UTJECAJ MAKROEKONOMSKIH POKAZATELJA EMITIVNIH ZEMALJA NA BROJ NOĆENJA TURISTA U PRIMORSKIM ŽUPANIJAMA REPUBLIKE HRVATSKE: PANEL MODELI

Glaurdić Mekinić, Ana

Master's thesis / Diplomski rad

2016

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:124:177393

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

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

UTJECAJ MAKROEKONOMSKIH POKAZATELJA EMITIVNIH ZEMALJA NA BROJ NOĆENJA TURISTA U PRIMORSKIM ŽUPANIJAMA REPUBLIKE HRVATSKE: PANEL MODELI

Mentor:

doc. dr. sc. Blanka Škrabić Perić

Student:

Ana Glaurdić Mekinić,

(Matični broj studenta: 2133075)

Split, rujan 2016.

Sadržaj

1. UVOD ... 3

1.1. Problem istraživanja ... 3

1.2. Predmet istraživanja ... 6

1.3. Istraživačke hipoteze ... 7

1.4. Ciljevi istraživanja ... 8

1.5. Metode istraživanja ... 9

1.6. Doprinos istraživanja ... 10

1.7. Struktura diplomskog rada ... 11

2. RAZVOJ TURIZAMA I OSNOVNE ZNAČAJKE TURISTIČKE POTRAŽNJE U HRVATSKOJ ... 12

2.1. Povijesni razvoj turizma ... 12

2.2. Osnovne značajke turističke potražnje ... 14

2.3. Pregled dosadašnjih istraživanja turističke potražnje ... 17

2.3.1. Pregled znanstvenih istraživanja turističke potražnje u svijetu ... 17

2.3.2. Pregled znanstvenih istraživanja turističke potražnje u Hrvatskoj ... 22

3. PANEL ANALIZA ... 25

3.1. Osnovne karakteristike panel analize ... 25

3.2. Statički panel modeli ... 25

3.2.2. Model s fiksnim efektom ... 27

3.2.3. Model s slučajnim efektom ... 29

3.2.4. Dijagnostički testovi za odabir prikladnog panel modela ... 32

3.3. Dinamički panel modeli ... 33

4. EMPIRIJSKA ANALIZA I REZULTATI ... 35

4.1. Deskriptivna analiza ... 35

4.2. Testiranje ekonomskog modela ... 48

4.3. Testiranje modela ... 54

4.4. Interpretacija rezultata i osvrt na istraživačke hipoteze ... 67

5. ZAKLJUČAK ... 73

SAŽETAK ... 75

SUMMARY ... 76

LITERATURA 77
PRILOZI 81
Popis tablica 81
Popis grafova 82
Popis slika 82

1. UVOD

1.1. Problem istraživanja

Turizam zadire u gotovo sve sfere društvenog i gospodarskog razvoja uopće, te je duboko inkorporiran u tijekove svakidašnjeg života (Čavlek et al., 2011) a u Hrvatskoj posljednjih godina ima iznimno važnu ulogu u gospodarstvu. Devizni prihod od turizma u Hrvatskoj konstantno raste, te je u 2014. godini dosegnuo rekordnu razinu s udjelom od 17,3% deviznih prihoda u BDP-u, tako da je premašio i pred kriznu 2008. godinu, dok je postotak novozaposlenih u turizmu u istom razdoblju iznosio 19,9%. Turizam u Hrvatskoj ostvaruje najveći doprinos u usporedbi s 19 europskih zemalja (osim Cipra), te se može zaključiti da je turizma od iznimne važnosti u Hrvatskoj.

Međutim, nedostatak odgovarajućeg ekonomskog mjerenja turizma često vodi i podcjenjivanju koristi od turizma, posebice u usporedbi s ostalim gospodarskim sektorima (Spurr, 2006). Problem je, među ostalim, i u činjenici da je turizam nemoguće svesti na jednu gospodarsku djelatnost, naročito zbog svog multiplikativnog učinka na razvoj ostalih gospodarskih grana kao što je poljoprivreda, promet i graditeljstvo.

Obzirom na važnost turizma, ne samo na nivou Republike Hrvatske, već i cijelog svijeta, ne začuđuje da se sve više znanstvenika bavi tom problematikom u namjeri da što bolje odredi faktore koji utječu na kretanja u turizmu i na taj način omoguće turizmu što bolji rast i razvoj. Također, imajući u vidu da je turizam dominantna grana u hrvatskom gospodarstvu potrebno je što preciznije odrediti determinante hrvatske turističke potražnje i na taj način omogućiti što bolje upravljanje istim.

Postoji veliki broj potencijalnih faktora koji objašnjavaju turističku potražnju, a specifikacija funkcije potražnje varira u skladu sa zemljom i/ili regijom koja se analizira, razdobljem istraživanja, vrstom podataka (vremenske serije ili panel podaci) i prirode turizma (odmor, poslovna putovanja, posjeta obitelji ili prijateljima, itd. (Crouch, 1994). Turistička potražnja se također može promatrati s različitih aspekata; ekonomskog, psihološkog i geografskog, ali se prvenstveno prati zbog ekonomskih učinaka koje generira (Petrić, 2014).

Turizam je kompleksan društveno-ekonomski fenomen koji sadrži mnoštvo međusobno zavisnih faktora. Znanstvenici u svojim radovima koriste faktore receptivnih tržišta (zemlje odredišta) i/ili emitivnih tržišta (zemlje polazišta), međutim većina znanstvenika u svojim istraživanjima kombinira faktore i iz emitivnih i iz receptivnih zemalja.

Iz analiziranih radova je uočeno da se turistička potražnja najčešće mjeri brojem noćenja turista, brojem dolazaka turista i/ili turističkom potrošnjom. Dohodak u emitivnim zemljama je nezavisna varijabla koja se najčešće koristi u istraživanjima turističke potražnje. Većina znanstvenika je potvrdila značajnu i pozitivnu vezu između BDP-a emitivnih zemalja i turističke potražnje (Dritsakis, 2004, Botti et al., 2006, Garĩn-Muńoz, 2006, Bentum-Ennin, 2014), dok u jednom dijelu radova ta veza nije značajna (Proença i Soukiazis, 2005, Culiu, 2014). Mani broj znanstvenika je koristio bruto domaći proizvod (BDP) receptivne zemlje kao jednu od varijabli koja objašnjava turističku potražnju. Pozitivan utjecaj BDP-a receptivnih zemalja na rast turističke potražnje potvrđen je u istraživanju Eugenio-Martína, Moralesa i Scarpe (2004) za latinoameričke zemlje, Culiuc (2014) za sve svjetske i OECD zemlje. Potvrđena je značajna i negativna veza između turističke potražnje i relativnih cijena receptivnih zemalja (Garĩn-Muńoz, 2006, Brida i Risso, 2009). Finalna potrošnja kućanstava također ima pozitivni predznak, ali njeno značenje varira ovisno o analiziranom receptivnom tržištu (Song et al., 2010). Stope nezaposlenosti u pravilu imaju negativan smjer, ali nisu uvijek značajan pokazatelj (Serra et al., 2014). Istraživanja su potvrdila značajan i pozitivan utjecaj tečaja receptivnih tržišta (Dritsakis, 2004 i 2012),

U nekim istraživanjima razmatrani su i još neki faktori. Tako Brida i Risso (2009) te Bentum-Ennin (2014) u model uvrštavaju troškove transporta, a rezultati variraju od značajnih pokazatelja negativnog smjera, do neznačajnih pokazatelja. Naudé i Saayman (2005) dolaze do zaključka da je politička stabilnost i turistička infrastruktura receptivne zemlje značajan faktor turističke potražnje s pozitivnim utjecajem dok Bentum-Ennin (2014) zaključuje da konkurentsko tržište ima značajan i negativan utjecaj na turističku potražnju. U svom radu Proença i Soukiazis (2005) koriste smještajne kapacitete u receptivnoj zemlji i omjer javnih investicija u receptivnoj zemlji kako bi istražili utjecaj na turističku potražnu, te zaključuju da je smještajni kapacitet glavna odrednica kojom se može objasniti turistička potražnja. Fourie i Santana–Gallego (2013) za analizu turističke potražnje koriste kapitalna ulaganja u receptivnoj zemlji, a kako bi prikazali troškove transporta koriste udaljenost između zemalja, te zaključuju da je većina varijabli značajna.

Znanstveni radovi koji analiziraju turističku potražnju u Hrvatskoj u nekim segmentima imaju različite zaključke. Stručka (2000), Mervar i Payne (2007), Škrinjarić (2011) zaključuju da je turistička potražnja emitivnih tržišta u pravilu elastična na promjene dohotka kod glavnih emitivnih zemalja. Međutim, u svom radu Stručka (2000) također dolazi do rezultata da tržište Češke ima negativni predznak kod dohodovnog koeficijenta mjerenog realnim BDP-

om emitivnog tržišta što sugerira da je Hrvatska kao receptivna destinacija na tom tržištu inferiorno dobro. Međutim, Belullo (2011) zaključuje da utjecaj realnog BDP-a emitivnih zemalja varira ovisno o strukturi gostiju. Za razliku od istraživanja u ostalim inozemnim zemljama realni tečaj nema statistički značajan utjecaj na kretanja inozemne turističke potražnje za odredištima u Hrvatskoj (Mervar i Payne, 2007). Cjenovna potražnja definirana prilagođenim relativnim cijenama uglavnom je negativno elastična (Stručka, 2000). Troškovi transporta su se pokazali kao neznačajni, dok se politička nestabilnost pokazala značajnom i negativnog smjera (Mervar i Payne, 2007). Kapitalna ulaganja imaju značajnu i pozitivnu vezu s turističkom potražnjom (Mervar i Payne, 2007).

Vidljivo je da u novije vrijeme samo nekolicina radova analizira determinante turističke potražnje u Republici Hrvatskoj. Većina radova (Belullo i Križman, 2000, Mervar i Payne, 2007, Škinjarić, 2011) promatraju broj noćenja na nivou države dok Škufilić i Štoković (2011) analiziraju broj noćenja u hotelima promatrajući četiri hrvatske turističke regije; Istru, Dalmaciju, Kvarner i kontinentalnu Hrvatsku. Belullo (2011) je pak koristeći broj noćenja analizirao potražnju turističkog naselja „Barbariga“ u Istri. U svjetskim okvirima sve češće se istraživanja provode na nivou regija unutar države. Njihovi rezultati ukazuju da različite regije imaju različite determinante (Proença i Soukiazis, 2005, Brida i Risso, 2009, Serra et al., 2014), odnosno da se zaključak teško donosi na nivou države. Imajući u vidu različitu ponudu u hrvatskim županijama, te različitu strukturu gostiju koji posjećuju iste, uočili smo potrebu istraživanje turističke potražnje svesti na nivo županije. Nakon provedene analize kako teorijskih stajališta tako i empirijskih zaključaka, **problematika istraživanja** se odnosi na proučavanje utjecaja glavnih makroekonomskih čimbenike emitivnih turističkih zemalja i makroekonomskih čimbenike receptivne zemlje na primorske županije Republike Hrvatske.

1.2. Predmet istraživanja

Obzirom da turizam predstavlja dominantnu granu u hrvatskom gospodarstvu, a na broj noćenja u primorskim županijama otpada 90% ukupnog broja noćenja u Hrvatskoj, analiza funkcije turističke potražnje u primorskim županijama je više nego opravdana. Tome dodatno doprinosi činjenica se samo nekolicina hrvatskih znanstvenika bavi problematikom turističke potražnje na nivou države (Stručka, 2000, Belullo i Križman, 2000, Mervar i Payne, 2007, Škrinjarić, 2011) te na nivou regije (Škufilić i Štoković, 2011) i na nivou turističkog naselja u Hrvatskoj (Belullo, 2011),dok ne postoji rad koji analizira turističku potražnju na nivou županija.

Predmet istraživanja u ovom radu je prvenstveno usmjeren na istraživanje utjecaja makroekonomskih pokazatelja emitivnih tržišta na broj noćenja turista u primorskim županijama. Također će se pokušati dokazati i utjecaj makroekonomskih pokazatelja receptivne zemlje, odnosno makroekonomskih pokazatelja regija (županija) na broj noćenja turista u primorskim županijama.

Predmet istraživanja je određen prostorno i vremenski. Analiza obuhvaća broj noćenja turista u primorskim županijama prema nacionalnosti inozemnih turista iz Europe u razdoblju od 2004. godine do 2014. godine. Prilikom odabira emitivnih zemalja vodilo se računa da se odaberu zemlje koje predstavljaju većinski udio u broju noćenja na promatranim primorskim županijama. Podaci su dobiveni od Turističkih zajednica Dubrovačko-neretvanske županije, Splitsko-dalmatinske županije, Šibensko-kninske županije, Zadarske županije, Ličko-senjske, Primorsko-goranske županije i Istarske županije, Zavoda za statistiku Republike Hrvatske, Područne jedinice zavoda za statistiku Splitsko-dalmatinske županije te su preuzeti s internetskih stranica Hrvatskog zavoda za zapošljavanje, World Bank, Eurostate i OECD-a.

Dakle, koristeći panel podatke analizirat će se turistička potražnja primorskih županija Republike Hrvatske. Funkcija turističke potražnje se modelira putem makroekonomskih čimbenika emitivne zemlje. Makroekonomski pokazatelji emitivnih zemalja su: BDP po glavi stanovnika, stopa nezaposlenosti, indeks potrošačkih cijena i izdaci konačne potrošnje po glavi. S obzirom na rezultate prethodnih istraživanja u modeliranje turističke potražnje je potrebno uključiti i pokazatelje turističkih odredišta. Stoga će se u model uključiti realni tečaj Hrvatske, dok će se ostali makroekonomski podaci receptivne zemlje svesti na nivo županije: BDP po glavi stanovnika promatrane županije i sezonska zaposlenost promatrane županije.

1.3. Istraživačke hipoteze

Na osnovi izvedene problematike i predmeta istraživanja, u cilju donošenja konkretnih zaključaka, postavljaju se **istraživačke hipoteza** uz teorijsko i empirijsko obrazloženje.

Hipoteza 1: Makroekonomski pokazatelji emitivnih tržišta značajno utječu na rast noćenja stranih turista u primorskim županijama Republike Hrvatske

Cilj hipoteze je utvrditi da rezultati dosadašnjih znanstvenih radova u kojima se sugerira da makroekonomski pokazatelji imaju značajan utjecaj na rast noćenja turista imaju značajan utjecaj i kada se istraživanje spusti na regionalni nivo, odnosno na nivo primorskih Županija. Dodatno, testiranje ove hipoteze će dati odgovor postoji li razlika utjecaja makroekonomskih pokazatelja emitivnih zemalja između županija.

Istraživanja koja se bave ovom problematikom sugeriraju da makroekonomski pokazatelji imaju značajan utjecaj na rast noćenja turista (Belullo i Križman, 2000, Botti et al., 2006, Mervar i Payne, 2007, Brida i Risso, 2009, Song et al., 2010, Škufilić i Štoković, 2011, Šimundić, 2015). Međutim važnost različitih makroekonomskih pokazatelja se mijenja s obzirom na korišteni skup zemalja ili zemlju, razdoblje te metodu. Tako primjerice većina istraživanja potvrđuje pozitivnu vezu između gospodarskog rasta emitivnih zemlja i turističke potražnje (Botti et al., 2006, Dritsakis, 2012, Song et al., 2010, Bentum-Ennin, 2014), dok neka istraživanja zaključuju da ne postoji veza između istih (Proença i Soukiazis, 2005, Culiuc, 2014). Slično i kod istraživanja provedenih za Hrvatsku postoji razlika. Jedan dio znanstvenika potvrđuje pozitivnu vezu između gospodarskog rasta emitivnih zemlja i turističke potražnje (Belullo i Križman, 2000, Škufilić i Štoković, 2011) dok neka istraživanja zaključuju da ne postoji veza između gospodarskog rasta i turističke potražnje za sva promatrana emitivna tržišta (Stručka, 2000).

Većina radova je potvrdila da postoji značajna i negativna veza između turističke potražnje i relativnih cijena (Garĩn-Muńoz, 2006, Botti et al., 2006, Brida i Risso, 2009, Škufilić i Štoković, 2011). Finalna potrošnja kućanstava također ima pozitivni predznak, ali njen značaj varira ovisno o analiziranom receptivnom tržištu (Serra et al., 2014). Stope nezaposlenosti u pravilu imaju negativan smjer, ali nisu uvijek značajan pokazatelj (Serra et al., 2014). Većina znanstvenika je u svojim radovima promatrala tečaj emitivnih zemalja koji se pokazao značajnim i pozitivnog smjera.

Hipoteza 2: Makroekonomski pokazatelji receptivne zemlje i promatranih županija značajno utječu na rast noćenja stranih turista u primorskim županijama Republike Hrvatske

Ipak, turistička potražnja se ne može modelirati samo pomoću determinanti emitivnih zemlja. U obzir treba svakako uzeti i pokazatelje receptivnih zemalja. Dosadašnja istraživanja su ustanovila da pokazatelji receptivnih zemlja imaju značajan utjecaj (Dritsakis, 2004, Proença i Soukiazis, 2005, Mervar i Payne, 2007, Škufilić i Štoković, 2011). Većina svjetskih istraživanja je potvrdila značajan utjecaj makroekonomskih čimbenika na turističku potražnju, kao što su BDP, prihodi, cijene, tečaj i trošak transporta. Slično kao i kod inozemnih radova najznačajniji čimbenici turističke potražnje za Republiku Hrvatsku su realni BDP, relativne cijene, dohodak, cijena supstituta, kapitalna ulaganja te politički događaji.

Imajuće u vidu sve navedeno i s obzirom da će se u ovom radu istraživanje spustiti na nivo županija i analizirani pokazatelji će se, ovisno o mogućnostima, svesti na razinu županije. Stoga će se u ovome radu turistička potražnja modelirati koristeći BDP i sezonsku zaposlenost promatrane županije dok će se indeks realnog tečaja promatrati na nivou države.

1.4. Ciljevi istraživanja

Ciljevi ovog rada su sljedeći

1. Dokazat utjecaj makroekonomskih pokazatelja emitivnih tržišta na broja noćenja njihovih turista u primorskim županijama.
2. Utvrditi utječu li makroekonomski pokazatelji emitivnih zemalja jednako na sve promatrane županije.
3. Istražiti koji pokazatelji receptivne zemlje imaju značajan utjecaj na turističku potražnju.
4. Odabrati najbolji procjenitelj za analizu panel podataka i postavljenih ekonomskih relacija.

1.5. Metode istraživanja

U posljednje vrijeme se za analizu turističke potražnje sve više koristi panel analiza (Garĭn-Muńoz, 2004, Brida i Risso, 2009, Serra et al., 2014, Škrinjarić, 2011). Za razliku od pripadajućih prostornih i vremenskih nizova panel podaci sadrže veći broj podataka, a procjene dobivene panel analizom su preciznije jer se zavisna varijabla mijenja po jedinici promatranja i po jedinici vremena. Umanjena je pristranost, umanjen je problem multikolinearnosti, manja je osjetljivost na netipične vrijednosti, a panel analiza omogućuje i mjerenje unutar jedinica promatranja.

Kako bi se potvrdile postavljene hipoteze rad će se sastojati od dva dijela: teorijski dio istraživanja i empirijski dio istraživanja. Primijenit će se opće znanstvene metode kao što su metoda analize i sinteze, metoda deskripcije, metoda klasifikacije, metoda kompilacije, induktivna i deduktivna metoda, statističke metode.

U teorijskom dijelu rada će se koristiti metoda analize koja će omogućiti raščlanjivanje složenih pojmova i zaključaka na jednostavne dijelove. Metoda sinteze će omogućiti povezivanje izdvojenih elemenata i procesa u jedinstvene cjeline. Metodom deskripcije će na jednostavan način opisati činjenice, procese i predmete te njihova empirijska potvrđivanja odnosa i veza, ali bez znanstvenog tumačenja i objašnjavanja. Metodom klasifikacije će se složeni pojmovi podijeliti na jednostavnije, dok će se metoda komparacije primjenjivati za uspoređivanje različitih mjera, teorija i metoda. Metode indukcije će se koristiti za donošenje zaključaka na temelju analize ograničenog broja pojedinačnih pojava, dok će se metodom dedukcije omogućiti da se iz općih sudova izvode posebni i pojedinačni zaključci.

U dijelu empirijskog istraživanja će se za ispitivanje postavljene hipoteze koristiti statističke metode kako bi se dala egzaktna ocjena zakonitosti pojave na osnovi osnovnih obilježja.

Sve potrebne analize, utjecaje među varijablama, tablično i grafičko prikazivanje varijabli i testiranje će se provoditi korištenjem programskog paketa STATA.

1.6. Doprinos istraživanja

Broj turista u Hrvatskoj se povećava iz godine u godinu, a županija Splitsko-dalmatinska je 2014. godine sudjelovala sa 17% u ukupnom broju dolazaka turista što je stavlja na treće mjesto iza Istarske županije sa 23%, te Primorsko-goranske županije koja sudjeluje sa svega jednim postotnim poenom više, odnosno sa 18%. U posljednjih 14 godina, Splitsko-dalmatinska županija, uz Zadarsku županiju, bilježi najveći porast broja noćenja turista. Udio u ukupnom broju noćenja turista se povećao sa 14% u 2000. godini na 18% u 2014. godini.

Gledajući na nacionalnoj razini primorske županije po broju noćenja turista sudjeluju s više od 90% u ukupnom broju.

Znanstveni radovi koji se bave ovom problematikom u Hrvatskoj su većinom analizirali turističku potražnju na nacionalnoj razini, dok su Škufilić i Štoković (2011) svoja istraživanja spustili na niži nivo, te analizirali turističku potražnju u četiri hrvatske regije. Međutim, još uvijek ne postoje radovi koji koriste panel podatke za analizu turističke potražnje u Hrvatskoj na nivou županije.

U dosadašnjim znanstvenim radovima su se koristili makroekonomski čimbenici receptivnih i/ili emitivnih zemalja. Niti jedan rad nije koristio makroekonomski čimbenike županije. Stoga će uvođenjem BDP po glavi stanovnika svake analizirane županije i broja zaposlenih u sezonskim poslovima promatranih županija također biti doprinos ovom istraživanju.

Analizirajući primorske županije, svaku za sebe, biti će moguće uočiti eventualne razlike u svezi utjecaja makroekonomskih pokazatelja na turističku potražnju.

Ne može se zanemariti ni doprinos koji će se ostvariti dokazivanjem ili opovrgavanjem postavljene hipoteze koja će omogućiti kreatorima turističkih politika na lokalnoj razini bolje razumijevanje učinka makroekonomskih pokazatelja emitivnih tržišta na njihovu županiju. U skladu s tim će im biti omogućeno donošenje i provođenja odluka koje su prihvatljivije potrebama njihove županije.

Rad može poslužiti i kao temelj za daljnja istraživanja koja bi se odnosila na proučavanje čimbenika koji utječu na turističku potražnju, izrazito turističkih, primorskih županija.

1.7. Struktura diplomskog rada

Diplomski rad se sastoji od pet poglavlja.

Uvodni dio rada definira problem i predmet istraživanja, definira istraživačke hipoteze, ciljeve istraživanja, objašnjava metode, kao i doprinos istraživanju.

Drugo poglavlje u teorijskom dijelu se bavi razvojem turizama i osnovnim značajkama turističke potražnje u Republici Hrvatskoj.

U trećem poglavlju slijedi teorijsko objašnjenje panel analize, njenih specifičnosti te modela koji se najčešće koriste u ekonometrijskim analizama.

Poglavlje Empirijska analiza i rezultati započet će definiranjem varijabli i deskriptivnom statistikom. Nakon toga će se na temelju statističkih testova odabrati najprikladniji panel modeli koji će se koristiti za procjenu modela turističke potražnje za svaku primorsku županiju. Dobiveni rezultati će se interpretirati te će se u konačnici prihvatiti ili opovrgnuti postojeće hipoteze.

U posljednjem poglavlju će se izložiti pregled cjelokupnog rada, kao i zaključci doneseni na osnovi dobivenih rezultata te će se iznijeti preporuke za daljnja istraživanja.

2. RAZVOJ TURIZAMA I OSNOVNE ZNAČAJKE TURISTIČKE POTRAŽNJE U REPUBLICI HRVATSKOJ

2.1. Povijesni razvoj turizma

Bez obzira na različite pokušaje sistematizacije povijesnog razvoja pojave putovanja i turizma, svi oni navode na isti zaključak. A to je da je putovanje pojava stara koliko i čovječanstvo, a da je turizam, bez obzira na njegovu blisku vezu s putovanjem, pojava čiji nastanak vezujemo uz napredak znanosti i tehnologije (naročito u oblasti prometa), uz porast životnog standarda te slobodnog vremena (Petrić 2013).

Prema Petrić (2013), neki teoretičari smatraju da se početak razvoja turizma poklapa s pojavom novca i razvojem trgovine oko 4000 g. pr. Kr. U tom razdoblju su se počela javljati prva putovanja koja su bila motivirana trgovinom, kulturnim potrebama, potrebama za stjecanje novih znanja ili zdravstvenim razlozima. U antičkom dobu se počinju javljati putovanja motivirana razonodom i rekreacijom, dok propašću Zapadnog Rimskog Carstva 476. g. takav vid putovanja je nestao na duže razdoblje. Ponovna uspostava putovanja slijedi tek u 12. st. a rezervirana su za vitezove, lutajuće propovjednike i pustolove. Prva masovnija putovanja potaknuta su religioznim motivima i javljaju se u srednjem vijeku. U 18. stoljeću, u razdoblju humanizma i renesanse, intelektualna elita iz razvijenih Europskih zemalja putovanjima zadovoljava svoje potrebe za upoznavanjem novih trendova i doživljavanja prirode. Od sredine 16. stoljeća pa do sredine 19. stoljeća putovanja su rezervirana za mlade pripadnike plemstva, aristokracije i bogatih trgovaca, i kao takva su postala neizostavnim dijelom školovanja i obrazovanja mladih intelektualaca. Ova putovanja se uvelike razlikuju od dotadašnjih putovanja, stoga ih neki teoretičari smatraju „*pretečom pravih turističkih putovanja*“. Obzirom na navedeno može se zaključiti da se putovalo tijekom cijele ljudske povijesti, međutim, zbog nedostatka osnovnih preduvjeta za nastanak i razvoj turizma u pravom smislu te riječi (razlozi zbog kojih se putovalo, način organizacije putovanja i sl.), ova putovanja se ne mogu nazvati turističkim putovanjima.

