

基于深层个性信息的个性化对话生成技术

陈杰¹, 蒋玉茹^{1,2}, 区可明³, 余泽鹏³, 张志华¹, 秦晓博¹, 王若凡¹, 张仰森¹

(1. 北京信息科技大学 计算机学院, 北京 100101; 2. 国家经济安全预警工程北京实验室, 北京 100044;
3. 拓尔思信息技术股份有限公司, 北京 100089)

摘要: 在日常交流中, 人们常在对话过程中不自觉地透露出自己的个性信息。个性化对话系统模拟了这一过程, 通过为模型引入个性信息生成个性化回复。个性化对话涉及个性表达、个性感知与个性理解3个核心动作。个性表达即在对话中表达自己的个性信息; 个性感知即从对方的话语中推理其蕴含的个性信息; 个性理解即对个性信息进行分类总结。具备了这些能力的对话模型能够更具吸引力地与人类进行对话。然而, 现有研究仅关注于实现模型个性表达的能力, 而忽略了对个性感知与个性理解的研究。为此, 提出一个个性化对话数据集PPU, 包含个性感知与个性理解的标注信息。同时设计一个可以利用深层个性信息的个性化对话模型PUT, 包括个性感知、个性理解和个性表达的相关模块。在PersonaChat数据集的实验中, PUT相较基线模型在困惑度指标上平均减小了5.39, 在F1指标上平均提升了1.86。同时, 在人工评估的流畅性与个性一致性指标中, PUT相较基线模型分别平均提升了15.55%和6.27%。实验结果表明, 个性感知与个性理解可有效增强模型的个性化对话性能。

关键词: 个性化对话; 个性表达; 个性感知; 个性理解

DOI: 10.11907/rj.dk.241226

开放科学(资源服务)标识码(OSID):



中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2025)005-0053-09

Technology for Generating Personalized Dialogues Based on Deep Persona Information

CHEN Jie¹, JIANG Yuru^{1,2}, OU Keming³, SHE Zepeng³, ZHANG Zhihua¹, QIN Xiaobo¹, WANG Ruofan¹, ZHANG Yangsen¹

(1. Computer School, Beijing Information Science and Technology University, Beijing 100101, China;
2. Beijing Laboratory of National Economic Security Early-Warning Engineering, Beijing 100044, China;
3. TRS Information Technology Co., Ltd, Beijing 100089, China)

Abstract: In daily communication, people often unconsciously reveal their personality information during conversations. The personalized dialogue system simulates this process by introducing personalized information into the model to generate personalized responses. Personalized dialogue involves three core actions: personality expression, personality perception, and personality understanding. Personality expression refers to expressing one's own personality information in dialogue; Personality perception refers to inferring the personality information contained in the other person's words; Personality understanding refers to the classification and summary of personality information. Dialogue models equipped with these abilities can engage in more attractive conversations with humans. However, existing research only focuses on the ability to express personality in models, while neglecting the study of personality perception and understanding. To this end, a personalized dialogue dataset PPU (Persona Perception and Understanding) is proposed, which includes annotated information on individual perception and understanding. Simultaneously design a personalized dialogue model PUT (Perception and Understanding Transformer) that can utilize deep personality information, including modules related to personality perception, understanding, and expression. In the experiments on the PersonaChat dataset, PUT reduced the perplexity index by an average of 5.39 compared to the baseline model, and improved the F1 index by an average of 1.86. Meanwhile, in the manually evaluated indicators of fluency and personality consistency, PUT showed an average improvement of 15.55% and 6.27% compared to the baseline model, respectively. The experimental results indicate that personality perception and under-

收稿日期: 2024-03-09

扫描二维码阅读全文:



基金项目: 北京市自然科学基金项目(4242019)

作者简介: 陈杰(1995-), 男, 北京信息科技大学计算机学院硕士研究生, 研究方向为自然语言处理; 蒋玉茹(1978-), 女, 博士, 北京信息科技大学计算机学院副教授、硕士生导师, 研究方向为自然语言处理。本文通讯作者: 蒋玉茹。

standing can effectively enhance the personalized dialogue performance of the model.

Key Words: personalized dialogue; personality expression; personality perception; personality understanding

0 引言

随着深度学习技术的发展,生成式对话系统逐渐替代了传统的基于规则或检索的系统,成为当下人机对话领域的主流方案。尽管如此,生成式对话系统仍然存在局限性,即倾向于生成训练数据中最普遍存在的共识性回答。在很多对话情境中,人们期望获得一个具有独特个性的聊天机器人,而普通的生成式模型无法满足这种需求。为此,Li等^[1]将个性信息(Persona)引入模型的对话生成过程中,并将个性信息定义为一个智能体(Agent)在对话互动中扮演的角色。个性信息的引入可使聊天机器人更加拟人化,既能拥有自己的年龄、性别、职业等基本属性,又能针对用户的问询产生独特的个性化回答。目前个性信息有两种主要表现形式,分别为以PersonaChat数据集为代表的自然语言形式和以PersonalDialog数据集为代表的键值对形式^[2]。

