

3.1 引言

电子商务与互联网的快速发展催生了海量信息。然而,海量信息会引发信息过载问题,使用户难以获取目标信息。推荐系统作为众多电商平台解决信息过载的重要工具,通过向用户推荐个性化物品,既能提升用户体验,又能带来更可观的经济效益。目前,推荐系统已广泛应用于电商网络的商品推荐、新闻网络的新闻推荐、广告网络的广告推荐等场景。

GCN 凭借强大的数据表征能力,在推荐系统中展现出优异性能,因此受到越来越多的关注。例如,Noroozi 等提出的用户和项目联合深度建模框架(Joint Deep Modeling of Users and Items Using Reviews for Recommendation,DeepCoNN)利用 GCN 学习文本嵌入以实现推荐功能;随后,He 等提出的简化和增强图卷积网络 LightGCN,采用多层卷积模块学习用户与物品的高阶关系;为进一步优化模型性能,Pan 等提出的星图神经网络(Star Graph Neural Networks,SGNN-HN)模型构建星型图,以缓解基于会话推荐中 GCN 的过度平滑问题;与此同时,Zhang 等提出的增强图神经网络(Enhanced Graph Neural Network,E-GNN)模型,通过生成权重矩阵学习交互物品的连接模式,用于基于会话的推荐;随后,Li 等在特征交互 GCN(Feature Interactive Graph Neural Network,FIKGRec)模型中提出特征交互型 GCN,用于学习复杂的特征交互以完成推荐任务;而无参数动态图嵌入(Parameter-free Dynamic Graph Embedding,FreeGEM)引入了一种增量网络嵌入方法,用于生成物品与用户节点的嵌入向量。然而,上述方法均忽略了用户-物品交互的重要性差异,这可能导致推荐性能受限。

随后,出现了一些基于图注意力网络的模型,这类模型可通过注意力机制学习用户-物品交互的重要性差异。注意力机制借鉴人类的视觉注意力机制,先确定目标区域的关注点,再向该目标区域投入更多注意力资源以获取更详细的目标区域信息,目前已成功应用于推荐系统。例如,Xia 等提出的基于自监督的图协同训练(Self-supervised Graph Co-training,COTREC)模型,其基于图注意力网络采用自监督学习提升基于会话的推荐性能;与此同时,Xu 等提出的关系感知动态属性图注意力网络(Relation-aware Dynamic Attributed Graph Attention Network,RA-AGAT)采用一种关系感知的动态属性图注意力网络,用于股票推荐;进一步地,Liu 等提出的情景化图注意力网络(Contextualized Graph

Attention Network, CGAT)利用用户特定的图注意力模块捕捉局部上下文信息,以实现推荐;而 Kim 等提出的健康感知图注意力(Exploiting Health Status-aware Attention and an EHR Graph+, HI-DR)模型则引入状态感知注意力,用于药物推荐。

然而,当前大多数方法主要依赖自适应训练注意力权重机制来调整模型参数,未能利用图中的拓扑关系在 GNN 中构建注意力感知模块。因此,这些方法无法有效捕捉两种不同类型节点间交互的重要性(而这种重要性对指导节点聚合至关重要),这一局限还可能导致计算复杂度升高。具体而言,基于 GCN 的方法通常利用拉普拉斯矩阵聚合节点特征,但这些方法未利用图的底层拓扑结构在拉普拉斯框架中融入注意力感知矩阵,难以区分节点交互的重要性差异。尽管基于自适应注意力权重训练机制的模型能够捕捉不同类型节点间交互的相对重要性,但它们在下游网络分析任务中存在时间复杂度高的问题,且缺乏直观易懂的解释。相比之下,利用网络的固有拓扑在 GCN 中融入注意力感知组件,既无须额外的参数训练,也无须在学习过程中重复更新参数,从而提升了模型的整体效率。时间复杂度的实证分析如图 3.1 所示。




图 3.1 时间复杂度分析

分析表明,图注意力网络(Graph Attention Network, GAT)的时间复杂度高于 GCN。具体而言,在 Core 数据集上分别使用图注意力网络和 GCN 进行节点分类任务训练,共训练 250 个轮次。实验结果显示,图注意力网络的准确率优于 GCN,但时间复杂度也高于 GCN。由此可见,基于自适应训练注意力权重的模型计算成本较高。因此,若能一次性生成注意力感知矩阵并将其融入 GCN 框架,就能避免在训练阶段重复调整参数,进而提升模型的整体效率。通过上述分析可以发现一个显著挑战,即如何有效利用图中的拓扑关系在 GCN 中构建注意力感知矩阵,以捕捉不同类型节点间交互的重要性,从而同时提升模型的可解释性与计算效率。

