

序列标签推荐

刘冰, 徐鹏宇, 陆思进, 王诗菁, 孙宏健, 景丽萍, 于剑

引用本文

刘冰, 徐鹏宇, 陆思进, 王诗菁, 孙宏健, 景丽萍, 于剑. [序列标签推荐](#)[J]. 计算机科学, 2025, 52(1): 142-150.

LIU Bing, XU Pengyu, LU Sijin, WANG Shijing, SUN Hongjian, JING Liping, YU Jian. [Sequential Tag Recommendation](#) [J]. Computer Science, 2025, 52(1): 142-150.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[提示学习中思维链生成和增强方法综述](#)

Survey of Chain-of-Thought Generation and Enhancement Methods in Prompt Learning
计算机科学, 2025, 52(1): 56-64. <https://doi.org/10.11896/jsjcx.240700172>

[MB-ATMK:融合属性权重和时序元知识的多行为序列推荐模型](#)

MB-ATMK:Multi-behavior Sequential Recommendation Integrating Attribute Weights and Temporal Meta-knowledge
计算机科学, 2024, 51(11A): 231100047-9. <https://doi.org/10.11896/jsjcx.231100047>

[基于相似性增强传播结构的谣言检测](#)

Rumor Detection Based on Similarity-enhanced Propagation Structure
计算机科学, 2024, 51(11A): 240200116-8. <https://doi.org/10.11896/jsjcx.240200116>

[融入时间信息的预训练序列推荐方法](#)

Time-aware Pre-training Method for Sequence Recommendation
计算机科学, 2024, 51(5): 45-53. <https://doi.org/10.11896/jsjcx.230200049>

[基于多空间属性信息融合的序列推荐](#)

Sequential Recommendation Based on Multi-space Attribute Information Fusion
计算机科学, 2024, 51(3): 102-108. <https://doi.org/10.11896/jsjcx.230600078>

序列标签推荐

刘冰 徐鹏宇 陆思进 王诗菁 孙宏健 景丽萍 于剑

北京交通大学交通数据分析与挖掘北京市重点实验室 北京 100044

北京交通大学计算机与信息技术学院 北京 100044

(bing.liu@bjtu.edu.cn)

摘要 随着互联网技术的发展以及社交网络的扩大,网络平台已经成为人们获取信息的一个重要途径。标签的引入提升了信息分类及检索效率。同时,标签推荐系统的出现不仅方便了用户输入标签,还提高了标签的质量。传统的标签推荐算法通常只考虑标签和项目两个主体,而忽略了用户在选择标签时个人意图所起到的重要作用。由于在标签推荐系统中标签最终由用户确定,因此用户的偏好在标签推荐中起着关键作用。为此,引入用户作为主体,并结合用户发布的历史帖子的先后顺序,将标签推荐任务建模为更加符合真实场景的序列标签推荐任务。提出了一种基于 MLP 的序列标签推荐方法(MLP for Sequential Tag Recommendation,MLP4STR),该方法显式地建模用户偏好用于引导整体标签推荐。MLP4STR 采用一种跨特征对齐的 MLP 序列特征提取框架,将文本和标签的特征对齐,获取用户的历史帖子信息和历史标签信息中隐含的用户动态兴趣。最后,结合帖子内容和用户偏好进行标签推荐。在 4 个真实世界的数据集上得到的实验结果表明,MLP4STR 能够有效地学习序列标签推荐中的用户历史行为序列的信息,其中,评价指标 F1@5 较最优的对比算法有显著提升。

关键词: 标签推荐;序列推荐;多标签学习;用户偏好

中图分类号 TP391

Sequential Tag Recommendation

LIU Bing,XU Pengyu,LU Sijin,WANG Shijing,SUN Hongjian,JING Liping and YU Jian

Beijing Key Lab of Traffic Data Analysis and Mining,Beijing Jiaotong University,Beijing 100044,China

School of Computer Science and Technology,Beijing Jiaotong University,Beijing 100044,China

Abstract With the development of Internet technology and the expansion of social networks,online platforms have become a significant avenue for people to access information. The introduction of tags has facilitated the categorization and retrieval of information. At the same time,the advent of tag recommendation systems not only makes it easier for users to input tags but also improves the quality of tags. Traditional tag recommendation algorithms typically only consider tags and items,overlooking the crucial role of personal intent when users choose tags. Since tags in a recommendation system are ultimately determined by users,user preferences play a key role in tag recommendation. Therefore,we introduce the user as a subject,and by incorporating the chronological order of users' historical posts,modeling the task of tag recommendation as a sequential tag recommendation task that is more aligned with real-world scenarios. To address this task,this paper proposes a method named MLP for sequential tag recommendation(MLP4STR),which explicitly models user preferences to guide the overall tag recommendation. MLP4STR employs a cross-feature alignment MLP framework for sequence feature extraction,aligns the features of text and tags to capture the dynamic interests of users implicit in their historical post and tag information. Finally,it recommends tags by combining post content and user preferences. Experimental results on four real-world datasets show that MLP4STR can effectively learn information from users' historical behavior sequences in sequential tag recommendation,and the evaluation metric F1@5 shows a significant

到稿日期:2024-07-29 返修日期:2024-09-23

基金项目:中央高校基本科研业务费专项资金(2019JBZ110);国家自然科学基金(62176020);国家重点研发计划(2020AAA0106800);北京市自然科学基金(L211016)

This work was supported by the Fundamental Research Funds for the Central Universities(2019JBZ110),National Natural Science Foundation of China(62176020),National Key Research and Development Program of China(2020AAA0106800) and Natural Science Foundation of Beijing,China(L211016).

通信作者:景丽萍(lpjing@bjtu.edu.cn)

improvement compared to the optimal baseline algorithms.

Keywords Tag recommendation, Sequential recommendation, Multi-label learning, User preference

随着互联网技术的发展和社交网络的普及,网络平台已成为人们获取信息、分享经验和进行交流的主要渠道。在数字媒体技术和互联网技术的共同推动下,各种社交网络、在线论坛以及电子商务平台如雨后春笋般涌现。这些平台为用户提供了一个发布内容、提出问题、分享见解以及寻找答案的平台,从知识共享到商品推荐等各个领域都有所涉及。然而,随着信息量的急剧增加,用户面临着信息过载的问题。为了解决这一问题,标签机制成为一种便捷的信息分类和检索方法^[1]。标签推荐系统应运而生,它不仅方便了用户输入标签还提高了标签的质量^[2]。标签推荐已成为近年来备受关注的重点研究课题,且已经涌现出大量的研究工作^[3]。目前已有的标签推荐算法主要分为两类:基于内容的标签推荐算法和协同过滤算法。基于内容的标签推荐算法直接对项目文本进行多标签分类,以提供标签建议;而协同过滤算法则是通过分析用户行为和兴趣,发现用户之间的相似性,并利用这种相似性来预测用户可能喜欢的物品或内容。