Tek sredinom 19. stoljeća dolaze etape koje se mogu nazvati turističkim etapama. Te etape se dijele na nekoliko razdoblja. Prva etapa se proteže od 1845-1875. godine i predstavlja razdoblje u kojem je u turističkim putovanjima prevladavala aristokracija. Druga etapa od 1875-1910. godine je značajna jer se javljaju prva turistička mjesta, a u putovanjima sudjeluje

i buržoazija. Treća etapa se javlja nakon 1910. g. kada se, nakon borbi za radnička prava, u turistička putovanja uključuje i srednji sloj građanstva.
Uz navedene razvojne etape turizma koje se najčešće korištene, neki znanstvenici povijest turizma dijele na drugačije etape. Pa tako Burkart i Medlik (1981) povijest turizma dijele na tri epohe i to: epoha prije industrijske revolucije, epoha željeznice i epoha iza Drugog svjetskog rata (doba automobila i aviona).

Prema Lickorishu i Jenkinsu (2006) povijest razvoja turizma dijeli se na četiri faze. Pretpovijest turizma je razdoblje koje obuhvaća srednjevjekovno doba i početak 17. stoljeća. Razdoblje željezničkog prometa obilježava drugu fazu razvoja turizma. Treća faza je faza međuratnog razdoblja između 1918. i 1939. godine, dok je četvrta faza razvoja turizma koja se još naziva i "uzletna faza" započela nakon Drugog svjetskog rata i traje sve do našeg vremena.

Prema Petrić (2013) početak turizma u Hrvatskoj se može vezati uz dolaske hodočasnika ili putovanja iz zdravstvenih razloga, ali tradicija organiziranog turizma u Hrvatskoj duga je oko 150 godina. Kao i u svijetu, tako i u Hrvatskoj, preduvjet za ozbiljnije bavljenje turizmom vezivalo se uz izgradnju cestovnih i željezničkih prometnica te uvođenje parobrodskih linija na Jadranskom moru. Prvi hoteli se otvaraju u razdoblju prije Prvog svjetskog rata, ponajprije uz jadransku obalu, kada su primorska mjesta postala središtima zdravstvenoga turizma.

U razdoblju između dva rata turizam u Hrvatskoj je dobio snažan zamah s prosječno milijun turističkih dolazaka godišnje. Otvorene su mjenjačnice, uvedene obvezne boravišne pristojbe, uspostavljene zrakoplovne linije, te su se izdavale turističke revije.

Međutim, tek zadnjih šezdesetak godina o turizmu možemo govoriti kao o masovnom fenomenu. Nakon Drugoga svjetskog rata obnovljena je turistička infrastruktura, počeli su se osnivati nacionalni parkovi i parkovi prirode te dramski, filmski i glazbeni festivali. Gospodarska ekspanzija 1960-ih godina potakla je gradnju mnogobrojnih turističkih objekata, uglavnom na Jadranu.

U posljednjih tridesetak godina turistički promet u Hrvatskoj obilježavaju tri bitno različite etape. U drugoj polovici 1980-ih broj turističkih dolazaka nastavio se kretati ujednačenim trendom povećanja te je prešao 10 milijuna dolazaka. Potom je slijedila etapa Domovinskoga rata u kojoj je broj turističkih dolazaka strelovito pao, naročito u primorskim krajevima. U

poslijeratnom razdoblju taj broj opet raste te niz hrvatskih turističkih mjesta bilježi snažan porast broja stranih turista. U posljednjih nekoliko godina registrirano je više od 10 milijuna dolazaka, odnosno oko 60 milijuna turističkih noćenja, te se Hrvatska ponovno pozicionira u vrh svjetske turističke potražnje.

Analizom turističke potražnje od 1980. do danas uočeno je da je udio stranih turista u Republici Hrvatskoj veći nego udio domaćih turista. Tradicionalno to su gosti iz Njemačke, Slovenije, Austrije, Italije, Češke i Slovačke. U posljednjih je desetak godina povećan broj turista iz Francuske, Nizozemske, Poljske, ali i prekomorskih zemalja.

U primorskom dijelu Republike Hrvatske turizam je nedvojbeno najunosnija djelatnost, osobito tijekom ljeta. Ljetna turistička sezona uglavnom traje od početka lipnja do kraja rujna i glavni je pokretač razvoja turističkih područja primorske Hrvatske. 2011. godine je u primorskoj Hrvatskoj zabilježeno 56 milijuna turističkih noćenja (94% ukupnog broja noćenja u Hrvatskoj). Od ukupnog broja turističkih noćenja 2012. godine (63 milijuna), 92% čine noćenja stranih gostiju. Najviše je takvih noćenja (32%) ostvareno u Istarskoj županiji, koja je i u infrastrukturnom smislu turistički najrazvijenija. Slijede ostale primorske županije: Primorsko-goranska (19%), Splitsko-dalmatinska (17%), Zadarska (11%) te Dubrovačko-neretvanska, Šibensko-kninska i Ličko-senjska (zajedno 17%). Sve ostale, tj. kontinentalne županije ostvaruju 4% ukupnog broja noćenja. U skladu s tim raspoređeni su i smještajni kapaciteti, uglavnom na jadranskoj obali.[1]

2.2. Osnovne značajke turističke potražnje

Pema Petrić (2013) ekonomska definicija turističke potražnje pretpostavlja ukupnu količinu roba i usluga koje je moguće plasirati na određenom turističkom tržištu u nekom vremenu uz određenu razinu cijena. Što bi značilo da turističku potražnju predstavlja skupina potencijalnih turista-potrošača koja svojim stavovima, navikama, željama i mogućnostima određuju količinu, kvalitetu te cijene pojedinih roba i usluga na turističkom tržištu.
Dobra koja se prodaju i kupuju, te noćenje, kao usluga koja se nudi u turističkim destinacijama su usko vezani uz pojam turist. Stoga se turistička potražnja može sagledavati i kroz broj realiziranih noćenja i kroz broj turista koji su posjetili turističku destinaciju. Turistička potražnja se realizira na tržištu, koje nije iracionalan pojam već određuje područja

[1] Institut za turizam (2016) dostupno na http://www.iztzg.hr/UserFiles/Pdf/Tomas/Tomas-Ljeto-2011-knjiga.pdf {pristupljeno 06.08.2016.}.

na kojima se susreću ponuda i potražnja. Obilježja turističke potražnje su dislociranost, heterogenost (kompleksnost), elastičnost, mobilnost te sezonski karakter.
Dislociranost turističke potražnje od turističke ponude predstavlja prostornu odvojenost tržišta turističke potražnje i turističke ponude. Heterogenost turističke potražnje podrazumijeva postojanje neodređenih skupina ljudi koji imaju različite turističke potrebe koje se zadovoljavaju na različite načine u različitim turističkim odredištima i u različito vrijeme. Elastičnost turističke potražnje predstavlja promjene veličine turističke potražnje za određenom turističkom uslugom uslijed promjena osobnog dohotka, cijene ili nekog od bitnih elemenata unutar turističke ponude. Reagiranje turističke potražnje na porast ili pad cijena, odnosno na porast ili pad osobnog dohotka se naziva primarna elastičnost, dok sekundarna elastičnost pretpostavlja reagiranje turističke potražnje na promjene u strukturi turističke ponude. Mobilnost turističke potražnje je izravna posljedica omasovljenja turističke potražnje uslijed visoke urbanizacije i razvoja suvremenih tehnologija. Sezonski karakter turističke potražnje je determinirana s dva uzroka. Prvi proizlazi iz klimatskih prilika receptivnog tržišta, a drugi se javlja kao odgovor na takve prilike, odnosno navike turista da godišnje odmore koriste u određenim vremenskim intervalima.

Turističku potražnju se u pravilu prati zbog ekonomskih učinaka koje generira, ali i zbog kreiranja politike koje mogu pridonijeti rastu i razvoju turizma.

Turistička potražna se može sagledavati s empirijskog i s teorijskog aspekta. Empirijsko sagledavanje turističke potražnje se u pravilu provodi uz pomoć anketnih istraživanja koji imaju za cilj utvrditi strukturu turista u konkretnoj turističkoj destinaciji.

S teorijskog aspekta cilj je potražnju sagledati u međuovisnosti s elementima koji ju određuju, kao što su cijene, dohodak i sl.

Za formiranje turističke potražnje potrebno je zadovoljiti unutarnje i vanjske pretpostavke. Unutarnje pretpostavljaju postojanje turističke potrebe, postojanje turističkih motiva, te potrebe za rekreacijom. Marković (1987) vanjske faktore potražnje dijeli na objektivne i subjektivne faktore. Objektivne pretpostavke proizlaze prvenstveno iz viška slobodnog vremena uvjetovanih životnim standardom, raspoloživih novčanih sredstava te životnom i radnom okolinom. Životni standard obuhvaća različite ekonomske, društvene, psihološke, biološke i ekološke uvjete u kojima živi i radi današnji čovjek, a pretpostavka su o imanju viška slobodnog vremena kojeg je pojedinac spreman utrošiti na putovanja. Standard

potencijalnog turističkog potrošača, koji se može promatrati kroz slobodna sredstva, je bitan preduvjet za odluku o turističkoj potrošnji, iako nije toliko ograničavajući kao vrijeme jer se u nedostatku likvidnosti može zadužiti u budućnosti. S promjenom načina života, radna i životna sredina je uvjetovala potrebu za turističkom rekreacijom. Politička sigurnost je također bitan faktor turističke potražnje. U ostale objektivne faktore potražnje mogu se ubrojiti pojedine socijalno-turističke tekovine te faktori bez kojih ne bi mogli djelovati ostali objektivni faktori. Iz objektivnih pretpostavki turističke potražnje proizlaze idealna, potencijalna, realna i efektivna masa potražnje. Idealna masa je ukupan broj stanovnika na određenom emitivnom prostoru umanjen za apsolutne apstinente. Potencijalna masa predstavlja ljude koji imaju višak slobodnog vremena i višak slobodnih financijskih sredstava i sposobni su se uključiti u turistička kretanja, ali zbog određenih zapreka nisu u mogućnosti postati turistička potražnja. Realna masa je masa ljudi koja ima i višak slobodnog vremena i višak slobodnih financijskih sredstava ali i čvrstu odluku da će taj isti novac i vrijeme utrošiti na turističko putovanje bez obzira na mjesto, vrijeme i način realizacije. Efektivna masa jest čista masa ljudi koja je ušla u turističku statistiku kroz broj ostvarenih dolazaka i ostvarenih noćenja. To su turisti koji su svoj boravak realizirali i vratili se u domicil. To je konačan rezultat tržišnog djelovanja kao zemlje, regije mjesta i/ili hotela.

Subjektivni faktori potražnje su oni faktori koji su povezani sa subjektivnim ponašanjem pojedinca, a počinju djelovati tek nakon postojanja objektivnih. Kada je turistička potražnja pojedinca temeljena na razumnim razlozima i postupcima govori se o racionalnim subjektivnim faktorima turističke potražnje. Međutim, kada pojedinac postupa bez razloga koji se mogu objasniti razumom ili logikom (moda, ugled, snobizam, prestiž i sl.), govori se o iracionalnim faktorima. Neki autori u iracionalne faktore ubrajaju i ljubav, religiozna uvjerenja i sl.

Lickorish i Jenkins (2006) za formiranje turističke potražnje te faktore dijele na ekonomske i neekonomske faktore. Ekonomski faktori potražnje su realni dohodak potrošača, odnosno raspoloživa financijska sredstva korigirana određenim inflacijskim utjecajem na cijene, slobodan dohodak, odnosno iznos koji se dobije kada se od raspoloživog dohotka odbiju osnovni troškovi života, te razina obiteljskog prihoda, odnosno prihodi koje participiraju svi članovi obitelji. Također, autori tvrde da na obujam turističke potražnje utječe i stupanj atraktivnosti destinacije te cijena usluga u destinaciji. Neekonomski faktori poticaja turističkog prometa se dijele na: strukturne (populacija i aktivnosti u slobodnom vremenu), te

motivacijske (obrazovanje, urbanizacija, marketing, trgovina putovanjima i atraktivnost destinacije).

Petrić (2012) nadalje objašnjava turističku potražnu s tri aspekta. S ekonomskog aspekta turistička potražnja koja se definira kao ukupna količina roba i usluga koje su kupci spremni kupiti na tržištu u određenom vremenu i po određenim cijenama. Analizira se elastičnost turističke potražnje, odnosno ovisnost o turističke potražnje promjeni cijena i dohotka. S aspekta psihologije potražnja se promatra kroz motivaciju i ponašanje kupaca, a s geografskog aspekta turistička potražnja se promatra kroz ukupan broj osoba koje putuju ili žele putovati radi korištenja turističkih sadržaja i usluga u mjestima udaljenim od njihova mjesta boravka i rada.

2.3. Pregled dosadašnjih istraživanja turističke potražnje

2.3.1. Pregled znanstvenih istraživanja turističke potražnje u svijetu

Turizam je kompleksan društveno-ekonomski fenomen koji sadrži mnoštvo međusobno zavisnih faktora. Znanstvenici koji modeliraju potražnju s ekonomskog aspekta u svojim radovima koriste faktore receptivnih tržišta (zemlje odredišta) i/ili emitivnih tržišta (zemlje polazišta), međutim većina znanstvenika u svojim istraživanjima kombinira faktore i iz emitivnih i iz receptivnih zemalja.

Kako bi objasnio turističku potražnu mjerenu brojem dolazaka turista iz emitivnih zemalja (Njemačka i Velika Britanija) u Grčku u razdoblju od 1960. godine do 2000. godine, Dritsakis (2004) koristi makroekonomske čimbenike uključujući realni BDP po stanovniku, trošak transporta (mjeren cijenom avionske karte) i realni tečaj receptivne zemlje. Zaključuje da postoji jaka uzročna veza između međunarodnih turističkih prihoda i gospodarskog rasta te jaka uzročna veza između realnog tečaja i ekonomskog rasta.

Eugenio-Martína et al. (2004) analiziraju odnos između turizma i gospodarskog rasta za latinoameričke zemlje od 1985. do 1998. godine. Latinoameričke zemlje dijele u tri skupine prema visini BDP-a po stanovniku receptivne zemlje. U svom radu koriste sigurnosti zemlje, cijene i razinu obrazovanja u receptivnoj zemlji. Rezultati pokazuju da je rast turizma bio povezan s gospodarskim rastom samo u zemljama s niskim i srednjim prihodima, ali ne u zemljama s visokim dohotkom. Za cijeli niz zemalja je dokazana pozitivna povezanost s BDP-om po stanovniku, međunarodnoj trgovini i očekivanom trajanju života. Rezultati upućuju da je varijabla cijena (definirana tečajem) statistički neznačajna u svim modelima što

sugerira da su druge varijable više relevantne za izbor latinoameričkih zemalja kao turističkog odredišta.

Naudé i Saayman (2005) analiziraju turističku potražnju kroz dolaske turista za 43 afričke zemlje u razdoblju od 1996. godine do 2000. godine. Uobičajene determinante potražnje kao dohodak, relativne cijene, troškovi putovanja zrakom, infrastruktura i marketing se nisu pokazale toliko značajnima kao u istraživanjima za druge skupine zemalja što upućuje da bi trebali poraditi na političkoj stabilnosti. politička

Proença i Soukiazis (2005) modeliraju turističku potražnju u regijama Portugala koristeći faktore receptivnog i emitivnih tržišta. Dakle, oni istražuju kako realni dohodak po stanovniku emitivnih zemalja (Španjolske, Njemačke, Francuske i Velike Britanije), relativne cijene, smještajni kapacitet u receptivnoj zemlji te omjer javnih investicija u receptivnoj zemlji utječe na omjer turističke potrošnje u regijama Portugala. Donesen je zaključak da je turizam luksuzna roba te da relativni troškovi života ne utječe bitno na odluku turista o izboru Portugala kao odredišta za odmor. Granica otvorenosti nema veliki utjecaj na veći turistički priljev u zemlju dok su smještajni kapacitet glavna odrednica kojom se može objasniti turistička potražnja u Portugalu.

Garĩn-Muńoz (2006) modelirajući turističku potražnju za Kanarskim otocima koristi podatke 15 najvažnijih emitivnih turističkih tržišta u razdoblju 1992. godine do 2002. godine te kombinira faktore emitivnih i receptivnih zemalja. Istražuje utjecaj BDP po glavi stanovnika receptivne zemlje, trošak življenja turista i trošak transporta (mjeren kroz cijenu goriva) na broj dolazaka turista po glavi stanovnika. Uz navedene čimbenike koristi i terorističke napade za dummy varijablu. Dobiveni rezultati su pokazali da je turistička potražnja za Kanarskim otocima ovisna o BDP po glavi stanovnika receptivne zemlje te o relativnim cijena i troškovima putovanja između emitivnih i receptivnih tržišta.

Botti et al. (2006) modeliraju turističku potražnju u Francuskoj u razdoblju od 1975. godine do 2003. godine analizirajući utjecaj makroekonomskih čimbenika kao što su realni BDP u stalnim cijenama emitivnih zemlje i relativne cijene na potrošnju turista iz Amerike, Velike Britanije, Španjolske i Italije. Svojim istraživanjem su potvrdili da realni BDP emitivne zemlje ima pozitivan utjecaj na turističku potrošnju u Francuskoj dok je odnos turističke potrošnje i relativnih cijena negativnog smjera.

Brida i Risso (2009) analiziraju turističku potražnju u njemačkoj regiji Južnog Tirola za razdoblje od 1987. godine do 2007. godine. Turističku potražnju modeliraju putem dohotka (BDP po glavi stanovnika Njemačke), volumena turizma (broj njemačkih turista za svako odredište), cijene (relativne cijene između Italije i Njemačka), cijene sirove nafte (pokazatelj troškova putovanja) te istražuju njihov utjecaj na broj noćenja turista. Rezultati istraživanja su potvrdili da potražnja prethodnih razdoblja ima pozitivan i značajan učinak na stvaranje potražnje budućih razdoblja odražavajući lojalnost turista te da je turistička potražnja ovisna o dohotku. Također je dokazano da troškovi putovanja i relativne cijene imaju značajan, ali negativan utjecaj na potražnju.

Song et al. (2010) proučavaju utjecaj potrošnje realnog BDP-a emitivnih zemalja, indeks cijena receptivne zemlje te tečajne razlike mjerene godišnjim prosječnim tržišnim cijenama u lokalnoj valuti prema dolaru na broj dolazaka turista iz Australije, Velike Britanije i SAD u Hong Kong. Zaključili su da prihodi imaju značajan utjecaj na dolaske turista u Hong Kong, dok je potrošnja u Hong Kongu uvjetovana cijenom.

Dritsakis (2012) istražuje odnose između gospodarskog rasta i razvoja turizma u sedam mediteranskih zemalja za razdoblje od 1980. godine do 2007. godine. Funkcija turističke potražnje se modelira putem realnog BDP po stanovniku, realnim primanjima po stanovniku, brojem međunarodnih turističkih dolazaka po stanovniku i realnim efektivnim tečajem emitivnih zemalja. Istražujući odnose između gospodarskog rasta i razvoja u sedam mediteranskih zemalja zaključio je da turistički primici imaju veći utjecaj na BDP u svim mediteranskim zemljama te da realni tečaj ima značajne učinke na stope gospodarskog rasta.

Fourie i Santana–Gallego (2013) za formiranje Afričke turističke potražnje kombiniraju faktore iz emitivnih i receptivnih tržišta. Kao determinante turističke potražnje koriste BDP po glavi stanovnika u receptivnoj i emitivnim zemljama, udaljenost između zemalja, kapitalna ulaganja u receptivnoj zemlji, bilateralnu trgovinu te koriste i dodatne dummy varijable koje bi mogle utjecati na dolazak turista u receptivnu zemlju iz emitivne zemlje. Zaključili su, za razliku od prethodnih istraživanja, da je većina varijabli značajna, međutim oni smatraju da su dobiveni rezultati posljedica problema koji se javljaju kao što su problem pouzdanosti podataka, pristranosti, multikolinearnosti, nekonzistentnost i slično.

Mordecki (2014) analizira utjecaj dolazaka i utjecaj potrošnje turista iz Argentine u Urugvaj u razdoblju od 1. mjeseca 1996. godine do 12. mjeseca 2013. godine, na prihode zemlje porijekla i relativne cijene koje su mjerene realnim tečajem između dviju zemalja (Argentina i

Urugvaj). Zaključuje da promjene dohotka imaju velik utjecaj na relativne cijene, dok je taj utjecaj neznačajan za broj turista koji dolaze.

Bentum-Ennin (2014) analiziraju turističku potražnju u Gani zasebno za svako promatrano emitivno tržište (Afriku, EU, Ameriku, istočnu i srednju Aziju). Istražuje kako na turističku potražnju utječu realni BDP emitivne zemlje, indeks potrošačkih cijena emitivne zemlje, cijena zamjenskog nigerijskog tržišta, regionalni izvoz, tečajna razlika, putni troškovi, indeks slobode i političkih prava. Rezultati vode do zaključka da dohodak emitivnih zemalja ima pozitivan utjecaj na turističku potražnju u Gani, troškovi transporta nisu značajni za dolaske, tečajna razlika je značajna i negativno utječe te da konkurentsko tržište također negativno utječe na turističku potražnju u Gani.

Serra et al. (2014) modeliraju turističku potražnju u regijama Portugala koristeći faktore emitivnih tržišta. Oni analiziraju utjecaje makroekonomskih čimbenika emitivnih tržišta (Velike Britanije, Njemačke, Nizozemske, Irske, Francuske i Španjolske) na turističku potražnju za sedam regija u Portugalu u razdoblju od 2000. godine do 2011.godine. Kao pokazatelj turističke potražnje koriste broj noćenja stranih turista te istražuju kako na nju utječu dohodak (BDP po stanovniku), realne cijene, stope nezaposlenosti i finalne potrošnje kućanstava. Teoretska očekivanja na kojima se temeljio ovaj rad je da makroekonomski čimbenici utječu na turističku potražnju. Dobiveni rezultati su različiti s obzirom na turističku regiju. Utjecaj BDP- na turističku potražnju u nekim regijama je vrlo ovisan o ekonomskoj situaciji emitivne zemlje, u nekim regijama ima pozitivan predznak, u nekim je vrijednost veća od 1, a u ostalim regijama koeficijent nije značajan. Zaključili su da se u određenim regijama BDP ne utječe na turističku potražnju, dok se u nekim regijama putovanje smatra luksuzom i kao takvo ima visok gospodarski potencijal. U radu je potvrđen negativan utjecaj relativnih cijena i turističke potražnje. Stopa nezaposlenosti ima negativan utjecaj za jednu regiju, dok za ostale regije ima pozitivan učinak. Finalna potrošnja kućanstava za četiri regije ima pozitivan utjecaj dok se za ostale regije procjenjuju da koeficijent nije značajan. Međunarodna turistička potražnja u Portugalu je heterogena, što znači da Portugal ima različite turističke proizvode i privlači različita tržišta. Provedeno istraživanje daje dodatni argument za testiranje prve postavljene hipotezu da makroekonomski faktori (BDP po stanovniku, nezaposlenosti, realne cijene i finalna potrošnje kućanstava) imaju utjecaj na broj noćenja turista.

Od novijih istraživnja, Šimundić (2015) u svom radu istražuje koje makroekonomske varijable utječu na promjenu turističke potražnje, te pokušava povezat promjene definiranih varijabli u emitivnim zemljama s gospodarskim rastom i brojem novih radnih mjesta u receptivnim zemljama. Modelira turističinu potražnju koristeći realni neto nacionalni dohodak po glavi stanovnika, udjel bruto investicija u BDP-u, veličinu stope štednje u BDP-u, cijenu rada po satu rada, realni tečaj te udio ulaganja u istraživanje i razvoj u BDP-u kako bi istražila njihov utjecaj na realni neto nacionalni dohodak po glavi stanovnika po osnovi putovanja za 22 zemlje Europske unije u razdoblju od 2001. godine do 2012. godine. Uočava da se odnos između kretanja turističke potražnje i varijabli koje su se koristile kao proxy za cijene (CPI, efektivni tečajevi i sl.) pokazao negativnim.

Na temelju detaljno iznesenog pregleda istraživanja može se zaključiti da ne postoji jedinstven skup varijabli kojima se može opisati turistička potražnja. Do sličnog zaključka je došla i Šimundić (2015) koja je zaključila da rezultati istraživanja variraju ovisno o karakteristikama i kontekstu destinacije koja je u fokusu istraživanja.

Turistička potražnja se najčešće mjeri brojem noćenja turista, brojem dolazaka turista i/ili turističkom potrošnjom. U većini znanstvenih radova je potvrđena značajna i pozitivna veza između BDP-a emitivnih zemalja i turističke potražnje (Dritsakis, 2004, Botti et al., 2006, Garĭn-Muńoz, 2006, Bentum-Ennin, 2014), a samo u manjem dijelu radova ta veza nije značajna (Proença i Soukiazis, 2005, Culiu, 2014). Također je potvrđena značajna veza između BDP-a receptivnih zemalja i turističke potražnje (Eugenio-Martína et al., 2004). Veza između turističke potražnje i relativnih cijena receptivnih zemalja se pokazala značajnom i negativnom (Garĭn-Muńoz, 2006, Brida i Risso, 2009). U znanstvenim radovima je potvrđeno da finalna potrošnja kućanstava ima pozitivni predznak, ali njeno značenje varira ovisno o analiziranom receptivnom tržištu (Song et al., 2010), dok stope nezaposlenosti u pravilu imaju negativan smjer, ali nisu uvijek značajan pokazatelj (Serra et al., 2014). Istraživanja su potvrdila značajan i pozitivan utjecaj tečaja receptivnih tržišta (Dritsakis, 2004 i 2012), dok troškovi transporta variraju od značajnih pokazatelja negativnog smjera (Brida i Risso, 2009) do neznačajnih pokazatelja (Bentum-Ennin, 2014). Značajnim se pokazala politička nestabilnost i turistička infrastruktura receptivne zemlje s tim da politička nestabilnost ima negativan smjer, a turistička infrastruktura pozitivan smjer (Naudé i Saayman, 2005). Odnos između turističke potražnje i konkurentskog tržišta u pravilu ima značajnu i negativnu vezu (Bentum-Ennin, 2014).

2.3.2. Pregled znanstvenih istraživanja turističke potražnje u Hrvatskoj

Kao što je već spomenuto turizam postaje dominantna grana u Hrvatskom gospodarstvu pa je očekivano da sve više hrvatskih znanstvenika u svojim radovima proučava faktore koji utječu na turističku potražnju u Republici Hrvatskoj.

Tako Stručka (2000) objašnjava turističku potražnju Republike Hrvatske u razdoblju od četvrtog kvartala 1993. do drugog kvartala 1999. godine, analizirajući utjecaj dohotka i relativnih cijena na broj noćenja turista iz emitivnih zemalja, zasebno za svako odabrano tržište: Njemačku, Austriju, Italiju, Nizozemsku, Sloveniju, Češku, Slovačku, Mađarsku i Poljsku. Rezultati istraživanja su pokazali da je turistička potražnja modelirana realnim BDP-om emitivnog tržišta, za sva tržišta pozitivno elastična. Jedino tržište Češke pokazuje negativni predznak kod dohodovnog koeficijenta što sugerira da je Hrvatska kao receptivna destinacija na tom tržištu inferiorno dobro. Cjenovna potražnja definirana prilagođenim relativnim cijenama uglavnom je negativno elastična.

