Utjecaj velike količine podataka na znanstvenonastavni rad

Vujnovac, Elizabeta

Master's thesis / Diplomski rad

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Humanities and Social Sciences / Sveučilište Josipa Jurja Strossmayera u Osijeku, Filozofski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:142:671531

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

FILOZOFSKI FAKULTET
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

Repository / Repozitorij:

FFOS-repository - Repository of the Faculty of Humanities and Social Sciences Osijek

zir.nsk.hr

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište Josipa Jurja Strossmayera u Osijeku

Filozofski fakultet

Diplomski studij Informatologije

Elizabeta Vujnovac

Utjecaj velike količine podataka na znanstvenonastavni rad

Diplomski rad

Mentor: doc. dr. sc. Boris Bosančić

Osijek, 2015.

Sažetak

U radu je dan prikaz fenomena velike količine podataka odnosno 'velikih podataka' (engl. *big data*) te utjecaju tog fenomena na znanstvenonastavni rad. U teorijskom dijelu rada osim općenitog prikaza navedenog fenomena dan je i osvrt na znanstvenonastavni rad u digitalnom okruženju. Istraživački dio rada, koji je proveden u listopadu 2015. godine, obuhvatio je 73 znanstvenonastavnih djelatnika Filozofskog fakulteta u Osijeku. U istraživanju su sudjelovali nastavnici gotovo svih odsjeka i katedri te svih dobnih skupina. Ciljevi istraživanja bili su vezani uz propitivanje stavova znanstvenonastavnog osoblja u svezi fenomena velike količine podataka s kojim su suočeni u svom znanstvenonastavnom radu. Posebna pozornost posvećena je ispitivanju stavova ispitanika u svezi poznavanja termina velike količine podataka te izravnoj pogođenosti ili nepogođenosti ovim fenomenom. Rezultati istraživanja upućuju na to kako je znanstvenonastavno osoblje upoznato s terminom velike količine podataka te da smatraju kako su djelomično pogođeni ovim fenomenom.

Ključne riječi: velika količina podataka, *big data*, veliki podatci, znanstvenonastavno osoblje, znanstvenonastavni rad

Sadržaj

1. UVOD 1

2. ZNANSTVENONASTAVNI RAD U DIGITALNOM OKRUŽENJU 2

2.1. Općenito o znanstvenonastavnom radu u digitalnom okruženju 2

2.2. E-znanost 2

2.2. E-učenje 4

2.1.1. Objekti učenja 4

2.1.2. Moodle kao platforma za e-učenje 5

3. VELIKA KOLIČINA PODATAKA (engl. *big data*) 6

3.1. Povijesni kontekst 6

3.1.1. Informacijska eksplozija i informacijsko preopterećenje 6

3.1.2. Informacijska poplava 7

3.2. Općenito o velikoj količini podataka 8

3.2.1. Nastanak velike količine podataka 8

3.2.2. Definicija velike količine podataka 9

3.2.3. Tipovi velike količine podataka 11

3.2.4. Mogućnosti korištenja velike količine podataka 11

3.2.5. Izazovi velike količine podataka 13

3.2.6. Analitika velike količine podataka 14

3.2.7. Velika količina podataka i knjižnična znanost 14

3.3. Primjeri velike količine podataka u znanstvenonastavnom radu 15

3.3.1. Velika količina podataka i znanstvenonastavni rad 15

3.3.2. Velika količina podataka i znanstvena istraživanja - primjer CERN-a 15

3.3.3. Velika količina podataka i nastavni rad - primjeri repozitorija objekata učenja 17

4. ISTRAŽIVANJE UTJECAJA VELIKE KOLIČINE PODATAKA NA ZNANSTVENONASTAVNI RAD 18

4.1. Svrha i ciljevi istraživanja 18

4.2. Metodologija i uzorak istraživanja 18
4.3. Rezultati istraživanja 19
5. ZAKLJUČAK 30
LITERATURA 33
PRILOZI 35

1. UVOD

U današnje vrijeme, svjedoci smo enormnog porasta uporabe informacijsko-komunikacijske tehnologije u svim porama ljudskog društva. Upravo zbog rapidnog razvoja informacijsko-komunikacijske tehnologije, količina podataka iz dana u dan raste velikom brzinom. Takve podatke postaje sve teže obrađivati i vrednovati kako bi bili u stanju preuzeti ulogu informacija, a zatim i znanja.

Svrha ovoga rada odnosi se na općeniti prikaz fenomena velike količine podataka odnosno 'velikih podataka' (engl. *big data*) i njegova utjecaja na znanstvenonastavni rad. Ciljevi rada tiču se propitivanja stavova znanstvenonastavnog osoblja (konkretno, znanstvenonastavnog osoblja Filozofskog fakulteta u Osijeku) o fenomenu velike količine podataka. Istraživačkim dijelom rada htjelo se utvrditi koliko je znanstvenonastavno osoblje upućeno u temu 'veliki podatci', odnosno velika količina podataka. Pa tako, jedan od ciljeva rada je utvrditi u kojoj mjeri znanstvenonastavno osoblje smatra da proizvodi i koristi veliku količinu podataka u svom znanstvenonastavnom radu te drži li da je pogođeno ovim fenomenom.

U drugom poglavlju rada govori se o znanstvenonastavnom radu u digitalnom okruženju te o promjenama koje se događaju uslijed ubrzanog razvoja informacijsko-komunikacijske tehnologije. Naglasak se stavlja kako na znanstveni rad u digitalnom okruženju koji se odvija u okviru e-znanosti, tako i na nastavni rad u mrežnom okruženju koji je prikazan kroz osvrt na pojam e-učenja te kratki prikaz sustava e-učenja Moodle. Moodle se opisuje kao platforma za nastavni rad preko koje nastavno osoblje komunicira sa studentima funkcionirajući takoreći u okruženju velike količine podataka.

Iduće poglavlje rada osvrće se na povijesni kontekst nastanka velike količine podataka kroz opise fenomena koji su prethodili fenomenu velike količine podataka. Opisuju se fenomeni informacijske eksplozije (engl. *information explosion*), informacijskog preopterećenja (engl. *information overload*) te informacijske poplave (engl. *information flood*). Nakon njihova opisa slijedi i opis fenomena velike količine podataka. Nakon poglavlja o velikoj količini podataka, slijedi poglavlje o primjerima velike količine podataka u znanstvenonastavnom radu čime se zaključuje teorijski dio rada.

Četvrto poglavlje donosi rezultate istraživanja provedenog u listopadu 2015. godine na Filozofskom fakultetu u Osijeku. Istraživanje je obuhvatilo znanstvenonastavno osoblje fakulteta. U istraživanju se putem anketnog upitnika s 12 pitanja pokušalo ući u trag

stavovima znanstvenonastavnog osoblja spram fenomena velike količine podataka. Pogotovo, drže li da su izravno pogođeni ovim fenomenom i ako da, u kojoj mjeri.
U zaključku rada, obrazloženi su rezultati istraživanja (kroz potvrđivanje i opovrgavanje postavljenih hipoteza istraživanja) te su iznesena promišljanja o budućim sličnim istraživanjima.

2. ZNANSTVENONASTAVNI RAD U DIGITALNOM OKRUŽENJU

2.1. Općenito o znanstvenonastavnom radu u digitalnom okruženju

Društvo i društvene institucije mijenjaju se uslijed rapidnih promjena koje sa sobom nosi razvoj informacijsko-komunikacijske tehnologije. Informacijsko-komunikacijska tehnologija omogućila je veću i bržu diseminaciju znanja i komunikacije unutar znanosti. Između ostalog, omogućila je i diseminaciju informacija na brz, jednostavan i učinkovit način, povezujući cijeli svijet. Tehnologija nam danas omogućuje kreiranje i povezanost zajednica u digitalnom odnosno mrežnom okruženju.[1] Napredak informacijske-komunikacijske tehnologije mijenja povezanost čovjeka i znanja, odnosno informacijsko-komunikacijska tehnologija jača veze čovjeka sa znanjem. Visoko školstvo i znanost među prvima su iskusili promjene koje je donijela informacijsko-komunikacijska tehnologija u vidu edukacije putem računala, odnosno interneta.[2] Znanstvenonastavni rad u digitalnom okruženju postaje popularan krajem 20. stoljeća kada se pristup znanosti mijenja radi uporabe informacijsko-komunikacijske tehnologije i interneta. Novi pojmovi s prefiksom "e-" i "kiber-" (engl. *cyber*) poput e-znanosti (engl. *e-science*), e-infrastrukture (engl. *e-infrastructure*), e-istraživanja (engl. *e-Research*), e-učenja (engl. *e-learning*) te kiberinfrastrukture (engl. *cyberinfrastructure*) i kiberinženjerstva (engl. *cyberenglineering*) odnose se na novu paradigmu shvaćanja znanstvenonastavnog rada koji se veže s izrazima dijeljenja i distribuiranja informacija te, dakako, suradnje znanstvenonastavnog osoblja u mrežnom okruženju.

2.2. E-znanost

Navedeni termini s prefiksima "e-" i "kiber-" najčešće se dovode u vezu s pojmom znanstvene informacijske infrastrukture odnosno informacijske infrastrukture koja postaje bitan dio razvoja znanstvenog rada u budućnosti. Konkretan pojam informacijske infrastrukture najviše

[1] Usp. Duderstadt, James J.; Atkins, Daniel E.; Houweling, Douglas Van. Higher education in the digital age: technology issues and strategies for American colleges and universities. Westport: Praeger publishers, 2002. Str. 1-2.
[2] Usp. Isto. Str. 1.

je povezan s pojmovima e-istraživanje i kiberinfrastruktura. U literaturi se znanstvena informacijska infrastruktura definira kao skupni pojam tehničkog, socijalnog i političkog okvira koji u obzir uzima ljude, tehnologiju, alate i usluge u svrhu napretka distribuirane i kolaborativne uporabe sadržaja kroz vrijeme te na daljinu.[3] E-istraživanje i kiberinfrastruktura ističu se radi zajedničkog cilja unaprjeđivanja znanstvene suradnje kroz osiguranje pristupa podatcima koji nastaju kroz proces istraživanja te dokumentima koji koriste navedene podatke uz podršku određenih alata i usluga. Informacijska infrastruktura osigurava središnje mjesto te stavlja naglasak na podatke znanstveno-istraživačkog rada. E-istraživanje nudi mogućnost ubrzavanja znanstvenog istraživanja te ga olakšava i čini učinkovitijim. Jedan od temeljnih pojmova e-istraživanja je e-znanost, koja se opisuje kao znanost velikih razmjera, zasnovana na suradnji, koja se javlja kao posljedica uporabe informacijsko-komunikacijske tehnologije. E-znanost, kao i ostali koncepti koji su početkom 21. stoljeća dobili prefikse "e-", samo nadopunjuju već postojeće kocepte te ne predstavljaju nove discipline nego se vežu uz novu znanstvenu informacijsku infrastrukturu koja omogućuje brža i učinkovitija istraživanja i komunikaciju.[4] Prve inicijative za izgradnju informacijske infrastrukture pokrenute su 2000. u Velikoj Britaniji te 2003. u SAD-u. Uredi za istraživanje Velike Britanije objavili su Osnovni program e-znanosti u kojemu nude i definiciju e-znanosti kao znanosti velikih razmjera koja se ostvaruje kroz distribuiranu globalnu suradnju omogućenu uporabom interneta. Nacionalna zaklada za znanost u SAD-u objavila je izvještaj o kiberinfrastrukturi u kojemu govori o tome kako je razvoj informacijsko-komunikacijske tehnologije dosegao stupanj uspostave sveobuhvatne kiberifrastrukture u kojoj će se znanstveno-istraživački rad provoditi na mnogo učinkovitiji način.[5] E-znanost i e-istraživanje su koncepti koji opisuju nastajanje znanstveno-informacijske infrastrukture iz koje je kasnije niknulo nekoliko novih koncepata s prefiksom "e-", od kojih je jedan i e-učenje. Općenito, koncepti s prefiksom "e-" ili prefiksom "kiber-" razlikuju se od tradicionalnih koncepata upravo po količini proizvedenih podataka koji se vežu uz njih. Primjerice, u tradicionalnoj znanosti stjecao se dojam da je porast podataka relativno umjeren, dok e-znanost obilježava rapidan porast podataka. Razlog tomu leži upravo u povećanom korištenju informacijsko-komunikacijske tehnologije i informacijskoj infrastrukturi koja nastaje kao posljedica toga.