标签推荐涉及用户、项目以及标签3个方面主体的信息,现有的方法主要考虑项目和标签两个主体,直接根据项目的内容进行推荐。然而,由于用户的生活环境、兴趣爱好、研究内容不同^[4],他们对相同的问题关注的重点也不同。例如,图1展示了Stack Exchange上来自相同用户和不同用户的5个帖子,可以发现,同一个用户发表帖子内容虽然不同,但标签却有重叠部分,说明用户关注的领域会影响其为帖子添加标签。另一方面,不同用户发布的两篇关于道尔顿分压定律的帖子却被标记了完全不同的标签,这表明用户在选择标签时会受到个人主观偏好的影响。标签推荐算法的最终目标是使推荐的标签能够被用户接受和采纳,因此用户的偏好直接影响着标签推荐的准确性,引入用户偏好可以起到重要的作用。

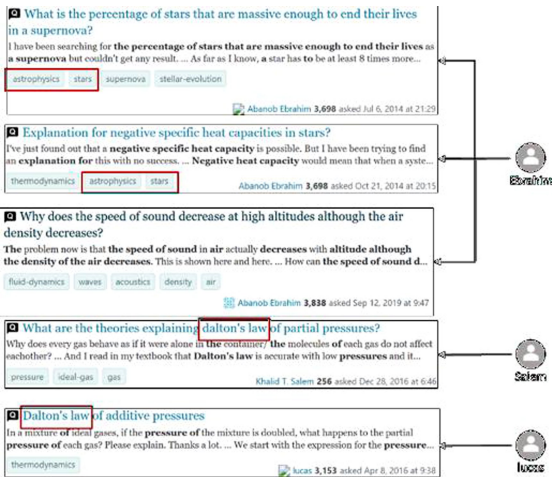


图1 Stack Exchange上的问题示例

Fig. 1 Example of problems on Stack Exchange

用户的偏好隐藏在用户所发布的历史信息中,而这些信息的发布有先后顺序。用户的动态兴趣变化与发布内容的

先后顺序紧密相关,如图1中的用户Ebrahim分别在七月份和十月份先后发布了两篇帖子,可以看出用户当前关注的内容是与“astrophysics”和“stars”相关的内容。由于用户的关注领域是动态变化的,因此下一阶段的偏好可能会和当前阶段的偏好不同,但常常存在依赖关系。后续Ebrahim为十二月发布的帖子标记的标签为“fluid-dynamics”“waves”“acoustics”“density”“air”,其中出现了新的标签,但这些标签与先前的标签也存在着较强的关联关系。可见,用户关注领域的动态变化规律也体现在用户发布的帖子的内容以及所标注的标签上。如果能够捕获这种隐含在帖子内容和标签内容中的顺序依赖关系,就可以更好地获取用户近期的偏好,以便进行更准确的标签推荐。

传统的标签推荐算法仅对项目内容进行建模,忽略了实际场景中用户的主体地位,并且训练时没有考虑到实际中项目发布的先后顺序,训练集中的数据可能在测试集的数据之前,存在信息泄露的问题。此外,用户的行为前后具有极强的关联性甚至因果性,所以不应采用静态的方式建模用户和项目的交互,而应将用户的行为采用动态序列的方式进行建模,获取用户当下的偏好。因此,为了与实际场景更相符,应将该任务重新建模为序列标签推荐任务。如图2所示,根据用户过去的发帖以及打标签序列构建一个动态的序列,考虑到用户行为的时序性,将用户过去的发帖以及对应的标签按照时间顺序组成一个序列,通过分析这个序列来理解用户的兴趣演变趋势。结合该兴趣演变趋势以及当前帖子的内容进行标签推荐。




图2 序列标签推荐

Fig. 2 Sequential tag recommendation

首先,为了后续进行序列建模,先对文本信息进行特征提取,使用预训练语言模型BERT来学习帖子的文本特征并获取帖子对应标签的语义表示;然后,对齐文本和标签信息,通过一种基于MLP的跨特征维度的序列建模方式捕获帖子的文本内容和标签内容中用户的动态偏好,得到位于同一空间的帖子内容表示和用户偏好表示,并将该偏好与当前帖子的语义特征融合作为特征表示。最后,利用交叉熵损失进行训练。

本文的主要贡献如下:

1)首次提出序列标签推荐任务。考虑到标签推荐中用户主体的重要性以及帖子发布的先后顺序,建模了一种更加接近真实场景的标签推荐任务。另外,收集和整理了4个真实

世界的序列标签推荐数据集¹⁾用于相关研究。

2) 针对上述任务,提出了算法 MLP4STR,采用一种基于 MLP 的跨特征对齐的序列特征提取框架,将文本和标签的特征对齐,充分获取用户历史帖子和标签的特征以及帖子和标签之间的交互关系,基于此特征进行用户偏好的学习,并结合用户偏好进行最终的标签推荐。

3) 在 4 个真实世界的数据集上进行实验,结果表明所提算法超过现有最优模型。其中,评价指标 F1@5 较最优的对比算法有显著提升,进一步证明了通过序列建模提取用户偏好的有效性。

1 相关工作

标签推荐领域目前已经有了大量的研究工作。现有的标签推荐算法可以分为两类:基于内容的标签推荐算法以及协同过滤算法。

基于内容的标签推荐算法往往将标签推荐问题简化为一个多标签分类任务,即忽略用户信息,通过直接对项目的内容进行建模,来为项目推荐标签。此类算法对于各种类型的内容,如文献、图像、歌曲、视频等都有研究。本文主要研究基于文本内容的标签推荐。传统的基于内容的标签推荐方法将项目的文本内容视为词袋(BoW),设计不同的标签排名策略用于标签推荐。例如 Song 等构造了文档和标签的二部图。聚类后,根据标签的重要性对标签进行排序^[5]。Xia 等提出了一种基于朴素贝叶斯的多标签分类器,并使用该分类器预测的标签排名分数^[6]。Wu 等进一步考虑标签内容相关性现象,使用概率图模型模拟标签生成过程^[7-8]。由于 BoW 特性的限制,传统方法无法获取文本内容的顺序信息或空间信息。最近,研究人员采用深度学习架构来捕捉这些关键信息。Gong 等采用了一种由全局和局部通道组成的带有注意机制的卷积神经网络(CNN)^[9]。Lei 等进一步引入了胶囊网络对部分与整体之间的内在空间关系进行编码^[10]。另一方面,Li 等采用了基于主题注意力机制的长短期记忆(LSTM)模型,该模型将 LDA 主题模型生成的主题分布整合到序列建模中^[11]。考虑到文档的层次化结构,Hassan 等^[12]使用双向门控循环单元(Bi-GRU)和层级注意机制作为句子编码器。预训练语言模型出现之后,He 等利用预训练模型和三重体系结构,用独立的语言模型对帖子的组件进行建模,进一步提升了标签推荐算法的准确率^[13]。为了充分利用网站中的多元数据,一些研究者不仅关注纯文本数据,还对其他类型的数据进行了整合。Chen 等^[14]和 Feng 等^[15]采用注意力机制对包含图片的数据源进行了多模态信息融合。Li 等^[16]则针对涉及代码的数据源,利用 transformer 的编码器进行了专门的优化和提升。Wang 等^[17]引入外源数据,利用知识图谱来丰富实体内容,并采用含有多个[CLS]编码的预训练语言模型的编码器来提取分类特征。

