ 。接下来,从 D_{shot} 中随机采样 5 个选项评估 QST 数据的示例,以此作为指导,使用 5-样本指令进一步引导 ChatGPT 生成符合要求的 QST,如式(2)所示。

$$X_{\text{QST-OPTION}} = \underset{x}{\operatorname{argmax}} \prod_{i=0}^n p(x_i | P, Q, O, A, S, I_{\text{option}}, x_{<i}) \quad (2)$$

其中, $S \in D_{\text{shot}}$ 是对应用于指导 ChatGPT 生成 QST 数据的示例。 I_{option} 则是表 1 中选项评估的提示词, $X_{\text{QST-OPTION}}$ 是根据该题目生成选项评估 QST 数据。

对于零样本和少样本设置下生成的选项评估 QST 数据,为了保证模型对所有选项都进行了思考,此生成步骤需要进行格式上的筛查,如图 5 所示。具体地,本文将 ChatGPT 和 GPT-4 的温度参数设置为 1.0,反复指示其生成选项评估的 QST 数据,直到符合格式要求为止。




图5 筛查选项评估 QST 数据的过程图

通过上述方法,本文从 RACE、CosmosQA、ReClor、LogiQA 和 LogiQA-2.0 的训练集中构造按步分析 QST 和选项评估 QST 数据各 9 866 条,分别称为集合 $D_{\text{QST-STEP}}$ 和集合 $D_{\text{QST-OPTION}}$ 。具体各个训练集在对应 QST 集合上的数据情况如表 2 所示。

表2 按步分析 QST 的数据情况(选项评估 QST 同下)

RACE-M	RACE-H	CosmosQA	ReClor	LogiQA	LogiQA 2.0
1 214	3 312	1 340	755	1 200	2 045

在数据创建完成后,这些数据将被用于本文提出的自我激活(2.2 节)和教师蒸馏(2.3 节)方法中。

2.2 自我激活(SA)

自我激活(SA)是通过零样本/少样本提示词激发模型思考的 CoT 方法。具体来说,在零样本的提示下,模型根据其描述,进行指定的 QST 类型思考,推理出正确的选项。在少样本提示下(本文采用 1-样本提示词),模型模仿提示词中来自集合 $D_{\text{QST-STEP}}$ (按步分析)或者 $D_{\text{QST-OPTION}}$ (选项评估)的样例进行思考,产生类似的推理路径,以更好地理解给定的文本段落。

在这一方法中,SA 提示词如表 3 所示,零样本的提示词指示模型对文章、问题和选项三者进行逐步思考(按步分析 QST),或者分析各个选项(选项评估 QST),根据模型自身生成的 QST 得到最佳的答案;1-样本的提示词包含一个来自集合 $D_{\text{QST-STEP}}$ 或者 $D_{\text{QST-OPTION}}$ 的五元组,模型参考这个五元组进行思考,能更加准确地理解文章、问题和选项三者之间的联系,选择正确的选项。

2.3 教师蒸馏(DT)

本文针对多项选择阅读理解任务,采用知识蒸馏(DT)的方法从教师模型中实现 CoT 思维过程数据的采集,包含模型微调(fine-tuning) $D_{\text{QST-STEP}}$ 或者

$D_{\text{QST-OPTION}}$ 的全部数据,用于微调一个小模型,提升小模型的 CoT 能力。为了提升教师蒸馏后模型的泛化性,本文只蒸馏 ChatGPT 的 CoT 能力,而不蒸馏其回答正确选项的能力,避免模型对 ChatGPT 的过拟合。

表3 使用自我激活(SA)指示模型 QST 思考的提示词

提示词类型	提示词
Zero-shot	For the given passage and question, use the provided options to determine the best answer. You should first think step by step/option-by-option and reach the best answer based on your thought.
零样本	对于给定的段落和问题,使用提供的选项来确定最佳答案。您应该首先逐步思考/分析各个选项,并根据您的想法得出最佳答案。
One-shot	For the given passage and question, you should think according to the thought provided in the previous examples and reach the best answer based on your thoughts. Previous example: $\{P_{\text{shot_sa}}, Q_{\text{shot_sa}}, O_{\text{shot_sa}}, R_{\text{shot_sa}}, A_{\text{shot_sa}}\}$
1-样本	对于给定的段落和问题,您应该按照前面示例中提供的理由进行思考,并根据您的想法得出最佳答案。之前的样例: $\{P_{\text{shot_sa}}, Q_{\text{shot_sa}}, O_{\text{shot_sa}}, R_{\text{shot_sa}}, A_{\text{shot_sa}}\}$

