用于商品搜索点击率预测的长短期用户兴趣分层融合

Qijie Shen 阿里巴巴集团 杭州，中国
qjshenxdu@gmail.com

Hong Wen 阿里巴巴集团 杭州，中国
qinggan.wh@alibaba-inc.com

Jing Zhang 悉尼大学 达灵顿，新南威尔士州 2008，澳大利亚
jing.zhang1@sydney.edu.au

Qi Rao 阿里巴巴集团 杭州，中国
rq145781@alibaba-inc.com

arXiv:2304.02089v1 [cs.IR] 4 Apr 2023

宽泛型
在个性化商品搜索中，点击率（CTR）估计是一项至关重要却颇具挑战的任务。然而，在商品搜索场景下，现有的点击率方法仍面临以下三项挑战：如何从多个方面更有效地提取用户的短期兴趣；如何提取用户的长期兴趣并将其与短期兴趣融合；以及如何解决长期兴趣与短期兴趣相互纠缠的问题。为应对这些挑战，本文提出一种名为分层兴趣融合网络（HIFN）的新方法，由四个基本模块构成：短期兴趣提取器（SIE）、长期兴趣提取器（LIE）、兴趣融合模块（IFM）和兴趣解耦模块（IDM）。具体而言，SIE通过整合三种基础兴趣编码器来提取用户的短期兴趣，分别是查询相关、目标相关和因果依赖兴趣编码器；随后，它将所得表示传递给LIE模块。LIE通过针对SIE模块提取的短期兴趣设计注意力机制，有效捕捉用户的长期兴趣。在IFM中，提取出的长期兴趣和短期兴趣以自适应方式进一步融合，再与原始上下文特征拼接，以得出最终预测结果。最后，针对长期兴趣与短期兴趣相互纠缠的特点，IDM进一步设计了一个自监督框架，以解耦长期兴趣和短期兴趣。在真实电子商务平台上进行的大规模离线和在线评估表明，HIFN优于当前最先进的方法。

CCS 概念
• **信息系统 → 信息检索**。

特此授予许可，可无偿制作本作品的全部或部分数字或纸质副本，供个人或课堂使用，但前提是不得为牟利或商业利益而制作或分发副本，且副本首页须附有本声明及完整引文。对于本作品中由非 ACM 所有人拥有的组件，必须尊重其版权。经注明出处后，允许编写摘要。若要以其他方式复制、重新发布、发布到服务器或重新分发至列表，则必须事先获得明确许可和/或支付费用。请通过 permissions@acm.org 向我们申请许可。*CIKM '22，2022*年*10*月*17*日至*21*日，美国佐治亚州亚特兰大© 2022 计算机协会。ACM ISBN 978-1-4503-9236-5/22/10...$15.00 https://doi.org/10.1145/3511808.3557351

关键词
个性化商品搜索，点击率预测

ACM 参考文献格式：
Qijie Shen、Hong Wen、Jing Zhang、Qi Rao。2022年。分层融合长期与短期用户兴趣，用于商品搜索中的点击率预测。载于第*31*届*ACM* 国际信息与知识管理会议论文集（*CIKM '22*），*2022* 年 *10* 月*17*日至*21*日，美国佐治亚州亚特兰大。ACM，美国纽约州纽约市，10页。https://doi.org/10.1145/3511808.3557351

1 引言

随着电子商务平台上商品的爆发式增长，商品搜索在发现满足用户需求的理想商品方面发挥着不可或缺的作用。当用户提交查询时，商品搜索会通过典型的多阶段流程“匹配→预排序→排序→重排序” [14, 15, 30]，从数十亿候选商品中筛选出一小组排序靠前的商品并呈现给终端用户。本文仅关注排序阶段的点击率（CTR）预测任务，该任务旨在预测用户点击商品的概率，对改善用户体验和提升电子商务平台的营收有着重要影响。

个性化商品搜索中的点击率预测任务，前提是准确提取用户的历史行为所反映的用户偏好，并将其与当前查询有效结合 [10]。此外，人们普遍认为，用户偏好 [4], *i.e.*分为长期和短期两类。前者体现了用户内在且相对稳定（缓慢变化）的偏好，例如对颜色、合身尺寸和价格的偏好；这些偏好会受到用户的家庭背景、年龄、婚姻状况、教育程度等因素的潜移默化影响 *etc*。而短期兴趣则反映用户在相对较短时期内的偏好意图，可以根据其近期行为推断，也会受到偶发的短暂事件影响，例如新品发布、季节变化，以及生日等个人特殊时刻 [26]。总之，与长期兴趣相比，用户的短期兴趣变化频率更高、幅度更大。

现有个性化商品搜索的一种典型范式是显式地用嵌入向量表示用户意图和商品，然后在潜在空间中通过点积进行匹配，或将其输入神经网络层以得到预测分数 [5]。例如，HEM [2]通过凸组合融合用户向量和查询向量来表示用户意图。AEM [1] 是

首个基于注意力的嵌入模型，它通过针对查询对用户的历史购买商品应用注意力机制，构建依赖于查询的用户嵌入。ZAM [1] 设计了一种零注意力机制，用于确定在不同场景下何时以及如何进行个性化。TEM [5]通过使用 Transformer 架构对查询序列和用户历史行为进行编码，动态控制个性化的影响。Guo [10] 提出了一种新颖的注意力长短期偏好模型（简称 ALSTP），用于在典型的个性化商品搜索场景中学习并融合与当前查询相关的用户长期和短期偏好。尽管现有商品搜索范式效果显著，我们认为它仍存在若干明显局限。

首先，现有方法总是根据用户提交的查询，聚合用户历史行为来提取用户兴趣表示。我们认为，只有当用户通过提交的查询明确表达需求时，这种策略才能有效发挥作用。例如，当用户提交查询“红色帆布鞋”时，该查询能够清楚地表达用户对颜色、类型和材质的要求，因此，直接针对用户与所提交查询相关的行为采用注意力机制，便能有效提取查询依赖兴趣。然而，用户有时也会以模糊的意图表达需求。例如，当用户发出查询“礼物”时，用户并未明确说明此刻想要的品牌、类别、风格、价格， *etc*. 因此，前一阶段的匹配会返回各种类型的候选商品。因此，我们需要针对每个目标商品，从历史行为中提取用户当前真正关注的兴趣。换言之，在这种情况下，另一种方案是针对目标产品而非查询采用注意力机制，以提取目标相关的用户兴趣。

其次，历史行为存在多种类型，例如点击、收藏或购买，这些行为往往被以往的研究无意中忽略，或仅被视为整合到原有框架中的某类行为特征。我们认为，多种类型的行为包含丰富的信息，值得深入研究，以获得更优的用户兴趣表示。然而，将它们整合到原有框架中并非易事。例如，部分用户的购买行为表明，其近期的期望需求最终已得到满足，这意味着购买行为对用户兴趣最终表示的贡献权重应当较小。相反，一些用户可能在特定类别上发生某次点击行为后继续点击或收藏，这表明用户兴趣的强度在持续增加，因此在最终的用户兴趣表示中，应当赋予这类行为更高的权重。本文将这一现象 *i.e.*——多种用户行为的因果关系——称为因果关系相关的用户兴趣。

第三，尽管当前最先进的长期与短期兴趣方法 *i.e.*（ALSTP）已取得显著效果，但它仍难以进一步提升性能，因为它只考虑查询依赖的用户兴趣，而忽略了目标依赖兴趣和因果依赖兴趣。因此，在某些情况下，它会导致较差的性能。此外，ALSTP 只是将长期兴趣与短期兴趣拼接起来，并在最终预测时将二者混合在一起，却没有明确区分二者对最终预测的重要性，这会导致准确性和可解释性较差。

