

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Antonio Protić

Zagreb, 2013 godina.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentori:

Prof. dr. sc. Biserka Runje, dipl. ing.

Student:

Antonio Protić

Zagreb, 2013 godina.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se prof. dr. sc. Biserki Runje i prof .dr. sc. Josipu Stepaniću na ukazanom strpljenju i razumijevanju i što su mi uvelike pomogla pri izradi ovog diplomskog rada.

Antonio Protić



**SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE**

Središnje povjerenstvo za završne i diplomske ispite

Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

DIPLOMSKI ZADATAK

Student:

ANTONIO PROTIĆ

Mat. br.: 0035152886

Naslov rada na hrvatskom jeziku:

ANALIZA METRIČKIH POKAZATELJA U POSTUPKU VREDNOVANJA ZNANSTVENIH ČASOPISA

Naslov rada na engleskom jeziku:

ANALYSIS OF METRIC INDICATORS IN THE PROCESS OF SCIENTIFIC JOURNALS EVALUATION

Opis zadatka:

- Potrebno je navesti i opisati uobičajene metričke pokazatelje razine kvalitete znanstvenih časopisa.
- Za odabrane časopise tehničkog područja, grafički prikazati raspodjele broja citata u jednom godištu. S obzirom na raspodjele broja citata radova u odabranim časopisima komentirati faktore odjeka časopisa.
- Za odabранo tehničko područje dati raspodjelu, mjere centralne tendencije i mjere rasipanja faktora odjeka. Kritički se osvrnuti na metričke pokazatelje razine kvalitete znanstvenih časopisa.

Zadatak zadan:

14. ožujka 2013.

Rok predaje rada:

16. svibnja 2013.

Predviđeni datum obrane:

22. - 24. svibnja 2013.

Zadatak zadao:

Prof. dr. sc. Biserka Runje

Predsjednik Povjerenstva:

Prof. dr. sc. Franjo Cajner

SADRŽAJ

SADRŽAJ	II
POPIS SLIKA	IV
POPIS TABLICA.....	VI
POPIS GRAFOVA.....	VII
POPIS KRATICA	VIII
SAŽETAK.....	IX
SUMMARY	X
1. UVOD	1
2. ZNANSTVENI ČASOPISI I NJIHOVI METRIČKI POKAZATELJI KVALITETE	3
2.1. Metrički pokazatelji.....	5
2.1.1 Faktor odjeka.....	5
2.1.2. Indeks brzine citiranja	6
2.1.3. Poluvrijeme citiranja	7
2.2. Multidisciplinarne citatne baze	13
2.2.1. WoS – Web of Science.....	13
2.2.2. Scopus	14
2.2.3. Google Scolar.....	15
3. UZORAK I METODOLOŠKI PRISTUP	16
3.1. Postupak prikupljanja podataka	16
4. ANALIZA CITATA I NJIHOVA USPOREDBA SA FAKTOROM ODJEKA	26
4.1. Grafički prikaz podataka i njihova analiza.....	29
4.1.1. Časopis Advaced Materials.....	29
4.1.2. Časopis Progress in Materials Science.....	32
4.1.3. Časopis Tehnički Vjesnik.....	34
4.2 Usporedba citata triju časopisa.....	35
4.3. Samocitiranost	37
4.4. Utvrđivanje moguće distribucije citata.....	40
4.5 Rezultati članka Distribution of Citations in one volume of a journal.....	43
4.5.1. Generalne karakteristike.....	44
4.5.2. Rezultati	46
4.6. Metoda.....	48
4.6.1. Distribucija citata	48
4.6.2. Prvi model: nasumično citiranje.....	49
4.6.3. Drugi model: Očekivani utjecaj radova smanjuje se eksponencijalno.....	50
4.6.4. Treći model: dvostruka eksponencijalna - Poissonova distribucija	52
4.6.5. Ovisnost citiranosti o svojstvima članka	55
5. FAKTOR ODJEKA ZNANSTVENIH PODRUČJA MATERIJALA I MULTIIDISCIPLINARNIH ZNANOSTI	64
5.1. Prednosti i nedostaci faktora odjeka.....	66
5.1.1. Efekti istraživanja znanstvenog polja.....	68

5.1.2 Preporuke	69
5.1.3 Vrednovanje znanstvene vrijednosti u svim specijaliziranim časopisima	71
5.1.4 Netočno tumačenje indikatora kvalitete.....	71
5.1.5 Utjecaj JIF-a na autorovo ponašanje	72
6. ZAKLJUČAK.....	74
LITERATURA.....	76
PRILOZI.....	77

POPIS SLIKA

Slika 1.Bradfordova distribucija	4
Slika 2.Generalizirana krivulja citiranosti.....	8
Slika 3. Prosječan faktor odjeka po znanstvenim disciplinama	9
Slika 4. Razlike između tipova časopisa u istom znanstvenom području	10
Slika 5a. Prosječna promjena u IF s obzirom na veličinu časopisa.....	12
Slika 5b. Fluktuacija IF-a u odnosu na veličinu časopisa	12
Slika 6. Faktor odjeka s obzirom na vremenski period računanja	13
Slika 7. Jedno od e-izdanja časopisa Advanced Materials	17
Slika 8. Sučelje tražilice WoS-ove baze podataka	18
Slika 9. Svi podaci određenog članka u WoS-ovoј bazi	20
Slika 10. Jedna od stranica prikupljenih podataka časopisa Advanced Materials	21
Slika 11. Podaci citata časopisa Progress in Material Science.....	25
Slika 12. Podaci citata časopisa Tehnički Vjesnik	25
Slika 13. Citiranost časopisa Advanced Materials (po godinama).....	38
Slika 14. Citiranost časopisa Progress in Materials Science (po godinama)	38
Slika 15. Citiranost časopisa Tehnički Vjesnik (po godinama)	39
Slika 16. Graf modela FVDC (1) za $a = 3$ i $b = 15$ (puna crta) $a= 3$ i $b = 1$ (isprekidana linija) $a = 1.2$ i $b = 1$ (točkasta linija).....	45
Slika 17. Graf modela FVDC-ijeve a) prosječne vrijednosti b) standardne devijacije kao funkcije od a . Solidne linije su za $b = 15$ i isprekidane za $b = 1$	46
Slika 18. Grafovi prikazuju ovisnost DC i FVDC o citatima za časopise a) A, b)B, c)C. Smeđi stupci referiraju se na graf prebrojanih citata, dok puna crna linija predstavlja prilagođene vrijednosti bazirane na (2). Vrijednosti na apscisi linearno su povezane sa odgovarajućim prosječnim vrijednostima citata.....	47
Slika 19. Distribucija citata za područja:Matematike, Kemije, Fizike, Biologije i Biokemije	49
Slika 20. Eksponencijalna - Poisson distribucija prilagođena empirijskim podacima za područja Biologije i Biokemije, Kemije, Matematike i Fizike.....	51
Slika 21. Eksponencijalna distribucija očekivane citiranosti članaka za područja Biologije i Biokemije, Kemije, Matematike, Fizike.....	52
Slika 22. Eksponencijalna distribucija očekivane citiranosti članaka za područje Fizike: usporedba eksponencijalne sa dvostrukom eksponencijalnom distribucijom	53
Slika 23. Dvostruka eksponencijalna- Poissonova distribucija prilagodena empirijskim podacima za područja Biologije i Biokemije, Matematike, Fizike i Kemije.....	54
Slika 24. Prosječna citiranost članaka objavljenih u 2004 g. u odnosu na br. koautora u području Biologije i Biokemije, Kemije, Matematike i Fizike	56

Slika 25. Prosječna citiranost članaka objavljenih u 2004 g. u odnosu na br. adresa u području Biologije i Biokemije, Kemije, Matematike i Fizike.....	57
Slika 26. Prosječna citiranost članka u odnosu na broj stranica članka za Biologiju i Biokemiju, Kemiju, Fiziku i Matematiku.....	57
Slika 27. Prosječna citiranost članka u odnosu na broj referenci za područja Biologije i Biokemije, Kemije, Fizike, Matematike.....	60
Slika 28. Prosječna citiranost članka u odnosu na faktor odjeka za područja Biologije i Biokemije, Kemije, Matematike i Fizike.....	60
Slika 29.Povećanje citiranosti u postocima u odnosu na inicijalnu vrijednost kada se promatrana varijabla poveća dvostruko u odnosu na njezinu početnu vrijednost	63

POPIS TABLICA

Tablica 1. Frekvencije citata članaka časopisa Advaced Materials za mjesec Prosinac i Studeni	21
Tablica 2. Frekvencije citata članaka časopisa Advaced Materials za mjesec Listopad i Rujan	22
Tablica 3. Frekvencije citata članaka časopisa Advaced Materials za mjesec Kolovoz i Srpanj	22
Tablica 4. Frekvencije citata članaka časopisa Advaced Materials za mjesec Lipanj i Svibanj	23
Tablica 5. Frekvencije citata članaka časopisa Advaced Materials za mjesec Travanj i Ožujak	23
Tablica 6. Frekvencije citata članaka časopisa Advaced Materials za mjesec Veljaču i Siječanj	24
Tablica 7. Standardni statistički podaci prikupljenog uzorka za časopis <i>Advanced Materials</i>	31
Tablica 8. Ukupna citiranost razreda citata	31
Tablica 9. Standardni statistički podaci prikupljenog uzorka za časopis <i>Progress in Materials Science</i>	33
Tablica 10. Osnovni statistički parametri časopisa <i>Progress in Materials science</i> (2007-2011)	34
Tablica 11. Usporedba podataka triju promatranih časopisa	35
Tablica 12. Utjecaj samo citiranosti na faktor odjeka promatranih triju časopisa (2010 g.) ...	39
Tablica 13. Procjena prilagodbe podataka Poisson-ovoj distribuciji	41
Tablica 14. Vrijednosti koeficijenata prikupljeni za model FVDC (8).....	46
Tablica 15. Podaci za provedeni neparametarski Kolmogorov-Smirnov test za nivo značajnosti od 0.05.	47
Tablica 16. Statistički parametri distribucija citata za područja: Matematike, Kemije, Fizike, Biologije i Biokemije.....	49
Tablica 17. Pozicija po prosječnoj citiranosti za promatrana područja.....	52
Tablica 18. Koimogorov –Smirnov test.....	54
Tablica 19. Distribucija članaka u odnosu na neka od svojstava članka i njihov utjecaj na povećanje citiranosti	62
Tablica 20. Metrički pokazatelji časopisa za znanstveno područje materijala i multidisciplinarnih znanosti.....	64
Tablica 21. Statistički podaci faktora odjeka za znanstveno područje materijala i multidisciplinarnih znanosti.....	65
Tablica 22. Problemi vezani za citatne analize i korištenje JIF-a	68
Tablica 23. Prijedlozi alternativa JIF-u	70

POPIS GRAFOVA

Graf 1. Distribucija citata časopisa Advaced Materials	29
Graf 2. Prikaz distribucije citata u razredima po deset	30
Graf 3. Distribucija citata časopisa Progress in Materials Sciences	32
Graf 4. Prikaz petogodišnje citiranosti članaka časopisa Progress in Materials Science.....	33
Graf 5. Distribucija citata časopisa Tehnički Vjesnik.....	34
Graf 6. Promatrane i dobivene vrijednosti za procjenu prilagodbe Poissnovoj distribuciji....	41
Graf 7. Vjerojatnost distribuiranja podataka prema normalnoj razdiobi	42
Graf 8. Vjerojatnost distribuiranja podataka prema logističkoj razdiobi	42
Graf 9. Vjerojatnost distribuiranja podataka prema dvo parametarskoj eksponencijalnoj distribuciji	43
Graf 10. Raspodjela faktora odjeka znanstvenog područja materijala i multidisciplinarnih znanosti	65

POPIS KRATICA

Oznaka	Opis
ISI	Institut za znanstvene informacije
SCI	Science Citation Index
JCR	Journal Citation Report
JACS	Journal Of American Chemical Society
RPR	Inedx Of Reasearch Potential Realized
IF	Impact Factor
WOS	Web Of Science
GS	Google Scolar
IP	Internet Protocol
NSK	Nacionalna sveučilišna knjižnica
SCIE	Science Citation Index Expanded
SSCI	Social Scientes Citation Index
ESI	Essential Science Indicators
K-S	Kolmogorov-Smirnov
JIF	Journal Impact Factor

SAŽETAK

Glavni cilj ovog rada je bio prikupiti i obraditi citate triju časopisa tehničkog područja. Podaci su prikupljani pomoću WoS-ove baze, te nakon toga statistički obrađivani. Pomoću dobivenih podataka citiranosti časopisa potrebno je bilo utvrditi kako se citati ponašaju unutar svakog časopisa i na temelju dobivenih podataka komentirati razlike između časopisa. Razlike su utvrđivane pomoću uobičajenih metričkih pokazatelja razine kvalitete znanstvenog časopisa. Nakon što su utvrđene moguće razlike, uzet je reprezentativni časopis za koji se smatralo da najbolje opisuje citiranost jednog prosječnog časopisa te su citati tog časopisa testirani dali se ponašaju prema ijednoj poznatoj distribuciji. Kada je utvrđeno kako se distribuiraju podaci, za tehničko područje materijala i multidisciplinarnih znanosti prikupljeni su faktori odjeka svih časopisa u ovim znanstvenim granama (u koje spadaju promatrana tri časopisa) i na temelju dobivene distribucije faktora odjeka utvrđeno je prema kojoj poznatoj distribuciji se faktori odjeka promatranog područja distribuiraju. U konačnici su komentirani prednosti i nedostaci faktora odjeka koji se danas smatra glavnim pokazateljem kvalitete znanstvenog časopisa.

Ključne riječi:

Statistika, citati, distribucija citata, faktor odjeka

SUMMARY

The main objective of this study was to collect and process cites of three journals in technical field. Data were collected using WoS's database, then statistically analyzed. Using data capture of the journal citations, it was necessary to determine how citations behave within each journal and on the basis of the data obtained to comment on the differences between journals. Differences were determined using conventional metric indicators of the level of quality of a scientific journal. After that, possible differences were identified, representative journal was chosen, which was thought that best describes an average journals, and the distribution of citations of that journal were tested whether they behave according to any one known distribution. When it was determined how collected data behave for technical fields of materials science and multidisciplinary impact factor data for all journals in this field were collected and on the basis of the obtained distribution of impact factors it was determined which known distribution describes this collected data. At the end it was discussed what are the good and bad sides of impact factor.

Key words:

Statistics, citations, distribution of citations, impact factor

1. UVOD

Razvojem računalstva došlo je do sve većeg razvoja znanosti, samim tim razvojem teško je ne priupitati se koji su radovi kroz povijest najznačajniji, dali su radovi prijašnjih znanstvenika više utjecali na ljudsku zajednicu ili radovi suvremene znanosti. Zašto danas znanstvenici rade u timovima, kad sama sociologija kaže da u grupi efikasnost pojedinca opada i kako to da za velika otkrića najčešće se spominje pojedinac, a ne grupa ljudi? Da bismo odgovorili na neka od ovih pitanja potreban nam je „opipljiva informacija“. Jedan od načina kao da dođemo do opipljivih podataka je kroz statistiku tj. analizom podataka koje smo prikupili kroz određeni vremenski period. U samom radu prikazat ćemo analize takvih podataka te koji sve parametri mogu utjecati na ove prikupljene podatke. Nadalje ćemo prikazati kako se ti podaci rasipaju i kakve zaključke možemo izvući iz ovakvih podataka.

Znanost je kompleksna ljudska djelatnost koja se temelji na stvaralačkoj snazi, inventivnosti i znanju znanstvenika. Svrha joj je kontinuirano stvaranje novih znanja kako bi došli do novih velikih spoznaja. Kao pokretač razvoja društva, znanost je po definiciji djelatnost trajnih promjena. Brzina i dinamika razvoja znanosti i pojedinih znanstvenih disciplina ovisne su o razvoju metodologije, primjeni novih istraživačkih metoda i instrumenata, otvorenosti i kreativnosti znanstvene zajednice. Kako se znanje stvara ovisi o društvenom ekonomskom, političkom, kulturnom, institucionalnom i kompleksnom istraživačkom kontekstu. Price (1963) je tvrdio da znanost kao cjeloviti sustav pokazuje eksponencijalni rast i prepostavljao je da će se taj trend nastaviti. Međutim znanost se kao organizirana djelatnost razvija ovisno o resursu društva. Danas se tvrdi da je taj rast linearan i najčešće ovisi o ulaganjima u istraživanje i razvoj. Iako u većini svijeta ova teza stoji u nekim zemljama društveni status je veliki motivacijski pokretač. Recimo u Japanu, ako je znanstvenik pridonio zajednici svojim radom osim novčane naknade za svoj rad dobit će i statusno priznanje, što je i zbog same kulture znanstveniku možda veća motivacija od financijske naknade.

S druge strane, interes stručnjaka koji se bave znanstvenom politikom uglavnom je usmjeren na financijski aspekt znanstvenog rada, odnosno na aspekt planiranja ulaganja i razvoj znanosti kao konkurentne djelatnosti. Budući da znanost nije isključivo ovisna o kreativnosti znanstvenika, za njeno funkcioniranje potrebna je kvalitetna znanstvena politika koja uvažava znanstvene rezultate istraživanja koji znanost proučavaju više aspektno kao kompleksan sustav (Wenzel, 2001)[1].

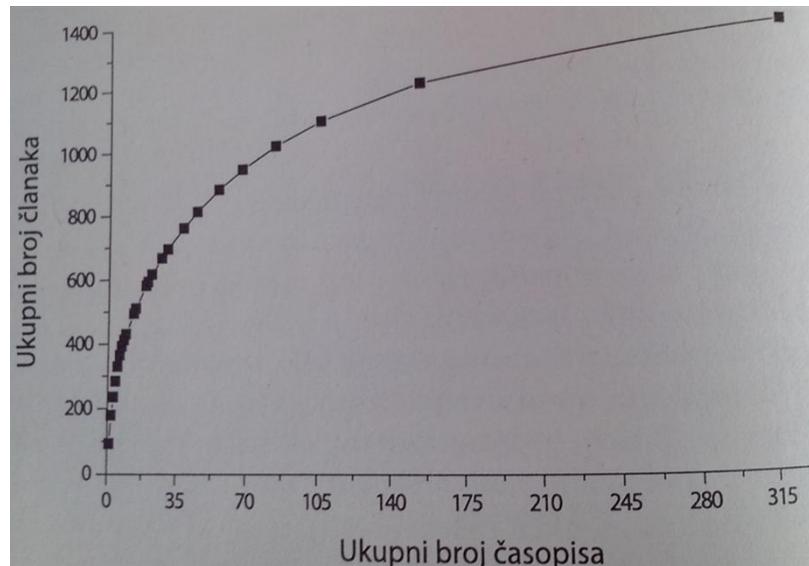
Kako su računala postala sve pristupačnija znanstvenicima došlo je i do sve većeg objavljivanja radova. Danas ima toliko znanstvenih radova da je nekad teško prepoznat koji je od njih kvalitetan, a koji je manje kvalitetan. Osim problema oko izbora kvalitetnog rada tu je problem i svjetske ekonomske krize koji zbog manjka novca na tržištu dozvoljava u konačnici financiranje samo vrlo dobrih i odličnih znanstvenih radova. Sustav vrednovanja znanstvenog rada najčešće se temelji na objavljenim radovima i publikacijama: članci u časopisima, monografije i autorske knjige, radovi u zbornicima, patenti, rješenja softverska i slično. Vrednovanju objavljenih znanstvenih radova pristupa se na dva načina: procjenom kompetentnih kolega, odnosno recenzentskim postupkom i scientometrijskim metodama. Recenzentski postupak najčešće se koristi pri vrednovanju, odnosno procijeni rukopisa za objavljivanje ili pak vrednovanju ukupnog znanstvenog rada pojedinca ili ustanove. Ovaj postupak trebao bi biti određena vrsta kvalitativnog vrednovanja. U metodi *peer review* trebala bi se procjenjivati relevantnost, originalnost, kvaliteta i potencijalni socioekonomski utjecaj rezultata istraživanja. Drugi je pristup vrednovanju rezultata znanstvenog rada metrijski, točnije bibliometrijski i scientometrijski. Bibliometrija je uži termin i u osnovi je vezan za bibliometrijske podatke o pojedinim publikacijama. Scientometrija, kao šire područje, uključuje predmete bibliometrijskih istraživanja, autorstvo, suradnju među znanstvenicima, citatne analize koje daju osnovu za istraživanja komunikacija u znanosti i praćenja razvoja znanosti, društvene i ekonomske aspekte znanstvene aktivnosti. Kako se ta istraživanja temelje na brojčanim pokazateljima i rezultati su im provjerljivi, ovakva se istraživanja smatraju objektivnim pristupom vrednovanja znanstvenog rada. Budući da su ovo ti već spomenuti „opipljivi podaci“ odlučeno je da će se u radu najviše pažnje posvetiti ovakvim podacima tj. točnije analizi citata. Danas najčešće korišten parametar kod analize citata je faktor odjeka. Razlog zašto se najviše koristi taj faktor jest u tome da je vrlo jednostavan za korištenje i samim time ne iziskuje mnogo vremena za dobivanje informacija o kvaliteti časopisa ili samog članka. Iako je faktor odjeka jednostavan za korištenje, zbog te jednostavnosti velike su mogućnosti manipulacije spomenutog faktora. Detaljnije o prednostima i nedostacima faktora odjeka govorit ćemo u nastavku rada. Osim faktora odjeka navesti i opisat će se uobičajene metričke pokazatelje kvalitete znanstvenog časopisa, za odabране časopise tehničkog područja , grafički će se prikazati raspodjеле broja citata u jednom godištu. S obzirom na raspodjelu broja citata radova u odabranim časopisima komentirati će se faktore odjeka časopisa. Nakon toga za odabranu tehničko područje dat će se raspodjelu, mjere centralne tendencije i mjere rasipanja faktora odjeka . U konačnici će se osvrnuti na metričke pokazatelje razine kvalitete znanstvenog časopisa.

2. ZNANSTVENI ČASOPISI I NJIHOVI METRIČKI POKAZATELJI KVALITETE

Budući da je časopis kao osnovni medij u znanstvenoj komuniciranju jedan je od najčešće korištenih, odlučeno je da za potrebe ovog rada odaberu se tri časopisa tehničkog područja, koja bi po znanstvenom području koje obrađuju bili što bliskiji strojarskim tehničkim područjima, tako da bi sa dobivenim podacima mogli komentirati i vidjeti kakvo je stanje u promatranim područjima bilo od vremena izdavanja do danas. Vrlo važno je bilo vidjeti kako se ti podaci distribuiraju, dali se može utvrditi moguća pravilna distribucija tih podataka i koji su to parametri koji utječu na faktor odjeka. Časopise koje smo odabrali su : Tehnički Vjesnik, *Advanced Materials* i *Progress in Materials Science*. Razlozi zašto su ovi časopisi odabrani je osim gore navedenih i to što su u govornom području koje nam je odgovaralo i zato što kasnije se moglo komentirati razlike u ponašanju citata stranih časopisa i hrvatskog časopisa.

Kroz parametre koji definiraju časopis može se pratiti razvoj pojedine znanstvene discipline i područja, te široki spektar njihovih utjecaja u znanstvenom okruženju. Časopis je u funkciji službenog medija koji javno registrira znanstvene spoznaje, medij je za diseminaciju informacija i društvena institucija kroz koju je vidljiv doprinos, prestiž, priznanje: autoru, uredniku, recenzentu, instituciji, zemlji i znanstvenoj disciplini. Ako znamo da trenutno postoji preko 100.000 znanstvenih, znanstveno stručnih časopisa, od čega je između 30 % i 40 % selektirano i obrađuje se u svjetskim bibliografskim bazama podataka , a do 10 % nalazi se u tzv. jezgri svjetskog znanja, ISI-jevim citatnim bazama podataka, nužno je znati kriterije koji određuju status pojedinog časopisa. Bradford je već ranih tridesetih dvadesetog stoljeća postavio jedan od osnovnih bibliometrijskih zakona, kojim je utvrdio da najveći broj važnih članaka za pojedino područje nalazi u malom broju časopisa. Ako želimo utvrditi koji su časopisi relevantni za pojedino područje, primjenom Bradfordovog zakona može se dobiti distribucija radova u časopisima po tzv. zonama. Neka je neka tema zastupljena u 200 časopisa s 1520 članaka, primjenom Bradfordove distribucije dobit ćemo zonu A koju čini 10 časopisa s 505 članaka, zonu B s 22 časopisa koji donose 495 članaka te zonu C koja čini 168 časopisa koji su objavili 520 članaka vezanih uz problematiku koja nas zanima. Dio autor nije mišljenja da je Bradfordov zakon raspršenosti primjenjiv na univerzalnoj razini. Brandyopadhyay (1999) je istraživao primjenjivost zakona na različite discipline. Ovaj zakon po njemu , u cijelosti vrijedi za cistu matematiku, statistiku, fiziku čvrstog stanja, strojarstvo, *Fakultet strojarstva i brodogradnje*

filozofiju, političke znanosti i sociologiju. Djelomično odgovara na uzorku iz matematike kao cjeline, primijenjene matematike, fizike kao cjeline, optike, nuklearne fizike, elektronike i filozofije. Međutim, za općenite, velike discipline, npr medicina općenito, fizika, kemija, Bradfordov zakon raspršenosti nije potvrđen [1]. Bradfordovu distribuciju možemo vidjeti na slici 1.



Slika 1.Bradfordova distribucija

Prepostavlja se da časopisi koji ulaze u tzv. jezgru ili skupinu koja bi trebala biti relevantna za neko područje, imaju neke zajedničke karakteristike odnosno parametre kvalitete. Kriterij koji određuju kvalitetu časopisa izrađeni su za potrebe baza podataka još krajem 60-ih godina dvadesetog stoljeća:

- Rukopisi koji se prihvataju za objavljivanje trebaju sadržavati nove znanstvene informacije temeljene na provjerljivim i pouzdanim metodama i statističkim postupcima
- Urednički odbor časopisa treba biti tako koncipiran da ima predstavnike svih poddisciplina kojim se časopis bavi
- Pored urednika treba postojati i kvalitetan recenzentski tim
- Časopis treba izlaziti redovito i dinamikom koja je određena
- Časopis treba biti zastupljen u svim relevantnim sekundarnim izvorima literature
- Časopis treba imati odgovarajući broj citata dobivenih od drugih časopisa

Te kriterije je prihvatio i ISI uz manje proširenje

- Obvezu sažetaka članaka na engleskom jeziku

- Adresu autora
- Kompletan popis referenci na koje se autor u tekstu poziva
- Te kriterij međunarodne zastupljenosti autora članaka

Rousseau (2002) dodaje ovim kriterijima još i važnost reputacije nakladnika i glavnog urednika kao dobar pokazatelj za potencijalnu važnost odnosno kvalitetu časopisa.

2.1. Metrički pokazatelji

Faktor odjeka je samo jedna od 3 standardizirane mjere kreirane od Instituta za znanstvene informacije (ISI) koja se može koristiti za mjerjenje i praćenje na koji način je časopis dobivao citate koji su bili davani člancima tijekom vremena. Prikupljanje citata teži da slijedi krivulju kao na slici 2. Citati članaka izdanih u određenoj godini rastu naglo, dolaze do vrhunca između dvije do šest godina nakon objavlјivanja. Od ovog vrhunca citiranje opada s vremenom. Krivulja citata bilo kojeg časopisa se može opisati prema relativnoj veličini krivulje (u smislu površine ispod linije). Ove karakteristike čine osnove ISI-jevih indikatora: faktor odjeka, indeks brzine citiranja, indeks poluvremena citiranja.

2.1.1 Faktor odjeka

Faktor odjeka časopisa , kao statistički pokazatelj potencijalne vrijednosti časopisa postao je u osnovi dostupan tek nakon nastanka ISI-jeve citatne baze podataka SCI (*Science Citation Indeks*). Ideja o faktoru odjeka znatno je starija od ISI-jevih citatnih indeksa i baze podataka *Journal Citation Report* (JCR) . Razradili su je Gross i Gross 1927. Godine analizirajući citate članaka objavljenih u časopisu *Journal of American Chemical Society* (JACS). Vodili su se prepostavkom da časopisi imaju veću informacijsku vrijednost ukoliko dobiva veći broj citata. Kako bi se časopisi lakše mogli uspoređivati, Raising je 1960. Godine predložio da se uvede faktor odjeka, koji je on nazvao specifični pokazatelj „*Indeks of Research Potential Realized*“ (RPR) odnosno “ indeks realiziranog potencijala istraživanja“. Međutim, Garfield (1979) je svoju ideju o faktoru odjeka iznio prvi puta 1955. godine, i kako kaže nije ni slutio koliko će kontroverzi izazvati s tim pokazateljem. 1960. godine zajedno je sa Sherom definirao faktor odjeka, s idejom da olakša proces selekcije časopisa za uključivanje u bazu podataka *Science Citation Indeks*. Trebali su instrument koji će biti metodološki jednostavan i koji će omogućiti usporedbu časopisa neovisno o njihovoj veličini. U odluci im je pomogao Reinsigov faktor odjeka časopisa, koji je Garfield 1960. godine standardizirao i generalizirao. U osnovi faktor odjeka je omjer broja citata dobiven na objavljene članke i broja objavljenih članaka u određenom razdoblju. Razlika u izračunavanju faktora odjeka odnosi se na

razdoblje u kojem se računa faktor odjeka. Faktor odjeka časopisa koji nalazimo u godišnjem izdanju JCR, računa se tako da se podijeli broj citata dobiven u tekućoj godini, na radove objavljene u proteklom dvogodišnjem periodu, s brojem radova objavljenih u istom tom razdoblju[1]. Primjer faktora odjeka za neki časopis u 2010. godini računa se na sljedeći način:

$$\text{Faktor odjeka(IF)} = \frac{\text{broj citata dobiven u 2010. na članke objavljene u 2008. i 2009 godini}}{\text{ukupan broj radova objavljen u 2008 i 2009 godini}}$$

Osnova obilježja faktora odjeka su:

- Faktor odjeka je pomagalo u određivanju kvalitete časopisa
- Faktor odjeka nije pomagalo u određivanju kvalitete pojedinog članka
- Faktor odjeka časopisa nije pomagalo u procjeni kvalitete pojedinog znanstvenika
- Faktor odjeka časopisa nije pomagalo u procjeni kvalitete istraživanja istraživačke skupine ukoliko ima manje od 100 radova u dvije godine
- Procjena kvalitete članaka, pojedinog znanstvenika ili grupe znanstvenika može se mjeriti citatnim analizama

2.1.2. Indeks brzine citiranja

JCR za svaki časopis nudi i mogućnost mjerjenja brzine kojom je prosječni članak citiran. Taj pokazatelj se zove indeks brzine citiranja (*immediacy indeks*) i definira se kao omjer broja citata koje je dobio časopis u istoj godini u kojoj su članci objavljeni i broja članaka objavljenih u istoj godini. U usporedbi s faktorom odjeka ima znatno manje značenje, pogotovo za neka područja. Ovaj indeks može biti pokazatelj popularnosti časopisa. Što je veći indeks brzine citiranja to mu je veća popularnost. Ovo zapravo upućuje na činjenicu da je časopis s ovako visokim indeksom često čitan. Visok indeks brzine čitanja imaju časopisi koji objavljaju popularne teme kao npr. članci vezani za solarne ćelije, baterije, telekom tehnologije, globalno zatopljenje itd...

