혁신전공 AI특화프로그램

Hyun-Je Song

Definition

Given: A piece of text (keywords, question, news article, ...)

Rank: Other pieces of text (passages, documents, queries, ...)

Ordered by: Their content-based similarity (considering only the text)

e.g., Web search



Focus: Ad hoc Retrieval

Given: query q

collection of texts

Return: a ranked list of k texts $d_1 \dots d_k$

Maximizing: a metric of interest



metric: 0.66

Other Problems: Question Answering

Approach:

- Rank passages
- Rank answer spans

Question

What causes precipitation to fall?

Passage Sentence

In meteorology, precipitation is any product of the condensation of atmospheric water vapor that falls under gravity.

Answer Candidate

gravity

Other Problems: Community Question Answering

Quora

hours.

it had become too expensive.

New question: What is the longest airline flight?

Related Questions

What is the longest airline flight physically possible? Not flying around...


Once aircraft range is maxed out, what will eventually be the longest non-stop...

What is the longest commercial flight?

What is the world's shortest daily airline flight?

What is the longest airline flight you have been on? Where were you going?

What's the longest flight from New York?



Singapore Airlines is relaunching the service five years after it was cut because

Source: Quora

Q Search Ouora

Other Problems: Text Recommendation

NEWS

ASTRONOMY

Andromeda's and the Milky Way's black holes will collide. Here's how it may play out

Supermassive black holes will merge less than 17 million years after galaxy merger

By Sid Perkins

MARCH 5, 2021 AT 8:00 AM

The supermassive black holes at the centers of the Milky Way and Andromeda galaxies are doomed to engulf each other in an ill-fated cosmological dance.

Source: Science News

Related Stories



Supermassive black hole gets kicked to the galactic curb
By Ashley Yeager • March 28, 2017



A newfound black hole in the Milky Way is weirdly heavy By Christopher Crockett • November 27, 2019



Big black holes can settle in the outskirts of small galaxies
By Lisa Grossman • May 23, 2019


Focus: Content-based Similarity

Agreement between query and a piece of text

IR Background

Unsupervised ranking methods Ranking with Dense Representations

A Simple Search Engine



Unsupervised Ranking Methods

$$S(q, d) = \sum_{t \in q \cap d} TF(t) \times IDF(t)$$

Sparse representations

Unsupervised Ranking Methods

$$BM25(q,d) = \sum_{t \in q \cap d} \log \frac{N - df(t) + 0.5}{df(t) + 0.5} \cdot \frac{tf(t,d) \cdot (k_1 + 1)}{tf(t,d) + k_1 \cdot (1 - b + b \cdot \frac{l_d}{L})}$$

TF component

$$\frac{\operatorname{tf}(t,d)\cdot(k_1+1)}{\operatorname{tf}(t,d)+k_1\cdot\left(1-b+b\cdot\frac{l_d}{L}\right)}$$

term saturation length normalization

Sparse Representations

Task: Estimate the relevance of text d to a query q:

q = "fix my air conditioner"

d ="... AC repair ..."

$$BM25(q,d) = \sum_{t \in q \cap d} \log \frac{N - df(t) + 0.5}{df(t) + 0.5} \cdot \frac{tf(t,d) \cdot (k_1 + 1)}{tf(t,d) + k_1 \cdot (1 - b + b \cdot \frac{l_d}{L})}$$

Advantages: 1) Fast to retrieve candidates from an inverted index because q is usually short. 2) Fast to compute because $q \cap d$ is usually small Disadvantage: Terms need to match exactly


Dense Representations

Continuous dense vectors \mathbb{R}^D

 ϕ is a similarity function (e.g., inner product or cosine similarity) $\phi(\eta(q), \eta(d)) \rightarrow \text{ideally measures how relevant } q \text{ and } d \text{ are to each other}$

Task: find the top k most relevant texts to a query

Brute-force search:




We often need to search many (e.g.: billions) of texts

- Brute-force won't scale


Approximate Nearest Neighbor Search

- Exchange accuracy for speed
- E.g.: k-means:




- In practice, ANN implementations are more complicated
- A fast dense retrieval library is available (e.g.: **Faiss**, Annoy, ScaNN)

Types of Encoders: Cross-encoder



Types of Encoders: Bi-encoder



Retrieval augmented LLMs

검색 증강 (초거대)언어 모델 Retrieval augmented (Large) language model

 A (Large) language model (LM) that uses an external datastore at test time


Mokpo

• A language model $P(x_n | x_1, x_2, \dots, x_{n-1})$

Autoregressive LM


The third largest city in South Jeolla Province is _____

It uses retrieval results from the external datastore (at test time)



Why retrieval augmented LMs?

