

Suvremena psihologija 15 (2012), 1, 97-117

Pregledni članak - UDK 159.946.4

PRODUKTIVNOST HRVATSKIH PSIHOLOGA: SCIENTOMETRIJSKA ANALIZA MREŽE SURADNJI NA RADOVIMA INDEKSIRANIM U BAZI WoS 1991-2010

Srebrenka Letina

Institut za društvena istraživanja u Zagrebu
Amruševa 11/II, 10000 Zagreb
srebrenka@idi.hr

Krešimir Zauder

Institut za društvena istraživanja u Zagrebu
Amruševa 11/II, 10000 Zagreb
kresimir@idi.hr

Maja Jokić

Institut za društvena istraživanja u Zagrebu
Amruševa 11/II, 10000 Zagreb
maja@idi.hr

Sažetak

Svrha rada je opisati produktivnost i međusobnu suradnju registriranih znanstvenika iz područja psihologije u Hrvatskoj ($N = 241$). Podaci o objavljenim radovima preuzeti su iz citatne baze WoS (Web of Science) za 169 znanstvenika u razdoblju od 1991. do 2010. godine. U skupu dobivenih radova (882 radova) provedena je analiza produktivnosti i koautorstva. Dobiveni rezultati o visokoj proporciji višeautorskih radova i nepostojanju spolnih razlika u produktivnosti u skladu su s nalazima u literaturi. Za analizu međusobne suradnje korištena je metoda analiza mreža (engl. social network analysis). Obradeni su indikatori koji proizlaze iz tog pristupa i opisuju mrežu (gustoća i najveća komponenta) kao i poziciju pojedinca unutar mreže (mjere centralnosti: stupanj centralnosti, međupovezanost i blizina, te artikulacijski čvorovi i nepovezani članovi). Utvrdili smo da su dobiveni indikatori umjereno do visoko povezani s produktivnošću znanstvenika. Radi uvida u razvoj mreže suradnje provedena je analiza karakteristika mreže kroz vrijeme. Zaključujemo da analiza mreže pruža korisne prediktore znanstvene produktivnosti i dodatne informacije o međusobnoj suradnji članova mreže. Za cijelovitiji uvid u suradnju buduća istraživanja bi trebala uzimati u obzir i druge oblike suradnje te nadopuniti nacrte istraživanja relevantnim varijablama poput zadovoljstva poslom i organizacijske klime. Rezultati se mogu iskoristiti pri planiranju, organizaciji i evaluaciji znanstvene djelatnosti.

Ključne riječi: znanstvena produktivnost, znanstvena suradnja, mreža koautora, mreža međusobne suradnje, scijentometrija, longitudinalna analiza mreže, psihologija u Hrvatskoj, znanstvena procjena

UVOD

Znanost kao jedna od najkompleksnijih djelatnosti podložna je, kao i ostale djelatnosti, sustavu vrednovanja. Razlozi za vrednovanjem su različiti i u osnovi se mogu svrstati u "vanske" i "unutarnje". "Vanski" su porast kompeticije u znanosti s obzirom na raspoloživa sredstva i pritisak da se pokaže doprinos na međunarodnoj razini. "Unutarnji" razlozi su stalna propitivanja o stanju, razvoju i vrijednostima unutar neke discipline (Jokić, 2005).

Danas se vrednovanja u znanosti najčešće provode mjerjenjima produktivnosti (broja i vrste objavljenih radova te njihovih karakteristika) i odjeka objavljenih rezultata istraživanja. Na produktivnost i na odjek utječu načini komunikacija u znanosti, među kojima značajnu ulogu ima znanstvena suradnja. Obilježje gotovo svih znanstvenih disciplina je međusobna suradnja znanstvenika s ciljem stvaranja novog znanja. Stoga je paradigma suvremene znanosti interdisciplinarnost, transdisciplinarnost i multidisciplinarnost koja se ostvaruje suradnjom formalnim i neformalnim načinima komunikacije. Suradnja se ostvaruje unutar znanstvene institucije stručnjaka istih i različitih znanstvenih disciplina i polja kao i sa srodnim institucijama unutar zemlje ili na međunarodnoj razini.

Znanstvena suradnja je složen fenomen koji je moguće istraživati na različitim razinama i na koji utječe veliki broj faktora. Važnost i mogućnost primjene rezultata istraživanja znanstvene suradnje u praćenju kognitivnog i socijalnog procesa razvoja znanosti prepoznate su i prate se u posljednjih 30-ak godina. Prema Katz i Martin (1997), do danas su obradivani različiti aspekti suradnje: kako mjeriti suradnju općenito i koautorstvo, koji faktori utječu i potiču porast istraživačke suradnje, koji su izvori suradnje (koja je uloga komunikacije i učinci fizičke i društvene bliskosti na sklonost suradnji), te koji su učinci suradnje na znanstvenu produktivnost.

Dostupnost podataka iz citatnih baza, prvenstveno WoS (Web of Science) omogućila je istraživanja suradnje analizama koautorstava u svrhu razumijevanja uvjeta u kojima nastaju inovacije, nova znanja i spoznaje, ali je otvorila i mogućnosti za potrebe znanstvene politike. S vremenom su se kvantitativna istraživanja usmjerila na različite razine agregacije podataka, budući da se koautorstvo može mjeriti između istraživača, istraživačkih grupa, institucija, područja, sektora (znanosti i industrije), zemalja, regija itd. (Sonnenwald, 2007). Kao dopuna kvantitativnim pokazateljima počela su se provoditi i kvalitativna istraživanja suradnje (npr. Knorr-Cetina, 1999).

Koautorstvo na objavljenim radovima često se koristi kao indikator suradnje i to zbog dostupnosti podataka, stabilnosti mjerjenja, mogućnosti provjere te neintruzivnosti i nereaktivnosti takve mjere (Sonnenwald, 2007). Ipak, većina autora

upozorava da se radi samo o aproksimativnom indikatoru koji zahvaća samo dio fenomena suradnje (Katz i Martin, 1997).

Ranija istraživanja razmatrala su kognitivnu, društvenu i ekonomsku ulogu ko-autorstva. Koautorstvo je promatrano kao dio ekonomske strategije članova znanstvene zajednice (Price, 1963), kao sredstvo pristupa resursima (informacijama i opremi) i način povezivanja sa znanstvenom elitom te time postizanja reputacije i vidljivosti u znanstvenoj zajednici (Beaver i Rosen, 1978), ali i kao sredstvo uza-jamnog intelektualnog i društvenog utjecaja u znanstvenoj zajednici (Edge, 1979; MacRoberts i MacRoberts, 1986). Istraživanja su pokazala da oblici suradnje u velikoj mjeri ovise o osobnom akademskom i intelektualnom "zaledu" poput discipline, užem području djelovanja suradnika i vrste istraživačkog sustava kojem pojedinac pripada. Jedan od važnijih vanjskih faktora koji utječu na suradnju jest nacionalni R&D evaluacijski sustav napredovanja. Stoga je za razumijevanje suradničkog ponašanja nužno u širi interpretativni okvir uključiti ulogu vanjskih faktora. Npr. u manjim znanstvenim zajednicama očekuje se da će znanstvena politika poticati takav sustav evaluacije koji će usmjeriti znanstvenike prema internacionalizaciji (Mali, Kronegger i Ferligo, 2010).

Osim šireg konteksta istraživačke politike i strukturalnih faktora općenito, na individualne strategije znanstvenog rada djeluju i osobni faktori poput osobne percepcije suradnje, na primjer, motivi, očekivana dobit, ali i osobne karakteristike poput socijalnog statusa, dobi, znanstvene produktivnosti i prepoznatljivosti. Osobni faktori su posebno važni u održavanju suradničkih odnosa. Sonnenwald (2007) tu navodi kompatibilnost osobnosti, sličnost pristupa znanosti, radne stilove, uzajamno poštovanje i povjerenje te ugodan zajednički rad.