Belullo i Križman (2000) analiziraju turistički promet Republike Hrvatske zasebno za svako promatrano tržište (Austriju, Njemačku, Italiju i Sloveniju) koristeći mjesečne podatke u razdoblju od 1. mjeseca 1994. godine do 12. mjeseca 1998. godine. U radu analiziraju utjecaj promjene dugoročnih i kratkoročnih dohodaka (nominalni dohodak i dohodak korigirane za tečaj i cijene) emitivnih zemalja na broj noćenja i broj dolazaka turista u Hrvatsku. Svojim radom zaključuju da postoji jaka i dugoročna veza s visokim koeficijentom elastičnosti između promjene dugoročnih dohodaka i turističkog prometa dok je kratkoročno gledajući ta veza zanemariva.

Mervar i Payne (2007) turističku potražnju za odredištima u Hrvatskoj u razdoblju od 1. mjeseca 1994. do 4. mjeseca 2004. godine modeliraju putem dohotka i cijena kombiniranjem faktora iz emitivnih i receptivnih tržišta. Rezultati istraživanja potvrđuju da je inozemna turistička potražnja pozitivno elastična na promjene dohotka kod glavnih emitivnih zemalja, ali da devizni realni tečaj i troškovi transporta (mjereni u cijenama nafte) nemaju statistički značajan utjecaj na kretanja inozemne turističke potražnje za odredištima u Hrvatskoj te da politički događaji negativno utječu na potražnju.

Škrinjarić (2011) također istražuje utjecaj makroekonomskih čimbenika na broj noćenja turista analizirajući turističku potražnju Republike Hrvatske u razdoblju od 1994. godine do 2009. godine te kombinira faktore emitivnih i receptivnih tržišta. Makroekonomski čimbenici

koje se koriste u ovom radu su BDP po glavi stanovnika emitivne zemlje, trgovinska otvorenost RH (udjel uvoza i izvoza u BDP-u), cijene supstituta Hrvatske kao destinacije (prosjek indeksa cijena konkurentskih zemalja), relativne cijene zemlje destinacije i emitivnih zemalja (recipročna vrijednost PPP konverzijskog faktora emitivne zemlje), kapitalna ulaganja izražena u stalnim cijenama, te rat i ekonomska kriza kao dummy varijable. U svom radu dolazi do zaključka da je turistička potražnja neelastična u odnosu na dohodak, dok je elastična s obzirom na cijene supstituta. Kapitalna ulaganja imaju pozitivne učinke u modelu.

Škufilić i Štoković (2011) procjenjuju funkciju turističke potražnje aproksimiranu brojem noćenja u hotelima u ovisnosti o prosječnoj cijeni noćenja u hotelima BDP-u po glavi stanovnika emitivnih zemalja, kvaliteti hotela mjerenu kategorijom hotela, postotku rezervacija objavljenih putem interneta te prosječnoj starosti hotela. Za analizu su koristili panel podatke za razdoblje od 1998. godine do 2008. godine pri čemu su jedinice promatranja bile regije – Istra, Dalmacija, Kvarner te kontinentalna Hrvatska. Zaključuju da su turistička potražnja i dohodak pozitivno povezani dok porast cijena smještaja negativno utječe na turističku potražnju.

U konačnici Belullo (2011) objašnjava kretanje dolazaka i noćenja turista glavnih emitivnih zemalja (Austrija, Slovenija, Njemačka, Italija) i Hrvatske u turističkom naselju Barbariga koristeći kvartalne podatke od 2005. godine do 2009. godine. Turističku funkciju je modelirao koristeći dolaske i noćenja turista s obzirom na zemlju podrijetla u odnosu s realnim BDP-om emitivne zemlje, tečaj eura, te dummy varijable: svjetsku ekonomsku krizu i svjetsko i europsko nogometno prvenstvo. Dobiveni rezultati variraju u odnosu na analiziranu strukturu gostiju. Tako je realni BDP statistički značajno utjecao kod gostiju iz Austrije i domaćih gostiju dok je kod gostiju iz Slovenije utjecao samo na povećanje broja dolazaka. Kod njemačkih gostiju povećanje njihovog BDP-a utjecalo je na smanjenje broja noćenja, a kod talijanskih gostiju promjena u njihovom realnom BDP-u nije utjecala na broj dolazaka i noćenja. To ukazuje da gosti iz Njemačke percipiraju Hrvatsku kao jeftinu turističku destinaciju te povećanjem realnog BDP-a Hrvatsku zamjenjuju skupljim turističkim destinacijama. Tečaj eura značajno utječe na goste iz Slovenije tako da povećanje tečaja povećava njihov dolazak. Svjetska ekonomska kriza utječe na dolaske i noćenja kod svih zemalja osim Austrije. Na njemačke i talijanske goste ona utječe negativno i na broj dolazaka i na broj noćenja. Kod slovenskih gostiju nailazi se samo na smanjenje broja dolazaka kao posljedice ekonomske krize. Glede hrvatskih gostiju ekonomska kriza utječe na smanjenje broja dolazaka dok povećava broj noćenja.

U znanstvenim radovima koji analiziraju turističku potražnju u Hrvatskoj zaključuje se da je turistička potražnja emitivnih tržišta u pravilu elastična na promjene dohotka kod glavnih emitivnih zemalja Stručka (2000), Mervar i Payne (2007), Škrinjarić (2011). Stručka (2000) u svom radu također dolazi do rezultata da tržište Češke ima negativni predznak kod dohodovnog koeficijenta mjerenog realnim BDP-om emitivnog tržišta što sugerira da je Hrvatska kao receptivna destinacija na tom tržištu inferiorno dobro. Belullo (2011) međutim zaključuje da utjecaj realnog BDP-a emitivnih zemalja varira ovisno o strukturu gostiju. U empirijskim radovima koji analiziraju turističku potražnju u Hrvatskoj realni tečaj se nije pokazao statistički značajan, odnosno zaključilo se da nema utjecaj na kretanja inozemne turističke potražnje za odredištima u Hrvatskoj (Mervar i Payne, 2007). Cjenovna potražnja je uglavnom negativno elastična (Stručka, 2000). Kapitalna ulaganja imaju značajnu i pozitivnu vezu s turističkom potražnjom, politička nestabilnost se pokazala značajnom i negativnog smjera, a troškovi transporta su se pokazali neznačajnima (Mervar i Payne, 2007).

Vidljivo je da je u novije vrijeme samo nekolicina radova analizira determinante turističke potražnje u Republici Hrvatskoj. Većina radova (Belullo i Križman, 2000, Mervar i Payne, 2007, Škinjarić, 2011) promatraju broj noćenja na nivou države. Škufilić i Štoković (2011) analiziraju broj noćenja u hotelima promatrajući četiri hrvatske turističke regije; Istru, Dalmaciju, Kvarner i kontinentalnu Hrvatsku dok je Belullo (2011) koristeći broj noćenja analizirao potražnju turističkog naselja „Barbariga“ u Istri. U svjetskim okvirima sve češće se istraživanja provode na nivou regija unutar države. Njihovi rezultati ukazuju da različite regije imaju različite determinante (Proença i Soukiazis, 2005, Brida i Risso, 2009, Serra et al., 2014), odnosno da se zaključak teško donosi na nivou države. Imajući u vidu različitu ponudu u hrvatskim županijama, te različitu strukturu gostiju koji posjećuju iste, uočili smo potrebu istraživanje turističke potražnje svesti na nivo županije.

3. PANEL ANALIZA [2]

3.1. Osnovne karakteristike panel analize

Panel podaci sadrže veći broj podataka nego pripadajući prostorni podaci ili pripadajući vremenski nizovi. Stoga su znatno efikasniji u istraživanjima s obzirom da se istovremeno analizira vremenska i prostorna komponenta neke pojave i kao takvi su postali neizostavan dio znanstvenih radova. Procjene dobivene panel analizom su preciznije jer se zavisna varijabla mijenja po vremenu i jedinicama promatranja. Pristranost podataka koja se pojavljuje zbog nedostatka podataka je uvelike smanjena primjenom panel podataka kao i mogućnost definiranja te testiranja kompliciranih ekonometrijskih modela. Manje su osjetljivi na netipične vrijednosti te omogućavaju mjerenje različitosti unutar jedinica promatranja. Rezultati dobiveni panel analizom su točniji na mikro podacima nego na makro razini. Panel podaci također umanjuju problem multikolinearnosti. Naime dogodi li se da su dvije varijable iste jedinice promatranja snažno korelirane, ali ta korelacija nije izražena između jedinica drugih jedinica promatranja ta korelacija gubi značajnost (Škrabić Perić, 2012). Kod panel podataka je bitno da su panel podaci koji se analiziraju homogeni odnosno da imaju zajednička svojstva. U protivnom analiza neće biti relevantna te se može dogoditi da se niti jedna varijabla ne pokaže statistički značajnom. Kada su podaci dostupni u svakom promatranom razdoblju i za sve jedinice promatrana govorimo o balansiranim panel podacima. Ukoliko za neke jedinice ili za neko promatrano razdoblje nedostaje podataka govorimo o nebalansiranim panel podacima. Kada se govori o ovisnosti o zavisnoj varijabli, panel podatke možemo podijeliti na statičke i dinamičke.

3.2. Statički panel modeli

3.2.1. Združeni panel model

Osnovna pretpostavka statičkih panel modela je ne postojanje autokorelacije tj. ovisnosti sadašnje vrijednosti neke varijable o njenoj prethodnoj vrijednosti. Statički panel modeli su robusni na korelaciju među opažanjima unutar jedne jedinice promatranja, a korelacija među opažanjima unutar jedne jedinice promatranja moraju biti konstantna bez obzira koliko ta opažanja bila vremenski udaljena i bez obzira da li se radi o modelu s fiksnim efektom ili modelu sa slučajnim efektom.

[2] Škrabić Perić, B. (2014): *Analiza panel podataka*, nastavni materijali. Split: Ekonomski fakultet Split.

Združeni panel model (engl. Pooled OLS) je najjednostavniji panel model, ali ima i najviše ograničenja te ne pretpostavlja različitosti između jedinica promatranja. Definira se kao:

$$y_{it} = \alpha + \beta_1 \cdot x_{it1} + \beta_2 \cdot x_{it2} + ... + \beta_K \cdot x_{itK} + \varepsilon_{it}; \quad (1)$$

$$i = 1,..., N, t = 1,..., T,$$

pri čemu:

N	označava broj jedinica promatranja,
T	označava broj razdoblja,
x_{itk}, k=1,…K	označava vrijednost k-te nezavisne varijable, i-te jedinice promatranja u t,
α	konstantni član, jednak za sve jedinice promatranja, ne mijenja se kroz vrijeme,
$\beta_1, \ldots, \beta_K$	parametri koje treba procijeniti,
ε_{it}	greška relacije i-te jedinice promatranja u razdoblju t.

Pretpostavka je da su ε_{it} nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu sa sredinom 0 i varijancom σ_ε^2. Uz to se pretpostavlja da su svi i x_{itk} nezavisni s ε_{it} za sve i, t, k.

Kako bi OLS procjenitelj bio nepristran, konzistentan i efikasan nužno je zadovoljiti slijedeće uvjete:

$$IID(0, \sigma_\varepsilon^2), Cov(y_{it}, y_{js}) = Cov(\varepsilon_{it}, \varepsilon_{js}) = 0,$$

(2) $\forall i, j = 1,2,..., N, \forall t, s = 1,2,..., T, t \neq s,$

(3) $E(x_{it}, \varepsilon_{it}) = 0,$

(4)

Podaci koji se koriste u panel podacima, u združenom modelu, se odnose na jednu jedinicu promatranja koja se ponavlja kroz više razdoblja. Stoga je gotovo nemoguće očekivati međusobnu nekoreliranost grešaka relacije u različitim razdobljima. Također je gotovo nemoguće očekivati nekoreliranost grešaka relacije i nezavisnih varijabli te konstantnu varijancu između jedinica promatranja. Isto tako gotovo je nemoguće očekivati konstantnu varijancu između jedinica promatranja. Ovaj model ne pretpostavlja različitosti između jedinica promatranja. Posljedice koje se događaju zbog svega navedenog dovode do pristrane i nekonzistentne procjene. Standardne greške se podcjenjuju jer se zanemaruje pozitivna

korelaciju između jedinica promatranja, odnosno, može se dogoditi da se neke varijable u modelu smatraju statistički značajnima iako to nisu (Škrabić Petrić, 2012).
Postoje različiti načini na koje se rješavaju prisutni nedostatci. Iako nije uvijek prikladan za procjenu panel podataka združeni model služi kao dobra podloga za izvođenje, odnosno transformaciju naprednijih panel modela.

Ponekad se združeni OLS model transformira tako da se izračuna prosječna vrijednost opažanja za svaku jedinicu promatranja. Procjenitelji modela „između" jedinica promatranja su konzistentni, ali nisu efikasni i mogu procijeniti utjecaj varijabli koje nisu promjenjive kroz vrijeme. Međutim, uprosječivanjem podataka gubi se vremenska komponenta te procijenjeni parametri nisu realni. Ovaj model nije primjenjiv za podatke koji sadrže varijable koje su izrazito promjenjive kroz vrijeme i imaju dugu vremensku komponentu.

3.2.2. Model s fiksnim efektom

Model s fiksnim efektom je jednostavni linearni model u kojem se konstantni član mijenja sa svakom jedinicom promatranja pri čemu je konstantan u vremenu, a definira se kao:

$$y_{it} = \alpha_i + \beta_1 \cdot x_{it1} + \beta_2 \cdot x_{it2} + ... + \beta_K \cdot x_{itK} + \varepsilon_{it}; \quad (5)$$

$$i = 1,..., N, t = 1,..., T,$$

pri čemu:

N	označava broj jedinica promatranja,
T	označava broj razdoblja,
x_{itk}, k=1,…K	vrijednost k-te nezavisne varijable, i-te jedinice promatranja u t vremenu
α_i	konstantni član, različit za sve jedinice promatranja, ne mijenja se kroz vrijeme,
$\beta_1, \ldots, \beta_K$	parametri koje treba procijeniti,
ε_{it}	greška procjene i-te jedinice promatranja u razdoblju t.

Dodatno, pretpostavka je da su ε_{it} nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu, sa sredinom 0 i varijancom σ_ε^2 , i pretpostavlja se da su svi x_{itk} nezavisni s ε_{it} za sve i, t, k.

Model s fiksnim efektom sadrži N različitih konstantnih članova, po jedan za svaku jedinicu promatranja. Potrebno je procijeniti *N-1* parametar više nego za združeni model. Metoda za procjenu modela s fiksnim efektom naziva se metoda najmanjih kvadrata s dummy varijablama (engl. Least Squers Dummy Variables, LSDV), a za procjenu istog potrebno je prethodno definirati dummy varijablu za svaku jedinicu promatranja.

Svojstva LSDV procjenitelja mijenjaju se s obzirom na karakteristike uzorka (obzirom na broj razdoblja i broj jedinica promatranja). Kada $T\rightarrow\infty$ procjenitelj fiksnog efekta postaje konzistentan u procjeni parametara β_1, β_2, … β_k i u procjeni dummy varijabli za svaku od jedinica promatranja α_1 α_2,…,α_N. Kada $N\rightarrow\infty$, a T je fiksan procjenitelj fiksnog efekta postaje konzistentan u procjeni parametara β_1, β_2,… β_k, ali procjene parametara uz dummy varijable α_1 α_2,…,α_N ostaju nekonzistentne bez obzira na povećanje jedinica promatranja.

Kao i u svakom modelu tako i kod LSDV procjenitelja se javljaju nedostatci. Zbog procjene konstantnog člana za svaku jedinicu promatranja dolazi do gubitka velikog broja stupnjeva slobode. Zbog velikog broja dummy varijabli može doći do pojave multikolinearnosti između nezavisnih varijabli. Kada se analizira veliki broj jedinica promatranja, zbog ograničenja statističkih paketa, može doći do nemogućnosti procjene model s fiksnim efektom. Također je nemoguće procijeniti varijable koje ne ovise o vremenu kao što su spol, rasa, religija i sl.

Da bi se procijenili parametri $\beta_1, \beta_2,\ldots, \beta_K$, uz pomoć modela s fiksnim efektom potrebno je definirati jednostavan model. Kako bi se definirao novi model potrebno je, uz pomoć transformacije podataka, eliminirati pojedinačne efekte α_i.

Naime, uvedu li se oznake $\overline{y_i}$, $\overline{x_{ik}}$ i $\overline{\varepsilon_i}$ za prosječne vrijednosti zavisne varijable, nezavisnih varijabli i grešaka relacije za jedinicu promatranja *i*, za *t* razdoblja:

$$\overline{y_i}=\frac{\sum_{t=1}^{T} y_{it}}{T}, \overline{x_{ik}}=\frac{\sum_{t=1}^{T} x_{itk}}{T}, \overline{\varepsilon_i}=\frac{\sum_{t=1}^{T} \varepsilon_{it}}{T} \tag{6}$$

$$i=1,\ldots,N, k=1,\ldots K$$

Dobivene prosječne vrijednosti svih varijabli, za svaku jedinicu promatranja *i*, uvrste u jednadžbu fiksnog efekta (prvu jednadžbu fiksnog efekta). Dobiva se jednadžba identična jednadžbi modela do na konstantu između jedinica promatranja (Beetwen model).

Nakon toga, od jednadžbe modela s fiksnim efektom se oduzme jednadžba modela između jedinica promatranja i dobije se sljedeća jednadžba:

$$y_{it} - \overline{y_i} = \beta_1 \cdot (x_{it1} - \overline{x_{i1}}) + \beta_2 \cdot (x_{it2} - \overline{x_{i2}}) + ... + \beta_K \cdot (x_{itK} - \overline{x_{iK}}) + (\varepsilon_{it} - \overline{\varepsilon_i}); \quad \textbf{(7)}$$

$$i = 1,..., N, t = 1,...T$$

Dobiveni model, regresijski je model odstupanja vrijednosti varijabli od prosječnih vrijednosti svake jedinice promatranja i ne uključuje fiksni efekt α_i. Naime svi α_i su se izgubili pri oduzimanju. Ponekad se u literaturi model između jedinica promatranja dobije oduzimanjem modela između jedinica promatranja od združenog modela.

Procijene od $\beta_1,\beta_2,\ldots,\beta_k$ koje se dobivaju metodom najmanjih kvadrata na temelju transformiranog modela nazivaju se procjene „unutar“ jedinica promatranja (engl. within estimates). Procjene dobivene opisanom metodom identične su procjenama parametara koje se dobivaju metodom najmanjih kvadrata s dummy varijablama uz razliku što model između jedinica promatranja ne procjenjuje pojedinačni efekt za svaku jedinicu promatranja.

3.2.3. Model s slučajnim efektom

Model sa slučajnim efektom je jednostavan linearan model u kojem se pretpostavlja da su jedinice promatranja odabrane na slučajan način. Također je pretpostavka da su razlike između jedinica promatranja slučajne. Model se definira:

$$y_{it} = \mu + \beta_1 \cdot x_{it1} + \beta_2 \cdot x_{it2} + ... + \beta_K \cdot x_{itK} + \alpha_i + \varepsilon_{it}; \quad (8)$$

$$i = 1,..., N, t = 1,..., T,$$

pri čemu:

N	označava broj jedinica promatranja,
T	označava broj razdoblja,
x_{itk}, $k=1,\ldots K$	vrijednost *k*-te nezavisne varijable, *i*-te jedinice promatranja u *t* vremenu,
μ	zajednički konstantni član za sve jedinice promatranja
a_i	slučajni efekt za svaku jedinicu promatranja
$\beta_1, \ldots, \beta_K$	parametri koje treba procijeniti,
ε_{it}	greška procjene *i*-te jedinice promatranja u razdoblju *t*.

U ovom modelu se pretpostavlja da su α_i nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja sa sredinom 0 i varijancom σ_ε^2. Isto tako pretpostavka je da su ε_{it} nezavisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu, sa sredinom 0 i varijancom σ_ε^2.

OLS nije primjerena metoda procjene parametara sa slučajnim efektom. Iz tog razloga koristi se generalizirana metoda najmanjih kvadrata (engl. Generalized Least Squares Method, GLS) koja procesom transformacije uklanja korelaciju među greškama relacije iste jedinice promatranja u različitim vremenskim točkama.

Postupak transformacije GLS modela :

$$y_{it} = \mu + \beta_1 \cdot x_{it1} + \beta_2 \cdot x_{it2} + ... + \beta_K \cdot x_{itK} + \alpha_i + \varepsilon_{it};$$
$$i = 1,..., N, t = 1,..., T, \tag{9}$$

Pretpostavke modela prema Baltagiju (2008) su iduće:

$$Cov(\alpha_i, x_{itk}) = 0; \qquad i = 1,2,..., N; t = 1,2,..., T; k = 1,..., K; \tag{10}$$

$$Cov(\varepsilon_{it}, x_{itk}) = 0; \qquad i = 1,2,..., N; t = 1,2,..., T; k = 1,..., K; \tag{11}$$

te da je:

$$Cov(\alpha_i, \varepsilon_{it}) = 0; \qquad i = 1,2,..., N; t = 1,..., T; \tag{12}$$

Uvodi se element v_{it} koji označava grešku relacije sastavljene od dva člana, odnosno od pojedinačne komponente α_i i specifične komponente ε_{it}, a izražava se kao zbroj:

$$v_{it} = \alpha_i + \varepsilon_{it}$$
$$i = 1,..., N, t = 1,..., T, \tag{13}$$

Obzirom da su α_i i ε_{it} međusobno nezavisne slučajne varijable, varijanca od v_{it} je homoskedastična pri čemu vrijedi da je jednaka:

$$Var(v_{it}) = \alpha_\alpha^2 + \alpha_\varepsilon^2; \qquad i = 1,..., N; t = 1,..., T; \tag{14}$$

Elementi matrice varijance i kovarijance su:

$$Cov(\nu_{it},\nu_{js}) = \begin{cases} \sigma_\alpha^2 + \sigma_\varepsilon^2 & \text{za } i = j,\ t = s \\ \sigma_\alpha^2 & \text{za } i = j,\ t \neq s \\ 0 & \text{inače.} \end{cases} \tag{15}$$

Iz formule o kovarijancama grešaka relacije proizlazi zaključak da postoji korelacija među greškama relacije iste jedinice promatranja u različitim vremenskim točkama s koeficijentom korelacije:

$$\rho = corr(\nu_{it},\nu_{is}) = \begin{cases} 1 & \text{za } i = j,\ t = s \\ \dfrac{\sigma_\alpha^2}{\sigma_\alpha^2 + \sigma_\varepsilon^2} & \text{za } i = j,\ t \neq s \\ 0 & \text{inače.} \end{cases} \tag{16}$$

Iz navedenih razmatranja može se zaključiti da OLS nije primjerena metoda za procjenu parametara sa slučajnim efektom. Stoga GLS transformacijama uklanja korelaciju među greškama relacije iste jedinice promatranja. U prvom koraku definira se parametar koji poprima vrijednost između 0 i 1:

$$\theta = 1 - \left[\frac{\sigma_\varepsilon^2}{\sigma_\varepsilon^2 + T\sigma_\alpha^2} \right]^{\frac{1}{2}} \tag{17}$$

Nakon toga se za svaku jedinicu promatranja i odredi prosječna vrijednost varijabli $\overline{y_{it}}; \overline{x_{it1}}; \overline{x_{it2}} \cdots \overline{x_{itK}}$ kao u relaciji (6) :

Uvrštavanjem prosječnih vrijednosti u regresijsku jednadžbu dobije se jednadžba:

$$\overline{y_i} = \mu + \beta_1 \cdot \overline{x_{i1}} + \beta_2 \cdot \overline{x_{i2}} + ... + \beta_K \cdot \overline{x_{iK}} + \overline{\nu_i}; \tag{18}$$

odnosno model „između“ jedinica promatranja. Oduzme li se od jednadžbe modela sa slučajnim efektom jednadžba modela između jedinica promatranja pomnožena s θ i grupiraju li se članovi uz parametre $\mu, \beta_1, \beta_2, ..., \beta_K$, dobije se sljedeća jednadžba:

$$y_{it} - \theta\overline{y_i} = \mu(1-\theta) + \beta_1 \cdot (x_{it1} - \theta\overline{x_{i1}}) + \beta_2 \cdot (x_{it2} - \theta\overline{x_{i2}}) + ... + \beta_K \cdot (x_{itK} - \theta\overline{x_{iK}}) + (\nu_{it} - \theta\overline{\nu_i}); \tag{19}$$

$$i = 1,..., N$$

Ova jednadžba koja se dobije transformacijom jednadžbe omogućava korištenje procjenitelja slučajnog efekta za procjenu združenog modela i modela s fiksnim efektom. Uvrsti li se u jednadžbu $\theta=0$, dobije se jednadžba združenog modela. Ako se u jednadžbu uvrsti $\theta=1$ dobije se formula koja je jednadžba modela s fiksnim efektom.

Prednost model sa slučajnim efektom je mogućnost procijene utjecaja varijabli koje su neovisne o vremenu. Procjene ovog modela se dobiva GLS metodom, dok se procjene fiksnog efekta dobivaju metodom OLS, što podrazumijeva da će u velikim uzorcima procjene slučajnog efekta imati manju varijancu. GLS procjenitelj parametara modela je pristran i nekonzistentan u slučajna kada je pogreška korelirana s bilo kojom nezavisnom varijablom. Stoga je tada bolje primijeniti model s fiksnim efektom jer je procjenitelj parametara u modelu s fiksnim efektom konzistentan bez obzira na prisutnost spomenute korelacije.

3.2.4. Dijagnostički testovi za odabir prikladnog panel modela

Odabir odgovarajućeg procjenitelja će omogućiti da empirijsko istraživanje ne rezultira pogrešnim zaključcima koji se mogu ogledavati u vrijednostima koeficijenata modela, statističkoj značajnosti i/ili predznaku koeficijenta. Pri odabiru procjenitelja treba voditi računa o karakteristikama uzorka, dinamici zavisne varijable, pretpostavki o mogućem problemu endogenosti, rezultatima dijagnostičkih testova koji se mogu koristiti te o svojstvima procjenitelja, odnosno, odabir se treba temeljiti na prednostima nekog procjenitelja u odnosu na druge procjenitelje. Poznavanje svojstava svakog od korištenih procjenitelja je preduvjet za odabir procjenitelja koji daje relevantne podatke.

Prilikom odabira modela treba istražiti prednosti i nedostatke modela koji se koristi u istraživanju.

