

## 极大似然估计与遗忘曲线的隐式反馈交互推荐算法

戚 晗<sup>1</sup> 朱天龙<sup>1,2</sup> 傅殿硕<sup>1</sup>  
QI Han ZHU Tianlong FU Dianshuo

## 摘 要

针对传统推荐算法对启动数据要求严苛且服务器性能要求过高导致实际项目中较难应用的问题,提出一种挂载在 ECS 服务器 (elastic compute service, ECS) 上的基于极大似然估计原理 (maximum likelihood estimate, MLE) 和双重艾宾浩斯遗忘算法 (double ebbinghaus forgetting algorithm, DEFA) 相结合的推荐算法 (EMDE)。首先,通过极大似然估计原理和双重艾宾浩斯遗忘算法结合,实现了对用户偏好数据的正态拟合,并且可以灵活地调整用户偏好的遗忘速度和保留程度。其次,充分考虑了对修改关闭原则,可以与现有业务模块高度解耦,并且具有轻量级的特性。实验结果表明,EMDE 算法可以成功避免推荐快速消耗用户兴趣和触及用户反感的交互,并选择合适的交互以达到增强用户黏性的目的。

## 关键词

极大似然估计; 正态拟合; 艾宾浩斯遗忘; 推荐算法; 用户黏性

doi: 10.3969/j.issn.1672-9528.2024.04.013

## 0 引言

在当今信息爆炸的时代,用户偏好分析和智能推荐系统已成为许多互联网企业和电子商务平台的重要交互。准确预测和了解用户的兴趣和行为模式,能够为用户提供个性化的推荐服务,从而提高用户满意度、增加用户黏性和促进商业增长<sup>[1]</sup>。为了实现这一目标,研究者们提出了许多不同的推荐算法和技术。

然而,当传统的推荐算法面对启动数据少的时候,只能望而却步。并且对于互联网公司来说,节省算力就等同于节省资金的投入,并且服务器性能要求过高导致实际项目中较难应用。根据研究,当和用户交互较简单时,完成速度较快,动机较强,容易消耗用户兴趣,而当交互复杂时,完成较慢,会感到厌烦,动力缺乏,使用户感到厌烦<sup>[2-3]</sup>。根据耶克斯-多德森定律,无论是缺乏动力还是过于强烈,都会对用户体验产生负面影响。根据最近的研究,适当的交互难度可以改善用户的表现、满意度和参与度,而过高或过低的交互难度可能会产生不利影响<sup>[4-7]</sup>。交互难度过高或过低,会使用户感到沮丧和不满,而过低的交互难度会让他们感到无聊和没有挑战性<sup>[8-9]</sup>。

针对上述问题,本文提出了一种基于极大似然估计和双重艾宾浩斯遗忘算法的用户偏好分析和推荐解决方案。该算法模块高效、灵活、可扩展,并已成功应用于 ECS 服务器。

通过极大似然估计实现对用户偏好数据的正态拟合,从少量历史数据中提取分布特征。采用多线程字典数据结构满足多线程需求。引入双重艾宾浩斯遗忘算法作为保底机制,灵活调整用户偏好的遗忘速度和保留程度。算法兼容常见的测试数据库工作流,提供可视化观察功能。在推荐阶段,接受来自数据库的数据流作为输入,实时更新用户最新偏好。算法模块与现有业务模块解耦,具有轻量级特性,易于集成和部署。

## 1 相关理论

## 1.1 极大似然估计

若干数据的极大似然估计定义为:

$$L(\mu, \sigma | x_1, x_2, \dots, x_n) = L(\mu, \sigma | x_1) \times L(\mu, \sigma | x_2) \times \dots \times L(\mu, \sigma | x_n) \quad (1)$$

当数据足够多时,数据间遵循正态分布,即:

$$L(\mu, \sigma | x_1, x_2, \dots, x_n) = \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{(x_1-\mu)^2}{2\sigma^2}} \times \dots \times \frac{1}{\sqrt{2\pi}\sigma^2} e^{-\frac{(x_n-\mu)^2}{2\sigma^2}} \quad (2)$$

取对数可得:

$$\begin{aligned} \ln[L(\mu, \sigma | x_1, x_2, \dots, x_n)] &= -\frac{1}{2} \ln(2\pi) - \ln(\sigma) - \frac{(x_1-\mu)^2}{2\sigma^2} - \dots - \frac{1}{2} \ln(2\pi) - \ln(\sigma) - \frac{(x_n-\mu)^2}{2\sigma^2} \\ &= -\frac{n}{2} \ln(2\pi) - n \ln(\sigma) - \sum_{i=1}^n \frac{(x_i-\mu)^2}{2\sigma^2} \end{aligned} \quad (3)$$

