Volatilnost turizma na eksterne šokove

Herman, Suzana

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Tourism and Hospitality Management / Sveučilište u Rijeci, Fakultet za menadžment u turizmu i ugostiteljstvu**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:191:969963

Rights / Prava: Attribution 4.0 International/Imenovanje 4.0 međunarodna

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

SVEUČILIŠTE U RIJECI
FAKULTET ZA MENADŽMENT
U TURIZMU I UGOSTITELJSTVU
OPATIJA, HRVATSKA

Repository / Repozitorij:

Repository of Faculty of Tourism and Hospitality Management - Repository of students works of the Faculty of Tourism and Hospitality Management

UNIRI DIGITALNA KNJIŽNICA

Image not found or type unknown

SVEUČILIŠTE U RIJECI
FAKULTET ZA MENADŽMENT U TURIZMU I UGOSTITELJSTVU

Suzana Herman

VOLATILNOST TURIZMA NA EKSTERNE ŠOKOVE

DOKTORSKA DISERTACIJA

Opatija, 2022.

Suzana Herman 2022. Volatilnost turizma na eksterne šokove

SVEUČILIŠTE U RIJECI
FAKULTET ZA MENADŽMENT U TURIZMU I UGOSTITELJSTVU

Suzana Herman

VOLATILNOST TURIZMA NA EKSTERNE ŠOKOVE

DOKTORSKA DISERTACIJA

Mentor: izv. prof. dr. sc. Daniel Dragičević
Komentor: izv. prof. dr. sc. Vladimir Arčabić

Opatija, 2022.

UNIVERSITY OF RIJEKA
FACULTY OF TOURISM AND HOSPITALITY MANAGEMENT

Suzana Herman

VOLATILITY OF TOURISM TO EXTERNAL SHOCKS

DOCTORAL THESIS

Opatija, 2022.

Mentor rada: izv. prof. dr.sc. Daniel Dragičević
Komentor rada: izv. prof. dr.sc. Vladimir Arčabić

Doktorski rad obranjen je dana 12. listopada, 2022. na Poslijediplomskom sveučilišnom doktorskom studiju „Poslovna ekonomija u turizmu i ugostiteljstvu“ na Fakultetu za menadžment u turizmu i ugostiteljstvu, Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. prof. dr. sc. Josip Tica, Ekonomski fakultet u Zagrebu, predsjednik povjerenstva
2. prof. dr. sc. Marinela Krstinić Nižić, Fakultet za menadžment u turizmu i ugostiteljstvu, članica povjerenstva
3. izv. prof. dr. sc. Maja Nikšić Radić, Fakultet za menadžment u turizmu i ugostiteljstvu, članica povjerenstva

ZAHVALA

Pišući ovu disertaciju, koja je proizvod višegodišnjeg rada, osjećam se dužnom velikom broju osoba koje su me inspirirale, motivirale i podržale tijekom moga studiranja na Fakultetu za menadžment u turizmu i ugostiteljstvu.

Posebno bih se zahvalila svojim mentorima dr. sc. Dragičević Danielu te doc. dr. sc. Arčabić Vladimiru na njihovom angažmanu, akademskom poticaju i velikodušnoj pomoći. Od samog početka izrade doktorske disertacije, čak i vikendom bili su dostupni i spremni saslušati moja pitanja, prijedloge, nedoumice. Osim mentoriranja pri izradi doktorske disertacije, mentori su me naučili strogom znanstvenom pristupu te mi ulili entuzijazam za istraživanje i kritičko razmišljanje. Hvala Vam i sigurna sam da će se naša suradnja nastaviti i nakon mog studentskog staža.

Veliko hvala mojoj obitelji kojoj moj doktorat vjerojatno znači više nego meni samoj. Hvala majci Jadranki i Zdenku na lijepim riječima utjehe kod teških trenutaka, ali isto tako i na svakom osmjehu i riječima hvale kod lijepih trenutaka. Hvala seki Lei na koju sam izuzetno ponosna zbog postignutih dosadašnjih rezultata. Hvala braci Dejanu i Maji koji su također, htjeli – ne htjeli, morali slušati moje žalopojke na tjednoj bazi.

Tajana, hvala ti što si bila moj zdrav razum u trenucima kada sam odustajala! Što si vršila pritisak na mene, provjeravajući koliko sam koji dan napisala... što si vjerovala u mene kad ja nisam.

Hvala mom suprugu Benjaminu, koji je uz mene najviše doživio i proživio pisanje moje disertacije… koji je preispitivao moje odluke kako bih ja bila još više sigurna u njih, koji je vjerovao u mene i koji me nije štedio kada bih naišla na izazove, već upravo suprotno, hrabrio bi me i uvjeravao da ja to mogu. Hvala ti što si se zajedno sa mnom veselio kada je sve išlo po planu i što si bio tu i brisao suze kada su nailazile prepreke.

Želim izraziti i veliku zahvalnost Fakultetu za menadžment u turizmu i ugostiteljstvu na svim statističkim i ekonometrijskim radionicama koje su bile organizirane za doktorande.

Hvala tati koji me čuva odozgo i naposljetku hvala i meni bez koje ovo, realno, ne bi bilo izvedivo. Bravo, Suzana!

SAŽETAK

Globalni međunarodni turizam danas je generator značajnog broja radnih mjesta te ostvaruje velik dio svjetskog dohotka, generira robu i usluge izravno i neizravno, privlači stranu valutu i pruža mogućnost stranih ulaganja. Unazad nekoliko godina bilježi se stalan porast međunarodnoga turizma. Ipak, taj porast djelomično slabi zbog utjecaja raznih eksternih šokova. Volatilnost se prema riječima mnogih autora opisuje kao nepredvidljiva mjera intenziteta varijacija. Navedene varijacije povezuju se s nepredvidivim kriznim situacijama odnosno događajima koji se obično zovu „novi šokovi“, a to mogu biti terorizam, epidemije, prirodne katastrofe, volatilnost tečaja, cijena nafte, politička (ne)stabilnost, ratovi te razne kriminalne aktivnosti. Takva globalna događanja snažno utječu na širok spektar političkih, pravnih i društvenih regulacija diljem svijeta. Taj fenomen mogao bi objasniti kako je turizam vrlo ranjiv u zemljama pogođenim vanjskim ili unutarnjim šokovima. Navedene nezavisne varijable u destinacijama mijenjaju obilježja turizma na razini destinacije, ali i svijeta, na taj način utječući na turističku potražnju, ali nadasve na gospodarsku situaciju zemlje.

Analiza glavnih čimbenika koji utječu na broj dolazaka kao i na broj noćenja turista u odabranim zemljama svijeta te evidentno prevelika ovisnost o turizmu, koji je itekako osjetljiv na eksterne šokove, nije poželjna. Unatoč očitoj ekonomskoj koristi koju donosi, turizam je sklon unutarnjim i vanjskim šokovima koji dovode do pada aktivnosti. Intenzitet i trajanje istih ovisit će o stvarnoj i percipiranoj pripremljenosti pogođenih zemalja te sposobnosti uvjeravanja da su navedene zemlje sigurne destinacije.

Poznavanje čimbenika koji utječu na turističku potražnju nužno je potrebno svim državama, a posebice onima čiji je udio turizma u BDP-u iznimno visok. Takve informacije mogu biti korisne za makroekonomsku analizu i prognozu.

Ciljevi rada istaknuti su kroz sustavno definiranje i kvantificiranje varijabli koje mogu utjecati na turizam današnjice: terorizam, zdravstvena pitanja, prirodne katastrofe, ratovi, politička (ne)stabilnost, volatilnost tečaja, cijena nafte, migracije. Zatim, utvrđivanjem razine volatilnosti turizma na eksterne šokove te ukazivanjem na važnost praćenja pojava koje utječu na volatilnost turizma.

U svrhu dokazivanja postavljenih hipoteza, korištena je i metoda panel analize koja istodobno analizira i vremensku i prostornu komponentu zadanih pojava. Panel podaci umanjuju pristranost parametara koji se pojavljuju zbog nedostataka podataka. Ova metoda omogućava kontrolu varijabli koje se ne mogu mjeriti, odnosno varijabli koje se mijenjaju kroz vrijeme.