通过融入个性信息,模型可以生成更具人格的个性化回复,从而增强对话的吸引力。然而在个性化对话过程中,除了表达自己的个性信息外,谈话一方还会对另一方的个性信息进行感知与理解。对话可以分为倾听与发言两个阶段。在倾听阶段,倾听者接收到发言者的话语,并推理出其中蕴含的个性信息,这便是个性感知的过程;推理出其个性信息后,倾听者会对这些信息进行分类总结,这便是个性理解的过程;最后,倾听者会综合考虑自身个性信息与对方的个性信息,并生成恰当的回复,这便是个性表达的过程。具备以上3个能力的对话模型能够更好地与人类进行具有吸引力的对话。然而,现有数据集仅包含用于训练个性表达的个性信息,而缺乏个性感知与个性理解的相关数据,造成了相关研究的缺失,亟需完善。

1 相关研究

1.1 个性化对话数据集

早期的对话数据集常常来自于电影剧本,如Open Subtitles和Cornell Movie。随着互联网的发展,社交媒体中的对话语料逐渐丰富起来,人们在微博、豆瓣、Facebook和Twitter等大型社交平台留下了大量公开对话。于是,研究人员构建了多个基于社交媒体上公开对话的数据集,例如Ubuntu和Daily-Dialog。这些通用对话数据集缺乏对话者的个性信息,因此无法用于个性化对话系统的构建。Facebook的Zhang等^[2]发布的PersonaChat数据集解决了这一问题,该研究招募标注员编写了上千组个性信息集合,并为标注员两两分配这些集合,要求其根据分配到的个性信息进行对话;Welleck等^[3]通过标注PersonaChat中个性信

息和对话的三元组关系,构建了一个自然语言推理数据集DialogueNLI,辅助提高了个性化对话的一致性。尽管PersonaChat数据集的对话质量较高,但是高昂的人工标注成本限制了其规模。Zheng等^[4]提出收集自微博的PersonalDialog个性化对话数据集,以用户的基本资料作为个性信息,其多轮对话数量为PersonaChat的近30倍。尽管PersonaChat和PersonalDialog数据集中均包含了对话者的个性信息,但是仍然缺乏个性信息与对应话语之间的关联信息以及个性信息的分类情况。基于PersonaChat,Xu等^[5]发布了一个带有个性信息的多回合数据集MSC。该数据集在PersonaChat的基础上进行了扩展,在原始对话上增加了后续几个回合的对话,将个性化对话的研究扩展到长期对话领域。此外,Xu等^[6]发布了一个中文个性化对话数据集DuLeMon,其对话分为SELF和BOTH两类,SELF部分的机器人在对话时仅知晓自己的个性信息,而BOTH部分的机器人则知晓自己以及部分对方的个性信息。MSC和DuLeMon数据集为个性化对话生成提供了全新的研究视角和平台,研究者可以更精细地利用个性信息。

1.2 个性化对话模型

随着PersonaChat和PersonalDialog等个性化对话数据集的发布,研究者们逐渐开始尝试在对话中融入说话人的个性信息。现有对话生成模型通常使用序列到序列(Seq2Seq)模型自回归地生成回复文本。以GPT为代表的预训练语言模型通过使用大量无标注文本数据对基于Transformer架构的模型进行预训练,获得了强大的语言性能^[7]。TransferTransfo和Lost in Conversation等方法通过微调GPT-2,在PersonaChat数据集上取得了较好表现^[8]。最近,Chen等^[9]利用潜变量来学习记忆隐含关系和话语关系,将自然语言推理任务引入到个性化对话生成中,进一步提高了对话的一致性。

尽管上述工作良好地完成了个性化对话中的个性表达,却忽视了个性感知与个性理解的重要性。认知科学研究表明,对话者之间的相互感知与理解是高质量对话的重要信号。Liu等^[10]基于这一理论提出了P2BOT模型,其可在谈话过程中建模对方说话人的个性信息向量以提升对话效果;Song等^[11]提出BoB模型,通过判断个性信息与回复之间的一致性,将个性化对话生成分解为一致性理解和对话生成两个子任务。沿着这一思路,Nie等^[12]引入一个矛盾检测任务来评估对话的一致性。然而上述方法均基于向量隐式理解个性信息,存在难以解释、不够灵活的局限性。

为研究个性感知和个性理解对个性化对话生成的影响,本文首先提出一个个性化对话数据集PPU(Persona Perception and Understanding),该数据集可在以下仓库中获取: <https://github.com/deepbluefantasy/PPU-Persona-Per>

ception-and-Understanding-Dataset。PPU中包含谈话者的话语和个性信息之间的关联标注,使得对话过程中的个性感知研究成为可能;其次,本文构建了一个个性信息的分类体系,以细粒度的方式将个性信息分为9个类别。基于该分类体系,本文对谈话者的个性信息进行了分类,从而获得了个性理解的标注数据;最后,本文设计了一个包含个性感知与个性理解模块的对话模型PUT(Perception and Understanding Transformer),使用PPU进行训练和测试。其中,个性感知模块可以根据对方的话语实时推理其个性信息;个性理解模块则能够对推理出的个性信息进行分类,从而更好地完成个性表达。因此,本文主要贡献有以下3点:①提出一个多轮对话数据集PPU,该数据集是第一个包含个性感知与个性理解标注数据的个性化对话数据集,使研究者可以更细粒度地利用个性信息完成个性化对话的生成工作,为该领域提供了全新的研究视角和平台;②设计了一个个性化对话模型PUT,通过对用户的个性进行感知与理解,增强了对话机器人的个性表达能力;③在PersonaChat数据集上的实验结果显示,PUT在多项机器评估指标和人工评估指标上优于现有先进模型,为个性化对话生成领域提供了新的基线。

