

$$MAE = \frac{1}{|\mathcal{R}^{te}|} \sum_{(u,j) \in \mathcal{R}^{te}} |R_{ij} - \hat{R}_{ij}| \tag{16}$$

$$RMSE = \sqrt{\frac{1}{|\mathcal{R}^{te}|} \sum_{(u,j) \in \mathcal{R}^{te}} (R_{ij} - \hat{R}_{ij})^2} \tag{17}$$

其中, \mathcal{R}^{te} 表示测试集, $|\mathcal{R}^{te}|$ 表示测试集中评分的数量.

3.3 对比算法及超参数设定

在实验中,我们选择基于 Librec(<http://www.librec.net>)平台来实现并验证 CRMF 算法.为了验证社会关系和关联关系在推荐过程中所起的作用,本文选取了 6 种主流的推荐算法与 CRMF 进行了详细对比,并在表 3 中给出了 7 种推荐算法中的超参数在 4 个数据集上的最佳取值.此外,实验 2~实验 6 中设置潜在特征向量维度 $d=10$.

- (1) **PMF**:由 Salakhutdinov 等人^[20]提出的一种基于概率的矩阵分解推荐算法,该算法仅考虑了用户对物品的评分信息;
- (2) **SoReg**:由 Ma 等人^[26]提出的一种基于社会关系的推荐算法,该算法将社会关系以社会正则化的方式约束传统矩阵分解时用户潜在特征向量的学习,使得存在社会关系的两个用户其潜在特征向量尽可能的相似;
- (3) **SoRec**:由 Ma 等人^[23]提出的一种基于社会关系的推荐算法,该算法通过同时分解评分矩阵和用户的社会关系矩阵并且以共享用户潜在特征矩阵的方式,学习出用户和物品的潜在特征矩阵;
- (4) **SociaMF**:由 Jamali 等人^[27]提出的一种将社交网络中的信任传播结构与 PMF 相结合的推荐算法,该算法有效地考虑了直接和间接信任的用户对目标用户评分的影响;
- (5) **TrustMF**:由 Yang 等人^[24]提出的一种基于信任关系的推荐算法,该算法合理地反映了信任用户之间的相互关系对于推荐过程中评分预测的影响;
- (6) **SVD++**:由 Koren 等人^[22]提出的一种同时考虑用户偏置、物品偏置以及用户隐式反馈信息的推荐算法,该算法是矩阵分解中推荐精度较高的算法,并且是当年 Netflix 大赛获奖者所使用的关键算法.

Table 3 Hyper-Parameter settings of compared algorithms

表 3 对比算法的超参数设置

Algorithms	Epinions	Flixster	Ciao	FilmTrust
PMF	$\lambda_U=\lambda_V=0.01$	$\lambda_U=\lambda_V=0.1$	$\lambda_U=\lambda_V=0.1$	$\lambda_U=\lambda_V=0.1$
SoRec	$\lambda_U=\lambda_V=0.001, \lambda_C=1$	$\lambda_U=\lambda_V=0.001, \lambda_C=0.001$	$\lambda_U=\lambda_V=0.001, \lambda_C=0.01$	$\lambda_U=\lambda_V=0.001, \lambda_C=0.1$
SoReg	$\lambda_U=\lambda_V=0.001, \beta=0.1$	$\lambda_U=\lambda_V=0.001, \beta=0.01$	$\lambda_U=\lambda_V=0.001, \beta=0.01$	$\lambda_U=\lambda_V=0.001, \beta=0.1$
SociaMF	$\lambda_U=\lambda_V=0.001, \lambda_T=5$	$\lambda_U=\lambda_V=0.001, \lambda_T=1$	$\lambda_U=\lambda_V=0.001, \lambda_T=1$	$\lambda_U=\lambda_V=0.001, \lambda_T=1$
TrustMF	$\lambda_U=\lambda_V=0.001, \lambda_T=1$	$\lambda_U=\lambda_V=0.001, \lambda_T=1$	$\lambda_U=\lambda_V=0.001, \lambda_T=1$	$\lambda_U=\lambda_V=0.001, \lambda_T=1$
SVD++	$\lambda_b=\lambda_U=\lambda_V=0.35$	$\lambda_b=\lambda_U=\lambda_V=0.03$	$\lambda_b=\lambda_U=\lambda_V=0.1$	$\lambda_b=\lambda_U=\lambda_V=0.1$
CRMF	$\lambda=0.4, \rho=80, \alpha=0.1, \beta=0.1$	$\lambda=0.8, \rho=50, \alpha=0.1, \beta=0.01$	$\lambda=0.4, \rho=100, \alpha=0.01, \beta=0.01$	$\lambda=1.2, \rho=20, \alpha=0.01, \beta=0.1$

3.4 实验结果与分析

实验 1:不同特征向量维度下的实验结果对比.

