

个性化大语言模型研究综述

1st 陈嘉蔚
计算机学院

摘要—随着大语言模型在理解、生成和推理任务中的广泛应用，如何使模型根据不同用户的历史行为、表达风格和偏好生成更贴合个体需求的内容，逐渐成为一个重要研究方向。个性化大语言模型 (Personalized Large Language Models, PLLMs) 旨在利用用户相关信息对模型输出进行调节，从而提升响应的针对性和一致性。现有研究已经在提示增强、参数高效微调 and 偏好对齐等方面提出了多种实现路径，但与此同时，也面临个性化能力难以迁移、长期演化能力不足以及隐私与安全风险等问题。

本文围绕 PLLM 的核心技术路线展开综述，从输入层提示、模型层适配和目标层对齐三个层面对现有方法进行梳理，并分析不同技术路线在建模深度、计算开销、存储成本和适用场景上的差异。其中，输入层方法主要通过上下文注入实现快速个性化，模型层方法侧重通过参数高效微调学习更稳定的用户特征，目标层方法则通过奖励设计与优化目标重构进一步提升个性化对齐能力。在此基础上，本文进一步讨论了 PLLM 在资产可移植性、持续学习、隐私保护和可信评估等方面面临的关键挑战。

总体来看，PLLM 的研究重点正在从“如何实现个性化”逐步转向“如何稳定、持续地实现个性化”。未来，如何在保证效率、安全性与可扩展性的前提下，实现可迁移、可演化和可治理的个性化能力，将成为该方向持续发展的关键问题。

关键词—个性化大语言模型；提示工程；参数高效微调；偏好对齐；持续学习

I. 引言

近年来，以 GPT、LLaMA 和 DeepSeek 为代表的大语言模型 (Large Language Models, LLMs) 在理解、生成和推理等任务中表现出较强能力，推动了自然语言处理 (Natural Language Processing, NLP) 技术的发展 [1] [2] [3]。但与此同时，通用大语言模型大多以统一方式响应不同用户，难以充分兼顾个体在表达风格、情感倾向和内容偏好等方面的差异 [2] [4]。在实际交互中，不同用户即使面对相同输入，也可能对应完全不同的期望输出。因此，如何让模型根据用户特征生成更贴合个人需求的内容，逐渐成为大语言模型研究中的一个重要方向。

个性化大语言模型 (Personalized LLM, PLLM) 的核心目标，是利用用户相关数据——如个人资料、历史对话、行为记录以及显式或隐式偏好——对模型输出进行调节，从而生成更符合个体需求的响应 [2] [3]。现有研究已经在提示增强、参数高效微调 and 偏好对齐等方面提出了多种实现路径，并在一定程度上验证了个性化建模的有效性。然而，这些方法往往仍然依赖特定基础模型。当底层模型发生更新，原有的个性化组件，如软提示、适配器或用户表征，往往难以直接迁移，进而带来额外的训练和维护成本 [1]。

在这一背景下，PLLM 的研究重点正在从“如何实现个性化”进一步转向“如何稳定、持续地实现个性化”。相比一次性的效果提升，研究者开始更加关注个性化能力的可迁移性、可扩展性以及长期交互中的演化能力。基于此，本文围绕 PLLM 的核心技术路线展开综述，从输入层提示、模型层适配和目标层对齐三个层面梳理现有方法，并进一步讨论该方向在持续演化、资产迁移和自主适应等方面的发展趋势。

II. PLLM 核心技术架构

为缓解通用大语言模型“一刀切”式响应的局限，研究者提出了多种将用户特定信息注入基础模型的方法。一般可将这类个性化机制抽象为个性化算子，并记为 \mathcal{P} ，其作用是在模型生成过程中引入与用户相关的偏好、历史和行为信息，从而使输出更贴近个体需求。现有 PLLM 方法大体可以归纳为三个层面：输入层提示 (Personalized Prompting)、模型层适配 (Personalized Adaptation) 和目标层对齐 (Personalized Alignment)。这一划分对应了个性化信息从外部上下文注入、到内部参数调整、再到优化目标重构的不同实现路径，也反映了个性化系统在计算开销、存储成本和建模深度之间的不同权衡。

