Pristup analizi i primjeni korisničkog označivanja u predmetnom opisu baštinske građe

Ivanjko, Tomislav

Doctoral thesis / Disertacija

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Humanities and Social Sciences / Sveučilište u Zagrebu, Filozofski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:131:118393

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Filozofski fakultet
Sveučilišta u Zagrebu

Repository / Repozitorij:

ODRAZ - open repository of the University of Zagreb
Faculty of Humanities and Social Sciences

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu
FILOZOFSKI FAKULTET

TOMISLAV IVANJKO

PRISTUP ANALIZI I PRIMJENI KORISNIČKOG OZNAČIVANJA U PREDMETNOM OPISU BAŠTINSKE GRAĐE

DOKTORSKI RAD

Zagreb, 2015.

Sveučilište u Zagrebu
FILOZOFSKI FAKULTET

TOMISLAV IVANJKO

PRISTUP ANALIZI I PRIMJENI KORISNIČKOG OZNAČIVANJA U PREDMETNOM OPISU BAŠTINSKE GRAĐE

DOKTORSKI RAD

Mentor:
dr. sc. Sonja Špiranec, izv. prof.

Zagreb, 2015.

University of Zagreb

FACULTY OF HUMANITIES AND SOCIAL SCIENCES

TOMISLAV IVANJKO

ANALYSIS AND IMPLEMENTATION OF FOLKSONOMIES IN SUBJECT INDEXING OF HERITAGE MATERIALS

DOCTORAL THESIS

Supervisor:
assoc. prof. Sonja Špiranec, PhD

Zagreb, 2015.

Mojim roditeljima, za njihovo odricanje i Maji, za njenu potporu.

ZAHVALE

U prvom redu zahvaljujem se svojoj mentorici, prof. dr. sc. Sonji Špiranec, na svim kritičkim primjedbama i pomoći kod vođenja ne samo ovog rada, već i niza drugih radova na kojima smo zajedno surađivali.

Zahvaljujem se i svojoj voditeljici projekta i pročelnici Odsjeka, prof. dr. sc. Jadranki Lasić-Lazić na iznimnom razumijevanju i potpori svim mojim istraživačkim idejama, kao i na stvaranju pozitivnog i poticajnog okruženja za mlade istraživače na Odsjeku.

Zahvaljujem se i prof. dr. sc. Banek Zorici koja je od prvih dana naše suradnje inzistirala na najvišim standardima znanstvenog rada te je imala strpljenja i razumijevanja za sve moje pogreške.

Zahvaljujem se i dr. sc. Goranu Zlodiju na nesebičnoj pomoći oko muzeološkog aspekta samog rada, kao i na povezivanju s muzejskom zajednicom te na velikoj pomoći njegovih suradnika bez čega ovaj rad ne bi bio moguć.

Zahvaljujem ravnateljici Hrvatskog povijesnog muzeja što je dopustila korištenje materijala u istraživanju, a posebno višoj kustosici Andreji Smetko na profesionalnom, ali iznad svega altruističnom pristupu u našoj suradnji, čime je značajno olakšala proces istraživanja i pridonijela kvaliteti disertacije.

Zahvaljujem se i dr. sc. Krešimiru Zauderu koji je svojim ekspertnim poznavanjem Pythona omogućio implementaciju programskih rješenja te je velikim teorijskim znanjem, konstruktivnim primjedbama i rješenjima značajno utjecao na kvalitetu ovog rada.

Zahvaljujem se i kolegama dr. sc. Vedranu Juričiću i dr. sc. Nikoli Ljubešiću na strpljenju i pomoći u implementaciji istraživanja, bez čijih bi tehničkih rješenja istraživanje teško bilo izvedivo.

Ovaj rad ne bi bio moguć bez suradnje ostalih kolega od kojih sam tijekom rada na Odsjeku mnogo naučio, kao i kolega iz AKM zajednice. Tu posebno moram istaknuti i zahvaliti se dr. sc. Mirni Willer koja je tijekom naše suradnje još od studentskih dana svojim velikim znanjem i širinom pogleda na polje istraživanja u velikoj mjeri pridonijela razvijanju mojih istraživačkih afiniteta.

Zahvaljujem se i Damiru Rossiniju na uloženome trudu u objašnjavanju i pomoći oko primjene statističkih metoda u radu te Petri Benčec na velikoj pomoći oko kvalitativnih analiza kao i napora u poboljšanju gramatičke ispravnosti teksta.

Na kraju se zahvaljujem i svojoj zaručnici Maji na razumijevanju i strpljenju u stresnim razdobljima istraživanja, kao i velikoj stručnoj potpori u izradi samog rada.

SAŽETAK

U ovom doktorskom radu ispitan je potencijal primjene korisničkog označivanja u predmetnom opisu baštinske građe kao metode poboljšanja pristupa i pretrage, kao i poboljšanja opisa i komplementiranja tradicionalnim sustavima za organizaciju znanja. Metodom nabave iz mnoštva i implementacijom igre sa svrhom prikupljene su ukupno 14402 korisničke oznake na 80 baštinskih predmeta, raspoređenih u 4 zbirke: arhivska, knjižnična, muzejska građa te fotografije. Statistička analiza pokazala je kako ne postoje značajne razlike u broju dodjeljivanja i broju dodanih korisničkih oznaka na razini zbirke te kako veći broj dodjeljivanja ne pokazuje korelaciju s veličinom korisničkog rječnika kojim se neka zbirka opisuje. Lingvistička analiza pokazala je kako se tipična korisnička oznaka sastoji od jedne do dvije riječi te je opća imenica u nominativu jednine, čime pokazuje obilježja klasičnih predmetnica. Značenjska analiza pokazala je kako je najveći broj oznaka dodan na generičkoj razini, tj. na razini koja ne zahtijeva specifično znanje već samo znanje prepoznavanja. U nastavku istraživanja uspoređene su predmetnice dodane od strane stručnjaka s korisničkim oznakama koje su prikupljene putem aplikacije na razini pojedinog predmeta. Prikazana je, implementirana i testirana na prikupljenom uzorku, nova metoda usporedbe implementacijom algoritamskog rješenja u programskom jeziku Python. Završni dio istraživanja u kojem su korisničke oznake nakon algoritamske obrade vraćene predmetnom stručnjaku na ocjenu korisnosti u predmetnom opisu građe, postavio je model koji omogućava relevantnim korisničkim oznakama za svaki predmet da se nalaze u setu oznaka koje stručnjak ocjenjuje kroz definiranje mjere i praga relevantnosti korisničke oznake za pojedini predmet. Model donosi novi pristup kojim se prag frekvencije uključenih korisničkih oznaka postavlja na vrijednost gornje granične vrijednosti u distribuciji korisničkih oznaka za pojedini predmet. Pokazalo se kako je predmetni stručnjak koji je ocjenjivao korisnost prikupljenih korisničkih oznaka dodanih arhivskoj, muzejskoj i fotografskoj građi (na skali od 1 do 5) vraćene oznake ocijenio prosječnom ocjenom 3.57 što pokazuje visoku primjenjivost samog modela za navedene vrste građe. Zaključni dio rada sumira glavne rezultate rada te se predlaže model analize i primjene korisničkog označivanja u predmetnom opisu baštinske građe.

KLJUČNE RIJEČI

Korisničko označivanje, baštinska građa, folksonomija, predmetna obrada, društveni softver

SUMMARY

This thesis explores possible approaches in analysis and implementation of folksonomies in subject indexing of heritage materials, in order to examine user tags as a method complementing traditional subject access in the online environment. An in-depth analysis of the research field, identifying key authors, papers and concepts was undertaken along with the presentation of main models and structure of folksonomies. The context and particularities of implementing social tagging in the description of heritage materials as well as of crowdsourcing and games with a purpose were explored, covering selected heritage projects that succeeded in successful implementation of this notions.

Research was undertaken using crowdsourcing methods, namely Game With a Purpose, a corpora of 14402 user tags on selected 80 heritage objects divided into 4 categories (library, archive, museum and photographs) was gathered for analysis. Statistical analysis of gathered corpora has shown that after a certain threshold is achieved, vocabulary base remains steady with only frequencies increasing. Linguistic analysis showed that a typical user tag consists of one word or phrase in singular, while content analysis identified most user tags as generic descriptors without added specific knowledge. User tags were compared to index terms from subject experts using the exact matching methods. A model of determining relevant user tags for a particular heritage object was defined and user tags obtained as a result were given back to the subject expert to evaluate their usefulness. Finally, a model of analysis and implementation of folksonomies in subject indexing of heritage materials was presented.

KEYWORDS:

Social tagging, folksonomies, subject access, heritage materials, crowdsourcing, GWAP, social software

STRUKTURIRANI SAŽETAK

Doktorski rad na 282 numerirane stranice sadrži tekst raspoređen u 7 dijelova: *Uvod, Predmetni pristup zabilježenom znanju, Organizacija znanja u mrežnom okruženju, Korisničko označivanje kao metoda organizacije znanja u Web 2.0 okruženju, Ključni aspekti primjene korisničkog označivanja u baštinskom okruženju, Istraživanje korisničkog označivanja u opisu baštinske građe* i *Zaključak* iza kojih slijede *Popis literature, Prilozi, Popis tablica, Popis slika, Životopis i popis javno objavljenih radova autora*.

Rad sadrži 92 slike, 29 tablica te popis citirane literature od 143 bibliografske jedinice.

U *Uvodu* se daje uvod u temeljne pojmove organizacije znanja (podatak, informacija, znanje) uz poseban naglasak na problematiku obrade i karakteristike zabilježenog znanja.

U prvom poglavlju naslovljenom *Predmetni pristup zabilježenom znanju* najprije se u sažetom obliku prikazuje povijesni razvoj predmetnog pristupa organizaciji znanja, a zatim temeljne osobine tradicionalnog pristupa predmetnoj obradi u području informacijskih znanosti. Nakon toga, izloženi su temeljni modeli tradicionalnog pristupa gdje je predmetni stručnjak u središtu procesa kao agent predmetne obrade. Poglavlje zatim donosi prednosti i nedostatke, kako prirodnog jezika, tako i kontroliranog jezika u postupku predmetne obrade te navodi temeljne probleme tradicionalnog pristupa obradi.

Drugo poglavlje naslovljeno *Organizacija znanja u mrežnom okruženju* daje pregled novih izazova s kojima je suočena predmetna obrada u mrežnom okruženju, gdje se fokus agenta koji provodi označivanje prebacuje s predmetnog stručnjaka (čiji su alati tezaurusi, klasifikacije i ontologije) na korisnika, ostvarujući ideju demokratskog pristupa informacijama. U poglavlju se zatim daje pregled temeljnih postavki i modela Web 2.0 pristupa i društvenog softvera, kao i povezanih koncepata organizacije znanja u takvom korisničko-orijentiranom okruženju. U nastavku poglavlja, donosi se pregled primjernih servisa koji uspješno implementiraju korisničke oznake kao metodu organizacije sadržaja. Za svaki prikazan servis daje se detaljan prikaz načina korištenja korisničkih oznaka u organizaciji sadržaja te osnovnih elemenata sučelja.

Treće poglavlje naslovljeno je *Korisničko označivanje kao metoda organizacije znanja u Web 2.0 okruženju.* Na početku poglavlja donosi se rasprava o terminologiji i prijevodima temeljnih engleskih termina na hrvatski jezik. U nastavku poglavlja dan je iscrpan pregled istraživanja korisničkog označivanja u znanstvenoj literaturi. Sam pregled literature poduzet je kombinacijom webometrijskih i scientometrijskih metoda gdje se identificiraju ključni autori i radovi na temelju kocitatne analize radova iz relevantnih baza podataka. Osim primjene kvantitativnih metoda, kojima se identificiraju najutjecajniji autori i radovi, poduzeta je i sadržajna analiza relevantnih

radova gdje su identificirane temeljne teme i pristupi u području istraživanja što je omogućilo jasno postavljanje istraživačkog fokusa u provedenom istraživanju.

Nakon pregleda istraživanja, donose se ostale relevantne teorijske postavke područja korisničkog označivanja, od strukture, formalnih modela i procesa korisničkog označivanja do kategorija i modela distribucije korisničkih oznaka.

Četvrto poglavlje naslovljeno *Ključni aspekti primjene korisničkog označivanja u baštinskom okruženju* bavi se smještanjem korisničkog označivanja unutar baštinskog okruženja sa svim posebnostima koje ono donosi. Donosi osnovne postavke korištenja kolektivne inteligencije, nabave iz mnoštva i igara sa svrhom kao temeljnih pristupa u baštinskom okruženju, dajući okvire u kojim se društveni softver i korisničko označivanje primjenjuju unutar baštinskog okruženja. Poglavlje donosi i izabrane primjere projekata pokrenutih u baštinskom okruženju koji koriste osnovne ideje nabave iz mnoštva i kolektivne inteligencije u opisu baštinske građe, bila ona arhivska, knjižnična ili muzejska. Fokus pregleda stavljen je na uspješne i pionirske projekte koji koriste suradničko označivanje kako bi omogućili korisnicima sudjelovanje u opisima baštinske građe.

Peto poglavlje naslovljeno je *Istraživanje korisničkog označivanja u opisu baštinske građe* i donosi opis plana, materijala, metoda, hipoteza i rezultata provedenog istraživanja. Na početku poglavlja jasno je definiran plan istraživanje te je postavljeno pet hipoteza rada. Nakon toga prikazani su materijali korišteni u istraživanju, kao i opis samog programskog rješenja korištenog za prikupljanje podataka. U nastavku rada su, tabličnim i grafičkim ilustracijama, prikazani rezultati demografske analize sudionika te statističke, lingvističke i značenjske analize prikupljenog korpusa korisničkih oznaka na hrvatskom jeziku.

Statistička analiza pokazala je kako ne postoje značajne razlike u broju dodjeljivanja i broju dodanih korisničkih oznaka na razini zbirke te kako veći broj dodjeljivanja ne pokazuje korelaciju s veličinom korisničkog rječnika kojim se neka zbirka opisuje. Lingvistička analiza pokazala je kako se tipična korisnička oznaka sastoji od jedne do dvije riječi te je opća imenica u nominativu jednine, čime pokazuje obilježja klasičnih predmetnica. Značenjska analiza pokazala je kako je najveći broj oznaka dodan na generičkoj razini, tj. na razini koja ne zahtijeva specifično znanje već samo znanje prepoznavanja.

U nastavku poglavlja pod naslovom *Ispitivanje razlika u pristupu korisničkom označivanju tradicionalnih vrsta građe u baštinskom okruženju* prikazani su rezultati usporedbe predmetnica dodanih od strane stručnjaka s korisničkim oznakama koje su prikupljene putem aplikacije na razini pojedinog predmeta. U ovom dijelu rada prikazana je, implementirana i testirana na prikupljenom uzorku nova metoda usporedbe koja se temelji na mjerama konzistentnosti

označivanja između dva predmetna stručnjaka, ali je u radu primijenjena na usporedbu setova predmetnica i korisničkih oznaka. Usporedba je provedena implementacijom algoritamskog rješenja usporedbe u programskom jeziku Python čime je omogućena automatska obrada podataka.

Završni dio poglavlja pod naslovom *Ocjena korisnosti prikupljenih korisničkih oznaka od strane predmetnog stručnjaka* prikazuje rezultate završnog dijela istraživanja, u kojem su korisničke oznake nakon algoritamske obrade vraćene predmetnom stručnjaku na ocjenu korisnosti u predmetnom opisu građe. Ovaj dio disertacije postavlja model koji omogućava relevantnim korisničkim oznakama za svaki predmet da se nalaze u setu oznaka koje stručnjak ocjenjuje kroz definiranje mjere i praga relevantnosti korisničke oznake za pojedini predmet. Model donosi novi pristup kojim se prag frekvencije uključenih korisničkih oznaka postavlja na vrijednost gornje granične vrijednosti u distribuciji korisničkih oznaka za pojedini predmet. Rješenje je algoritamski implementirano u programskom jeziku Python. Pokazalo se kako je predmetni stručnjak koji je ocjenjivao korisnost prikupljenih korisničkih oznaka dodanih arhivskoj, muzejskoj i fotografskoj građi (na skali od 1 do 5) vraćene oznake ocijenio prosječnom ocjenom 3,57 što pokazuje visoku primjenjivost samog modela za navedene vrste građe.

Posljednje poglavlje *Zaključak* donosi sumirane zaključke svakog poglavlja uz raspravu o ključnim rezultatima. Zaključni dio rada sumira i glavne rezultate rada, od definiranja dosad nepostojećeg prilagođenog modela statističke, lingvističke i značenjske analize korpusa korisničkih oznaka na hrvatskom jeziku te time omogućenog uvida u njihove statističke, lingvističke i značenjske aspekte, preko definiranja nove metode usporedbe setova predmetnica i korisničkih oznaka te definiranja mjere i praga relevantnosti korisničke oznake za pojedini izvor, pa do završnog dijela poglavlja u kojem se predlaže model analize i primjene korisničkog označivanja u predmetnom opisu baštinske građe.

Sadržaj

Uvod 1
1. Predmetni pristup zabilježenom znanju 6
1.1. Tradicionalni pristupi predmetnoj obradi 7
1.1.1. Predmetni stručnjak kao agent predmetne obrade 9
1.1.2. Problemi tradicionalnog pristupa predmetnoj obradi 16
1.1.2.1. Ostvarivanje korisničkog jamstva i semantički jaz 17
1.1.2.2. Konzistentnost između predmetnih stručnjaka 18
2. Organizacija znanja u mrežnom okruženju 20
2.1. Web 2.0 i društveni softver 22
2.2. Društvena osnova Weba 2.0 - društveni softver 25
2.2.1. Pregled servisa koji koriste suradničko označivanje i dijeljenje sadržaja 26
2.2.1.1. Servisi za suradničko označivanje i pohranu sadržaja 26
2.2.1.1.1. Delicious 28
2.2.1.1.2. Diigo 31
2.2.1.1.3. BibSonomy 34
2.2.1.2. Mrežni servisi za dijeljenje sadržaja 37
2.2.1.2.1. Flickr 38
2.2.1.2.2. YouTube 41
2.2.1.2.3. Last.fm 42
2.2.1.2.4. Twitter 46
3. Korisničko označivanje kao metoda organizacije znanja u Web 2.0 okruženju 48
3.1. Definicija korisničkog označivanja i prijevod temeljnih engleskih termina 49
3.2. Pregled istraživanja korisničkog označivanja u literaturi 51
3.2.1. Identificiranje ključnih termina 52
3.2.2. Webometrijska analiza ključnih pojmova 52
3.2.3. Identifikacija ključnih autora i radova 54
3.2.4. Kocitatna analiza radova 56
3.2.5. Sadržajna analiza radova i definiranje okvira istraživanja 60
3.3. Struktura folksonomije 64
3.4. Formalni modeli folksonomija 65
3.5. Proces korisničkog označivanja 69
3.6. Kategorije oznaka 72
3.7. Model distribucije korisničkih oznaka 74
4. Ključni aspekti primjene korisničkog označivanja u baštinskom okruženju 76

4.1. Korištenje kolektivne inteligencije ... 76
4.2. Nabava iz mnoštva ... 80
4.2.1. Igre sa svrhom kao metoda motivacije sudionika ... 84
4.3. Projekti suradničkog označivanja u baštinskom okruženju ... 86
4.3.1. Steve.museum ... 86
4.3.2. Penn Tags ... 88
4.3.3. LibraryThing ... 89
4.3.4. Library of Congress Photostream ... 93
4.3.5. Brooklyn Museum ... 94
5. Istraživanje korisničkog označivanja u opisu baštinske građe ... 96
5.1. Plan istraživanja ... 96
5.2. Hipoteze ... 97
5.3. Materijali ... 98
5.4. Prikupljanje korpusa oznaka ... 99
5.4.1. Kreiranje aplikacije za prikupljanje oznaka ... 99
5.4.2. Opis aplikacije za prikupljanje podataka ... 100
5.4.3. Demografska analiza igrača ... 105
5.5. Analiza korpusa oznaka ... 111
5.5.1. Statistička analiza ... 111
5.5.2. Lingvistička analiza ... 124
5.5.3. Značenjska analiza ... 128
5.6. Ispitivanje razlika u pristupu korisničkom označivanju tradicionalnih vrsta građe u baštinskom okruženju ... 133
5.6.1. Usporedba predmetnica dodanih od strane predmetnih stručnjaka i prikupljenih korisničkih oznaka ... 133
5.6.1.1. Definiranje metodologije usporedbe ... 136
5.6.1.2. Definiranje mjere usporedbe ... 140
5.6.1.3. Usporedba na zbirci arhivske građe ... 143
5.6.1.4. Usporedba na zbirci fotografija ... 146
5.6.1.5. Usporedba na zbirci knjižnične građe ... 148
5.6.1.6. Usporedba na zbirci muzejske građe ... 151
5.6.2. Ocjena korisnosti prikupljenih korisničkih oznaka od strane predmetnog stručnjaka ... 156
Zaključak ... 165
Popis literature ... 188
Prilozi ... 199
Prilog 1. Popis arhivske knjižnične i muzejske građe korištene u istraživanju ... 200
Prilog 2. Demografski podaci o igračima ... 233

Prilog 3. Broj dodjeljivanja i dodanih oznaka prema vrstama građe 237
Prilog 4. Predmetnice i korisničke oznake korištene u usporedbi..... 240
Prilog 5. Prosječne ocjene korisnosti korisničkih oznaka od strane predmetnih stručnjaka 263
Prilog 6. Python programsko rješenje 266
Životopis i popis javno objavljenih radova autora 280

Uvod

Jedna od temeljnih zadaća i polazišta informacijske profesije osiguravanje je učinkovitog pristupa informacijama koji se ostvaruje kroz organizaciju i predstavljanje znanja. U današnjem društvu, u kojem se svakodnevno stvara nepregledan broj novih podataka na temelju kojih se donose zaključci i temelje odluke na svim razinama funkcioniranja društva, upravljanje i organizacija novostvorenim, kao i već postojećim informacijama i znanjem, jedno je od ključnih pitanja bez kojeg bi funkcioniranje najjednostavnijih sustava postalo nezamislivo. Iako postoji niz pristupa osnovnim pojmovima, jedna od općeprihvaćenih podjela osnovnih pojmova organizacije i predstavljanja znanja temelji se na tzv. „piramidi znanja“ ili „piramidi mudrosti“ (engl. *DIKW – Data-Information-Knowledge-Wisdom*), pomoću koje možemo razjasniti i staviti u odnos osnovne pojmove područja organizacije i predstavljanja znanja (Slika 1).

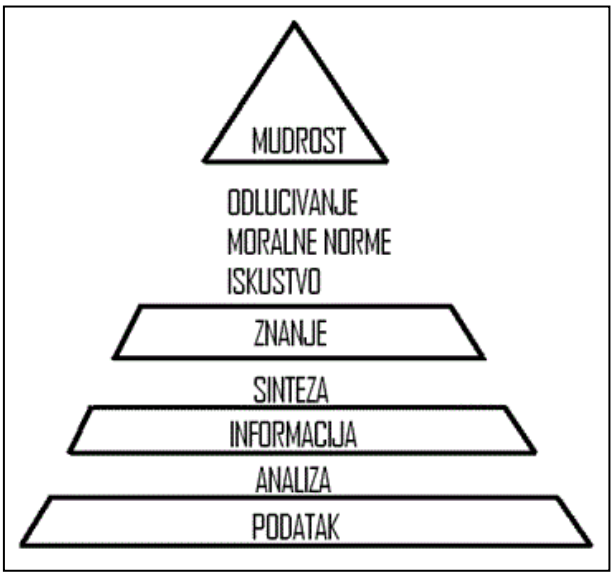

Slika 1 - Piramida podatak-informacija-znanje-mudrost
(Lasić-Lazić, 1996)

Kao što postoji niz pristupa području, postoji i niz definicija osnovnih pojmova. U nastavku donosimo dvije verzije definicija osnovnih pojmova.

Prvu donosi Ackoff (1989):

- *Podatak* je definiran kao vrijednost nekog objekta, događaja ili njihovog okruženja. On je rezultat *promatranja*, ali nije iskoristiv dok se ne pretvori u koristan (relevantan) oblik. Razlika između podatka i informacije je funkcionalna, a ne strukturalna.
- *Informacija* se nalazi u opisima, odgovoru na pitanja koja počinju riječima kao što su „tko“, „što“, „kada“ i „koliko.“ Informacijski sustavi stvaraju, pohranjuju, pretražuju i procesuiraju podatke. Informacije se izvode iz podataka.
- *Znanje* se odnosi na „znati kako“ (engl. *know-how*) te ono omogućuje transformaciju informacija u formu poučavanja. Znanje se može steći ili prijenosom od nekog drugog, tko ga posjeduje putem instrukcija, ili stjecanjem iz iskustva.
- *Mudrost* je sposobnost povećanja učinkovitosti. Mudrost dodaje vrijednost koja zahtijeva mentalnu sposobnost rasuđivanja. Impliciranje etičke i estetske vrijednosti su neodvojive od samog aktera te su jedinstvene i osobne.

Temeljeći se na prethodnim definicijama, Rowley i Hartley (2009) donose skupne definicije ključnih pojmova piramide:

- *Podatak* – diskretna, objektivna činjenica ili opažanje, koja nije organizirana niti obrađena te zbog toga nema značenja ili vrijednosti slijedom nedostatka konteksta ili interpretacije
- *Informacija* – organizirani i strukturirani podaci, koji su obrađeni na način da je informacija relevantna za specifičnu svrhu i u specifičnom kontekstu te je stoga značajna, vrijedna, korisna i relevantna
- *Znanje* – pojam koji je teško definirati, najčešće se određuje u odnosu na pojam informacije. Na primjer, postupak prijelaza znanja u mudrost se opisuje kao:
    - sinteza većeg broja informacijskih izvora tijekom vremena
    - strukturiranje uvjerenja
    - učenje i iskustvo
    - organizacija i procesuiranje u svrhu razumijevanja, akumulirano proučavanje i iskustvo
    - internalizacija u odnosu na kognitivne aspekte
    - mješavina kontekstualnih informacija, vrijednosti, iskustva i pravila

- kombinacija informacije, razumijevanja i sposobnosti
- kombinacija shvaćanja, vještina, treninga, zdravog razuma i iskustva.

Kao što je vidljivo iz navedenih pojmovnih određenja, autori najviše problema imaju u određenju pojma znanja i povezanih procesa kojim se informacije pretvaraju u znanje. Lasić-Lazić (1996) također primjećuje važnost zabilježenog znanja u području organizacije informacija: „…Znanje i informacija dva su povezana pojma koja se vrlo često koriste kao sinonimi. Određivanje što je znanje i kako se priopćuje mučilo je mnoge stručnjake, koji su onda kroz definiranje pojma pokušavali odrediti i značenje. Kao i informacija, sam pojam znanje intuitivno je razumljiv, ali nema jasnu definiciju. Postoje različite vrste znanja i različita tumačenja u različitim područjima. Za naše područje proučavanja korisno je razumijevanje zabilježenog znanja.“

Ovdje se ključnim smatra razlika između tacitnog (implicitnog) i eksplicitnog (zabilježenog) znanja. Prema Nonaki (1991), „Tacitno znanje je duboko ukorijenjeno znanje u postupcima i iskustvima drugih kao i u idejama, vrijednostima i emocijama koje ta osoba prihvaća". Tacitno znanje odnosi se na osobno znanje koje je neraskidivo od same osobe, uključujući iskustvo, uvjerenja ili osobne vrijednosti. Takvo znanje nema objektivno mjerljivu vrijednost, teško se prenosi drugoj osobi i verbalizira. Primjer ovakvog znanja, odnosno njegovog prenošenja je učenje jezika. Jezik ne možemo naučiti isključivo iz knjige o gramatici, nego je potrebno određeno iskustvo da bi ga uspješno savladali.

S druge strane, eksplicitno znanje je zabilježeno u dokumentima, lako se može pohraniti, pretraživati i koristiti te ponoviti i prenijeti drugima. Rowley i Hartley (2008), govoreći o svojoj knjizi „Organizing knowledge“, zaključuju raspravu riječima: „Izgleda kako postoji stalna rasprava o tome da li se eksplicitno znanje može opisati kao znanje ili je bolje nazvati ga informacija. Kako god razriješili tu raspravu, ova knjiga se bavi problemima organizacije eksplicitnog znanja.“

Ponovimo li početnu tvrdnju, prema kojoj je jedna od temeljnih zadaća i polazišta informacijske profesije osiguravanje učinkovitog pristupa informacijama, važno je dodati kako se to odnosi na pojam *eksplicitnog* znanja, dakle zapisanog i pohranjenog znanja. Time se fokus područja suzio na ipak jasnije polje organizacije zabilježenog znanja, što i jest sam predmet bibliotečne znanosti (Lasić-Lazić, 1996). Kako bismo mogli bolje razumjeti osnovne postupke i alate za organizaciju znanja, Rowley i Hartley (2008) donose pregled osnovnih karakteristika zabilježenog znanja u šest kategorija čiji se pregled donosi u nastavku:

- **Objektivnost**

  Iako je rasprava o objektivnosti znanja relevantna u svim znanstvenim područjima, najviše se manifestirala u društvenim znanostima iz razloga što je svako znanje produkt društva i kulturalnog okruženja unutar kojeg nastaje. Istraživači unutar područja društvenih znanosti svjesni su poteškoća povezanih uz stvaranje zajedničke stvarnosti koja bi se mogla smatrati objektivnom. S druge strane, istraživači u području prirodnih ili tehničkih znanosti ispituju fenomene u eksperimentalnom okruženju iz kojeg su uklonjene varijable okoliša te se time približavaju ideji objektivne stvarnosti. Dva su pojma povezana uz termin objektivnosti: *točnost* i *pouzdanost*. Točnost se odnosi na ispravno tumačenje podataka i informacija, dok pouzdanost implicira kako je informacija točan indikator varijable koja se želi mjeriti. Korisnici često prosuđuju pouzdanost informacije na temelju pouzdanosti izvora iz kojeg ona dolazi.

- **Pristupačnost**

  Pristupačnost se odnosi na raspoloživost znanja potencijalnim korisnicima. Ovdje postaje važna razlika između tacitnog i eksplicitnog znanja. Dok je tacitno znanje subjektivno i pripada pojedincu, većina eksplicitnog znanja pohranjena je u pisanom obliku te je dostupnija. Iako dostupnije, pristupačnost eksplicitnom znanju ovisi i o načinima njegove pohrane i organizacije, kao i komunikacije prema potencijalnim korisnicima. U tom kontekstu, osobne preferencije korisnika poput jezika, okruženja i prethodnog znanja utječu na uspjeh kojim je poruka primljena.

- **Relevantnost**

  Znanje je relevantno kada zadovoljava potrebe korisnika te doprinosi obavljanju korisničkog zadatka, bilo da se on odnosi na donošenje odluke, rješavanje problema ili učenje. Postoji više mjera relevantnosti, vezanih uz pojmove poput suvremenosti ili točnosti te se može mjeriti prema razini pertinentnosti i granularnosti informacija koje donosi. Informacija je pertinentna kada su svi materijali potrebni za uspješno izvršavanje zadataka raspoloživi, a razina specifičnosti samih materijala (granularnost) mora odgovarati zadatku i korisniku.

- **Suvremenost**

  Suvremenost i životni vijek znanja važni su iz dva razloga. Prvo, nove informacije mogu zamijeniti stare te je uvijek potrebna najnovija informacija, a drugo, zastarjele informacije treba izbaciti iz sustava. Svaka informacija ima svoj životni vijek, neke su relativno stabilne i ne zastarijevaju (npr. kako funkcionira ljudsko srce), dok neke gube relevantnost u roku od nekoliko sati (npr. vremenska prognoza) te ih je potrebno stalno osuvremenjivati, ali još uvijek imaju vrijednost kao povijesni podatak koji omogućuje detekciju trendova. Izazov je odrediti točan životni vijek svake informacije i upravljati njome prema toj karakteristici. U tom smislu, korisniku treba uvijek dati najsuvremeniju moguću informaciju, a iz sustava stalno treba izlučivati redundantne ili zastarjele informacije.

- **Struktura i organizacija**

  Svako znanje ima svoju strukturu koja je važna za njegovo razumijevanje. S jedne strane govorimo o kognitivnoj strukturi, tj. na koji način mozak procesuira nove informacije i povezuje nove i već poznate koncepte u smislenu cjelinu, dok s druge strane moramo uzeti u obzir i načine na koje pojedinci strukturiraju informacije u formi oralnog izričaja, pisanog teksta ili slikovnih prikaza. Dva su važna aspekta strukture: način na koji se elementi grupiraju u kategorije te definiranje odnosa između tih kategorija.

- **Sustavi**

  Sama struktura često je definirana samim sustavima za organizaciju znanja, bili oni samo konceptualni okviri, komunikacijski ili informacijski sustavi. Znanje je uvijek komunicirano kroz informacijske sustave te se u njima i pohranjuje. Takvi sustavi moraju biti dizajnirani na način da ostvare učinkovitu pretragu i pronalaženje informacija.

Svaku od navedenih karakteristika znanja potrebno je imati na umu kada se govori o bilo kakvoj organizaciji znanja, jer su te osobine ugrađene u samu prirodu informacija i znanja.

1. Predmetni pristup zabilježenom znanju

Već od izuma pisma i stvaranja prvih zapisa – bili oni na glinenim pločicama, papirusu ili bilo kojem drugom mediju – pojavila se potreba za njihovom sistematičnom i logičnom organizacijom. U okruženju baštinskih ustanova (arhiva, knjižnica, muzeja), osiguravanje točnog i iscrpnog opisa predmeta, radi lakše pohrane i pronalaženja, jedan je od osnovnih zadaća struke. Osnovna metoda opisa predmeta ostvaruje se kroz pohranjivanje metapodataka o samom predmetu, kao „navigacijskog“ sloja (Peters, 2009) koji služi korisnicima kao podloga za pronalaženje željenih informacija.

Skup pravila opisa i pohranjivanja surogata možemo objediniti pod skupnim nazivom „bibliografska kontrola“, čije su glavne zadaće (Foskett, 1996):

- identificirati postojanje svih mogućih dokumenata koji postoje na svim mogućim medijima
- identificirati radove sadržane u drugim dokumentima kao njihove dijelove (npr. članci u časopisu, radovi s konferencija, pojedinačna djela u antologijama, itd.)
- producirati popis dokumenata i djela prema standardnim pravilima citiranja
- osigurati korisne pristupne točke (indekse) tim popisima, uključujući minimalno pristup prema imenu, naslovu i predmetu
- pružiti mogućnost pronalaženja opisanog dokumenta unutar zbirke.

Kao jedna od prvih metoda ostvarivanja bibliografske kontrole pojavio se katalog – jednostavan popis građe prikupljene na nekom mjestu. U svojoj osnovi, katalog je jednostavna baza metapodataka o stvarnim predmetima te je služio korisnicima da preko njega, kao navigacijskog sloja, dolaze do podatka o tome gdje se željeni dokument ili predmet nalazi. Prvi stvarni katalozi bili su stručni, donoseći popise knjižnične građe raspoređene u osnovne skupine prema podjeli znanosti, djelatnosti i umjetnosti, i njima podređene skupine i podskupine. U takvom načinu organizacije, na prvom mjestu je logika organizacije koja omogućuje odgovore na korisnička pitanja o građi iz određenoga stručnog područja. Iako je stručni katalog, utemeljen na logici klasificiranja, dugo imao primat u području organizacije te se do polovice 19. stoljeća smatrao glavnim katalogom, tijekom vremena pojavio se i drugi, mnogo mlađi oblik stvarnog kataloga – predmetni katalog (Mikačić, 1990). Predmetni katalog pokušao je riješiti problem s kojim se susreću korisnici koji traže informacije o određenoj temi koja ih zanima, bez prethodnog znanja o autorima ili dokumentima u kojima se ta

informacija nalazi, što je teško saznati u stručnom katalogu koji, kao glavne pristupne točke, koristi imena autora i naslove. Prema Mikačić (1990), pojavom predmetnog kataloga, u osnovnoj ideji organizacije, logiku je zamijenila lingvistika: „…Uvidjevši kako su stvarni katalozi zapravo poluumjetni jezici za označivanje sadržaja…pojavili su se izrazi na engleskom jeziku *indexing language* (jezik za označivanje) i *retrieval language* (jezik za pronalaženje), što je bio znak da je lingvistika preuzela vodeće mjesto primijenjene znanosti u bibliotekarstvu umjesto logike."

Zadaću predmetnog pristupa kao dio zadaće knjižničnog kataloga navodi još 1876. godine C. Cutter u svojim „Pravilima za ukršteni katalog" (Cutter 1948, prema Golub, 2003) u sljedeće dvije zadaće:

1. omogućiti pronalaženje knjige za koju korisnik poznaje autora, naslov ili predmet (engl. *subject*)
2. pokazati što knjižnica od određenog autora, o određenom predmetu i određenoj vrsti literature posjeduje.

Iako su od te davne 1876. Cutterova pravila tijekom vremena ponešto prilagođena, posebno primjenom Pariških načela (IFLA, 1963) i IFLA-ine studije Funkcionalni zadaci bibliografskih zapisa (engl. *Functional Requirements for Bibliographic Records – FRBR)* (IFLA, 1998), ideja kako predmetna obrada ima centralnu ulogu u opisivanju sadržaja neke zbirke ostala je još uvijek misao vodilja predmetnog pristupa. Hill i Schottlaender (2008) govore o važnosti predmetne obrade: „Predmetna obrada – uključujući analizu sadržaja, stvaranje i dodavanje predmetnih odrednica te klasifikacijskih oznaka – osnovna je funkcija katalogizacije; iako skupa, ipak je neophodna."

Pojavom i razvojem predmetnih kataloga, počela se razvijati teorija i praksa predmetne obrade razvojem teorijskih modela i praktičnih alata za ostvarivanje cilja osiguravanja pristupa građi preko predmeta kao pristupne točke.

1.1. Tradicionalni pristupi predmetnoj obradi

Proces predmetne obrade i organizacije informacija, kao jedan od temeljnih problema u području informacijskih znanosti, snažno je utemeljen u nizu teorijskih djela (Taylor i Joudrey 2009; Rowley i Hartley, 2008; Foskett, 1996; Lancaster, 2003) koja navode metode, pristupe i probleme predmetnom pristupu informacijama. Pregled koji se donosi ni u jednom smislu nije iscrpan, već je više vezan uz isticanje temeljne problematike područja.

Taylor i Joudrey (2009) definiraju organizaciju informacija kao „proces opisa informacijskih izvora te pružanja imena, naziva i predmetnog pristupa tim opisima, rezultirajući podacima koji služe kao surogat stvarnim zabilježenim informacijama, na logično organiziran način.“ To je ukratko i opis samog procesa katalogizacije, koja uključuje formalnu i predmetnu obradu, kao temeljnih postupaka kojima se ostvaruje bibliografska kontrola. Dok formalna obrada pruža pristup informacijama preko formalnih karakteristika dokumenta (naslov, autor, …), proces predmetne obrade sadržaja omogućuje predmetni pristup samom dokumentu.

Kako bismo bolje sagledali i sve aspekte koji mogu sudjelovati u samom procesu indeksiranja, možemo koristiti prikaz temeljnih metoda predmetnog pristupa informacijama temeljen na tri osnovna aspekta (Peters i Stock, 2007) (Slika 2):

(1) osoba koja provodi označivanje
(2) informacijski izvor nad kojim se provodi označivanje
(3) metoda koja se koristi u procesu.

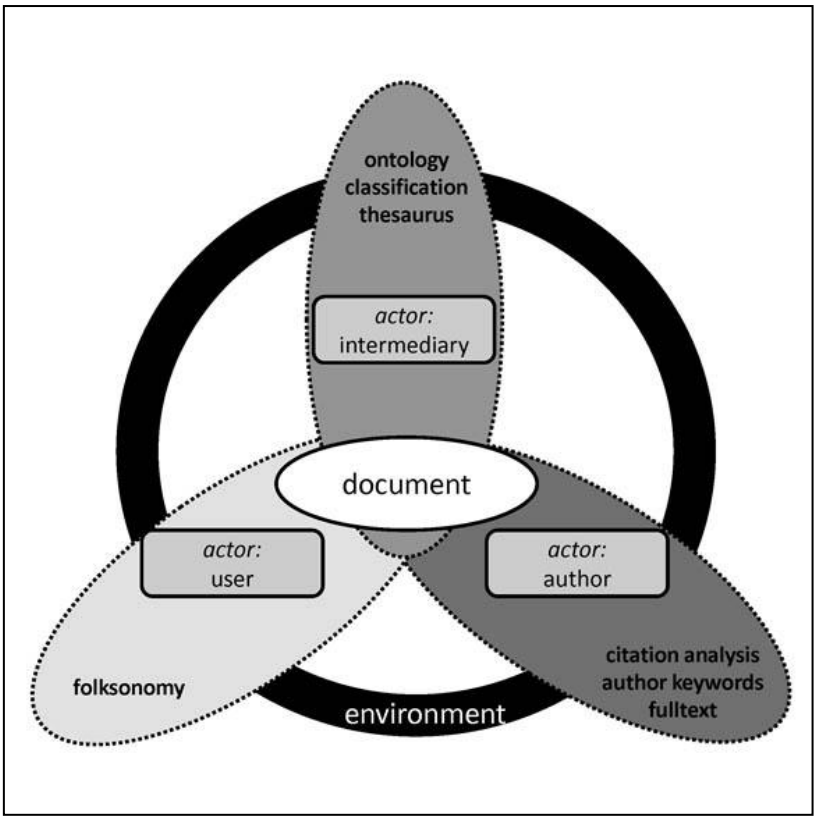

Slika 2 - Osnovni pristupi indeksiranju
(Peters i Stock, 2007)

Kada govorimo o agentu koji provodi označivanje nekog dokumenta ili informacijskog izvora, možemo razlikovati tri osnovne grupacije koje svojim aktivnostima usmjeravaju i definiraju krajnji cilj i svrhu same organizacije:

(1) autori samih dokumenata
(2) predmetni stručnjaci
(3) korisnici informacijskih izvora.

Svaki od tih pristupa daje drugačiji aspekt samom procesu organizacije. Kada sami autori opisuju vlastite radove ključnim riječima, čine to iz pozicije stručnjaka koji dobro poznaje svoje područje i terminologiju te ima iscrpna znanja iz svoje domene, ali mu često nedostaju znanja o samim predmetnim sustavima u kojima će se dodane ključne riječi i koristiti. Pojmovi dodani od strane autora najčešće se koriste u znanstvenim bazama podataka i odražavaju terminologiju koju koriste sami autori u svojim radovima te su korisni u procesu pronalaženja specifičnih termina od strane drugih autora koji se bave srodnim ili istim područjem istraživanja. Kako su autori ujedno i stručnjaci i korisnici radova drugih stručnjaka, možemo reći kako se pojmovi koje dodaju autori nalaze između dvije suprotne ideje - korisničkog označivanja i označivanja od strane predmetnih stručnjaka.

1.1.1. Predmetni stručnjak kao agent predmetne obrade

Tradicionalni pristup predmetnom opisu podrazumijeva postojanje predmetnog stručnjaka koji svojom ekspertizom jamči za finalni rezultat produciranja kontekstualnih metapodataka koji najbolje predstavljaju koncepte u označenom dokumentu. U nastavku donosimo temeljne modele tradicionalne predmetne obrade koji u središte postupka stavljaju predmetnog stručnjaka.

Osnovni teorijski model predmetne obrade donosi Lancaster (2003) razdvajajući ga na dva osnovna koraka:

(1) konceptualna analiza
(2) prijevod.

Iako se u praksi ta dva koraka često isprepleću te se analiza i prijevod u jezik za označivanje odvijaju istodobno ili asinkrono, u intelektualnom smislu oni predstavljaju dva odvojena koraka. Prvi korak, koji uključuje analizu, vezan je uz pojam „očemnosti“ (engl. *aboutness*) objekta koji se opisuje, u kojem je zadaća predmetnog stručnjaka odrediti o čemu govori neki

informacijski objekt te stvoriti uvjete za prelazak na drugi korak - prijevod termina u neki od sustava kontroliranog rječnika kao što su tezaurusi ili klasifikacije.

Prvi korak (konceptualna analiza) predmetnog pristupa ostvaren je kroz analizu koncepata prisutnih u samom informacijskom objektu koji se analizira, određivanju o čemu on govori te izražavanju očemnosti koristeći ključne riječi i termine (Svenonius, 2005; Taylor i Joudrey, 2009; Lancaster, 2003).

Osim temeljnog pristupa u dva koraka, proces predmetne obrade u literaturi (Chu, 2010; Foskett, 1996; Shatford, 1986) često se razdvaja i na tri osnovna postupka:

(1) određivanje od čega se objekt sastoji (engl. *ofness)*
(2) određivanje o čemu govori poruka sadržana u samom objektu (engl. *aboutness*)
(3) pridruživanje ključnih riječi i termina informacijskom objektu, predstavljajući od čega se sastoji (engl. *ofness)* i o čemu taj objekt govori (engl. *aboutness*) na niz različitih načina, pokušavajući ga povezati s predviđenom informacijskom potrebom korisnika.

U tom procesu predmetni stručnjaci trebaju pokušati biti objektivni i neutralni i ne nametati značenje nekog dokumenta korisniku kroz odabir predmetnica koje nisu vezane uz očemnost, tj. ne nuditi svoju interpretaciju. Iako to pravilo objektivnosti može izgledati jednostavno i samo po sebi razumljivo, Fairthorne (1969, prema Rowley i Hartley, 2008) donosi primjer u kojem se ogleda problematika: „Moby Dick je priča o kitu, Othello je o rupčiću i nizu drugih stvari. Poteškoća se nalazi u identifikaciji koja se od spomenutih stvari odnosi na relevantnu temu te kako se odnositi prema temama koje nisu eksplicitno spomenute u dokumentu…Dijelovi nekog dokumenta često nisu o onome o čemu govori cijeli dokument, niti je cijeli dokument obično suma svih stvari o kojima govori.“ Kako Rowley i Hartley (2008) zaključuju: „Drugim riječima, iako je prethodni odlomak spomenuo i kita i rupčić nitko ne bi rekao da je *o tome*. Posao je predmetnog stručnjaka osigurati pravilnu reprezentaciju generalne teme dokumenta kao i njegovih glavnih podtema.“ Ovdje se ogleda i ključni problem u predmetnoj obradi (zbog kojeg i automatsko označivanje često nije uspješno) - u kojoj mjeri riječi u nekom dokumentu zaista predstavljaju ono o čemu je dokument.

Uspješnost pronalaženja nekog informacijskog objekta zavisi o tome koliko je dobro informacijski stručnjak uspio opisati od čega se objekt sastoji (engl. *ofness)* i o čemu taj objekt govori (engl. *aboutness*) (Chan, 1989). Ovdje se javlja problem s prijevodom engleskih termina, jer dok za pojam *aboutness* možda i možemo ponuditi prikladni prijevod (očemnost - o čemu neki objekt govori), pojam *ofness* možemo prevesti samo opisno kao „ono od čega se

nešto sastoji.“ Kako bi se lakše razlikovala oba pojma u radu, pojam *ofness* koristimo u njegovom engleskom obliku.

Osnovno shvaćanje pojmova donose radovi Shatford (Shatford, 1984; Shatford 1994) koja je u njima razradila ideje povjesničara umjetnosti Erwina Panofskog, kako bi opisala proces analize slikovnih i tekstualnih materijala. Panofsky je u svojim radovima razradio sustav interpretacije slikovnog materijala na tri razine značenja - preikonografskoj, ikonografskoj i ikonološkoj. Iako je svoju teoriju ikonološke analize Panofsky razvio primarno na djelima renesansne umjetnosti Italije i sjeverne Europe (Baca, 2002; Panofsky, 1955) i namijenio je analizi umjetničkih djela, razdvajanje objekata na ono *od čega* se sastoji i *o čemu* govori na preikonološkoj i ikonografskoj razini opisa može se primijeniti u području predmetne obrade, kako slikovnih, tako i tekstualnih izvora. Kako navodi Shatford (1984): „…riječi i slike su surogati objekata…riječi su surogati po dogovoru, dok su slike surogati po projekciji.“

Prva razina značenja koju Panofsky naziva preikonografska odnosi se na „primarne ili prirodne osobine predmeta“ (Panofsky, 1955). Interpretacija na preikonografskoj razini identificira činjenične elemente od kojih je stvoren neki objekt. Analiza na preikonografskoj razini može biti ekspresivna ili činjenična. Npr. netko može prepoznati kako neka slika prikazuje bijelu kuću s crvenim krovom (činjenični pristup predmetu), dok druga osoba na toj slici možda vidi svoju vlastitu kuću u kojoj je odrasla te uz nju veže osjećaje ugode ili melankolije (ekspresivni pristup predmetu). Iako bi mogli argumentirati kako je ekspresivni pristup subjektivan, ipak za njega nije potrebno više od „…iskustva i znanja iz svakodnevnog života“ (Panofsky, 1955) što se uklapa u preikonografsku razinu.

Druga razina značenja koju Panofsky naziva ikonografska odnosi se na „…slike, priče i alegorije umjesto motiva…[ona] pretpostavlja poznavanje specifičnih tema i koncepata prenošenih kroz literarne izvore, usvojenih bilo svrhovitim čitanjem ili usmenom tradicijom“ (Panofsky, 1955). Zbog toga, na ovoj razini interpretacije, informacijski stručnjak mora imati „…uvid u načine na koje su, pod različitim povijesnim uvjetima, specifične teme ili koncepti izraženi predmetima ili događajima“ (Panofsky, 1955). Na ovoj razini, stručnjak koji interpretira predmet mora objasniti što on predstavlja. Shatford daje primjer: „…alegorijska slika može prikazivati čovjeka i lava, ali zapravo predstavljati ponos…kao što slika osobe koja plače može predstavljati tugu“ (Shatford, 1994).

Kada govori o pojmovima *ofness* i *aboutness*, Shatford navodi kako su oni vezani uz prve dvije razine, preikonografsku i ikonografsku razinu, dok se treća, ikonološka razina, ne može primijeniti u kontekstu predmetnog pristupa zbog subjektivnosti same interpretacije koju ona uključuje, pa se stoga „ova razina značenja ne može konzistentno indeksirati“ (Shatford,

1986). Koristeći se podjelom koju donosi Panofsky, na preikonografski i ikonografski opis, Shatford daje definicije osnovnih pojmova (Shatford, 1986):

- *Ofness*: odnosi se na konkretne i objektivne činjenice o nekom predmetu (činjenično znanje)
- *Aboutness*: odnosi se na apstraktno i subjektivno znanje o nekom predmetu (ekspresivno značenje).

U kontekstu primjene takve analize na tekstualne dokumente, Shatford (1986) smatra kako se preikonografska razina može koristiti kako bi se opisalo od čega se sastoji neki predmet, kao i o čemu govori. Chu (2010) govori kako *ofness* nekog objekta „…uključuje atribute kao što su autor, jezik, godina izdanja, dok se *aboutness* bavi predmetnim sadržajem sadržanih informacija.“ Analiziramo li pojmove u kontekstu opisa nekog dokumenta, možemo vidjeti kako *ofness* dijelom odgovara onome što obično nazivamo formalna obrada, dok se *aboutness* odnosi na predmetnu obradu u postupku opisa nekog dokumenta. S te strane, formalni opis ne zahtijeva posebnu interpretaciju i lakše ga je provesti. Chu (2010) primjećuje kako „… izražavanje informacija koje se temelje na podacima koje donosi *ofness* jednostavnije je i manje zahtjevno od izražavanja *aboutness* dijela nekog objekta.“

Problem s kojim se susreće formalna obrada ne leži u interpretaciji samih podataka (jer je relativno lako identificirati formalne karakteristike dokumenta koji se opisuje), već u raznim *varijacijama* u kojima ti podaci dolaze. Proces formalne obrade zahtijeva dobro poznavanje pravila bilježenja obaveznih podataka, ali isto tako uključuje velik broj iznimaka koje je potrebno pravilno smjestiti unutar zadanih okvira opisa. S takvim se razmišljanjima slaže i Shatford (1986) pišući „…činjenično značenje relativno je jednostavno za opis i označivanje, jer je veća vjerojatnost kako će se više ljudi složiti oko opisa nekog objekta ili događaja.“

Baca (2002) definira *aboutness* kao „…izraz koji se koristi u kontekstu predmetne obrade odnoseći se na tematsko ili simboličko značenje samog djela“, dok ga Lancaster (2003) identificira temeljnim pojmom predmetne obrade, definirajući ga kao „…teme zastupljene ili predstavljene u nekom dokumentu.“

Vratimo li se na definiciju organizacije informacija kao „..procesa opisa informacijskih izvora te pružanja imena, naziva i predmetnog pristupa tim opisima, rezultirajući podacima koji služe kao surogat stvarnim zabilježenim informacijama, na logično organiziran način“ (Taylor i Joudrey, 2009), možemo je sada sagledati u kontekstu pojmova *ofness* i *aboutness*. Kada informacijski stručnjak dodaje ime i naziv nekom objektu, on zapravo opisuje već postojeću vezu između samog objekta i riječi kojima ih opisuje. To možemo nazvati *ofness*. Kada informacijski stručnjak dodaje predmetnu odrednicu nekom objektu, on ne opisuje već

postojeću vezu, već procesom predmetne analize nastoji *stvoriti* tu vezu između objekta koji se opisuje i značenja riječi kojima se on opisuje. Ovdje ulogu ne igra samo činjenično stanje već i iskustvo same osobe s takvim ili sličnim objektima (Panofsky, 1955). Upravo zbog toga, predmetna obrada je neraskidivo vezana uz stručnost same osobe u području koje opisuje, jer bez prethodnog poznavanja materije i odnosa između pojmova unutar polja (poznavanja terminologije), teško je očekivati stvaranje smislene veze koja će omogućiti predmetni pristup. Kada je informacijski stručnjak uključen u takav proces, u kojem mu je zadaća analizom doći do odgovarajućih pojmovnih izraza koji najbolje opisuju o čemu neki dokument govori, tada on pruža *aboutness* nekog objekta (Panofsky, 1955; Shatford, 1984).

Ovakav pristup, koji naglašava pitanje očemnosti dokumenta, pretpostavlja kako je osoba koja provodi označivanje predmetni stručnjak, čija je zadaća prevesti koncepte, prisutne u nekom dokumentu, u kontrolirane termine.

Od prvotne analize u dva koraka (Lancaster, 2003) preko razdvajanja na tri koraka (Foskett, 1996; Shatford, 1986; Peters, 2009), David et al. (1995) daju još detaljniji prikaz procesa indeksiranja, gdje u sredinu procesa stavljaju baš predmetnog stručnjaka, detaljno razdvajajući proces na niz koraka koji uključuju postupke i znanja potrebna na svakoj razini predmetne obrade, razdvajajući sam proces na pet koraka (Slika 3).

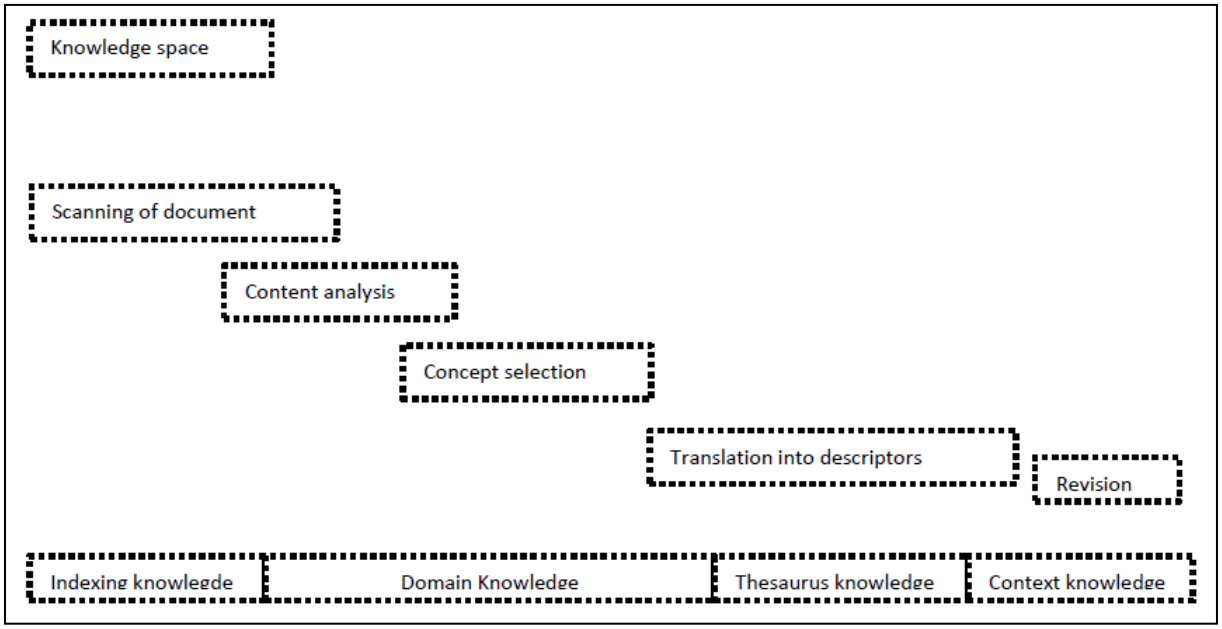

Slika 3 - Proces predmetne obrade
(David et al., 1995)

Predstavljeni model oslanja se na predmetnog stručnjaka, koji svojom ekspertizom jamči za finalni rezultat produciranja kontekstualnih metapodataka koji najbolje predstavljaju koncepte u označenom dokumentu. Naravno, sam proces je u praksi puno više iterativan, uključujući vraćanje na prethodne korake i kombinaciju više vrsta znanja u različitim koracima.

Nakon što je predmetni stručnjak odredio očemnost dokumenta, slijedi drugi korak, u kojem se odabire sama terminologija, tj. jezik za označivanje. Ovdje postoje dva osnovna puta - koristiti kontrolirani rječnik ili koristiti prirodni jezik. Radi preglednosti, Tablica 1 donosi prednosti i nedostatke svakog od pristupa.

Tablica 1 - Prednosti i nedostaci prirodnog i kontroliranog jezika u sustavima za označivanje (Rowley i Hartley, 2008)

	PREDNOSTI	**NEDOSTACI**

KONTROLIRANI JEZIK	• Olakšava snalaženje kroz:
	  ○ Kontrolu sinonima i homonima
	  ○ Upotrebu bilješki o pojmovima
	  ○ Prikaz širih, užih i povezanih pojmova
	• Izražavanje očemnosti kroz termine koji nisu nužno prisutni u dokumentu
	• Rješava sintaktičke probleme složenica
	• Povećava preciznost kroz mapiranje termina
		• Skupi za održavanje
		• Mogući nedostatak korisničkog jamstva
		• Moguće ljudske greške pri odabiru odgovarajućih termina
		• Moguća zastarjelost rječnika
		• Poteškoće u sustavnom izražavanju svih relevantnih veza između termina
		• Manjak specifičnosti i preciznosti
		• Manjak iscrpnosti
		• Korisnik mora biti upoznat s jezikom za označivanje

PRIRODNI JEZIK	• Jeftin za održavanje • Omogućuje pretragu cijelog sadržaja zbirke • Nema ljudske greške u odabiru termina • Uvijek odražava suvremeni rječnik • Visoka specifičnost pojmova daje veću preciznost osobito kod pretrage pojedinačnih pojmova (imena, nazivi,…) • Iscrpnost omogućuje veliki odziv .	• Veći naglasak na ulozi korisnika, osobito kod pojmova koji imaju sinonime ili srodne pojmove • Nemogućnost izražavanja implicitnih tema koje nisu prisutne kao pojam u samom dokumentu • Odsutnost hijerarhijskih veza između termina (opće-specifično) • Mora se poznavati rječnik struke • Sintaktički problemi kod složenih pojmova • Iscrpnost može voditi do manjka preciznosti

Kod kontroliranog rječnika, stručnjak kontrolira pojmove koje će koristiti u označivanju dokumenta te izabire pojmove iz različitih normativnih datoteka, obično za nazive, imena ili jednostavne uređene popise termina poput tezaurusa. Kod korištenja prirodnog jezika kao podloge za označivanje, ne postoji popis termina za označivanje, već se oni deriviraju iz samog dokumenta koji se označuje, analizom naslova, sažetka ili punog teksta samog dokumenta. Jedan od glavnih problema kontroliranog jezika jest njegova skupoća u stvaranju i održavanju baze pojmova. Izrada klasifikacijskih shema i tezaurusa, kao dva osnovna alata u predmetnom pristupu, vrlo je skup postupak koji zahtijeva mnogo vremena i resursa. S druge strane, prirodni jezik često ne može pružiti dovoljnu razinu specifičnosti koja je potrebna kod opisa specijaliziranih dokumenata. Upravo iz tih razloga, velike bibliografske baze podataka pokušavaju u svojim korisničkim sučeljima ujediniti kontrolirani i prirodni jezik, koristeći prekoordinirane popise termina kao osnovu za označivanje dokumenata, ali i omogućavajući pretragu punog teksta radi pronalaženja specifičnih termina koji su prisutni u dokumentu (Rowley i Hartley, 2008).

Predmetni rječnik koji se izabere, mora odrediti aspekt predmetne obrade u odnosu na dva osnovna elementa: iscrpnost i specifičnost. Pojam iscrpnosti odnosi se na broj koncepata koji će se uzeti u obzir u konceptualnom okviru nekog sustava (Taylor, 2003). Dokumenti koji se označuju, rijetko govore samo o jednom predmetu te je često potrebno dodati više deskriptora kako bi se izrazili osnovni koncepti prisutni u dokumentu. Iscrpnost može biti velika, dodavanjem velikog broja deskriptora, čime se povećava odziv u sustavu, ali smanjuje preciznost, ili može biti vrlo selektivna dodavanjem strogo kontroliranog broja deskriptora, čime se smanjuje odziv, ali povećava preciznost. Specifičnost se odnosi na „dubinu“ indeksiranja, tj. na to koliko će specifični biti deskriptori koje stručnjak izabire. Kao i iscrpnost, i specifičnost je vezana uz pojmove odziva i preciznosti. Dodjeljivanje specifičnih termina može povećati preciznost, ali će također smanjiti odziv, dok će općeniti termini povećati odziv, ali smanjiti preciznost, dajući korisniku rezultate pretrage koji nisu relevantni za njegov upit (Svenonius, 2005). Određivanje razine iscrpnosti i specifičnosti koju će primjenjivati predmetni stručnjaci, uglavnom se definira na razini ustanove kako bi bila ujednačena i prilagođena zbirci i korisnicima.

1.1.2. Problemi tradicionalnog pristupa predmetnoj obradi

Iako je tradicionalni pristup predmetnoj obradi pokušao standardizacijom i razvojem različitih modela razviti pristup koji će na najbolji mogući način omogućiti predmetni pristup informacijama, on nije bez svojih nedostataka. Različiti autori (Bates 1998; Lancaster, 2003;

Taylor, 2004; Peters, 2009) navode niz problema od kojih ćemo se ovdje usmjeriti na dva osnovna, važna za ovu disertaciju: ostvarivanje korisničkog jamstva te konzistentnost između predmetnih stručnjaka.

1.1.2.1. Ostvarivanje korisničkog jamstva i semantički jaz

Prvi problem s kojim se susreću predmetni stručnjaci u procesu predmetne obrade, vezan je uz drugi korak predmetne obrade: prevođenje koncepata u termine za označivanje. Golub (2003) navodi tri čimbenika specifičnosti u prevođenju na termine sustava za označivanje koji utječu na preciznost i odziv u pretraživanju: specifičnost i prikladnost rječnika (koliko su hijerarhijske razine samog rječnika specifične), specifičnost primjene (pravilo je da se upotrijebi najuži postojeći termin) i specifičnost termina u kontekstu danog kataloga (visoka specifičnost znači da je termin u katalogu relativno rijedak; ova specifičnost treba biti čimbenik u odabiru vrste kontroliranog rječnika prema katalogu). Bates (1998) kao prvi veliki izazov za svakog predmetnog stručnjaka navodi problem: „…previđanje kojim bi terminima ljudi s različitim informacijskim potrebama…mogli tražiti informaciju u onim slučajevima kada bi neki zapis zaista mogao zadovoljiti njihovu informacijsku potrebu.“ Ovo ukratko sumira problem - kako osigurati da termini sustava za označivanje odražavaju termine koje će korisnici koristiti u pretrazi, ali da opet budu dio kontroliranog sustava.

Svenonius (2005) navodi tri osnovna kriterija za izbor termina koji ulaze u kontrolirani rječnik: kriteriji književnog jamstva (engl. *literary warrant*), korisničkog jamstva (engl. *user warrant*) i strukturalnog jamstva (engl. *structural warrant*). Književno ili literarno jamstvo zahtijeva uvrštavanje termina koji se nalaze u građi koju je potrebno opisati, korisničko jamstvo odnosi se na potrebu da se uvrste oni termini ili nazivi koje koriste korisnici kod pretrage samog sadržaja, dok strukturalno jamstvo postoji zbog potrebe za uključivanjem onih termina koji nisu odabrani ni prema prvom, niti prema drugom jamstvu, ali su neophodne zbog strukturalne funkcije u rječniku, npr. zbog nadopunjavanja praznina u hijerarhiji ili okupljanja užih termina (Golub, 2003). Dok se književno i strukturalno jamstvo mogu ostvariti poštujući načela jezika predloška te grupiranjem, razdvajanjem ili stavljanjem u odnose samih termina, korisničko jamstvo se u praksi često teško ostvaruje zbog poteškoća u sustavnom utvrđivanju korisničkog rječnika. Čak i kada sam kontrolirani popis termina uključuje korisnički rječnik, problem zastarijevanja koncepata ili promjene značenja još je uvijek prisutan.

U modelima predmetne obrade koje smo naveli u prijašnjim poglavljima, a posebno u najdetaljnijoj razradi autora David et al. (1995) (Slika 3), kao jedan od ključnih alata za prijevod koncepta u termine sustava navodi se neki oblik kontroliranog popisa termina poput tezaurusa, koji stručnjaci koriste kako bi ujednačili terminologiju unutar sustava. Međutim, ništa ne garantira da će korisnici u svojim pretragama koristiti termine prisutne u samom kontroliranom popisu, stvarajući tako semantički jaz između pojmovlja koje koriste korisnici i termina koji opisuju sam sadržaj. Pojam „semantički jaz“ (engl. *semantic gap*) originalno je nastao kako bi opisao probleme opisivanja slikovnih materijala, ali se danas koristi u općenitom značenju kao: „…neslaganje između termina koji se nalaze u dokumentu i onog koji je korišten u pretrazi“ (Thøgersen, 2012).

1.1.2.2. Konzistentnost između predmetnih stručnjaka

Iako većina dokumenata ima glavni predmet koji će osobe koje vrše označivanje uglavnom isto odrediti, označivanje sporednih predmeta može znatno varirati. Thøgersen (2012) navodi dva zakona predmetne obrade koja je predložio J. Shera:

(1) nijedan predmetni stručnjak neće se složiti s rješenjem drugog predmetnog stručnjaka

(2) nijedan predmetni stručnjak neće prihvatiti vlastito rješenje šest mjeseci nakon prvotne predmetne obrade.

Ta dva zakona ukazuju na osnovni problem opisa bilo kojeg predmeta: nedostatak konzistentnosti. Konzistentnost se odnosi na potrebu da se isti predmeti označe istim terminima, kako bi u katalogu bili okupljeni slični predmeti, što se u praksi pokazalo teško izvedivim. Konzistentnost je obrnuto proporcionalna s iscrpnošću i specifičnošću jer visoka razina iscrpnosti ili visoka razina specifičnosti dovode do niske razine konzistentnosti (Svenonius, 2005; Olson i Boll 2001).

Modeli predmetne obrade koje smo naveli, podrazumijevaju kako bi dva odvojena predmetna stručnjaka trebala, slijedeći korake obrade, dodati iste ili barem slične deskriptore istom objektu koji se opisuje.

U literaturi se, kada to nije slučaj, problem često nalazi pod pojmovima *inter* i *intra-indexing* konzistentnost (engl. *inter-indexing consistency, intra-indexing consistency*). *Inter-indexing* konzistentnost odnosi se na prvi Sherain zakon, tj. činjenicu kako se dva predmetna stručnjaka često neće složiti oko opisa predmeta, dok se *intra-indexing* konzistentnost odnosi na drugi predloženi zakon: isti predmetni stručnjak koristit će različite deskriptore tijekom vremena kako bi označio isti sadržaj (Markey, 1984; Leonard, 1977).

Leonard (1977) definira *inter-indexing* konzistentnost kao: „kvantitativnu mjeru stupnja u kojem dva ili više predmetna stručnjaka percipiraju važne informacijske koncepte sadržane u dokumentu i izražavaju ih koristeći iste oznake ili termine.“ Osnovna mjera koja može pokazati nekonzistentnost između dva predmetna stručnjaka sastoji se u mjerenju razlika u deskriptorima koje dodaju istom dokumentu.

Lancaster (2003) navodi dva osnovna razloga zbog kojih se to može dogoditi nazivajući ih „neuspjehom konceptualne analize“ (engl. *conceptual analysis failure*) te „neuspjehom prijevoda“ (engl. *translation failure*). Neuspjeh konceptualne analize događa se kada „…predmetni stručnjak ne uspije prepoznati važnost konteksta pojedinog elementa sadržaja“, dok se neuspjeh prijevoda događa u trenutku kada „…predmetni stručnjak koristi neprikladni termin kako bi predstavio neki koncept, ili zbog nemarnosti ili nedostatka temeljnog znanja o području“ (Lancaster, 2003).

Bilo koji od ova dva razloga može dovesti do nekonzistentnosti u indeksiranju i time otežati pronalazak i okupljanje svih relevantnih dokumenata o nekoj temi unutar sustava te stoga postoji pozitivna povezanost između konzistentnosti predmetnog opisa i učinkovitosti sustava za pretragu (Leonard, 1977).

Većina korisnika informacije od baštinskih ustanova traži preko mrežnog kataloga, upisivanjem jednostavnih podataka poput naslova ili neke teme, očekujući relevantne rezultate na brzinu i bez mnogo truda, što problem korisničkog jamstva u samom opisu zbirke čini još uvijek vrlo relevantnim te se često ističe kako su upravo korisnici najbolji izvor termina za kontrolirani sustav, a tek onda jedinice građe (Golub, 2003).

Ovaj je kratki pregled predmetnog pristupa istaknuo osnovne postavke i probleme s kojima se susreće ostvarivanje predmetnog pristupa, primarno u analognom okruženju te u teorijskim raspravama. Sljedeći novi izazov pojavio se pojavom Interneta koji je donio nove poteškoće i tražio nova rješenja, o čemu se raspravlja u sljedećem poglavlju.

2. Organizacija znanja u mrežnom okruženju

Tradicionalni pristup predmetnoj obradi koji smo ukratko prikazali u prošlim poglavljima, pojavom Interneta te velikog broja mrežnih resursa počeo se susretati s potpuno novim izazovima. Počela su se postavljati pitanja o isplativosti i metodama predmetnog pristupa mrežnih resursa, uzimajući u obzir njihovo stalno povećavanje i skupoću tradicionalne predmetne obrade koja zahtijeva stručnjake, resurse i vrijeme. Nova paradigma traženja informacija postala je tražilica Google, koja funkcionira na principu pretrage pomoću ključnih riječi, a postala je ujedno i glavni način na koji korisnici traže sadržaj. Učestalo korištenje takvih jednostavnih sustava (jednostavnih s korisničke, ali kompliciranih s tehničke strane), stvorili su kod korisnika određene navike u pretraživanju i pojednostavljene obrasce informacijskog ponašanja, koje u smislu postupaka i očekivanja oni prenose i primjenjuju pri pretraživanju strukturiranih informacijskih sustava kakve nude razne baštinske ustanove. Baštinske ustanove, počevši od prvih arhiva pa do današnjih modernih sustava za pretraživanje, uvijek su se bavile organizacijom i pružanjem pristupa različitim izvorima informacija. Pojavom mrežnih resursa, stručnjaci, iz primarno knjižničarskog okruženja, pokušali su pružiti nova rješenja i alate kako bi organizirali velik broj mrežnih resursa.

Kako bi se pokušali riješiti problemi pronalaska relevantnih i kvalitetnih mrežnih izvora, unutar akademske zajednice 90-ih godina počela se razvijati ideja predmetnih portala, pod različitim nazivima poput „kvalitetni portali“ (engl. *quality gateways*), „predmetni direktoriji“ (engl. *subject directories*) ili „virtualne knjižnice“ (engl. *virtual libraries*) (Bawden i Robinson, 2002). Sam pojam odnosi se, kako na komercijalna rješenja poput Yahoo! Directories (https://dir.yahoo.com/), tako i na zbirke kvalitetnih mrežnih resursa organiziranih i izabranih od strane stručnjaka, kao što su Intute (http://www.intute.ac.uk/) ili BUBL (http://bubl.ac.uk/). Početni napori u organizaciji mrežnih resursa bili su usmjereni na primjenu klasičnih metoda taksonomske organizacije na mrežne izvore. Klasična organizacija mrežnih izvora podrazumijevala je ili primjenu neke od klasifikacijskih shema (DDK, UDK,…) ili organiziranje resursa u direktorije organizirane hijerarhijski. Bawden i Robinson (2002) sumirali su osnovne karakteristike predmetnog portala:

- jasno definiran predmetni opseg mrežnih resursa koji su obuhvaćeni zbirkom
- jasno definirani kriterij kvalitete kojim se izabiru mrežni resursi
- dosljedan oblik opisa resursa
- dosljedna kategorizacija, klasifikacija i označivanje zbirke
- jasno definirane razine odgovornosti za stvaranje i održavanje sustava.

Uzmemo li u obzir opseg i količinu mrežnih izvora koje bi trebalo organizirati na takav način, postaje jasan problem financiranja i isplativosti održavanja takvih sustava. I dok je takav način organizacije mrežnih resursa, zbog manjeg broja korisnika i mrežnih izvora, u početku bio dostatan, razvoj World Wide Web-a koji je doveo do naglog porasta dostupnih izvora i informacija, zahtijevao je pronalaženje novih pristupa i metoda u organizaciji informacija u mrežnom prostoru. Trenutno stanje jasno oslikava te probleme: BUBL kao i Intute prestali su s radom 2011. godine zbog ukidanja financiranja.

Vratimo li se opet na osnovne pristupe indeksiranju (Slika 2), možemo reći kako se u mrežnom okruženju fokus agenta koji provodi označivanje prebacuje s predmetnog stručnjaka (čiji su alati tezaurusi, klasifikacije i ontologije) na korisnika, ostvarujući ideju demokratskog pristupa informacijama. Takav pristup organizaciji informacija možemo razložiti na četiri osnovna aspekta (Cripe, 2007):

1. **Decentralizacija informacija**. Pristup kojemu je u osnovi taksonomska organizacija znanja, stavlja veliki naglasak i opterećenje na osoblje koje upravlja nekim sustavom kako bi on uspješno funkcionirao. Društveni pristup organizaciji informacija smanjuje teret odgovornosti centraliziranog ili hijerarhijskog pristupa.

2. **Povećana točnost i granularnost**. Društveni pristup informacijama teži većoj točnosti i specifičnosti organizacije, primjenjujući *bottom up* metodu indeksiranja, umjesto klasične *top down* metode. Umjesto da se odluke prepuste centralnom autoritetu, koji donosi odluke o relevantnosti pojedine informacije, proces odlučivanja prepušten je korisničkoj zajednici koja kroz svoju interakciju uspostavlja sustav relevantnih informacija.

3. **Samoispravljajući i samopoboljšavajući rezultati**. Društveni pristup problemu relevantnosti u osnovi je sposoban samog sebe ispravljati. Kako sve veći broj korisnika sudjeluje u označivanju informacija, svaka anomalija, koju neka subjektivna pozicija korisnika donosi u sustav, marginalizira se do točke nevažnosti za cijeli sustav. Na taj način, sustav samog sebe ispravlja i pruža sve veću razinu točnosti i granularnosti koje pozitivno utječu na relevantnost.

4. **Web 2.0 kultura sudjelovanja.** Demokratski pristup rješavanju problema relevantnosti nekog sustava, osnovna je osobina web 2.0 pristupa koji traži sudjelovanje korisnika,

radikalnu decentralizaciju te ponovno korištenje sadržaja kako bi se postigla bolja efikasnost sustava.

Posljednji aspekt uvodi novi pojam koji je postao neizostavan u svakoj raspravi o kreiranju i organizaciji sadržaja u mrežnom okruženju – pojam Web 2.0. O samom pojmu te sa njime povezanim konceptima organizacije znanja u takvom korisničko-orijentiranom okruženju, raspravljamo u sljedećem poglavlju.

2.1. Web 2.0 i društveni softver

Prva definicija pojma „Web 2.0“ potječe od Tima O'Reillya i suradnika: „*Web 2.0 označava mrežu kao platformu koja na jednom mjestu okuplja sve povezane uređaje; Web 2.0 aplikacije su one aplikacije koje najbolje izražavaju intrinzične mogućnosti platforme; pružajući softverske usluge kao stalno poboljšavajuću uslugu koja postaje sve bolja što je više ljudi koristi, konzumirajući i kombinirajući podatke iz različitih izvora, uključujući i pojedinačne korisnike, koji s druge strane pružaju svoje vlastite podatke u obliku koji dopušta njihovo korištenje od strane drugih korisnika, stvarajući nove mrežne mogućnosti kroz „arhitekturu sudjelovanja“, protežući se tako dalje od metafore stranice Web-a 1.0, kako bi se ostvarila bogatija korisnička iskustva*“ (O' Reilly, 2005).

Koncept Weba 2.0, povezanih servisa i tehnologija, O'Reilly je predstavio u svojevrsnoj mentalnoj mapi područja (Slika 4).

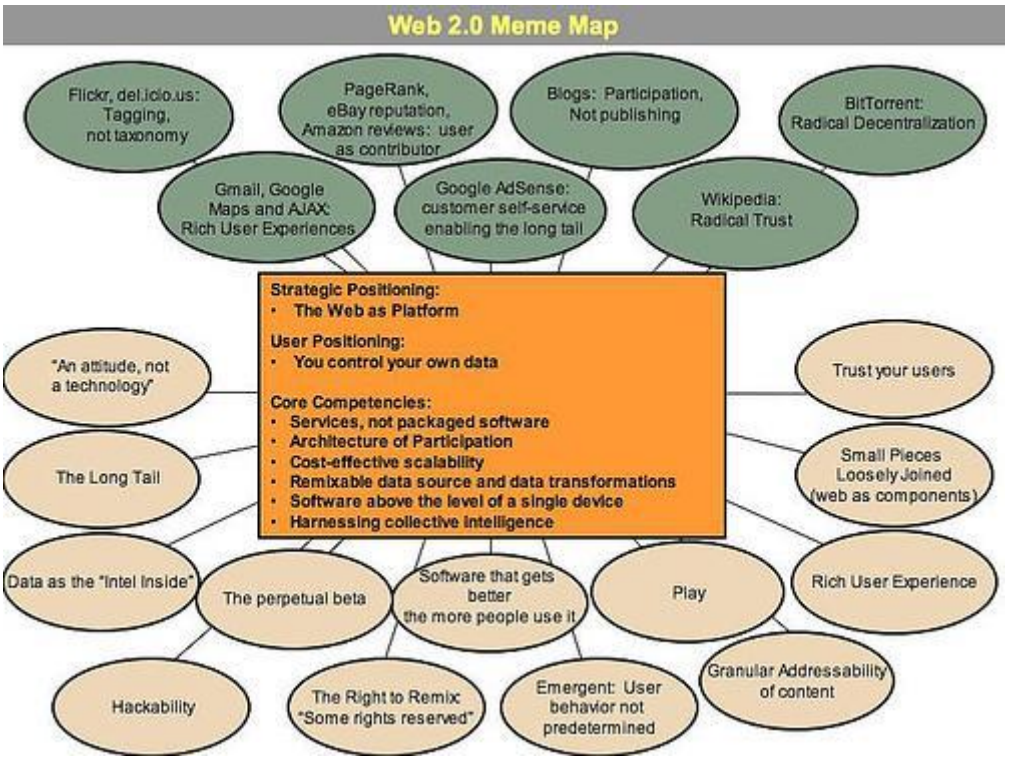

Slika 4 - Web 2.0 mentalna mapa
Izvor: http://www.oreillynet.com/oreilly/tim/news/2005/09/30/graphics/figure1.jpg

U literaturi se često govori kako Web 2.0 ne predstavlja novu tehnologiju već je produkt eksplozije stvaranja novih mrežnih sadržaja te se razdvaja na tri osnovna sloja. Cripe (2007) ta tri sloja definira kao tri osnove Web 2.0 pokreta:

1. Tehnološka osnova. Odnosi se na tehnologije koje podržavaju i omogućuju korisničko stvaranje sadržaja. Od najčešće spominjanih su to AJAX (engl. *Asynchronous JavaScript and XML*), API (engl. *Application Programming Interface*) te RSS (engl. *Really Simple Sindication*).

2. **Kulturološka osnova**. Odnosi se na stav koji stoji iza Web 2.0 pokreta, koji promovira individualiziran pristup te stvaranje sadržaja iz perspektive korisnika.

3. **Regulatorna osnova**. Odnosi se na pravila, poslovne pristupe i dobre prakse koje zahtijevaju stalan pristup izvorima informacija kao podlozi za odlučivanje.

Sličnu podjelu daje i Peters (2009) razlikujući tri povezane komponente koje čine osnovu Web 2.0 (Slika 5):

- **Licence** (omogućavanje lakog dijeljenja i pristupa sadržaju)
- **AJAX/RSS** (tehnološka osnova)
- **Društveni softver** (korisnička osnova)

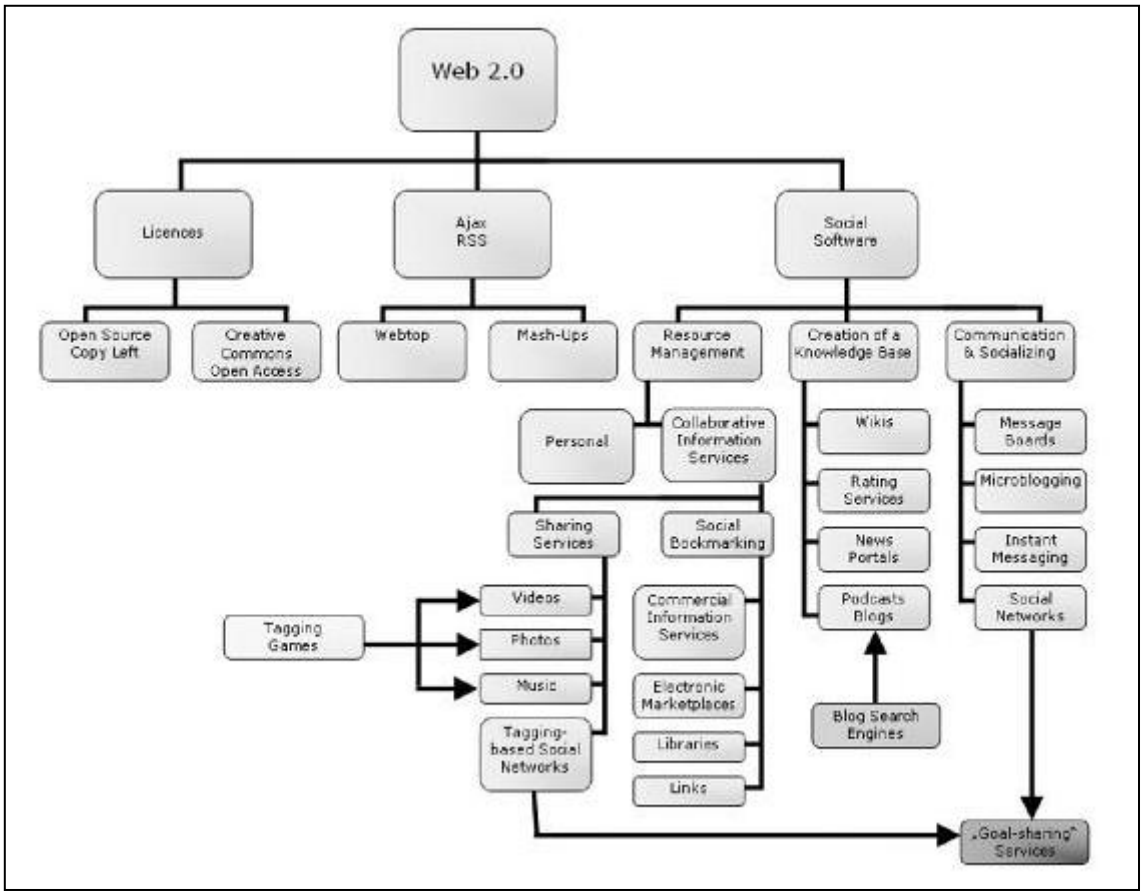

Slika 5 - Osnovne komponente Weba 2.0
(Peters, 2009)

Tehnološka komponenta odnosi se na tehnološke inovacije koje ga omogućuju, dok društveni softver naglašava njegovu korisničku komponentu. Na tehnološkoj razini Web 2.0 pokriva čitav niz programskih rješenja (AJAX, RSS, API,…) koji omogućuju korisnicima da stvaraju, prikupljaju, opisuju i razmjenjuju mrežne sadržaje. S druge strane, Web 2.0 odnosi se i na nove tendencije samog korištenja Internet prostora, omogućene novim razvojem tehnologija (mrežne zajednice, blogovi, wikiji…). Možemo reći da njegova tehnološka komponenta omogućuje onu socijalnu, no bez odaziva i prihvaćanja Internet zajednice, tehnološke inovacije ne bi imale previše učinka na sam način korištenja Interneta. Tako se u međudjelovanju socijalne i tehnološke komponente nazire područje koje pokriva Web 2.0 inicijativa. Web 2.0 inicijativa pokriva mnoge različite aspekte korištenja Interneta, od kojih

su svakako najeksponiraniji aspekti dijeljenja glazbe, fotografija, pisanja blogova, mrežne suradnje te stvaranja mrežnih zajednica.

2.2. Društvena osnova Weba 2.0 - društveni softver

Društveni softver zajednički je naziv za niz mrežnih servisa i alata koji omogućuju korisnicima da, više nego ikad prije, sudjeluju u stvaranju mrežnih sadržaja. Razvijanje Internet tehnologije omogućilo je korisnicima da postanu aktivni stvaraoci sadržaja, a ne samo njegovi pasivni primatelji i to je upravo ona glavna komponenta koju Web 2.0 naglašava – korisnici su Web.

Stvaranje termina "društveni softver" (engl. *social software*) pripisuje se sociologu Clayu Shirkyju koji ga jednostavno definira kao "softver koji omogućava grupnu interakciju" (Shirky, 2008). U nekim radovima, pojam društveni softver se izjednačava s pojmom Web 2.0 upravo zbog njegove ključne uloge u samom konceptu Weba 2.0 (Peters, 2009), a njegovi glavni koncepti su (Shirky, 2008):

1. **Omogućava komunikaciju između pojedinaca ili grupa.** Društveni softver posjeduje implicitne mehanizme koji omogućavaju grupama istih interesa da međusobno surađuju. Na taj način one postaju svjesne zajedničkih napora, ocjenjuju rad drugih te dopuštaju da drugi ocjenjuju njihov rad, a sve kako bi na taj način stvorene informacije koristile svim članovima zajednice.
2. **Omogućava grupno prikupljanje i dijeljenje resursa.** Društveni softver omogućuje da korisnici prikupljaju i dijele materijale. Od dijeljenja obiteljskih fotografija, pa do dijeljenja znanstvenih spoznaja, svaki je podatak nekome nova informacija, kao i sredstvo pomoću kojeg se može dobiti pravodobno reagiranje na objavljenu informaciju.
3. **Omogućava skupno upravljanje i organizaciju informacija.** Društveni softver omogućuje da znanje više ne bude prezentirano na samo jedan, tradicionalan način, već se pronalaze novi načini organizacije i pronalaženja znanja koje je korisno za interesnu grupu korisnika.
4. **Postaje bolji što ga više ljudi koristi**. Stvara se okruženje u kojem korisnici sami organiziraju svoje informacije na način na koji im to najbolje odgovara, a ujedno i svojim pojedinačnim naporima koriste cijeloj grupi. Društveni softver stvara takvo

okruženje za rad, u kojem je korist koju dobiva zajednica, uvijek veća od zbroja koristi svih pojedinaca koji ga koriste.

U svjetlu predmetnog pristupa, ovdje nam je najzanimljivija njegova treća osobina, osobina suradničkog indeksiranja prikupljenih izvora kao metoda organizacije sadržaja na suradničkim servisima (engl. *collaborative information services*). Naime, povećanjem broja mrežnih izvora, kao i korisnika koji te izvore stvaraju i objavljuju na mrežnim servisima, pojavila se potreba organizacije velikog broja resursa koja bi omogućila jednostavno opisivanje, ali ujedno i lako pronalaženje relevantnih izvora, u okviru čega se i razvila ideja suradničkog označivanja.

2.2.1. Pregled servisa koji koriste suradničko označivanje i dijeljenje sadržaja

Prije same rasprave o teoretskom pristupu suradničkom indeksiranju, potrebno je dati pregled primjernih servisa koji uspješno koriste suradničko označivanje kao metodu organizacije sadržaja, kako bi se na primjerima pokazale prednosti i nedostaci samog pristupa.

U svjetlu takvog pregleda, same servise možemo podijeliti na dva osnovna tipa (Peters, 2009):

(1**) servisi za suradničko označivanje i pohranu sadržaja** (engl. *social bookmarking services*)

(2) **servisi za dijeljenje sadržaja** (engl. *sharing services*).

Dok je prva vrsta servisa usmjerena na pohranjivanje, organiziranje, pretragu i upravljanje mrežnim izvorima, druga vrsta servisa usmjerena je na dijeljenje samog sadržaja, bio to video, glazba, fotografija ili bilo koja druga vrsta izvora.

2.2.1.1. Servisi za suradničko označivanje i pohranu sadržaja

Servisi za suradničko označivanje i pohranu sadržaja (engl. *social bookmarking services*) omogućuju korisnicima pohranjivanje, organiziranje, pretragu i upravljanje mrežnim resursima unutar svog personaliziranog korisničkog prostora, uz korištenje korisničkih oznaka kao metode organizacije sadržaja. Za razliku od jednostavnih sustava za pohranjivanje oznaka, koje možemo naći u svakom Internet pretraživaču, suradnički servisi proces pohranjivanja i organizacije poveznica premještaju u mrežno okruženje, omogućavajući dostupnost samih izvora s bilo kojeg mjesta s pristupom Internetu. Iako se koncept mrežnog dijeljenja poveznica može povezati i s ranijim servisima, njegova popularnost počela je

pokretanjem servisa Delicious 2003. godine (Peters, 2009). Osnovna ideja sustava bila je omogućavanje korisnicima da pohranjuju, opisuju i dijele poveznice u mrežnom okruženju.

Heymann, Koutrika i Garcia-Molina (2007) pružaju pregled strukture servisa za suradničko označivanje i pohranu sadržaja (Slika 6).

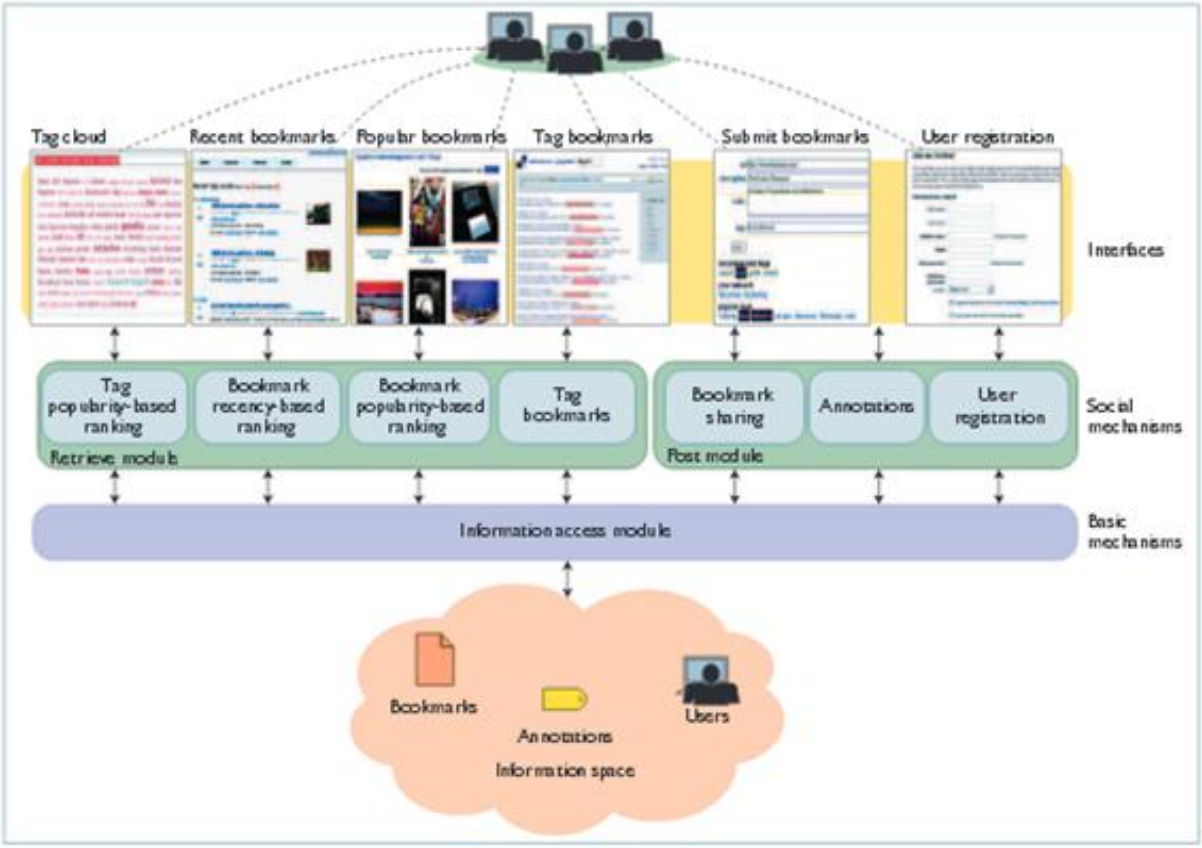

Slika 6 - Struktura servisa za suradničko označivanje
(Heymann, Koutrika i Garcia-Molina, 2007)

Cijeli proces kreće od registracije koja omogućuje kreiranje korisničkog računa kojim korisnik upravlja svojim resursima. Kada korisnik pronađe mrežni resurs, pohranjuje ga na izabranu platformu i opisuje, kako bi ga kategorizirao i omogućio ponovno pronalaženje. Sam opis i kategorizacija omogućeni su dodavanjem „korisnički generiranih ključnih riječi" (Trant, 2009) okupljenih pod pojmom „korisničke oznake" (engl. *tags*). Cijeli proces, tijekom kojeg korisnici dodjeljuju ključne riječi zajednički korištenim sadržajima, okupljen je pod pojmom društveno ili korisničko označivanje (engl. *social tagging*) (Golder i Huberman, 2006), a ukupnost svih dodijeljenih oznaka unutar neke informacijske platforme kreira folksonomiju (Trant, 2009).

Sam pojam folksonomije složen je od riječi „ljudi“ (engl. *folks*) i riječi „taksonomija“ (engl. *taxonomy*), upućujući na ideju korisničkog sudjelovanja u kreiranju sustava za označivanje i pretraživanje mrežne građe (Vander Wal, 2007), no sama terminološka primjerenost pojma još uvijek je predmet znanstvenih rasprava (Mathes, 2004).

Prije same rasprave o teorijskim postavkama korisničkog označivanja, u nastavku se donosi pregled izabranih primjera servisa za suradničko označivanje koji koriste suradničko označivanje kao metodu organizacije sadržaja. U osnovi, same servise možemo podijeliti na servise za pohranu i označivanje mrežnih izvora (npr. Delicious, Diigo, Pinterest), servise za upravljanje bibliografskim referencama (npr. Zotero, EndNote, RefWorks) i servise koji omogućuju i jedno i drugo (npr. Bibsonomy). Kako trenutno kompletan popis uključuje više od 50 aktivnih servisa (http://en.wikipedia.org/wiki/Comparison_of_reference_management_software; http://en.wikipedia.org/wiki/List_of_social_bookmarking_websites), napravljen je izbor onih koji su trenutno najpopularniji ili najbolje primjenjuju suradničko označivanje kao metodu organizacije sadržaja.

Pregled uključuje servis Delicious, kao pionirski primjer, koji je uveo organizaciju korisničkim oznakama u globalnu upotrebu te servis Diigo koji se danas može smatrati najnaprednijim servisom te vrste s mnogim dodanim značajkama. Također, daje se pregled sustava koji uz pretragu i spremanje mrežnih izvora, nude i mogućnost upravljanja bibliografskim referencama kao što je Bibsonomy.

2.2.1.1.1. Delicious

Jedan od prvih, globalno popularnih servisa za suradničko označivanje, Delicious (www.delicious.com), servis je koji služi korisnicima za pohranu, dijeljenje, opis i pronalaženje mrežnih izvora. Servis je pokrenut 2003. godine, zatim kupljen od strane Yahoo-a 2005., kada je i doživio najveću popularnost s više od 5 milijuna registriranih korisnika i preko 180 milijuna spremljenih poveznica (http://en.wikipedia.org/w/index.php?title=Delicious_(website)&oldid=622696993).

Kao jedan od globalno najpopularnijih servisa, popularizirao je upotrebu korisničkih oznaka kao metodu organizacije na globalnoj razini i postao standard s kojim se svi novi servisi moraju mjeriti. U svibnju 2014. kupljen je od strane kompanije Science.Inc i trenutno se nalazi u njihovom vlasništvu (http://blog.delicious.com/2014/05/our-bookmarking-platform-has-found-a-new-home-with-science-inc/).

Kako bi organizirao pohranjene sadržaje, Delicious koristi korisničke oznake, nekontrolirane termine koje sami korisnici dodaju pohranjenim izvorima. Proces dodavanja novog mrežnog izvora sastoji se od dodavanja poveznice na izvor koji želimo pohraniti. Nakon toga, potrebno je upisati naziv izvora (Slika 7), označiti ga korisničkim oznakama, po želji dodati komentar i jednostavno ga pohraniti.

Slika 7 - Proces dodavanja novog mrežnog izvora na Delicious.com

Također, postoji i određena kontrola samog procesa unosa oznaka: oznake je potrebno odvojiti zarezom, a postoji i popis preporučenih oznaka, tj. najčešće dodijeljenih oznaka izvoru koji trenutno spremamo od strane drugih korisnika sustava, kao i kratak pregled dobrih praksi označivanja, prelaskom pokazivača preko slike upitnika (Slika 8).

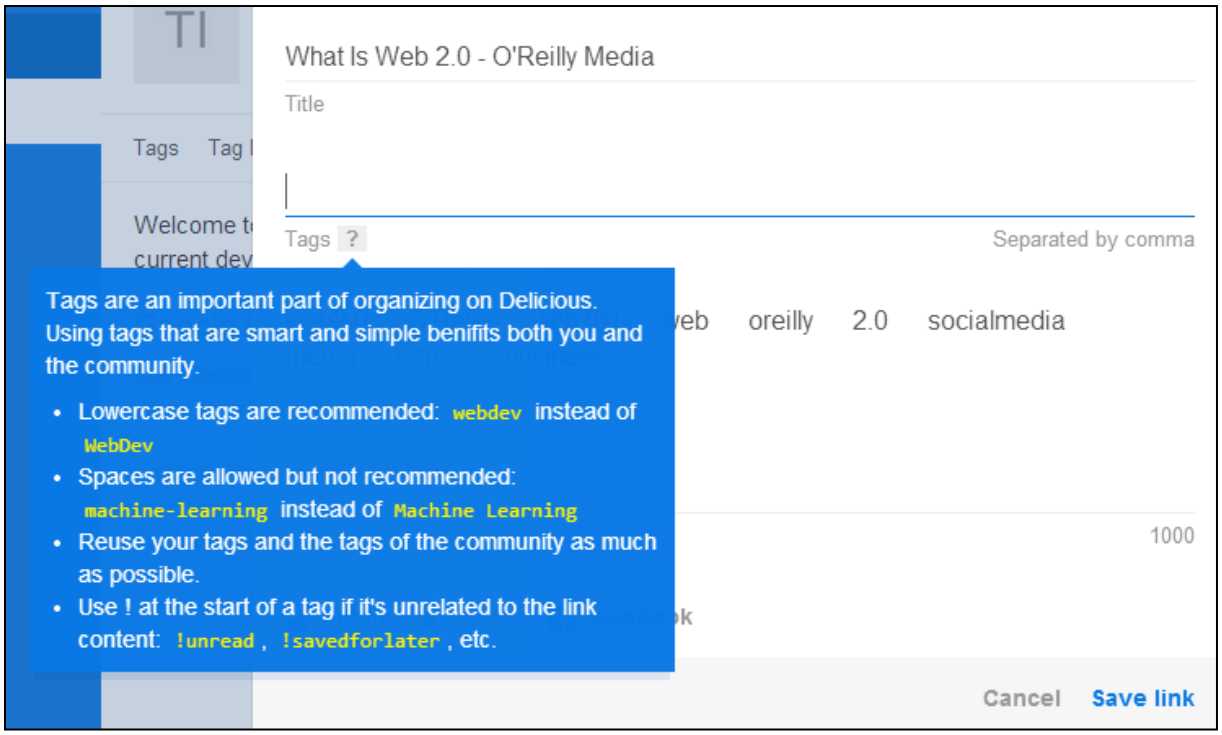

Slika 8 - Upute za dodavanje oznaka servisa Delicious.com

Kao što vidimo na slici, stvaratelji sustava svjesni su problema korištenja nekontroliranih oznaka i različitih leksičkih varijanti kojima se može označiti isti sadržaj. Stoga preporučuju korištenje malih slova kod imenovanja oznaka (*webdev* umjesto *WebDev*) te korištenje crtice kao poveznice između dvije riječi koje označavaju neki pojam umjesto razmaka (*machine-learning* umjesto *Machine Learning*).

Kako se upisane oznake ujedno i koriste kao popis termina kojima se generiraju preporučeni termini, dodana je još jedna mogućnost korištenja osobnih ili subjektivnih oznaka koje imaju značenje samom korisniku, ali neće koristiti samoj zajednici. Te oznake korisnici indiciraju stavljanjem uskličnika ispred oznake te one služe kao normalne oznake korisniku, ali se ne ubrajaju u set oznaka iz kojih se generiraju preporučene oznake.

Sustav omogućuje postupak društvenog pregledavanja (engl. *social browsing*) grupiranjem svih izvora označenih nekom oznakom preko URL adrese. Npr. svi izvori označeni oznakom *web2.0* okupljeni su na adresi http://delicious.com/tag/web2.0. (Slika 9).

