用于互补商品推荐的半监督对抗学习

Koby Bibas
kobybibas
@gmail.com Meta 特拉维夫，以色列

Oren Sar Shalom*
oren.sarshalo
m@gmail.com 亚马逊 特拉维夫，以色列

Dietmar Jannach
diet
mar.jannach@aau.at 克拉根福大学 克拉根福，奥地利

arXiv:2303.05812v1 [cs.IR] 10 Mar 2023

摘要

互补商品推荐是现代电子商务网站的常见功能。基于共同购买统计数据等协同信号的推荐效果非常好。然而，在某些在线市场（例如在线拍卖网站）中，商品目录会不断添加新商品。在这种情况下，由于缺乏交互数据，互补商品推荐往往基于商品侧信息。本文提出一种新颖的方法，能够利用商品侧信息和带标签的互补商品对，为冷启动商品生成有效的互补推荐，即为尚无共同购买统计数据的商品生成推荐。鉴于互补物品通常必须与种子商品属于不同类别，我们在技术上为每个商品类别维护一个潜在空间。同时，我们学习将分布式商品表示投影到这些类别空间中，以确定合适的推荐。我们架构中的主要学习过程利用带标签的互补物品对。此外，我们借鉴循环生成对抗网络（CycleGAN）的思想，即使在某个商品及其类别没有标注数据的情况下，也能利用可用的商品信息。在三个电子商务数据集上的实验表明，我们的方法效果显著。

CCS 概念

• **信息系统** →**推荐系统**。

关键词

推荐系统、互补物品、CycleGAN

ACM 参考格式：

Koby Bibas、Oren Sar Shalom 和 Dietmar Jannach。2023。用于互补商品推荐的半监督对抗学习。发表于*2023*年*ACM*网络会议（*WWW '23*）论文集，*2023*年*5*月*1*日至*5*日，美国德克萨斯州奥斯汀。ACM，纽约州纽约，美国，9页。https://doi.org/10.1145/3543507.3583462

*这项工作是在 Meta 任职期间完成的。

在不收取费用的情况下，允许为个人或课堂使用而复制本作品的全部或部分内容，无论采用数字形式还是纸质形式，前提是不得为营利或商业利益而复制或分发，且所有副本均须附有本声明和首页上的完整引文。对于本作品中由作者以外的其他人拥有版权的部分，必须尊重其版权。注明出处后可以进行摘要。以其他方式复制、再版、发布到服务器或分发至列表，均须事先获得明确许可和/或支付费用。请通过 permissions@acm.org 联系我们申请许可。*The Web Conference '23，2023* 年*4*月*30*日至*5*月*4*日，美国德克萨斯州奥斯汀© 2023 版权所有归所有者/作者所有。出版权已授权给 ACM。ACM ISBN 978-1-4503-9416-1/23/04...$15.00
https://doi.org/10.1145/3543507.3583462

1 引言

许多现代电子商务网站都会向顾客提供互补性商品推荐。例如，在线用户选购衬衫时，可能会收到适合搭配的裤子推荐。实际上，这类推荐通常以“经常一起购买”等标签呈现，也是电子商务平台开展交叉销售的重要驱动力 [5, 17, 18]。鉴于电子商务中的商品品类通常十分丰富，互补商品推荐的排序通常依据消费者群体中观察到的行为模式，例如共同购买模式。此外，还可能融入领域知识，例如，互补商品推荐必须来自预先定义的目标类别（如裤子），或来自与种子项目类别不同的类别；种子项目即寻求互补商品推荐的项目。

然而，在某些域中，商品目录可能变化极快 [30]。例如，在 eBay（*ebay.com*）拍卖平台上，新物品不断上架，而且某种产品通常只有一个可购买的样品 [8, 39]。因此，需要采用适用于冷启动种子物品的方法，即针对没有交易数据的物品。在这种情况下，不可能基于物品共同购买等协同信号对种子商品建模。因此，可能需要依赖其他方法，例如处理有关物品的辅助信息，如物品的自然语言描述或结构化商品属性。

尽管我们关注的是冷启动物品，但仍然可以利用聚合使用数据。具体而言，这类数据使我们能够推断出一组互补类别，即包含互补商品的类别，例如裤子和衬衫这两个类别。随后，可以将某个类别中商品的推荐范围限制在属于互补类别的物品之内。这种方法有三大优势：(1) 有助于排除不相关的推荐；(2) 显著缩短推理时间；(3) 可用于设计商品组合 [3, 50]（例如，每个互补类别推荐一件商品），从而让用户了解这些组合是如何形成的。鉴于这些优势，在 Facebook Shops 和 Instagram Shops[1] 等大型电子商务网站上，采用类别级约束进行互补商品推荐已成为一种常见做法。

在这项工作中，我们提出了一种新颖的深度学习模型来解决这一具有挑战性的问题设定。我们方法的主要技术思想是为每个商品类别维护一个潜在空间。同时，我们学习将借助辅助信息得到的物品表示转换到这些潜在空间中。

[1]https://research.facebook.com/blog/2021/12/shops-on-facebook-and-instagram-understanding-relationships-between-products-to-improve-buyer-and-seller-experience/

这一过程最终使我们能够在给定的类别空间中找到与种子商品接近的物品。我们架构中的基本学习过程基于使用带标签的互补商品对进行监督学习。需要指出的是，这些商品对（例如，可以通过分析网站现有的购物篮获得）不包含种子商品，因为我们要为冷启动商品提供推荐。相反，它们有助于我们学习不同类别之间的关联。由于某些类别的这类带标签商品对可能较为稀疏，我们还在架构中借鉴了循环生成对抗网络（CycleGAN）[49] 的思想。即使某个商品和类别没有标注数据，这种方法也使我们能够利用已有的商品信息。

总而言之，我们提出了一种用于互补商品推荐的新型半监督模型。在三个电子商务数据集上对该模型进行评估，结果证实，在不同的实验设置下，该模型均优于替代方法。此外，实验还清楚地展示了在架构中加入 CycleGAN 元素的优势。据我们所知，此前文献尚未探索利用 CycleGAN 概念来改进互补商品推荐。

2 背景与相关工作

现实世界电子商务中一种常见的技术方法是确定相关商品，例如在商品详情页上展示相关商品[2]；这通常依赖共同购买模式。基于此类简单购物篮分析的推荐可能出奇地有效 [22, 25]。然而，我们注意到，这些方法返回的商品不一定是互补商品；例如，两件特定的衬衫可能经常被一起购买 [11]。因此，在我们的研究中，我们假设互补商品属于预先定义的互补类别之一，且该类别与种子商品的类别不同（例如，衬衫对应的互补类别为裤子）。