协同过滤算法包括标签的协同过滤和用户的协同过滤。标签的协同过滤即通过考虑标签之间的相关性进行标签

推荐。因为同一个项目的标签之间也存在一定程度的相关性,比如表 1 中列举的“astrophysics”和“stars”就具有很强的相关性。类似的标签相关关系在每个项目所对应的标签集中普遍存在。早期传统的标签推荐方法利用标签之间的相关关系大幅度提升了标签推荐的性能^[18]。用户的协同过滤则是将用户的偏好考虑进来,进行标签推荐,也即个性化标签推荐。在进行标签推荐时,有一些方法可以借鉴,例如可以直接将用户的 id 信息与项目内容信息以及标签信息连接起来^[19],通过神经网络学习到潜在的用户偏好;但此时用户信息非常稀疏,起到的作用很小。将用户历史标签信息引入之后,可以将 id 信息与标签信息结合,通过构建异构图从而获取包含标签信息的用户偏好表示^[20];或者利用自编码器网络将历史标签信息进行编码从而获取用户偏好表示^[21];除了考虑到用户 id 信息、用户历史标签信息外,也可以引入用户历史项目信息,文献^[22]中引入了一个外部存储单元,存储注意力网络从用户的历史项目信息中学习到的用户偏好。

本文提出了一种新的方法,该方法在深入分析用户、标签和项目 3 个关键维度的基础上,重新建模了标签推荐任务。通过对用户历史行为的精细研究,本文不仅考虑了用户与标签的关联,而且重视用户发帖行为的时序性,由此将传统的标签推荐任务转化为更符合现实世界动态的序列标签推荐任务。

突破传统方法的局限,本文采取对用户最新帖子的评估,作为验证模型有效性的测试集数据。值得注意的是,尽管基于 Transformer 的方法^[23-26]在众多序列处理任务中表现卓越,但其在处理含有丰富文本语义的序列标签推荐场景时却遇到了挑战。Transformer 中的位置编码^[27]可能会干扰序列的本质语义,我们通过实验证实了这一现象。此外,由于自注意力机制计算复杂度与输入项目序列的长度成二次方,因此对计算资源的需求也随之增加。

在这样的背景下,受到 MLP-Mixer^[28]在时间序列处理中的成功应用^[29]的启发,本文提出了一种提取序列特征的跨维度对齐的 MLP 框架,专为本文重新建模的序列标签推荐任务设计。该框架不仅能有效捕捉序列信息,而且避免了引入任何可能破坏原始语义信息的外部编码,同时保持了较低的计算复杂度。

2 序列标签推荐

本章将详细介绍本文提出的模型。该模型通过对用户的历史行为进行序列建模来捕捉用户的偏好。通过整合用户偏好,进一步提出了一种辅助当前帖子标签推荐的方法。模型的整体框架如图 3 所示。输入包括用户发布的历史帖子文本信息、对应的历史标签信息以及当前帖子的文本内容。标签信息和文本信息分别通过标签编码器和文本编码器进行特征提取。随后,这些特征被传递给序列学习模块,在经过多层的跨维度序列特征提取层后,获得当前用户的偏好表示。最终,将该用户偏好与当前帖子的特征融合,以进行标签推荐。

¹⁾ https://drive.google.com/drive/folders/1hxqgT4WCazw969Jvqa_DZAckhIpGZOgR?usp=sharing

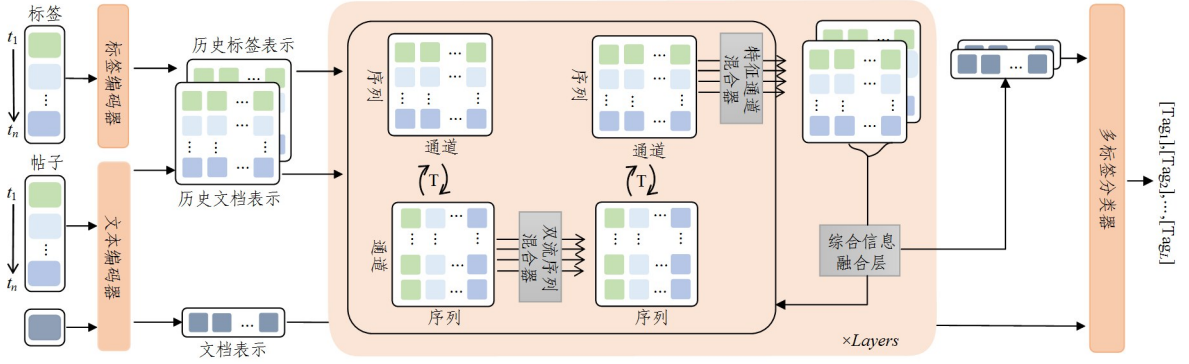


图3 MLP4STR模型概述

Fig. 3 Overview of MLP4STR model

2.1 问题描述

本文所考虑的是项目内容为文本内容时的标签推荐问题。使用花体字母(例如 \mathcal{A})表示集合,大写或者小写字母(例如 A, a)表示标量,小写粗体字母(例如 \mathbf{a})表示向量,大写粗体字母(例如 \mathbf{A})表示矩阵。将训练阶段输入的样本数据表示为 $\mathcal{P} = (\mathbf{X}_i, u_i, \mathbf{y}_i)_{i=1}^N$, 其中 N 表示样本帖子的个数, \mathbf{X}_i 表示第 i 个帖子的内容, u_i 表示第 i 个帖子的作者, $\mathbf{y}_i = (y_1, y_2, \dots, y_l, \dots, y_L)$ 表示第 i 个帖子可能涉及的候选标签集。此处的 $y_l \in \{0, 1\}$, 若 $y_l = 1$, 则表示该帖子被用户赋予了第 l 个标签; 反之, 若 $y_l = 0$ 则表示该帖子未被用户赋予第 l 个标签。 L 表示候选标签集中标签的总数。作者 u_i 发布的历史帖子的数量记为 l_{u_i} 。历史帖子包括帖子内容和标签两部分信息, 可以根据两部分信息将历史帖子序列拆分为文本序列 $\mathcal{D}_i = \{D_1, \dots, D_{l_{u_i}}\}$ 和标签序列 $\mathcal{T}_i = \{T_1, \dots, T_{l_{u_i}}\}$ 。在测试阶段模型为用户 u_i 的文档 \mathbf{X}_i 推荐标签 $f(\mathbf{X}_i, u_i)$, 我们期望 $f(\mathbf{X}_i, u_i)$ 与目标 \mathbf{y}_i 更加接近。

