

电商CTR预测技术演进与营销应用实践研究

刘颖琪, 赵金波

贵州大学大数据与信息工程学院, 贵州 贵阳

收稿日期: 2025年9月22日; 录用日期: 2025年10月10日; 发布日期: 2025年11月11日

摘要

点击率(CTR)预测是电子商务平台实现智能营销的关键技术, 广泛应用于广告投放、商品推荐和用户行为分析等核心场景。随着线上交易规模扩大, 精准、高效的CTR预测模型成为提升用户体验与平台收益的重要工具。本文围绕CTR预测在电商中的实际价值, 梳理其演进路径与主流方法, 重点探讨其在提升广告转化率、优化资源配置与构建用户画像中的应用成效, 并展望了个性化、可解释预测模型在未来电商智能营销中的发展方向。

关键词

点击率预测, 电子商务营销, 深度学习模型

A Study on the Evolution and Marketing Applications of CTR Prediction in E-Commerce

Yingqi Liu, Jinbo Zhao

School of Big Data and Information Engineering, Guizhou University, Guiyang Guizhou

Received: September 22, 2025; accepted: October 10, 2025; published: November 11, 2025

Abstract

Click-Through Rate (CTR) prediction is a key technology for intelligent marketing on e-commerce platforms, widely applied in core scenarios such as advertising delivery, product recommendation, and user behavior analysis. As the scale of online transactions expands, accurate and efficient CTR prediction models have become essential tools for enhancing user experience and increasing platform revenue. This paper focuses on the practical value of CTR prediction in e-commerce, reviews its development trajectory and mainstream methods, and highlights its effectiveness in improving

ad conversion rates, optimizing resource allocation, and constructing user profiles. Furthermore, it explores the future direction of personalized and interpretable prediction models in the context of intelligent e-commerce marketing.

Keywords

Click-Through Rate Prediction, E-Commerce Marketing, Deep Learning Models

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在数字经济持续深化的背景下,电子商务平台已成为连接商品、用户与数据的核心载体,而数字广告作为其流量变现和品牌建设的关键手段,正以前所未有的速度演进。根据艾瑞咨询发布的《2023 年中国互联网广告市场年度报告》显示,2022 年我国互联网广告市场规模首次突破万亿元大关,其中电商广告占比高达 40%,稳居各类广告投放场景之首[1]。这一趋势不仅彰显了电商广告对平台收益的战略价值,也对其投放效率与营销效能提出了更高要求。

随着广告数量激增和用户注意力碎片化趋势加剧,传统依赖规则配置与人工经验的广告投放方式已难以满足高效转化与精准触达的目标。广告点击率(Click-Through Rate, CTR)作为衡量广告吸引力与用户互动意愿的核心指标,在营销链路中扮演着预测用户行为、辅助决策投放、衡量广告价值等多重角色。CTR 的准确预测不仅直接影响广告曝光后的点击行为,还关系到平台的资源调度、广告主的预算分配以及整体 ROI 的优化水平[2]。

然而,CTR 预测作为一项典型的用户行为建模任务,面临着显著的挑战:其一,用户行为存在强烈的个体差异性与时效波动性,模型需具备高度的动态建模能力;其二,广告数据通常呈现出高维稀疏性与复杂交互结构,如广告 ID、上下文位置、关键词、设备类型等类别特征对预测能力构成挑战;其三,在冷启动场景下,新用户与新广告的缺乏历史行为数据将严重影响预测精度,成为当前实际应用中的难点问题[3]。

为应对上述挑战,近年来以大数据与深度学习为核心的建模范式不断取得突破。在深度模型的驱动下,CTR 预测方法从最初的逻辑回归、GBDT 等浅层模型,逐步发展为融合特征嵌入、注意力机制、兴趣建模和图神经网络等结构的复杂模型体系。例如, Wide & Deep 模型有效融合了线性与非线性特征, DeepFM 模型自动学习高阶特征交互关系, DIN 模型则首次引入兴趣激活机制以挖掘用户对特定广告的动态兴趣[4] [5]。这些方法的持续优化不仅提升了 CTR 预测的精度,也极大地推动了电商平台从“粗放式流量运营”走向“智能化精准营销”的转型。

