



Bojan Baškot

Centralna banka Bosne i Hercegovine

✉ bojanbaskot@gmail.com



Miloš Grujić

Penzijski rezervni fond Republike Srpske

✉ milos.grujic@pref.rs.ba



SPECIFIČNOSTI BOSNE I HERCEGOVINE KAO ODREDNICE DIREKTNIH STRANIH INVESTICIJA

THE SPECIFICS OF BOSNIA AND HERZEGOVINA AS A DETERMINANT OF FDI

Summary: In this paper we are presenting the reaction employment, wages, prices, industrial production, real effective exchange rate and wages on one standard deviation shock from foreign direct investments. We have used the vector autoregressive model with sign restrictions, where those restriction are defined by Uhlig's penalty function. Result show that main aggregates have the expected reaction. Considering the nature of the investments, their effects are in accordance with the macroeconomic logic. Consumption is an obvious channel for the positive reaction of employment and wages, where wages are, conditionally speaking, the measure of the labor's productivity.

Keywords: vector Autoregression model,
Uhlig's penalty function, sign restrictions

JEL classification: F43

Rezime: U radu smo predstavili reakciju zaposlenosti, plata, cijena, industrijske proizvodnje, domaće valute i plata u Bosni i Hercegovini na šok od jedne standardne devijacije koji su izazvale direktnе strane investicije. Koristili smo model vektorske autoregresije sa znakovnim restrikcijama sprovedenim kroz Uligovu penalizirajuću funkciju. Rezultati pokazuju da posmatrani agregati imaju očekivanu reakciju. Investicije, s obzirom na njihovu prirodu, imaju makroekonomski logične učinke. Potrošnja se nameće kao očigledan kanal preko koga se ostvaruje pozitivna reakcija zaposlenosti, odnosno plata, koje mogu uslovno da se dovedu u vezu s produktivnošću rada

Ključne riječi: model vektorske autoregresije,
Uligova penalizirajuća funkcija, znakovne restrikcije

JEL klasifikacija: F43

Direktne strane investicije smatraju se jednim od najznačajnijih generatora rasta. Naravno, investicije su često prizivane u kolokvijalnom govoru kao univerzalno dobro. Pozitivni efekti moraju biti naznačeni kao uslovni. Struktura, namjena i realizacija određuju konačne efekte ovih kapitalnih tokova.

Nećemo se baviti klasičnom percepcijom investicija koja podrazumijeva dva oblika provođenja direktnih stranih investicija. To su ulaganja u realnu imovinu i ulaganja u kupovinu drugih pravnih lica. Dalje, možemo govoriti o potpuno novim ulaganjima i ulaganjima u rekonstrukciju postojećih kapaciteta pa se kolokvijalno definišu kao grinfild (eng. greenfield) i braunfeld investicije (eng. brownfield).

Direktne strane investicije, bilo kakve vrste, imaju izražen promptni efekat. Efekti, kako oni pozitivni, tako i negativni, koji se manifestuju u dugom roku, obično nisu predmet dnevнополитичке analize.

Ovdje nas interesuju potencijalno širi efekti investicija od strane nerezidenata u smislu zaposlenosti, transfera tehnologija i drugih pokazatelja koji uglavnom trebaju više vremena da odreaguju na investiciju. Ovdje se fokusiramo na strukturu novoangažovane radne snage. Strane direktnе investicije traže jeftiniju radnu snagu, žele iskoristiti tržišni potencijal, javljaju se kao supstitucija za međunarodnu trgovinu, u manjoj ili većoj mjeri su povezani s prirodnim resursima.

Investicije ostvaruju svoj uticaj direktno i indirektno, putem svojevrsnog efekta "preljevanja". Indirektni imaju vremenski period djelovanja neuporedivo duži nego direktni efekti. Kratkoročni i pozitivan uticaj na autput određene ekonomije uslijed dolaska svježeg kapitala je neminovan. Nas interesuje dugoročan, odnosno konačan, širi efekat.

Investicije koje nisu povezane s prirodnim resursima su uglavnom povezane s multinacionalnim kompanijama, te su kompleksno-vertikalne po prirodi. Sa druge strane, investicije koje su povezane s prirodnim resursima imaju dosta manje interakcije s ljudskim kapitalom. Prvi tip investicija ima značajan odloženi efekat u prostoru na tržišni potencijal, a drugi tip se ne izdvaja u tom smislu.

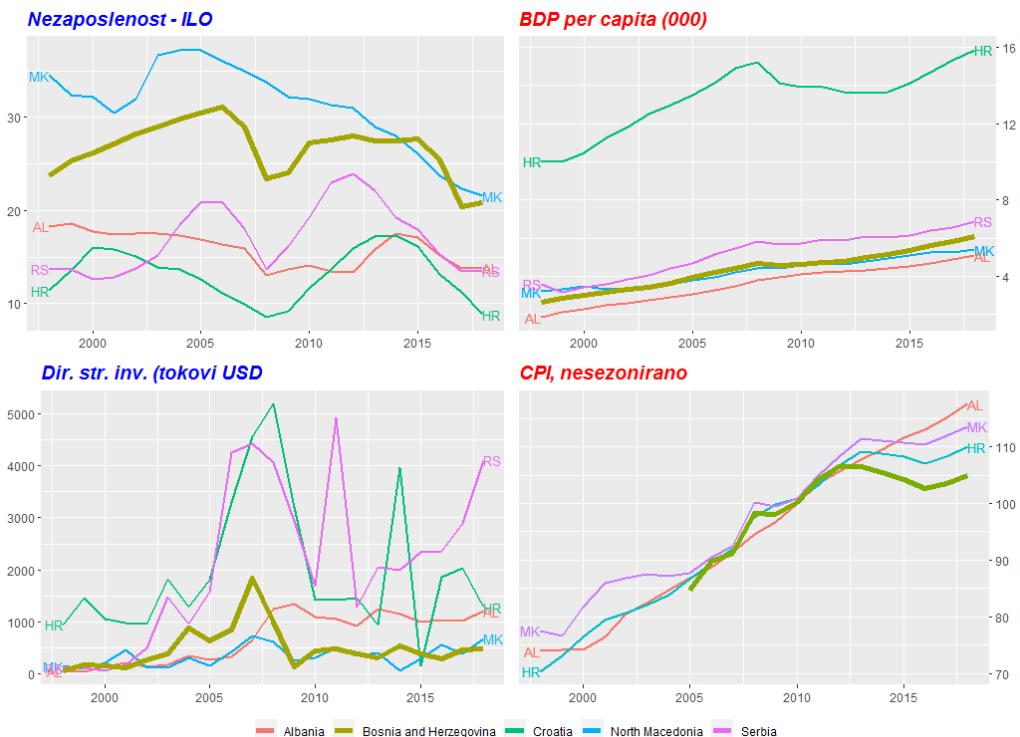
Kao metod istraživanja izabrali smo model vektorske autoregresije sa znakovnim restrikcijama. U užem smislu koristimo Uligovu (Uhlig) penalizirajuću funkciju da sprovedemo znakovne restrikcije.

Koristeći model vektorske autoregresije, uslovno govoreći, možemo koristiti zaokružen makroekonomski model koji sve promjenljive posmatra kao endogene. Sa znakovnim restrikcijama smanjujemo broj jednačina koje se ocjenjuju, i dobijamo rješiv model. Uligova penalizirajuća funkcija daje nam vezu sa Bajesovim statističkim zaključivanjem, koje je u odnosu na klasično statističko zaključivanje daleko robusnije kada su u pitanju problemi s podacima.

Ostatak rada je organizovan tako da naredna sekcija predstavlja pregled relevantne literature, a nakon toga dolazi dio koji predstavlja podatke korištene u analizi. Dijelu koji izlaže rezultate prethodi dio koji objašnjava primijenjeni model vektorske autoregresije s Uligovom penalizirajućom funkcijom kao instrumentom definisanja znakovnih restrikcija. Na kraju se nalaze zaključna razmatranja.

Kako BiH stoji po pitanju stranih ulaganja, nezaposlenosti, nivoa cijena i autputu u poređenju s okruženjem. U tom smislu odgovore možemo potražiti na slici 1.



**Slika 1. BiH u odnosu na zemlje okruženja**

Slika 1. otkriva ne baš zavidnu poziciju kada je nezaposlenost u pitanju, ali isto tako kada govorimo o direktnim stranim ulaganjima. Autput se i

drži solidno ako uzmemu u obzir prethodno spomenute aggregate, a CPI je na očekivanom nivou s obzirom na to da je valuta usidrena za evro.

