arXiv:2303.00276v1 [cs.IR] 1 Mar 2023

全空间学习框架：推荐系统全阶段无偏转化率预测

Shanshan Lyu、Qiwei Chen、Tao Zhuang、Junfeng Ge 阿里巴巴集团，中国
{lss271346,chenqiwei.cqw,zhuangtao.zt,beili.gjf}@alibaba-inc.com

摘要

推荐系统是在线服务的重要组成部分，尤其是对电子商务平台而言。推荐系统中的转化率（CVR）预测在优化电子商务的商品交易总额（GMV）目标方面发挥着重要作用。然而，转化率面临着众所周知的样本选择偏差（SSB）和数据稀疏性（DS）问题。尽管现有方法 ESMM 和 ESM^2 通过对用户行为路径建模，在全空间上利用所有曝光样本进行训练，但样本选择偏差和数据稀疏问题依然存在。在实际应用中，在线推理空间中的样本来自推荐系统流程的前一阶段，而非现有方法所建模的曝光空间。此外，现有方法主要通过构建特定场景下的行为路径来解决数据稀疏问题，忽略了电子商务平台各类场景中的行为。本文提出全空间学习框架：推荐系统全阶段无偏转化率预测，通过以一种新颖的方式重新定义商品交易总额目标，解决样本选择偏差和数据稀疏问题。具体而言，我们利用推荐系统流程前一阶段的样本，在整个数据空间上重新构建转化率模型，从而统一训练空间与在线推理空间。此外，我们在模型学习过程中显式引入来自电子商务平台其他场景的购买样本。在线 A/B 测试和离线实验表明，我们的框架具有优越性。该框架已部署于淘宝推荐的排序阶段，每天为数亿消费者提供推荐服务。

CCS 概念

• **信息系统** →**推荐系统**。

关键词

推荐系统，转化率预测

1 引言

如今，互联网已成为人们日常生活的重要组成部分，提供各种各样的服务。随着信息日益过载，推荐系统（RS）应运而生，为用户提供个性化、及时且准确的服务。在电子商务平台中，推荐分为多个阶段，例如匹配、排序等，如图 1 所示。推荐系统首先根据用户的历史反馈，召回大量用户可能感兴趣的商品。随后，根据点击率（CTR）、转化率（CVR）等指标对商品进行排序。最后，向用户展示排名靠前的商品，用户再向推荐系统反馈，例如点击、购买。

本文聚焦于转化率预测任务，这是推荐系统中的一项关键指标。例如，在电子商务平台上，实现商品交易总额最大化是最重要的目标之一，

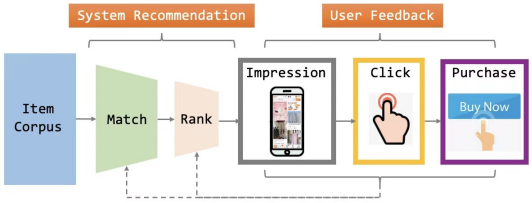

图 1：推荐流程。

其中转化率是一个重要因素。此外，准确估算转化率有助于平衡点击与购买偏好，从而提供更好的用户体验。

然而，转化率建模面临着诸多挑战，尤其是在我们的实际应用中遇到的两个关键问题。1）样本选择偏差问题（SSB）[15] 是指训练数据分布与推理数据分布之间存在系统性差异，这会损害模型性能。如图 2(a) 所示，排序的推理空间包含来自整个空间的样本，而传统转化率模型的训练空间则仅包含点击样本，这会降低模型的线上性能。2）数据稀疏性（DS）[1] 问题是指训练样本数量不足以拟合模型庞大的参数空间。尤其对于转化率任务，训练样本只占很小一部分，无法准确捕捉用户购买偏好。