Značajan metodološki napredak u istraživanju znanstvene suradnje nastao je primjenom metodologije analize društvenih mreža (engl. *Social Network Analysis* – SNA). Društvene mreže su grupe međusobno povezanih pojedinaca koji imaju neki zajednički atribut. SNA je interdisciplinarni pristup koji uključuje skup metoda, mjernih koncepata i teorija koje omogućuju empirijsko mjerjenje društvenih struktura i okoline unutar koje pojedinac funkcioniра (Borgatti, Mehra, Brass i Labianca, 2009). U psihologiji se primjenjivao u istraživanju različitih problematika, npr. socijalnog utjecaja, prijateljstva, vodstva, radne klime, širenja tračeva, grupne terapije itd. Neki autori ističu primjenjivost i potencijalne mogućnosti koje SNA metodologija ima u različitim područjima psihologije, npr. u organizacijskoj psihologiji (Hatala, 2006) i u istraživanju savjetovanja (Koehly i Shivy, 1998).

Iz važnosti istraživanja znanstvenih publikacija (čime se aproksimira produktivnost znanstvenika, ustanova, zemlje, regije i sl.) te važnosti suradnje u procesu publiciranja proizlaze dva cilja ovog rada:

- Opisati produktivnost znanstvenika u području psihologije iz Republike Hrvatske kroz njihove radove u časopisima indeksiranim u bazi WoS (Web of Science) u razdoblju od 1991. do 2010.

- Na istom skupu podataka opisati suradnju među psiholozima iz RH koristeći metodologiju SNA.

Nakon uvoda rad opisuje uzorak i korištenu metodologiju, a slijedi detaljniji opis analiziranog skupa podataka. Rezultati i diskusija su prikazani zajedno kako bi unatoč velikom broju analiza tekst zadržao koherentnost i da ne bi došlo do nepotrebnih ponavljanja.

METODA

Uzorak i metodologija

Inicijalni uzorak sastojao se od 241 znanstvenika koji su registrirani kao znanstvenici u području psihologije prema registru Ministarstva znanosti, obrazovanja i športa iz 2008 godine. Registar uključuje znanstvene novake (27,4%), aktivne znanstvenike (66%), te umirovljene znanstvene djelatnike (6,6%).

Postupak prikupljanja podataka sastojao se od povlačenja bibliografskih podataka za svakog znanstvenika u registru, iz međunarodne baze WoS za razdoblje od 1991. do 2010. godine. WoS je najstarija i najselektivnija međunarodna multidisciplinarna citatna baza znanstvene literature. WoS je jedan od glavnih izvora (uz Scopus i potencijalno Google Scholar) bibliometrijskih podataka za ovu vrstu istraživanja u kojem su indeksirani svi prestižni znanstveni časopisi (samo iz područja psihologije 2010. indeksirano je 530 časopisa). Baza je 2010. godine indeksirala 11 hrvatskih časopisa iz područja društvenih znanosti. Među njima je i časopis Suvremena psihologija.

U ovom istraživanju nismo se ograničili samo na časopise koji su indeksirani za znanstveno polje psihologije, nego na sve radeve na kojima je među autorima barem jedan od registriranih znanstvenika iz uzorka. Kao rezultat takvog pristupa uključeni su i radevi objavljeni u časopisima koji se prema klasifikaciji baze WoS primarno bave drugim znanstvenim područjima. Pri pretraživanju se posebno pazilo da se uzmu u obzir sve moguće inačice punog imena autora nastale zbog postojanja dva ili više prezimena, odnosno problema s dijakritičkim znakovima.

U preuzetom skupu podataka rad je glavna jedinica, a podatci podržavaju različite agregatne razine analize. U ovom ćemo se radu uglavnom usmjeriti na razinu autora.

Nakon provedene ekstrakcije utvrdili smo da 30% ($N = 72$) ispitanika nije imalo ni jedan zabilježen rad u WoS-u pa su isključeni iz daljnje analize. Krajnji uzorak ($N = 169$) sastojao se od 66% aktivnih znanstvenika, 31% znanstvenih novaka, i 3% umirovljenih znanstvenih djelatnika. Sastav uzorka po dobi je od 27 do 74 godine ($M = 44,7$; $SD = 12,1$), a po spolu 27% muškaraca i 73% žena. U najvećem postotku radi se o djelatnicima različitih hrvatskih sveučilišta (64,1%), zatim instituta (17,6%) te zdravstvenih ustanova (10%).

Na temelju prikupljenih podataka o objavljenim radovima znanstvenika iz definiranog uzorka, konstruirane su mreže suradnje među autorima. Analize mreža po čvorovima uključivale su mjere centralnosti (stupanj centralizacije, međupovezanost i blizinu) te identifikaciju tzv. artikulacijskih čvorova i nepovezanih aktera.

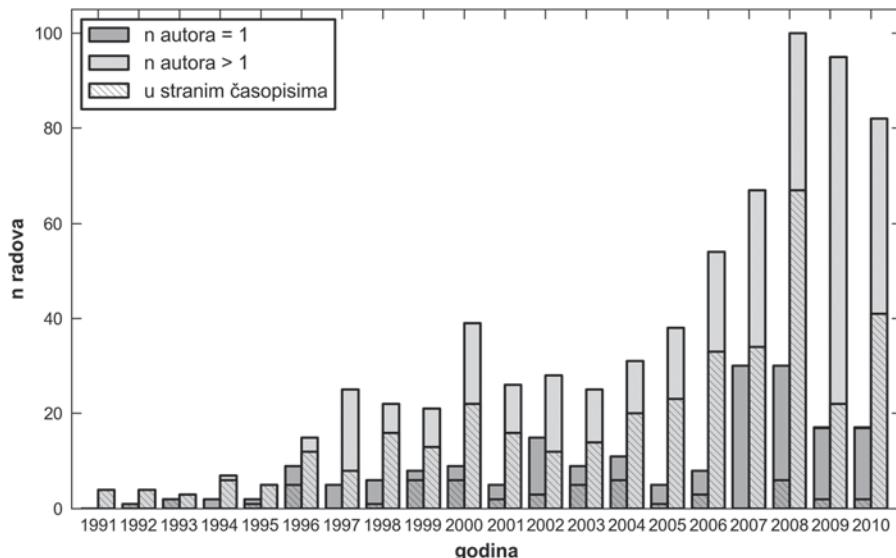
Obrane i slike vezane uz analizu mreža izrađene su u softveru vlastite izrade u programskom jeziku Python (koristeći modul Igraph).

REZULTATI I RASPRAVA

Analiza radova

169 autora različite duljine znanstvene aktivnosti u pretraživanom je intervalu od 20 godina u bazi WoS bilo registrirano na ukupno 882 rada. S obzirom na vrstu radova, dobiveni skup je sastavljen od: 72,8% (642) članaka, 1,9% (17) preglednih radova, 3,2% (28) cjelovitih radova s konferencija, 14,2% (125) sažetaka sa znanstvenih i stručnih skupova, i 7,9% (70) ostalih vrsta radova (uvodnici urednika, prikazi knjiga, biografski članci, korekcije itd.). Od ukupnog broja radova iz našeg uzorka indeksiranih u bazi WoS, njih 52% objavljeno je u hrvatskim časopisima.

Analiza radova prema godinama (Slika 1) upućuje na polagani trend povećavanja broja indeksiranih radova iz uzorka u 90-im godinama, plato dosežu u prvim godinama ovog stoljeća, a nakon 2007. dolazi do naglog porasta. Nagli porast broja



Slika 1. Jednoautorski i višeautorski radovi u domaćim i stranim časopisima indeksiranim u WoS-u od 1991. do 2010. godine



*Slika 2. Učestalost ključnih riječi radova indeksiranih u WoS-u 1991-2010
(najmanja frekvencija 5, najveća frekvencija 60)*

indeksiranih radova, 49,6% je objavljeno u razdoblju od 2007 do 2010., može se pripisati činjenici da je WoS od 2006. godine počeo s indeksiranjem većeg broja hrvatskih časopisa. Do 2006. uključena su 3 časopisa iz područja društvenih znanosti, a danas ih je 11.

