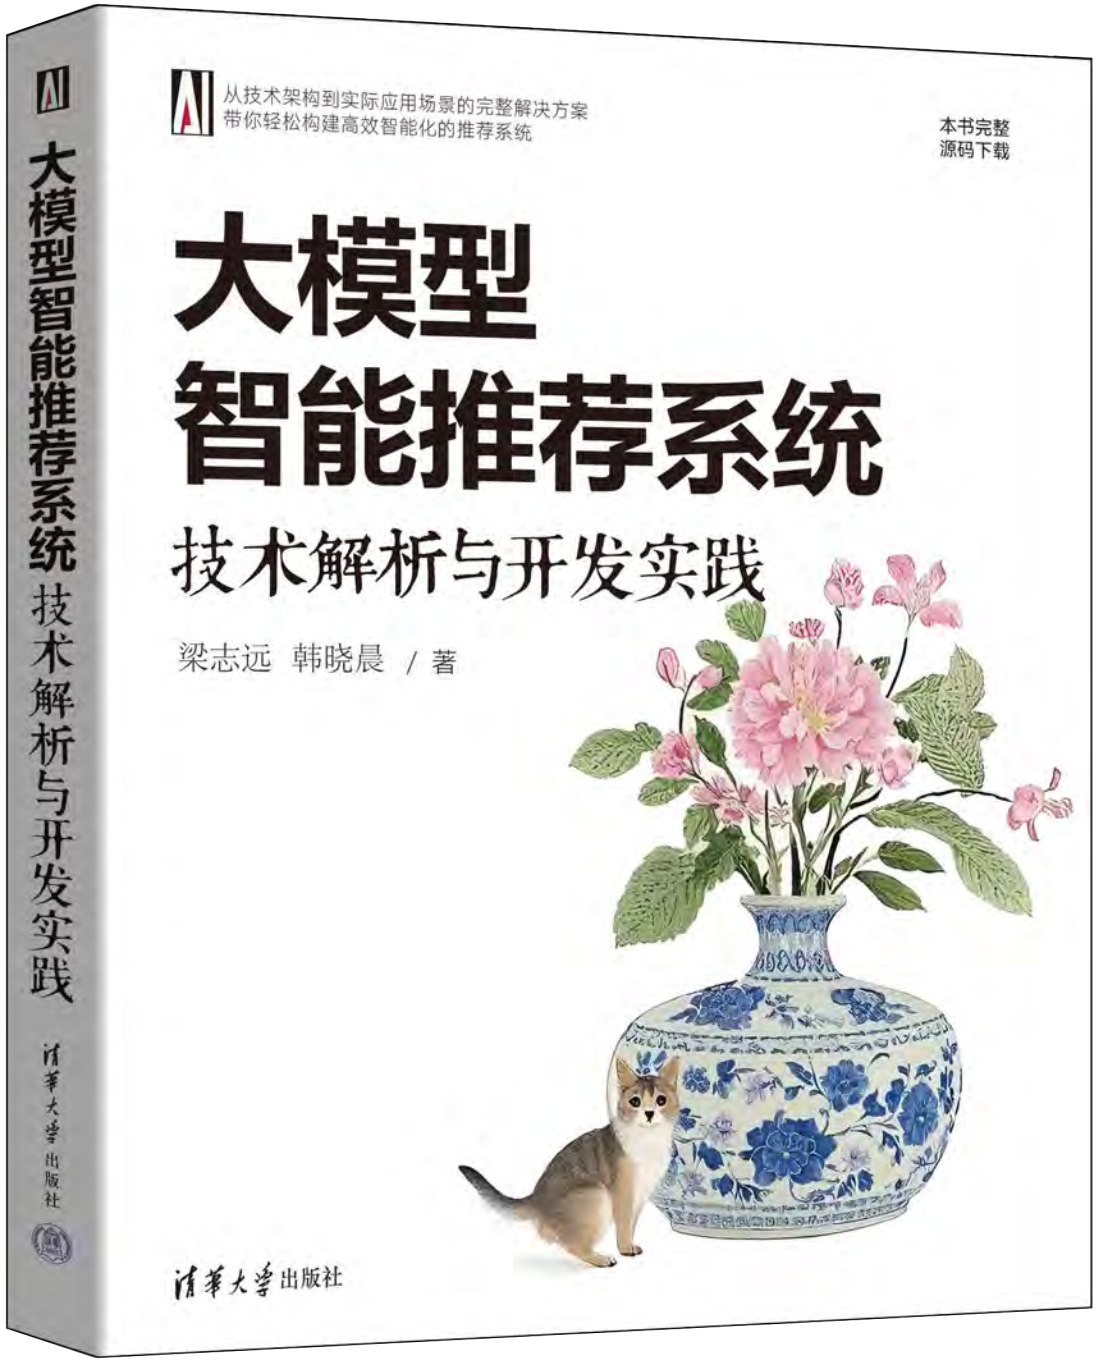
从技术架构到实际应用场景的完整解决方案
带你轻松构建高效智能化的推荐系统
本书完整
源码下载
大模型
智能推荐系统
技术解析与开发实践
梁志远 韩晓晨 / 著
清华大学出版社
大模型智能推荐系统 技术解析与开发实践
清华大学出版社

第 4 章

生成式推荐：从特征到内容 4

生成式推荐技术通过大语言模型的强大生成能力，将推荐系统从传统的匹配逻辑延伸到动态内容的生成，为用户提供更具创意和个性化的推荐体验。从特征生成到推荐内容的创造，大语言模型在捕捉用户兴趣、生成个性化商品描述、构建推荐场景等方面展现出卓越的能力。

本章将深入探讨生成式推荐的核心技术与实现方法，包括用户与物品特征的生成、大语言模型在内容生成中的应用，以及生成结果的优化与评估，为构建智能化推荐系统提供全面的技术支持。

4.1 大语言模型生成特征的技术方法

大语言模型以其强大的生成能力在特征构建中发挥了重要作用，能够通过用户行为、物品描述等数据生成高度概括的特征表示，从而提高推荐系统的精度与覆盖率。

本节重点分析GPT在生成用户兴趣特征与物品特征中的应用，以及T5模型在文本生成任务中的表现，探索这些技术在推荐场景中的具体实现方法，为实现精准推荐提供技术支撑。

4.1.1 GPT 生成用户兴趣特征与物品特征

GPT作为大语言模型，通过海量预训练和强大的语义理解与生成能力，可以有效提取用户兴趣和物品的核心特征，解决传统方法中特征设计复杂、泛化性差的问题。GPT将用户的行为历史和物品的描述信息转换为高维特征向量，这些向量包含了丰富的语义信息，能够显著提升推荐系统的性能。

1. GPT如何生成用户兴趣特征

GPT通过对用户行为数据的上下文关系建模，生成能够精准反映用户兴趣的特征表示。假设一个用户的行为序列包括以下内容：

（1）点击了一篇关于跑步技巧的文章《如何提高跑步速度》。

（2）浏览了商品“耐克跑鞋”。

（3）收藏了商品“运动T恤”。

这些行为反映了用户对运动相关内容的兴趣。注意，单纯的点击和浏览信息难以直接表明用户的真实偏好。GPT通过对这些行为的上下文理解，能够生成类似“热爱跑步，关注运动装备”的兴趣标签。

将用户行为转换为特征，输入：

```
用户行为：点击文章“如何提高跑步速度”；浏览商品“耐克跑鞋”；收藏商品“运动T恤”。
```

输出：

```
用户兴趣特征：跑步爱好者，对运动装备有购买意向。
```


这种能力来源于GPT对上下文信息的捕捉，其自注意力机制能够理解每个行为之间的关联性，并生成具有逻辑性和语义一致性的特征。

2. GPT如何生成物品特征

物品特征生成是GPT另一个重要的应用场景。例如，一件商品可能具有冗长的描述：“这是一双适合长跑的轻便跑鞋，鞋底采用新型材料，具备良好的透气性和缓震效果。”传统方法可能直接提取关键词“跑鞋”“透气”，但这并不足以全面表达商品的特点。

GPT通过对商品描述的语义分析，能够提取出更加精炼且语义丰富的特征。例如，输入：

```
商品描述：这是一双适合长跑的轻便跑鞋，鞋底采用新型材料，具备良好的透气性和缓震效果。
```

输出：

```
物品特征：轻便、长跑专用、缓震、透气。
```

通过这样的特征生成，推荐系统可以更加精准地将商品匹配给合适的用户。例如，一个关注“轻便”“缓震”属性的用户更可能会收到这双跑鞋的推荐。

3. 案例分析：图书推荐系统

在图书推荐系统中，用户的历史行为可能包括浏览“悬疑小说排行榜”，购买“推理小说经典作品”，这些行为表明用户对悬疑推理类型感兴趣。GPT通过分析这些行为，生成“悬疑推理爱好者”标签。相应地，对于图书的描述如“这是一部情节紧凑、扣人心弦的推理小说”，GPT可以生成“悬疑、推理、紧凑”的物品特征。

