

CC-RAG: 규칙 기반 자기 신뢰도 평가와 동적 검색 정책을 통한 RAG 성능 향상

순동현, 오민석, 이상철[†]
대구경북과학기술원

dhsoon@dgist.ac.kr, harrymark0@dgist.ac.kr, sangchul.lee@dgist.ac.kr

CC-RAG: Enhancing Retrieval-Augmented Generation with Rule-Based Self-Assessment and Adaptive Top-k Retrieval

Donghyeon Soon, Minseok Oh, SangChul Lee[†]
DGIST

요약

Retrieval-Augmented Generation(RAG)은 외부 문서를 검색하여 생성 모델의 응답에 근거를 제공함으로써 오픈 도메인 질의응답에서 사실성과 최신성을 향상시키는 대표적 접근법이다. 그러나 기존 RAG 파이프라인은 질문 난이도와 무관한 고정 top-k 검색, 검색 품질과 무관한 답변 생성, 그리고 생성 결과의 신뢰도 추정 부재로 인해 환각(hallucination) 및 무응답 문제가 발생할 수 있다. 본 연구는 이러한 한계를 완화하기 위해, 추가 학습이나 별도의 critic 모델 없이 추론 단계에서만 동작하는 경량 제어 기반 RAG인 CC-RAG(Confidence-Controlled RAG)를 제안한다. CC-RAG는 (1) 생성 토큰의 평균 로그확률, 답변 길이, 정보성 토큰 포함 여부, 문서-답변 간 어휘 중복도 등을 결합한 규칙 기반 자기 신뢰도 평가로 낮은 신뢰도의 응답을 탐지하고, (2) 질문 난이도 및 초기 검색 절수에 따라 검색 깊이 k 를 조절하는 동적 검색 정책을 통해 문맥 효율성과 정보 커버리지를 동시에 확보한다. NQ-Open 벤치마크에서 CC-RAG는 prompt 기반의 Naive RAG(16.58%) 및 Chat-Template 기반의 Baseline RAG(18.91%) 대비 정확도를 향상시켜 22.01%를 달성하였으며, ablation 분석을 통해 자기평가와 동적 검색이 상호 보완적으로 기여함을 확인하였다. 본 연구는 학습 비용 없이도 RAG의 신뢰성과 성능을 개선할 수 있는 실용적인 추론 제어 전략을 제시한다.

I. 서론

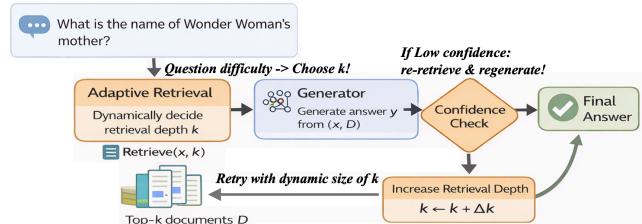
대규모 언어 모델(LLM)은 오픈 도메인 QA에서 뛰어난 생성 능력을 보이지만, 사전학습에 내재된 파라메트릭 지식에 의존해 최신 정보가 반영되지 않거나 외부 지식이 필요한 질문에서 환각(hallucination)이 발생할 수 있다. 이는 실제 서비스 환경에서 답변의 사실성과 신뢰성을 저해한다. Retrieval-Augmented Generation(RAG)은 외부 문서를 검색해 생성의 근거로 활용함으로써 이러한 한계를 완화하지만, 일반적인 rule-based RAG는 (1) 질문 난이도와 무관한 고정 top-k 검색, (2) 부정확한 검색 결과에도 답변 생성을 강제, (3) 생성 결과의 신뢰도 추정 부재로 환각을 사전에 억제하기 어렵다는 문제가 있다. 특히 소형 모델에서는 검색 품질에 대한 민감도가 더 크다. 본 연구는 이를 개선하기 위해 CC-RAG(Confidence-Controlled RAG)를 제안한다. CC-RAG는 추론 단계에서 규칙 기반 신뢰도 절수를 산출해 낮은 신뢰도의 경우 재검색·재생성을 수행하고, 질문 난이도에 따라 검색 깊이 k 를 동적으로 조절한다. 이를 통해 불필요한 문맥 증가를 줄이면서도 정보 누락을 완화해 RAG의 정확도와 신뢰성을 향상시키는 것을 목표로 한다.

