arXiv:2601.02306v1 [cs.IR] 5 Jan 2026

基于多任务学习实现 Spotify 播客广告与推广冷启动

Shivam Verma*
Spotify 伦敦，英国

Hannes Karlbom*
Spotify
斯德哥尔摩，瑞典

Yu Zhao
Spotify 斯德哥尔摩，瑞典

Nick Topping
Spotify 西雅图，美国

Vivian Chen
Spotify
旧金山 , USA

Kieran Stanley
Spotify 法国巴黎

Bharath Rengarajan
Spotify
旧金山 , USA

摘要

我们提出了一种统一的多目标模型，用于在 Spotify 播客生态系统中同时对广告和促销进行定向。我们的方法解决了个性化和冷启动初始化方面的关键挑战，尤其是针对新的广告目标。通过在多任务学习（MTL）框架中利用大规模广告与内容互动数据进行迁移学习，单一联合模型可以针对新的或数据稀少的定向任务（包括应用内促销）进行微调或直接应用。这种多目标设计通过对用户、内容、上下文和创意特征进行共享表示，同时优化广告和促销的播客成效，例如播放量、点击和关注，从而有效支持多样化的业务目标，并提升用户体验。

在线 A/B 测试显示，每次播放有效成本（eCPS）最高可降低 22%，这一效果在播放量较少的播客中尤为明显；播客播放率则提高了 18–24%。离线实验和消融实验凸显了辅助目标和特征组对冷启动表现的贡献。我们的经验表明，统一的建模策略能够提升可维护性、冷启动表现和覆盖率，同时打破以往彼此隔离的定向流程。我们还讨论了此类联合模型在实际广告系统中的权衡。

CCS 概念

• **信息系统** → **计算广告**；**推荐系统**；在线广告；• **计算方法学** →**多任务学习**。

关键词

在线广告；多任务学习；推荐系统

*两位作者对本研究的贡献相同。

本作品依据知识共享署名 4.0 国际许可协议授权。*WSDM '26*，美国爱达荷州博伊西© 2026 版权所有归作品所有者/作者所有。ACM ISBN 979-8-4007-2292-9/2026/02 https://doi.org/10.1145/3773966.3779388

ACM 参考格式：

Shivam Verma、Hannes Karlbom、Yu Zhao、Nick Topping、Vivian Chen、Kieran Stanley 和 Bharath Rengarajan。2026 年。基于多任务学习在 Spotify 上冷启动播客广告与推广。在第十九届 *ACM* 网络搜索与数据挖掘国际会议论文集（*WSDM '26*），*2026*年*2*月*22*日至*26*日，美国爱达荷州博伊西。ACM，美国纽约州纽约市，5 页。https://doi.org/10.1145/3773966.3779388

1 动机

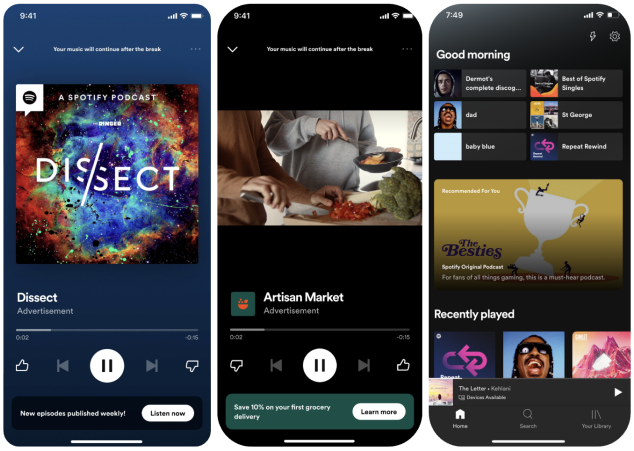

图 1：从左到右：(a) 播放中的播客音频广告。(b) 播放中的未静音播客视频广告。(c) Spotify 原创播客的展示广告。

Spotify拥有超过7亿用户，将播客视为一个重要且快速增长的内容垂类，因此，有效的个性化对于提升听众参与度、实现变现（尤其是面向超过4亿广告支持用户），以及推动播客创作者的发现与成长至关重要。该平台支持多种业务目标，从推动新剧集的初始播放量，到优化曝光到播放率（i2s）和点击率（CTR）；平台尤其注重提升播放量较低的创作者的曝光度，他们因数据稀缺而面临冷启动问题。连接用户与播客内容的主要机制有两种

