

基于大语言模型的多模态社交媒体信息流行度预测研究

王洁, 王子瞳, 彭岩, 郝博文
(首都师范大学管理学院, 北京 100089)

摘要: 针对现有多模态社交媒体信息流行度预测算法对特征依赖强、泛化能力不足、面对少样本/冷启动环境表现不佳的问题, 提出了一种基于大语言模型指令微调 and 人类对齐的多模态社交媒体流行度预测模型 MultiSmpLLM。首先, 定义面向冷启动用户的多模态社交媒体流行度预测任务。其次, 构建多模态微调指令, 并分别通过低秩适配微调 (LoRA) 和冻结微调 (Freeze) 方法对大语言基座模型 (Llama3) 进行指令微调。最后, 提出了一种改进直接偏好优化 (DPO) 的算法 IDPOP, 通过构造偏好数据, 并对 DPO 损失函数施加由参数调节的惩罚项, 解决了基于人类反馈的强化学习 (RLHF) 算法训练不稳定、不收敛, 以及标准 DPO 在社交媒体流行度预测任务中产生错误优化的问题。实验结果表明, MultiSmpLLM 显著优于传统多模态预测模型和 GPT-4o 等多模态大语言模型。

关键词: 大语言模型; 流行度预测; 指令微调; 人类对齐

中图分类号: TP393

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024193

Research on multimodal social media information popularity prediction based on large language model

WANG Jie, WANG Zitong, PENG Yan, HAO Bowen
School of Management, Capital Normal University, Beijing 100089, China

Abstract: To address the limitations of strong feature dependency, insufficient generalization, and inadequate performance in few-shot/cold-start settings in existing multimodal social media popularity prediction algorithms, a MultiSmpLLM model based on large language model with instruction fine-tuning and human alignment was proposed. Firstly, the task of multimodal social media popularity prediction for cold-start users was defined. Secondly, multimodal fine-tuning instructions were constructed, and the large language model (Llama3) was instructionally fine-tuned using the low-rank adaptation (LoRA) and parameter freeze (Freeze) method. Finally, an improved direct preference optimization (DPO) algorithm IDPOP was developed by constructing preference data and adding a parameter-tuned penalty to the DPO loss function, resolving instability and non-convergence in RLHF and incorrect optimization in standard DPO for social media popularity prediction. Experiments show MultiSmpLLM outperforms conventional multimodal prediction models and multimodal large language models such as GPT-4o.

Keywords: large language model, popularity prediction, instruction fine-tuning, human alignment

收稿日期: 2024-08-14; 修回日期: 2024-11-01

通信作者: 郝博文, 6974@cnu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62172287, No.62402328); 北京市教育委员会科研计划基金资助项目 (No.KM202410028007)

Foundation Items: The National Natural Science Foundation of China (No.62172287, No.62402328), R&D Program of Beijing Municipal Education Commission (No.KM202410028007)

0 引言

随着微博、推特等平台的持续发展，社交媒体已成为公众获取信息和传播信息的主要途径，如何有效预测信息在社交媒体上的流行度成为计算社会科学和网络科学等领域的研究热点。社交媒体流行度预测（SMPP, social media popularity prediction）旨在利用社交媒体平台的数据和信息来预测用户发布内容的受欢迎程度，这不仅有助于洞察用户的偏好和行为模式，也在推荐系统^[1]、在线广告^[2]、舆情治理^[3]等应用中具有重要作用。社交媒体平台上积累了大量用户生成内容，并且这些内容越来越趋于多元化，用户发布的信息不再局限于文本，而是包含图像、音视频、时空信息、标签等诸多类型的信息，充分利用这些信息对社交媒体流行度预测具有重要意义。多模态社交媒体流行度预测任务，即根据多模态信息，如输入的图片、文本、元数据等，预测社交媒体的流行度，如图1所示。

早期的研究通常采用点过程和特征工程的方法进行社交媒体流行度预测，这些方法虽然能对大部分的浏览活动进行有效建模^[4]，但同时也存在一些限制。例如，点过程方法缺乏对社交媒体信息本身内容的考虑^[5]，而特征工程方法极度依赖人工特征的质量，需要研究人员具备专业知识才能对不同平台设计有效的特征。近年来，得益于深度学习领域的发展，融合多模态特征的社交媒体流行度预测模型成为学者们主要的研究方向。多模态社交媒体流行度预测利用深度学习技术，以端到端的方式对社交媒体中多种模式的数据进行学习，然后使用特征

融合技术建立各模态特征之间的联系并预测社交媒体信息的流行度。此类研究有效解决了特征工程方法面临的启发式问题，并且由于考虑了多种模态的特征，通常能够获得比早期方法更好的性能，但其仍存在问题。1) 虽然模型可以从数据中自动提取特征，但仍需要针对平台特点设计不同的模型，因此缺少一种泛化性强、能够迁移至不同平台的预测模型。2) 在真实社交媒体平台中，发布帖子较少的用户占比较高^[6]，以往的研究通常缺乏对此类冷启动用户的考虑。3) 传统的流行度预测模型在训练时需要大量标注的社交媒体数据，在少样本环境中表现不佳。

大语言模型（LLM, large language model）的出现为以上问题提供了解决思路。得益于LLM强大的自然语言处理能力，一种方法是利用LLM直接进行社交媒体流行度预测。具体来说，通过上下文学习的方式使LLM理解预测任务，然后将社交媒体数据中的多模态特征构造为提示词输入LLM中进行预测。然而，3.4节中的实验结果表明，LLM通常无法给出精准的回答，难以完成流行度预测任务。另一种方法是受指令微调的启发，可以构建指令微调数据集，即要求LLM按照模板规定的指令格式回答问题，从而赋予其解决该预测任务的能力。但上述方法需要人为构造模板，且LLM通常无法判断生成答案的好坏，因此生成的答案可能与人类意图存在偏差。相对于直接通过模板微调LLM，基于人类反馈的强化学习（RLHF, reinforcement learning from human feedback）算法构造偏好

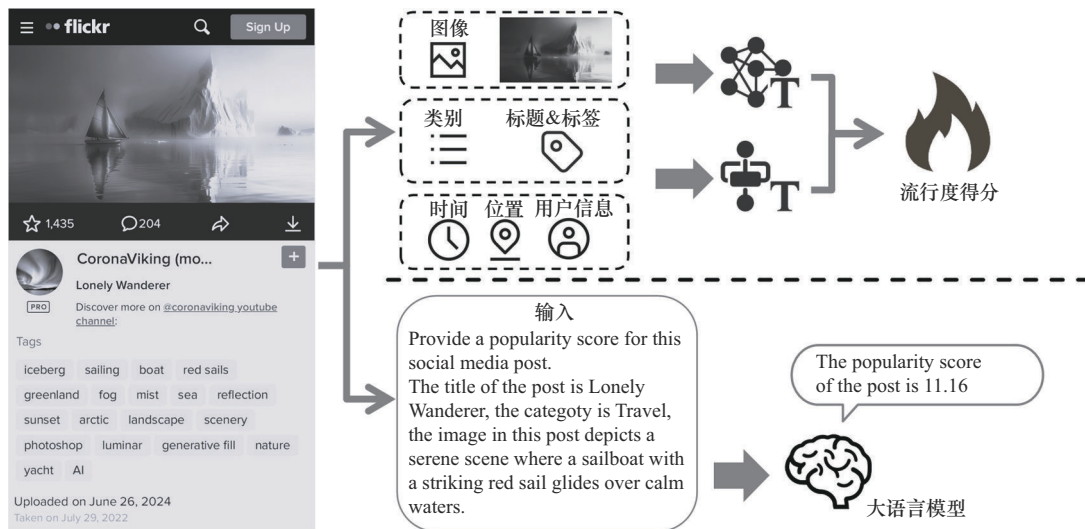


图1 多模态社交媒体流行度预测任务

数据,通过奖励模型标注 LLM 生成答案的相对好坏,因此能够赋予其识别生成答案好坏的能力,并进一步生成符合人类意图的答案。但 RLHF 算法需要额外训练奖励模型,且在训练中存在不稳定、收敛难的问题,增加了模型训练的复杂度和不稳定性,难以有效提高模型性能。

为解决上述问题,本文提出了一种新的多模态社交媒体流行度预测模型 MultiSmpLLM。首先构造指令,将多模态信息转换成 LLM 能够接受的自然语言形式。然后利用低秩适配 (LoRA, low-rank adaptive) 微调和 Freeze 微调方法对大语言基座模型 (Llama3) 进行微调,使微调后的模型能够初步理解该预测任务。之后,为强化 LLM 执行此预测任务的能力,提出了直接偏好优化 (DPO, direct preference optimization) 的改进算法正向直接偏好优化 (IDPOP, improve DPO positive) 算法。具体而言,构造偏好数据,并对 DPO 损失函数施加由参数调节的惩罚项,有效解决了主流 RLHF 算法训练不稳定、不收敛,以及标准 DPO 在社交媒体流行度预测任务中可能产生错误优化的问题。本文首次将 LLM 应用于多模态社交媒体流行度预测任务,并提出了一种不受特征限制,能够进行跨平台/跨数据集的多模态社交媒体流行度预测模型,解决了传统预测模型泛化性差的问题。实验结果表明,本文模型在少样本流行度预测任务中显著优于传统模型和未经微调的以及经过微调的大语言模型。研究表明,通过指令微调和正向直接偏好优化可以使大语言模型与具体回归任务对齐,该工作为后续类似研究提供了思路 and 基础。