表 I
PLLM 三类核心技术路线的对比

技术层面	核心思路	是否修改模型参数	个性化深度	主要优势	主要局限	代表方法
输入层提示	将用户画像、历史交互或检索结果组织为额外上下文，与当前任务输入一同送入模型	否	较浅	实现简单，部署成本低，对底层模型无侵入，便于快速迁移	受上下文窗口、检索质量和用户信息表达形式限制，个性化深度有限	Profile-Augmented Prompting、LaMP、MemoRAG、PPlug、RECAP、CoSteer
模型层适配	通过参数高效微调等方式调整模型内部参数，学习更稳定的用户特征表示	是（少量参数）	中等到较深	个性化能力较强，能够建模更细粒度的用户差异	训练、存储和维护成本较高，大规模用户场景下可扩展性受限	PLoRA、LM-P、RecLoRA、iLoRA、OPPU、PER-PCS、PROPER、FDLoRA
目标层对齐	通过奖励设计、偏好建模或解码时优化，使模型输出更符合用户特定偏好	通常是	较深	能够从优化目标层面建模个体差异，适合长期交互和动态偏好更新	偏好建模、奖励设计和在线交互机制较复杂，实施成本较高	MODPO、VPL、RLPA、PAD、AMULET、PsPLUG

表 I 对三类个性化技术路线进行了横向比较。本节将围绕上述三个层面，对相关方法及其发展脉络进行梳理。

A. 输入层：个性化提示

输入层方法的基本思路是在不修改模型参数的前提下，将用户相关信息整理为额外上下文，并与当前任务输入一同送入模型。这类方法实现简单、部署成本低，是个性化建模中最直接的一条路线。

在这一方向中，个人资料增强 (Profile-Augmented Prompting, PAG) 方法强调将用户历史信息压缩为结构化或自然语言形式的用户画像，再用于指导生成。例如，Cue-CoT [5] 利用链式推理从对话中提取情感和性格状态；PAG [6] 采用“先总结、后生成”的流程，以降低在线推理时的上下文负担；ONCE [7] 和 Matryoshka [8] 则进一步探索了如何从多源行为数据中提炼较为稳定的核心偏好。

与这种显式压缩用户信息的做法不同，检索增强方法更强调按需调用历史信息。检索增强提示 (Retrieval-Augmented Prompting) 通常通过语义匹配，从用户过往记录中选取与当前问题最相关的内容，再将其拼接到提示中。LaMP [9] 系统比较了提示内增强 (IPA) 和解码器融合 (FiD) 等不同架构在个性化任务中的表现；

MemoRAG [10] 等工作则进一步引入长短期记忆协同机制，以及基于轻量模型的记忆管理模块，以提升在大规模历史数据上的检索与定位能力。

除了显式文本提示，部分研究尝试将用户特征表示为连续向量，并以软提示的形式注入模型，从而减少自然语言压缩带来的信息损失。软融合提示 (Soft-Fused Prompting) 即属于这一类方法。例如，PPlug [4] 使用轻量级编码器将用户习惯聚合为单一向量，并附加到任务输入中；RECAP [11] 则通过前缀编码器将历史对话映射为稠密前缀，与解码器隐藏状态进行融合。

还有一类工作从“有无个性化信息时模型内部状态的差异”入手，试图显式提取和放大个性化因素。对比提示 (Contrastive Prompting) 方法通常通过比较不同条件下的表示或输出分布来引导生成。CoS (Context Steering) [12] 通过组合不同输入条件下的 Logit 分布来调节输出概率；StyleVector [13] 在隐藏层空间中提取风格向量，并通过缩放系数进行控制；CoSteer [14] 则进一步考虑了云端模型不可访问的场景，尝试利用本地小模型提供的差异信号来辅助个性化生成，在一定程度上兼顾了控制能力与隐私需求。