在此背景下,本文聚焦于 CTR 预测技术在电商广告营销中的价值应用,系统梳理主流建模方法及其发展脉络,剖析其在广告投放、内容优化、用户运营等环节的应用逻辑,进而探讨如何借助 CTR 预测构建数据驱动的营销优化路径。

2. CTR 预测技术与电商营销应用研究

广告点击率预测作为电商平台广告系统的核心技术之一,旨在根据用户行为、广告内容及上下文环境等多维信息,预测用户点击广告的概率。随着大数据和人工智能的发展,CTR 预测方法不断演进,整

体呈现出从浅层建模到深度学习、从单一特征到多模态融合的趋势。在此基础上, CTR 预测也逐步成为广告精准投放与智能营销的基础支撑。

2.1. CTR 预测方法的演进路径

1. 浅层模型阶段: 特征工程驱动的早期实践

在电商广告系统的初期建设阶段, CTR 预测大多依赖逻辑回归(Logistic Regression, LR)等线性模型。这类方法通过人工构造特征(如用户年龄、性别、地理位置与广告类目等)来建立点击概率模型, 具有实现简单、可解释性强的优势, 至今仍作为工业部署中的基线模型广泛应用[6]。

为克服线性模型对非线性交互特征表达能力的不足, 研究者提出了因子分解机(Factorization Machines, FM)和梯度提升树(Gradient Boosting Decision Trees, GBDT)等方法, 用于自动学习二阶甚至高阶特征组合关系, 从而提升模型表现[7]。但此类方法仍高度依赖复杂的特征工程, 对高维稀疏数据处理能力有限, 难以适应用户兴趣动态演化与广告语义理解的需求。

2. 深度学习驱动的创新

随着深度学习在推荐系统中的广泛应用, CTR 预测方法也迎来了结构性变革。谷歌提出的 Wide & Deep 模型首次将线性模型与深层神经网络融合, 实现了记忆性(memorization)与泛化性(generalization)的兼顾[4]。此后, DeepFM、DCN (Deep & Cross Network)、AutoInt 等模型相继涌现, 摆脱了对人工特征组合的依赖, 在预测精度与表达能力上取得显著提升[5]。

特别地, 阿里提出的 DIN (Deep Interest Network)模型引入了注意力机制, 根据上下文动态加权用户历史行为, 实现了对兴趣偏好的个性化捕捉, 有效提升了模型的用户匹配能力[2]。

3. 融合趋势与实际挑战并存

近年来, CTR 预测呈现出以下几大发展趋势:

(1) 多模态融合: 将图像、文本、语音等非结构化广告内容与用户行为、上下文数据进行融合学习, 提升模型对广告语义的理解能力;

(2) 序列建模强化用户兴趣动态跟踪: 借助 Transformer 等结构对长行为序列建模, 实现对用户兴趣演变的精细捕捉;

(3) 轻量化部署与在线更新能力提升: 为适应平台的高并发与实时反馈需求, 模型压缩、蒸馏与在线学习策略不断演进;

(4) 冷启动与可解释性问题的探索: 新广告、新用户带来的冷启动问题依旧严峻, 模型决策过程透明化亦成为工业落地的重要方向[8] [9]。

为更系统地总结不同 CTR 预测模型的特点与适用场景, 表 1 对典型模型在特征交互方式、序列建模能力、优缺点及工业应用情况进行了综合比较。这一对比有助于直观理解 CTR 预测技术从浅层线性模型向深度结构化与多模态方向的演进逻辑。

综上所述, CTR 预测模型的发展呈现出从线性记忆向深度非线性学习、从静态特征向动态兴趣建模的演进趋势。随着广告内容多样化与用户行为复杂化, 多模态特征融合、序列建模及可解释性优化将成为未来 CTR 模型的重要研究方向。

2.2. CTR 预测对电商营销链路的赋能路径

CTR 预测的意义远不止于“是否点击”的技术判断, 更是在营销全链路中扮演着决策引擎的角色。从人群筛选、预算分配, 到内容设计与效果复盘, 其价值贯穿营销生命周期。

