

基于心理咨询大模型的相对熵文本生成

周炎词, 杨俊文, 李伊劲, 朱国华

(江汉大学人工智能学院, 湖北 武汉 430056)

摘要: 目前, 通用大模型领域面临着特定知识不足、生成内容不可控的问题。为解决上述问题, 使用参数高效微调方法训练出大型语言模型 Psh-LLaMA3, 使其具备心理咨询领域的知识, 随后基于相对熵控制文本生成算法 CTGRE 实现模型的可控性生成。各项任务测试及文本生成任务结果表明, Psh-LLaMA3 在心理咨询任务中的生成文本质量优于基准模型, 在 ROUGE-1 评估指标上相较基准模型提升了 4%, 结合 CTGRE 算法后进一步提升了 2%, 展现出 CTGRE 算法在优化文本生成属性控制和提升情感表达精度方面的有效性。

关键词: 领域模型; 参数微调; 控制算法; 可控生成

DOI: 10.11907/rjdk.241909

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2025)012-0133-07

扫描二维码阅读全文:



Relative Entropy Text Generation Based on the Large Language Model of Psychological Counseling

ZHOU Yanci, YANG Junwen, LI Yijin, ZHU Guohua

(College of Artificial Intelligence, Jiangnan University, Wuhan 430056, China)

Abstract: At present, the field of general large models is facing the problems of insufficient specific knowledge and uncontrollable content generation. To solve the above problems, a parameter efficient fine-tuning method is used to train the large language model Psh-LLaMA3, which has knowledge in the field of psychological counseling. Then, based on the relative entropy control text generation algorithm CTGRE, the controllability of the model is achieved. The results of various task tests and text generation tasks show that Psh-LLaMA3 outperforms the benchmark model in generating text quality in psychological counseling tasks, with a 4% improvement in the ROUGE-1 evaluation index compared to the benchmark model. Combined with the CTGRE algorithm, it further improves by 2%, demonstrating the effectiveness of the CTGRE algorithm in optimizing text generation attribute control and improving emotional expression accuracy.

Key Words: domain-specific model; parameter-efficient fine-tuning; control algorithm; controllable generation

0 引言

近年来, 大型语言模型凭借其卓越的跨任务泛化能力引发广泛关注, 诸多主流模型在通用文本处理领域展现出显著优势。这些模型经过海量文本数据的训练, 具备了生成连贯且语义丰富的文本的能力, 广泛应用于机器翻译、问答系统、对话生成等领域。然而, 当这些模型被应用到特定领域的任务时, 往往面临着内容不可控、偏离目标任

务需求的问题, 导致生成文本的可靠性和实用性受到限制。

为推动大型语言模型在垂直领域的专业化应用, 模型微调 (Fine-tuning) 技术因其能够有效适配领域知识、提升任务适配性, 已成为当前研究与实践的核心方向之一。例如, Houlsby 等^[1]提出一种参数高效的迁移学习方法, 即使使用适配器模块 (Adapter Modules) 进行迁移。相比于传统的微调方法, 适配器模块只需为每个任务添加少量可训练参数, 且可以在不影响先前任务表现的情况下添加新任务。

收稿日期: 2024-10-27

基金项目: 江汉大学学科特色专项 (2022XKZX11)

作者简介: 周炎词 (2000-), 男, 江汉大学人工智能学院硕士研究生, 研究方向为自然语言处理; 杨俊文 (1999-), 男, 江汉大学人工智能学院硕士研究生, 研究方向为自然语言处理; 李伊劲 (2001-), 男, 江汉大学人工智能学院硕士研究生, 研究方向为自然语言处理; 朱国华 (1969-), 男, 博士, 江汉大学人工智能学院教授、硕士生导师, 研究方向为自然语言处理、分布式仿真、软件工程。本文通讯作者: 朱国华。

