arXiv:2304.04529v1 [cs.IR] 10 Apr 2023

FAN：用于电子商务推荐点击率预测的疲劳感知网络

Ming Li*,Naiyin Liu*, Xiaofeng Pan(✉), Yang Huang, Ningning Li, Ying min Su, Chengjun Mao, 和 Bo Cao

阿里巴巴集团, 杭州, 中国 hongming.lm@alibaba-inc.com, liuny5@mail2.sysu.edu.cn, pxfvintage@163.com, 21631140@zju.edu.cn,{lily.lnn,yingmin.sym,chengjun.mcj,zhizhao.cb}@alibaba-inc.com

摘要。 由于 $clicks$ 通常包含大量噪声，越来越多的研究致力于对隐式用户负面行为（$i.e.$、 $non\text{-}clicks$）进行建模。然而，这些方法要么依赖显式用户负面行为（$e.g.$、 $dislikes$），要么简单地将 $non\text{-}clicks$ 视为负反馈，未能全面学习用户负向兴趣。在这种情况下，用户可能会因为看到过多相似的推荐而产生疲劳。本文提出了疲劳感知网络（FAN），一种能够直接从 $non\text{-}clicks$感知用户疲劳的新型点击率模型。具体而言，我们首先对由 $non\text{-}clicks$生成的时间序列应用傅里叶变换，得到其频谱，其中包含关于用户疲劳的全面信息。随后，利用目标物品的类别信息调制该频谱，以建模不同类别在疲劳上限和用户耐心度方面存在差异所导致的偏差。此外，我们采用门控网络对用户疲劳置信度进行建模，并设计辅助任务来指导用户疲劳的学习，从而获得良好学习的疲劳表征，并将其与用户兴趣结合起来进行最终的点击率预测。在真实世界数据集上的实验结果验证了 FAN 的优越性，在线 A/B 测试也表明 FAN 的表现显著优于具有代表性的点击率模型。

关键词： 推荐系统 · 点击率预测 · 用户疲劳。

1 引言

推荐系统（RS）在信息过载的情境下帮助用户发现心仪物品，因而变得愈发不可或缺，同时也提升了用户体验并创造了新的商业价值 [21,24]。通常，工业级电子商务推荐系统由匹配组成。

* 两位作者贡献相同。Xiaofeng Pan 是通讯作者。

和排序。匹配阶段旨在检索与用户兴趣 [13,5], 相关的候选物品，之后排序阶段预测用户与这些候选物品互动的精确概率， $e.g.$、点击率（CTR） [26] 和转化率（CVR） [17,12]。本文聚焦于排序阶段的点击率（CTR）预测任务。

现有大多数点击率方法 [7,26,1] 在电子商务推荐中主要依赖隐式正反馈（$i.e.$、点击）作为正标签，并推断用户当前的兴趣，因为在实践中点击很容易被收集。然而，点击行为通常包含大量噪声 [16,18] ，因为点击与用户的真实偏好之间存在差距，而且历史用户行为中可能存在过时的兴趣 [9]。此外，正反馈倾向于推荐系统提供给用户的选择，因为用户只能点击向其展示的物品。因此，仅仅关注隐式正反馈将导致对用户兴趣的有偏建模以及同质化和短视的推荐，这可能会损害用户体验 [25]。

最近，一些研究者 [6,10]注意到仅依赖隐式正反馈的缺点，并尝试利用更丰富的隐式负反馈（$i.e.$，未点击）来学习用户负向兴趣。其核心思路是在损失函数中引入正则化，以确保正反馈的表示与<微信 id='5'>未点击相距较远。然而，用户没有点击某件物品，并不一定意味着用户不喜欢它。附近可能展示了某些相似物品，或者曝光的物品可能只是没有引起用户的注意。因此，在建模用户兴趣时忽略<微信 id='7'>未点击中的噪声，可能会导致冲突，并造成推荐不准确。另一类研究 [20,3,19] 尝试利用显式负反馈（$e.g.$，不喜欢），从隐式反馈（$i.e.$，未点击和点击）中提炼用户负向兴趣。然而，在电子商务推荐系统中，用户显式负向行为极为稀少。根据我们的电子商务平台统计，不到 0.01% 的曝光会产生不喜欢，不到购买数量的十分之一。