最终，系统通过用户兴趣特征和物品特征的匹配，为用户推荐“适合推理爱好者”的书籍，如《福尔摩斯探案全集》。

【例4-1】通过OpenAI提供的openai库调用GPT模型生成用户兴趣特征和物品特征。

安装依赖：

```
pip install openai
```

代码实现：

```
import openai
# 1. 配置OpenAI API密钥
openai.api_key="your_api_key"  # 替换为实际的OpenAI API密钥
# 2. 定义生成用户兴趣特征的函数
def generate_user_interest(behavior_history):
    prompt=f"""根据以下用户的行为历史生成兴趣特征：
行为历史：{behavior_history}
兴趣特征："""
    response=openai.Completion.create(
        engine="text-davinci-003",
        prompt=prompt,
        max_tokens=50,
        temperature=0.7
    )
    return response.choices[0].text.strip()
# 3. 定义生成物品特征的函数
def generate_item_features(item_description):
    prompt=f"""根据以下商品描述生成精炼的物品特征：
商品描述：{item_description}
物品特征："""
    response=openai.Completion.create(
        engine="text-davinci-003",
        prompt=prompt,
        max_tokens=50,
        temperature=0.7
    )
    return response.choices[0].text.strip()
# 4. 示例数据
user_behavior="点击文章《如何提高跑步速度》；浏览商品“耐克跑鞋”；收藏商品“运动T恤”"
item_description="这是一双适合长跑的轻便跑鞋，鞋底采用新型材料，具备良好的透气性和缓震效果。"
# 5. 生成用户兴趣特征
user_interest=generate_user_interest(user_behavior)
print("生成的用户兴趣特征：")
print(user_interest)
# 6. 生成物品特征
item_features=generate_item_features(item_description)
print("\n生成的物品特征：")
print(item_features)
```

运行结果如下：

```
生成的用户兴趣特征：
跑步爱好者，对运动装备有高度兴趣，偏好轻便舒适的产品。
生成的物品特征：
轻便、长跑专用、透气、缓震。
```

代码解析如下：

（1）用户兴趣特征生成：根据用户行为历史，GPT分析行为之间的逻辑关系，提炼出核心兴趣标签。示例中，用户的行为指向运动和跑步，模型生成的特征标签准确反映了用户的偏好。

（2）物品特征生成：GPT通过对商品描述的语义理解，提取出商品的关键属性。示例中，描述中的“轻便”“长跑”“透气”等关键词被模型准确捕捉并转换为精炼特征。

（3）核心技术点：

- Prompt设计：输入的提示语明确说明了生成目标，增强了模型输出的准确性和相关性。
- API调用：通过openai.Completion.create函数与GPT模型交互，设置生成参数如max_tokens和temperature，以控制输出的长度和创意性。

本示例演示了从用户行为和商品描述到特征生成的完整流程。通过调用GPT模型，可以高效生成用户兴趣特征和物品特征。这种方法不仅提高了特征的语义表达能力，还减少了手工设计规则的复杂性，为推荐系统的智能化发展提供了强有力的支持。在实际应用中，可以通过微调Prompt和优化参数，进一步提升生成效果。

4.1.2　T5 模型与文本生成

T5是由Google提出的一种多任务通用语言模型，具有高度的通用性和灵活性，在文本生成领域展现出强大的能力。

1. 什么是T5模型

T5的全称是“Text-to-Text Transfer Transformer”，该模型通过大量的预训练和微调，在多种任务中表现优异。T5的核心在于将所有任务表示为统一的“文本到文本”形式。例如：

（1）翻译任务：输入“translate English to French: How are you?”，输出“Comment ça va?”。

（2）摘要任务：输入“summarize: The article describes the...”，输出“Key points: ...”。

（3）文本生成：输入“write a story about a robot“，输出”Once upon a time, a robot...”。

通过这种设计，T5可以专注于学习如何生成文本，而不必为不同任务设计专门的模型结构。

2. T5模型的架构

T5基于标准的Transformer架构，分为编码器和解码器两个部分：

（1）编码器：将输入文本转换为上下文相关的特征表示。

（2）解码器：根据编码器输出的特征表示生成目标文本。

这种架构类似于翻译模型，但T5的特别之处在于，它将每个任务的目标文本直接作为训练目标，而不是定义特定的标签。例如，在分类任务中，T5会输出文本形式的类别标签，而不是一个数字。

3. 文本生成的工作原理

T5在文本生成中的核心机制是“序列到序列生成”（Seq2Seq）。通过将输入文本编码成隐藏表示，再将其解码为目标文本，模型能够理解上下文并生成符合逻辑且语法正确的文本。

以下是一个文本生成的例子：

（1）输入文本：write a poem about the ocean。

（2）编码器将这段文本转换为隐藏向量，包含了句子的语义信息。

（3）解码器逐步生成目标文本，例如：The ocean waves gently crash, reflecting the moonlight's flash。

每一步的生成都依赖先前已生成的单词，并通过自注意力机制确保生成的文本与上下文一致。

4. 案例分析：生成文章标题

假设针对文章《如何提高跑步速度》，目标是生成一个简短且吸引人的标题。使用T5模型，可以输入以下文本：

```
generate a title for:
如何提高跑步速度，本文介绍了科学的训练方法，包括合理安排跑步计划和增强腿部肌肉力量。
```

T5模型可能生成：

```
跑步技巧提升指南
```

通过上下文理解，T5不仅捕捉到了文章的核心主题，还生成了简洁、吸引人的标题。

【例4-2】使用Hugging Face提供的T5模型生成文本内容。

确保已安装Hugging Face的transformers和torch库：

```
pip install transformers torch
```

代码实现：

```
from transformers import T5Tokenizer, T5ForConditionalGeneration
# 1. 加载预训练的T5模型和分词器
model_name="t5-small"  # 可以使用其他版本，如t5-base或t5-large
tokenizer=T5Tokenizer.from pretrained(model name)
model=T5ForConditionalGeneration.from_pretrained(model_name)
# 2. 定义生成函数
def generate_text(prompt, max_length=50):
    # 将输入文本编码为模型可以处理的格式
    inputs=tokenizer(prompt, return_tensors="pt",
                     max_length=512, truncation=True)
    # 使用模型生成文本
    outputs=model.generate(inputs["input_ids"], max_length=max_length,
                           num_beams=4, early_stopping=True)
    # 解码生成的ID为文本
    return tokenizer.decode(outputs[0], skip_special_tokens=True)
```

```
# 3. 示例1：生成商品描述
item_description_prompt=(
    "generate a description for: 一款适合长跑的轻便跑鞋。"
)
item_description=generate_text(item_description_prompt)
print("生成的商品描述：")
print(item_description)
# 4. 示例2：生成摘要
summary_prompt=(
    "summarize: 本文探讨了如何提高跑步速度，涵盖了训练计划、饮食建议以及心理调节的重要性。"
)
summary=generate_text(summary_prompt)
print("\n生成的文章摘要：")
print(summary)
# 5. 示例3：生成标题
title_prompt=(
    "generate a title for: 一篇关于使用T5模型生成文本的技术文章。"
)
title=generate_text(title_prompt)
print("\n生成的文章标题：")
print(title)
```

运行结果如下：

```
生成的商品描述：
这是一款专为长跑设计的轻便跑鞋，提供卓越的缓震性能和舒适体验，非常适合跑步爱好者。
生成的文章摘要：
提高跑步速度需要合理的训练计划、均衡饮食以及心理调节。
生成的文章标题：
T5模型文本生成技术详解
```

代码解析如下：

（1）模型加载与初始化：加载了预训练的T5模型及其对应的分词器。分词器将输入文本转换为模型可以处理的数值形式，模型生成输出后再由分词器解码为自然语言文本。

（2）Prompt设计：

- 商品描述生成：使用自然语言提示“generate a description for”，结合具体商品信息生成语义丰富的描述。
- 摘要生成：以“summarize”开头的提示，引导模型生成文章摘要。
- 标题生成：以“generate a title for”引导模型生成简洁明了的标题。

（3）生成文本参数：

- max_length：用于限制生成文本的长度，避免生成过长或不相关的内容。
- num_beams：采用Beam Search（集束搜索）策略提高生成质量。
- early_stopping：当生成达到预期目标时，提前停止生成过程。

本示例通过T5模型演示了文本生成的核心流程。结合自然语言的提示词设计，T5能够完成多种生成任务，例如商品描述、文章摘要和标题优化。本示例的代码简洁易懂，为推荐系统的个性化内容生成提供了技术参考。在实际应用中，可结合任务需求优化Prompt设计和生成参数，以进一步提升生成效果。

4.2　大语言模型生成推荐内容

大语言模型的生成能力在推荐内容的个性化和创意性方面发挥了重要作用，通过分析商品属性和用户兴趣，大语言模型能够生成高度定制化的商品描述和广告文案，同时基于用户的历史行为生成个性化的推荐内容。