内容：**广告**，例如流内音频或视频广告位（图1a、1b），以及**促销**，用于展示具有战略重要性或与用户相关的内容，例如 Spotify Originals 的展示促销（图 1c ）。尽管两者的直接目标不同（广告点击与促销带来的直接播放），但这两个渠道的共同目标都是将用户与相关且引人入胜的播客相匹配，并依托相似的用户信号（例如收听历史、明确关注的内容）和内容偏好（例如流派、主题）。因此，一个渠道中的积极互动可以为另一个渠道的决策提供参考。

历史上，这些目标由彼此独立、专门化的机器学习模型分别处理。例如，为首页推广优化*i2s*的模型，会与为新播客系列的音频广告优化点击量的模型截然不同。这种孤立且针对特定任务的方法带来了若干挑战。首先是**创新缓慢**：引入新的业务或广告目标需要从头构建模型，这涉及大量工程工作、数据收集和 A/B 测试，可能会拖慢相关工具的推出，而这些工具能帮助播客创作者触达相关受众。其次是**优化目标的冷启动问题**：面向特定受众的新广告或促销产品，例如针对新兴或新创作者的“用户在看到广告后播放广告所推广内容的可能性”，往往缺乏足够的交互数据来训练高性能的专用模型，从而妨碍这些较少被播放的创作者获得可发现性。第三是**效率低下且错失协同效应**：独立的流水线难以利用播客广告和促销之间共享的潜在模式及重叠信号，也导致各团队各自为相关产品构建相似的模型。

这些挑战促使我们探索一种通过多任务学习（MTL）实现的**统一目标优化方法**。

2 相关工作

多任务学习通过联合学习相关任务 [5–7, 11, 13, 14, 16, 17, 26]，，促进从数据丰富的广告任务向数据稀缺的促销任务迁移（反之亦然），从而解决新晋和规模较小的创作者面临的冷启动问题。通过联合建模广告和促销，我们旨在整合学习过程，减少系统间的重复，并加快新能力的部署，最终提升听众的个性化体验和创作者的增长。我们的贡献聚焦于在多利益相关方、多目标场景下，依据业务目标的一致性对任务进行分组，以打破组织壁垒[8, 9, 15, 17, 19, 25, 29], ； 这对于平衡多样化的业务目标至关重要。

工业推荐系统中的多任务学习。多任务学习通过联合学习相关目标 [3]提升泛化能力。在工业规模下，各平台已采用多任务学习来关联参与度、满意度和变现等异构业务目标 [1, 7, 16, 20, 24, 26, 28], ，这凸显了共享表示的价值，同时也需要谨慎管理干扰。我们的工作沿袭这一方向，但具体聚焦于在单一框架内联合建模播客广告和促销。

联合优化与任务相关性。多任务学习中的一个核心挑战，是在可能相互冲突的目标之间进行权衡。将多任务学习视为多目标优化，可以提供有理论依据的方法来处理帕累托权衡 [2, 8, 11, 17, 29]。另一类研究探讨何时应共同学习多个任务，研究表明，任务亲和性或相关性会显著影响迁移 [19]。在我们的场景中，我们将广告与促销整合到同一个模型中，因为它们共享用户信号和内容信号，同时仍需控制跨目标干扰。

