章节一：环境配置与模型下载

1. 环境配置

```
# 1 虚拟环境安装
# (1) 本机
conda create -n flashrag python=3.11
conda activate flashrag


# (2) 云平台
conda create -n flashrag python=3.11
conda init bash && source /root/.bashrc
conda activate flashrag
conda install ipykernel
ipython kernel install --user --name=flashrag   # 设置kernel，--user表示当前用户，flashrag为虚拟环境
```

```
# 2 源码安装 FlashRAG
git clone https://github.com/RUC-NLPIR/FlashRAG.git
cd FlashRAG
pip install -e .

# 注意⚠️ ：可以直接用我提供的代码注解版
```

```
# 3 其它依赖包
# Install vllm for faster speed
pip install vllm>=0.4.1

# Install sentence-transformers
pip install sentence-transformers

# Install pyserini for bm25
pip install pyserini

# GPU(+CPU) version
conda install -c pytorch -c nvidia faiss-gpu=1.8.0

# CPU-only version
conda install -c pytorch faiss-cpu=1.8.0
```

```
# 安装git和git-lfs【可选，如果已安装，则跳过】
sudo apt update
sudo apt install git
curl -s https://packagecloud.io/install/repositories/github/git-
lfs/script.deb.sh | sudo bash
sudo apt-get install git-lfs
git lfs install
```

2. 下载模型

总共需要下载以下两个模型:

- E5-base-v2

```
git clone https://huggingface.co/intfloat/e5-base-v2
```

- Llama-3.2-3B-Instruct

```
git clone https://huggingface.co/meta-llama/Llama-3.2-3B-Instruct
```

- bge-large-zh-v1.5

```
git clone https://huggingface.co/BAAI/bge-large-zh-v1.5
```

- Qwen2.5-1.5B-Instruct

```
git clone https://huggingface.co/Qwen/Qwen2.5-1.5B-Instruct
```

如果是中国用户，推荐使用镜像平台 https://hf-mirror.com/ 进行下载。

3. 下载数据集

数据集包含了query和对应的标准答案，能够让我们评估构建的RAG系统的效果。

- **Demo数据集**： 为了简便，我们从NQ中采样了17条数据作为toy dataset, 其地址在 examples/quick_start/dataset/nq。后续RAG流程将在这些questions上进行。

- **Demo文档集合**： 文档集合包含了大量的切分好的段落，是RAG系统的外部知识来源。由于常用的文档集合往往非常大(~5G以上)，我们使用了一个通用知识数据集作为检索文档， 地址为 examples/quick_start/indexes/general_knowledge.jsonl。

> 由于文档数量较少，可能很多query都无法搜到相关的文本，这可能会影响最终的检索结果。

- **完整数据集**：作者提供的仓库中同样提供了大量处理好的基准数据集，如果需要获取完整的文

档集合，可以访问我们 (https://huggingface.co/datasets/RUC-NLPIR/FlashRAG_datasets) 进行下载和使用。

```
git clone https://huggingface.co/datasets/RUC-NLPIR/FlashRAG_datasets
```

章节二：快速入门

Demo-1：简单pipeline

我们在下面的步骤中会依次拆解各个步骤，并展示相应的代码 (simple_pipeline.py)。

（1）加载Config

首先我们需要加载`Config`，并填入之前下载的各种东西的路径。

`Config`管理着实验中所有的路径以及超参数。在FlashRAG中，各种参数可以通过`yaml`文件或者python内的字典传入Config中。

传入的参数会替换默认的内部参数，具体的各种参数以及其默认值可以参考`basic_config.yaml`。

在这里我们直接通过字典传入各种路径。

```
from flashrag.config import Config

config_dict = {
    'data_dir': 'dataset/',
    'index_path': 'indexes/e5_Flat.index',
    'corpus_path': 'indexes/general_knowledge.jsonl',
    'model2path': {'e5': <retriever_path>, 'llama2-7B-chat':
<generator_path>},
    'generator_model': 'llama2-7B-chat',
    'retrieval_method': 'e5',
    'metrics': ['em', 'f1', 'acc'],
    'retrieval_topk': 1,
    'save_intermediate_data': True
}

config = Config(config_dict=config_dict)
```

（2）加载数据集以及Pipeline

接着，我们需要加载相应的数据集和pipeline。

数据集可以通过前面设置的config自动读取，我们只需要选择对应需要的test集合就可以了。

而pipeline的加载需要我们先根据想进行的RAG流程选择一个合适的pipeline。这里我们选择`SequentialPipeline`，用于进行前面提到的Standard RAG流程。 然后pipeline的过程中会自动加载对应的组件(检索器和生成器)，并完成各种初始化。

```
from flashrag.utils import get_dataset
from flashrag.pipeline import SequentialPipeline

all_split = get_dataset(config)
test_data = all_split['test']
pipeline = SequentialPipeline(config)
```

（3）运行RAG流程

在完成上面的步骤之后，我们只需要调用`pipeline`的`.run`方法即可在数据集上运行RAG流程并生成评估结果。该方法返回一个包含中间结果和运行结果的数据集，其中`pred`属性的内容则是模型的预测结果。

需要注意的是，由于前面我们提供的是Toy文档集合和索引，因此结果可能会比较差。可以考虑换成自己的文档集合和索引，应该能够取得较好的结果。

在运行结束后，所有运行结果会被单独保存在本次实验对应的文件夹内，包括每个query的检索和生成结果，整体的评价分数等。

完整的代码如下:

```
from flashrag.config import Config
from flashrag.utils import get_dataset
from flashrag.pipeline import SequentialPipeline

config_dict = {
                'data_dir': 'dataset/',
                'index_path': 'indexes/e5_Flat.index',
                'corpus_path': 'indexes/general_knowledge.jsonl',
                'model2path': {'e5': <retriever_path>, 'Llama-3.2-1B-
Instruct': <generator_path>},
                'generator_model': 'Llama-3.2-1B-Instruct',
                'retrieval_method': 'e5',
                'metrics': ['em','f1','acc'],
                'retrieval_topk': 1,
                'save_intermediate_data': True
            }

config = Config(config_dict = config_dict)

all_split = get_dataset(config)
test_data = all_split['test']
pipeline = SequentialPipeline(config)

output_dataset = pipeline.run(test_data,do_eval=True)
print("---generation output---")
```

```
print(output_dataset.pred)
```

运行命令：

```
cd FlashRAG/examples/quick_start

python simple_pipeline.py --model_path /root/autodl-tmp/models/Llama-3.2-1B-Instruct --retriever_path /root/autodl-tmp/models/e5-base-v2
```

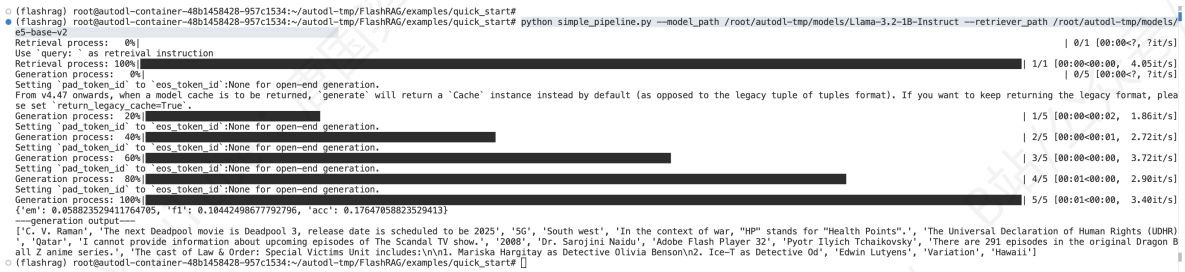

Demo-2： web端交互

```
# 备注：一个小坑，注意numpy版本适配问题，要安装 1.26.4 版本。
# pip install numpy==1.26.4

cd FlashRAG/examples/quick_start

cp ../methods/my_config.yaml .

streamlit run demo_en.py --server.port 6006 --server.address 0.0.0.0
```