在这种情况下，模型无法全面学习用户负向兴趣，用户也可能因看到过多相似推荐而感到疲劳。缓解用户疲劳的一种方法是在匹配阶段召回更多新物品，但通常不会立即奏效，因为大多数现有的点击率预测方法都不利于推荐用户此前未见过的物品。另一种常见的解决方案是探索与利用范式 [2,8]，它会考虑相关性、新颖性和疲劳等多个因素 [11,4]。然而，这类方法只是通过此前展示的相似物品数量等统计数据来建模用户疲劳，却忽略了相似推荐的时间频率分布，导致信息丢失。此外，用户兴趣与用户疲劳很可能会相互影响，因此探索与利用之间的权衡未必是最优选择。

基于这些观察，我们提出了一种新颖的点击率模型：疲劳感知网络（FAN），该模型能够从未点击 中更全面地感知用户疲劳，从而在点击率预测和用户方面均取得改进。

体验。自然地，我们认为用户疲劳应在类别层面进行建模，因为物品层面过于细粒度，而且电子商务推荐系统通常会避免推荐近期已推荐过的物品。给定一对用户和物品，我们提取近期相同类别的 未点击 记录，并统计每次推荐请求中该类别的数量，从而生成包含丰富用户疲劳信息的时间序列。随后，我们设计了疲劳表征模块（FRM），将快速傅里叶变换（FFT） [14] 应用于该时间序列，以获得其频谱，其中包含相似推荐的时间频率分布的综合信息。考虑到不同类别的疲劳上限和用户耐心度存在差异（$e.g.$、数字产品和服装），我们提出根据类别信息对频谱进行调制。此外，我们采用门控网络，根据用户活跃度对用户疲劳的置信度进行建模，并设计了一个辅助任务来指导FRM 的学习。通过这种方式，我们可以获得经过良好学习的疲劳表征。最后，我们将用户疲劳与用户兴趣结合起来，进行最终的点击率预测，从而避免过多的相似推荐并实现更准确的预测。我们的主要贡献总结如下：

– 我们研究了对电子商务推荐中的隐式用户负面行为（$i.e.$、未点击）进行建模的难点，并提出在点击率预测中显式建模用户疲劳，以避免用户看到过多相似推荐。– 我们提出了一种新颖的 FAN 模型，能够直接从未点击行为中感知用户疲劳。得益于频域表示和类别调制，我们能够全面且准确地建模用户疲劳。此外，通过精心设计的辅助任务，FAN能够充分关注用户不感兴趣的内容。– 在真实世界数据集上的实验表明，我们的 FAN模型优于具有代表性的方法，在线测试进一步表明，FAN 不仅提升了模型性能，也带来了更好的用户体验。我们还进行了广泛的分析，以验证我们在用户疲劳建模方面设计的有效性。代码已公开提供[1]。

2 提出的方法

2.1 模型输入

在点击率预测中，模型的输入为 $(\boldsymbol{x},\ y) \sim (X,\ Y)$，其中 $\boldsymbol{x}$ 是特征，$y \in \{0, 1\}$ 是点击标签。具体而言，本研究中的特征由五部分组成：1) 用户行为序列 $\boldsymbol{x}^{seq}$；2) 用户特征 $\boldsymbol{x}^{u}$，包括用户画像和用户统计特征；3) 物品特征 $\boldsymbol{x}^{i}$，例如物品 ID、类别、品牌及相关统计特征；4) 上下文特征 $\boldsymbol{x}^{c}$，例如位置和时间信息；5) 疲劳时间序列 $\boldsymbol{S}$, $i.e.$，即目标类别上未点击情况的统计序列，这是本研究首次提出的内容，后文将详细介绍。

[1] https://github.com/AaronPanXiaoFeng/FAN

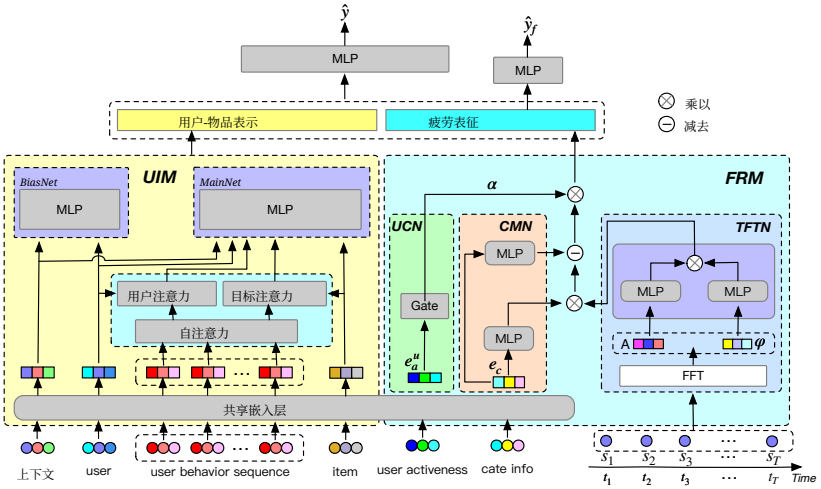


图 1. 所提出的疲劳感知网络（FAN）框架，由用户兴趣模块（UIM）和疲劳表征模块（FRM）组成。FRM 包含三个关键组件：时频变换网络（TFTN）、类目调制网络（CMN）和用户置信度网络（UCN）。