2 PPU数据集构建

个性感知意味着从话语中推理出相关个性信息,这需要对个性化对话中的话语与相关个性信息进行关联。个性理解意味着对给定的个性信息进行分类,这需要制定个性信息的分类体系,并进行标注。为获得相关数据,本文从PersonaChat数据集中获得原始语料,并使用机器与人工相结合的方式对语料进行标注。

2.1 个性感知数据

在个性化对话过程中,谈话双方A、B基于各自的个性信息展开对话。谈话者通常会根据对方的询问句 q 和自己的某条个性信息 p 作出回复 r 。本文将询问句 q 与对应的回复句 r 定义为一组QR对(Query-Response Pair)。如图1所示,QR对可分为两种类型:一类包含回复者的个性信息(a),另一类不含回复者的个性信息(b)。对于包含个性信息的QR对,本文将其与对应的个性信息 p 合称为QRP(Query-Response-Persona)三元组;对于不含个性信息的QR对,本文将其与“None”标签合称为QRN(Query-Response-None)三元组。

本文希望通过标注双方的话语与其个性信息之间的关联关系,从而获得上述QRP和QRN三元组。如图2所示,“You must be very fast. Hunting is one of my favorite hobbies”这句话与“I like to go hunting”这条个性信息存在关联,因此需要进行标注。本文采用基于GPT-3.5-Turbo版本的ChatGPT接口辅助完成标注任务。每个对话样本均进行3次独立的标注过程。当至少两次标注结果一致时,




Fig. 1 Two types of QR pairs

图1 QR对的两类型

话语与个性信息将被关联起来。否则,话语与给定的多条个性信息均不存在关联,为其分配特殊标记“-1”。

本文在PersonaChat数据集的17 878个多轮对话上进行了个性感知标注,将其中的52 493条话语与对应的个性信息关联起来,并将这些话语及个性信息全部替换成QRP三元组。剩余的78 945条话语与给定的个性信息不存在关联关系,本文为这些话语分配了特殊标记“-1”。这部分话语又分为两种,分别为:①包含个性信息的话语,但是该话语与给定的多条个性信息均不存在关联;②不包含个性信息的话语。显然,只有②可以被转换成QRN三元组。为获取QRN三元组,本文将这78 945条话语首先转换为QR对,然后筛选1 000条数据进行人工标注,判断其中是否存在个性信息。利用这1 000条数据,本文训练了一个二分类模型,用于对所有QR对进行分类,最终获得37 617个QRN三元组。为保证QRN三元组确实不存在个性信息,分类置信度阈值被设为90%。最终,PPU的个性感知数据中包含52 493个QRP三元组以及37 617个QRN三元组,共计90 110个个性感知三元组。

2.2 个性理解数据

本文将个性信息定义为关于谈话者的事实信息,可以




Fig. 2 Example of persona perception annotation

图2 个性感知标注示例

是与谈话者直接相关的信息,如身高、体重、兴趣等;也可以是谈话者间接相关的信息,如家庭成员信息、所在大学信息等。为确定个性信息的类别标签,本文首先根据国内外用户画像研究选择社会关系、工作状况、自然属性、兴趣属性等十余个候选类别^[13];然后,从已有个性化对话数据集 PersonaChat 和 PersonalDialog 中分别抽样 200 条个性信息,对其进行人工预标注。

基于预标注结果,本文对一些分布过少的类别进行合并,最终确定了 9 个个性信息类别,分别为:①个人信息(Personal Information)。指一个人内在或外在的属性、特征等信息,包括基本属性、身份、外貌、能力和身体状况等;②兴趣偏好(Interests and Preferences)。指一个人对于某个事物的喜恶信息,包括喜好、憎恶、恐惧、愿景以及其他能够暗示兴趣的事实陈述等;③家庭信息(Family Information)。指一切与家庭有关的事实信息,包括家庭关系信息、家庭成员的个性信息等;④人际关系(Interpersonal Relationships)。指与人际交往有关的事实信息,包括社会关系信息、人际交往的能力等;⑤生活习惯(Lifestyle Habits)。指与日常行为习惯和饮食偏好有关的事实信息,包括饮食习惯、穿着习惯、居住习惯、生活方式以及固定行为等;⑥教育信息(Educational Information)。指一切与教育相关的事实信息,包括学历信息、专业信息和学校信息等;⑦职业信息(Occupational Information)。指一切与职业相

关的事实信息,包括职业情况、薪水情况和工作细节等;⑧过往经历(Past Experiences)。指关于一个人曾经历过的事件信息,包括经历过的事件和未经历过的事件;⑨所有物信息(Possessions Information)。指自己所拥有的物品信息,包括财产信息和宠物信息。