根据文献[27],我们将训练集中评分数量少于 5 个的用户所构成的集合称为冷启动用户集.实验 1 比较了各种推荐算法在全体用户集和冷启动用户集上不同特征向量维度下的结果,文中分别设定潜在特征向量的维度为 $d=5, 10$.表 4 给出了各推荐算法在全体用户集上 MAE 和 $RMSE$ 的比较结果,表 5 给出了各推荐算法在冷启动用户集上 MAE 和 $RMSE$ 的比较结果.从两个表中的实验结果可看出,

- (1) 在全体用户集上, SVD++ 与 PMF 相比,其推荐精度有了较大的提升,这说明用户的偏置因素、物品的偏置因素以及用户的隐式反馈信息可提高算法的评分预测精度;
- (2) 在全体用户集和冷启动用户集上, SoReg, SoRec, SocialMF, TrustMF 与 PMF 相比,其推荐精度均有了较大的提高.这说明用户的社会关系有助于提高传统矩阵分解模型的预测精度,并有助于缓解用户的冷启动问题;

- (3) 在冷启动用户集上,CRMF 相比于 6 种对比算法其推荐精度有明显的提升.这是因为当用户为冷启动时,其社会关系的数量往往也较少,此时仅依赖社会关系对推荐算法精度的提升是有限的;但当目标物品为非冷启动时,考虑物品之间的关联关系可提升推荐算法的评分预测精度.

Table 4 Performance comparison on all users

表 4 全体用户集上的性能对比

All		Metrics	PMF	SoRec	SoReg	SociaMF	TrustMF	SVD++	CRMF	Improve (%)
Epinions	d=5	MAE	0.979	0.882	0.946	0.825	0.818	0.818	0.799	2.32
		RMSE	1.290	1.114	1.245	1.070	1.069	1.057	1.043	1.32
	d=10	MAE	0.909	0.884	0.896	0.826	0.819	0.818	0.797	2.56
		RMSE	1.197	1.142	1.167	1.082	1.095	1.057	1.038	1.79
Flixster	d=5	MAE	0.814	0.750	0.774	0.770	0.790	0.794	0.728	5.45
		RMSE	1.076	0.974	1.017	0.994	1.046	1.062	0.951	2.36
	d=10	MAE	0.806	0.785	0.785	0.784	0.794	0.791	0.718	8.42
		RMSE	1.063	1.018	1.034	1.009	1.061	1.048	0.947	6.14
Ciao	d=5	MAE	1.105	0.786	0.920	0.762	0.764	0.735	0.718	2.31
		RMSE	1.448	0.997	1.239	0.977	0.987	0.974	0.952	2.25
	d=10	MAE	0.903	0.776	0.854	0.749	0.767	0.733	0.717	2.18
		RMSE	1.179	1.026	1.167	0.997	1.024	0.967	0.952	1.55
FilmTrust	d=5	MAE	0.714	0.628	0.674	0.638	0.631	0.613	0.608	0.82
		RMSE	0.949	0.810	0.878	0.837	0.810	0.804	0.788	2.00
	d=10	MAE	0.735	0.638	0.668	0.643	0.631	0.611	0.607	0.65
		RMSE	0.968	0.831	0.875	0.844	0.819	0.802	0.787	1.87

