
融合评分和评论的推荐系统研究综述报告

推荐系统[1]一直以来是一个活跃的研究课题。很多研究是在用户提供显式评分反馈的情况[19,20]。但是在现实世界的场景中大多数反馈不是显式反馈，而是隐式反馈[9]。自动跟踪隐式反馈，例如监控点击，浏览时间，购买记录等。这些信息更容易收集，因为用户不必明确地表达其品味。如今隐式反馈已经在几乎任何信息系统中都可用，例如 Web 服务器在日志文件中记录任何访问的页面。

项目推荐是预测一组项目（例如，网站，电影，产品）上的个性化排名的任务。最常见的隐式反馈例如点击，购买。存在用于从诸如矩阵分解（MF）[19]或自适应 K 近邻的隐式反馈的项推荐的许多方法。[20]和[28]提出了一种用于从隐式反馈的项目预测的矩阵分解方法 WR-MF（Weighted Regularized Matrix Factorization）。即使这些方法是针对个性化排名的项目预测任务而设计的，但是它们没有一个被直接针对排名进行优化。因此，必须通过解释用户的行为信息，即隐式用户反馈来近似当前用户的偏好。相应地，在文献中已经提出了许多在推荐过程中利用隐式用户反馈的方法[4,9,37,51]。在这些情况下，通过解释用户行为来估计用户的真实偏好。用户通常将解释诸如项目购买或浏览项目的用户动作一段时间作为对项目感兴趣的符号。

1. 基于隐式反馈的推荐

近年来，已经开发了许多技术以更好地处理隐式用户反馈，为了处理隐式反馈，几个数值优化框架：（1）将置信水平与偏好值相关联[28]，对于非观察的关联具有“0”偏好。（2）考虑成对比较[37]，在优选和选择的非优选实例之间进行。（3）只考虑首选项[41]。在后两种情况下的推荐问题被制定为“学习排名”问题，其中目标是平滑的，性能指标如 AUC，MRR[2]等。[41]中的推荐是处理隐式反馈的基础。SVD ++方法[51]将隐式和显式反馈集成在矩阵分解模型中[52]，并且能够处理时间信息。[4]展示了如何将有关项目内容的附加信息集成到 SVD ++。贝叶斯个人化排名（BPR）[37]是一种 CF 方法，旨在处理隐式反馈。在 BPR 方法中，在训练阶段进行项目之间的成对比较，并且如果用户以某种形式与 i 而不与 j 进行交互，则项目 i 被认为优于项目 j。当与高度精确的基于 SVD ++方法[51]比较时，BPR 的一个特殊性在于其直接目的在于优化排序标准，而 SVD ++主要旨在使预测误差最小化。因此，BPR 可以被认为属于“学习排序”方法[50]的类别，由于它们的设计，通常能够胜过设计用于误差最小化的方法，例如准确率，召回率或 nDCG 等排名度量[2]。在 BPR 方法中，输入包括用户-项目评分矩阵，然而其仅捕获积极的交互一元反馈，即当用户已经与项目存