1. PREGLED LITERATURE

Neki od najvažnijih činilaca koji privlače strana ulaganja su: prirodna bogatstva, tržišni potencijal, ljudski kapital, odnosno radna snaga, razvijenost institucija, rizik koji se povezuje s određenom zemljom i sl. Kada govorimo o ograničenjima, institucije se često navode kao faktor koji može djelovati stimulativno, ali u slučaju nerazvijenosti istih navodi se ekstremno

nestimulativno dejstvo. Poelheke i Van der Pleg su pošli od panel regresionog modela, te zaključili da institucije nemaju statističku značajnost u procesu privlačenja direktnih stranih investicija. Pozadina je jednostavna. Kada je zemlja bogata prirodnim resursima, tada su političke elite sklone da rade na podrštvu institucija, jer iste onemogućavaju svo-

jevoljnost u korištenju prirodnih resursa bez uzimanja u obzir pozitivnih efekata po širu društvenu zajednicu. Isti autori pokazuju da udaljenost ima pozitivan uticaj na samu odluku o destinaciji investicija. Dalje, osnivanje svojevrsne podružnice u geografski udaljenoj zemlji imaće "sekundarni" efekat prelijevanja u vidu smanjenja obima međunarodne trgovine. Ovi autoru iznose značajnu tehničku napomenu. Vremenske serije koje predstavljaju određene podatke o direktnim stranim investicijama ne mogu nikako biti stacionarne. Neminovan je rastući trend. Isto tako navode i problem heterogenosti, koji je ključan kada govorimo o podacima organizovanim u obliku panela, te zaključuju da nije dovoljna sama pretpostavka o postojanju samo determinističkog trenda, te su u tom smislu potrebne korekcije u samom modelu (Poelhekke & Van der Ploeg, 2013). Napomenimo ovdje da, ukoliko moramo prepostaviti postojanje trenda kod vremenskih serija, u procesu sagledavanja vremenskih serija sa tehničko-ekonometrijskog aspekta, tada se nameće pitanje o preispitivanju pojma "rasta direktnih stranih investicija". Upravo je to osrvt koji se tiče ovog izlaganja. Potrebno je suštinsko razlučivanje efekata investicija. Sam broj koji pokazuje količinu investicija ne smije biti cilj. Taj broj je simptom, posljedica, indikator. Efekat investicija je višeslojan i kao takvog ga treba posmatrati.

Baltagi je sa grupom autora analizirao problem zanemarivanja heterogenosti panela u slučaju kada se posmatraju direktne strane investicije. Posmatrali su determinante direktnih stranih investicija iz SAD i povezane prodaje u periodu od 1989. do 1999. godine koristeći više vidova podataka na nivou pojedinih industrijskih djelatnosti (Baltagi, Egger, & Pfaffermayr, 2007). Postavili su model u kojem kontrolisu efekte trećih zemalja i binarnu promjenljivu koja predstavlja vrijeme specifično za određene

industrijske grane zemlje u koju se investira. Nije se posmatrala stacionarnost vremenskih serija povezanih s investicijama. U tom slučaju ako imamo heterogeni panel, koeficijenti regresije mogli bi biti pogrešni. Problematiku zanemarivanja karakteristika vremenskih serija kada su u pitanju direktnе strane investicije istraživao je i Blonigen sa grupom autora (Blonigeg, Davies, Wadell, & Naughton, 2007).

Prvi radovi vezani za panele bili su bazirani na razlikovanju "fiksnih" i "slučajnih" efekata. Mundlak (Mundlak) je omogućio pristup koji se može koristiti za linearne, ali i nelinearne slučajave koji podrazumijeva izbjegavanje upotrebe Hausmanovog (Hausmann) testa (Mundlak, 1978). Kasnije tim putem nastavljaju Arellano i Bond (Arellano & Bond, 1991), koji uvode ocjenjivanje parametara primjenom generalizovanog metoda momenata za podatke organizovane u vidu panela, ali prije svega kada je riječ o mikroekonomskim problemima. Kada smo kod tehničkih problema, napomenimo da jedan od razloga drugačijeg pristupa za panele leži u činjenici da frakcionalna kointegracija daje lažnu potvrdu nestacionarnosti kroz Johansenov test (Baillie & Bollerslev, 1994). Napomena problematike primjene panel regresionog modela je važna jer naizgled složena državna struktura u BiH može biti iskorištena kao tehničko-ekonometrijska prednost. Budući da postoje podaci za dva entiteta, možemo postaviti panel sa ekstremno malom jednom dimenzijom i samim tim dobiti na "dubini" vremenskih serija. Naravno, postoji mogućnost i posmatranja BiH kao dijela zapadnog Balkana. Prije takvih metodoloških pristupa treba voditi računa o svim navedenim ograničavajućim faktorima, koji nas dovode do upotrebe Uligove penalizirajuće funkcije kao pristupa koji je jednostavniji nego što bi bio slučaj da smo izabrali klasično statističko zaključivanje, te samim tim sve propozicije koje nameće Boks-Dženkinsov pristup.



Bilo koji pristup koji razmatra makroekonomsku problematiku direktnih stranih investicija mora prethodno uzeti u obzir raspoloživost podataka. Ovakvi problemi postaju krajnje značajni kada se razmatra slučaj BiH. Makroekonomski podaci su uglavnom obezbijedeni od strane državnih agencija. Istraživač nema izbora nego da uzima navedene podatke kao takve. Mogućnost sproveđenja istraživanja bilo koje vrste predstavlja izuzetan finansijski napor, te lakoća provođenja istraživanja na osnovu upitnika, intervjua i slično, koji su uglavnom na raspolaganju istraživačima koji se bave mikroekonomskim problemima, nije moguća za makroekonomskе probleme. Mikroekonomski problemi su statične prirode. Makroekonomski problemi su, sa druge strane, dinamičke prirode. Direktne strane investicije bi trebalo da se posmatraju u što dužem vremenskom periodu, dok sa druge strane mikroekonomski problemi obično imaju malenu vremensku dimenziju, ali dimenzije koje se odnose na posmatrane individualne entitete su veoma velike. Kada se posmatraju direktne strane investicije, dolazi u obzir posmatranje okvira koji je isključivo dinamičke prirode, što predstavlja dodatne izazove. Ovim pitanjem u kontekstu regresionih panel modela bavili su se Bai (Bai, 2009), Čadik i Pešeran (Chudik & Pesaran, 2014). Na ovom polju Pešeran je bio aktivан i samostalno (2006).

Model vektorske autoregresije uveo je Sims koristeći ovaj pristup u oblasti monetarne ekonomije (Sims, 1980). Ovaj pristup ima neodoljivu jednostavnost u modeliranju određenog ekonomskog sistema. Prevladavanje problema endogenosti na način da se manu pretvara u prednost otvara vrata za široku primjenu u svim oblastima. U oblasti ekonomije rada imamo radeće Fudžite (Fujita, 2012), Brauna, Deboka i Dičećija (Braun, Debock, & DiCeccio) i Kanove, Salida i Mikalećija (Canova,

Lopez-Salido, & Michelacci, 2007). Panel je, sa druge strane, nerijetko zgodan izbor za metodološki pristup za zaključivanje o uticaju direktnih stranih investicija. Međutim, to podrazumijeva postojanje homogene grupe, odnosno dugačkih vremenskih serija za više zemalja koje su "slične".

Metodološki pristup je jedna strana problema. Ako možemo uslovno tvrditi, većina investicija koje nisu povezane s potrošnjom u BiH, povezane su s prirodnim resursima, odnosno jeftinom radnom snagom. Izvozimo tekstil, namještaj, obuću, struju, metale, drvo i slično. Poelheke i Van der Pleg su prilikom posmatranja resursnih i neresursnih direktnih stranih investicija pošli od toga da ukoliko su greške stacionarne, kako u vremenu, tako i u prostoru, tada možemo računati na kointegraciju koja nam pomaže u sagledavanju dugoročnih efekata direktnih stranih investicija (Poelhekke & Van der Ploeg, 2013). Takođe, test jediničnog korijena podrazumijeva više napora budući da prostorni efekti onemogućavaju uspješnu primjenu standarnog IPS testa (akronim od Im, Pesaran i Shin). Zavisnost između pojedinačnih opservacija u panelu (ali ne kroz vrijeme) može se prevazići korištenjem testa Langražovog multiplikatora, uz dopuštanje promjenljive koja podrazumijeva docnju (engl. lag) u prostoru. Međutim, spomenuti autori Poelheke i Van der Pleg koriste IPS test i uspijevaju prevazići problem homogenosti panela. Isti autori su koristili GDP per capita kao proksi za tržišni potencijal, te su pokazali da tržišni potencijal zajedno s ljudskim kapitalom igra značajnu ulogu u procesu privlačenja investicija koje nisu povezane s resursima, što je u jednu ruku i očekivano, a udaljenosti i visoke stope poreza imaju suprotan efekat.

Kada je riječ o panelu i stranim direktnim investicijama u BiH, odnosno zemlje zapadnog Balkana, tada postoji niz ograničavajućih fak-

tora. Vremenske serije skoro svih zemalja u regionu, a i BiH, su izuzetno kratke. Samim tim dinamička priroda može vrlo lako biti izostavljena iz opsega posmatranja. U dijelu koji se bavi podacima objasnili smo niz nedostataka u konkretnom slučaju vezanom za BiH, a takvi primjeri su prisutni i u ostalim zemljama regiona. Sa druge strane, izgledna je primjena panela u situaciji u kojoj imamo dva entiteta. Međutim, niz radova gorespomenutog Pešerana bavi se problematikom primjene takvog pristupa za slučajeve koji imaju problematične karakteristike, a koji bi u primjeru BiH poprimili ekstreman oblik.

Poznato je da zemlje koje imaju slabu valutu u realnim uslovima imaju efekat privlačnosti stranih direktnih investicija uslijed činjenice da je kupovna moć novca izraženija, odnosno da su manji netgovinski troškovi u zemlji odrednici investicija (Froot & Stein, 1991). Viler i Mudi (Wheeler, Moody) su pokazali da nema korelacije između direktnih stranih investicija pravnih lica iz SAD i faktora rizika za određenu zemlju u koju se investira, što je dalje povezano s razvijenošću institucija, tako da i korelacija investicija nepovezanih s prirodnim resursima s razvijenošću institucija mora biti shvaćena krajnje uslovno (Wheeler & Mody, 1992). Ovi autori su kombinovali mjeru korupcije sa 12 drugih indikatora od kojih su neki: "podrška vlade privatnom poslovanju", "stav suprotstavljenih grupa prema direktnim stranim investicijama", "ukupno životno okruženje za strance" itd.