2.2 表示学习

文档表示学习: 在为文档推荐标签之前需要先学习到高质量的文档表示。预训练语言模型在自然语言处理任务上取得了显著的效果。它首先在无监督目标下对海量文本进行预训练, 然后在特定任务数据上进行微调。BERT^[30] 采用掩码语言模型 (Masked Language Model, MLM) 对双向的 Transformer 进行预训练, 以生成深层的双向语言表征, 通过微调在多项自然语言处理任务中都取得了很好的效果。所以我们将 BERT 应用到本文中來学习文本的向量表示, 再通过微调的方法适应标签推荐模型。首先在文档的开头和结尾添加标识符号, 构建第 i 篇帖子的 BERT 输入序列 \mathbf{X}_i , 文本编码器对输入进行编码后的表示为:

$$\mathbf{h}_i = \text{pooling}(\text{BERT}(\mathbf{X}_i)) \quad (1)$$

其中, $\mathbf{h}_i \in \mathbb{R}^{d_h}$ 为文档的表示; d_h 为词表示维度; *pooling* 为平均池化层, 用于将整个文档的单词进行信息聚合。

历史标签表示学习: 除历史帖子信息外, 历史标签信息也是重要的用户历史行为信息来源, 需要得到有效的标签表示。用户的历史发帖序列中涉及历史的标签序列 $\mathcal{T}_i = \{T_1, \dots, T_{l_{u_i}}\}$, 在建模用户历史序列之前需要先学习标签的隐表示 $\mathbf{z}_l \in \mathbb{R}^{d_h}$ 。设标签集中的任一标签对应的文本表示集合为 $\epsilon_k = \{\mathbf{h}_i | y_{i,k} = 1, \mathbf{h}_i \in \mathbb{R}^{d_h}\}$, $|\epsilon_k|$ 是涉及该标签的文档的个数。

我们通过聚合标签的正样本对应的文本编码来获取标签的表示:

$$\mathbf{z}_l = \sum_{j=1}^{|\epsilon_k|} \mathbf{h}_j \quad (2)$$

其中, $\mathbf{z}_l \in \mathbb{R}^{d_h}$, 我们设置标签的嵌入维度与文本的嵌入维度相同。因此, 在聚合过程中确保了文档的表示和标签的表示处于同一语义空间。这一方法的独特之处在于, 标签的含义正是由这些标签所标注的多个文档的共同特征所定义的。因此, 通过这一过程获得的标签表示不仅高度准确地捕捉了标签的语义含义, 还隐含地考虑了不同标签之间的相关性。这样得到的标签表示将在用户后续的偏好学习中发挥重要作用。

2.3 基于双流序列的用户偏好学习

为获取到用户兴趣偏好的动态演变趋势, 我们采用序列的方式来建模用户的历史行为。如前文所述, 此处可获取的用户历史行为信息包括历史文本序列和历史标签序列。

用户历史文本序列中包含丰富的兴趣爱好等偏好信息。充分利用历史发帖信息可以挖掘出用户的隐藏兴趣以及兴趣趋势变化, 将其作为前置信息, 有助于理解新阶段发布的帖子内容。用户历史帖子中的标签是用户对发布的帖子的内容的总结, 一方面这是历史帖子内容的浓缩表示, 另一方面用户使用的历史标签体现了用户打标签的习惯。因此, 这两部分的信息都有助于对新的帖子进行标签推荐。本文方法分别对这两部分的信息进行了显式的建模来捕获用户的偏好, 并跨特征对齐两部分的信息, 以捕获帖子文本和对应的标签内容之间的交互关系。

受近期 MLP-Mixer 在时间序列中成功应用^[29] 的启发, MLP-Mixer 可以成功建模序列信息, 并且可以避免引入额外信息对当前语义信息造成负面影响。本文采用基于 MLP 的结构来建模序列信息。将历史文本序列和历史标签序列作为输入, 通过综合信息融合器来获取用户的综合偏好。每个综合混合层包含 3 部分。首先为双流序列混合器, 建模序列依赖性, 即每个帖子或者标签的嵌入的相同通道构成的序列之间存在的顺序关系; 其次为特征通道混合器, 建模同一个帖子或者标签的嵌入的不同特征维度之间存在的关系; 最后是一个综合信息融合器, 将帖子的信息和标签的信息进行交互建模。

1) 双流序列混合器: 序列混合器是一个基于 MLP 的结构, 可以挖掘历史标签序列和历史文本序列中的顺序关系。以历史文本序列 \mathcal{D}_i 为例, 首先按照长度 l_{u_i} 对序列进行截取

操作,然后将其编码后的嵌入表示序列 $\mathcal{D} = \{d_1, \dots, d_i, \dots, d_{l_u}\}$, $d_i \in \mathbb{R}^{l_u}$ 作为输入,如图 4 所示,其嵌入表示的每个维度都可以表示为一个序列,例如第 j 维可以表示为序列 $d^j = \{d_1^j, \dots, d_i^j, \dots, d_{l_u}^j\}$, $d^j \in \mathbb{R}^{l_u}$. 并且由于这些特征表示属于同一维度,它们之间的顺序关系可以展示出用户在某个兴趣领域随着时间的变化,通过如下结构来捕获顺序关系:

$$\hat{d}^j = d^j + \mathbf{W}_1 g(\mathbf{W}_2 \text{LayerNorm}(d^j)) \quad (3)$$

其中, $j=1, 2, \dots, d_h$, $\hat{d}^j, d^j \in \mathbb{R}^{l_u}$, $\mathbf{W}_1 \in \mathbb{R}^{l_u \times r_u}$ 表示第一个全连接层的权重矩阵, $\mathbf{W}_2 \in \mathbb{R}^{r_u \times l_u}$ 表示第二个全连接层的权重矩阵, r_u 为可调节的隐层维度, g 表示非线性激活函数, LayerNorm 是归一化层。

