

# Analiziranje sadržaja tekstova upotrebom ontologije i semantičke sličnosti

Dejan Prodanović, Bojan Furlan, Boško Nikolić

**Sadržaj** — U radu je opisan novi pristup za analiziranje tekstova. Pristup je baziran na primeni onotlogije za određenu oblast i semantičke sličnosti. Rezultati analize su primenjeni na studentski forum za oblast arhitekture i organizacije računara na Elektrotehničkom fakultetu Univerziteta u Beogradu. Predavačima su izdvojeni samo oni postovi čiji sadržaj pripada nameni foruma i povezani su sa temama iz kursa.

**Ključne reči** — semantička sličnost, ontologija, semantičke mreže, analiza foruma.

## I. UVOD

Pостоје бројни приступи за проналачење информација (*Information Extraction*) из текста написаног на природном језику. Неки су базирани на *text mining* техникама и статистичком приступу, док се други заснивају на принципима рачунарске лингвистике и обраде природног језика. Предности статистичког приступа су у већој прецизности са повећањем корпуса за обраду, једноставнија реализација и дужа историја развоја и употребе. Са друге стране, уколико је потребно обрадити краћи текст (коментар, пitanje или одговор), што је случај код форума или blogова, овакав приступ неће dati најбоље резултате имајући у обзиру мали број рећи које се могу анализирати. Из tog razloga se za kraće tekstove može upotrebiti neka od tehnika računarsке лингвистике. Међутим, алати за аутоматско проналачење информација могу бити недовољно прецизни и изоставити информације вредне за dalju analizu i izvršavanje. Традиционални приступи за проналачење информација, чак и проширењи са коришћењем концепата umesto reči/izraza ne daju uvek права поклapanja, ако nema preklapanja конкретних концепата који представљају семантiku. Како се opisi entiteta tretiraju као не зависне celine, relacije које nisu eksplicitno navedene u opisu entiteta обично се ignorišu. Понада semantičke sličnosti je proširen razmatranjem bitnih svojstava i relacija između концепата помоћу ontologije.

Kонцепт дodeljivanja метрике скуповима израза или документа засноване на sličnosti njihovog značenja je jedan од ključних за razumevanje природних језика, jer omogућава прављење смислених поређења и закључivanja.

D. Prodanović, Elektrotehnički fakultet u Beogradu, Bulevar kralja Aleksandra 73, 11120 Beograd, Srbija; (telefon: 381-11-3218320, e-mail: [pd095011p@student.etf.bg.ac.rs](mailto:pd095011p@student.etf.bg.ac.rs))

B. Furlan, Elektrotehnički fakultet u Beogradu, Bulevar kralja Aleksandra 73, 11120 Beograd, Srbija; (telefon: 381-11-3218320, e-mail: [bfurlan@etf.rs](mailto:bfurlan@etf.rs))

B. Nikolić, Elektrotehnički fakultet u Beogradu, Bulevar kralja Aleksandra 73, 11120 Beograd, Srbija; (telefon: 381-11-3218320, e-mail: [nbsko@etf.rs](mailto:nbosko@etf.rs))

Zbog тога одредивање semantičke sličnosti има важну улогу у аутоматској категоризацији текста, машиној преводњи, проналачењу информација и другим областима вештачке интелигенције. Problem semantičkog poređenja kratkih tekstova има poseban значај, jer су kratki текстови у широкoj употреби на Internetu, у форми natpisa i opisa proizvoda, anotacija slike i web stranica, kratkih novinskih naslova, vesti, komentara, itd. Ovaj problem takođe има важну улогу у областима vezanim за obrazovanje i učenje, као што су studentski forumi i elektronski razgovori, аутоматско testiranje i ocenjivanje zadataka, itd.

Slični проблеми постоје и на forumima који се користе као подршка учењу и као dodatni resursi за реализацију pojedinih курсева. Jedan od takvih foruma је i forum за oblast arhitekture i organizacije računara studenata Elektrotehničkog fakulteta Univerziteta u Beogradu. Sami studenti су moderatori ovog foruma i користе га интезивно као извор dodatnih информација за предмете из ове области. За predavače veći deo sadržaja foruma je nekoristan (типа diskusije studenata шта је predавано на ком часу, које gradivo se појављује на kolokvijumima, mogućnost zamene termina laboratorijskih vežbi, ...), ali može sadržati i značajne информације. Način diskusije je neformalan, па predavač može indirektno doći до информација који delovi курса су најзанимљивији studentima, које теме им представљају највећи проблем, kada im je потребна dodatna literatura ili objašnjenje. Zato bi predavačima od velike помоћи bio алат који има могућност izdvajanja само onih postova čiji sadržaji zaista pripadaju nameni foruma i који говоре о темама vezanim за sadržaj курса. У овом раду је opisan jedan takav sistem, који за analizu postavljenih tekstova користи ontologiju i semantičku sličnost. U drugom pogлављу je kroz kratак pregled radova opisan problem i predstavljen predlog rešenja, dok су u trećem i četvrtom pogлављу opisane njegove најбитније фазе. У petom pogлављу је dat zaključak.