1 相关研究和准备工作

1.1 社交媒体流行度预测

学者们在社交媒体流行度预测领域已进行了大量研究,现有研究方法可以分为以下 3 类。

1) 点过程方法。将流行度视为用户转发行为的到达过程,常用的建模方法有泊松过程和霍克斯点过程。在基于点过程的研究中,信息转发的时间^[7]、覆盖范围和强度^[8]、用户行为规律^[9]等都会影响信息的流行度。但点过程方法通常对社交媒体本身的内容缺乏考虑,因此在多模态领域中表现不佳。

2) 特征工程方法。关键在于对社交媒体中多

种模式的数据进行特征提取和特征融合,并在特征与流行度之间建立一种关系,学者们一般从时序^[10-12]、结构^[13-14]、内容^[15-17]和用户^[18-20]4 个方面对流行度进行预测。然而,由于依赖特征,这种方法常常面临启发式问题,难以在新的领域推广。

3) 深度学习方法。该方法可以从输入数据中自动捕获特征,解决了特征工程方法面临的启发式问题。基于深度学习的研究通常使用图像预训练网络^[21]、词到向量模型^[22]或图网络^[23]对多模态特征进行端到端的提取,在考虑多模态内容的同时有效解决了启发式问题。但基于深度学习的预测模型仍未摆脱对特征的依赖,导致模型泛化性差、难以迁移至其他平台。

1.2 大语言模型微调

1.2.1 指令微调

指令微调指使用自然语言形式的数据对预训练后的 LLM 进行参数微调^[24]。首先需要构建自然语言形式的问答对,然后通过有监督的方式对 LLM 的参数进行微调。微调指令一般包含指令、输入和输出三部分,表 1 展示了不同微调指令下模型输入和输出的示例。

字段	示例 1	示例 2
指令	Please answer this question	Please translate from English to Chinese
输入	What is the capital of China	What is the capital of France
输出	Beijing	法国的首都是什么

目前已有诸多研究表明,LLM 仅使用少量样本进行指令微调即可解决多种下游任务^[25]。经过指令微调的 LLM 能够展现出较强的指令遵循能力,从而与各类下游任务对齐,并且在冷启动、跨域等场景下表现出优异的性能。例如,文献^[26]提出了一种基于 LLM 的全方位推荐系统,在少样本、冷/暖场景和跨领域场景中的推荐性能都优于传统的协同过滤推荐系统。文献^[27]利用标注的仇恨言论语料对 LLM 进行指令微调,提出了一种新的社交网络仇恨言论检测方法,实验证明基于 LLM 的方法分类性能优于传统预训练模型。此外,学者们在主题分类^[28]、疾病风险提示^[29-30]等其他细分领域中的研究也表明了 LLM 方法在解决传统预测问题时的有效性。

然而，由于大语言模型的参数量巨大，进行全量微调（Full-Tuning）需要较多的算力资源开销。因此，学者们通常使用参数高效微调的方法来调整模型中的一些层或参数。参数高效微调的方法可以显著降低需要训练的参数量，同时保证微调后的模型性能与全量微调相接近^[31-32]。

1.2.2 低秩适配微调

低秩适配（LoRA）微调^[33]是目前主流的参数高效微调方法之一，LoRA 微调首先冻结预训练模型的权重，然后在其参数矩阵上添加低秩分解矩阵来近似每层的参数更新，从而减少需要训练的参数量。

对于待更新的预训练权重矩阵 W_0 ，低秩适配微调将其更新表示为 $W = W_0 + \Delta W$ 。其中，原始权重矩阵 $W_0 \in \mathbb{R}^{d \times k}$ ， W 是更新后的权重矩阵， ΔW 是微调过程中的权重变化。LoRA 微调的基本思想是用低秩分解的方式表示 ΔW ，即 $\Delta W = BA$ ，其中， $B \in \mathbb{R}^{d \times r}$ 和 $A \in \mathbb{R}^{r \times k}$ 是低秩分解矩阵。在实际训练时，只需要训练 A 和 B 即可适配下游任务。在前向传播过程中， W_0 和 ΔW 都与相同的输入 x 相乘，其输出向量如式(1)所示。

$$h = W_0 x + \Delta W x = W_0 x + B A x \quad (1)$$

1.2.3 冻结微调

冻结微调（Freeze）同样是参数高效微调方法之一，Freeze 方法冻结模型大部分层，使其不参与反向传播，仅对少数关键层或参数进行微调。在实际应用中，通常冻结模型中靠前层的参数，以保留模型的预训练知识^[34]。而靠后层的参数则与具体任务相关，在训练时只需要在新数据集上对这些层进行微调即可赋予模型解决新任务的能力。冻结微调的优化过程可以描述为

$$L(\theta) = \mathcal{L}(y, f(x; \theta_{\text{freeze}}, \theta_{\text{train}})) \quad (2)$$

其中， θ 为更新后的参数， θ_{freeze} 和 θ_{train} 分别为冻结的参数和待训练的参数， x 为输入， y 为标签。

1.2.4 前缀微调

前缀微调（Prefix-Tuning）通过在大语言模型每一层 Transformer 的最前面加入连续和可训练的 Token 前缀，相较于离散的 Token 前缀更好优化，且效果更好^[31]。在微调阶段，大语言模型的原始参数保持不变，仅对前缀向量进行参数优化，有效降低了微调的成本。前缀微调的优化过程可以描述为

$$L(\theta) = \mathcal{L}(y, f(x; \theta_{\text{prefix}}, \theta_{\text{trans}})) \quad (3)$$

其中， θ_{prefix} 表示可训练的和添加的前缀参数， θ_{trans} 表示大语言模型的 Transformer 参数。

1.3 人类对齐

1.3.1 基于人类反馈的强化学习

尽管经过指令微调的 LLM 可以执行特定的下游预测任务，但模型的训练目标是根据上下文内容预测下一个词元，输出的内容可能不符合人类的价值偏好。因此，研究人员提出了人类对齐^[35]概念，目的是保证模型能够输出与人类期望或偏好一致的回答。RLHF 算法是目前主流的对齐方法之一^[36]，相对于直接通过模板进行微调，RLHF 算法构造偏好数据，并通过训练奖励模型来标注 LLM 输出回答的相对好坏，因此能够赋予 LLM 识别较优回答的能力，以生成符合人类意图的回答，Claude^[37]、Llama-2^[38]等研究都证明了该方法的有效性。

然而在实际应用中，RLHF 需要额外训练奖励模型，并通过强化学习和无监督的方式对 LLM 进行微调。这一过程不仅会消耗大量的计算资源，且强化学习算法在训练中存在不稳定、难收敛的问题，无法对模型的行为进行精确控制。为了解决这一问题，DPO 去除了对齐算法中对 LLM 采样和强化学习的部分，改为通过监督学习的方式并使用高质量对齐数据集对大语言模型进行微调^[39]。相比于 RLHF，DPO 可以在消耗较少计算资源的同时获得更好的性能和更高的稳定性。

1.3.2 直接偏好优化

DPO 的主要思想是变换 RLHF 目标函数的形式，并通过 Bradley-Terry 模型消除奖励函数 $r(x, y)$ ，从而不需要训练奖励模型，直接优化大语言模型的参数。DPO 的目标函数与 RLHF 一致，如式(4)所示。

$$L(\theta) = \max_{\pi_{\theta}} \mathbb{E}_{x \sim D, y \sim \pi_{\theta}(y|x)} [r_{\phi}(x, y)] - \beta D_{\text{KL}}[\pi_{\theta}(y|x) \parallel \pi_{\text{old}}(y|x)] \quad (4)$$

其中， π_{θ} 是模型的当前策略， $\pi_{\theta}(y|x)$ 是在给定输入 x 的情况下，模型生成输出 y 的概率； D 是偏好数据集，包含模型生成的不同输出和对应的人类偏好。 $r_{\phi}(x, y)$ 是 RLHF 算法中参数化的奖励函数； D_{KL} 是一种称为 KL 散度的正则项，表示当前策略 π_{θ} 与更新前策略 π_{old} 的差异； β 是控制参数，用于

调整正则项的权重。将KL (Kullback-Leibler) 散度函数展开并对式(4)进行化简, 即可得到待优化模型 π_θ 中奖励函数 r_ϕ 的表示, 如式(5)所示。

$$r_\phi(x,y) = \beta \log \frac{\pi_\theta(y|x)}{\pi_{old}(y|x)} + \beta \log Z(x) \quad (5)$$

接下来, 使用Bradley-Terry 模型对奖励函数进行建模, Bradley-Terry 模型表示为

$$P(y_w > y_l|x) = \frac{\exp(r(x,y_w))}{\exp(r(x,y_w)) + \exp(r(x,y_l))} \quad (6)$$