输出结果：

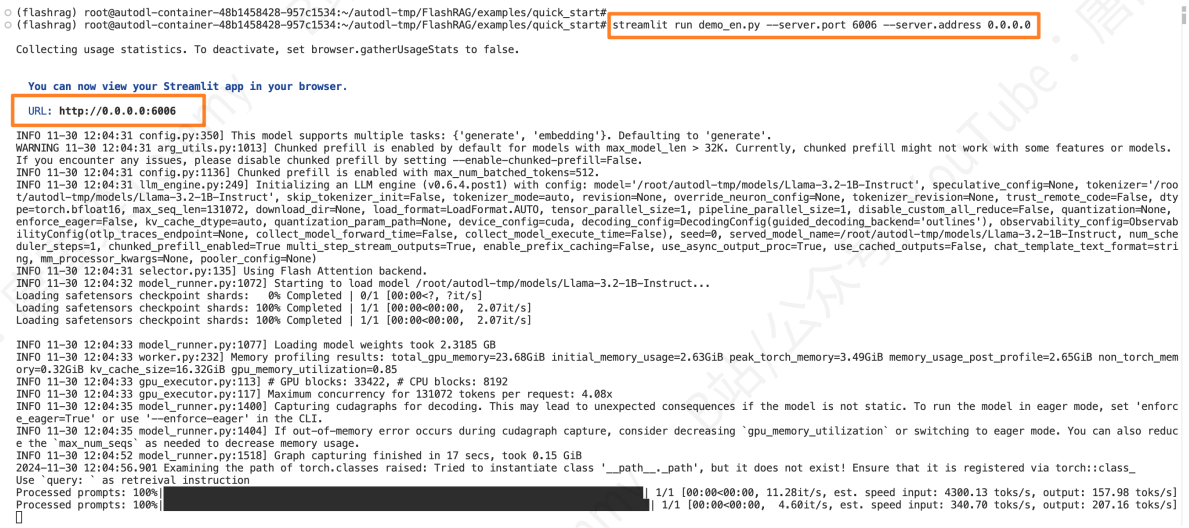

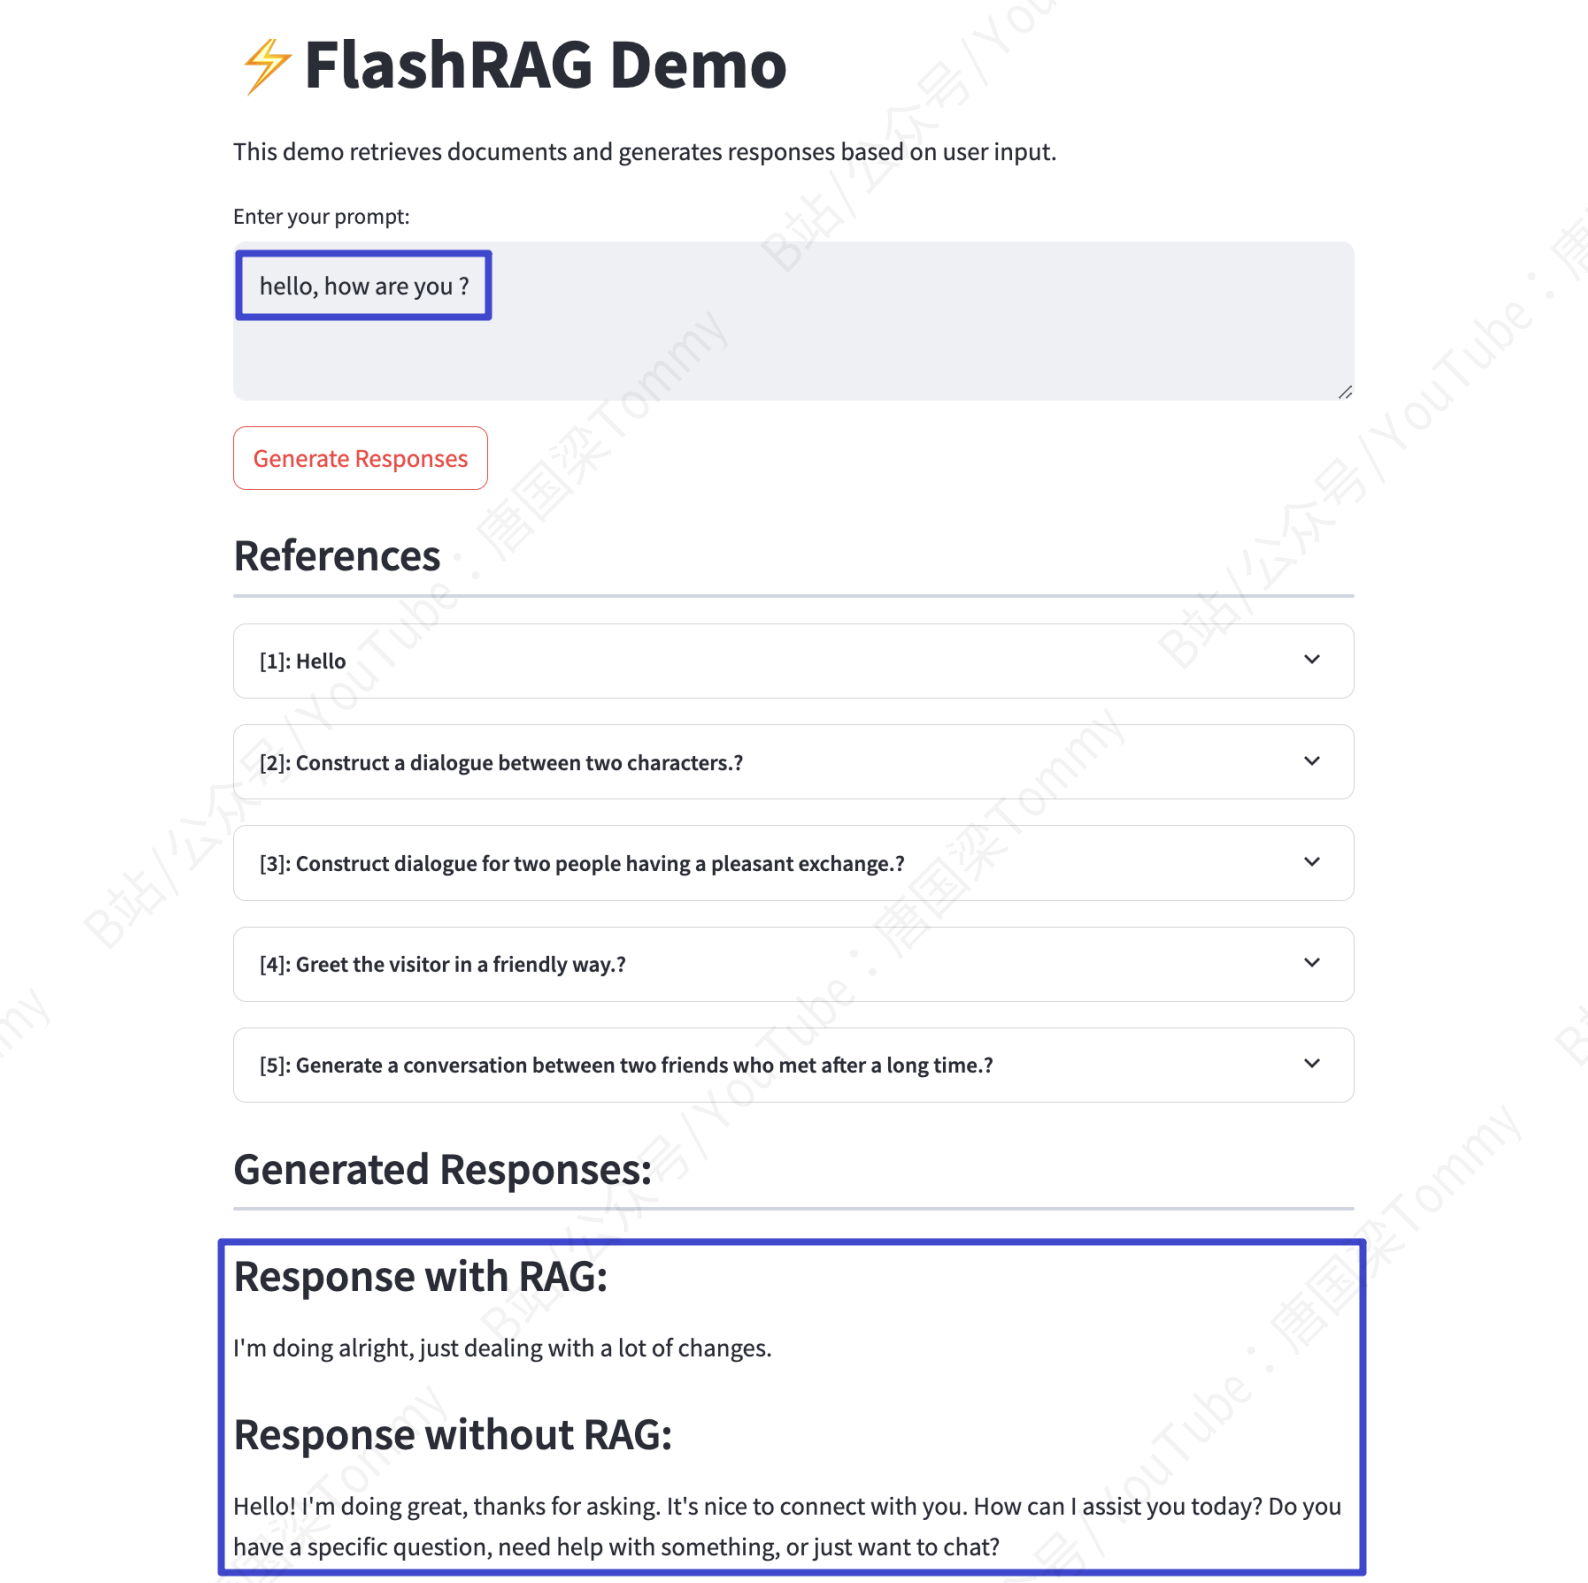

Demo-3：QA问答

chat_demo-1

```
cd FlashRAG/examples/quick_start

python chat_demo-1.py --model_path /root/autodl-tmp/models/Llama-3.2-1B-Instruct --retriever_path /root/autodl-tmp/models/e5-base-v2
```