为应对上述挑战，我们提出了一种用于商品搜索点击率预测的新方法——分层兴趣融合网络（HIFN）。该网络由四个基本模块组成：短期兴趣提取器（SIE）、长期兴趣提取器（LIE）、兴趣融合模块（IFM）和兴趣解耦模块（IDM）。具体而言，SIE 通过采用三个兴趣编码器来提取用户的短期兴趣： *i.e.*、查询依赖兴趣编码器（QDIE）、目标相关兴趣编码器（TDIE）和因果依赖兴趣编码器（CDIE），分别用于提取查询依赖、目标相关和因果依赖兴趣，随后以自适应方式融合这三种兴趣。在 LIE 中，我们设计了一种注意力机制，根据 SIE 模块的输出表示捕获用户的长期兴趣，随后在 IFM 模块中融合长期兴趣与短期兴趣。接着，将所有表示特征与原始上下文特征拼接，并输入全连接层以生成最终预测结果。最后，受 DLSR 启发， [32], IDM 为长期和短期兴趣注入伪标签，并采用自监督框架对长期和短期兴趣进行解耦。不过，与 DLSR 不同的是，我们设计了一种更新策略来设置长期兴趣代理，这种设置更为合适，且性能优于 DLSR 中的设置。本文的贡献主要有三点：

- 我们提出了一种名为 HIFN 的新方法，用于商品搜索中的点击率预测，以分层方式促进长短期用户兴趣表示的学习。
- 我们设计了包括 SIE、LIE、IFM 和 IDM 在内的四个关键模块，以共同应对商品搜索场景中的上述挑战，并且这些模块可以在多任务端到端学习框架中高效实现。
- 我们在真实世界的离线数据集上进行了广泛实验，并开展了在线 A/B 测试。两项结果均表明，HIFN 的效果优于当前最先进的方法。

2 提出的方法

本文提出了一种名为 HIFN 的新方法，如图 1 所示。该方法由四个基本模块组成，分别是短期兴趣提取器（SIE）、长期兴趣提取器（LIE）、兴趣融合模块（IFM）和兴趣解耦模块（IDM）。下面将对它们进行详细介绍。

2.1 问题定义

给定用户画像 u_p、长期用户行为 u_{b_l}、短期用户行为 u_{b_s}、目标商品 i、搜索查询 q和上下文特征 c，其中 $u_{b_l} = \{i_1, i_2, ...i_{T_l}\}$、$u_{b_s} = \{i_1, i_2, ...i_{T_s}\}$ 和 i_t分别表示集合 u_{b_l}（分别为 u_{b_s}）中用户长期（分别为短期）行为里的第 t 个交互物品。此外， T_l（分别为 T_s）表示用户长期（分别为短期）行为的长度。接下来，我们首先将它们编码为独热高维向量，再通过与相应的嵌入矩阵 [24, 25, 28]相乘，将这些向量转换为低维稠密向量。拼接各种类型的稠密向量后，我们得到分别对应于 u_p、 u_{b_l}、u_{b_s}、 i、 q、 c的嵌入向量 e_{u_p}、 $x_{u_{b_l}}$、 $x_{u_{b_s}}$、 e_i、 e_q、 e_c，

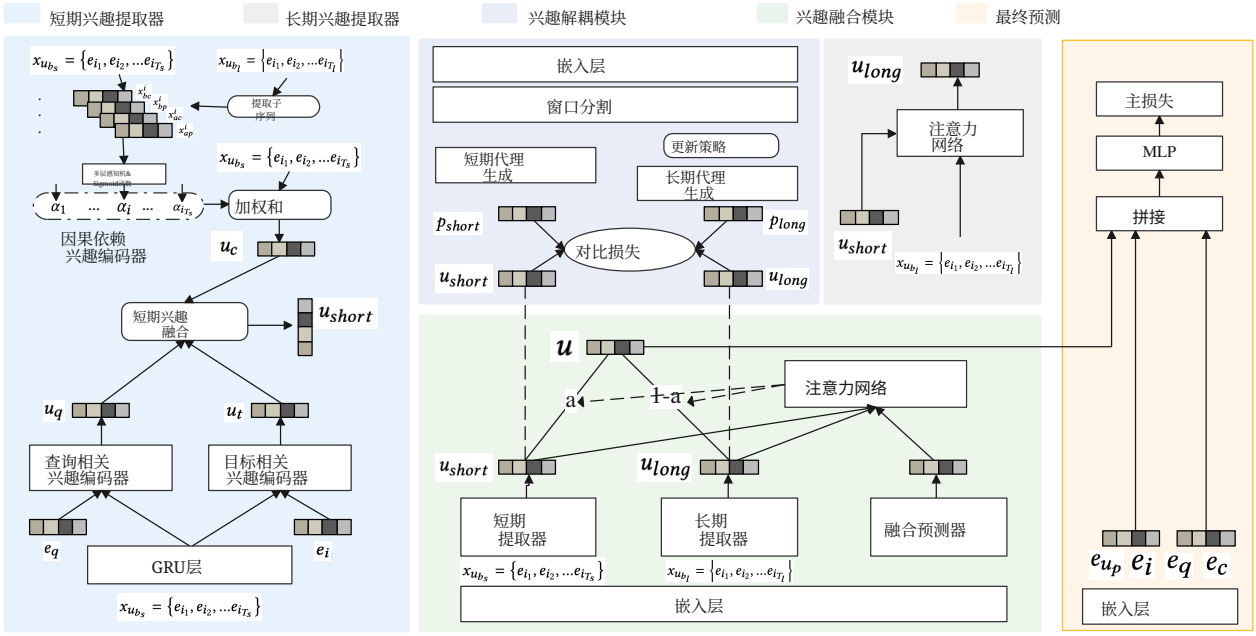


图1：所提出的 HIFN 的整体架构。它由多个模块组成，即 SIE、LIE、IFM 和 IDM

其中 $x_{u_{b_s}} = \{e_{i_1}, e_{i_2}, ...e_{i_{T_s}}\}$、$x_{u_{b_l}} = \{e_{i_1}, e_{i_2}, ...e_{i_{T_l}}\}$ 和 e_{i_t} 是用户第 t 个交互物品的嵌入向量。我们的目标是设计一个模型，预测用户在给定搜索查询 c 及相应相关特征时点击目标商品 i 的概率，形式化定义如下：$\hat{y}_{u,i} = F(e_{u_p}, x_{u_{b_l}}, x_{u_{b_s}}, e_i, e_q, e_c; \theta)$，其中 F 是以模型参数 θ 为参数的学习目标。

2.2 短期兴趣提取器

通常，用户的短期行为对于推断其近期兴趣发挥着至关重要的作用。尽管现有针对商品搜索中查询依赖兴趣提取的研究已展现出显著的性能，但由于在某些情况下用户的多重兴趣相互混淆，这些研究仍难以明确表达用户兴趣。因此，除了查询依赖兴趣提取之外，另一种补充方法是针对单个候选商品，从用户行为中提取相应的兴趣表示，称为目标相关兴趣提取。此外，用户通常会表现出多种类型的行为，*i.e.*，点击或购买，但以往研究在从用户行为中提取用户兴趣时往往忽略了这一点，或仅将其视为某一类行为特征。我们认为，用户的多种类型行为对于最终的用户兴趣提取至关重要，这种方法称为因果依赖兴趣提取。