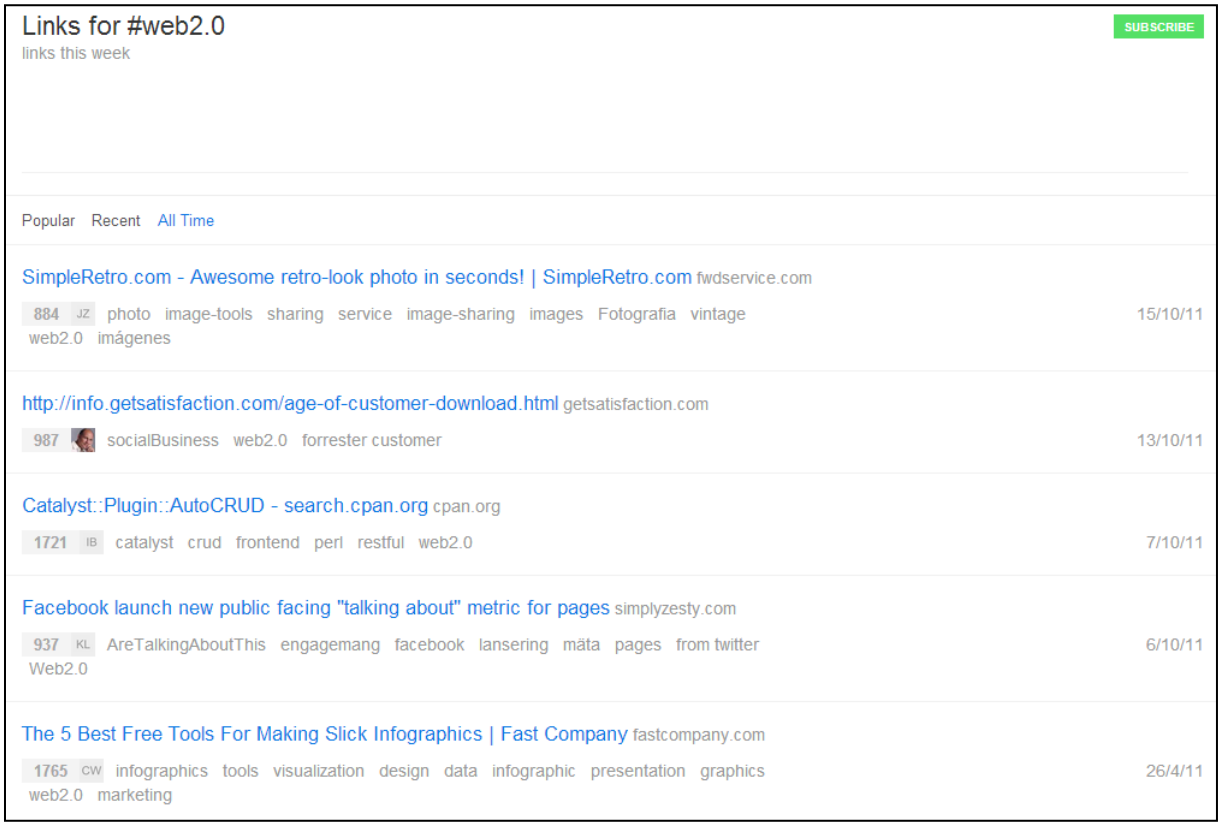

Slika 9 - Najpopularniji mrežni izvori označeni oznakom web2.0 unutar servisa Delicious.com

Na taj način, korisnici mogu saznati koji su izvori najčešće spremljeni od strane korisnika sustava, dajući time i pregled kvalitetne selekcije mrežnih izvora iz najrazličitijih područja ljudskog znanja, koje mogu koristiti i oni koji nisu nikada sudjelovali u njenom kreiranju. Tako je korist pojedinca (koji je organizirao izvore isključivo za sebe), u interakciji s velikim brojem drugih korisnika koji su radili to isto, dovela do velike koristi za sve korisnike.

2.2.1.1.2. Diigo

Diigo.com je servis za suradničko označivanje, u mnogim pogledima sličan servisu Delicious, jer omogućuje pohranu i organizaciju mrežnih izvora, ali također sadrži i dodatne osobine potpunog sustava za upravljanje znanjem. Uz pohranu i opisivanje samih mrežnih izvora, Diigo dopušta i pohranu te označivanje dijelova mrežnih stranica, grupnu suradnju oko istraživačkih tema te stvaranje osobnog sustava za upravljanje znanjem (Slika 10).

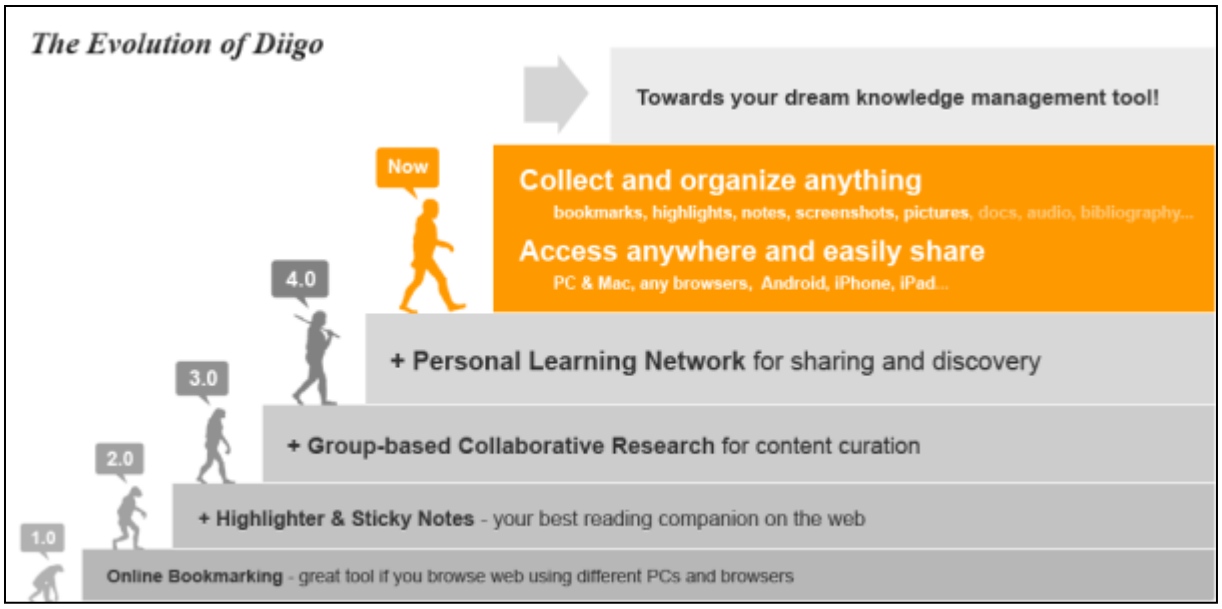

Slika 10 - Osobine servisa Diigo.com

Pokrenut je 2005. godine kao jednostavan servis za pohranu i organizaciju mrežnih izvora, a danas se smatra najkorištenijim servisom za suradničko označivanje s preko 7 milijuna registriranih korisnika te preko 350 milijuna spremljenih izvora (http://blog.diigo.com/2013/08/19/diigo-welcomes-its-7th-million-user-with-a-major-redesign/).

Proces dodavanja i označivanja samog mrežnog izvora sličan je onom Deliciousa, gdje se dodavanjem URL adrese izvora automatski povlače naziv i kratak opis (ako je to moguće) te popis preporučenih oznaka za dodani izvor (ako on postoji) (Slika 11).

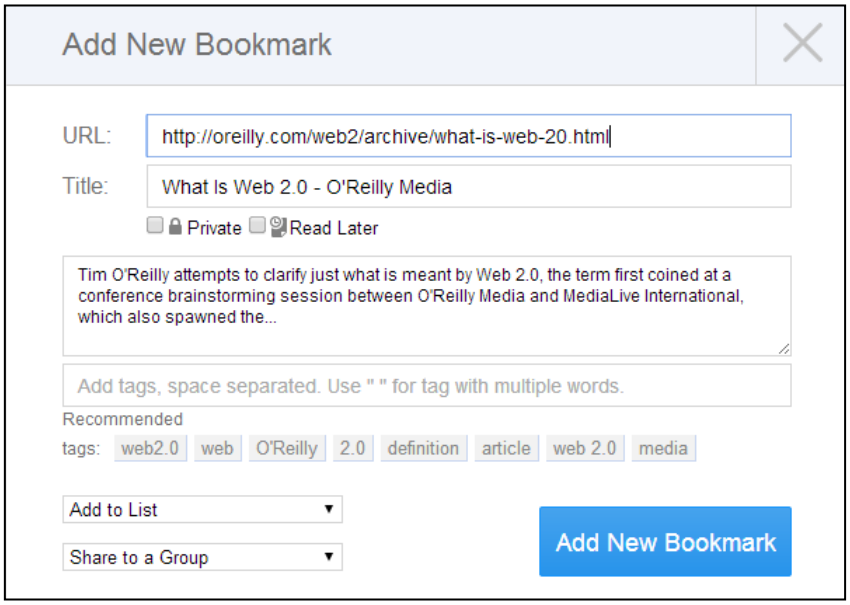

Slika 11 - Proces dodavanja novog mrežnog izvora na Diigo.com

Kao što je vidljivo iz slike, oznake se odvajaju samo razmakom, dok je fraze potrebno staviti unutar navodnika kako bi se pojavile kao jedinstvena oznaka. Također, postoji popis preporučenih oznaka, a izvor se može i odmah dodati nekom već postojećem popisu izvora ili podijeliti s grupom drugih korisnika.

Kao i kod servisa Delicious.com, i Diigo omogućuje društveno pregledavanje (engl. *social browsing*) grupiranjem svih izvora označenih nekom oznakom preko URL adrese. Npr. svi izvori označeni oznakom *web2.0* okupljeni su na adresi http://www.diigo.com/tag/web2.0. (Slika 12).

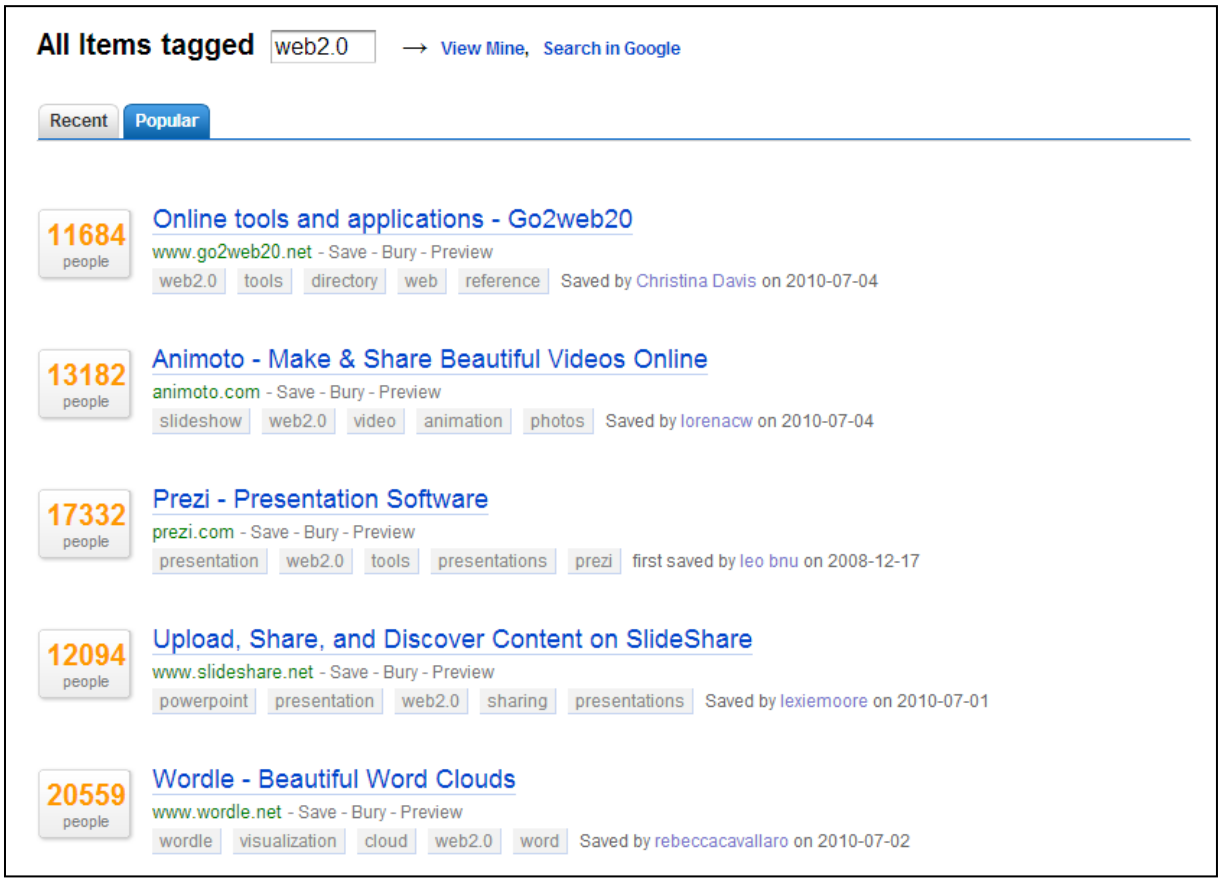

Slika 12 - Najpopularniji mrežni izvori označeni oznakom web2.0 unutar servisa Diigo.com

Popis je automatski poredan po broju korisnika koji su pohranili izvor, zajedno s nazivom izvora, URL adresom stranice, dodanim oznakama te imenom korisnika i datumom spremanja. Na taj način stvara se veoma koristan popis izabranih poveznica o nekoj temi, za koju je važno da nisu izabrane na temelju algoritma (kao u slučaju Google pretrage) već iza odabira stoji ljudska inteligencija. Na taj se način stvara vrlo kvalitetna baza znanja izabranih mrežnih izvora, koja se stalno nadopunjuje i osuvremenjuje.

Upravljanje osobnim poveznicama, koje je neki korisnik spremio, regulirano je putem osobne upravljačke ploče nazvane *My Library* koja objedinjuje sve aspekte (Slika 13).

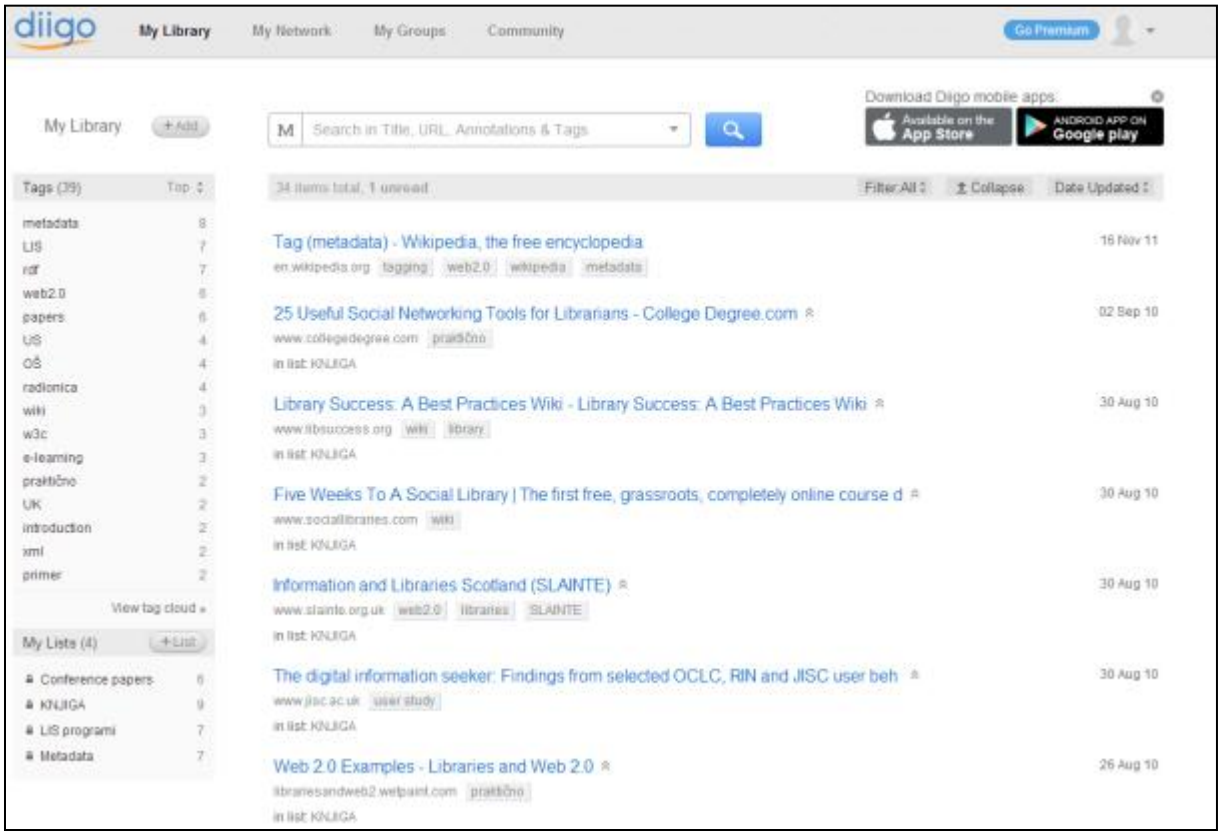

Slika 13 - Upravljačka ploča My Library servisa Diigo.com

Ovdje se nalazi popis spremljenih mrežnih izvora, s pripadajućim oznakama i datumom kada je oznaka spremljena. S lijeve strane nalazi se popis oznaka dodanih samim izvorima, s mogućnošću pregleda prema njihovoj frekvenciji ili u oblaku oznaka. Kako bi se omogućilo grupiranje mrežnih izvora, moguće je stvarati tematske popise koji okupljaju izvore vezane uz istu temu na jednom mjestu.

2.2.1.1.3. BibSonomy

Bibsonomy.org je servis za suradničko označivanje i dijeljenje mrežnih izvora, s naglaskom na prikupljanje i dijeljenje bibliografskih referenci. Pokrenut je 2006. godine kao projekt Sveučilišta Kassel i njime upravlja Knowledge & Data Engineering Group (http://www.kde.cs.uni-kassel.de/index_en.html). Sustav je zamišljen kao servis koji povezuje osobine servisa za mrežno prikupljanje izvora i platforme za prikupljanje i opisivanje bibliografskih referenci. Omogućava prikupljanje i opisivanje bibliografskih referenci, kao i pretragu znanstvene literature te se može koristiti kao repozitorij publikacija. Sustav je

prilagođen korištenju znanstvenih publikacija te omogućuje uvoz i izvoz bibliografskih referenci u standardnom BibTex formatu, kao i u nizu drugih formata.

Sustav omogućuje dodavanje mrežnih izvora ili publikacija. Proces dodavanja mrežnih izvora (Slika 14) vrlo je sličan kao kod servisa Diigo ili Delicious te traži osnovne elemente opisa poput URL adrese, naslova, opisa te korisničkih oznaka odvojenih razmakom koje zatim služe za organizaciju publikacija i izvora.

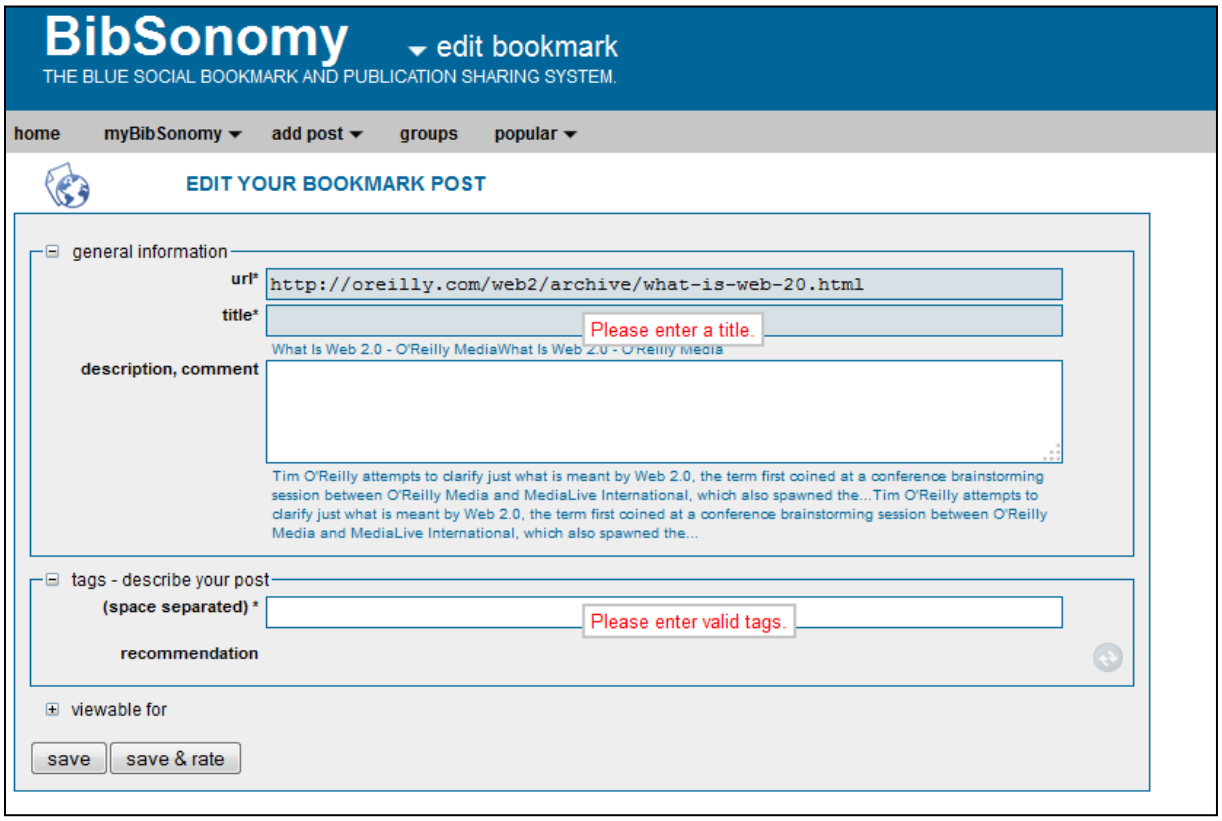

Slika 14 - Proces dodavanja novog mrežnog izvora na Bibsonomy.org

Iako servis ne daje preporuke kako oblikovati korisničke oznake tijekom procesa dodavanja novog izvora, sustav organizacije pomoću korisničkih oznaka detaljno je objašnjen na stranicama pomoći. Preporučuje se korištenje kratkih i sažetih oznaka u jednini kako bi se izbjegao velik broj leksičkih varijanti. Također, sustav podržava tzv. sistemske oznake koje već dolaze s predefiniranim značenjem (http://www.bibsonomy.org/help_en/How-to%20use%20TAGs).

Kao i kod servisa Delicious.com i Diigo, Bibsonomy također omogućuje društveno pregledavanje (engl. *social browsing*) grupiranjem svih izvora označenih nekom oznakom preko URL adrese. Npr. svi izvori označeni oznakom *web2.0* okupljeni su na adresi http://www.bibsonomy.org/tag/web2.0. (Slika 15).

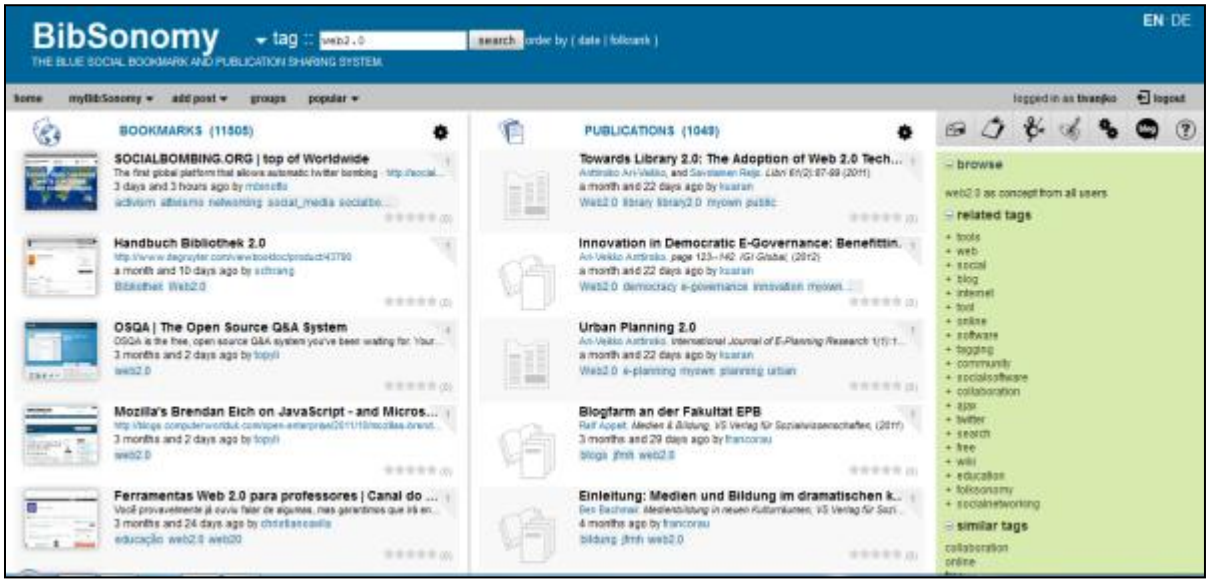

Slika 15 - Najpopularniji mrežni izvori označeni oznakom web2.0 unutar servisa Bisonomy

Izvori su odvojeni na mrežne izvore i publikacije, a moguće ih je sortirati prema datumu ili mjeri koju su autori nazvali *FolkRank* koja pronalazi visoko relevantne izvore za traženu korisničku oznaku. Algoritam je detaljno opisan u radu autora (Hotho et al., 2006), a temeljen je na idejama sličnima algoritmu koji koristi Google (PageRank) analizirajući strukturu veza između korisnika, oznaka i izvora kako bi izračunao relevantnost.

S desne strane nalazi se izbornik s povezanim i sličnim oznakama kojima se sama pretraga može dodatno precizirati, suziti ili proširiti.

Sustav također daje pregled popularnih sadržaja u pet kategorija: objave, korisničke oznake, autori, koncepti i rasprave. Popularne oznake i autori generiraju oblak oznaka koji indicira najtraženije teme i autore na samom servisu (Slika 16).

Slika 16 - Oblak oznaka najpopularnijih tema i autora servisa Bibsonomy.org

Jedan od veoma korisnih načina pregledavanja povezanih oznaka je i pregledavanje resursa prema konceptima. Na slici 17 pružen je abecedni popis koncepata i oznaka povezanih s njima.

folksonomy ←	bibsonomy bookmark bookmarking delicious display flickr flickr_-_photosharing folkrank knowledgeorganization mash-up_with_googlemap media_web_editing participation recommendation resources search_feed slide_sharing social societaltagging sort tag tagcloud tagging twitter_-_nanopublishing video_sharing web2.0 wiki
hardware ←	amd_stuff apple battery bluetooth brain-computer-interface cds_+_dvds cellphone computer cpu drivers electronics epson_stuff harddisk help_hardware hersteller keyboard kindle komponentenhersteller mac media multitouch netbook netcomm_modem_info oc_-_tweak palm parts pda printing raspberry spezifische_hardware t2000 usbstick video_cards western_digital_hard_drives wifi
html ←	html html-konverter html5 kurse sitestobegin/continuethreads:html:webauthoring suchmaschinen xhtml xhtml2 zeichensatz

Slika 17 - Popularni koncepti na stranici Bibsonomy.org

Na ovaj se način, na jednom mjestu mogu vidjeti različite oznake povezane s nekim konceptom. Analizom oznaka povezanih s oznakom *folksonomy*, možemo vidjeti kako ovakvo objedinjavanje oznaka, pod zajedničkim konceptom, funkcionira veoma dobro te su povezane oznake visoko relevantne za sam koncept.

U samom pristupu izgradnji servisa, jasno je da je on najprije namijenjen istraživačima kako bi im olakšao pronalaženje i pohranu mrežnih izvora, publikacija te njihovo kasnije korištenje kroz oblikovanje bibliografskih referenci. Sustav pruža niz mogućnosti organizacije sadržaja korištenjem korisničkih oznaka te je jedan od najboljih primjera kako korisničke oznake, uz dobro postavljenu strukturu sustava, mogu na učinkovit način organizirati mrežne sadržaje.

2.2.1.2. Mrežni servisi za dijeljenje sadržaja

Kao što smo već spomenuli, razvojem Weba 2.0 došlo je do razvoja mrežnih servisa koji omogućuju korisnicima da, više nego ikad prije, sudjeluju u stvaranju mrežnih sadržaja. Dijeljenje sadržaja između korisnika, bio to video, glazba, fotografija ili bilo koja druga vrsta izvora, postao je glavni način konzumacije mrežnih resursa. Servisi za dijeljenje sadržaja također su bili suočeni s problemom organizacije velikog broja resursa te su se mnogi okrenuli korištenju korisničkih oznaka kao osnovne metode organizacije. Većina servisa, od osnovne ideje okupljanja korisnika koji žele dijeliti s drugima svoje resurse, postupno je dodavala osobine društvenih mreža te danas omogućuju različite načine komunikacije između svojih korisnika. Možemo sa sigurnošću reći kako su danas društvene mreže primarni način na koji korisnici dijele i dobivaju informacije. Prema posljednjem popisu Wikipedije, koja uključuje samo servise s više od 100 000 registriranih korisnika (http://en.wikipedia.org/wiki/List_of_social_networking_websites), trenutno postoji preko 130 takvih društvenih mreža.

U pregled su uključeni najpopularniji servisi za dijeljenje fotografija (Flickr), video sadržaja (YouTube), glazbe (Last.fm) te primjeri društvene mreže koja upotrebljava korisničke oznake u pretrazi i organizaciji sadržaja (Twitter).

2.2.1.2.1. Flickr

Kada se govori o fotografijama u mrežnom okruženju, pristup dodjeljivanja oznaka najviše je popularizirao i u široku praksu uveo, najpoznatiji i najveći servis za razmjenu fotografija, Flickr (Flickr.com). Flickr je usluga koja omogućuje učitavanje, dijeljenje, komentiranje i kategoriziranje fotografija. Prema posljednjim podacima, Flickr ima preko 87 milijuna registriranih korisnika i procesuira oko 3,5 milijuna novih fotografija dnevno (http://en.wikipedia.org/wiki/Flickr).

Problem s fotografijama jest u tome što ih je veoma teško opisati preko samog slikovnog podatka, već je potrebno uz sliku pridodati metapodatke o samoj slici u tekstualnom obliku. Kako bi riješili taj problem, Flickr je omogućio opisivanje preko korisničkih oznaka stvarajući tako učinkovit način organizacije. Na taj se način fotografije opisuju od strane korisnika, kako bi ih opet novi korisnici lakše pronašli. Prilikom dodavanja nove fotografije ili videa, korisnici joj uz naziv dodaju i korisničke oznake, za koje postoji samo uputa da se različite oznake odvoje razmakom (Slika 18).

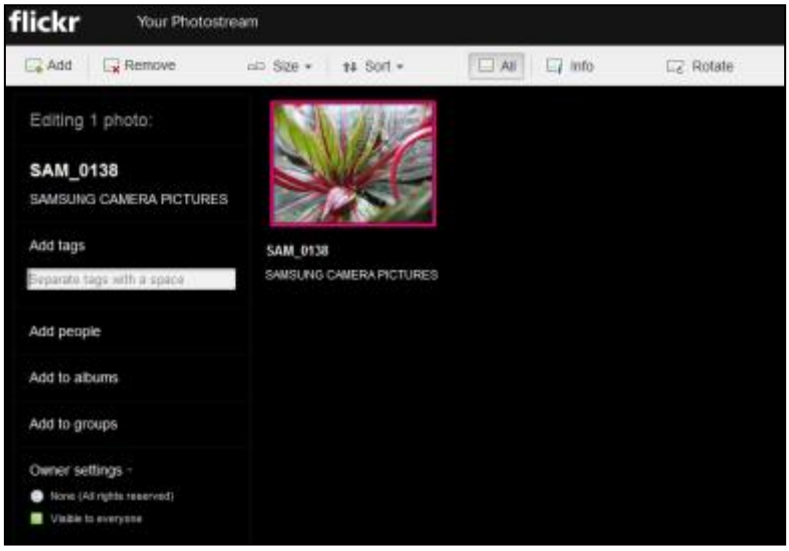

Slika 18 - Proces dodavanja nove fotografije na servis Flickr

Kako bi omogućili pristup samim fotografijama, Flickr koristi korisničke oznake koje indeksira i rabi u pretragama. Dodjeljivanje oznaka na Flickr-u i način na koji on funkcionira, veoma dobro predstavlja primjer označavanja slike malog mačića. Netko će toj slici dodijeliti oznaku „mačić“, a netko drugi oznaku „malen“, što će na kraju dovesti do toga da tu sliku kao

relevantan rezultat dobiju svi korisnici koji su u tražilicu upisali bilo koji od ova dva pojma. Ono što je ovdje veoma dobro jest što je ta slika zaista i relevantna u odnosu na oba pojma. Međutim, ta se veza ne bi mogla ostvariti označivanjem kontroliranim rječnikom, jer je malo vjerojatno da će riječ „malen“ ući u popis kontroliranih riječi, kojima bi netko označio sliku mačića. To je primjer kako označavanje nekontroliranim rječnikom može dovesti do novih veza između pojmova, koji su relevantni korisnicima, a koji se ne mogu ostvariti klasičnim taksonomskim označivanjem. Flickr također omogućava da fotografije objavite na svom blogu, a možete se i pridružiti već postojećim zajednicama okupljenima oko neke fotografske tehnike ili teme, ili sami stvoriti svoju novu zajednicu. Društveno pregledavanje omogućeno je pomoću grupiranja najpopularnijih oznaka dodanih fotografijama (Slika 19).

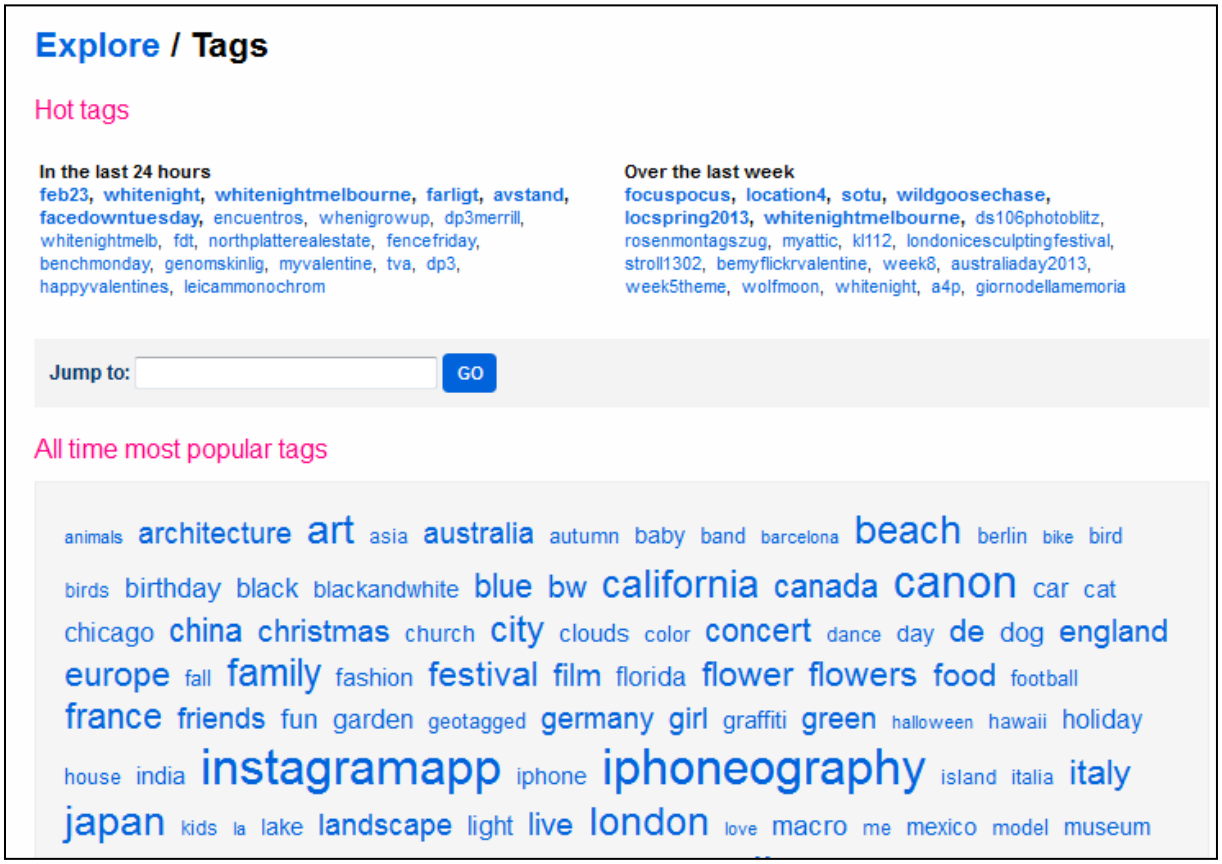

Slika 19 - Oblak oznaka najpopularnijih oznaka servisa Flickr

Kao što vidimo, lista grupira korisničke oznake vremenski, na najpopularnije u posljednjih 24 sata, posljednjih 7 dana te najpopularnije svih vremena. Popis najpopularnijih oznaka svih vremena prikazan je u obliku oblaka oznaka, u kojem veličina slova pojedinih oznaka ukazuje

na njihovu frekvenciju, tj. učestalost pojavljivanja u sustavu. Također, postoji i obrazac za pretragu kojim se brzo može doći do teme koja nas zanima.

Kao i kod prijašnjih servisa, omogućeno je grupiranje svih izvora označenih nekom oznakom preko URL adrese. Npr. svi izvori označeni oznakom *london* okupljeni su na adresi https://www.flickr.com/photos/tags/london/ (Slika 20).

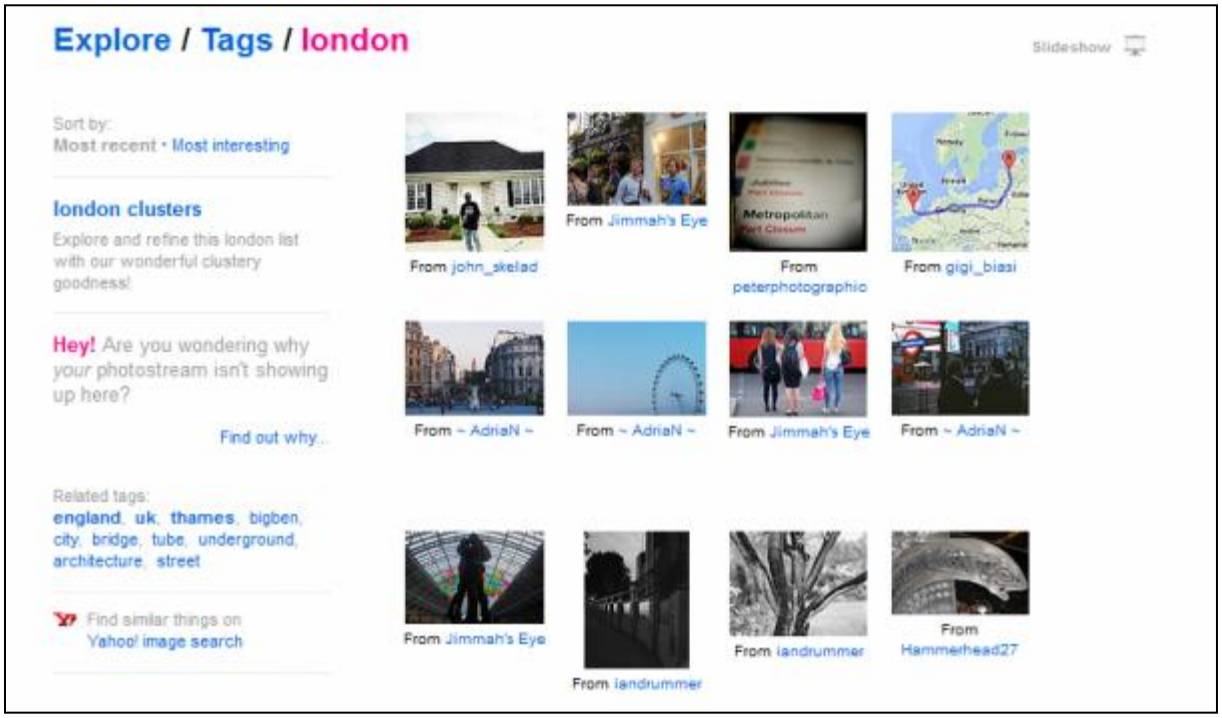

Slika 20 - Najpopularniji mrežni izvori označeni oznakom *london* na servisu Flickr

Sam popis prikazuje umanjene prikaze fotografija označenih izabranom oznakom, a moguće ga je sortirati prema recentnosti ili popularnosti. Postoji i popis povezanih korisničkih oznaka, tj. oznaka koje su drugi korisnici često koristili kada su dodavali oznaku koju pretražujemo (u ovome slučaju *london*). Flickr je prepoznao i važnost grupiranja sličnih oznaka u tematske skupine te je uveo klastere (engl. *clusters*), kategorizirane popise tematski sličnih oznaka. Sama odluka o tome koja će oznaka pripadati kojem klasteru prepuštena je automatskom algoritmu, koji pokušava razriješiti neke od problema koje korisničke oznake mogu uzrokovati. Kako se za korisničke oznake koristi prirodni jezik, sinonimija je jedan od klasičnih problema s kojima se svaki sustav, koji ih koristi u organizaciji, mora suočiti. Flickr je to pokušao regulirati razdvajanjem istih oznaka na klastere povezanih pojmova koji se odnose na potpuno različite koncepte. Ideja iza razdvajanja na klastere bila je, prije svega, usmjerena na bolje istraživanje višeznačnih pojmova, kao što su *jaguar* (auto ili životinja) ili

turkey (država Turska, životinja puran ili slike Dana zahvalnosti). Kao primjer možemo uzeti klasičan primjer višeznačne oznake *jaguar* (Slika 21).

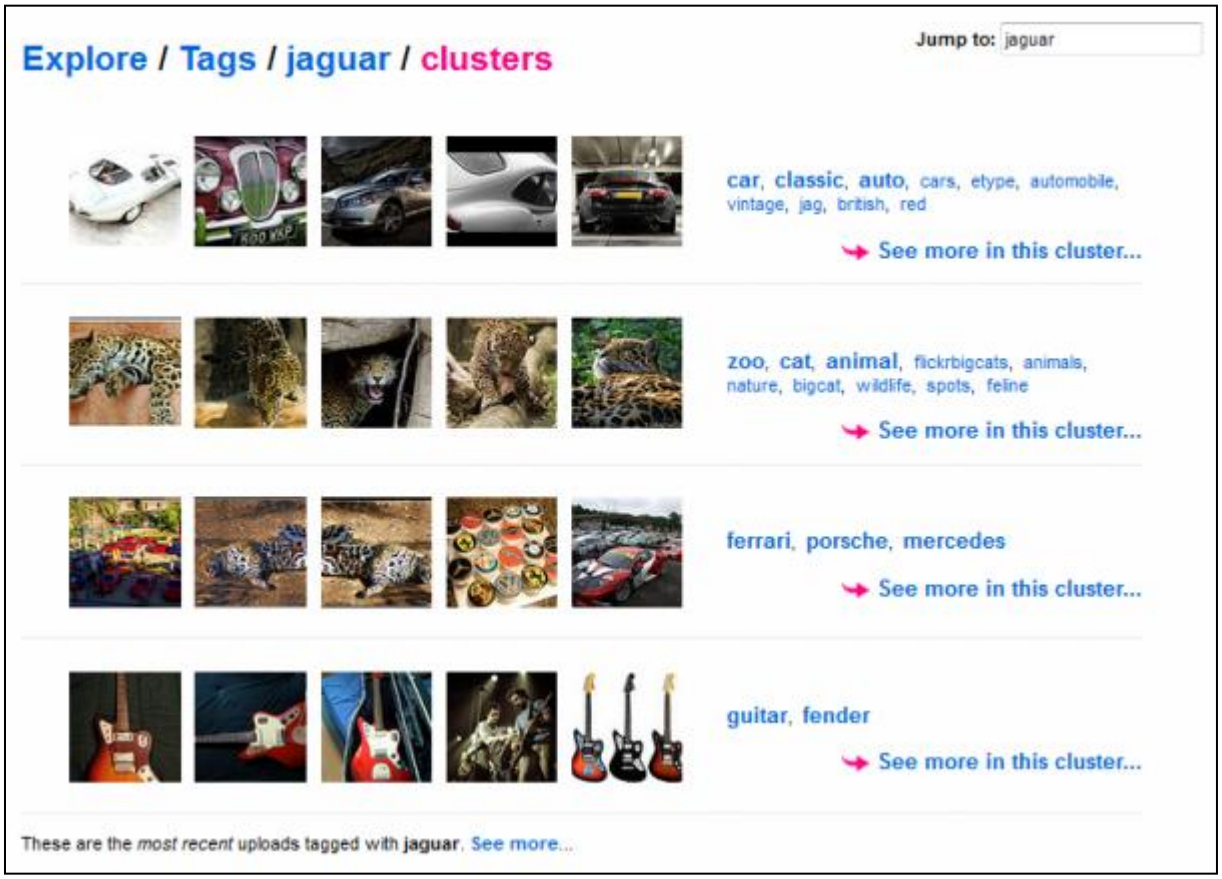

Slika 21 - Klasteri oznaka korisničke oznake jaguar na servisu Flickr

Analiziramo li klastere korisničke oznake *jaguar*, jasna je prednost razdvajanja na četiri klastera: prvi se odnosi na sve fotografije automobila marke Jaguar, drugi na životinju jaguara, treći na automobile općenito, dok se četvrti odnosi na model *Jaguar* električne gitare proizvođača Fender. Takav način dodatne kategorizacije vrlo je koristan u primjerima kada jedna oznaka ima više značenja.

2.2.1.2.2. YouTube

YouTube.com mrežni je servis za pohranu i dijeljenje video snimaka. Pokrenut je 2005. godine te je 2006. kupljen od strane Googlea i sada djeluje kao njihov servis. Prema njihovim podacima, stranica ima preko milijardu jedinstvenih posjeta korisnika mjesečno, koji pogledaju više od 6 milijardi sati video materijala, dok se 100 sati novih video materijala pohrani na servis svake minute, što YouTube čini najpopularnijim i najkorištenijim servisom

za pohranu i pregledavanje video materijala (https://www.youtube.com/yt/press/statistics.html).

Osim osnovnih opcija koje, nakon besplatne registracije, dopuštaju besplatnu pohranu i pregledavanje snimaka koje su drugi korisnici učinili dostupnima, YouTube također podržava komentiranje video zapisa. Zanimljiva opcija koju YouTube stranica pruža su tzv. povezane snimke (engl. *related videos*), koje prikazuju snimke drugih korisnika, a označene su istim oznakama kao i snimka koju trenutno gledamo. To je jako dobar način preporuke drugih video izvora, jer je vjerojatno da ako nas zanima neki video, da će nam i drugi označeni istom oznakom biti zanimljivi. Druga prednost toga je što možemo, pronašavši jednu snimku koja nas zanima, pomoću povezanih snimki, pronaći još cijeli niz nama relevantnih snimki. YouTube kao i Flickr dopušta, osim pregledavanja i pohranjivanja sadržaja na vlastitim stranicama, i reprodukciju sadržaja na osobnim stranicama korisnika. Pošto su takvi servisi za dijeljenje sadržaja najčešće besplatni, mnogi korisnici koriste ih za pohranjivanje vlastitih sadržaja koje zatim prikazuju na svojim stranicama.

Kao i kod slikovnog materijala, video također ovisi o tekstualnim opisima kako bi se mogao pronaći. Kako je YouTube kroz svoje korištenje postao komercijalna platforma mnogih izvođača, koji prikupljanjem velikog broja pretplatnika na svoje kanale zarađuju preko sustava oglašavanja, YouTube je morao implementirati razne algoritme koji sprečavaju zloupotrebu dodanih opisa uz video materijale. Korisnike se potiče na dodavanje kontekstualnih metapodataka materijalima koje postavljaju na servis, ali ih se upozorava na potrebu opisivanja videa samo relevantnim oznakama bez gomilanja nepotrebnih *spam* opisa (https://support.google.com/youtube/answer/2801973?hl=en).

2.2.1.2.3. Last.fm

Last.fm je servis za dijeljenje glazbe pokrenut 2002. godine koji omogućuje korisniku da kroz svoj profil odabere svoje najdraže izvođače te na temelju njih sustav preporučuje slične, druge izvođače koji bi ga mogli zanimati. Sustav također bilježi korisničku povijest slušanja i njegov glazbeni ukus i te informacije uključuje u poboljšanje sustava preporuka novih izvođača, pjesama ili žanrova. Oko dijeljenja glazbe na servisu se okupila i velika zajednica te je servis 2009. bilježio 30 milijuna registriranih korisnika (http://en.wikipedia.org/wiki/Last.fm).

Servis koristi korisničke oznake na sličan način kao i Flickr.com, ali implementirajući potpuno drugačiji pristup. Dok je na servisu Flickr svaki korisnik odgovoran za svoje oznake i

sam ih dodaje objavljenim materijalima, Last.fm potiče sve korisnike da dodaju oznake na način da cijela zajednica definira njihov sadržaj. Kako sve veći broj korisnika označava neki sadržaj (pjesmu ili izvođača), bilježenjem frekvencije dodavanja oznaka dobiva se skup od pet oznaka koje su korisnici najčešće dodali, na način da cijela zajednica sudjeluje u izboru oznaka koje najbolje pristaju nekom sadržaju. Njihova stranica s uputama navodi: „Oznake su kao ključne riječi koje služe za kategorizaciju glazbe – izvođača, albuma ili pjesama. One su jednostavni kratki opisi. Možete dodati koliko god želite oznaka…one su izvrstan način za klasificiranje sadržaja prema žanru…ali mogućnosti primjene su neograničene."

Stranica također navodi kako sustav ispravlja sam sebe u slučaju oznaka koje nisu prikladne nekom sadržaju: „…Zbog prirode oznaka koje su zapravo mišljenja korisnika, nije moguće ukloniti nečije mišljenje o tome kako bi neki izvođač trebao biti označen. Najviše što možete je označiti nešto na način na koji smatrate najboljim te kako sve više ljudi koristi tu oznaku, njena će popularnost biti sve veća i bit će relevantniji sadržaj od oznaka koje se manje koriste." (http://www.last.fm/help/faq?faqsearch=tags&submit=Search+FAQ).

Takav način pristupu organizacije sadržaja izvrsno oslikava demokratski pristup indeksiranju sadržaja, u kojem zajednička mišljenja velikog broja korisnika u konačnici daju općeprihvatljivo rješenje do kojeg se došlo uz sudjelovanje cijele zajednice.

Slika 22 prikazuje stranicu izvođača Johnnya Casha, jednog od najutjecajnijih glazbenika 20. stoljeća.

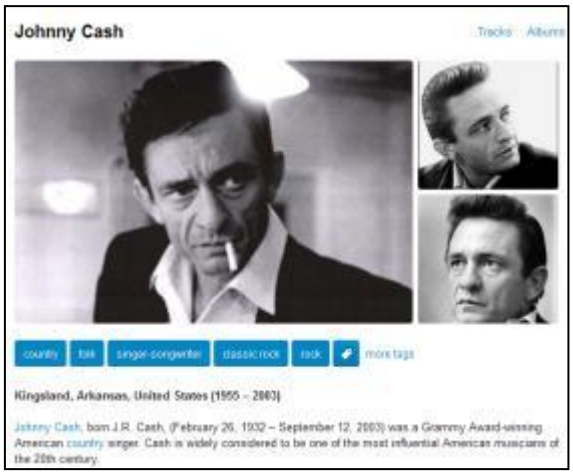

Slika 22 - Oznake dodane pojedinom izvođaču na servisu Last.Fm

Ovdje se dobro vidi kako pristup u kojem nije prikazana samo jedna oznaka, već oblak od 5 najčešće dodanih oznaka njegovim djelima, daje mnogo bolju sliku samog opusa. Ako bi Casha stavili samo u ladicu „country" izvođača ili samo „rock" izvođača, ne bismo dobili pravu sliku o njegovom cjelokupnom glazbenom opusu. Ovdje vidimo kako je zajednica

korisnika kategorizirala njegovu glazbu s dva različita elementa – rock glazba (engl. *classic rock*, *rock*) i tradicionalna narodna američka glazba (engl. *folk*, *country*), dodajući mu i element kojim se označuje da je, uz pjevanje, i autor mnogih svojih pjesama (engl. *singer-songwriter*). Iz takvog opisa drugi korisnici mogu prilično točno zaključiti kakav „zvuk“ mogu očekivati u pjesmama samog izvođača, čineći takav kontekstualni opis veoma relevantnim za pretragu.

Pritiskom na malu *bookmark* ikonu korisnik može dodati svoje oznake, a slijeđenjem poveznice *more tags* može vidjeti iscrpan oblak oznaka za izabranog autora (Slika 23).

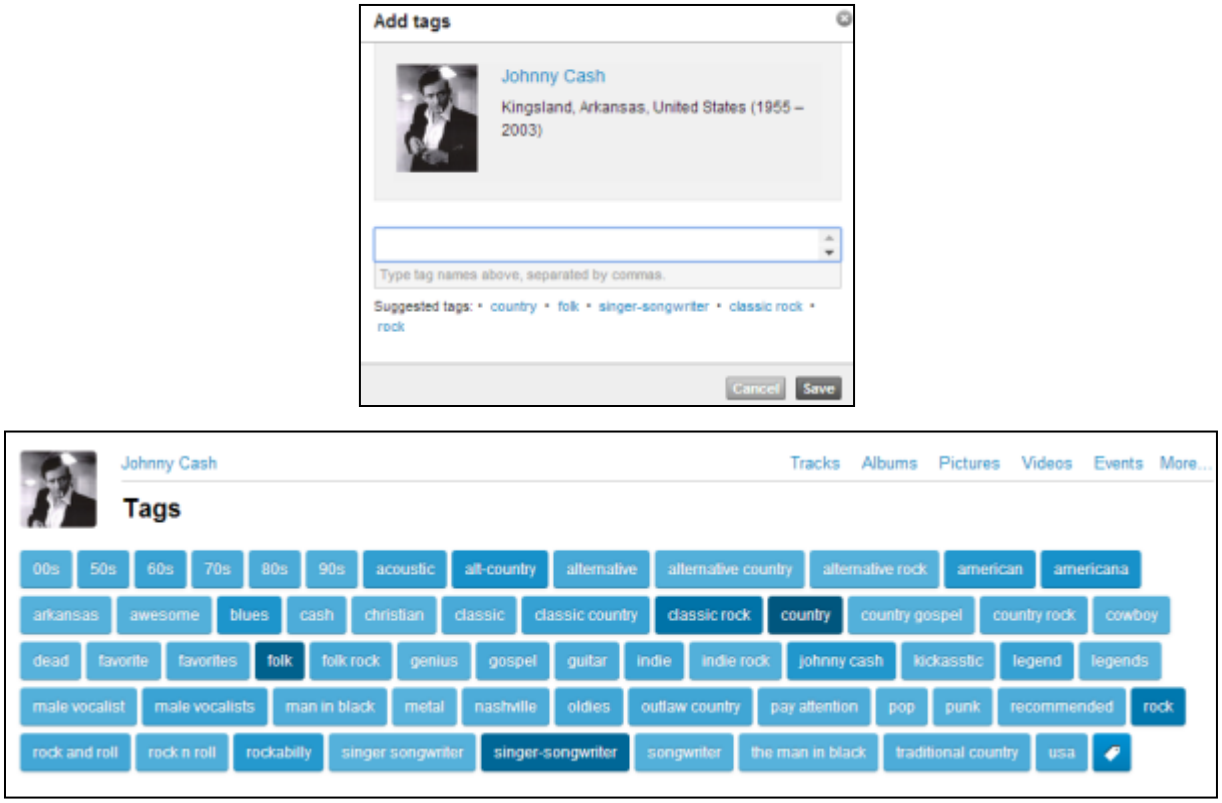

Slika 23 - Dodavanje nove oznake i oblak oznaka za izvođača Johnnya Casha na servisu Last.fm

Kao što vidimo iz slike, dodavanje nove oznake je vrlo jednostavno. Kao i kod drugih servisa koje smo analizirali, i ovdje se nalazi uputa o razdvajanju oznaka zarezom, kao i popis preporučenih oznaka (opet generiran od najčešće dodanih oznaka u sustavu). Iscrpan popis oznaka daje oblak oznaka od 60 najčešće dodanih oznaka, gdje je frekvencija (broj dodavanja oznaka) naznačena bojom (što je pozadina oznake tamnija, oznaka se češće pojavljuje u sustavu). Ovdje možemo vidjeti još nekoliko oznaka koje nisu među pet najfrekventnijih, ali su vrlo indikativne u specificiranju tematske i žanrovske usmjerenosti izvođača (*americana*,

blues, rockabilly, acoustic), kao i nekoliko osobnih oznaka (*favorite, favorites, awesome, recommended, pay attention*) koje daju subjektivnu ocjenu izvođača.

Sustav pruža i mogućnost pristupa oznakama preko oblaka oznaka, najpopularnijih oznaka gdje veličina slova oznake ukazuje na njenu frekvenciju (Slika 24).

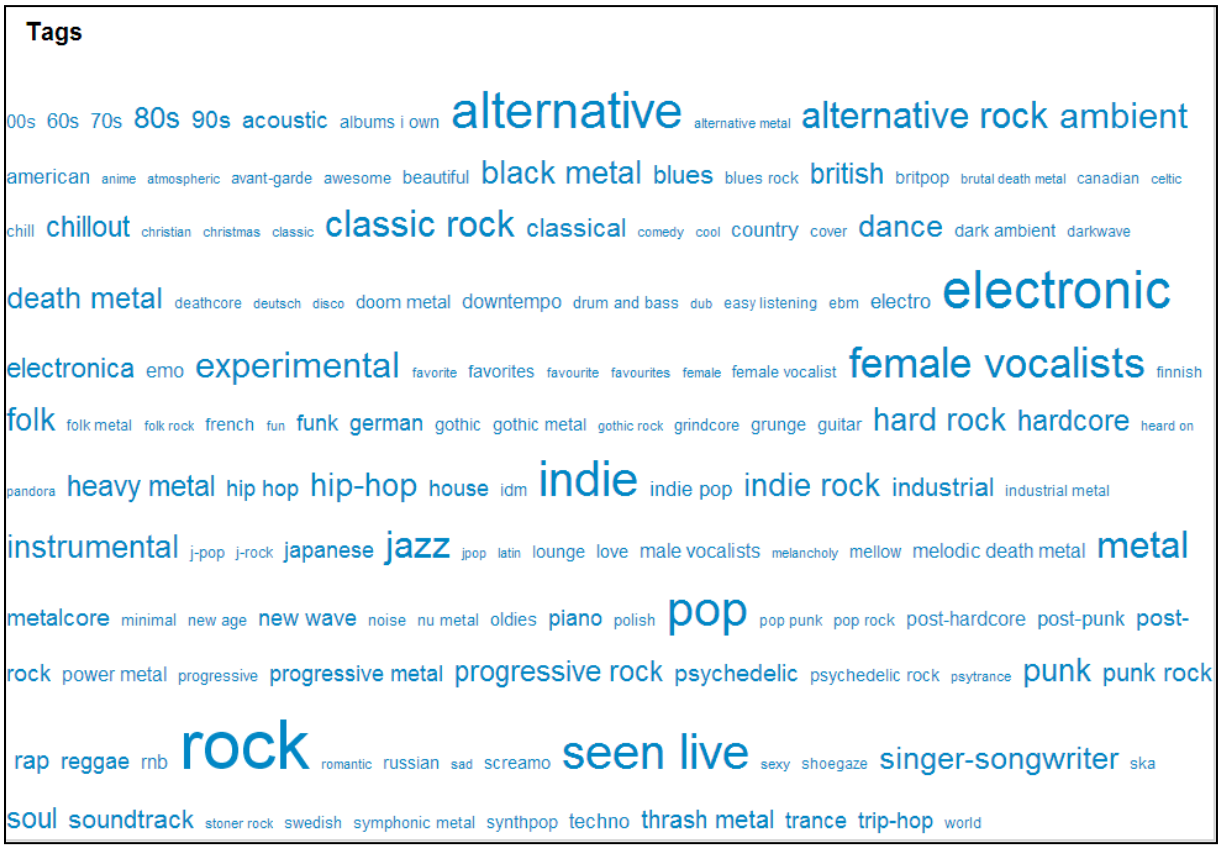

Slika 24 - Oblak oznaka najpopularnijih oznaka servisa Last.fm

Ovakvim prikazom korisničkih oznaka u oblaku oznaka, korisnicima je omogućen jednostavan i učinkovit uvid u najpopularnije žanrove na samom servisu, a slijeđenjem izabrane oznake može se doći na svojevrsnu početnu stranicu same oznake.

Slika 25 - Početna stranica oznake *rock* na servisu Last.fm

Slika 25 prikazuje početnu stranicu oznake *rock* (http://www.last.fm/tag/rock) na kojoj su okupljeni najpopularniji izvođači tog žanra, definicija samog pojma kao i povezane oznake.

Sustav korištenja oznaka veoma dobro funkcionira na samom servisu, a ideja kako zajednica bira i odlučuje kojim će se oznakama opisati neki izvođač, pjesma ili album, stvara jedan demokratski pristup organizaciji informacija. Ono što je specifično za ovakav način organizacije, gdje oznake generiraju korisnici, jest što sustav takvih kontekstualnih metapodataka ni u jednom trenutku nije konačan, već se stalno mijenja i prilagođava. U tom svjetlu, sustav opisa nikada ne zastarijeva jer odražava s jedne strane korisnički rječnik, a s druge strane lako može dodati nove žanrovske stilove u kojima se neki izvođač okuša.

2.2.1.2.4. Twitter

Twitter.com popularna je društvena mreža za *mikro-blogging*, omogućavajući korisnicima da u formi kratkih poruka (do 140 znakova) razmjenjuju poruke. Servis je pokrenut 2006. godine i danas je jedan od najpopularnijih Internet servisa uopće, s više od 200 milijuna registriranih korisnika (http://www.theguardian.com/technology/2013/sep/12/twitter-ipo-stock-market-launch).

Kako bi omogućili praćenje i kategorizaciju poruka koje korisnici razmjenjuju, Twitter je implementirao *hashtag* sustav, koji koristi kako bi označio ključne riječi ili teme o kojima neka poruka govori. Prema definiciji samog servisa: „…# simbol, koji se zove *hashtag*, koristi se za označivanje ključnih riječi ili tema unutar neke poruke. Stvoren je od strane samih Twitter korisnika kao metoda organizacije poruka“ (https://support.twitter.com/entries/49309).

Slika 26 prikazuje jednu poruku koja u sebi sadrži *hashtag* na temelju koje možemo objasniti temeljni princip.

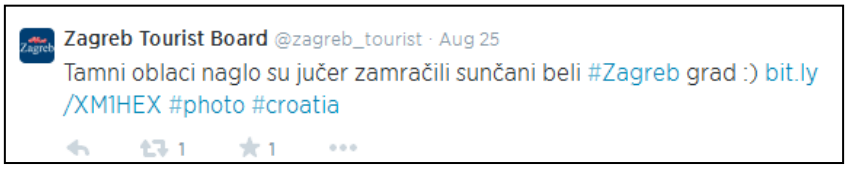

Slika 26 - Poruka na servisu Twitter.com

Slika prikazuje poruku na profilu Turističke zajednice grada Zagreba koja jednostavno objavljuje kako je jučer bilo oblačno i daje poveznicu na fotografiju koja to ilustrira. Teme same poruke naznačene su s 3 *hashtag*a (#Zagreb, #photo, #croatia). Twitter automatski sve riječi koje počinju znakom „#“ pretvara u link te se slijeđenjem te poveznice dobivaju najrecentnije poruke na servisu označene tim *hashtag*om. Na taj način omogućeno je grupiranje svih poruka na jednoj URL adresi (https://twitter.com/hashtag/zagreb). Osim grupiranja, korisnici imaju mogućnost pretplaćivanja na određeni *hashtag* kako bi im sve poruke koje su označene nekom temom odmah došle na njihov profil. Sam servis Twitter preporučuje ne više od dva *hashtaga* u jednoj poruci, kao i dodavanje samo relevantnih oznaka samoj poruci, kako bi se izbjegle *spam* poruke, kojima je cilj pojaviti se što češće u pretragama bez povezanosti za samu temu rasprave.

Iako koristi korisničke oznake kao i servisi koje smo analizirali u prošlim poglavljima, korištenje *hashtaga* unutar Twitter servisa ima dvojaku ulogu. S jedne strane, ima klasičnu ulogu korisničke oznake: anotira sadržaj, omogućuje dijeljenje s drugim korisnicima te sudjeluje u stvaranju folksonomije. S druge strane, zbog same prirode Twittera, gdje su interakcije između korisnika mnogo intenzivnije i brže, prihvaćanjem nekog *hashtaga* korisnik može izraziti zanimanje za temu ili pripadnost nekoj zajednici ili oboje. Twitter je primjer kako korisničke oznake ne moraju biti samo metoda organizacije sadržaja već mogu imati i društvenu ulogu, gdje služe kao mehanizam sudjelovanja u mrežnim raspravama ili pripadanja željenim virtualnim zajednicama (Yang et al.).

3. Korisničko označivanje kao metoda organizacije znanja u Web 2.0 okruženju

Prethodna su poglavlja dala širi kontekst samoj problematici korisničkih oznaka, od smještanja u širi kontekst predmetnog pristupa informacijama, preko pregleda novih izazova organizacije znanja u mrežnom okruženju, pa do pregleda utjecajnih mrežnih servisa koji koriste korisničke oznake kao metodu organizacije sadržaja.

Pojavom društvenog weba i niza povezanih korisničkih servisa predstavljenih u prethodnim poglavljima, pojavio se novi val korisničkog sudjelovanja u kreiranju i korištenju mrežnih izvora, te su potaknuti novi pristupi u organizaciji mrežnih izvora temeljeni na ideji korisničkog označivanja sadržaja. Mogućnosti koje nudi takav novi i alternativni pristup problematici organizacije informacija nisu zanemarive i glavni su pokretač rasprava koje su se intenzivno počele voditi oko pitanja do koje mjere društveno označivanje može doprinijeti poboljšanju predmetnog označivanja i organizacije informacija te na taj način usavršiti postojeće sustave za pretraživanje i pristup informacijama. Osnova implementacije korisničkog označivanja temelji se na ideji mudrosti mnoštva (Surowiecki, 2005). Promotrimo li četiri osnovne pretpostavke u svjetlu korisničkog označivanja, možemo zaključiti kako takav pristup ispunjava sva četiri osnovna uvjeta:

1. ***raznolikost mišljenja*** – svaki korisnik sustava opisuje resurse iz svoje perspektive i time daje svoj pogled na rješavanje problema pronalaženja i pretrage
2. ***neovisnost članova*** – svaki član zajednice sam odlučuje o dodanim oznakama, neovisno o drugim članovima
3. ***decentralizacija*** – proces opisivanja i organizacije korisničkim oznakama potpuno je decentraliziran, primjenjujući *bottom up* metodu organizaciji informacija
4. ***učinkovita metoda prikupljanja mišljenja*** – sustavi za korisničko označivanje su jednostavni i intuitivni, te omogućuju lako prikupljanje oznaka, dok prezentacija u obliku oblaka oznaka omogućava jednostavnu prezentaciju rezultata opisivanja.

Da nije riječ o marginalnoj ideji, pokazuju preporuke relevantnih i respektabilnih ustanova poput Kongresne knjižnice, čija Radna skupina u svojoj studiji o budućnosti bibliografske kontrole, nedvosmisleno preporučuje da knjižnice dopuste korisnicima dodavati oznake i druge podatke u katalog (Hill i Schottlaender, 2008).

3.1. Definicija korisničkog označivanja i prijevod temeljnih engleskih termina

Folksonomije su rezultat korisničkog označivanja (engl. *tagging*), koje je moguće opisati kao proces tijekom kojeg korisnici dodjeljuju ključne riječi zajednički korištenim sadržajima (Golder i Huberman, 2006), a ukupnost svih dodijeljenih oznaka unutar neke informacijske platforme kreira folksonomiju (Trant, 2009). Sam pojam folksonomije složen je od riječi „ljudi“ (engl. *folks*) i riječi „taksonomija“ (engl. *taxonomy*), upućujući na ideju korisničkog sudjelovanja u kreiranju sustava za označivanje i pretraživanje mrežne građe (Vander Wal, 2007). Sama terminološka primjerenost pojma još uvijek je predmet znanstvenih rasprava (Mathes, 2004), a Peters (2009) navodi iscrpan popis termina prisutnih u literaturi: „ethnoclassification", "communal categorization", "democratic indexing" (demokratsko označivanje), „mob indexing", "social classification system", "social indexing", "user-generated metadata", "collaborative tagging" (zajedničko označivanje), "social tagging" (društveno označivanje), "folksonomy" (folksonomija).

Istraživanjem literature pokazalo se kako se u radovima koristi nekoliko dominantnih termina za koje možemo reći da zadovoljavaju jamstvo uporabe, tj. da ih autori najčešće koriste u raspravama vezanima uz područje istraživanja korisničkog označivanja na engleskom jeziku i za koje je trebalo naći odgovarajući prijevod. Uz te pojmove postoji i nekoliko povezanih pojmova čija se rješenja prijevoda i definicije donose u Tablici 2.

.

Tablica 2 - Prijevodi temeljnih engleskih termina vezanih uz područje korisničkog označivanja

ENGLESKI TERMIN	HRVATSKI PRIJEVOD
Tag	**Korisnička oznaka** – informacija dodana nekome ili nečemu u svrhu identifikacije ili dodavanja neke druge informacije
Tagging	**Korisničko označivanje** – postupak organiziranja elektroničkih sadržaja koji čine korisnici, tako da se ti sadržaji indeksiraju/kategoriziraju ad hoc dodijeljenim ključnim riječima
Tag cloud	**Oblak korisničkih oznaka** – grafički prikaz dodijeljenih oznaka u kojem veličina slova odgovara frekvenciji oznake unutar skupa
Folksonomy	**Folksonomija** – cjelokupnost oznaka proizašlih iz postupka društvenog označivanja
Collaborative tagging (Social tagging)	**Društveno označivanje** – postupak organiziranja elektroničkih sadržaja, koji provodi više korisnika na način da se ti sadržaji indeksiraju/kategoriziraju ad hoc dodijeljenim ključnim riječima
Crowdsourcing	**Nabava iz mnoštva –** postupak u kojem se klasičan ljudski rad zamjenjuje članovima javnosti, gdje svaki član svojim malim doprinosom sudjeluju u ostvarivanju zajedničkog cilja

Postoje tek tri rada napisana na hrvatskom jeziku, koja se bave područjem korisničkog označivanja (Špiranec i Ivanjko, 2012; Špiranec i Ivanjko, 2013; Purgar-Kružić, 2012) te ćemo se na njih referirati u raspravi o terminologiji.

Oxfordski rječnik definira *tag* kao „oznaku dodanu nekome ili nečemu u svrhu identifikacije ili dodavanja neke druge informacije“ (engl. *label attached to someone or something for the purpose of identification or to give other information*), dok pojam *tagging* možemo odrediti kao „…postupak organiziranja elektroničkih sadržaja koji čine korisnici, tako da se ti sadržaji indeksiraju/kategoriziraju ad hoc dodijeljenim ključnim riječima.“ U engleskoj stručnoj literaturi za te oznake koristi se naziv *tag (*Purgarić-Kružić, 2012). Rad Špiranec i Ivanjko (2012) za termin *tag* koristi termin „korisnička oznaka“, dok za *tagging* koristi termin „korisničko označivanje.“ Dodavanjem pridjeva „korisničko“ naglašava se uloga korisnika koji ih dodjeljuju, te se termin specifičnije određuje čemu se priklanjamo i u ovoj disertaciji.

Rad Purgarić-Kružić (2012) donosi neka rješenja prijevoda ostalih temeljnih pojmova iz engleske literature. Autorica koristi dva temeljna termina na hrvatskom jeziku: „društveno/suradničko označivanje“ te „folksonomija.“ Termin „društveno/suradničko

označivanje“ označava skupni termin koji odgovara prijevodu više engleskih izvornih naziva (engl. *collective tagging, social tagging, user tagging, social indexing, shared tagging, collaborative tagging*), pod čime se podrazumijeva „…organizacijska metoda, tj. postupak organiziranja elektroničkih sadržaja koji čine korisnici, tako da se ti sadržaji indeksiraju/kategoriziraju ad hoc dodijeljenim ključnim riječima.“ Za taj isti pojam rad Špiranec i Ivanjko (2012) koristi termin „korisničko označivanje“, što je logična izvedenica termina koji se temelji na prijevodu termina *tag* kao „korisničke oznake.“ Treći ključni termin, *folksonomy*, u oba je rada preveden jednostavno kao „folksonomija“ pod čime se podrazumijeva „…cjelokupnost oznaka proizašlih iz postupka društvenog označivanja“ (Purgarić-Kružić, 2012). Problem tog prijevoda jest što termin *folksonomy* sadrži unutarnju logiku u engleskom jeziku, gdje se izmjenom prvog dijela riječi *tax* u *folk* (narod, puk) željelo naglasiti sudjelovanje korisnika u samom procesu dodavanja oznaka, dok se to u potpunosti gubi u hrvatskom prijevodu. Međutim, kako nemamo bolju riječ koja bi označavala taj pojam, a termin se javlja u hrvatskoj literaturi, koristit ćemo ga mjestimice i u ovome radu.

3.2. Pregled istraživanja korisničkog označivanja u literaturi

Pregled istraživanja izveden je u nekoliko komplementarnih faza, kako bi se osiguralo pronalaženje najvećeg mogućeg broja relevantnih radova najutjecajnijih autora te se dijelom temelji i na radu Lasić-Lazić, Špiranec i Ivanjko (2014). Kako je polje istraživanja relativno novo, s još neriješenim terminološkim i teorijskim problemima, u prvoj fazi pristupilo se identificiranju ključnih termina koje autori koriste u literaturi, te se na temelju toga poduzela webometrijska analiza njihovog korištenja, kako bi se osiguralo jamstvo uporabe samih termina u stručnoj literaturi te pružila osnova za pretragu bibliografskih baza podataka. Nakon identificiranja temeljnih koncepata, pretragom relevantnih baza podataka u području pokušalo se uvidjeti koliko je područje istraživanja zastupljeno u literaturi, tj. koliki se broj radova u relevantnim i recenziranim publikacijama bavi područjem društvenog označivanja u polju informacijskih znanosti čime se pokazalo koliko je područje istraživanja uopće relevantno unutar polja. Nakon kvantitativne identifikacije radova, pristupilo se pronalasku najutjecajnijih autora unutar područja korištenjem kocitatne analize. Nakon identifikacije ključnih autora i tema, na kraju pregleda istraživanja analizom sadržaja prikupljenih radova kreiran je okvir istraživanja u kojem se daje prikaz kategorija istraživanja, tema kojima se istraživanja bave, te primjera radova u kojima su takva istraživanja poduzeta.

Ovakav pregled literature, koji kombinira kvantitativne pristupe webometrije i bibliometrije sa kvalitativnim metodama analize sadržaja, pruža optimalnu metodologiju pronalaska najutjecajnijih radova i autora u nekom polju istraživanja, neovisno o njegovom području, te je iskoristiv i izvan okvira ovoga rada.

3.2.1. Identificiranje ključnih termina

Od pojave samog termina *folksonomy* (Vander Wal, 2004), različiti autori pokušali su opisati polje istraživanja koristeći velik broj teorijskih koncepata, kako bi objasnili problematiku istraživanja. Peters (2009) navodi iscrpan popis termina prisutnih u literaturi: „*ethnoclassification*", "*communal categorization*", "*democratic indexing"* (demokratsko označivanje), „*mob indexing*", "*social classification system*", "*social indexing", "user-generated metadata", "collaborative tagging"* (zajedničko označivanje), "*social tagging*" (društveno označivanje), "*folksonomy*" (folksonomija). Kako je polje istraživanja relativno novo, logična je početna heterogenost određenja kada je u pitanju terminološka određenost samog polja istraživanja. Iako je svaki doprinos terminološkom određenju pojma dobrodošao u svjetlu teorije, kod praktičnih problema istraživanja literature velik broj jednakopravnih pojmova u širokoj upotrebi otežava pronalaženje relevantnih radova. Kada se tome doda i nužnost korištenja jednog pojma kod pisanja na hrvatskom jeziku, postavlja se pitanje koji od pojmova u literaturi treba odabrati kao primarni izvor prijevoda. Jedan od pristupa koji nam može koristiti je jamstvo uporabe, tj. korištenje onog termina koji koristi najveći broj autora i nalazi se u najvećem broju radova.

3.2.2. Webometrijska analiza ključnih pojmova

Kako bismo otkrili najčešće korišteni termin, a time i otkrili jamstvo uporabe tog termina, poduzeta je webometrijska analiza pronađenih termina. Pojam webometrija (engl. *webometrics*) prvi se put spominje u članku koji su objavili Almind i Ingwersen 1997. godine (Almind i Ingwersen, 1997). Želeći ispitati ideju kvantitativne analize mrežnih izvora, utemeljene na metodama informetrije (engl. informetrics) kao šireg polja istraživanja informacija, odredili su polje webometrije kao „…istraživanje svih oblika mrežne komunikacije koristeći informetriju ili druge kvantitativne metode“ (Almind i Ingwersen, 1997). Općeprihvaćenu definiciju webometrije kao: „…istraživanja kvantitativnih aspekata stvaranja i korištenja informacijskih resursa, struktura i tehnologija oslanjajući se na pristupe bibliometrije i informetrije“, donose Bjorneborn i Ingwersen (2004).

Jedan je od osnovnih oblika webometrijskih istraživanja mjerenje broja spominjanja određenih dokumenata ili pojmova u mrežnom okruženju, tj. mjerenje njihova web utjecaja (engl. *web impact*). Osnovna ideja iza mjerenja web utjecaja jest ideja da su neki dokument ili neki pojam utjecajniji ako se više puta spominju na mrežnim stranicama. Praksa takve evaluacije utjecaja nekog dokumenta, brojanjem koliko se često spominje, dolazi iz polja bibliometrije, točnije analize citata. U analizi citata, broj puta koliko je neki znanstveni članak citiran u referencama drugih članaka uzima se kao indikator utjecaja ideja istraživanja koja su u njemu opisana. Tako se analizom citata dolazi do faktora utjecaja (engl. *impact factor*) nekog autora: što su autorovi radovi više citirani, njegov je utjecaj veći (Borgman i Furner, 2002). Slična ideja stoji i iza analize web utjecaja autora: što je rad nekog autora spominjaniji u mrežnom okruženju, to je njegov utjecaj veći. Ako želimo ispitati utjecaj neke ideje, dokumenta, pojma ili autora u mrežnom okruženju, mjerenje web utjecaja preko mrežnog spominjanja (engl. *web mentions*), jedan je od načina na koji to možemo saznati. Osnovna je metoda upisivanje pojmova čiji utjecaj želimo mjeriti, i uspoređivanje broja vraćenih rezultata, kako bismo dobili najspominjaniji, a time i najčešće korišteni pojam ili ideju.

Koristeći metodologiju i pristup webometrije, pomoću alata *Webometric Analyst 2.0* (http://lexiurl.wlv.ac.uk), provedena je analiza web spominjanja (engl. *web* mentions) za svaki od pojmova koje Peters (2009) navodi kao prisutne u literaturi. Tablica 3 donosi rezultate za svaki od pojmova te broj njegovih pojavljivanja na webu unutar različitih mrežnih sjedišta[1].

Tablica 3 - Analiza web spominjanja teorijskih termina prisutnih u literaturi

POJAM	BROJ POJAVLJIVANJA
folksonomy	**575**
user-generated metadata	**473**
social tagging	**453**
collaborative tagging	**298**
social classification system	**240**
social indexing	**188**
ethnoclassification	**166**
democratic indexing	**51**
mob indexing	**50**
communal categorization	**40**

[1] Čest je slučaj da se isti pojam pojavljuje više puta unutar jednog sjedišta, te kako bi rezultati bili kvalitetniji svako se pojavljivanje na web stranici unutar istog sjedišta broji samo jednom.

Kao što je vidljivo iz rezultata, najčešće spominjani termin je *folksonomy*, dok značajni broj rezultata bilježe i *user-generated metadata, social tagging, collaborative tagging, social classification system, social indexing* i *ethnoclassification*.
Detaljnijom analizom dokumenata u kojima su pojmovi pronađeni, pokazalo se kako pojmovi *social classification system, social indexing i ethnoclassification* javljaju velik broj „lažnih“ rezultata, pojavljujući se u radovima i kontekstu potpuno nevezanim za područje istraživanja[2], te su na temelju toga isključeni iz daljnje pretrage literature.

3.2.3. Identifikacija ključnih autora i radova

Rezultati webometrijskog istraživanja dali su nam četiri temeljna termina za koje možemo reći da zadovoljavaju jamstvo uporabe, tj. da se često koriste u raspravama vezanima uz područje istraživanja korisničkog označivanja na engleskom jeziku: *folksonomy, user-generated metadata, social tagging, collaborative tagging*. Koristeći te pojmove, kreiran je Booleov upit („folksonomy“ OR "social indexing" OR "social tagging" OR "user-generated metadata" OR "collaborative tagging"), kojim se željelo pokriti sve relevantne koncepte i time pronaći najveći mogući broj relevantnih radova o temi.
Koristeći takav upit, pretražene su dostupne relevantne baze podataka za područje informacijskih znanosti:

- Web of Science (http://wokinfo.com/products_tools/multidisciplinary/webofscience/),
- SCOPUS (http://www.info.sciverse.com/scopus).

Uz pretragu dvije najveće dostupne bibliografske baze iz područja, u pretragu literature uključen je i Google Scholar (http://scholar.google.com) kako bi se dobila šira baza radova osim onih objavljenih u časopisima s visokim faktorom utjecaja, kao što su knjige ili zbornici radova znanstvenih konferencija (Harzing, 2008). Za pretragu i analizu podataka dobivenih iz baze Google Scholar, korišten je softver Publish or Perish 4 (http://www.harzing.com/pop.htm).

Tablica 4 prikazuje sumirane podatke za svaki od bibliografskih izvora.

[2] Pojmovi su pronađeni primarno u radovima s područja sociologije, etnologije i lingvistike, označujući koncepte koji su potpuno različiti od istraživačkog problema kojim se bavi ovaj rad.

Tablica 4 - Broj radova i citata vezanih za područje društvenog označivanja u relevantnim bibliografskim bazama

IZVOR	BROJ RADOVA	BROJ CITATA
WOS	**346**	**2660**
SCOPUS	**1581**	**8848**
GOOGLE SCHOLAR	**1000+**	**31234**

Kao što rezultati pokazuju, postoji značajan broj radova koji se bave problemima društvenog označivanja unutar polja informacijskih znanosti. Očekivano je najmanji broj radova pronađen u bazi Web of Science (346), koja sadrži časopise s najvećim faktorom utjecaja, zatim u bazi SCOPUS (1581), te na kraju u bazi Google Scholar. Kako je softver *Publish or Perish 4*, kojim su se prikupljali podaci za bazu Google Scholar, ograničen na 1000 pogodaka, nije se mogao izračunati točan broj radova prisutnih u toj bazi. Kako bi se dobio uvid u najutjecajnije radove iz WOS-a i SCOPUS-a, uspoređeno je 20 najcitiranijih radova iz obje baze. Rezultati se nalaze u Tablici 5.

Tablica 5 - Radovi citirani u bazama WOS i SCOPUS prisutni u prvih dvadeset najcitiranijih u obje baze

AUTORI	NASLOV	WOS	SCOPUS
Golder i Huberman	*Usage patterns of collaborative tagging systems*	465	804
Mika[3]	*Ontologies are us: A unified model of social networks and semantics*	191	308
Hotho et al.	*Information retrieval in folksonomies: Search and ranking*	160	220

[3] Rad *Ontolgies are us* prisutan je u bazama WOS i SCOPUS u dvije neznatno različite verzije (rad sa konferencije iz 2005. godine prerađen je kao članak u časopisu 2007. godine), ali kako oba rada dijele iste osnovne pojmove i ideje, s intelektualne točke gledišta smatran je kao jedan rad.

Boulos, Kamel i Wheeler	*The emerging Web 2.0 social software: an enabling suite of sociable technologies in health and health care education*	138	264
Li, Snoek i Worring	*Learning Social Tag Relevance by Neighbor Voting*	38	78
Sinclair i Cardew-Hall	*The folksonomy tag cloud: when is it useful?*	38	91

Iz tablice vidimo kako je od dvadeset najcitiranijih radova samo njih šest prisutno u obje bibliografske baze, što pokazuje određenu heterogenost u istraživanjima. Ako tu uzmemo u obzir i Google Scholar, samo su tri članka među dvadeset najcitiranijih (*Usage patterns of collaborative tagging systems* (2158); *Information retrieval in folksonomies: Search and ranking* (725); *Ontologies are us: A unified model of social networks and semantics* (619)).
Ako želimo izdvojiti najutjecajniji rad, to je svakako rad *Usage patterns of collaborative tagging systems* (Golder i Huberman, 2006) koji je privukao daleko najviše citata u sve 3 bibliografske baze.

3.2.4. Kocitatna analiza radova

Kako bismo dobili uvid i u ostale utjecajne radove i autore koji se bave istraživanjem društvenog označivanja, u nastavku je provedena kocitatna analiza radova pronađenih u bazama WOS i SCOPUS. Kocitatna analiza jedna je od osnovnih bibliometrijskih metoda, kojom možemo identificirati utjecajne autore i radove u nekom polju, stvaranjem povezane mape utjecajnih autora najcitiranijih u nekom području (White i McCain, 2009).
Iz baze SCOPUS analiziran je ukupno 1581 članak s ukupno 8848 citata (Tablica 4). Analiza je provedena specijaliziranim alatom Bibexcel (http://www8.umu.se/inforsk/Bibexcel/), razvijenim od strane Olle Perssona za potrebe analiziranja velikih količina bibliografskih

podataka (Persson, Danell i Wiborg Schneider, 2009). Bibexcel je korišten za obradu podataka, dok je Pajek (http://pajek.imfm.si/doku.php) korišten za vizualizaciju (Batagelj i Mrvar, 2003).

Slika 27 pokazuje graf kocitata radova iz SCOPUS-a, gdje veličina kruga prikazuje broj citata koje je neki rad privukao, dok debljina linija koje ih povezuju prikazuje broj kocitata među radovima. Kako bi se smanjila kompleksnost vizualizacije, prikazane su veze između autora sa minimalno 20 kocitata.

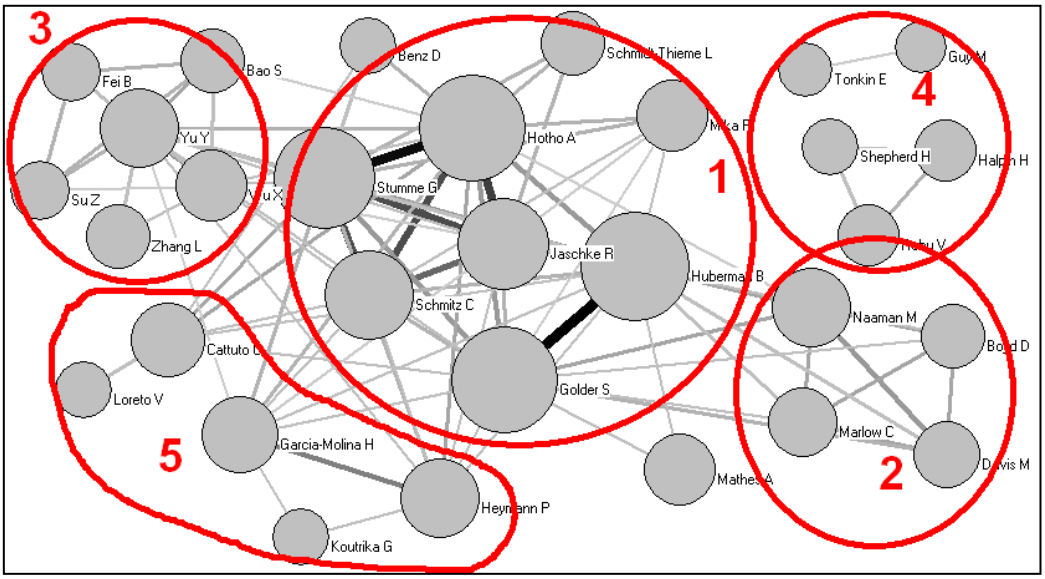

Slika 27 - Graf kocitata baziran na 8848 citata radova iz baze SCOPUS

Kako vidimo iz vizualizacije, možemo razlikovati 5 glavnih klastera autora povezanih velikim brojem kocitata. Opet, u središtu se nalaze autori koje smo identificirali kao najutjecajnije i u prethodnim analizama (Golder i Huberman; Hotho, Jäschke, Schmitz i Stumme), a koje povezuje i najveći broj kocitata (klaster 1). Zatim možemo izdvojiti tri klastera autora na marginama centralnog klastera (2, 3, 5), koji imaju jake međusobne veze kao i jake veze sa centralnim klasterom. I na kraju, u klasteru 4 vidimo autore koji imaju veliki broj kocitata, ali međusobnih, bez snažnog referenciranja na njihove radove od strane trećih autora.

Ova analiza otkrila je neke nove autore koje nismo vidjeli u prijašnjim analizama (Marlow et al. (*HT06, tagging paper, taxonomy, Flickr, academic article, to read*) i Xu et al. (*Exploring folksonomy for personalized search*)), ali i potvrdila ranije analize, odnosno utjecaj gore spomenutih autora.

Jedna od mogućnosti kocitatne analize, osim kreiranja mape utjecajnih autora i radova u nekom području, također je i identifikacija razvijanja polja istraživanja prema vremenu objave

najcitiranijih radova. Takva kocitatna analiza koja je uzela u obzir i vremensku komponentu nastanka rada, provedena je na 2660 citata dobivenih od 346 radova iz baze WOS (Tablica 4). Slika 28 prikazuje najcitiranije radove i skraćeni podatak o mjestu objavljivanja poredanih na vremenskoj crti. Kao i u prethodnoj analizi, veličina kruga prikazuje broj citata koje je neki rad privukao, dok debljina linija koje ih povezuju prikazuje broj kocitata među radovima.
Kako bi se smanjila kompleksnost vizualizacije, prikazane su veze između autora s minimalno 10 kocitata.

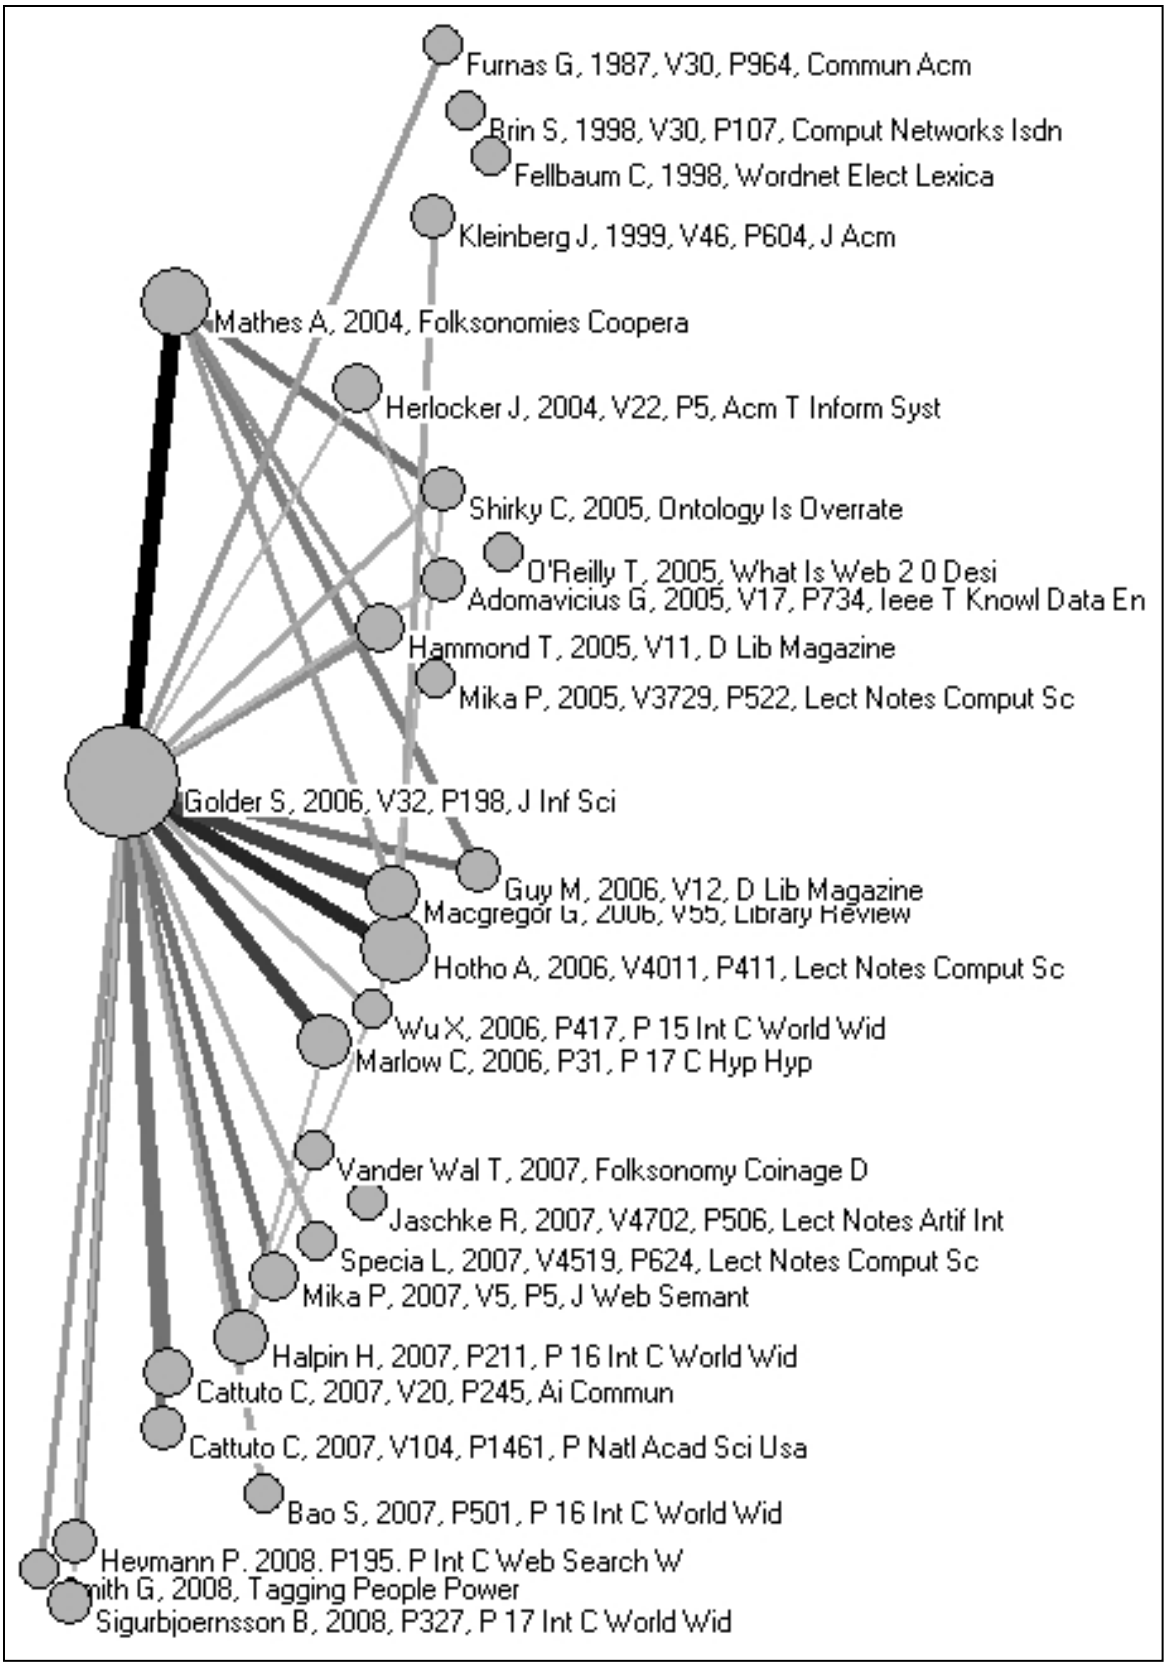

Slika 28 - Graf kocitata baziran na 2668 citata radova iz baze WOS sa dodanom vremenskom komponentom i časopisom u kojem je objavljen rad

Kako je vidljivo iz vizualizacije, dva su temeljna rada koja privlače veliki broj kocitata. Kao jedan od radova kojim je započeo razvoj polja istraživanja, izdvaja se rad Mathesa iz 2004. godine (*Folksonomies-cooperative classification and communication through shared metadata*) u kojem autor daje pregled osnovne istraživačke problematike, ali i raspravlja o osnovnoj terminologiji istraživanja, te predlaže termin *folksonomy* kao temeljni pojam kojim opisuje polje istraživanja. Drugi rad je opet rad autora Golder i Huberman (*Usage patterns of collaborative tagging systems*) koji daje teorijsku podlogu i strukturu proučavanja polju istraživanja, i ponovno se potvrđuje kao najutjecajniji rad u području. Ovakav prikaz, koji uključuje i vremensku komponentu objavljivanja, pruža dobru podlogu za početak istraživanja, navodeći tridesetak temeljnih radova iz područja. Analiza podataka o tome u kojem je časopisu neki rad objavljen, pokazuje kako je najveći broj radova objavljen u časopisima s područja informacijskih znanosti i knjižničarstva. Kako je primarno znanstveno polje ove disertacije knjižničarstvo, u nastavku se donosi sadržajna analiza radova samo iz tog područja.

3.2.5. Sadržajna analiza radova i definiranje okvira istraživanja

Kao što smo već pokazali u prijašnjim analizama (Tablica 3), rezultati webometrijskog istraživanja dali su nam četiri temeljna termina za koja možemo reći da zadovoljavaju jamstvo uporabe, tj. da se često koriste u raspravama vezanima uz područje istraživanja korisničkog označivanja na engleskom jeziku: *folksonomy*, *user-generated metadata*, *social tagging*, *collaborative tagging*. Koristeći te pojmove, ponovno je kreiran Booleov upit („folksonomy“ OR "social indexing" OR "social tagging" OR "user-generated metadata" OR "collaborative tagging"), kojim se željelo pokriti sve relevantne koncepte i time pronaći najveći mogući broj relevantnih radova o temi.

U istraživanje su uključena četiri različita izvora koja su smatrana najrelevantnijima za područje knjižničarstva:

- Web of Science (http://wokinfo.com/products_tools/multidisciplinary/webofscience/)
- SCOPUS (http://www.info.sciverse.com/scopus)
- LISTA (http://www.ebscohost.com/academic/library-information-science-technology-abstracts-lista)
- Google Scholar (http://scholar.google.com).

Tablica 6 pokazuje skupne rezultate pretraživanja zajedno sa postavljenim ograničenjima pretrage.

Tablica 6 - Izvori uključeni u pregled literature

SUČELJE	BAZA	POLJA PRETRAGE	PREDMETNO PODRUČJE	BROJ RADOVA
SCOPUS	SCOPUS	NASLOV-SAŽETAK-KLJUČNE RIJEČI	DRUŠTVENE ZNANOSTI	**267**
WOS	SCI-EXPANDED, SSCI, AandHCI	TEMA	KNJIŽNIČARSTVO	**119**
EBSCOHOST	LISTA	PREDMETNICE	KNJIŽNIČARSTVO	**71**
POP 4 SOFTWARE	GOGLE SCHOLAR	SVE	SVE	**1000+**

Inicijalna pretraga baze SCOPUS vratila je 275 radova. Međutim, zbog nemogućnosti baze da se pretraga ograniči samo na polje knjižničarstva, bilo je potrebno pregledati svaki od dobivenih rezultata. Pregledom se ustanovilo kako postoji određeni broj radova iz područja lingvistike u kojima se pojam "social indexing" koristi u potpuno različitom kontekstu, te su isključeni iz daljnje analize. Uz baze SCOPUS, WOS i LISTA, u pretragu je uključena i baza Google Scholar (http://scholar.google.com), kako bi se dobila šira baza radova osim onih objavljenih u časopisima s visokim faktorom utjecaja, kao što su knjige ili zbornici radova znanstvenih konferencija (Harzing, 2008). Za pretragu i analizu podataka dobivenih iz baze Google Scholar, korišten je softver Publish or Perish 4 (http://www.harzing.com/pop.htm). Kako je softver *Publish or Perish 4*, kojim su se prikupljali podaci za bazu Google Scholar, ograničen na 1000 rezultata, nije se mogao izračunati točan broj radova prisutnih u toj bazi. Dok je citiranost glavni element rangiranja utjecaja članaka u standardnim bibliografskim bazama, neki radovi pokazuju kako, iako se Google Scholar oslanja na citiranost autora, najbolje rangirani radovi vraćeni pretragom nisu nužno i oni najcitiraniji (Beel i Gipp, 2009). Iz tog razloga, u uzorak analize obuhvaćeno je prvih dvadeset radova iz baze Google Scholar prema rangu i prema citiranosti.

Nakon što su iz dobivenih rezultata iz Tablice 4 izbačeni duplikati te radovi koji nisu na engleskom jeziku, dobiven je konačni uzorak od 345 radova iz sve 4 baze.

Početna točka kreiranja okvira pregleda istraživanja trodijelna je analiza strukture društvenog označivanja, provedena u radovima Trant (2008) i Peters (2009), kojima su identificirana tri aspekta istraživanja: (1) oznake, (2) korisnici i (3) izvori. Tijekom analize, početne kategorije su prilagođene tijelu literature, te je dodana i kategorija „Općenite studije“ u koju su pobrojani svi radovi koji daju generalni uvod u područje istraživanja. Kako se značajan broj radova bavi s više od jednog aspekta, kategorije nisu ekskluzivne, već je jedan rad mogao biti dodijeljen u više kategorija. Konačne kategorije za analizu bile su:

(1) **Općenite studije** – uvodni radovi koji obrađuju temu društvenog označivanja unutar šireg područja proučavanja društvenog softvera
(2) **Istraživanje oznaka** – radovi koji proučavaju modele, strukturu, kategorizaciju te semantičke i lingvističke aspekte oznaka
(3) **Istraživanje korisnika** – radovi koji proučavaju korištenje društvenog označivanja unutar različitih okruženja (obrazovanje, istraživanje) ili sustava (npr. Flickr, Delicious)
(4) **Istraživanje izvora** (poboljšanje pristupa) – radovi koji proučavaju upotrebu korisničkog označivanja kao metode poboljšanja pristupa, pretrage, navigacije ili personalizacije informacijskih sustava, kao i poboljšanja opisa i komplementiranja tradicionalnim sustavima za organizaciju znanja.

Tablica 7 daje pregled broja radova dodijeljenih prema kategorijama, uz dodane primjere radova koji se bave tim aspektom istraživanja društvenog označivanja.