将参数  $\sigma$  视作常数,对另一参数  $\mu$  求偏导可得:

$$\frac{\partial}{\partial \mu} \ln[L(\mu, \sigma | x_1, x_2, \dots, x_n)] = 0 - 0 - \sum_{i=1}^n \frac{x_i - \mu}{\sigma^2} = \frac{\sum_{i=1}^n x_i - n\mu}{\sigma^2} \quad (4)$$

令  $\frac{\partial}{\partial \mu} \ln[L(\mu, \sigma | x_1, x_2, \dots, x_n)] = 0$ , 可得:

1. 沈阳航空航天大学 辽宁沈阳 110136

2. 深圳骄阳视觉创意科技股份有限公司 广东深圳 518000

$$\mu = \frac{\sum_{i=1}^n x_i}{n} \quad (5)$$

同理, 将参数  $\mu$  视作常数, 对另一参数  $\sigma$  求偏导可得:

$$\frac{\partial}{\partial \mu} \ln[L(\mu, \sigma | x_1, x_2, \dots, x_n)] = -\frac{n}{\sigma} + \sum_{i=1}^n \frac{(x_i - \mu)^2}{\sigma^3} \quad (6)$$

令  $\frac{\partial}{\partial \mu} \ln[L(\mu, \sigma | x_1, x_2, \dots, x_n)] = 0$ , 可得:

$$\sigma = \sqrt{\sum_{i=1}^n \frac{(x_i - \mu)^2}{n}} \quad (7)$$

通过以上分析可知:

$$\text{Mean} = \frac{\sum_{i=1}^n x_i}{n}, \text{StandardDeviation} = \sqrt{\sum_{i=1}^n \frac{(x_i - \mu)^2}{n}} \quad (8)$$

在代码中引入相关 MATLAB 库函数, 即可迅速进行极大似然估计拟合。

## 1.2 艾宾浩斯遗忘曲线

艾宾浩斯遗忘曲线的拟合方程为:

$$f = \frac{100k}{[\log(t)]^c + k} \quad (9)$$

初始极大似然估计概率  $P_{NORM}$  在受到遗忘曲线保留值影响后的概率为:

$$P_{EBHS1} = P_{NORM} \times \frac{100k_1}{[\log(t_1)]^{c_1} + k_1} \quad (10)$$

初始极大似然估计概率  $P_{NORM}$  在受到遗忘曲线遗忘值影响后的概率为:

$$P_{EBHS2} = P_{NORM} \times \left[ 1 - \frac{100k_2}{[\log(t_2)]^{c_2} + k_2} \right] \quad (11)$$

记若干次保留因素和遗忘因素影响对应权重分别为  $\lambda_{1i}$ 、 $\lambda_{2j}$ , 其加权艾宾浩斯遗忘概率为:

$$P_{EBHS} = P_{NORM} \times \frac{\sum_{i=1}^n \left[ \lambda_{1i} \times \frac{100k_{1i}}{[\log(t_{1i})]^{c_{1i}} + k_{1i}} \right] + \sum_{j=1}^m \left[ \lambda_{2j} \times \left[ 1 - \frac{100k_{2j}}{[\log(t_{2j})]^{c_{2j}} + k_{2j}} \right] \right]}{\sum_{i=1}^n \lambda_{1i} + \sum_{j=1}^m \lambda_{2j}} \quad (12)$$

## 1.3 归一化艾宾浩斯概率

考虑到经过艾宾浩斯影响后, 不同的 *Label* 对应的概率值有所不同, 为了方便比较, 进行归一化处理:

$$P_{EBHS-FITi} = \frac{P_{EBHSi}}{\sum_{i=1}^n P_{EBHSi}} \quad (13)$$

算法期望的目标为  $P_{EBHS-FIT}$  的最小值, 直接求导较为困难, 但显然该式可通过多次循环遍历计算存储于结构体中, 并通过对比得到最小值时对应的 *Label*, 后文将介绍如何通过代码实现上述过程。

## 2 算法描述

本节将详细介绍本文提出的 EMDEA 算法模块的实现细节和步骤。本算法旨在实现高效、灵活和可扩展的用户偏好

分析和推荐功能。以下是本文的代码描述, 限于篇幅原因, 仅介绍调用思路, 由于该算法为工程项目, 可以直接使用, 故可对照对应源码地址进行阅读, 项目地址:

[https://github.com/SangonomiyaSakunovi/FantasyOfSango\\_DailyMissionRecommendAlgorithm](https://github.com/SangonomiyaSakunovi/FantasyOfSango_DailyMissionRecommendAlgorithm)。EMDE 算法总体工作流程如图 1 所示。




