

基于最优传输和知识回放的新闻推荐模型增量学习方法

黄震华¹⁾ 林 威¹⁾ 吴正洋¹⁾ 刘 波¹⁾ 汤 庸¹⁾ 陈运文²⁾

¹⁾(华南师范大学计算机学院 广州 510631)

²⁾(达而观信息科技(上海)有限公司研发部 上海 201203)

摘 要 基于深度学习的个性化新闻推荐方法通常采用全量更新训练模型.然而,全量更新需要不断整合新数据形成新的训练集,虽然可以保障模型性能,但训练效率低下.另外,出于数据隐私和存储考虑,现实场景下的应用通常不会保留所有历史数据导致全量更新难以为继.增量学习是目前广泛采用的有效解决方法.然而,基于增量学习的新闻推荐模型也存在着新的挑战——灾难性遗忘问题,常见的解决策略有基于正则化和基于回放的方法.基于正则化的方法局限于个体样本在新任务中学习到的特征和原始网络的响应特征之间的对齐或空间几何结构匹配,缺乏全局视觉.基于回放的方法重放过往任务数据,可能导致数据隐私泄漏.为了解决以上不足,本文提出了基于最优传输和知识回放(Optimal Transport and Knowledge Replay)的新闻推荐模型增量学习方法 OT-KR. OT-KR方法通过联合分布知识提取器重构联合分布知识特征集合,并且使用最优传输理论在训练过程中最小化新任务和旧任务间的分布差异,确保新模型学习到的域分布可以同时拟合旧任务和新任务,实现知识融合.特别地,为了缓解数据隐私泄漏问题,OT-KR方法仅保存模型参数而非样本作为知识进行回放,同时,借鉴多教师知识蒸馏思想让新任务上的模型可以同时融合所有教师流中的分布信息,并根据任务的学习次序分配权重.通过在公开新闻推荐数据集上开展实验,结果表明 OT-KR方法的推荐性能优于基于目前主流增量学习技术的新闻推荐方法,在 AUC 和 NDCG@10 两个指标上比目前最优性能平均提高了 0.55% 和 0.47%,同时,能够很好地平衡模型的推荐性能和训练效率.

关键词 新闻推荐;增量学习;最优传输;多教师知识蒸馏;深度学习

中图分类号 TP311 DOI号 10.11897/SP.J.1016.2023.02161

Incremental News Recommendation Method Based on Optimal Transport and Knowledge Replay

HUANG Zhen-Hua¹⁾ LIN Wei¹⁾ WU Zheng-Yang¹⁾ LIU Bo¹⁾ TANG Yong¹⁾ CHEN Yun-Wen²⁾

¹⁾(School of Computer Science, South China Normal University, Guangzhou 510631)

²⁾(Research and Development Department, DataGrand Inc., Shanghai 201203)

Abstract Personalized news recommendation methods based on deep learning usually use full updates to train the model. However, full updates require continuous integration of new data to form a new training set. Although the performance of the news recommendation model can be effectively guaranteed, the training efficiency of the model is low. In addition, due to data privacy and storage considerations, news recommendation applications in real-world scenarios usually do

收稿日期:2022-11-29;在线发布日期:2023-07-11. 本课题得到国家自然科学基金(62172166, U1811263, 61772366)、广东省基础与应用基础研究基金(2022A1515011380)、上海市自然科学基金(17ZR1445900)资助. 黄震华(通信作者),博士,教授,博士生导师,主要研究领域为机器学习、数据挖掘、推荐系统. E-mail: jukiehuang@163.com. 林 威,硕士研究生,主要研究领域为推荐系统、增量学习. 吴正洋,博士,副教授,主要研究领域为推荐系统、知识追踪. 刘 波,博士,教授,主要研究领域为机器学习、云计算. 汤 庸,博士,教授,博士生导师,中国计算机学会(CCF)杰出会员,主要研究领域为数据挖掘、数据库. 陈运文,博士,正高级工程师,主要研究领域为机器学习、知识蒸馏.

not retain all historical data, making full-update unsustainable. For the problems mentioned above, an effective solution widely adopted at present is incremental learning. However, incremental learning-based news recommendation models also have new challenges, e.g., catastrophic forgetting. That is, the domain drift caused by the non-stationary distribution of the input domain of the task flow will lead to the catastrophic forgetting of user preference knowledge in the old data domain. Common solution strategies include regularization-based and replay-based methods. Regularization-based methods limit the forgetting of old knowledge by adding regularisation terms to the learning of new tasks but are limited to the alignment or spatial geometric structure matching between features learned by individual samples in a new task and the response features of the original network, which lacks global vision. Replay-based methods maintain the old knowledge of the model by replaying a subset of samples from previous tasks but may lead to data privacy leaks due to the use of past task data. In order to solve the shortcomings of existing methods, this paper proposes an incremental learning method OT-KR for news recommendation models based on optimal transport and knowledge replay. The OT-KR method first calculates a user's click probability score for the current candidate news based on general news recommendation architectures, and then fuses the news representation, user representation, and click probability score, and reconstructs the joint distribution knowledge feature through a joint distribution knowledge extractor. On this basis, the optimal transfer theory is used to minimize the distribution difference between the new task and the old task during the training process, to ensure that the domain distribution learned by the new model can fit both the old task and the new task and realize knowledge fusion. In particular, in order to alleviate the problem of data privacy leakage, OT-KR only saves the parameters of the news recommendation model instead of the samples of the news recommendation dataset as knowledge for playback. At the same time, drawing on the idea of multi-teacher knowledge distillation, the news recommendation model of the new task can simultaneously integrate the distribution information of all teacher streams, and allocate weights according to the learning order of the tasks. By conducting experiments on publicly available news recommendation datasets, the results show that the news recommendation performance of the OT-KR method is better than that of news recommendation methods based on current mainstream incremental learning techniques, with an average improvement of 0.55% and 0.47% over the current optimal news recommendation performance in both AUC and NDCG@10 metrics. And at the same time, it can well balance the recommendation performance and training efficiency of the news recommendation model.

Keywords news recommendation; incremental learning; optimal transport; multi-teacher knowledge distillation; deep learning

1 引 言

新闻推荐(News Recommendation)旨在帮助用户筛选出其感兴趣的新闻文章^[1-2]. 随着深度学习技术的发展,基于深度学习的个性化新闻推荐方法日新月异,受到研究人员的广泛关注.

目前,新闻推荐模型通常基于完整的数据集进行全量更新,即利用某个时刻下的全量数据进行模

型训练. 然而,新闻推荐系统每时每刻都会出现大量新闻数据和用户交互数据,全量更新方法每隔一段时间就需要整合新的数据构建新的数据集用于训练,虽然可以保障较高的新闻推荐性能,但数据量越大,所需要的训练时间就越长,训练效率越发低下. 另外,出于存储空间和数据隐私考虑^[3-4],许多新闻推荐系统通常不会保存所有历史数据,从而导致无法进行有效的全量更新.

近年来,增量学习(Incremental Learning)技术

被广泛应用于计算机视觉、自然语言处理和语音识别等领域来解决模型无法有效进行全量更新的问题,并取得了良好的效果^[5-7]。受此启发,本文在新闻推荐任务中引入增量学习概念,将全量更新转换为增量更新,并将训练过程从批处理模式转换为增量处理模式,仅利用新数据训练新闻推荐模型,更新后的模型在下次新数据到来之前为用户提供新闻推荐,有效提高了新闻推荐任务的实时性,帮助新闻推荐系统更快地适应新的数据模式。

通常,增量学习分为三种类型^[8],即:任务增量、类增量和域增量。我们发现,在新闻推荐任务中,用户交互数据以时间为单位进行收集,不同时刻收集的交互数据导致了新闻推荐任务数据流的非平稳分布。因此,不难看出,新闻推荐模型的增量学习属于域增量学习的研究范畴。通常,我们把“新闻推荐模型的增量学习”亦称为“基于域增量学习的新闻推荐任务”。

然而,对新闻推荐模型实施域增量学习将不可避免出现灾难性遗忘现象,主要原因在于任务输入数据域的非平稳分布所引发的域漂移,其表现为当模型在新任务上训练完成后,在过往的任务上的性能发生断崖式下跌,也就是说,在新的数据分布上更新的新闻推荐模型往往会忘记它以前学过的旧分布。目前,常见的解决策略主要有基于正则化和基于回放的方法。其中,基于正则化的方法以LWF (Learning without Forgetting)^[9]为代表,通过在新任务的学习中增加正则化项来限制旧知识的遗忘,但局限于个体样本在新任务中学习到的特征和原始网络的响应特征之间的特征对齐或空间几何结构匹配,缺乏全局视觉,没有从整体的角度考虑旧知识和新知识间的相关性。基于回放的方法以iCaRL (Incremental Classifier and Representation Learning)^[10]为代表,其基本思路是在新任务的训练过程中重放旧任务出现过的样本来维持模型的旧知识。该方法需要保存每个旧任务的部分数据,从而很大程度上造成数据隐私泄露问题。

为了解决现有方法的上述不足,本文将新闻推荐任务视为连续时间间隔上的非平稳数据分布任务流,并提出基于最优传输和知识回放(Optimal Transport and Knowledge Replay)的新闻推荐模型增量学习方法OT-KR。该方法首先基于通用的新闻推荐模型得到用户特征和候选新闻特征,并计算用户对于当前候选新闻的点击概率分数,保证模型在新任务上的泛化能力;接着,从全局的角度考虑旧

知识的巩固,对用户特征、候选新闻特征以及点击概率分数进行融合,通过联合分布知识提取器重构联合分布知识特征集合,并在反向传播过程中最小化通过最优传输^[11]计算得到的新、旧任务分布之间的瓦瑟斯坦(Wasserstein)距离,使得新模型学习到的域分布可以同时适应于旧任务和新任务,从而有效实现了联合分布知识的融合,达到缓解灾难性遗忘的目的。在此基础上,OT-KR方法采用了知识回放策略,即通过保存从过往任务学习得到的模型参数而非样本作为知识进行回放,从而既保留任务完整分布信息,又缓解了数据隐私的泄露。特别地,该策略基于多教师知识蒸馏思想^[12-15],使新任务的模型同时融合每个教师流中的分布信息,并且根据任务的学习次序来调节知识权重。

归纳起来,本文的主要贡献如下:

(1) 本文将域增量学习引入到新闻推荐任务中,来平衡模型的推荐性能和训练效率,并缓解由于存储空间和数据隐私原因造成无法进行有效全量更新的问题。

(2) 为了减轻灾难性遗忘问题,本文基于最优传输理论对不同数据域的分布差异进行约束,以确保当前模型能够同时拟合新、旧任务;同时,为了缓解数据隐私泄露问题,本文提出知识回放策略来取代现有的样本回放策略,并通过多教师知识蒸馏来更好地实现新任务的训练优化。