Opravdanost korištenja model sa fiksnim efektom testira se pomoću uobičajenog *F-testa* na način da se ispita nulta hipoteza o jednakosti konstantnih članova za sve jedinice promatranja. Ako rezultati testa odbace nultu hipotezu zaključuje se da je upotreba modela s fiksnim efektom opravdana u procjeni parametara definiranog modela. U protivnom, ne odbacivanjem nulte hipoteza donosi se zaključak da model s fiksnim efektom nije adekvatan u procjeni te se parametri upućuje na korištenje združenog modela. Ukoliko se prihvate postavljene nulte hipoteze F-testa i LM-testa zaključuje se da je opravdana upotreba združenog modela.

Kako bi se opravdalo korištenja modela sa slučajnim efektom potrebno ga je testirati uz pomoć LM testa (engl. Lagrange Multiplier test). Nulta hipoteza LM testa pretpostavlja da je

varijanca slučajnog efekta jedinica promatranja jednaka nuli. Ako rezultati LM testa odbace nultu hipotezu zaključuje se da je model sa slučajnim efektom prikladan za procjenu parametara, odnosno, ne postoji heterogenost među jedinicama promatranja. Ako rezultati testa ne odbace nultu hipotezu može se zaključiti da među jedinicama promatranja nema heterogenosti i da je korištenje modela sa slučajnim efektom neopravdano.

Pri usporedbi procijenjenih koeficijenata modela sa fiksnim efektom i modela sa slučajnim efektom koristi se Hausmanov test. Test polazi od pretpostavke ako ne postoji korelacija između α_i i nezavisnih varijabli x_{itk}, da su model sa fiksnim efektom i model sa slučajnim efektom konzistentni. U tom slučaju će, kada se radi o velikim uzorcima, procjene konvergirati pravoj vrijednosti parametra te se procjene između modela neće značajno razlikovati. Postavlja se nulta hipoteza Hausmanovog testa kojom se pretpostavlja da slučajna greška nije korelirana s niti jednom nezavisnom varijablom. Ukoliko se nulta hipoteza ne odbaci zaključuje se da je za analizu podataka efikasniji procjenitelj slučajnog efekta, a ukoliko se odbaci nulta hipoteza zaključuje se da je u tom slučaju korištenje procjenitelja fiksnog efekta opravdano.

3.3. Dinamički panel modeli

Većina ekonomskih pojava je u pravilu dinamičke prirode, odnosno sadašnja vrijednost neke varijable ovisi o prethodnim vrijednostima te varijable. Stoga je očekivano da se u većini istraživanja koriste dinamički panel podaci. Dinamički model se može definirati:

$$y_{it} = \mu + \gamma y_{i,t-1} + \beta_1 x_{it1} + \beta_2 x_{it2} + \ldots + \beta_K x_{itK} + \alpha_i + \varepsilon_{it}; \quad (20)$$

$$i = 1,\ldots,N, t = 1,\ldots,T,$$

pri čemu:

N	označava broj jedinica promatranja,
T	označava broj razdoblja,
$y_{i,t-1}$	zavisne varijable s pomakom,
x_{it}	označava vektor parametra dimenzije k, vektor koji sadrži vrijednost k-nezavisnih varijabli, i-te jedinice promatranja u t vremenu,
μ	konstantni član, jednak za sve jedinice promatranja, ne mijenja se kroz vrijeme,

γ,β parametri koje treba procijeniti,

α_i slučajni efekt za zemlju *i*

ε_{it} greška procjene *i*-te jedinice promatranja u razdoblju *t.*

pri čemu se pretpostavlja da su greške relacije ε_{it} nezavisno i identično distribuirane slučajne varijable sa sredinom 0 i varijancom σ_ε^2. Uvođenje zavisne varijable s pomakom dovodi do pojave korelacije između zavisne varijable s pomakom $y_{i,t-1}$ i α_i.

Za procjenu dinamičkih panel modela postoji više procjenitelja, a njihov odabir ovisi o broju jedinica promatranja i o broju razdoblje. Kada se u istraživanju raspolaže s velikim brojem jedinica promatranja (N $\rightarrow\infty$), i relativno malenim brojem razdoblja T preporučuje se korištenje Andersonov i Hsiaov procjenitelja (AH), Arellanov i Bondov procjenitelja (AB), Blundellov i Bondov procjenitelja (BB) te korigiranog procjenitelja fiksnog efekta (LSDVc). U slučaju kada je brojem razdoblja T >0, a jedinice promatranja N relativno male ili srednje dimenzije može se također koristiti korigirani procjenitelj fiksnog efekta (LSDVc), ali može se koristiti i prosječni procjenitelj grupe (engl. mean group estimator, MG) te združeni procjenitelj aritmetičkih sredina grupa (engl. pooled mean group, PMG).

Uz pomoć Sarganova testa ispituje se valjanost instrumenata koji su odabrani za procjenu modela. Nultom hipotezom se pretpostavlja da su instrumentalne varijable nekorelirane s rezidualima. Odbacivanjem nulte hipoteze se zaključuje da su neki od instrumenata korelirani s rezidualima, odnosno da u modelu postoji problem endogenosti. Ako se nulta hipoteza ne odbaci znači da su svi uvjeti zadovoljeni i da su odabrani instrumenti valjani.
U empirijskim istraživanjima se, uz Sarganov test, koriste još dva dijagnostička testa, m_1 *i* m_2 kojima se testira ne postojanje, odnosno postojanje problema autokorelacije. Nultom hipotezom testova se pretpostavlja nepostojanje problema autokorelacije s tim da test m_1 testira moguće postojanje problema autokorelacije prvog reda među prvim diferencijama reziduala, a test m_2 testira postojanje problema autokorelacije drugog reda među prvim diferencijama reziduala.

Obzirom da se u ovom radu upotreba dinamičkih panela nije pokazala prikladnom za analizu će koristiti statički panel podaci koji su detaljno objašnjeni u prethodnom dijelu rada. Razlog odabira statičkih panel modela su objašnjeni u poglavlju „*4.2. Testiranje ekonomskog modela"*. Stoga se dinamički panel podaci neće detaljnije razrađivati.

4. EMPIRIJSKA ANALIZA I REZULTATI

4.1. Deskriptivna analiza

Empirijska analiza se vrši nad brojem noćenja turista iz Europskih zemalja i to iz Austrije, Češke, Italije, Mađarske, Njemačke, Poljske, Slovačke, Slovenije, Francuske, Velike Britanije te Bosne i Hercegovine u primorskim županijama Hrvatske (Istarskoj županiji, Primorsko-goranskoj županiji, Ličko-senjskoj županiji, Zadarskoj županiji, Šibensko-kninskoj županiji, Splitsko-dalmatinskoj županiji i Dubrovačko-neretvanskoj županiji). Na slici 1 je geografski prikaz županija koje su obuhvaćene ovim uzorkom. Istraživanje je provedeno za razdoblje od 2004. godine do 2014. godine.



Slika 1: Geografski prikaz županija obuhvaćenih uzorkom istraživanja

Izvor: https://hr.wikipedia.org/wiki/Hrvatske_%C5%BEupanije - prilagodila autorica

Odabrane emitivne zemlje predstavljaju većinski udio u broju noćenja u promatranim primorskim županijama. Podaci o broju noćenja turista iz emitivnih zemalja su prikupljeni od županijskih turističkih zajednica i to: Istarske županije, Primorsko-goranske županije, Ličko-senjske, Zadarske županije, Šibensko-kninske županije, Splitsko-dalmatinske županije i Dubrovačko-neretvanske županije. Stopa nezaposlenosti emitivnih zemalja, indeks potrošačkih cijena emitivnih zemalja i izdaci konačne potrošnje po glavi stanovnika emitivnih zemalja su preuzete iz internetske baze podataka World Development Indicators (The World Bank) stranica. Rast BDP-a po glavi stanovnika emitivnih zemalja su preuzeti iz internetske baze podataka OECD-a, tečaj Hrvatske i BDP po glavi stanovnika promatrane županije su preuzeti iz internetske baze podataka Zavoda za statistiku Republike Hrvatske, dok su podaci o sezonskoj zaposlenosti po županijama preuzeti iz internetske baze podataka Hrvatskog zavoda za zapošljavanje.

Kako bi se ispitale postavljene istraživačke hipoteze korištene su varijable koje su analizirane u radu Serra et al. (2014) za regije Portugala. Kao nezavisne varijable koristile su se rast bruto domaćeg proizvoda po glavi stanovnika emitivnih zemalja (engl. Gross domestic product per capita), postotak ukupne nezaposlenost od ukupne radne snage (engl. Unemployment, total, % of total labor force), indeks potrošačkih cijena na bazi 2010. godine (engl. Consumer price index (2010=100)) te postotak godišnjih izdataka konačne potrošnje kućanstva po glavi stanovnika (engl. Household final consumption expenditure per capita growth (annual %)). Obzirom da je većina istraživanja ukazala na značajnost utjecaja makroekonomskih čimbenika receptivnog tržišta model je proširen za još tri varijable. Tečaj Hrvatske koji je izražen u američkim dolarima, što znači da je cijena domaće valute izražena u stranoj valuti (engl. Official exchange rate (US$, period average). Ukupna sezonska zaposlenost u promatranim županijama je bio logičan izbor za varijablu koju bi trebalo uvrstiti u model obzirom da su poslovi u turizmu u Hrvatskoj sezonskog karaktera te većina sezonskih poslova u primorskim županijama otpada baš na zaposlene u turizmu. Također je uključena i varijabla bruto domaći proizvod po glavi stanovnika svake analizirane županije (engl. domestic product per capita).

Varijable receptivnog tržišta su, osim tečaja Hrvatske, vraćene za jednu godinu da bi se izbjegao problem endogenosti. Navedene varijable su temeljne za dokazivanje postojanja veze između broja noćenja turista iz emitivnih zemalja i navedenih makroekonomskih čimbenika.

U slijedećem dijelu rada će se dati prikaz korištenih varijabli, oznake za iste, predviđeni predznak promatranih varijabli te će se obrazložiti izbor varijabli i razlog očekivanog smjera utjecaja. Također će se prikazati i obrazložiti izračuni deskriptivne statistike te će se definirat i teorijski obrazložiti ekonomski model na temelju kojeg će se provoditi daljnja analiza.

Tablica 1: Opis i prikaz varijabli

Naziv	***Pojašnjenje***	***Očekivani predznak***
BN_{izt}	TURISTIČKA POTRAŽNJA: - *broj noćenja turista iz zemlje **i** u županiji **z** u vremenu **t***	*Zavisna varijabla*
$BDPPC_{it}$	BRUTO DOMAĆI PROIZVOD: - *godišnji postotak stope rasta BDP-a po glavi stanovnika za zemlju **i** u vremenu **t***	+
$UNEMP_{it}$	UKUPNA NEZAPOSLENOST U EMITIVNOJ ZEMLJI: - *nezaposlenost ukupne radne snage (nacionalna procjena) u zemlji **i** u vremenu **t**, u %*	-
CPI_{it}	INDEKS POTROŠAČKIH CIJENA: - *indeks potrošačkih cijena zemlje **i** u odnosu na 2010*	-
FCI_{it}	FINALNA POTROŠNJA KUĆANSTVA: - *godišnji rast potrošnje u zemlji **i** za period **t***	+
ERHR	TEČAJ U REPUBLICI HRVATSKOJ: - *tečaj RH (LCU po US $, prosjek)*	-/+
EN_{zt}	SEZONSKA ZAPOSLENOST: - *sezonska zaposlenost u županiji **z** u vremenu **t,***	+
$BDPPC_{zt}$	BRUTO DOMAĆI PROIZVOD: - *godišnji BDP-a po glavi stanovnika (EUR) za županiju **z** u vremenu **t***	+

Izvor: izradila autorica

Iz tablice 1 je vidljivo da se za varijablu *rast bruto domaći proizvod emitivnih zemalja ($BDPPC_{it}$)* očekuje pozitivan predznak jer uz veći dohodak turisti imaju više slobodnog novca kojeg mogu trošiti na turistička putovanja. Do istih rezultata su došli i drugi autori (Dritsakis, 2004, Botti et al., 2006, Garĭn-Muńoz, 2006, Bentum-Ennin, 2014).

Nezaposlenost u emitivnoj zemlji ($UNEMP_{it}$) u pravilu ima negativan smjer (Serra et al., 2014). Pretpostavka je da će se turisti teže odlučiti na putovanja ako im je ekonomska budućnost neizvjesna, odnosno ako im je upitan priljev financijskih sredstava.

Također se očekuje negativan smjer *indeksa potrošačkih cijena (CPI_{it}),* (Stručka, 2000, Garĭn-Muńoz, 2006, Brida i Risso, 2009) koja se koristi kao proxy varijabla za cijene. Što znači da rast cijena u emitivnoj zemlji uglavnom rezultira poskupljenjima, te potencijalnim turistima opada kupovna moć. Stoga se oni vjerojatno neće odlučivati za putovanja.

Finalna potrošnja kućanstava (FCI_{it}) pozitivno utječe na turističku potražnju (Song et al., 2010) što podrazumijeva da će se turisti lakše odlučiti na putovanja ukoliko imaju više slobodnih financijskih sredstava na raspolaganju.

Očekuje se da će *tečaj Republike Hrvatska (ER_{RH})* imati pozitivan utjecaj na turističku potražnju (Dritsakis, 2004 i 2012). Rast tečaja dovodi do deprecijacije domaće valute što znači da je cijena domaće valute pala u terminima strane valute. Turisti iz emitivnih zemalja će za istu količinu novca u svojoj valuti dobiti veću količinu novca u domaćoj valuti što pozitivno utječe na turističku potražnju.

Istraživanja su potvrdila značajan utjecaj BDP-a receptivnih zemalja na rast turističke potražnje (Eugenio-Martína, et.al., 2004, Culiuc, 2014.). Veći BDPPC receptivne zemlje podrazumijeva zadovoljnije zaposlenike i bolju uslugu, a samim tim destinaciju čini poželjnijom.

Pretpostavka je da će *sezonska zaposlenost u županiji (EN_{zt})* imati pozitivan utjecaj na turističku potražnju. Veći broj zaposlenih u turizmu podrazumijeva bolju uslugu, a bolja usluga je bitan čimbenik u privlačenju većeg broja turista.

Većina dosadašnjih radova je koristila makroekonomske pokazatelje na nivou države, a u ovom radu se makroekonomski čimbenici spuštaju i na nivo županije. Obzirom da je svaka primorska županija u Hrvatskoj ima svoje posebnosti, što znači da ima različite turističke proizvode i privlači različita tržišta, za očekivati je da će istraživanje koje u svoj model uvrštava makroekonomske čimbenike na nivou županije dati kvalitetnije rezultate.

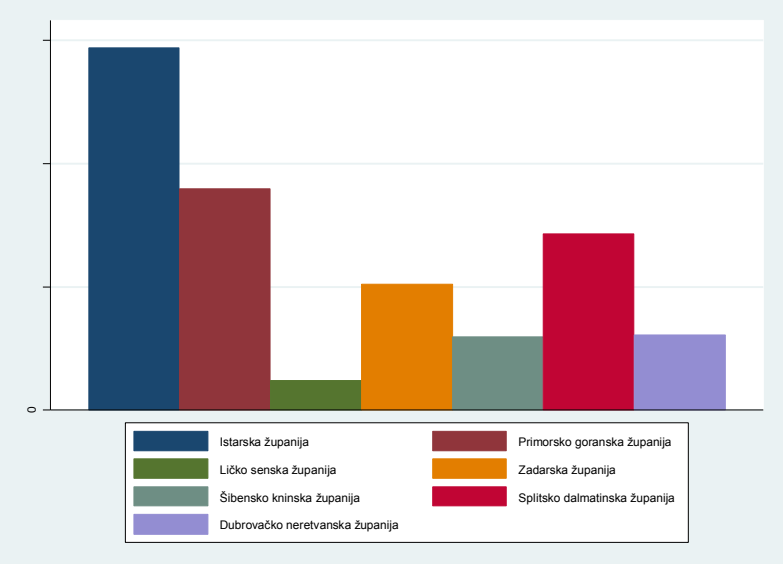
Izračuni deskriptivne statistike su nam omogućili bolji prikaz kretanja na turističkom tržištu primorskog dijela Hrvatske. Za sve promatrane varijable su izračunati broj opažanja, aritmetička sredina, standardna devijacija, minimalna i maksimalna vrijednost. U nastavku rada će se detaljno analizirati dobiveni rezultati deskriptivne statistike za svaku županiju zasebno. Zbog što boljeg poimanja situacije na tržištu u ovom dijelu rada će se i grafički prikazati kretanja ukupnog broja noćenja turista posebno za svaku županiju, prosječan broj noćenja turista prema promatranim županijama te grafički prikaz broja noćenja turista za svaku županiju prema emitivnoj zemlji iz kojih dolaze.

Tablica 2: Deskriptivna statistika uzorka $BDPPC_{it}$, $UNEMP_{it}$, CPI_{it}, FCI_{it}, ERHR

Varijable	*Broj opažanja*	*Aritmetička sredina*	*Standardna devijacija*	*Minimalna vrijednost*	*Maksimalna vrijednost*
$BDPPC_{it}$	121	1.701062	3.231044	-8.626932	10.8021
$UNEMP_{it}$	118	9.731356	5.698053	4.1	31.8
CPI_{it}	120	97.90454	8.085096	74.29818	111.7857
FCI_{it}	118	1.247507	2.343101	-6.699235	7.51145
ER_{HR}	121	5.595465	0.3227036	4.93504	6.034341

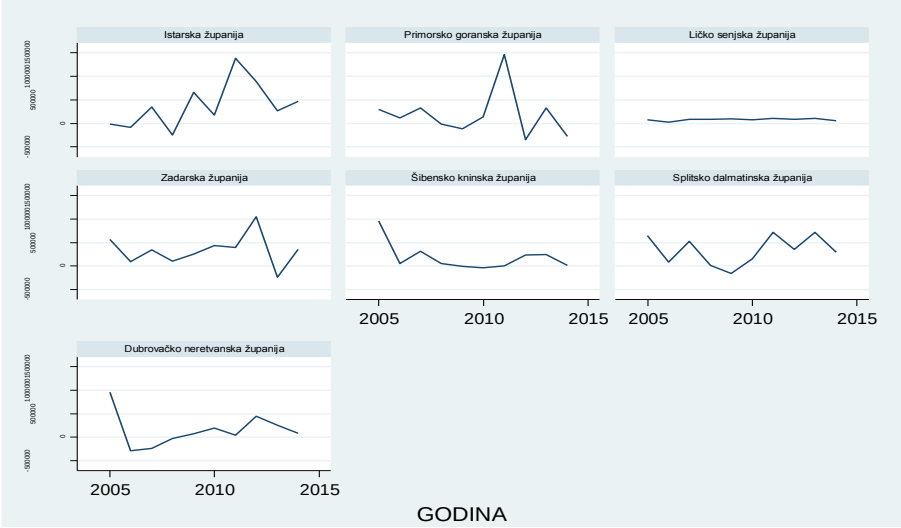
Izvor: izradila autorica

Iz rezultata deskriptivne statistike prikazanih u tablici 2, se zaključuje da *rast bruto domaći proizvod emitivnih zemalja po stanovniku ($BDPPC_{it}$)* u prosjeku iznosi 1.701062%. Maksimalan *rast bruto domaći proizvod emitivnih zemalja* po stanovniku iznosi 10.8021%, a minimalni rast negativni predznak i iznosi -8.626932 %. Prosječna *nezaposlenost u emitivnoj zemlji ($UNEMP_{it}$)* je bila 9.731356% , dok je minimalna vrijednost, odnosno minimalna prosječna nezaposlenost bila 4.1%, a maksimalna nezaposlenost 31,8%. *Indeks potrošačkih cijena emitivnih zemalja (CPI_{it})* je imao prosječnu vrijednost od 97.90454 u odnosu na 2010. godinu. Minimalna vrijednost bila 74.29818, a maksimalna 111.7857. *Finalna potrošnja kućanstva emitivnih zemalja (FCI_{it})*, u prosjeku rasla od 1.247507%. *Tečaj Republike Hrvatska (ER_{RH})* ima prosječnu vrijednost od 5.595465 u odnosu dolar; minimalna vrijednost bila 4.93504, a maksimalna 6.034341.



Graf 1: Prosječan broj noćenja turista prema promatranim županijama
Izvor: izradila autorica

Iz grafa broj 1 se može uočiti da Istarska županija prednjači prema prosječnom broju noćenja turista u razdoblju od 2004. godine do 2014. godine. Slijedi je Primorsko-goranska i Splitsko-dalmatinska županija.



Graf 2: Odvojen grafički prikaz kretanja ukupnog broja noćenja turista prema promatranim županijama

Izvor: izradila autorica

Analizirajući graf 2 može se uočiti da kretanja broja noćenja turista imaju različit intenzitet i dinamiku, ovisno o kojoj se županiji radi. Iz priloženog grafa se može zaključiti da kretanja broja noćenja u Ličko-senjskoj županiji nisu dinamična. Međutim, moramo imati u vidu da prosječan broj noćenja u toj županiji iznosi 1 195 146, tj. da je taj broj zamjetno manji od prosječnog broja noćenja u drugim županijama pa je dinamiku kretanja za tu županiju teško uočiti na zajedničkom grafu. Uočava se da je najveća oscilacija kretanja broja noćenja ostvarena u Primorsko-goranskoj županiji; slijede je Istarska županija i Zadarska županija. U Splitsko-dalmatinskoj županiji oscilacije su najuočljivije u razdoblju od 2010. godine do 2014. godine.

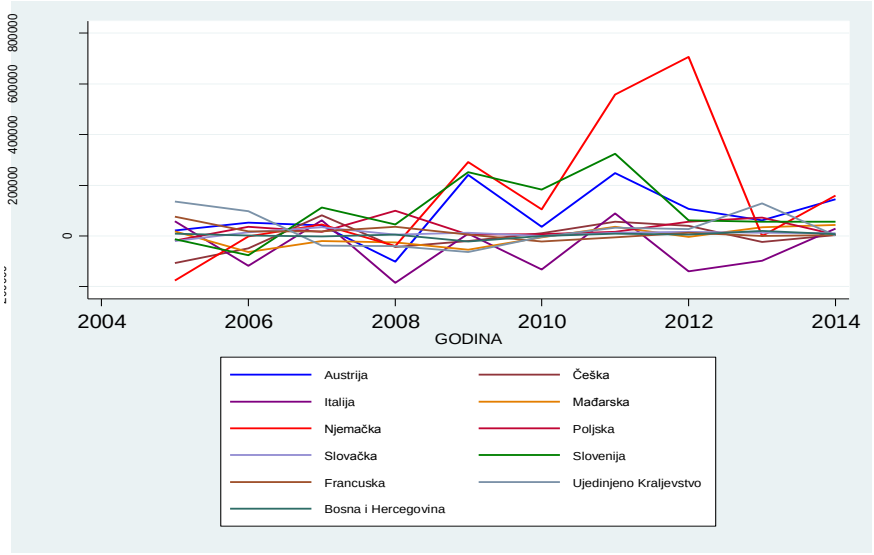
Tablica 3: Deskriptivna statistika uzorka za Istarsku županiju

Varijable	*Broj opažanja*	*Aritmetička sredina*	*Standardna devijacija*	*Minimalna vrijednost*	*Maksimalna vrijednost*
BN_{izt}	11	14692370	1540883	13299050	17247470
$BDPPC_{zt}$	110	12 6356	0.8979348	10 841	13 722
EN_{zt}	119	2454.286	332.7279	1099	3087

Izvor: izradila autorica

Na temelju rezultata deskriptivne statistike prikazane u tablici 3, može se zaključiti da je prosječan *broj noćenja turista* (BN_{izt}) u *Istarskoj županiji* iznosio 14 692 370; maksimalna vrijednost je 17 247 470 noćenja, dok je minimalna vrijednost 13 299 050 noćenja. Maksimalan broj noćenja u promatranom razdoblju su ostvarili turisti iz Njemačke u 2014. godini i iznosio je 6 786 065 noćenja, dok su minimalan broj noćenja ostvarili turisti iz Češke

2009. godine i iznosio je 70 031 noćenja. Prosječni *bruto domaći proizvod promatrane županije po glavi stanovnika* ($BDPPC_{zt}$) je iznosio 12.6356 EUR, dok je maksimalna vrijednost promatrane varijable iznosila 13.722 EUR po glavi stanovnika, a minimalna vrijednost je iznosila 10.841 EUR po stanovniku. Prosječna broj *sezonske zaposlenosti u županiji* (EN_{it}) je iznosio 2 298.181 radnika, dok je maksimalna vrijednost dosegla broj od 3 087, a minimalna 1.990 sezonskih radnika.



Graf 3: Grafički prikaz broja noćenja turista u Istarskoj županiji prema emitivnim tržištima iz kojih dolaze

Izvor: izradila autorica

Iz grafa 3, u kojem je prikazano kretanje *broja noćenja turista* (BN_{izt}) u *Istarskoj županiji* prema emitivnim tržištima iz kojih turisti dolaze uočene su najveće pozitivne oscilacije u 2012. godini kod turista koji dolaze iz Poljske. Manje oscilacije u kretanju se mogu uočiti kod turista koji dolaze iz Slovenije, Austrije i Italije. Kretanja broja noćenja za turiste koji dolaze iz ostalih emitivnih zemalja je uravnotežen.

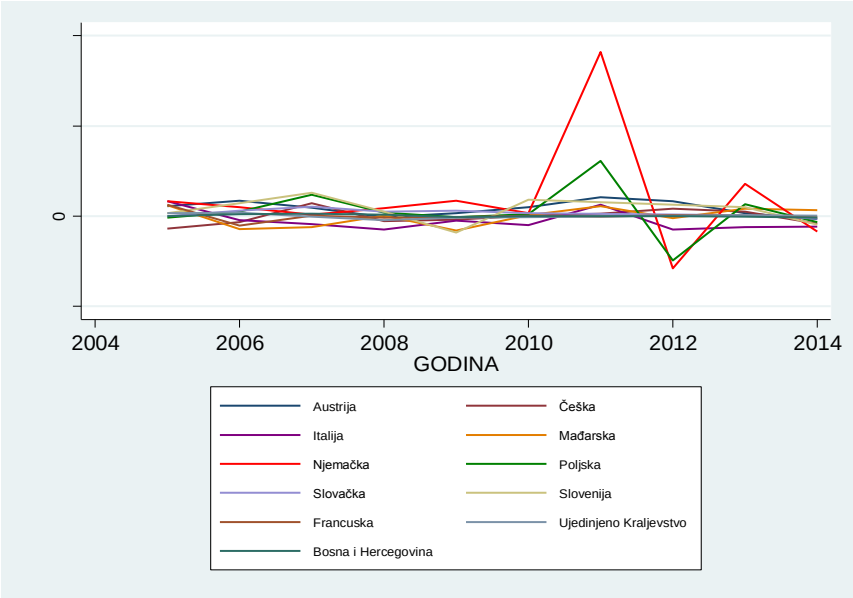
Tablica 4: Deskriptivna statistika uzorka za Primorsko-goransku županiju

Varijable	*Broj opažanja*	*Aritmetička sredina*	*Standardna devijacija*	*Minimalna vrijednost*	*Maksimalna vrijednost*
BN_{izt}	11	8977114	814273.9	7911254	10124021
$BDPPC_{zt}$	110	11 892	1.373746	8 956	13 463
EN_{zizt}	121	2439.091	287.6221	2012	2904

Izvor: izradila autorica

Iz tablice 4 se vidi da je u *Primorsko-goranskoj županiji* prosječan *broj noćenja turista* (BN_{izt}) iznosio 819 580.20; najveći vrijednost doseže brojku od 101 240 213 noćenja, a minimalan broj noćenja je bio 7 911 254 noćenja. Maksimalan broj noćenja u promatranom razdoblju su

ostvarili turisti iz Njemačke u 2011. godini i iznosio je 3 599 717 noćenja dok su minimalan broj noćenja ostvarili turisti iz Velike Britanije 2010.godine i iznosio je 57 789 noćenja. Prosječni *bruto domaći proizvod promatrane županije po glavi stanovnika* ($BDPPC_{zt}$) je iznosio 11.892 EUR; maksimalna vrijednost promatrane varijable iznosila 13.463 EUR po glavi stanovnika, a minimalna 8.956 EUR. Prosječna broj *sezonske zaposlenosti u županiji* (EN_{zt}) je iznosio 2 439.091, dok je minimalna broj zaposlenih radnika bio 2 012, a maksimalni broj zaposlenih sezonskih radnika iznosio 2 904.



