

DETERMINANTE TURISTIČKE POTRAŽNJE U HRVATSKOJ

Jurić, Ena

Master's thesis / Diplomski rad

2021

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://um.nsk.hr/um:nbn:hr:124:398748>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

[REFST - Repository of Economics faculty in Split](#)



UNIVERSITY OF SPLIT



**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

DIPLOMSKI RAD

**DETERMINANTE TURISTIČKE POTRAŽNJE U
HRVATSKOJ**

**Mentorica:
prof. dr. sc. Pervan Maja**

**Studentica:
Jurić Ena (2191369)**

Split, kolovoz, 2021.

Sadržaj

1. UVOD	1
1.1. Problem istraživanja	1
1.2. Predmet istraživanja	2
1.3. Istraživačke hipoteze	3
1.4. Ciljevi istraživanja	5
1.5. Doprinos istraživanja	5
1.6. Metode istraživanja i izvori podataka	6
1.7. Struktura rada	7
2. TEORIJSKI ASPEKTI TURISTIČKE POTRAŽNJE	8
2.1. Potražnja i determinante promjena potražnje	8
2.2. Turistička potražnja	10
2.2.1. Individualna turistička potražnja	10
2.2.2. Tržišna turistička potražnja	11
2.3. Elastičnost turističke potražnje	12
2.4. Turizam u Republici Hrvatskoj	16
3. MODELIRANJE TURISTIČKE POTRAŽNJE	21
3.1. Temeljne karakteristike modeliranja turističke potražnje	21
3.2. Pregled odabranih ranijih istraživanja u svijetu	21
3.2.1. Garín-Muñoz (2006): Model međunarodne turističke potražnje na Kanarskim Otocima	22
3.2.2. Garín-Muñoz (2007): Model njemačke potražnje za španjolskim turizmom	22
3.2.3. Ibrahim (2011): Model međunarodne turističke potražnje za Egiptom	23
3.2.4. Rodríguez, Martínez-Roget i Pawlowska (2012): Model akademske turističke potražnje u španjolskog Galiciji	24
3.2.5. Cerdeira Bento (2014): Model akademske turističke potražnje u Europi	25
3.2.6. Li H., Song i Li L. (2017): Model turističke potražnje s analizom utjecaja klimatskih razlika između domicila i destinacije	26
3.3. Pregled odabranih ranijih istraživanja u Republici Hrvatskoj	26
3.3.1. Mervar i Payne (2007): Model stane turističke potražnje za hrvatskim destinacijama	27
3.3.2. Škrinjarić (2011): Model inozemne turističke potražnje u Hrvatskoj	27
3.3.3. Škuflić i Štoković (2011): Funkcija potražnje za hrvatskim turističkim proizvodom	28
3.3.4. Baldigara i Mamula (2015): Model njemačke potražnje za hrvatskim turizmom	28

3.3.5. Kožić (2018): Petogodišnja prognoza turističkog prometa u Hrvatskoj	29
3.4. Pregled odabranih ranijih istraživanja u području utjecaja terorizma na turističku potražnju	29
3.4.1. Saha i Yap (2014): Utjecaj terorizma i političkih nestabilnosti na turističku industriju	30
3.4.2. Samitas, Asteriou, Polyzos i Kenourgios (2018): Terorizam i turizam u Grčkoj	30
3.4.3. Fourie, Rosselló-Nadal i Santana-Gallego (2020): Utjecaj terorizma, kriminala i korupcije na turizam	30
3.4.4. Ulucak, Yücel i İlkey (2020): Terorizam i turski turizam	31
4. EMPIRIJSKO ISTRAŽIVANJE DETERMINANTI STRANE TURISTIČKE POTRAŽNJE U HRVATSKOJ	32
4.1. Opis varijabli	32
4.1.1. Zavisna varijabla	33
4.1.2. Eksplanatorne varijable	33
4.2. Opis primijenjene metodologije	38
4.3. Deskriptivna statistika	40
4.4. Korelacijska analiza	41
4.5. Rezultati modela	43
4.5.1. Arellano-Bond i Sargan test	43
4.5.2. Analiza i interpretacija modela turističke potražnje u Republici Hrvatskoj	44
5. ZAKLJUČAK	48
SAŽETAK	50
SUMMARY	51
LITERATURA	52
POPIS GRAFIKONA	56
POPIS TABLICA	57

1. UVOD

1.1. Problem istraživanja

Potrošnja turističkih proizvoda, za razliku od većine ostalih dobara i usluga, uključuje kupnju većeg broja roba i usluga te njihovo korištenje i trošenje u samoj destinaciji, a koja je ujedno i mjesto opskrbe (Fletcher *et al.*, 2018). Turistička potražnja temelj je na kojem počivaju sve poslovne odluke povezane s turizmom. Poduzeća poput zrakoplovnih kompanija, turoperatora, hotela, *cruising* tvrtki te brojnih pružatelja rekreacijskih usluga, ali i vlasnika trgovina, zainteresirana su za potražnju turista za njihovim proizvodima. Uspjeh mnogih poduzeća u velikoj mjeri ili u potpunosti ovisi o stanju turističke potražnje, dok su krajnji poslovni neuspjesi često posljedice neuspjeha u zadovoljavanju potražnje na tržištu (Song, Witt i Li, 2009). Usporedno s globalnim fenomenom rasta potražnje za turizmom tijekom posljednjih desetljeća, rastao je i znanstveno-istraživački interes za područje turizma. Od tek nekolicine akademskih časopisa koji su u početku objavljivali radove povezane s turističkom tematikom, s godinama je taj broj narastao na čak više od 70 časopisa. Jedno od najvažnijih područja istraživačkog rada u turizmu je modeliranje i prognoziranje turističke potražnje za koje su podjednako zainteresirani kako akademici tako i praktičari (Song i Li, 2008). Ekonomski utjecaj turističkih tokova na gospodarstva često je značajan i djeluje kao pokretač gospodarskog rasta kod malih zajednica, ali i u velikim zemljama. Kako bi se poboljšali učinci turizma, u interesu je privatnog sektora, ali i same vlasti te donositelja politika pronaći odgovarajuće analitičke modele (Brida i Scuderi, 2013).

Prateći globalne trendove, i turizam u Republici Hrvatskoj posljednjih godina bilježi značajan rast te zauzima mjesto od strateške važnosti u hrvatskom gospodarstvu. Podaci Državnog zavoda za statistiku pokazuju kako je Hrvatska u posljednja dva desetljeća ostvarivala stalni rast broja dolazaka i noćenja turista. Od 2000. godine broj dolazaka turista gotovo se utrostručio: od 7,1 milijun dolazaka u 2000. godini do 19,6 milijuna dolazaka 2019. godine. Prevladavaju strani turisti s udjelom od 89% u ukupnom broju dolazaka turista u 2019. godini te većina turista posjećuje Hrvatsku tijekom ljetne sezone i boravi u privatnom smještaju, hotelima i kampovima (Ministarstvo turizma Republike Hrvatske, 2020). Hrvatsko gospodarstvo jako ovisi o turizmu. O tome svjedoče podaci kako je 2019. godine turizam ostvario doprinos hrvatskom BDP-u u iznosu od čak 25% ukupnog gospodarstva, a u ukupnoj zaposlenosti turizam je imao udio od 25,1% (WTTC, 2020). Navedeni čimbenici ukazuju na to

da nema sumnje da je upravljanje turističkom potražnjom jedan od glavnih izazova suvremenog turizma, a posebno u državama čija gospodarstva snažno ovise o turizmu poput Hrvatske.

1.2. Predmet istraživanja

Općenito, čimbenici koji utječu na turističku potražnju mogu se podijeliti na motivatore i odrednice. Dok se motivacija bavi psihološkim čimbenicima i pitanjima zašto ljudi uopće putuju i koje potrebe pokušavaju zadovoljiti, odrednice predstavljaju faktore koji utječu na samu potražnju. Faktori koji utječu na turističku potražnju mogu biti ekonomski, sociološki, demografski, politički, zemljopisni, i sl. (Fletcher *et al.*, 2018). Turistička potražnja problem je brojnih istraživanja koja nastoje identificirati upravo njezine ključne odrednice i njihov utjecaj, a sve u cilju boljeg razumijevanja i upravljanja turizmom kao gospodarskim pokretačem. Međunarodna turistička potražnja najčešće se mjeri u smislu broja turističkih dolazaka iz emitivne zemlje u receptivnu državu, u smislu turističke potrošnje od strane posjetitelja u destinaciji ili pak u smislu broja noćenja turista iz zemlje podrijetla u odredištu. Među eksplanatornim varijablama najčešće se pojavljuju stanovništvo i prihodi emitivne zemlje, cijene unutar destinacije, cijene supstituta, ukusi, marketing, očekivanja i postojanost navika te razni kvalitativni učinci koji se u modelima pojavljuju u obliku dummy varijabli (Song, Witt i Li, 2009). Posljednjih su godina provedena brojna istraživanja u području modeliranja i prognožiranja turističke potražnje. Međutim, modeli turističke potražnje uvelike se međusobno razlikuju u smislu izabranih zavisnih i nezavisnih varijabli, promatranih perioda i podataka, empirijskih metodologija kao i parova emitivnih i receptivnih zemalja (Dogru, Sirakaya-Turk i Crouch, 2017). Sve više autora, osim tradicionalnih varijabli potražnje, uvodi i specifične regresore kao odrednice turističke potražnje kako bi modele prilagodili ciljevima svojih istraživanja. Neke studije usredotočene su na posebne oblike turizma, primjerice akademski turizam, pa se kod njih kao odrednice turističke potražnje pojavljuju varijable usko vezane uz taj oblik turizma (Cerdeira Bento, 2014; Rodríguez, Martínez-Roget i Pawlowska, 2012). S druge strane, mnogobrojna istraživanja naglasak stavljaju na različite konkretne problematike (klimatske, ekološke, društvene, političke, terorizam, korupcija, itd.) i njihov utjecaj na turističku potražnju. Pojedini su autori tako razmatrali utjecaj klimatskih razlika između emitivne zemlje i destinacije na turističku potražnju (Li H., Song i Li L., 2017), ali i utjecaj terorizma na turističku potražnju (Ulucak, Yücel i İlkay, 2020; Samitas, Asteriou, Polyzos i Kenourgios, 2018; Saha i Yap, 2014).

S obzirom na značajnu ulogu turizma u hrvatskom gospodarstvu, ovim se radom žele istražiti temeljne odrednice (njihov smjer i intenzitet djelovanja) turističke potražnje u Republici Hrvatskoj. Sukladno proučenoj stručnoj i znanstvenoj literaturi te karakteristikama hrvatskog turizma i konkurentskog okruženja, predloženi model bi kao determinante turističke potražnje u Hrvatskoj izdvojio: vlastitu cijenu kao osnovnu funkciju potražnje, dohodak posjetitelja, cijene konkurentskih destinacija, prisutnost terorističkih aktivnosti na područjima konkurentskih zemalja te investicije u turizmu i ugostiteljstvu u Republici Hrvatskoj. Budući da tržištem dominiraju strani turisti, model bi se fokusirao isključivo na inozemnu turističku potražnju u Hrvatskoj.

1.3. Istraživačke hipoteze

Imajući u vidu ranije izloženi problem i predmet istraživanja, formirane su sljedeće hipoteze:

H1: Porast cijena u Hrvatskoj ima negativan utjecaj na turističku potražnju.

Sukladno mikroekonomskoj teoriji i zakonu potražnje, pri nižim cijenama nekog dobra, a uz ostale neizmijenjene uvjete, veća je njegova potraživana količina, *vice versa* (Perloff, 2020; Pavić, 2015). U empirijskom smislu, brojni su autori dokazali negativan utjecaj rasta cijena u destinacijama na turističku potražnju (Li H., Song i Li L., 2017; Cerdeira Bento, 2014; Ibrahim, 2011; Škuflić i Štoković, 2011; Garín-Muñoz, 2007; Garín-Muñoz, 2006). Za pretpostaviti je stoga da će porast cijena u Hrvatskoj rezultirati padom potražnje za turističkim uslugama u Hrvatskoj, *ceteris paribus*.

H2: Porast dohotka posjetitelja utječe na porast potražnje za hrvatskim turističkim proizvodom.

Polazeći od mikroekonomske teorije koja definira normalna dobra kao ona dobra kod kojih količina potražnje raste zajedno s porastom dohotka kupaca (Pavić, 2015) te imajući na umu rezultate empirijskih istraživanja koja su pokazala postojanje pozitivne veze između dohotka turista u njihovim domicilnim državama i turističke potražnje (Li H., Song i Li L., 2017; Ibrahim, 2011; Surugiu C., Leitão i Surugiu M. R., 2011; Škuflić i Štoković, 2011; Garín-Muñoz, 2007; Garín-Muñoz, 2006), pretpostavka je da se hrvatski turistički proizvod može

svrstati u kategoriju normalnih proizvoda te je za očekivati da će turisti uslijed povećanja vlastitog dohotka ostvariti veću potražnju za hrvatskim turističkim proizvodom, *ceteris paribus*.

H3: Porast cijena u konkurentskim destinacijama rezultira rastom potražnje za Hrvatskom kao turističkom destinacijom.

Mikroekonomska teorija definira kako u slučaju dobara koja su supstituti, rast cijene jednog supstituta povećava potražnju za drugim supstitutom, uz ostale neizmijenjene varijable (Perloff, 2020; Pavić, 2015). Empirijska istraživanja su pokazala da navedeno vrijedi i kod turističkih destinacija koje se smatraju konkurentima, odnosno supstitutima (Ibrahim, 2011; Škrinjarić, 2011; Patsouratis, Frangouli i Anastasopoulos, 2005). Budući da konkurentske destinacije predstavljaju svojevrsni supstitut Hrvatskoj kao turističkoj destinaciji, pretpostavlja se da će rast cijena u konkurentskim odredištima potaknuti turiste da se preorijentiraju na Hrvatsku kao turističku destinaciju, *ceteris paribus*.

H4: Prisutnost terorističkih aktivnosti na područjima konkurentskih destinacija pozitivno se odražava na turističku potražnju u Hrvatskoj.

Sigurnost predstavlja jedan od prioriteta turista pri donošenju odluke o putovanju. U prilog tome govore i rezultati empirijskih istraživanja koja su pokazala da prisutnost terorističkih aktivnosti u destinacijama ima negativne posljedice na turističku potražnju (Ulucak, Yücel i İlkey, 2020; Samitas, Asteriou, Polyzos i Kenourgios, 2018; Saha i Yap, 2014; Araña i León, 2008). Ako se ovome pridodaju i rezultati Tomas istraživanja u 2019. koji ističu osobnu sigurnost u Hrvatskoj kao jedan od najbolje ocijenjenih elemenata turističke ponude Hrvatske, pretpostavka je da će se u slučaju porasta terorističkih aktivnosti u konkurentskim destinacijama, određen dio turista zbog vlastite sigurnosti radije odlučiti na Hrvatsku kao svoju destinaciju, *ceteris paribus*.