基于上述考虑，我们首先采用门控循环单元 [7] 来模型化短期兴趣，因为它已成功应用于基于会话的推荐 [12]。RNN 模块以最近的 s 产品表示 $x_{u_{b_s}} = \{e_{i_1}, e_{i_2}, ...e_{i_{T_s}}\}$ 作为输入。

因此，我们可以得到一组高维隐式表示 $x_{u_{b_s}} = \{e_{i_1}, e_{i_2}, ...e_{i_{T_s}}\}$，表示短期用户偏好。

然后，我们将 $x_{u_{b_s}}$ 分别输入三个精心设计的兴趣编码器，即查询依赖兴趣编码器、目标相关兴趣编码器和因果依赖兴趣编码器。

2.2.1 查询依赖兴趣编码器。鉴于用户通过提交的查询明确表达其意图，我们可以直接设计一个名为查询依赖兴趣编码器（QDIE）的模块，根据用户的行为和所提交的查询，准确提取用户当前的兴趣。考虑到历史行为与当前提交的查询之间的相关性各不相同，我们采用 QDIE 模块中的注意力机制来提取查询依赖兴趣，其形式化表示如下：

$$u_q = \sum_{i \in x'_{u_{b_s}}} \frac{exp(f(e_q, e_i))}{\sum_{i' \in x'_{u_{b_s}}} exp(f(e_q, e_{i'}))} e_i \tag{1}$$

其中，$f(q, i)$ 是注意力函数，用于定义每个项目 i 相对于当前查询 q 的权重，定义如下：

$$f(q, i) = (i \cdot tanh(W_f \cdot q + b_f)) \cdot W_h \tag{2}$$

where $W_h \in \mathbb{R}^{\beta}$, $W_f \in \mathbb{R}^{\alpha \times \beta \times \alpha}$, $b_f \in \mathbb{R}^{\alpha \times \beta}$.

2.2.2 目标依赖兴趣编码器。实际上，用户有时无法通过提交的查询清晰地表达自己的搜索意图。在这种情况下，我们采用名为目标依赖兴趣编码器（TDIE）的模块，从用户与各个目标商品相关的行为中提取其当前

兴趣。以旅行场景为例，当用户在杭州的景点上有许多在线点击行为，并提交了名为杭州的查询后，我们可以推断，相较于杭州的小吃，用户可能更偏好西湖这一著名景点。与查询依赖兴趣编码器类似，我们直接针对目标商品 e_i，对 $x'_{u_{b_s}}$ 运用注意力机制，从而得到目标依赖兴趣 u_t。

2.2.3 因果依赖兴趣编码器。用户通常会通过多种类型的行为展现多样且持续的兴趣，*i.e.*，例如点击或购买。例如，如果用户对服装产生了兴趣，他们自然会在一段时间内持续对服装相关商品进行操作，直到需求得到满足，*i.e.*，最终买到心仪的服装。从数学上讲，设 e_i^t 表示用户行为 $x_{u_{b_s}}$ 中第 i 个行为物品在时间 t 所属的类别。实际上，对于时间 t 的行为物品，我们可以根据时间 t 之前（或之后）的点击（或购买）行为是否与 e_i^t 属于同一类别，从 $x_{u_{b_l}}$ 中提取四个辅助子序列：时间 t 之前的点击子序列 x_{bc}^i、时间 t 之前的购买子序列 x_{bp}^i、时间 t 之后的点击子序列 x_{ac}^i，以及时间 t 之后的购买子序列 x_{ap}^i。我们认为，有些用户会表现出强烈兴趣，因为他们会持续点击与第 t–个行为所属类别相同的商品，无论这些点击发生在 t 之前还是之后，尤其是在用户于时间 t 完成购买行为之后。同时，有些用户在时间 t 之前可能会持续点击与时间 t 所属类别相同的商品，但在完成购买行为后兴趣会逐渐减弱。因此，我们采用这四个辅助子序列来刻画用户在时间 t 的先前意图，表示如下：

$$\alpha_i = Sigmoid(FFN(Sum(x_{bc}^i)||Sum(x_{bp}^i)||Sum(x_{ac}^i)||Sum(x_{ap}^i))) \tag{3}$$

其中，$Sum(\cdot)$ 表示求和池化算子。使用求和池化的原因在于，它既能表达行为密度并取得良好效果，计算复杂度又低于其他方法（如门控循环单元、长短期记忆网络）。接下来，因果依赖兴趣的计算方式如下：

$$u_c = \sum_i \alpha_i e_i, \tag{4}$$

2.2.4 短期兴趣融合。如前所述，在不同用户意图下，这三个方面都发挥着重要作用，因此我们采用门控网络来融合短期兴趣的三个方面。该门控网络采用单层前馈网络，并使用 SoftMax 激活函数。它充当选择器，用于计算所选向量的加权和。

$$u_{short} = SoftMax(FFN(u_t, u_q, u_c))^T [u_t, u_q, u_c], \tag{5}$$

2.3 长期兴趣提取器

通常，用户的行为分为两个互不重叠的类别，*i.e.*：长期行为和短期行为。当用户的短期行为稀疏甚至缺失时，长期行为可作为补充线索来发现用户的兴趣。此外，用户的长期行为被视为其内在偏好的反映，并且会随时间缓慢演变，进而影响用户在较近一段时间内的短期行为。受此启发，我们提出了长期兴趣提取器（LTIE）模块，用于提取用户的长期兴趣。具体而言，我们根据生成的短期兴趣 u_{short}，如公式（1）和公式（2）所示，对长期行为应用注意力机制，以提取用户的长期兴趣 u_{long}。

2.4 兴趣融合模块

鉴于用户的长期兴趣和短期兴趣，如何将二者融合并非易事，因为它们对不同用户的贡献各不相同。一种直接的解决方案是采用拼接算子将二者整合起来，但仍难以有效区分各类兴趣的贡献。例如，即使篮球迷近期有大量与帆布鞋相关的行为，当他们提交“鞋子”这一查询时，仍可能因长期兴趣而持续点击篮球鞋。为此，我们设计了一个名为兴趣融合模块的模块，将两种兴趣表示与提交的查询、历史行为和目标商品无缝整合。形式化地说，该过程可表示为：

$$\alpha = sigmoid(FFN(e_i||e_q||u_{short}||u_{long}||\tau_{u_{b_l}})) \tag{6}$$

$$\tau_{u_{b_l}} = GRU(x_{u_{b_l}}) \tag{7}$$

其中，α 表示基于上述信息估计得到的融合权重。随后，最终的用户兴趣表示可表述如下。

$$u = \alpha \cdot u_{short} + (1 - \alpha) \cdot u_{long} \tag{8}$$

最后，我们将 u、e_i、e_q 和 e_c 拼接起来，形成一个综合向量，并将其输入一个以 $ReLU$ 为激活函数的多层感知机层，得到最终预测的点击率分数 $\hat{y}$。最后，我们将目标函数定义如下：

$$Loss_t = -\frac{1}{N} \sum_{(x,y) \in S} (y log\hat{y} + (1 - y) log(1 - \hat{y})), \tag{9}$$