Table 5 Performance comparison on cold start users

表 5 冷启动用户集上的性能对比

Cold Start		Metrics	PMF	SoRec	SoReg	SociaMF	TrustMF	SVD++	CRMF	Improve (%)
Epinions	d=5	MAE	1.451	0.892	1.398	0.864	0.891	0.889	0.848	1.85
		RMSE	1.770	1.138	1.735	1.133	1.125	1.162	1.078	4.18
	d=10	MAE	1.153	0.846	0.986	0.857	0.853	0.891	0.847	0.70
		RMSE	1.432	1.180	1.217	1.152	1.176	1.166	1.073	6.85
Flixster	d=5	MAE	1.097	0.872	1.058	0.881	0.871	0.868	0.843	2.88
		RMSE	1.390	1.096	1.358	1.103	1.093	1.122	1.053	3.65
	d=10	MAE	0.951	0.892	0.946	0.884	0.876	0.869	0.843	3.00
		RMSE	1.206	1.144	1.201	1.112	1.102	1.112	1.052	4.54
Ciao	d=5	MAE	1.406	0.775	0.905	0.757	0.750	0.719	0.696	3.20
		RMSE	1.763	0.983	1.106	0.964	0.955	0.958	0.923	3.35
	d=10	MAE	1.047	0.720	0.757	0.732	0.722	0.717	0.695	3.07
		RMSE	1.340	1.072	1.079	0.961	0.958	0.956	0.922	3.56
FilmTrust	d=5	MAE	0.814	0.670	0.783	0.697	0.674	0.677	0.649	3.13
		RMSE	1.079	0.857	0.980	0.916	0.867	0.897	0.838	2.27
	d=10	MAE	0.767	0.668	0.761	0.680	0.687	0.680	0.645	3.44
		RMSE	1.009	0.853	0.958	0.907	0.900	0.905	0.841	1.41

实验 2:不同评分数量下的实验结果对比.

为了对比不同评分数量下各算法的效果,本文依据训练集中用户的评分数量将用户划分为[0:10],[11:30],[31:50],[51:100],100 以上这 5 组,图 2 显示了 4 个数据集中每组用户所占的比例,从图中可看出:4 个数据集中,评分数量少于 10 的用户占大部分.依据用户的评分数量对训练集中的用户进行划分之后,使用训练集学习相应的推荐算法,然后在 5 组用户上分别计算 RMSE,结果如图 3 所示.从 4 个数据集的实验结果可看出,

- (1) 在数据极度稀疏时(评分数量小于 10),CRMF 算法明显优于其他推荐算法.这因为评分数据稀疏时,用户的社会关系往往也比较稀疏,同时考虑物品的关联关系可提高算法的推荐精度;
- (2) 随着用户评分数量的增加,CRMF 及对比算法所得出的 RMSE 值并没有持续变小.这因为用户的评分数量较少时,数据比较稀疏使得模型不易学习到用户的潜在特征向量.用户的评分数据过多,用户的兴趣会发散,这造成无法准确学习到表示用户喜好的潜在特征向量.但 CRMF 仍优于其他对比算法,这因为基于联合正则化的矩阵分解模型考虑了自适应正则化,它能够根据用户评分的数量对正则化程度进行自适应地调整,因此使得 CRMF 算法可更加有效地学习出模型的参数.




