Javno istraživanje i razvoj i nauka – privredne veze u ekonomskom razvoju: Implikacije za Bosnu i Hercegovinu

Slavo Radošević*

Sažetak: Ovaj rad predstavlja trenutno razumijevanje uloge javnog istraživanja i razvoja (I&R) u ekonomskom rastu i veze nauke i privrede u ekonomijama srednjeg nivoa dohotka, poput Bosne i Hercegovine (BiH). U drugom dijelu predstavljamo konvencionalno viđenje veza nauke i privrede koje te veze razmatra prvenstveno u smislu jednosmjernog prijenosa znanja ili njegove komercijalizacije iz istraživanja i razvoja u sektor poslovnih preduzeća. Na osnovu uporednih podataka, koji uključuju i BiH, pokazujemo alternativni pristup i raspravljamo o njegovoj relevantnosti u kontekstu BiH. Naš zaključak je da bi veze nauke i privrede (VNP) trebale podržati ukupno unaprijeđenje tehnologija, a ne (tj. ne samo) rast zasnovan na istraživanju i razvoju. U sljedećem dijelu predstavljamo trenutno razumijevanje uloge javnog istraživanja i razvoja u ekonomskom rastu. Drugi dio istražuje ulogu javnog istraživanja i razvoja u kontekstu konvergencije, dok treći dio posebno istražuje ulogu veza nauke i privrede u kontekstu konvergencije. Četvrti dio predlaže “*triple helix*” pristup vezama nauke i privrede za konvergencijske ekonomije. Njegove karakteristike ilustrujemo kroz podatke za ekonomije centralne i istočne Europe. Konačno, peti dio daje zaključak sa implikacijama za BiH.

Ključne riječi: Istraživanje i razvoj, nauka - privrede veze, *triple helix*, tehnološka nadogradnja

1. Uloga javnog istraživanja i razvoja u ekonomskom rastu¹

Konvencionalni argument za javna ulaganja u I&R, a posebno za javnu podršku privatnom I&R, temelji se na pretpostavci da firme ne ulažu u istraživanje i razvoj zbog mogućeg “curenja znanja”. Kao rezultat toga, kompanije imaju poteškoća u preuzimanju svih prednosti istraživanja i razvoja i, kao rezultat toga, premalo ulažu u I&R, što opravdava javnu podršku privatnom I&R.

Primarni analitički dokaz za ulogu javnog istraživanja i razvoja u ekonomskom rastu predstavlja ekonometrijska literatura o povratu od I&R. Ova literatura može se razdvojiti na:

* Prof. dr., Univerzitetski koledž u Londonu. E-mail: s.radosevic@ucl.ac.uk

¹ Ovaj dio se djelimično oslanja na rad Radošević S (2016) “The role of public research in economic development, Chapter II.1 in EC, Science, Research and Innovation performance of the EU. A contribution to the Open Innovation, Open Science, Open to the World agenda, DG for Research and Innovation”, Europska komisija, str. 119-139.

- procjene privatnih stopa povrata na I&R,
- procjene društvenih stopa povrata na I&R, te
- procjene povrata od javnog I&R.

1.1. Procjene privatnih i društvenih stopa povrata

Mjerenje stopa povrata na I&R temelji se na logici proizvodne funkcije, gdje se I&R tretira kao jedan od inputa pored kapitala i rada. Ovaj pristup dominira jer može dati kvantitativne procjene koliko I&R doprinosi rastu ili koliki su povrati ulaganja u I&R.

Procjene društvenih stopa povrata na I&R temelje se na pretpostavci da se prihodi od istraživanja i razvoja ne odnose samo na pronalazača, već i druge kompanije u istoj industriji. To je zato što su ove kompanije ili povezane lancima vrijednosti (dobavljači i kupci) ili sa konkurentima koji mogu slobodno učiti na osnovu grešaka lidera ili ih mogu oponašati. Društvena stopa povrata se potom procjenjuje dodavanjem privatne stope povrata (koristi za firmu koja vrši I&R) zbroju prinosa od istraživanja i razvoja koje provode vanjski elementi, bilo da se radi o drugim kompanijama ili industrijama ili zemljama.

Postoji saglasnost da su stope privatnog i društvenog povrata na privatno financirani I&R značajne i pozitivne u mnogim zemljama. Većina njih spada u raspon između (10%)20% i (30%)50%. Društveni povrat na I&R je značajan i znatno premašuje privatne prinose.² On premašuje privatni povrat za 50 do 100 posto. Sveikauskas (2007) sugerira da je privatni povrat na I&R oko 25 posto, dok je društveni povrat 65 posto.

Na makro nivou, studija OECD -a (2003) pokazuje jasnu pozitivnu vezu između intenziteta I&R-a privatnog sektora i rasta bruto domaćeg proizvoda (BDP-a) po glavi stanovnika za ekonomije OECD -a. Međutim, ne postoji jasna veza između javnog I&R i rasta, barem kratkoročno (ibid). Autori ističu da je to posljedica *“važnih interakcija između javnih i privatnih I&R aktivnosti, kao i teško mjerljivih koristi od javnog istraživanja i razvoja (npr. istraživanja u sektorima odbrane, energetike, zdravstva i univerzitetska istraživanja)*

² Za listu referenci na ove izvore vidi Radošević (2016) “The role of public research in economic development, Chapter II.1 in EC, Science, Research and Innovation performance of the EU. A contribution to the Open Innovation, Open Science, Open to the World agenda, DG for Research and Innovation”, Europska komisija, str. 119-139.

i od generiranja osnovnog znanja koje pruža dugoročno prelijevanje tehnologija” (OECD, 2003)³

1.2. Procjene povrata na javna I&R

Procjene povrata na javno financirani I&R opterećene su sa nekoliko metodoloških složenosti. Prvo, direktni efekti istraživanja i razvoja manje su važni od njegovih indirektnih efekata, koji se javljaju kada ulaganja u privatnom sektoru nadopunjuju rezultate javnog I&R-a. Drugo, ne treba sav javni I&R računati kao ulaganja, jer za značajan dio javnog I&R nije lako pripisati stopu povrata. Dakle, samo mali dio javnog istraživanja i razvoja treba klasificirati kao ulaganje (Sveiruskas, 2007). Treće, javni I&R omogućava ili otvara dalja ulaganja u I&R od strane privatnog sektora. U tom smislu, prilično je dvo-smisleno odvojiti privatna od javnih ulaganja kao da su ona neovisna jedna od drugih ako javno istraživanje uspostavi osnovno razumijevanje i koncepte dok ih privatna istraživanja i razvoj implementiraju. Dakle, ova dualna priroda javnog istraživanja i razvoja, gdje jedan njegov dio nema komercijalne ciljeve, dok drugi dijelovi stvaraju osnovu za buduća komercijalna kretanja, čini prilično nezgodnim tumačenje procjena povrata javno financiranih ulaganja u I&R.