H5: Investicije u turizam i ugostiteljstvo u Hrvatskoj imaju pozitivan utjecaj na turističku potražnju.

Neka empirijska istraživanja su pri modeliranju turističke potražnje razmatrala i elemente ponude koji mogu utjecati na samu turističku potražnju, poput ulaganja u turističku

infrastrukturu i ugostiteljske kapacitete te su njihovi rezultati pokazali da investicije u turizmu i ugostiteljstvu imaju pozitivne učinke na turizam (Nawaz i Hassan, 2016; Škrinjarić, 2011). Nastavno na to, za očekivati je da će povećane investicije u turizam i ugostiteljstvo u Hrvatskoj, potaknuti turiste da izaberu Hrvatsku kao svoje odredište putovanja, utječući na taj način direktno na rast turističke potražnje u RH, *ceteris paribus*.

1.4. Ciljevi istraživanja

Cilj ovog istraživanja je argumentirati i empirijski analizirati determinante strane potražnje za hrvatskim turističkim proizvodom te objasniti efekte pojedinih determinanti na turističku potražnju.

Konkretno, osim utjecaja dohotka posjetitelja, relativnih cijena i cijena konkurenata, cilj rada je i analizirati mogu li se (i na koji način) terorističke aktivnosti na područjima zemalja iz konkurentskog okruženja dovesti u vezu s turističkom potražnjom u Republici Hrvatskoj, ali i imaju li investicije u turizmu i ugostiteljstvu u Hrvatskoj utjecaj na količinu turističke potražnje.

U konačnici, cilj je formulacijom inovativnog modela doći do novih zaključaka o značajnim odrednicama turističke potražnje u Hrvatskoj u recentnom periodu, a koji će biti korisni kako turističkim akterima u praksi, tako i budućim istraživačima u ovom području.

1.5. Doprinos istraživanja

Potražnja za hrvatskim turističkim proizvodom u ovom se istraživanju procjenjuje za novi, recentni vremenski period od 2005. do 2019. godine. Također, ovo istraživanje osim tradicionalnih determinanti potražnje poput cijena, dohotka i utjecaja supstituta, u obzir uzima i efekte terorističkih aktivnosti na područjima konkurentskih država na turističku potražnju u Hrvatskoj kao i utjecaj investicija u turizmu i ugostiteljstvu u Hrvatskoj. Prema poznatim saznanjima, do sada nije provedeno istovrsno istraživanje na području Republike Hrvatske koje obuhvaća isti navedeni vremenski period, metodologiju i utjecaj odabrane kombinacije varijabli.

Istraživanje pridonosi boljem razumijevanju strane turističke potražnje u Hrvatskoj i utjecaja njezinih značajnih determinanti što može poslužiti turističkim subjektima u praksi pri

donošenju poslovnih odluka i politika kako na mikro, tako i na makro razini. Istraživanje također može poslužiti kao svojevrsna podloga budućim analitičarima turističke potražnje u Hrvatskoj pri formuliranju novih modela.

1.6. Metode istraživanja i izvori podataka

Znanstvena metoda općenito se odnosi na skup različitih postupaka kojima se znanost koristi u znanstvenim i istraživačkim radovima u svrhu istraživanja i prezentacije rezultata znanstvenog istraživanja te sa tako naziva svaki način znanstvenog istraživanja koje osigurava sigurno, sređeno, sustavno i točno znanje.

Znanstvene metode korištene u svrhu izrade ovog rada su:

- metoda analize kojom se složeni pojmovi, sudovi i zaključci raščlanjuju na njihove jednostavnije sastavne dijelove i elemente;
- metoda sinteze jednostavnih sudova u složenije;
- metoda dedukcije kojom se iz općih stavova izvode posebni i pojedinačni zaključci;
- metoda indukcije kojom se iz zapažanja pojedinačnih slučajeva dolazi do općih zaključaka;
- komparativna metoda uspoređivanja istih ili sličnih pojava ili činjenica te utvrđivanja njihovih sličnosti (Zelenika, 1998).

U svrhu izrade diplomskog rada korištena je znanstvena i stručna literature iz područja modeliranja i prognoziranja turističke potražnje.

U empirijskom dijelu rada formuliran je dinamički model turističke potražnje koji je ocijenjen primjenom GMM (generalizirana metoda momenata) procjenitelja. U tu su svrhu prikupljeni sekundarni podaci dostupni na internetskim stranicama Svjetske banke, Državnog zavoda za statistiku, OECD-a te organizacije Vision of Humanity.

1.7. Struktura rada

Diplomski rad sastoji se od pet poglavlja.

Uvodno poglavlje definira predmet i problem istraživanja, istraživačke hipoteze, ciljeve i doprinos te metode rada kao i samu strukturu rada.

U drugom poglavlju naglasak je na općim zakonitostima teorije potražnje s fokusom na specifičnosti turističke potražnje.

Treće poglavlje donosi analizu prethodno provedenih znanstvenih istraživanja iz područja modeliranja turističke potražnje.

Četvrto poglavlje sadrži objašnjenje metodologije, rezultate empirijskog istraživanja i njihovu interpretaciju.

Posljednje poglavlje sadrži zaključna razmatranja na osnovu provedenog istraživanja.

2. TEORIJSKI ASPEKTI TURISTIČKE POTRAŽNJE

2.1. Potražnja i determinante promjena potražnje

Za sam početak analize turističke potražnje, potrebno je prvo pojmovno odrediti potražnju općenito. Pod pojmom potražnje podrazumijeva se količina nekog dobra koju je kupac spreman kupiti na nekom tržištu tijekom određenog vremena po bilo kojoj mogućoj cijeni tog dobra, a dok se, s druge strane, pod pojmom količine potražnje podrazumijeva količina nekog dobra koju je kupac spreman kupiti na nekom tržištu tijekom nekog vremena, ali pri precizno određenoj cijeni toga dobra. Razlikovanje pojmova potražnje i količine potražnje ima svoju vrijednost u samoj praksi te se manifestira u činjenici da omogućuje analizu potražnje u odnosu na mogućnost da se na tržištu potražuje veća ili manja količina u odnosu na cijenu promatranog proizvoda ili usluge, odnosno druge varijable koje mogu imati utjecaj. Prema zakonu potražnje može se očekivati da će potražnja za nekim dobrom porasti ako se smanji njegova cijena i obratno, uz nepromijenjene ostale uvjete (Pavić, 2015).

Važno je i razlikovati pojmove individualna i tržišna potražnja. Dok se individualna potražnja odnosi na količinu nekog dobra koju je pojedinac voljan i sposoban kupiti pri njegovoj svakoj mogućoj cijeni, tržišna potražnja je pak količina dobra koju su svi pojedinci koji čine neko tržište voljni i sposobni kupiti pri svakoj mogućoj cijeni toga dobra. Sukladno tome, tržišna potražnja ustvari je zbroj svih individualnih potražnji na pojedinom tržištu (Pavić, 2015).

Potražnja je sklona promjenama, a te se promjene mogu svrstati u dva tipa. Prvi tip je promjena u količini potražnje koja se pojavljuje kao odgovor na promjenu cijene pojedinog dobra. Drugi tip je promjena u potražnji koja je uzrokovana promjenom bilo koje druge utjecajne varijable osim cijene promatranog proizvoda ili usluge.

Utjecaj na promjene u potražnji mogu imati različite determinante čija vrsta i intenzitet efekta ovise o svakom pojedinom dobru. Generalno gledano, osim cijene kao determinante promjena u količini potražnje, determinante promjene u potražnji su:

- dohodak potrošača,
- cijene povezanih dobara,
- ukusi i preferencije potrošača,
- broj stanovnika

- očekivanja potrošača.

Dohodak kao determinanta potražnje često se povezuje s razlikovanjem normalnih od inferiornih dobara. Naime, normalna dobra su ona dobra kod kojih količina potražnje raste s rastom dohotka potrošača. Suprotno tomu, kod inferiornih dobara tipično je da potražnja za njima opada s porastom dohotka potrošača (na primjer jeftinije i manje kvalitetne prehrambene namirnice u odnosu na skuplje i visoko kvalitetne).

Cijene povezanih dobara kao determinanta potražnje mogu se promatrati u kontekstu odnosa između promatranog dobra i povezanih dobara. S obzirom na taj odnos, razlikuju se dvije vrste dobara: supstituti i komplementi. Dok su supstituti dobra koja mogu biti međusobna zamjena jedno za drugo u potrošnji, komplementi se u potrošnji međusobno nadopunjavaju. Prema tome, porast cijene jednog supstituta dovodi do porasta potražnje za drugim supstitutom, dok porast cijene jednog komplementa rezultira padom potražnje za tim dobrom. Kao poznat primjer supstituta mogu se navesti maslac i margarin, a kao primjer komplementarnih dobara često se navode automobil i gorivo.

Globalizacijski procesi istaknuli su ulogu ukusa i preferencija potrošača pri determiniranju potražnje za određenim dobrima. Dobra koja su u skladu s dominantnim ukusom potrošača suočavaju se s povećanom potražnjom i obratno.

Porast broja stanovnika kao determinante potražnje kod većine dobara rezultira porastom potražnje, analogno kao što će potražnja za mnogim dobrima ostvariti pad uoči smanjenja broja stanovnika.

Očekivanja potrošača u ulozi determinante potražnje odnose se na očekivanja u vezi visine dohotka i cijena u budućnosti. Neki će kupac biti spremniji ostvariti višu potrošnju u sadašnjosti ako u budućnosti očekuje porast svog dohotka nego što bi to bio u situaciji gdje očekuje pad dohotka u budućnosti (sklonost štednji). Analogno je i kod cijena – kupci potražuju veću količinu nekog dobra ako očekuju porast njegove cijene u budućem periodu (Pavić, 2015).

2.2. Turistička potražnja

2.2.1. Individualna turistička potražnja

Poznavanje ponašanja pojedinaca te njihovog utjecaja na cjelovito turističko tržište, omogućuje predviđanje budućih trendova u turizmu te prilagođavanje turističkih proizvoda (turističke ponude) postojećoj potražnji kako bi ju se na što kvalitetniji način moglo zadovoljiti. Jednako tako, poznavanje prirode turističke potražnje važno je i za vladine politike pojedinih zemalja, primjerice u pogledu oporezivanja ili različitih utjecanja na posjetitelje i njihovo ponašanje. Jedna od specifičnosti turističke potražnje je u tome što, za razliku od većine ostalih dobara i usluga, potrošnja turističkog proizvoda od strane pojedinca podrazumijeva kupnju roba i usluga koji se konzumiraju u samoj destinaciji, odnosno na samom mjestu opskrbe tj. ponude (Fletcher *et al.*, 2018).

Ekonomska analiza turističke potražnje usredotočena je na čimbenike koji utječu na spremnost kao i stvarnu mogućnost pojedinca da plati turističke proizvode i usluge. Obično se individualna turistička potražnja prikazuje kao:

$$(1) q^i = f^i(P_t, P_1, \dots, P_m, y^i, z^i),$$


gdje je q^i = kvantitativna mjera turističke potražnje pojedinca (količina) te je ona funkcijski povezana sa sljedećim faktorima:

- P_t = cijena turističkog dobra;
- $P_1, \dots, P_m$ = cijene alternativnih dobara i usluga na koje turist može trošiti svoj budžet;
- y^i = prihod pojedinca;
- z^i = sociološki i demografski čimbenici karakteristični za pojedinca koji se tokom vremena polako mijenjaju (Fletcher *et al.*, 2018).

Ukoliko se sve varijable koje nisu predmet analize iz jednadžbe (1) drže konstantnima, točnije primjenom *ceteris paribus* pretpostavke, moguće je odrediti odnos između količine turističke potražnje i same cijene turističkih proizvoda i usluga. Na taj način formula (1) postaje:

$$(2) q^i = f^i(P_t, ceteris paribus) = f^i(P_t)$$

Ovaj odnos grafički je prikazan na Grafikonu 1 gdje krivulja potražnje D prikazuje količine turističkog dobra koje je pojedinac spreman kupiti pri različitim cijenama u danom vremenskom periodu (Fletcher *et al.*, 2018).



Grafikon 1. Individualna potražnja za turističkim dobrom

Izvor: Fletcher J., Fyall A., Gilbert D., Wanhill S. (2018): *Tourism principles and practice*, Harlow, Pearson, str. 31.

2.2.2. Tržišna turistička potražnja

Turistička potražnja može se definirati za pojedinu destinaciju kao količina turističkog proizvoda (kombinacija turističkih dobara i usluga u destinaciji) koju su turisti spremni kupiti unutar određenog vremenskog perioda pod danim uvjetima na tržištu. Vremenski period može biti mjesec, kvartal ili godina. Dani tržišni uvjeti koji imaju utjecaj na količinu turističke potražnje uključuju: turističke cijene u destinaciji (životni troškovi turista unutar destinacije i troškovi puta do same destinacije), dostupnost i cijene konkurentskih destinacija (supstituta), razinu dohotka potencijalnih posjetitelja, marketinške troškove promocije destinacije od strane nacionalnih turističkih organizacija, ukuse potrošača unutar emitivnih zemalja koji su podložni promjenama te ostale socijalne, kulturološke, geografske i političke čimbenike (Song, Witt i Li, 2009).

Tržišna potražnja u turizmu rezultat je skupa aktivnosti i odluka koje donose individualni posjetitelji (turisti) unutar generirajućih regija tj. unutar emitivnih zemalja. S obzirom da individualni turisti čine tržište, za pretpostaviti je da krivulje tržišne potražnje reagiraju na sličan način kao i individualne krivulje, stoga je čest pristup pri određivanju tržišne potražnje

horizontalno zbrajanje individualnih rasporeda potražnje. Uključe li se u razmatranje varijable različitih dohodaka posjetitelja te njihovi sociodemografski faktori, prilikom procjenjivanja tržišne potražnje bilo bi potrebno poznavati osobne okolnosti svakog pojedinog individualnog potrošača na turističkom tržištu kao i njihove dohotke. Međutim, već je intuitivno jasno da u praksi nije moguće doslovno prikupiti individualne podatke svih sudionika na tržištu, stoga je za procjenu tržišne turističke potražnje nužno koristiti aproksimacije kako bi se dobile približne vrijednosti traženih varijabli. (Fletcher *et al.*, 2018).

2.3. Elastičnost turističke potražnje

Mjere elastičnosti potražnje poput cjenovne, ukrštene i dohodovne elastičnosti potražnje određuju iznos postotne promjene količine potraživanog turističkog dobra kao rezultat 1%-tne promjene vrijednosti jedne od determinanti potražnje, dok se sve ostale determinante u funkciji potražnje drže konstantnima (Song i Witt, 2000).

