

Otvorena znanost. Kratak pregled pokreta i metodološkog značaja

Metodološka bilješka

Denis VLAŠIČEK¹  <https://orcid.org/0000-0003-1925-6818>

Hrvatski arhiv podataka za društvene znanosti, Hrvatska
dvlasice@ffzg.hr

Ivan FLIS  <https://orcid.org/0000-0002-0493-8026>

Hrvatsko katoličko sveučilište, Hrvatska
ivan.flis@unicath.hr

Svatko tko radi u sustavu znanosti tijekom posljednjih se godina susreo s pojmom otvorene znanosti. Poput neke poštapalice, pozivi za otvaranjem znanosti pojavljuju se u javnim politikama, nacionalnim (npr. NWO, bez dat.) i nadnacionalnim (Glavna uprava Istraživanje i inovacija, 2019) zakladama za financiranje istraživačkog rada, uredničkim tekstovima znanstvenih časopisa u gotovo svim znanstvenim disciplinama te suvremenim sociološkim i filozofskim opisima znanosti. Ukratko, duh otvorene znanosti izišao je iz boce i proširio se znanstvenoistraživačkim institucijama i svim drugim administrativnim tijelima vezanima uz njih. O čemu je zapravo riječ kad govorimo o otvorenoj znanosti?

POKRET ZA OTVORENU ZNANOST

Fecher i Friesike (2014) identificirali su pet “škola” okupljenih pod rastezljivim pojmom otvorene znanosti: demokratsku, javnu, pragmatičnu, infrastrukturnu i mjeriteljsku (Slika 1). Svaka od tih škola projicira svoje pretpostavke, ciljeve i glavne teme u današnji brzorastući pokret otvorene znanosti. Aktiviste demokratske škole pokreće pretpostavka da bi u demokratskom društvu pristup znanju trebao biti jednako dostupan svima. Shodno tomu, cilj je otvorene znanosti povećanje dostupnosti znanstvenih proizvoda (znanja i znanstvenih proizvoda, poput podataka ili istraživačkih materijala) svima putem smanjivanja nejednakosti u pristupu. Uz demokratsku perspektivu usko je povezana i javna škola otvorene znanosti, koja je usmjerena na omogućivanje pristupa znanstvenim procesima i rezultatima široj javnosti. Djelovanje demokratske i javne škole vezujemo uz stariji, ali izrazito