(3) 在公开新闻推荐数据集MIND (包括MIND_large和MIND_small)进行大量的实验。结果表明OT-KR方法在新闻推荐的增量学习方面优于目前主流的方法。

本文接下来组织如下:第2节介绍国内外相关工作;第3节给出本文的问题定义;第4节提出OT-KR方法,并对其详细描述;第5节给出实验结果与对比分析;第6节总结全文并对未来的研究工作进行展望。

2 相关工作

2.1 新闻推荐方法

传统新闻推荐方法基于特征工程对新闻和用户进行建模^[16-21]。这些方法严重依赖于人工特征工程,需要大量的专业领域知识。

近年来,基于深度学习的方法广泛应用于新闻推荐任务中,通过准确的新闻和用户建模有效实现了个性化的新闻推荐。现有的个性化新闻推荐方法

通常根据用户的新闻点击历史进行建模,并且根据用户和候选新闻的特征表示的相关性预测得分.其中,文献[22]提出的多视角学习模型 NAML (Neural News Recommendation with Attentive Multi-View Learning) 通过将标题、正文和类别作为不同的新闻视角组合学习统一的新闻特征.文献[23]提出了基于个性化注意力机制的新闻推荐模型 NPA (Neural News Recommendation with Personalized Attention), 根据用户偏好动态选择新闻的重要信息,有助于学习信息更加丰富的特征.文献[24]提出的 NRMS (Neural News Recommendation with Multi-Head Self-Attention) 模型基于单词之间的交互学习新闻的特征表示的同时进一步基于新闻之间的关联性增强用户的特征表示.文献[25]提出的 FIM (Fine-grained Interest Matching for Neural News Recommendation) 模型从多个语义层次对新闻文本中的每一对片段进行匹配,提取更多的细粒度信息.文献[26]提出的新闻推荐模型 HieRec (Hierarchical User Interest Modeling for Personalized News Recommendation) 基于用户兴趣层次建模新闻的多样化和多粒度的兴趣.文献[27-29]的新闻推荐模型进一步将用户的各种反馈整合到用户建模当中.

基于深度学习的模型在新闻推荐方面确实取得了比传统方法更好的性能.但是,以上这些方法假设整个数据集都可用于批处理训练,而现实应用中的新闻推荐模型面临的是数据分布不断变化的新闻任务数据流,如何在数据流中解决新闻推荐的遗忘问题才是本文的研究重点.最近,研究人员考虑如何将增量学习融入到基于图神经网络的推荐系统中来有效提升训练效率,并取得了一些创新性成果^[30-33].例如,文献[33]认为基于图的推荐系统的静态设置对于现实世界的应用是没有意义的,从而提供了一种有效的基于图的流式推荐手段.然而,这类工作目前主要从图的角度考虑增量学习,并且没有对现实场景下数据的域漂移进行有效的处理,在新闻推荐任务上不能取得很好的性能.

2.2 增量学习

增量学习也称为持续学习或终身学习^[8],旨在解决模型训练中的一个常见缺陷,即灾难性遗忘^[34-35].当机器学习模型在接受新任务的训练后,在旧任务上的表现通常会明显变差.近年来提出的解决方案,可简单划分为基于正则化的方法^[9, 36]、基于回放的方法^[10, 37]和基于动态架构^[38]的方法.基于动

态架构的方法常见于任务增量类型,在整个训练过程中增量地增加参数用于不同的任务,内存需求线性增长,与其他方法相比不公平,故本文只关注前两类方法.

基于正则化的方法主要通过对新任务的损失函数施加约束来巩固先前的知识.文献[9]的LWF方法基于单教师知识蒸馏^[39]思想,将蒸馏损失纳入新任务的损失函数中,文献[40]的LWM (Learning without Memorizing) 方法在LWF的基础上进一步考虑了基于注意力特征图的蒸馏损失.基于正则化的方法的另一个重要方向是通过估计模型参数重要性来扩展神经网络的损失函数,如EWC (Elastic Weight Consolidation)^[36], oEWC (online EWC)^[41], SI (Synaptic Intelligence)^[42]和RWALK (Riemannian Walk)^[43]等方法.

基于回放的方法通过存储旧任务的部分样本参与新任务的训练来克服灾难性的遗忘.文献[10]提出的iCaRL方法使用Herding技术^[44]选取旧任务的部分样本和新任务的所有样本构建训练集,并采用类均值最近邻分类器 (Nearest Class Mean classifier) 进行分类.文献[37]提出了经验回放方法ER (Experience Replay), 将旧任务的样本与当前任务样本结合到当前的训练批中.文献[45]的FDR (Function Distance Regularization) 方法存储任务边界的网络响应特征,在ER的基础上增加相应的正则化损失,文献[46]的DER (Dark Experience Replay) 方法进一步将FDR扩展到任务边界不明确的情况.文献[47]提出的SNCL方法在ER的基础上进一步考虑任务标签以及中间层的特征,对旧任务的经验进行完整的回放.源于互补学习系统CLS (Complementary Learning System) 理论的启发,文献[48]提出的CLS_ER方法在ER的基础上维持短期和长期语义记忆模型以再现旧任务样本的神经网络响应特征来实现知识巩固.此外,文献[49]的GEM (Gradient Episodic Memory) 方法及其轻量级模型A-GEM (Averaged-GEM)^[50]利用旧任务的样本构建优化约束,更正新任务的梯度下降方向.

基于正则化的方法通过额外的损失项来限制旧知识的遗忘.由于受限于模型容量,难以在模型的稳定性和可塑性中取得平衡,对新数据的适应性较差.基于回放的方法通过存储旧任务的部分样本参与新任务的训练,已被证明比基于正则化的方法更加有效^[8],但相应地带来了更多的内存和时间开销,

同时造成数据隐私泄露问题. 本文提出的方法将二者结合, 有效地缓解灾难性遗忘和数据隐私的泄露.

3 问题定义

3.1 新闻推荐模型域增量学习问题描述

与现有工作^[22-29]一致, 本文将新闻推荐问题定义为: 基于用户某段时间的新闻点击历史预测用户是否会点击之前没看过的候选新闻. 假设推荐系统中共有 n 个用户, 用户 u_i 的新闻点击历史为集合 $V_i = \{x_1^i, x_2^i, \dots, x_{c_i}^i\}$, 其中 $x_j^i (j = 1, \dots, c_i)$ 表示用户 u_i 点击的第 j 个新闻的标题, c_i 为 u_i 点击新闻的总数. 每个新闻的标题为一个词序列 $[\omega_1, \omega_2, \dots]$. 给定候选新闻 x_{cur} , 新闻推荐模型以 u_i 的新闻点击历史 V_i 作为输入, 计算 u_i 点击候选新闻 x_{cur} 的概率.

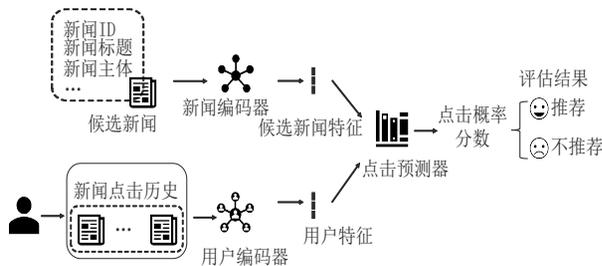


图1 新闻推荐模型通用架构图

基于深度学习的新闻推荐模型通常采取“两段式”方法对于用户和新闻分步显式建模^[51], 其架构如图1所示. 新闻编码器将用户新闻点击历史和候选新闻分别建模为相应的新闻特征 $\{h_1, h_2, \dots, h_{c_i}\}$ 和 h' . 用户编码器基于用户新闻点击历史的特征集合, 从整体偏好和时序兴趣等视角建模用户特征 u . 根据实际需要, 新闻编码器和用户编码器可以采用不同的深度学习部件. 不失一般性, 本文主要基于文献[23]的NPA模型结构. 点击预测器以 u 和 h' 的点乘作为用户点击该新闻的概率.

受文献[20]启发, 本文在训练模型时同样通过负采样技术联合预测 $k + 1$ 个新闻的点击概率分数. 其中, $k + 1$ 个新闻由同一个用户的1个正样本和随机采样的 k 个负样本组成, 对应的新闻特征为 h'_0 和 $\{h'_1, \dots, h'_k\}$. $k + 1$ 个候选新闻的点击概率分数 $\hat{y}_i (i = 0, \dots, k)$ 进行归一化处理得到 $\hat{y}_i (i = 0, \dots, k)$:

$$\hat{y}'_i = h_i'^T u, \quad (1)$$

$$\hat{y}_i = \frac{\exp(\hat{y}'_i)}{\sum_{j=0}^k \exp(\hat{y}'_j)} \quad (2)$$

新闻推荐任务的损失函数为所有正样本的负对数似然:

$$\mathcal{L}_{CE} = - \sum_{y_j \in \mathcal{S}^+} y_j \log(\hat{y}_j) \quad (3)$$

其中 \mathcal{S}^+ 为正样本集合, y_j 为样本的真实标签, \hat{y}_j 为样本的预测值.

标准的新闻推荐任务通过以上步骤可以得到从输入数据集 \mathcal{D} 映射到输出 \mathcal{Y} 的函数 \mathcal{F} , \mathcal{F} 为基于深度学习的新闻推荐模型. 在域增量学习设置下, 新闻推荐任务的输入数据集 \mathcal{D} 的分布是随着时间不断变化的, 而标签类别集合 \mathcal{Y} 保持不变, 即 $\mathcal{Y} = \{0, 1\}$. 为此, 本文引入了描述符 \mathcal{C} 来刻画数据流中每个任务对应的数据分布, 从而, 新闻推荐任务数据流可以定义为从分布 $\mathcal{C}_1, \mathcal{C}_2, \dots, \mathcal{C}_t$ 采样得到的任务序列 $(\mathcal{D}_1, \mathcal{C}_1, \mathcal{Y}_1), (\mathcal{D}_2, \mathcal{C}_2, \mathcal{Y}_2), \dots, (\mathcal{D}_t, \mathcal{C}_t, \mathcal{Y}_t)$, $t \rightarrow \infty$, 可得到相应时刻的新闻推荐模型为 $\mathcal{F}_1 \sim \mathcal{F}_t$.

