ANALIZA UTJECAJA ORUŽANIH SUKOBA NA GOSPODARSTVO

Kusić, Karla

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:363368

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

ANALIZA UTJECAJA ORUŽANIH SUKOBA NA GOSPODARSTVO

Mentor: **Student:**

Doc. dr. sc. Maja Mihaljević Kosor **Karla Kusić**

Split, rujan 2018.

SADRŽAJ:

1. UVOD 3

1.1. Problem istraživanja 3

1.2. Predmet istraživanja 5

1.3. Ciljevi rada 6

1.4. Istraživačke hipoteze 7

1.5. Metode istraživanja 7

1.6. Doprinos istraživanja 8

1.7. Struktura rada 8

2. RATOVI, NEMIRI I TERORIZAM 9

2.1. Povijest terorizma 9

2.2. Globalizacija i oružani sukobi 11

2.3. Uzročno – posljedični aspekti oružanih sukoba i utjecaj na gospodarstvo 15

3. PREGLED LITERATURE 18

4. EKONOMSKI POKAZATELJI RAZVOJA 21

5. STATISTIČKA ANALIZA UTJECAJA ORUŽANIH SUKOBA NA GOSPODARSTVO 24

5.1. Odabir modela i opis varijabli 24

5.2. Rezultati empirijske analize 33

5.2.1. Prihvaćanje ili odbijanje hipoteza 36

6. ZAKLJUČAK 37

SAŽETAK 38

SUMMARY 39

LITERATURA 40

POPIS GRAFIKONA 45

PRILOG 46

1. UVOD

1.1. Problem istraživanja

Oružani sukobi predstavljaju stanje odnosa između država u kojima zaraćene strane nastoje upotrebom oružane sile i drugim agresivnim i nasilnim sredstvima nametnuti drugoj strani svoju volju ili je potpuno pokoriti i sasvim uništiti njezinu državnu strukturu (Nick, 1999). Sukobi i borba za opstanak postoje otkada postoji i čovječanstvo. Kroz povijest su se vodili s ciljem proširenja teritorija ili ostvarivanja kontrole nad određenim ekonomskim resursima, a svaki rat je u određenoj mjeri imao utjecaj na ekonomiju. Osim smrtnih stradavanja, oružani sukobi ostavljaju pustoš i u gospodarstvu. Troškovi koje nose sa sobom su brojni, a mnogo novčanih sredstava odlazi na troškove naoružanja, streljiva i vojne opreme, izbjeglice i prognanike, plaće pripadnika oružanih snaga, štete u životima i zdravlju ljudi itd. Danas je situacija drugačija, no ratovi se i dalje događaju kako bi se ljudima nametnuli stavovi, razmišljanja, vjerska načela, te se želi dokazati tko je lider u svijetu bilo u ekonomskom ili bilo kojem drugom smislu.

Nalazimo se u globaliziranom svijetu, a nastanak globalizacije počinje s uspostavljanjem SAD-a kao vodeće, svjetske i globalne sile što može potvrditi i Sirotković (1996) ističući da presudan utjecaj na ekonomski razvoj razvijenih tržišnih ekonomija kao i na ukupna svjetska kretanja uz SAD, imaju još Njemačka i Japan. U svojem utjecajnom radu Veselica (2007) tvrdi ako se globalizacija shvaća kao ukinuće prepreka u slobodnoj trgovini i bolje povezivanje nacionalnih gospodarstava, ona može biti snaga koja će donijeti dobro i koja može omogućiti svima da se „obogate“, posebice siromašnima. Vedriš (2017) tvrdi kako globalni svijet karakterizira dinamičan tijek interesa i kontinuirano odmjeravanje snaga nacionalnih država i transnacionalnih kompanija. Dakle globalizacija je prvenstveno ekonomski proces i njome se nastoji stvoriti jedno otvoreno tržište roba i ideja kojim upravljaju multinacionalne i globalne institucije, a vlade različitih zemalja provode ekonomsku politiku koje zemljama omogućavaju razvoj i osiguravaju dobrobit za sve socijalne slojeve.

Lončar (2005) u svome članku navodi kako se razlikuju ekonomski, političko - pravni i kulturni aspekt globalizacije, od kojih ekonomski govori da se zbog multinacionalnih kompanija gospodarstvo širi bez granica i posluje se kao da nema gospodarskih i političkih

barijera. Pravno – politički aspekt odnosi se na narušenu državnu suverenost nastalu uključivanjem u međunarodne ugovore, zajednice i organizacije. Stvara se sustav globalnog upravljanja koje ograničava dosadašnju moć države pri čemu nastaje temelj za stvaranje nove, nadnacionalne države. Kulturni aspekt nalaže kako se danas velikom brzinom uvodi zajednički svjetski jezik, točnije engleski jezik. Na žalost, na taj način nestaju mnoge kulturalne posebnosti koje život na Zemlji čine zanimljivim i jedinstvenim. Kako se svijet razvija tako se javlja ideja da će se s razvojem globalizacije gospodarski i ekonomski problemi riješiti. No s razvojem globalizacije javlja se sve veća konkurentnost na tržištu pa stoga primat u ekonomskom liderstvu nastoji preuzeti Azija, iako joj se i Europa nalazi za petama. Prijetnje s kojima se susreće Europa, što u svome radu potvrđuje Latour (2017) su otvoreno napuštanje zemalja koje su izmislile mondijalizaciju, utjecaj klimatskih promjena te obveza da služi kao utočište milijunima migranata i izbjeglica.

Stoga, predmet istraživanja u ovom radu jesu nemiri, oružani sukobi i terorizam, te otkrivanje čimbenika koji utječu na njihovu pojavu. Također ćemo se u ovom radu koristiti pokazateljima koji će nam pomoći da steknemo bolji uvid u ekonomsku razvijenost i razvijenost zemalja općenito u kojima se ratovi odvijaju. Sirotković (1996) u svojoj knjizi otkriva kako kretanje stanovništva ima veoma istaknuto mjesto u međunarodnoj analitici ekonomskog razvoja, jer je krajnji cilj svakoga nacionalnoga gospodarstva zadovoljavanje životnih potreba stanovništva, odnosno poboljšanje uvjeta života i rada. S druge strane KhoshnevisYazdi i Khanalizadeh (2017) tvrde da zbog globaliziranog svijeta dolazi do onečišćenja okoliša i zraka što negativno utječe na ljudsko zdravlje i ima negativan utjecaj na produktivnost rada. To dalje utječe na industrijsku i domaću proizvodnju pa samim time i na rast poduzeća i gospodarstva. Najznačajniju karakteristiku dosadašnjeg ekonomskog razvoja predstavljaju ogromne razlike između razvijenog i nerazvijenog dijela suvremenog svijeta. Šebić (2004) kaže da se razina razvijenosti zemlje uobičajeno mjeri putem osnovnih pokazatelja kao što su tehnologija, bruto domaći proizvod po glavi stanovnika, indeksa ljudskog razvoja HDI, ljudskim kapitalom i prirodnim resursima, no Burnley et al., (2008) u svom radu koriste pokazateljima koji će nam omogućiti detaljniju analizu (ne)stabilnosti zemalja.

Istraživati će se utjecaj oružanih sukoba na gospodarstvo gdje zavisna varijabla prikazuje bruto domaći proizvod po glavi stanovnika (BDP per capita), dok nezavisna varijabla prikazuje strukturne pokazatelje. Najčešće proučavane objašnjene varijable kao što su objasnili Burnley et al. (2008) su ekonomski pokazatelji (BDP, rast BDP-a, izvoz i uvoz),

demografski i društveni pokazatelji (ukupna populacija, gustoća naseljenosti, WB indeks stabilnosti, očekivani životni vijek, stopa smrtnosti novorođenčadi), politički pokazatelji (politička prava, susjedne zemlje u ratu) i okolišne varijable (planinski teren, šumska pokrivenost, površina zemljišta). Dva pokazatelja obično se koriste za izračunavanje ekonomskog čimbenika u modelu sukoba, a to su bruto domaći proizvod (BDP) i stopa rasta.

Fokus će biti na zemljama Europske unije zbog blizine zemalja koje će se istraživati, njihove ekonomske, povijesne i političke povezanosti, te velike dostupnosti podataka. Podatke ćemo pronalaziti putem internetskih stranica kao što su Eurostat koji objavljuje službenu statistiku Europske unije i europskog područja, Penn World Table koji predstavlja bazu podataka s podacima o relativnim razinama dohotka, proizvodnje, inputa i produktivnosti, The World Bank koja predstavlja jedinstveno partnerstvo pet institucija koje rade na mnogim održivim rješenjima i drugih.

1.2. Predmet istraživanja

Iz opisa problema rada proizlazi i predmet istraživanja ovog rada, a to je analiza utjecaja oružanih sukoba na gospodarstva zemalja Europske unije.

Problemi koji se tiču novčanih sredstava i trošenja istih za vrijeme ratovanja su mnogobrojni, pa tako i Stern (2006) smatra da je novac važniji za organizacije sa zapovjednim i kadrovskim ustrojem koje provode napade velikih razmjera kao što su terorističke organizacije. Tijekom rata, većina energetskih sredstava kao što su gorivo i struja se preusmjerava na ratovanje, a ne na tržište u prodaju. Industrijska proizvodnja se fokusira na proizvodnju vojne opreme (oružje, vojna vozila, zaštitna oprema, vojna obuća i odjeća), a hrana i lijekovi odlaze vojnicima i izbjeglicama. Zbog toga dolazi do propadanja tvrtki i gubitka tržišta (dijelom zbog rata, a dijelom zbog neprilagođenosti novim tržišnim uvjetima) te se stvaraju troškovi propuštene ekonomske aktivnosti. Javlja se gubitak turističke djelatnosti i odljev radne snage jer ljudi tragaju za boljim i sigurnijim životnim uvjetima. Stiglitz i Bilmes (2008) govore kako su za vrijeme rata u Iraku cijene goriva porasle što je utjecalo na gotovo svaki aspekt ekonomije. Veće cijene goriva vodile su većem trgovinskom deficitu i inflacijskim pritiscima. Centralna banka na takve pritiske reagira povećanjem kamatnih stopa što rezultira nižim ulaganjima, padom cijena dionica i usporavanjem gospodarstva.

Bauman (2017) smatra da se u razvijenim dijelovima svijeta, u kojima ekonomski iseljenici i izbjeglice traže utočište, poslovni interesi potiču i pozdravljaju dotok jeftine radne snage i potencijalno unosnih kvalifikacija. Svaki građanin u radnoj dobi ostvaruje dobrobit za društvo. Njegovim odlaskom država se nalazi u gubitku jer ne ostvaruje svoje ulaganje, odnosno ne obrazuje radno sposobno stanovništvo. Samim time javlja se rast nezaposlenosti te pad životnog standarda, plaća i mirovina. Po završetku oružanih sukoba, javljaju se troškovi u vidu obnove kuća, tvornica, škola i infrastrukture, razminiravanja i financijske pomoći te naknada onima koji su sudjelovali u ratu. Nadalje, gubitak financijskih sredstava javlja se zbog nemogućnosti poljoprivredne proizvodnje u miniranim poljima te dugog oporavka općenito. No kako bi se cjelokupno društvo vratilo realnoj ekonomiji i rastu, Gavranović (2017) smatra da se odgovor nalazi u stvaranju realnih preduvjeta i poticaja (ne samo materijalnih i financijskih) kako bi se razvio poduzetnički duh, razmišljanje o domaćoj proizvodnji pa samim time i širem tržištu i mogućnosti izvoza domaćih proizvoda.

„S obzirom da se preferencije, okolnosti i dostupnost informacija za svakog od subjekata na tržištu razlikuju, različiti subjekti će donositi različite odluke“ (Reić, Mihaljević Kosor, 2011, str.13). Stoga ćemo nastojati objasniti preko različitih varijabli zbog čega se javljaju sukobi, kako utječu na zemlje i da li se mogu predvidjeti i samim time spriječiti istražujući različite pokazatelje.

1.3. Ciljevi rada

U ovom radu opisuje se znanstveno prihvatljivi pristup kako bi se izradio statistički model pomoću kojega će se analizirati utjecaj nemira, sukoba, oružanih sukoba i terorizma na gospodarstvo u zemljama Europske unije. U relevantnoj literaturi o utjecaju sukoba na gospodarstvo istražuje se povezanost između oružanih sukoba i određenih ekonomksih pokazatelja kao što su BDP, rast BDP-a, uvoz i izvoz. Smatra se da je analiza utjecaja oružanih sukoba dio ranog upozorenja u smislu procjene vjerojatnosti da se stabilna situacija pretvori u sukob od određene veličine (Burnley et al., 2008).

Druge varijable kao što su npr. smrtnost dojenčadi i očekivani životni vijek nisu uzroci oružanih sukoba već samo povezani čimbenici.

1.4. Istraživačke hipoteze

Kako bismo započeli istraživanje, prvo je potrebno precizno definirati hipoteze koje će se nakon provedenog istraživanja odbiti ili prihvatiti. Uzimajući u obzir definirane ciljeve možemo postaviti sljedeće hipoteze:

H1: Izloženost oružanim sukobima ima negativan utjecaj na BDP

H2: Zemlje s višim HDI indeksom imaju manju izloženost oružanim sukobima

Varijable za neke zemlje moraju se oprezno interpretirati budući da podaci o njima mogu biti rijetki, nepotpuni ili mogu nedostajati za određene godine, no model se može lako ažurirati onda kada podaci postanu dostupni. Za vrijeme ispitivanja ovih hipoteza dodatna pažnja će se posvetiti vremenskoj dosljednosti svih varijabli koje će biti uključene u istraživanje.

1.5. Metode istraživanja

Rad se sastoji od teorijskog i empirijskog dijela. Teorijski dio rada temelji se na prikupljanju i analiziranju znanstvene literature i empirijskih istraživanja. Opće znanstvene metode koje će se koristiti u teorijskom dijelu rada su induktivna metoda, deduktivna metoda, metoda analize, metoda sinteze, metoda generalizacije, metoda deskripcije.

Zbog što jednostavnijeg i preglednijeg prikaza rezultata, u empirijskom dijelu rada će se koristiti grafikoni i tablice, a sami rezultati će se interpretirati uz pomoć podataka sa Internet stranica kao što su Eurostat, Penn World Table, The World Bank i drugih, te statističke analize. Podaci će sadržavati prostornu komponentu (eng. cross-sectionaldata) te će se istraživati europske zemlje, a vremenska komponenta (eng. time-series) će obuhvaćati razdoblje od početka 21. stoljeća pa sve do posljednjih raspoloživih podataka.

1.6. Doprinos istraživanja

Doprinos ovog rada, osim teorijskog razmatranja i povezivanja ključnih pojmova, biti će i u analizi i obradi prikupljenih podataka. Dakle, statistički i teorijski podaci će biti objedinjeni kako bi dobili što bolji uvid utjecaja oružanih sukoba na gospodarstvo i ekonomiju različitih zemalja, a koristiti će se dinamički panel model s posljednjim dostupnim podacima. Problemi koje oružani sukobi sa sobom nose su rast nezaposlenosti, pad plaća, emigracije radno sposobnog stanovništva i još mnogi drugi. Uslijed njihovih izbijanja u razvijenijim zemljama možemo pretpostaviti da bi došlo do raznih oblika nejednakosti u komunikacijskim kanalima između zemalja, te sve većeg ograničenja protoka ljudi, informacija, roba i usluga.

1.7. Struktura rada

Struktura ovog diplomskog rada je tematski podijeljena na šest dijelova koji će biti međusobno povezani. U uvodnom dijelu rada definirati će se problem i predmet istraživanja te će se navesti ciljevi istraživanja, istraživačke hipoteze, metode istraživanja i doprinos istraživanja.

U drugom dijelu rada definirati će se teorija oružanih sukoba, te njihovi uzročno – posljedični aspekti.

U trećem dijelu rada bazirati ćemo se na pregledu literature, dok će se u četvrtom dijelu podrobnije objasniti varijable koje će se koristiti u samom istraživanju.

U četvrtom dijelu rada prikupljati će se informacije o pokazateljima i varijablama koje će se kasnije u petom dijelu empirijski obraditi i tabelarno prikazati.

U posljednjem dijeluće se prikazati zaključna razmišljanja. Ovisno o rezultatima istraživanja, istraživačke hipoteze će biti prihvaćene ili odbačene.

2. RATOVI, NEMIRI I TERORIZAM

2.1. Povijest terorizma

Na početku ovog dijela rada potrebno je razdijeliti i objasniti pojmove kao što su sukobi, ratovi i terorizam. Smatra se da većina tih pojmova ima slično značenje, što dokazuje činjenica da ih međusobno povezuje nasilje i oružani sukob. Kod svake od pojava dolazi do upotrebe fizičkih sredstava kako bi se drugima nanijela šteta ili ih se prisilio na određeno ponašanje. Dakle, sukob u vojnom značenju predstavlja oružano sučeljavanje društvenih skupina, političkih organizacija, etničkih zajednica ili država, koje uključuje mnoge značajke rata (oružano nasilje, rušenje vlasti, borbu za teritorij i dr.). Prema obujmu i razornim posljedicama sukobi se dijele na krize, sukobe niskog intenziteta i ratove (Hrvatska enciklopedija, 2018). Rat s druge strane predstavlja nasilan, oružani sukob između dviju ili više država, saveza ili većih društvenih skupina od kojih je barem jedna strana vojnički ustrojena, naoružana i opremljena. U širem smislu, rat je stanje organiziranoga, po trajanju unaprijed neograničenoga kolektivnog sukoba, a suvremena znanost obično traži i određenu smrtonosnost događaja (najčešće 1000 poginulih u borbama tijekom jedne godine ili za trajanja sukoba ako je kraći od godine dana) (Hrvatska enciklopedija, 2018).

Terorizam predstavlja specifičan oblik agresivnog djelovanja protiv naroda, životne sredine i materijalnih dobara neke zemlje u miru i u ratu (Cvjetković, 2002). Terorizam je predstavljao nešto strano i nepoznato sve do početka 21. stoljeća, iako se on javlja još od antičkih vremena. U posljednje vrijeme taj pojam se veže uz islamski ekstremizam iako ga Stajić (2008) smatra surogatom za rat ili zamjenom za rat sredstvima političkog nasilja. Dakle terorizam predstavlja vrstu nasilja koji se javlja zbog ostvarenja vjersko - političkih ciljeva i prisutan je u čovječanstvu od davnina. Nasilje se javlja u obliku sabotaža, otmica, uništavanja objekata i sl., a provode ga pojedinci koji u konačnici najčešće i sami sebi oduzmu život. Problem u definiranju pojma terorizam jest taj što se on kroz povijest mijenjao, te je prije predstavljao borbu za oslobođenje teritorija i naroda, potom rat i naposljetku borbu za vjersku slobodu. Ochsenwald i Fisher (2004) ističu da ljudi koji sudjeluju u terorističkim akcijama vide sebe kao žrtvama nepravde i upotrebljavaju oznaku terorista zbog svojih neprijatelja, a ne zbog sebe. Oni vide svoja djela kao apsolutno i moralno dobro, dok neprijatelje vide kao istinsko zlo.