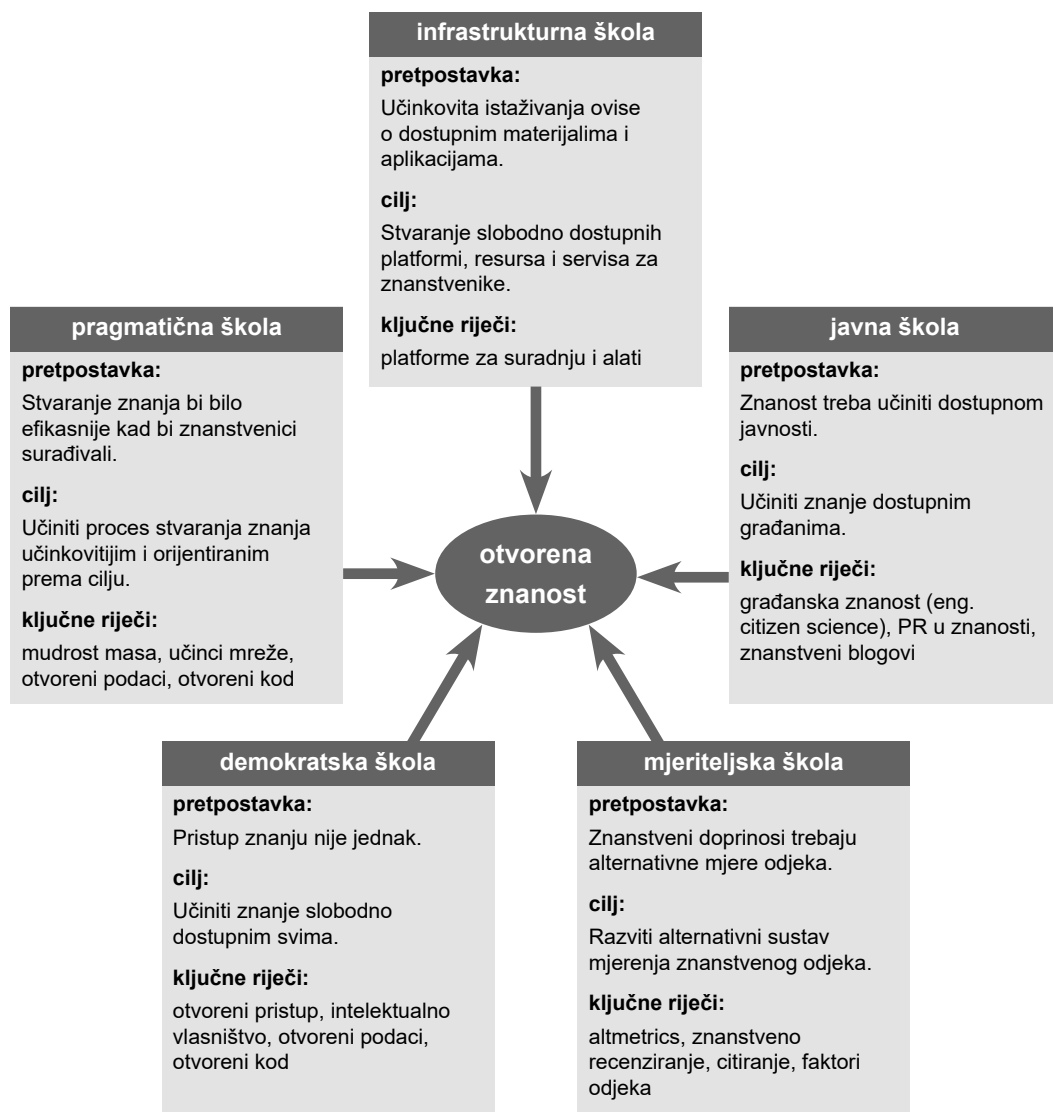
¹ Redoslijed autora odabran je koristeći programski jezik R i naredbu `set.seed(20210511); sample(c('Ivan', 'Denis'), replace = F)`.

uspješan, pokret za otvorenim pristupom znanstvenim radovima (engl. *open access*) te usmjerenost na znanstvene časopise i objavljivanje. Pragmatična i infrastrukturna škola više su orijentirane na procese i institucije samoga istraživačkog rada – prva zastupa stajalište da olakšavanje znanstvene suradnje čini proizvodnju znanstvenih spoznaja učinkovitijom, dok druga pokušava omogućiti takvu suradnju razvojem softverskih rješenja i platformi. Mjeriteljska škola usmjerena je na transformaciju načina evaluacije kvalitete znanstvenih istraživanja i samih znanstvenika. Aktivisti okupljeni oko mjeriteljske škole zagovaraju odmicanje od tradicionalnih mjera znanstvene produktivnosti, poput H-indeksa ili faktora odjeka (engl. *impact factor*), i razmatranje alternativnih mjera.

Uzimajući u obzir raznolike ciljeve opisanih škola i njihove pretpostavke, možemo vidjeti da pokret za otvorenu znanost nije jedinstven i monolitan, nego je polivalentan i ima više značenja. Kao pokret, otvorena znanost pokušava optimizirati procese i standarde znanstvenog istraživanja, učiniti znanost pristupačnijom znanstvenoj i općoj javnosti te razviti novi set standarda i kriterija za procjenjivanje kvalitete znanstvene produkcije. U najširem smislu, otvorena znanost predstavlja sve konstruktivno usmjerene reforme znanosti koje dolaze od samih znanstvenika.