总体来看，输入层方法对底层模型无侵入，使用门槛较低，适合快速部署和跨模型迁移；但这类方法的效

果通常受上下文窗口大小、检索质量以及用户信息表达形式的限制，个性化深度也相对有限。

B. 模型层：个性化适配

与输入层方法不同，模型层适配试图通过修改模型内部参数来建模更稳定、更细粒度的个体差异。这类方法通常能够获得更强的个性化能力，但也需要在训练成本、存储开销和部署复杂度之间做出权衡。由于全参数微调难以扩展到大规模用户场景，参数高效微调 (PEFT) 逐渐成为这一层面的主要技术基础，其中常见方法包括 LoRA、Prefix-tuning 等 [2]。从参数在用户之间的组织方式来看，现有方法大致可以分为共享适配模块和独立适配模块两类。

在共享适配模块 (One PEFT All Users) 范式中，所有用户共用同一组微调参数，通过附加用户 ID 或用户嵌入来区分不同偏好。PLoRA [15] 和 LM-P [16] 分别利用用户嵌入和静态标识符将个性化信息纳入 LoRA 训练过程，因此在冷启动场景中具有一定泛化能力。不过，单一共享结构对高度多样化的用户知识承载能力有限。针对这一问题，RecLoRA [17] 和 iLoRA [18] 引入了类似混合专家的思想，通过维护多组并行的 LoRA 参数，并结合软路由或动态加权机制，为不同输入选择更合适的适配路径，从而在控制额外计算开销的同时提高个性化精度。

独立适配模块 (One PEFT Per User) 范式则为每个用户维护专属的参数增量，形成典型的“基础模型 + 用户专属模块”结构。这一路径通常能够提供更强的个体定制能力，但随着用户规模扩大，存储和维护成本会迅速上升。为缓解这一问题，研究开始转向带有共享机制的协作式适配。OPPU [19] 采用两阶段训练策略，先学习共享的通用知识，再面向个人进行细化；PER-PCS [20] 进一步允许用户从共享参数池中动态组合和复用个性化参数片段，从而提升参数利用率；PROPER [21] 则通过层级化用户分组，在群体层和个体层之间逐步细化适配过程，以改善微调效果。

在分布式和隐私敏感场景下，个性化联邦学习 (PFL) 为模型层适配提供了另一条思路。相关工作尝试在不集中上传用户原始数据的前提下，实现全局知识共享与本地个性建模。FDLoRA [22] 和 FedDPA-LoRA [23] 等方法探索了如何利用双 LoRA 结构同时建模全局特性与本地差异，其中 FedDPA 通过实例级动态加

权来结合全局和本地适配器。FedSA-LoRA 则进一步指出 LoRA 中不同矩阵可能承担不同功能： A 矩阵更偏向学习通用语义，而 B 矩阵更适合保留本地习惯。基于这一观察，“共享 A 、保留本地 B ”的设计在降低通信成本的同时，也提升了非独立同分布 (Non-IID) 环境下的适配效果。

总体而言，模型层方法能够比输入层方法更充分地吸收用户特征，但其代价是更高的训练、存储和维护成本。如何在个性化效果与系统可扩展性之间取得平衡，仍然是这一方向的核心问题。

C. 目标层：个性化对齐

目标层方法关注的不再只是“向模型提供什么用户信息”或“修改哪些参数”，而是进一步追问：模型应当按照什么目标去学习和响应不同用户的偏好。其核心思路是通过重构优化目标或反馈机制，使模型在生成过程中更好地体现个体偏好的差异，从而弥补通用对齐方法在个性化场景下的不足。

这一方向通常将个性化偏好表示为多维目标的组合，并据此定义用户特定的奖励函数。基于这一思路，MORLHF 为不同偏好维度（如文体偏好、专业深度等）分别训练奖励模型，再通过线性组合指导策略学习；MODPO [24] 则将类似思想引入 DPO 框架，通过对多个对齐目标进行线性标量化，实现不依赖显式奖励模型的偏好优化。为了刻画更细粒度的用户差异，变分偏好学习 (Variational Preference Learning, VPL) [25] 引入用户特定的潜在变量，通过建模隐藏偏好分布来调节策略生成，从而提升模型对个体差异的适应能力。