## II. OPIS PROBLEMA I PREDLOG REŠENJA

U отвореној литератури се може прonaći više radova који се баве analiziranjem sadržaja tekstova.

У раду [1], opisan je метод за одредивање semantičke sličnosti dva kratka текста (рећенице или pasusa) користећи zajedno mere sličnosti reči zasnovane на рећнику i текстуалном корпузу, где се за svaku рећ u tekstu идентификује најбоље поклapanje sa другом рећи u suprotnom tekstu. Potom se taj rezultat pridodaje ukupnoj meri semantičke sličnosti.

У раду [2], predloženo je poboljšanje ovог приступа које укључује алгоритам лексичке sličnosti (poređenje на нивоу

niza karaktera) zajedno sa merom semantičke sličnosti reči zasnovane na textualnom korpusu.

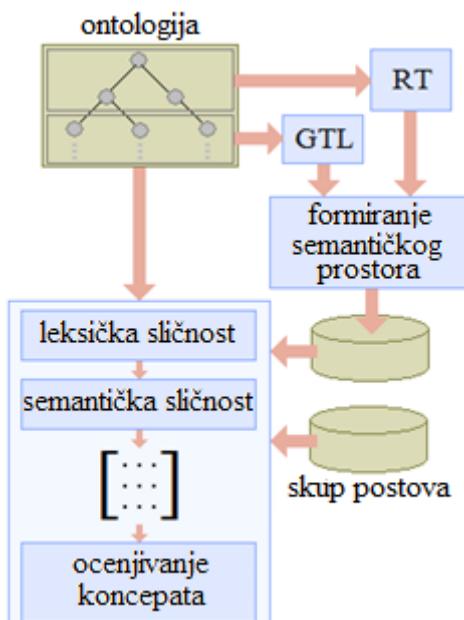
U radu [3], autori su predstavili metod za određivanje sličnosti rečenica koji koristi plitko parsiranje teksta. Iz rečenica se izdvajaju imenice, glagoli, kao i predlozi. Konačna sličnost se računa kao kombinacija sličnosti ove tri vrste izraza.

U radu [4], kombinovane su semantičke i sintaksičke informacije. Sintaksička analiza se vrši kroz proces dubokog parsiranja kako bi se u svakoj rečenici izdvojile fraze. Na kraju se izračunava sličnost između svih pojmoveva koji imaju istu sintaksičku ulogu pomoću leksičke baze.

Nažalost, za veliki broj jezika, među koje spada i srpski jezik, alati za duboko i plitko parsiranje nisu dostupni što navedene pristupe [3], [4] čini praktično neprimenljivim. Imajući ovo u vidu utvrđeno je da ni jedno od postojećih rešenja se ne može direktno primeniti na problem određivanja STSS (Short Text Semantic Similarity) tako da se može podjednako upotrebiti za engleski, srpski ili neki drugi jezik sa vrlo ograničenim elektronskim lingvističkim resursima. U ovom radu će biti opisan jedan novi pristup rešavanja opisanog problema.

Sve komponente sistema (korisnički interfejs, algoritmi i komunikacija između aplikacije i repozitorijuma za čuvanje semantičkog prostora) su realizovane u programskom jeziku Java. Ontologija je realizovana upotreboom alata *Protégé* [5], dok je za njeno čitanje iz datoteke korišćen alat *Jena* [6]. Za parsiranje web strana korišćen je programski alat *jsoup* [7], koji omogućava da se obradenim HTML dokumentima može pristupiti preko standardnih XML interfejsa. Ova komponenta je realizovana kao poseban servis koji periodično vrši obradu samo novog sadržaja.

Na slici 1. prikazan je blok dijagram sa najbitnijim elementima koji se koriste u radu softverskog sistema, gde se mogu uočiti dve faze: *formiranje semantičkog prostora*, *obrada postova*.



