

用于冷启动推荐的异质信息网络对比元学习*

方阳¹, 谭真¹, 陈子阳¹, 肖卫东¹, 张玲玲², 田锋³



¹(国防科技大学 信息系统工程重点实验室, 湖南 长沙 410073)

²(西安交通大学 计算机科学与技术学院, 陕西 西安 710049)

³(西安交通大学 电子与信息学部, 陕西 西安 710049)

通信作者: 谭真, E-mail: tanzhen08a@nudt.edu.cn

摘要: 在推荐系统中, 冷启动推荐由于缺乏用户和物品交互信息而具有很大的挑战性. 该问题可以由数据层和模型层的策略进行缓解. 传统的数据层方法利用如特征信息的辅助信息来增强用户和物品表示的学习. 最近, 异质信息网络被整合于推荐系统中. 它可以提供更丰富的辅助信息和更有意义的语义信息. 但是, 这些模型无法充分利用结构和语义信息, 并且忽视了网络中的无标签信息. 模型层的方法应用了元学习框架, 该框架通过学习相似任务的先验知识, 然后利用很少的标签信息适应新任务, 与冷启动问题相似. 综上, 提出了一个基于异质信息网络的对比元学习框架 CM-HIN, 同时, 在数据层和模型层解决冷启动问题. 具体的, 利用元路径和网络模式这两个视图分别刻画异质信息网络的高阶以及本地结构信息. 在元路径和网络模式视图中, 采用对比学习挖掘异质信息网络的无标签信息并整合两个视图. 在 3 个基准数据集上的 3 个冷启动推荐场景的大量实验中, CM-HIN 超越了所有先进的基线模型.

关键词: 冷启动推荐; 异质信息网络; 元学习; 对比学习

中图法分类号: TP18

中文引用格式: 方阳, 谭真, 陈子阳, 肖卫东, 张玲玲, 田锋. 用于冷启动推荐的异质信息网络对比元学习. 软件学报, 2023, 34(10): 4548–4564. <http://www.jos.org.cn/1000-9825/6886.htm>

英文引用格式: Fang Y, Tan Z, Chen ZY, Xiao WD, Zhang LL, Tian F. Contrastive Meta-learning on Heterogeneous Information Networks for Cold-start Recommendation. Ruan Jian Xue Bao/Journal of Software, 2023, 34(10): 4548–4564 (in Chinese). <http://www.jos.org.cn/1000-9825/6886.htm>

Contrastive Meta-learning on Heterogeneous Information Networks for Cold-start Recommendation

FANG Yang¹, TAN Zhen¹, CHEN Zi-Yang¹, XIAO Wei-Dong¹, ZHANG Ling-Ling², TIAN Feng³

¹(Science and Technology on Information Systems Engineering Laboratory, National University of Defense Technology, Changsha 410073, China)

²(School of Computer Science and Technology, Xi'an Jiaotong University, Xi'an 710049, China)

³(Faculty of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: In recommendation system, cold-start issue is challenging due to the lack of interactions between new users or new items. Such issue could be alleviated via data-level and model-level strategies. Traditional data-level methods employ side information like feature information to enhance the learning of user and item embeddings. Recently, heterogeneous information networks (HINs) have been incorporated into the recommendation system as they provide more fruitful auxiliary information and meaningful semantics. However,

* 基金项目: 科技创新 2030“新一代人工智能”重大专项(2020AAA0108800); 国家自然科学基金(61902417, 71971212, 62106190); CCF-联想蓝海科研基金

本文由“知识赋能的信息系统”专题特约编辑高宏教授、陈华钧教授、赵翔教授、李瑞轩教授推荐

收稿时间: 2022-07-05; 修改时间: 2022-08-18, 2022-12-14; 采用时间: 2022-12-28; jos 在线出版时间: 2023-01-13

these models are unable to capture the structural and semantic information comprehensively and neglect the unlabeled information of HINs during training. Model-level methods propose to apply the meta-learning framework which naturally fits into the cold-start issue, as it learns the prior knowledge from similar tasks and adapts to new tasks quickly with few labeled samples. Therefore, a contrastive meta-learning framework on HINs named CM-HIN is proposed, which addresses the cold-start issue in both data level and model level. Specifically, metapath and network schema views are explored to describe the higher-order and local structural information of HINs. Within metapath and network schema views, contrastive learning is adopted to mine the unlabeled information of HINs and these two views are incorporated. Extensive experiments on three benchmark datasets demonstrate that CM-HIN outperforms all state-of-the-art baselines in three cold-start scenarios.

Key words: cold-start recommendation; heterogeneous information network; meta-learning; contrastive learning

随着网络的爆炸性发展, 推荐系统^[1-3]在现实生活中有了越来越多的应用, 比如电子商务平台、新闻推送平台等等. 推荐系统根据每个用户的喜好和习惯推荐其感兴趣的信息, 可以减轻信息过载的问题. 传统的推荐系统主要基于协同过滤的方法, 即通过用户和物品的历史交互信息, 如购买、点击等, 计算用户对某物品感兴趣的概率. 但是, 每出现一个新用户和新物品, 其历史交互数据通常是非常稀疏的, 从而引出了推荐系统中常见的冷启动问题^[4], 其核心在于研究如何有效地学习新用户和新物品的表示.

为缓解冷启动问题, 通常的解决思路是借助辅助信息来增强新用户和新物品的表示^[4,5]. 最近, 异质信息网络被广泛用来与推荐系统相结合, 为用户和物品的表示提供大量的附加信息. 异质信息网络是由不同类型的节点和边组成的网络, 在日常生活中很常见, 例如社交网络、知识图谱等^[6]. 图 1(a)是一个典型的电影异质信息网络, 除了已有的用户和电影的交互信息外, 还描述了电影之间通过哪些导演或演员相互关联, 从而为用户推荐电影. 通常采用元路径来描述异质信息网络的高阶结构和语义信息^[7]. 元路径是由节点类型组成的序列, 每一个元路径通常具有相应的语义信息. 例如, *UIDI*这一元路径代表了两部电影具有相同的导演, 而用户已对其中一部电影进行了打分. 以上是在数据层面为解决冷启动问题做出的尝试.

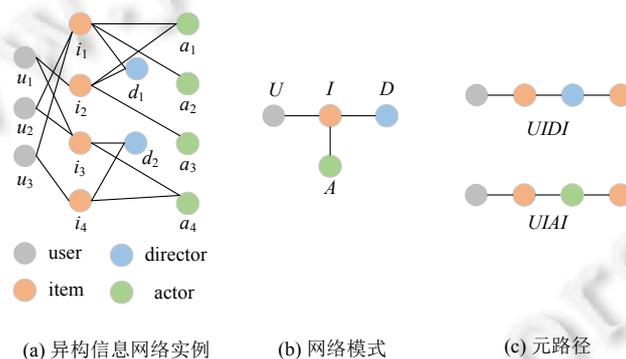


图 1 异质信息网络

在模型层面, 元学习在小样本学习中的广泛应用^[8], 吸引了部分学者借助元学习框架解决冷启动问题^[9]. 元学习首先学习各个任务的先验知识, 然后根据先验知识和少量的训练数据, 在新的任务上快速调整学习. 冷启动问题与元学习较为类似, 有监督信息较少(新用户或新物品历史交互信息较少), 而每一个任务可以看作是给每一个用户推荐物品. 模型首先在元训练过程中通过先验知识学习泛化能力, 然后在元测试过程中, 将模型快速微调至新任务上, 即为交互数据非常稀疏的冷启动用户推荐物品. 少数模型^[10-12]采用了元学习框架, 如 MAML^[8], 取得了一定的效果. 然而它们都忽视了一定的结构和语义信息, 且完全忽视了异质信息网络中大量的无监督信息, 从而影响了在冷启动推荐上的表示效果.

本文提出了基于异质信息网络的对比元学习框架 CM-HIN, 旨在从数据层和模型层两个层面解决推荐系统中的冷启动问题. 主要面临两个挑战: (1) 如何高效地描述异质信息网络中的结构信息和语义信息? (2) 如何利用异质信息网络中的无监督信息?

针对第 1 个挑战, 之前的模型^[12,13]提出了采用元路径刻画异质信息网络的高阶结构和语义信息, 但却忽视了网络的本地结构. 网络模式作为异质信息网络的元模板, 刻画了节点之间的直接联系^[14], 如图 1(b)所示, 它准确刻画了网络的本地结构信息. 因此, 本文同时考虑了元路径和网络模式这两个视图, 以刻画异质信息网络的结构.

针对第 2 个挑战, 受对比学习^[15]的启发, 采用自监督的方式训练无标签信息, 从而更深入地挖掘异质信息网络的特征. 之前的基于元学习的模型虽然利用了有监督信息, 却忽视了重要的无监督信息. 在元路径视图, 传统方法只是聚合了邻域信息, 本文通过将元路径看作关系, 并与元路径的起始节点、末尾节点一起构建三元组, 更深入地感知元路径的知识信息. 将邻域感知表示与知识感知表示作对比学习, 实现了自监督训练并将邻域信息与知识信息加以整合. 在网络模式视图, 本文采取丢节点操作, 构建对比学习的正例, 进行自监督训练, 得到网络模式视图下的节点表示信息. 最后, 本文又对元路径视图和网络模式视图进行对比学习训练, 整合这两个视图的信息, 最终得到用户和物品的表示学习向量.