Spomenuli smo udaljenost kao faktor koji određuje privlačnost za investitore. Sredinom 2019. godine Folksvagen (Volkswagen) je donio odluku da investira u nova postrojenja u Turskoj. U konkurenciji za ovu investiciju bile su Rumunija i Bugarska, dvije novopridošle članice EU, Srbija i Sjeverna Makedonija, dvije zemlje zapadnog Balkana koje su na granici s

EU, i Turska, koja jeste samo djelimično evropska zemlja. Sa druge strane, razvijenost institucija se nerijetko napominje kao drugi faktor koji podstiče strane investitora. U Turskoj se može uočiti trend koji je obilježen značajnim autokratskim tendencijama. Iako su neki potezi, poput smjene guvernera Centralne banke, nešto što smo mogli vidjeti i u Mađarskoj, zemlji koja je članica EU.

U globalnim tokovima kapitala na pomolu su tektonski poremećaji uslijed trgovinskog rata na relaciji SAD - Kina. Očekuju se investicioni manevri da bi se odgovorilo na novonastalu situaciju. Kineske investicije u susjedne azijske zemlje mogu biti jedan od odgovora na uvozne carine. Sa druge strane, Turska može biti posmatrana kao direktna konkurenca regionu zapadnog Balkana investicijama koje ciljaju na tržiste EU. Međutim, očigledno da unutrašnji negativni trendovi, ali i spoljnopolitički rizični potezi, ne čine Tursku manje atraktivnom destinacijom za investiranje u odnosu na region zapadnog Balkana, kome pripada BiH.

Fajgelbaum i saradnici su predložili da Linderova hipoteza može imati svoju primjenu u slučaju direktnih stranih investicija. Ideja je da zemlje na sličnom nivou dohotka postaju partneri u razmjeni investicija (Fajgelbaum, Grossman, & Helpman, 2015). U tom smislu očekivano je da Japan investira u EU u postrojenja za proizvodnju automobila jer evropski kupci imaju novca da kupe vozila japanskih proizvođača. Japan ima dovoljno visok nivo dohotka da može računati na investicije, recimo, njemačkih proizvođača automobila koji mogu očekivati prodaju na odgovarajućem nivou. Sa druge strane, tu se otvara pitanje EU u smislu homogenosti, te vezanih odstupanja od navedene hipoteze, ali isto tako to može služiti kao savršen argument za jasan afirmativan stav u smislu proširenja EU sa stanovišta zemalja zapadnog Balkana. Bugarska može dobiti investi-



ciju iako njen nivo dohotka nije u skladu s pro-dajnim preferencijama investitora, ali tu je tržište EU koje jeste.

U tom smislu moguće je posmatrati visok nivo investicija između zemalja bivše Jugoslavije. Međutim, tu postoji niz drugih potencijalnih objašnjenja koja nužno ne moraju imati uporište u ekonomskoj logici.

Ekonomski logika za investiranje nerijetko popusti pred drugim silama koje su druge prirode. Kada govorimo o transferima tehnologija zajedno s investicijama, tada je Kina sa svojim eksplisitnim pristupom quid pro quo (QPQ), dirigovanim od strane države, bila ekstreman primjer u tom smislu. Međutim, najnoviji trgovinski rat vjerovatno ostavlja i ostavljaće svoje tragove u nivou direktnih stranih investicija, ali i transfera tehnoloških dostignuća s tim investicijama.

QPQ je praksa koju je eksplisitno praktikovala Kina do 2001. godine (tada postoje članica Svjetske trgovinske organizacije) kada su u pitanju investicije multinacionalnih kompanija sektorima koji mogu biti okarakterisani kao visokotehnološki. Svaka investicija podrazumijevala je transfer tehnologija. Primjer za ovo je jasan akt kojim Komisija za državno planiranje Kine uvodi inicijativu za specifikacije zahtjeva koji se postavljaju pred multinacionalne kompanije koje hoće da uđu na tržište automobila (Holmes, McGrattan, & Prescott, 2015).

Ovim aktom propisuje se da strano pravno lice koje želi da prodaje automobile u Kini mora da obezbijedi formu zajedničkog ulaganja sa domaćim pravnim licem. Utvrđuje se zahtjev vezan za transfer tehnologija kojim se navadi da instalirani kapaciteti moraju biti na tehnološkom nivou devedesetih, te da mora biti utvrđeno odjeljenje za razvoj i istraživanje (Walsh, 1999).

Iako su ovakve smjernice pod pritiskom Svjetske trgovinske organizacije povučene iz

zvaničnih akata, zahtjevi u tom duhu i dalje su aktuelni, ali u nezvaničnom obliku. Zahtjevi za zajedničko ulaganje i dalje su aktuelni u industrijskim granama koje su klasifikovane kao prioritetne. Zajednička ulaganja moraju proći proces odobrenja u vladinim tijelima, a proces odobrenja je podložan diskrecionim odlukama tih tijela (Shea, 2012).

Jasno je da BiH nema na raspolaganju ni jedan instrument koji ima Kina za ovakav vid uslovljavanja s ciljem usmjeravanja kada su u pitanju direktne strane investicije. Centralizovana državna struktura s mogućnošću jasnog kontrolisanja tržišta koje svojom veličinom predstavlja presudnu destinaciju za bilo koju multinacionalnu kompaniju koja se smatra ozbilnjom je neuporediva sa stanjem u BiH.

Tržišni potencijal BiH u tom smislu nije uporediv. Posmatrano od 1998. godine, Austrija, Srbija i Hrvatska se nalaze na vrhu zemalja koje investiraju u BiH. Kada bismo izuzeli krupne investicije u bankarski sektor, Austrija bi izgubila prvo mjesto, te bismo imali Srbiju, Hrvatsku i Sloveniju na čelu. U svjetlu regionalnog pristupa penetraciji tržišta od strane međunarodnih korporacija, možemo jednostavno zaključiti da druge zemlje imaju prednost u odnosu na BiH kao polaznica regionalnih tržišnih poteza. Takve investicije, koje nisu povezane s jeftinim resursima, uslovno mogu donijeti višeslojan efekat prelijevanja, prije svega u tehnološkom smislu i u oblasti ljudskog kapitala. Više autora je potvrdilo uslovjenost efikasnosti investicija veličinom i potencijalom domaćeg tržišta. Tu su već spomenuti Poelheke i Van der Plege, zatim Balasubramanjam sa grupom autora (Balasubramanyam, Salisu, & Sapsford, 1999).

Naravno, efekti stranih ulaganja mogu biti i negativni. Efekat istiskivanja (eng. crowdout) se manifestuje u smislu da uslijed novih ulaganja dolazi do smanjenja postojeće domaće proizvod-

nje. Kada smo govorili o penetraciji tržišta kao poveznici za strana ulaganja, tada možemo negativni efekat sagledati krajnje jednostavno. Dolazak međunarodnog maloprodajnog lanca može zatvoriti vrata malom domaćem proizvođaču koji nije ravan široj konkurenциji koja sada ima direktni pristup tržištu. Kosova je poređila ovaj efekat u statičnom i dinamičkom okruženju, gdje dinamički okvir omogućuje poništavanje negativnog efekta uslijed efekata preljevanja (tehnološkog i u oblasti ljudskog kapitala, 2010).

Isto pitanje prilično eleganto može biti predstavljeno u Hekser-Olinovom okviru, odnosno, da budemo precizniji, Hekser-Olin-Stopler-

Samelsonov model (Hecksher-Ohlin-Stopler-Samuelson) je primjenljiv s nedvojbeno većom preciznošću u odnosu na pristup predstavljen u ovom izlaganju. Međutim, ovdje dajemo okvir sagledavanja odnosa šest promjenljivih, a H-O-S-S modeli su efikasni kada možemo jasno izdvojiti faktore od interesa. Recimo, imamo niz radova koji polaze u ovom pravcu i pokazuju kako povećanje tražnje može da ima uticaj na povećanu potrebu za kvalifikovanom radnom snagom u odnosu na nekvalifikovanu: Said i Eshennaway (2010), Goldberg i Pavcnik (2007), Robbinson i Gidling (1999) i Hanson i Harrison (1999).

2. METODOLOGIJA

Sims je uveo VAR uslijed nemogućnosti modela nastalih u okviru Kejnzijske škole da pruži adekvatne odgovore na inflatorna kretanja sedamdesetih godina prošlog vijeka. U osnovi ovaj pristup počiva na konceptu naizgled nepovezanih regresija, što u suštini znači da postavlja problem da je svaka kontrolisana promjenljiva u okviru posmatranog sistema jednačina istovremeno zavisna i nezavisna. U osnovi, ovaj pristup predstavlja pojednostavljenje modela opštег ekvilibrijuma.