Doprinos rada ekonomskim znanostima u teorijskom smislu određuje se u sistematizaciji i teorijskom definiranju turističkih kretanja te eksternih šokova kao što su teroristički napad, prirodne katastrofe, zdravstvena pitanja, politička nestabilnost, volatilnost tečaja, cijena nafte, rat i migracije. Doprinos se također određuje u analizi i sistematizaciji značaja utjecaja eksternih šokova na turizam te afirmaciji i razvoju znanja o važnosti i razumijevanju njihovog međuodnosa. Nadalje, doprinos rada počiva u razvoju i afirmaciji znanstvenih znanja o analiziranju i ocjenjivanju utjecaja eksternih šokova na turizam i turistička kretanja te u razvoju i primjeni ekonometrijskog modela panel analize kojim je u značajnoj mjeri moguće procijeniti osjetljivost turizma na eksterne šokove te pružiti odgovore na istraživačka pitanja. U konačnici znanstveni doprinos predstavlja i kvantifikacija utjecaja eksternih šokova na turizam kao i identifikacija smjera uzročnosti između turizma i eksternih šokova.

Ključne riječi: turizam, eksterni šokovi, ekonometrijsko modeliranje, panel analiza

JEL klasifikacijski kodovi: C50, C51, F63, Z30, Z38

ABSTRACT

The synonym of international tourism in the world is a generator that produces a significant number of jobs and a generator that generates a large part of the world's income, generates goods and services directly and indirectly, attracts foreign currency and provides the possibility of foreign investments. Over the past few years, there has been a steady increase in international tourism, but the reduction of this increase is also due to the impact of various external shocks. Volatility, according to many authors, is described as an unpredictable measure of the intensity of variations. These variations are associated with unpredictable crisis situations, i.e. events commonly called 'new shocks' such as terrorism, epidemics, natural disasters, exchange rate volatility, oil price, political (in)stability, wars and various crimes. Such global events have a profound impact on a wide range of political, legal and social regulations around the world. This phenomenon could explain how tourism is very vulnerable in countries affected by external or internal shocks. These independent variables in destinations change the characteristics of tourism at the level of the destination and the world, thus affecting the tourist demand but above all on the economic situation of the country.

An analysis of the main factors affecting the number of arrivals as well as the number of overnight stays of tourists in selected countries of the world and evidently too much dependence on tourism, which is very sensitive to external shocks, is not desirable. Despite the obvious economic benefits it brings, tourism is prone to internal and external shocks leading to a decline in activity. The intensity and duration will depend on the actual and perceived preparedness of the affected countries and the ability to convince that these countries are safe destinations.

Knowledge of the factors affecting tourist demand is necessarily necessary for all countries, especially those whose share of tourism in GDP is extremely high. Such information may be useful for macroeconomic analysis and forecasting.

The objectives of the work are highlighted through the attitude defined by it and quantifying variables, and which can affect the tourism of today: terrorism, health issues, natural disasters, wars, political (in)stability, exchange rate volatility, oil price, migration. Furthermore, determining the level of volatility of tourism to external shocks and pointing out the importance of monitoring phenomena affecting tourism volatility.

To proving the hypotheses set, a panel analysis method was also used, which simultaneously analyses both the temporal and spatial component of the given phenomena. Panel data reduces the bias of parameters that occur due to data deficiencies. This method allows you to control variables that cannot be measured, that is, variables that change over time.

Contributions of work to economic sciences in theoretical terms are determined in the systematization and theoretical definition of tourist movements and external shocks terrorist attack, natural disasters, health issues, political instability, exchange rate volatility, oil price, war, and migration. The contribution is also determined in the analysis and systematization of the importance of the impact of external shocks on tourism and affirmation and development of knowledge about the importance and understanding of their interrelationship. Furthermore, the contribution of the paper rests in the development and affirmation of scientific knowledge on the analysis and evaluation of the impact of external shocks on tourism and tourism developments, and in the development and development and implementation of the econometric model of panel analysis, which can significantly assess the susceptibility of tourism to external shocks and provide answers to research questions. Ultimately, the scientific contribution is the quantification of the impact of external shocks on tourism as well as the identification of the direction of causation between tourism and external shocks.

Key words: tourism, external shocks, econometric modeling, panel analysis

JEL classification code: C50, C51, F63, Z30, Z38

Sadržaj

ZAHVALA ... iv
SAŽETAK ... v
ABSTRACT ... vii
1. UVOD ... 1
1.1. Problem, predmet i objekti istraživanja ... 1
1.2. Znanstvena hipoteza i pomoćne hipoteze ... 4
1.3. Svrha i ciljevi istraživanja ... 5
1.4. Ocjena dosadašnjih istraživanja ... 6
1.5. Znanstvene metode ... 8
1.6. Kompozicija disertacije ... 9
2. POJMOVNO ODREĐENJE TURIZMA I EKSTERNIH ŠOKOVA ... 11
2.1. Turizam i njegovi oblici ... 11
2.2. Pojmovne odrednice međunarodnoga turizma i turista ... 12
2.3. Teorijske odrednice eksternih šokova ... 21
2.3.1. Terorizam ... 24
2.3.2. Politička nestabilnost ... 27
2.3.3. Rat ... 28
2.3.4. Migracije ... 30
2.3.5. Prirodne katastrofe ... 32
2.3.6. Zdravstvene krize ... 38
2.3.7. Cijena nafte ... 42
2.3.8. Volatilnost tečaja ... 43
3. ULOGA MEĐUNARODNOG TURIZMA U GLOBALNOJ EKONOMIJI ... 45
3.1. Ekonomski učinci turizma na svjetsko gospodarstvo ... 45
3.1.1. Pozitivni ekonomski učinci turizma ... 48
3.1.2. Negativni ekonomski učinci turizma ... 51
3.2. Socio-kulturni učinci turizma ... 52
3.3. Učinci turizma na okoliš ... 54
4. UTJECAJ EKSTERNIH ŠOKOVA NA TURIZAM ... 56
4.1. Terorizam i turizam ... 56
4.2. Politička nestabilnost i turizam ... 60
4.3. Ratovi i turizam ... 64
4.3. Migracije i turizam ... 68
4.4. Prirodne katastrofe i turizam ... 74
4.5. Zdravstvene krize ... 79
4.6. Volatilnost tečaja i turizam ... 83

4.7. Cijena nafte i turizam 86
5. EMPIRIJSKA ANALIZA UTJECAJA EKSTERNIH ŠOKOVA NA TURIZAM 91
5.1. Hipoteza 1: ***Postoji statistički signifikantna razlika u stupnju osjetljivosti turizma na odabrane eksterne šokove*** 99
5.2. Hipoteza 2: ***Kratkoročni i dugoročni efekti šokova na turizam različiti su po tipu eksternih šokova*** 119
5.3. Hipoteza 3: ***Postoji međuovisnost eksternih šokova i turizma*** 124
6. ZAKLJUČCI I SMJERNICE DALJNJIH ISTRAŽIVANJA 127
LITERATURA 132
POPIS TABLICA 189
POPIS SHEMA 190
POPIS GRAFIKONA 191
PRILOG 1 Mapiranje značajnih šokova kroz povijest 192
PRILOG 2 POPIS SVIH ZEMALJA OBUHVAĆENIH ISTRAŽIVANJEM 208
PRILOG 3 UDIO TURIZMA U STRUKTURI BDP-a (podjela skupova I i II) 210
PRILOG 4 ODABIR MODELA ZA CJELOKUPAN UZORAK 212
PRILOG 5 TESTOVI DIJAGNOSTIKE ZA CJELOKUPAN UZORAK 213
PRILOG 6 ODABIR MODELA PREMA SKUPINAMA 214
PRILOG 7 TESTOVI DIJAGNOSTIKE (PREMA SKUPINAMA) 216
PRILOG 8 ODABIR MODELA I TESTOVI DIJAGNOSTIKE (ZA MEDITERANSKE ZEMLJE) 219
PRILOG 9 REZULTATI TESTA JEDINIČNIH KORIJENA (*UNIT ROOT TEST*) 220
PRILOG 10 PANEL VAR odabir redoslijeda vremenskih pomaka unazad na uzroku procjene 223
PRILOG 11 PANEL VAR MODELI REZULTATI 224
PRILOG 12 PROCJENA STABILNOSTI VAR MODELA 226
PRILOG 13 DEKOMPOZICIJA VARIJANCE (FEVD) 227
PRILOG 14 PRIKAZ TERORISTIČKIH NAPADA U ODABRANOM RAZDOBLJU ZA MEDITERANSKE ZEMLJE 228
PRILOG 15 DEFINICIJA PRIRODNIH KATASTROFA 230

1. UVOD

1.1. Problem, predmet i objekti istraživanja

Premda se više desetljeća proučavaju teme koje se odnose na osjetljivost turizma, u teorijskoj primjeni još je uvijek nedovoljno istražena uloga većeg broja eksternih šokova i njihovih posljedica na turizam.