Jednoautorski radovi značajno su više zastupljeni u hrvatskim časopisima, dok radove iz našeg uzorka objavljene u međunarodnim časopisima karakterizira više-autorstvo ($\chi^2 = 43,821$, df = 1, p = 0,00).

Iako naš uzorak čine psiholozi, rezultati pokazuju da je najviše radova objavljeno u časopisima iz šire domene društvenih znanosti (294), zatim psihologije (178), medicine (115), psihijatrije (33), te raznih multidisciplinarnih područja (24). Promatrano na razini autora, 78,8% je objavljivalo u časopisima iz kategorije društvenih znanosti, 69,2% u kategoriji psihologije, 33,7% u medicini, 23% u multidisciplinarnim časopisima, 16,6% u časopisima iz psihijatrije.

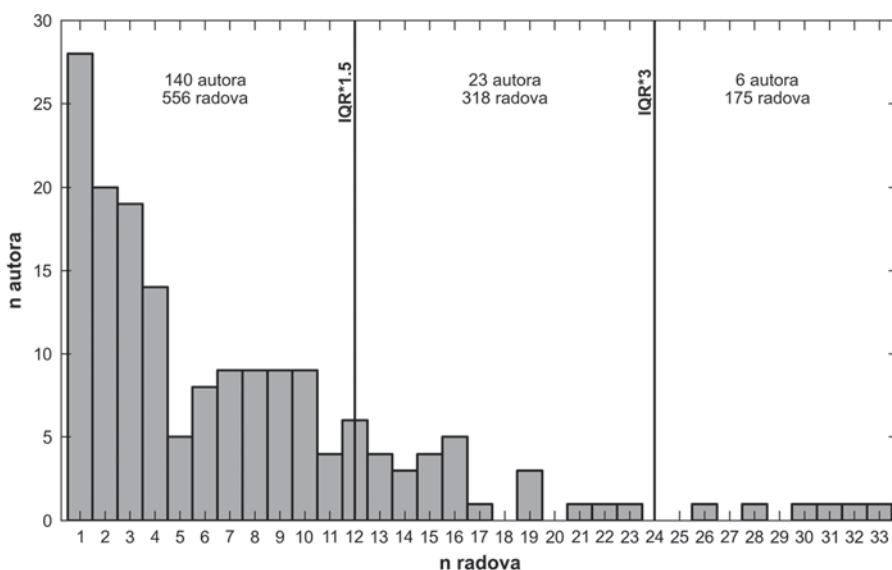
Analiza ključnih riječi pokazala je teme koje zanimaju hrvatske psihologe, a to su: različite vrste stavova, adolescenti, konstrukcija i provjera valjanosti različitih skala, spolne razlike, ličnost, stres, obitelj i depresija (Slika 2).

Produktivnost znanstvenika

Mjera produktivnosti za svakog znanstvenika bila je ukupan broj objavljenih radova indeksiranih u WoS-u 1991-2010. Na ovoj razini analize nismo uzimali u obzir vrstu radu niti broj autora na radu.

Najveći broj znanstvenika ima registriran jedan rad (17%), odnosno dva rada (12%). U pravilu, što je mjera produktivnosti veća, manja je frekvencija autora: 3 do 10 radova objavilo je 49% autora, od 11 do 20 radova – 18%, a više od 21 rad – 5% ($M=7,3$, $SD=6,8$, medijan 5, raspon od 1 do 33, asimetričnost 1,64, spljoštenost 2,98). Dobivena distribucija očekivano nalikuje Pareto distribuciji (Slika 3.). Kod istraživanja produktivnosti u znanosti tipično se dobivaju tzv. "fat-tailed" (Newman, 2004) izrazito pozitivno asimetrične distribucije (npr. u području psihologije López López, Caridad García-Cepero, Aguilar Bustamante, Silva i Aguado López, 2010).

Jedan od temeljnih zakona o znanstvenoj produktivnosti u bibliometrijskim istraživanjima je tzv. Lotkin zakon. Prema Lotki (Golub, Krištofić, Čengić i Pavić, 1997), polovinu ukupno objavljenih radova proizvede tek 10% najproduktivnijih autora. Pritom, prema Priceovu modelu, četvrtinu radova proizvede 2% hiperproduktivnih, a četvrtinu autori s jednim do dva objavljenih rada. Iako su kasnija istraživanja (Kvvik, 1989) pokazala da Lotkin zakon precjenjuje produktivnost najplodnijih znanstvenika, provjerili smo na našem uzorku i dobili da je 10% znanstvenika odgovorno za 43,5% radova. Stvarni postotak doprinosa tih autora u preuzetom skupu radova je vjerojatno manji budući da su neki od radova nastali u međusobnoj suradnji. Na Slici 3 može se zamjetiti da se nekoliko autora ističe po visokoj produktivnosti, 6 tzv. ekstremnih *outlier*a, imaju broj radova veći od $IQR \times 3 = 24$. Prema sadržaju radova mogli smo zaključiti da se radi o autorima koji djeluju u



Slika 3. Distribucija radova po autorima prema WoS-u za vremenski period od 1991. do 2010. (N autora = 169, N radova = 882)

Tablica 1. Opažene i očekivane frekvencije muških i ženskih autora u 4 skupine s obzirom na produktivnost

Spol	Produktivnost (n radova u Web of Sc-u)							
	Q ₁ (1 do 2 rada)		Q ₂ (3 do 5 radova)		Q ₃ (6 do 10 radova)		Q ₄ (više od 10 radova)	
	opaženi	očekivani	opaženi	očekivani	opaženi	očekivani	opaženi	očekivani
Ž	37	35,2	31	27,9	31	32,3	25	28,6
M	11	12,8	7	10,1	13	11,7	14	10,4
Ukupno	48	48	38	38	44	44	39	169

sljedećim subdisciplinama: socijalnoj psihologiji, psihologiji ličnosti, te zdravstvenoj psihologiji. Naime, prema nekim autorima (D'Amico i Canetto, 2010), postoje razlike među različitim subdisciplinama unutar psihologije. Primjerice, kognitivni, razvojni i socijalni psiholozi objavljaju više od kliničkih i edukacijskih psihologa.

Nakon podjele uzorka u četiri jednake grupe s obzirom na produktivnost prema kvartilima, provjerili smo postoje li razlike u produktivnosti s obzirom na spol. Utvrdili smo da razlike ne postoje (Tablica 1., $\chi^2 = 3,555$; $df = 3$, $p = 0,314$). To je u skladu s nekim istraživanjima, primjerice Schucan Bird (2011) je analizom objavljenih radova u Velikoj Britaniji i demografskih podataka znanstvenika iz područja društvenih znanosti utvrdila da je samo u području psihologije i znanstvene politike doprinos prema spolu podjednak, dok je u ostalim područjima doprinos muškaraca značajno veći.

Očekivano smo utvrdili da je dob zbog povezanosti s duljinom radnog staža pozitivno povezana s brojem indeksiranih radova (Spearmanov rho = 0,35; $p = 0,00$). Visina povezanosti je najvjerojatnije podcijenjena jer su stariji ispitanici u uzorku imali manje šanse imati indeksiran rad koji su objavili u ranijem dijelu svog radnog vijeka budući da je većina hrvatskih znanstvenih časopisa u ovoj bazi zastupljena tek relativno nedavno. Kad smo frekvenciju objavljenih radova sagledali u odnosu na dob autora u vrijeme objavljivanja rada, ustavili smo da su u našem uzorku autori bili najproduktivniji sredinom 30-ih i 40-ih godina svoga života.