在使用从隐式评级导出的成对偏好来优化 AUC 的排名标准，并且展示出了如何将该优化应用于 kNN 和矩阵分解推荐模型类别。BPR 模型的限制是它仅支持离散的一元反馈。但是在现实世界的应用中，隐式反馈不一定限于这样的二进制决定，例如存在不同类型的用户动作，比如项目浏览，购物车或购买动作，并且随着时间可以存在针对项目的若干动作。在实践中，一些类型的用户交互可以被认为是比其他类型更强的感兴趣的信号。购买操作可能比查看操作更强。对项目的多次点击可能比单次点击更具指示性，最近的浏览行动可能比过去更相关。BPR 属于“一类协同过滤”[20]方法，能够从正向反馈解释用户行为。同时，通过例如 AUC 优化标准，BPR 可以被认为是一个“学习排名”方法。另一种学习方法是 xCLiMF [40]，是 CLiMF[41]的改进方法，它使用分级的相关性量表，并优化排名标准，在这种情况下是预期互惠排名。BPR 方法纳入了时间和最近信息。与其他时间感知的 CF 方法相反，考虑时间方面仅是一种可能的合并分级相关反馈的方式。在文章中使用项目上的交互计数作为另一种可能的分级反馈形式。类似于[54]中提出的概率方法，其可以在学习偏好项时使用交互频率信息。例如在[35,49,53]中提出了对基本 BPR 方案的扩展。在[49]中，介绍了一种策略，根据负面项目的全局受欢迎度对负面项目的影响加权。在[53]中，作者将其他社交网络信息整合到 BPR 中。与我们的工作不同，他们的方法直接影响权重学习方法。[37]提出了一个替代抽样策略，旨在静态或自适应地确定最丰富的对。BPR ++ [43]是对 BPR 的扩展，考虑了各种形式的这种分级的隐式反馈。BPR++用于处理更细粒度，分级的偏好关系。主要思想是首先使用可用的“重要性”信息从数据中导出另外的成对偏好，并且在优化阶段，偏置优化过程以从这些另外可用的数据点绘制一定量的样本。提出在个性化排名过程中以更加细粒度的水平包含隐式反馈信号。因此，该方法允许区分任意类型的反馈，例如考虑时间和新近度方面。对于所考虑的域，与原始 BPR 方法相比，可以提高检索精度，并且可以实现更快的收敛。但是该方法并不是组合不同类型的用户反馈的方法，需要一个混合方法，进一步研究时间效应，并且观察所生成的推荐列表的其他特征，例如多样性和流行偏差。虽然许多现有的方法已经研究了如何使用社交连接来建立更好的模型用于评级预测，但很少有人使用社交连接作为获得更准确的基于排名的模型。社会贝叶斯个性化排名（SBPR）模型[11]使用社交连接来更好地估计用户的产品排名。

2.冷启动问题

从未被用户观看的推荐项目是基于协作过滤（CF）的推荐算法的瓶颈。为了缓解这个问题，项目内容表示（主要是文本形式）已经被用作学习潜在因子表示的辅助信息。矩阵分

解的潜在因子表示携带关于将用户和项目的情感因子的有价值的信息。从视频情感建模的角度建立有效的推荐系统来研究这些潜在因子。[5]提出了一种基于建模用户和项目之间的情感联系的学习潜在因子表示视频的新方法。并提出了一个比较分析的情感建模方法，基于潜在因子表示在视频内容的情感建模的功效，提出 visual-CLiMF[5]方法用于基于隐式反馈学习冷启动视频的潜在因子表示。Visual-CLiMF 是基于流行的 CLiMF[41]的方法，但表明项目的情感方面可以用作辅助信息，以提高 MRR 性能。这是一种将辅助内容信息与协同信息结合起来解决视频推荐中的冷启动问题的新方法。还提出了一个比较验证的基于矩阵因子的潜在因子表示在模拟情感反应视频的功效。

3.潜在因子模型

潜在因子携带的辨别信息显然是可用的协同信息的量的函数。矩阵分解非常成功地应用于显式和密集的用户项目协同信息[42]。在大多数实际情况下，协同信息是隐式的（仅正反馈）和稀疏的，这导致降低的推荐性能。因此，虽然[25,38]结合显式协同信息与内容信息，处理隐式反馈的作品只与这项工作有关。

很多方法考虑了潜在因子表示携带某种形式的情感反应信息，用于建立基于句法和中级语义信息的情感反应的内容。研究人员已经提出了用于建模对内容（文本[23]，音频[24]，图像[22]，视频[44]）的情感反应的几种方法。研究潜在因子表示所携带的抽象情感因子的动机，[30,31] 研究基于潜在因子携带关于用户对项目的感情连接的某种形式的信息。但他们都面临一些根本的挑战。因为手动标记是昂贵的，并且标签的抽象性质导致不可靠的标签，所以用于情感建模的标签数据集非常少，并且太小[26,47]。因此，大多数标记的数据集可用于非常积极或消极的情感反应。另外，如果它们不是手动创建的，则通过查询与他们相关联的具有非常积极或消极情感的内容来创建它们[29]。在[32]中提出了一组基于情感计算研究的低级特征。作为对语义特征的研究[22]提出了基于 2089 个形容词名词对的标签集的情感建模管道，这些名词对本质上是非常积极的或非常负面的。在[34]中提出了应用于视频情感建模的情感特征表示的详细分析。在[36]中，作者提出了通过上述特征工程方法学习的特征表示的效率与通过使用深非线性网络学习的表示相比较的比较分析。尽管深度非线性表示被显示为优于传统的基于特征工程的方法，但是没有过度拟合的学习深度网络需要大量的训练数据，这在情感建模场景中通常是不可用的。另一方面，使用已经被证明对于检测图像/视频中的视觉概念非常有用的现成的深层特征表示不能很好地概括用于情感建模。作为推荐视频的基础，[39]研究了影响用户“喜欢”视频的情感因素。学习有效的潜在因子在协