实践中常见的另一类推荐通常会以“相似商品”或“相关商品”等标签展示，其中一些可能是替代品 [5, 28, 35, 37, 44]。寻找相似商品是另一个相关问题，但与我们的研究重点几乎恰好相反。相关商品，例如 [37], ，理论上则既可以包括互补品（例如配件），也可以包括替代品，即替代选择。一些研究 [1, 2, 26] 旨在寻找互补产品，但这些方法往往无法区分相似物品与互补物品，因为种子物品和推荐物品由完全相同的网络编码。

就所探讨的研究挑战而言，Galron 等人 [8] 在 eBay 的工作与我们的研究最为接近，我们也采用了类似的评估方法。鉴于用户与物品交互数据的稀疏性妨碍了传统协同过滤方法的使用，[8] 提出基于商品的 DCF（深度协同过滤）方法，利用物品的辅助信息学习物品之间的相似度函数。随后，该相似度函数用于为给定的种子商品检索推荐结果；也就是说，神经网络将一对种子商品和目标商品作为输入，并输出相似度预测。在内部，该网络根据标题或类别等特征，将物品编码为稀疏特征向量。为了训练模型，使用了来自 eBay 的购买数据，其中包含由同一用户共同购买的物品对。计算实验和一项 A/B 测试表明，DCF 的表现显著优于 eBay 的现有系统。鉴于 DCF 已在真实场景中证明了其性能，我们在研究中将该方法用作基线。我们注意到，在评估中，来自同一类别的 DCF 推荐结果被视为真实标注。

P-Companion [11] 是另一种用于互补商品推荐的神经网络框架。该模型侧重于使推荐结果多样化；鉴于其表现优于其他几种方法 [10, 27, 40],，我们也将其用作基线。尽管该模型与我们的方法有一些共同点，但它不支持半监督学习。此外，它不会为每个类别维护独立的潜在空间，而是根据项目所属的类别，对项目嵌入中的不同维度赋予不同权重。

在应用方面，先前的许多研究都聚焦于时尚推荐 [7, 23, 41, 47]。在许多情况下，视觉方法非常有效 [6]。这类方法通常会考虑领域特性，并高度依赖商品图像来建立不同服装商品之间的关系，例如，将物品映射到共享的视觉风格空间中 [27]。例如，在一项近期研究中 [7], ，作者利用形状和颜色信息来学习哪些形状和颜色彼此兼容。文献 [14, 34]同样聚焦于兼容性估计。文献 [41]介绍了一种同时考虑视觉信息的基于会话的推荐方法。然而，这类视觉方法也有其局限性。具体而言，纯视觉方法可能会返回风格相似但并不互补的物品。因此，文献 [47], 提出了一种依赖文本信息的互补商品推荐方法，并且可以借助近期方法进行扩展 [32]。这些研究与我们的方法不同之处在于，我们的框架并非特定于某个领域。此外，我们的方法同时考虑视觉和文本辅助信息，还允许我们指定互补物品的目标类别。明确预测物品之间的兼容性并非本研究的重点，但这是未来值得探索的方向。同样，旨在自动判断两个物品究竟是替代品还是互补品的研究（例如 [24, 40], ）未来也可以整合到我们的框架中，以评估其是否有助于进一步提高准确率。

还有许多其他研究使用的数据集包含与我们在计算实验中使用的数据类似的共同购买或共同浏览商品信息，例如 [36, 48]。然而，这类研究的重点通常并非提供互补商品推荐，而是通过利用数据中的共现信息来提升总体预测准确率。但它们并不区分最终生成的推荐究竟包含的是替代品还是互补品。

对抗训练在推荐系统中的应用十分广泛 [19, 20, 29]。具体而言，[21], 提出了将 GANs 用于互补推荐的方法，其中生成器学习如何生成互补商品的图像。然而，该方法的目标是生成图像，而非商品。 [16] 提出了另一种生成对抗学习方法。给定一个种子商品，生成器网络会生成推荐结果

[2]这类推荐通常不会根据长期用户画像进行个性化，这也是我们当前工作的一个假设。参见 [39]，了解 eBay 上的一种个性化方法。

判别器则需要区分真实标注的推荐结果和生成的推荐结果。然而，该模型需要完全监督；与我们的方法不同，它无法控制推荐结果的重要特征，例如类别。

文献 [46] 提出了一种考虑质量的 互补商品推荐方法。其基本直觉是，物品的兼容性和推荐物品的质量都很重要。该方法中的质量依据显式商品评分来衡量，所提出的模型会综合考虑用户偏好和兼容性。在我们的研究中，情况则有所不同：我们不假设存在长期用户偏好档案和显式评分。不过，个性化推荐[38, 43, 45] 或考虑用户会话的序列特性 [42] ，或许是未来可以探索的方向。

3 所提方法概述

问题设定概要。 我们回顾一下问题设定的具体内容。给定一个种子商品和一个目标类别，任务是从目标类别中推荐互补商品[3]。主要挑战在于，种子商品尚无交互数据。不过，我们假设每件物品的类别已知，并且每件物品都有一些可用的辅助信息。此外，我们还假设存在一个由互补物品对组成的标注集[4]。该集合可以人工创建，也可以通过分析具有足够购买信号的物品对的共同购买模式等方式自动生成。不过，标注数据稀缺通常是一个固有问题，因此，能够应对这一问题的模型更为理想。

技术方法。 令 C 表示商品目录中所有商品类别的集合。如前所述，我们方法的一个关键思想是为每个商品类别维护一个潜在空间 $c \in C$。为了针对给定的种子商品进行推荐，我们首先为其创建一个分布式表示（即嵌入），然后将该嵌入转换到目标类别的潜在空间中。这个转换过程可以理解为：将种子商品的表示转换到目标类别的潜在空间中，从而创建一个伪商品。我们方法面临的主要挑战是，如何基于稀疏数据学习将物品转换到目标潜在空间，同时保留种子商品的重要特征。一旦种子商品位于目标类别的潜在空间中，就可以通过选择与其接近的物品，得出合理推荐。更正式地说，令 I_c 表示类别 c 中的物品集合。为了针对种子商品 s 在类别 c 中寻找合理推荐，我们会生成转换后的表示 v_s^c。然后根据物品与 v_s^c 的距离进行推荐：$\text{argmax}_{i \in I_c} \cos(v_s^c, v_i)$，其中 cos 表示余弦相似度，$v_i$ 是物品 i 的分布式表示。

回顾一下，在我们的方法中，我们旨在聚焦于每个项目的一组相关类别。因此，给定一个项目的类别，我们根据项目级带标签的数据确定互补类别。为了找到类别对应的互补类别集合 $c \in \mathsf{C}$，我们将项目级带标签的商品对汇总至类别级，以确定其他相关类别的集合[5]

架构组件。 整体架构包含两个主要部分。首先，架构包含一个监督学习组件，该组件利用商品侧信息以及互补物品配对的标注集，学习不同类别潜在空间之间的转换。由于这组配对的标注数据可能较为稀缺，尤其是在稀有类别中，因此我们扩展了架构，加入一个子网络，以支持利用商品目录中的所有物品进行无监督对抗学习。也就是说，该方法也适用于在数据集中没有对应类别的已标注互补商品的物品。因此，这两个部分结合起来构成了一种半监督学习方法。图1展示了该模型的整体架构。