DT 训练使用的指令模板如表 4 所示, $\{P, Q, O\}$ 是具体题目对应的文章、问题和选项。本文使用 2.1 节生成的金标准 QST 作为输出标签进行训练,用于训练模型使用 QST 解答题目的能力。其中,微调 $D_{\text{QST-STEP}}$ 的全部数据使得模型获得逐步思考得到答案的能力;而微调 $D_{\text{QST-OPTION}}$ 的全部数据使得模型能仔细评估每个选项,综合考虑各个选项的优缺点,通过对比选择最适合的答案。

表 4 用于训练按步分析和选项评估 QST 的指令模板

解题思维类型	指令模板
Step-by-step	For the given paragraph and question, use the options presented to determine the best response. You should think step by step first and conclude a best answer based on your thought.
按步分析	对于给定的段落和问题,使用提供的选项来确定最佳答案。您应该首先逐步思考,并根据您的想法得出最佳答案。 输入: {P,Q,O} 请逐步思考问题:
Option-by-option	For the given paragraph and question, use the options presented to determine the best response. You should think option-by-option first and conclude a best answer based on your thought.
选项评估	对于给定的段落和问题,使用提供的选项来确定最佳答案。您应该首先逐个选项进行思考,然后根据您的想法得出最佳答案。 输入: {P,Q,O} 请独立地评估每个选项:

为了高效地微调大模型,本文使用了参数高效微调(Parameter-Efficient Fine-Tuning, PEFT)的方法 LoRA (Low-Rank Adaptation)^[18] 微调模型。低秩分解可以自适应地应用在 Transformer 注意力机制^[19] 中的计算 q, k, v 嵌入的权重矩阵 W_q, W_k 和 W_v 上。其中, $W_q, W_k, W_v \in \mathbb{R}^{d \times k}$ 。以 W_q 为例,假设前向传播更新的矩阵为 $\Delta W_q \in \mathbb{R}^{d \times k}$, 本文将 ΔW_q 分解为 $A_q \in \mathbb{R}^{r \times k}$ 和 $B_q \in \mathbb{R}^{d \times r}$ 两个矩阵。其中, A_q 是随机高斯分布初始化得到的矩阵, B_q 为零矩阵, $r \ll \min(d, k)$ 。故对于嵌入 $q = W_q x$, q 的前向传播被修改为 $q = W_q x + B_q A_q x$, 其中, x 为输入词嵌入向量。训练中的参数更新都应用在 A_q 和 B_q 两个矩阵上, 因而大大减少了训练需要的计算开销。此外, 本文使用 Flash-attention^[20] 加快注意力机制部分的计算速度, 从而加快整体的训练速度。

3 实验

3.1 实验设置

为了验证方法的有效性, 本文选择了六个不同难度的 MCRC 数据集。本文将这六个数据集分为中等难度(RACE-M、RACE-H^[2]、CosmosQA^[7])和困难难度(ReClor^[8]、LogiQA^[9]和 LogiQA 2.0^[10])。

RACE-M&RACE-H 来自中国初高中英语考试的真实测试题, 可以评估模型的段落理解能力和答题能力。同时, CosmosQA 也是一个多项选择的阅读理解数据集, 主要评估模型在段落中的常识理解能力。ReClor、LogiQA 和 LogiQA 2.0 的数据来源于真实的法律考试题, 测试模型从文章中进行逻辑推理的能力, 这使得它们相比前三个数据集更具挑战性。

对于 ReClor 和 CosmosQA, 本文在它们的验证集上进行实验, 而对于其他数据集, 我们使用它们的测试集进行实验。每个数据集的详细信息如表 5 所示。

表 5 用于本文实验测试的数据集规模

RACE-M	RACE-H	CosmosQA	ReClor	LogiQA	LogiQA-2.0
1 436	3 498	2 985	500	651	1 572

在 SA 方法中, 本文使用 ChatGPT (gpt-3.5-turbo-0613), Llama-2-13B 和 vicuna-13B-v1.1^[21] 作为本文的测试模型。其中, ChatGPT 使用的是 OpenAI 官方的 gpt-3.5-turbo-0613 接口在线进行推理, Llama-2-13B 和 vicuna-13B-v1.1 则是在一块 A100 上进行离线本地推理。