输出结果：

Chat_demo-2

```
cd FlashRAG/examples/quick_start

python chat_demo-2.py --model_path /root/autodl-tmp/models/Llama-3.2-1B-Instruct --retriever_path /root/autodl-tmp/models/e5-base-v2
```

输出结果：

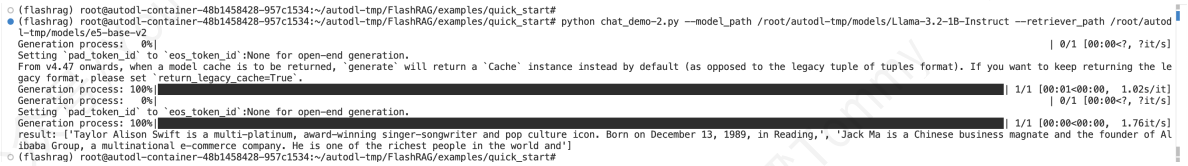

章节三：FlashRAG 模块剖析

1. RAG组件与Pipeline

在 FlashRAG 中，我们构建了一系列常见的 RAG 组件，包括检索器、生成器、优化器等。基于这些组件，我们组装了多个pipeline来实现 RAG 工作流，同时也提供了灵活性，允许用户自定义组合这些组件以创建自己的pipeline。

类型	模块	描述
判断器	SKR Judger	判断是否使用 SKR 方法进行检索
检索器	Dense Retriever	使用双编码器模型 (如 dpr、bge、e5)，基于 faiss 进行检索
	BM25 Retriever	基于 Lucene 的稀疏检索方法
	Bi-Encoder Reranker	使用双编码器计算匹配分数
	Cross-Encoder Reranker	使用交叉编码器计算匹配分数
优化器	Extractive Refiner	通过提取重要上下文对输入进行优化
	Abstractive Refiner	通过 seq2seq 模型优化输入
	LLMLingua Refiner	LLMLingua 系列提示压缩器
	SelectiveContext Refiner	Selective-Context 提示压缩器
	KG Refiner	使用 Trace 方法构建知识图谱
生成器	Encoder-Decoder Generator	编码器-解码器模型，支持 Fusion-in-Decoder (FiD)
	Decoder-only Generator	原生的 Transformers 实现
	FastChat Generator	使用 FastChat 加速生成
	vllm Generator	使用 vllm 加速生成

1.1 检索器

检索器接收一系列查询，并从语料库中检索与每个查询对应的前 k 个文档。可以使用 `flashrag.utils.get_retriever` 加载检索器，该方法根据配置中指定的 `retrieval_method` 确定检索器的类型（BM25 或 Dense），并在内部初始化检索器所需的语料库和模型。

```
retriever = get_retriever(config)
```

然后，可以使用 retriever.search（针对单个查询）或 retriever.batch_search（针对查询列表）执行检索。

```
# 如果设置 `return_scores=True`
retrieval_results, scores = self.retriever.batch_search(input_query_list,
return_scores=True)

# 如果设置 `return_scores=False`
retrieval_results = self.retriever.batch_search(input_query_list,
return_scores=False)
```

使用 batch_search 时，retrieval_results 是一个两层嵌套列表，如下所示：

```
[
    [doc1, doc2, ...],  # query1 的文档项
    [doc1, doc2, ....],  # query2 的文档项
    ...
]
```

使用 search 时，retrieval_results 是一个常规列表，包含每个查询的前 k 个文档项。每个文档项是一个包含 doc_id、title、contents 等字段的字典（类似于语料库中的内容）。scores 的格式与 retrieval_results 相同，只是每个 doc_item 被替换为一个 float 值，表示检索器提供的文档与查询之间的匹配得分。

- **检索器的附加功能**：检索器的 search 和 batch_search 函数通过两个装饰器实现了三个附加功能：
- **预加载检索结果**：适用于你自己为查询提供一些检索结果的情况。如果配置中设置了 use_retrieval_cache 且提供了缓存文件，它会首先检查缓存文件中是否包含相应查询的检索结果，如果存在则直接返回。
- **保存检索结果**：如果 save_retrieval_cache 设置为 True，检索器会将每个查询的检索结果保存为缓存，方便下次直接使用缓存。
- **重排序**：如果 use_reranker=True，search 函数将集成重排序功能，对检索结果进行进一步排序。

1.2 生成器

生成器接收提示作为输入，并返回每个提示对应的输出。可以使用 flashrag.utils.get_generator 加载生成器。根据输入的生成器模型名称，它会选择加载不同结构的生成器模型。

```
generator = get_generator(config)
```

然后，使用 generate 方法进行生成。

```
input_list = ['who is taylor swift?', 'who is jack ma?']
result = generator.generate(input_list)
```

可以通过 return_scores 获取每个 token 的生成概率。

```
result, scores = generator.generate(input_list, return_scores=True)
```

generate 函数还可以接收生成所需的参数，例如 topk、do_sample 等。这些参数也可以在配置中指定，但在 generate 中指定的参数优先级更高。

```
result = generator.generate(input_list, top_p=1.0, max_tokens=32)
```

1.3 配置

Config 类支持使用 .yaml 文件作为输入或直接使用变量作为输入。变量的优先级高于文件。**所有后续组件设置都依赖于** Config。

如果有需要使用的变量未在上述两个地方指定，将加载默认值（basic_config.yaml）。

```
from flashrag.config import Config

config_dict = {"retrieval_method": "bge"}
config = Config('my_config.yaml', config_dict = config_dict)
print(config['retrieval_method'])
```

1.4 Pipeline

我们根据推理路径将 RAG 方法分为四种类型：

- **顺序型**：按顺序执行 RAG 过程，例如 Query - (预检索) - Retriever - (后检索) - Generator。
- **条件型**：根据不同类型的输入查询执行不同的路径。
- **分支型**：并行执行多个路径，并合并每条路径的响应。
- **循环型**：迭代执行检索和生成。

在每种类别中，我们实现了相应的通用pipeline。

- **流水线组件**

类型	模块	描述
顺序型	Sequential Pipeline	按线性方式执行查询，支持优化器和重排序器
条件型	Conditional Pipeline	使用判断器模块，为不同类型的查询提供独特的执行路径
分支型	REPLUG Pipeline	通过整合多个生成路径中的概率生成答案
	SuRe Pipeline	根据每个文档的生成结果进行排序和合并
循环型	Iterative Pipeline	交替执行检索和生成
	Self-Ask Pipeline	使用 Self-Ask 方法将复杂问题分解为子问题
	Self-RAG Pipeline	自适应检索、优化和生成
	FLARE Pipeline	在生成过程中动态检索
	IRCOT Pipeline	将检索过程与 CoT (Chain-of-Thought) 集成

```
1. REPLUG pipeline
REPLUG: Retrieval-Augmented Black-Box Language Models
https://arxiv.org/abs/2301.12652v4

2. SuRe pipeline
SuRe: Summarizing Retrievals using Answer Candidates for Open-domain QA of
LLMs
https://arxiv.org/abs/2404.13081

3. Iterative pipeline

- Enhancing Retrieval-Augmented Large Language Models with Iterative
Retrieval-Generation Synergy
https://arxiv.org/abs/2305.15294v2

- Retrieval-Generation Synergy Augmented Large Language Models
https://arxiv.org/abs/2310.05149

4. Self-Ask pipeline
Measuring and Narrowing the Compositionality Gap in Language Models
https://arxiv.org/abs/2210.03350v3

5. Self-RAG pipeline
Self-RAG: Learning to Retrieve, Generate, and Critique through Self-Reflection
https://arxiv.org/pdf/2310.11511

6. FLARE pipeline
Active Retrieval Augmented Generation
https://arxiv.org/abs/2305.06983v2

7. IRCOT pipeline
```

```
Interleaving Retrieval with Chain-of-Thought Reasoning for Knowledge-Intensive
Multi-Step Questions
https://arxiv.org/abs/2212.10509v2
```