随着研究从静态对齐转向动态对齐，部分工作开始将个性化视为一个持续更新的交互过程。RLPA [26] 将个性化对齐建模为在线马尔可夫决策过程 (MDP)，使模型能够在与模拟用户的多轮交互中不断修正对用户偏好的估计。其双层奖励机制同时考虑画像推断准确性和响应质量，即分别通过档案奖励 (Profile Reward) 与响应奖励 (Response Reward) 约束模型行为，从而在冷启动和长程交互场景中取得更稳定的对齐效果。除此之外，自博弈方法如 SPIN [27] 也提供了一种不依赖外部人工反馈的优化思路，即通过模型内部对候选输出进行比较和筛选，逐步改善响应质量。

除了训练阶段的目标设计，还有一些工作关注推理阶段的即时对齐，即在不重新训练模型的情况下，根据

用户偏好实时调整解码过程。解码时对齐 (Decoding-time Alignment) 方法正是这一思路的代表。PAD [28] 在解码过程中引入令牌级个性化奖励, 以指导搜索方向; AMULET [29] 则从测试时学习的角度出发, 将每个 token 的生成视为在线优化问题, 通过比较有无用户提示条件下的输出差异实现即时偏好适配。针对显式文体指令与隐式个性需求之间可能存在的冲突, PsPLUG [30] 将个性化建模为一种分布残差, 并通过带有文体约束的偏好对比训练轻量化插件, 在一定程度上兼顾了风格控制与个体特征保留。

总体来看, 目标层方法更关注模型行为背后的优化原则, 因此在理论上能够实现更深层的个性化控制; 但这类方法通常依赖更复杂的偏好建模、奖励设计或在线交互机制, 实施成本也相对更高。随着个性化系统从一次性定制走向长期交互, 目标层对齐的重要性还会进一步提升。

III. 前沿挑战与未来展望

尽管个性化大语言模型 (PLLM) 在用户建模、偏好对齐和长期交互等方面已经取得了一定进展, 但这一方向仍处于快速发展阶段, 距离稳定、可靠且可持续的实际应用还有不少问题需要解决。这些问题不仅涉及模型效果本身, 也关系到系统的可迁移性、长期演化能力、隐私保护以及安全治理。

A. 模型耦合与资产的可移植性挑战

当前许多个性化系统通常采用“基础模型 + 个性化组件”的结构, 其中软提示、适配器或用户表征等个性化资产往往与特定基础模型紧密绑定。这种做法虽然能够在单一模型上取得较好的定制效果, 但一旦底层模型发生更新, 或者部署环境从云端大模型切换到边缘端小模型, 已有个性化资产往往难以直接复用, 从而带来额外的迁移与重训练成本。如何降低这种模型耦合带来的代价, 是 PLLM 走向长期可用的重要前提。现有研究已经开始关注个性化资产的解耦问题。例如, PUMA 框架 [1] 尝试以轻量级适配器作为中介, 实现个性化提示在不同模型之间的迁移。未来仍需进一步探索更稳定的跨模型表征映射方法, 以提高个性化资产在不同版本、不同架构之间的可移植性。

B. 终身学习中的稳定性与可塑性权衡

个性化系统面向的不是一次性任务, 而是随时间不断变化的用户需求。因此, PLLM 不仅要能够利用已有偏好信息生成当前响应, 还需要在长期交互中持续更新对用户的理解。这一过程天然面临稳定性与可塑性之间的矛盾: 如果模型过于依赖已有知识, 可能难以及时适应新需求; 如果更新过快, 又容易遗忘长期形成的稳定偏好。相关研究已经注意到这一问题。FOREVER [31] 受到遗忘曲线启发, 通过动态调度记忆重放来缓解持续学习中的遗忘现象, 为长期个性化建模提供了一种思路。不过, 现有方法大多仍停留在被动更新阶段, 即在新数据到来后再调整模型。未来更值得关注的问题是, 模型能否根据环境反馈和交互上下文主动识别哪些用户特征值得保留、哪些偏好已经发生变化, 并据此进行更有选择性的更新。

