

doi: 10.7690/bgzdh.2022.10.012

推荐系统发展现状及相关军事应用展望

李 肖, 刘德生, 常 青

(航天工程大学复杂电子系统仿真重点实验室, 北京 101416)

摘要: 针对推荐系统在军事领域的应用, 对推荐系统及现有的推荐算法进行研讨。根据阅读相关文献, 结合智能化技术的发展, 将推荐算法分为: 基于内容、基于协同过滤、混合、基于深度学习和基于知识图谱的推荐, 分别进行解释与分析, 总结出不同推荐算法的特点和优劣性, 并在情报产品分发、作战方案生成、装备体系建设 3 个军事领域进行展望与设想。结果表明, 推荐系统是应对信息化、智能化战争的一个很有价值的发展方向。

关键词: 推荐系统; 协同过滤; 深度学习; 知识图谱

中图分类号: TJ02 **文献标志码:** A

Development Status of Recommender System and Prospect of Related Military Application

Li Xiao, Liu Desheng, Chang Qing

(Complex Electronic System Simulation Key Laboratory, Space Engineering University, Beijing 101416, China)

Abstract: Aiming at the application of recommender system in the military field, the recommender system and the existing recommendation algorithm are discussed. According to the reading of relevant literature, combined with the development of intelligent technology, the recommendation algorithm is divided into: content-based, collaborative filtering, hybrid, deep learning and knowledge mapping recommendation, which are explained and analyzed respectively, and the characteristics, advantages and disadvantages of different recommendation algorithms are summarized. The prospects and assumptions are made in three military fields, namely, the distribution of intelligence products, the generation of operational schemes and the construction of equipment systems. The results show that the recommendation system is a valuable development direction to deal with the information and intelligent war.

Keywords: recommender system; collaborative filtering; deep learning; knowledge map

0 引言

伴随着互联网和信息技术的发展, 从信息匮乏进入到信息爆炸的时代, 虽然信息量的大幅增长满足了社会对于网络时代的需要, 但是面对海量的信息, 信息需求者无法快速获得自己感兴趣的部分, 信息提供者也无法将自己的产品或服务精确推送到需求者手上, 大量无效信息使信息的利用率降低。推荐系统的诞生可以有效地缓解这种信息过载的现象, 根据用户的兴趣和偏好, 将符合特点的物品主动推荐给用户。近几年, 深度学习的浪潮让推荐系统也走上了智能化的道路, 国内外的各大企业都开始使用深度学习技术来搭建推荐系统; 而在 2012 年谷歌提出知识图谱的概念之后, 结合知识图谱的推荐系统也成为了业界热门的研究对象。

在新时代信息化战争背景下, 军事领域同样出现了信息过载现象。随着战争的信息化水平不断提高, 各军兵种、不同武器平台、侦察情报单元等

协同一致, 共同完成作战目标的一体化作战是今后的主流作战形式, 这就导致参与作战的武器装备规模和从中产生的军事信息数量都呈海量化趋势; 因此, 笔者围绕推荐系统和推荐算法相关问题进行描述, 并对推荐系统应用于军事领域的不同方向进行展望。

1 推荐系统发展现状

1.1 推荐系统概述

推荐系统是一种为缓解信息过载问题而产生的一种信息服务技术。如图 1 所示, 推荐系统根据用户历史行为信息来构建用户兴趣模型并向用户推荐其可能感兴趣的信息, 被广泛用于个性化服务领域^[1], 在推荐者和寻求推荐者之间做出良好匹配的能力^[2]。一个推荐系统在进行推荐时有 3 个要素: 用户、物品、推荐算法。

1) 用户(user): 即推荐系统的服务对象。用户

收稿日期: 2022-06-29; 修回日期: 2022-07-28

基金项目: 国防重点基金项目(30504010104)