新闻推荐模型域增量学习旨在仅利用 t 时刻新数据 $(\mathcal{D}_t, \mathcal{C}_t, \mathcal{Y}_t)$ 来学习新闻推荐模型 \mathcal{F}_t , 使得 \mathcal{F}_t 能够最大程度同时拟合 $\mathcal{C}_1 \sim \mathcal{C}_t$, 并在 $t + 1$ 时刻的数据到达之前为用户提供新闻推荐服务.

4 OT-KR方法

本节介绍 OT-KR方法的具体实施细节, 总体架构如图2所示, 其联合实现了新闻推荐和增量训练学习.

4.1 知识融合

新闻推荐模型增量学习的主要挑战为新闻推荐任务输入流的非平稳分布引发的域漂移问题, 基于新任务学习到的分布知识不能很好地拟合旧任务, 表现为当前更新后的模型对于过往任务的推荐性能大幅度降低. 通常, 新闻推荐任务数据流随着时间 t 变化, 对应任务数据 $(\mathcal{D}_t, \mathcal{Y}_t)$ 的分布 \mathcal{C}_t 也在不断变化, 尽管标签集合 \mathcal{Y} 保持不变, 即任务之间发生了域漂移, 模型学习到的知识向新任务偏移, 如图3(a)所示, $\mathcal{C}(\mathcal{D}_{new}, \mathcal{Y}_{new}) \neq \mathcal{C}(\mathcal{D}_{old}, \mathcal{Y}_{old})$. 一般的正则化方法只关注于从特征层面鼓励网络模仿原始网络对旧任务样本的响应, 而域漂移才是新闻推荐模型增量学习发生灾难性遗忘的根源. 因此, 任务整体的分布信息对于知识的迁移更加重要. 如图3(b)所

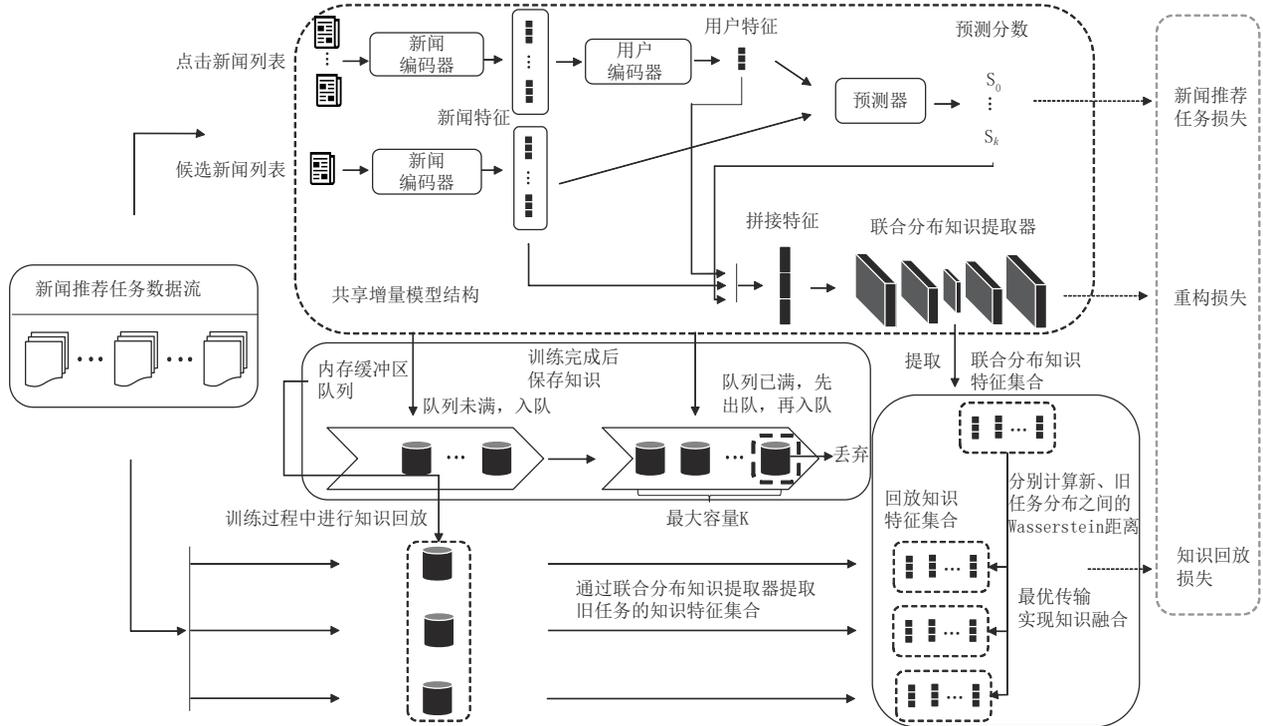


图2 OT-KR方法总体架构图

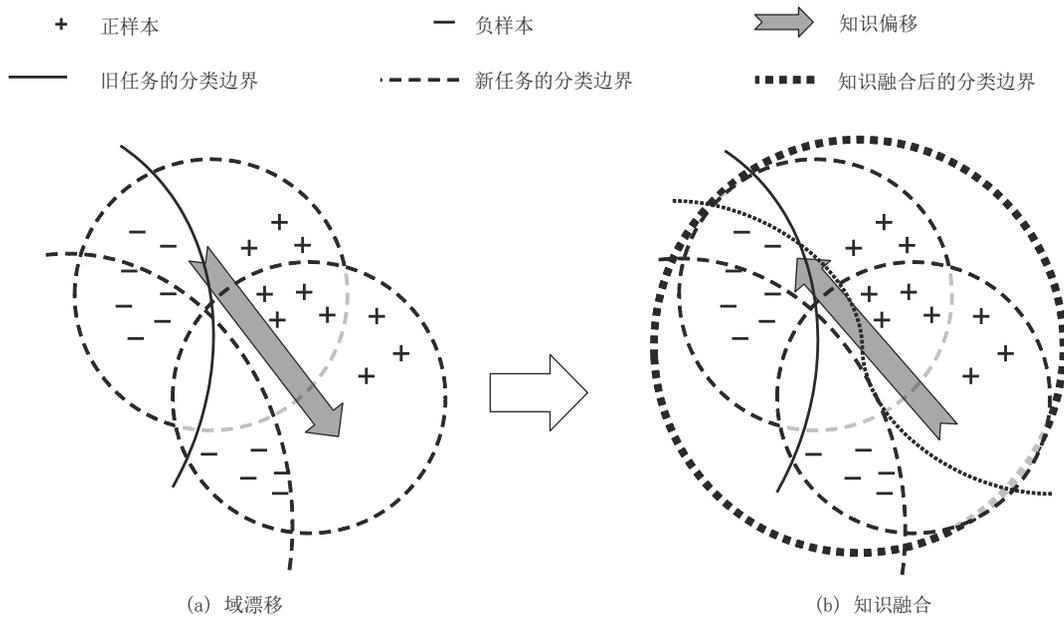


图3 知识融合过程

示,一方面我们希望新任务所学习到的分布知识不断靠近旧任务,另一方面,我们也希望新任务的模型可以维持当前任务的分布边界,这样将导致新任务的分布边界向旧任务的边界逐渐扩张,最终新任务的分布覆盖旧任务的分布,新任务的分类边界同时拟合新任务和旧任务,实现知识融合。

4.1.1 知识重构

模型学习到的全局知识通常无法直接通过新闻特征或者是用户特征表示.为此,本文使用神经网络重构出当前新闻推荐任务的全局知识.OT-KR方法首先基于3.1小节中的“两段式”新闻推荐方法保证新任务的泛化能力,即通过新闻编码器、用户编

码器以及点击预测器得到候选新闻特征 h'_i 和用户特征 u , 以及最终的点击概率分数 \hat{y}'_i .

当获得候选新闻特征 h'_i 和用户特征 u , 以及点击概率分数 \hat{y}'_i 后, 将三者直接拼接可得到当前新闻推荐任务的三元联合特征:

$$r = \text{concat}(u, h'_0 \cdots h'_k, \hat{y}'_0 \cdots \hat{y}'_k), \quad (4)$$

其中, $\text{concat}(\cdot)$ 为拼接函数.

不难看出, 拼接特征没有考虑 u 、 h'_i 和 \hat{y}'_i 三者之间的相互关系. 为此, 本文使用降噪自编码器 DAE (Denoising AutoEncoder) 结构^[52], 从全局角度捕捉三者之间的深层关系, 它由编码器和解码器组成, 其结构均为两层全连接层. 我们把该 DAE 作为知识提取器, 并采用 dropout 层取代随机噪声, 来获取具有鲁棒性的特征表示, 即联合分布知识特征. 首先, 拼接得到特征 r 之后, 经过一层 dropout 层引入噪声:

$$\tilde{h} = \text{dropout}(r) \quad (5)$$

\tilde{h} 输入编码器进行压缩得到隐层特征 z :

$$\tilde{h}_1 = \sigma(W_1 \tilde{h} + b_1) \quad (6)$$

$$z = \sigma(W_2 \tilde{h}_1 + b_2) \quad (7)$$

z 输入到解码器进行重构, 可得:

$$z_1 = \sigma(W_3 z + b_3) \quad (8)$$

$$g = \sigma(W_4 z_1 + b_4) \quad (9)$$

其中, σ 为 ReLU (Rectified Linear Unit) 非线性激活函数, $W_1 \sim W_4$ 为每个全连接层中可学习的模型参数, $b_1 \sim b_4$ 为每个全连接层中可学习的偏置项. 在此基础上, 通过均方差损失函数计算输入 r 和重构特征 g 之间的重构损失:

$$\mathcal{L}_{\text{rec}} = \frac{1}{l} \sum_{i=1}^l (r[i] - g[i])^2 \quad (10)$$

其中, r 和 g 的维度都为 l . 最后, 我们选取包含深层信息的隐层特征 z 作为联合分布知识特征.

4.1.2 最小化分布差异

对于在 t 时刻用于训练新任务模型的每一最小批数据 (规模为 b), 可以通过 4.1.1 小节中的知识提取器获取它的特征集合 Z^t , 数据的联合分布信息被封装在集合中; 而原始网络 (即 $t-1$ 时刻的旧任务模型) 在该最小批数据上对应的特征集合 Z^{t-1} , 其中蕴含着从过往任务学习的联合分布知识. 通常, 采用最小化新、旧任务联合分布间的差异, 可以让适应了新任务的模型很好地拟合旧任务^[53]. 鉴于此, 本文基于最优传输理论^[11], 获得新、旧任务分布间的最

优映射路径. 特别地, 最优传输充分考虑了分布内的结构信息, 并鼓励分布 $\mu(Z^t)$ 整体移动至另一个分布 $\nu(Z^{t-1})$, 最终能够从所有映射路径中获得代价最小的路径, 即 Wasserstein 距离.