4 监督学习组件

监督学习组件包含两个部分。**商品编码器**为物品创建嵌入。随后，**类别转换器**将编码后的商品转换到任意给定目标类别的潜在空间中。

商品编码器。 给定一个项目 i，模型首先根据其辅助信息生成其表示 v_i。在许多应用场景中，包括上文讨论的时尚领域，项目的图像都是极其重要的辅助信息。为利用这类信息，我们首先将项目图像输入预训练图像处理模型。然后，将其输出输入一个经训练的多层感知机（MLP）。对于类别特征，模型会为每个不同的取值拟合一个嵌入。值得注意的是，项目价格等连续特征可以通过离散化转换为类别特征来处理。为获得整体项目表示，我们将所有特征的表示拼接起来，并输入另一个多层感知机。我们承认，也可以采用其他更复杂的方法，而非简单的多层感知机。不过，这些潜在改进留待未来工作。还需指出的是，此处将类别本身用作另一项特征，因此**商品编码器**具有类别感知能力。

类别转换器。 这一组件的任务是学习如何将项目表示从一个潜在空间迁移到另一个潜在空间。例如，设 s 是一件特定的衬衫，p 和 n 是两条裤子（分别代表正例和负例），其嵌入分别为 v_s、v_p 和 v_n。假设 s 与 p 互补，但与 n 不互补。那么，我们希望学习一种变换，使衬衫的表示 v_s 投影到裤子领域后，所得表示与 v_p 的相似度高于与 v_n 的相似度。我们强调，结合项目表示和类别表示有许多合理的架构，其中一些架构允许不同类别的潜在空间具有异构维度。不过，我们选择的模型采用简单的嵌入拼接，然后接入一个多层感知机。

模型训练。 监督学习组件的训练基于给定的带标签商品对集合。每个带标签商品对由一个种子商品 s 和一个正例互补商品 p 组成，属于

[3]在实践中，可能存在多个互补类别，因此推荐过程可能需要针对每个类别重复进行。[4]请注意，标注集中的配对不包含种子商品。

[5]与 [41] 中的做法相同，我们不允许推荐来自同一类别的互补商品。不过，如有需要，这一限制也可以轻易取消。

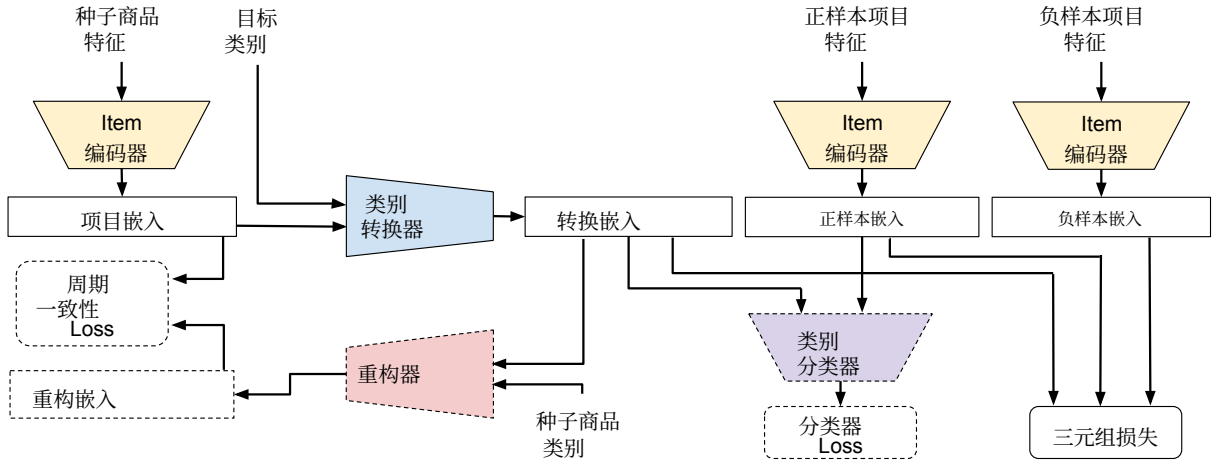

图1：该提案　　模型架构。虚线框中的元素属于对抗学习网络　　.

类别 c。对于每一对，我们都会进行负采样，并抽取一个负样本项目 n（同样来自类别 c）。随后，对每个物品调用商品编码器以获得表示 v_s、 v_p和 v_n。然后，对 v_s应用类别转换器，得到 v_s^c，即种子商品在目标潜在空间中的表示。我们使用三元组损失 [31]作为损失函数：$\mathrm{L}\left(v_s^c,\ v_p,\ v_n\right) = \max\left(\mathrm{d}\left(v_s^c,\ v_p\right) - \mathrm{d}\left(v_s^c,\ v_n\right) + \alpha,\ 0\right)$，其中 d 是距离函数；在我们的实验中，负余弦相似度表现良好。α 是一个超参数，用于设定间隔，使正样本比负样本更相似。

5 对抗学习组件

任何监督式学习方法的有效性都受限于可用的标注数据。如前所述，在互补商品推荐中，数据稀缺是一个常见问题。尤其是对于较稀有的类别，可能没有足够数量的带标签商品对，无法进行有效学习。因此，我们的架构包含一个实现无监督学习的对抗学习组件。借此，我们旨在利用商品目录中任意项目的信息，即使在给定类别中没有与其对应的带标签互补商品也是如此。在我们的示例中，如果给定一件特定的衬衫，而训练数据中的裤子类别没有与之互补的商品，就会出现这种情况。最终，两个组件的结合形成了一种半监督学习方法。需要强调的是，对抗组件仅用于进一步改进训练过程。在推理时间，仅使用商品编码器和类别转换器的输出即可确定推荐结果。

5.1 架构元素

该组件的主要目标是进一步提高类别转换器的有效性。为了确保类别转换器在整合无标签物品的信息时不会受到误导，对抗组件借鉴了 CycleGAN [49]。CycleGAN 最初是为图像到图像的转换问题而设计的，例如将夏季景观转换为冬季景观。这些网络中的一个核心思想是循环一致性。对于上述例子，如果将冬季景观转换回去后得到的图像与原始图像足够接近，那么这种转换就满足循环一致性。归根结底，循环一致性确保输入和输出之间存在有意义的配对关系。