Stilizirana činjenica ekonometrijskog istraživanja je da su stope povrata na javna istraživanja i razvoj niže ili manje značajne od onih iz privatnih I&R. Na primjer, vidi Griliches, 1986; Levy i Terleckyj, 1989; Lichtenberg i Siegel, 1991; Mansfield, 1980; Nadiri i Mamuneas, 1994. te reference citirane u Hall et al. 2010, Sveiruskas, 2007. i Kokko et al. (2015).⁴ Objašnjenja ovih rezultata su različita. Prvo, konvencionalno objašnjenje je da privatne kompanije mogu biti manje efikasne kada koriste javno finansiranje za I&R, ili ovo finansiranje može biti udaljeno od tržišta. Drugo, vladini projekti istraživanja i razvoja se nalaze u područjima koja su ili udaljena od tržišta (odbrana) ili se provode u mješovitom polju poput zdravstvenog sektora. Treće, javna istraživanja i razvoj ne stvaraju direktne koristi, već indirektno, razvijanjem osnova za I&R aktivnosti preduzeća i javnih organizacija (univerziteti, bolnice itd.). Četvrto, često se navodi da je javno istraživanje i razvoj usmjereno prema rizičnijim područjima, što bi trebalo smanjiti stopu povrata. Međutim, kada su

³ Park (1995.) je takođe otkrio da je I&R privatnog sektora važnije od javnog I&R u regresijama rasta u državama OECD-a. Vidi PARK, W.G. (1995), “International R&D Spillovers and OECD Economic Growth”, *Economic Inquiry*, Vol. 33, str. 571-91.

⁴ Za kompletnu listu referenci vidi Radošević (2016.) op. Cit.

uspješna, povrati na osnovna istraživanja i razvoj veći su u odnosu na povrate na primijenjena ili razvojna istraživanja i razvoj (Griliches, 1986; Link, 1981; Mansfield, 1980). Peto, vlade mogu pretjerano ulagati u naučno-tehnološka područja koja su ‘pretrpana’ i gdje su povrati niski. Također, trebamo imati na umu da postoje značajne razlike u tome koliko se industrije oslanjaju na javnu nauku. Na primjer, Marsili (2001) pokazuje da doprinos akademskog istraživanja industriji mjeren citatima naučnih radova u patentima može biti vrlo visok, npr u industrijama farmaceutskih proizvoda i računara. U drugim industrijama, ova vrsta doprinosa je niska, ali postojana, uglavnom kroz protok studenata.

1.3. Klasifikacija benefita javnog istraživanja

Iako ekonometrijski pristup dominira u procjeni učinaka istraživanja i razvoja, uključujući javno finansirani I&R, evidentno je da složenost odnosa između javnog istraživanja i razvoja i rasta zahtijeva alternativne pristupe. Znamo da su veze između javno finansiranog istraživanja i razvoja i privrede raznolike i indirektne. Na temelju ovih pretpostavki Martin et al. (1996) i Martin i Salter (2001) (vidi također Martin i Tang, 2006) razvili su klasifikaciju koristi javnog istraživanja, koja pokazuje raznolikost i složenost njegovih utjecaja. Ove koristi mogu nastati i iz privatnih istraživanja, iako vjerovatno u donekle izmijenjenom obliku i razmjeru. Oni razlikuju sljedeće vrste koristi (str. 520):

1. Povećanje količine korisnog znanja;
2. Obuka kvalifikovanih diplomaca;
3. Kreiranje novih naučnih instrumenata i metodologija;
4. Umrežavanje i stimulisanje društvene interakcije;
5. Jačanje kapaciteta za naučno i tehnološko rješavanje problema;
6. Stvaranje novih firmi.

Povećanje količine znanja

Javno istraživanje i razvoj povećava količine znanja koje je dostupno kompanijama. Publikacije predstavljaju bitan izvor učenja za kompanije u sektorima poput farmacije, ali zapravo je znanje, a ne samo informacije, ono što je kompanijama najvrednije. S obzirom da je javno istraživanje udaljeno od tržišta, ono stimulira i omogućava firmama da se usredsrede na istraživanja bliska tržištu, pa stoga predstavlja dopunu, a ne zamjenu. To zahtijeva poznavanje publikacija i neformalne kontakte, zajednički I&R i umrežavanje (Arundel et al., 1995).

Kvalifikovani diplomci

Kvalifikovani diplomci se u mnogim industrijama smatraju primarnom koristi za kompanije. Oni donose složene vještine rješavanja problema, nove metodologije i kapacitete za izvođenje istraživanja i razvoja. Naravno, ovaj prijenos varira od područja do područja i ovisi o tome gdje se nalaze kritične kompetencije u određenim tehnološkim područjima.

Novi instrumenti i metodologije

Instrumentacija ili naucna oprema aktivno pokreće naučni napredak (De Sola Price i Bedini, 1967). Stoga su razvoj novih instrumenata i metodologija bitan rezultat javnog istraživanja i razvoja, posebno u nekim sektorima.

Umrežavanje i društvene interakcije

Industrije su također društvene zajednice unutar kojih akademske mreže mogu odigrati vitalnu ulogu i bitan su dio tehnološkog umrežavanja. Veze sa akademskom zajednicom neophodne su u industrijama koje su direktno zavisne od nauke. U drugim slučajevima, gdje su diplomirani studenti važan izvor novih znanja, umrežavanje je više neformalnog tipa putem bivših učenika. U drugim sektorima mreže se održavaju uglavnom putem izložbi i konferencija. Martin i Salter (2001) daju pregled literature koja pokazuje intenzivnu lokaliziranu prirodu saradnje na istraživanju i razvoju, koja je odraz geografske, kulturne ili institucionalne blizine.

Tehnološko rješavanje problema

Kapaciteti istraživanja i razvoja javnog sektora u rješavanju problema nadopunjuju njegovu ulogu pružatelja opšteg naučnog znanja. Ova stručnost utjelovljena je u pojedinačnim ugovorima i saradnji sa univerzitetima i javnim službama za istraživanje sa pojedinim firmama i vrlo je česta u primijenjenim područjima istraživanja i razvoja.

Stvaranje novih firmi

Stvaranje novih firmi povezanih sa istraživanjem smatra se jednom od značajnih ili poželjnih prednosti javnog istraživanja i razvoja. Uprkos svim političkim hvalospjevima, čini se da je ovo mnogo manje značajna korist javnog istraživanja i razvoja (Brown i Mason, 2014).