作过滤中起着最重要的作用。基于矩阵分解技术的传统 CF 方法从用户项目评级中学习潜在因子，但是存在冷启动以及稀疏问题。一些改进的 CF 方法通过并入辅助信息作为正则化来丰富对潜在因子的先验。然而，由于评级和辅助信息的稀疏性质，所学习的潜在因子可能不是非常有效。为了解决这个问题，通过深度学习来学习有效的潜在表示是一种重要的方法。深度学习模型已经在许多应用中学习有效表示方面非常有吸引力。[10]通过将矩阵因式分解与深度特征学习相结合，提出了用于 CF 的通用深层架构。通过将概率矩阵分解与边缘化去噪叠加自动编码器相结合，提供了该架构的实例。

4.特征工程与标签

良好的基于特征工程的方法需要包含内容如何影响用户的知识，这是一个巨大的挑战，因为这涉及到问题的抽象和主观性质以及情感的维度。虽然有时它可能看起来相对更容易确定一些视频诱发的情感，这是很难针对大多数用户。例如，难以准确地确定在没有与情感相关联的强正或负的情况下经历的情感，这使得使用显式标签创建带标签的数据集有的时候并不可靠[5]。因此，用于情感建模的大多数现有的大部分数据集是基于高度积极或高度消极的情感类别。它们通过使用术语作为查询来创建，以搜索可能具有诸如标签的术语的图像或视频。但这存在问题，例如，“愤怒”一词可能会返回“愤怒的小鸟”的视频，这可能不需要做任何事情所表现的情感[29]，这说明了获取监督信息来模拟情感的挑战。使用深层网络作为特征工程的替代方法的学习表示需要大量标记的训练数据，因此受到缺乏监督信息[34]的可用性的限制。

5.推荐系统中的情感建模

推荐系统中的情感建模指的是自动估计内容将从用户接收的预期情绪反应的问题，而不是主观反应。基于情感模型的三个现有视觉特征的代表分别是，情感特征[32]，sentibank 特征[22]，混合 CNN 特征[48]，且都可以用基于 MF 的潜在因子[41]表示。[33]利用 Amazon 产品数据集构建主题模型，经过训练后可以自动从预测和解释这种关系的文本中发现主题。用于情感预测的现有神经网络方法通常仅捕获文本的语义，但忽略表达情绪的用户。这对于评论评级预测是不期望的，因为每个用户对如何解释评论的文本内容具有影响。例如，当由不同用户写时，相同的词（例如“好”）可以指示不同的情绪强度。[8]提出一个神经网络方法预测评论等级，将特定词的意义对用户特定修改考虑在内，扩展词汇语义组成模型并引入用户词组成向量模型（UWCVM），它有效地捕获用户如何作为影响连续词表示的函数。最后将 UWCVM 集成到一个监督学习框架，用于评估等级预测。

6.数据稀疏性问题

为了解决数据稀疏性问题，使用内容（视觉[27]，文本[45,46]）和上下文[21]辅助信息来改善推荐的性能。但是，不清楚如何从内容提取的句法信息翻译成可以有助于改进偏好预测的高级语义信息。[46]旨在学习文本数据的深度语义表示。对于数据稀疏性问题，协作主题回归（CTR）是一种有吸引力的方法，但是当辅助信息非常稀疏时，通过 CTR 学习的潜在表示可能不是非常有效。为了解决这个问题，[9]提出一种称为协作深度学习（CDL）的分层贝叶斯模型，该模型联合执行内容信息的深度表示学习和评级（反馈）矩阵的协同过滤。