缓解负迁移。当不同目标的梯度发生冲突时，就会产生负迁移。适用于工业场景的方法包括学习对任务损失进行加权（例如不确定性加权）[10], 、梯度平衡/归一化 [4], ，以及通过梯度手术解决冲突（PCGrad） [27], ； 此外，还有关于如何在生产环境中稳定大规模多任务排序模型的研究 [23]。多门混合专家等架构改进通过任务专属门控共享专家，以减少大规模场景中的干扰 [14], ； PLE 则引入渐进式共享/专属塔，进一步抑制推荐任务中的负迁移 [22]。我们的方法将统一建模与不平衡感知训练及审慎的共享机制相结合，在限制干扰的同时保留正向迁移。

3 系统演进与架构

我们从专用模型演进为统一的多任务学习（MTL）框架，该框架联合优化播客相关广告和促销目标。我们首先概述基线，然后对广告与促销联合模型进行形式化定义，包括任务定义和训练设置。

3.1 基线模型与初始方法

图2A展示了我们最初的仅推广多任务模型。每个训练样本都是向用户展示的一次播客推广曝光。共享特征编码器（应用批次后归一化）将输出馈送给任务专属塔——由多层感知机构成的堆叠结构——用于预测用户与推广内容的互动（例如播放、点击、点赞、关注）。

编码器接收四组特征：(1) 用户信号（历史收听记录、关注、搜索互动、高层级个人资料属性），(2) 内容信号（节目和单集标识符、学习得到的嵌入、类型、主题），(3) 上下文（时间、展示界面、会话状态），以及 (4) 推广元数据（广告位、版式、营销活动）。我们也考虑了混合专家（MoE） [12, 14, 18, 21] 变体，但共享底层模型作为主要的生产基线。

图2A和图2B展示了两种中间方案：

(1) **广告冷启动的促销模型**。我们重新使用促销模型为广告曝光评分。这使我们能够快速推出新的广告目标，但忽略了广告专属特征（例如创意类型、营销活动）以及用户与广告的互动模式。

(2) **单任务广告模型**。我们构建了一个仅广告 模型，在所有播客广告版位和广告创意（音频、视频、展示广告）上进行训练。该模型使用了类似的用户、内容和上下文特征，以及广告专属元数据（创意 ID、格式、营销活动、广告位）。尽管拥有丰富的广告日志，这种单任务方法仍难以有效平衡多样化的业务目标，也难以支持未来需要从所有平台内播客互动中学习的目标。

维护独立的数据管道和模型增加了工程开销，也限制了我们利用任务间共享结构的能力，因此促使我们寻求统一解决方案。

3.2 广告与推广联合建模的问题表述

我们将定向视为针对上下文 x（例如展示界面、时间、设备）中的用户—播客对 (u, c)，预测多个每次曝光结果。设 T 为二元预测任务的集合，包括：

- 推广后播放：推广曝光后播放；
- 广告后播放：广告曝光后播放；
- 点击：点击推广或广告；• 点赞或关注：点赞／关注推广播客。

对于每个任务 $t \in \mathrm{T}$，我们观测到一个二元标签 $y_t \in \{0, 1\}$。给定输入特征 x，模型生成任务特定概率 $p_t(x) = f_{\theta,\, t}(x)$，其参数 θ 由共享参数和任务特定参数组成。

统一模型（图 2C）由以下部分组成：

- 共享编码器 $h_\phi(x)$，将用户、内容、上下文和创意特征映射为联合表示 $z = h_\phi(x)$；
- 任务专属塔 $g_{\psi_t}(z)$，将 z 映射为每个任务 t 的逻辑值。

任务 t 的预测概率为

$$p_t(x) = \sigma\big(g_{\psi_t}(h_\phi(x))\big),$$

其中，$\sigma(\cdot)$ 是 Sigmoid函数。在架构上，共享编码器沿用了推广基线模型的设计，但融入了广告特定特征，并将广告和促销任务都纳入 T，从而能够对所有与播客相关的交互进行联合学习，同时保留任务特定能力。

3.3 优化与损失平衡

我们对 T 中的所有任务优化二元交叉熵损失，但采用两项设计来控制渠道之间的迁移：(1) 从广告到促销的自适应损失屏蔽，以及 (2) 在促销与广告之间进行来源平衡采样。