Uz otvorenu znanost, posljednjih se godina istodobno razvila i nova znanstvena disciplina metaznanosti. Kako i samo ime discipline implicira, metaznanost je znanost o znanosti, odnosno empirijski proučava intervencije koje predlažu aktivisti otvorene znanosti. Peterson i Panofsky (2020: 2) opisuju metaznanost kao “društveni pokret u znanosti kojim se želi koristiti oruđa znanosti, posebice kvantifikacije i eksperimentiranja, kako bi se dijagnosticirali problemi u istraživačkoj praksi i poboljšala učinkovitost.” Drugim riječima, razni reformatori i aktivisti otvorene znanosti počeli su producirati novu empirijsku literaturu koja nas informira o optimalnim intervencijama za poboljšanje kvalitete znanstvene produkcije.

Oblici otpora reformama također su raznoliki. Uključuju znanstvenike koji podliježu inerciji postojećeg sustava, jer su izgradili karijere ispunjavajući metrike koje se sada kritiziraju, kritičare metaznanosti koji smatraju da dubinske intervencije koje predlažu reformatori nisu dovoljno dobro teorijski razrađene, empirijski potvrđene ili u potpunosti primjerene za sva područja kvantitativne društvene znanosti (Devezer i dr., 2021; Szollosi i dr., 2020) te ideološke kritičare otvorene znanosti koji je odbacuju kao najnoviju instancu komercijalizacije i sveprisutnog nadgledanja na sveučilištima (Mirowski, 2018).



Slika 1. Prikaz temeljnih pretpostavki, ciljeva i ključnih riječi pet škola otvorene znanosti. Napravljeno na temelju Fecher i Friesike (2014).

REPLIKACIJSKA KRIZA I PSIHOLOGIJA

U posljednjih deset godina, pokret za otvorenu znanost i razvoj metaznanosti kao pomoćne discipline često se veže uz rasprave o replikacijskoj krizi, vezanoj ponajprije za kvantitativna društvena i biomedicinska istraživanja. Replikacijska kriza, koja je najviše zahvatila različita područja psihologije i biomedicine (Nelson i dr., 2021), svodi se na porast zabrinutosti određenih dijelova znanstvene zajednice da velik udio objavljenih istraživanja nije replikabilan.

Replikabilnost istraživanja podrazumijeva dobivanje sličnih rezultata kao i u izvornom istraživanju u uvjetima kad se istraživački postupak opisan u izvornom istraživanju (uz opravdane manje varijacije) ponovi na drugom uzorku. Istraživački projekt koji je postigao ogroman odjek te postavio znanstvenu psihologiju u središte razgovora o otvorenoj znanosti i replikabilnosti, međunarodno je istraživanje *Reproducibility Project: Psychology* (Open Science Collaboration, 2015). Velik broj istraživačkih timova psihologa pokušao je reproducirati stotinu istraživanja iz tri najprestižnija psihologijska časopisa. Dobiveni su rezultati bili porazni jer je uspješno replicirana tek otprilike jedna trećina izvornih nalaza.

Čak i prije spomenutoga replikacijskog istraživanja iz 2015. godine, znanstvena psihologija, posebice socijalna psihologija (Yong, 2012), predstavlja ogledan slučaj ili tzv. *poster child* za replikacijsku krizu. U standardnim povijesnim pregledima, ističu se dva slučaja s početka 2010-ih: katastrofalni razmjeri fabriciranja podataka u više od pedeset radova nizozemskoga eksperimentalnog socijalnog psihologa Diedrika Stapela (Derksen, 2021; Levelt, Drenth i Noort, 2012) te objavljivanje istraživanja koje je navodno dokazalo prekogniciju (gledanje u budućnost) u jednom od najprestižnijih međunarodnih časopisa socijalne psihologije – *Journal of Personality and Social Psychology* (Bem, 2011). Ta su dva slučaja – jedan kao etički, a drugi kao metodološki skandal – potaknula preispitivanje uobičajenih istraživačkih praksi (Munafò i dr., 2017; Wagenmakers i dr., 2011) i sustava recenziranja znanstvenih radova kao mehanizma kontrole kvalitete (Nosek, Spies i Motyl, 2012; Nosek i Bar-Anan, 2012). Otad su se brojni psiholozi okupili u reformski pokret koji pokušava identificirati uzroke replikacijske krize, posebice prepoznate u manjkavim etičkim i metodološkim standardima, ponajprije kvantitativnih istraživanja.

