

Pristopi k iskanju informacij - od klasičnih do jezikovnih modelov

Zaključna predstavitev pri predmetu raziskovalni seminar

Andrej Erjavec

Kazalo vsebine

01

Uvod

02

Iskanje informacij - definicija

03

Proces iskanja
informacij

04

Modeli za iskanje informacij

05

Zaključek




Uvod

- Naraščajoča količina digitalno shranjenih podatkov
- Iskanje informacij (IR) – veja računalniške znanosti
- >80% vseh podatkov je nestrukturiranih
- Ni vnaprej definirane sheme
- Več modelov za procesiranje besedil




Iskanje informacij - definicija

- Veja računalniške znanosti
- Hranjenje, predstavitev, iskanje informacij
- Tesno povezano z NLP in rudarjenjem besedil
- **Cilj: pridobiti množico relevantnih dokumentov glede na uporabnikovo poizvedbo.**



Poenostavljena shema procesa iskanja informacij
(vir: <https://botpenguin.com/glossary/information-retrieval>)


Proces iskanja informacij



Proces iskanja informacij (1)


1. Predobdelava

- A → a
- Tokenizacija
- Odstranjevanje pomensko manj pomembnih besed
- Stemming (Studying → Study)
- Lematizacija (Caring → Care)



2. Indeksiranje

- Pretvorba tokenov
- Inverzni indeks
- Vektorske predstavitve
- Vgnezditve




Proces iskanja informacij (2)

3. Iskanje

- Poizvedba
- Rezultat je nabor ustreznih dokumentov
- Ad-hoc in regex neučinkovita
- Enostavni algoritmi (BM25)
- Rezultat je naurejena množica dokumentov
- (N=1000)

4. Rangiranje

- Urejanje glede na relevantnost
- Kompleksnejši modeli
- Rezultat je urejena množica dokumentov
- (N=20)



Fazi iskanja in rangiranja
(vir: <https://neerajku.medium.com/document-ranking-using-bert-a4b00eb258c4>)

Izzivi pri iskanju informacij

Semantična neskladja

Uporabnik ne pozna structure ter besedišča dokumentov, zato prihaja do neskladij med poizvedbo ter vsebino dokumentov.

Semantika besedila

Podatki razpršeni po besedilu, relacije med koncepti definirane s semantiko + nepoznavanje strukture.

Polisemantičnost

Beseda ima lahkospremenjen pomen glede na kontekst. Model mora prepoznati kontekst okoli besede za določanje pomena.

Problem neskladja v besedišču

angl. Vocabulary mismatch problem.

Različni uporabniki za isti koncept uporabljajo različna poimenovanja.



Modeli za iskanje informacij

Boolovi modeli

- Boolova logika

Probabilistični model

- Binarni vektorji
BM25

Vektorski modeli

- Večdimanzionalni vektorski prostor
- Gosti vektorji
- Bag of Words
- TF-IDF

Vgnezditve

- Redki vektorji
- Word2Vec
- GloVe

Jezikovni modeli


- Zajem konteksta
- BERT
- modeli GPT

Boolov in razširjeni Boolov model

- Nizanje ključnih besed z logičnimi operatorji
- Lahko predstavimo z Venn diagramom
- Jasna struktura poizvedb
- Visoka stopnja nadzora nad pridobljenimi dokumenti
- Dokument ustreza ali pa ne ustreza (binaren rezultat)

Razširjeni Boolov model = klasični + algoritem za rangiranje

- Uteževanje poizvedb in dokumentov
- P-norm metrika
- Dokumenti rangirani po verjetnost, da so ustrezni



Probabilistični model

- Predstavitev z binarnimi vektorji.
- Komponenta vektorja = izraz v dokumentu
- Predp: pojavljanje izrazov v besedilu je statistično neodvisno.

Za vsak dokument izračunamo $P(R \mid d, q)$


Verjetnost, da je dokument d relavanen za poizvedbo q

BM25 (Best Match 25) uporabljen za iskanje in rangiranje.

- tf, idf + normalizacija dolžine besedila (preprečevanje prevlade daljših besedil)

Vektorski modeli

- Dokumenti = vektorji
- Večdimenzionalen Evklidski vektorski prostor
- Podobni izrazi so blizu v vektorskem prostoru
- Redka predstavitev (angl. sparse vectors; one-hot kodiranje)
 - $\text{dim} = |\text{korpus}|$
- Gosta predstavitev (angl. Dense vectors)
 - $\text{dim} \approx 300$
- Kosinusna in evklidska razdalja




Vektorska predstavitev besed
(vir: https://aegis4048.github.io/understanding_multi-dimensionality_in_vector_space_modeling)

TF-IDF

- Tf – število pojavitev besede v dokumentu
- Idf – normalizacija pogostih izrazov

$$TFIDF = tf(t,d) * IDF(t)$$


- + Učinkovit, enostaven za implementacijo
- Linearna rast utži s pogostostjo izraza (prioritizacija pogostih izrazov)
- Ni normalizacije dolžine dokumenta (BM25)



Vgnezditve

Do sedaj:


- redki vektorji ($\dim = |\text{korpus}|$)
- Ni zajema semantike besed
- Vgnezditve = predstavitev besed z gostimi vektorji
- Semantično podobne besede (dokumenti) so si blizu v vektorskem prostoru




Grafična predstavitev vgnezditve (vir: <https://devopedia.org/word-embedding>)

Word2Vec


- Google, 2013



Kontekst → ciljna beseda
(Boljši za redke besede)



Beseda → kontekst
(Hitrejši)



King - man + woman = queen

GloVe

- Model nenedzorovanega učenja
- Izboljšava Word2Vec
- Analiza so-pojavitve besed (kolikokrat se beseda pojavi v kontekstu druge besede v korpusu)
- Boljši v hitrosti napovedovanja kot CBOW in Skip-gram na enakem korpusu
- Ne upošteva polisemije besed (identični vektorji)
- Ne prepozna odvisnosti med besedami, pripon, predpon





Jezikovni modeli - BERT

- Razvoj globokega učenja in transformerskih modelov
- Modeli kontekstualnih vgnezditev
- Google, 2018
- Jedro Google spletnega iskalnika
- Dvosmerno branje besedila – zajem konteksta v obeh smereh od ciljne besede
- Predhodno treniran (pre-trained) na besedilih Wikipedia
- Pomen besede se dimamično prilagaja glede na kontekst (polisemija)
- Številne izpeljake (Docbert – klasifikacija dokumentov)

Maskirano jezikovno modeliranje


Naključno maskiranje besed in učenje rekonstrukcije iz širšega konteksta.

Napovedovanje naslednjega stavka

Ali si dva stavka logično sledita

Jezikovni modeli - GPT

- Generative pre-trained transformers
- Generacija tekočega, semantično smiselnega besedila
- Običajno niso uporabljeni za vektorsko predstavitev



Integracija LLM v proces iskanja informacij

Zaključek

- Velika količina digitalno shranjenih dokumentov → potreba po učinkovitem iskanju informacij
- Skozi leta razvoj v kompleksno znanstveno področje.
- Od klasičnih do jezikovnih modelov, nevronske mreže, globoko učenje



Hvala za pozornost!

Vprašanja?

Reference

[1]
B. Mitra and N. Craswell, “Neural Models for Information Retrieval,” May 03, 2017, *arXiv*: arXiv:1705.01509. doi: [10.48550/arXiv.1705.01509](https://doi.org/10.48550/arXiv.1705.01509).

[2]
Y. Zhu *et al.*, “Large Language Models for Information Retrieval: A Survey,” Sep. 04, 2024, *arXiv*: arXiv:2308.07107. doi: [10.48550/arXiv.2308.07107](https://doi.org/10.48550/arXiv.2308.07107).


[3]
K. A. Hambarde and H. Proença, “Information Retrieval: Recent Advances and Beyond,” *IEEE Access*, vol. 11, pp. 76581–76604, 2023, doi: [10.1109/ACCESS.2023.3295776](https://doi.org/10.1109/ACCESS.2023.3295776).

[4]
G. Salton, E. A. Fox, and H. Wu, “Extended Boolean information retrieval,” *Commun. ACM*, vol. 26, no. 11, pp. 1022–1036, Nov. 1983, doi: [10.1145/182.358466](https://doi.org/10.1145/182.358466).

[5]
P. Bafna, D. Pramod, and A. Vaidya, “Document Clustering: TF-IDF approach”.

[6]
D. Hiemstra and A. P. de Vries, “Relating the new language models of information retrieval to the traditional retrieval models”.

[7]



A. Petukhova, J. P. Matos-Carvalho, and N. Fachada, "Text Clustering with Large Language Model Embeddings," *International Journal of Cognitive Computing in Engineering*, vol. 6, pp. 100–108, Dec. 2025, doi: [10.1016/j.ijcce.2024.11.004](https://doi.org/10.1016/j.ijcce.2024.11.004).

[8]

M. Sanderson and W. B. Croft, "The History of Information Retrieval Research," *Proc. IEEE*, vol. 100, no. Special Centennial Issue, pp. 1444–1451, May 2012, doi: [10.1109/JPROC.2012.2189916](https://doi.org/10.1109/JPROC.2012.2189916).

[9]

K. W. Church, "Word2Vec," *Nat. Lang. Eng.*, vol. 23, no. 1, pp. 155–162, Jan. 2017, doi: [10.1017/S1351324916000334](https://doi.org/10.1017/S1351324916000334).

[10]

N. T. James and R. Kannan, "A Survey on Information Retrieval Models, Techniques and Applications," *IJARCSSE*, vol. 7, no. 7, p. 16, Sep. 2017, doi: [10.23956/ijarcsse.v7i7.90](https://doi.org/10.23956/ijarcsse.v7i7.90).

[11]

Q. Jiao and S. Zhang, "A Brief Survey of Word Embedding and Its Recent Development," in *2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, Chongqing, China: IEEE, Mar. 2021, pp. 1697–1701. doi: [10.1109/IAEAC50856.2021.9390956](https://doi.org/10.1109/IAEAC50856.2021.9390956).