Sl 1. Blok dijagram za fazu kreiranja i čuvanja semantičkog prostora

### III. FORMIRANJE SEMANTIČKOG PROSTORA

Ova faza se može predstaviti u sledećim koracima: *formiranje ontologije*, *pripremanje korpusa za formiranje semantičkog prostora*, *parsiranje korpusa* i *čuvanje semantičkog prostora*.

#### A. Formiranje ontologije

Na početku faze *formiranja ontologije*, definisan je skup tema po kojima se sadržaji postova mogu klasifikovati. Izbor tema je napravljen na osnovu preporuka od stručnih udruženja IEEE i ACM, po kojima je oblast arhitekture i organizacije računara podeljena na osnovna poglavља i odeljke unutar poglavљa. Svaki odeljak može se poistovetiti sa odgovarajućom temom. Uvedeni su koncepti (termini) koji nedvosmisleno opisuju entitete, njihove međusobne relacije i procese koji se dešavaju unutar računarskog sistema, tako da je moguće svaki koncept smestiti u stablo u kom može biti i/ili roditelj i/ili potomak, oceniti ga pomoću definisanog algoritma i uspostaviti relaciju između posmatranog koncepta i postova u kojima je identifikovan.

#### B. Pripremanja korpusa za formiranje semantičkog prostora

U ovoj fazi identifikovan je skup reprezentativnih tekstova (RT - Reprezentative Text, blok na slici 1) koji obuhvata tekstove iz knjiga i skripti koji se koriste na predavanjima i vežbama. Kako se ove tekstovi nalaze u različitim tipovima datoteka (pdf, doc), bilo je neophodno njihovo izdvajanje u textualne datoteke, koje se koriste kao ulazni parametar za obradu. Uspostavljene su relacije između koncepata na prva dva hiperarhijska nivoa (poglavlja i odeljci) i reprezentativnih tekstova na taj način što za svaki koncept na odgovarajućem hiperarhijskom nivou postoji jedan ili više reprezentativnih tekstova. Za koncept na hiperarhijskoj dubini većoj od dva formirana je lista ključnih reči (GTL - Global Tag List, blok na slici 1). Ova lista je rezultat spajanja svih lista ključnih reči i sadrži sve različite reči koje su u njihovom sastavu.

#### C. Parsiranje korpusa

*Parsiranje korpusa* (*Corpus parsing*) je neophodno kako bi se uklonile sve suvišne informacije i izdvojio tekst od interesa. Ova faza se izvršava nad korpusom reprezentativnih tekstova i globalnom listom tagova u fazi formiranja semantičkog prostora, odnosno nad korpusom postova u fazi obrade postova i obuhvata sledeće korake:

- *Čišćenje teksta*, odnosno uklanjanje znakova koji spadaju u druga pisma, reči koje sadrže brojeve, uklanjanje datuma, interpunkcije, kao i izjednačavanje malih i velikih slova.

- *Uklanjanje stop reči*, koje je neophodno kako bi se uklonile reči koje imaju zanemarljiv semantički sadržaj, kao što su predlozi, zamenice i veznici, ali se zbog njihove jezičke funkcije često pojavljuju u tekstu. Uklanjanjem ovih reči smanjuje se semantički prostor i povećava tačnost semantičkih algoritama, jer veze između semantički važnih reči postaju više naglašene.

- *Stemovanje (stemming)*, odnosno proces uklanjanja završetka reči predstavlja transformaciju u kojoj može

doći do uklanjanja sufiksa reči, pri čemu se ne gubi osnovni semantički sadržaj. Ovaj postupak se može shvatiti i kao proces normalizacije u kojem se nekoliko oblika reči preslikava u isti oblik pa se na taj način smanjuje broj različitih reči. U radu [8], predložen je opšti sufiksni metod za konstruisanje stemera za jezike sa bogatom fleksijom i oskudnim resursima. Za ovaj pristup eksperimentalno je utvrđena tačnost od 81,83% za srpski jezik. U korpusu analiziranih tekstova delimično je korišćeno latinično pismo sa kodiranjima u ASCII i UTF-8 formatu, odnosno cirilično pismo sa kodiranjem u UTF-16 formatu. Korišćeni stemer za srpski jezik prihvata kao ulaz reči napisane u *dual1* kodiranju, gde se svaki dijakritik koduje kombinacijom dva nedijakritička slova, pa je bilo potrebno izvršiti konverziju koja prevodi tekst sa latinice i cirilice u ovo kodiranje, a zatim izvršava stemovanje.