本文的主要贡献总结如下:

- 提出了基于异质信息网络的对比元学习框架 CM-HIN, 并在元路径和网络模式视图下挖掘异质信息网络的语义与结构信息, 从而在数据层和模型层解决冷启动推荐问题;
- 在元路径、网络模式中均设计了对比学习模型, 采用自监督训练的方法, 充分利用了元路径视图和网络模式视图中的无标签信息, 最后采用对比学习整合这两个视图;
- 在 3 个公开数据集上进行 3 个冷启动情景下的对比实验, 所提模型 CM-HIN 超越了所有先进的基线模型, 验证了所提模型的有效性.

本文第 1 节介绍冷启动推荐、元学习和对比学习的相关方法和研究现状. 第 2 节介绍本文所需基础知识, 包括异质信息网络和冷启动推荐的基本概念. 第 3 节介绍本文构建的用于冷启动推荐的异质信息网络对比元学习框架. 第 4 节通过对比实验验证所提模型的有效性. 最后总结全文.

1 相关工作

本节分别介绍冷启动推荐、异质信息网络表示学习、元学习和对比学习方面的相关工作与研究现状.

1.1 冷启动推荐

在推荐系统中, 当用户和物品的交互非常稀疏时, 很难为用户和物品学习有效的表示, 从而导致冷启动问题. 协同过滤模型^[3,5]在一般的推荐任务中取得了较好的效果, 却无法有效处理冷启动情景. 传统的解决冷启动推荐的模型采用了数据增强的方法, 即利用用户和物品的辅助信息^[4,16,17]. 除了这些传统的利用基于内容的特征的方法以外, 许多模型还提出了用异质信息网络提供丰富的辅助信息的方法. 异质信息网络描述了物品(如电影)和其他实体(如演员)之间的联系. 为了刻画异质信息网络的结构和语义信息, 很多方法采用了高阶的网络结构, 如元路径^[7]和元图^[18]等^[12,13,19]. 一些方法还结合了物品的评论、图像和知识图谱等信息来学习用户和物品的表示^[20,21]. 另有一类方法利用了迁移学习, 将源领域中学习到的表示应用在目标领域中的重复物品中^[22,23]. 上述这些方法只是在数据层面解决冷启动推荐问题, 非常依赖辅助数据的可获得性与质量.

1.2 异质信息网络表示学习

传统的异质信息网络的核心技术基于元路径, 通过不同的机制来刻画节点与元路径之间的关系. Metapath2Vec^[24]采用了异质 Word2Vec 技术, 将上下文的窗口限制为一个特定的类型. HIN2Vec^[25]采用元路径与节点之间的 Hadamard 乘积来捕获网络特征. 近来, 基于图神经网络的异质信息网络表示屡被提出. HetGNN^[26]首先聚合同一类型的节点特征, 然后采用注意力机制聚合不同的类型特征. HAN^[27]首先采用注意力机制聚合元路径的特征, 然后采用注意力机制聚合不同的元路径.

1.3 元学习

元学习的框架被广泛应用于少样本学习中, 其核心是在相似的学习任务上学到通用的先验知识, 从而只

需要一些很少的样本, 凭借先验知识在新的任务上快速微调, 实现评测结果^[28]. 元学习主要分为3类, 分别是基于指标的方法、基于模型的方法和基于优化的方法. 基于指标的方法在任务中学习一个指标或距离函数^[29], 而基于模型的方法为跨任务的快速泛化设计了一个架构或训练过程^[30]. 本文采用的基于优化的方法^[8]通过调整优化函数, 仅使用少量样本实现快速的调整.

元学习在冷启动问题中的成功应用, 提供了模型层面的解决方案. 具体地, 为解决冷启动问题, Vartak 等人^[9]提出了一个基于指标的方法. Lee 等人^[10]采用 MAML 框架, 基于稀疏的交互信息快速适应新用户和新物品. MAML 框架还被应用于基于场景的冷启动问题中, 将每个场景(例如, 购买运动器材和购买食品是两个场景)视为一个学习任务^[31]. 也有一些模型将元学习应用于具体的任务, 例如点击率(click through rate, CTR)预测^[11]和临床风险预测^[31]等. Lu 等人^[32]采用了元路径来刻画异质网络的语义和结构信息, 并整合在元学习框架中. 上述这些方法都忽视了一定的结构和语义信息, 且完全忽视了异质信息网络中大量的无监督信息.

1.4 对比学习

对比学习可以通过自监督学习的方式捕获异质信息网络中的无标签信息. 对比学习主要利用了样本间的约束信息构建辅助任务, 通过构建正负样本, 然后度量正负样本间的距离进行自监督学习. 自监督学习的关键在于如何合理地定义正负样本, 也是难点所在. 对比学习最早被应用于自然语言处理与计算视觉中, 最近也开始被应用在网络结构的数据上. 例如: GCC^[15]将从同一个节点出发, 不同的随机游走生成的子图作为正例, 由其他节点生成的子图作为负例; DGI^[33]通过互信息学习节点的表示与子图的表示, 给定一个子图, 节点属于该子图作为正例, 不属于该子图的节点作为负例. 本文首次在推荐系统中结合了图谱上的对比学习, 以充分挖掘异质信息网络的特征.

2 基础知识

本文所提方法主要是异质信息网络上的基于元学习的冷启动推荐, 下面对异质信息网络、冷启动推荐、元学习的相关概念和基础知识进行介绍.

2.1 异质信息网络

异质信息网络可被表示为 $G=(V,E,Type)$, 其中, V 表示节点集; E 表示边集; $Type$ 表示类型集合, 由 $Type_V$ 和 $Type_E$ 组成, 其中, $Type_V$ 和 $Type_E$ 分别表示节点类型的集合和边类型的集合. 边和节点分别存在一个类型映射函数, $\varphi_V:V \rightarrow Type_V$ 和 $\varphi_E:E \rightarrow Type_E$. $|Type_V|$ 和 $|Type_E|$ 分别表示节点和边的类型数量. $|Type_V|>1$ 或 $|Type_E|>1$ 代表该网络为异质信息网络. 如图 1(a)所示, 异质信息网络实例中, 有用户(U)、电影(I)、导演(D)和演员(A)这几个节点类型.

2.2 网络模式

网络模式可被表示为 $T_G=(Type_V, Type_E)$, 是异质信息网络 G 上的元模板. T_G 是一个由节点类型和边类型组成的图. 例如, 图 1(b)是图 1(a)的网络模式, 由所有的节点类型组成. 网络模式可被用来描述节点之间的直接联系, 即各个节点两两之间的联系, 从而刻画了网络的本地结构.

2.3 元路径

给定一个异质信息网络 $G=(V,E,Type)$, 元路径 P 是长度为 l 且定义在网络模式图 $T_G=(Type_V, Type_E)$ 的兼容节点类型和边类型的序列, 以下列形式表示: $Type_{V_1} \xrightarrow{Type_{E_1}} Type_{V_2} \xrightarrow{Type_{E_2}} \dots \xrightarrow{Type_{E_l}} Type_{V_{l+1}}$, 并将其简写为 $Type_{V_1} Type_{V_2} \dots Type_{V_{l+1}}$. 该元路径描绘了节点 V_1 和 V_{l+1} 之间的组合关系. 如图 1(c)所示: 存在两种元路径 $UIDI$ 和 $UIAI$, 分别表示不同的语义, 即某用户看了某电影, 该电影与另一个电影拥有相同的导演或者演员. 相应地, 根据图 1(a), $u_1 i_2 d_1 i_1$ 是元路径 $UIDI$ 的实例, 而 $u_1 i_2 a_1 i_1$ 是元路径 $UIAI$ 的实例. 元路径由诸多条关系组成, 即诸多个两两之间节点联系的组合, 因此, 它包含了高阶的结构信息.

2.4 冷启动推荐

在异质信息网络 $G=(V,E,Type)$, 将 $V_U, V_I \subset V$ 分别表示用户和物品的集合. 给定用户和物品的评分集合 $\mathcal{R}=\{r_{u,i} \geq 0: u \in V_U, i \in V_I, (u,i) \in E\}$, 我们的目标是预测未知的用户 u 和物品 i 之间的评分 $r_{u,i} \notin \mathcal{R}$. 特别地, 如果用户 u 是新用户, 且只有很少的一些评分, 即 $|\{r_{u',i} \in \mathcal{R}: u'=u\}|$ 的值非常小, 那么这就是一个用户冷启动问题(UC); 类似地, 如果物品 i 是新的物品, 且只有很少的一些评分, 即 $|\{r_{u,i'} \in \mathcal{R}: i'=i\}|$ 的值非常小, 那么这就是一个物品冷启动问题(IC); 如果用户 u 和物品 i 都是新的, 数量都非常小, 那么这就是一个用户-物品冷启动问题(UIC).

2.5 元学习

本文主要基于优化的元学习来解决少样本的冷启动问题. 在元学习过程中, 需要找到对新的任务最敏感的参数 θ , 从而在新任务中, 只需微调这些参数就可以获得较好的结果. 数学的, 给定任务分布 $p(\mathcal{T})$, 基于优化的元学习的目标是训练一个模型 f , 该模型可以基于 $p(\mathcal{T})$ 中获得的知识在新任务 \mathcal{T}_{new} 上快速调整得到结果. 如图 2 所示, 有两种更新的操作, 即全域更新和本地更新.

