arXiv:2305.05267v2 [cs.IR] 5 Jun 2023

利用客户表示学习个性化页面内容排序

Xin Shen、Yan Zhao、Sujan Perera、Yujia Liu、Jinyun Yan、Mitchell Goodman

摘要——在电子商务商店中，有丰富的推荐内容可帮助购物者更高效地购物。然而，鉴于商品数量众多，选择最相关的内容以减轻信息过载的负担至关重要。我们推出了一项由线性因果老虎机算法驱动的内容排序服务，可根据不同情境为每位购物者排序并选择内容。该算法主要利用汇总的客户行为特征，而忽略单个购物者的过往活动。我们研究了如何根据历史活动推断购物者兴趣这一问题。我们提出了一种基于深度学习的老虎机算法，融合了历史购物行为、客户潜在购物目标，以及客户与内容类别之间的关联。该模型带来了更加个性化的内容排序，归一化折损累计增益提升了 12.08%。

关键词——信息系统；内容排序；个性化；应用计算；在线购物；内容多样性；因果老虎机；上下文老虎机；浏览归因；整体优化

一、引言

Walmart 和 eBay 等电子商务商店会生成产品推荐，以提升购物体验。这些推荐通常以轮播组件的形式呈现。例如，限时优惠组件汇集限时优惠，供顾客浏览；经常一起购买组件展示顾客常常一起购买的其他产品，供顾客考虑搭配购买；相似商品比较组件则列出替代产品并提供细致的比较，帮助顾客做出决定。这类推荐使在线购物区别于线下商店购物，因为在线购物者必须手动查找相关内容。然而，过多的推荐内容可能令人应接不暇，而不相关的内容则可能损害信任。为了筛选出最相关的内容，我们构建了一个内容优化系统，用于对组件候选项进行排序，并确定顾客访问网店时展示哪些内容。该系统通过优化能力平衡不同的业务目标和方法，并综合考虑顾客、内容及购物情境。

我们观察到，客户对内容有着独特的偏好。例如，对于寻求优惠和对价格敏感的客户，他们喜欢查看优惠内容中的商品；对于有偏好品牌的客户，他们会更多地浏览包含同一品牌或相似品牌商品的内容。当前的排序算法纳入了客户档案特征和聚合行为特征，却忽略了丰富的会话内活动。这些活动（例如浏览、点击、购买和评论商品）隐含地体现了购物兴趣和意图。本文研究如何通过从会话内活动中学习购物兴趣来提高排序效率。

为了推断客户在会话中的购物兴趣，需要一种可动态学习的过程，将客户的参与度、客户表征与不同内容相关联。挑战主要有两方面：

- 为了执行相关性运算，客户表示和内容表示必须在同一嵌入空间中对齐。通过拼接或池化特征嵌入来聚合潜在的参与商品表示可能过于简单，且缺乏可靠性保证。因此，问题在于如何获取这些表示，同时充分考虑客户的购物模式以及能够揭示客户偏好的内容主要特征。

- 为了优化我们的问题，学习客户表示、内容表示以及其他类别内容上下文（例如品牌）之间的潜在相关性至关重要。采用简单内积来确定相关性条件的传统方法 [12] 可能存在偏差，因为推荐内容为何能够引起客户兴趣，其背后的隐含推理并非确定性的。因此，有必要采用可学习的过程来完成这项优化工作。

我们的贡献 我们的工作提出了一种用于内容优化的神经老虎机方法，根据客户的购物偏好和购物任务对排序内容进行优先级排序，同时为实现整体商业优化目标作出贡献。具体技术贡献如下：

1) 我们提出了一种解决方案，使用客户的购物模式感知的商品类别表示 [11] 和细粒度商品嵌入 [16] 来生成内容表示和客户表示。这确保了这两种表示位于同一语义嵌入空间中，并包含客户的高层购物意图和细粒度购物偏好。2) 我们的新应用思路是使用通道注意力卷积神经网络进行跨特征优化。这种方法在优化商业目标的同时，动态学习不同特征表示之间的相关性。

II. 相关工作

A. 因果老虎机到内容优化

在推荐系统领域，探索策略的应用是一个活跃的研究方向。近年来，线性方法和深度神经网络方法均已出现，并展现出令人期待的成果 [3],[19] 由电子商务应用。为了优化商业价值，它