残差连接




图 4 双流序列混合器的结构

Fig. 4 Structure of dual-flow sequence mixer

2) 特征通道混合器:和序列混合器类似,特征通道混合器也是一个基于 MLP 的结构,它们的关键区别在于用途。通道混合器的目标是学习嵌入向量的内在相关性。由于文本特征以及标签特征的不同维度表达了不同的信息,因此在进行序列信息的学习之后,捕获不同维度的特征向量之间的交互层的相关性,具体表达式如下:

$$\hat{d}_k = d_k + \mathbf{W}_3 g(\mathbf{W}_4 \text{LayerNorm}(d_k)) \quad (4)$$

其中, $k=1, 2, \dots, l_u$, $\hat{d}_k, d_k \in \mathbb{R}^{d_h}$, $\mathbf{W}_3 \in \mathbb{R}^{d_h \times r_u}$, $\mathbf{W}_4 \in \mathbb{R}^{r_u \times d_h}$ 与 $\mathbf{W}_1, \mathbf{W}_2$ 相同均为权重矩阵, r_u 为可调节的隐层维度。

3) 综合信息融合层:综合信息融合层是将文本特征和标签特征对应连接起来的关键组件。由于不同文本的标签可能会有不同的涵义,标签不同时文本内容也会有不同的侧重点,因此将两部分内容进行融合可以充分将文本和标签进行交互从而得到更加准确的嵌入表示。采用和序列混合器以及通道混合器类似的结构,每轮序列混合以及通道混合后都通过融合层进行一次对齐操作。该融合层表示为:

$$\hat{c}_k^j = c_k^j + \mathbf{W}_5 g(\mathbf{W}_6 \text{LayerNorm}(c_k^j)) \quad (5)$$

其中, $j=1, 2, \dots, d_h$, $k=1, 2, \dots, l_u$, $c_k^j = [d_k^j, t_k^j]$, d_k^j 表示文本特征, t_k^j 表示标签特征, $\hat{c}_k^j, c_k^j \in \mathbb{R}^2$ 。

2.4 标签预测

使用最新时刻的特征 $\hat{d}_{l_u}, \hat{t}_{l_u}$ 作为当前用户偏好的表示,并将其与文档表示结合以进行标签预测。鉴于不同用户对预测结果的影响程度可能不同且可能含有干扰信息,受研究^[31]启发,我们利用用户当前所发布的内容构建门控,从用户的历史行为所展现的偏好中获取相关的偏好,同时过滤掉无关的噪声。文本序列门控和标签序列门控分别为:

$$g_d = [h_i \oplus \hat{d}_{l_u}] \mathbf{W}_d + b_d \quad (6)$$

$$g_t = [h_i \oplus \hat{t}_{l_u}] \mathbf{W}_t + b_t \quad (7)$$

其中, $\mathbf{W}_d, \mathbf{W}_t \in \mathbb{R}^{2d_h \times d_h}$, $b_d, b_t, g_d, g_t \in \mathbb{R}^{d_h}$, \oplus 表示连接操作。点级别的门控机制针对偏好特征的每个元素都学习一个门控参数,可以对偏好特征中包含的信息进行逐点的细粒度筛选。将经过门控机制筛选后的偏好特征与当前帖子的特征相结合得到融合用户意图的特征表示。

$$\hat{h}_i = h_i + g_d \odot \hat{d}_{l_u} + g_t \odot \hat{t}_{l_u} \quad (8)$$

其中, \odot 表示按元素乘操作。最后,将获得的表示经过多标签分类器来获得标签 k 的概率。

$$f(\mathbf{X}_i, u_i, k) = \text{sigmoid}(\mathbf{W}_7 \hat{h}_i) \quad (9)$$

其中, $\mathbf{W}_7 \in \mathbb{R}^{d_h}$ 。

2.5 损失函数

最后采用相应的二元交叉熵函数作为标签排名的损失函数来训练模型参数。

$$L = - \sum_{i=1}^N \sum_{k=1}^L (y_{i,k} \log f(\mathbf{X}_i, u_i, k) + (1 - y_{i,k}) \log(1 - f(\mathbf{X}_i, u_i, k))) \quad (10)$$

其中, N 表示训练集数据的数量, L 表示标签的数量, $y_{i,k} \in \{0, 1\}$ 表示第 i 个帖子是否被赋予了标签 k , $y_{i,k} = 1$ 表示第 i 个帖子具有标签 k , 反之则不具有。

3 实验分析

3.1 实验设置

3.1.1 数据集

本文使用 4 个真实世界数据集: Physics, Academia, Cooking 和 Android。原始数据来自于在线问答网站 Stack Exchange。我们提取原始数据集中的用户、帖子、标签和时间信息,并去掉发帖数少于 5 个的用户,根据发帖时间排列构建现有数据集。4 个数据集的统计信息如表 1 所列。在划分训练集、验证集和测试集时,本文使用用户交互序列的最后一次交互帖子作为测试集,倒数第二次交互帖子作为验证集,之前的所有交互过的帖子作为训练集^[32-33]。

表 1 实验数据集

Table 1 Summary of experimental datasets

数据集	帖子总数	标签总数	用户总数	用户平均发帖数	单词总数	文本平均长度	平均标签数量
Physics	55716	883	4038	13.8	183042	206.6	3.2
Academia	14062	439	1850	7.6	43247	188.1	2.7
Cooking	10941	813	1338	8.2	35332	125.7	2.4
Android	49724	1277	1911	26.0	49724	134.5	2.5

3.1.2 评价指标

我们选择在标签推荐问题上广泛应用的评价指标^[9,34]: 精确率 Precision@k(P@k)、召回率 Recall@k(R@k) 和 F1-score@k(F1@k), 定义如下:

$$P@K = \frac{1}{M} \sum_{i=1}^M \frac{\text{hit}(k)_i}{k} \quad (11)$$

$$R@K = \frac{1}{M} \sum_{i=1}^M \frac{\text{hit}(k)_i}{\text{tag}_i} \quad (12)$$

$$F1@k = \frac{2 \cdot P@K \cdot R@K}{P@K + R@K} \quad (13)$$

其中, M 表示测试集的大小, k 表示算法推荐的标签的数量,

$hit(k)_i$ 表示算法推荐正确的标签数目, tag_i 表示项目 i 实际具有的标签数目。

3.1.3 对比算法

本文方法可以与任意的标签推荐算法组合,将用户偏好特征与文本特征融合,提升标签推荐算法的效果。本文选取了具有代表性的标签推荐算法进行对比实验用于验证所提方法的有效性,对比算法的介绍如下:

TLSTM^[11]:使用 LDA 主题模型获取主题信息来丰富文档的表示,从而利用主题来提取文档中的信息。

ABC^[34]:采用 CNN 神经网络和单词级别注意力机制来提取全局和局部信息以进行标签推荐。

CAN^[10]:在胶囊网络中加入了注意力机制,以捕获重要的和可区分的特征。

PBAM^[35]:建立了一个基于位置的注意力模型,用关键字自动标记文档。

HAN^[12]:采用深度递归神经网络将科技论文标题和摘要编码为语义向量。

PTM4Tag^[13]:使用预训练模型进行特征提取,并将平均池化后的向量进行特征融合。

KEIC^[17]:引入知识图谱丰富实体内容,并采用含有多个 [CLS] 编码的预训练语言模型的编码器来提取分类特征。

3.1.4 参数设置

本文使用自然语言工具包 (NLTK) 进行分词操作,保留

最频繁出现的 50000 个单词作为词汇表。设置模型的隐藏层大小为 512,丢弃率为 0.1。对于所有对比算法,单词嵌入维度设置为 100,GRU/LSTM 的隐藏层大小设置为 256。本文采用 Adam 优化器,并在验证损失不再减少时提前停止训练过程。

3.2 性能对比

本文提出的 MLP4STR 和 7 种对比算法在 4 个数据集上的评价指标得分情况如表 2—表 5 所列,最优结果用粗体表示,次优结果用下划线标出。

从对比实验结果可以看出,MLP4STR 明显优于现有方法。例如,在 4 个数据集上,其与最优的对比算法相比,在 F1@5 指标上均有提升。另外,在各数据集中 PTM4Tag 以及 KEIC 取得了次优结果。PTM4Tag 使用预训练模型学习不同模态的特征,并对不同模态特征先进行平均池化再进行融合。预训练的语言模型确实提取到了文本信息中的特征,有助于后续标签推荐的顺利进行。KEIC 利用外部知识丰富了文本实体的内容,对标签推荐起到了一定作用。各对比算法设计了不同的文本表示策略,但只利用了当前帖子对应的特征,没有挖掘用户的历史帖子所展现的偏好。MLP4STR 首先使用预训练语言模型学习文本特征的表示,然后通过序列建模提取到了动态的用户偏好,更加符合标签推荐的需求。因此,MLP4STR 取得了显著的性能提升。

表 2 评价指标在 Physics 数据集上的对比结果

Table 2 Comparative results of evaluation metrics on Physics dataset

方法	P@1	R@1	F1@1	P@3	R@3	F1@3	P@5	R@5	F1@5
TLSTM	52.3	20.2	29.2	36.6	39.7	38.1	27.9	48.9	35.5
PBAM	60.2	23.2	33.5	41.6	44.9	43.2	31.2	54.9	39.8
HAN	57.4	22.2	32.0	39.3	42.6	40.9	29.9	52.6	38.1
ACN	54.3	20.7	30.0	36.1	39.0	37.5	27.3	48.2	34.9
ABC	64.1	24.8	35.8	44.6	48.3	46.4	33.6	58.7	42.7
PTM4Tag	<u>70.7</u>	<u>27.8</u>	<u>39.9</u>	49.5	53.8	51.5	37.1	65.0	47.3
KEIC	<u>70.7</u>	27.6	39.7	<u>49.9</u>	<u>54.2</u>	<u>52.0</u>	<u>37.6</u>	<u>65.8</u>	<u>47.8</u>
MLP4STR	73.8	29.2	41.8	51.7	55.9	53.8	38.6	67.3	49.0

表 3 评价指标在 Academia 数据集上的对比结果

Table 3 Comparative results of evaluation metrics on Academia dataset

方法	P@1	R@1	F1@1	P@3	R@3	F1@3	P@5	R@5	F1@5
TLSTM	43.8	17.9	25.4	30.3	36.4	33.0	22.9	45.2	30.4
PBAM	48.3	19.8	28.0	31.8	37.4	34.4	24.4	47.3	32.2
HAN	42.2	17.1	24.3	27.6	32.4	29.8	21.4	41.5	28.2
ACN	38.1	15.1	21.6	26.0	30.1	27.9	20.1	38.5	26.4
ABC	58.2	24.2	34.2	39.8	47.5	43.3	30.2	58.7	39.8
PTM4Tag	62.2	26.0	36.7	42.6	50.2	46.1	31.5	60.9	41.5
KEIC	<u>64.2</u>	<u>26.8</u>	<u>37.8</u>	<u>43.5</u>	<u>52.1</u>	<u>47.4</u>	<u>32.1</u>	<u>62.1</u>	<u>42.3</u>
MLP4STR	65.8	27.6	38.8	44.4	52.8	48.2	32.9	64.0	43.4

表 4 评价指标在 Cooking 数据集上的对比结果

Table 4 Comparative results of evaluation metrics on Cooking dataset

方法	P@1	R@1	F1@1	P@3	R@3	F1@3	P@5	R@5	F1@5
TLSTM	31.5	15.0	20.3	19.7	27.0	22.8	14.9	33.4	20.6
PBAM	32.4	15.3	20.8	20.4	27.8	23.5	15.4	34.2	21.2
HAN	20.0	8.9	12.4	13.7	18.3	15.7	10.7	23.6	14.7
ACN	19.3	8.7	12.0	12.3	16.3	14.0	9.5	20.9	13.1
ABC	60.5	29.0	39.2	37.0	50.5	42.7	26.3	58.4	36.2
PTM4Tag	69.1	33.7	45.3	41.9	57.1	48.3	28.8	63.9	39.7
KEIC	<u>70.5</u>	<u>34.0</u>	<u>45.9</u>	<u>43.1</u>	<u>58.5</u>	<u>49.6</u>	<u>29.4</u>	<u>66.6</u>	<u>41.3</u>
MLP4STR	72.6	35.5	47.7	44.0	60.0	50.8	30.9	68.4	42.6

表 5 评价指标在 Android 数据集上的对比结果

Table 5 Comparative results of evaluation metrics on Android dataset

方法	P@1	R@1	F1@1	P@3	R@3	F1@3	P@5	R@5	F1@5
TLSTM	15.2	7.1	9.7	9.9	13.7	11.5	7.7	17.4	10.7
PBAM	21.4	10.0	13.6	14.0	19.0	16.1	10.8	23.7	14.8
HAN	14.0	6.4	8.8	10.5	14.1	12.1	8.3	18.1	11.3
ACN	15.1	7.0	9.6	10.4	13.6	11.8	8.3	17.8	11.3
ABC	45.1	21.8	29.4	27.3	37.2	31.5	19.8	43.9	27.3
PTM4tag	54.9	26.5	35.7	32.3	43.3	37.0	22.9	49.7	31.3
KEIC	55.3	26.4	35.8	33.3	44.7	38.2	23.5	51.0	32.1
MLP4STR	56.3	27.4	36.8	33.9	45.7	38.9	23.7	51.7	32.5

3.3 消融实验

为了进一步研究 MLP4STR 中关键模块的影响,本文进行了消融实验,研究了序列建模模块(seq)、历史标签信息(tag)和历史文本信息(doc)对最终性能的影响。在 Cooking 和 Android 两个数据集上对 F1@1、F1@3 和 F1@5 评价指标进行了对比,结果如图 4 所示。