作者简介: 李 肖(1997—), 男, 河南人, 从事系统建模与仿真研究。E-mail: lixiao19970604@163.com。

产生的交互数据、社交数据、标签以及上下文信息都可以作为推荐系统所需要的数据。

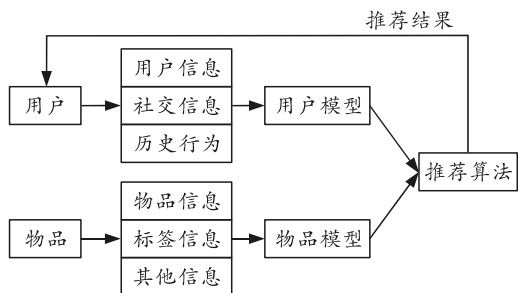


图 1 一般推荐系统

2) 物品 (item)：也被称为项目，是指被推荐的对象，既可以是实际商品，又可以是虚拟商品，还可以是某种服务。

3) 推荐算法：是整个推荐过程的关键部分，根据推荐需求，结合建立的用户模型，将最符合用户偏好的物品推荐给用户。不同的推荐方法原理不同，应用场景也不同。关于推荐算法的研究是推荐领域的研究重点。

1.2 经典推荐算法

1) 基于内容的推荐。

基于内容的推荐方法遵循用户可能会喜欢他之前点击或评价过的物品这一规律，根据用户已经选择过的资源项目的特征信息来进行相应推荐。

首先分析用户已经评价过的物品的特征来获取用户兴趣的描述，之后提取推荐对象的内容特征，与用户的兴趣点进行匹配，选择其中相似度较高的对象推荐给用户，如图 2 所示。




图 2 基于内容的推荐

基于内容的推荐作为一种形式简单、原理直观、易于理解的方法，存在以下优势：1) 不存在数据稀疏问题；2) 推荐结果具有很好的解释性。

特征提取技术存在限制，目前只有对文本信息的提取比较成熟，而对于多媒体信息并不能有效地处理；因此，只能利用在新闻或是网页的推荐中。其次，本方法很难出现新的推荐结果，没有惊喜度。

2) 基于协同过滤的推荐。

1992 年，GlodBerg 等^[3]提出了协同过滤

(collaborative filtering) 的概念，其关键在于通过用户物品的交互矩阵来寻找最近邻居，再通过最近邻居的信息来进行不同形式的推荐结果，也就是交互矩阵补全的过程，如图 3 所示。




图 3 基于协同过滤的推荐

协同过滤推荐算法大体上分为 3 类：基于用户的协同过滤推荐、基于物品 (项目) 的协同过滤推荐和基于模型的推荐。

基于用户的协同过滤推荐算法的主要工作可概括为寻找最近邻居并生成推荐，其关键在于用户之间相似度计算的问题。每个用户对物品的评价可以看作一个 m 维向量，因此计算用户之间的相似度就可以视为不同的 m 维向量间的相似度^[4]。常见的计算相似度的方法有余弦相似性、皮尔逊相关系数等。

计算出相似度之后，即可确定出最近邻居，根据其评分来生成推荐，提高了推荐的惊喜度和丰富性，但存在新用户冷启动问题，并且可解释性不足。

基于物品的协同过滤推荐算法的基本思路与基于用户的协同过滤推荐算法基本一致，以相同的方式计算物品之间的相似性。

基于模型的协同过滤算法利用用户对众多对象的评分来得到一个用户的模型，拟合物品和物品之间的关系，进而对某对象预测打分以实现用户的物品推荐。在实际场景中仅需利用生成的模型进行推荐，减少运算量^[5]。主流的基于模型的方法有机器学习、聚类算法^[6]、矩阵分解^[7]和因子分解机模型^[8]等。

3) 混合推荐。

在实际应用场景中可以针对不同的具体问题采用各种推荐策略的组合来进行推荐，以发挥不同推荐算法各自的优点，避免一定的缺点，提升推荐系统的性能，这种不同推荐方法的组合称为混合推荐方法。

混合推荐总结起来有 2 种思路：1) 推荐结果混合，用不同的推荐算法进行多次推荐，并将其结果按照一定方式进行混合；2) 推荐算法混合，直接在算法层面上进行融合，最后得出一个推荐结果。