[3] Usp. Borgman, C. L. What can studies of e-learning teach us about collaboration in e-research? Some findings from digital library studies. // Computer Supported Cooperative Work 15(2006), str. 359.
[4] Usp. Borgman, C. L. Scholarship in the digital age: information, infrastructure, and the internet. Cambridge; Massachusetts: MIT Press, 2007. Str. 19.
[5] Usp. Bosančić, Boris. Označavanje teksta starih knjiga na hrvatskom jeziku pomoću TEI standarda / doktorska disertacija. Zadar: Odjel za informacijske znanosti, 2011. str. 19-21.

2.2. E-učenje

E-učenje je osnova nastavnom radu u mrežnom okruženju. Odlikuju ga mnoge prednosti spram tradicionalnog načina učenja. Današnje tržište rada zahtjeva poznavanje informacijsko-komunikacijske tehnologije i snalaženje u mrežnom okruženju. E-učenje uzelo je maha devedesetih godina 20. stoljeća kada se informacijsko-komunikacijska tehnologija počela rapidno razvijati što je omogućilo integraciju znanstvenonastavnog i digitalnog okruženja. Velike ekonomske i socijalne promjene te tehničke predispozicije postavile su pivot u obrazovanju mladih generacija. Razvoj sustava obrazovanja zahtjeva prelazak s tradicionalnog na digitalno okruženje, odnosno mijenjanje strategija učenja i poučavanja, što naposljetku učenje i poučavanje premješta u digitalno okruženje.[6]

Proširivanjem tradicionalnog učenja u e-učenje, materijali za učenje mijenjaju svoj oblik pa tako tradicionalni materijali za učenje (udžbenici i vježbenice) dobivaju nadopunu u vidu digitalnih materijala za učenje. Esencijalna važnost digitalnih materijala za učenje je u tome što su svi digitalni materijali dostupni svima za razliku od tradicionalnih. Upravo zbog svoje dostupnosti i količine e-materijala, koja je u konstantnom porastu, e-učenje i e-materijali se dovode u vezu s fenomenom velike količine podataka. Velika količina podataka u nastavi se, dakle, između ostalog, odnosi i na veliku količinu dostupnih e-materijala te na konstantan porast e-materijala, pa tako i na porast podataka i informacija.[7]

2.1.1. Objekti učenja

Ono što je bitno spomenuti kada se govori o nastavnim materijalima i e-materijalima su objekti učenja. Objekti učenja (engl. *learning objects*) opisuju se kao elementi znanja koji se koriste u obrazovnom procesu.[8] Takav element znanja koristi se u obrazovnim materijalima koji su izrađeni s namjenom da se koriste preko interneta. Stoga, element znanja u obrazovnim materijalima zapisan je u digitalnom obliku. Objekt učenja, odnosno element znanja, može sadržavati kratki tekst, npr. u definiciju ili citat, može sadržavati vizualni zapis, npr. crtež, sliku ili shemu, audio zapis, npr. glazbenu ilustraciju, video zapis npr. simulaciju ili igrani film te interaktivnu mrežnu stranicu. Objekt učenja može sadržavati samo jedan element znanja, ali isto tako može biti i cjelokupna mrežna stranica ili kompletno predavanje o nekoj temi, kao i kompletan mrežni tečaj. Ono što obilježava objekte učenja je

[6] Usp. Duderstadt, James J.; Atkins, Daniel E.; Houweling, Douglas Van. Higher education in the digital age: technology issues and strategies for American colleges and universities. Nav. dj. str. 1-2
[7] Usp. Isto. Str. 2
[8] Usp. Objekti učenja "Learning Objects". URL: http://www.carnet.hr/referalni/obrazovni/iom/LO.html (2015-10-13)

karakteristika ponovnog korištenja sadržaja, da su pristupačni preko interneta te da se mogu jednostavno koristiti u raznim primjenama i raznim programskim okruženjima.[9] Organizacije koje koriste objekte učenja u obrazovnom procesu koriste i repozitorije objekata učenja. Repozitorij objekata učenja je zbirka obrazovnih materijala u digitalnom obliku, koja omogućuje sustavno korištenje i pohranjivanje svih sadržaja koji imaju veze s obrazovanjem.[10] U repozitorijima objekata učenja, svaki objekt učenja je opisan odabranim skupom metapodataka te osigurava pretraživanje po različitim kriterijima.[11] [12]

Web 2.0 servisi podupiru digitalne materijale za učenje koji se temelje na digitalnim protokolima i standardima. Primjer jednog takvog standarda je SCORM (engl. *Sharable Content Object Reference Model*) koji omogućuje dijeljenje i upravljanje videima, animacijama i mrežnim testovima odnosno provjerama znanja učenika i studenata. Jedan od sustava e-učenja koji koriste ovaj standard je i Moodle.[13]

2.1.2. Moodle kao platforma za e-učenje

Moodle je platforma za e-učenje koja je kreirana na način da znanstvenonastavnoj zajednici omogući kreiranje personaliziranog okruženja za e-učenje, podržavajući učenje i podučavanje putem velikog broja integriranih alata.[14] Moodle je softversko rješenje za kreiranje i održavanje mrežnih odnosno *online* kolegija putem interneta. Projekt Moodle se kontinuirano razvija te za cilj ima potporu obrazovnom okruženju koje se naziva društvenom pedagogijom konstrukcionizma (engl. *social constructionist pedagogy*).[15] Ova platforma je raspoloživa kao softver otvorenog kôda što znači da je Moodle zaštićen autorskim pravom, no dozvoljeno ga je kopirati, koristiti i mijenjati pod sljedećim uvjetima: da se pristup otvorenom kôdu omogući drugima, da se originalna licenca i obavijest o autorskom pravu ne mijenja ili uklanja te da se ista licenca primjenjuje na bilo koje buduće softversko rješenje. Moodle može pokretati bilo

[9] Usp. Isto.
[10] Usp. Isto.
[11] Usp. Repozitoriji objekata učenja. URL: http://www.carnet.hr/referalni/obrazovni/iom/LO4.html (2015-10-13)
[12] O repozitorijima objekata učenja u kontekstu fenomena velike količine podataka govorit će se u poglavlju 3.3.3.
[13] Usp. Molnar, Gyorgy. Teaching and Learning in modern digital Environment. // IEEE 13th International Symposium on Applied Machine Intelligence and Informatics, Slovakia, 2015. URL: https://www.researchgate.net/publicliterature.PublicLiterature.search.html?type=keyword&search-keyword=teaching+and+learning++in+modern+digital+environment (2015-09-22)
[14] Usp. About Moodle. URL: https://docs.moodle.org/29/en/About_Moodle#Backed_by_a_strong_community (2015-09-22)
[15] Usp. Isto.

koje računalo koje podržava PHP[16] i neku od poznatijih baza podataka, poglavito MySQL[17]. Sama riječ Moodle je akronim za modularno objektno-orijentirano dinamičko obrazovno okruženje (engl. *Modular Object-Oriented Dynamic Learning Environment*).[18]

Ova platforma samo je jedan od primjera mnogih drugih platformi koje omogućuju komunikaciju znanstvenonastavnog osoblja sa studentima te evaluaciju studenata u digitalnom okruženju. Izazov učenja u digitalnom okruženju je praćenje velike količine mrežno dostupnih materijala za učenje te evaluacija materijala za e-učenje. Nastavak ovoga rada tiče se velike količine podataka, odnosno podataka koje znanstvenonastavno osoblje rabi u svom znanstvenonastavnom radu.

3. VELIKA KOLIČINA PODATAKA (engl. *big data*)

3.1. Povijesni kontekst

3.1.1. Informacijska eksplozija i informacijsko preopterećenje

Informacijska eksplozija javlja se već s otkrićem tiskarskog stroja. Ovaj fenomen može biti definiran i kao ubrzani porast objavljenih informacija. Takav ubrzani porast informacija krivac je za situaciju u kojoj su korisnici informacija 'pretrpani' dostupnim informacijama. Informacijska eksplozija opisuje se i sintagmom informacijsko preopterećenje.[19] Informacijsko preopterećenje je stanje posjedovanja previše informacija te se u takvoj poziciji ne može donijeti relevantna odluka vezana uz nekakav problem.[20] Postoje dva tipa informacijskog preopterećenja: osobno preopterećenje i organizacijsko preopterećenje. Osobno preopterećenje događa se kada pojedinac traženjem određenih informacija vezanih uz obavljanje nekog zadatka dobije prekomjernu količinu informacija koje se ne mogu učinkovito obraditi upravo zbog svoje količine. Organizacijsko preopterećenje odnosi se na organizacije preopterećene količinom informacija do te mjere da informacije ne mogu obraditi, a samim time niti upotrijebiti. Do informacijske eksplozije dolazi upravo zbog velike količine objavljenih informacija iz kojih je teško procijeniti one relevantne i manje relevantne

[16] Programski jezik (engl. Hypertext Preprocessor)
[17] Relacijska baza podataka u otvorenom pristupu (engl. Structured Query Language)
[18] O Moodle rješenju. URL: https://docs.moodle.org/all/hr/O_Moodle_rje%C5%A1enju (2015-10-12)
[19] Usp. Kadiri, Jasiliu A.; Aderoto, Niran A. Infofmation explosion and the chalanges of information and communication technology utilization in Nigerian libraries and information centres. // Ozean Journal of Social Sciences 5, 1(2012), str. 21-30.
[20] Information explosion. URL: http://www.newworldencyclopedia.org/entry/Information_explosion (2015-09-14)

informacije.[21] Procijenjeno je kako je ljudska populacija proizvela 180 egzabajta (180 EB)[22] podataka od početaka pismene komunikacije do 2006. godine. Između 2006. i 2011. godine, porast se povećao za deset puta i dosegao 1600 egzabajta (1600 EB) proizvedenih podataka. Količina porasta podataka za 1600 egzabajta očekuje se svake 3 godine.[23]

3.1.2. Informacijska poplava

Moderno doba donosi jednu paradoksalnu situaciju: iako postoji vrlo velika količina dostupnih informacija, iz te nagomilane mase informacija vrlo je teško izlučiti relevantne. Dokazano je kako su kvaliteta i efikasnost u donošenju odluka u pozitivnoj korelaciji s količinom informacija kojima su ljudi koji donose određene odluke izloženi.[24] U slučaju da prime previše informacija, efikasnost donošenja odluka se rapidno smanjuje. Fenomen koji se pojavljuje u takvim situacijama zove se informacijska poplava (engl. *information flood*), a nastao je također kao posljedica velike proizvodnje podataka.[25] U 2003. procjenjeno je kako je čovječanstvo stvorilo 12 egzabajta[26] (12 EB) podataka. Jednako tako, samo u 2002. godini, procjenjeno je da tiskana građa, film, magnetički i optički mediji za pohranu podataka sadrže više od 5 egzabajta (5 EB) podataka. Navedena količina podataka koja je proizvedena u 2002.[27] može se ekvivalentno prikazati kao 37000 knjižnica veličine Kongresne knjižnice. S obzirom na broj stanovništva svih zemalja, odnosno kada se ovi podatci podijele na svakog stanovnika Zemlje, izračunato je kako je svaka osoba na svijetu proizvela 800 megabajta podataka u 2002. godini. Od 800 megabajta (800 MB) navedenih podataka po osobi, čak 92% podataka je pohranjeno na nekom od magnetskih medija, najviše na tvrdim diskovima. Ovakva pojava proizvodnje informacija uzrokuje tzv. "demokratizaciju" informacija. Sve veći broj ljudi stvara sve više informacija nego ikada prije u povijesti. Kvantitativno gledajući, količina digitalnih podataka eksponencijalno raste. Upravo zbog izuzetno velikog porasta količine digitalnih podataka te stvaratelja istih, skovan je termin 'egzabajt poplava' (engl. *Exaflood*). Stotine milijuna računala svakodnevno su 'u pogonu' kako bi omogućili opstanak informacija iz digitalnih izvora te razumijevanje i upravljanje istima. Razvojem tehnologije i povećanjem količine informacija iz digitalnih izvora, sa sigurnošću se može reći kako će

[21] Usp. Nav.dj. str. 22
[22] Usp. Exabyte. URL: http://techterms.com/definition/exabyte (2015-09-14)
[23] Usp. Floridi, Luciano. Big Data and Their Epistemological Challange. // Philosophy & Technology 25, 4(2012), str. 435-437. URL: http://link.springer.com/article/10.1007%2Fs13347-012-0093-4 (2015-09-14)
[24] Usp. Isto.
[25] Usp. Breuker, Joost et. al. Law, Ontologies and the semantic Web: Channelling the Legal Information Flood Amsterdam: IOS Press, 2009. Str. 3-4.
[26] Usp. Exabyte. Nav. dj.
[27] Usp. Floridi, Luciano. Big Data and Their Epistemological Challange. Nav. dj. Str. 435-437.

digitalni podatci i dalje količinski rasti te kako ćemo se uskoro približiti zetabajt eri (engl. *Zettabyte - ZB*).[28]

3.2. Općenito o velikoj količini podataka

3.2.1. Nastanak velike količine podataka

Proizvodnja velike količine različitih podataka poput fotografija, videozapisa i audiozapisa na dnevnoj razini dovela je do nastanka koncepta velike količine podataka. Brza evolucija informacijsko-komunikacijske tehnologije dovela je do povećanja podataka kojima se na dnevnoj razini treba upravljati. U 2009. svijet je proizveo 800 egzabajta podataka, a u 2011. proizvedeno 1,8 zetabajta (1,8 ZB) podataka. Predviđa se kako će svijet do 2020. godine proizvesti 40% više podataka nego što je proizveo do 2011. godine. S obzirom na to da su mjerne jedinice poput egzabajta i zetabajta relativno nepoznate, u Tablici 1 navedene su mjerne jedinice količine podataka.