已知采用了我们开发的因果老虎机优化方法 [14] ，该方法考虑了内容类型、客户类型等因素。在这项工作中，重点是通过利用客户嵌入、内容表示以及客户与内容的相关性，采用更有效的老虎机优化方法来提升个性化内容排名的性能，旨在帮助客户实现购物目标，从而进一步优化商业影响。

B. 客户表示与产品嵌入

将客户的购物模式和互动行为高效编码为稠密表示，旨在潜在空间中捕捉每位客户的隐式购物意图。这些表示已被证明有助于个性化和推荐 [1], [9], [13], [18]。现有的大多数方法 [17], [25] 都提出了一种高效的方法来聚合客户表示，同时确保这些表示处于相同的产品嵌入空间中，以执行诸如产品推荐检索和相似客户检索等任务。我们的工作主要借鉴这些方法来构建客户表示和内容嵌入，并基于我们最新的工作构建能够感知购物意图的产品嵌入。

C. 多通道深度神经网络

卷积神经网络（CNNs）近年来取得了显著进展 [7], [8]。研究表明，CNNs 能够将广泛的特征图（不仅限于图像）编码为更高维流形中的稠密且复杂的表示 [10]。这种丰富的表示有助于许多下游优化任务，例如识别、回归和问答。大量研究致力于提升卷积神经网络（CNNs）的识别性能，相关的大量研究便是明证 [2], [20], [24]。然而，针对如何发挥 CNNs 在回归任务中的潜力，研究关注明显不足。近期研究表明，通过多通道方法增加特征表示，能够显著提升模型在回归任务中的泛化能力 [21], [22], ，但这种方法本身也存在局限。为了更稳健地学习此类表示，通道注意力机制的发展有助于提升 CNNs 动态学习不同层特征图之间相关性的能力 [4], [27]，[28]。通道注意力机制对于优化具有多通道输入特征图的任务尤其有用。我们提出将通道注意力网络创新性地应用于基于多通道特征的优化，以完成内容排序任务。实验结果表明，我们的方法优于现有方法，并展示了通道注意力网络在内容排序任务中的有效性。

III. 问题定义

如今的推荐系统会收集每位用户 $\mathcal{U}$ 与商品 i 之间的交互，并根据内容与每位顾客购物行为（即点击、浏览和偏好）的相关性对商品进行排序。类似地，对于我们的内容优化用例，我们可以将整个流程视为一个更广义的推荐系统模型，而推荐的商品就是商店内容组件组 $\mathcal{B}$。模型需要将每位顾客与不同内容关联起来，以实现个性化排序。我们假设，为每位顾客提供更加个性化且相关的内容，有助于实现我们的业务目标 $\mathcal{R}$。这个问题的优化目标可以形式化为：

$$\mathbb{E}(\mathcal{R}|\mathcal{U},\mathcal{B}), \tag{1}$$

在为每位顾客排列个性化内容小组件组的条件下，优化整个商店的业务目标 $\mathcal{R}$

IV. 方法

本节介绍一种基于深度学习的内容优化多臂老虎机框架。我们的方法包括构建个性化特征，并将多种特征建模为多臂老虎机，以便在优化业务目标 MOI 的同时对内容进行排序。

A. 特征

为开展内容优化并提升个性化能力，我们引入了 4 类特征 $[\beta, \lambda, \tau, \gamma]$ ，分别用于类别型多臂老虎机和潜在个性化多臂老虎机。有关这些特征的详细说明，请参阅下文相应的小节。

1) 静态分类老虎机：当客户访问 [14], 商店零售网站上的网页 $p \in \mathcal{P}$ 时，我们会获取客户上下文 $\mathcal{C}$ 和购物上下文 $\mathcal{X}$。也可以单独生成与每个候选内容对应的上下文 $\mathcal{Z}$。随后，我们以非线性方式组合上下文$\mathcal{C}$、 $\mathcal{X}$和 $\mathcal{Z}$，形成一个 d 维向量 $\beta \in \mathcal{R}^d$。我们将这种老虎机 β 称为分类特征。以下列出一些上下文示例供参考：

- 购物上下文：地区、网页类型、小组件组 ID、页面商品、页面商品的元数据以及搜索查询
- 客户上下文：近期互动事件、客户登录状态以及 Prime 会员状态
- 内容上下文：小组件 ID、小组件元信息以及内容属性