Osiguravanje uvjeta za replikabilnost, putem intervencija informiranih otvorenom znanosti i metaznanosti, dovelo je do svojevrsne eksplozije novih istraživačkih praksi i postupaka usmjerenih na poboljšanje kvalitete kvantitativnih istraživanja. Neke od njih opisat ćemo u nastavku te obrazložiti zašto smatramo da predstavljaju pomak prema ostvarivanju nekih ciljeva ranije spomenutih škola otvorene znanosti.

VAŽNOST OTVORENE ZNANOSTI ZA ISTRAŽIVAČKU PRAKSU

Smatramo da su otvorene istraživačke prakse od ključne važnosti za sâm proces istraživačkog rada. Istraživački proces prožet je subjektivnim procjenama istraživača (Gelman i Loken, 2013) koje proizlaze iz njihova cjelokupnog poimanja svijeta i predmeta istraživanja (Flis, 2019). Toj subjektivnosti treba dodati i sve načine na koje svijet koji pokušavamo istražiti pruža aktivan ili pasivan otpor (primjerice, manjkave mjerne instrumente, slučajne pogreške u analitičkom kodu ili sudionike koji nepažljivo čitaju pitanja). U tim uvjetima transparentnost istraživačkog procesa izrazito je važna za razumijevanje njegovih rezultata. U sekcijama koje slijede pogledat ćemo neke elemente istraživačkog procesa te istaknuti kako ih je moguće poboljšati uvođenjem transparentnih istraživačkih praksi. Ukratko, osvrnut ćemo se na tri široka područja: znanstveno zaključivanje, (numeričku) reproducibilnost i ponovnu uporabu.

Kvantitativne metode i znanstveno zaključivanje

Istraživanja su u velikoj mjeri prožeta subjektivnim procjenama. Već nakon formulacije istraživačkog pitanja, istraživači se nalaze pred odlukom o tome kako izmjeriti sve varijable koje smatraju važnima ili zanimljivima. U kvantitativnim društvenim znanostima, mjerenje uglavnom podrazumijeva primjenu nekog upitnika, pri čemu za gotovo bilo koji predmet mjerenja postoji barem nekoliko različitih mjernih instrumenata. Istraživači ponekad konstruiraju *ad hoc* skale ili modificiraju postojeće mjerne instrumente jer, temeljem vlastite procjene, zaključuju da određena čestica nije prikladna za dani kontekst, u usporedbi s kontekstom u kojem je nastala. To je posebice slučaj u manjim jezičnim zajednicama, poput naše, gdje validiranih mjernih instrumenata za neke predmete mjerenja ima malo ili ih uopće nema. Na takve intervencije nailazimo i kod primjene starijih mjernih instrumenata, čije čestice istraživači ponekad smatraju zastarjelima ili kod primjene mjernih instrumenata na populacijama za koje nije provedena validacija. Spomenute intervencije mogu negativno utjecati na prikladnost mjernog instrumenta za ispitivanje nekog predmeta mjerenja. Primjerice, možemo sumnjati u valjanost rezultata nekog upitnika za mjerenje depresivnosti razvijenog sedamdesetih godina 20. stoljeća i validiranog na populaciji odraslih stanovnika SAD-a, ako taj upitnik primijenimo na učenike nižih razreda hrvatskih srednjih škola 2021. godine. Stoga, ključno je da istraživači budu transparentni oko odluka koje donose u vezi mjernih instrumenata jer to omogućuje adekvatnu procjenu provedenih istraživanja (Flake i Fried, 2020).