此外,在推荐系统中,GCN 主要通过对用户-物品交互建模,实现用户与物品的低维向量嵌入表示。例如,Behera 等提出的元数据嵌入深度协同推荐(Metadata Embedding Deep Collaborative Recommender System, MEDCRSS)模型利用协同推荐模块学习物品元数据; Dong 等在用户-项目-评论一致性的对比框架(A Contrastive Framework with User Item and Review Alignment for Recommendation, ReCAFR)中通过对齐用户、物品与评论信息来提升推荐性能。然而,上述方法均忽略了不同长度的用户-物品交互,未能学习用户-物品交互的高跳关系。后来出现了一些考虑不同长度用户-物品交互的研究工作,如 Song 等提

出的 AutoInt 模型自动学习分类特征与数值特征的高阶交互,用于在线推荐与广告系统;Chen 等提出的 GHCF 模型通过多关系 GCN 推荐模型捕捉用户与物品的高阶交互;Wang 等提出的基于学习方面感知的高阶表示(Learning Aspect-aware High-order Representations, AHOR)模型通过从评论和评分中构建异构图,学习面向特定维度的高阶表示以实现推荐。尽管如此,大多数现有方法仍忽略了不同长度用户-物品交互的重要性差异。

某电商网络实例表明,不同长度的用户-物品交互对目标节点具有不同的重要性。例如,图 3.2 展示了一个目标用户的电商网络示例,其中包含用户节点与物品节点,物品节点和用户节点之间的实线表示用户-物品交互的权重。




图 3.2 目标用户的电商网络

从图 3.2(b) 中可看出,在目标用户的一阶用户-物品交互中,不同物品节点的贡献存在差异;在目标用户的二阶用户-物品交互中,不同用户节点与物品节点的贡献也存在差异。直观而言,不同长度用户-物品交互的重要性差异对推荐性能具有显著影响,但以往研究均忽略了这一特性。部分研究通过人工设计元路径的方式学习不同长度的用户-物品交互,如 Wang 等 in 多维元路径时间图概率扩展(Multi-dimensional Meta-paths Temporal Graph Probabilistic Spreading, MD-MP-TGPS)模型中提出元路径时间图概率传播模型,用于个性化推荐;Li 等提出的元路径感知动态多兴趣学习(Meta-Paths Aware Dynamic Multi-interest Learning, MPDMI)模型则引入元路径感知的动态多兴趣学习方法,用于序列推荐任务。然而,针对不同的推荐网络,人工选择并构建合适的元路径是一项极具挑战性的工作。综上所述,如何设计一种自动学习架构,以捕捉不同长度用户-物品交互的重要性差异,仍是当前面临的另一项挑战。

为解决上述问题,本章提出一种用于推荐任务的注意力感知时间异构图注意力网络 THGAN,其架构如图 3.3 所示。

具体而言,首先在 GCN 中引入 CCHoN 相似度矩阵,构建时间异构图注意力网络,用于指导每个快照的节点特征聚合,从而更好地学习用户-物品交互的重要性差异;随后,在该时间异构图注意力网络中引入混合跳数图注意力模块,以自动学习不同长度用户-物品交互的重要性差异;最后,采用经典的 LSTM 更新模型参数,并捕捉各快照间的时间依赖性,以完成推荐任务。




图 3.3 THGAN 总体框架图

本章的贡献总结如下。

(1) 提出一种用于推荐任务的新型方法 THGAN。该方法通过在 GCN 中引入 CCHoN 相似度矩阵, 构建时间异构图注意力网络, 用于指导每个快照的节点特征聚合, 从而更好地学习用户-物品交互的重要性差异。

(2) 在提出的时间异构图注意力网络中引入混合跳数图注意力模块, 以自动学习不同长度用户-物品交互的重要性差异。

(3) 对 THGAN 进行了全面评估, 实验结果表明, 在两项不同的推荐任务中, THGAN 的性能均优于多种当前最先进的基准方法。

3.2 问题定义

一个推荐网络可定义为异构网络 $G_T = (U, V, Y)$, 其中 U 表示用户集合, V 表示物品集合; 用户可记为 u , 物品可记为 v ; Y 表示用户-物品交互关系, 用户 u 与物品 v 在时间戳 t 的交互可定义为 $Y = [y_{u,v}^t]_{|U| \times |V|} \in \{0, 1\}$, 其中 $t \in T$, T 表示所有时间戳的集合。