Tablica 1. Mjerne jedinice količine podataka.[29]

Tablica mjernih jedinica količine podataka			
Naziv	**Oznaka**	**Izgovor**	**Ekvivalent**
Bit	**b**	bit	–
Byte	**B**	bajt	8 b
Kilobyte	**KB**	kilobajt	1024 B
Megabyte	**MB**	megabajt	1024 KB
Gigabyte	**GB**	gigabajt	1024 MB
Terabyte	**TB**	terabajt	1024 GB
Petabyte	**PB**	petabajt	1024 TB
Exabyte	**EB**	egzabajt	1024 PB
Zettabyte	**ZB**	zetabajt	1024 EB
Yottabyte	**YB**	jotabajt	1024 ZB
Brontobyte	**BB**	brontobajt	1024 YB
Geobyte	**GEB**	geobajt	1024 BB

Veliko povećanje broja podataka, kao što je već rečeno, veže se uz ubrzan razvoj informacijsko-komunikacijske tehnologije. U 2011. prodano je sveukupno 63,3 milijuna tableta u svijetu, što je zahtijevalo svojevrsnu proliferaciju interneta odnosno povećanje broja dostupnih točaka za pristup internetu, primjerice u kafićima, restoranima, hotelima i

[28] Usp. Floridi, Luciano. Information: A very short introduction. New York: Oxford University Press, 2010. Str. 6-8. URL: http://lustiag.pp.fi/data/pdf/Fld.pdf (2015-09-14)

[29] Čelebić, Gorana; Rendulić, Dario Ilija. ITdesk.info - projekt računalne e-edukacije sa slobodnim pristupom - priručnik za digitalnu pismenost: osnovni pojmovi informacijske i komunikacijske tehnologije. Zagreb: Otvoreno društvo za razmjenu ideja, 2011. str. 9-10.

trgovinama. Pametne kuće, čiji su svi uređaji umreženi, proizvode ogromnu količinu podataka. Povećana dostupnost i prekomjerno korištenje interneta doveli su do detekcije novog fenomena - 'podatkovnog potopa' (engl. *data deluge*), jer je gotovo svaki aspekt života pojedinca moguće zabilježiti na internetu. Svijet danas broji oko 5 milijardi mobilnih telefona i milijune senzora povezanih s mobilnim uređajima. Društvene mreže koje su popularne zadnjih nekoliko godina proizvode veliku količinu podataka. Facebook bilježi 2,7 milijardi "sviđa mi se" (engl. *like*) klikova i 2,5 milijarde dijeljenih sadržaja poput objava, fotografija i videozapisa na dnevnoj razini. Tweeter, s druge strane, također broji 50 milijardi tvitova (engl. *tweets*) dnevno. Dakle, uzimajući u obzir društvene mreže odnosno društvene servise, potrebno je sačuvati i obraditi 500 terabajta (500 TB) podataka svakodnevno. Također, događa se i porast populacije koja koristi internet, što objašnjava eksploziju podataka u mrežnom okruženju, pa je tako za 2016. godinu procijenjeno da će broj korisnika interneta narasti na 3,4 milijarde, što je 45% svjetske populacije.[30]

3.2.2. Definicija velike količine podataka

Velika količina podataka je vrlo kompleksan pojam koji nema točno strukturiranu definiciju. Fraza 'velika količina podataka' odnosi se na velik, različit i kompleksan set podataka koji je generiran odnosno isporučen i stvoren od strane mjernih uređaja, senzora, e-mailova, videa, mrežnih transakcija, virtualnih tragova i svih ostalih digitalnih izvora. Točnije, termin 'velika količine podataka' skovan je nakon što su termini poput 'informacijske eksplozije' i 'informacijske poplave' prestali biti aktualni, no, ideja ostaje ista, odnosno termin 'velika količina podataka' se nadovezuje na prethodne termine. Velika količina podataka je sinonim eksponencijalnom rastu podataka koji se događa zbog razvoja novih tehnologija. Kompleksnost velike količine podataka naime ne leži u samom rastu tih podataka, ni njihovoj količini, nego u takozvanim 'malim uzorcima' (engl. *small patterns*) podataka. Problematično je pronaći te male uzorke podataka koji svakodnevno nastaju i koji su sastavni dijelovi bilo koje vrste znanja. Mali dijelovi odnosno uzorci podataka su relevantni jedino ako ih se prikuplja i upotrijebljava na pravi način, odnosno kada taj prikupljeni podatak postaje informacija, a ta informacija znanje. Količina podataka raste i uvijek će rasti. Stoga, velika količina podataka postaje 'veliki problem' sve do trenutka dok se ne ovlada odgovarajućom

[30] Usp. El Jamiy, Fatima et al. The potential and challengles of Big data - Recommendation systems next level application. // CoRR 23, (1)2015, str. 1-2. URL: http://arxiv.org/ftp/arxiv/papers/1501/1501.03424.pdf (2015-09-24)

metodom koja će biti u stanju izlučiti podatke koji su bitni i koji se mogu iskoristiti.[31] Velika količina podataka opisuje se s 3V, odnosno u novije vrijeme, s 5V obilježjima:

- Količina (engl. *Volume*) podataka
- Brzina (engl. *Velocity*) podataka
- Raznolikost (engl. *Variety*) podataka te
- Vjerodostojnost (engl. *Veracity*) podataka i
- Vrijednost (engl. *Value*) podataka.

Obilježje količine 'velikih podataka' odnosi se na brojnost podataka kojima je potrebno upravljati. Nikada u prošlosti nije postojalo više podataka nego sada, njihova količina, kao što je rečeno, raste eksponencijalno - čak 90% svih dostupnih podataka proizvedeno je u zadnje dvije godine. Količina podataka više se ne opisuje u gigabajtima već u terabajtima, petabajtima, egzabajtima i zetabajtima. Drugo obilježje 'velikih podataka' odnosi se na brzinu kojom podatci nastaju i brzinu kojom se obrađuju. Čovječanstvo je zainteresirano za dobivanje znanja iz neobrađenih podataka u realnom vremenu, što je praktički nemoguće ostvariti. Idealna situacija bila bi, dakle, obrađivanje podataka u trenutku kada oni nastanu. Raznolikost podataka odnosi se na tipove prikupljenih odnosno nastalih podataka. Podatci koji se analiziraju nisu strukturirani jednako kao prethodno analizirani podatci jer je teško zadržati dosljednost. Potrebno je dodavati vrijednost tradicionalnim podatcima kombinirajući ih s podatcima velike raznolikosti vanjskih izvora. Vjerodostojnost podataka je najvažnije obilježje fenomena velike količine podataka. Ono govori o problematici velike količine podataka - njihovoj relevantnosti i točnosti. Vjerodostojnost podataka naglašava potrebu za izdvajanjem kvalitetnih podataka iz velike količine podataka, točnije, odnosi se na potrebu za točnim i provjerenim sustavima za upravljanje 'velikim podatcima'. Najveći problem vjerodostojnosti podataka je ubrzani porast broja izvora podataka koji povećava količinu, ali smanjuje relevantnost podataka. Posljednje obilježje odnosi se na vrijednost 'velikih podataka' te predstavlja moguću uporabu i dobrobit dobivenu od podataka odnosno dobivanje korisnih informacija i naposljetku znanja. Dakle, kako bi se dobili uistinu vrijedni podatci, potrebno je uvrstiti određene, potencijalno bitne podatke u analize te odatle dobiti istinski vrijedne - informaciju i znanje.[32]

[31] Usp. Floridi, Luciano. Big Data and Their Epistemological Challange. // Philosophy & Technology 25, 4(2012), str. 435-437. URL: http://link.springer.com/article/10.1007%2Fs13347-012-0093-4 (2015-09-14)
[32] Usp. El Jamiy, Fatima et al. The potential and challengles of Big data - Recommendation systems next level application. Nav. dj. str. 1-2.

3.2.3. Tipovi velike količine podataka

Velike organizacije poput Facebooka, Googlea, Twittera i Amazona bile su među prvima koje su se suočile s povećanjem količine podataka na internetu. Kada se spominje termin 'velika količina podataka', bitno je razriješiti dileme vezane uz tipove velike količine podataka, odnosno odrediti koji tipovi podataka su upravo velika količina podataka ili točnije, odrediti koje naravi su ti podatci. Potrebno je razlikovati tri osnovna tipa 'velikih podataka' odnosno velike količine podataka:

- nestrukturirani podatci
- strukturirani podatci te
- polustrukturirani podatci

Nestrukturirani podatci su kategorija podataka koja se sastoji, primjerice, od PDF-ova (engl. *Portable Document Format*), e-mailova i dokumenata koji ne koriste niti jedan specifičan tip obrade podataka. Navedeni dokumenti postoje i pojavljuju se u istom formatu u kojemu su prikupljeni. Strukturirarni podatci su kategorija podataka koja uključuje tipove podataka koji se obrađuju te dopuštaju pohranu i uporabu podataka. Takvi podatci nalaze se u tradicionalnim bazama podataka koje nastoje proširiti svoje horizonte dovoljno kako bi mogle prikupljati, pohranjivati i analizirati i nestrukturirane i polustrukturirane podatke. Polustrukturirani podatci su kategorija podataka koja uključuje obrađene, ali nedovoljno obrađene podatke. Označeni tekst koji koristi XML ili HTML su primjeri polustrukturiranih podataka.[33]

3.2.4. Mogućnosti korištenja velike količine podataka

Dostupnost velike količine podatake može poboljšati donošenje odluka unutar organizacije te povećati kompetitivnost organizacije i ostalih javno-administrativnih službi te utjecati na razvoj globane ekonomije. Velika količina podataka pospješuje komunikaciju s korisnicima, odnosno putem analize 'velikih podataka' organizacije su u mogućnosti znati što njihovi korisnici mogu od njih očekivati. Također, analiza 'velikih podataka' koristi se u svrhu proučavanja određenih usluga i podizanja vrijednosti usluga. Dakle, logično je kako se analiza velike količine podataka može primijeniti u velikom broju područja, od znanstvenih istraživanja do nacionalne sigurnosti, od globalne ekonomije do javne društvene

[33] Usp. Grover, Nidhi. "Big Data" - Architecture, Issues, Opportunities and Challanges. // International Journal of Computer and Electronics Research 3, 1(2014), str. 26-27. URL: http://ijcer.org/index.php/ojs/article/view/497/229 (2015-09-28)

administracije (npr. porezne uprave). Slijedi nekoliko područja kojima je analiza velike količine podataka od presudne važnosti.