Postoje potpuno nerealna očekivanja u pogledu sposobnosti javnog istraživanja i razvoja da generira patente, prihode od licenciranja i povezana istraživanja zasnovana na patentu. Samo nekolicina univerziteta u svijetu uspješno je pretvorila istraživanje u inovacije, a većina prihoda od ovih aktivnosti potječe od vrlo malog broja univerziteta.⁵

2. Uloga javnog istraživanja i razvoja u kontekstu konvergencije

U ovom odjeljku bavimo se pitanjem: koja je relevantnost literature o stopama povrata na I&R za konvergencijske zemlje čije kompanije uglavnom djeluju “iza tehnološke granice”?

Prvo, istraživanje o procijenjenim stopama povrata implicitno pretpostavlja da sposobnosti preduzeća za I&R nisu problem. Međutim, to nije slučaj u konvergencijskim ekonomijama gdje je postotak kompanija koje su stalno aktivne u polju istraživanja i razvoja značajno manji. Drugo, podjednako se pretpostavlja da sposobnosti u akademskom sektoru omogućuju redovnu interakciju s poslovnim sektorom i da se te interakcije mogu mjeriti putem budžeta za I&R. Međutim, akademski sektor možda nije u mogućnosti da uđe u interakciju s poslovnim sektorom iz različitih razloga, uključujući jaz između baza znanja javnih organizacija za I&R i preduzeća. Stoga se apsorpcijski kapacitet poslovnog sektora ne može uzeti zdravo za gotovo.

Naša prva polazna tačka za razumijevanje uloge javnog istraživanja i razvoja u kontekstu konvergencije je ta da njegovu ulogu treba sagledati u tri izvora istraživanja i razvoja: privatnom istraživanju i razvoju, javnom istraživanju i razvoju i istraživanju i razvoju iz inostranstva. Relativna važnost ovih izvora varira u zavisnosti od razvoja. U fazi konvergencije strane veze su ključne, ali u post-konvergencijskoj fazi one nisu dovoljne jer ih je potrebno zamijeniti raznim lokalnim vezama (Albuquerque et al., 2015).

Druga polazna tačka je da se uloga javnog istraživanja i razvoja može shvatiti samo ako se razmatra u odnosu na nivo sposobnosti kompanija (Albuquerque et al., 2015). Dakle, moramo uzeti u obzir evoluciju kako

⁵ Npr. na samo 10% univerziteta u Europi odnosi se 85% ukupnih prihoda generiranih kroz izume. Univerziteti Ujedinjenog Kraljevstva stvaraju tek 2–4% svojih ukupnih prihoda kroz patentiranje i licenciranje, dok mnogo značajnija sredstva dolaze iz ugovorenih istraživanja, saradničkih istraživanja i profesionalnog obrazovanja. U SAD-u, MIT generira 22 spin off kompanije godišnje, dok je prosjek među 157 univerziteta tek 4. Izvor: OECD (2013), “Commercialising Public Research. New trends and strategies”, Pariz

lokalnog javnog istraživanja i razvoja, tako i lokalnih kompanija. Osim sposobnosti kompanija, trebali bismo uzeti u obzir i “sposobnosti univerziteta” (Eun et al. 2006) ili “akademske sposobnosti” (Liefner i Schiller, 2008) jer se i one razvijaju postajući sve raznovrsnije.⁶

Ključno je razmatrati odnos između javnog istraživanja i razvoja i poslovnog sektora u kontekstu evolucije. *“Kako se razvijaju sposobnosti kompanija, univerziteta i javnih istraživačkih instituta, mijenjaju se priroda, kanali i razlozi važnosti univerziteta za kompanije”* (Albuquerque et al., 2015).

Iz historijskih izvještaja o javnom istraživanju i razvoju saznajemo da kanali interakcije između javnog istraživanja i razvoja i poslovanja imaju historiju evolucije (Albuquerque et al., 2015). Daniel Schiller i Keun Lee (2015) ocrtavaju obrazac promjene odnosa između akademske zajednice i biznisa. U početku, univerziteti i javne istraživačke organizacije pružaju ljudske resurse, testiranje i jednostavno rješavanje problema (npr. savjetovanje i tehnička pomoć). Kasnije, univerziteti i javne istraživačke organizacije postaju bolje opremljeni, a lokalne kompanije mogu koristiti njihove laboratorije. Konačno, oni poduzimaju istraživačke aktivnosti koje zamjenjuju i nadopunjuju I&R od strane kompanija. Sličan proces se odvija i na strani kompanija. *“U početku, kompanije mogu koristiti samo univerzitetski obrazovane ljudske resurse, kasnije će moći tražiti od univerziteta i javnih istraživačkih organizacija rješavanje tehničkih problema, a kako ti problemi postaju složeniji, mogu se pojaviti pitanja za istraživanje, te zajednički projekti istraživanja i razvoja mogu postati dio agende”* (str. 21), (Kruss et al., 2015).

Historijske cinjenice pokazuju da je istraživanje na univerzitetima i u javnim laboratorijama u interakciji sa sposobnostima kompanija jedan od značajnih pokretača procesa konvergencije (Mazzoleni i Nelson, 2007). Međutim, programi istraživanja i razvoja koji su efektivno doprinijeli konvergenciji nisu djelovali unutar “izoliranih akademskih krugova”, već su bili usmjereni da pomognu u rješavanju problema i unaprijeđenju tehnologije relevantne za određeni ekonomski sektor. Uglavnom su to bile nauke i inženjerske discipline orijentirane na primjenu, gdje je nauka mogla biti u direktnoj interakciji sa problemima i mogućnostima u poljoprivredi, medicini i industriji. Konačno, osim univerziteta, važnu ulogu imale su i javne istraživačke organizacije

⁶Liefner i Schiller (2008) definiraju akademske sposobnosti kao *“set funkcionalnih vještina i organizacijskih sposobnosti institucija visokog obrazovanja neke zemlje da provode svoju proširenu ulogu u procesu tehnološke nadogradnje i učenja”* (str. 281). Akademske sposobnosti čine dio apsorpcijskih sposobnosti neke države ili eksternu dimenziju internih apsorpcijskih kapaciteta kompanija.

(JIO) smještene izvan glavne univerzitetske strukture, u namjenskim laboratorijama orijentiranim na aplikacije.

Unutar ove perspektive, koristi javnog istraživanja i razvoja imaju donekle različit slijed u kontekstu konvergencije u usporedbi sa ekonomijama koje su tehnološki lideri. Slijed predstavljen ispod odražava opadajuću važnost različitih tipova koristi u konvergentnim državama⁷:

1. **Obučavanje stručnih kadrova**; Obučavanje stručnih kadrova vjerovatno je najvažnija korist od javnog istraživanja i razvoja, posebno zato što kompanije nisu dovoljno razvijene da same ponude usvajanje neophodnih vještina⁸.
2. **Povećavanje kapaciteta za naučno-tehnološko rješavanje problema**;⁹
3. **Formiranje mreža i stimulacija društvenih interakcija**¹⁰;
4. **Kreiranje novih naučnih instrumenata i metodologija**¹¹;
5. **Povećanje količine korisnog znanja kroz ugovorena istraživanja**¹²;
6. **Kreiranje novih kompanija**¹³.