其中, x 为输入, y_w 和 y_l 分别为模型回答的正例和负例。将式(5)中的奖励函数代入式(6)并化简, 即可得到DPO 的损失函数为

$$\mathcal{L}_{DPO}(\pi_\theta; \pi_{old}) = -\mathbb{E}_{(x,y_w,y_l) \sim D} \left[\log \sigma \left(\beta \log \frac{\pi_\theta(y_w|x)}{\pi_{old}(y_w|x)} - \beta \log \frac{\pi_\theta(y_l|x)}{\pi_{old}(y_l|x)} \right) \right] \quad (7)$$

其中, σ 是逻辑函数, 表示为 $\sigma(x) = \frac{1}{1 + \exp(-x)}$ 。

2 方法

2.1 模型框架

MultiSmpLLM 模型结构如图2所示, 主要分为4个步骤。

1) 定义冷启动多模态社交媒体流行度预测任

务。将预测单条社交媒体帖子流行度转为根据用户的历史发帖信息预测其新发布帖子的流行度, 通过输入用户的历史发帖信息赋予模型刻画用户画像的能力。

2) 将多模态信息转换成LLM能够接受的自然语言形式, 构建多模态微调指令。对于多模态社交媒体中的视觉信息, 使用GPT-4模型将用户发布的图像转化为LLM可以接受的文本信息。将转化后的文本信息与其他文本信息和元数据信息整合为模型的输入, 将流行度得分作为模型的输出, 并为预测任务构建合理的提示, 形成完整的多模态微调指令。

3) 对基座模型执行微调, 使模型初步理解多模态社交媒体流行度预测任务。其中, LoRA 微调保持模型预训练权重不变, 通过低秩分解矩阵来近似每层的参数更新, 而Freeze 微调对原始模型的大部分参数进行冻结, 仅训练少部分参数。

4) 采用改进正向直接偏好优化算法IDPOP进行对齐, 强化大语言模型执行多模态社交媒体流行度预测任务的能力。首先构建偏好数据, 并在DPO 的基础上引入由参数调节的惩罚项, 解决RLHF 算法训练不稳定、不收敛, 以及标准DPO 在训练过程中可能产生错误优化的问题。

2.2 冷启动多模态社交媒体流行度预测任务定义

冷启动多模态社交媒体流行度预测任务可以描

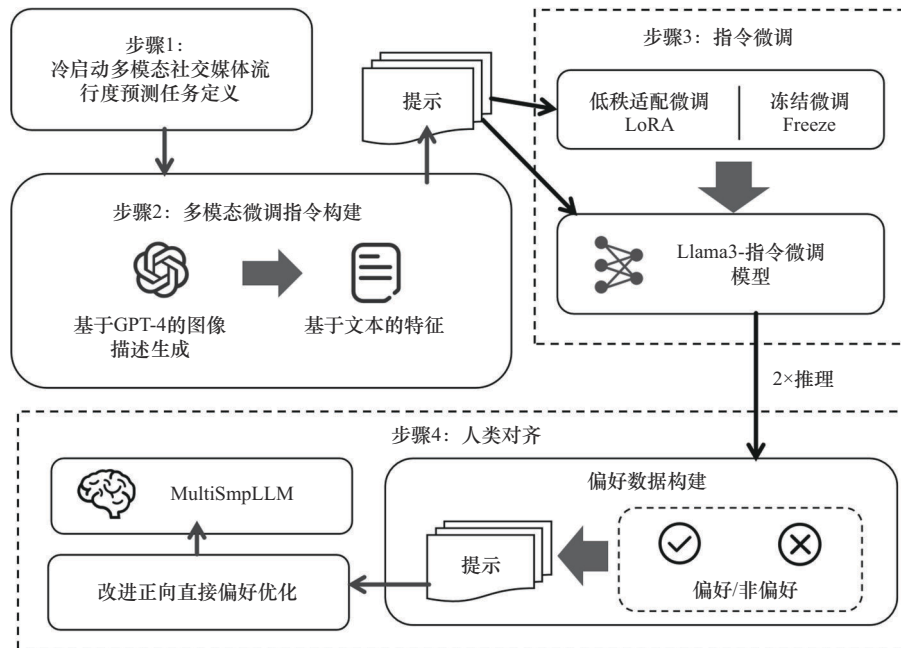


图2 MultiSmpLLM 模型结构

述为对社交媒体平台中用户 user 发布的内容 C ，通过未来某一时刻的流行度得分 S 进行预测，这一过程可以表示为 $S = f(C) = f(\text{img}, \text{text}, \text{user})$ 。其中， C 表示某个发表在社交网络中的帖子，通常包含图像、文本、用户等多模态信息， S 表示帖子的流行度得分， f 表示预测模型。

在冷启动多模态社交媒体流行度预测任务中，预测模型改为根据用户的历史发帖信息预测其新发布帖子的流行度，表示为

$$S(C_{i,n}) = f_{\text{LLM}}(C_{i,\text{old}}) = f_{\text{LLM}}\left(\sum_{k=1}^{n-1} C_{i,k}\right) \quad (8)$$

其中， $C_{i,n}$ 表示第 i 个用户最新发布的帖子，即需要预测的社交媒体信息， $C_{i,\text{old}}$ 表示用户 i 的历史发帖集合， $C_{i,k}$ 表示用户 i 发布的第 k 条帖子， f_{LLM} 表示本文模型 MultiSmpLLM。

2.3 多模态微调指令构建

本文多模态社交媒体流行度预测微调指令 J_1 由提示、输入和输出 3 个部分组成，表示为 $J_1 = \{X_I, X_{\text{in}}, X_{\text{out}}\}$ 。提示 X_I 用于指导 MultiSmpLLM 理解任务目标，规定了模型的输入和输出从而适配下游流行度预测任务。模型的输入包括用户的历史发帖信息和这些帖子的流行度得分，同时输入待预测帖子的信息，输出则是一个浮点型的数值，代表待预测帖子的流行度得分。因此提示 X_I 构建为 “Input a user’s historical posts on social media along with the popularity of these posts, and provide the popularity score for this new post based on this information. Output a number.”

X_{in} 和 X_{out} 共同构成了指令微调中的问答对，训练集和测试集中 X_{in} 和 X_{out} 的构成略有不同，此处以训练集为例进行介绍。针对某一用户构建的训练指令示例如表 2 所示。

训练集输入指令 $X_{\text{in},\text{train}} = \{C_{\text{old}}, S_{\text{old}}, C_{n-1}\}$ ，其中 C_{old} 表示用户历史发帖中包含的多模态信息，

S_{old} 表示用户历史发帖的流行度得分， C_{n-1} 表示用户最新发布帖子的上一条帖子中包含的多模态信息。 $X_{\text{in},\text{train}}$ 的构建分为 4 个步骤。

1) 图像模态转换。利用 GPT-4 模型将社交媒体帖子中的图像信息转换为图像字幕信息，并对转换后的图像字幕信息进行人工校验以确保图像模态转换的准确性。

2) 历史发帖信息 C_{old} 构建。具体来说，使用自然语言将图像字幕信息与社交媒体帖子中的文本模态信息进行拼接。根据以往相关研究的经验，本文仅选用帖子的标题、分类等内容作为文本模态信息，目的是在保证输入内容质量的同时，确保输入指令的长度不超过模型的上下文限制。除此之外， C_{old} 还使用每条帖子的 Pid 作为帖子的唯一标识符，用来与 S_{old} 中帖子的流行度得分对齐。根据实验类别的不同， C_{old} 包含至少一条，至多 3 条历史发帖信息。

3) 历史发帖流行度得分 S_{old} 构建。 S_{old} 由每条帖子的唯一标识符 Pid_i 和流行度得分 S_i 组成，且 S_{old} 的长度与 C_{old} 相同。

4) 待预测帖子信息 C_{n-1} 构建。 C_{n-1} 中的多模态信息表示与 C_{old} 类似，区别在于 C_{n-1} 只包含用户最新发布帖子的上一条帖子中包含的多模态信息，用于向模型进行提问。而输出 $X_{\text{out},\text{train}}$ 仅包含待预测帖子信息 C_{n-1} 的流行度得分 S_{n-1} 并作为模型的回答，表示为 $X_{\text{out},\text{train}} = \{S_{n-1}\}$ 。

在测试集中， $X_{\text{in},\text{test}} = \{C_{\text{old}}, C_{n-1}, S_{\text{old}}, S_{n-1}, C_n\}$ ， $X_{\text{out},\text{test}} = \{S_n\}$ 。即将训练集中用于向模型提问的多模态信息 C_{n-1} 作为历史发帖信息添加至测试集输入 $X_{\text{in},\text{test}}$ 中，而测试集中则使用用户最新发布帖子 C_n 作为待预测内容。

2.4 基于改进正向直接偏好优化的对齐

通过对 LLM 进行指令微调，模型可以根据目标用户发布的历史信息预测该用户新发布信息的流

表 2 多模态社交媒体流行度微调指令示例

字段	内容
指令	Input a user’s historical posts on social media along with the popularity of these posts, and provide the popularity score for this new post based on this information. Output a number.
输入	The target user ID is Uid. The information and popularity of the posts published by this user are as follows: The title of post Pid is Title, the category is Category, the subcategory is Subcategory, the concept is concept. The photo in the post shows Image-to-text. The popularity score of post Pid is Label. The target new post is Pid (new), the title is ... Provide the popularity score for this new post.
输出	7.52