Brian 等^[2]提出提示微调(Prompt Tuning)方法,通过学习软性提示来调整预训练语言模型的行为,从而使其适应特定的下游任务。相较于 GPT-3 使用的离散文本提示,软性提示通过反向传播机制实现端到端优化,能够动态整合来自任意数量标注样本的梯度信号,从而在参数空间中学习更鲁棒的提示表示^[3]。Li 等^[4]在提示微调的基础上提出一种轻量级语言生成任务优化方法——前缀微调(Prefix-tuning),仅优化一个小的连续任务特定向量(称为前缀),而不是修改整个大型语言模型的参数。该方法多应用于表格生成和摘要生成任务,只需学习预训练模型参数的 0.1% 便能在完整数据场景下达到与全模型微调相当的性能,且在低资源场景中的性能显著优于传统微调方法。LoRA(Low-Rank Adaptation of Large Language Models)是由 Edward 等^[5]提出的一种新的大型语言模型训练方式,该方法可以在保持预训练模型权重不变的情况下,通过注入可训练的秩分解矩阵来适应特定任务或领域。与全量微调方法相比,LoRA 可以大大减少需要微调的参数数量,显著减少了训练与推理的计算和存储成本,此外,LoRA 不会引入推理延迟,亦不会缩短输入序列长度,并且在多个任务之间进行快速切换时可以共享大部分模型参数。

在不同的应用场景中,大型语言模型的输出所采用的词汇、语言风格和情感表达方式等均需要进行人为控制。可控性生成技术的提出是大型语言模型从通用能力构建迈向精准场景适配的关键转折点,其通过显式约束机制、动态风格迁移、情感强度调节三大技术模块系统性解决了微调模型在垂直领域应用中的术语漂移、风格失配、情感失控三大核心痛点,实现了从“可用”到“可信”、从“通用”到“专业”的价值跃迁,增强了用户体验和互动效果。目前,主流的可控文本生成方法有 3 种,分别为:①重新训练模型。该类方法以 CTRL 和 Cocon 为代表,控制效果优异,但需要大量语料进行训练^[6-7];②属性鉴别器。该类方法以 PPLM 和 FUDGE 为代表,使用额外的属性鉴别器来修改生成模型解码的概率分布,从而控制生成文本的属性。然而,将鉴别器与生成模型分开可能导致计算时间较长、生成文本质量较低^[8-9];③提示微调。提示作为机器学习模型输入端的关键技术,通过在原始输入文本中嵌入结构化指令(如任务描述、上下文示例或控制标记),构建模型可解析的输入—输出映射关系,从而实现对生成结果的显式引导。然而,该类方法存在两个问题:首先,提示与当前解码步骤之间的距离增加,而这种距离是负相关的,会导致提示效果丧失^[10];其次,将提示移动到解码步骤附近会打乱整个上下文窗口,并增加模型遵循所有先前上下文的难度。

如何优化通用大模型以有效学习垂直领域的知识,确保在生成内容有效的情况下实现可控性文本生成是一个亟待解决的问题。为此,本文收集并整理领域知识数据

集,采用 QLoRA 方法训练出心理咨询领域的大语言模型 Psh-LLaMA3,基于相对熵控制文本生成算法(Control Text Generate Relative Entropy, CTGRE)与情感分类模型控制文本的生成属性。

1 模型构建

1.1 基准模型

本文选择在各大领域表现均较优秀的开源 LLaMA 大模型作为基准模型,其推理与泛化能力均较佳,能够完成多个自然语言处理任务。LLaMA 与 GPT 系列和其他基于 Transformer 的大规模语言模型类似,包含嵌入层、多层 Transformer 块和语言模型头^[11-12]。此外,其还结合了其他模型中使用的改进技术,如预归一化、SwiGLU 激活函数和旋转嵌入。Llama3 是 LLaMA 系列模型的最新一代产品,属于 LLaMA 模型的技术迭代与性能升级版本。其采用 Transformer 的 decoder 架构,这是一种基于自注意力机制的深度神经网络,能够高效处理序列数据。Transformer 架构通过并行化处理大幅提升了模型训练速度和性能。Llama3 由多个编码器和解码器层堆叠而成,每层包含自注意力机制和前馈神经网络。其中,编码器层负责处理输入文本,解码器层负责生成输出文本。

Llama3 模型结构如图 1 所示,其中 O 表示输出,“+”表示残差连接,“ $\blacktriangleleft$ ”表示因果掩码机制,“ $\bullet$ ”表示点乘。右边模块为注意力层,对输入进行编码后通过 RMSNorm 进行归一化处理,随后进行注意力计算,对查询向量 Q 、特征向量 K 采用 RoPE 旋转位置编码,用于增强模型对相对位置信息的捕捉能力。在计算查询向量 Q 与特征向量 K 的相似性时加入掩码机制,通过归一化指数函数 Softmax 后与价值向量 V 进行点乘,产生的输出向量与原有特征向量 Input Embedding 进行残差连接,以保留原始输入信息。左边模块为多层感知机,对残差连接后的向量信息进行 RMSNorm 归一化,对归一化向量进行特征升维 up, gate 门控机制使用 SiLU 激活函数处理归一化向量,然后与特征升维 up 后的向量进行点乘,以突出关键特征。随后进行降维操作 down,以降低计算复杂度和过拟合风险,再与先前输出进行残差连接。