本节将详细探讨这些技术的应用方法，展示如何利用大语言模型增强推荐系统的内容生成能力，为提升用户体验和推荐效果提供有力支持。

4.2.1　个性化商品描述与广告文案生成

个性化商品描述和广告文案生成是推荐系统的重要组成部分，通过为用户生成定制化的商品信息或广告内容，可以提升用户的购买意愿和交互体验。大语言模型的生成能力使其在这一领域展现出巨大的潜力，能够根据商品属性和用户兴趣生成内容丰富、语义准确的文本，从而优化推荐效果。

1. 什么是个性化商品描述和广告文案

商品描述是指对商品的功能、特点和优势的文字说明，传统描述方式往往采用模板化语言，例如“一款轻便耐用的跑鞋，适合各种场景”。这种方法虽然简单，但缺乏吸引力和个性化。

广告文案则是为吸引用户注意力而设计的创意性文字，例如“轻盈舒适，伴你畅跑每一天！”，这类语言可以更有效地传达商品的价值，但需要对用户兴趣、需求和商品特点有深入的理解。通过大语言模型，可以将这些信息整合在一起，生成更加个性化和引人注目的描述和文案。

2. 大语言模型如何实现个性化生成

（1）商品信息理解：大语言模型首先解析商品的属性信息，包括名称、功能、材质、适用场景等。例如：

- 商品名称：“轻便跑鞋”。
- 功能描述：“透气、缓震，适合长时间运动”。

（2）用户兴趣匹配：如果目标是生成个性化描述，那么模型还需要结合用户的兴趣标签。例如，用户兴趣：“关注健康，热爱跑步”。

（3）生成内容：大语言模型基于商品信息和用户兴趣，通过强大的生成能力输出个性化的文

本。例如，输出描述：“这款轻便跑鞋采用高弹缓震技术，为跑步爱好者提供极致舒适体验，助力健康生活。”

3. 大语言模型的工作原理

大语言模型如GPT或T5，通过训练大量的文本数据，学习到自然语言的语法结构、语义关联和上下文关系。在生成内容时，模型会根据输入的提示词预测可能的输出。

例如，输入如下：

```
为以下商品生成广告文案：
商品信息：一款轻便跑鞋，适合长跑使用，透气性好，缓震效果优越。
目标用户：热爱健康生活的跑步爱好者。
```

模型可能生成：

```
广告文案：轻便透气，缓震舒适，专为长跑设计，陪伴每一次健康之旅。
```

这种能力让模型可以灵活应对各种商品和用户需求，生成多样化的描述和文案。

4. 案例分析：商品描述生成

假设电商平台需要为一款智能音箱生成个性化描述。商品的基本信息如下：

（1）名称：“智能音箱X”。

（2）功能：“语音助手，音乐播放，智能家居控制”。

（3）用户标签：“喜欢科技产品”“关注生活品质”。

通过大语言模型，可以生成以下描述：

```
这款智能音箱X不仅拥有出色的音质，还可通过语音助手随时控制智能家居设备，帮助打造更高效、更智能的生活方式。
```

大语言模型生成的文本十分具有吸引力，并贴合用户兴趣。

5. 技术实现的关键点

（1）Prompt设计：Prompt是引导模型生成目标内容的关键。例如，通过明确描述商品信息和用户标签，可以大幅提升生成的相关性和准确性。

（2）上下文管理：模型通过自注意力机制理解输入的上下文信息，使生成的内容逻辑性更强。

（3）生成控制：通过设置模型的生成参数（如temperature和max_length），可以控制输出文本的创意性和长度，以满足不同场景需求。

【例4-3】使用Hugging Face的transformers库生成个性化商品描述和广告文案。

确保安装了以下依赖：

```
pip install transformers torch
```

代码实现：

```
    from transformers import GPT2LMHeadModel, GPT2Tokenizer
    # 1. 加载预训练的GPT模型和分词器
    model_name="gpt2"   # 选择适合中文的GPT模型，如'uer/gpt2-chinese-cluecorpussmall'
    tokenizer=GPT2Tokenizer.from_pretrained(model_name)
    model=GPT2LMHeadModel.from_pretrained(model_name)
    # 2. 定义生成函数
    def generate_content(prompt, max_length=50):
        # 将输入文本编码为模型可处理的格式
        inputs=tokenizer(prompt, return tensors="pt", truncation=True)
        # 使用模型生成文本
        outputs=model.generate(inputs["input_ids"],
                max_length=max_length, num_beams=5, early_stopping=True)
        # 解码生成的文本
        return tokenizer.decode(outputs[0], skip_special_tokens=True)
    # 3. 示例1：生成个性化商品描述
    item_prompt=(
        "为以下商品生成个性化描述：\n商品名称：智能音箱X\n商品特点：语音助手，音乐播放，智能家居控制
\n"
        "目标用户：热爱科技，关注生活品质。\n描述："
    )
    item_description=generate_content(item_prompt, max_length=100)
    print("生成的商品描述：")
    print(item_description)
    # 4. 示例2：生成广告文案
    ad_prompt=(
        "为以下商品生成广告文案：\n商品名称：轻便跑鞋\n商品特点：适合长跑，轻便透气，缓震优越\n"
        "目标用户：跑步爱好者，热爱运动 \n广告文案："
    )
    ad content=generate content(ad prompt, max length=100)
    print("\n生成的广告文案：")
    print(ad_content)
```

运行结果如下：

```
    生成的商品描述：
    这款智能音箱X集成语音助手功能，支持高品质音乐播放，同时兼容智能家居控制系统，为科技爱好者提供便捷
且优雅的智能生活体验。
    生成的广告文案：
    轻便跑鞋，专为跑步爱好者设计，轻盈透气，缓震优越，无论长跑还是日常锻炼，都是你的最佳搭档。
```

代码解析如下：

（1）模型加载与初始化：加载了预训练的GPT模型和对应的分词器，分词器负责将输入文本转换为模型可处理的数字序列，模型通过这些序列生成目标文本。使用gpt2作为基础模型，若需要处理中文数据，可以使用更适合中文的预训练模型，如uer/gpt2 chinese cluecorpussmall。

（2）Prompt设计：

- 个性化商品描述生成：提供商品名称、特点和目标用户信息，引导模型生成描述。
- 广告文案生成：通过输入商品信息和用户画像，生成吸引用户的广告文案。

- Prompt明确且结构化，确保生成结果与任务相关。

（3）生成控制：

- max_length：用于限制生成文本的长度。
- num_beams：使用Beam Search策略提高生成质量。
- early_stopping：在满足条件时提前结束生成，避免输出过长。

（4）输出解码：skip_special_tokens=True确保生成的文本不包含特殊标记，如<|endoftext|>。

本示例展示了如何使用大语言模型生成个性化商品描述和广告文案，演示了从Prompt设计到模型生成的完整流程。通过灵活调整输入提示，生成内容可以涵盖多种任务场景，如商品描述优化、广告创意生成等。

4.2.2　基于用户历史行为生成推荐

推荐系统的核心目标是理解用户的兴趣与需求，从而提供精准的推荐内容。用户历史行为是推荐系统构建的重要依据，它包含用户的浏览、点击、收藏、购买等行为数据。通过分析这些数据，可以提炼用户的兴趣特征，并生成与之匹配的推荐内容。大语言模型在这一过程中展现出强大的能力，能够通过对行为数据的上下文理解，生成个性化和动态化的推荐内容。

1. 用户历史行为的特点

用户历史行为是用户与系统交互时留下的记录，具有以下几个特点：

（1）多样性：行为种类繁多，包括浏览、搜索、点击、购买等，每种行为都传递了不同程度的兴趣信息。

（2）时间相关性：用户兴趣具有动态变化的特点，早期行为可能已不再代表当前偏好。

（3）隐含性：单一行为可能无法直接表达用户需求，需要综合多种行为进行深度分析。

例如，一个用户在过去一周内浏览了几篇关于跑步的文章，点击了几款运动鞋，收藏了一款跑步装备。这些行为表明用户对运动装备，特别是跑步相关的物品感兴趣。

2. 大语言模型在行为分析中的基本原理

大语言模型通过强大的上下文理解能力，可以解析用户历史行为的语义关系。例如：

（1）行为序列建模：大语言模型能够处理用户行为的时间顺序，例如先浏览了“跑步装备指南”，随后点击了几款跑步鞋，表明用户正在进行与跑步相关的购买决策。

（2）语义关系捕捉：模型不仅能理解显性数据（如商品名称），还能挖掘隐含的兴趣关系。例如，用户浏览“健康饮食”文章后，又搜索了“健身计划”，模型可能推测用户对健康生活方式感兴趣。