其中，S 表示训练集，其总规模为 N；$y \in \{0, 1\}$ 是真实标签，表示是否发生点击。

2.5 兴趣解耦模块

受到 Zheng [32] 提出的用于解耦的自监督框架的启发，我们将其应用于商品搜索。我们将短期行为的均值表示作为短期兴趣的代理。对于长期兴趣，我们认为，直接对全部长期行为取均值表示并采用 Zheng [32] 的方法，会导致次优性能。长期用户偏好相对稳定，更新缓慢；如果只是简单地计算均值表示，就会忽略长期兴趣的时间变化性。由于短期兴趣基于最近的 s 个交互商品，因此这一缺陷的影响微乎其微。我们将更新机制应用于长期兴趣代理的提取，以捕捉长期兴趣缓慢演变的特征。为简化起见，我们使用前 Ts 个商品对其进行初始化

随后，每交互一个 Ts 商品便对其进行更新（逐步演变）。在这种设置下，p 会基于一组包含 Ts 个商品的会话进行更新，该会话长度也就是对短期用户偏好进行建模的窗口大小。示意如下：

$$p_{long} = (1-\beta)p_{long} + \beta FFN(h_{t-1}) \tag{10}$$

其中，FFN 是由多层前馈网络组成的，h_{t-1} 是先前 Ts 交互商品的均值表示。至于短期代理，其计算方式如下：

$$p_{short} = MeanPooling\left\{e_{i_1}, e_{i_2}, ...e_{i_{T_s}}\right\} \tag{11}$$

将代理作为标签后，我们可以利用它们监督长短期兴趣的解耦。具体而言，我们在兴趣提取器的输出与代理之间进行对比学习 [16]，要求学习到的长短期兴趣表示与各自对应的代理相比与相反的代理更加相似。形式化地说，有以下四个对比任务：

$$sim(u_{long}, p_{long}) > sim(u_{long}, p_{short}) \tag{12}$$

$$sim(p_{long}, u_{long}) > sim(p_{long}, u_{short}) \tag{13}$$

$$sim(u_{short}, p_{short}) > sim(u_{short}, p_{long}) \tag{14}$$

$$sim(p_{short}, u_{short}) > sim(p_{short}, u_{long}) \tag{15}$$

其中，公式 (12)–(13) 监督长期兴趣，公式 (14)–(15) 监督短期兴趣，$sim(\cdot,\cdot)$ 用于衡量嵌入相似度。我们在长期与短期兴趣建模中加入自监督，与现有的无监督方法相比，这能够实现更强的解耦。我们基于贝叶斯个性化排序（BPR）实现成对损失函数，以完成对比学习，计算方式如下：

$$\pounds_{bpr}(a,p,q) = softplus(< a,q > - < a,p >) \tag{16}$$

$$\begin{aligned}\pounds_{con} = \pounds_{bpr}(u_{long}, p_{long}, p_{short}) + \pounds_{bpr}(p_{long}, u_{long}, u_{short}) + \\ \pounds_{bpr}(u_{short}, p_{short}, p_{long}) + \pounds_{bpr}(p_{short}, u_{short}, u_{long}).\end{aligned} \tag{17}$$

我们通过多任务学习，在两个目标上以端到端方式训练模型。具体而言，采用带有超参数 λ 以平衡各目标的联合损失函数，定义如下：

$$\pounds = Loss_t + \lambda \pounds_{con} \tag{18}$$

3 实验

为验证 HIFN 的有效性，我们在离线数据集和线上部署中进行了大量实验，并将其与具有代表性的最先进方法进行了比较。

3.1 数据集

我们使用两个数据集进行实验，包括一个公开数据集和一个工业数据集，分别是亚马逊和飞猪。这两个数据集的用户规模均达百万级，且均采集自真实应用场景。以下介绍所采用数据集的详情。数据集统计信息列于表 1。

表 1：离线数据集的统计信息。（QL 表示查询长度，PL 表示商品长度。）

数据集	服装、鞋类和珠宝	电子产品	玩具和礼品	飞猪
用户	36421	34489	76234	2029216
商品	22521	18397	63323	920487
查询	1998	1499	645	82409
平均查询长度	8.23	8.74	6.21	13.41
平均商品长度	75.36	95.36	196.3	53.67
查询-用户对				
训练集	456521	273890	1493132	26379808
验证集/测试集	4006/4151	753/890	10210/10131	83129/89936

飞猪[1] 飞猪数据集包含用户属性、查询、用户历史行为（包括点击、收藏和购买）以及目标产品，基于 2021 年 10 月 1 日至 10 月 31 日收集的用户日志生成。请注意，历史交互少于 20 次的用户已被移除。2021 年 10 月前 30 天的用户日志用作训练数据，而 10 月最后一天则用于验证（中午 12 点之前）和测试（中午 12 点之后）。训练数据集中的负样本设为用户曝光但未点击的产品，正样本则为被点击的产品。

亚马逊[2] 由于个性化商品搜索领域缺乏大规模公开数据集，我们与现有方法 [1, 10]一致，使用亚马逊数据集作为实验语料。在实验中，我们采用了所提供的五核心版本，其中剩余用户和商品分别至少有五条评论。此外，我们选择了三个规模各异的类别：服装、鞋类和珠宝、玩具与游戏、电子产品。这些数据集均包含多个类别，因此用户可能具有不同的兴趣。遵循参考文献 [11], 中的策略，我们根据用户的评论提取其商品购买行为，即用户评论过的商品就是他们购买的商品。我们的模型使用邻近窗口中先前购买的商品来建模用户短期兴趣。我们还进一步筛选数据集，确保每位用户至少有20件已购商品（即20条评论）。

遵循 [10], 所采用的相同范式，我们利用类别信息为每件已购买商品构造查询。该策略基于这样一项发现：定向商品搜索是用户搜索生产商名称、品牌或一组描述商品类别的词语。我们将四个数据集分别划分为训练集、验证集和测试集。我们首先从用户评论中提取用户-商品对，然后提取这些商品对应的查询，从而得到三元组。对于每个数据集，我们将每位用户最后一次购买交易留作测试集，倒数第二次购买交易留作验证集，其余交易用于训练集。此外，在训练阶段，我们隐藏验证集和测试集中的评论，以模拟现实场景。

[1]中国最受欢迎的在线旅游平台之一，www.fliggy.com [2] http://jmcauley.ucsd.edu/data/amazon

由于亚马逊数据集不提供负样本，我们采用负采样方法进行评估。具体而言，对于每个正向用户-查询-商品三元组，我们随机生成与查询类别相同的负商品，以模拟真实搜索场景。然后，将生成的商品、查询和用户组成负三元组样本。每个正向三元组对应生成十个负样本。

3.2 对比方法

为验证所提方法的有效性，我们将其与以下方法进行比较：

• **AEM** [1]：基于注意力的嵌入模型（AEM）通过利用查询关注用户的历史购买商品，构建查询相关的用户嵌入。

• **ZAM** [1]：零注意力模型（ZAM）在 AEM 的基础上引入零向量，并允许查询关注该零向量，从而实现差异化个性化。

• **TEM** [5]：基于Transformer的嵌入模型（TEM） [6]是一种先进模型，它使用 Transformer 对查询和历史已购商品进行编码，并根据编码后的查询-用户信息生成商品。

• **DeepFM** [9]：它结合了显式高阶交互模块、深度多层感知机模块和传统因子分解机模块，无需手动进行特征工程。

• **DIN** [34]：它利用注意力机制，根据相应目标激活相关的用户行为，并学习用户兴趣的自适应表示向量。

• **DIEN** [33]：它采用兴趣提取层，从用户的历史行为中捕捉时序兴趣，并结合门控循环单元与注意力机制，进一步捕捉与目标商品相关的兴趣。

• **ZAM+TDIE**：与 ZAM 相比，我们加入了目标依赖兴趣编码器（TDIE），用于建模目标相关的用户兴趣。目标相关的用户兴趣与用户表示拼接，形成新的用户兴趣向量。• **TEM+TDIE**：对 TEM 执行与 ZAM+TDIE 相同的操作。