Sen (1990.) smatra da periodicitet izlaženja časopisa ima važnu ulogu kod određivanja indeksa brzine čitanja. Časopisi koji izlaze tjedno imaju indeks brzine citiranja veći od onih koji izlaze kvartalno ili polugodišnje. Ako časopis izlazi dva puta godišnje drugi broj može izaći pod kraj godine, čime radovi s tog broja potencijalno imaju manju šansu za citiranje u godini objavljivanja. Indeks brzine citiranja izračunava se po formuli:

Ib = indeks brzine citiranja

Ib (A) = Indeks brzine citiranja časopisa u A kalendarskoj godini

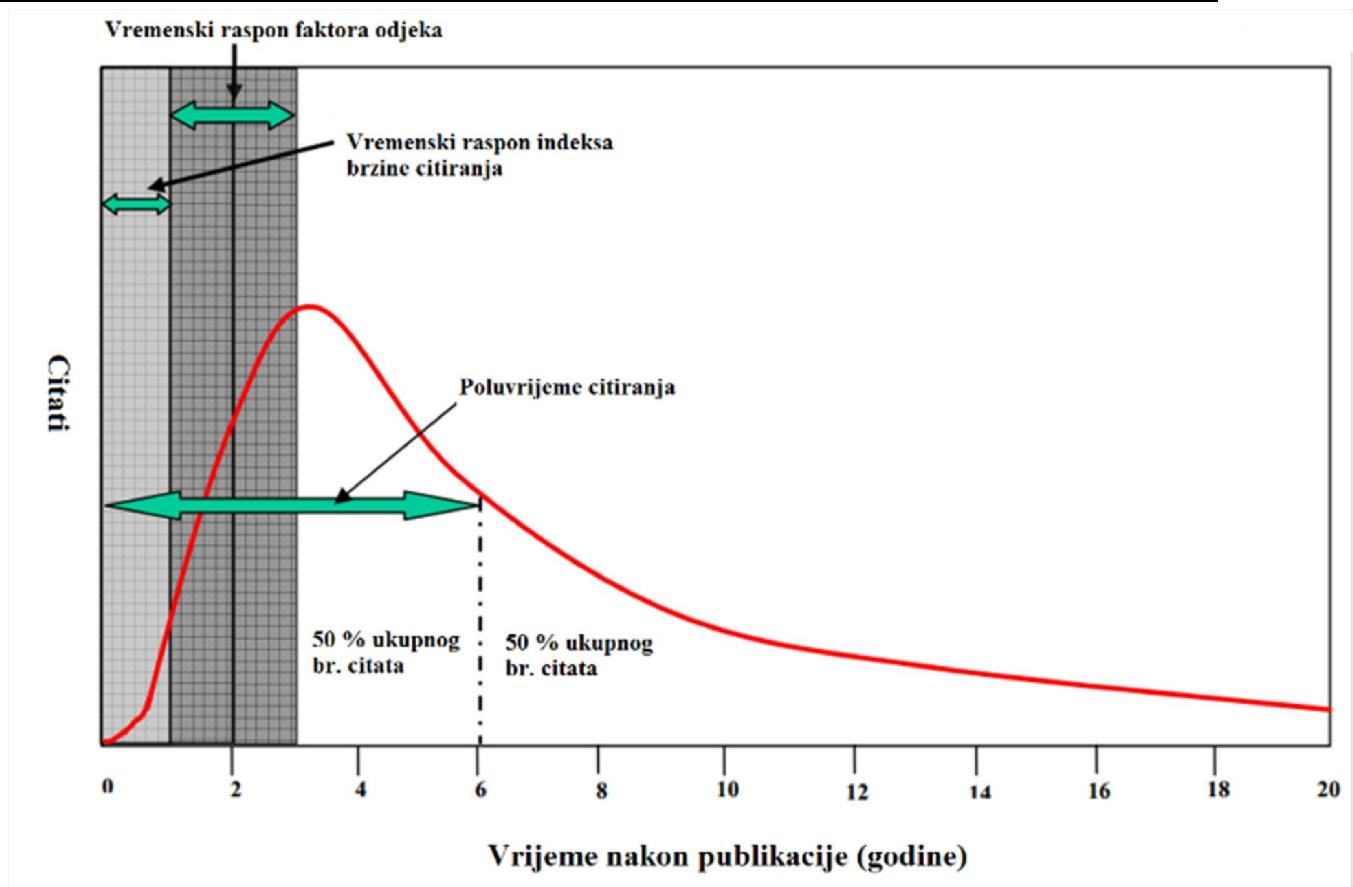
C = broj dobivenih citata u istoj godini

S = broj članaka objavljen u istoj godini

Na temelju podataka o indeksu brzine citiranja, JCR, rangira časopise i na taj način nudi listu časopisa čiji su članci u prosjeku najcitaniji u tekućoj godini. Kod ovog pokazatelja treba biti jako oprezan jer su mogući krivi zaključci. Ako želimo dobiti uvid u problematiku koja se jako intenzivno citira, odnosno želimo na taj način dobiti uvid u trendove u pojedinačnom području, tada vrijednost ovog indeksa dolazi do izražaja[1].

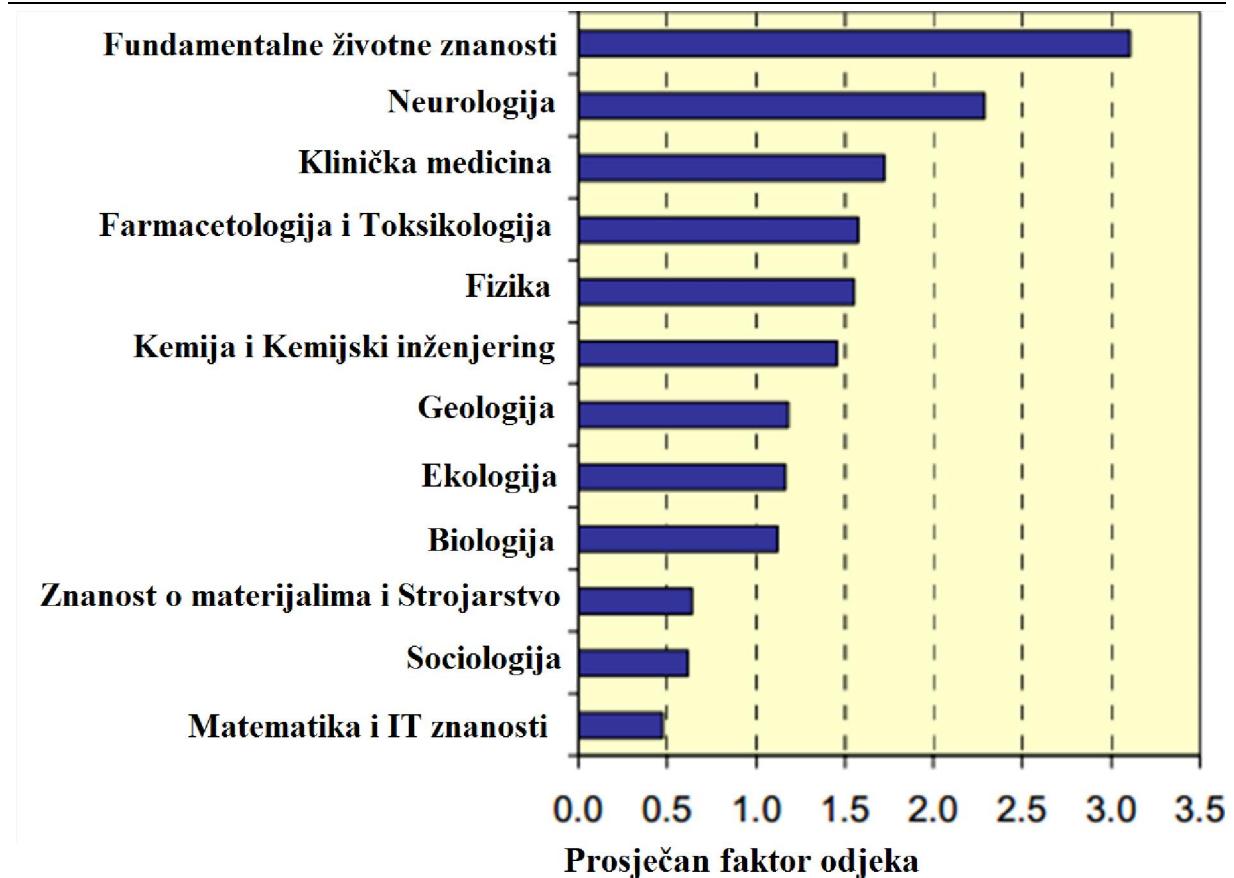
2.1.3. Poluvrijeme citiranja

Jedan od pokazatelja zastarjevanja citirane literature koju nudi JCR, je poluvrijeme citiranja (*cited half life*). Poluvrijeme citiranja predstavlja broj godina računatih unatrag u odnosu na tekuću godinu, koje čine 50% od ukupnog broja citata što ih je dobio taj časopis u tekućoj godini. Npr., ako je poluvrijeme citiranja časopisa 5,6 za godinu 2006. to znači da je polovicu citata koje je dobio promatrani časopis u 2006.godini bila publicirana u posljednje 5,6 godine. Preostala polovica dobivenih citata u toj godini bila je starija od 5,6 godine. Obično se poluvrijeme citiranja obrađuje s ostalim auto-pokazateljima koje nudi JCR, ali se metodologija može primijeniti i na časopise izvan korpusa citiranih baza. Ovaj pokazatelj može ukazivati radi li se o području tzv. *hard science* ili *soft science*. Vrijeme zastarjevanja literature je znatno brže u području tehnologije i bioloških znanosti, eksperimentalne fizike dok je znatno sporije kod teorijskih i matematičkih aspekata fizike. Proces zastarjevanja literature sastoji se od dva vremenska intervala koja se preklapaju. S jedne strane to je faza sazrijevanja, a s druge strane faza opadanja korištenja. Ako faza sazrijevanja korespondira s početnim razdobljem tada je to faza intenzivnog rasta citata, a faza padanja broja dobivenih citata smatra se fazom zasićenja. Da bi imali bolju predodžbu kako se ponašaju gore navedeni metrički pokazatelji, prikazat ćemo na slici 2. generaliziranu krivulju citiranosti u kojoj se svi parametri vrlo dobro vide, te na taj način možda bolje pojasniti uloge metričkih pokazatelja i ponašanja citata nakon objave časopisa.



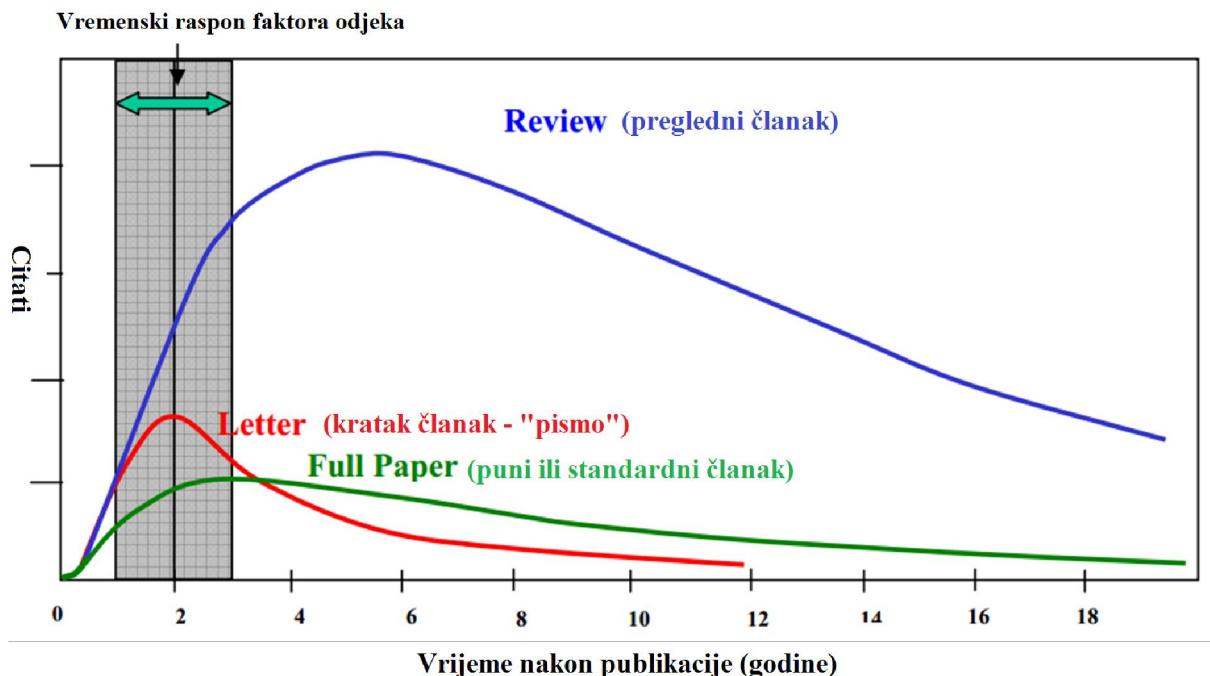
Slika 2.Generalizirana krivulja citiranosti

Od ove tri gore opisane mjere, faktor odjeka je mjeru koja se najčešće koristi i mjeru koju se često pogrešno shvaća. U ovom tekstu spomenut ćemo neke od čimbenika koji utječu na faktor odjeka. Na vrijednost faktora odjeka utječu sociološki i statistički faktori. Sociološki čimbenici uključuju predmetno područje časopisa, vrstu časopisa (pisma, cijeli članak, pregledni rad) i prosječan broj autora po dokumentu (koji se odnosi na predmetno područje). Statistički faktori uključuju veličinu časopisa i duljinu perioda u kojem su citati brojni.



Slika 3. Prosječan faktor odjeka po znanstvenim disciplinama

Slika 3. prikazuje kako absolutna vrijednost aritmetičke sredine faktora odjeka pokazuje značajne varijacije do znanstvenog polja do znanstvenog polja. Općenito, temeljna i čista predmetna područja imaju viši faktor odjeka od specijaliziranih područja. Razlika je toliko značajna da top časopis u jednom području može imati manji faktor odjeka nego najlošiji časopis u drugom području. Usko povezan s ovim fenomenom je fenomen koautorstva. Prosječan broj koautora na članku ovisi o znanstvenog područja, gdje recimo u socijalnoj znanosti imamo u prosjeku dva autora u odnosu na fundamentalne životne znanosti gdje u prosjeku imamo preko četiri koautora po članku. Nije iznenadujuće, ako uzmemos u obzir da autori imaju tendenciju da se referiraju na svoj rad, postoji signifikantna korelacija između prosječnog broja koautora u području sa faktorom odjeka tog područja. Ako uzmemos u obzir ovu činjenicu radovi različitih područja se ne bi trebali uspoređivati već samo radovi u istom području rada[3].



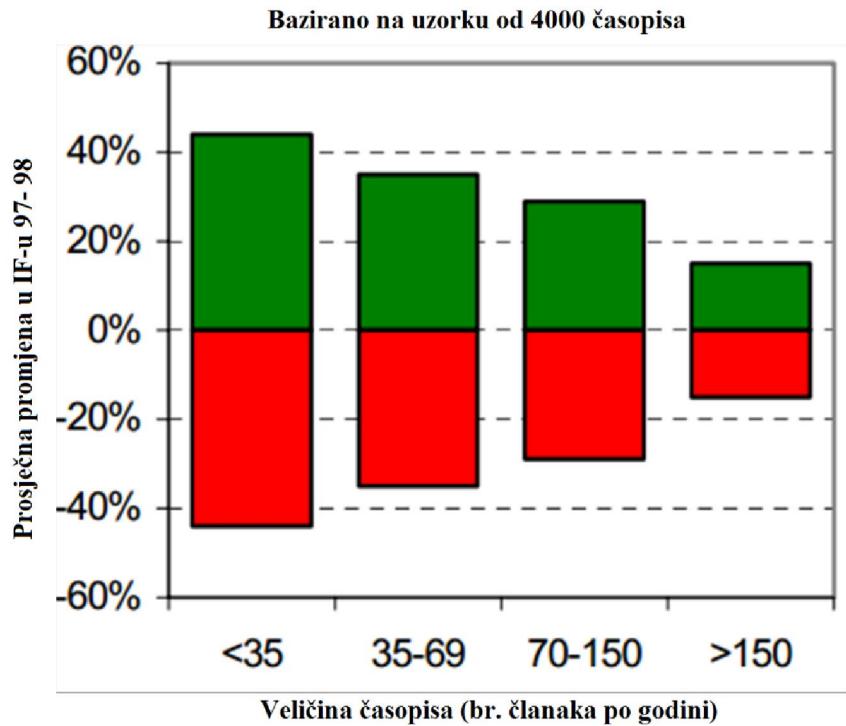
Slika 4. Razlike između tipova časopisa u istom znanstvenom području

Čak i unutar istog predmetnog područja postoje značajne razlike između s obzirom na tip časopisa ili članka. Ovo je prikazano na slici 4.

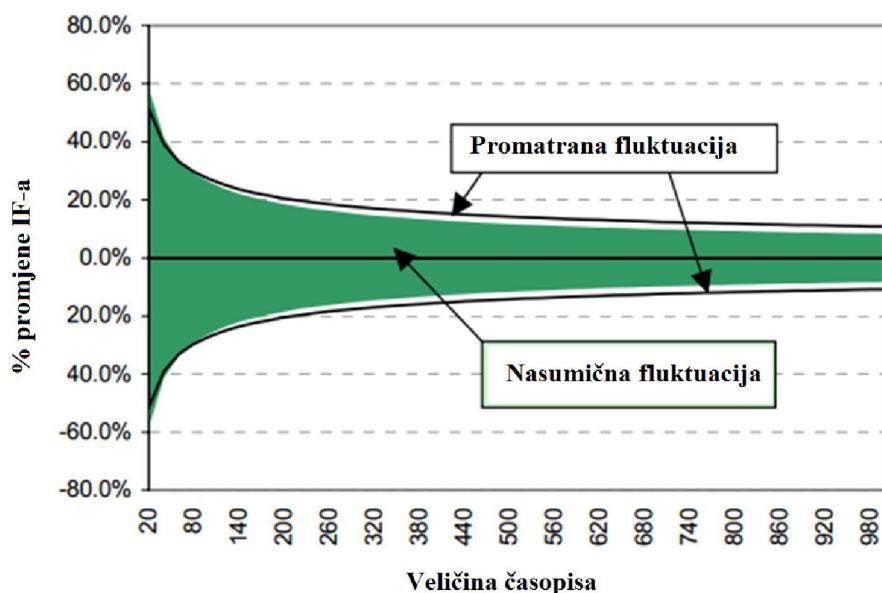
Kratak časopis ili časopis koji često objavljuje (često nazivan časopis „pisama“ objavljuje kratke rade, koji se ne bi trebali miješati sa pismima izdavaču) će imati visok faktor brzine citiranja, ali manji poluvijek citiranja (tj, vrhunac citiranja će biti bliži y- ordinati i nakon toga će uslijediti nagli pad citiranja). Kao posljedica toga veliku većinu citata će dobiti u razdoblju unutar dvije godine faktora odjeka. Nasuprot tome, časopisi sa člancima standardne dužine će imati svoj vrhunac citiranja 3 godine nakon objave, a time i niži faktor brzine citiranja od časopisa sa kratkim člancima. Također će imati manji pad citiranja nakon svog vrhunca citiranosti i samim time viši indeks poluvremena citiranja. Udio citata koji ulaze u razdoblje unutar dvije godine će biti manji kao rezultat oblika krivulje i faktora odjeka takvog časopisa će biti nešto manji od onog časopisa sa kratkim člancima. U slučaju preglednog časopisa, indeks brzine citiranosti je prilično nizak u odnosu na ostale promatrane parametre, citiranost se polako diže da bi svoj vrhunac bio postignut mnogo godina nakon objavlјivanja. Poluvijek citiranja je razmjerno dug budući da citiranost sporo opada nakon svog vrhunca. Udio krivulje koja se nalazi u sklopu dvogodišnjeg faktora odjeka, također je relativno mali, ali budući da je apsolutni broj citata prilično velik, faktor odjeka ovakvog časopisa najčešće je veći nego kod svih ostalih vrsta časopisa. Dakle s obzirom da ima različitih tipova časopisa za

različite vrste članaka, treba s određenom dozom brige i opreza uspoređivati faktore odjeka različitih tipova časopisa.

Budući da je faktor odjeka prosječna vrijednost, na faktoru odjeka se također mogu vidjeti promjene zbog statističkih utjecaja. Ovdje se misli na broj predmeta koji ulaze u prosjek, tj. Veličinu časopisa, broj članaka koji se objave na godišnjoj razini u promatranom časopisu ili veličina promatranog vremenskog perioda (koji je za standardni JRC faktor odjeka razdoblje od dvije godine). Učinci veličine časopisa mogu se vidjeti na slici 5.a. Ako veliki broj časopisa (4000, raspoređeni u kvartalima na temelju veličine časopisa) su ispitani i ako iscrtamo prosječnu varijaciju u faktoru odjeka iz jedne godine u drugu u odnosu na veličinu časopisa, dolazimo do zaključka da postoji očita korelacija između promjene faktora odjeka i veličine časopisa. To znači da kad se faktori odjeka uspoređuju između godina potrebno je uzeti u obzir veličinu časopisa faktora odjeka. Maleni časopisi (manje od 35 radova godišnje) u prosjeku variraju u faktoru odjeka +/- 40% iz jedne godine u drugu. Čak i veći časopisi nisu imuni na ovakve fluktuacije, kod časopisa koji objavljaju 150 članaka godišnje možemo vidjeti da su fluktuacije +/- 15%. Svaki časopis prilikom uzorkovanja uzima malen skup časopisa, pristran uzorak (pristran na način da prilikom odabira su uključeni subjektivni kriteriji) od velikog ali konačnog skupa članaka. Faktor odjeka i bilo kakvo kolebanje u njemu iz jedne godine u drugu može biti rezultat tog pristranog uzorka. Međutim, kakvu fluktuaciju bi vidjeli da uzorak nije bio pristran (subjektivan). Ova pogreška uzorka je procijenjena i prikazana na slici 5b. Ovdje promatrane fluktuacije predstavljaju stvarnu prosječnu promjenu faktora odjeka i studiji 4000 časopisa raspoređenih u grupe ovisno o njihovoj veličini. Osjenčano područje aproksimira fluktuaciju u faktoru odjeka koje bi bilo rezultat nasumično odabranog uzorka članaka, odnosno razlike između faktora odjeka dvaju takvih uzoraka iste veličine. Dakle, promjena u faktora odjeka za bilo koji časopis promatrane veličine nije ništa drukčiji od prosječnog časopisa, ako je taj faktor odjeka unutar promatrane fluktuacije i mogao bi se dogoditi nasumično, ako je fluktuacija unutar zasjenjenog područja. Na primjer, faktor odjeka časopisa od 140 članaka bi se trebao promijeniti za više od +/- 22% da bi bio signifikantan. Po istoj logici, razlika u faktoru odjeka između dva časopisa iste veličine i u istom znanstvenom području trebala bi biti unutar ovog fluktuacijskog područja. Faktor odjeka od 1,5 za časopis koji objavljuje 140 članaka se ne razlikuje značajno od drugog časopisa iste veličine sa faktorom odjeka 1,24.



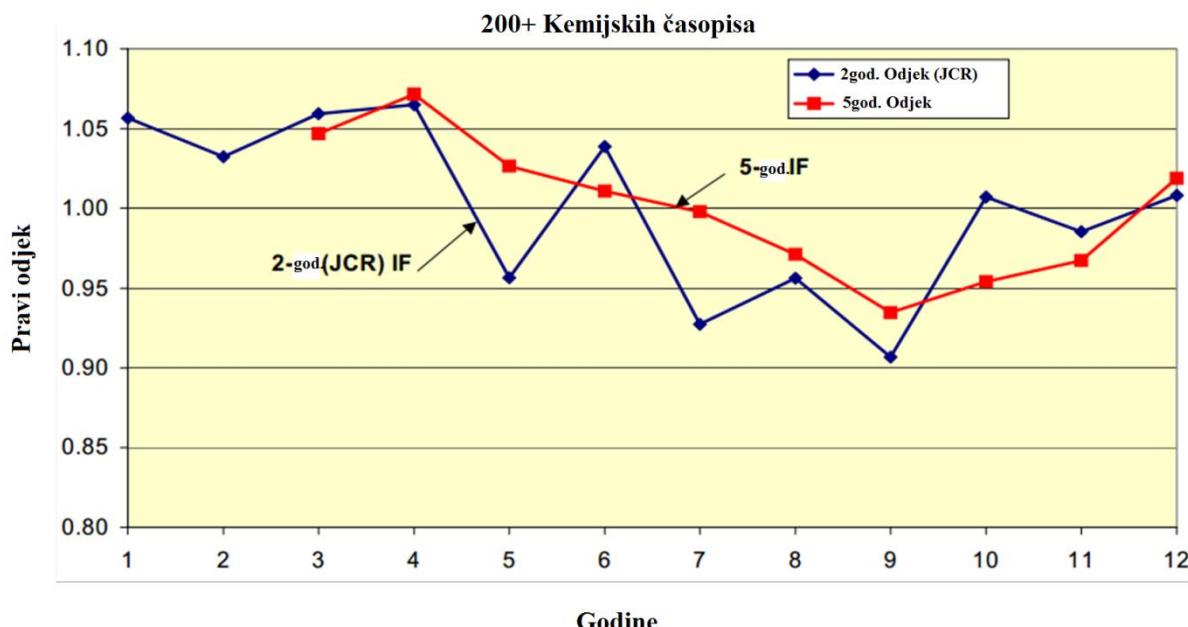
Slika 5a. Prosječna promjena u IF s obzirom na veličinu časopisa



Slika 5b. Fluktuacija IF-a u odnosu na veličinu časopisa

Proširenje vremenskog perioda sa standardne dvije godine JCR faktora odjeka na veći vremenski period moglo bi ispeglati neke statističke varijacije. Učinci ovakvog postupka vide se na slici 6. Na slici se može prosjek dvogodišnjeg i peterogodišnjeg faktora odjeka za otprilike 200 časopisa iz područja kemije i njihov prikaz promjena kroz godine. Petogodišnja mjera, prikazuje promjene tijekom vremena, ali te promjene su puno glađe od promjene kod

dvogodišnje mjere. Mjera koja se često koristi u procjeni časopisa ili kojom časopis dokazuje svoju važnost između svih ostalih časopisa u svom znanstvenom području. Međutim dramatične promjene u rangu mogu se dogoditi jednostavno ako promijenimo vremenski okvir mjerjenja. Na primjer, od 30 časopisa koji su odabrani, 24 je promijenilo rang za 11 mesta gore prilikom promjene sa dvogodišnjeg faktora odjeka na petogodišnji [3].



Slika 6. Faktor odjeka s obzirom na vremenski period računanja

2.2. Multidisciplinarnе citatne baze

Da bi se s bibliometrijskog aspekta moglo pristupiti istraživanju primarnih izvora informacija, nužan je sekundarni izvor koji bibliografski opisuje te publikacije. Za scientometrijska istraživanja dosad su najčešći sekundarni izvori bile profesionalne i komercijalne multidisciplinarnе citatne baze WoS i Scopus te javno dostupna citatna baza *Google Scholar*. Bibliografski zapisi no primarnim izvorima glavna su jedinica obrade podataka pa su značajke izvora tih podataka važne za kvalitetu i primjerenost ulaznih podataka [2].

2.2.1. WoS – Web of Science

Multidisciplinarna citatna baza današnjeg naziva WoS kreirana je početkom 60-ih godina 20. stoljeća. Ideja njenog osnivača Eugena Garfielda bila je stvoriti relevantan izvor najnovije znanstvene literature na međunarodnoj razini, a tek naknadno postala je izvorom za scijentometrijska istraživanja. Obradivala je isključivo časopise, a početni korpus od oko 600 časopisa tvorio je jezgru svjetskog znanja i predstavljao je 5-8% svih znanstvenih časopisa.

Baza se zvala SCI, a jedan segment WoS-a i danas nosi taj naziv. Izbor časopisa temeljio se Bretfordovom zakonu o raspršenosti. Upravo zbog ovog zakona WoS-SCI je bio, a za većinu svjetske zajednice i dalje jest, najprestižniji izvor literature i podataka za scijentometrijska istraživanja. Od tada i neprestana težnja znanstvenika da objave svoje rezultate u časopisima koje indeksira ova baza. Kako je s vremenom rastao broj znanstvenih časopisa, povećavao se i korpus časopisa koji je WoS-SCI indeksirao, ali je jezgru časopisa uvijek činilo manje od 10% časopisa. Ovaj seleksijski postupak u osnovi je funkcionirao do 2005. godine do kada se koncept uključivanja časopisa u ovu bazu značajno mijenja. Kao dokaz mogu poslužiti hrvatski časopisi indeksirani u toj bazi. Do 90-ih godina prošlog stoljeća SCI je indeksirao pet hrvatskih časopisa, a od 2005. indeksirao ih je 9. Pet godina kasnije i indeksira sadržaj preko četrdeset hrvatskih časopisa. Baza WoS osim znanstvenih radova indeksira i različite priloge: prikaze knjiga, kratka znanstvena priopćenja, uredničke uvodnike, sažetke sa znanstvenih skupova, nekrologe, ispravke i komentare koji mogu sadržavati i znanstvene informacije, ali nisu primarno registrirani kao znanstveni radovi. Iako se dio tih radova relativno lagano može izdvojiti, podatci o njima koje nudi WoS ne bi trebali uzeti kao gotove činjenice. Koji su pravi razlozi za uključivanje relativno velikog broja nacionalnih časopisa iz velikog broja zemalja u bazu WoS nije sasvim jasno. Mogući su razlozi konstantne primjedbe od strane akademске zajednice u noskoj zastupljenosti časopisa iz većine europskih zemalja, pogotovo nordijskih zemalja i Njemačke, ali i ostalih zemalja kojima engleski jezik nije materinji. Drugi mogući razlog pojava je konkurentske citatne baze Scopus koja je u selekciji časopisa, ali i ostalih publikacija, koristila princip šire obuhvatnosti. Za usporedbu, 2005.godine Scopus je u svoju bibliografsku obradu uključivao preko 60 hrvatskih časopisa iz svih područja. Kako su časopisi ključni komunikacijski kanal za razmjenu znanstvenih informacija, tako je WoS-SCI relativno dobar instrument za scijentometrijska istraživanja Važnim smatramo napomenuti da je WoS-SCI baza retrospektivno dostupna od 1900.godine, što za scijentometrijska istraživanja i razvoj znanosti nije beznačajan podatak.

2.2.2. Scopus

Multidisciplinarna citatna baza Scopus pojavila se potkraj 2004.godine i počela je s retrospektivnom obradom indeksiranih publikacija od 1996.godine. Do sada sadrži oko 47 milijuna bibliografskih zapisa literature, članaka u časopisima izbornika radova, patenata, knjiga i mrežnih stranica. Baza se osim najnovijim publikacijama puni i retrospektivno, publikacijama starijima od 1996.godine. Kao i u slučaju baze WoS radi se o komercijalnom, i time njoj konkurentskom proizvodu. Pojava skopusa uvelike je utjecala na razvoj novih

mogućnosti u WoS-u, ali i obrnuto. Princip selekcije izvora koji indeksira Scopus ne temelji se na Bradfordovoj distribuciji, što je slučaj kod WoS-a. Zapravo selekcija izvora za Scopus ne ide između one koju koriste WoS i Google Scolar. Za usporedbu, Scopus je od početka 2005.godine obradio relativno veliki broj hrvatskih časopisa. Ova baza relativno je više orijentirana europskim časopisima [2].

2.2.3. *Google Scolar*

Google Scolar je slobodno dostupna najobuhvatnija bibliografska i citatna baza koja se pojavljuje istovremeno kada i Scopus. Za razliku od WoS-a i Scopus-a, Google Scolar se uglavnom popunjava slobodnih indeksiranjem weba, a manje selekcijom časopisa i sličnih izvora. Ovaj pristup jamči opsežnost, ali odrednice za uključivanje aplikacija nisu jasno definirane, premda se pretpostavlja da imaju barem neka obilježja znanstvenog rada. Ta baza u usporedbi s komercijalnim citatnim bazama za sada nudi više nego skromne mjerne pokazatelje. Razina na kojoj su trenutno dostupni podatci iz GS-a ne predstavlja pouzdan izvor podataka. S obzirom da se podatci automatski pobiru iz različitih izvora, često sadrže greške, potrebno ih je preuzimati i obrađivati što podrazumijeva poznavanje autora i problematike. Kako se radi o besplatnom izvoru s drugačijim pristupom prikupljanja podataka o znanstvenim publikacijama u usporedbi s komercijalnim bazama WoS i Scopus u koje se godinama ulažu ogromna sredstva na razvoj i usavršavanje, od GS-a se ni ne mogu zasada očekivati bolji rezultati [2].

3. UZORAK I METODOLOŠKI PRISTUP

Sada kada smo apsolvirali što su to uobičajeni metrički pokazatelji razine znanstvene kvalitete i kada smo naveli koje citatne baze prikupljaju podatke za računanje ovih pokazatelja, u ovom dijelu rada opisat ćemo na koji način i kako su podaci potrebni za ovo istraživanje prikupljeni. Glavni cilj je bio prikupiti podatke iz jednog velikog časopisa i dva relativno manja časopisa. Druga podjela trebala nam je dati usporedbu između dvaju stranih časopisa tehničkog područja i jednog hrvatskog časopisa tehničkog područja. Također, jedan od značajnih čimbenika zašto su odabrani ovi časopisi je i u tome što su ovi časopisi pisani ili na engleskom ili hrvatskom govornom području jer časopisi na drugim govornim područjima nisu mogli doći u obzir zbog nepoznavanja ostalih govornih područja. Razlog zašto je uzet jedan veći časopis sa češćim objavlјivanjem radova je u tome da prilikom citatne analize imamo što više podataka, kako bi što bolje i točnije mogli grafički opisati dobivene podatke. Smatralo se da s većim uzorkom bi greške koje nastaju u citanim bazama manje utjecale na ove studije. Daljnji cilj bio je odabrati časopise koji su usko vezani za strojarstvo, kako bi kasnije mogli pomoći dobivenih parametara opisati stanje znanosti u strojarstvu za period koji je bio promatran tj. 2010. godina. Zbog vremenskog ograničenja izrade ovog rada odlučeno je da će se citati potrebni za istraživanje prikupljati za period od jedne godine, iako za dva manja časopisa kasnije je odlučeno da će taj period biti proširen jer količina podataka i nije bila tako velika za ta dva časopisa.