2.3.1. Cjenovna elastičnost turističke potražnje

U kontekstu formule (2) moguće je izračunati cjenovnu elastičnost turističke potražnje kao omjer postotne promjene količine potraživanog dobra i postotne promjene cijene tog dobra:

$$(3) e^i = \frac{\% - tna \text{ promjena količine } (q^i)}{\% - tna \text{ promjena cijene } (P_t)}$$


S obzirom da se količina i cijena kreću u suprotnim smjerovima, vrijednost elastičnosti izračunata iz stvarnih podataka uvijek je negativna, ali konvencionalno ju je uzeti u obzir i u njezinoj apsolutnoj vrijednosti. Kritična vrijednost e^i iznosi 1.0, za dobra čija cjenovna elastičnost potražnje iznosi više od 1 kaže se da je njihova potražnja elastična. Internacionalna putovanja najčešće imaju vrijednost cjenovne elastičnosti potražnje između 1.2 i 1.5, a iz toga proizlazi da bi pad cijena od 10% rezultirao s 12-15%-tnim povećanjem količine potražnje u turizmu (Fletcher *et al.*, 2018).

2.3.2. Ukrštena elastičnost turističke potražnje

Vrlo slična se analiza može provesti i uzimajući u obzir alternativna dobra i usluge koja konkuriraju za turistov budžet, odnosno cijene dobara i usluga na koje turist također može potrošiti svoj dohodak. Ukrštena elastičnost potražnje je postotna promjena potraživane količine kao odgovor na određenu postotnu promjenu cijene drugog dobra (Perloff, 2020). Iz odnosa količine turističke potražnje q^i i cijena alternativnih dobara i usluga P_m moguće je definirati ukrštenu elastičnost:

$$(4) e_x^i = \frac{\% - tna \text{ promjena količine } (q^i)}{\% - tna \text{ promjena cijene alternativnog dobra } (P_m)}$$

Vrijednost ukrštene elastičnosti pokazuje odnos dvaju dobara – jesu li ta dobra supstituti ili komplementi. U slučaju kada je neki proizvod ili usluga supstitut nekom turističkom dobru, tada smanjenje njegove cijene uzrokuje pad potražnje za turističkim dobrom (q^i). Na Grafikonu 2 ovo je prikazano pomakom krivulje potražnje D ulijevo, odnosno q_1 pada na q_2 . Prema tome, vrijednost ukrštene elastičnosti u slučaju supstituta poprima pozitivnu vrijednost. Obratno, ako je neki proizvod ili usluga komplement nekom turističkom dobru, tada pad njegove cijene uvjetuje porast potražnje za turističkim dobrom (q^i), sa q_1 na q_3 na Grafikonu 2, uz pomak krivulje potražnje udesno. Tada ukrštena elastičnost poprima negativnu vrijednost. (Fletcher *et al.*, 2018).



Grafikon 2. Efekti supstituta i komplementa na potražnju za turističkim dobrom


Izvor: Fletcher J., Fyall A., Gilbert D., Wanhill S. (2018): *Tourism principles and practice*, Harlow, Pearson, str. 32.

2.3.3. Dohodovna elastičnost turističke potražnje

Osim analize cjenovne i ukrštene elastičnosti, turističku potražnju moguće je promatrati i u kontekstu dohodovne elastičnosti. U ovom slučaju potrebno je u odnos s turističkom potražnjom (q^i) staviti dohodak pojedinca (y^i). Moglo bi se reći da je upravo analiza dohodovne elastičnosti potražnje u turizmu i najznačajnija iz razloga što u praksi postoje vrlo velike varijacije između dohodaka različitih potencijalnih posjetitelja. Također, dohodak je i jedna od najznačajnijih odrednica turističkih trendova. Dohodovna elastičnost definira se kao:

$$(5) e_y^i = \frac{\% - tna \text{ promjena količine } (q^i)}{\% - tna \text{ promjena visine dohotka } (y^i)}$$

Kada je vrijednost dohodovne elastičnosti veća od 1, promatrano dobro je luksuzno dobro, a kada je vrijednost dohodovne elastičnosti pozitivna, ali manja od 1, takvo dobro naziva se nužno dobro. U slučaju negativne vrijednosti dohodovne elastičnosti, promatrano dobro je inferiorno s obzirom da porast dohotka uvjetuje pad potražnje za takvim dobrom. Na Grafikonu 3 Engelovim krivuljama su prikazani opisani odnosi dobara. Turistička putovanja su, u pravilu, luksuzna dobra (Fletcher *et al.*, 2018).




Grafikon 3. Učinci promjena visine dohotka (Engelove krivulje)

Izvor: Fletcher J., Fyall A., Gilbert D., Wanhill S. (2018): *Tourism principles and practice*, Harlow, Pearson, str. 33.

Prosječna vrijednost dohodovne elastičnosti inozemnih putovanja u najznačajnijim emitivnim zemljama iznosi od +1.5 do +2.0. Prema tome, potražnja za turističkim dobrima i uslugama reagira na promjenu jedinice dohotka na način da potražnja raste po višoj stopi od samog dohotka. Unatoč raznim recesijama od razvoja suvremenog turizma 1950-ih, brojnost turističkih putovanja kontinuirano raste. Istraživači ovog fenomena objašnjavaju to kao "efekt zapornog kotača" ili "postojanost navike". Naime, kada ljudi sudjeluju u turizmu, s vremenom oni to žele sve više te nisu skloni odreći se svog godišnjeg odmora zbog ekonomskih kriza. Iz tih se razloga često rade prilagodbe u smislu duljine putovanja, izbora destinacije i vrste smještaja i sl. Generalno gledano, recesije iz prošlosti nisu značajno utjecale na turističku industriju. Ipak, to naravno ne znači da su turistička putovanja nužna dobra, već to znači da kada potrošač jednom iskusi turističko putovanje, u budućnosti ga stavlja visoko na listu prioriteta luksuznih dobara (Fletcher *et al.*, 2018).

2.4. Turizam u Republici Hrvatskoj

Turizam je u Republici Hrvatskoj posljednjih godina zauzeo mjesto od strateške važnosti za hrvatsko gospodarstvo. O razvoju receptivnog turizma u Hrvatskoj jasno svjedoče podaci o kontinuiranom rastu broja ostvarenih turističkih dolazaka i noćenja tijekom godina. Kretanje ukupnog broja dolazaka i noćenja u razdoblju od 2000. do 2019. godine prikazano je na Grafikonu 4.




Grafikon 4. Dolasci i noćenja turista u RH 2000-2019. (u 000)

Prikaz autorice prema: Ministarstvo turizma Republike Hrvatske (2020): Turizam u brojkama 2019.

Podaci Državnog zavoda za statistiku bilježe kako se broj ostvarenih dolazaka i noćenja više nego udvostručio u 2019. godini u odnosu na 2000. Najzastupljeniji objekti u strukturi noćenja turista u 2019. godini bila su kućanstva (48,8%), hoteli (22,8%) te kampovi i kampirališta (21%).

Podaci DZS-a također ukazuju na uvjerljivu dominaciju stranih turista naspram domaćima s udjelom od 89% u ukupnim dolascima te 92% u ukupno ostvarenim noćenjima u 2019. godini. U strukturi stranog turističkog prometa, kao oni s najvišim udjelom ostvarenih dolazaka i noćenja u RH prvenstveno se ističu turisti iz Njemačke, Slovenije, Austrije, Italije, Poljske, Ujedinjene Kraljevine, Češke, Francuske, Sjedinjenih Američkih Država te Mađarske (Ministarstvo turizma Republike Hrvatske, 2020). Na Grafikonu 5 vidljivo je kako posjetitelji


iz Njemačke ostvaruju najveći broj noćenja i dana boravka u Republici Hrvatskoj naspram ostalim emitivnim državama.



Grafikon 5. Strani turisti - noćenje i prosječan broj dana boravka po zemljama

Izvor: Ministarstvo turizma Republike Hrvatske (2020): Turizam u brojkama 2019.

Što se tiče sociodemografskog profila turista prema njihovoj dobi i pripadnosti generacijskim skupinama, Tomas istraživanje 2019. pokazalo je kako prevladavaju turisti koji pripadaju takozvanoj Generaciji X (1961.-1980.) s ukupnim udjelom od 46,3% te posjetitelji Generacije Y (1981.-1995.) s udjelom od 35%. Promatrajući na Grafikonu 6 rezultate uzastopnih Tomas istraživanja od 1987. do 2019. godine, na području Jadranske Hrvatske uočava se dominacija turista srednje životne dobi (od 30 do 49 godina), a prosječna se dob povećala sa 41 na 43 godine. Navedena dobna skupina ostvaruje polagani rast svojeg udjela tijekom cijeloga razdoblja u kojem se istraživanje provodilo i kreće se od 47% do 56%. Zastupljenost dobni skupina do 29 godina varira, ali se uočava i blagi pad u recentnom periodu i to sa 21% u 2014. na udio od 16% u 2019. godini.



Grafikon 6. Dob turista: Trend 1987.-2019.

Izvor: Institut za turizam (2020): TOMAS Ljeto 2019 - Stavovi i potrošnja turista u Hrvatskoj

U razdoblju od 2000. do 2019. godine, u Hrvatskoj su značajno porasli i prihodi od turizma. Podaci Hrvatske narodne banke pokazuju da su u 2000. godini prihodi vezani za putovanja i turizam iznosili ukupno 3.011,8 milijuna EUR, da bi u 2019. narasli do čak 10.539,1 milijuna EUR. Turizam u Republici Hrvatskoj također generira velik broj radnih mjesta, a posebno tijekom ljetne sezone.


Prema Tomas istraživanju 2019. godine, za posjet Jadranskoj Hrvatskoj, turisti su najviše bili motivirani morem (81%) i prirodom (56%). Dio posjetitelja kao motiv dolaska navodi i: *city break* (24%), *touring* (21%), sport i rekreaciju (15%), kulturu i umjetnost (13%), gastronomiju (7%), zabavu i festivale (6%) te mnoge druge motive. U Tablici 1 prikazani su najučestaliji motivi dolaska turista u Jadransku i Kontinentalnu Hrvatsku.

Tablica 1. Motivi dolaska turista

Rang	Jadranska Hrvatska	%	Rang	Kontinentalna Hrvatska	%
1.	More	81,5	1.	Priroda	31,7
2.	Priroda	56,2	2.	Touring, sightseeing	26,0
3.	Gradovi (city break)	23,8	3.	Gradovi (city break)	25,9
4.	Touring	21,0	4.	Sport i rekreacija	24,1
5.	Sport i rekreacija	14,9	5.	Posao	21,7
6.	Kultura i umjetnost	12,7	6.	Kultura i umjetnost	15,7
7.	Gastronomija	6,6	7.	Planinarenje	9,8
8.	Zabava i festivali	5,5	8.	Sela	9,6
9.	Sela	4,5	9.	Gastronomija	6,6
10.	Manifestacije i događanja	4,2	10.	Manifestacije i događanja	6,3

Izvor: Institut za turizam (2020): TOMAS Ljeto 2019 - Stavovi i potrošnja turista u Hrvatskoj

Internet je primarni izvor informacija o destinaciji, a slijede ga preporuke rodbine i prijatelja te iskustva prijašnjih boravaka. Navedeno prikazuje Grafikon 7. Također, lojalnost posjetitelja relativno je visoka - više od 50% stranih turista već je posjetilo Hrvatsku tri ili više puta.

**Grafikon 7. Izvori informacija o Hrvatskoj kao destinaciji**

Prikaz autorice prema: Institut za turizam (2020): TOMAS Ljeto 2019 - Stavovi i potrošnja turista u Hrvatskoj

Prema istom istraživanju najbolje ocijenjeni elementi turističke ponude su prirodne ljepote i krajolik, ljepota mjesta, osobna sigurnost, atmosfera i ugođaj te gostoljubivost lokalnog stanovništva, dok su najlošije ocijenjeni elementi prometna infrastruktura, ponuda noćnog života i zabave te prilagođenost destinacije osobama s posebnim potrebama.

World Economic Forum u svojem je izvještaju The Travel & Tourism Competitiveness Report 2019 rangirao Hrvatsku na 27. mjesto od ukupno 140 država prema indeksu konkurentnosti koji mjeri skup čimbenika i politika koje omogućuju održivi razvoj sektora turizma u državi. T&T indeks konkurentnosti ocjenjuje države u četiri područja: poticajno okruženje, politike u turističkoj industriji, infrastruktura te prirodni i kulturni resursi. Promatrajući navedeni indeks konkurentnosti, Hrvatska je 2019. ostvarila poboljšanje svog ranga u odnosu na 2017. godinu kada je zauzimala 32. mjesto od ukupno 136. Time je Hrvatska ostavila iza sebe konkurente među kojima su Malta (35. u 2019.), Turska (43. u 2019.), Cipar (44. u 2019.) i Bugarska (45. u 2019.).

3. MODELIRANJE TURISTIČKE POTRAŽNJE

3.1. Temeljne karakteristike modeliranja turističke potražnje

Na razini pojedinih država, potražnja za međunarodnim turističkim putovanjima razmatra se gotovo na jednak način kao i potražnja za uvozom i izvozom različitih roba, s tim da se uvoz odnosi na turističku potrošnju domaćeg stanovništva u inozemstvu, a dok se, obratno, izvoz odnosi na potražnju za turističkim proizvodima i uslugama promatrane zemlje ostvarenu od strane stranih turista iz inozemstva (Fletcher *et al.*, 2018). U praksi se pri modeliranju turističke potražnje često koriste dva funkcijska oblika modela, a to su linearni i eksponencijalni. Eksponencijalni oblik može se transformirati u linearni pomoću logaritamske transformacije što olakšava procjenu koeficijenata koji u tom obliku ujedno predstavljaju i same koeficijente elastičnosti. Zbog toga se, ali i zbog relativno dobrih empirijskih performansi, eksponencijalni oblik često koristi pri modeliranju turističke potražnje (Song, Witt i Li, 2009). Konstrukcija i procjenjivanje modela turističke potražnje u velikoj se mjeri oslanjaju na sekundarne izvore podataka. Metode modeliranja i prognoziranja turističke potražnje mogu se podijeliti u dvije opće kategorije, a to su kvalitativne i kvantitativne metode. Kvantitativnim metodama dominiraju dvije potkategorije: modeli vremenskih serija i ekonometrijski modeli, ali pojavljuju se i novi pristupi (Song i Li, 2008). Dok su ranija istraživanja turističke potražnje bila usredotočena primarno na problematiku samog mjerenja, konceptualizaciju varijabli i njihove prikladne aproksimacije, novija istraživanja se nastoje više fokusirati na tehnike modeliranja i prognoziranja te odabir pravih razina podataka. Unatoč velikoj zastupljenosti ove tematike među istraživačima, još uvijek ne postoji suglasje oko pitanja koji čimbenici u najvećoj mjeri determiniraju turističku potražnju niti koje su metode modeliranja i prognoziranja najučinkovitije (Dogru, Sirakaya-Turk i Crouch, 2017).