• **ALSTP** [10]：它利用注意力机制处理用户近期交互过的商品及其全局向量，以表示用户长期和短期偏好。它是个性化商品搜索中最先进的长期和短期建模方法。

3.3 指标

在实验中，我们使用曲线下面积（AUC）和对数损失（或交叉熵）[21, 22] 来评估所有对比模型在飞猪数据集上的排序能力。曲线下面积越大、对数损失越小，表示排序性能越好。在公开数据集（即亚马逊数据集）上，我们使用归一化折损累计增益@10、平均倒数排名和平均准确率均值 [10]，，因为这些数据集不提供负样本，而计算曲线下面积需要数据集中同时包含正样本和负样本。

3.4 实现细节

我们使用 Adam 优化器来训练模型。为多层感知机启用批量归一化，激活函数为 ReLU。我们使用网格搜索来寻找最佳超参数。我们所提出实现的最优设置为：批量大小为 512。学习率为 0.001。IDM 中的前馈网络（FFN）设为 [128, 64, 32, 16]，，短期兴趣融合中的 FFN 设为 [128, 64, 32, 3]。λ 在两个数据集上均为 0.1。Ts 在飞猪上为 10，在服装、鞋类和珠宝上为 8，在电子产品上为 14，在玩具和礼品上为 12。β 在飞猪上为 0.55，在服装、鞋类和珠宝上为 0.35，在电子产品上为 0.45，在玩具和礼品上为 0.6。每项实验结果的值为 10 次重复测试的平均值。

3.5 主要对比结果

我们在表 2 中展示了两个所采用数据集上的整体性能。根据结果，我们得出以下观察：

• **在商品搜索中，提取目标相关的用户兴趣至关重要**。AEM、ZAM 和 TEM 均对查询与用户行为之间的关联进行建模，以表示用户兴趣。然而，用户兴趣并不总是集中的。例如，当用户发出"服装"查询时，他并未表达对颜色、品牌和风格的偏好。用户会在结果页面中点击藏青色服装，而不是其他颜色的服装，因为藏青色是用户历史购买商品中最常见的颜色。如果我们只对查询与历史行为之间的关系进行建模，以提取用户兴趣向量，就会忽略这一重要因素。从表中可以看出，对查询和用户历史行为进行建模的方法（如 AEM、ZAM、TEM），以及对目标商品和用户历史行为进行建模的方法（如 DIN 和 DIEN），在不同数据集上的表现各不相同。然而，在加入对目标商品与用户行为序列之间关系进行建模的模块（TDIE）后，性能显著提升，这表明同时从两个角度对用户兴趣进行建模的重要性。

• **联合建模长期兴趣和短期兴趣并不总能提升商品搜索的性能**。尽管 ALSTP 是商品搜索领域最先进的长期与短期兴趣建模方法，但仍有许多问题尚未得到充分解决。首先，短期兴趣对最终预测起着重要作用，但 ALSTP 只考虑查询相关兴趣，忽略了目标相关兴趣和因果相关兴趣。其次，简单拼接长期兴趣和短期兴趣，忽略了它们在不同情境下的重要性各不相同这一事实。第三，将长期兴趣和短期兴趣相互纠缠地进行建模，会增加模型冗余，导致准确率下降。结果表明，ALSTP 在不同指标和数据集上的效果并不稳定。例如，ALSTP 是衣物数据集上表现最好的基线模型，但在电子产品数据集上的归一化折损累计增益表现比 ZAM 低约 5.35%。这表明，若不妥善解决上述问题，对长期兴趣和短期兴趣进行建模就无法带来稳定的提升。

• **HIFN 在所有数据集和指标上都取得了显著提升**。HIFN 的表现优于所有对比方法，取得了显著进步。具体而言，相较于最先进方法，HIFN 在衣物数据集上的归一化折损累计增益提升约 0.07，在飞猪数据集上的曲线下面积提升约 0.017。一致且显著的进步表明，与以往研究相比，HIFN 能够以更恰当的方式对长短期用户兴趣进行建模。

表 2：飞猪和亚马逊数据集上的整体性能。

数据集	服装、鞋类和珠宝			电子产品			玩具与游戏			飞猪	
模型	平均倒数排名	归一化折损累计增益	MAP	平均倒数排名	归一化折损累计增益	MAP	平均倒数排名	归一化折损累计增益	MAP	曲线下面积	对数损失
AEM	0.024	0.025	0.019	0.269	0.291	0.265	0.068	0.072	0.062	0.735	0.598
ZAM	0.025	0.027	0.021	0.289	0.315	0.288	0.079	0.112	0.088	0.734	0.601
TEM	0.027	0.026	0.023	0.201	0.261	0.194	0.138	0.158	0.129	0.731	0.621
DeepFM	0.020	0.028	0.016	0.222	0.296	0.286	0.073	0.104	0.073	0.737	0.588
DIN	0.022	0.029	0.018	0.223	0.298	0.289	0.075	0.105	0.076	0.739	0.581
DIEN	0.023	0.034	0.022	0.288	0.319	0.301	0.099	0.127	0.118	0.741	0.579
ZAM+TDIE	0.031	0.036	0.026	0.311	0.318	0.322	0.106	0.144	0.123	0.746	0.552
TEM+TDIE	0.032	0.034	0.028	0.315	0.289	0.291	0.141	0.162	0.134	0.749	0.541
ALSTP	0.034	0.037	0.029	0.302	0.299	0.294	0.101	0.134	0.120	0.742	0.576
HIFN	**0.041**	**0.044**	**0.035**	**0.331**	**0.342**	**0.351**	**0.162**	**0.171**	**0.143**	**0.759**	**0.533**

表3：短期兴趣提取器研究。

数据集	服装、鞋类和珠宝			飞猪	
模型	MRR	NDCG	MAP	AUC	对数损失
HIFN*	0.033	0.032	0.023	0.739	0.581
HIFN*+QDIE	0.037	0.038	0.028	0.746	0.553
HIFN*+TDIE	0.036	0.037	0.026	0.745	0.558
HIFN*+CDIE	0.033	0.032	0.024	0.744	0.561
不含 CDIE 的 HIFN	0.039	0.040	0.032	0.753	0.541
不含 TDIE 的 HIFN	0.036	0.039	0.031	0.751	0.549
不含 QDIE 的 HIFN	0.037	0.038	0.028	0.749	0.552
无门控的 HIFN	0.034	0.035	0.024	0.743	0.563
HIFN	**0.041**	**0.044**	**0.035**	**0.759**	**0.533**

3.6 短期兴趣提取器研究

本节将讨论短期兴趣提取器的各个模块如何影响 HIFN 的效果。基准模型为 HIFN*，它使用均值池化算子（无注意力）来聚合 GRU 层的输出。具体而言，我们考虑以下设置：1）添加 QDIE；2）添加 TIDE；3）添加 CDIE；4）添加 QDIE 和 TIDE，即不使用 CDIE；5）添加 QDIE 和 CDIE，即不使用 TIDE；6）添加 TIDE 和 CDIE，即不使用 QDIE；7）将融合门替换为均值池化算子。