C. 隐私屏障下的协作智能

个性化建模高度依赖用户数据, 而这些数据往往包含较强的私密性和情境性, 因此隐私风险始终是 PLLM 落地过程中无法回避的问题。个性化联邦学习 (PFL) 为这一问题提供了一条可行路径, 即在不直接上传原始数据的前提下实现多方协同训练。但在真实场景中, 设备算力差异、通信条件不稳定以及不同用户之间显著的非独立同分布 (Non-IID) 特征, 会使全局共享与本地个性化之间的平衡变得更加困难。换言之, 如何在保护隐私的同时维持模型的泛化能力和个体适配能力, 仍是一个尚未解决的核心问题。未来研究可以进一步结合差分隐私、安全多方计算 (MPC) 等机制, 在减少敏感信息暴露风险的同时, 提高分布式个性化建模的稳定性和实用性。

D. 伦理治理与可信评估

随着个性化程度不断加深, 模型在更贴合用户需求的同时, 也可能放大已有偏见、强化信息偏食, 甚至形成更加封闭的反馈循环。除此之外, 具备持续更新和自适应能力的个性化系统在长期运行中还可能出现行为漂移, 使模型逐渐偏离最初设定的安全边界。因此, PLLM 的研究不能只关注个性化效果, 还需要同步考虑其可解释性、安全性和社会影响。今后的一个重要方向, 是建立能够同时覆盖个性化收益与潜在风险的评测框架。例如, 除了评估模型是否更符合用户偏好, 还应

考察其是否加剧偏见、削弱信息多样性，或在长期交互中产生不可控行为。在此基础上，引入面向社会价值约束的治理机制，以及能够随着模型能力变化而持续更新的动态评测基准，将有助于推动 PLLM 朝着更可靠、更可控的方向发展。