具体来说, 我们首先基于特征集合来表示对应的分布:

$$\mu(Z^t) = \sum_{i=1}^b \alpha_i \delta_{z_i^t}, \quad Z^t = \{z_i^t\}_{i=1}^b \quad (11)$$

$$\nu(Z^{t-1}) = \sum_{j=1}^b \beta_j \delta_{z_j^{t-1}}, \quad Z^{t-1} = \{z_j^{t-1}\}_{j=1}^b \quad (12)$$

其中, δ_o 表示以 o 为中心的狄拉克函数, α_i 和 β_j 为权重系数, 并且使得 $\sum_{i=1}^b \alpha_i = 1$ 和 $\sum_{j=1}^b \beta_j = 1$. 在此基础上, 最优传输问题可以定义为

$$\begin{aligned} \mathcal{Q}(\mu, \nu) &= \min \langle C, P \rangle = \min \sum_{ij} C_{ij} P_{ij} \\ \text{s.t. } P \mathbf{A} &= \mu, P \mathbf{A}^\top = \nu \end{aligned} \quad (13)$$

其中, P 为一个质点从一个分布移动到另一个分布所需代价的耦合矩阵, C 为距离矩阵, $C_{i,j} = \text{cost}(z_i^t, z_j^{t-1})$ 表示从分布 μ 的第 i 个点移动到分布 ν 的第 j 个点所需的代价, $\text{cost}(\cdot)$ 为度量两个特征向量相似度的代价函数, 该代价可以使用不同距离进行衡量, 如余弦距离, \mathbf{A} 为单位列向量.

为了降低求解成本, 并与现有深度学习框架兼容, 本文采用轻量级实现 Sinkhorn 距离^[54], 通过在公式 (13) 中增加耦合矩阵熵正则化项, 使原问题由 Sinkhorn 算法^[55] 求取近似解, 得到最小化新、旧任务之间的联合分布差异损失函数 \mathcal{L}_{KF} :

$$\mathcal{L}_{\text{KF}} = \mathcal{Q}(\mu, \nu) - \epsilon \mathcal{H}(P) \quad (14)$$

$$\mathcal{H}(P) = - \sum_{i,j} P_{ij} (\log(P_{ij}) - 1) \quad (15)$$

其中, \mathcal{H} 为耦合矩阵 P 的熵, ϵ 为权重参数.

由记忆遗忘规律^[56] 可知, 遗忘在学习完成后立即开始, 而且先快后慢, 因此在增量学习过程中, 知识融合策略需要按照既定的记忆周期反复回顾旧知识, 当模型通过反复训练使得短时记忆转换为长时记忆, 即模型已牢记旧任务的知识时, 其对于旧知识的依赖程度就已降低了.

因此, 与文献[57]类似, 本文在知识融合过程中采用动态权重 ϕ_ζ :

$$\phi_\zeta = \frac{\exp(-\gamma \cdot \zeta)}{\exp(-\gamma \cdot \zeta) + 1} \quad (16)$$

其中, γ 用于控制权重下降的程度, ζ 为训练批次. 不难看出, 权重 ϕ_ζ 永远不会衰减至 0, 即表示对知识的遗忘不可避免.

4.2 知识回放

传统基于回放的方法通过将保存的旧任务样本用于新任务的模型训练,来缓解增量学习中的灾难性遗忘,但同时也带来了数据隐私泄露问题.为此,OT-KR方法以每个旧任务得到的新闻推荐模型 \mathcal{F} 作为知识进行直接回放,并引入内存缓冲区 M 用于存储每个旧任务得到的模型 \mathcal{F} .出于存储效率考虑,假设 M 最多可以存储 m 个模型,我们基于队列的特性对 M 中的模型进行管理,维护当前推荐任务的前 m 个旧任务所得到的 m 个模型.当 M 已满,则删除队首模型为后面的模型进队提供空间.同时,在知识回放策略的基础上,本文借鉴了多教师知识蒸馏思想^[12-15],整合多个分布作为教师指导新闻推荐模型训练来进一步缓解灾难性遗忘.

具体地,内存缓冲区 M 的模型队列需要依次通过知识提取器重构出新闻推荐任务的联合分布知识特征 \mathbf{z} ,并由公式(14)分别计算出各自的联合分布差异损失 \mathcal{L}_{KF}^i , $i \in \{1, \dots, m\}$.这 m 个损失进而通过平均得到教师模型的总体损失:

$$\mathcal{L}_{MT} = \frac{1}{m} \sum_{i=1}^m \mathcal{L}_{KF}^i. \quad (17)$$

简单的平均不利于学生模型对于早期学习知识的记忆.为此,根据知识学习时间长短来制定教师模型指导的权重,使得越早学习过的记忆能得到更多的回顾,即模型进队越早,其对应的损失的权重越大.基于每个模型在队列的索引 q_i 计算其权重,并整合多个教师的指导,从而, \mathcal{L}_{MT} 可修改为

$$\lambda_i = \frac{\exp(q_i)}{\sum_{j=1}^m \exp(q_j)} \quad (18)$$

$$\mathcal{L}_{MT} = \sum_{i=1}^m \lambda_i \phi_\zeta \mathcal{L}_{KF}^i \quad (19)$$

此外,为了进一步提升多教师模型指导的健壮性,本文增加教师模型的集成进行额外指导.在多个教师模型通过知识提取器获取联合分布知识特征后,不直接计算损失函数,而是先通过平均权重进行融合,得到教师集成的分布知识特征:

$$\mathbf{z}_f = \frac{1}{m} \sum_{i=1}^m \mathbf{z}_i \quad (20)$$

教师模型的集成同样看作一个教师模型,蕴含着从多个旧任务学习到的联合分布知识 \mathbf{z}_f .通过 \mathbf{z}_f 同样可以通过公式(12)得到旧任务分布 ν ,并基于最优传输理论计算公式(14)得到由教师模型的集成指导学生模型训练的额外的联合分

布差异损失 \mathcal{L}_{EN} .从而,知识回放的损失函数可表示为

$$\mathcal{L}_{KR} = \mathcal{L}_{MT} + \phi \phi_\zeta \mathcal{L}_{EN} \quad (21)$$

其中, ϕ 为模型集成损失对应的权重.最终我们可以获得整个训练过程的损失函数为

$$\mathcal{L} = \mathcal{L}_{CE} + \mathcal{L}_{Rec} + \mathcal{L}_{KR} \quad (22)$$

下面,我们给出OT-KR方法在 t 时刻模型增量学习伪代码(如算法1所示)及其时间、空间复杂度分析.由于 $t=1$ 对应初始新闻推荐模型的训练优化,不涉及增量学习过程,所以此处令 $t > 1$.

算法1. OT-KR方法

输入: t 时刻新闻推荐任务数据集 \mathcal{D}_t ;最小批规模 b ;

训练周期 \mathcal{T} 内存队列 M^{t-1} .

输出:包含新闻推荐模型 \mathcal{F}_t 的新内存队列 M^t .

BEGIN

1. $\mathcal{F}_t \leftarrow \mathcal{F}_{t-1} \in M^{t-1}$;
2. FOR $j=1=\mathcal{T}$ DO
3. FOR $(V, X, Y) \in \mathcal{D}_t$ DO
 - /* V 为用户新闻点击历史, X 为 $k+1$ 条候选新闻,
 Y 为候选新闻的真实标签*/
 - 4. 基于 X 产生候选新闻特征 \mathbf{h}_i , $i \in \{0, \dots, k\}$;
 - 5. 基于 V 产生用户特征 \mathbf{u} ;
 - 6. 基于根据公式(1)-(3)计算 \mathcal{L}_{CE} ;
 - 7. 根据公式(4)-(9)产生联合分布知识特征 \mathbf{z} ;
 - 8. 根据公式(10)计算 \mathcal{L}_{Rec} ;
 - 9. FOR $\varpi=1=m^{t-1}$ DO
 - /* m^{t-1} 为内存队列 M^{t-1} 的当前长度;*/
 - 10. 从 M^{t-1} 中取出 \mathcal{F}_ϖ 根据公式(4)-(9)产生 \mathbf{z}_ϖ ;
 - 11. 基于 \mathbf{z} 和 \mathbf{z}_ϖ 根据公式(11)-(14)计算 \mathcal{L}_{KF}^ϖ ;
 - 12. END FOR
 - 13. 根据公式(18)-(19)计算 \mathcal{L}_{MT} ;
 - 14. 根据公式(20)产生模型集成的 \mathbf{z}_f ;
 - 15. 基于 \mathbf{z} 和 \mathbf{z}_f 根据公式(11)-(14)计算 \mathcal{L}_{EN} ;
 - 16. 根据公式(21)-(22)计算 \mathcal{L} ;
 - 17. 使用优化器ADAM^[58]得到更新后的 \mathcal{F}_t ;
 - 18. END FOR
 - 19. END FOR
 - 20. IF $m^{t-1} < m$ THEN /* m 为内存队列的最大容量*/
 - 21. \mathcal{F}_t 进入内存队列 M^{t-1} ;
 - 22. ELSE
 - 23. M^{t-1} 队首模型出队;
 - 24. \mathcal{F}_t 进入内存队列 M^{t-1} ;
 - 25. END IF
 - 26. $M^t \leftarrow M^{t-1}$;
 - 27. 返回新内存队列 M^t ;
- END

为了便于描述,记 $h = |\mathcal{D}_t|$,并把用户点击新闻

历史的数量记为 c . 在算法 1 中, 步骤 4-8 的时间开销为 $O(\mathcal{T}dh/k)$, 其中, d 为词嵌入向量的维度, k 为负采样的数量; 步骤 10-11 的最大时间开销为 $O(m\mathcal{T}sh/k)$, 其中 s 为 Sinkhorn 距离^[54] 的最大迭代次数, m 为内存队列的最大容量; 另外, 步骤 13-17 的时间开销为 $O(\mathcal{T}sh/k)$. 因此, OT-KR 方法在数据流中单个任务的时间复杂度为: $O(\mathcal{T}((m+1)s+cd)h/k)$.

在算法 1 中, 步骤 4-6 的空间开销为 $O(cdh)$; 步骤 7-8 的空间开销为 $O(lh)$, 其中 l 为联合分布知识特征 z 的维度; 步骤 10-11 的最大空间开销为 $O(mlh)$; 另外, 步骤 14-15 所对应的空间开销为 $O(lh)$. 因此, OT-KR 方法在数据流中单个任务的空间复杂度为: $O(((m+2)l+cd)h)$.