(1) 助力精准人群匹配与用户画像构建

Table 1. Comparison of different CTR prediction models
表 1. 不同 CTR 预测模型的比较

模型名称	核心结构	特征交互机制	序列建模能力	优点	局限性	代表应用
LR	线性回归	无	不支持	简单高效, 易部署	表达能力弱, 难捕捉非线性	早期 CTR 预测基线
FM	因子分解	二阶特征交互	不支持	适用于高维稀疏特征	高阶表达力不足	推荐系统特征建模
GBDT	决策树集成	非线性组合 (隐式)	部分支持	可解释性强, 适用于特征选择	对稀疏特征支持差	特征工程辅助工具
DCNv2	CrossNet + DNN	显式高阶交叉结构	不支持	强特征组合能力, 工业落地成熟	依赖结构静态特征	Facebook 广告排序
AutoInt	自注意力结构 + Embedding 交互	多阶交互建模	不支持	能自动学习复杂交叉特征	无行为序列建模能力	多行业 CTR 预测模型
GraphCTR/ Fi-GNN	图神经网络	基于图结构交互	部分支持	可建模用户 - 广告图谱关系	构图开销大, 部署复杂	TikTok 广告推荐
SASRec-based CTR	Transformer 结构 (含自注意力)	全局交互	支持	序列建模, 多模态兼容	推理成本高, 部署需优化	Amazon 广告排序
Self-Supervised CTR	对比/预训练	隐式特征关联	支持	缓解冷启动、泛化能力强	训练复杂, 标签依赖弱化	冷启动推荐 / 新广告
Causal CTR	因果推理 + 反事实建模	减少混杂因素干扰	部分支持	去偏能力强, 结果更可靠	需假设建模与额外数据	精准营销 归因优化

CTR 模型通过对用户历史点击数据的建模, 提炼兴趣关键词、上下文偏好等隐性特征, 进而实现更精细的个性化广告推送。在实时竞价(RTB)系统中, 高 CTR 用户被优先匹配高价值广告, 从而显著提升点击率与转化效果[10]。

与此同时, CTR 预测结果还能动态更新用户标签体系, 支持推荐算法的不断演化, 提高用户体验与平台粘性。

(2) 支撑广告预算优化与 ROI 管理

对于广告主而言, 如何在预算有限条件下实现转化最大化, 是长期关注的问题。CTR 预测通过对广告曝光价值的前瞻性评估, 支持平台设定更精细的出价机制与曝光频控策略, 从而优化资源分配路径。研究指出, CTR 与 CVR (转化率)联合建模的“双塔结构”在预测用户全路径行为方面优势显著, 有助于实现从点击到购买的收益最大化[11]。

(3) 反哺创意设计与 A/B 测试决策

CTR 不仅是衡量效果的指标, 也可用于优化内容本身。例如, 不同标题措辞、图文组合与颜色风格对 CTR 的影响可通过模型判别与对比得出。研究显示, 品牌词在广告标题中的位置显著影响用户点击倾向。通过 CTR 预测模型与 A/B 测试联动, 平台可实现快速内容试验与优化, 推动从“经验决策”向“数据驱动”转型。

(4) 推动营销场景智能化与系统联动

CTR 预测在平台营销系统中具备高度的通用性, 已被广泛嵌入会员召回、促销推送、品牌传播、视频推荐等场景。例如, 在大促节期间, 系统可依据用户在促销广告中的 CTR 响应筛选高潜用户, 实现营销资源的精细投放。同时, CTR 预测结果也成为营销复盘与效能分析的重要参考指标, 支撑完整的闭环管理[12]。

3. 研究方法与设计

在数字营销日益智能化的背景下, 电商平台对广告点击率预测的依赖日益增强。CTR 预测不仅是广告排序的核心技术, 更是支撑广告竞价、预算分配、内容创意优化等营销活动的基础。鉴于本文不进行实验验证, 第三章旨在构建一种面向电商实际应用场景的 CTR 预测理论框架, 系统梳理其特征工程、模型架构以及营销业务的协同逻辑, 为后续系统优化与商业实践提供可行性方案与策略支撑。

3.1. 数据建模框架与问题定义

CTR 预测可被抽象为一个典型的二分类问题, 即判断用户是否会点击展示的某条广告。该问题的核心在于如何从用户-广告交互行为中挖掘潜在的点击意愿, 而这离不开对高维、稀疏、动态的多源数据的有效建模。根据行业实践, CTR 预测主要依赖以下三类特征:

(1) 用户侧特征: 涵盖用户的基础属性(性别、年龄、地域等)与行为特征(历史点击、浏览路径、购买记录等), 用于刻画其潜在兴趣与偏好。

(2) 广告侧特征: 包括广告 ID、类目、关键词、创意样式、投放渠道等, 决定了广告本身的吸引力与适配性。

(3) 上下文环境特征: 如时间戳、设备类型、地理位置、网络状态等, 用于反映用户所处的交互情境。

这些特征之间往往存在复杂的非线性交互关系, 传统的线性模型难以有效捕捉。因此, 基于深度学习的高层次建模方式成为趋势, 其关键在于通过端到端学习, 构建特征表达与点击行为之间的隐含映射关系。

3.2. 特征工程思路

在 CTR 建模中, 尽管深度模型能够自动学习特征表示, 但合理的特征处理策略依然是模型效果的重要保障, 尤其在数据预处理与结构编码环节。

(1) 类别特征嵌入: 电商广告数据中存在大量类别型变量, 如用户 ID、广告 ID、商品类目等。通过 Embedding 技术, 将其映射为低维稠密向量, 有助于捕捉共现关系与语义相似性。

(2) 连续特征归一与分桶: 对于点击频率、停留时长等连续特征, 采用 Min-Max 归一化或分段离散 (Bucketization) 方式进行编码, 以提升模型的非线性表达能力。

(3) 行为序列特征: 用户历史行为具有序列性与上下文依赖, 需借助滑动窗口或 RNN/Transformer 等机制提取兴趣演化轨迹, 例如构建“最近 N 次浏览商品”序列, 辅助模型理解当前意图。

近年来, 随着 AutoML 与自监督学习的发展, 研究者也开始探索特征自动构造与压缩, 以减少人工干预, 提升特征表达的泛化能力与可移植性。

3.3. 主流深度 CTR 模型分析

CTR 预测模型经历了从线性回归到深度神经网络的演进过程。以下列举三种在电商领域具有代表性的结构:

(1) Wide & Deep 模型

该模型由 Google 提出, 创新性地融合了“Wide”(线性记忆特征)与“Deep”(深层非线性交互)两个子结构。其中, Wide 部分处理手工构造的组合特征, 如用户与广告的交互项; Deep 部分利用神经网络学习高阶隐含特征。此结构兼顾记忆能力与泛化能力, 适用于用户行为历史丰富且广告样本多样的场景[4]。

(2) DeepFM 模型

DeepFM 在结构上将 FM 与 DNN 进行集成, 并通过共享 Embedding 层实现端到端训练。该设计无需

显式构造交叉特征, 便能高效建模高维稀疏输入, 尤其适用于电商平台复杂的广告-用户匹配任务。其在工业实践中的表现稳定, 已广泛部署于阿里、腾讯、字节跳动等平台[5]。

(3) DIN 模型

DIN 由阿里巴巴提出, 突破性地引入了注意力机制, 使模型能够对用户历史行为序列进行加权建模。与传统模型仅进行特征“累加”不同, DIN 强调广告当前内容与历史行为的“匹配度”, 在动态兴趣捕捉方面具有显著优势, 是实现“个性化推荐广告”的关键模型之一[2]。

3.4. CTR 预测与电商投放的协同机制

CTR 预测并非孤立的技术任务, 其核心价值体现在对广告投放策略的赋能上。基于 CTR 模型的预测结果, 电商平台可实现如下协同优化逻辑:

(1) 广告展现排序优化: 将高 CTR 广告优先展示, 提升整体点击效率与平台收益。

(2) 用户定向与人群管理: 通过 CTR 得分将广告推送给潜在点击意愿强烈的用户, 实现高精度投放。

(3) 预算控制与竞价策略: 结合 eCPM (预期千次展示收益) 计算公式, 基于 CTR 动态调整出价, 提高 ROI。

(4) 创意内容 A/B 测试: 基于 CTR 波动数据, 平台可识别哪些文案、图片、位置设计更具吸引力, 辅助内容优化迭代。

(5) 营销链路拓展: 结合 CVR 预测, 构建从点击到成交的完整优化闭环, 增强营销全链条智能化能力[13]。

4. 营销优化策略与商业实践路径

在数据驱动日益成为营销主流逻辑的今天, CTR 预测模型不仅是广告点击行为的量化工具, 更是联动用户洞察、广告内容创意、流量资源配置与品牌运营策略的关键技术支点。电商平台正借助高性能 CTR 预测模型, 在广告精准投放、内容迭代、用户管理与 ROI (投资回报率) 提升等多个环节实现营销效能跃升。