在推荐系统中, 如何学习不同长度用户-物品交互的重要性差异仍是一项挑战。因此, 推荐问题可形式化描述如下: 给定异构网络 $G_T = (U, V, Y)$, 首先在 GCN 中构建 CCHoN 相似度矩阵, 进而构建时序异构图注意力网络, 用于指导每个快照的节点特征聚合, 从而更好地学习用户-物品交互的重要性差异; 随后, 在该时间异构图注意力网络中引入混合跳数图注意力模块, 以自动学习短长度与长长度用户-物品交互的重要性差异。推荐任务的目标是: 根据目标用户 u 的历史时间戳数据, 评估其在时间戳 t 与物品 v 发生交互的概率 y_{uv}^t , 并按照 y_{uv}^t 值从大到小对物品进行排序, 生成 Top- N 物品推荐列表。

3.3 THGAN 模型

接下来介绍 THGAN 模型。具体而言,首先在 GCN 中引入 CCHoN 相似度矩阵,以学习用户-物品交互的重要性差异;随后,在构建的时间异构图注意力网络中引入混合跳数图注意力模块,以自动学习不同长度用户-物品交互的重要性差异。

3.3.1 异构图注意力网络

基于 GCN 的推荐模型在用户-物品图的用户与物品嵌入学习中表现出优异性能,这类模型通过堆叠多个嵌入传播层,能够学习图的高阶关系。GCN 凭借强大的数据表征能力在推荐系统中受到越来越多的关注。GCN 的每一层定义如式(3-1)所示:

$$\mathbf{H}^{(i+1)} = \sigma(\mathbf{A}\mathbf{H}^{(i)}\mathbf{W}^{(i)}) \quad (3-1)$$

其中,GCN 第 i 层的输入与输出分别定义为 $\mathbf{H}^{(i)} \in \mathbf{R}^{N \times d_i}$ 和 $\mathbf{H}^{(i+1)} \in \mathbf{R}^{N \times d_{i+1}}$; N 表示所有用户与物品节点的总数; σ 表示非线性激活函数; $\mathbf{W}^{(i)}$ 为权重矩阵; $\mathbf{A}$ 为拉普拉斯矩阵,其构建方式如式(3-2)所示:

$$\mathbf{A} = \mathbf{D}^{-\frac{1}{2}}(\mathbf{A} + \mathbf{I}_N)\mathbf{D}^{\frac{1}{2}} \quad (3-2)$$

其中, $\mathbf{D}$ 表示度矩阵, $\mathbf{A}$ 表示邻接矩阵, $\mathbf{I}_N$ 表示推荐网络的单位矩阵, N 同样代表所有用户与物品节点的总数。然而,GCN 主要用于同构图表示学习,无法直接应用于异构图。为适配推荐网络,将用户节点与物品节点结合,构建用户-物品图对应的邻接矩阵 $\mathbf{A}$ 。此外,大多数现有基于 GCN 的方法通过平均聚合物品特征来计算用户特征,这种方式难以学习不同物品对用户的重要性。尽管现有基于图注意力网络的方法能够学习用户与物品节点间的这种重要性,但计算过程耗时且缺乏直观易懂的解释。

因此,在 GCN 中加入 CCHoN 相似度矩阵,以进一步指导节点聚合。新的拉普拉斯矩阵 $\mathbf{A}_{\text{new}}$ 定义如式(3-3)所示:

$$\mathbf{A}_{\text{new}} = \mathbf{D}^{-\frac{1}{2}}(\mathbf{A} + \epsilon \mathbf{S}_{\text{CCHoN}}^{\tau} + \mathbf{I}_N)\mathbf{D}^{\frac{1}{2}} \quad (3-3)$$

其中, $\mathbf{S}_{\text{CCHoN}}^{\tau}$ 是用于确定物品与用户间相似度的 CCHoN 相似度矩阵。该 CCHoN 相似度矩阵可通过式(3-4)得到:

$$\mathbf{S}^{\tau}(u_i, v_i) = \frac{\sum_{k=1}^K 2\text{CoN}_k^{\tau}(u_i, v_i)}{\sum_{k=1}^K (N_k^{\tau}(u_i) + N_k^{\tau}(v_i))} \quad (3-4)$$

