

# Žad Deljkić

## Programski alati za automatsko mapiranje tematskih područja

*Software tools for automatic mapping of subject areas*

### Zadatak

U svrhu brzog obuhvaćanja temeljnih informacija za neko tematsko područje, potrebno je predložiti programske alate koji bi automatski prikupljali standardne podatke o tematskom području te grafički prikazivali međuzavisnosti na način prilagođen korisniku za daljnju analizu. Naglasak staviti na programsku dogradnju i korištenje programskih alata u širokoj uporabi, poput internetskih preglednika, i rješenja zasnovana na otvorenom kodu.

---

[Dnevnik rada](#) [GitHub repozitorij](#)

---

### Plan rada

1. Napisati upute za uspješno prevođenje i pokretanje NetGlub master-a, slave-a i klijenta (GUI)
2. Napraviti i dokumentirati što veći broj različitih transformacija
3. Napisati detaljne upute za izradu transformacija - od izrade Python skripte do integriranja u NetGlub sistem
4. Uspješno prevesti i pokrenuti klijent-a na Windows OS-u, napisati upute za to
5. Isprobati cijeli sistem preko mreže - master i slave(ovi) na Ubuntu OS-u, klijenti na Ubuntu i Windows OS-u
6. Napisati popis budućih projekata u kontekstu ovog rada
7. Ostalo:
  1. ~~Provjeri je li NetGlub smatra da su dva entiteta sa istim primarnim (npr. naslov knjige), ali različitim sekundarnim atributima (npr. autori, izdavač) jednaki (je li ih "merge-a") saznato - zapisano u poglavlje "Entiteti" niže~~
  2. PhraseToSimilarPhrasesW - makni rezultate sa "sidebar" i "nav" u nazivu
  3. Transformacija ili mehanizam koji provjerava je li fraza "legitimna" - pokuša naći knjige, članke, i sl. i ako ništa ne nađe onda nije?

---

### Upute za NetGlub

- Općenito o NetGlub-u, osnovno korištenje NetGlub-a
- Prevođenje i pokretanje NetGlub master-a, slave-a i klijenta na Ubuntu 14.04.
- Prevođenje i pokretanje NetGlub klijenta na Windows 7
- Izrada NetGlub transformacije i integriranje u cijeli sistem
- Pokretanje NetGlub master-a i slave-a za mrežni rad

## Entiteti

- Phrase - default entitet, najčešće ulazni
- Book
- Article
- Conference
- Author

### Zapisivanje imena autora:

U entitetima Book i Article bi u polju "authors" imena autora trebala biti ovako zapisana:

<prezime1>, <ime1>; <prezime2>, <ime2>; ...

Prezime bi trebali biti puno prezime, dok ime može biti puno ime, inicijali i slično - ovisi što nam je dostupno kod baze koju pretražujemo.

U različitim stranicama/bazama je ime autora različito zapisano. U nekim slučajevima u istoj bazi ime autora može biti zapisano u različitim formatima. Zadatak transformacije koja daje knjigu ili članak kao izlaz da pokuša pročitati i zapisati imena autora u ispravnom formatu.

Sam entitet autora ima jedno obavezno polje - prezime. Tako da i ako je na nekim stranicama zapisano puno ime, na nekima samo inicijali, a na nekima primjerice puno prvo ime i inicijali srednjeg imena, autor će se i dalje prepoznati kao isti. Nedostatak toga je rubni slučaj kada postoji više autora sa istim prezimenom u istom području, ali to je prihvatljiva posljedica za dobivenu fleksibilnost.

### Isti (spojeni entiteti):

Netglub smatra da su dva entiteta jednaka ako su im svi obavezni atributi (optional=false) jednaki. Službeno ne postoji nikakav "primarni" atribut - no konvencija među default entitetima je da svaki entitet ima atribut nazvan "value" koji je obavezan (uz još ostale obvezne/neobvezne attribute).

Tu nastaje dilema - ako je za knjige i članke jedini obvezni atribut naslov, netglub neće moći razlikovati dve knjige s istim naslovom. Zato je potrebno uvesti još neki atribut koji će ih razlikovati.

Ja sam stavio da to bude polje autora. U tom slučaju se može dogoditi da netglub smatra da su dvije zapravo iste knjige različite jer imaju različiti tekst u polju autora (npr. "Doe John" i "Doe J"), no u praksi je to manji problem od prvog problema kojeg ovo rješava (različite knjige - isti naslov).