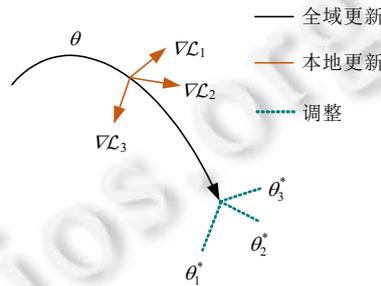


图 2 基于优化的元学习图例

元学习需要将每个任务划分为支持集和查询集. 首先, 在任务 \mathcal{T}_i 的支持集上, 模型以本地更新率 ϵ 将参数 θ 更新为 θ_i^* (学习过程):

$$\theta_i^* = \theta - \epsilon \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta}) \tag{1}$$

其中, \mathcal{L} 表示损失函数. 基于面向某一特定任务的本地更新参数 θ_i^* , 模型在不同的任务上, 以全域学习率 μ 优化 $\mathcal{L}_{\mathcal{T}_i}(f_{\theta_i^*})$. 通过这样的方式, 全域参数 θ 可以适应不同的任务:

$$\min_{\theta} \sum_{\mathcal{T}_i \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_i}(\theta_i^*) = \sum_{\mathcal{T}_i \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_i}(f_{\theta - \epsilon \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})}) \tag{2}$$

$$\theta = \theta - \mu \nabla_{\theta} \sum_{\mathcal{T}_i \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_i}(f_{\theta_i^*}) \tag{3}$$

在全域更新的过程中, 全域参数 θ 以将 θ_i^* 作用于查询集的损失来更新(学会学习的过程).

3 模型

本节主要介绍一个新的模型 CM-HIN 来解决冷启动问题, 即基于异质信息网络上的对比元学习. 首先介绍该模型的概览, 然后介绍模型的细节.

3.1 模型概览

如图 3 所示, 该模型是一个基于 MAML^[8] 的元学习框架, 在进行冷启动推荐时, 需要明确具体的设置. 将一个任务与一个用户进行绑定, 即对于一个用户 u , $\mathcal{T}_u=(S_u, Q_u)$, 其中, S_u 表示支持集, Q_u 表示查询集. 在元训练过程中, S_u 和 Q_u 是从用户 u 已有交互的物品集中选取的, 且 S_u 和 Q_u 中包含的物品互不重复. 而在元测试的过程中, $\mathcal{T}_u \in \mathcal{T}_{test}$ 同样有测试集和查询集, 而查询集中物品需要被预测评分. 如第 2.4 节所述: UC 任务是新的用户, 即元训练中不存在的用户; IC 任务是新物品, 即元训练中不存在的物品; 而 UIC 任务代表用户和物品均未在元训

练中出现.

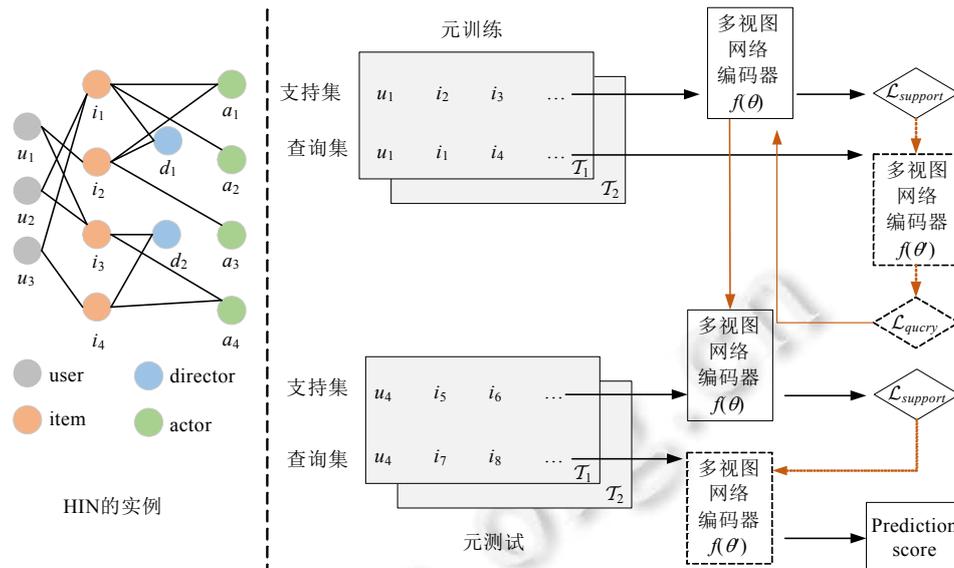


图3 CM-HIN 的整体框架图

对于每一个任务, 在元训练过程中, 支持集上的样本首先由参数为 θ 的多视图图谱编码器训练, 得到支持集的损失函数 $\mathcal{L}_{support}$, 并用来将编码器参数更新为 θ' . 然后, 对应的查询集中的样本由参数为 θ' 的编码器训练, 得到查询集的损失函数 \mathcal{L}'_{query} . 在元训练中的所有任务上重复该步骤, 以计算 \mathcal{L}'_{query} 的和, 然后用其更新编码器的参数. 更新后的编码器作用于元测试中的支持集, 并得到元测试支持集的损失函数. 用该损失函数训练编码器, 最后, 在查询集中预测得到最终的物品评分.

可以看到, 该框架的关键部分是多视图图谱编码器的构建. 我们基于对比学习构建该编码器, 充分挖掘和利用异质信息网络的特征.

3.2 多视图图谱编码器

我们利用对比学习的方法, 从网络模式和元路径这两个视图来分别挖掘异质信息网络的特征. 如第 2.2 节和第 2.3 节所介绍的, 网络模式主要针对网络的本地结构, 而元路径主要针对网络的高阶结构. 以支持集中的 (u_1, i_2) 为例, 基于 (u_1, i_2) 采样得到相关的元路径与网络模式实例, 并将其输入到如图 4 所示的多视图图谱编码器中.

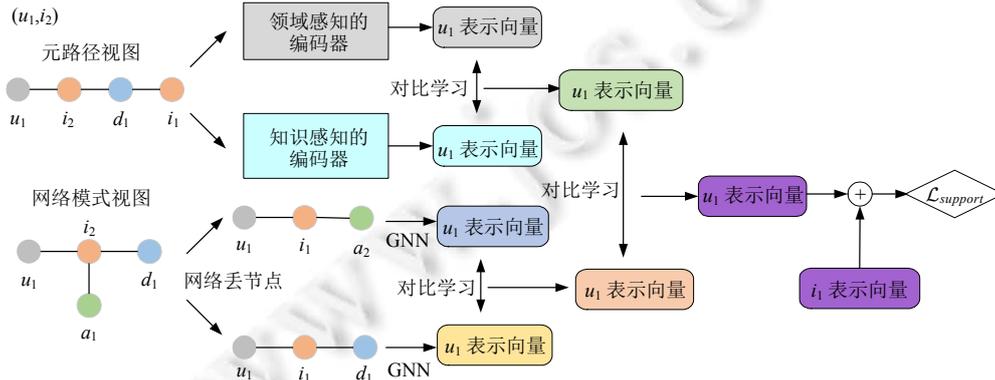


图4 多视图图谱编码器

3.2.1 元路径视图的对比学习

• 邻域感知的编码器

GCN^[34]通过聚合邻域节点学习目标节点的表示,因此,基于元路径的 GCN 编码器可以视为邻域感知的编码器.对于支持集中的 u_1 ,存在一个以该节点为起点的元路径集合 $\{P_1, P_2, \dots, P_M\}$.给定一个元路径 P_n ,可以得到基于该元路径的邻居节点集合 $N_u^{P_n}$.例如图 4, $u_1 i_2 d_1 i_1$ 是元路径 $UIDI$ 的实例,而 i_2 、 d_1 、 i_1 是该元路径下 u_1 的邻居节点.每一种元路径代表了一种语义,对于元路径 P_n ,用元路径 GCN 编码其特征,得到:

$$h_u^{P_n} = \frac{1}{d_u + 1} h_u + \sum_{j \in N_u^{P_n}} \frac{1}{\sqrt{(d_u + 1)(d_j + 1)}} h_j \quad (4)$$

其中, d_u 和 d_j 分别是节点 u 和节点 j 映射特征向量的维度.对于元路径集合,那么节点 u 就有 M 个表示向量,即 $\{h_u^{P_1}, \dots, h_u^{P_M}\}$.采用注意力机制为不同的元路径赋予不同的权重组合,得到最终的元路径视图下邻域感知的表示 z_u^{mpn} :

$$z_u^{mpn} = \sum_{n=1}^M \alpha_{P_n} \cdot h_u^{P_n} \quad (5)$$

其中,权重 α_{P_n} 的计算如下:

$$w_{P_n} = \frac{1}{|V|} \sum_{u \in V} \mathbf{a}_{mp}^T \cdot \tanh(\mathbf{w}_{mp} h_u^{P_n} + \mathbf{b}_{mp}) \quad (6)$$

$$\alpha_{P_n} = \frac{\exp(w_{P_n})}{\sum_{u=1}^M \exp(w_{P_u})} \quad (7)$$

其中, $\mathbf{w}_{mp} \in \mathbb{R}^{d \times d}$ 和 $\mathbf{b}_{mp} \in \mathbb{R}^{d \times 1}$ 是可学习的参数, \mathbf{a}_{mp} 表示元路径级的注意力向量.

• 知识感知的编码器

上述聚合邻域信息的操作,没有考虑元路径本身所持有的语义信息即知识.例如,元路径 IDI 代表了具有相同导演的电影这一知识,也可视为联结该路径头尾节点的真实关系.因此,我们将元路径实例视为三元组 (u, P, j) .对于一个三元组 (u, P, j) ,可以得到如下的得分函数:

$$s(u, P, j) = \|W_r h_u + h_p - W_r h_j\|_2^2 \quad (8)$$

其中, h_u 、 h_p 和 h_j 分别为头节点、元路径和尾节点的表示; W_r 是映射矩阵,将头节点和尾节点映射至元路径的表示空间.该得分函数越小,表明这个三元组成立的概率越大.通过负采样得到不成立的三元组 $(u, P, j)'$,可以得到如下的得分函数:

$$\mathcal{L}_{Knowledge} = \sum_{(u, P, j), (u, P, j)' \in Triplet} -\ln \sigma(s(u, P, j) - s(u, P, j')) \quad (9)$$

其中, $Triplet$ 是包含正例和负例三元组的集合.具体地,在负采样时,通过替换正例三元组的头节点或尾节点构建负样本,替换后仍为正例的三元组会被剔除.训练得到用户 u 元路径视图下知识感知的表示向量 z_u^{mpk} .