3.1. Postupak prikupljanja podataka

Časopisi za koje je odlučeno da će se prikupljaju podaci su: *Advaced Materials, Progress in Materials Science*, Tehnički Vjesnik. Baza iz koje su prikupljeni podaci je već spomenuta baza podataka WoS (*Web of Science*), budući da je ova baza pokrivala odabrane časopise i da se i danas ta baza smatra najkvalitetnijom bazom odlučeno je da će se baš iz te citatne baze podataka izvlačiti podaci za ove časopise. WoS osim što ima najopširniju provjeru podataka ima i neke od dodatnih alata za analizu citata koja nam je kasnije pomogla u prikupljanju nekih od informacija bitnih za kasniji dio ovog rada. Prvi problem na koji se naišlo je bio u tome što da bi pristupili WoS- ovoj bazi morate pristupati preko njihovom serveru poznatog IP-a (Internet protokol). Takav IP najčešće imaju znanstvene institucije, znači od svoje kuće se ne možete spojiti ovim bazama (osim u slučaju ako platite pristup). Odlučeno je da će ta institucija biti NSK- Nacionalna sveučilišna knjižnica, jer pristup prostorima knjižnice i Fakultet strojarstva i brodogradnje

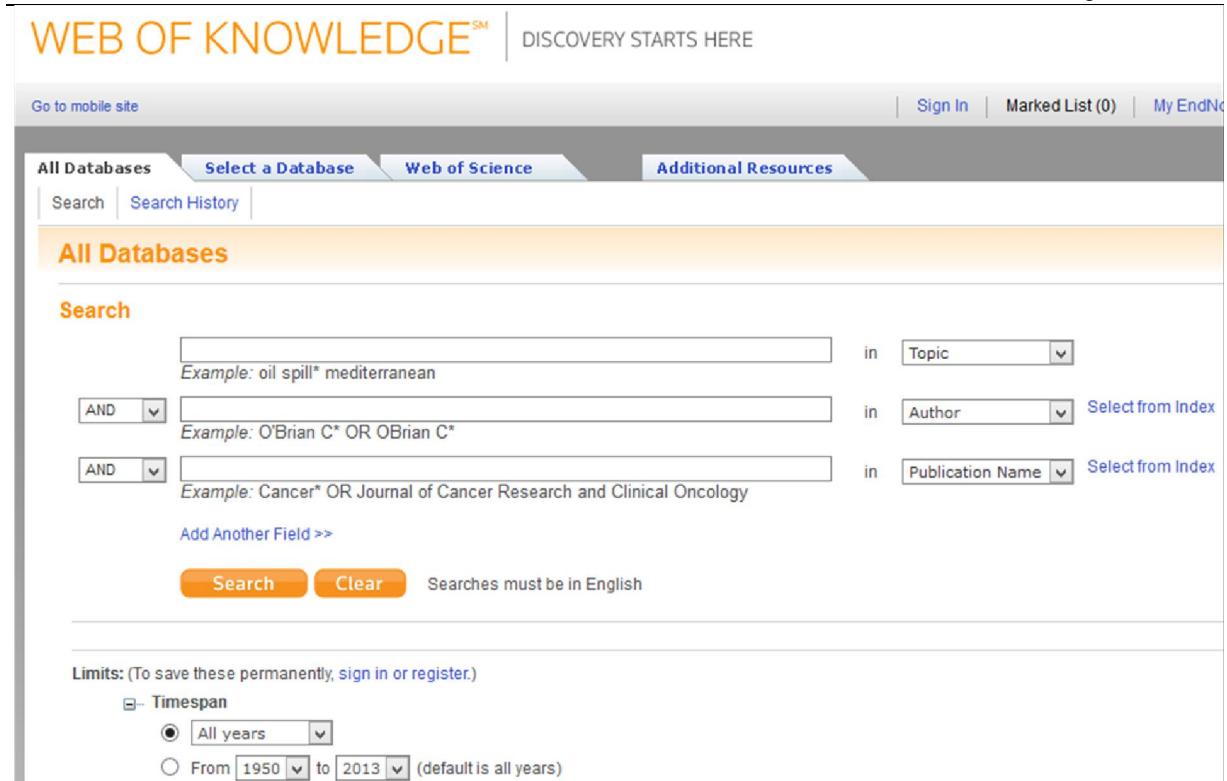
bežičnom internetu je vremenski veći nego što bi to bio u prostorima Fakulteta Strojarstva i Brodogradnje.

Prvi časopis s kojim se krenulo prikupljati podatke bio je *Advanced Materials*. Njegovo web izdanje možemo vidjeti na slici 7.

The screenshot shows a search result for the journal "Advanced Materials". The first result is an article titled "Tissue Engineering: A Modular, Hydroxyapatite-Binding Version of Vascular Endothelial Growth Factor (Adv. Mater. 48/2010) (page 5436)". The article is by Jae Sung Lee, Amy J. Wagoner Johnson, and William L. Murphy, published online on 15 DEC 2010. The abstract discusses a biomimetic peptide capable of binding hydroxyapatite and promoting pro-angiogenic activity. Below the abstract is a thumbnail of the journal cover featuring a green and yellow molecular structure. The second result is a "Contents" section for the journal issue (Adv. Mater. 48/2010), which includes an article on "Ultrafast Manipulation of Self-Assembled Form Birefringence in Glass (page 5442)" by Yasuhiko Shimotsuma, Masaaki Sakakura, Peter G. Kazansky, Martynas Beresna, Jiarong Qiu, Kiyotaka Miura, and Kazuyuki Hirao, published online on 15 DEC 2010. This article is marked as "FREE". The third result is a "Correction" section for the same journal issue, listing the same article as the "Contents" section. The page number 5442 is also present in the correction section.

Slika 7. Jedno od e-izdanja časopisa Advanced Materials

Časopis se izdaje 4 puta mjesečno, sa u prosjeku po 16 članaka. Da bi mogli saznati koliko je neki članak citiran, kopiramo naslov članka iz časopisa u WoS-ovu tražilicu i tražimo u bazi dali postoji takav naslov u bazi. Sučelje na tražilici ima 3 parametra s kojim možete specificirati i olakšati traženje, neki od tih parametara su: autor, godina izdanja, časopis u kojem je članak izdan itd. Sučelje WoS-ove baze može se vidjeti na slici 8.



Slika 8. Sučelje tražilice WoS-ove baze podataka

U 90 % slučajeva tražilica će ponuditi naslov koji tražimo i kada se klikne na taj naslov prikazat će se svi podaci koje WoS ima o ovom članku. Za potrebe ovom rada uzeti su podaci o citiranosti i broju referenci članka kojeg se unijelo u tražilicu. Ti podaci su zatim prebačeni u tablice napravljene da bi se lakše sortirali preuzeti podaci. U preostalih 10 % slučajeva kad tražilica ne nudi traženi naslov, najčešće je zbog toga što u naslovu postoje neke netipične oznake, kao primjerice grčka slova, tada uzimamo dijelove naslova i pomoću njih pokušavamo pronaći traženi naslov. Naravno ovo traži dodatno vrijeme, koje je nažalost ograničeno. Tijekom prikupljanja podataka naišlo se na još neke sitne probleme koji su uzimali vrijeme, recimo tema izdanja je na početku liste naslova, ali se ponavlja u popisu članaka izdanja časopisa i to nikad na istom dijelu liste, tako da se tu trebalo paziti kako ne bi dva puta tražilo podatke za isti naslov i kako ih se ne bi prebacilo u tablice, jer bi to automatski radilo veliku grešku kada bi se u konačnici statistički obrađivalo podatke. Daljnji problem je bio u tome što u NSK često zna biti opterećen sustav bežičnog interneta i tada dolazi do naglog usporavanja prikupljanja podataka. Osim ovih detalja koji su uzimali vrijeme na slici 7. možemo vidjeti korekciju članka objavljenu 15.12.2010 na članak prvotno objavljen 23.08.2010, iako korekcije znaju biti citirane one uglavnom imaju vrlo mali broj citata i odlučeno je da neće ulaziti u analizu. Općenito korekcije članaka ne bi trebale ulaziti u proračun faktora odjeka jer zbog svoje vrlo male citiranosti bi nepravedno smanjivale taj

faktor. Nakon što su se prikupili podatci za jedno izdanje svi ti podaci iz gore navedenih razloga bi sve provjerili par puta i kad bi se zaključilo da količina podataka odgovara broju članaka prešlo bi se na sljedeće izdanje i tako za čitavu godinu dana promatranog časopisa. Na slici 9. možemo vidjeti kako izgledaju podaci jednog članka u WoS-ovoј bazi. Podaci koje možemo prikupiti o časopisu osim broja citata i referenci su recimo, koliko je članak imao koautora ili koliko je znanstvenika radilo na ovom radu. Osim toga sadrži i broj znanstvenih institucija koje su sudjelovale pri izradi rada. Razlog zašto se spominju i ovi podaci je zbog toga što u dalnjem dijelu rada će se objasniti, kako ovi podaci koji ne izgledaju tako značajno mogu imati utjecaja na faktor odjeka. Vrijeme koje je bilo potrebno za prikupljanje podataka za ovaj časopis može se dobiti jednostavnom matematikom. Kada se uzmu svi parametri od: traženja, kopiranja, provjere i sortiranja podataka, za jedan članak u prosjeku je potrebno oko 5 -7 min, ako časopis izlazi 4 put mjesečno te je u svakom izdanju po 16 članaka ukupna količina članaka je $12 \times 4 \times 16 = 768 +/- 15$ članaka. Ova brojka se poklapa sa WoS-ovim izvješćem koje kaže da je u 2010. godini u časopisu *Advaced Materials* objavljeno 777 članaka, kada se prebroje podaci ovog istraživanja dobiveno je 783 članka što je prihvatljiva greška, ako je greška, jer se zna da WoS-ove baze znaju sadržati greške.

Vrijeme potrebno za prikupljanje podataka ovog časopisa je teško procijeniti, ali ako pomnožimo prosječnih 6 min koje je utrošeno po jednom članku dobivamo broj od ukupno 4680 min, što preračunato u sate iznosi 78 sati potrebnih da bi se prikupili podaci samo za ovaj časopis.

Engineering the Extracellular Environment: Strategies for Building 2D and 3D Cellular Structures

Author(s): Guillame-Gentil, O (Guillame-Gentil, Orane)^[1,2]; Semenov, O (Semenov, Oleg)^[1,2,4]; Roca, AS (Roca, Ana Sala)^[1,2,3]; Groth, T (Groth, Thomas)^[5]; Zahn, R (Zahn, Raphael)^[1,2]
Voroš, J (Voroš, Janos)^[1,2]; Zenobi-Wong, M (Zenobi-Wong, Marcy)^[1,2]

Source: ADVANCED MATERIALS Volume: 22 Issue: 48 Pages: 5443-5462 DOI: 10.1002/adma.201001747 Published: DEC 21 2010

Times Cited: 20 (from Web of Science)

Cited References: 262 [view related records] [Citation Map]

Abstract: Cell fate is regulated by extracellular environmental signals. Receptor specific interaction of the cell with proteins, glycans, soluble factors as well as neighboring cells can steer cells towards proliferation, differentiation, apoptosis or migration. In this review, approaches to build cellular structures by engineering aspects of the extracellular environment are described. These methods include non-specific modifications to control the wettability and stiffness of surfaces using self-assembled monolayers (SAMs) and polyelectrolyte multilayers (PEMs) as well as methods where the temporal activation and spatial distribution of adhesion ligands is controlled. Building on these techniques, construction of two-dimensional cell sheets using temperature sensitive polymers or electrochemical dissolution is described together with current applications of these grafts in the clinical arena. Finally, methods to pattern cells in three-dimensions as well as to functionalize the 3D environment with biologic motifs take us one step closer to being able to engineer multicellular tissues and organs.

Accession Number: WOS:000285397400002

Document Type: Review

Language: English

KeyWords Plus: POLYELECTROLYTE MULTILAYER FILMS; SELF-ASSEMBLED MONOLAYERS; ENZYMATICALLY-TAILORED PECTINS; OSTEOBLAST-LIKE CELLS; ENDOTHELIAL-CELL; SMOOTH-MUSCLE; IN-VITRO; CROSS-LINKING; STEM-CELLS; ELECTROCHEMICAL DESORPTION

Reprint Address: Zenobi-Wong, M (reprint author)
Inst Biomed Engn Univ, Lab Biosensors & Bioelect, Gloriastr 35, CH-8092 Zurich, Switzerland.

Addresses:
[1] Inst Biomed Engn Univ, Lab Biosensors & Bioelect, CH-8092 Zurich, Switzerland
[2] ETH, CH-8092 Zurich, Switzerland
[3] Univ Zurich Hosp, Dept Cranio-maxillofacial Surg, CH-8091 Zurich, Switzerland
[4] Univ Zurich Hosp, Dept Obstet, CH-8091 Zurich, Switzerland
[5] Univ Halle Wittenberg, Inst Pharm, Biomed Mat Grp, D-06120 Halle, Germany

E-mail Addresses: zmarcy@ethz.ch

Author Identifiers:

Funding:

Funding Agency	Grant Number
National Science Foundation	PMPDP2_122997
European Union	NMP4-SL-2009-229292

[Show funding text]

Publisher: WILEY-V CH VERLAG GMBH, PO BOX 10 11 61, D-69451 WEINHEIM, GERMANY

Web of Science Categories: Chemistry, Multidisciplinary; Chemistry, Physical; Nanoscience & Nanotechnology; Materials Science, Multidisciplinary; Physics, Applied; Physics, Condensed Matter

Research Areas: Chemistry, Science & Technology - Other Topics; Materials Science; Physics

Slika 9. Svi podaci određenog članka u WoS-ovoj bazi

Nakon što su se prikupili svi podaci za časopis *Advaced Materials*, ti isti podaci posloženi su u eksel tablice i u standardne word tablice. U eksel tablicama su sortirani podaci tako da svaki stupac označava datum izdanja časopisa i broj izdanja, količina podataka koja je stala na jednoj stranici eksela je za period od dva mjeseca tj za 8 izdanja časopisa. Znači ukupno se prikupilo 6 stranica podataka u ekelu. Prikaz jedne stranice prikupljenih podataka možemo vidjeti na slici 10. Korištenje eksela kao pomoćnog programa pomoglo je da ti podaci budu što finije raspoređeni kako ne bi došlo do mogućih grešaka pri analizi podataka, a i te podatke kasnije lako je prikupit i ubacit u program Minitab 16. koji je korišten za većinski dio statističke analize napravljene u ovom radu. Kada su se prikupili podaci za čitavu godinu i kada su popunjene stranice, odlučeno je da bi podatke bilo dobro rasporediti u razrede budući da je raspon citata varirao od 0 do 736. Razredi citata napravljeni su tako da prvi razred čine članci koji imaju od 0 – 9 citata, drugi razred od 10- 19 citat itd do zadnjeg razreda od 80 +, budući da članci sa preko 80 citata su izuzetno rijetki nije bilo potrebe raspodijeliti podatke u nove razrede. Ti podaci prikazani su u tablicama 1-6.

B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
21.12 izd. 48		14.12 izd. 47.		07.12 izd. 46.		01.12 izd. 45.		24.11 izd. 44.		16.11 izd. 43.		09.11 izd. 42.		02.11 izd. 41.
11		19		16		0				15		24		
12		19		11						70		38		13
14		4		12		55		48				18		7
19		2		26		12		52		4		3		10
52		12		76		16		20		18		6		4
16		3		8		10		5		31		9		15
31		26		5		15		15		5		23		44
17		4		18		4		2		24		2		2
14		24		17		21		9		15		11		11
12		6		3		11		10		49		28		7
7		10		9		9		19		1		5		7
1		8		16		32		5		12		6		1
14		9		16		1		57		5		34		7
18		72		19		13		17		77		18		4
11		5		15		14		13		15		34		27
5		6		8		46		61		23		22		46
10		27		1		11		18		33		18		
14				2		6		12		14		3		
						12		1		29		11		
						8		16		6				
						24		8		22				
						8		10		2				
						17		8		8				
						35		7						
						35		25						
								17						
								4						
								9						

Slika 10. Jedna od stranica prikupljenih podataka časopisa Advanced Materials

Tablica 1. Frekvencije citata članaka časopisa Advaced Materials za mjesec Prosinac i Studeni

Razred frekvencija citata	Datum i broj izdanja promatranog časopisa								Σ
	21.12 izd. 48.	14.12 izd. 47.	07.12 izd. 46.	01.12 izd. 45.	24.11 izd. 44.	16.11 izd. 43.	09.11 izd. 42.	02.11 izd. 41.	
0--9	3	9	7	7	10	7	7	8	58
10--19	13	4	9	10	10	6	5	4	61
20-29	0	3	1	2	2	4	4	1	17
30-39	1	0	0	3	0	2	3	0	9
40-49	0	0	0	1	1	1	0	2	5
50-59	1	0	0	1	2	0	0	0	4
60-69	0	0	0	0	1	0	0	0	1
70-79	0	1	1	0	0	2	0	0	4
80 +	0	0	0	0	0	0	0	0	0
Ukupan br. članaka	18	17	18	24	26	22	19	15	

Tablica 2. Frekvencije citata članaka časopisa Advanced Materials za mjesec Listopad i Rujan

Razred frekvencija citata	Datum i broj izdanja promatranog časopisa								
	25. 10. Izd. 40.	15.10. Izd. 39.	08.10. Izd. 38.	01.10. Izd. 37.	22.09. Izd. 36.	15.09. Izd. 35.	08.09. Izd. 34.	01.09. Izd. 33.	Σ
0--9	7	6	5	5	8	4	1	9	45
10--19	6	3	6	5	6	2	0	7	35
20-29	1	3	1	3	2	2	0	1	13
30--39	2	0	2	2	2	0	2	1	11
40--49	0	2	0	0	0	0	2	1	5
50--59	1	0	0	0	1	3	0	1	6
60--69	0	0	1	0	0	0	1	0	2
70--79	1	0	0	1	0	1	1	0	4
80 +	0	1	0	1	1	1	2	1	7
Ukupan br. članaka	18	15	15	17	20	13	9	21	

Tablica 3. Frekvencije citata članaka časopisa Advanced Materials za mjesec Kolovoz i Srpanj

Razred frekvencija citata	Datum i broj izdanja promatranog časopisa							
	24.08. Izd. 32.	17.08. Izd. 31.	10.08. Izd. 30.	03.08. Izd. 29.	27.07. Izd. 28.	20.07. Izd. 26-27	06.07. Izd. 25.	Σ
0--9	6	2	6	5	5	5	8	37
10--19	7	3	6	4	6	4	4	34
20-29	0	2	1	2	2	2	2	11
30--39	4	2	1	0	1	0	1	9
40--49	1	1	2	2	1	0	0	7
50--59	1	1	1	0	1	0	0	4
60--69	1	0	0	1	0	0	0	2
70--79	0	2	2	0	1	1	1	7
80 +	0	0	0	0	0	0	1	1
Ukupan br. članaka	20	13	19	14	17	12	17	

Tablica 4. Frekvencije citata članaka časopisa Advaced Materials za mjesec Lipanj i Svibanj

Razred frekvencija citata	Datum i broj izdanja promatranog časopisa									Σ
	25.06. Izd. 24.	18.06. Izd. 23.	11.06. Izd. 22.	04.06. Izd. 21.	25.05. Izd. 20	18.05. Izd. 19.	11.05. Izd. 18.	04.05. Izd. 17		
0--9	9	3	5	4	2	6	7	3	39	
10--19	7	10	3	6	5	4	4	6	45	
20-29	1	3	1	3	0	2	2	2	14	
30-39	2	0	1	2	0	1	2	3	11	
40-49	0	0	0	1	3	1	0	1	6	
50-59	1	1	1	0	1	4	1	0	9	
60-69	0	0	0	0	0	0	0	1	1	
70-79	0	1	0	0	1	1	0	0	3	
80 +	0	0	2	0	3	1	0	0	6	
Ukupan br. članaka	20	18	13	16	15	20	16	16		

Tablica 5. Frekvencije citata članaka časopisa Advaced Materials za mjesec Travanj i Ožujak

Razred frekvencija citata	Datum i broj izdanja promatranog časopisa									Σ
	22.04. Izd. 16.	18.04. Izd. 15.	12.04. Izd. 14.	06.04. Izd. 13.	26.03. Izd. 12	19.03. Izd. 11.	12.03. Izd. 10.	05.03. Izd. 9.		
0--9	2	2	5	3	3	3	5	6	29	
10--19	5	3	6	4	5	4	4	5	36	
20-29	2	1	1	2	1	0	0	3	10	
30-39	2	3	0	2	3	3	2	2	17	
40-49	1	1	0	1	2	1	0	1	7	
50-59	1	0	0	1	1	1	0	0	4	
60-69	0	0	2	0	0	0	1	0	3	
70-79	0	2	1	0	0	2	0	1	6	
80 +	2	1	1	0	2	1	2	1	10	
Ukupan br. članaka	15	13	16	13	17	15	14	19		

Tablica 6. Frekvencije citata članaka časopisa Advaced Materials za mjesec Veljaču i Siječanj

Razred frekvencija citata	Datum i broj izdanja promatranog časopisa								
	23.02. Izd. 8.	16.02. Izd. 7.	09.02. Izd. 6.	02.02. Izd. 5.	26.01. Izd. 4.	19.01. Izd. 3.	12.01. Izd. 2.	05.01. Izd. 1.	Σ
0--9	4	1	1	2	4	6	0	4	22
10--19	4	3	6	6	7	7	0	4	37
20-29	1	1	4	4	1	1	1	9	22
30--39	1	0	4	2	2	2	0	2	13
40--49	0	1	2	1	0	1	4	0	9
50--59	1	1	0	0	0	0	1	1	4
60--69	1	1	0	2	1	1	0	0	6
70--79	1	0	0	0	0	1	0	0	2
80 +	2	1	2	1	2	3	2	1	14
Ukupan br. članaka	15	9	19	18	17	22	8	21	

Isti postupak prikupljanja podataka primijenjen je na preostala dva časopisa koja ulaze u analizu. Budući da časopisi *Progress in Materials science* i Tehnički Vjesnik izlaze dosta rjeđe od gore navedeno časopisa podatke nije bilo potrebno dodatno sortirati u tablice već su svi podaci bili dovoljno pregledni i sa samog eksela. Kako ovi časopisi nisu imali veliku količinu podataka to nam je pružilo mogućnost da bar za jedan časopisa prikupimo podatke za više godina, ovako se moglo direktno izračunati faktor odjeka za promatrane časopise bez potrebe da u svrhu proračuna uzimamo dodatne podatke iz WoS-ove baze kako bi izračunali faktor odjeka. Za časopis *Progress in Materials Science* prikupljeni su podaci za pet godina, a za časopis Tehnički vjesnik za godinu dana. Razlog zašto je za časopis Tehnički vjesnik prikupljeno podataka samo za godinu dana je u tome što podaci za ovu prikupljenu godinu već na očigled moglo vidjeti da nema značajnijih promjena iz godine u godinu. Na slikama 11-12. Možemo vidjeti podatke za preostala dva časopisa.

Vremenski period koji je bio potreban za prikupljanje podataka za preostala dva časopisa je oko 15 sati. U ovo vrijeme naravno i ulazi vrijeme provjere podataka i usporedbe sa časopisom dali su podaci ispravni tj, dali razredi citata odgovaraju broju članaka u časopisu.

	A God. 2011.	B God. 2010.	C God. 2009.	D God. 2008.	E God. 2007.
1					
2					
3	88	39	158	262	272
4	4	12	25	81	42
5	14	49	71	113	13
6	109	33	103	37	27
7	10	89	92	56	14
8	5	31	20	39	14
9	61	24	39	21	21
10	7	82	248	89	35
11	2	0	71	72	3
12	7	60	27	14	6
13	14	84	65	382	13
14	109	55	40	258	9
15	10	31	49	22	6
16	7		1	55	42
17	0		21		2
18	1		8		76
19	1		23		243
20	4		26		76
21	3		14		233
22	3		15		191
23	29		9		125
24	7		21		59
25	143		64		135
26			31		113
27					328

Slika 11. Podaci citata časopisa Progress in Material Science

B Vol 17. No. 1.	C Vol 17. No. 2.	D Vol. No. 3.	E Vol. No. 4.
0	1	0	0
0	0	0	3
0	1	0	0
0	2	0	0
1	0	0	1
0	0	1	0
1	1	1	1
1	0	0	0
0	0	0	0
2	0	0	2
1	0	2	7
1	1	0	1
2	1	1	0
0	7	2	0
2	0	0	0
2	1	0	0
		2	0
		0	1
		2	0
			1
			0

Slika 12. Podaci citata časopisa Tehnički Vjesnik

4. ANALIZA CITATA I NJIHOVA USPOREDBA SA FAKTOROM ODJEKA

Svrha objavljivanja rezultata istraživanja je da ih auditorij kojemu su namijenjeni pročita i upotrijebi, iskoristi u dalnjem istraživanju. Svakom znanstveniku je priznanje u činjenici da je njegov rad netko od kolega uočio, smatrao ga relevantnim i pozvao se na njega kroz citate. Znati tko je pročitao određeni rad i je li i kakav je utjecaj određeni rad imao na čitateljstvo kojemu je namijenjen, vrlo je važno za znanstvenike koji su to istraživanje obavili, kao i za ljudе koji te radove vrednuju. Koliko je neki rad zaista korišten i u kojoj je mjeri utjecao na ostale znanstvenike, za sada je vrlo teško utvrditi, jer se radi o subjektivnim utjecajima na pojedine znanstvenike. Je li neki rad čitan moguće je u osnovi provjeriti na dva načina, iako niti jedan od njih nije sasvim pouzdan. Prvi način je da se prati korištenost časopisa u knjižnicama odnosno da se prati njihovo korištenje u električnom obliku. Stopa citiranosti se sve više koristi kao procjena utjecaja publikacije znanstvenika, institucije ili zemlje na znanstvenu zajednicu. Postoje mnoge institucije koje koriste bibliometrijske pokazatelje za usmjeravanje istraživačke politike, za zapošljavanje ili za unapređenje istraživača. S obzirom na važnost koju nosi brojanje citata danas, cilj ovog rada je predstaviti kako se citati distribuiraju unutar znanstvenog područja i odrediti ovisnost citiranosti o značajkama koje članak sadrži. Analiza citata se koristi i koristila se za procjenu važnosti znanstvene publikacije, cilj ovakvog načina procjenjivanja je da pomoću citiranja od strane drugih znanstvenika možemo procijeniti da li je određeni znanstveni rad utjecajan u znanstvenoj ili je manje utjecajan u znanstvenoj zajednici, ovakav sistem dobiva još više na važnosti kada ga promatramo na globalnom nivou. Pretpostavljajući da je broj citata povezan sa znanstvenom kvalitetom, danas se on koristi pri donošenju odluka financiranja znanstvenog projekta, povišicama, pri zapošljavanju znanstvenika, kao i za procjenu znanstvenih rezultata kojeg su postigle zemlje. Mnogo godina WoS je bio jedini izvor indeksiranih citata, ali razvojem tehnologija baza danas tu mogućnost posjeduju i druge baze podataka. Ovo pridonosi proširenju primjenjivosti bibliometrijskih analiza na specijalizirana područja i područja manje zastupljena u sveobuhvatnim bazama kao što su WoS i Scopus.

Zabilježeno je nekoliko pokušaja u literaturi za opisivanjem distribucije citata. Distribucija zakona snage je sugerirana od (Naranan, 1971; Seglen, 1992), ali ni jedan zadovoljavajući teoretski model ovakve distribucije citata za sada postoji. U kasnim osamdesetim grupa znanstvenika iz Budimpešte (Glänsel, Schubert, Telcs, Braun), koristili su Waring-ovu

distribuciju za opisivanje bibliometrijske produktivnosti. Sichel (1992) je predložio troparametarsku generaliziranu invertnu Gaussian Poisson distribuciju kao zadovoljavajući matematički model za promatranje raspodjele broja referenci u dokumentu i za ostala bibliometrijska svojstva. Još ne tako davno, Van Raan (2001) je predložio proces natjecanja u dva koraka koji vodi ka modificiranoj Basel funkciji distribucije. Radicchi, Fortunato, i Castellano (2008) koristili su longnormal distribucijsku funkciju kako bi opisali podatke 14 ispitanih skupina od 200 ponuđenih u WoS-u. Uglavnom s dobrim rezultatima za godinu 1999, ako izostavimo repove visoke i niske citiranosti. Bornmann and Daniel (2009), proučavali su distribuciju stope citiranosti. Radichijev relativni indikator c_f i z -scores (koji su dugo korišteni u psihološkim testiranjima za normalizaciju rezultata testa) za odbacivanje ili prihvaćanje rukopisa (koji su objavljeni drugdje) od *Angewandte Chemie International Edition*. Rezultati su pokazivali da z -scores su prikladniji od c_f vrijednosti za usporedbe citiranosti različitih disciplina. Količina citiranosti rada može biti izazvana od mnogo faktora, koji nisu usko vezani za znanstveni sadržaj rada. Kultura citiranja u disciplini sigurno ima makro efekt, ali manja je vjerojatnost da će ostali faktori biti važni. Bornmann i Daniel (2008a) napravili su recenziju studija o tome kakvo je ponašanje znanstvenika pri citiranju, kako bi se utvrdilo koji faktori navode znanstvenike da citiraju ostale radove. Autori se natječe kako bi objavili svoje radove u najboljim časopisima vjerujući kako će to povećati njihov utjecaj u polju kojim se bave, ali adresa ustanove koja je financirala autora također može biti bitna. Citiranje između znanstvenika znatno se razlikuje od polja do polja, a samim time i broj citata može biti vrlo različit. Radicchi i suradnici su procijenili prosječnu stopu citiranosti za neke od kategorija koje se koriste u JCR-u, kako bi pokazali koliko varira od discipline do discipline. Postoje i druge varijable koje su zanimljive karakteristike publikacije, kao što su: broj koautora, broj adresa, broj stranica, broj referenci i faktor odjeka časopisa. Glanzel and Thijs (2004) su ukazali na to da prosječna citiranost članka u biomedicinskom istraživanju, kemiji i matematici raste sa brojem koautora, a posebno je tu istaknuta citiranost od stranih znanstvenika. Leimu and Koricheva (2005) napravili su istraživanje nad 53 časopisa koja se bave ekologijom, kako bi zaključili da članci koji imaju 4 koautora imaju veću prosječnu citiranost nego časopisi sa manje koautora. Pokazalo se da znanstvenici koji su spremni na suradnju, produciraju bolje rezultate samim time i veći faktor odjeka. Međutim, Herbertz (1995) ne pronalazi korelaciju između broja adresa i prosjeka citiranosti publikacija iz brojnih istraživačkih instituta u molekularnoj biologiji. Utjecaj duljine rada na citiranost analiziran je od Peters-a i van Raan-a (1994), koji su u svoje istraživanje uključili set od 226 radova napisanih od 18 internacionalno poznatih znanstvenika u polju kemijskog inženjerstva.