Predstavimo jednostavan VAR model za slučaj kada imamo samo dvije promjenljive i dvije vremenske docnje (laga):

$$\begin{aligned}y_t &= a_{10} + a_{11}y_{t-1} + a_{12}z_{t-1} + e_{yt} \\z_t &= a_{20} + a_{21}y_{t-1} + a_{22}z_{t-1} + e_{zt}\end{aligned}$$

U relaciji (1) imamo dio koji se odnosi na dio pomicnih prosjeka, koeficijenti a_{10} i a_{20} , i koeficijente koji se odnose na autoregresion dio a_{11}, a_{12}, a_{21} i a_{22} . Dva šoka se odnose na greške

$$\begin{bmatrix} e_{1t} \\ e_{2t} \end{bmatrix} = \begin{bmatrix} 1 & b_{12} \\ b_{21} & 1 \end{bmatrix}^{-1} \begin{bmatrix} \varepsilon_{yt} \\ \varepsilon_{zt} \end{bmatrix}.$$

U ovom istraživanju kontrolišemo šest promjenljivih i tri vremenske docnje, te sistem postaje veći. Dobijamo niz jednačina gdje svaka promjenljiva bude zavisna u jednoj od njih, ali je u ostalim nezavisna. Dobijamo okvir u kojem možemo sagledati promjenljive u cijelokupnoj složenosti njihovih međusobnih odnosa. Nаравно, ovdje izostaje preciznost klasičnog regresionog pristupa. Sa druge strane, pristup koji podrazumijeva upotrebu ocjenjivača s metodom minimiziranja kvadrata odstupanja, podrazumijeva niz pretpostavki koje u praksi rijetko stoje. Ovdje smo već spomenuli međusobnu kauzalnost i endogenost, ali tu je i normalni raspored reziduala i druga svojstva vezana za karakteristike obuhvaćenih vremenskih serija. Spomenuli smo ranije koje su promjenljive uključene u analizu:



<i>log_FDI</i>	
<i>IP</i>	
<i>WAGES</i>	
<i>EMPL</i>	(2)
<i>CPI</i>	
<i>REER</i>	

Kada relaciju (2) predstavimo kao sistem jednačina analogan sistemu (1) dobijamo relaciju (3) gdje možemo sagledati složenost sistema. Naravno da pošto se u osnovi radi o sistemu niza regresionih jednačina imamo koeficijent determinacija, ali njegovo tumačenje nema smisla. Naime, poznato je da prosto dodavanje promjenljivih dovodi do povećanja istog, a tu je i međusobna kauzalnost. Sa druge strane, osvrnuli bismo se ukratko na problematičnost a priori pretpostavke o preciznosti klasičnog regresionog pristupa kada su u pi-

tanju makroekonomske vremenske serije, a pogotovo one koje se odnose na BiH. Koliko je moguće tvrditi da je broj zaposlenih u zvaničnim evidencijama stvarno tačan? Metodologija za utvrđivanje bruto društvenog proizvoda se mijenjala, a da se nije nastavila paralelna upotreba po staroj metodologiji. Koliko je duga vremenska serija zvanične statistike kamatnih stopa? Problematika statistike cijena, kada se uđe u dublju analitiku po pojedinim komponentama, je tek složena. Naravno, neke od ovih stvari, pogotovo onih koji se tiču statistike cijena, nisu strane ni uređenijim sistemima (u praksi su uvijek "čudna" velika odstupanja revizija procjena od onih inicijalnih), ali mora se imati na umu niz ovih činjenica kada se pokušava dati rezultat koji bi bio paralela "normalnim" makroekonometrijskim prognozama. Zato u ovom izlaganju koristimo VAR. Sagledavamo potencijalne odnose u smislu pravca reakcija pojedinih promjenljivih.

$$\begin{aligned}
 \log_FDI_t = & a_{10} + a_{11} \log_FDI_{t-1} + a_{12} \log_FDI_{t-2} + a_{13} \log_FDI_{t-3} + e_{FDIt} \\
 & + a_{14} WAGES + a_{15} WAGES_{t-1} + a_{16} WAGES_{t-2} + a_{17} WAGES_{t-3} + e_{WAGESt} \\
 & + a_{18} IP + a_{19} IP_{t-1} + a_{110} IP_{t-2} + a_{111} IP_{t-3} + e_{IPt} \\
 & + a_{112} EMPL + a_{113} EMPL_{t-1} + a_{114} EMPL_{t-2} + a_{115} EMPL_{t-3} + e_{EMPLt} \\
 & + a_{116} CPI + a_{117} CPI_{t-1} + a_{118} CPI_{t-2} + a_{119} CPI_{t-3} + e_{CPIt} \\
 & + a_{120} REER + a_{121} REER_{t-1} + a_{122} REER_{t-2} + a_{123} REER_{t-3} + e_{REERT} \\
 IP = & a_{20} + a_{21} IP_{t-1} + a_{22} IP_{t-2} + a_{23} IP_{t-3} + e_{IPt} \\
 & + a_{24} \log_FDI + a_{25} \log_FDI_{t-1} + a_{26} \log_FDI_{t-2} + a_{27} \log_FDI_{t-3} + e_{FDIt} \\
 & + a_{28} WAGES + a_{29} WAGES_{t-1} + a_{210} WAGES_{t-2} + a_{211} WAGES_{t-3} + e_{WAGESt} \\
 & + a_{212} EMPL + a_{213} EMPL_{t-1} + a_{214} EMPL_{t-2} + a_{215} EMPL_{t-3} + e_{EMPLt} \\
 & + a_{216} CPI + a_{217} CPI_{t-1} + a_{218} CPI_{t-2} + a_{219} CPI_{t-3} + e_{CPIt} \\
 & + a_{220} REER + a_{221} REER_{t-1} + a_{222} REER_{t-2} + a_{223} REER_{t-3} + e_{REERT} \\
 WAGES = & a_{30} + a_{31} WAGES_{t-1} + a_{32} WAGES_{t-2} + a_{33} WAGES_{t-3} + e_{WAGESt} \\
 & + a_{34} \log_FDI + a_{35} \log_FDI_{t-1} + a_{36} \log_FDI_{t-2} + a_{37} \log_FDI_{t-3} + e_{FDIt} \\
 & + a_{38} IP + a_{39} IP_{t-1} + a_{310} IP_{t-2} + a_{111} IP_{t-3} + e_{IPt} \\
 & + a_{312} EMPL + a_{313} EMPL_{t-1} + a_{314} EMPL_{t-2} + a_{315} EMPL_{t-3} + e_{EMPLt} \\
 & + a_{316} CPI + a_{317} CPI_{t-1} + a_{318} CPI_{t-2} + a_{319} CPI_{t-3} + e_{CPIt} \\
 & + a_{320} REER + a_{321} REER_{t-1} + a_{322} REER_{t-2} + a_{323} REER_{t-3} + e_{REERT} \\
 EMPL = & a_{40} + a_{41} EMPL_{t-1} + a_{42} EMPL_{t-2} + a_{43} EMPL_{t-3} + e_{EMPLt} \\
 & + a_{44} \log_FDI + a_{45} \log_FDI_{t-1} + a_{46} \log_FDI_{t-2} + a_{47} \log_FDI_{t-3} + e_{FDIt} \\
 & + a_{48} WAGES + a_{49} WAGES_{t-1} + a_{410} WAGES_{t-2} + a_{411} WAGES_{t-3} + e_{WAGESt} \\
 & + a_{412} IP + a_{413} IP_{t-1} + a_{414} IP_{t-2} + a_{415} IP_{t-3} + e_{IPt} \\
 & + a_{416} CPI + a_{417} CPI_{t-1} + a_{418} CPI_{t-2} + a_{419} CPI_{t-3} + e_{CPIt} \\
 & + a_{420} REER + a_{421} REER_{t-1} + a_{422} REER_{t-2} + a_{423} REER_{t-3} + e_{REERT} \\
 CPI = & a_{50} + a_{51} CPI_{t-1} + a_{52} CPI_{t-2} + a_{53} CPI_{t-3} + e_{CPIt} \\
 & + a_{54} \log_FDI + a_{55} \log_FDI_{t-1} + a_{56} \log_FDI_{t-2} + a_{57} \log_FDI_{t-3} + e_{FDIt} \\
 & + a_{58} WAGES + a_{59} WAGES_{t-1} + a_{510} WAGES_{t-2} + a_{511} WAGES_{t-3} + e_{WAGESt} \\
 & + a_{512} IP + a_{513} IP_{t-1} + a_{514} IP_{t-2} + a_{515} IP_{t-3} + e_{IPt} \\
 & + a_{516} EMPL + a_{517} EMPL_{t-1} + a_{518} EMPL_{t-2} + a_{519} EMPL_{t-3} + e_{EMPLt} \\
 & + a_{520} REER + a_{521} REER_{t-1} + a_{522} REER_{t-2} + a_{523} REER_{t-3} + e_{REERT} \\
 REER = & a_{60} + a_{61} REER_{t-1} + a_{62} REER_{t-2} + a_{63} REER_{t-3} + e_{CPIt} \\
 & + a_{64} \log_FDI + a_{65} \log_FDI_{t-1} + a_{66} \log_FDI_{t-2} + a_{67} \log_FDI_{t-3} + e_{FDIt} \\
 & + a_{68} WAGES + a_{69} WAGES_{t-1} + a_{610} WAGES_{t-2} + a_{611} WAGES_{t-3} + e_{WAGESt} \\
 & + a_{612} IP + a_{613} IP_{t-1} + a_{614} IP_{t-2} + a_{615} IP_{t-3} + e_{IPt} \\
 & + a_{516} EMPL + a_{517} EMPL_{t-1} + a_{518} EMPL_{t-2} + a_{519} EMPL_{t-3} + e_{EMPLt} \\
 & + a_{620} CPI + a_{621} CPI_{t-1} + a_{622} CPI_{t-2} + a_{523} CPI_{t-3} + e_{CPIt}
 \end{aligned} \tag{3}$$



U ovom istraživanju pretpostavka je da $a_{18}, \dots, a_{111} > 0$. Pored toga, potrebno je obratiti pažnju na poredak promjenljivih jer se primjenjuje istovremeno dekompozicija Čoleskog (Cholesky). Sistem mora da pretrpi niz restrikcija da bi bio rješiv. Kada su u analizu uključene restrikcije, tada imamo strukturalni VAR. Restrikcije su obično uslovljene na određenoj teoretskoj podlozi. U navedenom sistemu jednačina imamo 6x24 koeficijenata.