---

2. 数据集和文档语料库

- **数据集**

我们收集并处理了 38 个广泛用于 RAG 研究的数据集，对其进行预处理以确保格式一致，便于使用。对于某些数据集（如 Wiki-asp），我们根据社区常用的方法对其进行调整，以适配 RAG 任务的要求。

```
# 所有数据集均可在 Huggingface 获取
https://huggingface.co/datasets/RUC-NLPIR/FlashRAG_datasets
```

对于每个数据集，我们将每个分割保存为一个 .jsonl 文件，每一行表示一个字典，格式如下：

```
{
    'id': str,
    'question': str,
    'golden_answers': List[str],
    'metadata': dict
}
```

- **文档语料库**

我们的工具支持检索文档集合的 .jsonl 格式，其结构如下：

```
{"id":"0", "contents": "..."}
{"id":"1", "contents": "..."}
```

contents 键是构建索引的关键。对于同时包含文本和标题的文档，我们建议将 contents 的值设置为 {title}\n{text}。语料库文件还可以包含其他键，用于记录文档的附加特征。

在学术研究中，**Wikipedia 和 MS MARCO** 是最常用的检索文档集合。对于 Wikipedia，我们提供了一个综合脚本（参考：process-wiki.md）将任意 Wikipedia 转储文件处理为干净的语料库。对于 MS MARCO，它在发布时已被处理完毕，可以直接从其 托管链接 下载到 Hugging Face 平台。

```
# Tevatron/msmarco-passage-corpus
https://huggingface.co/datasets/Tevatron/msmarco-passage-corpus
```

3. 参数配置

FlashRAG 提供了全面的参数管理，用于控制实验。**FlashRAG** 支持两种参数配置方式：**YAML 配置文件**和**参数字典**。参数通过 Config 模块进行分配。

在实际使用中，config 可以以字典访问的方式使用，例如：

```
from flashrag.config import Config
config_dict = {'generator_model': 'llama2-7B'}
config = Config(config_dict=config_dict)
model_name = config['generator_model']
```

在大多数情况下，大部分参数无需修改。

- **配置文件**

配置文件应使用 **YAML** 格式，用户需根据 YAML 语法填写相应的参数。本库提供了模板文件供用户参考，模板中包含每个参数的具体含义的注释。

```
from flashrag.config import Config
config = Config(config_file_path='myconfig.yaml')
```

- **参数字典**

另一种方式是通过 Python 字典设置配置，其中键为参数名称，值为参数值。相比使用文件，这种方式更灵活。

以下是使用参数字典的代码：

```
from flashrag.config import Config
config_dict = {'generator_model': 'llama2-7B'}
config = Config(config_dict=config_dict)
```

- **优先级**

在 **FlashRAG** 中，支持同时使用两种方法。配置方式的优先级为：**参数字典 > 配置文件 > 默认设置**。

默认设置记录在 basic_config.yaml 中。

- **路径设置**

为了方便管理各种模型路径和索引路径，我们引入了 **model2path**、**model2pooling** 和 **method2index**。用户只需在这里填写相应的名称和路径，即可自动加载需要使用的路径。

例如，在 **model2path** 中设置了 **llama2-7B** 的路径后，可以直接将其指定为对应的模型，而无需重写路径。

```
model2path:
  llama2-7B: 'my_path'
generator_model: 'llama2-7B'
```

如果在字典中找不到相应的模型路径，它会查找与模型路径对应的参数（例如，generator_model_path）。

此规则适用于以下参数：retrieval_method，rerank_model_name，generator_model，index_path

- **配置示例**

示例配置文件可以在 basic_config.yaml 中找到。下面我们将介绍配置文件中的每个部分。

basc_config.yaml :

```
# 基础设置

# ----------------------------------------------全局路径----------------------
---------------------------#
# 各种模型的路径
model2path:
  e5: "intfloat/e5-base-v2"
  bge: "intfloat/e5-base-v2"
  contriever: "facebook/contriever"
  llama2-7B-chat: "meta-llama/Llama-2-7b-chat-hf"
  llama2-7B: "meta-llama/Llama-2-7b-hf"
  llama2-13B: "meta-llama/Llama-2-13b-hf"
  llama2-13B-chat: "meta-llama/Llama-2-13b-chat-hf"

# 每个嵌入模型的池化方法
model2pooling:
  e5: "mean"
  bge: "cls"
  contriever: "mean"
  jina: 'mean'
  dpr: cls

# 检索模型的索引路径
method2index:
  e5: ~ # 如果未提供，将自动设置
  bm25: ~
  contriever: ~

# ----------------------------------------------环境设置----------------------
---------------------------#
# 数据和输出的目录路径
data_dir: "dataset/"
save_dir: "output/"

gpu_id: "0,1,2,3"
dataset_name: "nq" # 数据集名称，存储在 data_dir 中
```

```yaml
split: ["test"]  # 要加载的数据集分割（例如 train, dev, test）

# 测试的采样配置
test_sample_num: ~  # 测试的样本数量（仅适用于 dev/test 分割），如果为 None，则测试所有样本
random_sample: False # 是否随机抽取测试样本

# 用于结果复现的随机种子
seed: 2024

# 是否保存中间数据
save_intermediate_data: True
save_note: 'experiment'

# ----------------------------------------------检索设置----------------------------------------#
# 如果设置了名称，模型路径将在全局路径中查找
retrieval_method: "e5"  # 检索模型的名称或路径
retrieval_model_path: ~ # 检索模型的路径
index_path: ~ # 如果未提供，将自动设置
faiss_gpu: False # 是否使用 GPU 保存索引
corpus_path: ~  # 以 '.jsonl' 格式存储文档的语料库路径

use_sentence_transformer: False # 如果设置，检索器将通过 `sentence transformer` 库加载
retrieval_topk: 5 # 检索的文档数量
retrieval_batch_size: 256  # 检索的批处理大小
retrieval_use_fp16: True  # 是否对检索模型使用 fp16
retrieval_query_max_length: 128  # 查询的最大长度
save_retrieval_cache: True # 是否保存检索缓存
use_retrieval_cache: False # 是否使用检索缓存
retrieval_cache_path: ~ # 检索缓存的路径
retrieval_pooling_method: ~ # 如果未提供，将自动设置

use_reranker: False # 是否使用重排序器
rerank_model_name: ~ # 与 retrieval_method 相同
rerank_model_path: ~ # 重排序器模型的路径，路径将在 `model2path` 中自动查找
rerank_pooling_method: ~
rerank_topk: 5  # 重排序后保留的文档数量
rerank_max_length: 512
rerank_batch_size: 256 # 重排序器的批处理大小
rerank_use_fp16: True

# ----------------------------------------------生成器设置----------------------------------------#
framework: fschat # 大语言模型的推理框架，支持：'hf', 'vllm', 'fschat', 'openai'
generator_model: "llama3-8B-instruct" # 生成器模型的名称或路径
# openai 模型的设置，仅在 openai 框架中有效
openai_setting:
  api_key: ~
  base_url: ~

generator_model_path: ~
```

```yaml
generator_max_input_len: 1024  # 输入的最大长度
generator_batch_size: 4 # 生成的批处理大小，对 vllm 无效
generation_params:
  #do_sample: false
  max_tokens: 32
  #temperature: 1.0
  #top_p: 1.0
use_fid: False # 是否使用 FID，仅对编码器-解码器模型有效

# ------------------------------------------------评估设置--------------------
-----------------------------#
# 评估结果的指标
metrics: ['em','f1','acc,'precision','recall']
# 指定指标的设置，将在某些指标中调用
metric_setting:
  retrieval_recall_topk: 5
save_metric_score: True # 是否将指标得分保存到 txt 文件中
```

章节四：构建索引实践

1. 准备语料库

为了构建索引，首先需要将语料库保存为如下所示的 jsonl 格式，每行代表一个文档。

```
{"id": "0", "contents": "用于构建索引的内容"}
{"id": "1", "contents": "用于构建索引的内容"}
```

如果你希望使用维基百科作为语料库，可以参考文档【FlashRAG/docs/process-wiki.md】将其转换为索引格式。

注意⚠️ 可以基于OpenAI API进行数据抽取，理解，生成。

2. 创建索引

- 对于 **稠密检索方法**（尤其是流行的嵌入模型），使用 faiss 构建索引。
- 对于 **稀疏检索方法（BM25）**，基于 Pyserini 或 bm25s 将语料库构建为 Lucene 倒排索引。构建的索引包含原始文档。