Takvo stanje, odnosno neriješeni znanstveni problem istraživanja implicira mnogobrojne negativne posljedice:

- nedovoljno poznavanje važnih teorijskih značajki vezanih za posljedice koje donosi volatilnost turizma, posebice za zemlje visokoovisne o turizmu,
- površno i nedovoljno znanje o utjecaju rizičnih čimbenika na turizam,
- površno i nedovoljno znanje o utjecaju eksternih čimbenika na turizam rezultira dugoročnim oporavkom zemalja koje ovise o turizmu,
- nepoznavanje i ignoriranje važnih činjenica vezanih uz komplementarne aktivnosti s turizmom znatno usporava gospodarski razvoj u svim zemljama.

Sukladno navedenoj problematici i determiniranome problemu znanstvenog istraživanja, definiran je predmet znanstvenog istraživanja:

- istražiti teorijska uporišta iz perspektive osjetljivosti turizma na eksterne šokove,
- istražiti aktualne probleme koji utječu na volatilnost turizma,
- povezati teorijska i empirijska uporišta te prikazati važnost percipiranja aktualnih problema koji utječu na volatilnost turizma, a posebno zemalja koje su ovisne o turizmu,
- istražiti aktualne teorijske probleme i sustavno formulirati i predočiti rezultate dosadašnjih istraživanja raznih autora o stupnju volatilnosti turizma – utjecaju terorizma, zdravstvene krize, prirodnih katastrofa, političke nestabilnosti, volatilnosti tečaja, financijske krize 2008. godine, ratova, migracija te cijene nafte na turizam.

Turizam kao gospodarska, kulturna i socijalna pojava predstavlja jednu od najznačajnijih aktivnosti suvremenog društva i gospodarskog razvoja u svjetskim razmjerima, a osobito je postala značajna u receptivnim zemljama, odnosno u zemljama u razvoju. Doprinos turizma svjetskom bruto domaćem proizvodu (BDP) već sedmu godinu zaredom nadmašuje rast svjetskog gospodarstva. U 2017. godini doprinosi ostvareni od strane turizma rastu po stopi od 4,6% što je brže od ukupnog svjetskog gospodarskog rasta koji je iznosio 3%. Godine 2017. direktni i indirektni utjecaji turizma u svjetskom BDP-u iznosili su 8,3 bilijuna USD (10,4% svjetskog BDP-a) te ukupno 313 milijuna radnih mjesta (1 od 10 radnih mjesta u svijetu čini

radno mjesto vezano uz turizam). Potrošnja inozemnih turista u 2017. iznosila je 1,5 bilijuna USD što čini 6,5% ukupnoga svjetskog BDP-a. Procjenjuje se da je u turizmu tijekom 2017. investirano ukupno 882 milijarde USD (4,5% ukupnih investicija svijeta). Navedeni podaci ukazuju na činjenicu o značajnom utjecaju turizma na svjetsko gospodarstvo. Gospodarski učinci turizma posebno su značajni za zemlje u razvoju. Dolaskom do navedenih saznanja, ujedno se dolazi do činjenice o prevelikoj ovisnosti o turizmu koji je izuzetno osjetljiv na eksterne šokove. Eksterni šokovi i volatilnost turizma uvelike utječu na ekonomsko stanje zemalja. Prevelik udio deviznog prihoda ostvarenoga od turizma u BDP-u u pojedinim je državama znatno iznad svjetske razine. Činjenica je da turizam i devizni prihod ostvaren od turizma značajno pridonose gospodarskom rastu većini zemalja, posljedično tome i ekonomskoj stabilnosti istih, no isto tako prevelika ovisnost o turizmu može dovesti i do ekonomskog kraha pojedinih zemalja, posebice onih koje se prvenstveno oslanjaju na turizam. Dosadašnja istraživanja ukazuju na činjenicu kako se prosperitet nacionalnih gospodarstava temelji na varijabli visokog rizika iz razloga što je trend njenoga kretanja izrazito podložan eksternim šokovima.

Provedba turizma najvećim dijelom vrši se kroz treći gospodarski sektor, uslužni sektor. Po svojoj prirodi usluge se ne mogu fizički pohraniti, izuzev usluga informacija, dakle potrošač da bi konzumirao uslugu mora biti na mjestu potrošnje, odnosno odredišta. Ako u turističkom odredištu nema gostiju, pružatelji turističkih usluga ne mogu prodavati svoje proizvode, što znači da ako gosti ne putuju, nema potražnje za turističkim proizvodima, odnosno turističkim uslugama. Izostanak turističke potražnje za turističkim proizvodima značio bi da u slučaju u kojem država nema gostiju, nema ni potražnje, dakle nema prodaje i rezultat toga jest nedostatak potrebe za turističkim uslugama koje kao domino efekt utječu na gospodarstvo države, odnosno makroekonomske varijable poput BDP-a, zaposlenost, investicije i slično. Slijed takvih događaja, kao što je drastično smanjenje međunarodne turističke potražnje, smanjenje prihoda ostvarenog od turizma ili smanjenje broja noćenja stranih turista, ostavlja negativan utjecaj na cjelokupni turizam te se kao takav može nazvati krizom. U ekstremnim slučajevima kriza bi mogla ugasiti cijelu turističku aktivnost što bi dovelo do ozbiljnih posljedica za cjelokupno gospodarstvo države, a posebice onih visokoovisnih turističkih zemalja. U određenim državama turizam je otporniji, no u onim slabije razvijenim njegovim narušavanjem utječe se na cjelokupno stanje u zemlji.

Krize koje pogađaju turizam mogu se definirati kao neočekivani događaji koji utječu na turista, odnosno na njegovo povjerenje u destinaciju. Eksterni šokovi kao što su terorizam, zdravstvena kriza, prirodne katastrofe, volatilnost tečaja, cijena nafte, politička nestabilnost, ratovi,

migracije, financijska kriza svakako mogu dovesti zemlju do krize, i to krize ekstremnih razmjera.

Istraživanja raznih autora pokazuju kako već desetljećima traje rasprava o moralnim i političkim pitanjima koja se odnose na definiciju terorizma.
Terorizam nije ni pokret, a nije, kažu, ni filozofija, već alat kojim se želi uplašiti i zastrašiti civilno stanovništvo odnosno izazvati paniku, psihološki strah te nesigurnost koja se zatim kao lavina nekontrolirano širi. Terorizam je unazad nekoliko godina postao gorući problem današnjice. Moguće ga je okarakterizirati kao oblik nezakonitog čina nasilja koji je počinjen s ciljem kako bi se prikupila otkupnina, svrgnula vlada, dobilo oslobođenje zarobljenika, izvršila osveta za stvarna ili zamišljena nedjela ili kako bi se kaznili (ne)vjernici neke religije.

Nadalje, kada su zdravstvena pitanja u središtu istraživanja, literatura pokazuje kako su zdravlje i makroekonomija snažno povezani, jer dobro zdravlje u populaciji poboljšava ekonomske ishode u zemlji, budući da podiže ekonomsku dobrobit kroz višu razinu produktivnosti rada, obrazovanja i ulaganja u demografske promjene. Sva ta pitanja često se promatraju dugoročno, zajedno s poboljšanjem zdravstvene statistike, a u mnogim je slučajevima teško utvrditi pravi uzročni odnos.