具体而言，我们的对抗学习组件包含两个主要子网络：分类器 和重构器。分类器 接收商品表示 v_i和类别 c作为输入，并返回商品 i属于类别 c的概率。为此，分类器 将 v_i输入多层感知机，为每个类别分配一个分数，其中最后一层的大小为 $|\mathrm{C}|$。随后，使用 *Softmax* 将这些分数转换为概率，并提取商品属于类别 c的概率。最后，将转换后的表示 v_i^c发送给分类器，以确认它确实看起来像是类别 c中某个商品的表示。这个辅助组件促使类别转换器 生成可靠的嵌入。然而，它可能无法训练出优秀的推荐系统，因为无法保证种子商品的重要特征得以保留。在我们的示例中，转换后的表示看起来可能属于一条裤子，但未必能带来好的推荐，因为它并未受到约束，无法确保保留原始衬衫的具体或抽象属性，例如风格、年龄群体或价格。

为了解决这一问题，我们引入重构器，促使类别转换器满足循环一致性，并保留种子商品的特征。具体而言，该网络接收转换后的表示 v_i^c以及种子商品的原始类别，并通过返回一个向量 v_{ni}来重构种子商品的原始表示 v_i，使得 $v_i \approx v_{ni}$。

5.2 模型训练

对抗学习组件包含两种损失函数：一种用于重构器，另一种用于分类器。为了对整个架构进行端到端学习，最终损失由这两种损失和监督学习组件的损失函数加权求和得到。各项损失的权重构成凸组合，并由超参数确定。

循环一致性损失。 在我们的方法中，重构器的损失是欧几里得距离 $\|v_i - v_{r_i}\|^2$。由于损失中的两项 v_i 和 v_{ri} 都是通过学习网络得到的输出，因此可能达到一种退化但最优的损失。例如，如果商品编码器 和类别转换器 无论输入是什么都返回相同的固定值，那么损失将为 0。为了解决这个问题，我们回顾一下，该损失的目的是促使类别转换器 不要丢弃种子商品中由 v_i 表示的重要特征。因此， v_i 充当该损失的标签。因此，我们阻止由于该损失而从 v_i 反向传播梯度。我们指出，该过程借助从 v_{ri} 得到的雅可比矩阵，可以进一步改善商品编码器。

分类器损失。 如上所述，给定一个商品表示和一个类别，分类器 会输出概率 p，表示该商品属于此类别的可能性。通常，其损失为交叉熵；由于输入的真实类别只有一个，损失可简化为 $-\log p$。我们应牢记，只有经过充分训练的分类器才能对类别转换器 构成挑战，从而促使其生成合适的表示。这带来了若干困难，也使架构的简单实现不可行。下面我们将讨论这些挑战以及相应的解决方法。为了以最佳方式训练分类器，我们向其提供两种类型的训练样本。

第一种类型由商品编码器的真实输出组成。具体而言，我们调用分类器 两次，分别输入种子商品 v_s 和正样本商品 v_p[6] 的嵌入，标签类别则取自商品目录。然而，我们注意到，标准实现也会影响商品编码器。具体来说，这最终可能导致模型退化，因为类别是商品编码器的输入。这样一来，商品编码器 就会被驱使着与类别转换器 合作，以牺牲模型的真正目标——提供推荐——为代价，在这项损失上取得出色表现。例如，商品编码器 可能会输出类别嵌入，而忽略其余输入特征。因此，我们在实现模型时阻止分类器 的梯度通过商品编码器的参数反向传播。实验表明，这使性能显著提升。

关于分类器的第二种输入，我们回想一下，类别转换器旨在生成嵌入 v_s^c，使分类器将 v_s^c 分类为仿佛它属于类别 c。为了避免类别转换器找到只能欺骗分类器、但看起来不像类别 c 中真实物品向量的边界情况（对抗样本），让分类器在类别转换器 v_s^c的输出上以类别 c为标签进行训练十分重要。若采用这种方式， v_s^c会同时用于训练类别转换器和分类器，但两者的目标不同。类别转换器旨在欺骗分类器，而后者则需要对类别转换器构成挑战。为解决这一问题，我们使用带有梯度反转层的对抗训练。这意味着在反向传播过程中，类别转换器获得原始梯度，而分类器则由梯度的加法逆元引导。

[6]考虑到运行时间，负样本项目的嵌入不会输入分类器，尽管添加它非常简单。

值得注意的是，该模型具有可扩展性，因为其训练时间与标注集和物品-类别对的规模呈线性关系；此外，参数量随类别数量线性增长。

5.3 CycleGAN 的具体调整

在这里，我们将更详细地阐述 CycleGAN 与我们的方法之间的共性和差异。具体而言，本节将说明我们如何以创新的方式将 CycleGAN 的理念迁移到互补项目推荐问题中。

CycleGAN 是生成对抗网络（GAN）的一种变体[9],，包含两个生成器和两个判别器，它们同时进行训练。设 X为给定转换问题（例如从夏季到冬季）中的源域， Y为目标域。生成器 G 学习将图像从 X转换到 Y。生成器 F 学习将图像从 Y转换到 X。判别器 D_X 学习区分 X中的真实图像与生成图像 F（Y）。也就是说，其目标是对 $x \in X$返回较高的概率值，对 F(y) 返回较低的概率值，其中 $y \in Y$。同样，判别器 D_Y 在域 Y中运行。为简便起见，我们统称 D_X 和 D_Y 为 D，即用于区分真实图像与生成图像的判别器。这些网络通过对抗训练进行训练。通常希望 G(x) 不会舍弃原始图像的重要特征。这样可以确保 G(x) 是对x的转换，而不只是看起来属于 Y、却与 x 毫无关联的图像。为此，引入了循环一致性损失。具体而言，该损失旨在最小化 x 与 F(G(x)) 之间的差异。

我们首先说明，在某种意义上，商品编码器 充当真实分布，类别转换器 充当 G，分类器 充当 D，而重构器 充当 F。给定输入表示 v 和类别 c，分类器 按如下方式工作。如果 v 是由商品编码器直接生成的，那么它应确认该项目属于指定类别 c；否则， v 会进一步经由类别转换器转换，而分类器 应拒绝假定项目与类别之间存在关联。因此，与生成对抗网络类似，分类器 （D）旨在对来自商品编码器 （真实分布）的输入输出接近 1 的概率，而对来自类别转换器 （G）的输入输出 0 的概率。与 CycleGAN 中的做法一样，我们的方法使用重构器来计算循环一致性损失；重构器将商品表示转换回其原始类别，因此充当 F。

然而，这两个模型之间存在一些显著差异。首先，CycleGAN 中从真实分布抽取的实例是源域中的真实图像。因此，循环一致性损失定义明确，因为原始图像 x 充当 F(G(x)) 的标签。相比之下，我们的方法作用于特征空间。也就是说，“真实分布”实际上是商品编码器的输出，而它是一个经过学习的 网络。因此，图像编码器 的输出也充当标签，这可能会妨碍其训练。如前所述，我们通过停止来自种子商品向量的梯度来解决这一问题。

另一个差异源于类别转换器的复杂性。在 CycleGAN 中只有两个域，而在我们的问题中，域（类别）的数量可达数百个。因此，我们选择训练一个适用于所有类别的统一转换器。