II. 본론

2.1 시스템 구성 및 배경

본 연구는 두 단계로 구성된다. 먼저 Transformer 기반 GPT-small 언어 모델을 구현하고 사전학습 및 다운스트림 태스크를 통해 기본 생성 성능을 검증한다. 이후 BM25 검색기와 instruction-tuned LLM을 결합한 프롬프트 기반 RAG를 구축하고 이를 CC-RAG로 확장한다. GPT-small과 Baseline RAG를 직접 구현한 이유는, 프롬프트 구성·검색 깊이·재시도 로직 등 개별 요소의 영향을 분리하여 CC-RAG의 추론 단계 제어 효과를 재현 가능하게 검증하기 위함이다.

Figure 1. CC-RAG 모델의 파이프라인



기본 RAG는 검색된 문서를 프롬프트에 삽입한 뒤 답변을 생성하는 retrieve-then-generate 구조를 따른다. 본 연구에서는 검색 문서를 질문 앞에 단순 연결하는 flat prompt 방식을 Naive RAG로 정의하며, 이는 고정 k 검색과 신뢰도 추정 부재로 인해 검색 품질이 낮을 경우 무응답이나 환각이 발생하기 쉽다. 이를 개선하기 위해, LLaMA의 chat-template과 <docs> 블록을 적용한 Baseline RAG를 구축하고, 여기에 신뢰도 기반 재시도와 동적 검색 깊이 조절을 추가한 CC-RAG를 제안한다. 세 방법의 차이는 프롬프트 구조와 추론 단계 제어 유무로 요약되며, 성능 비교는 표 1에 제시한다.

표 1. NQ-Open에서 RAG 변형 모델들의 정확도 비교

Model	Prompt Format	Accuracy (%)
Naive RAG	Flat prompt	16.58
Baseline RAG	Chat-template	18.91
CC-RAG (ours)	Chat-template	22.01

2.2 제안기법: CC-RAG(Confidence-Controlled RAG)

본 절에서는 CC-RAG의 핵심 구성요소를 소개한다. 먼저 2.2.1절에서는 추가 학습 없이 계산 가능한 휴리스틱

표 2. Baseline RAG 와 CC-RAG(제안 방법)의 정성적 비교

Question	Baseline RAG	CC-RAG (Ours)	Ground Truth
Who sings "Does He Love Me" with Reba?	(No answer generated)	Linda Davis	Linda Davis
Where do the Great Lakes meet the ocean?	(No answer generated)	the Saint Lawrence River	the Saint Lawrence River
Who played Jason in Friday the 13th Part 1?	Tommy Jarvis	Ari Lehman	Ari Lehman
Who played Draco Malfoy in the Harry Potter movies?	Tom Felton	Tom Felton	Thomas Andrew Felton
What is the name of Wonder Woman's mother?	Queen Hippolyta	Queen Hippolyta	Queen Hippolyta

표 3. Ablation 실험 결과

Model	Acc (%) ↑	R-1 ↑	R-2 ↑	R-L ↑	R-L _{sum} ↑
Naive RAG	16.60	0.117	0.061	0.116	0.116
Baseline RAG	18.91	0.153	0.098	0.152	0.152
w/o Self-Assessment	21.88	0.254	0.145	0.254	0.254
w/o Dynamic Retrieval	21.79	0.254	0.146	0.253	0.254
CC-RAG (Ours)	22.01	0.256	0.146	0.255	0.255

신호를 결합해 생성 답변의 신뢰도를 추정하고, 신뢰도가 낮을 경우 재검색·재생성을 수행하는 메커니즘을 설명한다. 이어서 2.2.2절에서는 질문 난이도 및 초기 검색 품질에 따라 검색 깊이 k 를 동적으로 조절하는 정책을 제시하여, 단순 질의의 불필요한 문맥을 줄이면서도 어려운 질의의 정보 누락을 완화하는 방법을 다룬다.

2.2.1 규칙 기반 자기 신뢰도 평가(Self-Assessment)와 재시도

Self-RAG[1]는 생성 결과를 비평(critic)하여 낮은 신뢰도의 답변에 대해 재검색·재생성을 수행하는 루프 구조를 갖는다. 본 연구는 별도의 학습된 critic 모델 없이 규칙 기반 점수 산출로 대체하여 계산 비용을 크게 줄인다. 답변 y 와 문서 집합 D 가 주어졌을 때, CC-RAG는 신뢰도 점수 $s_{conf} \in [0,1]$ 를 다음과 같이 정의한다.

$$s_{conf}(x) = \sigma(w_1 \cdot \overline{\log p_\theta(y | x, D)} + w_2 \cdot f_{len}(y) + w_3 \cdot f_{NE}(y) + w_4 \cdot f_{overlap}(y, D))$$