• 邻域感知和知识感知的对比学习

在冷启动推荐中,除了少量的标签信息外,存在大量的无标签信息.为了充分利用这些无标签信息,采用自监督的对比学习来区分两种感知模式下同一节点的表示与其他节点的表示.对于一个用户 u ,邻域感知下的表示为 z_u^{mpn} ,知识感知下的表示为 z_u^{mpk} ,它们之间组成正例,而其他节点的表示作为负例.由此,可以得到如下的目标函数:

$$\mathcal{L}_{constrative}^{mp} = -\log \frac{\exp(\text{sim}(z_u^{mpn}, z_u^{mpk}) / \tau)}{\sum_{j \in V} \exp(\text{sim}(z_j^{mpn}, z_j^{mpk}) / \tau)} \quad (10)$$

其中,

- $\text{sim}(\cdot, \cdot)$ 表示为 $\text{sim}(\cdot, \cdot) = e(g(\cdot), g(\cdot))$, 其中, $g(\cdot)$ 是多层感知器(MLP),由非线性激活函数转换表示;而 $e(\cdot)$ 是相似度函数,我们采用余弦相似度进行计算;

➤ τ 代表温度参数.

最终, 我们训练如下的得分函数以获得用户 u 在元路径视图下的表示 z_u^{mp} :

$$\mathcal{L}^{mp} = \mathcal{L}_{Knowledge} + \mathcal{L}_{contrastive}^{mp} \quad (11)$$

3.2.2 网络模式视图的对比学习

• 网络模式的 GNN 编码器

给定用户节点 u , 它与 K 个其他类型的节点相连 $\{A_1, A_2, \dots, A_K\}$. 那么, $N_u^{A_n}$ 可表示为节点 u 的类型为 A_n 的邻居节点. 类似地, 参照 GNN 编码器聚合的思想, 我们首先聚合同一类型下的邻居节点:

$$h_u^{A_n} = \sigma \left(\sum_{j \in N_u^{A_n}} h_j \right) \quad (12)$$

其中, σ 是激活函数, h_j 是节点 j 的映射特征向量.

不同类型的节点对与给定节点 u 的表示会有不同的贡献, 因此, 在得到各个类型的表示向量 $\{h_u^{A_1}, h_u^{A_2}, \dots, h_u^{A_K}\}$ 之后, 采用注意力机制获得网络模式下的表示 z_u^{ns} . 首先, 需要计算各个节点类型的权重:

$$w_{A_n} = \frac{1}{|V|} \sum_{u \in V} \mathbf{a}_{ns}^T \cdot \tanh(\mathbf{w}_{ns} h_u^{A_n} + \mathbf{b}_{ns}) \quad (13)$$

$$\alpha_{ns} = \frac{\exp(w_{A_n})}{\sum_{u=1}^K \exp(w_{A_u})} \quad (14)$$

其中, $\mathbf{w}_{sc} \in \mathbb{R}^{d \times d}$ 和 $\mathbf{b}_{sc} \in \mathbb{R}^{d \times 1}$ 是可学习的参数, \mathbf{a}_{sc} 表示类型级的注意力向量, α_{ns} 即为各个类型节点的权重. 由此可得 z_u^{ns} 的表示向量:

$$z_u^{ns} = \sum_{n=1}^M \alpha_{p_n} \cdot h_u^{p_n} \quad (15)$$

• 图谱丢节点对比学习

采用图谱丢节点操作来进行图谱增强, 实现图谱结构级的对比学习. 具体地, 如图 4 所示, 分别丢掉导演和演员类别的节点, 采用上述网络模式的 GNN 编码器进行编码. 对于节点 u , 丢掉导演节点的表示为 z_u^{ns-d} , 丢掉演员节点的表示为 z_u^{ns-a} , 它们之间组成正例, 而其他节点的表示作为负例. 由此, 类似元路径视图下的对比学习, 可以得到如下目标函数:

$$\mathcal{L}_{contrastive}^{ns} = -\log \frac{\exp(\text{sim}(z_u^{ns-d}, z_u^{ns-a}) / \tau)}{\sum_{j \in V} \exp(\text{sim}(z_j^{ns-d}, z_j^{ns-a}) / \tau)} \quad (16)$$

其中,

- $\text{sim}(\cdot, \cdot)$ 表示为 $\text{sim}(\cdot, \cdot) = e(\mathbf{g}(\cdot), \mathbf{g}(\cdot))$, 其中, $\mathbf{g}(\cdot)$ 是多层感知器 (MLP), 由非线性激活函数转换表示; 而 $e(\cdot)$ 是相似度函数, 我们采用余弦相似度进行计算;
- τ 代表温度参数.

最终, 我们训练如上的得分函数以获得用户 u 在网络模式视图下的表示 z_u^{ns} .

3.2.3 元路径视图与网络模式视图下的对比学习

对于用户 u , 在分别获得元路径视图下的表示 z_u^{mp} 和网络模式视图下的表示 z_u^{ns} 之后, 我们继续采用对比学习利用自监督的信息, 由此, 可以充分挖掘元路径的高阶结构信息和本地结构信息, 并进行整合. 具体地, 同一节点 u 的元路径视图下的表示 z_u^{mp} 和网络模式视图下的表示 z_u^{ns} 为正例对, 其余节点的表示为负例. 于是得到如下目标函数:

$$\mathcal{L}_{contrastive}^{multi-view} = -\log \frac{\exp(\text{sim}(z_u^{mp}, z_u^{ns}) / \tau)}{\sum_{j \in V} \exp(\text{sim}(z_j^{mp}, z_j^{ns}) / \tau)} \quad (17)$$

其中, $\text{sim}(\cdot, \cdot)$ 与各个视图下的 $\text{sim}(\cdot, \cdot)$ 一致, τ 代表温度参数.

最终, 我们训练如下的得分函数充分利用异质信息网络中的无标签信息, 获得了用户 u 在双视图对比下的表示 $z_u^{\text{multi-view}}$:

$$\mathcal{L}_{\text{unsupervised}} = \mathcal{L}_{\text{contrastive}}^{\text{ms}} + \mathcal{L}^{\text{mp}} + \mathcal{L}_{\text{contrastive}}^{\text{multi-view}} \quad (18)$$

3.2.4 用户与物品的得分计算

采用同样的方式, 可以计算得到物品的表示向量 $z_i^{\text{multi-view}}$. 根据用户表示向量 $z_u^{\text{multi-view}}$ 和物品表示向量 $z_i^{\text{multi-view}}$, 可以预测用户 u 对物品 i 的偏好得分:

$$\hat{r}_{u,i} = f_\gamma(z_u^{\text{multi-view}}, z_i^{\text{multi-view}}) = \text{MLP}(z_u^{\text{multi-view}} \oplus z_i^{\text{multi-view}}) \quad (19)$$

其中, MLP 是双层的多层感知器, \oplus 表示联结操作. f_γ 是得分的预测函数, γ 是其中的参数, 包括了多层感知器中的权重和偏差. 对于用户 u , 最小化如下的损失函数以学习它的偏好:

$$\mathcal{L}_{\text{supervised}} = \frac{1}{|\mathcal{R}_u|} \sum_{i \in \mathcal{R}_u} (r_{u,i} - \hat{r}_{u,i})^2 \quad (20)$$

其中, $\mathcal{R}_u = \{i: r_{u,i} \in \mathcal{R}\}$ 表示已被用户 u 标记的物品集, $r_{u,i}$ 是用户 u 对物品 i 真实的评分. 因此, 该损失函数是有监督条件下得到的.

对于一个给定的任务 \mathcal{T}_u , 元学习过程中的损失函数是有监督和自监督损失函数的组合:

$$\mathcal{L}_{\mathcal{T}_u}(\theta) = \lambda \mathcal{L}_{\text{unsupervised}} + (1 - \lambda) \mathcal{L}_{\text{supervised}} \quad (21)$$

其中, λ 衡量有监督和无监督损失函数的比重, 将其设为 0.2; θ 为多视图图谱编码器的参数.

3.3 基于梯度的元学习

如第 2.5 节介绍, 对于任务即用户 u , 根据元学习在支持集上的损失函数, 以 ε 为本地更新学习率, 更新得到视图图谱编码器的参数 θ'_u :

$$\theta'_u = \theta - \varepsilon \nabla_{\theta} \mathcal{L}_{\mathcal{T}_u}(f_{\theta}) \quad (22)$$

然后, 模型在查询集的所有任务上, 以全局学习率 μ 优化 $\mathcal{L}_{\mathcal{T}_u}(f_{\theta'_u})$, 从而更新全域参数 θ .

$$\min_{\theta} \sum_{\mathcal{T}_u \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_u}(\theta'_u) = \sum_{\mathcal{T}_u \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_u}(f_{\theta - \varepsilon \nabla_{\theta} \mathcal{L}_{\mathcal{T}_u}(f_{\theta})}) \quad (23)$$

$$\theta = \theta - \mu \nabla_{\theta} \sum_{\mathcal{T}_u \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_u}(f_{\theta'_u}) \quad (24)$$

这样, 全域参数 θ 可以快速适应不同的任务.