现在，我们描述疲劳时间序列的提取过程。给定一对用户和物品，我们首先检索该用户最近几天的推荐请求，并按时间排序。对于每个请求，我们计算与目标物品属于同一类别的未点击数量，得到时间序列 $\boldsymbol{S} = \{s_1, s_2, ..., s_T\}$，其中 s_T 表示第 T 个请求中目标类别的未点击数量，T 表示请求数。$\boldsymbol{S}$ 中的元素可视为时域中的疲劳原始指标。为了确保 $\boldsymbol{S}$ 与疲劳之间的相关性，我们在提取过程中针对特殊情况采用以下规则：1）如果第 i 个请求中目标类别有点击，我们将 s_i 设为 0，因为这与用户的正向兴趣更相关，对疲劳的影响较小；2）如果某个请求中没有目标类别的物品，我们就忽略该请求，因为它与目标疲劳无关。通过按请求粒度汇总未点击并按时间顺序整理统计数据，疲劳的原始信息更加可靠和全面。

2.2 用户兴趣模块

如图 1 所示，UIM 的输入特征由 $\boldsymbol{x}^u$、$\boldsymbol{x}^i$、$\boldsymbol{x}^c$ 和 $\boldsymbol{x}^{seq}$ 组成，详见第 2.1 节。这些特征可进一步分为两类：类别特征和数值特征。我们根据数值特征的边界值对其进行离散化，并将其转换为类别类型。随后，每个类别特征都编码为一个独热向量。鉴于独热编码具有稀疏性，我们进一步通过共享嵌入层对其进行处理，从而得到嵌入后的用户特征、物品特征、上下文特征和用户行为序列，即 $i.e.$、$\boldsymbol{e}^u$、$\boldsymbol{e}^i$、$\boldsymbol{e}^c$ 和 $\boldsymbol{e}^{seq} = \{\boldsymbol{e}^i_1, ..., \boldsymbol{e}^i_l\}$，其中 $\boldsymbol{e}^i_l$ 表示第 l 个用户行为对应的物品嵌入，l 表示序列长度。

对于用户行为序列，我们执行三种注意力计算。首先，对 $\boldsymbol{e}^{seq}$ 计算多头自注意力 [15]，从多个兴趣视角建模用户偏好，$\hat{}\boldsymbol{e}^{seq} = \{\hat{}\boldsymbol{e}^{i}_{1},..., \hat{}\boldsymbol{e}^{i}_{l}\}$ 为输出。其次，计算用户注意力 $\boldsymbol{a}^{u}$，通过让$\boldsymbol{e}^{u}$ 关注 $\hat{}\boldsymbol{e}^{seq}$来挖掘个性化信息。第三，采用目标注意力 $\boldsymbol{a}^{i}$，通过让 $\boldsymbol{e}^{i}$ 关注 $\hat{}\boldsymbol{e}^{seq}$来激活与目标物品相关的历史兴趣。为了保留原始信息以便进一步学习交互，我们将 $\boldsymbol{e}^{i}$、$\boldsymbol{e}^{u}$ 和 $\boldsymbol{e}^{c}$ 与 $\boldsymbol{a}^{u}$ 和 $\boldsymbol{a}^{i}$拼接，并将其输入 MainNet（$i.e.$，一个多层感知机（MLP））。同时，我们将 $\boldsymbol{e}^{u}$ 和 $\boldsymbol{e}^{c}$ 输入另一个多层感知机（$i.e.$，即 BiasNet），以建模不同用户在不同情境下通常会对相似物品表现出不同反应这一偏差。最后，将 MainNet 和 BiasNet 的输出拼接，得到用户-物品表示 $\boldsymbol{r}_{ui}$。

2.3 疲劳表示模块

时频变换网络。给定疲劳时间序列 $\boldsymbol{S}$，我们认为，与时域相比，在频域中对用户疲劳建模更有益，原因有二：**1)** $\boldsymbol{S}$ 仅包含每次请求中未点击的幅度信息，而在频域中，我们可以观察到每个频率分量的幅度（与幅值相关）和相位（与位置相关），这更有利于捕捉疲劳的周期性演变；2）在频域中，我们可以方便地区分不同频率分量的影响，从而进行更精细的建模。