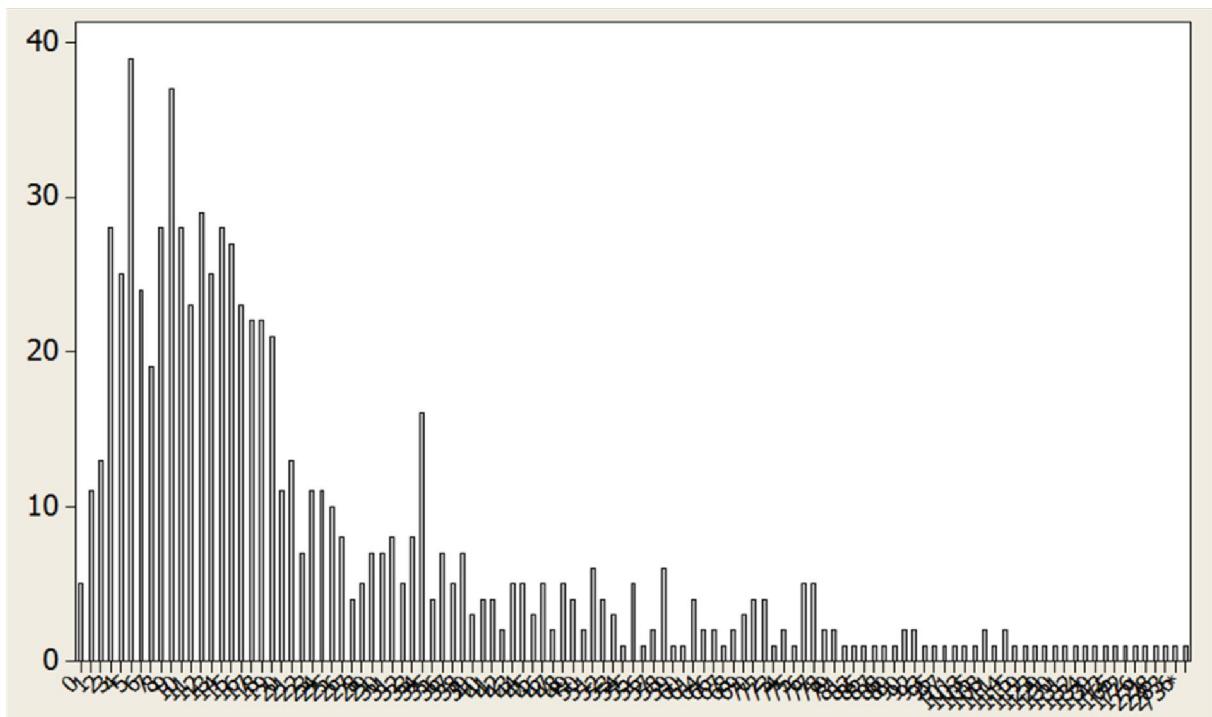
Rezultati su pokazali da ima povezanosti između duljine članka i njegovog utjecaja kod kraćih članaka, ali ne i kod dužih članaka. Bornmann i Daniel (2007) proveli su istraživanje nad 96 prijavljenih članaka, za istraživanje u biomedicini koje je financirala internacionalna fondacija . Rezultati su pokazali da s povećanjem stranica može doći do povećanja citiranosti. Peters i van Raan (1994) također su pokazali da broj referenci korelira sa povećanjem utjecaja. Odnosi između faktora odjeka časopisa i prosječne citiranosti članka u istom časopisu detaljno je studirana od Seglena (1994) za publikacijsku listu dobivenu od 16 viših znanstvenika poznatog Norveškog biomedicinskog instituta za istraživanje. Za ove liste je našao da postoji slaba korelacija između citiranosti članka i utjecaja časopisa za cijelu populaciju članaka, ali grupiranje članaka u definirane skupine utjecaja časopisa izgleda da je povećalo korelaciju. Druge studije pokazuju da može postojati povezanost između prosječne stope citata i faktora odjeka. Boyack i Klavans (2005) su odabrali skup podataka kombinirajući SCIE / SSCI (Web of Science) za godine 2002. i 2003., a utvrđeno je da postoji tendencija povećavanja citiranosti kako faktor odjeka časopisa raste. Opravданje za korištenje ovog parametra je u tome da je krajnji cilj ovog istraživanja pronaći mehanizam predviđanja koji bi bio bolji za računanje budućeg utjecaja trenutačnih članaka. Ova studija predstavljaju vrlo jednostavan model distribucije citata, gdje se prepostavlja da su citati nasumično podijeljeni između članaka organiziranih u razrede eksponencijalno padajućeg utjecaja. Ovo je naravno gruba aproksimacija, jer vjerujemo da se radovi mogu nekako razlikovati po svojoj 'unutarnjoj kvaliteti' ali svi znamo da ne postoji način procjene a priori ove "kvalitete" [1,4].

4.1. Grafički prikaz podataka i njihova analiza

U ovom dijelu rada prikazat ćemo kako se podaci ponašaju u odabrana tri časopisa. Na temelj tih podataka pokušat će se utvrditi i opisati dali se podaci ponašaju unutar neke od nama poznatih distribucija. Osim prikupljenih podataka o citiranosti članaka prikupili su se i podaci o tome koliko je koji članak imao referenci. Na temelju podataka o referencama pokušat će se utvrditi dali postoji povezanost između broja referenci članka i njegove citiranosti te u konačnici, dali se ti podaci reflektiraju na faktor odjeka. Nadalje spomenut će se još neki parametri koji opisuju standardni članak koje možemo vidjeti na slici 9. kao što su broj koautora i broj adresa tj. znanstvenih institucija koje su bile uključene u izradu članka.

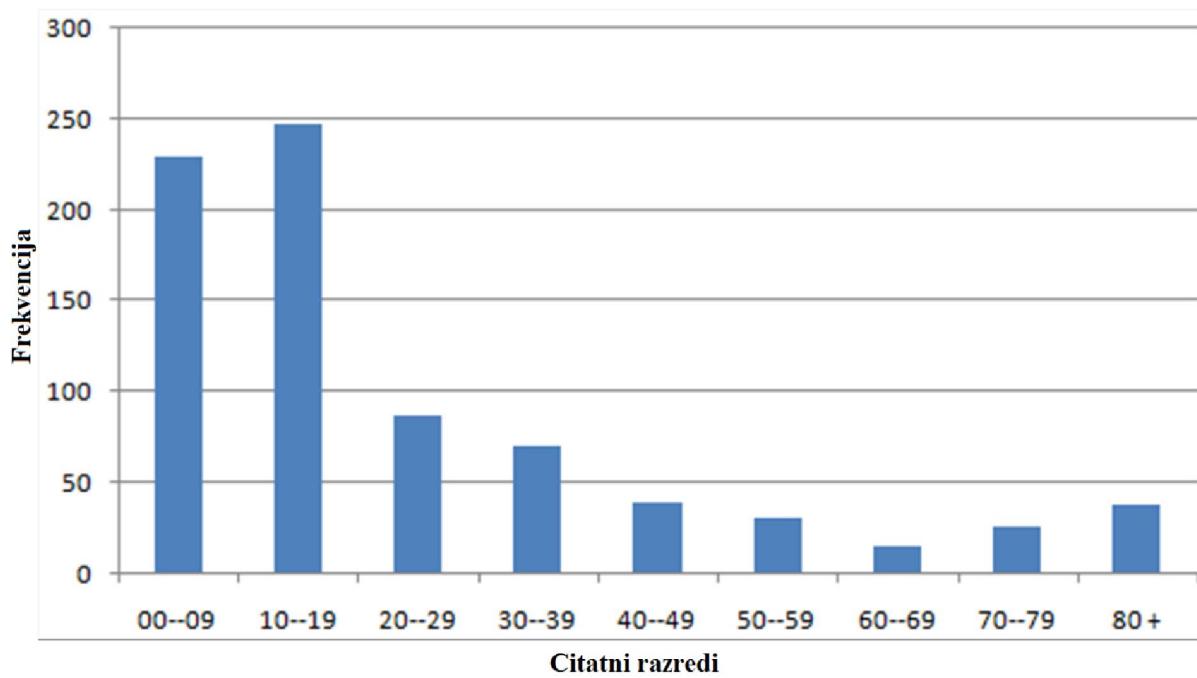
4.1.1. Časopis *Advaced Materials*

Časopis *Advanced Materials* je tjedni recenzirani znanstveni časopis koji pokriva sva znanstvena područja koje se bave istraživanjima o materijalima. Članci su uglavnom ili pregledni radovi ili originalni znanstveni radovi. U časopisu se objavljuju radovi koji pokrivaju područja: kemije, fizike, nano tehnologije, keramike, metalurgije i bio materijala. *Advaced Materials* je Njemački časopis pisan na engleskom govornom području i spada u top europske tehničke časopise. U prosjeku objavljuje oko 16 članka po izdanju, ako uzmem da se izdaje na tjedno bazi isпадa da časopis objavi godišnje oko 770 članaka, što bi svrstalo ovaj



Graf 1. Distribucija citata časopisa *Advaced Materials*

časopis u tip časopisa koji vrlo često objavljuje. Zašto se spominje učestalost objavljivanja, iz razloga što se već utvrdilo da se časopisi koji često objavljuju uglavnom objavljuju članke tipa pisma ili originalne rade, dok je manja mogućnost da će ovakav časopis objavljavati pregledne članke budući da su ovakvi članci veći od prosječnog članka i iziskuju više vremena od ostala dva tipa, samim time se i rjeđe objavljuju. Za potrebe analize prikupljeno je 783 članka što se za 7 članaka razlikuje od WoS-ove baze iz koje je su prikupljeni podaci. Ova razlika može se objasniti sa nekoliko detalja, a oni su da prilikom prikupljana podataka se uzeo ispravak nekog prijašnjeg članka koji je citabilan, ali ne bi smio ulaziti u citatnu analizu, a ni u proračun faktora odjeka. Ako jedan ovakav ispravak članka dobije recimo 7 citata teško ga je prepoznati u hrpi članaka jer ispravci rijetko dobivaju citate. Mora se uzeti u obzir da postoji vrlo mala mogućnost da je WoS pogriješio u brojanju iako ovaj časopis spada u top časopise tako da se posebna pozornost daje pri pregledu podataka ovakvog časopisa. Uredništvo časopisa *Advaced Materijals* neće se žaliti što imaju manji broj članaka na isti broj citata jer na ovaj način imaju nešto veći faktor odjeka budući da je faktor odjeka prosječna veličina kroz dvije godine. Uglavnom za potrebe ovog rada neće se značajna greška dogoditi zbog ove razlike. Na grafu 1. možemo vidjeti raspodjelu citata časopisa *Advaced Materials* za 2010. godinu. Može se primjetiti da graf ovlike količine podataka teško je smjestiti u jedan A4 format papira, zato je izrađen i pregledniji graf u kojem su citati formirani u razrede po deset.



Graf 2. Prikaz distribucije citata u razredima po deset

U slučaju ovog časopisa odmah se primjećuje da prva dva stupca prezentiraju veći dio članaka budući da je frekventnost članaka koji spada u prozor od 0-20 prikupljenih citata po članku najveća, čak 57,2 % svih članaka koji su objavljeni u 2010. godini, što potvrđuje Bradfordovu tezu da mali broj članaka dobiva većinu citata koje časopis dobije. U tablici 7. možemo vidjeti prikaz vrijednosti standardnih statističkih parametara za prikupljene podatke koji su se dobili pomoću programa Minitab 16.

Tablica 7. Standardni statistički podaci prikupljenog uzorka za časopis *Advanced Materials*

Varijabla	N	Aritm. sred.	SE St.dev	St. dev.	Var.	Suma	Q1	Median	Q3	Maks.
C1	783	26,73	1,14	39,37	1549,88	20933	9	16	33	736

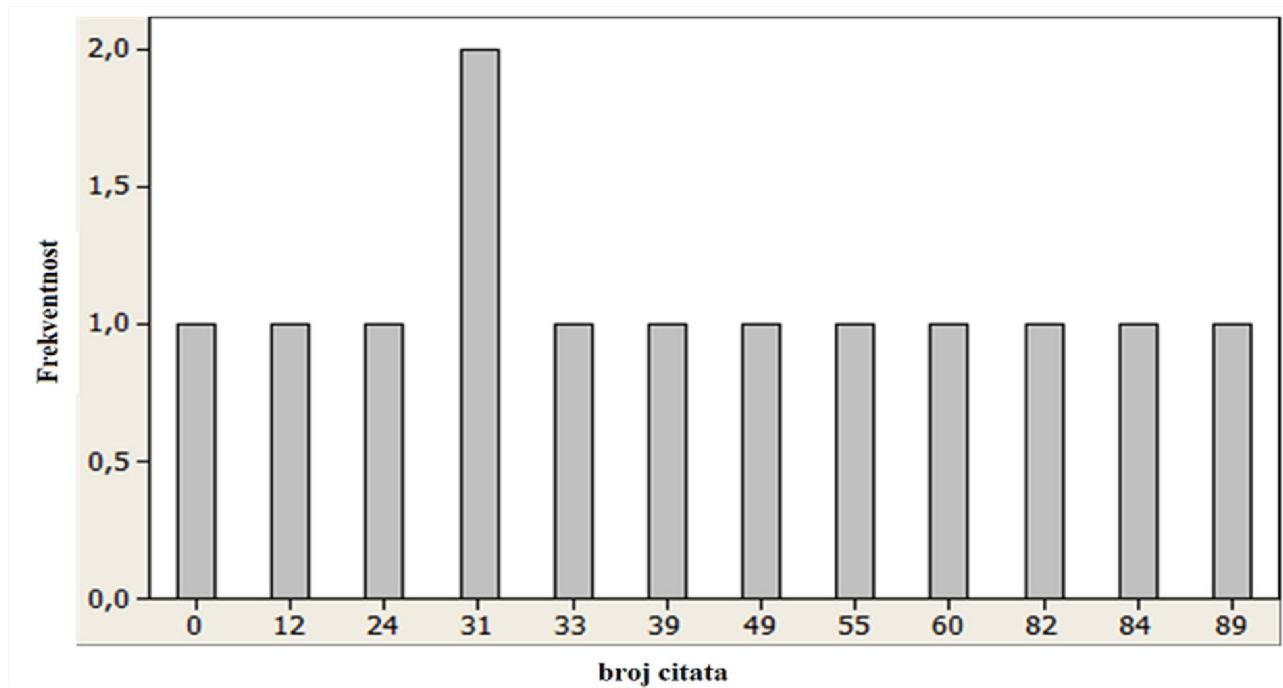
Dobiveni rezultati govore da je članak u prosjeku citiran 26,73 puta i da se medijan svih citata nalazi na vrijednosti od 16 citata. Ukupna suma citata u prvom mjesecu 2013. godine iznosila je 20933 citata na članke objavljene 2010. godine. Ako bi se pomnožilo frekvencije razreda sa srednjom vrijednošću razreda dobivaju se aproksimativne vrijednosti ukupne citiranosti tog razreda, ove vrijednosti mogu se vidjeti u tablici 8. Tek kada su se zbrojili razrede citata od 40 do 80 + prešla se granicu od 50% točnije 54,64 % ukupnih citata koje je su članci dobili od 2010 do 2013, postotak članaka koji to ostvaruje je oko 19 % od ukupnog broja izdanih članaka. Ovo upućuje na to da je većina citata koncentrirana u manjem broju članaka.

Tablica 8. Ukupna citiranost razreda citata

Raspont broja citat	Frekvencije citata	Ukupan broj citata
0--9	230	$230 \times 5 = 1150$
10--19	248	$248 \times 15 = 3720$
20--29	87	$87 \times 25 = 2175$
30--39	70	$70 \times 35 = 2450$
40--49	39	$39 \times 45 = 1755$
50--59	31	$31 \times 55 = 1705$
60--69	15	$15 \times 65 = 975$
70--79	26	$26 \times 75 = 1950$
80 +	38	$20933 - 15880 = 5053$

4.1.2. Časopis *Progress in Materials Science*

Časopis *Progress in Materials Science* objavljuje autoritativna mišljenja o najnovijim dostignućima u znanosti materijala i njihovom iskorištavanju u inženjerstvu. Časopis se objavljuje na engleskom jeziku i spada u top časopise koji se bave znanstvenom granom materijala. Naglasak je stavljen na temeljnim aspektima predmeta, posebice onim koji se tiču mikrostruktura i kako mikrostruktura definira svojstva materijala (mehanička, kemijska, magnetska, električna i optička) uključujući i elektroničke, atomističke, prirode kondenzirane faze, na njihovu mikrostrukturu, te odnos između njihove strukture i svojstava. Časopis objavljuje pregledne članke koji su uglavnom duži od originalnih znanstvenih radova i imaju veći broj referenci. Prema JCR-u svaki članak koji ima više od 100 referenci vodi se kao pregledni članak. Ovakvi radovi dijele se u tri skupine: 1) one čiji autori, kao eksperti za to područje, donose kritičke preglede vrednovanja doprinosa određenom istraživačkom problemu, 2) one koji donose pregled literature koja se odnosi na činjenice i rezultate vezane uz neki istraživački problem, a manje stavove autora koji ih pišu, te 3) one koji donose godišnje preglede literature kojima je cilj informirati zainteresiranu javnost o određenom problemu u tom razdoblju. U prosjeku se objavljuje oko 20 članaka na godinu iako broj članaka znatno varira od godine do godine tako recimo za 2010. godine objavljeno je 13 članaka, dok je godinu poslijе objavljeno 23 članka, što bi se moglo reći da je velika razlika između dvije godine. Podaci koji su obrađeni za ovaj časopis odnose se na 2010. godinu. Grafički prikaz podataka možemo vidjeti na grafu 3.



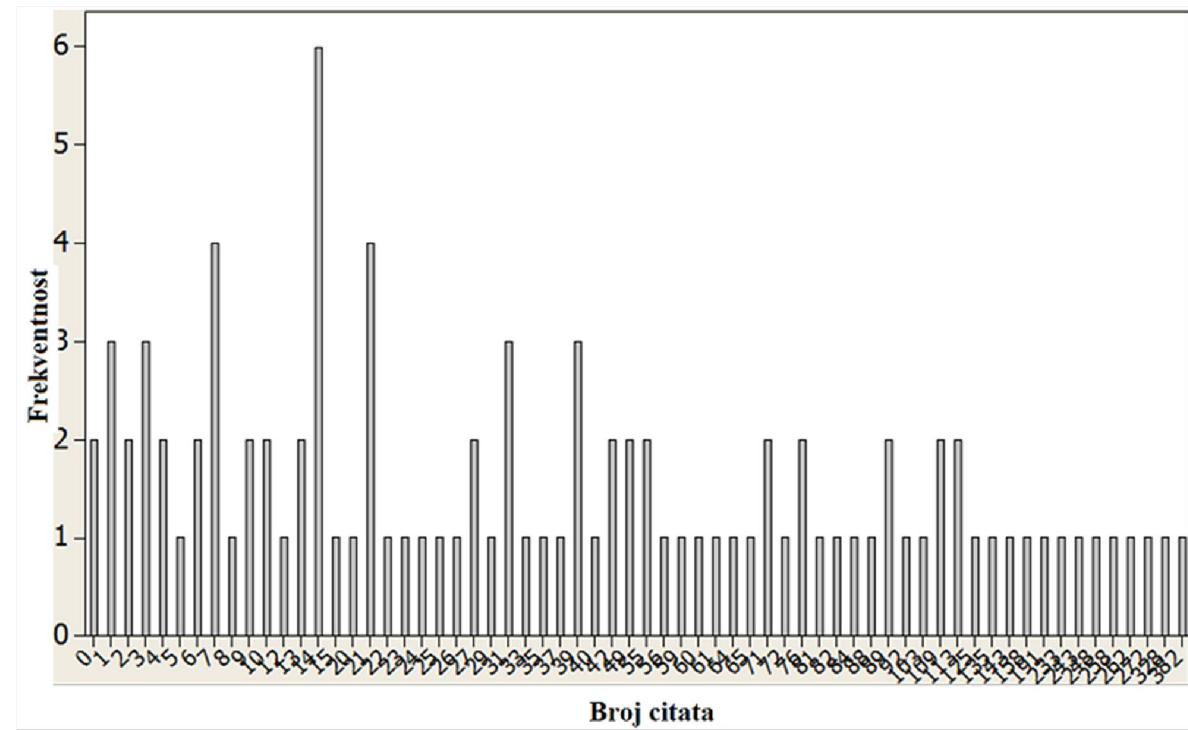
Graf 3. Distribucija citata časopisa *Progress in Materials Sciences*

Budući da je u 2010. godini u objavljeno samo 13 članaka u časopisu *Progress in Materials Science* grafički prikaz citiranosti članaka izgleda dosta jednolično. Iz grafa se može vidjeti da je raspon citata od 0 - 89, te da su dva članka dobila po 31 citat, a svi ostali su različito citirani (0,12,24,33,39,49,55,60,88,84,89). U tablici 9. može se vidjeti prikaz vrijednosti standardnih statističkih parametara za prikupljene podatke koji su se dobili pomoću programa Minitab 16.

Tablica 9. Standardni statistički podaci prikupljenog uzorka za časopis Progress in Materials Science

Varijabla	N	Aritmet. sred.	SE St.dev	St. dev.	Suma	Q1	Median	Q3	Maks.
C1	13	45,31	7,72	27,83	589	27,50	39,00	71	89

Iz podataka možemo očitati da je ukupan zbroj citata akumuliranih od objavljinjanja 2010. do 2013. godine iznosi 589 citata. Prosječna citiranost po članku je 45,31 citat i medijan iznosi 39 citata. Najcitiraniji članak imao je 89 citata, a najslabije citirani članak nije uopće bio citiran, što je dosta čudno za časopis ovakvog statusa. Budući da se ne mogu izvući neki korisniji podaci iz prijašnjeg grafa, prikazat će se podaci za petogodišnje razdoblje časopisa tj. na grafu 4. prikaz će se citiranosti časopisa od 2007. do 2011. godine.



Graf 4. Prikaz petogodišnje citiranosti članaka časopisa Progress in Materials Science

U tablici 10. Možemo vidjeti osnovne statističke parametre za petogodišnje razdoblje (2007-2011) časopisa Progress in Materials Science

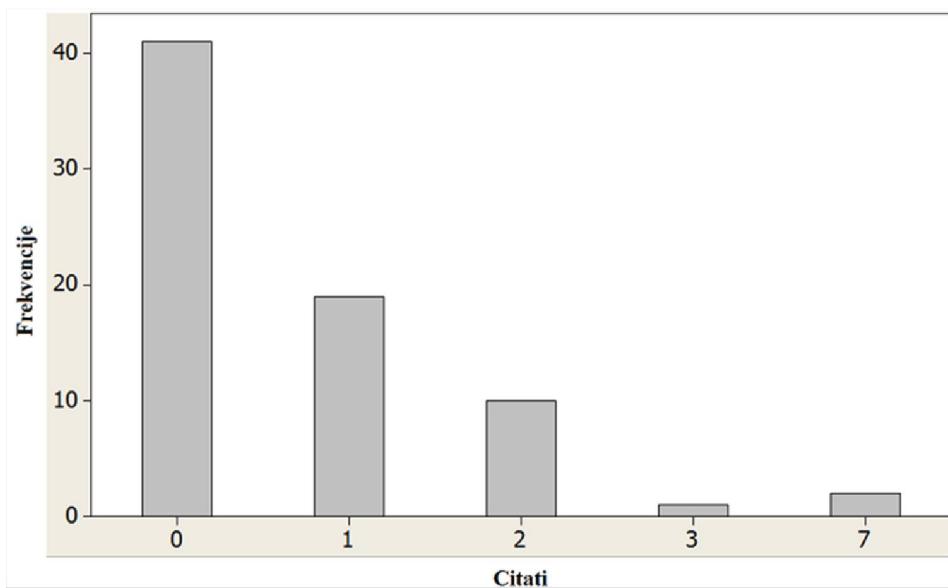
Tablica 10. Osnovni statistički parametri časopisa Progress in Materials science (2007-2011)

Variable	N	Mean	StDev	Variance	Sum	Q1	Median	Q3	Maximum
C1	99	61,28	76,93	5918,31	6067,00	12,00	31,00	81,00	382,00

Raspon citata koje su članci dobili u promatranom vremenskom razdoblju kreće se od 0 do 382 citata. I kod ovog kao i kod prijašnje opisanog časopisa primjećuje se koncentriranost slabije citiranih članaka na lijevom dijelu grafa. Ukupan broj članaka u petogodišnjem razdoblju je 99 članka. Ako uzmemo raspon od 0-25 citata i prebroje se članci u tom rasponu, dolazimo do brojke od 43 članka, što u postocima iznosi 43 % od ukupnog broja članaka. Prosječna citiranost iznosi 61,3 citata po članku, a medijan iznosi 31. Povećanju prosječne citiranosti u odnosu na 2010. godinu pridonijeli su članci iz ranijih godina (2007,2008) jer ti članci su imali veći vremenski period da prikupe citate. Ako se prisjetimo slike 4. na slici se može vidjeti da pregledni članci najveću citiranost postižu 5-6 godina nakon objave, što objašnjava ovo povećanje citiranosti od 16 citata po članku.

4.1.3. Časopis Tehnički Vjesnik

Časopis Tehnički Vjesnik - *Technical Gazette* objavljuje znanstvene i stručne rade iz područja strojarstva, elektrotehnike i građevinarstva, a također i iz njihovih graničnih područja. Prvo izdanje izdano je 1994. godine. Izdaje se 6 puta godišnje i u prosjeku po izdanju izdaje 19 članka. Objavljeni članci objavljaju se na Hrvatskom i Engleskom jeziku. Na grafu 5. prikazat će se prikupljeni citati članaka časopisa od objavljivanja 2010. godine do vremena prikupljanja, početka 2013. godine.

**Graf 5. Distribucija citata časopisa Tehnički Vjesnik**

Nažalost na grafikonu se vidi vrlo loša citiranost Hrvatskog časopisa 41 članak od ukupno 73 uopće nisu citirani, što bi u postocima iznosilo da 56 % članaka u časopisu nisu citirani u 3 godine otkad teče njihovo objavlјivanje. Devetnaest članaka citirano je jednom, deset članaka citirano je dvaput, jedan triput i dva članka su dobila 7 citata. Citati ovih dvaju članaka pokrivaju 25 % ukupne citiranosti časopisa. Mora se napomenuti da je dio tih citata kod ova dva članka dobiven samocitiranjem. Ukupan broj citata u razdoblju od 2010. do 2013. godine iznosio je 56 citata. Prosječna citiranost je 0,767 citata po članku, medijan je na nuli.

4.2 Usporedba citata triju časopisa

Usporedbom grafova i podataka koji su proizašli iz statističke analize grafova dobili su se sljedeći podaci koje možemo vidjeti u tablici 11.

Tablica 11. Usporedba podataka triju promatranih časopisa

Naslov časopisa	Tip članaka	Br. objavljenih članaka	Prosječna citiranost po članku	Uk. zbroj citata članaka	Faktor odjeka	St. Devijacija
Advanced Materials	Originalni znanstveni radovi	783	26,73	20933	13,877	39,37
Progress in Materials Science	Pregledni radovi	13	45,31	589	18,216	27,83
Tehnički Vjesnik	Originalni znanstveni radovi	73	0,767	56	0,347	1,307

Ono što definira faktor odjeka časopisa je omjer citata dobivenih u promatranoj godini na članke objavljene u prijašnje dvije godine i broja radova objavljenih u te dvije godine. Moglo bi se zaključiti da je faktor odjeka prosječna citiranost časopisa gledano iz promatrane godine na prijašnje dvije godine. Ako je ovo zaista tako prosječna citiranost članaka časopisa nakon tri godine trebala bi biti u korelaciji sa faktorom odjeka budući da su rijetke promjene u kulturi citiranja. Podatak koji bi mogao utjecati na ovo je tip članka koji objavljuje časopis. Iz tablice možemo vidjeti da časopisi *Advaced Materials* i Tehnički vjesnik objavljuju originalne znanstvene radove, dok časopis *Progress in Material Science* objavljuje pregledne radove. Neke od razlika između preglednih radova i originalnih znanstvenih radova su: broj koautora, broju referenci, broj stranica, broj adresa, veća kontrola kvalitete rada. Svi ovi podaci definiraju jedan članak i u prosjeku pregledni članci ih imaju više. Nadalje, razlika između ovih časopisa je u broju objavljenih članaka u godini, vidljivo je da dva časopisa koji objavljaju originalne znanstvene radove puno više objavljaju nego časopis koji objavljuje

pregledne radove. Budući da časopisi koji objavljaju originalne znanstvene rade više objavljaju radova, vjerojatnost da će objaviti loš rad je veća nego kod drugog tipa časopisa, zato na usporedbi grafova možemo vidjeti da je koncentracija lošijih članaka veća kod časopisa koji objavljaju originalne znanstvene rade što se vrlo dobro može vidjeti na grafovima 1. i 5., gdje je to prikazano na lijevom dijelu grafa. S druge strane, ako časopis objavljuje više rade zar ne bi trebao imati i više dobrih rade, u konačnici da, ali vjerojatnost da će nastati dobar rad je puno manja nego da će nastati loš rad. Što nam potvrđuje rezultate dobivene na grafovima. Veći broj loših rade smanjiće prosječnu citiranost članka što je vidljivo u tablici 10. Iako je ukupna citiranost časopisa *Advanced Materials* 20933 citata u odnosu na časopis *Progress in Materials Science* koji ima ukupnu citiranost 589 citata i njihov odnos objavljenih članaka 783 u časopisu *Advaced Materials* u odnosu na 13 objavljenih u časopisu *Progress in Material Scieces*. Dolazimo do toga da je prosječna citiranost prvog časopisa 26,73, a drugog 45,31. Ako podijelimo prosječnu citiranost članka sa 2 (budući da u proračun faktora odjeka ulaze dvije godine) dobiva se okvirno vrijednosti približne faktora odjeka, okvirno iz razloga što ovisi koliko je druga godina koja ulazi u proračun bila uspješna ili neuspješna (za koju nemamo podatke). Faktor odjeka za časopis *Advanced Materials* za 2011. godinu iznosio je 13,877, dok je za časopis *Progres in Materials Science* iznosio je 18,216. Ako faktor odjeka predstavlja utjecajnost časopisa na znanstvenu zajednicu, postavlja se logično pitanje ne bili 20933 citata trebalo imati veći utjecaj od 589 citata. O nekim nedostacima faktora odjeka govorit će se kasnije u radu.

Izostavljanje Tehničkog Vjesnika iz usporedbe je najviše zbog toga jer nije u užoj konkurenciji ovim dvaju časopisima. Za loš faktor odjeka Hrvatskog časopisa nabrojat će nekoliko mogućih razloga. Nažalost zbog ekonomске krize i lošeg financijskog stanja znanstvenih institucija u Hrvatskoj vrlo malo se ulaže u znanstvene projekte tako da znanstvenici i da imaju znanja ne mogu iskoristiti svoje potencijale. Nadalje, već je poznato da godinama se vrlo malo poduzima po pitanju suradnje znanstvenih institucija i industrije što također pridodaje lošim rezultatima u Hrvatskoj znanosti. Osim financijskih problema tu je i pitanje kulture citiranja. Recimo američki znanstvenici citirajući se međusobno dižu prosječnost citiranja svojih rade oko 30 % u odnosu na ostatak svijeta. Za potrebe ovog rada priupitano je par znanstvenika dali citiraju rade kolega sa istog instituta koji rade u istom području, odgovor je bio da nemaju potrebe kada njihov rad nije direktno povezan. Ovu izjavu moglo bi se protumačiti kao poštena izjava, ali ako u Hrvatskoj želimo povećati faktor

odjeka trebala bi se povećati suradnja između znanstvenika. U konačnici tu je i problem jezične barijere, često se prilikom prijevoda sa Hrvatskog na Engleski znaju izgubiti detalji, osim toga duže treba da se objavi rad što je za članak koji objavljuje popularnu temu kao recimo: solarne ploče ili nova baterijska tehnologija jako bitno, budući da se promjene na ovim područjima brzo dešavaju.

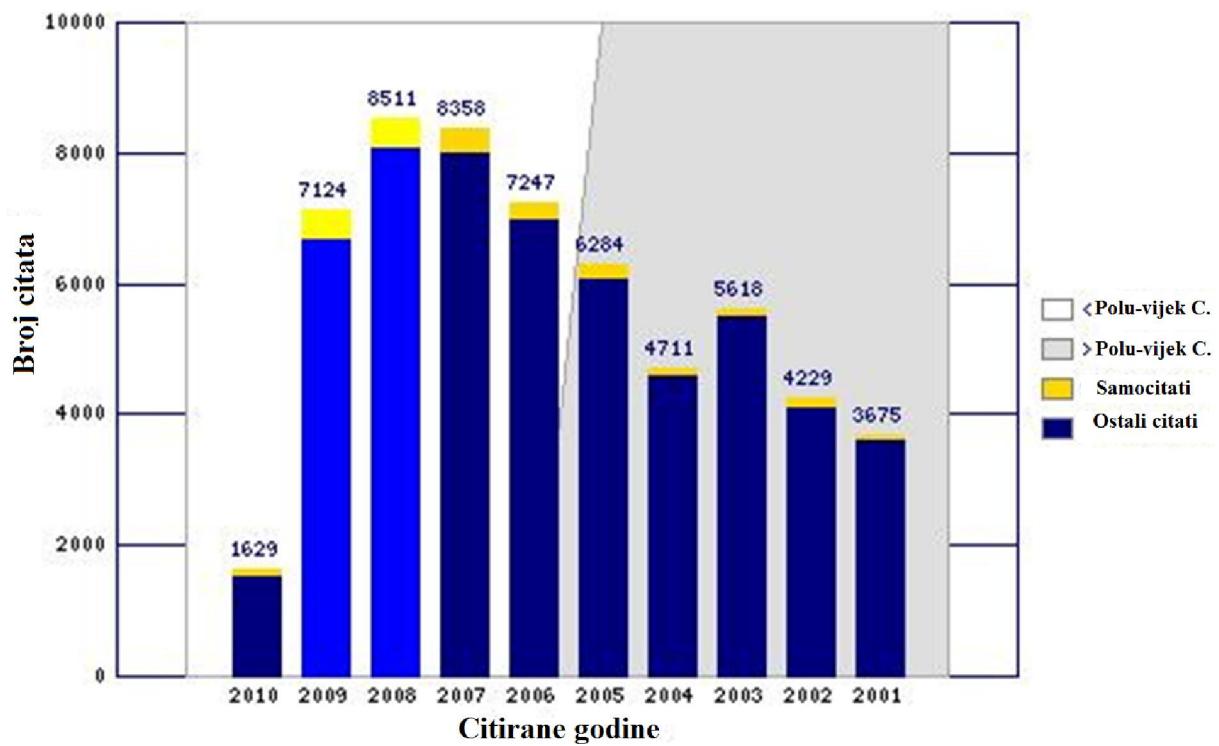
4.3. Samocitiranost

Samocitiranost se obično definira kao oblik citiranosti u kojoj citirani dokument i onaj koji ga citira ima najmanje jednog zajedničkog autora. Ako su tri autora A i B i C koautori na radu P1, koji je dalje citiran u radu P2, a autori su mu B i C i D i E, tada rad P1 postaje citatom za autora A, a samocitatom za autore B i C (Debackere i Glanzel, 2004). Termin samocitata može se koristiti i za ostale citatne veze, npr. samocitiranost časopisa ili institucionalna samocitiranost. U vrlo restriktivnoj definiciji samocitiranosti, pod ovim pojmom se podrazumijevaju samo slučajevi kada se radi o prvom autoru, koji citira sebe i svoj rad u kojem je prvi autor (Aksnes, 2003).