Obostrana kauzalnost između promjenljivih se podrazumijeva - endogenost nije prepreka kao u klasičnom regresionom okviru. Relacije koje se odnose na greške, a one su povezane sa šokovima koje izaziva određena promjenljiva. Sagledavanje šokova u VAR modelu najjednostavnije preko impulsno-responsivnih funkcija. Naravno, postoji mogućnost analize matrice varijansi i kovarijansi, ali ovakav pristup u praksi ne omogućava posebnu praktičnu interpretabilnost rezultata.

U ovom radu ne koristimo klasični pristup modelu vektorske autoregresije. Strukturalne škove identifikujemo uz pomoć Uligovog (Uhlig, 2005) metoda penalizirajuće funkcije (penalty function method). Uzimamo šok od jedne standardne devijacije. Sve navedeno je relativno standardna procedura, te podrazumijeva polaznu tačku u restrikcijama na moguće reakcije određenih agregata na određeni šok, gdje se ograničava moguća reakcija na pozitivnu, odnosno negativnu. U osnovi ovo predstavlja kompromis između metoda odbijanja koji je predstavio Ulig i onoga kojeg je predstavila grupa autora okupljena oko Rubio-Ramireza (Rubio-Ramirez, Wagoner, & Zha, 2010).

Ovaj pristup je dio šireg makroekonometrijskog nazora koji se oslanja na znakovne restrikcije. Samo definisanje znakovnih restrikcija može biti sprovedeno na više načina, a ovaj koji je ovdje primijenjen u osnovi počiva na Bajesovom statističkom zaključivanju. Baumaster i Hamilton su pokazali da tradicionalni pristup uvođenja

ograničenja u reakciji određenih ekonomskih agregata u modelima vektorske autoregresije suštinski nije drugačija od uzimanja uzoraka na osnovu prethodno definisanog teorijskog rasporeda vjerovatnoće. Kada pretpostavimo reakciju u određenom pravcu, u suštini usvajamo apriorna polazna uvjerenja, što je obilježje statističkog zaključivanja koje počiva na Bajesovom teoremu, te predstavlja alternativu klasičnom statističkom zaključivanju (Baumeister & Hamilton, 2015). Na kraju, ovaj pristup omogućava određenu fleksibilnost po pitanju osjetljivih vremenskih serija vezanih za Bosnu i Hercegovinu.

Ovdje polazimo od Uligovog metoda $(n-1) \times 1$ i koristimo uzoraka iz normalne distribucije koja je projektovana u R^n dimenzionalni prostor koristeći stereografsku projekciju. Ovaj pristup pronalazi impulsni vektor (vektor u kojem se nalaze poticaji za reakcije od interesa) koji je najbliži mogući situaciji u kojoj su prethodno definisane restrikcije zadovoljene putem minimiziranja funkcije koja penalizira kršenja znakovnih restrikcija. Postupak se nastavlja tako da simulacije definiše model koji je optimalan sa stanovišta definisanih restrikcija. Dakle, ovaj pristup polazi od skupa definisanih modela koji se postepeno sužava. Naravno, ovdje se otvara cijeli niz pitanja vezanih za razlike, odnosno sličnosti između klasičnog i Bajesovog statističkog zaključivanja. U tom smislu više detalja pruža rad Munai i Šorfhajda (Moon & Schorfheide, 2012).

Funkcija koja penalizira ograničava sve nizove impulsa i reakcija simetrično. Da bi se znakovni restrikcije tretirali jednak, tada imamo $l_j = -1$ ukoliko je znak restrikcije pozitivan, te $l_j = 1$ ako je restrikcija negativna. Skaliranje promjenljivih se sprovodi tako da se uzimaju greške priraštaja promjenljivih, u oznaci σ_j . Ako je $r_{j,\alpha}(k)$ -ti odgovor u k -tom koraku na impulsni vektor α , tada problem minimiziranja može biti zapisan kako slijedi (Danne, 2015):

$$\min_{\alpha} \Psi(\alpha) = \sum_{j \in J} \sum_{k \in K} b \times f \left(l_j \frac{r_{j,\alpha}(k)}{\sigma_j} \right)$$

gdje je b faktor penalizacije $f(\square)$ takav da važi

$$b = \begin{cases} 1 & \text{za } f \left(l_j \frac{r_{j,\alpha}(k)}{\sigma_j} \leq 0 \right) \\ \text{penalty} & \text{za } f \left(l_j \frac{r_{j,\alpha}(k)}{\sigma_j} > 0 \right) \end{cases}$$

Navedeni faktor je nenegativan skalar. Nakon ovoga treba definisati impulsni vektor koji minimizira "penale" koji su dodijeljeni promjenljivima (koje su pod restrikcijom) za definisani vremenski period. Fudžita je, recimo, primijenio ovaj pristup tako da je identifikovao šokove s minimalnim restrikcijama u oblasti ekonomije rada (Fujita, 2012), što je zahtjevниji poduhvat od ovog našeg, koji je klasičan makroekonomski problem.

3. PODACI KORIŠTENI U ANALIZI

Podaci koji su korišteni u najvećem obimu su raspoloživi na statističkom portalu Centralne banke Bosne i Hercegovine, odnosno objavila ih je Agencija za statistiku Bosne i Hercegovine. Određeni dijelovi koji nedostaju dopunjeni su "prognoziranjem unazad" (back-forecasting), ako se radi o cijelim dijelovima vremenske serije, odnosno koristili smo metod

"randomforest" za popunjavanje pojedinačnih vrijednosti koje nedostaju. Morali smo vršiti i prilagođavanje frekvencija pomoću metoda Denton-Šolet (Denton-Cholette).

Na kraju smo dobili vremenske serije na mjesecnom nivou za period od početka 2008. do kraja juna 2017. godine.

Variable	FDI mill.(Q)	Remittance mill.(M)	Wages (M)	IP (M)	Employment (M)	CPI (M)	REER (M)
Mean	398	63.6	813.8	103.3	704437	102.55	97.14
Median	364.2	62.73	823.5	102.76	699618.69	103.57	97.99
St. Dev.	263.2	13.75	29.4	5.54	22034.32	2.88	2.53
Min	41.7	35.16	677	93.38	650507.62	95.65	92.55
Max	13375	121.78	860	116.25	775378.91	106.45	100.07

Tabela 1. Deskriptivna statistika kontrolisanih promjenljivih

Ne koristimo BDP kao mjeru autputa ekonomije budući da bismo tada morali vršiti još jednu transformaciju vezanu za frekven-

ciju. Odlučili smo se za indeks industrijske proizvodnje (IP). U prilog ovakvoj odluci ide i činjenica da se metodologija za definisanje

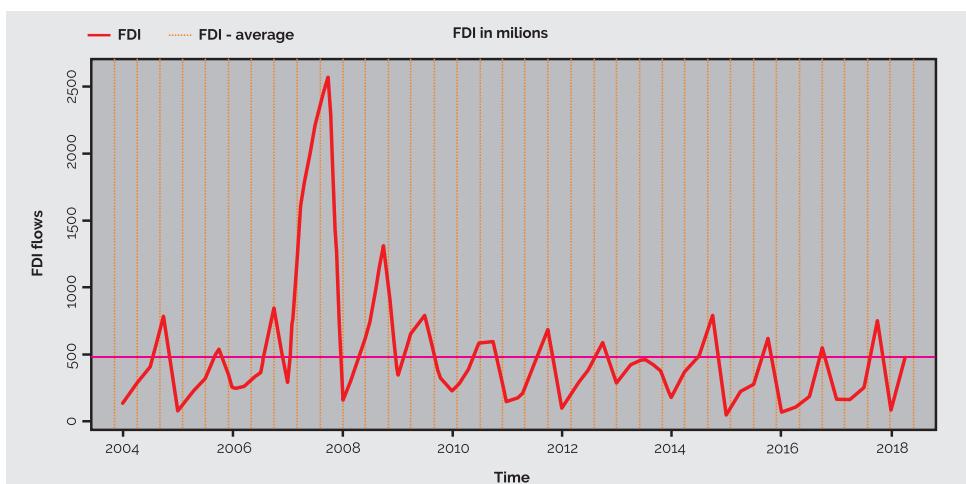


BDP mijenjala, bez nastavljanja primjenjivanja po staroj metodologiji. Da imamo definisanu vremensku seriju po staroj metodologiji, mogli bismo uraditi prognoziranje gdje bi vremenska serija po napuštenoj metodologiji mogla biti uključena u regresionu jednačinu. Tako bismo imali dragocjene informacije koje bi omogućile da precizno definišemo vremensku seriju BDP na cijelokupan vremenski period.

Međutim, ovako bismo morali obaviti još jednu transformaciju koja mora donijeti dodatnu dozu nepreciznosti budući da nemamo aktuelnu seriju po staroj metodologiji kao regresor. S obzirom na stanje podataka vezanih

za Bosnu i Hercegovinu, te sve transformacije koje smo morali uraditi da bismo dobili upotrebljive vremenske serije, dodatan potez koji povećava nepreciznost podataka morao bi se izbjegći ako je to moguće.