1.2 数据准备与模型优化

1.2.1 数据准备

数据污染在机器学习的所有领域中都常见,当涉及到大型语言模型时,其变得更加复杂、微妙且难以检测。本文选择 CpsyCoun 数据集、SoulStar 数据集、RuoZhiBa 数据集进行实验,与私有大型语言模型进行数据获取后进行主题相关性评估与道德法律规范处理,确保样本与心理咨询相关,不含有个人隐私信息且符合伦理规范^[13-14]。Li 等^[15]研究认为同一个数据集中的高质量数据微调比包含数据





Fig. 1 Overall structure of the Llama3 model

污染的整个数据集微调效果更好。本文通过学习并利用训练后的大型语言模型作为数据探索器,对数据集进行评分并选取排名前 10% 的数据作为优质数据集,从而减少数据污染。将处理后的数据集分为通用数据集和心理数据集,分别通过 Llama3 原始模型进行初始训练,形成心理模型 Psh-base-Llama3 和通用模型 ver-Llama3。采用 NUGGETS 方法对两类数据集进行评分,筛选高质量数据,从而得到心理学及通用训练数据集。数据集构建流程如图 2 所示。

1.2.2 模型优化

大型语言模型为了达到更高的精度和更广泛的通用性,采用了巨大的网络规模,通常具有数以亿计甚至千亿级别的参数,在训练和微调时需要大量显存和计算资源。随着任务复杂度的增加,模型在处理更长的上下文和更多的训练数据时所需的时间和硬件成本急剧增加。在微调过程中,尽管预训练模型的参数规模很大,但是这些参数的更新通常可以通过较小的矩阵表示,这意味着模型权重

**Fig. 2** Datasets construction flow

更新的秩实际上是较低的,也就是说权重更新在某种程度上是重复训练的。LoRA 假设在适应过程中有一个预训练的权重矩阵 $W \in R^{d \times k}$, 其通过低秩分解 $W + \Delta W = W + BA$ 来进行更新, 其中 $B \in R^{d \times r}$, $A \in R^{r \times k}$, 且 $r \ll \min(d, k)$ 。在训练过程中, W 为预训练模型的原始权重, 不会在微调过程中更新, B 和 A 是可训练的参数, 它们远小于 W , 因此训练时需要更新的参数量显著减少。基于低秩矩阵的乘积能够有效地近似全量的权重更新, 从而减少了模型训练时对显存和计算资源的需求。在 LoRA 的基础上, QLoRA (Quantized Low-Rank Adaptation) 通过结合量化与低秩分解显著减少了微调过程中的内存和计算资源需求, 同时仍能保持模型的高性能^[16]。其不仅使用 LoRA 的低秩分解来降低参数更新的计算开销, 而且通过参数量化来进一步压缩模型的存储需求。

QLoRA 利用低比特量化(如 4-bit 或 8-bit)来存储预训练模型的权重矩阵 W , 这样不会损失太多精度。同时, LoRA 用于更新的低秩矩阵 B 和 A 仍然是在全精度下进行训练与更新的。权重量化大幅降低了显存需求, 可以在更有限的硬件环境下运行更大的模型。这种结合使得 QLoRA 能够在相对低成本的硬件上对大规模预训练模型进行高效微调。因此, 本文采用 QLoRA 训练方法对基准模型进行训练。为使模型的收敛更稳定, 将 `batch_size` 设置为 32, 训练轮次设置为 3 次, 初始学习率设置为 $2e-4$ 。为实现稳定的梯度更新, 采用升温学习方式, 在模型训练前期逐渐将学习率上升至设定学习率, 在之后的训练过程中采用余弦退火的方式降低学习率, 以使模型更加精细地调整参数。优化器选择 AdamW, 使用默认动量加速梯度下降^[17]。在神经网络中, 权重通常呈现非均匀分布, 采用 nf4 量化方式会根据这些权重的具体分布情况来量化, 从而保持更高的精度。使用双重量化减少由于低位数量化引起的数值误差, 进而提升模型性能。在任务训练时, 由于数据复杂度相较于通用数据更高, 将秩 r 设置为 32, 从而捕获更多复杂特征。将 `lora_alpha` 设置为 64, 以使模型在逐步微调中保持较高的稳定性, 适应复杂任务。最大数据长度设置为 4 096, 采用 Hugging Face `load_datasets` 加载数据。模型每 1 000 个训练步保存一次, 为节省磁盘空间, 最多保留 5 个模型。