受此启发，我们执行 N点快速傅里叶变换，将 $\boldsymbol{S}$ 转换到频域：

$$\begin{aligned} &\boldsymbol{A}, \boldsymbol{\varphi} = FFT(\boldsymbol{S}), \\ &\boldsymbol{A} = [A_1, ..., A_k, ..., A_N] \in \mathbb{R}^N, \\ &\boldsymbol{\varphi} = [\varphi_1, ..., \varphi_k, ..., \varphi_N] \in \mathbb{R}^N, \end{aligned} \tag{1}$$

其中，$\boldsymbol{A}$ 和 $\boldsymbol{\varphi}$ 分别是幅度向量和相位向量。

为自适应地捕捉不同频率分量的不同影响，并获得幅度和相位的高阶表示，我们分别将$\boldsymbol{A}$ 和 $\boldsymbol{\varphi}$ 输入两层多层感知机。然后，对结果执行逐元素乘法，以建模幅度与相位的交互，并获得组合表示：

$$\begin{aligned} \boldsymbol{A'} &= MLP_A(\boldsymbol{A}) \in \mathbb{R}^N, \\ \boldsymbol{\varphi'} &= MLP_\varphi(\boldsymbol{\varphi}) \in \mathbb{R}^N, \\ \boldsymbol{F} &= \boldsymbol{A'} \otimes \boldsymbol{\varphi'} \in \mathbb{R}^N, \end{aligned} \tag{2}$$

$\boldsymbol{F}$包含有关用户疲劳的全面信息，被视为原始疲劳表示。值得注意的是，MLP_A 和 MLP_φ 用于学习不同频率分量的影响并不相同。对于幅度，低频分量更稳健，而高频分量可能包含更多噪声，因此应予以衰减。对于

相位而言，低频分量比高频分量更重要，因为高频信号的位置对相位的敏感度低于低频信号的位置。

类目调制网络。直观地说，不同类别的疲劳上限和用户耐心度各不相同。受APG [23], 精神的启发，我们提出根据不同实例动态生成模型参数，这有助于捕捉定制化模式并增强模型能力。因此，我们可以针对不同类-别自适应地建模用户疲劳。具体而言，对于每个类别，我们将疲劳上限形式化为偏置向量 $\boldsymbol{b_c}$，将用户耐心度形式化为权重向量 $\boldsymbol{w_c}$，这两个向量分别由目标物品的类别信息生成：

$$\begin{aligned} \boldsymbol{b_c} &= MLP_b(\boldsymbol{e_c}) \in \mathbb{R}^N, \\ \boldsymbol{w_c} &= MLP_\alpha(\boldsymbol{e_c}) \in \mathbb{R}^N, \end{aligned} \tag{3}$$

其中， $\boldsymbol{e_c}$ 是类目特征的嵌入，包括类目ID及其对应的统计特征，这些特征可从物品特征 $\boldsymbol{x}^i$中获得。为了对我们的直觉进行建模，我们将原始疲劳表示 $\boldsymbol{F}$ 调制为：

$$\boldsymbol{F_c} = \boldsymbol{b_c} - \boldsymbol{w_c} \otimes \boldsymbol{F} \in \mathbb{R}^N, \tag{4}$$

与 $\boldsymbol{F}$ 相比， $\boldsymbol{F_c}$ 考虑了不同类别之间的疲劳差异，因此能够更准确地表示疲劳。

用户置信度网络。 显然，活跃度较高的用户会产生更多反馈，这使用户疲劳建模更有信心，反之亦然。因此，我们采用门控网络，根据用户活跃度对用户疲劳置信度进行建模。具体而言，我们将 $\boldsymbol{e_a^u}$（由用户特征 $\boldsymbol{x}^u$生成的用户活跃度嵌入）输入多层感知机，得到置信度因子$\boldsymbol{\alpha_u}$，随后对 $\boldsymbol{\alpha_u}$ 和 $\boldsymbol{F_c}$执行逐元素乘法，得到$i.e.$,

$$\begin{aligned} \boldsymbol{\alpha_u} &= MLP_u(\boldsymbol{e_a^u}) \in \mathbb{R}^N, \\ \boldsymbol{F_{uc}} &= \boldsymbol{\alpha_u} \otimes \boldsymbol{F_c} \in \mathbb{R}^N, \end{aligned} \tag{5}$$