本章旨在系统梳理 CTR 预测模型在实际营销中的应用路径, 从投放机制优化、内容生成策略、用户分层触达, 到闭环营销系统构建, 全面揭示该类模型对商业决策的赋能潜力。

4.1. 广告投放效率优化

CTR 预测模型通过“点击可能性”的量化估计, 为广告投放策略注入数据逻辑, 使电商平台从“经验驱动”向“算法驱动”成功转型:

(1) 曝光排序机制优化: 借助 CTR 预测结果对候选广告进行得分排序, 系统优先展示预估点击概率高的广告, 提升单位展示价值。

(2) 人群定向精准化: 模型融合用户历史浏览、点击轨迹、兴趣标签等特征, 有效支持 Lookalike 人群扩展、兴趣圈层筛选, 降低投放冗余。

(3) RTB 竞价逻辑增强: CTR 作为 eCPM (Effective Cost Per Mille) 的关键组成, 可指导实时竞价出价策略, 提高出价效率与回报率。

(4) 点击后链路延伸: 越来越多平台采用“双塔模型”(CTR + CVR) 协同预测, 不仅关注点击概率, 还对转化率进行建模, 实现从曝光到点击再到转化的闭环链路优化。

这一阶段的优化体现了 CTR 模型在媒体资源调度与商业资源配置中的基础支撑作用。

4.2. 广告内容与创意策略的智能演化

CTR 不仅反映用户兴趣, 还能成为评估创意表现力与市场反馈的重要指标, 是广告内容生产的重要

闭环变量。

- (1) 创意要素量化分析：通过 CTR 模型对不同关键词组合、广告图像风格、颜色布局等影响因素进行量化反馈，有助于平台提取“高转化因子”，指导后续内容设计。
 - (2) 嵌入式 A/B 测试与优化：CTR 模型可与广告平台的 A/B 实验系统集成，实时跟踪各类创意版本的效果变化，快速收敛于最优内容路径。
 - (3) 支持多模态内容协同建模：面对短视频、动图、图文融合等内容形式，CTR 模型逐步扩展至多模态建模维度，结合图像卷积网络(CNN)与文本嵌入技术，实现语义理解与场景适配[8]。
- 这使广告创意生成从“经验主义”跃迁至“数据指导”的科学路径，显著提升创意 ROI 与用户共鸣强度。

4.3. 用户分层运营与精准触达路径

- CTR 模型在用户维度的深入建模，也为运营策略提供了细粒度支持，推动用户生命周期管理体系的精细化：
- (1) 用户价值分层管理：基于历史 CTR 分布与点击行为趋势，平台可构建“高潜力”“高响应”“沉默流失”等用户画像，支持差异化内容推荐。
 - (2) 会员沉默召回策略设计：针对 CTR 下降明显的沉默用户，通过再唤醒类广告定向推送，实现“挽回式营销”操作路径。
 - (3) 兴趣驱动的推荐融合：CTR 预测结果可作为协同过滤、DSSM、Transformer 等推荐系统算法的重要输入变量，实现“内容 + 人群”融合推荐逻辑[7]。
- 该路径构建出一种面向用户全生命周期的可持续营销管理方案，特别适用于私域运营和平台会员体系的优化设计。

4.4. 营销全流程的闭环构建

CTR 模型作为电商广告系统的核心组件，已从前端点击预测，扩展至营销系统全流程的价值闭环构建(表 2)：

Table 2. The mechanism of CTR prediction technology in e-commerce marketing
表 2. CTR 预测技术在电商营销环节中的作用机制