Tablica 7 - Kategorizacija radova koji se bave društvenim označivanjem u području knjižničarstva, temeljena na 345 radova iz baza SCOPUS, WOS, LISTA i Google Scholar

KATEGORIJA	PRIMJER RADOVA	BROJ RADOVA
OPĆENITE STUDIJE	Quintarelli (2005)	**40**
ISTRAŽIVANJE OZNAKA	Golder i Huberman (2006)	**113**
ISTRAŽIVANJE KORISNIKA	Kipp i Campbell (2010);	**111**
ISTRAŽIVANJE IZVORA (POBOLJŠANJE PRISTUPA)	Mika (2005)	**193**

Osim drugačijih pristupa i tematike, radovi koji pripadaju različitim kategorijama također su pridonijeli na nekoliko različitih načina. Općeniti radovi, koji obrađuju temu korisničkog označivanja, bave se uvodom u područje istraživanja smještaju temu društvenog označivanja unutar šireg područja proučavanja društvenog softvera, te tako određuju njene granice istraživanja. Daljnji radovi koji se bave istraživanjem oznaka samom području istraživanja daju strukturu, te produciraju modele i okvire unutar kojih se istraživanja provode. Istraživanje korisnika dodaje još jedan važan element – razumijevanje motivacije, obrazaca ponašanja i korisnost društvenog označivanja unutar različitih okruženja, kao što je obrazovno akademsko ili daje uvid u korisnike određenih servisa ili alata poput Flickra ili Deliciousa

Međutim, svaki od tih aspekata proučavanja komplementaran je krajnjem cilju većine istraživanja – kako iskoristiti korisničko označivanje kao metodu poboljšanja pristupa, pretrage, navigacije ili personalizacije informacijskih sustava, kao i poboljšanja opisa i komplementiranja tradicionalnim sustavima za organizaciju znanja. Pregled radova koji spadaju u tu kategoriju pokazuje kako se društveno označivanje pokušava iskoristiti na nekoliko načina.

Prvi pristup istražuje na koji način oznake mogu poboljšati učinkovitost sustava za pretraživanje, bilo korištenjem oznaka kao sredstvo navigacije unutar korisničkog sučelja kao metodu poboljšanja rezultata pretrage ili kao osnovu za razne preporučne sustave

Druga vrsta radova istražuje potencijal korisničkih oznaka u sustavima za označivanje, kao metodu komplementarnu standardnim metodama organizacije znanja. Glavna pitanja koja se ovdje istražuju usmjerena su na potencijal korisničkih oznaka kao alternativne metode predmetnog opisa, ili kako bi se standardne metode opisa od strane predmetnih stručnjaka dopunile i poboljšale upotrebom stvaranog korisničkog rječnika u svrhu ostvarivanja korisničkog jamstva unutar sustava predmetne obrade (Rolla, 2009).

I na kraju imamo i treći pristup, izraženiji u radovima s područja računalnih znanosti, u kojima se korisničko označivanje promatra kao pogodan sustav na kojem je moguće graditi složenije odnose poput ontologija na putu prema okruženju semantičkog weba.

3.3. Struktura folksonomije

Struktura folksonomije definirana je u literaturi (Mika, 2005; Peters, 2009; Marlow et al., 2006; Halpin, Robu i Shepherd, 2007) pomoću tri glavna elementa:

(1) **izvori** – sadržaj koji se označuje korisničkim oznakama
(2) **korisnici** – subjekti koji označavaju sadržaj
(3) **korisničke oznake** – slobodno oblikovane ključne riječi nastale kao rezultat korisničkog označivanja.

Iako se ti elementi često različito nazivaju u samoj literaturi, njihov odnos i semantika uvijek su isti: jedan ili više korisnika (ljudi ili agenti) opisuju izvore (objekte ili instance) s jednom ili više korisničkih oznaka (ključnih riječi, opisa). Tako se u odnosu „oznake-korisnici-izvori" kreira polje značenja korisničkog označivanja.

Pojam ***izvora*** odnosi se na sve što unutar nekog sustava korisničkog označivanja može biti označeno. U literaturi se pod tim pojmom javljaju termini sadržaj, informacija, dokument, objekt, entitet ili instanca (Tonkin et al., 2008; Golder i Huberman, 2006; Gruber, 2007; Mika, 2005; Peters, 2009). U konačnici, sustav odlučuje što može biti izvor, bio to mrežni izvor (npr. Delicoius), ili specifičan tip izvora poput slike (npr. Flickr), videa (npr. Youtube) ili knjiga (npr. LibraryThing)

Pojam ***korisnika*** odnosi se na subjekte koji dodaju korisničke oznake unutar nekog sustava. Termini koji se pojavljuju u literaturi su još i agent ili *tagger* (Mika, 2005; Gruber, 2007). Korisnici najčešće koriste servise za korisničko označivanje kako bi prikupili određene izvore, te ih opisali radi kasnijeg pronalaženja (npr. Delicious), ili i sami mogu biti autori izvora te ih tada opisuju kako bi ih drugi korisnici lakše pronašli (npr. Flickr, Youtube). U samom procesu korisnici sudjeluju kreiranjem korisničkih računa, osobnog prostora na servisu u kojem komuniciraju, kako sa sadržajima na servisu, tako i sa drugim korisnicima.

Pojam ***korisničke oznake*** odnosi se na slobodno oblikovane ključne riječi koje korisnici dodaju izvorima. Korisnička oznaka može biti bilo kakav niz znakova, imao on neko značenje ili ne. Sam proces dodavanja oznaka uvijek je u nekoj mjeri upravljan samim sustavom, bilo da se navode kratke upute (npr. „odvojite različite pojmove zarezom“) ili se daju preporučene oznake, tj. oznake koje su drugi korisnici najčešće dodali izvoru koji trenutno opisujemo. Sama oznaka može biti jedna riječ ili složeni izraz. Kako neki sustavi koriste razmak kao indikaciju odvajanja različitih oznaka, nekoliko je načina na koji se rješava taj problem. Jedan je stavljanje složenog izraza u navodnike („web 2.0“) ili spajanje dviju riječi (web2.0), drugi dodavanje donje crtice (web_2.0) ili povlake (web-2.0), a treći korištenje razmaka kao indikaciju nove oznake te se sve što je između dva razmaka smatra jednom oznakom. Naravno, kako je sam način rješavanja stvar konvencije unutar sustava, dolazi do različitih problema kada se dvije ili više konvencija koriste unutar istog sustava. Sustavi također često ograničavaju maksimalan broj korisničkih oznaka koje se mogu dodati jednom izvoru, pa je to kod servisa Delicous 50, dok Flickr ograničava broj oznaka na 75.

3.4. Formalni modeli folksonomija

Prihvaćena formalna definicija folksonomije u literaturi (Halpin, Robu, Shepherd, 2007; Abel et al., 2007; Cattuto et. al, 2007) glasi:

Folksonomija F je n-torka F = (U,T,R,Y),
gdje U označava set korisnika, T set oznaka, R set izvora, a Y odnose između njih

Najčešće se prikazuje kao model od tri međusobno povezana sloja (Vander Wal, 2005; Marlow et al., 2006; Peters, 2009; Halpin, Robu i Shepherd, 2007). Prilagođeni model na slici 29 prema Lohman (2013) ilustrira veze koje nastaju u procesu korisničkog označivanja, razlikujući eksplicitne veze, koje nastaju samim dodavanjem oznaka, te implicitne veze, kao što je npr. veza između dva korisnika koji opisuju isti resurs (npr. *u1* i *u2*) ili koriste istu oznaku (npr. *u3* i *u4*).

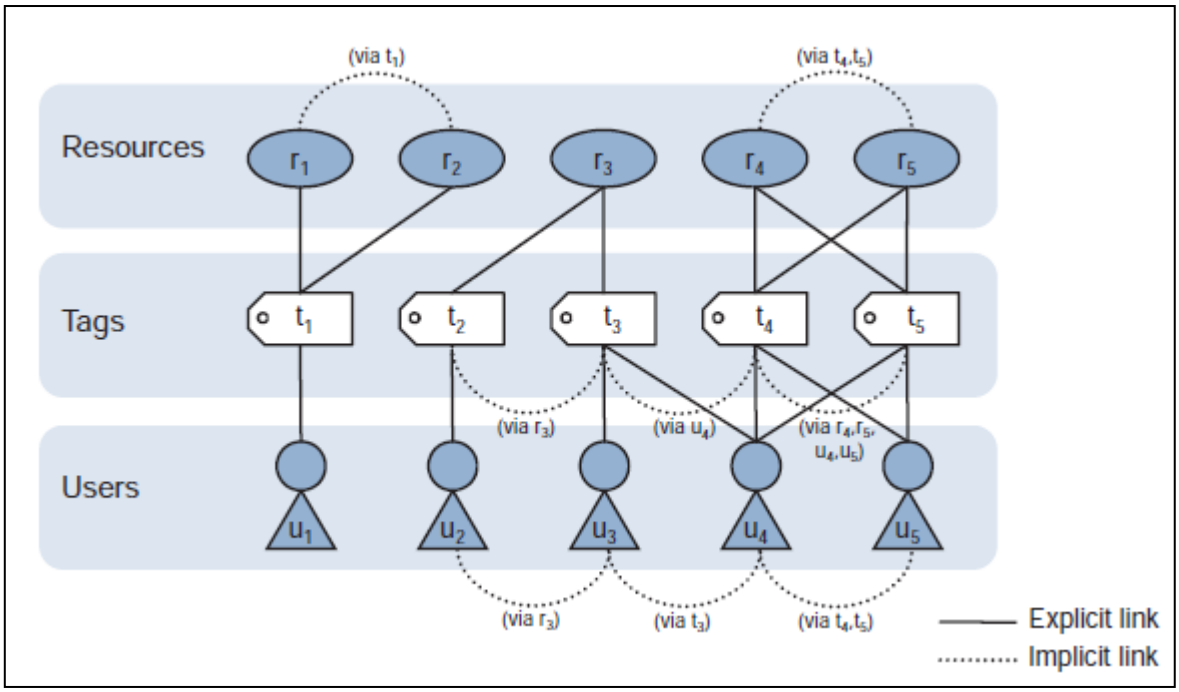

Slika 29 - Troslojni model folksonomije
(prema Lohman, 2013)

Peters (2009) daje pregled niza modela kojima se prikazuju odnosi unutar folksonomije. Osnovni model prikazuje kao tripartitni hipergraf, gdje su korisnici i izvori povezani međusobno unutar sustava, a korisničke oznake djeluju kao poveznice između njih (Slika 30).

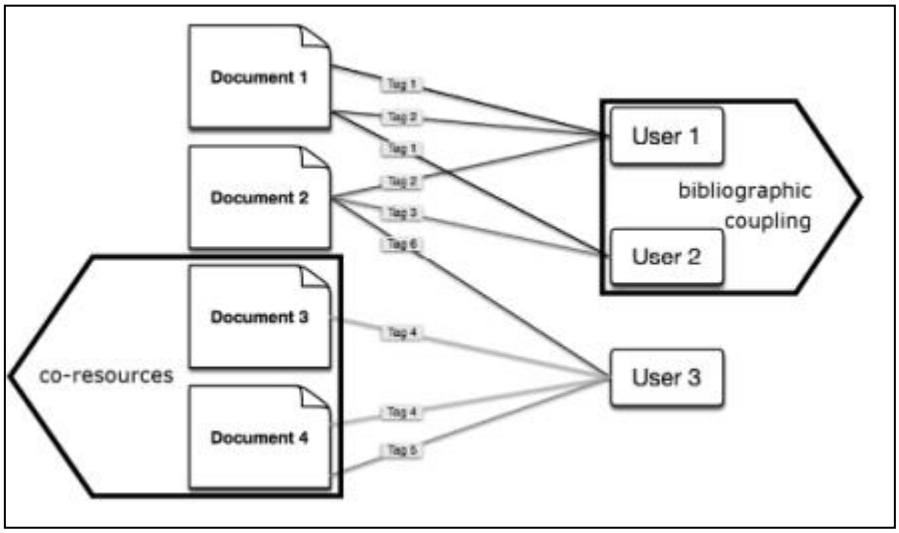

Slika 30 - Tripartitni hipergraf korisnika, izvora i oznaka
(prema Peters, 2009)

U ovom modelu, izvori (dokumenti) mogu biti povezani tematski (dijele istu oznaku, npr. Document 3 i Document 4) i preko korisnika (dva ili više korisnika opisuju isti izvor). Na isti

način, korisnici mogu također biti povezani tematski (ako koriste istu oznaku) ili bibliografski (ako opisuju isti izvor).

Tonkin et al. (2008) (prema Peters, 2009) daju tri komplementarna modela kojima se opisuje polje korištenja korisničkih oznaka. Rad koristi termin informacija koji se odnosi na termin resurs u dosad navedenim modelima.

Prvi model (Slika 31) stavlja naglasak na vezu između korisnika i informacije, a oznake naglašavaju na koji način korisnik shvaća informacije.

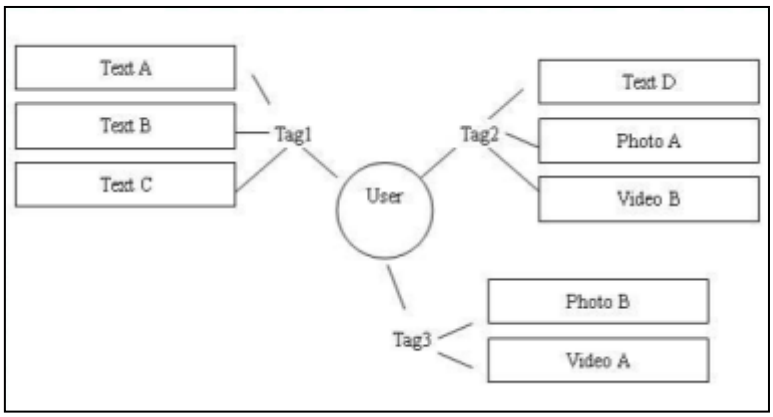

Slika 31 - Model korisnik-oznaka-informacija
(izvor Tonkin et al., 2008)

Drugi model (Slika 32) stavlja naglasak na odnose između korisnika, prikazujući načine na koji su sami korisnici povezani unutar sustava putem zajedničkih oznaka, tj. njihovu tematsku povezanost.

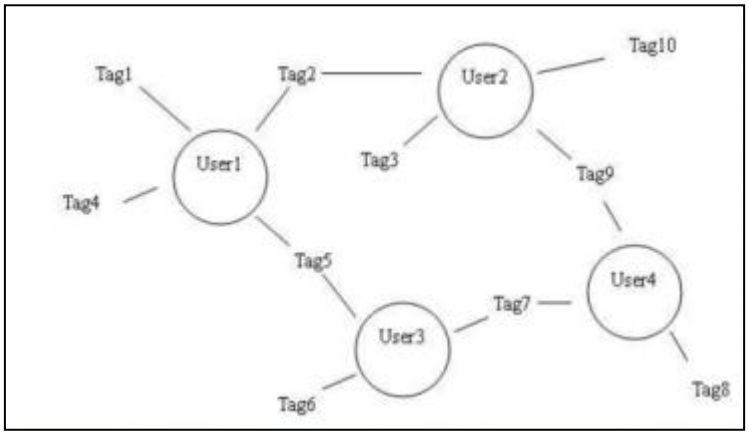

Slika 32 - Model korisnik-oznaka-korisnik
(izvor Tonkin et al., 2008)

Treći model (Slika 33) stavlja naglasak na veze između različitih izvora podataka, gdje oznake služe kao metapodaci koji eksplicitno izražavaju veze, te služe kao podloga za više instance zaključivanja poput ontologija (Peters, 2009).

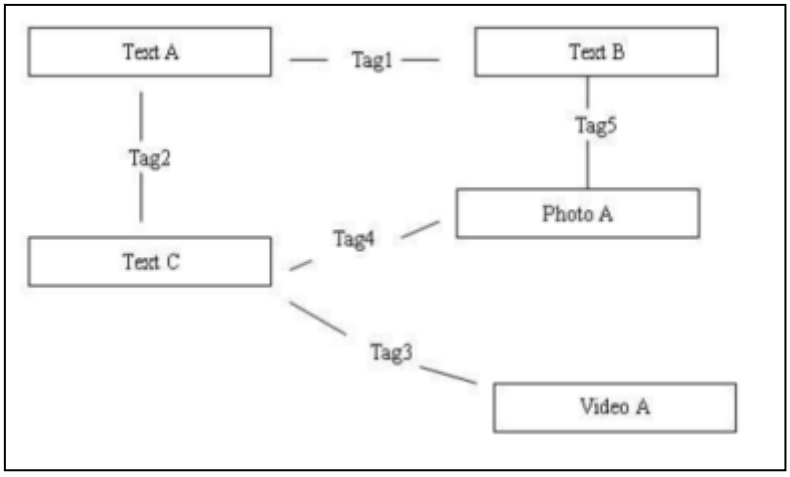

Slika 33 - Model informacija-oznaka-informacija
(izvor Tonkin et al., 2008)

Navedeni modeli prikazuju na koji način sustavi, koji koriste korisničko označivanje, pristupaju organizaciji i predstavljanju znanja unutar sustava. Cijeli sustav počiva na tome da u samom postupku označivanja i organizacije sudjeluje velik broj korisnika, te se „pročišćavanje“ sustava od nerelevantnih ili pogrešnih oznaka regulira demokratskom idejom glasovanja. Svaki put kada neki korisnik doda oznaku nekom izvoru, on zapravo daje svoj glas dodanom pojmu te povećava njegovu frekvenciju i relevantnost unutar sustava kao cjeline. Cijeli sustav ovisi o frekvenciji oznaka, gdje najčešće dodane oznake služe kao sustav preporučivanja i otkrivanja informacija, kao jedan od kritičnih momenata organizacije informacija u mrežnom okuženju (Peters, 2009).

Uz predstavljane modele, potrebno je dodati kako se u literaturi načelno razlikuju dvije vrste folksonomija: široke i uske. Vander Wal (2005) daje pregled oba pristupa (Slika 34).

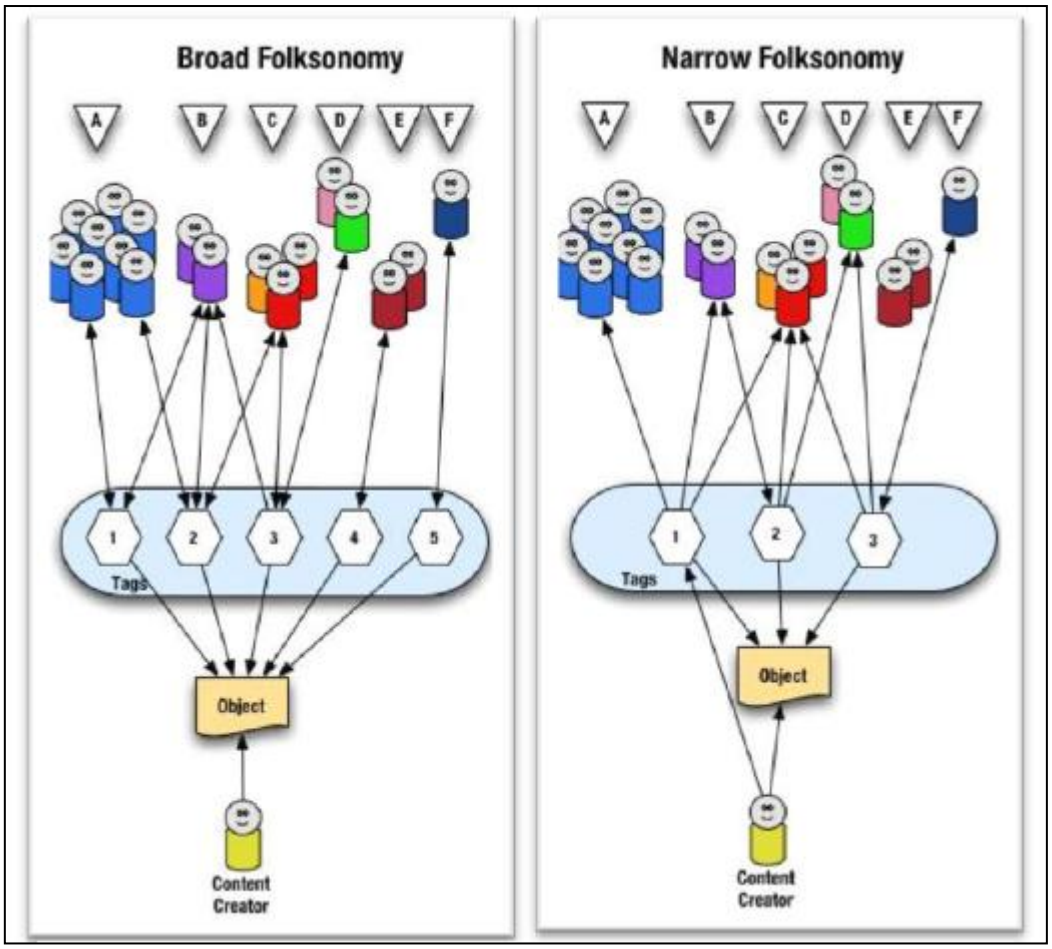

Slika 34 - Široke i uske folksonomije
(Vander Wal, 2005)

Dok je u širokoj folksonomiji jedan objekt opisan od strane većeg broja korisnika s više oznaka, u uskoj folksonomiji jedna oznaka može biti dodana samo jednom.

Iako se navedeni modeli mogu primijeniti na obje vrste folksonomija, u najvećem broju slučajeva, kada se govori o korisničkom označivanju u ovome radu, misli se na pristup upravljanja širokim folksonomijama u kojima veći broj korisnika može dodati istu oznaku više puta, a najpopularnije oznake dobivaju se frekvencijom pojavljivanja unutar sustava.

3.5. Proces korisničkog označivanja

Dok navedeni modeli daju prikladan teorijski model odnosa između korisnika, izvora i oznaka, potrebno je dodatno reći nešto i o samom procesu dodavanja korisničkih oznaka, tj. o tome kako korisnici dodaju oznake te koja je njihova motivacija.

Kako smo već raspravljali u prethodnim poglavljima, proces klasične predmetne obrade često se razdvaja na tri osnovna postupka (Chu, 2010; Foskett, 1996; Shatford, 1986):

(1) određivanje od čega se objekt sastoji (engl. *ofness*)
(2) određivanje o čemu govori poruka sadržana u samom objektu (engl. *aboutness*)
(3) pridruživanje ključnih riječi i termina informacijskom objektu predstavljajući od čega se sastoji (engl. *ofness*) i o čemu taj objekt govori (engl. *aboutness*) na niz različitih načina, pokušavajući ga povezati s predviđenom informacijskom potrebom korisnika.

Thøgersen (2012) daje pregled osnovnog procesa dodavanja korisničkih oznaka (Slika 35):

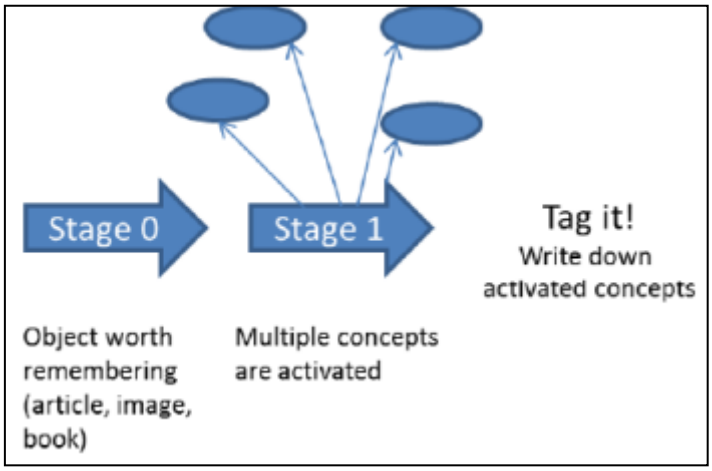

Slika 35 - Proces dodavanja korisničke oznake
(Thøgersen, 2012)

Kao što vidimo iz modela, sve počinje pronalaženjem izvora koji želimo označiti, odabira između različitih koncepata te na kraju dodavanja nekog od koncepata samom izvoru. Iako bismo letimičnim pregledom modela mogli zaključiti kako je proces dodavanja korisničkih oznaka uvelike sličan procesu indeksiranja, postoji nekoliko temeljnih razlika u pristupu.
Prva velika razlika je u agentu koji provodi samo označivanje – dok je to u tradicionalnom modelu predmetni stručnjak čija ekspertiza jamči kvalitetu opisa, u procesu korisničkog označivanja proces je decentraliziran te uspješnost opisa i organizacije ovisi o zajedničkim naporima cijele zajednice. Svaki korisnik dodaje svoje koncepte nekom objektu, a konačni konsenzus oko najboljih koncepata dobiva se „popularnošću“, tj. frekvencijom neke oznake.
Druga razlika je u samom rječniku koji se koristi kako bi se izrazili koncepti. Dok predmetni stručnjak svoje koncepte izražava na temelju kontroliranog rječnika, težeći time ujednačenosti opisa, kod korisničkog označivanja nema takvog ograničenja – što god korisnik smatrao prikladnom oznakom, može biti dio opisa samog izvora.

Treća temeljna razlika odnosi se na motivaciju svakog od agenta koji provodi opisivanje. Predmetni stručnjak opisuje izvor kako bi olakšao pristup te izabire koncepte kako bi omogućio najprikladnije pristupne točke potencijalnim korisnicima koji žele doći do određenog izvora, te mu je to jedina motivacija kojom se vodi kod opisa. Kod procesa korisničkog označivanja, omogućavanje pristupa drugima samo je jedna od mogućih motivacija koje neki korisnik ima u procesu dodavanja korisničkih oznaka.
Marlow et al. (2006) donose iscrpan popis motivacija kod dodavanja korisničkih oznaka:

1) buduće pronalaženje
2) doprinos i dijeljenje
3) privlačenje pažnje
4) igra i natjecanje
5) samoprezentacija
6) izražavanje mišljenja.

Kako, za razliku od predmetnog označivanja, dodjeljivanje oznaka ne zahtijeva predmetno znanje ili poznavanje konteksta, motivacija za dodavanje korisničkih oznaka često ovisi o samoj namjeri korisnika, gdje se razlozi zbog kojih korisnici nekog sustava dodaju korisničke oznake mogu promatrati iz dvije osnovne perspektive (Marvasti, 2008):

1) Osobna motivacija – korisnici dodaju korisničke oznake kako bi organizirali vlastite sadržaje u mrežnom okruženju i/ili kako bi ih lakše kasnije pronašli. U klasičnoj hijerarhijskoj strukturi organizacije (u npr. mapama dokumenata) korisnik se mora sjetiti logike same organizacije kako bi došao do nekog resursa (putem direktorija i poddirektorija), dok dodavanje ključne riječi samom izvoru (tj. korisničke oznake) omogućuje ponovno pronalaženje tog izvora putem pretrage.
2) Društvena motivacija – korisnici dodaju korisničke oznake kako bi doprinijeli organizaciji unutar sustava te dijelili izvore s drugim korisnicima.

Na tragu te podjele, govoreći o servisima za društveno označivanje, Golder i Huberman (2006) navode kako „tipično takve stranice omogućuju korisnicima dodavanje oznaka i dijeljenje sadržaja, te na taj način korisnici mogu ne samo organizirati vlastite izvore, već i pregledavati izvore koje su označili drugi korisnici.“ Takav pristup „društvenom pregledavanju“ (engl. *social browsing*) implementiran je u nizu servisa koji su pruženi kao

primjer u prethodnim poglavljima (npr. Delicious, Flickr, itd.), gdje se putem URL adrese na jednom mjestu okupljaju izvori koji su najčešće označeni izabranom oznakom, tvoreći tako popis najpopularnijih izvora unutar neke platforme. Okupljanjem najpopularnijih oznaka unutar sustava u oblak oznaka dodana je nova vrijednost otkrivanju informacija – privlačenje pažnje na popularne koncepte i teme koje korisnici pohranjuju ili opisuju unutar sustava.

3.6. Kategorije oznaka

Uz značajan broj radova koji su se bavili motivacijom iza dodjeljivanja korisničkih oznaka, veći broj radova bavio se i kategoriziranjem samih dodanih oznaka. Kategorizacija nam može otkriti svrhe za koje se oznake koriste, kao i identifikaciju određenih obrazaca označivanja (Peters, 2009).

U jednom od prvih istraživanja te vrste Mathes (2004), temeljem analize servisa Flickr i Delicious, utvrdio je 8 kategorija oznaka:

1) tehničke oznake (npr. RSS)
2) žanrovske oznake (humor)
3) samo-organizirajuće oznake (to-do),
4) oznake naziva mjesta (New York),
5) godine (2007),
6) boje
7) fotografski pojmovi (camera)
8) pojmovi koji se odnose na vlastito ja (oznake ega).

Golder i Huberman (2006) istražujući Delicious utvrdili su 7 kategorija:

1) tema (generički opisi koji opisuju očemnost (engl. *aboutness*))
2) tip (blog, članak)
3) vlasništvo (autor)
4) pridjevi (odražavaju mišljenje, npr. smiješno)
5) samoreferentne oznake koje opisuju odnos osobe koja označuje i izvora (npr. my_stuff)
6) organizacijske oznake koje opisuju buduće korištenje izvora (npr. to-read)

7) nesamostalne/relacijske oznake koje pobliže opisuju drugu i svoje značenje temelje na odnosu s drugom oznakom.

Heckner, Mühlbacher i Wolff (2008) proveli su empirijsku studiju temeljeći svoju analizu na ključnim riječima iz različitih sustava za organizaciju bibliografskih zapisa, te umjesto taksativnog nabrajanja kategorija oznaka, uspostavili model funkcionalne i lingvističke kategorizacije oznaka.
Model kategorizacije uključuje:

1) funkcionalne oznake: oznake koje pokrivaju one koje se odnose na sadržaj (očemnost) izvora i osobne oznake
2) lingvističke aspekte oznaka (pravopis, oblik i vrsta riječi)
3) redundantne oznake (oznake podudarne s dijelovima teksta).

U istraživanju korpusa oznaka na hrvatskom jeziku, Špiranec i Ivanjko (2012) pokazali su kako postoji velika podudarnost s tradicionalnim pomagalima u lingvističkoj formi (hrvatski jezik, imenice, nominativ, jednina). Na razini funkcionalne analize je, suprotno očekivanom, utvrđena mala zastupljenost osobnih/subjektivnih ili emotivnih oznaka koje omogućuju nove modele pretraživanja i pristupa informacijama, utemeljene na suradničkom načelu i preporučenim sustavima. Također, istraživanje je pokazalo da korisnici organiziraju informacije uglavnom prema predmetu/sadržaju te da su formalne karakteristike rijetko zastupljene. Drugim riječima, pojmovni korpusi najučestalije korištenih oznaka ne ukazuju na potrebu uvođenja neke nove vrste metapodataka poput osobnih ili subjektivnih, no upućuju na potrebu označivanja informacija prema sadržaju/predmetu, budući da sami korisnici informacije pretežito organiziraju prema predmetu.

Al-Khalifa i Davis (2007) pokušali su pružiti dodatnu razradu samih funkcionalnih oznaka pa razlikuju :

1) osobne oznake namijenjene privatnoj upotrebi
2) subjektivne oznake koje izražavaju korisničko mišljenje
3) činjenične oznake koje opisuju temu samog izvora.

Navedena i srodna istraživanja mahom su utvrdila novu vrstu oznaka, uglavnom nepoznatu postojećim predmetnim jezicima i kontroliranim rječnicima koji se rabe u informacijskoj

zajednici. Riječ je o oznakama koje su poput osobnih, u potpunosti razumljive samo osobama koje ih dodjeljuju, a opisuju budući postupak, poput oznaka „to_do“ ili „to_read.“ Kipp (2006) je u svom istraživanju utvrdila da ovaj novi tip oznaka zauzima velik postotak u ukupnoj količini oznaka sustava za društveno prikupljanje poveznica (Delicious, Connotea, CiteULike), iz čega je moguće zaključiti da su vrlo važni korisnicima. Zamjetna je i pojava oznaka koje također spadaju u subjektivne ili osobne oznake, a kroz koje korisnici izražavaju stav, mišljenje ili procjenu izvora ili neizravno komuniciraju s drugim korisnicima. Takve je oznake moguće nazvati emotivnim ili afektivnim oznakama, a za informacijsku su zajednicu iznimno zanimljive jer predstavljaju dodanu vrijednost u informacijskom smislu. One omogućuju nove modele pretraživanja i pristupa informacijama utemeljene na suradničkom načelu koje su se već dokazale u domeni društvenih mreža i Weba 2.0 .

3.7. Model distribucije korisničkih oznaka

Uz motivaciju i kategorizaciju korisničkih oznaka, niz radova bavio se proučavanjem razdioba i modela distribucije korisničkih oznaka. U tom smislu, u literaturi je uveden pojam *docsonomy* (Peters et al., 2011) koji označava skup svih korisničkih oznaka dodijeljenih jednom izvoru unutar jedne široke folksonomije. Kako je u širokim folksonomijama moguće bilježiti podatak o frekvenciji dodanih oznaka, sortiramo li oznake prema frekvenciji pojavljivanja, možemo grafički prikazati frekvencijsku razdiobu dodanih korisničkih oznaka (Halpin, Robu i Shepherd, 2007).

Velik broj primjera u literaturi (Shirky, 2003; Vander Wal, 2005; Munk i Mork, 2007; Heymann, Koutrika i Garcia-Molina, 2007) identificira kako tipična razdioba korisničkih oznaka, dodijeljenih jednom izvoru, pokazuje obilježja tipične *power law* krivulje (Slika 36).

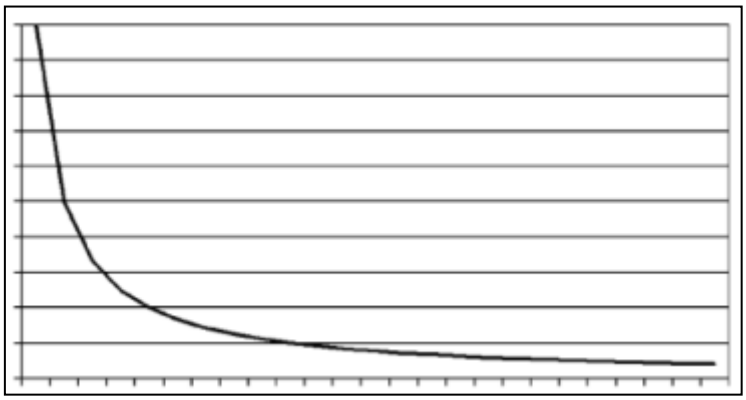

Slika 36 - Tipična power law razdioba podataka

Takav model pronalazimo u analizi niza fenomena u informacijskim znanostima, od Bradfordovog zakona o distribuciji članaka (npr. 20% naslova časopisa objavljuje oko 80% relevantnih članaka o određenom predmetu), Lotkinog zakona o produktivnosti autora (mali broj autora piše veliki broj članaka) ili Zipfove distribucije (mali broj riječi pojavljuje se često) (Tuđman, Boras i Dovedan, 1993).

Primijenjeno na analizu modela razdiobe korisničkih oznaka, pokazalo se kako, unutar jedne folksonomije, postoji mali broj oznaka koje su često dodane (velike frekvencije) i velik broj oznaka koje su dodane samo jednom (niska frekvencija). Na temelju analize frekvencije moguće je razlikovati tzv. *power tags*, korisničke oznake s visokom frekvencijom koje se nalaze s lijeve strane distribucije, te *long tail* oznake koje se grupiraju na desnoj strani distribucije.

Osim pojma *power tags*, projekti nabave iz mnoštva identificirali su i pojam *power user*, gdje se pokazalo kako razdioba broja dodanih oznaka od strane korisnika također slijedi istu razdiobu. Jedan primjer je i, već prije spomenuti, pilot projekt opisivanja fotografija na popularnom servisu za dijeljenje fotografija, Flickr, koji je pokrenula Kongresna knjižnica u Washingtonu, gdje se pokazalo kako je za dodavanje 40% svih korisničkih oznaka odgovorno samo 10 korisnika koji su se pokazali iznimno motiviranima, te je svaki dodao preko 3000 oznaka, dok je čak 500 korisnika dodalo samo jednu oznaku.

4. Ključni aspekti primjene korisničkog označivanja u baštinskom okruženju

Razvojem društvenog softvera, baštinske institucije brzo su počele uviđati prednosti i potencijal novih pristupa korištenju baštinske građe u mrežnom okruženju. Mnoge baštinske ustanove počele su koristiti mogućnosti raznih web 2.0 alata, poput blogova ili društvenih mreža, kako bi osnažile svoju mrežnu prisutnost i otvorile nove komunikacijske kanale sa svojim korisnicima. ICOM definira zadaću baštinskih ustanova (primarno misleći na muzeje, ali se to može u nekom aspektu primijeniti i na praktički sve baštinske ustanove, uključujući i arhive i knjižnice) kao ustanove koje: „...nabavljaju, čuvaju, istražuju, komuniciraju i predstavljaju javnosti materijalnu i nematerijalnu baštinu u cilju edukacije, istraživanja ili razonode“ (ICOM, 2007).

Originalna ideja Weba 2.0 o korištenju kolektivne inteligencije, pronašla je svoje mjesto i u području digitalne kulturne baštine, ali u ponešto izmijenjenome obliku. Osnovna ideja je pružila široku perspektivu unutar ideje kako veća zajednica ili grupa ljudi može stvoriti kolektivno djelo, koje svojom vrijednošću nadmašuje pojedinačne napore svakog pojedinca koji u njemu sudjeluje (O’Reilly i Batelle, 2009).

Kako smo već raspravljali u prijašnjim poglavljima, ideje korištenja kolektivne inteligencije možemo promatrati kroz tri osnovne ideje: društvenog računarstva s jedne, i ljudskog računarstva s druge strane, te nabave iz mnoštva kao područja koji ima osobine obje strane. Dok je „ljudsko računarstvo“ (engl. *human computing*) pokušalo koristiti ljudsku inteligenciju za rješavanje problema koje računala ne mogu riješiti, stvarajući aplikacije poput ESP igre ili reCaptche, „društveno računarstvo“ (engl. *social computing*) je otvorilo vrata korištenju snage velikog broja korisnika i stvaranja njihove povezane zajednice, što je ostvareno u servisima poput Facebooka, Youtube-a ili Wikipedije.

4.1. Korištenje kolektivne inteligencije

Web 2.0 servisi uvelike se oslanjaju na sudjelovanje korisnika u pružanju sve bolje usluge, pa između tih servisa i njihove zajednice, koja djeluje kao pravi razvojni tim, postoji sporazum o „međusobnom povjerenju.“ Kako korisnici stvaraju ili generiraju sadržaj, važno je da nitko namjerno ne sabotira sustav dajući mu stalno krive podatke. S druge strane, servis postoji zbog korisnika, te je njegovo što bolje funkcioniranje korisnicima u interesu. Jedan od najboljih primjera korištenja kolektivne inteligencije u praksi je servis za društveno

označivanje Delicious, koji omogućuje dijeljenje mrežnih poveznica u mrežnom okruženju. Jednostavnim označavanjem izvora, koji neki korisnik smatra korisnim i vrijednim, te njegovim pohranjivanjem i dijeljenjem s ostalim korisnicima, stvorena je veoma korisna i relevantna baza korisničkih poveznica iz najrazličitijih područja ljudskog znanja. Tako je znanje pojedinca, koji koristi servis radi vlastite koristi, u suradnji s ostalim korisnicima, iskorišteno na dobrobit cijele zajednice.

Surowiecki (2005) je definirao četiri osnova uvjeta koja mogu dovesti do korištenja kolektivne inteligencije u pogledu mudrosti mnoštva (engl. *wisdom of the crowd*):

1. **raznolikost mišljenja** – svaki korisnik daje svoju perspektivu i pogled na rješavanje problema
2. **neovisnost članova** – svaki član zajednice mora donositi neovisne odluke
3. **decentralizacija** – proces ne smije biti kontroliran iz jednog središta
4. **dobra metoda prikupljanja mišljenja** – sustav mora omogućavati lako prikupljanje i prezentaciju rezultata aktivnosti.

Jedan od termina pod kojim se pokušalo objediniti inicijative primjene društvenog softvera u baštinskom okruženju je pojam "nabave iz mnoštva" (engl. *crowdsourcing*) (Howe, 2008; Howe 2010). Kako bi bilo jasnije u kojim aspektima je korisničko označivanje dio samih inicijativa, potrebno je najprije razjasniti pojam *crowdsourcing*. Istražujući pojam u literaturi, pojavljuje se niz povezanih termina kao što su "kolektivna inteligencija“ (engl. *collective intelligence*), "mudrost mnoštva“ (engl. *wisdom of the crowds*), „ljudsko računarstvo“ (engl. *human computing*), „društveno računarstvo“ (engl. *social computing*), što dodatno otežava dobivanje jasne slike o samom području. Quinn i Bederson (2011) pokušali su dati pregled svih povezanih pojmova i njihovih odnosa u području inicijativa prikazanih na Slici 37.

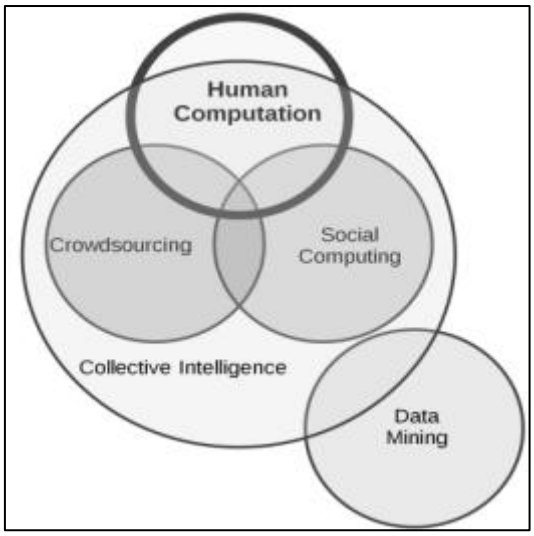

Slika 37 - Prikaz područja i terminologije crowdsourcinga

Autori identificiraju tri osnovne komponente koje sačinjavaju polje korištenja kolektivne inteligencije: ljudsko računarstvo, nabava iz mnoštva, te društveno računarstvo. Smještanje tih termina unutar istog polja kolektivne inteligencije temelje na njihovoj zajedničkoj pretpostavci za uspješnu implementaciju - veća grupa korisnika koja je potrebna kako bi sustav bio uspješan. Sve tri inicijative kao osnovnu pretpostavku zahtijevaju sudjelovanje većeg broja korisnika koji svaki, svojim malim doprinosom, sudjeluje u ostvarivanju zajedničkog cilja. Unutar ovog okvira, važno je razlikovati između dvije slične, ali u osnovi vrlo različite inicijative: ljudsko računarstvo i nabava iz mnoštva. Pojam ljudskog računarstva korišten u modernom značenju najviše se pripisuje radovima Lousia von Ahna (von Ahn, 2005; Law i von Ahn, 2009; von Ahn i Dabbish, 2008), gdje je termin ljudskog računarstva definiran kao: "...paradigma korištenja ljudske moći procesuiranja kako bi se riješili problemi koje računala još ne mogu riješiti" (von Ahn, 2011). Glavna ideja korištenja ljudskog računarstva sastoji se u korištenju ljudske inteligencije većeg broja ljudi, kako bi se riješili zahtjevni računalni problemi za koje ne postoje zadovoljavajuća rješenja koja mogu ponuditi računala, poput sofisticiranih algoritama ili računalnih programa. Jedan od klasičnih primjera korištenja sustava, koji koristi ljudsko računarstvo, je reCAPTCHA, sustav za transkribiranje skeniranih tekstova za koje OCR nije učinkovit. Sustav iskorištava sustav CAPTCHA, koji koristi slike koje računala ne mogu pročitati, kako bi se osiguralo da je iza neke akcije (npr. registracija na neku mrežnu aplikaciju) čovjek, a ne neki automatizirani program. Umjesto da se koriste namjerno iskrivljene slike teksta, sustav reCAPTCHA koristi slike pravih riječi iz

skeniranih tekstova za koje se pokazalo kako ih računala ne mogu zadovoljavajuće prepoznati putem OCR tehnologije. Prikaz sustava može se vidjeti na slici 38.

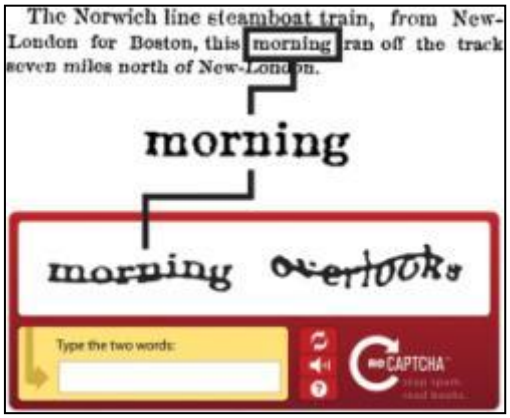

Slika 38 - reCAPTCHA sustav
Izvor: http://irevolution.files.wordpress.com/2013/06/recaptcha_pic2.jpg

Quinn i Bederson (2011) sumiraju razlike između nabave iz mnoštva i ljudskog računarstva: "...dok ljudsko računarstvo zamjenjuje računala ljudima, nabava iz mnoštva zamjenjuje klasičan ljudski rad s članovima javnosti". Owens (2012) također uočava ključnu razliku između ta dva pojma, koristeći malo drugačiju terminologiju, smatrajući mudrost mnoštva (engl. *wisdom of the crowd*) i ljudsko računarstvo (engl. *human computing*) kao dva suprotna pola u inicijativama korištenja kolektivne inteligencije. Tablica 8 prikazuje ključne razlike između dva pristupa.

Tablica 8 - Ključne razlike između pristupa ljudskog računarstva i mudrosti mnoštva

	Ljudsko računarstvo	Mudrost mnoštva
Alati	Sofisticirano	Jednostavno
Priroda zadatka	Visoko strukturirano okruženje	Labavo definirano s nejasnim krajem zadatka
Vremensko opterećenje	Brzo i diskretno	Dužeg trajanja
Društvena interakcija	Minimalno	Dobro povezana zajednica
Pravila	Nametnuta tehničkim ograničenjima	Postignuta dogovorom unutar zajednice

Povežemo li pojam nabave iz mnoštva s korisničkim označivanjem u svjetlu istraživanja poduzetog u ovoj disertaciji, najzanimljiviji su nam projekti koji spadaju u korištenje kolektivne inteligencije okupljene pod nazivom "nabava iz mnoštva", koji obuhvaćaju različite inicijative koje, između ostalog, uključuju i korištenje korisničkog označivanja kao metode dopune standardnog opisa predmeta u zbirkama baštinskih ustanova.

4.2. Nabava iz mnoštva

Prvi problem koji se pojavljuje u literaturi pitanje je samog pojma "nabava iz mnoštva", koji mnogi istraživači ne smatraju uopće prikladnim za područje baštine. Owens (2013) upitnim smatra i pojam *crowd* (mnoštvo) kao i *sourcing* (nabava), argumentirajući kako velika većina projekata korištenja kolektivne inteligencije u području baštine ne uključuje velik broj ljudi (*crowd*) niti outsourcing. Jedan od termina koji neki istraživači smatraju prikladnijim je pojam *nichesourcing* koji podrazumijeva "...specifičan tip nabave iz mnoštva u kojem su složeni zadaci podijeljeni između male skupine amatera stručnjaka...prije nego nekom bezimenom mnoštvu" (de Boer et al., 2012). Owens (2012) dodaje kako su projekti unutar područja kulturne baštine baš takvi: „...pozivaju na sudjelovanje zainteresiranih i angažiranih članova javnosti…[koji] nastavljaju dugu tradiciju volontiranja i uključivanja građana u kreiranje i razvoj javnih dobara". Uzimajući u obzir navedene argumente, možemo vidjeti kako ideja korištenja kolektivne inteligencije nije samo usmjerena na čisto "iskorištavanje" javnosti, već želi javnost uključiti kako bi doprinijeli i bili ravnopravni suradnici u samome procesu komunikacije digitalne baštine (Bonney et al., 2008). Korištenje snage korisnika nije usmjereno samo na obavljanje nekog posla (kao npr. kod servisa Mechanical Turk), već je jedna od glavnih ideja ostvariti komunikaciju između same zbirke koja se opisuje i korisnika, kako bi se fokus prebacio s „konzumiranja“ u suradnju. Takav pristup najčešće dovodi do manje skupine amatera istraživača, koji imaju intrinzičnu motivaciju za sudjelovanje i koji su se uključili iz vlastitih razloga, bili oni znatiželja, želja za pomoći ili nešto treće. Ovdje se opet možemo osvrnuti na neprikladnost riječi nabava iz mnoštva kada se opisuju projekti korištenja kolektivne inteligencije u baštinskom okruženju: u većini slučajeva ne pomaže mnoštvo, već manja skupina amatera istraživača, a njihov doprinos je intrinzično motiviran i ne smatra se *poslom* u tom smislu (tj. nema klasičnog outsourcinga). Kako se termin već koristi i u širokoj je upotrebi, u nastavku se donosi okvir unutar kojeg treba shvaćati projekte nabave iz mnoštva kada se oni ostvaruju unutar baštinskog okruženja.

Jedan od sveobuhvatnih pokušaja prikaza područja nabave iz mnoštva i stvaranja okvira unutar kojega možemo bolje razumjeti različite inicijative unutar područja jest infografika

“Crowdsourcing Industry Landscape” (http://www.crowdsourcing.org/editorial/november-2011-crowdsourcing-industry-landscape-infographic/7680), koja prikazuje svojevrsnu kategorizaciju područja iz perspektive različitih servisa koji implementiraju ideju nabave iz mnoštva.

Sama kategorizacija organizira polje u šest različitih područja:

- ***crowdfunding*** **(grupno ili kolektivno financiranje)** – prikupljanje financijskih sredstava u mrežnom okruženju, kako bi se financirali razni projekti za koje osnivači nemaju dovoljno financijskih sredstava da ih financiraju sami (npr. kickstarter.com, gofundme.com)
- ***crowd creativity*** **(grupna ili kolektivna kreativnost)** – otvoreni natječaji u kojima se traže kreativni pojedinci koji razvijaju originalne sadržaje (npr. istockphoto.com, minted.com)
- ***distributed knowledge*** **(dijeljeno znanje)** – prikupljanje informacija i znanja iz široke baze amatera kako bi se poboljšali određeni sustavi ili servisi (npr**.** GalaxyZoo, openbuildings.com)
- ***cloud labour*** **(rad u oblaku)** – raspodjela zadataka koju treba obaviti na široku bazu „radnika na zahtjev“ koji su plaćeni za svoj posao (npr. AmazonMechanicalTurk, tagasauris.com)
- ***open innovation*** **(otvorena inovacija) –** pozivanje javnosti na doprinos u nekom području u smislu razvijanja novih ideja (npr. challengepost.com, innocentive.com)
- **alati –** aplikacije, platforme i alati koji podržavaju suradnju, komunikaciju i dijeljenje između korisnika (npr. socialvibe.com, bigdoor.com).

Sagledamo li ove kategorije iz perspektive digitalne baštine, možemo izdvojiti kategoriju dijeljenog znanja kao onu koja najbolje odražava inicijative nabave iz mnoštva unutra. Kao što je prije spomenuto, projekti korištenja kolektivne inteligencije u baštinskom okruženju žele uključiti motivirane korisnike koji doprinose, surađuju i suradnici su u cijelome procesu. Navedena kategorizacija na slici 37 odnosi se na širi aspekt korištenja kolektivne inteligencije, onaj industrijski koji je zapravo okrenut tržištu, te je zbog toga ipak potrebno malo suziti sam fokus inicijativa na baštinski sektor. Temeljem pristupa samom području u literaturi (Ridge 2011; Simon 2010; Oomen i Arroyo 2011), možemo razlikovati tri različita aspekta na temelju kojih možemo napraviti kategorizaciju:

- **sudjelovanje** – kategorizacija projekata nabave iz mnoštva temeljene na razini korisničkog sudjelovanja
- **aktivnosti** – kategorizacija projekata na temelju poduzetih aktivnosti
- **inicijative** – kategorizacija projekata na temelju ishoda pokrenutih inicijativa.

Tri navedena aspekta predstavljaju ujedno i tri temeljna pitanja na koja svaka institucija, koja želi pokrenuti projekt nabave iz mnoštva, mora odgovoriti: tko su predviđeni korisnici, koje aktivnosti bi trebalo poduzeti, te koji su opipljivi ishodi koji se očekuju nakon završetka projekta.

Razradivši prvi aspekt kategorizacije, onaj koji kao temelj koristi razinu sudjelovanja korisnika u samom projektu, Simon (2011) navodi četiri osnovna modela sudjelovanja korisnika u nekom projektu korištenja kolektivne inteligencije u području baštine:

- **doprinosni** - projekti koji traže ograničeni doprinos korisnika i strogo su regulirani od strane institucije
- **suradnički** - korisnici su pozvani sudjelovati kao aktivni partneri u samom stvaranju projekta, ali ideja i organizacija su kontrolirani od strane institucije
- **stvaralački** – korisnici rade zajedno s osobljem institucije od samog početka predlažući ideje i načine ostvarenja
- **domaćinski** – projekti u kojima institucija daje svoj prostor i/ili resurse kako bi se ostvarili programi razvijeni i implementirani od strane javnosti, bez sudjelovanja osoblja institucije.

Ovaj pristup kategorizaciji polja kroz razine moguće suradnje s potencijalnim korisnicima daje okvir unutar kojeg institucije mogu uključiti korisnike u svoje projekte. Kako Simon (2010) piše:„…nijedan model nije bolji od ostalih, niti bi trebali biti shvaćeni kao postupni prijelaz u model „apsolutne participacije“…razlike između modela participacije u korelaciji su sa razinom upravljanja, kontrole i kreativne slobode koju imaju osoblje i posjetitelji.“

Drugi aspekt, na temelju kojeg možemo kategorizirati aktivnosti korištenja kolektivne inteligencije, temelji se na poduzetim aktivnostima koje se mogu implementirati u procesu

komunikacije digitaliziranih objekata. Ridge (2011) daje pregled mogućih aktivnosti u kojima korisnici mogu sudjelovati u kontekstu nabave iz mnoštva:

- **korisničko označivanje** – dodavanje opisa pojedinačnim predmetima
- **ukazivanje na pogreške** – označivanje problematičnog ili netočnog sadržaja kojima je potrebno daljnje istraživanje ili ispravak podataka
- **povezivanje** – stvaranje veza između dva objekta, objekta i kontroliranih naziva ili objekta i povezanih materijala
- **kategorizacija** – dodavanje strukturiranih naziva skupinama objekata, sakupljanje većeg broja objekata u povezane skupine ili definiranje veza između objekata
- **preferenciranje** – biranje između dva objekta na temelju virtualnog glasanja
- **bilježenje osobne priče** – kontekstualizacija detalja pružanjem subjektivnih usmenih povijesti ili iskustvima očevidaca
- **kreativni izazovi –** pisanje zanimljive lažne povijesti za poznate objekte ili svrhe korištenja nepoznatih objekata.

Posljednji aspekt koji treba uzeti u obzir kod implementacije nabave iz mnoštva jest i perspektiva opipljivih ishoda, tj. na koji način različite aktivnosti mogu doprinijeti samoj praksi i što same inicijative mogu ponuditi kao opipljiv rezultat. Oomen i Arroyo (2011) daju pregled različitih inicijativa temeljenih na njihovom predviđenom ishodu:

- **ispravljanje i transkripcija** – otvoreni poziv korisnicima na ispravljanje ili prepisivanje rezultata digitalizacije
- **kontekstualizacija** – dodavanje kontekstualnog znanja objektima, npr. pričanjem priče ili pisanjem članaka/wikija koji sadrže kontekstualne podatke
- **dopunjavanje zbirke** – aktivno traženje novih objekata koji mogu biti uključeni u izložbu ili zbirku
- **klasifikacija** – sakupljanje deskriptivnih metapodataka o objektima unutar zbirke
- **co-curation** – korištenje inspiracije/ekspertize amatera kako bi se kreirala izložba
- **crowdfunding** – kolektivna suradnja unutar koje se skuplja novac i drugi resursi kako bi se podržali projekti inicirani od strane predlagatelja.

Dodavanjem navedenog trećeg aspekta, stvoren je teorijski okvir za primjenu inicijativa korištenja nabave iz mnoštva u baštinskom okruženju. Obzirom na željenu razinu sudjelovanja korisnika, poduzete aktivnosti kao i predviđen ishod inicijativa, mnoge AKM institucije mogu odabrati sebi prikladnu strategiju korištenja nabave iz mnoštva, prikladnu svojim resursima, upravljačkoj strukturi, financijama i potrebama zbirke. Neka baštinska institucija može u prvi plan staviti komunikacijski aspekt te prepustiti inicijativu stvaranja korisnicima, smatrajući ih suradnicima u cijelom procesu komunikacije neke zbirke javnosti, koristeći njihovu kreativnost i inspiraciju. S druge strane, može strogo kontrolirati proces uključivanja javnosti i koristiti korisnike samo u ograničenom opsegu na strogo definiranim zadacima, poput transkripcije ili ispravljanja digitaliziranih tekstova. Nakon početnih inicijativa digitalizacije u baštinskom okruženju, sljedeći korak je iskorištavanje stvorenih digitalnih zbirki na nove načine, a ne samo klasičnom prezentacijom na mrežnim stranicama.

4.2.1. Igre sa svrhom kao metoda motivacije sudionika

Jedan od važnih aspekata primjene nabave iz mnoštva jest i osiguravanje kako će u samim projektima sudjelovati dovoljan broj sudionika, kako bi finalni rezultat bio zadovoljavajući. Iako smo već napomenuli kako pristup nabavi iz mnoštva u baštinskom okruženju najčešće dovodi do manje skupine amatera istraživača, koji imaju intrinzičnu motivaciju za sudjelovanje i koji su se uključili iz vlastitih razloga, ipak je u samoj osnovi nabave iz mnoštva ideja da u samom procesu sudjeluje veći broj sudionika.

Müller, Thoring i Oostinga (2010) navode četiri osnovna razloga zbog kojih korisnici žele sudjelovati u projektima nabave iz mnoštva: novac, altruizam, korisnost te zabava. Dok je novac motivacija na komercijalnim servisima (npr. Mechanical Turk), u baštinskom okruženju najčešće korisnici pokazuju altruizam, želeći biti korisni i tako sudjelovati u stvaranju novih javnih dobara. Jedan od načina na koji se pokušala dodati i treća dimenzija samom procesu, ona zabavna, jest i primjena igara sa svrhom.

Ideju igara sa svrhom (engl. *GWAP – Games With a Purpose*) razvili su Louis von Ahn i Laura Dabbish (von Ahn i Dabbish, 2004) kao metodu kojom su pokušali riješiti problem opisivanja slika u mrežnom okruženju. Ideju su primijenili u razvoju ESP igre (engl. *The ESP Game*), kao igru za dva igrača u kojoj oba igrača dobivaju istu sliku na svojem ekranu i neovisno jedan o drugome upisuju pojmove koji je najbolje opisuju, dobivajući bodove kada oba igrača upišu isti opisni pojam za dobivenu sliku (Slika 39).

Slika 39 - ESP igra
Izvor: http://mmdays.com/wp-content/uploads/2007/02/esp_game.jpg

Owens (2012) igru opisuje kao: "...sofisticirani mali alat koji nas zaokuplja u visoko strukturiranom zadatku u veoma kratkom vremenu...s veoma malo vremenske posvećenosti...praktički bez društvene interakcije...a pravila igre su strogo određena tehničkim pretpostavkama sustava". Kako automatsko označivanje još uvijek ne daje zadovoljavajuće rezultate, posebno kod opisa slika, von Ahn je predložio nabavu iz mnoštva u obliku igre kao jedno od mogućih rješenja (von Ahn, 2006).

Igra je postigla veliki uspjeh te je u prava četiri mjeseca prikupila više od 1.3 milijuna opisa u čemu je sudjelovalo preko 13.000 igrača. Ručna evaluacija prikupljenih opisa pokazala je kako je više od 85% dodanih oznaka bilo relevantno za fotografiju koja se opisivala, dok je samo 2% oznaka bilo ocijenjeno kao nepovezane sa samom slikom. Pokazalo se kako je ESP igra oblik korisničkog sudjelovanja u kojem oni uživaju, te kako igra producira relevantne opise te je prikladan alat za značajno poboljšanje opisa slika u mrežnom okruženju (von Ahn i Dabbish, 2004). Nakon uspjeha ESP igre, polje igara sa svrhom proširilo se na niz implementacija te na opisivanje niza različitih vrsti zapisa poput fotografija, audio zapisa ili tekstualnih zapisa. Veliki uspjeh ESP igre i predloženog pristupa potaknuli su i bili važna karika u razvijanju interesa baštinskih ustanova za korisničke oznake i načine na koji se one

mogu iskoristiti u opisu i pronalaženju baštinske građe u mrežnom okruženju (Bearman i Trant, 2005).

4.3. Projekti suradničkog označivanja u baštinskom okruženju

U ovom poglavlju donose se izabrani primjeri projekata pokrenutih u baštinskom okruženju, koji koriste osnovne ideje nabave iz mnoštva i kolektivne inteligencije u opisu baštinske građe, bila ona arhivska, knjižnična ili muzejska. Fokus pregleda stavljen je na uspješne i pionirske projekte koji koriste suradničko označivanje kako bi omogućili korisnicima sudjelovanje u opisima baštinske građe.

4.3.1. Steve.museum

Jedan od prvih primjera korištenja korisničkog označivanja projekt je „Steve.museum“ (http://www.steve.museum/) pokrenut 2005. godine kao suradnički projekt nekolicine muzejskih ustanova. Ideja projekta bila je ispitivanje mogućih rješenja problema semantičkog jaza između formalnog opisa predmeta od strane muzeja i rječnika koji koriste korisnici kada traže građu (Slika 40). Projekt je ispitivao razlikuju li se korisnički termini od onih koji se nalaze u muzejskoj dokumentaciji, mogu li korisničke oznake poboljšati pretragu i pronalaženje muzejskih predmeta unutar neke zbirke, te smatraju li muzejski stručnjaci korisničke oznake korisnima (Trant, 2009).

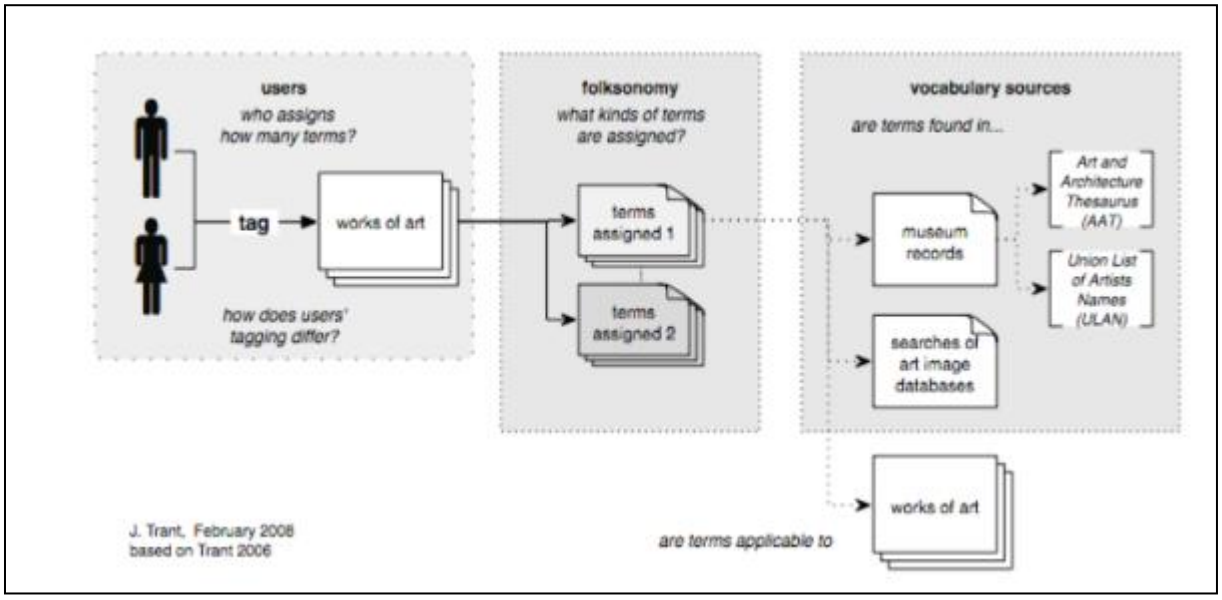

Slika 40 - Proces istraživanja projekta Steve Museum (Trant, 2009)

Kako bi se prikupile korisničke oznake, kreiran je alat nazvan *steve.tagger*, rješenje otvorenog koda koje omogućuje dodavanje korisničkih oznaka digitaliziranim zbirkama (http://tagger.steve.museum/) (Slika 41).

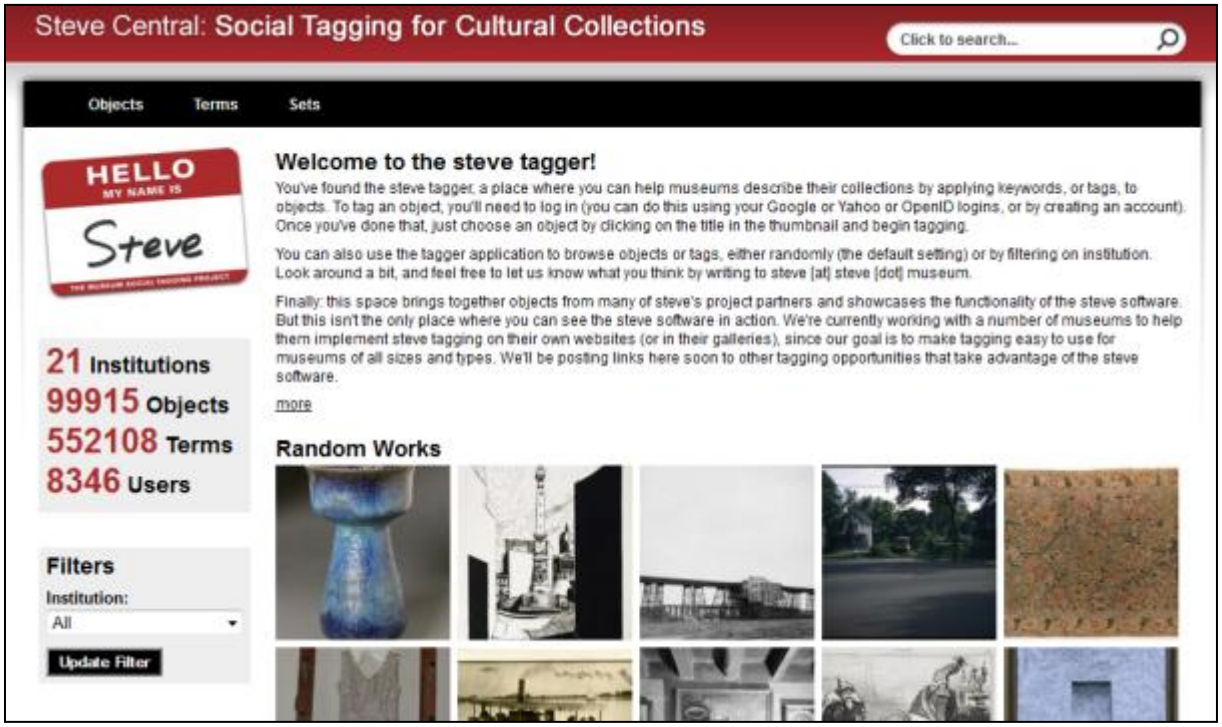

Slika 41 - Mrežna stranica alata steve.tagger
Izvor: http://tagger.steve.museum/

U originalnom istraživanju, koje je trajalo od 2006.-2008. godine, sudjelovalo je 11 baštinskih ustanova s ukupno 1784 digitalizirana predmeta. Ukupno je u istraživanju sudjelovao preko 1621 korisnik koji je dodao 37.000 korisničkih oznaka.

Rezultati istraživanja pokazali su kako 86% korisničkih oznaka nije bilo prisutno nigdje u muzejskoj dokumentaciji, te kako su muzejski stručnjaci 88% korisničkih oznaka ocijenili korisnima u pretrazi. Istraživanje je zaključilo kako se korisnički rječnik značajno razlikuje od rječnika koji koriste muzejski stručnjaci kada opisuju svoje zbirke (Trant, 2009).

Nakon završetka projekta, *steve tagger* alat se nastavio koristiti u baštinskim ustanovama i trenutno se koristi u 21 instituciji te je pokrenuo niz različitih primjena i inicijativa unutar zajednice baštinskih institucija.

Nastavak projekta proveden je unutar programa „T3: Text, Tags, Trust," (http://www.umiacs.umd.edu/research/t3/research.shtml) u koji se uključila i akademska zajednica (Sveučilište u Marylandu), čiji je cilj istražiti moguće pristupe računalne lingvistike u uključenju korisničkih oznaka u opise baštinskih predmeta (Klavans et. al, 2011).

4.3.2. Penn Tags

PennTags (http://tags.library.upenn.edu), razvijen od strane knjižnice Sveučilišta u Pennsylvaniji, jedan je od prvih sustava koji koriste korisničko označivanje u okruženju knjižničnog kataloga. Ideja je slična servisu Delicious.com, ali je kreirana i namijenjena uskoj akademskoj zajednici samog sveučilišta. Servis omogućuje korisnicima spremanje, anotiranje, označivanje te dijeljenje mrežnih izvora. Korisničke oznake i anotacije dodane svakom spremljenom izvoru spremaju se unutar korisničkog profila kako bi im se lako pristupilo kasnije, a jedan od načina organizacije jest i okupljanje oznaka u oblak oznaka (Slika 42)

Slika 42 - Oblak oznaka na servisu Penn Tags

Sustav također omogućuje suradnju između korisnika, gdje korisnici mogu vidjeti što drugi korisnici označuju i spremaju, koje oznake koriste, te ih mogu koristiti u okviru svoje spremljene zbirke izvora, ili se pak pretplatiti na željenu oznaku te automatski, putem RSS-a, primati izvore označene tom oznakom. Nakon početnih inicijativa uključivanja korisničkog označivanja u kataloge knjižnica, danas je uključivanje mogućnosti dodavanja korisničkih oznaka standardna mogućnost knjižničnih kataloga. Inicijativa uključivanja korisnika u obogaćivanje sadržaja unutar knjižničnog kataloga okupljena je oko pojma OPAC 2.0 ili SOPAC (Social Opac). Osnovne mogućnosti koje nudi SOPAC su (Chalon, Di Pretoro i Kohn, L., 2008):

- komentiranje: omogućavanje korisniku dodavanje vlastitih kratkih opisa zapisu knjige
- ocjenjivanje: omogućavanje korisniku ocjenjivanje knjiga sustavom dodavanja do 5 zvjezdica
- korisničko označivanje: omogućavanje korisniku dodavanje vlastitih korisničkih oznaka

- predlaganje: korisniku se automatski preporučuju druge knjige unutar knjižnice na temelju pregledanih i posuđenih knjiga.

Unutar OPAC 2.0 okvira, korisničko označivanje jedan je od glavnih elemenata kojim se obogaćuje katalog te omogućuje korisnička organizacija sadržaja.
Iako osnovna ideja dijeli mnogo funkcionalnosti sa sustavima za suradničko dijeljenje sadržaja opisanima u prethodnim poglavljima poput Delicious.com ili Diigo.com, ono što Penn Tags dodaju u cijelu ideju integracija je sustava za korisničko označivanje u mrežni katalog knjižnice. Korisnici mogu spremati zapise izravno iz kataloga, dodavati oznake zapisima u katalogu te stvarati projekte – popise povezanih mrežnih izvora, oznaka i opisa o nekoj temi. Na taj način korisnici stvaraju anotirane bibliografije koje mogu biti vrlo korisne kod traženja literature o istraživačkoj temi ili stvaranja popisa literature za neki kolegij. Dijeljenjem stvorenih projekata između korisnika, sam sustav postaje veoma korisno i snažno istraživačko oruđe za otkrivanje relevantnih izvora koje knjižnica posjeduje.

4.3.3. LibraryThing

Iako sam servis nije pokrenut od strane baštinskih ustanova, LibraryThing (https://www.librarything.com), mrežni servis koji omogućuje skupnu katalogizaciju knjiga te oko kojeg se okupila vrlo aktivna mrežna zajednica, prikladan je primjer načina na koji korisničke oznake mogu organizirati sadržaje unutar knjižničnog kataloga. Pokrenut je 2005. godine i danas broji preko 1,8 milijuna korisnika, 90 milijuna katalogiziranih knjiga te 110 milijuna dodanih korisničkih oznaka (https://www.librarything.com/zeitgeist). Stvaranjem korisničkog profila, korisnik može sudjelovati u samom servisu na tri razine: kao servis za osobnu katalogizaciju, kao društvenu mrežu, te kao platformu za društvenu katalogizaciju.

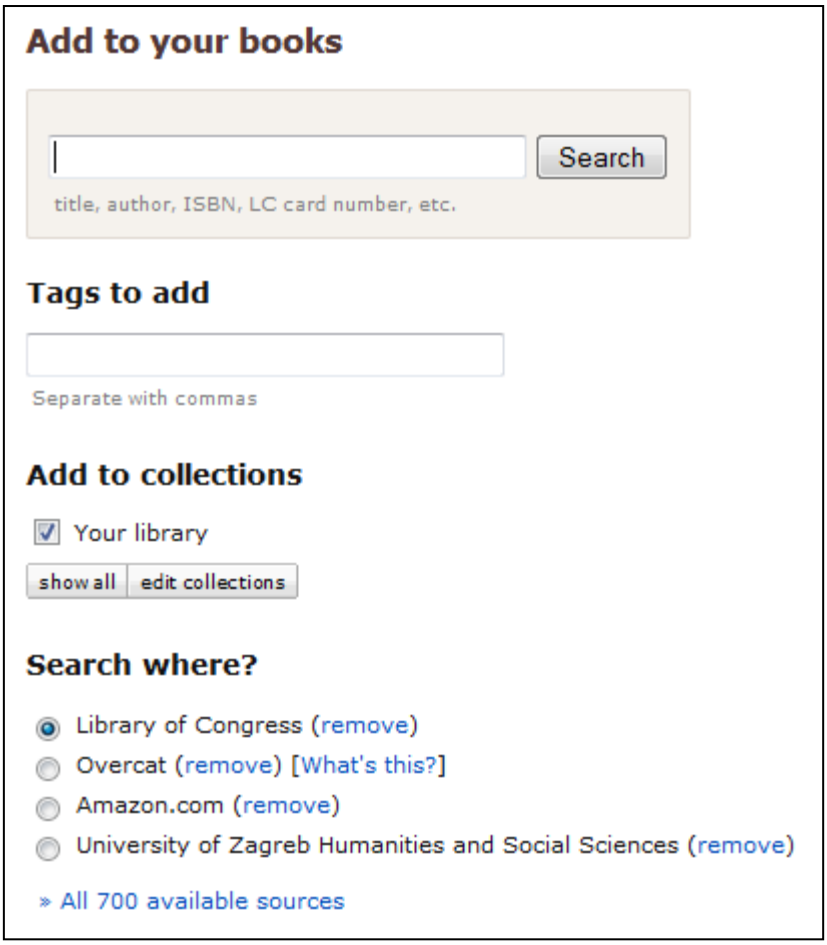

Slika 43 - Dodavanje nove knjige na servisu LibraryThing

Nova knjiga može se dodati jednostavnom pretragom prema naslovu, autoru, ISBN-u i nizu ostalih deskriptora ili prema korisničkim oznakama. LibraryThing u pretragu uključuje preko 700 različitih mrežnih kataloga te povlači njihove zapise. Moguće je pretraživati skupno ili odabrati jedan katalog koji se želi pretraživati. Slika 43 prikazuje proces dodavanja nove knjige, s dodanim katalogom Knjižnice Filozofskog fakulteta kao jedinim raspoloživim iz Hrvatske.

Nakon pronalaska knjige u željenom katalogu, knjiga se dodaje profilu korisnika gdje joj on može dodati svoje oznake, kao i vidjeti koji su drugi korisnici dodali taj isti izvor te oblak oznaka najčešće dodanih korisničkih oznaka izabranom izvoru (Slika 44).

Slika 44 - Prikaz korisničkih oznaka dodanih knjizi Folksonomies, indexing and retrieval na servisu LibraryThing

U procesu dodavanja vlastitih korisničkih oznaka, korisnike se upućuje da oznake treba odvojiti zarezom, te se daje primjer nekoliko oznaka, kao i poveznica na temu pomoći u kojoj se objašnjavaju što su to korisničke oznake i kako se koriste (Slika 45).

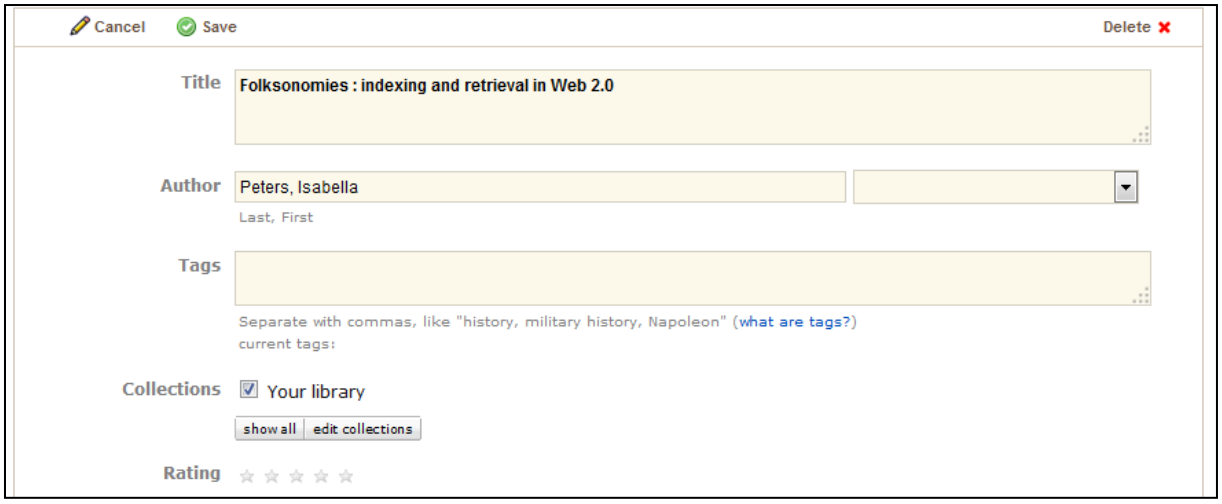

Slika 45 - Uređivanje zapisa knjige te dodavanje korisničkih oznaka na servisu LibraryThing

Prema definiciji samog servisa:„Korisničke oznake su jednostavan način kategorizacije knjiga na način koji želite, a ne kako to neka knjižnica radi. Bilo što može biti oznaka – samo upišite riječ ili frazu odvojenu zarezom. Na taj način netko može djelo „Da Vincijev kod“ označiti kao *roman*, dok će netko drugi dodati oznake *jeftino, religija*, a treća osoba može dodati samo *vikendica*. Oznake su posebno korisne kod traženja i kategoriziranja – kada trebate popis svih knjiga koje vam se nalaze u vikendici“ (http://www.librarything.com/concepts#what).

Osim mogućnosti dodavanja oznaka, korisnicima se pruža i mogućnost kombiniranja, tj. spajanja oznaka, kojom se pokušao riješiti kako problem sinonimije, tako i različitih konvencija dodavanja oznaka unutar sustava, te istoznačnih oznaka na različitim jezicima. Spajanje oznaka se preporučuje samo u slučaju kada dvije oznake imaju isto značenje i istu upotrebu unutar sustava. Npr. oznake *WWII, WW2* i *World War Two* imaju isto značenje i koriste se za označivanje istih tema unutar knjiga, te je preporučeno da se te tri oznake spoje kako bi korisnik, koji traži knjige o 2. svjetskom ratu, dobio sve knjige koje su opisane bilo kojom od te tri oznake. Proces predlaganja oznaka koje treba spojiti (ili razdvojiti) prepušten je korisničkoj zajednici, gdje svaki korisnik može predložiti spajanje/razdvajanje neke oznake, te se zatim glasanjem na razini sustava odlučuje hoće li se neki prijedlog prihvatiti ili odbaciti.

Slika 46 - Proces glasanja o spajanju/razdvajanju oznaka na servisu LibraryThing

Slika 46 prikazuje predložena spajanja oznaka, gdje možemo vidjeti kako su, između ostalih, predložena spajanja oznaka koja znače isto na različitim jezicima (*Nordafrika* i *North Africa),* te dvije različite konvencije pisanja (*Camus-Albert* i *Albert Camus*, *Nov2013* i *November 2013*). Na taj način omogućena je određena kontrola korisničkih oznaka za koju nije potrebna intervencija u sustav od nekog stručnjaka, već je sama odluka o razini i tipu kontrole prepuštena samim korisnicima koji koriste sustav.

Kako je moguće stvarati liste knjiga te se okupljati u grupe korisnika, oko servisa se stvorila snažna korisnička zajednica te je na taj način katalogiziran velik broj knjiga te dodan velik

broj korisničkih oznaka, što čini LibraryThing pogodnim za provođenje različitih istraživanja vezanih uz korisničke oznake i ideju društvenog katalogiziranja.

4.3.4. Library of Congress Photostream

Prepoznavši mogućnosti korištenja društvenog softvera u povećanju vidljivosti i korištenju svojih zbirki, kao i mogućnostima otvaranja novih kanala komunikacije sa svojim korisnicima, u siječnju 2008. godine Kongresna knjižnica u Washingtonu pokrenula je pilot projekt opisivanja svojih fotografija na popularnom servisu za dijeljenje fotografija Flickr (http://www.loc.gov/rr/print/flickr_pilot.html). Knjižnica je inicijalno postavila oko 3000 fotografija (http://www.flickr.com/photos/library_of_congress) pozivajući javnost da im doda korisničke oznake i opiše ih. U prva 24 sata, slike su pogledane preko milijun puta, a do zaključenja pilot projekta u listopadu 2008. dodano je preko 60 000 korisničkih oznaka.
Ideja pilot projekta izražena je kroz tri strateška cilja (Library of Congress, 2008):

- povećati vidljivost dijeljenjem fotografija iz zbirke knjižnice s potencijalnim korisnicima, koji bi možda i htjeli pregledavati fotografije, ali ne posjećuju mrežnu stranicu knjižnice
- dobiti uvid u bolje razumijevanje načina na koji korisničko označivanje i doprinos zajednice može donijeti korist, kako knjižnici, tako i korisnicima
- steći iskustvo u sudjelovanju u novim mrežnim zajednicama koje nalaze interes u materijalima koje knjižnica posjeduje.

Pilot projekt pokazao se veoma uspješnim. Dodano je ukupno 67 176 oznaka samim fotografijama, fotografije su pogledane više od 10 milijuna puta, a u dodavanju oznaka sudjelovalo je preko 2500 različitih korisnika. Pokazalo se kako je za dodavanje 40% svih korisničkih oznaka odgovorno samo 10 korisnika, koji su se pokazali iznimno motiviranima te je svaki dodao preko 3000 oznaka, dok je čak 500 korisnika dodalo samo jednu oznaku. Tako se na empirijskim podacima još jednom potvrdila ideja da je u baštinskom okruženju prisutan specifičan tip nabave iz mnoštva, gdje u većini slučajeva ne pomaže mnoštvo, već manja skupina amatera istraživača, a njihov doprinos je intrinzično motiviran i ne smatra se poslom u tom smislu (de Boer et al., 2012).
Jedan od rezultata samog projekta je i pokretanje Flickr Commons projekta – inicijative Kongresne knjižnice u kojoj se potiče članove Flickr zajednice na interakciju s digitaliziranim

objektima baštine, koji nisu zaštićeni autorskim pravima (https://www.flickr.com/commons). Projekt ima dva osnovna cilja: (1) poboljšati pristup javno dostupnim zbirkama fotografija i (2) pružiti način na koji se javnost može uključiti u prikupljanje informacija i stvaranje novog znanja (https://www.flickr.com/commons#faq).

U projekt je trenutno uključeno preko 90 prestižnih institucija iz cijelog svijeta, od Danske kraljevske knjižnice, Škotske nacionalne knjižnice pa do Getty istraživačkog instituta i NASA-e (https://www.flickr.com/commons/institutions/).

4.3.5. Brooklyn Museum

Jedan je od prvih muzeja koji je implementirao igru kao način prikupljanja korisničkih oznaka bio Brooklyn Museum. Od 2008. godine muzej je prikupljao korisničke oznake preko igre nazvane *Tag! You're It!* te je već u prvih 10 mjeseci prikupio oko 60 000 oznaka (Cairns, 2013). Kako bi eliminirao oznake koje su netočne ili nisu relevantne, muzej je iskoristio mudrost mnoštva implementirajući sustav glasanja na jedinstven način. Pomoću opcije *Freeze Tag!*, registrirani korisnici su mogli predložiti koju oznaku žele izbrisati, a ako se dvoje ili više drugih članova složilo, oznaka je bila uklonjena iz opisa predmeta. S druge strane, ako bi najmanje troje drugih članova predložilo vraćanje oznake, ona bi ponovno bila uključena u opis. Od 2010. muzej je razvio i igru za mobilne uređaje *Gallery Tag!* koja je omogućavala korisnicima interakciju sa zbirkom unutar samog galerijskog prostora. Dok fizički posjećuju izložbu, korisnici su mogli putem mobilne aplikacije dodavati korisničke oznake samim djelima skupljajući bodove. Dodane oznake tako bi se dodavale samim djelima u mrežnom okruženju, povezujući tako virtualni i stvarni prostor izložbe putem komunikacije s korisnikom (Cairns, 2013).

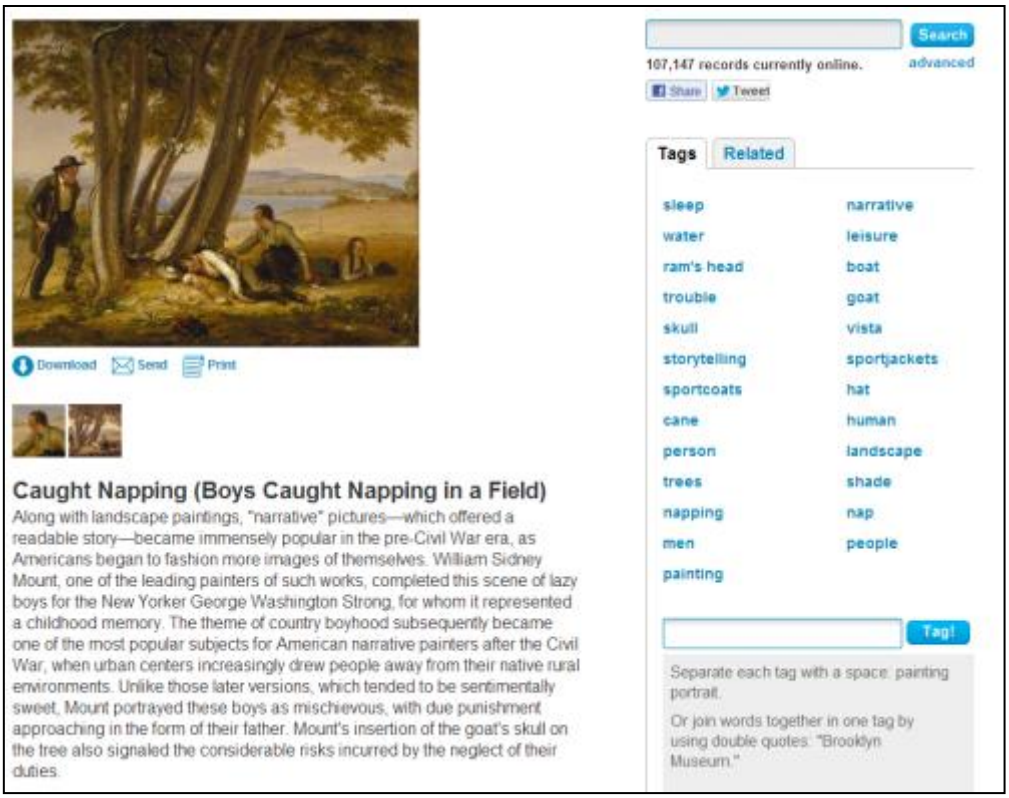

Slika 47 - Dodavanje korisničkih oznaka predmetu unutar virtualne zbirke Brooklyn Museuma

Razvijene igre više nisu aktivne (http://www.brooklynmuseum.org/opencollection/tag_game/), a kroz njih je zbirci dodano više od 230 000 korisničkih oznaka. Muzej je implementirao dodavanje korisničkih oznaka kao mogućnost unutar svoje virtualne zbirke (Slika 47).

5. Istraživanje korisničkog označivanja u opisu baštinske građe

Nakon pruženih teorijskih okvira, unutra kojeg djeluje korisničko označivanje kao specifičan pristup predmetnoj obradi digitalnih objekata, te dodavanjem okvira funkcioniranja korištenja kolektivne inteligencije i aktivnosti nabave iz mnoštva unutar baštinskog okruženja, u ovom poglavlju predstavljeni su rezultati poduzetog istraživanja.

Pregled literature i kategorizacija dosadašnjih istraživanja omogućila je i jasnije postavljanje istraživačkog problema ove disertacije, gdje se njen fokus usmjerava na potencijal primjene korisničkog označivanja u predmetnom opisu baštinske građe, što spada u četvrtu kategoriju analize (**Istraživanje izvora** (poboljšanje pristupa) - *radovi koji proučavaju upotrebu korisničkog označivanja kao metode poboljšanja pristupa, pretrage, navigacije ili personalizacije informacijskih sustava, kao i poboljšanja opisa i komplementiranja tradicionalnim sustavima za organizaciju znanja*), ali dodaje i novi aspekt baštinske građe kao predmeta opisa.

5.1. Plan istraživanja

Cilj istraživanja bio je ispitati pristupe primjeni korisničkih oznaka u standardni predmetni opis baštinske građe, kao protutežu i dopunu tradicionalnim modelima organizacije informacija.

Plan istraživanja sastojao se od tri komplementarne faze:

1. **Prikupljanje korpusa oznaka metodom nabave iz mnoštva**
2. **Statistička, lingvistička i funkcionalna analiza korpusa korisničkih oznaka**
3. **Ispitivanje razlika u pristupu korisničkom označivanju tradicionalnih vrsta građe u AKM ustanovama**
    a. **Usporedba predmetnica dodanih od strane predmetnih stručnjaka i prikupljenih korisničkih oznaka**
    b. **Ocjena korisnosti prikupljenih korisničkih oznaka od strane predmetnog stručnjaka.**

Svaka od faza obrađuje se u zasebnom poglavlju, uz prikaz metodologije, teorijskih postavki i rezultata.

5.2. Hipoteze

Kroz 3 faze istraživanja pristupilo se testiranju dviju hipoteza:

H1: Korisničke oznake donose naznake novih elemenata opisa koji nisu prisutni u tradicionalnom predmetnom pristupu

Hipoteza H1 testirana je kroz lingvističku analizu prikupljenog korpusa korisničkih oznaka na hrvatskom jeziku, čime se nastojalo prihvatiti ili odbaciti postojanje elemenata opisa koje dodaju korisničke oznake, a koje nisu prisutne u tradicionalnom predmetnom pristupu.

H2: Potencijal korisničkih oznaka kao predmetnih pristupnica pokazuje posebnosti s obzirom na vrstu građe koja se prikuplja u baštinskim ustanovama

Hipoteza H2 testirana je kroz tri različita aspekta analize i kroz 3 povezane hipoteze.

H2a Postoji značajna razlika u kvantitativnim pokazateljima prikupljenog korpusa korisničkih oznaka na razini različitih vrsta građe

Hipoteza H2a testirana je statističkom analizom prikupljenog korpusa korisničkih oznaka, kako bi se analizirale razlike na kvantitativnoj razini između različitih vrsta građe.

H2b: Postoji značajna razlika u mjeri preklapanja između predmetnica dodanih od strane stručnjaka i prikupljenih korisničkih oznaka na razini različitih vrsta građe

Hipoteza H2b testirana je usporedbom predmetnica dodanih od strane predmetnih stručnjaka i prikupljenih korisničkih oznaka na sintaktičkoj razini.

H2c: Postoji značajna razlika u ocjeni prikladnosti korisničkih oznaka za predmetni opis od strane predmetnog stručnjaka

Hipoteza H2c testirana je ocjenom korisnosti prikupljenih oznaka na razini predmeta u predmetnom opisu različitih vrsta građe od strane predmetnog stručnjaka.

5.3. Materijali

Kako bi se omogućilo testiranje hipoteze H2, bilo je potrebno izabrati materijale koji predstavljaju tradicionalne vrste građe, koja se prikuplja u svakoj od baštinskih ustanova. Kako bi se zadovoljila ta pretpostavka, izabrani materijali podijeljeni su na:

- **arhivsku građu** (20 skeniranih arhivskih dokumenata)
- **muzejsku građu** (20 digitaliziranih muzejskih izložaka)
- **knjižničnu građu** (20 skeniranih naslovnica knjiga s kataložnim opisima)
- **fotografije** (20 skeniranih fotografija).

Ovdje treba napomenuti kako su predložene kategorije i materijali odabrani na teorijskoj razini, kako bi omogućili međusobnu usporedbu, dok je u praksi granica između različitih vrsta građe teško vidljiva pa je čest slučaj da svaka od baštinskih institucija, bila ona arhiv, knjižnica ili muzej, zapravo sadrži u svojim zbirkama sve vrste navedene građe.

Uz razdvajanje materijala prema vrstama, kao jedna od pretpostavki bila je okupljanje materijala oko neke teme, kako bi se analiza mogla provoditi na razini zbirke (prema vrsti građe) te pojedinačnih predmeta.

Kao primarni izvor arhivskih i muzejskih materijala, korišten je katalog i materijali izložbe *Domovinski rat*, održane u Hrvatskom povijesnom muzeju od 1.12. 2011. – 30.9.2012., autora Matee Brstilo Rešetar, Ivice Nevešćanina i Andreje Smetko (Domovinski rat: katalog izložbe, 2013), dok su knjižnični materijali izabrani od monografija vezanih uz temu Domovinskog rata dostupnih u katalogu Knjižnice Hrvatskog Sabora.

Detaljan popis svih materijala s pripadajućim opisima, skeniranim fotografijama i predmetnicama nalazi se u Prilogu 1 *(Popis arhivske, knjižnične i muzejske građe korištene u istraživanju*), dok su u nastavku po jedan od primjera svake vrste materijala i pripadajućih opisa iz kataloga izložbe radi ilustracije. Samim opisima iz kataloga izložbe, dodane su i predmetnice kojima je opisan u mrežnom katalogu muzeja, dok su knjižničnoj građi dodane predmetnice iz mrežnog kataloga knjižnice Hrvatskog Sabora.

5.4. Prikupljanje korpusa oznaka

Nakon određivanja osnovnih materijala istraživanja i segmentiranja prema vrsti, pristupilo se prikupljanju korpusa oznaka na hrvatskom jeziku. Osnovna pretpostavka uspješnog istraživanja bila je prikupljanje dovoljnog broja korisničkih oznaka na hrvatskom jeziku na kojima se mogu testirati predložene hipoteze. Kako bi se prikupio potreban broj korisničkih oznaka na hrvatskom jeziku, za potrebe istraživanja kreirano je rješenje kojim će se moći prikupiti korpus oznaka na materijalima koje baštinske ustanove tradicionalno prikupljaju.

5.4.1. Kreiranje aplikacije za prikupljanje oznaka

Pregledom dostupnih rješenja, odabrano je rješenje otvorenog koda *Metadata Games* (http://www.metadatagames.org) razvijeno od strane fakulteta Dartmouth (http://dartmouth.edu/), točnije njihovog studija za razvijanje aplikacija Tiltfactor (http://www.tiltfactor.org/) koje koristi oblik igre kako bi prikupio podatke o materijalima u baštinskim ustanovama. Kako sami autori aplikacije pišu:„..Ideja iza projekta *Metadata Games* je kako se igre i igrom upravljane aktivnosti mogu koristiti kako bi privukli publiku na sudjelovanje u pružanju korisnih deskriptivnih metapodataka…takav pristup u obliku igre privlači sudionike i olakšava proces prikupljanja korisničkih oznaka na način ugodan za korisnika“ (Flanagan i Carini, 2012).

Upravo je u tome bila i ideja iza korištenja igre kao medija za prikupljanje oznaka. Naime, kako je za potrebe istraživanja minimalan predviđeni broj oznaka postavljen na 2000 oznaka, teško je bilo očekivati kako bi neko rješenje koje uključuje jednostavno upisivanje pojmova imalo zadovoljavajući odjek u smislu motivacije ispitanika u upisivanju oznaka za 80 predviđenih objekata, te bi bilo veoma zamorno postavi li se u obliku standardnog anketnog upitnika.

Sama aplikacija *Metadata Games* zapravo je skup alata koji su usmjereni prikupljanju korisničkih opisa fotografija, videa ili audio zapisa, kako bi time pridonijeli boljem opisu samih predmeta unutar zbirke. Namijenjena je korisnicima koje se potiče na sudjelovanje, institucijama koje se potiče na pružanje materijala za opis i razvojnim programerima kako bi implementirali postojeća i razvijali nove mogućnosti samog alata.

Izvorni kod alata dostupan je pod AGPL v3+ licencom (http://www.gnu.org/licenses/agpl-3.0.html) na adresi https://github.com/tiltfactor/, a potpuni popis uvjeta korištenja aplikacije dostupan je na adresi http://www.metadatagames.org/terms/.

Aplikacija radi na LAMP programskom paketu (linux, apache, mysql, php) i bila je implementirana na serveru Odsjeka za informacijske i komunikacijske znanosti, prevedena na hrvatski jezik i prilagođena potrebama istraživanja (http://faust.ffzg.hr/metadatagames/www/index.php).

5.4.2. Opis aplikacije za prikupljanje podataka

Cijeli proces dodavanja oznaka s korisničke strane počinje kreiranjem vlastitog profila koji je prilagođen, kako bi se okvirom registracije prikupljali i demografski podaci o igračima (Slika 48).

Slika 48 - Proces registracije i stvaranje profila

Korisnici su trebali izabrati korisničko ime i lozinku te upisati adresu e-pošte. U procesu prikupljanja demografskih podataka, svaki je korisnik upisao svoj spol, dob, razinu i područje

obrazovanja. Nakon registracije, korisnici su mogli aktivirati svoj korisnički račun i početi igrati igru.

Sam paket alata sastoji se od nekoliko različitih igara, od kojih je za potrebe istraživanja implementirana igra pod nazivom *ZenTag* – najjednostavniji oblik igre u kojoj korisnik opisuje predmete upisujući pojmove u polje ispod slike (Slika 49).

Slika 49 - Sučelje igre ZenTag korištene za prikupljanje korisničkih oznaka u istraživanju

Samo sučelje je prevedeno na hrvatski jezik i prilagođeno te se sastoji od 5 osnovnih elemenata:

- **upute za igranje** koje objašnjavaju što se traži od igrača, kako postići bodove te dodatnih uputa
- **slika i pripadajuće polje ispod slike** unutar kojeg se unose korisničke oznake
- **podaci o trenutnoj igri,** koji navode ime korisnika, broj bodova, broj bodova u trenutno pokrenutoj igri te broj slike na kojoj se igrač nalazi
- **opcija za propuštanje slike** kojom se može preskočiti prikazani objekt

- **podatak o autorskom pravu** koji navodi vlasništvo i uvjete korištenja materijala na stranici.

Aplikacija omogućuje određivanje broja slika koje će se prikazivati u jednoj igri, te je ona u slučaju istraživanja bila postavljena na 6 slika u jednoj igri koje su nasumce birane iz predefiniranih materijala. Nakon završene igre, korisnik dobiva povratnu informaciju o svojim bodovima i upisanim oznakama te može započeti novu igru (Slika 50).

Slika 50 - Ekran nakon završene igre

Kako bi se stvorila određena natjecateljska atmosfera i motiviralo igrače, na početnoj stranici aplikacije stajao je popis sa 10 najboljih igrača, kao i znački koje su postigli (Slika 51).

Najboljih 10 igrača

Igrač	Rezultat	Broj pokušaja
Lili22	888	7
delusive	870	4
tockica	794	8
lily	648	4
pipistrelic	608	3
Jean d'Arc	572	3
dsusa	550	2
MiniBee	538	10
Nina	528	6
Maric77	472	28

Vaši rezultati

Igra	Rezultat	Broj pokušaja
Domovinski rat	12	13

Vaše značke

Amater (100) Istraživač (500) Znanstvenik (1000) Mudrac (2000)

Slika 51 - Popis najboljih igrača i osvojenih znački

Značke su podijeljene na 4 razine: *Amater* (100 bodova), *Istraživač* (500 bodova), *Znanstvenik* (1000 bodova) te *Mudrac* (2000 bodova), te ih korisnici dobivaju postizanjem bodova.

Sam proces upisivanja pojmova reguliran je s dvije upute igračima koje se nalaze na lijevoj strani same stranice sa igrom:

(1) Kako bi se potaknulo upisivanje pojmova relevantnih za samu sliku koja se upisuje, uputa za igranje uključivala je i podatak o tome kako se za svaki novi pojam koji se doda nekom objektu dobiva 2, dok se za svaki pojam koji su upisali i drugi korisnici dobiva 4 boda. To je značilo da korisnici moraju razmisliti što bi drugi igrači upisali kao opisni pojam kod nekog objekta i tako oblikovati svoje pojmove, što podrazumijeva veću povezanost samih oznaka i predmeta koji se opisuju.

(2) Kako bi se upisane oznake ravnomjerno rasporedile između opisivanih predmeta, igračima je preporučeno da, ukoliko dobiju predmet koji su već opisivali, preskoče ga koristeći opciju "PRESKOČI SLIKU".

Aplikacija ima opciju zabrane pojavljivanja slike koja se već pojavljivala i ona je postavljena na interval od 30 sekundi, ali se to ne odnosi na situaciju kada se počinje nova igra pa je bilo moguće u kratkom periodu dobiti dva ista predmeta.

Osim korisničkog sučelja, aplikacija nudi i administratorsko sučelje u okviru kojeg se može upravljati različitim aspektima same aplikacije (Slika 52).

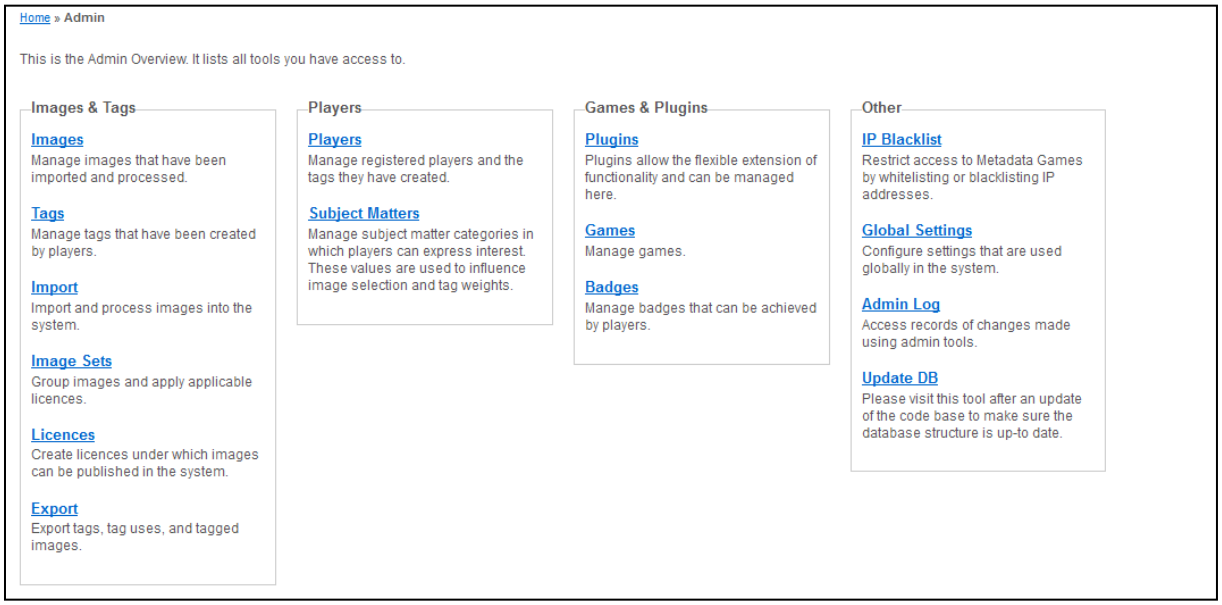

Slika 52 - Administratorsko sučelje aplikacije za prikupljanje podataka

Administratorsko sučelje nudi mogućnost upravljanja materijalima, oznakama, igračima, igrama i različitim drugim opcijama koje su potrebne u korištenju i prilagođavanju aplikacije potrebama neke institucije.