针对上述挑战，人们提出了许多方法 [5, 7, 12, 16]。例如，全空间多任务模型（ESMM）通过多任务学习框架对浏览后点击率和浏览后点击转化率（CTCVR）进行建模，并将所有曝光样本作为全空间来训练转化率，从而缓解了样本选择偏差和数据稀疏问题。ESM^2 [12] 利用点击与购买之间的更多行为来应对数据稀疏问题。然而，这些方法仍然受到样本选择偏差和数据稀疏问题的困扰。一方面，这些方法通过使用所有曝光样本进行训练来解决样本选择偏差问题，但在实际线上实践中，排序的推理空间是从前一匹配阶段召回的样本，如图 1 所示。训练空间与推理空间之间仍然存在差异，这会损害模型性能。另一方面，这些方法通过构建从点击到购买的多种行为路径（例如加入购物车或收藏）来缓解数据稀疏问题，但忽略了电子商务平台不同场景中的行为。如图 2(b) 所示，在中国最大的电子商务平台之一淘宝[1]上，点击和购买行为发生在多种场景中，例如搜索、推荐、购物车等。用户在电子商务平台所有场景中的反馈都有助于更准确地捕捉用户偏好。因此，如何利用用户在电子商务平台所有场景中的行为是一个非常重要的问题。

[1]https://www.taobao.com/



(a) 样本选择偏差问题。 (b) 淘宝中的各种场景。

图 2：样本选择偏差问题及淘宝中各种场景的示意图。

本文提出了全空间学习框架（ESLM）：为解决样本选择偏差和数据稀疏问题，我们提出了推荐系统全阶段无偏转化率预测方法。我们从推荐系统整体视角重新定义商品交易总额目标，并据此提出一种在全空间上刻画转化率预测的新方法。具体而言，我们通过建模从推荐系统前一阶段到自有场景中购买行为的全数据空间概率来训练转化率预测模型，从而消除训练空间与推理空间之间的差异。此外，我们还明确建模用户在自有场景及淘宝其他场景中的购买反馈，以缓解数据稀疏问题。具体来说，我们将转化率分解为两部分：1）从整个数据空间到所有场景中购买行为的概率；2）从所有场景中的购买样本到自有场景购买样本的概率。离线实验和在线A/B 测试表明，与现有方法相比，我们的框架具有优越性。该框架已部署于淘宝推荐的排序阶段，每天为数亿消费者提供推荐服务。

2 框架

2.1 问题表述

电子商务推荐系统由多个阶段组成，主要包括匹配和排序。在匹配阶段，系统根据用户特征，从海量候选项中快速检索出少量商品。随后，将匹配阶段检索出的商品作为排序阶段的输入。电子商务平台最重要的优化目标之一是商品交易总额（GMV），它可以分解为

$$GMV = Traffic * CTR * CVR * price. \quad (1)$$

传统转化率模型对样本的概率进行建模

$$p_{ClickToPay} = p\ Pay = ()。$$

$1|Click = 1$
ESMM 提出在整个空间中使用所有曝光样本，通过将点击后转化率建模为 $p_{PvToPay} = p(Click = 1|Pv = 1) * p(Pay = 1|Click = 1, Pv = 1)$ 来训练转化率模型。然而，这种建模方式存在两个问题。1）样本选择偏差。训练和推理的数据空间不同：训练空间中的样本是曝光样本或点击样本，而推理空间中的样本来自推荐系统的前一阶段。2）数据稀疏问题。传统模型只使用本场景中的样本进行训练，忽略了淘宝所有场景中的丰富行为，这会导致数据稀疏问题。因此，如何保持训练空间和推理空间的一致性，以及如何在推荐系统的所有阶段利用淘宝所有场景中的样本，是非常重要的问题。

因此，我们提出一种全空间学习框架，通过重构概率空间来补充现有的商品交易总额函数，从而缓解上述问题。

首先，我们重构概率空间。为了使训练空间与在线推理空间保持一致，我们充分利用推荐系统的结构，直接构建从前一阶段的样本到我们场景中的购买样本的概率，定义如下：

$$p_{PSToPay_g} = p(Pay_g = 1|PS = 1). \quad (2)$$

其中，$\{Pay_g = 1\}$ 是我们自身场景中的购买样本，$\{PS = 1\}$ 是来自推荐系统前一阶段的样本（如图 1 所示）。此外，为了缓解数据稀疏问题，我们在推荐系统的每个阶段（即匹配和排序）都使用淘宝所有场景中的购买样本。进一步地，我们将该概率分解为以下形式。

$$\begin{aligned} p_{PSToPay_g} &= p(Pay_g = 1|PS = 1) \\ &= p(Pay_a = 1|PS = 1) * p(Pay_g = 1|Pay_a = 1, PS = 1). \end{aligned} \quad (3)$$