而在 DT 方法中, 由于 ChatGPT 未开源, 本文只用 Llama-2-13B 和 vicuna-13B-v1.1 进行 LoRA 训练。在使用 LoRA 训练时, LoRA 低秩分解的低秩数 r 为 16, 训练批次为 8, 都在一块 A100 上进行离线训练和推理。

本文使用 ChatGPT (gpt-3.5-turbo-0613), Llama-2-13B 和 vicuna-13B-v1.1 零样本/1-样本 直接回答的性能作为本文主实验的基线性能, 基线测试使用的提示词见附录 C^①。

3.2 实验指标

实验指标采用当前问答中常用的准确率(Acc)评估模型的答题能力, 另外, 本文还使用严格准确率(Acc-H)来评估模型的选项判断能力。

准确率 Acc 的计算方式如式(3)所示。

$$\text{Acc} = \frac{1}{n} \sum_{i=1}^n y_i \quad (3)$$

其中, n 是总题目数, 若模型预测的答案和标签一致, 则 $y_i = 1$, 否则 $y_i = 0$ 。

值得说明的是, 模型在回答多项选择阅读理解时, 会存在还没有正确理解所有的选项, 就直接做出选择

① https://pan.baidu.com/s/1eHljhIVZc_02MM0cXOpFNQ?pwd=fsj7 提取码: fsj7

的情况,因此,准确率 Acc 并不能完全检验模型是否正确理解了所有选项。为了衡量模型对选项的理解程度,本文使用严格准确率 Acc-H 来衡量模型对选项的判断能力。Acc-H 计算了模型判断各个选项正确的题目占总题目的比例,具体如式(4)所示。

$$\text{Acc-H} = \frac{1}{n} \sum_{i=1}^n \prod_{j=1}^k \text{judge}_{ij} \quad (4)$$

其中, k 是选项总数,若模型对选项的判断与标签一致,则 $\text{judge}_{ij} = 1$, 否则 $\text{judge}_{ij} = 0$, 即当且仅当模型对题目的各个选项判断都正确时,该题目才算正确。测量严格准确率使用的提示词见附录 C 的表 12 和附录 D 的表 13。

此外,为了方便描述实验中上述指标的变化情况,本文计算了各指标的平均结果,即平均准确率 (Average Acc) 和平均严格准确率 (Average Acc-H)。

3.3 实验结果分析

实际结果如表 6 所示。从结果中可以看出,按步分析 QST 侧重于帮助模型用正确选项回答问题,因此准确率更高,在 DT 部分分别使 Llama-2-13B 和

vicuna-13B-v1.1 平均提升准确率 22.61% 和 17.53%, 分别比选项评估 QST 平均多提升准确率 6.33% 和 7.69%。而选项评估的 QST 则侧重于帮助模型更好地理解选项,对各个选项给予正确的判断,因此严格准确率更高,在 DT 部分分别使 Llama-2-13B 和 vicuna-13B-v1.1 平均提升严格准确率 17.21% 和 28.95%, 分别比按步分析 QST 平均多提升严格准确率 14.12% 和 20.04%。

通过准确率指标来看,SA 没有让所有模型熟练运用选项评估的 QST 来解答问题,而激活按步分析的 QST 的指令相对简单,能使模型在多个数据集上有良好的性能,例如 ChatGPT 在 ReClor 数据集和 LogiQA-2.0 数据集上分别提升准确率 1.80% 和 4.14%。本文猜测激活选项评估的 QST 的提示词过于复杂,模型难以准确地执行,且模型在选项思考方面缺乏训练,不能准确地进行选项分析。而在 DT 部分间接验证了此猜测,对于 Llama-2-13B 和 vicuna-13B-v1.1,在微调其选项评估的 QST 后,多个数据集的严格准确率和准确率都有显著提高,详细分析见 3.3.1 节和 3.3.2 节。

表 6 主要实验结果

(a) 准确率结果

(单位: %)