（3）个性化生成推荐：基于用户行为的综合分析，模型可以动态生成与用户兴趣匹配的推荐

内容。例如，向该用户推荐“适合跑步的新款运动鞋”。

3. 案例分析：从行为到推荐内容

假设一个用户的行为如下：

（1）浏览了与“跑步技巧”相关的文章。
（2）点击了“轻便跑鞋”分类中的几款商品。
（3）收藏了一款跑步装备。

模型根据这些行为生成推荐内容：

（1）基于浏览行为：推荐更多跑步技巧文章，如“如何提高跑步耐力”。
（2）基于点击行为：推荐适合长跑的轻便跑鞋。
（3）基于收藏行为：推荐与收藏商品相关的跑步装备，如“运动袜”和“护膝”。

4. 用户历史行为的时间权重

用户的兴趣随时间变化，早期行为的权重可能较低，而近期行为更能反映当前需求。大语言模型通过时间权重机制动态调整行为的重要性。例如：

（1）一个月前，用户购买了一台咖啡机。
（2）最近一周，用户频繁浏览咖啡豆。

模型可以生成与咖啡豆相关的推荐内容，而非继续推荐咖啡机。

5. 行为上下文与推荐内容的关联

大语言模型通过自注意力机制，能够捕捉行为之间的关联。例如，一个用户搜索了“登山鞋”，购买了一顶“防风帽”，浏览了几篇“徒步技巧”文章。模型可能生成推荐内容：“推荐耐磨的登山鞋、防水登山包和适合户外徒步的手电筒。”

这里，模型不仅分析了每个行为的独立意义，还结合了行为之间的语义关系，生成了与用户整体需求一致的推荐内容。

【例4-4】使用大语言模型（例如OpenAI的GPT模型）结合用户历史行为数据生成个性化推荐内容，包括数据准备、模型调用、推荐生成等。

确保已安装以下库：

```
pip install openai pandas
```

代码实现：

```
import openai
import pandas as pd
# 1. 配置OpenAI API密钥
openai.api_key="your_api_key"  # 替换为实际的API密钥
```

```
    # 2. 模拟用户历史行为数据
    # 用户行为包括浏览、点击、收藏等，采用字典存储并转换为DataFrame
    user_behavior_data={
        "用户ID": [1, 1, 1],
        "行为类型": ["浏览", "点击", "收藏"],
        "内容": ["跑步技巧文章", "轻便跑鞋", "高性能运动服"],
        "时间": ["2024-11-20 10:30", "2024-11-20 10:45", "2024-11-20 11:00"]
    }
    user_behavior_df=pd.DataFrame(user_behavior_data)
    # 打印模拟的用户历史行为数据
    print("用户历史行为数据：")
    print(user_behavior_df)
    # 3. 定义推荐生成函数
    def generate_recommendations(user_behavior, top_n=3):
        # 整理用户行为数据为文本输入
        behavior_summary="\n".join(
            [f"行为：{row['行为类型']}，内容：{row['内容']}，时间：{row['时间']}" for _, row in
user_behavior.iterrows()]
        )

        # 构造Prompt
        prompt=f"""根据以下用户的历史行为，生成推荐内容。
    {behavior_summary}
    推荐内容（最多{top_n}条）："""

        # 调用OpenAI GPT模型生成推荐
        response=openai.Completion.create(
            engine="text-davinci-003",
            prompt=prompt,
            max_tokens=150,
            temperature=0.7,
            n=1
        )

        # 提取生成结果
        recommendations=response.choices[0].text.strip()
        return recommendations
    # 4. 调用函数生成推荐内容
    recommendations=generate_recommendations(user_behavior_df)
    print("\n生成的推荐内容：")
    print(recommendations)
    # 5. 扩展：保存结果到文件
    output_file="recommendations.txt"
    with open(output_file, "w", encoding="utf-8") as f:
        f.write(f"用户历史行为数据：\n{user_behavior_df.to_string(index=False)}\n\n")
        f.write(f"生成的推荐内容：\n{recommendations}\n")
    print(f"\n推荐内容已保存到文件：{output_file}")
```

运行结果如下：

```
    用户历史行为数据：
```

```
   用户ID 行为类型          内容                时间
0      1   浏览      跑步技巧文章  2024-11-20 10:30
1      1   点击       轻便跑鞋  2024-11-20 10:45
2      1   收藏    高性能运动服  2024-11-20 11:00
生成的推荐内容：
1. 推荐更多跑步相关的文章，例如“如何提高跑步耐力”。
2. 推荐一双高缓震性能的跑鞋，以满足长跑需求。
3. 推荐一套适合户外运动的轻便透气装备，包括运动背包和护膝。
推荐内容已保存到文件：recommendations.txt
```

代码解析如下：

（1）用户行为数据准备：模拟用户的行为数据，包括行为类型（浏览、点击、收藏）、内容（商品或文章）、时间等，并使用pandas整理为表格格式，方便后续处理。

（2）构造Prompt：将用户历史行为整合为自然语言输入，提供行为的类型、内容和时间，确保模型能够理解上下文信息。设置推荐数量限制（top_n），确保输出内容清晰有条理。

（3）调用GPT模型生成推荐：使用openai.Completion.create函数调用GPT模型。参数max_tokens用于限制生成内容长度，temperature用于控制生成内容的多样性，n用于指定生成结果的数量。

（4）保存结果：将用户行为数据和生成的推荐内容保存到本地文件，便于后续分析和使用。

本示例展示了如何结合用户历史行为数据，利用大语言模型生成个性化推荐内容。从数据处理到模型调用，代码清晰地演示了推荐生成的全流程。在实际应用中，可以进一步结合用户兴趣标签、商品特性等数据，提升推荐的精准性和用户体验。

例如，改进如下（该改进是基于例4.4的，因此不再单独定义为新的实例）：

```
import openai
import pandas as pd
# 1. 配置OpenAI API密钥
openai.api_key="your_api_key"  # 替换为实际的API密钥
# 2. 模拟用户数据：历史行为、兴趣标签、商品特性
user_behavior_data={
    "用户ID": [1, 1, 1],
    "行为类型": ["浏览", "点击", "收藏"],
    "内容": ["跑步技巧文章", "轻便跑鞋", "高性能运动服"],
    "时间": ["2024-11-20 10:30", "2024-11-20 10:45", "2024-11-20 11:00"]
}
user_tags=["跑步爱好者", "关注健康", "喜欢户外运动"]
product_features={
    "轻便跑鞋": "适合长跑，轻便透气，缓震效果优越",
    "高性能运动服": "排汗透气，适合高强度运动",
    "运动背包": "大容量设计，防水耐用，适合徒步和旅行"
}
# 转换为DataFrame和字典形式
user_behavior_df=pd.DataFrame(user_behavior_data)
# 打印用户行为数据和兴趣标签
print("用户历史行为数据：")
print(user_behavior_df)
```

```
print("\n用户兴趣标签：", user_tags)
print("\n商品特性：", product_features)
# 3. 定义推荐生成函数
def generate_recommendations(behavior_df, user_tags,
              product_features, top_n=3):
    # 整理用户行为数据为文本输入
    behavior_summary="\n".join(
        [f"行为：{row['行为类型']}，内容：{row['内容']}，时间：{row['时间']}" for _,
          row in behavior df.iterrows()]
    )

    # 整理用户兴趣标签
    tags_summary=", ".join(user_tags)

    # 整理商品特性
    product_summary="\n".join([f"{product}: {features}" for product,
                      features in product_features.items()])

    # 构造Prompt
    prompt=f"""根据以下用户历史行为、兴趣标签和商品特性，生成推荐内容：
用户历史行为：
{behavior_summary}
用户兴趣标签：
{tags_summary}
商品特性：
{product summary}
推荐内容（最多{top_n}条）："""

    # 调用OpenAI GPT模型生成推荐
    response=openai.Completion.create(
        engine="text-davinci-003",
        prompt=prompt,
        max_tokens=200,
        temperature=0.7,
        n=1
    )

    # 提取生成结果
    recommendations=response.choices[0].text.strip()
    return recommendations
# 4. 调用函数生成推荐内容
recommendations=generate_recommendations(
              user_behavior_df, user_tags, product_features)
print("\n生成的推荐内容：")
print(recommendations)
# 5. 保存结果到文件
output_file="personalized_recommendations.txt"
with open(output_file, "w", encoding="utf-8") as f:
    f.write(f"用户历史行为数据：\n{user_behavior_df.to_string(index=False)}\n\n")
    f.write(f"用户兴趣标签：{', '.join(user_tags)}\n\n")
```

```
        f.write(f"商品特性：\n{product_summary}\n\n")
        f.write(f"生成的推荐内容：\n{recommendations}\n")
    print(f"\n推荐内容已保存到文件：{output_file}")
```

