

# 人工智能在电子商务个性化推荐系统中的应用与优化

赵伟

(安徽中澳科技职业学院 安徽合肥 230041)

**摘要:** 随着电子商务的快速发展和人工智能技术的不断进步,个性化推荐系统已成为提升用户购物体验和平台运营效率的关键技术。本文深入分析了人工智能在电子商务个性化推荐系统中的应用现状,探讨了深度学习、强化学习等先进算法在推荐系统中的具体应用方案,并针对现有系统存在的问题提出了优化方案。研究表明,基于人工智能的个性化推荐系统能够显著提高推荐准确率和用户满意度,同时在计算效率、实时性等方面具有明显优势。

**关键词:** 人工智能; 电子商务; 个性化推荐系统; 应用; 优化

**引言:** 电子商务的蓬勃发展带来了海量商品信息,如何帮助用户快速找到所需商品,提供个性化的购物体验,已成为各大电商平台面临的重要挑战。传统的推荐方法往往难以准确把握用户需求的动态变化,且在处理海量数据时存在效率瓶颈。随着人工智能技术的快速发展,特别是深度学习、强化学习等先进算法的成熟应用,为解决这些问题提供了新的技术路径。

## 一、电子商务推荐系统的发展现状

### 1、传统推荐系统的局限性

传统的电商推荐系统尽管在实践应用中取得了一些成效,但其固有的局限性日益凸显。由于用户与商品之间的交互数据往往呈现出高度稀疏的特点,这直接影响了推荐结果的准确性和可靠性。同时,当系统面对新注册用户或新上架商品时,由于缺乏足够的历史行为数据作为支撑,难以做出准确的推荐判断。此外,在处理海量数据时,传统推荐算法的计算效率普遍较低,难以满足电商平台对实时推荐的迫切需求。而在特征表达方面,传统算法也难以深入挖掘用户行为特征与商品特征之间存在的潜在关联关系,因此往往无法准确把握用户的真实需求和兴趣偏好,从而影响推荐的精准度和用户体验。

### 2、人工智能技术的应用优势

随着人工智能技术的快速发展,其在推荐系统领域展现出显著的应用优势和巨大潜力。通过运用深度学习模型,系统能够自动学习和提取特征表示,这极大地提升了特征提取的能力和效果。而端到端的学习方式则可以实现推荐流程的整体优化,有效提高系统运行效率。通过引入强化学习方法,推荐系统能够持续追踪和适应用户兴趣的动态变化,从而在长期推荐效果上取得明显改善。另外,迁移学习技术的应用为解决新用户冷启动问题提供了有效途径,能够快速构建起用户画像,显著提升推荐系统的实用性和准确性,为用户提供更加个性化和精准

的推荐服务。

## 二、关键技术与算法实现

### 1、深度学习在推荐系统中的应用

#### 1.1 深度神经网络模型

##### 1.1.1 多层感知机

多层感知机作为深度学习中最基础的网络结构,在推荐系统中发挥着重要作用。它通过多个隐藏层的非线性变换,能够有效学习用户与商品之间的交互特征,并自动发现各种潜在的特征组合模式。与传统的线性模型相比,多层感知机具有更强的特征表达能力,因此可以捕获用户行为与商品属性之间复杂的非线性关系。通过深度网络结构的逐层特征提取和变换,多层感知机不仅能够学习到更加抽象的高阶特征表示,而且可以自适应地调整特征的重要性权重,从而在个性化推荐任务中取得更好的效果。此外,多层感知机的模型结构具有较强的灵活性和可扩展性,便于与其他深度学习模型进行组合,构建更加强大的混合推荐模型。

##### 1.1.2 卷积神经网络

卷积神经网络在处理商品图像、文本描述等非结构化数据方面具有独特优势。通过卷积操作和池化层的组合,卷积神经网络能够自动提取商品的视觉特征和语义特征,从而更全面地理解商品的内容特征。特别是在电商场景中,商品的视觉表现对用户的购买决策具有重要影响,而卷积神经网络可以精确捕获商品图像中的色彩、纹理、形状等关键视觉元素。同时,卷积神经网络还支持多模态特征的融合,可以将图像特征、文本特征等不同类型的信息进行有效整合,生成更加丰富的商品表示,这为提供更精准的个性化推荐奠定了基础。

##### 1.1.3 循环神经网络

循环神经网络专门用于处理序列数据,能够有效捕捉用户

行为的时序特征和依赖关系。通过记忆单元的设计,循环神经网络可以保存用户历史行为的信息,并利用这些信息来预测用户的未来兴趣。在实际应用中,用户的兴趣往往会随时间动态变化,而循环神经网络能够建模这种兴趣演变过程,从而提供更加及时和准确的动态推荐。此外,循环神经网络还可以识别用户行为序列中的重要模式和规律,例如周期性购物习惯或兴趣转移趋势,这些信息对于提升推荐系统的预测准确性具有重要价值。