Koristimo vremenske serije vezane za zaposlenost, vrijednost valute, cijenu rada, nivo cijena, a pored autputa, tu su naravno direktne strane investicije. Koristimo priraštaje originalnih podataka o tokovima investicija, ne o stanju investicija, što nas ne dovodi u situaciju rastućeg trenda. Na ovaj način dobijamo dodatnu dozu u stacionarnost posmatrane serije. Pogledajmo podatke na slici 1. koji se odnose na strane investicije, a definisani su kvartalno.



Slika 2. Tokovi stranih direktnih investicija u BiH

Izvor: Prikaz autora, Agencija za statistiku (za brojčane podatke)

Kao što možemo vidjeti, imamo tokove stranih direktnih investicija, a ne (kumulativna) stanja, budući da nemamo uzlazni trend. Možemo biti relativno zadovoljni stacionarnošću originalnih podataka, izuzev perioda koji prethodi globalnoj finansijskoj krizi, u kojem nemamo snažan

pad koliko smo imali snažan rast investicija u periodu netom prije krize. Kao što vidimo, ovdje moramo uraditi sezonsko prilagođavanje, što je urađeno u procesu analize za sve posmatrane vremenske serije.

4. REZULTATI

Postavljamo model vektorske autoregresije kao metodološki okvir da sagledamo reakciju zaposlenosti, plata, cijena, industri-

jske proizvodnje i plata na šok od jedne standardne devijacije koji su izazvale direktnе strane investicije.

Promjenljiva	Znak reakcije	K (broj mjeseci na koji se restrikcija odnosi)
Priraštaji direktnih stranih investicija	+	min=1, max=3

Tabela 2. Restrikcije - znak reakcije indeksa industrijske proizvodnje i vremenski period na koji se restrikcija odnosi

Izvor: Prikaz autora

Definisali smo okvir gdje su direktne strane investicije na prvom mjestu po direktnosti. Stavljanje investicija na prvo mjesto u modelu vektorske autoregresije ima svoje uporište u makroekonomskoj literaturi. Investicije, kakve god da su, moraju imati, ako ništa drugo, direktni i promptno pozitivan uticaj na rast autputa. Svježi kapital inicijalno mora dovesti barem do povećanja potrošnje, što se mora očitovati pozitivno barem u simboličnoj mjeri na nivo autputa u nacionalnoj ekonomiji.

Izabrali smo tri vremenska perioda za pretpostavljenu docnju, odnosno prepostavljamo da je vremenski period od jednog kvartala dovoljan da se "uhvati dinamička suština", a sa druge strane model nije prevelik. Pošli smo od jednostavnog modela vektorske autoregresije koji ima strukturu kako je predložio Čoleski (Cholesky), te smo primijenili niz informacionih kriterijuma - Akaikev (AIC), Bayesov (BIC), te Hana-Kvinov (HQC).

Zaobišli smo konvencionalni pristup koji podrazumijeva striktni Boks-Dženkinsov (Box-Jenkins) okvir budući da smo se opredijelili za

Bajesovo statističko zaključivanje, odnosno Uligovu penalizirajuću funkciju, te smo mogli zauzeti nešto robusniji stav prema generalnoj formi podataka koji se koriste u analizi. Naravno, nemamo namjeru da predstavimo model koji bi trebalo da služi za prognoziranje, te samim tim kalibracija modela u tom smislu nije predmet ove analize.

Napomenimo da nismo uključili vremenski trend u model. Kao što smo ranije napomenuli, ne želimo preglomazan model. Model vektorske autoregresije koristi endogenost kao poželjno svojstvo, za razliku od klasičnog regresionog modela koji ovo svojstvo predstavlja kao negativnu osobinu. Svaka promjenljiva može uticati na onu drugu i obratno, a tu je i dinamički okvir od tri mjeseca. Takve premise, sa šest kontrolisanih promjenljivih, moraju se "upakovati" u sistem jednačina koji se može riješiti. Naravno, znakovne restrikcije nam omogućavaju da imamo sistem koji je rješiv.

Prilikom replikacije uzorka koristili smo Monte Karlo (Monte Carlo) simulaciju koja polazi od Markovljevih lanaca (Markow). Broj





replikacija koji je korišten je 2.000. Isti broj je određen za iteracije prilikom procesa minimizacije penalizirajuće funkcije.

Kontrolišemo sljedeće promjenljive:

1. Priraštaji direktnih stranih investicija – log_FDI
2. Broj zaposlenih – EMPL
3. Indeks industrijske proizvodnje – IP
4. Indeks potrošačkih cijena – CPI
5. Plate – WAGES
6. Indeks realnog efektivnog kursa prema dolaru - REER

Broj zaposlenih raste uslijed reakcije na šok izazvan direktnim stranim investicijama, a isto tako rastu i prosječne plate (Slika 2). Rast zaposlenih je zabilježen iz više razloga. Izražene su migracije, a u posmatranom periodu isto tako se vrše znatna zapošljavanja u državnom sektoru, ali i realizacije niza programa odlaska u penziju osoba koje su bile registrovane kao nezaposlene.

Ipak, pozitivan udar na zaposlenost je potvrđen u ovakovom makroekonomskom okviru. Naravno, sagledavanje svih faktora traži kompleksnije skupove podataka. Recimo, efekat jedne od najvećih direktnih stranih investicija u termoelektrane trebalo bi da uzme u obzir nivo zagodenja koje izazivaju takve investicije. Postavlja se logično pitanje koji je vremenski period za povrat navedenih investicija, ako znamo za planove na globalnom nivou da se do 2050. godine zatvore sve elektrane koje koriste ugalj.

Međutim, BiH je prinuđena na takve investicije, uslijed već spomenutih ogromnih stopa nezaposlenosti, ali i niza drugih razloga. Postavlja se i pitanje razloga "zabrinutosti", prije svega evropskih zemalja, za ovakve investicione poduhvate. Da li su prigovori motivisani čisto ekološkim motivima? Zapadni Balkan nije jedina geopolitička arena gdje se investiciona aktivnost narastajućeg diva posmatra sa dozom

zabrinutosti od strane "savjeta mudraca" starog i novog svijeta. Afrika je arena s nešto ozbiljnijim propozicijama. Isto se postavlja pitanje u vezi s investicionim valom u elektrane na ugalj koji se finansira kineskim kapitalom. Odgovor afričkih zemalja je jasan - licemjerstvo zemalja koje su svoj razvoj grijale na uglju ima uporište u zabrinutosti zbog aktivnosti institucija iz Kine u takvim investicionim poduhvatima. Dakle, navedena zabrinutost možda ima geopolitičke motive, a ne čisto ekološke. Iako u našem slučaju, zbog blizine, ekološka kritika koja dolazi od strane zemalja EU donekle i ima svoje opravdanje, ali onda i blizina treba da bude odlučujući faktor u lociranju velikih investicionih odluka koje se iniciraju iz tih zemalja. Jednostavno rečeno, imajući na umu snažan uticaj međunarodne zajednice u BiH, politika "mrkve i štapa" podrazumijeva da se nekad upotrebljava i mrkva.

Može se postaviti pitanje koliko su direktnе strane investicije uticale na produktivnost rada, iako je pozitivan uticaj na količinu angažovane radne snage očigledan. U tom smislu možemo ustanoviti da postoji rast prosječnih plata, te je moguća interpretacija da je produktivnost rada reagovala u pozitivnom smislu. Međutim, ovdje je potrebna dublja analiza stvarnih uzroka rasta prosječnih plata. Naime, ovaj agregat je u posmatranom periodu u najvećem dijelu bio određen odlukama donesenim u javnom sektoru. U periodu od posljednje dvije godine (2017-2019), koji nije obuhvaćen analizom, ali i u budućem periodu može se očekivati rast plata indukovani odlukama u privatnom sektoru. Neosporno je da, iako direktnе strane investicije ne izazovu radikalni uticaj na produktivnost rada, imaju potrošnju kao kanal uticaja na prosječne plate.

Međutim, kada je riječ o indeksu industrijske proizvodnje, vidimo da je izražen kratkoročni pozitivan uticaj. Dugoročan rast, očigledno, traži krupne, strukturalne poteze. Tu jedino možemo spomenuti ranije zaključke u

vezi s investicijama koje obuhvataju prirodne resurse i koje prevladavaju u BiH, ali i niz strukturalnih problema. Ako pogledamo strukturu investicija, onda je jasno da su rijetki slučajevi u kojima možemo govoriti o tehnološkim transferima sličnim onima u Kini. Slučaj da multinacionalna kompanija ustanovi odjeljenje za istraživanje i razvoj u BiH može biti samo sporadičan.

Vidimo da investicije ne ostvaruju nikakav inflatorni pritisak. Ovdje dolazimo do nemogućnosti vođenja monetarne politike od strane Centralne banke BiH i činjenice da inflacija ima ekstremno malu volatilnost. Samim tim, uhvatiti statistički značajnu reakciju indeksa potrošačkih cijena jeste uzaludan posao.

U globalnim okvirima raste zabrinutost u vezi s "japanizacijom" globalne ekonomije zapadnog svijeta. Navedeni termin obilježava stanje u kojem uslijed straha od recesije donosioci odluka duži vremenski period nisu u mogućnosti da učine ključne poteze koji bi omogućili dizanje "radne temperature" određene ekonomije. Istovremeno, kamatne stope su niske, a deflacija kuca na vrata. Dodatno, imate stanovništvo koje stari.