1.3 智能化推荐算法

智能化是推荐领域不可避免的趋势，近几年，深度学习在推荐领域也有着重要的应用价值，受到了各大企业与研究团队的青睐。近期，随着知识图谱相关技术的发展，推荐系统与知识图谱的结合也成为了业界研究的重点。

1) 基于深度学习的推荐。

深度学习的优势在于表达能力强，能挖掘出更多数据中潜藏的模式；并且结构十分灵活，可根据不同推荐场景或不同特点的数据来进行调整。

2015 年，澳大利亚国立大学提出了 AutoRec 模型^[9]，是一种单隐层神经网络推荐模型，把协同过滤与自编码器相结合。2016 年，微软提出了 Deep Crossing 模型^[10]，这也是第 1 个最完整的应用深度学习的推荐系统。

谷歌于 2016 年提出了 Wide&Deep 模型^[11]，如图 4 所示。此模型结合了单输入层的 Wide 部分和由嵌入层与多隐层组成的 Deep 部分，能够快速处理并记忆大量历史行为特征，并且具有强大的表达能力。




图 4 Wide&Deep 模型

此后，国内外众多研究团队对该模型进行改进与优化：将 Wide 部分改为交叉网络的 Deep&Cross^[12]；将 Wide 部分替换为因子分解机的

Deep&FM^[13]；在 Deep 部分加入注意力机制的 AFM^[14]；在 Deep 部分加入特征交叉池化层的 NFM^[15]等。此外，采用多层神经网络加输出层的结构替代了矩阵分解模型的基于深度学习的协同过滤模型 NeuralCF^[16]，还有利用强化学习技术的 DRN 模型^[17]。

2) 基于知识图谱的推荐。

知识图谱可以解释为一系列相互连接的实体及其属性，包含边与节点。其中节点为实体或概念，而边则代表 2 个不同实体或概念之间的属性关系。知识图谱中大量实体与关系可以作为一种有效的辅助信息，缓和了冷启动和数据稀疏的问题，并且提升了推荐过程的准确性、多样性和可解释性。

基于知识图谱的推荐方法可以分为 3 类：

一是嵌入法。知识图谱的嵌入 (knowledge graph embedding) 即知识图谱的向量表示，是将知识图谱中的实体和关系映射到连续的向量空间，并包含一些语义层面的信息，方便计算机的理解和后续的应用。之后，依据具体的推荐场景来设计合理的推荐模型，将得到的向量表示作为输入，输出用户对物品兴趣度的预测。

二是路径法。该方法一般构建用户—物品知识图谱，并利用知识图谱中实体的连通性进行推荐，基本思想是考虑到用户和 (或) 物品之间连通相似性 (实体语义相似性)，进而提升推荐效果。

三是结合了嵌入法与路径法，将实体和关系的表示与路径连通信息相结合，根据实体之间的“传播”和用户或物品与邻域之间的网状结构来挖掘用户或物品在知识图谱中的附加信息。

表 1 中总结了目前常见的基于知识图谱的推荐算法。

表 1 基于知识图谱的推荐算法

算法名称	类型	框架
协同知识库嵌入 ^[18] (CKE)	嵌入	自编码器+协同过滤
深度知识感知网络 ^[19] (DKN)	嵌入	卷积神经网络+注意力机制
基于用户-物品知识图的协同过滤 ^[20] (CFKG)	嵌入	协同过滤
知识图谱增强推荐的多任务特征学习 ^[21] (MKR)	嵌入	强化学习+注意力机制
深度知识分解机 ^[22] (DKFM)	嵌入	深度神经网络+分解机
异构信息网络中实体相似性正则化的协同过滤 ^[23] (HeteMF)	路径	矩阵分解
具有隐式用户反馈的异构信息网络中的推荐 ^[24] (HeteRec)	路径	矩阵分解
使用异构关系的基于社交网络的协同过滤推荐 ^[25] (HeteCF)	路径	矩阵分解
知识图谱嵌入方法 ^[26] (RKGE)	路径	循环神经网络+注意力机制
知识路径循环网络 ^[27] (KPRN)	路径	循环神经网络+注意力机制
可解释的交互驱动用户建模 ^[28] (EIUM)	路径	卷积神经网络+注意力机制
推荐系统中用户在知识图谱上的偏好传播 ^[29] (RippleNet)	结合	注意力机制
知识图谱卷积网络 ^[30] (KGCN)	结合	图神经网络+注意力机制
知识图谱注意力网络 ^[31] (KGAT)	结合	图神经网络+注意力机制
个性化推荐的注意力知识图谱嵌入 ^[32] (AKGE)	结合	图神经网络+注意力机制