Analiza suradnje

Većina radova je očekivano napisana u suradnji s barem još jednim znanstvenikom. Tablica 2. prikazuje dominantnost višeautorskih radova (78,3%) u odnosu na jednoautorske radove (21,7%) s približnim omjerom 3:1. Dvoautorskih radova bilo je 24,5%, radova s 3 autora 25,1% dok je radova s 4 i više autora bilo 27,6%. Promatrano prema vremenskim periodima od 5 godina, udio radova s obzirom na broj autora nije se značajno razlikovao ($\chi^2 = 13,416$; $df = 12$; $p = 0,186$). Prosje-

Tablica 2. Zastupljenost radova s različitim brojem autora tijekom četiri petogodišnja perioda

Vremenski period	Broj autora na radu							Prosječan broj autora po radu (medijan)
	1	2	3	4	5-10	11-20	>20	
1991.-1995.	23,30%	23,30%	36,70%	13,30%	3,30%			2,5 (3)
1996.-2000.	23,30%	26,40%	22,60%	10,70%	15,10%	0,60%	1,30%	3,43 (3)
2000.-2005.	23,30%	21,80%	23,80%	6,70%	22,30%	1,60%	0,50%	3,71 (3)
2006.-2010.	20,40%	25,00%	25,60%	7,80%	17,00%	2,60%	1,60%	3,95 (3)
1991.-2010.	21,70%	24,50%	25,10%	8,30%	17,30%	1,90%	1,20%	3,75 (3)

čan broj autora po radu je 3,75 (medijan 3), $SD = 6,586$ (raspon: 1-95). Promatrano po razdobljima od 5 godina, može se zamjetiti blago povećanje prosječnog broja autora po radu. Međutim, stabilnost medijana od tri autora za sve periode pokazuje da se ne radi o značajnom trendu, već o većoj pojavi radova s netipično velikim brojem autora.

Nizak udio jednoautorskih radova nije iznenađujući. Strahan (1982) je ustavio porast broja radova s više od jednog autora od 19,6% 1956. godine na 76,7% 1979. godine. Smanjenje udjela jednoautorskih radova i povećanje broja autora po radu je utvrđen trend u znanosti, izraženiji u području prirodnih nego društvenih znanosti. Prema Croninu, Shawu i La Barre (2003) iznimka je psihologija, gdje višeautorstvo postaje norma. Ranija istraživanja na području psihologije na različitim skupovima radova iz prestižnih časopisa (Over i Smallman, 1973; Smith, 1958; Strahan, 1982) pokazala su da od sredine 20. stoljeća postoji trend smanjenja broja jednoautorskih radova i povećanja broja autora po radu.

Naši rezultati pokazuju da od 1991. do 2010. postoji stabilnost u proporciji jednoautorskih radova i prosječnog broja autora na radu. To je u skladu s istraživanjima Zooka (1987), koji je na temelju analize radova iz časopisa *Journal of Counseling Psychology* zaključio da je došlo do zaustavljanja trenda porasta autora po radu u psihologiji. Najveći porast je postojao za troautorske radove, a iz Tablice 2 je vidljivo da za naš uzorak postoji mali, ali konstantan porast udjela tih radova za ispitivana razdoblja. Trendovi višeautorstva su slični onima koji su utvrđeni bibliometrijskim analizama u drugim zemljama (npr. López López i sur., 2010). Holaday i Yost (1994) su na uzorku autora iz četiri različita područja psihologije u razdoblju od 11 godina utvrdili da nije došlo do značajnog povećanja broja autora po radu, ali su pronađene razlike među područjima (medicinski časopisi su imali više radova sa 4 ili više autora).

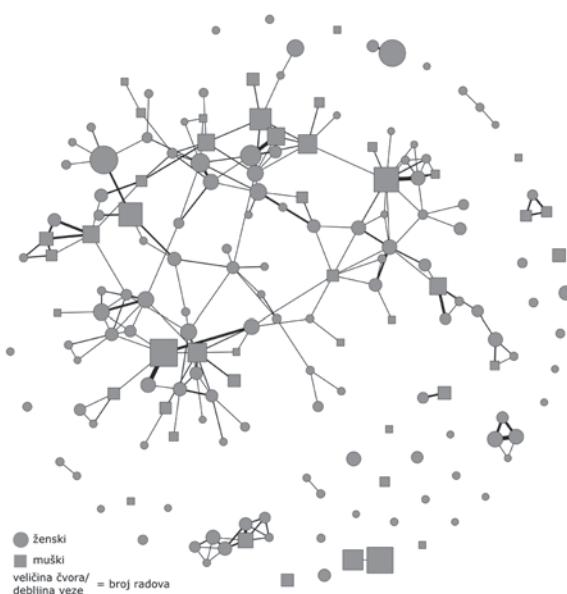
U ovom kontekstu je zanimljivo spomenuti da je na uzorku radova iz prirodnih znanosti s hrvatskim adresama u WoS-u, u razdoblju 1991.-2005. pronađen trend značajnog povećanja broja autora po radu (Jermen, 2012, disertacija u izradi).

Analiza mreže koautorstva

Od ukupno 3.311 zabilježenih autorstva na čitavom skupu radova, naš uzorak je odgovoran za 1.230 autorstva. Mnogi su radovi nastali u suradnji s neregistriranim znanstvenicima, znanstvenicima iz drugih zemalja i znanstvenicima iz drugih područja pa ta autorstva nisu bili zahvaćena našim uzorkom. Dakle, dobivena mreža prikazuje cjelovitu suradnju samo među psihologima iz uzorka, ali ne i suradnju među svim autorima na istim radovima. To je metodološki nedostatak koji je u praksi vrlo teško zaobići za veće skupove radova. Naime, radi se o problemu identifikacije nepoznatih autora putem imena u obliku u kojem se koristilo na radu.

Grafički prikazana mreža (Slika 4.) sastoji se od čvorova koji predstavljaju pojedine znanstvenike i od neusmjerenih veza koje označavaju suradnju znanstvenika detektiranih putem koautorstva na radovima indeksiranim u WoS-u. Prema Newmannu (2001) mreže koautorstva su najbolji bibliometrijski indikatori za opisivanje različitih obrazaca suradnje u akademskim znanstvenim disciplinama.

Koristeći mjere iz analize mreža, po čvoru smo izračunali vrijednosti za tri mjere centralnosti (stupanj centralizacije, međupovezanost i bliskost) te identifikaciju tzv. artikulacijskih čvorova i nepovezanih aktera. Kako se radi o varijablama koje nisu normalno distribuirane, pri opisu rezultata koristili smo neparametrijske statističke postupke.



Slika 4. Mreža suradnje 169 autora iz područja psihologije prema radovima indeksiranim u WoS-u (1991-2010)

Mjere centralnosti

Različite vrste centralnosti određuju centralnost pojedinog aktera preko evaluacije njegove lokacije u mreži. Takve mjere pomažu u određivanju važnosti pojedinih čvorova. Centralnost opisuje u kojoj je mjeri kohezija organizirana oko određenog čvora (Scott, 2000). Freeman (1979) je ustanovio da je centralnost važan strukturalni faktor koji utječe na vodstvo, zadovoljstvo i učinkovitost.

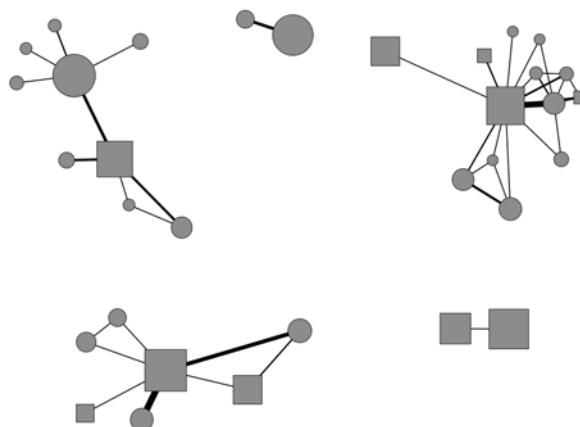
Stupanj centralnosti (engl. degree centrality, DC) je broj direktnih veza koje ima čvor (kod neusmjerenih veza), odnosno u našoj mreži, broj različitih znanstvenika iz uzorka s kojima akter surađuje jednom ili više puta. Ova mjera centralnosti uzima u obzir samo direktne veze, a ostale mjere pokušavaju zahvatiti indirektan utjecaj koji akter ima u mreži (Koehly i Shivy, 1998).

