arXiv:2304.00578v1 [cs.IR] 2 Apr 2023

面向多次重复用户-物品交互的序列感知物品推荐

Juan Pablo Equihua[1,3], Maged Ali[2], Henrik Nordmark[3,1] 和 Berthold Lausen[1,4*]

[1]数学科学系，埃塞克斯大学，科尔切斯特，英国。[2]埃塞克斯商学院，埃塞克斯大学，科尔切斯特，英国。[3]Innovation，Profusion Media Ltd.，保罗街，伦敦，英国。[4]医学信息学、生物统计学与流行病学研究所，医学院，埃尔朗根-纽伦堡弗里德里希-亚历山大大学，瓦尔德街6号，埃尔朗根，91054，德国。

*通讯作者。电子邮件：berthold.lausen@fau.de；贡献作者：je18890@essex.ac.uk；maaali@essex.ac.uk；henrikn@profusion.com；

摘要

推荐系统是机器学习和数据科学最成功的应用之一。它们在各种应用领域都取得了成功，包括电子商务、媒体流内容、电子邮件营销，以及几乎所有个性化能够改善用户体验或提升销售额和客户参与度的行业。这类系统的主要目标是分析用户过去的行为，预测哪些物品最受用户关注。它们通常采用矩阵补全技术构建，例如协同过滤或矩阵分解。然而，尽管这些方法在众多现实应用中取得了巨大成功，但当用户可能多次与同一物品交互，或用户偏好随时间变化时，它们的效果仍然有限。

我们的灵感来自自然语言处理技术压缩、处理和分析文本序列的方法。我们设计了一种推荐系统，将时间维度引入物品推荐任务，并考虑每位用户的物品交互序列，以生成推荐。实证结果表明，在零售环境中，即使没有显式反馈，该方法也能准确预测所有用户与物品的交互；此外，在一次 A/B实时测试中，总销售额提升了 5%，单个客户的支出增加了 50% 以上。

关键词： 推荐系统、自然语言处理、深度学习、客户体验。

引言

推荐系统或许是近年来机器学习（ML）和人工智能（AI）中最成功的应用之一

二十年来，这些系统已在广泛的应用领域中成功设计、测试并投入使用，向用户展示大量相关项目；当潜在物品目录特别……时，它们尤其有用

可推荐商品的数量足够庞大，以至于人们不可能手动进行推荐。总体而言，推荐系统被认为是向用户提供个性化内容的有效方式。例如，流媒体服务网飞会向客户展示针对用户预测的电影评分，帮助他们决定哪些内容更适合观看，也更能引起兴趣。全球在线零售商亚马逊则根据相似客户以往的购买历史，向用户提供预测的物品评分。由于这些工具的最终目标是向个人用户推荐更合适的物品，或推荐客户会喜欢的物品，因此这类系统通常被归类为推荐系统。

推荐系统起源于信息检索领域：识别哪些在线文本内容可能与给定用户查询最相关，然后根据用户易于消费的方式对检索出的相关性最高的文档列表进行排序。然而，尽管这种方法在 90 年代被不同公司广泛用于推荐特定物品，但它很快就被更先进的技术所取代。这些技术包括基于内容的协同过滤（CF）Balabanovic 和 Shoham (1997年)以及矩阵分解（MF）Koren、Bell 和 Volinsky(2009年推荐系统，其目标是在矩阵补全框架中利用用户行为和购买记录的历史信息，学习用户偏好与物品之间的关系，例如奇异值分解（SVD）Zhou、He、Huang 和 Zhang (2015），目标是在用户-物品评分矩阵中预测用户未来的偏好。这些成熟的技术各有优缺点，许多研究人员、公司和人工智能从业者选择以不同方式组合技术，为用户提供更好的推荐，并提升整体收入、客户参与度或模型性能。这推动了混合推荐系统Burke (2002的发展，其中加权推荐器Claypool 等人 (1999年）、混合推荐器 Smyth 和 Cotter(2000年）和特征组合推荐器 Basu、Hirsh 和 Cohen (1998年）或许是业界最常用的方法。尽管这些技术通常能够处理推荐系统中的一些问题，例如冷启动将新物品或用户添加到系统中的问题Jazayeriy、Mohammadi 和 Band (2018年），但它们在多个应用领域中仍存在若干性能问题Marchand 和 Marx(2020年）。

在各行各业，推荐系统都是强大的工具，能够通过个性化提升用户体验，并通过识别最可能与用户相关的物品来增加销售额和总体收入 Aggarwal (2016年); Gunawar-dana and Shani (2009年); Zhao, Lee, andWynne(2014年)。与计算机视觉和自然语言处理（NLP）等其他应用领域的情况类似，深度学习在推荐系统领域也能取得卓越成果。借助深度神经网络揭示用户-物品交互之间复杂的非线性关系，深度学习能够轻松超越长期沿用的技术；而且，这些模型还能直接从通常十分丰富的数据中学习复杂的用户-物品关系 Zhang,Yao,Sun, and Tay (2019年)。事实证明，在推荐系统中应用深度学习，无需在部署阶段投入大量精力，就能显著优于其他技术。第三节将进一步介绍这类方法。

尽管借助深度学习增强的协同过滤和矩阵分解等技术，在现实场景中捕捉非线性用户-物品关系方面取得了巨大成功，但它们仍存在局限：当用户偏好随时间变化时，或当用户在整个产品目录中仅与少数物品进行多次交互时，这些技术往往表现不佳。对于许多专业零售商以及中小型企业（SMEs）设置而言，后一种情况十分常见。此外，由于协同过滤和矩阵分解属于矩阵补全方法，通常会假设数据中的所有用户-物品交互都已知对应的确切物品偏好，即用户评分。已有研究提出了为用户-物品对生成合成评分的方法 Su和 Khoshgoftaar（2009年）；Trofimov等（2017年），例如创建仅依赖于用户购买或交互不同物品次数的函数。然而，这些合成评分的构建通常完全是任意的，当系统在现实场景中进行测试时，可能导致不现实的假设和不准确的预测。

过去几年中，围绕序列感知推荐系统开展了大量研究De Souza Pereira Moreira、Rabhi、Lee、Ak和Oldridge（2021年）；Guy Shani（2005年）；Quadrana、Cremonesi和Jannach（2018年）；Wu、Ahmed、Beutel、Smola和Jing（2017年）；Zhang等（2019年），尤其是在隐式反馈的背景下，即数据中所有或大多数用户-物品交互所对应的确切用户评分未知。受自然语言处理启发，序列感知推荐系统与传统的矩阵补全方法存在本质差异。序列方法将客户交易视为序列信息，把产品目录中的每件物品视为词典中的一个单词或词元Quadrana等（2018年），并汇总每位客户进行的所有交易，以构建词元序列，这与处理词语序列类似。随后，可以利用为每位用户生成的新序列，将客户嵌入共同的表示空间，并预测序列中下一个最可能出现的词元或物品；物品推荐可以简单地通过选择最有可能成为已购物品序列下一部分的物品来实现。

本文其余部分安排如下：第二节回顾推荐系统的现有文献，以及这些系统如何与深度学习、神经网络和序列模型相结合。第三节概述我们的序列感知推荐系统的方法论，以及如何将交易压缩并表示为词元序列。第四节介绍在英国两家大型零售商的数据上进行的实验结果，以及推荐系统基准测试中常用的$MovieLens$ 数据集。最后，第五节概述本研究的主要结论和未来研究方向。

已有研究

符号说明

在典型的推荐场景中，有一组用户 $U = \{u_1, u_2, ..., u_{|U|}\}$，数量为 $| U |$，以及一组物品 $I = \{i_1, i_2, ..., i_{|I|}\}$，数量为 $| I |$。不过，由于业务限制，通常只需对可能可推荐商品的一个子集进行排序，因为 $U = \{u_1, u_2, ..., u_{|U|}\}$ 物品并非始终有货，或可能已停产。