#### D. Čuvanje semantičkog prostora

Čuvanje semantičkog prostora na disku je neophodno u cilju izbegavanja njegovog ponovnog kreiranja pri svakom pokretanju obrade. Ono se najčešće realizuje na dva načina: korišćenjem baze podataka ili datoteke koja sadrži serijalizovane objekte. Za čuvanje semantičkog prostora izabrana je baza podataka, dok se ontologija čuva u xml-serijalizovanoj datoteci.

### IV. OBRADA POSTOVA

Na slici 2 je prikazan glavni deo koda za obradu postova. U ovoj fazi utvrđuje se semantička sličnost između pročitanih reči u obrađenim postovima i reči iz globalne liste tagova kako bi se formirala ontološka komatrica. Ova struktura je potrebna u fazi ocenjivanja i utvrđivanja relacija između koncepata i obrađenih postova i za njeno izračunavanje korišćene su dve pomoćne strukture [9]: matrica leksičke i matrica semantičke sličnosti.

```
// pročitaj korpus obrađenih postova u odgovarajući niz
Text[] preprocessedTextArray = readPreprocessedTextArray();
// pročitaj ontološko stablo
ConceptTree conceptTree = readConceptTree();
// iz ontološkog stabla pročitaj obrađenu globalnu listu tagova
GlobalTagList globalTagList = conceptTree.getGlobalTagList();

// obrada svakog pojedinačnog posta
for (Text text : preprocessedTextArray)
{
    // obrada svake pročitane reči u obrađenom postu
    for (String[] tokenArray = text.getTextArray())
    {
        for (Tag tag : globalTagList)
        {
            // računanje ontološke komatricice
            Matrix m = calc_ontology_comatrix(tokenArray, globalTagList);
            // ocenjivanje koncepata
            score_the_concepts(m, conceptTree);
        }
    }
}
```

Sl 2. Glavni deo koda za obradu postova

#### A. Izračunavanje ontološke komatricice

Matrica leksičke sličnosti je predstavljena matricom  $M_1$  dimenzija  $m \times n$ , gde je  $m$  broj pročitanih reči iz obrađenog posta,  $n$  broj pročitanih reči iz globalne liste

sinonima za koncepte,  $\alpha_{ij} \in (0,1); i = 1, \dots, m; j = 1, \dots, n$ . Svaka vrednost  $\alpha_{ij}$  predstavlja sličnost na nivou niza karaktera između reči-kolone i reči-reda. Redovi matrice se koriste za pročitane reči iz obrađenog posta. Kolone matrice se koriste za reči iz globalne liste obrađenih sinonima za koncepte. Leksička sličnost između dve reči se računa pomoću algoritma najduže podsekvencije. Vrednost nula označava potpuno različite sadržaje dva niza karaktera, dok jedan ukazuje na identične.

$$M_1 = \begin{bmatrix} \alpha_{11} & \cdots & \alpha_{1n} \\ \vdots & \ddots & \vdots \\ \alpha_{m1} & \cdots & \alpha_{mn} \end{bmatrix} \quad (1)$$

Matrica semantičke sličnosti je predstavljena matricom  $M_2$  dimenzija  $m \times n$ , gde je  $m$  broj pročitanih reči iz obrađenog posta,  $n$  broj pročitanih reči iz globalne liste obrađenih sinonima za koncepte,  $\beta_{ij} \in [0,1]; i = 1, \dots, m; j = 1, \dots, n$ . Svaka vrednost  $\beta_{ij}$  u matrici predstavlja semantičku sličnost između reči-kolone i reči-reda. Redovi matrice se koriste za pročitane reči iz obrađenog posta. Kolone matrice se koriste za reči iz globalne liste obrađenih sinonima za koncepte. Vrednost nula označava potpuno različite semantičke sadržaje dve reči, dok vrednost jedan ukazuje na identične. Semantička sličnost između dve reči određuje se izračunavanjem kosinusne sličnosti njihovih kontekstnih vektora dobijenih iz baze podataka.

$$M_2 = \begin{bmatrix} \beta_{11} & \cdots & \beta_{1n} \\ \vdots & \ddots & \vdots \\ \beta_{m1} & \cdots & \beta_{mn} \end{bmatrix} \quad (2)$$