3.6.1 各模块的消融研究。本节中，我们研究短期兴趣编码器的影响。如表3所示，基础模型的表现最差，这表明若不提炼有用信号，它们很容易淹没在噪声中。此外，与基础模型相比，QDIE、TDIE 或 CDIE 均能提升曲线下面积，其中 QDIE 带来的增益最大，CDIE 带来的增益最小。这表明，捕捉查询相关、目标相关和因果依赖的用户兴趣均能带来提升，而查询依赖的用户兴趣对预测准确率的帮助最大，这也符合商品搜索的特点。（注意，添加 CDIE 模块仅使 Cloth- ing 的表现略有提升，但在飞猪上带来的提升相对显著。这是因为亚马逊仅包含用户购买行为，而飞猪包含购买和点击行为；CDIE 旨在从用户多种历史行为类型中提取信息。）4)、5) 和 6) 的表现均优于先前方法，这表明这些兴趣提取模块提取的信息

表 4：不同查询类型下的 SIE 研究。

查询类型	宽泛型	精确型
模型	AUC	AUC
HIFN	**0.748**	**0.776**
不含 QDIE 的 HIFN	0.745	0.759
不含 TDIE 的 HIFN	0.739	0.772
不含 CDIE 的 HIFN	0.742	0.768

具有互补性。相比之下，HIFN 从三个不同角度学习用户短期兴趣，并通过精心设计的门控网络融合它们的输出向量，从而取得了最高的增益。这表明，捕捉查询相关、目标相关和因果依赖的用户兴趣能够提升预测准确率。

3.6.2 不同查询类型的数据集研究。本节研究不同查询类型的数据集中不同兴趣提取器的影响。我们首先根据查询类型将飞猪测试集划分为两组，一组是抽象搜索查询，另一组是精确型（即非抽象）搜索查询。我们将抽象搜索查询定义为：1）目的地，例如杭州、上海、迈阿密；2）标签，例如玩乐、冲浪。与精确型搜索不同，用户发起抽象查询时不会表达出明显的需求意图。如表 4 所示，有几点值得注意。一方面，在精确型查询数据集中，不含 QDIE 的 HIFN 的表现比另外两个模型更差，这表明当用户具有明确需求时，针对查询提取用户兴趣可以带来更多收益。另一方面，在抽象查询数据集中，不含 TDIE 的 HIFN 的表现比另外两个模型更差，这表明当用户没有明确意图时，目标相关兴趣发挥着最重要的作用，而针对目标商品提取用户兴趣，是从用户的多重兴趣中挖掘意图的有效方式。这进一步验证了联合建模查询相关、目标相关和因果关系相关的用户兴趣能够取得显著的性能提升。

3.7 长期兴趣提取器研究

在本节中，我们研究 HIFN 中长期兴趣提取器的影响。基准模型为 HIFN†，它提取用户

表 5：长期兴趣提取器研究。

数据集	服装、鞋类和珠宝			飞猪	
模型	MRR	NDCG	MAP	AUC	对数损失
HIFN†	0.035	0.036	0.029	0.745	0.554
HIFN†+目标注意力	0.036	0.037	0.03	0.746	0.553
HIFN†+查询注意力	0.039	0.042	0.032	0.754	0.558
HIFN†+用户注意力	/	/	/	0.752	0.564
HIFN	**0.041**	**0.044**	**0.035**	**0.759**	**0.533**

表 6：兴趣融合模块研究。

数据集	服装、鞋类和珠宝			飞猪	
模型	MRR	NDCG	MAP	AUC	对数损失
拼接	0.035	0.036	0.029	0.750	0.539
α=0.9	0.037	0.036	0.028	0.747	0.544
α=0.75	0.036	0.034	0.025	0.749	0.541
α=0.6	0.034	0.033	0.022	0.751	0.537
α=0.45	0.035	0.034	0.024	0.753	0.535
α=0.3	0.036	0.035	0.026	0.747	0.543
α=0.15	0.032	0.031	0.021	0.748	0.545
HIFN	**0.041**	**0.044**	**0.035**	**0.759**	**0.533**

行为时使用均值池化算子（无注意力）。具体而言，我们考虑以下设置：1）目标注意力：将目标商品作为查询，将行为物品作为注意力机制中的键；2）查询注意力：采用与商品搜索领域最先进的长短期方法 ALSTP 相同的长期注意力机制；3）用户注意力：将用户字段特征作为查询，将行为物品作为注意力机制中的键。

从表 5 可以看出，每种注意力机制都优于基础模型，这表明，直接对用户的长期行为进行均值池化，无法充分关注并利用其中的有用信息。ALSTP 中使用的查询注意力机制和用户注意力机制，表现均优于目标注意力。我们认为，用户的长期兴趣较为稳定，变化缓慢，而用户字段和查询字段特征体现了用户的内在特征，在一定程度上与用户的长期兴趣相一致。（由于亚马逊数据集中没有用户画像特征，因此我们仅在飞猪数据集上针对用户注意力进行了实验。）HIFN 利用短期兴趣激活长期兴趣，取得了最佳表现。我们推测，这是因为短期兴趣是融合了用户画像、查询和近期行为的统一向量，能够更恰当地提取用户的长期兴趣。

3.8 长期与短期兴趣解耦研究

为了证明解耦框架的有效性，我们设计了两类实验。首先，我们将验证该框架能否良好地解耦短期兴趣和长期兴趣。其次，我们将验证不同代理设置对结果的影响。

3.8.1 反事实评估。如果不同因素的重要性会随时间变化，那么学习底层因素的解耦表示有利于提高最终准确率 [20]。在电子商务商品搜索中，用户会有多种类型的行为，例如购买、收藏和点击；每种行为所揭示的用户偏好强度各不相同，即购买表达了较强的偏好，而点击表达了相对较弱的偏好。Grbovic [8] 指出，成本较高的行为往往更多地受到用户长期兴趣的驱动，而点击等成本较低的行为则更多地反映短期兴趣。众所周知，购买（金钱成本）的成本高于收藏（双击成本），而收藏的成本又高于点击（只需点击一次）。因此，我们设计了一组实验来验证解耦的有效性。由于亚马逊数据集仅包含用户购买行为，我们在飞猪数据集上验证其效果。我们首先使用曝光-点击数据集训练一个模型，并在飞猪的点击、收藏和购买测试数据集上进行预测。直观而言，在融合这两个方面时，预测购买行为时短期兴趣的权重应小于预测点击行为时的权重。我们将所提出的模型 HIFN 与不含自监督框架的 HIFN，以及用于商品搜索的最先进长短期方法 ALSTP 进行比较。

表 7 展示了点击商品、收藏商品和已购商品的曲线下面积、对数损失及平均值 α。我们得到以下发现。首先，HIFN（不含 IDM）的表现优于 ALSTP，说明 HIFN 提取并融合长期兴趣和短期兴趣的方式比 ALSTP 更恰当、更有效。其次，尽管使用点击数据训练的模型来预测购买/收藏具有挑战性，HIFN 仍取得了良好的结果，并在收藏测试集和购买测试集上优于其他对比方法。第三，HIFN 在点击行为上的平均值 α 大于收藏行为，而收藏行为又大于购买行为，这与前文的论述一致：成本较高的行为往往更多受用户长期兴趣驱动，而点击这类成本较低的行为则更多反映短期兴趣。然而，HIFN（不含 IDM）在收藏行为上的平均值 α 小于购买行为；ALSTP 在点击行为上的平均值 α 也小于购买/收藏行为。这表明，HIFN 在一定程度上成功解耦了长期兴趣与短期兴趣，而 HIFN（不含 IDM）和 ALSTP 则将二者混杂在一起。