（1）对于稠密检索方法

（1.1）基于Transformers库

根据以下代码修改参数为你的配置。

```
# 英语
python -m flashrag.retriever.index_builder \
    --retrieval_method e5 \
    --model_path /root/autodl-tmp/models/e5-base-v2 \
    --corpus_path /root/autodl-
tmp/FlashRAG/examples/quick_start/indexes/docs.jsonl \
    --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/ \
    --use_fp16 \
    --max_length 512 \
    --batch_size 256 \
    --pooling_method mean \
    --faiss_type Flat
```

```
(flashrag) (base) root@autodl-container-48b1458428-957c1534:~/autodl-tmp# python -m flashrag.retriever.index_builder \
    --retrieval_method e5 \
    --model_path /root/autodl-tmp/models/e5-base-v2 \
    --corpus_path /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/docs.jsonl \
    --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/ \
    --use_fp16 \
    --max_length 512 \
    --batch_size 256 \
    --pooling_method mean \
    --faiss_type Flat
/root/autodl-tmp/FlashRAG/flashrag/retriever/index_builder.py:63: UserWarning: Instruction is set to default: passage:
  warnings.warn(f"Instruction is set to default: {self.instruction}")
/root/autodl-tmp/FlashRAG/examples/quick_start/indexes/
/root/autodl-tmp/FlashRAG/flashrag/retriever/index_builder.py:103: UserWarning: Some files already exists in save dir and may be overwri
tten.
  warnings.warn("Some files already exists in save dir and may be overwritten.", UserWarning)
Generating train split: 20 examples [00:00, 1827.34 examples/s]
Finish loading...
Inference Embeddings:: 100%|████████████████████████████████████████████████████████████| 1/1 [00:00<00:00,  2.42it/s]
Creating index
Finish!
```

> --pooling_method：如果未指定，我们将根据模型名称和模型文件自动选择。但是，由于不同嵌入模型使用的池化方法不同，为确保准确性，你可以**指定与使用的检索模型对应的池化方法**（mean、pooler 或 cls）。
>
> --instruction：某些嵌入模型需要额外的指令以在编码前连接查询，可以在此处指定。目前，对于 E5 和 BGE 模型，我们将自动填充指令，而其他模型需要手动补充。
>
> --faiss_type：Flat表示使用扁平索引（全精度暴力搜索），Flat 索引虽然精确，但可能在大规模数据集上速度较慢。其他常用索引类型包括 IVF、HNSW 等。

```
# 中文
python -m flashrag.retriever.index_builder \
    --retrieval_method bge \
    --model_path /root/autodl-tmp/models/bge-large-zh-v1.5 \
    --corpus_path /root/autodl-
tmp/FlashRAG/examples/quick_start/indexes/docs.jsonl \
    --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/ \
    --use_fp16 \
    --max_length 512 \
    --batch_size 256 \
    --pooling_method mean \
    --faiss_type Flat
```

- **执行命令：**

```
(flashrag) (base) root@autodl-container-48b1458428-957c1534:~/autodl-tmp# python -m flashrag.retriever.index_builder \
    --retrieval_method bge \
    --model_path /root/autodl-tmp/models/bge-large-zh-v1.5 \
    --corpus_path /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/docs.jsonl \
    --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/ \
    --use_fp16 \
    --max_length 512 \
    --batch_size 256 \
    --pooling_method mean \
    --faiss_type Flat
/root/autodl-tmp/FlashRAG/flashrag/retriever/index_builder.py:61: UserWarning: Instruction is not set!
  warnings.warn("Instruction is not set!")
/root/autodl-tmp/FlashRAG/examples/quick_start/indexes/
/root/autodl-tmp/FlashRAG/flashrag/retriever/index_builder.py:103: UserWarning: Some files already exists in save dir and may be overwritten.
  warnings.warn("Some files already exists in save dir and may be overwritten.", UserWarning)
Generating train split: 20 examples [00:00, 2655.30 examples/s]
Finish loading...
Inference Embeddings:: 100%|████████████████████████████████████████████████████| 1/1 [00:00<00:00,  2.64it/s]
Creating index
Finish!
```

（2）基于Sentence-Transformers库

如果检索模型支持 sentence transformers 库，可以使用以下代码来构建索引（**无需考虑池化方法**）。

```
python -m flashrag.retriever.index_builder \
    --retrieval_method e5 \
    --model_path /root/autodl-tmp/models/e5-base-v2 \
    --corpus_path /root/autodl-
tmp/FlashRAG/examples/quick_start/indexes/docs.jsonl \
    --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/ \
    --use_fp16 \
    --max_length 512 \
    --batch_size 256 \
    --sentence_transformer \
    --faiss_type Flat
```

（2）对于稀疏检索方法（BM25）

如果构建 BM25 索引，则无需指定 model_path。

- **使用 BM25s 构建索引**

```
python -m flashrag.retriever.index_builder \
  --retrieval_method bm25 \
  --corpus_path /root/autodl-
tmp/FlashRAG/examples/quick_start/indexes/docs.jsonl \
  --bm25_backend bm25s \
  --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/
```

```
(flashrag) (base) root@autodl-container-48b1458428-957c1534:~/autodl-tmp#
(flashrag) (base) root@autodl-container-48b1458428-957c1534:~/autodl-tmp# python -m flashrag.retriever.index_builder \
  --retrieval_method bm25 \
  --corpus_path /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/docs.jsonl \
  --bm25_backend bm25s \
  --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/
/root/autodl-tmp/FlashRAG/flashrag/retriever/index_builder.py:61: UserWarning: Instruction is not set!
  warnings.warn("Instruction is not set!")
Pooling method not found in None, use default pooling method (mean).
/root/autodl-tmp/FlashRAG/examples/quick_start/indexes/
/root/autodl-tmp/FlashRAG/flashrag/retriever/index_builder.py:103: UserWarning: Some files already exists in save dir and may be overwritten.
  warnings.warn("Some files already exists in save dir and may be overwritten.", UserWarning)
Finish loading...
Finding newlines for mmindex: 100%|████████████████████████████████████████████| 6.11k/6.11k [00:00<00:00, 7.04MB/s]
Finish!
```

- **使用 Pyserini 构建索引**

```
# Ubuntu系统，需要安装 JAVA
# sudo apt install openjdk-21-jdk

python -m flashrag.retriever.index_builder \
    --retrieval_method bm25 \
    --corpus_path /root/autodl-
tmp/FlashRAG/examples/quick_start/indexes/docs.jsonl \
    --bm25_backend pyserini \
    --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/
```

```
2024-12-16 22:31:32,140 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:205) - Setting log level to INFO
2024-12-16 22:31:32,143 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:208) - ============ Loading Index Configuration ============
2024-12-16 22:31:32,143 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:209) - AbstractIndexer settings:
2024-12-16 22:31:32,143 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:210) -  + DocumentCollection path: /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/bm2
5/temp
2024-12-16 22:31:32,143 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:211) -  + CollectionClass: JsonCollection
2024-12-16 22:31:32,143 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:212) -  + Index path: /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/bm25
2024-12-16 22:31:32,144 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:213) -  + Threads: 1
2024-12-16 22:31:32,144 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:214) -  + Optimize (merge segments)? false
Dec 16, 2024 10:31:32 PM org.apache.lucene.store.MemorySegmentIndexInputProvider <init>
INFO: Using MemorySegmentIndexInput with Java 21; to disable start with -Dorg.apache.lucene.store.MMapDirectory.enableMemorySegments=false
2024-12-16 22:31:32,166 INFO  [main] index.IndexCollection (IndexCollection.java:246) - Using DefaultEnglishAnalyzer
2024-12-16 22:31:32,166 INFO  [main] index.IndexCollection (IndexCollection.java:247) - Stemmer: porter
2024-12-16 22:31:32,166 INFO  [main] index.IndexCollection (IndexCollection.java:248) - Keep stopwords? false
2024-12-16 22:31:32,166 INFO  [main] index.IndexCollection (IndexCollection.java:249) - Stopwords file: null
2024-12-16 22:31:32,254 INFO  [main] index.IndexCollection (IndexCollection.java:197) - IndexCollection settings:
2024-12-16 22:31:32,254 INFO  [main] index.IndexCollection (IndexCollection.java:198) -  + Generator: DefaultLuceneDocumentGenerator
2024-12-16 22:31:32,254 INFO  [main] index.IndexCollection (IndexCollection.java:199) -  + Language: en
2024-12-16 22:31:32,255 INFO  [main] index.IndexCollection (IndexCollection.java:200) -  + Stemmer: porter
2024-12-16 22:31:32,255 INFO  [main] index.IndexCollection (IndexCollection.java:201) -  + Keep stopwords? false
2024-12-16 22:31:32,255 INFO  [main] index.IndexCollection (IndexCollection.java:202) -  + Stopwords: null
2024-12-16 22:31:32,255 INFO  [main] index.IndexCollection (IndexCollection.java:203) -  + Store positions? false
2024-12-16 22:31:32,255 INFO  [main] index.IndexCollection (IndexCollection.java:204) -  + Store docvectors? false
2024-12-16 22:31:32,256 INFO  [main] index.IndexCollection (IndexCollection.java:205) -  + Store document "contents" field? false
2024-12-16 22:31:32,256 INFO  [main] index.IndexCollection (IndexCollection.java:206) -  + Store document "raw" field? false
2024-12-16 22:31:32,256 INFO  [main] index.IndexCollection (IndexCollection.java:207) -  + Additional fields to index: []
2024-12-16 22:31:32,256 INFO  [main] index.IndexCollection (IndexCollection.java:208) -  + Whitelist: null
2024-12-16 22:31:32,256 INFO  [main] index.IndexCollection (IndexCollection.java:209) -  + Pretokenized?: false
2024-12-16 22:31:32,256 INFO  [main] index.IndexCollection (IndexCollection.java:210) -  + Codec: Lucene99
2024-12-16 22:31:32,256 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:238) - ============ Indexing Collection ============
2024-12-16 22:31:32,258 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:247) - Thread pool with 1 threads initialized.
2024-12-16 22:31:32,259 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:248) - 1 file found in /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/bm25/temp
2024-12-16 22:31:32,259 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:249) - Starting to index...
2024-12-16 22:31:32,412 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:307) - Indexing Complete! 20 documents indexed
2024-12-16 22:31:32,412 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:308) - ============ Final Counter Values ============
2024-12-16 22:31:32,412 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:309) - indexed:              20
2024-12-16 22:31:32,413 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:310) - unindexable:           0
2024-12-16 22:31:32,413 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:311) - empty:               0
2024-12-16 22:31:32,413 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:312) - skipped:             0
2024-12-16 22:31:32,413 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:313) - errors:              0
2024-12-16 22:31:32,417 INFO  [main] index.AbstractIndexer (AbstractIndexer.java:316) - Total 20 documents indexed in 00:00:00
Finish!
```