令 $\mathrm{T_P}$ 和 $\mathrm{T_A}$ 分别表示促销任务和广告任务的集合，其中 $\mathrm{T} = \mathrm{T_P} \cup \mathrm{T_A}$。我们将相应的促销曝光和广告曝光集合分别记为 $\mathrm{D^P}$ 和 $\mathrm{D^A}$，并令 $\mathrm{D} = \mathrm{D^P} \cup \mathrm{D^A}$。每个曝光 $x \in \mathrm{D}$ 都带有一个来源标签 $s(x) \in \{\mathrm{P}, \mathrm{A}\}$。

我们定义一个二元掩码 $m_{s,\, t}$ 用于规定任务 t 是否应针对来源为 s 的曝光计算损失：

$$m_{s,t} = \begin{cases} 0, & \text{if } s = \mathrm{A} \text{ and } t \in \mathcal{T}^{\mathrm{P}}, \\ 1, & \text{otherwise.} \end{cases}$$

这实现了定向迁移：促销曝光会同时更新促销塔和广告塔，而广告曝光仅更新广告塔。总体训练目标为

$$\mathcal{L} = \sum_{t \in \mathcal{T}} \lambda_t \, \mathbb{E}_{(x, y_t) \sim \mathcal{D}} \Big[m_{s(x),t} \, \ell_{\mathrm{BCE}}\big(y_t, p_t(x)\big) \Big],$$

其中，λ_t 是任务 t 的非负权重（在我们的部署中设为 1），ℓ_{BCE} 是二元交叉熵损失。在实践中，该掩码可防止广告特定信号直接影响促销塔，同时仍允许促销信号帮助广告，这一点很有价值，因为某些广告目标的数据相对稀疏。

为确保不同渠道之间保持一致，我们采用来源均衡采样：构建每个小批次时，确保约 50% 的曝光来自 $\mathrm{D^P}$，另外 50% 来自 $\mathrm{D^A}$。这样可以使促销和广告产生的梯度保持在相近的尺度，避免联合模型偏向流量更大的来源。

表1：各配置的平均精度（AP）对比。相对于基线促销模型（图2A）的变化。

任务设置	促销 AP	广告 AP
促销流仅头部	−7.9%	−8.8%
仅广告流头部	−65.2%	+27.0%
广告流 + ANC 头	−64.8%	+46.5%
促销 + 广告 五任务多任务学习	+4.5%	+50.2%

4 实验与结果

我们将联合模型与第 3.1 节中的仅促销基线和仅广告基线进行比较。我们先介绍实验设置，再呈现离线和在线结果，并总结消融实验。

4.1 实验设置

数据与划分。 我们使用 Spotify 播客广告和促销系统在数月期间的生产日志进行训练。我们按照时间将曝光划分为训练集、验证集和测试集：较早的日期用于训练，中间日期用于验证，最近的日期用于测试。广告和促销曝光合并处理，但保留渠道标签和特定任务的结果。

评估指标。 离线评估中，我们使用平均精度（AP）来概括精确率–召回率曲线；在类别严重不平衡的情况下，它比 AUC-ROC 更具参考价值。在线评估中，我们关注：

- 有效单次播放成本（eCPS）：广告支出除以由此产生的播客播放量；
- 播放率（i2s）：曝光到播放率；• 点击率（CTR）。

我们报告所有播客以及播放量较低的创作者（播放量少于 5,000 次的节目）的指标；这一细分群体受冷启动的影响尤为显著。

训练详情。 所有模型使用相同的优化器（Adam）和学习率调度。我们使用验证集上播放任务的 AP 调优超参数。

4.2 离线评估结果

表 1 对比了多目标推广–广告模型、生产基线和其他任务分组。统一的“促销 + 广告五任务多任务学习”模型表现最佳。

与仅促销基线相比，联合模型的促销 AP 提高了 +4.5%，广告 AP 提高了 +50.2%。即使加入辅助头，仅广告配置在促销任务上的表现仍然弱得多，广告任务上的表现也不及联合模型，这表明促销与广告之间的跨渠道迁移至关重要。