在得到经过更新的内存队列 \mathcal{M} 后, 取其队尾模型 \mathcal{F}_i 为用户提供新闻推荐服务. 给定当前用户 u_{cur} 的新闻点击历史 V_{cur} 和待推荐新闻集合 \mathcal{X}_{cur} , \mathcal{F}_i 将 u_{cur} 的特征 \mathbf{u}_{cur} 与 \mathcal{X}_{cur} 中的每个新闻 x_i 的特征 \mathbf{h}_i' 作为输入, 通过公式 (1) 计算 u_{cur} 点击 x_i 的概率分数 \hat{y}'_{cur} . 在此基础上, 选取概率分数最高的 N 项新闻作为被推荐的候选项.

5 实验评估

5.1 数据集

实验使用主流的公开数据集 MIND^[59]. 该数据集收集了用户在 6 周内的用户行为日志, 每个日志记录用户点击事件、未点击事件和用户在该日志前的历史点击新闻. 它里面的每篇新闻都包含丰富的文本内容, 包括标题、摘要、正文、类别等. 与现有工作^[22-29]一致, 我们使用 MIND 数据集的两个版本: MIND_large 和 MIND_small. 表 1 给出数据集的统计信息.

表 1 数据集的统计信息

统计数据	MIND_small	MIND_large
新闻数量	93 698	161 013
用户数量	50 000	1 000 000
记录数量	230 117	24 155 470

对于 MIND 数据集, 为了模拟数据分布不断发生变化的新闻推荐场景, 本文对数据集进行了预处理, 即根据用户行为日志中的日期, 将两个版本数据

集以天为单位进行划分, 分别得到 2019 年 11 月 9 日至 2019 年 11 月 15 号, 共 7 天的用户行为日志, 使用 7 个更新周期在数据流上增量训练新闻推荐模型, 共 7 个任务. 为了简单, 经过预处理后的数据流仍然命名为 MIND_small 和 MIND_large. 出于训练效率考虑, 我们进一步从 MIND_small 数据流的每个任务中随机抽取 10K 条数据构成数据集, 其中 80% 作为训练集, 剩下的 20% 作为测试集. 对于 MIND_large 数据流, 每个任务抽取 30K 条数据构成数据集, 其中 80% 作为训练集, 剩下 20% 作为测试集.

5.2 比较方法

本文将 OT-KR 方法与如下主流的增量学习方法进行比较:

LWF^[9]: 首次基于知识蒸馏来解决任务增量学习问题, 进而被文献^[10]应用于类增量学习, 本文用它来实施域增量学习.

oEWC^[41]: EWC 在贝叶斯框架中引入网络参数的不确定性, 通过 FIM (Fisher Information Matrix) 近似估计参数重要性, 但 FIM 计算十分耗时且正则化项随着任务数量增加不断增加, oEWC 在其基础上改进, 只需一个正则项.

SI^[42]: 度量单个突触的重要性惩罚模型参数的变化, 使得重要参数保持相对良好的权重.

RWALK^[43]: 以 KL 散度为基础对 EWC 和 PI (Path Integral) 进行修改和结合.

IGCN^[30]: 通过时间感知特征融合模块用于捕获用户和物品特征随时间变化的模式.

FIRE^[32]: 设计基于增量和时间感知的滤波器 (Temporal Information Filter) 捕捉用户偏好随时间漂移的动态变化.

LCE^[33]: 假设一种节点类型 (例如用户) 比其他节点类型 (例如新闻) 更适合静态表示, 本文选择用户保持静态表示.

Dropout^[60]: 将 dropout 作为隐式门机制, 保证神经网络的可塑性和稳定性, 本文在新闻编码器和用户编码器中都增加了 dropout 层.

AGEM^[50]: 通过使用随机样本的平均梯度得到不等式约束修正新任务梯度下降方向的方法, 解决 GEM^[49] 中使用所有旧任务的回放样本计算梯度导致训练时间过长的的问题.

FDR^[45]: 通过存储过往任务的范例样本和网络输出来对齐旧任务和新任务之间的输出.

ER^[37]: 基于经验重放的增量学习方法, 采用 RS (Reservoir Sampling) 采样方法, 训练过程将旧任务

样本和当前任务样本混合。

DER^[46]:在ER的基础上进行改进,基于暗知识(Dark Knowledge)提取过往经验,在整个优化过程中进行匹配。

Inverse_Degree^[31]:基于经验重放的增量学习方法,通过基于用户交互数量(图节点的度数)采样方法取代均匀采样。

SNCL^[47]:在ER的基础上进行改进,在内存缓冲区存储过往任务的样本、标签以及中间层特征,并且在整个优化过程中进行匹配。

CLS_ER^[48]:基于CLS理论的双重记忆经验回放方法,同时维护两个模型建立长期和短期的语义记忆,模拟信息适应的快速和缓慢。

Finetune:微调方法,在每个增量步骤只使用新数据微调通过过往任务训练得到的新闻推荐模型而不使用任何缓解灾难性遗忘的策略,一般作为增量学习方法性能的下界。

Joint:全量更新方法,在每个增量步骤中使用到目前为止的所有数据从头开始训练新闻推荐模型,一般作为增量学习方法性能的上界。

上述对比方法中,前8个方法为基于正则化的增量学习方法,第9-15个方法为基于回放的增量学习方法。为了验证本文OT-KR方法的有效性,我们选取三个主流新闻推荐模型,即NAML^[22]、NPA^[23]和NRMS^[24]作为基础模型,应用上述的增量学习方法分别进行实验。

5.3 评估指标与超参设置

本文实验环境为:Python 3.7.13、PyTorch1.11.0、GeForce RTX2080Ti GPU,并采用4个常用的新闻推荐评估指标:AUC(Area Under the Curve)、MRR(Mean Reciprocal Rank)、NDCG@5(Normalized Discounted Cumulative Gain)和NDCG@10。

本文方法的超参设置如下:(1)使用基于最小批的ADAM优化器^[58]优化模型参数,新闻推荐模型NPA^[23]和NAML^[22]使用的最小批大小为100,而NRMS^[24]使用的最小批大小为64;(2)基于回放的方法在MIND_small和MIND_large数据集回放的样本分别为2000和3000;(3)学习率在{0.01, 0.001, 0.0001}之间调整;(4)内存缓冲区M存储模型的数量m在{2, 3, 4, 5, 6}之间调整;(5)与现有工作^[22-24]一致,负采样技术采样样本数量k设置为4;(6)公式(14)中的权重参数 ϵ 设置为0.1;(7)算法1中的最大迭代次数 q 设置为100;(8)公式(16)中控

制权重下降的程度参数 γ 设置为1;(9)公式(22)中模型集成损失对应的权重 ϕ 设置为0.7。

5.4 与现有方法的性能对比

为了检验OT-KR方法的推荐性能,本小节将它与目前主流的增量学习方法(见5.2小节)进行比较。此处实验采用NPA^[23]作为新闻推荐模型。为了便于观察各类方法缓解灾难性遗忘的能力,表2给出了所有方法在7个任务上的平均推荐性能以及本文方法基于目前增量方法的最优性能提高百分比(%imprv),从中可以看出:

(1)新闻推荐模型增量学习的性能上界方法Joint明显优于下界方法Finetune,但之间差异没有非常巨大。例如,在MIND_small数据集上,Joint和Finetune方法的AUC指标差异为5.16%,而在MIND_large数据集上的差异为4.37%。这主要是因为新闻推荐任务流的数据分布变化过程较为缓慢,因此Finetune方法对新任务进行微调时,新闻推荐模型在旧任务的性能不会剧烈下降。

(2)基于正则化的方法在Finetune方法的基础上提升较小,这表明,一般的正则化手段不能够有效缓解灾难性遗忘问题。其中,LWF方法可视为Finetune方法和知识蒸馏的结合,希望在训练数据上保留旧任务的输出,但仅通过样本在新任务中学习到的特征和旧模型的对应特征之间对齐,虽然计算效率较高,但防止遗忘的效果不明显。oEWC、SI以及RWALK等方法试图通过结构正则化来克服固定容量模型的遗忘,通过估计任务参数的重要性惩罚学习新任务时的较大偏差来保留旧任务中使用的重要权重参数。过往知识被保存在冻结的核心空间中,而剩余的知识在学习下一个任务时被更新,但当模型权重到了任务流后期,可以更新的权重就会越来越少,变得不再可信。此外,Dropout方法通过隐式的门机制控制记忆以获取稳定模型,虽然在一定程度上它牺牲了可塑性,但从表2可以看出,在MIND_small和MIND_large数据集上基本都能达到基于正则化方法中的最优性能。

(3)与基于正则化的方法相比,基于回放的方法通过重放存储在内存缓冲区中的数据样本来解决灾难性遗忘问题,在数据分布不断变化的新闻推荐场景下表现出更好的性能。其中,DER方法认为软目标比硬目标携带了更有价值的信息,并通过软目标在数据流中保持相似性结构,相比Finetune方法,其

各个指标在 MIND_small 数据集上分别提升了 2.48%、2.18%、1.77% 和 2.14%，而在 MIND_large 数据集上分别提升了 1.94%、1.9%、1.71% 和 1.76%。与 DER 方法中的局部信息相比，CLS_ER 在持续学习任务的同时通过积累编码在相应权重中

的知识，形成长期语义记忆和短期语义记忆，为新任务的学习提供了任务间的关系信息，有效保持序列间的相似性结构，性能得到了进一步提升。此外，可以看出，梯度和回放相结合的方法 AGEM 对于新闻推荐任务的增量学习效果不佳。

表2 本文 OT-KR 方法与现有 12 个主流增量学习方法的推荐性能 (NPA 作为新闻推荐模型架构)