Danas se preko medija terorizam najviše povezuje s islamističkim skupinama i zemljama Bliskog istoka. Može se reći da je takvo razmišljanje djelomično krivo jer teroristička organizacije djeluju u cijelom svijetu. Nasilna ideologija na koju se teroristi pozivaju u opravdavanju upotrebe nasilja tek je pokriće za njihovo ponašanje. Jedan od najpoznatijih napada je onaj 11. rujna 2001. godine kada su oteta četiri zrakoplova od kojih su dva udarila Svjetski trgovački centar u New Yorku, jedan u Pentagon, dok se posljednji srušio u Pennsylvaniji. Prema službenim izvještajima, 19 osoba u službi Al-Qaide pretvorili su 4 zrakoplova u do tada najveće samoubilačke bombe. I prije i poslije toga napada bilo je pojava nasilja europskih terorista, no terorističke akcije arapskih i islamskih organizacija znatno su snažnije djelovale na europsku maštu i medije.

Venner (2004) u svojoj knjizi navodi kako intelektualni korijeni terorizma kao sustava potječu još iz doba Francuske revolucije kada je Ustavotvorna skupština donijela „zakon o sumnjivima“ koji predviđa da čovjek nema pravo na branitelja i nema pravo na pravnu zaštitu. Svatko može biti sumnjiv i mora dokazati da je ispunjavao građanske dužnosti i nevinost. Ipak, Venner naglašava kako je terorizam kao povijesna pojava nastao početkom 19. stoljeća i da se od tada neprestano širi. Procvatom medija sam pojam terorizma predstavljen je široj javnosti. S druge strane Rapoport (2002) tvrdi da prvi val terorizma počinje krajem 19. stoljeća, te ističe dva razloga: doktrinu i tehnologiju. Transformacija u komunikacijskim i transportnim oblicima je drugi razlog koji objašnjava širenje prvog vala. Telegraf, dnevne novine i željezničke pruge procvjetali su u tom razdoblju, a i kasnije tijekom 20. stoljeća, tehnologija je nastavila smanjivati vrijeme i prostor.

U posljednje vrijeme teroristički napadi se većinom događaju u razvijenijim gradovima europskih zemalja. Terorističke akcije tjeraju vlade da odgovore neočekivanim, izvanrednim i destruktivnim načinima. Prije nekoliko godina i sama pomisao da će ulicama Bruxellesa vojnici ići u ophodnju, čuvati ulaze u metro stanice te stajati ispred trgovačkih centara je izazivala strah. Sada su takve pojave normalne i umjesto straha daju osjećaj sigurnosti. Stanovnici zemalja Europske unije različito gledaju na situaciju kako terorizam utječe na njihovu zemlju. Istina je da terorizam predstavlja prijetnju za sve zemlje, no one koje ne pokazuju zabrinutost su itekako svjesne da strah od terorizma ima utjecaj i na gospodarstvo, pogotovo u granama poput turizma i ugostiteljstva.

Iako sama riječ terorizam unosi strah među ljude, većina napada koja se događa od 50-tih godina prošlog stoljeća dogovorena je i pomno isplanirana unutar određene organizacije.

Može se reći da postoji velika povezanost između pojmova terorizam i organizacija. Prema Turku (2004) klasični model terorističke organizacije je usko organizirana hijerarhija koja se sastoji od malih, izoliranih stanica čiji članovi imaju vrlo malo znanja o planiranju i organizaciji iznad i izvan njihove stanice. Njeni članovi su disciplinirani uz pomoć društvene izolacije (osobito od obitelji i bivših prijatelja), ucjena zbog počinjenih zločina nakon kojih pokazuju svoju predanost, fizičkih prijetnji te nemaju pristup nikakvim informacijama. Financijske resurse potrebne za održavanje takvih organizacija dobivaju od donacija osoba koje simpatiziraju takav oblik organizacija, te od raznih kaznenih djela (otmice ljudi i traženje otkupnine, bankovne pljačke i slično). Zanini i Edwards (2001) navode novije i manje hijerarhijski organizirane terorističke organizacije kao što su Hamas, Palestinski islamski džihad, Hezbollah i Al-Kaida koje su ujedno postale i najaktivnijim terorističkim organizacijama.

2.2. Globalizacija i oružani sukobi

Početak rata bilježi se u dalekoj ljudskoj prošlosti, te izvire iz ljudskih reakcija koje su se razvijale milijunima godina. Rat se ne može povezati ni sa kakvim iskrivljenim ili životinjskim instinktom. Radi se o jednoj formi agresije koja je specifična za ljude i uz pomoć koje se ljudske grupe bore za zemljište i prirodna bogatstva. On predstavlja jednu od najdramatičnijih, ali i najsloženijih društvenih pojava. Mnogo je definicija rata, no one sve ne uključuju rat samo kao čin, već stanje među ljudima, državama ili organizacijama do kojega dolazi zbog razilaženja među određenim stavovima koji se mogu riješiti jedino silom. Iako ga najčešće obilježavaju oružane operacije, rat ima i mnoge druge dimenzije kao što su psihološka, pravna, socijalna, ekonomska i druge. Krivokapić (2003) kaže da ratovi, iako su počeli još prije 10.000 godina, on smatra kako su, od onih zabilježenih kroz povijest, od 3600. godine pr. Kr. do danas odnijeli više od 3,5 milijarde ljudskih života. Smatra se da su najkrvaviji ratovi u povijesti bili Prvi i Drugi svjetski rat, no i ranije vođeni ratovi su imali veliki broj žrtava. Isti autor također navodi kako postoji više klasifikacija ratova, ali neke od najčešćih podjela su s obzirom na karakter (međunarodni ili unutrašnji), vrstu sredstava i metoda ratovanja, broj uključenih strana i druge.

Ratove također razlikujemo i po razlozima zbog kojih su izbili, a neki od njih su borba za ljudska prava između vladajuće klase i robova, stalni pritisak na neprijatelja radi njegove

demoralizacije i dezorganizacije, namjerno uništavanje životne sredine, svjesna uzrokovanja i širenja zaraznih bolesti, nacionalno oslobođenje i nezavisnost, oduzimanje određenog dobra ili iznuđivanje određenih ustupaka, obrana ili širenje određene vjere, zauzimanje tuđeg teritorija, pljačkanje tuđe imovine i drugi. Dakle čovjek ratuje sve dok ne podmiri svoje elementarne potrebe preživljavanja i slobode. Jedan od prvih razloga zbog kojih su izbijali razni sukobi je bio novac. Čak je i Ciceron rekao kako je *glavno poticalo na rat novac*. On se javlja na prijelazu od prvobitne zajednice k robovlasničkom društvu. Leko i Jurković (1998) spominju prirodni novac (primitivni oblici novca bili su krzno, školjke, stoka i drugi) kao prvi oblik razmjene sredstava. No daljnjim napretkom podjele rada te širenjem nacionalnog tržišta, novac se mijenjao i njegova je funkcija u razmjeni sredstava postala nezamjenjiva, a moć mu je postajala sve veća. Kako su godine odmicale razvijala se industrija i tehnologija, a svijet i ljudi su postali užurbaniji. Od 19. stoljeća proizvodnja u svijetu raste mnogo brže od broja stanovnika, a svijet postaje međusobno integriran i sve što se događa lokalno, može se odraziti i globalno. Uz takav užurbani ritam dolazi do pojave globalizacije.

Na prijelazu iz 19. u 20. stoljeće odnosi među državama u Europi znatno su se razlikovali od današnjih, jer se tada smatralo da državna snaga proizlazi iz teritorijalne dominacije. Kasnije najvažniji cilj državne politike postaje pristup sirovinama i inozemnim tržištima kako bi se i dalje održao postojeći životni standard. U Europi države žele biti posebne na način da svaka od njih ima jedinstveni pristup ključnim područjima politika. Jasni i rani počeci europskog identiteta srednjovjekovni su, a bitna karakteristika Europe je činjenica da je ona unutar sebe vrlo različita. No unatoč svim različitostima, Europa ima svoje jasne i izrazite utemeljenosti, a one mogu biti iz starijeg ili novijeg doba. Teritorijalno širenje Europe ostvaruje se kroz pokretanje organizacija kao što je Europska unija, čiji je glavni moto približavanje jedinstvu i idealu. Europska unija nije uvijek bila ovako velika kao danas. Godine 1951. Belgija, Njemačka, Francuska, Italija, Luksemburg i Nizozemska su započele gospodarsku suradnju, a s vremenom je sve više zemalja odlučilo surađivati, pa je Unija dosegnula sadašnju veličinu od 28 država članica. Sudjelovanje u projektu Europske unije donosi određene koristi za zemlje sudionice, ali postoje i određene dužnosti koje proizlaze iz Ugovora o EU. Kandžija i Cvečić (2010) navode kako su glavne koristi od članstva u Europskoj uniji ravnopravno sudjelovanje u radu tijela Unije i oblikovanje zajedničkih odluka i politika, korištenje prednosti Unutarnjeg tržišta i utjecaja EU-a u međunarodnim odnosima, suradnja u razvojnim projektima, zaštita koju pruža Zajednička obrambena i sigurnosna politika Unije, te korištenje aranžmana Unije u međunarodnoj trgovini, u sklopu sporazuma EU-a i Svjetske trgovinske

organizacije (WTO). S druge strane, isti autori navode kako članstvo u EU nosi određene obveze zemalja članica, pa su tako osnovne dužnosti članica EU-a primjena pravnih propisa Unije, tj. pravne stečevine koja se svakim danom povećava zbog širine zajedničkih aktivnosti članica unutar EU-a, aktivni doprinos ispunjavanja ciljeva EU-a putem aktivnosti na razini država članica i na razini Europske unije, te uplaćivanje u proračun Europske unije određenog dijela prihoda od PDV-a.

Sami proces globalizacije dobio na značaju nakon industrijske revolucije i kapitalističkog načina proizvodnje, čiji je cilj bio stjecanje i povećanje profita. Industrijska revolucija i tehnološki napredak smanjili su troškove proizvodnje i omogućili stvaranje novih proizvoda, procesa i metoda, koji su do tada bili potpuno nepoznati. Galović (2017) govori kako je prvi val globalizacije bio je prekinut Prvim svjetskim ratom, koji je inicirao pad liberalne politike međunarodne razmjene i rast nacionalnog protekcionizma. Na izbijanje rata utjecale su trajne napetosti u složenom sustavu saveza uspostavljenom nakon 1870. koji se počeo iscrpljivati, utrka u naoružanju, unutrašnjopolitička situacija u pojedinim državama, te slaba diplomatska komunikacija. Nakon Drugog svjetskog rata novi je val globalizacije ponovno ojačao međunarodnu trgovinu, koja je zabilježila oštar uzlazni trend i ostvarila visoke stope rasta. No iako su rat i svaka upotreba sile zabranjeni određenim poveljama i međunarodnim pravima, ratovi se nažalost i dalje događaju i u 21. stoljeću, a razlozi su uglavnom političke i ekonomske prirode. Jedni od aktualnijih ratova u posljednjih 20 godina su rat protiv terorizma koji je započeo 2001. godine (koji su pokrenule Sjedinjene Američke Države protiv globalne terorističke mreže Al-Qaide i protuameričkih država i organizacija u svijetu, nakon terorističkih napada u američkim gradovima New Yorku i Washingtonu 11. rujna 2001. godine), valutni rat iz 2008. godine (kada su Sjedinjene Države, početkom globalne ekonomske krize, počele opet tiskati velike količine dolara kako bi kupovinom drugih valuta spustile vrijednost dolara i tako povećale svoj izvoz i smanjile nezaposlenost), te rat u Siriji koji je započeo 2011. godine (vodi se u Siriji između vlade i džihadističkih pobunjenika, koji uz pomoć zapadnih sila i njihovih arapskih saveznika nastoje svrgnuti predsjednika i njegovu vladajuću stranku).

Ratovi su se kroz povijest vodili s ciljem ostvarivanja kontrole nad određenim ekonomskim resursima. Svaki je rat u većoj ili manjoj mjeri imao utjecaj na ekonomsku povijest, često mijenjajući odnose na tržištima. No nakon mnogih ratova i sukoba, europske zemlje započinju proces međusobnog povezivanja. Jedan od ciljeva tog povezivanja bio je izbjeći daljnja međusobna neprijateljstva i stvoriti Europu u kojoj će sve zemlje međusobno surađivati i

pomagati se. Globalizacijom započinju procesi koji se osjećaju u svim dijelovima svijeta. Za globalizaciju se može reći da je ona zapravo posljedica razvoja znanosti, suvremene tehnologije i tržišne ekonomije. Omogućila je slobodno kretanje kapitala, roba, informacija i ljudi kroz širenje i ukidanje granica. Prema Galoviću (2017) globalizacija je, usprkos povećanju ukupnog svjetskog bogatstva, doprinijela i povećanju nejednakosti među zemljama i unutar njih samih. Pri tom se misli na jaz između sjevera (SAD, većina europskih zemalja i neke države jugoistočne Azije) i juga (zemlje Trećeg svijeta). Taj jaz između bogatih i nerazvijenih zemalja se javlja iz razloga što bogate zemlje postaju sve bogatije zahvaljujući kapitalu kojega posjeduju i kojega mogu velikom brzinom umnažati.

S druge strane siromašne zemlje ostaju i dalje nerazvijene jer ne posjeduju dovoljnu količinu kapitala s kojim bi mogle poslovati. Svaka zemlja želi biti ekonomski lider, a najčešće glavni ciljevi su im povećanje i poboljšanje životnog standarda, brz, uravnotežen i stabilan ekonomski rast, te rast zaposlenosti i efikasnosti. Ona omogućuje interakciju različitih kultura koje se međusobno obogaćuju, stvaranje ekonomije obujma zbog proširenja tržišta, bržeg tehnološkog razvoja, te većih građanskih i političkih prava. Čovjeku se dodjeljuje nova uloga u društvu, odnosno on sve više postaje sredstvo, a napredak tehnike i tehnologije postaje cilj. Dakle s razvojem tehnologije, tržišta i proizvodnje, čovjek je taj koji će proizvode kupovati i trošiti i na taj način omogućiti dodatni rast tržišta. Prema Karliću (2008) neke od pozitivnih strana globalizacije su: širenje gospodarskih uspjeha, pronalaženje načina da se proizvede više npr. hrane za siromašniji dio svijeta, čemu dodatno pridonose znanost i znanstvena istraživanja. Također i materijalna pomoć stradalima u raznim nepogodama (potresi, požari, poplave) koja vrlo brzo stiže iz cijeloga svijeta, zatim proizvodnja dobara i njihova ponuda svim građanima svijeta po jeftinijoj cijeni, te naposljetku uvođenje demokratizacije i u ona društva koja su stoljećima pod vlašću raznih vlastodržaca. S druge strane, globalizacija ima i negativne strane. Veliki i moćni narodi u napasti su da iskorištavaju gospodarsku moć manjih naroda, kako bi ih podvrgli svojim ekonomskim i političkim opcijama, dok svjesno ili nesvjesno globalizacija briše razlike među narodima i ljudima u odnosu na njihovu povijest, jezik i kulturu. Stvaranje globalnog tržišta i prihvaćanje teze o slobodnom tržištu potiče nejednakosti za države različitog stupnja razvoja zbog čega dolazi do pojave ekonomske krize. Zbog posljedica globalne gospodarske krize zapadne (visokorazvijene) zemlje su gospodarski oslabile, velike financijske institucije su većinom postale nacionalizirane ili su ugašene, oslabila je njihova industrijska ponuda i potražnja, povećala se nezaposlenost, a jačale su i političke tenzije koje su rezultirale ratovima na Bliskom istoku.

2.3. Uzročno – posljedični aspekti oružanih sukoba i utjecaj na gospodarstvo

Ratovi su u različitim državama imali različite posljedice, no usprkos tome mogu se odrediti pojedini fenomeni koji su većini zemalja bili zajednički. Najveće teškoće za ratnu proizvodnju događale su se zbog prekida ili ograničenja međunarodnog prometa o kojemu je ovisila ekonomija svih glavnih europskih zemalja, te zbog pomicanja internacionalnih prometnih tokova za vrijeme ratovanja. Velika novost je bila uvođenje nove radničke klase po dobi, spolu i profesionalnoj kvalificiranosti, odnosno uvođenje žena u radništvo. Uvođenje nove radne snage naišlo je na otpor sa svih strana. Radnička i sindikalna udruženja protivila su se radu žena jer su dijelili tradicionalne poglede na ulogu žene u društvu. U početcima žene nisu imale nikakva prava i smatralo se normalnim da vode samo kućanstva, a industrijska revolucija je imala nepovoljan učinak na ženske živote: dvostruki rad (u tvornici i domaćinstvu), naporan rad u nehumanim uvjetima, manje plaćen rad od muškaraca, češći zdravstveni problemi i češće ozljede na radu zbog šire odjeće (Hrvatski povijesni portal, 2010). Niske nadnice trebale su žene zadržati doma da ne oduzimaju muškarcima posao. S druge strane žene su poslodavcima bile isplativije jer su poslušnije i jednako djelotvorne kao muškarci.

Ratovi dugoročno otežavaju gospodarski razvoj te su skupi i razorni za kapital, unutarnju i međunarodnu trgovinu te predstavljaju ozbiljne prijetnje za gospodarstva zemalja sudionica. Oni sa sobom nose velike ljudske gubitke i materijalna razaranja, nedostatak sirovina, žitarica i hrane, zatvorene tvornice, neobrađena polja, uništene mostove i željeznice. Zbog ovakvih stanja dolazi do pojave tražitelja azila, izbjeglica i migranata (UNHCR, 2001). Prema UN-u, tražitelji azila su osobe koje traže izbjeglički status. Oni su pobjegli iz svoje zemlje u potrazi za međunarodnom zaštitom uslijed izbijanja sukoba. S druge strane izbjeglice su osobe koje napuštaju svoju zemlju u strahu od progona zbog rase, nacionalnosti, pripadnosti određenoj društvenoj skupini ili političkoj opciji, te ne uživaju zaštitu svoje države i progonom im može prijetiti i njihova vlada. Oni odlaze kako bi spasili svoj život ili sačuvali svoju slobodu. Zahvaljujući centrima za socijalnu pomoć, Fondu za azil, migracije i integraciju, Crvenom križu, te dijelu državnog proračuna, tražiteljima azila i izbjeglicama može biti pružena adekvatna financijska pomoć. Migranti se uvelike razlikuju od izbjeglica jer napuštaju zemlju iz razloga koji nisu povezani s progonom. Oni možda žele studirati u inozemstvu, ujediniti se sa svojom obitelji ili poboljšati svoje buduće ekonomske perspektive, a nastavljaju uživati

zaštitu svoje vlade čak i kada su u inozemstvu. Migrante pretežito predstavlja mlađe stanovništvo koje je u potrazi za boljim i ekonomski sigurnijim životom.