通过上述操作，我们获得了经过微调的疲劳表征 $\boldsymbol{F_{uc}}$ ，它同时考虑了类别偏差和用户偏差。

2.4 训练

在UIM和FRM的基础上，用户-物品表示 $\boldsymbol{r_{ui}}$ 和疲劳表征 $\boldsymbol{F_{uc}}$ 通过拼接进行组合，并输入多层感知机，以生成最终的点击率预测：

$$\hat{y} = f_\theta(\boldsymbol{x}) = MLP_o(concat(\boldsymbol{r_{ui}}, \boldsymbol{F_{uc}})), \tag{6}$$

MLP_o 的最后一层使用$Sigmoid$ 作为激活函数，将预测结果映射为点击概率。我们采用广泛使用的对数损失作为主要损失函数，其计算方式如下：

$$L_m = -\frac{1}{|\mathcal{D}|} \sum_{(\boldsymbol{x},y)\in\mathcal{D}} (y \, log \, \hat{y} + (1-y) \, log(1-\hat{y})), \tag{7}$$

其中 $\mathcal{D}$ 表示训练集， $|\mathcal{D}|$ 表示 $\mathcal{D}$中的样本数量。

此外，为指导 FRM 的学习，我们设计了一个额外的辅助任务 $i.e.$，用于预测疲劳程度：

$$\hat{y}_f = MLP_f(\boldsymbol{F_{uc}}), \tag{8}$$

其中， $MLP_f(\cdot)$ 是一个 3 层的多层感知机，其最后一层使用 $Sigmoid$作为激活函数。为了为 $\hat{}y_f$ 找到一个可信的疲劳标签，我们将用户接下来三天内的用户行为纳入考虑。如果用户点击了目标类别，我们假设该用户没有被过度曝光，并将疲劳标签标记为负类。如果用户在一定次数的曝光后仍未点击目标类别，我们将疲劳标签标记为正类。其他情况下的训练集样本不用于疲劳预测任务。通过在适当的时间窗口内汇总用户行为，我们可以获得目标类别上相对稳定且可信的疲劳标签 y_f 。然后，我们计算$\hat{}y_f$ 与 y_f 之间的对数损失，并将最终损失表述如下：

$$\begin{aligned} L_f &= -\frac{1}{|\mathcal{D}|} \sum_{(\boldsymbol{x},y_f)\in\mathcal{D}} (y_f \, log \, \hat{y}_f + (1-y_f) \, log(1-\hat{y}_f)), \\ L &= L_m + \beta L_f. \end{aligned} \tag{9}$$

其中， β 是一个在训练过程中逐渐增大的缩放超参数，而 β 的最优最大值则通过实验确定。借助辅助损失 L_f，FRM 会被引导去关注用户不感兴趣的内容，从而更好地学习用户疲劳。

3 实验

3.1 实验设置

数据集。 我们收集并抽取了[2] 2022/08/24至2022/09/26期间手机天猫推荐场景中的在线服务日志，作为我们的实验数据集。随后，我们将数据划分为两个互不重叠的部分。2022/08/24至2022/09/25期间的数据用于训练，而2022/09/26的数据用于测试。表1总结了我们数据集的详细统计信息。

[2] 数据收集遵循应用的用户服务协议，并保护用户的个人信息。

8 M. Li 等人**表1**。 所建立数据集的统计信息。

#数据集	#用户	#物品	#曝光	#点击	#购买
训练集	9.40M	7.39M	835.76M	66.62M	277.22K
test	842.71K	2.70M	26.62M	2.15M	10.82K

评估指标。 离线对比中，我们使用ROC曲线下面积（AUC）作为评估指标。在线A/B测试中，我们使用$PCTR = p(click|impression)$和平均用户点击次数（IPV），这些指标广泛应用于工业推荐系统。此外，我们使用每用户曝光叶子类目数（LCEN）和每用户叶子类目点击数（LCCN）来衡量推荐多样性。

竞品。 作为点击率预测领域的代表性模型，**DIN** [26] 被选作基准模型。此外，我们将所提出的 FAN 模型的性能与一系列同时对点击 和非点击进行建模的最先进方法进行比较，$i.e.$、**DFN** [20], **DUMN** [3] 以及**Gama** [22]。此外，为了展示 FAN 中所设计结构的有效性，我们还进行了以下消融实验：