3. Veze između nauke i privrede u kontekstu konvergencije

Obično se pretpostavlja da su veze nauke i privrede prilično nerazvijene u konvergencijskim kontekstima kakav je u BiH. Međutim, istraživanje koje su proveli Albuquerque et al. (2015), i dokazi iz EU to opovrgavaju (vidi Radošević, 2016). Prvo, dokazi iz istraživanja o inovacijama u konvergentnim ekonomijama pokazuju da inovativne kompanije univerzitete smatraju vrlo važnim izvorima informacija u sličnoj ili čak većoj mjeri nego u razvijenim zemljama. Na primjer, u brazilskoj anketi o inovacijama iz 2008. godine, 6,8% inovativnih kompanija smatralo je univerzitete visoko važnim izvorom

⁷ U fusnotama dajemo prijedloge mogućeg istraživačkog projekta koji bi mogao pokušati prikazati obim ovih poveznica kroz statističke indikatore. Naravno, prva opcija bi bila da se provede namjensko istraživanje o obimu ovih koristi.

⁸ Ova dimenzija se može izmjeriti kroz WEF GCR podatke o kvalitetu obrazovanja, kao pokazatelju kvalitete obučenosti stručnih kadrova.

⁹ Ova dimenzija mogla bi se izvesti iz podataka o finansiranju istraživanja i razvoja iz poslovnog sektora, sektora visokog obrazovanja i javnog sektora, iz podataka istraživanja inovacija o izvorima informacija za inovacije – univerziteta i javnih istraživačkih organizacija

¹⁰ Ova dimenzija može se izvesti iz podataka inovacijskih istraživanja o izvorima informacija za inovacije

¹¹ Ova dimenzija može se izvesti iz podataka o investicijama u istraživanje i razvoj

¹² Ova dimenzija može se izvesti iz podataka o radovima i patentima iz sektora visokog obrazovanja i javnih istraživačkih organizacija, ukoliko su isti dostupni

¹³ Ova dimenzija može se izvesti iz podataka o javno finansiranom rizičnom kapitalu

informacija. U Istraživanju inovacija EU koje je provela EK, ovaj omjer je bio 4,3% (Albuquerque et al., 2015). Takođe, nema značajne razlike između razvijenih zemalja i zemalja u razvoju u rangiranju kompanija po važnosti izvora inovacija. Na primjer, korelacija u važnosti izvora informacija za inovacije između SAD -a i Indije iznosi 0,886 (tablica 5.6 u Albuquerque et al., 2015).

Dokazi kao što je ovaj dovode u pitanje prevladavajuće mišljenje da su u konvergencijskim zemljama veze između javnog i poslovnog istraživanja i razvoja nepostojeće ili slabe. Smatramo da je ovaj mit raširen jer je odnos između javnog istraživanja i razvoja i poslovnog sektora umanjen zbog komercijalizacije istraživanja i razvoja. Zaista, iz te perspektive, veze između nauke i privrede slabe su u zemljama koje zaostaju za tehnološkom granicom. Međutim, ovo je prilično redukcionistički stav o ulozi javnog istraživanja i razvoja. Ovo gledište proizilazi iz situacije u razvijenim zemljama, što je dovelo do *Triple Helix* inicijative. Osnovna ideja je da se priroda znanja u novim industrijama promijenila tako da zahtijeva nove oblike interakcije između nauke i privrede, gdje se njihove uloge mnogo više preklapaju.¹⁴ Međutim, kako su s pravom istaknuli Eun et al. (2006), ove industrije čine manjinu tehnološkog spektra u konvergentnim ekonomijama. Za dokaze o CEE regiji, vidi Radošević et al. (2010).

Dokazi dakle ukazuju na važnost inovacijskih aktivnosti koje nisu temeljene na istraživanju i razvoju, te da je inovacijska politika u mnogim zemljama Srednje i Istočne Europe izrazito pristrana prema promociji rasta zasnovanog samo na istraživanju i razvoju. Međutim, ulaganja u I&R sama po sebi ne moraju nužno dovesti do inovacija zbog različitih strukturnih faktora. Prvo, istraživanje i razvoj mogu biti udaljeni od tržišta, pa stoga, iako sistem istraživanja i razvoja može biti međunarodno odličan, lokalna industrija možda neće moći komercijalizirati rezultate tog istraživanja i razvoja. Drugdje je to opisano kao jaz između međunarodne izvrsnosti i lokalne relevantnosti (Radošević, 2011).¹⁵ Drugo, I&R često nije primarni izvor inovacija, već se inovacije pojavljuju putem inovacijskih modusa koji nisu temeljeni na

¹⁴ Vidi Etzkowitz, H., Leydesdorff, L. (Eds.), 1997. *Universities and the Global Knowledge Economy: A Triple Helix of University-Industry-Government Relations*. Pinter, London.; Etzkowitz, H., 1998. *The norms of entrepreneurial science: cognitive effects of the new university-industry linkages*. *Research Policy* 27, 823–833.; Etzkowitz, H., Leydesdorff, L., 1999. *The future location of research and technology transfer*. *Journal of Technology Transfer* 24, 111–123.

¹⁵ Radošević 2011. op cit

istraživanju i razvoju. Slika 1 prikazuje privredu kao mjesto većeg broja široko definiranih modusa inovacija.

Inovacije se ne odvijaju samo na temelju istraživanja i razvoja, već postoje i različite vrste inovacija koje se temelje na iskustvu (rad-korištenje-interakcija) (Lorenz i Lundvall, 2006). Rast i produktivnost ekonomije mogu počivati na nizu drugih aktivnosti koje nisu inovacijske u užem smislu, ili su postepene inovacije (poboljšanja u inženjeringu proizvoda i procesa). Takođe, razne aktivnosti za povećanje produktivnosti, poput aktivnosti vezanih za kvalitet i druge aktivnosti poput praksi upravljanja usmjerenih na proizvodnju, mogu potaknuti rast dodane vrijednosti ili produktivnosti (Bloom i Van Reenen, 2010). Međutim, ove aktivnosti često mogu biti mnogo kritičnije za rast produktivnosti, konkurentnosti i zaposlenosti nego I&R. Umjesto toga, istraživanje i razvoj često su važni kao promotori apsorpcijskih kapaciteta, odnosno kao aktivnost koja pomaže kompanijama i sektoru istraživanja i razvoja da prate trendove u istraživanju i razvoju i povećaju kapacitete za prilagođavanje uvezenih tehnologija.