行度。这一过程虽然赋予了模型执行多模态 SMPP 任务的能力,但其无法判断预测结果的准确度,而且其回答可能与真实流行度之间存在较大偏差。为解决这一问题,本文尝试使用 DPO 算法,即通过构造偏好数据,利用偏好数据本身直接优化模型参数以赋予模型预测信息流行度的能力。但标准的 DPO 算法仅通过提高回答对之间的相对概率来优化模型,而不考虑生成正例回答的绝对概率,容易导致算法对模型进行错误优化,使模型的预测误差增大(具体细节见 2.4.2 节)。因此,本文提出了改进的正向直接偏好优化算法 IDPOP,该算法对 DPO 损失函数施加由参数调节的惩罚项,解决了 RLHF 算法训练不稳定、不收敛,以及标准 DPO 在社交媒体流行度预测任务中产生错误优化的问题。

2.4.1 偏好数据构建

从原始数据集中按照同样的预处理和抽样方法抽取一个相同大小的子数据集,并按照 2.3 节中介绍的微调指令构建方法将数据集构建为测试指令的形式。然后使用微调后的模型对全部的数据进行推理,为了得到偏好回答和非偏好回答,这个推理过程一共进行两次,表示为

$$(S_{j,1}, S_{j,2}) = [L_{\text{fin}}(J_{\text{fin}}^1(C_j)), L_{\text{fin}}(J_{\text{fin}}^1(C_j))] \quad (9)$$

其中, $S_{j,1}$ 和 $S_{j,2}$ 是模型针对同一用户给出的不同的流行度预测结果, J_{fin}^1 是多模态信息流行度预测微调指令 J_1 的提示和输入部分, L_{fin} 是经过指令微调后的 LLM。为了从 2 个回答中选出偏好回答(chosen)和非偏好回答(rejected),分别计算预测结果与真实值 $S_{j,r}$ 之间的绝对误差,并分别记为 $M_{j,1}$ 和 $M_{j,2}$ 。其中,绝对误差较小的回答将作为对齐数据集中的偏好回答 $S_{j,\text{chosen}}$,另一个作为非偏好回答 $S_{j,\text{rejected}}$ 。对齐数据集 D_A 表示为 $D_A = \{J_{1,j}, S_{j,\text{chosen}}, S_{j,\text{rejected}}\}$ 。

直接偏好优化指令 J_2 由 3 个部分组成,分别为多模态社交媒体流行度预测微调指令 J_1 的输入部分、偏好回答和非偏好回答,表示为 $J_2 = \{J_{\text{in}}^1, S_{\text{chosen}}, S_{\text{rejected}}\}$ 。针对某一用户构建的直接偏好优化指令示例如表 3 所示。

2.4.2 改进正向直接偏好优化

标准的 DPO 算法通过最大化正例对 (x, y_w) 与负例对 (x, y_l) 之间的相对概率来优化模型,但是在某些情况下,这种优化方法会导致模型输出偏好回答 y_w 的绝对概率下降。文献[40]研究分析了这种错误优化出现的原因。首先求解式(7)中 DPO 算法的损失函数的梯度,如式(10)所示。

$$\nabla_{\theta} L_{\text{DPO}}(\pi_{\theta}; \pi_{\text{old}}) \propto - [\nabla_{\theta} \log \pi_{\theta}(y_w|x) - \nabla_{\theta} \log \pi_{\theta}(y_l|x)] \quad (10)$$

其中, ∇_{θ} 表示对参数 θ 的梯度,其正比于偏好回答与非偏好回答对数概率梯度差值的负数。为方便说明,文献[40]假设偏好回答 $y_w = (t_1, t_2, \dots, t_m, \dots, t_K)$ 和非偏好回答 $y_l = (t_1, t_2, \dots, t'_m, \dots, t_K)$ 仅在 $m = 1$ 处不同。将 $m = 1$ 处的 Token 记为 t_k , 当 $k > 1$ 时, 2 个回答的梯度差异可以表示为

$$\nabla_{\theta} \log \pi_{\theta}(t_k | y_w^{<k}, x) - \nabla_{\theta} \log \pi_{\theta}(t_k | y_l^{<k}, x) = s_j^{\{y_l^{<k}, x\}} - s_j^{\{y_w^{<k}, x\}} \quad (11)$$

其中, $y_w^{<k}$ 表示回答 y_w 的前 $k - 1$ 个 Token, s_j 表示模型生成第 j 个 Token 的概率。由于经过指令微调的大语言模型已经拥有较好的性能,因此通常存在 $s_1^{\{y_w^{<k}, x\}} \geq s_1^{\{y_l^{<k}, x\}}$ 。且式(10)中 $-\nabla_{\theta} \log \pi_{\theta}(y_w|x) - \nabla_{\theta} \log \pi_{\theta}(y_l|x) > 0$, 当 $j \neq 1$ 时, 则有 $s_j^{\{y_w^{<k}, x\}} < s_j^{\{y_l^{<k}, x\}}$, 表明对于所有相同的 Token 来说,优化后的模型 π_{θ} 与原始模型 π_{old} 相比,生成偏好回答的概率有所下降。

表 3 直接偏好优化指令示例

字段	内容
指令	The target user ID is Uid. The information and popularity of the posts published by this user are as follows: The title of post Pid is Title, the category is Category, the subcategory is Subcategory, the concept is Concept. The photo in the post shows Image-to-text. The popularity score of post Pid is Label. The target new post is Pid(new), the title is ... Provide the popularity score for this new post.
偏好回答	9.94
非偏好回答	12.63

可以看出,这种错误的优化在偏好回答与非偏好回答之间差异较小的情况下出现的概率较高。在本文研究中,模型的回答是社交媒体的流行度得分,偏好数据集中正例对与负例对差异较小,使用标准的DPO算法会导致错误优化问题的出现。为此,本文提出IDPOP算法来解决这一问题。

IDPOP算法首先在DPO的损失函数中增加了一个额外的惩罚项,以确保模型在优化过程中不会显著降低正例对的流行度得分,从而提升模型的整体性能。加入惩罚项的损失函数表示为

$$L_{\text{IDPOP}}(\pi_{\theta}; \pi_{\text{old}}) = -\mathbb{E}_{(x, y_w, y_l) \sim D} \left[\log \sigma \left(\beta \log \frac{\pi_{\theta}(y_w|x)}{\pi_{\text{old}}(y_w|x)} - \beta \log \frac{\pi_{\theta}(y_l|x)}{\pi_{\text{old}}(y_l|x)} \right) - \lambda \max \left(0, \log \frac{\pi_{\text{old}}(y_w|x)}{\pi_{\theta}(y_w|x)} \right) \right] \quad (12)$$

其中, λ 是超参数,用于控制惩罚项的强度;

$\max \left(0, \log \frac{\pi_{\text{old}}(y_w|x)}{\pi_{\theta}(y_w|x)} \right)$ 是在DPO损失函数中添加的惩罚项,当新的策略 π_{θ} 生成偏好回答的概率低于更新前策略 π_{old} 时,则会增加额外的损失,从而确保模型可以提高生成偏好回答的绝对概率。

惩罚项虽然通过添加额外的损失项避免了错误优化问题的发生,但其仍然存在两点不足。1) 损失项的调节参数 λ 是一个定值,即算法无法根据具体的偏好数据自动调整损失项的强度。2) 由于缺少经验,人为确定调节参数 λ 的大小是较为困难的,如果通过网络搜索的方式寻找较优的 λ 则会消耗大量的计算资源。因此, IDPOP 算法对调节参数 λ 进行修改,允许算法为偏好数据和非偏好数据赋予权重分数,从而动态调节损失项的强度以适配社交媒体流行度预测任务。

具体来说,首先对每个回答赋予权重分数 W 。 W 可以用来量化回答的偏好程度,计算方式如式(13)所示。

$$W_j = 10 \exp \left(-\alpha \frac{M_j}{M_{\max} - M_{\min}} \right) \quad (13)$$

其中, M_{\max} 和 M_{\min} 分别是对齐数据集 D_A 中绝对误差的最大值和最小值。 α 是一个调节系数,用于控制权重分数的衰减速度。通过式(12),绝对误差较小的回答会获得较高的权重分数,同时随着绝对误差的增加,权重分数下降的速度越快。接下来,计

算新的损失项调节参数 μ , 如式(14)所示。

$$\mu_j = \frac{\lambda}{W_{j,c} - W_{j,r} + \delta} \quad (14)$$

其中, μ_j 是第 j 对偏好数据的调节参数, $W_{j,c}$ 是偏好回答的权重, $W_{j,r}$ 是非偏好回答的权重, δ 是一个用于避免除零的小数。当偏好数据的差异较小时,新的调节参数 μ 可以使损失项的强度增加,避免优化后的模型过于偏离原始模型,而当偏好数据差异较大时则允许算法对模型进行较大的优化。

3 实验和讨论

3.1 数据集和预处理

本文使用公开数据集 SMPD^[6] 和 TPIC2017^[41] 开展实验。其中,采用 SMPD 数据集训练模型并对模型的性能进行评估,并利用 TPIC2017 数据集测试模型的跨数据集零样本泛化能力。