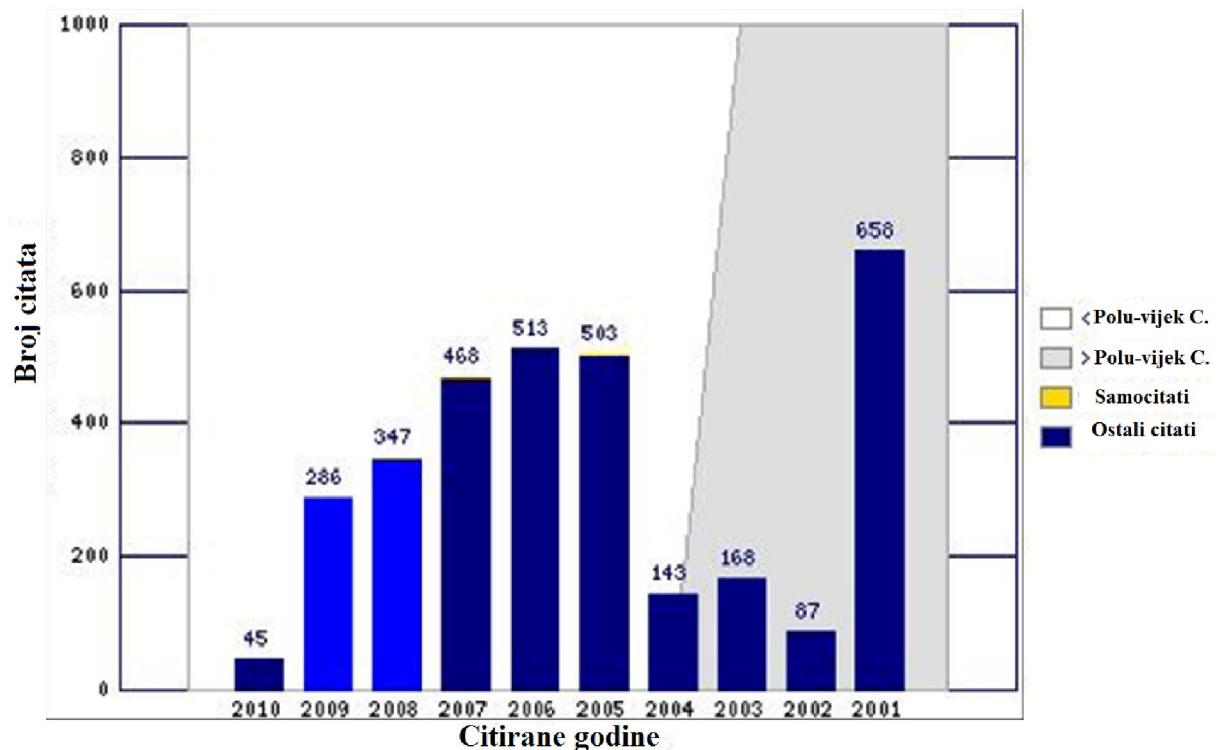
Pojava samocitiranosti se različito tumači ovisno o autorima i područjima. Odnosno, tretira ju se kao dvosmisleni fenomen. Neki autori smatraju sasvim prirodnim da se u određenim situacijama autori pozivaju na svoja prethodna istraživanja i rezultate. Motivi za samocitiranje su različiti i kompleksni, uključuju psihološke čimbenike koji su povezani i s iskustvom kao i sa samopouzdanjem. Dio komentara znanstvenika o samocitatima, koje je istraživao Hyland (2003) mogli bi se svesti na to da citiranjem vlastitih radova autor pokazuje poznavanje područja, odnosno koliko je taj duboko involviran u određenu problematiku. To pokazuje da autor zna o čemu govori i da znanstvenoj zajednici ima što reći. Pozicioniranjem sebe unutar citiranog korpusa, autor povećava svoj autoritet.

S druge strane dio autora citira sam sebe iz egocentričnih pobuda kako bi sam sebe učinio vidljivijim i pokazao svoj autoritet. Međutim, broj samocitata je ograničen, u slučaju kada se radi o samo jednom autoru, i ovaj aspekt može imati samo djelomičan učinak.

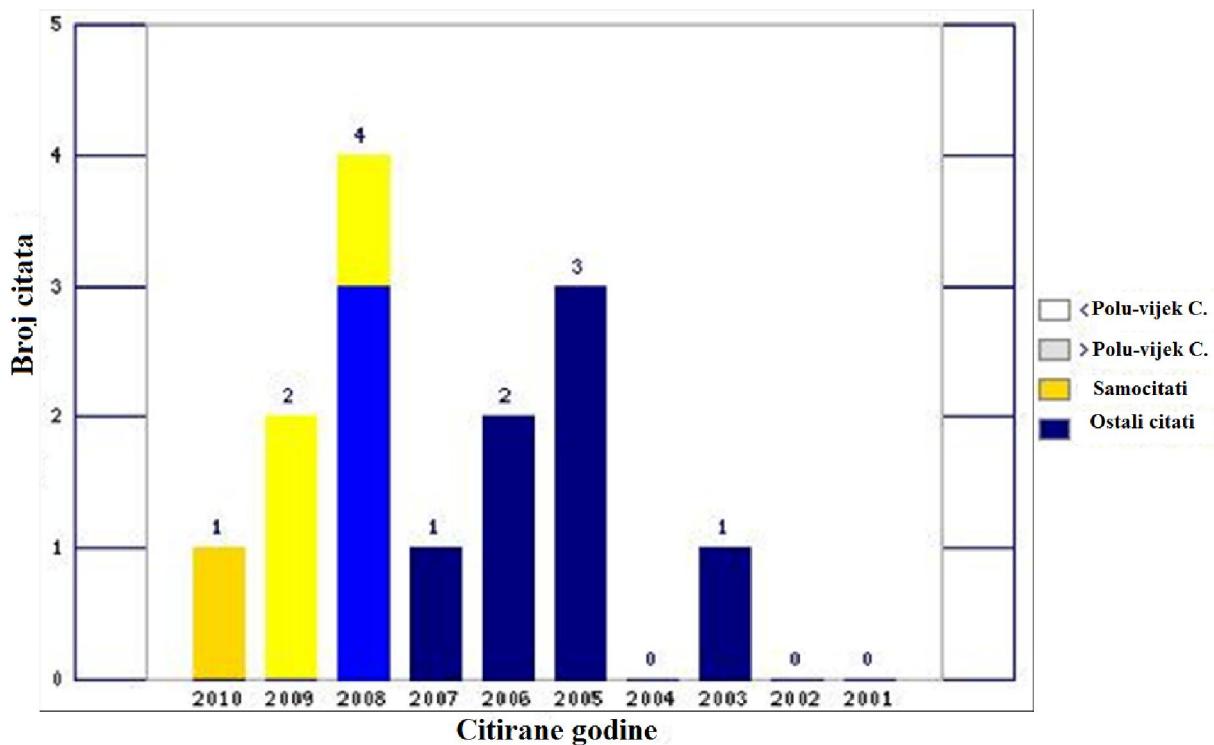
Aspekt samocitiranosti postaje problematičan kada se citiranost uzima kao pokazatelj vrednovanja nečijeg rada, naročito fakulteta, sveučilišta ili instituta. Može se dogoditi da pojedino sveučilište ili institut učestalije citira radove svojih kolega i time, kroz oblik samocitiranosti, na relativno umjetan način podiže razinu citiranosti. Naime, vrednovanjem nečijeg rada kroz broj citata i citatne analize može se dobiti uvid u utjecaj određenog rada na šиру znanstvenu zajednicu. U slučaju velikog broja samocitata ovaj utjecaj može biti upitan [1].



Slika 13. Citiranost časopisa Advanced Materials (po godinama)



Slika 14. Citiranost časopisa Progress in Materials Science (po godinama)



Slika 15. Citiranost časopisa Tehnički Vjesnik (po godinama)

Tablica 12. Utjecaj samo citiranosti na faktor odjeka promatranih triju časopisa (2010 g.)

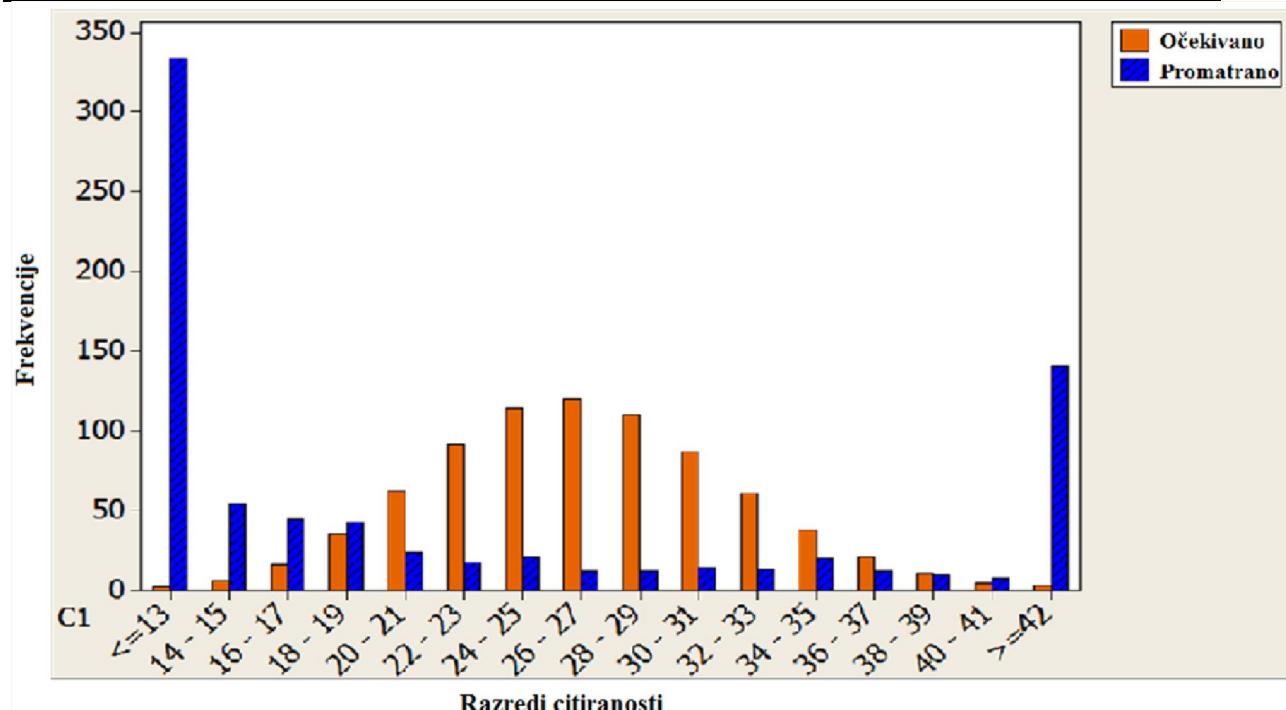
Advanced Materials		Progress in Materials Science		Tehnički Vjesnik	
Uk.broj citata	68115	Uk.broj citata	4660	Uk.broj citata	14
Br. citata korišten u faktoru odjeka	15635	Br. citata korišten u faktoru odjeka	633	Br. citata korišten u faktoru odjeka	6
Faktor odjeka	10,88	Faktor odjeka	16,658	Faktor odjeka	0,083
Samocitati	2518 (3% od 68115)	Samocitati	15 (0% od 4660)	Samocitati	4 (28% od 14)
Samocitati uračunati u faktoru odjeka	897 (5% od 15635)	Samocitati uračunati u faktoru odjeka	2 (0% od 633)	Samocitati uračunati u faktoru odjeka	3 (50% od 6)
Faktor odjeka bez samocitata	10,256	Faktor odjeka bez samocitata	16,605	Faktor odjeka bez samocitata	0,042

U tablici 12. može se vidjeti utjecaj samo citata unutar časopisa na njihove faktore odjeka i koliki bi faktor odjeka bio da nema samo citata. Najmanju promjenu u faktoru odjeka ima časopis *Progress in Materials Science*, zašto je to tako vjerojatno leži u činjenici da časopis

Progress in Materials Science objavljuje najmanji broj radova na godišnjoj razini. Samim time vjerojatnost da će biti citiran unutar samog časopisa je značajno manja nego kod ostala dva časopisa. Kod časopisa Tehnički Vjesnik promjena u faktoru odjeka je najveća, ako bi uklonili samocitati koji su ušli u proračun faktora odjeka, dobio bi se umanjen faktor odjeka časopisa za 50 %, razlog ovome je što ovaj časopis ima puno manji raspon publike. Mora se uzeti u obzir da u Hrvatskoj ima svega nekoliko tehničkih časopisa i da je vjerojatnost da će hrvatski znanstvenik citirati članak iz hrvatskog časopisa puno veća, nego da će strani znanstvenik citirati hrvatski časopis. Kada uzmemu u obzir parametre da ima malo tehničkih časopisa na određeni broj Hrvatskih znanstvenika, dobiva se velika vjerojatnost će se neki članak citirati unutar samog časopisa Tehnički Vjesnik. Časopis *Advanced Materials* imao je 897 samocitata na ukupni broj od 15635 citata uračunat u faktor odjeka, što iznosi oko 5 % od ukupne citiranosti, ako bi oduzeli samocitate iz proračuna faktora odjeka, dobio bi se faktor odjeka od 10,256. Ovo je prihvatljiva brojka samocitata u odnosu na ukupnu citiranost, ako se uzme u obzir da je 777 članaka objavljeno u časopisu Advanced Materials.

4.4. Utvrđivanje moguće distribucije citata

Naše opravdanje za korištenje ovog parametra je u tome da je krajnji cilj ovog istraživanja pronaći mehanizam predviđanja koji bi bio bolji za računanje budućeg utjecaja trenutačnih članaka. Ova studija predstavljaju vrlo jednostavan model distribucije citata, gdje se pretpostavlja da su citati nasumično podijeljeni između članaka organiziranih u razrede eksponencijalno padajućeg utjecaja. Ovo je naravno gruba aproksimacija, jer vjerujemo da se radovi mogu nekako razlikovati po svojoj 'unutarnjoj kvaliteti' ali svi znamo da ne postoji način procjene a priori ove "kvalitete". Za potrebe utvrđivanja distribucije citata odabran je časopis za koji se imalo najviše podataka vjerujući da će se sa ovim časopisom s najvećom točnošću odrediti distribucija podataka budući da je prema broju članaka najveći, te samim time greške u procijeni će biti manje. Da mogli utvrditi koja od postojećih distribucija opisuje ove podatke, potrebno je bilo prikupljene podatke ubaciti u statistički program (budući da bi ručno računanje dugo trajalo), a program koji se za tu svrhu koristio bio je Minitab 16. Podaci koji su korišteni su isti oni iz kojih je kreiran graf 1. časopisa *Advanced Materials*. Kada su podaci ubačeni u program, potrebno je bilo odabrati na koje ćemo razdiobe testirati podatke. Prvu distribuciju koju smo testirali bila je Poissonova distribucija iz razloga što bi bilo logično da članci koji rijetko dobivaju citate (citiranost kao rijedak događaj) mogli ponašati po ovakvoj distribuciji, a i ovakvih članaka ima najviše. Dobiveni rezultati mogu se vidjeti na grafu 6.



Graf 6. Promatrane i dobivene vrijednosti za procjenu prilagodbe Poissnovoj distribuciji

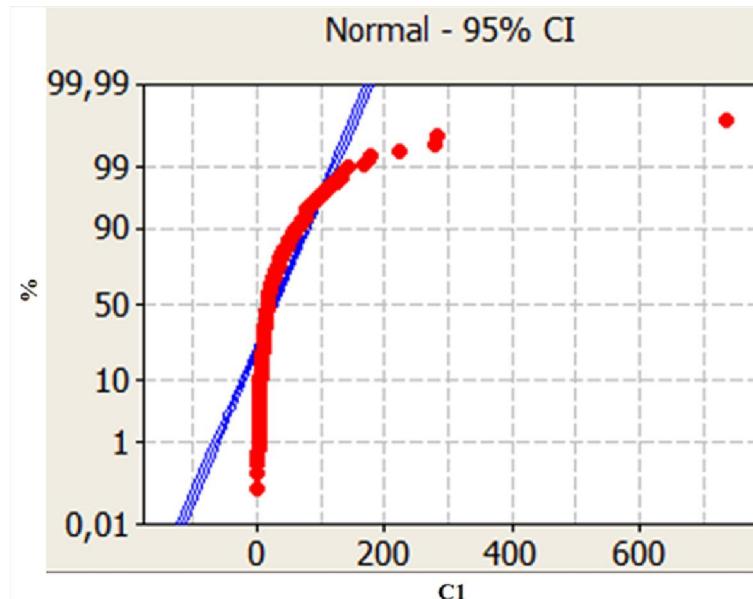
Tablica 13. Procjena prilagodbe podataka Poisson-ovoj distribuciji

Razredi citata	Promatrana	Poisson vjerojatnost	Očekivana
<=13	334	0,002587	2,025
14 - 15	55	0,007454	5,836
16 - 17	45	0,020525	16,071
18 - 19	43	0,044856	35,122
20 - 21	24	0,079671	62,382
22 - 23	18	0,117250	91,807
24 - 25	21	0,145286	113,759
26 - 27	12	0,153638	120,299
28 - 29	12	0,140266	109,828
30 - 31	15	0,111666	87,434
32 - 33	13	0,078196	61,228
34 - 35	20	0,048538	38,005
36 - 37	12	0,026888	21,054
38 - 39	10	0,013374	10,472
40 - 41	8	0,006006	4,703
>=42	141	0,003798	2,974

Na grafu iznad možemo vidjeti da očekivane i promatrane vrijednosti se značajno razlikuju.

P-vrijednost za dobivene rezultate iznosi 0,000 tj. odbacujemo tezu da se podaci ponašaju po Poissonovoj distribuciji.

Nakon toga citate se testiralo, dali odgovaraju sljedećim trima distribucijama: Normalnoj, logističkoj, 2 - parametarskoj eksponencijalnoj. Dobivene rezultate možemo vidjeti na grafovima 7.-9.

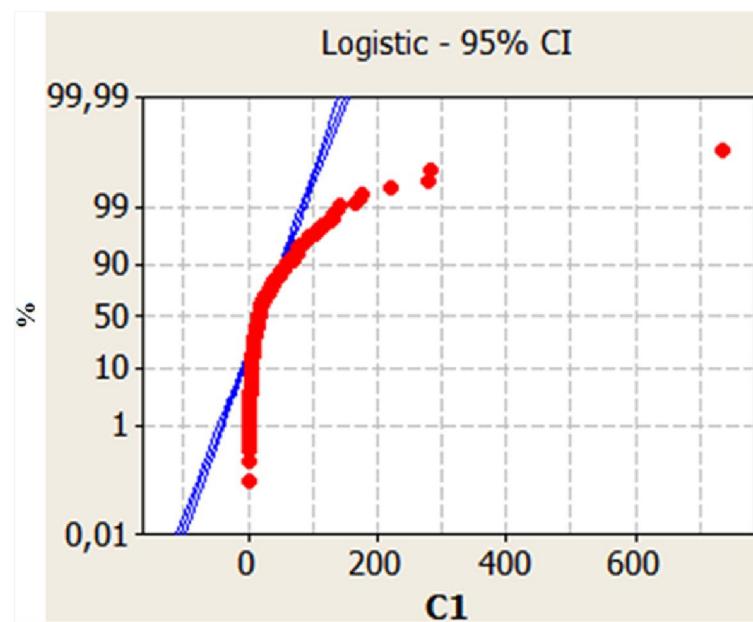


Graf 7. Vjerovatnost distribuiranja podataka prema normalnoj razdiobi

Varijabla C1 predstavlja citate članaka koji su uvedeni u program.

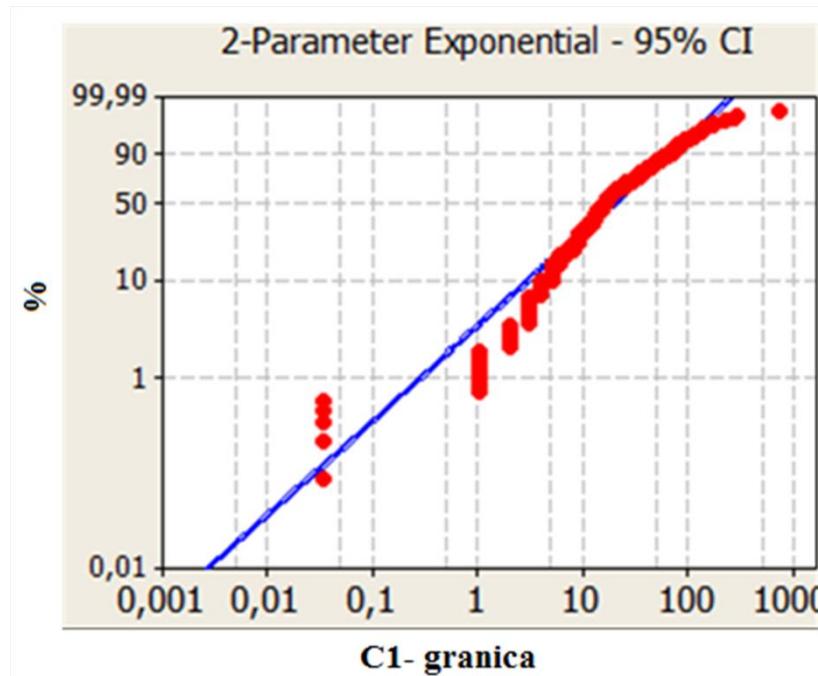
P-vrijednost < 0,005, vrlo mala p-vrijednost sugerira da se citati ne ponašaju prema Normalnoj razdiobi, tako da i ovu distribuciju odbacujemo kao moguću distribuciju raspodijele podataka.

Sljedeća testirana distribucija je logistička distribucija.



Graf 8. Vjerovatnost distribuiranja podataka prema logističkoj razdiobi

P-vrijednost < 0,005, distribucija se odbacuje kao moguća distribucija citata



Graf 9. Vjerojatnost distribuiranja podataka prema dvo parametarskoj eksponencijalnoj distribuciji

P-vrijednost < 0,01, distribucija se odbacuje kao moguća distribucija raspodijele citata.

Testiralo se podatke još na Weibull-ovu, Gama, Eksponencijalnu i dugačku-logističku razdiobu i rezultati su pokazali da niti jedna od ovih razdioba se ne poklapa sa podacima unesenim u program tj. prikupljenim citatima članaka. Određene tipove razdioba program uopće ni ne može napraviti iz razloga što u podacima imamo 0 kao veličinu. Budući da se nije uspjela pronaći jednostavna razdioba distribucije citata bilo je potrebno prilagoditi podatke kako bi možda mogli pronaći distribuciju koja opisuje raspodjelu citata članaka. Ova prilagodbu podataka može se vidjeti u radu *Distribution of Citations in one volume of a journal*. Rezultate ovog članka možemo vidjeti u nastavku rada.

4.5 Rezultati članka *Distribution of Citations in one volume of a journal*

Neka A bude broj članaka u grupi. Numeriramo ih koristeći indeks $i = 1, \dots, K$, pomoću nekih nespecificiranih kriterija, npr; rastući datum kada su rukopisi prikupljeni. Broj citata i -tog članka je n_i i ukupan broj citata za dani volumen označava se sa $N = n_1 + \dots + n_k$. Relativna frekvencija citata i -tom članku je $f_i = n_i/N$. Set

$$\{f_1, f_2, \dots, f_k\} \quad (1)$$

je distribucija citata (DC) grupe članaka koji su objavljeni u definiranom volumenu odabranog znanstvenog časopisa.

4.5.1. Generalne karakteristike

Modelirana funkcija vjerojatnosti distribucije citata (FVDC) je sljedeća.

$$p(x; a, b) = b^{1-\frac{1}{a}} \times \frac{\sin^{\frac{\pi}{a}}}{\frac{\pi}{a}} \times \frac{1}{b+x^a} \quad (2)$$

Gdje je x kontinuirana varijabla, generalizacija broja citata, a a i b su dva parametra koja će se odredit iz prilagodbe (2) u (1), koristeći nelinearnu metodu najmanjeg kvadrata. Parametar a je odgovoran za dug rep citata od (2). U toj regiji x -osi funkcija zahtijeva formu distribucije zakona moći,

$$p(p \gg b; a, b) \sim x^{-a} \quad (3)$$

dok u suprotnoj regiji, $x \ll b$ funkcija (2) sklona konstantnoj vrijednosti. Forma (3) je usklađena sa brojem rezultata baziranoj na analizi značajne količine citata. Budući N kao što je definirano ovdje se smatra da će biti puno manji od broja citata koji se koriste u drugim kontekstima, očekujemo da će ovdje diskriminacija različitih, ali kvalitativno sličnih oblika, nije moguća. U regiji slabe citiranosti, $x \ll b$, slično tome, očekujemo da se taj oblik DC nije mogao diskriminirati između mnogih funkcionalno različitih, ali kvalitativno sličnih funkcija što je razlog zašto smo odabrali formu koja na jednostavan obuhvaća ne divergentno ponašanje granice niskog broja citata. Prije nego počnemo, pretpostavljaju se da u (2) x je kontinuiran, realna, ne negativna varijabla kojoj cijelobrojne vrijednosti imaju značenje mogućeg broja citata. Zanimljivo je napomenuti da forma sliči izmijenjenoj Pareto distribuciji, podrijetlom iz gospodarskog konteksta predstavljajući još jedan doprinos ostalim disciplinama na formuliranju bibliometrijskog parametra. Da sumiramo, forma (2) ima dva parametra koja su zasebno povezana sa dva povezana, međusobno različita dijela DC. Pretpostavljamo da u slučaju prilično velikog N-a, DC je sklona određenoj FVDC. Prva karakteristika FVDC je njezin moment, očekivana vrijednost. Ovo je usko povezano sa faktorom odjeka, razlika se strogo pripisuje broju godina prilikom kojih su članci prikupljali citate, također kao i izvoru literature u kojim su se citati prikupljali. Ipak pretpostavljamo da razlike nisu značajne, već su tehničkog karaktera. Stoga smatramo a očekivane vrijednosti FVDC nalikuju faktoru odjeka. Za FVDC (2), očekivana vrijednost postoji za $a > 2$ i jednaka je

$$\bar{x}(a, b) = \frac{b^{1/a}}{2 \cos(\pi/a)} \quad (4)$$

Međutim, očekivana vrijednost je pretpostavljena na osnovi prosječne vrijednosti utvrđene za DC. U statistici prosječna vrijednost je razuman predstavnik distribucije, ako je ta distribucija normalna distribucija. Budući da DC su pretežno iskrivljenog oblika, prosječne vrijednosti ne predstavljaju ih pouzdano. Umjesto toga medijani i srodne statističke mjere (decili, kvartili,...) su pouzdaniji predstavnici. Kako bi se što više povezali sa faktorom odjeka, nastavljamo sa (4). Njegova osjetljivost κ_x je dvokomponentna funkcija definirana u nastavku:

$$\kappa_x(a, b) = \left(\left(\frac{\partial \bar{x}}{\partial b} \right)_{a,b}, \left(\frac{\partial \bar{x}}{\partial a} \right)_{a,b} \right). \quad (5)$$

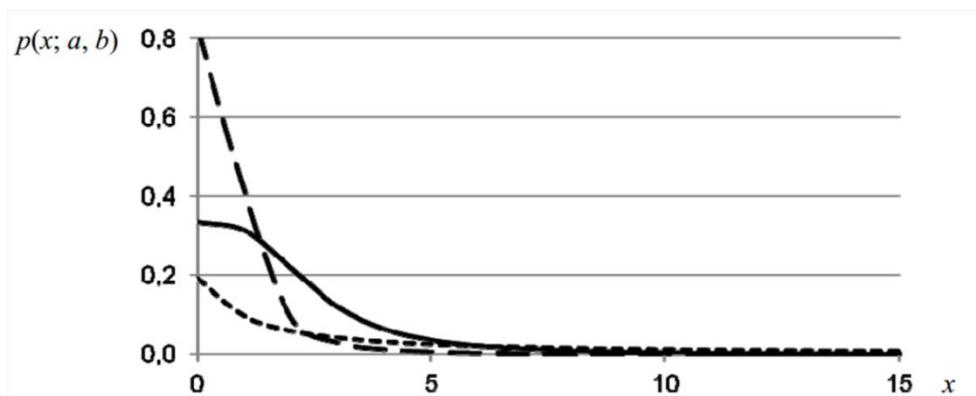
Druga karakteristika njezine distribucije je varijanca, kalkulirana kombinacijom prvog i drugog momenta distribucije. Standardna devijacija FVDC postoji za $a > 3$ i jednaka je

$$s(a, b) = b^{2/a} \left[\frac{\sin(\pi/a)}{\sin(3\pi/a)} - \frac{1}{4\cos^2(\pi/a)} \right]. \quad (6)$$

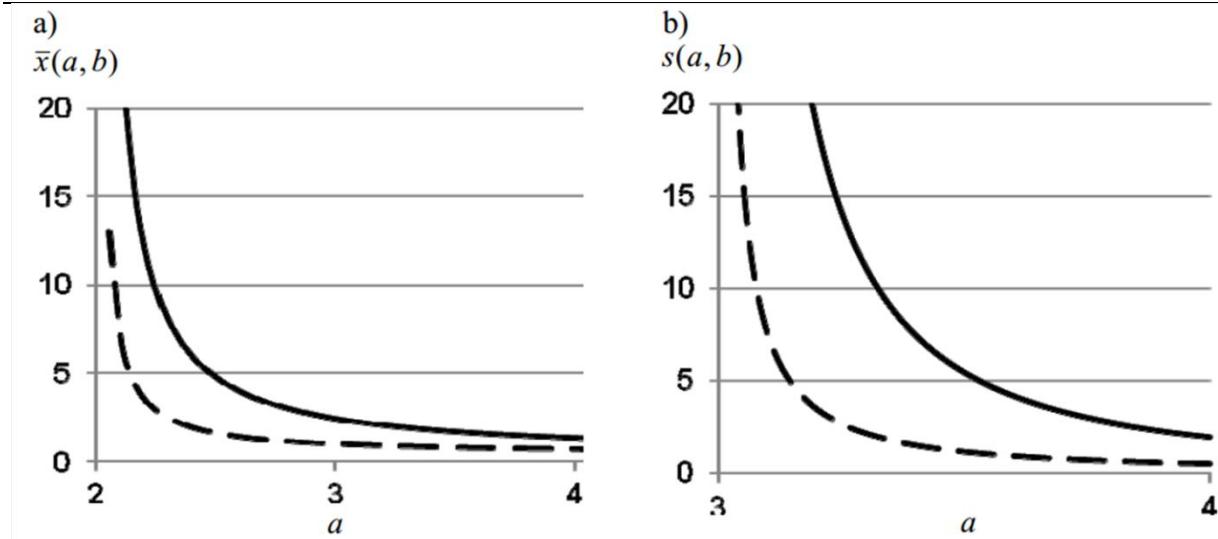
Dok odgovarajuća osjetljivost κ_s je jednaka

$$\kappa_s(a, b) = \left(\left(\frac{\partial s}{\partial b} \right)_{a,b}, \left(\frac{\partial s}{\partial a} \right)_{a,b} \right). \quad (7)$$

Osjetljivosti su veličine koje mjeru do koje će se vrijednosti FVDC (2) promjeniti, za dane vrijednosti a i b , u slučaju vrlo male promjene u formalne jedinice u DC (1). Slika 16. prikazuje FVDC ubaćen u (1), dok slika 17. prikazuje očekivane vrijednost (4) i varijancu (6). Grafikoni različitih komponenti dviju osjetljivosti imaju oblik sličan onome od očekivane vrijednosti i varijance, naročito u predjelu blizu donje granice raspona za vrijednost a za koju su definirani. U tom smislu, za $a > 3$, komponente osjetljivosti imaju više izraženu osjetljivost na male promjene u a , i više su pogodni za diskriminiranje naizgled slične, ali ipak kvantitativno različite FVDC[9].



Slika 16. Graf modela FVDC (1) za $a = 3$ i $b = 15$ (puna crta) $a = 3$ i $b = 1$ (isprekidana linija) a $= 1,2$ i $b = 1$ (točkasta linija)



Slika 17. Graf modela FVDC-ijeve a) prosječne vrijednosti b) standardne devijacije kao funkcije od a . Solidne linije su za $b = 15$ i isprekidane za $b = 1$.