U prvoj fazi formiranja ontološke komatrice uklanjuju se svi redovi, odnosno kolone u kojima je vrednost  $\beta$  jednak nuli i dobija se matrica  $M_3$  dimenzija  $m \times n$ , gde su  $m$  broj redova, odnosno kolona iz matrice preostalih nakon sažimanja matrice  $M_2$ . U svakoj ćeliji matrice nalaze se uređeni skupovi  $C_{ij} = \{(c_1, w_1), \dots, (c_k, w_k)\}, TF - IDF_i, S_{ij}\}$ , gde je  $i = 1, \dots, m; j = 1, \dots, n; k \in (0, < \text{broj koncepata} >)$ . U svakom uređenom skupu  $C_{ij}$ ,  $c_k$  je koncept u čijoj listi obrađenih sinonimima se nalazi reč iz kolone  $j$ ,  $w_j$  težinski koeficijent koji predstavlja stepen pripadnosti reči u obrađenom sinonimu i određuje se kao recipročna vrednost broja reči u obrađenom sinonimu (na primer, ako je pročitana reč iz posta *kontroler*, a sinonim *DMA kontroler*, težinski koeficijent iznosi 0.5),  $TF - IDF_k$  je proizvod frekvencija pročitane reči u postu i inverzne dokument frekvencije, čija vrednost raste сразмерno broju pojavljivanja reči u dokumentu, ali je kompenzovana frekvencijom pojavljivanja reči u čitavom korpusu,  $S_{ij}$  ukupna semantička sličnost između reči u redu  $i$  i koloni  $j$  izračunata kao  $S_{ij} = 0.45\alpha_{ij} + 0.55\beta_{ij}$ , pri čemu su vrednosti koeficijenata utvrđene empirijskim putem.

$$M_3 = \begin{bmatrix} C_{11} & \cdots & C_{1n} \\ \vdots & \ddots & \vdots \\ C_{m1} & \cdots & C_{mn} \end{bmatrix} \quad (3)$$

U procesu sažimanja matrice  $M_3$  uklanjuju se svi redovi, odnosno kolone u kojima su vrednosti  $C_{ij}$  prazni skupovi i

dobija se matrica  $M_4$  dimenzija  $m \times n$ , gde su  $m$  i  $n$  broj redova i kolona iz matrice  $M_3$  preostalih nakon sažimanja.

### B. Ocenjivanje koncepata

Ocena koncepta predstavlja meru zastupljenosti određene oblasti u dokumentu gde je koncept pronađen. Posmatrajući međusobne relacije između koncepata, njihove različite hijerarhijske nivoe, kao i to da se koncepti na nižim nivoima mogu predstaviti pomoću liste ključnih reči, izdvojeni su sledeći parametri, koji se koriste u fazi ocenjivanja:

- *Koncentracija* predstavlja meru prisutnosti koncepta i njegovih potomaka u semantičkom podstablu. Težinski koeficijent za koncept određuje se na osnovu broja reči u tagu za taj koncept po sledećem kriterijumu:

$$w_{c_i} = \begin{cases} 0, & ncount(c_i) = 0 \\ 0.15, & ncount(c_i) > 0 \wedge ntokens(c_i) = 1 \\ 0.2, & ncount(c_i) > 0 \wedge ntokens(c_i) = 2 \\ 0.3, & ncount(c_i) > 0 \wedge ntokens(c_i) \geq 3 \end{cases} \quad (4)$$

, gde je:

- $ncount(c_i)$  - broj pojavljivanja sinonima u tekstu,
- $ntokens(c_i)$  - broj reči u pronađenom sinonimu.

Koncentracija za određeni koncept se određuje na osnovu njegovog težinskog koeficijenta i koncentracija za sve direktnе podkoncepte po sledećem obrascu:

$$score(c_i) = w_{c_i} + \frac{\sum_{j=1}^{child(c_i)} score(c_j)}{child(c_i)} \quad (5)$$

, gde je:

- $w_{c_i}$  - težinski koeficijent za koncept  $c_i$ ,
- $child(c_i)$  - broj direktnih potomaka koncepta  $c_i$ .

- *Relevantnost koncepta u semantičkom podstablu* predstavlja meru zastupljenosti svih njegovih potomaka u dokumentu i određuje se po sledećem obrascu:

$$cr(c_i) = \frac{nsc(c_i)}{nsub(c_i)} \quad (6)$$

, gde je:

- $nsc(c_i)$  - broj podkonceptata za koncept  $c_i$  računajući i koncept  $c_i$ , sa koncentracijom većom od definisanog praga,

-  $nsub(c_i)$  - ukupan broj podkonceptata za koncept  $c_i$  računajući i koncept  $c_i$ .