Fig.2 Distribution of users with different ratings

图 2 不同评分数量下用户的分布

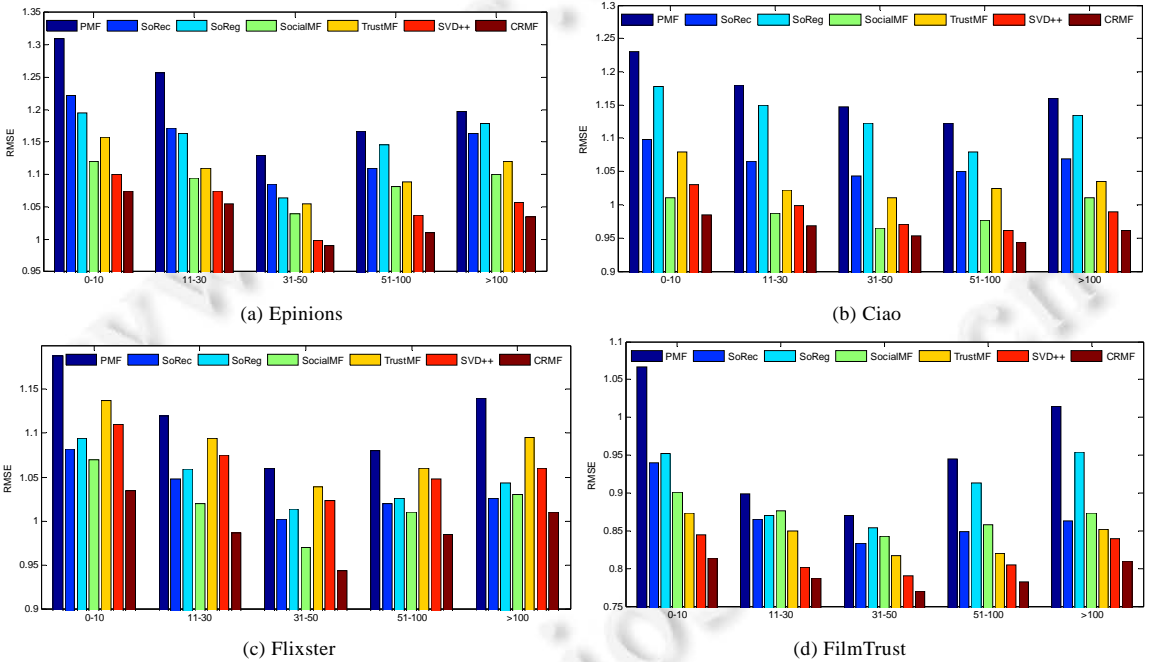


Fig.3 Comparison on users with different ratings

图 3 不同评分数量下用户对比结果

实验 3:不同社会关系下的实验结果对比.

为了评估各算法在不同社会关系下的推荐精度,依据训练集中用户拥有的社会关系数量将用户划分为 [1:5],[6:10],[11:20],[21:40],[41:100],[101:500],500 以上这 7 组,图 4 显示了每组用户所占的比例,从图中可看出,大多数用户所拥有的社会关系数量不多于 5 个.依据用户所拥有的社会关系数量对训练集中的用户进行划分后,使用训练集学习相应的算法.本实验仅对考虑社会关系的 SoRec,SoReg,SocialMF,TrustMF,CRMF 这 5 种推荐算法进行了详细对比,结果如图 5 所示.从 4 个数据集的实验结果可看出,

- (1) 在 FilmTrust 数据集上,各算法的 RMSE 值反而随着用户拥有社会关系数量的增加而增加.根据文献 [43]可知,该数据集将社会关系中真实的信任度转成二值数据时丢失了一些有用的信息,同时产生了噪声数据;
- (2) 在 Epinions,Flixster 及 Ciao 数据集上,随着社会关系数量的增加,5 种推荐算法的 RMSE 值并没有持续

变小.这因为当用户拥有的社会关系数量较少时,仅靠评分数据不能有效地对用户建模而影响了算法的精度.当用户的社会关系数量过多被考虑时,用户的兴趣过度依靠近邻的影响,使得学习的用户的潜在特征向量会比较发散.因此仅当用户的社会关系达到一定数量时,5种推荐算法才取得较优效果;

(3) 在4个数据集的每组用户上,CRMF均要优于其他推荐算法.这因为基于联合正则化的矩阵分解模型不仅考虑了社会关系与关联关系,而且使用了自适应正则化,使得矩阵分解模型能有效地对用户和物品进行建模.




Fig.4 Distribution of users with different social relationships

图4 不同社会关系下用户的分布




Fig.5 Comparison on users with different social relationships

图5 不同社会关系下用户的对比结果

实验4:关联关系获取方法的对比.

本实验是为了评估不同的获取关联关系的方法对推荐算法精度的影响.我们首先根据皮尔逊相关系数计算两两物品之间的相似度;然后,为每个目标物品选择10个最相似的物品作为关联关系;最后,将得到的无向关

联关系与 SVD++结合,得到改进的推荐算法,简称 SVD-IS.相应地,基于本文构建的关联程度(公式(7))可为每个物品选择 10 个最相关的物品作为有向的关联关系.同样地,我们将获取的有向关联关系与 SVD++结合得到改进的推荐算法,简称 SVD-IR.SVD-IS,SVD-IR 在相同超参数下的实验结果如表 6 所示.从表中的实验结果可看出,

- (1) 相比于表 4 中的 SVD++算法,考虑了物品之间相似性关系的 SVD-IS 在 4 个数据集上,其推荐精度有不同程度的提升.这是因为考虑物品的近邻关系,能够更好地对物品进行建模,这与文献[36,37]的结论是一致的;
- (2) 相比于 SVD-IS,SVD-IR 在 4 个数据集上,其推荐精度有了较高的提升.这是因为相比于无向的相似性关系,本文方法所获取的有向关联关系更符合现实世界中物品推荐的场景.