本文基于该分类体系对 PersonaChat 数据集中的 13 592 条个性信息进行人工标注,其中有 64 条数据不存在个性信息,例如“it was too small”,这属于原始标注中存在的失误,本文在 PPU 中去除了这部分无效数据。图 3 为剩余 13 528 条数据的统计结果,其中个人信息和兴趣偏好是占比最高的两类个性信息,比例均为 23%;职业信息、家庭信息和生活习惯占比近似,约在 11% 上下浮动;所有物信息、教育信息、过往经历和人际关系则占比较小,约在 5% 上下浮动。综合而言,9 个类别占比可划分成 3 个梯队,但是 3 个梯队之间的差距较小,数量分布相对均衡。

3 PUT 模型构建

PUT 模型包含个性感知模块、个性理解模块和对话生成模块 3 个部分。总体结构见图 4。

3.1 个性感知模块

本文利用个性感知模块 g_{β} 从上一轮对话中推理出其中蕴含的个性信息。如式(1)所示,给定 $U = \{u_{t-1}^B, u_t^A\}$,个




Fig. 3 Data distribution of persona understanding

图 3 个性理解数据的分布情况

性感知模块 g_p 的任务为: 如果 u_t^A 中存在个性信息, 即当前的 U 属于 QRP 三元组, 此时生成 $I = p_j^A$; 否则, 当前的 U 属于 QRN 三元组, 此时生成 $I = \text{None}$ 。

$$g_p(I|U; \beta) = \begin{cases} P(p|u_{t-1}^B, u_t^A; \beta), & \text{if } U \in \text{QRP} \\ P(\text{None}|u_{t-1}^B, u_t^A; \beta), & \text{if } U \in \text{QRN} \end{cases} \quad (1)$$




Fig. 4 Overall structure of the PUT model

图 4 PUT 模型总体结构




Fig. 5 Structure of persona perception module

图 5 性感知模块结构

如图 5 所示, 性感知模块由标准的 Transformer 编码器和解码器组成。将当前的 QR 对与提示词 (Prompt) 进行拼接后作为输入文本传入到 Transformer 的编码器中, 其会将输入文本对应的词元 (Token) 转换为稠密向量。这些向量随后会加入到 Transformer 的解码器中生成个性信息。由于 Transformer 的解码器同样可以将词元转换为稠密向量, 也可仅使用解码器同时完成编码输入文本、生成个性信息的工作, 此时性感知模块仅包含图 5 的右半部分。在训练过程中, 使用交叉熵损失 (Cross Entropy Loss) 优化模型输出序列中每个词元的预测概率分布与实际词元序列之间的差异。通过最小化交叉熵损失, 训练得到的性感知模块可以从 QR 对中生成回复者的个性信息。

3.2 个性理解模块

在真实的对话场景中, 如果对方在话语中表露出自己的个性信息, 那么谈话人往往也会根据自己与之相关的个性信息产生针对性回复。然而对话双方的个性信息并非

总是直接相关,因此本文使用个性理解模块 h_ϕ 对双方的个性信息 p 进行分类,使模型利用同类别的个性信息进行回复。具体来说,本文目标为确定个性信息 p 属于预定义的个性类别集合 $C = \{c_1, c_2, \dots, c_9\}$ 中的哪一个,即个性理解模块 h_ϕ 需要根据输入的个性信息 p 预测其所属的个性类别 c 。预测公式为:

$$h_\phi(c|p; \phi) = \text{softmax}(\text{score}(p, c_1; \phi), \text{score}(p, c_2; \phi), \dots, \text{score}(p, c_k; \phi)) \quad (2)$$

式中: $\text{score}(p, c_i; \phi)$ 表示模型 h_ϕ 计算的个性信息 p 与类别 c_i 的相关性分数,softmax函数用于将这些分数转换为概率。

如图6所示,个性理解模块由Transformer的编码器部分组成。将个性信息作为输入文本传入到Transformer的编码器中可以得到其对应的语义向量,通过该语义向量可以得到当前个性信息为9个个性类别的概率。在训练过程中,使用交叉熵损失优化个性信息的预测类别概率分布与实际个性类别之间的差异。通过最小化交叉熵损失,训练得到的个性理解模块可以准确预测个性信息类别。




Fig. 6 Structure of persona understanding module

图6 个性理解模块结构

3.3 对话生成模块

对话系统的任务为根据用户话语生成相应的回复文本。个性化对话生成的本质是使模型根据多轮对话历史以及分配给模型的个性信息生成相应的回复。给定多轮对话历史 $D = \{u_1^A, u_1^B, u_2^A, u_2^B, \dots, u_t^A\}$,其中 u^A 和 u^B 分别表示用户A和模型B的话语,设模型的个性信息 $P_B = \{p_1^B, p_2^B, \dots, p_n^B\}$,则过去的对话生成模型 f_θ 需要在 t 时刻基于历史 D 及模型的个性信息 P_B 生成当前的回复 $Y = u_t^B$ 。表示为:

$$f_\theta(Y|D, P_B; \theta) = p(u_t^B | u_1^A, u_1^B, \dots, u_t^A, p_{1:n}^B; \theta) \quad (3)$$