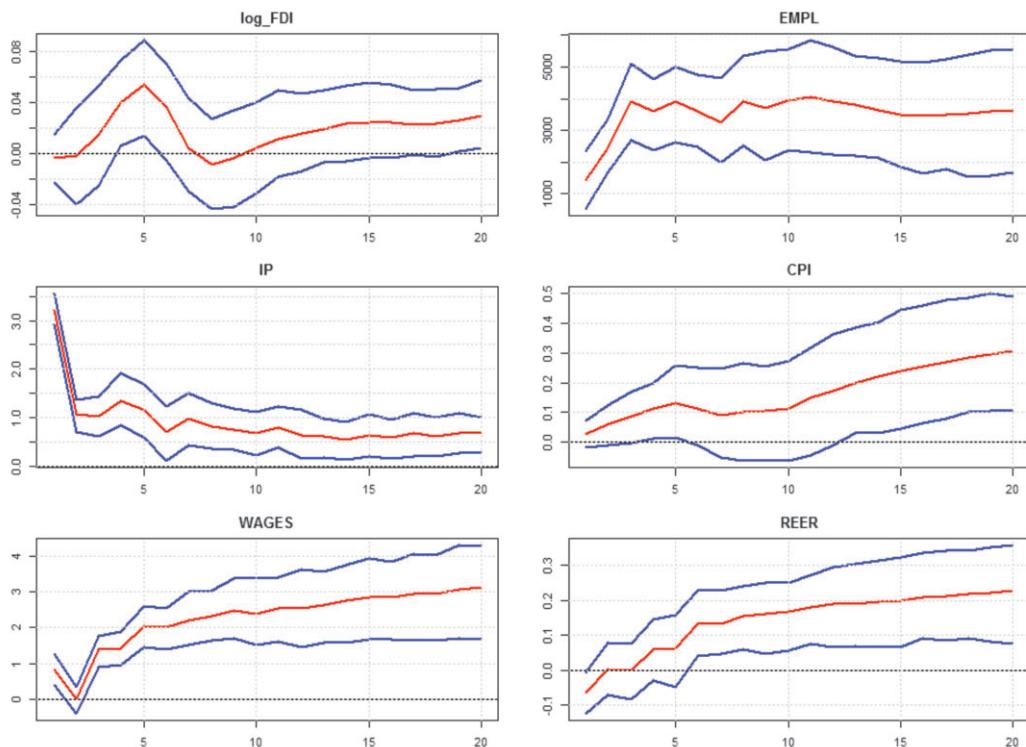
Opisano stanje moglo bi nastupiti i u BiH. Nedostaju negativne stope rasta, i tu je razlika što kamatne stope ne konvergiraju nuli. Čemu strah od niskih kamatnih stopa kada se ulazi u recesiju? Razlog je jednostavan. Kamatne stope su jedan od ključnih elemenata monetarne politike. Kada stvari idu loše, šta monetarne vlasti mogu uraditi? Sniziti kamatne stope. Ali, ako su one već negativne ili jednake nuli, kako ih smanjiti?

Izgledalo bi da BiH ima još karata zaigranje da nije jedne stvari - rigoroznog valutnog odbora. BiH svejedno nema mogućnosti vođenja samostalne monetarne politike, te razloga za zabrinutost da ulazimo u rece-

siju, a da su nam kamatne stope ionako niske, nema. Ako se slutnje o recesiji u najvećoj ekonomiji EU ostvare, BiH ne može uraditi ništa.

Realni efektivni kurs prema dolaru koristimo iz metodoloških razloga, da bismo zaokružili makroekonomski okvir. Iako je, uslijed činjenice da imamo "currency board", pitanje ovakvog poteza diskutabilno, te devalvaciju nacionalne valute i pozitivnu reakciju nacionalne valute, ne treba komentarisati dalje od onoga što smo ranije rekli. Naime, spomenuli smo da potcijenjena nacionalna valuta djeluje pozitivno na direktne strane investicije. Iako ova konstatacija ima i drugačije poglede, nećemo dalje elaborirati analizu u ovom pravcu. Ali, ako samo rekli da model vektorske autoregresije predstavlja pojednostavljen makroekonomski model nacionalne ekonomije, te kontrolišemo ovu promjenljivu da bismo obezbijedili dotok informacija koje se tiču snage nacionalne valute.





Slika 3. Rezultati istraživanja

Izvor: Kalkulacija autora

Slika 2. možda prikazuje očekivane reakcija pet promjenljivih na šok izazvan investicijama, ali pokazuje jednu zabrinjavajuću stvar. Slabu reakciju stranih direktnih investicija na šok od njih samih. Razlozi za ovo mogu biti razni. Jedan može biti tehničke prirode, u smislu da se javlja greška prilikom mjerjenja, odnosno da u samom procesu sakupljanja podataka imamo određene nedosljednosti ili jednostavno serije ne reprezentuju adekvatno posmatranu kategoriju. Recimo, zaposlenost ne obuhvata značajan dio zaposlenih u sivoj ekonomiji, te

negativni aspekti investicija neće biti ni uhvaćeni - ljudi koji su radili i prestali raditi nisu uopšte obuhvaćeni.

Drugi, izgledniji razlog je taj da direktnе strane investicije ostvaruju očekivane reakcije pet kontrolisanih promjenljivih, ali da je njihov ukupni uticaj prilično malen. Zaista, kada se pogleda reakcija autputa na ulaganja, vidi se pozitivna reakcija neka četiri mjeseca, od čega prva tri imamo uslijed usvojenih restrikcija, da bi kasnije uslijedio lagani pad s ulaskom u stanje odsustva bilo kakve reakcije.

ZAKLJUČAK

Direktne strane investicije su neminovnost za BiH. Struktura, učestalost, cijena, uslovno govoreći, investicija nije mogla u prošlosti biti predmet naročitog izbora uslijed ogromnog pritiska koji je nezaposlenost pravila u ekonomskom, političkom i sociološkom smislu. Makroekonomski okvir koji je ovdje predstavljen opisuje efekat stranih direktnih investicija koji je relativno očekivan za jednu ekonomiju kao što je BiH.

Reakcija zaposlenosti i plata je u očekivanim okvirima, neautonomna monetarna politika diktira reakciju monetarnih agregata i inflacije, a i reakcija autputa je očekivana s obzirom na to da je većina krupnih investicija povezana s prirodnim resursima.

Investicije koje nisu povezane s prirodnim resursima imaju značajan efekat preljevanja na cjelokupan tržišni okvir, ali i na ljudski kapital. To u suštini dovodi do rasta produktivnosti rada, a kasnije i rasta cijene rada kao svojevrsnog indikatora produktivnosti rada.

Jednostavno statističko smanjivanje broja nezaposlenih za zemlju koja je tako blizu evropskog tržišta rada u sadašnjim uslovima jednostavno nije dovoljno. Sa druge strane, spomenuli smo svojevrsno licemjerstvo donosioca odluka u perjanicama EU. Blizina BiH mogla bi biti pozitivan argument za neresурсне investicije, a ne da bude pozitivan argument za alociranje ljudskog kapitala. Ljudski potencijal ove zemlje mogao bi se bolje razvijati na mjestu gdje je nikao, a ne da se presadi u zemlje EU.

Postavlja se pitanje bezuslovnog osuđivanja direktnih stranih investicija na uspjeh. Kada kažemo uslovljavanja, ne mislimo na ona koja imaju svoje uporište u geopolitičkim razlozima. Kada govorimo o uslovljanju i investicijama, Kina je interesantan primjer sa stanovišta

odredišta investicija, ali i sa stanovišta investitora.

Kritike investicija koje dolaze iz Kine imaju svoje uporište prije svega u razlozima geopolitičke prirode, te kao takve moraju biti propaćene konkretnim potezima, ali onima koje imaju pozitivne, konstruktivne motive. Region zapadnog Balkana je dovoljno bio žarište onih destruktivnih.

Quid pro quo je pristup koji je imao najizraženiju primjenu u Kini. Ovaj princip je u nekim periodima skorije ekonomske istorije bio izraženiji nego što je danas, ali princip je bio jednostavan. Omogućava se pristup kineskom tržištu, ali kompanije moraju tehnološko znanje ostaviti entitetu koji je u rezidentnom vlasništvu. U slučaju Kine više stvari je išlo njoj u korist u odnosu na prosječnu zemlju zapadnog Balkana. Prije svega veličina tržišta. Nerezidentni investitor je spreman žrtvovati intelektualno vlasništvo na trenutni tehnološki nivo za udio na tržištu te veličine. Investitor se djelimično i kocka u korist brzog tehnološkog napretka, nadajući se da aktuelni tehnološki nivo gubi na važnosti vremenom većom progresijom nego što je ukupna korist od penetracije na tržište te veličine. Međutim, uspjeh kineske privrede u smislu samostalnog nastavka od tako utvrđenih početnih pozicija je očigledan.

U BiH postoji tipičan hodogram reakcije na investicije nerezidenta, kao što smo mogli vidjeti u rezultatima ovog istraživanja. Međutim, uloga BiH u toj igri je krajnje pasivna. Ako opet uzmemu primjer Kine kao drugu krajnost, njena veličina je prvi razlog koji joj omogućava igranje proaktivne uloge. Drugi razlog jeste mogućnost ekstremnog protekcionizma. Kina je neobična tvorevina tržišne ekonomije i komunističkog uređenja. Ova druga karakteris-





tika daje polugu za protekcionizam, koji jedna zemlja na vratima EU može samo da sanja.