Slika 1. Privreda kao mjesto većeg broja modusa inovacija

Izvor: Dominique Foray, Kevin Morgan i Slavo Radošević (2018), The role of smart specialisation in the EU research and innovation policy landscape, EU Directorate-General for Regional and Urban Policy, Radni dokument, dostupan na: http://ec.europa.eu/regional_policy/sources/docgener/brochure/smart/role_smartspecialisation_ri.pdf

“Rad-korištenje-interakcija” modus inoviranja važan je kako u razvijenim tako i u manje razvijenim zemljama, a ipak je izrazito zanemaren.

Produktivnost ekonomija poput Bosne i Hercegovine mnogo je više vođena raznim aktivnostima koje nisu vezane za I&R. Tri najvažnije su: inženjering, proizvodne sposobnosti i prakse upravljanja. Nažalost, podaci o ovim aktivnostima su oskudni. Konačno, čak i kada kompanije inoviraju, većina njihovih rashoda odnosi se na nabavku mašina i opreme.

Važno je prepoznati da su ove aktivnosti međusobno komplementarne i kumulativne. Uspješne kompanije su one koje spajaju inovacije zasnovane na istraživanju i razvoju i modusu rada-korištenja-interakcije. Razvijene proizvodne sposobnosti i inženjerska poboljšanja (postupne inovacije) preduslovi su za ambicioznije inovacijske napore. Poboljšane prakse upravljanja takođe su snažno povezane sa nivoima produktivnosti kompanija i ekonomija. Dakle, inovacijska politika se ne može svesti na inovacije zasnovane na istraživanju i razvoju, već treba prepoznati i uzeti u obzir raznolikost inovacijskih modusa i aktivnosti za povećanje produktivnosti. Stoga, politiku istraživanja i razvoja treba nadopuniti mjerama koje se bave nizom drugih jednako važnih izvora inovacija i rasta produktivnosti.

Alternativni način da se ova pitanja konceptualiziraju je procijeniti u kojoj se mjeri politika bavi čitavim spektrom tehnoloških i proizvodnih sposobnosti kompanija kroz takozvano “stepenište kompetencija” ili “ljestvicu inovacija” (Slika 2). Možemo samo pretpostaviti da su u BiH ove stepenice prilično strme, odnosno da je udio istraživača u poslovnom sektoru vrlo ograničen, kao i da je udio kompanija sa tehnološkim kompetencijama također nizak.

Slika 2: Segmentiranje kompanija na ljestvici inovacija

Izvršitelji istraživanja	<ul style="list-style-type: none"> - istraživački odjel ili njegov ekvivalent - sposobnost za dugoročni pogled na tehnološke sposobnosti
Tehnološki kompetentni	<ul style="list-style-type: none"> - više inženjera - određena budžetska diskrecija - sposobnost za učešće u tehnološkim mrežama
Kompanije sa minimumom kapaciteta	<ul style="list-style-type: none"> - jedan inženjer - Sposobnost za usvajanje / adaptaciju gotovih rješenja - moguće da trebaju pomoć u implementaciji
Nisko-tehnološka MSP	<ul style="list-style-type: none"> - beznačajna tehnološka sposobnost - nema uočene potrebe za ovim - moguće da uopšte nema potrebe

Izvor: De Jager D. et al. (2002), Competence Centre Programme Estonia Feasibility Study, naručena od strane Odjela za tehnologiju i inovacije Ministarstva ekonomskih odnosa i komunikacija Republike Estonije, Tallinn.

Nije iznenađujuće da znamo mnogo više o istraživačko-razvojnem sistemu i pitanjima rasta zasnovanog na istraživanju i razvoju nego o inovacijskim aktivnostima koje se ne odnose na I&R. Stoga postoji snažna potreba za istraživanjem ovih aktivnosti, jer tek kada budu dostupni novi podaci o tim aktivnostima “skrivenih inovacija” moći ćemo legitimirati i podržati planske aktivnosti. Standardni model u ovoj oblasti koji povezuje I&R, inovacije i produktivnost je takozvani CDM model koji se može testirati na osnovu BEEPS podataka za BiH ili drugih podataka koji bi mogli kombinirati podatke iz istraživanja inovacija s drugim podacima na nivou kompanija (Okvir 1).¹⁶ Ovo istraživanje bi pokazalo koja su ograničenja CDM modela u ekonomijama poput BiH. Je li inovacija jedini pokretač produktivnosti? Koje su druge odrednice produktivnosti? Ovo bi također bila prilika za pokušaj ekonometrijskog testiranja alternativa ili modifikacija ovog modela, koji se ne zasniva na istraživanju i razvoju kao značajnom inputu, već na varijablama poput ulaganja, i koji bi se zasnivao na sintetičkom pokazatelju nadogradnje tehnologije zasnovanom na kombinaciji pitanja iz istraživanja inovacija.¹⁷ Rezultati ovog modela bacili bi mnogo više analitičkog svjetla na važnost istraživanja i razvoja za produktivnost nego što je to moguće u ovom opisnom istraživanju.

Druga linija istraživanja trebala bi se temeljiti na anketi na nivou kompanija i uzimala bi u obzir čitav niz njihovih inovacijskih aktivnosti prikazanih na slici 2.

Okvir 1: Šta je CDM model?

Tzv. CDM model je način na koji ekonomisti istražuju odnos između istraživanja i razvoja, inovacija i produktivnosti na nivou kompanije. CDM model se zasniva na nizu od tri koraka.

- U prvom koraku, kompanije odlučuju da li će, i koliko, investirati u I&R. Samo ukoliko je neto povrat na ovu investiciju pozitivan (sto analitičar ne može odrediti ali je poznato kompanijama) oni će imati pozitivno ulaganje u I&R.

¹⁶ Naziv CDM predstavlja inicijale trojice autora ovog modela: Crépon, B., E. Duguet and J. Mairesse (1998), “Research, Innovation, and Productivity: An Econometric Analysis at the Firm Level”, *Economics of Innovation and New Technology*, 7(3), str. 115–156.

¹⁷ Za neke od ideja koje se mogu koristiti u razvoju alternativnih varijabli vidi tabelu 2.2, Golderbg et al. (2011), *Igniting Innovation. Rethinking the Role of Government in Emerging Europe and Central Asia*, World Bank, Washington

- U drugom koraku, model upoređuje zadane investicije u I&R sa inovacijskim outputima, definiranim ili kao inovativnom prodajom ili kao broj patenata, koristeći funkciju proizvodnje znanja.
- Konačno, u trećem koraku, CDM procjenjuje proizvodnu funkciju koja opisuje odnos između inovacijskih outputa i produktivnosti.