与过去的工作不同,本文设计的PUT除对话生成模块

f_θ (用于个性表达)外,还包含个性感知模块 g_β 和个性理解模块 h_γ 。借助个性感知模块 g_β ,模型可以从当前对话历史 D 中推理出用户的个性信息 $P_A = \{p_1^A, p_2^A, \dots, p_x^A\}$,其中 $x \in [0, t]$;借助个性理解模块 h_γ ,模型可以对 P_A 和 P_B 中的个性信息进行分类,从而获得带有类别标签的个性信息 $P'_A = \{p_1'^A, p_2'^A, \dots, p_x'^A\}$ 和 $P'_B = \{p_1'^B, p_2'^B, \dots, p_n'^B\}$ 。最终,对话生成模块 f_θ 可以在 t 时刻基于对话历史 D 、带有类别标签的用户个性信息 P'_A 以及带有类别标签的模型个性信息 P'_B 生成当前回复 $Y = u_t^B$ 。表示为:

$$f_\theta(Y|D, P'_A, P'_B; \theta) = P(u_t^B | u_1^A, u_1^B, \dots, u_t^A, p_{1:x}^A, p_{1:n}^B; \theta) \quad (4)$$

与个性感知模块类似,对话生成模块既可由标准的Transformer编码器与解码器组成,也可以仅包含解码器部分。将对话历史、带有标签的个性信息与提示词拼接后,作为输入文本传入到Transformer的编码器(或解码器)中即可获得对应词元的语义向量。Transformer的解码器利用这些语义向量自回归地生成回复文本。在训练过程中,通过交叉熵损失可以优化模型输出。经过训练得到的对话生成模块可以利用对话历史及双方的个性信息生成共情的个性化回复信息。

4 实验方法与结果分析

4.1 实验设置

本文实验基于PyTorch和HuggingFace的Transformers库完成,实验环境为搭载了8张NVIDIA A100 GPT的CentOS服务器。训练过程使用AdamW作为优化器,其中个性感知和对话生成实验使用的学习率为 $1e-4$,个性理解实验使用的学习率为 $2e-5$ ^[14]。个性感知实验训练7轮,批次大小为64;个性理解实验训练7轮,批次大小为256;个性化对话生成实验训练7轮,批次大小为16。

4.2 评价指标

在个性感知实验中,本文采用困惑度(Perplexity, PPL)、BLEU和Rouge-L作为评估指标。其中,PPL可以衡量模型在测试集上与人工标注的负对数似然损失大小,其值越低表示模型越倾向于生成人工标注对应的文本;BLEU衡量了模型回复的 n -元词交叉水平上与人工标注的相似程度;Rouge-L则评估了模型回复的长序列重叠,即基于最长公共子序列的一致性。BLEU和Rouge-L的值越高,表明模型回复与人工标注越一致。在个性理解实验中,本文采用准确率作为评估指标,准确率越高,分类性能越好。在个性化对话生成实验中,本文采用PPL和F1两个机器评估指标,其中F1在词元水平上计算了生成结果与人工标注的相似程度,其值越小,表示模型输出结果与人工标注的差异越小。

4.3 个性感知实验

本文基于Flan-T5和LLaMA-2-chat模型构建个性感知模块,从话语中生成个性信息^[15-16]。Flan-T5是一个标

准的 Transformer 预训练模型,其将所有自然语言处理任务形式化为文本到文本任务,然后使用 1 800 余个任务进行指令微调,提高了模型的性能和泛化性。而 LLaMA-2-chat 则仅由 Transformer 的解码器部分构成,其首先在无监督文本上进行预训练,然后经历有监督精调(Supervised Fine-Tuning, SFT)和人类反馈强化学习(Reinforcement Learning with Human Feedback, RLHF)阶段,同样能够较好地完成指令遵循任务。本文使用 PPU 数据集训练个性感知模型。在进行实验时,QR 对加上提示词后会被转换成“Query: {q} Response: {r} What factual information can we infer about the speaker from the response?”的形式,其中 q 为具体的问句句,r 为具体的回复句。输出结果为“Persona: {p}”或“Persona: None”,其中 p 为回复者从 QR 对中表达的个性信息,None 表示当前 QR 对中无个性信息。利用从 PPU 中得到的 52 493 个 QRP 三元组和 37 617 个 QRN 三元组对 3 个不同大小的 Flan-T5 进行全参数微调,同时使用 LoRA 的方式对 7B 参数的 LLaMA-2-chat 进行参数高效微调^[17]。图 7 为以上 4 个模型在训练过程中的验证损失值曲线。可以看出,3 个不同大小 Flan-T5 模型的下降趋势趋同。由于 LLaMA-2-chat 模型架构异于前三者,验证损失值不可直接对比,但整体仍呈现下降趋势。