方法	MIND_small				MIND_large			
	AUC	NDCG@5	NDCG@10	MRR	AUC	NDCG@5	NDCG@10	MRR
Finetune	0.6674	0.3569	0.4142	0.3274	0.6904	0.3791	0.4359	0.3466
Joint	0.7190	0.4003	0.4569	0.3666	0.7341	0.4200	0.4757	0.3831
LWF	0.6751	0.3621	0.4195	0.3331	0.6960	0.3825	0.4398	0.3504
oEWC	0.6735	0.3598	0.4180	0.3322	0.6958	0.3822	0.4392	0.3499
SI	0.6732	0.3614	0.4188	0.3349	0.6966	0.3839	0.4408	0.3507
RWALK	0.6769	0.3595	0.4182	0.3317	0.6952	0.3824	0.4385	0.3493
Dropout	0.6799	0.3620	0.4198	0.3341	0.6999	0.3876	0.4439	0.3547
IGCN	0.6752	0.3596	0.4178	0.3321	0.6902	0.3700	0.4357	0.3473
FIRE	0.6747	0.3557	0.4132	0.3286	0.6953	0.3812	0.4390	0.3489
LCE	0.6771	0.3625	0.4210	0.3346	0.6948	0.3784	0.4357	0.3465
AGEM	0.6831	0.3680	0.4239	0.3383	0.7010	0.3891	0.4461	0.3565
FDR	0.6864	0.3757	0.4310	0.3464	0.7038	0.3948	0.4495	0.3622
ER	0.6844	0.3705	0.4272	0.3431	0.7020	0.3903	0.4460	0.3581
DER	0.6922	0.3787	0.4319	0.3488	0.7098	0.3981	0.4530	0.3642
Inverse_Degree	0.6833	0.3705	0.4283	0.3429	0.7066	0.3922	0.4505	0.3613
SNCL	0.6899	0.3772	0.4325	0.3470	0.7003	0.3937	0.4493	0.3617
CLS_ER	0.6930	0.3748	0.4320	0.3460	0.7117	0.3966	0.4532	0.3640
OT-KR	0.7008	0.3829	0.4413	0.3530	0.7153	0.4004	0.4570	0.3648
%imprv	(0.78%)	(0.42%)	(0.93%)	(0.42%)	(0.36%)	(0.23%)	(0.38%)	(0.06%)

(4) 基于图神经网络的增量推荐方法 IGCN、FIRE、LCE 和 Inverse_Degree 表现较差。这主要是因为基于图神经网络的增量推荐方法仅仅从图的角度来考虑推荐系统的增量问题，即从子图上不断加入新的子节点后如何可以实现持续学习，并没有考虑到新闻推荐任务输入流的非平稳分布引发的域漂移问题。其中，Inverse_Degree 属于典型的基于回放的方法，因此在这四个方法中性能最佳。

(5) 本文 OT-KR 方法的推荐性能在所有评估指标上均优于目前主流的增量学习方法。例如，在 MIND_small 数据集上，OT-KR 方法的 4 个指标比目前最好增量方法分别提升了 0.78%、0.42%、0.93% 以及 0.42%。这主要是因为：① OT-KR 方法从全局角度考虑旧知识的巩固，通过最小化新、旧任务之间的域差异实现联合分布知识的融合，从而有效地解决了域漂移问题，而不仅仅考虑局部信息的正则化；② OT-KR 方法利用知识回放策略来取

代传统的样本回放策略，从而能够回顾从任务流上依次学习到的完整知识，虽然内存需求稍微有所增加，但在数据隐私保护的同时也能够进一步有效缓解了灾难性遗忘问题。

5.5 消融实验

本小节通过消融实验，对 OT-KR 方法各主要组件的有效性进行检验。实验包含 3 种 OT-KR 方法的变种模型：

M1: 仅使用知识融合策略；

M2: 在 M1 基础上使用知识回放策略；

M3: 在 M2 基础上进一步使用模型集成。

表 3 给出了 3 种变种的推荐性能。从中可以看出，尽管 M1 从全局角度考虑旧知识的巩固，性能优于大部分主流增量学习方法，但由于没有使用知识回放策略，仅限于相邻任务的知识融合，到了任务流后期旧任务的知识难免会发生遗忘。对比表 2 可知，M1 在 MIND_small 上的 NDCG@5 和 MRR 指标低于 DER 方法 0.19% 和 0.42%。而

M2增加知识回放策略从内存缓冲区获取过往任务的多个信息流,即使到了任务流后期,也能保证大部分的旧知识不被遗忘,所有4个评估指标均超过主流增量学习方法.此外,M3在M2的基础上引入模型集成,新闻推荐性能得到进一步提

升,在MIND_small数据集和MIND_large数据集上,4个指标分别提升了0.21%、0.19%、0.31%和0.3%,以及0.09%、0.18%、0.14%和0.2%.因此,OT-KR方法的各个组件均有利于提高推荐性能.

表3 OT-KR方法变种方法的推荐性能

方法	MIND_small				MIND_large			
	AUC	NDCG@5	NDCG@10	MRR	AUC	NDCG@5	NDCG@10	MRR
M1	0.6960	0.3768	0.4332	0.3446	0.7135	0.3981	0.4541	0.3622
M2	0.6987	0.3810	0.4382	0.3500	0.7150	0.3989	0.4555	0.3636
M3	0.7008	0.3829	0.4413	0.3530	0.7153	0.4004	0.4570	0.3648

表4 本文OT-KR方法与现有12个主流增量学习方法的推荐性能(NRMS和NAML作为新闻推荐模型架构)

方法	NRMS				NAML			
	AUC	NDCG@5	NDCG@10	MRR	AUC	NDCG@5	NDCG@10	MRR
Finetune	0.6704	0.3554	0.4139	0.3287	0.6755	0.3617	0.4189	0.3336
Joint	0.7112	0.3955	0.4515	0.3630	0.7270	0.4100	0.4668	0.3753
LWF	0.6723	0.3572	0.4147	0.3295	0.6829	0.3669	0.4248	0.3379
oEWC	0.6761	0.3599	0.4185	0.3311	0.6766	0.3616	0.4193	0.3320
SI	0.6718	0.3571	0.4152	0.3293	0.6784	0.3615	0.4207	0.3334
RWALK	0.6798	0.3631	0.4203	0.3364	0.693	0.376	0.4340	0.3460
IGCN	0.6713	0.3554	0.4150	0.3290	0.6782	0.3631	0.4209	0.3333
FIRE	0.6715	0.3568	0.4147	0.3295	0.6885	0.3683	0.4263	0.3398
LCE	0.6701	0.3537	0.4124	0.3270	0.6776	0.3612	0.4196	0.3335
Dropout	0.6733	0.3583	0.4161	0.3312	0.6811	0.3658	0.4247	0.3370
AGEM	0.6837	0.3696	0.4271	0.3429	0.6895	0.3725	0.4296	0.3427
FDR	0.6859	0.3749	0.4307	0.3462	0.6961	0.3819	0.4372	0.3512
ER	0.6765	0.3587	0.4161	0.3329	0.6934	0.3759	0.4331	0.3480
DER	0.6854	0.3697	0.4264	0.3424	0.7010	0.3830	0.4400	0.3520
Inverse_Degree	0.6840	0.3699	0.4282	0.3431	0.6862	0.3706	0.4293	0.3438
SNCL	0.6896	0.3756	0.4326	0.3478	0.6934	0.3818	0.4368	0.3519
CLS_ER	0.6872	0.3688	0.4266	0.3430	0.7032	0.3833	0.4394	0.3527
OT-KR	0.6943	0.3760	0.4333	0.3463	0.7065	0.3846	0.4429	0.3529
%imprv	(0.71%)	(0.11%)	(0.26%)	(0.01%)	(0.33%)	(0.13)	(0.29)	(0.02%)

5.6 基于其它主流新闻推荐模型的对比实验

为了进一步检验OT-KR方法在新闻推荐模型增量学习上的有效性,本小节选取另外两个主流的新闻推荐模型NRMS^[24]和NAML^[22],并在数据集MIND_small上进行了推荐性能对比实验.特别地,这两个模型均采用“两段式”方法^[51].

其中,NAML模型基于多视角学习来解决新闻信息的多样性问题,其新闻编码器分别从新闻的标题、正文、类别和子类别中学习新闻表示,从不同的视角来获取新闻信息.NRMS模型则是通过多头自注意力网络分别捕捉单词与单词、新闻与新闻之间的相关性,弥补了CNN无法捕捉长距离的单词交互

的不足.表4给出了所有增量学习方法在7个任务上的平均推荐性能以及本文方法基于目前增量方法的最优性能提高百分比(%imprv),从中可以看出,以NRMS和NAML为新闻推荐模型架构时,各增量学习方法的推荐性能趋势基本与表2保持一致,基于回放的方法普遍比基于正则化的方法性能更优,同时,本文OT-KR方法在全部4个评估指标上仍达到了最优性能.

5.7 训练时间对比

本小节通过实验对比不同新闻推荐模型增量学习方法的训练效率.实验以最后一个任务结束时的挂钟时间(秒)来评估OT-KR方法三个变体

M1~M3以及主流增量学习方法的训练效率. 为了保证公平的比较, 实验在相同的条件下进行, 图4给出了在 MIND_small 和 MIND_large 数据集上所有增量方法与上界 Joint 方法的训练时间对比, 其中纵坐标表示方法名, 横坐标表示每个方法与上界 Joint 方法的训练时间比值. 从中可以得出如下结论:

(1) 相比上界 Joint 方法所需要的训练时间, 下界 Finetune 方法仅基于当前新闻推荐任务的数据进行训练, 训练速度最快, 基于正则化的方法在其基础上需要消耗更多时间, 但仍然相对较快 (除 FIRE 外).

(2) 基于回放的方法虽在缓解灾难性遗忘方面有所提升, 但训练时间也相应增加, 这主要是因为基于回放的方法通过回放旧任务的样本增加了每个更新周期处理样本的总数量, 其中 CLS_ER 方法的训练时间最长, 已接近上界 Joint 方法需要的训练时间.

(3) 本文方法的变种 M1 能够以基于正则化的方法的训练效率达到接近目前最佳的基于回放的方法的性能. 然而, 若要想在所有指标上都达到最佳性能, 需要使用本文方法的变种 M2 或变种 M3, 相应也带来更多的时间开销.

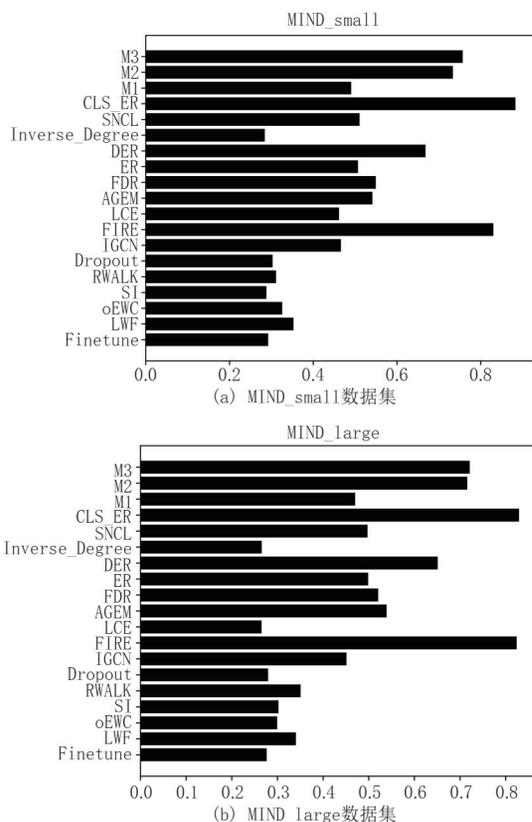


图4 不同增量学习方法训练时间对比

5.8 超参数性能影响

本小节探索 OT-KR 方法变种 M2 中的重要超参数对于新闻推荐性能的影响, 即知识回放策略中使用的内存缓冲区 M 中暂存模型数量 m 对于训练效率和模型推荐性能的影响, 设置 $m \in \{2, 3, 4, 5, 6\}$, 其他超参数的取值与 5.3 小节一致. 图 5 分别给出相同指标在不同数据集上的性能比较.