5.4.3. Demografska analiza igrača

Nakon odabira programskog rješenja i prilagođavanja aplikacije vlastitim materijalima, igra je putem različitih mailing lista distribuirana potencijalnim korisnicima, tj. igračima. Igra je bila aktivna u razdoblju od 1.7.2014. – 1.8.2014. nakon čega je aplikacija postala neaktivna.

U razdoblju od 30 dana igri je pristupilo 185 registriranih igrača, od kojih je njih 147 bilo aktivno (igrači koji su dodali barem jednu oznaku). Detaljni podaci nalaze se u Prilogu 2 (*Demografski podaci o igračima*), dok se u nastavku donose grafički prikazi pojedinih analiza.

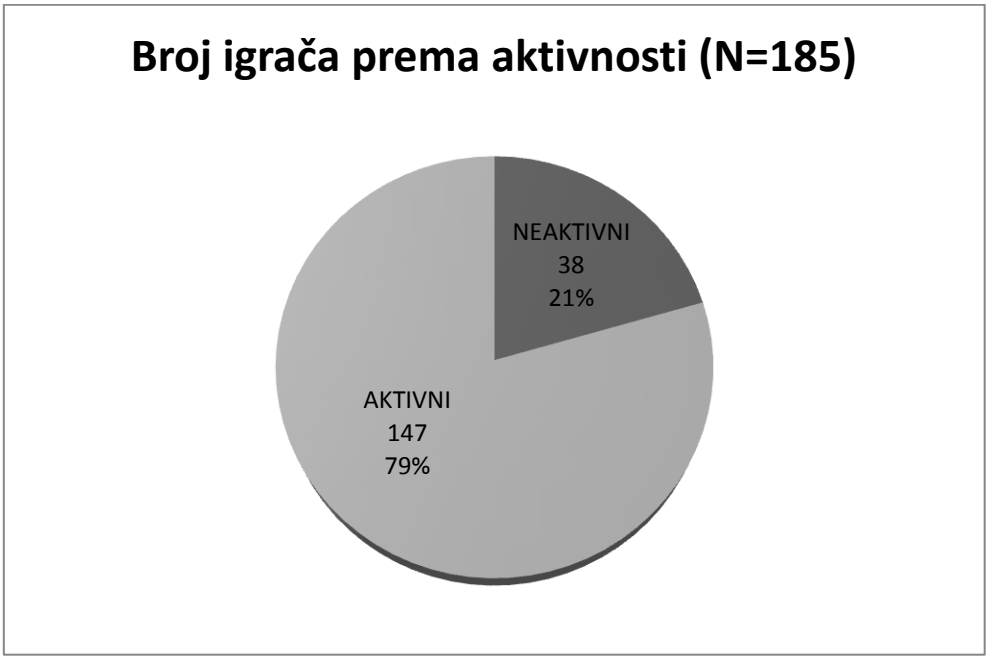

Slika 53 - Broj igrača prema aktivnosti

Kao što vidimo iz prikaza, oko 20% igrača se registriralo, ali je bilo potpuno neaktivno i nije dodalo nijedan opis (Slika 53).

Kako je putem aplikacije bilo moguće opisivati predmete i dodavati oznake i bez registracije, značajan broj oznaka dodan je i od strane gostiju (Slika 54).

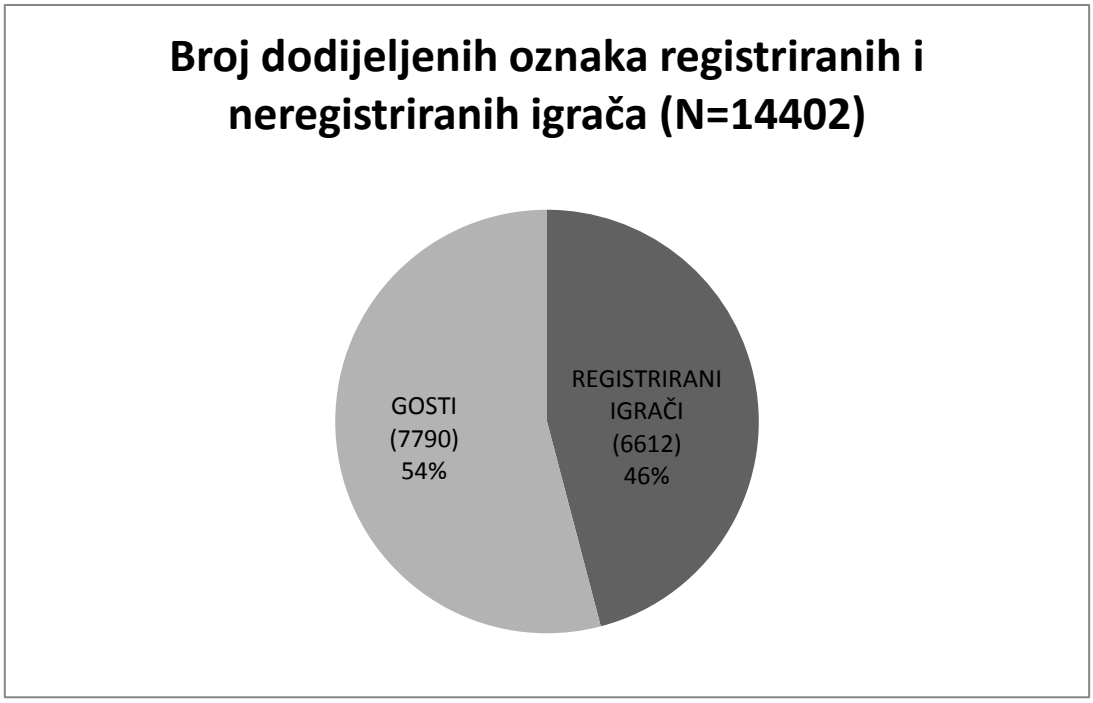

Slika 54 - Broj dodanih oznaka registriranih i neregistriranih igrača

Ovdje vidimo kako je više od 50% dodanih oznaka zapravo dodano od igrača čiju demografsku sliku ne poznajemo. Uzmemo li u obzir da je tijekom diseminacije obavijesti bilo naglašeno kako je, iako se igri može pristupiti i bez registracije, preporučeni način igranja ipak registracija, kako bi se mogli dobiti osnovni demografski podaci tijekom procesa registracije, više od 50% oznaka dodali su igrači koji se nisu registrirali. To pokazuje kako je vrlo vjerojatno u realnim uvjetima očekivati da igrači preferiraju dodavati opise bez registracije.

Daljnja demografska analiza odnosi se na aktivne igrače, tj. na uzorak od 147 igrača. Tijekom registracije bilježeni su osnovni demografski podaci čiji se rezultati donose u nastavku.

Tablica 9 donosi podatke o uzorku od 6612 dodjeljivanja od strane registriranih korisnika, kako bi se dobio uvid u obrasce dodjeljivanja.

Tablica 9 - Kvantitativni podaci o oznakama dodanima od strane registriranih korisnika

BROJ IGRAČA	**147**
BROJ DODIJELJENIH OZNAKA	6612
PROSJEK	44.5
MAX	235
MIN	1
STDEV	47.4

Kao što vidimo iz tablice, postoji veoma velika razlika između maksimalnog i minimalnog broja oznaka koji je dodao neki korisnik, što pokazuje i mjera standardne devijacije (STDEV). Slika 55 pokazuje razdiobu dodanih oznaka prema broju dodjeljivanja od strane pojedinog korisnika.

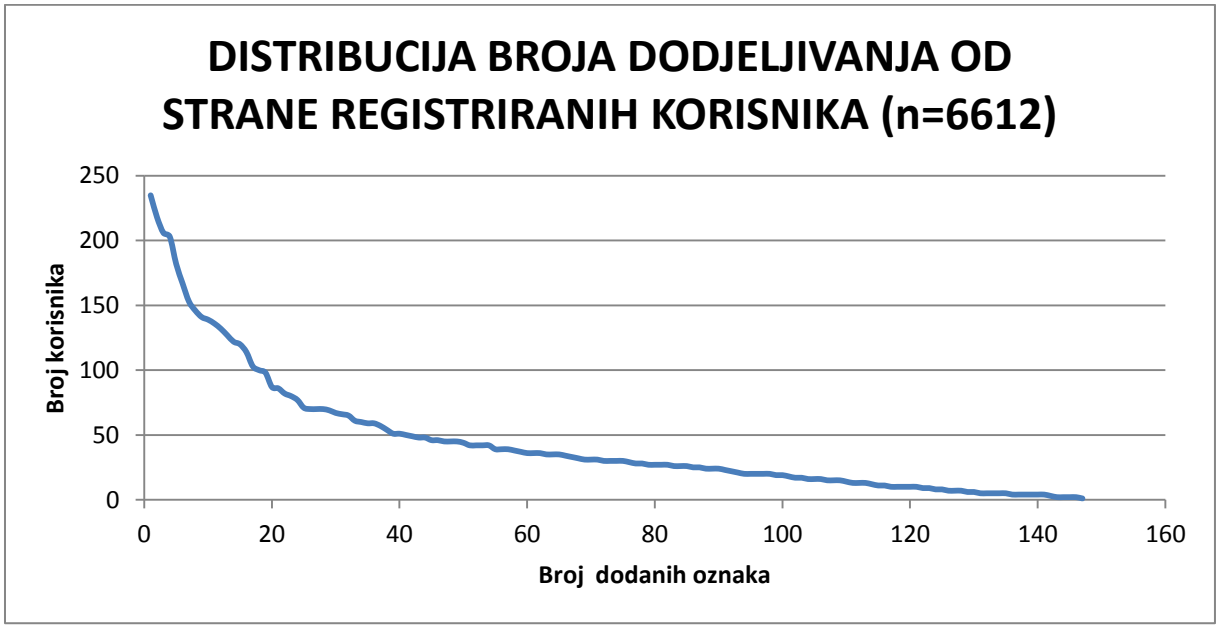

Slika 55 - Distribucija dodijeljenih oznaka od strane registriranih korisnika

Podaci pokazuju kako postoji manji broj korisnika koji su dodali veći broj oznaka, te veći broj njih koji su dodali malen broj oznaka, što potvrđuje pojavu *power usera*, gdje se pokazalo kako razdioba broja dodjeljivanja oznaka od strane korisnika također slijedi *power law* razdiobu.

Detaljni podaci u Prilogu 2 (*Demografski podaci o igračima*) potvrđuju takav zaključak i pokazuju kako je 20 korisnika koji su dodali najveći broj oznaka (14%) odgovoran za čak 44% svih oznaka (2929).

Sljedeći podatak koji se bilježio o igračima, podatak je o spolu (Slika 56).

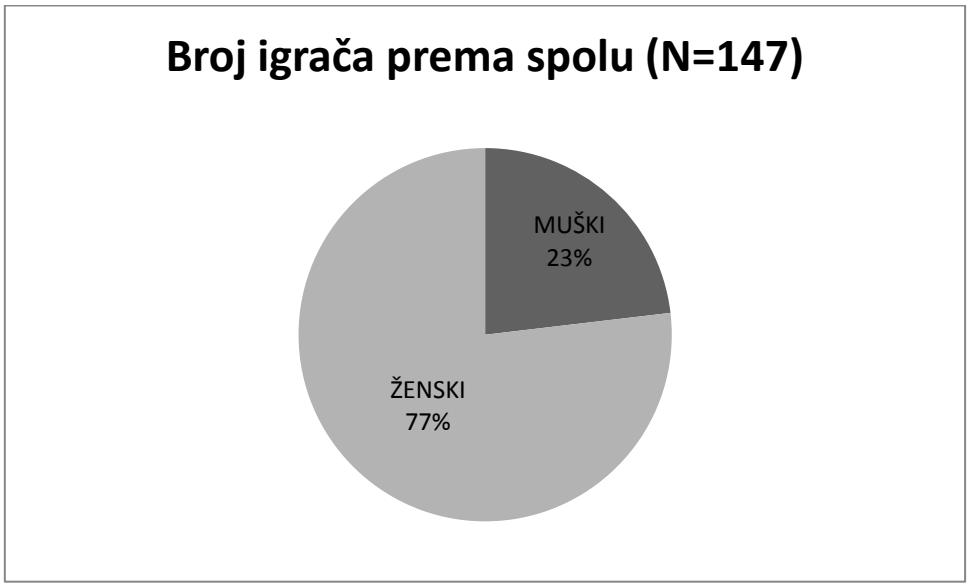

Slika 56 - Broj igrača prema spolu

Pokazalo se kako je više od 2/3 registriranih igrača bilo ženskog spola (77%), što je u skladu s recentnim istraživanjima koje pokazuju porast broja žena koje igraju neku od vrsta video igara, te kako je značajno veći broj žena koje igraju edukativne igre nego što je to broj muškaraca (ESA, 2014).

Sljedeći podatak koji se bilježio tijekom registracije, podatak je o dobi igrača (Slika 57).

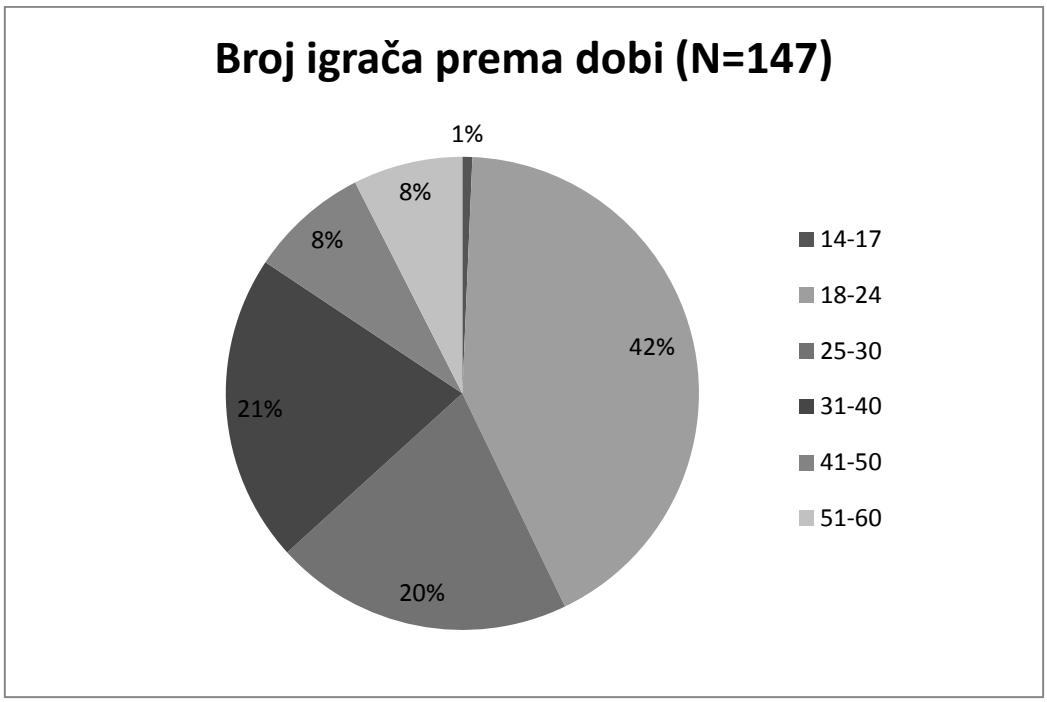

Slika 57 - Broj igrača prema dobi

Podaci pokazuju kako je najveći broj igrača bilo u dobi od 18-24 godine (42%), a značajan je broj i igrača u dobi od 25-30 godina (20%) te od 31-40 godina (20%). Kako je istraživanje distribuirano između ostalog i među studentima Filozofskog fakulteta, očekivana je veća populacija sudionika koji su u rasponu između 18 i 30 godina, što se pokazalo točnim gdje 62% sudionika spada u tu dobnu kategoriju.

Dodamo li tim podacima i podatke o razini obrazovanja na kojoj se trenutno sudionici nalaze, (Slika 58) vidljiva je velika uloga studentske populacije u samom istraživanju.

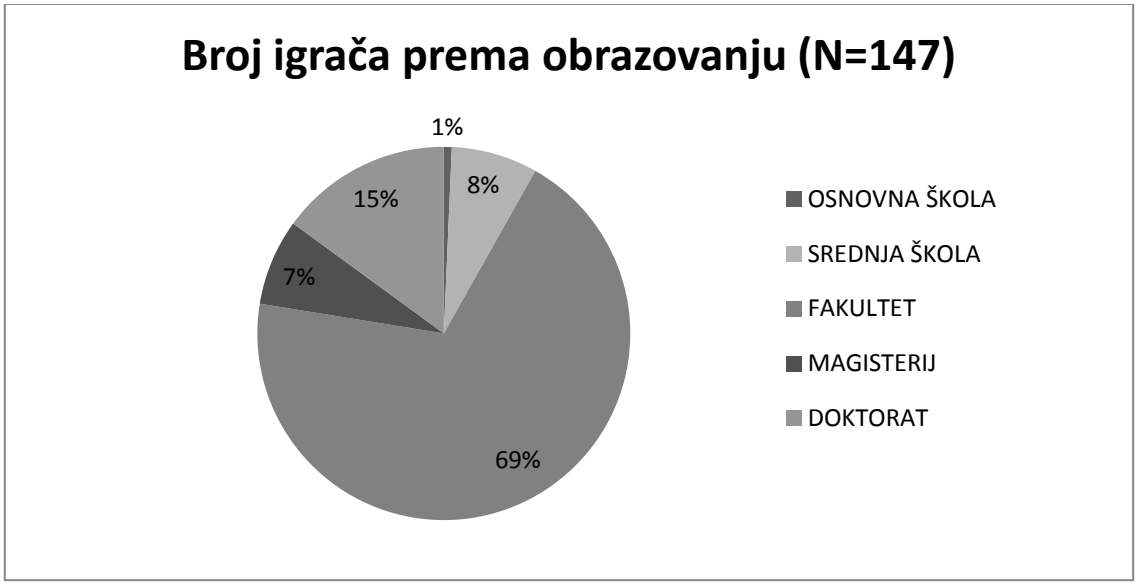

Slika 58 - Broj igrača prema obrazovanju

Podaci o registriranim korisnicima pokazuju kako je najveći broj sudionika istraživanja završio ili trenutno pohađa fakultet (69%), a značajan je i broj sudionika koji su završili ili trenutno pohađaju doktorski studij (15%). Opet, kako je diseminacija obavijesti o istraživanju bila putem mailing lista, od kojih je jedna i ona doktorskih studenata Odsjeka za informacijske i komunikacijske znanosti, očekivao se značajan broj sudionika koji su trenutno na doktorskom studiju.

Posljednji bilježeni podatak obuhvaćao je područje u kojem su se sudionici obrazovali ili se trenutno obrazuju (Slika 59).

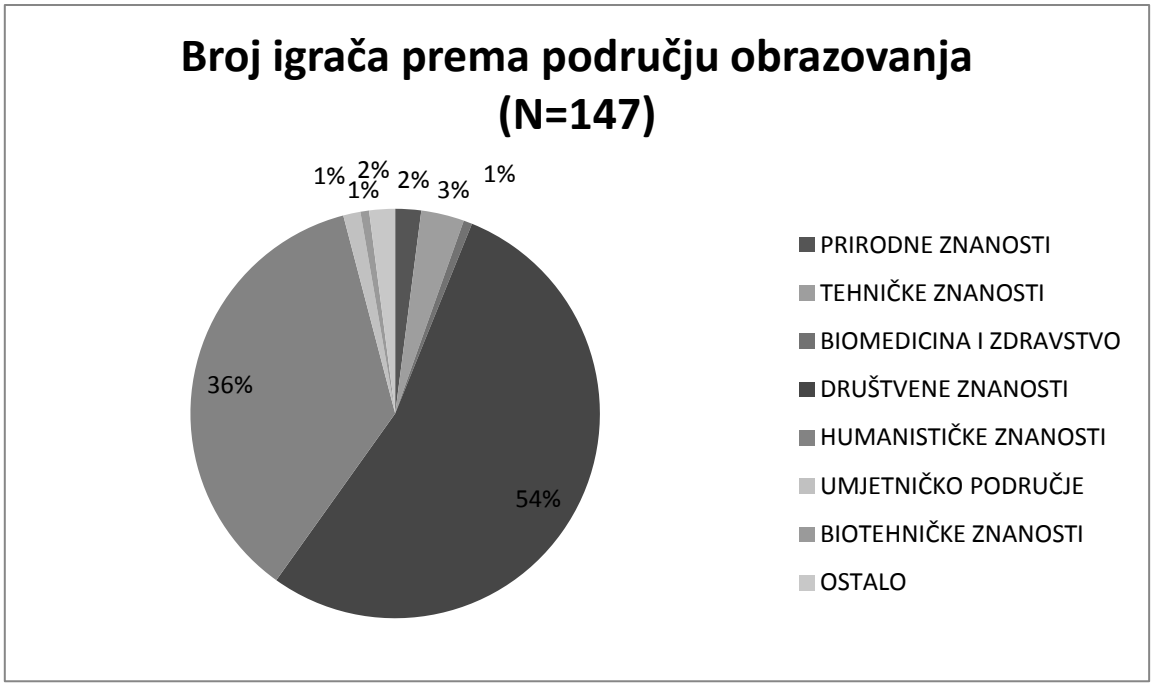

Slika 59 - Broj igrača prema području obrazovanja

Kao što je jasno vidljivo iz podataka, gotovo svi sudionici dolaze iz društveno-humanističkog područja (90%), što je i očekivano.

5.5. Analiza korpusa oznaka

Analiza korpusa prikupljenih korisničkih oznaka provedena je na tri razine:

1) statistička analiza (kvantitativni podaci)
2) lingvistička analiza (formalna analiza vezana uz gramatička obilježja)
3) značenjska analiza (sadržajna analiza vezana uz sadržaj i značenje).

5.5.1. Statistička analiza

Statistička analiza odnosila se na ispitivanje kvantitativnih osobina prikupljenog korpusa. U razdoblju od 1.7.2014. - 1.8.2014. putem aplikacije je ukupno dodijeljeno 14402 korisničke oznake na uzorku od 80 predmeta. Kvantitativne osobine prikupljenog korpusa analizirane su algoritamskim rješenjem kreiranim u programu Python 2.7 (Prilog 5 - *Python programsko rješenje*).

Radi lakšeg grafičkog prikaza podataka, vrstama građe su dodane kratice prema legendi:

ARH - arhivska građa (20 skeniranih arhivskih dokumenata)
MUZ - muzejska građa (20 digitaliziranih muzejskih izložaka)
KNJ - knjižnična građa (20 skeniranih naslovnica knjiga s kataložnim opisima)
FOTO - fotografije (20 skeniranih fotografija).

Takav način bilježenja sustavno će se koristiti u svim grafičkim prikazima koji se odnose na prikaz podataka o vrstama građe.

Prilog 3 (*Broj dodjeljivanja i dodanih oznaka prema vrstama građe*) donosi tablice s potpunim podacima, dok Tablica 10 donosi sumirane podatke o broju dodjeljivanja s osnovnim statističkim pokazateljima.

Tablica 10 - Sumirani podaci o broju dodjeljivanja prema vrstama građe

VRSTA GRAĐE	BROJ DODJELJIVANJA	MAX	MIN	PROSJEK	STDEV
MUZ	2976	239	64	148.8	52.71
KNJ	3818	332	83	190.9	74.39
FOTO	4484	454	114	224.2	86.97
ARH	3124	320	98	156.2	59.36
UKUPNO	**14402**	**454**	**83**	**180**	**68.36**

Slika 60 grafički prikazuje broj dodjeljivanja oznaka prema vrstama građe i broju.

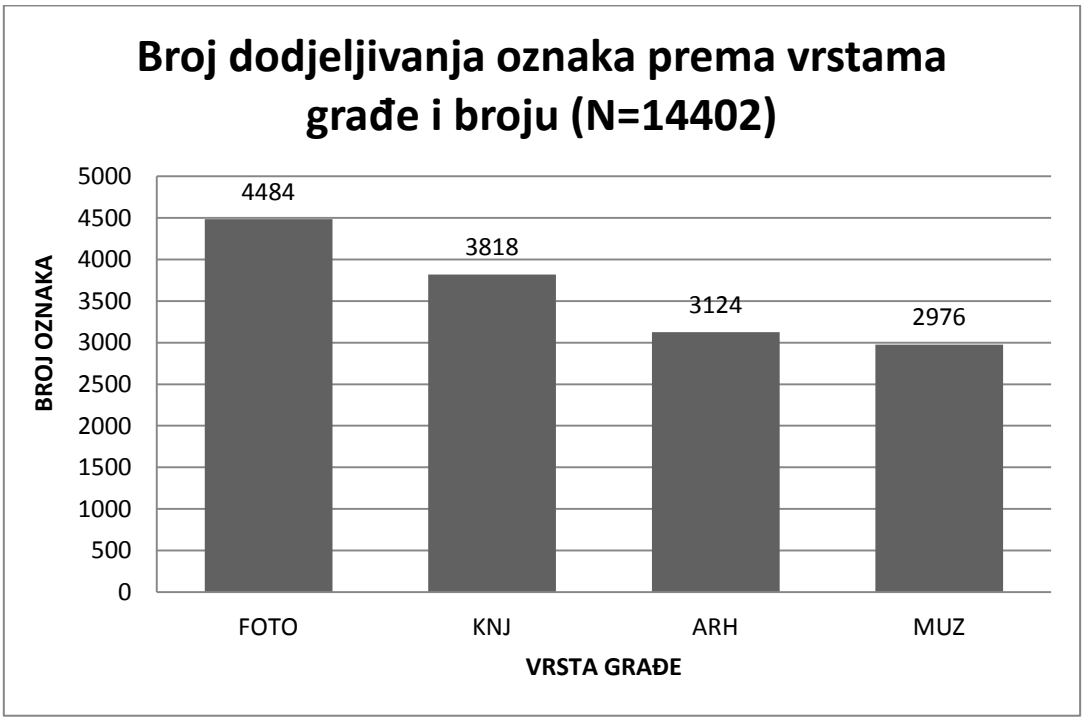

Slika 60 - Broj dodjeljivanja oznaka prema vrstama građe i broju

Kako vidimo iz prikaza, od ukupno 14402 dodijeljene korisničke oznake, najveći broj u prikupljenom korpusu dodijeljen je fotografijama (31%), zatim knjižničnoj građi (26%) te arhivskoj (22%) i muzejskoj (21%).

Prikažemo li distribuciju frekvencije na razini broja dodjeljivanja pojedine oznake (Slika 61), možemo vidjeti kako frekvencijska distribucija slijedi modele u literaturi (Shirky, 2003; Vander Wal, 2005; Munk i Mork, 2007; Heymann, Koutrika i Garcia-Molina, 2007) koji pokazuju kako tipična razdioba korisničkih oznaka dodijeljenih jednom izvoru pokazuje obilježja tipične *power law* krivulje.

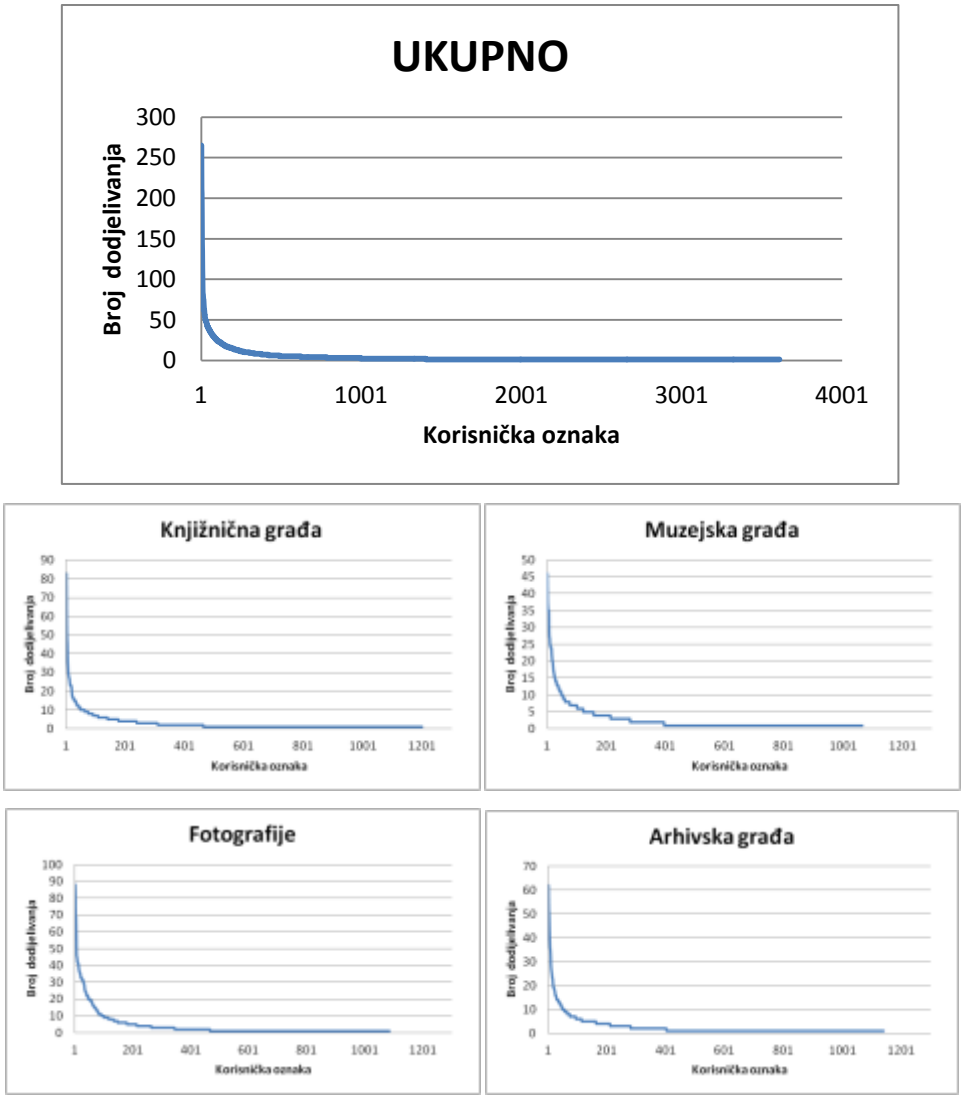

Slika 61 - Frekvencijska razdioba broja dodjeljivanja korisničkih oznaka prema vrstama građe

Kao što vidimo, pokazalo se kako na razini frekvencije pojedinih oznaka, postoji mali broj oznaka koje su često dodane (velike frekvencije) i velik broj oznaka koje su dodane samo jednom (niska frekvencija).

Uz broj dodjeljivanja koji uključuje i frekvenciju dodijeljenih oznaka, važno je prikazati i udio dodanih oznaka, tj. broj oznaka na razini predmeta bez podatka o frekvenciji. Na primjer, nekom predmetu mogla je biti dodana ista oznaka veći broj puta od strane različitih korisnika (npr. oznaka „rat“ dodana 15 puta istom predmetu), te bi zbrajanje svih frekvencija dodjeljivanja iznosilo ukupan broj dodjeljivanja te oznake na razini predmeta, a sumirani podaci za sve predmete dali bi pokazatelj na razini zbirke. Na taj način bi ukupan broj dodjeljivanja oznake „rat“ u ovom slučaju iznosio 15.

Broj dodanih oznaka označava pak broj oznaka dodanih nekom predmetu, bez podatka o broju dodavanja. Na taj način, iako oznaka „rat“ ima 15 dodjeljivanja od strane različitih korisnika, na razini predmeta broji se samo jednom, a zbrajanjem broja takvih oznaka dobiva se broj dodanih oznaka nekom predmetu.

Prilog 2 donosi tablicu s ukupnim podacima, dok Tablica 11 donosi sumirane podatke o dodanim oznakama s osnovnim statističkim pokazateljima.

Tablica 11 - Sumirani podaci o dodanim oznakama prema vrstama građe

VRSTA GRAĐE	BROJ DODANIH OZNAKA	MAX	MIN	PROSJEK	STDEV
MUZ	1403	111	33	70.15	23.77
KNJ	1803	128	43	90.15	20.76
FOTO	1811	129	56	90.55	21.08
ARH	1571	169	54	78.55	25.13
UKUPNO	**6588**	**169**	**33**	**82.35**	**22.69**

Analiziramo li grafički raspodjelu dodanih oznaka prema vrstama građe (Slika 62), možemo vidjeti kako raspodjela broja dodanih oznaka odgovara broju dodjeljivanja, tj. što je više dodjeljivanja nekoj vrsti građe, veći je i broj dodanih oznaka, ali su razlike između dodanih oznaka znatno smanjene.

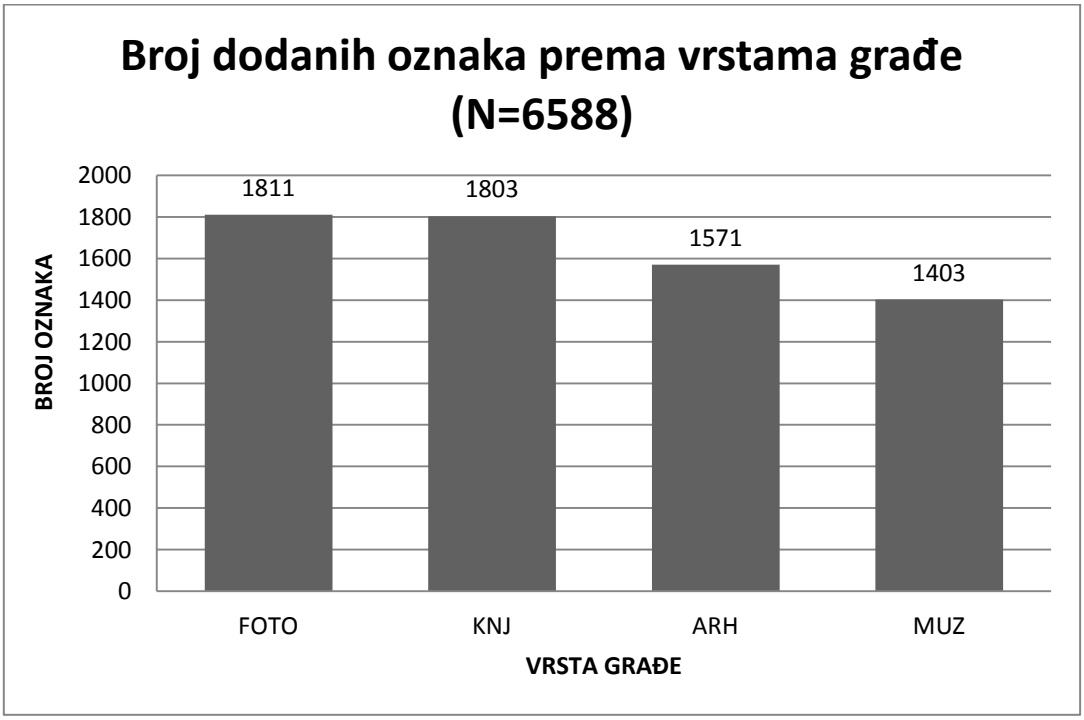

Slika 62 - Broj dodanih oznaka prema vrstama građe

Od ukupno 6588 dodanih oznaka, najviše je oznaka dodano fotografijama i knjižničnoj građi (27%), zatim arhivskoj građi (24%) te muzejskoj (22%).

Usporedimo li broj dodjeljivanja s brojem dodanih oznaka (Slika 63), možemo vidjeti kako je od ukupno 14402 dodijeljene oznake na razini predmeta, njih 46% (6588) bilo jedinstvenih.

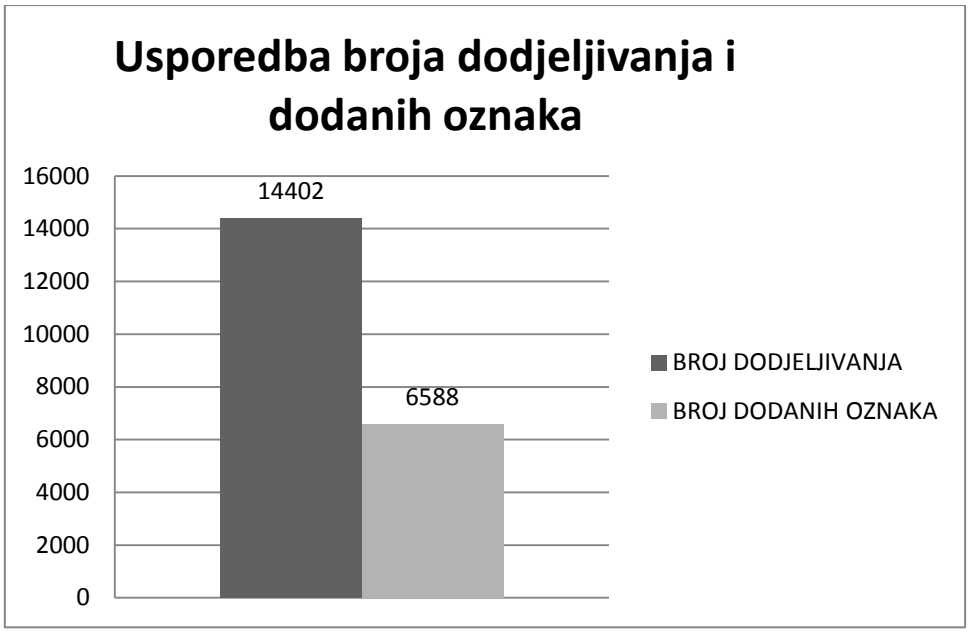

Slika 63 - Udio dodanih oznaka u broju dodjeljivanja na razini predmeta

Kako bi se vidjela raspodjela udjela dodanih oznaka po različitim vrstama predmeta, i u tom smislu pokazalo kolika je veličina korisničkog rječnika bila potrebna za opis neke zbirke predmeta, Slika 64 prikazuje sumirane podatke prema zbirkama, broju dodjeljivanja te broju dodanih oznaka.

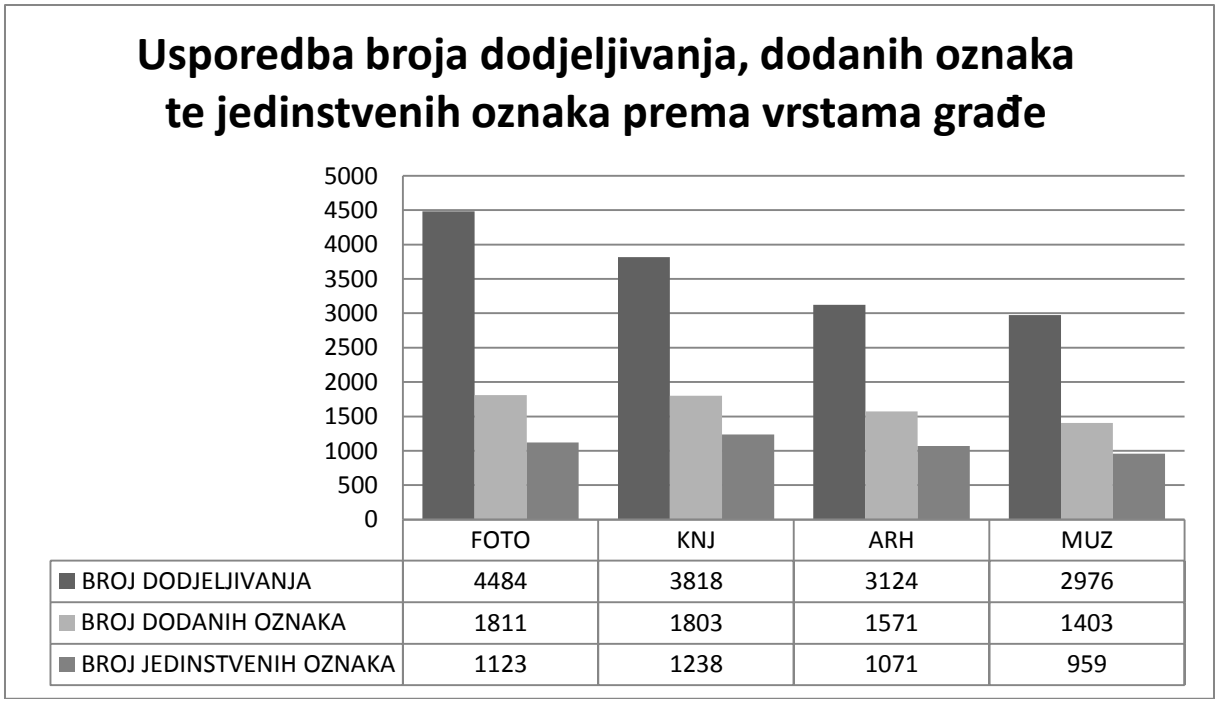

Slika 64 - Broj dodjeljivanja, dodanih oznaka te jedinstvenih oznaka prema vrstama građe

Iako možemo vidjeti kako, na razini zbirke, veći broj dodjeljivanja uvjetuje i veći broj dodanih oznaka, što je i logična pretpostavka, udjeli po vrstama građe pokazuju značajna odstupanja. Tako udio dodanih oznaka varira od 40% (1811) kod fotografija, preko 47% kod knjižnične i muzejske građe 47% (1803 i 1403), do 50% kod arhivske građe (1571).

Usporedimo li broj dodjeljivanja i broj dodanih oznaka, možemo vidjeti kako, iako je broj dodjeljivanja fotografijama značajno veći od broja dodjeljivanja ostalim vrstama predmeta (za 5-10% ili od 666 za knjižničnu građu pa do 1508 za muzejsku građu), on nije uvjetovao i značajnije povećanje broja oznaka prema vrstama.

Na primjer, iako su fotografije imale čak 1508 dodjeljivanja (10%) više od muzejske građe, usporedba broja dodanih oznaka pokazuje upola manju razliku od samo 408 oznaka (5%).

Ovdje možemo odmah uočiti određeni obrazac koji može upućivati na činjenicu kako, nakon nekog broja korpusa riječi kojima korisnici opisuju zbirku, povećanje broja dodjeljivanja neće uvjetovati ujedno i povećanje u samom korisničkom rječniku, već samo frekvenciju već postojećih oznaka. U tom pogledu, možemo vidjeti indikacije potrebnog uzorka dodanih korisničkih oznaka nakon kojeg više nema značajnog povećanja rječničke baze, već samo raste frekvencija dodjeljivanja istih oznaka.

Kako bismo mogli detaljnije analizirati obrasce povezanosti broja dodjeljivanja i dodanih oznaka na razini povećanja korisničkog rječnika, izvršena je analiza korelacije između dobivenih setova podataka. U ovome dijelu, osim broja dodjeljivanja i broja dodanih oznaka,

dodan je i podatak o jedinstvenim oznakama unutar seta dodanih oznaka (tj. oznake čija je frekvencija 1). Takve oznake zapravo su indikator povećanja baze riječi kojima se opisuje neki predmet ili neka zbirka. Naime, kod opisa predmeta, korisnik je suočen s 2 izbora: odabrati već postojeću oznaku unutar sustava i time povećati njenu frekvenciju ili dodati oznaku koja još ne postoji unutar sustava i time povećati rječničku bazu. Tablica 12 pokazuje koeficijent korelacije između broj dodjeljivanja i broja dodanih oznaka prema vrstama građe.

Tablica 12 - Koeficijent korelacije između broja dodjeljivanja i broja dodanih oznaka prema vrstama građe

VRSTA GRAĐE	BROJ DODJELJIVANJA	BROJ DODANIH OZNAKA	KOEFICIJENT KORELACIJE
MUZ	2976	1403	**+0.66**
KNJ	3818	1803	**+0.50**
FOTO	4484	1811	**+0.50**
ARH	3124	1571	**+0.72**
UKUPNO	**14402**	**6588**	**+0.61**

Podaci na razini vrste građe pokazuju kako je najveća povezanost kod arhivske građe (0.7), dok je najmanja kod knjižnične građe (0.5).

Grafički prikaz odnosa između broja dodjeljivanja i dodanih oznaka na razini predmeta (Slika 65) jasno pokazuje kako je broj dodjeljivanja u jasnoj korelaciji sa brojem dodanih oznaka.

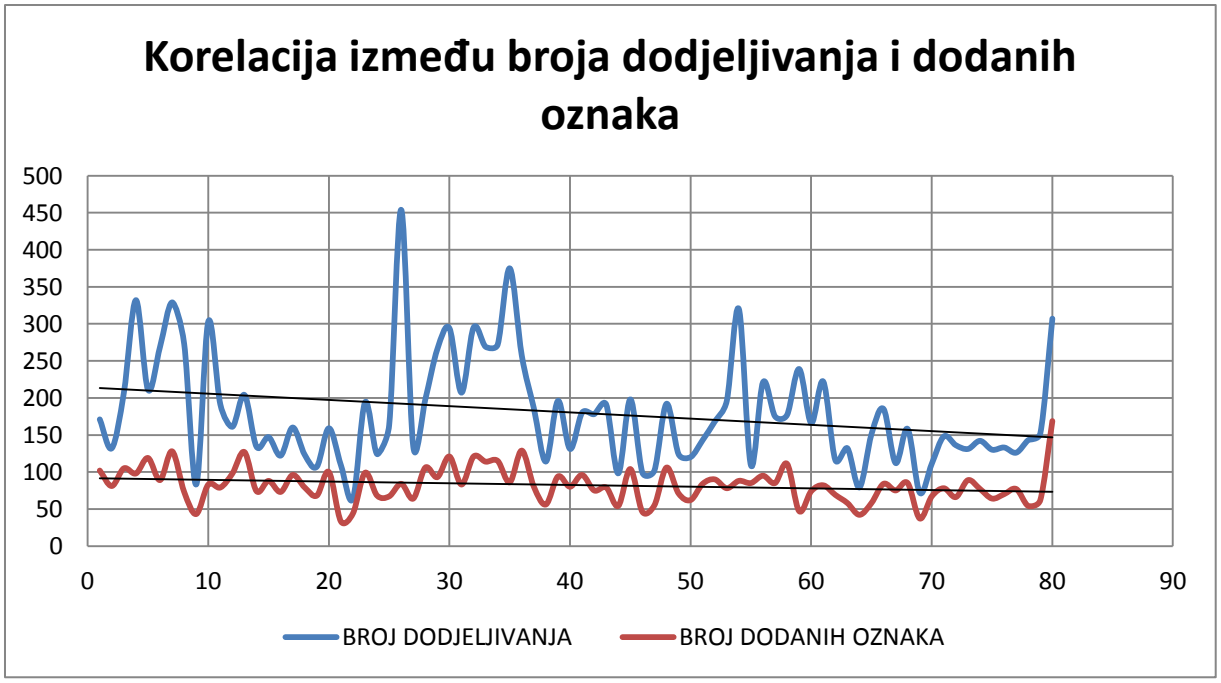

Slika 65 - Korelacija između broja dodjeljivanja i broja dodanih oznaka na razini predmeta

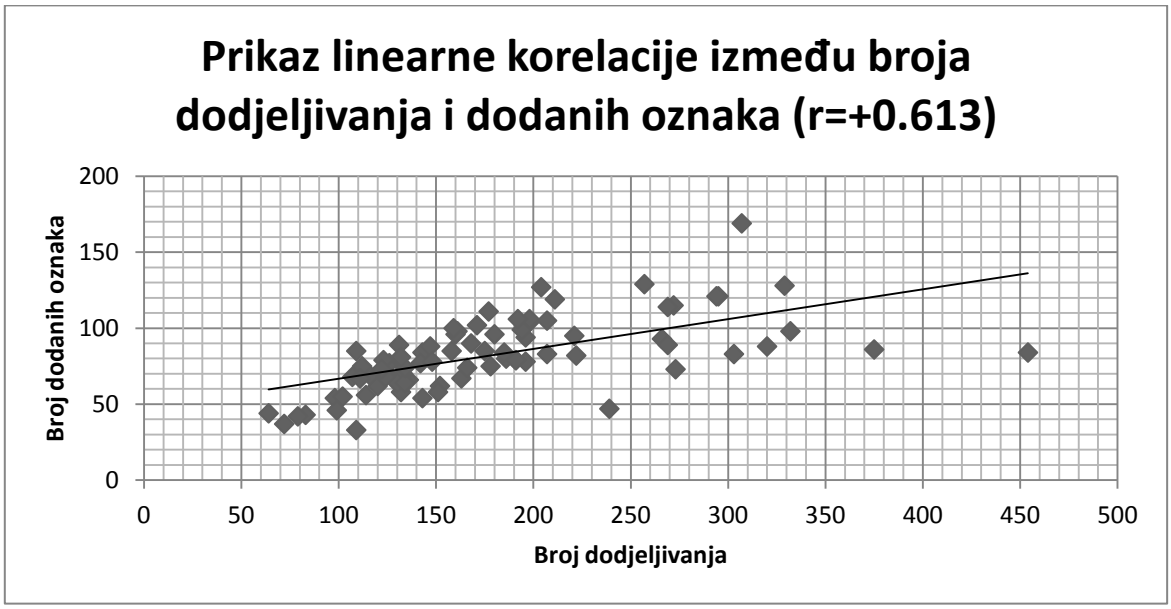

Slika 66 - Prikaz linearne korelacije između broja dodjeljivanja i broja dodijeljenih oznaka na razini predmeta

Izračunavanjem koeficijenta korelacije, koji iznosi 0.613, i grafičkim prikazom pokazuje se kako je povezanost između promatranih setova podataka uzlazno pozitivna, između umjerene (+0.5) i snažne (+0.7) korelacije (Slika 66). Rezultati pokazuju kako je broj dodjeljivanja pozitivno povezan s brojem dodanih oznaka, odnosno veći broj dodjeljivanja ujedno će rezultirati i većim brojem dodanih oznaka.

Druga analiza usporedila je povezanost između broja dodanih oznaka i broja jedinstvenih dodanih oznaka (Tablica 13).

Tablica 13 - Koeficijent korelacije između broja dodanih oznaka i broja jedinstvenih dodanih oznaka prema vrstama građe

VRSTA GRAĐE	BROJ DODANIH OZNAKA	BROJ JEDINSTVENIH DODANIH OZNAKA (FREKVENCIJA=1)	KOEFICIJENT KORELACIJE
MUZ	1403	**959**	**+0.94**
KNJ	1803	**1238**	**+0.89**
FOTO	1811	**1123**	**+0.78**
ARH	1571	**1071**	**+0.92**
UKUPNO	**6588**	**4391**	**+0.88**

Podaci na razini vrste građe pokazuju kako je najveća povezanost kod arhivske građe (0.92), dok je najmanja kod knjižnične građe (0.89), ali sve vrste građe pokazuju vrlo snažnu povezanost.

Grafički prikaz odnosa između broja dodanih oznaka i broja jedinstvenih oznaka na razini predmeta (Slika 67) jasno pokazuje kako je broj dodanih oznaka u snažnoj korelaciji s brojem oznaka frekvencije 1.

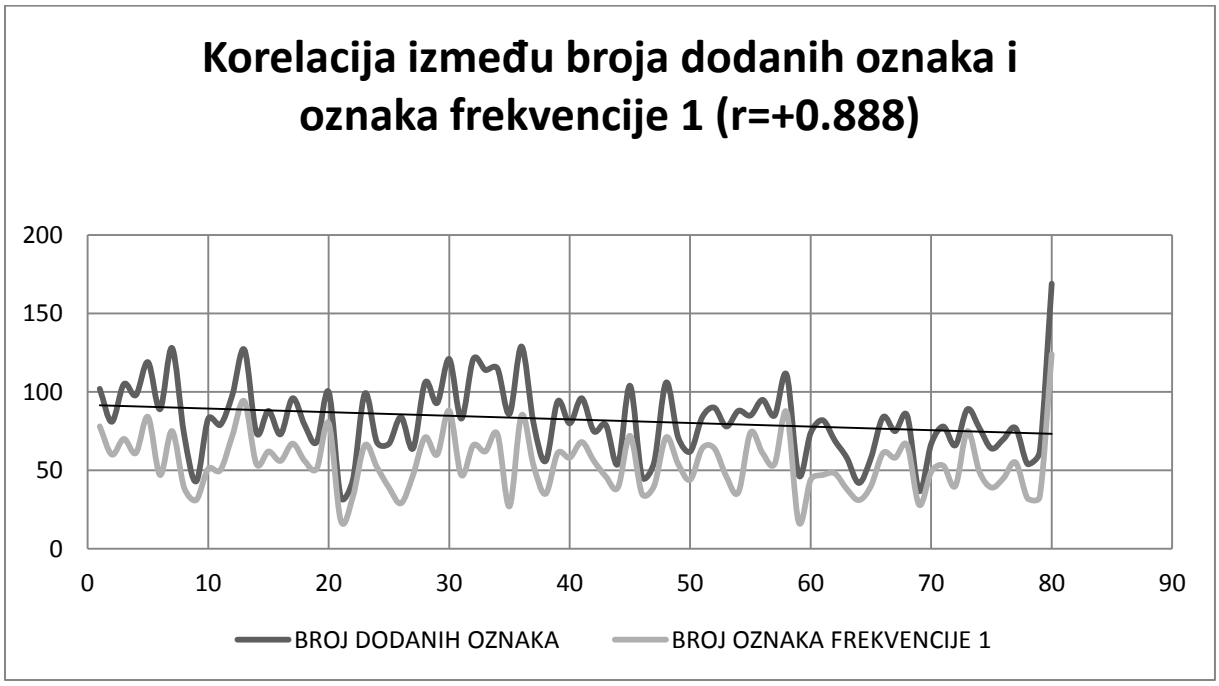

Slika 67 - Odnos između broja dodanih oznaka i broja jedinstvenih oznaka na razini predmeta

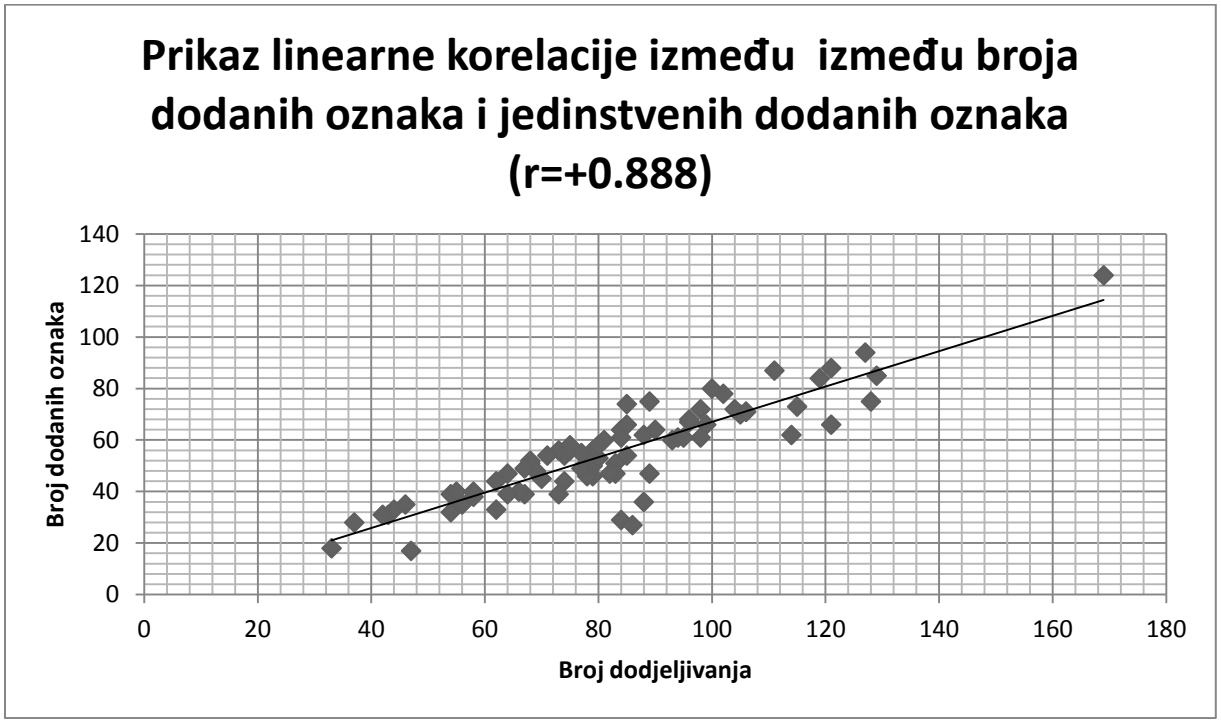

Slika 68 - Prikaz linearne korelacije između broja dodanih oznaka i broja jedinstvenih dodanih oznaka na razini predmeta

Izračunavanjem koeficijenta korelacije, koji iznosi 0.888, i grafičkim prikazom pokazuje se kako je povezanost između promatranih setova podataka uzlazno pozitivna, odnosno snažne korelacije (Slika 68). Rezultati pokazuju kako je broj dodanih oznaka snažno povezan s brojem jedinstvenih dodanih oznaka, odnosno veći broj dodanih oznaka ujedno će rezultirati i većim brojem jedinstvenih dodanih oznaka, tj. oznaka frekvencije 1.

Treća analiza usporedila je povezanost broja dodjeljivanja i broja jedinstvenih oznaka na razini predmeta, kako bi se utvrdilo hoće li veći broj dodjeljivanja na razini predmeta ujedno i uvjetovati veći korisnički rječnik (broj jedinstvenih oznaka) (Tablica 14).

Tablica 14 - Koeficijent korelacije između broja dodjeljivanja i broja jedinstvenih dodanih oznaka prema vrstama građe

VRSTA GRAĐE	BROJ DODJELJIVANJA	BROJ JEDINSTVENIH DODANIH OZNAKA (FREKVENCIJA=1)	KOEFICIJENT KORELACIJE
MUZ	2976	**959**	**+0.41**
KNJ	3818	**1238**	**+0.12**
FOTO	4484	**1123**	**-0.05**
ARH	3124	**1071**	**+0.40**
UKUPNO	**14402**	**4391**	**+0.23**

Podaci na razini vrste građe pokazuju slabu povezanost kod muzejske i arhivske građe (+0.4) te ne pokazuje povezanost kod knjižnične građe (+0.12) niti kod fotografske (-0.05).

Grafički prikaz broja dodjeljivanja i broja jedinstvenih dodanih oznaka na razini predmeta (Slika 69) jasno pokazuje raspršenost podataka oko regresijskog pravca, čime se pokazuje kako je broj dodjeljivanja u slaboj korelaciji sa brojem dodanih oznaka.

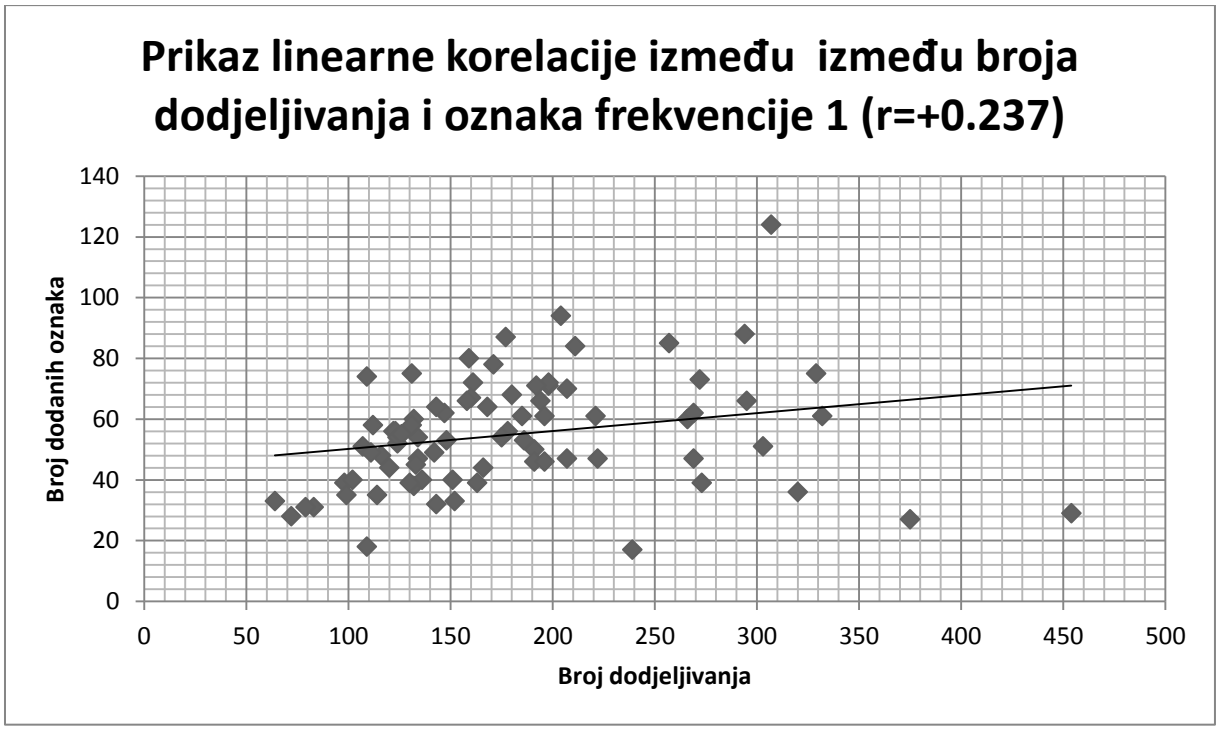

Slika 69 - Korelacija broja dodjeljivanja i broja jedinstvenih dodanih oznaka na razini predmeta

Na kraju, možemo sumirati podatke za sve tri usporedbe (Tablica 15).

Tablica 15 - Sumirani podaci o korelaciji između broja dodjeljivanja, broja dodanih oznaka i broja jedinstvenih oznaka na razini predmeta

	BROJ DODANIH OZNAKA
BROJ DODJELJIVANJA	**0.613**
	BROJ JEDINSTVENIH OZNAKA
BROJ DODANIH OZNAKA	**0.888**
	BROJ JEDINSTVENIH OZNAKA
BROJ DODJELJIVANJA	**0.237**

Provođenjem analize povezanosti mjerenjem korelacije želio se ispitati uočeni obrazac – kako, nakon nekog broja korpusa riječi kojima korisnici opisuju zbirku, povećanje broja dodjeljivanja neće uvjetovati ujedno i povećanje u samom korisničkom rječniku, već samo frekvenciju već postojećih oznaka.

Ispitivanjem povezanosti između prikupljenih setova podataka takva se pretpostavka i potvrdila jer se pokazalo kako, iako su broj dodjeljivanja i dodanih oznaka, kao i broj dodanih oznaka i broj jedinstvenih oznaka umjereno do snažno povezani, korelacija između broja dodjeljivanja i broja jedinstvenih oznaka nije se potvrdila.

Na temelju dobivenih podataka možemo zaključiti kako se na prikupljenom uzorku od 14402 dodijeljene oznake na 80 predmeta, pokazalo da veći broj dodjeljivanja nakon određene granice ne uvjetuje i proporcionalno povećavanje korisničkog rječnika.

Kao što možemo vidjeti na Slici 64 (*Broj dodjeljivanja i dodanih oznaka prema vrstama građe*), analiza pokazuje kako se korisnički rječnik u opisu jedne vrste građe definirao u okviru prosjeka od 1800 riječi (25% ukupnog broja dodjeljivanja), bez obzira što je broj dodjeljivanja jednoj vrsti građe bio značajno veći (u ovom slučaju fotografijama). Na temelju analize podataka možemo zaključiti kako, nakon prikupljenih 1800 dodanih oznaka na razini zbirke, nije bilo daljnjeg značajnog povećanja korisničkog rječnika, već se samo povećavala frekvencija već postojećih oznaka. Zaključujući u tom pogledu, možemo reći da prikupljanje minimalno 1800 dodanih oznaka na razini zbirke od 20 predmeta predstavlja optimalnu granicu na kojoj će se pokriti cijela baza korisničkog rječnika.

Nakon statističke analize prikupljenog korpusa oznaka na hrvatskom jeziku možemo izdvojiti sljedeće zaključke:

- ne postoji značajna razlika u broju dodjeljivanja na razini zbirke
- ne postoji značajna razlika u broju dodanih oznaka na razini zbirke
- broj dodjeljivanja je snažno pozitivno povezan s brojem dodanih oznaka
- broj dodanih oznaka je snažno pozitivno povezan s brojem jedinstvenih oznaka
- broj dodjeljivanja pokazuje slabu povezanost s brojem jedinstvenih oznaka
- prikupljanje minimalno 1800 dodanih oznaka na razini zbirke od 20 predmeta predstavlja optimalnu granicu na kojoj će se pokriti cijela baza korisničkog rječnika.

Statistička analiza prikupljenog korpusa korisničkih oznaka poduzeta je kako bi se uvidjele eventualne razlike na kvantitativnoj razini između različitih vrsta građe. U tom pogledu postavljena je hipoteza H2a.

H2a Postoji značajna razlika u kvantitativnim pokazateljima prikupljenog korpusa korisničkih oznaka na razini različitih vrsta građe

Nakon provedene statističke analize možemo zaključiti kako se na statističkoj razini nije pokazala značajna razlika u kvantitativnim pokazateljima prikupljenog korpusa korisničkih oznaka te hipoteza **nije dokazana**.

5.5.2. Lingvistička analiza

Druga razina analize prikupljenog korpusa korisničkih oznaka odnosila se na kvalitativnu analizu rječnika prikupljenog korpusa, kako bi se dobio uvid u osobine korisničkog rječnika na lingvističkoj razini.

Kao što je vidljivo iz pregleda postojećih istraživanja, postoji niz mogućih pristupa analizi oznaka, te je najprije bilo potrebno definirati kategorije analize. Pregledavanjem dostupnih istraživanja i analizom različitih pristupa, pokazalo se kako je za potrebe ovog istraživanja najprimjerenija kategorizacija korisničkih oznaka predložena u radu Heckner, Mühlbacher i Wolf (2008), koja je prilagođena za potrebe istraživanja korpusa oznaka na hrvatskom jeziku u radu Špiranec i Ivanjko (2012). Prilagođene kategorije analize korištene u ovome radu prikazane su na slici 70.

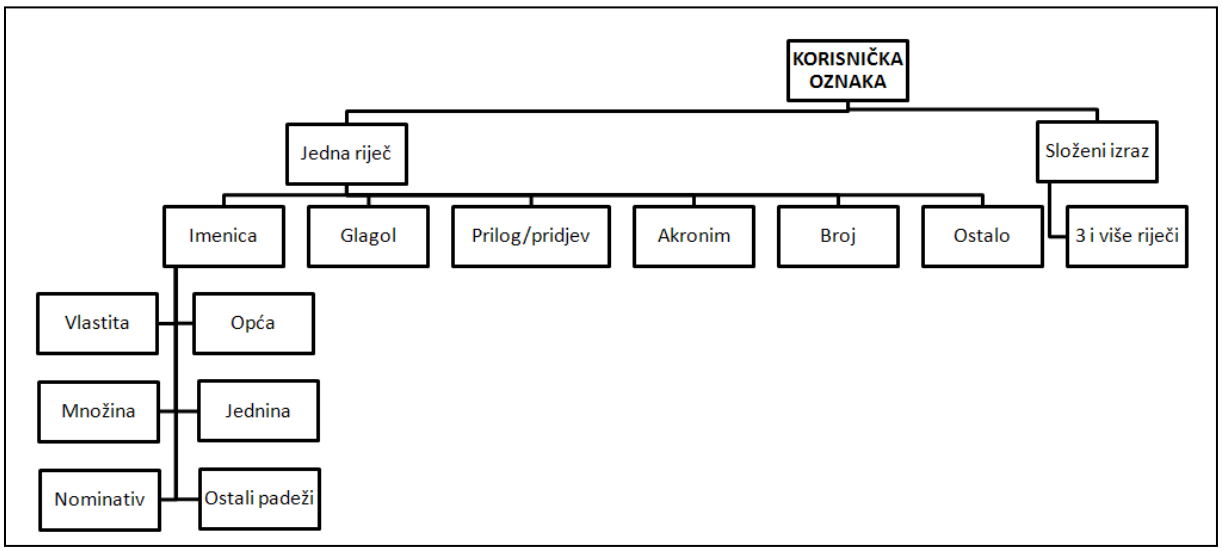

Slika 70 - Kategorije lingvističke analize.
Prilagođeni model prema Špiranec i Ivanjko (2012)

Kako je vidljivo iz implementiranog modela analize, osim analize prema broju riječi unutar same korisničke oznake, korisničke oznake su analizirane prema vrsti riječi, gdje su imenice dodatno analizirane prema vrsti, broju i padežu.

Analiza je provedena na korpusu od 6588 dodanih oznaka. Slika 71 prikazuje prvu razinu analize, prema broju riječi od kojih se sastoji pojedina oznaka.

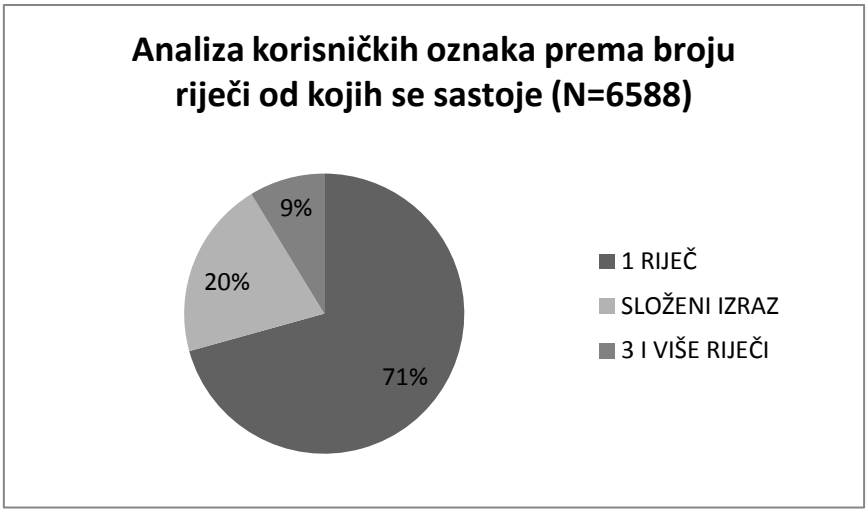

Slika 71 - Analiza korisničkih oznaka prema broju riječi od kojih se sastoje

Kao što je vidljivo iz podataka, najveći broj oznaka sastojao se od samo jedne riječi, dok je 91% korpusa bilo složeno od jedne riječi ili fraze (2 riječi).

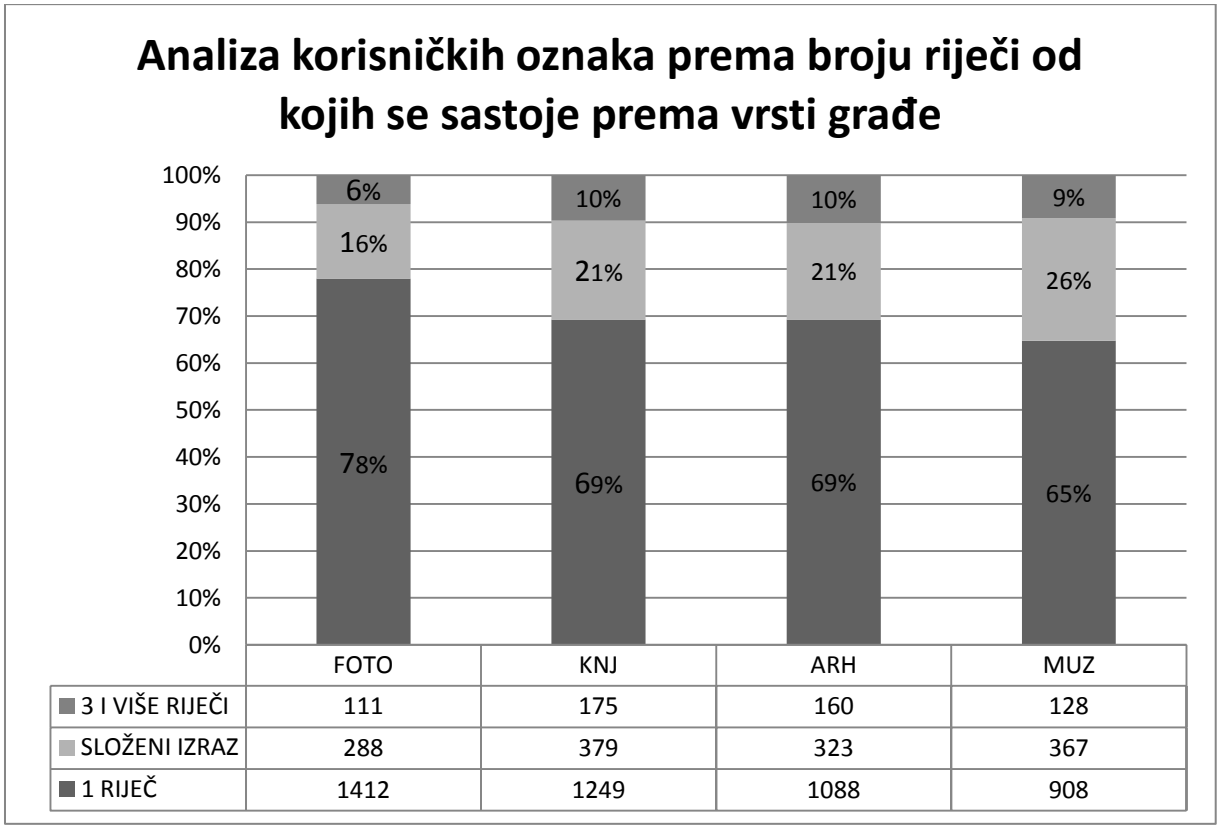

	FOTO	KNJ	ARH	MUZ
3 I VIŠE RIJEČI	111	175	160	128
SLOŽENI IZRAZ	288	379	323	367
1 RIJEČ	1412	1249	1088	908

Slika 72 - Analiza korisničkih oznaka prema broju riječi od kojih se sastoji prema vrsti građe

Analiza na razini vrste opisivane građe (slika 72) pokazala je kako su fotografije bile najviše opisivane jednom riječju, dok su ostale vrste građe imale podjednake udjele.

Sljedeća analiza odnosila se na vrste riječi kojima pripada pojedina korisnička oznaka.

Od ukupno 4657 dodanih oznaka na razini predmeta koje su se sastojale od jedne riječi, izbacivanjem istih oznaka koje se javljaju u opisu različitih predmeta, korpus je sveden na ukupno 2080 jedinstvenih oznaka od jedne riječi na razini korpusa prikupljenih oznaka na kojima je provedena analiza. Slika 73 prikazuje dobivene rezultate.

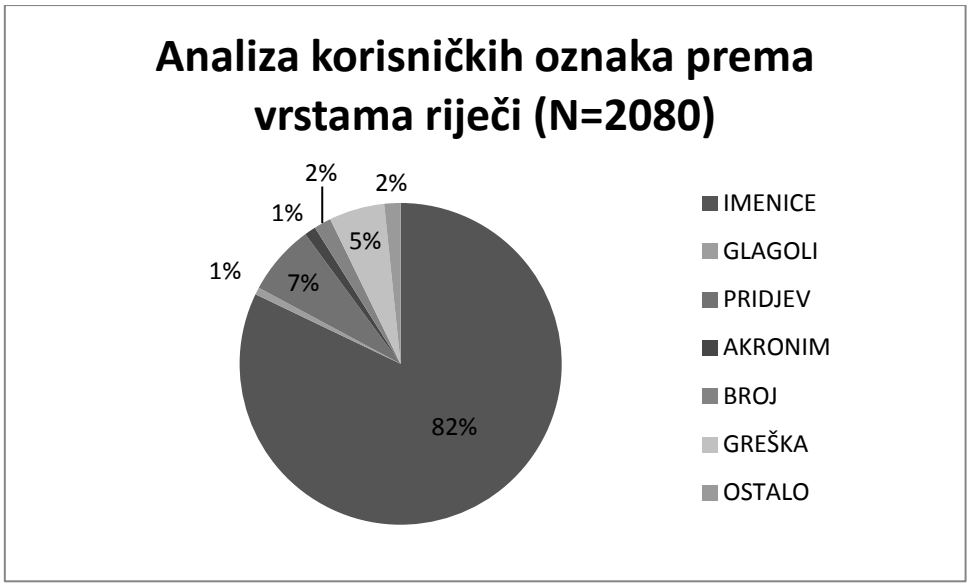

Slika 73 - Analiza korisničkih oznaka prema vrstama riječi

Kako vidimo na prikazu podataka, velika većina riječi pripada imenicama (82%), dok su od ostalih riječi samo pridjevi i greške prisutne u količini većoj od 5%.

Posljednja razina lingvističke analize odnosila se na analizu imenica prema vrsti, broju i rodu. Slika 74 prikazuje analizirane podatke.

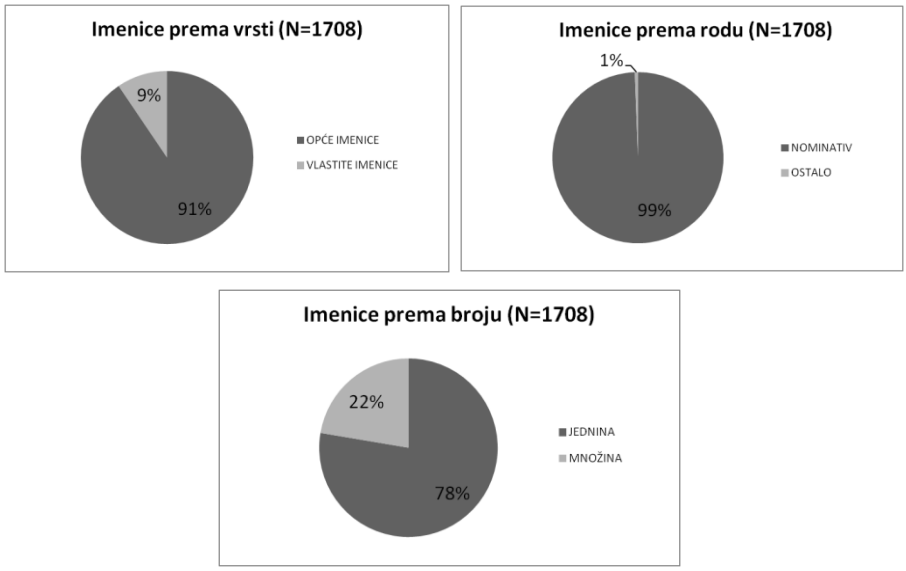

Slika 74 - Imenice prema vrsti, broju i rodu

Kako vidimo, većina korpusa imenica pripada općim imenicama (91%), jednini (78%) i nominativu (99%).

Nakon provedene analiza prikupljenog korpusa korisničkih oznaka na lingvističkoj razini, možemo sumirati podatke dobivene analizom

Na razini broja riječi od kojih se sastoji pojedina oznaka, pokazalo se kako se najveći broj oznaka sastojao se od samo jedne riječi, dok je 91% korpusa bilo složeno od jedne riječi ili fraze (2 riječi). Analiza na razini vrste građe nije pokazivala veća odstupanja od ukupnih udjela, gdje se pokazala slična raspodjela od 70%-20%-10% (jedna riječ – dvije riječi- tri i više riječi).

Što se tiče vrste riječi, pokazalo se kako je tipična oznaka imenica (82%), i to opća (91%) u jednini (78%) i nominativu (99%).

Slijedom navedenih podataka možemo testirati hipotezu H1, kojom se kroz lingvističku analizu prikupljenog korpusa korisničkih oznaka na hrvatskom jeziku identificira postojanje elemenata opisa, koje dodaju korisničke oznake, a koje nisu prisutne u tradicionalnom predmetnom pristupu:

H1: Korisničke oznake donose naznake novih elemenata opisa koji nisu prisutni u tradicionalnom predmetnom pristupu

Na temelju dobivenih podataka nema naznaka novih elemenata opisa te se **hipoteza odbacuje.**

5.5.3. Značenjska analiza

Treća razina analize odnosila se na analizu razine značenja na kojoj su dodane korisničke oznake vizualnim resursima. Kako smo već spomenuli, Panofsky je u svojim radovima razradio sustav interpretacije slikovnog materijala na tri razine značenja: preikonografskoj, ikonografskoj i ikonološkoj. Panofsky je svoju teoriju ikonološke analize razvio primarno na djelima renesansne umjetnosti Italije i sjeverne Europe (Baca, 2002; Panofsky, 1955) i namijenio je analizi umjetničkih djela. No razdvajanje objekata na ono od čega se sastoji, o čemu govori i koje mu je simboličko značenje može se primijeniti u području predmetne obrade primarno slikovnih izvora. Originalnu shemu koju je donio Panofsky razradila je Shatford (1986), koja je primijenila osnovne ideje na predmetni opis slikovne građe, preimenujući osnovne kategorije na generičku, specifičnu i apstraktnu razinu. Klenczoni i Rygiel (2014) donose primjer tri razine analize prema modelu Panofsky/Shatford na slici Leonarda da Vincija *Lady with an Ermine* (http://commons.wikimedia.org/wiki/File:Lady_with_an_Ermine.jpg) (Slika 75).

Pre-iconographic	woman, animal, jewelry
Iconographic	Cecilia Gallerani, ermine, necklace
Iconological	beauty, purity, aristocracy

Slika 75 - Tri razine analize prema modelu Panofsky/Shatford
(prema Klenczoni i Rygiel, 2014)

Prva razina odgovara generičkim pojmovima (žena, životinja, nakit), druga specifičnim pojmovima koji dodatno specificiraju generičke pojmove (ime portretirane osobe (Cecilia Gallerani), vrsta životinje (lasica), vrsta nakita (ogrlica)), dok se treća razina odnosi na apstraktne pojmove povezane s izvorom (ljepota, čistoća, aristokracija). Na taj način svaka od

razina odgovara na jedno od pitanja: tko?, što?, gdje?, kada?, čime se pokrivaju svi aspekti opisa slikovnih izvora.

Shatford je u svojim radovima (Shatford, 1986) dalje razradila aspekte opisa, uvodeći distinkciju između aspekta *ofness*, koji se odnosi na konkretne i objektivne činjenice o nekom predmetu (od čega se nešto sastoji) i *aboutness*, koji se odnosi se na apstraktno i subjektivno znanje o nekom predmetu (o čemu nešto govori). Uz ta dva pojma, koncept predmetnog opisa proširen je i pojmom *isness* (što je to o čemu se govori) kako bi se kategorija opisa proširile iz opisa slika na opis svih vrsta primarno vizualne građe. Klenczoni i Rygiel (2014) donose primjer koji oslikava te tri temeljne razine pristupa koristeći skulpturu *Laookontove skupine* (http://commons.wikimedia.org/wiki/File:Laokoon-Gruppe-03.jpg.) (Slika 74).

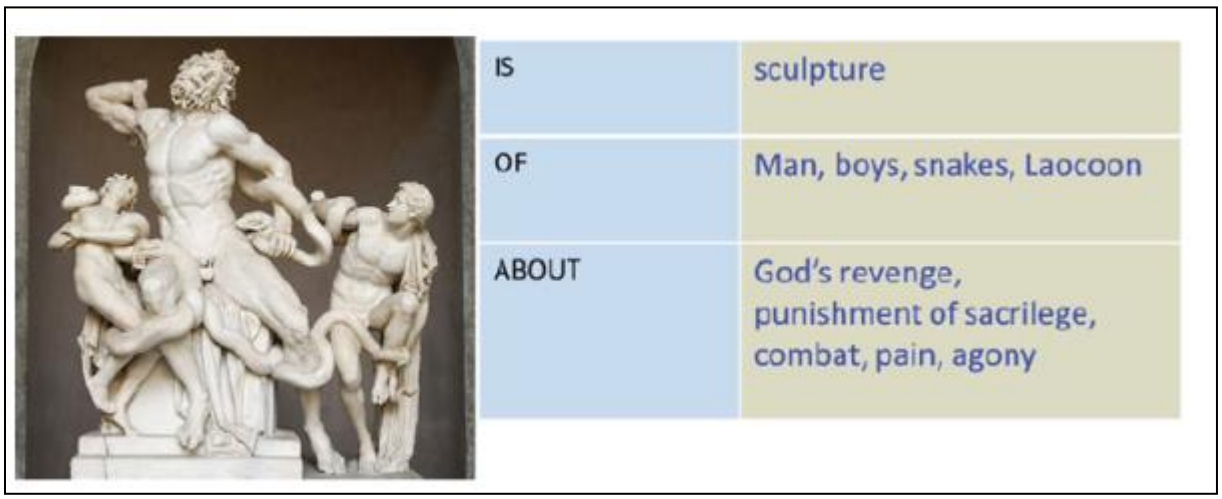

Slika 76 - Razine isness, ofness i aboutness u analizi vizualne građe
(prema Klenczoni i Rygiel, 2014)

Prva razina definira samu vrstu izvora informacija (skulptura), druga se odnosi na identificiranje pojmova vezanih uz resurs (čovjek, djeca, zmije, Laookont), dok se treća odnosi na apstraktne pojmove vezane uz prikazano (Božja osveta, kazna za svetogrđe, borba, bol, agonija).

Usporedimo li te tri razine s razinama prikazanima na slici 75 i originalnom Panofsky/Shatford modelu, možemo vidjeti kako u prvom modelu nema prve razine (vrste izvora) jer se on uvijek odnosi na slike, zatim kako razina *ofness* uključuje i preikonografske (generičke) pojmove (čovjek, dječaci), kao i ikonografske (specifične) pojmove (zmije, Laookon), dok se treća razina (apstraktna) podudara u oba modela.

Pregledom modela opisa vizualnih izvora uvidjelo se kako oba modela imaju svojih prednosti i kategorija koje bi mogle dati prikladnu analizu razine značenja na kojoj su dodane korisničke oznake.

Kako se materijali kojima su dodane korisničke oznake u ovom istraživanju sastoje od različitih vrsta vizualnih izvora (muzejska građa, plakati, fotografije), a ne samo slika, bilo je potrebno u analizu uključiti i podatak o vrsti izvora (*isness*) prisutan u drugom modelu. S druge strane, prvi model detaljnije razrađuje razinu *ofness* na generičke pojmove (koji ne zahtijevaju specifično znanje već samo znanje prepoznavanja), te specifične pojmove (koji identificiraju specifične karakteristike prisutne na izvoru) te je tu razinu također trebalo uključiti u opis. U tom pogledu, razina značenja korisničkih oznaka analizirana je prema modelu u tablici 16 koji uključuje kombinaciju pristupa navedenih u literaturi.

Tablica 16 - Razine analize vizualne građe primijenjene u disertaciji

RAZINA	NAZIV	OPIS
1. razina	***ISNESS***	identificira vrstu izvora koji se opisuje (npr. plakat, fotografija)
2. razina	***OFNESS***	
	• GENERIČKI POJMOVI	ne zahtijevaju specifično znanje već samo znanje prepoznavanja
	• SPECIFIČNI POJMOVI	identificiraju specifične karakteristike prisutne na izvoru
3. razina	***ABOUTNESS***	odnosi se na apstraktne pojmove vezane uz prikazano

Primjer analize prema modelu prikazan je u tablici 17.

Tablica 17 - Primjer analize vizualne građe

ISNESS	fotografija
OFNESS	
GENERIČKA RAZINA	automobil, sudar
SPECIFIČNA RAZINA	crveni fićo, tenk
ABOUTNESS	rat, agresija

Na prvoj razini identificirana je vrsta izvora (fotografija), na drugoj razini identificirani su generički (automobil, sudar) i specifični (crveni fićo, tenk) pojmovi, dok su na trećoj razini identificirani pojmovi na apstraktnoj razini (rat,agresija).

Prema tim kategorijama provedena je analiza na 40 vizualnih izvora između materijala (20 fotografija, 20 muzejskih predmeta) sumiranih u Tablicama 18 i 19, dok slike 77 i 78 donose grafičke prikaze.

Tablica 18 - Rezultati analize razina značenja korisničkih oznaka dodanih vizualnoj građi

VRSTA	BROJ IZVORA	BROJ KORISNIČKIH OZNAKA	*ISNESS*	*OFNESS*	*ABOUTNESS*	OSTALO
FOTO	20	1811	43	1372	327	34
MUZ	20	1403	12	1156	163	55
TOTAL	**40**	**3214**	**55**	**2528**	**490**	**89**

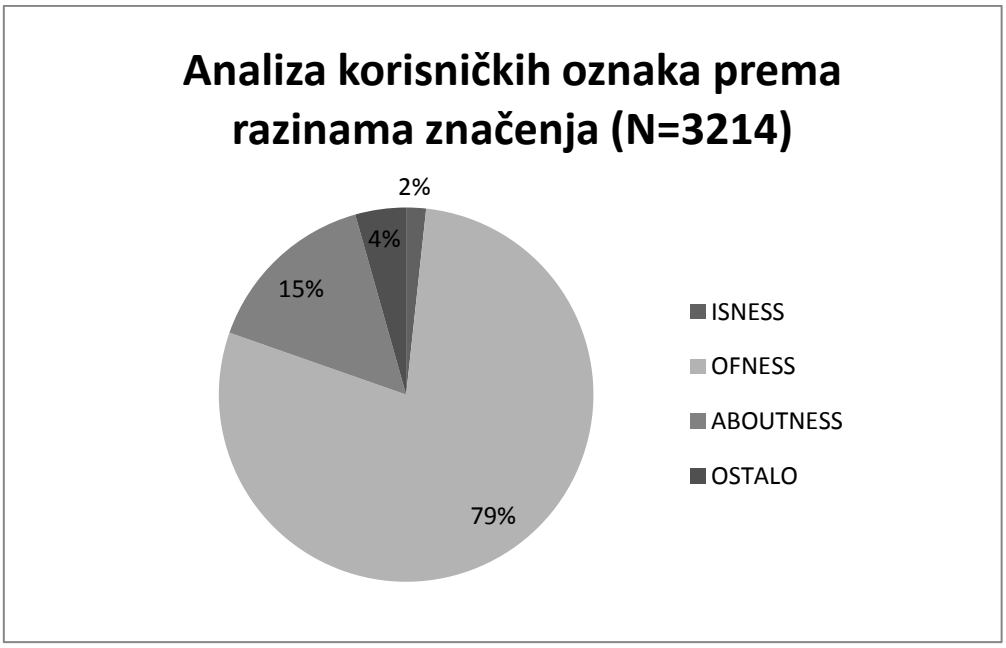

Slika 77 - Analiza razina značenja korisničkih oznaka dodanih vizualnoj građi

Analiza prema razinama značenja pokazala je kako je najveći broj korisničkih oznaka (79%) dodan na razini *ofness*, tj. razini definiranja objekta koji se na nekoj slici nalazi. Analiza prema pojedinoj vrsti građe (muzejska ili fotografije) nije pokazala značajne razlike.

Tablica 19 - Rezultati analize razine značenja *ofness* korisničkih oznaka dodanih vizualnoj građi

VRSTA	BROJ IZVORA	BROJ KORISNIČKIH OZNAKA	*OFNESS*	GENERIČKI	SPECIFIČNI
FOTO	20	1811	1372	1212	160
MUZ	20	1403	1156	925	232
UKUPNO	**40**	**3214**	**2528**	**2137**	**392**

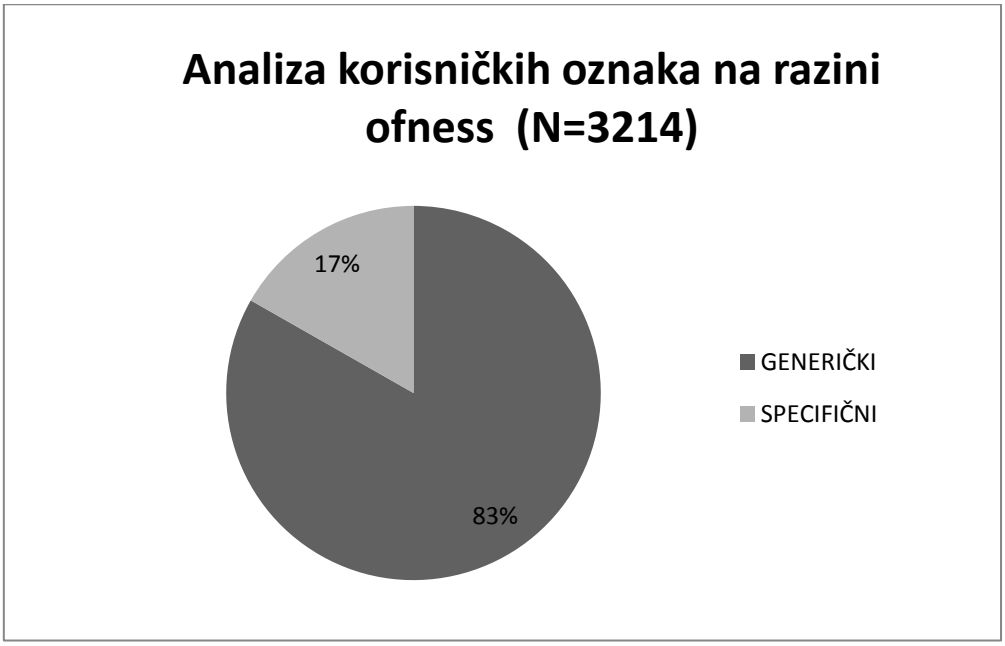

Slika 78 - Analiza razine značenja *ofness* korisničkih oznaka dodanih vizualnoj građi

Daljnja analiza *ofness* razine pokazala je kako je najveći broj oznaka dodan na generičkoj razini (83%) koja ne zahtijeva predznanje o samoj građi, već se oslanja samo na element prepoznavanja općenitih pojmova.

Nakon analize razina značenja, na kojoj se nalaze dodane korisničke oznake, možemo zaključiti kako je najveći broj oznaka dodan na generičkoj *ofness* razini, tj. korisnici najviše dodaju oznake na toj razini (oko 80%).

Takav rezultat je i predviđen jer je teško očekivati od korisnika veliko predznanje o samim predmetima, zato se i očekuje da će njihove oznake opisivati generičke pojmove prisutne na vizualnom resursu. Na ukupnom korpusu dodan je i značajan broj oznaka koje imaju subjektivnu komponentu, na razini *aboutness* (15% ili 490 oznaka).

5.6. Ispitivanje razlika u pristupu korisničkom označivanju tradicionalnih vrsta građe u baštinskom okruženju

Treća je faza analize prikupljenog korpusa oznaka bila usmjerena na razlike u korištenim terminima od strane predmetnog stručnjaka i korisničkih oznaka prikupljenih putem aplikacije.

Analiza je provedena u dvije komplementarne faze:

1. usporedba predmetnica dodanih od strane predmetnih stručnjaka i prikupljenih korisničkih oznaka
2. ocjena korisnosti prikupljenih oznaka za predmetni opis opisivane građe.

U prvoj fazi pristupilo se usporedbi i mjerenju preklapanja između rječnika koji je koristio predmetni stručnjak u opisu predmeta s korisničkim rječnikom prikupljenim putem aplikacije.

U drugoj fazi prikupljene oznake na razini predmeta dane su predmetnom stručnjaku kako bi ocijenio njihovu prikladnost i korisnost za predmetni opis, tj. dao odgovor na pitanje u kojoj mjeri i kako bi ih trebalo uključiti u predmetni opis.

5.6.1. Usporedba predmetnica dodanih od strane predmetnih stručnjaka i prikupljenih korisničkih oznaka

Prve studije koje su se bavile usporedbom dva seta termina predmetnog opisa unutar baštinskog okruženja odnosile su se na mjerenje konzistentnosti između dva predmetna stručnjaka (engl. *inter-indexer consistency*) (David et al., 1995). Choi (2011) daje pregled radova koji se bave problematikom konzistentnosti u predmetnom opisu, čije izabrane primjere donosimo u nastavku.

Leonard (1977) daje pregled studija konzistentnosti među predmetnim stručnjacima u razdoblju od 1954. do 1975 godine, ukazujući na problem kako je sama mjera konzistentnosti definirana različito od strane različitih istraživača tijekom vremena, što je dovelo do primjedbi da ne postoji standardna mjera konzistencije (Hooper, 1965), te kako specifičnosti okruženja u kojem se istraživanja provode dovode do nemogućnosti općenite primjene rezultata (Cooper, 1969).

Hooper (1965) i Rolling (1981) daju dvije formule koje su tijekom vremena postale najprihvatljivije mjere konzistentnosti između dva predmetna stručnjaka:

$$Hooper = c/(a+b-c)$$

$$Rolling = 2c/(a+b)$$

a – broj termina dodan od strane prvog stručnjaka

b – broj termina dodan od drugog stručnjaka

c – broj termina koji su dodala oba stručnjaka (zajednički termini).

Formula je korištena u nizu istraživanja koja su se bavila mjerenjem konzistentnosti između dva ili više predmetnih stručnjaka (Choi, 2011). Kao što je već pokazano u pregledu istraživanja, pojavom korisničkog označivanja velik broj radova proučavao je upotrebu korisničkog označivanja kao metode poboljšanja pristupa, pretrage, navigacije ili personalizacije informacijskih sustava, kao i poboljšanja opisa i komplementiranja tradicionalnim sustavima za organizaciju znanja.

Pojavom korisničkog označivanja kao metode kojom korisnici sami opisuju i organiziraju izvore, polje primjene formule konzistentnosti između predmetnih stručnjaka proširilo se na mjerenje razlika između pristupa u označivanju od strane korisnika i predmetnih stručnjaka, kako bi se pokušao izmjeriti semantički jaz između predmetnih odrednica i korisničkog rječnika (Rorissa, 2010).

Kipp i Campbell (2006) analizirali su obrasce korisničkog označivanja među korisnicima servisa Delicious, kako bi uvidjeli može li korisničko označivanje poboljšati praksu tradicionalnog predmetnog pristupa i zaključili kako su korisnici pokazali konzistentnost s tradicionalnim konceptima očemnosti u predmetnom pristupu.

Špiranec i Ivanjko (2012) ispitivali su razlike u korisničkim oznakama dodanima znanstvenome članku na uzorku od 40 preddiplomskih i 40 diplomskih studenata informacijskih znanosti, želeći utvrditi hoće li studenti, koji imaju više znanja o metodama predmetne obrade, kreirati folksonomiju veće kvalitete. Hipoteza se pokazala točnom jer je skup oznaka od strane diplomskih studenata bio konzistentniji i pokazivao veću sličnost s ključnim riječima dodanima od strane autora.

Kao dio projekta *steve.museum*, Trant (2009) je analizirala korisničke oznake dodane od strane posjetitelja muzeja s predmetnim opisom dodanim od strane muzejskih stručnjaka. Rezultati su pokazali kako je rječnik korisničkih oznaka veoma različit od onog koji su koristili stručnjaci. Čak 86% oznaka koje su dodali korisnici nisu bili dio rječnika stručnjaka, ali je čak 88% oznaka ocijenjeno korisnima od strane stručnjaka kao pristupnica u pretrazi.

Lin, et al. (2006) uspoređivali su korisničke oznake iz servisa Connotea s terminima iz naslova i deskriptorima iz MeSH tezaurusa. Usporedba između ta tri seta pokazala je samo 11% preklapanja.

Kipp (2011) je uspoređivala korisničke oznake iz servisa CitULike i autorske ključne riječi i termine iz MeSH tezaurusa te zaključila kako i čitatelji i autori koriste termine koji su slični terminima iz tezaurusa, ali nisu isti kao same predmetnice.

Lu, Park, i Hu (2010) usporedili su korisničke oznake iz servisa LibraryThing s predmetnicama iz sustava Kongresne knjižnice (LCSH) na razini zbirke, kao i dokumenta. Pokazalo se kako je na razini zbirke vjerojatnost 50% da će predmetnica biti upotrijebljena kao korisnička oznaka, dok je na razini dokumenta preklapanje često korištenih termina između korisnika i stručnjaka bilo veoma maleno.

Al-Khalifa i Davis (2006) mjerili su sintaktičko preklapanje između folksonomija i predmetnih stručnjaka i pronašli kako postoji 19.48% preklapanja između korisničkih oznaka i deskriptora.

Kipp (2005) je mjerila semantičko preklapanje između ključnih riječi autora, deskriptora i korisničkih oznaka te se pokazalo kako je najčešće preklapanje bilo povezano asocijativnim vezama, a tek zatim na sintaktičkoj razini. Pokazalo se kako velik broj termina uopće nije bio povezan.

Wetterström (2008) je proveo istraživanje u kojem je mala skupina dodala oznake na 217 dokumenata, kako bi ih zatim usporedio s postojećim deskriptorima u sustavu LCSH. Pokazalo se kako je preklapanje na sintaktičkoj razini iznosilo 9.14%, ali je uključivanje širih i užih termina činilo 14.61% i 19.62% svih oznaka.

Thomas, Caudle, i Schmitz (2009) analizirali su korisničke oznake iz više različitih servisa i usporedili ih s LCSH deskriptorima za iste izvore. Pokazalo se kako je samo 6% oznaka bilo prisutno u deskriptorima, dok je 22% oznaka bilo na neki način vezano za postojeće deskriptore, iako nisu imali isti lingvistički izraz.

Stvilia i Jörgensen (2010) usporedili su oznake dodane od strane korisnika zbirci fotografija Kongresne knjižnice putem sustava Flickr s deskriptorima iz tezaurusa za grafičke materijale (TGM) i LCSH. Pokazalo se kao je samo 21% korisničkih oznaka prisutno u TGM-u, dok je 45% oznaka pronađeno u LCSH. Autori su nakon provedenog istraživanja dali preporuku kako bi se postojeći sustavi kontroliranih rječnika mogli poboljšati i nadopuniti korisničkim oznakama.

Sva nabrojana istraživanja pokazala su kako rezultati preklapanja variraju u odnosu na mjeru i razinu usporedbe koja se koristi u različitim pristupima. Preklapanja su varirala od 6%

(Thomas, Caudle i Schmitz, 2009) do 20% (Al-Khalifa i Davis, 2006), što pokazuje kako na globalnoj razini nije pronađena adekvatna mjera ili postignut konsenzus oko toga kako se korisničke oznake mogu usporediti s kontroliranim rječnicima, već se rezultati moraju promatrati ili na razini pojedine zbirke, vrste materijala ili tipa korisnika koji sudjeluju u opisivanju.

5.6.1.1. Definiranje metodologije usporedbe

Kako je već spomenuto u poglavlju 5.3, materijali istraživanja podijeljeni su u četiri skupine:

- **arhivska građa** (20 skeniranih arhivskih dokumenata)
- **muzejska građa** (20 digitaliziranih muzejskih izložaka)
- **knjižnična građa** (20 skeniranih naslovnica knjiga s kataložnim opisima)
- **fotografije** (20 skeniranih fotografija).

Materijali su odabrani u suradnji s predmetnim stručnjakom koji je u procesu odabira svakom predmetu dodijelio i tematske odrednice koje su predstavljale prvi set usporedbe – predmetnice dodijeljene od strane predmetnog stručnjaka.
Prikupljanjem korisničkih oznaka na istim materijalima dobiven je i drugi set usporedbe – dodane korisničke oznake na razini predmeta. Prilog 3 (*Predmetnice i korisničke oznake korištene u usporedbi*) donosi potpune setove predmetnica i korisničkih oznaka korištenih u usporedbi, dok Tablice 20 i 21 prikazuju sumirane podatke na razini svake vrste građe s osnovnim statističkim pokazateljima za svaki set podataka.