Fig. 7 Verification loss curves of four models during the training process

图 7 4 个模型训练过程验证损失值曲线

表 1 为微调后 4 个模型在测试集上的表现。可以看出,在 PPL 指标上,参数量最大的 LLaMA-2-chat 取得最好表现,Flan-T5-base 和 Flan-T5-Large 其次,Flan-T5-small 表现最差。PPL 较低意味着模型对生成结果更加置信,也反映了模型对于给定文本的理解程度更高。随着参数量的增加,模型能够更好地理解原始文本。在 BLEU 和 Rouge-L 这两个文本相似度指标上,Flan-T5-large 和 LLaMA-2-chat 分别取得了最佳结果,表明二者能够输出与标准结果最相似的结果。因此,本文选择 Flan-T5-large 和 LLaMA-2-chat 作为个性感知模块的基座分别进行实验。

4.4 个性理解实验

本文基于 BERT 模型构建个性理解模块,对个性信息进行九分类^[18]。BERT 是一个基于 Transformer 编码器的

Table 1 Performance of 4 models on the test set after fine-tuning
表 1 微调后 4 个模型在测试集上的表现

模型	参数量	PPL ↓	BLEU ↑	Rouge-L ↑
Flan-T5-small	80M	2.290	0.26	0.538 1
Flan-T5-base	250M	1.990	0.24	0.546 5
Flan-T5-large	780M	2.020	0.26	0.551 2
LLaMA-2-chat	7B	1.749	0.21	0.661 1

预训练语言模型,可以获取输入文本的整体语义信息。DistilBERT 是 BERT 的轻量化版本,利用知识蒸馏技术减少了参数量^[19]。RoBERTa 是 BERT 的改进版本,通过取消下一个句子任务、增加动态掩码机制,在多项自然语言处理任务中取得了较好表现^[20]。

采用 PPU 数据集训练个性理解模型。PPU 中共有 13 592 条个性信息,包含 3 068 条个人信息、3 090 条兴趣偏好、1 558 条家庭信息、502 条人际关系、1 390 条生活习惯、674 条教育信息、1 744 条职业信息、628 条过往经历和 874 条所有物信息,其中训练集、验证集与测试集的比例为 8:1:1。使用这些个性信息作为输入,类别标签作为输出,在 3 类 BERT 模型不同大小版本上进行实验。结果见图 8。可以看出,各模型在训练过程中验证损失值的下降趋势趋同。




Fig. 8 Verification loss curve of each model during the training process

图 8 各模型训练过程验证损失值曲线

表 2 为各类 BERT 模型微调后的实验结果。可以看出,5 个模型在测试集上均表现出良好性能,其中 RoBERTa-large 表现最优,准确率达到 91.19%。虽然 DistilBERT-base 的准确率比 RoBERTa-large 低 0.59%,但其参数量仅为 BERT-base 的 1/6。因此,本文选择 DistilBERT-base 作为个性理解模块的基座模型。

Table 2 Experimental results of various BERT models after fine-tuning
表 2 各类 BERT 模型微调后的实验结果

模型	参数量/M	Accuracy/% ↑
DistilBERT-base	60	90.60
BERT-base	110	90.75
BERT-large	340	89.55
RoBERTa-base	125	89.25
RoBERTa-large	355	91.19

4.5 个性化对话生成实验

使用 PersonaChat 数据集进行个性化对话生成实验。该数据集中存在 2 种不同类型的数据,分别为 Original Dataset 和 Revised Dataset。二者的对话内容完全相同,但个性信息有所区别,其中 Original Dataset 中的个性信息是对话标注者在标注对话时参考的原始个性信息,而 Revised Dataset 中的个性信息则是原始个性信息经过同义改写后的版本。

4.5.1 对比基线

使用个性化对话生成领域的 SOTA 模型作为实验基线,包括 Lost in Conversation^[8]、LMEDR^[9]、P2BOT^[10]、TransferTransfo^[21]。其中,Lost in Conversation、TransferTransfo 均使用 GPT-2 作为语言基座,前者通过拼接错误的回复句,使用下一个句子损失来辅助 GPT-2 的训练,后者则使用 GPT-2 来初始化编码器和解码器的权重训练模型^[22]。P2BOT 着眼于建模谈话对象的个性信息向量,使用 Receiver 模块(BERT)建模对方的个性向量,使用 Transmitter(GPT-2)模块进行对话生成。其设置了 3 个奖励目标,关注生成的回复与谈话对象个性信息的相关性,使用强化学习优化模型。LMEDR 是当前业界表现最好的模型,其训练分为两个阶段:第一阶段使用 DialogueNLI 数据集训练潜变量 M 和预训练模型 BART^[23];第二阶段将潜变量 M 固定,使用 PersonaChat 数据集训练潜变量 N 和 BART。通过潜变量 M 和 N ,LMEDR 将自然语言推理任务引入到个性化对话生成中,提高了模型性能。