Još jedan problem koji sukobi i ratovi nose sa sobom jest dugoročnih utjecaj na turizam. Na mediteranskim zemljama turizam je jedna od najvažnijih gospodarskih grana, a zbog niza koristi koje proizlaze iz njegova razvoja, turizam je stekao status iznimno važne komponente nacionalnih gospodarstava mnogih zemalja. Osnovne funkcije suvremenoga turizma dijele se na društvene i ekonomske (Hrvatska enciklopedija, 2018). Društvene funkcije turizma pridonose humanističkim vrijednostima turizma (obogaćivanju čovjeka novim spoznajama, doživljajima i aktivnostima) i povezuju se s izvornim motivima turističkih kretanja, koji nisu u vezi s postizanjem gospodarskih ciljeva, dok ekonomske funkcije turizma predstavljaju aktivnosti usmjerene na postizanje konkretnih gospodarskih učinaka kao što su turistička potrošnja, izvoz roba i usluga, izravne investicije, povećanje zaposlenosti, razvoj nedovoljno razvijenih područja i slično, na razini poduzeća i organizacija izravno ili neizravno uključenih u kreiranje turističke ponude, ali i na području turističke destinacije. Usred izbijanja sukoba, turizam će se najsporije oporavljati zbog narušene građevinske infrastrukture i drastičnog smanjenja sadržaja, zbog čega je potrebno vratiti originalan i prvobitan izgled određenih područja. Andrijević (1997) kaže kako je Domovinski rat ostavio vidne tragove na Hrvatskoj turističkoj infrastrukturi, ali i na broju turista koji se drastično smanjio prve ratne godine 1991. na 2.146.000 ili 74,74% manje u odnosu na prethodnu godinu ili čak 77,8% u odnosu na 1989. godinu koja se uzima kao "normalnom" godinom turizma. Dakle, u konačnici je potrebno povratiti sigurnost turista, jer upoznati sa situacijom u čijim su područjima vladali nemiri, svjesni su da ekonomska situacija nije stabilna. S druge strane, potrebno bi bilo sniziti cijene svih raspoloživih sadržaja kako bi ih zemlje povoljnošću ponude i raznih paketa privukle da ponovo posjećuju atraktivne destinacije.

Za vrijeme svakog rata vojsku je potrebno dobro opskrbiti svim sredstvima kako bi vojnici bili što efikasniji na bojišnici. To znači da je potrebna velika nabava sredstava zbog koje se većina industrijske proizvodnje preusmjerava za vojne potrebe. Možemo reći da dolazi do razvoja lanca opskrbe. Dakle robe, usluge i informacije se kreću od dobavljača, preko transporta, proizvođača, distributera, maloprodaje do krajnjeg kupca odnosno vojske. Cravetto i Goldstein (2008) govore kako nisu samo tvornice oružja radile za bojišnicu i povećavale proizvodnju zbog ratnih narudžbi. Za vrijeme Prvog svjetskog rata povećana je proizvodnja cipela s 400.000 pari na mjesec na milijun pari mjesečno, industrija vune je povećala svoju proizvodnju na 102.000 kilometara materijala kao i automobilska industrija na

otprilike 70.000 raznih vozila. Gotovo da nije bilo grane industrije koja je bila isključena iz rastućih državnih narudžbi potaknutih ratom. Za vlade i visoke vojne zapovjednike bilo je neophodno dobiti potporu svoga naroda kako bi osigurali osnovne sirovine. S obzirom na upravljanje tijekovima roba, novca i informacija, nabava kao poslovna funkcija dobila je potpuno drugo značenje uključujući više strateških zadataka. Kemijska industrija okrenula se proizvodnji eksploziva, a industrija metala i strojeva je sve više jačala. Porastom industrijske proizvodnje bilo je potrebno zaposliti više ljudi, stoga je i zaposlenost narasla, ali zaposlenici su bili podložni intenzivnom ritmu posla i malim nadnicama.

S druge strane, nakon završetka rata se javljaju razne financijske obveze. Potrebno je isplatiti novce veteranima koji su sudjelovali u ratu, a koji ispunjavaju uvjete za isplatu obvezne naknade za invalidnost, te psihički i fizički oboljelim osobama. Javljaju se troškovi u vidu pružanja medicinske pomoći za vrijeme ratovanja, a po završetku rata slijedi obnavljanje vojske u vidu zamjene istrošene opreme i ulaganje u nova vozila i oružja. Ratovi mogu rezultirati uništavanjem imovine, žrtvama, troškovima liječenja, oštećenjem infrastrukture i trgovinskim ograničenjima. U konačnici ratovi oslabljuju povjerenja ulagača što je ključni element poticanju priljeva izravnih inozemnih ulaganja, te na taj način oslabljuju ekonomiju i usporavaju ekonomski rast.

Može se reći da koliko god oružani sukobi djeluju negativno na ekonomski rast i razvoj zemalja u kojima se odvijaju, toliko barem u maloj mjeri djeluju pozitivno na istu zbog preusmjeravanja industrijske proizvodnje za vojne potrebe.

3. PREGLED LITERATURE

Znanstvene rasprave i istraživanja se u posljednje vrijeme dosta baziraju na temama kao što su ratovi, terorizam i nemiri. U prethodnim poglavljima izneseni su uzroci oružanih sukoba, te gospodarske posljedice koje nose sa sobom. Mnogi istraživači u svojim radovima uzimaju u obzir različite zemlje ili skupine zemalja, te različite makroekonomske varijable. Razna znanstvena istraživanja dokaz su da postoji sve veći interes znanstvenika u proučavanju utjecaja terorizma na gospodarstvo općenito. U sljedećem tekstu detaljnije će se analizirati takvi radovi.

Abadie i Gandeazabal (2003) u svom radu pokušavaju otkriti terorističke aktivnosti koje su uzrokovale povećanu globalnu nesigurnost s negativnim utjecajem na distribuciju i prijenos kapitala i priljeva ulaganja u različitim zemljama. Otkrili su da nakon izbijanja terorizma u kasnim 1960-tim godinama, BDP po glavi stanovnika u regiji Basque (najbogatija regija u Španjolskoj) je pao za 10 postotnih bodova u odnosu na sintetsku kontrolnu regiju bez terorizma. Osim toga, razdoblje primirja iz 1998. i 1999. godine primijenili su kao prirodni eksperiment.

Gries et al. (2009) analiziraju ulogu ekonomske uspješnosti u određivanju terorističkog nasilja. Koriste Hsiao-Grangerovu metodu kako bi testirali uzrok rasta terorizma i vezu između intenziteta domaćeg terorizma i stope realnog rasta BDP-a po stanovniku u sedam europskih zemalja (Francuska, Njemačka, Grčka, Italija, Portugal, Španjolska i Ujedinjeno Kraljevstvo) u razdoblju od 1951. do 2004. godine. Rezultati potvrđuju da se gospodarstva pogođena napadima uspješno prilagođavaju prijetnjama terora, te da ekonomski rast nije umanjen.

Mehmood (2013) provodi istraživanje na primjeru Pakistana uz pomoć Kvazi-strukturni VAR modela, modela vektorske ispravke pogrešaka, Impuls ResponseFunctions modela i Granger-Causality testova na uzorku koji pokriva više od 4500 terorističkih incidenata u razdoblju od 1973. do 2010. godine i dolazi do zaključka kako je terorizam cjelokupno koštao Pakistan oko 33,02% njegovog nacionalnog dohotka, što je približno gubitku od 1% realnog BDP-a po glavi stanovnika svake godine. Stoga terorizam uzrokuje da pakistansko gospodarstvo ostaje ispod svoje potencijalne razine dohotka.

Cinar (2017) analizira utjecaj gospodarskog rasta kao rezultat terorističkih napada uz pomoć panel podataka na uzorku od 115 zemalja u periodu od 2000. do 2015. godine. Varijable koje

koristi u svom istraživanju su ekonomski rast i teror indeks (ovaj indeks izračunava logaritam 1 plus prosjek broja smrtnih slučajeva nastalih uslijed terorističkog napada unutar Zelene linije, broja terorističkih ozljeda nastalih uslijed terorističkog napada unutar Zelene linije i broja terorističkih događaja unutar Zelene linije. Zelena linija ustanovljena je 1949. godine i predstavlja granicu na kojoj je sklopljeno primirje između Izraela i njezinih protivnika Sirije, Jordana i Egipta). Zaključuje kako postoji negativan utjecaj terorističkih napada na gospodarski rast većine zemalja, međutim taj učinak u zemljama sa niskim prihodima je oko 3 puta veći nego u zemljama sa visokim prihodima. Dakle, ovo istraživanje zapravo predlaže gospodarski rast kao indirektni instrument borbe protiv terorizma, odnosno povećanje razine dohotka imati će za posljedicu da pojedinci ne poduzimaju nikakve ilegalne akcije.

Slično prethodnom istraživanju, Tavares (2004) istražuje utjecaj terorističkih napada i ekonomskih troškova na razini zemlje. Makroekonomske varijable koje koristi u radu su BDP po stanovniku, uvoz i izvoz, ukupni rashod države i ukupno stanovništvo, te pokrivaju većinu zemalja svijeta između 1972. i 2001. godine. On dolazi do zaključka kako su bogatije zemlje podložnije terorističkim napadima, razina političkih prava nije značajno povezana s pojavom terorizma, te mlado stanovništvo koncentrirano u urbanim područjima povećava rizik od pojave terorizma.

Bandyopadhyay et al. (2011) istražuju vezu između terorizma i direktnih stranih ulaganja koristeći dinamičke panel podatke za 78 razvijenih zemalja između 1984. i 2008. godine, te dolaze do zaključka kako terorizam ima negativan i značajan utjecaj na izravna strana ulaganja, te kažu kako se razlikuju negativne posljedice izravnih stranih ulaganja od „domaćeg“ terorizma i transnacionalnog terorizma. Naime, negativan utjecaj transnacionalnog terorizma na izravna strana ulaganja je 2,5 do 3 puta veći od „domaćeg“ terorizma.

Musayev (2016) istražuje potencijalni uzrok pozitivnih eksternalija u vezi između vojnih rashoda i ekonomskog rasta koristeći metodu procjene panel podataka. Dolazi do zaključka da vojni izdaci u prisutnosti visokih unutarnjih prijetnji potiču ekonomski rast, dok vojni izdaci kojima upravlja korupcija i najam smanjuju rast. Također analiza pokazuje da su vojni izdaci manje štetni za zemlje s velikom količinom prirodnog bogatstva sve dok im bogatstvo resursa nije povezano s korupcijskim aktivnostima.

U istraživanju koje provode Frey et al. (2007) spominje se kako terorizam može ostaviti mnoge ekonomske posljedice na turizam, izravna strana ulaganja, potrošnju i štednju,

ulaganja, cijene dionica, vanjsku trgovinu, urbanizaciju i ukupni gospodarski razvoj, uključujući troškove napada 11. rujna 2001. godine. No u ovom istraživanju posebna se pozornost posvećuje gubitcima nastalih uslijed terorističkih akcija. Autori ističu kako terorizam dovodi do značajnog smanjenja zadovoljstva životom, naglašavajući kako bi pojedinci imaju velike gubitke korisnosti zbog čega bi im se trebao značajno povećati dohodak kao nadoknada za štete nanesene terorizmom.

Filer i Stanišić (2013) analizirali su utjecaj terorizma na priljev kapitala koristeći se panel podacima i podacima sa The Global TerrorismDatabase (GTD) stranice na uzorku od 160 zemalja kroz 25 godina, te su došli do zaključka kako terorističke napade može znatno smanjiti izravni investicijski tok bez utjecaja na inozemni dug i investicijski portfelj. Dakle povećana teroristička aktivnost jako smanjuje udio izravnih stranih ulaganja.

Što se tiče teorije etničkih sukoba, Blimes (2006) se koristi statističkom analizom i heteroskedastičnošću kako bi istaknuo da postoje čimbenici zbog kojih postoji veća mogućnost da bi građanski rat mogao izbiti, no etničke skupine pružaju prirodne rascjepe za društvo i kao takve mogu pomoći prevladavanju problema koji mogu spriječiti izbijanje rata u zemljama u kojima takve etničke skupine ne postoje.

Bezić et al. (2016) istražuju utjecaj terorizma na priljev FDI-a u određenim europskim zemljama. U istraživanju koriste generaliziranu metodu momenata (Generalized method of moments – GMM) kako bi istražili 29 zemalja kroz period od 2000. do 2013. godine, te ističu kako rezultati istraživanja potvrđuju da terorizam ima negativan utjecaj na sigurnost priljeva inozemnih izravnih ulaganja u odabrane zemlje Europske unije i Europske ekonomske zajednice. Posljedica toga su protuteroristički troškovi sigurnosti koji opterećuju gospodarstvo i umanjuju njegov konkurentni potencijal, a istodobno utječu na povećanje cijena proizvoda u pogođenim zemljama.

4. EKONOMSKI POKAZATELJI RAZVOJA

Brojke u ekonomiji je potrebno interpretirati kako bismo što bolje razumjeli na koji način funkcionira gospodarstvo, vladine ekonomske novosti i postigli bolje razumijevanje svih novosti. Glavni fokus će biti na zemljama Europske unije, te pokazateljima koji će kroz dinamičku panel analizu otkriti utjecaj oružanih sukoba na gospodarstvo.

Postoje brojni pokazatelji razvijenosti neke države, no s obzirom na njihovo bogatstvo razlikujemo razvijene zemlje i zemlje u razvoju. Zemlje u razvoju odlikuje visok natalitet, mortalitet, udio mladog stanovništva, te visoke stope prirasta. Većina je zemalja u razvoju usmjerena na proizvodnju primarnih proizvoda ili im je ekonomija koncentrirana na jedan sektor, s nedovoljno razvijenom prometnom infrastrukturom, slabom unutrašnjom i vanjskom trgovinom, nepovoljnom obrazovnom strukturom stanovništva, nerazvijenim društvenim službama i nerazvijenom političkom kulturom (Strategije ekonomskog razvoja, 2018). U razvijenim zemljama javlja se nizak natalitet, visok udio starog stanovništva, pozitivna migracijska bilanca i brži rast gospodarstva od stanovništva. Proučavanje razvoja je zapravo mjerenje kako se jedna zemlja razvila u usporedbi s drugim zemljama ili istom zemljom, gledajući kroz vrijeme. Ekonomski razvoj nije isto što i rast, jer razvoj odražava društveni i gospodarski napredak, a zahtjeva ekonomski rast. Ekonomski pokazatelji rasta su bruto domaći proizvod, bruto domaći proizvod po glavi stanovnika, izvoz i uvoz, a među njima se još ističu i ukupna populacija, HDI indeks ljudskog razvoja, inflacija i nezaposlenost, kao i demografski i društveni pokazatelji (ukupna populacija, gustoća naseljenosti, očekivani životni vijek, stopa smrtnosti novorođenčadi), politički pokazatelji (politička prava, susjedne zemlje u ratu) i okolišne varijable (planinski teren, šumska pokrivenost, površina zemljišta). U sljedeći paragrafima detaljnije će biti objašnjeni navedeni pojmovi.

Bruto domaći proizvod (BDP) predstavlja vrijednost svih dovršenih roba i usluga koji su bili proizvedeni unutar jedne države u određenom vremenskom razdoblju. Izražen je u novčanim jedinicama, a uključuje samo one proizvode i usluge koji su dovršeni i spremni za neposrednu potrošnju (Ekonomski rječnik, 2016). Glavna svrha izračunavanja bruto domaćeg proizvoda je dobivanje uvida u razvoj, gospodarsku aktivnost neke države, te stupanj rasta njenog gospodarstva. Dakle BDP predstavlja ukupan zbroj privatne i državne potrošnje, bruto kapitalnih ulaganja u osnovna sredstva i neto izvoza. S druge strane bruto domaći proizvod po glavi stanovnika (BDP per capita) jest pokazatelj razine životnog standarda stanovništva određene države. Važan je pokazatelj ekonomske uspješnosti i korisna jedinica za usporedbu

između prosjeka životnog standarda i ekonomskog blagostanja. Međutim, BDP po glavi stanovnika nije mjerilo osobnog dohotka, a koristi se za usporedbe među zemljama što također ima određene slabosti.

Sljedeći pokazatelj razvoja je izvoz (robe i usluga), te predstavlja vrijednost svih dobara i ostalih tržišnih usluga koje se pružaju u ostatku svijeta. Oni uključuju vrijednost robe, tereta, osiguranja, prijevoza, putovanja, autorske naknade, naknade za licencu i druge usluge, kao što su komunikacija, građevinska, financijska, informacijska, poslovna, osobna i državna služba (The World Bank, 2018). Kod uvoza je situacija slična kao i kod izvoza, jedina je razlika što se dobra i tržišne usluge primaju iz ostatka svijeta.

Društveni razvoj može se mjeriti i kroz indeks ljudskog razvoja (HDI) koji predstavlja kombinaciju pokazatelja obrazovanja, prihoda i očekivanog trajanja života. Indeks se može koristiti za ispitivanje nacionalnih političkih odluka, uspoređujući dvije zemlje s istom razinom BND-a po glavi stanovnika što može rezultirati s različitim ishodima ljudskog razvoja. Vrijednost indeksa kreće se između minimalne i maksimalne vrijednosti (0 i 1) za svaki čimbenik, te se mjeri u odnosu na dužinu i kakvoću života, mjerenu vremenom trajanja života od trenutka poroda, zatim znanja koje se mjeri pomoću pismenosti, te životnog standarda koji je mjeren BDP-om per capita prema paritetu kupovne moći u američkim dolarima (United Nations development programme, 2018).

Bejaković (2003) kaže da je nezaposlenost stanje u kojemu se dio radno sposobnog stanovništva ne može zaposliti primjereno svojim sposobnostima i kvalifikacijama, uz uobičajenu plaću. U nezaposlene se ubrajaju i svi članovi društva koji su djelomično zaposleni, ali njihova radna snaga nije u punoj mjeri iskorištena, ne rade puno radno vrijeme i nemaju primanja dostatna za normalan život. Većina zemalja materijalno osigurava nezaposleno stanovništvo, a pravo na novčanu naknadu uglavnom se stječe nakon što je osoba radila određeni broj mjeseci, pri čemu radni odnos ne smije prestati njezinom krivnjom ili sporazumom. Stopa nezaposlenosti realno prikazuje stvarno stanje gospodarstva, a predstavlja omjer broja nezaposlenih i ukupno raspoložive radne snage i izražava se u postocima. Ukupna se populacija temelji na de facto definiciji stanovništva, koja broji sve stanovnike bez obzira na pravni status ili državljanstvo.