有了统一转换器后，重构器 似乎是多余的，因为类别转换器 也可以在任意一对类别之间进行转换。然而，在实验中我们发现，将这两个网络分开有一个关键优势。我们推测这是由它们不同的目标所致。类别转换器 旨在找到优质推荐，而重构器 则希望恢复物品原本的潜在特征。因此，类别转- 换器 可能会生成与热门或高质量物品相似的向量，因为这类物品通常能带来良好的推荐；而重构器 则不受这一需求约束。因此，负责生成推荐的类别转换器最好与重构器区分开来。

6 实验评估

我们对所提出的方法进行了深入的实验评估。为确保可复现性，我们已在线共享所有代码 [7]。

6.1 实验设计

数据集与预处理。 我们使用来自 *Ama- zon* [13], 的真实世界数据，这些数据也曾用于以往的相关研究 [11, 24]。首先，我们从这些数据集中提取物品的辅助信息，包括图像、价格和类别。此外，数据集中的每个物品 i 都可以关联一份推荐物品列表 $\{r_i\}$，这些物品是经常被一起购买的。从 $\{r_i\}$ 中移除与 i 属于同一类别的物品后，我们便得到一组互补物品对标注集 $\{(s, r_i)\}$，并在实验中将其用于模型训练和评估。需要指出的是，这些物品对可能是不对称的，例如，笔记本电脑可能会伴随充电器推荐，但反之则未必。

我们考察了 亚马逊 数据集的三个子集：“服装、鞋类和珠宝”（简称服装）、“家居与厨房”（家居）以及“玩具与游戏”（玩具）。之所以选择这些子集，是因为互补商品在这些域中至关重要。同时，它们在垂直领域、目标用户、影响互补性概念的属性，以及物品和类别数量等关键方面各不相同。这些数据集的主要统计信息见表 1。

表 1：数据集统计信息

统计项	服装	Toys	Home
#物品	14,591	20,510	29,258
#项目对	53,375	112,964	162,497
#类别	126	124	286
#类别对	4,621	5,734	18,999
每个类别的平均物品数	115.8	165.4	102.3
每个类别的最多物品数	808	2,558	796
每个类别的最少物品数	12	16	11

在预处理方面，我们剔除了物品少于五个的类别，以减少噪声。我们使用 ResNet152 [12] 作为预训练图像处理模型。如果一个项目包含多张图像，我们只使用第一张。此外，我们采用等深分箱，将连续价格离散化为二十分箱。我们随机抽取 80% 的数据作为训练集，其余数据用于验证和测试。为模拟冷启动问题，我们确保验证集和测试集中的种子商品不会出现在训练集中。

评估流程与指标。 给定一个种子商品后，我们的模型会输出一个互补物品排序列表。因此，我们采用标准的基于列表的准确率指标，即命中率（$HR@k$）和归一化折损累计增益（NDCG），参见 [33]。此外，由于标注集高度偏向热门物品，一些模型可能会在推荐中集中于少数此类热门物品，从而导致覆盖范围和多样性有限。因此，我们还报告目录覆盖率 [15],，其定义为测试集种子物品对应的前 k 个推荐列表中出现的商品目录物品占目录总物品的比例。该指标中的 k 值为 10。

按照所述问题设定，在主要评估方案中，推荐所需的类别是已知的。为了展示各方法的稳健性，我们还在推荐可以来自任意类别的设定下进行了实验。需要注意的是，我们的模型要求将目标类别作为输入。为了生成涵盖所有相关类别的推荐列表，我们以轮询方式遍历种子商品的所有互补类别，并迭代选择下一条推荐。

基线方法。 我们将模型与以下基线方法进行比较。

- **流行度** 是一种简单而有效的基线方法，它利用标注集统计每个物品的流行度。对于每个物品 i，它会记录在标注集中有多少种子物品将 i 标注为其互补商品。
- **DCF** [8] 是一种近期提出、针对冷启动商品进行优化的神经网络模型。由于其代码未公开，我们根据原论文实现了该模型，并将代码公开。
- **DCF-Hard**是我们在此提出的*DCF*的变体。它利用类别信息进行困难负样本挖掘。具体而言，负样本并非从整个商品目录中抽取，而仅从标注目标商品所属类别的物品中抽取。
- **P-Companion** [11] 是另一种近期提出的神经网络模型。由于其代码未公开，我们实现了该模型，并将代码一并发布在我们的代码库中。为了使其适用于我们的问题设定，我们进行了两项修改。首先，我们控制目标类别；其次，我们省略协同信息，以支持冷启动问题。

我们通过手动调节，为模型和每个数据集上的基线方法都仔细调整了超参数。最终的超参数可在代码仓库中找到。

6.2 结果

6.2.1 主要结果。 表 2 报告了我们实验的主要结果，其中向推荐系统提供了类别。我们将提出的模型命名为**ALCIR**，即***A***对抗式 ***L***学习 ***C***互补 ***I***物品 ***R***推荐。为了分析架构中各个组成部分的贡献，我们报告了以下模型的结果：(a) *ALCIR-Sup*，仅包含第 4 节所述的监督学习组件；(b) *ALCIR*，即第 5 节所述的完整 模型。

[7] https://fb.me/cgan_c互补性_商品_推荐

表 2：类别感知推荐性能

方法	NDCG	HR@1	HR@5	HR@10	覆盖率（%）
服装数据集					
流行度 0.238		0.051	0.153	0.234	6.99
DCF 0.211		0.011	0.059	0.111	7.24
DCF-Hard	0.226	0.019	0.083	0.147	40.49
P-Companion	0.238	0.030	0.102	0.169	84.59
ALCIR-Sup	0.298	0.074	0.203	0.302	**89.92**
ALCIR	**0.316**	**0.092**	**0.233**	**0.332**	88.5
玩具数据集					
流行度	0.231	0.038	0.126	0.200	5.13
DCF	0.193	0.009	0.042	0.081	5.96
DCF-Hard	0.208	0.017	0.064	0.111	36.72
P-Companion	0.235	0.028	0.104	0.172	**93.78**
ALCIR-Sup	0.297	0.073	0.205	0.303	90.46
ALCIR	**0.308**	**0.078**	**0.224**	**0.330**	82.62
Home 数据集					
流行度	0.251	0.048	0.160	0.255	8.2
DCF	0.211	0.011	0.051	0.102	8.32
DCF-Hard	0.221	0.014	0.046	0.077	12.82
P-Companion	0.245	0.032	0.111	0.187	**94.45**
ALCIR-Sup	0.296	0.068	0.197	0.293	93.44
ALCIR	**0.304**	**0.077**	**0.210**	**0.312**	94.38

表2中的结果显示，在全部三个数据集上，*ALCIR* 在准确率指标方面始终优于所有基线方法，通常优势显著[8]。我们还观察到，仅模型的监督组件（*ALCIR-Supervised*）就已优于基线方法。随后，对抗组件进一步提升了这些已经很出色的结果。