Analiza međusobne suradnje znanstvenika iz uzorka pokazala je da je 80,5% autora surađivalo barem s još jednim autorom iz uzorka. Unutar uzorka u razdoblju od 20 godina, autori su surađivali u prosjeku s dvoje drugih autora iz uzorka ($M = 2,38$, $SD = 2,20$, medijan 2, raspon od 0 do 12). Autori se razlikuju s obzirom na broj suradnji: najveći broj autora je surađivalo s jednim (24,9%), potom 2 (18,9%) autora (iz uzorka), dok brojnije suradnje (više od 5) ostvaruje manji broj autora (10%). Dobivena distribucija suradnje je očekivano pozitivno asimetrična, što se tipično dobiva bez obzira na disciplinu unutar koje se mjeri učestalost suradnje (Newman, 2004).

Broj suradnji je pozitivno i umjерeno visoko povezan s brojem radova (Spearmanov rho = 0,54; $p < 001$). Visoki DC upućuje na to da je autor dobro povezan i ima pristup mnogim izvorima znanja i resursa (Walter, Lechner i Kellermanns, 2007). Liao i Yen (2012) su na uzorku iz informacijskih znanosti dobili da je DC bio najbolji prediktor znanstvene produktivnosti ($\beta = 0,541$) u usporedbi s drugim mjerama suradnje koji se ne izvode iz SNA analize. Podaci odgovaraju rezultatima ankete prema kojoj znanstvenici redovito surađuju s dvoje do četvero domaćih suradnika (Prpić i Brajdić Vuković, 2005, p. 46). Iste autorice su zaključile da je viši položaj znanstvenika povezan s većim socijalnim kapitalom, odnosno brojem domaćih, ali i stranih suradnika.

Povezanost dobi autora i broja suradnji unutar uzorka nije pronađena ($\rho = 0,03$, $p = 0,747$). Takav rezultat je iznenadjujući jer sugerira da dulje radno iskustvo nije povezano sa stjecanjem većeg broja suradnika iz uzorka. Međutim, moguće je da se radi o posljedici činjenice da mreža prikazuje samo suradnju unutar uzorka.

Međupovezanost (engl. betweenness centrality, BC) mjeri koliko puta se neki čvor nalazi "između" bilo koja dva čvora u mreži. Viša vrijednost upućuje na to da akter služi kao "cut point" ili povezujuća osoba za protok informacija između mnogih drugih, međusobno nepovezanih aktera u mreži. Točnije se definira kao broj najkraćih putova između svih parova čvorova koji prolazi kroz određeni čvor (Wasserman i Faust, 2007). Omogućuje identificiranje "najutjecajnijih" autora. U ovom skupu je ponovljen rezultat da autori s najvišim vrijednostima povezanosti međusobno usko ne surađuju (Newman, 2004).



Slika 5. Mreže koautorstava najproduktivnijih autora u skupu

Slika 5 prikazuje podmrežu slike 4 na kojoj su uključeni samo ekstremni *outlieri* po produktivnosti u našem uzorku ($N = 6$) i njihovi "prvi susjedi". Samo dva *outlieri* su direktno međusobno surađivala, a zanimljivo je da ne postoje suradnje između prvih susjeda različitih *outlieri*. *Outlieri* s malim brojem veza upućuju na angažman u područjima koja nisu primarna za uzorak (npr. medicina).

Blizina (engl. closeness centrality, CC): odnosi se na duljinu puta koja je potrebna da akter "dođe" do svakog aktera u mreži. To je stupanj u kojem je pojedinac blizak sa svim ostalima u mreži (direktno ili indirektno). Uzima u obzir i indirektne puteve između aktera preko udaljenosti pojedinog aktera od svih ostalih članova mreže (Wasserman i Faust, 2007). Odražava mogućnost pristupa informacijama kroz mrežu (Koehly i Shivy, 1998).

Gustoća, artikulacijski čvorovi i nepovezani akteri

Gustoća (engl. Density, D) mreže predstavlja proporciju ostvarenih veza od svih mogućih veza. To je mjera općenite razine povezanosti među čvorovima u mreži i služi kao općenita mjera kohezije. S razvojem neke grupe, vremenom raste i gustoća, što sugerira da grupa postaje sve kohezivnija. Gustoća mreže autora (D) je 0,01, što znači da je kod 169 znanstvenika u 20 godina ostvareno 1% od svih potencijalno mogućih veza. Mjera ima više smisla za manje grupe unutar kojih pojedinci blisko surađuju. Primjerice, za odvojenu komponentu koju čine djelatnici jednog odsjeka za psihologiju (na Slici 4. smještena desno dolje) $D = 0,53$. Mreže se sastoje obično od nekoliko komponenti različite veličine, od kojih su neke povezane s drugima, a neke su izolirane. Najveća komponenta ima najveću povezanu grupu pojedinaca u mreži komponenata, sadrži 63,9% uzorka ($D = 0,03$).

Artikulacijski čvorovi (engl. articulation pont ili cut-point, AP) su akteri koji povezuju inače nepovezane dijelove mreže; odnosno, to su osobe koje su povezane s barem dvije osobe koje međusobno nisu direktno ni indirektno u vezi. Bez tih aktera, mreža bi se raspala na veći broj nepovezanih komponenti. Prema nekim teorijama (Golubović, 2008), zbog pristupa međusobno nepovezanim izvorima, artikulacijski čvorovi posjeduju tzv. društveni kapital.

U našem skupu identificirana su 33 artikulacijska čvora. Mann-Whitney U testom utvrdili smo da postoje značajne razlike u odnosu na ostatak skupa na ostalim ispitivanim SNA varijablama ($p = 0,00$), te produktivnosti ($p = 0,00$) i dobi ($p = 0,03$). Artikulacijski čvorovi imaju više SNA vrijednosti, produktivniji su i starije dobi. Koristeći χ^2 utvrdili smo da među artikulacijskim čvorovima ne postoji razlika u zastupljenosti prema spolu ($\chi^2 = 1,990$, $df = 1$; $p = 0,12$).

U uzorku su identificirana 33 znanstvenika koji nisu povezani ni s jednim drugim znanstvenikom iz skupa, tzv. nepovezani članovi skupa. Od 33 samo 7 je objavilo isključivo jednoautorske radove. Zastupljenost po spolu je podjednaka kao i u čitavom uzorku. Uvid u distribuciju po dobi znanstvenika pokazao je da su više zastupljeni relativno stariji, odnosno mlađi autori, što sugerira da se nedostatak suradnje može interpretirati kao posljedica činjenice da je za neke autore definirani vremenski okvir zahvatio raniju, odnosno kasniju fazu karijere, pa time nisu još ostvarene ili registrirane suradnje s ostalima iz skupa.

Povezanost SNA mjera i produktivnosti

Povezanost SNA indikatora međusobno kao i ukupna produktivnost mjerena brojem svih objavljenih radova, prikazana je u Tablici 3. SNA varijable međusobno su visoko povezane, što je očekivano budući da mjere slične koncepte. Sve SNA mjere su značajno povezane s produktivnošću. Najvišu povezanost s produktivnošću ima mjeru međupovezanosti ($\rho = 0,62$), a umjerenou visoku povezanost s