4.5.2 机器评估指标

表 3 为 PUT 模型与基线模型的机器指标比较。可以看出,PUT 模型的 PPL 指标大幅超越基线模型。与目前最好的 LMEDR 模型相比,使用 Flan-T5 和 LLaMA-2-chat 作为基座的 PUT 模型在 Original Dataset 上的 PPL 分别降低了 36.76% 和 47.32%,在 Revised Dataset 上的 PPL 分别降低了 43.74% 和 48.29%。在 F1 指标上,以 Flan-T5 作为对话基座的 PUT 在 Original Dataset 上略逊于 LMEDR (-0.73%),但在 Revised Dataset 上达到了 7.27% 的提升。Revised Dataset 中给出的谈话者个性信息是经过同义改写后的版本,避免了与原始个性信息的词重叠,这意味着 Revised Dataset 比 Original Dataset 的训练难度更大。PUT 模型在 Revised Dataset 上取得的提升表明,个性感知模块与个性理解模块可更好地应对复杂场景下的对话生成。值得一提的是,以 LLaMA-2-chat 为基座的 PUT 尽管在 PPL 指标上取得了较好表现,但在 F1 指标上逊于 LMEDR 和 P2BOT,原因是 F1 仅计算了生成结果与标准答案的重复度,并不能很好地体现大语言模型的性能。

4.5.3 人工评估指标

将 PUT 模型与当前最先进的 LMEDR 模型进行人工评估指标的比较,采用两个维度的评估指标,分别为流畅性(Fluency)和个性一致性(Persona Consistency)。流畅性旨在衡量模型生成的回复与用户询问之间的语义流畅程度

Table 3 Machine evaluation index results of personalized dialogue generation experimental

表 3 个性化对话生成实验机器评估指标结果

模型	Original-PPL ↓	Original-F1 ↑	Revised-PPL ↓	Revised-F1 ↑
Lost in Conversation	-	17.79	-	16.83
TransferTransfo	17.51	19.09	-	-
P2BOT	15.12	19.77	18.89	19.08
LMEDR	10.99	21.99	13.42	19.54
PUT-Flan-T5	6.95 (-36.76%)	21.83 (-0.73%)	7.55 (-43.74%)	20.96 (+7.27%)
PUT-LLaMA-2-chat	5.79 (-47.32%)	19.39 (-11.82%)	6.94 (-48.29%)	19.02 (-2.66%)

和相关性,评分范围为 1~5;个性一致性表示模型生成的回复与预设个性信息之间的一致性,评分范围为 1~5。本次评估由 2 名专业的对话系统领域研究者执行,由测试集中随机抽取 100 个对话样本。评估时,每位评估者均获得包括对话上下文、对话者个性信息以及 3 个模型的回复结果在内的完整信息。为保证评估的客观性与公正性,回复结果的模型来源被匿名处理,以消除评估者潜在的评估偏见。人工评估指标结果见表 4。可以看出,PUT 模型在个性一致性方面相较 LMEDR 模型的提升幅度较小(2.17% 和 10.37%),但在流畅性方面表现出较大提升(9.12% 和 21.98%)。这是由于 PUT 模型在生成回复时不仅考虑了表达其预设的个性信息,而且考虑了根据感知到的用户个性信息来定制化回复。基于 LLaMA-2-chat 的 PUT 相较 LMEDR 在流畅性和个性一致性方面均取得较大提升。

Table 4 Results of manual evaluation indicators for personalized dialogue generation experiment

表 4 个性化对话生成实验人工评估指标结果

模型	fluency ↑	Persona Consistency ↑	Avg ↑
LMEDR	3.73	4.05	3.89
PUT-Flan-T5	4.07(+9.12%)	4.14(+2.17%)	4.105(+5.53%)
PUT-LLaMA-2-chat	4.55(+21.98%)	4.47(+10.37%)	4.47(+16.18%)

4.5.4 消融实验

为探究个性感知与个性理解模块的实际效果,本文进行以下消融实验。表 5 和表 6 为去除个性感知模块和个性理解模块后模型的表现,其中表 5 的 PUT 模型使用 Flan-T5 作为基座,表 6 的 PUT 模型使用 LLaMA-2-chat 作为基座。可以看出,在去除个性感知模块后,模型的 PPL 增加了 4.17% 和 1.73%,F1 减少了 5.27% 和 5.11%;去除个性理解模块后,模型的 PPL 增加了 2.45% 和 5.7%,F1 减少了 5.91% 和 0.88%。单独去除两个模块,模型的 PPL 和 F1 指标均有所下降,表明个性感知模块与个性理解模块对于个性化对话生成均有积极意义。将二者同时去除时,模型的 PPL 增加了 5.32% 和 7.43%,达到最大值;F1 下降了 7.05% 和 5.52%,达到最小值,进一步验证了两个模块的关键作用。感知并理解对方的个性信息是人类在现实场景下进

行对话时不可或缺的动作。通过模仿这一行为,PUT更好地完成了个性化对话任务。

Table 5 Ablation study data (PUT-Flan-T5)

表5 消融实验数据(PUT-Flan-T5)

模型	PPL ↓	F1 ↑
PUT-Flan-T5	6.95	21.83
PUT-Flan-T5 w/o PP	7.24(+4.17%)	20.68(-5.27%)
PUT-Flan-T5 w/o PU	7.12(+2.45%)	20.54(-5.91%)
PUT-Flan-T5 w/o PP and PU	7.32(+5.32%)	20.29(-7.05%)

Table 6 Ablation study data (PUT-LLaMA-2-chat)