其中, K 表示跳数, τ 定义推荐网络的时间距离,通过调整 τ ,CCHoN 能够捕捉具有强时间依赖性的 K 跳共同邻居, $\text{CoN}_k^{\tau}(u_i, v_i)$ 表示在时间距离 τ 内第 k 跳中节点 u_i 和节点 v_i 的邻居数量。此外,引入参数 ϵ 以控制 CCHoN 的贡献度。通过这种方式,节点 u 和节点 v 间的重要性可通过 $\mathbf{S}^{\tau}(u_i, v_i)$ 捕捉。

3.3.2 混合跳数图注意力模块

大多数现有方法未考虑不同长度用户-物品交互的重要性差异。因此在构建的时间异

构图注意力网络中引入混合跳数图注意力模块,以自动学习不同长度用户-物品交互的重要性差异。该混合跳数图注意力模块的设计灵感来源于基于稀疏邻域混合的高阶图卷积架构,混合跳数图注意力模块能够学习不同距离下的邻域混合关系。具体而言,它在不同特征空间融合 1 跳, ..., P 跳邻居的信息,从而实现对网络中不同跳数特征的聚合。混合跳数图注意力模块的每一层定义如式(3-5)所示:

$$\mathbf{H}^{(i+1)} = ||_{j=0}^P (\mathbf{A}^j \mathbf{H}^{(i)} \mathbf{W}_j^{(i)}) \quad (3-5)$$

与式(3-1)定义的 GCN 层相比,混合跳数图注意力模块新增了以下参数: $j \in \{0, P\}$ 表示矩阵 $\mathbf{A}$ 的幂次, $\mathbf{A}^j$ 表示拉普拉斯矩阵 $\mathbf{A}$ 自乘 j 次, $||$ 表示按列拼接。通过这种方式,混合跳数图注意力模块能够从 1 跳, ..., P 跳邻居的不同特征空间中学习特征。然而,混合跳数图注意力模块适用于同构图,而推荐网络通常为异构图,与同构图相比,其包含不同类型的节点与边。此外,该模型无法识别不同特征空间中交互的重要性差异。

为学习推荐网络中不同长度用户-物品交互的重要性差异,将混合跳数图注意力模块定义如式(3-6)所示:

$$\mathbf{H}^{(i+1)} = \sigma \left(\frac{1}{P} \sum_{j=1}^P (\mathbf{A}_{\text{new}}^j \mathbf{H}^{(i)} \mathbf{W}^{(i)}) \right) \quad (3-6)$$

其中, $j \in \{0, P\}$ 表示矩阵 $\mathbf{A}_{\text{new}}$ 的幂次, $\mathbf{A}_{\text{new}}^j$ 表示矩阵 $\mathbf{A}_{\text{new}}$ 自乘 j 次,对应 j 长度的用户-物品交互。由于 $\mathbf{A}_{\text{new}}$ 已体现用户-物品交互的重要性差异,因此 $\mathbf{A}_{\text{new}}^j$ 描述了 j 长度用户-物品交互的重要性。为涵盖 1 跳, ..., P 跳的用户-物品交互,通过 $\frac{1}{P} \sum_{j=1}^P$ 对不同长度的交互信息进行融合,模型能够自动学习不同长度用户-物品交互的重要性差异。

最后,采用经典的 LSTM 更新模型参数,并捕捉各快照间的时间依赖性,以完成推荐任务。模型参数更新采用经典的二元交叉熵损失函数,其定义如式(3-7)所示:

$$\mathcal{L} = \sum_{i=1}^N \log D(\mathbf{h}_i^t, g^t) + \sum_{j=1}^N \log(1 - D(\hat{\mathbf{h}}_j^t, g^t)) \quad (3-7)$$

其中, N 表示所有用户与物品节点的总数, $\mathbf{h}_i^t$ 表示时间戳 t 下节点 i 的嵌入向量, $\hat{\mathbf{h}}_j^t$ 表示时间戳 t 下节点 j 的负样本嵌入向量。 g^t 表示图级全局表示编码器, $D(\mathbf{h}_i^t, g^t)$ 表示判别器 D 基于 g^t 和 $\mathbf{h}_i^t$ 输出的概率值,其计算方式为 $D(\mathbf{h}_i^t, g^t) = \sigma(\mathbf{h}_i^{t\top} \mathbf{B}^t g^t)$,其中 σ 表示非线性激活函数, $\mathbf{B}^t$ 表示可训练的评分矩阵。