3.2. Pregled odabranih ranijih istraživanja u svijetu

Sukladno ranije navedenom, modeliranje i prognoziranje turističke potražnje već je dugi niz godina učestala tema brojnih istraživanja. Brojni su autori ponudili različite modele turističke potražnje koji se odnose na određene emitivne i receptivne države, vremenske periode, posebne oblike turizma kao i specifične čimbenike koji mogu utjecati na potražnju za turizmom. Većina modela istražuje ulaznu turističku potražnju (*inbound tourism*) u tradicionalno receptivnim državama i destinacijama (Garín-Muñoz, 2006; Garín-Muñoz, 2007; Škrinjarić, 2011), ali

postoje i modeli koji analiziraju i izlaznu turističku potražnju (*outbound tourism*) u emitivnim područjima (Seetaram, Forsyth i Dwyer, 2016).

S obzirom da je cilj ovog diplomskog rada odrediti determinante turističke potražnje u Republici Hrvatskoj koja je primarno receptivna destinacija, u nastavku će biti naglasak na modelima koji se bave tematikom modeliranja ulazne turističke potražnje.

3.2.1. Garín-Muñoz (2006): Model međunarodne turističke potražnje na Kanarskim Otocima

Garín-Muñoz (2006) metodom generaliziranih momenata (GMM-DIFF) nad panel podacima uvodi dinamički model međunarodne turističke potražnje na Kanarskim Otocima za 15 najvažnijih emitivnih tržišta tijekom razdoblja od 1992 do 2002.

Kao mjeru turističke potražnje, za zavisnu varijablu koristi broj turističkih dolazaka. Eksplanatorne varijable u modelu su:

- zavisna varijabla s vremenskim pomakom koja predstavlja potražnju u prethodnoj godini;
- indeks relativne cijene (troškovi života turista u destinaciji u odnosu na troškove života u domicilu korigirano za tečaj);
- putni troškovi aproksimirani cijenom sirove nafte;
- BDP *per capita* emitivnih država kao determinanta dohotka;
- nekoliko *dummy* varijabli za kontrolu posebnih događaja tijekom promatranog perioda.

Rezultati su pokazali da se turizam na Kanarskim Otocima može svrstati među luksuzna dobra, a zavisna varijabla s vremenskim pomakom pokazala se značajnom te je objašnjena u kontekstu visoke lojalnosti posjetitelja destinaciji kao i važnosti takozvanog *word-of-mouth* efekta pri čemu se o destinaciji širi glas „od usta do usta“.

3.2.2. Garín-Muñoz (2007): Model njemačke potražnje za španjolskim turizmom

Garín-Muñoz (2007) koristeći ponovno panel podatke i metodu generaliziranih momenata (GMM-DIFF), formulira dinamički model njemačke potražnje za španjolskim turizmom u

periodu 1991-2003. Španjolska je pri ovoj analizi podijeljena na 17 destinacija koje odgovaraju španjolskim autonomnim zajednicama.

Zavisna varijabla (mjera turističke potražnje) u ovom modelu je broj noćenja u hotelima i srodnim smještajnim objektima u svakoj od 17 destinacija, odnosno autonomnih zajednica Španjolske.

Eksplanatorne varijable su:

- zavisna varijabla s vremenskim pomakom koja predstavlja prethodnu potražnju;
- njemački BDP *per capita* kao pokazatelj dohotka turista;
- indeks relativnih cijena;
- putni troškovi iskazani cijenom sirove nafte;
- *dummy* varijable zbog posebnih faktora tijekom promatranog razdoblja.

Empirijski rezultati dobiveni nakon modeliranja njemačke potražnje za turizmom u Španjolskoj prilično su slični rezultatima prethodno opisanog istraživanja na Kanarskim Otocima, potvrđujući još jednom da turistička potražnja u proteklom razdoblju ima značajan utjecaj na sadašnju turističku potražnju te da je turizam u Španjolskoj luksuzno dobro za Nijemce. Rezultati vezani za dohodovnu elastičnost pokazali su da ekonomska situacija u Njemačkoj snažno determinira turističku potražnju u Španjolskoj, ali i da su njemački turisti jako osjetljivi i na cijene.

3.2.3. Ibrahim (2011): Model međunarodne turističke potražnje za Egiptom

Ibrahim (2011) je na uzorku od osam najvažnijih emitivnih tržišta Egipta proveo panel model fiksnih efekata međunarodne turističke potražnje za period 1990-2008.

U ulozi zavisne varijable koja predstavlja mjeru potražnje, odabran je broj dolazaka.

Nezavisne varijable u modelu su:

- BDP *per capita* emitivnih zemalja kao determinanta dohotka;
- varijabla relativnih cijena izračunata kao kvocijent indeksa potrošačkih cijena Egipta i zemalja podrijetla turista;
- relativni tečaj dobiven kao kvocijent realnog efektivnog tečaja Egipta i domicilnih država turista;

- trgovinska otvorenost Egipta određena kao ukupna vrijednost uvoza i izvoza robe i usluga između Egipta i domicilne zemlje turista podijeljena s BDP-om Egipta;
- cijena supstituta izražena kao indeks potrošačkih cijena Tunisa.

Većina varijabli u modelu pokazala se statistički značajnom i u skladu s mikroekonomskom teorijom. Najvažniji zaključci odnose se na činjenice da se turistička potražnja za Egiptom pokazala kao dohodovno neelastična te vrlo osjetljiva na cijene. Također, utvrđena je i visoka ukrštena elastičnost s Tunisom kao supstitutabilnim odredištem.

3.2.4. Rodríguez, Martínez-Roget i Pawlowska (2012): Model akademske turističke potražnje u španjolskog Galiciji

Autori Rodríguez, Martínez-Roget i Pawlowska (2012) u svojem se istraživanju fokusiraju na poseban oblik turizma – akademski turizam i to na području španjolske autonomne zajednice Galicije. Slično kao i u prethodne dvije studije, analiza je provedena primjenom dinamičkog panel modela metodom generaliziranih momenata. Promatran je period od 2001. do 2009. godine.

Kao zavisna varijabla korišten je broj godišnje upisanih inozemnih studenata iz 36 različitih država na trima galicijskim sveučilištima u promatranom vremenskom razdoblju, a s obzirom da je model dinamički, zavisna varijabla s vremenskim pomakom nalazi se među eksplanatornim faktorima u modelu.

Među eksplanatornim varijablama, osim uobičajenih ekonomskih, u obzir su uzete i neekonomske varijable. Ekonomske eksplanatorne varijable u modelu su:

- indeks relativnih cijena prikazan kao omjer indeksa potrošačkih cijena u domicilnim državama i indeksa potrošačkih cijena u Galiciji;
- BDP *per capita* zemalja podrijetla dolaznih studenata;
- putni troškovi aproksimirani umnoškom udaljenosti svake zemlje podrijetla sa prosječnom godišnjom cijenom barela nafte.

Ostale eksplanatorne varijable u modelu specifične su za akademski turizam:

- pokazatelj koji kvantificira razlike između studenata na Sveučilištu Santiago i preostala dva lokalna sveučilišta;

- *dummy* varijabla u svrhu kontrole efekta implementacije bolonjskog sistema obrazovanja;
- razvijenost Erasmus programa razmjene studenata u promatranim domicilnim državama;
- broj studenata u visokom obrazovanju u promatranim državama;
- *dummy* varijabla za kontrolu efekta sličnosti govornih područja između domicila i Španjolske.

Rezultati su pokazali da je akademski turizam u najvećoj mjeri determiniran upravo varijablama koje nisu isključivo ekonomske prirode. U prvom redu ističu se značaj navika i preferencija studenata, potencijal diferencijalne atraktivnosti lokalnog Sveučilišta Santiago de Compostela, a važan je i utjecaj programa razmjene studenata Erasmus.

3.2.5. Cerdeira Bento (2014): Model akademske turističke potražnje u Europi

Na prevladavajući utjecaj specifičnih neekonomskih varijabli naspram ekonomskim, slično kao i kod prethodnog modela, ukazuju i rezultati autora Cerdeira Bento (2014) koji u središte interesa također stavlja akademski turizam i potražnju za takvim oblikom turizma. I u ovoj studiji korištena je metoda generaliziranih momenata za procjenu dinamičkog panel modela, a promatran je period 2000-2010. Uzorak obuhvaća 31 europsku državu koje ostvaruju dolaske stranih studenata na svojim visokoškolskim institucijama.

Ekonomске determinante potražnje u ovom modelu su:

- BDP *per capita* u zemljama odredišta kao pokazatelj standarda života u destinaciji;
- indeks relativnih cijena kao omjer indeksa potrošačkih cijena u destinaciji i domicilu;
- putni troškovi u smislu troška povratnog putovanja iz domicilne države do destinacije.

Ostale determinante u modelu nisu ekonomske prirode, već su usko povezane za područje akademskog turizma (broj studenata koji odlaze iz domicilne zemlje u sklopu Erasmus programa, broj studenata u visokom obrazovanju u destinaciji, broj dolaznih stranih studenata u destinaciji).

3.2.6. Li H., Song i Li L. (2017): Model turističke potražnje s analizom utjecaja klimatskih razlika između domicila i destinacije

Zanimljiv primjer modela turističke potražnje s uključenim specifičnim faktorima čiji se utjecaj na potražnju za turizmom želi istražiti donose autori Li H., Song i Li L. (2017). Oni su u standardni model turističke potražnje uključili i klimatske faktore kao eksplanatorne varijable (podatke o klimatskim uvjetima u domicilu posjetitelja, podatke o klimatskim uvjetima u destinaciji te podatke o razlici između klime u destinaciji i klime matične zemlje posjetitelja) te su uspjeli pokazati da svi klimatski čimbenici imaju značajan utjecaj na potražnju za turizmom u 19 turističkih gradova u kontinentalnoj Kini među turistima iz Hong Konga. Ponovno, korištena je metoda generaliziranih momenata nad panel podacima.

Zavisna varijabla u modelu, odnosno mjera potražnje je broj turističkih dolazaka iz Hong Konga, a osim zavisne varijable s vremenskim pomakom, među standardnim eksplanatornim varijablama u ovom modelu našle su se i:

- BDP *per capita* Hong Konga;
- pokazatelj relativnih cijena izračunat kao omjer indeksa potrošačkih cijena u destinacijskim gradovima i Hong Kongu korigiran za devizni tečaj;
- *dummy* varijable zbog mogućih utjecaja poznatih događanja na turističku potražnju (Olimpijske igre u Pekingu 2008, Shanghai Expo 2010, Azijske igre u Guangzhouu 2010).

3.3. Pregled odabranih ranijih istraživanja u Republici Hrvatskoj

I u Republici Hrvatskoj postoji niz istraživanja u području modeliranja i prognoziranja dolazne turističke potražnje. U tu su svrhu korištene razne kvantitativne metodologije poput modela s autoregresijskim distribuiranim pomacima (ARDL) (Mervar i Payne, 2007), analize panel podataka (Škrinjarić, 2011; Škuflić i Štoković, 2011) te Box-Jenkinsonovog pristupa (Baldigara i Mamula, 2015; Kožić, 2018).

U nastavku su ukratko predstavljeni spomenuti modeli.

3.3.1. Mervar i Payne (2007): Model stane turističke potražnje za hrvatskim destinacijama

Autori Mervar i Payne (2007) su u svrhu procjene dugoročne elastičnosti turističke potražnje u Hrvatskoj primijenili Pesaran-Shin-Smithovu metodu testiranja kritičnih vrijednosti te uspostavili model s autoregresijskim distribuiranim pomacima (ARDL). Korišteni su kvartalni podaci za promatrani period od 1994. do 2004. godine. Mjera turističke potražnje u ovom modelu je broj noćenja stranih turista, dok su dohodak u emitivnim zemljama, tečaj te putni troškovi objašnjavajuće varijable. U modelu su prisutne i *dummy* varijable koje se odnose na događaje vezane uz političke i ratne nestabilnosti u devedesetim godinama.

Autori su u konačnici zaključili da turističku potražnju za Hrvatskom u periodu od prvog kvartala 1994. do četvrtog kvartala 2004. karakterizira jaka pozitivna dohodovna elastičnost u odnosu na ključna emitivna tržišta. Također, pokazali su kako devizni tečaj te troškovi prijevoza nemaju statistički značajan utjecaj na turističku potražnju. Osvrnuli su se i na političke i ratne nestabilnosti u zemlji i regiji za vrijeme devedesetih godina te zaključili kako su navedeni događaji negativno utjecali na turizam u Republici Hrvatskoj.

3.3.2. Škrinjarić (2011): Model inozemne turističke potražnje u Hrvatskoj

Dinamički panel model strane turističke potražnje za hrvatskim turizmom predstavila je autorica Škrinjarić (2011). Za procjenu modela korištena je generalizirana metoda momenata, a uzorak sadrži godišnje podatke o 19 zemalja za period 1994.-2009. Za mjeru potražnje odabran je broj noćenja turista iz promatranih zemalja u odabranom periodu.

Determinante potražnje u ovom modelu su:

- potražnja u prethodnom razdoblju (zavisna varijabla s vremenskim pomakom);
- bruto nacionalni dohodak po stanovniku emitivnih država;
- trgovinska otvorenost Hrvatske;
- cijene konkurentskih destinacija;
- relativne cijene Hrvatske i emitivnih zemalja;
- kapitalna ulaganja u ugostiteljstvu;
- *dummy* varijable za 1995. (vojno redarstvene akcije Bljesak i Oluja) i 1999. godinu (kriza na Kosovu).

Rezultati su pokazali da se, ovisno o primijenjenom modelu, dohodovna elastičnost kreće od 0,2% do 0,5%, dok se ukrštena elastičnost s konkurentima kreće od 0,8% do 1,2%. Uz to, rezultati pokazuju osjetljivost potražnje na promjene cijena i pozitivan utjecaj kapitalnih ulaganja na turističku potražnju u Hrvatskoj.

3.3.3. Škuflić i Štoković (2011): Funkcija potražnje za hrvatskim turističkim proizvodom

Škuflić i Štoković (2011) također u ponudili svoj model potražnje za hrvatskim turističkim proizvodom koristeći poopćenu metodu najmanjih kvadrata (GLS) za procjenu regresijskih parametara. Promatrana je turistička potražnja u četiri hrvatske turističke regije – Dalmaciji, Kvarneru, Istri i Kontinentalnoj Hrvatskoj u vremenskom periodu od 1998. do 2008. godine. Količinu potražnje predstavlja broj ostvarenih noćenja u hotelskom smještaju.

Determinante potražnje u ovom modelu su:

- prosječna cijena noćenja u hotelima u različitim hrvatskim regijama;
- prosječni broj zvjezdica hotela u regiji kao pokazatelj kvalitete turističkog proizvoda;
- BDP *per capita* emitivne države iz koje se ostvaruje najveći turistički promet u pojedinoj promatranoj regiji;
- udio rezervacija ostvarenih putem Interneta kao pokazatelj promjena ponašanja potrošača;
- prosječna starost hotela kao još jedan pokazatelj kvalitete smještaja.