Graf 4: Grafički prikaz broja noćenja turista u Primorsko-goranskoj županiji prema emitivnim tržištima iz kojih dolaze

Izvor: izradila autorica

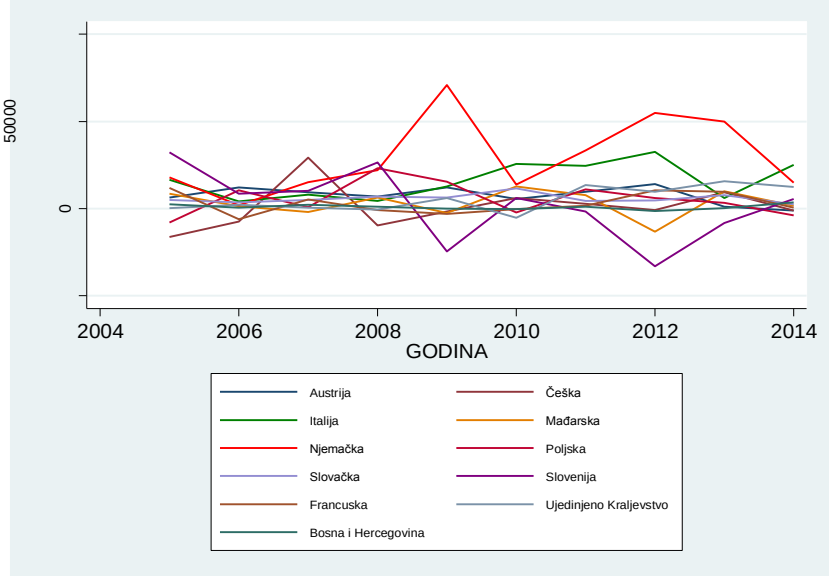
Iz grafa 4 je razvidno da je kretanje *broja noćenja turista* (BN_{izt}) turista iz emitivnih zemalja ujednačeno, osim jačih oscilacija u broju noćenja turista koji dolaze iz Njemačke i to u razdoblju nakon 2010. godine kada dolazi do pozitivnih oscilacija koje u 2012. godini poprimaju negativan smjer. Slične oscilacije u istom razdoblje, ali manjeg intenziteta su uočene za turiste koji stižu iz Poljske.

Tablica 5: Deskriptivna statistika uzorka za Ličko-senjsku županiju

Varijable	*Broj opažanja*	*Aritmetička sredina*	*Standardna devijacija*	*Minimalna vrijednost*	*Maksimalna vrijednost*
BN_{izt}	11	1195146	274232.3	816317	1611922
$BDPPC_{zt}$	110	8 2692	0.648559	7 519	9 523
EN_{zt}	121	387.0909	168.7156	189	705

Izvor: izradila autorica

Iz tablice 5 se može uočiti da je prosječan *broj noćenja turista (BN_{izt})* u *Ličko-senjskoj županiji* iznosio 1 195 146 noćenja; maksimalan broj noćenja turista u promatranom razdoblju je iznosio 1 611 922 noćenja, dok je minimalan broj noćenja turista u tom razdoblju iznosio 816 317 noćenja. Maksimalan broj noćenja u promatranom razdoblju su ostvarili turisti iz Njemačke u 2014. godini i iznosio je 467 827 noćenja. Prosječni *bruto domaći proizvod promatrane županije po glavi stanovnika ($BDPPC_{zt}$)* iznosi 8.2692 EUR, dok je maksimalna vrijednost promatrane varijable iznosila 9.523 EUR po glavi stanovnika, a minimalna vrijednost je iznosila 7.519 EUR po glavi stanovnika. Prosječna broj *sezonske zaposlenosti u županiji (EN_{iz})* je iznosio 387.0909, dok je minimalna broj zaposlenih sezonskih radnika bio 189, a maksimalni 705 radnika.



Graf 5: Grafički prikaz broja noćenja turista u Ličko-senjskoj županiji prema emitivnim tržištima iz kojih dolaze

Izvor: izradila autorica

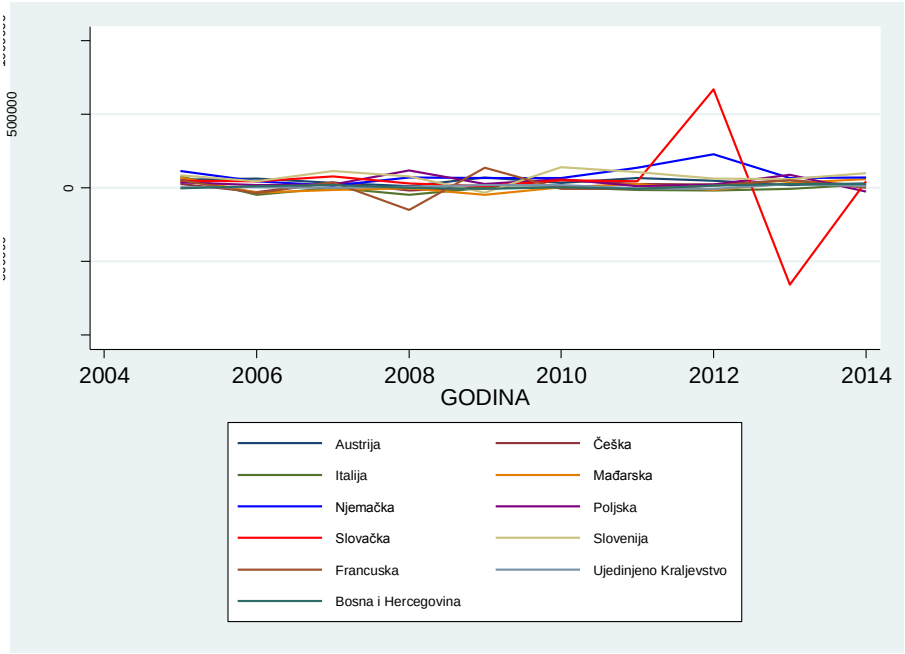
U Ličko-senjskoj županiji se uočavaju učestale oscilacije u kretanju *broja noćenja turista (BN_{izt})* što je vidljivo u grafu 5. Najveće oscilacije se događaju u 2009. godini i u razdoblju od 2011. godine do 2013. godine. Pozitivne oscilacije se uočavaju kod turista iz Njemačke i Italije, dok se negativne oscilacije uočavaju kod turista iz Slovenije, a što je vidljivo u grafu 5.

Tablica 6: Deskriptivna statistika uzorka za Zadarsku županiju

Varijable	*Broj opažanja*	*Aritmetička sredina*	*Standardna devijacija*	*Minimalna vrijednost*	*Maksimalna vrijednost*
BN_{izt}	11	5111618	1153388	3445176	6809526
$BDPPC_{zt}$	110	8 1742	0.8376645	6 592	9 723
EN_{zt}	121	1869.364	770.4825	1013	3188

Izvor: izradila autorica

Iz tablice 6 je vidljivo da *Zadarska županija* bilježi prosječan *broj noćenja turista (BN_{izt})* od 5 111 618 noćenja, od čega je maksimalna vrijednost bila 6 809 526 noćenja. U ukupnom broju noćenja najviše otpadalo na turista iz Njemačke i to 1 726 133 noćenja. Minimalna vrijednost od 3 445 176 noćenja je ostvarena 2004. godine. Prosječni *bruto domaći proizvod promatrane županije po glavi stanovnika ($BDPPC_{zt}$)* iznosi 8.1742 EUR, dok je maksimalna vrijednost promatrane varijable iznosila 9.523 EUR po glavi stanovnika, a minimalna vrijednost je iznosila 6.592 EUR po glavi stanovnika. Prosječna *sezonska zaposlenost u županiji (EN_{zt})* iznosio je 1 869.364 radnika.



Graf 6: Grafički prikaz broja noćenja turista u Zadarskoj županiji prema emitivnim tržištima iz kojih dolaze
Izvor: izradila autorica

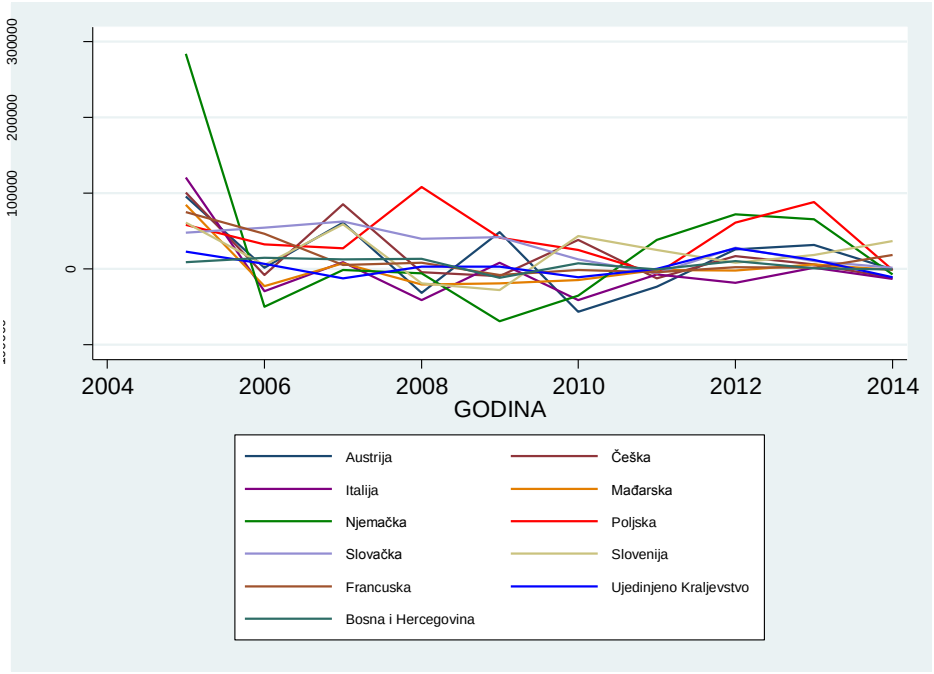
U grafu 6 je prikazano kretanja *broja noćenja turista (BN_{izt})* u Zadarskoj županiji. Uočava se da je do 2011. godine kretanje broja noćenja ujednačeno, a nakon 2011. godine nastavlja se sličan trend. To vrijedi za sve turiste osim turista iz Slovačke za koje se u 2012. godini uočava pozitivni trend, ali već u 2013. godini taj trend poprima negativan smjer. Uočavaju se i manje oscilacije kod turista koji dolaze iz Njemačke.

Tablica 7: Deskriptivna statistika uzorka za Šibensko-kninsku županiju

Varijable	*Broj opažanja*	*Aritmetička sredina*	*Standardna devijacija*	*Minimalna vrijednost*	*Maksimalna vrijednost*
BN_{izt}	11	2976554	504829.5	1702308	3540884
$BDPPC_{zt}$	110	7 5235	0.7290794	5 963	8 405
EN_{zt}	121	2046.182	580.1403	1209	3108

Izvor: izradila autorica

Prema prikazanim rezultatima u tablici 7, u Šibensko-kninskoj županiji najveći *broj noćenja turista (BN_{izt})* je ostvaren u 2014. godini i to 3 540 884 noćenja, a najmanji broj noćenja je ostvaren u 2004. godini. Prosječni *bruto domaći proizvod promatrane županije po glavi stanovnika ($BDPPC_{zt}$)* za ovu županiju iznosi 7.5235 EUR po glavi stanovnika, dok je maksimalna vrijednost promatrane varijable iznosila 8.405 EUR po glavi stanovnika, a minimalna vrijednost po glavi stanovnika je iznosila 5.963 EUR. Prosječna *sezonske zaposlenosti u županiji (EN_{zt})* je iznosila 2 046.182 radnika, dok je minimalna broj zaposlenih sezonskih radnika bio 1 209, a maksimalni 3 108 radnika.



Graf 7: Grafički prikaz broja noćenja turista u Šibensko-kninskoj županiji prema emitivnim tržištima iz kojih dolaze

Izvor: izradila autorica

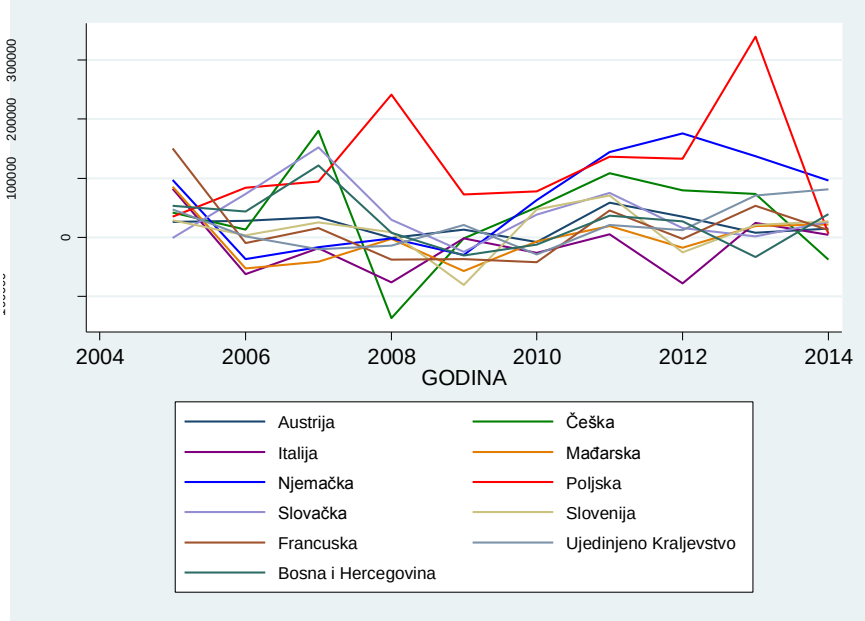
Iz grafa 7 se mogu uočiti učestale oscilacije kretanjima *broja noćenja turista (BN_{izt})* u Šibensko-kninskoj županiji kroz cijelo promatrano razdoblje, a najizraženije je kod turista iz Poljske, Njemačke i Austrije.

Tablica 8: Deskriptivna statistika uzorka za Splitsko-dalmatinsku županiju

Varijable	*Broj opažanja*	*Aritmetička sredina*	*Standardna devijacija*	*Minimalna vrijednost*	*Maksimalna vrijednost*
BN_{izt}	11	7149813	1034273	5596502	8952390
$BDPPC_{zt}$	110	7 9194	0.7597855	6 494	9 074
EN_{zt}	121	4774.273	1530.991	3464	7929

Izvor: izradila autorica

Kao i ostale županije i *Splitsko-dalmatinska županija* bilježi najveći *broj noćenja turista (BN)* u 2014. godini u iznosu od 8 952 390 noćenja, od čega je najveći udio turista iz Češke. Prosječan *broj noćenja turista* (BN_{izt}) u promatranom razdoblju je 7 149 813 noćenja. Iz rezultata prikazanih u tablici 8 se uočava da je maksimalna vrijednost prosječnog *bruto domaćeg proizvoda promatrane županije po glavi stanovnika* ($BDPPC_{zt}$) iznosila 9.074 EUR, a minimalna vrijednost 6.494 EUR po glavi stanovnika. *Sezonska zaposlenost u županiji* (EN_{zt}) mjerena brojem radnika je očekivano najveća u 2014. godini kada je bilo angažirano 7 929 radnika. Minimalan broj je iznosio 3 464 angažiranih radnika.



Graf 8: Grafički prikaz broja noćenja turista u Splitsko-dalmatinskoj županiji prema emitivnim tržištima iz kojih dolaze

Izvor: izradila autorica

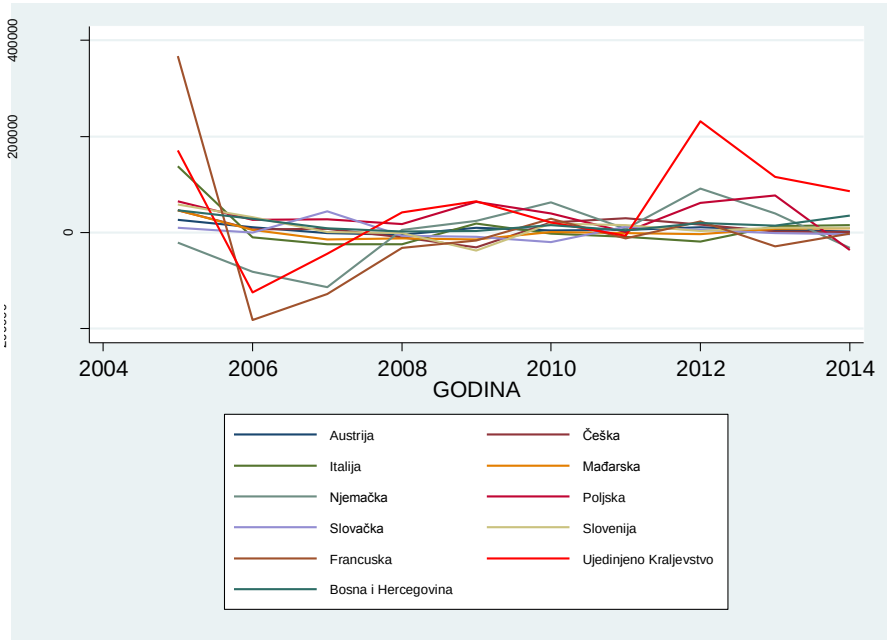
U odnosu na ostale županije najveće oscilacije su uočene u kretanjima turista u Splitsko-dalmatinskoj županiji. Iz grafa 8 je vidljivo da se u cijelom analiziranom razdoblju događaju oscilacije, a najizraženije su pozitivne oscilacije kod turista koji dolaze iz Poljske, te negativne oscilacije kod Čeških turista.

Tablica 9: Deskriptivna statistika uzorka za Dubrovačko-neretvansku županiju

Varijable	*Broj opažanja*	*Aritmetička sredina*	*Standardna devijacija*	*Minimalna vrijednost*	*Maksimalna vrijednost*
BN_{izt}	11	3043048	454983.6	2284684	3776981
$BDPPC_{zt}$	110	9 7011	1.068899	7 473	11 103
EN_{zt}	121	2837.909	733.7374	2152	4536

Izvor: izrada autora

Dubrovačko-neretvanska županija bilježi najveći *broj noćenja turista* (BN_{izt}) u 2014. godini i to 3 776 981 noćenja s najvećim udjelom gostiju iz Bosne i Hercegovine, a slijede ih gosti iz Velike Britanije. Prosječni *bruto domaći proizvod promatrane županije po glavi stanovnika* ($BDPPC_{zt}$) za ovu županiju iznosi 8.1742 EUR, dok je minimalna vrijednost promatrane varijable iznosila 6.592 EUR po glavi stanovnika, a maksimalna vrijednost je dosegnuta 2008. godine i iznosila je 11.103 EUR po glavi stanovnika što je uočeno iz rezultati deskriptivne statistike prikazanih u tablici 9. Prosječna broj *sezonske zaposlenosti u županiji* (EN_{zt}) je iznosio 2 837.909 radnika, sa maksimalnim brojem zaposlenih sezonskih radnika od 4 536 radnika, dok je neočekivano minimalni broj radnika bio angažiran u 2009. god. i to 2 152 radnika.



Graf 9: Grafički prikaz broja noćenja turista u Dubrovačko-neretvanskoj županiji prema emitivnim tržištima iz kojih dolaze

Izvor: izradila autorica

Iz grafa 9 se može uočiti da se u Dubrovačko-neretvanskoj županiji u 2006. godini uočavaju negativne oscilacije kod kretanja *broja noćenja turista* (BN_{izt}) turista iz Francuske, Velike Britanije i Njemačke koje u 2012. godini kreću u pozitivnom smjeru.

4.2. Testiranje ekonomskog modela

Kako bi proveli analizu prikupljenih panel podataka koristit će se statički panel model. Naime, upotrebom broja noćenja kao zavisne varijable koeficijent uz zavisnu varijablu bio je veći od jedan što ukazuje na nestacionarnost modela. Iz tog razloga zavisna varijabla je diferencirana i kao takva je uvrštavana u model. U takvim modelima koeficijent uz zavisnu varijablu iz prethodnog razdoblja je bio statistički neznačajan stoga se analiza vršila upotrebom statičkih modela.

Prilikom odabira odgovarajućeg procjenitelja testirati će se združeni model, model sa slučajnim efektom te model s fiksnim efektom te će se na temelju provedenih testova odlučiti koji model je najbolji.

Obzirom da postojanje multikolinearnosti između promatranih varijabli može uzrokovati poremećaj pri procjeni vrijednosti parametara, njihove značajnosti te smjera utjecaja na zavisnu varijablu potrebno je prije formiranja ekonometrijskog modela ispitati međusobnu korelaciju između promatranih nezavisnih varijabli. Do sada nije pronađen nit jedan primjeren test za otkrivanje multikolionearnosti u panel modelima stoga Baltagi et al. (2009) za uočavanje problema multikolinearnosti preporučuje korištenje koeficijenta korelacije između parova potencijalnih nezavisnih varijabli u empirijskim radovima koji koriste panel modele. U obzir se obično uzima vrijednost koeficijenata s deskriptivnog motrišta i to: $r > 0.80$ radi se o jakoj pozitivnoj korelaciji, $0.50 < r \leq 0.80$ radi se o srednje jakoj pozitivnoj korelaciji, $0 < r \leq 0.5$ radi se o slaboj pozitivnoj korelaciji. Na isti način se zaključuje ako je korelacija negativna.[3] Zbog što bolje preglednosti, tablice s rezultatima testa o postojanju korelacije su navedene za svaku županiju posebno.

Tablica 10: Korelacijska matrica između parova varijabli $BDPPC_{it}$ UNEMP, CPI, FCI i ER_{HR}

	$BDPPC_{it}$	$UNEMP_{it}$	CPI_{it}	FCI_{it}	ER_{HR}
$BDPPC_{it}$	1.0000				
$UNEMP_{it}$	0.1294	1.0000			
CPI_{it}	-0.3914*	0.0330	1.0000		
FCI_{it}	**0.7632***	-0.0074	-0.4338*	1.0000	
ER_{HR}	0.2265*	0.0698	-0.1773	0.0765	1.0000

Izvor: izradila autorica

[3] Rozga, A.(2009): *Statistika za ekonomiste*, Ekonomski fakultet Split, Split, str. 182.

Prvo je proveden test korelacije između parova nezavisnih varijabli koji se pojavljuju za sve županije što je prikazano u tablici 10. Unutar matrice uočena je srednje jaka pozitivna korelacija u iznosu od 0.7632 između *rasta bruto domaćeg proizvoda emitivnih zemalja (*$BDPPC_{it}$*),* te *finalne potrošnje kućanstva emitivnih zemalja (*FCI_{it}*),* iz čega se može zaključiti da se promatrane varijable ne bi smjele istovremeno uvrštavati u model jer može postojati problem multikolinearnosti. Ostali koeficijenti korelacije su manji od 0.5, što znači da za ostale parove nezavisnih varijabli ne bi trebalo biti ozbiljnijih problema multikolinearnosti, odnosno da se radi o slaboj korelaciji.

Tablica 11: Korelacijska matrica - Istarska županija

	$BDPPC_{it}$	$UNEMP_{it}$	CPI_{it}	FCI_{it}	ER_{HR}	BN_{izt}	$BDPPC_{zt}$	EN_{zt}
$BDPPC_{it}$	1.0000							
$UNEMP_{it}$	0.1294	1.0000						
CPI_{it}	-0.3914*	0.0330	1.0000					
FCI_{it}	0.7632*	-0.0074	-0.4338*	1.0000				
ER_{HR}	0.2265*	0.0698	-0.1773	0.0765	1.0000			
BN_{izt}	-0.1604	-0.3286*	0.1101	-0.1760	0.0128	1.0000		
$BDPPC_{zt}$	-0.3133*	-0.0255	**0.5683***	-0.2414*	**-0.8818***	0.0181	1.0000	
EN_{zt}	-0.0907	0.0104	**0.6490***	-0.2051*	0.2176*	0.0565	0.0248	1.0000

Izvor: izradila autorica

U provedenom testu korelacije za *Istarsku županiju*, prikazano u tablici 11 uočava se srednje jaka pozitivna korelacija između *indeksa potrošačkih cijena emitivnih zemalja (*CPI_{it}*)* i *bruto domaćeg proizvoda promatrane županije (*$BDPPC_{zt}$*)* u iznosu od 0.5683, te srednje jaka pozitivna korelacija između *indeksa potrošačkih cijena emitivnih zemalja (*CPI_{it}*)* i *sezonske zaposlenosti u županiji (*EN_{zt}*)* u iznosu od 0.6490. Također se uočava i jaka negativna korelacija između *bruto domaćeg proizvoda promatrane županije (*$BDPPC_{zt}$*)* i *tečaja Republike Hrvatska (*ER_{RH}*).* Zaključuje se kako bi istovremeno uvrštavanje spomenutih varijabli moglo dovesti do problema multikolinearnosti. Ostali koeficijenti korelacije su manji od 0.5 što znači da za ostale parove varijabli ne bi trebalo biti ozbiljnijih problema multikolinearnosti.