Za sažetak i aplikaciju CDM modela u kontekstu CEE/CIS regije, vidi EBRD *Transition Report 2014: Innovation in Transition*, poglavlje 2, str. 31-42.

4. ‘Triple helix’ pristup vezama između nauke i privrede za konvergentne ekonomije

Konvencionalni pristup vezama između nauke i privrede, koji te veze svodi na komercijalizaciju javnog istraživanja i razvoja, previše je uzak i makroekonomski marginalan za konvergentne ekonomije. Kao što je ranije naglašeno, uloga javnih istraživačkih organizacija može se shvatiti samo u odnosu na sposobnosti kompanija za promjenu. To je potvrđeno širim ispitivanjem ovih veza u ekonomijama u razvoju (vidi Albuquerque et al., 2015). Kako se sposobnosti kompanija, univerziteta i istraživačkih instituta nadograđuju, priroda veza između univerziteta i kompanija se mijenja.

Takođe, pored veza između domaće privrede i nauke, moramo uzeti u obzir i veze između stranih direktnih investicija (SDI) i domaćih firmi i između SDI i domaćih univerziteta i istraživačkih instituta. Zašto? U konvergentnim ekonomijama, glavni priliv znanja dolazi kroz SDI i trgovinske odnose u lancima snabdijevanja (podugovaranje) i izvoz. Takođe, javne istraživačke organizacije mogu pristupiti međunarodnim mrežama znanja putem međunarodnih projekata, uključujući Horizon Europe ili Erasmus programe razmjene.

Domaće kompanije oslanjaju se na strane izvore znanja u licenciranju i ‘obrnutom inženjeringu’ ili u saradnji sa kupcima i matičnim kompanijama. Međutim, kako se zemlje razvijaju, važnost lokalnih izvora znanja, uključujući I&R, raste. U početku se lokalno znanje koristi kao nadopuna osnovnom tehnološkom znanju iz inostranstva. Kako se zemlje razvijaju, domaće veze postaju sve važnije.

Dakle, veze između nauke i privrede treba posmatrati u ovom kontekstu sposobnosti kompanija i I&R sistema za istraživanje i razvoj, i njihovog odnosa sa stranim partnerima. Slika 3 stilizovano prikazuje stvarni *triple helix* model u konvergentnim ekonomijama koji je od velike važnosti za zemlje poput BiH.

Slika 3: Triple helix model inovacija i veza između nauke i privrede u konvergentnim ekonomijama

Izvor: Radošević, 2021, Science industry links chapter: UNECE Innovation for Sustainable Development (I4SD) Review of Moldova, forthcoming

Slika 3 sugerira da nisu važne samo veze između domaćih kompanija i javnih istraživačkih organizacija, već još više veze između domaćih i stranih kompanija i veze univerziteta sa stranim firmama i međunarodnim izvorima znanja. Kako se zemlje razvijaju, priroda odnosa između nauke i privrede se mijenja. U početnim fazama, veze sa SDI su ključne, ali kako se zemlje postupno tehnološki unapređuju, odnosi između domaćih kompanija i domaćih organizacija za I&R postaju sve važniji.

U nastavku ilustriramo snagu i intenzitet svakog od tri stuba spirale u slučaju ekonomija centralne i istočne Europe, uključujući Zapadni Balkan.

Subjektivna procjena intenziteta univerzitetsko-istraživačke saradnje u istraživanju i razvoju putem WEF-ovih globalnih izvještaja o konkurentnosti na skali od 1-7 (najbolje) pokazuje relativno visoku ocjenu saradnje univerziteta i privrede u BiH u poređenju sa drugim ekonomijama zapadnog Balkana, Srbijom i Hrvatskom. Kako tumačimo ovaj rezultat? Prvo, pojedinačni pokazatelj treba posmatrati u kontekstu drugih pokazatelja. Drugo, kao što je ranije istaknuto, stanje veza između nauke i privrede može se shvatiti samo u kontekstu sposobnosti kako kompanija tako i akademske zajednice.

Slika 4: Procjena saradnje između univerziteta i privrede u istraživanju i razvoju za 2019. (skala 1-7)

Izvor: WEF GCR

Slika 5 pokazuje da je kvaliteta naučnih i istraživačkih usluga i njihova dostupnost relativno niska. Štaviše, čini se da je najlošija u poređenju sa svim uporednicima na slici 5. Ovo može sugerisati da je saradnja relativno bolja s obzirom na sposobnosti akademskog i poslovnog sektora nego u drugim ekonomijama zapadnog Balkana. Međutim, u ekonomskom žargonu, ova saradnja se može opisati kao saradnja “ravnoteže na niskom nivou”. Drugim riječima, odvija se na vrlo niskim nivoima u istraživačko-razvojnim i inovacijskim aktivnostima akademskog i poslovnog sektora. Sljedeće dvije slike idu u prilog ovoj hipotezi.

Slika 5: Kvalitet i dostupnost istraživačko-razvojnih usluga

Izvor: WEF GCR

Slika 6 pokazuje da je intenzitet istraživanja i razvoja BH ekonomije također najniži među uporednim ekonomijama. Njen prosječni intenzitet istraživanja i razvoja od samo 0,2% i 656 istraživača na 1 milion stanovnika ukazuju na minimalna ulaganja, koja su nedovoljna za adekvatno usvajanje stranog znanja, a kamoli za značajne aktivnosti stvaranja znanja.

Slika 6: Udio bruto ulaganja u I&R u GDP-u i broj istraživača na 1 milion stanovnika u 2019.

Izvor: World Bank Development indicators database

Drugi stub *triple helix* inovacijskog modela je sektor poslovnih kompanija. S obzirom na općenito vrlo niske rashode za I&R u BiH, pretpostavljamo da su ulaganja u poslovnom sektoru relativno marginalna. Ovo je dodatno otežano dominacijom malih preduzeća u ekonomskoj strukturi, koja po pravilu nemaju sopstvene kapacitete za I&R, te deindustrijalizacijom u postsocijalističkom periodu. Dakle, na ovoj osnovi, ne možemo očekivati “uzvodnu” potražnju za istraživanjem i razvojem bilo interno (unutar kompanije) ili eksterno (kroz vanjsko istraživanje i razvoj). Međutim, možemo očekivati mogući rast potražnje od “nizvodnih” aktivnosti u kompanijama, odnosno aktivnosti vezanih za poboljšanje proizvodnih sposobnosti, kvalitete i diferencijacije proizvoda.