1.3 基于相对熵的可控性生成

相对熵是一种用于衡量两个概率分布 p 与 q 之间差异的度量。具体来说, 其衡量了当使用分布 q 来近似分布 p 时所带来的信息损失。该指标具有非对称性。表示为:

$$D_{KL}(p||q) = \sum_{x \in T} p(x) \log \frac{p(x)}{q(x)} \quad (1)$$

式中: p 为真实分布; q 为预测分布; T 为子词标记的集合。

从统计学意义上来说, 相对熵可以用来衡量两个分布之间的差异程度。两者差异越小, 相对熵越小。当两个分布一致时, 相对熵为 0。在可控性文本生成中, 将不同的相

对熵组合并产生一个新的优化目标, 最终的真实分布 p 需要具备预测分布 q 的属性。相对熵对分布中的每个标记 x 给予相同的权重, 即每个词或符号的偏差对输出总结果的影响是一样的。可给当前标记增加一个权重, 该权重取决于上下文, 通过赋予相关标记更高的权重来控制生成过程中某些标记的影响力。对所有加权后标记进行相对熵计算。公式为:

$$D'_{KL}(p||q) = \sum p(x) f(x) \log \frac{p(x)}{q(x)} \quad (2)$$

式中: $f(x)$ 为每个标记 x 的权重, 反映了不同标记在生成过程中的相对重要性。较高的 $f(x)$ 表示该标记对生成特性更重要, 因此希望 p 能逼近 q 。通过最优化这个组合, 得到的分布 P 便会在不同属性之间达到一种平衡。最优化公式为:

$$P(x) = \sigma \left(\frac{1}{\sum_{i=1}^n f(x)} \cdot \sum_{i=1}^n f(x) \cdot \log q(x) \right) \quad (3)$$

式中: σ 表示 *softmax* 函数将放大高分项、压缩低分项, 使得权重差异在概率空间中变成一个有效的概率分布, 并保证所有可能的值之和为 1。

通过上述公式可以将不同的输入属性、提示、语言模型进行不同形式的组合, 从而改变概率分布进行可控性文本生成。许多有用的性质可以表示为概率分布的线性组合 $F(x) = \sum_{i=1}^n \alpha_i q_i$, 其中 F 为组合后的生成分布, q_i 为模型的第 i 个分布, α_i 为所希望采纳的权重。通过调整不同 q_i 的权重可控制生成文本的特性。

FUDGE 将输入文本相关联的概率与二元分类器一起用于引导输出分布, 可以表达不易用自然语言表达的属性^[9]。例如, Christiano 等^[18]提出的人类反馈强化学习 (Reinforcement Learning from Human Feedback, RLHF) 中的奖励模型或 Solaiman 等^[19]提出的 AI 生成文本。通过结合式 (2) 和式 (3), 本文引入 SCIR 的情感分类模型 RoBERTa-wwm-ext-large^[20]。该模型在情感分类方面表现出色, 可以将文本情感分为积极、正常和消极 3 种类型。使用该模型判断生成文本是否符合某种特性, 使其同时符合语言模型和分类器所指定的属性, 可表示为 $F(x) = \sum_{i=1}^n \alpha_i q_i + \alpha_c C$, 其中 C 为分类器模型, α_c 表示分类器权重。利用分类器为模型生成的输出提供一种过滤机制, 使生成文本的概率分布不仅受到原始模型的影响, 而且受到分类器的调节, 确保生成的文本符合指定的目标特性。