– **不含 FRM 的 FAN（UIM）**：作为 FAN 的子结构，UIM 通过添加预测层即可用作深度点击率模型，并采用注意力机制 [15]对用户正向行为序列进行建模。– **不含 TFTN 的 FAN**：为证明 TFTN 的必要性，我们移除 TFTN 模块，直接使用输入的疲劳时间序列。– **不含 CMN 的 FAN**：为了验证 FRM 中的类目调制网络（CMN）为 FAN 带来的增益，我们移除 CMN，并将 TFTN 的输出与 UCN 的输出进行逐元素乘积后直接处理。– **不含 UCN 的 FAN**：与不含 CMN 的 FAN 类似，我们通过从 FRM 中移除 UCN 来测试其性能。

实现细节。 除 DIN 忽略未点击 数据、DFN 和 DUMN 额外采用用户的显式负反馈外，所有模型使用相同的特征。所有模型均基于分布式 TensorFlow 1.4 实现，并使用 10 台参数服务器和 4 块 Nvidia Tesla V100 16GB GPU 进行训练。物品ID的嵌入维度为 64，类目ID和品牌ID的嵌入维度为 32，其他类别特征的嵌入维度为 8。我们在 UIM 中使用 8 头注意力结构，隐藏维度为 128；在 FRM 中使用 32 点快速傅里叶变换。训练时采用 Adagrad优化器，学习率为 0.01，小批量大小为 1024。在训练过程中，β 会随训练步数增加，从 0.01 线性递增至 0.5。我们报告各方法在经验上最优的超参数设置下取得的结果。

3.2 总体结果

对于离线评估，每个模型重复运行五次，并选取每个模型的最佳版本进行在线 A/B 测试，测试持续了 3 天，从2022年10月5日到2022年10月8日。离线和在线对比结果见表2，主要观察结果总结如下：

表2。 对比实验的离线和在线结果

模型	离线	在线增益			
	AUC（均值±标准差）	点击率	IPV	LCEN	LCCN
DIN(基准模型)	0.7178±0.00247	0.00%	0.00%	0.00%	0.00%
DFN	0.7194±0.00585	-0.30%	-0.31%	+0.85%	+0.53%
DUMN	0.7218±0.00429	+0.17%	-0.74%	+0.59%	+1.15%
Gama	0.7225±0.00472	+0.89%	+0.42%	-0.26%	+0.57%
FANw/o FRM(UIM)	0.7193±0.00238	-0.85%	+0.79%	+2.52%	+1.41%
FAN（本文模型）	**0.7249±0.00176**	**+1.63%**	**+1.09%**	**+11.13%**	**+3.29%**

1. 与 DIN 相比，UIM 模型在离线评估中表现更好。尽管 UIM 的点击率略低，但它能够推荐比 DIN 更丰富的类别并吸引更多 IPV，这表明我们对用户兴趣进行建模的设计是有效的。

2. DFN 和 DUMN 通过利用显式负反馈提炼隐式负反馈，在离线 AUC 指标上优于 DIN。然而，在电子商务中，用户的显式负反馈极其稀少，不足以全面学习用户负向兴趣。因此，DFN 和 DUMN 在在线推荐场景中表现不佳。

3. Gama 模型通过在频域对隐式负反馈进行去噪，在 AUC、点击率和 IPV 上略优于 DIN、DFN 和 DUMN。然而，它仍专注于建模用户感兴趣的内容，因此无法提升推荐多样性。在这种情况下，用户可能会过度接触太多相似推荐。

4. 无论在线还是离线，FAN 模型都取得了最佳表现。值得注意的是，FAN 不仅提升了在线流量（$i.e.$、点击率和 IPV）的效率，还显著提高了推荐多样性。得益于频域表示和类别调制，我们对疲劳的建模更加全面、准确，从而帮助用户避免看到太多相似推荐，并探索更多新物品。此外，通过精心设计的辅助任务，FAN 比 Gama 模型更加关注用户不感兴趣的内容。

3.3 消融研究

为展示 FAN 中所设计结构的有效性，我们还按照第3.1节的详细说明开展了一系列消融实验。结果详见表3。总体而言，从 FAN 中移除 FRM 或 FRM 的关键子结构会导致 AUC 下降，说明了我们模型设计的有效性。其他补充结论总结如下：

1. FAN w/o TFTN 与 FAN 的对比表明，TFTN 能够更好地利用疲劳时间序列。通过快速傅里叶变换提取频谱后，TFTN 进一步建模不同频率分量的不同影响，有助于学习更好的疲劳表征，以用于最终预测。

2. 移除CMN后，FANw/o CMN的性能出现了显著下-降，几乎与移除整个FRM相当。这一观-察证明了我们的直觉是正确的：不同类别的疲劳上限和用户耐心度上限各不相同，并证实了在建模用户疲劳时进行类别调制的必要性。