ISO9000 certifikati i aplikacije za zaštitne žigove po milionu stanovnika su nesavršeno ali vrijedno mjerilo za ovu vrstu aktivnosti. Broj od 172 ISO9900 certifikata na 1 milion stanovnika u BiH spada u donju grupu uporednih ekonomija. Iznad je ekonomija CIS-a, koje su većinom izvan globalnih proizvodnih mreža, ali je znatno ispod susjednih i centralnoeuropskih ekonomija. Ovo odražava vrlo ograničenu integraciju BiH u lance vrijednosti EU gdje su standardi kvaliteta jedan od preduslova. Situacija je lošija u pogledu zaštitnih žigova, koji predstavljaju mjerilo za diferencijaciju proizvoda na domaćem i stranom tržištu. To također može odražavati njenu ekonomsku strukturu u kojoj postoji mali udio industrije robe široke potrošnje.

Slika 7: ISO900 certifikati i zaštitni žigovi na 1 milion stanovnika, prosjek za period 2015-19.

Izvor: ISO i WIPO baze podataka

Ključna karakteristika kompetentnih kompanija su njihove organizacione sposobnosti, pomoću kojih razumijemo kako se ljudi i resursi okupljaju kako bi obavili neki posao unutar kompanije. Organizacijske sposobnosti proizlaze iz niza povezanih aktivnosti unutar kompanije, a ne iz bilo koje pojedinačne aktivnosti. Ne postoje dogovorena mjerila organizacijskih sposobnosti. Kao nesavršene zamjene za iste, ovdje koristimo dvije komponente koje bi mogle baciti malo svjetla na njihov nivo razvoja: postojan kapacitet za apsorpciju

tehnologija i kontrola međunarodne distribucije. Slika 8 prikazuje procjenu svake od ovih komponenti za BiH kao i za uporedne ekonomije. BiH je rangirana u grupi na začelju. Njene kompanije imaju niske sposobnosti usvajanja novih tehnologija i zavise od stranih partnera za pristup međunarodnim kanalima distribucije. Obje značajke snažno će oblikovati opseg i prirodu veza između nauke i privrede.

Slika 8: Procjena postojećih kapaciteta za apsorpciju tehnologija i kontrolu međunarodnih distribucijskih kanala (WEF GCR 2019).

Izvor: WEF GCR

Treći stub veza između nauke i privrede u konvergentnim ekonomijama su SDI, koje predstavljaju primarni izvor novih tehnologija i srodnog znanja. U ekonomiji koja nema dovoljno kapitala i novih tehnologija i sa ograničenim pristupom stranim tržištima, direktne strane investicije (SDI), podugovaranje i drugi oblici znanja neophodni su za nadogradnju tehnologije, zapošljavanje i izvoz. Štoviše, BiH je pozicionirana blizu srednjoeuropskih ekonomija, što je izvrsna prilika da se pridruži njihovim industrijskim mrežama i integrira u lance snabdijevanja EU.

Ako kao kriterij koristimo udio neto priljeva u BDP-u, ovaj potencijal za brzu integraciju u industrijske mreže EU još nije iskorišten. U odnosu na uporedne ekonomije, BiH se nalazi u grupi ekonomija koje su strani investitori

“otkrili” nakon 2008. godine. Međutim, ukupan udio priliva je i dalje oskudan (1,5% BDP-a u periodu 2015-19).

Slika 8¹⁸: *Prosjek SDI neto priliva za period 2014-19 u % BDP-a*

Izvor: World Bank Development Indicators database

Alternativni način sticanja stranog znanja je kupovina stranih prava intelektualnog vlasništva putem licenci i drugih elemenata intelektualne svojine (softver itd.). Ovaj kanal stjecanja znanja je prilično marginalan u BiH i nalazi se na nivou od 0,001% BDP -a

Ukratko, naši vrlo nesistematski i prilično nesavršeni pokazatelji o tri stuba *triple helix* metode sugeriraju da su sva tri prilično slaba, pogotovo ako ih posmatramo u konvencionalnom smislu veza nauke i privrede zasnovanih na istraživanju i razvoju. Postoje značajna ograničenja tradicionalnog pogleda na veze nauke i privrede, gdje sektor istraživanja i razvoja djeluje kao primarni izvor znanja, a sektor poslovnih preduzeća kao primalac. Ključni pokretač inovacijskog procesa su kompanije, a karakteristike njihovih inovacijskih procesa određuju obim i razinu saradnje sa sektorom za istraživanje i razvoj. Ovo nas ostavlja sa pitanjem: Koji je najproduktivniji okvir veza između nauke i privrede u konvergentnim ekonomijama poput BiH?

¹⁸ SDI neto prilivi predstavljaju vrijednost dolaznih direktnih investicija od strane nerezidentnih investitora u posmatranoj ekonomiji.

5. Veze između nauke i privrede: implikacije za BiH

Naš zaključak o gornjem pitanju svodi se na jednu rečenicu: veze između nauke i privrede bi trebale podržavati nadogradnju tehnologija, a ne (ili ne samo) rast zasnovan na istraživanju i razvoju. Drugdje smo detaljnije razvili nadogradnju tehnologije kao odgovarajući okvir za mjerenje i konceptualiziranje razvoja tehnologije u konvergentnim ekonomijama (vidi Radošević i Yoruk, 2016, 2018, 2019; Radošević, 2017; Bruno et al., 2021).

Većina kompanija u novim državama članicama EU, kao i u zemljama Zapadnog Balkana, su “non-I&R inovatori” (Arundel et al., 2008). Stoga, kako bi se postigao rast i zaposlenost, politika se ne bi trebala fokusirati isključivo na poticanje ulaganja u I&R i podršku restrukturiranju prema industrijama koje su intenzivno aktivne u istraživanju i razvoju. Više od polovine kompanija u zemljama centralne i istočne Europe inovira bez ulaganja u I&R, a možemo pretpostaviti da je ovaj udio još veći u BiH. Umjesto toga, fokus politike trebao bi se baviti mnogo više faktorima proizvodnih sposobnosti (kvaliteta, produktivnost, vještine, inženjering, softver, usluge intenzivnog znanja itd.).

U skladu s tim, zemlje Zapadnog Balkana trebale bi težiti izgradnji politika koje će poticati ove procese. Pitanje je da li je ‘mainstream’ politika za nauku i tehnologije, ili inovacijska politika dovoljan i neophodan odgovor za poticanje razvoja industrije/tehnologije u regiji Zapadnog Balkana? Tvrdimo da je ‘mainstream’ politika inovacija neophodan, ali ne i dovoljan element za promicanje tehnološkog razvoja ekonomija Zapadnog Balkana. U ovim ekonomijama, I&R prvenstveno djeluju kao faktor apsorpcijske sposobnosti, a ne kao direktni izvor dodane vrijednosti i zapošljavanja.