Prvo područje je područje poduzetništva i trgovine. U području poduzetništva i trgovine količina podataka se svakih 1,2 godine udvostruči gotovo u svim velikim poduzećima. Proučavanje velike količine podataka u poduzećima pomoglo bi optimiziranju poduzetničkog procesa, otkrivanju uzoraka poslovanja, boljem razumijevanju klijenata, njihovog ponašanja, potreba i namjera. Drugo područje koje ima koristi od prikupljanja i analize velike količine podataka je područje znanosti i istraživačkog rada. Ovo područje proizvodi velike količine podataka različitoga tipa jer se temelji na otkrivanju različitih tipova podataka.[34] Sljedeće područje prikupljanja i analize velike količine podataka pripada zdravstvu. Javno zdravstvo i medicina su područja u kojema prikupljanje i analiza velike količine podataka omogućuju efektivno liječenje te smanjuje troškove istoga. Analiza velike količine podataka u ovom području omogućuje otkrivanje, praćenje i poboljšanje zdravstva u svim aspektima te predviđanje uzoraka različitih bolesti.[35] Velika količina podataka u zdravstvu povezana je i sa specifičnim informacijama o pacijentima. Primjer toga su magnetska rezonanca i CT skeniranje koji bilježe patološke karakteristike pacijenata te također analiziraju velike količine podataka.[36] Navedena područja naročito su zainteresirana za analizu velike količine podataka, no velika količina podataka analizira se i u užim, odnosno specifičnijim područjima. Mobilni operateri odnosno mobilne tvrtke također analiziraju velike količine podataka. Predviđa se kako će do 2016. godine mobilno podatkovni promet porasti na 10,8 egzabajta podataka na mjesečnoj razini i to radi porasta korištenja pametnih telefona i tableta. Analiza velike količine podataka u području mobilnih mreža potrebna je radi poboljšanja kvalitete mrežne usluge mobilnih operatera, sigurnosti te kontroliranja mobilnog prometa. Sljedeće područje koje primjenjuje analizu velike količine podataka tiče se sigurnosti odnosno video nadzora. Za potrebe sigurnosti (najčešće fizičkih objekata) prikuplja se velika količine podataka u obliku video zapisa. Mediji, koji prikupljaju velike količine podataka o svojim korisnicima i njihovim navikama gledanja ili čitanja, također analiziraju velike količine podataka u svrhu dobivanja informacija o svojim korisnicima. Velika količina

[34] Kao primjer, u poglavlju 3.3.1. razmotrit će se slučaj Europske organizacije za nuklearna istraživanja (engl. *European Organization for Nuclear Research - CERN*) koja u svom nuklearnom laboratoriju pogoni Veliki hadronski sudarač čestica (engl. *The Large Hadron Collider*), danas najsnažniji ubrzivač i sudarač čestica u svijetu. LHC proizvodi toliko podataka da su za njihoo prikupljanje i analizu potrebne tisuće računala na 150 podatkovnih centara diljem svijeta. Drugim riječima, CERN je eklatantni primjer proizvodnje i analize enormne količine podataka za potrebe znanstveno-istraživačkog rada.

[35] Usp. El Jamiy, Fatima et al. The potential and challengles of Big data - Recommendation systems next level application. Nav. dj. str. 3.

[36] Usp. Grover, Nidhi. "Big Data" - Architecture, Issues, Opportunities and Challanges. Nav. dj. Str. 29.

podataka pojavljuje se i u GPS uređajima koji na svoj način analiziraju 'velike podatke' te im daju značenje. Studije okoliša prikupljaju i analiziraju podatke tisuća senzora koji nadziru zrak, vodu i meteorološke uvjete. Pažljiva analiza ovih velikih podataka može se koristiti za predviđanje klimatskih uvjeta i kontrolu podzemnih voda te kontrolu povećanja CO_2 emisija u atmosferi.

3.2.5. Izazovi velike količine podataka

Fenomen velike količine podataka sadrži i neke izazove s kojima se treba suočiti. Kada je u pitanju velika količina podataka, izazovi se tiču same pohrane, prikupljanja i analize takvih podataka. Svaka osoba suočena s velikom količinom podataka, a to je gotovo svaka osoba koja pristupa internetu, suočena je s ogromnim količinama podataka koji nastaju ogromnom brzinom te ih je vrlo teško koristiti, odnosno pronaći njihovu vrijednost i uporabljivost. Informacijska poplava rezultirala je velikom količinom nestrukturiranih i polustrukturiranih podataka kojima je teško upravljati, stoga su izazovi velike količine podataka sljedeći:

- integracija i prikupljanje velike količine podataka,
- prijenos velike količine podataka te
- analiza velike količine podataka.

Integracija i prikupljanje podataka odnosi se na pronalaženje i pohranu velike količine podataka. Svakodnevno se proizvodi 2,5 kvintilijuna bajtova podataka[37], a količina proizvedenih podataka na dnevnoj bazi raste svakodnevno. Zbog nemogućnosti pohrane svih podataka koji se proizvode, podatci se moraju brisati jer je danas još uvijek teško obraditi i pohraniti velike količine podataka. Drugim riječima, radi nemogućnosti pohrane podataka, neki potencijalno korisni podatci mogu biti izgubljeni. Prijenos velike količine podataka je u ovisnosti o mrežnoj pohrani podataka. Pohrana velika količine podataka na mreži popularizirala je takozvane 'računalne oblake' (engl. *cloud computing*). 'Računalni oblaci' organizacijama, ali i pojedincima, dopuštaju pohranu velike količine podataka jer zapremina 'računalnog oblaka' može biti usklađena s potrebama pojedinca ili organizacije. Analiza velike količine podataka odnosi se na činjenicu kako čovjek bez uporabe računala i računalnog alata nije u stanju analizirati velike količine podataka, pa se u tu svrhu koristi 'analitika velike količine podataka' (engl. *big data analytics*) za potrebe učinkovite analize podataka.[38]

[37] Usp. El Jamiy, Fatima et al. The potential and challengles of Big data - Recommendation systems next level application. Nav. dj. Str. 3.
[38] Usp. Isto. Str. 3.

3.2.6. Analitika velike količine podataka

S obzirom na karakteristike velike količine podataka, na probleme količine, brzine, raznolikosti, vjerodostojnosti i vrijednosti podataka, logično je za pretpostaviti kako je upravo analiza velike količine podataka veliki izazov u ovom području. Analitika velike količine podataka odnosi se na upravljanje velikom količinom podataka, jer upravo 'analitika velike količine podataka' omogućuje da podatak postane korisna informacija. Analitika velike količine podataka odnosi se na procese koje je potrebno poduzeti u svrhu otkrivanja korisnih informacija u podatcima. Analitikom se pokušavaju utvrditi vrijedne korelacije među podatcima, 'skriveni obrasci' (engl. *hidden paterns*) te druge korisne informacije u svrhu donošenja odluka na temelju tih informacija. Dakle, analitika velike količine podataka omogućuje analizu strukturiranih, polustrukturiranih te nestrukturiranih podataka u svrhu pronalaženja vrijednosti u tim podatcima, odnosno u svrhu pronalaženja korisnih informacija.[39]

3.2.7. Velika količina podataka i knjižnična znanost

Velika količina podataka ima vrlo čvrstu povezanost s knjižnicama. Upravo radi širenja i povećanja količine podataka u svijetu te radi potencijalnog utjecaja podataka na akademsku zajednicu, knjižničari bi trebali biti upućeni u fenomen velike količine podataka i izazove koje postavlja, a pogotovo s načinom na koji velika količina podataka utječe na znanstvena istraživanja. Knjižničari bi trebali biti upoznati i s načinom na koji tvrtke danas postupaju s velikom količinom podataka te načinom na koji će se studenti suočavati s velikom količinom podataka u budućnosti. Predmetni stručnjaci u području znanosti trebali bi biti upoznati s velikom količinom podataka te u kojoj je mjeri fenomen velike količine podataka zahvatio i odrazio se na podatke znanstvenih istraživanja. Tako bi svi predmetni knjižničari za potrebe procesa pretraživanja informacija u okviru istraživanja, trebali biti svjesni na koji način se velika količina podataka može koristiti te gdje se ti podatci mogu pronaći. Svaka knjižnica trebala bi prihvatiti svoju ulogu u vrednovanju velike količine podataka, kao i ulogu u kreiranju taksonomija i metapodatkovnih shema u svrhu lakšeg snalaženja u velikoj količini podataka. Knjižnice kao mjesta koja diseminiraju informacije i čuvaju znanje, trebale bi osigurati pristup i pohranu velikoj količini podataka. Knjižnice cijene vrijednost tradicionalnih izvora informacija, no trebale bi prepoznati vrijednosti i manje strukturiranih podataka na način da uvide vrijednosti u novoj i korisnoj analitici koja uključuje

[39] Usp. Sharma, Sugam et all. A brief review on leading big data models // Data Science Journal 13, 4(2014) str. 138-151. URL: https://www.jstage.jst.go.jp/article/dsj/13/0/13_14-041/_pdf (2015-10-03)

informacijske vizualizacijske alate putem kojih akademska zajednica može pretraživati velike količine podataka.[40] Sve knjižnične ustanove trebale bi ustanoviti koje vrste podataka žele pohranjivati i što bi od velike količine podataka trebale skupljati koristeći specifične alate za njihovo prikupljanje. Knjižničari bi trebali odvojiti vrijeme za proučavanje velike količine podataka i otkriti koje su konkretne prednosti velike količine podataka za njih same.[41]

3.3. Primjeri velike količine podataka u znanstvenonastavnom radu

3.3.1. Velika količina podataka i znanstvenonastavni rad

Znanstvenonastavni rad u mrežnom okruženju pojavio se na određenom stupnju razvoja informacijsko-komunikacijske tehnologije. Znanstvenonastavno osoblje usavršava tehnike poučavanja koristeći alate i izvore koji su im na raspologanju zahvaljujući internetu. Ono što velika količina podataka omogućuje znanstvenonastavnom osoblju je značajno poboljšanje komunikacije između znanstvenonastavnog osoblja i studenata te nove metode učenja.[42]

Znanstvenonastavno osoblje trebalo bi redovito pratiti napredak studenata u svrhu otkrivanja koliko je student posvećen kolegiju. Primjenom alata koji prikupljaju veliku količinu podataka, znanstvenonastavno osoblje je u mogućnosti pratiti aktivnosti studenata (na nastavi i na ispitima), uspoređujući ih međusobno i s prethodnim generacijama. Alati koji prikupljaju veliku količinu podataka omogućuju praćenje svakoga kolegija u realnom vremenu, dok ih znanstvenonastavno osoblje može proučavati na daljinu, prema potrebi.[43]

3.3.2. Velika količina podataka i znanstvena istraživanja - primjer CERN-a

Velika količina podataka i znanstveni rad sustavno su isprepleteni. Jedan od najeklatantnijih primjera korištenja velike količine podataka u znanosti predstavlja CERN. U današnje vrijeme, CERN se u javnosti najviše spominje u svezi s LHC-om, trenutno najvećim i najsnažnijim ubrzivačem i sudaračem čestica na svijetu, koji je ujedno možda i najveći i najkompliciraniji znanstveni eksperiment ikada započet u povijesti čovječanstva.[44] Osnutak CERN-a dogodio se 1954. godine kada ga je ustanovilo 12 europskih zemalja kroz zajednički

[40] Usp. Bieraugel, Mark. Keeping Up With... Big Data. URL: http://www.ala.org/acrl/publications/keeping_up_with/big_data (2015-10-03)
[41] Usp. Bieraugel, Mark. Isto.
[42] Kellen, Vince. Applying Big Data in Higher Education: A Case Study // Data Insight & Social BI 13, 8(2013), str. 1-39. URL: https://www.sap.com/bin/sapcom/no_no/downloadasset.2014-01-jan-29-18.applying-big-data-in-higher-education-a-case-study-pdf.html (2015-10-05)
[43] Usp. Picciano, Anthony G. The Evolution of Big Data and Learning Analytics in American Higher Education. // Journal of Asynchronous Learning Networks 16, 3(2012), str. 9-20. URL: http://eric.ed.gov/?id=EJ982669 (2015-10-05)
[44] Kao što je poznato široj znanstvenoj javnosti, znanstvena istraživanja u CERN-u nastoje razotkriti najskrovitije tajne prirode uključujući i misterij nastanka svemira.

projekt. Kao organizacija, CERN je odgovoran za mnoga znanstvena otkrića i dostignuća, a kao najpoznatije može se istaknuti otkriće Higgsovog bozona 2012. godine. Istraživanja u CERN-u povezana su s fenomenom velike količine podataka koju u svom radu generira upravo LHC koji proizvede 30 petabajta (30 PB) podataka godišnje, što je ekvivalent 15 trilijuna stranica isprintanog teksta. LHC je započeo s radom 2008. godine. Od tada do danas, LHC je (iz)generirao ogromnu količinu podataka.

U prvo vrijeme, u doba prvih sudarača čestica tijekom druge polovine 20. stoljeća, pristup takvim podatcima bio je omogućen jedino dolaskom u Ženevu i njihovim osobnim preuzimanjem. Problem pristupa podatcima doveo je do rješenja u obliku kreiranja CERNnet-a, mreže međusobno povezanih računala koja se 'prostirala' od Sjedinjenih Američkih Država do Europe, što je naposljetku 1989. godine dovelo do kreiranja *World Wide Web-a*. U današnjem LHC-u, na četiri velika projekta danas radi oko 8000 istraživača, koji u realnom vremenu mogu pristupiti podatcima istraživanja praktički s bilo koje točke u svijetu koja je povezana na internet.