$I' \subset I$。一般而言，推荐系统的目标是为每位用户 $u_j \in U$生成一份相关物品 $L_{u_j} \subset I$ 列表。这通常通过学习一个映射函数 $f(X_U(u_j)\ X_I(i_k)) : X_U \times X_I \to \mathbb{R}$来实现，该函数可以预测物品 i_k 对用户 u_j而言有多相关。其中，X_U 和 X_I 分别表示用户和物品可用全部信息的特征空间，例如用户评分、用户和物品特征，以及从数据中人工构造的特征。

计算出预测结果后，可以通过按每位用户 u_j 的相关性从高到低对物品排序，得到推荐列表 L_{u_j}。以下各节探讨了研究和行业应用中用于从隐式反馈场景中学习该函数 f 的不同方法。

隐式反馈推荐系统。

在 90 年代初，推荐系统主要依赖显式反馈，即收集用户针对每件物品的评分和评论，以获取推荐意见 Balabanovic 和 Shoham(1997)；Claypool 等人(1999)；Resnick、Iacovou、Suchak、Bergstrom 和 Riedl (1994年)，这些评分和评论通常能清楚地表明用户对产品及其特征的喜好或偏好，也是客户忠诚度的指标 Ravula、Jha 和 Biswas (2022年)。然而，随着推荐系统被企业大规模、广泛地使用，获取可靠的显式反馈日益困难。此外，在某些领域，获取用户的显式反馈本身就十分困难，甚至不可能。例如，在零售环境中，用户通常一次到店就会将大量物品放入购物篮。购买完成后要求用户逐一对每件物品提供反馈，对用户而言并不实际，也无益于提升用户体验。在这种情况下，我们只能依赖隐式反馈。隐式反馈可以通过伪评分获得，也可以在数据预处理阶段，利用通常任意定义的函数，根据用户的不同数据信号进行估算，例如

例如，某物品的购买次数，或在线会话期间发生的不同类型事件。

由于用户提供的可靠显式评分较为稀缺，研究者提出了多种基于隐式反馈的推荐系统。例如，N´u˜nez Valdez、Quintana、Gonzalez Crespo、Isasi 和 Herrera-Viedma(2018年)探索了利用从电子商务平台用户日志信息中获取的隐式反馈来推荐电子书的不同方案，例如会话时长、点击次数、用户阅读时间和评论数量。Hu、Koren 和 Volinsky(2008)提出，通过关联不同置信区间，获取用户的正向或负向偏好信息，从而大规模推荐电视节目。Lee、Park 和 Park(2008)在电子商务平台上进行物品推荐，采用伪评分并引入时间信息，纳入用户与物品交互的时间，以及物品最初上架以来经过的时间，从而通过向用户推广全新物品来影响推荐系统的准确性。

矩阵补全推荐系统

协同过滤

协同过滤于 20 世纪 90 年代末被提出，作为基于内容和基于特征的推荐系统的一种便捷替代方案。这些系统大多专注于提取人工设计的用户和/或物品数据特征，旨在寻找购买记录之间的相似性，从而预测用户未来感兴趣的物品。相比之下，GroupLensResnick 等人（1994年）提出的协同过滤方法，旨在根据一组用户此前对相似物品的喜好程度，估计某个用户会多喜欢某个特定物品。在协同过滤中，评分是根据图1所示的用户-物品矩阵估算的，其中，已知的历史用户评分表示为 $r_{u,\ i}$，对应用户 u 和物品 i；未知的未来评分 $\hat{r}_{u,\ i}$ 则估算为

$$\hat{r}_{u,i} = \frac{\sum_{j \in I} r_{u,i} \cdot w_{i,j}}{\sum_{j \in I} w_{i,j}},$$

其中 $w_{i,\ j}$ 表示物品 i 与一个物品 $j \in I$ 之间的相似度，可通过余弦相似度、Jaccard相似度、KL散度等任意相似度函数获得。

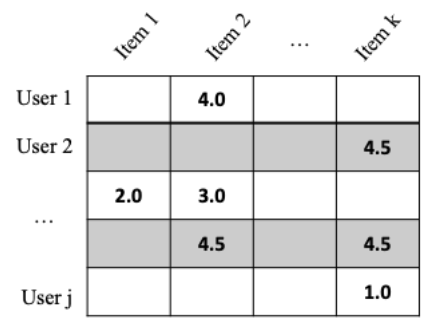

图 1 一组用户 $u \in U$ 和一组物品 $i \in I$的评分表示矩阵

实际上，估算评分 $\hat{r}_{u,\ i}$ 时，通常只使用物品 $J \subset I$ 的一个子集，即物品 i 的邻域，而不是全部物品；这样可以提高可扩展性，并通过仅使用最相似的物品来降低变异性。

业内已有多个成功的应用案例，利用协同过滤来提升销售额与收入。例如，Linden、Smith 和 York（2003）在大型电子商务网站 *Amazon.com* 部署了基于物品的协同过滤推荐系统，用于个性化展示网站每天数百万购物用户所看到的内容，而不受先前客户所作评分或购买记录数量的限制。此外，协同过滤方法还可以轻松地与大量机器学习技术相结合，例如聚类Ungar 和 Foster （1998年）、潜在语义分析Hofmann（2004）或马尔可夫决策过程GuyShani（2005年），以提升评分估计的性能与可扩展性。

尽管协同过滤技术相对容易在生产环境中实施，并且已被证明能够在多个行业的应用中提升收入和客户满意度，但这些方法仍存在一些局限性。首先，完全已知的用户评分应明确且可靠地表达用户对物品的偏好，而这在隐式反馈场景中通常难以实现，因为评分通常只能从用户信号中获得。其次，由于未来用户评分是直接根据物品相似度

$w_{i,\ j}$ 在高度稀疏的数据集中，用户仅对少数物品进行评分，这会导致估计评分产生额外的变异，从而造成整体性能下降，并导致推荐结果遗漏。

矩阵分解

为解决推荐系统中的数据稀疏性问题，不同方法采用降维技术，例如奇异值分解 (SVD)和主成分分析 (PCA)，将高度稀疏的用户-物品交互矩阵压缩为低维稠密的用户和物品表示。

矩阵分解 Koren 等人(2009年) 将用户和物品表示为维度为 k 的潜因子，这些潜因子直接从用户-物品交互矩阵中推断得出，从而可以通过用户和物品潜因子的内积轻松估算未知评分。数学上，每个物品 $i \in I$ 都与一个隐含潜向量 $q_i \in R^k$相关联，而每个用户$u \in U$则与一个向量 $p_u \in R^k$相关联；对于每个用户和物品，相应的向量 p_u 和 q_i 用于衡量 u 和 i 与相应潜因子的关联是正向还是负向，通常 $k << min(|\ U\ |, |\ I\ |)$。因此，物品的估计用户评分可以通过用户和物品潜因子之间的“相似度” 来估算，即:

$$\hat{r}(u,i) = q_i^T \cdot p_u$$

在训练阶段，可以通过最小化已观测评分与预测评分之间的误差来学习潜因子；对于这些评分，其真实值是完全已知的，通常使用均方误差（$MSE = \frac{1}{|U|\times|I|}\sum_{j=1}^{|U|}\sum_{k=1}^{|I|}(r_{u_j,\ i_k} - \hat{}r_{u_j,\ i_k})^2$）作为损失函数。随后，可以选择潜因子内积最大的预测评分来生成推荐。已有多项研究扩展了这一概念：Bell、Koren 和 Volinsky (2007年) 将基于邻域的协同过滤与 SVD 矩阵分解在更高层次上结合，在大型数据集上提升估计性能，同时无需对缺失评分进行插补，也避免了训练时的参数收缩。Paterek(2007年提出了一种加权奇异值分解，并将额外的偏置项加入 SVD，并针对每个物品进行核岭回归后处理。Salakhutdinov 和 Mnih (2007年) 提出了概率矩阵分解（PMF），在模型参数中引入自适应先验，使其性能优于 SVD，同时保持模型在大型数据集上的可扩展性，即使用户的物品交互很少也能如此。