Table 6 Impact of item relations on RMSE

表 6 物品的关联关系对 RMSE 的影响

算法	数据集			
	Epinions	Flixster	Ciao	FilmTrust
SVD-IS	1.051	0.995	0.964	0.799
SVD-IR	1.045	0.974	0.960	0.795

实验 5:自适应正则化的有效性验证.

本实验是为了评估自适应正则化对于推荐算法精度的影响.我们将用户的社会关系和物品的关联关系同时与 SVD++算法结合,可得改进的推荐算法,简称 SVD-DR.SVD-DR 与 CRMF 算法在 4 个数据集上的评分预测精度见表 7.从表中的实验结果可看出:考虑了自适应正则化的推荐算法 CRMF 明显优于仅考虑社会关系和关联关系的推荐算法 SVD-DR.这是因为考虑自适应正则化的矩阵分解模型不仅无需评分矩阵中评分的分布为均匀分布.而且对于大规模非平衡数据集更易搜索到合适的正则化超参数.

Table 7 Impact of adaptive regularization on RMSE

表 7 自适应正则化对 RMSE 的影响

算法	数据集			
	Epinions	Flixster	Ciao	FilmTrust
SVD-DR	1.041	0.968	0.957	0.793
CRMF	1.038	0.947	0.952	0.787

实验 6:超参数对算法的影响.

为了说明 CRMF 算法的超参数对推荐结果的影响,本文以数据集 Ciao 为例,详细讨论了各超参数下的实验结果.本文设定 α 和 β 的取值为 0.00001,0.0001,0.001,0.01,0.1,0.3.超参数 C 的取值为 0,10,20,50,100,150,200.超参数 K 的取值为 0,10,20,30,40,50,60,70,80,90,100.从图 6 可看出,

- (1) β 控制着用户的社会关系对推荐结果的影响.图 6(a)显示了超参数 β 的变化对 RMSE 的影响,其值从 0.00001 开始先下降,到达某个阈值后上升.这说明用户的社会关系在 CRMF 算法中所占的比重直接影响推荐结果的好坏;
- (2) α 控制着物品之间的关联关系在推荐过程所占的比重.图 6(b)显示了超参数 α 的变化对 RMSE 值的影响,其值从 0.00001 开始先下降,到达某个阈值后上升.这表明物品之间的关联关系在 CRMF 算法中所占的比重直接影响推荐结果的好坏.在数据集 Ciao 上,由 $\alpha=\beta=0.01$ 算法取得较高精度,说明物品之间的关联关系在用户决策时也是必不可少的;
- (3) $\rho=0$ 表示物品之间的关联程度等于关联规则中的置信度.从图 6(c)可看出:随着 ρ 值的增加,算法的推荐精度先增加后降低.这说明物品之间关联程度的获取,仅当综合考虑支持度与置信度时才使得算法精度较高;
- (4) σ 表示物品拥有的关联关系数量.从图 6(d)可看出:当 $\sigma=0$ 时,表示 CRMF 算法不考虑物品之间的关联关系;随着 σ 值的增加,算法的精度有所提高,这说明本文获取物品之间关联关系的方法的有效性;在 $\sigma=40$ 以后,算法的精度开始下降,这主要是因为 σ 值过大会导致对目标物品引入一些关联程度较低的

关联关系.