7.深度学习与协同过滤

近些年来，神经网络成为研究的热点，深度学习方法结合协同过滤方法成为推荐领域研究的重要方法。神经网络可以很大程度上替代特征工程的过程，自动化地完成特征的提取。YouTube 代表了现有最大规模和最复杂的工业推荐系统之一，但依然注重由深度学习带来的性能改进[6]。矩阵因式分解通过简单的固定函数即作为对于对应的行和列的潜在特征向量的内积来近似矩阵的条目。[16]使用一个任意函数替代内积，在学习潜在特征向量的同时从数据中学习，用多层前馈神经网络替换内积，并通过交替优化固定潜在特征的网络和优化固定网络的潜在特征来学习。[18]提出了卷积矩阵分解（ConvMF），一种上下文感知推荐模型，将卷积神经网络（CNN）集成到概率矩阵分解（PMF），以此来捕获文档的上下文信息。虽然稀疏输入受到很少的关注，但仍然是神经网络中一个具有挑战性的问题。[15]介绍了一个神经网络架构，从稀疏评级输入计算非线性矩阵分解。基于自动编码器的架构被证明是有前景的一种方法。[13]通过使用适用于输入具有缺失值的数据的损失函数，以及通过并入边信息来增强自动编码器架构。实验表明边信息仅仅略微改善了对所有用户/项目的平均测试误差，但它对冷用户/项目具有更大的影响。[17]提出协作去噪自动编码器（CDAE）方法，使用去噪自动编码器得到 Top-N 推荐。[14]提出了 AutoRec，一种用于协同过滤（CF）的新型自动编码器框架，AutoRec 是紧凑和高效的训练模型。在线服务在很大程度上依赖于自动个性化来向大量用户推荐相关内容，这要求系统迅速扩展以适应第一次访问在线服务的新用户流。[7]提出一个基于内容的推荐系统，以解决推荐质量和系统的可扩展性，根据他们的网络浏览历史和搜索查询使用丰富的功能集来表示用户。并使用深度学习方法将用户和项目映射到潜在空间，其中用户及其首选项目之间的相似性被最大化，通过引入多视图深度学习模型来扩展模型，以共同学习来自不同领域和用户特征的项目的特征。

混合推荐模型是场景的应用方法，组合几个模型会比单个模型有更好的表现结果。[3]通过区分用户的不同评分模式开发设计偏好模型，然后将其应用于 CF 算法。结合现有的三种 CF 算法（诸如基于用户的，基于项目的和基于矩阵分解的算法），来解决推荐系统中向目标用户检索前 N 项的排名列表的问题。[12]将点击响应和购买活动之间的时间动态模型化为统一的框架，提出了一种称为动态集合矩阵分解（DCMF）的新的矩阵分解方法来解决点击和转化率问题。

9.总结

尽管推荐领域取得了很大进展，当前推荐系统仍然需要进一步进行必要的改进以使推荐方法更有效并且更适用于广泛的实际应用。不同推荐方法有各自的优缺点，需要通过混合的方法，结合各种方法的优点，弥补不足，最终达到良好的推荐效果。

引用

- [1] Ricci F, Rokach L, Shapira B. Introduction to recommender systems handbook[M]. Springer US, 2011.
- [2] Shani G, Gunawardana A. Evaluating recommendation systems[M]//Recommender systems handbook. Springer US, 2011: 257-297.
- [3] Lee J, Lee D, Lee Y C, et al. Improving the accuracy of top-N recommendation using a preference model[J]. Information Sciences, 2016, 348: 290-304.
- [4] Manzato M G. gSVD++: supporting implicit feedback on recommender systems with metadata awareness[C]//Proceedings of the 28th Annual ACM Symposium on Applied Computing. ACM, 2013: 908-913.
- [5] Roy S, Guntuku S C. Latent Factor Representations for Cold-Start Video Recommendation[C]//Proceedings of the 10th ACM Conference on Recommender Systems. ACM, 2016: 99-106.
- [6] Covington P, Adams J, Sargin E. Deep neural networks for youtube recommendations[C]//Proceedings of the 10th ACM Conference on Recommender Systems. ACM, 2016: 191-198.
- [7] Elkahky A M, Song Y, He X. A multi-view deep learning approach for cross domain user modeling in recommendation systems[C]//Proceedings of the 24th International Conference on World Wide Web. ACM, 2015: 278-288.
- [8] Tang D, Qin B, Liu T, et al. User modeling with neural network for review rating prediction[C]//Proceedings of the 24th International Conference on Artificial Intelligence. AAAI Press, 2015:

1340-1346.

[9] Oard D W, Kim J. Implicit feedback for recommender systems[C]//Proceedings of the AAAI workshop on recommender systems. 1998: 81-83.