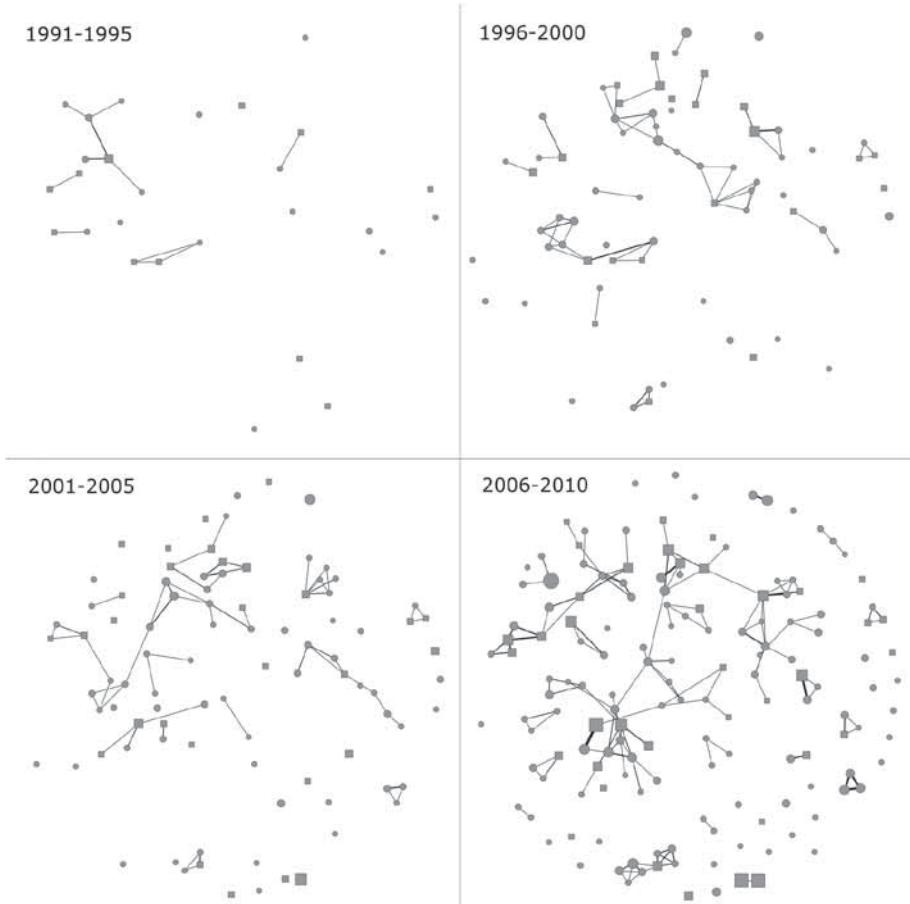
Tablica 3. Deskriptivna statistika i Spearmanov koeficijent korelacije (ρ) između SNA mjera i produktivnosti

	n radova	stupanj centralnosti	međupovezanost	blizina	M (medijan)	SD	raspon
n radova					7,28 (5)	6,75	1-33
stupanj centralnosti	0,594**				2,38 (2)	2,20	0-12
međupovezanost	0,617**	0,819**			136,78 (0)	281,83	0-1423,63
blizina	0,415**	0,817**	0,709**		0,012 (0,015)	0,005	0,006-0,016
artikulacijski čvor	0,376**	0,534**	0,687**	0,434**	-	-	0/1

kriterijem imaju stupanj centralnosti i blizina (0,59, odnosno 0,42). Relativno nižu povezanost s produktivnošću ima artikulacijski čvor jer se radi o dihotomnoj varijabli (0,38).

Analiza kroz vremenske periode

Mrežne studije često prikazuju stanje mreže onako kako je zatečeno u određenom trenutku. Da bi se dobio uvid u dinamiku, odnosno procese razvijanja pa i propadanja mreža, potrebno je sagledati mrežu kroz različite vremenske periode. Podjelom 20-godišnjeg perioda na četiri intervala po 5 godina, napravili smo vizualizaciju mreže i izračunali neke od indikatora za svako pojedino razdoblje (Slika 6. i Tablica 4.).



Slika 6. Mreže kautorstva za četiri petogodišnja razdoblja

Tablica 4. Svojstva mreža i karakteristike skupa za četiri petogodišnja razdoblja i za cijelokupno razdoblje (1991-2010)

Svojstva mreže	t1 1991–1995	t2 1996–2000	t3 2001–2005	t4 2006–2010	t1-t4 1991–2010
n autora (n čvorova)	27	70	91	152	169
n veza	11	53	56	132	201
prosječna duljina puta	1,667	2,271	2,915	4,963	4,970
gustoća	0,031	0,022	0,014	0,012	0,014
prosječan stupanj centralnosti	0,815	1,514	1,231	1,737	2,379
prosječna blizina	1,066	0,015	0,011	0,008	0,012
prosječna međupovezanost	0,519	2,543	3,703	32,066	136,775
broj komponenti	4	10	10	18	10
% čvorova u najvećoj komponenti	22,2	18,6	15,4	30,3	63,9
% (n) nepovezanih autora	44,4 (12)	27,1 (19)	37,4 (34)	22,4 (34)	19,5 (33)
n artikulacijskih čvorova	2	10	19	33	33
Karakteristike skupa					
n radova	30	159	193	500	882
prosječan broj svih autora po radu	2,5	3,434	3,71	3,948	3,75
prosječan broj autora iz uzorka po radu	1,47	1,36	1,34	1,42	1,39
% (n) jednoautorskih radova	23,3 (7)	23,3 (37)	23,3 (45)	20,4 (102)	21,7 (191)
prosječan broj jednoautorskih radova po autoru	0,26	0,53	0,49	0,67	1,13
prosječan broj svih radova po autoru	1,11	2,27	2,12	3,29	5,22
n privremenih autora	2	4	5	59	-
n pridošlih autora	25	45	29	-	-
n terminatora	-	1	5	93	-
n kontinuiranih autora	-	20	52	-	-

Pri interpretaciji razlika potreban je oprez jer se mreže za različita razdoblja razlikuju po veličini. Veći broj aktera utječe tako da mjere upućuju na manji stupanj kohezije (npr. broj komponenti je sve veći kako broj aktera raste).

Iz Tablice 4. je vidljivo da svako naredno razdoblje bilježi veći broj aktivnih autora, a time i veza među njima. To se posebice odnosi na četvrtu razdoblje, što se može objasniti činjenicom da je u tom razdoblju baza uključila veći broj hrvatskih časopisa. Time je postao vidljiv veći broj hrvatskih autora i njihovih suradnji. Stoga u tom razdoblju većina mjerjenih svojstva mreže pokazuje velike promjene.

Ako izuzmemo promjene koje su metodološki artefakt, promjene u strukturi mogu se objasniti s tri vrste faktora: formalni faktori koje definira organizacijska struktura, sadržaj istraživanja te neformalna društvena organizacija koja postoji pored formalne.

Kako mreža raste s porastom broja veza, nastaje sve veća komponenta koja se sastoji od velikog broja pojedinaca koji su međusobno povezani direktno ili posredno preko drugih članova. Mreža suradnje je obično fragmentirana u veći broj komponenti. Razlog tome je što u svakom polju postoji obično manji broj znanstvenika koji ne surađuju ni s kim, odnosno objavljaju samo jednoautorske radove. Također, znanstvenici mogu pripadati različitim subdisciplinama, odnosno baviti se posve različitim problematikama/sadržajima. U većini područja, većina autora pripada jednoj glavnoj komponenti. Međutim, unutar nekog područja akteri su u ranijim fazama manje povezani nego kasnije (Kronegger, Ferligoj i Doreian, 2011). Ta se pravilnost donekle može zamijetiti preko postotka aktera u najvećoj komponenti koji raste kroz sva četiri razdoblja. Također, postotak nepovezanih članova pokazuje trend smanjivanja, što upućuje na sve veću povezanost među aktivnim autorima.

Budući da je za svako razdoblje analiziran poseban skup podataka, vizualnom inspekциjom mreža kroz razdoblja možemo uočiti stabilnost pojedinih aktera (konstantnost u produkciji) i održivost suradnji. Vezano uz te karakteristike, Price (Mali i sur., 2010) navodi sljedeće kategorije suradnika u znanosti: privremeni (autori koji objavljaju u određenom periodu, ali ne prije ni poslije tog perioda), pridošlice (koji objavljaju u tom periodu i poslije, ali nikad prije), terminatori (objavljaju prije i u tom periodu, ali nikad poslije) i kontinuirani (objavljaju prije, za vrijeme i poslije promatrano perioda). U našem uzorku 10,7% (N=18) autora je objavilo u svakom od četiri promatrana razdoblja.