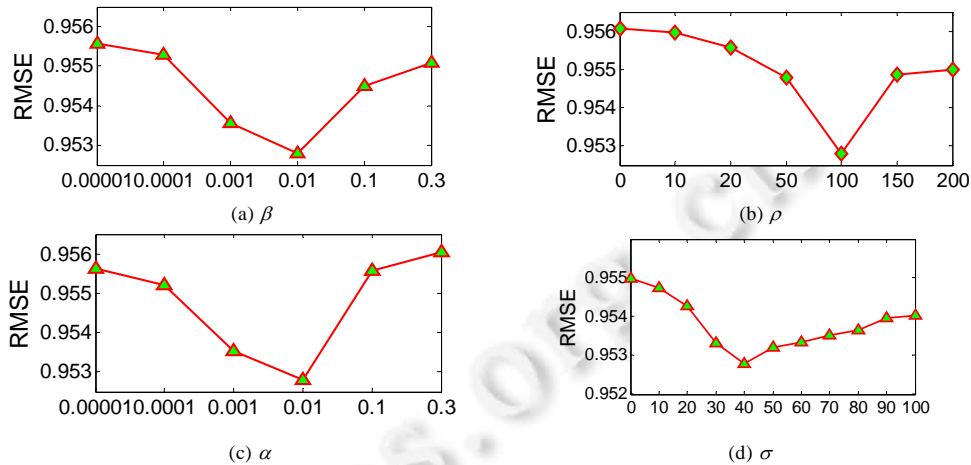


Fig.6 Impact of hyperparameters

图6 超参数的影响

4 结论

本文首先给出一种度量物品之间关联程度的方法,通过该方法可获取物品之间的有向关联关系;然后将其以关联正则化的方式与自适应正则化相结合,融入基于社会正则化的矩阵分解模型中,提出了基于联合正则化的矩阵分解模型,并证明了联合正则化是一种加权的原子范数.由于物品之间关联关系的获取无需物品的标签、属性等额外信息,因此,基于联合正则化的矩阵分解模型拥有更广泛的应用范围.在4个真实数据集上的实验表明:与主流的推荐算法相比,本文算法不仅可缓解用户的冷启动问题,而且能够更有效地预测不同类型用户的实际评分.

在未来的研究中,我们将把重点放在解决物品冷启动相关的问题上.这种情况下,如何将情境信息(时间、地理等)和物品的视觉特征融入到本文的推荐模型中,来更好地预测目标用户对特定物品的喜好,这也是我们下一步要改进的方向.

References:

- [1] Lü LY, Medo M, Yeung CH, Zhang YC, Zhang ZK, Zhou T. Recommender systems. *Physics Reports*, 2012,519(1):1-49.
- [2] Bobadilla J, Ortega F, Hernando A, Gutiérrez A. Recommender systems survey. *Knowledge-Based Systems*, 2013,46(1):109-132.
- [3] Wu L, Liu Q, Chen E, Yuan NJ, Guo GM, Xie X. Relevance meets coverage: A unified framework to generate diversified recommendations. *ACM Trans. on Intelligent Systems and Technology (TIST)*, 2016,7(3):39.
- [4] Liu Q, Chen E, Xiong H, Ding CH, Chen J. Enhancing collaborative filtering by user interest expansion via personalized ranking. *IEEE Trans. on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2012,42(1):218-233.
- [5] Liu JG, Zhou T, Wang BH. Research progress of personalized recommendation system. *Progress in Natural Science*, 2009,19(1): 1-15 (in Chinese with English abstract).
- [6] Adomavicius G, Tuzhilin A. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Trans. on Knowledge and Data Engineering*, 2005,17(16):734-749.
- [7] Sarwar B, Karypis G, Konstan J, Riedl J. Item-Based collaborative filtering recommendation algorithms. In: *Proc. of the 10th Conf. on World Wide Web*. ACM Press, 2001. 285-295.
- [8] Liu Q, Chen E, Xiong H, Ge Y, Li ZM, Wu X. A cocktail approach for travel package recommendation. *IEEE Trans. on Knowledge and Data Engineering*, 2014,26(2):278-293.
- [9] Chiang KY, Hsieh CJ, Dhillon IS. Matrix completion with noisy side information. In: *Proc. of the 28th Conf. on Neural Information Processing Systems*. Curran Associates Press, 2015. 3447-3455.