Tablica 20 - Broj dodanih oznaka prema vrstama građe

VRSTA GRAĐE	BROJ DODANIH OZNAKA	MAX	MIN	PROSJEK	STDEV
MUZ	1403	111	33	70.15	23.77
KNJ	1803	128	43	90.15	20.76
FOTO	1811	129	56	90.55	21.08
ARH	1571	169	54	78.55	25.13
UKUPNO	**6588**	**169**	**33**	**82.35**	**22.68**

Tablica 21 - Broj dodanih predmetnica prema vrstama građe

VRSTA GRAĐE	BROJ PREDMETNICA	MAX	MIN	PROSJEK	STDEV
MUZ	123	11	4	6.50	1.63
KNJ	191	9	4	5.85	1.63
FOTO	117	14	6	9.55	2.39
ARH	130	10	4	6.15	2.23
UKUPNO	**561**	**14**	**4**	**7.01**	**1.97**

Kako vidimo iz analiziranih podataka, raspodjela broja korisničkih oznaka na razini predmeta vrlo je nejednaka, uz prosjek od 82.3 korisničke oznake, ali značajnu standardnu devijaciju (22.7) koja se pokazuje i u podatku o najmanjem (33) i najvećem (169) broju seta korisničkih oznaka dodanih jednom predmetu.

Što se tiče dodanih predmetnica, one su uglavnom u rasponu od 4-10 tematskih odrednica po predmetu, uz prosjek od 7 predmetnica dodanih jednom predmetu.

Nakon definiranja osnovnih setova usporedbe (Prilog 3), bilo je potrebno odlučiti na kojoj će se razini dobiveni setovi termina uspoređivati.

Pregled istraživanja u literaturi pokazao je kako se u osnovi usporedba može odvijati na dvije razine:

1) **sintaktičko preklapanje** – metoda se sastoji od mjerenja broja jednakih termina u dva seta, ili putem *exact-matching* metode (usporedba termina u njihovom originalnom obliku), ili putem *fuzzy* metode (usporedba termina nakon lematizacije, tj. svođenja na osnovni oblik)

2) **semantičko preklapanje** – usporedba dva seta termina prema povezanom značenju koji stoji iza samog oblika riječi.

Kako je cilj ove disertacije ispitati vrijednost korisničkih oznaka, imperativno je bilo da se ne ulazi u bilo kakvo ispravljanje ili prilagodbu termina na jezičnoj razini, te je stoga u ovoj disertaciji poduzeta sintaktička usporedba termina pomoću *exact matching* metode, uz nekoliko prilagodbi na sintaktičkoj razini koje ne utječu na jezične osobine samih korištenih termina.

Prema studiji Lancaster i Smith (1983), kako bi se zadovoljio uvjet *exact matching*–a potrebno je zadovoljiti pet pravila:

1) jednina i množina iste riječi smatraju se kao dva različita termina (npr. čizma i čizme)

2) različite varijante pisanja smatraju se različitim terminima (ne ću i neću)

3) različiti oblici iste riječi smatraju se različitim terminima (npr. dijete, djeca, dječji)

4) akronimi i puni nazivi smatraju se različitim terminima (npr. UN i Ujedinjeni narodi)

5) složeni termini moraju u potpunosti odgovarati načinu pisanja (npr. domovinski rat, Domovinski rat i domovinski-rat su tri različita termina).

Ova disertacija slijedi prva četiri pravila za određivanje poklapanja na sintaktičkoj razini, dok se peto pravilo prilagodilo u tri koraka:

1) uklonjeni su svi znakovi koji nisu unicode slova, brojevi i razmak (dva razmaka, tab, itd.)

2) uklonjene su sve oznake koje sadrže samo razmak (prazni niz)

3) sva slova pretvorena su u mala slova.

Slika 79 prikazuje dio Python programa koji izvršava navedeno na korpusu korisničkih oznaka i predmetnica putem `prepareTag` funkcije.

```
def prepareTag(s, leave = "-"):

"""

    priprema oznaku ili predmetnicu:

        1. uklanja sve znakove koje nisu UNICODE slova, brojevi,
razmak ili znakovi nabrojani u "leave" parametru
        2. pretvara sve znakove koji su prisutni u leave u razmake
        3. normalizira i kompresira "whitespace" (uključujući i tab
znakove i slično)
        4. provjerava da oznaka sadrži išta osim razmaka, u kojem
slučaju se ignorira
        5. pretvara sva slova u mala slova

         """

    # drop non word characters, non space characters
    s = re.sub(r'[^\w\s%s]' % leave, '', s, re.UNICODE)

    # replace characters that should be treated as space
    s = s.replace("-", " ").replace("_", " ")

    # normalize and compress whitespace
    s = " ".join(s.split())

    # make s lowercase
    s = s.lower()
```

Slika 79 - Priprema seta termina za usporedbu u Python programskom rješenju

Dok prve dvije iteracije samo pročišćavaju setove za usporedbu, kako bi bili sigurni da ostaju samo termini koji imaju neko značenje, treća iteracija osigurava da isti nizovi znakova, napisani u različitim varijantama (domovinski rat, Domovinski rat, hrvatska, Hrvatska), budu svedeni na isti oblik i time daju pogodak kod uspoređivanja termina. Nakon sređivanja setova predmetnica i korisničkih oznaka, pristupilo se usporedbi setova termina kako na razini predmeta, tako i na razini zbirke.

Prva analiza odnosila se na mjerenje broja zajedničkih termina između dobivenih korisničkih oznaka i predmetnica koje je dodijelio stručnjak. Postupak usporedbe može se prikazati Vennovim dijagramima (Slika 80).

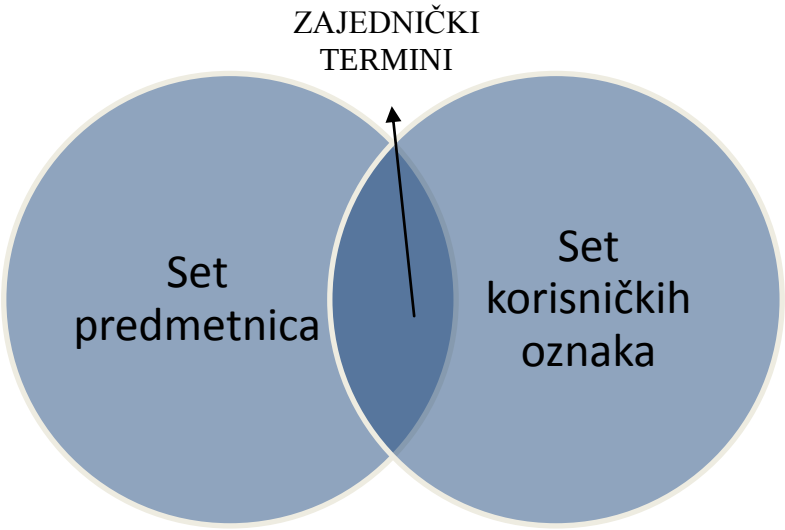

Slika 80 - Prikaz mjere preklapanja između predmetnica i korisničkih oznaka putem Venn dijagrama

Određivanjem zajedničkih termina u oba skupa podataka, mjerilo se preklapanje između seta korisničkih oznaka i predmetnica na sintaktičkoj razini.

5.6.1.2. Definiranje mjere usporedbe

Analizom mjera sličnosti na sintaktičkoj razini pokazalo je kako je najčešće korištena mjera u literaturi ona definirana u Hooper (1965):

$$(1)\ \frac{c}{(a+b-c)}$$

a – broj termina prvog seta

b – broj termina drugog seta

c – broj zajedničkih termina.

U teoretskom smislu, mjera je ista kako i Jaccard/Tanimoto koeficijent sličnosti koji se u literaturi (Ibrahim, Hamid i Herman, 2008; Tsai, Hwang i Tang, 2011) definira kao:

$$(2)\ S_{ij} = \frac{N_{ij}}{N_i + N_j - N_{ij}}$$

S*ij* – koeficijent sličnosti između *i* i *j*

N*i* – broj dijelova skupa *i*

N*j* – broj dijelova skupa *j*

N*ij* – broj zajedničkih dijelova.

Špiranec i Ivanjko (2012) prilagodili su formulu (2) u usporedbi setova autorskih ključnih riječi i korisničkih oznaka, kako bi dobili koeficijent efikasnosti između korisnika s različitim razinama predznanja

$$(3)\ T_e = \frac{N_i}{N_k+N_t-N_i}$$

T*e* – učinkovitost označivanja

N*k* – set autorskih ključnih riječi

N*t* – set korisničkih oznaka

N*i*– broj termina koji se pojavljuje u oba seta.

Al-Khalifa i Davies (2006) prilagodili su originalnu formulu (1) kako bi mogli mjeriti postotak preklapanja između seta ključnih riječi i korisničkih oznaka:

$$(4)\ P = \frac{N}{(Fs+Ks)-N}\ X100$$

P – postotak preklapanja
N – broj zajedničkih termina
Fs – veličina seta korisničkih oznaka
Ks – veličina seta ključnih riječi.

Kao što vidimo, formula (5) zadržava isti oblik kao i (1) uz dodavanje množenja sa 100. Kako sama formula uzima u obzir veličinu oba seta termina, koja je u ovom slučaju veoma nejednaka (broj oznaka mnogostruko je veći od broja predmetnica dodanih istom predmetu), dodano je množenje sa 100 kako bi se dobili jasniji rezultati.

Za potrebe usporedbe na sintaktičkoj razini ova disertacija primijenila je mjeru definiranu u radu Al-Khalifa i Davis (2006) uz prilagođenu terminologiju:

$$(5)\ K_s = \frac{N_{po}}{N_p+N_o-N_{po}}\ X100$$

Ks – koeficijent sličnosti
Np – set predmetnica dodanih od strane stručnjaka
No – set korisničkih oznaka prikupljenih putem aplikacije
Npo – set zajedničkih termina koji se nalaze u oba seta.

Algoritamsko rješenje usporedbe implementirano je funkcijom `getTagsAndSubjects` i `def calcKS` u Pythonu (Slika 81).

```
def getTagsAndSubjects(data, keys = None):
    """
    Izrađuje preklapanje oznaka i predmetnica na razini predmeta i
vraća vrijednosti broj oznaka (n_t), broj predmetnica (n_s) i broj
predmetnica u oznakama (n_ts)
    """
    tags = {}
    subjects = {}
    if not keys:
        keys = data
    for key in keys:
        item = data[key]
        for t in item["oznake"]:
            if t not in tags:
                tags[t] = 0
            tags[t] += item["oznake"][t]
        for s in item["predmetnice"]:
            if s not in subjects:
                subjects[s] = 0
            subjects[s] += 1
    return tags, subjects
"""
    Izračunava koeficijent sličnosti (Ks)
"""
def calcKs(n_t, n_s, n_ts):
    return round( (n_ts/(n_t+n_s-n_ts)) * 100,  2)
```

Slika 81 - Funkcije getTagsAndSubjects i def calcKS implementirane u Pythonu

Uz mjeru koeficijenta sličnosti, analizirana je i pokrivenost predmetnica u korisničkim oznakama usporedbom broja zajedničkih elemenata s brojem dodanih predmetnica. Pokrivenost se mjerila jednostavnom formulom

$$(6)\ \frac{N_{po}}{N_p} X100\%$$

gdje su

Np – set predmetnica dodanih od strane stručnjaka
Npo – set zajedničkih termina koji se nalaze u oba seta.

Na taj način moglo se analizirati u kojoj su mjeri korisničke oznake pokrile termine prisutne u dodanim predmetnicama, tj. u kojoj je mjeri korisnički rječnik sličan terminima koje je koristio predmetni stručnjak.

U nastavku se donose podaci prema pojedinim vrstama građe za svaku od navedenih mjera.

5.6.1.3. Usporedba na zbirci arhivske građe

Kao što podaci u Tablici 22 pokazuju, unutar zbirke arhivskih predmeta, prosječno su se 3 termina, koje je dodao predmetni stručnjak, također pojavila i u setu termina korisničkih oznaka, a prosječna pokrivenost predmetnica u korisničkim oznakama iznosila je 42%.

.

Tablica 22 - Preklapanje između setova termina predmetnica i korisničkih oznaka na arhivskoj građi

	BROJ PREDMETNICA	BROJ KORISNIČKIH OZNAKA	BROJ ZAJEDNIČKH TERMINA	Ks	UDIO ZAJEDNIČKIH TERMINA U PREDMETNICAMA
UKUPNO	**130**	**1571**	**52**	**3.38**	**41.97%**
MAX	11	169	5	7.02	75.00%
MIN	4	54	1	1.69	16.67%
PROSJEK	6.50	78.55	2.60	3.38	41.97%
STDEV	1.64	25.13	0.99	1.65	17.03%

Grafički prikaz koeficijenta sličnosti (Slika 82) i udjela zajedničkih termina u predmetnicama (slika 80), sortiran prema najvećim vrijednostima, potvrđuje podatak o dosta visokoj standardnoj devijaciji između rezultata na razini predmeta od 17%.

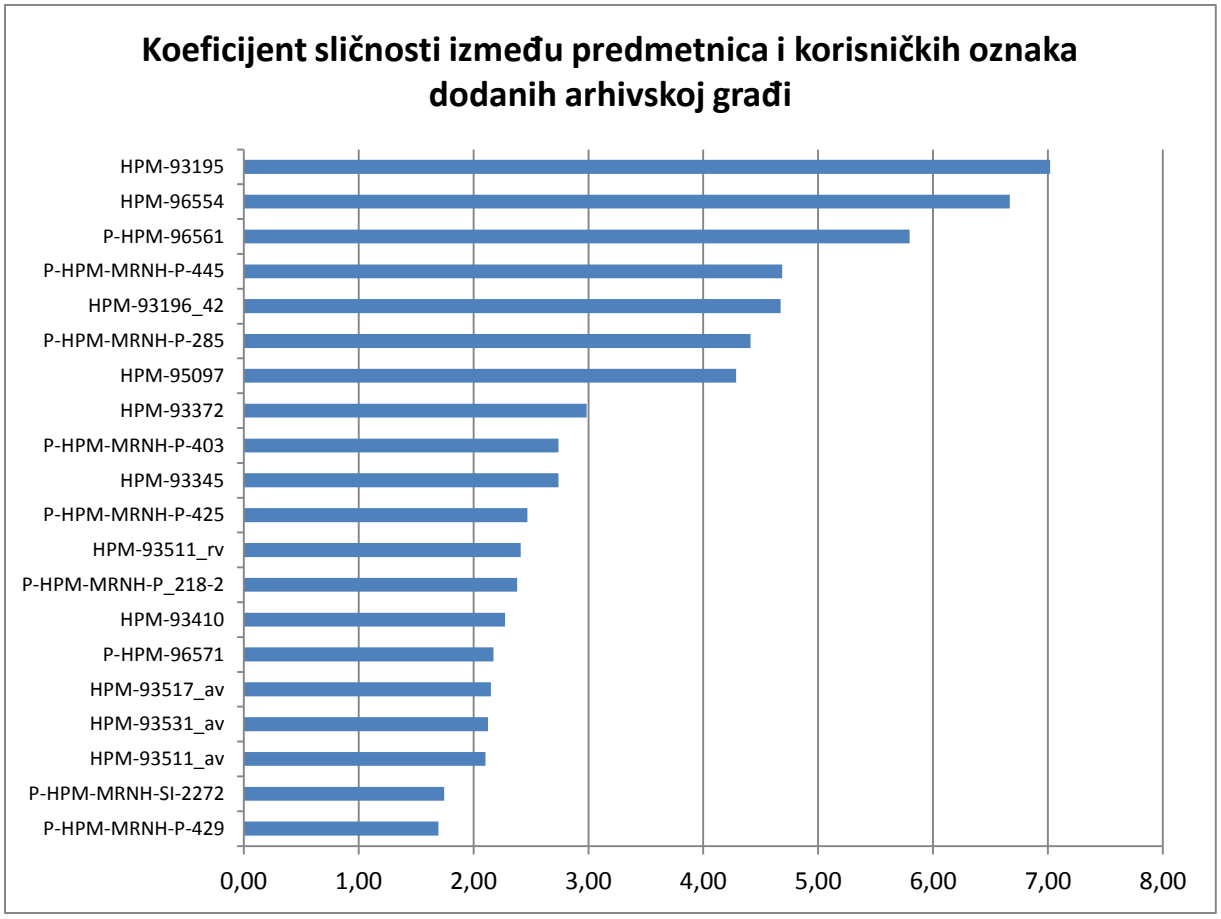

Slika 82 - Koeficijent sličnosti između predmetnica i korisničkih oznaka dodanih arhivskoj građi

Analizom na razini predmeta možemo vidjeti kako koeficijent sličnosti varira od čak 7 (predmet HPM-93195) pa do ispod 2 (predmet P-HPM-MRNH-P-429).

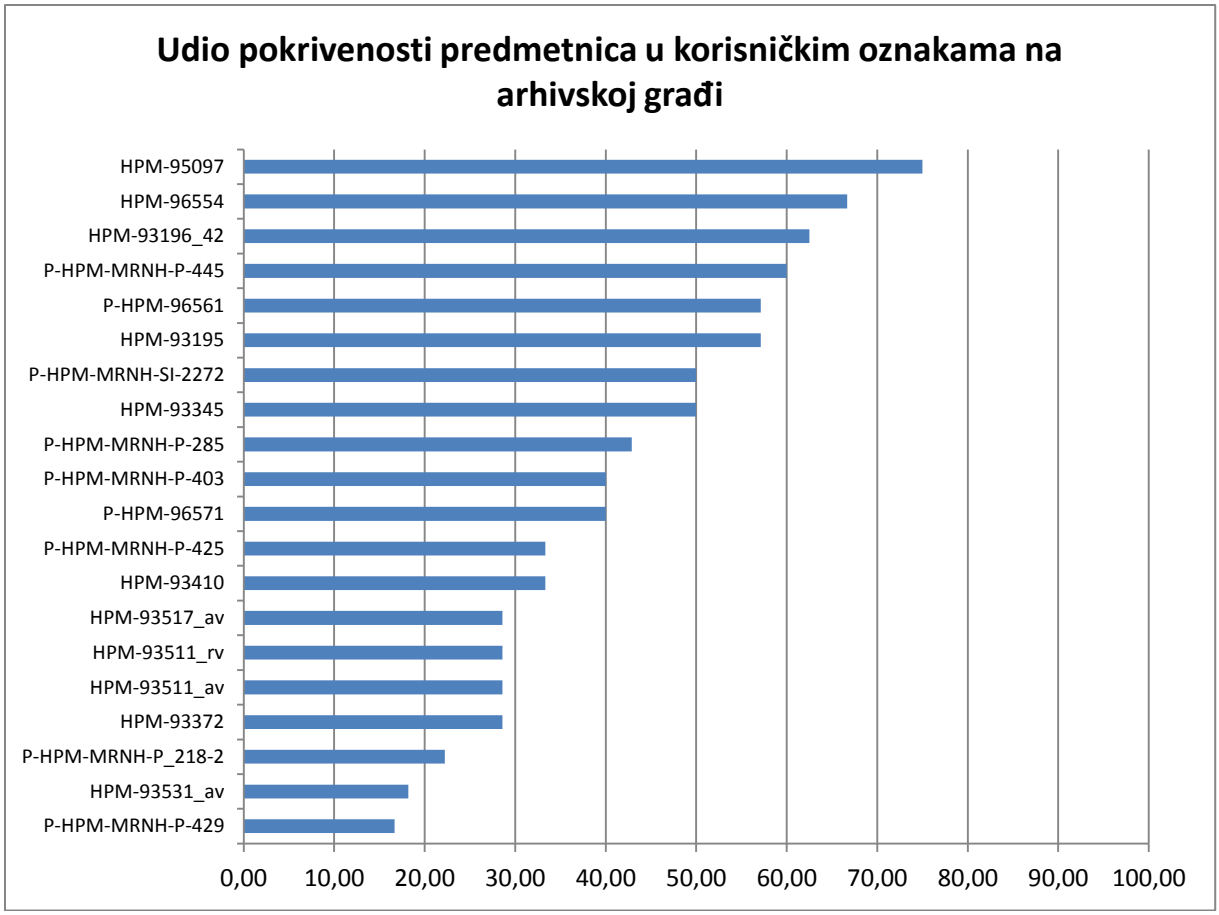

Slika 83 - Udio pokrivenosti predmetnica u korisničkim oznakama dodanima arhivskoj građi

Analizom na razini predmeta možemo vidjeti kako pokrivenost predmetnica u korisničkim oznakama varira od preko 70% (predmet HPM-95097) pa do ispod 20% (predmet HPM-93531_av i predmet P-HPM-MRNH-P-429).

Arhivska građa unutar zbirke bila je podijeljena na još dvije podskupine: zbirku dokumenata i zbirku plakata, kako bi se dobila opreka vizualnih i tekstualnih materijala unutar zbirke. Analiziramo li podatke na toj razlici, nema jasnih obrazaca koji bi ukazali na drugačiji pristup plakatima ili dokumentima, kako na razini koeficijenta sličnosti, tako i na razini pokrivenosti predmetnica u korisničkim oznakama (na slikama 82 i 83 predmeti koji počinju oznakom „P-„ odnose se na plakate).

Mjerenje koeficijenta sličnosti i udjela pokrivenosti na razini predmeta omogućilo je usporedbu povezanosti te dvije mjere, tj. daje odgovor na pitanje oslikava li zaista koeficijent sličnosti, mjeren prema navedenoj formuli, i pokrivenost predmetnica u korisničkim oznakama. Ta se pretpostavka pokazala točnom jer je na razini zbirke arhivskih predmeta korelacija između te dvije mjere iznosila r=+0.75, što pokazuje snažnu pozitivnu povezanost.

U tom pogledu, mjera koeficijenta sličnosti pokazala se pouzdanom kao mjera usporedbe sličnosti dva seta termina s nejednakim brojem elemenata u svakome skupu na razini zbirke predmeta arhivske građe.

5.6.1.4. Usporedba na zbirci fotografija

Kao što podaci u Tablici 23 pokazuju, unutar zbirke fotografija, prosječno su se 3 termina, koja je dodao predmetni stručnjak, također pojavila i u setu termina korisničkih oznaka, a prosječna pokrivenost predmetnica u korisničkim oznakama iznosila je 53%.

Tablica 23 - Preklapanje između setova termina predmetnica i korisničkih oznaka dodanih fotografijama

	BROJ PREDMETNICA	BROJ KORISNIČKIH OZNAKA	BROJ ZAJEDNIČKH TERMINA	Ks	UDIO ZAJEDNIČKIH TERMINA U PREDMETNICAMA
UKUPNO	**117**	**1811**	**61**	**3.35**	**52.87%**
MAX	9	129	5	7.35	100.00%
MIN	4	56	1	1.41	25.00%
PROSJEK	5.85	90.55	3.05	3.35	52.87%
STDEV	1.63	21.08	1.19	1.48	18.82%

Kao i kod arhivske građe, grafički prikaz koeficijenta sličnosti (Slika 84) i udjela zajedničkih termina u predmetnicama (Slika 85), sortiran prema najvećim vrijednostima, potvrđuje podatak o dosta visokoj standardnoj devijaciji između rezultata na razini predmeta od 18%.

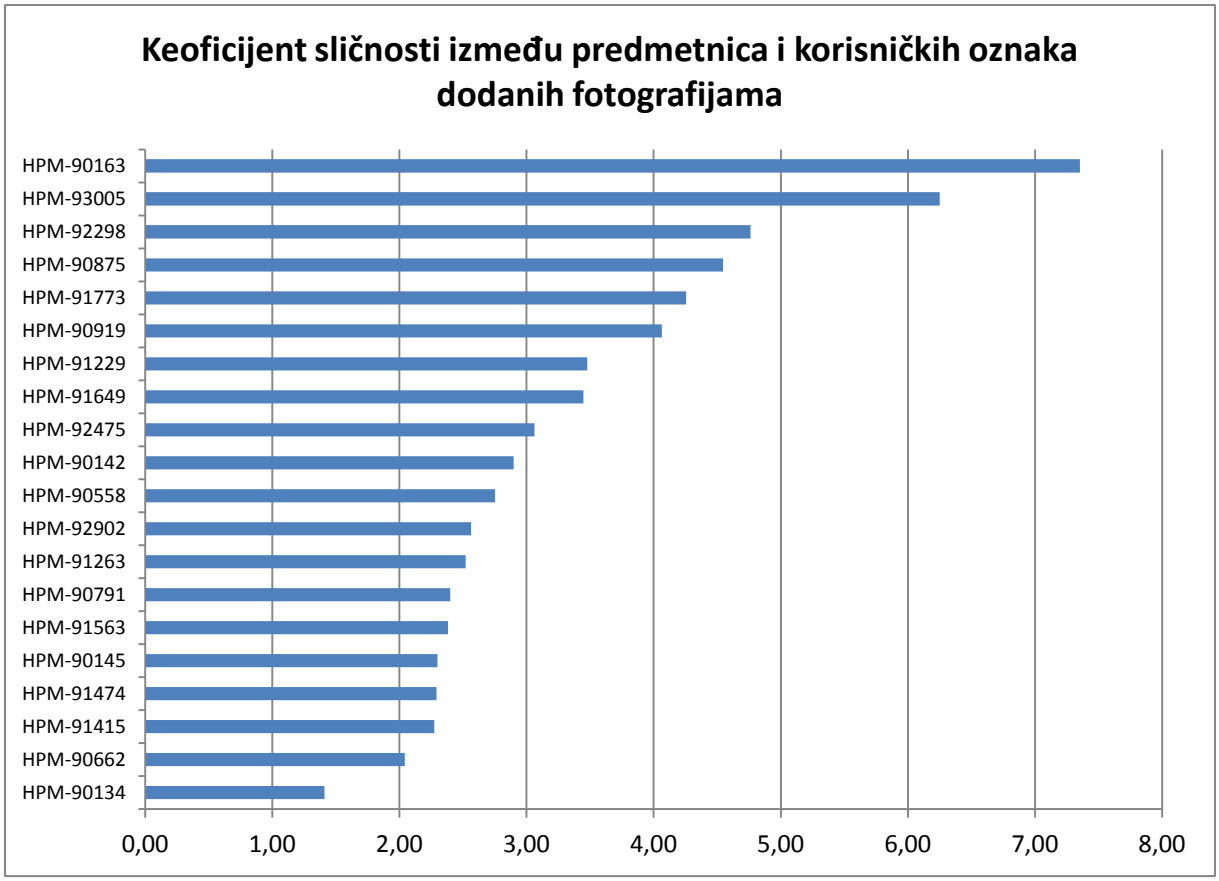

Slika 84 - Koeficijent sličnosti između predmetnica i korisničkih oznaka dodanih fotografijama

Analizom koeficijenta sličnosti na razini predmeta možemo vidjeti kako on varira od čak 7.35 (predmet HPM-90163) pa do ispod 2 (predmet HPM-91034).

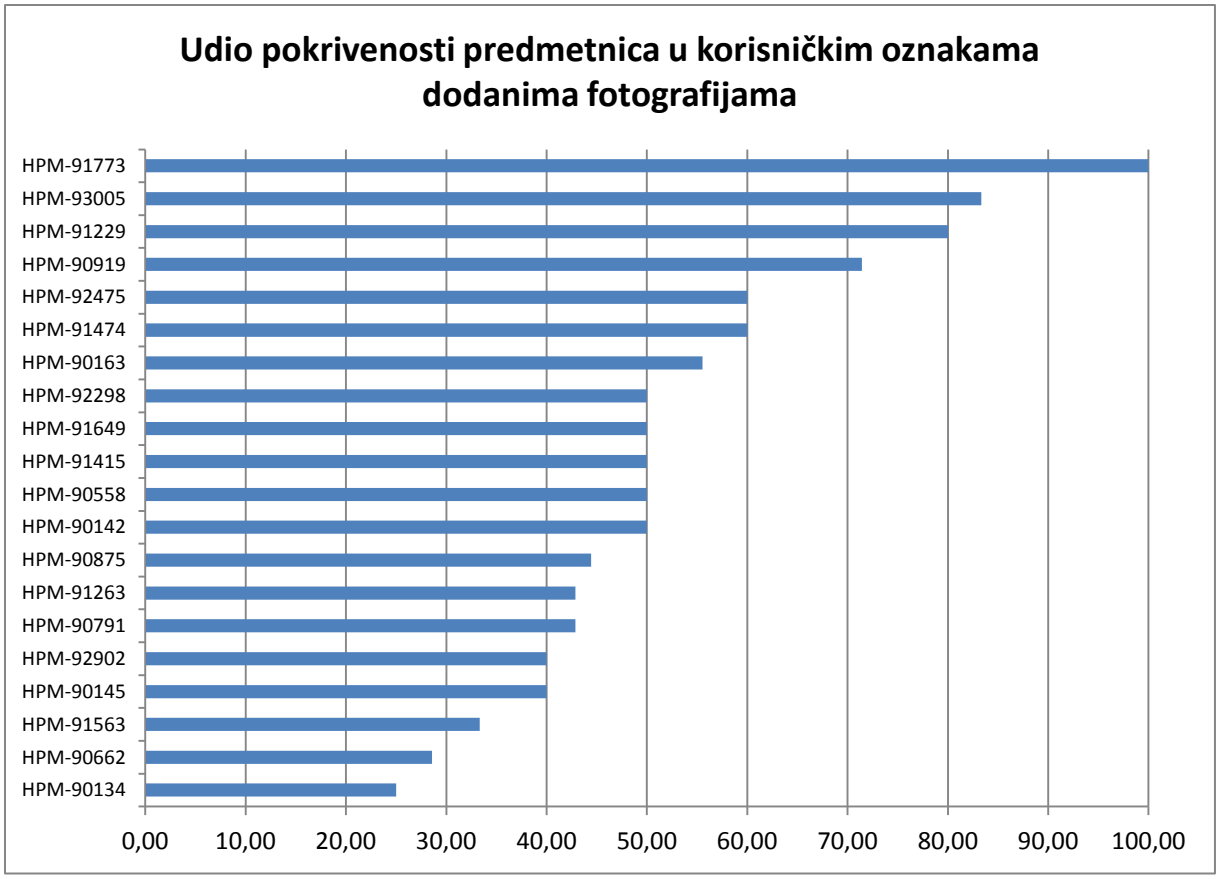

Slika 85 - Udio pokrivenosti predmetnica u korisničkim oznakama dodanima fotografijama

Analizom na razini predmeta možemo vidjeti kako pokrivenost predmetnica u korisničkim oznakama varira od 100% (predmet HPM-91773) pa do ispod 30% (predmeti HPM-90134 i HPM-90662).

Mjerenjem korelacije između koeficijenta sličnosti i udjela pokrivenosti na razini predmeta pokazalo se kako povezanost postoji, ali je umjereno pozitivna (r=+0.54).

U tom pogledu, mjera koeficijenta sličnosti pokazala se umjereno pouzdanom kao mjera usporedbe sličnosti dva seta termina s nejednakim brojem elemenata u svakome skupu na razini zbirke fotografija.

5.6.1.5. Usporedba na zbirci knjižnične građe

Kao što podaci u Tablici 24 pokazuju, unutar zbirke knjižnične građe, prosječno su se 4 termina, koje je dodao predmetni stručnjak, također pojavila i u setu termina korisničkih oznaka, a prosječna pokrivenost predmetnica u korisničkim oznakama iznosila je 48%.

Tablica 24 - Preklapanje između setova termina predmetnica i korisničkih oznaka dodanih knjižničnoj građi

	BROJ PREDMETNICA	BROJ KORISNIČKIH OZNAKA	BROJ ZAJEDNIČKH TERMINA	Ks	UDIO ZAJEDNIČKIH TERMINA U PREDMETNICAMA
TOTAL	**191**	**1803**	**86**	**4.70**	**48.34%**
MAX	14	128	8	8.89	100.00%
MIN	6	43	2	2.63	20.00%
PROSJEK	9.55	90.15	4.30	4.73	48.34%
STDEV	2.39	20.76	1.45	1.98	21.07%

Grafički prikaz koeficijenta sličnosti (Slika 86) i udjela zajedničkih termina u predmetnicama (slika 87), sortiran prema najvećim vrijednostima, potvrđuje podatak o dosta visokoj standardnoj devijaciji između rezultata na razini predmeta od 21%.

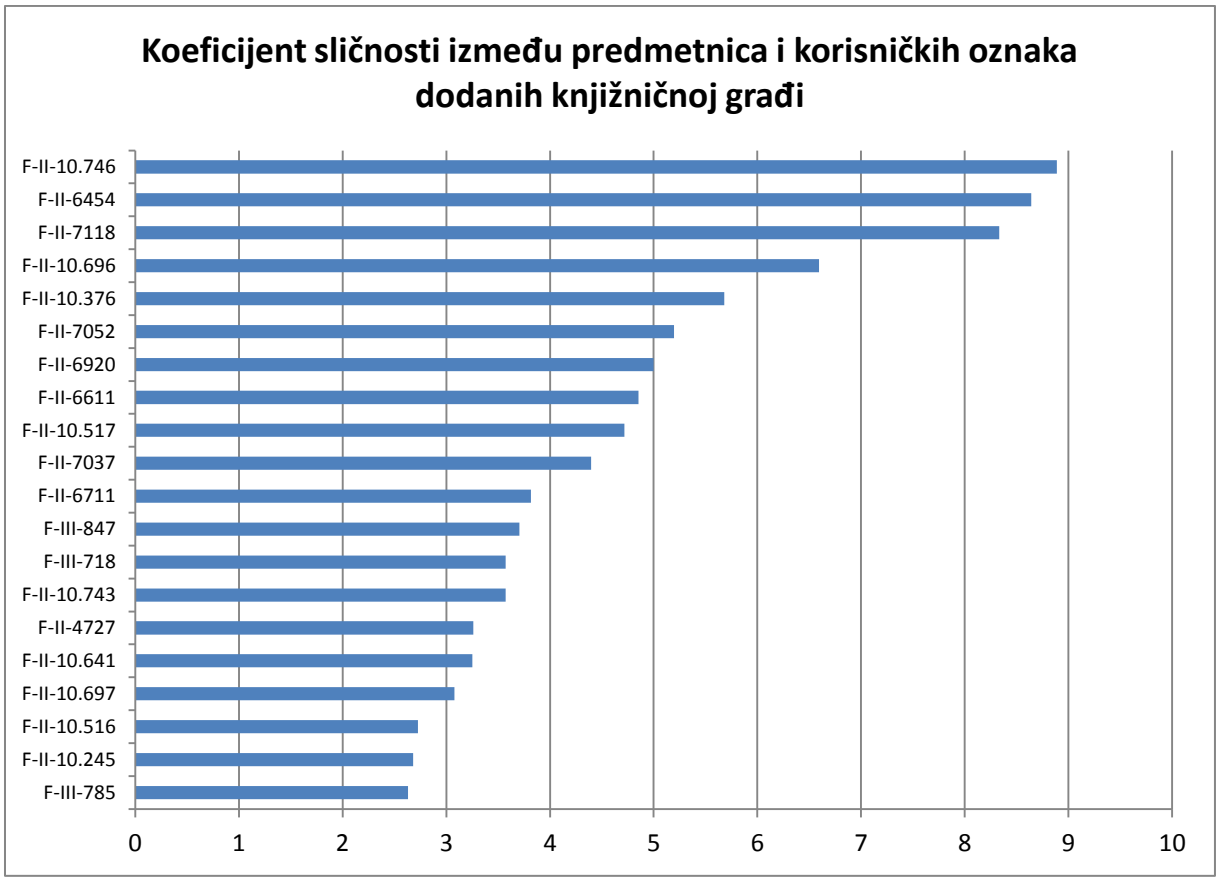

Slika 86 - Koeficijent sličnosti između predmetnica i korisničkih oznaka dodanih knjižničnoj građi

Analizom koeficijenta sličnosti na razini predmeta možemo vidjeti kako on varira od čak 8.89 (predmet F-II-10.746) pa do ispod 3 (predmeti F-II-10.516, F-II-10.245 i F-III-785).

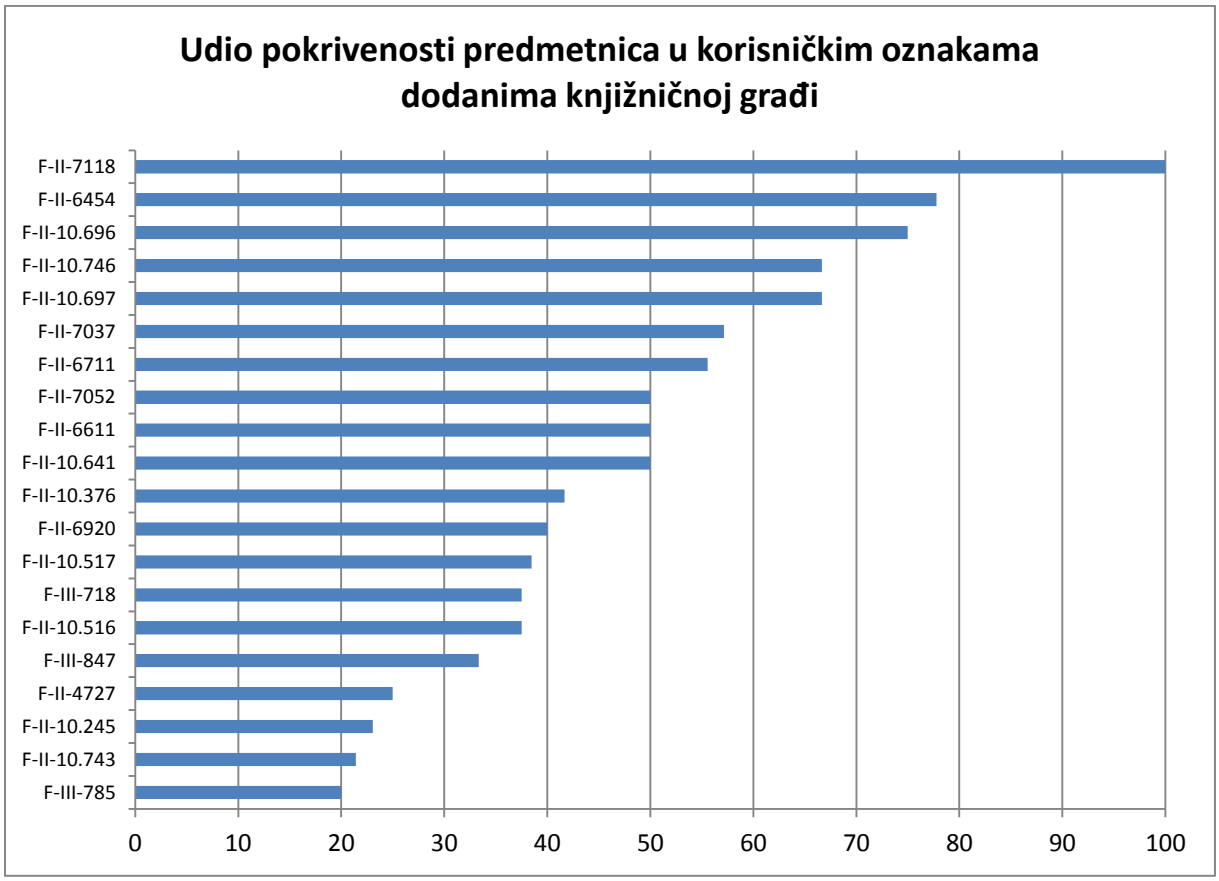

Slika 87 - Udio pokrivenosti predmetnica u korisničkim oznakama dodanima knjižničnoj građi

Analizom na razini predmeta možemo vidjeti kako pokrivenost predmetnica u korisničkim oznakama varira od 100% (predmet F-II-7118) pa do ispod 20% (predmet F-III-785).

Mjerenjem korelacije između koeficijenta sličnosti i udjela pokrivenosti na razini predmeta pokazalo se kako postoji umjerena do snažna pozitivna povezanost (r=+0.76).

U tom pogledu, mjera koeficijenta sličnosti pokazala se pouzdanom kao mjera usporedbe sličnosti dva seta termina s nejednakim brojem elemenata u svakome skupu na razini zbirke knjižnične građe.

5.6.1.6. Usporedba na zbirci muzejske građe

Kao što podaci u Tablici 25 pokazuju, unutar zbirke muzejske građe, prosječno su se 2 termina, koje je dodao predmetni stručnjak, također pojavila i u setu termina korisničkih oznaka, a prosječna pokrivenost predmetnica u korisničkim oznakama iznosila je 42%.

Tablica 25 - Usporedba predmetnica i korisničkih oznaka na zbirci muzejske građi

	BROJ PREDMETNICA	BROJ KORISNIČKIH OZNAKA	BROJ ZAJEDNIČKH TERMINA	Ks	UDIO ZAJEDNIČKIH TERMINA U PREDMETNICAMA
TOTAL	**123**	**1403**	**47**	**3.56**	**42.32%**
MAX	10	111	4	7.55	100.00%
MIN	4	33	0	0.00	0.00%
PROSJEK	6.15	70.15	2.35	3.56	42.32%
STDEV	2.23	23.77	1.31	2.32	25.02%

Grafički prikaz koeficijenta sličnosti (Slika 88) i udjela zajedničkih termina u predmetnicama (Slika 89), sortiran prema najvećim vrijednostima, potvrđuje podatak o dosta visokoj standardnoj devijaciji između rezultata na razini predmeta od 25%.

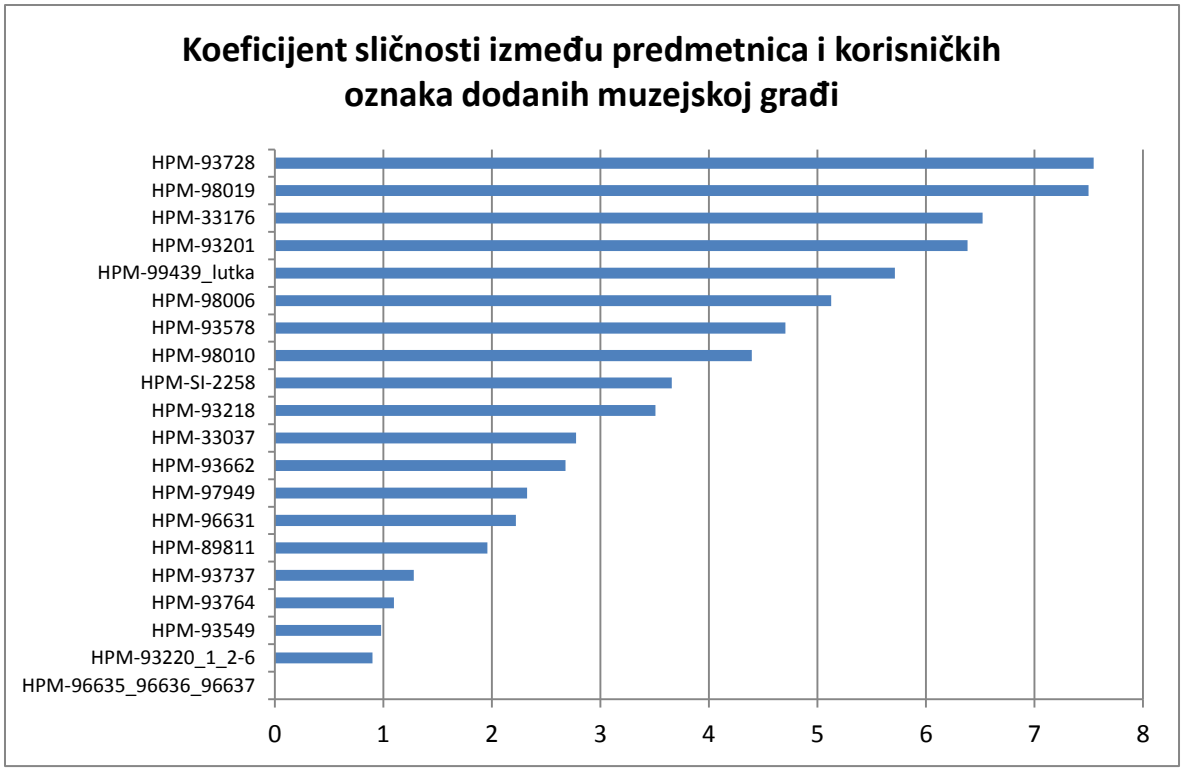

Slika 88 - Koeficijent sličnosti između predmetnica i korisničkih oznaka dodanih muzejskoj građi

Analizom koeficijenta sličnosti na razini predmeta možemo vidjeti kako on varira od čak 7.50 (predmet HPM-93728) pa do nule (predmet HPM-96635_96636_96637).

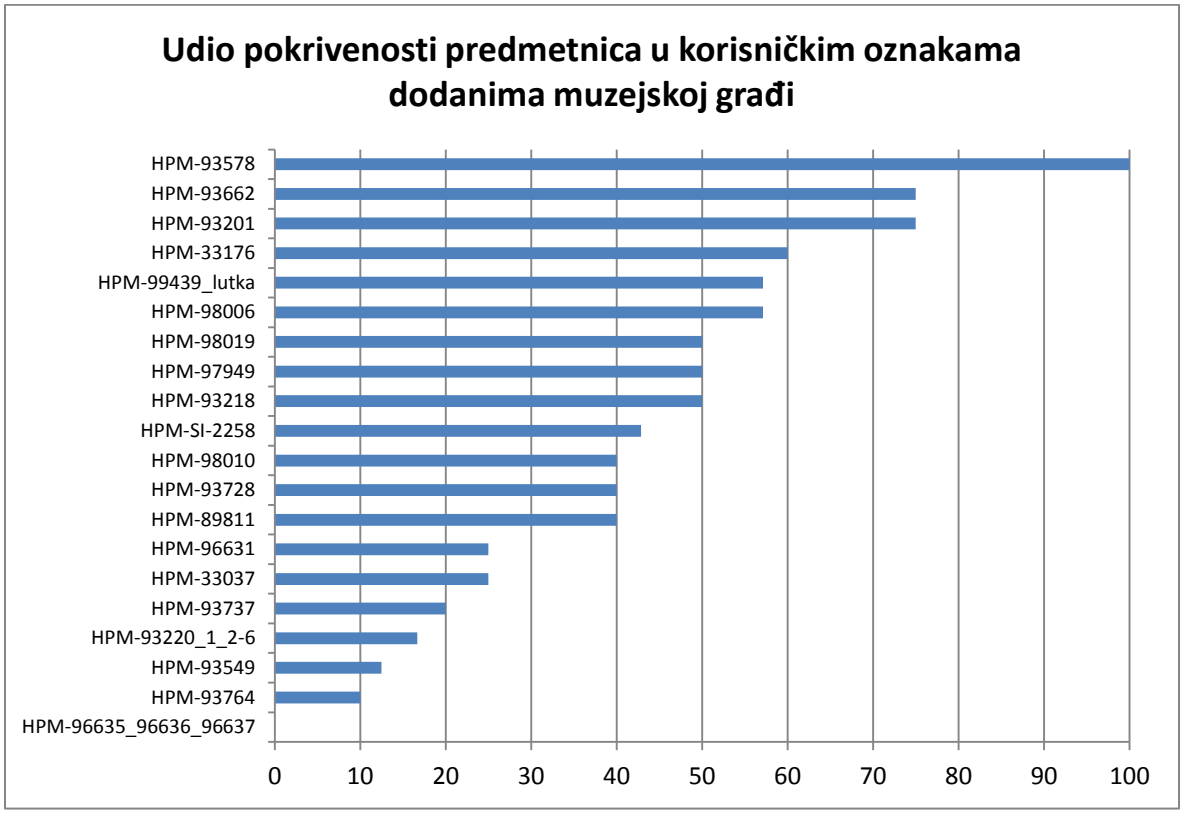

Slika 89 - Udio pokrivenosti predmetnica u korisničkim oznakama dodanima muzejskoj građi

Analizom na razini predmeta možemo vidjeti kako pokrivenost predmetnica u korisničkim oznakama varira od 100% (predmet HPM-93578) pa do 0% (predmet HPM-96635_96636_96637).
Mjerenjem korelacije između koeficijenta sličnosti i udjela pokrivenosti na razini predmeta pokazalo se kako postoji umjerena do snažna pozitivna povezanost (r=+0.65).
U tom pogledu, mjera koeficijenta sličnosti pokazala se pouzdanom kao mjera usporedbe sličnosti dva seta termina s nejednakim brojem elemenata u svakome skupu na razini zbirke knjižnične građe.

Rezultati su pokazali kako nema većih odstupanja u pokrivenosti predmetnica korisničkim rječnikom, kao niti usporedbom putem koeficijenta sličnosti na razini zbirke. Tablica 26 donosi sumirane podatke prema vrstama građe.

Tablica 26 - Preklapanje između setova termina predmetnica i korisničkih oznaka - sumirani podaci

VRSTA	BROJ PREDMETNICA	BROJ KORISNIČKIH OZNAKA	BROJ ZAJEDNIČKIH ELEMENATA	UDIO ZAJEDNIČKIH TERMINA U PREDMETNICAMA	Ks	STDEV	KORELACIJA
MUZ	123	1403	47	42.32%	3.56	25.02	0.65
KNJ	191	1803	86	48.34%	4.73	21.07	0.76
FOTO	117	1811	61	52.87%	3.35	18.82	0.54
ARH	130	1571	52	41.97%	3.38	17.03	0.75
UKUPNO	**561**	**6588**	**246**	**46.37%**	**3.76**	**20.48**	**0.67**

Usporedba predmetnica dodanih od strane predmetnih stručnjaka i prikupljenih korisničkih oznaka na razini predmeta poduzeta je kako bi se uvidjele eventualne razlike u pristupu korisničkom označivanju tradicionalnih vrsta građe u AKM ustanovama. U tom smislu postavljena je hipoteza H2b:

H2b: Postoji značajna razlika u mjeri preklapanja između predmetnica dodanih od strane stručnjaka i prikupljenih korisničkih oznaka na razini različitih vrsta građe

Nakon provedene analize možemo zaključiti kako se na razini različitih vrsta građe nije pokazala značajna razlika u pokazateljima usporedbe predmetnica i korisničkih oznaka te hipoteza **nije dokazana.**

5.6.2. Ocjena korisnosti prikupljenih korisničkih oznaka od strane predmetnog stručnjaka

Druga faza istraživanja, kojom se željela ispitati razlika u prikupljenim korisničkim oznakama na razini predmeta, uključivala je ocjenu prikladnosti prikupljenih oznaka od strane predmetnog stručnjaka.

Kako je već opisano, svaki od 80 predmeta opisan je s dva seta termina: (1) predmetnice dodijeljene od strane predmetnog stručnjaka i (2) prikupljene korisničke oznake putem aplikacije. Ideja je ovog dijela istraživanja bila dati prikupljene korisničke oznake natrag samom predmetnom stručnjaku kako bi ocijenio koliko su oznake, dodane od strane korisnika, korisne iz stručne perspektive, tj. koliko su prikladne za uključivanje u predmetni opis.

Kako vidimo iz Tablice 26, predmetima je dodano 6588 korisničkih oznaka, što je predstavljalo preveliki set termina za ocjenu, jer bi sam postupak zahtijevao previše utrošenog vremena. Upravo zbog toga bilo je potrebno kreirati model kojim bi se set svih korisničkih oznaka sveo na set korisničkih oznaka za koji je moguće očekivati da ga predmetni stručnjak može pregledati i ocijeniti, tj. kreirati model koji će omogućiti relevantnim korisničkim oznakama za svaki predmet da se nalaze u setu oznaka koje stručnjak ocjenjuje.

Osnovni koraci u kreiranju modela bili su:

1. odrediti mjeru relevantnosti korisničke oznake za pojedini predmet
2. odrediti prag relevantnosti korisničke oznake za pojedini predmet
3. provesti analizu dodanih oznaka prema mjeri i pragu koji je odabran
5. dobivene oznake dati stručnjaku na ocjenjivanje.

Mjera relevantnosti korisničke oznake za pojedini predmet

Kako je prikazano u pregledu servisa koji koriste korisničke oznake kao metodu organizacije (npr. Last.fm), pokazalo se kako je frekvencija termina kojom je opisan neki predmet uzimana kao mjera relevantnosti neke korisničke oznake. To jednostavno znači kako sustav bilježi sva pojavljivanja nekog termina uz određeni resurs te se svakim pojavljivanjem iste oznake, dodane od strane različitih korisnika, dobiva njena frekvencija na razini opisa predmeta unutar sustava. Kako je u ovom istraživanju način prikupljanja podataka uključivao i frekvenciju svake oznake dodane nekom predmetu, bilo je moguće primijeniti istu metodu. Ideja same

frekvencijske metode je prilično jednostavna – što je više različitih korisnika dalo neku oznaku pojedinom izvoru, možemo tu oznaku smatrati relevantnijom za taj izvor. Time se ostvaruje demokratični pristup indeksiranju koji je u samoj osnovi korisničkog označivanja – što više korisnika „glasa“ za neku oznaku, njena relevantnost unutar sustava raste.

Prag relevantnosti korisničke oznake za pojedini predmet

Nakon odluke o tome kako je frekvencija osnova relevantnosti neke korisničke oznake za neki predmet, bilo je potrebno odlučiti kako postaviti prag uključivanja, tj. kolika je minimalna frekvencija koja će osigurati da oznaka bude uključena u set za ocjenjivanje.

Ovdje u osnovi možemo razlikovati dva pristupa:

(1) **postaviti prag rangiranja** – odabrati određen broj najfrekventnijih oznaka (npr. 10 ili 20) i njih uključiti u set

(2) **postaviti frekvencijski prag** (npr. 3 ili 5) – uključiti sve oznake koje zadovoljavaju ili prelaze prag i njih uključiti u set.

Prva metoda je način na koji funkcionira servis Last.fm koji smo opisivali ranije. Uz svaki resurs koji se opisuje na servisu pojavljuje se 5 najčešće dodanih oznaka, dok je oblak oznaka za svaki resurs ograničen na 60 najčešćih oznaka. Ovdje sama frekvencija igra ulogu rangiranja, tj. ona sama po sebi nema značenje – moguće je da u setu od najčešćih oznaka, oznaka s najmanjom frekvencijom bude 1 ili 100, ovisno o broju oznaka unutar sustava i korisnika koji koriste sustav. Kako se unutar servisa stalno dodaju nove oznake, ta su dva popisa podložna stalnoj promjeni i mijenjaju se ovisno o tome uspijeva li neka oznaka ući u 5 ili 60 najčešćih oznaka za neki resurs, što takav način mjerenja relevantnosti neke oznake čini prikladnim za sustave koji se stalno nadopunjuju novim podacima i za koje se očekuje veliki broj korisnika.

Drugi pristup temelji se na principu određivanja minimalne frekvencije koju neka oznaka može imati unutar sustava, kako bi se smatrala relevantnom. Ovdje se kao glavno pitanje postavlja određivanje te minimalne frekvencije. Dok je u prvoj metodi frekvencija važna samo kao pokazatelj ranga, ovdje je njena uloga drugačija – postavimo li frekvencijski prag na npr. 2, tada je moguće (ako nemamo dovoljan broj oznaka i sve dodane oznake imaju frekvenciju 1) da sam set za ocjenjivanje bude prazan i ne uključuje nijednu oznaku.

U ovoj disertaciji odlučeno je kako će set oznaka za ocjenjivanje slijediti drugi pristup, tj. kreiranje seta temeljit će se na postavljanju frekvencijskog praga. Odluka je donesena iz tri osnovna razloga:

(1) aplikacijom se prikupio konačan broj podataka i nema potrebe za sustavom rangiranja koji uzima u obzir nove oznake

(2) broj dodanih oznaka pokazuje značajne nejednakosti na razini predmeta (Prilog 3), što znači da bi se najčešće oznake za neke predmete temeljile na znatno različitoj frekvenciji

(3) postavljanje granice rangiranja prenisko ili previsoko moglo bi isključiti relevantne oznake (s visokom frekvencijom) na predmetima koji imaju velik broj dodanih oznaka ili uključiti one koje nisu relevantne (npr. frekvencije 1) na predmetima s manjim brojem dodanih oznaka.

Iz tih razloga, odlučeno je kako je bolja metoda koristiti podatak o frekvenciji ne samo kao metodu rangiranja, već uzeti i samu frekvenciju u obzir kao mjeru relevantnosti, tj. mjeriti relevantnost neke oznake ne u odnosu na druge oznake, već u odnosu na broj korisnika koji su je pridružili nekom resursu.

Određivanje praga minimalne frekvencije

Kao što je već spomenuto, kod pristupa koji smo odabrali, glavno pitanje koje se postavlja je određivanje praga minimalne frekvencije. Pregledom literature samo je Trant (2009) radila ovakvu vrstu istraživanja u kojem se korisničke oznake vraćaju stručnjaku na ocjenjivanje, ali rad uopće ne postavlja granicu, već zbog manjeg broja prikupljenih korisničkih oznaka uključuje sve oznake. Kako to nije bilo moguće u ovom istraživanju zbog velikog broja korisničkih oznaka, pokazalo se kako je potrebno odrediti frekvencijski prag.

Da bi odredili kako pristupiti određivanju razine frekvencijskog praga, najprije se treba vratiti na prikaz frekvencijske razdiobe samih prikupljenih oznaka. Kako smo vidjeli, frekvencijska distribucija broja dodjeljivanja je vrlo nejednaka, gdje je veliki broj oznaka dodan mali broj puta, dok je mali broj oznaka dodan veliki broj puta. Takva raspodjela ukazuje na postojanje ekstremnih vrijednosti te je asimetrična. To se potvrđuje i visokim stupnjem standardne devijacije i velikim razlikama između maksimalnih i minimalnih vrijednosti. Kod takvih nejednakih i asimetričnih distribucija, korisna mjera varijabilnosti je interkvartilni rang, razlika između vrijednosti koja pada na 3. kvartil i vrijednosti koja pada na 1. kvartil i obuhvaća središnjih 50% rezultata (Petz, 2002), koji nam omogućuje izračunavanje gornje granične vrijednosti neke distribucije (engl. *top outlier*). Uzmimo jedan primjer iz prikupljenih podataka kako bismo ilustrirali navedenu mjeru.

Predmet HPM-93196_42.jpg ima set dodanih korisničkih oznaka koje, sortirane prema uzlaznoj frekvenciji, daju sljedeći uređeni set od ukupno 104 podatka o frekvenciji:

{1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 1; 2; 2; 2; 2; 2; 2; 2; 2; 2; 3; 3; 3; 3; 3; 3; 3; 3; 3; 4; 4; 4; 5; 5; 5; 5; 6; 6; 6; 6; 7; 8; 10}

Slika 90 prikazuje grafički prikaz intekvartilnih i gornjih graničnih vrijednosti preko box-plot grafa.

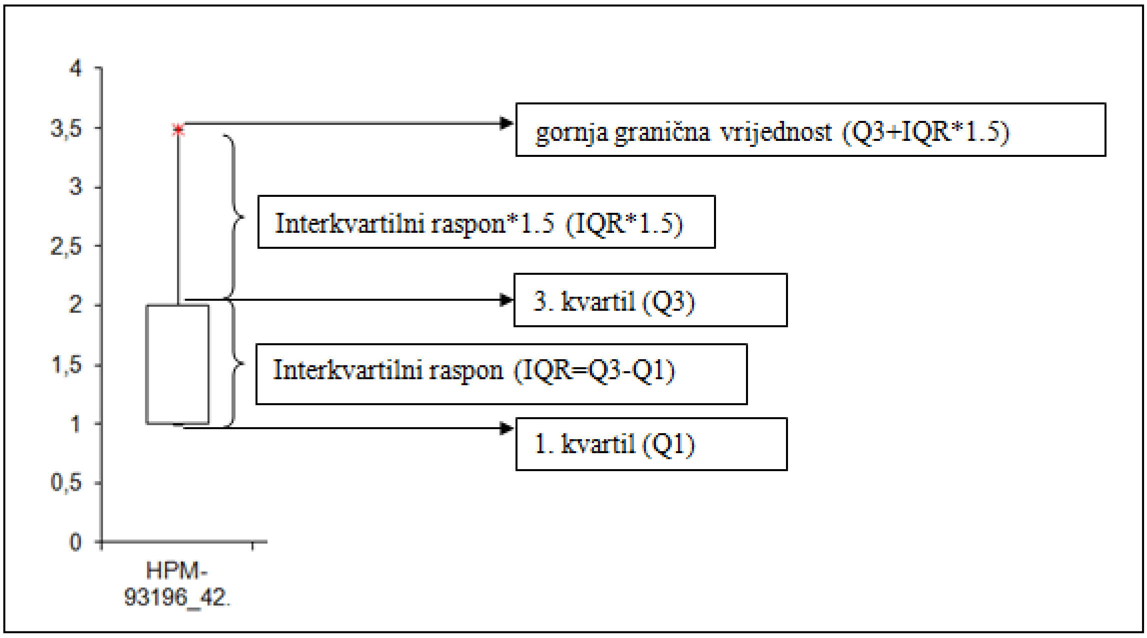

Slika 90 - Grafički prikaz intekvartilnih i gornjih graničnih vrijednosti preko box-plot grafa

Kako bi dobili 1. kvartil, tj. poziciju u setu ispod koje se nalazi 25% svih vrijednosti unutar seta, pomnožimo ukupan broj elemenata s 0.25 (104*0.25) te time dobijemo poziciju položaja prvog kvartila (26). Dakle na 26. poziciji u našem setu podataka nalazi se vrijednost ispod koje se nalazi 25% svih vrijednosti seta. U našem slučaju on iznosi 1, tj Q1=1.

Kako bi dobili 3. kvartil, tj. poziciju u setu ispod koje se nalazi 75% svih vrijednosti unutar seta, pomnožimo sa 0.75 (104*0.75) te time dobijemo poziciju položaja trećeg kvartila (78). Dakle na 78. poziciji u našem setu podataka nalazi se vrijednost ispod koje se nalazi 75% svih vrijednosti seta. U našem slučaju on iznosi 2, tj Q3=2.

Nakon što smo izračunali vrijednosti 1. i 3. kvartila, oduzimanjem vrijednosti Q1 od Q3 dobivamo interkvartilni raspon, tj. raspon u koji spada 50% svih rezultata. U našem slučaju ta vrijednost iznosi 1, tj, IQR=1.

Na temelju izračunatog interkvartilnog raspona, moguće je izračunati granične vrijednosti. Graničnom vrijednošću smatra se svaka vrijednost koja je 1.5 puta veća ili manja od interkvartilnog raspona, tj. 1.5 puta veća ili manja od 50% vrijednosti u setu (Petz, 2002). Na taj način možemo izračunati graničnu vrijednost za naš set (1*1.5) koja iznosi 1.5.

S obzirom da želimo dobiti gornju graničnu vrijednost (engl. *top outlier*), graničnu vrijednost dodamo na vrijednost 3. kvartila (Q3). U našem slučaju ona iznosi 3.5 (2+1.5). Kako nama treba cijeli broj, gornju graničnu vrijednost zaokružujemo na veći broj i time dobivamo frekvencijsku granicu definiranu na vrijednosti 4.

Korištenjem statističke metode određivanja granice pomoću dorađivanja gornje granične vrijednosti u distribuciji, omogućena je varijabilna granica prikladna za svaki predmet u odnosu na njegovu frekvencijsku distribuciju, što mjeru čini prikladnom bez obzira na razlike između predmeta. Dakle, za naš početni set od 104 oznake, primjenom ove metode, set je sveden na 14 korisničkih oznaka koje imaju frekvenciju 4 ili višu.

Algoritamsko rješenje izračunavanja kvartila implementirano je u programskom jeziku Python pomoću proširenja za računanje kvantila, autora Ernesta Adoria (http://adorio-research.org/wordpress/?p=125), a gornje granične vrijednosti pomoću funkcije `getTopOutlierCutoff` prikazane na slici 91.

```
def getTopOutlierCutoff(p, multi=1.5):
    p = sorted(p)
    q1 = quantile(p, 0.25, issorted=True)
    q3 = quantile(p, 0.75, issorted=True)
    iqr = q3 - q1
    return q3 + iqr * multi
```

Slika 91 - Određivanje gornje granične vrijednosti pomoću funkcije getTopOutlierCutoff

Nakon provedenog postupka za sve predmete, prije postupka ocjenjivanja od strane stručnjaka, provedena je usporedba dobivenog seta termina sa setom predmetnica, kako bi se iz dobivenog seta izbacile sve oznake koje su već prisutne u predmetnicama.

Predmetnim stručnjacima vraćen je set oznaka, uz uputu da svaku oznaku ocijene prema razini korisnosti za opis pojedinog predmeta. Za procjenu korisnosti korištena je standardna Likertova skala od 1 do 5 s pripadajućim tumačenjem:

1- nikako ne uključiti u opis predmeta
2- ne uključiti u opis predmeta
3- može se i ne mora uključiti (nije pogrešno, ali nema neku dodanu vrijednost)
4- uključiti u opis predmeta
5 - svakako uključiti u opis predmeta

Uz samu skalu, predmetnim stručnjacima dane su i kratke usmene upute o ocjenjivanju u kojima se objasnilo kako model testira način na koji bi se korpus korisničkih oznaka (koji može biti i više stotina tisuća ili više milijuna), pomoću automatskih metoda, sveo na korpus u kojem su zadržane sve osobine korisničkog rječnika (uključivanje najfrekventnijih oznaka), kao i na veličinu za koju se može očekivati da stručnjak može u razumno vrijeme pregledati i ocijeniti njihovu korisnost uključenja u opis predmeta. U tom smislu, stručnjaku su oznake samo prijedlozi termina koji su dobiveni od strane korisnika, mogu se prilagođavati te mijenjati po želji prije uključenja u sam opis predmeta. Oznake treba ocijeniti obzirom na njihov potencijal, a ne isključivo na lingvističkoj razini. Oznaku ne treba promatrati isključivo kao dodatak samim predmetnicama, već kao mogući zaseban skup koji bi se, recimo, prikazivao pored samog opisa predmeta pod imenom npr. „korisničke oznake“, te se u tom svjetlu ocjenjuju kao moguće nove pristupne točke u pretrazi za nekim od predmeta unutar zbirke, a ne isključivo kao novi element koji bi se dodao samim predmetnicama.
Prilog 5 (*Prosječne ocjene korisnosti korisničkih oznaka od strane predmetnih stručnjaka*) donosi potpune podatke, dok se u tablicama u nastavku nalaze sumirani podaci prema vrstama građe. Tablice 27 i 28 donose sumirane statističke podatke o broju oznaka koje su dane na ocjenu predmetnim stručnjacima, te prosječne ocjene korisnosti korisničkih oznaka od strane predmetnih stručnjaka.

Tablica 27 – Statistički pokazatelji seta korisničkih oznaka koje su dane na ocjenu predmetnim stručnjacima (sumirani podaci)

VRSTA	BROJ PREDMETA	BROJ OZNAKA	PROSJEČAN BROJ OZNAKA	NAJVEĆI BROJ OZNAKA	NAJMANJI BROJ OZNAKA	STDEV	MEDIJAN	MOD
MUZ	20	138	6.9	13	1	3.63	7	7
FOTO	20	178	8.9	19	1	4.72	8	8
ARH	20	147	7.35	25	3	4.86	6.5	5
KNJ	20	143	7.15	14	3	3.08	6.5	5
UKUPNO	**80**	**606**	**7.575**	**25**	**1**	**4.07**	**6.75**	**5**

Tablica 28 - Prosječne ocjene korisnosti korisničkih oznaka od strane predmetnih stručnjaka (sumirani podaci)

VRSTA	BROJ PREDMETA	BROJ OZNAKA	PROSJEČNA OCJENA	NAJVEĆA OCJENA	NAJMANJA OCJENA	STDEV	MEDIJAN	MOD
MUZ	20	138	4.08	5	3.38	0.47	4.00	4.00
FOTO	20	178	3.72	5	3.00	0.59	4.00	4.33
ARH	20	147	3.81	5	3.00	0.54	4.11	4.33
KNJ	20	143	2.66	4	1.40	0.71	2.65	3.25
UKUPNO	**80**	**606**	**3.57**	**5**	**2.70**	**0.58**	**4.00**	**4.33**

Kako vidimo iz podataka, algoritamsko rješenje određivanja frekvencijske granice pojedinih predmeta dalo je ujednačene setove korisničkih oznaka za ocjenu s rasponom od 138 do 178 korisničkih oznaka po zbirci. Raspodjela oznaka po predmetu pokazuje dosta velike varijacije na razini predmeta (od 1 do 25 korisničkih oznaka), međutim, podaci o srednjoj vrijednost skupa (6,75) kao i najčešćoj vrijednosti u skupu (5) uz podatak o standardnoj devijaciji (4,07) pokazuju kako je od 80 predmeta za najveći broj njih algoritam dao između 5 i 10 korisničkih oznaka (47 ili 59%), dok je manje od 5 oznaka dao za 17 predmeta (21%), a više od 10 za 16 predmeta (20%). Ti podaci pokazuju kako je izbacivanjem ekstremnih vrijednosti skup korisničkih oznaka dobivenih algoritmom prilično ujednačeno raspoređen po predmetima.

Što se tiče prosječnih ocjena, podaci pokazuju kako je predmetni stručnjak, koji je ocjenjivao korisnost oznaka dodanih arhivskoj, muzejskoj i fotografskoj građi, visoko ocijenio samu korisnost (medijan i mod iznad 4), s minimalnom prosječnom ocjenom 3, što pokazuje visoku korisnost samog modela za navedene vrste građe.

Ocjena za knjižničnu građu znatno je manja i odstupa od prosjeka ostalih vrsta građe, što se može objasniti samim načinom prikupljanja podatka. Naime, sama aplikacija poticala je korisnike na *opisivanje* same skenirane surogate knjižnične građe, te se velik broj oznaka odnosio na opise motiva na naslovnicama koje nisu relevantne za predmetni opis samog djela. S te strane, predmetni stručnjak je nisko ocijenio takve korisničke oznake jer nisu vezane uz predmet samog djela.

Vratimo li se na samu skalu ocjenjivanja, možemo vidjeti kako u određivanju granice ocjene na kojoj će stručnjak uključiti oznaku u predmetni opis možemo slijediti dva pristupa:

1. **postaviti granicu na ocjenu >=3** i time *isključiti* sve oznake koje su dobile ocjene „1- nikako ne uključiti u opis predmeta“ ili „2- ne uključiti u opis predmeta“ ili

2. **postaviti granicu na ocjenu >=4** i tim *uključiti* samo oznake koje su dobile ocjene „4-uključiti u opis predmeta“ i „5-svakako uključiti opis predmeta“

Tablica 29 prikazuje postotak korisničkih oznaka koje bi predmetni stručnjak uključio u opis uz različito postavljene granice.

Tablica 29 - Postotak korisničkih oznaka koje bi predmetni stručnjak uključio u opis

VRSTA	BROJ PREDMETA	BROJ OZNAKA	POSTOTAK UKLJUČENIH (OCJENA >=4)	POSTOTAK UKLJUČENIH (OCJENA >=3)
MUZ	**20**	**138**	**75%**	**92%**
FOTO	**20**	**178**	**62%**	**82%**
ARH	**20**	**147**	**63%**	**89%**
KNJ	**20**	**143**	**31%**	**58%**
UKUPNO	80	606	57.75%	80.25%

Kako možemo vidjeti, postavimo li granicu na ocjenu 3 ili više, pokazuje se kako je u prosjeku samo 10% oznaka za arhivsku, muzejsku i fotografsku građu ocijenjeno neprikladnima, dok je taj broj 42% za knjižničnu građu.

Postavimo li granicu na ocjenu 4 ili više, tada u opis ulazi od 62-75% posto svih oznaka predloženih modelom za arhivsku, muzejsku i fotografsku građu, dok je taj postotak 31% za knjižničnu građu.

Ti podaci jasno pokazuju kako je predloženi model pristupa analizi i implementaciji prikladniji za muzejsku, arhivsku i fotografsku građu, dok kod knjižnične građe pokazuje slabiju učinkovitost.

Na temelju dobivenih podataka, možemo pristupiti ocjeni hipoteze H2c:

H2c: Postoji značajna razlika u ocjeni prikladnosti korisničkih oznaka za predmetni opis od strane predmetnog stručnjaka

Kako je analizom prikupljenih podataka uočena značajna razlika u ocjeni prikladnosti oznaka za predmetni opis knjižnične građe, gdje se pokazalo kako je model primjeren za analizu i implementaciju arhivske, muzejske i fotografske građe, dok kod knjižnične građe pokazuje značajno slabiju učinkovitost, možemo zaključiti kako je **hipoteza dokazana.**

Zaključak

Nakon izloženih praktičnih implementacija korisničkog označivanja, teorijskih modela, pregleda istraživanja u znanstvenoj literaturi te provedenog istraživanja na korpusu hrvatskih korisničkih oznaka, ovdje možemo sumirati zaključke svakog poglavlja uz raspravu o ključnim rezultatima.

Servisi za suradničko označivanje uveli su korisničke oznake kao metodu organizacije izvora na globalnu razinu. Takav način organizacije omogućuje korisniku pregledavanje i pretraživanje izvora kroz pet pristupnih točaka (Peters, 2009):

- **oblak oznaka** – popis najčešće dodanih oznaka unutar sustava
- **nedavno dodani izvori** – popis svježe dodanih oznaka u sustav od strane korisnika
- **popularni izvori** – popis najpopularnijih izvora rangiranih prema broju spremanja od strane korisnika
- **pojedinačne oznake** – popis svih izvora označenih pojedinačnom oznakom
- **osobne oznake korisnika** – popis svih izvora koje je neki korisnik pohranio zajedno s oznakama koje je dodao.

Osnovni postupak temelji se na ideji kako korisnici, neovisno jedan o drugome, označuju sadržaj te time na demokratski način stvaraju novi sadržaj koji postaje raspoloživ cijeloj zajednici. Takav pristup organizaciji sadržaja jedan je od osnovnih principa Weba 2.0, u kojem arhitektura servisa omogućava da mali doprinos svakog korisnika daje velike rezultate za cijelu zajednicu. Kada se on uključi u ukupnost svih oznaka na sustavu, stvara se sustav korisničke organizacije u kojoj nitko od korisnika nema osjećaj da je uložio poseban napor oko samog postupka.

Osim što sustavi omogućuju pretraživanje i organizaciju, jedna od najvećih prednosti je omogućavanje društvenog pregledavanja grupiranjem tema preko URL adrese ili oblaka oznaka. Na taj način korisnik, koji i nije siguran u samu terminologiju ili nije upoznat sa svim podtemama neke šire teme, može na jednostavan način doći do relevantne informacije, što je i mjera uspješnosti sustava općenito.

Još jedna prednost sustava koji koriste korisničko označivanje mogućnost je interaktivnosti i istraživanja načina na koji korisnici mogu organizirati sadržaj. Oznake se mogu slobodno

stvarati, grupirati, dijeliti s drugima ili je moguće stvoriti privatan sustav organizacije koji najbolje odgovara korisniku u odnosu na sadržaj koji označuje.

Dok kod klasičnih taksonomija smjer označivanja teče od općeg prema posebnome, dodjeljivanje korisničkih oznaka tu formulu okreće u suprotnome smjeru, krećući od pojedinačnih obilježja svake stvari, koristeći korisnike koji generiraju sve pojmove koji se njima čine prikladnima za opisivanje nekog izvora. Tako sami korisnici kroz praksu stvaraju vlastiti sustav organizacije, a ujedno i zadržavaju mogućnost da dodavanjem svojih oznaka zadrže subjektivni pristup, dodajući oznake koje su njima relevantne i pomoću kojih kasnije mogu pronaći označeni sadržaj.

Servisi za suradničko označivanje imaju niz prednosti pred tradicionalnim metodama automatskog pronalaženja mrežnih izvora ili automatske klasifikacije istih. Dok se u takvim metodama cijeli pronalazak i označavanje resursa obavljaju automatski od strane računala, u servisima za suradničko označivanje taj posao preuzimaju stvarne osobe. I dok se računalo oslanja na složene algoritme pomoću kojih se pokušava doprijeti do značenja sadržaja nekog resursa, ljudska selekcija i označavanje izvora mnogo je kvalitetnija jer se oslanja na stvarno razumijevanje izvora. Uz to, korisnici će označivati one izvore koje smatraju korisnima, što znači da će najkorisniji izvori biti i najviše puta označeni. To omogućuje rangiranje resursa po njihovoj popularnosti, tj. korisnosti. Takvo rangiranje provode ljudi, što je mnogo bolji pokazatelj korisnosti nekog izvora krajnjim korisnicima od metoda koje se provode automatski i koje se oslanjaju na neku od metoda automatskog rangiranja. Kao što smo već spomenuli kod opisa servisa Last.fm, sustav takvih kontekstualnih metapodataka nije ni u jednom trenutku konačan, već se stalno mijenja i prilagođava. Na taj način sustav opisa nikada ne zastarijeva jer odražava s jedne strane korisnički rječnik, a s druge strane lako se može dodati nove oznake koje bolje odražavaju sam sadržaj servisa.

Istraživanje korisničkog označivanja u znanstvenoj literaturi

Pristup pregledu literature u nekoliko komplementarnih faza omogućio je vrlo jasan uvid u polje istraživanja, pruživši pregršt korisnih podataka. Prva faza, u kojoj se pristupilo identificiranju i webometrijskoj analizi ključnih termina koje autori koriste, osigurala je jamstvo uporabe samih termina u stručnoj literaturi te pružila osnovu za pretragu znanstvenih baza podataka, kao i za početak rješavanja terminoloških problema prijevoda osnovnih termina na hrvatski jezik. Pokazalo se kako u literaturi postoje četiri temeljna termina za koje možemo reći da zadovoljavaju jamstvo uporabe, tj. da se često koriste u raspravama vezanima

uz područje istraživanja korisničkog označivanja na engleskom jeziku: *folksonomy, user-generated metadata, social tagging* i *collaborative tagging*. Identificiranje ključnih termina vrlo je važan korak u pregledu istraživanja bilo kojeg područja zbog opasnosti da se izostavljanjem jednog od termina iz pregleda literature izostavi niz značajnih radova. Kako je teško očekivati da će neki pregled literature obuhvatiti potpuni uzorak svih radova napisanih na izabranu temu, ovom metodom osigurava se da će uzorak prikupljenih istraživanja biti reprezentativan.

Identifikacijom temeljnih teorijskih termina, moglo se pristupiti pretrazi relevantnih baza podataka u ovom području, kako bi se pokušalo uvidjeti koliko je područje istraživanja zastupljeno u literaturi, tj. koliki se broj radova u relevantnim i recenziranim publikacijama bavi područjem društvenog označivanja u polju informacijskih znanosti. Opet, novo područje istraživanja traži dodatni oprez zbog mogućnosti da tema istraživanja nije dovoljno zastupljena u relevantnim bazama podataka unutar područja, što s jedne strane može značiti inovativnost same teme, ali u većini slučajeva znači kako tema s razlogom nije izazvala veći interes autora pa treba razmisliti o njenoj relevantnosti i znanstvenom doprinosu. Rezultati pretrage radova o društvenom označivanju pokazali su kako je područje, iako mlado s najranijim radovima objavljenim 2004. godine, već ima značajan broj radova koji se bave područjem unutar relevantnih i recenziranih publikacija iz područja.

Očekivano je najmanji broj radova pronađen u bazi Web of Science (346) koja sadrži časopise s najvećim faktorom utjecaja, zatim u bazi SCOPUS (1581) te na kraju u bazi Google Scholar. Pokazalo se kako je od dvadeset najcitiranijih radova samo njih šest prisutno u obje bibliografske baze (WOS i SCOPUS), što pokazuje određenu heterogenost u istraživanjima, ali i važnost uključivanja više izvora u pregled literature. Daljnja bibliometrijska analiza radova omogućila je uvid u najutjecajnije autore korištenjem analize kocitata kao i kreiranje svojevrsne vremenske lente najutjecajnijih radova uključivanjem godine objave citiranih radova u analizu. Obje analize potvrdile su rad autora Goldera i Hubermana (*Usage patterns of collaborative tagging systems*), koji daje teorijsku podlogu i strukturu proučavanja polju istraživanja i potvrdile ga kao najutjecajniji rad u području, ali i dale pregled ostalih najcitiranijih radova u području.

Nakon kvantitativne analize područja kroz analizu citiranosti radova, sljedeći je korak u pregledu literature bio sadržajna analiza pronađenih radova kako bi se dobio okvir i tematsko određenje polja istraživanja. Analizom podataka o tome u kojem je časopisu neki rad objavljen, pokazalo se kako je najveći broj radova objavljen u časopisima s područja informacijskih znanosti te, specifičnije, knjižničarstva (engl. *Library and Information Science*

(LIS)). Uz baze SCOPUS, WOS i LISTA, u pretragu je uključena i baza Google Scholar kako bi se dobila šira baza radova osim onih objavljenih u časopisima s visokim faktorom utjecaja, kao što su knjige ili zbornici radova znanstvenih konferencija. Nakon što su iz dobivenih rezultata izbačeni duplikati te radovi koji nisu na engleskom jeziku, dobiven je konačni uzorak od 345 radova iz sve 4 baze na kojima je provedena analiza. Iako je teško kategorizirati radove u samo jednu od kategorija, jer se s praktičnog stanovišta većina radova bavi temom s više aspekata, kreiran je teorijski okvir koji se sastojao od četiri temeljne kategorije:

(1) **općenite studije** – uvodni radovi koji obrađuju temu društvenog označivanja unutar šireg područja proučavanja društvenog softvera
(2) **istraživanje oznaka** – radovi koji proučavaju modele, strukturu, kategorizaciju te semantičke i lingvističke aspekte oznaka
(3) **istraživanje korisnika** – radovi koji proučavaju korištenje društvenog označivanja unutar različitih okruženja (obrazovanje, istraživanje) ili sustava (npr. Flickr, Delicious)
(4) **istraživanje izvora** (poboljšanje pristupa) – radovi koji proučavaju upotrebu korisničkog označivanja kao metode poboljšanja pristupa, pretrage, navigacije ili personalizacije informacijskih sustava, kao i poboljšanja opisa i komplementiranja tradicionalnim sustavima za organizaciju znanja.

Pokazalo se kako najveći broj radova pripada posljednjoj kategoriji te kako istraživači najveći potencijal korisničkih oznaka vide upravo u poboljšanju sustava za označivanje i pretraživanje. Ovakva kategorizacija omogućila je i jasnije postavljanje istraživačkog problema ove disertacije, gdje se njen fokus usmjerava na potencijal primjene korisničkog označivanja u predmetnom opisu baštinske građe, što spada u četvrtu kategoriju analize, ali dodaje i novi aspekt baštinske građe kao predmeta opisa.

Korisničko označivanje kao metoda organizacije sadržaja

Pregled istraživanja pokazao je kako je područje istraživanja korisničkog označivanja u znanstvenoj literaturi intenzivno započelo s razvojem od 2004. godine te se u 10 godina istraživanja razvilo u značajnu istraživačku temu s velikim brojem radova i različitih pristupa samoj problematici - od razvoja teorijskih modela do praktičnih programskih rješenja. Shirky

(2005) je među prvima započeo raspravu o prednostima korisničkog označivanja u odnosu na klasifikacije, taksonomije ili ontologije (tj. sustave temeljene na kontroliranom rječniku) te naveo kako bi trebalo više pozornosti posvetiti korisničkoj organizaciji sadržaja iz jednostavnog razlog što njihova *bottom-up* metoda organizacije daje smisao i kontekst nekom izvoru iz korisničke perspektive. S tog aspekta, problemi sinonimije i višeznačnosti ne predstavljaju problem jer svaka jezična ili lingvistička varijacija nekog termina daje drugu korisničku perspektivu, a time je i nositelj novog i korisnog značenja (Shirky, 2005).

Pozitivne osvrte na korisničko označivanje daju i mnogi drugi autori koji se slažu s konstatacijom da su posrijedi jeftiniji i manje zahtjevni sustavi koji ne traže posebnu edukaciju korisnika, a neki također drže da je suradničko označivanje vrijedno kod postavljanja strategija pretraživanja, budući da osigurava povećani broj pristupnica i podržava slučajno otkrivanje informacija (Mathes, 2004). Drugi autori smatraju korisničke oznake kao iznimno korisne za pregledavanje i neodređeno pretraživanje informacijskih izvora kojima korisnik ne zna ni autora ni naslov (Quintarelli, 2005). Također, korisničkim označivanjem broj pristupnica se znatno povećava (Kipp, 2007), osobito ako je riječ o slikovnim materijalima i video zapisima (Kellog Smith, 2011).

Negativni osvrti na korisničko označivanje uglavnom se temelje na samoj kritici prirode procesa označivanja u kojem svaki korisnik ima pravo na vlastiti rječnik i perspektivu, što može dovesti do netočnosti, nekonzistentnosti i kontradikcija unutar sustava (Peters, 2009).

Nedostatak kontrole i normalizacije jezika iz perspektive optimiziranja sustava za pretraživanje informacija, naravno, otvara vrata svim neželjenim jezičnim fenomenima poput sinonimije, homonimije ili neuređenim odnosima prema specifičnosti označivanja. Stoga se, kada je riječ o folksonomijama i korisničkom označivanju, kritike najučestalije odnose na navedene jezične fenomene (Golder i Huberman, 2006), tendenciju korištenja širih i nespecifičnih pojmova (Munk i Mork, 2007), subjektivnost i osobnost oznaka koje su razumljive samo osobi koja ih je dodijelila, redundantnost izraza i pojavu pravopisnih i leksičkih varijanti (Rolla, 2009) te nedostatak konvencija i pravila označivanja (Guy i Tonkin, 2006).

Folksonomije i taksonomije

Razlike između folksonomija i tradicionalnih sustava za organizaciju informacija predmet su analize mnogih autora, pri čemu kritičke aspekte folksonomija najčešće navode autori iz područja informacijskih znanosti i knjižničarstva, koji folksonomije tumače s aspekta

prednosti tradicionalnih sustava te polaze od stava da korisničke oznake mogu isključivo nadograditi, ali ne i zamijeniti visoko strukturirana pomagala za organizaciju informacija. S druge strane, pregršt literature ukazuje upravo na nedostatke i anakronizam klasifikacijskih ili abecednih predmetnih sustava u odnosu na suvremene potrebe. Razmatranje prednosti i nedostataka folksonomija važno su polazište za prosudbu njihove primjenjivosti u baštinskom okruženju.

Prema Peters (2009) folksonomije kao alternativa tradicionalnim sustavima za organizaciju i počivaju na drugačijim polazištima, unatoč istoj svrsi:

- ne razvijaju se prema definiranim pravilima i načelima, već rastu organski i napreduju s povećanim korištenjem
- za korištenje folksonomije korisnici se ne moraju upoznavati s njihovim pravilima i načelima kao kod kontroliranih rječnika
- umjesto odabira kriterija, imenovanja predmeta, klasa i njihovog popunjavanja resursima kao kod tradicionalnih metoda indeksiranja, folksonomije polaze od izvora te stoga njeguju tzv. pristup usmjeren na izvore (engl. *resource-centric approach*), umjesto usmjerenosti na kriterije (engl. *criteria-centric approach*).

Zbog tih i sličnih problema, sve se više pokušava spojiti tradicionalna pravila taksonomije s praksom dodjeljivanja korisničkih oznaka. Radi se o pristupu koji pokušava spojiti prednosti slobodnog pristupa u dodjeljivanju oznaka s organizacijskom snagom klasičnih taksonomija. Usmjerenost korisniku vodilja je djelovanja svih informacijskih ustanova, a realizaciju tog načela u području označivanja informacija ometaju nedovoljna znanja o korisnicima i njihovim potrebama, obrascima pretraživanja izvora i korištenom nazivlju. Dodatnu poteškoću predstavlja dinamična priroda predmeta, potreba i jezika korisnika koji se mijenjaju gotovo u stvarnom vremenu. Koncept korisničkog označivanja potencijalno umanjuje opisane poteškoće budući da korisničke oznake pružaju ažurni uvid u rječnik korisnika istovremeno umanjujući troškove njegovog utvrđivanja. Osim potencijalne prednosti utvrđivanja korisničkog jamstva, temeljne prednosti folksonomija proizlaze iz brojnih nedostataka tradicionalnih sustava. Shirky (2003) smatra da ekskluzivna priroda postojećih kontroliranih rječnika narušava njihovu korisnost i sugerira da one ne mogu odražavati promjenjivu prirodu znanja i potrebe suvremenog korisnika informacija. Nadalje, tvrdi da bi jezični fenomeni poput dvoznačnosti i istoznačnosti koji su inherentni korisničkom označivanju trebali biti dopušteni, budući da se radi o istinskom predstavljanju znanja koje je potpuni odraz leksičke stvarnosti bez gubitka značenjske suštine. Da su folksonomije u odnosu na tradicionalne

kontrolirane rječnike ažurnije i lako izražavaju nove koncepte, uočavaju mnogi autori (Mathes, 2004; Quintarelli, 2005). Drugi autori drže da se folksonomije razlikuju od tradicionalnih indeksnih jezika jer odgovaraju duhu modernog vremena koje karakteriziraju inovacije, novi predmeti, koncepti i područja istraživanja, ali i sveopća decentralizacija i širenje zajednica prakse (engl. *communities of practice*) (Tonkin, 2008). U kontekstu prednosti folksonomija kao modela organizacije informacija, potrebno je spomenuti i subjektivnu dimenziju oznaka kao novi dodani aspekt označivanja i pretraživanja. To se odnosi na oznake poput „glupo“, „zanimljivo“ ili „dosadno“, koje se odnose na emocije, mišljenja, stavove i prosudbu o kvaliteti informacijskog izvora kao poželjnom svojstvu kojim valja obogatiti postupke pristupa i organizacije (Rolla, 2009).

Nedostaci korisničkog označivanja

Kao i kod taksonomskog pristupa organizaciji informacija, i sustavi za korisničko označivanje imaju svoje prednosti i nedostatke koji u većini slučajeva proizlaze iz dva osnovna postupka u stvaranju folksonomije - korištenje prirodnog jezika i odsutnost stroge kontrole procesa.

Višeznačnost

Jedan od najčešćih problema korisničkog označivanja nemogućnost je razlikovanja pojmova koji imaju više značenja, kao klasičan problem koji se javlja u korištenju svakog sustava koji se oslanja na korištenje riječi prirodnog jezika bez dodanog konteksta. Na primjer, korisnička oznaka "list" može označavati ribu, dio biljke ili dio noge. Slijeđenjem poveznice na sve izvore koji su označeni oznakom list, dobit ćemo niz izvora koji se, iako se isto pišu, ovisno o kontekstu, odnose na veoma različite pojmove. Neki sustavi poput Bibsonomya pokušali su riješiti taj problem predlažući povezane pojmove koji se često pojavljuju uz odabranu oznaku u pretragama ili u drugim oznakama uz isti izvor, pa bi tako oznaku list mogli precizirati dodavanjem ili oznake "riba", "tijelo" ili "biljka", ovisno o željenom rezultatu. Još jedan problem koji se često javlja jest i slučaj da neka oznaka označava akronim koji je višeznačan. Na primjer, oznaka "hnk" može označavati pojam vezan uz kazalište (Hrvatsko narodno kazalište) ili vezan uz nogomet (hrvatski nogometni klub), što može izazvati miješanje različitih koncepata unutar sustava. Govoreći o nedostacima sustava koji se temelje na korisničkom označivanju, Golder i Huberman (2006) ističu takve probleme kao što je onaj kada se korisničke oznake ne koriste samo kao opisni pojmovi, već se na njima temelji i

sustav pretrage i pronalaženja izvora, jer u tom slučaju sustav ne može razlikovati slučajeve kad ista oznaka kao rezultat pretrage vraća različite koncepte.

Sinonimija

Drugi značajan problem koji proizlazi iz korištenja nekontroliranog prirodnog jezika, kao podloge za označivanje, jest i problem sinonimije. Dok kod višeznačnosti problem predstavlja što jedna riječ ukazuje na moguće različite koncepte, kod sinonimije problem predstavlja što jedan koncept može biti izražen različitim pojmovima koji, iako imaju različite izraze, njihov se sadržaj potpuno ili u većoj mjeri podudara. Na primjer, neki informatički pojam može biti označen terminom "računalo" ili "kompjuter" kao sinonimima za isti koncept. Takva nedosljednost u označivanju dovodi do situacije u kojoj svi relevantni izvori nisu okupljeni pod istim pojmom, što smanjuje iscrpnost dobivenih rezultata i može izostaviti relevantne rezultate iz pretrage. Problem je i u tome što je nemoguće zaključiti koliki je broj izostavljenih rezultata, jer se ne zna kojim se sve terminom mogao označiti neki relevantan pojam (npr. netko je relevantan izvor mogao označiti oznakom "PC") te je nemoguće i eventualno konstruirati upit koji bi uzeo u obzir sve moguće povezane termine kojim je jedan koncept označen unutar sustava.

Različite varijante pisanja

Treći česti problem unutar sustava temeljenih na korisničkom označivanju javlja se kada se za isti koncept koristi isti pojam, ali uz različite varijante u pisanju. Prvi problem ovdje predstavljaju situacije u kojima su dva povezana izvora (npr. dvije slike na kojima je grupa pasa) označena u jednom slučaju jedninom (pas), a u drugom slučaju množinom (psi). Ako pretraga nije uključivala obje varijante, iz rezultata će biti ispušten barem jedan relevantan izvor. Dok se to u nekoj mjeri i može riješiti svođenjem riječi na njen korijen (lematizacijom) te korištenjem zamjenskih znakova, postoji niz primjera u kojima su jednina i množina neke riječi potpuno različite riječi (npr. čovjek-ljudi).

Drugi problem s kojim se susreću sustavi koji koriste korisničke oznake pitanje je načina na koji se pojedine riječi vežu u fraze. Dok neki sustavi pojedine termine odvajaju razmakom, pa ukoliko želite upisati neku frazu, morate povezati termine nekim znakom (npr. web_20 ili web-20) ili ih pisati zajedno (web20), drugi jedinstvenom oznakom smatraju sve što se nalazi između dva zareza. Iako je sama konvencija slaganja fraza u većini slučajeva upravljana sustavom (upute kako upisivati oznake), sustavi ne mogu prisiliti korisnike na slijeđenje uputa te poštivanje različitih konvencija (možda kao navika iz nekog drugog sustava) pa se lako

može dogoditi da korisnici isti koncept označe istom frazom, ali zbog razlika u konvenciji pisanja zapravo dodaju niz različitih oznaka i time onemoguće okupljanje svih relevantnih izvora oko jedne oznake.

Različite razine specifičnosti

Dok su problemi o kojima smo raspravljali u gornjem tekstu bazirani na lingvističkim osobinama samog jezika, problem specifičnosti i nedostatka značenja odnosi se na semantičku, odnosno značenjsku razinu. Kod opisivanja nekog izvora korisnik može odabrati niz termina koji su veoma različiti po svojoj specifičnosti. Na primjer, sliku buldoga netko može označiti terminom životinja (općenita razina), pas (srednja razina) ili buldog (specifična razina), što ovisi s jedne strane, o predznanju samog korisnika, ali i s druge strane, o samom shvaćanju razine specifičnosti koja se od njega očekuje. Problem je u tome što različiti ljudi imaju različita predznanja o predmetima koje opisuju, kao i različito shvaćanje hijerarhijskih razina specifičnosti. Golder i Huberman (2006) o tome pišu: „Za većinu ljudi, općenita razina označavanja mačke bila bi riječ „mačka“ prije nego „životinja“ ili „perzijska“ ili „sijamska mačka.“ Tanaka i Taylor (1991) u svome su istraživanju pokazali kako su ispitanici u razlikovanju slika pasa i ptica češće koristili termine „pas“ i „ptica“ nego specifičnije poput „bigl“ ili „crvendać.“

Primijenimo li to na sustave koji opisuju izvore putem korisničkih oznaka, možemo vidjeti kako te dvije kognitivne osobine ljudi (predznanje i razina specifičnosti) mogu dovesti do niza problema unutar sustava. Imamo li korisnika s velikim predznanjem o recimo programiranju, on određene izvore može označiti specifičnim pojmovima koji se odnose samo na taj izvor (npr. terminom *python* ili *perl*). Međutim, za drugog korisnika, koji se tek upoznaje s područjem, to su možda previše specifični termini koje on niti ne poznaje te ih zato neće ni tražiti. Obrnuta situacija događa se kada korisnik s premalo znanja o nekom izvoru dodaje oznaku koja je na općenitoj razini (npr. programiranje) što s aspekta stručnjaka koji traži izvore predstavlja previše općenitu i time neupotrebljivu oznaku.

Nedostatak značenja i odnosa između pojmova

U baštinskom okruženju predmetni stručnjaci odgovorni su za predstavljanje nekog predmeta na ispravnoj razini kroz svoju stručnost i poznavanje konteksta. Problem koji se javlja kod korisničkih oznaka jest u tome što mnogi baštinski predmeti zahtijevaju mnogo kontekstualnog znanja pa i samo označivanje od strane korisnika može biti samo na veoma općenitoj razini i samim time neupotrebljivo za predmetni opis. Upravo zbog toga, često se u

literaturi govori o već spomenutim „amaterima stručnjacima“ (de Boer et al., 2012) koji, iako nisu dio „službenog“ osoblja, ipak su upoznati s materijom u dovoljnoj mjeri da mogu pridonijeti. U tom smislu, ocjenjivanje zahtjevnosti opisivanja nekog izvora na kognitivnoj razini važan je preduvjet za odabir najbolje metode uključivanja korisnika u opis.

Drugi problem koji se javlja jest i problem definiranja bilo kakvih odnosa između samih termina unutar sustava. Dok kontrolirani rječnici uvijek imaju dodanu vrijednost u vidu tezaurusa koji definira pojmove i njihove odnose (nadređeni, podređeni, preporučeni i povezani pojmovi), korisničke oznake tih odnosa nemaju, već se sve oznake nalaze na istoj razini. Na taj način gubi se velik dio informacija koje su vrlo korisne za krajnjeg korisnika, kao što su informacije o podređenim i nadređenim pojmovima koje rješavaju problem nedostatka značenja (korisnik koji nađe termin *programiranje* može lako razradom hijerarhije vidjeti kako su *python* i *perl* zapravo programski jezici), kao i probleme sinonimije i višeznačnosti (pomoću povezanih i preporučenih pojmova).

Kod korisničkog označivanja takvih mehanizama nema u samom pristupu, pa se takvi problemi pokušavaju premostiti povezivanjem korisničkih oznaka s vanjskim izvorima poput tezaurusa ili klasifikacija kako bi se ta vrsta značenja dodala u sam sustav, kao što je to slučaj sa servisom Bibsonomy koji tijekom pretrage nudi izbornik s povezanim i sličnim oznakama kojima se sama pretraga može dodatno precizirati, suziti ili proširiti (Hotho et al., 2006).

Prednosti korisničkog označivanja

Iako nabrojani nedostaci korisničkog označivanja predstavljaju značajne probleme u organizaciji znanja temeljenoj na korisničkim oznakama, niz radova koji se bave proučavanjem karakteristika sustava za korisničko označivanje (Quintarelli, 2005; Peters, 2009; Wu, Zhang i Yu, 2006; Golder i Huberman, 2006) dalo je niz pozitivnih osvrta na aspekte korištenja korisničkog označivanja. Yeung et al. (2007) daju pregled osnovnih prednosti:

Niski kognitivni trošak

Za razliku od klasičnog predmetnog pristupa koji zahtijeva veoma visoku posvećenost procesu te poznavanje, kako predmeta koji se označava tako i strukture rječnika kojim se označava (npr. EuroVoc), korisničko označivanje ne zahtijeva bilo kakvo prethodno znanje o samom resursu niti se oslanja na prekoordinirane sustave ili taksonomske podjele koje bi korisnik morao poznavati. Svaki korisnik jednostavno pristupa nekom izvoru označavajući ga sebi svojstvenim rječnikom, kako god mu to odgovara. U tom smislu kognitivna uključenost

korisnika je veoma mala, a samo predznanje nije potrebno te su korisnici mnogo voljniji dodavati oznake, nego npr. kad ih sustav prisiljava na upotrebu neke sheme kontroliranog rječnika.

Bolja osobna organizacija i pretraga izvora

Korištenjem slobodno izabranih vlastitih termina, korisnicima je na raspolaganju mnogo fleksibilniji set oznaka od onih koje bi mogli dodati u nekom kontroliranom sustavu. Upravo zbog toga, korisničke oznake su, kao sustav organizacije vlastitih izvora unutar nekog sustava, mnogo intuitivnije i specifičnije od npr. hijerarhijske organizacije u različitim mapama ili svrstavanja u predefinirane kategorije. Osim brže organizacije, brži je i sustav pretrage jer se jednostavnom pretragom za izabrani termin dobivaju svi izvori označeni tom oznakom, bez potrebe poznavanja hijerarhije same organizacije (u kojoj se datoteci nešto nalazi).

Neposredna komunikacija i povratna informacija

Kada korisnik doda korisničku oznaku u sustav, većina postojećih sustava pruži mu popis već postojećih oznaka kojima su drugi korisnici označivali izvor (preporučene oznake). Na taj način korisniku se pruža mogućnost ili slijediti većinu i označiti izvor najčešćim oznakama, ili dodati svoje (osobne) oznake koje neće možda imati relevantnost na razini sustava, ali će samom korisniku biti veoma korisne. Kada je sustav postavljen na taj način, on pruža korisniku trenutačnu povratnu informaciju o oznaci koju dodaje te mu omogućava i komunikaciju s drugim korisnicima unutar sustava na način da zajedničkim djelovanjem dodaju relevantne oznake nekom izvoru. Tako korisnici mogu u isto vrijeme sudjelovati u organizaciji izvora za cijelu zajednicu (dodavanjem preporučenih oznaka koje će okupiti izvor na razini sustava), kao i u osobnoj organizaciji (dodajući oznake koje imaju neko značenje samo korisniku).

Prilagođenost promjenama u rječniku

Kako je već spomenuto u raspravi o problemima tradicionalnog predmetnog pristupa putem klasifikacija ili taksonomije, čak i kada sam kontrolirani popis termina uključuje korisnički rječnik, problem zastarijevanja koncepata ili promjene značenja još je uvijek prisutan. Veliki sustavi koji se temelje na kontroliranom rječniku u samoj su svojoj prirodi spori u prihvaćanju i korištenju novih termina. Svaka promjena popisa kontroliranih termina zahtijeva detaljnu analizu i slaganje stručne zajednice koja ga održava i koristi, kao i određeno vrijeme u kojem se opravdanost novih termina mora oslikavati i u samim izvorima. Dok je uključenje termina

poput *web 2.0* ili *ajax*, koji označuju nove pojmove ili tehnologije, u kontrolirani rječnik dugotrajan proces, u sustavima koji koriste korisničko označivanje oni se pojavljuju čim se neki termin počinje koristiti u mrežnom okruženju. U slučaju pojavljivanja novih termina, nije potrebno ulaziti u mijenjanje složenih predefiniranih shema kontroliranog rječnika, već se termin počinje koristiti kao oznaka gotovo u isto vrijeme kada se pojavi kao novi termin u mrežnom okruženju. Na taj način sustavi korisničkog označivanja mogu vrlo brzo okupiti i organizirati informacije o novim fenomenima te postaju relevantan izvor mrežnih informacija o aktualnim temama.