3. 案例Demo

```
streamlit run demo_zh.py --server.port 6006 --server.address 0.0.0.0
```

章节五：论文实验流程复现

所有使用的代码都基于仓库的 example/methods。我们为各种方法设置了适当的超参数。如果你需要自己调整它们，可以参考为每种方法提供的配置字典以及每种方法的原始论文。

1. 设置基本配置

首先，你需要在 `my_config.yaml` 中填写各种下载的路径。具体来说，你需要填写以下四个字段：

- **model2path**：用你自己的路径替换 E5 和 Llama3-8B-instruct 模型的路径
- **method2index**：填写使用 E5 构建的索引文件的路径
- **corpus_path**：填写 `jsonl` 格式的 Wikipedia 语料库文件的路径
- **data_dir**：更改为你自己的数据集下载路径

2. 实践-1：检索器 AAR（Contriever与ANCE）

这种方法需要使用一个新的检索器，因此你需要下载检索器并构建索引。

- **步骤1：下载 AAR-Contriever 与 AAR-ANCE**

```
git clone https://huggingface.co/OpenMatch/AAR-ANCE

git clone https://huggingface.co/OpenMatch/AAR-Contriever-KILT
```

- **步骤2：为 AAR-Contriever 和 AAR-ANCE 构建索引（注意，池化方法应该是 'mean' 和 'cls'）**

```
# AAR-contriever
python -m flashrag.retriever.index_builder \
    --retrieval_method aar-contriever \
    --model_path /root/autodl-tmp/models/AAR-Contriever-KILT \
    --corpus_path /root/autodl-
tmp/FlashRAG/examples/quick_start/indexes/general_knowledge.jsonl \
    --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/ \
    --use_fp16 \
    --max_length 512 \
    --batch_size 256 \
    --pooling_method mean \
    --faiss_type Flat
```

```
(flashrag) (base) root@autodl-container-48b1458428-957c1534:~/autodl-tmp#
(flashrag) (base) root@autodl-container-48b1458428-957c1534:~/autodl-tmp# python -m flashrag.retriever.index_builder \
    --retrieval_method aar-contriever \
    --model_path /root/autodl-tmp/models/AAR-Contriever-KILT \
    --corpus_path /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/general_knowledge.jsonl \
    --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/ \
    --use_fp16 \
    --max_length 512 \
    --batch_size 256 \
    --pooling_method mean \
    --faiss_type Flat
/root/autodl-tmp/FlashRAG/flashrag/retriever/index_builder.py:61: UserWarning: Instruction is not set!
  warnings.warn("Instruction is not set!")
/root/autodl-tmp/FlashRAG/examples/quick_start/indexes/
/root/autodl-tmp/FlashRAG/flashrag/retriever/index_builder.py:103: UserWarning: Some files already exists in save dir and may be overwritten.
  warnings.warn("Some files already exists in save dir and may be overwritten.", UserWarning)
Finish loading...
Inference Embeddings:: 100%|████████████████████████████████████████████████████████████| 59/59 [00:21<00:00,  2.74it/s]
Creating index
Finish!
```

```
# AAR-ANCE
python -m flashrag.retriever.index_builder \
    --retrieval_method aar-ance \
    --model_path /root/autodl-tmp/models/AAR-ANCE \
    --corpus_path /root/autodl-
tmp/FlashRAG/examples/quick_start/indexes/general_knowledge.jsonl \
    --save_dir /root/autodl-tmp/FlashRAG/examples/quick_start/indexes/ \
    --use_fp16 \
    --max_length 512 \
    --batch_size 256 \
    --pooling_method cls \
    --faiss_type Flat
```

