

Tečaj edukatora za edukatore: Dohvaćanje informacija u području Biomedicine i zdravstva

Matijaca, Danira

Educational content / Obrazovni sadržaj

Publication status / Verzija rada: **Accepted version / Završna verzija rukopisa prihvaćena za objavljivanje (postprint)**

Publication year / Godina izdavanja: **2024**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:171:945046>

Rights / Prava: [Attribution-NonCommercial 4.0 International/Imenovanje-Nekomercijalno 4.0 međunarodna](#)


Download date / Datum preuzimanja: **2025-01-24**



Repository / Repozitorij:

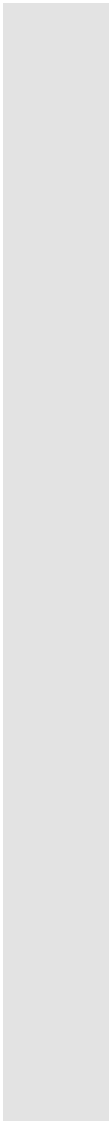
[MEFST Repository](#)





Biomedical information retrieval (BIR)

Dohvaćanje
informacija iz
područja Biomedicine
i zdravstva



Information retrieval



VEKTORSKI MODEL

- način predstavljanja dokumenata i upita kao vektora u višedimenzionalnom prostoru
 - Svaka riječ u dokumentu ima brojčanu vrijednost
 - Dokumenti i upiti se predstavljaju kao vektori
 - Sličnost između dokumenta i upita mjeri se kao "blizina" njihovih vektora

Primjer:

3 riječi: "Zagreb", "hotel", "restoran"

Dokument: "Zagreb ima mnogo hotela"Možemo ga predstaviti kao vektor: [1, 1, 0]

Upit: "hoteli u Zagrebu" [1, 1, 0]

VEKTORSKI MODEL

Što predstavljaju brojevi u vektoru?

1. Binarni pristup [0,1]

Dokument: "Zagreb hotel restoran"

Vektor: [1, 1, 1, 0, 0] znači:

1 = riječ postoji u dokumentu, 0 = riječ ne postoji

2. Brojanje pojavljivanja

Dokument: "Zagreb hotel hotel restoran hotel"

Vektor: [1, 3, 1, 0, 0] znači:

Brojevi pokazuju koliko se puta riječ pojavila

3. TF-IDF težine

Dokument: "Zagreb hotel hotel restoran hotel"

Vektor: [0.2, 0.5, 0.3, 0, 0] znači:

Brojevi pokazuju važnost riječi u dokumentu

Veća vrijednost = riječ je važnija za dokument

VEKTORSKI MODEL

TF (Term Frequency)

Koliko puta se riječ pojavljuje u dokumentu

Primjer: riječ "hotel" se pojavljuje 3 puta u dokumentu → $TF = 3$

IDF (Inverse Document Frequency)

Koliko je riječ rijetka u svim dokumentima

Primjer: "hotel" se pojavljuje u malo dokumenata → IDF velik

BM25

Poboljšani TF-IDF koji:

1. Ograničava utjecaj previše ponavljanja riječi
2. Uzima u obzir duljinu dokumenta

AI vektorska metoda

Vektorski modeli u AI

Klasični vektorski model

- Svaka riječ = jedna vrijednost (0 ili 1)
- Brojevi pokazuju samo pojavljivanje riječi
- Ne razumije značenje riječi
- Vektor: [1,1,0] = ["hotel", "Zagreb", "restoran"]

Problem: "hotel" i "apartman" su potpuno različiti

AI vektorski model (embeddings)

- Svaka riječ = vektor sa stotinama vrijednosti
- Svaka vrijednost predstavlja neku značajku riječi
- Razumije značenje i kontekst
- Vektor: [0.2, 0.8, 0.1, ...] = semantički opis riječi

Prednost: "hotel" i "apartman" imaju slične vrijednosti

Koriste ga: BERT, Word2Vec, GPT modeli...