考察其他模型的排序后，我们发现，基于流行度的方法是一个难以超越的基线。*DCF* 模型，甚至是改进后的*DCF-Hard* 模型，其准确率都未达到基于流行度的方法的水平。*P-Companion* 表现更好，但命中率仍未达到热门物品推荐的数值。只有在归一化折损累计增益方面，*P-Companion* 才达到相近的性能水平。不过，基于流行度的方法表现出色并不令人意外。对数据集的检查发现，最受欢迎的十个物品涵盖了五分之一到四分之一的已标注互补物品。此外，[11] 中对"共同购买"方法的评估也表明，*P-Companion* 在以用户为中心的研究中并未优于此类基于流行度的方法[9]。

相比之下，我们提出的模型始终优于基于流行度的模型。我们还观察到，*ALCIR* 的覆盖率较高，介于82%至94%之间。只有*P-Companion* 方法的目录覆盖率略高。基于流行度的方法在设计上只会推荐非常热门的物品，因此覆盖率最低。有趣的是，*DCF* 方法的目录覆盖率也很低。改进后的 DCF 版本（*DCF-Hard*）在很大程度上解决了覆盖率问题。

[8]我们在代码仓库中报告了其他截断阈值下的结果。[9]在 [8]中未考察基于流行度的推荐。

表3最后展示了如上所述，在考虑互补商品推荐的所有相关类别时的性能结果。自然地，与已知类别的情况相比，所有模型在该实验中的性能都较低。尽管如此，我们观察到，所提出的模型 ALCIR 在这一问题设定下同样表现更优。

表3：不含目标类别的推荐性能

方法	NDCG	HR@1	HR@5	HR@10	覆盖率（%）
服装数据集					
流行度	0.099	0.001	0.005	0.007	0.06
DCF	0.111	0.000	0.001	0.002	0.09
DCF-Hard	0.118	0.001	0.003	0.007	1.82
P-Companion	0.111	0.000	0.002	0.003	0.62
ALCIR-Sup	0.150	0.009	0.036	0.060	59.36
ALCIR	**0.170**	**0.012**	**0.060**	**0.098**	**60.55**
玩具数据集					
流行度	0.102	0.001	0.003	0.005	0.04
DCF	0.124	0.000	0.001	0.002	0.06
DCF-Hard	0.148	0.003	0.010	0.016	5.67
P-Companion	0.123	0.001	0.001	0.002	5.12
ALCIR-Sup	0.172	**0.010**	0.044	0.021	**64.56**
ALCIR	**0.184**	0.009	**0.046**	**0.071**	56.03
Home 数据集					
流行度	0.093	0.000	0.001	0.002	0.03
DCF	0.117	0.000	0.001	0.002	0.05
DCF-Hard	0.117	0.000	0.002	0.003	0.13
P-Companion	0.117	0.000	0.001	0.001	1.61
ALCIR-Sup	0.143	0.005	0.021	0.033	53.42
ALCIR	**0.150**	**0.008**	**0.030**	**0.049**	**55.53**

6.2.2 补充分析。

数据稀缺的影响。 在将无监督学习组件引入模型时，我们的一个主要假设是，它对稀有类别尤其有益。为验证这一假设，我们进行了以下分析，以评估在改变每对类别的标注数据量时，完整的 *ALCIR* 方法所作出的相对贡献。为此，我们统计每对互补类别的标注实例数量，并将这些数量划分为十个大小相等的分箱。我们按照每对类别的标注数据量从少到多对分箱排序。因此，前几个分箱代表训练集中监督信息较少的互补类别对。

图2展示了各模型在十个分箱中的表现。需要指出的是，不同分箱之间的性能指标不能简单地进行比较，因为每个分箱包含不同的目标类别，推荐系统需要从中选择的物品数量也各不相同。因此，只能比较同一数据集、同一分箱中不同模型的表现，因为它们对应完全相同的测试项。考虑到这一点，我们可以观察到所有数据集都呈现出相同的趋势：对于稀有类别对，即图的左侧部分，*ALCIR* 的相对优势更大，也就是说

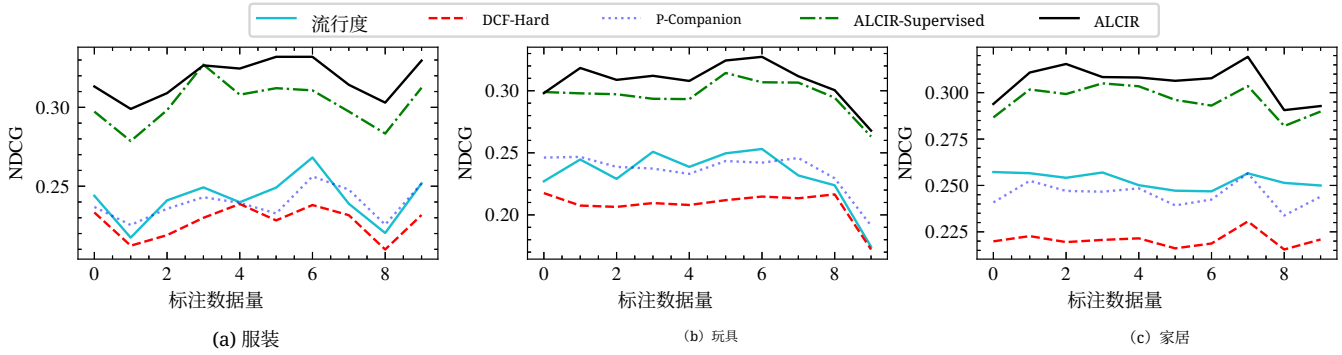

图2：不同标注数据量下的性能

表4：类别感知推荐的消融研究

方法	NDCG	HR@1	HR@5	HR@10
服装数据集				
分类器+周期	0.21 (-33.5%)	0.015 (-83.9%)	0.059 (-74.7%)	0.114 (-65.7%)
ALCIR-Sup	0.298 (-5.7%)	0.074 (-19.4%)	0.203 (-13.1%)	0.302 (-8.9%)
三元组+循环	0.311 (-1.8%)	0.087 (-5.6%)	0.226 (-3.1%)	0.319 (-3.8%)
三元组+分类器	0.305 (-3.5%)	0.082 (-11.3%)	0.213 (-8.8%)	0.306 (-7.5%)
ALCIR	0.316	0.092	0.233	0.332
玩具数据集				
分类器+周期	0.207 (-32.9%)	0.016 (-79.5%)	0.07 (-68.7%)	0.124 (-62.5%)
ALCIR-Sup	0.297 (-3.7%)	0.073 (-6.4%)	0.205 (-8.7%)	0.303 (-8.2%)
三元组+循环	0.294 (-4.4%)	0.072 (-6.8%)	0.205 (-8.3%)	0.303 (-8.4%)
三元组+分类器	0.298 (-3.3%)	0.073 (-6.6%)	0.209 (-6.6%)	0.309 (-6.5%)
ALCIR	0.308	0.078	0.224	0.330
Home 数据集				
分类器+周期	0.218 (-28.1%)	0.014 (-81.2%)	0.068 (-67.5%)	0.127 (-59.3%)
ALCIR-Sup	0.296 (-2.6%)	0.068 (-11.4%)	0.197 (-6.1%)	0.293 (-6.1%)
三元组+循环	0.298 (-2%)	0.069 (-9.9%)	0.201 (-4.1%)	0.303 (-2.9%)
三元组+分类器	0.297 (-2.1%)	0.069 (-10.7%)	0.199 (-4.9%)	0.297 (-4.7%)
ALCIR	0.304	0.077	0.210	0.312