由图 5 可以看出, 逐渐增大内存缓冲区 M 的容量 m 并不能持续带来更好的推荐性能. 例如, 对于

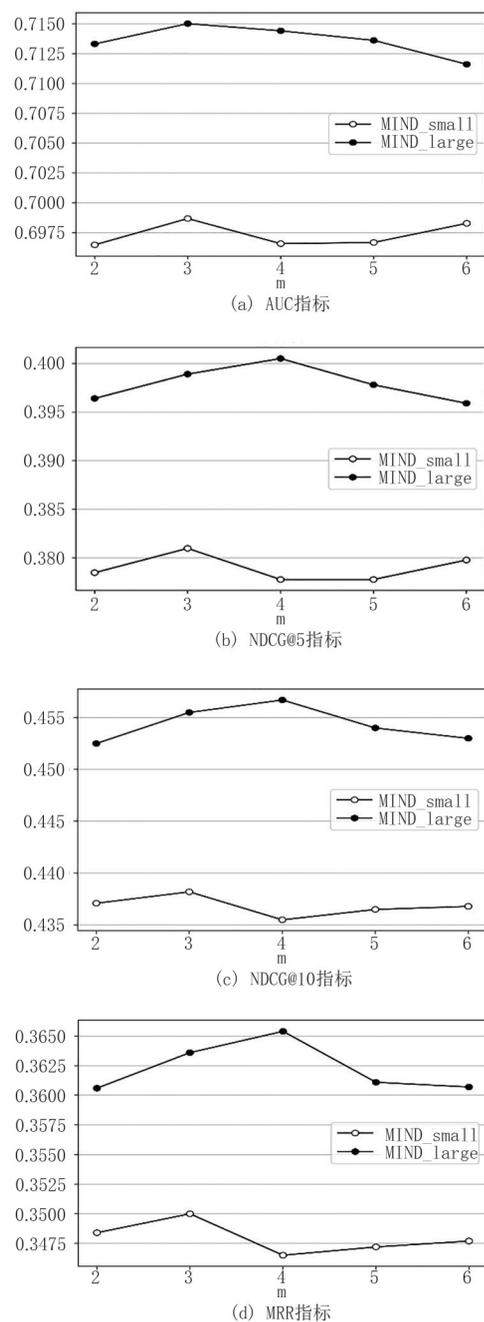


图5 超参数 m 对新闻推荐性能的影响

MIND_small数据集,随着 m 取值的增大,推荐性能将逐渐上升.当 m 增大至3时,新闻推荐模型在4个指标都能取到最大值,可见推荐性能已经达到最优.随后, m 继续增大至6时,新闻推荐性能反而下降.对于MIND_large数据集,当 m 增大至4时,新闻推荐模型在NDCG@5、NDCG@10和MRR指标上取得最大值,综合推荐性能将达到最优.因此,我们能够得出,当 m 从1开始不断增大时,OT-KR方法可以从过往任务中整合更多的信息流,从而能够更为充分地从过往任务中学习全局分布知识.然而,当 m 达到3(MIND_small数据集)或4(MIND_large数据集)后,随着 m 继续增大,整合太多的信息流会为新闻推荐任务的增量训练带来额外的噪声,反而导致推荐性能的下降.因此,保留所有旧任务的模型(m 取最大值)并不能带来最优的推荐性能.

在此基础上,我们进一步实验并计算了M2变种采用不同 m 值时与上界Joint方法训练时间的比例,如图6所示.从中可以看出,训练时间与 m 的取值成正比, m 增大不仅会带来更多的训练时间开销,而且内存压力也会加剧.因此,综合新闻推荐模型的性能与训练效率来看,MIND_small数据集上的最优 m 值为3,而MIND_large数据集上的最优 m 值为4.

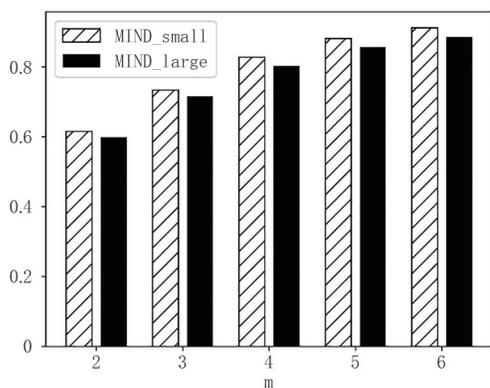


图6 不同 m 值对训练效率的影响

6 总结与将来工作

本文将域增量学习引入到新闻推荐任务中,提出一种基于最优传输和知识回放的增量学习方法OT-KR,来有效平衡推荐性能和训练效率.OT-KR方法基于最优传输理论评估和捕捉任务序列间的域差异变化,在训练过程中基于全局知识实现知识融

合.在此基础上,OT-KR方法通过知识回放来替换传统的样本回放策略,避免数据隐私泄露的同时能够有效缓解灾难性遗忘.在主流的公开数据集上进行多组实验,实验结果表明OT-KR方法具有有效性和实用性.

本文将来的工作主要包括两个方面:

(1)由于OT-KR方法的变种M3虽然可以达到最佳性能,但仍然需要一些额外的训练时间开销,因此,我们将考虑改进最优传输的求解算法来得到更为轻量级的解决方案;

(2)鉴于通过知识提取器可以在低维空间重构出当前任务的全局知识,我们将考虑改善知识提取器的网络结构来深入挖掘用户特征、候选新闻特征和点击概率分数三者之间的相互关系,从而能够进一步提高推荐性能.

参 考 文 献

- [1] De Francisci Morales G, Gionis A, Lucchese C. From chatter to headlines: Harnessing the real-time web for personalized news recommendation//Proceedings of the 15th ACM International Conference on Web Search and Data Mining. Seattle, USA, 2012: 153-162
- [2] Zhang Y J, Dong Z, Meng X W. Research on personalized advertising recommendation systems and their applications. Chinese Journal of Computers, 2021, 44 (3): 531-563 (in Chinese)
(张玉洁,董政,孟祥武.个性化广告推荐系统及其应用研究.计算机学报,2021,44(3):531-563)
- [3] Zhuang H, Weng Z, Xie R, et al. ACIL: Analytic class-incremental learning with absolute memorization and privacy protection. arXiv preprint, arXiv:2205.14922, 2022
- [4] Dong J, Wang L, Fang Z, et al. Federated class-incremental learning// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA, 2022: 10164-10173
- [5] Mai Z, Li R, Jeong J, et al. Online continual learning in image classification: an empirical survey. Neurocomputing, 2022, 469: 28-51
- [6] Biesialska M, Biesialska K, Costa-jussà M R. Continual lifelong learning in natural language processing: A survey// Proceedings of the 28th International Conference on Computational Linguistics. Barcelona, Spain, 2020: 6523-6541
- [7] Chennupati G, Rao M, Chadha G, et al. ILASR: Privacy-preserving incremental learning for automatic speech recognition at production scale//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Washington, USA, 2022: 2780-2788
- [8] Van de Ven G M, Tolias A S. Three scenarios for continual learning. arXiv preprint, arXiv:1904.07734, 2019

- [9] Li Z, Hoiem D. Learning without forgetting. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 40(12): 2935-2947
- [10] Rebuffi S A, Kolesnikov A, Sperl G, et al. iCaRL: Incremental classifier and representation learning//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA, 2017: 2001-2010
- [11] Cao J Z, Mo L Y, Du Q, Guo Y, Zhao P L, Huang J Z, Tan M K. Joint distribution matching method and applications based on optimal transport theory. *Chinese Journal of Computers*, 2021, 44(6): 1233-1245 (in Chinese)
(曹杰彰, 莫朗元, 杜卿, 国雍, 赵沛霖, 黄俊洲, 谭明奎. 基于最优传输理论的联合分布匹配方法及应用. *计算机学报*, 2021, 44(6): 1233-1245)
- [12] Wu M C, Chiu C T. Multi-teacher knowledge distillation for compressed video action recognition based on deep learning. *Journal of Systems Architecture*, 2020, 103: 101695
- [13] You S, Xu C, Xu C, Tao D. Learning from multiple teacher networks//*Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Halifax, Canada, 2017: 1285-1294
- [14] Fukuda T, Suzuki M, Kurata G, Thomas S, Cui J, Ramabhadran B. Efficient knowledge distillation from an ensemble of teachers//*Proceedings of the 18th Annual Conference of the International Speech Communication Association*. Stockholm, Sweden, 2017: 3697-3701
- [15] Huang Z H, Yang S Z, Lin W, Ni J, Sun S L, Chen Y W, Tang Y. Knowledge distillation: A survey. *Chinese Journal of Computers*, 2022, 45(3): 624-653 (in Chinese)
(黄震华, 杨顺志, 林威, 倪娟, 孙圣力, 陈运文, 汤庸. 知识蒸馏研究综述. *计算机学报*, 2022, 45(3): 624-653)
- [16] Phelan O, McCarthy K, Smyth B. Using twitter to recommend real-time topical news//*Proceedings of the 3rd ACM Conference on Recommender Systems*. New York, USA, 2009: 385-388
- [17] Li L, Chu W, Langford J, et al. A contextual-bandit approach to personalized news article recommendation//*Proceedings of the 19th International Conference on World Wide Web*. Raleigh, USA, 2010: 661-670
- [18] Liu J, Dolan P, Pedersen E R. Personalized news recommendation based on click behavior//*Proceedings of the 15th International Conference on Intelligent User Interfaces*. Hong Kong, China 2010: 31-40
- [19] Son J W, Kim A Y, Park S B. A location-based news article recommendation with explicit localized semantic analysis//*Proceedings of the 36th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Dublin, Ireland, 2013: 293-302
- [20] Huang P S, He X, Gao J, et al. Learning deep structured semantic models for web search using clickthrough data//*Proceedings of the 22nd ACM International Conference on Information & Knowledge Management*. San Francisco, USA, 2013: 2333-2338
- [21] Bansal T, Das M, Bhattacharyya C. Content driven user profiling for comment-worthy recommendations of news and blog articles//*Proceedings of the 9th ACM Conference on Recommender Systems*. Vienna, Austria, 2015: 195-202
- [22] Wu C, Wu F, An M, et al. Neural news recommendation with attentive multi-view learning//*Proceedings of the 28th International Joint Conference on Artificial Intelligence*. Macao, China, 2019: 3863-3869
- [23] Wu C, Wu F, An M, et al. NPA: Neural news recommendation with personalized attention//*Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Anchorage, USA, 2019: 2576-2584
- [24] Wu C, Wu F, Ge S, et al. Neural news recommendation with multi-head self-attention//*Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*. Hong Kong, China, 2019: 6389-6394
- [25] Wang H, Wu F, Liu Z, et al. Fine-grained interest matching for neural news recommendation//*Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*. 2020: 836-845
- [26] Qi T, Wu F, Wu C, et al. HieRec: Hierarchical user interest modeling for personalized news recommendation//*Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing*. 2021: 5446-5456
- [27] Wu C, Wu F, Qi T, et al. User modeling with click preference and reading satisfaction for news recommendation//*Proceedings of the 29th International Conference on International Joint Conference on Artificial Intelligence*. Yokohama, Japan, 2021: 3023-3029
- [28] Xie R, Ling C, Wang Y, et al. Deep feedback network for recommendation//*Proceedings of the 29th International Conference on International Joint Conferences on Artificial Intelligence*. Yokohama, Japan, 2021: 2519-2525
- [29] Wu C, Wu F, Qi T, et al. Feedrec: News feed recommendation with various user feedbacks//*Proceedings of the ACM Web Conference 2022*. 2022: 2088-2097
- [30] Xia J, Li D, Gu H, et al. Incremental graph convolutional network for collaborative filtering//*Proceedings of the 30th ACM International Conference on Information & Knowledge Management*. 2021: 2170-2179
- [31] Ahrabian K, Xu Y, Zhang Y, et al. Structure aware experience replay for incremental learning in graph-based recommender systems//*Proceedings of the 30th ACM International Conference on Information & Knowledge Management*. Virtual conference, 2021: 2832-2836
- [32] Xia J, Li D, Gu H, et al. FIRE: Fast incremental recommendation with graph signal processing//*Proceedings of the ACM Web Conference 2022*. 2022: 2360-2369
- [33] Hang M, Schnabel T, Yang L, et al. Lightweight compositional embeddings for incremental streaming recommendation. *arXiv preprint, arXiv:2202.02427*, 2022