U istraživanjima u kojima se analizira utjecaj različitih čimbenika na razvoj gospodarstva, uključene su varijable kao što su inozemna izravna ulaganja (FDI), ka-open indeks, Ginijev koeficijent, sukobi i katastrofe. S obzirom da se u ovom istraživanju većina tih varijabli neće

koristiti, njihova dodatna objašnjena neće biti potrebna. Varijabla sukobi (kasnije u istraživanju će se nazivati incidenti) se odnosi na društvene pojave kao što su teroristički napadi, točnije ukupan broj terorističkih napada, a podaci o njima su prikupljeni iz referentne baze podataka Global Terrorism Database. Najčešće korištena mjera je broj terorističkih incidenata u jednoj zemlji na godišnjoj razini. Jedna od kritika ove mjere jest da ignorira informacije s obzirom na intenzitet incidenata (broj poginulih ili ozlijeđenih), što bi značilo da napadi koji su bili usmjereni na objekte u kojima nitko nije ozlijeđen ili ubijen bi prenjeli iste rezultate kao i oni incidenti s desecima žrtava (Filer i Stanišić, 2013). Brojna empirijska istraživanja ističu da incidenti uvode poremećaje u gospodarstvu, izravno djelujući na investicije. Provedena istraživanja uključuju broj terorističkih incidenata i/ili žrtve terorizma kao nezavisne varijable modela, te općenito potvrđuju negativan utjecaj terorizma na izravna strana ulaganja (FDI) i kapitalne tokove, no u ovom istraživanju fokus će biti na incidentima i njihovom utjecaju na BDP.

5. STATISTIČKA ANALIZA UTJECAJA ORUŽANIH SUKOBA NA GOSPODARSTVO

5.1. Odabir modela i opis varijabli

U ovom dijelu rada će se na temelju Arellano-Bond (1991) generalizirane metode momenata (engl. Generalized Method of Moments – GMM) procijeniti dinamički panel model. Panel podaci omogućuju empirijsku analizu čiji rezultati ne bi bili mogući upotrebom samo prostorne ili vremenske dimenzije. Dinamički panel modeli imaju širu ekonomsku primjenu od statičkih panel modela jer čak i kada koeficijenti lagirane zavisne varijable nisu od izravnog interesa, omogućavanje dinamike može biti ključno za procjenu ostalih parametara. Škrabić Perić (2012) tvrdi da dinamički panel modeli sadržavaju zavisnu varijablu s pomakom za jedan ili više vremenskih perioda unatrag ovisno o svojstvima zavisne varijable. Panel podaci omogućavaju definiranje i testiranje kompliciranijih ekonometrijskih modela, te umanjuju problem multikolinearnosti. Oni moraju biti homogeni, tj. jedinice promatranja moraju imati zajednička svojstva. Ukoliko taj uvjet nije ispunjen rezultati analize neće biti relevantni, odnosno niti jedna varijabla neće biti statistički značajna. Također, relacije korištenih varijabli su dinamičke prirode, odnosno njihova sadašnja vrijednost ovisi o prethodnim vrijednostima te varijable. Ovaj je procjenitelj primjeren za procjenu podataka s velikim brojem jedinica promatranja i relativno malim brojem razdoblja.

Podaci sadrže prostornu (eng. cross-sectional data) i vremensku komponentu (eng. time-series), zbog čega panel analiza omogućuje veći broj opservacija. Panel modelima može se procijeniti utjecaj jedne ili više varijabli na promatranu zavisnu varijablu (u ovom slučaju su dvije, budući da su takve hipoteze). Za razliku od višestruke regresije, kod panel analize zavisna varijabla mijenja se i po jedinicama promatranja, ali i vremenski. Zbog toga se procjene varijabli koje determiniraju zavisnu varijablu smatraju preciznijima.

Kao instrumentalna varijabla u ovom modelu će se koristit lagirana vrijednost zavisne varijable s jednim vremenskim pomakom unatrag. Varijable koje će biti uključene u dinamičku panel analizu su delta BDP, delta BDP s vremenskim pomakom (lagirana), incidenti (ranije u tekstu navedeni kao sukobi) i HDI indeks. Važno je napomenuti kako su podaci za pojedine varijable dostupni do 2015. godine, kao što je HDI indeks, stoga će ovo istraživanje obuhvaćati vremenski period od 15 godina, odnosno do posljednjih dostupnih podataka. Prilikom prikupljanja podataka za analizu, različite varijable su istaknute u teoriji

kao što su inozemna izravna ulaganja (FDI), Ginijev koeficijent, ka_open index, mortalitet, migracije i druge, no zbog nestabilnosti modela nisu uključene u analizu, odnosno u finalni model. U tablici 1 nalazi se opis varijabli koje će biti korištene u analizi.

Tablica 1: Opis varijabli i izvori podataka

Varijabla	Opis varijabli	Izvor
bdp	Aposlutna promjena BDP-a u pojedinoj zemlji	United Nations conference on trade and development
delta bdp L1.	Apsolutna promjena BDP-a s pomakom	Izračun autora
incidenti	Teroristički napadi	Global Terrorism Database
hdi indeks	Indeks ljudskog razvoja	Human Development Indeks stranica

Izvor: Izračun autora

U tablici 2 nalaze se rezultati deskriptivne statistike koja se bavi uređivanjem prikupljenih podataka, njihovim grafičkim prikazivanjem i opisivanjem pomoću numeričkih vrijednosti kao što su prosjek, standardna devijacija, korelacija itd.

Tablica 2: Deskriptivna statistika

Variable		Mean	Stand. Dev.	Min	Max	Observations	
deltabdp	overall	394.8691	1246.986	-7122.256	13532.67	N=	420
	between		333.7865	-84.94958	1653.131	n=	28
	within		1203.031	-7706.538	12274.41	T=	15
incidenti	overall	5.683036	16.125	0	137	N=	448
	between		11.48333	0	47.75	n=	28
	within		11.51407	-37.06696	94.93304	T=	16
hdi indeks	overall	0.8467723	0.0458359	0.708	0.926	N=	448
	between		0.0417111	0.7599375	0.9039375	n=	28
	within		0.0204815	0.7751473	0.8867723	T=	16

Izvor: Izračun autora

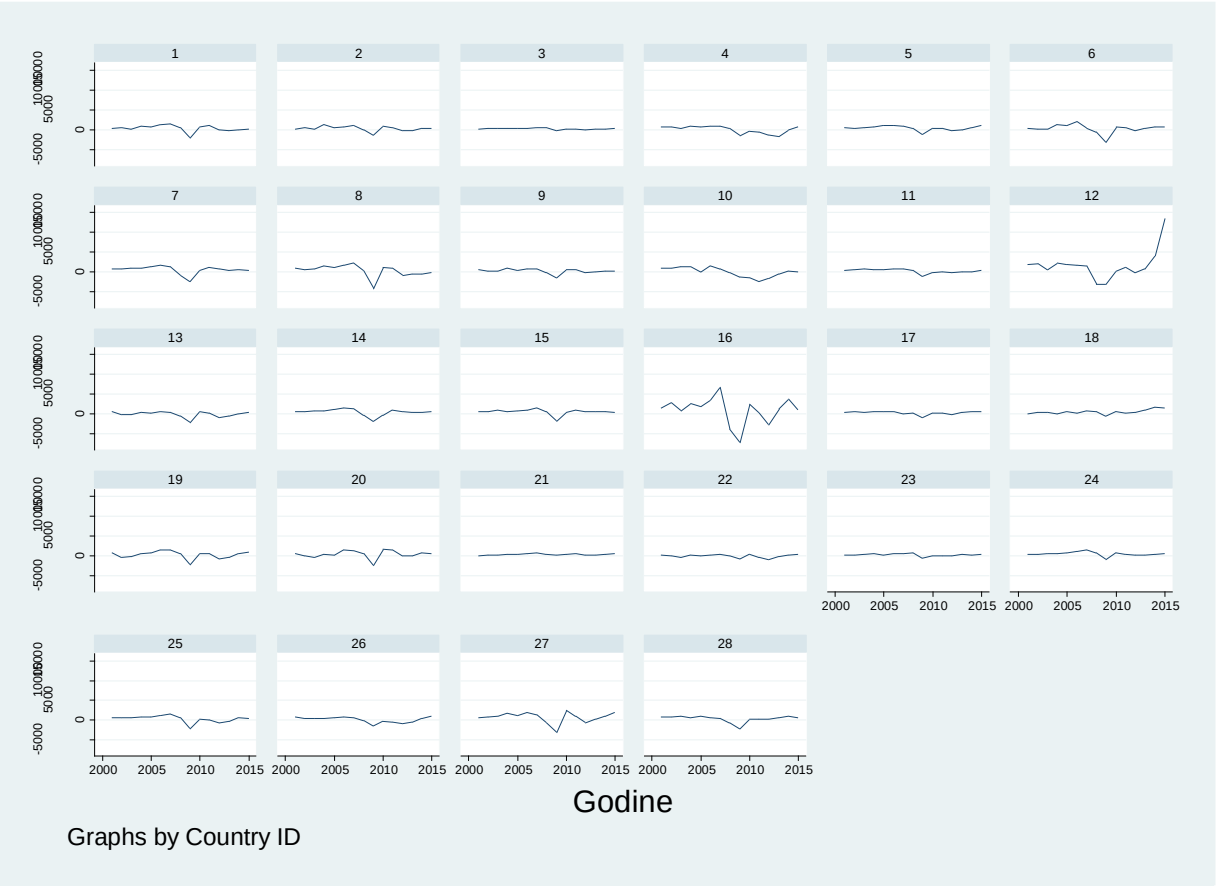
Iz prikazanih rezultata dolazimo do zaključka kako prosječni apsolutni porast BDP-a u u Europskoj uniji tijekom 15 godina iznosi 394,86 milijuna dolara godišnje uz prosječno odstupanje države članice od 333,78 milijuna dolara u odnosu na prosjek, dok 1203,03 milijuna dolara predstavlja prosječno odstupanje apsolutnog rasta BDP-a EU u odnosu na prosjek.

Prosječni broj incidenata unutar Europske unije tijekom 15 godina iznosi 5,68 incidenata godišnje uz prosječno odstupanje države članice od 11,48 incidenata u odnosu na prosjek, dok 11,514 incidenata predstavlja prosječno odstupanje broja godišnjih incidenata u EU promatranog raszoblja u odnosu na prosjek. Najveći broj incidenata tijekom 1 godine u 1 jednoj zemlji je bio 137 u Ujedinjenom Kraljevstvu u 2013. godini, dok je maksimalni prosječni broj incidenata po državi članici iznosio 47,97 incidenata, a maksimalni prosječni godišnji broj incidenata u cijeloj EU iznosi 94,33 incidenta.

Prosječni HDI indeks u EU tijekom 15 godina iznosi 0,846 godišnje uz prosječno odstupanje države članice od 0,04 u odnosu na prosjek, dok je 0,02 prosječno odstupanje broja incidenata svake godine promatranog razdoblja u odnosu na prosjek.

Prije rezultata samog istraživanja prikazat će se grafikoni s vrijednostima varijabli korištenih u radu kako bi se situacija unutar zemalja članica podrobnije analizirala i što bolje prikazala, a vrijednosti pokazatelja prikupljene putem Interneta nalaze se u prilogu na kraju rada. Podaci za BDP prikupljeni su sa United Nations conference on trade and development (UNCTADSTAT) stranice na kojoj se nalazi više od 150 indikatora i statističkih vremenskih serija bitnih za analizu međunarodne trgovine, ekonomskih trendova, izravnih stranih ulaganja itd., dok su podaci za sukobe preuzeti sa The Global Terrorism Database (GTD) stranice koja predstavlja otvorenu bazu podataka o terorističkim događajima diljem svijeta od 1970. do 2017. godine. Podaci za HDI indeks prikupljeni su sa Human Development Index stranice kojoj je cilj pomaknuti fokus na ekonomije u razvoju, te kako bi se naglasilo da ljudi i njihove sposobnosti trebaju biti konačni kriteriji za procjenu razvoja zemlje, a ne samog gospodarskog rasta.

S obzirom da je u analizi zavisna varijabla delta BDP, na grafu 1 će se prikazati njeno kretanje kroz razdoblje od 15 godina za svih 28 zemalja članica.

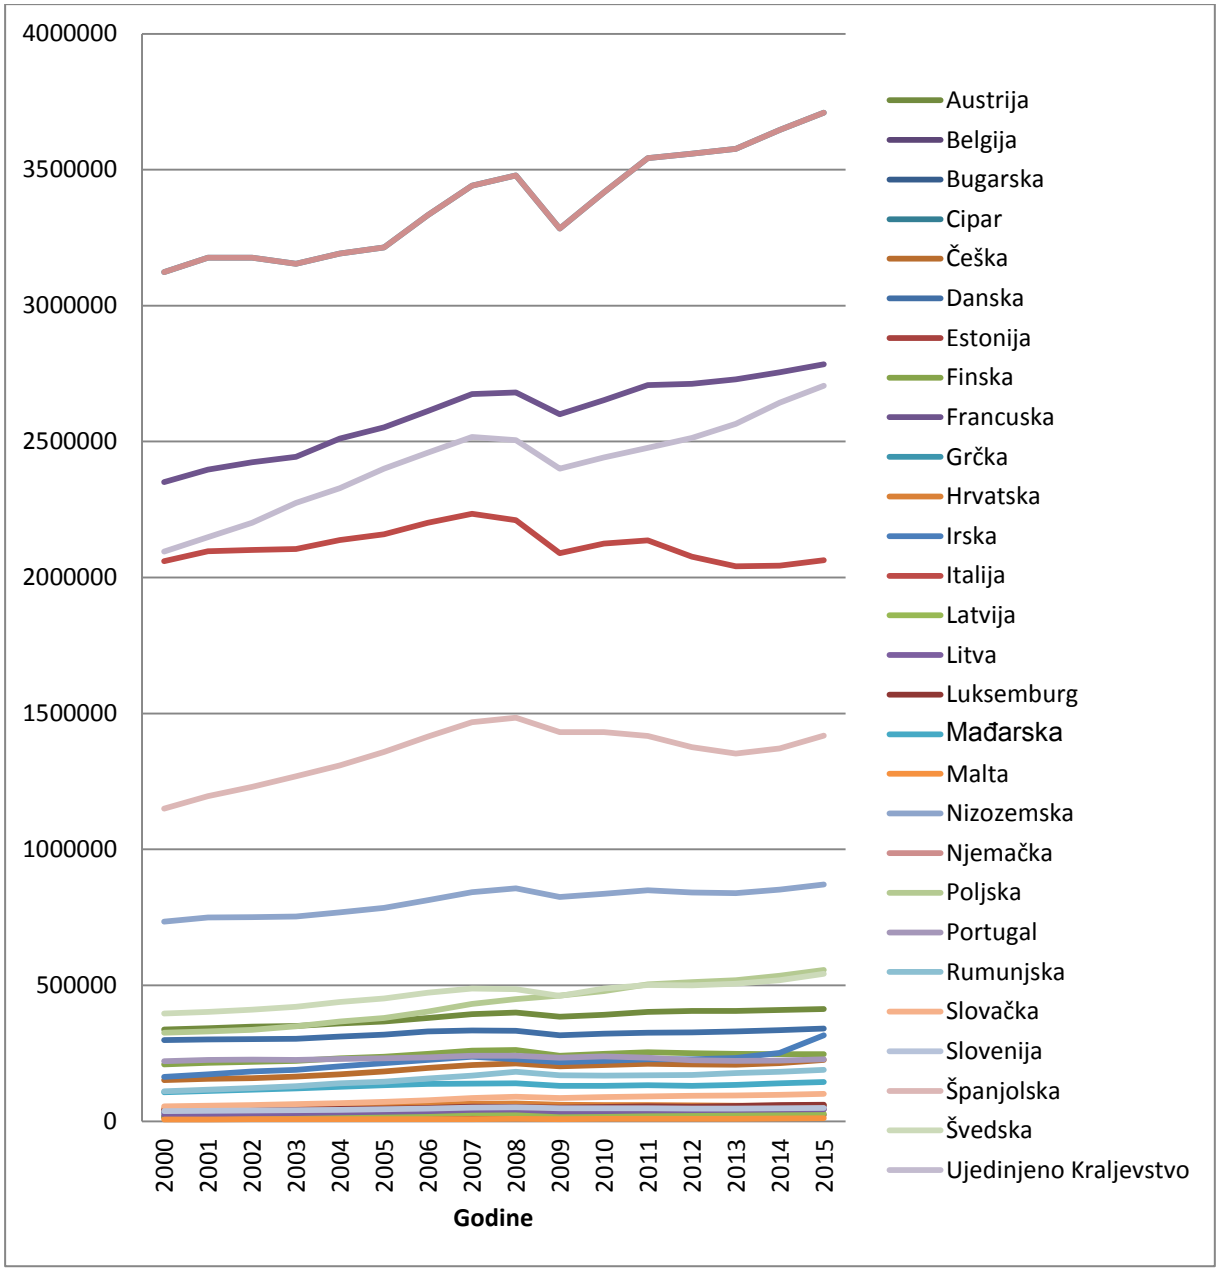


Graf 1: Prikaz delta BDP-a za 28 zemalja Europske unije

Izvor: Izračun autora

Grafički prikazi napravljeni su u programu STATA i sadrže podatke o delta BDP-u za svih 28 članica Europske unije tijekom promatranog razdoblja od 15 godina. Na većini grafova je vidljivo da dolazi do promjene, točnije do pada BDP-a što se odražava na smjer kretanja prikazane linije. Pad se događa u svim zemljama u isto vrijeme i to između 2008. i 2009. godine, a najveći pad vidljiv je u 16. grafu na kojemu se nalaze podaci za Luksemburg. To je država koja bilježi brz rast i razvoj gospodarstva, no s obziromda je osjetila jak utjecaj krize na gospodarstvo, iz grafa je vidljivo da se situacija relativno brzo stabilizirala. Godina 2008. obilježava početak financijske krize kako u svijetu, tako i u Europi. Društveni proizvod se smanjuje, profiti i realni dohoci padaju, a nezaposlenost raste po višim stopama. Neposredan pokretač krize bio je slom tržišta drugorazrednih hipoteka u SAD-u, a intervencijama nacionalnih država, najprije u financijskom, a nedugo zatim i u realnom sektoru, zaustavljen je daljnji pad gospodarske aktivnosti, te nakon silazne faze započinje oporavak gospodarstva

koji može biti sporiji ili brži, nepotpun ili ipak može dovesti određeno gospodarstvo do novog ekonomskog poleta.