[10] Li S, Kawale J, Fu Y. Deep collaborative filtering via marginalized denoising auto-encoder[C]//Proceedings of the 24th ACM International on Conference on Information and Knowledge Management. ACM, 2015: 811-820.

[11] Zhao T, McAuley J, King I. Leveraging social connections to improve personalized ranking for collaborative filtering[C]//Proceedings of the 23rd ACM International Conference on Conference on Information and Knowledge Management. ACM, 2014: 261-270.

[12] Li S, Kawale J, Fu Y. Predicting user behavior in display advertising via dynamic collective matrix factorization[C]//Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2015: 875-878.

[13] Strub F, Gaudel R, Mary J. Hybrid Recommender System based on Autoencoders[C]//Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. ACM, 2016: 11-16.

[14] Sedhain S, Menon A K, Sanner S, et al. Autorec: Autoencoders meet collaborative filtering[C]//Proceedings of the 24th International Conference on World Wide Web. ACM, 2015: 111-112.

[15] Strub F, Mary J. Collaborative Filtering with Stacked Denoising AutoEncoders and Sparse Inputs[C]//NIPS Workshop on Machine Learning for eCommerce. 2015.

[16] Dziugaite G K, Roy D M. Neural Network Matrix Factorization[J]. arXiv preprint arXiv:1511.06443, 2015.

[17] Wu Y, DuBois C, Zheng A X, et al. Collaborative denoising auto-encoders for top-n recommender systems[C]//Proceedings of the Ninth ACM International Conference on Web Search and Data Mining. ACM, 2016: 153-162.

[18] Kim D, Park C, Oh J, et al. Convolutional Matrix Factorization for Document Context-Aware Recommendation[C]//Proceedings of the 10th ACM Conference on Recommender Systems. ACM, 2016: 233-240.

[19] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems[J]. Computer, 2009, 42(8): 30-37.

-
- [20] Pan R, Zhou Y, Cao B, et al. One-class collaborative filtering[C]//2008 Eighth IEEE International Conference on Data Mining. IEEE, 2008: 502-511.
- [21] Baltrunas L, Ludwig B, Ricci F. Matrix factorization techniques for context aware recommendation[C] //Proceedings of the fifth ACM conference on Recommender systems. ACM, 2011: 301-304.
- [22] Borth D, Chen T, Ji R, et al. Sentibank: large-scale ontology and classifiers for detecting sentiment and emotions in visual content[C]//Proceedings of the 21st ACM international conference on Multimedia. ACM, 2013: 459-460.
- [23] Cambria E, Fu J, Bisio F, et al. AffectiveSpace 2: Enabling Affective Intuition for Concept-Level Sentiment Analysis[C]//AAAI. 2015: 508-514.
- [24] Elshenawy A K, Carter S, Braga D. It's Not Just What You Say, But How You Say It: Multimodal Sentiment Analysis Via Crowdsourcing[C]//Third AAAI Conference on Human Computation and Crowdsourcing. 2016.
- [25] Forbes P, Zhu M. Content-boosted matrix factorization for recommender systems: experiments with recipe recommendation[C]//Proceedings of the fifth ACM conference on Recommender systems. ACM, 2011: 261-264.
- [26] Guntuku S C, Scott M J, Ghinea G, et al. Personality, Culture, and System Factors-Impact on Affective Response to Multimedia[J]. arXiv preprint arXiv:1606.06873, 2016.
- [27] He R, McAuley J. VBPR: visual bayesian personalized ranking from implicit feedback[J]. arXiv preprint arXiv:1510.01784, 2015.
- [28] Hu Y, Koren Y, Volinsky C. Collaborative filtering for implicit feedback datasets[C]//2008 Eighth IEEE International Conference on Data Mining. Ieee, 2008: 263-272.
- [29] Jiang Y G, Xu B, Xue X. Predicting Emotions in User-Generated Videos[C]//AAAI. 2014: 73-79.
- [30] Kim J, Yoo J B, Lim H, et al. Sentiment Prediction Using Collaborative Filtering[C]//ICWSM. 2013.
- [31] Li F, Wang S, Liu S, et al. SUIT: A Supervised User-Item Based Topic Model for Sentiment Analysis[C]//AAAI. 2014: 1636-1642.
- [32] Machajdik J, Hanbury A. Affective image classification using features inspired by psychology and art theory[C]//Proceedings of the 18th ACM international conference on

Multimedia. ACM, 2010: 83-92.