SMPD 数据集是 ACM MM 举办的社交媒体预测 (SMP, social media prediction) 年度挑战赛中使用的公开数据集。该数据集来自照片分享网站 Flickr, 共包含由 70 000 个用户发布的 486 000 个社交媒体帖子,每个帖子均由图像、用户资料、发布时间、文本描述等多模态信息组成。数据集的训练集部分包含按发帖时间排序的前 30 万个帖子,测试集包含剩下的部分,由于测试集的标签是非公开的,因此本文只使用训练集的部分进行实验。

在预处理阶段,首先删除了 SMPD 数据集中无法访问的帖子(这通常由用户删除或更改公开性导致),表 4 展示了处理后的 SMPD 数据集统计信息。之后通过 Uid 和发布的帖子数量对用户进行分组,删除发帖数量在 5 以下的用户。最后从剩下的用户中随机抽取了 200 个用户,每个用户保留其最新发布 5 条帖子,得到了共 1 000 个社交媒体帖子作为面向冷启动用户的少样本数据集。此外,为了避免随机抽取用户对实验结果产生影响,本文使用相同的方式构造了 2 个新的数据集 (2×200 个用户和 2×1 000 个社交媒体帖子) 作为额外的测试数据,用来保证模型的泛化性和稳定性。为进一步探索 LLM 在多样本情况下的表现,本文综合考虑 GPU 算力等因素,选取原始数据集的 5%、10% 和 15% 开展多样本预测实验。

表 4 SMPD 数据集统计信息

字段	统计值
用户数	31 413
帖子数	242 512
分类	756
标签种类	201 568
平均标签数量	20.92
平均标题长度	29.07
平均流行度得分	6.37

3.2 基线方法

对比实验主要包含三类方法。已公开源码的流行度预测算法模型 USTC-CR 和 HyFea, 对话大语言模型 GPT-3.5、ChatGLM-6B、Llama2-7B 和 Llama3.2-1B, 多模态大语言模型 GPT-4o 和 VisualGLM-6B, 这些模型的介绍如下。

USTC-CR^[19]。该模型提出了一种新的流行度预测框架, 集成了 2 个使用不同数据集训练的 CatBoost 模型, 并使用滑动窗口平均值来进行时序建模, 具有较好的泛化性。

HyFea^[20]。该模型充分考虑了如图像、类别、时空、用户资料和标签等多种多模态特征, 同时对各类特征采用多种方法进行提取和学习, 然后使用 CatBoost 来集成所有特征进行预测。HyFea 和 USTC-CR 是 2020 年 SMP 挑战中并列第一的方法。

GPT-3.5 和 GPT-4o^[42]。OpenAI 发布的大语言模型, 其中 GPT-3.5 为纯文本对话模型, GPT-4o 为多模态大语言模型。

ChatGLM-6B^[43] 和 VisualGLM-6B^[44]。智普 AI 发布的开源、支持中英双语的对话语言模型。ChatGLM-6B 使用了和 ChatGPT 相似的监督微调和 RLHF 等技术, 可以生成符合人类偏好的回答。VisualGLM-6B 是支持图像的多模态对话模型, 该模型语言部分基于 ChatGLM-6B, 图像部分通过 BLIP2-Qformer 建立视觉模型与语言模型的桥梁。

Llama2-7B 和 Llama3.2-1B^[37]。Meta 开发的开源大语言模型。采用优化的 Transformer 架构, 训练过程使用监督微调和 RLHF 等技术, 可以生成符合人类偏好的回答。该模型在大多数基准测试中性能优于其他开源模型。

3.3 实验设置

为探索模型在不同少样本预测任务上的性能表

现, 本文设置 1-shot、2-shot、3-shot 流行度预测实验。即对每个用户, 分别选取按时间排序后发布的前 1、2、3 条社交媒体帖子作为用户的历史发帖信息。剩余帖子中发布时间最早的帖子将作为训练指令中的提问内容, 最新发布的帖子作为真实值以验证模型的性能。

在基线方法方面, 流行度预测算法模型将采用各基线模型公开代码的实验设置, 在本文的少样本数据集上进行训练和评估。闭源 LLM 将采用上下文学习的方式指导模型理解流行度预测任务, 从而得到预测结果。对于开源 LLM, 本文同时报告未经微调和微调后的模型性能, 模型微调将采用与 3.3 节中类似的微调指令对模型进行训练。

在评价指标方面, 本文与 SMPD 官方一致, 选取了平均绝对误差 (MAE, mean absolute error) 和斯皮尔曼排序相关性 (SRC, Spearman's rank correlation coefficient)。由 MAE 计算预测流行度和真实流行度之间绝对误差的平均值, 计算公式如式(15)所示。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{S}_i - S_i| \quad (15)$$

其中, n 是少样本数据集中用户的数量, \hat{S}_i 和 S_i 分别是用户 i 最新发表帖子流行度的预测值和真实值, MAE 的数值越接近零, 表示模型性能越好。SRC 是真实流行度集合 S 和预测流行度集合 \hat{S} 之间的排序相关性的量化, 计算式如式(16)所示。

$$\text{SRC} = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{S_i - \bar{S}}{\sigma_S} \right) \left(\frac{\hat{S}_i - \bar{\hat{S}}}{\sigma_{\hat{S}}} \right) \quad (16)$$

其中, \bar{S} 和 σ_S 分别是真实流行度集合的平均值和方差, $\bar{\hat{S}}$ 和 $\sigma_{\hat{S}}$ 分别是预测流行度集合的平均值和方差。SRC 接近 -1 表示预测流行度和真实流行度负相关, 接近 1 则表示正相关。在本文中, SRC 越接近 1 表示模型性能越好。

在指令微调和偏好对齐阶段, 采用了全量微调、前缀微调、冻结微调及低秩适配微调等不同微调方法。值得注意的是, 由于计算资源有限, 仅选用了参数量较少的模型 (Llama3.2-1B) 进行 Full-Tuning 用于对比。其余对比实验则使用参数高效微调方法, 如 LoRA、Freeze 和 Prefix-Tuning。

3.4 实验结果

表 5 展示了 MultiSmpLLM 模型和其他基线方

法在 SMPD 数据集上的实验结果。表 6 和表 7 是在额外测试集上进行的实验，用于减少数据抽样对实

验结果产生的影响，额外进行的实验仅报告预测结果符合要求的模型。

表 5 SMPD 数据集实验结果

模型	1-shot		2-shot		3-shot	
	MAE	SRC	MAE	SRC	MAE	SRC
HyFea	2.10	0.59	1.93	0.63	1.78	0.67
CR	2.16	0.62	2.09	0.71	1.71	0.76
GPT-3.5	—	—	—	—	—	—
GPT-4o	3.07	NaN	2.78	NaN	3.05	NaN
ChatGLM-6B	—	—	—	—	—	—
VisualGLM-6B	—	—	—	—	—	—
VisualGLM-6B(LoRA)	3.77	0.11	2.43	0.09	4.76	-0.17
Llama2-7B	—	—	—	—	—	—
Llama2-7B(LoRA)	3.24	0.19	3.65	-0.10	2.67	0.24
Llama3.2-1B(Full-Tuning)	3.09	0.05	3.34	-0.01	1.69	0.75
MultiSmpLLM(Prefix-Tuning)	—	—	—	—	—	—
MultiSmpLLM(Freeze)	3.12	0.13	2.53	0.34	2.68	0.32
MultiSmpLLM(LoRA)	1.23	0.80	1.33	0.71	1.02	0.89

表 6 额外测试集-1 实验结果

模型	1-shot		2-shot		3-shot	
	MAE	SRC	MAE	SRC	MAE	SRC
HyFea	2.08	0.40	1.95	0.42	1.85	0.45
CR	1.90	0.39	1.87	0.43	1.84	0.44
VisualGLM-6B(LoRA)	3.63	0.13	2.50	0.13	4.67	-0.22
Llama2-7B(LoRA)	3.05	0.22	3.04	0.17	2.88	0.24
Llama3.2-1B(Full-Tuning)	2.54	0.12	2.66	0.14	1.98	0.55
MultiSmpLLM(Freeze)	3.31	-0.07	3.42	0.07	2.65	0.31
MultiSmpLLM(LoRA)	1.40	0.80	1.05	0.83	0.92	0.85

表 7 额外测试集-2 实验结果

模型	1-shot		2-shot		3-shot	
	MAE	SRC	MAE	SRC	MAE	SRC
HyFea	1.97	0.34	1.95	0.41	2.07	0.35
CR	1.99	0.46	2.00	0.51	2.00	0.49
VisualGLM-6B(LoRA)	3.72	0.09	2.45	-0.13	4.54	0.12
Llama2-7B(LoRA)	3.67	-0.13	3.25	0.19	3.06	0.25
Llama3.2-1B(Full-Tuning)	2.57	0.08	2.45	0.20	1.86	0.69
MultiSmpLLM(Freeze)	3.10	0.09	3.29	0.14	3.15	0.05
MultiSmpLLM(LoRA)	1.31	0.77	1.03	0.84	0.94	0.81