Jednom kad su podatci prikupljeni (ili, u slučaju predregistracije, prije nego što prikupljanje podataka uopće započne; Nosek i dr., 2018), istraživači donose odluku o tome kako analizirati podatke. U slučaju upitničkih podataka, to uključuje i način formiranja ukupnog rezultata (primjerice, hoće li odabrati neku jednostavnu linearnu kombinaciju čestica ili neki oblik diferencijalnog ponderiranja). Nadalje, istraživači sami odabiru varijable čiji doprinos žele uzeti u obzir (takozvane kontrolne varijable) ili kriterije isključivanja koje će primijeniti na podatke (primjerice, rezultate proglasiti ekstremnima ako su za određenu standardnu devijaciju udaljeni od aritmetičke sredine).

Pri odabiru statističkog postupka, istraživači se vode vlastitim poznavanjem područja istraživanja i podataka kojima barataju. No, u pojedinim slučajevima nije nužno jasno koji bi od dostupnih statističkih postupaka trebao imati prednost, odnosno koji bi trebao biti "ispravan". Odlazeći samo korak dalje, možemo se pitati postoji li, uopće, "ispravan" statistički postupak ili samo postupci koji su više ili manje prikladni za određenu situaciju.

Istraživači se, dakako, ne moraju slagati oko toga koji je statistički postupak prikladniji, to jest, za svako istraživačko pitanje postoji više statističkih postupaka koje bi različite skupine istraživača mogle smatrati prikladnima. To je izvrsno ilustrirano u radu *Many Analysts, One Dataset* Silberzahna i dr. (2018), koji su prikupili izvještaje od 29 timova istraživača zamoljenih da analiziraju isti skup podataka i pokušaju odgovoriti na isto istraživačko pitanje. Analize timova razlikovale su se po odabranom analitičkom pristupu. Primjerice, timovi su se koristili različitim verzijama višestruke linearne regresije, logističke regresije ili Poisson regresije, kao i različitim brojem prediktora uključenih u analizu (između 0 i 7). Zanimljivo je uočiti dvije stvari. Prvo, procjene timova, kao i intervali pouzdanosti tih procjena znatno su varirali. Dobivene procjene uglavnom su ukazivale na postojanje efekta u istom smjeru, ali intervali pouzdanosti su u nekim slučajevima dopuštali zaključak da efekt postoji, a u drugima ne. Drugo, što je još zanimljivije, iznosi procjena i pripadajućih intervala pouzdanosti u nekim su slučajevima bili gotovo identični, iako su korišteni različiti statistički pristupi, s različitim brojem prediktora.

Time želimo istaknuti temeljnu ulogu koju transparentnost istraživačkog postupka igra u znanosti. Transparentno prikazivanje istraživačkih odluka, podataka, materijala i analitičkog koda nužno je da bi se ispravno interpretirali nalazi nekog istraživanja. Spomenuti elementi predstavljaju kontekst koji je ključan za razumijevanje dobivenih rezultata. Osim toga, transparentnost istraživačkog procesa drugim pripadnicima zainteresirane zajednice daje mogućnost temeljite evaluacije nekog istraživanja.

Numerička reproducibilnost

Dostupnost koda (sintakse) i podataka omogućava numeričko reproduciranje rezultata provedenih istraživanja. Numeričkim reproduciranjem rezultata podrazumijevamo dobivanje istih rezultata statističkih postupaka na podacima izvornog istraživanja. Dakle, svako istraživanje treba imati detaljno opisan postupak analiziranja podataka, što uključuje transformacije izvornih varijabli, isključivanja pojedinih slučajeva, odabir i konfiguraciju statističkih testova te njihovih parametara. Koristeći se izvornim podacima moguće je dobiti rezultate analiza jednake (zanemarujući manja odstupanja) onima u izvornom radu. Iako na prvu može izgledati da je riječ o trivijalnom cilju, nedavna istraživanja (na primjer, Archmiller i dr., 2020) pokazuju da to nije slučaj, često jer sami podatci nisu dostupni drugim istraživačima.