在元测试中, 将 θ 作用于支持集的新任务上, 根据支持集上的损失函数快速更新参数, 将该参数应用于查询集, 训练得到用户对某一物品的得分偏好.

3.4 模型健壮性分析

对比学习会造成模型健壮性下降, 即无法顺利迁移到其他领域. 然而, 本文的元学习框架却具有迁移性, 在元训练中使用某领域数据集进行训练, 在元测试中可以用其他领域的数据集进行测试. 因此, 元学习框架弥补了对比学习带来的健壮性和迁移性弱的问题.

4 实验分析

4.1 数据集

我们在 3 个常用的公开基准数据集上展开实验, 分别是 DBook (<https://book.douban.com>)、MovieLens (<https://grouplens.org/datasets/movielens/>) 和 Yelp (<https://www.yelp.com/dataset/challenge>). 它们的数据统计结果见表 1(下划线表示被推荐的物品类型).

表 1 实验数据集

数据集	节点类型	节点数量	边类型	边的数量	稀疏度(%)
DBook	User (<i>U</i>)	10 529	<i>UB</i>	649 381	99.71
	Book (<i>B</i>)	20 934	<i>BA</i>	20 934	
	Author (<i>A</i>)	10 544	<i>UU</i>	169 150	
MovieLens	User (<i>U</i>)	6 040	<i>UM</i>	1 000 209	95.73
	Movie (<i>M</i>)	3 881	<i>MA</i>	15 738	
	Actor (<i>A</i>)	8 030	<i>MD</i>	4 210	
	Director (<i>D</i>)	2 186			
Yelp	User (<i>U</i>)	51 264	<i>UB</i>	1 301 869	92.63
	Business (<i>B</i>)	34 199	<i>BC</i>	34 199	
	City (<i>C</i>)	510	<i>BT</i>	103 150	
	Category (<i>T</i>)	541			

DBook 是一个被广泛使用的书籍评分数据集^[19], 书籍由 1–5 评分. MovieLens 是由 GroupLens 发布的基准数据集, 包括了 1919 年到 2000 年的电影评分, 评分同样在 1–5 之间. Yelp 也是一个广泛使用的推荐数据集, 每一个商户的评分也在 1–5 之间.

在每个数据集中, 根据用户的加入时间或首次打分时间以及物品首次出现时间, 将用户和物品分为两类: 已存在的和新出现的. 新出现的用户(物品)和已存在的用户(物品)的比例大致为 2:8. 然后, 再将数据集分为元训练集和元测试集. 在元训练集中, 训练的都是已存在的用户和已存在的物品以及它们之间的评分. 将元训练集中 10% 的数据作为验证集, 其余均为元测试数据集. 由此, 在整个训练过程中, 训练集占 72%, 验证集占 8%, 测试集占 20%. 可以分为 3 种冷启动情景: (1) 为新用户推荐已存在的物品(UC 问题); (2) 为老用户推荐新物品(IC 问题); (3) 为新用户推荐新物品(UIC 问题).

接着构建支持集和查询集. 取已为 13 个至 100 个物品打过的用户, 其中选取 10 个物品作为查询集, 其余的物品作为该用户的支持集. 支持集大小的影响将在参数分析中进行衡量. 构建元路径时, 将长度设为最大为 3. 元路径的构建是随机的, 长度 ≤ 3 的存在于该网络中的元路径均会被构建, 例如图 3 中的 *UIDI*、*UIAI*、*IDI*、*UI* 等各种存在于网络中的元路径, 都会被获取和构建.

4.2 评价指标及基准模型

在本文中, 我们采用 3 个常用的评价指标^[3,10,19], 分别是平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和归一化折扣累计收益(normalized discounted cumulative gain, NDCG). 我们计算排序为 5 时的 NDCG, 即 $NDCG@5$. MAE 值越低、RMSE 值越低、 $NDCG@5$ 值越高, 代表模型的效果越好.

为了验证模型的有效性, 我们选择了下列基准模型. 首先是传统的推荐方法, 将其应用于冷启动场景下.

- FM^[35]是一个基于特征的基准模型, 它可以利用辅助信息. 将二阶互动的因式分解的秩设为 8, 并采用系数为 0.1 的 $L2$ 正则化;
- NeuM^[3]包括一个通用的矩阵分解模块和多层感知器模块. 将层数设为(64,32,16,8), 学习率设为 0.001;
- DropoutNet^[17]是一个基于神经网络的模型, 学习率设为 0.9, dropout 率设为 0.5;
- GC-MC^[36]是一个基于图谱的自动编码器框架, 以实现矩阵补全. 第 1 层和第 2 层的隐藏单元分别设为 500 和 75. Dropout 的比例设为 0.7.

我们又选择了一些基于异质信息网络的表示推荐模型, 它们设计时未考虑冷启动推荐场景.

- Metapath2Vec^[24]应用基于随机游走的元路径学习节点表示. 随机游走的长度设为 40, 随机游走的个数设为 10, Word2Vec 窗口的大小设为 3;
- HAN^[27]利用层级注意力来描述节点级和语义级的信息. 注意力头设为 3, 学习率设为 0.005, dropout 率设为 0.6.

下面是基于异质信息网络的冷启动推荐模型.

- HERec^[19]是一个基于异质信息网络推荐的异质网络表示模型. 将其中需要调整的参数 α 和 β 设为 1.0, 其余随机游走的设定与 Metapath2Vec 一致;
- MvDGAE^[13]在异质信息网络上采用多视图的去噪自编码器来解决冷启动问题. 将学习率设为 0.005, 表示维度设为 128, dropout 率设为 0.4.

最后, 我们也采用了元学习的冷启动模型作为基准模型.

- MetaEmb^[11]是一个为点击率(click through rate, CTR)预测的元学习模型. 将系数 α 设为 0.1;
- MeLU^[10]是在推荐系统中, 采用 MAML 框架解决冷启动问题的模型. 两层决策层均为 64 个节点, 本地更新步骤设为 1;
- MetaHIN^[12]是一个在异质信息网络上, 采用元学习解决冷启动问题的模型. 表示的维度设为 32, 元学习率设为 0.000 5.

4.3 实验细节

我们使用自适应矩估计(adaptive moment estimation, Adam)来优化 CM-HIN. 对于所有的数据集, 每一批次的大小设为 32. 全域学习率设为 0.000 5, 本地学习率设为 0.01, 本地更新的次数设为 1. 节点表示向量的维度设为 64. 温度参数设为 0.07. 我们采用 PyTorch 和 Python 来运行 CM-HIN. 采用的硬件设备为 Intel(R) Core(TM)i7-10700K CPU+RTX 3090 GPU, 内存为 64 GB. 采用的操作系统为 Ubuntu 16.04.1.

4.4 实验结果与分析

在本节中, 为了验证模型的有效性, 我们将 CM-HIN 在 3 个公开数据集上与各个先进的基准模型进行比较, 包括 3 个冷启动情景 UC、IC 和 UIC 以及非冷启动情景.

表 2-表 5 分别展示了以上 4 个场景的实验结果. 加粗的结果表明最好的结果, 下划线表示次好的结果.

表 2 UC 情景下, 3 个数据集上的实验结果

模型	DBook			MovieLens			Yelp		
	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5
FM	0.702 7	0.915 8	0.803 2	1.042 1	1.323 6	0.730 3	0.958 1	1.217 7	0.807 5
NeuMF	0.654 1	0.805 8	0.822 5	0.856 9	1.050 8	0.770 8	0.941 3	1.154 6	0.768 9
DropoutNet	0.831 1	0.901 6	0.811 4	0.929 1	1.172 1	0.770 5	0.855 7	1.036 9	0.795 9
GC-MC	0.906 1	0.976 7	0.782 1	1.151 3	1.374 2	0.721 3	0.932 1	1.110 4	0.803 4
Mp2Vec	0.666 9	0.839 1	0.814 4	0.879 3	1.096 8	0.823 3	0.897 2	1.161 3	0.823 5
HERec	0.651 8	0.8192	0.823 3	0.869 1	0.991 6	0.838 9	0.889 4	1.099 8	0.823 5
HAN	0.653 7	0.826 5	0.792 1	0.947 2	1.140 2	0.717 6	0.943 8	1.151 8	0.750 0
MvDGAE	<u>0.600 9</u>	<u>0.716 8</u>	<u>0.905 9</u>	<u>0.779 8</u>	<u>0.952 6</u>	<u>0.873 4</u>	<u>0.781 4</u>	<u>0.928 1</u>	<u>0.863 5</u>
MetaEmb	0.678 2	0.855 3	0.852 7	0.826 1	1.030 8	0.779 5	0.898 8	1.049 6	0.787 5
MeLU	0.635 3	0.773 3	0.879 3	0.810 4	0.975 6	0.841 5	0.834 1	1.001 7	0.827 5
MetaHIN	0.601 9	0.726 1	0.889 3	0.786 9	0.959 3	0.849 2	0.791 5	0.944 5	0.838 5
CM-HIN	0.587 9	0.705 4	0.915 4	0.764 5	0.948 9	0.884 5	0.774 1	0.918 4	0.884 5