Tablica 12: Korelacijska matrica – Primorsko-goranska županija

	$BDPPC_{it}$	$UNEM_{it}$	CPI_{it}	FCI_{it}	ER_{HR}	BN_{izt}	$BDPPC_{zt}$	EN_{zt}
$BDPPC_{it}$	1.0000							
$UNEMP_{it}$	0.1294	1.0000						
CPI_{it}	-0.3914*	0.0330	1.0000					
FCI_{it}	0.7632*	-0.0074	-0.4338*	1.0000				
ER_{HR}	0.2265*	0.0698	-0.1773	0.0765	1.0000			
BN_{izt}	-0.1356	-0.3510*	0.1037	-0.1767	-0.0113	1.0000		
$BDPPC_{zt}$	-0.3965*	0.0074	**0.7910***	-0.3918*	**-0.6820***	0.0603	1.0000	
EN_{zt}	0.0089	0.0702	**0.7192***	-0.2142*	0.3448*	0.0751	0.3207*	1.0000

Izvor: izradila autorica

Problem multikolinearnosti u *Primorsko-goranskoj županiji* prikazan u tablici 12 je moguć između varijabli *indeksa potrošačkih cijena emitivnih zemalja (CPI_{it})* i varijabli: *bruto domaćeg proizvoda promatrane županije ($BDPPC_{zt}$)* u iznosu od 0.7910 i *sezonske zaposlenost u promatranoj županiji (EN_{zt})* u iznosu od 0.7192 gdje je uočena srednje jaka i pozitivna korelacija. Također je uočena srednje jaka negativna korelacija između *bruto domaćeg proizvoda promatrane županije ($BDPPC_{zt}$)* i *tečaja Republike Hrvatska (ER_{RH})* u iznosu od -0.6820. Ostale varijable ne bi trebale imati probleme multikolinearnosti.

Tablica 13: Korelacijska matrica - Ličko-senjska županija

	$BDPPC_{it}$	$UNEMP_{it}$	CPI_{it}	FCI_{it}	ER_{HR}	BN_{izt}	$BDPPC_{zt}$	EN_{zt}
$BDPPC_{it}$	1.0000							
$UNEMP_{it}$	0.1294	1.0000						
CPI_{it}	-0.3914*	0.0330	1.0000					
FCI_{it}	0.7632*	-0.0074	-0.4338*	1.0000				
ER_{HR}	0.2265*	0.0698	-0.1773	0.0765	1.0000			
BN_{izt}	-0.1760	-0.3539*	0.2058*	-0.1743	-0.0261	1.0000		
$BDPPC_{zt}$	-0.0523	-0.0803	-0.2489*	0.0858	-0.2903*	-0.0725	1.0000	
EN_{zt}	-0.2515*	0.0242	**0.8769***	-0.3357*	-0.0780	0.2194*	-0.3463*	1.0000

Izvor: izradila autorica

U tablici 13 je prikazan provedeni test korelacije za *Ličko-senjsku županiju* koji pokazuje jaku pozitivnu korelaciju između varijabli *sezonska zaposlenost u promatranoj županiji (EN_{zt})* i *indeksa potrošačkih cijena emitivnih zemalja (CPI_{it})* u iznosu od 0.8769. Istovremeno uvrštavanje navedenih varijabli moglo bi voditi ozbiljnom problemu multikolinearnosti. Ostali koeficijenti korelacije između varijabli su manji od 0.5 što znači da za ostale parove varijabli ne bi trebalo biti problema multikolinearnosti.

Tablica 14: Korelacijska matrica - Zadarska županija

	$BDPP_{it}$	$UNEMP_{it}$	CPI_{it}	FCI_{it}	ER_{HR}	BN_{izt}	$BDPPC_{zt}$	EN_{zt}
$BDPPC_{it}$	1.0000							
$UNEMP_{it}$	0.1294	1.0000						
CPI_{it}	-0.3914*	0.0330	1.0000					
FCI_{it}	0.7632*	-0.0074	-0.4338*	1.0000				
ER_{HR}	0.2265*	0.0698	-0.1773	0.0765	1.0000			
BN_{izt}	-0.0959	-0.3287*	0.2379*	-0.1596	-0.0058	1.0000		
$BDPPC_{zt}$	-0.3018*	-0.0608	0.4436*	-0.1697	**-0.9281***	0.0897	1.0000	
EN_{zt}	-0.3672*	0.0636	**0.8621***	-0.4691*	0.1563	0.2503*	0.0828	1.0000

Izvor: izradila autorica

U *Zadarskoj županiji*, nakon provedenog testa korelacije, koji je prikazan u tablici 14, uočava se mogući problem multikolinearnosti između varijabli *indeksa potrošačkih cijena emitivnih zemalja (CPI_{it})* i *sezonske zaposlenost u županiji (EN_{zt})* gdje je uočena jaka pozitivna korelacija u iznosu od 0.8621. Uočena je i jaka negativna korelacija između *bruto domaćeg*

proizvoda promatrane županije ($BDPPC_{zt}$) i *tečaja Republike Hrvatska (ER_{RH})* u iznosu od -0.92181. Zaključuje se kako bi istovremeno uvrštavanje spomenutih varijabli moglo dovesti do ozbiljnih problema multikolinearnosti. Ostale promatrane varijable nemaju probleme multikolinearnosti.

Tablica 15: Korelacijska matrica - Šibensko-kninska županija

	$BDPPC_{it}$	$UNEMP_{it}$	CPI_{it}	FCI_{it}	ER_{HR}	BN_{izt}	$BDPPC_{zt}$	EN_{zt}
$BDPPC_{it}$	1.0000							
$UNEMP_{it}$	0.1294	1.0000						
CPI_{it}	-0.3914*	0.0330	1.0000					
FCI_{it}	0.7632*	-0.0074	-0.4338*	1.0000				
ER_{HR}	0.2265*	0.0698	-0.1773	0.0765	1.0000			
BN_{izt}	-0.0299	-0.3174*	0.2090*	-0.0584	-0.0926	1.0000		
$BDPPC_{zt}$	-0.1726	-0.0135	**0.6592**	* -0.1875	**-0.7269***	0.2082*	1.0000	
EN_{zt}	-0.2549*	0.0306	**0.8835***	-0.3453*	0.0489	0.2002*	**0.6321***	1.0000

Izvor: izradila autorica

Mogući problem multikolinearnosti u Šibensko-kninskoj županiji je prikazan u tablici 15. Problem se može javiti između *indeksa potrošačkih cijena emitivnih zemalja (CPI_{it})* i dviju varijabli: *bruto domaći proizvod promatrane županije ($BDPPC_{zt}$)* u iznosu od 0.6592 i *sezonske zaposlenost u promatranoj županiji (EN_{zt})* u iznosu od 0.8835. Uočena je i srednje jaka negativna korelacija između *bruto domaćeg proizvoda promatrane županije ($BDPPC_{zt}$)* i *tečaja Republike Hrvatska (ER_{RH})* u iznosu od -0.7269, te srednje jaka pozitivna korelacija u iznosu od 0.6321 između *bruto domaćeg proizvoda promatrane županije ($BDPPC_{zt}$)* i *sezonske zaposlenosti promatrane županije (EN_{zt}).* Ostali koeficijenti korelacije su manji od 0.5 što znači da za ostale parove varijabli ne bi trebalo biti ozbiljnijih problema multikolinearnosti. .

Tablica 16: Korelacijska matrica - Splitsko-dalmatinska županija

	$BDPPC_{it}$	$UNEMP_{it}$	CPI_{it}	FCI_{it}	ER_{HR}	BN_{izt}	$BDPPC_{zt}$	EN_{zt}
$BDPPC_{it}$	1.0000							
$UNEMP_{it}$	0.1294	1.0000						
CPI_{it}	-0.3914*	0.0330	1.0000					
FCI_{it}	0.7632*	-0.0074	-0.4338*	1.0000				
ER_{HR}	0.2265*	0.0698	-0.1773	0.0765	1.0000			
BN_{izt}	0.0997	-0.1180	0.1863*	0.0790	-0.0160	1.0000		
$BDPPC_{zt}$	-0.2295*	-0.0470	0.4377*	-0.1306	**-0.9088***	0.0787	1.0000	
EN_{zt}	-0.1609	0.0319	**0.8223***	-0.2879*	0.1944*	0.2031*	0.0599	1.0000

Izvor: izradila autorica

Veći problem multikolinearnosti u Splitsko-dalmatinskoj županiji je moguć između *bruto domaćeg proizvoda promatrane županije ($BDPPC_{zt}$)* i *tečaja Republike Hrvatska (ER_{RH})* gdje je uočena jaka negativna korelacija u iznosu od -0.9088 što je vidljivo iz tablice 16. Problem

multikolinearnosti je moguć i između *indeksa potrošačkih cijena emitivnih zemalja (CPI_{it})* i *sezonske zaposlenost (EN_{zt})* gdje je uočena jaka pozitivna korelacija. Ostali parovi varijabli ne bi trebali imati probleme multikolinearnosti.

Tablica 17: Korelacijska matrica - Dubrovačko-neretvanska županija

	$BDPPC_{it}$	$UNEMP_{it}$	CPI_{it}	FCI_{it}	ER_{HR}	BN_{izt}	$BDPPC_{zt}$	EN_{zt}
$BDPPC_{it}$	1.0000							
$UNEMP_{it}$	0.1294	1.0000						
CPI_{it}	-0.3914*	0.0330	1.0000					
FCI_{it}	0.7632*	-0.0074	-0.4338*	1.0000				
ER_{HR}	0.2265*	0.0698	-0.1773	0.0765	1.0000			
BN_{izt}	-0.1303	-0.1624	0.2244*	-0.0136	0.0596	1.0000		
$BDPPC_{zt}$	-0.2941*	-0.0336	**0.5328***	-0.2003*	**-0.8567***	0.0299	1.0000	
EN_{zt}	-0.0994	0.0221	**0.7696***	-0.2205*	0.2592*	0.1894*	0.1597	1.0000

Izvor: izradila autorica

U tablici 17 prikazani su rezultati o mogućoj korelaciji u Dubrovačko-neretvanskoj županiji. Uočava se pozitivna veza *indeksa potrošačkih cijena emitivnih zemalja (CPI_{it})* i to srednje jaka u odnosu na *bruto domaći proizvod promatrane županije ($BDPPC_{zt}$)* u iznosu od -0.5328 te jaka u odnosu na *sezonsku zaposlenost u županiji (EN_{zt})* u iznosu od 0.7696. Uočena je i jaka negativna korelacija u iznosu od -0.8567 između *bruto domaćeg proizvoda promatrane županije ($BDPPC_{zt}$)* i *realnog tečaja Republike Hrvatska (ER_{RH})*. Ostali parovi varijabli ne bi trebali imati problem multikolinearnosti.

Početni zapis jednadžbe statičkog panel modela se može prikazati ovako:

$$BN_{izt} = \alpha + \beta_1 \cdot BDPPC_{it} + \beta_2 \cdot UNEMP_{it} + \beta_3 \cdot CPI_{it} + \beta_4 \cdot FCI_{it} + \beta_5 \cdot ER_{\mathrm{HR}} + \beta_6 \cdot EN_{z,t-1} + \beta_7 \cdot BDPCPC_{z,t-1} + \varepsilon_{it};$$

(21)

pri čemu je :

BN_{izt}	broj noćenja turista iz zemlje *i* u županiji *z* u vremenu *t*
$BDPPC_{it}$	vrijednost rasta BDP-a po glavi stanovnika zemlje *i* u razdoblju *t*
$UEMP_{it}$	ukupna nezaposlenost zemlje *i* u razdoblju *t*
CPI_{it}	indeks potrošačkih cijena zemlje *i* u odnosu na 2010. g.
FCI_{it}	godišnji rast potrošnje kućanstva u zemlji *i* za period *t*
ER_{HR}	tečaja Republike Hrvatske izražen u američkim dolarima
EN_{zt-1}	ukupna zaposlenost sezonskih radnika u županiji *z* u vremenu *t-1*
$BDPPC_{zt-1}$	vrijednost BDP-a po glavi stanovnika županije *z* u razdoblju *t-1*
ε_{it}	greška relacije za zemlje *i* u razdoblju *t*
β_1 , β_2, …, β_6	parametri koje treba procijeniti
α	konstantni član koji je jednak za sve jedinice promatranja i ne mijenja se kroz vrijeme
i	1, …, 11 emitivne zemlje iz kojih dolaze turisti (Austrija, Češka, Italija, Mađarska, Njemačka, Poljska, Slovačka, Slovenija, Francuska, Velika Britanija, Bosna i Hercegovina)
z	1, …7 promatrane županije (Istarska, Primorsko-goranska, Zadarska, Ličko-senjska, Šibensko-kninska, Splitsko-dalmatinska, Dubrovačko-neretvanska)
t	vrijeme 2004., 2005.,…,2014.

Nakon testiranja svih triju modela u nastavku slijedi prikaz onih modela koji su nakon provedenih testova pokazali najboljima.

4.3. Testiranje modela

Po uzoru na istraživanje koje je proveo Serra et al. (2014) za turističke regije u Portugalu u prvom modelu su korištene iste varijable kao i u navedenom radu, ali je model proširen za makroekonomske pokazatelje receptivnog tržišta i promatrane županije. Obzirom da je između varijabli *bruto domaći proizvod emitivne zemlje ($BDPPC_{it}$)* i *finalne potrošnje kućanstva (FCI_{it})* uočena srednje jaka i pozitivna korelacija u nastavku rada će se analizirati modeli u kojima spomenute varijable nisu istovremeno uvrštavanje.

Nadalje, u radu su rezultati panel analize provedeni za svaku županiju zasebno te su temeljem dijagnostičkih testova dani rezultati za onaj model koji se na temelju istih pokazao najprikladnijim, bilo da se radi o združenom modelu, modelu s fiksnim efektom ili modelu sa slučajnom efektom.

Tako se združeni model pokazao najboljim za Primorsko-goransku, Zadarsku i Dubrovačko-neretvansku županiju. Model s slučajnim efektom se pokazao najboljim za Istarsku, Ličko-senjsku i većinu modela u Splitsko dalmatinskoj županiji. Za većinu modela u Šibensko-kninskoj županiji je najprikladniji združeni model. Međutim za drugi model *($Model_{SKZ2}$)* u Šibensko-kninskoj županiji i za četvrti model *($Model_{SDZ4}$)* u Splitsko-dalmatinskoj županiji je najprikladniji model s fiksnim efektom.

U nastavku rada se definiraju najpovoljniji izvorni statistički modeli iz kojih će se isključivati varijable u skladu s potrebama analiziranog modela.

Zbog mogućeg problema multikolinearnosti procijenjeno je više modela kako bi se izbjeglo istovremeno uvrštavanje varijabli koje su u međusobnoj korelaciji. U drugom modelu, zbog moguće korelacije s varijablom *rast bruto domaćeg proizvoda emitivnih zemalja ($BDPPC_{it}$),* je isključena varijabla *finalna potrošnja kućanstva (FCI_{it})* za sve županije. Iz istog razloga je u trećem modelu izostavljena varijabla *rast bruto domaćeg proizvoda emitivnih zemalja ($BDPPC_{it}$),* a uključena varijabla *finalna potrošnja kućanstva (FCI_{it}).* U četvrtom modelu je, uz već isključenu varijablu *rast bruto domaćeg proizvoda emitivnih zemalja ($BDPPC_{it}$),* isključena i varijabla *indeks potrošačkih cijena (CPI_{it})* iz razloga što je uočena srednje jaka pozitivna korelacija s varijablama *bruto domaći proizvod županije ($BDPPC_{z,t-1}$)* i *sezonskom zaposlenosti u županiji ($EN_{z,t-1}$).* Iz petog modela su uz već isključene varijable *rast bruto domaćeg proizvoda emitivnih zemalja ($BDPPC_{it}$)* i *indeksa potrošačkih cijena (CPI_{it})* isključena i varijabla *tečaja Republike Hrvatske (ER_{HR})* zbog mogućeg problema

multikolinearnosti s varijablom *bruto domaći proizvod županije* ($BDPPC_{z,t-1}$). Ovaj model nije proveden za Ličko-senjsku županiju jer u toj županiji nije uočen mogući problem multikolinearnosti između *tečaja Republike Hrvatske* (ER_{HR}) i *bruto domaćeg proizvoda županije* ($BDPPC_{z,t-1}$).

Za dvije županije se uvodi i šesti model. U *Šibensko-kninskoj županiji* je nakon provedenog testa korelacije uočen mogući problem multikolinearnosti između varijable *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) i dviju varijabli: *tečaja Republike Hrvatske* (ER_{HR}) i *sezonske zaposlenosti u županiji* ($EN_{z,t-1}$) te je dodan šesti model iz kojeg su isključene varijable *rast bruto domaćeg proizvoda emitivnih zemalja* ($BDPPC_{it}$), *indeks potrošačkih cijena* (CPI_{it}) i varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$), kako bi se dobio model u kojem nije moguć problema multikolinearnosti između varijabli.

Za razliku od većine ostalih županija varijabla *tečaj Republike Hrvatske* (ER_{HR}) statistički značajan za *Dubrovačku neretvansku županiju* dok varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) nije statistički značajna. Stoga je za tu županiju također uveden šesti model u koji se uključuje varijabla *tečaja Republike Hrvatske* (ER_{HR}), a isključuje se varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$).

Proveden je Wooldriegov test koji je potvrdio da u većini županija nema autokorelacije u procijenjenim modelima.

U tablici 18 dani su rezultati za Istarsku županiju.

Tablica 18: Rezultati panel analize - Istarska županija

	$Model_{IZ1}$	$Model_{IZ2}$	$Model_{IZ3}$	$Model_{IZ4}$	$Model_{IZ5}$
VARIJABLA	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}
$BDPPC_{it}$	-3048.0 (5919.3)	6356.1 (4981.6)			
$UNEMP_{it}$	-6166.2** (3024.0)	-6302.1** (2897.4)	-6305.5** (2936.7)	-6270.5** (3002.6)	-6251.3** (3051.1)
CPI_{it}	1762.3 (2265.2)	201.6 (2281.0)	1468.0 (2183.8)		
FCI_{it}	20873.8*** (7521.6)		18529.4*** (6088.5)	18231.7*** (6040.8)	19918.2*** (6023.2)
ER_{HR}	-4368.5 (36312.0)	-19535.0 (37014.0)	-9228.7 (35000.4)	-12354.3 (34514.4)	
$EN_{z,t-1}$	45.91* (25.53)	48.45* (25.93)	42.91* (24.53)	43.68* (24.95)	37.31 (60.80)
$BDPPC_{z,t-1}$	-10311.6** (4613.7)	-9098.3* (4759.1)	-11401.1*** (4051.4)	-13003.1*** (3312.6)	-13469.6*** (3570.7)
_cons	-152653.6 (330453.3)	88574.5 (329495.6)	-89014.6 (305685.3)	73476.1 (184267.7)	10658.1 (145105.6)
F-test	0.0079	0.0128	0.0068	0.0060	0.0018
LM-test	0.0071	0.0296	0.0065	0.0053	0.0006
Hausman test	0.4761	0.3921	0.4069	0.4851	0.7197
Odabrani model	***Model s slučajni efektom***	***Model s slučajni efektom***	***Model s slučajni efektom***	***Model s slučajni efektom***	***Model s slučajni efektom***
N	97	98	97	97	97

**** označava ju statističku značajnost na razini *p < 0.1 ** p < 0,.05, ***p < 0.01; vrijednosti u zagradama su t-vrijednosti*
Izvor:izradila autorica

Za Istarsku županiju je, nakon provedenog F-testa i LM-testa, proveden Hausman test na temelju kojeg se najprikladnijim pokazao model sa slučajnim efektom.

U drugom modelu ($Model_{IZ2}$) je varijabla *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) statistički značajna pri razini pouzdanosti od 95%, a varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) pri razini pouzdanosti od 90%. Varijabla *sezonska zaposlenost u županiji* ($EN_{z,t-1}$) je statistički značajna pri razini pouzdanosti od 90%.

U slijedećem modelu ($Model_{IZ3}$) procjenjuje se da su varijable *finalna potrošnja kućanstva* (FCI_{it}) i *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) statistički značajne pri razini pouzdanosti od 99%, a varijabla *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) je

statistički značajna pri razini signifikantnosti od 95%, dok se varijabla *sezonska zaposlenost u županiji ($EN_{z,t-1}$)* statistički značajna pri razini signifikantnosti od 90%.

U četvrtom modelu ($Model_{IZ4}$) su dobivene iste procjene kao i u prethodnom modelu: varijable *finalna potrošnja kućanstva (FCI_{it})* i *bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$)* su statistički značajne pri razini pouzdanosti od 99%, a varijabla *ukupna nezaposlenost u emitivnoj zemlji ($UNEMP_{it}$)* je statistički značajna pri razini signifikantnosti od 95% dok se varijabla *sezonska zaposlenost u županiji ($EN_{z,t-1}$)* statistički značajna pri razini signifikantnosti od 90%.

U petom modelu ($Model_{IZ5}$) su varijable *finalna potrošnja kućanstva (FCI_{it})* i *bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$)* statistički značajne pri razini pouzdanosti od 99%. *Ukupna nezaposlenost u emitivnoj zemlji ($UNEMP_{it}$)* je statistički značajna pri razini signifikantnosti od 95%. Varijabla *sezonska zaposlenost u županiji ($EN_{z,t-1}$)* nije statistički značajna.

Iz navedenih analiza prikazanih u tablici 18 može se zaključiti da su u Istarskoj županiji varijable *finalna potrošnja kućanstva (FCI_{it})* i *ukupna nezaposlenost u emitivnoj zemlji ($UNEMP_{it}$)* statistički značajne u svim modelima s tim da *finalna potrošnja kućanstva (FCI_{it})* ima pozitivan utjecaj, a *ukupna nezaposlenost u emitivnoj zemlji ($UNEMP_{it}$)* ima negativan utjecaj. Varijabla *sezonska zaposlenost u županiji ($EN_{z,t-1}$)* ima pozitivan smjer i samo u posljednjem modelu *($Model_{IZ5}$)* nije statistički značajna. Varijabla *bruto domaćeg proizvoda promatrane županije ($BDPPC_{z,t-1}$)* ima negativan smjer i statistički je značajna u svim modelima. Varijable *rast bruto domaćeg proizvoda emitivnih zemalja ($BDPPC_{it}$), indeks potrošačkih cijena (CPI_{it})* i *tečaja Republike Hrvatske (ER_{HR}),*u niti jednom modelu nisu statistički značajni.

U tablici 19 dani su rezultati za Primorsko-goransku županiju

Tablica 19: Rezultati panel analize - Primorsko-goranska županija

	$Model_{PGZ1}$	$Model_{PGZ2}$	$Model_{PGZ3}$	$Model_{PGZ4}$	$Model_{PGZ5}$
VARIJABLA	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}
$BDPPC_{it}$	11928.8* (6285.8)	12190.0*** (4429.1)			
$UNEMP_{it}$	-3031.1 (2220.5)	-2713.0 (2022.3)	-2171.6 (2207.2)	-2162.6 (2188.9)	-2249.9 (2180.8)
CPI_{it}	-368.3 (2940.8)	-471.5 (2815.2)	173.5 (2971.9)		
FCI_{it}	505.6 (8126.0)		11328.0* (5877.8)	11241.6* (5654.7)	11162.5* (5640.5)
ER_{HR}	-51451.9 (44424.6)	-50839.6 (42721.8)	-30531.7 (43696.4)	-31421.9 (40707.9)	
$EN_{z,t-1}$	68.15 (78.25)	67.10 (77.19)	63.69 (79.41)	66.82 (58.27)	54.86 (56.04)
$BDPPC_{z,t-1}$	-4249.4* (2532.1)	-4218.3* (2494.1)	-2513.0 (2397.3)	-2587.4 (2018.2)	-2620.3 (2013.0)
_cons	213445.5 (350408.1)	220095.0 (325225.3)	44067.2 (344057.7)	58988.9 (228933.0)	-85414.9 (131643.8)
F-test	0.5742	0.5463	0.5526	0.5442	0.5442
LM-test	1.0000	0.4229	0.4378	0.4404	0.5340
Hausman test					
Odabrani model	***Združeni model***	***Združeni model***	***Združeni model***	***Združeni model***	***Združeni model***
N	91	92	91	91	91
R^2	0.103	0.102	0.064	0.064	0.064

**** označava ju statističku značajnost na razini *p < 0.1 ** p < 0,.05, ***p < 0.01; vrijednosti u zagradama su t-vrijednosti*
Izvor:izradila autorica

Nakon provedenih testova, F-testa i LM-testa, nulta hipoteza se ne odbacuje, te se donosi zaključak da modeli s fiksnim i slučajnim efektom nisu adekvatni u procjeni, te se prihvaća združeni model kao najprikladnijim model za Primorsko-goransku županiju.

Iz tablice 19 se može zaključiti da su u drugom modelu ($Model_{PGZ2}$) dvije varijable statistički značajne i to *rast bruto domaćeg proizvoda emitivnih zemalja* ($BDPPC_{it}$) pri razini pouzdanosti od 99%, te varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) pri razini pouzdanosti od 90%. Ostale varijable nisu statistički značajne.

U trećem, četvrtom i petom modelu ($Model_{PGZ3}$ $Model_{PGZ4}$ *i* $Model_{PGZ5}$) je samo varijabla *finalna potrošnja kućanstva* (FCI_{it}) statistički značajna i to pri razini pouzdanosti od 90%.

U Primorsko-goranskoj županiji je varijabla *finalna potrošnja kućanstva (FCI_{it})* statistički značajne u svim interpretiranim modelima i pozitivno utječe na broj noćenja turista. Varijabla *rast bruto domaćeg proizvoda emitivnih zemalja ($BDPPC_{it}$)* ima pozitivan smjer i statistički je značajna u jednom modelu *($Model_{PGZ2}$)*, dok je varijabla *bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$)* u dva modela *($Model_{PGZ20}$* i *$Model_{PGZ3}$*) statistički značajna, ali ima negativan smjer.

Tablici 20 prikazuje rezultate Ličko senjske županije .

Tablica 20: Rezultati panel analize - Ličko-senjska županija

	$Model_{LSZ1}$	***$Model_{LSZ2}$***	***$Model_{LSZ3}$***	***$Model_{LSZ4}$***
VARIJABLA	***BN_{izt}***	***BN_{izt}***	***BN_{izt}***	***BN_{izt}***
$BDPPC_{it}$	190.7 (641.9)	732.7 (459.8)		
$UNEMP_{it}$	-753.6** (380.7)	-835.0** (416.3)	-796.9* (412.2)	-849.2* (438.8)
CPI_{it}	55.10 (412.3)	-24.07 (404.7)	25.94 (403.2)	
FCI_{it}	1112.2 (887.4)		1325.5** (636.9)	1334.4** (617.4)
ER_{HR}	-6696.7 (5595.3)	-6773.2 (5370.3)	-6145.7 (5179.6)	-6161.4 (4857.4)
$EN_{z,t-1}$	24.22 (23.21)	21.40 (22.60)	25.83 (22.71)	27.35** (11.65)
$BDPPC_{z,t-1}$	-254.7 (167.1)	-242.6 (159.3)	-243.4 (154.4)	-246.6 (151.5)
_cons	36584.0 (50620.1)	47115.2 (48652.5)	36359.4 (49171.1)	39000.0 (25565.6)
F-test	0.0000	0.0000	0.0000	0.0000
LM-test	0.0000	0.0000	0.0000	0.0000
Hausman test	0.0853	0.3949	0.2409	0.4857
Odabrani model	***Model s slučajni efektom***	***Model s slučajni efektom***	***Model s slučajni efektom***	***Model s slučajni efektom***
N	97	98	97	97

**** označava ju statističku značajnost na razini *p < 0.1 ** p < 0,.05, ***p < 0.01; vrijednosti u zagradama su t-vrijednosti*
Izvor:izradila autorica

Za Ličko-senjsku županiju su provedeni F-test i LM-test, te se nakon dobivenih rezultata kojima se ne odbacuje nulta hipoteza, proveo i Hausman test kako bi se odredilo da li je za daljnje istraživanja prikladniji model sa fiksnim efektom ili model s slučajnim efektom. Na

temelju rezultata Hausmanovog testa prihvaćen je model s slučajnim efektom kao najprikladniji model za Ličko-senjsku županiju.