Izvor: datoteka qng/src/graph.cpp, funkcija Node::isSimilitarTo

## Transformacije

### Gotove transformacije:

- PhraseToSimilarPhrasesW - uzima frazu i nalazi slične fraze pomoću Wikipedije
- PhraseToBookLOC - uzima frazu i nalazi relevantne knjige pomoću Library of Congress
- PhraseToArticlesGS - uzima frazu i nalazi relevantne članke pomoću Google Scholar-a
- PhraseToConferenceCA - uzima frazu i nalazi relevantne konferencije pomoću

[www.conferencealerts.com](http://www.conferencealerts.com)

- PhraseToBookArticleKoha - uzima frazu i stranicu koja koristi Koha sistem kao parametar, vraća relevantne članke i knjige. Primjeri stranica sa Koha sistemom:
  - [FER Središnja Knjižnica](#)
  - [Knjižnica FFZG](#)
- Book/ArticleToAuthor - transformacija koja će izvući autore iz knjiga/članaka, bila bi korisna kako bi se mogli grafički vidjeti oko kojih autora se "grupiraju" knjige i članci (tj. tko je potencijalno "bitniji" unutar nekog područja)
- PhraseToArticleIEEE - uzima frazu, vraća članak iz IEEE Xplore baze

### Buduće transformacije:

- PhraseToBook/Article - različite transformacije koje uzimaju frazu i vraćaju relevantne knjige/članke koristeći sljedeće baze:
  - Amazon
  - NSK
  - Hrčak
  - Crosbi
  - Web of Science
  - Online baze (koristeći proxy?)
  - ACM Digital Library
- PhraseToConference - različite transformacije koje uzimaju frazu i vraćaju relevantne konferencije koristeći sljedeće baze:
  - [IEEE Conference and Events](#)
- Transformacije u suprotnom smjeru (autor → knjige/članci → fraze)
- Transformacija koja povezuje osobu s FER-a i zavod koristeći <https://www.fer.unizg.hr/imenik>
- PhraseToSimilarPhrases - transformacija za nalaženje sličnih fraza samo mijenjanjem individualnih riječi u frazi njenim sinonimima + možda mehanizam koji za svaki dobiveni rezultat provjerava jel dobar/zadovoljavajući

### Lokalno testiranje transformacija:

Primjer pozivanja transformacije iz ljuske:

```
./transform phrase value test "" NbResult 5
```

Gornji primjer poziva transformaciju s ulaznim entitetom tipa "phrase", čiji je atribut "value" jednak "test" i s parametrom "NbResult" jednakim "5"

### Sigurnost

- Master na istom interfeceu/ip adresi očekuje i slaveove i klijente - to bi trebalo biti moguće odvojiti
  - npr. slave-ovi samo na 127.0.0.1, a klijenti na 0.0.0.0
- Master nikako ne autorizira slaveove - postoji "kostur" te funkcionalnosti ali nije implementirana
- Datoteke u /etc/netglub/ obično svi korisnici mogu čitati - a između ostalog sadrže username i password za bazu podataka, privatne ključeve certifikata...

## Budući projekti

- Alat koji prebacuje datoteku u NetGlub (.ntg) formatu u mind mapu u Freemind formatu (.mm)
  - .ntg je zippani XML, .mm je čisti XML - jednostavna python skripta bi bila dovoljna
- Alat koji potpuno zaobilazi NetGlub i "ručno" korisničko prtraživanje direktno koristi transformacije kako bi od ulazne fraze automatski generirao mapirano područje (možda u obliku mind mape)
  - Alat bi prvo mogao naći slične fraze pomoću PhraseToSimilarPhrases i filtrirati dobre pomoću nekog mehanizma
  - Zatim bi našao knjige, članke i slično pomoću već postojećih transformacija
  - Na kraju bi rezultate nekako lijepo prikazao - možda u obliku Freemind mind mape (.mm)
- Izrada alternativnog NetGlub klijenta koji radi unutar internet preglednika
- Izrada dodatnih transformacija (vidi "Buduće transformacije" gore)
- Pokrenuti javno dostupan server koji pokreće Netglub infrastrukturu na koju se ljudi mogu spojiti samo sa klijentom, bez potrebe da sami doma imaju pokrenut master i slave
  - Možda je za tu svrhu moguće dobiti [VPS od srca?](#)
- Master nezna reagirati na timeout od mysql baze - popraviti to
  - ako se nista ne desava 8 sati po defaultu master ce izgubit konekciju i kod sljedeceg pokusaja konekcije od klijenta ce se pojaviti serial not valid
  - rjesenje za sad je povecati wait\_timeout na maksimalnu vrijednost od 1 godine i restartat master bar 1 godisnje
  - rjesenje 2 promjena source koda, dve opcije:
    - a) main.cpp: setconnectoptions(mysql\_opt\_reconnect) ne cini se da radi
    - b) ntgsessionmanager.cpp: db.isopen() i isactive() navodno ne funkcionira <https://bugreports.qt.io/browse/qtbug-223>
  - implementirati provjeru jel db ziv na neki drugi nacin?

From: <http://studentski-izvjestaji.zesoi.fer.hr/> - **Studentski izvještaji**

Permanent link: [http://studentski-izvjestaji.zesoi.fer.hr/doku.php?id=studenti:zad\\_deljkic:zd-zr-start&rev=1433254857](http://studentski-izvjestaji.zesoi.fer.hr/doku.php?id=studenti:zad_deljkic:zd-zr-start&rev=1433254857)

Last update: **2023/06/19 16:20**