- [10] Rao N, Yu HF, Ravikumar P, Dhillon IS. Collaborative filtering with graph information: Consistency and scalable methods. In: Proc. of the 28th Conf. on Neural Information Processing Systems. Curran Associates Press, 2015. 2107–2115.
- [11] Li DS, Chen C, Lv Q, Yan JC, Shang L, Chu SM. Low-Rank matrix approximation with stability. In: Proc. of the 33rd Int'l Conf. on Machine Learning. ACM Press, 2016.
- [12] Wang YX, Xu H. Stability of matrix factorization for collaborative filtering. In: Proc. of the 29th Int'l Conf. on Machine Learning. ACM Press, 2012. 417–424.
- [13] Bhaskar SA. Probabilistic low-rank matrix completion from quantized measurements. *Journal of Machine Learning Research*, 2016, 17(60):1–34.
- [14] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems. *IEEE Computer*, 2009,42(8):30–37.
- [15] Koren Y. Collaborative filtering with temporal dynamics. In: Proc. of the 9th Int'l ACM SIGKDD Conf. on Knowledge Discovery and Data Mining. ACM Press, 2009. 89–97.
- [16] Hu Y, Koren Y, Volinsky C. Collaborative filtering for implicit feedback datasets. In: Proc. of the 8th IEEE Int'l Conf. on Data Mining. IEEE, 2008. 263–272.
- [17] Srebro N, Rennie JDM, Jaakkola T. Maximum margin matrix factorization. In: Proc. of the 17th Int'l Conf. on Neural Information Processing Systems. Curran Associates Press, 2004. 1329–1336.
- [18] Lawrence ND, Urtasun R. Non-Linear matrix factorization with Gaussian processes. In: Proc. of the 26th Int'l Conf. on Machine Learning. ACM Press, 2009. 601–608.
- [19] Liu XY, Aggarwal C, Li YF, Kong XG, Sun XY, Sathé S. Kernelized matrix factorization for collaborative filtering. In: Proc. of the SIAM Int'l Conf. on Data Mining. SIAM/Omnipress, 2016. 399–416.
- [20] Salakhutdinov R, Mnih A. Probabilistic matrix factorization. In: Proc. of the 21st Conf. on Neural Information Processing Systems. Curran Associates Press, 2008. 1257–1264.
- [21] Salakhutdinov R, Mnih A. Bayesian probabilistic matrix factorization using Markov chain Monte Carlo. In: Proc. of the 25th Int'l Conf. on Machine Learning. ACM Press, 2008. 880–887.
- [22] Koren Y. Factorization meets the neighborhood: A multifaceted collaborative filtering model. In: Proc. of the 8th Int'l ACM SIGKDD Conf. on Knowledge Discovery and Data Mining. ACM Press, 2008. 426–434.
- [23] Ma H, Yang HX, Lyu MR, King I. SoRec: Social recommendation using probabilistic matrix factorization. In: Proc. of the 17th Int'l Conf. on Information and Knowledge Management. ACM Press, 2008. 978–991.
- [24] Yang B, Lei Y, Liu DY, Liu JM. Social collaborative filtering by trust. In: Proc. of the 23rd Int'l Joint Conf. on Artificial Intelligence. IJCAI/AAAI Press, 2013. 2747–2753.
- [25] Guo L, Ma J, Chen ZM. Trust strength aware social recommendation method. *Journal of Computer Research and Development*, 2015,50(9):1805–1813 (in Chinese with English abstract).
- [26] Ma H, Zhou D, Liu C, Lyu MR, King I. Recommender systems with social regularization. In: Proc. of the 25th Int'l Conf. on Web Search and Data Mining. ACM Press, 2011. 287–296.
- [27] Jamali M, Ester M. A matrix factorization technique with trust propagation for recommendation in social networks. In: Proc. of the 4th Int'l Conf. on Recommender Systems. ACM Press, 2010. 135–142.
- [28] Ma H, Lyu MR, King I. Learning to recommend with trust and distrust relationships. In: Proc. of the 3rd Int'l Conf. on Recommender Systems. ACM Press, 2009. 189–196.
- [29] Meng XW, Liu SD, Zhang YJ, Hu X. Research on social recommender systems. *Ruan Jian Xue Bao/Journal of Software*, 2015, 26(6):1356–1372 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4831.htm> [doi: 10.13328/j.cnki.jos.004831]
- [30] Sun GF, Wu L, Liu Q, Zhu C, Chen EH. Recommendations based on collaborative filtering by exploiting sequential behaviors. *Ruan Jian Xue Bao/Journal of Software*, 2013,24(11):2721–2733 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4478.htm> [doi: 10.3724/SP.J.1001.2013.04478]
- [31] Wu L, Chen E, Liu Q, Xu LL, Bao TF, Zhang L. Leveraging tagging for neighborhood-aware probabilistic matrix factorization. In: Proc. of the 21st ACM Int'l Conf. on Information and Knowledge Management. ACM Press, 2012. 1854–1858.
- [32] Gu QQ, Zhou J, Ding C. Collaborative filtering: Weighted nonnegative matrix factorization incorporating user and item graphs. In: Proc. of the SIAM Int'l Conf. on Data Mining. SIAM/Omnipress, 2010. 199–210.
- [33] Yu X, Ren X, Gu Q, Sun YZ, Han JW. Collaborative filtering with entity similarity regularization in heterogeneous information networks. In: Proc. of the 2nd IJCAI Workshop on Heterogeneous Information Network Analysis. 2013.