Utjecaj prirodnih katastrofa unazad nekoliko godina sve je češći i to se može pripisati klimatskim promjenama diljem svijeta. Prirodne katastrofe za posljedicu uzrokuju da turistička odredišta u potpunosti izgube prirodnu ljepotu i kulturu.
Političke nestabilnosti imaju za posljedicu preusmjerenje turističkih tijekova, dok ih s druge strane stanje prosperiteta i mira pospješuje. Turizam se, izuzev činjenice da predstavlja važan gospodarski čimbenik, također koristi kao potpora ili pritisak u ulozi diplomatskog čimbenika.

Ratovi također imaju velikog utjecaja na turizam zemlje, reflektirajući se negativnim posljedicama na cjelokupno stanje zemlje. Posljedica ratnog stanja neke države je prisilna migracija, odnosno izbjeglištvo. Prisilno iseljavanje stanovništva negativno utječe na percepciju turista na način da turist preispituje svoje odluke o putovanju na odredište rizičnog područja iz razloga što je njegova sigurnost potencijalno ugrožena.

Nadalje, volatilnost tečaja također predstavlja varijablu koja se zbog svoje volatilnosti može negativno reflektirati na turizam odredišne zemlje. Svaka od spomenutih varijabli posljedično

se odražava negativnim učinkom na turistička kretanja, cjelokupno stanje zemlje, iseljavanjem domicilnog stanovništva i mnogo drugih. Turizmu je potrebno 13 mjeseci da se oporavi od terorističkog napada, 21 mjesec oporavka potrebno je u slučaju širenja bolesti, 24 mjeseca u slučaju ekoloških katastrofa te 27 mjeseci nakon političkih previranja i ratova što isto tako potvrđuje potrebu da je temu neophodno izučavati u širem kontekstu.

1.2. Znanstvena hipoteza i pomoćne hipoteze

Kako bi se definirale znanstvene hipoteze disertacije, izvršena je analiza dosadašnjih istraživanja domaćih i stranih autora znanstveno-stručne literature koja su usko vezana uz utjecaj eksternih šokova turističke aktivnosti. Zaključno razmišljanje na temelju pregleda literature jest da je turizam itekako važna i vrlo proučavana tematika. Utjecaj raznih eksternih šokova na turističke aktivnosti proučavane su od strane raznih autora, no ono što je odmah primjetno jest da nije pronađen ni jedan rad koji bi obuhvatio toliki broj nezavisnih varijabli na svjetskoj razini te proučavao njihov utjecaj na turističke aktivnosti. Slijedom navedenog postavljeni znanstveni problem i predmet istraživanja te definirani znanstveni ciljevi impliciraju sljedeće osnovne znanstvene hipoteze:

H1) Postoji statistički signifikantna razlika u stupnju osjetljivosti turizma na odabrane eksterne šokove.

H2) Kratkoročni i dugoročni efekti šokova na turizam različiti su po tipu eksternih šokova.

H3) Postoji međuovisnost eksternih šokova i turizma.

Potpuna nepredvidivost predstavlja zajedničko obilježje eksternih šokova, a isti nastaju pod utjecajem prirodnih zbivanja i katastrofa na što se ne može utjecati, ali i pod utjecajem ljudske aktivnosti što bi se moglo spriječiti. Dosadašnja istraživanja raznih autora što međunarodnih, što domaćih testirala su pojedinačno na primjer utjecaj terorizma na turizam, utjecaj političke nestabilnosti na turizam i slično, no vrlo je malen broj radova odnosno autora koji istražuju negativan utjecaj eksternih šokova na turizam u kontekstu više postavljenih nezavisnih varijabli na svjetskoj razini. Eksterni šokovi koji će u ovom radu biti obuhvaćeni su terorizam, zdravstvene krize, prirodne katastrofe, politička nestabilnost, volatilnost tečaja, cijena nafte, migracije, ratovi.

Hipoteza 1 ima za pretpostavku da će rezultati svih nezavisnih varijabli prikazivati statistički različite vrijednosti. Dakle, osam nezavisnih varijabli čiji će se utjecaj na turističke aktivnosti

proučavati prikazivat će različite rezultate, odnosno dobiveni rezultati varirat će ovisno o razini ovisnosti pojedine zemlje o turizmu.

Hipoteza 2 ima za pretpostavku da će eksterni šokovi odnosno nezavisne varijable imati različit utjecaj i posljedice u kratkom i dugom roku pa samim time i oporavak od istih traje duže ili kraće.

Hipoteza 3 postavljena je iz razloga što se kroz istraživanje i upotrebu postavljenih znanstvenih metoda želi utvrditi veza i smjer utjecaja eksternih šokova na turizam.

Ovom hipotezom želi se prikazati i dokazati negativan utjecaj više eksternih šokova na turizam pritom promatrajući svjetsku razinu. Pretpostavka je da bilo kakva nestabilnost zemlje (bilo da je uzrokovana terorizmom, zdravstvenom krizom, klimatskim promjenama i sl.) ostavlja posljedice na međunarodna turistička kretanja i prihod ostvaren od turizma. Eksterni šokovi imaju izravan utjecaj na trendove na strani turističke potražnje i na strani turističke ponude. Turizam zbog svog interdisciplinarnog karaktera i prostorne odvojenosti turističke potražnje od turističke ponude iskazuje visok stupanj volatilnosti na sve vrste promjena s kojima se svijet suočava u proteklom desetljeću, premda je takvih nepredvidivih događaja bilo i u prijašnjim razdobljima.

1.3. Svrha i ciljevi istraživanja

Turizam kao jedna od najbrže rastućih aktivnosti današnjice predstavlja iznimno značajan doprinos gospodarskom rastu svake zemlje. Razvijene zemlje pogođene npr. epidemijom, terorističkim napadom ili bilo kojim od zadanih eksternih šokova posljedice evidentiraju u kratkoročnom periodu odnosno u periodu u kojem traje oporavak. Dugoročno gledano, u razvijenim zemljama posljedice nisu toliko značajne, odnosno one su vidljive, no sanacija istih traje puno kraće nego što je slučaj kod zemalja u razvoju. Problem se pojavljuje u zemljama u razvoju koje u većem postotku ovise o prihodu ostvarenom od turizma, odnosno u situacijama kada devizni prihod ostvaren od turizma čini značajan udio u BDP-u te zemlje. Razlog za zabrinutost predstavlja upravo volatilnost turizma na eksterne šokove kao što su terorizam, politička nestabilnost, rat, migracije, zdravstvene krize, prirodne katastrofe, volatilnost tečaja, cijena nafte. Oporavak slabije razvijenih zemalja traje mnogo duže i posljedice su znatno veće nego što je slučaj s razvijenim zemljama, posebice kod zemalja koje su ovisne o turizmu. Svake godine sve su češći slučajevi kao što su neočekivana prirodna katastrofa, epidemija ili obračuni političkih razmjera koji dovode do terorizma. Zemlje pogođene nekim od eksternih šokova

osim u nižoj stopi rasta BDP-a posljedice evidentiraju i pri stopi zaposlenosti koja drastično pada. Također, posljedice negativnih učinaka odražavaju se i na investicije, točnije direktne strane investicije koje u visokorizičnim zemljama drastično padaju ili ih gotovo i nema. Razlog svemu navedenom jest visoka rizičnost pogođenih zemalja te percepcija koju strani turisti ostvaruju o pogođenoj destinaciji i to najčešće u vidu nesigurnosti koja je posljedica utjecaja eksternih šokova. Da ovisnost isključivo o turizmu nije poželjna, dokazuju mnogobrojna istraživanja raznih autora koji su istraživali osjetljivost turizma s obzirom na određenu zadanu varijablu. Doprinos ovog rada je sveobuhvatna i istovremena analiza velikog broja eksternih šokova i njihovog utjecaja na turizam, dok su u literaturi eksterni šokovi dominantno promatrani zasebno. Izravno, i u najužoj vezi s postavljenim znanstvenim problemom istraživanja, znanstvenim predmetom istraživanja i postavljenim znanstvenim hipotezama definirani su svrha i ciljevi istraživanja.