Za postizanje numeričke reproducibilnosti ključno je podatke istraživanja učiniti javno dostupnima. Istraživačima su na raspolaganju različiti servisi, poput institucijskih repozitorija ili komercijalnih servisa poput GitHuba (www.github.com) ili FigSharea (www.figshare.com). Osim takvih servisa, u Hrvatskoj odnedavno djeluje i Hrvatski arhiv podataka za društvene znanosti (CROSSDA), čiji ciljevi uključuju objavu i pohranu podataka nastalih u društvenim istraživanjima. Jedna od prednosti Hrvatskog arhiva podataka za društvene znanosti nad drugim servisima jest to što istraživači u procesu objave podataka surađuju s djelatnicima Arhiva, koji pružaju podršku pri radu s podacima u svim fazama istraživanja te pri arhiviranju i dijeljenju podataka.

Osim dijeljenja podataka, važno je i to da istraživači dovoljno detaljno opišu sve transformacije podataka, kao i postupak njihova analiziranja, uključujući i računalne programe koji su korišteni za obradu podataka te njihove verzije. Korištenje programskih jezika uvelike olakšava bilježenje tog procesa jer pohranjeni kod (sintaksa) eksplicitno prikazuje proces analize podataka. Pritom zagovaramo korištenje programskih jezika otvorenog koda, budući da su oni besplatno dostupni svima koji mogu zadovoljiti minimalne tehničke uvjete. Neki od programskih jezika često korištenih za rad s podacima i statističke analize su Python i R, a kao novi jezik na sceni pojavljuje se i Julia. Za učenje svih triju jezika postoji mnogo besplatnih resursa; primjerice Wickham i Golemund (2016; <https://r4ds.had.co.nz/>) za R, Downey (2012; <https://greenteapress.com/thinkpython2/html/index.html>) za Python, i Lauwens i Downey (2019; <https://benlauwens.github.io/ThinkJulia.jl/latest/book.html>) za Juliju.

Ponovna uporaba

Objavlivanje podataka omogućuje ponovnu uporabu na više načina. S jedne strane, dijeljenje podataka omogućuje drugim istraživačima da pokušaju odgovoriti na isto istraživačko pitanje koristeći se nekim alternativnim statističkim postupkom. Osim toga, dijeljenje podataka omogućuje istraživačima da odgovore na nova istraživačka pitanja koja izvorni tim istraživača nije razmotrio.

Da bi se povećala upotrebljivost nekog skupa podataka, važno je voditi dovoljno detaljnu i pristupačnu dokumentaciju. Svaki skup podataka predstavlja sliku nekog dijela svijeta u određenom vremenskom periodu. Da bi se ta slika ispravno interpretirala, potreban je kontekst koji opisuje kako su podatci nastali. Taj kontekst sadržava informacije o samim varijablama (značenje svake pojedine varijable, moguće vrijednosti, oznake za podatke koji nedostaju i slično) te o cjelokupnom procesu prikupljanja podataka (vrijeme i metodologija prikupljanja podataka, ciljana populacija i slično). Koristan resurs sa savjetima za dokumentiranje podataka je *Data Management Expert Guide*, koji izdaje Konzorcij europskih arhiva podataka za društvene znanosti (CEESDA; CESSDA Training Team, 2020).

ZAKLJUČAK

U ovom smo pregledu ponudili kratak uvod u teme poput otvorene znanosti, meta-znanosti i replikacijske krize te ponudili praktične prijedloge za poboljšanje znanstvenog zaključivanja, numeričke reproducibilnosti i ponovne uporabe podataka. Nove istraživačke prakse koje predlažu aktivisti otvorene znanosti raznolike su i mnogobrojne (Crüwell i dr., 2019). Važno je da im se pristupa kao švedskom stolu, na kojem se odabire ono što je primjereno i korisno za vlastiti istraživački rad (Bergmann, 2018; prema Kathawalla, Silverstein i Syed, 2021), a ne kao posvemašnjoj promjeni svih uvriježenih istraživačkih navika. Takvim pristupom, malim koracima, postupno poboljšavamo vlastiti istraživački rad i time pridonosimo cjelokupnom korpusu znanja u svom području.