U slučaju CERN-a odnosno LHC-a, velika količina podataka nastaje kao rezultat bilježenja sudara 600 milijuna čestica u sekundi. S obzirom na činjenicu da se do tog vremena ni jedna organizacija u svijetu nije morala suočiti s prikupljanjem ovako velike količine podataka, CERN je konstruirao Svjetsku računalnu mrežu ubrzivača čestica (engl. *Worldwide Large Hadron Collider Computer Grid*) koristeći računalne sustave sveučilišta i istraživačkih grupa koje surađuju na projektu. Ovakvo 'distribuirano računarstvo' (engl. *distributed computing*) omogućuje ekonomičan mrežni sustav pohrane koji bi inače bio preskup za jedan statičan podatkovni centar. Osim kreiranja ekonomičnijeg sustava, ovakav decentralizirani pristup posjeduje mnogo prednosti kao što su pristup podatcima velikom brzinom iz bilo kojeg dijela svijeta te pristup sigurnosnim kopijama distribuiranim diljem svijeta. Pohranjivanje podataka istraživanja u eksperimentima koji su uključivali LHC pokazao se vrlo skupim. Od 2008. godine do danas troškovi pohranjivanja podataka istraživanja narasli su na oko 5,5 milijardi dolara godišnje.

Od osnutka CERN-a 1950-ih, generacije znanstvenika su stvorile svoje karijere na osnovi podataka koje je proizvela ova organizacija. Podatci koji su prikupljeni na brojnim istraživanjima su povećali mogućnost razumijevanja svemira, odnosno odgovorili na pitanja

kako i na koji način svemir funcionira. Ništa od navedenoga ne bi bilo moguće da se CERN nije usredotočio ka inovacijama u polju velike količine podataka.[45]

3.3.3. Velika količina podataka i nastavni rad - primjeri repozitorija objekata učenja

Slobodno se može reći da se fenomen velike količine podataka u nastavnom radu očituje kroz veliku količinu dostupnih e-materijala za izvedbu nastave. E-materijali su često povezani s objektima učenja, odnosno e-materijali su načinjeni od objekata učenja koji se pak čuvaju u repozitorijima objekata učenja. Primjeri repozitorija objekata učenja su MERLOT i Ariadne. Merlot (engl. *Multimedia Educational Resource for Learning and Online Teaching*) je recenzirana zbirka besplatnih i otvorenih servisa za učenje i poučavanje. Projekt MERLOT započeo je 1997. godine u Kaliforniji kada je Sveučilišni centar za distribuirano učenje (engl. *California State University Center for Distributed Learning*) izradio projekt te mu omogućio besplatan pristup. Do srpnja 2000. godine, projektu je pristupilo 23 institucije visokog obrazovanja. MERLOT je projekt konzorcija fakulteta koji razvijaju standarde vrednovanja, recenziraju mrežne obrazovne materijale te ih također i pohranjuju.[46] Repozitorij Ariadne je projekt istoimene neprofitne organizacije čiji su ciljevi omogućiti nastanak, dijeljenje i ponovno korištenje znanja kroz uporabu informacijsko-komunikacijske tehnologije, zatim razvijati metodologiju i softverska rješenja koja će omogućiti fleksibilan, učinkovit pristup širokom području znanja, očuvanje multikulturalnih i višejezičnih zbirki te potporu obrazovnoj i istraživačkoj zajednici. Repozitorij Ariadne posjeduje infrastrukturu za diseminaciju i upravljanje mrežnim obrazovnim izvorima odnosno e-materijalima. Vizija ove organizacije, koja podupire kontinuiran razvoj infrastrukture, tiče se osiguravanja fleksibilnog, učinkovitog pristupa velikoj količini obrazovnih materijala odnosno e-materijala za obrazovanje.[47] Oba projekta, odnosno oba repozitorija objekata učenja omogućuju pristup velikom broju e-materijala za učenje i poučavanje, što ih svrstava u sustave koji se ujedno bave upravljanjem i vrednovanjem velike količine podataka.

[45] Marr, Bernard. Big Data: Uncovering the Secrets of Our Universe at CERN, 22. svibnja 2015. URL: http://www.datasciencecentral.com/profiles/blogs/big-data-uncovering-the-secrets-of-our-universe-at-cern (2015-10-05)
[46] How We Got Started. URL: http://info.merlot.org/merlothelp/index.htm#who_we_are.htm (2015-10-13)
[47] Ariadne: Ariadne Foundation. URL: http://www.ariadne-eu.org/content/about (2015-10-13)

4. ISTRAŽIVANJE UTJECAJA VELIKE KOLIČINE PODATAKA NA ZNANSTVENONASTAVNI RAD

4.1. Svrha i ciljevi istraživanja

Ovim istraživanjem nastojao se ispitati utjecaj fenomena velike količine podataka na znanstvenonastavni rad. U svojstvu ispitanika, u istraživanju je sudjelovalo znanstvenonastavno osoblje Filozofskog fakulteta u Osijeku. Ciljevi istraživanja vezani su uz propitivanje stavova znanstvenonastavnog osoblja u svezi fenomena velike količine podataka. Posredno, željelo se ispitati i na kojim medijima znanstvenonastavno osoblje pohranjuje podatke za potrebe znanstvenog i nastavnog rada te okvirno količinu pohranjenih podataka. Isto tako, istraživanjem se nastojalo ispitati i koje multimedijalne sadržaje znanstvenonastavno osoblje rabi u svom znanstvenonastavnom radu te koju količinu podataka proizvede. Istraživanjem se željelo ispitati i mišljenje znanstvenonastavnog osoblja o količini literature koju prikupljaju za potrebe znanstvenog i nastavnog rada te saznati njihove stavove o velikoj količini znanstvenih i nastavnih materijala s kojima se susreću. Posebna pozornost posvećena je ispitivanju stavova ispitanika u svezi poznavanja termina velike količine podataka te izravnoj pogođenosti ili nepogođenosti ovim fenomenom.
Hipoteze ovoga rada bile su sljedeće:

H1. Znanstvenonastavno osoblje koristi multimedijalne sadržaje više u nastavnom nego u znanstvenom radu.

H2. Znanstvenonastavno osoblje smatra da ne proizvodi veliku količinu podataka u svom znanstvenom i nastavnom radu.

H3. Znanstvenonastavno osoblje upoznato je s terminom 'velika količina podataka' te se smatraju izravno pogođeni tim fenomenom.

4.2. Metodologija i uzorak istraživanja

U ovom istraživanju koristila se metoda anketnog upitnika. Anketni upitnik sadržavao je 12 pitanja. Prva dva pitanja bila su demografske prirode, dok su se treće i četvrto pitanje odnosili na podatke o zvanju znanstvenonastavnog osoblja te odsjeku odnosno katedri kojima pripadaju. Naime, kako je već navedeno, u istraživanju je sudjelovalo znanstvenonastavno osoblje Filozofskog fakulteta u Osijeku koji ima sveukupno devet odsjeka i dvije katedre. Pitanja od rednog broja pet do osam tražila su od ispitanika da navedu vrstu medija pohrane

podataka i vrstu multimedijalnih sadržaja koju koriste u znanstvene i nastavne svrhe te okvirnu količinu podataka koju pohranjuju odnosno proizvode u znanstvenonastavnom radu.

Devetim i desetim pitanjem ispitali su se stavovi znanstvenonastavnog osoblja vezani uz količinu znanstvene i nastavne literature, odnosno vremena potrebnog za njihovo pretraživanje. Ovim pitanjima željelo se saznati i u kojoj mjeri ispitanici osjećaju eventualnu frustraciju prilikom pretraživanja znanstvene i nastavne literature zbog njihove obimnosti. Posljednja dva pitanja odnosila su se na upoznatost znanstvenonastavnog osoblja s fenomenom velike količine podataka te njihov osobni stav o pogođenosti istim. Istraživanje je provedeno na Filozofskom fakultetu u Osijeku u listopadu 2015. godine. Na Filozofskom fakultetu u Osijeku postoji 146 osoba koje se vode kao znanstvenonastavno osoblje, a na anketni upitnik odgovorilo je 73 osobe što iznosi točno 50% od maksimalnog mogućeg broja ispitanika.

4.3. Rezultati istraživanja

Anketnom upitniku pristupilo je sveukupno 25 muških ispitanika što predstavlja 34,2% sveukupnog broja ispitanika, dok je osoba ženskog spola odnosno ispitanica sveukupno 48 što je 65,8% sveukupnih ispitanika. Tablica 2. prikazuje frekvenciju muškog i ženskog spola u istraživanju.

Tablica 2. Frekvencija spolova u istraživanju.

Frekvencija muškog i ženskog spola	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**
Muški spol	25	34,2%
Ženski spol	48	65,8%

Što se tiče dobi ispitanika, njih 70 navelo je svoju dob. Najmlađi ispitanik ima 24 godine, dok najstariji 62 godine. Tri ispitanika nisu navela svoju dob. Sveukupni prosjek godina ispitanika je približno 39 godina. Vezano za znanstvenonastavno zvanje ispitanika, kao što je vidljivo iz Tablice 3, najviše ispitanika je u zvanju docenta, sveukupno 24 ispitanika što čini 32,9% sveukupnog broja ispitanika, dok najmanje ispitanika ima zvanje znanstvenog novaka, svega jedna osoba, što je 1,4% sveukupnog broja ispitanika. Nakon docenata, najviše ispitanika su u zvanju asistenta, sveukupno 14 osoba, što je 19,2% sveukupnog broja ispitanika te poslijedoktoranada, sveukupno 13 osoba, što je 17,8% sveukupnog broja ispitanika. Anketni upitnik nije ispunio ni jedan predavač i lektor.

Tablica 3. Frekvencija zvanja ispitanika.

Zvanja ispitanika	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**
Redoviti profesor	7	9,6%
Izvanredni profesor	7	9,6%
Docent	24	32,9%
Poslijedoktorand	13	17,8%
Viši asistent	2	2,7%
Asistent	14	19,2%
Znanstveni novak	1	1,4%
Viši predavač	3	4,1%
Viši lektor	2	2,7%

Nakon što je utvrđen omjer spolova i zvanja, važno je bilo utvrditi i omjer pripadnosti znanstvenonastavnog osoblja određenim odsjecima i katedrama. Kako je vidljivo iz Tablice 4, najviše znanstvenonastavnog osoblja koje je ispunilo anketni upitnik dolazi s Odsjeka za hrvatski jezik i književnost, njih 16, što čini 22,2% sveukupnog broja ispitanika. Drugi odsjek koji je najbrojniji po broju ispitanika je Odsjek za informacijske znanosti na kojemu je sveukupno 15 osoba ispunilo anketni upitnik, što čini 20,8% sveukupnog broja ispitanika. Nakon Odsjeka za informacijske znanosti, po brojnosti ispitanika ističe se i Odsjek za psihologiju na kojemu je 10 osoba ispunilo anketni upitnik, što čini 13,9% sveukupnog broja ispitanika. Na Katedri za mađarski jezik, Odsjeku za njemački jezik i književnost te na Katedri za zajedničke sadržaje najmanje je znanstvenonastavnog osoblja koji su sudjelovali u istraživanju, po 3 osobe sa svakog odsjeka odnosno katedre, što čini 4,2% ispitanika sa svakog odsjeka odnosno katedre. Jedan ispitanik nije odgovorio na pitanje o odsjeku kojemu pripada.

Tablica 4. Frekvencija pripadnosti ispitanika pojedinim odsjecima i katedrama.

Odsjeci i katedre ispitanika	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**
Odsjek za engleski jezik i književnost	6	8,3%
Odsjek za filozofiju	4	5,6%
Odsjek za hrvatski jezik i književnost	16	22,2%
Odsjek za informacijske znanosti	15	20,8%
Katedra za mađarski jezik i književnost	3	4,2%

Odsjek za njemački jezik i književnost	3	4,2%
Odsjek za pedagogiju	5	6,9%%
Odsjek za povijest	7	9,7%%
Odsjek za psihologiju	10	13,9%
Katedra za zajedničke sadržaje	3	4,2%

Nakon analize demografskih podataka ispitanika te podataka koji se odnose na njihovo znanstvenonastavno zvanje te odsjek odnosno katedru s kojih dolaze, slijede podatci koji se tiču tematike ovoga rada.

Petim pitanjem anketnog upitnika željela se saznati vrsta medija na koju znanstvenonastavno osoblje pohranjuje podatke za potrebe svog znanstvenog i nastavnog rada. Bilo je moguće odabrati više odgovora. Svi ispitanici su odgovorili na ovo pitanje. Čak 71 ispitanik odnosno 97,3% ispitanika odgovorilo je kako svoje podatke pohranjuje na osobnom računalu. Taj odgovor odnosio se na čuvanje podataka na stolnom i prijenosnom računalu te tabletu. Na vanjskoj memorijskoj jedinici svoje podatke pohranjuje 60 ispitanika znanstvenonastavnog osoblja što čini 82,2% sveukupnog broja ispitanika. Ovaj odgovor odnosio se na USB disk te vanjski disk. Mrežnu memorijsku jedinicu, koja uključuje tzv. *oblak* usluge poput Google drive-a, Box-a, Dropbox-a i Onedrive-a, koristi 34 ispitanika, odnosno 46,6% sveukupnog njihovog broja. Dodatni mediji na kojima znanstvenonastavno osoblje pohranjuje svoje podatke su DVD (engl. *Digital Video Disc*), što je navela jedna osoba odnosno 1,4% sveukupnog broja ispitanika, e-mail, koji su navela 3 ispitanika (4,1% sveukupnog broja ispitanika), Moodle, koji je navela jedna osoba (1,4% ispitanika) te tiskane knjige i časopisi koje je navela jedna osoba (1,4% ispitanika). Tablica 5 prikazuje frekvenciju vrste medija pohrane podataka za potrebe znanstvenonastavnog rada.