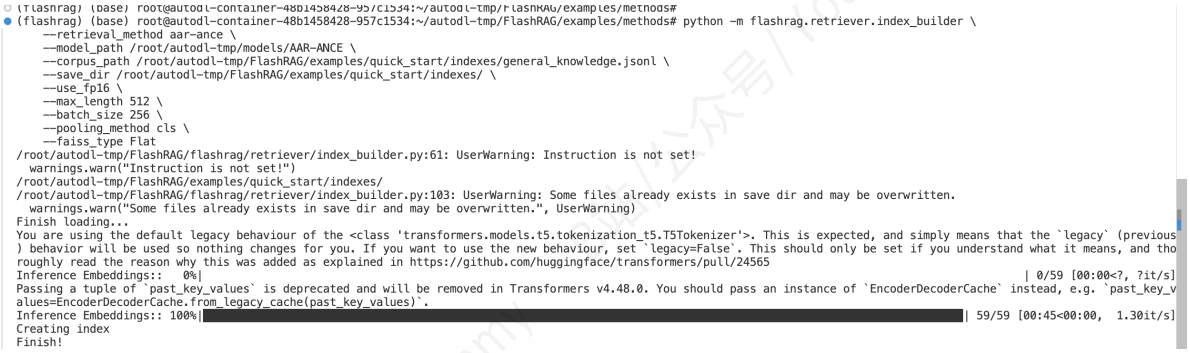

- **步骤3：修改 methods/my_config.yaml 里的配置信息**

```yaml
# ----------------------Global Paths-------------------------------#
# Paths to models
model2path:
  e5: "intfloat/e5-base-v2"
  bge: "BAAI/bge-base-en-v1.5"
  llama2-7B-chat: "meta-llama/Llama-2-7b-chat-hf"
  llama2-7B: "meta-llama/Llama-2-7b-hf"
  llama2-13B: "meta-llama/Llama-2-13b-hf"
  llama2-13B-chat: "meta-llama/Llama-2-13b-chat-hf"
  llama3-8B-instruct: "meta-llama/Meta-Llama-3-8B-Instruct"
  Llama-3.2-1B-Instruct: "/root/autodl-tmp/models/Llama-3.2-1B-Instruct"


# Pooling methods for each embedding model
model2pooling:
  e5: "mean"
  bge: "cls"
  contriever: "mean"
  jina: 'mean'
  dpr: 'cls'

# Indexes path for retrieval models
method2index:
  e5: ~
  bm25: ~
  contriever: ~

# ----------------------Environment Settings-----------------------#
# Directory paths for data and outputs
data_dir: "/root/autodl-tmp/datasets/FlashRAG_datasets"
save_dir: "output/"

gpu_id: "0,1,2,3"
dataset_name: "nq" # name of the dataset in data_dir
split: [ "test" ]  # dataset split to load (e.g. train,dev,test)

# Sampling configurations for testing
```

```yaml
test_sample_num: ~  # number of samples to test (only work in dev/test split), if None, test all samples
random_sample: False # whether to randomly sample the test samples

# Seed for reproducibility
seed: 2024

# Whether save intermediate data
save_intermediate_data: True
save_note: 'experiment'

# ------------------------Retrieval Settings------------------------------
---#
# If set the name, the model path will be find in global paths
retrieval_method: "contriever"  # name or path of the retrieval model.
index_path: ~ # SET AUTOMATICALLY IF NOT PROVIDED.
faiss_gpu: True # whether use gpu to hold index
corpus_path: "/root/autodl-tmp/FlashRAG/examples/quick_start/indexes/general_knowledge.jsonl"

instruction: ~ # instruction for retrieval model
retrieval_topk: 5 # number of retrieved documents
retrieval_batch_size: 256  # batch size for retrieval
retrieval_use_fp16: True  # whether to use fp16 for retrieval model
retrieval_query_max_length: 128  # max length of the query
save_retrieval_cache: False # whether to save the retrieval cache
use_retrieval_cache: False # whether to use the retrieval cache
retrieval_cache_path: ~ # path to the retrieval cache
retrieval_pooling_method: ~ # set automatically if not provided

use_reranker: False # whether to use reranker
rerank_model_name: ~ # same as retrieval_method
rerank_model_path: ~ # path to reranker model, path will be automatically find in `retriever_model2path`
rerank_pooling_method: ~
rerank_topk: 5  # number of remain documents after reranking
rerank_max_length: 512
rerank_batch_size: 256 # batch size for reranker
rerank_use_fp16: True

# ------------------------Generator Settings-----------------------------#
framework: vllm # inference frame work of LLM, supporting: 'hf','vllm','fschat'
generator_model: "Llama-3.2-1B-Instruct" # name or path of the generator model
generator_max_input_len: 2048  # max length of the input
generator_batch_size: 2 # batch size for generation, invalid for vllm
generation_params:
  do_sample: False
  max_tokens: 32
use_fid: False # whether to use FID, only valid in encoder-decoder model
```

```
# ----------------------------Refiner Settings-----------------------------
--#
# If set, the refiner will be used to refine the retrieval documents.
refiner_name: ~
refiner_model_path: ~

# Used for extractive method (e.g embedding models)
refiner_topk: 5 # number of remain sentence after refiner
refiner_pooling_method: 'mean' # pooling method of refiner model
refiner_encode_max_length: 256
# Used for abstractive method (e.g. generation models like bart-large-cnn)
refiner_max_input_length: 1024
refiner_max_output_length: 512

# Specify settings for llmlingua
llmlingua_config:
  rate: 0.55
  condition_in_question: 'after_condition'
  reorder_context: 'sort'
  dynamic_context_compression_ratio: 0.3
  condition_compare: True
  context_budget: "+100"
  rank_method: 'longllmlingua'
sc_config:
  'reduce_ratio': 0.5

# -------------------------Evaluation Settings----------------------------#
# Metrics to evaluate the result
metrics: [ 'em','f1','acc','precision','recall']
# Specify setting for metric, will be called within certain metrics
metric_setting:
  retrieval_recall_topk: 5
save_metric_score: True #  whether to save the metric score into txt file
```

- **步骤4：在 `run_exp.py` 中的 `AAR` 函数中修改 `index_path` 和 `model2path`**

```
def aar(args):
    """
    Reference:
        Zichun Yu et al. "Augmentation-Adapted Retriever Improves
Generalization of Language Models as Generic Plug-In"
        in ACL 2023.
        Official repo: https://github.com/OpenMatch/Augmentation-Adapted-
Retriever
    """
    # two types of checkpoint: ance / contriever
    # retrieval_method = "AAR-contriever"  # AAR-ANCE
    # index path of this retriever
    retrieval_method = args.method_name
```

```
    if "contriever" in retrieval_method:
        index_path = "/root/autodl-
tmp/FlashRAG/examples/quick_start/indexes/aar-contriever_Flat.index"
    else:
        index_path = "aar-ance_Flat.index"

    model2path = {"AAR-contriever": "/root/autodl-tmp/models/AAR-Contriever-
KILT", "AAR-ANCE": "model/AAR-ANCE"}
    model2pooling = {"AAR-contriever": "mean", "AAR-ANCE": "cls"}
    save_note = retrieval_method
    config_dict = {
        "retrieval_method": retrieval_method,
        "model2path": model2path,
        "index_path": index_path,
        "model2pooling": model2pooling,
        "save_note": save_note,
        "gpu_id": args.gpu_id,
        "dataset_name": args.dataset_name,
    }

    # preparation
    config = Config("/root/autodl-
tmp/FlashRAG/examples/methods/my_config.yaml", config_dict)
    all_split = get_dataset(config)
    test_data = all_split[args.split]

    from flashrag.pipeline import SequentialPipeline

    pred_process_fun = lambda x: x.split("\n")[0]
    pipeline = SequentialPipeline(config)
    # result = pipeline.run(test_data, pred_process_fun=pred_process_fun)
    result = pipeline.run(test_data)
    print(result)
```

- **步骤5：执行命令**

```
# AAR-contriever

python run_exp.py \
    --method_name 'AAR-contriever' \
    --split 'test' \
    --dataset_name 'nq' \
    --gpu_id '0'
```

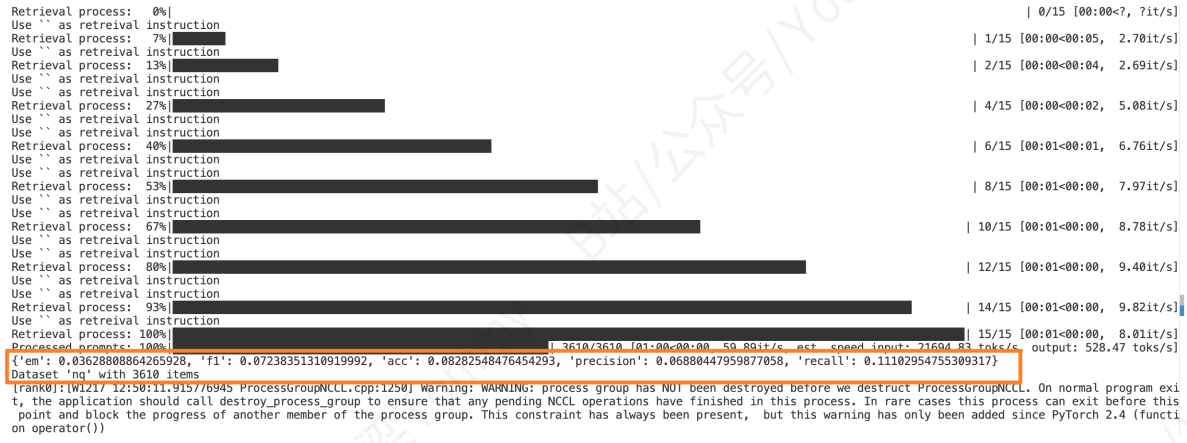


```
# AAR-ANCE

python run_exp.py \
    --method_name 'AAR-ANCE' \
    --split 'test' \
    --dataset_name 'nq' \
    --gpu_id '0'
```

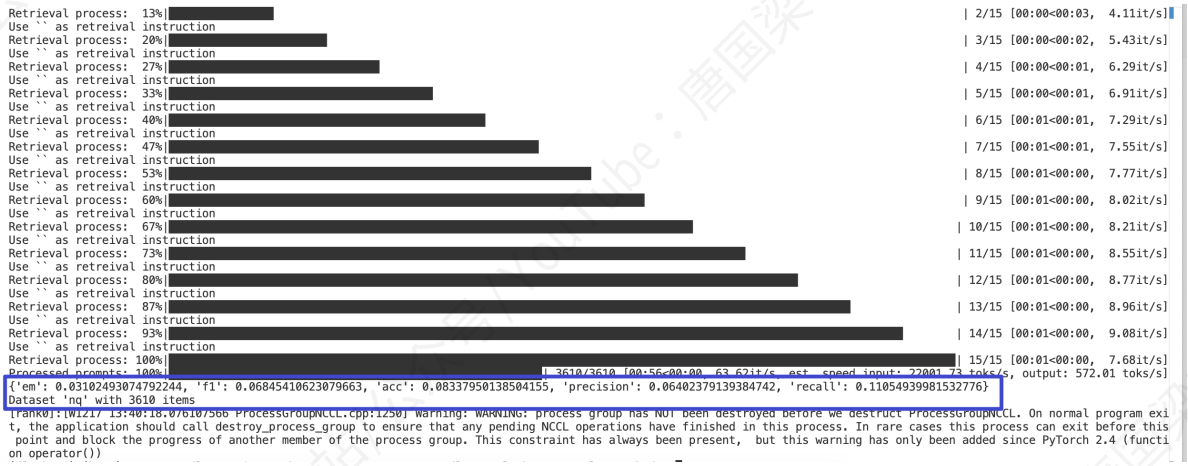

3. 实践-2：流水线 Self-RAG

- **第1步：修改在 `run_exp.py` 中的 `selfrag` 函数中修改 `index_path` 和 `model2path`**

```
def selfrag(args):
    """
    Reference:
        Akari Asai et al. " SELF-RAG: Learning to Retrieve, Generate and
Critique through self-reflection"
        in ICLR 2024.
        Official repo: https://github.com/AkariAsai/self-rag
    """
    config_dict = {
```

```
        "index_path": "/root/autodl-
tmp/FlashRAG/examples/quick_start/indexes/bge_Flat.index",
        "retrieval_model_path": "/root/autodl-tmp/models/bge-large-zh-v1.5",
        "generator_model": "selfrag-llama2-7B",
        "generator_model_path": "/root/autodl-tmp/models/selfrag_llama2_7b",
        "framework": "vllm",
        "save_note": "self-rag",
        "gpu_id": args.gpu_id,
        "generation_params": {
            "max_tokens": 128,
            "temperature": 0.0,
            "top_p": 1.0,
            "skip_special_tokens": False,
        },
        "dataset_name": args.dataset_name,
    }
    config = Config("/root/autodl-
tmp/FlashRAG/examples/methods/my_config.yaml", config_dict)

    all_split = get_dataset(config)
    test_data = all_split[args.split]

    from flashrag.pipeline import SelfRAGPipeline

    pipeline = SelfRAGPipeline(
        config,
        threhsold=0.2,
        max_depth=2,
        beam_width=2,
        w_rel=1.0,
        w_sup=1.0,
        w_use=1.0,
        use_grounding=True,
        use_utility=True,
        use_seqscore=True,
        ignore_cont=True,
        mode="adaptive_retrieval",
    )
    result = pipeline.run(test_data, long_form=False)

    print(result)
```