LITERATURA

- Archmiller AA, Johnson AD, Nolan J, Edwards M, Elliott LH, Ferguson JM, Iannarilli F, Vélez J, Vitense K, Johnson DH i Fieberg J (2020). Computational Reproducibility in the Wildlife Society's Flagship Journals, *The Journal of Wildlife Management*, 84 (5): 1012–1017. <https://doi.org/10.1002/jwmg.21855>
- Bem DJ (2011). Feeling the Future: Experimental evidence for anomalous retroactive influences on cognition and affect, *Journal of Personality and Social Psychology*, 100 (3): 407–425. <https://doi.org/10.1037/a0021524>
- CESSDA Training Team (2020). *CESSDA Data Management Expert Guide*. Bergen, Norveška: Konzorcij europski arhiva podataka za društvene znanosti. <https://zenodo.org/record/3820473#.YDzA7twxk-U> (1. studenog 2021.)
- Crüwell S, van Doorn J, Etz A, Makel MC, Moshontz H, Niebaum JC, Orben A, Parsons S i Schulte-Mecklenbeck M (2019). Seven Easy Steps to Open Science, *Zeitschrift für Psychologie*, 227 (4): 237–248. <https://doi.org/10.1027/2151-2604/a000387>
- Devezer B, Navarro DJ, Vandekerckhove J, i Ozge Buzbas E (2021). The Case for Formal Methodology in Scientific Reform, *Royal Society Open Science*, 8 (3), 200805. <https://doi.org/10.1098/rsos.200805>
- Derksen M (2021). A Menagerie of Imposters and Truth-Tellers: Diederik Stapel and the crisis in psychology. U: Woolgar S, Vogel E, Moats D i Helgesson C-F (ur.). *The Imposter as Social Theory: Thinking with Gatecrashers, Cheats and Charlatans*. Bristol: Bristol University Press, 53–76. <https://doi.org/10.2307/j.ctv1p6hphs.8>
- Downey AB (2016). *Think Python*. Sebastopol, California: O'Reilly Media
- Fecher B i Friesike S (2014). Open Science: One Term, Five Schools of Thought. U: Bartling S i Friesike S (ur.). *Opening Science: The Evolving Guide on How the Internet is Changing Research, Collaboration and Scholarly Publishing*. Cham: Springer International Publishing, 17–47. https://doi.org/10.1007/978-3-319-00026-8_2
- Flake JK i Fried E (2020). Measurement Schmeasurement: Questionable Measurement Practices and How to Avoid Them, *Advances in Methods and Practices in Psychological Science*, 3 (4): 456–465. <https://doi.org/10.1177/2515245920952393>
- Flis I (2019). Psychologists Psychologizing Scientific Psychology: An Epistemological Reading of the Replication Crisis, *Theory & Psychology*, 29 (2): 158–181. <https://doi.org/10.1177/0959354319835322>
- Gelman A i Loken E (2013). The Garden of Forking Paths: Why Multiple Comparisons Can be a Problem, Even When There is No “Fishing Expedition” or “p-hacking” and the Research Hypothesis was Posited Ahead of Time. <https://stat.columbia.edu/~gelman/research/unpublished/forking.pdf> (5. studenog 2021.)
- Glavna uprava Istraživanje i inovacija (2019). Open Science Factsheet. https://ec.europa.eu/info/sites/default/files/research_and_innovation/knowledge_publications_tools_and_data/documents/ec_rtd_factsheet-open-science_2019.pdf (30. rujna 2021.)
- Kathawalla U-K, Silverstein P i Syed M (2021). Easing Into Open Science: A Guide For Graduate Students and Their Advisors, *Collabra: Psychology*, 7 (1). Elektronička objava teksta prije tiska, 4. siječnja. <https://doi.org/10.1525/collabra.18684>
- Lauwens B i Downey A (2019). *Think Julia: How to Think Like a Computer Scientist*. Sebastopol, California: O'Reilly Media.