基于深度学习的推荐系统

如第一节所述，推荐系统可以与前馈神经网络（FNN）、卷积神经网络（CNN）和循环神经网络（RNN）等神经网络相结合，以发现非线性且复杂的用户-物品交互，并为用户提供更好的推荐 Covington、Adams 和 Sargin (2016年); Hariri、Mobasher 和 Burke (2012年); He 等人 (2017 年); Zhang 等人 (2019 年)。这类架构通常由多个神经网络构件组成，可定义为单个可微函数，并通过分类或排序损失进行端到端训练，以提升推荐性能并对物品列表进行排序。此外，它们还能在输入数据中整合多种形式的数据，例如用户评论、推文、物品图像或声音，旨在具备混合推荐系统的行为特征和优势，同时避免昂贵的人工特征工程。

得益于 *TensorFlow* 和 *PyTorch*等深度学习框架易于使用，加之现代计算机的计算能力不断增强，过去十年间，基于深度学习的推荐系统已应用于多个行业的研究和商业应用中。例如，He 等人（2017年）将协同过滤中的内积替换为多层感知机（MLP），后者能够从数据中学习任意函数，并发现用户－物品矩阵中的非线性关系，其表现优于多种协同过滤方法。 Covington 等人（2016年）在候选生成－排序分类框架中结合使用两个神经网络，为大型视频流媒体平台 *YouTube*的用户生成可扩展性极高的推荐，并将排序空间从数百万个物品缩减至仅几千个。在这项工作中，作者

结合不同类型用户行为的信息与物品嵌入，以高精度生成相关物品列表。Volkovs、Yu 和 Poutanen（2017年）提出了一种名为 *DropoutNet* 的方法，该方法结合矩阵分解与神经网络来解决冷启动问题，其假设是：缺少用户信息与高效处理缺失数据的情况类似。

序列感知推荐系统

部署在生产环境中的现代推荐系统，主要依赖将矩阵补全技术与用户和物品特征相结合，以检测用户的长期偏好。然而，这些技术大多无法很好地应对用户偏好随时间显著变化，或用户反复与同一组物品交互的场景。序列感知推荐系统通常在序列框架中考量用户-物品交互，以检测用户偏好在短时间内的变化，并快速高效地识别短期流行趋势Quadrana 等人(2018年)。通常，这类系统的输入是按时间排序并带有时间戳的用户过往行为列表，输出则是最有可能与用户相关的物品有序列表，正如前文所述的传统物品推荐设置。

Quadrana 等人 (2018年) 将序列感知推荐场景分为四类：上下文适应，即需要了解用户所处的上下文（如地理位置、当前天气或一天中的时间），以便提供相关推荐。 趋势检测，即了解社区趋势和热门物品的个体趋势至关重要。重复推荐，即用户可能在单个或多个会话中反复与每个物品交互。 顺序约束，即用户行为发生的实际顺序揭示了接下来最有可能采取的行为。

近年来，序列感知推荐系统已在多个应用领域得到广泛研究。例如，GuyShani(2005年) 提出了一种基于

马尔可夫决策过程（MDP）的强化学习框架，用于提高在线书店中推荐物品的收入。Baeza-Yates、Jiang、Silvestri 和 Harrison (2015) 研究了如何通过预测用户近期可能使用的应用来提升移动应用使用率，从而提供个性化用户体验。他们利用热门推荐和基于会话的特征工程，证明其方法优于朴素贝叶斯和支持向量机（SVMs）等不同预测方法，同时应对新应用不断涌现所带来的冷启动问题。¨Hariri 等人 (2012年) 提出了一种用于音乐推荐的上下文感知推荐系统。该系统分析用户在当前会话中此前听过的歌曲序列，以及映射为主题序列的人为整理的播放列表数据库，其推荐表现优于协同过滤或基于内容的过滤方法。 J. Wang 和 Zhang (2013年) 提出了一种面向电子商务行业的重复交互推荐系统，该系统结合生存分析中的比例风险假设，对一段时间内用户与物品交互的联合概率进行建模。

方法论

本节介绍如何在数学上对用户-物品交互随时间的变化进行建模，并说明用于估计用户在给定时间范围内与特定物品集合交互的可能性的架构 $I' \in I$。马尔可夫决策过程（MDP）、潜在狄利克雷分配（LDA）和循环神经网络（RNN）等序列建模技术，适用于分析具有时间依赖性和/或内在序列形式的数据，例如自然语言处理与理解任务中的情感分析、文本分类和下一个词元预测。尽管物品推荐通常不被视为序列任务，但有多种序列技术可用于提升推荐性能。在本研究中，我们借鉴自然语言处理领域的思路和数据预处理技术，以序列框架处理用户交易，

例如分词和序列嵌入，并利用循环神经网络估计数据集中每位用户与特定物品交互的概率。

根据第二节引入的记号，我们可以将序列推荐问题描述如下：设 $U = \{u_1, ..., u_{|U|}\}$为用户集合， $I = \{i_1, ..., i_{|I|}\}$ 为物品集合。与前文介绍的矩阵补全方法不同，后者旨在估计每位用户 $u_j \in U$ 对每件物品 $i_k \in I$的总体估计评分 $\hat{r}(u_j, i_k)$；我们的目标是在给定时间范围内，求用户 u_j 与物品 i_k 发生交互的概率，表示为 $P_{u_j}(i_k) = P(i_k \mid Seq(u_j))$。其中， $Seq(u_j)$ 是用户 u_j 此前购买的物品所构成的有序序列，其具体构造将在下一节介绍。

为估计概率 $P_{u_j}(i_k)$，我们使用图2所示的循环神经网络，该网络由一个嵌入层、两个长短期记忆网络（LSTM）单元以及一个具有五层、采用 sigmoid 激活函数且输出维度为 $|I'|$ 的前馈网络组成，对应所有潜在的可推荐商品。

数据预处理

受自然语言处理技术压缩和处理序列数据的方式启发，我们旨在将用户-物品交互作为序列任务来处理。为此，我们基于表1所示的原始事务数据构建物品交互序列 $Seq(u_j) = [i_{u_j,1}\, i_{u_j,2} \ldots i_{u_j,u_{n_j}}]$，其中每个用户 $u_j \in U$对应一个序列，如表2所示。该列表中的元素是以空格分隔、按时间戳排序的物品 ID，表示用户 u_j 交互过的物品。这样，就可以直接将序列 $Seq(u_j)$作为文本序列处理，其中每个物品 ID 都相当于自然语言处理任务词典中的一个词。

接着，用户u_j的模型目标向量构建为 $Y_{u_j} = [y_{u_j,i}, y_{u_j,2}, \ldots, y_{u_j,|I'|}]$，其中$y_{u_j,\ k} = 1$ 如果用户 u_j 在性能周期内与物品i_k 发生过交互，则取该值，否则为 0。

表 1 原始事务数据

用户 ID	物品 ID	时间戳
u_1	i_1	$t_{1,0}$
u_1	i_2	$t_{1,1}$
u_2	i_1	$t_{2,0}$
...	...	...
u_j	i_d	$t_{j,d}$
u_j	i_{d+1}	$t_{j,d+1}$
...	...	...

表2 客户序列交易

客户ID	$Seq(u_j)$
u_1	$[i_{u_1,1}\, i_{u_1,2} \ldots i_{u_1,n_1}]$
u_2	$[i_{u_2,1}\, i_{u_2,2} \ldots i_{u_2,n_2}]$
...	...
u_j	$[i_{u_j,1}\, i_{u_j,2} \ldots i_{u_j,n_k}]$
...	...