Znanstveni ciljevi rada su:

- sustavno definirati i kvantificirati varijable koje mogu utjecati na turizam današnjice: terorizam, zdravstvena pitanja, prirodne katastrofe, ratovi, politička (ne)stabilnost, volatilnost tečaja, cijena nafte, migracije
- utvrditi stupanj volatilnost turizma na eksterne šokove.

U nastavku se navode aplikativni ciljevi rada koji će se bazirati na definiranje zavisnih i nezavisnih varijabli postavljenih u radu:

- ukazati na važnost praćenja pojava koje utječu na volatilnost turizma
- nositeljima ekonomske politike pružiti prijedlog definiranja strategije za ublažavanje posljedica izazvanih utjecajem eksternih šokova na turizam.

1.4. Ocjena dosadašnjih istraživanja

Dugoročni i kratkoročni utjecaji terorizma na međunarodnu turističku potražnju znatno se razlikuju. Dok jedni autori tvrde kako je kratkoročan utjecaj na međunarodni turizam elastičan na terorizam, drugi pak navode kako kratkoročni utjecaji bilježe značajan utjecaj na turističku potražnju, dok dugoročni utjecaji ne pokazuju utjecaje na turistička kretanja. Utjecaj terorizma ostavlja drugačije posljedice u svakoj od pogođenih zemalja, oviseći pritom o njihovoj političkoj (ne)stabilnosti, razini dohotka i stupnju turističke razvijenosti. Veličina događaja, frekventnost ljudi, vrijeme napada i vrsta napada utječu na percepciju rizika u očima turista.

Takvi događaji utječu na percepciju turizma te odvlače ljude od putovanja u visokorizične destinacije. Međunarodna turistička potražnja reagira različito u zemljama koje su bile obuhvaćene terorističkim napadima ili npr. epidemijom u odnosu na destinacije koje su bile pogođene i napadima i epidemijom. Pandemija gripe koja je zahvatila svijet 2009./2010. imala je utjecaj na potražnju za turizmom, što je vidljivo u promjenama ostvarenih noćenja. Bolesti i krize općenito predstavljaju opasnost i veliki rizik. Krizne situacije povezane sa zdravljem utječu na percepciju turista što rezultira značajnim padom turističke potražnje sa značajnim socioekonomskim posljedicama, osobito u zemljama koje ovise o turizmu. Važnost ekonomskih učinaka turizma prepoznata je u većini zemalja, posebice onih otočnih, no postavlja se pitanje negativnog efekta ako se zemlja previše oslanja na turizam kao sredstvo gospodarskog razvoja. Preveliko oslanjanje na turizam umjereno utječe na odnos između razvoja turizma i gospodarskog razvoja. Kada je u pitanju volatilnost tečaja, autori istraživanja navode kako približni učinci volatilnosti cijena obično budu različiti, pri čemu tečaj obično ima očekivani negativan utjecaj na dolaske turista, dok volatilnost tečaja može imati pozitivne ili negativne učinke na dolaske turista. Pojedina istraživanja ističu osjetljivost mlađe populacije na promjene tečaja kao i važnost realnoga efektivnog tečaja na povećanje tržišne konkurentnosti i snažnoga utjecaja domicilnih šokova na ulazne tokove turizma u odnosu na vanjske šokove. Otkrivaju se varijacije u djelotvornosti različitih vrsta političkih intervencija. Autori navode kako su mjere ekonomske politike odraz nedorečene politike razvoja turizma. Promatrajući na primjer Indoneziju odnosno njezinu podložnost prirodnim katastrofama uzrokovanim klimatskim promjenama, može se zaključiti kako većina turista razumije posljedice i ozbiljnost prirodnih katastrofa uzrokovanih klimatskim promjenama. S obzirom na velik broj učestalih eksternih šokova koji su unazad dva desetljeća pogodili Tajland, valja istaknuti kako je značajan negativan utjecaj na turističku potražnju u toj zemlji evidentiran zbog posljedica azijske financijske krize, posljedica napada 11. rujna, SARS-a i epidemije ptičje gripe. Eksterni šokovi itekako imaju velik utjecaj na međunarodnu turističku potražnju. Dužina posljedica (kratkoročno ili dugoročno) ovisi o brzini povratka zemlje u ravnotežu. Utjecaj političke nestabilnosti na turizam pokazuje dvojako razmišljanje i percepciju od strane turista. Dio turista će unatoč političkoj nestabilnosti odlučiti otići na putovanje isključivo zbog toga što je negativna promidžba utjecala na drastičan pad cijena turističkih proizvoda, dok se drugi dio turista ne odlučuje na putovanje isključivo zbog vlastite sigurnosti bez obzira na niske cijene. Unutarnji sukobi, nemiri i ratovi uvelike utječu na turizam zemlje i imaju produženo djelovanje s negativnim posljedicama na cjelokupno stanje zemlje. Npr. Zaljevski rat drastično je smanjio turistička kretanja ne samo na području ratnih djelovanja već i u široj regiji Bliskog i Srednjeg

istoka, dok su se nemiri u Albaniji odrazili na turizam grčkog otoka Krfa. U dugom roku, odnos između političke nestabilnosti i turizma pokazuje negativnu konotaciju. Šokovi na tržištu cijene nafte istodobno utječu na inflaciju i indeks udjela u turističkom sektoru. Agregatna potražnja cijene nafte ima izravni ili neizravni učinak na prihode od turizma i gospodarski rast. Učinci viših cijena nafte globalno pokazuju relativno štetan utjecaj za turistički sektor Novog Zelanda iako su negativni učinci u cjelini bili manje izraženi. Mnogi su autori analizirali utjecaje pojedinih eksternih varijabli na turizam, odnosno istraživanja su se fokusirala većinom na jednu varijablu i njen utjecaj na turizam koristeći pritom raznolike metode, analize, periode i države. Malen broj dosadašnjih istraživanja odnosi se na veći obuhvat eksternih šokova (dvije do tri nezavisne varijable) koji svojom pojavom negativno utječu na turizam.

1.5. Znanstvene metode

Istraživanje rada disertacije temeljeno je na prikupljenim sekundarnim podacima domaće i strane znanstveno-stručne literature. U znanstvenom istraživanju, formuliranju i prezentiranju rezultata istraživanja doktorske disertacije korištene su znanstvene metode uobičajene za ovakvu vrstu znanstvenoga rada i to prije svega: induktivna i deduktivna metoda, metoda analize i sinteze, metoda apstrakcije i konkretizacije, metoda generalizacije i specijalizacije, metoda dokazivanja i opovrgavanja, komparativna metoda, metoda klasifikacije, statistička i matematička metoda. Za istraživanje literature koja je usko vezana uz problem znanstvenoga istraživanja koristila se znanstvena metoda zvana metoda istraživanja za stolom (eng. „desk research method“). Navedena metoda podrazumijeva sveukupnu analizu postojeće pisane građe o fenomenu koji se proučava, odnosno pregled postojeće literature vezane uz zadanu temu. Uz navedene, a u svrhu dokazivanja postavljenih hipoteza, korištena je i metoda panel analize koja istodobno analizira i vremensku i prostornu komponentu zadanih pojava. Panel podaci umanjuju pristranost parametara koji se pojavljuju zbog nedostataka podataka. Ova metoda omogućava kontrolu varijabli koje se ne mogu mjeriti, odnosno varijabli koje se mijenjaju kroz vrijeme. Mogućnost testiranja zahtjevnijih i kompliciranijih ekonometrijskih modela te ublažavanje problema multikolinearnosti predstavljaju prednosti provedbe panel analize. Podaci unutar panel analize moraju imati zajednička svojstva, odnosno moraju biti homogeni kako bi rezultati biti relevantni. U svrhu procjene kratkoročnih efekata primijenit će se Panel VAR (eng. Panel vector autoregression) koji je nastao kao alternativa modelima multivarijantnih simultanih jednadžbi. Doktorsko istraživanje bazira se na prikupljenim

sekundarnim podacima, koji su prikupljeni od raznih međunarodnih institucija, a obrađivani su pomoću opisanih metoda. Sekundarni podaci prikupljeni su od međunarodnih institucija kao što su World Bank, World Tourism Organization, World Travel and Tourism Council, NUMBEO – Cost of living, WITS – World Integrated Trade Solution, Global Financial Data, International Energy Agency, ENERDATA – Global Energy Statistical Yearbook, JodiGas, World Health Organization, Global Terrorism Database, United Nations Office for Disaster Risk Reduction, EM-DAT The International Disaster Database, Our World in Data, Munich RE, Safe Around Worldwide Governance Indicators, The Global Economy, The Correlates of War Project, STATISTA, OECD DATA, Eurostat. Korišteni su podaci o međunarodnim turističkim kretanjima, ostvarenom prihodu od turizma, broju ostvarenih noćenja stranih turista, podaci o kretanju tečaja, terorističkim napadima, prirodnim katastrofama, zdravstvenim krizama, cijeni nafte, ratovima, migracijama te financijskoj krizi 2008. godine.