2 实验方法与结果分析

2.1 实验环境与参数配置

实验所使用的平台与运行环境配置如表 1 所示。

2.2 数据集

本文使用多种数据集评估模型在不同场景下的表现。分别为: ① MMLU (Massive Multitask Language Understand-

Table 1 Experimental environment configuration
表 1 实验环境配置

配置	具体参数
操作系统	Ubuntu 18.04
CPU 处理器	Intel(R) Xeon(R) Platinum 8457C
GPU 型号	L20(40 GB)*3
GPU 内存	120 GB
内存	128 GB
CUDA	12.1
深度学习框架	Pytorch 2.0.1
Python	3.10

ing)^[21]。其是一个广泛使用的多任务语言理解数据集,包含 57 个不同的任务,涵盖从基础知识(如数学、物理)到高级专业(如医学、法律)等领域,主要用于评估模型的通用语言理解能力;②CMMLU (Chinese MMLU)^[22]。其是 MMLU 的中文版本,涵盖中文语言环境下的多任务理解问题,用于评估模型在中文专业领域和基础知识方面的表现;③LongBench^[23]。其是一组针对长文本任务设计的数据集,由 6 类 21 个不同任务组成,覆盖了单文档 QA、多文档 QA、摘要、Few-shot 学习、合成任务和代码补全等关键的长文本应用场景,用于评估模型在处理长文本、跨段推理和多轮对话中的表现;④C-Eval^[24]。其是一个针对中文语言模型的基准评测集,包含文本分类、序列标注、机器翻译等任务,旨在评估中文环境下模型的综合表现,特别是模型在实际应用场景中的表现;⑤心理学数据集。其由 CpsyCoun 数据集、SoulStar 数据集、大模型范式心理数据集经数据处理评分后的未训练数据集构成,包含来自心理学场景的对话和问答数据,用于模拟心理咨询和情感分析等特定任务,以评估模型在专用场景下的定制化表现。

2.3 模型说明

实验的目标是评估由 Meta 发布的原版 LLaMA3 模型、Cui 等^[25]推出的中文 LLaMA3-Chinese、微调得出的心理模型 Psh-LLaMA3,以及 3 种模型结合控制算法的 Psh-LLaMA3-CTGRE、LLaMA3-CTGRE、LLaMA3-Chinese-CTGRE 的性能,其中 LLaMA3 为 Instruct 版本。

2.4 性能评估指标

采用准确率 (Accuracy)、ROUGE 和 BLEU 等指标,针对不同的数据集和任务类型进行评价。

2.4.1 准确率

准确率是衡量模型在多项选择或分类任务中表现的关键指标,表示模型预测正确结果的比例。计算公式为:

$$Accuracy = \frac{\text{预测正确的样本数}}{\text{总样本数}} \quad (4)$$

MMLU 和 CMMLU 数据集的评估集用于不同任务的少样本学习 (few-shot) 场景。这两个数据集以 0-shot、1-shot 和 5-shot 设置下的准确率作为评测指标,以测试其在没有训练样本或提供少量示例情况下的泛化能力。Long-Bench、C-Eval 数据集以文本生成的相似度计算结果平均分作为性能评估指标。

2.4.2 ROUGE 和 BLEU

在心理学数据集任务中,模型的文本生成性能评估主要采用 ROUGE 和 BLEU 两个指标,主要用于评估生成文本与参考文本之间的相似度和连贯性。其中 ROUGE 用于评估生成文本和参考文本在词汇、短语和句子上的重叠程度,常用变体包括:①ROUGE-1。用于衡量生成文本与参考文本在单词层面的重叠程度;②ROUGE-2。用于衡量生成文本与参考文本在双词短语层面的重叠程度;③ROUGE-L。用于计算生成文本和参考文本中的最长公共子序列 (Longest Common Subsequence, LCS),反映生成文本的连贯性和结构相似度。

BLEU 常用于评估机器翻译和文本生成的质量,核心机制是通过计算生成文本与参考文本之间的 n-gram 精确匹配程度来量化生成质量。具体包括:①BLEU-1。用于评估生成文本与参考文本在单词层面的匹配程度;②BLEU-2、BLEU-3 和 BLEU-4。分别用于评估生成文本与参考文本在 2 词、3 词和 4 词短语层面的匹配程度。

2.5 实验结果与分析

2.5.1 MMLU 数据集结果分析

各模型在 MMLU 数据集上的准确率如表 2 所示。可以看出,LLaMA3-Chinese 模型整体表现最为出色。具体来说,该模型能够快速理解和处理来自不同领域的信息,在少样本学习情境中准确率较高,不仅可以在没有样本的情况下进行推理,而且可以利用少量示例实现性能的显著提升,在需要灵活应对多样任务的场景中表现非常稳定。