分词和嵌入

分词

分词是自然语言处理中的一种简单而强大的技术，用于转换文本句子，并将其拆分为组成句子的不同元素或“词元”。例如，给定文本句子‘为不同用户和物品提供推荐’，分词会返回由六个词元组成的序列[‘推荐’ ‘为’ ‘不同’ ‘用户’ ‘和’ ‘物品’], ，每个单词都是一个独立的词元。基于词典的分词或许是人工智能行业中最常见的分词类型。这种方法使用预先定义的词典，将词语映射为词元；这些词典通常由大量文本序列学习得出，因此能够对每个待处理的新句子进行分词。不过，自然语言处理文献中还介绍了其他分词方法，例如基于规则的分词、正则表达式分词或子词分词，这些方法不在本文的讨论范围之内。

由于在这项工作中，要处理的词元并非预训练词典中的真实词语，而是物品标识符，因此有必要在模型训练期间从数据中学习一个新词典，并在预测阶段用它压缩购买序列。

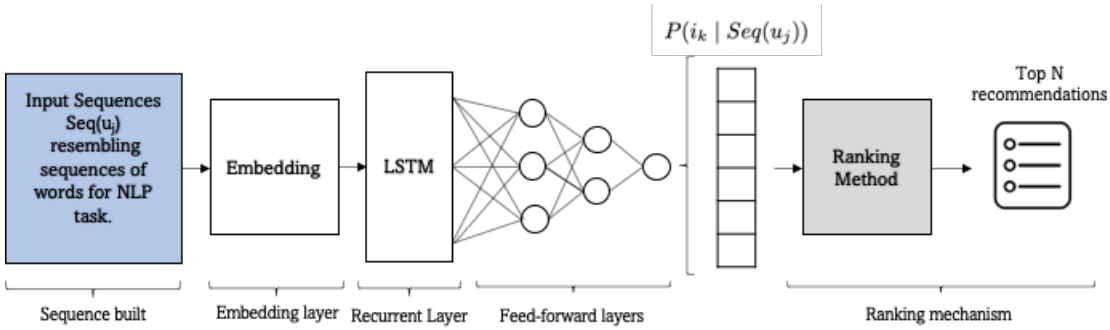

图 2 用于估计未来词元交互概率的循环模型。输入的事务序列$Seq(u_j)$经过嵌入层和两个长短期记忆单元（LSTM）处理，随后输入一个具有 Sigmoid 激活函数的多层感知机，其大小为 $|I'|$，以获得用户-物品交互的概率 $P_{u_j}(i_k)$。

Word2Vec 嵌入

词嵌入是自然语言处理和信息检索中常用的强大方法，通过获取文档中词语的表示，解决处理大型文本语料时面临的高维问题。Bengio、Ducharme、Vincent 和 Janvin(2003）。Word2Vec 嵌入由Mikolov、Chen、Corrado 和 Dean(2013年）于 2013 年提出，旨在为可能包含数十亿个词元的词典学习高质量的稠密词向量表示，同时尽量保留词语在语义和句中位置方面的相似性。

特别是，连续词袋模型（连续词袋模型）Mikolov 等人（2013年）是一种无监督神经网络，具有一个用于所有词的全连接隐藏层（又称共享投影矩阵），用来表示网络中的每个词元，并根据其上下文或周围词语预测当前词。尽管连续词袋模型结构简单，却广泛应用于文本应用中，以寻找可扩展的词表示，作为高度稀疏的词袋表示的替代方案。尽管 Word2Vec 嵌入被视为无监督方法，但它们是在监督框架中学习的，例如分类或下一个词元预测（如本研究所示）；具体做法是将嵌入层连接到整体架构中，并通过反向传播进行训练，如图2。

N 元语法模型

自然语言处理领域提出了 N 元语法模型，以高效预测下一个词元给定前n-1 个词元的句子，这些技术已广泛应用于拼写检查、文本生成和 DNA 序列分析等应用中 Bickel、Haider 和 Scheffer (2005年);L. Wang(2012年)，用于捕捉序列中词元分布的表示，并假设存在上下文相关性，即彼此距离较近的词元之间的相关性强于距离较远的词元。

在最简单的形式中，词元预测通过最大似然估计计算，即估计 $P(w_n) = \prod_{k=1}^{n} P(w_k \mid w_{1:k-1})$，其中$w_k$ 表示给定序列中的第 k 个词元Bickel 等人 (2005年）。然而，一些方法会将词元聚类到不同组中，并借助聚类和平滑来平滑每个词元的概率；也有方法采用编码器—解码器和注意力机制，以提高预测性能 Qi 等人 (2020年）。

损失函数

模型训练时，我们使用二元交叉熵作为损失函数，并使用随机梯度下降和反向传播来优化图 2所示的模型架构，因此，优化问题可以表述为最小化定义如下的损失函数

$$Loss = -\frac{1}{|U|}\sum_{j=1}^{|U|}\sum_{i=1}^{|I'|} y_{i,j} \cdot log(P_{u_j}(i_k))$$

其中，$y_{i,\ j}$ 是数据预处理部分中引入的二元目标变量，对应于性能周期内用户-物品交互的指示函数，

并且 $P_{u_j}(i_k)$ 是神经网络对概率的估计值。

排序机制

由于推荐系统的最终目标是向用户输出一份可能相关的物品列表，因此许多技术会在训练期间纳入排序方法和专门的排序损失，以统一模型的训练与测试，并减轻服务偏差Covington等(2016年); Guy Shani（2005 年);Zhang 等 (2019 年）。排序过程还可以纳入有关物品的其他业务相关信息，而不影响概率的估计。例如，在现实场景中，我们可能希望推荐一件与用户发生交互的概率稍低、但对推荐方公司而言利润更高的物品。

在这项工作中，我们在训练时将排序过程与整体模型架构分离，因为这样可以更灵活地响应业务规则，以及公司可以推广的商品优惠。最终物品列表的生成过程很直接：推荐增量最高的物品 $R(u_j, i_k)$，其中增量以用户-物品交互概率相对于某物品的基准交互概率来衡量 i_k。

$$R(u_j, i_k) = \frac{P_{u_j}(i_k)}{P(i_k)}$$

其中，$P(i_k)$ 表示随机用户与物品 i_k 发生交互的概率。$R(u_j, i_k)$ 可解释为用户 u_j 与物品 i_k 发生交互的可能性是随机用户的多少倍。

训练过程

图 2 所示神经网络的训练过程，是通过反向传播最小化前文介绍的损失函数来实现的。为了创建输入序列，我们决定将交易划分为两个互不重叠的集合，以便根据任意分析日期获取观测数据和性能数据；该日期可根据业务需求和交互频率设定。然后，可以仅使用观测期内（早于 $Seq(u_j$分析日期）的交易，为所有用户创建输入序列），而目标值则由性能期内（晚于分析日期）的交易构成，如数据预处理部分所示。为所有用户获取序列后，我们进一步将这些数据划分为 80% 用于模型训练，20% 用于结果验证。算法 1 中的伪代码详细说明了数据预处理和模型训练的完整流程。

性能指标

与评估传统分类或回归技术相比，评估推荐系统的复杂程度更高，原因有多种：在隐式反馈场景中，可能无法了解用户对物品的真实偏好，这会导致模型评估产生算法偏差，因为无法像矩阵补全技术那样，使用均方误差等误差指标将模型预测与用户明确给出的评分进行比较。不同的推荐技术也可能因数据集的某些特征而表现出显著差异，例如用户和物品的数量、数据稀疏性、评分尺度等。因此，评估推荐可能需要依赖特定场景指标和人工分析。最后，推荐系统常用的评估指标完全忽略了一个事实：大多数用户可能只是因为不熟悉某些产品而没有机会与之交互，而非缺乏偏好。此外，这些指标仅适用于基于历史用户-物品交互的离线评估，未必适用于生产环境；在生产环境中必须立即测试效率，而设计用于评估推荐性能的在线评估实验可能需要投入更多精力，通常成本也更高。