结果显示, 通过 LoRA 微调的 MultiSmpLLM 模型在全部的 1-shot、2-shot、3-shot 实验中获得了最好的性能。使用 Freeze 和 Full-Tuning 微调的模型性能则表现不佳, 仅略优于微调后的 VisualGLM 和 Llama2 模型。使用 Prefix-Tuning 微调的模型仅能复述输入问题, 且回答中带有乱码。这可能是由于 Prefix-Tuning 微调方法中可训练的参数量有限, 不足以精确拟合数据集的分布, 导致无法解决该预测问题。因此, 以下实验和讨论都将使用 LoRA 微调的 MultiSmpLLM 模型进行。在 3 种类型的实验中, 3-shot 实验的性能最优, 说明随着输入的用户历史发帖信息数量的增加, 模型获得了更加精准的用户画像刻画能力。从实验中可以得到以下结论。1) 其他 LLM 预测方法中, 标注“-”表明模型无法回答该问题; 标注“NaN”则表示对于所有的待预测帖子, 模型均给出同样的流行度得分, 因此无法计算 SRC 的值。这 2 种情况均说明未经指令微调的 LLM 通常不具备执行 SMPP 任务的能力。2) 经过指令微调的 VisualGLM-6B(LoRA)、Llama2-7B(LoRA)和 Llama3.2-1B(Full-Tuning)模型可以执行该预测任务, 但对比实验的结果表明此类 LLM 的性能低于传统的流行度预测模型。此类情况的原因可能与基座模型性能有关, Llama2 和 VisualGLM 均是较早发布的开源 LLM, 在训练语料的质量、训练时长、参数量等方面均不及 Llama3 模型。而 Llama3.2 虽然为近期公布的新模型, 但由于其计算资源有限, 仅能对其 1 B 版本进行全量微调用于对比, 基座模型参数量小导致该模型对自然语言的理解能力不如 7 B 等参数量的模型, 因此预测性能不佳。同时, 由于未经过对齐训练, 模型只能执行预测任务并给出符合任务要求的回答, 而无法保证回答的准确性。3) HyFea 和 USTC-CR 模型在对比实验中获得了较好的性能, 但性能略低于本文模型 MultiSmpLLM, 说明传统的流行度预测算法模型在少样本环境下的预测性能与 LLM 存在一定差距。

在多样本预测任务中, 选取传统模型 HyFea、多模态大模型 VisualGLM-6B(LoRA)和本文模型 MultiSmpLLM 进行实验, 以更全面地评估模型的性能和鲁棒性。

图 3~图 5 分别展示了各模型多样本预测任务的实验结果。其中, 随着样本数量的增加, Hy-

Fea 和 MultiSmpLLM 模型的性能在 MAE 和 SRC 这 2 种评价指标上均有所提高, 当样本数量增加至 SMPD 数据集的 15% 时, 2 种模型的性能基本持平。微调后的多模态大模型 VisualGLM-6B(LoRA)在扩充样本后虽然 MAE 略有降低, 但其在 SRC 指标上的性能表现仍然不佳。从多样本预测实验的结果可以看出, 相比传统预测模型, LLM 的优势仍在于处理小样本预测任务, 即仅利用极少样本量微调, 处理下游任务的表现就能与传统模型使用大量样本训练一致。此外, 本文提出的多模态社交媒体流行度预测模型 MultiSmpLLM 在多样本环境下同样拥有较好的预测性能, 证明了本文模型的泛用性和鲁棒性。


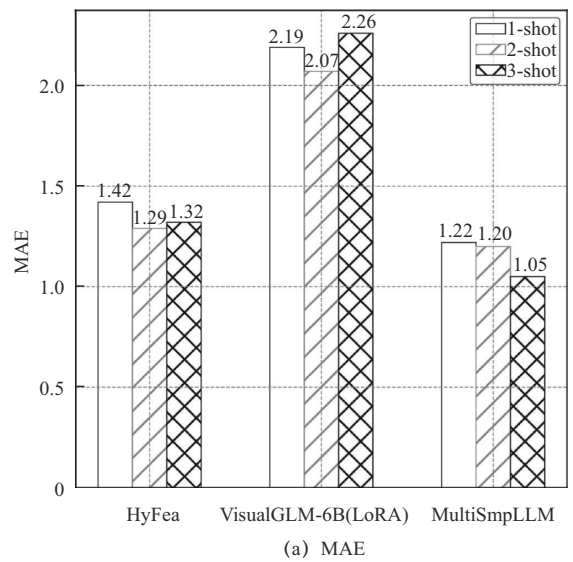


图 3 SMPD 数据集 5% 样本实验结果

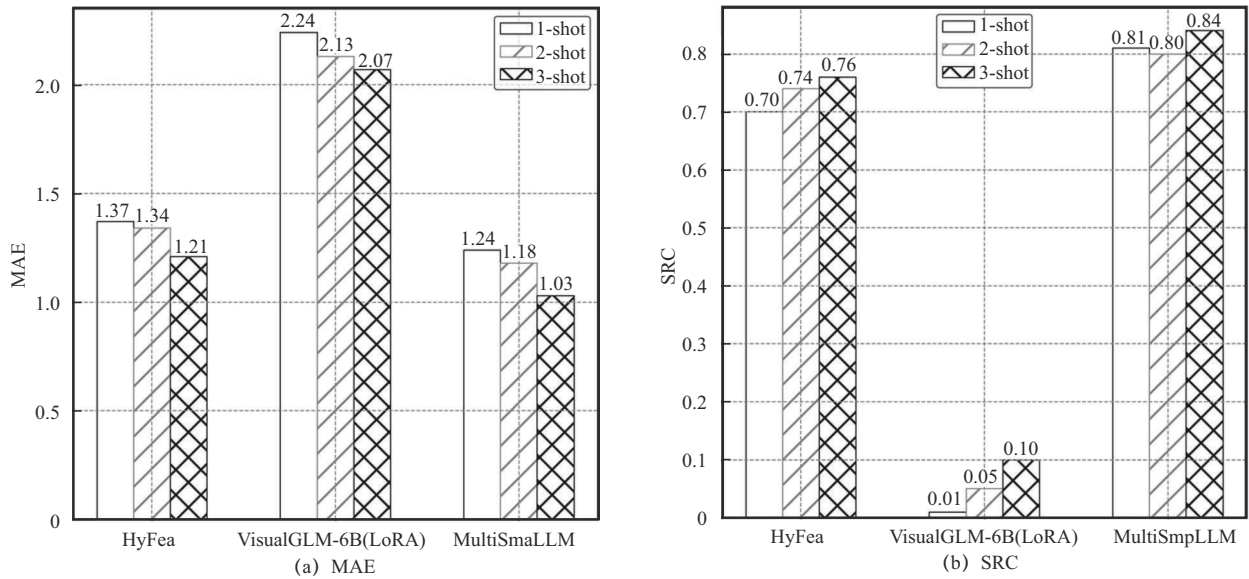


图4 SMPD数据集10%样本实验结果

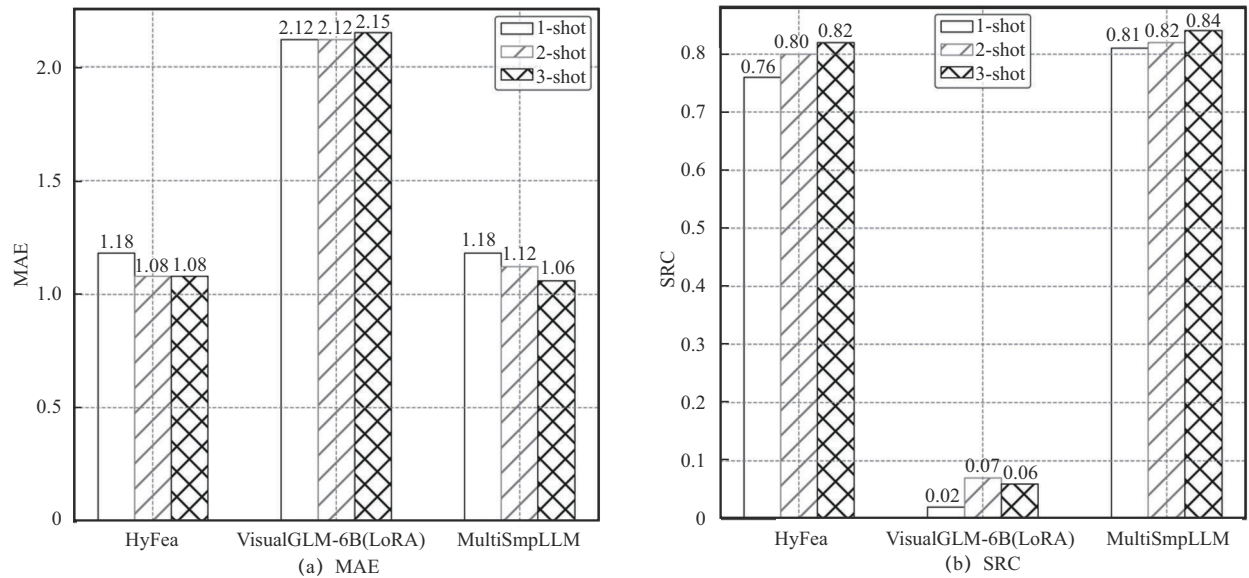


图5 SMPD数据集15%样本实验结果

3.5 消融实验

在消融实验部分，为验证 MultiSmpLLM 模型各部分的有效性，本文基于 SMPD 数据集，分别在 1-shot、2-shot 和 3-shot 实验上开展了消融实验，其中，各模型介绍如下。