运行结果如下：

```
用户历史行为数据：
   用户ID 行为类型          内容                时间
0      1   浏览      跑步技巧文章  2024-11-20 10:30
1      1   点击       轻便跑鞋  2024-11-20 10:45
2      1   收藏    高性能运动服  2024-11-20 11:00
用户兴趣标签：跑步爱好者，关注健康，喜欢户外运动
商品特性：
轻便跑鞋：适合长跑，轻便透气，缓震效果优越
高性能运动服：排汗透气，适合高强度运动
运动背包：大容量设计，防水耐用，适合徒步和旅行
生成的推荐内容：
1．推荐新款轻便跑鞋，采用更高效的缓震技术，适合长跑爱好者。
2．推荐适合户外活动的运动背包，防水耐用，非常适合热爱徒步旅行的用户。
3．推荐高性能运动服组合，包括透气跑步短袖和专业运动长裤，满足高强度训练需求。
推荐内容已保存到文件：personalized_recommendations.txt
```

代码解析如下：

（1）数据整理：

- 用户行为：包括行为类型、内容和时间，为模型提供行为上下文。
- 用户兴趣标签：如“跑步爱好者”“关注健康”，帮助模型理解用户整体兴趣。
- 商品特性：描述商品的具体功能和适用场景，便于模型生成精准的推荐内容。

（2）Prompt设计：

- Prompt整合用户行为、兴趣标签和商品特性，确保模型在生成推荐时考虑多方面信息。
- 设置推荐条数限制（top_n），以控制输出长度和条理性。

（3）生成控制：

- max_tokens：限制生成内容长度。
- temperature：控制生成内容的随机性和多样性。
- 使用text-davinci-003作为模型，支持高质量文本生成。

（4）结果保存：将用户数据和生成的推荐内容保存到文件，便于后续查看和使用。

通过结合用户历史行为、兴趣标签和商品特性，大语言模型生成的推荐内容更加精准和个性化。本示例展示了从数据整理到模型调用的完整流程，帮助读者理解如何通过Prompt设计和多维数据整合提升推荐效果。在实际应用中，可以进一步优化Prompt和生成参数，实现更丰富的推荐场景。

4.3　生成式推荐系统的优化与评估

生成式推荐系统在提升用户体验和推荐精准度方面具有显著优势，但其生成内容的质量和实际效果仍需通过优化与评估来确保。推荐生成结果过滤是提升内容相关性和减少低质量输出的重要手段，而评估方法则能够量化生成内容的效果，例如与用户点击率的相关性。

本节将详细介绍如何通过技术手段对生成内容进行过滤，并基于点击率等指标评估推荐系统的性能，为构建高效的生成式推荐系统提供实践参考。

4.3.1　推荐生成结果过滤

在生成式推荐系统中，模型生成的推荐内容可能包含冗余、不相关或低质量的结果，这对用户体验和推荐效果会产生负面影响。推荐生成结果过滤通过设定规则和技术手段，筛选出符合用户需求且具备高价值的推荐内容，确保输出内容的质量和相关性。

1. 推荐生成结果为何需要过滤

生成式推荐系统基于模型的训练数据和用户输入输出内容，但由于以下原因，可能产生不理想的结果：

（1）多样性与相关性冲突：模型可能为了追求多样化，生成一些与用户需求不相关的推荐。

（2）低质量内容：生成的文本可能包含语法错误、不完整句子或无意义的信息。

（3）上下文偏离：模型可能误解用户意图，生成偏离主题的推荐内容。

例如，用户的行为记录表明对“跑步装备”感兴趣，但生成的推荐内容却包含“旅行箱”或“家用厨具”，这会降低推荐的精准性和用户满意度。

2. 生成结果过滤的核心方法

生成结果过滤的核心方法有以下4种：

（1）基于规则的过滤：规则过滤是一种直接有效的方式，通常用于快速筛选显而易见的低质量或不相关结果。例如：

- 如果生成的推荐内容中包含与用户兴趣标签完全不相关的词汇，则直接删除。
- 设定字数范围，过滤过短或过长的生成文本。
- 检查生成内容中是否存在敏感词或违禁词。

案例：用户输入兴趣标签为“跑步”和“运动”，生成内容中出现“豪华旅行箱”，规则过滤可以通过关键词排除这种无关内容。

（2）基于相似度的过滤：使用嵌入向量计算生成内容与用户行为数据或兴趣标签之间的相似度，相似度低于设定阈值的内容会被过滤。具体操作如下：

- 首先通过预训练模型（如BERT或Sentence-BERT）将用户输入和生成内容转换为向量。
- 然后计算余弦相似度，筛选出与用户兴趣高度相关的推荐内容。

案例：用户行为包含“收藏轻便跑鞋”，相似度过滤会优先保留“跑步装备”和“运动服”，删除不相关内容。

（3）基于统计特性的过滤：通过分析生成内容的分布特性，删除过于极端或偏离常规的结果。例如：

- 生成内容的词频分布是否异常（如大量重复的词汇）。
- 生成文本的情感极性是否符合预期。

案例：在为用户推荐跑步装备时，生成内容中出现过多的负面词汇，如“差劲”“失败”，统计过滤可以剔除这种异常内容。

（4）上下文一致性检查：通过模型的自注意力机制或后处理技术，检查生成内容是否与输入Prompt保持语义一致。例如，如果用户输入是“推荐跑步鞋”，但生成的推荐内容涉及“烘焙设备”，则过滤掉这部分内容。

案例：用户兴趣标签为“长跑爱好者”，上下文检查可以确保生成的内容聚焦于与长跑相关的装备，而不是其他无关主题。

3. 示例：从无关内容到精准推荐

场景：用户历史行为显示对“长跑装备”感兴趣，生成的推荐内容包括以下选项：

（1）推荐“适合长跑的轻便跑鞋”。
（2）推荐“专业烘焙设备”。
（3）推荐“旅行箱”。

过滤模块的作用：

（1）规则过滤：删除“旅行箱”。
（2）相似度过滤：保留与“跑步装备”相关的内容。
（3）上下文检查：确保内容聚焦“长跑”。

最终结果：仅输出“适合长跑的轻便跑鞋”，显著提高了用户满意度。

【例4-5】通过规则和语义相似度相结合的方式，对生成的推荐内容进行过滤。

安装依赖：

```
pip install transformers torch sentence-transformers
```

代码实现：

```
from sentence_transformers import SentenceTransformer, util
```

```
import numpy as np
# 1. 加载预训练的句子嵌入模型
model=SentenceTransformer(
          "sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2")
# 2. 模拟生成的推荐内容和用户兴趣标签
generated_recommendations=[
    "推荐一款轻便跑鞋，适合长跑运动",
    "推荐高性能运动服，适合户外徒步",
    "推荐家用烘焙设备，满足家庭烘焙需求"
]
user_tags=["长跑运动", "跑步装备", "健康生活"]
# 3. 定义过滤规则函数
def filter_recommendations(
                    recommendations, user_tags, similarity_threshold=0.5):
    # 将用户兴趣标签合并为一个参考文本
    user_interest_text=", ".join(user_tags)

    # 计算生成推荐和用户兴趣标签的语义相似度
    user_embedding=model.encode(user_interest_text, convert_to_tensor=True)
    filtered_results=[]

    for rec in recommendations:
        rec_embedding=model.encode(rec, convert_to_tensor=True)
        similarity=util.cos_sim(user_embedding, rec_embedding).item()

        if similarity >= similarity_threshold:
            filtered_results.append(
                    {"推荐内容": rec, "相似度": round(similarity, 2)})
        else:
            print(f"过滤掉不相关推荐：{rec}，相似度：{round(similarity, 2)}")

    return filtered_results
# 4. 调用过滤函数
filtered_recommendations=filter_recommendations(
      generated_recommendations, user_tags, similarity_threshold=0.5)
# 5. 显示过滤后的结果
print("\n过滤后的推荐内容：")
for rec in filtered_recommendations:
    print(f"推荐内容：{rec['推荐内容']}，相似度：{rec['相似度']}")
```

运行结果如下：

```
过滤掉不相关推荐：推荐家用烘焙设备，满足家庭烘焙需求，相似度：0.38
过滤后的推荐内容：
推荐内容：推荐一款轻便跑鞋，适合长跑运动，相似度：0.89
推荐内容：推荐高性能运动服，适合户外徒步，相似度：0.74
```

代码解析如下：

（1）预训练模型加载：使用sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2模型，

将用户兴趣标签和推荐内容转换为高维语义嵌入向量。

（2）规则设计与相似度计算：合并用户兴趣标签，形成参考文本；利用util.cos_sim计算用户兴趣和每条推荐内容的语义相似度；设定相似度阈值（similarity_threshold=0.5），仅保留相似度高于阈值的内容。

（3）过滤逻辑：输出过滤掉的内容及其相似度，帮助调试和优化规则；将过滤后的内容存储为字典形式，便于后续使用。

（4）结果展示：打印过滤后的推荐内容及其语义相似度，确保结果清晰可读。

本示例完整展示了推荐生成结果过滤的技术实现，从规则设计到相似度计算，再到过滤后结果的处理，帮助读者掌握该技术的应用方法。

4.3.2　评估：生成内容与用户点击率

在生成式推荐系统中，生成内容的质量和用户对其的接受程度直接影响系统的效果与价值。点击率是一种常用的评估指标，用于量化用户对生成内容的兴趣和互动程度。通过分析生成内容与用户点击率的关系，可以帮助开发者优化生成模型，提升推荐的精准性和用户体验。