其中，$\{Pay_a = 1\}$ 是来自前一阶段的样本与淘宝所有场景中的购买样本的联合集合，概率$p(Pay_g = 1|Pay_a = 1,\ PS = 1)$ 表示所有场景中的购买样本转化为我们自身场景中的购买样本的概率。

这种转化率建模方式有三个优点。1）训练和推理的候选数据空间一致。离线训练和在线推理的数据空间都是推荐系统前一阶段返回的样本。因此，在线预测与离线训练之间不存在不一致，从而缓解了样本选择偏差问题。2）我们在模型学习过程中明确引入了淘宝所有场景中的购买样本，从而缓解数据稀疏问题。然而，仅将其他场景的购买样本引入模型，可能会使更多不适合我们场景的商品曝光。3）我们对所有场景中的购买样本转化为我们自身场景样本的概率进行建模，因此，最终的建模目标是我们自身场景的正样本。这种建模方式更符合我们自身场景的需求，可以减少不适合该场景的样本曝光。

最后，它作为对传统优化目标GMV的补充，其形式化定义如下：

$$GMV = Traffic * (p_{PvToPay} + \alpha * p_{PSToPay}) * price. \quad (4)$$

2.2 模型

本节将详细介绍我们的模型网络（图3）。模型由两部分组成。第一部分 $p(Pay_a = 1|PS = 1)$ 对前一阶段的样本在所有场景中转化为购买样本的概率进行建模。第二部分 $p(Pay_g = 1|Pay_a = 1,\ PS =1)$ 对所有场景中的购买样本在我们的场景中转化为购买样本的概率进行建模。

嵌入层 将大量稀疏特征映射到低维稠密向量空间。输入特征包括用户画像特征、用户行为序列、物品属性特征和上下文特征。

多头目标注意力层捕捉目标物品与用户历史行为序列之间的相似度。标准目标注意力基于多头注意力结构 [9]，已广泛应用于点击率模型中的用户序列数据建模 [6, 13, 17]。与自然语言处理模型不同，点击率模型将目标物品作为查询，将用户行为序列作为

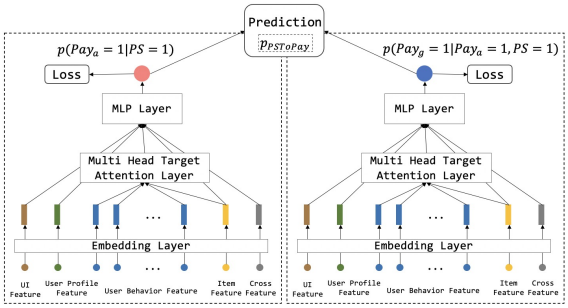

图3：我们的模型网络结构。

键和值。单头注意力的公式以及用户序列的表示形式如下：

p q

$$Attention_i(Q,K,V) = softmax(\frac{QK^T}{\sqrt{d_k}}),$$
$$S = Concat(Attention_1, Attention_2, \ldots, Attention_h)W^S, \tag{5}$$

其中，$Q = E_s W_i^Q, K = E_s W_i^K, V = E_s W_i^V$表示商品的嵌入矩阵，$Es$；$W_i^Q, W_i^K, W_i^V$表示$i-th$注意力头的线性投影矩阵；$Concat(\cdot)$表示拼接操作，$W^S$表示线性投影矩阵，$h$表示注意力头的数量。

多层感知机层和损失函数。通过拼接所有特征的表示，我们使用三个全连接层进一步学习稠密特征之间的交互，这种做法在工业级推荐系统中广泛应用。

为了预测用户是否会在淘宝的所有场景中购买目标物品，我们将其建模为一个二分类问题，并采用 $Sigmoid$ 函数作为输出单元。最终，交叉熵损失函数定义为

$$Loss_{PSToPay_a} = -\frac{1}{N}\sum_{(x,y)\in D}^{N}(ylogp(x)) + (1-y)log(1-p(x))), \tag{6}$$

其中，$p(x) = p(Pay_a = 1|PS = 1, x)$ 表示用户在淘宝所有场景中购买样本 x 的预测概率，D 是推荐系统前一阶段所有样本的数据集，而$y \in 0$，1 是用于表示用户是否在淘宝所有场景中购买目标物品的标签。