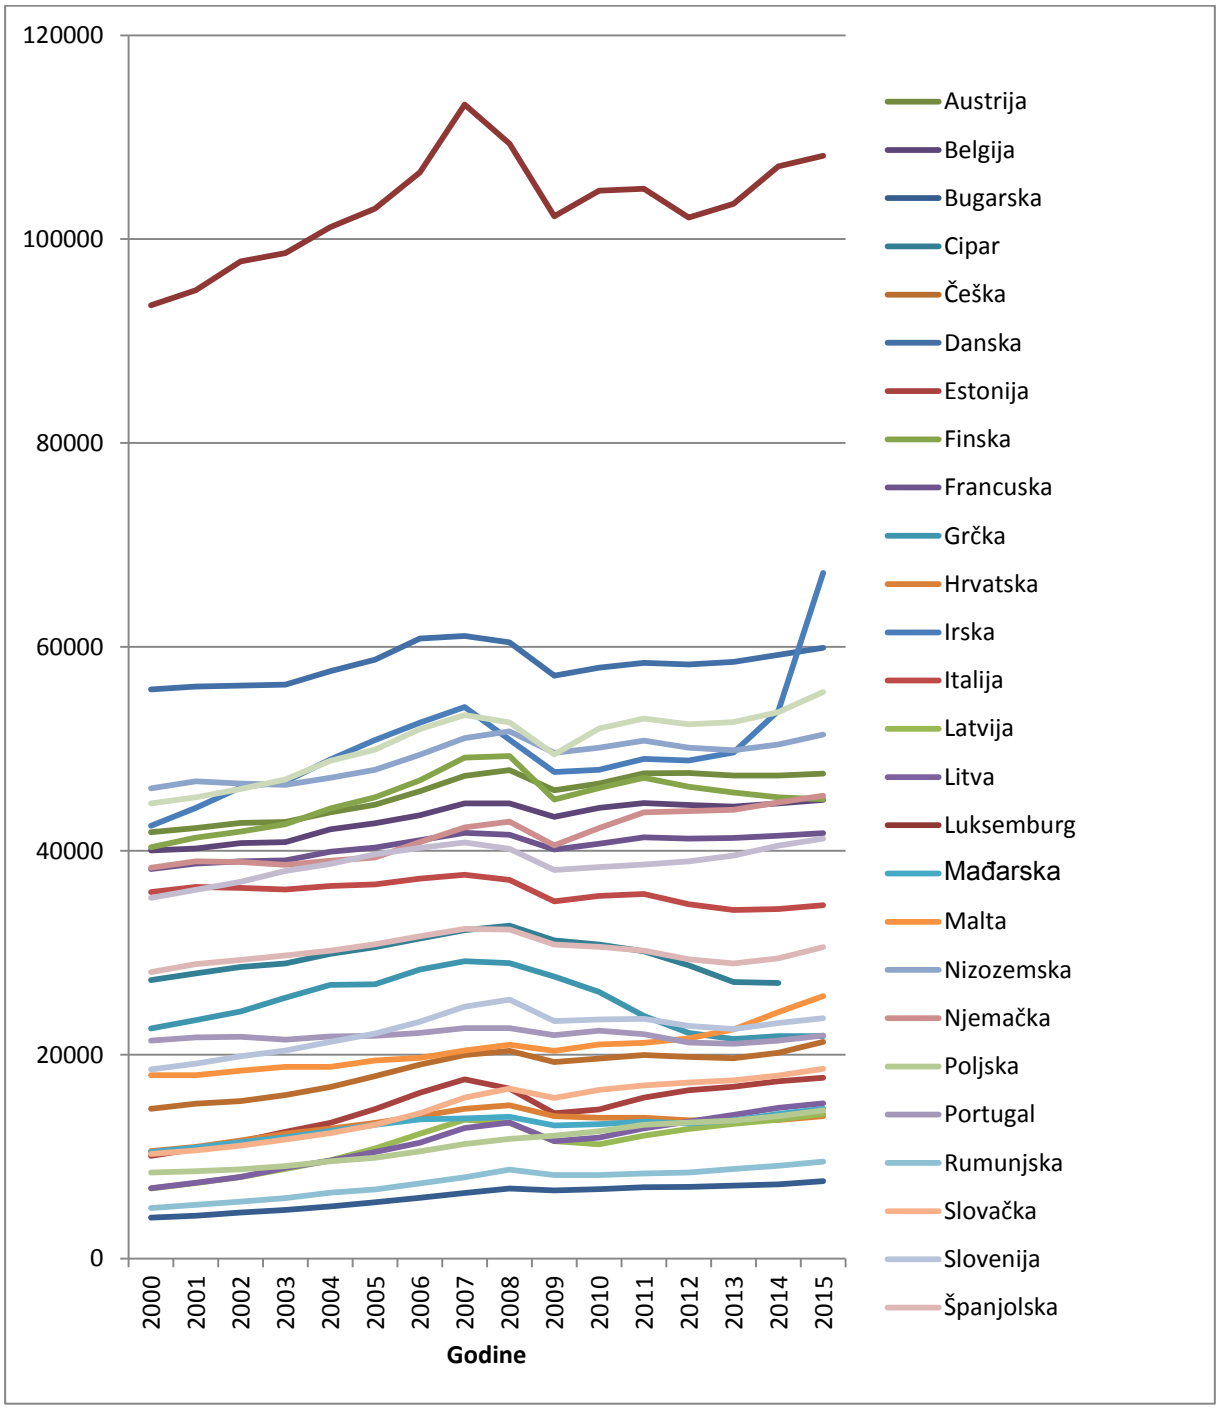


Graf 2: Kretanje BDP-a u zemljama članicama Europske unije

Izvor: Izračun autora

Iz prikupljenih podataka s United Nations conference on trade and development (UNCTADSTAT) stranice vidljivo je da najmanji BDP izražen u dolarima u prosjeku ima Malta u iznosu od 8.492,76 milijuna dolara, dok najveći ima Grčka u iznosu sa 3.376.517,00

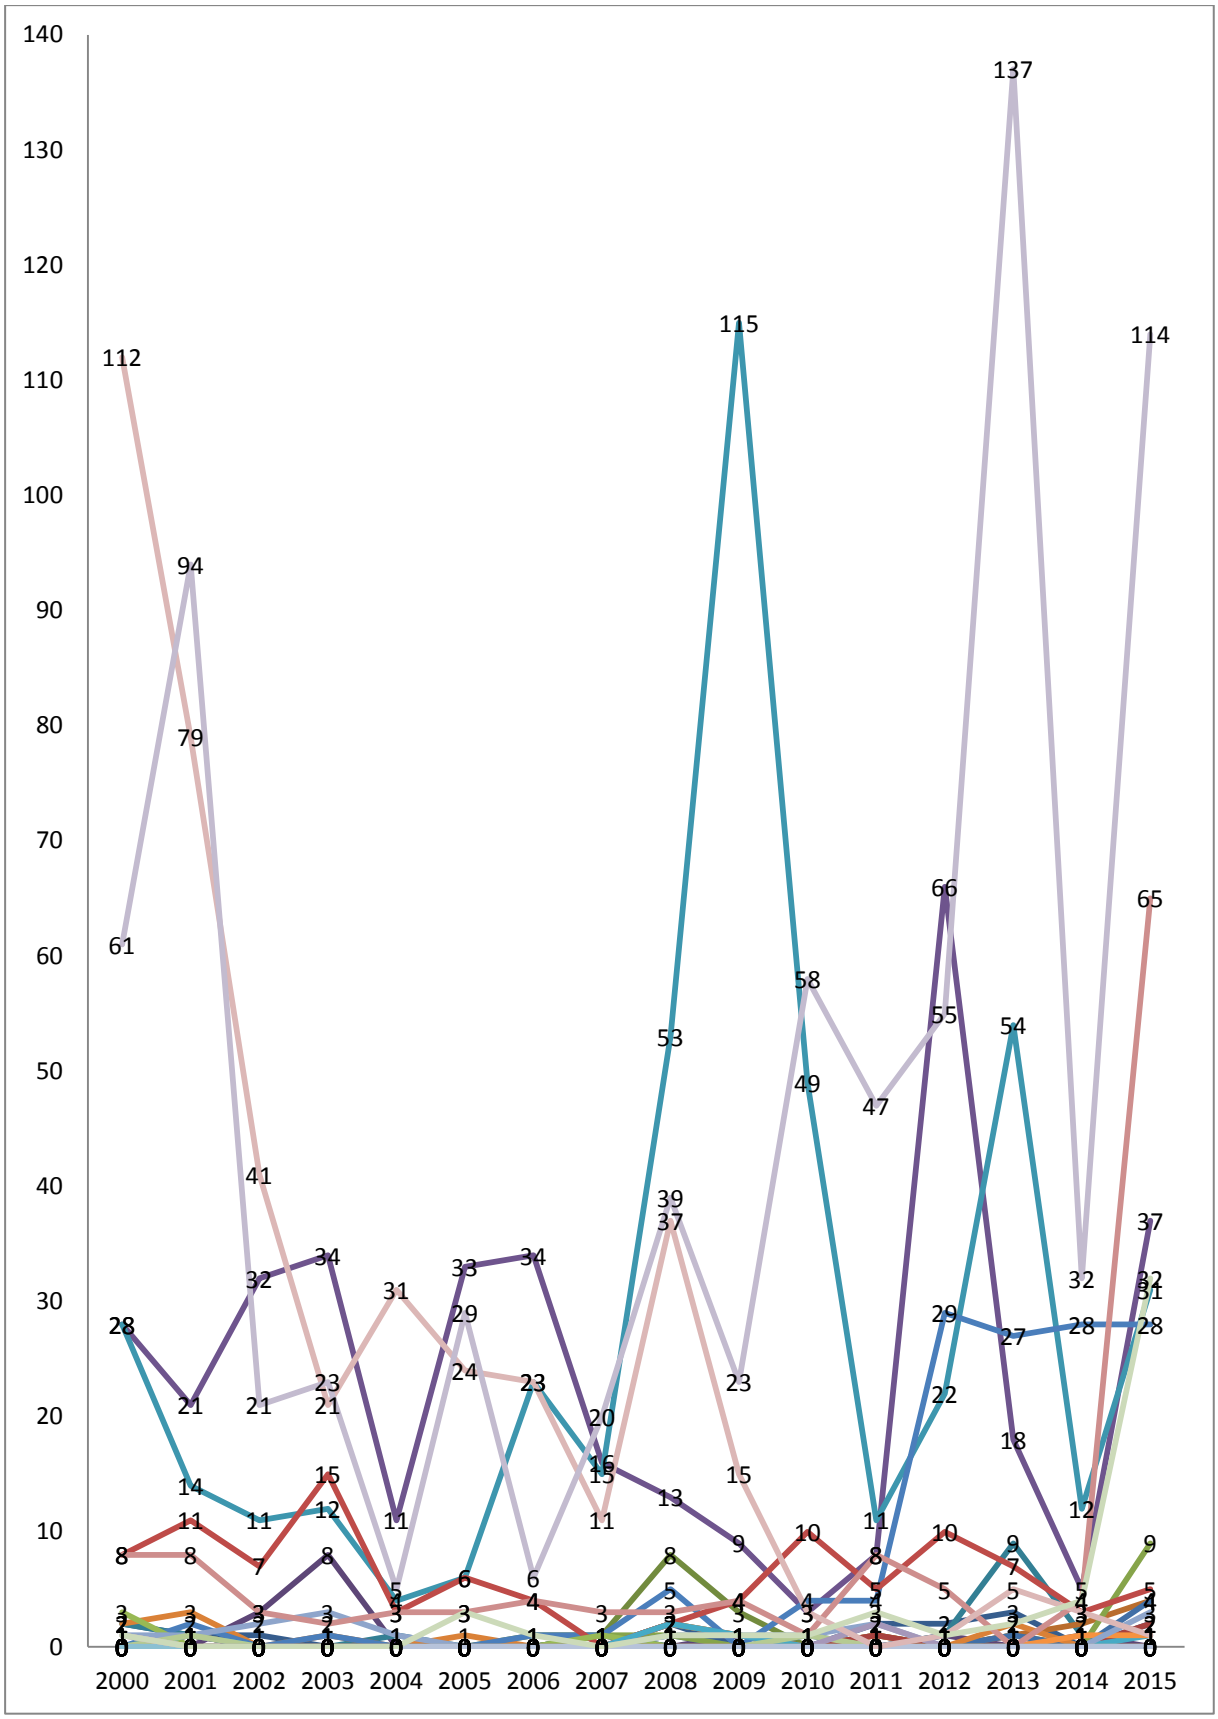
milijuna dolara. Veći bruto domaći proizvod neke zemlje predstavlja veću gospodarsku aktivnost te zemlje, no dakako, veći bruto domaći proizvod ne znači po sebi i veću kvalitetu življenja stanovništva neke zemlje, odnosno države. Detaljniji uvid u gospodarstvo neke zemlje pruža graf 3 na kojemu je prikazano kretanje BDP-a po glavi stanovnika.



Graf 3: Prikaz BDP-a po glavi stanovnika u Europskoj uniji

Izvor: Izračun autora

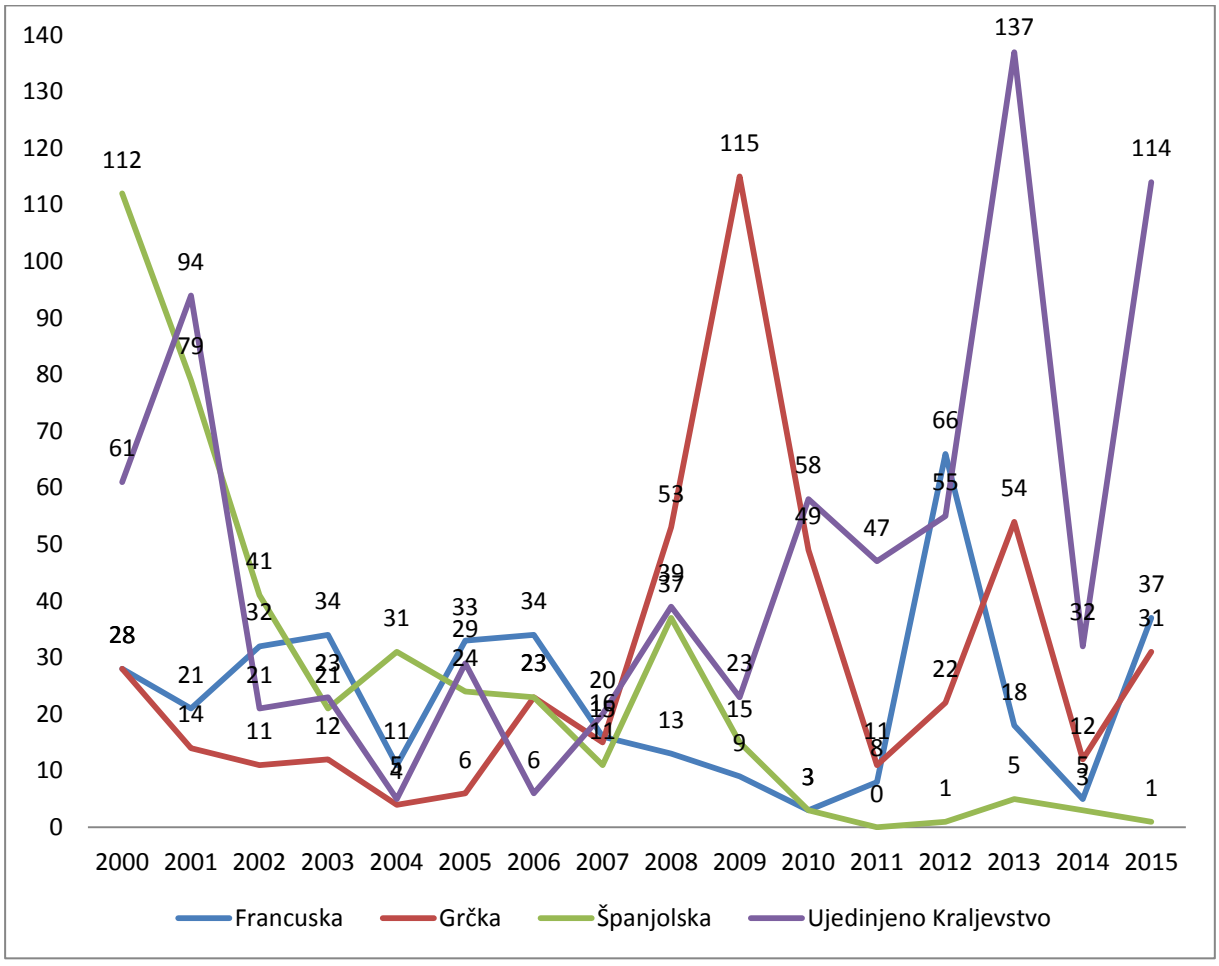
Najmanji BDP po glavi stanovnika ima Bugarska sa 6.078,48 dolara, dok najviši ima Luksemburg sa 103.194,70 dolara po stanovniku. BDP po stanovniku ponekad se koristi kao pokazatelj životnog standarda, što bi značilo da zemlje s višim BDP-om po stanovniku imaju viši životni standard. Također se može koristiti za mjerenje produktivnosti radne snage zemlje jer mjeri ukupnu proizvodnju dobara i usluga po svakom članu radne snage u određenoj zemlji.



Graf 4: Prikaz sukoba u Europskoj uniji

Izvor: Izračun autora

Iz grafičkog prikaza sukoba (koji predstavljaju ukupan broj terorističkih napada, a podaci o njima su prikupljeni iz referentne baze podataka Global Terrorism Database. Najčešće korištena mjera je broj terorističkih incidenata u jednoj zemlji na godišnjoj razini) možemo zaključiti kako se najveći broj sukoba događao u Ujedinjenom Kraljevstvu, Grčkoj, Francuskoj i Španjolskoj. Najmanji broj oružanih sukoba, točnije nijedan oružani sukob kroz posljednjih 15 godina imale su Litva, Luksemburg i Rumunjska, dok se najveći broj, u prosjeku 48 oružanih sukoba (47,75), dogodio u Ujedinjenom Kraljevstvu od 2000. do 2015. godine.



Graf 5: Prikaz sukoba u Francuskoj, Grčkoj, Španjolskoj i Ujedinjenom Kraljevstvu

Izvor: Izračun autora

Najveći broj sukoba dogodio se u Ujedinjenom Kraljevstvu 2013. godine i to čak 137 sukoba. Slijedi ga Grčka sa 115 napada 2013. godine, potom Španjolska sa 112 napada 2000. godine,

te na kraju Francuska sa 66 sukoba 2012. godine. Rastući tren sukoba ima jedino Ujedinjeno Kraljevstvo, dok je opadajući tren vidljiv u Španjolskoj. Može se primjetiti kako se broj sukoba smanjio između 2003. i 2005. godine u većini zemalja, no nagli porast je vidljiv u Grčkoj i Ujedinjenom Kraljevstvu nakon 2007. godine, dok je postupni pad vidljiv u Španjolskoj.