1.6. Kompozicija disertacije

Doktorska disertacija strukturirana je kroz sedam međusobno povezanih tematskih poglavlja.

Prvo poglavlje naslova *Uvod* definira problem, predmet i objekte istraživanja, postavlja znanstvene hipoteze, određuje svrhu i ciljeve istraživanja. U istom poglavlju ocijenjeni su rezultati prethodnih istraživanja tematike doktorske disertacije te navedene i opisane najvažnije znanstvene metode korištene u znanstvenom istraživanju i prezentiranju rezultata istraživanja. Uvodno poglavlje završava obrazloženjem strukture rada.

Pojmovno određenje turizma i eksternih šokova (i volatilnosti) naslov je drugoga poglavlja. U ovom poglavlju pojmovno je određen turizam, eksterni šokovi i volatilnost. Navedene odrednice sustavno su sistematizirane te je znanstveno utemeljeno propitan njihov međuodnos.

Važnost međunarodnoga turizma u sustavu globalne ekonomije propitana je u trećem poglavlju koje nosi naslov *Uloga međunarodnoga turizma u globalnoj ekonomiji.* Pozitivni i negativni učinci turizma navedeni su s ekonomskog, socio-kulturnog i ekološkog aspekta.

Utjecaj eksternih šokova na turizam naslov je četvrtog poglavlja. Ovo poglavlje daje detaljan pregled literature o postavljenim nezavisnim varijablama u radu. Kritički se analiziraju i sustavno prikazuju korišteni modeli i rezultati istraživanja stranih i domaćih autora, a vezanih uz volatilnost turizma na eksterne šokove.

Empirijska analiza utjecaja eksternih šokova na turizam naslov je petog poglavlja. U ovom poglavlju obrađeni su prikupljeni empirijski (sekundarni) podaci primjenom ekonometrijskoga modela panel analize i panel VAR-a. Panel analiza jest ekonometrijski model koji obuhvaća vremenske i prostorne komponente, te je ujedno temeljni cilj poglavlja. Putem tabličnog prikaza navode se i objašnjavaju zavisne i nezavisne varijable, kreira se ekonometrijski model te se provode analize s dostupnim podacima svih zemalja u svijetu. Spomenuta panel analiza provodi se s ciljem testiranja postavljenih hipoteza i utvrđivanja utjecaja eksternih šokova na turizam.

Posljednje poglavlje *Zaključak* na sažeti način prezentira najvažnije rezultate provedenoga istraživanja. Uz obrazloženja o dokazanim znanstvenim hipotezama naglašava se znanstveni i aplikativni doprinos rada kao i ograničenja istraživanja te preporuke nositeljima ekonomske politike.

2. POJMOVNO ODREĐENJE TURIZMA I EKSTERNIH ŠOKOVA

Na petom kongresu AIEST (franc. Association internationale des experts scientifiques du tourisme – AIEST) održanom 1954. godine prihvaćena je definicija turizama koju su napisali švicarski znanstvenici Hunziker i Krapf (1942, str. 10), a ona glasi: „*Turizam je skup odnosa i pojava koje proizlaze iz putovanja i boravka posjetitelja nekog mjesta, ako se tim boravkom ne zasniva stalno prebivalište i ako s takvim boravkom nije povezana nikakva njihova gospodarska djelatnost.*“

Nastavno na navedenu definiciju valja napomenuti kako terminološki turizam ne predstavlja industriju kako navodi nekolicina autora u svojim radovima. Turizam je živi organizam koji vertikalno i horizontalno veže druge industrije odnosno manifestira se kroz niz drugih djelatnosti te je sastavnica različitih gospodarskih grana, no ne predstavlja industriju, gospodarsku granu niti djelatnost. Istraživanja pokazuju kako je turistička potrošnja veća u kontinentalnim nego u obalnim dijelovima, a razlog navedenom jest konzumacija raznih sadržaja tijekom cijelog dana. Za primjer se može uzeti Austrija koja ne posjeduje obalu unutar svojih granica, a koju posjete milijuni turista godišnje. Turisti pritom generiraju turističku potrošnju te time povećavaju prihod ostvaren od turizma. Gospodarstvenici koji nisu direktno vezani uz turizam ostvaruju prihode koje će trošiti na raznorazne aktivnosti zahvaljujući posjetima, odnosno potrošnji turista, što bi značilo da ostvarena dobit ostaje unutar Austrije.

Postoji niz način na koji se turizam može definirati, pa je iz tog razloga Svjetska turistička organizacija Ujedinjenih naroda (United Nations World Tourism Organization – UNWTO) u razdoblju od 2005. do 2007. godine započela rječnik pojmova vezanih uz turizam. UNWTO (2008) turizam definira kao društveni, kulturni i gospodarski fenomen koji podrazumijeva kretanje ljudi u zemlje ili mjesta izvan njihovog uobičajenog okruženja u osobne ili poslovne/profesionalne svrhe. Ti se ljudi nazivaju posjetiteljima (koji mogu biti ili turisti ili izletnici; stanovnici ili nerezidenti) i turizam ima veze s njihovim aktivnostima, od kojih neke uključuju i troškove turizma.

2.1. Turizam i njegovi oblici

Oblici turizma predstavljaju način provođenja turizma ovisno o uzrocima i vanjskim utjecajima, a moguće je razlikovati nekoliko oblika koji se temelje na sljedećim kriterijima: (Tureac i Turtureanu, 2010; International Recommendations of Tourism Statistics, 2008, str. 15)

- „Domaći turizam (engl. Domestic Tourism) obuhvaća aktivnosti rezidencijalnog posjetitelja unutar referentne zemlje, bilo kao dio domaćeg turističkog putovanja bilo kao dio odlaznog turističkog putovanja.
- Ulazni (receptivni) turizam (engl. Inbound Tourism) obuhvaća aktivnosti nerezidentnog posjetitelja u referentnoj zemlji na ulaznom turističkom putovanju.
- Izlazni (emitivni) turizam (engl. Outbound Tourism) obuhvaća aktivnosti rezidencijalnog posjetitelja izvan referentne zemlje, bilo kao dio izlaznog turističkog putovanja bilo kao dio domaćeg turističkog putovanja.“

Navedena tri oblika turizma mogu se kombinirati na različite načine kako bi se dobili drugi oblici turizma (International Recommendations of Tourism Statistics, 2008, str., 15):

- „Unutrašnji (interni) turizam (eng. Internal tourism) obuhvaća domaći turizam i ulazni turizam, odnosno aktivnosti rezidentnih i nerezidentnih posjetitelja unutar referentne zemlje kao dio domaćih ili međunarodnih turističkih putovanja.
- Nacionalni turizam (eng. National tourism) obuhvaća domaći turizam i izlazni turizam, to jest aktivnosti rezidentnih posjetitelja unutar i izvan referentne zemlje, bilo u sklopu domaćih bilo izlaznih turističkih putovanja.
- Međunarodni turizam (eng. International tourism) obuhvaća ulazni turizam i izlazni turizam, odnosno aktivnosti rezidentnih posjetitelja izvan referentne zemlje, bilo u sklopu domaćih bilo odlaznih turističkih putovanja, i aktivnosti nerezidentnih posjetitelja u zemlji referentne zemlje na ulaznim turističkim putovanjima.“

Međunarodni turizam, točnije dolasci međunarodnih turističkih kretanja, prihod ostvaren od turizma i ostvarena noćenja kao što je već spomenuto predstavljaju zavisne varijable unutar empirijskog dijela istraživanja disertacije, stoga se u narednom potpoglavlju opširnije opisuju pojmovne odrednice međunarodnog turizma.