Dakle, BiH mora da pronađe svoj put u svjetskim tokovima kapitala. BiH jeste izvor jeftinog resursa - za zemlje EU prije svega. Kada kažemo "jeftine resurse", tada mislimo na rad, ali i na ljudski kapital. Ljudski kapital stavljamo na prvo mjesto, a onda dolaze rudna bogatstva, šuma, hidropotencijala i sl.

Da li postoji mogućnost da se trenutno najveći odvodni ventil resursa (ljudski kapital) okrene u našu korist?

Prema nekim podacima, doznake predstavljaju skoro 10% BDP BiH. Neobično su važan dio kapitalnih tokova koji održava ravnotežu.

Mogu li se ovi tokovi drugaćije usmjeriti?

Na kraju, jednostavan primjer. Jedna od najprofitabilnijih željezara na svijetu, za EU sigurno, smještena je u Lincu (Linz). Radna snaga nije jeftina, ruda ima nizak udio željeza, a ugalj je daleko. Ne postavljamo ovo pitanje u klišeiziranom smislu: "Zašto kod nas ne bi moglo?" Ovo pitanje postavljamo u smislu da krivca, ali i faktora uspjeha, moramo početi tražiti u nama samima. U tom smislu treba posmatrati i direktne strane investicije. Kapitalni tokovi su, kao što sam naziv kaže, tokovi. Opstanjanje, manevrisanje na istim razdvaja uspješne od neuspješnih. Nikako nije riječ o deus ex machina ekonomskom čudu, niti takvo postoji.

LITERATURA

- Amuendo-Dorantes, C., & Pozo, S. (2006). Migration, Remittances, and Male and Female Employment. *The American Economic Review*, 96(2), 222-226.
- Arellano , M., & Bond, S. (1991). Some Tests of Specification for Panel Data: Monte Carlo Evidence and an Application to Employment Equations. *The Review of Economic Studies*, 58(2), 277-297.
- Bai, J. (2009). Panel data models with interactive fixed effects. *Econometrica*, 77, 1229–1279.
- Bailey, N., Kapetanios, G., & Pesaran, M. H. (2012). Exponents of cross-sectional dependence: Estimation and inference. CESifoWorking Paper No. 3722.
- Baillie, R. T., & Bollerslev, T. (1994). Cointegration, Fractional Cointegration, and Exchange Rate Dynamics. *Journal of Finance*, 737-745.
- Balasubramanyam, V. N., Salisu, M., & Sapsford, D. (1999). Foreign direct investment as an engine of growth. *The Journal of International Trade & Economic Development*, 8(1), 27-40. <http://dx.doi.org/10.1080/096381999000000003>
- Baltagi, B., Egger, P., & Pfaffermayr. (2007). Estimating the Model of Complex FDI: Are There Third-Country Effects? *Journal of Econometrics*, 140, 260-281.
- Baskot, B. (2016, June). Exogenous Macroeconomic Shocks and Their Propagation in Bosnia and Herzegovina. Economics Section, IHEID Working Papers. Geneve: The Graduate Institute of International Studies.
- Baumeister, C., & Hamilton, J. D. (2015). Sign Restriction Structural Vector Autoregres-

- sions, and Useful Prior Information. *Econometrica*, 83(5), 1963-1999.
- Blomstrom, M., Fors, G., & Lipsey, R. E. (1997). Foreign Direct Investment and Employment: Home Country Experience in the United States and Sweden. *Economic Journal*, 107(445), 1787-1797.
- Blonigeg, B. A., Davies, R. B., Wadell, G. R., & Naughton, H. T. (2007). FDI in space: Spatial Autoregressive Relationship in Foreign Direct Investment. *European Economic Review*, 51, 1303-1325.
- Braun, H., Debock, R., & DiCecio, R. (working paper 2007-015A). Supply shocks, demand, shocks, and labor market fluctuations. Federal Reserve Bank of St. Louis.
- Canova, F., Lopez-Salido, D., & Michelacci, C. (2007). Shumpeterian technology shocks. *Economics Working Papers* 1012. Department of Economics and Business, Universitat Pompeu Fabra, .
- Chudik, A., & Pesaran, M. H. (2014). Aggregation in large dynamic panels. *Journal of Econometrics*, 178(2), 273-285.
- Chudik, A., & Pesaran, M. H. (2013). Econometric analysis of high dimensional VARs featuring a dominant unit. *Econometric Reviews*, 32, 592-649.
- Cox, D., & Stark, O. (1994). Intergenerational Transfers and the Demonstration Effect. *Boston College Working Papers in Economics* 329.
- Danne, C. (2015, December 19.). VAR-signR: Estimating VARs using sign restrictions in R. Preuzeto 10. maja, 2018 sa <https://mpra.ub.uni-muenchen.de/68429/>
- de Mello Jr, L. R. (1999). Foreign direct investment-led growth: Evidence from time series and panel data. *Oxford economic papers*, 1(51), 133-151.
- Fajgelbaum, P., Grossman, G. M., & Helpman, E. (2015). A Linder Hypothesis for Foreign Direct Investment. *Review of Economic Studies*, 82, 83-121.
- Froot, K., & Stein, J. (1991). Exchange Rates and Foreign Direct Investment: An Imperfect Capital Markets Approach. *Quarterly Journal of Economics*, 106, 1191-1217.
- Fujita, S. (2012). Dynamics of Worker Flows and Vacancies: Evidences from the Sign Restriction Approach. *Journal of Applied Econometrics*, 89-121.
- Funkhouser, E. (1992). Migration from Nicaragua: Some Recent Evidence. *World Development*, 20(8), 1209-1218.
- Goldeberg, P., & Pavcnik, N. (2007). Distributional Effects of Globalization in Developing Countries. *Journal of Economic Literature*, 39-82.
- Hanson, G. H., & Harrison, A. (1999). Trade, Technology and Wage Inequality. *Industrial and Labor Relations Review*, 271-288.
- Holmes, T. J., McGrattan, E. R., & Prescott, E. C. (2015). Quid Pro Quo: Technology Capital Transfers for Market Access in China. *Review of Economic Studies*, 82, 1154-1193.
- Kosova, R. (2010). Do Foreign Firms Crowd Out Domestic Firms? Evidences from the Czech Republic. *Review of Economics and Statistics*, 92(4), 861-881.
- Lucas, R. E., & Stark, O. (1985). Motivations to Remit: Evidence from Botswana. *Journal of Political Economy*, 93(5), 901-918. Preuzeto 14. februara, 2018 sa: <http://www.jstor.org/stable/1833062>
- Moon, R. H., & Schorfheide , F. (2012). BAYESIAN AND FREQUENTIST INFERENCE IN PARTIALLY IDENTIFIED MODELS. *Econometrica*, 80(2), 755-782.



- Mundlak, Y. (1978). On the Pooling of Time Series and Cross Section Data. *Econometrica*, 69-85.
- Orsag, S., Mikerevic, D., & Baskot, B. (2017). Foreign direct investment and the development of small transition economies. *Acta Economica*, 15(27), 200.-221.
- Oruc, N., & Tabaković, A. (2016). Motives for Remittances Change During the Financial Crisis in Bosnia and Herzegovina. *Südosteuropa*. 64. 10.1515/soeu-2016-0003. *Journal of Politics and Society*, 27-47.
- Pesaran, M. H. (2006). Estimation and inference in large heterogeneous panels with multi-factor error structure. *Econometrica*, 74, 967–1012.
- Poelhekke, S., & van der Ploeg, F. (2013, July). Do Natural Resources Attract Nonresource FDI? *The Review of Economics and Statistics*, 95(3), 1046-1065.
- Robinson, D., & Gidling, H. (1999). Trade Liberalization and Relative Wages of More Skilled Workers in Costa Rica. *Review of Development Economics*, 140-54.
- Rodriguez, E. R., & Tiongson, E. R. (2001). Temporary Migration Overseas and Household Labor Supply: Evidence from Urban Philippines. *International Migration Review*, 35(3), 709-725.
- Rubio-Ramirez, J., Wagoner, D. F., & Zha, T. (2010). Structural Vector Autoregressions: Theory of Identification and Algorithms for Inference. *Review of Economic Studies*, 77, 665-696.
- Said, M., & Elshennawy, A. (2010). The Impact of Trade Liberalization on Manufacturing Employment and Wages in Egypt 1990-2007. Carnegie-Rochester Conferences on Public Policy, 251-286.
- Shea, D. (2012, December 5). The Impact of International Technology Transfer on American Research and Development. Testimony: Committee on Science, Space, and Technology Subcommittee on Investigations and Oversight. House of Representatives, US.
- Sims, C. A. (1980). Macroeconomics and Reality. *Econometrica*.
- Uhlig, H. (2005). What are the effects of monetary policy on output? Results from an agnostic identification procedure. *Journal of Monetary Economics*, 52, 381–419.
- Walsh, K. A. (1999). U.S. Commercial Technology Transfer to the People's Republic of China: A Report to the Office of Strategic Industries and Economic Security. Bureau of Export Administration.
- Wheeler, D., & Mody, A. (1992). International Investment Location Decisions: The Case of U.S. Firms. *Journal of International Economics*, 33, 57-76.
- Yang, D. (2011). Migrant Remittances. *The Journal of Economic Perspectives*, 129-151.
- Yang, D., & Choi, H. (2007). Are Remittances Insurance? Evidence from Rainfall Shocks in the Philippines. *THE WORLD BANK ECONOMIC REVIEW*, 21(2), 219–248.