4.3 辅助头的影响

联合模型包含用于预测点击、点赞和关注（ANC）的辅助头。表 1 显示，与基线相比，在仅含广告的模型中添加 ANC 头可将广告 AP 从 +27% 提高至 +46.5%，这证实了对中间互动信号进行建模有助于播放预测。然而，这种仅含广告的配置会严重

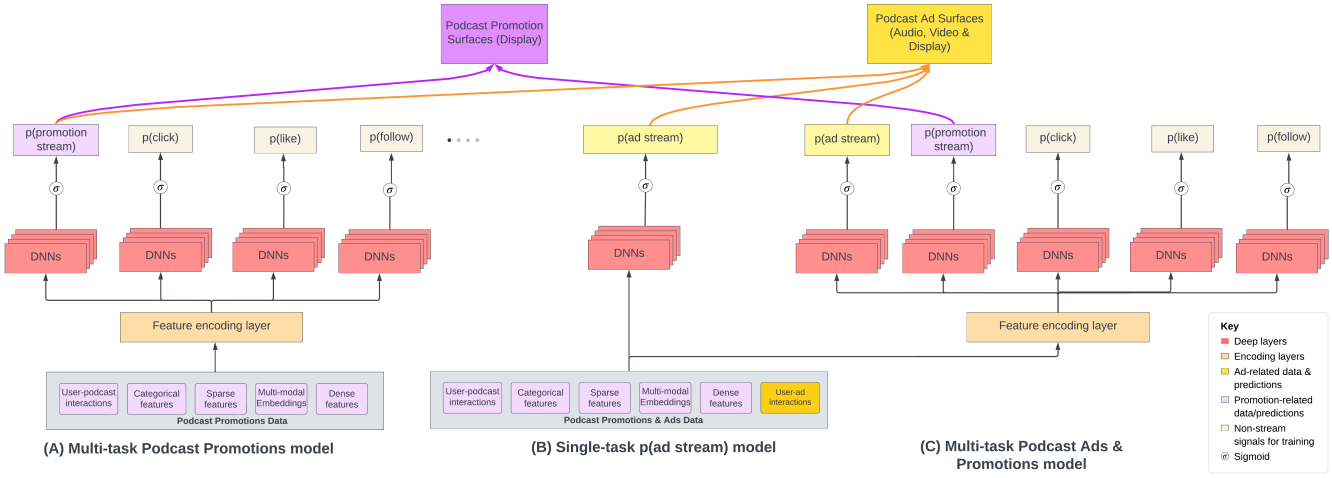

图 2：（A）仅使用促销数据的播客模型，用于在广告目标的冷启动阶段提供广告流预测。（B）整合促销和广告数据的单任务 pAdStream 模型。（C）用于促销和广告的多任务联合模型，同时服务这两项业务。

表 2：所有及播放量较少的播客创作者的 A/B 测试结果（p 值 < 0.05）。播放量较少的播客播放量不足 5,000。相对于基线的变化（图 2A）。

细分群体	i2s	eCPS	CTR	# 播放量
所有播客	+18%	−20%	+10%	+18%
播放量较低的创作者	+24%	−22%	+9%	+27%

降低促销 AP（约为 −65%），这表明若没有促销数据，仅靠辅助头是不够的。

在统一多任务学习设置中，在广告和促销上使用 ANC 头，可提升两个 渠道的 AP。辅助标签与跨渠道训练结合时最有用，能让共享编码器学习到更丰富的用户和内容表征。

4.4 在线 A/B 测试结果

我们在 180+ 个市场开展了预算拆分 A/B 测试，将五任务联合模型与使用促销模型进行广告冷启动的基线进行比较（图2A）。

联合模型同时提升了曝光到播放率、点击率和成本效益。播放量较低的创作者获益最大，eCPS 降低了 22%，播放量增加了 27%，证明该方法对冷启动内容尤其有效。

4.4.1 冷启动表现。 为了更好地了解联合模型在不同受欢迎程度的播客中的表现，我们进一步按 Spotify 的播放量等级细分结果。根据滚动 30 天窗口内累计的收听时长（单次播放超过 60 秒），将播客分为八个等级。就本文而言，等级 0–2 对应高播放量播客，而等级 3–5 则涵盖低播放量节目，与播放量较低的创作者群体相对应。