- [34] Luo C, Pang W, Wang Z. Hete-CF: Social-Based collaborative filtering recommendation using heterogeneous relations. In: Proc. of the 2014 IEEE Int'l Conf. on Data Mining. IEEE, 2014. 917–922.
- [35] Liang D, Altoosaar J, Charlin L, Blei DM. Factorization meets the item embedding: Regularizing matrix factorization with item co-occurrence. In: Proc. of the 10th Int'l Conf. on Recommender Systems. ACM Press, 2016. 59–66.
- [36] Ma H. An experimental study on implicit social recommendation. In: Proc. of the 36th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM Press, 2013. 73–82.
- [37] Zheng J, Liu J, Shi C, Zhuang FZ, Li JZ, Wu B. Dual similarity regularization for recommendation. In: Proc. of the 20th Pacific-Asia Conf. on Knowledge Discovery and Data Mining. Springer Int'l Publishing, 2016. 542–554.
- [38] Charu C. Recommender Systems: The Textbook. New York: Springer-Verlag, 2016. 77–81.
- [39] Srebro N, Salakhutdinov R. Collaborative filtering in a non-uniform world: Learning with the weighted trace norm. In: Proc. of the 23rd Conf. on Neural Information Processing Systems. Curran Associates Press, 2010. 2056–2064.
- [40] Chandrasekaran V, Recht B, Parrilo PA, Willsky AS. The convex geometry of linear inverse problems. Foundations of Computational Mathematics, 2012,12(6):805–849.
- [41] Chen YD, Bhojanapalli S, Sanghavi S, Ward R. Coherent matrix completion. Journal of Machine Learning Research, 2014,32: 674–682.
- [42] Bouchard G, Guo SB, Yin DW. Convex collective matrix factorization. Journal of Machine Learning Research, 2013,31:144–152.
- [43] Fang H, Bao Y, Zhang J. Leveraging decomposed trust in probabilistic matrix factorization for effective recommendation. In: Proc. of the 28th AAAI Conf. on Artificial Intelligence. AAAI Press, 2014. 30–36.

附中文参考文献:

- [5] 刘建国,周涛,汪秉宏.个性化推荐系统的研究进展.自然科学研究进展,2009,19(1):1–15.
- [25] 郭磊,马军,陈竹敏.一种信任关系强度敏感的社会化推荐算法.计算机研究与发展,2015,50(9):1805–1813.
- [29] 孟祥武,刘树栋,张玉洁,胡勋.社会化推荐系统研究.软件学报,2015,26(6):1356–1372. <http://www.jos.org.cn/1000-9825/4831.htm> [doi: 10.13328/j.cnki.jos.004831]
- [30] 孙光福,吴乐,刘淇,朱琛,陈恩红.基于时序行为的协同过滤推荐算法.软件学报,2013,24(11):2721–2733. <http://www.jos.org.cn/1000-9825/4478.htm> [doi: 10.3724/SP.J.1001.2013.04478]



吴宾(1991—),男,河南柘城人,硕士,CCF 学生会员,主要研究领域为机器学习,推荐系统.



叶阳东(1962—),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为智能系统,机器学习,数据库.



娄铮铮(1984—),男,博士,讲师,CCF 专业会员,主要研究领域为机器学习,模式识别,推荐系统.