2 推荐系统军事应用展望

信息化战争要求对数据有良好的应用能力，而推荐技术可以在军事的多个领域，以多个维度去解决信息过载的问题，提高信息的利用率，实现辅助决策以及协助装备体系建设。

2.1 推荐系统在军事情报产品中的应用

随着军事情报收集手段的增加、侦察平台精度的提升以及情报系统处理分析能力的发展，指挥员会获得大量不同类型、不同时空的情报信息，而对于不同军兵种和不同职责的指挥员来说，军事情报的需求也不尽相同。依靠指挥员本身去发掘海量情报中的有效信息是一个繁琐的过程，并且充满了局限性。

情报推荐服务是利用情报系统获取、分析情报用户作战任务过程中的行为和个性化情报需求特征，推导、预测用户的潜在需求，并实时跟踪用户的需求更新情况，主动将用户需要的情报资源提供给情报用户的活动^[33]。推荐技术在其中发挥了重要作用，其过程如图 5 所示。与民用推荐系统相似，情报推荐系统同样利用了交互数据，通过历史记录对用户进行画像，而对于情报来说，则会进行特征学习技术来对情报进行描述，再进行用户偏好与情报的匹配，将匹配度最高的情报作为推荐结果推荐给用户^[34]。




图 5 军事情报推荐基本流程

目前，对于情报推荐服务大多采用了基于内容和基于协同过滤的推荐方法，对于文本型情报，一般用基于内容的推荐方法效果最好，王中伟等^[35]提出了一种基于 ISM 方法的军事文本信息智能推荐技术，并利用分层思想对推荐系统进行了架构设计，构建了军事用户角色的特征层次模型。古秦弋等应用基于内容的推荐技术到雷达情报领域中，提出了基于内容的雷达情报筛选^[36]、推荐^[37]与分发^[38]技术。余苗等^[39]利用层次分析法构建了用户空间，利用基于模型的协同过滤推荐技术的思想，用朴素贝叶斯分类方法挖掘了用户兴趣并建立了模型，实现了雷达情报按需分发。

2.2 推荐技术在任务规划中的应用

推荐技术同样可以应用于指挥控制领域，在作战任务规划时可以利用推荐技术来帮助决策者拟制任务，起到辅助决策的作用。

任务规划技术是指在统一的战略指导下，从战略、战役、战术到技术层次，对作战资源、运用方式、作战目标、作战进程、作战行动、作战路线等进行综合筹划和详细设计的过程^[40]，其过程如图 6 所示。而作战方案生成是指挥控制过程中必不可少的一步，更是作战任务规划流程中的重要环节。

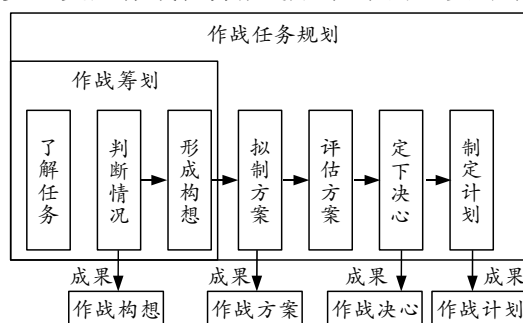


图 6 作战任务规划过程

影响作战的要素有很多，而在定下作战决心并确立作战构想后，需要选择合适的武器装备并生成一些可行的作战方案来进行评估。在面对海量且关系复杂的可用装备资源时，指挥员会出现知识储备不足或是知识迷失的情况，而推荐技术可以帮助指挥员选出适应于当前使命任务的装备，帮助指挥员生成作战方案。笔者认为，在该场景下使用基于知识图谱的推荐系统，如图 7 所示。