同样地，为了对用户是否会在当前场景或其他场景中购买目标物品进行建模，损失函数定义为：

$$Loss_{Pay_aToPay_g} = -\frac{1}{N}\sum_{(x,y)\in D_p}^{N}(ylogp(x)) + (1-y)log(1-p(x))), \tag{7}$$

其中，$p(x) = p(Pay_a = 1|PS = 1, x)$表示样本在我们的场景或其他场景中被购买的预测概率，D_p 是由推荐系统前一阶段的样本与所有场景中的购买样本组成的联合数据集，而 $y \in 0$，1是一个标签，用于指示目标物品是否在我们的场景中被购买。

表 1：数据集统计信息。

数据集	用户	商品	样本
淘宝	463,734,383	136,025,054	90,849,473,690

3 实验

3.1 实验设置

数据集。 数据集根据淘宝 App[2]的日志构建。我们基于用户十五天内的行为构建离线数据集。前十四天作为训练数据，最后一天作为测试数据。数据集的统计信息如表 1所示，其规模极大且十分稀疏。传统训练数据集来自曝光日志，相关统计信息如表 1所示，但这无法满足我们的新范式。因此，我们构建了一个新数据集。首先，我们记录推荐系统前一阶段排序 $\{PS = 1\}$ 中的所有样本，并记录淘宝所有场景中的购买样本 $\{Pay = 1\}$。然后，我们合并 $\{PS = 1\}$ 和 $\{Pay = 1\}$，以利用购买样本 $\{Pay_a = 1\}$。我们对负样本进行负采样。数据集 $\{Pay_a = 1\}$ 可分为我们场景中的正样本 $\{Pay_g = 1\}$ 和其他场景中的正样本。$\{Pay_a = 1\}$ 为我们的模型带来了数倍的正样本，有效缓解了数据稀疏问题。

评估指标。对于在线 A/B 测试，我们使用转化率评估所有模型。对于离线评估，我们使用曲线下面积（AUC）指标。我们在两个数据集上使用几种不同的标签评估 AUC。对于 $\{Pv = 1\}$ 曝光数据集，如果商品在我们的场景中被购买，则评估 AUC(PvToPay$_g$)；对于 $\{PS = 1\}$ 数据集，如果商品在我们的场景中被购买，则评估 AUC(PSToPay$_g$)；对于 $\{PS = 1\}$ 数据集，如果商品在淘宝的所有场景中被购买，则评估 AUC(PSToPay$_a$)。传统的曲线下面积（AUC）离线评估较为困难，因为我们的框架会改变曝光商品。因此，我们需要结合在线和离线评估结果进行分析。

基线方法。为了评估我们模型的有效性，我们将其与 ESMM[5], ESM^2[12], 以及我们的基线方法进行比较。基线方法在我们自己的场景数据上分别训练转化率模型和点击率模型。为了验证统一训练与推理数据空间，以及明确利用其他场景中的购买样本的有效性，我们提出了以下模型变体。1）Pv2Pay$_g$在曝光数据集上训练，用于建模概率 $p(Pay_g = 1|Pv = 1)$。2）PS2Pay$_g$ 在前一阶段的样本上训练，用于建模概率 $p(Pay_g = 1|PS = 1)$。与我们的框架相比，该方法没有引入其他场景的样本。

设置。我们的模型使用 Python 2.7 和 Tensorflow 1.4 实现，并选择“Adagrad”作为优化器，学习率设为 0.01。超参数 alpha 根据离线曲线下面积和在线 A/B 测试通过网格搜索进行微调，最终取值为 0.1。

3.2 实验结果

本节分析实验结果，旨在回答三个问题。研究问题1：我们的框架在转化率预测方面是否优于现有方法？研究问题2：基于 $\{PS = 1\}$ 数据集建模，我们的方法是否能够缓解样本选择偏差？研究问题3：通过显式引入淘宝其他场景中的用户行为，是否能够有效缓解数据稀疏问题？

[2]https://www.taobao.com/

表2：最先进方法在$\{Pv = 1\}$曝光数据集上的在线CVR增益和离线AUC(PvToPay$_g$)。

方法	AUC(PvToPay$_g$)	转化率增益
基线	0.8623	-
ESMM	0.8634	+1.3%
ESM^2	0.8643	+2.2%
Our	0.8548	+7.3%