Table 2 Accuracy of each model on the MMLU dataset

表 2 各模型在 MMLU 数据集上的准确率 (%)

模型	0-shot	1-shot	5-shot
	Accuracy	Accuracy	Accuracy
LLaMA3	62.1	62.4	63.7
LLaMA3-Chinese	62.9	63.8	64.1
Psh-LLaMA3	61.8	62.0	62.5
Psh-LLaMA3-CTGRE	61.2	62.0	62.5
LLaMA3-CTGRE	61.5	62.4	63.7
LLaMA3-Chinese-CTGRE	62.3	63.8	64.1

2.5.2 CMMLU 数据集结果分析

各模型在 CMMLU 数据集上的准确率如表 3 所示。可以看出,LLaMA3-Chinese 在 CMMLU 的 1-shot 设置中持续领先,这得益于其设计目标是广泛覆盖中文语境中的各类任务。该模型在训练过程中通过大规模的中文文本数据优化,从而具备了丰富的知识库和良好的适应性。LLaMA3-Chinese-CTGRE 在 0-shot 与 5-shot 中保持领先,表明情感分类模型能够对模型输出提供引导,使其目标达成率进一步提高。

2.5.3 C-Eval 数据集结果分析

各模型在 C-Eval 数据集上的准确率如表 4 所示。可以看出,LLaMA3-Chinese 系列模型在经过中文文本训练后,不仅获得了中文语言的理解与生产能力,而且准确率始终比原版 LLaMA3 模型系列领先 3%~4%。心理语料微

Table 3 Accuracy of each model on the CMMLU dataset**表3 各模型在CMMLU数据集上的准确率 (%)**

模型	0-shot	1-shot	5-shot
	Accuracy	Accuracy	Accuracy
LLaMA3	50.9	50.9	51.9
LLaMA3-Chinese	52.9	54.4	53.3
Psh-LLaMA3	48.8	51.5	52.2
Psh-LLaMA3-CTGRE	49.2	51.5	52.3
LLaMA3-CTGRE	48.9	49.0	49.9
LLaMA3-Chinese-CTGRE	53.3	54.2	53.8

调对模型的通用性能帮助有限,0-shot 设置下模型性能略有下降,但在5-shot 场景下勉强追回。CTGRE 主要用于控制生成,只在Psh-Llama3的1-shot 上较原版LLaMA3 模型有小幅提升。

Table 4 Accuracy of each model on the C-Eval dataset**表4 各模型在C-Eval数据集上的准确率 (%)**

模型	0-shot	1-shot	5-shot
	Accuracy	Accuracy	Accuracy
LLaMA3	50.1	49.7	50.2
LLaMA3-Chinese	53.9	53.4	54.6
Psh-LLaMA3	49.7	50.5	52.2
Psh-LLaMA3-CTGRE	50.4	52.3	51.3
LLaMA3-CTGRE	50.4	49.7	49.8
LLaMA3-Chinese-CTGRE	53.9	53.3	54.7

2.5.4 LongBench数据集结果分析

各模型在LongBench数据集上的准确率如表5所示。可以看出,表现最出色的为LLaMA-3-Chinese-CTGRE,其综合平均分达到42.21。该模型借助CTGRE有效控制概率分布,使得输出情感色彩无偏差,因此在多文档阅读、代码

理解和综合推理等需要整合大量信息的任务上领先。得益于中文专用语料和词表,LLaMA-3-Chinese-CTGRE 在LongBench数据集的多数中文子任务中具备天然优势,虽然与英文原版LLaMA-3相比,其在英文单文档解读和极端代码场景中略逊色,但整体均衡性更佳。

Table 5 Accuracy of each model on the LongBench dataset**表5 各模型在LongBench数据集上的准确率 (%)**

模型	单文档	多文档	摘要	FS学习	代码	合成	平均
LLaMA3	52.1	13.1	0.1	22.0	51.3	94.5	38.85
LLaMA3-Chinese	19.9	28.5	24.4	27.6	59.0	91.9	37.70
Psh-LLaMA3	23.6	31.7	25.3	25.4	52.3	87.9	41.00
Psh-LLaMA3-CTGRE	24.3	32.6	25.3	25.4	50.9	89.3	41.30
LLaMA3-CTGRE	52.1	16.4	0.3	22.0	49.2	94.5	39.00
LLaMA3-Chinese-CTGRE	22.1	30.3	24.4	27.4	57.3	92.0	42.21