여기서 $\overline{\log p_\theta(y | x, D)}$ 는 생성 토큰 평균 로그확률, f_{len} 은 답변 길이 휴리스틱, f_{NE} 는 숫자/고유명사 등 정보성 토큰 가중, $f_{overlap}$ 은 답변과 검색 문서 간 어휘 중복 (lexical overlap)을 의미한다. 신뢰도 점수가 임계값 τ 보다 낮을 경우($\tau=0.8$), 다음과 같이 재검색 및 재생성을 수행한다.

$$\text{if } s_{conf}(x) < \tau \Rightarrow k \leftarrow k + \Delta k, D \leftarrow \text{Retrieve}(x, k), y \leftarrow \text{Generate}(x, D)$$

이 재시도 메커니즘은 검색 근거가 불충분하거나 잘못된 경우 발생하는 환각을 완화하며, 정성 비교에서 무응답/오답이 정답으로 회복되는 사례를 확인할 수 있다(표 2 참조).

2.2.2 질문 난이도 기반 동적 검색 깊이(Dynamic Retrieval Depth)

기존 RAG는 모든 질문에 대해 동일한 k 개의 문서를 검색하는데, 이는 쉬운 질문에 대해 불필요한 문맥을 증가시키거나 어려운 질문에서 정보 누락을 초래한다. CC-RAG는 질문 길이 및 모호성, 초기 BM25 점수 등을 기반으로 난이도를 추정하여 검색 깊이 k 를 동적으로 조절한다. 예를 들어 비교적 단순한 질문에는 $k=2$ 수준의 소량 검색을 적용해 효율성을 확보하고, 정보 요구가 큰 질문에서는 k 를 최대 10까지 증가시켜 커버리지를 높인다. 또한 전체 문맥은 예산(예: 3000 토큰) 내에서 절단하여 과도한 토큰 사용을 방지한다.

2.3 실험 결과

본 연구는 NQ-Open에서 Accuracy와 ROUGE 계열 지표로 성능을 평가하고, Naive RAG(flat prompt), Baseline RAG(chat-template), CC-RAG를 비교하였다. 표 1의 정량 결과, CC-RAG는 추가 학습 없이 추론 단계 제어만으로 정확도를 개선했다($16.58\% \rightarrow 18.91\% \rightarrow 22.01\%$).

표 3의 정성 결과에서는 Baseline RAG가 무응답을 출력하거나 잘못된 개체를 생성한 경우, CC-RAG가 재검색을 통해 정답을 회복하는 경향을 보였다. 또한 ablation(표 3)에서 자기 신뢰도 평가와 동적 검색 깊이는 각각 단독 적용 시에도 성능을 높였고, 결합했을 때 최고 성능을 기록해 두 모듈이 상호 보완적으로 작동함을 확인했다.

III. 결론

본 연구는 기존의 RAG 파이프라인의 한계인 고정 검색 정책과 신뢰도 추정 부재로 인한 환각 문제를 완화하기 위해, 규칙 기반 자기 신뢰도 평가와 동적 검색 깊이 조절을 결합한 CC-RAG(Confidence-Controlled RAG)를 제안하였다. CC-RAG는 별도의 critic 모델이나 추가 학습 없이 추론 단계에서만 동작하며, 낮은 신뢰도의 답변에 대해 재검색·재생성을 수행함으로써 답변의 정확도와 신뢰성을 향상시킨다. 실험 결과 CC-RAG는 NQ-Open에서 Naive/Baseline RAG 대비 정확도 및 ROUGE 성능을 유의미하게 개선하였고, ablation 분석을 통해 자기평가와 동적 검색이 각각 성능 향상에 기여하며 결합 시 최적의 성능을 보임을 확인하였다. 또한 구현 관점에서 추가 학습 비용이 없고 추론 오버헤드가 매우 작아, 자연 시간이나 계산 자원이 제한된 환경에서도 적용 가능성이 높다. 다만 본 접근법은 검색기가 지속적으로 무관 문서를 상위에 랭크하는 경우 성능 한계가 존재한다. 향후 연구에서는 검색 불확실성 추정, 재랭킹 및 다중 흡 질의응답(multi-hop QA) 확장을 통해 한계를 보완할 수 있으며, 도메인 특화 환경으로의 적용 가능성도 추가 검증이 필요하다.

ACKNOWLEDGMENT

본 연구성과는 2025년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(RS-2025-090085).

참고 문헌

- [1] Asai, A., et al. (2023). Self-RAG: Learning to critique answers for improved retrieval-augmented generation, EMNLP, 2023.