3.3.3 可解释性分析

$\mathbf{S}^r(u_i, v_i)$ 保留了节点 u 与节点 v 间的重要性信息。 $\mathbf{S}^r(u_i, v_i)$ 值越大,节点 u 与节点 v 的相似度越高。与传统基于 GCN 的方法采用 $\mathbf{A}_r + \mathbf{I}_N$ 指导节点聚合不同,将 CCHoN 相似度矩阵作为额外项引入 GCN,以进一步指导节点聚合。因此,THGAN 模型能够更好地学习用户-物品交互的重要性差异,并能在节点层面明确图嵌入传播层中每个相邻节点的贡献,从而增强图消息传递层的可解释性。

3.3.4 时间复杂度分析

设 K 为跳数, T 为用户和物品节点集合的规模, d 为嵌入维度, E 为用户-物品网络的

交互次数。 I 和 J 分别为用户数量和物品数量。计算 $\mathbf{S}^{\tau}(u_i, v_i)$ 的时间复杂度为 $O(K \cdot \tau \cdot (I+J))$; L 层图嵌入传播的时间复杂度为 $O(L \times |E| \times d)$ 。尽管模型需要计算 $\mathbf{S}^{\tau}(u_i, v_i)$, 但由于该计算仅需执行一次, 其计算成本低于模型训练阶段的成本。与自适应训练注意力权重机制相比, THGAN 模型避免了训练过程中参数的重复更新, 提高了模型效率。

3.4 实验

通过下一次交互预测和未来物品推荐两项任务, 对 THGAN 模型的效率与有效性展开全面实验验证。

3.4.1 数据集与基准模型

1. 数据集

采用 Wikipedia 和 LastFM 数据集验证下一次交互预测任务的有效性, 采用 MovieLens-1M(简称 ML-1M) 和 MovieLens-100K(简称 ML-100K) 数据集验证未来物品推荐任务的有效性, 表 3.1 展示了这 4 个数据集的统计信息。

表 3.1 数据集统计信息

数 据 集	用户节点数量	项目节点数量	交 互 数 量
Wikipedia	8227	1000	157 474
LastFM	1000	1000	1 293 103
ML-100K	1000	1700	100 000
ML-1M	6000	4000	100 000 000

2. 基准模型

为验证 THGAN 框架在下一交互预测和未来物品推荐任务中的性能, 选取以下模型作为基准模型, 各模型的说明如下。

- (1) JODIE: 采用耦合循环神经网络学习物品和用户的嵌入轨迹。
- (2) LatentCross: 利用循环神经网络融入上下文信息, 实现循环推荐。
- (3) LightGCN: 通过多层卷积模块学习用户与物品的高阶关系。
- (4) GHCF: 基于多关系 GCN 推荐模型, 捕捉用户与物品的高跳交互。
- (5) CoPE: 提出基于常微分方程的 GCN, 捕捉信息传播与演化, 用于未来交互预测。
- (6) FreeGEM: 采用增量网络嵌入方法对物品和用户节点进行嵌入。
- (7) DGCN: 在 GCN 中引入新的 Dice 相似系数, 学习节点间的重要性差异, 实现动态图的表示学习, 实验中采用其表示向量进行推荐。
- (8) XSimGCL: 为对比学习如何影响并提升推荐系统性能提供了新视角。
- (9) IntGCL: 提出一种基于图的可解释对比学习方法, 旨在提升推荐系统性能。

3.4.2 实验设置

实验中,跳数 K 设为 2,幂次 P 设为 2,嵌入维度 d 设为 128;根据时间戳在所有数据集上构建 5 个快照,时间距离 τ 设为 3。下一次交互预测任务采用 MRR 和 Hit@10 作为评估指标,未来物品推荐任务采用 Recall@10 作为评估指标。基准模型的参数均设为最优值,实验独立重复 10 次,最终报告下一次交互预测和未来物品推荐任务的平均值。

3.4.3 下一次交互预测

基于用户历史交互行为预测其下一次交互,是推荐系统中的典型应用。在该任务中,用户可能与同一物品产生多次交互行为。实验选取 JODIE、LatentCross、CoPE、GHCF、FreeGEM、DGCN、XSimGCL 作为基准模型,在 LastFM 和 Wikipedia 数据集上对比各模型的 MRR 和 Hit@10 值。