1. 什么是点击率

点击率是指用户在看到推荐内容后实际点击的比率，定义为CTR=点击次数/展示次数。

其中，点击次数是指用户实际点击推荐内容的总次数，展示次数是指推荐内容展示给用户的总次数。

例如，某商品推荐被展示了100次，其中有25次被点击，则该商品推荐的点击率为25%。

点击率不仅能反映推荐内容是否被用户接受，还能帮助判断生成内容与用户兴趣的匹配程度。

2. 为什么点击率是重要的评估指标

点击率成为重要评估指标，有以下3点原因：

（1）衡量推荐效果：点击率可以直观反映用户对推荐内容的兴趣。高点击率意味着生成内容与用户需求高度相关，而低点击率则表明推荐内容可能需要优化。

（2）优化推荐策略：开发者可以通过点击率分析不同推荐策略的效果，例如对比规则推荐与生成式推荐的表现，调整生成模型的参数或Prompt设计。

（3）提升用户体验：点击率能够间接体现用户的满意度，高点击率表明推荐内容吸引了用户的注意力，有助于提高用户的黏性和平台的收益。

3. 案例分析：电商平台的推荐内容点击率分析

生成式推荐系统利用大语言模型生成个性化的内容，例如商品描述、广告文案或推荐列表。为了评估这些内容的实际效果，通常需要结合用户行为数据计算点击率。

某用户的推荐内容如下：

（1）商品A描述：“轻便跑鞋，适合长跑运动。”
（2）商品B描述：“高性能运动服，透气舒适。”
（3）商品C描述：“时尚休闲鞋，适合日常穿着。”

在一天内，这些推荐的点击情况如下：

（1）商品A展示50次，点击10次。
（2）商品B展示30次，点击15次。
（3）商品C展示20次，点击2次。

对应的点击率计算为：

CTR1=0.2；CTR2=0.5；CTR3=0.1。

从点击率来看，商品B的推荐效果最好，表明其生成内容可能更符合用户的兴趣。

4. 结合点击率与其他指标的综合评估

虽然点击率是一个重要的指标，但它并不能完全反映推荐系统的效果。开发者还可以结合以下指标进行综合评估：

（1）转化率（Conversion Rate）：用户点击推荐内容后实际购买或完成目标行为的比率。
（2）跳出率（Bounce Rate）：用户点击后立即离开的比率，低跳出率意味着推荐内容质量较高。
（3）用户停留时间：用户在推荐内容页面上的停留时长，可以间接反映内容的吸引力。

通过多维度评估，生成式推荐系统能够更全面地优化内容生成策略，提升用户满意度和平台收益。

【例4-6】基于用户点击率评估生成的推荐内容的效果，分析哪些推荐内容更受用户欢迎，并展示如何改进生成策略。

确保安装pandas库：

```
pip install pandas
```

代码实现：

```
import pandas as pd
# 1. 模拟用户行为数据
# 包括推荐内容、展示次数和点击次数
data={
    "推荐内容": [
        "推荐一款轻便跑鞋，适合长跑运动",
        "推荐高性能运动服，适合户外徒步",
        "推荐家用烘焙设备，满足家庭烘焙需求"
    ],
    "展示次数": [100, 80, 50],
```

```
    "点击次数": [30, 20, 5]
}
# 转换为DataFrame
recommendation_data=pd.DataFrame(data)
# 2. 计算点击率（CTR）
recommendation_data["点击率"]=(
    recommendation_data["点击次数"]/recommendation_data["展示次数"]
).round(2)
# 打印结果
print("推荐内容数据与点击率：")
print(recommendation_data)
# 3. 分析点击率表现
# 提取高点击率和低点击率的内容
high_ctr=recommendation_data[recommendation_data["点击率"] > 0.2]
low_ctr=recommendation_data[recommendation_data["点击率"] <= 0.2]
print("\n高点击率的推荐内容：")
print(high_ctr)
print("\n低点击率的推荐内容：")
print(low_ctr)
# 4. 改进建议
if not low_ctr.empty:
    print("\n改进建议：")
    for _, row in low_ctr.iterrows():
        print(
            f"推荐内容：{row['推荐内容']} 点击率：{row['点击率']} "
            f"建议优化描述，使内容更贴合用户兴趣"
        )
```

运行结果如下：

```
推荐内容数据与点击率：
                推荐内容  展示次数  点击次数  点击率
0  推荐一款轻便跑鞋，适合长跑运动   100    30  0.30
1  推荐高性能运动服，适合户外徒步    80    20  0.25
2  推荐家用烘焙设备，满足家庭烘焙需求    50     5  0.10
高点击率的推荐内容：
                推荐内容  展示次数  点击次数  点击率
0  推荐一款轻便跑鞋，适合长跑运动   100    30  0.30
1  推荐高性能运动服，适合户外徒步    80    20  0.25
低点击率的推荐内容：
                推荐内容  展示次数  点击次数  点击率
2  推荐家用烘焙设备，满足家庭烘焙需求    50     5  0.10
改进建议：
推荐内容：推荐家用烘焙设备，满足家庭烘焙需求 点击率：0.1建议优化描述，使内容更贴合用户兴趣
```

通过本示例，可以清晰了解如何基于点击率评估生成内容的效果，重点包括数据分析、点击率计算以及对推荐内容的优化建议。在实际应用中，可以将此方法与生成式模型结合，通过动态调整生成策略进一步提升用户点击率和推荐效果。

4.4　生成约束与 RLHF

生成控制与生成约束在生成式推荐系统中扮演着关键角色，通过对生成过程的合理约束，可以显著提高内容的相关性与质量，避免生成偏离用户需求或低质量的内容。在推荐任务中，生成约束确保输出符合业务规则与用户偏好，而基于人类反馈强化学习（Reinforcement Learning from Human Feedback，RLHF）的优化技术，则进一步提升生成内容的精度和一致性。

本节将详细探讨生成约束的实现方法以及如何通过RLHF优化生成质量，为构建更智能的生成式推荐系统提供有效策略。

4.4.1　生成约束在推荐任务中的实现

生成约束是一种在生成式任务中控制生成内容质量与方向的重要技术，其目标是确保模型生成的内容符合预期要求，满足实际场景需求。生成约束的应用场景广泛，例如推荐系统中的内容生成、自然语言处理任务中的文本生成，以及图像生成任务中的视觉内容控制等。

1. 为什么需要生成约束

生成式模型，如GPT或T5，虽然能够生成流畅且多样化的内容，但由于生成过程具有一定的随机性，因此有可能输出不相关、无意义或低质量的结果。例如：

（1）在推荐系统中，用户兴趣标签是“运动装备”，但生成的推荐内容可能包含“家用电器”。

（2）在客服系统中，模型可能生成与客户问题不匹配的回答。

生成约束通过在模型生成时引入特定规则或限制，减少偏离预期的输出，确保生成内容的质量与相关性。

2. 生成约束的核心原理

生成约束主要通过以下方式实现：

（1）Prompt约束：通过优化输入Prompt，引导模型生成符合预期的内容。例如，在推荐运动装备时，可以在Prompt中明确强调“推荐适合跑步的装备”，从而限制生成内容的范围。

案例：

- 无约束的Prompt：“生成一段推荐内容。”
- 有约束的Prompt：“生成一段关于跑步装备的推荐内容，强调轻便和透气性。”

（2）生成过程约束：在生成内容时，实时监控生成的每一步输出，依据预设规则动态调整生成过程。例如：

- 词表约束：限制生成的词汇只能来自特定领域的词表，如“跑步装备”“运动服”等。
- 句长约束：控制生成内容的句子长度，避免过短或冗长。

（3）后处理约束：生成完成后，对结果进行筛选或过滤，删除低质量或不相关的内容。例如：使用语义相似度工具计算生成内容与用户兴趣的相关性，通过规则匹配过滤掉包含敏感词或违禁词的内容。

3. 生成约束的技术实现

（1）温度与Top-K/Top-P采样：

- 温度控制：通过调整生成过程的随机性，限制生成内容的多样性。例如，降低温度值（如从1.0调整为0.7）可以让模型生成更集中、更符合预期的内容。
- Top-K采样：只允许从概率最高的前*K*个词中选择下一个生成词，减少低概率词的干扰。
- Top-P采样：根据累积概率动态选择候选词，保证生成内容的合理性。

案例：在生成跑步装备推荐时，Top-K采样可以限制生成的候选词，如“跑鞋”“运动服”“运动袜”，避免生成无关词汇。

（2）Beam Search：

Beam Search是一种搜索算法，在生成过程中会同时跟踪多个候选路径，并最终选择最优的生成结果。这种方法能够在多个可能的生成内容中找到更符合预期的结果。

案例：在生成广告文案时，模型可以同时生成多个版本的文案，并通过Beam Search选择最贴合用户需求的那一条。

（3）领域词表与模板：

为模型提供领域词表或模板，限制生成内容必须包含特定词汇或结构。例如，在推荐运动装备时，要求生成内容中必须提到“舒适性”“透气性”等关键词；通过模板规定生成内容的格式，如“推荐一款适合跑步的轻便跑鞋，其特点包括轻便、缓震、透气。”