Llama3。去除了 MultiSmpLLM 中的指令微调 and IDPOP 对齐，仅使用基座模型完成社交媒体流行度预测任务。

Llama3-finetune。去除了 MultiSmpLLM 中的 IDPOP 对齐，仅使用指令微调来赋予模型执行少样本流行度预测任务的能力。

Llama3-finetune-DPO。去除了 MultiSmpLLM 中的 IDPOP 对齐，改为使用 DPO 对齐。

Llama3-IDPOP。去除了 MultiSmpLLM 中的指令微调，直接使用 IDPOP 对齐。

消融实验结果如图 6 所示，其中未经任何微调的 Llama3 模型虽然在训练语料和模型参数数量上显著多于 ChatGLM 和 Llama2 等模型，但仍无法通过上下文学习的方式有效解决多模态社交媒体流行度预测的问题，因此未报告 Llama3 模型的性能。在其他模型中，去除指令微调 and IDPOP 对齐后 MultiSmpLLM 模型的性能均产生了一定程度的下降。

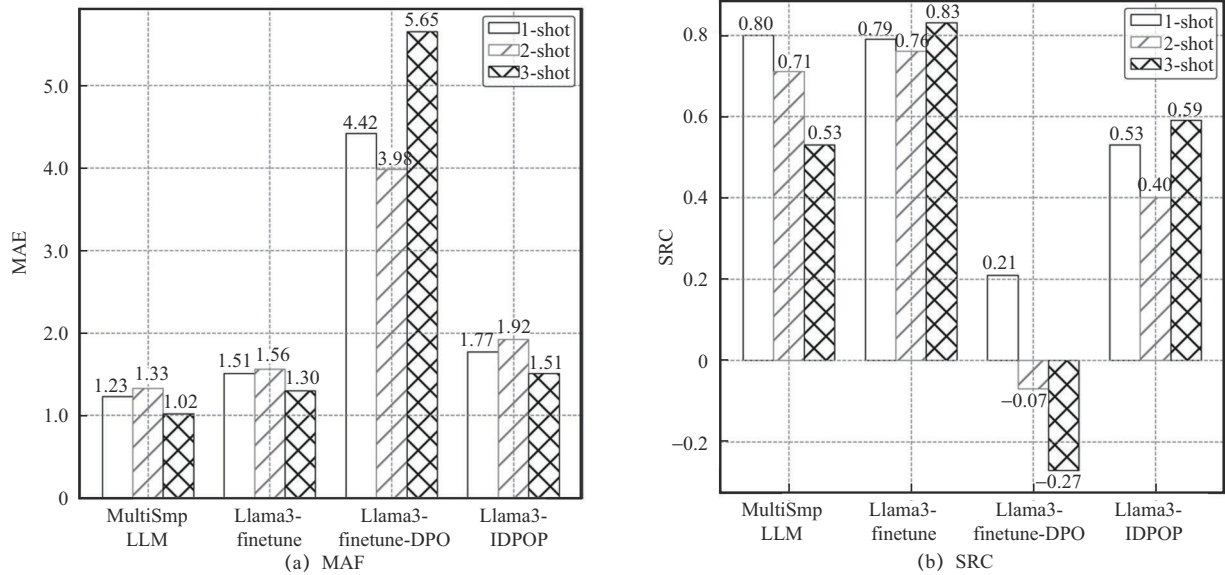


图6 消融实验结果

其中 Llama3-IDPOP 模型由于去除了指令微调, 在实验中出现了部分输出结果不符合要求的情况, 证明了指令微调提供问答模板在实际应用中的重要性。Llama3-finetune-DPO 模型性能下降较大, 几乎无法给出准确的回答, 原因在于 IDPOP 对齐过程中出现了标准 DPO 算法对模型的错误优化问题, 使模型输出偏好回答的概率降低, 说明使用 IDPOP 代替 DPO 进行模型对齐可以有效避免错误优化问题的发生。

3.6 跨数据集研究

使用另一个公开数据集 TPIC2017 验证模型的跨数据集预测能力。该数据集包含 392 个匿名用户 3 年内所有的照片分享记录, 共包含 68 万条社交媒体帖子。TPIC2017 数据集同样来自 Flickr, 但其包含的特征与 SMPD 数据集不同, 除照片图像和用户个人资料以外, TPIC2017 数据集没有收集标题、标签等文本信息, 取而代之的是标题长度、标签数量、群组数等元数据。由于该数据包含的用户较

少, 本文选用所有发帖数大于或等于 4 的用户, 每个用户保留其最新发布的 4 条帖子, 共得到 276 个用户和 1 104 条社交媒体帖子作为测试数据。

在跨数据集研究中, 本文使用在 SMPD 数据集上训练的模型对 TPIC2017 数据集中的社交媒体帖子进行流行度预测, 以评估模型的泛化能力。实验方面, 所有基于 LLM 的预测模型均会根据 TPIC2017 数据集中的特征调整输入 Prompt, 表 8 展示了跨数据集研究中 MultiSmpLLM 在 2-shot 实验下使用的输入 Prompt 示例。流行度预测算法模型由于数据集不同, 导致缺少部分输入特征, 为保证此类模型能够正常输出预测结果, 所有缺少的特征将通过填充 0 进行处理。其余实验设置与 3.3 节中的介绍相同。

表 9 展示了跨数据集实验结果, 本文模型 MultiSmpLLM 仅在 1-shot 实验中 MAE 指标略低于流行度预测算法模型 USTC-CR。但 HyFea 和 USTC-CR 模型在全部 1-shot、2-shot、3-shot 实验中的 SRC 指

表 8 跨数据集研究输入指令示例

字段	内容
指令	Input a user's historical posts on social media along with the popularity of these posts, and provide the popularity score for this new post based on this information. Output a number.
输入	The target user ID is 387@N54. The information and popularity of the posts published by this user are as follows: The title length of post 606812 is 18, the number of tags is 7, the release date is 2012-7-16. The photo in the post shows ... The popularity score of post 606812 is 7.2. The popularity score of post 608844 is 5.8. The target new post is 608845, the title length is 20, the number of tags is 0, the release date is 2012-7-23. The photo in the new post shows ... Provide the popularity score for this new post.

表 9

跨数据集实验结果(TPIC2017)

模型	1-shot		2-shot		3-shot	
	MAE	SRC	MAE	SRC	MAE	SRC
HyFea	2.38	-0.02	1.94	-0.01	1.89	0.01
USTC-CR	1.90	0.05	1.93	-0.01	1.86	0.07
VisualGLM-6B(LoRA)	4.22	0.09	3.34	0.14	4.96	0.13
Llama2-7B(LoRA)	3.28	0.16	4.53	0.19	3.37	0.22
MultiSmpLLM	1.93	0.58	1.88	0.60	1.79	0.63

标均接近 0，即模型的预测结果与真实值之间没有相关性。这表明传统的流行度预测算法模型面对全新的社交媒体数据时，由于新特征与训练特征不匹配，无法有效计算新社交媒体帖子的流行度。微调后的 VisualGLM 和 Llama2 模型虽然在 SRC 指标上的表现略优于流行度预测算法模型，但预测误差显著高于其他模型。而 MultiSmpLLM 模型得益于 IDPOP 对齐，以及基座模型具有较好的自然语言理解能力，在跨数据集研究的大部分实验和指标上均表现出最优的性能，证明了本文模型具有较好的泛化性。

4 结束语

本文提出了一种新的面向少样本/冷启动环境的多模态社交媒体流行度预测模型 MultiSmpLLM。首先构造问答模板并通过低秩适配微调 LoRA 方法赋予大语言模型进行多模态社交媒体流行度预测的能力。随后通过 IDPOP 算法进行人类对齐使模型进一步输出符合人类意图的回答。IDPOP 算法首先构造偏好数据，然后在 DPO 损失函数的基础上施加由参数调节的惩罚项，解决了 RLHF 算法训练不稳定、不收敛，以及标准 DPO 在本文预测任务中产生错误优化的问题。实验结果表明，MultiSmpLLM 模型拥有更好的预测性能和泛化性。

目前利用大语言模型解决社交媒体流行度预测问题的研究较少，本文主要解决一般的大语言模型仅通过上下文学习无法执行社交媒体流行度预测任务的问题。在实际应用中，对模型给出的流行度预测结果进行解释也是十分重要的一环，传统的流行度预测模型一般不具备解释能力。而大语言模型得益于其强大的自然语言理解能力，使准确解释流行度预测结果成为可能，这将在后续工作中进行深入研究。

参考文献:

- [1] SHOKEEN J, RANA C. Social recommender systems: techniques, domains, metrics, datasets and future scope[J]. *Journal of Intelligent Information Systems*, 2020, 54(3): 633-667.
- [2] ALRASHIDI M, SELAMAT A, IBRAHIM R, et al. Social recommendation for social networks using deep learning approach: a systematic review, taxonomy, issues, and future directions[J]. *IEEE Access*, 2023, 11: 63874-63894.
- [3] LI Y M, XU X K, RIAZ M, et al. Risk identification of public opinion on social media: a new approach based on cross-spatial network analysis[J]. *The Electronic Library*, 2024, 42(4): 576-597.
- [4] CRANE R, SORNETTE D. Robust dynamic classes revealed by measuring the response function of a social system[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2008, 105(41): 15649-15653.
- [5] DU N, DAI H J, TRIVEDI R, et al. Recurrent marked temporal point processes: embedding event history to vector[C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2016: 1555-1564.
- [6] WU B, CHENG W H, LIU P Y, et al. SMP challenge: an overview of social media prediction challenge 2019[C]//*Proceedings of the 27th ACM International Conference on Multimedia*. New York: ACM Press, 2019: 2667-2671.
- [7] BLUNDELL C, HELLER K A, BECK J M. Modelling reciprocating relationships with Hawkes processes[J]. *Advances in Neural Information Processing Systems*, 2012, 4: 2600-2608.
- [8] LIN S Y, KONG X N, YU P S. Predicting trends in social networks via dynamic activeness model[C]//*Proceedings of the 22nd ACM International Conference on Information & Knowledge Management*. New York: ACM Press, 2013: 1661-1666.
- [9] KOBAYASHI R, LAMBIOTTE R. TiDeH: time-dependent Hawkes process for predicting retweet dynamics[C]//*Proceedings of the International AAAI Conference on Web and Social Media*, 2021, 10(1): 191-200.
- [10] GAO S, MA J, CHEN Z M. Modeling and predicting retweeting dynamics on microblogging platforms[C]//*Proceedings of the Eighth ACM International Conference on Web Search and Data Mining*. New York: ACM Press, 2015: 107-116.

- [11] CANNEYT S V, LEROUX P, DHOEDT B, et al. Modeling and predicting the popularity of online news based on temporal and content-related features[J]. *Multimedia Tools and Applications*, 2018, 77(1): 1409-1436.
- [12] ZHOU F, XU X, TRAJCEVSKI G, et al. A survey of information cascade analysis: models, predictions, and recent advances[J]. *ACM Computing Surveys*, 2022, 54(2): 1-36.
- [13] BAO P, SHEN H W, HUANG J M, et al. Popularity prediction in microblogging network: a case study on sina weibo[C]//*Proceedings of the 22nd International Conference on World Wide Web*. New York: ACM Press, 2013: 177-178.
- [14] WENG L L, MENCZER F, AHN Y Y. Predicting successful memes using network and community structure[C]//*Proceedings of the International AAAI Conference on Web and Social Media*, 2014, 8(1): 535-544.
- [15] HONG L J, DAN O, DAVISON B D. Predicting popular messages in twitter[C]//*Proceedings of the 20th International Conference Companion on World Wide Web*. New York: ACM Press, 2011: 57-58.
- [16] ARORA A, HASSIJA V, BANSAL S, et al. A novel multimodal online news popularity prediction model based on ensemble learning[J]. *Expert Systems*, 2023, 40(8): 1-23.
- [17] NAVEED N, GOTTRON T, KUNEGIS J, et al. Bad news travel fast: a content-based analysis of interestingness on twitter[C]//*Proceedings of the 3rd International Web Science Conference*. New York: ACM Press, 2011: 1-7.
- [18] BAKSHY E, HOFMAN J M, MASON W A, et al. Everyone's an influencer: quantifying influence on twitter[C]//*Proceedings of the Fourth ACM International Conference on Web Search and Data Mining*. New York: ACM Press, 2011: 65-74.
- [19] WANG K, WANG P H, CHEN X, et al. A feature generalization framework for social media popularity prediction[C]//*Proceedings of the 28th ACM International Conference on Multimedia*. New York: ACM Press, 2020: 4570-4574.
- [20] LAI X, ZHANG Y H, ZHANG W. HyFea: winning solution to social media popularity prediction for multimedia grand challenge 2020[C]//*Proceedings of the 28th ACM International Conference on Multimedia*. New York: ACM Press, 2020: 4565-4569.
- [21] DING K Y, WANG R G, WANG S Q. Social media popularity prediction: a multiple feature fusion approach with deep neural networks[C]//*Proceedings of the 27th ACM International Conference on Multimedia*. New York: ACM Press, 2019: 2682-2686.
- [22] HSU C C, KANG L W, LEE C Y, et al. Popularity prediction of social media based on multi-modal feature mining[C]//*Proceedings of the 27th ACM International Conference on Multimedia*. New York: ACM Press, 2019: 2687-2691.
- [23] JIA X Q, SHANG J X, LIU D J, et al. HeDAN: heterogeneous diffusion attention network for popularity prediction of online content[J]. *Knowledge-Based Systems*, 2022, 254: 109659.
- [24] 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.
- [25] WEI J, BOSMA M, ZHAO V Y, et al. Finetuned language models are zero-shot learners[J]. *arXiv Preprint*, arXiv: 2109.01652, 2021.
- [26] KIM S, KANG H, CHOI S, et al. Large language models meet collaborative filtering: an efficient all-round LLM-based recommender system[J]. *arXiv Preprint*, arXiv: 2404.11343, 2024.
- [27] KIKKISETTI D, MUSTAFA R U, MELILLO W, et al. Using LLMs to discover emerging coded antisemitic hate-speech in extremist social media[J]. *arXiv Preprint*, arXiv: 2401.10841, 2024.
- [28] ISLAM T, GOLDWASSER D. Discovering latent themes in social media messaging: a machine-in-the-loop approach integrating LLMs[J]. *arXiv Preprint*, arXiv: 2403.10707, 2024.
- [29] RADWAN A, AMARNEH M, ALAWNEH H, et al. Predictive analytics in mental health leveraging LLM embeddings and machine learning models for social media analysis[J]. *International Journal of Web Services Research*, 2024, 21(1): 1-22.
- [30] WANG Y, INKPEN D, GAMAARACHCHIGE P K. Explainable depression detection using large language models on social media data[C]//*Proceedings of the 9th Workshop on Computational Linguistics and Clinical Psychology*. Piscataway: IEEE Press, 2024: 108-126.
- [31] 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*. Piscataway: IEEE Press, 2021: 4582-4597.
- [32] LESTER B, AL-FOU R, CONSTANT N. The power of scale for parameter-efficient prompt tuning[C]//*Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*. Piscataway: IEEE Press, 2021: 3045-3059.
- [33] HU E J, SHEN Y L, WALLIS P, et al. Lora: low-rank adaptation of large language models[J]. *arXiv Preprint*, arXiv: 2106.09685, 2021.
- [34] LIU Y H, AGARWAL S, VENKATARAMAN S. AutoFreeze: automatically freezing model blocks to accelerate fine-tuning[J]. *arXiv Preprint*, arXiv: 2102.01386, 2021.
- [35] CHRISTIANO P, LEIKE J, BROWN T B, et al. Deep reinforcement learning from human preferences[J]. *arXiv Preprint*, arXiv: 1706.03741, 2017.
- [36] OUYANG L, WU J, JIANG X, et al. Training language models to follow instructions with human feedback[J]. *Advances in Neural Information Processing Systems*, 2022, 35: 27730-27744.
- [37] BAI Y T, KADAVATH S, KUNDU S, et al. Constitutional AI: harmlessness from AI feedback[J]. *arXiv Preprint*, arXiv: 2212.08073, 2022.
- [38] TOUVRON H, MARTIN L, STONE K R, et al. Llama 2: open foundation and fine-tuned chat models[J]. *arXiv Preprint*, arXiv: 2307.09288, 2023.
- [39] RAFAILOV R, SHARMA A, MITCHELL E, et al. Direct preference optimization: your language model is secretly a reward model[C]//*Proceedings of the 37th International Conference on Neural Information Processing Systems*. Massachusetts: MIT Press, 2023: 53728-53741.

[40] PAL A, KARKHANIS D, DOOLEY S, et al. Smaug: fixing failure modes of preference optimisation with DPO-positive[J]. arXiv Preprint, arXiv: 2402.13228, 2024.

[41] WU B, CHENG W H, ZHANG Y D, et al. Sequential prediction of social media popularity with deep temporal context networks[J]. arXiv Preprint, arXiv: 1712.04443, 2017.

[42] ACHIAM J, ADLER S, AGARWAL S, et al. Gpt-4 technical report[J]. arXiv Preprint, arXiv: 2303.08774, 2023.

[43] ZENG A H, LIU X, DU Z X, et al. GLM-130B: an open bilingual pre-trained model[J]. arXiv Preprint, arXiv: 2210.02414, 2022.

[44] DING M, YANG Z Y, HONG W Y, et al. CogView: mastering text-to-image generation via transformers[J]. Advances in Neural Information Processing Systems, 2021, 34: 19822-19835.




王子瞳 (2000-), 男, 北京人, 首都师范大学硕士生, 主要研究方向为数据挖掘、机器学习等。




彭岩 (1967-), 女, 北京人, 博士, 首都师范大学教授、博士生导师, 主要研究方向为数据挖掘、机器学习等。

[作者简介]



王洁 (1977-), 女, 湖北黄石人, 博士, 首都师范大学教授、硕士生导师, 主要研究方向为社交网络分析、数据挖掘等。



郝博文 (1995-), 男, 黑龙江牡丹江人, 博士, 首都师范大学讲师, 主要研究方向为数据挖掘、推荐系统、自然语言处理等。