	QST type	Average Acc	RACE-M Acc	RACE-H Acc	CosmosQA Acc	ReClor Acc	LogiQA Acc	LogiQA-2.0 Acc
Baseline(0-shot)								
Llama-2-13B	—	43.86	58.84	53.20	52.62	36.00	29.49	33.01
vicuna-13B-v1.1	—	47.13	65.87	58.29	56.48	39.00	28.87	34.28
ChatGPT	—	61.42	83.98	77.70	70.95	56.00	34.56	45.35
自我激活(SA)								
Llama-2-13B	按步分析	42.60	55.22	54.17	47.40	40.00	26.88	31.93
	(0-shot)	(-1.26)	(-3.62)	(+0.97)	(-5.22)	(+4.00)	(-2.61)	(-1.08)
	按步分析	43.28	57.45	58.57	48.74	36.00	28.57	30.40
	(1-shot)	(-0.56)	(-1.39)	(+5.37)	(-3.88)	—	(-0.92)	(-2.61)
	选项评估	42.93	60.30	52.97	45.49	35.40	29.33	34.09
	(1-shot).	(-0.93)	(+1.46)	(-0.23)	(-7.13)	(-0.60)	(-0.16)	(+1.08)
vicuna-13B-v1.1	按步分析	40.50	53.76	50.60	48.07	31.20	28.26	31.10
	(0-shot)	(-6.63)	(-12.11)	(-7.69)	(+8.41)	(-7.80)	(-0.61)	(-3.18)
	按步分析	47.77	63.99	59.91	57.92	40.80	28.57	35.43
	(1-shot)	(+0.64)	(-1.88)	(+1.62)	(+1.44)	(+1.80)	(-0.30)	(+1.15)
	选项评估	45.63	63.44	54.68	50.85	39.60	29.18	36.00
	(1-shot).	(-1.50)	(-2.43)	(-3.61)	(-5.63)	(+0.60)	(+0.31)	(+1.72)

续表

	QST type	Average Acc	RACE-M Acc	RACE-H Acc	CosmosQA Acc	ReClor Acc	LogiQA Acc	LogiQA-2.0 Acc
ChatGPT	按步分析	61.18	82.59	78.55	64.85	57.80	33.79	49.49
	(0-shot)	(−0.24)	(−1.39)	(+0.85)	(−6.10)	(+1.80)	(−0.77)	(+4.14)
	按步分析	55.23	82.10	77.13	73.90	55.20	37.32	49.04
	(1-shot)	(+1.01)	(−1.88)	(−0.57)	(+2.95)	(−0.80)	(+2.76)	(+3.69)
	选项评估	56.12	78.34	73.95	59.12	47.40	35.02	42.87
	(1-shot)	(−5.30)	(−5.64)	(−3.75)	(−11.83)	(−8.60)	(+0.46)	(−2.48)

教师蒸馏(DT)

Llama-2-13B	按步分析	66.47	74.67	77.50	77.58	66.60	46.69	55.78
		(+22.61)	(+15.83)	(+24.30)	(+24.96)	(+30.00)	(+17.20)	(+25.77)
	选项评估	60.14	75.27	68.83	67.77	56.40	42.08	50.50
		(+16.28)	(+14.43)	(+15.63)	(+15.15)	(+20.40)	(+12.59)	(+17.49)
vicuna-13B-v1.1	按步分析	64.66	79.80	75.78	73.06	61.00	44.54	53.75
		(+17.53)	(+13.93)	(+17.49)	(+16.58)	(+22.00)	(+15.67)	(+19.47)
	选项评估	56.97	71.86	67.09	61.90	53.20	40.86	46.88
		(+9.84)	(+5.99)	(+8.80)	(+5.42)	(+14.20)	(+11.99)	(+12.60)

(b) 严格准确率结果

(单位: %)

	QST type	Average Acc-H	RACE-M Acc-H	RACE-H Acc-H	CosmosQA Acc-H	ReClor Acc-H	LogiQA Acc-H	LogiQA-2.0 Acc-H
Baseline(0-shot)								
Llama-2-13B	—	22.67	29.38	12.57	43.31	19.60	13.51	17.62
vicuna-13B-v1.1	—	5.09	5.84	2.74	12.12	2.80	3.22	3.81
ChatGPT	—	35.60	58.98	45.48	48.17	27.20	14.74	19.02

自我激活(SA)