Glavni izazov je kako započeti industrijsku i tehnološku nadogradnju, koja je specifična za određenu industriju. Čini se da baza znanja za takav proces na Zapadnom Balkanu nije glavno ograničenje. Njeni dijelovi već postoje ili su u procesu stvaranja putem opsežne strane tehničke pomoći. Na primjer, studija OECD -a (2010) o sektorskoj konkurentnosti nekoliko sektora Zapadnog Balkana ukazala je na puteve za razvoj u sektorima odjavnih predmeta, dobavljača u automobilske industriji i IT outsourcingu poslovnih procesa (vidi ispod). Izazov je kako promovirati veze između nauke i privrede koje mogu podržati ove procese?

Obrasci industrijskog razvoja na Zapadnom Balkanu u odabranim industrijama

Odjeća: od isključivo CTM (42%) usluga do postupnog uvođenja usluga dodane vrijednosti (OEM/OBM) + prevazilaženje imitacija (škole dizajna)

Dobavljači u automobilskoj industriji: izaći iz ‘troškovne zamke’ podgovaranja i krenuti prema unaprijeđenim standardima kvaliteta, dizajna i vještina upravljanja lancem opskrbe

BPIT Outsourcing: od fragmentiranih, raznolikih i kompanija orijentiranih na lokalno tržište ka fokusu na ključne kompetencije (specijalizacije) i kreiranje BPIT šampiona

Izvor: Author based on OECD (2010)

Reference

- Albuquerque, Eduardo Wilson Suzigan, Glenda Kruss, Keun Lee (eds)(2015) *Developing National Systems of Innovation: University–Industry Interactions in the Global South*, Edward Elgar, Cheltenham.
- Arundel, A., C. Bordoy and M. Kanerva (2008), ‘Neglected innovators: how do innovative firms that do not perform R&D innovate? Results of an analysis of the Innobarometer 2007 survey No. 215’, INNO-Metrics Thematic Paper
- Arundel, A., Van de Paal, G., Soete, L., 1995. PACE Report: Innovation Strategies of Europe’s Largest Firms: Results of the PACE Survey for Information Sources, Public Research, Protection of Innovations, and Government Programmes. Final Report, MERIT, University of Limburg, Maastricht
- Bloom, N. and Van Reenen, J. (2010) Why Do Management Practices Differ across Firms and Countries? *Journal of Economic Perspectives*, Volume 24, Number 1, Winter 2010, p.203–224
- Derek de Sola Price and Silvio A. Bedini, (1967) “Instrumentation,” in *Technology in Western Civilisation*, ed.
- Eduardo Albuquerque, Wilson Suzigan, Glenda Kruss, Keun Lee (eds)(2015) *Developing National Systems of Innovation: University–Industry Interactions in the Global South*, Edward Elgar, Cheltenham.
- Glenda Kruss, Keun Lee, Wilson Suzigan, and Eduardo Albuquerque (2015) Introduction, In Albuquerque et al (2015) op cit
- Griliches, Z. (1986). “Productivity, R&D, and basic research at the firm level in the 1970s”. *American Economic Review* 76, 141–154.
- Jong-Hak Eun, Keun Lee, Guisheng Wu (2006) Explaining the “University-run enterprises” in China: A theoretical framework for university–industry relationship in developing countries and its application to China, *Research Policy* 35 (2006) 1329–1346
- Lee, Jong Dong Lee, Slavo Radošević, Dirk Meissner, Nick Vonortas (eds) *Technology Upgrading and Economic Catch-up*, Oxford University Press
- Levy, D., Terleckyj, N. (1989). “Problems identifying returns to R&D in an industry”. *Managerial and Decision Economics* 1–2, 43–49.

- Lichtenberg, F.R., Siegel, D.S. (1991). "The impact of R&D investment on productivity-new evidence using linked R&D-LRD data". *Economic Inquiry* XXIX, 203–228.
- Liefner, I., Schiller, D. (2008). Academic capabilities in developing countries – a conceptual framework with empirical illustrations from Thailand. *Research Policy*, 37, 276–293.
- Lorenz, E. and Lundval, B. A. (2006)(eds) How European economies learn: coordinating competing models, Oxford University Press, Oxford.
- Mansfield, E. (1980). "Basic research and productivity increase in manufacturing". *American Economic Review* 70, 863–873.
- Mazzoleni Roberto and Richard R. Nelson (2007) Public research institutions and economic catch-up, *Research Policy* 36 (2007) 1512–1528
- Melvin Kranzberg and Carroll W. Pursell, Jr. (Oxford: Oxford University Press).
- Meyer-Krahmer, F., Schmoch, U., 1998. Science-based technologies: university–industry interactions in four fields. *Research Policy* 27, 835–851.
- Nadiri, M.I., Mamuneas, T.P. (1994). "Effects of public infrastructure and R&D capital on the cost structure and performance of US manufacturing industries". *Review of Economics and Statistics* 76 (1), 22–37.
- OECD 2003 The Sources of Economic Growth in OECD Countries, Paris
- OECD 2003 The Sources of Economic Growth in OECD Countries, Paris
- Radošević S. (2017) Upgrading technology in Central and Eastern European economies. *IZA World of Labor*: 338 doi: 10.15185/izawol.338
- Radošević Slavo and Esin Yoruk (2016) Why Do We Need Theory and Metrics of Technology Upgrading?, *Asian Journal of Technology Innovation*, Volume 24, 2016 - Issue sup1, <http://dx.doi.org/10.1080/19761597.2016.1207415>
- Radošević Slavo and Esin Yoruk (2018) Technology upgrading of middle-income economies: A new approach and Results, *Technological Forecasting & Social Change* 129: pp. 56–75
- Radošević, S., M. Savic and R. Woodward (2010) *Knowledge based entrepreneurship in central and eastern Europe: results of a firm level based survey*, In Malerba, F. (ed) *Knowledge-Intensive Entrepreneurship and Innovation Systems*, Routledge, p.198-218
- Radošević, Slavo Deniz E. Yoruk and Esin Yoruk (2019) Technology Upgrading and Growth In Central and Eastern Europe, Chapter 8 in *Social and Economic Development in Central and Eastern Europe. Stability and Change after 1990* Edited By Grzegorz Gorzelak, Routledge, London
- Randolph Luca Bruno, Kirill Osaulenko and Slavo Radošević (2021) Technology Upgrading in Emerging Economies: A New Approach to its Measurement, Results and Relationship to Mainstream Measures , In Lee et al, Oxford University Press
- Schmoch, U., 1997. Indicators of the relations between science and technology. *Scientometrics* 38: 1., 103–116.
- Sveikauskas Leo 2007 R&D and Productivity Growth: A Review of the Literature, Bureau of Labor Statistics Working Paper 408