表6 消融实验数据

模型	PPL ↓	F1 ↑
PUT-LLaMA-2-chat	5.79	19.39
PUT-LLaMA-2-chat w/o PP	5.89(+1.73%)	18.40(-5.11%)
PUT-LLaMA-2-chat w/o PU	6.12(+5.70%)	19.22(-0.88%)
PUT-LLaMA-2-chat w/o PP and PU	6.22(+7.43%)	18.32(-5.52%)

5 结语

为深入探讨个性感知和个性理解在个性化对话生成中的作用,本文提出一个包含个性感知模块与个性理解模块的PUT模型,同时设计了一个创新的个性化对话数据集PPU。实验结果表明,在PersonaChat数据集上,PUT的困惑度平均减小了5.39,F1值平均提升了1.86,流畅性相较于基线模型平均提升了15.55%,个性一致性平均提升了6.27%,验证了个性感知与个性理解的积极作用。PUT可以将对方说话人的个性信息显式地推理出来,并进行理解分类,具有更强的可解释性与灵活性;而PPU数据集的引入可为个性化对话生成领域提供新的研究视角,为对话过程中的实时个性推理提供实验平台。尽管PUT生成了个性类别标签以辅助对话生成,但其仅仅是作为上下文供大模型生成相关内容。后续研究可考虑利用检索增强技术,根据类别标签搜索相关个性资料,进一步提示生成式模型以生成更丰富的回复。

参考文献:

- [1] LI J, GALLEY M, BROCKETT C, et al. A persona-based neural conversation model[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, 2016: 994-1003.
- [2] ZHANG S, DINAN E, URBANEK J, et al. Personalizing dialogue agents: I have a dog, do you have pets too? [C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, 2018: 2204-2213.
- [3] WELLECK S, WESTON J, SZLAM A, et al. Dialogue natural language inference[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019: 3731-3741.
- [4] ZHENG Y, CHEN G, HUANG M, et al. Personalized dialogue generation with diversified traits[DB/OL]. <https://arxiv.org/abs/1901.09672>.
- [5] XU J, SZLAM A, WESTON J. Beyond goldfish memory: long-term open-domain conversation[C]//Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics, 2022: 5180-5197.
- [6] XU X, GOU Z, WU W, et al. Long time no see! open-domain conversation with long-term persona memory[C]//Findings of the Association for Computational Linguistics, 2022: 2639-2650.
- [7] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 5998-6008.
- [8] GOLOVANOV S, TSELOUSOV A, KURBANOV R, et al. Lost in conversation: a conversational agent based on the transformer and transfer learning[C]//The NeurIPS'18 Competition, 2020: 295-315.
- [9] CHEN R, WANG J, YU L, et al. Learning to memorize entailment and discourse relations for persona-consistent dialogues[C]//Proceedings of the 37th AAAI Conference on Artificial Intelligence, 2023: 12653-12661.
- [10] LIU Q, CHEN Y, CHEN B, et al. You impress me: dialogue generation via mutual persona perception[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020: 1417-1427.
- [11] SONG H, WANG Y, ZHANG K, et al. BoB: BERT over BERT for training persona-based dialogue models from limited personalized data[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, 2021: 167-177.
- [12] NIE Y, WILLIAMSON M, BANSAL M, et al. I like fish, especially dolphins: addressing contradictions in dialogue modeling[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, 2021: 1699-1713.
- [13] XU F, YING J R. A review of user profile research at home and abroad[J]. Library Science Research, 2020(12): 7-16.
徐芳,应洁茹.国内外用户画像研究综述[J].图书馆学研究,2020(12): 7-16.
- [14] LOSHCILLOV I, FRANK H. Decoupled weight decay regularization[C]//International Conference on Learning Representations, 2018: 1-14.
- [15] CHUNG H W, HOU L, LONGPRE S, et al. Scaling instruction-finetuned language models[DB/OL]. <https://arxiv.org/abs/2210.11416>.
- [16] TOUVRON H, MARTIN L, STONE K, et al. Llama 2: open foundation and fine-tuned chat models[DB/OL]. <https://arxiv.org/abs/2307.09288>.
- [17] EDWARD J H, SHEN Y L, WALLIS P, et al. LoRA: low-rank adaptation of large language models[C]//International Conference on Learning Representations, 2021: 1-26.
- [18] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2019: 4171-4186.
- [19] SANH V, DEBUT L, CHAUMOND J, et al. DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter[DB/OL]. <https://arxiv.org/abs/1910.01108>.
- [20] LIU Y, OTT M, GOYAL N, et al. RoBERTa: a robustly optimized BERT pretraining approach[DB/OL]. <https://arxiv.org/abs/1907.11692>.
- [21] WOLF T, SANH V, CHAUMOND J, et al. Transfertransfo: a transfer learning approach for neural network based conversational agents[DB/OL]. <https://arxiv.org/abs/1901.08149>.
- [22] RADFORD A, WU J, CHILD R, et al. Language models are unsupervised multitask learners[EB/OL]. <https://openai.com/research/gpt-2-1-5b-release>.
- [23] LEWIS M, LIU Y, GOYAL N, et al. BART: denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020: 7871-7880.

(责任编辑:尹晨茹)