2) 潜在个性化老虎机：为了获得两个客户表示 λ 和 τ，按照类似的设置 [17], ，我们分别在产品类别层级 [11] 和商品层级 [16]汇总两种近期开发的产品嵌入技术。这些嵌入捕捉产品语义和购物者行为，例如共同浏览和共同购买的商品。来自产品类别层级汇总的客户表示 λ 提供了客户整体购物目标的高层次信号，而商品层级汇总 τ 则捕捉更细粒度的偏好，例如颜色和品牌。

对于内容表示 γ，我们汇总内容小组件中的所有产品，以确保 γ 处于与客户表示相同的嵌入空间中。例如，“再次购买”

小组件包含四种产品，我们使用产品类别级嵌入来编码该小组件的整体特征和用途。

在建模阶段，所有 $[\lambda, \tau, \gamma]$ 均作为潜在个性化老虎机特征。

B. 奖励

我们提出针对整体会话后续价值进行优化，该价值由客户与内容的交互产生，这与已有解决方案 [14] 一致。一旦完成排序并呈现内容，我们便会记录客户的交互事件，例如曝光、点击、购买及其他高价值操作。随后，使用后续一段时间内产生的总价值来计算我们关注的指标 MOI。值得注意的是，MOI 可以实时获取。符合预定义标准的内容将被赋予这一测量值作为奖励。内容排序模型随后会学习在特定情境下向客户展示内容时预测该会话后续价值，并据此做出排序决策。我们的方法会衡量并归因于客户与内容交互后，在所有设备、应用程序、小组件组和网页上的全站影响，

我们将其称为利用汇总会话后续价值，对多种内容类型进行整体优化。

C. 排序器模型

我们的目标是对候选内容集合 C_q 中每个符合条件的候选内容 c 进行排序，使排名靠前的 K 个排序内容T_q 能够根据每位客户的购物偏好和意图实现个性化，同时优化期望的奖励$\mathcal{R}$。我们提出的方法不同于我们在先前工作 [14]，中描述的线性建模方法，后者通过广义线性模型对 $\mathcal{R}$ 与类别型老虎机特征之间的相关性进行建模。相反，我们提出一种逐通道注意力深度神经网络方法 ResNeSt [27]，用于对类别型老虎机和潜在个性化老虎机到 $\mathcal{R}$ 的映射进行建模。我们允许该模型的跨通道注意力机制动态学习不同通道中所有特征之间的潜在相关性，尤其是内容表示 γ、客户表示 λ 和 τ 之间的语义相关性，从而将所有老虎机融合为高维流形上的稠密表示。随后，使用该稠密表示来优化指定的 $\mathcal{R}$。与许多现有的内容检索和搜索方法[12], [17], 相比，这些方法使用内积来计算客户表示与产品嵌入之间的排序分数，而我们的方法会在优化 $\mathcal{R}$ 的同时动态学习这种相关性，该指标代表期望的业务指标 MOI。

V. 模型评估与实验

在本节中，我们将评估所提出的方法，以研究围绕所提出创新点的以下研究问题（RQs）：

•研究问题1：所提出的个性化特征（包括客户表示和内容表示（λ、τ 和γ））是否提升了个性化排序性能?

•研究问题2：对于深度神经老虎机模型而言，分通道注意力机制是否是利用个性化特征的必要条件?

A. 离线结果

1）评估协议：我们使用以下指标评估所有模型：

1）回归指标。我们的问题是一个回归问题，需要对观测奖励 $\mathcal{R}$ 进行回归，然后对内容排序。虽然较低的回归误差并不总能保证更好的排序，但模型应力求降低回归误差，以改善排序，同时确保可解释性。我们提出两种广泛使用的回归指标：（1）均方误差损失，用于衡量回归质量，并体现偏差-方差权衡；它也是模型的训练损失函数；（2）平均绝对误差，其衡量回归质量的方式与均方误差类似，但对生产系统中常见的异常值不那么敏感。这两项指标还能进一步评估模型对数据的拟合程度，以判断特征与 $\mathcal{R}$之间是否存在相关性。