按等级重新评估 A/B 测试后，我们观察到，播放量较低的播客取得了显著更大的提升。对于高播放量等级，*i2s* 的相对提升从约 +7%（等级 0）增长到 +20%（等级 2），而平均每次播放成本 下降了 4–17%。相比之下，低播放量等级的效果要大得多：*i2s*提升约 +27%（等级 3）、 +33%（等级 4），等级 5 则最高达到 +60%，相应的每次播放成本分别下降约 20%、24% 和 38%。这种单调递增的趋势——从等级 0 到等级 5，相对收益逐渐增大——有力地证明，统一模型在冷启动和低播放量场景中尤其有效；在这些场景下，数据稀疏，传统的孤岛式模型难以发挥作用。

5 结论

本文介绍了 Spotify 成功开发并部署了一个用于播客广告和促销定向的统一多任务模型。我们的联合优化方法通过有效利用迁移学习，显著优于传统的孤岛式模型；在大量广告数据上进行预训练，使模型能够在包括促销在内的多种任务中表现出色，尤其是在冷启动场景下。

这项工作的关键经验表明，将彼此不同却相互关联的推荐任务整合起来力量强大：此举不仅能带来显著的性能提升，还能促进至关重要的组织协同效应，例如打破以往各自为政的局面，改善跨团队协作并加强战略协同。此外，在此类联合模型中利用迁移学习，可以有效缓解新内容和新目标面临的冷启动问题。该模型能够同时提升多种业务目标——涵盖广告流、广告点击和促销播放量——并取得显著增益，这表明其运行状态更接近帕累托最优前沿 [11]。虽然本研究聚焦于播客，但这种方法也可自然拓展至其他垂直领域（如音乐、有声读物和视频），这些领域中的广告和自然推广共享用户和内容表征。