LMs can't memorize all (long-tail) knowledge in their parameters



0.8 Accuracy 0.4 10^{2} 10^{3} 10^{4} 10⁵ 10^{1} **Popularity** [Mallen et al., 2023]

What is Joe Biden's occupation? vs What is Kathy Saltzman's occupation?

23년 8월 31일 기준

기준

기준

미래 정보 기술 산업 전망 심포지엄에 대한 정보를 찾지 못했습니다. 심포지엄에 대한 추가 정보를 알려주시면 정확한 답변을 드릴 수 있습니다.

Why retrieval augmented LMs?

Augmenting LMs with relevant retrieved text helps to generate text

다음의 검색된 문서를 바탕으로 정보과학회에서 주관하는 미래 정보 기술·산업 전망 심포지엄에 대해 알려. 줘

검색된 문서: "안녕하십니까?

한국정보과학회(KIISE), 한국과학기술정보연구원(KISTI), 한국전자통신연구원(ETRI), 그리고 소프트웨어 정책연구소(SPRi)가 공동으로 개최하는 2023 information Technology and Industry Prospects (ITIP 2023) "제41회 미래 정보 기술·산업 전망" 심포지움에 여러분을 초대합니다.

국내 정보과학 분야 대표 학회인 한국정보과학회에서는 우리나라 정보산업의 주요 현안을 살피고, 4차산업 혁명 등 기술발전의 기류에 맞추어 향후 나아갈 방향을 제시함으로써 우리나라 정보산업발전에 기여하기 위 한 노력을 이어가고자 1983년부터 '정보산업리뷰심포지움'을 개최해왔습니다. 그리고 2011년부터는 이를 '미래 정보기술·산업전망 (iTIP)'이라는 명칭으로 변경하여 한국과학기술정보연구원, 한국전자통신연구원, 소프트웨어정책연구소와 공동으로 심포지움을 개최하고 있습니다.

올해에는 다양하면서 새로운 모습으로 급격하게 발전하는 사회에서 중요한 ICT 기술의 역할과 기술발전 전 망을 조명하고자 합니다. 특히 2022년 말에 등장하여 폭발적인 관심을 끌고 있는 생성형 AI 기술을 중심으 로 미래 사회의 변화를 예측함으로써 선제적·능동적인 대응 방안 마련을 위하여 "생성형 AI 기술 : 인프라, 알 고리즘, 활용"이라는 주제로 iTIP 2023을 준비하였습니다.

이번 iTIP 2023에서는 서울여대 김명주 교수님과 한국전자통신연구원 김영길 본부장님의 기조강연과 함께 9분의 최고 전문가들로부터 생성형 AI 윤리 및 규제를 포함하여 기술 동향 뿐만 아니라 인프라, 다양한 알고 리즘 및 응용 사례를 중심으로 앞으로 전개될 미래 전망을 파악할 수 있는 초청강연으로 준비하였습니다.

앞으로 급속도로 발전할 사회에서 생성형 AI 기술의 중요성과 향후 SW중심의 기술적 사회적 변화를 전망하고 보다 건강한 사회를 만들기 위해 노력하는 한국정보과학회에서 여러분을 iTIP 2023 심포지움에 초대합 니다."



한국정보과학회에서 주관하는 "미래 정보 기술·산업 전망" 심포지움(iTIP 2023)에 관한 정보는 다음과 같습 니다:

1. 주관 기관:

- 한국정보과학회(KIISE)
- 한국과학기술정보연구원(KISTI)
- 한국전자통신연구원(ETRI)
- 소프트웨어정책연구소(SPRi)

2. 역사 및 배경:

- 한국정보과학회는 1983년부터 '정보산업리뷰심포지움'을 개최하여 우리나라 정보산업발전에 기여하려고 노력해 왔습니다.
- 2011년부터 현재의 '미래 정보기술-산업전망 (iTIP)'이라는 명칭으로 변경하였고, 다른 연구기관과 공동으로 심포지움을 개최하고 있습니다.
- 3. 2023년 주제: "생성형 Al 기술 : 인프라. 알고리즘. 활용"
 - 2022년 말에 대중적인 관심을 받기 시작한 생성형 AI 기술에 대한 깊은 이해와 그 기술이 가져올 미래의 사회적 변화를 중심으로 심포지움이 준비되었습니다.