4.5.2. Rezultati

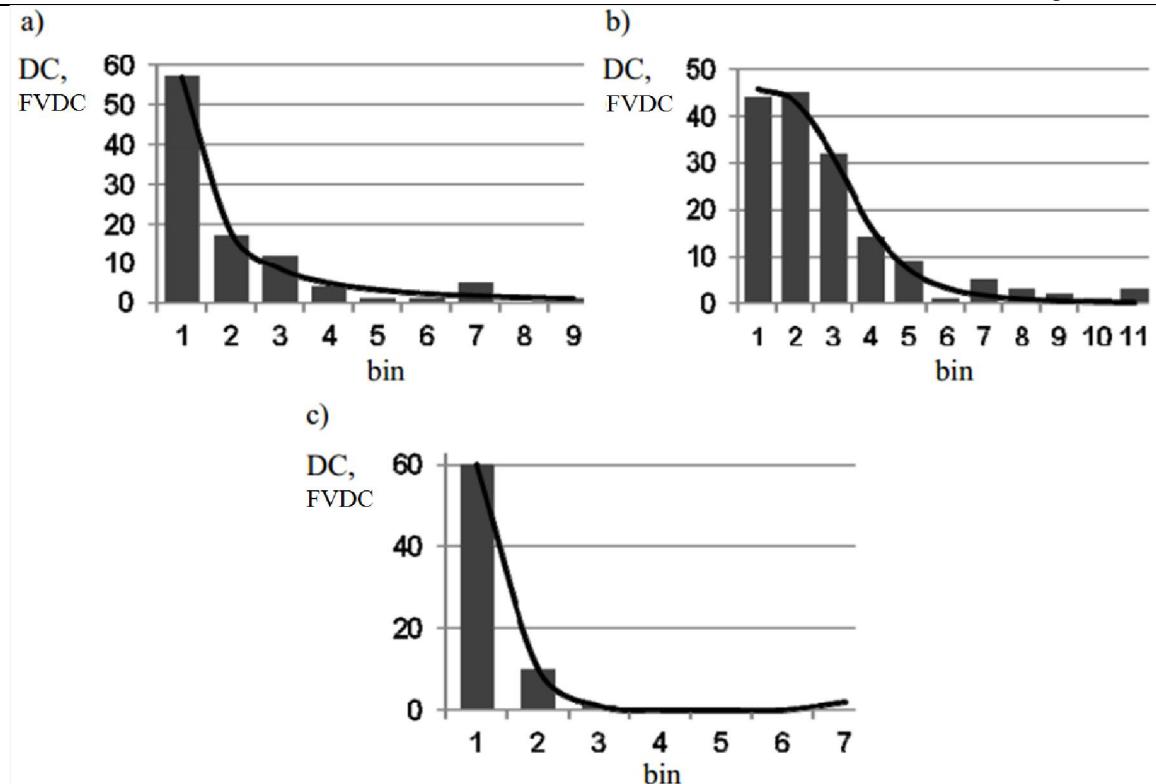
Dobiveni grafovi distribucije citata na slici 18. slični su grafovima 1,4,5, prilagođeni su prema (3), sa linearnom transformacijom u kojoj reprezentativna vrijednost broja citata u prikazanom stupcu (x) je linearno transformirana u x' koja se podudara sa rednim brojem stupca. Nije bilo dodatnih kriterija za utvrđivanje širine stupaca. Softver R-project Ver. 2.15.2 je korišten za prilagođavanje izraza $N_A \times p(x; a, b)$ prikupljenim podacima sa nelinearnom metodom najmanjeg kvadrata. Formalno, kako bi isključili bilo kakvu normalizaciju i uključili opisanu linearnu transformaciju, podaci prikazani na slici 3 prilagođeni su formi

$$\frac{k_1}{1+k_2x^{k_3}}, \quad (8)$$

S vrijednostima dobivenim za koeficijente $k_{1,2,3}$, kao što su prikazani u tablici 14. Grafovi funkcije (8) za određeni časopis prikazani su na slici 3., ubačeni su u grafove kako bi komparacija bila lakša.

Tablica 14. Vrijednosti koeficijenata prikupljeni za model FVDC (8)

Časopis	k_1	k_2	k_3
A	277,4	3,870	1,895
B	45,89	0,002	4,792
C	64,8	0,079	6,107



Slika 18. Grafovi prikazuju ovisnost DC i FVDC o citatima za časopise a) A, b)B, c)C. Smeđi stupci referiraju se na graf prebrojanih citata, dok puna crna linija predstavlja prilagođene vrijednosti bazirane na (2). Vrijednosti na apscisi linearno su povezane sa odgovarajućim prosječnim vrijednostima citata

Koristio se neparametarski Kolmogorov-Smirnov test za ispitivanje koliko je dobro distribucija prilagođena. Hipoteza je da podaci slijede specificiranu distribuciju, a alternativna hipoteza je da podaci ne slijede specificiranu distribuciju. Za svaki časopis, statistički D je manji od kritične vrijednosti $D_{\text{kritično}}$, stoga nemamo dovoljno dokaza da odbijemo navedenu hipotezu. Može se zaključiti da uz razinu značajnosti od 0,05 podaci slijede navedenu distribuciju [9].

Tablica 15. Podaci za provedeni neparametarski Kolmogorov-Smirnov test za nivo značajnosti od 0,05.

Časopis	D	$D_{\text{kritično}}$
A	0,030	0,388
B	0,064	0,452
C	0,027	0,381

Također kako bi usporedili dobivene podatke referirat ćemo se na rad koji su radili E.S. Vieira, J.A.N.F. Gomes (2009) sa Lisabonskog instituta za tehnologiju.

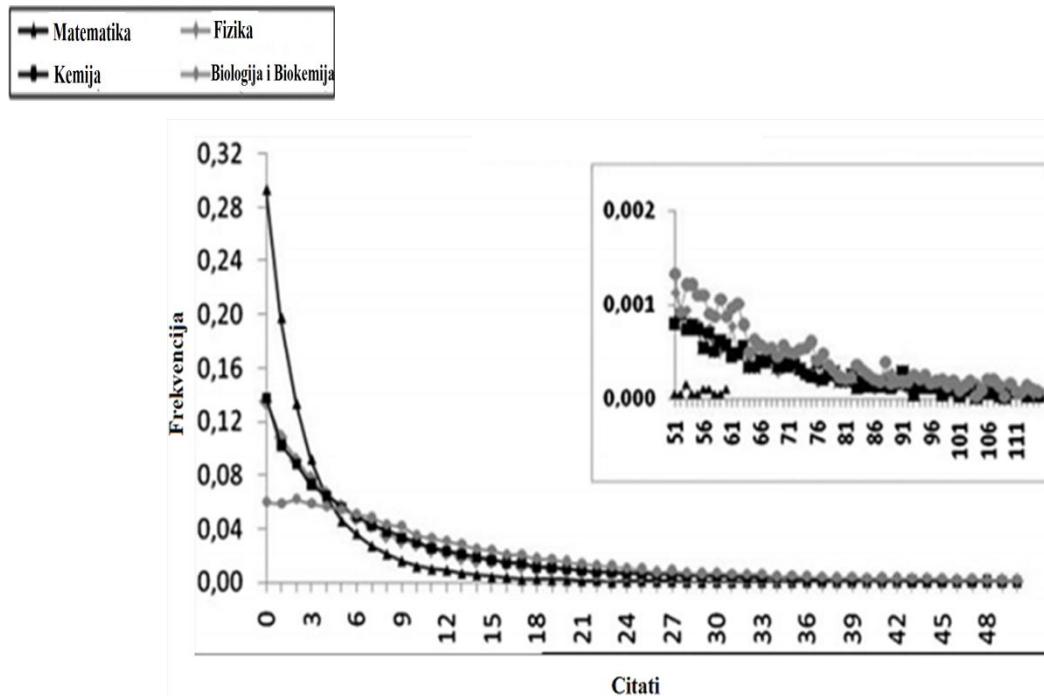
4.6. Metoda

Istraživanja su temeljena na analizi 222 116 članaka objavljenih u 2004 g; u časopisima koji su indeksirani *Web of Science* (WoS) bazama, a klasificirani su prema temeljnim znanstvenim pokazateljima (ESI) u znanstvenim poljima Biologije, Biokemije, Kemije, Matematike i Fizike (*Thomson Reuters*, 2009a). ESI je kompilacija statističkih podataka vezanih uz publikacije, citate i citiranosti po stranici časopisa, znanstveniku, instituciji i zemlji koji se odnose na 10 godina Thomson Reuters podataka. Broj časopisa koji pripadaju svakom polju bio je 455 (44.248 članaka) za biologiju i biokemiju, 574 (97,177 članaka) za kemiju, 387 (20,127 članaka) za matematiku i 338 (64,614 članaka) za fiziku. Sve informacije o tim člancima prikupljene su iz WoS-a kako bi izgradili bazu podataka iz koje bi imali informacije o broju koautora, institucionalnih adresa, broju stranica, broju referenci, časopisa i broju citata (od godine objave do danas) za svaki dokument koji je klasificiran kao članak. Za studij distribucije citata prebrojali su se citat svakog pojedinog članka i onda su se grupirali članci sa istim brojem citata, od nule do maksimalnog broja citata za određenu skupinu članaka, da bi se odredilo kako varijable koje karakteriziraju jedan članak mogu utjecati na postignutu citiranost članka, odnos između prosječne citiranosti i broja ko-autora, broja adresa, broja stranica, broja referenci i faktora odjeka koji se proučava. Za svako znanstveno polje odabrani su članci sa jednim, dvoje, troje itd., koautora i njihova citiranost je prebrojana. Ista metodologija primijenjena je i kod drugih varijabli. Istraživanje odnosa između prosječne citiranosti članka i faktora odjeka napravljena je na način da se izvukao svaki faktor odjeka (2006 *Journal Citation Reports*) za svaki časopis koji pripada području analize.

4.6.1. Distribucija citata

Slika 19. Prikazuje učestalost pojave članaka sa nula, jedan, dva, tri i tako dalje citata za vremenski period od 5 godina. Raspodjele za fiziku i kemiju su slične. Vidljivo je da su u matematici citati puno rjeđi nego što su za biologiju i biokemiju. Parametri tih razdioba su sažeti u Tablici 16. u nastavku. Distribucije su vrlo iskrivljene, ali medijani vrlo blizu slijede prosjeku, omjer varira od 0,52 do 0,66. Razlog ovih razlika morao bi biti povezan sa kulturom publikacije same discipline. Uglavnom matematičari daju mnogo manje referenci u svojim člancima, tako da zbog toga broj citata mora biti mnogo niži. Unutar svake discipline (ili pod-discipline) razlozi zbog kojih članak dobije veći ili manji broj citata teško se može detaljno utvrditi. Ako se prepostavlja da je citirani dokument utjecao na autora koji je citirao, broj citata bi bila mjera utjecaja koji dokument imao u znanstvenoj zajednici.

Međutim, ostali razlozi mogu dovesti do citiranja, tako da uzročni argument postaje puno teži za definirati. Moglo bi se očekivati, da baveći se ovako velikim brojem dokumenata, studija distribucije može pomoći razumijevanju motivacije za citiranje određenog članka.



Slika 19. Distribucija citata za područja: Matematike, Kemije, Fizike, Biologije i Biokemije

Tablica 16. Statistički parametri distribucija citata za područja: Matematike, Kemije, Fizike, Biologije i Biokemije

Znan. polje	Br. članaka	Prosječna citiranost	Medijan	Varijacija	Stand. devijacija
Biologija i biokemija	44,248	13,59	9	358,34	18,93
Kemija	97,177	9,55	5	284,44	16,88
Matematika	20,127	3,22	2	38,44	6,20
Fizika	64,614	9,72	5	269,62	16,42

4.6.2. Prvi model: nasumično citiranje

Uzmimo pretpostavku da je autor odlučio odabratи nasumično svoje reference, svaki objavljeni članak imat će istu (vrlo malu) vjerojatnost da bude citiran. Broj citata dobivenih od svakog članka bi slijedio Poissonovu distribuciju sa aritmetičkom sredinom izračunatom kao odnos zbroja svih citata (od svih članaka koji su objavljeni u 2004. g. od strane bilo koje publikacije koja je referencirana u WoS-u od 2004-2008) podijeljenih sa brojem članaka u 2004. godini. Poissonova distribucija ima varijancu jednaku aritmetičkoj sredini i funkcija gustoće vjerojatnosti je

$$P(k; \mu) = \frac{\mu^k}{k!} e^{-\mu}$$

U tablici 16. Može se vidjeti da su rezultati dobiveni za varijancu mnogo veći od onih dobivenih za aritmetičku sredinu, što sugerira da hipoteza da svi članci imaju isti očekivani utjecaj je kriva, kao što smo mogli i pretpostaviti. Ovaj rezultat postavlja pitanje o raspodjeli očekivanih utjecaja radova u određenoj disciplini

4. 6.3. Drugi model: Očekivani utjecaj radova smanjuje se eksponencijalno

Sada se može pretpostaviti da članci određene discipline se mogu organizirati u skupinama s istom vjerojatnošću citiranosti ili očekivane citiranosti. Za dobrobit rasprave, može se pretpostaviti da svaki autor piše vrlo mali broj dobrih radova i veliki broj radova niže kvalitete, kvaliteta znači ovdje jednostavno svoj očekivani učinak. Pretpostavimo da se ta kvaliteta mjeri po prosječnoj citiranosti radova u ovoj klasi. Za svaku od tih klasa, Poissonova raspodjela će se primijeniti za opisivanje raspodjele broja citata, koje bi ti jednakim dobri radovi dobili. Promatrana distribucija će biti konvolucija gustoće funkcije Poissonove distribucije od distribucije prosjeka, kao njegov jedinstveni parametar. Ovaj prosječan broj citata ovdje ćemo nazvati očekivana citiranost radova u određenoj klasi. Pretpostavimo da raspodjela ove očekivane citiranosti, μ , ima eksponencijalni oblik,

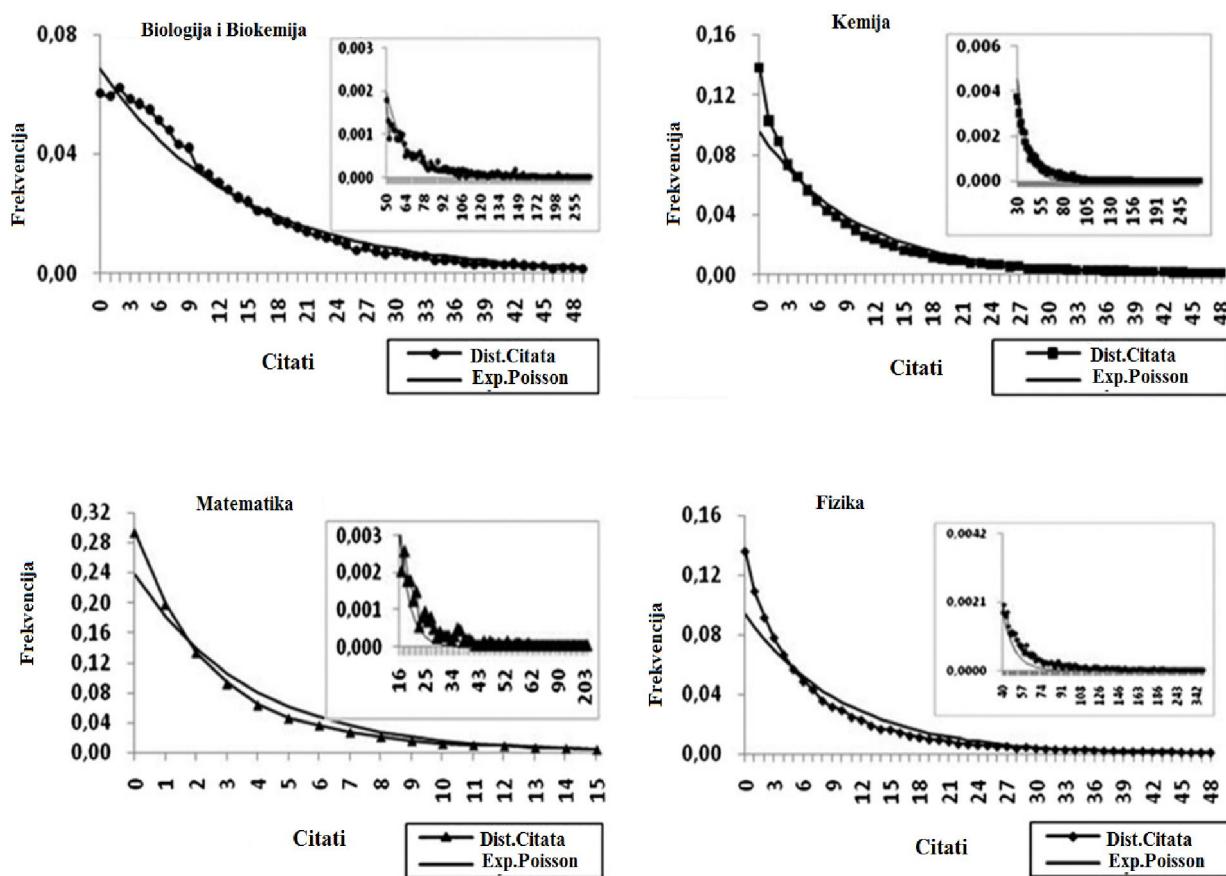
$$F(\mu; E) = \frac{1}{E} e^{-\frac{\mu}{E}}$$

gdje je parametar E prosječna vrijednost slučajne varijable μ , prosječna vrijednost očekivane citiranosti svi razreda članaka pretpostavljamo da formira kontinuirani skup. Vjerojatnost nastanka članka sa citiranošću k može se izračunati sa izravnom integracijom Poissonove i Eksponencijalne distribucije.

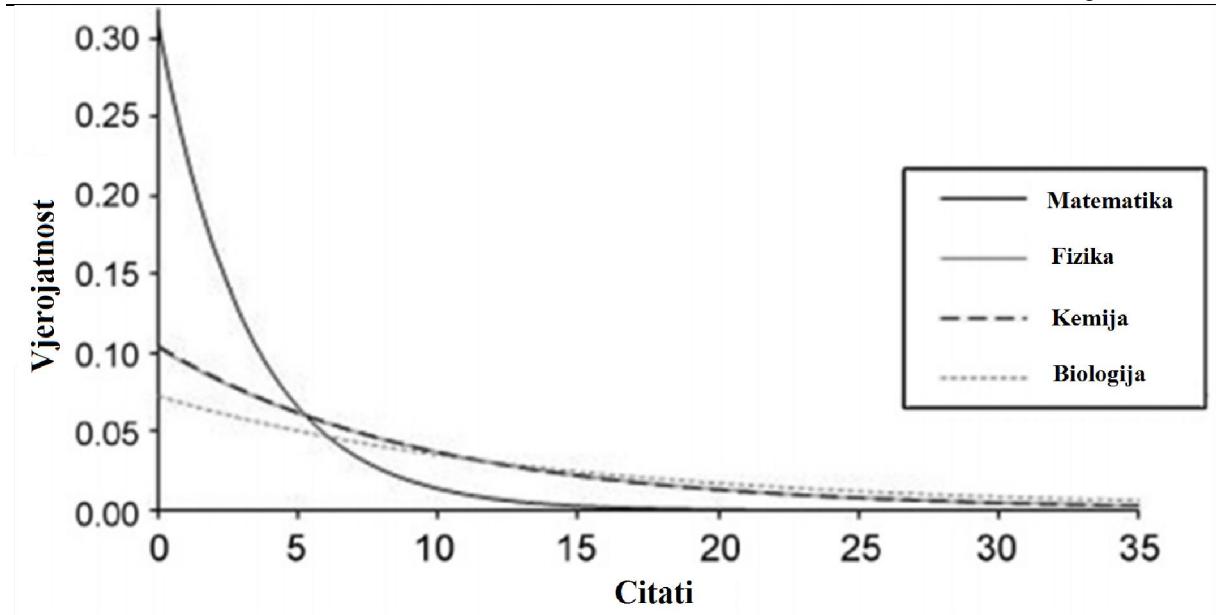
$$P(k) = \int_0^\alpha P(k; \mu) F(E; \mu) d\mu$$

Ova distribucija ima srednju vrijednost E i varijancu jednaku izrazu $E(E+1)$. Ovo bi mogli nazvati eksponencijalno-poissonova distribucija, kako bi očistili model citata koji koristimo. U stvari, ova distribucija nastanka vjerojatnosti citiranosti članka k je već dobro poznata geometrijska distribucija. Ovu distribuciju se koristilo za četiri discipline kao što je prikazano na slici 20. gdje parametar E nije ubačen, već izabran da bude jednak promatranom prosječnom broju citata. Kvaliteta podudarnosti je iznenadjuće dobra s obzirom na to da eksponencijalno-poissonova distribucija ima jedinstven parametar i s obzirom na to da se koristila prosječnu citiranost po članku bez ikakvog podešavanja. To ukazuje na stupanj

valjanosti hipoteze da se članci mogu rangirati prema svojstvima članka koji su nekako povezani sa kvalitetom, očekivani utjecaj je mjeran po očekivanom broju citata ili citiranosti; ovaj broj je bio pretpostavljen da će se distribuirati kao eksponencijalni pad (ponor) kao što je prikazano na slici 21. Za discipline smo koristili prosječan broj promatranih citata. Kao što se očekivalo fizika i kemija su se ponašale vrlo slično dok s druge strane Matematika, Biologija i Biokemija su se ponašale drugačije. U Matematici, učestalost pojave članaka s niskom očekivanom citiranošću je vrlo visoka, dok u Biologiji i Biokemiji časopisi sa visokom očekivanom citiranošću su puno češći. Za top 10 % članka njihova očekivana citiranost leži iznad 31 za Biologiju i Biokemiju, iznad 22 za Fiziku i Kemiju i iznad 7 u Matematici. Ove razlike očekivanih citata prikazane su u Tablici 17., a očekivani citati su izraženi u decilima. Iznenadujuće je to kako ova jednostavna pretpostavka dovodi do distribucije citiranosti tako bliske onoj promatranoj, a uzimimo u obzir da za reprezentaciju svake discipline nije uzeto ništa više nego prosječna citiranost po članku. Ako želimo poboljšati kvalitetu naših rezultata, drugi parametar bi trebalo uvesti u distribucijsku funkciju.



Slika 20. Eksponencijalna - Poisson distribucija prilagođena empirijskim podacima za područja Biologije i Biokemije, Kemije, Matematike i Fizike



Slika 21. Eksponencijalna distribucija očekivane citiranosti članaka za područja Biologije i Biokemije, Kemije, Matematike, Fizike

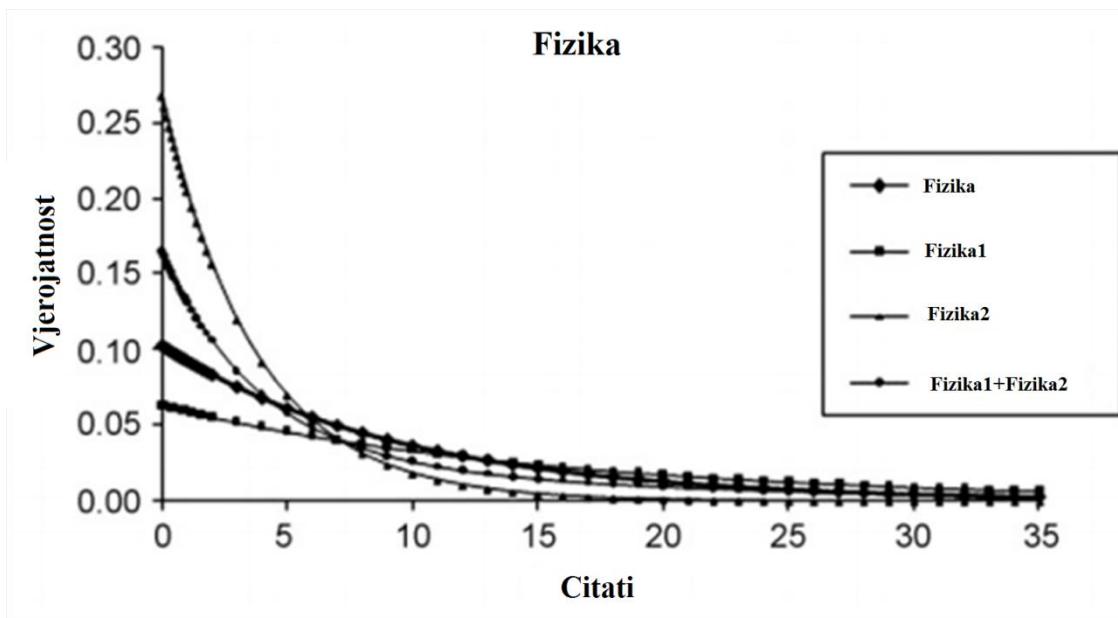
Tablica 17. Pozicija po prosječnoj citiranosti za promatrana područja

Decili	Pozicija u decilima				Prosječna citiranost u decilima			
	Biologija i biokemija	Kemija	Matematika	Fizika	Biologija i biokemija	Kemija	Matematika	Fizika
1.	1,43	1,01	0,34	1,02	0,703	0,494	0,167	0,503
2.	3,03.	2,13	0,72	2,17	2,216	1,557	0,525	1,585
3.	4,85	3,41	1,15	3,47	3,919	2,754	0,928	2,803
4.	6,94	4,88	1,64	4,96	5,867	4,123	1,390	4,196
5.	9,42	6,62	2,23	6,74	8,142	5,721	1,929	5,823
6.	12,45	8,75	2,95	8,90	10,877	7,644	2,577	7,780
7.	16,36	11,50	3,87	11,70	14,311	10,056	3,390	10,236
8.	21,87	15,37	5,18	15,64	18,927	13,301	4,483	13,538
9.	31,29	21,99	7,41	22,38	26,037	18,297	6,167	18,623
10.	∞	∞	∞	∞	44,873	31,533	10,629	32,096

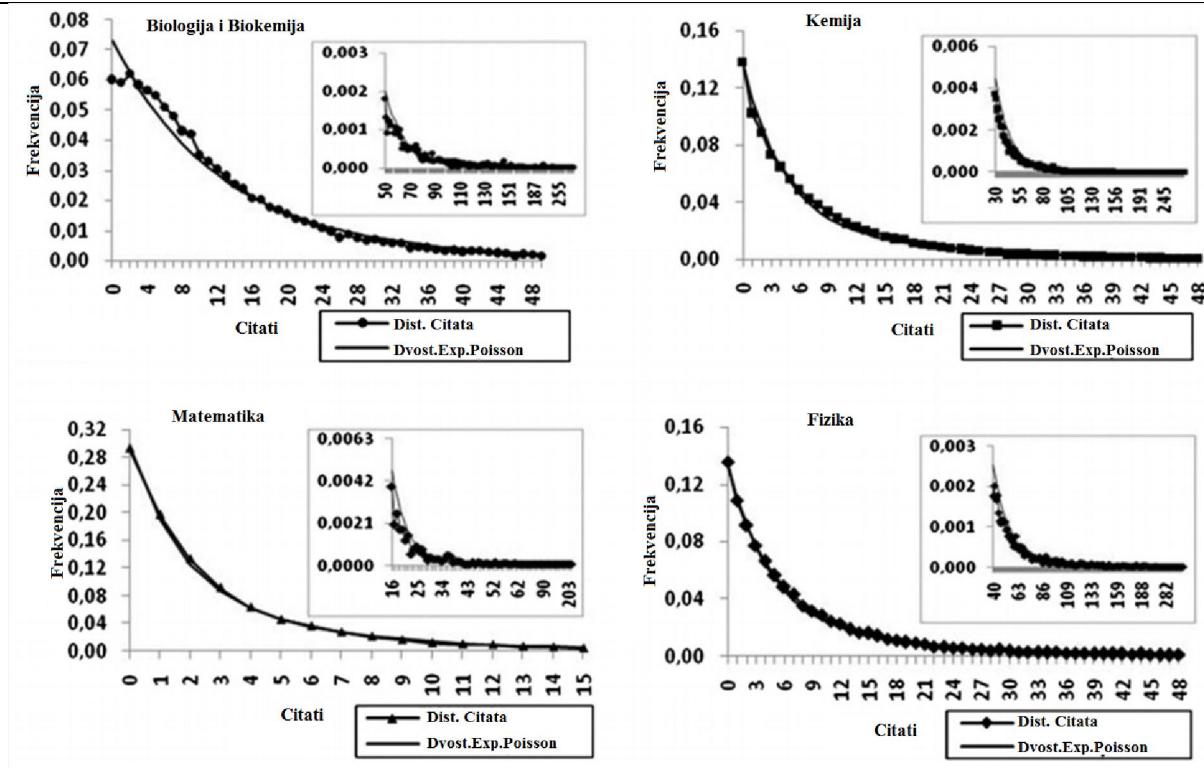
4.6.4. Treći model: dvostruka eksponencijalna - Poissonova distribucija

U nastojanju da prilagodimo naš model podacima citiranosti, pokušavamo koristiti fleksibilniju distribuciju za očekivanu citiranost dobivenu od prosjeka dvaju eksponenata. Efekt je prikazan na slici 22. za slučaj Fizike. Efekt ovih dvaju parametara distribucije, moglo bi se lakše razumjeti gledajući nove rezultate. Najnižih 10 % očekivane citiranosti smanjen je s $1,02 - 0,55$ decila citiranosti; na 50 %, citiranost se smanjuje sa 6,74 na 3,9; na drugoj

strani, 90% naviše očekivane citiranosti, očekivan citiranost se povećava sa 22,4 na 24,0. Naravno, jednostavna eksponencijalna-Poissonova distribucija (ili geometrijska) i nova dvostruko eksponencijalna doveli su do istog prosječnog utjecaja citiranosti promatranih znanstvenih grana. Neto rezultat je da se povećava frekvencija nisko citiranih članaka, a smanjuje se predviđena frekvencija u regiji sa višim brojem citiranosti. Koristeći ovu novu raspodjelu s uvjetima koji bi trebali reproducirati prosjek i standardnu devijaciju podataka, dobivamo prikaz podataka na slici 23. u nastavku. Kvaliteta preklapanja podataka poboljšava se znatno u usko i srednjem rasponu, ali se također poboljšava i u samom repu grafa. Alternativna metoda se sastoji od metode najmanjeg kvadrata dvostrukе Poissonove distribucije na empirijskim podacima. Time poboljšavamo prilagodbu bez većih kvalitativnih razlika.



Slika 22. Eksponencijalna distribucija očekivane citiranosti članaka za područje Fizike: usporedba eksponencijalne sa dvostrukom eksponencijalnom distribucijom



Slika 23. Dvostruka eksponencijalna- Poissonova distribucija prilagođena empirijskim podacima za područja Biologije i Biokemije, Matematike, Fizike i Kemije

Tablica 18. Kolmogorov-Smirnov test

Znanstveno polje	D _{obs}		Kritične vrijednosti za K-S, D _{obs}	
	Exp. Poisson	Dvostruka Exp. Poissom	Razina signifikantnosti 0.01.	Razina signifikantnosti 0.01.
Biologija i biokemija	0,034	0,024	0,115	0,096
Kemija	0,075	0,019	0,107	0,089
Matematika	0,073	0,015	0,181	0,151
Fizika	0,092	0,022	0,110	0,092

Za procjenu kvalitete prilagodbe podataka koristili smo Kolmogorov-Smirnov (K-S) test. K-S se koristi za testiranje hipoteze da dani skup se mogao izvući iz zadane distribucije. Statistika testa dana je jednadžbom:

$$D_{\text{obs}} = \text{Max} |F(x) - S(x)|$$

Gdje su $F(x)$ i $S(x)$ teoretske i promatrane funkcije razdiobe.

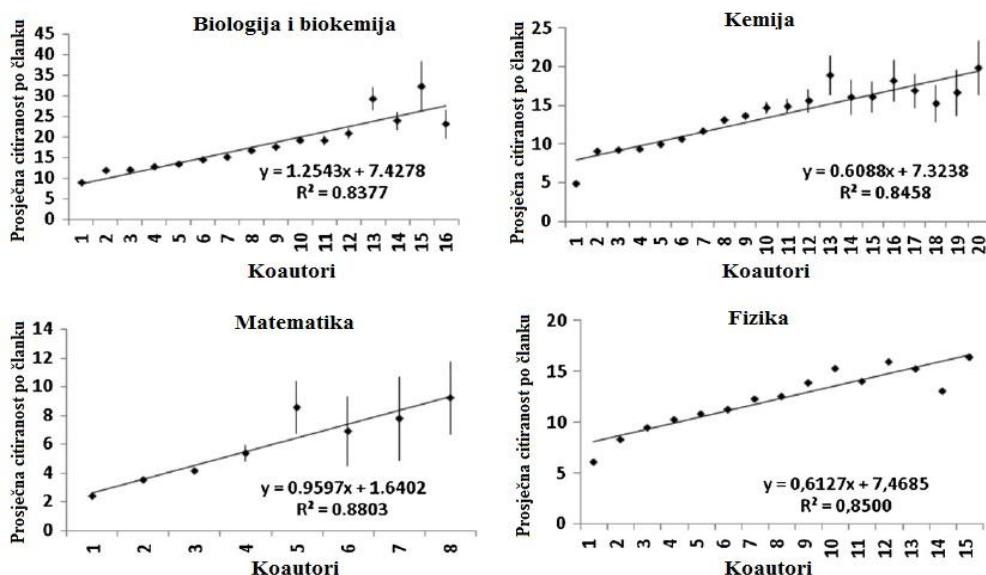
Tablica 18. potvrđuje da se predložene distribucije ne mogu isključiti sa dvostrukom eksponencijalnom- Poissonovom distribucijom, opravdavajući opis koji je naveden iznad.