参考文献

- [1] Z. Zhao, C. Gao, Y. Zhang, H. Liu, W. Gan, H. Guo, Y. Liu, and F. Feng, “Don’t start over: A cost-effective framework for migrating personalized prompts between llms,” *CoRR*, vol. abs/2601.12034, 2026. [Online]. Available: <https://doi.org/10.48550/arXiv.2601.12034>
- [2] J. Liu, Z. Qiu, Z. Li, Q. Dai, J. Zhu, M. Hu, M. Yang, and I. King, “A survey of personalized large language models: Progress and future directions,” *CoRR*, vol. abs/2502.11528, 2025. [Online]. Available: <https://doi.org/10.48550/arXiv.2502.11528>
- [3] Z. Zhang, R. A. Rossi, B. Kveton, Y. Shao, D. Yang, H. Zamani, F. Deroncourt, J. Barrow, T. Yu, S. Kim, R. Zhang, J. Gu, T. Derr, H. Chen, J. Wu, X. Chen, Z. Wang, S. Mitra, N. Lipka, N. K. Ahmed, and Y. Wang, “Personalization of large language models: A survey,” *Trans. Mach. Learn. Res.*, vol. 2025, 2025. [Online]. Available: <https://openreview.net/forum?id=tf6A9EYMo6>
- [4] J. Liu, Y. Zhu, S. Wang, X. Wei, E. Min, Y. Lu, S. Wang, D. Yin, and Z. Dou, “Llms + persona-plugin = personalized llms,” in *Proceedings of the 63rd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), ACL 2025, Vienna, Austria, July 27 - August 1, 2025*, W. Che, J. Nabende, E. Shutova, and M. T. Pilehvar, Eds. Association for Computational Linguistics, 2025, pp. 9373–9385. [Online]. Available: <https://aclanthology.org/2025.acl-long.461/>
- [5] H. Wang, R. Wang, F. Mi, Y. Deng, Z. Wang, B. Liang, R. Xu, and K. Wong, “Cue-cot: Chain-of-thought prompting for responding to in-depth dialogue questions with llms,” in *Findings of the Association for Computational Linguistics: EMNLP 2023, Singapore, December 6-10, 2023*, ser. Findings of ACL, H. Bouamor, J. Pino, and K. Bali, Eds. Association for Computational Linguistics, 2023, pp. 12047–12064. [Online]. Available: <https://doi.org/10.18653/v1/2023.findings-emnlp.806>
- [6] C. Richardson, Y. Zhang, K. Gillespie, S. Kar, A. Singh, Z. Raeesy, O. Z. Khan, and A. Sethy, “Integrating summarization and retrieval for enhanced personalization via large language models,” *CoRR*, vol. abs/2310.20081, 2023. [Online]. Available: <https://doi.org/10.48550/arXiv.2310.20081>
- [7] Q. Liu, N. Chen, T. Sakai, and X. Wu, “ONCE: boosting content-based recommendation with both open- and closed-source large language models,” in *Proceedings of the 17th ACM International Conference on Web Search and Data Mining, WSDM 2024, Merida, Mexico, March 4-8, 2024*, L. A. Caudillo-Mata, S. Lattanzi, A. M. Medina, L. Akoglu, A. Gionis, and S. Vassilvitskii, Eds. ACM, 2024, pp. 452–461. [Online]. Available: <https://doi.org/10.1145/3616855.3635845>
- [8] C. Li, Y. Zhuang, R. Qiang, H. Sun, H. Dai, C. Zhang, and B. Dai, “Matryoshka: Learning to drive black-box llms with llms,” *CoRR*, vol. abs/2410.20749, 2024. [Online]. Available: <https://doi.org/10.48550/arXiv.2410.20749>
- [9] A. Salemi, S. Mysore, M. Bendersky, and H. Zamani, “Lamp: When large language models meet personalization,” in *Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), ACL 2024, Bangkok, Thailand, August 11-16, 2024*, L. Ku, A. Martins, and V. Srikumar, Eds. Association for Computational Linguistics, 2024, pp. 7370–7392. [Online]. Available: <https://doi.org/10.18653/v1/2024.acl-long.399>
- [10] H. Qian, Z. Liu, P. Zhang, K. Mao, D. Lian, Z. Dou, and T. Huang, “Memorag: Boosting long context processing with global memory-enhanced retrieval augmentation,” in *Proceedings of the ACM on Web Conference 2025, WWW 2025, Sydney, NSW, Australia, 28 April 2025- 2 May 2025*, G. Long, M. Blumestein, Y. Chang, L. Lewin-Eytan, Z. H. Huang, and E. Yom-Tov, Eds. ACM, 2025, pp. 2366–2377. [Online]. Available: <https://doi.org/10.1145/3696410.3714805>
- [11] S. Liu, H. Cho, M. Freedman, X. Ma, and J. May, “RECAP: retrieval-enhanced context-aware prefix encoder for personalized dialogue response generation,” in *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), ACL 2023, Toronto, Canada, July 9-14, 2023*, A. Rogers, J. L. Boyd-Graber, and N. Okazaki, Eds. Association for Computational Linguistics, 2023, pp. 8404–8419. [Online]. Available: <https://doi.org/10.18653/v1/2023.acl-long.468>
- [12] J. Z. He, S. Pandey, M. L. Schrum, and A. D. Dragan, “Context steering: Controllable personalization at inference time,” in *The Thirteenth International Conference on Learning Representations, ICLR 2025, Singapore, April 24-28, 2025*. OpenReview.net, 2025. [Online]. Available: <https://openreview.net/forum?id=xQCXInDq0m>
- [13] K. Konen, S. F. Jentzsch, D. Diallo, P. Schütt, O. Bensch, R. E. Baff, D. Opitz, and T. Hecking, “Style vectors for steering generative large language models,” in *Findings of the Association for Computational Linguistics: EAACL 2024, St. Julian’s, Malta, March 17-22, 2024*, ser. Findings of ACL, Y. Graham and M. Purver, Eds. Association for Computational Linguistics, 2024, pp. 782–802. [Online]. Available: <https://aclanthology.org/2024.findings-eaACL.52>
- [14] H. Lv, S. Liang, H. Wang, H. Gu, Y. Wu, W. Guo, D. Lian, Y. Liu, and E. Chen, “Costeer: Collaborative decoding-time personalization via local delta steering,” *CoRR*, vol. abs/2507.04756, 2025. [Online]. Available: <https://doi.org/10.48550/arXiv.2507.04756>
- [15] M. Yan, Z. Wang, Z. Jia, S. Venkataraman, and Y. Wang, “Plora: Efficient lora hyperparameter tuning for large models,” *CoRR*, vol. abs/2508.02932, 2025. [Online]. Available: <https://doi.org/10.48550/arXiv.2508.02932>
- [16] S. Wozniak, B. Koptyra, A. Janz, P. Kazienko, and J. Kocon, “Personalized large language models,” in *IEEE International Conference on Data Mining, ICDM 2024 - Workshops, Abu Dhabi, United Arab Emirates, December 9, 2024*. IEEE, 2024, pp. 511–520. [Online]. Available: <https://doi.org/10.1109/ICDMW65004.2024.00071>