- [34] French R M. Catastrophic forgetting in connectionist networks. *Trends in Cognitive Sciences*, 1999, 3(4): 128-135
- [35] McCloskey M, Cohen N J. Catastrophic interference in connectionist networks: The sequential learning problem. *Psychology of Learning and Motivation*. USA: Academic Press, 1989
- [36] Kirkpatrick J, Pascanu R, Rabinowitz N, et al. Overcoming catastrophic forgetting in neural networks. *Proceedings of the National Academy of Sciences of the United States of America*, 2017, 114(13): 3521
- [37] Riemer M, Cases I, Ajemian R, et al. Learning to learn without forgetting by maximizing transfer and minimizing interference. *arXiv preprint, arXiv:1810.11910*, 2018
- [38] Rusu A A, Rabinowitz N C, Desjardins G, et al. Progressive neural networks. *arXiv preprint, arXiv:1606.04671*, 2016
- [39] Hinton G, Vinyals O, Dean J. Distilling the knowledge in a neural network. *arXiv preprint arXiv:1503.02531*, 2015
- [40] Dhar P, Singh R V, Peng K C, et al. Learning without memorizing//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, USA, 2019; 5138-5146
- [41] Schwarz J, Czarnecki W, Luketina J, et al. Progress & compress: A scalable framework for continual learning//*Proceedings of the 35th International Conference on Machine Learning*. Stockholm, Sweden, 2018; 4528-4537
- [42] Zenke F, Poole B, Ganguli S. Continual learning through synaptic intelligence//*Proceedings of the 34th International Conference on Machine Learning*. Sydney, Australia, 2017; 3987-3995
- [43] Chaudhry A, Dokania P K, Ajanthan T, et al. Riemannian walk for incremental learning: Understanding forgetting and intransigence. *arXiv preprint arXiv:1801.10112*, 2018
- [44] Welling M. Herding dynamical weights to learn//*Proceedings of the 26th Annual International Conference on Machine Learning*. Montreal, Canada, 2009; 1121-1128
- [45] Benjamin A, Rolnick D, Kording K. Measuring and regularizing networks in function space. *arXiv preprint, arXiv:1805.08289*, 2018
- [46] Buzzega P, Boschini M, Porrello A, et al. Dark experience for general continual learning: A strong, simple baseline//*Proceedings of the 34th Conference on Neural Information Processing Systems*. Vancouver, Canada, 2020; 15920-15930
- [47] Yan Q, Gong D, Liu Y, et al. Learning bayesian sparse networks with full experience replay for continual learning//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, USA, 2022; 109-118
- [48] Arani E, Sarfraz F, Zonooz B. Learning fast, learning slow: A general continual learning method based on complementary learning system//*Proceedings of the International Conference on Learning Representations*. 2022; 1-22
- [49] Lopez-Paz D, Ranzato M A. Gradient episodic memory for continual learning//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach, USA, 2017; 6470-6479
- [50] Chaudhry A, Ranzato M A, Rohrbach M, et al. Efficient lifelong learning with a-gem. *arXiv preprint, arXiv:1812.00420*, 2018
- [51] Tian X, Ding Q, Liao Z, Sun G. A review of deep learning based news recommendation algorithm research. *Computer Science and Exploration*, 2021, 15(6): 971-998 (in Chinese) (田萱, 丁琪, 廖子慧, 孙国栋. 基于深度学习的新闻推荐算法研究综述. *计算机科学与探索*, 2021, 15(6): 971-998)
- [52] Vincent P, Larochelle H, Bengio Y, et al. Extracting and composing robust features with denoising autoencoders//*Proceedings of the 25th International Conference on Machine Learning*. Helsinki, Finland, 2008; 1096-1103
- [53] Long M, Wang J, Ding G, et al. Transfer feature learning with joint distribution adaptation//*Proceedings of the IEEE International Conference on Computer Vision*. Sydney, Australia, 2013; 2200-2207
- [54] Cuturi M. Sinkhorn distances: Lightspeed computation of optimal transportation distances. *arXiv preprint, arXiv:1306.0895*, 2013
- [55] Thornton J, Cuturi M. Rethinking initialization of the sinkhorn algorithm. *arXiv preprint, arXiv:2206.07630*, 2022
- [56] Trahan D E, Larrabee G J. Effect of normal aging on rate of forgetting. *Neuropsychology*, 1992, 6(2): 115
- [57] Ganin Y, Lempitsky V. Unsupervised domain adaptation by backpropagation//*Proceedings of the 32nd International Conference on Machine Learning*. Lille, France, 2015; 1180-1189
- [58] Zohrevand A, Imani Z. An empirical study of the performance of different optimizers in the deep neural networks//*Proceedings of the 2022 International Conference on Machine Vision and Image Processing*. Ahvaz, Iran, 2022; 1-5
- [59] Wu F, Qiao Y, Chen J H, et al. Mind: A large-scale dataset for news recommendation//*Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*. 2020; 3597-3606
- [60] Mirzadeh S I, Farajtabar M, Ghasemzadeh H. Dropout as an implicit gating mechanism for continual learning//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2020; 232-233



LIN Wei, M. S. candidate. His research interests include recommender system and incremental learning.

HUANG Zhen-Hua, Ph.D., professor, Ph. D. supervisor. His research interests include machine learning, data mining and recommender system.

WU Zheng-Yang, Ph.D., associate professor. His research interests include recommender system and knowledge tracking.

LIU Bo, Ph. D., professor. His research interests include machine learning and cloud computing.

TANG Yong, Ph. D., professor, Ph. D. supervisor. His research interests include data mining and database.

CHEN Yun-Wen, Ph. D., His research interests include machine learning and knowledge distillation.

Background

News recommendation technology can deeply mine user interests and alleviate the information overload problem caused by massive news. With the development of deep learning, deep neural network-based news recommendation models has become a research hotspot and focus in the recommender system community. News recommendation models are usually fully updated based on complete datasets, that is, all the data at a certain moment are used for model training. However, a large amount of news data and user interaction records appear on the news platform all the time, and the full-volume update method needs to integrate new data every time to build a new dataset for training. It can ensure high recommendation performance, but the larger the amount of data, the longer the training time required for full-volume update, and the training efficiency is low. Additionally, some recommendation platforms could not store all the previous data and be unable to provide complete volume upgrades in realistic settings due to privacy and storage issues. One of the best solutions to the aforementioned issues is incremental learning. For continuous model learning in real-world settings, incremental learning has recently been proposed and has shown promising results. Therefore, this paper introduces the concept of incremental learning in the task of news recommendation to convert full update into incremental update.

The introduction of domain incremental learning into the news recommendation task inevitably results in catastrophic forgetting, which is commonly solved by regularization-based and replay-based approaches. The regularization-based approaches, represented by LWF (Learning without Forgetting), limit the forgetting of old

knowledge by adding regularization terms to the learning of new tasks, but are limited to feature alignment or spatial geometry matching between individual samples learned in new tasks and the responses of the original network, lacking global vision. The basic idea of replay-based approaches is to maintain the old knowledge of model by replaying the samples that appeared in previous tasks during the training of new tasks, which violates the setting that the data of past tasks are not available, leading to the security problem of user data privacy in the news recommendation scenario.

To solve the above problems, this paper treats the news recommendation task in real scenarios as a non-smooth data distribution task flow in days, and proposes an incremental method for news recommendation models, called OT-KR. It fully considers the consolidation of old knowledge from a global perspective and minimizes the distribution difference between new and old tasks based on optimal transmission to achieve knowledge fusion. On this basis, OT-KR proposes the knowledge playback strategy by saving the models learned from previous tasks, because only the models can contain the complete distribution information of the task, and will not lead to data privacy leakage. Experimental results on public news recommendation datasets show that OT-KR method outperforms the current mainstream methods in recommendation performance.

This work is partially supported by the National Natural Science Foundation of China (No. 62172166, No. 61772366 and No. U1811263), which aims to research on deep learning-based recommender system, and the Guangdong Basic and Applied Basic Research Foundation (No. 2022A1515011380), which aims to research on incremental learning.