Načini AI procesuiranja

Hijerarhija AI Tehnologija

1. Artificial Intelligence (AI)

- Najširi pojam
- Uključuje sve sustave koji simuliraju ljudsku inteligenciju

2. Machine Learning

- Podskup AI-ja
- Sustavi koji uče iz podataka i poboljšavaju se s iskustvom

3. Deep Learning

- Podskup Machine Learninga
- Koristi neuronske mreže s više slojeva za obradu

4. Natural Language Processing (NLP)

- Specifično područje AI-ja fokusirano na obradi jezika
- Kombinira različite AI tehnike

5. LLM (Large Language Models)

- Specifična implementacija (GPT, BERT, Claude)
- Koristi Deep Learning (Transformere)
- Najnapredniji oblik AI procesuiranja jezika

AI vs. Klasično

Uloga AI u Pretraživanju

1. Razumijevanje Upita

- Prepoznaje sinonime ("auto" = "automobil")
- Razumije kontekst ("jaguar" - životinja ili auto?)

2. Pametnije Rangiranje

- Uzima u obzir kvalitetu sadržaja
- Personalizira rezultate prema korisniku

3. Semantička Analiza

- Razumije značenje, ne samo riječi
- Povezuje slične koncepte

Klasično: "hotel Zagreb" → traži točne riječi

AI: "smještaj blizu centra Zagreba" → razumije namjeru i kontekst

Boolean

Boolean Pretraživanje

Dokumenti:

D1: "Luksuzni hotel u Zagrebu"

D2: "Zagreb je glavni grad"

D3: "Hotel nudi parking"

Operatori:

AND: obje riječi moraju postojati

OR: barem jedna riječ mora postojati

NOT: riječ ne smije postojati

Upit: "hotel AND Zagreb"

D1: "Luksuzni hotel u Zagrebu"

✓ Sadrži obje riječi → ODGOVARA

D2: "Zagreb je glavni grad"

X Nema riječ "hotel" → NE ODGOVARA

D3: "Hotel nudi parking"

X Nema riječ "Zagreb" → NE ODGOVARA

Evaluacija pretraživanja

Preciznost i Odziv

Rezultati za upit "Hotel u Zagrebu"

Sustav je vratio 5 dokumenata:

1. Hotel Westin Zagreb ✓

2. Hotel Dubrovnik Zagreb ✓

3. Apartman u Zagrebu X

4. Restoran Zagreb X


Preciznost = Točni/Vraćeni = 2/4 = 0.5 (50%)

→ Koliko vraćenih rezultata je relevantno

Odziv = Točni/Ukupno_relevantni = 2/3 = 0.67 (67%)

→ Koliko relevantnih dokumenata smo pronašli

Vennov dijagram



Preciznost = Točni/Vraćeni

Odziv = Točni/Relevantni

Evaluacija pretraživanja

F-mjera i MAP

F-mjera (F1 Score)

Formula:

$$F = 2 \times (\text{Preciznost} \times \text{Odziv}) / (\text{Preciznost} + \text{Odziv})$$

Primjer:

- Preciznost = 0.8 (80%)
- Odziv = 0.6 (60%)
- F-mjera = $2 \times (0.8 \times 0.6) / (0.8 + 0.6) = 0.686$ (69%)

MAP (Mean Average Precision)

Rangirani rezultati (✓ = relevantno, X = nije relevantno):

1. ✓ (P=1/1=1.0)
2. X
3. ✓ (P=2/3=0.67)
4. ✓ (P=3/4=0.75)

$$AP = (1.0 + 0.67 + 0.75) / 3$$

$$AP = 0.81 \text{ (81\%)}$$

MAP je prosjek AP-a za sve upite

Baze podataka

Izvori za dohvaćanje

Ključan aspekt
biomedicinskih
istraživanja i
medicine
utemeljene na
dokazima

- **Izvori za dohvaćanje / baze podataka**
 - PubMed
 - Google Scholar
 - Web of Science
 - Scopus
- **Alati za dohvaćanje**
 - Klasični upiti (Queries)
 - Sustavi umjetne inteligencije

Baze podataka vrste

- Osnovne vrste:
 - Bibliografske
 - podaci o primarnim izvorima: autor/i, naslov rada, naslov knjige, naslov časopisa, godina/svezak/stranice, naziv ustanove i sl., ključne riječi, sažetak...
 - Na području Biomedicine: MEDLINE, EMBASE, CURRENT CONTENTS, PsycINFO, CINAHL
 - Citatne
 - podaci o broju citata
 - WOS, SCOPUS, Google Scholar
 - Baze podataka s cjelovitim tekstovima
 - [Nature Journals Collection](#)
 - [Springer Journals](#)
 - [Cambridge Journals](#)
 - [IOPscience](#)
 - [Taylor & Francis Subject Collections](#)
 - [The Cochrane Database of Systematic Reviews](#)
 - ...
 - Kombinirane