Llama-2-13B	按步分析	12.22	9.54	5.46	26.46	12.80	8.44	10.62
	(0-shot)	(−10.45)	(−19.84)	(−7.11)	(−16.85)	(−6.80)	(−5.07)	(−7.00)
	按步分析	0.42	0.13	0.17	0.63	0.60	0.46	0.50
	(1-shot)	(−22.25)	(−29.25)	(−12.40)	(−42.68)	(−19.00)	(−13.05)	(−17.12)
	选项评估	23.90	32.59	30.16	29.31	19.80	17.51	14.05
	(1-shot)	(+1.23)	(+3.21)	(+17.59)	(−14.00)	(+0.20)	(+4.00)	(−3.57)
vicuna-13B-v1.1	按步分析	8.62	9.54	6.31	16.64	6.80	5.52	6.93
	(0-shot)	(+3.53)	(+3.70)	(+3.57)	(+4.52)	(+4.00)	(+2.30)	(+3.12)
	按步分析	6.31	4.94	5.66	11.25	6.20	4.14	5.72
	(1-shot)	(+1.22)	(−0.90)	(+2.92)	(−0.87)	(+3.40)	(+0.92)	(+1.91)
	选项评估	12.92	15.38	3.45	23.88	14.40	9.52	10.87
	(1-shot)	(+7.83)	(+9.54)	(+0.71)	(+11.76)	(+11.60)	(+6.30)	(+7.06)

续表

	QST type	Average Acc-H	RACE-M Acc-H	RACE-H Acc-H	CosmosQA Acc-H	ReClor Acc-H	LogiQA Acc-H	LogiQA-2.0 Acc-H
ChatGPT	按步分析	55.78	59.19	48.94	96.44	90.80	18.27	21.05
	(0-shot)	(+20.18)	(+0.21)	(+3.46)	(+48.27)	(+63.60)	(+3.53)	(+2.03)
	按步分析	42.55	55.29	48.86	56.71	38.20	22.42	33.84
	(1-shot)	(+6.95)	(-3.69)	(+3.38)	(+8.54)	(+11.00)	(+7.68)	(+14.82)
	选项评估	54.46	56.68	45.85	95.27	89.60	18.74	20.61
	(1-shot)	(+18.86)	(-2.30)	(+0.37)	(+47.10)	(+62.40)	(+4.00)	(+1.59)
教师蒸馏(DT)								
Llama-2-13B	按步分析	25.76	20.33	25.47	35.41	? 27.20	23.35	22.77
		(+3.09)	(-9.05)	(+12.90)	(-7.90)	(+7.60)	(+9.84)	(+5.15)
	选项评估	39.91	59.89	51.69	32.33	40.40	22.89	32.25
		(+17.21)	(+30.51)	(+39.32)	(-10.98)	(+20.80)	(+9.38)	(+14.63)
vicuna-13B-v1.1	按步分析	14.00	14.13	12.24	23.28	12.60	10.60	11.13
		(+8.91)	(+8.29)	(+9.5)	(+11.16)	(+9.80)	(+7.38)	(+7.32)
	选项评估	34.04	49.72	42.62	42.11	25.40	21.04	23.35
		(+28.95)	(+43.88)	(+39.88)	(+29.99)	(+22.60)	(+17.82)	(+19.74)

3.3.1 自我激活(SA)

SA 的实验结果如表 6 所示,本文测试了 ChatGPT、Llama-2-13B 和 vicuna-13B-v1.1 在使用按步分析 QST 和选项评估 QST 后在各个数据集的性能。具体来说,Llama-2-13B、vicuna-13B-v1.1 和 ChatGPT 在零样本提示下使用按步解析 QST 后平均准确率都出现了微弱的下降,分别下降 1.26%,6.63%和 0.24%。对于中等难度的数据集(RACE-M、RACE-H、CosmosQA),Llama-2-13B、vicuna-13B-v1.1 和 ChatGPT 的性能提升不显著;而在困难部分的数据集(ReClor、LogiQA、LogiQA-2.0)上的性能表现不佳,我们猜测其中的原因是困难数据集中大部分题目都要求较高的推理能力,按步分析并没有做到精细的选项分析。

而在严格准确率方面,Llama-2-13B 在各个数据集上性能都有所下降,平均准确率下降 10.45%,vicuna-13B-v1.1 和 ChatGPT 则是在所有数据集上性能有所提升,平均准确率分别提升了 3.53%和 20.18%。

在少样本提示的实验中,模型模仿 ChatGPT 生成的 QST 表现出不同的结果:

(1) 对于 Llama-2-13B,在 RACE-M 上,按步分析的 QST 使 Llama-2-13B 在准确率上小幅降低

(-1.39%),而在 RACE-H 上,选项评估 QST 使 Llama-2-13B 提高了准确率(+1.46%)。在严格准确率方面,按步分析 QST 造成了 Llama-2-13B 性能的显著下降,在不同数据集上准确率下降 12.40%到 42.68%,但选项评估 QST 帮助 Llama-2-13B 在 RACE-M 和 LogiQA 数据集中性能有所提升,准确率分别提升了 1.46%和 1.08%。