Fouss 和 Saerens(2009年) 提出通过考虑不同特征来评估推荐系统的性能，例如覆盖率（用于衡量推荐系统能够提供推荐的数据集所占百分比）、计算时间（用于衡量系统能多快为大量用户提供推荐），以及鲁棒性（用于评估数据中加入噪声后模型的表现）。

算法 1序列感知推荐系统伪代码。

输入： 以表格形式呈现的客户交易数据1 包含 '客户*ID*'、'购买日期'、'商品编号'。

输出： 面向用户的商品列表推荐。

数据划分：
- 根据设定的分析日期划分训练数据，得到观察数据和评估交易数据。

- 将全部数据划分为两个互不重叠的客户集合，分别用于训练（80%）和验证（20%）。

数据预处理：
- 使用观测交易数据，为数据集中的每位用户创建 $Seq(u_j)$，其中包含用户 u_j 先前购买物品的按时间排序的商品 ID，具体如数据预处理部分所述。
- 使用性能数据，为每位用户创建目标向量

$$Y_{u_j} = [y_{u_j,i_1}, y_{u_j,i_2}, \ldots, y_{u_j,i_{|I|}}],$$

其中包含性能周期内的用户-物品交互，具体如数据预处理部分所述。

模型训练：
- 使用图2所示的架构、预处理步骤获得的数据以及损失函数部分所述的二元交叉熵作为损失函数，通过反向传播训练序列感知模型。

模型预测：
- 对每个用户，获取其与每个可能推荐的物品交互的概率 ^ ^ ^$P_u = [P_{u_j}(i_1) \ldots, \ P_{u_j}(i_{|I|})]$。

排序过程：
- 对每个用户 u_j 和物品 $i_k \in | \ I' \ |$，根据排序机制部分所述，获取交互概率的估计增量 $R(u_j, \ i_k)$

$$R(u_j, i_k) = \left[\frac{\hat{P}_{u_j}(i_1)}{P(i_1)}, \ldots, \frac{\hat{P}_{u_j}(i_{|I'|})}{P(i_{|I'|})} \right]$$

- 对每位用户，推荐使 $R(u_j, \ i_k)$ 最大的前 K 个物品。

对于本研究而言，这些指标中的某些可能适用于我们的情况，也可能不适用，因为我们试图估计的是用户与物品交互的概率，而不是项目相关性，也不是用户会有多喜欢每个物品。以下章节从技术角度简要概述了用于评估我们方法的模型性能和用户推荐的性能指标。

归一化折损累计增益

由J¨arvelin 和 Kek¨al¨ainen(2002) 提出的归一化折损累计增益（NDCG）是一种广受欢迎的排序质量指标，广泛用于信息检索和推荐系统中，以评估长度为 p 的物品列表。该指标通过信息增益函数（折损累计增益）考量物品的相关程度，其定义如下：

$$DCGp = \sum_{k=1}^{p} \frac{relevance_{i_k}}{log_2(k+1)},$$

此外，它还通过一个折损函数考量列表中相关物品的排序与可能的最佳排序（理想折损累计增益）之间的差异。

$$IDCGp = \sum_{k=1}^{REL_p} \frac{relevance_{i_k}}{log_2(k+1)},$$

其中，REL_p 表示截至位置 p 的所有可能相关物品列表；如果物品与用户相关，则 $relevance_{i_k} = 1$，否则为 0。因此，归一化折损累计增益定义如下：

$$NDCG_p = \frac{DCGp}{IDCGp},$$

其取值范围为 0 到 1，NDCG 值越高，推荐列表中的物品排序就越好。

平均准确率均值

平均准确率均值（MAP）是源自信息检索领域的一种指标，可用于了解一个物品列表相对于所有可能的用户查询有多相关。在推荐系统评估中，该指标

通过计算每个 K物品推荐列表的平均精度（AP@K）均值，来评估这些推荐列表的质量，其定义如下：

$$AP@K = \frac{1}{rel_K} \sum_{k=1}^{K} \frac{\#\text{ of relevant items at k}}{k},$$

其中，rel_K 表示前 K 个结果中相关物品的总数，可理解为推荐列表中对该用户而言相关物品所占的比例。

销售额与收入

如第一节所述，向用户推荐合适物品的主要目标之一，是提高企业的整体销售额与收入 Gunawardana 和 Shani (2009年)，这可以通过在购买订单期间交叉销售相关物品、通过高度个性化的服务推荐促使客户续订订阅，或者向客户展示合适的广告和优惠以鼓励他们采取行动来实现，例如购买原本没有打算购买的物品，或延长购物时间。

在这项工作中，我们旨在预测用户与物品未来发生交互的概率，从而优先推荐最有可能购买的物品，无论用户过去是否已与该物品发生过交互。因此，我们鼓励客户购买企业希望推广的合适物品组合。为了评估我们的方法论相较于其他推荐系统所带来的收入增量（由于知识产权限制，我们无法提供这些系统的任何技术细节），我们与英国一家大型零售商设计并开展了一项实时A/B测试实验，以评估采用我们的方法进行推荐与采用其他推荐系统方案对收入的影响。该实验的结果将在下一节中介绍。

实验与结果

Profusion 是一家位于英国伦敦的数据咨询公司，为英国各地的零售商和金融公司提供数据分析服务。为了增加收入并提升客户参与度，Profusion 运用多种技术进行物品推荐。为了评估该系统的有效性，我们在 Profusion 客户提供的两个真实零售数据集上进行了多项实验。出于保密考虑，我们不会公开这两家零售公司的名称，而是将它们称为 公司*1* 和公司 *2*。

数据集 1:公司*1* - 零售

第一个数据集包含英国一家专营酒精饮料销售的零售商公司*1*的客户交易。抽样数据中的交易总量近 8000 万笔，涵盖 2016年3月至2022年2月期间，300 多万名客户的购买记录。虽然在整个观察期内，客户可购买的不同物品有 10,000 种，但客户在其整个客户生命周期内平均只与其中 24 种物品发生交互，而且很少对购买的物品提供显式反馈。由于数据高度稀疏且缺少任何显式反馈，这带来了与训练推荐系统相关的若干问题。

在离线实验中，我们使用分析日期（2021年9月）之前全部事务数据的 80%，以便获得 6 个月的客户交易数据用于性能评估；并使用分析日期之后的 100% 数据进行评估。公司*1* 的测试结果见表 3。

数据集 2：公司 *2* - 零售

第二个数据集包含英国一家大型建筑设备零售商公司 *2*的交易信息。2020年6月至2022年3月期间，120万名客户共进行了近8000万笔购买。该数据集包含73,000种可能推荐的物品，不过平均而言，每位用户在其生命周期内只会与51种不同的物品发生交互。

与第一个数据集类似，我们仅考虑定义的分析日期（2021年9月）之前80%的客户交易数据，以留出6个月的性能窗口，其余交易用于模型测试。该数据集的模型性能见表3。

数据集 3：开放数据集：***Movielens 25M***

MovieLens 数据集Harper 和 Konstan(2015) 被广泛用于研究和业界，对推荐系统性能进行基准测试。本研究使用的数据版本是由 *GroupLensResearch*提供的 MovieLens 25M，其中包含 1995年1月至2019年11月期间 62,000 部电影和 162,000 位用户的 2,500 万条电影评分。该数据集中的每位用户至少为 20 部电影评分，这缓解了因信息不足而产生的冷启动问题。如前所述，所需的数据预处理不使用评分，因此我们只考虑数据中用户与物品之间的交互。MovieLens 数据集的模型性能见表3。