知识图谱有良好的数据表达能力和灵活的建模性，可以很好地处理关联密集数据，将海量的资源有机结合起来，以直观立体的方式展现，并且可以提高推荐的准确性和可解释性，更能满足作战的要求。针对目前已有的武器装备资源，可以构建相应的知识图谱作为推荐物品的基础，然后进行使命任务分解，得到可以被作战平台所理解的元任务。之后，将元任务作为用户，通过基于知识图谱的推荐算法，针对不同的作战任务需求，推荐出对应的装备，辅助作战方案的生成。在实际作战中，武器装备的选择和运用是一个复杂的约束问题；因此，武器装备类型以推荐系统为主，而武器装备数量则以规划模型为主。

由于作战的特殊性，作战方案对推荐系统也有更高的要求：1) 更强的准确性和可解释性。前文提到过，知识图谱可以提高这 2 项性能；此外，还可

以通过算法的设计或优化, 得到一种适应作战的推荐算法。2) 结合更多因素, 在生成作战方案时, 还要考虑战场态势等诸多因素, 如果可以结合这些因素进行可用资源的推荐, 可以进一步提高辅助决策

的能力。3) 实时性的要求, 在作战条件下, 可用资源与使命任务可能随着战场情况而发生变动; 因此, 如何在频繁更新的情况下进行实时推荐也是一个值得发展的方向。

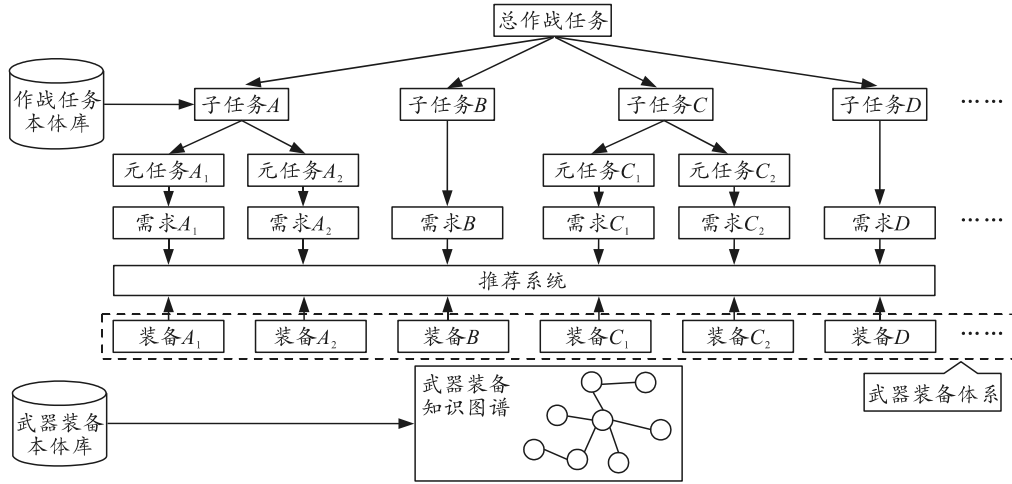


图 7 推荐系统应用于作战方案生成

2.3 推荐技术在武器装备体系建设中的应用

在《中国军事百科全书》中, 武器装备体系的定义为: 武器装备体系是武器装备在高度机械化基础上, 通过数字化和网络化集成等信息化技术改造, 实现整体结构和功能一体化的新形态; 现代武器装备体系是由功能上相互关联的战斗装备、综合电子信息系统、保障装备等装备系统构成的有机整体。

武器装备体系是现代信息化战争的物质基础。信息化条件下的现代战争呈现出的体系对抗特征, 作战的使命任务更加复杂多样, 对武器装备体系的体系结构灵活性和作战能力适应性都提出了更高的要求。武器装备体系的建设必须从上述要求出发, 实现从作战使命-作战任务-作战能力-装备体系的合理映射, 构架满足作战需求的武器装备体系。目前, 通常采用基于需求工程思想和体系结构方法实现武器装备体系的顶层设计, 映射过程过度依赖专家的知识经验。利用推荐系统, 根据典型作战应用场景构建作战需求知识图谱, 根据作战任务目标, 自动分解形成作战能力需求空间, 并据此推荐满足各项作战能力指标要求的装备类型、装备战技指标, 为构建高效、灵活、鲁棒的武器装备体系提供参考。