5.2. Rezultati empirijske analize

Varijable koje će biti uključene u dinamičku panel analizu su delta BDP, delta BDP s vremenskim pomakom (lagirana), incidenti (ranije u tekstu navedeni kao sukobi) i HDI indeks. Istraživanje će obuhvaćati razdoblje od 2000. do 2015. godine, odnosno do posljednjih dostupnih podataka. Dinamički model s jednom vremenom pomaknutom (lagiranom) varijablom može se prikazati uz pomoć sljedeće jednadžbe:

$$y_{it} = \beta y_{t-1} + u_i + v_{it,} \; |\beta| < 1$$

gdje je y_{it} vrijednost zavisne varijable u razdoblju t; y_{t-1} je zavisna varijabla s vremenskim pomakom za jedno razdoblje; u_i su pojedinačni vremenski nepromjenjivi učinci, a v_{it} je slučajna pogreška.

Ova jednadžba može biti zapisana i u ekonometrijskom obliku:

$$\Delta BDP_{it} = \beta_1 \Delta BDP(-1)_{i(t-1)} + \beta_2 Incidenti_{it} + \beta_3 HDI\ indeks_{it} + \sum_{t=2002}^{2015} godina_t + u_{it} + v_{it}$$

pri čemu ΔBDP_{it} označava apsolutnu promjenu BDP-a tj. zavisnu varijablu, $\Delta BDP(-1)_{i(t-1)}$ označava apsolutnu promjenu BDP-a, odnosno nezavisnu varijablu s vremenskim pomakom unatrag za jedno razdoblje (godinu), a incidenti i HDI indeks označavaju nezavisne varijable.

U nastavku slijedi tablica 3 s prikazom rezultata panel analize i njihovim objašnjenjima.

Tablica 3: Rezultati panel analize za EU-28 od 2000. do 2015. godine

	(1)
	deltabdp
L. deltabdp	0.409***
	(0,001)
incidenti	5.397***
	(0.733)
hdiindeks	836.474***
	(8.885)
N	392
r2	

Standard errors in parentheses

*p<0.10, **p<0.05, ***p<0.01

Izvor: Izračun autora

Iako promatramo period od 2000. do 2015. godine, u analizi koristimo lagiranu (s vremenskim pomakom) varijablu delta BDP, stoga se pri izračunu uzima u obzir prošlo razdoblje (t-1; podaci za 1999. godinu nisu korišteni u analizi zbog čega podaci za 2000. godinu ne mogu biti izračunati). U tablici 3 je vidljivo da su u procijenjenom modelu sve nezavisne varijable statistički značajne jer su im empirijske razine signifikantnosti manje od 0,05 i iznose približno 0, što vrijedi i za apsolutnu promjenu BDP-a s pomakom.

Koeficijent uz apsolutnu promjenu BDP-a s pomakom je statistički značajan jer mu je empirijska razina signifikantnosti manja od 0,05 tj. približna je 0. Koeficijent je i pozitivan što je i očekivani rezultat jer BDP iz prethodnog razdoblja pozitivno utječe na zavisnu varijablu.

Koeficijent uz broj incidenata je pozitivan i pokazuje da bi se apsolutni rast BDP-a povećao za 5,39 milijuna dolara ukoliko bi se broj incidenata povećao za jednu jedinicu uz uvjet da ostale varijable ostanu nepromijenjene.

Koeficijent uz HDI indeks je također pozitivan i statistički signifikantan na razini od 1% i pokazuje da bi se apsolutni rast BDP-a povećao za 8,36 milijuna dolara ukoliko bi se HDI indeks povećao za jednu jedinicu uz uvjet da ostale varijable ostanu nepromijenjene.

Valjanost instrumenata korištenih u procjeni modela testirali smo Sarganovim testom (Tablica 4) koji se temelji na pretpostavci da bi reziduali trebali bit nekorelirani sa skupom egzogenih varijabli, u slučaju da se zaista radi o egzogenim instrumentima (pored Sarganovog testa provodi se i testiranje autokorelacije u rezidualima, pomoću testova m_1 i m_2). Zbog toga je je poželjno prihvaćanje nulte hipoteze koja kaže da su odabrane instrumentalne varijable nekorelirane s rezidualima. Odbijanje nulte hipoteze značilo bi da u modelu postoji problem endogenosti. Zbog toga je važan i odabir optimalnog broja instrumenata kako bi se prihvatila nulta hipoteza Sarganovog testa, a da se usto vrijeme ne poveća značajno pristranost procjenitelja. Ovo upućuje na zaključak da u ovom modelu oružani sukobi imaju pozitivan utjecaj na promjenu BDP-a.

Tablica 4: : Sargan test analize utjecaja broja incidenata i HDI indeksa na rast BDP-a

```
Sargan test of overidentifying restrictions
        H0: overidentifying restrictions are valid

        chi2(25)     =  25.93009
        Prob > chi2  =    0.4113
```

Izvor: Izračun autora

Sarganovim testom se testira nulta hipoteza prema kojoj se pretpostavlja valjanost instrumentalnih varijabli. U ovom slučaju testna veličina je hi-kvadrat vrijednost 25,93009 dok je pripadajuća empirijska razina signifikantnosti 0,4113. Dakle veća od 0.05, odnosno od uobičajene razine signifikantnosti, nulta hipoteza o valjanosti instrumentalnih varijabli se prihvaća što znači da je model prikladan. U tablici 5 nalaze se rezultati Arellano-Bond testa.

Tablica 5: Arrelando – Bond test autokorelacije analize utjecaja broja incidenata i HDI indeksa na promjenu BDP-a

```
Arellano-Bond test for zero autocorrelation in first-differenced errors
```

Order	z	Prob > z
1	-2.3354	0.0195
2	-1.512	0.1305

```
H0: no autocorrelation
```

Izvor: Izračun autora

Arellando - Bond testovi za autokorelaciju prvog reda pokazali su kako je vrijednost $m_1$testa je iznosila 0,0195 i manja od uobičajene razine signifikantnosti 0,05 zbog čega se nulta hipoteza odbacuje, što znači da u ovom modelu postoji autokorelacija reziduala prvog reda. No, budući da se među prvim diferencijama reziduala očekuje postojanje autokorelacije prvog reda, njezino se postojanje najčešće zanemaruje.

Naime, unatoč postojanju autokorelacije prvog reda među prvim diferencijama reziduala procjene parametara su konzistentne. No, ako postoji i autokorelacija drugog reda među prvim diferencijama reziduala, procjene parametara su nekonzistentne. U ovom slučaju, u m_2 testu, empirijska razina signifikantnosti je iznosila 0,1305 i veća je od 0,05, te se prihvaća nulta hipoteza o nepostojanju autokorelacije drugog reda. Budući da se autokorelacija u prvom redu može zanemariti, izabrani model s pripadajućim varijablama je prikladan i valjan za statističku analizu.

5.2.1. Prihvaćanje ili odbijanje hipoteza

Na početku rada postavljene su dvije hipoteze od kojih bi prva trebala ukazati na negativan utjecaj oružanih sukoba na kretanje BDP-a. Svi pokazatelji između incidenata i BDP-a su statistički značajni stoga se ova hipoteza odbija. To znači da s porastom incidenata tj. oružanih sukoba BDP će rasti jer će se više angažirati policija i vojska da bi se zaštitilo stanovništvo, a proizvodnja će biti usmjerena na potrebe vojske stoga će se proizvoditi više vojne odjeće i opreme.

Druga hipoteza tvrdi da su zemlje s višim HDI indeksom manje izložene oružanim sukobima, ali zbog statističke značajnosti pokazatelja incidenti i HDI indeksa, ova hipoteza se također odbija. HDI indeks prikazuje razvijenost zemalja u odnosu na životni vijek stanovništva, pismenost i standard života, a prema prikupljenim podacima može se zaključiti kako većina zemalja članica Europske unije spada u vrlo razvijene zemlje svijeta. S obzirom na provedenu analizu i konačne rezultate, vidljivo je da će razvijenije zemlje biti više izložene oružanim sukobima. Proučavajući trend kretanja incidenata, vidljivo je da se posljednjih godina sve više incidenata javlja u razvijenijim zemljama kao što je Ujedinjeno Kraljevstvo, Francuska i slične zemlje.

6. ZAKLJUČAK

Proučavajući povijest zemalja Europske unije, može se zaključiti kako s razvojem stanovništva dolazi i do pojave oružanih sukoba. Prvotno su se javili zbog potrebe za prevlašću nad hranom ili vodom, no kasnije oni prerastaju u ratove zbog želje za oduzimanjem teritorija i širenjem granica vlastite države. S vremenom su ratovi imali sve veći utjecaj na razvoj gospodarstva zemalja, no s pojavom globalizacije oružani sukobi gube na značaju.

Analizirajući zemlje Europske unije kroz vremenski raspon od 15 godina, vidljivo je da svaka zemlja ima određene periode pada i rasta gospodarstva. U promatranom razdoblju dolazi do pojave kako ekonomske krize, tako i povećanog broja incidenata, odnosno terorističkih napada. Sama pojava krize iz 2008. godine potresla je SAD, što se kasnije osjetilo i u ostatku svijeta, a najveći utjecaj imala je na pad potrošnje, proizvodnje i opsega trgovine, uzrokujući rast nezaposlenosti. Već krajem 2008. godine dolazi do smanjenja industrijske proizvodnje i opsega trgovine, a takvi se trendovi u 2009. godini dodatno zaoštravaju. Razvijene zemlje suočene su s recesijom, a zemlje u razvoju s znatnim usporavanjem gospodarskog rasta. No, s vremenom su se zemlje Europske unije uspjele izvući iz krize i nastavile su razvijati svoja gospodarstva. Iako su se posljedice ekonomske krize kroz godine osjećale, ali sve manje i manje, počeo se javljati sve veći broj oružanih sukoba, a najveći broj zabilježen je u Ujedinjenom Kraljevstvu, potom u Grčkoj, Španjolskoj i Francuskoj.

Na početku rada postavljene su dvije hipoteze koje su u konačnici odbačene, a analiza se provodila uz pomoć generalizirane metode momenata (GMM). To je je generička metoda za procjenu parametara u statističkim modelima, a panel podaci omogućuju empirijsku analizu čiji rezultati ne bi bili mogući upotrebom samo prostorne ili vremenske dimenzije. Dinamički panel modeli sadržavaju zavisnu varijablu s pomakom za jedan ili više vremenskih perioda unatrag ovisno o svojstvima zavisne varijable, a u ovom modelu zavisna varijabla je delta BDP s vremenskim pomakom (lagirana), dok su nezavisne varijable delta BDP, incidenti i HDI indeks. Na temelju dobivenih rezultata analize može se zaključiti da pojava oružanih sukoba sa sobom donosi mnoge probleme kao što su ljudske žrtve, promjene granica, političke promjene i mnoge druge, ali što je zemlja razvijenija, postoji veća mogućnost da će se u njoj javiti oružani sukobi, a s rastom oružanih sukoba rasti će i BDP.

SAŽETAK

Nemiri, sukobi, ratovi i terorizam javljaju se u svijetu još od davnina. U prvobitnoj zajednici sukobi između plemena javljali su se zbog potrebe za hranom, vodom ili skloništem, no s razvojem društva sukobi prerastaju u ratove jer se ljudi bore s vanjskim neprijateljima ili pokušavaju ovladati otporom unutar države. U posljednje vrijeme posebna pozornost se pridaje terorizmu zbog čega određeni pojedinci ili skupine pojedinaca pokušavaju nasiljem postići različite političke ili društvene ciljeve. Cilj ovog rada je objasniti kako oružani sukobi utječu na gospodarstva zemalja članica Europske unije. Provedena je analiza na 28 zemalja članica Europske unije u razdoblju od 2000. do 2015. godine uz pomoć generalizirane metode momenata (GMM) i dinamičkih panela. Dinamički panel modeli sadržavaju zavisnu varijablu s pomakom za jedan ili više vremenskih perioda unatrag ovisno o svojstvima zavisne varijable. Testiranje hipoteza je potvrdilo kako rast oružanih sukoba utječe na rast BDP-a, te da u razvijenijim zemljama postoji veća mogućnost od njihovog izbijanja. Oružani sukobi ostavljaju razne posljedice kao što su ljudske žrtve, promjene granica i političke promjene. Uzroci njihovog izbijanja su želja za prevlašću, rušenje tržišne pozicije, porast vojne snage i drugi, ali su uglavnom ekonomske ili religijske prirode. Činjenica je da se pojavljivanje oružanih sukoba nikad neće moći spriječiti, no od svih negativnosti koje nose sa sobom, čini se da u konačnici utječu na razvoj gospodarstva.

Ključne riječi: *oružani sukobi, gospodarstvo, Europska unija, Generalizirana metoda momenata (GMM), dinamički panel.*

SUMMARY

Turmoil, conflicts, wars and terrorism have appeared in the world since ancient times. In the original community, conflicts between the tribes appeared due to the need for food, water, or shelter. With the development of society, conflicts evolved into wars because people were struggling with external enemies or they were trying to master the resistance within the state. . Recently, special attention is dedicated to terrorism, which is why certain individuals or groups of individuals are trying to achieve political and social goals by violence. The aim of this paper is to explain how armed conflicts affect countries economy in The European Union. An analysis was carried out in 28 EU member states over the period from 2000 to 2015 with the help of the Generalized Method of Moments (GMM) and dynamic panels. Dynamic panel models contain a dependency variable with a lag for one or more reverse periods depending on the properties of the dependent variable. Tested hypothesis have confirmed that the growth of armed conflicts affects GDP growth and that in more developed countries there is a greater possibility of their outbreak. Armed conflicts leave various consequences such as human sacrifices, change of borders, and political change. The causes of their outbursts are desire to dominate, deterioration of the market position, increase of military power and others. But mainly reasons are economic or religious nature. The fact is that the emergence of armed conflicts will never be prevented, but all the negativities they come with, it seems they ultimately affect on development of the economy.

Keywords: *conflict, economy, EuropeanUnion, Generalized Method of Moments, dynamic panel.*

LITERATURA

1. Abadie, G. i Gardeazabal, J., 2003. The economic costs of conflicts: A case study of the basque country, The American Economic Review, Vol. 93 (1), str. 113–132. Dostupno na: http://www.nyu.edu/gsas/dept/politics/faculty/beck/abadie_aer.pdf [pristupljeno 25.07.2018.].
2. Andrijević, B., 1997. Terorizam kao globalni problem svih turističkih razvijenih područja. Faculty of Economics and Business, University of Zagreb, Vol. 9 (2), str. 109-135. Dostupno na: https://www.jstor.org/stable/23233146 [pristupljeno 07.08.2018.].
3. Arellano, M. i Bond, S., 1991. Some test of specification for Panel data, Monte Carlo Evidence and Application to Employment Equations. Review of Economic Studies, 58(2), pp. 277-297. Dostupno na: https://doi.org/10.2307/2297968 [pristupljeno 21.09.2018.].
4. Bandyopadhyay, S., Sandler, T. i Younas, J., 2011. Foreign Direct Investment, Aid, and Terrorism: An Analysis of Developing Countries. Federal Reserve Bank of St. Louis. Dostupno na: http://research.stlouisfed.org/wp/2011/2011-004.pdf [pristupljeno 14.08.2018.].
5. Bauman, Z., 2017. Migracijska panika i njena (zlo)upotreba. Europski glasnik, br. 22, str. 129 – 138.
6. Bejaković, P. 2003. Nezaposlenost. Financijska teorija i praksa, Vol. 27 (4), pp. 659-661. Dostupno na: http://www.ijf.hr/pojmovnik/PDF/4-03.pdf [pristupljeno 01.09.2018.].
7. Bezić, H., Galović, T. i Mišević, P., 2016. Theimpactofterrorism on the FDI ofthe EU and EEA Countries, Zbornik radova ekonomskog fakulteta u Rijeci, Vol. 34 (2), str. 333 – 362. Dostupno na: https://hrcak.srce.hr/file/252525 [pristupljeno 30.07.2018.].
8. Blimes, J. R., 2006. The Indirect Effect of Ethnic Heterogenity on the Likelihood of Civil War Onset. University of Colorado, Vol. 50 (4), str. 536-547. Dostupno na: http://journals.sagepub.com/doi/10.1177/00222706289402 [pristupljeno 15.08.2018.].
9. Burnley, C., Buda, D. i Kayitakire, F. (2008): Quantitative global model for armed coflict risk assessment, European Commission. Dostupno na: http://publications.jrc.ec.europa.eu/repository/bitstream/JRC46309/conflict-risk-assessment-june2008.pdf [pristupljeno 03.04.2018.].

10. Çinar, M., 2017. The effects of terrorism on economic growth: Panel data approach, Zbornik radova ekonomskog fakulteta u Rijeci, Vol. 35, str. 97 – 121. Dostupno na: https://pdfs.semanticscholar.org/f3ba/730902dfd2cf42295bdc84eca51d12a40cb1.pdf[pristupljeno 30.07.2018.].
11. Cravetto, E. i Goldstein, I. (2008): Povijest / 16 : Prvi svjetski rat i poslijeratna Europa : (1914.-1936.), Europapress holding, Zagreb.
12. Cvjetković, B. (2002): Terorizam- sredstva i posljedice, Kupola Laus, Split.
13. Drukker, D. M. 2010. An introduction to GMM estimation using Stata, German Stata Users' Group, Berlin. Dostupno na: https://www.stata.com/meeting/germany10 /germany10_drukker.pdf [pristupljeno 11.09.2018.].
14. Ekonomski rječnik (2016): Bruto domaći proizvod, dostupno na: http://www.ekonomskirjecnik.com/definicije/bruto-domaci-proizvod-bdp.html [pristupljeno 02.09.2018.].
15. Europska unija (2018): O Europskoj uniji, dostupno na: https://europa.eu/european-union/about-eu/countries_hr#28-dr%C5%BEava-%C4%8Dlanica-europske-unije [pristupljeno 03.09.2018.].
16. Filer, R., Stanišić, D., 2012. The effect of terrorist incidents on capital flows, CERGE-EI Working Paper Series, 480. Dostupno na: http://ssrn.com/abstract=2257389 [pristupljeno 14.08.2018.].
17. Frey, B., S., Luechinger, S. i Stutzer, A., 2007. Calculating Tragedy: Assessing the Cost of Terrorism, Journal of Economic surveys, Vol. 21 (1), str 1-24. Dostupno na: https://doi.org/10.1111/j.1467-6419.2007.00505.x [pristupljeno 14.08.2018.].
18. Galović, T. (2017): Putevima krupnog kapitala i globalizacije. Ekonomski fakultet Sveučilišta u Rijeci, Tiskara Zagreb, dostupno na: https://bib.irb.hr/datoteka/904799.Galovic_2017_e_izdanje.pdf [pristupljeno 01.08.2018.].
19. Gavranović, A., 2017. Zašto Hrvatska nije izvozna zemlja. Ekonomija/Economics, br. 24 (1), str. 1 – 22.
20. Gries, T., Krieger, T., Meierrieks, D., 2011. Causal Linkages Between Domestic Terrorism and Economic Growth, Defence and Peace Economics, Vol. 22 (5), str. 493–508. Dostupno na: https://doi.org/10.1080/10242694.2010.532943 [pristupljeno 25.07.2018.].
21. Hrvatska enciklopedija (2018): Rat, Leksikografski zavod Miroslav Krleža, dostupno na: http://www.enciklopedija.hr/Natuknica.aspx?ID=51918 [pristupljeno 30.08.2018.].