Glavni zaključci odnosili su se na činjenice da su prihodi na ključnim emitivnim tržištima pozitivno povezani s turističkom potražnjom, da rast cijena ima negativan utjecaj na potražnju za turističkim proizvodima te da turistički akteri moraju obratiti posebnu pažnju na mogućnost ostvarivanja rezervacija i informiranja kupaca putem internetskih stranica.

3.3.4. Baldigara i Mamula (2015): Model njemačke potražnje za hrvatskim turizmom

Autorice Baldigara i Mamula (2015) u svojoj su se studiji pomoću Box-Jenkinsonove metodologije posvetile pronalasku sezonskog ARIMA modela (integrirani autoregresijski model i model pomičnih prosjeka) koji bi najbolje mogao opisati njemačku potražnju za

hrvatskim turizmom. Mjera turističke potražnje u modelu je broj dolazaka njemačkih turista u vremenskom razdoblju 2003-2012. Promatrani su kvartalni podaci u navedenom periodu.

Kao najadekvatniji pokazao se model $ARIMA(0,0,0)(1,1,3)_4$ čije su prognostičke performanse ocijenjene iznimno uspješnima te koji je pokazao dobru korespondenciju sa stvarnim podacima iz uzorka. Autorice su također naglasile važnost provođenja daljnjih empirijskih istraživanja turističke potražnje u Republici Hrvatskoj zbog snažne ovisnosti gospodarstva o turizmu.

3.3.5. Kožić (2018): Petogodišnja prognoza turističkog prometa u Hrvatskoj

Jedna od najnovijih analiza turističke potražnje u Republici Hrvatskoj je studija autora Kožića (2018) u kojoj autor za cilj ima prognozirati količinu fizičkog turističkog prometa koja se može očekivati u Hrvatskoj tijekom idućih pet godina na temelju turističke potražnje mjerene brojem noćenja, raspoloživih smještajnih kapaciteta te sezonalnosti hrvatskog turizma. Kožić (2018) u svom radu inovativno kombinira Box-Jenkins metodologiju s metodologijom matematičkog programiranja. Prognozira da se u navedenom srednjoročnom razdoblju može očekivati umjereni rast fizičkog turističkog prometa, odnosno da bi broj noćenja u komercijalnom smještaju u Republici Hrvatskoj do 2022. godine trebao dosegnuti 105,4 milijuna.

3.4. Pregled odabranih ranijih istraživanja u području utjecaja terorizma na turističku potražnju

Turizam je takva gospodarska djelatnost u kojoj i ponuda i potražnja mogu biti osjetljive na događaje poput terorizma ili političkih nestabilnosti. Odsutnost terorizma i nasilja općeprihvaćen je preduvjet razvoja turističke destinacije. S obzirom na prisutnost brojnih terorističkih napada tokom posljednjih desetljeća, razvio se i istraživački interes za analizu veze između terorizma i turizma pri čemu su rezultati empirijskih istraživanja pokazala negativan utjecaj terorizma na turističku industriju (Araña i León, 2008). U nastavku su ukratko prikazani glavni zaključci odabranih recentnih istraživanja na temu terorizma i turizma.

3.4.1. Saha i Yap (2014): Utjecaj terorizma i političkih nestabilnosti na turističku industriju

Autori Saha i Yap (2014) analizirali su panel podatke 139 različitih država tijekom vremenskog perioda od 1999. do 2009. godine kako bi odredili u kojoj mjeri terorizam i političke nestabilnosti unutar države mogu utjecati na turističku industriju. Rezultati njihovog istraživanja pokazali su da terorizam, nakon određene prijelomne točke, znatno umanjuje iznos prihoda od turizma kao i broj turističkih dolazaka. Utjecaj političke nestabilnosti pokazuje veću volatilnost u pogledu turističke potražnje, a učinak je maksimalan u kombinaciji sa prisustvom straha od rizičnih terorističkih napada.

3.4.2. Samitas, Asteriou, Polyzos i Kenourgios (2018): Terorizam i turizam u Grčkoj

Negativan utjecaj terorizma na turizam potvrdili su i autori Samitas, Asteriou, Polyzos i Kenourgios (2018) koji su analizirali utjecaj terorizma na turističku potražnju u Grčkoj u periodu od 1977. do 2012. godine. Rezultati su pokazali da terorizam ima značajan negativan utjecaj na broj turističkih dolazaka u Grčkoj te da je veza između terorizma i turističke potražnje jednosmjerna, tj. da teroristički incidenti utječu na turističku potražnju, ali ne vrijedi i obratno. Autori sugeriraju da bi bilo poželjno da vlasti uspostave čvrste mjere protiv terorizma kao i različite mjere za promicanje turizma i sigurnosti kao odgovor na terorističke incidente.

3.4.3. Fourie, Rosselló-Nadal i Santana-Gallego (2020): Utjecaj terorizma, kriminala i korupcije na turizam

Jedna od najnovijih studija razmatrane tematike je i istraživanje autora Fourie, Rosselló-Nadal i Santana-Gallego (2020) u kojem su autori uspostavili gravitacijski model koji analizira utjecaj sigurnosnih prijetnji (korupcije, kriminala i terorizma) na međunarodni turizam mjeren brojem dolazaka. Promatran je vremenski period od 1995. do 2016. godine na uzorku od 171 države. Njihovi su rezultati pokazali kako turisti preferiraju destinacije sa sličnim razinama sigurnosti koje postoje u domicilu, odnosno da se turisti iz stabilnih domicilnih država radije odlučuju na putovanje u države sa sličnim sigurnosnim uvjetima, dok su turisti iz nestabilnijih domicilnih zemalja tolerantniji na terorizam, kriminal i korupciju pri odabiru destinacije. Fourie, Rosselló-Nadal i Santana-Gallego (2020) su također zaključili da dobra informiranost turista o destinaciji

može reducirati negativan utjecaj sigurnosnih prijetnji poput terorizma, kriminala i korupcije na dolazni turizam.

3.4.4. Ulucak, Yücel i İlkay (2020): Terorizam i turski turizam

Autori Ulucak, Yücel i İlkay (2020) proveli su analizu nad panel podacima koristeći gravitacijski model kako bi istražili determinante turističke potražnje u Turskoj. Promatran je broj turističkih dolazaka u Tursku iz 25 najznačajnijih emitivnih zemalja u vremenskom periodu od 1998. do 2017. godine. Rezultati njihovog empirijskog istraživanja potvrdili su teorijska očekivanja za sve razmatrane varijable. Varijabla koja se pokazala kao dominantni čimbenik turističke potražnje u Turskoj upravo je terorizam koji prema modelu autora Ulucak, Yücel i İlkay (2020) uzrokuje značajna smanjenja broja turističkih dolazaka.

4. EMPIRIJSKO ISTRAŽIVANJE DETERMINANTI STRANE TURISTIČKE POTRAŽNJE U HRVATSKOJ

4.1. Opis varijabli

Varijable u ovom modelu odabrane su na temelju proučene relevantne literature, prethodnih istraživanja te u skladu s dostupnosti podataka. U nastavku je objašnjena svaka varijabla iz modela, izvori podataka kao i teorijski očekivani predznaci. Godišnji podaci se odnose na 16 emitivnih država i 9 konkurentskih zemalja, a promatran je vremenski period od 2005. do 2019. godine. Garín-Muñoz (2006) navodi kako se korištenjem godišnjih podataka izbjegavaju potencijalni problemi koji mogu proizaći zbog sezonalnosti. Odabrana su najznačajnija emitivna tržišta prema ostvarenom broju dolazaka u navedenom vremenskom razdoblju: Njemačka, Slovenija, Austrija, Poljska, Italija, Češka, Slovačka, Mađarska, Ujedinjeno Kraljevstvo, Nizozemska, Sjedinjene Američke Države, Francuska te skandinavsko tržište (prema Hrvatskoj turističkoj zajednici skandinavskom tržištu pripadaju Švedska, Norveška, Finska i Danska). Konkurenti su određeni prema Institutu za turizam (2011) koji Španjolsku, Italiju, Grčku, Tursku, Maltu, Bugarsku, Cipar, Francusku i Portugal svrstava među široki hrvatski konkurentski krug.

Kako bi se mogao ostvariti cilj ovog rada te postaviti odgovarajući model turističke potražnje, po uzoru na brojna prethodna empirijska istraživanja, varijable su formirane kao panel podaci. Panel podaci takva su vrsta podataka koji istovremeno u obzir uzimaju vremensku i prostornu komponentu neke varijable, stoga se panel analiza često koristi u različitim ekonometrijskim i empirijskim istraživanjima. Prednost panel analize ogleda se i u tome što podaci koji nisu bili dostatni za analizu vremenskih nizova kao ni za prostornu analizu, ujedinjeni u panel podatke mogu pružiti kvalitetne empirijske rezultate. Panel analiza svoju primjenu pronalazi u svim područjima ekonomije, kako na mikro tako i makro razini. Sukladno prirodi panel podataka, za njihovu ekonometrijsku analizu uspostavile su se posebne metode i modeli. Kako bi se formirala baza podataka potrebna za panel analizu, potrebno je sakupiti podatke o jedinicama promatranja kroz vrijeme (Aljinović i Marasović, 2012). Garín-Muñoz (2006) navodi kako korištenje panel podataka u analizi povećava raspon varijacija varijabli zbog značajnih razlika između emitivnih zemalja poput razlika u dohotku i sociodemografskim karakteristikama. Također, ističe kako korištenje ove vrste podataka omogućuje upotrebu više stupnjeva slobode nego što je to slučaj s vremenskim nizovima ili podacima presjeka te omogućuje kontrolu

izostavljene varijable pristranosti pa se stoga smanjuje problem multikolinearnosti i poboljšava točnost procjene parametara.

U ovom empirijskom istraživanju, spomenute jedinice promatranja su 16 odabranih emitivnih država i 9 konkurentskih zemalja, a promatrani vremenski period 2005.-2019.

4.1.1. Zavisna varijabla

Po uzoru na Garín-Muñoz (2006), Ibrahim (2011) te Li H., Song i Li L. (2017), zavisna varijabla u modelu je broj turističkih dolazaka u Republiku Hrvatsku od strane turista sa najznačajnijih emitivnih tržišta ($Q_{i,t}$). Ova varijabla ujedno predstavlja i mjeru turističke potražnje u modelu. Pokazuje broj turističkih dolazaka iz emitivne države i u godini t ($i = \text{Austrija, ... Ujedinjeno Kraljevstvo}$; $t = 2005, \dots, 2019$). Podaci su preuzeti od Državnog zavoda za statistiku koji dolaske turista definira kao broj prijavljenih osoba (turista) koje su ostvarile noćenje u objektu koji pruža uslugu smještaja.

4.1.2. Eksplanatorne varijable

Zavisna varijabla s vremenskim pomakom. Kao i u ostalim dinamičkim modelima, vrijednost zavisne varijable s vremenskim pomakom uključena je u model kao eksplanatorna varijabla ($Q_{i,t-1}$). Ova varijabla predstavlja potražnju u prethodnom razdoblju. Garín-Muñoz (2006; 2007) objašnjava razloge koji opravdavaju uključivanje prethodne potrošnje kao regresora. Prvi razlog odnosi se na to što je manje neizvjesnosti povezano s boravkom u destinaciji koja je posjetiteljima već poznata, u usporedbi s putovanjem u nepoznato inozemno odredište. Drugi razlog odnosi se na činjenicu da se znanje i glas o destinaciji širi kako turisti prepričavaju događaje i dojmove o svojem putovanju prijateljima i poznanicima, smanjujući time nesigurnost i neizvjesnost za potencijalne nove posjetitelje iste destinacije. Garín-Muñoz (2006; 2007) također naglašava da je moguće da će se, ako se zanemari utjecaj prošle potražnje, učinak relevantnih varijabli koje se razmatraju precijeniti.

Prema rezultatima prethodnih istraživanja, očekuje se pozitivan predznak ove varijable.

Dohodak. S obzirom da je velika većina prethodnih povezanih istraživanja (Garín-Muñoz, 2006; Garín-Muñoz, 2007; Ibrahim, 2011; Škuflić i Štoković, 2011; Li H., Song i Li L., 2017) koristila BDP po stanovniku u emitivnoj državi kao pokazatelj dohotka turista, isti se koristi i u ovom modelu ($Y_{i,t}$). Odabrani su podaci koji se odnose na BDP *per capita* mjeren metodom pariteta kupovne moći (PKM). Navedena metoda mjerenja BDP-a, gdje jedan dolar ima moć kupnje iste količine robe i usluga u svim zemljama, omogućuje usporedbu ekonomskih agregata na temelju fizičkih razina proizvodnje, bez utjecaja promjena cijena i tečaja. Podaci su prikupljeni sa službene web stranice Svjetske banke.

Polazeći od mikroekonomske teorije kao i od prethodnih istraživanja, za ovu varijablu očekuje se pozitivan predznak.

Relativne cijene. Aproksimacija za relativne cijene izračunata je u skladu s Li H., Song i Li L. (2017.) i Song et al (2010.) gdje se cijene i tečajevi zajednički uzimaju u obzir pri izračunu varijable relativne cijene ($P_{i,t}$).

Varijabla koja predstavlja cijenu turizma u Hrvatskoj definirana je kao:

$$(6) P_{i,t} = \frac{CPI_{CROt}/EX_{CROt}}{CPI_{it}/EX_{it}},$$

gdje su CPI_{CROt} i CPI_{it} indeksi potrošačkih cijena za Hrvatsku, odnosno emitivnu zemlju i , a EX_{CROt} i EX_{it} su tečajevi između hrvatske kune i američkog dolara, odnosno lokalne valute emitivne zemlje i te američkog dolara.

Podaci o indeksima potrošačkih cijena preuzeti su od Svjetske banke, a podaci o tečajevima preuzeti su sa službenih internetskih stranica OECD-a.

Ova varijabla, uzevši u obzir mikroekonomsku teoriju i prethodna istraživanja, ima negativni očekivani predznak.

Cijene supstituta. Cijene supstituta također su uključene u model. Po uzoru na Škrinjarić (2011), ova se varijabla mjeri kao prosječni indeks potrošačkih cijena devet konkurenata: Španjolske, Italije, Grčke, Turske, Malte, Bugarske, Cipra, Francuske i Portugala ($KONK_t$). Kao što je prethodno spomenuto, Hrvatski institut za turizam (2011) ove konkurente naziva širokim hrvatskim konkurentskim krugom. Podaci za ovu varijablu prikupljeni su sa službene

web stranice Svjetske banke. Pretpostavka je da će, kad cijene u konkurentskim destinacijama porastu, porasti turistička potražnja za Hrvatskom, *ceteris paribus*, pa se očekuje pozitivan predznak ove varijable.