## 1.2 注意力机制

### 1.2.1 自注意力机制

自注意力机制通过计算序列中各个元素之间的相互关联性,成功突破了传统序列建模方法的局限。在推荐系统中,它能够精确捕捉用户行为序列内部的复杂依赖关系,从而有效识别出对当前推荐任务最具影响力的关键行为特征。通过计算不同行为之间的注意力权重,自注意力机制可以自适应地调整各个历史行为的重要性,使得模型能够更加准确地理解用户的兴趣偏好。此外,自注意力机制还具有并行计算的优势,可以同时处理序列中的所有元素,这不仅提高了计算效率,而且增强了特征表达的有效性。在实际应用中,自注意力机制通过建立行为之间的直接连接,能够更好地挖掘用户行为序列中蕴含的长期依赖关系,为提供更精准的个性化推荐奠定了基础。

### 1.2.2 多头注意力机制

多头注意力机制作为自注意力机制的扩展和优化,通过设置多个并行的注意力头,能够从不同的角度和维度来学习特征表示。每个注意力头都可以关注序列中的不同方面,有些可能专注于用户的短期兴趣,有些则可能捕捉长期偏好,这种多角度的特征学习显著增强了模型的表达能力。与单一的注意力机制相比,多头注意力能够同时考虑多个特征子空间,因此可以获得更加全面和丰富的特征表示。这种机制不仅提高了推荐结果的多样性,而且能够更好地平衡推荐的准确性和新颖性。

## 2、强化学习的创新应用

### 2.1 基于价值函数的方法

#### 2.1.1 DQN (Deep Q-Network)

DQN 通过将深度学习与传统 Q 学习方法相结合,有效解决了推荐系统中大规模状态空间的处理难题。在实际应用中,它使用深度神经网络来近似 Q 值函数,从而能够处理包含用户行为、商品特征等在内的高维状态空间。这种结合不仅扩展了强化学习在推荐系统中的应用范围,而且能够自动学习状态表示,进而优化长期推荐效果。通过经验回放机制,DQN 可以打破数据样本之间的相关性,提高训练效率和模型的泛化能力。此外,

DQN 还采用目标网络来稳定训练过程,使得模型能够逐步收敛到更优的策略,从而在动态变化的推荐环境中实现更好的性能表现。

#### 2.1.2 Double DQN

Double DQN 作为 DQN 的改进版本,着重解决了 Q 值过估计的问题。它通过引入两个独立的神经网络来分别进行动作选择和价值评估,有效降低了 Q 值的估计偏差。这种设计不仅提高了训练过程的稳定性,而且能够产生更加准确的 Q 值估计,从而改善推荐系统的整体质量。在实践中,Double DQN 通过减少过度乐观的价值估计,使得推荐系统能够做出更加谨慎和合理的决策。同时,它还保留了原始 DQN 的优点,如经验回放和目标网络等机制,但在动作评估方面提供了更可靠的估计。这种改进使得推荐系统能够更好地平衡探索与利用,从而在保证推荐准确性的同时,也能维持适当的推荐多样性。

## 2.2 基于策略梯度的方法

### 2.2.1 REINFORCE 算法

REINFORCE 算法作为一种直接优化推荐策略的方法,在推荐系统中展现出独特的优势。它不需要显式地维护价值函数,而是直接通过策略梯度来更新模型参数,这使得算法具有更强的适应性和灵活性。特别是在处理连续动作空间时,REINFORCE 算法能够自然地处理推荐系统中的各种复杂决策,如商品排序分数的精确调整或个性化参数的连续优化。通过采样轨迹并利用整体回报来指导策略更新,该算法能够有效地学习到更优的推荐策略。此外,REINFORCE 算法还可以引入基线函数来减少政策梯度的方差,从而提升训练的稳定性,使得推荐系统能够在动态环境中持续优化并提供更好的服务质量。

### 2.2.2 Actor-Critic 框架

Actor-Critic 框架通过巧妙地结合价值函数和策略梯度方法,克服了单纯使用策略梯度的局限性。该框架包含两个核心组件:负责动作选择的 Actor 网络和负责状态评估的 Critic 网络。通过 Critic 网络提供的价值估计来指导 Actor 网络的策略更新,这种设计显著降低了训练过程中的方差,使得模型能够更快地收敛到理想的推荐策略。同时,Actor-Critic 框架还保留了策略梯度方法的优点,能够在连续动作空间中进行有效的策略优化。此外,由于 Critic 网络提供了及时的价值估计,使得每个时间步都能进行策略更新,这大大提高了算法的样本效率,加快了模型的收敛速度。