图的左侧部分。相反，对于非常热门的类别对，完整模型的优势会缩小；这一现象在玩具和家居数据集中尤为明显。总体而言，该分析证实了我们的假设，即完整模型尤其适用于稀有类别。

消融研究。除了包含有监督和无监督两个组成部分外，我们的架构还有一个核心特点，即使用了多种特定的损失函数（三元组损失、循环一致性损失和分类器损失），旨在提升模型性能。为验证这些架构要素对模型整体性能的贡献，我们进行了消融研究，评估仅使用部分组件时的性能。表4展示了分析结果，包括绝对数值以及相对于完整模型性能的数值（括号内）。结果表明，所有组件确实都有助于提升模型性能。最值得注意的是，不使用标注数据、仅使用分类器的无监督损失和循环一致性损失的模型表现最差。然而，鉴于标注数据的重要性早已广为人知，这一结果并不令人意外。

7 未来工作

在本研究中，我们针对互补商品推荐这一高度相关的问题，提出了一种新颖的半监督方法；深入的实证评估清楚地证明了该方法的优势。我们的发现指明了若干未来研究方向。本研究聚焦于冷启动商品的互补商品推荐，并假设现有数据（例如共同购买数据）可用于热启动商品。未来，我们计划在同一框架下扩展模型，使其也支持热启动商品。这样，商品编码器的输入特征也将包含协同数据，例如应用文献 [4]提出的方法。除了此类扩展以及在 [39, 46], 中持续开展相关研究之外，进一步提升模型有效性的其他有前景方法，可能包括对互补商品推荐进行个性化，以及考虑商品的质量。最后，我们的问题设定可以视为领域自适应的一个特例，即将表示从一个类别迁移到另一个类别。一个有趣的未来研究方向是将我们的方法扩展到其他推荐场景，例如上下文感知推荐，在这些场景中，我们会针对不同上下文生成商品表示。