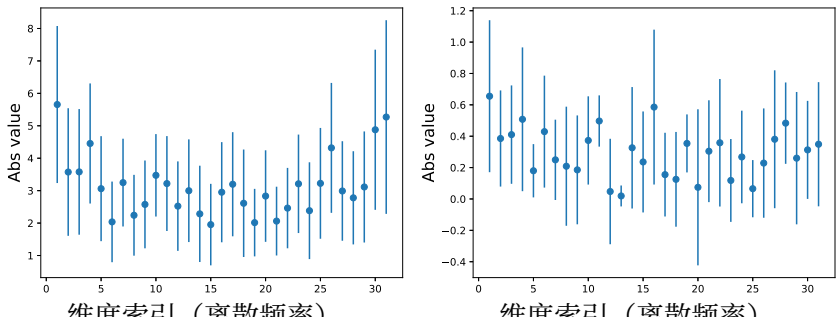
3. 将 FAN w/o UCN 与 FAN 进行比较，可以观察到 AUC 下降，这表明考虑用户置信度有助于学习疲劳表征。

表3. 消融实验的离线结果

模型	AUC（均值±标准差。）
FAN 不含 FRM(UIM)	0.7193±0.00238
不含TFTN的FAN	0.7225±0.00135
不含 CMN 的 FAN	0.7199±0.00147
不含 UCN 的 FAN	0.7237±0.00187
FAN	**0.7249±0.00176**

3.4 有效性分析

为了进一步分析TFTN和FRM的工作方式，我们将TFTN和FRM的输出进行可视化。具体而言，我们随机选择1000个样本并将其输入FAN，为每个样本提取 $\boldsymbol{F}$ 和 $\boldsymbol{F_{uc}}$。然后，我们分别绘制 $\boldsymbol{F}$ 和 $\boldsymbol{F_{uc}}$ 的均值和标准差图，如图2所示。由于FFT的对称特性，图2(a)呈现出近似对称的结构。不同维度之间的输出值差异很大。第6维和第15维附近的频率分量响应较弱，而其他频率分量的响应较高，这表明我们的TFTN在FRM中充当二阶带阻滤波器。从图2(b)中，我们可以观察到，对称结构不再存在，并且不同的频率分量得到进一步激活。这一观察结果表明，我们设计的CMN和UCN具备频率选择能力。此外，某些频率分量的标准差变大，而另一些变小，表明FRM进一步削弱了不重要的分量并增强了重要的分量。



(a) TFTN 输出put　　(b) FRM 输出put

图 2. TFTN 和 FRM 输出的均值和标准差

4 结论

在本文中，我们研究了对电子商务中的隐式用户负面行为（$i.e.$，未点击）进行建模的难点，并提出了一种名为FAN 的新模型，该模型从疲劳建模的角度捕捉目标类别中的用户负向兴趣。在 FAN 中，我们应用快速傅里叶变换（FFT）从相应的未点击序列中获取时频信息，然后在考虑类别偏差和用户置信度的情况下，利用这些信息学习高阶疲劳表征。此外，我们精心设计了一个辅助任务，以引导 FRM的学习。通过这种方式，可以学习高质量的疲劳表征，从而促进点击率和用户体验的提升；这一点已通过真实世界的离线数据集以及在线 A/B测试得到验证。大量分析进一步证实了我们模型设计的有效性。