22. Hrvatska enciklopedija (2018): Terorizam, Leksikografski zavod Miroslav Krleža, dostupno na: http://www.enciklopedija.hr/Natuknica.aspx?ID=60997 [pristupljeno 30.08.2018.].
23. Kandžija, V., Cvečić, C. (2010): Ekonomika i politika Europske unije. Ekonomski fakultet Sveučilišta, Rijeka.
24. Karlić, I., 2008. Dvoznačnost fenomena globalizacije. Filozofska istraživanja, Vol. 1, str. 87 – 106. Dostupno na: file:///C:/Users/78016795/Downloads/08_Karlic.pdf [pristupljeno 09.08.2018.].
25. KhoshnevisYazdi, S. i Khanalizadeh, B., 2017. Air pollution, economic growth and health care expenditure. Economic research, Vol. 30 (1), str. 1181 – 1190.
26. Krivokapić, B., 2003. Pojam rata i klasifikacije ratova. Megatrend Review, Vol. 10 (3), str. 3-30. Dostupno na: https://www.academia.edu/29439315/Boris_Krivokapic_POJAM_RATA_I_KLASIFIKACIJE_RATOVA_Megatrend_Review_3_2013_Pp._3-30 [pristupljeno 05.08.2018.].
27. Latour, B., 2017. Europa kao utočište. Europski glasnik. br. 22, str. 207 – 214.
28. Leko, V. i Jurković, P. (1998): Rječnik bankarstva, MASMEDIA, Zagreb.
29. Lončar, J., 2005. Globalizacija – pojam, nastanak i trendovi razvoja. Geoadria, Vol. 10, str. 91-104. Dostupno na: https://hrcak.srce.hr/file/14812 [pristupljeno 22.05.2018.].
30. Matotek, V. (2010): Prava žena kroz povijest, Hrvatski povijesni portal. Dostupno na: http://povijest.net/2018/?p=1456 [pristupljeno 09.08.2018.].
31. Mehmood, S., 2013. Terrorism and the macroeconomy: Evidence from Pakistan, Defence and Peace Economics, Vol. 25, No. 5, str. 509–534. Dostupno na: http://dx.doi.org/10.1080/10242694.2013.793529 [pristupljeno 15.08.2018.].
32. Musayev, V., 2016. Externalities in Military Spending and Growth: The Role of Natural Resources as a Channel throughConflict. Defence and Peace Economics, Vol. 27 (3) str. 378–391. Dostupno na: https://doi.org/10.1080/10242694.2014.994833 [pristupljeno 14.08.2018.].
33. Nick, S. (1999): Diplomatski leksikon, Barbat, Zagreb.
34. Ochsenwald, W. i Fisher, S. N. (2004): The Middle East: A History, 6. izd., McGraw-Hill, New York.
35. Čičin – Šain, D. (2018): Strategije ekonomskog razvoja, predavanje iz Osnova ekonomije, Internet, dostupno na:

http://www.unizd.hr/portals/4/nastavni_mat/1_godina/ekonomija/ekonomija_39.pdf [pristupljeno 10.09.2018.].

36. Rapoport, D. C. (2002): The Four Waves of Rebel Terror and September 11. Anthropoetics – The Journal of Generative Anthropology, Vol. 8 (1), str. 1-14. Dostupno na: https://wrldrels.org/wp-content/uploads/2016/02/Rapoport-Four-Waves-of-Terror.pdf [pristupljeno 30.07.2018.].
37. Sirotković, J. (1996): Hrvatsko gospodarstvo: privredna kretanja i ekonomska politika, Hrvatska akademija znanosti i umjetnosti, Golden marketing, Zagreb.
38. Stajić, Lj. (2008): Osnovi sistema bezbednosti, Pravni fakultet u Novom Sadu, Novi Sad.
39. Stern, J. (2006): Terorizam u ime Boga – Zašto ubijaju vjerski militanti, Slovo, Zagreb.
40. Stiglitz, J. i Bilmes, L. J. (2008): The Three Trillion Dollar War, Penguin Group, PenguinBooksLtd, England.
41. Šebić, F. (2004): Uvod u ekonomiju: izbor tekstova, Univerzitet u Sarajevu, Ekonomski fakultet, Sarajevo.
42. Škrabić Perić, B. (2012): Utjecaj stranog vlasništva banke na njezin kreditni rizik u zemljama srednje i istočne Europe: dinamički panel modeli, Ekonomski fakultet u Splitu, Split.
43. Tavares, J., 2004. The Open Society Assesses Its Enemies: Shocks, Disasters and Terrorist Attacks, Journal of Monetary Economics, Vol. 51 (5), str. 1039–1070, Dostupno na: https://doi.org/10.1016/j.jmoneco.2004.04.009 [pristupljeno 30.07.2018.].
44. The World Bank (2018): Exports of goods and services, Internet, dostupno na: https://data.worldbank.org/indicator/NE.EXP.GNFS.KN [pristupljeno 02.09.2018.].
45. Turk, A. T. (2004): Sociology of Terorism. Department of Sociology, University of California, dostupno na: http://ruraleconomics.fib.ugm.ac.id/wp-content/uploads/02-Austin-Turk-Sociology-of-Terrorism.pdf [pristupljeno 31.07.2018.].
46. UNHCR, 2001. Who we help. Dostupno na http://www.unhcr.hr/kome-pomazemo [pristupljeno 14.08.2018.].
47. United Nations development programme (2018): Human Development Index (HDI), Internet, dostupno na: http://hdr.undp.org/en/content/human-development-index-hdi [pristupljeno 10.09.2018.].

48. Vedriš, M., 2017. Hrvatska: regionalno, EU i globalno okruženje. Ekonomija/Economics, Vol. 24 (1), str. 143 – 166.
49. Venner, D. (2004): Povijest terorizma, Alfa, Zagreb.
50. Veselica, V. (2007): Zlatno pero Vladimira Veselice: odabrane teme hrvatskih poduzetnika i obrtnika iz Zlatnih knjiga, A. G. Matoš, Samobor; Zavod za poslovna istraživanja, Ekonomski fakultet, Zagreb.
51. Zanini, M. i Edwards, S. J. A. (2001): The networking of terror in the information age – Chapter Two, Networks and Netwars, dostupno na: http://derzhava.in.ua:8081/kafedry/kaf_polit_analit_prognoz/DocLib/Networks_netwars2.pdf [pristupljeno 31.07.2018.].

POPIS TABLICA

Tablica 1: Opis varijabli i izvori podataka 25
Tablica 2: Aritmetička sredina, standardna devijacija, minimalna i maksimalna vrijednost apsolutne promjene bdp-a, broja incidenata i hdi indeksa 25
Tablica 3: Rezultati panel analize za EU-28 od 2000. do 2015. godine 34
Tablica 4: : Sargan test analize utjecaja broja incidenata i HDI indeksa na rast BDP-a 35
Tablica 5: Arrelando – Bond test autokorelacije analize utjecaja broja incidenata i HDI indeksa na promjenu BDP-a 35

POPIS GRAFIKONA

Graf 1: Prikaz delta BDP-a za 28 zemalja Europske unije 27
Graf 2: Kretanje BDP-a u zemljama članicama Europske unije 28
Graf 3: Prikaz BDP-a po glavi stanovnika u Europskoj uniji 29
Graf 4: Prikaz sukoba u Europskoj uniji 31
Graf 5: Prikaz sukoba u Francuskoj, Grčkoj, Španjolskoj i Ujedinjenom Kraljevstvu 32

PRILOG

Zemlje	Godine	BDP per capita	BDP u mil $	HDI indeks	Incidenti
Austrija	2000	41821,68039	337470,6819	0.837	0
Austrija	2001	42237,45635	342028,2777	0.847	0
Austrija	2002	42743,31936	347691,7699	0.837	0
Austrija	2003	42848,23943	350320,8641	0.841	0
Austrija	2004	43788,26644	359799,6466	0.848	0
Austrija	2005	44525,97518	367501,815	0.854	0
Austrija	2006	45845,30236	379816,1811	0.860	1
Austrija	2007	47351,00323	393571,2637	0.864	1
Austrija	2008	47929,85575	399660,8495	0.870	8
Austrija	2009	45934,96874	384477,4339	0.872	3
Austrija	2010	46598,70667	391892,7465	0.880	0
Austrija	2011	47624,53565	402897,0947	0.884	1
Austrija	2012	47654,76217	405901,7243	0.887	0
Austrija	2013	47378,90864	406405,9497	0.892	1
Austrija	2014	47378,22476	409026,6375	0.892	0
Austrija	2015	47584,06777	412965,8029	0.893	0
Belgija	2000	40050,25541	40050,25541	0.873	0
Belgija	2001	40230,5051	40230,5051	0.875	0
Belgija	2002	40765,65293	40765,65293	0.878	3
Belgija	2003	40867,83462	40867,83462	0.880	8
Belgija	2004	42106,44401	42106,44401	0.861	0
Belgija	2005	42716,11115	42716,11115	0.865	0
Belgija	2006	43486,9238	43486,9238	0.871	0
Belgija	2007	44657,64404	44657,64404	0.874	1
Belgija	2008	44667,85258	44667,85258	0.876	0
Belgija	2009	43335,31811	43335,31811	0.878	1
Belgija	2010	44205,15869	44205,15869	0.884	0
Belgija	2011	44696,31626	44696,31626	0.886	0
Belgija	2012	44516,46908	44516,46908	0.889	1
Belgija	2013	44333,9784	44333,9784	0.890	0
Belgija	2014	44662,18567	44662,18567	0.895	1
Belgija	2015	45013,43119	45013,43119	0.896	0
Bugarska	2000	4040,550953	32315,46588	0.713	2
Bugarska	2001	4228,438916	33533,82933	0.723	1
Bugarska	2002	4516,211232	35524,90594	0.729	1
Bugarska	2003	4786,932002	37356,6477	0.738	0
Bugarska	2004	5134,873592	39760,68183	0.745	0
Bugarska	2005	5543,252493	42593,03841	0.750	0

Bugarska	2006	5970,004103	45521,03651	0.755	0
Bugarska	2007	6457,595193	48864,29349	0.761	0
Bugarska	2008	6898,077364	51806,84427	0.768	2
Bugarska	2009	6699,1382	49948,97539	0.770	0
Bugarska	2010	6834,996088	50610,34368	0.775	0
Bugarska	2011	7011,689862	51579,48411	0.778	2
Bugarska	2012	7057,83243	51595,45821	0.781	2
Bugarska	2013	7162,026754	52040,29624	0.787	3
Bugarska	2014	7301,402171	52731,78518	0.792	0
Bugarska	2015	7612,696334	54639,33622	0.794	2
Cipar	2000	27316,56044	18958,07655	0.800	2
Cipar	2001	27996,82327	19640,68492	0.805	1
Cipar	2002	28618,68719	20308,32729	0.815	0
Cipar	2003	28973,0123	20811,07881	0.823	0
Cipar	2004	29894,79353	21762,28045	0.826	1
Cipar	2005	30564,78405	22572,69578	0.829	0
Cipar	2006	31415,32208	23590,78086	0.836	0
Cipar	2007	32237,06962	24728,06414	0.844	1
Cipar	2008	32652,77995	25683,50394	0.849	0
Cipar	2009	31224,57523	25228,16681	0.853	0
Cipar	2010	30819,0266	25560,72979	0.847	0
Cipar	2011	30139,39452	25642,84411	0.850	0
Cipar	2012	28773,50877	24858,65239	0.850	1
Cipar	2013	27129,24303	23383,50843	0.850	9
Cipar	2014	27044,79414	23055,31605	0.854	1
Cipar	2015	27736,85315	23511,58028	0.856	3
Češka	2000	14717,40032	151436,074	0.821	0
Češka	2001	15193,65967	156057,178	0.828	1
Češka	2002	15472,15849	158627,3611	0.833	0
Češka	2003	16050,0462	164340,8689	0.839	1
Češka	2004	16843,68916	172471,5615	0.840	0
Češka	2005	17896,2256	183582,6319	0.847	0
Češka	2006	19052,36801	196206,7729	0.851	0
Češka	2007	19992,64699	207055,5679	0.856	0
Češka	2008	20402,24053	212668,7524	0.858	2
Češka	2009	19297,68086	202371,788	0.859	1
Češka	2010	19647,94825	207016,402	0.861	0
Češka	2011	19980,33518	211166,4681	0.864	1
Češka	2012	19786,74912	209477,4652	0.865	0
Češka	2013	19676,6867	208464,2834	0.871	1
Češka	2014	20203,21795	214124,3308	0.875	2
Češka	2015	21265,34924	225492,7022	0.878	4
Danska	2000	55834,13594	298220,9519	0.862	0

Danska	2001	56116,51294	300675,7556	0.875	0
Danska	2002	56223,54926	302077,9417	0.882	0
Danska	2003	56294,42551	303256,2688	0.893	0
Danska	2004	57627,52281	311347,7327	0.897	0
Danska	2005	58768,05561	318622,8847	0.902	0
Danska	2006	60814,12715	331090,5349	0.904	0
Danska	2007	61079,27091	334100,9855	0.906	0
Danska	2008	60458,83926	332390,3042	0.906	1
Danska	2009	57194,34004	316081,489	0.906	0
Danska	2010	57966,58742	321995,3503	0.910	1
Danska	2011	58446,55657	326299,7026	0.922	0
Danska	2012	58288,80534	327038,6686	0.924	0
Danska	2013	58549,44948	330091,0816	0.926	1
Danska	2014	59223,44407	335436,494	0.923	0
Danska	2015	59912,80019	340825,6469	0.925	4
Estonija	2000	10080,10284	14103,19284	0.781	0
Estonija	2001	10774,90167	14995,74312	0.791	1
Estonija	2002	11503,9962	15906,94367	0.798	0
Estonija	2003	12445,56528	17086,62859	0.805	0
Estonija	2004	13319,63532	18162,18853	0.812	0
Estonija	2005	14680,51697	19901,61347	0.822	0
Estonija	2006	16264,68016	21945,88414	0.829	0
Estonija	2007	17593,02587	23646,29346	0.835	0
Estonija	2008	16693,73195	22364,79302	0.836	0
Estonija	2009	14277,04915	19071,71056	0.833	0
Estonija	2010	14640,43668	19502,55498	0.838	0
Estonija	2011	15796,03178	20984,22263	0.850	1
Estonija	2012	16520,11907	21888,06744	0.856	0
Estonija	2013	16883,05086	22311,96469	0.860	0
Estonija	2014	17413,27386	22956,94632	0.863	0
Estonija	2015	17745,67453	23341,25836	0.865	2
Finska	2000	40358,79785	209379,5867	0.856	0
Finska	2001	41300,66452	214783,2385	0.863	0
Finska	2002	41890,78647	218392,2951	0.866	0
Finska	2003	42613,85375	222747,0028	0.869	0
Finska	2004	44159,48263	231492,1774	0.864	0
Finska	2005	45242,60479	237927,5559	0.869	0
Finska	2006	46910,98139	247575,988	0.873	0
Finska	2007	49152,81648	260412,3099	0.876	1
Finska	2008	49303,35546	262289,0193	0.878	1
Finska	2009	45033,91099	240600,2444	0.874	0
Finska	2010	46181,49149	247799,8158	0.878	0
Finska	2011	47162,53184	254170,2974	0.884	0

Finska	2012	46286,02871	250545,3477	0.887	0
Finska	2013	45735,45805	248646,123	0.890	0
Finska	2014	45254,24222	247075,3556	0.893	0
Finska	2015	45066,7087	247054,1648	0.895	9
Francuska	2000	38226,13655	2350989,164	0.849	28
Francuska	2001	38762,31554	2396938,058	0.851	21
Francuska	2002	38978,32252	2423746,777	0.852	32
Francuska	2003	39074,34716	2443610,149	0.857	34
Francuska	2004	39929,6539	2511699,491	0.860	11
Francuska	2005	40331,36213	2552080,431	0.870	33
Francuska	2006	41042,45549	2612859,618	0.873	34
Francuska	2007	41764,42753	2675185,574	0.877	16
Francuska	2008	41592,59618	2680432,282	0.879	13
Francuska	2009	40125,10416	2601060,363	0.879	9
Francuska	2010	40688,58972	2652199,461	0.882	3
Francuska	2011	41325,85421	2707612,566	0.885	8
Francuska	2012	41204,39282	2712605,249	0.887	66
Francuska	2013	41263,20974	2728757,93	0.890	18
Francuska	2014	41479,27222	2755011,201	0.894	5
Francuska	2015	41746,97672	2784683,739	0.897	37
Grčka	2000	22572,78911	3123907,847	0.801	28
Grčka	2001	23416,55459	3176872,812	0.811	14
Grčka	2002	24264,86115	3176872,812	0.823	11
Grčka	2003	25609,7804	3154319,996	0.830	12
Grčka	2004	26841,67199	3191224,607	0.839	4
Grčka	2005	26929,0719	3213777,436	0.850	6
Grčka	2006	28356,9593	3332692,33	0.855	23
Grčka	2007	29176,89328	3441355,939	0.853	15
Grčka	2008	28980,42696	3478602,265	0.857	53
Grčka	2009	27675,45346	3283144,458	0.859	115
Grčka	2010	26154,24129	3417094,563	0.860	49
Grčka	2011	23813,97538	3542160,229	0.858	11
Grčka	2012	22161,86675	3559587,403	0.860	22
Grčka	2013	21551,38787	3577014,591	0.862	54
Grčka	2014	21819,85676	3646039,898	0.865	12
Grčka	2015	21847,393	3709597,863	0.866	31
Hrvatska	2000	10564,05595	46778,40037	0.749	2
Hrvatska	2001	10976,42506	48384,95979	0.759	3
Hrvatska	2002	11584,52256	50923,46438	0.765	0
Hrvatska	2003	12247,52895	53753,74319	0.771	0
Hrvatska	2004	12762,18698	55948,40676	0.777	0
Hrvatska	2005	13311,36885	58277,93157	0.783	1
Hrvatska	2006	13971,83439	61066,68261	0.793	0