Tablica 5. Frekvencija vrste medija za pohranu podataka za potrebe znanstvenonastavnog rada.

Medij pohrane za potrebe znanstvenonastavnog rada	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**
Osobno računalo (stolno, prijenosno, tablet)	71	97,3%
Vanjska memorijska jedinica (USB disk, vanjski disk i sl.)	60	82,2%
Mrežna memorijska jedinica (*oblak* usluga npr. Google Drive, Box,	34	46,6%

Dropbox, OneDrive i sl.)		
Nešto drugo	9	12,3%

Iz navedenih rezultata može se zaključiti kako gotovo svi ispitanici kao medij pohrane podataka koriste osobno računalo. U nešto manjem postotku koriste i vanjske memorijske jedinice, dok mrežne memorijske jedinice koristi manje od polovine ispitanika. Šesto pitanje anketnog upitnika odnosilo se na vrste multimedijalnih sadržaja koje koriste ispitanici. I u ovom pitanju bilo je moguće označiti više odgovora. Svi ispitanici odgovorili su na ovo pitanje. Vezano uz znanstveni rad, slike kao multimedijalni sadržaj koristi 56 ispitanika odnosno 76,7% sveukupnog broja ispitanika. Video zapise u svom znanstvenom radu koristi 25 ispitanika odnosno 34,2% sveukupnog broja ispitanika, dok zvučne zapise koristi 18 ispitanika odnosno 24,7% sveukupnog broja ispitanika. Od drugih multimedijalnih materijala za potrebe znanstvenog rada koriste se još i online upitnik te film. Online upitnik i film koristi po jedna osoba u svakoj kategoriji (1,4%). Ostali navedeni sadržaji u odgovoru "nešto drugo" nisu multimedijalnog karaktera te se stoga neće uzimati u obzir. Što se tiče nastavnog rada, multimedijalne sadržaje u obliku slika koristi 60 ispitanika, što čini 82,2% sveukupnog broja ispitanika. Dakle, većina ispitanika koristi slike u nastavnom radu i to u većem postotku nego što ih koriste u znanstvenom radu. Video zapise u nastavnom radu koristi 62 ispitanika, što čini 84,9% sveukupnog broja ispitanika iz čega se može zaključiti da upravo video zapisi čine najveći postotak korištenosti multimedijanih sadržaja u nastavi, ali i u znanstvenom radu. Zvučne zapise u nastavi koristi 34 ispitanika, što čini 46,6% sveukupnog broja ispitanika. Također, zvučni zapisi koriste se više u nastavi nego u znanstvenom radu. Od drugih multimedijalnih sadržaja u nastavi koriste se još i animacije (koristi ih jedna osoba što je postotak od 1,4% sveukupnog broja ispitanika), film (koristi ga jedna osoba što je sveukupno 1,4% ispitanika) te online interaktivni materijali poput online kviza (koristi ga jedna osoba, što čini postotak od 1,4% ispitanika). Tablica 6 prikazuje frekvencije korištenja multimedijalnih materijala u znanstvenom i nastavnom radu.

Tablica 6. Frekvencije korištenja multimedijalnih materijala u znanstvenom i nastavnom radu.

Multimedijalni sadržaji koji se koriste u znanstvenom i nastavnom radu	**Znanstveni rad**		**Nastavni rad**	
	Broj znanstvenonastavnog osoblja	**Postotak znanstvenonastavnog osoblja**	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**

Slike (infografike, fotografije i sl.)	56	76,7%	60	82,2%
Video zapisi (youtube i sl.)	25	34,2%	62	84,9%
Zvučni zapisi	18	24,7%	34	46,6%
Nešto drugo	8	11%	7	9,6%

Sveukupno gledajući, multimedijalni materijali koriste se više u nastavi nego u znanosti što potvrđuje hipotezu 1.

Količinom podataka koju znanstvenonastavno osoblje pohranjuje na nekom od medija bavi se pitanje broj 7 u kojemu su ispitanici trebali procijeniti količinu podataka koju pohranjuju u znanstvenom i nastavnom radu. Manje od 10 MB podataka u znanstvenom radu pohranjuju 4 osobe (5,6% sveukupnog broja ispitanika), dok ih je u nastavnom radu 10 (14,1% ispitanika). Između 10 i 100 MB podataka u znanstvenom radu pohranjuje 17 ispitanika (23,6%), a u nastavnom radu to čini 7 ispitanika (9,9%). To nam govori da između 10 i 100 MB podataka pohranjuje više ispitanika u znanstvenom nego u nastavnom radu. Između 100 i 1000 MB podataka u znanstvenom radu pohranjuje 8 ispitanika (11,1%), a u nastavnom radu istu količinu podataka pohranjuje 15 ispitanika (21,1%) što nam ponovno govori da u nastavnom radu ovu količinu podataka pohranjuje više ispitanika nego što to čini u znanstvenom radu. Više od 1000 MB u znanstvenom radu pohranjuje 22 ispitanika (30,6%) dok u nastavnom radu istu količinu podataka pohranjuje 21 ispitanik (29,6%) što nam govori da približno jednak broj ispitanika pohranjuje više od 1000 MB u znanstvenom i u nastavnom radu. Najviše ispitanika koji su odgovorili na ovo pitanje (22 ispitanika u znanstvenom radu i 21 ispitanik u nastavnom radu) pohranjuje više od 1000 MB i u znanstvenom i u nastavnom radu. Dakle, odgovor "više od 1000 MB" najzastupljeniji je odgovor u obje kategorije. Međutim, čak 21 ispitanik u znanstvenom radu (29,2%) i 18 ispitanika u nastavnom radu (25,4%) odgovorilo je kako ne može procijeniti količinu podataka koju pohranjuje u znanstvenom i nastavnom radu. Tablica 7 prikazuje frekvenciju pohrane podataka u znanstvenom i nastavnom radu.

Tablica 7. Frekvencija količine pohranjenih podataka za potrebe znanstvenog i nastavnog rada.

Količina	**Znanstveni rad**	**Nastavni rad**

pohranjenih podataka na nekom od medija pohrane	Broj znanstvenonastavnog osoblja	Postotak znanstvenonastavnog osoblja	Broj znanstvenonastavnog osoblja	Postotak znanstvenonastavnog osoblja
Manje od 10 MB	4	5,6%	10	14,1%
Između 10 - 100 MB	17	23,6%	7	9,9%
Između 100 - 1000 MB	8	11,1%	15	21,1%
Više od 1000 MB (više od 1 GB)	22	30,6%	21	29,6%
Ne mogu procijeniti	21	29,2%	18	25,4%

Zaključno, u obje kategorije (znanstvenoj i nastavnoj) najviše ispitanika odgovorilo je kako pohranjuje više od 1000 MB podataka.

Sljedećim pitanjem željelo se utvrditi slažu li se ispitanici s činjenicom da proizvode veliku količinu podataka u znanstvenom i nastavnom radu. Na ovo pitanje odgovorili su svi ispitanici. Broj ispitanika koji se ne slažu da u znanstvenom radu proizvode veliku količinu podataka iznosio je 11 (15,1% sveukupnog broja ispitanika) dok se 10 (13,7%) ispitanika izjasnilo da se ne slažu da u nastavnom radu proizvode veliku količinu podataka. Može se zaključiti da postoji približno jednak broj ispitanika koji se slažu i ne slaže da u znanstvenom radu proizvode veliku količinu podataka. 32 ispitanika (43,8% sveukupnog broja ispitanika) se slažu da u znanstvenom radu proizvode veliku količinu podataka dok se 35 ispitanika (47,9% sveukupnog broja ispitanika) izjasnilo da se slažu da u nastavnom radu proizvode veliku količinu podataka. Ispitanika koji se ni slažu niti ne slažu s činjenicom da u znanstvenonastavnom radu proizvode veliku količinu podatka bilo je 30 u znanstvenom radu (41,2%) i 28 u nastavnom radu (38,4%). Tablica 8 prikazuje frekvenciju slaganja ispitanika s činjenicom da proizvode veliku količinu podataka u znanstvenonastavnom radu.

Tablica 8. Frekvencija slaganja i neslaganja ispitanika s proizvodnjom velike količine podataka u znanstvenonastavnom radu.

U znanstvenom i nastavnom radu proizvodi se velika količina podataka	Znanstveni rad		Nastavni rad	
	Broj znanstvenonastavnog osoblja	Postotak znanstvenonastavnog osoblja	Broj znanstvenonastavnog osoblja	Postotak znanstvenonastavnog osoblja
Ne, ne slažem	11	15,1%	10	13,7%

se				
Da, slažem se	32	43,8%	35	47,9%
Niti se slažem niti se ne slažem	30	41,2%	28	38,4%

Može se zaključiti kako se manji broj ispitanika ne slaže s izjavom da u znanstvenonastavnom radu proizvodi veliku količinu podataka dok se veći broj ispitanika slaže s navedenom izjavom. Međutim, približno 40% ispitanika je neodlučno po pitanju toga proizvode li veliku količinu podataka. Iako je velik broj ispitanika neodlučnog stava, većina ispitanika se ipak slaže s izjavom da proizvodi veliku količinu podataka stoga se može reći da je hipoteza 2 odbačena.

Pitanjima broj 9 i 10 pokušao se utvrditi stupanj slaganja i neslaganja ispitanika s izjavama o velikoj količini podataka koje se odnose na količinu dostupne literature o predmetu znanstvenog istraživanja kao i količini dostupnih nastavnih materijala za pripremu nastave. Istim pitanjima želio se utvrditi i stav ispitanika prema vremenu potrebnom za pregledavanje navedene literature odnosno nastavnih materijala. Isto tako, ovim pitanjima nastojalo se otkriti i u kojoj mjeri ispitanici osjećaju eventualnu frustraciju prilikom pretraživanja znanstvene i nastavne literature. S izjavom da je literatura o predmetu znanstvenog područja obimna u potpunosti se ne slaže 5 ispitanika (6,8%), djelomično se ne slaže 7 ispitanika (9,6%), niti se slaže ni ne slaže 12 ispitanika (16,4%), djelomično se slaže 24 ispitanika (32,9%), a u potpunosti se slaže 25 ispitanika (34,2%). To znači da se najviše ispitanika u potpunosti slaže s izjavom da je literatura o predmetu znanstvenog područja obimna. S izjavom da su nastavni materijali iz kolegija koje ispitanici predaju studentima obimniji nego prije u potpunosti se ne slaže 6 ispitanika (8,2%), djelomično se ne slaže 6 ispitanika (8,2%), niti se slaže ni ne slaže 15 ispitanika (20,7%), djelomično se slaže 28 ispitanika (38,4%), a u potpunosti se slaže 18 ispitanika (24,7%). Dakle, najviše ispitanika samo se djelomično slaže s izjavom da je literatura za pripremu nastavnih materijala kolegija koje predaju obimnija nego prije. Tablica 9 pokazuje stupanj slaganja i neslaganja znanstvenonastavnog osoblja s navedenim izjavama.

Tablica 9. Slaganje i neslaganje ispitanika s navedenim izjavama o obimnosti znanstvene literature i nastavnih materijala.

	Literatura o predmetu znanstvenog	Nastavni materijali kolegija koje

	područja je obimna.		predajem obimniji su nego prije.	
	Broj znanstvenonastavnog osoblja	**Postotak znanstvenonastavnog osoblja**	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**
U potpunosti se ne slažem	5	6,8%	6	8,2%
Djelomično se ne slažem	7	9,6%	6	8,2%
Niti se slažem niti se ne slažem	12	16,4%	15	20,5%
Djelomično se slažem	24	32,9%	28	38,4%
U potpunosti se slažem	25	34,2%	18	24,7%

Generalno gledajući, većina ispitanika slaže se da je literatura za potrebe znanstvenog i nastavnog rada obimnija nego ikada prije.