3 结论

笔者围绕推荐系统这一领域, 对推荐系统以及现有不同类型的推荐算法进行了归纳总结, 并对推荐系统在不同军事领域的应用进行了展望, 对利用推荐系统服务于信息化智能化作战的可能性进行探

讨。结果表明, 推荐系统可以很好地解决信息过载问题, 提高信息利用率。

参考文献:

- [1] 高建煌. 个性化推荐系统技术与应用[D]. 合肥: 中国科学技术大学, 2010.
- [2] RESNICK P, VARIAN H R. Recommender systems[J]. Communications of the Acm, 1997, 40(3): 56-58.
- [3] GOLDBERG D, NICHOLS D, OKI B M, et al. Using collaborative filtering to weave an information tapestry[J]. Communications of the Acm, 1992, 35(12): 61-70.
- [4] 王国霞, 刘贺平. 个性化推荐系统综述[J]. 计算机工程与应用, 2012, 48(7): 66-76.
- [5] BREESE J S, HECKERMAN D, KADIE C. Empirical Analysis of Predictive Algorithms for Collaborative Filtering[J]. Uncertainty in Artificial Intelligence, 2013, 98(7): 43-52.
- [6] 肖晓丽, 钱娅丽, 李旦江, 等. 基于用户兴趣和社交信任的聚类推荐算法[J]. 计算机应用, 2016, 36(5): 6.
- [7] KOREN Y, BELL R, VOLINSKY C. Matrix Factorization Techniques for Recommender Systems[J]. Computer, 2009, 42(8): 30-37.
- [8] RENDLE S. Factorization Machines[C]//IEEE International Conference on Data Mining. IEEE, 2010.
- [9] SUVASH, ADITYA, SCOTT, AutoRec: Autoencoders Meet Collaborative Filtering[C]//International Conference on World Wide Web. ACM, 2015.
- [10] SHAN Y, HOENS T R, JIAO J, et al. Deep Crossing: Web-Scale Modeling without Manually Crafted Combinatorial Features[C]//the 22nd ACM SIGKDD International Conference. ACM, 2016.
- [11] CHENG H T, KOC L, HARMSSEN J, et al. Wide & Deep