2）排序指标。我们模型的最终目标是对内容进行排序。在这项工作中，我们提出使用 NDCG@5（一种位置感知指标，用于衡量最终排序的质量，并为较高位置赋予更大的权重）；我们评估的页面只有 5 个展示位，因此将 NDCG 的测量范围限制在前 5 位。在这项工作中，为了评估个性化排序的改进情况，我们将互动奖励定义为 Re客户点击某项内容，并且还会产生下游会话奖励 R （我们关注的指标），因此 $Re = I(clicked) * R$，NDCG@5 因此定义为 $\frac{DCG_5}{IDCG_5}$，其中 $IDCG_5$ 是 DCG_5 的理想顺序，并且

$$DCG_5 = \sum_{i=1}^{5} \frac{Re_i}{log_2(i+1)}, \tag{2}$$

我们报告所有用户的平均指标。根据最佳验证集 NDCG@5 得分选择模型，并报告其在测试集上的表现。

2）基线方法：我们将提出的模型与基线方法进行比较，并开展实验，以考察（1）引入个性化特征的影响，以及（2）不同模型结构如何适配个性化特征及现有的类别特征：

1) 生产基线：该方法是一种静态推荐方法，目前已投入生产环境。我们使用了贝叶斯线性老虎机（Bayesian Linear Bandit），该算法利用静态类别特征（包括客户上下文，例如“is_prime_member”）以及静态内容特征，对内容进行排序，并在探索与利用之间进行权衡。

2）神经网络基线 A：近期关于神经老虎机的研究 [26]表明，其深层表示在探索方面具有较强的鲁棒性，因此我们实现了一种不使用注意力机制的前馈神经老虎机方法 [23]，并采用与生产基线相同的特征。此举旨在评估在线性方法与非线性方法下，我们的问题设置所产生的差异。

全部与生产基线比较：使用静态类别特征的广义线性模型				
标签	方法	均方误差损失降低幅度	平均绝对误差降低幅度	NDCG@5 提升幅度
为客户和内容使用静态类别特征				
1. 神经网络基线 A	具有类别特征的前馈神经网络模型	+2.78%	-4.25%	+5.59%
2. DIN-A	带类别特征的 DIN	-3.78%	+4.27%	-16.08%
同时使用客户和内容的静态类别特征与个性化特征				
3. 神经网络基线 B	采用我们的个性化特征和类别特征的神经网络基线	-6.70%	-1.68%	-0.99%
4. DIN-B	DIN-A，结合我们的个性化特征和类别特征	-26.58%	-27.59%	-34.27%
5. 我们的工作	基于 ResNeSt 的神经老虎机，结合我们的个性化特征和类别特征	-19.61%	-8.15%	**+16**.08%

表 I 离线结果表

3）DIN-A：我们进一步采用了亚马逊近期推出的先进（SOTA）注意力推荐模型 [16]，，该模型能够捕捉客户参与行为之间的交互。输入特征与生产基线保持一致。我们希望评估采用包含注意力机制的、更复杂的模型结构所带来的性能提升。

4) 神经网络基线 B 该模型结构与神经网络基线 A 相同，使用生产环境的类别特征和新提出的个性化特征。我们旨在评估在简单方案中纳入更多个性化特征所带来的增量收益。

5) DIN-B 我们采用了与生产环境相同的最先进注意力模型结构，既使用了生产环境的类别特征，也使用了我们提出的个性化特征。这是为了评估在最先进模型结构中加入更多个性化特征所带来的增量收益。

6) ResNeSt神经老虎机：这是所提出的模型结构，采用所需的分通道注意力机制 [27]，以便在我们的内容优化工作中恰当地学习类别特征与个性化特征之间的交互。

B. 性能比较

表 I 展示了我们提出的解决方案和基准测试在所有基准测试中的表现。采用 ResNeSt架构以及静态类别特征和个性化特征后，我们的解决方案在所有指标上均表现稳定，其中均方误差损失显著降低 19.61%，平均绝对误差显著降低 8.15%。与客户真实数据中偏好的内容相比，我们的解决方案还显著提升了归一化折损累计增益，证明了在优化所需奖励 R 的同时实现高相关性个性化内容排序的可行性。以下分析阐明了我们提出的个性化特征以及采用 ResNeSt 作为模型架构这两项贡献的必要性。

个性化特征重要性，研究问题1。实验1和实验2表明，仅使用静态类别特征和鲁棒模型架构无法提升性能。实验1中的神经网络基线 A 提升了归一化折损累计增益（+5.59%），但均方误差和平均绝对误差的下降情况不一致，这表明模型未能拟合类别特征。特征与优化目标 $\mathcal{R}$ 之间的相关性较弱，导致排序性能的保真度下降。实验2采用 DIN-A 和最先进模型结构，结果相似，个性化性能更差（归一化折损累计增益下降 -16.08%）。