Iz tablice 20 je vidljivo da je u drugom modelu ($Model_{LSZ2}$) samo varijabla *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) statistički značajne pri razini pouzdanosti od 95%. Ostale varijable nisu statistički značajne.

U trećem modelu ($Model_{LSZ3}$) su statistički značajne *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) te *indeks potrošačkih cijena* pri razini pouzdanosti od 90%, dok je *finalna potrošnja kućanstva* (FCI_{it}) statistički značajna pri razini pouzdanosti od 95%. Ostale varijable nisu statistički značajne.

U četvrtom modelu ($Model_{LSZ4}$) varijabla *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) je statistički značajne pri razini pouzdanosti od 90%, a *finalna potrošnja kućanstva* (FCI_{it}) i *sezonska zaposlenost u županiji* ($EN_{l.LSZ}$) su statistički značajne pri razini pouzdanosti od 95%. Varijable *tečaj Republike Hrvatske* (ER_{HR}) i *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) nisu statistički značajne.

Obzirom da za Ličko-senjsku županiju nije uočen mogući problem multikolinearnosti između *tečaja Republike Hrvatske* (ER_{HR}) i *bruto domaćeg proizvoda županije* ($BDPPC_{z,t-1}$), nije bilo potrebe istraživanje proširivati za peti model koji pretpostavlja korelaciju između te dvije varijable. Za ovu županiju je statistički značajna *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) u svim modelima i ima negativan smjer, dok je *finalna potrošnja kućanstva* (FCI_{it}) pozitivnog smjera i značajna je u dva modela ($Model_{LS3}$ i $Model_{LS4}$). *Sezonska zaposlenost u županiji* ($EN_{z,t-1}$) ima pozitivan smjer, a statistički je značajna samo u četvrtom modelu ($Model_{LS2}$).

U tablici 21 dani su rezultati za Zadarsku županiju

Tablica 21: Rezultati panel analize - Zadarska županija

	$Model_{ZZ1}$	$Model_{ZZ2}$	$Model_{ZZ3}$	$Model_{ZZ4}$	$Model_{ZZ5}$
VARIJABLA	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}
$BDPPC_{it}$	4935.8 (6105.0)	7100.5 (4372.9)			
$UNEMP_{it}$	-1934.7 (2066.4)	-2073.8 (1890.5)	-1584.4 (2016.6)	-1530.4 (2017.0)	-1499.0 (2016.1)
CPI_{it}	4739.5 (3850.0)	4949.5 (3789.7)	3852.4 (3683.3)		
FCI_{it}	3951.1 (7682.6)		8239.3 (5547.0)	7462.9 (5500.0)	7968.5 (5473.7)
ER_{HR}	75132.4 (50838.8)	76346.9 (50197.1)	71603.0 (50553.5)	37853.7 (38936.3)	
$EN_{z,t-1}$	-57.43 (46.29)	-63.50 (44.29)	-43.12 (42.69)	-5.424 (22.90)	3.643 (20.91)
$BDPPC_{z,t-1}$	-1882.0 (2067.8)	-1829.1 (2045.0)	-1327.5 (1947.0)	-1861.9 (1879.7)	-1714.1 (1873.0)
_cons	-743356.4 (534184.2)	-758393.1 (528217.3)	-662666.8 (523767.3)	-157543.2 (202829.0)	35519.1 (41268.2)
F-test	0.8788	0.8746	0.8485	0.8329	0.8327
LM-test	1.0000	1.0000	1.0000	1.0000	1.0000
Hausman test					
Odabrani model	***Združeni model***	***Združeni model***	***Združeni model***	***Združeni model***	***Združeni model***
N	97	98	97	97	97
R^2	0.056	0.054	0.049	0.038	0.028

**** označava ju statističku značajnost na razini *p < 0.1 ** p < 0,.05, ***p < 0.01; vrijednosti u zagradama su t-vrijednosti*

Izvor:izradila autorica

Kako se na osnovu rezultata F-testa i LM-testa odbacila nulta hipoteza prihvaćen je združeni model kao najprikladnijim modelom za Zadarsku županiju. Međutim, za razliku od ostalih županija za Zadarsku županiju u niti jednom modelu nema statistički značajnih varijabli što rezultira odbacivanjem postavljenih hipoteza. Prve hipoteze kojom se tvrdi da makroekonomski pokazatelji emitivnih tržišta značajno utječu na rast noćenja stranih turista u primorskim županijama Republike Hrvatske, odnosno Zadarske županije, te druge hipoteze kojom se tvrdi da makroekonomski pokazatelji receptivne zemlje i promatranih županija (Zadarske županije), značajno utječu na rast noćenja stranih turista u primorskoj - Zadarskoj županiji.

Tablica 22 prikazuje rezultate Šibensko-kninske županije

Tablica 22: Rezultati panel analize - Šibensko-kninska županija

	$Model_{SKZ1}$	$Model_{SKZ2}$	$Model_{SKZ3}$	$Model_{SKZ4}$	$Model_{SKZ5}$	$Model_{SKZ6}$
VARIJABLA	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}
$BDPPC_{it}$	-3566.5 (2268.3)	-4318.8** (1999.5)				
$UNEMP_{it}$	87.17 (774.9)	-3813.2 (2690.1)	-156.1 (765.4)	-118.7 (761.2)	50.35 (799.1)	1.211 (721.4)
CPI_{it}	760.1 (1214.0)	133.1 (1268.5)	833.7 (1223.0)			
FCI_{it}	6851.5** (2796.8)		3915.3* (2098.9)	3652.9* (2057.3)	2894.7 (2150.8)	4307.2** (1705.7)
ER_{HR}	49156.1*** (13910.2)	54120.4*** (15446.2)	46336.2*** (13906.4)	45435.5*** (13802.7)		47595.7*** (12813.3)
$EN_{z,t-1}$	-17.90 (19.76)	-18.47 (20.15)	-20.88 (19.83)	-9.870 (11.46)	-8.475 (12.05)	-19.93** (8.404)
$BDPPC_{z,t-1}$	1405.5** (681.3)	2372.1*** (715.0)	912.3 (609.7)	850.4 (601.2)	1293.9** (616.4)	
_cons	-302702.8** (124718.6)	-224107.8* (123331.0)	-286493.9** (127169.8)	-219879.7*** (78198.8)	26046.0 (24303.6)	-212913.1*** (70805.6)
F-test	0.2237	0.0793	0.5703	0.5330	0.5493	0.7662
LM-test	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
Hausman test						
Odabrani model	***Združeni model***	***Model s fiksnim efektom***	***Združeni model***	***Združeni model***	***Združeni model***	***Združeni model***
N	97	98	97	97	97	97
R^2	0.262	0.281	0.242	0.238	0.147	0.219

**** označava ju statističku značajnost na razini *p < 0.1 ** p < 0,.05, ***p < 0.01; vrijednosti u zagradama su t-vrijednosti*
Izvor:izradila autorica

Na temelju provedenih testova, F-testa i LM-testa može se zaključiti da je združeni model najbolji pokazatelj za Šibensko-kninsku županiju, osim za drugi model ($Model_{SKZ2}$) u kojem se na temelju F-testa moglo zaključiti da je model s fiksnim efektom najprikladniji pokazatelj.

U drugom modelu ($Model_{SKZ2}$) su varijable *tečaj Republici Hrvatskoj* (ER_{HR}) i *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) statistički značajne pri razini pouzdanosti od 99%. *Rast bruto domaćeg proizvoda emitivnih zemalja* ($BDPPC_{it}$) je također statistički značajan pri razini pouzdanosti od 95%.

U trećem ($Model_{SKZ3}$) i četvrtom ($Model_{SKZ4}$) modelu je statistički značajna varijabla *finalna potrošnja kućanstva* (FCI_{it}) pri razini pouzdanosti od 90% te varijable i *tečaj Republike Hrvatske* (ER_{HR}) pri razini pouzdanosti od 99%.

U petom modelu ($Model_{SDZ5}$) je statistički značajna samo varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) i to pri razini pouzdanosti od 95%.

Obzirom da je Šibensko-kninska županija jedina županija u kojoj je nakon provedenog testa korelacije uočio mogući problem multikolinearnosti između varijable *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) i dviju varijabli: *tečaja Republike Hrvatske* (ER_{HR}) i *sezonske zaposlenosti u županiji* ($EN_{z,t-1}$) dodan je još jedan model iz kojeg su isključene varijable *rast bruto domaćeg proizvoda emitivnih zemalja* ($BDPPC_{it}$), *indeks potrošačkih cijena* (CPI_{it}) i varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) kako bi se dobio model u kojem ne postoji mogućnost problema multikolinearnosti između varijabli. U tom modelu ($Model_{SDZ6}$) su varijable *finalna potrošnja kućanstva* (FCI_{it}) i *sezonska zaposlenost u županiji* ($EN_{z,t-1}$) statistički značajne pri razini pouzdanosti od 95%, a varijabla *tečaj Republike Hrvatske* (ER_{HR}) je statistički značajna pri razini pouzdanosti od 99%. Varijabla *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) nije statistički značajna.

U Šibensko-kninskoj županiji, kao što se može vidjeti u tablici 22, *tečaj u Republici Hrvatskoj* (ER_{HR}) je pozitivnog smjera i ima najveći stupanj signifikantnosti od 99% u svim modelima. *Rast bruto domaćeg proizvoda emitivnih zemalja* ($BDPPC_{it}$) je također statistički značajan, ali suprotno očekivanju dobiveni predznak je negativnog smjera. Do sličnih rezultata u svom istraživanju je došao i Stručka (2000) za tržište Češke gdje se uočava negativan predznak kod dohodovnog koeficijenta mjerenog realnim BDP-om emitivnog tržišta. On zaključuje da takav rezultat sugerira da je Hrvatska tom tržištu inferiorno dobro, u ovom slučaju Šibensko-kninska županija. Varijabla *finalna potrošnja kućanstva* (FCI_{it}) je pozitivnog smjera i samo u zadnjem modelu ($Model_{SKZ5}$) nije statistički značajna, a varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) je pozitivnog smjera i statistički je značajna u drugom ($Model_{SKZ2}$) i petom ($Model_{SKZ5}$) modelu.

U tablici 23 dani su rezultati za Splitsko-dalmatinsku županiju.

Tablica 23: Rezultati panel analize - Splitsko-dalmatinska županija

	$Model_{SDZ1}$	$Model_{SDZ2}$	$Model_{SDZ3}$	$Model_{SDZ4}$	$Model_{SDZ5}$
VARIJABLA	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}
$BDPPC_{it}$	7469.1** (3332.0)	11028.9*** (2672.8)			
$UNEMP_{it}$	-1510.0 (1535.8)	-1543.6 (1445.3)	-902.5 (1488.3)	-5973.5 (4077.2)	-744.5 (1429.0)
CPI_{it}	-920.5 (2005.7)	-1603.9 (1985.2)	170.6 (1993.0)		
FCI_{it}	7308.3* (4158.3)		13279.4*** (3374.2)	8215.1** (3820.1)	13502.5*** (3333.7)
ER_{HR}	2152.9 (25548.9)	-4562.6 (25349.1)	16468.8 (25354.4)	28840.7 (23349.3)	
$EN_{z,t-1}$	23.48* (12.17)	24.03** (12.26)	19.45 (12.34)	18.34*** (6.905)	22.44*** (6.402)
$BDPPC_{z,t-1}$	-2921.8* (1507.6)	-2830.4* (1514.4)	-1299.2 (1340.7)	-590.4 (1174.4)	-1238.9 (1136.8)
_cons	12756.2 (259055.1)	118012.4 (253256.0)	-162026.0 (253215.5)	-156095.5 (107284.7)	-68883.5** (31620.7)
F-test	0.0227	0.0059	0.0089	0.0084	0.0114
LM-test	0.0660	0.0135	0.0247	0.0248	0.0259
Hausman test	0.3421	0.1402	0.1271	0.0752	0.1209
Odabrani model	***Model s slučajni efektom***	***Model s slučajni efektom***	***Model s slučajni efektom***	***Model s fiksnim efektom***	***Model s slučajni efektom***
N	97	98	97	97	97

**** označava ju statističku značajnost na razini *p < 0.1 ** p < 0,.05, ***p < 0.01; vrijednosti u zagradama su t-vrijednosti*
Izvor:izradila autorica

Za Splitsko-dalmatinsku županiju se, nakon provedenog Hausman test, zaključilo da je model s slučajnim efektom najprikladniji pokazatelj za prvi, drugi, treći i peti model, dok je za četvrti model najprikladniji model s fiksnim efektom.

U drugom modelu ($Model_{SDZ2}$) se statistički značajna pokazala varijabla *rast bruto domaćeg proizvoda emitivnih zemalja ($BDPPC_{it}$)* pri razini pouzdanosti od 99%, varijabla *sezonska zaposlenost u županiji ($EN_{z,t-1}$),* pri razini pouzdanosti od 95%, te varijabla *bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$)* pri razini pouzdanosti od 90%.

U trećem modelu ($Model_{SDZ3}$) je statistički značajna varijabla *finalna potrošnja kućanstva (FCI)* pri razini pouzdanosti od 99%. Ostale varijable nisu statistički značajne.

U četvrtom modelu ($Model_{SDZ4}$) su statistički značajne varijable *finalna potrošnja kućanstva (FCI)*, pri razini signifikantnosti od 95% i *sezonska zaposlenost u županiji* ($EN_{z,t-1}$) pri razini pouzdanosti od 99%.

U petom modelu varijable *finalna potrošnja kućanstva* (FCI_{it}) i *sezonska zaposlenost u županiji* ($EN_{z,t-1}$) su statistički značajne pri razini pouzdanosti od 99%, a varijable *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) i *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) nisu statistički značajne.

U Splitsko-dalmatinskoj županije pozitivan utjecaj na broj noćenja turista imaju varijable *rast bruto domaćeg proizvoda emitivnih zemalja* ($BDPPC_{it}$) i *finalna potrošnja kućanstva* (FCI_{it}) te su statistički značajne u svim modelima. Varijabla *sezonska zaposlenost u županiji* ($EN_{z,t-1}$) također ima pozitivan utjecaj te samo u trećem modelu ($Model_{SDZ3}$) nije statistički značajna. *Bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) negativno utječe na broj noćenja turista, ali je samo u drugom modelu ($Model_{SDZ2}$) statistički značajan.

Tablica 22 prikazuje rezultate Dubrovačko-neretvanska županija

Tablica 24: Rezultati panel analize - Dubrovačko-neretvanska županija

	$Model_{DNZ1}$	$Model_{DNZ2}$	$Model_{DNZ3}$	$Model_{DNZ4}$	$Model_{DNZ5}$	$Model_{DNZ6}$
VARIJABLA	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}	BN_{izt}
$BDPPC_{it}$	-1276.8 (3124.0)	2602.9 (2352.9)				
$UNEMP_{it}$	-546.3 (1159.7)	-687.7 (1079.4)	-640.1 (1131.5)	-652.7 (1123.3)	-392.5 (1174.9)	-328.5 (1087.3)
CPI_{it}	-283.7 (1844.0)	-598.2 (1846.4)	-331.5 (1831.8)			
FCI_{it}	7843.5* (4201.1)		6701.9** (3123.6)	6733.4** (3102.1)	5487.0* (3227.1)	2346.3 (2496.6)
ER_{HR}	68477.3*** (22040.1)	60896.1*** (21795.6)	67257.5*** (21735.8)	67931.1*** (21300.6)		52777.2** (20130.5)
$EN_{z,t-1}$	0.708 (25.05)	-1.438 (25.23)	0.614 (24.94)	-2.804 (16.20)	10.21 (16.44)	-7.039 (12.07)
$BDPPC_{z,t-1}$	-2485.6* (1404.3)	-2176.0 (1405.9)	-2631.3* (1352.0)	-2480.5** (1059.2)	-1478.0 (1060.7)	
_cons	-331007.8* (195605.6)	-249332.1 (192274.2)	-318452.8 (192282.6)	-346422.8*** (113777.8)	-9297.5 (44128.7)	-260331.8** (106294.8)
F-test	0.7730	0.6246	0.7538	0.7450	0.8501	0.6343
LM-test	0.1989	0.1989	1.0000	1.0000	1.0000	1.0000
Hausman test						
Odabrani model	***Združeni model***	***Združeni model***	***Združeni model***	***Združeni model***	***Združeni model***	***Združeni model***
N	97	98	97	97	97	107

**** označava ju statističku značajnost na razini *p < 0.1 ** p < 0,.05, ***p < 0.01; vrijednosti u zagradama su t-vrijednosti*
Izvor:izradila autorica

Za Dubrovačko-neretvansku županiju je, nakon provedenih testova F-testa i LM-testa, odabran združeni model kao najprikladniji pokazatelj.

U drugom modelu ($Model_{DNZ2}$) je statistički značajan samo *tečaj Republike Hrvatske* (ER_{HR}) pri razini pouzdanosti od 99%. Ostale varijable nisu statistički značajne.

U trećem ($Model_{DNZ3}$) i četvrtom modelu ($Model_{DNZ4}$) su statistički značajni varijabla *finalna potrošnja kućanstva* (FCI_{it}) pri razini pouzdanosti od 95% i *tečaj Republike Hrvatske* (ER_{HR}) pri razini pouzdanosti od 99%. *Bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) je statistički značajan u trećem modelu ($Model_{DNZ3}$) pri razini pouzdanosti od 90% i u četvrtom modelu ($Model_{DNZ4}$) pri razini pouzdanosti od 95%.

U petom modelu ($Model_{DNZ5}$) je isključena varijabla *tečaja Republike Hrvatske* (ER_{HR}) koja je u ovoj županiji imala jaku korelaciji s varijablom *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$). U modelu je statistički značajna samo varijabla *finalna potrošnja kućanstva* (FCI_{it}) pri razini pouzdanosti od 90%. Ostale varijable nisu statistički značajne.

Za razliku od većine županija, u *Dubrovačko-neretvanskoj županiji* se varijabla *tečaj Republike Hrvatske* (ER_{HR}) pokazao statistički značajan, a varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) statistički neznačajna. Stoga je uveden šesti model ($Model_{DNZ6}$) u koji se uključuje varijabla *tečaja Republike Hrvatske* (ER_{HR}), a isključuje varijabla *bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$). U tom modelu je statistički značajna samo varijabla *tečaj Republike Hrvatske* (ER_{HR}) pri razini pouzdanosti od 95% dok ostale varijable nisu statistički značajne.

Iz tablice 24 može se zaključiti da u *Dubrovačko-neretvanskoj županiji* varijable *finalna potrošnja kućanstva* (FCI_{it}) i *tečaj Republike Hrvatske* (ER_{HR}) imaju pozitivan utjecaj na broj noćenja turista. *Tečaj Republike Hrvatske* (ER_{HR}) je statistički značajna u svim modelima, dok je varijabla *finalna potrošnja kućanstva* (FCI_{it}) samo u posljednjem modelu ($Model_{DNZ6}$) statistički neznačajna. *Bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) negativno utječe na broj noćenja turista te je statistički značajna u trećem i četvrtom modelu ($Model_{DNZ3}$ *i* $Model_{DNZ4}$) .

4.4. Interpretacija rezultata i osvrt na istraživačke hipoteze

Na temelju dosadašnjih istraživanja autorica je odredila očekivani predznak nezavisnih varijabli. U slijedećoj tablici je dat prikaz dobivenih predznaka po županijama.

Tablica 25: Prikaz očekivanog i dobivenog predznaka promatranih varijabli

	Naziv	*Očekivani predznak*	*DOBIVENI PREDZNAK PO ŽUPANIJAM*						
			Istarska županija	*Primorsko-goranska županija*	*Ličko-senjska županija*	*Zadarska županija*	*Šibensko-kninska županija*	*Splitsko-dalmatinska županija*	*Dubrovačko-neretvanska županija*
1	$BDPPC_{it}$	+	+	+	+	+	-	+	+
2	$UNEMP_{it}$	-	-	-	-	-	-/+	-	-
3	CPI_{it}	-	+	-/+	-/+	+	+	-/+	-
4	FCI_{it}	+	+	+	+	+	+	+	+
5	ERHR	+	-	-	-	+	+	-/+	+
6	EN_{zt}	+	+	+	+	-/+	-	+	-/+
7	$BDPPC_{zt}$	+	-	-	-	-	+	-	-

Izvor:izradila autorica

Iz prikazane tablice 25 može se uočiti da su dobiveni rezultati za većinu varijabli u skladu s očekivanim. Utjecaj *Rasta bruto domaćeg proizvoda emitivne zemlje ($BDPPC_{it}$)* na rast *broja noćenja turista iz emitivnih zemalja (BN_{izt})* je u većini županija pozitivan, a pokazao se statistički značajnim u Primorsko-goranskoj i Splitsko-dalmatinskoj županiju. U Šibensko-kninskoj županiji je utjecaj također statički značajan ali negativnog smjera, što bi moglo značiti da je Šibensko-kninska županija inferiorno dobro, odnosno porastom prihoda turista iz emitivnih zemalja dolazi do supstitucije Šibensko-kninske županije s drugom skupljom destinacijom. U ostalim županijama *rast bruto domaćeg proizvoda emitivne zemlje ($BDPPC_{it}$)* nije statistički značajna.

Ukupna nezaposlenost u emitivnoj zemlji ($UNEMP_{it}$) u skladu s očekivanjima negativno utječe na *broj noćenja turista iz emitivnih zemalja (BN_{izt}).* Statistički je značajna u Istarskoj i Ličko-senjskoj županiji što bi značilo da će u slučaju nezaposlenosti, odnosno zbog ekonomskoj neizvjesnosti turisti odgoditi putovanja u te županije. U ostalima županijama ta veza nije značajna što znači na nezaposlenost u tim županijama nema veliki utjecaj na broj noćenja turista.

Iako se očekivalo da će *indeks potrošačkih cijena (CPI_{it})* biti negativno elastičan u ovom istraživanju njegov smjer varira ovisno o promatranoj županiji i promatranom modelu, ali u

niti jednom modelu nije statistički značajan. Što znači da turistička potražnja za promatranim županijama nije uvjetovana rastom cijena emitivnoj zemlji.

Finalna potrošnja kućanstva (FCI_{it}) pozitivno utječe na *broj noćenja turista iz emitivnih zemalja (BN_{izt})* i samo je u Zadarskoj županiji je statistički neznačajna. U ostalim županijama je statistički značajna s različitim razinama pouzdanosti. Na ovaj način moguće je kvantificirati pozitivan učinak na broj noćenjima kada se konačna potrošnja kućanstava na inozemnim tržištima turizma povećava.

Očekivano je da će *tečaj Republike Hrvatske (ER_{HR}),* imati značajan utjecaj i pozitivni smjer. Značajna i pozitivan veza ove varijable s *brojem noćenja turista iz emitivnih zemalja (BN_{izt})* uočena je u Šibensko-kninskoj i Dubrovačko-neretvanskoj županiji. U ostalim županijama ta je veza neznačajna što bi značilo da u tim županijama, za razliku od Šibensko-kninske i Dubrovačko-neretvanske županije, rastom tečaja turisti neće potrošiti više novca, odnosno neće se povećati broj noćenja.

Pretpostavka je da će *sezonska zaposlenost u županiji ($EN_{z,t-1}$)* imati značajnu i pozitivnu vezu s *brojem noćenja turista iz emitivnih zemalja (BN_{izt})* što je i potvrđeno za većinu županija (Istarsku, Ličko-senjsku, Šibensko-kninsku i Splitsko-dalmatinsku županiju). Može se zaključiti da u tim županijama veća sezonska zaposlenost pridonosi boljoj turističkoj usluzi i samim tim pozitivno utječe na broj noćenja. U Zadarskoj i Dubrovačko-neretvanskoj županiji smjer varira ovisno o modelu i nije statički značajan, dok je u Šibensko-kninskoj županiji *sezonska zaposlenost u županiji ($EN_{z,t-1}$)* negativnog smjera, ali je statički značajna samo u jednom modelu.

Utjecaj varijable *bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$)* varira ovisno o strukturi gostiju. U Šibensko-kninskoj županiji veza između *bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$)* i *broja noćenja turista iz emitivnih zemalja (BN_{izt})* statistički je značajna i pozitivnog smjera. Pretpostavlja se da povećanjem BDP-a i zaposlenici u turizmu imaju veća primanja koja uvjetuju veće zadovoljstvo zaposlenika koje pak rezultira pružanjem kvalitetnije uslugu te samim tim pozitivno utječu na broj noćenja. U Istarskoj, Primorsko-goranskoj, Splitsko-dalmatinskoj i Dubrovačko-neretvanskoj županiji ova je varijabla statistički značajna i negativnog smjera što znači da *bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$)* negativno utječe na broj noćenja u navedenim županijama. Moguće je da se razvojem gospodarstva stanovništvo okreće nekom drugim, unosnijim poslovima, što za poslijedicu ima negativan utjecaj na turističku potražnju.

Na temelju svega navedenog može se zaključiti da varijable u većini županija imaju utjecaj očekivanog smjera na *broja noćenja turista iz emitivnih zemalja* (BN_{izt}). U nastavku rada donose se zaključci o prihvaćanju ili odbacivanju hipoteza za svaku razmatranu županiju.

U svim promatranim modelima za Istarsku županiju *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) je statistički značajna i ima negativan utjecaj na *broj noćenja turista* (BN_{izt}) dok je *finalna potrošnja kućanstva* (FCI_{it}) također statistički značajna, ali ima pozitivan utjecaj.

Stoga se može **prihvatiti prva nulta hipoteza koja kaže da makroekonomski pokazatelji emitivnih tržišta (*ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) i *finalna potrošnja kućanstva* (FCI_{it})) značajno utječu na rast noćenja stranih turista u Istarskoj županiji.**

Bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$) je statistički značajna i ima negativan utjecaj na *broj noćenja turista* (BN_{izt}). S*ezonska zaposlenost u županiji* ($EN_{z,t-1}$) utječe pozitivno, ali samo u posljednjem modelu nije statistički značajna.