Prilagođenost korisniku i stvaranje korisničkih zajednica

Korisničko označivanje pokazalo se kao vrlo jednostavan i učinkovit način organizacije osobnih mrežnih izvora. Korisnici koji imaju potrebu za pronalaženjem uvijek svježih informacija iz svojeg područja mogu na jednostavan način, putem korisničkih oznaka, označiti, pohraniti i pronaći željene izvore. Sama ideja kako za cijeli proces mogu koristiti vlastiti rječnik, olakšava cijeli proces i potiče korisnike na korištenje takvih sustava. Kada se tome doda i niz drugih korisnika koji koriste neki sustav s istim ciljem, brzo se oko dijeljenja i organizacije samih izvora stvara snažna i povezana zajednica. Flickr je na taj način okupio entuzijaste i profesionalce koji se bave fotografijom i omogućio ne samo pohranu i pretraživanje vlastitih fotografija, već i dijeljenje svojih fotografija s drugim korisnicima. Tako se vrlo brzo stvaraju mrežne zajednice korisnika koji su zainteresirani za iste teme te je omogućeno ne samo pronalaženje novih izvora koji nas zanimaju, već i drugih korisnika koji dijele zajednički interes.

Istraživanje korisničkog označivanja u opisu baštinske građe

Pregled literature i kategorizacija prijašnjih istraživanja omogućila je i jasnije postavljanje istraživačkog problema ove disertacije, gdje se njen fokus usmjerava na potencijal primjene korisničkog označivanja u predmetnom opisu baštinske građe, što spada u četvrtu kategoriju analize (**Istraživanje izvora** (poboljšanje pristupa) - *radovi koji proučavaju upotrebu korisničkog označivanja kao metode poboljšanja pristupa, pretrage, navigacije ili personalizacije informacijskih sustava, kao i poboljšanja opisa i komplementiranja tradicionalnim sustavima za organizaciju znanja*), ali dodaje i novi aspekt baštinske građe kao predmeta opisa.

Cilj istraživanja bio je ispitati načine implementacije korisničkih oznaka u standardni predmetni opis baštinske građe kao protutežu i dopunu tradicionalnim modelima organizacije informacija.

Plan istraživanja sastojao se od tri komplementarne faze:

1. **prikupljanje korpusa oznaka metodom nabave iz mnoštva**
2. **statistička, lingvistička i funkcionalna analiza korpusa korisničkih oznaka**
3. **ispitivanje razlika u pristupu korisničkom označivanju tradicionalnih vrsta građe u AKM ustanovama**
   a) **usporedba predmetnica dodanih od strane predmetnih stručnjaka i prikupljenih korisničkih oznaka**
   b) **ocjena korisnosti prikupljenih korisničkih oznaka od strane predmetnog stručnjaka.**

Kroz tri navedene faze istraživanja pristupilo se testiranju sljedećih hipoteza:

H1: Korisničke oznake donose naznake novih elemenata opisa koji nisu prisutni u tradicionalnom predmetnom pristupu

H2: Potencijal korisničkih oznaka kao predmetnih pristupnica pokazuje posebnosti s obzirom na vrstu građe koja se prikuplja u baštinskim ustanovama

H2a: Postoji značajna razlika u kvantitativnim pokazateljima prikupljenog korpusa korisničkih oznaka na razini različitih vrsta građe

H2b: Postoji značajna razlika u mjeri preklapanja između predmetnica dodanih od strane stručnjaka i prikupljenih korisničkih oznaka na razini različitih vrsta građe

H2c: Postoji značajna razlika u ocjeni prikladnosti korisničkih oznaka za predmetni opis od strane predmetnog stručnjaka

Demografska slika sudionika istraživanja

Demografska slika sudionika istraživanja pokazala je nekoliko jasnih demografskih obilježja. Kao prvi značajan aspekt pokazao se podatak kako je više od 50% dodanih oznaka zapravo dodano od igrača čiju demografsku sliku ne poznajemo, jer su dodali oznake bez procesa registracije pa nije bilo moguće ocijeniti tko stoji iza dodavanja više od polovice prikupljenih oznaka. Iako je tijekom diseminacije obavijesti bilo naglašeno kako je preporučeni način igranja ipak registracija, kako bi se mogli dobiti osnovni demografski podaci tijekom procesa registracije, čak i u tom slučaju pokazalo se kako je veći broj sudionika odlučio preskočiti proces registracije. Dopuštanje opcije dodavanja oznaka bez registracije bilo je omogućeno baš zbog takvih obrazaca korisničkog ponašanja, gdje se nauštrb nepotpune demografske slike sudionika dobilo preko 50% više korisničkih oznaka, što je značajno povećalo broj korisničkih oznaka na razini predmeta, kako bi se osigurao dovoljno veliki korpus oznaka na kojima se provela analiza.

Iako je demografska slika nepotpuna, može se pretpostaviti da i nepoznati dio sudionika također pokazuje obilježja registriranih korisnika pošto je demografska analiza provedena na značajnom uzorku od 147 registriranih korisnika.

Pokazalo se kako je broj dodanih oznaka od strane registriranih korisnika veoma nejednako distribuiran te pokazuje obilježja *power law* krivulje koja identificira *power users*, korisnike koji su dodali veliki broj oznaka. Taj se zaključak potvrdio velikom standardnom devijacijom u broju dodanih oznaka (47) te podatkom kako je 20 sudionika koji su dodali najveći broj oznaka (14% od ukupno 147 sudionika) odgovorno za čak 2929 oznaka (44% u ukupnom uzorku od 6612 oznaka).

Sumiramo li demografske podatke o sudionicima, možemo reći kako je tipični sudionik istraživanja:

- ženskog spola (77%)
- između 18 i 30 godina (62%)
- pohađa najmanje fakultet ili ga je završio (69%)
- društveno-humanističkog usmjerenja (90%).

Demografska analiza uzorka pokazuje kako je tipični sudionik istraživanja student društveno-humanističkog usmjerenja, što je očekivana demografska skupina obzirom na diseminaciju obavijesti o istraživanju putem studentske mailing liste čije obavijesti primaju svi studenti Filozofskog fakulteta kojih ima između 7 i 8 tisuća i iz čije je populacije sudjelovao najveći broj ispitanika.

Statistička analiza prikupljenog korpusa

Na temelju dobivenih podataka možemo zaključiti kako se na prikupljenom uzorku od 14402 dodijeljene oznake na 80 predmeta pokazalo kako veći broj dodjeljivanja nakon određene granice ne uvjetuje i proporcionalno povećavanje korisničkog rječnika.

Analiza je pokazala kako se korisnički rječnik u opisu jedne vrste građe definirao u okviru prosjeka od 1800 riječi (25% ukupnog broja dodjeljivanja), bez obzira što je broj dodjeljivanja jednoj vrsti građe bio značajno veći (fotografijama u ovom slučaju). Na temelju analize podataka možemo zaključiti kako nakon prikupljenih 1800 dodanih oznaka na razini zbirke, nije bilo daljnjeg značajnog povećanja korisničkog rječnika, već se samo povećavala frekvencija već postojećih oznaka. Zaključujući u tom pogledu, možemo reći kako prikupljanje minimalno 1800 dodanih oznaka na razini zbirke od 20 predmeta predstavlja optimalnu granicu na kojoj će se pokriti cijela baza korisničkog rječnika.

Nakon statističke analize prikupljenog korpusa oznaka na hrvatskom jeziku možemo izdvojiti sljedeće zaključke:

- ne postoji značajna razlika u broju dodjeljivanja na razini zbirke
- ne postoji značajna razlika u broju dodanih oznaka na razini zbirke
- broj dodjeljivanja je snažno pozitivno povezan s brojem dodanih oznaka
- broj dodanih oznaka je snažno pozitivno povezan s brojem jedinstvenih oznaka
- broj dodjeljivanja pokazuje slabu povezanost s brojem jedinstvenih oznaka
- prikupljanje minimalno 1800 dodanih oznaka na razini zbirke od 20 predmeta predstavlja optimalnu granicu na kojoj će se pokriti cijela baza korisničkog rječnika.

Statistička analiza prikupljenog korpusa korisničkih oznaka poduzeta je kako bi se uvidjele eventualne razlike na kvantitativnoj razini između različitih vrsta građe. U tom pogledu postavljena je hipoteza H2a.

H2a Postoji značajna razlika u kvantitativnim pokazateljima prikupljenog korpusa korisničkih oznaka na razini različitih vrsta građe

Nakon provedene statističke analize možemo zaključiti kako se na statističkoj razini nije pokazala značajna razlika u kvantitativnim pokazateljima prikupljenog korpusa korisničkih oznaka te **hipoteza nije dokazana**.

Lingvistička analiza prikupljenog korpusa

Nakon provedene analize prikupljenog korpusa korisničkih oznaka na lingvističkoj razini, možemo sumirati podatke dobivene analizom.

Na razini broja riječi od kojih se sastoji pojedina oznaka, pokazalo se kako se najveći broj oznaka sastojao od samo jedne riječi, a 91% korpusa bilo je složeno od jedne riječi ili fraze (2 riječi). Analiza na razini vrste građe nije pokazivala veća odstupanja od ukupnih udjela, gdje se pokazala slična raspodjela od 70%-20%-10% (jedna riječ – dvije riječi- tri i više riječi).

Što se tiče vrste riječi, pokazalo se kako je tipična oznaka imenica (82%), i to opća (91%) u jednini (78%) i nominativu (99%).

Slijedom navedenih podataka možemo testirati hipotezu H1 kojom se kroz lingvističku analizu prikupljenog korpusa korisničkih oznaka na hrvatskom jeziku identificira postojanje elemenata opisa koje dodaju korisničke oznake, a koje nisu prisutne u tradicionalnom predmetnom pristupu.

H1: Korisničke oznake donose naznake novih elemenata opisa koji nisu prisutni u tradicionalnom predmetnom pristupu

Na temelju dobivenih podataka nema naznaka novih elemenata opisa te **hipoteza nije dokazana.**

Značenjska analiza prikupljenog korpusa

Daljnja analiza *ofness* razine pokazala je kako je najveći broj oznaka dodan na generičkoj razini (83%) koja ne zahtijeva predznanje o samoj građi, već se oslanja samo na element prepoznavanja općenitih pojmova.

Nakon analize razina značenja na kojoj se nalaze dodane korisničke oznake, možemo zaključiti kako je najveći broj oznaka dodan na generičkoj *ofness* razini, tj. korisnici najviše dodaju oznake na toj razini (oko 80%).

Takav rezultat je i predviđen jer je teško očekivati od korisnika veliko predznanje o samim predmetima te se očekuje da će njihove oznake opisivati generičke pojmove prisutne na vizualnom resursu. Na ukupnom korpusu dodan je i značajan broj oznaka koje imaju subjektivnu komponentu, na razini *aboutness* (15% ili 490 oznaka), što pokazuje kako je tema cijele zbirke (Domovinski rat) pobudila dosta osjećaja i zbog toga dodanih subjektivnih korisničkih oznaka.

Usporedba predmetnica i korisničkih oznaka

Najveći koeficijent sličnosti pokazao se na knjižničnoj građi (4.73) dok je najmanja sličnost između termina kojima su opisivane fotografije (3.35). Analiziramo li podatak o udjelu zajedničkih termina u samim predmetnicama, tj. koliki je postotak rječnika predmetnog stručnjaka pokriven dodanim korisničkim oznakama, možemo vidjeti kako se postotak pokrivenosti kreće oko 50%, s najvećom pokrivenošću predmetnica kod fotografske građe (53%), a najmanjom kod arhivske građe (42%).

Analiza na razini predmeta pokazala je kako su odstupanja od prosjeka zbirke znatna. Prosječna standardna devijacija u udjelu pokrivenosti predmetnica u korisničkim oznakama iznosila je 20%, što ukazuje na znatne razlike u broju zajedničkih termina na razini predmeta. Pokrivenost predmetnica u korisničkim oznakama varirala je od potpune pokrivenosti (100%) pa do nijednog zajedničkog elementa (0%), što pokazuje kako su neki predmeti stvorili veći semantički jaz između korisničkog rječnika i rječnika predmetnog stručnjaka.

Što se tiče pouzdanosti koeficijenta sličnosti kao mjere usporedbe, pokazalo se kako je prosječna korelacija na razini predmeta bila umjerena do snažna (r=+0.67), što indicira da je koeficijent sličnosti dobra mjera usporedbe te kako će veći koeficijent sličnosti ujedno i značiti veći broj zajedničkih elemenata i preklapanja. Analizirajući povezanost na razini zbirke, pokazalo se kako je koeficijent sličnosti pokazao veću pouzdanost na tekstualnoj građi (arhivska i muzejska građa), gdje je korelacija bila snažna (+0.75 i +0.76), dok je manju

pouzdanost pokazao na primarno vizualnim resursima (fotografije i muzejska građa), gdje je koeficijent korelacije pokazao umjerenu povezanost (+0.65 i +0.54).

Usporedba predmetnica dodanih od strane predmetnih stručnjaka i prikupljenih korisničkih oznaka na razini predmeta poduzeta je kako bi se uvidjele eventualne razlike u pristupu korisničkom označivanju tradicionalnih vrsta građe u AKM ustanovama. U tom smislu postavljena je hipoteza H2b:

H2b: Postoji značajna razlika u mjeri preklapanja između predmetnica dodanih od strane stručnjaka i prikupljenih korisničkih oznaka na razini različitih vrsta građe

Nakon provedene analize možemo zaključiti kako se na razini različitih vrsta građe nije pokazala značajna razlika u pokazateljima usporedbe predmetnica i korisničkih oznaka te **hipoteza nije dokazana.**

Ocjena korisnosti prikupljenih oznaka od strane predmetnih stručnjaka

Provedenim istraživanjem svaki od 80 predmeta opisan je s dva seta termina:

(1) predmetnice dodijeljene od strane predmetnog stručnjaka

(2) prikupljene korisničke oznake putem aplikacije.

Ideja je ovog dijela istraživanja bila dati prikupljene korisničke oznake natrag samom predmetnom stručnjaku kako bi ocijenio koliko su oznake, dodane od strane korisnika, korisne iz stručne perspektive, tj. koliko su prikladne za uključivanje u predmetni opis.

U istraživanju, predmetima je dodano 6588 korisničkih oznaka, što je predstavljalo preveliki set termina za ocjenu, jer bi sam postupak zahtijevao previše utrošenog vremena. Upravo zbog toga bilo je potrebno kreirati model kojim bi se set svih korisničkih oznaka sveo na set korisničkih oznaka za koji je moguće očekivati da ga predmetni stručnjak može pregledati i ocijeniti, tj. kreirati model koji će omogućiti relevantnim korisničkim oznakama za svaki predmet da se nalaze u setu oznaka koje stručnjak ocjenjuje.

Predloženi model uključuje dva nova metodološka postupka:

(1) određivanje mjere relevantnosti korisničke oznake za pojedini predmet

(2) određivanje praga relevantnosti korisničke oznake za pojedini predmet

Nakon implementacije modela i analize podatka, pokazalo se kako je predloženi model pristupa analizi i implementaciji prikladniji za muzejsku, arhivsku i fotografsku građu, dok kod knjižnične građe pokazuje slabiju učinkovitost.
Na temelju dobivenih podataka, možemo pristupiti ocjeni hipoteze H2c:

H2c: Postoji značajna razlika u ocjeni prikladnosti korisničkih oznaka za predmetni opis od strane predmetnog stručnjaka

Kako je analizom prikupljenih podataka uočena značajna razlika u ocjeni prikladnosti oznaka za predmetni opis knjižnične građe, gdje se pokazalo kako je model primjeren za analizu i implementaciju arhivske, muzejske i fotografske građe, dok kod knjižnične građe pokazuje značajno slabiju učinkovitost, možemo zaključiti kako je **hipoteza dokazana.**

Zaključno o korisničkom označivanju kao metodi organizacije sadržaja

Pokušamo li dati konačnu ocjenu o tome ima li korisničko označivanje više pozitivnih ili negativnih aspekata, moramo uzeti u obzir i samo okruženje i aplikacije unutar kojih promatramo sam pristup. Kada govorimo o mrežnom okruženju i organizaciji nepreglednog broja različitih izvora, iluzorno je očekivati kako bi bilo koja vrsta zajedničkog (kontroliranog) rječnika mogla biti osnova svim korisnicima u opisivanju i organiziranju vlastitih izvora. Kao što primjeri pokušaja taksonomske organizacije mrežnih izvora (kao što su Intute ili BUBL) pokazuju, bilo kakav hijerarhijski pristup organizaciji neodrživ je na duži rok. Jednostavna činjenica kako kontrolirani rječnici nisu praktični niti ekonomično isplativi kada govorimo o organizaciji znanja u mrežnom okruženju, ne ostavlja drugi izbor od traženja moguće alternative (Quintarelli, 2005).
Upravo iz tog razloga, korisničko označivanje predstavlja prikladan i moguć pristup u kojem korisnici mogu organizirati mrežne izvore za vlastitu upotrebu kao i dijeljenje s drugim korisnicima. Hotho et al. (2006) pišu kako za razliku od ontologija korisničko označivanje nema problem „uskog grla“ (engl. *bottleneck*), koncepta preuzetog iz upravljanja znanjem koji se odnosi na probleme dijeljenja znanja između većeg broja ljudi. Wagner (2006) navodi osnovne osobine „uskog grla“, koje možemo povezati s primjenom klasičnih metoda indeksiranja u mrežnom okruženju:
1) **Uska propusnost** (engl. *narrow bandwith*). Broj kanala koji omogućuju pretvaranje znanja od izvora do razine organizacije često je malen. U smislu indeksiranja odnosi se na malen broj raspoloživih stručnjaka koji zahtijevaju skupo obrazovanje i vrijeme kako bi obavili zadatak.

U slučaju korisničkih oznaka taj problem ne postoji, svaki korisnik predstavlja jedan kanal te se problem rješava na brz i jeftin način.

2) **Objavljivanje s odmakom** (engl. *acquisition latency*). Spor proces stvaranja znanja često je povezan s odmakom između vremena kada je to znanje stvoreno, do trenutka kada se može podijeliti s drugima. U smislu indeksiranja odnosi se na dug proces koji je potreban kako bi se izvori kvalitetno opisali, što dovodi do skupljanja velikog broja izvora koje stručnjak ne stigne opisati. Klasičan je primjer digitalizacija, kod koje se u kratko vrijeme može stvoriti velik broj novih predmeta, ali samo opisivanje tih predmeta odgađa mogućnost da se oni predstave javnosti. Korisničko označivanje opet rješava problem time što se predmeti bez opisa mogu odmah nakon stvaranja predstaviti korisnicima koji dodavanjem oznaka mogu stvoriti opise i omogućiti organizaciju i pohranu.

3) **Netočnost znanja** (engl. *knowledge inacuraccy*). Stručnjaci nisu imuni na pogreške te je moguće da u sustavu postoji nekonzistentnost i netočnost koju je unio sam stručnjak. Kod procesa predmetne obrade identificirani su značajni problemi nekonzistentnosti između različitih stručnjaka kada pristupaju istom izvoru. Korisničko označivanje takve pogreške, sustavom bilježenja frekvencija pojedinih oznaka, izmješta na margine samog opisa te time smanjuje utjecaj pogrešaka koje se unose u sustav.

4) Zamka održavanja (engl. *maitenance trap*). Rastom količine znanja povećava se i razina potrebnog održavanja unutar sustava. Stvaranje, održavanje i primjena kontroliranih rječnika u predmetnom opisu zahtijeva financijske i stručne resurse koji rastu veličinom zbirke koja se opisuje. Cijena plaćanja osoblja i velik broj novih izvora, koji nastaju u mrežnom okruženju na dnevnoj razini, zapreke su koje je teško premostiti u sustavima koji pokušavaju principe klasične organizacije informacija prenijeti u mrežno okruženje. Korisničke oznake taj problem rješavaju uključivanjem velikog broja korisnika koji u sustavu vide i vlastitu korist te su potaknuti na sudjelovanje, a korištenjem vlastitog rječnika odražavaju korisničko jamstvo u korištenim terminima.

Sve navedene prednosti korisničke oznake pokazuju u mrežnom okruženju koje, kao i korisničke oznake, predstavlja nekontrolirano okruženje unutar kojeg je teško očekivati veći konsenzus oko načina organizacije, rječnika koji će se koristiti ili samo svrhe organizacije izvora. S druge strane, kada govorimo o sustavima unutar kojih je potrebna veća razina kontrole i konsenzusa, u kojima je broj izvora ograničen i unutar kojih se do konsenzusa o načinu organizacije i terminologiji može lakše doći, pristupi koje nude ontologije i taksonomije imaju više prednosti od onih koje donose korisničke oznake. Upravo zbog toga, većina autora zagovara komplementarne pristupe koji ne promatraju tradicionalne sustave

temeljene na kontroliranom rječniku i korisničko označivanje kao dva odvojena svijeta, već kao sustave koji mogu i trebali bi biti međusobno komplementarni.

Metodu predloženog pristupa možemo sumirati modelom analize i primjene korisničkog označivanja u predmetnom opisu baštinske građe (Slika 92). Pregledom nekih od najuspješnijih primjera implementacije korisničkog označivanja u opis predmeta u baštinskom okruženju, pokazalo se kako postoji niz mogućih pristupa. Komunikacija samih zbirki putem uključivanja javnosti pokazala se kao vrlo zahvalan i koristan pristup, koji daje više koristi od samih korisničkih oznaka koje korisnici dodaju. Sam proces uključivanja korisnika u opis zbirke, bilo putem korištenja vanjskih servisa ili razvijanja vlastitih rješenja, pokazao se mnogo plodonosnijim od izlaganja zbirke u virtualnom okruženju. Dok su procesi samog prijenosa zbirke u virtualni oblik (digitalizacija) već dobro poznati te su postali uobičajeni način komplementiranja fizičke zbirke u virtualnom prostoru (mrežna stranica obavezan je dio predstavljanja svake baštinske ustanove), postavlja se pitanje da li korisnici uopće pristupaju digitalnim sadržajima ako su samo pasivno izloženi na mrežnoj stranici ustanove. U ovom slučaju implementacija nekih od principa nabave iz mnoštva, bio to otvoreni poziv korisnicima na ispravljanje rezultata digitalizacije, dodavanje kontekstualnog znanja objektima ili dopunjavanje opisa predmeta dodavanjem korisničkih oznaka, pokazao se kao vrlo dobar način uključivanja korisnika u dijalog s izloženim predmetima. Dok su u komercijalnim servisima, poput Last.fm ili Flickr, korisnici motivirani vlastitom korišću od servisa s jedne i učinkovite organizacije sadržaja na njima s druge strane, u baštinskom okruženju situacija je ipak ponešto drugačija. Svi nabrojani projekti pokazuju kako je motivacija korisnika za sudjelovanjem u takvim projektima često intrinzična te oni zaista žele doprinijeti boljem opisu, boljoj pohrani i boljem pronalaženju digitaliziranih objekata baštine. Sljedeći korak koji treba poduzeti jest ispitati na koji način takav korisnički sadržaj najbolje uključiti u već postojeću dokumentaciju te koje modele primijeniti u prikupljanju, obradi i implementaciji korisničkih oznaka u opis predmeta baštine.

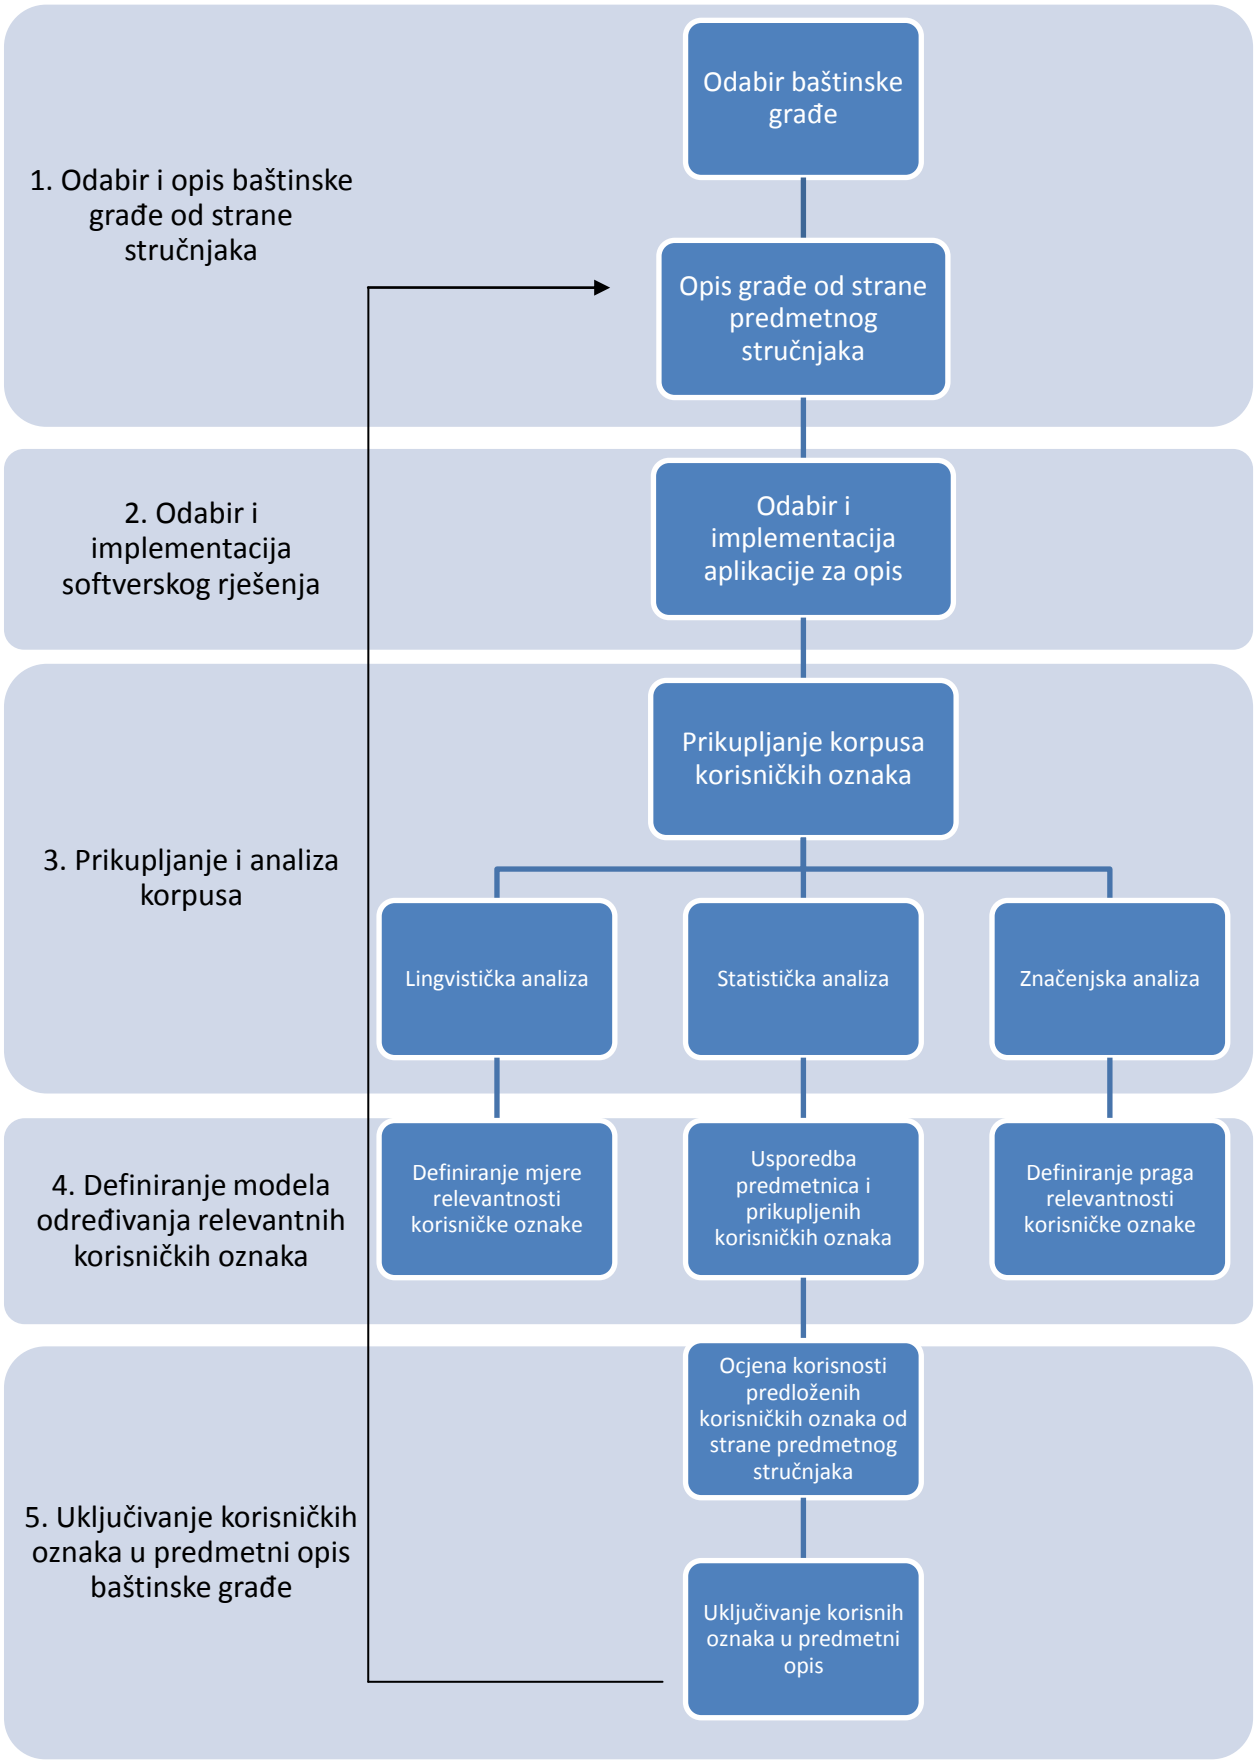

Slika 92 - Model analize i primjene korisničkog označivanja u predmetnom opisu baštinske građe

Ovaj je rad pokazao da optimalan i suvremen pristup označivanju te predstavljanju znanja traži nadopunjavanje tradicionalnih sustava značajkama koje nude folksonomije i obrnuto.
U svojim glavnim dijelovima, rad je pružio doprinose sljedećim poljima istraživanja korisničkog označivanja:

1. scijentometrijski pristup pregledu literature koji kombinira webometrijske i bibliometrijske metode i alate (BibExcel, Pajek, Webometric Analyst 2.0, Publish or Perish 4)
2. implementacija igre sa svrhom kao metode nabave iz mnoštva na baštinskoj građi
3. kreiranje metodologije i testiranje statističke, lingvističke i značenjske analize prilagođene hrvatskom jeziku na korpusu od 14402 korisničke oznake (6588 dodanih)
4. model implementacije korisničkih oznaka od prikupljanja oznaka do implementacije u predmetni opis
5. definiranje i testiranje mjere i praga relevantnosti korisničke oznake za pojedini predmet
6. kreiranje metodologije i testiranje ocjene korisnosti predloženog modela
7. kreiranje algoritamskih rješenja obrade podataka u programskom jeziku Python.

Sumirajući prednosti i nedostatke korisničkog označivanja, Mathes (2004) zaključuje: „Njegova nekontrolirana priroda je u osnovi kaotična i pati od problema nepreciznosti i dvosmislenosti koja se učinkovito rješava uvođenjem normativnih postupaka u razvijenim kontroliranim rječnicima. Suprotno tome, sustavi koji se temelje na korisničkom označivanju i koji potiču korisnike na organizaciju informacija na njihove vlastite načine, nadmoćni su u reagiranju na potrebe korisnika i njihov rječnik te aktivno uključuju korisnike u sam sustav organizacije.“ Komplementarne i hibridne pristupe zagovaraju stoga mnogi autori (Mendes, Quiñonez-Skinner i Skaggs, 2009; Rethlefsen, 2007; Sinclair i Cardew-Hall, 2008; Thomas, Caudle i Schmitz, 2009; Guy i Tonkin, 2009) koji smatraju da će udruživanje folksonomija i kontroliranih rječnika rezultirati bogatijim, točnijim i ažurnijim opisom izvora te poboljšati predmetni pristup informacijama u mrežnom okruženju. Upravo zbog tih nastojanja potrebno je istražiti moguće pristupe uključivanja korisničkih oznaka u predmetne sustave muzeja, arhiva i knjižnica, čemu je i ovaj rad dao svoj doprinos.

Popis literature

1. Abel, F. et al. (2007). *GroupMe!-where semantic web meets web 2.0*. Berlin: Springer.
2. Ackoff, R. L. (1989). From data to wisdom. *Journal of Applied Systems Analysis*, 15, 3-9.
3. Al-Khalifa, H. i Davis, H. (2006). Folksonomies versus automatic keyword extraction: an empirical study. *IADIS International Journal on Computer Science and Information Systems*, 1(2), 132-143.
4. Al-Khalifa, H. i Davis, H. (2007). Towards better understanding of folksonomic patterns. *Proceedings of the eighteenth conference on Hypertext and hypermedia (HT '07)*, ACM, New York, SAD, 163-166.
5. Almind, T. C. i Ingwersen, P. (1997). Informetric analyses of the World Wide Web: methodological approaches to „webometrics." *Journal of Documentation*, 53(4), 404-426.
6. Babu, B. R. i O'Brien, A (2000). Web OPAC interfaces: an overview. *The electronic library*, 18(5), 316-327.
7. Baca, M. ur. (2002). *Introduction to art image access: Issues, tools, standards, strategies*. Los Angeles, CA: Getty Research Institute.
8. Bar–Ilan, J. et al.(2010). The effects of background information and social interaction on image tagging. *Journal of the American Society for Information Science and Technology*, 61(5), 940–951.
9. Batagelj, V. i Mrvar, A. (2003). Pajek - Analysis and Visualization of Large Networks. *Graph Drawing Software* / Jünger, M. i Mutzel, P., (ur.). Berlin: Springer, 77-103.
10. Bates, M. (1998). Indexing and access for digital libraries and the Internet. *Journal of the American Society for Information Science*, 49, 1185-1205.
11. Bawden, D. i Robinson, L. (2002). Internet subject gateways revisited. *International Journal of Information Management*, 22(2), 157-162.
12. Bearman, D. i Trant, J. (2005). Social terminology enhancement through vernacular engagement: exploring collaborative annotation to encourage interaction with museum collections. *D-Lib Magazine*, 11(9).
13. Beel, J. i Gipp, B, (2009). Google Scholar's Ranking Algorithm: the impact of articles' age: an empirical study. *Proceeedings of the 6th International Conference on Information Technology: New Generations*, 160-164.
14. Bjorneborn, L. i Ingwersen, P. (2004). Toward a basic framework for webometrics. *Journal of the American Society for Information Science and Technology*, 55(14), 1216-1227.

15. Bonney, R. et al., (2009). Public participation in scientific research: defining the field and assessing its potential for informal science education. *A CAISE Inquiry Group report*. Dostupno na: http://informalscience.org/images/research/PublicParticipationinScientificResearch.pdf (22.11.2014.).
16. Borgman, C. L. i Furner, J. (2002). Scholarly communication and bibliometrics. *Annual Review of Information Science and Technology* / (ur.) B. Cronin. Medford, NJ : Information Today, 3-72.
17. Cairns, S. (2013). Mutualizing museum knowledge: Folksonomies and the changing shape of expertise. *Curator: The Museum Journal*, 56(1), 107-119.
18. Caras, G.J. (1968). Indexing from abstracts of documents. *Journal of Chemical Documentation*, 8(1), 20-22.
19. Cattuto et al. (2007). Network properties of folksonomies. *Ai Communications*, 20(4) 245-262.
20. Chalon, P. X., Di Pretoro, E. i Kohn, L. (2008).OPAC 2.0: Opportunities, development and analysis. *11th European Conference of Medical and Health Libraries, Helsinki, Finska.* Dostupno na: http://eprints.rclis.org/12136/ (22.11.2014.)
21. Chan, L.M. (1989). Inter-indexer consistency in subject cataloging. *Information Technology and Libraries*, 8(4), 349-358.
22. Choi, Y. (2011). *Usefulness of social tagging in organizing and providing access to the web: An analysis of indexing consistency and quality*, doktorska disertacija, University of Illinois. Dostupno na: http://hdl.handle.net/2142/26256 (22.11.2014.) .
23. Chu, H. (2010). *Information representation and retrieval in the digital age*. Medford, NJ: Information Today.
24. Cooper, W. S. (1969). Is interindexer consistency a hobgoblin? *American Documentation*, 20(3), 268-278.
25. Cripe, B. (2007). Folksonomy, keywords, and tags: Social and democratic user interaction in enterprise content management. *An Oracle Business and Technology White Paper*. Dostupno na: http://www. oracle.com/technology/products/content-management/pdf/OracleSocialTaggingWhitePaper.pdf (22.11.2014.).
26. *Crowdsourcing industry landscape*. (2011). Dostupno na: http://www.crowdsourcing.org/document/december-2011-crowdsourcing-industry-landscape-download-version/9664 (22.11.2014.).

27. David, C. et al.(1995). Indexing as problem solving: a cognitive approach to consistency. *Proceedings of the annual meeting-american society for information science*, 32, 49-55.
28. de Boer, V. et al. (2012). Nichesourcing: harnessing the power of crowds of experts. *Proceedings of the 18th International Conference, (EKAW 2012)*. Berlin, Heidelberg: Springer, 16-20.
29. Domovinski rat: katalog izložbe. (2013). Zagreb : Hrvatski povijesni muzej
30. ESA (2014). *Essential facts about the computer and video game industry*. Dostupno na: http://www.theesa.com/facts/pdfs/ESA_EF_2014.pdf (22.11.2014.).
31. Flanagan, M. i Carini, P. (2012). How games can help us access and understand archival images. *American Archivist*, 75(2), 514-537.
32. Foskett, A.C. (1996). *The subject approach to information*. 5. izd. London: Library Association.
33. Golder, S. A. i Huberman, B. A. (2006). Usage patterns of collaborative tagging systems. *Journal of information science*, 32(2) 198-208.
34. Golub, K. et al. (2009). EnTag: enhancing social tagging for discovery. *Proceedings of the 9th ACM/IEEE-CS joint conference on Digital libraries*,163-172.
35. Golub, K. (2003). *Predmetno pretraživanje u knjižničnim katalozima s web-sučeljem : magistarski rad*. Zagreb: Filozofski fakultet.
36. Gruber, T. (2007). Ontology of folksonomy: A mash-up of apples and oranges. International Journal on Semantic Web and Information Systems, 3(2), 1-11.
37. Guy, M. i Tonkin, E. (2006). Tidying up tags? *D-Lib Magazine* 12(1). Dostupno na: http://www.dlib.org/dlib/Jan.06/guy/01guy.html (22.11.2014.).
38. Halpin, H., Robu, V. i Shepherd, H. (2007). The complex dynamics of collaborative tagging. *Proceedings of the 16th International Conference on World Wide Web, (WWW '07),* 211–220.
39. Harzing, A.W. (2008). *Google Scholar: a new data source for citation analysis*. Dostupno na: http://www.harzing.com/pop_gs.htm (22.11.2014.).
40. Harzing, A.W. (2007). *Publish or Perish 4*. Dostupno na: http://www.harzing.com/pop.htm (22.11.2014.).
41. Heckner, M.; Mühlbacher, S. i Wolff, C. (2008). Tagging tagging: analysing user keywords in scientific bibliography management systems. *Journal of Digital Information*, 9(2).
42. Heymann, P., Koutrika, G. i Garcia-Molina, H. (2007). Fighting spam on social web sites: A survey of approaches and future challenges. *Internet Computing, IEEE*, 11(6), 36-45.

43. Hill, J. S. i Schottlaender, B. E. (2008). *On the record: Report of the Library of Congress Working Group on the Future of Bibliographic Control*. Dostupno na: http://www.loc.gov/bibliographic-future/news/lcwg-ontherecord-jan08-final.pdf (22.11.2014).
44. Hooper, R.S. (1965). *Indexer consistency tests: Origin, measurements, results and utilization*. IBM, Bethesda.
45. Hotho, A. et al. (2006). Information retrieval in folksonomies: search and ranking. *Proceedings of the 3rd European conference on The Semantic Web: research and applications (ESWC'06).* Berlin, Heidelberg: Springer, 411-426
46. Howe, J. (2008).*Crowdsourcing: why the power of the crowd is driving the future of business*. New York: Crown.
47. Howe, J. (2010).*Crowdsourcing: a definition*. Dostupno na: http://crowdsourcing.typepad.com (22.11.2014.).
48. Ibrahim, H.G., Hamid, R.P. i Herman, R.L. (2008). Machine cell formation based on a new similarity coefficient. *Journal of Industrial and Systems Engineering*, 1(4), 318-44.
49. ICOM (2007). *Museum definition*. Dostupno na: http://icom.museum/the-vision/museum-definition/ (22.11.2014.).
50. IFLA (1963). Statement of principles adopted by the International Conference on Cataloguing Principles. *International Conference on Cataloguing Principles, Pariz, 9.-18. listopad 1961*.
51. IFLA (1998). *Functional requirements for bibliographic records: final report*. IFLA Study Group on the Functional Requirements for Bibliographic Records. München: K.G. Saur. Dostupno na: http://www.ifla.org/publications/functional-requirements-for-bibliographic-records (22.11.2014.).
52. Kellogg Smith, M. (2011). Viewer tagging in art museums: comparisons to concepts and vocabularies of art museum visitors. *Proceedings of the 17th Annual ASISiT SIG/CR Classification Research Workshop*. Dostupno na: http://arizona.openrepository.com/arizona/bitstream/10150/105154/1/smith.pdf (22.11.2014.).
53. Kipp, M. E. (2005).Complementary or discrete contexts in online indexing: A comparison of user, creator, and intermediary keywords. *Canadian Journal of Information and Library Science*, 29(4),419–436.

54. Kipp, M. E. (2006). @toread and cool : tagging for time, task and emotion. Dostupno na: http://eprints.rclis.org/bitstream/10760/13909/1/mkipp-sigcrposter-ASIST2006.pdf (22.11.2014.)
55. Kipp, M. E. (2007).*Tagging for health information organisation and retrieval*. Dostupno na: http://eprints.rclis.org/bitstream/10760/14065/1/mkipp-naskopaper2007.pdf (22.11.2014.).
56. Kipp, M. E. (2011). User, author and professional Indexing in context: An exploration of agging practices on CiteULike. *Canadian Journal of Information and Library Science*, 35(1), 17-48.
57. Kipp, M. E. i Campbell, D.G. (2010). Searching with Tags: Do Tags Help Users Find Things? *Knowledge Organization*, 37(4), 239-255.
58. Klavans, J. et al. (2011). Taming social tags: Computational linguistic analysis of tags for images in museums. *University of Maryland Institute for Advanced Computer Studies Report No. UMIACS-TR-2011-07*. Dostupno na: http://hdl.handle.net/1903/11394 (22.11.2014.).
59. Klenczon, W. i Rygiel, P. (2014). Librarian cornered by images, or how to index visual resources. *Cataloging i Classification Quarterly*, 52(1), 42-61.
60. Kwan, Y. i Chan, L. (2009). Linking folksonomy to Library of Congress subject headings: An exploratory study. *Journal of Documentation*, 65(6), 872–900
61. Lancaster, F. W. i Smith, L. C. (1983). *Compatibility issues affecting information systems and services*. Paris: UNESCO.
62. Lancaster, F. W. (2003). Indexing and abstracting in theory and practice. 3. izd. London: Facet Publishing.
63. Lasić-Lazić, J. (1996). Znanje o znanju. Zagreb: Zavod za informacijske studije Odsjeka za informacijske znanosti, Filozofski fakultet.
64. Lasić-Lazić, J.; Špiranec, S. i Ivanjko, T. (2014). Tag-resource-user: a review of approaches in studying folksonomies. *Qualitative and Quantitative Methods in Libraries -electronic journal*, 3, 683-692.
65. Law, E. i von Ahn, L. (2009). Input-agreement: a new mechanism for collecting data using human computation games. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems,(CHI '09*). New York: ACM, 1197-1206.
66. Lee, B. (2005). Can *social tagging overcome barriers to content classification?* Dostupno na: http://www.headshift.com/our-blog/2004/08/30/can-social-tagging-overcome-ba/ (22.11.2014.).

67. Leonard, L. (1977). *Inter-indexer consistency studies, 1954-1975: A review of the literature and summary of study results*. Urbana-Champaign: University of Illinois, Graduate School of Library Science.
68. Library of Congress (2008). *For the common good: The Library of Congress Flickr pilot project.* Library of Congress, Prints and Photographs Division. Dostupno na: http://www.loc.gov/rr/print/flickr_report_final.pdf (22.11.2014.)
69. Lohmann, S. (2013). *Conceptualization and visualization of tagging and folksonomies*. Doktorska disertacija. Madrid: Departamento de informatica. Dostupno na: http://e-archivo.uc3m.es/bitstream/handle/10016/18179/tesis_steffen_lohmann_2013.pdf (22.11. 2014.).
70. Lu, C., Park, J. i Hu, X. (2010). User tags versus expert–assigned subject terms: A comparison of LibraryThing tags and Library of Congress Subject Headings. *Journal of Information Science*, 36(6), 763–779.
71. Markey, K. (1984). Interindexer consistency tests: a literature review and report of a test of consistency in indexing visual materials. *Library and Information Science Research*, 6, 155-177.
72. Marlow, et al. (2006). HT06, tagging paper, taxonomy, flickr, academic article, to read. *Proceedings of the 17th ACM Conference on Hypertext and Hypermedia, (HYPERTEXT '06),* ACM, 31–40.
73. Marvasti, A. F. (2008). Social structure in tagging practices: reality or myth? Magistarski rad. Kingston, Ontario, Canada: Queen's University.
74. Mathes, A. (2004). Folksonomies - cooperative classification and communication through shared metadata. *Computer Mediated Communication*, 47(10)
75. Mendes, L. H; Quiñonez-Skinner. J. i Skaggs, D. (2009). Subjecting the catalog to tagging. *Library Hi Tech*, 27(1), 30-41.
76. Mika, P. (2005). Ontologies are us: A unified model of social networks and semantics. In *Proceedings of the 4th International Semantic Web Conference 2005, (ISWC '05),* 522–536.
77. Mikačić, M. (1990). *Teorijske osnove sustava za izradbu predmetnog kataloga : doktorska disertacija*. Zagreb : vlast. nakl.
78. Müller, R., Thoring, K. i Oostinga, R. (2010). Crowdsourcing with semantic differentials: a game to investigate the meaning of form. *AMCIS 2010 Proceedings*, 342.
79. Munk, T.B. i Mork, K. (2007). Folksonomies, tagging communities, and tagging strategies: an empirical study. *Knowledge Organization*, 34(3), 115-127.

80. Nonaka, I. (1991). The knowledge-creating company. *Harvard business review*, 69(6), 96-104.
81. O'Reilly, T. (2005). W*hat is Web 2.0: design patterns and business models for the next generation of software*. Dostupno na: http://www.oreillynet.com/pub/a/oreilly/tim/news/2005/09/30/what-is-web-20.html (22.11.2015.).
82. O'Reilly, T. i Battelle, J. (2009). *Web squared: Web 2.0 five years on*. Dostupno na: http://gossgrove.com/sites/default/files/web2009_websquared-whitepaper.pdf (22.11.2014.)
83. Olson, H. A. i Boll, J. J. (2001). *Subject analysis in online catalogs*. Englewood: Libraries Unlimited.
84. Olson, H. A. i Wolfram, D. (2008). Syntagmatic relationships and indexing consistency on a larger scale. *Journal of Documentation*, 64(4), 602-615
85. Library of Congress (2008). On the record: report of the Library of Congress working group on the future of bibliographic control. Dostupno na: www.loc.gov/bibliographic-future/news/lcwg-ontherecord-jan08-final.pdf (22.11.2014).
86. Oomen, J. i Aroyo, L. (2011). Crowdsourcing in the cultural heritage domain: opportunities and challenges. *Proceedings of the 5th International Conference on Communities and Technologies, (CiT '11).* New York: ACM, 138-149.
87. Owens, T. (2013). Digital cultural heritage and the crowd. *Curator: The Museum Journal.* 56(1), 121-130.
88. Owens, T. (2013). *Human Computation and Wisdom of Crowds in Cultural Heritage*. Dostupno na: http://www.trevorowens.org/2012/06/human-computation-and-wisdom-of-crowds-in-cultural-heritage (22.11.2014.)
89. Panofsky, E. (1955). *Meaning in the visual arts*. Chicago: The University of Chicago Press.
90. Persson, O. D., Danell, R. i Wiborg Schneider, J. (2009). How to use Bibexcel for various types of bibliometric analysis. *Celebrating scholarly communication studies: A Festschrift for Olle Persson at his 60th Birthday*, International Society for Scientometrics and Informetrics, 9-24
91. Peters, I. (2009). *Folksonomies: indexing and retrieval in Web 2.0*. Berlin: De Gruyter Saur
92. Peters, I. et al. (2011). Retrieval effectiveness of tagging systems. *Proceedings of the American Society for Information Science and Technology*, 48, 1-4.
93. Peters, I. i Stock, W.G. (2007). Folksonomies and information retrieval. *Proceedings of the American Society for Information Science and Technology*, 44(1), 1-28.

94. Petz, B. (2002). *Osnovne statističke metode za nematematičare*. 4. izd. Jastrebarsko : Naklada Slap
95. Purgarić-Kružić, B. (2012). Društveno označivanje i knjižnice. *Vjesnik bibliotekara Hrvatske*, 54(4), 189-210.
96. Quinn, A. J. i Bederson, B. B. (2011). Human computation: a survey and taxonomy of a growing field. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, (CHI '11).* New York: ACM, 1403-1412.
97. Quintarelli, E. (2005). Folksonomies: power to the people. *ISKO Italy-UniMIB meeting*. Dostupno na: http://www.iskoi.org/doc/folksonomies.htm (22.11.2014.)
98. Rethlefsen, M. L. (2007). Tags help make libraries Del.icio.us: social bookmarking and tagging boost participation. *Library Journal*, 132(15), 26-28.
99. Ridge, M. (2011). Playing with difficult objects – game designs to improve museum collections. *Proceedings of the Museums and the Web 2011*. Toronto: Archives and Museum Informatics.
100. Rolla, Peter J. (2009). User tags versus subject headings: can user-supplied data improve subject access to library collections? *Library Resources and Technical Services*, 53(3), 174-184.
101. Rolling, L. (1981). Indexing consistency, quality and efficiency. *Information Processing and Management*, 17, 69-76.
102. Rorissa, A. (2010). A comparative study of Flickr tags and index terms in a general image collection. *Journal of the American Society for Information Science and Technology*, 61(11), 2230-2242.
103. Rowley, J. (1994). The controlled versus natural indexing languages debate revisited: a perspective on information retrieval practice and research. *Journal of Information Science*, 20(2), 108-118.
104. Rowley, J. i Hartley, R. (2008). *Organizing knowledge: an introduction to managing access to information*. Aldershot, England, Burlington, VT : Ashgate
105. Shatford, S. (1984). Describing a picture: A thousand words are seldom cost effective. *Cataloging and Classification Quarterly*, 4(4), 13-30.
106. Shatford, S. (1986). Analyzing the subject of a picture: A theoretical approach. *Cataloging and Classification Quarterly*, 6(3), 39-62.
107. Shatford, S. (1994). Some issues in the indexing of images. *Journal of the American Society for Information Science*, 45(8), 583-588.

108. Shirky, C. (2003). A group is its own worst enemy, 2003. Dostupno na: http://www.shirky.com/writings/group_enemy.html (22.11.2014.).
109. Shirky, C. (2005). Folksonomies + controlled vocabularies. Dostupno na: http://many.corante.com/archives/2005/01/07/folksonomies_controlled_vocabularies.php (22.11.2014.).
110. Simon, N. (2010). *The Participatory Museum*. Santa Cruz, California: Museum 2.0
111. Sinclair, J. i Cardew-Hall, M. (2008). The folksonomy tag cloud : when is it useful? *Journal of Information Science* 34(1), 15-29.
112. Stock, W. (2007). Folksonomies and science communication: A mash-up of professional science databases and Web 2.0 services. *Information Services and Use*, 27(3), 97-103.
113. Stvilia, B. i Jörgensen, C. (2010). Member activities and quality of tags in a collection of historical photographs in Flickr. *Journal of the American Society for Information Science and Technology*, 61(12), 2477-2489.
114. Surowiecki, J. (2005). *The wisdom of crowds*. Random House LLC.
115. Svenonius, E. (2005). *Intelektualne osnove organizacije informacija*. Lokve : Benja
116. Špiranec, S.(2010). Što je e-učenje bez metapodataka? 13. seminar Arhivi, knjižnice, muzeji : mogućnosti suradnje u okruženju globalne informacijske infrastrukture : zbornik radova / Willer, M. i Faletar Tanacković, S., (ur.). Zagreb: Hrvatsko knjižničarsko društvo, 75-89.
117. Špiranec, S. i Banek Zorica, M. (2008). Web 2.0 i Semantički web: ista ili različita odredišta? 11. seminar Arhivi, knjižnice, muzeji : mogućnosti suradnje u okruženju globalne informacijske infrastrukture : zbornik radova / Willer, M., (ur.). Zagreb: Hrvatsko knjižničarsko društvo, 27-43.
118. Špiranec, S. i Ivanjko, T. (2012). Predmetni jezici s korisničkim jamstvom: što možemo naučiti od folksonomija? *15. seminar Arhivi, knjižnice, muzeji : mogućnosti suradnje u okruženju globalne informacijske infrastrukture* / Hassenay, D. i Krtalić, M.,(ur.). Zagreb: Hrvatsko knjižničarsko društvo, 57-72.
119. Špiranec, S. i Ivanjko, T. (2013). Experts vs. novices tagging behavior: an exploratory analysis. *Procedia-Social and Behavioral Sciences*, 73, 456-459.
120. Špiranec, S. i Ivanjko, T. (2013). Providing access to textual and image resources: analyzing tagging practices. *Proceedings of the 21st International BOBCATSSS Conference*, 32.
121. Špiranec, S. i Ivanjko, T. (2013). Korisničko označivanje tekstualnih i vizualnih informacija: što mogu očekivati AKM ustanove? *16. seminar Arhivi, knjižnice, muzeji : mogućnosti*

suradnje u okruženju globalne informacijske strukture : zbornik radova / Tomašević, N. i Despot, I. (ur.). Zagreb : Hrvatsko knjižničarsko društvo, 66-79.

122. Tanaka, J. i Taylor, M. (1991). Object categories and expertise: is the basic level in the eye of the beholder? *Cognitive Psychology*, 23(3), 457-482.
123. Taylor, A. i Joudrey, D. N. (2009). *The organization of information*. 3. izd. Libraries Unlimited, Westport, CT.
124. Thelwall, M. (2013). *Webometrics and Social Web research methods*. 2013. Dostupno na: http://www.scit.wlv.ac.uk/~cm1993/papers/IntroductionToWebometricsAndSocialWebAnalysis.pdf (22.11.2014.).
125. Thøgersen, R. (2012). *Crowdsourcing for image metadata: a comparison between game-generated tags and professional descriptors*. Doktorska disertacija. Dostupno na: http://hdl.handle.net/10642/1267 (22.11.2014.).
126. Thomas, M.; Caudle, D. M. i Schmitz, C.M. (2009). To tag or not to tag? *Library Hi Tech*, 27(3), 411-434.
127. Tonkin, E., et al. (2008). Collaborative and social tagging networks. *Ariadne*, 54. Dostupno na: http://www.ariadne.ac.uk/issue54/tonkin-et-al/ (22.11.2014.).
128. Trant, J. (2009). Tagging, folksonomy and art museums: Results of steve.museum's research. Archives i Museum Informatics. Dostupno na: http://www.museumsandtheweb.com/files/trantSteveResearchReport2008.pdf (22.11.2014.).
129. Tsai, L. C., Hwang, S. L. i Tang, K. H. (2011). Analysis of keyword-based tagging behaviors of experts and novices. *Online Information Review*, 35, 272-290.
130. Tuđman, M., Boras, D. i Dovedan, Z. (1993). Uvod u informacijsku znanost. Zagreb: Školska knjiga.
131. Vander Wal, T. (2007). Folksonomy coinage and definition. Dostupno na: http://vanderwal.net/folksonomy.html. (22.11.2014.).
132. von Ahn, L. (2006). Games with a purpose. *IEEE Computer Magazine*, 39(6), 96-98.
133. von Ahn, L. et al. (2008). ReCAPTCHA: human-based character recognition via web security measures. *Science*, 321, 1465-1468.
134. von Ahn, L. (2011). Human Computation. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, 5(3), 1-121.
135. von Ahn, L. i Dabbish, L. (2004). Labeling images with a computer game. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, (CHI '04). New York: ACM, 319-326.

136. von Ahn, L. i Dabbish, L. (2008). Designing games with a purpose. *Communications of the ACM*, 51(8), 58-67.

137. Wagner, C. (2006). Breaking the knowledge acquisition bottleneck through conversational knowledge management. *Information Resources Management Journal*, 19(1), 70-83.

138. Wetterström, M. (2008). The complementarity of tags and LCSH – a tagging experiment and investigation into added value in a New Zealand library context. *The New Zealand Library and Information Management Journal*, 50(4), 296-310.

139. White, H. D. i McCain, K. W. (2009). Visualizing a discipline: An author co-citation analysis of information science, 1972-1995. *Journal of the American Society for Information Science*, 49 (4), 327-355.

140. Wu, X., Zhang, L. i Yu, Y. (2006). Exploring social annotations for the semantic web: *Proceedings of the 15th international conference on World Wide Web (WWW '06).* New York: ACM, 417-426

141. Yang, L. et al. (2012). We know what@ you# tag: does the dual role affect hashtag adoption? *Proceedings of the 21st international conference on World Wide Web (WWW'12)*. New York: ACM, 261-270

142. Yeung, et al. (2007). *Understanding the semantics of ambiguous tags in folksonomies*. Dostuno na: http://eprints.soton.ac.uk/264869/1/tag_semantics.pdf (22.11.2014.)

143. Kwan, Y. i Chan, L. M. Linking folksonomy to Library of Congress subject headings : an exploratory study. *Journal of Documentation*, 65(6), 872-900.

Prilozi

Prilog 1. Popis arhivske knjižnične i muzejske građe korištene u istraživanju

ID	NAZIV	MATERIJALNI OPIS	ANOTACIJA	SLIKA
HPM-90163	Tenk gazi osječkog crvenog "fiću"	Josip Petrić, Osijek, 27. 6. 1991. c/b fotografija, 30,5 x 40,4 cm	Snimke HTV-ova snimatelja Žarka Plevnika i *Večernjakova* fotoreportera Josipa Petrića kako tenk gazi crvenog „fiću“ na osječkim ulicama najzornije su odaslale svijetu vijest o početku agresije na Republiku Hrvatsku. Crveni „fićo“ ubrzo je postao simbolom ne samo obrane Osijeka, nego i građanskog otpora otvorenoj agresiji na Republiku Hrvatsku. Događaj se zbio 27. lipnja 1991., dva dana nakon proglašenja samostalnosti Republike Hrvatske i Republike Slovenije, kada je JNA napala Sloveniju. U poslijepodnevnim satima iz vojarne JNA na osječke ulice izašla su četiri tenka i tri oklopna vozila 12. mehanizirane brigade, iz kojih se pucalo, s ciljem zastrašivanja okupljenih građana i demonstriranja moći. Pritom je na križanju tadašnje Kleinove ulice (danas Ulice kneza Trpimira) i Vukovarske ulice oštećeno i pregaženo nekoliko automobila i autobus. Jedan od pregaženih automobila bila je i crvena *Zastava 750*, popularno zvana *fićo*, koji je Osječanin Branko Breškić, danas preminuli hrvatski branitelj, u znak prosvjeda postavio pred kolonu tenkova. Tenk je vozio ročnik Josip Ilić koji je uz uperen pištolj svog nadređenog pregazio „fiću.“ Nakon nekoliko dana ročnik je pobjegao iz JNA i uključio se u 3. gardijsku brigadu u koju se dobrovoljno uključio i Branko Breškić. Njihov susret nakon rata zabilježen je u dokumentarnom filmu redatelja Vladimira Tadeja *Crveni fićo* snimljenom 2000. godine.	
HPM-90919	Prosvjed majki ispred Zapovjedništva 5. vojne oblasti	Hrvoje Knez, Zagreb, 30. 8. 1991. c/b fotografija; 18 x 13 cm	Spontani prosvjedi majki vojnika prerasli su krajem kolovoza u organizirani pokret majki za mir čiji su se sinovi zatekli na odsluženju vojnog roka u JNA. Pod dojmom napada JNA u srpnju i kolovozu i zabrinutosti za sudbinu svojih sinova koji su u jedinicama JNA, majke su na skupu održanom 25. kolovoza 1991. na zagrebačkom Velesajmu odlučile svoje zahtjeve uputiti vodstvu JNA u Beogradu pozivajući roditelje iz drugih republika da im se pridruže. Pokret tada dobiva ime Bedem ljubavi kao suprotnost vojnim planovima JNA vođenim pod šiframa Bedem-I i Bedem-II, a koji su prvo predviđali vojno osvajanje Slovenije. Majke iz Hrvatske, Bosne i Hercegovine i Makedonije organizirano su 29. kolovoza 1991. otišle u Beograd u sjedište generalštaba JNA tražiti: otpuštanje vojnika kojima jednogodišnji vojni rok ističe u rujnu, premještanje vojnika kojima još nije istekao vojni rok u matične republike kako bi ondje odslužili ostatak vojnog roka, povlačenje armije u kasarne te aboliciju svih vojnih dezertera i povratak mira. Nakon što je kolona autobusa bila zaustavljena kod Šida, a potom i zadržana na ulazu u Beograd, majke su bile odvedene u Dom JNA u Topčideru, gdje su bile	

			izvrgnute torturi kako bi ih se razjedinilo u njihovim zahtjevima. JNA u svom glasilu Front izvještava da je u Beograd stiglo 2000 roditelja vojnika iz Zagreba, Splita, Bjelovara, Osijeka i drugih gradova u Hrvatskoj te iz Sarajeva, Tuzle i Skoplja, a akciju majki naziva „bedem mržnje prema Jugoslaviji i JNA.“ (Front, 6. 9. 1991.: 4-5). Nakon neuspješne misije u Beogradu (od 29. do 31. kolovoza 1991.) majke su organizirale mirne prosvjede u Bruxellesu početkom rujna 1991., gdje su svoje zahtjeve izložile u Europskom parlamentu, zatim u Bonnu, Frankfurtu, Münchenu i Parizu. Nakon povratka iz Europe članice pokreta uputile su apel majkama u Srbiji da "zajednički dignemo svoj glas - zaustavimo rat", u formi letka koji je bio odaslan na više tisuća adresa koje su nasumce birale iz telefonskih imenika srpskih gradova. (Hrvatsko ratno pismo, 1992: 229) Tijekom rata pokret je djelovao u Varaždinu, Zagrebu, Bjelovaru, Osijeku, Splitu, Rijeci, Puntu i drugim gradovima, usmjerivši kasnije svoje djelovanje i na humanitarni rad oko pomoći ranjenim vojnicima i oko prihvata prognanika i izbjeglica. Kao humanitarna, nevladina udruga, Bedem ljubavi djeluje i danas.	
HPM-90134	Pustoš u Hrvatskoj Kostajnici	Josip Bistrović, Hrvatska Kostajnica, kolovoz 1991. c/b fotografija; 40,4 x 30,5 cm		
HPM-90662	Prognanice iz Baranje	Jadran Mimica, Osijek, 1991. c/b negativ; 6 x 7,5 cm		

HPM-90791	Spašavanje dječaka	Marin Topić, Osijek, listopad 1991. presnimka; c/b negativ; 7,5 x 6 cm	Na fotografiji je zaustavljen trenutak hrvatskog branitelja koji u trku nosi dječaka. Hrvatski branitelj je Zvonko Ljušanin, pripadnik Baranjskog bataljuna, koji spašava dječaka Jakova za vrijeme topničkog napada na Osijek početkom listopada 1991. Fotografija je reproducirana na jednom od 13 plakata iz ciklusa Documenta Croatica u izdanju Hrvatskog informativnog pula i akcije Dobro je činiti dobro 1991. godine. Djeca su bile višestruke žrtve rata. Stradavanje, proživljeni strah, gubitak roditelja, rođaka i prijatelja, iskustvo zatočeništva i mučenja, izbjeglištva i progonstva, izgubljeno djetinjstvo i naglo odrastanje trajne su i nenadoknadive posljedice rata. Brojna djeca koja su ostala živjeti na područjima pod izravnom ratnom opasnošću na jesen 1991. godine odlazak u školu zamijenila su učestalim odlascima i višemjesečnim životom u podrumu, te se nastava neko vrijeme odvijala preko radija. Zbog sigurnosti djeca su bila evakuirana u priobalna mjesta ili u europske države (Čehoslovačku, Mađarsku, Austriju, Italiju), te su upravo među prognanima najbrojnija bila djeca. Unatoč potpisivanju konačnog primirja u siječnju 1992. godine i dolaska plavih kaciga UN-a granatiranja i napadi na hrvatske gradove bili su nastavljeni, a time i stradavanje djece. Prema nepotpunim podacima koji se odnose na slobodno područje RH, tijekom rata u Hrvatskoj ranjeno je 1044 djece, a 323 djece je poginulo zbog ratnih razaranja. Oko 70 posto djece stradalo je zbog izravnog neprijateljskog djelovanja (u eksplozijama granata, mina, u raketiranjima iz zrakoplova, od snajpera), dok je 30 posto poginulo u igri vatrenim oružjem. Bez jednog roditelja ostalo je 5497 djece, a 74 djeteta ostala su bez oba roditelja. Prema nepotpunim podacima, na okupiranim područjima RH smrtno je stradalo 54 djece. Samo u Slavonskom Brodu, gradu s najviše poginule djece, tijekom 1992. godine poginulo je 28 djece. Stoga se upravo u tom gradu svake godine održava susret roditelja poginule djece, a ispred Osnovne škole Huge Badalića, gdje je poginulo 16 učenika, podignut je spomenik Djevojčica na spomen svim dječjim žrtvama u Domovinskom ratu. „Na početku smo silazili u podrum kada je svirala uzbuna, a poslije smo odlazili kada su označavali kraj zračne opasnosti. Tek je tada znalo postati opasno. (...) Zajednička molitva krunice bila je nešto poput rituala koji se nije preskakao. (...)Vrijeme se kratilo i uz lampu koja se nije gasila cijele noći. Djeca bi se okupila oko nje i igrala se praveći različite sjene na zidu. Zaigrala bi se i pokoja partija jamba. Najmlađi među nama imao je samo godinu dana, a svoje prve korake napravio je upravo u podrumu Vukovarske 99. Svaka pa i ona najstrašnija situacija koja nam se dogodila tijekom dana, uvečer, kada bismo se svi okupili, prepričavala bi se u detalje. Iz nje bi se uvijek izvlačilo ono čemu bismo se svi slatko smijali. Slavili smo u podrumu i Božić. Okitili smo dva bora, ali nismo imali pravih poklona (...)“, sjećanja su dvanaestipolgodišnje djevojčice Mihaele Vuksanić iz Osijeka (Barišić, 2011: 68-69).	

HPM-90875	Stup sigurnosti	Jadran Mimica, Zagreb, prosinac 1991. c/b fotografija; 24 x 18 cm	Fotografija prikazuje oproštaj dječaka na glavnom zagrebačkom kolodvoru s ocem koji odlazi na osječku frontu. Udruženje fotoreportera Hrvatskog novinarskog društva proglasilo ju je fotografijom mjeseca prosinca 1991. godine. Izvor: Večernji list, 10. 12. 1991.	
HPM-91563	Spaljena kuća	Snježana Kundija, Lipik, 4. 2. 1992. c/b fotografija; 13 x 18 cm	Na fasadi kuće ostavljena je poruka srpskog agresora: „PETA KOZARSKA BRIGADA“ s iscrtanom peokrakom zvijezdom i srpskim križem s četiri ocila.	
HPM-91415	Osmrtnice	Josip Bistrović, Zadar, 31. 5. 1992. c/b fotografija; 18 x 13 cm		
HPM-92902	Vodotoranj	J. Isaac, Vukovar, 4. 9. 1992. c/b fotografija; 20,3 x 25,5 cm	Vodotoranj na ulazu u vukovarsko naselje Mitnicu bio je jedna od najčešćih meta napada srpskog topništva na grad. Danas je simbol pobjede i sjećanja na Vukovar 1991.	

HPM-91263	Vukovar	TANJUG (Telegrafska agencija nove Jugoslavije), Vukovar, 19. 11. 1991. c/b fotografija; 21,5 x 30 cm		
HPM-90145	Banija	Josip Bistrović, 1991. c/b fotografija; 30,4 x 40,5 cm		
HPM-91229	Pakrac	Boris Fabijanec, rujan 1991. fotografija u boji; 9 x 13 cm;		
HPM-91773	Sisak, Komarevo	Saša Kralj, 21. 3. 1992. leica film; 2,4 x 3,6 cm		

HPM-92298	„Zid boli“ ispred sjedišta UNPROFOR-a	Aleksandar Korka, Zagreb, 28. 9. 1993. Leica film, 2,6 x 3,4 cm	Zid boli izgrađen od cigli koje simboliziraju poginule i nestale hrvatske branitelje i civile nastao je spontano u rujnu 1993. godine ispred sjedišta mirovnih snaga UN-a u Selskoj cesti u Zagrebu kao protest i apel međunarodnoj zajednici. Idejna začetnica bila je Zdenka Farkaš, voditeljica udruge „Apel.“ Načinjen je od crvenih cigli s upisanim imenima nestalih i crnih s imenima ubijenih s okupiranog područja. U tisku se naziva i zidom istine, zidom plača. Pred zidom su se palile svijeće u bojama trobojnice (crvena za ljubav, bijela za istinu, plava za vjernost), potpisivale su se rezolucije, održavale mise zadušnice, protestiralo zbog neučinkovitosti UNPROFOR-a i međunarodne zajednice . O sudbinama žena i roditelja koji još uvijek traže svoje najmilije snimljen je dokumentarni film autorice Shenide Bilalli pod nazivom Zid boli - The wall of grief 1996. godine. S odlaskom UNPROFOR-a i zatvaranja njihovog sjedišta u Zagrebu 1995. godine, ovaj simbol stradanja izgubio je svoju prvotnu funkciju da svojom prisutnošću stalno podsjeća predstavnike međunarodne zajednice na problem nestalih. Nakon deset godina, Zid je 2003. godine preseljen i ugrađen u spomenik Glas hrvatske žrtve – Zid boli na groblju Mirogoj. Danas je na nekadašnjoj lokaciji u Selskoj cesti ostalo samo zvono koje je 1994. godine postavila Udruga obitelji zatočenih i nestalih hrvatskih branitelja. Izvor: Večernji list, 13. 2. 1994.: 1; Billali, 1996. (IEF-video 789). Lit: Gdje su naši, 1996; Bilalli, Shenida, 2005.	
HPM-93005	Oluja	Josip Bistrović, Knin, 5. 8. 1995. c/b fotografija, 17,7 x 24 cm		
HPM-90558	Pripadnici pričuvnog sastava MUP-a RH u logoru Manjača	dopisnica Arene iz Banja Luke, logor Manjača, Bosna i Hercegovina, 29. 9. 1991. c/b fotografija; 13 x 18 cm	Na fotografiji su pripadnici pričuvnog sastava Ministarstva unutarnjih poslova Republike Hrvatske snimljeni neposredno pred ulazom u logor Manjača pri povratku s „dobrovoljnog rada.“ Prvi slijeva je Vladimir Štefanac, do njega Jurica Maričić, a u trećem redu, drugi s lijeva, Stjepan Videk. U logoru su bili zatočeni 58 dana, od 12. 9. 1991. do 9. 11. 1991. kada su razmijenjeni na mostu između Bosanskog Šamca i Slavonskog Šamca. Nakon osvajanja Hrvatske Kostajnice od Banjalučkog korpusa JNA i VII. Banijske brigade, 12. rujna 1991. predala su se 282 hrvatska branitelja. Dio zarobljenih hrvatskih branitelja bio je odveden u Glinu, a veći dio s civilima interniran u srbijanski logor koji je bio organiziran na vojno-poljoprivrednom dobru JNA na planini Manjača, u blizini Banja Luke na teritoriju Bosne i Hercegovine (sastoji se	

			od 10 štala i dvije manje prostorije za osoblje). Svi zarobljenici su odvođeni na informativne razgovore. U logoru su pripadnici ZNG-a odvojeni od pripadnika MUP-a, od kojih su pripadnici garde (ZNG-a) bili više podvrgnuti zlostavljanjima, a posebno su oštro bili tretirani prebjezi iz JNA. „Dnevni ritam života odvijao se u velikoj neizvjesnosti, bez ikakvog kontakta s vanjskim svijetom, slušanja radija ili TV, pa čak ni čitanja tiska, osim „Narodne armije." Nije bilo vode za prati. Hrana se dovozila, a zatočenici su je dijelili i za one u samici. Na principu „dobrovoljnosti" (rad ili batine) radilo se u skupinama od 30 ljudi na krumpiništu ili šumi, pa je taj fizički rad bio neka vrsta relaksa u otežanoj psihičkoj torturi. Major KOS-a uvjeravao je zatočenike, da ih hrv. Vlada ne želi ili uopće ne razmišlja o razmjeni. Čak i stražari-vojnici s kojima se povremeno razgovralo lagali su o razmjeni po naredjenju. Tek krajem rujna logor na Manjači posjetili predstavnici Međunarodnog Crvenog križa iz Geneve i tek putem njih, zatočenici na formularima poslali prve poruke obiteljima i nakon dva tjedna dobili odgovore." (Sjećanje sudionika zatočenih u Manjači u vremenu od 13. XI – 8. XI 1991., Zagreb, 15. 1. 1992., dokumentacija HPM-a). U Zagrebu je djelovao Odbor za Manjaču koji je obiteljima pružao informacije, a preko poruka Crvenog križa bili su uspostavljeni kontakti sa zarobljenima. Većina zatočenika razmijenjena je 9. studenoga 1991. u Bosanskom Šamcu uz prisutnost predstavnika Međunarodnog Crvenog križa. Konvoj autobusa stigao je u Zagreb, gdje su ih u hotelu „Panorama" dočekale liječničke ekipe i njihove obitelji. Popis poginulih, nestalih, ranjenih i zatočenih pripadnika ZNG-a i MUP-a u borbama na području Hrvatske Kostajnice 1991. donosi Vladimir Štefanac u knjizi U logorima Manjače i Gline, svjedočenja hrvatskih branitelja. O sudbini skupine nestalih hrvatskih branitelja Hrvatske Kostajnice doznaje se tek u studenom 1997. kada je otkrivena masovna grobnica na mjestu bivšeg stočnog groblja (Kronologija rata, 1998: 596). Izvor: Razgovor djelatnika HPM-a s Klukom Giuniom, HPM, Zagreb, studeni 2011. Lit: Štefanac, 1994; Štefanac, 1996; Williams i Switzer, 1999: 295.	
HPM-90142	Odlazak civila iz Sunje	Josip Bistrović, 1991. c/b fotografija; 28,3 x 40,4 cm	Na fotografiji je kao mjesto navedena Sunja. Ista fotografija na plakatu HIC-a pod red. br. 16 potpisana je: Slunj (Reljanović, 2010: 97). Lit: War crimes against Croatia, 1991: 57	

HPM-91474	Prognanica ispred zagrebačke sportske dvorane „Martinovka“	Saša Kralj, Zagreb, travanj 1992. Leica film; 2,4 x 3,6 cm		
HPM-92475	Humanitarna pomoć akcije Nachbar in Not	Marko Perić, Đakovo, jesen 1991. c/b fotografija; 13 x 18 cm	Akciju Susjed u nevolji pokrenuo je austrijski Caritas koji je među prvima reagirao na ratna zbivanja u susjednim zemljama bivše Jugoslavije. Uz pomoć Austrijskog radija, lokalnih radio postaja i tiska te niza dobrotvornih organizacija i anonimnih pojedinaca prikupljala se pomoć u hrani i ostalim potrepštinama. Pomoć se dopremala šleperima koji su bili oblijepljeni prepoznatljivim nazivom akcije Nachbar in Not. Do travnja 1993. u Hrvatsku je preko akcije prikupljeno i dopremljeno 38.000 tona pomoći u vrijednosti 570 milijuna šilinga, a u ljeto iste godine stigao je 2000. šleper. Akcija se pokazala vrlo uspješnom i efikasnom, pogotovo u animiranju pojedinaca u pružanju pomoći čovjeku u nevolji, te su i druge europske zemlje poput Luksemburga, Švicarske, Nizozemske, Belgije, Švedske i Italije pokazale interes za austrijski model humanitarnog djelovanja. Akciju je koordinirao Peter Quendler, predstavnik Austrijskog Caritasa, koji je za svoj rad odlikovan počasnim odličjem Koruške te izabran za Korušanina godine. Austrijski Caritas je također tijekom rata u Hrvatskoj provodio humanitarne akcije Krov nad glavom, kojom su se prikupljala sredstva za obnovu obiteljskih kuća, i Dijete u nevolji kojom se prikupljala pomoć u odjeći. Izvor: Caritas nadbiskupije Zagrebačke, 1993: 12-13.	

HPM-91649	Službena ceremonija podizanja zastava novih članica Ujedinjenih naroda		Republika Hrvatska je primljena kao 178. članica Ujedinjenih naroda za vrijeme 46. Generalne skupštine, rezolucijom A/RES/46/238 od 22. svibnja 1992. godine. Istoga dana u članstvo su primljene Slovenija i Bosna i Hercegovina. Nakon priznanja hrvatske samostalnosti i suverenosti, prijem Republike Hrvatske u svjetsku zajednicu ravnopravnih i nezavisnih država ocijenjen je tada kao jedan od najznačajnijih datuma u hrvatskoj povijesti. Fotografije sa svečanosti primanja Hrvatske u Organizaciju Ujedinjenih naroda pristigle su diplomatskom poštom iz Veleposlanstva RH u SAD-u (preko djelatnika Ministarstva vanjskih poslova RH, Mladena Peličarića u New Yorku), uoči otvorenja izložbe HPM-a Živjeti s ratom protiv rata 18. lipnja 1992. godine.	
HPM 97949	Tabla minske opasnosti	naručitelj: Hrvatski centar za razminiranje; Hrvatska, 1.desetljeće 21. st. aluminijski lim, željezo; lijevanje, strojno prešanje, rezanje, tisak; š. 80 cm, v. 60 cm (v. cjeline 102,5 cm)	Pravokutna tabla s nosivom željeznom konstrukcijom. Natpisna podloga je bijele boje s tekstom upozorenja: „NE PRILAZITE / NA OVOM PODRUČJU JE VELIKA / OPASNOST OD MINA.“ Na sredini gornje trećine table je crveni trokut u kojem je bijelom bojom otisnuta lubanja s prekriženim kostima ispod, s natpisom velikim bijelim slovima „MINE / MINES.“ U donjem desnom kutu logo Hrvatskoga centra za razminiranje otisnut crveno. Na poleđini željezna konstrukcija za postavljenje u prostor. Pravilnikom o načinu obavljanja poslova humanitarnog razminiranja propisan je način obavljanja općeg i tehničkog izvida, poslova pretraživanja i/ili razminiranja, pomoćnih poslova razminiranja, obilježavanja minski sumnjive površine te stručni nadzor.U Pravilniku se pored ostaloga propisuje izgled tabli i oznaka te način obilježavanja MSP-a odnosno područja zagađenih MES-om i NUS-om. Table minske opasnosti predstavljaju osnovni način obilježavanja MSP-a i jasno vizualno upozorenje na opasnost od mina, kao i zabranu ulaska stanovništva u MSP. Uz međunarodni simbol smrtne opasnosti (lubanja s prekriženim kostima) na njima se nalazi i tekst upozorenja (najčešće na hrvatskom i engleskom jeziku). Postavljaju se na mjestima mogućeg pristupa MSP-u (putovi, staze i druge površine gdje se očekuje kretanje ljudi), odnosno na preglednim mjestima te moraju biti vidljive s udaljenosti od najmanje 50 m.Lit.: Narodne novine (53/2007, 111/2007 i 141/2011)	

HPM-93552	Suvenirska zastavica obilježavanja 600. godišnjice Kosovske bitke	Srbija, 1989. platno, sintetički konac, karton; sitotisak, lijepljenje, rezanje, strojno pletenje, šivanje; 23 x 8,5 cm; ćirilica	Zastavica od bijeloga platna opšivena žutim konopčićem, na aversu smeđom bojom otisnut lik Slobodana Miloševića s natpisom na ćirilici: „LIČNOST GODINE.“ Na reversu službeni logo proslave obilježavanja 600. godišnjice osmansko-srpske bitke na Kosovu – unutar crvene kružnice s lovorovom granom, upisane godine obljetnice: "600 G // 1389 //1989". Glavna svečanost održala se na Vidovdan 28. lipnja 1989. na Gazimestanu (Kosovo Polje). Proslava je označila vrhunac popularnosti Slobodana Miloševića, tada već predsjednika Predsjedništva SR Srbije koji je prethodno mitinzima i tzv. „antibirokratskom revolucijom“ preuzeo vlast nad Vojvodinom i Kosovom ukinuvši im autonomiju te u SR Crnoj Gori postavio na vlast ljude odane njegovoj politici. U svom je govoru za vrijeme svečanosti označio po mnogima početak borbe Srbije za teritorijalno proširenje: „Šest vekova kasnije, danas, opet smo u bitkama, i pred bitkama. One nisu oružane, mada i takve još nisu isključene.“ Na proslavi su zabilježeni nacionalistički istupi okupljenog mnoštva koje je uz srpske i crkvene zastave nosilo brojne bedževe, značke, šajkače i četnička obilježja te portrete Slobodana Miloševića uzvikujući parole i pjesme: „Niko nema šta Srbin imade“, „Slobodan je naše rosno cveće“, „Takvog junaka nije rodila majka“, „Evo Slobodana lepote naše“, „Tamo daleko“, „Ko to kaže, ko to laže“, „Slobo, slobodo, Srbija se budi“ i sl. (Večernji list, 14. 7. 1989.: 5) Proslava 600. obljetnice Kosovske bitke održala se potom 8. i 9. srpnja i u Kninu u atmosferi zategnutih odnosa između Hrvatske i Srbije. Organizatori proslave bili su Socijalistički savez Hrvatske (SSRNH) i Srpska pravoslavna crkva. Prvi je dan prema službenim organima održana osnivačka skupština Srpskog kulturnog društva „Zora“ za čijeg je predsjednika izabran Jovan Opačić koji je u svom govoru naglasio cilj društva u zaustavljanju “kulturne denacionalizacije i asimilacije srpskog naroda na ovim prostorima.“ Proslava se drugog dana održala uz crkvu Lazarica na Kosovu polju kod Knina na kojoj su pojedine domaće grupe i „mitingaši“ iz Srbije, Bosne i Hercegovine te Crne Gore iskoristili proslavu za promociju srpskih nacionalističkih ciljeva, a ikonografija je bila slična onoj na Gazimestanu. Tijekom govora isticala se ugroženost Srba, a cijela proslava, prema modelu „mitingašenja“ na Kosovu i Vojvodini, imala je za cilj mobilizirati srpsko stanovništvo u Hrvatskoj. Društveno-politički organi u SR Hrvatskoj osudili su nacionalističke ispade na proslavi i pokušaje destabilizacije Hrvatske. Proslava je dobila velik prostor i u novinstvu, a prepucavanja su dodatno zaoštrila međunacionalne odnose. Tijekom ljeta, posebno na jadranskoj obali, zabilježeni su i fizički sukobi na nacionalnoj osnovi. Izvor: Večernji list, 29. 6. 1989.: 4; Večernji list, 17. 7. 1989.: 17. Lit: Barić, 2005: 42-52; Govor Slobodana Miloševića, 2009.	

HPM-96631/1-2	Crna šubara s bedžem srpskih oznaka	Srbija, 1990. (?) kapa: krzno; šivanje; promjer 25,5 cm, v. 31 cm; bedž: papir, željezni lim; tisak u boji, plastificiranje, strojno prešanje; promjer 5,5 cm	Tradicionalna srpska muška kapa stožastog oblika, načinjena od crnog janjećeg krzna s kokardom – okruglim bedžom s motivom srpske trobojnice i križem s četiri ocila. Šubara je dio srpske narodne nošnje. Koristili su je srpski vojnici u Prvom svjetskom ratu, a u Drugom svjetskom ratu četnici. Pojavljuje se ponovno kao dio četničke ikonografije prisutne na srpskim mitinzima organiziranim tijekom 1990. godine u Hrvatskoj te kao sastavni dio uniforme srpskih četničkih paravojnih odreda koji se ponovno aktiviraju tijekom agresije na Republiku Hrvatsku	
HPM-93201	Borbena kaciga JNA	SFRJ, 1980-tih metalna legura, koža, platno; lijevanje, šivanje, lijepljenje; š. 23,7 cm, v. 15 cm, d. 28,3 cm	Borbena kaciga JNA sivomaslinaste boje s otisnutom crvenom zvijezdom petokrakom s prednje strane.	
HPM-98019	Kaciga pripadnika zaštitne mirovne misije UN-a (UNPROFOR)	naručilac Organizacija ujedinjenih naroda, New York, 2. pol. 20. st. metalna slitina: lijevanje; pamučni konac: panama vez; sintetički konac: strojno tkanje; željezo: lijevanje; visina 17 cm, širina 23 cm, dubina 28 cm	Kaciga pripadnika Ujedinjenih naroda („plavih kaciga“) obojena svijetloplavom službenom bojom UN-a. Na pojedinim mjestima oštećena boja. Kaciga svjedoči o slaboj opremljenosti pojedinih nacionalnih jedinica. Ovaj model kacige rabljen je duže vrijeme, 90-tih su ih nosili pripadnici misija i u Hrvatskoj. Na ovoj nedostaje natpis bijelom bojom "UN" te amblem Ujedinjenih naroda. Moguće da su je pripadnici misije sami bojali na terenu.	

HPM-93218	Natpisna ulična tabla	Vinkovci, 20. stoljeće željezni lim; lijevanje, emajliranje, bojanje; 28 x 48 cm	Tabla pravokutnog oblika s natpisom bijelim tiskanim slovima na plavoj pozadini "GLAGOLJAŠKA / ULICA", uokvirena bijelom bordurom. Tabla je probijena metcima.	
HPM-93220_1_2-6	Ostaci spaljenih i oštećenih svezaka knjiga iz Gradske knjižnice i čitaonice Vinkovci	Vinkovci, rujan 1991. papir, željezo; tisak, uvezivanje, lijevanje; knjige: 19,8 x 14,2 cm (i ostaci sa zgarišta)	Knjižnica i cijeli knjižni fond potpuno su izgorjeli u granatiranju grada u noći 16. na 17. 9. 1991. U fondu knjižnice prije razaranja bilo je 75.000 svezaka knjiga, 1.239 svezaka časopisa, 365 dijafilmova te 523 gramofonske ploče ozbiljne glazbe. U Muzeju se čuvaju ostaci zapaljenih knjiga te u cijelosti sačuvane, ali oštećene knjige Divota prašine Vjekoslava Kaleba (1954.) i Posljednja igra Nikole Pulića (1971.) probijene zrnom streljiva koje se zadržalo u koricama. Zanimljivo je da je tema obaju romana Drugi svjetski rat u Dalmatinskoj zagori viđen očima djeteta. Književnik Branimir Donat, potaknut izložbom Vinkovci u ratu održanom u Muzeju grada Zagreba (23. 11. - 6. 12.1991.) gdje su bile izložene te dvije knjige, u članku pod nazivom Metkom na knjige objavljenom u Večernjem listu 27. studenog 1991. među ostalim je napisao: "Ovim librocidom simbolično je ubijena i suvremena hrvaska književnost. (...) Uništiti srce Hrvatske, svijest o samoj sebi, kulturu, pisanu riječ. Ali nedužne knjige pokazale su se i ovom zgodom kao vrlo otporni borci, probijenih grudi one i dalje žive, rekao bih da će živjeti još intenzivnije, jer se njima do kraja demaskira taktika protivnika... ". Tijekom 1991. ukupno je razoreno ili oštećeno 210 knjižnica.	
HPM-33037	Zastava „Knežija“	Zagreb, 1992. svila, pozamenterijska vrpca; ručni rad; 120 x 90 cm	Hrvatska trobojnica s povijesnim hrvatskim grbom i natpisom „KNEŽIJA.“ Zastava je ručni rad majke hrvatskog gardista Siniše Peternela, pripadnika 3. voda s Knežije (dio Zagreba) koji se nalazio u sastavu 161. brigade Marijan Celjak- Sisak OZ - Zagreb. Ova je zastava primjer neslužbene zastave hrvatske vojske i njenih postrojbi u vrijeme njezina formiranja. Bibl: Stoljeće promjena, 2001: 116.	

HPM-33176	Višecijevni bacač tromblonskih mina	„Jelen“, Turopolje, 1991. 600 x 550 x 550 mm; kalibar: 59 mm	Bacač je proizveden krajem 1991. u puškarskoj radionici „Jelen“ iz Turopolja, pod vodstvom Petra Vučetića. Sastoji se od postolja na kojemu je 16 cijevi (jedna nedostaje), povezanih zajedničkim sustavom za napinjanje. Ispaljivanje se obavlja pojedinačno za svaku cijev, a maksimalna brzina za sve cijevi je 20 sekundi. Domet projektila je do 900 metara. Bacač je izrađen u jednom primjerku, a u upotrebi je bio već od travnja 1992. godine. Lit: Čime se branila Hrvatska, 1994: 58-59; Stoljeće promjena, 2001: 117.	
HPM-93578	Oznaka za rukav ZNG RH 1. BRIGADA	neutvrđen, 1991.-1995. tkanina, konac: vezenje, širina 8 cm, visina 10,5 cm		
HPM-93662	Oznaka za rukav 2. BRIGADA ZNG RH GROM	neutvrđen, 1991.-1995. tkanina, konac: vezenje; širina 7,5 cm, visina 10,5 cm		

HPM-98006	Vojna košulja Nikole Šabana	Hrvatska, do 1995. pamučna tkanina; v. 82 cm, š. leđa 53 cm, dulj. rukava 62cm	Vojna košulja Nikole Šabana iz Gospića, pripadnika 1. bojne 9. gardijske brigade „Vukovi.“ Izvedena u četverobojnom maskirnom tisku, dugih je rukava, na prednjem dijelu s dva džepa s poklopcima u visini prsiju, a na ramenom dijelu s naramenicama. Košulja se kopča načinom prekrivne letvice, a širina orukvice regulira se pomoću dva dugmeta. Na nadlaktičnom dijelu rukava prišivene su oznake HV-a i 9. gardijske brigade, kakve su, uostalom, koristili i ostali pripadnici gardijskih brigada tijekom Domovinskog rata. Iznad desnog džepa naziv brigade „VUKOVI“, a iznad lijevog oznaka čina narednika.	
HPM 99439	Pilotsko odijelo stožernog brigadira Rudolfa Perešina		Rudolf Perešin rođen je 25. ožujka 1958. u Jakšincu, općina Gornja Stubica. Do početka Domovinskog rata letio je u sastavu 352. izviđačke avijacijske eskadrile JRZ bazirane u velikoj vojnoj zračnoj luci JNA kod Bihaća. Dana 25. listopada 1991. bježi svojim MiG-om u Austriju, čime izaziva pozornost svjetske javnosti i izjavljuje da on kao Hrvat ne želi pucati u vlastiti narod. Nakon četiri dana vraća se u Hrvatsku i odmah se aktivno uključuje u obranu Hrvatske te poslije postaje i zapovjednikom 1. lovačke eskadrile HRZ i PZO. Pilot Rudolf Perešin poginuo je tijekom vojno-redarstvene operacije Bljesak, nakon što su neprijateljske snage 2. svibnja 1995. godine oborile avion MiG-21 kojim je upravljao. Njegovi posmrtni ostaci vraćeni su Hrvatskoj 4. kolovoza 1997, a 15. rujna 1997. pokopan je na Gradskom groblju Mirogoj. Rudolf Perešin poginuo je kao zapovjednik 21. eskadrile lovačkih aviona 91. Pleso HRZ i PZO-a. Sudjelovao je u svim borbenim operacijama HRZ i PZO-a. Odlikovan je Redom kneza Domagoja s ogrlicom, Redom Nikole Šubića Zrinskog, Redom bana Jelačića, Redom Petra Zrinskog i Frana Krste Frankopana s pozlatom, Redom Stjepana Radića, Spomenicom domovinskog rata i Spomenicom domovinske zahvalnosti za 5 godina. Nositelj je medalja za Iznimni pothvat i Bljesak.	

HPM-93764	„Žute čizme“ vukovarskog branitelja Željka Šandora	Jugoslavenski kombinat gume i obuće „Borovo“, Vukovar, 80-ih god. 20. st. koža, tkanina, guma, metal; šivanje, lijepljenje, utiskivanje; dulj. 28 cm, v. 18 cm; sign. „HERMAN / SURVIVORS“	Muške čizme, gležnjače, izrađene od brušene kože žute boje, s pojačanim gornjim rubom oko gležnja od smeđe kože i debelim gumenim potplatom . S unutrašnje strane podstavljene su žutom tkaninom. Na gumenom potplatu i na vanjskoj strani desne čizme utisnut zaštitni znak marke: „HERMAN / SURVIVORS.“ Čizme su bez vezica, u trošnom stanju (gumeni potplat se raspada). Čizme su pripadale Željku Šandoru, pripadniku 204. vukovarske brigade u kojima je nakon zauzimanja Vukovara odveden u srbijanski logor Sremska Mitrovica, a potom u Vojno-istražni zatvor Beograd. Nakon 9 mjeseci zarobljeništva, razmijenjen je u Nemetinu 14. 8. 1992. Uz čizme, Željko Šandor je u logoru imao ručni sat i maskirnu majicu. U nedostaku službene odore hrvatskih branitelja, uprava tvornice Borovo podijelila je nekoliko tisuća pari žutih čizama pripadnicima ZNG-a i MUP-a, koje je proizvodila po licenci kanadske tvrtke kao obuću za šumarske radnike u Kanadi. Zbog toga su ih zvali „kanađanke“ ili „žute čizme“, zbog njihove žute boje. Nazivale su se i „zengama“ što je bila skraćenica za pripadnika Zbora narodne garde (ZNG). Neprijateljska strana odnosila se iznimno brutalno prema zarobljenim osobama koje su ih nosile. Neki su zbog tih čizama bili ubijeni. (Rehak, 2000:49). Željko Šandor svjedoči da je pri izlascima u dvorište logora redovito izlazio bos, kako mu „žute čizme“ ne bi priskrbile dodatne probleme (studeni 2011.). Dopisnica HTV-a Višnja Mišin prilikom izvještavanja s ekshumacije na Novom groblju u Vukovaru, koja su započela u travnju 1998., u svojoj knjizi bilježi sljedeće: „(...) Hodajući uz taj gotovo stotinu metara dugi rov u kome su tijela žrtava bila položena jedno uz drugo, većina u crnim plastičnim vrećama JNA, pažnju su mi zaokupile žute „Borovo“ čizme, tzv. kanađanke koje su, gotovo nove, stršile s poluistrunulih tijela mrtvih „zengi.“ Te su čizme Srbima bile dovoljan razlog da nekog strijeljaju jer je među njima vladalo mišljenje da „samo najkrvoločniji Hrvati nose takve čizme“ (Mišin, 1998: 106).	
HPM-98010	Borbena kaciga M1 vukovarskog branitelja Zvonimira Mažara	SAD, do 1985. metalna legura, pamučna i sintetička tkanina, koža; lijevanje, šivanje; obujam: 73,5 cm	Borbena kaciga M1 američke proizvodnje koju su tijekom Domovinskog rata često koristili pripadnici hrvatske vojske. Kaciga je maslinastozelena, a preko nje je navučena zaštitna tkanina maskirnog uzorka. Oko zaštitne tkanine nalazi se traka na kojoj je vidljiv, od strane branitelja ručno napisan, simboličan natpis „VU 91“ (Vukovar 1991.). U unutrašnjosti, na kožnom remenu upisani inicijali vlasnika „ZM.“	

HPM-93737	Paket cjelodnevnog obroka za hrvatsku vojsku „HV-1“	Podravka, Koprivnica; Zvečevo d.d, Požega; Pliva – Tvornica farmaceutskih i kemijskih proizvoda, Zagreb, 1993. karton, tisak u boji, lijepljenje; 19,5 x 8 x 13 cm	Bijela pravokutna kutija s otisnutom hrvatskom trobojnicom na poklopcu i šifrom obroka „HV-1“ te datumom proizvodnje 11. 11. 1993. Dnevni menu je otisnut na komadiću papira, a od sadržaja obroka je sačuvano slijedeće: goveđi narezak u konzervi, juneća pašteta, „Kinder lada“ (2 kom), keksi „Koestlin“ u maskirnoj plastičnoj foliji, tzv. „Rambo keksi“ (2 kom), desertna čokolada „Zvečevo“, „Limač“ bomboni s okusom limuna (2 kom), „Ponita“ prašak za vitaminski napitak s prirodnom aromom naranče (2 kom), „Asepsoleta“ maramice za dezinfekciju (3 kom).	
HPM-93549	Šah od kartona, izrađen u srbijanskom logoru	Zvonko Herceg, logor Sremska Mitrovica, Srbija, 19. 11. 1991. – 22. 5. 1992. karton, olovka; rezanje, crtanje, bojenje; ploča: 30 x 28,5 cm; figurice: 32 komada, 2,2 x 2 cm	Šahovska ploča i figure izrađeni su od smeđeg kartona čija su polja i figurice (njih 16) obojeni grafitnom olovkom.	
	Odjeća i predmeti doktorice Vesne Bosanac s kojima se vratila iz zatočeništva iz Srbije			

HPM-93728	Kutija humanitarne pomoći Europske zajednice "ECHO" i Britanskog Crvenog križa	Pošiljatelji: ECHO; Britanski Crveni križ, Velika Britanija, poslije 1992. ljepenka; tisak u boji; 27 x 32 cm, d.: 27 cm	Kartonska kutija u kojoj je poslana humanitarna pomoć u higijenskim potrepštinama s logom organizacije „ECHO“ - Odjela Europske zajednice za humanitarnu pomoć (The Humanitarian Aid Department of the European Commission) ranije poznatijoj pod nazivom The European Community Humanitarian Office). Odjel je osnovan 1992. godine i djeluje s organizacijama partnerima kao što su Crveni križ, Crveni polumjesec, UN i dr. Na kutiji je s prednje strane ispod loga ECHO-a otisnut natpis „DONATED BY// EUROPEAN COMMUNITY HUMANITARIAN OFFICE“, na bočnoj „BRITISH RED CROSS“ koji je pomoć poslao te na stražnjoj strani logo Međunarodne federacije Crvenog križa i Crvenog polumjeseca „INTERNATIONAL FEDERATION OF RED CROSS AND RED CRESCENT SOCIETIES.“	
HPM-89811	Zastava Ujedinjenih naroda s naljepnicama zemalja sudionica Zaštitnih snaga UNPROFOR-a	naručitelj: OUN (Organizacija Ujedinjenih naroda), 1992. - 1993. sintetičko platno, papir, aluminij; strojno šivanje, sitotisak, lijepljenje; 88,5 x 136 cm	Zastava plave boje s bijelim amblemom Organizacije Ujedinjenih naroda uokolo kojega je nalijepljena 31 naljepnica zemalja sudionica mirovne misije - zastave i amblemi kontingenata Nizozemske, Sjedinjenih Američkih Država, Finske, Kenije, Ukrajine, Luksemburga, Irske, Švedske, Nepala, Francuske, Jordana, Norveške, Njemačke, Velike Britanije, Kanade, Gane, Rusije, Čehoslovačke, Poljske, Danske, Novog Zelanda, Islanda, Španjolske, Bangladeša, Kolumbije i Argentine te naljepnica Organizacije UN-a i američke pokretne vojne bolnice „212th Mobile Army Surgical Hospital“ (MASH) koja je djelovala u okviru humanitarne operacije „Operation Provide Promise“52 kao potpora UN vojnika u regiji. Ispod samoga amblema UN-a nedostaje naljepnica s hrvatskim grbom. S lijeve strane bijeli porub s dva metalna prstena kroz koje se provlači uže za vezivanje na jarbol. Zastava se nalazila u glavnom štabu misije Zaštitnih snaga Ujedinjenih naroda u Selskoj cesti u Zagrebu u trenutku kada je UNPROFOR osim na području Republike Hrvatske obavljao zadaće i u susjednoj Bosni i Hercegovini nakon izbijanja rata u proljeće 1992. godine. Lit: Operation, 1996; Operation, 2011.	
P-HPM-96571	Predizborni plakat Koalicije narodnog sporazuma	izdavač: Koalicija narodnog sporazuma,dizajn: Boris Ljubičić, Studio International, fotograf: Petar Dabac, tisak: Grafički Zavod Hrvatske, Zagreb; Zagreb, proljeće 1990. papir; offset tisak;	Na sivoj podlozi fotografirane su raznobojne šahovske figure s jakom sjenom. S njihove desne strane otisnut je dizajnirani logo stranke koji se sastoji od raznobojnih spojenih kvadrata u čija su polja upisana velika bijela slova koja tvore riječ „KOALICIJA“, ispod njega crnim malim slovima otisnut je tekst: „narodnog sporazuma.“ S lijeve stranefigura crnim je slovima oisnut promidžbenitekst: „Glasajte za nas. // Pobijedit će // moderna // HRVATSKA.“ Koaliciju narodnog sporazuma na prvim demokratskim višestranačkim izborima činile su: Hrvatska demokratska stranka (HDS), Hrvatska kršćanska demokratska stranka (HKDS), Hrvatska seljačka stranka (HSS), Hrvatska socijalno-liberalna stranka (HSLS) i Socijaldemokratska stranka Hrvatske (SDSH) te nestranačke osobe, nekadašnje vođe Hrvatskoga proljeća Savka Dabčević-Kučar, Miko Tripalo i drugi.	