- Learning for Recommender Systems[C]//Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. ACM, 2016.
- [12] WANG R, FU B, FU G, et al. Deep & Cross Network for Ad Click Predictions[C]//ADKDD'17. ACM, 2017.
- [13] GUO H F, TANG R M, YE Y M, et al. Deep FM: a factorization-machine based neural network for CTR prediction[EB/OL]. (2017-03-13). <https://arxiv.org/abs/1703.04247>.
- [14] XIAO J, YE H, HE X N, et al. Attentional factorization machines: Learning the weight of feature interactions via attention networks[C]. arXiv preprint arXiv, 2017: 1708.
- [15] HE X, CHUA T S. Neural factorization machines for sparse predictive analytics[C]. Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR '17), 2017: 355-364.
- [16] HE X, LIAO L, ZHANG H, et al. Neural Collaborative Filtering[C]. WWW'17: Proceedings of the 26th International Conference on World Wide Web, 2017: 173-182.
- [17] ZHENG G J. DRN: A deep reinforcement learning framework for news Recommender[C]. Proceedings of the 2018 World Wide Web Conference. International World Wide Web Conferences Steering Committee, 2018.
- [18] ZHANG F, YUAN N J, LIAN D, et al. Collaborative knowledge base embedding for recommender systems[C]. Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, 2016: 353-362.
- [19] WANG H, ZHANG F, XIE X, et al. DKN: Deep knowledge-aware network for news recommendation[C]. Proceedings of the 2018 World Wide Web Conference, 2018: 1835-1844.
- [20] ZHANG Y, AI Q, CHEN X, et al. Learning over knowledge-base embeddings for recommendation[C]. arXiv preprint arXiv, 2018: 1803.06540.
- [21] WANG H, ZHANG F, ZHAO M, et al. Multi-Task Feature Learning for Knowledge Graph Enhanced Recommendation[C]//The World Wide Web Conference. IEEE, 2019: 2000-2010.
- [22] DADOUN A, TRONCY R, RATIER O, et al. Location embeddings for next trip recommendation[C]//Companion Proceedings of The 2019 World Wide Web Conference. ACM, 2019: 896-903.
- [23] YU X, REN X, GU Q, et al. Collaborative filtering with entity similarity regularization in heterogeneous information networks[C]//IJCAI HINA. IEEE, 2013.
- [24] YU X, REN X, SUN Y, et al. Recommendation in heterogeneous information networks with implicit user feedback[C]//Proceedings of the 7th ACM conference on Recommender systems. ACM, 2013: 347-350.
- [25] LUO C, PANG W, WANG Z, et al. Hete-cf: Social-based collaborative filtering recommendation using heterogeneous relations[C]//2014 IEEE International Conference on Data Mining. IEEE, 2014: 917-922.
- [26] SUN Z, YANG J, ZHANG J, et al. Recurrent knowledge graph embedding for effective recommendation[C]//Proceedings of the 12th ACM Conference on Recommender Systems. ACM, 2018: 297-305.
- [27] WANG X, WANG D, XU C, et al. Explainable reasoning over knowledge graphs for recommendation[C]//Proceedings of the AAAI Conference on Artificial Intelligence. IEEE, 2019: 5329-5336.
- [28] HUANG X, FANG Q, QIAN S, et al. Explainable Interaction-driven User Modeling over Knowledge Graph for Sequential Recommendation[C]//Proceedings of the 27th ACM International Conference on Multimedia. ACM, 2019: 548-556.
- [29] WANG H, ZHANG F, WANG J, et al. Ripplenet: Propagating user preferences on the knowledge graph for recommender systems[C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management. ACM, 2018: 417-426.
- [30] WANG H, ZHAO M, XIE X, et al. Knowledge graph convolutional networks for recommender systems[C]//The World Wide Web Conference. IEEE, 2019: 3307-3313.
- [31] WANG X, HE X, CAO Y, et al. KGAT: Knowledge Graph Attention Network for Recommendation[J]. arXiv preprint arXiv: 1905.07854, 2019.
- [32] SHA X, SUN Z, ZHANG J, et al. Attentive knowledge graph embedding for personalized recommendation[J]. arXiv preprint arXiv: 1910.08288, 2019.
- [33] 刘如, 唐磊, 吴晨生, 等. 基于情报主动推送服务的用户管理模型研究[J]. 竞争情报, 2016, 12(5): 10-16.
- [34] 黄志良, 申远, 胡彪, 等. 军事情报推荐技术发展综述[J]. 科学技术与工程, 2020, 20(15): 5900-5909.
- [35] 王中伟, 袁杭萍, 孙毅, 等. 面向军事信息服务的智能推荐技术[J]. 指挥控制与仿真, 2019(4): 114-119.
- [36] 古秦弋, 杨瑞娟, 黄美荣. 基于内容相似度的雷达情报筛选技术[J]. 空军预警学院学报, 2017, 31(3): 190-193.
- [37] 古秦弋, 杨瑞娟, 黄美荣. 基于加权内容相似度的雷达情报推荐技术研究[J]. 空军预警学院学报, 2017, 31(6): 427-431.
- [38] 古秦弋, 杨瑞娟, 黄美荣, 等. Relief F 内容相似度的雷达情报按需分发[J]. 现代防御技术, 2018, 46(3): 184-190.
- [39] 余苗, 杨瑞娟, 程红斌, 等. 基于 Naive Bayes 算法的雷达情报分发技术[J]. 现代雷达, 2014, 36(7): 46-50, 53.
- [40] 牛鹏飞, 孙硕. 对作战任务规划的理解与思考[C]//第六届中国指挥控制大会论文集(上册). 北京: 中国指挥控制学会, 2018: 210-251.