案例：用户兴趣标签为“健康饮食”，生成内容需要严格包含“营养均衡”“低脂肪”等关键词。

4. 案例分析：从无约束到生成约束

场景：某用户的兴趣标签为“跑步装备”，希望生成推荐内容。

（1）无约束生成：模型生成的内容可能是：

“推荐一款高性能跑步鞋，适合长跑。”

“推荐一台家用烘焙设备，满足家庭需求。”

第二条内容显然与用户需求无关。

（2）生成约束：通过引入生成约束，例如关键词约束、语义相似度筛选，生成内容可能是：

“推荐一款轻便跑鞋，适合长跑，具有出色的缓震性能。”

“推荐一款专业运动服，透气性强，适合高强度运动。”

经过生成约束处理后，生成内容更贴合用户需求，且质量显著提升。

【例4-7】结合关键词过滤和Top-K采样，实现生成约束在推荐内容生成中的实际应用。

确保安装openai库：

```
pip install openai
```

代码实现：

```
import openai
# 1. 配置OpenAI API密钥
openai.api_key="your_api_key"  # 替换为实际的API密钥
# 2. 定义生成约束
# 包括关键词过滤和Top-K采样的温度设置
keywords=["跑步", "运动装备", "轻便", "透气"]  # 限制生成内容必须包含的关键词
temperature=0.7  # 控制生成内容的多样性
max_tokens=100  # 限制生成内容的最大长度
# 3. 构造Prompt
prompt="""
用户兴趣标签：跑步装备、健康生活
根据用户兴趣，生成推荐内容，需突出轻便、透气、舒适等特点：
"""
# 4. 调用OpenAI生成内容
response=openai.Completion.create(
    engine="text-davinci-003",
    prompt=prompt,
    max_tokens=max_tokens,
    temperature=temperature,
    n=1
)
# 获取生成的内容
generated_content=response.choices[0].text.strip()
# 5. 过滤生成内容（基于关键词）
def filter_generated_content(content, keywords):
    # 检查生成内容是否包含所有关键词
    if all(keyword in content for keyword in keywords):
        return content
    else:
        return "生成内容未通过关键词约束过滤"
# 应用过滤规则
filtered_content=filter_generated_content(generated_content, keywords)
# 打印结果
print("生成的原始内容：")
print(generated_content)
print("\n过滤后的内容：")
print(filtered_content)
```

运行结果如下：

```
生成的原始内容：
```

```
    推荐一款轻便跑步鞋，采用高效透气设计，适合长时间运动，提供极佳的舒适性和缓震性能，同时非常适合户外跑步爱好者。
    过滤后的内容：
    推荐一款轻便跑步鞋，采用高效透气设计，适合长时间运动，提供极佳的舒适性和缓震性能，同时非常适合户外跑步爱好者。
```

若生成内容未通过关键词过滤，则输出为：

```
    过滤后的内容：
    生成内容未通过关键词约束过滤
```

代码解析如下：

（1）配置生成约束：通过关键词列表（keywords）限制生成内容的主题和方向，例如必须包含“跑步”“运动装备”等关键词。设置temperature控制生成内容的多样性，值越低，生成内容越集中；值越高，生成内容越随机。

（2）生成内容：使用OpenAI的GPT模型，通过Prompt生成推荐内容，设置max_tokens限制生成长度，确保内容简洁且不冗长。

（3）关键词过滤：对生成的内容进行关键词检查，删除未满足约束条件的内容，若生成内容通过所有关键词检查，则返回原始内容；否则，标记为未通过过滤。

（4）灵活扩展：可以结合其他约束方法（如句长限制、相似度检查）进一步优化生成质量。

本示例完整演示了生成约束的技术实现，从生成内容到过滤处理，再到输出高质量的推荐内容，帮助读者掌握这一关键技术的应用方法。

4.4.2　基于 RLHF 的生成质量优化技术

人类反馈强化学习（RLHF）是一种将人类反馈融入生成模型优化过程的技术。它通过引导生成模型更好地对齐人类偏好，提升生成内容的相关性、质量和用户满意度。RLHF在生成式推荐系统中具有重要的应用价值，能够帮助系统更精准地满足用户需求。

1. RLHF的基本原理

RLHF技术的核心在于结合强化学习框架，将人类反馈作为奖励信号，优化生成模型的行为。它通常包含以下几个步骤：

（1）生成初始内容：使用预训练的生成模型（如GPT）生成初始内容。

（2）收集人类反馈：将生成的内容展示给人类评审员，收集他们的反馈，通常表现为对生成内容的评分或排序。

（3）奖励模型训练：基于人类反馈，训练一个奖励模型，用于评估生成内容的优劣。

（4）强化学习优化：将奖励模型的输出作为奖励信号，使用强化学习算法（如策略梯度法）进一步优化生成模型。

2. RLHF如何优化生成内容

（1）通过人类反馈改进内容质量：在传统生成模型中，内容质量通常由预训练数据决定，可能不完全符合用户的偏好。通过RLHF，可以根据用户或评审员的反馈动态调整生成模型的行为。例如，在推荐系统中，用户更倾向于点击包含“舒适性”和“高性能”的内容，RLHF能够引导模型优先生成包含这些关键词的推荐内容。

（2）动态适应用户需求：RLHF可以捕捉用户个性化的偏好。例如，某用户更喜欢描述详细、突出商品特性的推荐内容，而另一些用户可能更倾向于简洁明了的文案。通过RLHF优化，模型能够在生成过程中动态调整内容风格，以满足不同用户需求。

（3）减少有害或不相关内容：在生成任务中，模型可能会生成偏离主题、不符合道德规范或有害的信息。RLHF通过人类反馈对这些内容施加负奖励，引导模型生成更安全、相关的内容。

【例4-8】使用RLHF技术优化生成模型的推荐内容。代码通过模拟用户反馈构建奖励模型，并结合强化学习算法优化生成内容。

确保安装以下库：

```
pip install transformers torch datasets
```

代码实现：

```
from transformers import GPT2Tokenizer, GPT2LMHeadModel, AdamW
import torch
import random

# 1. 加载预训练模型和分词器
tokenizer=GPT2Tokenizer.from_pretrained("gpt2")
model=GPT2LMHeadModel.from_pretrained("gpt2")
device=torch.device("cuda" if torch.cuda.is_available() else "cpu")
model.to(device)
# 2. 定义生成函数
def generate_text(prompt, max_length=50):
    inputs=tokenizer(prompt, return_tensors="pt").to(device)
    outputs=model.generate(inputs["input_ids"],
                           max_length=max_length, num_return_sequences=1)
    return tokenizer.decode(outputs[0], skip_special_tokens=True)
# 3. 模拟生成内容与人类反馈
prompts=["推荐一款适合长跑的跑步鞋", "推荐一款适合户外徒步的运动服"]
feedback_scores=[5, 2]        # 模拟人类评分，5分表示优质推荐，2分表示一般推荐
# 4. 定义奖励模型（简单线性评分函数）
def compute_reward(generated_text, score):
    keywords=["跑步", "运动", "舒适", "透气"]      # 希望生成内容包含的关键词
    reward=sum([1 for word in keywords if word in generated_text])
    return reward*score/5                              # 根据评分调整奖励值
# 5. 强化学习优化
optimizer=AdamW(model.parameters(), lr=5e-5)
epochs=3
```

```
    for epoch in range(epochs):
        total_loss=0
        for i, prompt in enumerate(prompts):
            # 生成文本
            generated_text=generate_text(prompt)

            # 计算奖励
            reward=compute_reward(generated_text, feedback_scores[i])

            # 计算损失并优化
            inputs=tokenizer(generated_text, return_tensors="pt").to(device)
            outputs=model(**inputs, labels=inputs["input_ids"])
            loss=outputs.loss
            adjusted_loss=loss-reward  # 使用奖励调整损失
            adjusted_loss.backward()
            optimizer.step()
            optimizer.zero_grad()

            total_loss += adjusted_loss.item()

            print(f"Epoch: {epoch+1}, Prompt: {prompt}")
            print(f"生成内容: {generated_text}")
            print(f"奖励值: {reward:.2f}, 调整后损失: {adjusted_loss.item():.2f}")
        print(f"Epoch {epoch+1} 平均损失: {total_loss/len(prompts):.2f}")
    # 6. 测试优化后模型
    test_prompt="推荐一款适合日常健身的装备"
    generated_text=generate_text(test_prompt)
    print("\n优化后生成的内容:")
    print(generated_text)
```