- [17] J. Zhu, J. Lin, X. Dai, B. Chen, R. Shan, J. Zhu, R. Tang, Y. Yu, and W. Zhang, “Lifelong personalized low-rank adaptation of large language models for recommendation,” *CoRR*, vol. abs/2408.03533, 2024. [Online]. Available: <https://doi.org/10.48550/arXiv.2408.03533>
- [18] X. Kong, J. Wu, A. Zhang, L. Sheng, H. Lin, X. Wang, and X. He, “Customizing language models with instance-wise lora for sequential recommendation,” in *Advances in Neural Information Processing Systems 38: Annual Conference on Neural Information Processing Systems 2024, NeurIPS 2024, Vancouver, BC, Canada, December 10 - 15, 2024*, A. Globersons, L. Mackey, D. Belgrave, A. Fan, U. Paquet, J. M. Tomczak, and C. Zhang, Eds., 2024. [Online]. Available: http://papers.nips.cc/paper_files/paper/2024/hash/cd476d01692c508ddf1cb43c6279a704-Abstract-Conference.html
- [19] Z. Tan, Q. Zeng, Y. Tian, Z. Liu, B. Yin, and M. Jiang, “Democratizing large language models via personalized parameter-efficient fine-tuning,” in *Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing, EMNLP 2024, Miami, FL, USA, November 12-16, 2024*, Y. Al-Onaizan, M. Bansal, and Y. Chen, Eds. Association for Computational Linguistics, 2024, pp. 6476–6491. [Online]. Available: <https://doi.org/10.18653/v1/2024.emnlp-main.372>
- [20] Z. Tan, Z. Liu, and M. Jiang, “Personalized pieces: Efficient personalized large language models through collaborative efforts,” in *Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing, EMNLP 2024, Miami, FL, USA, November 12-16, 2024*, Y. Al-Onaizan, M. Bansal, and Y. Chen, Eds. Association for Computational Linguistics, 2024, pp. 6459–6475. [Online]. Available: <https://doi.org/10.18653/v1/2024.emnlp-main.371>
- [21] L. Zhang, J. Wu, D. Zhou, and Y. He, “PROPER: A progressive learning framework for personalized large language models with group-level adaptation,” in *Proceedings of the 63rd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), ACL 2025, Vienna, Austria, July 27 - August 1, 2025*, W. Che, J. Nabende, E. Shutova, and M. T. Pilehvar, Eds. Association for Computational Linguistics, 2025, pp. 16 399–16 411. [Online]. Available: <https://aclanthology.org/2025.acl-long.800/>
- [22] J. Qi, Z. Luan, S. Huang, C. J. Fung, H. Yang, and D. Qian, “Fdlora: Personalized federated learning of large language model via dual lora tuning,” *CoRR*, vol. abs/2406.07925, 2024. [Online]. Available: <https://doi.org/10.48550/arXiv.2406.07925>
- [23] Y. Yang, G. Long, T. Shen, J. Jiang, and M. Blumenstein, “Dual-personalizing adapter for federated foundation models,” in *Advances in Neural Information Processing Systems 38: Annual Conference on Neural Information Processing Systems 2024, NeurIPS 2024, Vancouver, BC, Canada, December 10 - 15, 2024*, A. Globersons, L. Mackey, D. Belgrave, A. Fan, U. Paquet, J. M. Tomczak, and C. Zhang, Eds., 2024. [Online]. Available: http://papers.nips.cc/paper_files/paper/2024/hash/45a30141c6719e9cfedfb51f1c665a37-Abstract-Conference.html