下一次交互预测的性能如表 3.2 所示,THGAN 模型在 LastFM 和 Wikipedia 数据集上均取得了最优的 MRR 和 Hit@10 值。

表 3.2 下一次交互预测的性能

模 型	Wikipedia		LastFM	
	MRR	Hit@10	MRR	Hit@10
JODIE	0.746	0.822	0.195	0.307
LatentCross	0.424	0.481	0.148	0.307
CoPE	0.750	0.890	0.200	0.446
GHCF	0.233	0.567	0.105	0.274
FreeGEM	0.786	0.852	0.195	0.453
DGCN	0.547	0.644	0.102	0.199
XSimGCL	0.775	0.858	0.210	0.452
THGAN	0.841	0.917	0.227	0.464

实验发现,CoPE 和 FreeGEM 的性能优于其他部分基准模型,CoPE 通过基于常微分方程的 GCN 捕捉信息的传播与演化;FreeGEM 则采用增量网络嵌入方法对物品和用户节点进行嵌入,但这两种方法在对用户和物品进行嵌入时,均未考虑节点间的重要性差异。尽管 DGCN 引入了新的 Dice 相似度以学习节点重要性,但该相似度仅考虑节点的直接邻居,无法捕捉网络的高阶信息;XSimGCL 虽通过对比学习提升了推荐性能,但仍不敌 THGAN。本质上,THGAN 方法通过在 GCN 中引入 CCHoN 相似度矩阵,构建时序异构图注意力网络以指导每个快照的节点特征聚合,随后又引入混合跳数图注意力模块,自动学习不同长度用户-物品交互的重要性差异,正是这一设计使 THGAN 能够更精准地学习不同长度用户-物品交互的重要性,从而取得最优的 MRR 和 Hit@10 值。

3.4.4 未来物品推荐

基于用户历史交互行为预测其未来交互,同样是推荐系统中的典型应用。在该任务中,用户最多与同一物品发生一次交互。实验选取 GHCF、JODIE、LightGCN、CoPE、

DGCN、FreeGEM、IntGCL 作为基准模型,在 ML-100K 和 ML-1M 数据集上对比各模型的 Recall 值。未来物品推荐的 Recall@10 值如表 3.3 所示。

表 3.3 未来物品推荐的性能

模 型	ML-100K	ML-1M
	Recall@10	Recall@10
GHCF	0.022	0.005
JODIE	0.074	0.035
LightGCN	0.025	0.029
CoPE	0.081	0.049
DGCN	0.073	0.042
FreeGEM	0.149	0.065
IntGCL	0.155	0.069
THGAN	0.164	0.081

实验结果显示,THGAN 模型在 ML-100K 和 ML-1M 数据集上均取得了最优的 Recall@10 值。其中,LightGCN 和 GHCF 性能最差,原因是这两种模型均为静态方法,无法学习网络的动态信息,其他基准模型虽能学习网络动态信息,但未考虑不同长度用户-物品交互的重要性差异,因此性能均不及 THGAN。本质上,THGAN 通过在 GCN 中引入 CCHoN 相似度矩阵构建时序异构图注意力网络,指导每个快照的节点特征聚合,同时引入混合跳数图注意力模块自动学习不同长度交互的重要性,这一设计使 THGAN 能更精准地捕捉交互的重要性差异,从而取得最优的 Recall@10 值。

3.4.5 消融实验

为验证 CCHoN 相似度矩阵的有效性,实验构建了 THGAN 的变体模型,移除 CCHoN 相似度矩阵的 THGAN(记为 THGAN₁),并在未来物品推荐任务中对比 THGAN 与 THGAN₁ 的性能,消融实验结果如图 3.4 所示。




图 3.4 消融实验

实验结果表明,在 ML-100K 数据集上,THGAN 的平均 Recall@10 值比 THGAN₁ 高出 10%;在 ML-1M 数据集上,THGAN 的平均 Recall@10 值比 THGAN₁ 高出 5%。

值得注意的是,在下次交互预测任务中,THGAN 的性能同样显著优于 THGAN_1。这一结果的原因可能在于传统 CNN 忽略了用户-物品交互的重要性差异,而 THGAN 通过在 CNN 中引入 CCHoN 相似度矩阵,构建时序异构图注意力网络以指导每个快照的节点特征聚合,能够更精准地学习交互重要性差异。由此可见,CCHoN 相似度矩阵可有效提升推荐性能。