Sugirano je da bi se negativna binomna distribucija ili (gama- Poissonova) dobro uklapala sa podacima citata, ali sva testiranja su provedena sa prilično ograničenim brojem dokumenata. Naravno, ova negativna binomna distribucija jednaka je geometrijskoj distribuciji kada (eksponencijalno- Poissonovoj) kada je jedan od dvaju parametara nepromjenjiv. Ovi jednostavnii modeli sugeriraju na to da uspjeh članka, ovisno o njegovim svojstvima, se može opisati sa samo jednim brojem - očekivana citiranost, a taj broj možemo prikazati na način da uzmemo prosjek dviju eksponencijalnih distribucija (ili u našem slučaju dvostrukih eksponencijalnih distribucija) ili gama razdiobe. Ovo saznanje ne poništava mogućnost da neko od svojstava dokumenta neće u budućnosti utjecati na citiranost dokumenta. Časopis u kojem se objavljuje članak očekuje se da će imat veliki utjecaj budući da se svi autori članka bore kako bi objavili svoj članak u najboljem časopisu svojeg područja. Ostale značajke kao što su veličina papira ili njegov broj stranica, broj referenci, broj koautora i broj adresa zasigurno može utjecati na broj citata što će članak dobiti. Ta svojstva mogu se mjeriti na vrlo jednostavan način , ako se zanemari različite veličine slova koje mogu stati na jednu stranicu časopisa ovisno o njegovom formatu. Najčešće korišteni parametar za mjerjenje kvalitete časopisa je WoS-ov faktor odjeka koji se izračunava dijeljenjem broja ukupnog broja citata (koji možemo vidjeti u *Journal Citation Report*) u promatranoj godini sa ukupnim brojem članka odjavljenih u prethodne dvije godine. Za primjer uzeli smo proizvoljno jedan članak i u periodu od 5 godina skupio je 1230 citata . Prosjek ovog članka po godini ne podudara se sa faktorom odjeka, ali će bit povezan s njime na manje očigledan način. Ovisnost prosjeka govori vrlo malo o ponašanju citiranosti pojedinog članka, budući da je varijanca vrlo velika, a raspodjela dosta iskrivljena i na taj način opravdava ovu studiju.

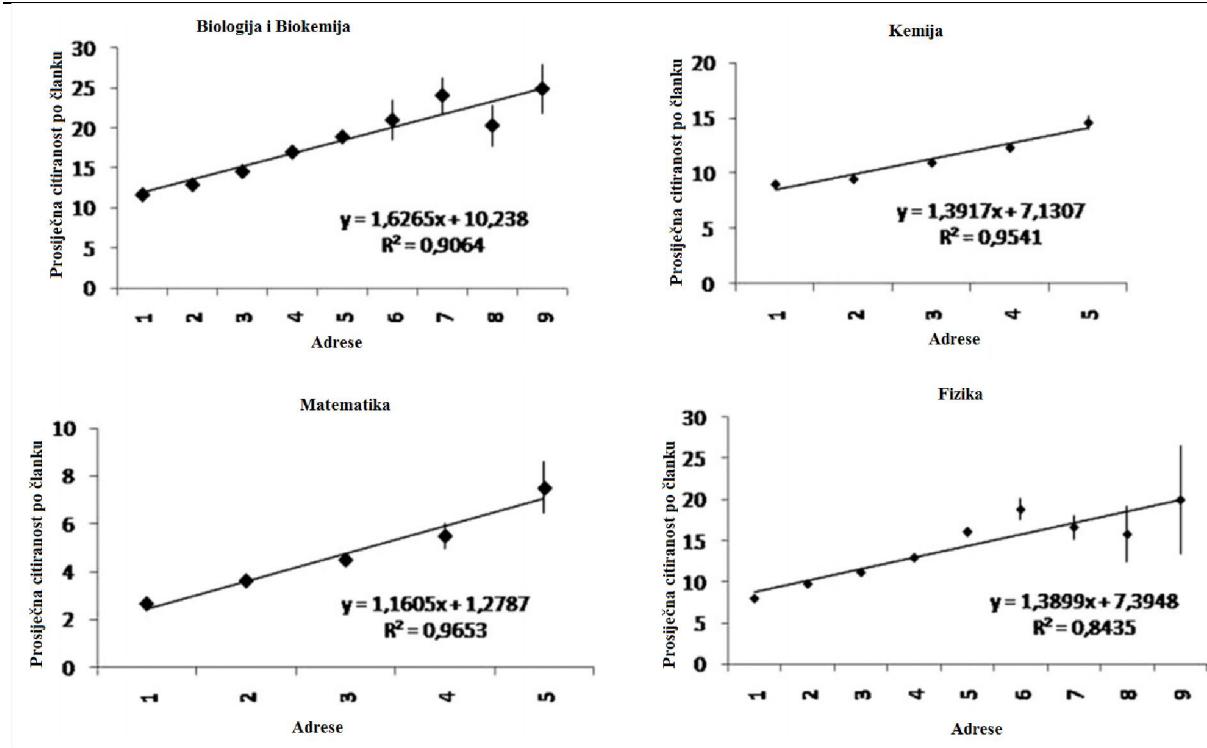
4.6.5. Ovisnost citiranosti o svojstvima članka

Sada promatramo mogućnost ovisnosti broja citata članka o nekim njegovim svojstvima kao što su: broj koautora, broj adresa, broj referenci i faktor odjeka časopisa u kojem je članak izdan. Za svaki od četiriju znanstvenih područja koje promatramo, ucrtali smo prosječnu stopu citiranosti uz veličinu parametra. Ovisnost prosječne stope citiranosti o broju koautora za promatrane znanstvene grane prikazano je na slici 24. gdje je procijenjena standardna devijacija aritmetičke sredine prikazana kao greška. Rezultati upućuju na ovisnost između prosječnog utjecaja i broja koautora. Koeficijenti korelacije R^2 , su niski kao rezultat jednog specifičnog članka koji je ulazio u analizu i također iz razloga što veliki broj koautora ima

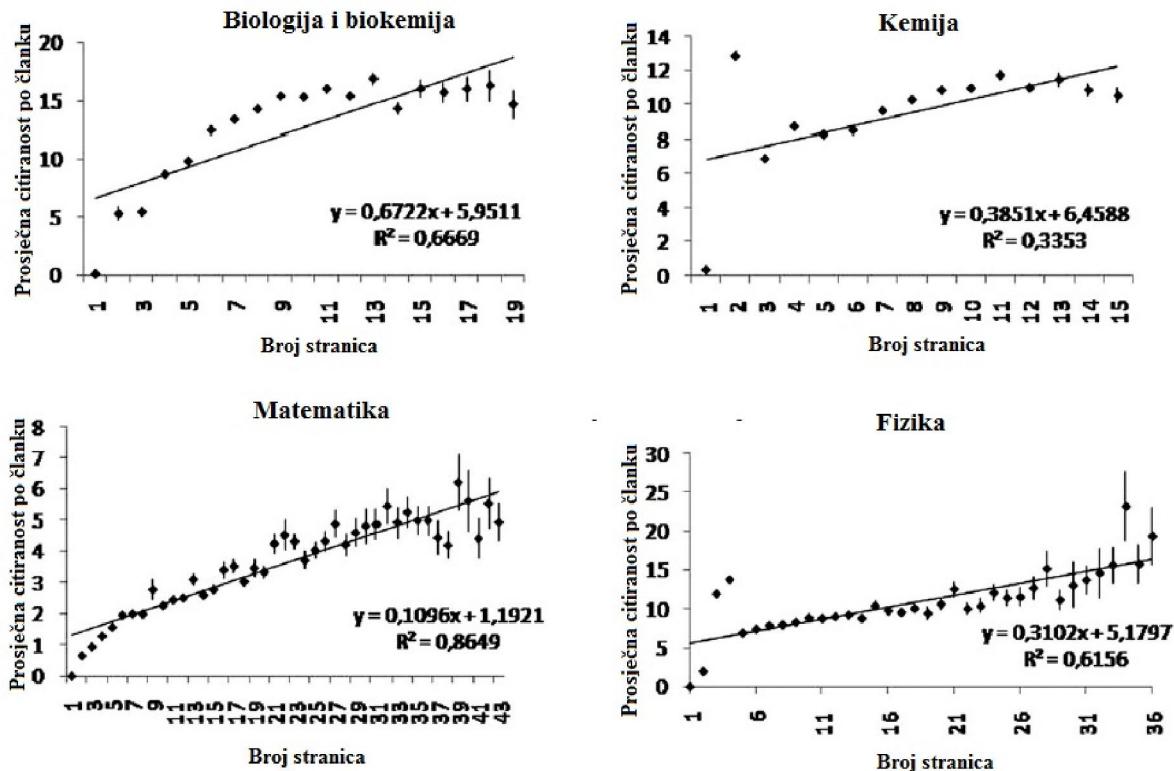
mali broj objavljenih članaka i zato je greška aritmetičke sredine velika. Najveći pronađeni broj koautora za jedan članak je bilo: 27 u biologiji, biokemiji i kemiji, 12 u matematici i 592 u fizici. Za broj koautora većih nego što je prikazano na slici, broj takvih dokumenata postane znatno manji i pogreške vezane za takve dokumente postaju izraženije. Prosječan broj koautora po dokumentu je najveći za Biologiju i Biokemiju (4,84) i skoro isti za Fiziku i Kemiju (3,98 i 3,89). Za matematiku prosječan broj koautora po dokumentu je bio 1,84. Za biologiju i biokemiju, kemiju i fiziku možemo vidjeti da je prosječna stopa citiranosti članka sa jednim autorom je manja nego što bi se to dalo očekivati ekstrapolacijom podataka za dvoje ili više autora. Slika 25. prikazuje prosječni utjecaj članka s obzirom na broj adresa za Biologiju i Biokemiju, Kemiju, Fiziku i Matematiku gdje je procijenjena standardna devijacija aritmetičke sredine prikazana kao greška. Ovisnost prosječnog utjecaja citiranosti o broju adresa je jasna i manji koeficijent korelacije za fiziku je razlog zato što u takvim člancima u prosjeku ima manji broj adresa nego u drugim promatranim znanstvenim granama. Prosječan broj adresa po dokumentu je gotovo isti u svim područjima (2,25, 1,75, 1,62 i 2,11 za biologiju i biokemiju, kemiju, matematiku i fiziku. Maksimalan broj adresa je pronađen za fiziku 114, dok je za druga područja maksimalno prikupljeni broj adresa znatno niži (22, 10 i 7 za biologiju i biokemiju, kemiju i matematiku. Suprotno prethodnom slučaju, točke koje odgovaraju pojedinačnoj adresi članka vrlo su blizu regresijskom pravcu, ali i dalje se možemo raspravljati da one pokazuju posebno ponašanje kod Kemije i Fizike [4].



Slika 24. Prosječna citaranost članaka objavljenih u 2004 g. u odnosu na br. koautora u području Biologije i Biokemije, Kemije, Matematike i Fizike



Slika 25. Prosječna citiranost članaka objavljenih u 2004 g. u odnosu na br. adresa u području Biologije i Biokemije, Kemije, Matematike i Fizike



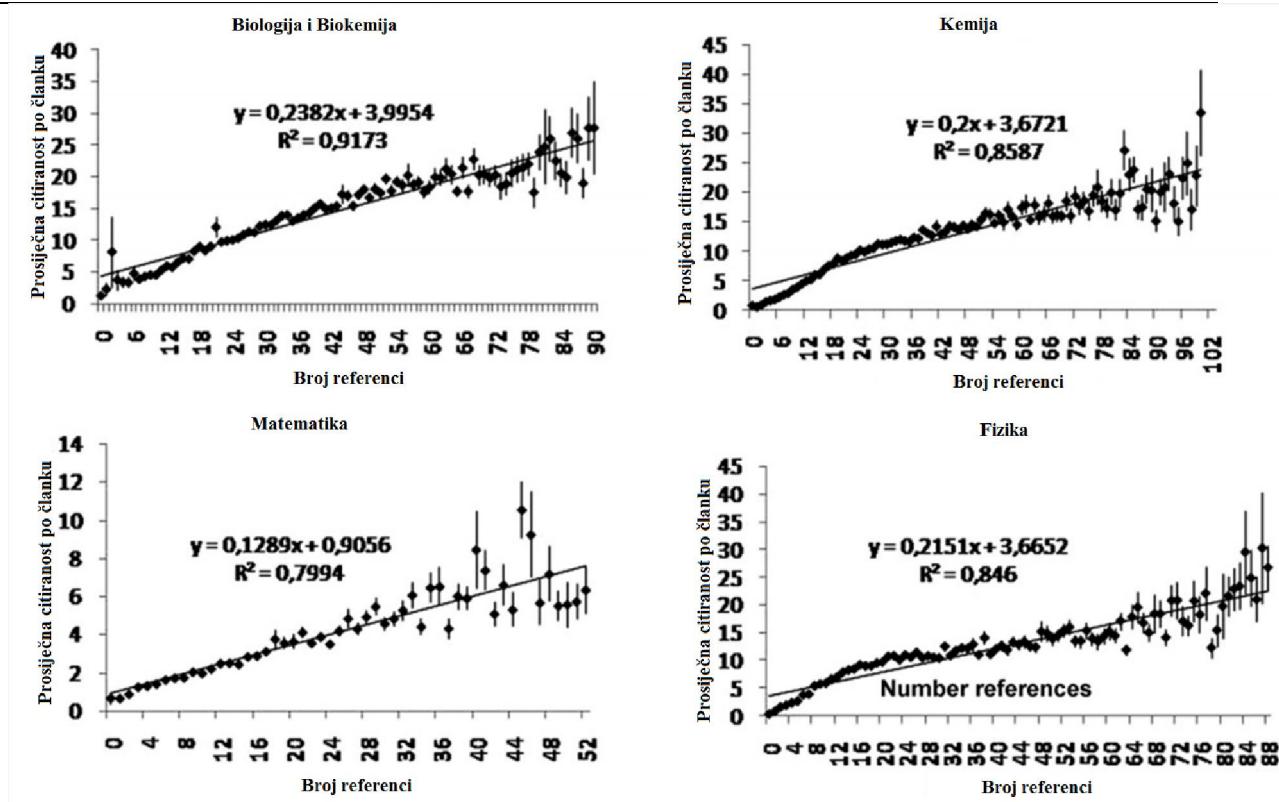
Slika 26. Prosječna citiranost članka u odnosu na broj stranica članka za Biologiju i Biokemiju, Kemiju, Fiziku i Matematiku

Na slici 26. iscrtan je utjecaj časopisa u odnosu na broj stranica članka za biologiju i biokemiju, kemiju, fiziku i matematiku sa procijenjenom standardnom devijacijom aritmetičke sredine prikazanom kao greška. Ovisnost odjeka citata o broju stranica članka daleko je kompleksniji. Ovo je najjednostavnije objasniti time da se članci različitim načinom pišu za promatrane discipline koje su indeksirane u WoS-u. Dokumenti sa jednom dvije ili tri stranice su klasificirani kao "člank" u WoS-u, a takovi dokumenti inače se ne bi smatrali primarnim istraživačkim dokumentom i citiranost koju ovi dokumenti izazovu padaju daleko od uzorka ostalih znanstvenih članaka. Prosječan broj stranica po dokumentu je 17,82, 9,72, 8,68 i 6,89 za matematiku, fiziku, biologiju i biokemiju i kemiju. Maksimalni broj pronađenih stranica je bio 512, 333, 240 i 198 za matematiku, kemiju, fiziku i biologiju i biokemiju. Broj stranica je možda dobar pokazatelj ostalih značajki koje klasificiraju dokument prema Thomson Reuters-u kao članak. U svim poljima, članci sa jednom stranicom imaju vrlo mali utjecaj, daleko ispod nego što se očekuje po regresijskom pravcu. Gledajući u detalje na dokumentima razvrstanim u ovoj skupini, saznali smo da su takvim dokumenti bile novosti ili kratke vijesti objavljene u znanstvenim časopisima koje je WoS ubrajao kao članak. U drugim slučajevima, to uključuje i rade dostavljene na konferencijama i objavljene u *Physics Today*, Fizika svijetu, *Chemical Week* i *Chemical World* među ostalima. U svim slučajevima, broj jednostraničnih članaka je malen i on se ne pojavljuje u grešci budući da takvi članci imaju mali utjecaj. Prosječna stopa citiranosti dobivena za članke sa dvije stranice u grani Kemije i tri ili četiri stranice za fiziku je relativno visoka. Ovakvi članci se obično objavljuju u časopisima s visokim faktorom utjecaja. Za kemiju, većina tih rada su objavljeni u časopisima kao što su *Angewandte Chemie International Edition*, *Chemical Communications* i časopis *The American Chemical Society* klasificiranih prema časopisu kao komunikacija, dok je u WoS oni se smatraju člancima. Za fiziku, ovi rade su objavljeni u časopisima kao što su *Applied Physics Letters*, *Optics Letters*, *IEEE Photonics Technology Letters* ili *Journal of Applied Physics* gdje je prosječan broj stranica po dokumentu između tri i četiri.

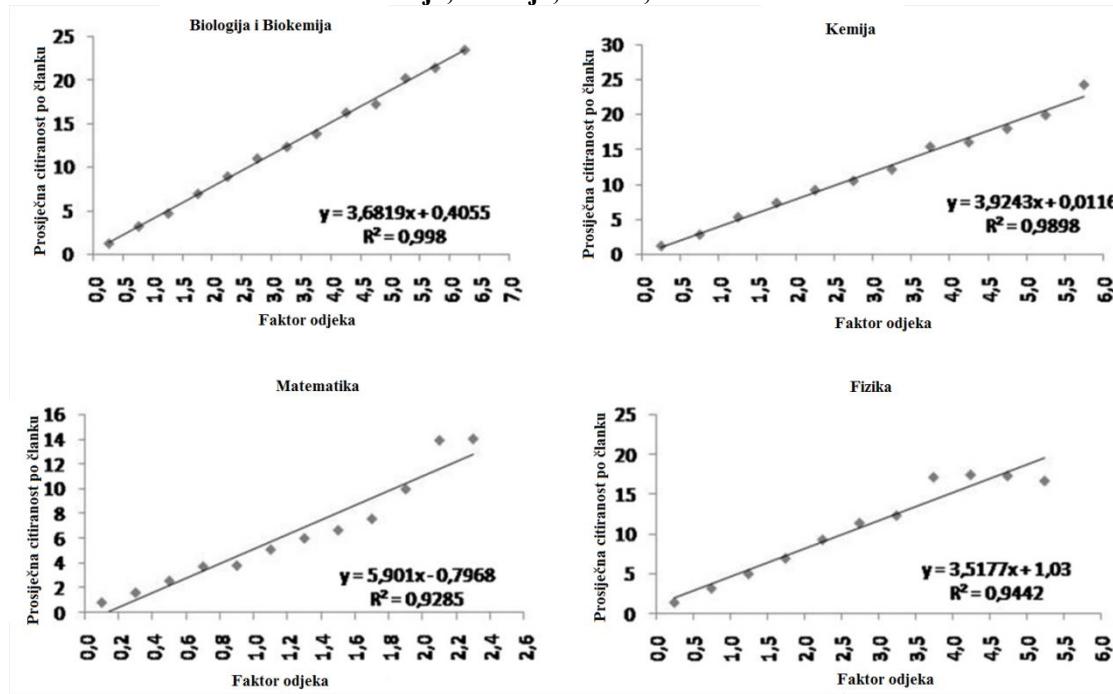
Na slici 27. je iscrtan prosječan utjecaj članka u odnosu na broj referenci za biologiju i biokemiju, kemiju, fiziku i matematiku sa procjenom standardne devijacije aritmetičke sredine prikazane kao greška. Ovisnost je vrlo jasna, ali malo izvan linearog ponašanja i to se manifestiralo kao relativno nizak koreacijski koeficijent. Prosječan broj referenci po dokumentu je najviši za biologiju i biokemiju (36,76). Za kemiju, fiziku i matematiku prosječna broj referenci je 28,64, 24,11 i 18,25. Za biologiju i biokemiju možemo primjetiti da skup članaka s dvije reference ima prosječan utjecaj daleko iznad onoga što bi se očekivalo. To je zbog jednog članka sa 207 citata koji utječe na prosjek od samo 37 članaka s

dvije reference. Ovaj netipičan dokument pridonosi velikoj grešci. Članci sa samo nekoliko referenci imaju vrlo mali prosječan broj citata, daleko ispod onoga što predviđa regresijski pravac u svim područjima osim u matematici gdje su došli blizu predviđenog.

Za sva područja, povećanje standardne devijacije raste s povećanjem broja referenci zbog manjeg broja članaka. Slika 28. prikazuje varijacije prosječne stope citiranosti u razdoblju od 5 godina razmatranu usporedno sa faktorom odjeka časopisa. Greške standardne devijacije prosječne citiranosti po članku nisu prikazane u ovom grafu, budući da su premale da bi se vidjele. Faktor odjeka časopisa u ovom istraživanju varira između 0,048 i 24,007 za biologiju i biokemiju, između 0,051 i 10,232 za kemiju, između 0,090 i 2,426 za matematiku i između 0,121 i 7,072 za fiziku. Prosječni faktor odjeka je za biologiju i biokemiju 3,585, za kemiju 2,435, za matematiku 0,663 i 2,488 za fiziku. Valja napomenuti da je ovaj prosjek dobiven kao omjer broja citata u 2004-2008 članaka datiranih od 2004, dok *Thomson Reuters* razmatra sve citate u 2006. podijeljene sa brojem članaka objavljenim u 2004. i 2005. godini. Broj članaka koji su objavljeni u časopisima, a koji nisu u 2006 JCR je 3,2%, 0,84%, 0,35% i 2,7% od ukupnog broja u biologiju i biokemiju, kemiju, matematiku i fiziku. Na slici 26. prikazane su samo točke koje odgovaraju faktoru odjeka sa 50 ili više članaka (u jednom ili više časopisa). Trebalo bi napomenuti da linije na slici 28. možda su prilagođene da idu kroz ishodište, ali to ne bi trebalo promijeniti zaključak budući da nagib trpi manje promjene, a koeficijent R^2 smanjuje se za manje od 0,01. Koeficijenti korelacije idu od 0,998 u biologiji i biokemiji do 0,93 u matematici. Međutim, koristeći različite vremenske raspone, uvodi učinak vremenskog citata koji će vjerojatno varirati od faktora odjeka časopisa. . Sličnu raspršenost mogli bismo naći u grafu između petogodišnjeg faktora odjeka u odnosu na dvogodišnji faktor odjeka WoS-a. Kako bi se procijenila među korelacija između pet nezavisnih varijabli promatranih u ovoj studiji, odredili smo Spearmanov koeficijent. Za svako polje koje smo istraživali najveća vrijednost Spearmanovog koeficijenta pojavljuje se između broja autora i broja adresa [0,48–0,70] i između broja stranica i broja referenci [0,50–0,57]. Međutim, ove vrijednosti nisu visoke i sugeriraju umjerenu među korelaciju. Za među korelaciiju između ostalih varijabli, vrijednosti dobivene za Spearmanov koeficijent ukazuju na slabu ili vrlo slabu korelaciju. Vrijednosti dobivene za Spearmanov koeficijent ukazuju na to da broj adresa i broj stranica se ne bi trebali uzeti kao zasebne varijable u budućim istraživanjima. Broju referenci bi se trebalo dati prednost budući da broj stranica ovisi o formatu tiskanja časopisa. Što se tiče broja adresa, ovo bi se moglo smatrati da je ovisno o broju autora, ali ne i obrnuto. To sugerira da samo jedan od tih faktora treba uzeti u obzir u studiji pri korištenju podataka citiranosti.



Slika 27. Prosječna citiranost članka u odnosu na broj referenci za područja Biologije i Biokemije, Kemije, Fizike, Matematike

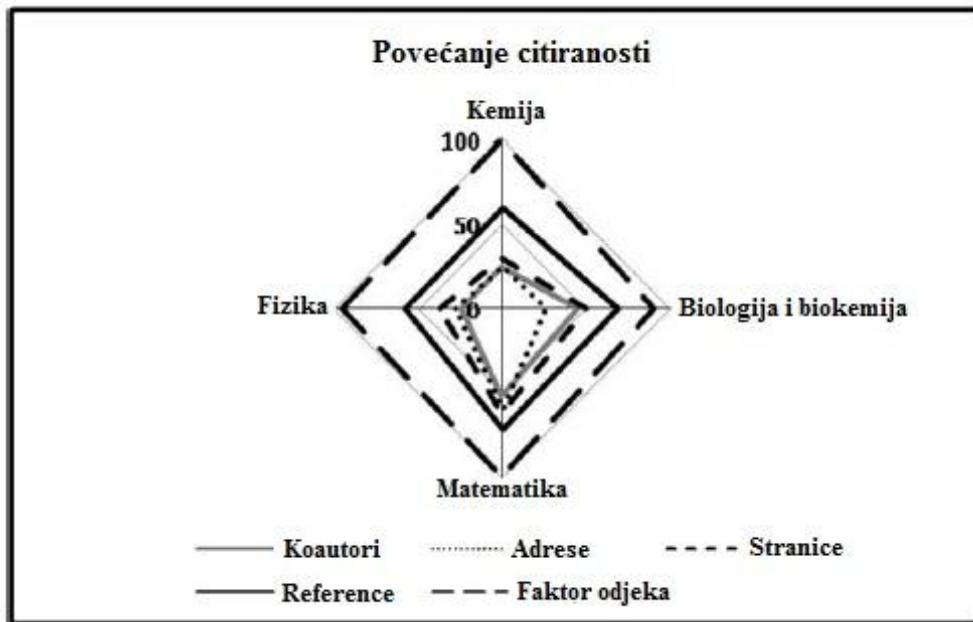


Slika 28. Prosječna citiranost članka u odnosu na faktor odjeka za područja Biologije i Biokemije, Kemije, Matematike i Fizike

Ovisnost nađena između citiranosti članka i pet svojstava koje smo naveli je dosta čvrsta u smislu da možemo predvidjeti da će rezultati citata (2003-2008) dobivenih recimo iz publikacija objavljenih 2003 g. potkrijepiti one dobivene za 2004 . S druge strane, korelacija pronađena kod prosječnih vrijednosti citiranosti velikih skupina dokumenata ne dopušta direktne zaključke za individualne dokumente. Ovo se može vidjeti u standardnim devijacijama aritmetičkih sredina vidljivim na slikama 25-29 iz kojih se vidi da su korelacije vrlo male, ali odgovaraju velikim populacijama. Poboljšanje citiranosti prikazano je u tablici 21. i na slici 29, a odnosi se na povećanje prosječne citiranosti, kada idemo sa aritmetičke sredine na dvostruku aritmetičku sredinu svake nezavisne varijable. Faktor utjecaja je varijabla na kojoj se taj efekt vidi najviše. Vidimo da prosječna citiranost po članku objavljenom u časopisu sa faktorom odjeka dvostrukе vrijednosti aritmetičke sredine ima također dvostruko veći faktor odjeka u odnosu na časopise u kojima je faktor odjeka slične vrijednosti kao i aritmetička sredina. Ovo također vrijedi i za druga navedena znanstvena područja osim za matematiku, gdje je porast dvostruko veći. Za faktor odjeka, vrlo velika vrijednost povećanja citiranosti na području matematike može se objasniti sa velikom vremenskom razlikom između citata. Naravno to je izravna posljedica Garfieldove definicije faktora utjecaja časopisa koji se koristi u WoS-u. Kad uzmemu u obzir utjecaj broja referenci, povećanje od prosječne citiranosti po časopisu varira od 58 % za Fiziku i 72 % za Matematiku. Dvostruko povećanje broja stranica članka od prosječne rezultira povećanjem citiranosti članka od 30 % za kemiju do 62 % za matematiku. Kod povećanje broja adresa u članku,došlo je do povećanja citiranosti od 25 % u kemiji do 60 % u matematici. I konačno, broj koautora članka utječe na poboljšanje citiranosti od 24 % za fiziku do 52 % za matematiku. Linije na slici 29. predstavljaju svaku od pet varijabli i njihovu interakciju sa xx-osi i yy-osi koja predstavlja postotak povećanja u svakom polju. Znanstveno polje matematike vidljivo ima najveći efekt utjecaja ovih pet varijabli koje su uzete u obzir. Najmanji utjecaj su imale na polje kemije i fizike. Faktor utjecaja je varijabla sa najvećim povećanjem, nakon čega slijedi broj referenci i broj stranica. Poboljšanja vezana za broj koautora i broj adresa su otprilike ista za kemiju matematiku i fiziku, ali vidljivo različita za biologiju i biokemiju. [4].

Tablica 19. Distribucija članaka u odnosu na neka od svojstava članka i njihov utjecaj na povećanje citiranosti

Varijable	Biologija i biokemija	Kemija	Matematika	Fizika
<i>Koautori</i>				
Prosjek	4,84	3,98	1,84	3,9
Stand. dev.	2,65	4,40	0,90	38,98
R^2	0,837	0,845	0,880	0,850
Povećanje citiranosti	45%	25%	52%	24%
<i>Adrese</i>				
Prosjek	2,25	1,75	1,62	2,11
Stand. dev.	1,25	0,86	0,80	6,5
R^2	0,906	0,954	0,965	0,843
Povećanje citiranosti	26%	25%	60%	28%
<i>Stranice</i>				
Prosjek	8,69	6,89	17,82	9,72
Stand. dev.	4,24	4,04	13,98	6,69
R^2	0,666	0,335	0,864	0,615
Povećanje citiranosti	50%	30%	61%	37%
<i>Reference</i>				
Prosjek	26,76	28,64	18,25	24,11
Stand. dev.	17,04	17,17	12,27	6,69
R^2	0,917	0,858	0,799	0,615
Povećanje citiranosti	69%	60%	72%	58%
<i>Faktor odjeka</i>				
Prosjek	3,585	2,435	0,663	2,488
Stand. dev.	2,51	3,75	0,40	2,79
R^2	0,998	0,989	0,929	0,944
Povećanje citiranosti	97%	99%	125%	89%



Slika 29. Povećanje citiranosti u postocima u odnosu na inicijalnu vrijednost kada se promatrana varijabla poveća dvostruko u odnosu na njezinu početnu vrijednost

Ovo istraživanje ovdje predstavljeno prikazuje nam određeno ovisnosti između spomenutih značajki članka i prosječne citiranosti članka, što je suprotno onome što su neka druga istraživanja sugerirala (Herbertz, 1995; Seglen, 1994). Ostali zaključci su sljedeći:

- Prosječna citiranost po članku je najveća u biologiji i biokemiji, gotovo ista za fiziku i kemiju i najmanja za matematiku
- Distribucija citiranosti dobro je opisana sa dvostrukom eksponencijalnom - Poissonovom raspodjelom za sva područja
- Rezultati su pokazali ovisnost prosječne citiranosti po članku o nekim značajkama članka, iako ova ovisnost može biti daleko od linearne u nekim slučajevima. Ovo je također demonstrirano od Bornmanna i Daniela 2006 godine, ali oni su koristili negativan binomni regresijski model.
- Biologija i biokemija imaju najveći broj koautora po članku, dok matematika najniži. Za biologiju i biokemiju, kemiju i fiziku možemo vidjeti da aritmetička sredina citiranosti članaka sa jednim autorom je niža od onog dobivenog ekstrapolacijom vrijednosti za dva ili više autora.
- Prosječan broj adresa po dokumentu je gotovo isti u svim područjima.
- Jednostranični članci imaju vrlo mali utjecaj u svim poljima. To je zbog određenih vrsta dokumenata koje WoS svrstava kao članke.
- Prosječan broj referenci po dokumentu je najveći u Biologiji i Biokemiji dok je najniži u Matematici [4].