Također se može **prihvatiti i druga hipoteza u kojoj se tvrdi da makroekonomski pokazatelji receptivne zemlje i makroekonomski pokazatelji promatrane županije (*bruto domaći proizvod promatrane županije* ($BDPPC_{z,t-1}$) i *sezonska zaposlenost u županiji* ($EN_{z,t-1}$)) značajno utječu na rast noćenja stranih turista u Istarskoj županiji.**

Kod Primorsko-goranske županije *rast bruto domaćeg proizvoda emitivnih zemalja* ($BDPPC_{it}$) i *finalna potrošnja kućanstva* (FCI_{it}) su statistički značajni i imaju pozitivan smjer.

Prihvaća se prva nulta hipoteza koja kaže da makroekonomski pokazatelji emitivnih tržišta (*rast bruto domaćeg proizvoda emitivnih zemalja* ($BDPPC_{it}$) i *finalna potrošnja kućanstva* (FCI_{it})) značajno utječu na rast noćenja stranih turista u Primorsko-goranskoj županiji.

Obzirom da ostale varijable nisu značajne u niti jednom modelu **odbacuje se druga nulta hipoteza te se zaključuje da makroekonomski pokazatelji receptivne zemlje i makroekonomski pokazatelji promatrane županije ne utječu na rast noćenja stranih turista u Primorsko-goranskoj županiji.**

Na osnovu rezultata za Ličko-senjsku županiju se zaključuje da je *ukupna nezaposlenost u emitivnoj zemlji* ($UNEMP_{it}$) statistički značajna za sve modele te ima negativan utjecaj na *broj noćenja turista* (BN_{izt}) Također i *finalna potrošnja kućanstva* (FCI_{it}) je statistički značajna u svim modelima i ima pozitivan utjecaj.

Stoga se **prihvaća prva nulta hipoteza koja kaže da makroekonomski pokazatelji emitivnih tržišta (*ukupna nezaposlenost u emitivnoj zemlji ($UNEMP_{it}$)* i *finalna potrošnja kućanstva (FCI_{it})*) značajno utječu na rast noćenja stranih turista u Ličko-senjskoj županiji.**

S*ezonska zaposlenost u županiji ($EN_{z,t-1}$)* u Ličko-senjskoj županiji je u posljednja dva ($Model_{LSZ4}$ i $Model_{LSZ5}$) modela statistički značajna i ima pozitivan utjecaj.

Stoga se **može prihvatiti druga nulta hipoteza u kojoj se tvrdi da makroekonomski pokazatelji promatrane županije (*sezonska zaposlenost u županiji ($EN_{z,t-1}$)*), značajno utječu na rast noćenja stranih turista u Ličko-senjskoj županiji.**

U Zadarskoj županiji niti jedna varijabla nije statistički značajna. Stoga **se odbacuju obe nulte hipoteze i zaključuje se da makroekonomski pokazatelji emitivnih tržišta ne utječu na rast noćenja stranih turista u Zadarskoj županiju, te da makroekonomski pokazatelji receptivne zemlje i makroekonomskih pokazatelja promatrane županije također ne utječu na rast noćenja stranih turista u Zadarskoj županiju.**

U Šibensko-kninskoj županiji *rast bruto domaćeg proizvoda emitivnih zemalja ($BDPPC_{it}$)* ima značajan, ali negativan utjecaj na *broj noćenja turista (BN_{izt}). Finalna potrošnja kućanstva (FCI_{it})* je pozitivnog smjera i u većini modela statistički značajna.

Na osnovu dobivenih rezultata može se **prihvatiti prva nulta hipoteza koja kaže da makroekonomski pokazatelji emitivnih tržišta značajno utječu na rast noćenja stranih turista u Šibensko-kninskoj županiji.**

Tečaj Republike Hrvatske (ER_{HR}) u Šibensko-kninskoj županiji je pozitivnog smjera i u svim modelima statistički značajan. *Sezonska zaposlenost u županiji ($EN_{z,t-1}$)* utječe negativno što ponovno nije u skladu s očekivanjima, ali je značajna samo u posljednjem modelu. *Bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$)* ima pozitivan utjecaj na *broj noćenja turista (BN_{izt})* i značajan je u dva modela.

Također se može **prihvatiti i druga nulta hipoteza u kojoj se tvrdi da makroekonomski pokazatelji receptivne zemlje i makroekonomskih pokazatelja promatrane županije značajno utječu na rast noćenja stranih turista u Šibensko-kninskoj županiji.**

Međutim, prije prihvaćanja postavljenih hipoteza a zbog dobivenih neuobičajenih rezultata bilo bi poželjno detaljnije istražiti inozemnu turističku potražnu u Šibensko-kninskoj županiji.

U Splitsko-dalmatinskoj županiji *rast bruto domaćeg proizvoda emitivnih zemalja ($BDPPC_{it}$)* i *finalna potrošnja kućanstva (FCI_{it})* je statistički značajan i ima pozitivan utjecaj na *broj noćenja turista (BN_{izt})* u svim promatranim modelima.

Prihvaća se prva nulta hipoteza koja kaže da makroekonomski pokazatelji emitivnih tržišta značajno utječu na rast noćenja stranih turista u Splitsko-dalmatinskoj županiji.

Bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$) ima negativan utjecaj na *broj noćenja turista (BN_{izt}),* ali je značajan samo u drugom modelu ($Model_{SDZ2}$) dok *sezonska zaposlenost u županiji ($EN_{z,t-1}$)* utječe pozitivno, a značajna je u drugom ($Model_{SDZ2}$), četvrtom ($Model_{SDZ4}$) i petom ($Model_{SDZ5}$) modelu.

Također se može **prihvatiti i druga nulta hipoteza koja tvrdi da makroekonomski pokazatelji promatrane županije značajno utječu na rast noćenja stranih turista u Splitsko-dalmatinskoj županiji.**

U Dubrovačkoj neretvanskoj županiji *finalna potrošnja kućanstva (FCI_{it})* je pozitivnog smjera i statistički je značajna.

Prihvaća se prva nulta hipoteza koja kaže da makroekonomski pokazatelji emitivnih tržišta (*finalna potrošnja kućanstva (FCI_{it})),* značajno utječe na rast noćenja stranih turista u Dubrovačkoj neretvanskoj županiji.

Tečaj Republike Hrvatske (ER_{HR}) je statistički značajan i pozitivnog smjera, a *bruto domaći proizvod promatrane županije ($BDPPC_{z,t-1}$)* ima negativan utjecaj na *broj noćenja turista (BN_{izt})* te je značajan samo u trećem ($Model_{DNZ3}$) i četvrtome ($Model_{DNZ4}$) modelu.

Prihvaća se i druga nulta hipoteza te se tvrdi da makroekonomski pokazatelji receptivnog tržišta i makroekonomski pokazatelji promatrane županije značajno utječu na rast noćenja stranih turista u Dubrovačkoj neretvanskoj županiji.

Nakon provedenog istraživanja može se uočiti da dvije županije naveliko odskaču u rezultatima u usporedbi s ostalim županijama. Tako u Zadarskoj županiji ne postoji nikakva statistički značajna veza između analiziranih varijabli dok u Šibensko-kninskoj županiji rezultati smjera kretanja za tri promatrane varijable (*bruto domaći proizvod emitivne zemlje, ukupna nezaposlenost u emitivnoj zemlji, bruto domaći proizvod županije)* odskaču od rezultata koji su dobivene za druge županije.

5. ZAKLJUČAK

Turizam u Hrvatskoj je posljednjih godina postao najvažnija gospodarska grana stoga se u ovom radu pokušalo objasniti evoluciju međunarodnih noćenja u svakoj primorskoj županiji u Hrvatskoj. Identificirane su odrednice međunarodne turističke potražnje u Hrvatskoj za sedam primorskih županija na koje otpada 90% od ukupnog broja noćenja stranih turista u Hrvatskoj. Analiza uključuje glavne turističke izvore tržišta u Hrvatskoj: Austriju, Češku, Njemačku, Mađarsku, Italiju, Poljsku, Slovačku, Sloveniju, Francusku, Veliku Britaniju te Bosnu i Hercegovinu. Za objašnjenje turističke potražnje korištene su makroekonomske varijable: rast bruto domaćeg proizvoda emitivnih zemalja, potrošnja kućanstava emitivnih zemalja, ukupna stopa nezaposlenosti emitivnih zemalja i indeks relativnih cijena emitivnih zemalja od 2004. do 2014. godine. Također model se proširuje sa tečajem Hrvatske, bruto domaćim proizvodom promatrane županije i brojem sezonskih radnika u promatranoj županiji za isto razdoblje od 2004. godine do 2014. godine. Doprinos ovog rada počiva na boljem razumijevanju međunarodne turističke potražnje za svaku od sedam županija u Hrvatskoj kroz identifikaciju različitih makroekonomskih odrednica koje objašnjavaju međunarodnu turističku potražnju. Rezultati dobiveni u ovom radu ukazuju na to da inozemna turistička potražnja ima različite obrasce ponašanja ovisno o županiji te da je inozemna turistička potražnja za primorske županije u Hrvatskoj jako dinamična. Što se tiče teorijske implikacije ovi rezultati uglavnom su u skladu s prethodnim studijama. Izradom ovog rada uočeno je kompleksnost analizirane turističke potražnje po primorskim regijama u Hrvatskoj te je stoga daljnje istraživanje neophodno.

U skladu s teoretskim očekivanjima analizirani makroekonomski čimbenici emitivnih zemalja imaju značajan utjecaj na turističku potražnju u primorskim županijama Republike Hrvatske. Najizraženiji je utjecaj varijable finalna potrošnja kućanstva koja u svim županijama ima pozitivan utjecaj na broj noćenja inozemnih turista, i samo za jednu županiju nije statistički značajna. BDPPC emitivnih zemalja ima pozitivan utjecaj na broja noćenja inozemnih turista, dok nezaposlenost u emitivnoj zemlji negativno utječe na broj noćenja. Iako se očekivalo da će indeks potrošačkih cijena biti negativno elastičan u ovom istraživanju njegov smjer varira ovisno o promatranoj županiji i promatranom modelu, ali u niti jednom modelu nije statistički značajan. Makroekonomski čimbenici receptivne zemlje i promatranih županija su se također pokazali značajnima u većini modela, što je predstavlja veliki doprinos ovom istraživanju. Značajna i pozitivna veza tečaja Republike Hrvatske je potvrđena u dvije županije. Sezonska

zaposlenost u županiji iz prethodne godine ima značajnu i pozitivnu vezu u većini županija, utjecaj varijable bruto domaći proizvod promatrane županije je također značajan u većini županija, a smjer utjecaja.

Različite varijable su se pokazale značajnima za različite županije. Na temelju rezultata se za sve županije ne može odbaciti ni prva ni druga hipoteza što implicira da su makroekonomski pokazatelji emitivnih i receptivnih zemalja značajni za modeliranje turističke potražnje u primorskim županijama u Hrvatskoj s tim da nisu univerzalni po svim županijama.

Obzirom da turistička potražnja u primorskim županijama nema univerzalan obrazac ponašanja bilo bi poželjno da se buduća istraživanja turističke potražnje usmjeri na svaku županiju posebno. Za buduća istraživanja bi bilo poželjno uključiti dodatne varijable kao što su *troškovi prijevoza* koji se mogu mjereni cijenom nafte, cijenom avionskih karata i/ili udaljenošću između destinacija. Bitne varijable su i razvijenosti *turističke infrastrukture* koja se može mjeriti brojem raspoloživih smještajnih kapaciteta ili kvalitetom smještajnih kapaciteta (mjerena brojem kategoriziranih zvjezdica), a utjecaj *razvijenosti infrastrukture* receptivne zemlje (mjereni neto investicijama u infrastrukturu). Obzirom da je Hrvatska turistički atraktivna zemlja varijablu *atraktivnost destinacije* (koju se može mjeriti brojem UNESCO-vih lokaliteta svjetske baštine) bi svakako trebalo također uključiti u buduće modele istraživanja. Jako je bitno istražiti utjecaj *ulaganja u marketing* za turističku potražnju iako se ta varijabla zbog nemogućnosti kvalitetnog mjerenja često zaobilazi u empirijskim istraživanjima. *Društveni faktor* u receptivnim zemljama koje je moguće uključiti u buduća istraživanja su *sigurnost* i *politička stabilnost* te faktor *obrazovanja.* Obzirom da je turistička potražnja u primorskim županijama sezonskog karaktera, odnosno uvjetovana lijepim vremenom, bilo bi poželjno ispitati učinke sunčanih dana na turističku potražnju.

Većina znanstvenik smatra da ljudsko ponašanje nije toliko racionalno i u potpunosti ekonomski uvjetovano, stoga bi za dublje razumijevanje turističke potražnje analiza trebala ići dalje od mikro i makroekonomskih čimbenika.

SAŽETAK

Ključne riječi: turistička potražnja, makroekonomski čimbenici emitivnih i receptivnih tržišta, primorske županije Republike Hrvatske, panel analiza.

Svrha ovog rada je istražiti utjecaja najvažnijih makroekonomskih čimbenika emitivnih zemalja, receptivne zemlje, te makroekonomskih čimbenika promatranih županija na broj noćenja turista u primorskim županijama Republike Hrvatske. Provedena je panel analiza turističke potražnje za sedam županija u Republici Hrvatskoj (Istarska, Primorsko-goranska, Zadarska, Ličko-senjska, Šibensko-kninska, Splitsko-dalmatinska, Dubrovačko-neretvanska), u kojima se promatralo utjecaj jedanaest emitivnih tržišta (Austrija, Češka, Italija, Mađarska, Njemačka, Poljska, Slovačka, Slovenija, Francuska, Velika Britanija, Bosna i Hercegovina) u razdoblju od 2004. do 2014. godine. Kako bi se objasnila potražnja za turizam, koriste se makroekonomske varijable: rast BDPPC-a, nezaposlenost, finalna potrošnju, indeks potrošačkih cijena za jedanaest zemljama porijekla, tečaj receptivne zemlje, te BDPPC-a i sezonsku zaposlenost promatranih županija. Dobiveni rezultati su ukazali na važnost makroekonomskih pokazatelja kako emitivnih zemalja tako i receptivne zemlje i makroekonomskih pokazatelja pojedinih županija. Također rezultati pokazuju da inozemna turistička potražnja ima različite obrasce ponašanja ovisno o promatranim županijama.

SUMMARY

Keywords: tourism demand, macroeconomic factors emitting and receptive markets, the Croatian coastal counties, panel analysis.

The main purpose of this paper is to investigate the influence of the most important macroeconomic factors emitting countries, receptive country, as well as macroeconomic factors observed counties in the number of overnight stays in the coastal Croatian counties. Here was conducted a panel analysis of tourist demand for seven counties in the Republic of Croatia (Istria, Primorje-Gorski Kotar, Zadar, Dalmatia-Split, Sibenik-Knin, Split-Dalmatia, Dubrovnik-Neretva), where was observed the influence of eleven source markets (Austria, Czech Republic , Italy, Hungary, Germany, Poland, Slovakia, Slovenia, France, the United Kingdom, Bosnia and Herzegovina) in the period from 2004 to 2014. In order to explain the demand for tourism, here are used macroeconomic variables: growth GDPpc's, unemployment, final consumption, the consumer price index for the first eleven countries of origin, currency in receiving country , as well as GDPpc and seasonal employment in observed counties. The results pointed to the importance of macroeconomic indicators of the emitting countries as well as receptive country and the macroeconomic indicators of individual counties. Also the results showed that foreign tourist demand had different patterns of behavior depending on the observed counties.

LITERATURA

Belullo, A., Kižman, D. (2000): *Utjecaj promjena u dohocima glavnih emitivnih zemalja na turistički promet u Hrvatskoj.* Ekonomski pregled, 51 (7/8). pp. 681-700. ISSN 0424-7558.

Belullo. A. (2011): Analiza *čimbenika elastičnosti na dolaske i noćenja turista na primjeru turističkog naselja Barbariga,* Pula: Sveučilište Jurja Dobrile u Puli, Oeconomica Jadertina 2/2011.

Bentum-Ennin, I. (2014): *Modelling international tourism demand in Gana, University of Cape Coast, Ghana,* Global Business and Economics Research Journal ISSN: 2302-4593 Vol. 3 (12): 1 – 22.

Botti, L., Peypoch, N., Randriamboarison, R., Solonandrasana, B (2006): *An Econometric Model of Tourism Demand in France,* University of Perpignan, pp. 115-126.

Brida, J. G., Risso, W.A., (2009): *A dynamic panel data study of the German demand for tourism in South Tyrol*, Tourism and Hospitality Resear, 9(4): 305-313.

Burkart, A. J., Medlik, S., (1981): *Tourism, Past, Present, Future, Heinemann and Butterworth,* London,

Crouch, G.I. (1994): *Demand Elasticities for Short-Haul versus Long-Haul Tourism*, Journal of Travel Research, 33, pp. 2-7.

Culiuc, A. (2014): *Determinants of International Tourism, International Monetary Fund,* Working Paper, WP 14-82.

Čavlek, N., Bartoluci, M., Prebežac, D., Kesar, O. (2011): *Turizam – ekonomske osnove i organizacijski sustav*, Školska knjiga, Zagreb.

Dritsakis, N. (2004): Tourism as a Long-run Economic Growth Factor: An Empirical Investigation for Greece Using Causality Analysis, Tourism Economics, 10, pp. 305-316.

Dritsakis, N. (2012) *Tourism development and economic growth in seven Mediterranean countries: A panel data approach,* Tourism Economics, 18 (4). pp. 801-816.

Eugenio-Martín, J.L., Martín Morales, N., Scarpa, R. (2004): *Tourism and Economic Growthin Latin American Countries: A Panel Data Approach,* Nota di Lavoro, Fondazione Eni EnricoMattei, No. 26.2004.

Fourie, J., Santana–Gallego, M. (2013): *The Determinants of African Tourism,* Taylor & Francis Journals, vol. 30(3): pages 347-366.

Garín-Muňoz, T. (2006): *Inbound International Tourism to Canary Islands: A Dynamic Panel Dana Model,* Tourism Management 27, pp. 281-291.

Lickorish, L. J., Jenkins C.L., (2006): *„Uvod u turizam“,* nakladnik Ekokon Split .

Marković Z., Marković, S.(1987): *Osnove turizma,* , Zagreb: Školska knjiga .

Mervar, A., Payne, J.E. (2007): Analysis of Foreign Tourism Demand for Croatian Destinations: Long-Run Elasticity Estimates, Tourism Economics, 13(3).

Mordecki, G. (2014): *Determinants of argentinean tourism Demand in Uruguay,* Uruguay: Instituto de Economua.

Naude, W., Sayman, A., (2005): *Determinants of tourist arrivals in Africa: a panel data regression analysis,* Tourism Economics, 11 (3), pp. 365-391.

Petrić, L. (2012.): *Osnove Turizma,* Split: Ekonomski fakultet u Splitu

Petrić, L. (2014): *Upravljanje razvojem turizma,* Split: Ekonomski fakultet Split.

Proença, S.A., Soukiazis E. (2005): *Demand for Tourism in Portugal: A Panel Data Approach,Coimbra,* Portugal: Centro de Estudos da Uniao Européia: Discussion Paper No. 29.

Rozga, A.(2009): *Statistika za ekonomiste,* Split: Ekonomski fakultet Split

Serra, J., Correia, A., Rodrigues, P.M.M. (2014): A *comparative analysis of tourism destination demand in Portugal,* Journal of Destination Marketing & Management, 2, 221-227.

Song, H., Li, G,. Witt, S.F., Fei, B. (2010): *Tourism demand modelling and forecasting:how should demand be measured?* Tourism Economics, 16 (1) (2010), pp. 63–81.

Spurr, R. (2006): *Tourism Satellite Accounts, u Dwyer, L. i Forsyth, P. (eds.),* International Handbook on the Economics of Tourism, Cheltenham: Edwar Elgar Publishing, pp. 283-300.

Stučka, T. (2000): *OLS model fizičkih pokazatelja inozemnoga turističkog prometa na hrvatskom tržištu*, HNB Istraživanja, I-7.

Šimundić, B. (2015): *Makroekonomske determinante emitivnog turizma i njihov utjecaj na gospodarstva receptivnih zemalja,* doktorska disertacija. Split: Ekonomski fakultet Split.

Škrabić Perić, B. (2014): *Analiza panel podataka,* nastavni materijali. Split: Ekonomski fakultet Split.

Škrinjarić, T. (2011): Istraživanje inozemne turističke potražnje u Hrvatskoj primjenom analize panel podataka, Acta Turistica, Vol 23 (2).

Škuflić, L., Štoković, I. (2011): Demand Function for Croatian Tourist Product: A Panel Data Approach, Modern Economy, 2, pp. 49-53.

Web izvori:

EUROSTAT (2015): dostupno na http://ec.europa.eu/eurostat/data/database { pristupljeno 10.09.2015.}.

World Bank (2015) dostupno na http://data.worldbank.org/ **{**pristupljeno 10.09.2015.}.

OECD (2015) dostupno na http://www.oecd.org/economy/economicstudies.htm {pristupljeno 11.09.2015.}.

Državni zavod za statistiku (2014) dostupno na http://statistika.hzz.hr/Statistika.aspx?tipIzvjestaja=3 {pristupljeno 15.09.2015.}.

Hrvatski zavod za zapošljavanje (2016) dostupno na http://trzisterada.hzz.hr/hr/Counties/Employment Activity Gender/8?timeid=201100 {pristupljeno 01.06.2016.}.

Hrvatski zavod za zapošljavanje (2016) dostupno na http://trzisterada.hzz.hr/hr/Counties/Employment Activity Gender/8?timeid=201100 {pristupljeno 01.06.2016.}.

Ministarstvo turizma Republike Hrvatske (2015) dostupno na http://www.mint.hr/default.aspx?id=336 {pristupljeno 11.09.2015.}.

Istarska županija (2016) dostupno na http://www.istra-istria.hr/index.php?id=1409 {pristupljeno 06.08.2016. }.

Splitsko-dalmatinska županija (2016) dostupno na http://www.dalmacija.hr/portals/0/docs/UOturizam/GLAVNI%20PLAN%20TURIZMA.pdf pristupljeno 06.08.2016.}.

Dubrovačko-neretvanska županija (2016) dostupno na http://edubrovnik.org/02_SRTDNZ_IZVJESTAJ_SITUACIJE_TRZISTE_partnersko_vijece.pdf { pristupljeno 17.07.2016.}.

Hrvatska turistička zajednica (2016) http://croatia.eu/article.php?id=34&lang=1 {pristupljeno 17.07.2016.}.

Portal Croatialink.com (2016) dostupno na http://croatialink.com/wiki/Turizam:_definicija,_nastanak,_razvoj_i_podjela {pristupljeno 17.07.2016.}.

Zavod za prostorno uređenje Dubrovačko-neretvanske županije (2011) dostupno na

http://edubrovnik.org/02_SRTDNZ_IZVJESTAJ_SITUACIJE_TRZISTE_partnersko_vijece.pdf: Strategija razvoja turizma Dubrovačko-neretvanske županije {pristupljeno 17.07.2016.}.

Institut za turizam (2016) dostupno na http://www.iztzg.hr/UserFiles/Pdf/Tomas/Tomas-Ljeto-2011-knjiga.pdf {pristupljeno 06.08.2016.}.

Leksikografski zavod Miroslav Krleža (2016) dostupno na http://www.enciklopedija.hr/natuknica.aspx?id=62763 {pristupljeno 06.08.2016.}.

Wikipedija – Slobodna enciklopedija (2016) https://hr.wikipedia.org/wiki/Hrvatske_%C5%BEupanije {pristupljeno 06.08.2016.}.

PRILOZI

Popis tablica

- Tablica 1: Opis i prikaz varijabli
- Tablica 2: Deskriptivna statistika uzorka BDPPC, UNEMP, CPI, FCI, ER_{HR}
- Tablica 3: Deskriptivna statistika uzorka za Istarsku županiju
- Tablica 4: Deskriptivna statistika uzorka za Primorsko-goransku županiju
- Tablica 5: Deskriptivna statistika uzorka za Ličko-senjsku županiju
- Tablica 6: Deskriptivna statistika uzorka za Zadarsku županiju
- Tablica 7: Deskriptivna statistika uzorka za Šibensko-kninsku županiju
- Tablica 8: Deskriptivna statistika uzorka za Splitsko-dalmatinsku županiju
- Tablica 9: Deskriptivna statistika uzorka za Dubrovačko-neretvansku županiju
- Tablica 10: Korelacijska matrica između parova varijabli BDPPC UNEMP, CPI, FCI i ER_{HR} Tablica 11: Korelacijska matrica - Istarska županija
- Tablica 12: Korelacijska matrica - Primorsko-goranska županija
- Tablica 13: Korelacijska matrica - Ličko-senjska županija
- Tablica 14: Korelacijska matrica - Zadarska županija
- Tablica 15: Korelacijska matrica - Šibensko-kninska županija
- Tablica 16: Korelacijska matrica - Splitsko-dalmatinska županija
- Tablica 17: Korelacijska matrica - Dubrovačko-neretvanska županija
- Tablica 18: Rezultati panel analize - Istarska županija
- Tablica 19: Rezultati panel analize - Primorsko-goranska županija
- Tablica 20: Rezultati panel analize - Ličko-senjska županija
- Tablica 21: Rezultati panel analize - Zadarska županija
- Tablica 22: Rezultati panel analize - Šibensko-kninska županija
- Tablica 23: Rezultati panel analize - Splitsko-dalmatinska županija
- Tablica 24: Rezultati panel analize - Dubrovačko-neretvanska županija
- Tablica 25: Prikaz očekivanog i dobivenog predznaka promatranih varijabli

Popis grafova

- Graf 1: Prosječan broj noćenja turista prema promatranim županijama
- Graf 2: Odvojen grafički prikaz kretanja ukupnog broja noćenja turista prema promatranim županijama
- Graf 3: Grafički prikaz broja noćenja turista u Istarskoj županiji prema emitivnim tržištima iz kojih dolaze
- Graf 4: Grafički prikaz broja noćenja turista u Primorsko-goranskoj županiji prema emitivnim tržištima iz kojih dolaze
- Graf 5: Grafički prikaz broja noćenja turista u Ličko-senjskoj županiji prema emitivnim tržištima iz kojih dolaze
- Graf 6: Grafički prikaz broja noćenja turista u Zadarskoj županiji prema emitivnim tržištima iz kojih dolaze
- Graf 7: Grafički prikaz broja noćenja turista u Šibensko-kninskoj županiji prema emitivnim tržištima iz kojih dolaze
- Graf 8: Grafički prikaz broja noćenja turista u Splitsko-dalmatinskoj županiji prema emitivnim tržištima iz kojih dolaze
- Graf 9: Grafički prikaz broja noćenja turista u Dubrovačko-neretvanskoj županiji prema emitivnim tržištima iz kojih dolaze

Popis slika

- Slika 1: Geografski prikaz županija obuhvaćenih uzorkom istraživanja