2.2. Pojmovne odrednice međunarodnoga turizma i turista

Međunarodne posjetitelje karakterizira glavna svrha njihova putovanja, koja je definirana kao svrha u nedostatku koje se putovanje ne bi dogodilo, dok međunarodne putnike karakterizira razlog zbog kojeg su isključeni iz kategorije posjetitelja:

a) ako su u vezi poslodavac – zaposlenik (granična, sezonska i drugi kratkotrajni radnici)

b) u uobičajenom okruženju (sve ostale situacije) (International Recommendations of Tourism Statistics, 2008, str. 15)

Razlozi zbog kojih ljudi žele putovati raznoliki su i složeni. Iskustvo i doživljaji koji se dožive tijekom turističkog putovanja komponente su koje pozitivno utječu na snažan rast turističke potražnje unazad nekoliko godina. Povećani interes za turističku potražnju usko je vezan uz povećanje turističke ponude i kreiranje novih turističkih proizvoda.

Prema podacima UNWTO-a (2009) rast turističkih dolazaka u rekordnom broju od 25 milijuna s ostvarenih 2 milijarde dolara prihoda evidentiran je već rane 1950. godine. Masovno kretanje turista svoje početke evidentira još i ranije, točnije negdje od 1900. godine kada je samo društveni sloj veće platežne moći bio u mogućnosti koristiti privilegije putovanja. „Prve međudržavne organizacije političkog i socijalnog karaktera javljaju se na pragu 20. stoljeća, a one su redom Liga naroda i Međunarodna organizacija rada, utemeljene 1919. godine, te Međunarodno udruženje za socijalnu sigurnost 1927. godine." (Bartoluci, Čavlek, Kesar i Prebežac, 2011, str. 109)

Vijeće Lige naroda 1950. godine preporučuje definiciju međunarodnog turista, a razlog navedenom bio je prvenstveno statističke prirode. Tri godine nakon Statistička komisija Ujedinjenih naroda donosi definiciju pojma „međunarodni posjetitelj" te „međunarodni turizam". Prema podacima Međunarodnih preporuka za statistiku turizma (2008, str. 2) međunarodni turizam definiran je kao „aktivnost koja obuhvaća ulazni i izlazni turizam, odnosno aktivnosti rezidencijalnih posjetitelja izvan referentne zemlje bilo u sklopu domaćih ili odlaznih turističkih putovanja i aktivnosti nerezidentnih posjetitelja u zemlji referentne zemlje na ulaznim turističkim putovanjima".

Nadalje, „međunarodne posjetitelje" karakterizira glavna svrha njihova putovanja koja je definirana kao svrha u nedostatku koje se putovanje ne bi odvijalo, dok ostale međunarodne putnike karakterizira razlog zbog kojeg su isključeni iz kategorije posjetitelja, a to su:

(a) ako su u odnosu poslodavac – zaposlenik (granični, sezonski i drugi kratkoročni radnici)
(b) da su unutar uobičajenog okruženja
(c) pojedinci koji mijenjaju svoju zemlju prebivališta.

Međunarodni putnik smatra se međunarodnim posjetiteljem s obzirom na referentnu zemlju ako je:

(a) na turističkom putovanju i
(b) nerezident koji putuje u referentnu zemlju ili rezident koji putuje izvan nje.

Također, međunarodni putnik koji dolazi na granicu definira se kroz dvije moguće kategorije:

(a) onu međunarodnih posjetitelja (povratak odlaznih posjetitelja u slučaju stanovnika ili dolazaka u slučaju nerezidenta) i

(b) drugih međunarodnih putnika koji nisu uključeni u turizam (Međunarodne preporuke za statistiku turizma, 2008, str. 16).

Potražnja za međunarodnim turizmom oduvijek je signifikantna, prvenstveno promatrajući s ekonomskog aspekata, a razlog navedenom jest činjenica kako spomenuti oblik turizma igra važnu ulogu u trgovini i novčanim tokovima između receptivnog i emitivnog turističkog tržišta. Domaći i međunarodni turizam međusobno su isprepleteni te utječu jedan na drugog. Izbor turističke destinacije turista mijenja se ovisno o okolnostima, te domaći turizam može biti zamijenjen međunarodnim turizmom i obrnuto pod uplivom vanjskih čimbenika kao što su relativan rast realnog dohotka, razlika u cijenama između zemalja i međunarodne političke okolnosti. Unazad nekoliko desetljeća, u mnogim je zapadnim zemljama tradicija „domaćeg godišnjeg odmora“ zamijenjena odlaznim odmorom, pod utjecajem rasta životnog standarda i prihoda, dok su tranzicijske zemlje naglo povećale kretanje unutar države odnosno domaći turizam (WTO, 1995b, str. 34).

Izraz „turist“ prvi je put upotrijebljen u istraživanju Stendhala (1838) u „Mémoires d’un touriste” (Maccabe, 2009). Najranije definicije turiste definiraju kao „ljude koji su na privremenim putovanjima daleko od svoje kuće te koji troše novac zarađen u rezidentnom području, ne u području koje posjećuju“ (Ogilvie, 1933; Shaw i Williams, 1994).

Vijeće Lige naroda 1937. godine turista definira kao „svaku osobu koja putuje u periodu od 24 sata i duže, u zemlju koja nije njegova rezidentna zemlja“.

U svjetlu navedene definicije osoba se može smatrati turistom ako:

- putuje kako bi zadovoljila svoje potrebe odnosno iz zadovoljstva, zdravlja i slično
- putuje zbog sastanka ili bilo kakve misije (znanstvena, administrativna, religiozna)
- putuje u poslovne svrhe
- putuje kruzerom u neku destinaciju iako u njoj ostaje manje od 24 sata.

Navedena definicija također definira i kategorizira tko sve ne ulazi u kategoriju turista:

- osoba koja stiže s ili bez ugovora o radu, a koja će se zaposliti ili se baviti bilo kojom poslovnom aktivnošću u zemlji

- osoba koja dolazi osnovati stalno prebivalište u nekoj zemlji
- učenici, studenti i mladi u internatu, ustanovi ili školi
- stanovnici pograničnog područja i osobe s prebivalištem u jednoj državi, a rade u susjednoj zemlji
- putnici koji prolaze kroz neku zemlju bez zaustavljanja ili čak i ako je zaustavljanje duže od 24 sata. Agarwal i Upadhyay, 2006, str. 10)

Godine 1967. Statistička komisija Ujedinjenih naroda (engl. United Nations Statistics Division – UNSTAT) predlaže razlikovanje između posjetitelja i turista ovisno o noćenju (Smith, 1989.). Godinu dana nakon toga Međunarodna unija službenih putničkih agencija definira posjetitelja na sljedeći način: „Posjetitelj se definira kao osoba koja putuje u zemlju koja mu nije rezidentna iz bilo kojeg razloga osim onoga koji je povezan s ostvarivanjem lukrativne djelatnosti.“ (Candela i Figini, 2012, str. 26) Prema navedenoj definiciji posjetitelj je svatko onaj tko putuje u skladu s nekim motivom. Svjetska turistička organizacija sugerira da se međunarodne posjetitelje definira kao pojedince koji ulaze u zemlju koja nije njihova rezidentna zemlja. U navedenu definiciju ne ulaze migranti, ljude koji traže posao, diplomati, izbjeglice, nomadi, granični radnici ili radnici koji su odsutni više od godinu dana (UNWTO, 1976).