另一方面，实验3（神经网络基线 B）和实验4（DIN-B）在输入我们提出的个性化特征后，模型拟合性能均得到稳定提升，均方误差损失和平均绝对误差也有所降低。这表明，我们提出的个性化特征与最终优化奖励 $\mathcal{R}$ 具有更强的相关性。

模型结构重要性，研究问题2。实验 3（神经网络基线 B）和实验 4（DIN-B）通过增强个性化特征与奖励 R 之间的相关性进行学习，但在个性化排序方面表现不佳（归一化折损累计增益分别下降 0.99% 和 34.27%）。这表明，简单的深度神经网络以及采用传统注意力层的 DIN 未能恰当地学习个性化特征。值得注意的是，所提出的采用分通道注意力的 ResNeSt 模型在模型拟合和个性化排序方面表现稳健，证明了我们提出的模型结构对于恰当学习个性化特征是必要的。

VI. 结论与未来工作

如今，电子商务的购物页面包含多种内容类型，以满足不同的购物者意图。为了有效地对这些内容类型进行排序，了解每位购物者的行为至关重要，而当前的内容排序解决方案并未考虑这一点。为此，我们提出了一种方法，利用粗粒度和细粒度产品嵌入来表示购物者偏好，与最先进的方法相比，能够提升内容排序效果。我们的结果表明，通过购物者的交互来了解其购物者意图，有望改善电子商务内容排序。未来，我们计划通过纳入更丰富的信息来增强产品嵌入，例如将用户的交互知识图谱作为先验，以及更丰富的目录数据，从而开发一种融合粗粒度和细粒度嵌入的内容排序方法 [5], [6], [15]。

参考文献

[1] Farah Tawfiq Abdul Hussien、Abdul Monem S Rahma 和 Hala B Abdulwahab。基于客户行为动态分析的电子商务推荐系统。《可持续发展》，13(19):10786，2021。 [2] Ahmed Ali Mohammed Al-Saffar、Hai Tao 和 Mohammed Ahmed Talab。深度卷积神经网络在图像分类中的综述。载于《2017年雷达、天线、微波、电子与电信国际会议（ICRA MET）论文集》，第26–31页。IEEE，2017。[3] Alberto Bietti、Alekh Agarwal 和 John Langford。上下文老虎机对比评测。《机器学习研究杂志》，22 5976，2021 1 5928( ): – 。[4] Long Chen、Hanwang Zhang、Jun Xiao、Liqiang Nie、Jian Shao、Wei Liu 和 Tat-Seng Chua。Sca-cnn：用于图像描述的卷积网络空间与通道注意力。载于《IEEE计算机视觉与模式识别会议论文集》，第5659–5667页，2017。[5] Yankai Chen、Menglin Yang、Yingxue Zhang、Mengchen Zhao、Ziqiao Meng、Jianye Hao 和 Irwin King。利用双曲几何对知识感知推荐中的无标度图进行建模。载于《第十五届ACM国际网络搜索与数据挖掘会议（WSDM）论文集》，第94–102页，2022。[6] Yankai Chen、Yaming Yang、Yujing Wang、Jing Bai、Xiangchen Song 和 Irwin King。协同引导的注意力知识感知图卷积网络，用于个性化推荐。载于《2022年IEEE第38届国际数据工程会议（ICDE）论文集》，第299–311页。IEEE，2022。 [7] Ian Goodfellow、Yoshua Bengio 和 Aaron Courville。卷积网络。载于《深度学习》，第2016卷，第330–372页。MIT出版社，美国马萨诸塞州剑桥，2016。 [8] Ian Goodfellow、Yoshua Bengio 和 Aaron Courville。《深度学习》。MIT出版社，2016。 [9] Joël Goossens、Tiblets Demewez 和 Marwan Hassani。通过考虑订单的推荐有效引导客户旅程。载于《2018年IEEE国际数据挖掘会议研讨会（ICDMW）论文集》，第828–837页。IEEE，2018。[10]Jiuxiang Gu、Zhenhua Wang、Jason Kuen、Lianyang Ma、Amir Shahroudy、Bing Shuai、Ting Liu、Xingxing Wang、Gang Wang、Jianfei Cai 等。卷积神经网络的最新进展。《模式识别》，77:354–377，2018。[11] Junheng Hao、Tong Zhao、Jin Li、Xin Luna Dong、Christos Faloutsos、Yizhou Sun 和 Wei Wang。P-companion：多样化互补产品推荐的原则性框架。载于CIKM，第2517–2524页，2020。 [12] Kohei Hirata、Daichi Amagata、Sumio Fujita 和 Takahiro Hara。高效且有效地解决多样性感知的最大内积搜索问题。载于《第16届ACM推荐系统大会论文集》，第198–207页，2022。 [13] Junzhong Ji、Zhiqiang Sha、Chunnian Liu 和 Ning Zhong。基于客户购物模型的电子商务在线推荐。载于《IEEE/WIC网络智能国际会议（WI 2003）论文集》，第68–74页。IEEE，2003。[14] Sameer Kanase、Yan Zhao、Shenghe Xu、Mitchell Goodman、Manohar Mandalapu、Benjamyn Ward、Chan Jeon、Shreya Kamath、Ben Cohen、Vlad Suslikov、Yujia Liu、Hengjia Zhang、Yannick Kimmel、Saad Khan、Brent Payne 和 Patricia Grao。因果老虎机在内容优化中的应用。载于《第5届在线推荐系统与用户建模研讨会（ORSUM 2022）论文集》，与《第16届ACM推荐系统大会（RecSys 2022）》同期举行，美国华盛顿州西雅图，2022。[15] Jiacheng Li、Ming Wang、Jin Li、Jinmiao Fu、Xin Shen、Jingbo Shang 和 Julian McAuley。文本就是你所需要的一切：为序列推荐学习语言表示，2023。[16] Aashiq Muhamed、Iman Keivanloo、Sujan Perera、James Mracek、Yi Xu、Qingjun Cui、Santosh Rajagopalan、Belinda Zeng 和 Trishul Chilimbi。Ctr-bert：针对十亿参数教师模型的高性价比知识蒸馏。载于NeurIPS高效自然语言与语音处理研讨会，2021。[17] Aditya Pal、Chantat Eksombatchai、Yitong Zhou、Bo Zhao、Charles Rosenberg 和 Jure Leskovec。Pinnersage：用于Pinterest推荐的多模态用户嵌入框架。载于《第26届ACM SIGKDD知识发现与数据挖掘国际会议论文集》，第2311–2320页，2020。 [18] You-Jin Park 和 Kun-Nyeong Chang。基于个人及群体行为的个性化产品推荐客户画像模型。《应用专家系统》，36(2):1932–1939，2009。