		677 x 980 mm		
P-HPM-MRNH-P-285	Plakat „ZA MIR – HRVATSKI UMJETNICI 1991 FOR PEACE - CROATIAN ARTISTS“	Vladimir Gudac; Zagreb, 1991. papir; tisak; 700 x 500 mm	Plakat hrvatskih umjetnika za mir s uvećanom novinskom fotografijom generalpukovnika Blagoja Adžića. Na njegovu nosu nacrtan je zrakoplov. Ispod brade, a na okovratniku tekst „GENERAL JNA BLAGOJE ADŽIĆ“, sasvim dolje crni rub u kojem je po sredini bijelom bojom otisnut naslov plakata, a desno signatura autora. Plakat je nastao u sklopu akcije Hrvatski umjetnici za mir	
P-HPM-MRNH-P-429	Plakat „KRV / ATS / KA!“	Boris Ljubičić, izdavač: Naša djeca, tisak:Turistkomerc, Zagreb, rujan 1991. papir; tisak u boji; 840 x 596 mm; sign.d. l.: „INTERNATIONAL Design: Boris Ljubičić Tisak Printed by TURISTKOMERC Zagreb“; sign. d. d.: „OFFSET NAŠA DJECA	Na crnoj podlozi preko cijelog plakata u tri reda bijelim slovima otisnuta riječ „KRVATSKA“ posuta crvenim mrljama. U znaku uskličnika, u trećem retku, natpis Hrvatska na njemačkom, engleskom, japanskom (?) i francuskom jeziku i godina „1991.“	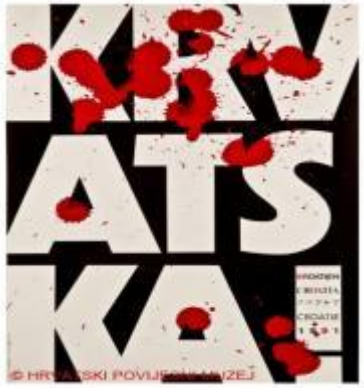

		Rujan 1991.“		
P-HPM-MRNH-P-425	Plakat „OSIJEK / NIKADA / NEĆE / BITI / OCEK“	Predrag Došen, 1991. papir; tisak u boji; 980 x 675 mm; sign. sr.d.: „PORTFOLIO“	Na crnoj podlozi otisnut tekst velikim bijelim tiskanim slovima u pet reda „OSIJEK / NIKADA / NEĆE / BITI / OCEK.“ Riječ „NIKADA“ podvučena crvenom crtom, a ime grada Osijeka ispisano na ćirilici.	
P-HPM-MRNH-P_218-2	Plakat „CROATIA 90 / CROATIA 91 / CROATIA 92“	Dalibor Jelavić, izdavač Muzejsko-galerijski centar, tisak Naša djeca, Zagreb, 1991. Tisak u boji, 490 x 680 mm; sign. d.d.: „TV SPOT-idejno rješenje – Idea: Dalibor Jelavić-ARTRESOR – Režija i animacija – Animation directed by: Tomislav Mikulić-3D Studio – Sinhronizacija –	Na sivo-plavoj pozadini u tri retka otisnut tekst na engleskom jeziku: „CROATIA 90 / CROATIA 91 / CROATIA 92.“ Tekst je otisnut u bojama hrvatske trobojnice, a umjesto slova „O“ u riječi CROATIA“ redom se izmjenjuju znakovi koji obilježavaju značenje datuma: dva crvena kvadrata za proglašenje samostalnosti 1990., crvena mrlja za ratnu stvarnost 1991. i krug od dvanaest žutih petokrakih zvijezda za međunarodno priznanje u 1992. godini. Plakat je „zamrznuta slika“ posljednje sekvence spota autora Dalibora Jelavića (idejno rješenje), Tomislava Mikulića (režija animacije) i Gorana Fuzula (sinkronizacija) koji je prvi put prikazan na Hrvatskoj televiziji 27. rujna 1991. Svojim sadržajem spot upućuje na neposrednu prošlost – najprije se uz tekst CROATIA 90 i hrvatsku himnu Lijepa naša kao glazbene podloge redaju prizori višestranačkih izbora i donošenja akta o samostalnosti Republike Hrvatske, zatim na sadašnjost – tekst CROATIA 91 popraćen je zvukovima rata i prizorima ratne stvarnosti, i na kraju na željenu budućnost – uz prethodna dva teksta pojavljuje se tekst CROATIA 92 uz glazbu Ode radosti iz 9. simfonije Ludwiga van Beethovena. Ova posljednja sekvenca spota bila je potom naknadno otisnuta na razglednice, čestitke i plakate. Spot je jedan od radova umjetnika koji su se odazvali pozivu Komisije za likovnu umjetnost Gradskog fonda za kulturu grada Zagreba početkom rujna 1991. za	

		Dubbing: Goran Fuzul-HTV; Izdavač – Publisher: Muzejsko-galerijski centar – Zagreb – Croatia, 1991. – Tisak – Printed by: Naša djeca“	realizaciju izložbe idejnih rješenja za plakate ili drugih oblika vizualnih poruka na temu Za obranu i obnovu Hrvatske. Radovi su bili izloženi u Umjetničkom paviljonu u Zagrebu od 8. Studenog do 8. prosinca 1991.	
HPM-MRNH-SI-2258	Plakat „VUKOWAR“	izdavač: Klub Vukovaraca, Zagreb, tisak C. P. Grafis, Samobor, 1992. papir; tisak; 325 x 600 mm	Na bijeloj pozadini je otisnut naziv grada „VUKOWAR“ u bojama hrvatske zastave. Između slova O, koje je ispunjeno šahovnicom, i V uzdiže se šaka s uzdignuta dva prsta koji tvore slovo „V“ – simbol pobjede („for Victory“ - engl. za pobjedu), te ujedno i slovo W tako da posljednja tri slova tvore englesku riječ WAR – rat. Vukovarski prognanici organizirali su raznovrsne oblike društvenog i kulturnog života. Prvih dana djelovao je samo Crveni križ Vukovar, koji je imao značajnu ulogu u podjeli humanitarne pomoći i traženju nestalih osoba. Klub Vukovaraca u Zagrebu okupljao je prognanike s područja općine Vukovar i bio je značajno mjesto susreta. Uskoro su osnovani klubovi u još dvadesetak mjesta Hrvatske (Bjelovaru, Đurđevcu, Kumrovcu, Makarskoj, Osijeku, Požegi, Puli, Slatini, Splitu i u drugim hrvatskim gradovima). Posebnu važnost pridavali su apelativnoj djelatnosti i organiziranju dobrovoljnog prikupljanja priloga za obnovu Vukovara. U vrijeme najžešćih razaranja i napada na Vukovar Klub Vukovaraca u Zagrebu tisako je 17. studenog 1991. knjigu VUKOWAR u kojoj je objavljen apel Vukovar – Croatia Aid SOS cijelom civiliziranom svijetu datiran 14. 10. 1991.	

P-HPM-MRNH-P-445	Plakat „VOLIŠ LI / HRVATSKU?“	Boris Ljubičić, 1991. papir; tisak u boji; 980 x 680 mm		
HPM-P-403	Plakat „I MOJ JE / TATA / HRVATSKI VOJNIK“	Ivo Vrtarić, fotografija: Darko Bavoljak, izdavač: War press OGP, Novska, tisak: Sensa; Novska, 1992. papir; tisak u boji; 689 x 467 mm	Mobilizacijski plakat „I moj je tata hrvatski vojnik“ Operativne grupe „Posavina“ – Novska idejom slijedi jedan od najpoznatijih britanskih mobilizacijskih plakata iz Prvog svjetskog rata: Daddy, what did you do in the Great War? Savilea Lumleya	

P-HPM-96561	Plakat „ZA HRVATSKU KAO TIGAR“	Vladimir Kostjuk, Zagreb, 1991. papir; tisak u boji; 670 x 475 mm	Plakat 1. gardijske brigade „Tigrovi”. Na plakatu je pripadnik brigade Ivan Belečetić (rođen u Đakovu 7. rujna 1972.), koji je Tigrovima pristupio 29. srpnja 1991. godine. Kao pripadnik Izvidničke satnije sudjelovao je u borbama na bojištima u zapadnoj Slavoniji, na karlovačkom, velebitskom i dubrovačkom bojištu te u operacijama Maslenica, Ljeto 95 i Bljesak. Poginuo je kod Slunja 6. kolovoza 1995. u oslobodilačkoj operaciji Oluja.	© HRVATSKI POVIJESNI MUZEJ
HPM-93345	Letak Gradskog štaba Civilne zaštite: „Građanima Zagreba“	Ivan Parać, zapovjednik GŠCZ, Zagreb, 19. 7. 1991. papir; tisak; 20,8 x 14,9 cm, sign. d. d.: „ZAPOVJEDNIK / Ivan Parać“	Na papiru pravokutnog formata žućkaste boje otisnut tekst uputa o pripremama i ponašanju građana u slučaju napada iz zraka na grad Zagreb. U pozadini teksta otisnut međunarodni znak civilne zaštite (istostraničan trokut tamnoplave boje). U potpisu Ivan Parać. Ivan Parać bio je potpredsjednik Izvršnog vijeća Skupštine Grada, a od sredine 1991. zapovjednik Gradskog štaba Civilne zaštite grada Zagreba. Zagrebu, kao glavnom gradu Hrvatske, najveća je opasnost prijetila od velikog broja vojarni i vojnih objekata JNA smještenih u samom gradu i njegovoj okolici. Na području grada Zagreba i okolice bila su smještena 52 vojna objekta JNA. Oružani napadi JNA na grad i okolicu intenzivirali su se nakon Odluke o blokadi svih vojnih objekata u Hrvatskoj od 13. rujna 1991. Tada su posebno bila ugrožena područja Novog Zagreba, Pešćenice i Dubrave u čijoj su blizini bile najveće vojarne „Maršalka“ i „Borongajka“, a granatirana su i naselja oko baze JNA na zagrebačkom aerodromu Pleso. Zračni i raketni napadi na grad i okolicu započinju od 1. listopada 1991. objavom ultimatuma JNA kojim je započeo opći napad na gradove u Hrvatskoj. Tada je raketiran i onesposobljen radioteleviziski toranj Sljeme (4. 10. 1991.), a potom su u znak odmazde na dan pada vojarne u Samoboru raketirana i rubna gradska naselja i samoborsko područje. Pritom je poginula prognanica iz Vukovara. Dan prije proglašenja neovisnosti Hrvatske, 7. 10. 1991. raketirani su Banski dvori i zagrebački Gornji grad, sjedište Vlade RH. Do kraja godine još su nekoliko puta bila raketirana rubna gradska područja i zgrada	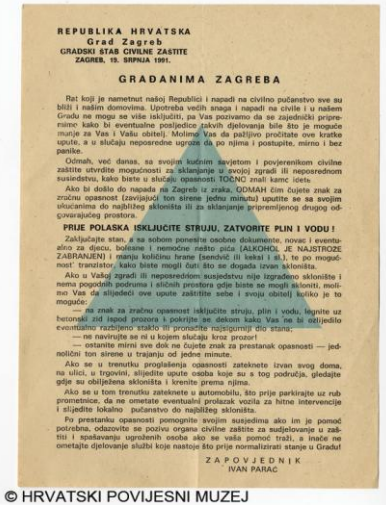 REPUBLIKA HRVATSKA Grad Zagreb GRADSKI ŠTAB CIVILNE ZAŠTITE ZAGREB, 19. SRPNJA 1991. GRAĐANIMA ZAGREBA Rat koji je nametnut našoj Republici i napadi na civilno pučanstvo sve su bliži i našim domovima. Upotreba većih snaga i napadi na civile i u našem Gradu ne mogu se više isključiti, pa Vas pozivamo da se zajednički pripremimo kako bi eventualne posljedice takvih djelovanja bile što je moguće manje za Vas i Vašu obitelj. Molimo Vas da pažljivo pročitate ove kratke upute, a u slučaju neposredne ugroze da po njima i postupite, mirno i bez panike. Odmah, već danas, sa svojim kućnim savjetom i povjerenikom civilne zaštite utvrdite mogućnosti za sklanjanje u svojoj zgradi ili neposrednom susjedstvu, kako biste u slučaju opasnosti TOČNO znali kamo ići. Ako bi došlo do napada na Zagreb iz zraka, ODMAH čim čujete znak za zračnu opasnost (izvijajući ton sirene jedna minuta) uputite se sa svojim ulucanima do najbližeg skloništa ili za sklanjanje pripremljenog drugog odgovarajućeg prostora. PRIJE POLASKA ISKLJUČITE STRUJU, ZATVORITE PLIN I VODU ! Zaključajte stan, a sa sobom ponesite osobne dokumente, novac i eventualno za djecu, bolesne i nemoćne nešto pića (ALKOHOL JE NAJSTROŽE ZABRANJEN) i manju količinu hrane (sendvič ili keksi i sl.), te po mogućnost tranzistor, kako biste mogli čuti što se događa izvan skloništa. Ako u Vašoj zgradi ili neposrednom susjedstvu nije izgrađeno sklonište i nema pogodnih podruma i sličnih prostora gdje biste se mogli skloniti, molimo Vas da slijedeći ove upute zaštitite sebe i svoju obitelj, koliko je to moguće: — na znak za zračnu opasnost isključite struju, plin i vodu, legnite uz betonski zid ispod prozora i pokrijte se dekom kako Vas ne bi ozljedilo eventualno razbijeno staklo ili pronađite najsigurniji dio stana; — ne navirujte se ni u kojem slučaju kroz prozor! — ostanite mirni sve dok ne čujete znak za prestanak opasnosti — jednolični ton sirene u trajanju od jedne minute. Ako se u trenutku proglašenja opasnosti zateknete izvan svog doma, na ulici, u trgovini, slijedite upute osoba koje su s tog područja, gledajte gdje su obilježena skloništa i krenite prema njima. Ako se u tom trenutku zateknete u automobilu, što prije parkirajte uz rub prometnice, da ne ometate eventualni prolazak vozila za hitne intervencije i slijedite lokalno pučanstvo do najbližeg skloništa. Po prestanku opasnosti pomognite svojim susjedima ako im je pomoć potrebna, odazovite se pozivu organa civilne zaštite za sudjelovanje u zaštiti i spašavanju ugroženih osoba ako se vaša pomoć traži, a inače ne ometajte djelovanje službi koje nastoje što prije normalizirati stanje u Gradu! ZAPOVJEDNIK IVAN PARAĆ © HRVATSKI POVIJESNI MUZEJ

			Hrvatske televizije na Prisavlju (8. 11. 1991.). Posljednji i najpogubniji zračni napad na grad bio je izvršen 2. i 3. svibnja 1995., kada je u znak odmazde nakon vojno-redarstvene operacije Bljesak Zagreb raketiran zabranjenim kazetnim bombama. U takvim okolnostima život u gradu, koji nije bio izravno ugrožen od srpske agresije, obilježile su uzbune i odlasci u skloništa, a noću zamračenja grada. Grad je bio oblijepljen trakama, cestovni prolazi i izlazi iz vojarni JNA blokirani ježevima (prepreke izrađene od željezničkih ili tramvajskih šina), a podrumi zaštićeni vrećama s pijeskom. Bila je to ratna svakodnevica građana gotovo cijele Hrvatske. O sigurnosti i spašavanju građana i materijalnih dobara te poduzimanju mjera zaštite brinula je Civilna zaštita . Njezin se rad organizirao u sklopu obrane grada, a uključivao je pripremu skloništa i organizaciju sklanjanja ljudi tijekom uzbuna, izradu planova za sklanjanje, postavljanje odgovarajućih znakova, izradu pravilnika ponašanja u skloništima, zaštitu podrumskih prostorija vrećama s pijeskom, nadziranje i provedbu zaštitnih mjera zamračenja kako noćna rasvjeta ne bi poslužila kao orijentacija neprijateljskom zrakoplovstvu, te informiranje građana o pravilima ponašanja prilikom opće i zračne opasnosti kao i o postupanju pri nailasku na neeksplodirana eksplozivna sredstva. U tu su svrhu bile snimane TV emisije i tiskane brošure i plakati.	
P-HPM-MRNH-SI-2272	Letak „SAČUVAJMO MIR I SIGURNOST U NAŠEM GRADU I NAŠOJ OKOLICI“	Ministarstvo unutarnjih poslova Republike Hrvatske, Karlovac, 1992. papir; tisak; 14,6 x 20,7 cm	Na bijelom papiru plavim otisnut tekst, na zaglavlju lijevo otisnut shematizirani prikaz karlovačke utvrde („zvijezde“) unutar koje je golubica i prekrižena ručna bomba. Informativno-propagandni letak Ministarstva unutarnjih poslova RH upućen je građanima grada Karlovca koje se poziva na održavanje reda i mira u gradu te apelira protiv miniranja i uništavanja napuštene imovine kao namirivanje duga koji su „načinili neki naši bivši sugrađani otišavši na stranu divljih hordi.“ Građane se poziva da svaku takvu uočenu kriminalnu radnju prijave policiji. Agresija na Hrvatsku i ratno stanje doveli su do pogoršanja stanja javne sigurnosti i porasta različitih oblika nasilja i kriminala na područjima pod nadzorom hrvatskih vlasti. Tijekom ljeta i jeseni 1991. dio Srba napustio je veće gradove, posebno one blizu bojišta, Karlovac, Sisak, Zadar, Gospić, Osijek, Vinkovce pa i Zagreb. Odlazili su na područje koje nadziru pobunjeni Srbi, ili u Bosnu i u Srbiju, što zbog neprihvaćanja legalno izabrane hrvatske vlasti, a što zbog straha i osjećaja nesigurnosti. Nasilno ponašanje je s jedne strane bilo potpirivano srbijanskom promidžbom, a s druge strane poticanjem nepovjerenja prema srpskom stanovništvu od strane pojedinih hrvatskih medija, te demoliranjem i uništavanjem imovine u vlasništvu Srba i njihovim otpuštanjem s radnih mjesta. Najradikalniji primjer odnosa prema Srbima u Hrvatskoj bila su ubojstva srpskih civila ili zarobljenih vojnika, dijelom pojedinačna, a dijelom i u skupinama, te vršenje	

			osvete nad građanima za koje se smatralo da pomažu srpsku stranu. Gotovo 200.000 Srba iselilo se iz područja pod nadzorom hrvatskih vlasti, a uništeno je između 2000 i 3000 kuća čiji su vlasnici bili Srbi.	
HPM-93195	„APEL ZA POMOĆ SABORSKOM“	Željka Zatezalo, tajnica Crvenog križa Hrvatske Općinske organizacije Ogulin, Ogulin, 9. 11. 1991. kopija; papir, strojopis; 29 x 21 cm	Apel je upućen dr. Nenadu Javorniku, izvršnom predsjedniku Crvenog križa Hrvatske (danas Hrvatski Crveni križ) u Zagrebu, s namjerom da se proslijedi dalje. Traži se hitna pomoć za evakuaciju mjesnog stanovništva, za oko 1600 civila, koje se sklonilo u selo Saborsko, u Karlovačkoj županiji. Navodi se da je Saborsko u okruženju od 15. 8. 1991. i da se od tada ništa ne poduzima, iako su pozivi za pomoć odaslani i međunarodnoj organizaciji „Liječnici bez granica.“ Ističe se da je Saborsko bez mogućnosti dostave hrane, lijekova i sanitetskog materijala. Na kraju se navodi da su u obližnjoj šumi pripadnici MUP-a naišli na dvadeset leševa civila koji su vjerojatno bježali iz okolnih sela prema Saborskom. Nekoliko dana nakon slanja dopisa, Saborsko je bilo osvojeno i potpuno uništeno. U optužnici Međunarodnog kaznenog suda za bivšu Jugoslaviju (International Criminal Tribunal for the Former Yugoslavia – ICTY) protiv Slobodana Miloševića navodi se da su 12. studenoga 1991. godine „pripadnici JNA, "Martićeve policije" i Teritorijalne obrane ušli u selo Saborsko, gdje su „ubili najmanje dvadeset hrvatskih civila“ te da je poslije toga „selo sravnjeno sa zemljom.“ U prilogu optužnice „Dodatak I“ navode se imena 28 žrtava uz troje neidentificiranih.	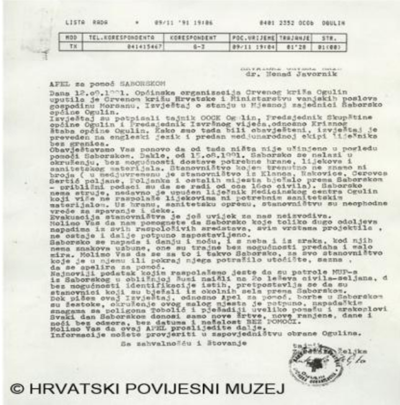

LISTA RADA * 09/11 '91 19:06 8401 2352 OCCb OGULIN

MOD	TEL.KORESPONDENTA	KORESPONDENT	POC.VRIJEME	TRAJANJE	STR.
TX	041415467	6-3	09/11 19:04	01'28	01(00)

dr. Nenad Javornik

APEL za pomoć SABORSKOM

Dana 12.09.1991. Općinska organizacija Crvenog križa Ogulin uputila je Crvenom križu Hrvatske i Ministarstvu vanjskih poslova gospodinu Morsanu, Izvještaj o stanju u Mjesnoj zajednici Saborsko općine Ogulin.
Izvještaj su potpisali tajnik OOCK Ogulin, Predsjednik Skupštine općine Ogulin i Predsjednik Izvršnog vijeća,odnosno Kriznog štaba općine Ogulin. Kako smo tada bili obavješteni, izvještaj je preveden na engleski jezik i predan medjunarodnoj ekipi liječnika bez granica.
Obavještavamo Vas ponovo da od tada ništa nije učinjeno u pogledu pomoći Saborskom. Dakle, od 15.08.1991. Saborsko se nalazi u okruženju, bez mogućnosti dostave potrebne hrane, lijekova i sanitetskog materijala. Stanovništvo kojem trenutno ne znamo ni broja (u medjuvremenu je stanovništvo iz Klanca, Rakovice, Cerovca Sertić poljane, Poljanke i ostalih mjesta bježalo prema Saborskom - približni podaci su da se radi od oco 1600 civila). Saborsko nema struje, nedavno je upućen liječnik Medicinskog centra Ogulin koji više ne raspolaže lijekovima ni potrebnim sanitetskim materijalom. Uz hranu, sanitetsku opremu, stanovništvu su neophodne vreće za spavanje i deke.
Evakuacija stanovništva je još uvijek za nas neizvodiva.
Molimo Vas da nam pomognete da Saborsko koje toliko dugo odoljeva napadima iz svih raspoloživih sredstava, svim vrstama projektila , ne ostaje i dalje potpuno zapostavljeno.
Saborsko se napada i danju i noću, i s neba i iz zraka, kod njih nema znakova uzbune, one su trajne bez mogućnosti predaha i malo mira. Molimo Vas da se za to i takvo Saborsko, za svo stanovništvo koje je u njemu ili pokraj njega potražilo utočište, sazna , da se apelira za pomoć.
Najnoviji podatak kojim raspolažemo jeste da su patrole MUP-a iz Saborskog u obližnjoj šumi naišli na 20 leševa civila-seljana, d bez mogućnosti identifikacije istih, pretpostavlja se da su stanovnici koji su bježali iz okolnih sela prema Saborskom.
Dok pišem ovaj Izvještaj, odnosno Apel za pomoć, borbe u Saborskom su žestoke, okruženje ovog malog mjesta je potpuno, napadačkim snagama sa poligona Tobolić i pješadiji uveliko pomažu i zrakoplovi Svaki dan Saborskom donosi samo nove žrtve, nove ranjene, dane i noći bez odmora, bez datuma i nažalost BEZ POMOĆI.
Molimo Vas da ovaj APEL proslijedite dalje.
Informacije možete provjeriti u zapovjedništvu obrane Ogulina.

Sa zahvalnošću i štovanje

tajnik
[illegible] Željka
[illegible]

© HRVATSKI POVIJESNI MUZEJ

HPM-93196_42	Apeli i prosvjedi dr. Vesne Bosanac	Vesna Bosanac, Medicinski centar Vukovar, Vukovar, 20. 10. 1991. – 19. 11. 1991. kopija; papir; rukopis, strojopis, faksiranje; 29 x 21 cm, 56 listova; hrvatski i engleski jezik; sign. d.d.: „dr. Bosanac Vesna“	Kopije apela i prosvjeda u formi faksa i isprinta telefonskih poruka koje je dr. Vesna Bosanac slala iz vukovarske bolnice u listopadu i studenom 1991. godine, u vrijeme najžešćih napada na Vukovar. Na zaglavlju faksiranih poruka nalazi se naziv i adresa institucije: „MEDICINSKI CENTAR VUKOVAR/...“ s logom institucije. Poruke su najvećim dijelom faksirane uredu Promatračke misije Europske zajednice u hotel „I“ u Zagrebu, a preko Misije upućene na adrese međunarodnih organizacija i državnika: dr. Christophera Bessea i Wilna Van Aartsena iz organizacije „Liječnici bez granica“, predsjedavajućeg Konferencije o bivšoj Jugoslaviji Lorda Petera Carringtona, predsjednika Ministarskoga vijeća Europske zajednice Hansa van den Broeka, britanskog premijera Johna Majora, američkog predsjednika Georgea W. Busha, talijanskog predsjednika Francesca Cossige, njemačkog kancelara Helmuta Kohla, njemačkog ministra vanjskih poslova Hansa Dietricha Genschera, australskog premijera Roberta Jamesa Lee Hawkea, nizozemskog veleposlanika i posebnog izaslanika Europske zajednice Henryja Wijnaendtsa, Ujedinjenih naroda, zatim su adresirani na Ured predsjednika RH, ministra zdravstva Andriju Hebranga, generala Antuna Tusa (načelnika Glavnog stožera HV-a) te zapovjednika JNA, Andriju Rašetu i admirala Stanu Broveta. Pojedini faksevi i telefonski izvještaji izravno su odaslani „Obrani Vukovara“, Uredu predsjednika RH i majoru JNA Vladimiru Rajtaru. Prijepisi pojedinih poruka primljeni telefonskim putem izvršeni su u Centru pošta Osijek HPT-a. Većina poruka prevedena je na engleski jezik. Dvije poruke u rukopisu poslane su Međunarodnoj misiji za konvoj pomoći ranjenicima i civilima Vukovara s uputama i zahtjevima u organiziranju evakuacije planirane 12. listopada 1991. U daljnjim se porukama, pisanim na pisaćem stroju, gotovo svakodnevno od 20. listopada do 19. studenoga 1991. izvještava o broju stradalih, jačini i opsegu napada na bolnicu, teškim uvjetima rada u bolnici, nedostatku lijekova i vode, stradavanju i ugroženosti djece, žena, civila i medicinskog osoblja te se neprekidno apelira za hitnim prekidom vatre i deblokadom Vukovara. Na dan pada grada, 18. 11. 1991., poslano je pet telefonskih poruka, „hitni prosvjedi“ u 8:50, u 10:10, prosvjed u 12:35 potpisuju dr. Vesna Bosanac i povjerenik hrvatske Vlade Marin Vidić-Bili, te u 15:40 i 16:55. Posljednja telefonska poruka poslana je iz bolnice 19. 11. 1991. u 9:01. Doktorica Vesna Bosanac bila je pedijatrica u vukovarskoj bolnici kada je izabrana za ravnateljicu Ratne bolnice Vukovar u srpnju 1991. Gotovo je svakodnevno slala izvještaje i apele za pomoć i spas ranjenika, te prosvjede zbog granatiranja i razaranja bolnice Promatračkoj misiji EZ-a u Zagrebu koju je molila da se ove poruke proslijede europskim i svjetskim dužnosnicima. Do 15. studenog iz bolnice je mogla slati fakseve, a do kraja, dok nije zarobljena, slala je telefonske poruke. Neki od apela sačuvani su u kopijama. Originale kao i cjelokupnu medicinsku	

			dokumentaciju iz bolnice je oduzela Jugoslavenska narodna armija prilikom preuzimanja bolnice 20. studenoga 1991. Dr. Vesna Bosanac tada je odvedena iz bolnice u logor Sremska Mitrovica u Srbiji, a potom u Vojno-istražni zatvor u Beogradu. Puštena je, zajedno sa svojim suprugom, prilikom razmjene zarobljenika 10. prosinca 1991. Nakon izlaska iz logora nastavila je pisati apele. Putovala je u London, Pariz i Bruxelles, isprva s Bedemom ljubavi, te državnicima i političarima osobno svjedočila o stradanju vukovarske bolnice i Vukovara. Završetkom mirne reintegracije hrvatskog Podunavlja vratila se u Vukovar kao ravnateljica Medicinskog centra Vukovar. Više puta je svjedočila pred Međunarodnim kaznenim sudom za bivšu Jugoslaviju u Den Haagu o zločinima počinjenima nad vukovarskom bolnicom i ranjenicima. Dr. Vesna Bosanac postala je heroinom Vukovara i simbolom humanosti	
HPM-93531_av	Popis zarobljenika i raspored rada u srbijanskom logoru Manjača	Boris Zadravec, logor Manjača, 13. 9. 1991. – 9. 11. 1991. papir, kemijska olovka; rukopis; 28,3 x 20,2 cm, 1 list (obostrano)	Popis je u logoru sastavio Boris Zadravec iz Čakovca, zapovjednik rezervnog sastava MUP-a RH i zapovjednik brigade "Zagreb 8", zarobljen 12. 9. 1991. u Hrvatskoj Kostajnici te zatočen u logoru Manjača do 9. 11. 1991. Na popisu se nalaze 72 osobe, pripadnici djelatnog i pričuvnog sastava MUP-a. Na drugoj strani skicirana je tablica u koju su se upisivala radna zaduženja logoraša po danima. Uz imena pojedinih logoraša upisane su skraćenice za pojedine vrste poslova koje su „dobrovoljno" (rad ili batine) obavljali u logoru: „k" za vađenje krumpira, „o" za čuvanje ovaca, „šp" za rad u šumi popodne, „r" za kopanje rovova, „Ka" za rad u kasarni te „s" za čišćenje snijega. Četiri logoraša bila su zadužena za rad u kuhinji. Izvor: Sjećanje sudionika zatočenih u Manjači, 1992. (Dokumentacija HPM-a); Razgovor djelatnika HPM-a s Borisom Zadravcem, HPM, Zagreb, studeni 2011. Lit: Štefanac, 1996: 104.	
HPM-93517_av	"Kalendar nadanja" načinjen u logoru Sremska Mitrovica	Stefan Kenigskneh Vladimir Kenigskneht, logor Stajićevo, logor Sremska Mitrovica, Srbija, 18. 11. 1991. – 26. 4. 1992. papir, kemijska olovka; rezanje, lijepljenje, rukopis; 21,4 x 9,3 cm	Kalendar je načinjen na komadu presavijenog papira koji je sa stražnje strane slijepljen dijelovima papirnate ambalaže paštete proizvedene u Sremskoj Mitrovici. Kalendar obuhvaća vremensko radzoblje od 18. 11. 1991. do 26. 4. 1992. Neki dani su posebno označeni, kao npr. 2. 12. 1991. kada su otac i sin iz logora Stajićevo kraj Zrenjanina u Srbiji prebačeni u Kazneno-popravni dom Sremska Mitrovica te 27. 3. 1992., dan kada su pušteni iz logora. U koloni sa strane brojeni su dani njihova zatočeništva. Izbrojeno je 125 dana.	

HPM-93511_av HPM-9311_rv	Poruka Crvenog križa	izdavač: Međunarodni odbor Crvenog križa, rujan 1991., pošiljatelj: Vladimir Kenigskneht, logor Stajićevo, Srbija, 2. 12. 1991. papir, olovka; tisak, rukopis; 20,9 x 14,7 cm	List ispunjenog obrasca s naslovom Poruka Crvenog križa s i amblemom Međunarodnog odbora Crvenog križa u Ženevi u zaglavlju, tiskan na francuskom, srpskom i hrvatskom jeziku. Na prednjoj strani obrasca pod brojevima od 7. do 12. traže se podaci o pošiljatelju i primatelju poruke (ime, prezime, datum rođenja, spol, ime i prezime oca i adresa stanovanja), a na poleđini je mjesto za poruku, te datum i potpis podnositelja. Poruku šalje Vladimir Kenigskneht iz logora Stajićevo 2. 12. 1991., a upućena je Vesni Königsknecht u Zagreb. Tekst poruke: "TATA I JA SMO DOBRO NALAZIMO SE U VOJNOM ZATVORU U STAJIĆEVU KRAJ ZRENJANINA. MOLIM TE DA POKUŠAŠ PRONAĆI MAMU I SEKU. OBAVIJESTI OSTALE DA SMO ŽIVI I ZDRAVI. PUNO TE POZDRAVLJA BRAT VLADIMIR"	
HPM-93410	Pismo „Draga Vesna, Fredi i svi u kući!"	Marinka, Melbourne, Australija, 16. 12. 1991. kopija; tisak, rukopis, fotokopiranje; 29,6 x 21 cm; hrvatski jezik	Na središnjem dijelu papira kopirana četiri članka izrezana iz iseljeničkih novina pod naslovima: „Pomoć Zagoraca i Metkovčana“, „Avioni Croatia Airlinesa polijeću iz Graza“, „Protestni skup australskih Hrvata“ i „Useljavanje u Australiju“, a uokolo njih rukom pisana poruka. Pismo je upućeno rodbini u Hrvatskoj iz Melbournea. U odabranim člancima, izrezanim iz raznih iseljeničkih novina, obavještava se o djelatnosti iseljeništva iz Australije u organiziranju humanitarne pomoći i davanju potpore za međunarodno priznanje Hrvatske. U pismu se navodi kako hrvatsko iseljeništvo pomaže domovini u vidu prikupljanja novčanih sredstava, te slanja odjeće i hrane. „...Svi daju svega. Svaki petak vozimo pun auto. Ja pravim torte „za djecu Hrvatske“ i prodaju se na Hrvatskom pikniku 9 za 1300 dolara. Onda znate kako ljudi daju sve za našu Domovinu...“ Također se ističe popularnost pjesme Tomislava Ivčića Stop the War in Croatia koja je u Melbourneu "na top-listi od 1-10".	

HPM-96554	Obavijest o akciji sakupljanja dobrotvornih priloga	izdavač: Župni „Caritas”, Vrbovsko, studeni 1991. (?) papir; rukopis; 68 x 59,5 cm	Rukom ispisan tekst poziva građane mjesne zajednice Vrbovsko na sudjelovanje u dobrotvornoj akciji prikupljanja priloga župnog Caritasa koja će se održati 16.-17. XI. (godina nije upisana, vjerojatno je 1991.). Rednim brojevima od 1 do 6 navodi se što se prikuplja: trajna hrana, dječja hrana, dječji zimski odjevni predmeti, zimski odjevni predmeti za odrasle,toaletni pribor i novčani prilozi. Na kraju je obavijest da će sva domaćinstva biti posjećena te potpis organizatora akcije „ŽUPNI ‘CARITAS’ / VRBOVSKO”. Župni Caritas Vrbovsko – sv. Ivan Nepomuk djeluje pod Caritasom Riječke nadbiskupije i dio je Hrvatskog Caritasa. Hrvatski Caritas je krajem 1993. Pokrenuo akciju uspostavljanja kumstva obitelji s brojnom djecom, hendikepiranom djecom i djecom poginulih branitelja. Pomoć se posebno prikupljala na svjetski dan selilaca i izbjeglica koji se u Hrvatskoj obilježava na blagdan Svete Obitelji (nedjelja između Božića i Nove godine) i slavi kao Iseljenički dan, kada Crkva poziva zajednicu na solidarnost u pružanju pomoći i potpore izbjeglima	
HPM-95097	Apel za mir u Hrvatskoj s potpisima nobelovaca	Pošiljatelj: Max-Planck-Institut für Biochemie, Martinsried, Njemačka, 13. 11. 1991., 25. 11. 1991., 28. 11. 1991., 5. 12. 1991. kopija; računalni ispis, rukopis, faksiranje; 29,5 x 21 cm, 8 listova; engleski jezik	Na telefaks adresu Instituta Ruđer Bošković u Zagrebu u razdoblju od 13. 11. do 5. 12. 1991. slani su potpisi nobelovaca koji su se odazvali akciji Apel za mir u Hrvatskoj. Uz potpise nobelovaca poslan je i obrazac dopisa datiran 25. 11.1991., koji je prof. dr. Robert Huber iz Max-Planck-Institut für Biochemie u Martinsriedu kraj Münchena slao na različite adrese obavještavajući javnost o inicijativi i apelu nobelovaca. Na poticaj apela američkog nobelovca Linusa Paulinga upućenog svjetskim vladama 23. rujna 1991. godine, akciju supotpisivanja Apela za mir u Hrvatskoj pokrenula je dr. Greta Pifat-Mrzljak s Instituta Ruđer Bošković u Zagrebu. U listopadu 1991. godine obratila se njemačkim nobelovcima prof. Manfredu Eigenu iz Max-Planck-Institut für Biophysikalische Chemie u Göttingenu i prof. dr. Robertu Huberu iz Max-Planck-Institut für Biochemie u Martinsriedu. Akcija je trajala do veljače 1992., do kada je apel potpisalo 127 nobelovaca. Apel za mir u Hrvatskoj s potpisima 81 nobelovca otisnut je na plakatu br. 21 iz ciklusa plakata HELP! STOP THE WAR IN CROATIA u izdanju Hrvatskog informativnog centra. Apel je također, uz pomoć hrvatskog iseljeništva, bio objavljen i u New York Timesu 14. siječnja 1992., uoči međunarodnog priznanja Hrvatske. Institut Ruđer Bošković i njegovi suradnici razaslali su više od 13 tisuća pisama i apela na adrese znanstvenika, znanstvenih institucija, političara, vlada i raznih javnih medija. Svoju djelatnost Institut je objavio u knjizi Znanstvenici protiv rata u Hrvatskoj na engleskom jeziku.	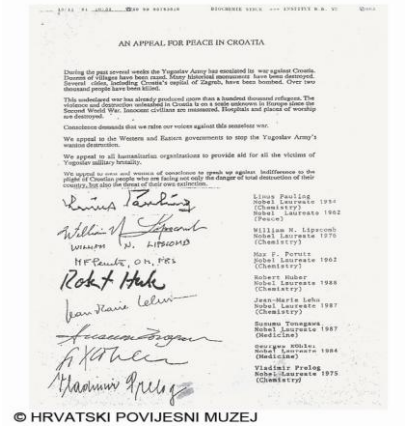

HPM-93372	Propusnica za kretanje u svrhu obavljanja poljoprivrednih radova na okupiranome teritoriju RH	JNA, Komanda grada Iloka, potpukovnik Dušan Madžarev, komandant mjesta Ilok, Ilok, 12. 3. 1992. papir, kemijska olovka, tinta; strojopis, fotokopiranje, rukopis, otiskivanje; 14,8 x 21,1 cm	Na bijelom papiru tekst ispisan strojopisom i nadopunjen podacima kemijskom olovkom. Propusnica glasi na ime Mišić Marka iz Šarengrada, kojemu se omogućuje obavljanje poljoprivrednih radova traktorom u razdoblju od 12. 3. 1992. do 31. 3. 1992. Dokument ovjeren okruglim pečatom: "JNA / KOMANDA GRADA / ILOK" s potpisom potpukovnika Dušana Madžareva, „komandanta mjesta Ilok.“	
F-II-10.245	Hrvatski domovinski rat : 1991-1993	Marinko Ogorec. - Opatija : "Otokar Keršovani", 1994.	Knjiga je napisana kao osobno viđenje Domovinskog rata iz perspektive jednog sudionika. Autor s određene vremenske distance raščlanjuje uzroke i tijek događanja u hrvatsko-srpskom sukobu, usredotočujući se prije svega na njegovu vojno-strategijsku dimenziju. U knjizi se na pristupačan način daje pregled značajnijih operacija i bojeva vođenih u ratu.	
F-II-10.376	Priče iz Vukovara	Siniša Glavašević. - Zagreb : Matica hrvatska, 1992.	Knjiga, koja je objavljena posmrtno, sastavljena je od toplih priča o temeljnim ljudskim vrijednostima koje je Siniša Glavašević čitao slušateljima radija opkoljenoga grada. Ove lirske priče jedini su sačuvani literarni pokušaji Siniše Glavaševića.	
F-II-10.516	Hrvatska - država stvorena u ratu	Marcus Tanner ; s engleskoga prevela Daša Drndić. - Zagreb : Barbat : Hrvatska sveučilišna naklada : Hrvatski institut za povijest, 1999.	Knjiga je rezultat autorovog nastojanja da ljudima s engleskog govornog područja približi zemlju koja njima još uvijek nije dovoljno poznata, uočivši njen strateški položaj, ali i povijesno, kulturno i umjetničko nasljeđe. Namjera autora je bila pisati o ratu devedesetih, ali da bi pojasnio uzroke tog rata, krenuo je u prošlost, počevši s prvim hrvatskim banovima u srednjem vijeku sustavno predočivši i promišljajući tisućljetnu hrvatsku povijest u ozračju europskog duha.	

F-II-6920	Hrvatska i veliko ratište : međunarodne igre na prostoru zvanom bivša Jugoslavija	Davor Domazet Lošo. - Zagreb : Udruga sv. Jurja, 2002.	U knjizi su iznesena autorova strategijska promišljanja odlučujućih ratnih događanja (Bljesak, Oluja) na velikom ratištu (veći dio Hrvatske i Bosne i Hercegovine). Dana je raščlana i događaja na terenu, i geneze sukoba, i uloge međunarodne zajednice, i geopolitičkih interesa i ambicija velikih (i nešto manjih) sila.	
F-II-10.641	"Nebeska Srbija" u Hrvatskoj : mit, zbilja, oprost, zaborav, obnova	Nenad Piskač. - Zaprešić : Grafički studio, 2005.	Knjiga se bavi srpskom pobunom u Hrvatskoj u razdoblju od 1991. do 1995. godine te na temelju izvornih dokumenata tzv. Republike Srpske Krajine nastoji razotkriti svjetonazorsko-ideološku, političku, normativnu i organizacijsku strukturu te paradržave. Središnji dio knjige čine dokumenti i izvori tzv. RSK, dosad u većem broju nepoznati široj javnosti.	
F-II-10.696	Gotovina : stvarnost i mit	Ivica Đikić, Davor Krile, Boris Pavelić. - Zagreb : Novi Liber, 2010.	Knjiga govori o glavnim odrednicama života generala Ante Gotovine. Autori podastiru podatke o njegovu životu i boravku u inozemstvu, opisuju organiziranje prvih vojnih akcija za oslobađanje Hrvatske te na kraju izlažu gledišta o vojno-redarstvenoj akciji "Oluja". Knjiga također sadrži podatke o društvenoj, političkoj i ekonomskoj uključenosti vojnih starješina u civilni život.	
F-II-6611	Hrvatske ratne štete	Mate Pavković. - Zagreb : Defimi, 1997.	Knjiga se bavi problematikom hrvatskih ratnih šteta koje su nanesene velikosrpskom agresijom. Štete o kojima autor govori počinjene su najtežih ratnih godina - 1991. i 1992. godine. Osim o agresiji na Hrvatsku i hrvatskim ratnim štetama, knjiga govori i o ratovima i ratnim štetama općenito, o naknadi ratnih šteta (reparaciji) te o politici obnove.	
F-II-6711	Nedovršeni mir : izvještaj Međunarodne komisije za Balkan	Leo Tindemans ... [et al.] ; [preveo s engleskoga Mijo Pavić]. - Zagreb : Hrvatski helsinški odbor za ljudska prava ; Sarajevo : Pravni centar FOD	Riječ je o izvještaju Međunarodne komisije za Balkan koja se prije svega bavila dijagnozom epicentra konflikta na Balkanu (Bosna, hrvatsko-srpski odnosi, Kosovo), "uzrocima rata". Donosi se prikaz stavova EU-a, SAD-a, Rusije i UN-a u odnosu na rat u Hrvatskoj, a poslije i na rat u Bosni i Hercegovini.	

		BiH, 1997.		
F-III-785	Suzama do istine	[glavni urednik Vlado Horvat]. - Zagreb : "Vukovarske majke", udruga roditelja i obitelji zarobljenih i nasilno odvedenih hrvatskih branitelja, 1999.	Druga knjiga iz trilogije o traženju zatočenih i nestalih hrvatskih branitelja i civila je dokument o rezultatima traženja, ekshumacije i identifikacije na području Vukovarsko-srijemske županije, zaključno s 31. ožujkom 1999. godine.	
F-II-6454	Sve moje bitke	Janko Bobetko ; [priredio, dokumentaciju odabrao i zabilješkama popratio Božo Rudež ; izrada karata Edo Butijer]. - Zagreb : vlast. nakl., 1996.	U knjizi nalazimo sjećanja i svjedočanstva te dokumente o godinama - 1941. - 1971. - 1990. - 1995. i zbivanjima u kojima je autor aktivno sudjelovao. Knjiga je podijeljena na tri poglavlja: Zapisi i svjedočanstva, Dokumenti, Dodaci. Autor otvoreno govori o svim bitkama koje je planirao, izvodio i završio. Knjiga je bogato dokumentirana brojnim fotografijama, kartama vojnih operacija, kopijama vojnih dokumenata - zapovijedi, naloga, direktiva, pisama itd.	
F-II-7037	Uspon i pad "Republike Srpske krajine"	priredio Davor Pauković. - Zagreb : Centar za politološka istraživanja, 2005.	Knjiga sadrži zbirku dokumenata koji su vezani za tzv. Republiku Srpsku krajinu i koji su od presudne važnosti za proučavanje najnovije hrvatske povijesti odnosno Domovinskog rata. U knjizi se nalaze relevantni hrvatski dokumenti za to vrijeme, dokumenti koje su izdavale vlasti srpskih pobunjenih oblasti u Hrvatskoj te međunarodni dokumenti relevantni za taj dio hrvatske povijesti.	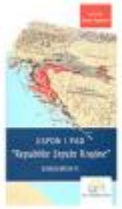

F-II-7118	Slobodan Milošević : anatomija zločina	Dušan Viro. - Zagreb : Profil, 2007.	Riječ je o političkoj biografiji Slobodana Miloševića čiji se život prati od smrti Josipa Broza Tita i raspada Jugoslavije. Slijedi pregled tijeka oružane agresije na susjedne samostalne republike u skladu s politikom stvaranja Velike Srbije. Također, obrađen je i Miloševićev zalazak, koji nastupa jačanjem njegove političke opozicije, izborni poraz te uhićenje i gorki kraj u haaškoj ćeliji.	
F-III-718	Gdje su naši najmiliji?	[glavni urednik Vlado Horvat]. - Zagreb : Udruženje Vukovarske majke : Poglavarstvo grada Vukovara, 1995.	Knjiga se bavi sudbinom u ratu nestalih i zatočenih branitelja i građana Republike Hrvatske. Donosi i popis svih traženih osoba s područja cijele Hrvatske i nekih dijelova Bosne i Hercegovine te velik broj fotografija zatočenih i nasilno odvedenih.	
F-III-847	Apeli dr. Vesne Bosanac	Vesna Bosanac ; priredio i uredio, [fotografije] Mladen Pavković. - Koprivnica : Alineja, 2002.	Publikacija sadrži pedesetak molbi i apela dr. Vesne Bosanac raznim nacionalnim i međunarodnim institucijama za pomoć vukovarskoj bolnici, ranjenicima i civilima koji su u bolnici našli posljednje utočište tijekom najvećeg razaranja grada, od 20. listopada 1991. do samog pada Vukovara 18. studenog 1991. godine. Apeli prikazuju stanje vukovarske bolnice tijekom najtežih dana granatiranja grada.	
F-II-10.517	Rat u Hrvatskoj i Bosni i Hercegovini	Dušan Bilandžić ... [et al.] ; uredili Branka Moguš i Ivo Žanić. - Zagreb : Naklada Jesenski i Turk ; Sarajevo : Dani, 1999.	Knjiga je rezultat okruglog stola održanog u Budimpešti u rujnu 1998., čiji su sudionici bili ključne figure dvaju ratova - časnici i političari iz BiH i Hrvatske, a sučelili su se s odabranim stručnjacima iz lokalnih i inozemnih akademskih krugova. Cilj je skupa i knjige ne samo utemeljenje vjerodostojnije povijesne građe, nego i razumijevanje vođenja političko-vojnih poslova. U prilogu su kronologija događanja u razdoblju od 1985. - 1995. i karte, a unutar knjige su i kratke bilješke o autorima, sudionicima i suradnicima.	
F-II-10.743	Sunčica = Sunny	[urednica = editor Marija Slišković ; prijevod = translation Nikolina Beljo, Julienne Eden Bušić]. - Zagreb : Hrvatsko društvo	Knjiga sadrži 14 istinitih svjedočanstava žrtava ratnog zločina i proživljenih patnji zatočenih žena u Vukovaru i okolici tijekom Domovinskog rata za vrijeme agresije Srbije i JNA na Hrvatsku	

		logoraša srpskih koncentracijskih logora, 2011.		
F-II-7052	Srpska pobuna u Hrvatskoj : 1990.-1995.	Nikica Barić. - Zagreb : Golden marketing - Tehnička knjiga, 2005	Knjiga se bavi uzrocima, povodima, samim tijekom i posljedicama pobune dijela hrvatskih Srba i velikosrpskom agresijom u Hrvatskoj od 1990. do 1995. godine. Autor opširno opisuje pripreme za pobunu i okupaciju dijela Hrvatske od strane pobunjenih hrvatskih Srba, ali i gospodarski, politički i društveni život u okupiranim dijelovima Hrvatske od 1991. do 1995. Autor se dotiče i posljedica srpske pobune i njihovog vojnog poraza po stanovništvo iz bivših okupiranih područja, kao i pitanjima političke i vojne odgovornosti za odlazak dijela hrvatskih Srba 1995. godine.	
F-II-4727	Perešin : život i smrt : o Rudolfu, ne samo pilotu ...	Branka Primorac. - 2. izd. - Zagreb : Naklada Stih : Udruga "Susreti za Rudija Perišina", 2004.	Knjiga je romansiranu biografija pilota Rudolfa Perešina. Prošlost hvatana iz druge ruke, od njegove supruge, prijatelja, rodbine, iz novinskih članaka.	
F-II-10.746	Zločini nad civilima u srpsko-crnogorskoj agresiji na Republiku Hrvatsku	Andrija Hebrang. - Zagreb : Udruga hrvatskih liječnika dragovoljaca 1990.-1991. ; Zadar : Ogranak Matice hrvatske, 2013.	Knjiga je nastala na temelju evidencija o ubijanju i ranjavanju hrvatskih civila Glavnog stožera saniteta Ministarstva zdravstva Republike Hrvatske kao i na temelju projekta Analiza rezultata saniteta u Domovinskom ratu Udruge hrvatskih liječnika dragovoljaca 1990. - 1991. Autor nastoji utvrditi pravu brojku civilnih stradalnika Domovinskog rata.	
F-II-10.697	Vukovar 1991. : dokumenti iz srpskih izvora	[urednik knjige Tihomir Ponoš]. - Zagreb : Novi Liber, 2010. - 417 str. ; 22 cm	Publikacija je skraćeno izdanje dvotomne knjige Vukovarska tragedija 1991. u mreži propagandnih laži i oružane moći JNA, koja je 2007. objavljena u Beogradu, a sadrži članke iz srpskih novina, svjedočenja pred Međunarodnim kaznenim sudom za bivšu Jugoslaviju u Haagu i pred Specijalnim sudom za ratne zločine u Beogradu.	

Prilog 2. Demografski podaci o igračima

R. BR	ID	Spol	Dob	Stupanj obrazovanja	Područje obrazovanja	Broj dodanih oznaka
1	141	Ž	18-24	Fakultet	Društvene znanosti	235
2	180	Ž	25-30	Magisterij	Društvene znanosti	218
3	105	Ž	31-40	Fakultet	Društvene znanosti	206
4	23	Ž	18-24	Fakultet	Društvene znanosti	203
5	109	Ž	31-40	Fakultet	Humanističke znanosti	182
6	166	Ž	41-50	Doktorat	Društvene znanosti	167
7	78	Ž	51-60	Fakultet	Humanističke znanosti	153
8	121	Ž	25-30	Fakultet	Društvene znanosti	146
9	25	Ž	18-24	Fakultet	Društvene znanosti	141
10	77	Ž	18-24	Fakultet	Humanističke znanosti	139
11	52	Ž	41-50	Srednja škola	Društvene znanosti	136
12	20	Ž	31-40	Fakultet	Društvene znanosti	132
13	120	Ž	25-30	Fakultet	Društvene znanosti	127
14	47	M	31-40	Fakultet	Društvene znanosti	122
15	170	Ž	25-30	Fakultet	Društvene znanosti	120
16	29	Ž	18-24	Fakultet	Društvene znanosti	114
17	156	Ž	18-24	Fakultet	Humanističke znanosti	103
18	30	Ž	18-24	Fakultet	Društvene znanosti	100
19	115	M	25-30	Fakultet	Društvene znanosti	98
20	21	M	18-24	Fakultet	Humanističke znanosti	87
21	103	Ž	18-24	Fakultet	Humanističke znanosti	86
22	149	Ž	41-50	Fakultet	Društvene znanosti	82
23	173	Ž	31-40	Fakultet	Biomedicina i zdravstvo	80
24	117	Ž	25-30	Fakultet	Društvene znanosti	77
25	40	Ž	31-40	Doktorat	Humanističke znanosti	71
26	150	M	31-40	Doktorat	Društvene znanosti	70
27	183	Ž	25-30	Srednja škola	Humanističke znanosti	70
28	186	Ž	25-30	Fakultet	Društvene znanosti	70
29	63	Ž	31-40	Doktorat	Društvene znanosti	69
30	64	Ž	18-24	Fakultet	Humanističke znanosti	67
31	143	M	51-60	Fakultet	Društvene znanosti	66
32	49	Ž	18-24	Fakultet	Humanističke znanosti	65
33	195	Ž	51-60	Doktorat	Društvene znanosti	61
34	37	Ž	18-24	Fakultet	Društvene znanosti	60
35	57	Ž	41-50	Doktorat	Humanističke znanosti	59
36	193	Ž	25-30	Fakultet	Društvene znanosti	59
37	202	Ž	25-30	Doktorat	Društvene znanosti	57
38	94	Ž	18-24	Srednja škola	Društvene znanosti	54
39	59	Ž	51-60	Fakultet	Tehničke znanosti	51
40	155	Ž	18-24	Srednja škola	Humanističke znanosti	51
41	110	Ž	18-24	Fakultet	Društvene znanosti	50

42	51	Ž	31-40	Fakultet	Tehničke znanosti	49
43	26	Ž	25-30	Fakultet	Humanističke znanosti	48
44	71	Ž	25-30	Fakultet	Humanističke znanosti	48
45	102	Ž	51-60	Fakultet	Humanističke znanosti	46
46	161	M	14-17	Osnovna škola	Ostalo	46
47	116	Ž	18-24	Fakultet	Humanističke znanosti	45
48	144	Ž	41-50	Fakultet	Društvene znanosti	45
49	133	Ž	18-24	Fakultet	Humanističke znanosti	45
50	67	Ž	18-24	Fakultet	Društvene znanosti	44
51	19	M	18-24	Fakultet	Društvene znanosti	42
52	129	Ž	18-24	Fakultet	Humanističke znanosti	42
53	45	M	18-24	Fakultet	Humanističke znanosti	42
54	75	M	18-24	Srednja škola	Društvene znanosti	42
55	107	M	31-40	Doktorat	Društvene znanosti	39
56	65	Ž	31-40	Srednja škola	Umjetničko područje	39
57	88	Ž	18-24	Fakultet	Društvene znanosti	39
58	169	Ž	18-24	Magisterij	Društvene znanosti	38
59	113	M	25-30	Fakultet	Ostalo	37
60	28	Ž	18-24	Fakultet	Društvene znanosti	36
61	46	Ž	18-24	Fakultet	Humanističke znanosti	36
62	31	M	31-40	Magisterij	Humanističke znanosti	36
63	147	Ž	51-60	Fakultet	Humanističke znanosti	35
64	142	Ž	51-60	Fakultet	Društvene znanosti	35
65	38	M	18-24	Fakultet	Društvene znanosti	35
66	60	Ž	18-24	Fakultet	Društvene znanosti	34
67	174	Ž	41-50	Fakultet	Društvene znanosti	33
68	48	Ž	41-50	Doktorat	Humanističke znanosti	32
69	146	Ž	31-40	Doktorat	Društvene znanosti	31
70	191	M	31-40	Doktorat	Društvene znanosti	31
71	190	Ž	25-30	Fakultet	Društvene znanosti	31
72	153	Ž	31-40	Magisterij	Društvene znanosti	30
73	36	M	18-24	Fakultet	Humanističke znanosti	30
74	99	M	31-40	Fakultet	Društvene znanosti	30
75	89	Ž	18-24	Fakultet	Društvene znanosti	30
76	74	M	25-30	Magisterij	Humanističke znanosti	29
77	85	M	31-40	Fakultet	Humanističke znanosti	28
78	159	Ž	41-50	Doktorat	Društvene znanosti	28
79	53	Ž	18-24	Fakultet	Društvene znanosti	27
80	164	M	18-24	Fakultet	Humanističke znanosti	27
81	189	Ž	18-24	Fakultet	Humanističke znanosti	27
82	27	M	18-24	Fakultet	Humanističke znanosti	27
83	122	Ž	41-50	Fakultet	Humanističke znanosti	26
84	181	Ž	41-50	Fakultet	Društvene znanosti	26
85	203	M	31-40	Doktorat	Tehničke znanosti	26
86	97	Ž	18-24	Fakultet	Društvene znanosti	25

87	163	Ž	31-40	Fakultet	Društvene znanosti	25
88	98	M	31-40	Srednja škola	Tehničke znanosti	24
89	132	M	18-24	Fakultet	Društvene znanosti	24
90	136	Ž	18-24	Srednja škola	Humanističke znanosti	24
91	157	Ž	18-24	Fakultet	Umjetničko područje	23
92	152	Ž	51-60	Doktorat	Humanističke znanosti	22
93	192	Ž	25-30	Fakultet	Humanističke znanosti	21
94	55	M	31-40	Fakultet	Humanističke znanosti	20
95	127	Ž	25-30	Fakultet	Humanističke znanosti	20
96	128	Ž	18-24	Fakultet	Humanističke znanosti	20
97	140	Ž	18-24	Fakultet	Društvene znanosti	20
98	76	Ž	18-24	Fakultet	Humanističke znanosti	20
99	44	M	18-24	Fakultet	Društvene znanosti	19
100	96	Ž	18-24	Fakultet	Prirodne znanosti	19
101	80	Ž	18-24	Magisterij	Društvene znanosti	18
102	178	Ž	25-30	Fakultet	Društvene znanosti	17
103	135	Ž	18-24	Fakultet	Društvene znanosti	17
104	35	Ž	25-30	Srednja škola	Ostalo	16
105	114	Ž	31-40	Fakultet	Društvene znanosti	16
106	177	Ž	18-24	Fakultet	Društvene znanosti	16
107	123	Ž	18-24	Fakultet	Humanističke znanosti	15
108	194	Ž	25-30	Magisterij	Društvene znanosti	15
109	54	Ž	25-30	Fakultet	Humanističke znanosti	15
110	39	Ž	31-40	Srednja škola	Humanističke znanosti	14
111	34	Ž	18-24	Fakultet	Društvene znanosti	13
112	118	M	18-24	Magisterij	Društvene znanosti	13
113	104	Ž	31-40	Doktorat	Društvene znanosti	13
114	125	M	18-24	Fakultet	Društvene znanosti	12
115	33	Ž	41-50	Doktorat	Humanističke znanosti	11
116	154	Ž	18-24	Fakultet	Prirodne znanosti	11
117	16	M	18-24	Fakultet	Humanističke znanosti	10
118	187	Ž	31-40	Fakultet	Društvene znanosti	10
119	197	Ž	25-30	Doktorat	Društvene znanosti	10
120	70	Ž	25-30	Fakultet	Humanističke znanosti	10
121	111	Ž	41-50	Fakultet	Društvene znanosti	10
122	176	Ž	25-30	Fakultet	Humanističke znanosti	9
123	137	M	31-40	Doktorat	Humanističke znanosti	9
124	61	Ž	18-24	Magisterij	Društvene znanosti	8
125	81	Ž	18-24	Fakultet	Društvene znanosti	8
126	131	Ž	18-24	Fakultet	Društvene znanosti	7
127	151	M	25-30	Srednja škola	Humanističke znanosti	7
128	175	Ž	51-60	Magisterij	Prirodne znanosti	7
129	100	Ž	31-40	Fakultet	Tehničke znanosti	6
130	199	Ž	51-60	Fakultet	Društvene znanosti	6
131	43	Ž	25-30	Fakultet	Društvene znanosti	5

132	41	Ž	18-24	Fakultet	Humanističke znanosti	5
133	165	Ž	25-30	Fakultet	Društvene znanosti	5
134	171	Ž	18-24	Fakultet	Društvene znanosti	5
135	204	Ž	31-40	Fakultet	Društvene znanosti	5
136	83	Ž	18-24	Fakultet	Humanističke znanosti	4
137	108	Ž	25-30	Fakultet	Humanističke znanosti	4
138	24	M	31-40	Magisterij	Humanističke znanosti	4
139	58	Ž	25-30	Fakultet	Humanističke znanosti	4
140	119	Ž	18-24	Fakultet	Društvene znanosti	4
141	185	Ž	51-60	Doktorat	Društvene znanosti	4
142	160	Ž	25-30	Doktorat	Biotehničke znanosti	3
143	112	Ž	18-24	Fakultet	Društvene znanosti	2
144	167	Ž	18-24	Fakultet	Humanističke znanosti	2
145	196	M	31-40	Doktorat	Društvene znanosti	2
146	198	M	31-40	Doktorat	Društvene znanosti	2
147	68	M	18-24	Fakultet	Humanističke znanosti	1

Prilog 3. Broj dodjeljivanja i dodanih oznaka prema vrstama građe

A. MUZEJSKA GRAĐA

ID	BROJ DODJELJIVANJA	BROJ DODANIH OZNAKA
HPM-93728	239	47
HPM-93764	222	82
HPM-93549	221	95
HPM-89811	194	99
HPM-93220_1_2-6	192	106
HPM-97949	185	84
HPM-93662	177	111
HPM-93578	175	85
HPM-93737	166	74
HPM-98010	158	85
HPM-96635_96636_96637	151	58
HPM-SI-2258	148	78
HPM-98006	112	75
HPM-99439_lutka	111	67
HPM-33037	109	33
HPM-93218	102	55
HPM-93201	99	46
HPM-96631	79	42
HPM-98019	72	37
HPM-33176	64	44
UKUPNO	**2976**	**1403**
MAX	**239**	**111**
MIN	**64**	**33**
PROSJEK	**148.8**	**70.15**
STDEV	**52.71**	**23.77**

B. KNJIŽNIČNA GRAĐA

ID	BROJ DODJELJIVANJA	BROJ DODANIH OZNAKA
F-II-10.517	332	98
F-II-10.697	329	128
F-II-4727	303	83
F-II-10.743	273	73
F-II-10.696	269	89
F-II-10.641	211	119
F-II-10.516	207	105
F-II-6711	204	127
F-II-6454	191	79

F-II-10.245	171	102
F-II-6611	161	98
F-II-7118	160	96
F-III-847	159	100
F-II-7037	147	88
F-II-6920	134	74
F-II-10.376	132	81
F-III-718	123	79
F-II-7052	122	73
F-III-785	107	68
F-II-10.746	83	43
UKUPNO	**3818**	**1803**
MAX	**332**	**128**
MIN	**83**	**43**
PROSJEK	**190.9**	**90.15**
STDEV	**74.39**	**20.76**

C. FOTOGRAFIJE

ID	BROJ DODJELJIVANJA	BROJ DODANIH OZNAKA
HPM-90134	124	68
HPM-90142	163	67
HPM-90145	454	84
HPM-90163	134	64
HPM-90558	198	106
HPM-90662	266	93
HPM-90791	294	121
HPM-90875	207	83
HPM-90919	295	121
HPM-91229	269	114
HPM-91263	272	115
HPM-91415	375	86
HPM-91474	257	129
HPM-91563	186	80
HPM-91649	114	56
HPM-91773	196	94
HPM-92298	131	80
HPM-92475	180	96
HPM-92902	178	75
HPM-93005	191	79
UKUPNO	**4484**	**1811**
MAX	**454**	**129**
MIN	**114**	**56**
PROSJEK	**224.2**	**90.55**
STDEV	**86.97**	**21.08**

D. ARHIVSKA GRAĐA

ID	BROJ DODJELJIVANJA	BROJ DODANIH OZNAKA
HPM-93195	98	54
HPM-93196_42	198	104
HPM-93345	124	71
HPM-93372	120	62
HPM-93410	143	84
HPM-93511_av	168	90
HPM-93511_rv	196	78
HPM-93517_av	320	88
HPM-93531_av	109	85
HPM-95097	116	69
HPM-96554	132	58
P-HPM-96561	136	66
P-HPM-96571	131	89
P-HPM-MRNH-P_218-2	142	77
P-HPM-MRNH-P-285	130	64
P-HPM-MRNH-P-403	133	70
P-HPM-MRNH-P-425	126	77
P-HPM-MRNH-P-429	143	54
P-HPM-MRNH-P-445	152	62
P-HPM-MRNH-SI-2272	307	169
UKUPNO	**3124**	**1571**
MAX	**320**	**169**
MIN	**98**	**54**
PROSJEK	**156.2**	**78.55**
STDEV	**59.36**	**25.13**

Prilog 4. Predmetnice i korisničke oznake korištene u usporedbi

ID	BROJ PREDMETNICA	BROJ KORISNIČKIH OZNAKA	PREDMETNICE	KORISNIČKE OZNAKE
F-II-10.245	13	102	domovinski rat; hrvatska; jugoslavija; kopnena vojska; legija; nacionalna obrana; obrambena politika; oružane snage; rat za nezavisnost; ratna mornarica; ratno zrakoplovstvo; vojne snage; vojska	1994; agresija; autor; bibliografski opis; bitka; bljesak; boj; bojevi; bol; borba; borbe; branitelj; crvena boja; dim; dimenzija; domovina; domovinski rat; domovinski rat u hrvatskoj; feniks; glupost; golubica; golunbica; hrvatska; hrvatska rat; hrvatski domovinski rat; hrvatsko srpski sukob; ime pisca; iskoristi rat; istina; jedan sudionik; knjiga; knjiga o domvinskom ratu; književnost; kontrast crvene i žute boje; korice; krv; marinko gorec; marinko ogorec; nacionalnost; narančasta; narančasti okvir; naslijeđe; naslov; naslovnica; obrana; odlomak; određena vremenska distanca; ogorec o ratu; okvir; oluja; opatija; osobno viđenje; osobno viđenje rata; otokar keršoivani; perspektiva; plamen; podaci; ponos; povijest; pregled; pregled značajnih operacija; pristupačan način; ptica; publikacija; ranjenici; rat; razaranja; raščlanjivati uzroke; rečenice; romb; sjećanje; slova; smeša; smrt; stjeg; stradanja; strah; strategija; sudionik; sukob; tekst; teror; tijek događaja; tijek rata; tuga; usredotočiti se; uzroci; uzroci rata; uzrok rata; vatra; viđenje; vojna operacija; vojna strategija; vojne operacije; vojne strategije; vojnik; vojno strategijska dimenzija; vojska; vođen; šahovnica; žuta boja; žuta golubica
F-II-10.376	12	81	civilna žrtva; domovinski rat; glavašević; komunikacijska struka; novinar; rat za nezavisnost; ratna žrtva; reporter; siniša; vukovar; zvanje u komunikacijskoj struci; žrtva rata	balkon; barokna zgrada; bla; bol; bolnica; cesta; crna boja; crvena boja; crveni naslov; dobrota; domovinski rat; glad; glavašević; grad heroj; hangari; hrvatska; iseljavanje; jad; kaput; knjiga; knjiga siniše glavaševića; korice knjige; krov; kuća; kuće; lirika; ljubav; ljudske vrijednosti; logori; lukovi; mrcilište; nada; naslovna stranica; naslovnica; nebo; novinar; novinarstvo; opis; opkoljeni; opsada vukovara; pad; patnja; pločnik; pogibija; posljedice rata; prica; priče; priče iz vukovara; protjerivanje iz domova; prozor; prozori; publikacija; pustoš; radio; ranjenici; rat; ratni izvjestitelj; razaranje; ruševine; ruševne kuće; samoća; siniša; siniša glavašević; sjećanja; slova; smrt; stratišta; stup; svjedočanstva; teški život; tople uspomene iz ledenog užasa; torba; tragedija; ulica; ulična rasvjeta; uspomene; vukovar; zajedništvo; žena; ženska torba; žrtve
F-II-10.516	8	105	domovinski rat; hrvatska; hrvatsko proljeće; nezavisna država hrvatska; politika; politički život; povijest; rat za nezavisnost	autor; balkon; barbat; bijela boja; crkva; crveni; crveni križ; dalmacija; daša; daša drndić; devedesete; domovina; domovinski rat; drnić; drvo; država; država stvorena u ratu; dubrovnik; duh; enciklopedija; engleski; engleski jezik; europa; europska država; govor; grad; građevine; hrvatska; hrvatska ban; hrvatska povijest; hrvatski; hrvatski institut za povijest; institut; izdanje; kamena kuća; katalogizirano; knjiga; knjigu o stovrenoj hrvatskoj u ratu; kopno; kriz; kultura; kupola; marcus; marcus tanner; more; nasljeđe; naslov; naslovnica; naslovnica knjige; nastajanje ljudi; ograda; opis; opis knjige; opis sadrzaja; palma; palme; plavo; podaci o knjizi; područje; položaj; položaj hrvatske; povijesni

				pregled; povijest; povijesti; požar; prijevod; prozor; prozori; prošlost; publikacija; rat; rat za promociju; ratna prošlost; rađanje suverene hrvatske; recenzija; rezultat; riječi; ruševine; sažetak sadržaja knjige; siva boja; slika; slobodna država; slova; smeđa boja; srednji vijek; strategija; stvaranje; stvorena; svjedoci; tanner; tekst; toranj; tvrđava; u ratu; umjetničko naslijeđe; uzroci rata; vrata; zagreb; zastava; zemlja; zgarište; zgrada; zgrade; zlatna sloca; zvonik
F-II-10.517	13	98	bljesak vojna operacija; bosna i hercegovina; domovinski rat; hrvatska; jugoslavija; legija; nacionalna obrana; obrambena politika; oluja vojna operacija; oružane snage; slovenija; vojne snage; vojska	1985 1995; 1991; 1995; 1998; 2 miša u gnjijezdu; akademici; akademici o ratu; akademski krugovi; atak; autori; bibliografski podaci; bibliografski zapis; bih; bijele bombe; bijelo; bilandžić; bilješke; bomba; bombe; bosna; bosna i hercegovina; bosna i hersegovina; brojevi; brojke; budimpešta; casnici; crnilo; crno; crtica; domovina; domovinski rat; dušan bilandžić; figure; ftič; gnijezdo; gnjezdo; godine; granate; građa; grenate; hercegovina; hrvati; hrvatska; hrvatski domovinski rat; islam; istraživanje; jad; jaja; jugoslavija; karte; kataložni opis; knjiga; knjiga o ratu; kratki sadržaj; kronologija; mizerija; miševi; mrak; muslimani; naslovnica; neke stvariljudi ne znam da li dobro vidim u gnijezdu; okrugli stol; opis; opis knjige; osmanlije; patnja; pisanice; politicari; politicko vojni poslovi; politika; povijesni pregled; povijest; ptica; publikacija; rat; rat u bih; ratna tematika; recenzija; rukavice; sažetak; sažetak knjige; skup; slama; slova; smrt; srbi; stručnjaci; sudionici; suradnici; tuga; turska; uskrs; vjera; vjerodostojnost; vojni poslovi; vojska; vremensko razdoblje; štapići
F-II-10.641	8	119	dokument; domovinski rat; hrvatska; okupirani teritorij; okupirano područje; rat za nezavisnost; srbi; zaposjednuto područje	agresori; autor; balvan revolucija; bistrina; bolesni umovi; borbe; brdo; crna majica; crne majica; djeca; dječaci; dječji osmjeh; dokument; dokumenti; domovinski rat; dva dječaka; dvojica mladića; engleski jezik; fotografija; general; gora; gotovina; hrvatska; hrvatska zastava; hrvatski barjak; hrvatski jezik; ideja velike srbije; ideološka struktura srbije; informacije; izvorni dokumenti; jna; junaštvo; kamen; kameni zid; kamenje; karadžić; katalogizacija; knin; kninska tvrđava; knjiga; kuća; literatura; ljudi; matić; mit; muškarci; naslovnica; nebeska; nebeska srbija; nebeska srbija u hrvatskoj; nebeska srbija u hrvatskoj mit; nebo; nenad; nenad piskač; neviđeni dokumenti; njemački jezik; normativna struktura srbije; oblaci; obnova; obrana; obrana teritorija; ograda; opis; opis knjige; oprost; organizacija ratovanja; oslobođenje; osmijeh; paradržava; paradržava republika srpska krajina; paravojska; piskač; planina; pobuna; politika; politička struktura srbije; ponos; poturice; prijevod; publikacija; raslinje; rat; ratni zločinac; razaranja; razbojnici; republika srpska krajina; rečenice; riječi; sažetak; slika; sloboda; slova; srbi; srbija; sreća; srpska krajina; srpska mitologija; srpska paradržava; srpska pobuna; stijena; stijene; struktura države; tekst; trava; tvrđava; uspjeh; ustaše; utvrda; veselje; vijorenje; visina; vojne akcije; zaborav; zagrljaj; zastava; zašto; zbilja; zid; četnici
F-II-10.696	8	89	ante; domovinski rat; gotovina; međunarodni kazneni tribunal;	akcija; ante; ante gotovina; autobiografija; autori; bibliografski podaci; bibliotečno obrađena knjiga; bijela; biografija; borac; borba; civili; domovinski rat; epaulete; fotografija; gardist; general; general ante gotovina; general gotovina; gledište; gotovina; govor; grb; haag; haški optuženik; heroj; heroj ili zločinac; hrvatska; hrvatska vojska; ime i

			optužni akt; oružane snage; rat za nezavisnost; životopis	prezime; kapa; kataložni opis; knin; knjiga; knjiga o generalu anti gotovini; knjiga o generalu gotovini; košulja; kravata; lice; list; međunarodni kazneni tribunal; nada; narodni heroj; naslov; naslovna fotografija; naslovnica; nepravedno suđenje s pravednim završetkom; nos; o anti gotovini; obrana; odlikovanja; odora; oluja; opis; opis knjige; orden; ordeni; ordenje; oružane snage; oslobođenje; oči; pleter; pobjeda; pogled; presuda; rat; ratište; ratnik; rever; slika; slova; stvarnost i mir; suđenje; taktika; uniforma; usta; uši; vojne akcije; vojnik; vojska; zatvor; zločinac; značke; čin; činovi; čovijek; čovjek; život; životopis
F-II-10.697	6	128	dokument; domovinski rat; povijesni pregled; svjedočenje; tisak; vukovar	1991; 20stoljeće; anotacija; auto; automobil; beograd; bibliografski opis; bibliografski podaci; bibliografski zapis; cesta; cigla; crijep; crijepovi; cveno; devastacija; dokument; dokumenti; dokumenti iz srpskih izvora; domovina; domovinski rat; genocid; glavni stvarni naslov; građevinski otpad; haag; hag; hodanje; impresum; isbd; isbd interpunkcijski simboli; iseljavanje; izbjeglice; izdavač; izvor; jad; jna; jugoslavija; kaos; kapa; kaput; kataložni opis omeđene publikacije; katastrofa; knjiga; knjige; kratki sadržaj; krov; kuća; kuće; laž; logor; međunarodni kazneni sud haag; međunarodni kazneni sud u haagu; migranti; monografije; mreža; mucenje; muškarac; naslovnica; navod; neistine; neizvjesnost; nered; novine; omeđena publikacija; omot; omot knjige; opis; otpad; pad; podatak o odgovornosti; podnaslov; posljedice domovinskog rata; propaganda; publikacija; publikacije; rat; ratna drama; ratna propaganda; ratna razaranja; ratni zločin; ratni zločini; raz; razaranje; razrušena kuća; razrušeni vukovar; riječi; rušenje; ruševine; samoća; skupina materijalnog opisa; slika omota; slova; smrt; specijalni sud za ratne zločine u beogradu; srbi; srbija; srpske novine; srpski dokumenti; srpski izvori; stara kuća; stradavanje; sud; sudski iskazi; suđenje; svjedočenja; svjedočenje; teror; tihomir ponoš; tragedija; tragično zbivanje; tuga; ubijanja; ubojstva; ulica; uništenje; urbicid; ustroj napadačkih jedinica; vojnik; vukoval; vukovar; vukovar 1991; vukovarska tragedija; zagreb; zbirka dokumenata; zgrada; zločini; članak; čovjek; šešir
F-II-10.743	14	73	civilna žrtva; domovinski rat; eksterminacijski logor; hrvatska; istrebljivački logor; koncentracijski logor; koncentracioni logor; konclogor; ratna žrtva; ratni zarobljenik; seksualno nasilje; silovanje; spolno	agresija; agresijažene; bijes; bodljikava žica; bol; crna ptica; crna žica; domovinski rat; duša; dvojezični naslov; grana; hrabrost; hrvatska; jna; katalogizacija; kataložni opis; kljun; knjiga; krhkost; krv; lastavica; list; logor; memorija; mucenje; nasilje nad ženama u domovinskom ratu; nepravda; oksimoron; patnja; pero; prica; ptica; pticu na bodljikavoj žici logora; ptičica; rana; rat; ratni zločin; ratni zločini hrvatska; rep; sadržaj knjige; sažetak; silovanje; siva slika; sivo; sjena; sjene straha; sloboda; slova; srbija; strah; sunce; sunny; sunčica; svjedočanstva; svjedočanstva žrtava domovinskog rata; svjedočanstvo; svjetlost; tama; vlat trave; vukovar; zatočeništvo; zlostavljanje; zločin; zločini; žene; žene u ratu; žene u srpskim koncentracijskim logorima; žene žrtve rata; žica; život; životne priče; žrtve; žrtve srpske agresije na hrvatsku

			nasilje; žrtva rata	
F-II-10.746	6	43	civilna žrtva; domovinski rat; hrvat; hrvatska; ratni zločin; ratni zločinac	andrija hebrang; bol; civil; civili; civilna stradanja; civilna žrtva; civilni stradalnici domovniskog rata; crna gora; domovinski rat; dragovoljci; evidencija; evidencija o ubijanju i ranjavanju; grb; hebrang; hrvatska; hrvatski grb; kapi krvi; kaplica krvi; kataložni opis; knjiga; kockice; krv; krvarenje; naslov; naslov knjige; naslovna stranica; naslovnica; rat; ratne žrtve; ratni zločin; sažetak; srbija; srce; srce domovine koje krvari hrvatska šahovnica u obliku srca; stradali u domovinskom ratu; stradanja; tekst; tetovaža; ubijanje; udruga hrvatskih liječnika dragovoljaca; zločin; zločini; šahovnica
F-II-4727	12	83	domovinski rat; legija; oružane snage; perešin; rat za nezavisnost; ratna žrtva; ratno zrakoplovstvo; rudolf; vojne snage; vojska; životopis; žrtva rata	austrija; avijatičari; avion; avion iza čovjeka; bijeg; biografija; branka primorac; branka primorac perešin; cra odjeća; crna odjeća; devet; domovina; domovinski rat; fotografija muškarca; fotografije oblaka; gitara; glava; gornja stubica; heroj; hrabrost; ime; ime autora knjige; jna; kaciga; katalogizavija; knjiga; knjiga branka primorca; knjižni zapis; kontrast; kratak opis knjige; kriz; kult ličnosti; list; ljubav; mig21; naslov; naslov knjige; naslovnica; naslovnica knjige; nebo; nespretna kompozicija; nečitljivo; nijanse plave; o rudolfu; oblaci; oblak; opis; opis knjige; perešin; pilot; plavo nebo; podnaslov; pogibija; pravokutnici; prezime; primorac; rascjepkano prostranstvo; rat; ratni memoari; roman; rudi; rudolf; rudolf perešin; rudolf perišin; rudolf peršin; ruka; sažetak; sjeta; slova; smrt; supruga; susreti za rudija; tile; torba na leđima; uniforma; velikan; vojnik; zagreb; značka; ćelavi; čovjek; život; život i smrt
F-II-6454	9	79	antifašistički pokret; bljesak vojna operacija; bobetko; domovinski rat; hrvatsko proljeće; janko; oluja vojna operacija; oružane snage; životopis	1941; 1971; 1990; 1995; antifašistički pokret; autobiografija; bibliografski podaci; biografija; bitka; bitke; bobetko; borac; direktiva; dokument; dokumenti; domovinski rat; genaral; general; hrvatska vojska; hrvatski general; hrvatsko proljeće; ideologija; ime grada; ime i prezime; janko; janko bobetko; janko boetko; kapa; knjiga; knjiga janka bobetka sve moje bitke; knjiga o janku bobetku; košulja; kratki sadržaj; kravata; krošnja; lice; memoari; mrtav; nacionalnost; nalog; naslov; nos; obrana; odijelo; odličja; odora; oko; oluja; opis; ordeni; oružane snage; osmijeh; pismo; ponos; portret; profil; publikacija; rat; ratovanje; sjećanja; slova; starac; stari čovijek; sve moje bitke; svjedočanstva; uho; uniforma; usta; vojne operacije; vojnik; vojnička kapa; vojska; zapisi; zapovijed; zelena boja; zlatna boja; čin; čovjek; životopis
F-II-6611	10	98	domovinski rat; hrvatska; materijalna šteta; naknada štete; oružani sukob; popravljanje štete; rat; rat za nezavisnost; ratna šteta; šteta	1991; 1992; 1997; agresija; baka; baka zvoni; bol; bor; crkva; crkva uništena od bombadiranja; crkve; djevica marija; domovi; domovina; domovinski; domovinski rat; drvo; dubrovnik; ekonomija; fizički; grana; grane; građevina; hrvatska; hrvatske ratne štete; izrešetana fasada; izrušeno; jad; kataložni opis; kip; knjiga; knjiga hrvatske ratne štete; konop; kuće; loša; majka; mate pavković; metci; nada; naknada ratnih šteta; naslovna strana; nebo; nepovratno; novac; obitelji; obnova; omot; organizacija; ostatak; oštećenje; pisac; politika; politika obnove; psihički; rat; ratna agresija; ratna šteta; ratne stete; razaranje; razdoblje; razrušena crkva; reparacija; rupe od metaka; ruševina; ruševina crkve; ruševine; ruševni toranj; sažetak; slova; srpska agresija; srušeni zvonik; stalak za zvono; stara baka; starica; stepenice; stradanja; svetac; teško; tuga; ulaz; ulaz u crkvu; uništena crkva; uništeno; utopija; uže; velikosrpska agresija; vitraj; vrata; vukovar; zvonar; zvonik;

				zvono; čempres; četnici; članak; špaga; šteta; žena
F-II-6711	9	127	bosna i hercegovina; domovinski rat; hrvatska; međunarodna arbitraža; međunarodno mirenje; međunarodno posredovanje; mirovni pregovori; rat za nezavisnost; rješavanje sporova	1997; anotacija; balkan; bijeg; bol; bosna; bosna i hercegovina; brkovi; broj; cesta; cipela; djeca; dječak; dom; domovinski rat; egzodus; eu; glad; glava; glavni stvarni naslov; gomila; hercegovina; hrvatska; hrvatsko srpski odnosi; isbd; iseljavanje; izbjeglice; izbjegličtvo; izvještaj; izvještaj međunarodne komisije za balkan; izvještaji; katalogizacija; kataložni opis; katolici; knjiga; kolona izbjeglica; konflikti; kosova; kosovo; krizna žarišta na balkanu; leo tindemans; ljubav; ljudi; manipulirani narod; marama; marame; masa; međuljudski odnosi; međunarodna arbitraža; međunarodna komisija; međunarodna komisija za balkan; mir; mržnja; muslimani; muškarac rubac; muškarac u tačkama karijoli unprofor; muškarci; narod; naslovnica; nedovršeni; nedovršeni mir; nedovšeni mir; nepodnošenje; nepomirivost; nepopravljivo; nepravda; nesreća; netolerantnost; netrpeljivost; noga; odnosi; omot; omđene publikacija; opis knjige; opis slike; otpor; plavi šljemovi; podnaslov; politički odnosi; pomaganje; poniženje; posavina; posljedice; pravoslavci; prognanici; progon; progresivno; prošlost; publikacija; rat; rješavanje sporova; rusija; sad; sažetak; sivo; skupine kataložnog opisa; slaveni; slavonija; slika omota; slova; smrt; srbija; srce; starac; strah; stvari; suza; tačke; tekst; tmurno; torbe; tuga; un; unprofor; uzroci; uzroci rata; uzrok rata; veze; vojnici; vrećica; zajedništvo; zlo; čarape; šljemovi; žalost; žene; žrtva
F-II-6920	10	74	bljesak vojna operacija; bosna i hercegovina; domovinski rat; hrvatska; međunarodna arbitraža; okupirano područje; oluja vojna operacija; oružane snage; oslobođeno područje; rat za nezavisnost	agresija; analiza; autor knjige; bibliografski podaci; bih; bljesak; bljesak oluja; bosna; bosna i hercegovina; bosne i hercegovine; brojevi; davor domazet lošo; domovinski rat; epicentar; generali; geopolitika; granica; granice; hrvatka; hrvatska; hrvatska i veliko ratište; ideologija; ime autora; karta; karta hrvatske; katalog; katalogizacija; knjiga; knjiga hrvatska i veliko ratište; krug; krugovi; kružnica; mali krug; mali kruh; međunarodna arbitraža; more; naslijeđe; naslov knjige; naslovnica; naslovnica knjige; oluja; omot knjige; opis; opis djela; patnja; pismo; plava boja; plavo; podaci o izdanju; područje; popratni tekst; povijest; pravokutnici; pubikacija; publikacija; rat; ratište; ratna događanja; ratovanje; rh; sažetak sadržaja knjige; slova; slovenija; slovenije; strategija; strategije; sukobi; tri kružnice; velika bijela slova; veliko ratište; vojne operacije; vojska; zemljopisna karta; zemljovid
F-II-7037	7	88	autonomna zajednica; domovinski rat; hrvatska; okupirano područje; službeni dokument; srbi; zakonodavstvo	boje; bosna; bosna i hercegovina; brojevi; centar za politološka istraživanja; crvena; dalmacija; davor pauković; dio balkana; dio europe; dokument; dokumentacija; dokumenti; domovinski rat; granice država; građanski rat; hrvatska; hrvatska povijest; hrvatska povijest i sadašnjost; informacije; istra; jadran; jadransko more; karta; karta hrvatske; kartu hrvatske; kataložni opis; knjiga; knjiga uspon i pad republike srpske krajine dokumenti; krajina; kvarner; lijepa naša; lika; mapa; mađarska; moj dom; more; naslov; naslovnica; novija povijest; oblast; odlomak; okupirana područja rh; okupirano područje; opis; otoci; otoke; oznaka; pad; pad srpske krajine; pauković; planine; plava; plavo polje s tekstom;

				područje okupirane hrvatske; povijest; publikacija; reljefna karta; republika hrvatska; republika srpska krajina; republika srpske krajine; rečenice; riječi; sažetak; sažetak knjige dokumenata; simbol; siva; slova; slovenija; slovo; smedja; srbi; srbija; srpska krajina; srpski pobunjenici; sukob; tekst; teritorij; uspon; uspon i pad; uspon srpske krajine; zbirka dokumenata; zemlja; zemljopisna karta; zemljopisna karta hrvatske; zemljovid; znakovi; zuta
F-II-7052	8	73	domovinski rat; hrvatska; nacionalna manjina; okupirano područje; oluja vojna operacija; pokret za autonomiju; srbi; ustrojstvo institucije	1990; 1995; 2 zastave; agresija; anotacija; barić; brojevi; cccc; civili; domovinski rat; društvo; glava; gospodarstvo; grb; hrvati; hrvatska; hrvatski srbi; isbd; izvor; knjiga; knjiga o srpskoj pobuni u rh; korica knjige; korice knjige; kratki sadrzaj knjige; ljudi; lkudi; masa ljudi; mase; miting; miting istine; nacionalna manjina; nacionalne manjine; nacionalnost; napad; naslovnica; nepravda; nikica; nikica barić; odgovornost; odlomak; okupacija; omeđena građa; oružana pobuna; oči; pobuna; pobuna hrvatskih srba; podaci o knjizi; politika; povijest; povod; problemi; rat; razdoblje; sažetak; skupine kataložnog opisa; slika omota; slova; srbi; srbi u hrvatskoj; srbija; srpska pobuna; srpska pobuna u hrvatskoj; stanovništvo; tekst; teško je zgaziti gusjenicu na jabuci radije pričekajte da od; uzrok; velikosrpska agresija; vojnici; vojska; zastava; zastave; znanost; znanstveni tekst
F-II-7118	8	96	bosna i hercegovina; domovinski rat; državni poglavar; hrvatska; milošević; politika; slobodan; srbija	agresija; agresor; analiza politike; anatomija; anatomija zločina; bibliografski podaci; biografija; biografija milošević; biografija slobodana miloševića; bivšeg predsjednika republike srbije koji je sada pokojan slobo; bolesnik; bosna i hercegovina; cigara; cigareta; diktatura; domovinski rat; državni poglavar; dušan viro; dušan vito; etiketa na naslovnici koja je nečitka; fotografija; gigara; haag; hrvatska; hrvatski domovinski rat; ime autora knjige dušan viro; informacije; isključivost; jugoslavija; kataložni opis; knjiga; koju je napisao dušan viro izdavač knjige je profil; kosa; kratki sadržaj; lažljivac; milošević; mržnja; muškarac; na slici vidim slobodana miloševića; namršteno lice; naslov knjige slobodan milošević; naslovnica; naslovnica knjige o slobodanu miloševiću; natpis profil na naslovnici; nesnošljivost; netrpeljivost; nečovjek; odijelo; opis; osoba; plamen; podlac; podnaslov anatomija zločina; politika; političar; politička ličnost; politički programi; politički stavovi; političko djelovanje; prikaz; profil; proćelavost; psihopat; pušenje; rat; ratne akcije; ratni zločinac; reklama; rečenice; riječi; ruka; ruke; sažetak; sažetak knjige osnovni podaci o knjizi sažetak; sebeljub; sijeda kosa; slika; slika slobodana miloševića; sloboda milošević; slobodan; slobodan milošević; slova; smrtonoša; srbija; tekst; ubojica; upaljač; vatra; vatra iz upaljača; velika srbija; viro; zločin; zločinac; četnik; šaka; životopis
F-III-718	8	79	branitelj domovinskoga rata; domovinski rat; hrvatska; rat za nezavisnost; ratna žrtva; ratni zarobljenik;	baner; bosna i hercegovina; branitelji; briga; crna podloga; domovinski rat; fotografije; fotografije ljudi na baneru; gdje su naši najmiliji; gubici; hrvatska; izgubljeni ili zagubljeni; knjiga; knjižni zapis; lica; ljubav; ljudi; logori; molba; molitva; najmiliji; nasilje; nasilno odvedeni; naslov; naslovnica; natpis; natpis na baneru; navodnici; naši najmiliji; nesretna sudbina; nestale osobe; nestali; nestali i zatočeni; nestali ljudi; obitelj; opis; opis knjige; očaj; piramida; pitanje; plakat; plač; poginuli; prekriženi prsti; prsti; publikacija; rat; ratne tragedije; razaranje obitelji; razbacana slova na baneru; rečenica; riječi; ruke; ruke

			vukovar; žrtva rata	sklopljene u molitvu; sažetak; sklopljene ruke; skup; slova; smislena cjelina; smrt; strah; traganje; transparent; tražene osobe; traženje; trokut; tuga; vjera; vlado horvat; vukovar; vukovarske majke; zabrinutost; zarobljeništvo; zastava; zatočeni; zatočeni branitelji; zatočeništvo; čežnja; žalost
F-III-785	10	68	civilna žrtva; domovinski rat; etničko čišćenje; rat za nezavisnost; ratna žrtva; ratni zarobljenik; ratni zločin; ratni zločinac; vukovar; žrtva rata	bibliografski opis; bibliografski podaci; bijela golubica; branitelj; branitelji; civili nestali u domovinskom ratu; crne korice; crno; do istine; dokument; domovinski rat; ekshumacija; golubica; grb; horvat; hrvatski branitelji; idenfikacija nestalih; identifikacija ekshumiranih tijela; istina; kameni spomenik; katalogizirana knjiga; kataložni opis knjige; knjiga; lik golubice u spomeniku; majke; naslovnica; natpis; natpis na spomeniku; nestala osoba; nestali; nestali branitelji i civili; nestali hrvatski branitelji; nestali u ratu; obitelj; opis; ploča; podaci o knjizi; poginuli; poginuli branitelji; ptica; publikacija; rat; roditelj; spomen obilježje; spomen područje; spomenik; suzama; suzama do istine; suze; tekst; trilogija; triologija; tuga; udruga; urednik; vlado; vlado horvat; vojnici; vukovar; vukovarska županija; vukovarske majke; vukovarsko srijemska županija; zarobljenik; zatočeni; zatočeni u ratu; zatočeništvo; šahovnica; žrtve razaranja
F-III-847	12	100	bolnica; bosanac vesna; domovinski rat; klinika; liječnička usluga; medicinska usluga; medicinsko zbrinjavanje; rat za nezavisnost; telemedicinski centar; vukovar; zdravstvena usluga; zdravstvena ustanova	18; 1991; 2002; 20lis; agresija; aleli; alineja; anotacija; apel; apeli; apeli međunarodnim institucijama; apeli vesne bosanac; balkon; bol; bolnica; bosanac vesna; branitelji; brjevi; brojevi; civil; civili; dokument; dokumenti; domovina; domovinski rat; dopisi; dr vesna bosanac; drveće; fotografija; fotografije; fotografije rata; glavni stvarni naslov; godina; institucije; isbd; kataložni opis; kataložni opisi; knjiga; koprivnica; kosa; krov; kuća; liječnik; međunarodne; mladen pavković; molba; molbe i apeli; molbe za pomoć vukovarskoj bolnici; molga; nacionalni; naslov; natips; našli posljednje utočište; neljudskost; nepravda; omeđena publikacija; omot knjige; pad vukovara; papir; patnja; pedesetak molbi; pisma; plavo; podaci o odgovornosti; poginuli; pomoć; prikazuju stanje vukovarske bolnice; proredio; prozor; publikacija; ranjenici; rat; ravnateljica; razaranje; rečenice; riječi; ruka; sadržavati; sažetak; slika omota; slike; slova; stanje; strahote; sudeni; tekst; tijekom najtežih dana granatiranja grada; tijekom razaranja grada; tuga; uredio; vesna; vesna bosanac; vrsta; vukovar; vukovar 1991; vukovarska bolnica; zagrada; zagrade; zločin; žena
HPM-33037	4	33	domovinski rat; hrvatska vojska; obrana; vojska	barjak; bijela; bijela boja; boje; branitelji; crvena; crvena boja; domovinski rat; grb; hrvatska; hrvatska zastava; hrvatski grb; knežija; kockice; kvart; natpis; plava; plava boja; rese; resice; rukotvorina; svila; tkanina; trešnjevka; trobojnica; udruga; ustaška zastava; zagreb; zastava; zastava knežija; zlatna; zlatne resice; šahovnica
HPM-33176	5	44	domovinski rat; hrvatska vojska; obrana; oružje; vojska	boje; cijev; cijevi; copyright znak; cro; domovinski rat; granata; granate; grb; haubica; hrvatska; hrvatska vojska; hrvatski grb; hrđa; izložak; kotačić; maskirne boje; metak; metal; metalno postolje; metci; mina; mine; minobacač; municija; muzejski izložak; oružje; oznaka; oznaka za hrvatsko vlasništvo; ratni stroj; razaranje; skulptura; sprej; sredstvo za borbu; topovi; tromblon; vijak; vojnici; zelena boja; zeleno; čahure; čelik; šahovnica;

				željezo
HPM-89811	5	99	domovinski rat; mirovna misija; organizacija ujedinjenih naroda; un; unprofor	albanija; amblemi; argentina; belgija; bijela; bijelo; britanija; britanska zastava; copyright; finska; finski grb; francuska; francuska zastava; gana; globus; grb; grb gane; grb ujedinjenih naroda; grbovi; heraldika; hrvatska; hrvatski povijesni muzej; irska; irska zastava; italija; japan; jedinstvo; jordan; jordanska zastava; kamerun; kanada; kanadska zastava; kenija; kenijska zastava; kolumbija; kolumbijska zastava; kontinenti; kraljevstvo; logo; lovorov vijenac; luksemburški grb; luxembourg; makedonija; maslinova grančica; maslinove grančice; mađarska; meridijani; mir; njemačka; njemačka zastava; norveška; novi zeland; odličja; održavanje mira; oznake; plava; plava boja; plavo; poljska; poljski grb; pomoć; promatrači; pšenica; rumunjska; rusija; sad; savez; sigurnost; simboli; strani vojnici; ujedinjeni narodi; ujedninjeno; un; unicef; united nations; united nations protection forces; unprofor; velika britanija; vojni amblemi; vojni grbovi; vojničke oznake; wales; zastava; zastava ujedinjenih naroda; zastava usa a; zastave; zastave zemalja; zastave zemalja svijeta; zaštitne snage ujedinjenih naroda; zemlje svijeta; zemljovid; znak un a; znak unprofor a; značka; značke; članice; španjolska; švedska; švedski grb
HPM-90134	4	68	agresija; domovinski rat; hrvatska kostajnica; stradanje	bol; cesta; cigla; cigle; copyright; dimnjak; drveće; drvo; genocid; hrvatska kostajnica; hrvatski povijesni muzej; izgnani narod; izlog; kapija; krov; krovovi; kuća; kuće; kućni broj; lampe; lokva; mokra cesta; nadstrešnica; napušten; napuštena ulica; natpis; natpisi; nebo; nip; noge; pas; pasji rep; prazne ulice; prognanici; prozor; prozori; pročelja kuća; pusti grad; pusto mjesto; pustoš; rat; razaranje; reklame; rep; rina; selo; siromaštvo; stara kuća; stare fasade; stare kuće; staro; tenda; trgovina; trošno; tuga; ukras na prozoru; ulica; ulica grada u kojoj je netom završio rat nema ni žive dušeosi; ulice; ulična svjetiljka; uresi; vrata; vukovar; zid; šaht; šarplaninac; šuma; žica
HPM-90142	4	67	civili; domovinski rat; prognanici; stradanje	agresija; auto; automobil; automobili; bake; bijeg; brada; brdašce; brdo; brežuljak; cesta; djeca; dječak; domovinski rat; gumene čizme; haljine; hrana; isljeavanje; izbjeglice; izbjeglištvo; izbjelice; kamion; kapa; kolona; ljudi; ljudi u bijegu pred ratom prognni sa svojih ognjišta; majke; marame; migracije; mladi; muškarac; napuštanje doma; nasilje; odlazak; odlaze u nepoznato; osobni automobil; pregača; prognanici; prognanici koje smještaju negdje na moru; progon; progranici; prtljaga; put; puška; pušta; rat; rubac; ruksak; sandale; spas; stanovništvo; starci; starica; starice; strah; torba; torbe; veste; vojnici; vojnik; vojska; vozila; vrećice; zbijeg; zima; štap; žene
HPM-90145	5	84	domovinski rat; hrvatska vojska; obrana; pobjeda; vojska	automobil; bomba; borac; bore na licu; borovi; branitelj; cigareta; civil; civili; crno bijela slika; dolazak pobjedničke vojske u selo; domovinski rat; drveće; drvo; dugmad; dva prsta; džemper; džep; frizura; frizura mavrović; granata; granata u džepu; granatam naušnica; gumb; hrabrost ratnika; hrvatska; hrvatski vojnik; indijanci slave rat; irokeza; jezik; košulja; kuća; kuće; lišće; ljudi; mir; mitraljez; mladić; muškarac; nadanje; naočale; narukvica; nausnica; odora; oružje; osmijeh; osmjeh; pištolj; pobjeda; ponos; požrtvovnost; prolaznici; prolaznik; prozor; prozori; prsluk; prsti; pulover; puška; radost; raketa; rat; ratnik; ruke; sako; sat; sigurnost; sijeda kosa; slavlje; sretni ljudi; sreća; starac; tip s naušnicom; tri osobe; tromblon; uniforma; veselje; vojnik; zadovoljstvo; znak mira; čin;