4. 주요 프로그램:

- 기조강연: 서울여대 김명주 교수와 한국전자통신연구원 김영길 본부장의 강연
- 초청강연: 총 9명의 전문가들이 참여하여 생성형 AI의 윤리 및 규제, 기술 동향, 인프라, 다양한 알고리 즉, 응용 사례 등에 대한 내용을 발표하고 향후 전망을 함께 논의합니다.

이 심포지움은 생성형 AI 기술의 중요성을 인식하고, 이를 중심으로 한 SW 중심의 기술적·사회적 변화에 대한 전망과 함께 미래 사회의 건강한 발전을 위한 노력을 주제로 합니다.

- 한국정보과학회(KIISE), 한국과학기술정보연구원(KISTI), 한국전자통신연구원(ETRI), 그리고 소프트웨어정책연구소(SPRI)가 공동으로 개최하는 2023 information Technology and Industry Prospects (iTIP 2023) "제41회 미래 정보 기술·산업 전망" 심포지움에 대한 정보는 다음과 같습니다.
 - 행사명: 2023 information Technology and Industry Prospects (iTIP 2023) "제41회 미래 정보기술·산 업 전망" 심포지움
 - 주제: 생성형 AI 기술 : 인프라, 알고리즘, 활용
 - 초청강연: 생성형 AI 윤리 및 규제를 포함하여 기술 동향 뿐만 아니라 인프라, 다양한 알고리즘 및 응용 사례를 중 심으로 앞으로 전개될 미래 전망을 파악할 수 있는 초청강연으로 준비하였습니다.
 - 주최: 한국정보과학회(KIISE), 한국과학기술정보연구원(KISTI), 한국전자통신연구원(ETRI), 소프트웨어정책연구소(SPRI)

국내 정보과학 분야 대표 학회인 한국정보과학회에서는 우리나라 정보산업의 주요 현안을 살피고, 4차산업혁명 등 기술발전의 기류에 맞추어 향후 나아갈 방향을 제시함으로써 우리나라 정보산업발전에 기여하기 위한 노력을 이어가고자 1983년부터 '정보산업리뷰심포지움'을 개최해왔습니다. 그리고 2011년부터는 이를 '미래 정보기술·산업전망 (ITIP)'이라는 명칭으로 변경하여 한국과학기술정보연구원, 한국전자통신연구원, 소프트웨어정책연구소와 공동으로 심포지움을 개최하고 있습니다.



Why retrieval augmented LMs?


LMs' knowledge is easily outdated and expensive to update

남자 마라톤 세계 신기록은?


저의 정보가 2021년 9월까지만 업데이트되어 있기 때문에, 그 이후의 데이터는 제공할 수 없습니다. 하지만 2021년 9월 현재로는, 남자 마라톤의 세계 신기록은 에티오피아의 케네니사 베키레(Kenenisa Bekele)가 2019년 9월 29일에 독일의 베를린 마라톤에서 세운 2시간 1분 41초입니다.

이 기록은 시간이 지나면서 더 빨라질 가능성이 있으므로, 가장 최신의 정보를 확인하시려면 공식 스포츠 기 관이나 믿을 수 있는 뉴스 소스를 참조하시는 것이 좋을 것입니다.

Existing LMs' knowledge editing methods are still NOT scalable




Open-domain question answering



Open-domain summarization


Generate a summary about



Joe Biden (born November 20, 1942) is the 46th president of the United States. He graduated from the University of Delaware in 1965 with a Bachelor of Arts in history and

코드 생성


Retrieve code (API) documentations about related functions



Fact verification / revision

2:01:39

2:01:09



Marathon. [1][2] This run improved on his own previous world record by 30 seconds. In 2018, he broke the then

September 25,

2022

September 16, 2018 Berlin Marathon

Berlin Marathon

world record by 1 minute and 18 seconds, the greatest improvement over a previous record since 1967. [1]

Kenya

≡ Kenya

Eliud Kipchoge

Eliud Kipchoge

Fact verification

1. You said: The marathon world record is 2:01:39, ...

2. I checked: What is the marathon world record?

3. I found this article: Kenyan Eliud Kipchoge set a world for men of 2:01:09, ...

4. Reasoning: The article said the world record time is

2:01:09, you said it is 2:01:39

5. Therefore: This disagrees with what you said.

Revised output

The marathon world record is **2:01:09**, set by Eliud Kipchoge of Kenya in **2022**.

IAAF^[1]

IAAF^[87]