National Library of Medicine

NLM

najpoznatije
informacijsko
čvorište za
diseminaciju
biomedicinskih
informacija

National Library of Medicine (NLM)

Lokacija:

- Bethesda, Maryland, SAD
- Dio National Institutes of Health (NIH) kampusa
- 8600 Rockville Pike, Bethesda, MD 20894


Institucija:

- Najveća biomedicinska knjižnica na svijetu
- Dio američkog ministarstva zdravstva (U.S. Department of Health)
- Osnovana 1836. godine

Značaj:

- Središte biomedicinskih informacija za cijeli svijet
- Upravlja ključnim bazama podataka (PubMed, MEDLINE)
- Razvija standarde za medicinsku informatiku

Katalog →



National Library of Medicine (NLM)

Glavni Resursi:



MEDLINE



PubMed



MeSH



Clinical
Trials



PMC

Pretraživanje:

- Boolean operatori (AND, OR, NOT)
- MeSH tezaurus za precizno pretraživanje
- Filteri (tip publikacije, godina, jezik...)


Značaj:

- Najveća biomedicinska knjižnica na svijetu
- Besplatan pristup medicinskoj literaturi




National Library of Medicine

Pubmed sučelje




- održava je NLM (National Library of Medicine)



- Sadrži:
 - Članke u časopisima indeksiranim u NLM bazi [MEDLINE](#)
 - uvršteno više od 5000 biomedicinskih časopisa
 - dostupna preko platformi: WOS, OVID, PUBMED, EBSCOhost
 - dnevno ažuriranje
 - online [knjige i dokumente](#) iz područja Biomedicine
 - cjelovite tekstove (PUBMED CENTRAL [PMC](#))
 - članci o istraživanjima financiranim javnim novcem (SAD)

Pubmed sučelja



Clarivate

Web of Science™

WEB OF SCIENCE sučelje

- zapisi/reference unose se od 1945.
- alati za analizu uspješnosti i kvalitete istraživanja
 - Broj citata
- oko 34,000 časopisa
- jedinstveno sučelje za **više baza**

The screenshot shows a search interface with two main tabs: "DOCUMENTS" and "RESEARCHERS". Below the tabs, there is a search bar with the text "Search in: All Databases ^" and "Collections: All v". A dropdown menu is open, listing several databases: "Web of Science Core Collection", "BIOSIS Citation Index", "Current Contents Connect", "Data Citation Index", "Derwent Innovations Index", "KCI-Korean Journal Database", "MEDLINE®", "Preprint Citation Index" (with a "New" badge), and "ProQuest™ Dissertations & Theses Citation Index" (with a "New" badge). To the right of the dropdown, there is a section titled "All Databases (1637-present)" with a description: "For the most comprehensive results, search across all subscribed resources using a common set of search fields." Below this description is a search input field and a "Search" button.

WOS (All databases)

Current Contents Connect

CCC

- dio WOS kolekcije
- Vlasnici u prošlosti:
 - Institute for Scientific Information
 - Thomson Reuters
 - **Clarivate Analytics** (danas)
- Indeksira sadržaje preko 10.000 znanstvenih časopisa i drugih publikacija
- Publikacije objavljene od 1989. do danas
- Baza se ažurira jednom tjedno

WoSCC Core Collection

Science Citation Index Expanded (SCIE)
Social Sciences Citation Index (SSCI)
Arts & Humanities Citation Index (AHCI)
Conference Proceedings Citation Index-
Science (CPCI-S) – od 1990.
Conference Proceedings Citation Index-
Social Science & Humanities (CPCI-
SSH)
Book Citation Index – Science
Book Citation Index – Social Sciences &
Humanities (BKCI-SSH)
Emerging Sources Citation Index (ESCI)
Current Chemical Reactions (CCR-
EXPANDED)
Index Chemicus (IC)

- Indeksira sadržaje preko 24 000 znanstvenih časopisa
- Publikacije objavljene od 1955. do danas
- Pretraživanje
 - General Search (Documents)
 - zapisa o indeksiranim publikacijama
 - Cited References
 - popisa korištene literature u indeksiranim publikacijama
 - Structure
 - pretraživanje struktura (npr. kemijskih)
- Časopisima u WoSCC-u na temelju citiranosti članaka izračunava se svake godine čimbenik utjecaja **Impact Factor**

KLINIČKI POKUSI



The **Epistemonikos Database of Trials** contains over **1,350,000** records of randomized trials sourced from multiple electronic databases, preprint servers, trial registries, and other sources.