2.5.5 心理数据集结果分析

心理学数据集为自建数据集,包含心理咨询问答对、心理健康建议等文本内容。具体格式为json 语句块,测试数据样例如表6所示。

在测试阶段将instruction 与input 的内容进行拼接作为输入传送给模型,在评估设置上,batch_size=64,max_tokens=512,temperature=0.3。各模型在心理数据集上的表现如表7所示。可以看出,Psh-LLaMA3 与CTGRE 组合模型的表现心理咨询领域中领先,尤其是心理咨询场景下的ROUGE-1 指标相较于LLaMA3 模型达到4%左右的提升,这是由于Psh-LLaMA3 模型的训练过程进行了针对性优化。结合CTGRE 方法后模型性能进一步提升2%左右,说明模型在生成文本时能够更好地控制输出的属性,包括情感表达的准确性和连贯性。

Table 6 Single data example**表6 单个数据样例**

Instruction		Input	Output
现在你是一个心理辅导员, 请你用专业的知识帮我解决	我最近总是感觉很焦虑,尤其是每次完成一项工作或者参加一个活动之后,我都会有种莫名的空虚感和不安全感		你好,我能理解你的困扰。这种在完成任务后出现的空虚感和不安全感可能源于你对自身价值的过度绑定在工作或活动的结果上。这是“成就焦虑”的一种表现。首先,尝试给自己设定合理的工作与休息的比例,每完成一件事后,不妨安排一些你喜欢的事情作为奖励,让心灵有所依托。同时,我们可以进行正念练习,帮助你更好地活在当下,而不是过分担忧未来或纠结过去

Table 7 The performance of each model on the psychological dataset**表7 各模型在心理数据集上的表现**

模型	ROUGE-1	ROUGE-2	ROUGE-L	BLEU-1	BLEU-2	BLEU-3	BLEU-4
LLaMA3	22.15	4.87	14.63	19.37	7.28	2.98	1.29
LLaMA3-Chinese	26.02	5.91	14.49	23.49	9.43	4.11	1.84
Psh-LLaMA3	26.50	7.69	15.86	15.65	7.26	3.85	2.18
Psh-LLaMA3-CTGRE	28.31	7.42	16.94	17.83	8.75	3.96	2.73
LLaMA3-CTGRE	23.78	5.63	15.24	20.94	8.11	3.52	1.68
LLaMA3-Chinese-CTGRE	27.17	6.49	15.38	24.12	9.85	4.32	2.35

3 结语

本文提出一种面向心理咨询领域的大型语言模型

Psh-LLaMA3,并结合相对熵控制算法CTGRE 提升了模型在心理咨询对话场景中的可控性生成能力。结果表明,Psh-LLaMA3 在心理数据集任务中表现优异,较对照模型在各任务上的性能提升了1%~4%。在ROUGE-1 评估指

标上,结合 CTGRE 的 Psh-LLaMA3 模型相较 LLaMA3 得到了 6.16% 的提升,证明了 CTGRE 算法在优化文本生成属性控制和提升情感表达精度方面的有效性。Psh-LLaMA3 在心理学及特定场景的文本生成任务中展现了出色性能,说明通过相对熵控制策略提升特定领域生成内容的可控性是有效的,特别是对于需要精细化情感和语言风格控制的应用场景。虽然本文在心理咨询领域可控文本生成技术与系统实现上取得了一定成果,但仍存在以下局限性,未来可从以下方向进一步优化:①当前研究聚焦于文本模态,未来可引入用户语音、表情等跨模态信息,构建多模态心理咨询数据集,增强模型对用户多类型信息的理解能力;②探讨 CTGRE 算法在其他特定领域的应用,以实现更多场景下的高效可控性文本生成,从而推动特定领域的大模型在实际应用中的价值提升。

参考文献:

- [1] HOULSBY N, GIURGIU A, JASTRZEBSKI S, et al. Parameter-efficient transfer learning for NLP[DB/OL]. <https://arxiv.org/abs/1902.00751>.
- [2] BRIAN L, RAMI A, NOAH C. The power of scale for parameter-efficient prompt tuning[DB/OL]. <https://arxiv.org/abs/2104.08691>.
- [3] BROWN T B, MANN B, RYDER N, et al. Language models are few-shot learners[DB/OL]. <https://arxiv.org/pdf/2005.14165>.
- [4] LI X L, LIANG P. Prefix-tuning: optimizing continuous prompts for generation[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, 2021: 4582-4597.
- [5] EDWARD H, SHEN Y, WALLIS P, et al. LoRA: low-rank adaptation of large language models[DB/OL]. <https://arxiv.org/abs/2106.09685>.
- [6] KESKAR N S, MCCANN B, VARSHNEY L R, et al. CTRL: a conditional transformer language model for controllable generation[DB/OL]. <https://arxiv.org/pdf/1909.05858.pdf>.
- [7] CHAN A, ONG Y S, PUNG B T W, et al. COCON: a self-supervised approach for controlled text generation[DB/OL]. <https://arxiv.org/abs/2006.03535>.
- [8] DATHATHRI S, MADOTTO A, LAN J, et al. Plug and play language models: a simple approach to controlled text generation[DB/OL]. <https://arxiv.org/abs/1912.02164>.
- [9] YANG K, KLEIN D. FUDGE: controlled text generation with future discriminators[C]//Annual Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2021: 3511-3535.
- [10] ZOU X, YIN D, ZHONG Q Y, et al. Controllable generation from pre-trained language models via inverse prompting[C]//ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2021: 2450-2460.
- [11] TOUVRON H, LAVRIL T, IZACARD G, et al. LLaMA: open and efficient foundation language models[DB/OL]. <https://arxiv.org/pdf/2302.13971.pdf>.
- [12] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[DB/OL]. <https://arxiv.org/abs/1706.03762>.
- [13] ZHANG C, LI R, TAN M, et al. CPsycoun: a report-based multi-turn dialogue reconstruction and evaluation framework for Chinese psychological counseling[DB/OL]. <https://arxiv.org/abs/2405.16433>.
- [14] NOBODY-ML. SoulStar[EB/OL]. <https://github.com/Nobody-ML/SoulStar>.
- [15] LI Y, HUI B, XIA X, et al. One shot learning as instruction data prospector for large language models[DB/OL]. <https://arxiv.org/abs/2312.10302>.
- [16] DETTMERS T, PAGNONI A, HOLTZMAN A, et al. QLoRA: efficient finetuning of quantized LLMs[DB/OL]. <https://arxiv.org/abs/2305.14314>.
- [17] LOSHCILLOV I, HUTTER F. Decoupled weight decay regularization[DB/OL]. <https://arxiv.org/abs/1711.05101>.
- [18] CHRISTIANO P F, LEIKE J, BROWN T B, et al. Deep reinforcement learning from human preferences[DB/OL]. <https://arxiv.org/abs/1706.03741>.
- [19] SOLAIMAN I, BRUNDAGE M, CLARK J, et al. Release strategies and the social impacts of language models[DB/OL]. <https://arxiv.org/abs/1908.09203.pdf>.
- [20] CUI Y, CHE W, LIU T, et al. Revisiting pre-trained models for Chinese natural language processing[C]//Findings of the Association for Computational Linguistics, 2020: 657-668.
- [21] DAN H, COLLIN B, STEVEN B, et al. Measuring massive multitask language understanding[C]//Vienna: International Conference on Learning Representations, 2021.
- [22] LI H N, ZHANG Y X, KOTO F, et al. CMMLU: measuring massive multitask language understanding in Chinese[C]//The Association for Computational Linguistics (Findings), 2024: 11260-11285.
- [23] HUANG Y Z, BAI Y Z, ZHU Z H, et al. C-Eval: a multi-level multi-discipline Chinese evaluation suite for foundation models[DB/OL]. <https://arxiv.org/abs/2305.08322>.
- [24] BAI Y S, LV X, ZHANG J J, et al. LongBench: a bilingual multitask benchmark for long context understanding[C]//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics, 2024: 3119-3137.
- [25] CUI Y M. Chinese-LLaMA-Alpaca-3[EB/OL]. <https://github.com/ymcui/Chinese-LLaMA-Alpaca-3>.

(责任编辑:尹晨茹)