表 3 IC 情景下, 3 个数据集上的实验结果

模型	DBook			MovieLens			Yelp		
	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5
FM	0.718 6	0.921 1	0.834 2	1.348 8	1.850 3	0.721 8	0.829 3	1.103 2	0.812 2
NeuMF	0.706 3	0.818 8	0.739 6	0.982 2	1.204 2	0.606 3	0.927 3	1.100 9	0.772 2
DropoutNet	0.712 2	0.802 1	0.822 9	0.960 4	1.175 5	0.754 7	0.811 6	1.030 1	0.794 3
GC-MC	0.908 1	0.970 2	0.763 4	1.043 3	1.275 3	0.706 2	0.899 8	1.104 3	0.802 3
Mp2Vec	0.737 1	0.929 4	0.823 1	1.061 5	1.300 4	0.636 7	0.797 9	1.030 4	0.833 7
HERec	0.748 1	0.941 2	0.782 7	0.995 9	1.178 2	0.731 2	0.810 7	1.047 6	0.829 1
HAN	0.661 9	0.835 8	0.778 7	0.914 7	1.085 7	0.727 3	0.812 6	1.028 6	0.757 4
MvDGAE	<u>0.612 2</u>	<u>0.740 6</u>	<u>0.894 7</u>	<u>0.856 6</u>	<u>0.978 9</u>	<u>0.844 2</u>	<u>0.695 2</u>	<u>0.854 3</u>	<u>0.882 7</u>
MetaEmb	0.674 1	0.799 3	0.853 7	0.908 4	1.087 4	0.813 3	0.805 5	0.940 7	0.809 2
MeLU	0.651 8	0.773 8	0.888 2	0.919 6	1.094 1	0.804 1	0.756 7	0.916 9	0.845 1
MetaHIN	0.625 2	0.746 9	0.890 2	0.867 5	1.046 2	0.834 1	0.717 4	0.869 6	0.855 1
CM-HIN	0.602 4	0.735 4	0.904 1	0.841 2	0.970 1	0.856 4	0.681 5	0.841 1	0.899 4

表 4 UIC 情景下, 3 个数据集上的实验结果

模型	DBook			MovieLens			Yelp		
	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5
FM	0.832 6	0.958 7	0.820 1	1.300 1	1.735 1	0.701 5	0.836 3	1.117 6	0.827 8
NeuMF	0.694 9	0.821 7	0.856 6	0.968 6	1.283 2	0.806 3	0.986 0	1.140 2	0.783 6
DropoutNet	0.831 6	0.848 9	0.801 2	0.963 5	1.179 1	0.761 7	0.822 5	0.973 6	0.805 9
GC-MC	0.781 3	0.890 8	0.800 3	1.029 5	1.263 5	0.730 2	0.889 4	1.110 9	0.792 3
Mp2Vec	0.798 7	1.013 5	0.852 7	1.054 8	1.289 5	0.668 7	0.838 1	1.099 3	0.813 7
HERec	0.785 9	0.981 3	0.854 5	0.997 4	1.101 2	0.738 9	0.827 4	0.988 7	0.803 4
HAN	0.658 8	0.833 9	0.800 3	0.946 7	1.140 4	0.690 7	0.832 0	1.032 3	0.755 9
MvDGAE	0.620 1	0.743 3	0.905 4	0.849 6	0.986 9	0.855 3	0.707 4	0.852 3	0.872 2
MetaEmb	0.773 3	0.990 1	0.854 1	0.912 2	1.108 8	0.808 7	0.828 5	0.947 6	0.818 8
MeLU	0.651 7	0.775 2	0.889 1	0.909 1	1.079 2	0.810 6	0.735 8	0.892 1	0.845 2
MetaHIN	0.631 8	0.758 9	0.893 4	0.858 6	1.028 6	0.837 4	0.719 5	0.869 5	0.852 1
CM-HIN	0.610 1	0.735 4	0.911 4	0.838 7	0.974 1	0.867 4	0.697 7	0.842 8	0.885 7

表 5 非冷启动情景下, 3 个数据集上的实验结果

模型	DBook			MovieLens			Yelp		
	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5
FM	0.735 8	0.976 3	0.808 6	1.004 3	1.162 8	0.649 3	0.864 2	1.065 5	0.798 6
NeuMF	0.690 4	0.837 3	0.792 4	0.924 9	1.138 8	0.733 5	0.761 1	0.973 1	0.806 9
DropoutNet	0.710 8	0.799 1	0.826 8	0.959 5	1.173 1	0.723 1	0.821 9	1.033 3	0.739 4
GC-MC	0.805 6	0.924 9	0.803 2	0.986 3	1.223 8	0.714 7	0.851 8	1.032 7	0.802 3
Mp2Vec	0.689 7	0.847 1	0.834 2	0.878 8	1.100 6	0.709 1	0.792 4	1.019 1	0.800 5
HERec	0.679 4	0.840 9	0.841 1	0.865 2	1.000 7	0.718 2	0.791 1	0.989 7	0.810 1
HAN	0.638 2	0.824 9	0.786 0	0.896 8	1.084 8	0.737 7	0.792 5	0.994 3	0.763 8
MvDGAE	0.563 4	0.706 9	0.911 4	0.698 7	0.885 9	0.880 1	0.692 1	0.833 9	0.882 9
MetaEmb	0.709 5	0.821 8	0.796 7	0.808 6	1.014 9	0.807 7	0.767 7	0.978 9	0.774 0
MeLU	0.651 9	0.783 4	0.869 7	0.808 4	0.997 8	0.843 3	0.738 2	0.902 8	0.835 6
MetaHIN	0.639 3	0.770 4	0.885 9	0.799 7	0.949 1	0.849 9	0.695 2	0.844 5	0.847 7
CM-HIN	0.554 1	0.684 1	0.921 5	0.674 1	0.874 5	0.898 4	0.687 1	0.824 7	0.895 4

针对所有冷启动情景, CM-HIN 相较所有模型都取得了最好的结果. 传统方法的实验结果是最差的, 因为它们只将异质网络的信息作为内容特征, 忽略了异质信息网络中丰富的语义和高阶网络结构信息. 基于异质信息网络的模型可以取得相对较好的模型, 这证明, 利用元路径可以在一定程度上挖掘网络的语义和高阶结构信息. 除了 MvDGAE 之外, 其余的基于异质信息网络的模型都遵循传统的监督学习模式, 忽略了在冷启动问题中会存在的训练和推理过程的差异性. 采用元学习的方法可以更好地处理训练和推理数据差异性的问题, 从而使基于元学习的方法普遍优于除了 MvDGAE 的基于异质信息网络的模型. MvDGAE 通过重构丢弃的若干视图的方式来解决冷启动问题, 取得了较好的效果, 但仍然要差于 CM-HIN 的性能. 这是因为 MvDGAE 仅将不同的元路径当作视图, 而 CM-HIN 的视图既包括元路径, 也包括网络模式, 既描述了元路径具有的语义和高阶结构信息, 又描述了网络模式具有的语义和本地结构信息.

针对非冷启动情景, CM-HIN 依然取得了最好的结果. 虽然是非冷启动的场景, 但是如表 1 所示, 该数据集依然非常稀疏, 因此联合元路径视图和网络模式视图来深入挖掘异质信息网络的语义和结构信息, 可以适应稀疏性较高的实验数据集. 同时, 在利用元路径和网络模式视图的过程中, 采用对比学习充分挖掘网络中大量的无标签信息, 使得处理稀疏性数据更为高效.

4.5 消融分析

本节进行消融分析, 以验证模型中不同模块的贡献. 在元路径视图中, 为了分别验证邻域感知和知识感知模块的作用, 我们设计了两个模型变种: Neighbor⁻表明去除了邻域感知模块, 只以知识感知模块学习节点表示; Know⁻表明去除了知识感知模块, 只以邻域感知模块学习节点参数. 在网络模式视图中, 为了验证丢节点对比学习的作用, 我们设计了模型变种 Drop⁻, 它直接在网络模式实例上用本文设计的 GNN 编码器进行训练.

为了分别验证元路径视图和网络模式视图的作用, 我们设计了两个变种, 分别是 MP⁻和 NS⁻: 前者没有元路径视图模块, 只以网络模式视图训练; 后者没有网络模式模块, 只以元路径视图训练.

最后,为了验证元学习框架的有效性,我们采用了一个变种 BM,它只采用多视图参数编码器进行训练,不进行元学习。

表 6 展示了 UIC 情景下的消融分析的实验结果。由于在 3 个情景下的实验结果具有相似的趋势,因此仅展示 UIC 情景下的实验结果。Neighbor⁻和 Know⁻在 3 个数据集上都劣于 CM-HIN,这说明在元路径视图上综合利用邻域信息和知识信息可以帮助模型提升效果。Drop⁻也劣于 CM-HIN,这说明在网络模式视图中,采用丢节点对比学习相对于直接用 GNN 编码,在描述网络结构信息的同时,充分利用了无标签的信息。MP⁻和 NS⁻均大幅度劣于 CM-HIN,说明丢失任意一个视图都能对实验结果产生重大的影响,进一步证实了 CM-HIN 综合利用元路径的高阶结构与网络模式的本地结构的优势。BM 在所有变体中取得了最差的结果,突出了元学习框架在解决冷启动问题时的优势。

表 6 UIC 情景下的 CM-HIN 消融分析

模型	DBook			MovieLens			Yelp		
	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5	MAE	RMSE	NDCG@5
Neighbor ⁻	0.619 7	0.748 9	0.909 5	0.841 8	0.980 2	0.860 8	0.709 5	0.849 7	0.878 6
Know ⁻	0.618 9	0.748 5	0.908 8	0.842 1	0.981 2	0.860 1	0.708 5	0.848 1	0.879 7
Drop ⁻	0.615 1	0.739 8	0.910 8	0.840 1	0.976 8	0.864 7	0.700 5	0.845 2	0.882 1
MP ⁻	0.621 1	0.759 7	0.901 4	0.848 7	0.991 2	0.850 4	0.721 5	0.859 5	0.869 9
NS ⁻	0.620 4	0.754 1	0.902 8	0.847 7	0.990 8	0.851 3	0.719 9	0.854 5	0.872 5
BM	0.625 4	0.761 1	0.897 1	0.854 2	0.997 4	0.841 2	0.724 1	0.864 1	0.864 1
CM-HIN	0.610 1	0.735 4	0.911 4	0.838 7	0.974 1	0.867 4	0.697 7	0.842 8	0.885 7