为回答研究问题1，我们将我们的模型与 ESMM、ESM^{2}进行了比较。从在线结果（表2）可以观察到，我们的模型优于现有最先进的方法，证明了我们的框架在解决样本选择偏差和数据稀疏问题方面的优越性。从表2可以看出，我们的模型在现有曝光数据集上的曲线下面积略低，但在线转化率提升显著更高。这是因为我们的模型改变了在线数据分布，与现有数据集空间并不一致。

为回答研究问题2，我们比较了模型 PvToPay$_g$ 和 PSToPay$_g$ 的不同变体。从表 3 可以看出，PSToPay$_g$ 的曲线下面积更高，在线结果也优于 PvToPay$_g$，这证明了其在缓解样本选择偏差问题方面的有效性。

为回答研究问题3，我们比较了是否在框架中引入其他场景的样本。从表 2 和表 3 可以看出，我们框架的实验结果显著优于未引入全局样本的模型。这表明，通过我们的框架引入全局领域知识能够缓解数据稀疏问题，并提升模型的泛化性能，从而改善排序效果。

4 相关工作

转化率预测。目前很少有文献直接针对 CVR 任务提出方法 [2, 5, 11, 12, 14]。ESMM [5] 和 ESM^2 [12] 旨在解决 CVR 任务中的 SSB 和 DS 问题。ESMM 将点击率预测任务和点击后转化率预测任务作为辅助任务，引入到主要的 CVR 任务中。ESM^2 提出了点击后行为分解，并将最终的 CVR 与一些辅助任务结合起来进行建模。因此，这两种方法通过构建用户行为路径，同时解决了 SSB 和 DS 问题。然而，这些方法仍然存在 SSB 和 DS 问题。在真实的推荐系统中，在线推理空间中的样本来自推荐系统的前一阶段，而不是这两种方法所使用的曝光空间。对于 DS 问题，这两种方法仅对各自场景中的行为进行建模，而忽略了其他场景中的行为。我们的框架通过重新构建特定场景下的购买概率，缓解了 SSB 和 DS 问题。我们的模型基于推荐系统前一阶段的样本构建概率，统一了训练空间和推理空间。对于 DS 问题，我们通过分解概率，利用淘宝所有场景中的购买样本。这样一来，我们的模型便能利用整个空间中的所有样本以及淘宝所有场景中的购买标签，从而同时解决 SSB 和 DS 问题。

多任务学习。虽然多任务学习框架（MMOE [3], PLE [8]）可以在多任务学习中建模不同场景下的同一任务，例如场景 A 中的双塔转化率和场景 B中的转化率，但最终输出仍然是场景 A中的转化率，

表3：变体模型的$\{PS = 1\}$数据集上的在线CVR增益和离线AUC（PSToPay$_g$）、AUC（PSToPay$_a$）。

方法	AUC（PSToPay$_g$）	AUC（PSToPay$_a$）	CVR增益
基线	0.8623	0.9325	-
Pv2Pay$_g$	0.8574	0.9286	-
PS2Pay$_g$	0.8233	0.9514	+0.8%
Our	0.8548	0.9562	+7.3%

它以隐式方式利用标签样本，并影响主任务的嵌入和神经网络权重。我们以显式方式利用标签样本，这更适合在线部署。

5 结论

本文提出了一种在淘宝中对商品交易总额进行建模的新框架。该模型统一了训练空间和推理空间，并在淘宝的所有场景中引入标签样本，从而缓解了样本选择偏差和数据稀疏问题。线上和线下实验结果表明，与现有方法相比，我们的框架具有优越性。该框架已部署于淘宝首页推荐的排序阶段，为中国数亿用户提供服务。未来，该框架还可扩展到点击率等其他任务。