- Levelt WJM, Drenth P i Noort E (2012). Flawed Science: The Fraudulent Research Practices of Social Psychologist Diederik Stapel. <https://www.tilburguniversity.edu/nl/over/profiel/kwaliteit-voorop/commissie-levelt/> (30. rujna 2021.)
- Mirowski P (2018). The Future(s) of Open Science, *Social Studies of Science*, 48 (2): 171–203. <https://doi.org/10.1177/0306312718772086>
- Munafò MR, Nosek BA, Bishop DVM, Button KS, Chambers CD, Du Sert NP, Simonsohn U, Wagenmakers E-J, Ware JJ i Ioannidis JPA (2017). A Manifesto for Reproducible Science, *Nature Human Behaviour*, 1, 0021. Elektronička objava teksta prije tiska, 10. siječnja. <https://doi.org/10.1038/s41562-016-0021>
- Nelson NC, Chung J, Ichikawa K i Malik MM (2021). Psychology Exceptionalism and the Multiple Discovery of the Replication Crisis, *Review of General Psychology*. Elektronička objava teksta prije tiska, 23. rujna. <https://doi.org/10.1177/10892680211046508>
- Nosek BA i Bar-Anan Y (2012). Scientific Utopia: I. Opening Scientific Communication, *Psychological Inquiry*, 23 (3): 217–243. <https://doi.org/10.1080/1047840X.2012.692215>
- Nosek BA, Ebersole CR, DeHaven AC i Mellor DT (2018). The Preregistration Revolution, *Proceedings of the National Academy of Sciences*, 115 (11): 2600–2606. <https://doi.org/10.1073/pnas.1708274114>
- Nosek BA, Spies JR i Motyl M (2012). Scientific Utopia: II. Restructuring Incentives and Practices to Promote Truth over Publishability, *Perspectives on Psychological Science*, 7 (6): 615–631. <https://doi.org/10.1177/17456691612459058>
- NWO (bez dat.). Open Science. <https://www.nwo.nl/en/open-science> (30. rujna 2021.)
- Open Science Collaboration (2015). Estimating the Reproducibility of Psychological Science, *Science*, 349 (6251). Elektronička objava teksta prije tiska, 28. kolovoza. <https://doi.org/10.1126/science.aac4716>
- Peterson D i Panofsky A (2020). Metascience as a Scientific Social Movement. <https://doi.org/10.31235/osf.io/4dsqa> (30. rujna 2021.)
- Silberzahn R, Uhlmann EL, Martin DP, Anselmi P, Aust F, Awtrey E, Bahnik Š, Bai F, Bannard C, Bonnier E, Carlsson R, Cheung F, Christensen G, Clay R, Craig MA, Dalla Rosa A, Dam L, Evans MH, Flores Cervantes I, ..., Nosek BA (2018). Many Analysts, One Data Set: Making Transparent How Variations in Analytic Choices Affect Results, *Advances in Methods and Practices in Psychological Science*, 1 (3): 337–356. <https://doi.org/10.1177/2515245917747646>
- Szollosi A, Kellen D, Navarro DJ, Shiffrin R, van Rooij I, Van Zandt T i Donkin C (2020). Is Preregistration Worthwhile?, *Trends in Cognitive Sciences*, 24 (2): 94–95. <https://doi.org/10.1016/j.tics.2019.11.009>
- Wagenmakers EJ, Wetzels R, Borsboom D i van der Maas HLJ (2011). Why Psychologists Must Change the Way They Analyze Their Data: The Case of psi: Comment on Bem (2011), *Journal of Personality and Social Psychology*, 100 (3): 426–432. <https://doi.org/10.1037/a0022790>
- Wickham H i Grolemund G (2016). *R for Data Science: Import, Tidy, Transform, Visualize, and Model Data*. Sebastopol, California: O'Reilly Media
- Yong E (2012). Nobel Laureate Challenges Psychologists to Clean up Their Act. *Nature News*, 3. listopada. <https://doi.org/10.1038/nature.2012.11535> (18. prosinca 2021.)