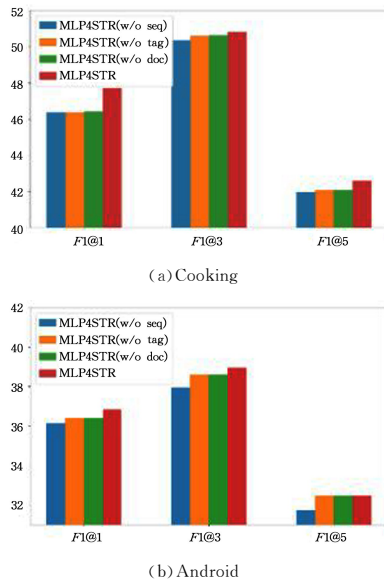


图 4 两个数据集上的消融实验 F1@K 对比结果

Fig. 4 F1@K comparison results of ablation experiments on two datasets

去掉序列建模的 seq 模块,直接改用池化层之后,模型的 F1@5 分别下降了 2.4% 和 1.4%,这验证了对历史序列进行序列建模的有效性。在仅仅使用用户历史标签信息或者历史帖子信息进行建模时,各评估指标均有所下降,说明了同时采用历史标签信息和历史帖子信息进行交互建模的作用。通过对历史标签信息和历史帖子信息的交互学习,提取到了更为准确的用户偏好,更好地实现了面向用户的标签推荐。

3.4 参数敏感性分析

由于所提模型涵盖了用户的历史信息,因此在本节中探讨了用户历史信息序列长度对标签推荐效果的影响。实验结果基于 Cooking 和 Android 两个数据集,具体如图 5 所示。

Android 数据集上的平均用户历史序列长度为 26,在该数据集上,F1@5 的结果在历史序列长度为 25 时达到峰值。Cooking 数据集中平均用户历史序列长度为 8.2,在该数据集上,F1@5 的结果在平均历史序列长度附近呈现先上升后下降的趋势。总体来说,实验结果长度为平均用户历史序列长度时可以取得最优结果。这是由于序列过短时其中包含的

信息不足,因此实验效果不好;序列过长时,虽然序列信息增强,但所有用户的序列长度不能完全满足该要求,反而会导致效果下降。

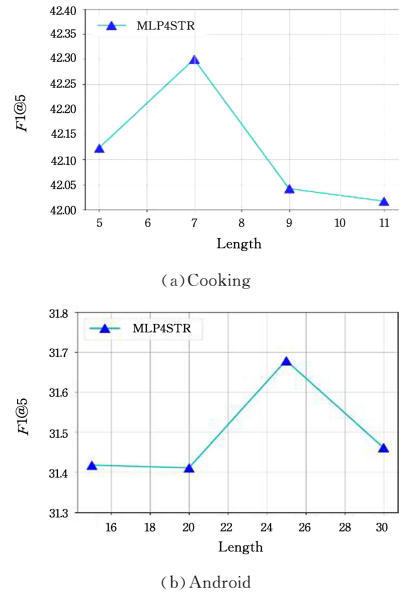


图 5 MLP4STR 在历史序列长度不同时的实验效果

Fig. 5 Performance of MLP4STR with different historical sequence length

3.5 案例分析

为了证明所提算法可以有效地捕获到用户偏好,本文从数据集中取出一篇文章对不同算法的预测结果进行展示。如图 6 所示,Post2 为测试集中的一篇文章,Post1 为该用户历史发布的帖子,图中包含帖子发布的时间信息。

Post1: Does Huawei-u8160 support USB host? I have a Huawei-u8160(A. K. AVodafone 858) which is running Cyanogenmod 7.2. I was wondering if it supports USB host so I can connect a keyboard or a Flash drive. Tag: cyanogenmod;usb-host-mode;huawei-u8160; Time: 2012-06-21
Post2: where can I find fuse. ko file for my Huawei-u8160 ? I have a Huawei-u8160 running Cyanogenmod 7.2. I have been looking for the fuse. ko module for my phone, but whenever I find anything, terminal emulator tells me that it is incompatible! I want it to enable NTFS file system support using this tutorial So I was wondering where I can find the appropriate fuse. ko module. Tag: cyanogenmod;huawei-u8160;ntfs;Time: 2012-09-16
MLP4STR Result: cyanogenmod;huawei-u8160;root-access;
PTM4Tag Result: cyanogenmod;root-access;partitions;

图 6 标签推荐结果示例

Fig. 6 Example of tag recommendation results

可以发现本文方法成功为 Post2 推荐出了两个标签“cyanogenmod”和“huawei-u8160”,但是 PTM4Tag 仅仅推荐了一个标签。PTM4Tag 仅通过对 Post2 的内容特征进行标签推荐,没能给出更加符合用户偏好的标签。MLP4STR 在融入序列信息后,成功将 Post1 中所展现的用户偏好提取出来并用于指导当前帖子的标签推荐过程。

结束语 本文首次提出序列标签推荐任务。考虑到标签推荐中用户主体的重要性以及帖子发布的先后顺序,建模了一种更加接近真实场景的标签推荐任务。提出了一种显式地建模用户偏好用于引导整体标签推荐的算法 MLP4STR,采用一种跨特征对齐的 MLP 序列特征提取框架,将文本和标签的特征对齐,获取用户的历史帖子信息和历史标签信息中隐含的用户动态兴趣。最后,结合帖子内容和用户偏好进行标签推荐。在 4 个真实世界的数据集上的实验结果表明,MLP4STR 能够有效地学习序列标签推荐中的用户历史行为序列。