## 三、系统优化与实现策略

### 1、特征工程优化

#### 1.1 多源数据融合

多源数据融合技术通过整合用户画像、商品信息、场景上下文等多维度数据，为推荐系统提供了更加全面的信息基础。在实际应用中，这种融合不仅包括基础的用户人口统计学特征和商品属性信息，还涉及用户的历史行为轨迹、社交网络关系以及实时的环境上下文等多个方面。通过深度学习模型的特征提取和转换，系统能够将这些异构数据映射到统一的特征空间，从而构建更加丰富和有效的特征表示。这种多源数据的整合极大地增强了推荐系统对用户兴趣和需求的理解能力，使得系统能够捕获更多维度的用户偏好信息。

### 1.2 特征选择与降维

特征选择与降维技术在处理高维特征数据时发挥着关键作用，通过使用自编码器这一深度学习模型，系统能够有效地将高维特征压缩到低维空间，同时保留数据中最重要的信息结构。在这个过程中，自编码器通过非线性变换学习数据的内部表示，并通过重构误差来指导特征压缩的质量。此外，通过分析特征的重要性权重，系统能够识别并选择对推荐任务最具影响力的关键特征，从而降低特征空间的维度。这种降维过程不仅显著提高了计算效率，减少了存储开销，而且通过去除冗余和噪声特征，还能提升模型的泛化能力。

## 2、模型训练优化

### 2.1 分布式训练框架

分布式训练框架通过协调多台机器的计算资源，有效支持了大规模推荐模型的训练过程。在实际应用中，这种框架采用参数服务器架构或者同步训练策略，使得模型能够在多个计算节点上并行训练，从而显著提高训练效率。通过合理的任务调度和数据分配机制，分布式训练框架不仅能够充分利用集群资源，还能有效降低单机的资源消耗。此外，这种框架还提供了容错机制和负载均衡策略，确保训练过程的稳定性和可靠性。在处理海量用户行为数据时，分布式训练框架能够灵活地扩展计算资源，同时通过优化的通信机制减少节点间的数据传输开销，从而在保证模型性能的同时提升训练效率。

### 2.2 增量学习策略

增量学习策略通过持续不断地更新模型参数，使推荐系统能够及时适应数据分布的动态变化。这种策略不需要周期性地重新训练整个模型，而是可以基于新到达的数据样本进行在线更新，从而大大提高了模型的适应性和时效性。在电商场景中，用户兴趣和商品特征都在不断变化，增量学习能够帮助系统快速捕捉这些变化，并相应地调整推荐策略。通过设计合适的参数更新规则和遗忘机制，系统既能保持对历史数据的记忆，又

能够充分学习新数据中的模式，从而在动态环境中维持较好的推荐效果。

## 3、推荐系统架构优化

### 3.1 微服务架构

微服务架构通过将推荐系统的各个功能组件进行解耦，实现了系统架构的模块化和轻量化。在这种架构下，每个微服务都负责特定的业务功能，如用户画像服务、特征工程服务、模型训练服务等，它们之间通过标准化的接口进行通信和数据交换。这种模块化的设计不仅提高了系统的可扩展性，使得各个组件能够独立扩容和升级，而且大大简化了系统的维护和更新工作。当需要增加新功能或优化现有服务时，只需要对相关微服务进行修改，而不会影响其他组件的正常运行。

### 3.2 实时计算框架

实时计算框架作为推荐系统的核心组件，主要负责处理持续不断产生的用户行为数据流。通过采用流式处理技术，系统能够实时捕获和分析用户的最新行为，并快速更新用户兴趣模型，从而提供及时的个性化推荐服务。该框架采用了高效的数据流水线设计，能够在毫秒级别内完成特征提取、模型预测等关键操作，显著优化了系统的响应时间。此外，实时计算框架还具备弹性伸缩能力，可以根据业务负载动态调整计算资源，确保在流量高峰期也能保持稳定的服务质量。

结束语：本文系统探讨了人工智能技术在电子商务个性化推荐系统中的应用与优化策略。研究表明，深度学习、强化学习等先进算法能够有效提升推荐系统的性能，而多项优化措施的实施则进一步提高了系统的实用性。未来，随着新技术的不断涌现和应用场景的持续拓展，个性化推荐系统将在提升用户体验和促进电子商务发展方面发挥更加重要的作用。

### 参考文献：

- [1]姜蕾,田素妍.人工智能时代电子商务专业人才培养模式初探[J].商业经济,2024,(12):74-76+94.
- [2]林小芳.人工智能在计算机辅助电子商务决策中的应用[J].数字通信世界,2024,(11):159-161.
- [3]肖志超.电子商务的未来:人工智能的驱动力[J].现代营销(下旬刊),2024,(10):152-154.
- [4]杨姣.数字经济时代下人工智能在电子商务供应链优化中的应用[J].中国电子商情,2024,(18):95-97.

作者简介:姓名:赵伟(1975年10月-),性别:男,民族:汉,籍贯:巢湖市,单位:安徽中澳科技职业学院,职称:助教,学历:研究生,研究方向:电子商务。