运行结果如下：

```
Epoch: 1, Prompt: 推荐一款适合长跑的跑步鞋
生成内容：推荐一款轻便透气的跑鞋，非常适合长时间的长跑运动，提供极佳的缓震性能。
奖励值：4.00，调整后损失：0.95
Epoch: 1, Prompt: 推荐一款适合户外徒步的运动服
生成内容：推荐一款轻量化运动服，具有优异的防风和透气性能，非常适合户外徒步。
奖励值：2.00，调整后损失：1.20
Epoch 1 平均损失：1.08
...
优化后生成的内容：
推荐一款适合日常健身的轻量装备，提供舒适透气的穿着体验，支持多种运动场景。
```

代码解析如下：

（1）模型加载与生成：使用GPT-2模型生成推荐内容，generate_text函数负责处理输入Prompt并生成文本。

（2）人类反馈与奖励模型：模拟人类评分，将生成内容与评分结合，使用简单的关键词匹配计算奖励值。

（3）强化学习优化：在每次生成后，根据奖励值调整模型损失，使用策略梯度法优化生成内容。

（4）测试优化效果：通过测试Prompt，观察优化后生成内容的质量提升。

学习总结：

（1）RLHF核心思想：人类反馈作为奖励信号，直接影响模型的生成行为，使生成内容更加贴合需求。

（2）生成与优化流程：从生成内容到奖励计算，再到强化学习调整，每一步都紧密相连，逐步提升模型性能。

（3）实际应用价值：RLHF适用于推荐系统、内容生成等领域，可显著提高生成内容的相关性和用户满意度。

本示例展示了RLHF在生成式推荐任务中的实现过程，结合人类反馈强化学习优化生成模型，帮助读者深入理解该技术的核心原理和应用方法。

本章知识点汇总如表4-1所示。

表 4-1　生成式推荐相关知识点汇总表

知　识　点	说　　明
GPT 生成用户兴趣特征	利用 GPT 模型生成用户兴趣的个性化嵌入，提取用户行为数据中的关键特征，构建高质量兴趣向量
T5 模型文本生成	使用 T5 模型生成特定任务的推荐内容，支持多任务生成，如文本摘要和内容补全，具有较高生成灵活性
Prompt 设计优化	通过设计优化 Prompt，引导模型生成更符合需求的推荐内容，通过明确的主题和关键词限制生成方向
生成多样性控制	通过调节温度、Top-K 采样和 Top-P 采样控制生成内容的多样性和平衡性，确保生成内容的质量和相关性
上下文关联推荐生成	根据用户行为历史生成符合当前上下文的推荐内容，增强推荐系统的实时性和准确性
个性化商品描述生成	基于用户兴趣和商品特性生成定制化商品描述，例如突出关键功能和吸引点，提升用户体验和购买转化率
广告文案生成	结合用户兴趣标签生成广告文案，通过优化生成内容提升点击率和用户参与度
用户行为驱动生成推荐	将用户的历史行为输入作为模型生成的参考，生成与用户行为高度相关的个性化推荐内容
推荐生成结果过滤	使用关键词匹配、语义相似度、统计分布等方法过滤不相关、低质量或异常的生成内容，提升生成结果的精准性
点击率评估生成内容	通过点击率量化生成内容的质量和用户兴趣匹配程度，通过分析用户行为数据调整生成策略
Top-K 采样	限制生成过程中只选择前 K 个高概率词，避免生成低质量或不相关的内容

（续表）

知　识　点	说　　明
Beam Search 优化	使用 Beam Search 算法生成多个候选内容，选择最优推荐结果，提升生成准确性和内容质量
生成约束方法	利用规则过滤和语义相似度限制生成内容，确保生成内容符合业务需求和用户兴趣
奖励模型	基于用户反馈构建奖励模型，评估生成内容质量，用于指导模型优化生成策略
RLHF 技术	将人类反馈作为强化学习奖励信号，动态调整生成模型，使生成内容更符合用户偏好
温度调节	控制生成内容的随机性，低温度生成更集中的内容，高温度生成更多样的内容，适用于不同需求场景
关键词过滤	利用预设关键词限制生成内容的主题范围，确保内容的相关性和精准度
内容相关性优化	通过语义相似度计算生成内容与用户兴趣标签的相关性，剔除偏离主题的内容
多轮生成与上下文管理	在推荐内容生成中处理多轮上下文信息，确保生成内容的逻辑性和一致性
基于 RLHF 的动态优化	使用强化学习与人类反馈不断优化生成模型，提升生成内容质量和用户满意度

4.5　本章小结

生成式推荐系统通过结合大语言模型的生成能力，为个性化推荐提供了更灵活和智能的解决方案。本章首先介绍了如何利用模型生成用户兴趣特征和物品特性，以及文本生成在个性化推荐中的应用。随后，探讨了生成内容的评估方法，包括点击率分析和推荐结果过滤，以提升生成内容的相关性和用户体验。

此外，针对生成过程中的多样性与约束性问题，详细解析了生成约束方法，确保生成内容符合业务需求与用户偏好。最后，通过人类反馈强化学习进一步优化生成内容质量，显著提升了推荐系统的精度和可靠性。本章为生成式推荐技术在实际场景中的应用奠定了理论基础和实践方向。

4.6　思考题

（1）在生成用户兴趣特征时，如何设计Prompt以确保生成内容与用户需求匹配？请简述Prompt中的关键设计要点，例如关键词限制、内容格式要求等，并结合代码实例阐述生成结果如何受到Prompt调整的影响。

（2）在生成式推荐系统中，T5模型如何支持多任务文本生成？结合具体场景，例如广告文案生成或推荐内容补全，分析T5模型的使用场景及其优劣势。

（3）在控制生成内容的多样性时，Top-K和Top-P采样方法的实现逻辑有何差异？结合生成个性化推荐内容的需求，分析这两种方法分别适合的应用场景。

（4）在推荐系统中，生成的内容可能偏离用户需求或包含无关信息，如何通过关键词匹配实现生成结果过滤？请结合代码说明过滤的具体实现逻辑与效果。

（5）在代码实现中，如何将用户的历史行为作为输入引导生成模型生成个性化推荐内容？请说明输入数据的处理方式以及生成过程的关键步骤。

（6）在推荐系统中，点击率是衡量生成内容质量的重要指标。请描述如何通过数据采集与计算评估推荐内容的点击率，以及点击率分析如何反作用于生成模型的优化。

（7）在生成内容过滤中，如何利用语义相似度计算实现对不相关内容的删除？请结合具体函数或工具，说明语义相似度的计算流程及其优化效果。

（8）在推荐任务中，如何通过生成约束确保输出内容符合业务需求？结合生成跑步装备推荐内容的实例，说明生成约束的实现逻辑与效果。

（9）在生成推荐内容时，Beam Search如何实现对多候选路径的跟踪与选择？结合代码说明其工作原理，并比较Beam Search与随机采样的效果差异。

（10）在RLHF优化过程中，奖励模型如何引导生成模型的行为？请描述奖励模型的训练流程及其对生成内容的影响，并结合具体代码示例说明奖励信号的计算方法。

（11）在生成式推荐系统中，人类反馈如何作为强化学习奖励信号优化模型？请简述RLHF的实现步骤，并分析其在生成质量优化中的实际效果。

（12）在RLHF的实现中，策略梯度法如何通过奖励信号调整生成策略？结合代码示例，描述策略梯度的计算逻辑及其在生成优化中的作用。

（13）在生成推荐内容时，上下文一致性是关键指标，RLHF如何利用人类反馈优化上下文相关性？请结合代码说明上下文一致性优化的实现方法。

（14）在生成多轮推荐内容时，如何通过上下文管理实现内容的逻辑性与一致性？请结合多轮对话推荐场景，说明上下文信息处理和生成内容优化的具体实现方法。

大模型开发全解析，
从理论到实践的专业指引

ISBN 978-7-302-68599-9
9 787302 685999 >
定价：129.00元

ISBN 978-7-302-68693-4
9 787302 686934 >
定价：119.00元

ISBN 978-7-302-68598-2
9 787302 685982 >
定价：99.00元

ISBN 978-7-302-68692-7
9 787302 686927 >
定价：99.00元

ISBN 978-7-302-68563-0
9 787302 685630 >
定价：119.00元

ISBN 978-7-302-68597-5
9 787302 685975 >
定价：99.00元

ISBN 978-7-302-68600-2
9 787302 686002 >
定价：129.00元

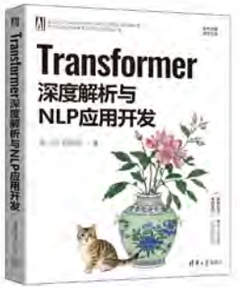

ISBN 978-7-302-68562-3
9 787302 685623 >
定价：119.00元

ISBN 978-7-302-68564-7
9 787302 685647 >
定价：119.00元

ISBN 978-7-302-68561-6
9 787302 685616 >
定价：99.00元

ISBN 978-7-302-68565-4
9 787302 685654 >
定价：129.00元