[19] Carlos Riquelme、George Tucker 和 Jasper Snoek。深度贝叶斯老虎机对决：用于汤普森采样的贝叶斯深度网络实证比较。arXiv 预印本 arXiv:1802.09127，2018。[20] Xin Shen、Praful Agrawal 和 Zhong wei Cheng。针对时尚检测，基于不平衡标签样本分布进行数据高效训练，2023年。[21] Xin Shen、Kyungdon Joo 和 Jean Oh。Fishrecgan：一种用于鱼眼校正与标定的端到端生成对抗网络，2023年。[22] Xin Shen、Xiaonan Zhao 和 Rui Luo。语义嵌入深度神经网络：提升多标签图像分类性能的通用方法，2023年。[23] Ashish Vaswani、Noam Shazeer、Niki Parmar、Jakob Uszkoreit、Llion Jones、Aidan N Gomez、Łukasz Kaiser 和 Illia Polosukhin。注意力就是一切。NeurIPS，30，2017。[24] Ruyue Xin、Jiang Zhang 和 Yitong Shao。使用卷积神经网络进行复杂网络分类。《清华大学学报（英文版）》，25(4):447–457，2020。[25] Jiajing Xu、Andrew Zhai 和 Charles Rosenberg。重新思考 Pinterest 上的个性化排序：一种端到端方法。载于第 16 届 ACM推荐系统大会论文集，页码 –，2022。[26] Pan Xu、Zheng Wen、Handong Zhao 和 Quanquan Gu。基于深层表示与浅层探索的神经上下文老虎机。arXiv 预印本 arXiv:2012.01780，2020。[27] Hang Zhang、Chongruo Wu、Zhongyue Zhang、Yi Zhu、Haibin Lin、Zhi Zhang、Yue Sun、Tong He、Jonas Mueller、R Manmatha 等。ResNeSt：分裂注意力网络。载于IEEE/CVF计算机视觉与模式识别会议论文集，页码 2736–2746，2022。[28] Yulun Zhang、Kunpeng Li、Kai Li、Lichen Wang、Bineng Zhong 和 Yun Fu。使用超深残差通道注意力网络进行图像超分辨率。载于欧洲计算机视觉会议（ECCV）论文集，页码 286–301，2018。