Terorizam u konkurentskim destinacijama. Utjecaj terorizma u konkurentskim destinacijama također je uključen u model ($TEROR_t$). S obzirom da su u nekim od zemalja iz šireg konkurentskog kruga u promatranom periodu postojale terorističke aktivnosti, dok u Republici Hrvatskoj nisu, postavlja se pitanje kako terorizam u konkurentskim destinacijama utječe na turističku potražnju u Hrvatskoj.

Kao mjera terorizma u konkurentskim zemljama odabran je Globalni indeks terorizma koji objavljuje organizacija Vision of Humanity, a utemeljen je na Globalnoj bazi podataka o terorizmu (GTD) koja je najrespektabilniji izvor podataka o terorizmu današnjice. Organizacija Vision of Humanity podržana je od strane Instituta za ekonomiju i mir (IEP). Prema Vision of Humanity, Globalni indeks terorizma (GTI) složena je mjera koja se sastoji od četiri pokazatelja: incidenata, smrtnih slučajeva, ozljeda i imovinskih šteta. Globalni indeks terorizma ocjenjuje svaku zemlju na ljestvici od 0 do 10, pri čemu 0 predstavlja odsustvo utjecaja terorizma, dok 10 predstavlja najveći mjerljivi učinak terorizma. Zemlje su rangirane padajućim redoslijedom s najlošijim ocjenama na vrhu ljestvice. Što se tiče same definicije terorizma, Globalni indeks terorizma definira terorizam kao prijetnju ili stvarnu primjenu ilegalne sile i nasilja od strane nedržavnog aktera u svrhu postizanja političkih, ekonomskih, vjerskih ili socijalnih ciljeva kroz strah, prisilu ili zastrašivanje. Ova definicija uzima u obzir da se terorizam ne odnosi samo na fizički čin napada, već i na psihološki utjecaj koji ostavlja na društvo dugo vremena nakon samog čina (Institute for Economics & Peace, 2020).

Globalni indeksi terorizma svih devet konkurenata iz spomenutog širokog konkurentskog kruga Hrvatske uzeti su u obzir pri izračunu prosječnog stupnja terorizma na konkurentskim područjima, osim Bugarske, Malte i Portugala za koje nažalost nisu bili dostupni svi podaci.

Obzirom na proučenu literaturu, ali i općepoznatu praksu, pretpostavlja se da će posjetitelji preferirati sigurnije zemlje pa će u slučaju terorizma u konkurentskim destinacijama, odmor radije provesti u Hrvatskoj. Stoga se očekuje pozitivan predznak za globalni indeks terorizma.

Investicije u turizmu i ugostiteljstvu. Posljednja varijabla uključena u model odnosi se na investicije turističkih dionika u Hrvatskoj (INV_t). Kao aproksimacija investicija u turizmu i ugostiteljstvu, u ovom su modelu promatrane bruto investicije u novu i rabljenu dugotrajnu imovinu prema djelatnosti investitora. Konkretno, kao djelatnost investitora, prema NKD 2002 promatrano je područje hoteli i restorani, a po NKD 2007 u obzir je uzeto područje djelatnosti pružanja smještaja te pripreme i usluživanja hrane. Podaci su preuzeti od Državnog zavoda za statistiku. Slijedeći Nawaza i Hassana (2016) koji sugeriraju pozitivan učinak javnih i privatnih ulaganja na rast turizma, te Škrinjarić (2011) čiji je model pokazao pozitivan i značajan učinak kapitalnih ulaganja na turističku potražnju u Hrvatskoj, očekuje se pozitivan predznak varijable ulaganja.

Tablica 2 u nastavku prikazuje sumarni prikaz i opis odabranih varijabli, izvora podataka te očekivanih predznaka.

Tablica 2. Varijable u modelu turističke potražnje u RH

Ime varijable	Opis i izvor varijable	Očekivani predznak
Zavisna varijabla		
Broj turističkih dolazaka ($Q_{i,t}$)	broj turističkih dolazaka iz emitivne države i u godini t ($i = \text{Austrija, ... Ujedinjeno}$ $\text{Kraljevstvo; } t = 2005, \dots,$ 2019); DZS	/
Eksplanatorne varijable		
Zavisna varijabla s vremenskim pomakom ($Q_{i,t-1}$)	Potražnja u prethodnom razdoblju, DZS	+
Dohodak ($Y_{i,t}$)	BDP <i>per capita</i> mjeren metodom pariteta kupovne moći (PKM)	+
Relativne cijene ($P_{i,t}$)	Omjer indeksa potrošačkih cijena RH i emitivnih zemalja, korigiranih za tečaj; World Bank, OECD	-
Cijene supstituta ($KONK_t$)	prosječni CPI zemalja iz širokog konkurentskog kruga; World Bank	+
Terorizam u konkurentskim destinacijama ($TEROR_t$)	Globalni indeks terorizma (GTI); Vision of Humanity	+
Investicije u turizmu i ugostiteljstvu (INV_t)	bruto investicije dionika uključenih u pružanje ugostiteljskih usluga; DZS	+

Izvor: prikaz autorice

4.2. Opis primijenjene metodologije

Prethodna istraživanja pokazala su da prošla potražnja za nekim dobrom ili uslugom može imati utjecaj na buduću potražnju te da se priroda potražnje za turističkim proizvodima, kao i mnogi drugi ekonomski odnosi, može okarakterizirati kao dinamička. Iz tog je razloga model potražnje za hrvatskim turizmom u ovom radu također dinamičkog karaktera. Polazni oblik modela turističke potražnje na temelju odabranih varijabli može se izraziti kao:

$$(7) DOLASCI_{i,t} = f(DOLASCI_{i,t-1}, Y_{i,t}, P_{i,t}, KONK_t, TEROR_t, INV_t).$$

Nadalje, kako bi model mogao poprimiti linearni oblik, a procijenjeni parametri interpretirati kao koeficijenti elastičnosti, nad originalnim vrijednostima svih odabranih varijabli izvršena je logaritamska transformacija te su sve vrijednosti u konačnici iskazane prirodnim logaritmom. Stoga oblik modela (7) poprima sljedeći oblik:

$$(8) \ln DOLASCI_{i,t} = f(\ln DOLASCI_{i,t-1}, \ln Y_{i,t}, \ln P_{i,t}, \ln KONK_t, \ln TEROR_t, \ln INV_t)$$

Nastavno na navedeno, opći oblik modela turističke potražnje u Republici Hrvatskoj u ovome radu izražen je kao:

$$(9) Q_{it} = \alpha + \delta Q_{i,t-1} + \sum_{n=1}^N \beta_n X_{it}^n + \varepsilon_{it}$$

gdje je:

- Q_{it} broj turističkih dolazaka iz emitivne države i u godini t ($i = \text{Austrija, ... Ujedinjeno Kraljevstvo}$; $t = 2005, \dots, 2019$);
- α konstantni član;
- δ brzina prilagodbe postojećeg stanja zavisne varijable prema željenom stanju;
- $Q_{i,t-1}$ vrijednost zavisne varijable u prethodnoj godini, tj. broj turističkih dolazaka u prethodnoj godini;
- β procijenjeni parametri;

- X_{it} eksplanatorne varijable (dohodak, relativne cijene, cijene supstituta, terorizam i investicije);
- ε_{it} greške relacije koje obuhvaćaju nezavisno i identično distribuirane slučajne varijable sa sredinom 0 i varijancom σ_ε^2 (Škuflić i Mlinarić, 2015).

Pri vrijednosti člana δ blizu nule prisutna je velika brzina prilagodbe prema optimalnoj razini, dok vrijednost δ blizu jedinice ukazuje na vrlo spor postupak prilagodbe. Prvi slučaj ukazuje na to da je industrija prilično konkurentna, dok je u drugom slučaju industrija manje konkurentna (Athanasoglou et al. 2008).

U modelima koji uključuju dinamičke specifikacije, procjenitelji poput obične i poopcene metode najmanjih kvadrata (OLS-a i GLS-a) prouzrokovali bi pristrane i nedosljedne procjene. Stoga, kako bi se prevladao spomenuti problem, u ovom se radu primjenjuje postupak generalizirane metode momenata koji su predložili Arellano i Bond (1991). Ipak, da bi se dobila konzistentna i nepristrana procjena, generalizirana metoda momenata zahtjeva da ne postoji autokorelacija greške ε_{it} (Cameron i Trivedi, 2010). Iz tog je razloga potrebno dijagnostičkim testovima provjeriti postoji li problem autokorelacije među prvim diferencijama rezidualnih odstupanja. Ispitivanje autokorelacije prvog i drugog reda obično se vrši pomoću Arellano i Bond testa (testovi $m1$ i $m2$). Ako je prisutna autokorelacija prvog reda među prvim diferencijama reziduala, procjene parametara su i dalje konzistentne. S druge strane, ako je utvrđena korelacija drugog reda među prvim diferencijama reziduala, procjene parametara nisu konzistentne. Uz to, izračun testa $m2$ je moguć u slučaju kada broj opažanja za svaku jedinicu promatranja iznosi najmanje 5 (Škuflić i Mlinarić, 2015).

Drugi dijagnostički test koji se uobičajeno koristi u ovoj vrsti analize je Sarganov test koji provjerava valjanost odabranih instrumenata potrebnih za procjenu modela na način da analizira koreliranost instrumentalnih varijabli sa rezidualima. Sarganov test zapravo ispituje preidentifikaciju ograničenja jer se podrazumijeva da uvođenje svake nove instrumentalne varijable uvodi i novi uvjet, odnosno ograničenje koje treba biti zadovoljeno (Škuflić i Mlinarić, 2015).

Svi rezultati koji će biti nadalje prikazani u ovome radu izračunati su pomoću statističkog softvera Stata.

4.3. Deskriptivna statistika

Uobičajeno je analizu rezultata započeti deskriptivnom statistikom. Navedene podatke sadrži Tablica 3.

Važno je napomenuti da, s obzirom da je iz metodoloških razloga izvršena logaritamska transformacija originalnih podataka te su sve vrijednosti iskazane prirodnim logaritmom, varijable čije su originalne vrijednosti iznosile ispod 1, u Tablici 3 očekivano poprimaju negativni predznak. Upravo je to slučaj s varijablom relativne cijene.

Tablica 3. Deskriptivna statistika

Varijabla	Br. opažanja	Aritmetička sredina	Standardna devijacija	Minimum	Maksimum
Broj dolazaka	240	12,81373	1,036438	9,798127	14,87375
Dohodak	240	10,65484	0,2816625	9,852072	11,06089
Relativne cijene	240	-0,9706406	1,607109	-2,407293	3,687157
Cijene supstituta	240	4,640946	0,1047956	4,444048	4,814013
Globalni indeks terorizma	240	1,229785	0,0991673	1,048021	1,417793
Investicije u ugostiteljstvu RH	240	14,92641	0,3951921	14,17439	15,46292

Izvor: izračun autorice

U periodu od 2005. do 2019. godine, prosječni broj dolazaka posjetitelja iz promatranog uzorka je iznosio 367 225. Najmanji broj dolazaka (18 000) zabilježen je od strane turista iz Finske 2006. godine, dok je najveći broj dolazaka (2 881 284) zabilježen 2019. godine i to od strane njemačkih turista. Prosječni dohodak turista iz uzorka mjeren BDP-om *per capita* u

vremenskom periodu od 2005. do 2019. iznosio je 42 397 \$. Najniži dohodak u uzorku zabilježen je 2005. godine za emitivno tržište Poljske (18 998 \$), a najviši 2019. u Norveškoj (63 633 \$). Prosjek relativnih cijena između Republike Hrvatske i emitivnih zemalja je 0,3788 što ukazuje na to da su cijene u Hrvatskoj u prosjeku povoljnije od cijena u emitivnim državama. U kontekstu relativnih cijena Republike Hrvatske i odabranih emitivnih tržišta, podaci pokazuju kako je Hrvatska bila najpovoljnija u odnosu na cijene u Ujedinjenom Kraljevstvu 2005. godine, dok je najskuplja bila za posjetitelje iz Mađarske 2006. godine. Što se tiče cijena supstituta, odnosno konkurentskih destinacija, prosječni indeks potrošačkih cijena iznosio je 103,6 u promatranom vremenskom razdoblju. Najmanja vrijednost zabilježena je 2005. godine u iznosu od 85,12, dok su konkurentske države najviši indeks potrošačkih cijena u prosjeku ostvarile 2019. godine i to u iznosu od 123,23. Također, konkurentske su destinacije zajedno zabilježile vrijednost globalnog indeksa terorizma u prosječnom iznosu od 3,42 u promatranom periodu. Najmanju stopu terorizma (GIT) imao je Cipar 2011. godine sa iznosom od 0,048, dok je Turska zabilježila najveći GIT od svih konkurenata 2016. godine i to u iznosu od 7,5. Prosječne investicije od strane dionika u turizmu i ugostiteljstvu Republike Hrvatske u promatranom periodu iznosile su 3,04 mlrd HRK. Vrijednost investicija najniža je bila 2010. godine i to u iznosu od 1,4 mlrd HRK, dok je najviša vrijednost investicija u turizmu i ugostiteljstvu RH zabilježena 2017. godine u iznosu od 5,2 mlrd HRK.

4.4. Korelacijska analiza

Tablica 4 prikazuje korelacijsku analizu. Pojam korelacije podrazumijeva međuovisnost, odnosno povezanost slučajnih varijabli. Stupanj podudarnosti slučajnih varijabli, u ovom slučaju determinanti turističke potražnje, predstavlja mjeru korelacije (Rozga, 2009).

Tablica 4. Korelacijska analiza

	Broj dolazaka	Dohodak	Relativne cijene	Cijene supstituta	Globalni indeks terorizma	Investicije u ugostiteljstvu RH
Broj dolazaka	1					
Dohodak	-0,2318	1				
Relativne cijene	-0,1637	-0,3183	1			
Cijene supstituta	0,2254	0,1540	-0,0015	1		
Globalni indeks terorizma	0,1738	0,0967	-0,0063	0,4169	1	
Investicije u ugostiteljstvu RH	0,1311	0,0994	-0,0017	0,2104	0,6453	1

Izvor: izračun autorice

S deskriptivnog motrišta, iz tablice je vidljivo da sve varijable međusobno imaju slabu korelaciju jer im je apsolutna vrijednost koeficijenta korelacije niža od 0,5. Jedina iznimka su varijable investicije u ugostiteljstvu RH i globalni indeks terorizma u konkurentskim destinacijama čiji međusobni koeficijent korelacije ukazuje na srednje jaku povezanost, no ista je i dalje ispod vrijednosti od 0,8 koja bi prema Rozgi (2009) ukazivala na jaku međusobnu korelaciju. Generalno, budući su sve vrijednosti koeficijenata korelacije niže od 0,7 može se zaključiti kako među varijablama ne postoji problem multikolinearnosti.