S izjavom da je u današnje vrijeme potrebno puno više vremena za pregledavnje literature o predmetu znanstvenog istraživanja u potpunosti se ne slaže 9 ispitanika (12,3%), djelomično se ne slaže 8 ispitanika (11%), niti se slaže ni ne slaže 18 ispitanika (24,7%), djelomično se slaže 13 ispitanika (17,8%), a u potpunosti se slaže 25 ispitanika (34,2%). Dakle, ponovno najviše ispitanika u potpunosti se slaže s izjavom da im je u današnje vrijeme potrebno puno više vremena za pregledavanje literature o predmetu istraživanja nego prije. S izjavom da uvid u dostupnu literaturu za pripremu nastavnih materijala kolegija oduzima više vremena nego prije u potpunosti se ne slaže 9 ispitanika (12,3%), djelomično se ne slaže 6 ispitanika (8,2%), niti se slaže ni ne slaže 19 ispitanika (26%), djelomično se slaže 27 ispitanika (37%), a u potpunosti se slaže 12 ispitanika (16,4%). Najviše ispitanika, dakle, djelomično se slaže s izjavom da im uvid u dostupnu literaturu za pripremu nastavnih materijala oduzima više vremena nego prije. Tablica 10 prikazuje stupanj slaganja i neslaganja s navedenim izjavama.

Tablica 10. Stupanj slaganja i neslaganja s navedenim izjavama o vremenu potrebnom za pregledavanje literature u svrhu znanstvenonastavnog rada.

	Danas mi je potrebno puno više vremena za pregledavanje postojeće literature o predmetu mog znanstvenog istraživanja nego prije	Uvid u dostupnu literaturu za pripremu nastavnih materijala kolegija oduzima mi više vremena nego prije

	Broj znanstvenonastavnog osoblja	**Postotak znanstvenonastavnog osoblja**	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**
U potpunosti se ne slažem	9	12,3%	9	12,3%
Djelomično se ne slažem	8	11%	6	8,2%
Niti se slažem niti se ne slažem	18	24,7%	19	26%
Djelomično se slažem	13	17,8%	27	37%
U potpunosti se slažem	25	34,2%	12	16,4%

Zaključno, znanstvenonastavno osoblje generalno se slaže s izjavama da je potrebno puno više vremena za pregledavanje literature za potrebe znanstvenonastavnog rada nego prije.

S izjavom da se osjećaju frustriranima prilikom pregledavanja literature u znanstvenom radu u potpunosti se ne slaže 17 ispitanika (23,3%), djelomično se ne slaže 13 ispitanika (17,8%), niti se slaže ni ne slaže 10 ispitanika (13,7%), djelomično se slaže 21 ispitanik (28,8%), a u potpunosti se slaže 12 ispitanika (16,4%). Ovi rezultati pokazuju kako se ispitanici u najvećoj mjeri djelomično slažu s izjavom o osjećaju frustracije pri pregledavanja literature u svom znanstvenom radu. S izjavom o osjećaju frustracije pri pregledavanju literature za pripremu nastavnih materijala u potpunosti se ne slaže 18 ispitanika (24,7%), djelomično se ne slaže 18 ispitanika (24,7%), niti se slaže niti ne slaže 13 ispitanika (17,8%), djelomično se slaže 18 ispitanika (24,7%), a u potpunosti se slaže 6 ispitanika (8,2%). Ovi rezultati govore kako se ispitanici oko osjećaja frustriranosti pri pretraživanju literature u svom nastavnom radu u jednakoj mjeri u potpunosti ne slažu i djelomično ne slažu, dok se istovremeno u jednakoj mjeri i djelomično slažu s navedenim izjavama. Tablica 11 prikazuje stupanj slaganja i neslaganja o osjećaju frustriranosti pri pregledavanju literature u znanstvenonastavne svrhe.

Tablica 11. Stupanj slaganja i neslaganja o osjećaju frustriranosti pri pregledavanju literature u znanstvenonastavne svrhe.

	Osjećam frustraciju pri pregledavanju postojeće literature o odabranom predmetu znanstvenog istraživanja zbog	Osjećam frustraciju pri pregledavanju literature za pripremu nastavnih materijala kolegija ubog velike količine

	velike količine dostupnih podataka		dostupnih podataka	
	Broj znanstvenonastavnog osoblja	**Postotak znanstvenonastavnog osoblja**	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**
U potpunosti se ne slažem	17	23,3%	18	24,7%
Djelomično se ne slažem	13	17,8%	18	24,7%
Niti se slažem niti se ne slažem	10	13,7%	13	17,8%
Djelomično se slažem	21	28,8%	18	24,7%
U potpunosti se slažem	12	16,4%	6	8,2%

Pitanja 11 i 12 odnosila su se na upoznatost ispitanika s terminom velike količine podataka te njihovim stavom o vlastitoj pogođenosti tim fenomenom. Pitanjem broj 11 željelo se utvrditi u kojoj mjeri je znanstvenonastavno osoblje upoznato s terminom 'veliki podatci' odnosno velika količina podataka. Na pitanje broj 11 odgovorilo je 72 ispitanika. 44 ispitanika (61,1%) odgovorilo je kako je upoznato s terminom, dok je 28 ispitanika (38,9%) odgovorilo kako nije upoznato s navedenim terminom. Rezultati su pokazali kako je većina ispitanika upoznata s terminom velika količina podataka što potvrđuje prvi dio hipoteze 3. Tablica 12 prikazuje frekvenciju upoznatosti ispitanika s terminom velika količina podataka.

Tablica 12. Frekvenciju upoznatosti ispitanika s terminom 'velika količina podataka'.

Upoznatost s terminom 'veliki podatci' odnosno velika količina podataka	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**
Da, upoznat/a sam s terminom	44	61,1%
Ne, nisam upoznat/a s terminom	28	38,9%

Vezano uz pitanje broj 12 koje se tiče stava o pogođenosti fenomenom velike količine podataka, 19 ispitanika (26,8%) odgovorilo je da je pogođeno fenomenom velike količine podataka, 33 ispitanika (46,5%) da je samo djelomično pogođeno istim fenomenom, dok je 19 ispitanika (26,8%) ustvrdilo kako njime nije pogođeno. Iz rezultata je vidljivo kako je većina ispitanika odgovorila da je djelomično pogođena fenomenom, dok je jednak postotak odnosno broj ispitanika odgovorio da je pogođen i da nije pogođen fenomenom velike količine

podataka. Tablica 13 prikazuje frekvenciju stavova ispitanika o pogođenosti fenomenom velike količine podataka.

Tablica 13. Frekvencija stavova ispitanika o pogođenosti fenomenom velike količine podataka.

Smatram da sam izravno pogođen fenomenom velike količine podataka	**Broj znanstvenonastavnog osoblja**	**Postotak znanstvenonastavnog osoblja**
Da, smatram da sam izravno pogođen fenomenom	19	26,8%
Djelomično sam pogođen fenomenom	33	46,5%
Ne, smatram da nisam pogođen fenomenom	19	26,8%

5. ZAKLJUČAK

Svrha ovoga rada bila je dati općeniti prikaz fenomena velike količine podataka te ispitati njegov utjecaj na znanstvenonastavni rad. Cilj rada bio je utvrditi upoznatost znanstvenonastavnog osoblja s terminom velike količine podataka kao i njegov utjecaj na njihov znanstvenonastavni rad. Povezanost znanstvenonastavnog rada i velike količine podataka pokušala se propitati istraživanjem koje je uključivalo ispitivanje mišljenja znanstvenonastavnog osoblja o tom fenomenu.

U prvom dijelu rada opisan je prikaz znanstvenonastavnog rad u digitalnom okruženju. Znanstvenonastavni rad u digitalnom okruženju provodi se od kraja 20. stoljeća kada se pristup znanosti promijenio radi napretka informacijsko-komunikacijske tehnologije i njene uporabe i primjene u znanosti i obrazovnom procesu. Informacijska infrastruktura bitan je koncept u znanstvenonastavnom radu u digitalnom okruženju jer upravo informacijska infrastruktura omogućuje razvoj znanosti i nastavnog poučavanja u mrežnom okruženju. Znanstveni rad u digitalnom okruženju najćešće se dovodi u vezu s pojmom znanstvene informacijske infrastrukture koja se definira kao skupni pojam tehničkog, socijalnog i političkog okvira koji u obzir uzima ljude, tehnologiju, alate i usluge u svrhu napretka distribuirane i kolaborativne uporabe sadržaja kroz vrijeme te na daljinu. Također, nastavni rad u digitalnom okruženju očituje se kroz definiranje pojma e-učenje, koje se objašnjava kao učenje i poučavanje u digitalnom okruženju, koristeći informacijsko-komunikacijsku tehnologiju. Digitalno okruženje donijelo je i objekte učenja, koji se definiraju kao elementi znanja, izrađeni s namjenom da se koriste putem interneta, odnosno u digitalnom obliku. Nadovezujući se na objekte učenja, bitno je spomenuti i repozitorije objekata učenja koji pohranjuju objekte učenja te ih pomoću metapodataka opisuju kako bi ih se kasnije moglo učinkovito pretraživati. U e-učenju bitna je informacijsko-komunikacijska tehnologija, a prednosti informacijsko-komunikacijske tehnologije su nastanak platfomi za nastavni rad, a jedna od platformi koja je opisana u radu je i Moodle, koji je kreiran kako bi omogućio personalizirano okruženje za e-učenje, time podržavajući učenje na daljinu. Znanstvenonastavnom osoblju putem Moodle-a dostupno je mnoštvo podataka o studentima i njihovom napretku u studiranju. Moodle osigurava dijeljenje podataka između nastavnika i studenta. Naravno, podatci koji su podijeljeni vrlo su kompleksni te je njihova količina neupitno velika te se oni svrstavaju u fenomen velike količine podataka.

Fenomen velike količine podataka na početku se opisivao kroz povijesni kontekst te je u radu navedeno što je prethodilo fenomenu velike količine podataka. Informacijska eksplozija, informacijsko preopterećenje i informacijska poplava koncepti su koji su najavili nastanak fenomena velike količine podataka. Informacijska eksplozija odnosi se na ubrzani porast objavljenih informacija. Time dolazi do informacijskog preopterećenja, koje se definira kao stanje posjedovanja previše informacija te je u tom stanju nemoguće donijeti relevantnu odluku vezanu uz nekakav problem, a što na koncu dovodi do informacijske poplave, čiji je glavni problem efikasnost donošenja odluka radi informacijskog preopterećenja. Ova tri koncepta prethodila su nastanku fenomena velike količine podataka koji se u literaturi definira kao kompleksan pojam, ali bez točno strukturirane definicije. Veliku količinu podataka obilježava proizvodnja tzv. 'teških' podataka, poput video zapisa i fotografija, ali i prekomjerna proizvodnja tzv. 'lakih' podataka poput Word dokumenata. Fenomen velike količine podataka obilježen je količinom, brzinom, raznolikošću, vjerodostojnošću i vrijednošću podataka. Brzina nastajanja podataka jedan je od središnjih problema ovog područja, jer se nagomilani podatci ne mogu učinkovito pohraniti i proučiti u kratkom vremenu. Knjižničari i informacijski stručnjaci, kao osobe koje na dnevnoj razini obavljaju pretraživanje podataka u svrhu informiranja javnosti, trebali bi biti upućeni u probleme fenomena velike količine podataka. Glavni primjer korištenja i obrade velike količine podataka u znanosti je CERN, čiji Veliki hadronski sudarač čestica proizvodi ogromne količine podataka. Primjeri velike količine podataka u nastavi su repozitoriji objekata učenja koji pohranjuju i evaluiraju e-materijale.

1. U istraživanju, u kojemu koristila metoda anketnog upitnika, nastojao se ispitati utjecaj velike količine podataka na znanstvenonastavni rad. Istraživanje je provedeno na način ispitivanja stavova znanstvenonastavnog osoblja o fenomenu velike količine podataka. Primjerice, pokušalo se otkriti mišljenje znanstvenonastavnog osoblja o teškoćama pri pregledavanju i traženju literature u znanstvenom i nastavnom radu, obimnosti znanstvene literature i nastavnih materijala te njihovoj eventualnoj frustriranosti pri pregledavanju i prikupljanju znanstvene i nastavne literature upravo poradi fenomena velike količine podataka. Ovim istraživanjem željelo se utvrditi i je li znanstvenonastavno osoblje upoznato s terminom velike količine podataka te smatra li da je pogođeno ovim fenomenom. U ovom radu postavljeno je nekoliko istraživačkih hipoteza kojima se željela provjeriti povezanost velike

količine podataka sa znanstvenonastavnim radom te na koji način velika količina podataka na njega utječe.

Hipoteza 1 (znanstvenonastavno osoblje koristi multimedijalne sadržaje više u nastavnom nego u znanstvenom radu) je prihvaćena. Znanstvenonastavno osoblje multimedijalne sadržaje u većoj mjeri koristi u nastavnom nego u znanstvenom radu. U gotovo svim navedenim kategorijama multimedijalnih sadržaja, veći postotak znanstvenonastvnog osoblja naveo je kako multimedijalne sadržaje koristi u nastavnom radu.