				čovjek; šuška; žbunje
HPM-90163	9	64	agresija; domovinski rat; građanski otpor; jna; jugoslavenska narodna armija; osijek; otpor; stradanje; vojska	1991; 27lip; agresija; auti; auto; automobil; barikade; bijelo; borba; brojevi; cesta; copyright; crveni fićo; domovinski rat; fijat; fićo; fotografija; gaženje; grayscale; gubitak; hrvatski povijesni muzej; jna; jugić; kotači; ljudi; motion blur; muzej; napad; naslov; nebo; nevoljkost; osijek; otpor; peglica; povijest; početak domovinskog rata; prolaznici; prozori; rat; registracija; registracijska tablica; sadizam; sivo; slova; srbi; staklo; sudar; sukob; suti; svjetla; tenk; tenk gazi fiću; tenk i fićo; točkovi; ulica; uništavanje; uništenje; vojna sila; zgaženi fićo; zgrada; zgrade; šteta; život; žrtva
HPM-90558	6	106	bosna i hercegovina; domovinski rat; logor manjača; logoraši; manjača; zarobljenici	bandere; beznađe; bol; borba; cesta; copyright; crne majice; crno bijelo; domovinski rat; drveće; duge majice oko struka; glad; grm; grupa; hlače; hod; hrvatski povijesni muzej; jad; kazna; kolona; kontrast crne i bijele boje; košulje; koža; kratka majica; kriz; križanje; križevi; križni put; livada; ljeto; ljudi; logor; logoraši; lubanja; majica; majice; mladići; muškarac; muškarci; napor; neizvjesnost; nečija djeca; noge; nokti; nos; nosevi; obrijane glave; obrijani; odijela; odjeća; ograda; oko; očaj; oči; patnja; pijesak; pješačenje; podčinjenost; pognute glave; polja; polje; poljski put; povorka; prisila; proćelavi; prsti; put; rad; radnici; rana; rat; ratni zarobljenici; ratni zatvorenici; ratnici; razočaranost; robija; ruke; savac; sjene; skupina; smrt; stradanje; struja; stup; stupovi; sunce; suze; suša; trava; tuga; uho; usta; uši; vojnici; vruće; vrućina; zarobljenici; zatočenici; zatočenik; zatvorenici; zavezani; znoj; ćelavi; čovjek; žega; žrtvovanje
HPM-90662	7	93	baranja; bol; civili; domovinski rat; patnja; prognanici; stradanje	baka; balkon; beznađe; bol; bolest; bore na licu; briga; brkovi; dijete; djeca; djevojka; djevojčica; dječak; dječak s majkom; dječje lice; domovinski rat; dragovoljac; gubitak; gumu kamiona; informacija; izbjeglice; iščekivanje; jad; kosa; kotač; kćer; kći; lice; ljubav; ljudi; majica; majka; maramica; maramica kosa; maramicu u ruci; muškarac s brkovima; muškarci; nausnica; naušnice; naušnice u ušima; nos; nošnja; obitelj; ograda; oko; otac; plač; pletena majica; pogibija; pogled; pogledi; povezanost; prepoznavanje; profil; prozor; prsti; pruge; rastanak; rat; razaranje; roditelji; ruka; ruku preko ustiju; rupčić; sin; sjena; smrt; stara koža; strah; stupici; suknja; susret; suze; tišina; tragedija; tuga; tupi pogled; uagrljaj; uho; umor; unuka; uplakanu majku; utjeha; užas; vojnik; vrata; zabrinutost; zagrljaj; zgrada; žalost; žena; žene; ženu u narodnoj nošnji
HPM-90791	7	121	civili; djeca u ratu; domovinski rat; hrvatska vojska; osijek; stradanje; vojska	agresija; asfalt; auto; automobil; automobila; bijeg; bježanje; bojišnica; bomba; bombardirana kuća; bombardiranje; branitelj; civili u ratnim stradanjima; copyright; crno bijela fotografija; crno bijelo; dan; destrukcija; dijete; dim; dimnjak; djete; dječak; domovinski rat; duga sijena; egzodus; evakuacija; fasada; fotografija; geleri; genocid; granate; građa hrvatskog povijesnog muzeja; hrabrost; hrvatska vojska; hrvatski povijesni muzej; izbijeni prozori; kaciga; kamenčići; krater; krhotine; krov kuće; kuća; lens flare; lim; ljubav; ljudskost; mitraljez; muškarac; napad; nebo; neizvjesnost; ništavilo; odora; odsjaj; ograda; opasnost; oružje; ostaci auta; patnja; plakat; pobjeda; pomoć; prozor; prozori; pustoš; puška; rat; ratna stradanja; ratne posljedice; ratnik spašava dijete; razaranje; razbijeni auto; razlupani auto; razorene građevine; razorenost; razrovana cesta; razrušena kuća; razrušena zgrada; rešetka; rešetke; rupa; ruševina; ruševine; sjena; spašava dijete;

				spašavanje; srušena kuća; starica; stradanje; strah; strahote rata; sunčeve zrake; tuga; ulica; uništavanje; uništen automobil; uništena kuća; uništeni auto; uništeni automobil; uništenje; urušena kuća; uzbuna; užas; užurbanost; vojnik; vojnik i djete; vojnička kaciga; vukovar; zagrljaj; zbjeg; zgrada; zid; čizma; čizme; čizna; čovijek; čovjek; šljem; šteta; žurba
HPM-90875	9	83	civili; djeca u ratu; domovinski rat; hrvatska vojska; hrvatski vojnik; obrana; rastanak; vojnik; vojska	baloner; beba; branitelj; briga; cipela; dijete; djeca; dječja cipela; domovinski rat; donji dio trenirke; duda; džep; fotografija; gardist; gumbi; hlače; hrvatski branitelj; izbjeglice; jakna; kalašnjikov; kapa; kaput; ljubav; ljudi; lopta; maskirna odjeća; maskirna odora; maskirna uniforma; maskirne hlače; mitraljez; muškarac; nemoć; nevinost; nogometna lopta; obitelj; odlazak; odora; oproštaj; oružje; otac; ovisnost; oči; povezanost; puška; rastanak; rat; razdvajanje; ruka; ruksak; samoća; sigurnost; sin; skrivanje; strah; stup; sudbina; suosjećanje; tata; tenisice; torba; torbe; trenirka; tuga; uniforma; vesta; vezice; vijnička čizma; virenje; vjetrovka; vojni ruksak; vojnik; vojničke čizme; vojska; zagrljaj; zakrpa; zaštita; čekanje; čizma; čizme; čuvar; šipka; željezni stup; žena
HPM-90919	7	121	apel; bedem ljubavi; domovinski rat; jna; prosvjed; ročnici jna; vojarne	akcija; apel; bake; bedem ljubavi; boje; bol; borba; demonstracije; dijete; dlanovi; domovina; domovinski rat; drvo; dva prsta; fotografija; golubica; gužva; hrvatska; hrvatski povijesni muzej; izgubljeni sinovi; jedinstvo; jna; kosa; krunica; krunice; letak; lišće; ljudi; loša šminka; loše frizure; majice; majka; majke; majke stradalih u ratu; majčinska ljubav; masa; mir; miting; mnoštvo; molba; molitva; muzejska građa; muškarac; muškarci; nada; naočale; narukvica; natpisi; neknjižna građa; nestali; obitelj; ograda; okupljanje; očevi stradalih u ratu; plakat; plakati; plakati protiv rata; plava; pobjeda; podignute ruke; poginuli; pomoć; posljedice rata; potreaga; prosvjed; protest; prozor; prsti; pruge; rat; razočaranje; religija; roza; ruka u zraku; rukav; ruke; ruž; sat; satovi; sestre; sin; sinovi; skup; služenje vojnog roka; smrt; snaga; strah; suze; svijeća; svijeće; torba; torbe; trajna; transparenti; traženje oslobađanja zatvorenika; tuga; ubijeni; udovice; upornost; uzdignute ruke; v znak pobjede; vjera; vojni rok; vojnici; vratite nam naše sinove; vraćanje; vukovarke majke; zabrinutost; zagreb; zahtjev; zajedništvo; zelena; zgrada; zid; znak mira; zuta; zvijezde; šareni plakati; žena; žene; žene lišće
HPM-91229	5	114	domovinski rat; hrvatska vojska; obrana; pakrac; vojska	akcija; antena; antene; asfalt; bandera; bijeg; bježanje; bomba; bor; borba; borovi; branitelj; cesta; cipela; crijep; crijepovi; domovina; domovinski rat; drvena ograda; drveće; drvo; drvored; dvorište; električni stup; fotografija; front; garda; grana; hodanje; horizont; hrvatska; hrvatska vojska; hrvatski povijesni muzej; kaciga; kalašnjikov; kamen; kamenje; krov; krovovi; kuća; kuće; list; lišće; ljeto u ratu; ljudi; makadam; mitraljez; muškarci; naoružani vojnici; naoružanje; napad; naselje; nebo; neprijateljska paljba; nlo; oblak; obrana; ograda; okruženje; opasač; operacija; oprema; oružje; pazi granata; polje; položaj; povlačenje; projektil; prozor; prozori; pucanje; put; puška; puške; rasvjetno sredstvo; rat; ratište; ratna strategija; ratne igre; reklama; remen; ruksak; selo; skrivanje; slavonija; slika; smrt; snajperska paljba; stabla; stablo; stup; stupovi; trava; trpinska cesta; trčanje; ulica; uniforma; uniforma smb; uniforme; vojna akcija; vojne uniforme; vojnici; vojnici u bijegu; vojnik; vojska; vukovar; zaklon; čempres; čizme; čučanj; šljem; šljunak; šljunak vojnici; žica

HPM-91263	7	115	agresija; domovinski rat; prognanici; srpska vojska; stradanje; vojska; vukovar	armatura; auto; automobil; beskućnici; beton; bijeda; bijeg; bol; bolesni ljudi; bolnica; cesta; cigla; cigle; crno bijelo; dan; daske; domovine; dostojanstvo; fićo; genocid; grad; granatiranje; gubitak grada; gubitak nade; iseljavanje; izbjeglica; izbjeglice; izbjeglištvo; izgnanik; izrušeno naselje; jad; jak; jna; kamenje; kaput; kofer; kovčeg; krov; krovišta; krovovi; kuće; lijep; ljudi; mrcilište; muzej; muškarac; nada; napuštanje; nebo; neimaština; nemir; neprepoznatljivo mjesto; nesreća; odlazak; okupacija; olupina; olupina automobila; onemoćali ljudi; ostaci; ostatak; pad; pad vukovara; patnja; plač; polomljen; ponosan; prestanak uzbune; prognanici; prognanici napuštaju grad; prognanik; progonstvo; prometni znak; prozor; prozori; prtljaga; putnik; raketiranje; rat; ratno razaranje; razaranje; razbijeno; razoren grad; razoreni grad; razoreni vukovar; razrušavanje; razrušen; ruševine; siniša glavašević; siromaštvo; smrt; snaga; stanovništvo; starci; strah; stratište; stupovi; torba; trpinjska cesta; tuga; tužan; ulica; uništen automobil; uništeni automobil; uništeni domovi; vesna bosanac; vodotoranj; vojnici; vojska; vukovar; zapaljen; zgrade; četnici; čovjek; žalost; život
HPM-91415	4	86	agresija; domovinski rat; stradanje; zadar	akcija; automobil; betonska ograda; bolesno dijete; brkovi; cigle; crkva; dijete; dijete na slici; dim; domovinski rat; drvo; dvije žene; glava; gorući automobil; goruću automobil; grane; građevina; koji čita osmrtnice osmrtnice se nalaze na pročelju zgrade na; koncert; kosa; košulja; kriz; krov; krošnja; kuća; lišće; ljudi; mislim da se radi o morskom gradu; mnogo mrtvih; mrtav čovjek; muškarac; muškarac koji čita; muškatas; na slici koju je objavio hrvatski povijesni muzej vidim muškarc; najave koncerta; naočale; obavijesti; objava koncerta; oglas; oglasna ploča; oglasni pano na zidu kuće na njemu su zaljepljene osmrtnice; ograda; osmrtnica; osmrtnice; oči žene; plakat; plakati; plamen; poster; požar; prozor; prozori; prsluk; ptica; pukotine; put; putokaz; ranjenik; rat; rat pobijedio kulturu; razdjeljak; slike razaranja; smrt; smrtovnice; stablo; stradanje; stupici; te prikazi slika rata kako su škure u pozadini karakteristične; tlo; torba; trava; tuga; umrli; vatra; vrata; zgrada; zid; zid s osmrtnicama; znak; znatiželja; čovjek; čovjek čita osmrtnice; šaloporke; šaropoljke; škure
HPM-91474	5	129	civili; domovinski rat; prognanici; stradanje; zagreb	90 te; asfalt; auto; automobil; automobili; baba; baka; bakica; bijeg; bijeli fićo; cesta; cipele; crna boja; crna odjeća; crne skute; crnina; crno; crno bijelo; daleko od kuće; domovinski rat; drvo; dvorana; fakultet; fer; fićek; fićo; fotografija; gaće; gaće na štapu; grafit; grafit iza karte martinovka; grafiti; grana; gubitak voljene osobe; haljina; hrvatski povijesni muzej; invalidska kolica; invalidsko mjesto; iščekivanje; karta; kotač; kotači; krov; kumica; list; lišće; majka; marama; markinovka; martinovka; muzejska građa; natpis; neknjižna građa; noge; nogostup; nos; obitelj; obješeno rublje; odjeća; oglasna ploča; oči; papiri; parking; parkiralište; plakat; ploča; pločnik; pregača; prognanica; prognanici; progonstvo; prozor; prošlost; putokat; rat; ratno vrijeme; registarska tablica; registracijska oznaka; roba; rubac; rublje; rublje koje se suši; ruka; ruke; sjena; sjene; slova; smeće; smještaj; sport; sportska dvorana; spotr; stara žena; stara žena u crnoj odjeći; starica; starica u crnini; starica u crnome; staro; starost; strelica; strjelica; studentska sportska dvorana; studentska sportska dvorana martinovka; stup; suknja; susilo; sušenje; sušenje rublja;

				sušenje veša; tabla; tjelesni; tjelesni odgoj; tlocrt; trava; trenirka; tuga; usamljenost; veš; yo; zabrinutost; zagreb; zid; znak; znak za invalide; čekanje; štrik; žena; žene; žrtve
HPM-91563	6	80	agresija; domovinski rat; etničko čišćenje; lipik; srpska vojska; vojska	5 kozarska brigada; agresija; bombardiranje; brigada; broj; cigla; cigle; crno bijela fotografija; crvena zvezda; cuko; destrukcija; dimnjak; dokument; domovinski rat; fotografija; grafit; grafiti; grb srbije; greda; imena luda nalaze se svuda; jad; jna; jugoslavija; kratica jugoslavenske narodne armije; krhotine; kuća; kućni broj; mali pas u užasu rata; muzejska građa; nacionalizam; natpis; od koje je ostao samo zidna njemu su grafiti jna i četnika ispr; ostaci; palež; paljevina; paravojne postojbe; paravojska; pas; peta kozarska brigada; petokraka; petokraka zvijezda na zidu stare ruševne kuće; povijesna građa; požar; požarište; prozor; prozori; pukotina; rat; ratna razaranja; ratni grafiti; razaranje; rupa; rupe; rupe od metaka; ruševina; ruševine; simbol; simboli; skraćenica od jugoslavenske narodne armije; slova; smeće; sprej; srbi; srbija; srpska oružana pobuna; srpska pobuna; srušena zgrada; sukob; tuga; ulica; uništavanje; uništena kuća; zgrada; zid; znakovi; zvijezda; zvijezda petokraka; zvjezda petokraka; četnici; četnički znak
HPM-91649	4	56	domovinski rat; državnost; međunarodno priznanje; ujedinjeni narodi	0911 memorial centar; dokumenti; država; franjo tuđman; glave; grupa ljudi; hrvatska; ina; jarboli; kosa; kraj rata; ljudi; međunarodno priznanje; mir; moš; muškarci; nebo; neboder; neboderi; neovisnost; new york; nezavisnost; odijela; oduševljenje; otvorenje; pljesak; pobjeda; podizanje hrvatske zastave; podizanje zastave; politicari; politika; ponos; povijest; primanje u članstvo; priznanje hrvatske; prozori; sad; samostalnost; službena tijela; staklo; stup; stupovi; svečanost; trobojnica; ujedinjeni narodi; un; ustanove; visina; zastava; zastave; zelenilo; zgrada; zgrade; zlatna kugla; šahovnica; žena
HPM-91773	4	94	domovinski rat; hrvatska vojska; obrana; vojska	balkon; beretka; bljesak; borba; borci; branitelji; branitelji u domovinckom ratu; brigada; brkovi; cigla; cigle; crno bijela slika; crno bijelo; daske; deka; domovina; domovinski rat; dragovoljci; drveće; dvorište; fotografija; grb; grmlje; grupa vojnika; herceg bosna; hrvatska; hrvatska vojska; hrvatska zastava; hrvatski branitelji; hrvatski povijesni muzej; hrvatski povijesni muzeji; kapa; kape; knežija; kraj rata; krov; krpa; kuća; ljudi; mobilizacija; muzejska građa; muškarci; naočale; natpis na zastavi; neknjižna građa; obnova; obrana; odora; ograda; oluja; oslobođenje; p; pokrivač; položaj; pomoć; povijest; protivnici; prozor; prozori; rat; ratna odjeća; rolete; roletne; selo; skupina; slavonija; slikanje; sloboda; staja; staklo; stara kuća; staza; suborci; taktika; tepih; trava; trobojnica; uniforma; vojnici; vojno redarstvena akcija; vojska; vrata; vukovarski vojnici; zagreb; zajednička fotografija; zastava; zemlja; zločini; čizma; čizme; šahovnica; šakovnica; štala; štap
HPM-92298	8	80	apel; civili; domovinski rat; nestali; protest; stradanje; zagreb; zid boli	bandera; budućnost; cesta; cigla; cigle; cipele; domovinski rat; drveće; drvo; fotografija; grad zagreb; grupa; hodanje; hrvatski povijesni muzej; iščekivanje; kapa; lampioni; list; ljudi; muzejska građa; muškarci; narod; neizvjesnost; neknjižna građa; nestali; obitelji stradalih i nestalih; odjeća; odluka; ograda; okupljeni ljudi; organizator bedem ljubavi majke hrvatskih branitelja na svakoj c; pitanje; plava zastava; plač; poginuli; posjetitelj; povjesničar; povorka ljudi; počast; prolaznici; proljeće; prozor; prozori; ranjenih i poginulih osoba; rasvjetno tijelo; ratna razaranja hrvatska; red; selska; selska cesta; sjećanje

				na žrtve; spontani spomenik; stablo; strah; stup; stupovi; suknja; torba; traka; tuga; ulica; un; vojarna; vrata; zabrinutost; zagreb; zagreb izgrađen je ispred tadašnjeg sjedišta unprofor a i sad; zastava; zgrada; zid; zid bola; zid boli; zid boli u selskoj ulici; zid nestalih osoba; zid plača; zid plača zagreb; zid sjećanja; čekanje; članovi obitelji; žalost; žene
HPM-92475	5	96	civili; domovinski rat; humanitarna pomoć; humanitarnost; prognanici	austrija; bijelo; bijelu vreću; caritas; cerada; cipele; crno; daske; dijete; dječaci; domovinski rat; donacija; drvene palete; drvo; dva dječaka; dvorište; europaleta; felga; fotografija; glava; guma; gume; gumu kamiona; higijenske potrepštine; hlače; hrana; hrvatska dijaspora; hrvatsko iseljeništvo; humanitarna; humanitarna pomoć; izbjeglice; kamion; kaput; karton; karton na podu; kontenjer; kosa; kotač; kotači; krov; krov kuće; kutije; kuća; lica; ljude u redu; ljudi; ljudi bez domova; majica; marama; metalnu ogradu na kojoj su plakati; milosrđe; mladići; muzejska građa; muškarci; nasmijanu ženu; natpis; natpisi; neknjižna građa; obješen kaput; odjeća; ograda; ogradu na kojoj dječaci sjede; opskrba stanovništva; osmijeh; osmjeh; paleta; palete; plakat; plakat caritasa; plakati; podjela humaniratne pomoći; pomoć; preživljavanje; prikupljanje pomoći; prognanici; prozor; pulover; rad; rat; reklama; ruka; slika; slova; starac; stari ljudi; starije osobe; stariji ljudi; strana pomoć; susjed u nevolji; uho; volonteri; vreće; zajedništvo; zid; žena; žene
HPM-92902	5	75	agresija; domovinski rat; otpor; stradanje; vukovar	1991; auto; automobil; buba; cigla; copyright; crno bijelo; domovinski rat; drveće; drvo; eksplozija; grad heroj; hrvatski povijesni muzej; jakost; jesen; kataklizma; korov; krhotine; krov; kuća; lišće; makadam; mitnica; nebo; nema života; ogoljela stabla; olupina; olupina auta; olupina automobila; osušeno drveće; ovčara; oštećeni toranj; poraz; prošlost; pustoš; put; raketiranje; rasturena buba; rat; ratna ikebana; ratna razaranja hrvatska; razaranje; razoreni vukovar; razrušeni grad; rupe; ruševina; ruševine; ruševinu; rušine; simbol borbe; simbol otpora; simbol patnje; simbol rata; simbol stradanja; slavonija; spomenik; srbi; srušena kuća; stari auto; stradanja; stup; trava; tuga; uništavanje; uništeni automobil; uništeno drveće; usamljenost; vodotoranj; vodotoranj u vukovaru; vukovar; vukovarski vodotoranj; vw buba; šteta; žbunje; život
HPM-93005	6	79	akcija oluja; domovinski rat; hrvatska vojska; oluja; pobjeda; vojska	1995; auta; auti; auto; automobil; automobili; balkon; biljka; borac; branitelj; cesta; cipela; dobrovoljci; domovinski rat; drvaće; drvena ograda; drvo; garda; gardijska brigada; glava; grad; hrvatska; hrvatska vojska; hrvatski vojnik; izlog; kalašnjikov; knin; ljudi; lokva; mitraljez; nadstrešnica; natpis; nebo; neobična registarska pločica; ograda; oluja; oružje; oslobođenje; oslobođenje knina; osmijeh; palma; pločnik; pobjeda; ponos; povratak; prozor; prozori; puška; rat; ratnik; registarska tablica; registracija; ruka; ruke; semafor; slavlje; sloboda; sreća; stakleni izlozi; stup; tablica; tenda; terorist; trgovina; ulica; ulica u kninu; ulična svjetiljka; uniforma; veselje; vojnici; vojnik; vojnik hrvatske vojske; vojska; vozila; vrata; zgrada; zgrade; čizma; žica
HPM-93195	7	54	agresija; apel; domovinski rat; hrvatski crveni križ; saborsko; stradanje;	1991; agresija; apel; apel za pomoć; bijela boja; brojevi; brojke; crta; crveni; crveni križ; dan; datum; dokument; domovinski rat; dopis; dr; ekvakuacija stanovništva; evakuacija; godina; hrvatska; hrvatski povijesni muzej; izvještaj; javornik; korespodencija; korespodent; kriz; krug; latinica; lista; lista rada; nenad; obrana; ogulin; papir; pečat; pomoć; potpis; rada; rat; razaranja; rub; sabor; saborsko; saborsko u okruženju; slova; stalni

			ubojstvo	napadi civilnog stanovništva; stanje; tablica; telegram; zatezalo; zeljko; znak križa; štambilj; žig
HPM-93196_42	8	104	agresija; apel; bolnica; domovinski rat; stradanje; vesna bosanac; vukovar; vukovarska bolnica	1991; adresa; apel; armija; artiljerijsko naoružanje; bebe; bestijalnost agresora; beznađe; bolnica; bolnica vukovar; bombardiranje; bosanac; branitelji; brojevi; brojke; civilna žrtva; datum; djeca; dokument; dokument o napadima na medicinski centar vukovar; domovinski rat; dopis; dr v bodanac; dragovoljci; evakuacija; granatiranja; grb; hipokrat; hitna intervencija; hrabrost; hrvatska; inkubator; intervencija; izvještaj; jna; liječnici; logo; logo medicinskog centra vukovar; medicina; medicinska oprema; medicinski centar; medicinski centar vukovar; medicinsko osoblje; memorandum; molba; molba za pomoć; molbu; napad; napadi; napadi na bolnicu; naslov; nedonošće; neprestana paljba; novorođenčad; obavijest; obrana; okupirana bolnica u vukovaru; operacije; opis; opis vukovarske bolnice; oružani napadi na bolnicu; ostavljeni; očaj; paljba; pečat; pismo; pismo doktorice bosanac; pismo iz vukovara; podaci; pomoć; potpis; poziv u pomoć; poziv upomoć; poziv za pomoć; požari; ranjenici; ranjenik; rat; razaranja; rađanje nedonošćeta; ruka; simbol; slova; spas; sramota civilizacije; strah; strahote rata; studeni; tekst; tiskana slova; titula; trudnice; urušavanja; vapaj u pomoć; vesna bosanac; voda; vojnici; vukovar; zdrastveno stanje; zmija; znak; žene; žig; život
HPM-93201	4	46	domovinski rat; jna; jugoslavenska narodna armija; vojska	bijela pozadina; bre; crvena petokraka na šljemu; crvena zvezda; crvena zvijezda; domovinski rat; eksponat; glava; građa hrvatskog povijesnog muzeja; jna; jna šljem; kaciga; kopča; maslinastozelena boja; muzejski izložak; muzejski predmet; natpis hrvatski povijesni muzej; obrana; odora; partizan; partizani; petokraka; predmet; rat; simbol copyright; snb; srbija; stalak; traka; traka za vezivanje šljema; vojna kaciga; vojna oprema; vojni šljem iz doba jna; vojnik; vojnički šlljem; vojska; zašita glave; zelena; zelena vojna boja; zeleni šljem; zvijezda; zvijezda petokraka; šipka; šljem; šljem jugoslavenske vojske na stalku; štap
HPM-93218	4	55	agresija; domovinski rat; stradanje; vinkovci	adresa; baština; bijela; bijela boja; bijela crta; copyright; crna; domovinski rat; geleri; glagoljaška ulica; granatirano; hrvatski povijesni muzej; hrvatsko pismo; hrđa; ime; ime ulice; latinica; lokacija; meci; metak; muzej; natips; natpis; natpis ulice; naziv; naziv ulice; oštećenja; oštećenja od metaka; oštećenje; plava; plava boja; plava tabla; ploha; ploča; ploču; protiv glagoljice; pucanje; rat; razaranje; rub; rupa; rupe; rupe od metaka; slova; tabla; tablica; ulica; vinkovci; vukovar; znak; znak za copyright; znak za naziv ulice; znak za ulicu; čavao; šrapnel
HPM-93220_1_2-6	6	106	agresija; domovinski rat; knjižnica; kultura; stradanje; vinkovci	baština; bibliotečka građa; bijela; bijele knjige; bijeli stolnjak; bijeli zid; bilješke; bogorodica; bombardiranje; brod; cenzura; divota prašino; djevica marija; dječja knjiga; dječja knjiga posljednja igra; dječje knjige; dokumenti; druga dječja knjiga čiji naslov ne vidim ali istog izdavača k; evidencijski karton; garež; gori; gospa; ilustrirane knjige; istrgane i poluspaljene listove različitih knjiga; isus; izgoreno; izgorjele knjige; izgorjeli listovi; izgorjelo; jedrilica; karton; knjiga; knjige; književnost; knjižni listić; knjižnica; knjižnična građa; korice; kulturna baština; kulturocid; lektira; list; listovi; ljudi; majka božja; marija; muzej; nabožna ilustracija posljednje večere; nagoreni listovi; nagorjele

				stranice; naslov; natpis hrvatski povijesni muzej; nesreća; obezvrjeđivanje; ostaci; oštećene knjige; palež; paljba; paljenje knjiga; paljevina; papir; papiri; pepeo; pepeo od knjiga po stolnjaku; plava; podloga; posljednja igra; posljednja igra dvije knjige; požar; rat; razorene knjižnice; religija; rečenice; riječi; sitna slova; siva; slika; slika blažene djevice marije i malog isusa; slova; spaljena knjiga; spaljene knjige; spaljeni papiri; spaljenje knjige; spaljeno; spašeni; sramota; stol pokriven stolnjakom; stranica; stranice; sveta marija; sveta slika; svetogrđe; tekst; uništavanje; uništena baština; uništene knjige; uništenje; uništeno; vandalizam; vatra; zapis; zločin; znak za copyright; znanje; zuta; čađa
HPM-93345	4	71	civili; civilna zaštita; domovinski rat; obrana	1990; civilna zaštita; crna boja; dan; datum; deka; dokument; dom; domovinski rat; dopis; efemerna građa; godina; grad; grad zagreb; građanstvo; hrana; hrvatski povijesni muzej; ime; ime grada; ime i prezime; ivan parać; letak; mala slova; mjere u slučaju opasnosti; mjesec; muzejska građa; narančasta boja; naslov; neknjižna građa; obavijest; obavijest građanima; opasnost; opća opasnost; papir; piramida; pismo; piće; plin; ponašanje; prezime; proglas; rat; ratna opasnost; ratno stanje; savjeti; sigurnost; sitni tisak; sklonište; službeni dokument; smeđi papir; spis; stanovništvo; tekst; tranzistor; trokut; upite za ponašanje u slučaju zračnog napada; upozorenje; upozorenje građanima; upute; upute ponašanja za vrijeme rata; upute za postupanje; uzbune; velika slova; vojska; zagreb; zapovjednik; zaštita; zelena boja; zeleni trokut; zračna opasnost; zvuk sirena
HPM-93372	7	62	civili; domovinski rat; ilok; okupacija; poljoprivredni radovi; republika srpska krajina; srbi u hrvatskoj	1992; administracija; brojevi; cenzurirani tekst; crta; crte; datum; devedeset i peta; dokument; dokument o kontroli kretanja; dozvola; dozvola za kretanje vozilom; dušan madžarev; godina; hrvatski povijesni muzej; ilok; ispravljani tekst; komandant; komandant mesta ilok; list; list papira; lična karta; neispunjena polja; nečitko; nožnost; odobrenje; opis; oznaka za copyright; papir; pečat; pisača mašina; plava kemijska; plava tinta; poljoprivredni radovi; posao; potips; potpis; potpisi; potpukovnik dušan hadžarev; potvrda; pozadina skenera; preklop; prekrižena polja; propusnica; propusnica za osobu i vozilo; rat; razderotina; registracija; relacija; sati; skenirani dokument; slova; tip vozila; titula; uši na rubu stranice; verifikacija; vlastoručni potpis; vojni dokument; vozilo; vrijeme; vukovar; žig
HPM-93410	6	84	australija; domovinski rat; humanitarna akcija; humanitarna pomoć; humanitarnost; iseljeništvo	austraija; australia; australija; bijeg; bog; briga; dijaspora; djeca; dobročiniteljstvo; dolari; domovina; domovinski rat; dopisivanje; dopisnica; emigranti; fotokopija; garderoba; graz; hrabrost; hrana; hrvati; hrvati u australiji; hrvatska; hrvatski piknik; imigranti; informacija; informacije; inozemstvo; iseljavanje; iseljenici; isječci iz novina kao informacija o ratu u hrvatskoj; izrezak; korespondencija; ljubav; ljudskost; melbourne; melburn; metkovec; metković; metkovčani; migracije; mir; molitva; molitva za mir; nada; naši ljudi; novci; novine; novinski clanci; novinski isječci; novinski članak; obavijest; oglas; patnja naroda; pisma; pismo; pismo podrške; pismo vesni; podrška; pomoć; pomoć stradalima; poruka; posljedice rata; pozivi na iseljavanje u australiju; pressclipping; prijatelji; put; rat; riječi; rukopis; sakupljanje potrepština; skupljanje priloga za pomoć hrvatskoj; solidarnost; spašavanje; sydney; torte; useljavanje; utjeha; vjera; zagorci; zagorje; članak; članci; želja za mirom

HPM-93511_av	7	90	crveni križ; domovinski rat; logor stajićevo; logoraši; srbija; srpski logori; vukovar	adresa; adresa stanovanja; adrese; bijeli papir; bilješke; birokracija; briga; britanski crveni križ; broj; broj dokumenta; brojevi telefona; brojke; crna tinta; crvena tinta; crveni; crveni križ; crveno; daljina; datum rođenja; dokument; dokument crvenog križa; formular; francuski; geneva; grada zagreba; hrvatski; i u muci ne odajemo godine; ime; ime oca; imena; inozemstvo; jakob; kenigskneht; kriz; lijep rukopis; logo; logo crvenog križa; međunarodni komitet crvenog križa; nada; nedostajanje; novac; obavijest; obitelj; otpusno pismo; oznaka za copyright; papir; pečat; pismo; pismo iz caritasa; plava tinta; podaci; pomoć; poruka; poruka crvenog križa; poruka crvenog krsta; potvrda; pozadina skenera; pošiljalac; pošiljka; pošta; prazne crte; preklop; prezime; primatelj; proletarska divizija; rat; rodbina; rukopis; slanje; slova; službeni dokument; spol; srpski; stari poštanski broj; stari poštanski broj grada zagreba; tekst; telefon; telefonski brojevi; trojezično; udaljenost; vesna; vesna kenigsknecht; vladimir; vladimir kenigskneht; vukovar; zagreb; zahtjev; zaokruživanje; znak; ženeva
HPM-93511_rv	7	78	crveni križ; domovinski rat; logor stajićevo; logoraši; srbija; srpski logori; vukovar	1991; bol; branitelj; brat; briga; brojevi; brzojav; datum; datuma 02121991; dijete; domovinski rat; dvojezični obrazac poruke crvenog križa; glad; izbjeglica; iščekivanje; list; ljubav; logor; mama; mucenje; muka; nada; natpis; nesreća; obavijest; obitelj; odgovor; odgovor na poruku; ohrabrenje; olakšanje; osobno pismo; papir; patnja; pismo; pismo bratu; pismo koje piše brat bratu da su on i tat uredu i moli brata da; pismo pomoći; plava boja; poruka; poruka brata vladimira kenigsknehta; poruka osobne prirode; potpis; potraga; potraga za mamom i sekom; pozdrav; prognanici; rat; ratni zarobljenici; ratno pismo; ratno zarbljeništvo; razdvojena obitelj; riječi; rukopis; seka; sin; slova; smrt; srbija; stajićevo; strah; tata; tekst; tragedija; tuga; vijesti; vladimir; vojni logor; vojni zatvor; vojni zatvor stajićevo; vojni zatvor u stajićevu; zabrinutost; zarobljenik; zarobljeništvo; zatočenici; zatočeništvo; zatvor; zima; zrenjanin
HPM-93517_av	7	88	domovinski rat; logoraši; logori; srbija; sremska mitrovica; srpski logori; vukovar	1; 11; 12; 1991; 1992; 2; 3; 4; arapski brojevi; bol; borba; brojevi; brojke; brojke i slova; dani; dani u tjednu; datum; datumi; devedesete; devedesete godine; domovinski rat; drugi; dvanaesti; godina; godine; ime; imena; jad; jedanaesti; kalendar; kalendar nadanja; kalendar zarobljenika; kazneni popravni dom; kazneno popravni dom mitrovica; kazneno popravni dom sremska mitrovica; kenigskneht; kocka; kockice; kratice; križaljka; krug; kvadratići; logor; mitrovica; mjeseci; mjeseci u godini; mobilizacija; nada; nadanja; nadanje; obitelj; odbrojavanje; osobni kalendar; oznaka; ozujak; papir; plava boja; plava kemijska; prezime; prosinac; prvi; rat; retci; rimski brojevi; rukopis; sijecan; siva boja; sloboda; slova; sremska mitrovica; srijemska mitrovica; stefan i vladimir kenigskneht; studeni; stupci; tablica; tekst; travanj; treći; tuga; vjera; vojnici; zaokruženi brojevi; zapis; zatvorski kalendar; čekanje; četvrti; želja; žrtvovanje
HPM-93531_av	11	85	bosna i hercegovina; domovinski rat; hrvatska kostajnica;	aktivnost; bijela pozadina; brojevi; brojke; cijelo; crni okvir; crvena boja; crveni natpisi; dani; disciplina; dnevnik zarobljeništva; domovinski rat; ime; imena; imena i prezimena vojnika; imenik; inventar; kasarna; kolona s imenima i prezimenima vojnika; kolona s rednim brojevima; kopanje rova; kratice; krumpir; kupovina; lista; margetić; marljivost; meni; muzejski izložak hrvatskog povijesnog muzeja; namirnice; natpis hrvatski povijesni

			hrvatska vojska; logor; logor manjača; logoraši; manjača; srpski logori; vojska; zarobljenici	muzej; neka evidencija; neuredna evidencija unutar kolona s brojkama i simbolima; neuredno iscrtane kolone; niz simbola zaduženja; ovce; papir; penkalo; pisano; plava boja; plavi natpisi; podaci; podjela; popis; popis osoba; popis poslova; popis zaduženja; poslušnost; pravo; prehrana; prezime; prezimena; prodaja; rad; radna lista; radni zadatci; ranjeni; raspored; raspored vojnika; ratni raspored; ratni zarobljenici; različite brojke; različiti isparavci na listu papira; red; ručak; ručno ispisani list papira; schindlerova lista; slova; snijeg; spisak imena; spol; tablica; uvjeti; vojarna; vojni popis; vojnici; vojska; znak za copyright; čišćenje; čišćenje snijega; črčke; šifre; šuma; šunka; žuto
HPM-93549	8	95	domovinski rat; igra; logoraši; srbija; sremska mitrovica; srpski logori; vukovar; zvonko herceg	16 pijuna; 2 kralja; 2 kraljice; 4 konja; 4 kule; 4 lovca; antikvitet; bijela kraljica; bijela polja; bijela pozadina; bijele kule; bijeli; bijeli konji; bijeli kralj; bijeli lovci; bijeli pijuni; bijeli šahovski pijuni; bijelo; copywright hrvatski poivjesni muzej; cretži šahovskih figura na pergamentu; crna kraljica; crna polja; crne kule; crni; crni i bijeli; crni konji; crni kralj; crni lovci; crni okvir; crni pijuni; crni šahovski pijuni; crno; crtež; crtež šahovskog polja na pergamentu; dama; dokolica; društvena igra; drvena ploča; drveni šah; figure; grb; igra; improvizacija; karton; kasparov; kockice; konj; kralj; kraljica; kula; kvadrati; kvadratići; list; list papira; logička igra; lovac; muzej; muzejski izložak; nadmudrivanje; natpis; natpis hrvatski povijesni muzej; nbpi; papir; pergament; pijun; pijuni; pješaci; platno; ploča; polja; povijest; prva; prva prloča za šah; razbibriga; razmišljanje; ručna izrada; ručni rad; skakač; stara; stara ploča za šah; strategija; tabla; tabla za šah; taktika igre; top; topovi; unikat; znak copyrighta; čuva se u muzeju; šah; šah platno; šahovnica; šahovska ploča; šahovske figure; šahovsko polje
HPM-93578	4	85	domovinski rat; hrvatska vojska; obrana; vojska	1 brigada; 1 brigada tigrovi; 1 gardijska brigada; 1 gardijska brigada tigrovi; amblem; amblem brigade; amblem vojske; amblem za vojnu odoru; aplikacija; bedz; bijela boja; branitelji; brigada; brigada koja se borila u domovinskom ratu; brkovi; brojevi; crna boja; crtež; crvena boja; domovinski rat; gardijska brigada; gardisti; grb; grb prve brigade tigrovi; griva; hrvatska; hrvatska vojska; hrvatska zastava; hrvatske oružane snage; hrvatski grb; hrvatski povijesni muzej; hrvatski vojnici; jezik; kljove; krzno; lav; logo i brigade; logotip; lđ; modra boja; muzejska građa; muzejski izložaj; naziv; njuška; obrana; oluja; oslobođenje; oznaka; oznaka brigade; oznaka tigrova; oznake; oči; očnjaci; ponos; prišivak; prva brigada; rat; ratište; redni broj jedan; republika hrvatska; slova; slovo u; split; tekstil; tigar; tigrovi; tkanina; uši; vojna formacija; vojna jedinica; vojni amblemi; vojnici; vojnik; vojska; zagreb; zbor narodne garde; zbor narodne garde republike hrvatke; zbor narodne garde republike hrvatske; zng; znk; zubi; zvijer; šahovnica; štit; žuta boja
HPM-93662	4	111	domovinski rat; hrvatska vojska; obrana; vojska	2 brigada; agresija; akcija grom; amblem; amblem gromova; artefakt; bijela; bijela boja; bijela pozadina; bijelo; bljesak; branitelji; brigada; brigade; broj; brojevi; brojka 2; crni okvir; crtež; crvena; crvena bijela plava boja; crvena boja; crveno; domovina; domovinski rat; druga; druga brigada; epoleta; gardijska brigada; grb; grb vojne brigade; grom; gromovi; groomovi; heraldika; heroji; hrvatska; hrvatska zastava; hrvatski; izložba; jačina; ljubav; logotip; munja; muzej; nada; naljepnica; natpis; natpis 2 brigada zng rh; natpis grom; natpis hrvatski povijesni muzej; naziv; neizmjerno; nepopravljivo; nikat; nokat;

				obrana; oluja; oružane snage; osjećaj; oznaka; palac; plava; plava boja; plavo; poletnost; ponos; povijesni; povijest; poštovanje; prišivak; propaganda; prst; prsti; ptsp; pume; rat; razgledanje; razmatranje; republika; republika hrvatska; ruka; simboli munje; slova; snaga; stisnuta šaka; stradanja; tablete; terapije; teror; tigrovi; točkice; trobojnica; udarac; učenje; vojne operacije; vojnici; vojska; zastava; zaštini znak brigade zng rh; zaštita; zbor narodne garde; znak; znak copyrighta; znak munje; zuta; čaka; šaka; žrtve; žuta boja; žuto
HPM-93728	10	47	britanski crveni križ; crveni križ; crveni polumjesec; domovinski rat; echo; europska zajednica; humanitarna pomoć; humanitarnost; izbjeglice; prognanici	bijeda; bijela traka; britanija; britanski; britanski crveni križ; british red cross; crvena; crvena linija; crveni križ; crveni mjesec; crveni polumjesec; domovina; društvo; hrana; humanitarizam; humanitarna; humanitarna pomoć; international federation of red cross and red crescent societies; izgladnjeli; japan; kartonska kutija; katastrofa; kriz; krpe; kutija; maramice; medicina; mjesec; narod; otvorena kutija; paket; paket pomoći; polumjesec; pomoć; potrgana kutija; prva pomoć; ranjenici; samoljepljiva traka; selojtep; selotejp; smeđa traka; spas; strah; strgano; velika britanija; vrveni križ; zavoji
HPM-93737	5	74	domovinski rat; hrvatska vojska; prehrana; vojni obrok; vojska	asepsol; asepsoleta; bar kod; bijela; bijla pozadina; bomboni; bonita; caritas; cjelodnevni obrok; cjelodnevni obrok hratske vojske; cjelodnevni obrok hv 1; crvena; desert; desertna čokolada; dnevni obrok; domaća proizvodnja; domovinski rat; energija; eurokrem; govedina; goveđi narezak; higijenskim potrepštinama; hrana; hrans; hrvatska zastava; hrvatski proizvodi; humanitarna pomoć; humanutarna pomoć u hrani; junetina; juneća pašteta; karitas; keks; keksi; kinderlada; konzerva; konzerve; krava; kutija; limač; lino lada; mesni doručak; namaz; namirnice; napitak; narezak; natpis; obrana; obrok; paket; paket iz karitasa; paketić; pašteta; pekmez; podravka; poklon paket; pomoć; pozadina; rat; ratne rezerve; račun; selotejp; slatkiši; slatko; sol; uzbuna; vlažna maramica; vlažne maramice; vojnik; woodland maskirni uzorak; woodland uzorak; zuta; čokolada; čokolade i igara; čokoladica
HPM-93764	10	82	bata; domovinski rat; hrvatska vojska; logor; logoraši; sremska mitrovica; srpski logori; tvornica bata; vojska; vukovar	američke vojne cipere; bez; bez vezica; blatnjave; blato; boja ilovače; cipele; dotrajalo; dvije visoke muške cipele bez vezica; fleke; gležnjače; gležnjerice; guma; hodanje; istrosena obuca; istrošene cipele vjerojatno su pripadale nekom vojniku; istrošenost; iznošene; iznošene cipele; iznošeno; jezici; jezik; konac; koža; kvalitetno; metalna oka; moderno; mrlje; muka; muškarac; nema znirance; nošeno; ofucane; opšav; otpad; par cipela bez spigeta; par gležnjerica; pete; poderane; poderotine; poghabano; pohabane; potrošeno; prljave; prljave cipele; prljavo; prošiveno; rabljeno; raspadnuto; ripne; rupice; siromašno; smedje; smeđa; smeđe; stare; stare cipele; staro; strgane; svevremenski; teren; teško stanje; timberland; timberlandice; tuga; uništene; uništeno; vezice; visoke cipele; vojnicke cipele; vojničke čizme; vojska; zimske cipele; čizme; čizme bez gospodara; đon; đonovi; šare; šavovi; škornje; žniranci; žuto

HPM-95097	4	69	apel; domovinski rat; institut ruđer bošković; nobelovci	agresija; antiratni apel; apel; apel za mir; apel za mit u hrvatskoj; appel za mir u hrvatskoj; bijeli papir; bombardiranje; broj faksa; dokument; domovinski rat; drugi; engleski jezik; faks poruka; georges köhler; hrvatska; humaniratna pomoć; humanitarna pomoć; humanitarne organizacije; humanitarnost; ikonica za telefon; imena; indiferentnost; izumiranje; jean marie lehn; jugoslavija; latinski; linus pauling; lista; max perutz; medicine i nobelovca za mir za pomoć hrvatskoj koja je napadnut; međunarodni apel za mir; mir; mir u hrvatskoj; mirovni sporazum; molba; nobelova nagrada; nobelovci; opasnost; papir; peticija za mir u hrvatskoj; pismo; pomoć; poruka; potpisi; potpisi znanstvenika iz područja kemije i medicine; potpisnici; poziv; poziv na mir u hrvatskoj; poziv u pomoć; pregovori; primirje; puno potpisa; rat; razaranje; robert huber; rukopis; slova; solidarnost; susumu tonegawa; tekst; tekst na engleskom; titule; tj pismo nobelovaca s područja kemije; vlada; vladama zapada i istoka; vladimir prelog; william lipscomb; zagreb
HPM-96554	6	58	caritas; domovinski rat; humanitarna akcija; humanitarna pomoć; humanitarnost; vrbovsko	aktivisti; caritas; crte; crvena slova; crveno; datum; datumi; dječja hrana; dječji zimski odjevni predmeti; dobrotvorne svrhe; dobrovoljni prilozi; domaćinstva; domaćinstvo; domovinski rat; donacije; građani; gubici; higijenske potrepštine; hrana; hrvatski povijesni muzej; humanitarnost; ispomoć; karitas; letak; mjesna zajednica; novac; novčani prilog; novčani prilozi; obavijest; odjeća; oglas humanitarne udruge caritas da prikuplja dobrotvorne pr; okvir; papir; plakat; plava slova; pomoć; popis; poruka; prikupljanje pomoći; prilog; prilozi; proglas; rat; sakupljanje; sakupljanje priloga; skupljanje; slova; solidarnost; stari rukopis; studeni; toaletni pribor; trajna hrana; vrbovsko; vrbovsko karitas; zima; zimska odjeća; zimski odjevni predmeti za odrasle; župa
HPM-96631	4	42	domovinski rat; mitinzi; srpska pobuna; velika srbija	4s; ali nisam sigurna; bedz; bijela boja; bijelo; cccc; crna boja; crna kapa; crno; crvena boja; crveno; domovinski rat; grb; kapa; kapa s četničkim grbom; kapa četnikuša; katastrofa; kokarda; mislim da je ustaška kapa; ocijelo; oznaka; paravojska; plava boja; plavo; simbol; slovo s; srbi; srbija; srpska zastava; srpsko; vuna; zastava; znak; značka; ćirilica; četnici; četnik; četnička kapa; šajkača; šubara; šubara s kokardom; šubara sa značenjem
HPM-96635_96636_96637	9	58	beograd; domovinski rat; logoraši; srbija; sremska mitrovica; srpski logori; vesna bosanac; vukovar; vukovarska bolnica	cipele; crne cipele; crne čizme; crno; dama; damska torba; devedesete; drvo; dugmad; dugme; dvije cipele; džep; gumb; gumbi; kaput; kaput klasičnog kroja; kopča; koža; kožna torbica; kragna; lakirane čizme; lutka; materijali; moda; muzej; nosač; o; obleka; odjeća; pepita; pepita uzorak; pipeta kaput; plastika; posebna prigoda; puce; remen; rukav; rukavi; smedje; smeđa; smeđa torba; smeđe; stalak; tkanina; tobica; torba; tvid; uzorak; vješalica; četiri; čizme; žena; ženska konfekcija; ženska moda; ženska odjeća; ženske cipele i ženska torbica; ženski kaput na stalku;ženski kaput i cipele
HPM-97949	4	84	domovinski rat; mine; razminiranje; stradanje	bijelo; bombe; copiright; copyright; crno; crveni okvir; crveni prevrnuti trokut; crveni trokut; crveno; domovinski rat; držač; eksplozija; eksplozivi; hcr; hrvatska; hrvatski centar za razminiranje; hrvatski povijesni muzej; kosti; kostur; kosturska glava; kvadrat; lubanja; metaln aploca s oznakom; metalna šipka; metalni držak; mina; mine; mines; minirana

				područja; miniranje; minirano područje; minska polja; minsko polje oznaka; mrtvačka glava; muzejski izložak; naopaki trokut; natpis; ne prilazite; obavijest; okvir; opasno područje; opasnost; opasnost od mina; oprez; ovo područje; oznaka minskog polja; oznaka protiv mina; pažnja; ploča; područje koje još nije razminirano; poginuli; poruka; povijesni muzej; rat; ratno nasljedje; razminiravanje; razminirači; sijena; slika; slova; smrt; stalak; strah; stup; sume; suvenir; tabelu s natpisom o opasnosti; tabla; tekst; trokut; upozorenje; upozorenje od mina; upozorenje za mine; velika opasnost; zabrana; zabrana prilaska; zabranjeno podrucje; znak; znak koji upozorava na opasnost od mina; znak opasnosti; znak smrti; znak upozorenja; znak za opasnost; šipka
HPM-98006	7	75	9 gardijska brigada vukovi; domovinski rat; gospić; hrvatska vojska; nikola šaban; obrana; vojska	9 gardijska brigada; branitelj; brigada; brigada vukovi; crna boja; devedesete; domovinski rat; dugmad; džep; džepovi; epoleta; garda; gardijska brigada; gardijska brigada vukovi; gardističko; grb; gumb; hrvatska; hrvatska uniforma; hrvatska vojska; hrvatske oružane snage; hrvatski branitelj; hrvatski domovinski rad; hrvatski grb; hrvatski povijesni muzej; hrvatski vojnik; jakna; kaput; košulja; košulja 9 gardijske brigade vukovi; maskirna; maskirna odora; maskirna uniforma; maskirne šare; maskirno; mladost; natpis; obrana; odijelo; odora; ovratnik; oznaka čina; oznake; ponos; prišivka; prošlost; puška; rat; ratna uniforma; ratne boje; slika vuka; slova; smeđa boja; smeđe crna zelena drap boja; tuga; uniforma; uspjeh; vješalica; vojna košulja; vojna odora; vojna oznaka; vojna uniforma; vojna uniforma vukovi; vojnička jakna; vojska; vuk; vukovar; vukovi; zbor narodne garde; zelena boja; značka; časnik; čin; činovi; šahovnica
HPM-98010	10	85	204 brigada hv; atila; domovinski rat; hrvatska vojska; hv; obrana; vojna policija; vojska; vukovar; zvonimir mažar	1991; a s kim vi bankarite; bijela boja; borba; branitelj; broj; brojevi; cibonin toranj; devedeset i jedan; devedesete; dobrovoljac; domovina; domovinski rat; erste banka; faks; fer; glava; godina; hotel international; hrana; hrvatska; igrice; ime; jedan u nizu; kaciga; kaciga vukovarskog branitelja; kamuflaža; kapa; knjižnica; krov ffzg a; kuće; laž; maskirna; maskirna odora; maskirne boje; maskirno; maskirno odijelo; maskirno pokrivalo za glavu; medvedgrad; medvednica; mir; obrana; odora; oluk; oznaka; platko; pogibija; ponos; pravda; rat; remen; rupe; s kariranim uzorkom; samoća; sedam; sjena; skraćenica grada; sljam; sljeme; slova; smb; smeđa; suvenir; tkanina; trakica; u; uniforma; vojna odora; vojni šljem; vojnik; vojnička kaciga; vojnički uzorak; vojnički šljem; vojska; vrbik; vukovar; vukovar 91; westin; zagrepčanka; zaštita; zbor narodne garde; zgrade; šare; šljem; štit
HPM-98019	6	37	domovinski rat; mirovna misija; organizacija ujedinjenih naroda; ujedinjeni narodi; un; unprofor	anarhija; bijela pozadina; boja; domovinski rat; individualnost; izmet; kaciga; metal; metalno; obod; odsjaj; otpor; oštećenje; patnja; plava; plava kaciga; plavi šljem; plavo; pohabanost; predmet; rat; rupa od metka; sjajno; ujedinjene nacije ne narodi; un; un kaciga; un ovci; unhcr; unprofor; uporaba; urin; vojna oprema; vojska; zaštita; zaštita glave; zlostavljanje; šljem
HPM-99439_lutka	7	67	domovinski rat; hrvatska vojska;	avijacija; avijatičar; bojni otrov; borba; branitelj; ciferšlus; cijev za zrak; cipele; domoljub; eksponat; gardistička uniforma; hlače; hrvatska vojska; hrvatsko zrakoplovstvo; jakna;

			jna; obrana; rudolf perešin; vojska; zrakoplovstvo	jaknu; kaciga; kacigu; kagica; konstrukcija uniforeme; koža; kožna jakna; kožne cipele; maska; maska za disanje; maskirna uniforma; maskirne hlače; masku; mig; motorist; nuklearka; odijelo; odijelo za pilota; odora; odsjaj u kacigi; otrov; perišin; pilot; pilotska kaciga; polot; ponos; radijacija; rat; ratna moda; ratno; rudolf perešin; specijalno odijelo; teško; uniforma; uniformu; vizir; vojna uniforma; vojne cipele; vojne čizme; vojni pilot; vojnik; vojnil; vojnička odjeća; vojničke hlače; vojno odijelo; vojno zrakoplovstvo; vojska; zelena traka; znakovlje; zrakoplovstvo; čizme; žniranci
HPM-SI-2258	7	78	angažirani plakat; apel; domovinski rat; obrana; pobjeda; ratni plakat; vukovar	adresa; bijela; bijela boja; bijeli; bijelo; boje hrvatske zastave; broj; brojevi; copyright znak; crta; crtica; crven; crvena; crvena boja; crveno; crveno bijele kockice; dizajn; dlan; domoljub; domovina; domovinski rat; dva; dva podignuta prsta; dva prsta; dvotočka; grad heroj; grb; hrvatska; hrvatska zastava; hrvatski grb; hrvatstvo; htvatska zastava; informacije; informacijske znanosti; klub; klub vukovaraca; kockice; krug; ljubav; logo; mir; modra boja; muzej; narančasta boja; natpis vukovar; organizacija; organizacija znanja; peace; plakat; plava; plavi; plavo; pobjeda; ponos; poruka; poziv; prst; prsti; rat; roza; ruka; simbol otpora vukovara; siva boja; slova; slovo; strah; točka; trobojnica; victory; vukovar; vukovar u hrvatskoj trobojnici i znak mira; war; zagreb; zastava; znak mira; šahovnica; šahovnica adresa; šaka
P-HPM-96561	7	66	1 gardijska brigada tigrovi; domovinski rat; hrvatska vojska; mobilizacijski plakat; ratni plakat; tigrovi; vojska	1 gardijska; 1 gardijska brigada; borba; branitelj; branitelji; brigada; copyright; domoljublje; domovinski rat; gardist; hrabrost; hrvatska; hrvatska vojska; hrvatski grb; hrvatski povijesni muzej; hrvatski tigrovi; hrvatski vojnik; ivan; kaciga; kapa; kockive; koncentriranost; lav; lice; maskirano lice; mlad; naprtnjača; natpis; nos; odanost; odlučnost; odvažnost; oprema; oružja; oružje; oznaka; oči; plakat; pljuca; pogled; poruka; poster; požrtvovnost; prišivka; prva gardijska brigada; puška; rat; rat u očima; ratnik; ruksak; smrt; specijalna postrojba; suparnik; tigar; tigrovi; torba; uniforma; vojna oprema; vojnik; vojnik 1 hrvatske brigade tigrovi; vojska; zabrinutost; zelena; zeleno; čin; šljem
P-HPM-96571	5	89	domovinski rat; izbori; koalicija narodnog sporazuma; političke stranke; višestranačje	1990; bijela; bijelu; boje; copyright simbol; copywright hrvatski povjesni muzej; crna boja; crvena; crvenu; devedesete; figure; figurice; glasanje; hrvatska; igrače figure; izbori; jedinstvo; kampanja; kns; koalicija; koalicija narodnog sporazuma; konj; kopirajt; kula; likove; ljubičasta; ljubičastu; lovac; loš font; miko tripalo; mirko tripalo; moderna hrvatska; narančastu; narod; natjecanje; natpis; nečitljivost; odličan dizan; oglas; pad; parlamentarni izbori; pijun; pijuni; plakat; plava; plavu; politika; politička poruka; politička stranka; polja; poraz; poruka; pozadinu; poziv; pravokutnike; predizborna kampanja; predizborni slogan; prljavština; promidžbeni plakat; propaganda; prvi izbori; rat; raznolikost; reklamni plakat; riječi; sabor; sdp; sijene; sjena; slova; slova bez podloge šarenog kvadratića; slova u raznim bojama; stranke; suradnja; svjetlo; top; zagreb; zelena; zelenu; znak za copyright; šafovske figure; šah; šah figure u neobičnim bojama; šahovnica; šahovske figure; šarene kockice; šareni kvadratići sa slovima; šareni pijuni; žar
P-HPM-MRNH-P-285	7	64	angažirani plakat; blagoje adžić; domovinski rat;	adžić; antiratni plakat; avion; avion nacrtan na nosu; bezizražajnost; bešćutnost; blagoje; blagoje adžić; bosna i hercegovina; brada; brkovi; crno bijela fotografija; croatian artists; domovinski rat; emocije; for peace; fotografija badžića; general; general jna; general jna

			jna; kultura; ratni plakat; umjetnici	blagoje adžić; generalska odora; generalski čin; glava; gneral; greška; hrvatska; hrvatski umjetnici; jna; jugoslavija; kosa; lice; lik; muškarac; nos; obrve; odora; osoba; ozbiljno; oči; plakat; portret; portret glave; poster; prepotencija; ramena; ratni avion; samodopadnost; sijeda kosa; stari čovjek; stoik; svjetla; uho; uho avion; uniforma; usne; usta; uši; vojnik; vojno lice; za mir; za mir hrvatski umjetnici 1991; zrakoplov; činovi; čovjek
P-HPM-MRNH-P-403	5	70	domovinski rat; hrvatska vojska; mobilizacijski plakat; ratni plakat; vojska	branitelj; branitelji; copyright; dijete; dječak; domoljub; domovinski rat; drukeri; dva prsta; gardist; glava; grb; hlače; hravtski povijesni muzej; hrvatska; hrvatski branitelji; hrvatski grb; hrvatski vojnik; hrvatsko povijesni muzej; htvatski; jakna; je; kosa; loš dizajn; majica; maskirna uniforma; mir; moj; natpis; nerazumijevanje; neukusno; noge; nos; novska; odora; operativna grupa posavina; operativna grupa posavina novska; osmjeh; otac; oči; patent; plakat; podignuta ruka; ponos; ponosni dječaj; ponosni sin; posavina; posavkam; prsti; rat; ruka; ruke; slova; tata; tijelo; traka oko glave; traka za glavu; traka za kosu; uiforma; uniforma; usta; uši; vezice za cipele; victory; vojnik; vojska; čizme; čizmice; štampana slova; žuta ruka
P-HPM-MRNH-P-425	6	77	angažirani plakat; apel; domovinski rat; obrana; osijek; ratni plakat	bijela; bijlo; biti; biti osek; boja; bunt; crna; crni plakat s bijelim slovima; crno; crta; crvena linija; crveno; dizajn; dok mu ne dodaju ij; domovinski rat; glagol biti; grad u slavoniji; gradient; grafičko oblikovanje; grafičko rješenje; hrapavo; hrvatska; hrvatski povijesni muzej; istaknuto; kreda; latinica; linija; muzej; muzejska građa; naglasak; napuknuto; narančasta; narančasta crta; narančasto; natpis; natpis protiv ćirilice; nebo; neknjižna građa; neće; nikada; nikada podvučeno crvenom linijom; obrana hrvatske; ocek; osek; osijek; osvjetljenje; otpor; parola; pastelno; plakat; plakat na kom stoji da osijek nikada neće biti ocek napisano ć; ploha; ploča; pobuna; podcrtano; podjela grada; portfolio; poster; povijest; prljavo bijela; protiv srba; protiv ćirilice; rat; riječ; riječi; rub; sjena; sjena riječ; slavonija; sloboda; slogan; slova; srbija; stencil; usklik; ćirilica; štampana slova
P-HPM-MRNH-P-429	6	54	angažirani plakat; apel; domovinski rat; kultura; ratni plakat; umjetnici	1991; bijela; bijela boja; bijela slova na crnoj podlozi; boja; boje; borba; crna; crna boja; crnilo; crvena; crvena boja; crveno; dizajn; dom; domovinski rat; fleke; godina 1991; grafička umjetnost plakati; gubitak; hrvatska; hrvatski povijesni muzej; ivan ljubičić; izložba; izložba slika iz domovinskog rata; kaplje krvi; knjiga; krv; krvatska; krvava hrvatska u 1991 godini; krvoprolićе; ljubav; ljudi; mrak; mrlje; muzej; plakat; poster; propaganda; pucnjevi; rat; rat u hrvatskoj; ratna propaganda; ratna razaranja plakat; slova; smrt; stradanja; tama; tuga; umjetnički; usklicnik; uskrs; čistoća; žrtve
P-HPM-MRNH-P-445	5	62	domovinski rat; hrvatska vojska; mobilizacijski plakat; ratni plakat; vojska	anonimno; bijela boja; branitelj; domoljublje; domovina; domovinski rat; duh; dva prsta; hrvatska; hrvatski povijesni muzej; hrvatski vojnik; jakna; košulja; ljubav; maskirna košulja; maskirno; mobilizacija; nacija; naslov; nasovnica; natpis; natpis voliš li hrvatsku; nedostatak slova; novačenje; obris čovjeka; odora; odora hrvatske vojske; osoba; osoba u sjeni; osoba u sjeni s rukom u znaku pobjede; peace; pitanje; plakat; pobjeda; poziv; poziv u domovinski rat; poziv u rat; poziv za vojsku; prsti; rat; ratna odjeća; ratna odora; ratni plakat; regrutacija; ruka; silueta; slova; slova vješalica; tijelo; unforma; uniforma; upitnik; victory; vješalica; vojnici; vojnik; vojska; voliš hrvatsku; voliš li hrvatsku; znak v; čovjek; žuta boja

P-HPM-MRNH-P_218-2	9	77	agresija; angažirani plakat; apel; domovinski rat; kultura; međunarodno priznanje; ratni plakat; samostalnost; umjetnici	1990; 1991; 1992; 90; 91; 92; bijela; bijela boja; bijelo; boja; boje; brijeli; broj; brojevi; brojke; budućnost; croatia; crven; crvena; crvena boja; crveno; domovina; domovinski rat; eu; europa; europska unija; europska zajednica; europski logo; europskla unija; fotografija; godine; grafički simboli; hrvatska; hrvatski logo; hrvatski povijesni muzej; kocka; kockice; kopirajt; kroata; kronologija; krv; krvava mrlja; logo; mrlja; mrlja od krvi; nacionalizam; napredak; neknjižna građa; packa; plakat; plava; plava boja; plavi; plavo; poster; povijest hrvatske; prepoznatljivost; priznanje; progres; promjene; rat; ratne godine; samostalna hrvatska; samostalnost; sjena; slika; slova; stvaranje; trobojnica; ujedinjena država; vijelo; zaslon; zastava; zvijezda; zvijezdice; zvjezdice; šahovnica
P-HPM-MRNH-SI-2272	6	169	apel; domovinski rat; karlovac; osveta; propaganda; srbi u hrvatskoj	10 trgovina; 37 kafića; 4 stana; 4 vikendice; 47 kuća; 7 automobila; 7 kioska; 8 zanatskih radionica; 92; amblem policije s golubicom; apel; apel građanima; automobili; bedem; bijeli papir; bijelo; bit ćemo tu; bobma; bomba; bombardiranje; bonba; borba; broj telefona; brojevi; brojke; budimo zajedno; copyright; dim; dinamit; dinmit; divlje horde; djeca; domovi; domovinski rat; dosadno; dostojanstvo; dug; eksplozivna sredstva; golub; golubica; govoriti; grad; granata; građa hrvatskog povijesnog muzeja; grb; heksagon; hrvatska; hrvatski grad; hrvatski povijesni muzej; izgubiti; jedno nejako dijete; kad ovaj suludi radt prestane; kafić; kafići; karlovac; karta; kiosci; kiosk; kockice; kriz; kuća; kuće; let; letak; logo; mina; mir; mirno; molba; muzej; muzejska građa; nada; napuštanje; načiniti; naš grad; naša okolica; nejako dijet; nejasno; neknjižna građa; neobzirnost; nepogoda; nered; nestajanje; nestalo; obavijest; obljetnica; obrana; opasnost; osluškujmo svaki šum; otići; oznaka; plakat; plakat policije s pozivom na očuvanje mira i sigurnosti; plamen; plan grada; plava; plava boja; plavo; policija; pomoć; poruka; potreba; povrat oružja; poziv; poziv na prekid rata; poziv na samoorganiziranje; pozovite 92; prekrižena ručna granata; prekriženo; prica; proglas; projektili; protiv; protiv razaranja; ptica; radionica; radionice; rat; rat hrvati; razaranja; razmislimo; razum; riječi; rucna bomba; samoća; savjest; sačuvajmo; sačuvati mir; shema; sigurno; sigurnost; simbol; sisak; sloboda; slobodan; slova; smisao; spomen; stan; stradavanja; strah; sugrađani; suludi rat; telefonski broj; telefonski broj 92; tiskana slova; tlocrt; točka; trebati; trgovina; tvrđa; tvrđava; uništenje; upitnik; upozorenje; usklicnik; utvrda; učinimo sve da se to ne ponovi; vapaj; vikendice; vratiti; zabrana; zarez; zaštita; zvijezda; čuvajmo svoje ulaze; šahovnica; šestagon; život

Prilog 5. Prosječne ocjene korisnosti korisničkih oznaka od strane predmetnih stručnjaka

A. MUZEJSKA GRAĐA

Red. br.	ID	BROJ OZNAKA	PROSJEČNA OCJENA
1	HPM-93578	13	4.38
2	HPM-98006	5	3.80
3	HPM-93220_1_2-6	9	3.78
4	HPM-96635_96636_96637	8	3.75
5	HPM-98010	9	3.89
6	HPM-33176	2	4.00
7	HPM-93201	6	4.33
8	HPM-98019	5	4.00
9	HPM-93218	7	4.14
10	HPM-89811	1	5.00
11	HPM-93549	13	3.38
12	HPM-93737	11	3.55
13	HPM-97949	10	4.60
14	HPM-SI-2258	7	4.00
15	HPM-33037	3	4.67
16	HPM-93764	2	3.50
17	HPM-99439_lutka	7	4.71
18	HPM-93728	3	4.67
19	HPM-93662	11	4.00
20	HPM-96631	6	3.50
	UKUPNO	**138**	**-**
	MAX	**13**	**5.00**
	MIN	**1**	**3.38**
	PROSJEK	**7**	**4.08**
	STDEV	**3.63**	**0.47**
	MEDIJAN	**7**	**4.00**
	MOD	**7**	**4.00**

B. KNJIŽNIČNA GRAĐA

Red. br.	ID	BROJ OZNAKA	PROSJEČNA OCJENA
1	F-III-718	5	1.80
2	F-II-10.376	4	3.25
3	F-II-10.641	9	2.44
4	F-II-7118	8	1.88
5	F-II-6920	5	2.80
6	F-II-6454	4	3.00

7	F-II-10.743	10	3.20
8	F-II-10.245	11	2.27
9	F-II-10.697	7	3.00
10	F-III-785	6	2.50
11	F-II-10.516	11	1.91
12	F-II-10.696	5	3.20
13	F-II-6611	5	1.40
14	F-II-10.746	3	1.67
15	F-II-6711	8	2.38
16	F-II-4727	14	2.43
17	F-II-10.517	3	3.67
18	F-II-7052	8	3.25
19	F-III-847	11	4.00
20	F-II-7037	6	3.33
	UKUPNO	**143**	**-**
	MAX	**14**	**4.00**
	MIN	**3**	**1.40**
	PROSJEK	**7**	**2.67**
	STDEV	**3.08**	**0.71**
	MEDIJAN	**6.5**	**2.65**
	MOD	**5**	**3.25**

C. ARHIVSKA GRAĐA

Red. br.	ID	BROJ OZNAKA	PROSJEČNA OCJENA
1	P-HPM-MRNH-P-429	6	4.33
2	P-HPM-MRNH-SI-2272	25	3.16
3	HPM-93517_av	5	3.60
4	HPM-93372	5	4.40
5	P-HPM-MRNH-P-403	9	4.11
6	P-HPM-MRNH-P-425	5	3.80
7	HPM-93511_rv	10	3.60
8	HPM-93531_av	3	4.33
9	HPM-96554	3	4.67
10	HPM-93195	4	4.50
11	HPM-93345	10	4.10
12	HPM-95097	3	5.00
13	P-HPM-96561	7	3.71
14	HPM-93196_42	12	3.58
15	P-HPM-MRNH-P-445	5	4.80
16	P-HPM-96571	8	3.38
17	P-HPM-MRNH-P_218-2	8	4.13
18	HPM-93410	7	4.14
19	P-HPM-MRNH-P-285	7	3.00

20	HPM-93511_av	5	3.80
	UKUPNO	**147**	**-**
	MAX	**25**	**5.00**
	MIN	**3**	**3.00**
	PROSJEK	**7**	**4.01**
	STDEV	**4.86**	**0.54**
	MEDIJAN	**6.5**	**4.11**
	MOD	**5**	**4.33**

D. FOTOGRAFIJE

Red. Br.	ID	BROJ OZNAKA	PROSJEČNA OCJENA
1	HPM-90919	7	4.43
2	HPM-90145	8	3.13
3	HPM-92475	10	3.40
4	HPM-91415	8	3.00
5	HPM-90558	11	3.09
6	HPM-91263	4	4.50
7	HPM-90163	4	4.25
8	HPM-91474	16	3.19
9	HPM-90134	10	3.50
10	HPM-91229	6	4.33
11	HPM-90875	8	4.13
12	HPM-91649	1	5.00
13	HPM-90791	19	3.84
14	HPM-93005	3	4.67
15	HPM-91563	12	4.33
16	HPM-90662	14	3.57
17	HPM-90142	7	4.00
18	HPM-92902	16	3.38
19	HPM-92298	5	4.40
20	HPM-91773	9	4.00
	UKUPNO	**178**	
	MAX	**19**	**5.00**
	MIN	**1**	**3.00**
	PROSJEK	**9**	**3.91**
	STDEV	**4.72**	**0.59**
	MEDIJAN	**8**	**4.00**
	MOD	**8**	**4.33**

Prilog 6. Python programsko rješenje

MAIN.py

```
# ulazi
user_path = "input/user_data.csv"
pro_path = "input/pro_data.csv"
# izlazi
excel_path = "output/report.xlsx"
json_path = "output/data.json"

import json
from this_tools import *

# usnimi korisničke podatke i agregiraj ih po šifri predmeta
raw_user_data = loadData(user_path)
user_data = prepareUserData(raw_user_data, id_correct_user)

# usnimi "pro" podatke (već agregirani po predmetima)
raw_pro_data = loadData(pro_path)
pro_data = prepareProData(raw_pro_data)

# diže grešku ako korisnički skup šifri nije identičan skupu šifri
iz predmetnica
checkIDs(user_data, pro_data)

# spoji podatke na šifri
data = mergeData(user_data, pro_data)

# nadopuni podatke s pokazateljima po predmetu
calcItemIndicators(data)

# agregirani pokazatelji za zbirku
collection_report = calcCollectionIndicators(data)

# spremi sređene podatke u json
with open(json_path, "w", encoding="utf-8") as fle:
    json.dump(data, fle, ensure_ascii=False, indent=2)

# izvezi podatke u excel
item_header = [
    "id",
    "vrsta",
    'n_predmetnica',
    'n_oznaka',
    'n_oznaka_predmetnica',
    'n_oznaka_predmetnica(zbirka)',
    'n_dodjeljivanja',
    'n_dodjeljivanja_oznaka_predmetnica',
    'n_dodjeljivanja_oznaka_predmetnica(zbirka)',
    'n_oznaka_jednom',
    "IICM",
    "n_riječi_oznake_1",
```

```
    "n_riječi_oznake_2",
    "n_riječi_oznake_3+",
    "n_riječi_predmetnice_1",
    "n_riječi_predmetnice_2",
    "n_riječi_predmetnice_3+",
    'često_granica',
    'predmetnice',
    'oznake',
    'često_korištene_oznake',
    'često_korištene_oznake_ne_predmetnice'
]
item_join_cols = range(-4, 0)

collection_header = [
    "skupina",
    "n_predmeta",
    'n_predmetnica',
    'n_oznaka',
    'n_oznaka_predmetnica',
    'n_dodjeljivanja',
    'n_dodjeljivanja_oznaka_predmetnica',
    'n_oznaka_jednom',
    "n_dodjeljivanja_predmetnica",
    "n_predmetnica_jednom",
    "IICM",
    "n_riječi_oznake_1",
    "n_riječi_oznake_2",
    "n_riječi_oznake_3+",
    "n_riječi_predmetnice_1",
    "n_riječi_predmetnice_2",
    "n_riječi_predmetnice_3+",
]

ts_header = ["SVE", "KNJIZ", "MUZEJ", "FOTO", "ARH-DOKUMENT", "ARH-
PLAKAT"]

from openpyxl import Workbook

# COUNT TAGS AND SUBJECTS BY ITEM TYPES

all_tags, all_subjects = getTagsAndSubjects(data)

group_tags = {
    "ARH-DOKUMENT":defaultdict(int),
    "ARH-PLAKAT":defaultdict(int),
    "KNJIZ":defaultdict(int),
    "FOTO":defaultdict(int),
    "MUZEJ":defaultdict(int)
}

group_subjects = {
    "ARH-DOKUMENT":defaultdict(int),
    "ARH-PLAKAT":defaultdict(int),
    "KNJIZ":defaultdict(int),
    "FOTO":defaultdict(int),
    "MUZEJ":defaultdict(int)
```

```
}

for item in data.values():
    t = item["vrsta"]

    for o, n in item["oznake"].items():
        group_tags[t][o] += n

    for s in item["predmetnice"]:
        group_subjects[t][s] += 1

tags = defaultdict(dict)
subjects = defaultdict(dict)

for tag in all_tags:
    tags[tag]["SVE"] = all_tags[tag]
    for group in group_tags:
        tags[tag][group] = group_tags[group][tag]

for subject in all_subjects:
    subjects[subject]["SVE"] = all_subjects[subject]
    for group in group_subjects:
        subjects[subject][group] = group_subjects[group][subject]

# OUTPUT EVERYTHING TO EXCEL

wb = Workbook()
dataToExcelSheet(wb, "predmeti", data, item_header, item_join_cols)
dataToExcelSheet(wb, "zbirka", collection_report, collection_header)
dataToExcelSheet(wb, "oznake", tags, ts_header, (), "oznaka")
dataToExcelSheet(wb, "predmetnice", subjects, ts_header, (),
"predmetnica")checkDataToExcelSheet(wb, data) # podaci za stručni
pregled
wb.remove_sheet(wb.worksheets[0])
wb.save(excel_path)
```

TOOLS.py

```
from collections import defaultdict
import csv
from operator import itemgetter
import re

# DATA PREPARATION

def loadData(pth):
    """
    usnimava podatke iz .csv formata u dict
    """
    with open(pth, encoding="utf-8") as fle:
        reader = csv.reader(fle, delimiter=";")
        header =[h.strip().lower() for h in next(reader)]
```

```
        data = []
        for row in reader:
            data.append(dict(zip(header, row)))
        return data


def prepareTag(s, leave = "-", vocab_control=False, thesaurus=None):
    """
    priprema oznaku ili predmetnicu:
        1. uklanja sve znakove koje nisu unicode slova, brojevi,
razmak ili znakovi nabrojani u "leave" parametru
        2. pretvara sve znakove koji su prisutni u leave u razmake
        3. normalizira i kompresira "whitespace" (uključujući i tab
znakove i slično)
        4. provjerava da oznaka sadrži išta osim razmaka, u kojem
slučaju se ignorira
        5. pretvara sva slova u mala slova
        6. opcionalno, kontrola rječnika
    """
    # drop non word characters, non space characters
    s = re.sub(r'[^\w\s%s]' % leave, '', s, re.UNICODE)
    # replace characters that should be treated as space
    s = s.replace("-", " ").replace("_", " ")
    # normalize and compress whitespace
    s = " ".join(s.split())
    # make s lowercase
    s = s.lower()
    # apply vocabulary control
    if vocab_control:
        if not thesaurus:
            raise Exception("thesaurus argument must be passed if
word_control==True")
        s = thesaurus.get(s, s)
    if s:
        return s
    else:
        return None


def prepareUserData(data, id_correct):
    """
    priprema korisničke podatke:
        1. agregira oznake po predmetu (i razriješava broj
dodjeljivanja oznake)
        2. priprema oznake, vidi prepareTag funkciju
    """
    _data = {}
    for item in data:
        tag = prepareTag(item["tag"])
        if not tag:
            continue # skip possible trash input (whitespace or
interpunction)
        id_ = item['imagename'].strip()[:-4]
        id_ = id_correct.get(id_, id_)
        uc = int(item["tagusecnt"])
        # svako dodjeljivanje taga je bilježeno dvaput
```

```
        assert not uc % 2, "Use count not even"
        use_count = int(uc / 2)
        if id_ not in _data:
            _data[id_] = {
                "id":id_,
                "oznake":{}
            }
        tags = _data[id_]["oznake"]
        if tag in tags:
            tags[tag] += use_count
        else:
            tags[tag] = use_count
    return _data


def preparePro Data(data):
    """
    priprema podatke o zbirci:
        1. priprema predmetnice kao i oznake, vidi prepareTag
funkciju
    """
    _data = {}
    for item in data:
        id = item["id"].strip()
        assert id not in _data, "Duplicate pro id found"
        pp = set()
        for p in item["predmetnice"].split(","):
            p = prepareTag(p)
            if p: # skip possible trash input (whitespace or
interpunction)
                pp.add(p)

        _data[id] = {
            "id":id,
            "predmetnice":list(pp),
            "vrsta":item["vrsta"]
        }
    return _data


def checkIDs(user_data, pro_data):
    """
    provjerava da su šifre predmeta u user_data i pro_data identične
    """
    U = set(user_data)
    P = set(pro_data)
    if U != P:
        user_ex = ';'.join(U - P)
        pro_ex = ';'.join(P - U)
        error_message= "Exclusive item ids detected; user: {}, pro:
{}"
        raise Exception(error_message.format(user_ex, pro_ex))


def mergeData(user_data, pro_data):
    """
```

```
    spaja podatke o predmetima iz oznaka i predmetnica
    """
    data = {}
    for id_ in user_data:
        item = user_data[id_].copy()
        item.update(pro_data[id_])
        data[id_] = item
    return data

# INDICATORS CALCULATION

def getOutlayingTags(t, mild=True):
    if mild:
        cutoff = getTopOutlierCutoff(t.values())
    else:
        cutoff = getTopOutlierCutoff(t.values(), 3)
    if cutoff < 2:
        cutoff = 2
    l = []
    for tag in t:
        if t[tag] > cutoff:
            l.append(tag)
    return l, cutoff


def countUsedOnce(t):
    return sum(filter(lambda n: n == 1, t.values()))

def calcIICM(n_t, n_s, n_ts):
    return round( (n_ts/(n_t+n_s-n_ts)) * 100,  2)

def calcWordNs(t):
    results = {
        1:0,
        2:0,
        3:0
    }
    for tag in t:
        l = len(tag.split())
        if l > 2:
            results[3] += 1
        else:
            results[l] += 1
    return results

def getTagsAndSubjects(data, keys = None):
    """
    Izrađuje distribucije oznaka i predmetnica za zbirku predmeta.
    """
    tags = {}
    subjects = {}
    if not keys:
        keys = data
    for key in keys:
        item = data[key]
        for t in item["oznake"]:
```

```
            if t not in tags:
                tags[t] = 0
            tags[t] += item["oznake"][t]
        for s in item["predmetnice"]:
            if s not in subjects:
                subjects[s] = 0
            subjects[s] += 1
    return tags, subjects


def getBaseIndicators(tags, subject_set, mild=True):
    """
    Stvara izvještaj indikatora koji vrijede i za jedan predmet i za
zbirku predmeta.
    """
    t = set(tags)
    ts = t & subject_set
    n_t = len(t)
    n_s = len(subject_set)
    n_ts = len(ts)
    n_t_use = sum(tags.values())
    n_ts_use = sum(tags[_t] for _t in ts)

    frequent, cutoff = getOutlayingTags(tags, mild)
    n_used_once = sum(filter(lambda n: n == 1, tags.values()))
    tag_word_ns = calcWordNs(t)
    subject_word_ns = calcWordNs(subject_set)


    report = {
        "n_oznaka":n_t,
        "n_predmetnica":n_s,

        "n_dodjeljivanja":n_t_use,
        "n_oznaka_jednom":n_used_once,
        "često_korištene_oznake":frequent,
        "često_korištene_oznake_ne_predmetnice":list(set(frequent) -
subject_set),
        "često_granica":cutoff,

        "n_oznaka_predmetnica":n_ts,
        "n_dodjeljivanja_oznaka_predmetnica":n_ts_use,
        "IICM":calcIICM(n_t, n_s, n_ts),
        "n_riječi_oznake_1":tag_word_ns[1],
        "n_riječi_oznake_2":tag_word_ns[2],
        "n_riječi_oznake_3+":tag_word_ns[3],
        "n_riječi_predmetnice_1":subject_word_ns[1],
        "n_riječi_predmetnice_2":subject_word_ns[2],
        "n_riječi_predmetnice_3+":subject_word_ns[3]
    }

    return report


def getItemIndicators(tags, item_subject_set,
collection_subject_set):
```

```
    """
    Stvara izvještaj indikatora koji imaju smisla samo za predmet.
    """
    t = set(tags)
    tst = t & collection_subject_set
    n_tst = len(tst)
    n_tst_use = sum(tags[_t] for _t in tst)

    report = {
        "n_oznaka_predmetnica(zbirka)":n_tst,
        "n_dodjeljivanja_oznaka_predmetnica(zbirka)":n_tst_use,
    }

    return report


def getCollectionIndicators(tags, subjects):
    """
    Stvara izvještaj indikatora koji imaju smisla samo za zbirku.
    """
    return {
        "n_predmetnica_jednom":countUsedOnce(subjects),
        "n_dodjeljivanja_predmetnica":sum(subjects.values()),
    }


def calcItemIndicators(data):
    """
    Dodaje indikatore za predmet u podatke o predmetima.
    """
    all_tags, all_subjects = getTagsAndSubjects(data)
    collection_subject_set = set(all_subjects)
    for item in data.values():
        tags = item["oznake"]
        item_subject_set = set(item["predmetnice"])
        item.update(getBaseIndicators(tags, item_subject_set))
        item.update(getItemIndicators(tags, item_subject_set,
collection_subject_set))


def calcCollectionIndicators(data):
    """
    Izrađuje indikatore za cijelu zbirku i pojedine vrste predmeta.
    """
    groups = defaultdict(set)
    groups["ukupno"] = set(data)
    for item in data.values():
        groups[item["vrsta"]].add(item["id"])
    report = {}
    for key in groups:
        ids = groups[key]
        report[key] = this_report = {
            "skupina":key,
            "n_predmeta":len(ids),
        }
        tags, subjects = getTagsAndSubjects(data, ids)
```

```
        this_report.update(getBaseIndicators(tags, set(subjects)))
        this_report.update(getCollectionIndicators(tags, subjects))
    return report

# OUTPUT HELPERS

def itemToRow(item, header, join_cols = ()):
    row = [item[att] for att in header]
    for i in join_cols:
        row[i] = '; '.join(sorted(row[i]))
    return row


def dataToExcelSheet(wb, name, data, header, join_cols=()):
    ws = wb.create_sheet(title=name)
    ws.append(header)
    for key in sorted(data):
        item = data[key]
        ws.append(itemToRow(item, header, join_cols))


def dictToExcelSheet(wb, name, data, header):
    ws = wb.create_sheet(title=name)
    ws.append(header)
    rows = sorted(data.items(), key=itemgetter(1), reverse=True)
    for row in rows:
        ws.append(row)


def checkDataToExcelSheet(wb, data):
    ws = wb.create_sheet(title="za_pregled")
    ws.append(["id", "vrsta", "oznaka", "ocjena"])
    for item in data.values():
        id_ = item["id"]
        type_ = item["vrsta"]
        for tag in
sorted(item["često_korištene_oznake_ne_predmetnice"]):
            ws.append([id_, type_, tag, ''])

# STAT TOOLS

from math import modf, floor
def quantile(p, q=0.5, qtype=8, issorted=False):
    """
    Args:
       x - input data
       q - quantile
       qtype - algorithm
       issorted- True if x already sorted.

    Compute quantiles from input array x given q.For median,
    specify q=0.5.

    References:
       http://reference.wolfram.com/mathematica/ref/Quantile.html
```

```
       http://wiki.r-
project.org/rwiki/doku.php?id=rdoc:stats:quantile

    Author:
    Ernesto P.Adorio Ph.D.
    UP Extension Program in Pampanga, Clark Field.
    from:http://adorio-research.org/wordpress/?p=125
    """
    if not issorted:
        y = sorted(p)
    else:
        y = p
    if not (1 <= qtype <= 9):
        return None  # error!

    # Parameters for the Hyndman and Fan algorithm
    abcd = [(0, 0, 1, 0),  # inverse empirical distrib.function., R
type 1
            (0.5, 0, 1, 0),  # similar to type 1, averaged, R type 2
            (0.5, 0, 0, 0),  # nearest order statistic,(SAS) R type
3

            (0, 0, 0, 1),  # California linear interpolation, R type
4
            (0.5, 0, 0, 1),  # hydrologists method, R type 5
            (0, 1, 0, 1),
            # mean-based estimate(Weibull method), (SPSS,Minitab),
type 6
            (1, -1, 0, 1),  # mode-based method,(S, S-Plus), R type
7
            (1.0 / 3, 1.0 / 3, 0, 1),  # median-unbiased,   R type 8
            (3 / 8.0, 0.25, 0, 1)  # normal-unbiased, R type 9.
    ]

    a, b, c, d = abcd[qtype - 1]
    n = len(y)
    g, j = modf(a + (n + b) * q - 1)
    if j < 0:
        return y[0]
    elif j >= n:
        return y[n - 1]

    j = int(floor(j))
    if g == 0:
        return y[j]
    else:
        return y[j] + (y[j + 1] - y[j]) * (c + d * g)


def getTopOutlierCutoff(p, multi=1.5):
    p = sorted(p)
    q1 = quantile(p, 0.25, issorted=True)
    q3 = quantile(p, 0.75, issorted=True)
    iqr = q3 - q1
    return q3 + iqr * multi
```

Popis tablica

Tablica 1 - Prednosti i nedostaci prirodnog i kontroliranog jezika u sustavima za označivanje 15
Tablica 2 - Prijevodi temeljnih engleskih termina vezanih uz područje korisničkog označivanja 50
Tablica 3 - Analiza web spominjanja teorijskih termina prisutnih u literaturi 53
Tablica 4 - Broj radova i citata vezanih za područje društvenog označivanja u relevantnim bibliografskim bazama 55
Tablica 5 - Radovi citirani u bazama WOS i SCOPUS prisutni u prvih dvadeset najcitiranijih u obje baze 55
Tablica 6 - Izvori uključeni u pregled literature 61
Tablica 7 - Kategorizacija radova koji se bave društvenim označivanjem u području knjižničarstva, temeljena na 345 radova iz baza SCOPUS, WOS, LISTA i Google Scholar .. 63
Tablica 8 - Ključne razlike između pristupa ljudskog računarstva i mudrosti mnoštva 79
Tablica 9 - Kvantitativni podaci o oznakama dodanima od strane registriranih korisnika 107
Tablica 10 - Sumirani podaci o broju dodjeljivanja prema vrstama građe 111
Tablica 11 - Sumirani podaci o dodanim oznakama prema vrstama građe 114
Tablica 12 - Koeficijent korelacije između broja dodjeljivanja i broja dodanih oznaka prema vrstama građe 117
Tablica 13 - Koeficijent korelacije između broja dodanih oznaka i broja jedinstvenih dodanih oznaka prema vrstama građe 119
Tablica 14 - Koeficijent korelacije između broja dodjeljivanja i broja jedinstvenih dodanih oznaka prema vrstama građe 121
Tablica 15 - Sumirani podaci o korelaciji između broja dodjeljivanja, broja dodanih oznaka i broja jedinstvenih oznaka na razini predmeta 122
Tablica 16 - Razine analize vizualne građe primijenjene u disertaciji 130
Tablica 17 - Primjer analize vizualne građe 130
Tablica 18 - Rezultati analize razina značenja korisničkih oznaka dodanih vizualnoj građi . 131
Tablica 19 - Rezultati analize razine značenja *ofness* korisničkih oznaka dodanih vizualnoj građi 132
Tablica 20 - Broj dodanih oznaka prema vrstama građe 136
Tablica 21 - Broj dodanih predmetnica prema vrstama građe 137
Tablica 22 - Preklapanje između setova termina predmetnica i korisničkih oznaka na arhivskoj građi 143
Tablica 23 - Preklapanje između setova termina predmetnica i korisničkih oznaka dodanih fotografijama 146
Tablica 24 - Preklapanje između setova termina predmetnica i korisničkih oznaka dodanih knjižničnoj građi 149
Tablica 25 - Usporedba predmetnica i korisničkih oznaka na zbirci muzejske građi 151
Tablica 26 - Preklapanje između setova termina predmetnica i korisničkih oznaka - sumirani podaci 154
Tablica 27 – Statistički pokazatelji seta korisničkih oznaka koje su dane na ocjenu predmetnim stručnjacima (sumirani podaci) 162
Tablica 28 - Prosječne ocjene korisnosti korisničkih oznaka od strane predmetnih stručnjaka (sumirani podaci) 162
Tablica 29 - Postotak korisničkih oznaka koje bi predmetni stručnjak uključio u opis 164

Popis slika

Slika 1 - Piramida podatak-informacija-znanje-mudrost 1
Slika 2 - Osnovni pristupi indeksiranju 8
Slika 3 - Proces predmetne obrade 13
Slika 4 - Web 2.0 mentalna mapa 23
Slika 5 - Osnovne komponente Weba 2.0 24
Slika 6 - Struktura servisa za suradničko označivanje 27
Slika 7 - Proces dodavanja novog mrežnog izvora na Delicious.com 29
Slika 8 - Upute za dodavanje oznaka servisa Delicious.com 30
Slika 9 - Najpopularniji mrežni izvori označeni oznakom web2.0 unutar servisa Delicious.com 31
Slika 10 - Osobine servisa Diigo.com 32
Slika 11 - Proces dodavanja novog mrežnog izvora na Diigo.com 32
Slika 12 - Najpopularniji mrežni izvori označeni oznakom web2.0 unutar servisa Diigo.com 33
Slika 13 - Upravljačka ploča My Library servisa Diigo.com 34
Slika 14 - Proces dodavanja novog mrežnog izvora na Bibsonomy.org 35
Slika 15 - Najpopularniji mrežni izvori označeni oznakom web2.0 unutar servisa Bisonomy 36
Slika 16 - Oblak oznaka najpopularnijih tema i autora servisa Bibsonomy.org 36
Slika 17 - Popularni koncepti na stranici Bibsonomy.org 37
Slika 18 - Proces dodavanja nove fotografije na servis Flickr 38
Slika 19 - Oblak oznaka najpopularnijih oznaka servisa Flickr 39
Slika 20 - Najpopularniji mrežni izvori označeni oznakom *london* na servisu Flickr 40
Slika 21 - Klasteri oznaka korisničke oznake jaguar na servisu Flickr 41
Slika 22 - Oznake dodane pojedinom izvođaču na servisu Last.Fm 43
Slika 23 - Dodavanje nove oznake i oblak oznaka za izvođača Johnnya Casha na servisu Last.fm 44
Slika 24 - Oblak oznaka najpopularnijih oznaka servisa Last.fm 45
Slika 25 - Početna stranica oznake *rock* na servisu Last.fm 46
Slika 26 - Poruka na servisu Twitter.com 47
Slika 27 - Graf kocitata baziran na 8848 citata radova iz baze SCOPUS 57
Slika 28 - Graf kocitata baziran na 2668 citata radova iz baze WOS sa dodanom vremenskom komponentom i časopisom u kojem je objavljen rad 59
Slika 29 - Troslojni model folksonomije 66
Slika 30 - Tripartitni hipergraf korisnika, izvora i oznaka 66
Slika 31 - Model korisnik-oznaka-informacija 67
Slika 32 - Model korisnik-oznaka-korisnik 67
Slika 33 - Model informacija-oznaka-informacija 68
Slika 34 - Široke i uske folksonomije 69
Slika 35 - Proces dodavanja korisničke oznake 70
Slika 36 - Tipična power law razdioba podataka 74
Slika 37 - Prikaz područja i terminologije crowdsourcinga 78
Slika 38 - reCAPTCHA sustav 79
Slika 39 - ESP igra 85
Slika 40 - Proces istraživanja projekta Steve Museum 86
Slika 41 - Mrežna stranica alata steve.tagger 87
Slika 42 - Oblak oznaka na servisu Penn Tags 88
Slika 43 - Dodavanje nove knjige na servisu LibraryThing 90
Slika 44 - Prikaz korisničkih oznaka dodanih knjizi Folksonomies, indexing and retrieval na servisu LibraryThing 91

Slika 45 - Uređivanje zapisa knjige te dodavanje korisničkih oznaka na servisu LibraryThing 91
Slika 46 - Proces glasanja o spajanju/razdvajanju oznaka na servisu LibraryThing 92
Slika 47 - Dodavanje korisničkih oznaka predmetu unutar virtualne zbirke Brooklyn Museuma 95
Slika 48 - Proces registracije i stvaranje profila 100
Slika 49 - Sučelje igre ZenTag korištene za prikupljanje korisničkih oznaka u istraživanju 101
Slika 50 - Ekran nakon završene igre 102
Slika 51 - Popis najboljih igrača i osvojenih znački 103
Slika 52 - Administratorsko sučelje aplikacije za prikupljanje podataka 104
Slika 53 - Broj igrača prema aktivnosti 105
Slika 54 - Broj dodanih oznaka registriranih i neregistriranih igrača 106
Slika 55 - Distribucija dodijeljenih oznaka od strane registriranih korisnika 107
Slika 56 - Broj igrača prema spolu 108
Slika 57 - Broj igrača prema dobi 108
Slika 58 - Broj igrača prema obrazovanju 109
Slika 59 - Broj igrača prema području obrazovanja 110
Slika 60 - Broj dodjeljivanja oznaka prema vrstama građe i broju 112
Slika 61 - Frekvencijska razdioba broja dodjeljivanja korisničkih oznaka prema vrstama građe 113
Slika 62 - Broj dodanih oznaka prema vrstama građe 114
Slika 63 - Udio dodanih oznaka u broju dodjeljivanja na razini predmeta 115
Slika 64 - Broj dodjeljivanja, dodanih oznaka te jedinstvenih oznaka prema vrstama građe 116
Slika 65 - Korelacija između broja dodjeljivanja i broja dodanih oznaka na razini predmeta 118
Slika 66 - Prikaz linearne korelacije između broja dodjeljivanja i broja dodijeljenih oznaka na razini predmeta 118
Slika 67 - Odnos između broja dodanih oznaka i broja jedinstvenih oznaka na razini predmeta 119
Slika 68 - Prikaz linearne korelacije između broja dodanih oznaka i broja jedinstvenih dodanih oznaka na razini predmeta 120
Slika 69 - Korelacija broja dodjeljivanja i broja jedinstvenih dodanih oznaka na razini predmeta 121
Slika 70 - Kategorije lingvističke analize 124
Slika 71 - Analiza korisničkih oznaka prema broju riječi od kojih se sastoje 125
Slika 72 - Analiza korisničkih oznaka prema broju riječi od kojih se sastoji prema vrsti građe 125
Slika 73 - Analiza korisničkih oznaka prema vrstama riječi 126
Slika 74 - Imenice prema vrsti, broju i rodu 126
Slika 75 - Tri razine analize prema modelu Panofsky/Shatford 128
Slika 76 - Razine isness, ofness i aboutness u analizi vizualne građe 129
Slika 77 - Analiza razina značenja korisničkih oznaka dodanih vizualnoj građi 131
Slika 78 - Analiza razine značenja *ofness* korisničkih oznaka dodanih vizualnoj građi 132
Slika 79 - Priprema seta termina za usporedbu u Python programskom rješenju 138
Slika 80 - Prikaz mjere preklapanja između predmetnica i korisničkih oznaka putem Venn dijagrama 139
Slika 81 - Funkcije getTagsAndSubjects i def calcKS implementirane u Pythonu 142
Slika 82 - Koeficijent sličnosti između predmetnica i korisničkih oznaka dodanih arhivskoj građi 144

Slika 83 - Udio pokrivenosti predmetnica u korisničkim oznakama dodanima arhivskoj građi 145
Slika 84 - Koeficijent sličnosti između predmetnica i korisničkih oznaka dodanih fotografijama 147
Slika 85 - Udio pokrivenosti predmetnica u korisničkim oznakama dodanima fotografijama 148
Slika 86 - Koeficijent sličnosti između predmetnica i korisničkih oznaka dodanih knjižničnoj građi 149
Slika 87 - Udio pokrivenosti predmetnica u korisničkim oznakama dodanima knjižničnoj građi 150
Slika 88 - Koeficijent sličnosti između predmetnica i korisničkih oznaka dodanih muzejskoj građi 152
Slika 89 - Udio pokrivenosti predmetnica u korisničkim oznakama dodanima muzejskoj građi 152
Slika 90 - Grafički prikaz intekvartilnih i gornjih graničnih vrijednosti preko box-plot grafa 159
Slika 91 - Određivanje gornje granične vrijednosti pomoću funkcije getTopOutlierCutoff . 160
Slika 92 - Model analize i primjene korisničkog označivanja u predmetnom opisu baštinske građe 186

Životopis i popis javno objavljenih radova autora

Tomislav Ivanjko (matični broj znanstvenika 314670) rođen je 1984. Diplomirao je 2008. godine radom s područja bibliotekarstva čime završava dvopredmetni studij komparativne književnosti i informacijskih i komunikacijskih znanosti na Filozofskom fakultetu Sveučilišta u Zagrebu. Dobitnik je nagrade Zaklade dr. Ljerke Markić-Čučuković za najboljeg studenta bliotekarstva na Sveučilištu u Zagrebu za ak. godinu 2004./2005. Od 2009. godine radi kao znanstveni novak na Odsjeku za informacijske i komunikacijske znanosti na projektu *Organizacija informacija i znanja u elektroničkom obrazovnom okruženju* (0130462) pod vodstvom prof. dr. sc. J. Lasić-Lazić u okviru znanstveno istraživačkog programa *Strategije digitalizacije znanja i baštine*. Aktivno sudjeluje u izvođenju nastave na preddiplomskim i diplomskim studijima Odsjeka za informacijske i komunikacijske znanosti. U sklopu znanstvenog rada sudjelovao je i izlagao na većem broju domaćih i međunarodnih znanstvenih konferencija i objavio dvadesetak znanstvenih radova. Član je Katedre za organizaciju znanja te se bavi pitanjima korisničkog označivanja, predmetne obrade te društvenog softvera.

Popis radova iz Hrvatske znanstvene bibliografije (CROSBI)

Poglavlja u knjizi

1. Banek Zorica, Mihaela; Špiranec, Sonja; Ivanjko, Tomislav. Folksonomies to enhance the knowledge organization and management // La médiation numérique : renouvellement et diversification des pratiques / Boustany, Joumana ; Broudoux, Evelyne ; Chartron, Ghislaine (ur.). Bruxelles : De Boeck, 2014. Str. 53-64.

2. Banek Zorica, Mihaela; Ivanjko, Tomislav.Social Networking at the University - Student Research Patterns and Online Activities // University Information Systems : selected problems / Leszek Rudak (ur.). Warsaw : Difin : EUNIS, 2010. Str. 473-482.

Znanstveni radovi u drugim časopisima

1. Banek Zorica, Mihaela; Ivanjko, Tomislav; Špiranec, Sonja.
Mystery Shopping in Libraries: are we ready?. // Qualitative and Quantitative Methods in Libraries - electronic journal. 2 (2014) ; 433-442 (članak, znanstveni).

2. Lasić-Lazić, Jadranka; Špiranec, Sonja; Ivanjko, Tomislav.
Tag-resource-user: a review of approaches in studying folksonomies. // Qualitative and Quantitative Methods in Libraries -electronic journal. 3 (2014) ; 683-692 (članak, znanstveni).

3. Špiranec, Sonja; Pečarić, Đilda; Ivanjko, Tomislav.
Attaining Employability Skills by Focusing on Information Competencies: How Far Are We?. // Qualitative and Quantitative Methods in Libraries-electronic journal. 4 (2014) ; 979-986 (članak, znanstveni).

4. Ivanjko, Tomislav.
Teaching Universal Decimal Classification (UDC) to undergraduate students: a folksonomy driven approach. // INFuture2013: Information Governance. 4 (2013) ; 97-103 (članak, znanstveni).

5. Zlodi, Goran; Ivanjko, Tomislav.
Crowdsourcing digital cultural heritage. // INFuture2013: Information Governance. 4 (2013) ; 199-207 (pregledni rad, znanstveni).

Znanstveni radovi u zbornicima skupova s međunar.rec.

1. Špiranec, Sonja; Ivanjko, Tomislav.
Providing access to textual and image resources: analyzing tagging practices // Proceedings of the 21st international BOBCATSSS conference: from collections to connections, turning libraries inside out / Taskin, Z. ; Cakmak, T. ; Dogan, G. (ur.).
Ankara : Hacettepe University Department of Information Management, 2014. 32-35 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

2. Špiranec, Sonja; Ivanjko, Tomislav; Pečarić, Đilda.
Implementation of information competencies as key employment skills at the Faculty of Humanities and Social Sciences // Proceedings of the 37th International Convention MIPRO 2014 / Biljanović, Petar (ur.).
Rijeka : MIPRO, 2014. 886-890 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

3. Špiranec, Sonja; Ivanjko, Tomislav.
Experts vs. Novices Tagging Behavior: An Exploratory Analysis // Proceedings of the 2nd International Conference on Integrated Information (IC-ININFO 2012) / Giannakopoulos, Georgios ; Sakas Damianos P. ; Vlachos, Dimitrios S. ; Kyriaki-Manessi, Daphne (ur.).
2013. 456-459 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

4. Banek Zorica, Mihaela; Ivanjko, Tomislav.
Knjižnice, studenti i društvene mreže : ispitivanje informacijskih navika studenata // Zbornik radova 4. međunarodne konferencije BAM 2010 - Evropske smjernice za saradnju biblioteka arhiva i muzeja : informacijske ustanove za 21. stoljeće / Rešidbegović, A ; Sabljaković, B. ; Grebović, N. (ur.).
Sarajevo : Asocijacija informacijskih stručnjaka - bibliotekara, arhivista i muzeologa, 2012. 135-143 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

5. Banek Zorica, Mihaela; Ivanjko, Tomislav; Benčec, Maja.
Social networking and libraries // Proceedings of the IADIS international conference e-Society 2012 / Kommers, P. ; Isaias, P. (ur.).
Berlin : IADIS, 2012. 511-515 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

6. Banek Zorica, Mihaela; Ivanjko, Tomislav; Benčec, Maja.
Croatian libraries on Facebook: content analysis // 35th International Convention MIPRO 2012: Computers in Education / Biljanović, Petar (ur.).
Rijeka : Croatian Society for Information and Communication Technology, Electronics and Microelectronics, 2012. 1316-1320 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

7. Banek Zorica, Mihaela; Ogrizek Biškupić, Ivana; Ivanjko, Tomislav.
Student interaction in electronic environment // IADIS MULTI CONFERENCE ON COMPUTER SCIENCE AND INFORMATION SYSTEMS 2011 - e-LEARNING 2011 / Baptista Nunes, Miguel ; McPherson, Maggie (ur.).
Rom, Italy : IADIS Press, 2011. 386-392 (međunarodna recenzija,objavljeni rad,znanstveni).

8. Banek Zorica, Mihaela; Ogrizek Biškupić, Ivana; Ivanjko, Tomislav; Špiranec, Sonja.
Students and Privacy in the Networked Environment // 34th International Convention MIPRO 2011: Computers in Education / Čičin-Šain, Marina ; Uroda, Ivan ; Turčić Prstačić, Ivana ; Sluganović, Ivanka (ur.).
Rijeka : Hrvatska udruga za informacijsku i komunikacijsku tehnologiju, elektroniku i mikroelektroniku, 2011. 127-131 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

Drugi radovi u zbornicima skupova s recenzijom

1. Špiranec, Sonja; Ivanjko, Tomislav.
Korisničko označivanje tekstualnih i vizualnih informacija: što mogu očekivati AKM ustanove? // 16. seminar Arhivi, knjižnice, muzeji : mogućnosti suradnje u okruženju globalne informacijske strukture : zbornik radova / Tomašević, Nives ; Despot, Ivana (ur.).
Zagreb : Hrvatsko knjižničarsko društvo, 2013. 66-79 (predavanje,domaća recenzija,objavljeni rad,znanstveni).

2. Špiranec, Sonja; Ivanjko, Tomislav.
Predmetni jezici s korisničkim jamstvom: što možemo naučiti od folksonomija? // 15. seminar Arhivi, knjižnice, muzeji : mogućnosti suradnje u okruženju globalne informacijske infrastrukture : zbornik radova / Hassenay, Damir. ; Krtalić, Maja (ur.).
Zagreb : Hrvatsko knjižničarsko društvo, 2012. 57-72 (predavanje,domaća recenzija,objavljeni rad,stručni).

3. Banek Zorica, Mihaela; Benčec, Maja; Brunšek, Iva; Ivanjko, Tomislav; Mišalongin, Ivana; Šajatović, Lidija.
Student u potrazi za informacijom : Mystery shopping u hrvatskim knjižnicama // 18. Proljetna škola školskih knjižničara Republike Hrvatske Hrvatske Školsko knjižničarstvo i cjeloživotno učenje : Zbornik radova / Šušnjić, Biserka ; Franko, Đudita (ur.).
Zagreb ; Rijeka : Agencija za odgoj i obrazovanje ; Prva sušačka gimnazija, 2007. 158-163 (predavanje,domaća recenzija,objavljeni rad,znanstveni).