- *Relevantnost koncepta u dokumentu* određuje se na osnovu utvrđenih relacija u ontološkoj komatrici između odgovarajućeg koncepta i pročitanih reči u obradenom postu računanjem kvadratne sredine između relevantnosti koncepta u semantičkom podstablu i  $TF - IDF$  za pročitanu reč.

$$dr(c_i) = \sqrt{\frac{cr^2(c_i) + \sum_{i=0}^n (TF-IDF)_i^2}{n+1}} \quad (7)$$

, gde je:

-  $n$  - broj pročitanih reči u postu za koje postoji relacija sa odgovarajućim konceptom u ontološkoj komatrici.

Ukupna ocena za koncept formirana je na osnovu prethodno opisanih parametara i računa se po sledećem obrascu:

$$totalscore_{c_i} = w_{sc} \cdot score(c_i) + w_{cr} \cdot cr(c_i) + w_{dr} \cdot dr(c_i) \quad (8)$$

, gde su:

-  $w_{sc}, w_{cr}, w_{dr}$  - koeficijenti srazmere za koncentraciju, relevantnost koncepta i relevantnost dokumenta sa definisanim konstantama: 0.2, 0.3 i 0.5 respektivno.

## V. ZAKLJUČAK

U radu je opisan softverski sistem koji analizira sadržaje postova studentskog foruma i pomaže predavaču sa informacijama o najzastupljenijim temama i konceptima. Sistem je primenjen na oblast arhitekture i organizacije računara korišćenjem tehnika semantičke sličnosti i ontologije baziranoj na ovoj oblasti. Verifikacija realizovanog sistema je izvršena na postovima studentskog foruma Elektrotehničkog fakulteta Univerziteta u Beogradu. Dobijene informacije predavači mogu iskoristiti u svrhu promene i poboljšavanja svojih predavanja. Sistem trenutno predstavlja jednu funkcionalnu celinu, ali može biti deo složenijeg tutorskog softvera, jer je realizovan na modularan i proširiv način.

## LITERATURA

- [1] R. Mihalcea, C. Corley, and C. Strapparava, "Corpus-based and knowledge-based measures of text semantic similarity," in *National Conference on Artificial Intelligence*, 2006, vol. 21, no. 1, pp. 775–780
- [2] A. Islam and D. Inkpen, "Semantic text similarity using corpus-based word similarity and string similarity," *ACM Trans. Knowl. Discov. Data*, vol. 2, no. 2, pp. 1–25, Jul. 2008.
- [3] J. Oliva, J. I. Serrano, M. D. del Castillo, and Á. Iglesias, "SyMSS: A syntax-based measure for short-text semantic similarity," *Data Knowl. Eng.*, vol. 70, no. 4, pp. 390–405, Apr. 2011.
- [4] L. Li, Y. Zhou, B. Yuan, J. Wang, and X. Hu, "Sentence similarity measurement based on shallow parsing," in *Fuzzy Systems and Knowledge Discovery*, 2009, pp. 487–491.
- [5] Protégé, Ontology creation tool, <http://protege.stanford.edu>
- [6] Jena Semantic Web Framework, <http://jena.sourceforge.net>
- [7] jsoup, java HTML parser, <http://jsoup.org>
- [8] V. Kešelj and D. Šipka, "A suffix subsumption-based approach to building stemmers and lemmatizers for highly inflectional languages with sparse resource," *INFOTHECA-Journal Informatics Librariansh.*, vol. IX, no. 1–2, p. 24a–33a, 2008.
- [9] B. Furlan, V. Batanović, B. Nikolić, Semantic Similarity of Short Texts in Languages with a Deficient Natural Language Processing Support, *DECISION SUPPORT SYSTEMS*, Vol. 55, No. 3, pp. 710–719, Jun, 2013

## ABSTRACT

This paper describes new approach for text analyzing. The approach is based on applying domain ontology and semantic similarity. Analysis results are applied on the computer architecture and organization student forum on Faculty for Electrical Engineering, University of Belgrade. Teachers were singled out only those posts whose content belongs to the purpose of the forum and are related with the topics from the course.

## TEXT CONTENT ANALYSIS USING ONTOLOGY AND SEMANTIC SIMILARITY

D. Prodanović, B. Furlan, B. Nikolić