Istraživači iz prirodnih, tehničkih i biomedicinskih znanosti surađuju više nego istraživači iz društvenih znanosti (Price, 1963). Tzv. "lab" discipline podrazumijevaju suradničku aktivnost radi zajedničkog rada istraživača u laboratorijima i na skupoj opremi, dok "office" discipline nemaju to svojstvo i pružaju veću slobodu pojedinim istraživačima za rad u vlastitim uredima. Sličnu dimenziju opisuje i Berelson (Over i Smallman, 1973), koji discipline kategorizira u one koje barataju podacima (npr. kemija, biologija, fizika) i one koje barataju riječima i simbolima (npr. edukacijske znanosti, filozofija, matematika). Psihologija se općenito svrstava između te dvije krajnosti, iako postoje razlike između subdisciplina.

Jedan od najpopularnijih modela za objašnjenje nastanka i razvoja mreže suradnje u znanosti je model preferencijalnog povezivanja (engl. *preferential attachment*) (Börner, Boyack, Milojević i Morris, 2012). Osnovna pretpostavka tog modela jest da će novi autor koji ulazi u mrežu najvjerojatnije biti koautor s nekim tko već ima veliki broj koautora. Prominentni znanstvenici odgovorni su za povezivanje mreže te tako dolazi do organizacije po principu preferencijalne privrženosti. To je proces u kojem se resursi distribuiraju među pojedincima prema tome koliko već imaju, tako da oni koji već imaju puno dobivaju više od onih koji nemaju (učinak tzv. "kumulativne prednosti", često nazivano i Matejevim učinkom). Također, razumno je očekivati da će novi i nepoznati autori, posebice iz zemalja s tzv. znanstvene periferije, pri slanju rada u prestižni strani časopis imati manju vjerljivost odbijanja ako im koautor bude znanstvenik koji je već međunarodno prepoznat.

López López i sur., (2010) su u svom istraživanju prikazali mrežu suradnje na radovima iz psihologije objavljenima u Latinskoj Americi. Mreža se sastojala od 11 manjih grupa autora (do 6) koji međusobno nisu surađivali, a istraživanje je rađeno u trogodišnjem razdoblju. Taj obrazac suradnje opisuje model tzv. "malog svijeta".

Ograničenja i implikacije

Kao što je ranije spomenuto, bitno ograničenje ovog istraživanja je necjelovitost mreže. Zahvaćeni su samo registrirani znanstvenici iz polja psihologije i njihova međusobna suradnja. Suradnja psihologa iz našeg uzorka sa znanstvenicima iz drugih područja na objavljenim radovima u časopisima koje je indeksirala baza WoS u razdoblju 1991.-2010., nije obuhvaćena ovom analizom iz objektivnih opisanih razloga. Stoga je dobivena slika vjerojatno u nepoznatoj mjeri iskrivljena. Moguće ograničenje je i korištenje podataka samo iz WoS baze, odnosno selekcioniranog skupa radova, čime je cjelovitost ispitivanja unutarnacionalnih obrazaca produktivnosti i suradnje izostalo.

Svjesni smo da mjerjenje suradnje samo bibliometrijskim indikatorima isključuje mnoge druge važne oblike suradnje. Taj bi se nedostatak mogao prevladati u budućim istraživanjima korištenjem metodoloških pristupa koji bi uključivali upitnike i kvalitativne metode suradnje. Primjerice, De Hann (Mali i sur., 2010) predlaže šest indikatora za mjerjenje suradnje među znanstvenicima u društvenim znanostima: koautorstvo, zajedničko uredništvo publikacija, zajednička supervizija na disertacijama, pisanje projekata, sudjelovanje u formalnim istraživačkim projektima i organizacija znanstvenih konferencija. Navedeni oblici suradnje pokazuju da znanstvena suradnja ne mora uvijek rezultirati koautorstvom na publikacijama. Naprotiv, prema nekim istraživačima otprilike polovina znanstvene suradnje je nevidljiva formalnim komunikacijskim kanalima (Kronegger i sur., 2011).

Naposljetku, iako su objektivnost i točnost prednosti korištenja bibliometrijskih indikatora, moramo upozoriti da su greške pri unosu podataka u bazu i pri ekstrakciji podataka, zatim netransparentni kriteriji uključivanja časopisa u bazu te odluke o koautorstvu koje nisu utemeljene na zaslugama za doprinos radu realan i ozbiljan izvor kontaminacije valjanosti podataka. Osim broja objavljenih radova, ubuduće bi trebalo pokušati zahvatiti i kvalitetu radova (preko broja citata, odjeka časopisa ili procjene stručnjaka).

Buduća istraživanja trebala bi u većoj mjeri koristiti mogućnosti koje pruža analiza mreža, i uključiti SNA mjere u šire modele kao eksplanatorne varijable u regresijskim ili strukturalnim modelima za objašnjenje nekih relevantnih ishoda (Koehly i Shivy, 1998). Također, trebalo bi pri analizi uzeti u obzir i mnoge druge varijable koje dokazano utječu na produktivnost, poput vrste, prestiža i veličine ustanove u kojoj pojedinac radi, te radni status pojedinca unutar organizacije. Pretpostavljamo da bi uključivanje različitih varijabli iz organizacijske psihologije (npr.

zadovoljstvo poslom, organizacijska klima, motivacija) bio posebno koristan smjer istraživanja.

ZAKLJUČCI

Ovim smo istraživanjem željeli dobiti uvid u obrasce objavljivanja hrvatskih psihologa u 20-godišnjem razdoblju, od proglašenja samostalnosti 1991. do 2010. Istraživanja ove vrste namijenjena su u prvom redu samim znanstvenicima u području, kako bi pomogla u procjeni i očekivanjima vlastite znanstvene aktivnosti, ali i potencijalnom utjecaju na razvoj područja kojim se bave.

U skladu s istraživanjima u literaturi, manji broj autora je odgovoran za neproporcionalno velik dio publikacija, produktivnost je povezana s dobi autora, ali nisu dobivene razlike s obzirom na spol.

Unutar definiranog skupa pronašli smo da pojedinac surađuje u prosjeku s dvoje drugih autora u razdoblju od 1991. do 2010. Dodatna vrijednost našeg istraživanja jest što smo pri analizi znanstvene suradnje koristili SNA (engl. *social network analysis*) pristup. Na taj smo način iz bibliometrijskih podataka dobili dodatne indikatore (mjere centralizacije, identifikacija artikulacijskih čvorova i nepovezanih autora) koji su se pokazali pozitivno i umjereni do visoko prediktivnima za mjere produktivnosti. Suvremena znanstvena produkcija nije solitarna aktivnost, već kolektivna djelatnost, što se očituje i u organizacijskim jedinicama koje nisu pojedinci, već grupe znanstvenika (Mali, Kronegger, Doreian i Ferligoj, 2012). Mrežni pristup uzima u obzir kontekst u kojem se pojedinac nalazi i pruža informacije o statusu i lokaciji autora u široj strukturi zajednice te stoga omogućuje napredak u razumijevanju procesa u znanosti.

Znanstvena suradnja nije samo indikator, već i sredstvo znanstvene produktivnosti i odjeka. Istraživanja su pokazala da su koautorski radovi više citirani od jednoautorskih radova (Price, 1963). Istraživači u različitim disciplinama slažu se da se ne radi o jednostavnom odnosu te je potrebno istražiti cijenu i nedostatke suradnje (npr. cijena koordinacije, nedostatak motivacije i povjerenja), odnosno postojanje neke optimalne razine za produktivnost koja se razlikuje za različita područja znanstvene djelatnosti.

Ovo istraživanje je, koliko je nama poznato, prva scientometrijska analiza psihologije i prvo istraživanje koje koristi mrežni pristup (SNA) u području istražavanja znanstvene komunikacije u društvenim znanostima u Hrvatskoj.

Unatoč ograničenjima istraživanjima, rezultati bi se mogli iskoristiti pri planiranju i vrednovanju znanstvenog rada. Primjerice, rezultati koji upućuju na asimetričnost distribucije produktivnosti i razlike koje postoje među subdisciplinama govore da je potrebno pažljivo određivanje očekivane učinkovitosti za pojedinog znanstvenika. Važnost suradnje s drugim znanstvenicima i umrežavanja mogli bi biti korisni kod planiranja i evaluacije mentorskih aktivnosti, odnosno pri edukaciji mladih znanstvenika.