环节	CTR 预测作用机制
广告曝光	排序广告优先级、提升展示效果
转化行为	联合 CVR 模型分析转化链路、提高 ROI
内容创意	辅助 A/B 测试与内容选择、支撑创意策略方向
用户运营	精准触达目标人群、实现多渠道联动营销
效果评估	提供关键指标支撑，作为营销活动成效的核心评价维度

- 因此，为保障 CTR 模型在复杂商业环境中的高效落地，企业可从以下三个方向入手：
- (1) 模型管理体系建设：建立离线与在线模型版本控制与评估机制，确保模型更新的连续性与可追溯性；
 - (2) 业务协同机制：在广告投放、用户增长、内容运营部门间建立 CTR 指标共识，使模型预测结果与业务目标紧密对齐；
 - (3) 效果监测与反馈闭环：构建 CTR-CVR-ROI 全链路指标体系，利用 A/B 实验与实时监控仪表盘

持续优化策略。

4.5. 多模型协同优化的 CTR 预测实践分析

在电商平台的实际营销场景中, CTR 预测模型通常以多模型协同的方式运行, 以同时满足不同业务环节的需求。以下内容基于公开文献与工业界技术报告的总结, 展示了典型电商平台在大规模广告投放场景下的模型协同实践路径与经验。

首先, 在主流广告推荐系统中, 主流 CTR 模型多采用阿里巴巴提出的 Deep Interest Network (DIN)。该模型通过引入自注意力结构, 对用户的历史行为序列进行加权建模, 从而提升了用户兴趣匹配精度。根据 KDD 2018 的报告, DIN 模型在实际广告排序任务中相较于传统 DeepFM 模型的 CTR 提升约 10%~20%, 显著改善了推荐结果的相关性与用户响应率[2]。

其次, 为解决冷启动问题, 部分平台引入了基于 Meta-Learning 的嵌入层微调机制。该机制在多任务学习框架下通过任务迁移实现对新广告或新用户的快速适应。研究表明, 该方法在 CTR 预测任务中能够显著提升泛化性能; 在公开数据集上, 相关模型的预测误差下降约 5%~12%, 表现出良好的迁移与稳定性[14] [15]。

此外, 为了进一步实现收益最大化, 平台广告出价与分发环节通常结合多目标实时优化(Multi-Objective Optimization, MOO)模块, 对 CTR、CVR 与 ROI 等多维指标进行联合建模与动态权衡。根据 KDD 2020 的研究与工业实验结果, 此类优化策略可带来 ROI 提升约 10%~15%, 并有效平衡点击率与商业转化目标之间的冲突[16]。

综上所述, 当前主流电商平台的 CTR 预测体系逐渐形成了以“主力行为建模 + 冷启动优化 + 多目标收益调控”为核心的多模型协同架构。这种体系不仅提高了广告投放的精准性与资源利用效率, 也反映出 CTR 预测技术从单点建模向全链路优化、从算法驱动向策略驱动的演进趋势。

4.6. 未来商业实践的拓展路径

在电商广告进入高度竞争与碎片化阶段后, CTR 预测的商业化路径将进一步延展至以下方向:

- (1) 多模态广告理解: 融合图文、视频、语音等多源数据进行 CTR 预测, 提升语义匹配深度;
- (2) 因人而异的兴趣建模: 引入强化学习、图神经网络等机制, 更准确建模兴趣演化路径;
- (3) 实时反馈闭环: 结合流式计算和在线学习, 动态调整投放策略, 提升实时响应能力;
- (4) 隐私保护与模型合规性: 构建联邦学习机制, 在保障用户隐私的前提下持续优化 CTR 模型。

这些趋势标志着 CTR 预测将不再局限于技术手段, 而成为平台商业智能的核心驱动力。

5. 结语

在电商平台迈向精细化运营的背景下, CTR 预测已完成从规则驱动到数据驱动、再到智能进化的演变过程。基于深度学习的 CTR 模型不断突破建模瓶颈, 从静态特征学习迈向序列建模、跨模态理解与实时反馈优化, 推动了广告系统从“曝光优先”走向“兴趣优先”和“价值优先”的变革。

总而言之, CTR 预测将不再仅是“预测点击概率”的算法任务, 而是成为驱动电商平台战略决策、用户体验升级与商业价值释放的底层能力支撑。未来, 在智能化营销持续深化的背景下, CTR 模型将在电商生态中扮演愈加重要的角色, 助力企业实现从“量的竞争”向“质的跃升”的转型目标。

参考文献

- [1] 艾瑞咨询. 2023 年中国互联网广告市场年度报告[EB/OL]. <https://report.iresearch.cn>, 2025-09-01.