图 1 EMDE 算法总体工作流程

## 2.1 数据导入和存储流程

在考虑兼容主流数据库工作流 (如 MongoDB) 的前提下, 导入和处理数据, 并生成拟合结果以反映用户的偏好分布, 为后续的推荐过程提供基础。为了实现这一目标, 使用 EPPlus 库处理数据。具体的流程如下。

(1) 数据导入: 使用 LoadExcelColumnName 函数加载数据中指定范围内的列名, 无需提前指定, 该函数返回一个包含列名的字符串列表。然后, 使用 LoadExcelMultiFloatValue 函数加载数据中指定范围内的浮点数数据, 返回一个包含浮点数数据的嵌套列表。这些数据将用于后续的极大似然拟合。

(2) 极大似然估计拟合: 基于加载的数据, 进行极大似然估计拟合, 利用统计方法建模用户的偏好分布。这一步骤将生成拟合结果, 反映了用户的偏好分布情况。

(3) 结果存储: 拟合结果将存储于缓存实例中, 以供后续的推荐过程使用。这样, 可以在推荐过程中基于用户的偏好分布进行合理的交互选择。此外, 还提供了可选的结果可视化观察功能, 方便用户进行直观的观察和分析。

通过以上流程, 能够高效地导入和处理各种数据库导出的数据, 并通过极大似然估计拟合生成用户的偏好分布结果。

## 2.2 极大似然估计拟合

为了实现对用户偏好数据的正态拟合, 通过提取历史数据中的分布特征, 对用户的偏好进行建模和预测。具体而言, 收集和整理用户的交互完成时间数据, 并利用极大似然估计方法拟合出最适合这些数据的正态分布模型。这个拟合过程

对计算资源的需求较低,因此即使在普通商用服务器上,也能够频繁地重新拟合以适应最新的用户情况。具体的流程如下。

(1) FitColumnNamesAndNormalDistributionToList 函数:该函数对每一列数据进行拟合操作,并返回包含拟合结果的列表。在函数内部,调用 FitColumnNamesAndNormalDistributionToDict 函数。

(2) FitColumnNamesAndNormalDistributionToDict 函数:该函数调用内部的 FitNormalDistributionToList 函数,接受一个浮点数数据列表,并进行极大似然估计拟合。拟合结果存储在私有多线程字典 cacheNormalDistributionDic 中,以便后续的数据预测使用。在拟合过程中,使用 CalculateMean 和 CalculateStandardDeviation 函数计算数据的均值和标准差,并利用这些参数构建正态分布模型。

通过以上流程,能够基于极大似然估计原理对用户偏好数据进行正态拟合,并提供可视化和分析功能,以支持运营人员进行数据分析和决策。

### 2.3 双重艾宾浩斯遗忘算法

为了保证推荐系统的稳定性和适应用户兴趣的变化,引入了双重艾宾浩斯遗忘算法作为保底机制。通过调整权重参数、遗忘  $K$  值和  $C$  值,灵活地控制用户偏好的遗忘速度和保留程度。具体的流程如下。

(1) GetDMRProbabilityToList 函数:该函数接受一个 userDatas 列表,其中包含用户的偏好数据。首先,计算拟合结果的原始概率总和和最小的完成交互数。然后,根据拟合结果和双重艾宾浩斯遗忘算法的参数,计算双重艾宾浩斯概率值更新到 userDatas 列表中,并返回更新后的列表。

(2) CalculateEbbinghausRetention 函数:该函数用于计算艾宾浩斯遗忘算法中的遗忘保留概率。它接受艾宾浩斯算法的  $K$  值、 $C$  值和经过的天数,并进行一定的加权处理。这些参数可以根据需求进行自定义。最终,函数返回经过遗忘保留调节后的概率值。

通过结合双重艾宾浩斯遗忘算法,能够根据拟合结果和

用户的历史偏好信息,灵活地调整遗忘速度和保留程度,以提高推荐系统的多样性和用户体验。这样做可以避免过度推荐热门交互或忽视冷门交互,从而保证推荐系统的稳定性和准确性。EMDE 算法 CodeMap 和 EMDE 配置信息 CodeMap 分别如图 2 和图 3 所示。




图 2 EMDE 算法 CodeMap(Microsoft Visual Studio 企业版)




图 3 EMDE 配置信息 CodeMap (Microsoft Visual Studio 企业版)

### 3 实验结果与分析

数据集使用深圳某公司 AR 导览项目内测数据。这些数据涵盖了不同交互类型和用户偏好的多样性。为了评估本文提出的算法模块的性能和有效性,研究者进行了一系列实验,并对实验结果进行了详细的分析。以下是实验的设置和结果分析。