A notable source are randomized trials included in systematic reviews from the Epistemonikos Database of Systematic Reviews.

Sučelje

nizozemskog izdavača Elseviera

Bibliografski zapisi publikacija
objavljenih od 1790.

Članci iz časopisa

Knjige

Zbornici

alati za analizu
uspješnosti i kvalitete istraživanja

Broj citata

<input type="checkbox"/>	Article	5,532,159
<input type="checkbox"/>	Conference paper	771,632
<input type="checkbox"/>	Review	546,434
<input type="checkbox"/>	Book chapter	362,751
<input type="checkbox"/>	Book	114,145
<input type="checkbox"/>	Editorial	50,260
<input type="checkbox"/>	Letter	48,762
<input type="checkbox"/>	Note	41,791
<input type="checkbox"/>	Short survey	17,008
<input type="checkbox"/>	Erratum	15,487
<input type="checkbox"/>	Conference review	7,425
<input type="checkbox"/>	Retracted	2,065
<input type="checkbox"/>	Data paper	2,046
<input type="checkbox"/>	Report	645
<input type="checkbox"/>	Abstract report	164
<input type="checkbox"/>	Undefined	49
<input type="checkbox"/>	Business article	33

Baze s podacima o utjecajnosti časopisa

- važne pri odabiru časopisa za objavljivanje
- pokazatelji kvalitete časopisa
- polazište za vrednovanje produktivnosti i utjecajnosti znanstvenika → NAPREDOVANJE

Clarivate

Journal Citation Reports™

Journals

Categories

Publishers

Countries/Regions

SJR

Scimago Journal & Country Rank

MESH baza

MEDICINSKI TEZAURUS

- održava je [NCBI](#) (National Center for Biotechnology Information)
- MeSH izraze ručno indeksiraju eksperti koji čitaju znanstvene publikacije i odabiru relevantne MeSH pojmove na temelju sadržaja članaka
- Datoteke se ažuriraju svaki tjedan od ponedjeljka do petka do 20:00 h
- MESH izrazi povećavaju kvalitetu rezultata pretraživanja
- razvijaju se alati koji u tekstu automatski prepoznaju MESH pojmove
 - [MeSH on Demand](#)

The Cochrane Library

- Cochrane Collaboration
 - Međunarodna neprofitna organizacija koja izrađuje, objavljuje i održava sustavne preglede (*systematic reviews*) o učincima intervencija u zdravstvu
- Cochraneova knjižnica je dostupna hrvatskoj akademskoj zajednici i zdravstvenim ustanovama preko Ovidovog sučelja
 - Ostali je mogu pretraživati do razine sažetaka

The Cochrane Library

- Cochrane knjižnica sadrži različite baze podataka, najvažnije su:
 - **The Cochrane Database of Systematic Reviews**
 - sustavni pregledni članci i protokoli za članke koji su u postupku izrade
 - najbolji izvor podataka o učinkovitosti terapije
 - **Database of Abstracts of Reviews of Effects (DARE)**
 - strukturirani sažetci kvalitativno procijenjenih sustavnih pregleda koji nisu izrađeni u okviru Cochrane kolaboracije
 - **The Cochrane Central Register of Controlled Trials (CENTRAL)**
 - nezaobilazan izvor randomiziranih kontroliranih pokusa koji se preuzimaju iz različitih baza (MEDLINE, EMBASE...) ili su pronađeni ručnim pretraživanjem literature

Select Resource(s) to search:

▼ **All Resources**

Books@Ovid January 17, 2017 i

Journals@Ovid Full Text January 19, 2017 i

Your Journals@Ovid i

EBM Reviews - ACP Journal Club 1991 to January 2017 i

EBM Reviews - Cochrane Central Register of Controlled Trials November 2016 i

EBM Reviews - Cochrane Database of Systematic Reviews 2005 to January 18, 2017 i

EBM Reviews - Cochrane Methodology Register 3rd Quarter 2012 i

EBM Reviews - Database of Abstracts of Reviews of Effects 1st Quarter 2015 i

EBM Reviews - Health Technology Assessment 4th Quarter 2016 i

EBM Reviews - NHS Economic Evaluation Database 1st Quarter 2015 i

EBM Reviews Full Text - Cochrane DSR, ACP Journal Club, and DARE i

All EBM Reviews - Cochrane DSR, ACP Journal Club, DARE, CCTR, CMR, HTA, and NHSEED i