4.6 参数分析

最后,我们探讨不同的参数选择对模型实验结果的影响。同样地,因为不同的冷启动场景下结果趋势类似,我们仅选择 UIC 场景下的实验结果。我们选取了 3 个参数进行分析,分别是本地更新的次数、支持集的大小和表示向量维度的大小。

图 5 展示了不同的本地更新次数对实验表现的影响。本地更新的参数设为 1-5。可以看到,模型对本地更新的次数并不十分敏感,因此,只需要 1 次本地更新就可以快速为冷启动场景下的用户推荐物品,从而证明了模型的高效。

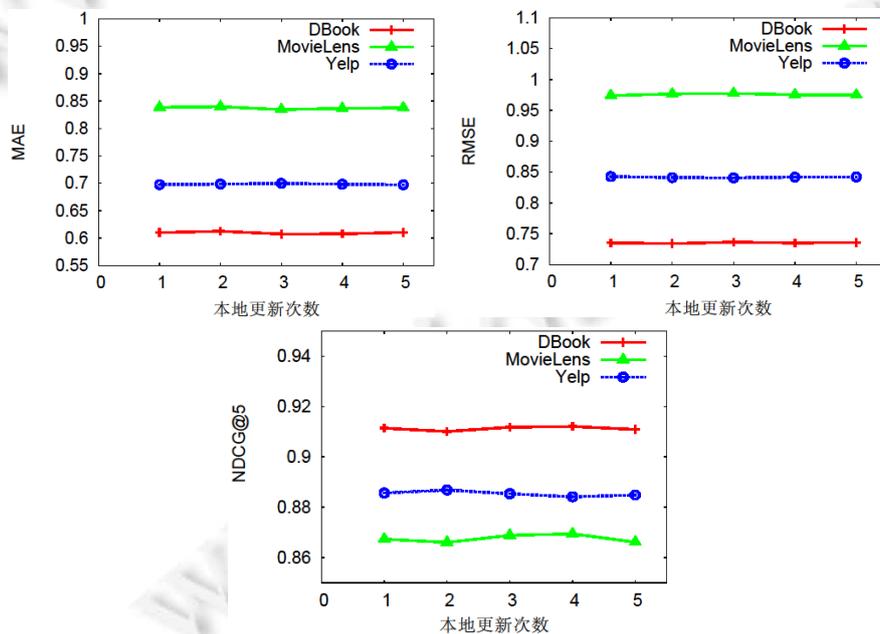


图 5 不同的本地更新次数的实验表现

图 6 展示了不同的支持集大小对实验表现的影响. 支持集的大小设为 5、10、20、40、80. 可以看到: 随着支持集大小的增加, 模型效果有一定的提升, 但是总体提升有限, 从而证明了 CM-HIN 可以在较小的支持集下就取得较好的成果, 非常适合解决冷启动问题.

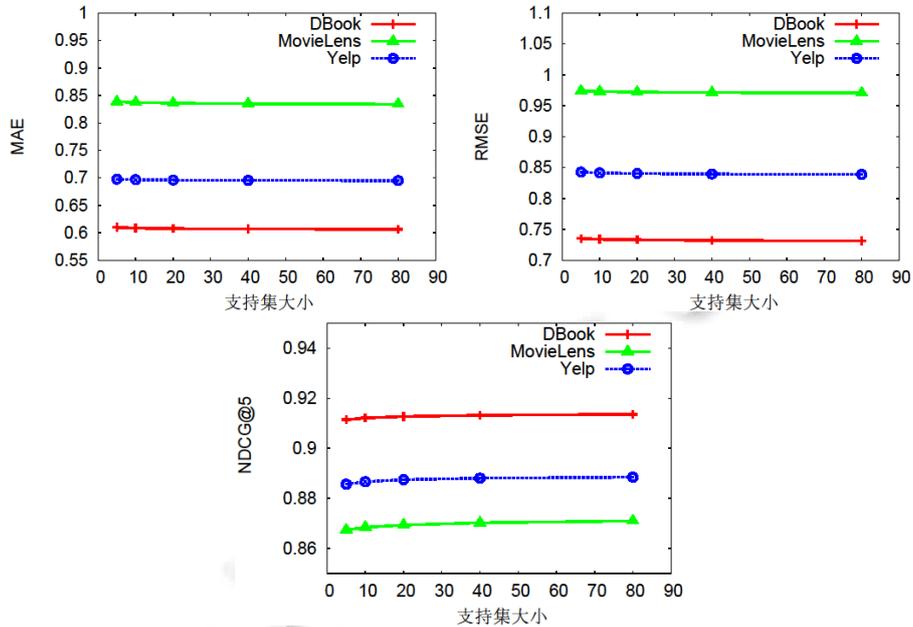


图 6 不同支持集大小的实验表现

图 7 展示了不同的向量表示维度对实验表现的影响. 维度的大小设为 16、32、64、128、256. 可以看到: 随着维度大小增加到 64, 模型的表现快速提升; 之后, 模型的表现基本维持稳定. 这说明 64 维的大小已经可以较好地表示向量的特征.

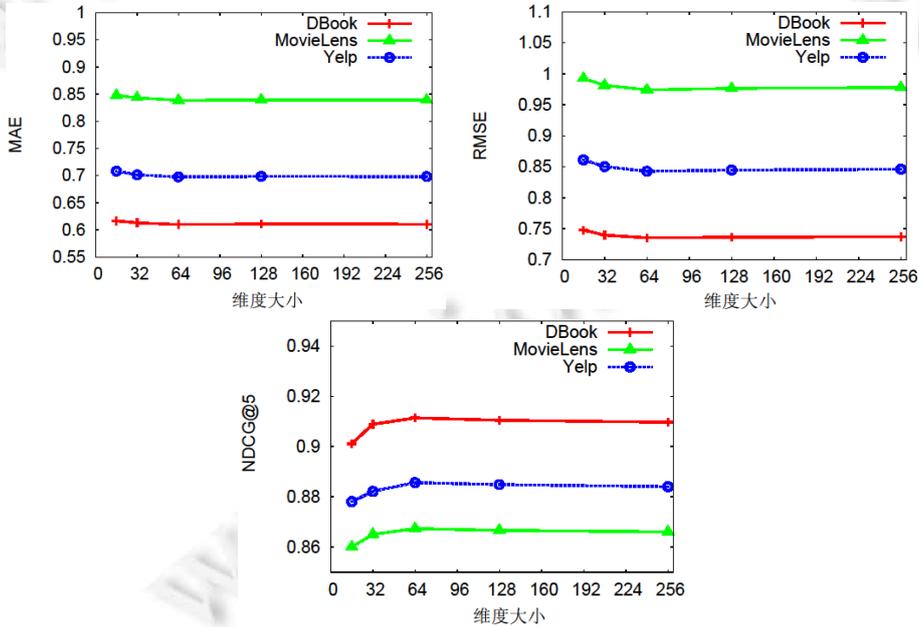


图 7 不同维度大小的实验表现

4.7 反例分析

本节我们对模型推荐错误的反例进行分析. 实验在 UIC 场景下进行, 实验比较的模型是效果较好的考虑了冷启动情形的模型, 即 HERec、MvDGAE、MetaEmb、MeLU 和 Meta-HIN. 应推荐的电影的类型为 Action, 可以看到, 只有 CM-HIN 推荐了同类型的电影(尽管电影推荐错误), 进一步验证了模型的有效性(见表 7).

表 7 反例分析

模型	MovieLens		
	UserID	MovieID	电影类型
HERec	33	67	Crime
MvDGAE	33	1 023	Thriller
MetaEmb	33	1 183	Adventure
MeLU	33	578	Thriller
MetaHIN	33	876	Crime
CM-HIN	33	1 354	Action

4.8 效率分析

本节我们对模型的效率进行分析, 分别展示了模型训练(标记为 train)和推理(标记为 inference)阶段的运行时间. 我们仅与效果较好的考虑了冷启动情形的模型进行比较, 即 HERec、MvDGAE、MetaEmb、MeLU 和 Meta-HIN. 由于其他两个场景与 UIC 场景下模型的性能相似, 因此我们仅考虑 UIC 场景下的运行时间. 由表 8 可以看到: 在冷启动方法中, CM-HIN 的运行时间仅比 HERec 高, 反映了模型较高的效率.

表 8 模型训练和推理的运行时间(s/epoch)

模型	DBook		MovieLens		Yelp	
	Train	Inference	Train	Inference	Train	Inference
HERec	70.4	1.9	20.5	1.8	108.5	2.4
MvDGAE	175.3	6.5	98.4	4.4	280.5	7.8
MetaEmb	119.9	3.5	65.4	2.9	200.4	4.4
MeLU	100.4	2.5	50.1	2.3	180.5	3.6
MetaHIN	150.4	4.9	80.5	3.5	230.2	5.5
CM-HIN	90.5	2.4	34.4	2.1	140.6	3.1

5 总结

推荐系统中, 解决冷启动问题旨在为交互信息十分稀疏的用户和物品学习有效的表示, 实际应用十分广泛. 本文提出了基于异质信息网络的对比元学习解决冷启动问题. 针对现有的基于元学习的冷启动模型无法有效刻画异质信息网络中的结构和语义信息以及忽视了大量的无标签信息等问题, 本文提出了多视图编码器, 处理了元路径和网络模式这两个视图, 分别挖掘高阶和本地的结构与语义信息; 而后, 在元路径和网络模式中使用对比学习挖掘网络的无标签信息, 并继续使用对比学习整合两个视图获得用户和物品的表示; 最后, 将该编码器整合在元学习框架中, 有效解决了冷启动推荐问题. 在 3 个公开基准数据集上进行了 3 个冷启动场景下的对比实验, CM-HIN 的实验结果优于所有基线模型, 验证了所提模型的有效性.