(2) 类似的结论也在 vicuna-13b-v1.1 的实验上得出:按步分析 QST 使 vicuna-13b-v1.1 在 RACE-H、CosmosQA、ReClor 和 LogiQA-2.0 上小幅提升了准确率,分别提升了 1.62%,1.44%,1.80%和 1.15%。选项评估 QST 则在 ReClor、LogiQA 和 LogiQA-2.0 上提升了准确率,分别提升了 0.60%,0.31%和 1.72%。在严格准确率方面,按步分析 QST 在各个数据集上平均提升准确率 1.22%,而选项评估 QST 帮助 vicuna-13b-v1.1 在所有数据集上提高了 6.30%以上的性能。

(3) 类似地,ChatGPT 在按步分析 QST 和选项评估 QST 帮助下获得的提升较少,在各个数据集的平均准确率上甚至有所下降,分别提升 1.01%和下降 5.30%。但在多个数据集上严格准确率提升明显,分别平均提升了 6.95%和 18.86%。

对于 SA 提升模型性能不稳定的问题,本文推

测当前的模型尚未专门学习分析每个选项的能力，这在 3.3.2 节中间接得到了验证。

3.3.2 教师蒸馏(DT)

根据 2.4 节方法,本文在 DT 方法中,从实验使用的六个数据集的训练集中随机抽取了一些数据,使用的训练数据分布如表 7 所示。各个子训练集的规模是根据难度和训练集原本的规模进行加权计算得到。

表 7 训练集具体组成

Middle			Hard		
RACE-M	RACE-H	CosmosQA	ReClor	LogiQA	LogiQA-2.0
1 214	3 312	1 340	755	1 200	2 045

DT 的实验结果如表 6 所示,在蒸馏了由 ChatGPT 生成的 QST 之后,Llama-2-13B 和 vicuna-13B-v1.1 都能够更深入地分析段落,并在整个实验中达到最佳性能。

(1) Llama-2-13B 在经过从 ChatGPT 中蒸馏了按步分析 QST 数据训练后,在所有六个数据集上准确率提高了 15.83% 以上,而 vicuna-13B-v1.1 则提高了 13.93% 以上。在严格准确率方面,总体来说,按步分析 QST 使两个模型在多个数据集上性能都有所提升,平均严格准确率分别提升了 3.09% 和 8.91%,这说明按步分析 QST 帮助模型粗略审阅了选项,而 Llama-2-13B 在 RACE-M 和 CosmosQA 上严格准确率有所下降,分别下降 9.05% 和 7.90%,也说明粗略的审阅并不能保证模型能对各个选项做出足够精确的判断。

(2) 在经过从 ChatGPT 中蒸馏了选项评估 QST 数据训练后,Llama-2-13B 和 vicuna-13B-v1.1 在六个数据集上的准确率分别提高了 12.59% 以上和 5.42% 以上。在严格准确率方面,Llama-2-13B 和 vicuna-13B-v1.1 的性能都有大幅提升,平均严格准确率分别提升了 17.21% 和 28.95%,远超按步分析 QST 对各个模型带来的提升。此外,在多个数据集上模型的判断各个选项正误的能力也有所提升,例如 Llama-2-13B 在 RACE-M 数据集上严格准确率由下降 9.05% 变为提升 30.51%,说明了选项评估 QST 能帮助模型对各个选项做出更加精细的判断。

(3) 无论何种 QST,通过 DT 后均能提升模型性能,这证明了对于多项选择阅读理解任务考虑解题思维过程的重要性。除此之外,DT 方法相比 SA 方法,能稳定大幅提升大模型的思考性能,两个模型

上的平均准确率分别多提升了 14.12% 和 20.04%,这间接证明了本文假设,即大模型可能并未完全掌握与任务相关的思维能力。

4 讨论

本节讨论为什么两种 QST 在 SA 部分不能显著提升模型性能(见 4.1 节,其中着重讨论了选项评估 QST)。此外,本节还列出了本文方法的消融实验(见 4.2 节)。

4.1 SA 方法问题原因分析

首先,本文猜测 SA 方法生成的 QST 质量不佳,因此本文用 ChatGPT 在 RACE-M、CosmosQA 和 ReClor 数据集中生成 QST 数据来代替 SA 方法生成的 QST 数据,对比结果如表 8 所示。结果显示 Llama-2-13B 和 vicuna-13B-v1.1 在使用由 ChatGPT 生成的 QST 数据后能更好地回答多项选择阅读理解任务,这验证了我们的猜测。