参考文献

[1] Kuang Chih Lee、B. B. Orten、A. Dasdan 和 W. Li。2012年。利用过往表现数据估算展示广告的转化率。第*18*届 *ACM SIGKDD* 会议论文集，768–776。[2] Quan Lu、Shengjun Pan、Liang Wang、Junwei Pan、Fengdan Wan 和 Hongxia Yang。2017年。在线展示广告转化率预测的实用框架。载于*ADKDD'17* 论文集。1–9。[3] Jiaqi Ma、Zhe Zhao、Xinyang Yi、Jilin Chen、Lichan Hong 和 Ed H Chi。2018年。使用多门混合专家模型建模多任务学习中的任务关系。载于*SIGKDD*。1930–1939。[4] Xiao Ma、Liqin Zhao、Guan Huang、Zhi Wang、Zelin Hu、Xiaoqiang Zhu 和 Kun Gai。2018年。全空间多任务模型：一种估算点击后转化率的有效方法。载于第*41*届国际 *ACM SIGIR* 会议。[5] Xiao Ma、Liqin Zhao、Guan Huang、Zhi Wang、Zelin Hu、Xiaoqiang Zhu 和 Kun Gai。2018年。全空间多任务模型：一种估算点击后转化率的有效方法。载于第*41*届国际 *ACM SIGIR* 会议。[6] Pi Qi、Xiaoqiang Zhu、Guorui Zhou、Yujing Zhang 和 Kun Gai。2020年。利用终身序列行为数据进行基于搜索的用户兴趣建模，以预测点击率。载于*arXiv* 预印本 *arXiv:2006.05639 (2020)*。[7] P. Rong、Y. Zhou、B. Cao、N. N. Liu 和 Y. Qiang。2008年。单类协同过滤。载于第八届 *IEEE* 国际数据挖掘会议。[8] Hongyan Tang、Junning Liu、Ming Zhao 和 Xudong Gong。2020年。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。[9] Ashish Vaswani、Noam Shazeer、Niki Parmar、Jakob Uszkoreit、Llion Jones、Aidan N Gomez、Lukasz Kaiser 和 Illia Polosukhin。2017年。注意力就是一切。载于神经信息处理系统进展。5998–6008。[10] H. Wen、J. Zhang、Q. Lin、K. Yang 和 P. Huang。2019年。用于推荐系统转化率预测的多层深度级联树。*AAAI*人工智能会议论文集 33 (2019)，338–345。[11] H. Wen、J. Zhang、Q. Lin、K. Yang 和 P. Huang。2019年。用于推荐系统转化率预测的多层深度级联树。*AAAI*人工智能会议论文集 33 (2019)，338–345。[12] Hong Wen、Jing Zhang、Yuan Wang、Fuyu Lv 和 Keping Yang。2020年。通过点击后行为分解进行全空间多任务建模，以预测转化率。载于第*43*届国际 *ACM SIGIR* 会议。[13] Jun Xiao、Hao Ye、Xiangnan He、Hanwang Zhang、Fei Wu 和 Tat Seng Chua。2017年。注意力因子分解机：通过注意力网络学习特征交互的权重。载于*arXiv* 预印本 *arXiv:1708.04617 (2017)*。[14] H. Yang、Q. Lu、A Xianen Qiu 和 C. Han。2016年。通过全局和局部特征的动态迁移学习进行大规模转化率预测。载于大数据、流与异构源挖掘研讨会：算法、系统、编程模型与应用 (2016)，103–119。

[15] Bianca Zadrozny。2004年。在样本选择偏差下学习并评估分类器。载于国际机器学习大会。[16] Weinan Zhang、Tianxiong Zhou、Jun Wang 和 Jian Xu。2016年。用于展示广告中删失数据无偏学习的竞价感知梯度下降。载于*SIGKDD*。[17] G. Zhou、W. Bian、K. Wu、L. Ren、Q. Pi、Y. Zhang、C. Xiao、X. R. Sheng、N. Mou 和 X. Luo。2020年。CAN：重新审视点击率预测中的特征协同行为

预测。（2020年）。[18] G. Zhou、N. Mou、Y. Fan、Q. Pi 和 K. Gai。2019年。用于点击率预测的深度兴趣演化网络。人工智能 *AAAI* 会议论文集 33（2019年），5941–5948。[19] G. Zhou、C. Song、X. Zhu、Y. Fan、H. Zhu、X. Ma、Y. Yan、J. Jin、H. Li 和 K. Gai。2018年。用于点击率预测的深度兴趣网络。*SIGKDD*（2018年），1059–1068。