5. FAKTOR ODJEKA ZNANSTVENIH PODRUČJA MATERIJALA I MULTIDISCIPLINARNIH ZNANOSTI

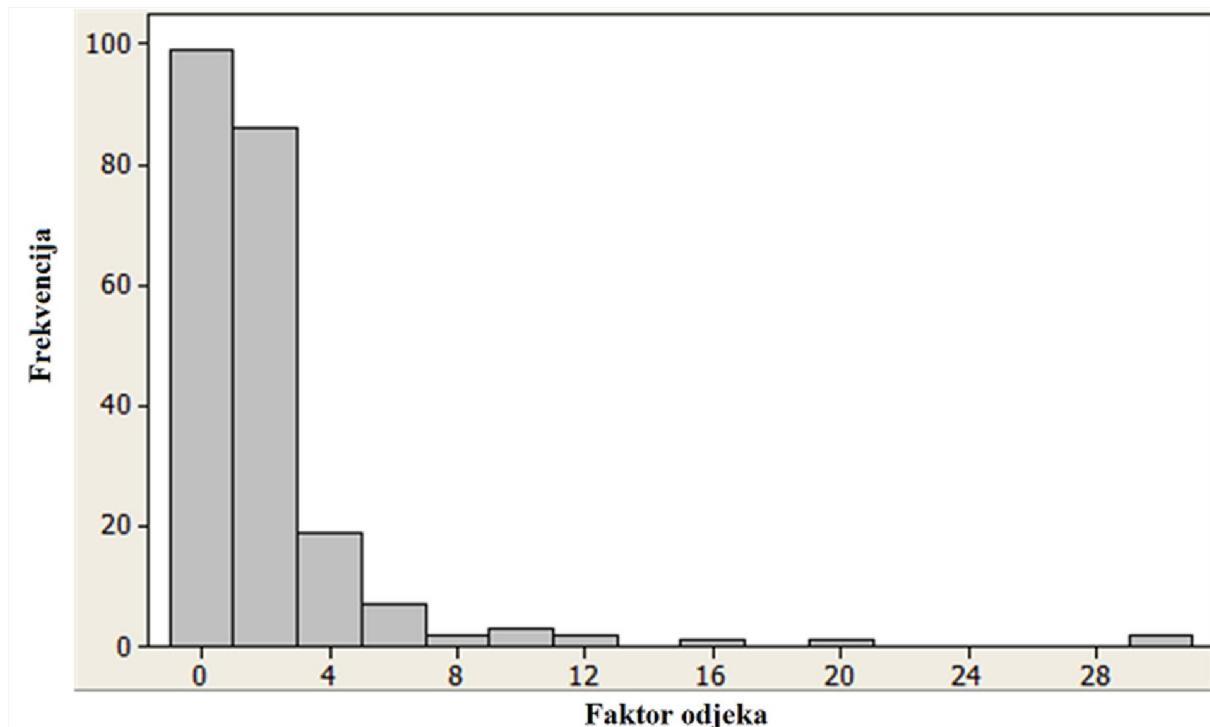
Da bi mogli znati kako se ponaša faktor odjeka u nekom znanstvenom području potrebni su nam svi faktori odjeka časopisa u tom području. Časopisi koje se promatralo u ovom radu vezani su za znanstvena područja materijala i multidisciplinarnih znanosti. Nakon što je odabранo znanstveno potrebno je bilo prikupiti od nekuda sve faktore odjeka časopisa koje spadaju u to promatrano područje, a do tih podataka moguće je doći pomoću WoS-ove baze podataka. U WoS-ovoj bazi postoji mogućnost da se iz listaju svi časopisi istog znanstvenog područja, također potrebno je odabrati godinu za koju će nam baza izbaciti podatke. U ovom slučaju odabrana je 2010. godina. Kada je to napravljeno dobiva se tablica podataka časopisa posložena po alfabetском redu. Ove podatke možemo vidjeti u tablici 16.

Tablica 20. Metrički pokazatelji časopisa za znanstveno područje materijala i multidisciplinarnih znanosti

Rank	Abbreviated Journal Title (linked to journal information)	ISSN	JCR Data (j)						Eigenfactor® Metrics (j)	
			Total Cites	I _j	5-Year Impact Factor	Immediacy Index	Articles	Cited Half-life	Eigenfactor® Score	Article Influence® Score
1	ACI MATER J	0889-325X	1928	1.023	1.155	0.083	72	>10.0	0.00397	0.659
2	ACI STRUCT J	0889-3241	2050	0.782	1.076	0.107	84	>10.0	0.00492	0.620
3	ACS APPL MATER INTER	1944-8244	1482	2.925	2.925	0.597	516	1.4	0.00684	0.881
4	ACS NANO	1936-0851	9914	9.865	9.962	1.478	986	1.8	0.05575	3.393
5	ACTA MATER	1359-6454	29025	3.791	4.367	0.732	653	6.5	0.09968	1.754
6	ACTA MECH SOLIDA SIN	0894-9166	277	0.543	0.586	0.000	38	5.0	0.00094	0.178
7	ADV CEM RES	0951-7197	316	0.651	0.757	0.607	28	9.2	0.00081	0.407
8	ADV ENG MATER	1438-1656	3250	1.746	2.011	0.128	243	5.6	0.01258	0.736
9	ADV FUNCT MATER	1616-301X	22516	8.508	9.442	1.202	481	3.8	0.11097	3.075
10	ADV MATER	0935-9648	68115	10.880	11.306	2.097	777	5.2	0.24245	3.765
11	ADV MATER PROCESS	0882-7958	357	0.192	0.216	0.053	57	9.5	0.00048	0.064
12	ANN CHIM-SCI MAT	0151-9107	389	0.171	0.309	0.000	21	>10.0	0.00049	0.109
13	ANNU REV MATER RES	1531-7331	4668	10.333	10.561	0.909	22	9.7	0.00990	5.206
14	APPL PHYS A-MATER	0947-8396	11157	1.765	1.938	0.271	557	6.3	0.03444	0.677
15	ARCH CIV MECH ENG	1644-9665	51	0.383		0.057	35		0.00027	
16	ATOMIZATION SPRAY	1044-5110	714	0.928	0.917	0.103	58	>10.0	0.00152	0.362
17	B MATER SCI	0250-4707	1665	0.944	1.231	0.071	112	7.0	0.00399	0.354
18	CARBON	0008-6223	23855	4.896	5.728	1.025	559	6.3	0.05849	1.604
19	CEMENT CONCRETE RES	0008-8846	9293	2.187	2.553	0.351	191	8.9	0.01908	0.978
20	CHALCOGENIDE LETT	1584-8663	192	0.836	0.959	0.244	86	2.1	0.00058	0.174

U tablici 20. Može se vidjeti metričke pokazatelje časopisa kao ukupan broj citata, faktor odjeka, 5 godišnji faktor odjeka, indeks brzine citiranja, broj članaka časopisa, poluvijek citiranja itd. Za potrebe rada odabran je stupac označen sa strelicom tj. faktor odjeka časopisa. Utvrđeno je da promatrano znanstveno područje ukupno sadrži 225 časopisa, ali za nekoliko časopisa nije prikazan faktor odjeka iz razloga što je prekratko u bazi da bi se faktor odjeka tih časopisa mogao izračunati. Od 225 časopisa tri nisu imala izračunat faktor odjeka u tablicama, ovo bi značilo da ova tri časopisa su manje od tri godine u WoS-ovoj bazi, koliko

je potrebno da bi se izračunao faktor odjeka. Nakon što su se unijeli svi podaci u statistički program Minitab 16, program je iscrtao distribuciju faktora odjeka koju možemo vidjeti na grafu 10.



Graf 10. Raspodjela faktora odjeka znanstvenog područja materijala i multidisciplinarnih znanosti

Tablica 21. Statistički podaci faktora odjeka za znanstveno područje materijala i multidisciplinarnih znanosti

Varijabla	N	Aritm. sred.	SE St.dev	St. dev.	Var.	Suma	Q1	Median	Q3	Maks.
C1	222	2,16	0,248	3,693	13,635	479,435	0,569	1,107	2,081	30,324

Raspon vrijednosti faktora odjeka časopisa kreće se od 0,024 do 30,324, budući da se većina faktora odjeka kreće u vrijednosti od 0 do 5, vrijednosti na apscisi i ordinati su raspoređene tako da se mogu vidjeti na grafu zbog bolje preglednosti. Utvrđeno je da 91 % časopisa spada u razred gdje je vrijednost faktora odjeka 0-5. Ovo potvrđuje Bradfordovu (Paretovu) distribuciju da većinu citata dobiva oko 10 % svih časopisa, tzv. jezgra znanja. Na grafu 10. može se primijetiti da distribucija ima „dug rep“. Dugi rep je naziv za već dugo poznato svojstvo nekih statističkih distribucija (poput Zipfovog zakona, zakona moći, Paretove distribucije i opće Lévyeve distribucije). Svojstvo je također znano pod nazivima "debeli rep", "rep zakona moći" i "Paretov rep". Kod distribucija dugog repa populaciju visoke frekvencije

ili visoke amplitude slijedi populacija niske frekvencije ili niske amplitude, koja postupno asimptotski "odlazi u rep" (krivulja teži k nuli u beskonačnost). Događaji na udaljenom dijelu repa imaju vrlo nisku vjerojatnost ostvarivanja. Svaka od ovih distribucija mogla bi opisivati distribuciju faktora odjeka , da bi točno mogli utvrditi koja najbolje odgovara promatranom grafu potrebna bi bila detaljnija analiza.

Ukupna suma svih faktora odjeka odabranog područja iznosi 479,435 na 222 časopisa u znanstvenom polju, daje prosječan faktor odjeka od 2,160. Ako uzmemo u obzir da se većina članaka nalazi u prozoru 0-5 faktora odjeka , možda bi bolja mjera za srednju vrijednost bio medijan koji iznosi 1,107, koji nam govori da časopis koji je po sredini na rang listi svih časopisa ima faktor odjeka 1,107 tj časopisi na 110. i 111. mjestu. Znajući ovu činjenicu možemo sa sigurnošću reći da dva internacionalna časopisa koji su bili predmet ovog rada sa svojim faktorima odjeka od 10,88 i 16,658 spadaju u top 10 % časopisa promatranog znanstvenog područja. Nažalost stanje u Hrvatskoj znanosti je poražavajuće što i govori faktor odjeka hrvatskog tehničkog časopisa promatranog u ovom radu čiji je faktor odjeka za 2010. godinu iznosio 0,083, iako je 2011. godine iznosi 0,3 to je daleko od neke ozbiljnije vrijednosti faktora odjeka koja bi Hrvatsku stavila u nešto povoljniju poziciju u odnosu na svjetsku znanost.

5.1. Prednosti i nedostaci faktora odjeka

Faktor odjeka načelno je napravljen za mnoge druge svrhe, ali se najviše koristi kao mjerilo procijene kvalitete individualnog znanstvenog rada. Sama ideja korištenja ovakvog alata i nije bila loša, ali s vremenom se otkrilo da se s ovakvom metodom može značajno manipulirat, te u konačnici dolazi do toga da se izašlo izvan okvira za koje je ova metoda u srži bila napravljena. Zbog same širine manipulacije faktorom odjeka u današnje vrijeme sama kvaliteta znanstvenog rada ne bi se smjela mjeriti samo sa faktorom odjeka, a sam faktor odjeka bi se trebao koristiti sa oprezom i ne bi smio biti dominantno mjerilo pri ocjeni rada.

Objava istraživanja u znanstvenim časopisima je mehanizam kojim se najnovija otkrića, zanimljive informacije i nova znanja službeno objavljaju u znanstvenoj zajednici. Identifikacija i evaluacija istraživanja visoke znanstvene vrijednosti je važan, ali težak zadatak. Stoga, kvantitativna metoda mjerjenja kvalitete članka kao što je faktor odjeka je sve popularnija i postaje sve više kao surogat mjera za procjenu kvalitete znanstvenog članka. U nekim zemljama, JIF se koristi i kao kriterij za procjenu financiranja projekta, zatim za procjenu efikasnosti istraživačkog osoblja i često se koristi pri procjeni bonusa na plaću znanstvenika. Međutim jedan faktor ne može mjeriti znanstvenu vjerodostojnost članka,

kvalitetu časopisa, pojedince, specifične istraživačke projekte ili istraživačke institucije. Doista, zbog ovih i drugih razloga bilo je mnogobrojnih članaka koji su kritizirali korištenje JIF-a kao mjeru za kvalitetu članka i mjeru za kvalitetu časopisa. U ovom dijelu rada sažet će se glavna pitanja vezana za problematiku korištenja JIF-a kao glavno mjerilo za kvalitetu. Dosta znanstvenika tvrdi da ovakav način ocjenjivanja negativno djeluje na polja i znanstvenike koji rade u poljima niskog faktora odjeka i za posljedicu može imati lošu istraživačku kvalitetu. Glavni problemi vezani za citat analize i korištenje JIF-a predstavljeni su u tablici 22.

Institut za znanstvene informacije (ISI) u Philadelphia, SAD, stvorio je bazu podataka koja kontinuirano kodira sve reference koje se nalaze u referentnim listama članka iz 13,673 časopisa unutar prirodnih znanosti (od 2005). Međutim, ovo je samo mali dio od ukupnog broja (126 000) znanstvenih časopisa u svijetu (od 1996). Štoviše, ISI-jeva baza podataka nastoji omogućiti dovoljno zastupljenosti na svim specijaliziranim područjima, s time odabrani časopisi ne moraju nužno obuhvaćati one časopise koji su najviše citirani. ISI baza podataka ima sklonost uglavnom odabirati časopise sa engleskim govornim područjem i najviše je zastupljena u Sjeverno Američkim publikacijama. Ova jezična pristranost dodatno je pojačana od strane autora članaka koji najčešće citiraju članke na svom jeziku. Procijenjeno je da u 1995 g. većina citata u bazi dolazi od strane američkih znanstvenika, koji su skloni citirati jedne druge, na taj način podižući stopu citiranosti za 30 % iznad svjetskog prosjeka. Citat indeksi skupljaju bibliografske citate samo iz članka časopisa, a ne iz knjiga, poglavila u knjizi ili iz konferencijskih skupova. Ove ne-članačke publikacije ulaze u citirane reference, ali citati se uvažavaju samo ako su iz nekog članka. Greške vezane za citate mogu nastati i da se citati koji ne bi smjeli ulaziti u citate ipak ulaze, recimo ako se citira uvodni članak časopisa, osoba koja ga je napisala dobit će citat u bazi iako to ne bi smjela po pravilima. Kako ISI baza se ne korigira za samo citiranje, to ostavlja mogućnost da urednici, možda nenamjerno "napušu" faktor odjeka časopisa citirajući svoje uvodne članke. Časopisi su oštroskažnjavani zbog objavljuvanja dijelova znanstvenih skupova, jer su uvršteni u nazivnik JIF jednadžbe, ali ne i u brojnik. Na ovaj način JIF je smanjen, iako takvi skupovi imaju visoku obrazovnu vrijednost. Međutim, neselektivno uključivanje svih vrsta publikacija kao izvor bi nepravedno smanjilo JIF, budući da većina tih publikacija nikad ni nije bila namijenjena citiranju [5].

Tablica 22. Problemi vezani za citatne analize i korištenje JIF-a

Tehnički problemi ISI baza podataka	Učinci znanstvenog polja	Selekcija reference i motivacija citera	Problemi povezani sa korištenje faktora utjecaja časopisa
Pristranost prema engleskom govornom području	Obujam znanstvenog polja	Primarni kriterij izbora reference nije kvaliteta, već sličnost promatranom istraživanju	JIF se odreduje tehnikalijama nevezanim za znanstvenu kvalitetu časopisa
Pristran uzorak časopisa uključen u bazu podataka	Dinamika polja (ekspanzija ili kontrakcija)	Nepotpuno referenciranje zbog ograničenog prostora u časopisu	JIF nije statistički predstavnik pojedinog članka
Različita pokrivenost bazom podataka između znanstvenih polja	Tip znanstvene teme	Kopiranje reference	Distribucija citata članaka unutar istog časopisa su neujednačene
Knjige, konferencije, zbornici, pisma, nisu uključeni kao izvor citata	Među odnosi u polju (npr : klinička medicina se oslanja na temeljne znanosti, ali ne i obrnuto)	Laskanje (citiranje urednika časopisa)	JIF je u slaboj korelaciji sa stvarnim brojem citata pojedinog časopisa
Kašnjenje sa registracijom citata	Znanstvena područja sa literaturom koja brzo zastarjeva su favorizirana	Samo citiranje	Nema mehanizma za ispravljanje samo citiranja
Pogreške u prijepisu ili tisku (do 25 %)		Češće citiranje bliskih kolega	Selektivno samo citiranje u časopisu: Autori članaka imaju tendenciju da citiraju druge članke u istom časopisu
Sinonimi (nekoliko varijanti istog članka)		Visoka citiranost sažetaka	JIF je funkcija broja referenci po članku u području istraživanja
Homonimija (nekoliko autora s istim imenom)		Korisnost pri istraživanju, rađe nego čista znanstvena kvaliteta je primarni cilj pri izboru reference	Kratak put publikacije rezultira visokim JIF-om
Vrijeme izdavanja članka penalizira grane koje češće izdaju članke			Nacionalna pristranost u referentnom izboru preferira Američke časopise
			Sažeci članaka visoko su citirani što rezultira višim JIF-om

5.1.1. Efekti istraživanja znanstvenog polja

Učinci istraživačkih polja su složeni. Glavni problem pri korištenju JIF-a za znanstvene evaluacije je da faktor ne dopušta usporedbe između različitih područja istraživanja. Na stopu

citiranost i JIF može utjecati izbor znanstvenog polja, dinamika polja, i veličina znanstvenog područja. Znanstvenici se češće odlučuju na izbor teme koja će vjerojatno biti više citirana. Znanstvenici koji rade u područjima koja se brzo razvijaju, kao što je npr; stečeno imuno-deficijentni sidrom (SIDA), vjerojatno će imat veću stopu citiranosti u odnosu na istraživače koji rade u području istraživanja dječje osteoporoze. Razlog tome je što istraživanje vezano za AIDS je relativno novo istraživačko područje i tu će biti mnogo citatora u odnosu na postojeće materijale. U velikim istraživačkim poljima, prosječna stopa citiranosti trebala bi biti neovisna o veličini istraživačkog polja. Međutim, širina citiranosti će vjerojatno biti šira u polju istraživanja koje je veće, s time osiguravajući bolje izglede da nekolicina istraživača u tom polju postanu vrlo citirani.

5.1.2 Preporuke

Predložen Benchmarch od Scientific Merit (znanstvene zasluge)

Zbog brojnih nedostataka JIF-a i njegove mogućnosti manipulacije predložene su neke nove metode ocjenjivanja znanstvenih radova u različitim literaturama koje su prikazane u tablici 23; međutim, ne postoji konsenzus oko nove bolje alternative JIF-u. Predloženo je da odgovarajuće metode za usporedbu kvalitete znanstvenih članaka, znanstvenih zasluga pojedinaca i institucija budu više faktorijalne. Niti jedna jednostavna ili sažeta metoda nije dovoljna da bi se procijenila kvaliteta znanstvenog rada. Neki od faktora bi se trebali uzeti u obzir pri procjeni kvalitete znanstvenog članka ili časopisa, kao što su recimo odgovarajuće statističke metode, konstrukcija same znanstvene studije, motivi izrade znanstvenog rada, mogućnost generaliziranja sa ostalim znanstvenim poljima, bilo kakvu mogućnost šire primjene u znanstvenoj zajednici.

Istraživači bi trebali svoje napore usredotočiti na radove koji će biti visoke znanstvene vrijednosti, a ne na one radove koji su popularni i s time ciljati na visok faktor odjeka. U određenim uvjetima, lokalni ili nacionalni utjecaj znanstvenog rada može biti od veće važnosti nego utjecaj tog istog rada na svjetskoj razini. Analiza citata ne bi smjela bit skraćeni put ukupne procijene, već to bi trebala bit početna točka temeljne analize znanstvenog rada.

Tablica 23. Prijedlozi alternativa JIF-u

Problem	Preporučene alternative	Komentari
Utjecaj u polju	Podjela stope citiranosti sa JIF-om	Povećava faktor slabije citiranih časopisa, a smanjuje faktor bolje citiranih časopisa
	Kreiranje zasebnog faktora utjecaja za svako znanstveno polje	Nefleksibilno i ne tako korisno
Pristranost baza podataka	Svaki jezik svoja baza podataka ili svaka znanstvena grana svoja baza podataka	Financijski skupo u smislu održavanja podataka i ljudskih resursa
		Ne možemo se osloniti na podskup časopisa, budući da neki znanstvenici rade u uskim područjima i svoje radove objavljaju u općim časopisima
Problem vremenskog perioda izdavanja članka	Povećati izračun faktora utjecaja časopisa sa 2 godine na 5 ili 10 npr.	Ne ispravlja u potpunosti vremena izdavanja određenih časopisa
Različite discipline	Ponderirani JIF: Pomnožimo JIF sa koeficijentom koji bi neutralizirao razlike između znanstvenih disciplina. Ovo se može izračunati na načina da se usporedi JIF časopisa sa najvišim JIF-om u toj grani	Vanske usporedbe i usporedbe časopisa unutar polja mogu dati iskrivljenu sliku, budući da su u obzir uzeti samo specijalizirani časopisi. Stvarna dodjela ranka specijaliziranom časopisu od Instituta za znanstvene informacije neće se uvjek poklapati sa mišljenjem stručnjaka u tom području koji je časopis najutjecajniji na tom području
	Istraživačke institucije mogle bi kreirati grupaciju vlastitih specijaliziranih časopisa	Tailor-izvedbe vrlo su osjetljive na manipulaciju i u konačnici može doći do stanja u kojem se ne može raditi Manje je jasno kako popularnost unutar discipline se može neutralizirati
Relativni faktor utjecaja	Usporedba aktualnog broja citata članka sa prosječnim brojem citata časopisa u kojem je objavljen	Ovo bi moglo smanjiti društvene razlike između časopisa i moglo bi skrenuti pozornost na članke u manje cijenjenim časopisima

5.1.3 Vrednovanje znanstvene vrijednosti u svim specijaliziranim časopisima

Stvarna dodjela ranka specijaliziranom časopisu od Instituta za znanstvene informacije neće se uvijek poklapati sa mišljenjem stručnjaka u tom području, po pitanju koji je časopis najutjecajniji na tom području. Primjerice, Internacionalni časopis *Leprosyranks* nalazi se među top časopisima tropске medicine, ali nije uključen u kategoriju zaraznih bolesti. Isto tako, časopis *Parasitology Today and Tomorrow* koji se bavi parazitologijom nije uključen u kategoriju tropске medicine, a uglavnom objavljuje članke vezane za tropске bolesti. Da su ovi časopisi smješteni u predložene kategorije njihov JIF bi se sigurno povećao. Istraživačke institucije moguće bi kreirati grupaciju vlastitih specijaliziranih časopisa koje bi moguće odgovarati bolje na svojem području interesa; međutim ovakva rješenja mogu naginjati prema vlastitoj proizvoljnoj manipulaciji i moglo bi rezultirati situacijom u kojoj nije moguće raditi. Također nije poznato rješenje kako bi se popularnost znanstvenika ili institucija unutar područja neutralizirala. Dakle stopa citiranosti znanstvenika koji rade u različitim područjima ne mogu se uspoređivati, a to pravilo bi se također trebalo primjenjivati u podspecijaliziranim poljima istog znanstvenog područja.

Nije korisno da npr: istraživačka tijela koja dodjeljuju potpore za određenu subvenciju, znanstveniku ili grupi znanstvenika, da ti isti znanstvenici moraju zadovoljiti određeni JIF. Možda bi bilo prikladnije da se od znanstvenika očekuje recimo objava 5 članaka u nekom poznatom časopisu umjesto da se od znanstvenika očekuje visok JIF iako njegovo područje nije tako "popularno". Tu bi onda vanjski stručni recenzenti ocjenjivali dali su ti časopisi dovoljno visoke kvalitete i ako jesu znanstveniku bi onda bila odobrena subvencija predviđena za projekt [5].

5.1.4 Netočno tumačenje indikatora kvalitete

ISI je komercijalna tvrtka kojoj je primarni cilj pružiti istraživačima pristup podacima visoke kvalitete kako bi istraživači svoje istraživanje mogli što bolje obaviti. JIF je izvedena mjera kako bi mogli uspoređivati različite časopise, tako da možemo izuzet časopise visoke kvalitete. Korištenje analize citata i JIF-a postao je primarni postupak pri procjenjivanju kvalitete znanstvenog istraživanja. Budući da se časopisi mogu uspoređivati, zbog velike mogućnosti usporedbe može doći i do pre interpretiranosti te zbog toga može istraživače navesti prema krivom zaključku koji se možda i ne bi dogodio da su se više oslanjali na svoje

istraživanje. JIF se također koristi kako bi se procijenila relativna važnost istraživača, istraživačkom programa te ustanove (instituta) u kojoj se vrše istraživanja. Međutim JIF je samo vremenski definira stopu citiranosti i ništa više. Nešto što se naziva JIF ne bi trebalo bit zloupotrijebljeno za procjenu vrijednosti časopisa ili za potvrdu vrijednosti pojedinog istraživača i istraživačkog programa, a posebice u donošenju odluka zapošljavanja znanstvenika i financiranja njihovih istraživanja. JIF ima sve utjecajniju ulogu, budući da autori i institucije su često ocjenjeni i financirani samo na temelju broja publikacija izdanih u časopisima sa visokim faktorom odjeka. Ipak, kao indikator kvalitete pojedinca i institucije JIF je često kritiziran zbog toga što se može s njime manipulirati. Postoji opća zabrinutost da je sve više uredničkih odluka časopisa orijentirano člancima koji će donijeti profit časopisu, a sve manje odluka orijentirano da radovi pridonesu općem znanstvenom dobru. Indikatori kvalitete su vrlo nepovoljna mjera ocjenjivanja kvalitete manjih istraživača, grupa ili pojedinaca. Što je specifičnija JIF bazirana procjena to je ta ista procjena češće bivana osporavana. Pojedina citiranost članka određuje JIF, a ne obrnuto. Sam kreator JIF je izjavio da je netočno suditi članak prema faktoru odjeka časopisa u kojem je objavljen. [5].

5.1.5 Utjecaj JIF-a na autorovo ponašanje

Za rezultate određenih istraživanja koja su usko vezana za određeno područje bit će prikladnije da se objave u nekom lokalnom časopisu budući da će imati veći utjecaj na čitatelje koji žive na tom području. Međutim, stavlјajući naglasak na časopise sa visokim faktorom odjeka može izazvati to da autori šalju svoje radeve časopisima koji nisu najprikladniji za objavu njihovih rada. Mnogi znanstvenici vjeruju da objavom svojih rada u časopisima sa visokim JIF-om će povećati citiranost njihovih rada u odnosu na manje poznate časopise. Otkad su institucije za financiranje počele koristiti JIF za mjerilo raspodjele sredstava znanstvenim institucijama ili pojedincima, uslijedilo je to da su znanstvenici počeli slati svoje najbolje radeve časopisima sa visokim JIF-om i time su indirektno časopisi u zemljama gdje nema časopisa sa jako visokim JIF-om počeli dobivati manja finansijska sredstva i na taj način takvi su časopisi počeli polako propadati. Tako da danas u manjim zemljama domaći časopisi vrlo teško postižu visok JIF. Međutim i unatoč svim pokazateljima da manji časopisi propadaju JIF se i dalje u većini zemalja koristi kao primarno mjerilo za dodjelu sredstava istraživanju. JIF je jednostavan alat za usporedbu istraživačkog doprinosa na način da broji količinu autorovih rada i njegovu citiranost , ali na kraju što je zaista bitno, dali je to kvantiteta ili kvaliteta.

Stopa citiranosti opisana je sa jako mnogo tehničkih faktora na koje prava znanstvena kvaliteta može imati vrlo mali utjecaj. Vrlo je primamljivo dati veliku važnost naizgled objektivnom mjerilu kvalitete, ali uvezši u obzir tehničke nedostatke, ranjivosti, izobličenja, i manipulativnost ovih statističkih podataka, stopa citiranosti se vrlo lako može krivo protumačiti i trebalo bi je uzimati sa mjerom opreza. Statistika članaka i časopisa nikad ne bi trebala imati prednost nad detaljnom analizom kvalitete istraživanja. [5].

6. ZAKLJUČAK

Ovaj rad naglašava važnost uvođenja pouzdanih bibliometrijskih pokazatelja koji su svojstveni časopisu u smislu da oni ubrajaju što manje indikatora koji ne pripadaju određenom časopisu, kao što su podaci temeljeni na podacima iz drugih časopisa. Na taj način, naglasak je na izgradnji kompletног seta koherentnih neizostavnih bibliometrijskih pokazatelja za časopis. Slijedeći ovo, temelj za takav pristup je formuliran, ilustriran i analiziran, temeljen formalno na Pareto – sličnom funkcionalnom obliku za modeliranu funkciju vjerojatnosti distribucije citata. [9].

Nastojanje pronalaska zakona po kojem se distribuiraju citati već dugo postoji. Razlozi zašto ga je teško pronaći leže u činjenici da jako puno parametara utječe na citiranje članka. Prva činjenica od koje moramo krenuti da svaki članak mora biti odabran između ostalih članaka koji su poslani uredniшtvu nekog časopisa, uredniшtvu bira članke na temelju određenih parametara koji ne moraju biti isti za svaki časopis, osim pravila izbora članka tu je i subjektivan faktor ljudi koji biraju, koji članak ulazi u uži izbor, a koji ne. Poznato je da kultura citiranja svakog znanstvenog područja nije ista, tako recimo u Biomedicini imamo puno veću citiranost nego recimo u Matematici. Nadalje u današnje vrijeme kada tržiste definira gdje će se novci uložiti, a gdje neće u znanstvenim krugovima postoji sve veća potreba da se pišu članci "popularnih tema" kao recimo; razvoj baterija, smanjenje zagađenja, omega-3 kiseline itd. Osim ovih parametara koji nisu direktno vezani, tu su svojstva samog članka koja definiraju članak u WoS-ovoј bazi, a ona su : broj koautora, broj referenci, broj citata, broj adresa. Kroz rad se ukazalo na to da svi ovi parametri koreliraju sa citiranošću članka u većoj ili manjoj mjeri, ukazujući na to da je veća vjerojatnost da će članak biti bolje citiran, ako su mu spomenuti parametri broјčano veći. Recimo, ako rad ima veliki broj referenci postoji puno veća vjerojatnost da neko od autora u referencama u budućnosti citira taj rad. Uspoređujući distribucije citata tri časopisa utvrđeno je da se ne distribuiraju jednako citati časopisa koji objavljaju pregledne članke i citati časopisa koji objavljaju originalne znanstvene radove. Časopisi koji objavljaju originalne znanstvene radove puno češće objavljaju, samim time vjerojatnost da će objaviti lošiji rad je puno veća. Zato na lijevom dijelu grafova koji opisuju distribuciju citata ovakvih časopisa vidimo puno veću frekvenciju radova slabije citiranosti. U zadnjem poglavljtu ukazano je na to da faktor odjeka, koja je

najzastupljenija mjera procijene kvalitete časopisa je vrlo podobna manipulaciji zbog svoje jednostavnosti.

JIF je relativno jednostavna i isplativa analiza citata uspoređujući je sa podrobnom analizom citata. Međutim, JIF očito nije optimalna veličina za procjenu kvalitete iako to neki znanstvenici i urednici časopisa smatraju. ISI je svjestan većine nedostataka ovakve analize od samih početaka, te je upozorio da se njihovi alati ne koriste za individualnu procjenu. Ovi problemi ukazuju na to da nijedna metoda procjenjivanja je neprobojna mogućoj malverzaciji.

Kao i kod drugih mjeri višestrukih pojava, prijelaz iz kvalitativnih u kvantitativne mjerne može povući za sobom niz pogrešnih zaključaka. Korisnici JIF-a trebaju znati prednosti i nedostatke JIF-a i dobivene analize JIF-a uzimati sa dozom suzdržanosti, te ne bi trebali pre-interpretirati dobivene podatke, jer samo kada se podaci zloupotrebljavaju pogreške se javljaju. I zaključno: *Zanimljivo je kako se znanstvenici mogu osloniti na tako ne znanstvenu metodu procjene kvalitete znanstvenog rada kao što je faktor utjecaja časopisa u kojem je objavljen rad* (Steven Lock, Emeritus Editor ,British Medical Journal) [5].

Kao i kod svih mjeri kvalitete, kod tumačenje JIF-a treba uzimati u obzir sva njegova ograničenja.

LITERATURA

- [1] Jokić, M.: Bibliometrijski aspekti vrednovanja znanstvenog rada, Sveučilišna knjižara Zagreb, 2005.
- [2] Jokić, M; Krešimir Zauder; Srebrenka letina : Karakteristike Hrvatske nacionalne i međunarodne znanstvene produkcije , Institut za društvena istraživanja u Zagrebu, Zagreb, 2012.
- [3] M. Amin , M. Mabe: Impact factors: Use and abuse , Elsevier., The Boulevard, Langford Lane, Kidlington, Oxford OX5 1GB, UK , 2000.
- [4] E.S. Vieira, J.A.N.F. Gomes, Citations to scientific articles: Its distribution and dependence on the article features, Journal of Informetrics 4, 2010
- [5] Tam Cam Ha, Say Beng Tan, Khee Chee Soo, *The Journal Impact Factor: Too Much of an Impact?*, Annals Academy of Medicine, 2006
- [6] <http://onlinelibrary.wiley.com/doi/10.1002/adma.v22.48/issuetoc>
- [7] <http://www.journals.elsevier.com/progress-in-materials-science/#>
- [8] <http://hrcak.srce.hr/tehnicki-vjesnik>
- [9] Protić, Antonio; Runje, Biserka; Stepanić, Josip. [Distribution of Citations in one Volume of a Journal](#).// INDECS Interdisciplinary Description of Complex Systems. **Vol 11** (2013) , No. 2; 227-237 (članak, znanstveni)

PRILOZI

I. CD-R disc