未来的研究有以下几个方向: (1) 本文在静态的推荐系统中进行实验, 下一步可以考虑时序信息, 进行动态的冷启动推荐; (2) 对比学习中正负例的设计可以进一步优化, 如设计更难被识别的负例; (3) 自监督的方法还包括生成式学习, 可以利用生成式学习进一步挖掘无标签信息.

References:

- [1] Dacrema MF, Cremonesi P, Jannach D. Are we really making much progress? A worrying analysis of recent neural recommendation approaches. In: Proc. of the 13th ACM Conf. on Recommender System. 2019. 101–109.
- [2] Hu B, Shi C, Zhao WX, Yu PS. Leveraging meta-path based context for top- n recommendation with a neural co-attention model. In: Proc. of the 24th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. 2018. 1531–1540.
- [3] Wang X, He XN, Wang M, Feng F, Chua TS. Neural graph collaborative filtering. In: Proc. of the 42nd ACM SIGIR Int'l Conf. on Research and Development in Information Retrieval. 2019. 165–174.

- [4] Zhu Y, Lin JH, He SB, Wang BD, Guan ZY, Liu HF, Cai D. Addressing the item cold-start problem by attribute-driven active learning. *IEEE Trans. on Knowledge and Data Engineering*, 2020, 32(4): 631–644.
- [5] Li XP, She J. Collaborative variational autoencoder for recommender systems. In: *Proc. of the 40th ACM SIGIR Int'l Conf. on Research and Development in Information Retrieval*. 2017. 305–314.
- [6] Shi C, Wang RJ, Wang X. A survey of heterogeneous information networks analysis and applications. *Ruan Jian Xue Bao/Journal of Software*, 2022, 33(2): 598–621 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6357.htm> [doi: 10.13328/j.cnki.jos.006357]
- [7] Sun YZ, Han JW, Yan XF, Yu PS, Wu TY. PathSim: Meta path-based top- K similarity search in heterogeneous information networks. *Proc. of the VLDB Endowment*, 2011, 4(11): 992–1003.
- [8] Finn C, Abbeel P, Levine S. Model-agnostic meta-learning for fast adaptation of deep networks. In: *Proc. of the 34th Int'l Conf on Machine Learning*. 2017. 1126–1135.
- [9] Vartak M, Thiagarajan A, Miranda C, Bratman J, Larochelle H. A meta-learning perspective on cold-start recommendations for items. In: *Proc. of the Annual Conf. on Neural Information Processing Systems*. 2017. 6904–6914.
- [10] Lee H, Im J, Jang S, Cho H, Chung S. MeLU: Meta-learned user preference estimator for cold-start recommendation. In: *Proc. of the 25th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining*. 2019. 1073–1082.
- [11] Pan F, Li S, Ao X, Tang PZ, He Q. Warm up cold-start advertisements: Improving CTR predictions via learning to learn ID embeddings. In: *Proc. of the 42nd ACM SIGIR Int'l Conf. on Research and Development in Information Retrieval*. 2019. 695–704.
- [12] Lu YF, Fang Y, Shi C. Meta-learning on heterogeneous information networks for cold-start recommendation. In: *Proc. of the 26th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining*. 2020. 1563–1573.
- [13] Zheng JW, Ma1 QL, Gu H, Zheng ZJ. Multi-view denoising graph auto-encoders on heterogeneous information networks for cold-start recommendation. In: *Proc. of the 27th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining*. 2021. 2338–2348.
- [14] Sun YZ, Han JW. Ming heterogeneous information networks: A structural analysis approach. *ACM SIGKDD Explorations Newsletter*, 2013, 14(2): 20–28.
- [15] Qiu JZ, Chen QB, Dong YX, Zhang J, Yang HX, Ding M, Wang KS, Tang J. GCC: Graph contrastive coding for graph neural network pre-training. In: *Proc. of the 26th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining*. 2020. 1150–1160.
- [16] Le DT, Fang Y, Lauw HW. Modeling sequential preferences with dynamic user and context factors. In: *Proc. of the Machine Learning and Knowledge Discovery in Databases—European Conf*. 2016. 145–161.
- [17] Volkovs M, Yu GW, Poutanen T. Dropoutnet: Addressing cold start in recommender systems. In: *Proc. of the Annual Conf. on Neural Information Processing Systems*. 2017. 4957–4966.
- [18] Fang Y, Lin WQ, Zheng VW, Wu M, Shi JQ, Chang K, Li XL. Metagraph-based learning on heterogeneous graphs. *IEEE Trans. on Knowledge and Data Engineering*, 2021, 33(1): 154–168.
- [19] Shi C, Hu BB, Zhao WX, Yu PS. Heterogeneous information network embedding for recommendation. *IEEE Trans. on Knowledge and Data Engineering*, 2018, 31(2): 357–370.
- [20] Wang X, He XN, Cao YX, Liu M, Chua TS. Kgat: Knowledge graph attention network for recommendation. In: *Proc. of the 25th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining*. 2019. 950–958.
- [21] Zhang YF, Ai QY, Chen X, Croft WB. Joint representation learning for top- n recommendation with heterogeneous information sources. In: *Proc. of the 2017 ACM Conf. on Information and Knowledge Management*. 2017. 1449–1458.
- [22] Hu GN, Zhang Y, Yang Q. Conet: Collaborative cross networks for cross-domain recommendation. In: *Proc. of the 2018 ACM Conf. on Information and Knowledge Management*. 2018. 667–676.
- [23] Kang SK, Hwang JY, Lee D, Yu H. Semi-supervised learning for cross-domain recommendation to cold-start users. In: *Proc. of the 2019 ACM Conf. on Information and Knowledge Management*. 2019. 1563–1572.
- [24] Dong YX, Chawla NV, Swami A. Metapath2Vec: Scalable feature learning for networks. In: *Proc. of the 23rd ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining*. 2017. 135–144.

- [25] Fu TY, Lee WC, Lei Z. Hin2Vec: Explore meta-paths in heterogeneous information networks for representation learning. In: Proc. of the 2017 ACM Conf. on Information and Knowledge Management. 2017. 1797–1806.
- [26] Zhang CX, Song DJ, Huang C, Swami A, Chawla NV. Heterogeneous graph neural network. In: Proc. of the 25th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. 2019. 793–803.
- [27] Wang X, Ji HY, Shi C, Wang B, Ye YF, Cui P, Yu PS. Heterogeneous graph attention network. In: Proc. of the World Wide Web Conf. 2019. 2022–2032.
- [28] Vilalta R, Drissi Y. A perspective view and survey of meta-learning. Artificial Intelligence Review, 2002, 18(2): 77–95.
- [29] Snell J, Swersky K, Zemel R. Prototypical networks for few-shot learning. In: Proc. of the Annual Conf. on Neural Information Processing Systems. 2017. 4077–4087.
- [30] Santoro A, Bartunov S, Botvinick M, Wierstra D, Lillicrap T. Meta-learning with memory-augmented neural networks. In: Proc. of the 33rd Int'l Conf on Machine Learning. 2016. 1842–1850.
- [31] Du ZX, Wang XW, Yang HX, Zhou JR, Tang J. Sequential scenario-specific meta learner for online recommendation. In: Proc. of the 25th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. 2019. 2895–2904.
- [32] Zhang XS, Tang FY, Dodge HH, Zhou JY, Wang F. Metapred: Meta-learning for clinical risk prediction with limited patient electronic health records. In: Proc. of the 25th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. 2019. 2487–2495.
- [33] Velickovic P, Fedus W, Hamilton WL, Lio P, Bengio Y, Hjelm RD. Deep graph infomax. In: Proc. of the 7th Int'l Conf. on Learning Representations. 2019.
- [34] Kipf TN, Welling M. Semi-supervised classification with graph convolutional networks. In: Proc. of the 5th Int'l Conf. on Learning Representations. 2017.
- [35] Rendle S, Gantner Z, Freudenthaler C, Schmidt-Thieme L. Fast context-aware recommendations with factorization machines. In: Proc. of the 34th ACM SIGIR Int'l Conf. on Research and Development in Information Retrieval. 2011. 635–644.
- [36] Berg RVD, Kipf TN, Welling M. Graph convolutional matrix completion. arXiv:1706.02263, 2017.

附中文参考文献:

- [6] 石川, 王睿嘉, 王啸. 异质信息网络分析与应用综述. 软件学报, 2022, 33(2): 598–621. <http://www.jos.org.cn/1000-9825/6357.htm> [doi: 10.13328/j.cnki.jos.006357]



方阳(1993—), 男, 博士生, 主要研究领域为异质信息网络, 表示学习.



肖卫东(1968—), 男, 博士, 教授, 博士生导师, 主要研究领域为情报智能, 数据工程.



谭真(1991—), 男, 博士, 讲师, 主要研究领域为知识图谱, 表示学习.



张玲玲(1992—), 女, 博士, 助理教授, CCF 专业会员, 主要研究领域为跨媒体信息挖掘, 零样本与小样本学习.



陈子阳(1999—), 男, 硕士生, 主要研究领域为知识图谱.



田锋(1972—), 男, 博士, 教授, 博士生导师, IEEE 高级会员, CCF 专业会员, 主要研究领域为大数据分析, 人工智能.