AGRICOLA 1970 to December 2016 i

FRIC 1965 to October 2016 i

C
O
C
H
R
A
N
E

L
I
B
R
A
R
Y

OK

Add Group

Delete Group

INFO

sustavi

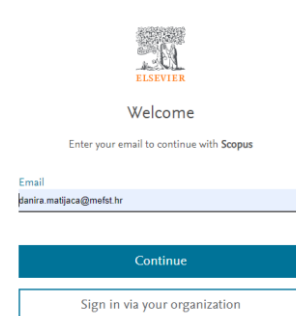

- SUMSearch
 - Istovremeno pretražuje različite medicinske izvore (DARE, Medline, National Guideline Clearinghouse)
 - pristup slobodan
- TRIPDatabase
 - Pretražuje veliki broj EBM-izvora
 - pristup slobodan do određene razine
- UpToDate
 - Komercijalni servis koji daje odgovore na klinička pitanja

PRISTUPI izvorima

- a) slobodni
- b) uz licencu

NACIONALNE
LICENCE

- Registrirajte se na fakultetskom računalu
- Možete koristiti bilo koju e-mail adresu (WOS)
- Potvrdite svoju račun putem e-maila (WOS)
- Koristite adresu u sustavu AAI@EduHr (SCOPUS)



- Od kuće slobodno pristupate putem prijave!

Klasični upiti

WoS Query

Karakteristike WoS pretraživanja:

Klasične značajke:

- Boolean operatori (AND, OR, NOT)
- Egzaktno podudaranje izraza
- Korištenje zagrada za grupiranje

Napredne značajke:

- NEAR/n operator za blizinu riječi
- Filtriranje po metapodacima
- Pretraživanje po citatima

Primjer WoS upita:


```
TS=(("artificial intelligence" NEAR/3 "information retrieval")  
AND ("search engine*" OR "web search"))
```

Objašnjenje:

- TS = pretraživanje po temi (topic search)
- NEAR/3 = riječi su udaljene najviše 3 riječi

1. Mhawi DN, Olewi HW, Saed NH, Al-Taie HL. An Efficient Information Retrieval System Using Evolutionary Algorithms. Network. 2022 Dec;2(4):583–605.

Ponavljanje
postupka




Oblikovanje upita

- Početna formulaciju upita
 - predviđanje riječi koje će biti uključene u upit
- Preoblikovanje upita
 - izmjena početnog upita radi boljeg odaziva i preciznosti
- Proširenje upita (Query Expansion)
 - preoblikuje početni upit dodavanjem sličnih izraza, izvučenih iz nekoliko izvora
- Optimizacija upita
 - prilagodba parametara pretraživanja

Bazični Booleanovi operatori

Booleanovi Operatori


AND



Oba pojma moraju
biti prisutna

A AND B


OR



Barem jedan pojam
mora biti prisutan

A OR B

NOT



Pojam ne smije
biti prisutan

NOT A

Primjer:

"hotel" AND "Zagreb" NOT "hostel"

→ Traži dokumente koji sadrže "hotel" i "Zagreb", ali ne sadrže "hostel"

Model PICO

PICO Framework

P

Population
Pacijenti
Problem

I

Intervention
Intervencija
Tretman

C

Comparison
Usporedba
Kontrola

O

Outcome
Ishod
Rezultat

Primjer:

P: dijabetes tip 2 | I: metformin | C: placebo | O: razina glukoze u krvi

AI ALATI

SR Accelerator: Alat namijenjen ubrzavanju i optimizaciji procesa revizije i analize istraživanja.

Notepad LM: Alat za vođenje bilješki i organizaciju misli, često korišten za brzo bilježenje ideja

• **Chat GPT**: AI asistent za generiranje teksta, koristan za podršku pri učenju, pisanju i istraživanju

Claude: Napredni AI model dizajniran za poslovne primjene i analizu podataka

Scite AI: Alat za analizu i procjenu znanstvenih radova, koji omogućava korisnicima da vide kako su drugi istraživači citirali radove.