参考文献

1. Ai, Z., Wang, S., Jia, S., Guo, S.：面向序列推荐的核心兴趣聚焦自注意力机制。载于：高级应用数据库系统。第306–314页。Springer International Publishing, Cham（2022） 2. Auer, P.：利用置信界处理利用与探索之间的权衡。《机器学习研究杂志》**3**（11月），397–422（2002） 3. Bian, Z., Zhou, S., Fu, H., Yang, Q., Sun, Z., Tang, J., Liu, G., Liu, K., Li, X.：用于推荐的去噪用户感知记忆网络。载于：第十五届 ACM 推荐系统大会。第400–410页（2021） 4. Cao, J., Sun, W., Shen, Z.J.M., Ettl, M.：面向依赖点击模型的疲劳感知老虎机算法。载于：AAAI 人工智能大会论文集。第34卷，第3341–3348页（2020） 5. Covington, P., Adams, J., Sargin, E.：用于 YouTube 推荐的深度神经网络。载于：第10届 ACM 推荐系统大会论文集。第191–198页（2016） 6. Gong, S., Zhu, K.Q.：正向、负向与中性：对基于会话的新闻推荐中的隐式反馈进行建模。arXiv 预印本 arXiv:2205.06058（2022） 7. Guo, H., Tang, R., Ye, Y., Li, Z., He, X.：DeepFM：一种基于因子分解机的点击率预测神经网络。arXiv 预印本 arXiv:1703.04247（2017） 8. Li, L., Chu, W., Langford, J., Schapire, R.E.：一种用于个性化新闻文章推荐的上下文老虎机方法。载于：第19届万维网国际会议论文集。第661–670页（2010） 9. Li, X., Wang, C., Tong, B., Tan, J., Zeng, X., Zhuang, T.：用于点击率预测的深度时间感知物品演化网络。载于：第29届 ACM 信息与知识管理国际会议论文集。第785–794页（2020） 10. Lv, F., Li, M., Guo, T., Yu, C., Sun, F., Jin, T., Ng, W.：XDM：利用用户未点击行为改进推荐系统的序列深度匹配。载于：高级应用数据库系统国际会议。第364–376页。Springer（2022） 11. Ma, H., Liu, X., Shen, Z.：在线新闻推荐中的用户疲劳。载于：第25届万维网国际会议论文集。第1363–1372页（2016）

12. Pan, X., Li, M., Zhang, J., Yu, K., Wen, H., Wang, L., Mao, C., Cao, B.：MetaCVR：通过元学习在小规模推荐场景中预测转化率。载于：第45届 ACM SIGIR 信息检索研究与发展国际会议论文集。第2110–2114页（2022） 13. Sarwar, B., Karypis, G., Konstan, J., Riedl, J.：基于物品的协同过滤推荐算法。载于：第10届万维网国际会议论文集。第285–295页（2001） 14. Soliman, S.S., Srinath, M.D.：连续与离散信号和系统。恩格尔伍德克利夫斯（1990） 15. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Ł., Polosukhin, I.：Attention Is All You Need。载于：神经信息处理系统进展。第5998–6008页（2017） 16. Wang, M., Gong, M., Zheng, X., Zhang, K.：对推荐中的隐式反馈动态缺失进行建模。《神经信息处理系统进展》**31**（2018） 17. Wen, H., Zhang, J., Wang, Y., Lv, F., Bao, W., Lin, Q., Yang, K.：通过点击后行为分解实现全空间多任务建模，用于转化率预测。载于：第43届 ACM SIGIR 信息检索研究与发展国际会议论文集。第2377–2386页（2020） 18. Wen, H., Yang, L., Estrin, D.：利用点击后反馈进行内容推荐。载于：第13届 ACM 推荐系统大会论文集。第278–286页（2019） 19. Wu, C., Wu, F., Qi, T., Liu, Q., Tian, X., Li, J., He, W., Huang, Y., Xie, X.：FeedRec：融合多种用户反馈的新闻推送推荐。载于：2022年 ACM Web 大会论文集。第2088–2097页（2022） 20. Xie, R., Ling, C., Wang, Y., Wang, R., Xia, F., Lin, L.：用于推荐的深度反馈网络。载于：第二十九届国际人工智能联合会议论文集。第2519–2525页（2021） 21. Xu, C., Peak, D., Prybutok, V.：移动应用推荐中的顾客价值、满意度与忠诚度视角。《决策支持系统》**79**，171–183（2015） 22. Xu, X., Fang, Z., Yu, Q., Huang, R., Fan, C., Li, Y., He, Y., Peng, C., Lin, Z., Shao, J., 等：用于点击率预测曝光序列建模的门控适配小波多分辨率分析。载于：第45届 ACM SIGIR 信息检索研究与发展国际会议论文集。第1890–1894页（2022） 23. Yan, B., Wang, P., Zhang, K., Li, F., Deng, H., Xu, J., Zheng, B.：APG：用于点击率预测的自适应参数生成网络。载于：神经信息处理系统进展（2022） 24. Zhang, J., Tao, D.：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），7789–7817（2020） 25. Zhao, Q., Harper, F.M., Adomavicius, G., Konstan, J.A.：显式反馈还是隐式反馈？参与度还是满意度？一项关于基于机器学习的推荐系统的实地实验。载于：第33届 ACM 应用计算年会论文集。第1331–1340页（2018） 26. Zhou, G., Zhu, X., Song, C., Fan, Y., Zhu, H., Ma, X., Yan, Y., Jin, J., Li, H., Gai, K.：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。第1059–1068页（2018）