参考文献

[1] Fedor Borisyuk, Mingzhou Zhou, Qingquan Song, Siyu Zhu, Birjodh Tiwana, Ganesh Parameswaran, Siddharth Dangi, Lars Hertel, Qiang Charles Xiao, Xi- aochen Hou, 等。2024。LiRank：LinkedIn工业级大规模排序模型。载于第*30*届*ACM SIGKDD*知识发现与数据挖掘会议论文集。4804–4815。[2] David Carmel, Elad Haramaty, Arnon Lazerson, 和 Liane Lewin-Eytan。2020。使用随机标签聚合优化商品搜索的多目标排序。载于*2020*年万维网大会论文集。ACM，373–383。[3] Rich Caruana。1997。多任务学习。机器学习28（1997），41–75。[4] Zhao Chen, Vijay Badrinarayanan, Chen-Yu Lee, 和 Andrew Rabinovich。2018。GradNorm：深度多任务网络中用于自适应损失平衡的梯度归一化。载于国际机器学习大会。PMLR，794–803。[5] Heng-Tze Cheng, Levent Koc, Jeremiah Harmsen, Tal Shaked, Tushar Chandra, Hrishi Aradhye, Glen Anderson, Greg Corrado, Wei Chai, Mustafa Ispir, Rohan Anil, Zakaria Haque, Lichan Hong, Vihan Jain, Xiaobing Liu, 和 Hemal Shah。2016。面向推荐系统的 Wide & Deep 学习。载于第*1*届推荐系统深度学习研讨会论文集（*DLRS*）。ACM，7–10。[6] Ronan Collobert 和 Jason Weston。2008。自然语言处理的统一架构：结合多任务学习的深度神经网络。载于第*25*届国际机器学习大会论文集。ACM，芬兰赫尔辛基，160 167 10 1145 1390156 1390177 –。doi: . / . Paul Covington, Jay [7] Adams, 和 Emre Sargin。2016。用于 YouTube 推荐的深度神经网络。载于第*10*届*ACM*推荐系统会议论文集。IEEE，美国马萨诸塞州波士顿。doi: 10 1145 2959100 2959190 . / . [8] 2023 Dietmar Jannach 和 Himan Abdollahpouri。. 多目标推荐系统综述。*Frontiers in Big Data* 6（2023），1157899。[9] Olivier Jeunen, Jatin Mandav, Ivan Potapov, Nakul Agarwal, Sourabh Vaid, Wen- zhe Shi, 和 Aleksei Ustimenko。2024。通过多变量策略学习实现多目标推荐。载于第*18*届*ACM*推荐系统会议论文集（意大利巴里）（*RecSys '24*）。计算机协会，美国纽约州纽约市，712 721 10 1145 3640457 3688132 –。doi: . / . Alex Kendall, [10] 2018 Yarin Gal, 和 Roberto Cipolla。. 使用不确定性加权场景几何与语义损失的多任务学习。载于*2018 IEEE/CVF*计算机视觉与模式识别会议（*CVPR*）。IEEE，美国犹他州盐湖城。doi: 10 1109 2018 00781 . /CVPR. . Xi Lin, Hui-Ling Zhen, [11] Zhenhua Li, Qingfu Zhang, 和 Sam Kwong。2019。帕累托多任务学习。载于第*33*届神经信息处理系统国际会议论文集。ACM，加拿大温哥华，12060–12070。doi:10.5555/3454287.3455367[12] Xi Victoria Lin, Akshat Shrivastava, Liang Luo, Srinivasan Iyer, Mike Lewis, Gargi Ghosh, Luke Zettlemoyer, 和 Armen Aghajanyan。2024。MoMa：通过模态感知专家混合实现高效的早期融合预训练。arXiv: 2407 21770 [ ] 2407 21770 . cs.AI [13] https://arxiv.org/abs/ 。Mingsheng Long, Zhangjie Cao, Jianmin Wang, 和 Philip S. Yu。2017。使用多线性关系网络学习多个任务。载于第*31*届神经信息处理系统国际会议论文集。ACM，美国加利福尼亚州长滩，1593 1602 10 5555 3294771 3294923 –。doi: . / . Jiaqi Ma, Zhe [14] Zhao, Xinyang Yi, Jilin Chen, Lichan Hong, 和 Ed Chi。2018。使用多门控专家混合模型建模多任务学习中的任务关系。载于第*24*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集。ACM，英国伦敦，1930–1939。doi:10.1145/3219819.3220007[15] Ning Ma, Mustafa Ispir, Yuan Li, Yongpeng Yang, Zhe Chen, Derek Zhiyuan Cheng, Lan Nie, 和 Kishor Barman。2022。面向 Google信息流广告拍卖模型的在线多任务学习框架。载于第*28*届*ACM SIGKDD*知识发现与数据挖掘会议论文集（美国华盛顿特区）（*KDD '22*）。计算机协会，美国纽约州纽约市，3477–3485。doi:10.1145/3534678.3539055