结果

本节通过比较前文介绍的排序指标，实证展示我们方法的有效性：针对零售业中的三个数据集，将 MAP@1、MAP@10 和 NDCG 与协同过滤和矩阵分解方法进行比较。表 3列出了这项性能评估的详细信息。除离线评估外，我们还通过对 公司*1* 开展实时 A/B 实验，评估该方法对整体收入的影响；实验比较了采用我们方法实现的销售额与采用矩阵分解的另一推荐系统实现的销售额，后者由公司*1*使用。该测试的更多详情将在下一节的表 5中介绍。

值得一提的是，本节中得到的指标 MAP 和 NDCG 仅根据客户在六个月内的历史购买记录计算，未考虑到客户可能并不知道产品目录中所有可供推荐的物品，而只了解热门物品这一事实。这可能会在评估推荐系统中针对冷门物品的用户-物品交互表现时造成机会均等方面的偏差，因为即使这些物品高度相关，用户购买它们的可能性也天生较低。为在解决这一问题的同时，将我们的方法与协同过滤和矩阵分解技术进行比较，我们进行了离线推荐，方法是使用抽样数据集训练所有推荐系统，该数据集不包含各数据集中最热门的 10% 物品的购买记录。本实验的 MAP@1、MAP@10 和 NDCG 指标结果见表4。

实时A/B测试结果。

如前所述，在已知用户评分信息时，通常使用平均绝对误差（MAE）等离线指标评估推荐系统；在无法获得真实用户偏好信息时，则使用 MAP@K 和 NDCG 等排序指标。除了针对 MAP@K 和 NDCG 开展离线评估外，我们还对纳入面向 公司*1* 的电子邮件营销活动中的物品推荐进行了实时 A/B 测试。在该测试中，我们将所提方法与内部推荐系统进行比较；由于无法提供更多细节，只能说明其整体表现与矩阵分解模型相当。该测试仅考察从公司希望在面向超过 500,000 位客户的电子邮件营销活动中推广的 8 种可推荐商品中，排在首位的 1 项物品推荐。其中 6 种物品被视为 公司*1* 的优先物品，如有可能应排在最前；另外两种被视为热门物品，如果没有更合适的推荐，则应作为默认物品发送。两个系统各自的首位推荐以及默认物品，都作为主横幅展示在发送给客户的电子邮件中，如图 3 所示；两种系统的电子邮件组件其余部分（如页眉、图像和邮件中推广的其他物品）均保持不变。

虽然受保密限制，我们无法在排序层面比较这些系统，但可以提供实时测试所用的八种物品中，每种物品的平均购买排名概率。如图 4 所示，我们的推荐系统能够识别出最适合推荐给客户的物品，并以高出 20 至 40 倍的精度，将客户排在排名列表前列。此外，整体销售结果显示，与由公司系统定位的用户相比，由我们的系统定位的用户平均客户收入增加了 51%。

表3 在验证数据集中，训练时采用 20% 的未观测客户，并允许 6 个月的用户-物品交互作为性能周期，通过离线实验获得的推荐性能。

	公司*1*			公司 *2*			*MovieLens*		
	MAP@1	**MAP@10**	**NDCG**	**MAP@1**	**MAP@10**	**NDCG**	**MAP@1**	**MAP@10**	**NDCG**
序列感知	**0.0119**	0.0233	**0.0314**	**0.0354**	0.1003	**0.1559**	**0.0085**	**0.0124**	**0.0160**
协同过滤	0.0111	**0.0265**	0.0215	0.0139	0.1016	0.0607	0.0016	0.0046	0.0067
矩阵分解	0.0014	0.0144	0.0265	0.0146	**0.1143**	0.0643	0.0021	0.0046	0.0063

表4 从移除训练期间最热门的10%物品后获得的子集训练数据集的推荐性能；在观测窗口包含6个月交易的数据集中，对验证数据集中20%未观测客户进行评估。

	公司*1*			公司 *2*			*MovieLens*		
	MAP@1	**MAP@10**	**NDCG**	**MAP@1**	**MAP@10**	**NDCG**	**MAP@1**	**MAP@10**	**NDCG**
序列感知	**0.0051**	0.0078	**0.0095**	**0.0050**	0.0092	0.0141	0.0010	0.0081	0.0177
协同过滤	0.0015	**0.0091**	0.0058	0.0000	**0.0186**	0.0013	**0.0210**	**0.0403**	**0.0535**
矩阵分解	0.0026	0.0055	0.0069	0.0000	0.0053	**0.0162**	0.0000	0.0130	0.0090



图3 在实时A/B测试中发送给客户的电子邮件模板。50% 的客户被选中接收使用矩阵分解的系统 A 的推荐，另外 50% 的客户则接收序列感知推荐。只有没有交易历史的客户才会被纳入默认模板，并向他们展示热门物品。

A/B 测试收入结果的更多详细信息见表 5。

结论

本研究提出了一种创新方法，利用循环神经网络和传统上用于自然语言处理领域、以预测词语的数据预处理方法，在考虑客户历史购买记录的顺序的同时，为每位客户提供物品推荐。尽管序列感知推荐系统已在客户偏好会在短时间内发生剧烈变化的领域得到广泛探索和应用，例如移动应用使用，以及第二节提及的电子游戏应用，但据我们所知，尚无研究将序列感知物品推荐应用于零售业，而本研究第四节所用数据集展示的正是此类应用。

本研究的主要动机是在零售业等场景中进行物品推荐。在这些场景下，第二节介绍的类似矩阵补全的协同过滤方法和矩阵分解方法，因多种不同原因而表现不佳；与此同时，推荐效果至少仍与上述广泛使用的方法相当，尤其是在推荐列表顶部。例如，用户偏好可能随时间迅速变化，或者用户可能反复与特定物品互动，却不提供显式评分。

本研究提出的序列感知推荐系统解决了这些问题，并通过内在地假设物品可能在购买序列中多次出现，且所有物品（包括用户之前购买过的物品）都可能包含在可推荐商品集合中，使预测性能保持在与其他推荐技术相当的水平。这一改变使我们能够实现两个主要目标：首先，无论用户是否已经购买过相关产品，都能为用户找出最合适的产品，从而提高客户参与度。其次，通过识别哪些物品最有可能按顺序被购买，并提供个性化推荐和特别优惠，改善客户旅程。