参考文献

[1] Unaiza Ahsan、Xiquan Cui、Rebecca West、Mingming Guo、Khalifeh Al Jadda 等。2020。基于深度多模态嵌入的在线零售互补推荐。载于2020年IEEE国际大数据会议（Big Data）。IEEE，1774–1779。[2] Marina Angelovska、Sina Sheikholeslami、Bas Dunn 和 Amir H Payberah。2021。用于检测互补产品的孪生神经网络。载于第16届欧洲计算语言学协会分会会议论文集：学生研究研讨会。65–70。[3] Tzoof Avny Brosh、Amit Livne、Oren Sar Shalom、Bracha Shapira 和 Mark Last。2022。BRUCE：利用上下文化商品嵌入进行捆绑推荐。载于第16届ACM推荐系统会议论文集。237–245。[4] Koby Bibas、Oren Sar Shalom 和 Dietmar Jannach。2022。协同图像理解。载于第31届ACM信息与知识管理国际会议。[5] Yuri M Brovman、Marie Jacob、Natraj Srinivasan、Stephen Neola、Daniel Galron、Ryan Snyder 和 Paul Wang。2016。在半结构化市场中优化相似商品推荐以最大化转化。载于第10届ACM推荐系统会议论文集。199–202。[6] Rami Cohen、Oren Sar Shalom、Dietmar Jannach 和 Amihood Amir。2021。面向视觉感知推荐系统的黑盒攻击模型。载于第14届ACM网络搜索与数据挖掘国际会议论文集。94–102。[7] Lavinia De Divitiis、Federico Becattini、Claudio Baecchi 和 Alberto Del Bimbo。2023。时尚推荐中的特征解耦。ACM多媒体计算、通信与应用汇刊（TOMM）19（2023）。[8] Daniel A Galron、Yuri M Brovman、Jin Chung、Michal Wieja 和 Paul Wang。2018。面向稀疏隐式反馈的深度基于商品的协同过滤。arXiv预印本 arXiv:1812.10546（2018）。[9] Ian Goodfellow、Jean Pouget-Abadie、Mehdi Mirza、Bing Xu、David Warde-Farley、Sherjil Ozair、Aaron Courville 和 Yoshua Bengio。2020。生成对抗网络。《ACM通讯》63卷第11期（2020），139–144。[10] Junheng Hao、Muhao Chao、Wenchao Yu、Yizhou Sun 和 Wei Wang。2019。通过联合嵌入实例与本体概念，实现知识库的通用表示学习。载于第25届ACM SIGKDD知识发现与数据挖掘国际会议论文集。1709–1719。[11] Junheng Hao、Tong Zhao、Jin Li、Xin Luna Dong、Christos Faloutsos、Yizhou Sun 和 Wei Wang。2020。P-Companion：多样化互补产品推荐的有原则框架。载于第29届ACM信息与知识管理国际会议论文集。2517–2524。[12] Kaiming He、Xiangyu Zhang、Shaoqing Ren 和 Jian Sun。2016。用于图像识别的深度残差学习。载于IEEE计算机视觉与模式识别会议论文集。770–778。[13] Ruining He 和 Julian McAuley。2016。起伏变化：利用单类协同过滤建模时尚趋势的视觉演变。载于第25届万维网国际会议论文集。507–517。[14] Ruining He、Charles Packer 和 Julian McAuley。2016。为异构商品推荐学习跨类别兼容性。载于2016年IEEE第16届数据挖掘国际会议（ICDM）。937–942。[15] Jonathan L. Herlocker、Joseph A. Konstan、Loren G. Terveen 和 John T. Riedl。2004。评估协同过滤推荐系统。《信息系统汇刊》22卷第1期（2004），5–53。[16] Cong Phuoc Huynh、Arridhana Ciptadi、Ambrish Tyagi 和 Amit Agrawal。2018。CRAFT：基于对抗性特征变换的互补推荐。载于ECCV研讨会（3）。54–66。[17] Dietmar Jannach 和 Michael Jugovac。2019。衡量推荐系统的商业价值。ACM管理信息系统汇刊10卷第4期（2019）。[18] Dietmar Jannach、Oren Sar Shalom 和 Joseph A Konstan。2019。迈向更具影响力的推荐系统研究。载于ImpactRS@ RecSys。[19] Adit Krishnan、Hari Cheruvu、Cheng Tao 和 Hari Sundaram。2019。社交推荐的模块化对抗方法。载于第28届ACM信息与知识管理国际会议论文集。1753–1762。[20] Adit Krishnan、Ashish Sharma、Aravind Sankar 和 Hari Sundaram。2018。通过对抗方法提升神经协同过滤的长尾性能。载于第27届ACM信息与知识管理国际会议论文集。1491–1494。[21] Sudhir Kumar 和 Mithun Das Gupta。2019。c+GAN：互补时尚商品推荐。arXiv预印本 arXiv:1906.05596（2019）。[22] Dokyun Lee 和 Kartik Hosanagar。2019。推荐系统如何影响销售多样性？通过随机实地实验开展跨类别调查。《信息系统研究》30卷第1期（2019），239–259。[23] Zhi Li、Bo Wu、Qi Liu、Likang Wu、Hongke Zhao 和 Tao Mei。2021。学习互补推荐中的组合视觉一致性。载于第二十九届人工智能国际联合会议。[24] Yiding Liu、Yulong Gu、Zhuoye Ding、Junchao Gao、Ziyi Guo、Yongjun Bao 和 Weipeng Yan。2020。用于推断可替代商品和互补商品的解耦图卷积网络。载于第29届ACM信息与知识管理国际会议论文集（CIKM '20）。2621–2628。[25] Malte Ludewig 和 Dietmar Jannach。2018。会话推荐算法评估。《用户建模与用户自适应交互》28，4–5（2018），331–390。[26] Mansi Ranjit Mane、Stephen Guo 和 Kannan Achan。2019。使用四元组网络学习互补相似性。arXiv 预印本 arXiv:1908.09928（2019）。[27] Julian McAuley、Rahul Pandey 和 Jure Leskovec。2015。推断可替代与互补产品网络。载于第21届ACM SIGKDD知识发现与数据挖掘国际会议论文集（KDD '15）。785–794。[28] Julian McAuley、Christopher Targett、Qinfeng Shi 和 Anton van den Hengel。2015。基于图像的风格与替代品推荐。载于第38届国际ACM SIGIR信息检索研究与发展会议论文集（SIGIR '15）。43–52。[29] Yehezkel S. Resheff、Yanai Elazar、Moni Shahar 和 Oren Sar Shalom。2019。通过用户表示的对抗训练实现推荐系统中的隐私与公平性。载于第8届模式识别应用与方法国际会议（ICPRAM）论文集。476–482。[30] Oren Sar Shalom、Shlomo Berkovsky、Royi Ronen、Elad Ziklik 和 Amir Amihood。2015。数据质量对推荐系统至关重要。载于第9届 ACM推荐系统会议论文集。257–260。[31] Florian Schroff、Dmitry Kalenichenko 和 James Philbin。2015。Facenet：用于人脸识别和聚类的统一嵌入。载于 IEEE计算机视觉与模式识别会议论文集。815–823。[32] Oren Sar Shalom、Haggai Roitman 和 Pigi Kouki。2021。推荐系统中的自然语言处理。载于《推荐系统手册》。Springer。[33] Guy Shani 和 Asela Gunawardana。2011。推荐系统评估。载于《推荐系统手册》。Springer，257–297。[34] Xuemeng Song、Fuli Feng、Xianjing Han、Xin Yang、Wei Liu 和 Liqiang Nie。2018。结合注意力知识蒸馏的神经兼容性建模。CoRR abs/1805 00313 2018 1805 00313。（）。[35] http://arxiv.org/abs/。Christoph Trattner 和 Dietmar Jannach。2019。。《从人类判断中学习推荐相似物品》。《用户建模与用户自适应交互》30（2019），1–49。[36] Ilya Trofimov。2018。从购物篮和浏览会话中推断互补产品。CoRR abs/1809 09621 2018 1809 09621。（）。[37] http://arxiv.org/abs/。Jian Wang、Badrul Sarwar 和 Neel Sundaresan。2011。。《在电子商务中利用相关产品进行购买后推荐》。载于第五届 ACM推荐系统会议论文集（RecSys '11）。329–332。[38] Rui Wang、Ning Yang 和 S Yu Philip。2022。学习方面级互补性以实现意图感知互补推荐。《Knowledge-Based Systems》（2022），109936。[39] Tian Wang、Yuri M Brovman 和 Sriganesh Madhvanath。2021。eBay 上基于个性化嵌入的电子商务推荐。arXiv 预印本 arXiv:2102.06156（2021）。[40] Zihan Wang、Ziheng Jiang、Zhaochun Ren、Jiliang Tang 和 Dawei Yin。2018。用于区分电子商务中可替代与互补产品的路径约束框架。载于第11届 ACM网络搜索与数据挖掘国际会议论文集（WSDM '18）。619–627。[41] Jui-Chieh Wu、José Antonio Sánchez Rodríguez 和 Humberto Jesús Corona Pampín。2019。基于会话的互补时尚推荐。arXiv 预印本 arXiv:1908.08327（2019）。[42] Da Xu、Chuanwei Ruan、Evren Korpeoglu、Sushant Kumar 和 Kannan Achan。2020。面向电子商务的产品知识图谱嵌入。载于第13届网络搜索与数据挖掘国际会议论文集。672–680。[43] An Yan、Chaosheng Dong、Yan Gao、Jinmiao Fu、Tong Zhao、Yi Sun 和 Julian McAuley。2022。个性化互补产品推荐。载于 2022 年网络会议伴随论文集。146–151。[44] Yuan Yao 和 F. Maxwell Harper。2018。判断相似性：一项以用户为中心的相关物品推荐研究。载于第12届 ACM推荐系统会议论文集（RecSys '18）。288–296。[45] Wei Zhang、Zeyuan Chen、Hongyuan Zha 和 Jianyong Wang。2021。利用可替代与互补关系进行基于图的序列产品推荐。《ACM信息系统汇刊》（TOIS）（2021）。[46] Yin Zhang、Haokai Lu、Wei Niu 和 James Caverlee。2018。质量感知神经互补物品推荐。载于第12届 ACM推荐系统会议论文集。77–85。[47] Kui Zhao、Xia Hu、Jiajun Bu 和 Can Wang。2017。用于互补推荐的深度风格匹配。arXiv 预印本 arXiv:1708.07938（2017）。[48] Tong Zhao、Julian McAuley、Mengya Li 和 Irwin King。2017。利用可替代与互补产品网络提高推荐准确率。载于2017年国际神经网络联合会议（IJCNN）。[49] Jun-Yan Zhu、Taesung Park、Phillip Isola 和 Alexei A Efros。2017。使用循环一致对抗网络进行非配对图像到图像转换。载于 IEEE国际计算机视觉会议论文集。2223–2232。[50] Tao Zhu、Patrick Harrington、Junjun Li 和 Lei Tang。2014。电子商务中的捆绑推荐。载于第37届国际ACM SIGIR信息检索研究与发展会议论文集。657–666。