表 8 自我激活(SA)阶段使用 ChatGPT 的 QST 性能对比

(a) 准确率对比 (单位: %)			
Llama-2-13B	CosmosQA	ReClor	LogiQA-2.0
按步分析	48.74	36.00	30.40
按步分析(ChatGPT)	64.32 ↑	58.20 ↑	48.91 ↑
选项评估	45.49	35.40	34.09
选项评估(ChatGPT)	60.13 ↑	46.00 ↑	39.94 ↑
(b) 严格准确率对比 (单位: %)			
Llama-2-13B	CosmosQA	ReClor	LogiQA-2.0
按步分析	0.63	0.60	0.50
按步分析(ChatGPT)	56.81 ↑	40.60 ↑	30.08 ↑
选项评估	29.31	19.80	14.05
选项评估(ChatGPT)	44.38 ↑	31.00 ↑	23.40 ↑

4.2 选项评估 QST 的消融实验

为了验证选项评估 QST 能有效帮助模型判断各个选项,本文移除其中一个选项的 QST 数据进行消融实验。移除策略分为两种:移除正确选项的 QST(-正确选项)和移除随机选项的 QST(-随机选项),前者移除的是模型认为正确的选项的 QST 数据,后者则随机移除其中一个选项的 QST 数据。

在 RACE-M 和 ReClor 数据集上的实验结果如

表 9 所示。在随机移除其中一个选项的 QST 后,在 vicuna-13b-v1.1 上的准确率有所下降,说明其他候选选项的 QST 对选项评估 QST 的有效性。相比之下,移除正确选项的 QST 后,Vicuna-13b-v1.1 的准确率大幅下降,说明正确选项的 QST 对于选项评估 QST 的必要性。此外,本文通过附录 A 中的表 10 展示了其中一个样例,验证了正确选项的 QST 与候选选项的 QST 对模型进行选项分析的重要性。

表 9 在 DT 方法对选项评估 QST 的消融实验(准确率)
(单位: %)

Vicuna-13B-v1.1	RACE-M	ReClor
选项评估	71.86	53.20
—正确选项	24.51 (−47.35)	28.40 (−24.80)
—随机选项	57.72 (−14.14)	45.20 (−8.00)

5 结论

本文引入了解题思维(QST)以提升大模型在多项选择阅读理解方面的思考能力。本文提出了两种 QST: 按步分析和选项评估。前者更关注求解正确选项以回答问题,并粗略地审阅了其他选项,而后者则更关注判断每个选项的正确性,通过比较选项得到最合适的答案。本文通过使用自我激活(SA)和教师蒸馏(DT)这两种简单但高效的方法利用了这两种 QST 的数据,并在六个难度不同的多项阅读理解数据集上验证了其有效性。实验结果表明,对大模型进行中间思考过程的微调(即 DT),能使大模型表现得更好,按步分析的 QST 和选项评估的 QST 都大幅提升了模型的性能。