[33] McAuley J, Pandey R, Leskovec J. Inferring networks of substitutable and complementary products[C]//Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2015: 785-794.

[34] Peng K C, Chen T, Sadovnik A, et al. A mixed bag of emotions: Model, predict, and transfer emotion distributions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 860-868.

[35] Rendle S, Freudenthaler C. Improving pairwise learning for item recommendation from implicit feedback[C]//Proceedings of the 7th ACM international conference on Web search and data mining. ACM, 2014: 273-282.

[36] Sharif Razavian A, Azizpour H, Sullivan J, et al. CNN features off-the-shelf: an astounding baseline for recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2014: 806-813.

[37] Rendle S, Freudenthaler C, Gantner Z, et al. BPR: Bayesian personalized ranking from implicit feedback[C]//Proceedings of the twenty-fifth conference on uncertainty in artificial intelligence. AUAI Press, 2009: 452-461.

[38] Ronen R, Koenigstein N, Ziklik E, et al. Selecting content-based features for collaborative filtering recommenders[C]//Proceedings of the 7th ACM conference on Recommender systems. ACM, 2013: 407-410.

[39] Sakaki M, Niki K, Mather M. Beyond arousal and valence: The importance of the biological versus social relevance of emotional stimuli[J]. Cognitive, Affective, & Behavioral Neuroscience, 2012, 12(1): 115-139.

[40] Shi Y, Karatzoglou A, Baltrunas L, et al. xCLiMF: optimizing expected reciprocal rank for data with multiple levels of relevance[C]//Proceedings of the 7th ACM conference on Recommender systems. ACM, 2013: 431-434.

[41] Shi Y, Karatzoglou A, Baltrunas L, et al. CLiMF: learning to maximize reciprocal rank with collaborative less-is-more filtering[C]//Proceedings of the sixth ACM conference on Recommender systems. ACM, 2012: 139-146.

[42] Shi Y, Larson M, Hanjalic A. Collaborative filtering beyond the user-item matrix: A survey of the state of the art and future challenges[J]. ACM Computing Surveys (CSUR), 2014, 47(1): 3.

-
- [43] Lerche L, Jannach D. Using graded implicit feedback for bayesian personalized ranking[C]//Proceedings of the 8th ACM Conference on Recommender systems. ACM, 2014: 353-356.
- [44] Soleymani M, Pantic M, Pun T. Multimodal emotion recognition in response to videos[J]. IEEE transactions on affective computing, 2012, 3(2): 211-223.
- [45] Wang C, Blei D M. Collaborative topic modeling for recommending scientific articles[C]//Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining. ACM, 2011: 448-456.
- [46] Wang H, Wang N, Yeung D Y. Collaborative deep learning for recommender systems[C]//Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2015: 1235-1244.
- [47] Wang S, Ji Q. Video affective content analysis: a survey of state-of-the-art methods[J]. IEEE Transactions on Affective Computing, 2015, 6(4): 410-430.
- [48] Zhou B, Lapedriza A, Xiao J, et al. Learning deep features for scene recognition using places database[C]//Advances in neural information processing systems. 2014: 487-495.
- [49] Gantner Z, Drumond L, Freudenthaler C, et al. Personalized Ranking for Non-Uniformly Sampled Items[C]//KDD Cup. 2012: 231-247.
- [50] Karatzoglou A, Baltrunas L, Shi Y. Learning to rank for recommender systems[C]//Proceedings of the 7th ACM conference on Recommender systems. ACM, 2013: 493-494.
- [51] Koren Y. Factorization meets the neighborhood: a multifaceted collaborative filtering model[C]//Proceedings of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining. ACM, 2008: 426-434.
- [52] Koren Y. Collaborative filtering with temporal dynamics[J]. Communications of the ACM, 2010, 53(4): 89-97.
- [53] Krohn-Grimberghe A, Drumond L, Freudenthaler C, et al. Multi-relational matrix factorization using bayesian personalized ranking for social network data[C]//Proceedings of the fifth ACM international conference on Web search and data mining. ACM, 2012: 173-182.
- [54] Ma H, Liu C, King I, et al. Probabilistic factor models for web site

recommendation[C]//Proceedings of the 34th international ACM SIGIR conference on
Research and development in Information Retrieval. ACM, 2011: 265-274.