Hipoteza 2 (znanstvenonastavno osoblje smatra da ne proizvodi veliku količinu podataka u svom znanstvenom i nastavnom radu) je odbačena. Većina znanstvenonastavnog osoblja slaže se s tvrdnjom da proizvodi veliku količinu podataka u svom znanstvenonastavnom radu. Ipak, potrebno je naglasiti kako je velik broj ispitanika koji su neodlučni u tvrdnji vezanoj za proizvodnju velike količine podataka.

Hipoteza 3 (znanstvenonastavno osoblje upoznato je s terminom 'velika količina podataka' te se smatraju izravno pogođeni tim fenomenom) djelomično je potvrđena. Većina znanstvenonastavnog osoblja upoznata je s terminom velike količine podataka, njih više od 60%, no u većini smatraju kako su samo djelomično pogođeni fenomenom, stoga je prvi dio hipoteze potvrđen, dok drugi dio nije.

Znanstvenonastavno osoblje zahvaćeno je fenomenom velike količine podataka, što se očituje kroz količinu podataka koju pohranjuju na svojim računalima, multimedijalnim sadržajima koje koriste, te količini znanstvene literature i nastavnih materijala koje su obvezni pretražiti za efikasno obavljanje svojega posla.

Ovaj rad može poslužiti kao temelj budućim istraživanjima u području znanstvenonastavnog rada i velike količine podataka. U budućnosti bilo bi zanimljivo utvrditi koje oblike multimedijalnih sadržaja znanstvenonastavno osoblje pohranjuje u najvećoj mjeri. Također, bilo bi poželjno preciznije odrediti točnu količinu pohranjenih multimedijalnih i drugih sadržaja.

LITERATURA

1. About Moodle. URL: https://docs.moodle.org/29/en/About_Moodle#Backed_by_a_strong_community
2. Ariadne: Ariadne Foundation. URL: http://www.ariadne-eu.org/content/about
3. Bieraugel, Mark. Keeping Up With... Big Data. URL: http://www.ala.org/acrl/publications/keeping_up_with/big_data
4. Breuker, Joost et. al. Law, Ontologies and the semantic Web: Channelling the Legal Information Flood Amsterdam: IOS Press, 2009. Str. 3-4.
5. Borgman, C. L. What can studies of e-learning teach us about collaboration in e-research? Some findings from digital library studies. // Computer Supported Cooperative Work 15(2006), str. 359.
6. Borgman, C. L. Scholarship in the digital age: information, infrastructure, and the internet. Cambridge; Massachusetts: MIT Press, 2007. Str. 19.
7. Bosančić, Boris. Označavanje teksta starih knjiga na hrvatskom jeziku pomoću TEI standarda / doktorska disertacija. Zadar: Odjel za informacijske znanosti, 2011.
8. Čelebić, Gorana; Rendulić, Dario Ilija. ITdesk.info - projekt računalne e-edukacije sa slobodnim pristupom - priručnik za digitalnu pismenost: osnovni pojmovi informacijske i komunikacijske tehnologije. Zagreb: Otvoreno društvo za razmjenu ideja, 2011. str. 9-10.
9. Duderstadt, James J.; Atkins, Daniel E.; Houweling, Douglas Van. Higher education in the digital age: technology issues and strategies for American colleges and universities. Westport: Praeger publishers, 2002. Str. 1-2.
10. El Jamiy, Fatima et al. The potential and challengles of Big data - Recommendation systems next level application. // CoRR 23, (1)2015, str. 1-2. URL: http://arxiv.org/ftp/arxiv/papers/1501/1501.03424.pdf
11. Exabyte. URL: http://techterms.com/definition/exabyte
12. Filozofija. URL: https://docs.moodle.org/all/hr/Filozofija
13. Floridi, Luciano. Big Data and Their Epistemological Challange. // Philosophy & Technology 25, 4(2012), str. 435-437. URL: http://link.springer.com/article/10.1007%2Fs13347-012-0093-4
14. Floridi, Luciano. Information: A very short introduction. New York: Oxford University Press, 2010. Str. 6-8. URL: http://lustiag.pp.fi/data/pdf/Fld.pdf

15. Grover, Nidhi. "Big Data" - Architecture, Issues, Opportunities and Challanges. // International Journal of Computer and Electronics Research 3, 1(2014), str. 26-27. URL: http://ijcer.org/index.php/ojs/article/view/497/229
16. How We Got Started. URL: http://info.merlot.org/merlothelp/index.htm#who_we_are.htm
17. Information explosion. URL: http://www.newworldencyclopedia.org/entry/Information_explosion
18. Kadiri, Jasiliu A.; Aderoto, Niran A. Infofmation explosion and the chalanges of information and communication technology utilization in Nigerian libraries and information centres. // Ozean Journal of Social Sciences 5, 1(2012), str. 21-30.
19. Kellen, Vince. Applying Big Data in Higher Education: A Case Study // Data Insight & Social BI 13, 8(2013), str. 1-39. URL: https://www.sap.com/bin/sapcom/no_no/downloadasset.2014-01-jan-29-18.applying-big-data-in-higher-education-a-case-study-pdf.html
20. Marr, Bernard. Big Data: Uncovering the Secrets of Our Universe at CERN, 22. svibnja 2015. URL: http://www.datasciencecentral.com/profiles/blogs/big-data-uncovering-the-secrets-of-our-universe-at-cern
21. Molnar, Gyorgy. Teaching and Learning in modern digital Environment. // IEEE 13th International Symposium on Applied Machine Intelligence and Informatics, Slovakia, 2015. URL: https://www.researchgate.net/publicliterature.PublicLiterature.search.html?type=keyword&search-keyword=teaching+and+learning++in+modern+digital+environment
22. O Moodle rješenju. URL: https://docs.moodle.org/all/hr/O_Moodle_rje%C5%A1enju
23. Objekti učenja "Learning Objects". URL: http://www.carnet.hr/referalni/obrazovni/iom/LO.html
24. Picciano, Anthony G. The Evolution of Big Data and Learning Analytics in American Higher Education. // Journal of Asynchronous Learning Networks 16, 3(2012), str. 9-20. URL: http://eric.ed.gov/?id=EJ982669
25. Repozitoriji objekata učenja. URL: http://www.carnet.hr/referalni/obrazovni/iom/LO4.html
26. 26. Sharma, Sugam et all. A brief review on leading big data models // Data Science Journal 13, 4(2014) str. 138-151. URL: https://www.jstage.jst.go.jp/article/dsj/13/0/13_14-041/_pdf

PRILOZI

Prilog 1. Anketni upitnik korišten za istraživanje.

Poštovani, upitnik koji se nalazi pred Vama osmišljen je u svrhu istraživanja vezanog za utjecaj velike količine podataka na znanstvenonastavni rad, a rezultati upitnika koristit će se za pisanje diplomskog rada. Upitnik je anoniman te Vam njegovo ispunjavanje ne bi trebalo uzeti više od 5-7 minuta Vašeg vremena. Molimo Vas da pažljivo pročitate pitanja te odaberete odgovore koji se odnose na Vas. Hvala unaprijed!

1. Spol

☐ M

☐ Ž

2. Dob _____

3. Molimo navedite Vaše zvanje.

☐ redoviti profesor

☐ izvanredni profesor

☐ docent

☐ poslijedoktorand

☐ viši asistent

☐ asistent

☐ znanstveni novak

☐ viši predavač

☐ predavač

☐ viši lektor

☐ lektor

4. S kojeg ste odsjeka?

☐ Odsjek za engleski jezik i književnost

☐ Odsjek za filozofiju

☐ Odsjek za hrvatski jezik i književnost

☐ Odsjek za informacijske znanosti

☐ Katedra za mađarski jezik i književnost

☐ Odsjek za njemački jezik i književnost

☐ Odsjek za pedagogiju

☐ Odsjek za povijest

☐ Odsjek za psihologiju

☐ Katedra za zajedničke sadržaje

☐ Odsjek za cjeloživotno obrazovanje

5. Na kojem mediju pohranjujete podatke za potrebe vašeg znanstvenog i nastavnog rada? (Moguće izabrati više odgovora)

☐ Osobno računalo (stolno, prijenosno, tablet)

☐ Vanjska memorijska jedinica (USB disk, vanjski disk i sl.)

☐ Mrežna memorijska jedinica (*Cloud* usluga npr. Google Drive, Box, Dropbox, OneDrive i sl.)

☐ Nešto drugo? _____

6. Koje od multimedijalnih sadržaja koristite u znanstvenom i nastavnom radu? (Moguće izabrati više odgovora)

U <u>znanstvenom</u> radu koristim…	**U <u>nastavnom radu</u> koristim…**
☐ Slike (infografike, fotografije i sl.)	☐ Slike (infografike, fotografije i sl.)
☐ Video zapisi (youtube i sl.)	☐ Video zapisi (youtube i sl.)
☐ Zvučni zapisi	☐ Zvučni zapisi
☐ Nešto drugo _____	☐ Nešto drugo _____

7. Možete li okvirno procijeniti količinu podataka koju pohranjujete na nekome od medija za potrebe vašeg znanstvenog i nastavnog rada (odnosi se na zauzeće odabranog medija za pohranu podataka znanstvenonastavnog rada u MB (megabajtima))?

U <u>znanstvenom</u> radu pohranjujem …	**U <u>nastavnom</u> radu pohranjujem…**
☐ manje od 10 MB	☐ manje od 10 MB
☐ između 10 – 100 MB	☐ između 10 – 100 MB
☐ između 100 - 1000 MB	☐ između 100 - 1000 MB
☐ više od 1000 MB (više od 1 GB)	☐ više od 1000 MB (više od 1 GB)
☐ ne mogu procijeniti	☐ ne mogu procijeniti

8. Držite li da u svom znanstvenom i nastavnom radu proizvodite veliku količinu podataka?

Proizvodim veliku količinu podataka u <u>znanstvenom</u> radu (podatci znanstvenih istraživanja)	**Proizvodim veliku količinu podataka u <u>nastavnom</u> radu (priprema nastavnih materijala)**
☐ Ne, ne slažem se ☐ Da, slažem se ☐ Niti se slažem niti se ne slažem	☐ Ne, ne slažem se ☐ Da, slažem se ☐ Niti se slažem niti se ne slažem

9. Molimo odredite na skali od 1 (U potpunosti se ne slažem) do 5 (U potpunosti se slažem) koliko se postojeće tvrdnje odnose na Vas.

		U potpunosti se ne slažem 1	Djelomično se ne slažem 2	Niti se slažem niti se ne slažem 3	Djelomično se slažem 4	U potpunosti se slažem 5
a)	Postojeću literaturu o predmetu mog znanstvenog istraživanja smatram obimnom.	☐	☐	☐	☐	☐
b)	Danas mi je potrebno puno više vremena za pregledavanje postojeće literature o predmetu mog znanstvenog istraživanja nego prije.	☐	☐	☐	☐	☐
c)	Danas je nemoguće u cijelosti pregledati postojeću literaturu o odabranom predmetu znanstvenog istraživanja.	☐	☐	☐	☐	☐
d)	Osjećam frustraciju pri pregledavanju postojeće literature o odabranom predmetu znanstvenog istraživanja zbog velike količine dostupnih podataka.	☐	☐	☐	☐	☐

10. Molimo odredite na skali od 1 (U potpunosti se ne slažem) do 5 (U potpunosti se slažem) koliko se postojeće tvrdnje odnose na Vas.

		U potpunosti se ne slažem 1	Djelomično se ne slažem 2	Niti se slažem niti se ne slažem 3	Djelomično se slažem 4	U potpunosti se slažem 5
a)	Jedinice obvezne i izborne literature iz kolegija koje predajem brojnije su nego prije.	☐	☐	☐	☐	☐
b)	Nastavni materijali kolegija koje predajem obimniji su nego prije. (prezentacije, multimedijalni sadržaji, objekti učenja i sl.).	☐	☐	☐	☐	☐
c)	Uvid u dostupnu literaturu za pripremu nastavnih materijala kolegija oduzima mi više vremena nego prije.	☐	☐	☐	☐	☐
d)	Osjećam frustraciju pri pregledavanju literature za pripremu nastavnih materijala kolegija zbog velike količine dostupnih podataka.	☐	☐	☐	☐	☐

11. Jeste li upoznati s terminom "veliki podatci" (engl. *Big Data*) ili "velika količina podataka"?

☐ Da, upoznat/a sam s terminom ☐ Ne, nisam upoznat/a s terminom

12. Smatrate li se izravno pogođeni fenomenom 'velike količine podataka'?

☐ Da

☐ Djelomično

☐ Ne