- [2] Zhou, G., Zhu, X., Song, C., Fan, Y., Zhu, H., Ma, X., *et al.* (2018) Deep Interest Network for Click-Through Rate Prediction. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, London, 19-23 August 2018, 1059-1068. <https://doi.org/10.1145/3219819.3219823>
- [3] Qu, Y.R., Cai, H., Ren, K., Zhang, W.N., *et al.* (2016) Product-Based Neural Networks for User Response Prediction. 2016 *IEEE 16th International Conference on Data Mining (ICDM)*, Barcelona, 12-15 December 2016, 1149-1154. <https://doi.org/10.1109/icdm.2016.0151>
- [4] Cheng, H.T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., *et al.* (2016) Wide & Deep Learning for Recommender Systems. *Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*, Boston, 15 September 2016, 7-10. <https://doi.org/10.1145/2988450.2988454>
- [5] Guo, H., Tang, R., Ye, Y., Li, Z. and He, X. (2017). DeepFM: A Factorization-Machine Based Neural Network for CTR Prediction. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*, Melbourne, 19-25 August 2017, 1725-1731. <https://doi.org/10.24963/ijcai.2017/239>
- [6] 周雄伟, 王晓煜, 李翠. 品牌词位置对消费者点击行为的影响——基于唯品会折扣广告的经验研究[J]. 管理评论, 2025, 37(5): 121-132.
- [7] 张林. 融合注意力机制和用户行为数据的点击率预测方法研究[D]: [硕士学位论文]. 济南: 山东师范大学, 2024.
- [8] 闫芳. 生成式多模态 AI 在电商智能营销中的融合应用与效能评估[J]. 营销界, 2025(10): 19-21.
- [9] 龚雪鸾, 陈艳姣, 王帅. 在线广告点击率预测方法的研究综述[J]. 中文信息学报, 2023, 37(4): 1-17.
- [10] 程小宝. 基于多头双线性特征融合的点击率预测模型研究[D]: [硕士学位论文]. 合肥: 安徽建筑大学, 2025.
- [11] He, X., Pan, J., Jin, O., Xu, T., Liu, B., Xu, T., *et al.* (2014). Practical Lessons from Predicting Clicks on Ads at Facebook. *Proceedings of the Eighth International Workshop on Data Mining for Online Advertising*, New York, 24-27 August 2014, 1-9. <https://doi.org/10.1145/2648584.2648589>
- [12] 朱嘉方. 使用包含特定用途的关键词对广告点击率的影响分析[J]. 现代营销, 2025(6): 62-64.
- [13] Wang, R., Shivanna, R., Cheng, D., Jain, S., Lin, D., Hong, L., *et al.* (2021) DCN V2: Improved Deep & Cross Network and Practical Lessons for Web-Scale Learning to Rank Systems. *Proceedings of the Web Conference 2021*, Ljubljana Slovenia, 19-23 April 2021, 1785-1797. <https://doi.org/10.1145/3442381.3450078>
- [14] Jin, J., Song, C., Li, H., Gai, K., Wang, J. and Zhang, W. (2018) Real-Time Bidding with Multi-Agent Reinforcement Learning in Display Advertising. *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*, Torino, 22-26 October 2018, 2193-2201. <https://doi.org/10.1145/3269206.3272021>
- [15] Pan, F., Li, S., Ao, X., Tang, P. and He, Q. (2019) Warm Up Cold-Start Advertisements: Improving CTR Predictions via Learning to Learn ID Embeddings. *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, Paris, 21-25 July 2019, 695-704. <https://doi.org/10.1145/3331184.3331268>
- [16] Liu, B., Wang, Y., Li, Z., *et al.* (2020) Real-Time Bidding with Multi-Objective Optimization in E-Commerce Advertising Systems. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, California, 23-27 August 2020, 3434-3442.