执行命令：

```
python run_exp.py \
    --method_name 'selfrag' \
    --split 'test' \
    --dataset_name 'nq' \
    --gpu_id '0'
```

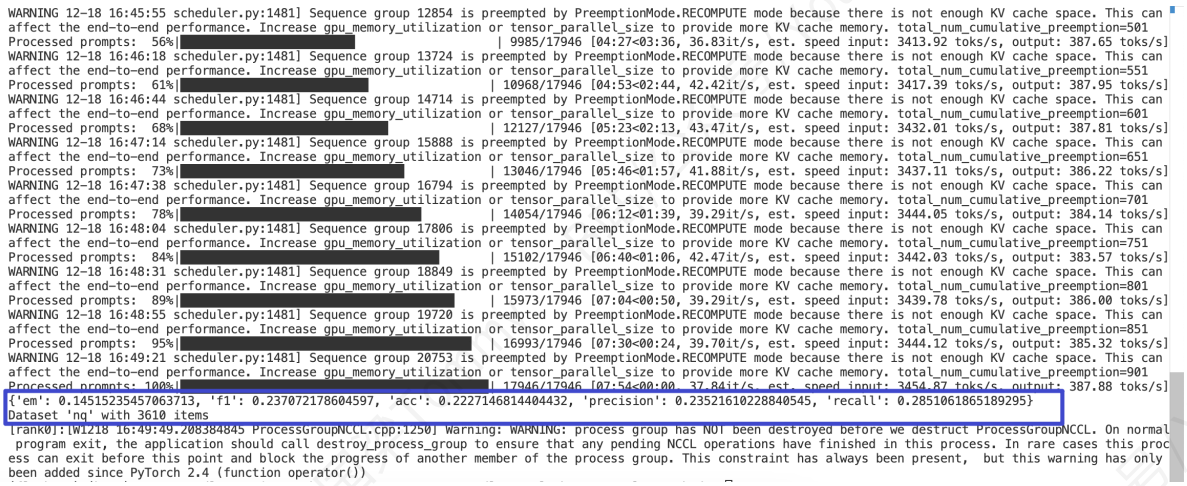

章节六：核心源码解析

Debug-1 : simple_pipeline.py

AI进阶学习

B站课堂：

https://space.bilibili.com/474347248/pugv

https://space.bilibili.com/3546748815411393/pugv

官方网站： https://www.tgltommy.com/ (国内访问需科学上网)

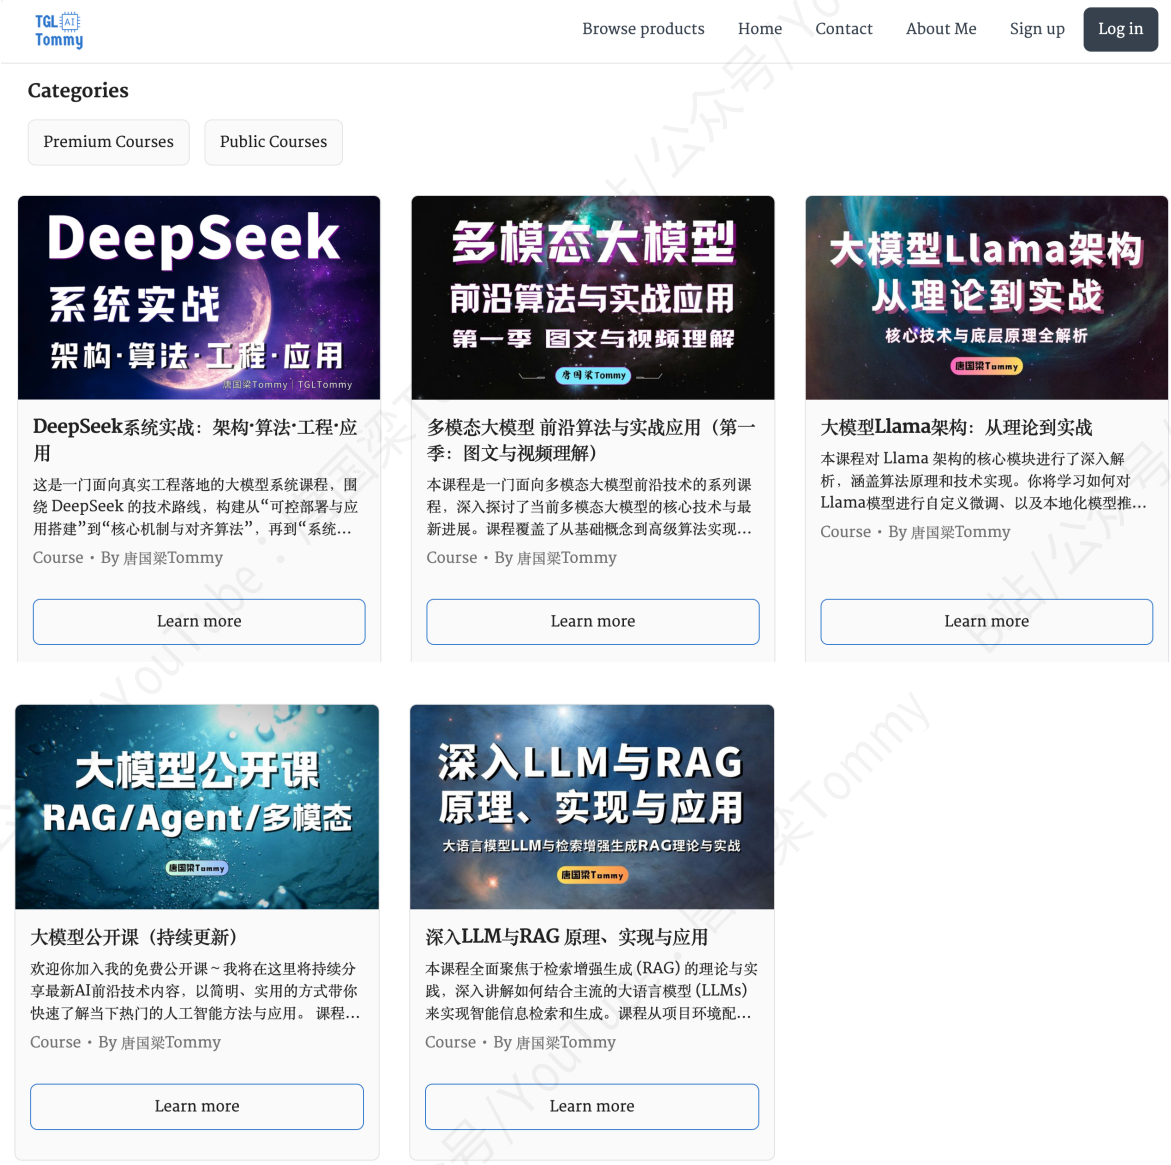

如果你希望系统掌握大模型核心技术、以及Agent应用开发，推荐你学习我刚上线的这门新课：**《DeepSeek 系统实战：架构·算法·工程·应用》**，这是一套从模型微调、部署，到强化学习训练的系统学习路线，课程以企业级落地为目标，你将掌握LLM核心原理、Agentic RAG、MoE/MLA/MTP机制拆解、PPO/GRPO强化学习与工业级DeepSeek-OCR多模态实战等，**想系统掌握并落地这些能力，就从这门课开始。**点击以下链接查看课程详情：

B站：https://www.bilibili.com/cheese/play/ss556613313

官网（国内访问需科学上网）：https://www.tgltommy.com/p/deepseek

B站/公众号/YouTube：唐国梁Tommy

欢迎关注微信公众号

官方网站：TGLTommy.com(需科学上网)