此外，在生产环境中维护我们的推荐系统的成本低于维护矩阵补全方法的成本，因为后者需要不断更新，以纳入新的用户-物品交互，而

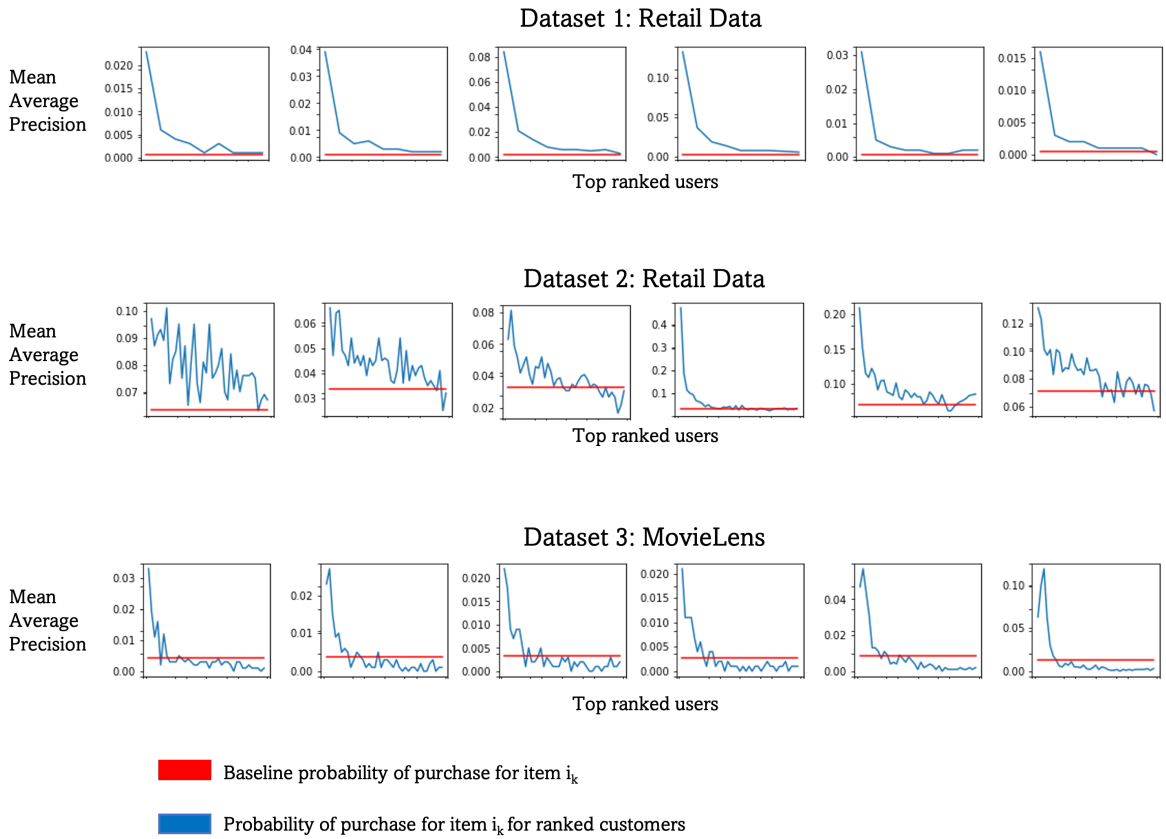

图 4 在每个数据集中随机选取的 6 种产品上的序列感知推荐平均准确率均值。

表5 采用序列感知方法进行物品推荐，与基于矩阵分解的内部推荐系统对比所得的 A/B 测试收入结果。由于需遵守提供数据和实验设置的公司的保密限制，本报告中的销售额已乘以一个随机数，以保护机密信息。

	系统 A：内部推荐系统				系统 B：序列感知推荐系统			
Item	用户数量	响应	总收入	人均收入	用户数量	响应	总收入	人均收入
物品 1	7.0%	1.75%	£13,622	£37.73	4.4%	0.99%	£9,030	£69.44
物品 2	8.8%	1.17%	£13,720	£45.15	8.9%	0.95%	£20,440	£81.76
物品 3	3.7%	0.88%	£2,149	£22.12	16.4%	0.88%	£24,472	£57.05
第4项	11.5%	1.81%	£35,105	£56.70	8.1%	1.02%	£21,042	£85.54
第5项	8.2%	1.49%	£17,003	46.97英镑	9.2%	0.88%	£20,517	85.47英镑
第6项	10.6%	0.88%	£14,294	51.80英镑	6.1%	0.99%	12,719	70.28英镑
项目 7	9.8%	1.27%	£16,079	£43.54	38.9%	0.48%	£25,578	£46.62
物品 8	40.5%	0.60%	£15,981	£22.33	7.9%	0.56%	£672	£5.11
总计	100%	1.05%	£127,953	£41.23	100%	0.73%	£134,470	£62.37

我们的方法只需考虑输入网络的数据发生的变化，这对企业和机器学习工程师而言非常便利。此外，我们的方法生成物品推荐的速度明显快于矩阵补全技术，因为无需改为逐个用户估计偏好，而不是同时估计所有用户和所有物品的偏好。

然而，尽管与第四节所述的基线模型相比，我们的方法取得了出色的性能，但仍存在局限性。由于最终概率

用户-物品交互是根据循环神经网络的 softmax 输出层估算的，因此我们的方法容易受到热门物品所引发的选择偏差影响。在训练期间，特定物品的交互次数极不平衡时，就会出现这种情况；这种不平衡在预测阶段可能不会持续存在，从而影响整体物品排序。此外，在引入新物品进行排序时，我们的方法会受到严重的冷启动问题困扰，因为数据预处理一节中引入的训练目标，是根据每个物品在特定时间段内的数据构建的。最后，如表 4 所示，当每位客户的推荐列表规模较大时，我们的方法可能不是表现最佳的方法；但在目标是基于最新数据找出排名第一的物品的推荐场景中，我们的方法表现更佳。

本文提出的方法论可通过多种方式轻松扩展，以提升物品推荐性能。我们的方法主要着眼于对每位客户的历史购买记录进行编码并捕捉其中的信息，因此目前忽略了用户和物品特征，以及潜在的人工构造特征。这些特征可以轻松添加到神经网络或任何其他可用于进行词元预测的模型的输入中。

声明

资助。 本研究由 Innovate UK、埃塞克斯大学（注册编号：Z699129X）和 Profusion Media LTD（一家在英格兰注册的公司，注册编号为 6947442）通过知识转移合作计划提供支持。

利益冲突。 作者不存在相关的财务或非财务利益冲突。

代码可用性。 本研究的代码属于 ProfusionMedia LTD. 的知识产权，未公开提供。

作者贡献。J.E 负责实现算法、开展数据分析并撰写初稿，B.L. 负责核验结果并监督本项工作。所有作者均对论文进行了修订，阅读并同意发表版本的手稿。

参考文献

Aggarwal, C.C.（2016）。推荐系统：教科书（第1版）。Springer 出版公司股份有限公司。

Baeza-Yates, R., Jiang, D., Silvestri, F., Harrison, B.（2015）。预测你将要使用的下一个应用。第八届 *ACM* 国际网页搜索与数据挖掘会议论文集（第285–294页）。美国纽约州纽约市：计算机协会。取自 https://doi.org/10.1145/2684822.2685302 10.1145/2684822.2685302

Balabanovic,M.,&Shoham,Y.（1997,03）。Fab：基于内容的协同推荐。《*ACM* 通讯》，*40*，66-72。

10.1145/245108.245124

Basu, C., Hirsh, H., Cohen, W.W. (1998年). 将推荐作为分类：在推荐中使用社会信息和基于内容的信息。*AAAI/IAAI*。

Bell, R., Koren, Y., Volinsky, C. (2007年). 通过在多个尺度上建模关系，提高大型推荐系统的准确性。（第95–104页）。美国纽约州纽约市：计算机协会。检索自 https://doi.org/10.1145/1281192.1281206

Bengio, Y., Ducharme, R., Vincent, P., J anvin, C. (2003年3月). 一种神经概率语言模型。机器学习研究期刊，*3*(无)，1137–1155。

Bickel, S., Haider, P., Scheffer, T.（2005年）。使用 n 元语言模型预测句子。人类语言技术与自然语言处理实证方法会议论文集（第 193–200 页）。美国：计算语言学协会。检索自 https://doi.org/10.3115/1220575.1220600

Burke, R.（2002年，11月）。混合推荐系统：综述与实验。用户建模与用户自适应交互，*12*。

10.1023/A:1021240730564

Claypool, M., Gokhale, A., Miranda, T., Murnikov, P., Netes, D., Sartin, M. (1999年). 在在线报纸中结合基于内容的方法和协同过滤器。*ACM SIGIR '99* 推荐系统研讨会论文集：算法与评估。加利福尼亚州伯克利：ACM。

Covington, P., Adams, J., Sargin,E. (2016年). 面向 YouTube 推荐的深度神经网络。第十届 *ACM* 推荐系统会议论文集（第 191–198 页）。美国纽约州纽约市：计算机协会。检索自 https://doi.org/10.1145/2959100.2959190