[16] Xiao Ma、Liqin Zhao、Guan Huang、Zhi Wang、Zelin Hu、Xiaoqiang Zhu 和 Kun Gai。2018。全空间多任务模型：一种有效的点击后转化率估算方法。载于第*41*届国际 *ACM SIGIR* 信息检索研究与发展会议论文集。ACM，1137–1140。[17] Ozan Sener 和 Vladlen Koltun。2018。将多任务学习视为多目标优化。载于第*32*届神经信息处理系统国际会议论文集。ACM，加拿大蒙特利尔，525–536。doi:10.5555/ 3326943.3326992[18] Noam Shazeer、*Azalia Mirhoseini、*Krzysztof Maziarz、Andy Davis、Quoc Le、Geoffrey Hinton 和 Jeff Dean。2017。超大规模神经网络：稀疏门控专家混合层。载于国际学习表征会议。https://openreview.net/forum?id=B1ckMDqlg [19] Trevor Standley、Amir R. Zamir、Dawn Chen、Leonidas Guibas、Jitendra Malik 和 Silvio Savarese。2020。多任务学习中哪些任务应该一起学习？载于第*37*届国际机器学习会议（*ICML '20*）论文集。[20] Chun How Tan、Austin Chan、Malay Haldar、Jie Tang、Xin Liu、Mustafa Abdool、Huiji Gao、Liwei He 和 Sanjeev Katariya。2023。通过多任务学习优化 Airbnb 搜索旅程。载于第*29*届 *ACM SIGKDD* 知识发现与数据挖掘会议论文集（美国加利福尼亚州长滩）*(KDD '23)*。计算机协会，美国纽约州纽约市，4872–4881。doi:10.1145/3580305.3599881[21] Anke Tang、Li Shen、Yong Luo、Nan Yin、Lefei Zhang 和 Dacheng Tao。2024。通过权重集成专家混合合并多任务模型。载于第*41*届国际机器学习大会。[22] Hongyan Tang、Junning Liu、Ming Zhao 和 Xudong Gong。2020。渐进式分层提取（PLE）：一种用于个性化推荐的新型多任务学习（MTL）模型。载于第*14*届 *ACM* 推荐系统会议论文集（线上会议，巴西）*(RecSys '20)*。计算机协会，美国纽约州纽约市，269–278。doi:10.1145/3383313.3412236[23] Jiaxi Tang、Yoel Drori、Daryl Chang、Maheswaran Sathiamoorthy、Justin Gilmer、Li Wei、Xinyang Yi、Lichan Hong 和 Ed H. Chi。2023。提升推荐系统中多任务排序模型的训练稳定性。载于第*29*届 *ACM SIGKDD* 知识发现与数据挖掘会议论文集。ACM，4882–4893。[24] Shivam Verma、Vivian Chen 和 Darren Mei。2025。用于 Spotify 流媒体广告定向的以音频为中心的多任务学习框架。载于第*31*届 *ACM SIGKDD* 知识发现与数据挖掘会议第*2*卷论文集（加拿大安大略省多伦多）*(KDD '25)*。计算机协会，美国纽约州纽约市，4945 4955 10 1145 3711896 3737190 –。[25] doi: . / . Haolun Wu、Chen Ma、Bhaskar Mitra、Fernando Diaz 和 Xue Liu。2022。面向多利益相关方公平性感知推荐的多目标优化框架。*ACM* 信息系统汇刊 41，2，文章47（2022年12月），29页。doi:10.1145/3564285[26] Xinyang Yi、Ji Yang、Lichan Hong、Derek Zhiyuan Cheng、Lukasz Heldt、Aditee Kumthekar、Zhe Zhao、Li Wei 和 Ed H. Chi。2019。用于大规模语料项目推荐的采样偏差校正神经建模。载于第*13*届 *ACM* 推荐系统会议论文集。ACM，269–277。[27] Tianhe Yu、Saurabh Kumar、Abhishek Gupta、Sergey Levine、Karol Hausman 和 Chelsea Finn。2020。多任务学习的梯度手术。神经信息处理系统进展33（2020），5824–5836。[28] Zhe Zhao、Lichan Hong、Li Wei、Jilin Chen、Aniruddh Nath、Shawn Andrews、Aditee Kumthekar、Maheswaran Sathiamoorthy、Xinyang Yi 和 Ed Chi。2019。推荐下一个观看的视频：一种多任务排序系统。载于第*13*届 *ACM* 推荐系统会议论文集。ACM，丹麦哥本哈根，43 51 10 1145 3298689 3346997 –。doi: . / . Yong Zheng 和 David Xuejun Wang。。《多目标优化推荐系统综述》。神经计算474（2022），141–153。[29] 2022