参 考 文 献

- [1] KRESTEL R, FANKHAUSER P, NEJDL W, et al. Latent dirichlet allocation for tag recommendation[C]// Proceedings of the ACM Conference on Recommender Systems. New York: Association for Computing Machinery, 2009: 61-68.
- [2] BELÉM F M, ALMEIDA J M, GONÇALVES M A. A survey on tag recommendation methods[J]. Journal of the Association for Information Science and Technology, 2017, 68(4): 830-844.
- [3] XU P Y, LIU H F, LIU B. Survey of Tag Recommendation Methods Journal of Software[J]. Journal of Software, 2021, 33(4): 1244-1266.
- [4] SUN J S, ZHU M Y, JIANG Y C, et al. Hierarchical attention model for personalized tag recommendation[J]. Journal of the Association for Information Science and Technology, 2021, 72(2): 173-189.
- [5] SONG Y, ZHUANG Z M, LI H J, et al. Realtime automatic tag recommendation[C]// Proceedings of the 31st Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2008: 515-522.
- [6] XIA X, DAVID L, WANG X Y, et al. Tag recommendation in software information sites[C]// Proceedings of the 10th Working Conference on Mining Software Repositories(MSR). Piscataway: IEEE Computer Society, 2013: 287-296.
- [7] WU Y, YAO Y, XU F, et al. Tag2word: Using tags to generate words for content based tag recommendation[C]// Proceedings of the 25th ACM International on Conference on Information and Knowledge Management. New York: Association for Computing Machinery, 2016: 2287-2292.
- [8] WU Y, XI S Q, YAO Y, et al. Guiding supervised topic modeling for content based tag recommendation[J]. Neurocomputing, 2018, 314: 479-489.
- [9] TANG S J, YAO Y, ZHANG S W, et al. An integral tag recommendation model for textual content[C]// Proceedings of the AAAI Conference on Artificial Intelligence. Menlo Park: AAAI Press, 2019: 5109-5116.
- [10] LEI K, FU Q A, YANG M, et al. Tag recommendation by text classification with attention-based capsule network[J]. Neurocomputing, 2020, 391: 65-73.
- [11] LI Y, LIU T, JIANG J, et al. Hashtag recommendation with topical attention-based lstm[C]// Proceedings of the 26th International Conference on Computational Linguistics: Technical Papers. New York: Association for Computing Machinery, 2016: 3019-3029.
- [12] HASSAN H A, SANSONETTI G, GASPARETTI F, et al. Semantic-based tag recommendation in scientific bookmarking systems[C]// Proceedings of the 12th ACM Conference on Recommender Systems. New York: Association for Computing Machinery, 2018: 465-469.
- [13] HE J D, XU B W, YANG Z, et al. PTM4Tag: Sharpening Tag Recommendation of Stack Overflow Posts with Pre-trained Models[C]// Proceedings of the 30th IEEE/ACM International Conference on Program Comprehension. New York: Association for Computing Machinery, 2022: 1-11.
- [14] CHEN Y C, LAI K T, LIU D, et al. Tagnet: triplet-attention graph networks for hashtag recommendation[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 32(3): 1148-1159.
- [15] FENG K, LIU T, ZHANG H, et al. Tnod: Transformer network with object detection for tag recommendation[C]// Proceedings of the 2023 ACM International Conference on Multimedia Retrieval. 2023: 617-621.
- [16] LI L, WANG P, ZHENG X, et al. Dual-interactive fusion for code-mixed deep representation learning in tag recommendation [J]. Information Fusion, 2023, 99: 101862.
- [17] WANG L, LI Y, KEIC: A tag recommendation framework with knowledge enhancement and interclass correlation[J]. Information Sciences, 2023, 645: 119330.
- [18] SIGURBJÖRNSSON B, ZWOL R. Flickr tag recommendation based on collective knowledge[C]// Proceedings of the International Conference on World Wide Web. New York: Springer, 2008: 327-336.
- [19] NGUYEN H, WISTUBA M, GRABOCKA J, et al. Personalized deep learning for tag recommendation[C]// Proceedings of the Pacific-Asia Conference on Knowledge Discovery and Data Mining. Berlin: Springer, 2017: 186-197.
- [20] MAITY S K, PANIGRAHI A, GHOSH S, et al. DeepTagRec: A content-cum-user based tag recommendation framework for stack overflow[C]// Proceedings of European Conference on Information Retrieval. Switzerland: Springer, 2019: 125-131.
- [21] QUINTANILLA E, RAWAT Y, SAKRYUKIN A, et al. Adversarial learning for personalized tag recommendation[C]// IEEE Transactions on Multimedia. Piscataway: IEEE Computer Society, 2020, 23: 1083-1094.
- [22] ZHANG S W, YAO Y, XU F, et al. Hashtag recommendation for photo sharing services[C]// Proceedings of the AAAI Conference on Artificial Intelligence. Menlo Park: AAAI Press, 2019: 5805-5812.
- [23] KANG W C, MCAULEY J. Self-attentive sequential recommen-

- dation[C] // 2018 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE Computer Society, 2018: 197-220.
- [24] ZHANG T T, ZHAO P P, LIU Y C, et al. Feature-level deeper self-attention network for sequential recommendation[C] // Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. San Francisco: Morgan Kaufmann, 2019: 4320-4326.
- [25] ZHOU P L, YE Q C, XIE Y Q, et al. Attention Calibration for Transformer-based Sequential Recommendation [C] // Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. 2023: 3595-3605.
- [26] SUN F, LIU J, WU J, et al. Bert4rec: Sequential recommendation with bidirectional encoder representations from transformer [C] // Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: Association for Computing Machinery, 2019: 1441-1450.
- [27] ZHENG J, RAMASINGHE S, LUCEY S. Rethinking positional encoding[J]. arXiv:2107.02561. 2021.
- [28] LI M, ZHAO X, LYU C, et al. MLP4Rec: A pure MLP architecture for sequential recommendations[C] // Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence. San Francisco: Morgan Kaufmann, 2022: 2138-2144.
- [29] EKAMBARAM V, JATI A, NGUYEN N, et al. TSMixer: Lightweight MLP-Mixer Model for Multivariate Time Series Forecasting[C] // Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: Association for Computing Machinery, 2023: 459-469.
- [30] DEVLIN J, CHANG MW, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding [C] // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg: Association for Computational Linguistics, 2019: 4171-4186.
- [31] KUMAR S, SHIVANI A, AKHTAR M S, et al. When did you become so smart, oh wise one? Sarcasm Explanation in Multi-modal Multi-party Dialogues[C] // Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. 2022: 5956-5968.
- [32] LI M Y, ZHANG Z J, ZHAO X Y, et al. AutoMLP: Automated MLP for Sequential Recommendations[C] // Proceedings of the ACM Web Conference. New York: Association for Computing Machinery, 2023: 1190-1198.
- [33] LIANG J H, ZHAO X Y, LI M Y, et al. MMMLP: multi-modal multilayer perceptron for sequential recommendations[C] // Proceedings of the ACM Web Conference 2023. 2023: 1109-1117.
- [34] GONG Y Y, ZHANG Q. Hashtag recommendation using attention-based convolutional neural network[C] // Proceedings of International Joint Conference on Artificial Intelligence. San Francisco: Morgan Kaufmann, 2016: 2782-2788.
- [35] SUN B, ZHU Y Z, XIAO Y K, et al. Automatic Question Tagging with Deep Neural Networks[J]. IEEE Transactions on Learning Technologies. Piscataway: IEEE Computer Society, 2019: 29-43.



LIU Bing, born in 2000, master, is a student member of CCF(No. P2313G). Her main research interests include tag recommendation and multi-label learning.



JING Liping, Ph.D, professor, is a professional member of CCF(No. 18443S). Her main research interests include machine learning and its application in artificial intelligence field and so on.

(责任编辑:李亚辉)