Važno je za naglasiti kako koeficijenti linearne korelacije koji su statistički značajni ne moraju ujedno imati i praktično značenje (Rozga, 2009). Primjerice, prisutnost neke pozitivne ili negativne veze između promatranih varijabli (npr. negativna korelacija između dohotka i broja dolazaka vidljiva u Tablici 4), ne treba nužno indicirati njezinu prisutnost i u ocijenjenom modelu. Ovo se u konkretnom primjeru pokazalo točnim.

4.5. Rezultati modela

Konačno, Tablica 5 donosi rezultate dinamičkog panel modela. Svi ocijenjeni parametri u modelu u skladu su sa teorijskim očekivanjima i imaju statistički značajan utjecaj na turističku potražnju.

Tablica 5. Rezultati dinamičkog panel modela

Varijabla	Koeficijent	P
$Q_{i,t-1}$	0,5320686	0,000
$Y_{i,t}$	0,7797762	0,000
$P_{i,t}$	-0,3154752	0,018
$KONK_t$	0,4883548	0,001
$TEROR_t$	0,3352734	0,000
INV_t	0,0183021	0,105
Konstanta	-5.367705	0,000
Br. opažanja	208	
Arellano-Bond (m1) (p-vrijednost)	0,0357	
Arellano-Bond (m2) (p-vrijednost)	0,9942	
Sargan test (p-vrijednost)	0,9631	

Izvor: izračun autorice

4.5.1. Arellano-Bond i Sargan test

Prije same interpretacije rezultata, potrebno je prvo provesti potrebne dijagnostičke testove u svrhu provjere valjanosti modela. U Tablici 5 mogu se vidjeti rezultati Arellano-Bond i Sargan testa.

Među prvim diferencijama reziduala prisutna je autokorelacija prvoga reda pri razini signifikantnosti od 0,05 jer je $m1 (0,036) < 0,05$, pa se stoga odbacuje nulta hipoteza o nepostojanju autokorelacije prvoga reda. Međutim, čak i uz prisustvo autokorelacije prvoga reda, procjene parametara u modelu i dalje mogu biti konzistentne. Ono što je ključno jest da autokorelacija drugoga reda među prvim diferencijama reziduala nije prisutna jer $m2$ iznosi 0,99 što prelazi razinu signifikantnosti od 0,05 pa se stoga može prihvatiti hipoteza o nepostojanju autokorelacije drugoga reda. Navedeno ujedno čini kriterij Arellano-Bond testa zadovoljenim.

Druga provjera odnosi se na Sargan test čija p-vrijednost u modelu iznosi 0,96 što prelazi razinu signifikantnosti od 0,05 pa se može zaključiti da su odabrani instrumenti u modelu valjani.

S obzirom da je model zadovoljio oba dijagnostička testiranja – Arellano-Bond te Sargan test, može se dalje analizirati i interpretirati u skladu s dobivenim rezultatima.

4.5.2. Analiza i interpretacija modela turističke potražnje u Republici Hrvatskoj

Ocijenjeni koeficijent uz zavisnu varijablu s vremenskim pomakom ($Q_{i,t-1}$) iznosi 0,5 te je statistički značajan pri razini signifikantnosti od 1%. Uzimajući u obzir prethodno objašnjeno tumačenje ovog koeficijenta od strane Athanasoglou *et al.* (2008), može se zaključiti da je turistička industrija u Republici Hrvatskoj umjereno konkurentna. Koeficijent prošle potražnje u vrijednosti 0,5 također ukazuje na prisutnost dosljednosti navika turista koji se rado ponovno vraćaju u Hrvatsku kao i mogućeg efekta „od usta do usta“. Slični rezultati o pozitivnom utjecaju prethodne potražnje na buduću turističku potražnju, mogu se pronaći i kod Garín-Muñoz (2006, 2007) koja također naglašava važnost pružanja visokokvalitetne usluge u svrhu stjecanja dobre reputacije među turistima te privlačenja kako starih, tako i novih posjetitelja. Ovakav rezultat također je u skladu s nalazima Tomas istraživanja 2019. koje je pokazalo kako je u Republici Hrvatskoj prisutna visoka lojalnost turista te koje je također prepoznalo preporuke rodbine i prijatelja te prijašnji boravak kao najznačajnije izvore informacija o destinaciji (uz Internet).

Koeficijent cjenovne elastičnosti ($P_{i,t}$) iznosi -0,3% te je statistički značajan pri razini signifikantnosti od 5%. Konkretno, ovaj koeficijent pokazuje kako 1%-tni rast relativnih cijena u Republici Hrvatskoj u odnosu na emitivna tržišta, uzrokuje 0,3%-tni pad turističke potražnje.

Koeficijent ima teorijski očekivan negativni predznak. S obzirom da je apsolutna vrijednost koeficijenta cjenovne elastičnosti manja od 1, dolazi se do zaključka da, prema ovom modelu, turizam u Republici Hrvatskoj nije osjetljiv na promjene cijena, to jest da je potražnja za hrvatskim turističkim proizvodom cjenovno neelastična. Ovaj se parametar može pokušati povezati s prethodno ocijenjenim koeficijentom dohodovne elastičnosti i prošle potražnje. Prema modelu, može se pretpostaviti da su turisti sa najznačajnijih emitivnih tržišta neosjetljivi na promjene vlastitog dohotka i relativnih cijena uslijed visoke lojalnosti destinaciji. Slične rezultate polučila su i istraživanja Garín-Muñoz (2006) te Rodríguez, Martínez-Roget i Pawlowska (2012).

Temeljem dobivenog rezultata, hipoteza *H1* koja glasi da porast cijena u Hrvatskoj ima negativan utjecaj na turističku potražnju može se prihvatiti jer, iako slabo, turistička potražnja ipak i dalje negativno reagira na rast cijena.

Koeficijent dohodovne elastičnosti ($Y_{i,t}$) iznosi 0,8% te je statistički značajan pri razini signifikantnosti od 1%. Prema ovom modelu, 1%-tni rast dohotka na emitivnim tržištima uzrokuje približno 0,8%-tni rast turističke potražnje u Republici Hrvatskoj. Unatoč tome što je predznak ovog parametra očekivano pozitivan, koeficijent dohodovne elastičnosti ipak je manji od 1. Ta činjenica sugerira da posjetitelji sa najznačajnijih emitivnih tržišta, turizam u Republici Hrvatskoj ipak ne smatraju luksuznim, već normalnim dobrom (koji teži luksuznom). Sukladno navedenom, s obzirom da je prema ovom modelu potražnja za hrvatskim turističkim proizvodom dohodovno neelastična, može se zaključiti da turisti iz najznačajnijih emitivnih zemalja nisu osjetljivi na promjene vlastitog dohotka kada donose odluke o putovanju u Hrvatsku. Ta se činjenica može povezati i sa prethodno utvrđenom dosljednosti navika turista koji se rado vraćaju u Hrvatsku, neovisno o svojem dohotku. Slične rezultate dobili su i Ibrahim (2011) i Škrinjaric (2011).

U konačnici, na temelju pozitivnog predznaka koeficijenta dohodovne elastičnosti i njegove statističke značajnosti, može se prihvatiti hipoteza *H2* koja glasi da porast dohotka posjetitelja utječe na porast potražnje za hrvatskim turističkim proizvodom.

Koeficijent ukrštene elastičnosti, odnosno parametar uz varijablu cijene konkurenata ($KONK_t$), iznosi 0,5% i statistički je značajan pri razini signifikantnosti od 1%. Sukladno tome, 1%-tni rast cijena u konkurentskim destinacijama iz šireg mediteranskog kruga uzrokovao bi 0,5%-tni rast potražnje za turizmom u Republici Hrvatskoj. Ovaj rezultat potvrđuje da su odabrane promatrane konkurentske destinacije svojevrсни supstituti za hrvatski turizam. Činjenica da se

skup promatranih država može smatrati supstitutima za Republiku Hrvatsku kao turističku destinaciju može se u praksi implicirati na pozitivan, ali i negativan način po hrvatski turizam. Stoga je važno da dionici u hrvatskom turizmu prate stanje i usmjere svoju pažnju i prema konkurentskim destinacijama pri donošenju poslovnih odluka i politika, a ne samo prema emitivnim tržištima. Ovakav se rezultat može poistovjetiti i sa rezultatima Škrinjaric (2011).

Na osnovu iznosa koeficijenta ukrštene elastičnosti i njegove statističke značajnosti prihvaća se i hipoteza *H3* koja navodi kako porast cijena u konkurentskim destinacijama rezultira rastom potražnje za Hrvatskom kao turističkom destinacijom.

Ocijenjeni parametar uz varijablu koja predstavlja terorizam u konkurentskim destinacijama iznosi 0,3% i statistički je značajan pri razini signifikantnosti od 1%. Ovaj koeficijent pokazuje kako 1%-tni rast terorističkih aktivnosti na konkurentskim područjima (iskazan globalnim indeksom terorizma) utječe na potražnju za hrvatskim turističkim proizvodom na način da ona u tom slučaju raste za 0,3%. Navedeni rezultat je u skladu sa činjenicom da je osobna sigurnost jedan od najbolje ocijenjenih elemenata turističke ponude u Republici Hrvatskoj prema Tomas istraživanju 2019. Ovaj parametar također sugerira da eksterni događaji na konkurentskim tržištima mogu posljedično utjecati i na turističku potražnju u Hrvatskoj. Značajan utjecaj terorizma na turističku potražnju, između ostalih, potvrdili su i Samitas, Asteriou, Polyzos i Kenourgios (2018), Fourie, Rosselló-Nadal and Santana-Gallego (2020) te and Ulucak, Yücel and İlkay (2020).

U skladu s opisanim rezultatima, može se prihvatiti hipoteza *H4* koja tvrdi da se prisutnost terorističkih aktivnosti na područjima konkurentskih destinacija pozitivno odražava na turističku potražnju u Hrvatskoj, odnosno da se dio turista, u slučaju pojave terorizma u konkurentskim destinacijama, radije opredijeli za Republiku Hrvatsku kao sigurniju turističku destinaciju.

Zadnji procijenjeni parametar odnosi se na varijablu investicija u turizmu i ugostiteljstvu u Republici Hrvatskoj te on iznosi 0,02%. Što se tiče statističke značajnosti ovog koeficijenta, on se nalazi na granici prihvatanja pri razini signifikantnosti od 10%. Na temelju ovog rezultata može se zaključiti da je potražnja za hrvatskim turističkim proizvodom slabo osjetljiva na promjene na strani ponude jer bi rast kapitalnih ulaganja od 1% implicirao tek 0,2%-tni rast turističke potražnje. Također, ova se varijabla pokazala najmanje statistički značajnom od svih ostalih u modelu. Međutim, važno je naglasiti kako se u praksi investiranje u turizam odnosi na daleko širi skup različitih ulaganja među kojima su i infrastrukturna ulaganja, građevinski

radovi, ulaganja u ljudske resurse i mnoga druga, dok ovaj model zbog pojednostavljenja u obzir uzima samo uže područje ulaganja koje se odnosi na djelatnosti pružanja smještaja te pripreme i usluživanja hrane (hoteli i restorani). Stoga se niska vrijednost koeficijenta može objasniti i činjenicom da je promatran utjecaj samo dijela relevantnih investicija.

U konačnici je pozitivan učinak investicija na samu turističku potražnju ovim modelom ponovno potvrđen što je u skladu s rezultatima Škrinjarić (2011). Sukladno navedenom, može se prihvatiti i hipoteza *H5* koja navodi kako investicije u turizmu i ugostiteljstvu u Hrvatskoj imaju pozitivan utjecaj na turističku potražnju.

5. ZAKLJUČAK

Zbog iznimnog značaja turističke industrije za hrvatsko gospodarstvo, važno je učestalo provoditi različite analize i empirijska istraživanja kako bi donositelji odluka i turistički akteri iz prakse bolje razumjeli prirodu turističke potražnje i istoj se na adekvatan način prilagodili.

U ovome je radu uspostavljen novi model strane turističke potražnje u Republici Hrvatskoj primjenom panel podataka i generalizirane metode momenata (GMM) na osnovu kojeg je prihvaćano svih pet inicijalno postavljenih hipoteza.

Rezultati empirijskog istraživanja, koje promatra period od 2005. do 2019. godine, pokazali su visoku značajnost utjecaja potražnje u prethodnim razdobljima na sadašnju potražnju. Također, prema rezultatima istraživanja, potražnja za hrvatskim turizmom u promatranom je periodu cjenovno i dohodovno neelastična. Unatoč neelastičnosti, iako slab, potvrđen je teorijski očekivan negativan utjecaj rasta cijena u Hrvatskoj, odnosno pozitivan utjecaj rasta dohotka posjetitelja na potražnju za hrvatskim turizmom. Navedeno je u konačnici uvjetovalo prihvaćanje hipoteza *H1* i *H2* o negativnom učinku rasta cijena i pozitivnom utjecaju rasta dohotka na turističku potražnju u Hrvatskoj. Sukladno navedenim rezultatima, može se donijeti zaključak kako je kvaliteta same turističke ponude ključna za postizanje lojalnosti posjetitelja te da su lojalni potrošači manje osjetljivi na promjene cijena i vlastitog dohotka. Stoga je važno kontinuirano raditi na očuvanju i unaprjeđenju kvalitete ponude, a sve u svrhu poticanja daljnje lojalnosti od strane postojećih potrošača i privlačenja novih kojima je sam sadržaj ponude važniji od cijene i vlastitog dohotka. Budući da je model je pokazao da uslijed povećanja cijena u konkurentskim destinacijama dolazi do povećanja turističke potražnje u Hrvatskoj te time potvrdio hipotezu *H3* o efektu supstituta, dolazi se do zaključka kako je kod donošenja cjenovnih politika važno uzeti u obzir i cijene u konkurentskim destinacijama koje se mogu karakterizirati kao supstituti hrvatskom turističkom proizvodu. Posebnu pažnju važno je obratiti na one elemente ponude koji su se pokazali kao najbolje i najlošije percipirani od strane turista. S obzirom da je osobna sigurnost jedan od najbolje ocijenjenih elemenata ponude od strane turista, a rezultati empirijskog istraživanja potvrdili su hipotezu *H4* kako se dio turista uslijed terorističkih aktivnosti na konkurentskim područjima preorijentira na Hrvatsku kao turističku destinaciju, poželjno bi bilo dodatno naglasiti aspekt sigurnosti destinacije kod promotivnih aktivnosti (primjerice Hrvatske turističke zajednice ili lokalnih turističkih zajednica). Investicije u turizmu i ugostiteljstvu pokazale su se kao najmanje značajna determinanta potražnje, ali je potvrđen njihov pozitivan učinak te je time prihvaćena hipoteza *H5* o

pozitivnom utjecaju investicija u turizam i ugostiteljstvo na turističku potražnju. Unatoč graničnoj značajnosti varijable u procijenjenom modelu, ulaganja na strani ponude od iznimne su važnosti za dugoročno održavanje postojeće lojalnosti posjetitelja kao i za pridobivanje novih kupaca, stoga se ova determinanta ne smije zanemariti.