Hrvatska	2007	14719,7855	64211,6198	0.800	0
Hrvatska	2008	15055,99152	65530,11905	0.803	2
Hrvatska	2009	13980,7286	60691,51725	0.803	1
Hrvatska	2010	13823,31675	59829,42987	0.808	0
Hrvatska	2011	13825,47563	59634,40562	0.815	0
Hrvatska	2012	13568,12348	58295,7953	0.817	0
Hrvatska	2013	13539,18769	57918,01834	0.820	2
Hrvatska	2014	13590,57345	57862,31495	0.823	0
Hrvatska	2015	13980,24601	59220,54579	0.827	0
Irska	2000	42458,73851	163414,1738	0.857	0
Irska	2001	44227,45765	172898,0906	0.862	2
Irska	2002	46225,69865	183806,6908	0.870	0
Irska	2003	46805,37549	189540,5679	0.880	1
Irska	2004	48974,68611	202204,1863	0.889	0
Irska	2005	50878,3415	214349,2825	0.896	0
Irska	2006	52559,94858	226184,9059	0.902	1
Irska	2007	54106,96037	237966,3615	0.908	1
Irska	2008	50917,83823	228600,1664	0.909	5
Irska	2009	47727,72911	218023,3211	0.907	0
Irska	2010	47969,48512	221951,3538	0.909	4
Irska	2011	49023,63797	228576,5849	0.895	4
Irska	2012	48878,96308	228661,5081	0.902	29
Irska	2013	49639,14951	232408,8599	0.910	27
Irska	2014	53723,03202	251764,7699	0.920	28
Irska	2015	67255,70497	316109,0097	0.923	28
Italija	2000	35958,73642	2060209,812	0.828	8
Italija	2001	36460,6681	2096720,561	0.836	11
Italija	2002	36364,49432	2101931,882	0.841	7
Italija	2003	36203,26531	2105112,608	0.846	15
Italija	2004	36557,39744	2138414,142	0.851	3
Italija	2005	36707,66188	2158721,909	0.856	6
Italija	2006	37272,23153	2202038,556	0.862	4
Italija	2007	37672,59326	2234493,775	0.866	0
Italija	2008	37158,55313	2211022,534	0.868	2
Italija	2009	35039,3722	2089813,086	0.869	4
Italija	2010	35577,85262	2125058,27	0.872	10
Italija	2011	35764,96686	2137311,88	0.877	5
Italija	2012	34771,92925	2077060,649	0.876	10
Italija	2013	34208,7178	2041165,774	0.877	7
Italija	2014	34294,92471	2043485,998	0.881	3
Italija	2015	34684,49276	2063873,41	0.887	5
Latvija	2000	6888,655097	16423,6766	0.728	3
Latvija	2001	7412,995205	17484,86129	0.746	0

Latvija	2002	8028,67329	18726,81622	0.761	0
Latvija	2003	8806,417048	20305,61627	0.776	0
Latvija	2004	9653,181276	21998,20042	0.791	0
Latvija	2005	10813,2948	24351,35607	0.807	0
Latvija	2006	12244,42792	27246,58263	0.814	0
Latvija	2007	13629,90546	29965,5925	0.819	1
Latvija	2008	13307,59829	28902,51988	0.821	0
Latvija	2009	11532,16998	24740,06805	0.815	0
Latvija	2010	11216,06814	23765,14354	0.810	0
Latvija	2011	12082,04873	25281,6024	0.812	0
Latvija	2012	12728,39336	26301,6211	0.814	0
Latvija	2013	13220,4685	26980,12059	0.822	0
Latvija	2014	13638,10721	27496,12889	0.828	0
Latvija	2015	14190,11068	28276,10852	0.830	0
Litva	2000	6930,859311	24270,72572	0.757	0
Litva	2001	7443,034861	25854,25242	0.770	0
Litva	2002	8012,819982	27602,19368	0.780	0
Litva	2003	8936,122814	30511,0688	0.792	0
Litva	2004	9615,035353	32509,5691	0.798	0
Litva	2005	10472,21206	35021,71612	0.807	0
Litva	2006	11385,99455	37615,58001	0.812	0
Litva	2007	12817,4343	41786,0022	0.820	0
Litva	2008	13340,3256	42884,17085	0.825	0
Litva	2009	11528,51636	36531,23985	0.824	0
Litva	2010	11886,24451	37130,28625	0.826	0
Litva	2011	12784,29848	39374,11798	0.830	0
Litva	2012	13459,87364	40880,94737	0.834	0
Litva	2013	14116,27812	42311,20037	0.841	0
Litva	2014	14790,7742	43807,9954	0.846	0
Litva	2015	15245,72391	44699,33433	0.848	0
Luksemburg	2000	93505,14468	40777,87411	0.854	0
Luksemburg	2001	94980,80331	41810,35966	0.860	0
Luksemburg	2002	97824,54424	43407,29372	0.865	0
Luksemburg	2003	98619,16725	44114,52313	0.867	0
Luksemburg	2004	101164,4434	45708,01766	0.874	0
Luksemburg	2005	103000,7696	47158,07835	0.880	0
Luksemburg	2006	106540,0637	49600,15281	0.877	0
Luksemburg	2007	113211,5722	53744,02397	0.887	0
Luksemburg	2008	109370,8026	53056,3232	0.888	0
Luksemburg	2009	102248,5468	50743,80658	0.884	0
Luksemburg	2010	104771,8632	53212,47681	0.894	0
Luksemburg	2011	104942,0349	54563,66656	0.892	0
Luksemburg	2012	102127,4356	54371,31907	0.892	0

Luksemburg	2013	103462,5955	56358,24846	0.892	0
Luksemburg	2014	107153,4868	59611,19915	0.896	0
Luksemburg	2015	108192,4154	61317,07772	0.898	0
Mađarska	2000	10480,00473	107116,6629	0.769	0
Mađarska	2001	10911,36305	111230,4895	0.775	1
Mađarska	2002	11434,76581	116267,2351	0.784	0
Mađarska	2003	11905,19055	120741,9188	0.793	0
Mađarska	2004	12534,24988	126784,9528	0.795	0
Mađarska	2005	13121,40074	132348,5494	0.802	0
Mađarska	2006	13668,15123	137445,5209	0.809	0
Mađarska	2007	13771,41236	138043,0813	0.812	0
Mađarska	2008	13934,6669	139224,0579	0.816	2
Mađarska	2009	13057,14063	130035,3062	0.817	1
Mađarska	2010	13187,42432	130922,6387	0.821	0
Mađarska	2011	13446,72871	133098,4639	0.823	0
Mađarska	2012	13263,91181	130910,6181	0.824	0
Mađarska	2013	13580,46162	133654,7884	0.834	0
Mađarska	2014	14195,51625	139305,3565	0.834	0
Mađarska	2015	14717,60771	143995,97	0.836	1
Malta	2000	18001,87285	7140,766898	0.783	0
Malta	2001	17998,54197	7184,208021	0.786	0
Malta	2002	18436,19384	7398,499898	0.790	0
Malta	2003	18815,70843	7586,700613	0.797	0
Malta	2004	18815,33157	7620,340994	0.805	0
Malta	2005	19441,79189	7908,668198	0.809	0
Malta	2006	19711,26937	8053,295349	0.808	0
Malta	2007	20409,08121	8374,335837	0.813	0
Malta	2008	20999,74778	8654,584052	0.815	0
Malta	2009	20387,84228	8441,484157	0.819	0
Malta	2010	21005,35724	8740,539199	0.826	0
Malta	2011	21188,03081	8864,372886	0.821	0
Malta	2012	21615,31065	9095,484953	0.828	0
Malta	2013	22477,09575	9513,340869	0.847	0
Malta	2014	24180,23051	10290,3807	0.853	1
Malta	2015	25763,98544	11017,0924	0.856	1
Nizozemska	2000	46131,22109	734694,4997	0.878	1
Nizozemska	2001	46840,80491	750301,3529	0.882	1
Nizozemska	2002	46620,87769	751078,8901	0.881	2
Nizozemska	2003	46491,79993	753211,3726	0.885	3
Nizozemska	2004	47184,76674	768506,8836	0.888	1
Nizozemska	2005	47968,58715	785109,445	0.893	0
Nizozemska	2006	49435,7434	812734,5962	0.899	0
Nizozemska	2007	51056,55221	842793,3666	0.905	0

Nizozemska	2008	51730,74407	857112,9382	0.906	1
Nizozemska	2009	49607,51567	824820,4922	0.906	1
Nizozemska	2010	50134,51408	836389,9372	0.911	1
Nizozemska	2011	50803,86204	850304,3406	0.921	2
Nizozemska	2012	50110,87886	841316,3057	0.922	0
Nizozemska	2013	49865,19955	839714,9509	0.923	0
Nizozemska	2014	50424,43907	851636,3026	0.923	0
Nizozemska	2015	51414,81132	870889,7302	0.924	3
Njemačka	2000	38335,91648	3123907,847	0.860	8
Njemačka	2001	38962,89657	3176872,812	0.867	8
Njemačka	2002	38926,60332	3176872,812	0.872	3
Njemačka	2003	38614,95093	3154319,996	0.877	2
Njemačka	2004	39052,79167	3191224,607	0.884	3
Njemačka	2005	39350,17605	3213777,436	0.892	3
Njemačka	2006	40871,69367	3332692,33	0.898	4
Njemačka	2007	42305,96732	3441355,939	0.903	3
Njemačka	2008	42876,39331	3478602,265	0.906	3
Njemačka	2009	40549,8628	3283144,458	0.907	4
Njemačka	2010	42241,22189	3417094,563	0.912	1
Njemačka	2011	43766,04523	3542160,229	0.916	8
Njemačka	2012	43909,62169	3559587,403	0.919	5
Njemačka	2013	44016,59352	3577014,591	0.920	0
Njemačka	2014	44742,36238	3646039,898	0.924	4
Njemačka	2015	45400,78624	3709597,863	0.926	65
Poljska	2000	8461,719602	326203,4792	0.784	0
Poljska	2001	8573,213413	330274,5164	0.790	1
Poljska	2002	8757,231066	337017,4138	0.796	0
Poljska	2003	9079,970902	349023,4216	0.800	0
Poljska	2004	9556,917661	366948,0413	0.797	0
Poljska	2005	9899,417162	379768,0342	0.803	0
Poljska	2006	10517,09178	403236,1947	0.808	0
Poljska	2007	11260,31139	431603,0626	0.813	0
Poljska	2008	11740,028	449944,6618	0.818	0
Poljska	2009	12071,3808	462634,0998	0.822	0
Poljska	2010	12507,26981	479321,1289	0.829	1
Poljska	2011	13135,63951	503370,1456	0.834	0
Poljska	2012	13348,08244	511463,8676	0.838	0
Poljska	2013	13536,683	518582,8939	0.850	0
Poljska	2014	13987,09659	535608,7288	0.852	0
Poljska	2015	14535,40898	556200,7097	0.855	0
Portugal	2000	21377,96271	221371,305	0.782	0
Portugal	2001	21700,78391	225673,2226	0.788	0
Portugal	2002	21774,74356	227408,1926	0.789	0

Portugal	2003	21481,95919	225283,7335	0.792	0
Portugal	2004	21785,62824	229364,9327	0.790	0
Portugal	2005	21874,85608	231123,67	0.793	0
Portugal	2006	22142,85176	234713,1437	0.797	0
Portugal	2007	22630,24308	240562,1996	0.804	0
Portugal	2008	22628,55174	241041,5734	0.809	0
Portugal	2009	21937,10995	233863,1054	0.812	0
Portugal	2010	22371,03477	238303,4434	0.818	0
Portugal	2011	22018,13873	233949,99	0.824	2
Portugal	2012	21218,07616	224525,8839	0.827	0
Portugal	2013	21086,17644	221988,3915	0.837	0
Portugal	2014	21389,30022	223970,956	0.841	0
Portugal	2015	21889,20285	228052,0689	0.843	0
Rumunjska	2000	4970,265353	109982,6679	0.708	0
Rumunjska	2001	5282,578451	116132,9178	0.714	0
Rumunjska	2002	5589,351022	122153,4556	0.722	0
Rumunjska	2003	5932,268779	128901,7878	0.733	0
Rumunjska	2004	6469,146734	139676,4081	0.745	0
Rumunjska	2005	6789,377779	145503,2774	0.755	0
Rumunjska	2006	7400,899085	157224,1229	0.766	0
Rumunjska	2007	7987,015323	168015,7409	0.780	0
Rumunjska	2008	8752,098436	182228,1767	0.795	0
Rumunjska	2009	8213,734744	169350,4133	0.797	0
Rumunjska	2010	8218,943104	167998,049	0.798	0
Rumunjska	2011	8366,075363	169772,4913	0.797	0
Rumunjska	2012	8470,501775	170860,6513	0.794	0
Rumunjska	2013	8814,679924	176894,7685	0.797	0
Rumunjska	2014	9129,274709	182336,5936	0.798	0
Rumunjska	2015	9534,666656	189516,9555	0.802	0
Slovačka	2000	10276,70703	55486,10965	0.763	1
Slovačka	2001	10615,96762	57326,28883	0.763	0
Slovačka	2002	11095,80167	59919,03777	0.771	0
Slovačka	2003	11697,63218	63165,88022	0.776	0
Slovačka	2004	12313,85646	66487,67053	0.784	0
Slovačka	2005	13146,27033	70976,22712	0.793	0
Slovačka	2006	14258,62431	76975,76793	0.802	0
Slovačka	2007	15799,12464	85288,82529	0.813	0
Slovačka	2008	16686,94214	90090,39769	0.820	0
Slovačka	2009	15776,64155	85205,20776	0.822	0
Slovačka	2010	16561,09252	89501,01292	0.829	0
Slovačka	2011	17010,48764	92024,13554	0.835	0
Slovačka	2012	17269,31945	93549,11229	0.838	0
Slovačka	2013	17500,70483	94943,5988	0.841	0

Slovačka	2014	17956,51039	97554,86585	0.842	0
Slovačka	2015	18625,64872	101310,8263	0.845	0
Slovenija	2000	18574,67449	36935,72166	0.824	1
Slovenija	2001	19123,95211	38025,09106	0.835	0
Slovenija	2002	19858,45425	39483,84968	0.843	0
Slovenija	2003	20415,65011	40606,01352	0.850	0
Slovenija	2004	21277,72714	42373,10417	0.853	0
Slovenija	2005	22075,7011	44069,30267	0.858	0
Slovenija	2006	23236,8855	46561,86204	0.865	0
Slovenija	2007	24729,60371	49794,02153	0.869	0
Slovenija	2008	25406,92695	51437,28907	0.873	0
Slovenija	2009	23300,59063	47426,58138	0.872	0
Slovenija	2010	23476,60765	48013,60672	0.876	0
Slovenija	2011	23533,91643	48325,39123	0.877	0
Slovenija	2012	22828,35058	47035,30526	0.878	0
Slovenija	2013	22507,33851	46502,83974	0.888	0
Slovenija	2014	23124,98062	47888,2505	0.888	0
Slovenija	2015	23602,41111	48969,99934	0.890	0
Španjolska	2000	28102,38477	1149491,825	0.825	112
Španjolska	2001	28881,92922	1195483,789	0.828	79
Španjolska	2002	29293,69169	1229910,878	0.830	41
Španjolska	2003	29754,13421	1269115,167	0.833	21
Španjolska	2004	30201,94809	1309304,827	0.837	31
Španjolska	2005	30834,93269	1358051,593	0.844	24
Španjolska	2006	31631,55856	1414738,284	0.849	23
Španjolska	2007	32340,46087	1468058,289	0.854	11
Španjolska	2008	32272,55194	1484466,583	0.858	37
Španjolska	2009	30798,97624	1431415,437	0.860	15
Španjolska	2010	30597,53512	1431616,75	0.867	3
Španjolska	2011	30214,11869	1417318,263	0.871	0
Španjolska	2012	29361,90662	1375822,721	0.874	1
Španjolska	2013	28959,87384	1352355,244	0.877	5
Španjolska	2014	29470,41845	1371017,709	0.882	3
Španjolska	2015	30563,48935	1418074,51	0.884	1
Švedska	2000	44645,77518	396527,7027	0.877	1
Švedska	2001	45261,45501	402727,0576	0.880	0
Švedska	2002	46081,38269	411077,9141	0.882	0
Švedska	2003	47018,80497	420885,1653	0.888	0
Švedska	2004	48836,31011	439069,6343	0.890	0
Švedska	2005	49946,11058	451444,0638	0.892	3
Švedska	2006	51956,31257	472608,3356	0.895	1
Švedska	2007	53332,69104	488700,4079	0.897	0
Švedska	2008	52612,74237	485978,1138	0.898	1

Švedska	2009	49474,7296	460781,8057	0.895	1
Švedska	2010	52009,47305	488377,6896	0.901	1
Švedska	2011	52968,07354	501390,0636	0.903	3
Švedska	2012	52401,14807	499954,4804	0.904	1
Švedska	2013	52641,38717	506159,94	0.906	2
Švedska	2014	53599,11699	519341,9978	0.909	4
Švedska	2015	55597,15982	542826,4838	0.913	32
Ujedinjeno Kraljevstvo	2000	35408,65177	2095205,24	0.866	61
Ujedinjeno Kraljevstvo	2001	36187,06002	2148509,997	0.870	94
Ujedinjeno Kraljevstvo	2002	36951,15221	2201317,743	0.874	21
Ujedinjeno Kraljevstvo	2003	38031,29055	2274531,575	0.878	23
Ujedinjeno Kraljevstvo	2004	38732,4845	2328311,858	0.886	5
Ujedinjeno Kraljevstvo	2005	39664,75337	2400398,464	0.890	29
Ujedinjeno Kraljevstvo	2006	40294,0471	2459352,242	0.889	6
Ujedinjeno Kraljevstvo	2007	40833,03998	2517311,999	0.892	20
Ujedinjeno Kraljevstvo	2008	40207,39464	2505416,684	0.895	39
Ujedinjeno Kraljevstvo	2009	38126,99274	2400495,861	0.895	23
Ujedinjeno Kraljevstvo	2010	38415,54686	2441173,395	0.902	58
Ujedinjeno Kraljevstvo	2011	38665,31043	2476634,465	0.898	47
Ujedinjeno Kraljevstvo	2012	38970,39875	2513321,59	0.899	55
Ujedinjeno Kraljevstvo	2013	39529,82562	2564904,713	0.904	137
Ujedinjeno Kraljevstvo	2014	40502,49641	2643243,341	0.908	32
Ujedinjeno Kraljevstvo	2015	41210,95645	2705252,231	0.910	114