参考文献

- [1] DZENDZIK D, FOSTER J, VOGEL C. English machine reading comprehension datasets: A survey [C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing, 2021: 8784-8804.
- [2] LAI G, XIE Q, LIU H, et al. RACE: Large-scale reading comprehension dataset from examinations [C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing, 2017: 785-794.
- [3] LASKAR M T R, BARI M S, RAHMAN M, et al. A systematic study and comprehensive evaluation of chatgpt on benchmark datasets [C]//Proceedings of the Association for Computational Linguistics, 2023: 431-469.
- [4] TAY Y, DEGHANI M, TRAN V Q, et al. UL2: Unifying language learning paradigms[C]//Proceedings of the 11th International Conference on Learning Representations, 2023.
- [5] JIANG Z H, YU W, ZHOU D, et al. ConvBERT: Improving bert with span-based dynamic convolution[J]. Advances in Neural Information Processing Systems, 2020, 33: 12837-12848.
- [6] WEI J, WANG X, SCHUURMANS D, et al. Chain-of-thought prompting elicits reasoning in large language models[J]. Advances in Neural Information Processing Systems, 2022, 35: 24824-24837.
- [7] HUANG L, LE BRAS R, BHAGAVATULA C, et al. Cosmos QA: Machine reading comprehension with contextual commonsense reasoning [C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing, 2019: 2391-2401.
- [8] YU W, JIANG Z, DONG Y, et al. ReClor: A reading comprehension dataset requiring logical reasoning [C]//Proceedings of the International Conference on Learning Representations, 2020.
- [9] LIU J, CUI L, LIU H, et al. LogiQA: A challenge dataset for machine reading comprehension with logical reasoning [C]//Proceedings of the 29th International Joint Conference on Artificial Intelligence, 2020: 3622-3628.
- [10] LIU H, LIU J, CUI L, et al. LogiQA 2.0: An improved dataset for logical reasoning in natural language understanding [C]//Proceedings of the IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2023.
- [11] YAO S, YU D, ZHAO J, et al. Tree of thoughts: Deliberate problem solving with large language models [C]//Proceedings of the Advances in Neural Information Processing Systems, 2024.
- [12] BESTA M, BLACH N, KUBICEK A, et al. Graph of thoughts: Solving elaborate problems with large language models [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2024, 38(16): 17682-17690.
- [13] HENDRYCKS D, BURNS C, KADAVATH S, et al. Measuring mathematical problem solving with the math dataset[J]. Sort, 2(4): 1-6.
- [14] HUANG Y, BAI Y, ZHU Z, et al. C-eval: A multi-level multi-discipline chinese evaluation suite for foundation models [C]//Proceedings of the Advances in Neural Information Processing Systems, 2024.

(下转第 206 页)

- [28] ZHANG Z, MAI W, XIONG H, et al. A token-wise graph-based framework for multimodal named entity recognition [C]//Proceedings of the International Conference on Multimedia and Expo. IEEE, 2023: 2153-2158.

- [29] CHENG J, LONG K, ZHANG S, et al. Text-image scene graph fusion for multi-modal named entity

recognition [C]//Proceedings of the IEEE Transactions on Artificial Intelligence, 2023.

- [30] CHEN J, XUE Y, ZHANG H, et al. On development of multimodal named entity recognition using part-of-speech and mixture of experts[J]. International Journal of Machine Learning and Cybernetics, 2023, 14(6): 2181-2192.



彭魁(1997—), 硕士, 主要研究领域为自然语言处理、多模态命名实体识别。

E-mail: pk2360236826@163.com



刘杰(1970—), 通信作者, 博士, 教授, 博士生导师, 主要研究领域为自然语言处理、知识工程、知识图谱等。

E-mail: liujxxy@126.com



许明英(1987—), 博士, 讲师, 主要研究领域为自然语言处理、人工智能、多模态学习。

E-mail: xumingying@ncut.edu.cn

(上接第 187 页)

- [15] CHUNG H W, HOU L, LONGPRE S, et al. Scaling instruction-finetuned language models [J]. Journal of Machine Learning Research, 2024, 25(70): 1-53.

- [16] HO N, SCHMID L, YUN S Y. Large language models are reasoning teachers [C]//Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics, 2023: 14852-14882.

- [17] SHRIDHAR K, STOLFO A, SACHAN M. Distilling reasoning capabilities into smaller language models [C]//Proceedings of the Association for Computational Linguistics, 2023: 7059-7073.

- [18] HU E J, WALLIS P, ALLEN ZHU Z, et al. LoRA: Low-rank adaptation of large language models [C]//

Proceedings of the International Conference on Learning Representations, 2022.

- [19] VASWANI A. Attention is all you need [C]//Proceedings of the Advances in Neural Information Processing Systems, 2017.

- [20] DAO T, FU D, ERMON S, et al. Flash-attention: Fast and memory-efficient exact attention with io-awareness [C]//Proceedings of the Advances in Neural Information Processing Systems, 2022, 35: 16344-16359.

- [21] ZHENG L, CHIANG W L, SHENG Y, et al. Judging LLM-as-a-judge with mt-bench and chatbot arena [C]//Proceedings of the Advances in Neural Information Processing Systems, 2024.



苏艺淞(2000—), 硕士, 主要研究领域为大语言模型和问答。

E-mail: 221020042@fzu.edu.cn



廖祥文(1980—), 通信作者, 博士, 教授, 主要研究领域为自然语言处理、信息检索、社会计算和网络内容安全。

E-mail: liaoxw@fzu.edu.cn



张元哲(1986—), 博士, 副研究员, 主要研究领域为自然语言处理、知识工程、可解释性研究。

E-mail: yuanyzhe.zhang@ia.ac.cn