Usprkos tome što je model polučio statistički značajne rezultate u skladu s mikroekonomskom teorijom, zbog određenih ograničenja, važno je ipak na ove rezultate gledati primarno kao orijentir za akcije u praksi, a ne ih shvaćati doslovno. Za svaku od analiziranih varijabli korištene su aproksimacije u skladu s dostupnosti podatka te je moguće da bi korištenje drugačijih indikatora za iste odabrane determinante (ili pak drugog uzorka) rezultiralo nešto drugačijim zaključcima. Također je važno naglasiti kako je ovaj model podosta općenit te ne ulazi dublje u problematiku koje se turističke destinacije mogu smatrati direktnim konkurentima Hrvatskoj i zašto, već je za uzorak odabran široki mediteranski krug konkurenata definiran od strane Instituta za turizam. Turistički proizvodi nekih od odabranih destinacija iz navedenog uzorka te njihova emitivna tržišta u određenoj se mjeri razlikuju od hrvatskog turističkog proizvoda i ključnih tržišta, pa bi u svrhu preciznije analize ukrštene elastičnosti bilo potrebno posebno i detaljnije istraživanje koje bi svakog od konkurenata analiziralo pojedinačno. Isto tako, i varijabla investicija u turizmu i ugostiteljstvu u praksi obuhvaća mnogo širi spektar ulaganja od samo promatranih područja NKD-a, ali je u svrhu pojednostavljenja ovoga modela odabrano samo ono najuže povezano s industrijom. Buduća istraživanja ove tematike u svrhu detaljnije analize utjecaja investicija na turističku potražnju trebala bi uključiti u promatranje i ulaganja poput građevinskih, infrastrukturnih, ulaganja u ljudske potencijale i mnoge druge.

Kao inicijalni pokušaj modeliranja turističke potražnje u Hrvatskoj u recentnom periodu s uključenom varijablom terorizma, ovaj je model svojim rezultatima u konačnici stvorio dobar okvir za praksu, ali i polazište za daljnja empirijska istraživanja ove problematike.

SAŽETAK

Modeliranje i prognoziranje turističke potražnje već je niz godina zastupljena tema brojnih empirijskih istraživanja. Različiti su autori u svojim studijama analizirali turističku potražnju na raznim primjerima receptivnih i emitivnih zemalja. S obzirom da je gospodarstvo Republike Hrvatske okrenuto turizmu te o njemu u velikoj mjeri ovisno, važno je provoditi slične analize turističke potražnje u Hrvatskoj. Rezultati takvih empirijskih istraživanja korisni su za turističke aktere iz prakse poput ugostitelja, turoperatora, prijevoznika i mnogih drugih, ali i za donositelje politika i odluka na višim instancama.

U ovom je radu prikazan dinamički model strane turističke potražnje u Republici Hrvatskoj u periodu od 2005. do 2019. godine. U svrhu procjene modela korištena je generalizirana metoda momenata (GMM) nad panel podacima. Prema saznanjima autorice na temelju proučene relevantne literature, ovaj je model prvi koji analizira utjecaj terorizma u konkurentskim destinacijama na potražnju za turizmom u Republici Hrvatskoj. Također, promatran je recentni period od 2005. do 2019. godine što ga čini najnovijim modelom turističke potražnje u Hrvatskoj.

Svi procijenjeni parametri u skladu su sa teorijskim očekivanjima i statistički značajni pri odgovarajućim razinama signifikantnosti. Rezultati empirijskog istraživanja potvrdili su pozitivan učinak potražnje u prethodnom razdoblju na tekuću potražnju te njezinu značajnost. Potražnja za hrvatskim turističkim proizvodom prema ovom se modelu pokazala dohodovno i cjenovno neelastična. Pozitivan predznak koeficijenta ukrštene elastičnosti potvrdio je da se konkurentske destinacije iz širokog mediteranskog kruga mogu smatrati supstitutima Hrvatskoj kao turističkoj destinaciji. Iz modela također proizlazi zaključak kako prisutnost terorističkih aktivnosti u konkurentskim državama potiče turiste da se preorijentiraju na Hrvatsku kao sigurniju destinaciju. Značajnost investicija u turizmu i ugostiteljstvu na granici je prihvatanja te model sugerira kako turistička potražnja reagira pozitivno, ali ipak slabo na ulaganja na strani turističke ponude.

Ključne riječi: turistička potražnja, modeliranje turističke potražnje, determinante turističke potražnje, panel podaci, generalizirana metoda momenata

SUMMARY

Tourism demand modelling and forecasting has been a topic of numerous empirical researches for many years. Various authors in their studies analysed tourism demand on diverse examples of receptive and emitting countries. Given that the Croatian economy is focused on tourism industry and largely dependent on it, it is important to conduct similar analyses of tourism demand in Croatia. The results of such empirical studies are useful for tourism stakeholders such as caterers, tour operators, carriers and many others, but also for policy makers and decision-makers in higher instances.

This paper presents a dynamic panel data model of foreign tourist demand in Croatia in the period from 2005 to 2019. For the purpose of model estimation, a generalized method of moments (GMM) was applied. According to the author's best knowledge based on the study of relevant literature, this model is the first to analyse the impact of terrorism in competing destinations on tourism demand in Croatia. Also, the period from 2005 to 2019 was observed, which makes it the latest model of tourist demand in Croatia.

All estimated parameters are in line with theoretical expectations and statistically significant at appropriate levels of significance. The results of the empirical research confirmed the positive impact of previous demand on current demand as well as its statistical significance. According to this model, income and price inelasticity of demand for Croatian tourism product is proved. The positive sign of the cross-elasticity coefficient confirmed that competing destinations from the wide Mediterranean circle can be considered as substitutes for Croatia as a tourist destination. The model also concludes that the presence of terrorist activities in competing countries encourage tourists to turn themselves over to Croatia as a safer destination. The statistical significance of investments made by tourism stakeholders is at limit of acceptance and model suggests that tourism demand responds positively but still weakly to investments on tourism supply side.

Keywords: tourism demand, tourism demand modelling, determinants of tourism demand, panel data, generalized method of moments

LITERATURA

Knjige i članci:

1. Aljinović Z., Marasović B. (2012): Matematički modeli u analizi razvoja hrvatskog financijskog tržišta. Ekonomski fakultet u Splitu, Split
2. Araña J.E., León C.J., (2008): The impact of terrorism on tourism demand. *Annals of tourism research*, 35(2), str. 299-315.
3. Arellano M., Bond S. (1991): Some Test of Specification for Panel Data, Monte Carlo Evidence and Application to Employment Equations, *Review of Economic Studies* 58, str. 277–297.
4. Athanasoglou P. P., Brissimis, S. N., Delis M. D. (2008): Bank-specific, industry-specific and macroeconomic determinants of bank profitability, *Journal of International Financial Markets, Institutions and Money* 18(2), str. 121-136.
5. Baldigara T., Mamula M. (2015): Modelling international tourism demand using seasonal ARIMA models. *Tourism and hospitality management*, 21(1), str. 19-31.
6. Brida J. G., Scuderi R. (2013): Determinants of tourist expenditure: A review of microeconometric models, *Tourism Management Perspectives* 6, str. 28-40
7. Cameron A.C., Trivedi P.K. (2010) *Microeconometrics Using Stata*, Revised Edition, A Stata Press Publication, StataCorp LP, College Station, Texas
8. Cerdeira Bento J. P. (2014): The Determinants of International Academic Tourism Demand in Europe. *Tourism Economics*, 20(3), str. 611-628
9. Dogru T., Sirakaya-Turk E., Crouch G. I. (2017): Remodeling international tourism demand: Old theory and new evidence, *Tourism management* 60, str. 47-55
10. Fletcher J., Fyall A., Gilbert D., Wanhill S. (2018): *Tourism principles and practice*, London, Pearson
11. Fourie J., Rosselló-Nadal J., Santana-Gallego M. (2020): Fatal attraction: How security threats hurt tourism, *Journal of Travel Research* 59(2), str. 209-219.
12. Garín-Muñoz T. (2006): Inbound international tourism to Canary Islands: a dynamic panel data model, *Tourism Management* 27, str. 281-291
13. Garín-Muñoz T. (2007): German demand for tourism in Spain, *Tourism Management* 28, str. 12-22

14. Ibrahim M. (2011): The determinants of international tourism demand for Egypt: Panel data evidence. *European Journal of Economics, Finance and Administrative Sciences*, 30(2011), str. 50-58.
15. Kožić I. (2018): Prognoziranje srednjoročnog dosega fizičkog turističkog prometa u Hrvatskoj, *Ekonomski misao i praksa* 2, str. 419-437.
16. Li H., Song H., Li L. (2017): A Dynamic Panel Data Analysis of Climate and Tourism Demand: Additional Evidence. *Journal of Travel Research*, 56(2), str. 158-171
17. Mervar A., Payne J.E. (2007): An analysis of foreign tourism demand for Croatian destinations: long-run elasticity estimates, *Radni materijali EIZ-a*, (1), str. 5-21.
18. Nawaz M. A., Hassan S. (2016): Investment and Tourism: Insights from the literature. *International Journal of Economics Perspectives*, 10(4), str. 581-590.
19. Patsouratis V., Frangouli Z., Anastasopoulos G. (2005): Competition in tourism among the Mediterranean countries. *Applied Economics*, 37(16), str. 1865-1870.
20. Pavić I. (2015): *Mikroekonomija: teorija i praksa*. Sveučilište u Splitu, Ekonomski fakultet, Split
21. Perloff J. M. (2020): *Microeconomics: Theory and applications with calculus*. 5th edn, Pearson, London
22. Rodríguez X.A., Martínez-Roget F., Pawlowska E. (2012): Academic tourism demand in Galicia, Spain. *Tourism Management*, 33(6), str. 1583-1590.
23. Rozga A. (2009): *Statistika za ekonomiste*. Ekonomski fakultet. Split
24. Saha S., Yap G. (2014): The moderation effects of political instability and terrorism on tourism development: A cross-country panel analysis. *Journal of Travel Research*, 53(4), str.509-521.
25. Samitas A., Asteriou D., Polyzos S., Kenourgios D. (2018): Terrorist incidents and tourism demand: Evidence from Greece. *Tourism management perspectives*, 25, str. 23-28.
26. Seetaram N., Forsyth P., Dwyer L. (2016): Measuring price elasticities of demand for outbound tourism using competitiveness indices. *Annals of Tourism Research*, 56, str. 65-79.
27. Song H., Li G. (2008): Tourism demand modelling and forecasting—A review of recent research, *Tourism Management* 29, str. 203-220.
28. Song H., Witt S. F. (2000): *Tourism demand modelling and forecasting: Modern econometric approaches*. Pergamon, Oxford
29. Song H., Witt S. F., Li G. (2009): *The advanced econometrics of tourism demand*. Routledge, New York

30. Surugiu C., Leitão N. C., Surugiu M. R. (2011): A panel data modelling of international tourism demand: Evidences for Romania. *Economic research-Ekonomska istraživanja*, 24(1), str. 134-145.
31. Škrinjarić T. (2011): Istraživanje inozemne turističke potražnje u Hrvatskoj primjenom analize panel podataka, *Acta turistica*, 23(2), str.145-173.
32. Škuflić L., Mlinarić D. (2015): Microeconomic determinants of profitability for Croatian hotel industry. *Ekonomski pregled* 66(5), str. 477-494.
33. Škuflić L., Štoković I. (2011): Demand Function for Croatian Tourist Product: A Panel Data Approach, *Modern Economy* 2(1), str. 49-53.
34. Tavares J. M., Leitão N. C. (2017): The determinants of international tourism demand for Brazil. *Tourism Economics*, 23(4), str. 834–845.
35. Ulucak R., Yücel A.G., İlkey S.Ç. (2020): Dynamics of tourism demand in Turkey: Panel data analysis using gravity model. *Tourism Economics*, 26(8), str. 1394-1414.
36. Wong K. K. F., Song H., Witt S. F., Wu D. C. (2007). Tourism forecasting: To combine or not to combine? *Tourism Management*, 28(4), str. 1068-1078.
37. Zelenika R. (1998): Metodologija i tehnologija izrade znanstvenog i stručnog djela, Ekonomski fakultet, Rijeka

Izvori s Interneta:

1. Calderwood L.U., Soshkin M. (2019): The travel and tourism competitiveness report 2019. World Economic Forum, Geneva, [Internet], dostupno na: <https://www.visionofhumanity.org/wp-content/uploads/2020/11/GTI-2020-web-2.pdf> [15.06.2021.]
2. Institut za turizam (2011): Glavni plan i strategija razvoja turizma Republike Hrvatske. Izvještaj 3. Hrvatski turizam i konkurentsko okruženje, Institut za turizam, Zagreb, [Internet], dostupno na: <https://mint.gov.hr/UserDocsImages/arhiva/Izvjestaj-3-121102-IZT.pdf> [10.06.2021.]
3. Institut za turizam (2020): TOMAS Ljeto 2019 - Stavovi i potrošnja turista u Hrvatskoj, Institut za turizam, Zagreb, [Internet], dostupno na: <http://www.iztztg.hr/files/file/RADOVI/KNJIGE/TOMAS-Hrvatska-2019.pdf> [02.06.2021.]

4. Institute for Economics & Peace (2020): Global Terrorism Index 2020: Measuring the Impact of Terrorism, Sydney, [Internet], dostupno na: <http://visionofhumanity.org/reports> [30.06.2021.]
5. Ministarstvo turizma Republike Hrvatske (2020): Turizam u brojkama 2019., Ministarstvo turizma Republike Hrvatske, Zagreb, [Internet], dostupno na: <https://www.htz.hr/hr-HR/informacije-o-trzistima/analize-s-podrucja-turizma/turizam-u-brojkama> [02.06.2021.]
6. WTTC (2020): Economic Impact Reports. Croatia 2020 Annual research: Key highlights, World Travel & Tourism Council, [Internet], dostupno na: <https://wttc.org/Research/Economic-Impact> [12.04.2021.]

POPIS GRAFIKONA

Grafikon 1. Individualna potražnja za turističkim dobrom	11
Grafikon 2. Efekti supstituta i komplementa na potražnju za turističkim dobrom	13
Grafikon 3. Učinci promjena visine dohotka (Engelove krivulje)	14
Grafikon 4. Dolasci i noćenja turista u RH 2000-2019. (u 000)	16
Grafikon 5. Strani turisti - noćenje i prosječan broj dana boravka po zemljama	17
Grafikon 6. Dob turista: Trend 1987.-2019.	18
Grafikon 7. Izvori informacija o Hrvatskoj kao destinaciji.....	19

POPIS TABLICA

Tablica 1. Motivi dolaska turista	19
Tablica 2. Varijable u modelu turističke potražnje u RH	37
Tablica 3. Deskriptivna statistika	40
Tablica 4. Korelacijska analiza	42
Tablica 5. Rezultati dinamičkog panel modela.....	43