LITERATURA

- Beaver, D.B., Rosen, R. (1978). Studies in scientific collaboration Part I.: The professional origins of scientific co-authorship. *Scientometrics*, 1, 65-84.
- Borgatti, S.P., Mehra, A., Brass, D.J., Labianca, G. (2009). Network Analysis in the Social Sciences. *Science*, 323, 892-895.
- Börner, K., Bojack, K.W., Milojević, S., Morris, S. (2012). An Introduction to Modelling Science: Basic Model Types, Dey Definitions, and a General Framework for the Comparison of Process Models. U A. Scharnhorst, K. Börner, P. Van Den Besselaar (Ur.), *Models of Science Dynamics* (3-23). Thousand Oaks, CA: Sage.
- Cronin, B., Shaw, D., La Barre, K. (2003). A cast of thousands: Coauthorship and subauthorship collaboration in the 20th century as manifested in the scholarly journal literature of psychology and philosophy. *Journal of the American Society for Information Science and Technology*, 54, 855-871.
- D'Amico, R., Canetto, S.S. (2010). Similarities and Differences in Women's and Men's Publication and Citation Record among Academic Psychologists. *Journal of Women and Minorities in Science and Engineering*, 16, 343-361.
- Edge, D. (1979). Quantitative Measures of Communication in Science: A Critical Review. *History of Science*, 17, 102-134.
- Freeman, L.C. (1979). Centrality in social networks conceptual clarification. *Social networks*, 1, 215-239.
- Golub, B., Krištofić, B., Čengić, D., Pavić, Z. (1997). *Znanstvene i privredne elite*. Zagreb: Institut za društvena istraživanja.
- Golubović, N. (2008). Sources of social capital. *Sociologija*, 50, 17-34.
- Hatala, J.P. (2006). Social Network Analysis in Human Resource Development: A New Methodology. *Human Resource Development Review*, 5, 45-71.
- Holiday, M., Yost, T.E. (1994). Psychology of the scientist: LXVIII. Trends in multiple authorship. *Psychological Reports*, 74, 299-303.
- Jermen, N. (2012). *Analiza znanstvene aktivnosti na području prirodnih znanosti u hrvatskoj u razdoblju od 1991. do 2005. godine (disertacija u izradi)*. Zagreb: Filozofski fakultet.
- Jokić, M. (2005). *Bibliometrijski aspekti vrednovanja znanstvenog rada*. Sveučilišna knjižara. Retrieved from <http://books.google.hr/books?id=KvU8AAAACAAJ>
- Katz, J.S., Martin, B.R. (1997). What is research collaboration? *Research policy*, 26, 1-18.
- Knorr-Cetina, K. (1999). *Epistemic cultures: how the sciences make knowledge*. Harvard University Press. Retrieved from <http://www.google.hr/books?id=WFEeib0Q9L0C>
- Koehly, L.M., Shivy, V.A. (1998). Social network analysis: A new methodology for counseling research. *Journal of Counseling Psychology*, 45, 3.
- Kronegger, L., Ferligoj, A., Doreian, P. (2011). On the dynamics of national scientific systems. *Quality & Quantity*, 45, 989-1015.
- Kyvik, S. (1989). Productivity differences fields of learning, and Lotka's law. *Scientometrics*, 15, 205-214.
- Liao, C.H., Yen, H.R. (2012). Quantifying the degree of research collaboration: A comparative study of collaborative measures. *Journal of Informetrics*, 6, 27-33.

- López López, W., Caridad García-Cepero, M., Aguilar Bustamante, M.C., Silva, L.M., Aguado López, E. (2010). General overview of academic production in Ibero-American psychology, 2005-2007. *Papeles del Psicólogo*, 31, 296-309.
- MacRoberts, M.H., MacRoberts, B.R. (1986). Quantitative measures of communication in science: A study of the formal level. *Social Studies of Science*, 16, 151.
- Mali, F., Kronegger, L., Ferligoj, A. (2010). Co-authorship trends and collaboration patterns in the Slovenian sociological community. *Corvinus Journal of Sociology and Social Policy*, 1, 29-50.
- Mali, F., Kronegger, L., Doreian, P., Ferligoj, A. (2012). Dynamic scientific co-authorship networks. In A. Scharnhorst, K. Börner, P. Van Den Besselaar (Eds.), *Models of Science Dynamics* (195-232). Thousand Oaks, CA: Sage.
- Newman, M.E.J. (2001). The structure of scientific collaboration networks. *Proceedings of the National Academy of Sciences*, 98, 404.
- Newman, M.E.J. (2004). Coauthorship networks and patterns of scientific collaboration. *Proceedings of the National Academy of Sciences*, 101, 5200-5205.
- Over, R., Smallman, S. (1973). Maintenance of individual visibility in publication of collaborative research by psychologists. *American Psychologist*, 28, 161.
- Price, D.J.S. (1963). *Little science, big science*. George B. Pegram lectures series. Columbia University Press. Retrieved from <http://books.google.hr/books?id=uaT7tgAACAAJ>
- Prpić, K., Brajdić Vuković, M. (2005). Znanstvena proizvodnja i produktivnost. U K. Prpić (Ur.), *Elite znanja u društvu (ne)znanja*. Zagreb: Institut za društvena istraživanja u Zagrebu.
- Schucan Bird, K. (2011). Do women publish fewer journal articles than men? Sex differences in publication productivity in the social sciences. *British Journal of Sociology of Education*, 32, 921-937.
- Scott, J. (2000). *Social network analysis: a handbook* (2nd ed.). SAGE. Retrieved from <http://books.google.hr/books?id=dXeHcgAACAAJ>
- Smith, M. (1958). The trend toward multiple authorship in psychology. *American Psychologist*, 13, 596.
- Sonnenwald, D. H. (2007). Scientific collaboration: a synthesis of challenges and strategies. *Annual Review of Information Science and Technology*, 41, 643-681.
- Strahan, R.F. (1982). More on JCP publication: Single versus multiple authorship. *Journal of Counseling Psychology*, 29, 430.
- Walter, J., Lechner, C., Kellermanns, F.W. (2007). Knowledge transfer between and within alliance partners: Private versus collective benefits of social capital. *Journal of Business Research*, 60, 698-710.
- Wasserman, S., Faust, K. (2007). *Social network analysis : methods and applications*. Cambridge: Cambridge University Press.
- Zook, A. (1987). Trend toward multiple authorship: Update and extension. *Journal of Counseling Psychology*, 34, 77.

THE PRODUCTIVITY OF CROATIAN PSYCHOLOGISTS:
A SCIENTOMETRIC ANALYSIS OF NETWORK COOPERATION
ON WORKS INDEXED IN THE WoS DATABASE
FROM 1991 TO 2010

Abstract

The purpose of the research is to describe the productivity and cooperation of registered scientists in the field of Psychology in Croatia ($N = 241$) based on journal publications indexed in the Web of science (WoS) in the time period 1991-2010. A total of 882 publications were found for 169 authors and authorship and co-authorship were analysed. Productivity data is presented on a descriptive level. The results show a high proportion of multi-author works and a lack of gender differences in productivity which is in agreement with the current literature. For the analysis of cooperation, we used social network analysis methodology including analysis of the network through four separate time periods. Indicators describing both the network (density, largest component) and the position of nodes (authors) in the network (centrality measures: degree centrality, betweenness, closeness, articulation points and singles) were calculated and found to be in a medium to highly correlation with author productivity. We conclude that network analysis provides useful productivity predictors and additional insight into cooperation among members. For a more complete cooperation analysis, future research should also encompass other forms of cooperation as well as use additional relevant variables such as job satisfaction and organisational climate. The results may be useful for the planning, organisation and evaluation of scientific efforts.

Key words: scientific productivity, scientific collaboration, coauthorship network, social network analysis, scientometrics, longitudinal network analysis, psychology in Croatia, science evaluation

Primljeno: 21. 02. 2012.