3.4.6 超参分析

本节对模型关键超参数展开全面分析,具体探究幂次 P 、时间距离参数 τ 和嵌入维度 d 对推荐性能的影响。

1. 幂次 P 的影响

实验将幂次 P 的取值从 1 调整至 4,分析不同长度的用户-物品交互对 THGAN 模型在两项任务上性能的影响。不同幂次 P 的取值在 4 个不同的数据集上的实验结果如图 3.5 所示。




图 3.5 不同幂次 P 的取值在 4 个不同的数据集上的实验结果

实验表明,随着不同长度的用户-物品交互被纳入分析,两项任务的性能均有所提升,且在 $P=2$ 时达到最优;当 P 继续增大,两项任务的性能均出现小幅下降。该实验结果再次证明,考虑不同长度用户-物品交互对提升推荐性能具有重要意义。

2. 时间距离 τ 的影响

实验通过时间戳构建 5 个快照,分析时间距离参数 τ 对两项任务性能的影响,以此验证 CCHoN 相似度矩阵的有效性。不同时间距离的切片数 τ 的取值在 4 个不同的数据集上的实验结果如图 3.6 所示。

实验表明,随着时间快照数量的增加,两项任务的性能缓慢提升,在 $\tau=3$ 时达到最优;当快照数量继续增加,两项任务的性能均出现小幅下降。实验结果表明,时间距离参数 τ 对模型性能的影响虽小于其他参数,但仍存在一定影响,因此在 CCHoN 相似度矩阵中需合理设置该参数。




图 3.6 不同时间距离的切片数 τ 的取值在 4 个不同的数据集上的实验结果

3. 嵌入维度 d 的影响

实验将嵌入维度 d 的取值设为 32、64、128、256，分析其对 THGAN 模型在两项任务上性能的影响。不同嵌入维度 d 的取值在 4 个不同的数据集上的实验结果如图 3.7 所示。




图 3.7 不同嵌入维度 d 的取值在 4 个不同的数据集上的实验结果

实验表明,随着嵌入维度的增加,两项任务的性能均有所提升,在 $d=128$ 时达到最优;当嵌入维度继续增大,两项任务的性能均出现下降。因此,实验将 THGAN 的嵌入维度设为 128。

3.4.7 效率分析

在下次交互预测任务中评估 THGAN 的效率。为保证公平性,实验首先选取同样基于 GCN 的 JODIE 和 CoPE 模型与 THGAN 进行对比,随后选取 DGCN 与 THGAN 展开性能比较。其中,JODIE 和 CoPE 均利用 CNN 学习用户与物品的嵌入表示,DGCN 则通过在 CNN 中引入新的 Dice 相似度,捕捉动态图表示学习过程中节点间的重要性差异。不同模型的运行时间如表 3.4 所示,在该任务中,THGAN 的运行时间低于所有基准模型。随着交互次数的增加,CoPE 和 JODIE 的运行时间显著增长,而 THGAN 的运行时间仅小幅增

加,在实际应用中更具实用性。与自适应训练注意力权重机制不同,THGAN 在训练过程中无须重复更新注意力参数,从而提升了整体效率。

表 3.4 不同模型的运行时间

模 型	基于 Wikipedia 的运行时间/s	基于 LastFM 的运行时间/s
CoPE	3589.1	51 212.5
JODIE	350.0	15 790.0
DGCN	82.1	3783.1
THGAN	63.7	3662.5

3.5 本章小结

本章提出了一种注意力感知时序异构图注意力网络推荐方法 THGAN。具体而言,THGAN 采用所构建的时序异构图注意力网络,识别每个快照中用户-物品交互的重要性差异,其核心是通过在 GCN 中引入 CCHoN 相似度矩阵,指导节点特征聚合,从而学习用户-物品交互的重要性差异。随后,在该时序异构图注意力网络中引入混合跳数图注意力模块,以自动学习不同长度用户-物品交互的重要性差异。最后,采用经典的 LSTM 更新模型参数,并捕捉所有快照间的时间依赖性,以完成推荐任务。通过对 THGAN 的性能评估可知,在两项推荐任务(下一次交互预测、未来物品推荐)中,该模型相比多种当前最先进的基准方法均展现出显著优势。