3.8.2 长期兴趣代理更新的有效性。尽管 Zheng [32] 提出了一种用于代理设置以解耦用户兴趣的简单策略，但我们认为该策略忽视了长期兴趣会缓慢演变这一特性，因此提出了长期兴趣代理更新策略来解决这一问题。本节针对不同指标，研究了长期兴趣代理更新策略在四个数据集上的有效性。如表 8 所示，采用长期用户偏好更新策略的性能优于不进行更新的情况。具体而言，在三个亚马逊数据集上，更新策略分别使归一化折损累计增益提升约 0.003、0.002 和 0.003；在飞猪数据集上，曲线下面积提升约 0.007。这与我们的假设一致：长期用户偏好应当逐步更新。

表 7：兴趣解耦模块研究。

数据集	点击			收藏			购买		
模型	AUC	对数损失	平均值（α）	AUC	对数损失	平均值（α）	AUC	对数损失	平均值（α）
HIFN	**0.759**	**0.533**	0.783	**0.746**	**0.569**	0.721	**0.741**	**0.573**	0.699
不含 IDM 的 HIFN	0.753	0.549	0.637	0.741	0.578	0.526	0.737	0.586	0.672
ALSTP	0.742	0.576	0.433	0.733	0.591	0.621	0.729	0.598	0.596

表 8：不同代理设置的研究。

数据集	服装			电子产品			玩具与游戏			飞猪	
策略	MRR	NDCG	MAP	MRR	NDCG	MAP	MRR	NDCG	MAP	AUC	对数损失
未更新	0.038	0.041	0.032	0.329	0.340	0.347	0.159	0.168	0.137	0.752	0.542
已更新	**0.041**	**0.044**	**0.035**	**0.331**	**0.342**	**0.351**	**0.162**	**0.171**	**0.143**	**0.759**	**0.533**

3.9 兴趣融合模块研究

尽管 ALSTP 取得了显著的性能提升，我们认为，拼接长期兴趣和短期兴趣会导致性能下降。在 HIFN 中，我们提出以自适应方式聚合二者。我们将 HIFN 与两种不同设置进行比较：1）拼接；2）结合这两个方面时使用固定的 α。结果如表 6 所示，可以发现，采用 IFM 的 HIFN 优于所有其他设置。这些结果验证了对长期兴趣和短期兴趣进行自适应融合的必要性。

3.10 在线 A/B 测试

我们还在平台上部署了 HIFN 并进行了 A/B 测试，其中基线模型为 TEM+TDIE（此前，TEM+TDIE 已在线证明，其结果优于第 3.5 节中的其他对比方法）。在连续 15 天内，所提出的方法相较于基线模型的整体点击率平均提升了 **5.13%**，这与离线评估结果一致。目前，HIFN 已部署在线并承载主要流量。

4 相关工作

4.1 商品搜索

认识到个性化在商品搜索中的重要性，Ai 等人 [2] 提出了一种层次化嵌入模型，通过对查询和用户向量进行凸组合来预测已购商品。Guo 等人 [10] 利用注意力机制处理用户近期购买记录及其全局向量，以表示用户长期和短期偏好。近期，Ai 等人 [1] 通过分析商业搜索日志发现，个性化并非总能带来正向效果。他们进一步提出了零注意力模型（ZAM），用于控制个性化的影响。不过，个性化所能产生的最大影响仍不超过查询本身。Bi 等人 [5] 发现了这一局限，并提出了一种 Transformer 模型，用于编码查询和历史已购商品，使个性化的影响范围可以从完全没有到充分发挥。这些模型通过捕捉与查询相关的动态用户兴趣来构建用户画像。然而，它们忽略了目标依赖兴趣和因果依赖兴趣，而这些兴趣能够为更准确的预测提供额外信息。

4.2 点击率预测

现有点击率预测工作主要从以下方面关注单一场景建模：1）特征交互（例如，因子分解机 [18], DeepFM [9]）；2）用户历史行为（例如，DIN[34], DIEN [33]）。因子分解机（FM）旨在显式建模特征交互，而逻辑回归（LR） [19] 和跟随正则化领导者（FTRL） [17] 等传统广义线性模型则无法解决交互问题。Wide&Deep[6] 和 DeepFM [9] 结合低阶和高阶特征来提升性能。FmFM [23] 为每个字段特征设置不同的嵌入维度，从而减少模型参数量并避免过拟合。DIN [34] 利用注意力机制，根据候选商品从用户行为序列中捕捉相关兴趣。DIEN[33] 进一步利用门控循环单元结构捕捉用户兴趣的演化。考虑到单个向量可能不足以捕捉复杂的用户模式，DMIN [27] 通过专门设计的提取器层对用户的多重兴趣进行建模。

4.3 长期与短期兴趣建模

推荐领域对长期与短期兴趣建模进行了广泛研究，并提出了多种方法 [3, 13, 31]，以明确区分长期兴趣和短期兴趣。例如，Zhao [31] 使用矩阵分解建模长期兴趣，并使用循环神经网络建模短期兴趣。Yu [29] 开发了一种用于建模短期兴趣的长短期记忆网络变体，并采用非对称奇异值分解建模长期兴趣。然而，在商品搜索中，由于用户发出的查询，长期与短期兴趣建模变得困难。ALSPT 是商品搜索中最先进的长期与短期兴趣建模方法，它通过对用户近期行为和全局向量应用注意力机制来表示长期和短期偏好，取得了显著的性能提升，但在兴趣建模和融合方面仍存在不足。

5 结论

本文介绍了一种用于商品搜索的新型点击率模型 HIFN，它由四个精心设计的模块组成：SIE、LIE、IFM 和 IDM。SIE 旨在提取短期

兴趣的不同方面。LIE 旨在根据 SIE 的输出提取长期兴趣。随后，IFM 以自适应方式融合长期和短期兴趣。IDM 用于解耦兴趣的这两个方面。这些模块共同集成在一个端到端多任务学习框架中。在真实世界电子商务平台上开展的大量离线和在线实验表明，HIFN 优于最先进方法。