使用了一个包含 4 个交互和 23 条数据的训练集作为实验数据。测试数据方面,选择了一组较为有特点的数据,涵盖快速完成、超时完成和两个常规时间内完成的数据,期望该算法可以避免推荐快速和超时两个交互,而在两个常规交互中选择合适的交互。

在实验中,利用算法模块进行拟合,然后导入测试数据记录推荐结果。重点观察算法是否能够成功避免推荐完成较快和较慢的交互,以及综合选择适合的交互作为推荐结果的能力。随机算法与 EMDE 算法推荐概率对比表见表 1。随机

算法与 EMDE 算法推荐概率对比图见图 4。

表 1 随机算法与 EMDE 算法推荐概率对比表

| 标签      | 交互 1            | 交互 2 | 交互 3         | 交互 4         |
|---------|-----------------|------|--------------|--------------|
| 完成时间    | 20              | 500  | 95           | 106          |
| 历史次数    | 2               | 1    | 3            | 1            |
| 历史间隔    | 1               | 2    | 1            | 3            |
| 随机算法    | 0.25            | 0.25 | 0.25         | 0.25         |
| EMDE 算法 | 2.505 394 5E-12 | 0    | 0.187 336 53 | 0.812 663 44 |




图 4 随机算法与 EMDE 算法推荐概率对比图

通过对实验结果的分析，可以看出本文提出的算法模块在避免推荐完成较快交互和较慢交互方面表现出了良好的效果。这得益于双重艾宾浩斯遗忘算法的保底机制，它能够根据参数灵活调整交互偏好的遗忘速度和保留程度。其综合选择能力使其能够根据用户的偏好分布和保底机制合理选择推荐结果，从而提高了推荐系统的多样性和用户体验。

4 结论和展望

本研究成功开发了基于极大似然估计和双重艾宾浩斯遗忘算法的 C# 算法模块，具备高效、灵活和可扩展的用户偏好分析和推荐功能。实验结果表明，该模块避免了过度推荐热门交互和忽视冷门交互，通过正态拟合预测用户偏好分布并选择合适的交互，提高了推荐系统质量和用户满意度。该模块还具备多线程支持和轻量级特性，易于集成到商业项目中。未来研究将致力于提升适应性和可扩展性，将模块作为 nuget 插件，并解决基于 IOCP 或 KCP 多线程异步的 AR 状态同步服务器需求。商业化应用和用户隐私保护也是关注的重点，通过实际测试和改进算法，提供更好的个性化推荐服务。

参考文献：

[1]PANAGIOTIS D P, DIMITRIOS E K. Game difficulty adaptation and experience personalization: a literature review[J].International journal of human-computer interaction, 2023,39:1-22.

[2]TIAN S, ZIXING D, LIZHEN C, et al. System development and evaluation of human-computer interaction approach for assessing functional impairment for people with mild cognitive impairment: a pilot study[J]. International journal of human-computer interaction, 2023,6:1-15.

[3]WEIMIN T. The player experience and design implications of narrative games[J]. International journal of human-computer interaction, 2023,39:2742-2769.

[4]EMMA J P, HAYTHAM M F, FABIO Z. A case for personalized non-player character companion design[J]. International journal of human-computer interaction, 2023,3: 1-20.

[5]YUSUKE G, TETSUNARI I. Instant difficulty adjustment: predicting success rate of vr kendama when changing the difficulty level[J]. Augmented humans conference, 2023, 3: 346-348.

[6]MUHARREM A, HASAN K, VASIF N.Examination of adaptation components in serious games: a systematic review study[J]. Education and information technologies, 2022, 28: 6541-6562.

[7]JÚLIO C L, RUI P L.A review of dynamic difficulty adjustment methods for serious games[J]. Optimization, learning algorithms and applications, 2022,1754:144-159.

[8]LIN Z, YUFEI X, LUQIANG X. The impact of personalization feature on students' engagement patterns in a role-playing game: a cultural perspective[J]. Education and information technologies, 2022,28:8357-8375.

[9]LOK C S, YASMINE R, SIMON S, et al. Personalised learning through context-based adaptation in the serious games with gating mechanism[J]. Education and information technologies, 2023,28:13077-13108.

【作者简介】

戚晗(1982—)，男，黑龙江铁力人，副教授，研究方向：量子机器学习、移动云计算、网络安全。

朱天龙(1994—)，男，辽宁沈阳人，硕士研究生，全栈交互媒体与增强现实混合开发架构师，研究方向：AR 增强现实开发全栈技术解决方案。

傅殿硕(1997—)，男，辽宁沈阳人，硕士研究生，研究方向：时序数据预测。

(收稿日期：2024-01-09)