- [24] Z. Zhou, J. Liu, J. Shao, X. Yue, C. Yang, W. Ouyang, and Y. Qiao, “Beyond one-preference-fits-all alignment: Multi-objective direct preference optimization,” in *Findings of the Association for Computational Linguistics, ACL 2024, Bangkok, Thailand and virtual meeting, August 11-16, 2024*, ser. Findings of ACL, L. Ku, A. Martins, and V. Srikumar, Eds. Association for Computational Linguistics, 2024, pp. 10 586–10 613. [Online]. Available: <https://doi.org/10.18653/v1/2024.findings-acl.630>
- [25] S. Poddar, Y. Wan, H. Ivison, A. Gupta, and N. Jaques, “Personalizing reinforcement learning from human feedback with variational preference learning,” in *Advances in Neural Information Processing Systems 38: Annual Conference on Neural Information Processing Systems 2024, NeurIPS 2024, Vancouver, BC, Canada, December 10 - 15, 2024*, A. Globersons, L. Mackey, D. Belgrave, A. Fan, U. Paquet, J. M. Tomczak, and C. Zhang, Eds., 2024. [Online]. Available: http://papers.nips.cc/paper_files/paper/2024/hash/5e1c255653eb98cef13f45b2d337c882-Abstract-Conference.html
- [26] W. Zhao, X. Sui, Y. Hu, J. Guo, H. Liu, B. Li, Y. Zhao, B. Qin, and T. Liu, “Teaching language models to evolve with users: Dynamic profile modeling for personalized alignment,” *CoRR*, vol. abs/2505.15456, 2025. [Online]. Available: <https://doi.org/10.48550/arXiv.2505.15456>
- [27] Z. Chen, Y. Deng, H. Yuan, K. Ji, and Q. Gu, “Self-play fine-tuning converts weak language models to strong language models,” in *Forty-first International Conference on Machine Learning, ICML 2024, Vienna, Austria, July 21-27, 2024*, ser. Proceedings of Machine Learning Research, R. Salakhutdinov, Z. Kolter, K. A. Heller, A. Weller, N. Oliver, J. Scarlett, and F. Berkenkamp, Eds. PMLR / OpenReview.net, 2024, pp. 6621–6642. [Online]. Available: <https://proceedings.mlr.press/v235/chen24j.html>
- [28] R. Chen, X. Zhang, M. Luo, W. Chai, and Z. Liu, “PAD: personalized alignment of llms at decoding-time,” in *The Thirteenth International Conference on Learning Representations, ICLR 2025, Singapore, April 24-28, 2025*. OpenReview.net, 2025. [Online]. Available: <https://openreview.net/forum?id=e7AUJpP8bV>
- [29] Z. Zhang, F. Bai, Q. Chen, C. Ma, M. Wang, H. Sun, Z. Zheng, and Y. Yang, “Amulet: Realignment during test time for personalized preference adaptation of llms,” in *The Thirteenth International Conference on Learning Representations, ICLR 2025, Singapore, April 24-28, 2025*. OpenReview.net, 2025. [Online]. Available: <https://openreview.net/forum?id=f9w89OY2cp>
- [30] Y. Song, J. Wu, S. Yuan, C. Shen, J. Wang, A. M. Rahmani, N. D. Dutt, and Y. Wang, “Styles + persona-plug = customized llms,” *CoRR*, vol. abs/2601.06362, 2026. [Online]. Available: <https://doi.org/10.48550/arXiv.2601.06362>
- [31] Y. Feng, H. Wang, J. Li, X. Chu, Z. Kang, Y. Liu, Y. Wang, P. S. Yu, and X. Wu, “FOREVER: forgetting curve-inspired memory replay for language model continual learning,” *CoRR*, vol. abs/2601.03938, 2026. [Online]. Available: <https://doi.org/10.48550/arXiv.2601.03938>