参考文献

[1] Qingyao Ai、Daniel N Hill、SVN Vishwanathan 和 W Bruce Croft。2019。面向个性化商品搜索的零注意力模型。载于第*28*届*ACM*信息与知识管理国际会议论文集。379–388。[2] Qingyao Ai、Yongfeng Zhang、Keping Bi、Xu Chen 和 W Bruce Croft。2017。面向个性化商品搜索的层次化嵌入模型学习。载于第*40*届*ACM SIGIR*信息检索研究与发展国际会议论文集。645–654。[3] Mingxiao An、Fangzhao Wu、Chuhan Wu、Kun Zhang、Zheng Liu 和 Xing Xie。2019。基于长期和短期用户表征的神经新闻推荐。载于第*57*届计算语言学协会年会论文集。336–345。[4] Paul N Bennett、Ryen W White、Wei Chu、Susan T Dumais、Peter Bailey、Fedor Borisyuk 和 Xiaoyuan Cui。2012。建模短期和长期行为对搜索个性化的影响。载于第*35*届*ACM SIGIR*信息检索研究与发展国际会议论文集。185–194。[5] Keping Bi、Qingyao Ai 和 W Bruce Croft。2020。面向个性化商品搜索的基于Transformer的嵌入模型。载于第*43*届*ACM SIGIR*信息检索研究与发展国际会议论文集。1521–1524。[6] Heng-Tze Cheng、Levent Koc、Jeremiah Harmsen、Tal Shaked、Tushar Chandra、Hrishi Aradhye、Glen Anderson、Greg Corrado、Wei Chai、Mustafa Ispir 等。2016。推荐系统中的宽深学习。载于首届推荐系统深度学习研讨会论文集。7–10。[7] Kyunghyun Cho、Bart Van Merriënboer、Dzmitry Bahdanau 和 Yoshua Bengio。2014。论神经机器翻译的特性：编码器-解码器方法。*arXiv*预印本 *arXiv:1409.1259*（2014）。[8] Mihajlo Grbovic 和 Haibin Cheng。2018。利用嵌入实现Airbnb搜索排序的实时个性化。载于第*24*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集。311–320。[9] Huifeng Guo、Ruiming Tang、Yunming Ye、Zhenguo Li 和 Xiuqiang He。2017。DeepFM：用于点击率预测的基于因子分解机的神经网络。载于第*26*届国际人工智能联合会议论文集。1725–1731。[10] Yangyang Guo、Zhiyong Cheng、Liqiang Nie、Yinglong Wang、Jun Ma 和 Mohan Kankanhalli。2019。面向个性化商品搜索的注意力长期短期偏好建模。*ACM*信息系统汇刊（*TOIS*）37，2（2019），1–27。[11] Ruining He 和 Julian McAuley。2016。起伏变化：利用单类协同过滤建模时尚趋势的视觉演变。载于第*25*届万维网国际会议论文集。507–517。[12] Balázs Hidasi、Alexandros Karatzoglou、Linas Baltrunas 和 Domonkos Tikk。2015。基于循环神经网络的会话推荐。*arXiv*预印本 *arXiv:1511.06939*（2015）。[13] Linmei Hu、Chen Li、Chuan Shi、Cheng Yang 和 Chao Shao。2020。结合长期和短期兴趣建模的图神经新闻推荐。信息处理与管理57，2（2020），102142。[14] Sen Li、Fuyu Lv、Taiwei Jin、Guli Lin、Keping Yang、Xiaoyi Zeng、Xiao-Ming Wu 和 Qianli Ma。2021。淘宝搜索中的基于嵌入的商品检索。载于第*27*届*ACM SIGKDD*知识发现与数据挖掘会议论文集。3181–3189。[15] Zhao Li、Xin Shen、Yuhang Jiao、Xuming Pan、Pengcheng Zou、Xianling Meng、Chengwei Yao 和 Jiajun Bu。2020。层次化二部图神经网络：面向大规模电子商务应用。载于*2020*年*IEEE*第*36*届国际数据工程会议（*ICDE*）。IEEE，1677–1688。

[16] Yixin Liu、Zhao Li、Shirui Pan、Chen Gong、Chuan Zhou 和 George Karypis。2021。通过对比式自监督学习检测属性网络中的异常。*IEEE*神经网络与学习系统汇刊33，6（2021），2378–2392。[17] H Brendan McMahan、Gary Holt、David Sculley、Michael Young、Dietmar Ebner、Julian Grady、Lan Nie、Todd Phillips、Eugene Davydov、Daniel Golovin 等。2013。广告点击预测：来自一线实践的观点。载于第*19*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集。1222–1230。[18] Steffen Rendle。2010。因子分解机。载于*2010*年*IEEE*国际数据挖掘会议论文集。IEEE，995–1000。[19] Matthew Richardson、Ewa Dominowska 和 Robert Ragno。2007。预测点击：估算新广告的点击率。载于第*16*届万维网国际会议论文集。521–530。[20] Bernhard Schölkopf、Francesco Locatello、Stefan Bauer、Nan Rosemary Ke、Nal Kalchbrenner、Anirudh Goyal 和 Yoshua Bengio。2021。迈向因果表征学习。*IEEE*会刊109，5（2021），612–634。[21] Qijie Shen、Wanjie Tao、Jing Zhang、Hong Wen、Zulong Chen 和 Quan Lu。2021。SAR-Net：面向数百种旅行场景中个性化公平推荐的场景感知排序网络。载于第*30*届*ACM*信息与知识管理国际会议论文集。4094–4103。[22] Qijie Shen、Hong Wen、Wanjie Tao、Jing Zhang、Fuyu Lv、Zulong Chen 和 Zhao Li。2022。用于触发式推荐中点击率预测的深度兴趣突出网络。载于*ACM Web*会议*2022*论文集。422–430。[23] Yang Sun、Junwei Pan、Alex Zhang 和 Aaron Flores。2021。FMˆ2：面向推荐系统的字段矩阵化因子分解机。*arXiv*预印本 *arXiv:2102.12994*（2021）。[24] Wanjie Tao、Liangyue Li、Chen Chen、Zulong Chen 和 Hong Wen。2022。线上遇见线下：探索旅行目的地预测中的周期性。载于第*45*届*ACM SIGIR*信息检索研究与发展国际会议论文集。2366–2370。[25] Wanjie Tao、Yu Li、Liangyue Li、Zulong Chen、Hong Wen、Peilin Chen、Tingting Liang 和 Quan Lu。2022。SMINet：面向冷启动用户推荐的状态感知多方面兴趣表征网络。载于*AAAI*人工智能会议论文集，第36卷。8476–8484。[26] Liang Xiang、Quan Yuan、Shiwan Zhao、Li Chen、Xiatian Zhang、Qing Yang 和 Jimeng Sun。2010。通过长短期偏好融合实现图上的时序推荐。载于第*16*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集。723–732。[27] Zhibo Xiao、Luwei Yang、Wen Jiang、Yi Wei、Yi Hu 和 Hao Wang。2020。用于点击率预测的深度多兴趣网络。载于第*29*届*ACM*信息与知识管理国际会议论文集。2265–2268。[28] Jia Xu、Jin Huang、Zulong Chen、Yang Li、Wanjie Tao 和 Chuanfei Xu。2022。ODNET：一种用于航班推荐的新型个性化起讫点排序网络。载于*2022*年*IEEE*第*38*届国际数据工程会议（*ICDE*）。IEEE，3481–3493。[29] Zeping Yu、Jianxun Lian、Ahmad Mahmoody、Gongshen Liu 和 Xing Xie。2019。利用长期与短期偏好进行自适应用户建模，实现个性化推荐。载于*IJCAI*。4213–4219。[30] Jing Zhang 和 Dacheng Tao。2020。赋予万物智能：物联网人工智能的进展、挑战与机遇综述。*IEEE*物联网期刊8，10（2020），7789–7817。[31] Wei Zhao、Benyou Wang、Jianbo Ye、Yongqiang Gao、Min Yang 和 Xiaojun Chen。2018。PLASTIC：通过对抗训练，在Top-n推荐中优先考虑长期和短期信息。载于*Ijcai*。3676–3682。[32] Yu Zheng、Chen Gao、Jianxin Chang、Yanan Niu、Yang Song、Depeng Jin 和 Yong Li。2022。解耦推荐中的长期与短期兴趣。载于*ACM Web*会议*2022*论文集。2256–2267。[33] Guorui Zhou、Na Mou、Ying Fan、Qi Pi、Weijie Bian、Chang Zhou、Xiaoqiang Zhu 和 Kun Gai。2019。用于点击率预测的深度兴趣演化网络。载于*AAAI*人工智能会议论文集。[34] Guorui Zhou、Xiaoqiang Zhu、Chenru Song、Ying Fan、Han Zhu、Xiao Ma、Yanghui Yan、Junqi Jin、Han Li 和 Kun Gai。2018。用于点击率预测的深度兴趣网络。载于第*24*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集。ACM，1059–1068。