De Souza Pereira Moreira, G., Rabhi, S., Lee, J.M., Ak, R., Oldridge, E. (2021年). Transformers4rec：弥合自然语言处理与序列式/会话式推荐之间的差距。载于第十五届 *ACM* 推荐系统会议论文集（第 143–153 页）。美国纽约州纽约市：计算机协会。检索自 https://doi.org/10.1145/3460231.3474255 Fouss, F., & Saerens, M. (2009, 01). 评估推荐系统的性能：实验比较。（第 735 - 738 页）。10.1109/WIIAT.2008.252 Gunawardana, A., & Shani, G. (2009, dec). 推荐任务准确率评估指标综述。《机器学习研究杂志》，*10*, 2935–2962. Guy Shani, R.I.B., David Heckerman (2005年). 基于马尔可夫决策过程的推荐系统。《机器学习研究杂志》，*6*(43), 1265-1295. 检索自 http://jmlr.org/papers/v6/shani05a.html

Hariri, N.,Mobasher, B.,Burke, R.（2012年）。上下文感知音乐推荐

基于潜在主题序列模式。第六届 *ACM* 推荐系统会议论文集（第 131–138 页）。美国纽约州纽约市：计算机协会。取自 https://doi.org/10.1145/2365952.2365979

Harper, F.M., & Konstan, J.A. (2015年，12月). MovieLens 数据集：历史与背景。*ACM Trans. Inter-act. Intell. Syst.*, *5*(4)。取自 https://doi.org/10.1145/2827872

He, X., Liao, L., Zhang, H., Nie, L., Hu, X., Chua, T.-S. (2017年). 神经协同过滤。arXiv。取自 https://arxiv.org/abs/1708.05031

Hofmann, T. (2004年，1月). 用于协同过滤的潜在语义模型。*ACM Trans.Inf. Syst.*, *22*(1), 89–115。取自 https://doi.org/10.1145/963770.963774

10.1145/963770.963774

Hu, Y., Koren, Y., Volinsky, C. (2008). 面向隐式反馈数据集的协同过滤。*2008*年 *IEEE* 第八届国际数据挖掘会议（第 263-272 页）。10.1109/ICDM .2008.22 J¨arvelin, K., & Kek¨al¨ainen, J. (2002, oct). 基于累积增益的 IR 技术评估。*ACM* 信息系统汇刊，*20*(4)，422–446。取自 https://doi.org/10.1145/582415.582418 Jazayeriy, H., Mohammadi, S., Band, S. (2018, 01). 面向冷启动用户、利用分类物品的快速推荐系统。《数学与计算应用》，*23*，1。10.3390/mca23010001 Koren, Y., Bell, R., Volinsky, C. (2009). 推荐系统的矩阵分解技术。《计算机》，*42*(8)，30-37。

10.1109/MC.2009.263

Lee, T.Q., Park, Y., Park, Y.-T. (2008). 使用隐式反馈实现有效推荐系统的基于时间的方法。《专家系统与应用》，*34*(4)，3055-3062。取自 https://www.sciencedirect.com/science/article/pii/S0957417407002357 https://doi.org/10.1016/j.eswa.2007.06 .031 Linden, G., Smith, B., York, J. (2003). 亚马逊网推荐：物品到物品的协同过滤。*IEEE* 互联网计算，*7*(1)，76-80。

10.1109/MIC.2003.1167344

Marchand, A., & Marx, P.（2020年）。基于偏好的解释的自动产品推荐。《零售学杂志》，*96*（3），328-343。检索自 https://www.sciencedirect.com/science/article/pii/S0022435920300014 Mikolov, T., Chen, K., Corrado, G., Dean, J.（2013年）。在向量空间中高效估计词语表示。arXiv。检索自 https://arxiv.org/abs/1301.3781 N´u˜nez Valdez, E., Quintana, D., Gonzalez Cre- spo, R., Isasi, P.,Herrera-Viedma, E.（2018年10月）。一种基于隐式反馈的电子书选择性传播推荐系统。《信息科学》，*467*，87-98。

10.1016/j.ins.2018.07.068

Paterek, A.（2007年，01月）。改进用于协同过滤的正则化奇异值分解。*KDD Cup* 论文集与研讨会。Qi, W.、Yan, Y.、Gong, Y.、Liu, D.、Duan, N.、Chen, J.、……Zhou, M.（2020年）。*ProphetNet*：预测序列到序列预训练中的未来 *n*元语法。arXiv。取自 https://arxiv.org/abs/2001.04063

Quadrana, M., Cremonesi, P., Jannach, D.（2018年）。序列感知推荐系统。arXiv。取自 https://arxiv.org/abs/1802.08452

Ravula, P., Jha, S., Biswas, A.（2022年）。在线评论中，重复购买意向相较于推荐的说服力。《零售学杂志》。取自 https://www.sciencedirect.com/science/article/pii/S0022435922000410

Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., Riedl, J.（1994年）。GroupLens：用于网络新闻协同过滤的开放式架构。计算机支持的协同工作领域*1994*年*ACM*会议论文集（第175–186页）。美国纽约州纽约市：计算机协会。取自 https://doi.org/10.1145/192844.192905

Salakhutdinov, R., & Mnih, A.（2007年）。概率矩阵分解。《神经信息处理系统进展》第20届国际神经信息处理系统会议论文集（第1257–1264页）。美国纽约州雷德胡克：Curran Associates Inc.

Smyth, B., & Cotter, P.（2000年）。数字电视时代的个性化电视节目单服务。《Knowledge-BasedSystems》，13(2)，53-59。获取自 https://www.sciencedirect.com/science/ar- ticle/pii/S0950705100000460

Su, X., & Khoshgoftaar, T.M.（2009年1月）。协同过滤技术综述。《人工智能进展》，2009年。获取自 https://doi.org/10.1155/2009/421425

Trofimov, M., Sidana, S., Horodnitskii, O., Laclau, C., Maximov, Y., Amini, M.-R.（2017年，04月）。面向推荐系统中隐式反馈和显式反馈的表示学习与成对排序。

Ungar, L.H., & Foster, D.P.（1998年）。协同过滤的聚类方法。*AAAI 1998*年。

Volkovs, M., Yu, G., Poutanen, T.（2017年）。DropoutNet：解决推荐系统中的冷启动问题。I. Guyon 等（编），《神经信息处理系统进展》（第30卷）。Curran Associates, Inc.。获取自 https://proceedings.neurips.cc/paper/2017/file/dbd22ba3bd0df8f385bdac3e9f8be207-Paper.pdf

Wang, J., & Zhang, Y. (2013年). 电子商务推荐的机会模型：合适的产品；合适的时间。(第 303–312 页). 美国纽约州纽约市：计算机协会。获取自 https://doi.org/10.1145/2484028.2484067

Wang, L. (2012年, 02). 基于统计语言模型将DNA序列切分为词。*Nature Precedings*, *7*。

10.1038/npre.2012.6939.1

Wu, C.-Y., Ahmed, A., Beutel, A., Smola, A.J., Jing, H. (2017年). 循环推荐网络。第十届*ACM*网页搜索与数据挖掘国际会议论文集 (第 495–503 页). 美国纽约州纽约市：计算机协会。获取自 https://doi.org/10.1145/3018661.3018689

Zhang, S., Yao, L., Sun, A., Tay, Y. (2019年, feb). 基于深度学习的推荐系统：综述与新视角。*ACM Comput. Surv.*, *52*(1). 获取自 https://doi.org/10.1145/3285029 Zhao, G., Lee, M.L., Wynne, H. (2014年). 利用潜在簇中的购买间隔进行产品推荐。美国纽约州纽约市：计算机协会。获取自 https://doi.org/10.1145/2659480.2659496

Zhou, X., He, J., Huang, G., Zhang, Y. (2015). 基于SVD 的增量式

推荐系统的方法。《计算机与系统科学杂志》，*81*(4)，717-733。取自 https://www.sciencedirect.com/science/article/pii/S0022000014001706