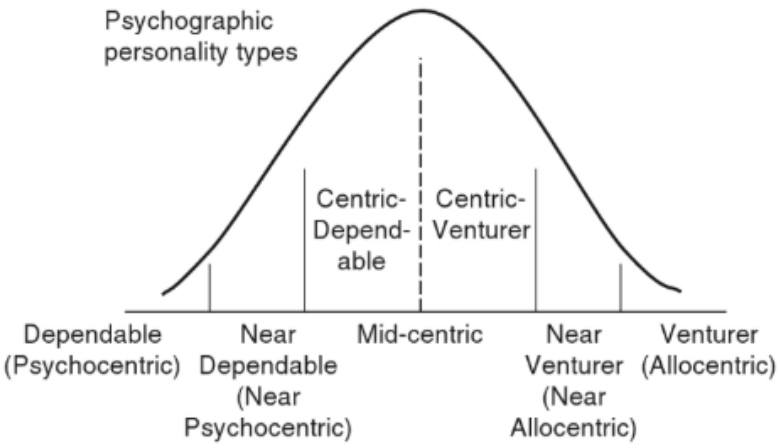
Svrha putovanja razvijena je na način da uključuje rekreaciju, liječenje, putovanja motivirana vjerskim, obiteljskim ili sportskim razlozima, konferencije, studij ili tranzit u drugu zemlju. Turisti se stoga prema Smithu (1989) definiraju kao posjetitelji koji ostvaruju noćenje, što isključuje izletnike koji unutar turističke destinacije borave do 24 sata bez ostvarivanja noćenja.

Različiti profili turista teže zadovoljenju različitih potreba unutar turističke destinacije koju posjećuju. Turističke tipologije opis su karakterističnih oblika ponašanja turističkih potrošača. Reflektiraju različite motivacije, interese i stilove putovanja od strane turista. Većina tipologija u literaturi pokušava grupirati turiste prema njihovim željama u smislu destinacija, aktivnosti tijekom odmora, samostalnih putovanja u odnosu na paket-aranžmane.

Tipologija turista u različite segmente pomoći će razumjeti i identificirati određeno ponašanje, određene karakteristike te vrste iskustava za kojima teže (Wickens, 2002). Tipologija turista od velikog je interesa i za turističke destinacije receptivnog karaktera koje žele privući određeni profil turista (Uriely, 2009). Scott, Laws i Boksberger (2009) navode kako uspostavljanje različitih vrsta turista pomaže u razumijevanju kakva im se turistička iskustva mogu ponuditi.

Povećanje broja i specifičnosti tipologija započelo je krajem Drugog svjetskog rata kao rezultat primjene znanosti u turizmu. Plog (1964) je klasificirao turiste prema destinaciji koju preferiraju. Ustvrdio je da postoji kontinuitet između vrsta turista od alocentričnog do psihocentričnog (shema 1.). „Alocentrični turisti traže nove destinacije i spremni su riskirati u potrazi za novim kulturama i mjestima. S druge strane, psihocentrični turisti traže poznate destinacije i sretniji su kada su okruženi turistima koji isto razmišljaju“ (Woodside i Martin, 2008, str. 23).

Shema 1 Alocentrična i psihocentrična distribucija



Izvor: Woodside i Martin, (2008)

Tijekom 1970-ih tipologija zasnovana na dobi i ekonomiji klasificirana je od strane Cohena (1979). Ova tipologija razlikuje dvije ne-institucionalizirane vrste (organizirani masovni turisti ili individualni masovni turisti) i dvije ne-institucionalizirane uloge (bjegunci i istraživači) (Williams, 2004, str. 176 – 177).

- Organizirani masovni turisti: najmanje su avanturistički turisti. Pri kupnji svog paketnog odmora ostaju zatvoreni u „balon okruženja“, unutar kojeg su udaljeni od zajednice domaćina jer ostaju prvenstveno u hotelskim kompleksima. Striktno se pridržavaju plana svog putovanja koji je određen od strane putničke agencije, pa čak i njihova putovanja izvan kompleksa zapravo su organizirana putovanja. Oni donose malo odluka tijekom svog odmora.

Turističko putovanje može biti planirano ili od strane turističke agencije ili od strane samog turista (Holden i Fannell, 2012, str. 69).

Kulturni turizam na primjer u većini slučajeva omogućava turističkog vodiča i uključuje brojne turiste koji dolaze zajedno sa strogim planom puta u pogledu mjesta susreta, prijevoza do lokacije i slično (Mowforth i Munt, 2015).

- Individualni masovni turisti: imaju dosta sličnosti s masovno organiziranim turistima prvenstveno zato što koriste sadržaje koje im omogućuje turoperator, ali imaju određenu kontrolu nad svojim planovima. Hotel koriste kao bazu, a najčešće unajme automobil za vlastita putovanja. Mnogi individualni masovni turisti će kao i organizirani masovni turisti posjetiti ista mjesta i znamenitosti.

Poneke karakteristike organiziranog masovnog turista slažu se s karakteristikama individualnog masovnog turista, međutim slično će se iskustvo razlikovati za istraživače, jer vjerojatno neće slijediti ili planirati unaprijed kao i drugi turisti. Oni više vole spontana i autentična iskustva koja se ne mogu uvijek pružiti od strane turističkih vodiča (Novelli, 2005, str. 3).

- Istraživač: samostalno organizira svoje putovanje i pokušava sići s utabane staze. Takvi će turisti također preferirati ugodan turistički smještaj, no velik dio njihovih putovanja bit će povezan s motivacijom za druženje s lokalnim ljudima, te će često pokušati govoriti jezikom zajednice domaćina. Unatoč tome, istraživač za vrijeme svog putovanja zadržava mnoge osnovne rutine vlastitog načina života.
- Bjegunac: najčešće izbjegava kontakt s turistima i turističkim ustanovama i identificira se u zajednici domaćina. Bjegunci će živjeti s mještanima i usvajati mnoge prakse i običaje te zajednice.

Cohen (1979) je osim navedenog sažeo i pet načina turističkog iskustva: rekreacijski, diverzijski, iskustveni, eksperimentalni i egzistencijalni.

Promatrajući demografske aspekte turizma, Smith (2014) turiste opisuje u nekoliko razina:

1. Istraživač: vrlo ograničen broj koji traži otkriće i sudjelovanje s lokalnim ljudima.
2. Elitistički: posebni individualno prilagođeni posjeti egzotičnim mjestima.
3. Nekonvencionalan: želja za odmakom od gužve.
4. Neobičan: posjet s osobitim ciljevima kao što su fizička opasnost ili izolacija.
5. Početni masovni: stalan tijek, putuje sam ili u malim organiziranim skupinama koristeći neke zajedničke usluge.
6. Masovni: opće turističko tržište koje vodi do turističkih enklava u inozemstvu.

7. Čarter: masovno putovanje na odredišta za opuštanje koja uključuju što više standardiziranih hotelskih objekata prema uzoru na Zapad (ili prema uzoru na Japan).

Važnost odnosa između načina života i potrošnje dovodi do proširenja tipologije 1990-ih godina. Pregled ili primjena tipologije vrijednosti životnog stila s ciljem razumijevanja trendova u turizmu istražena je kod nekoliko autora tijekom godina (Gratton, 1990; Schott, 2002: Cooper et al. 2008). Nove vrste turizma poput alternativnog pojavljuju se nakon što se počinje percipirati okoliš, pa je tako nastala još jedna klasifikacija turista poput ekoturista ili zelenih turista (Smith i Eadigton, 1992). Turistički tipološki modeli korisni su zbog činjenice da ističu široku raznolikost turista te pružaju uvid u njihovu motivaciju i njihovo ponašanje što u konačnici omogućuje način segmentiranja turista u različite skupine. Stavovi turista o načinu na koji će provesti svoje odmore ovise o nizu faktora među kojima se najviše ističu: razina raspoloživog dohotka, više slobodnog vremena, bolji uvjeti mobilnosti, viša razina obrazovanja i sofisticirani ukus.

Motivacija turista

Motivacija kao unutarnji ljudski nagon vodi čovjekovo ponašanje i odlučivanje kada je u pitanju posao, sport, putovanje i slobodno vrijeme. Istraživanja na temu motivacije najčešće polaze od Maslowljeve hijerarhije potreba (1954), Iso-Aholaovog (1982) motivacijskoga modela te teorije faktora guranja i privlačenja (*push-pull)* Cromptona (1979). Ključni čimbenik prilikom određivanja kategorija turista jest turistička motivacija (Yoo, Yoon i Park, 2018).

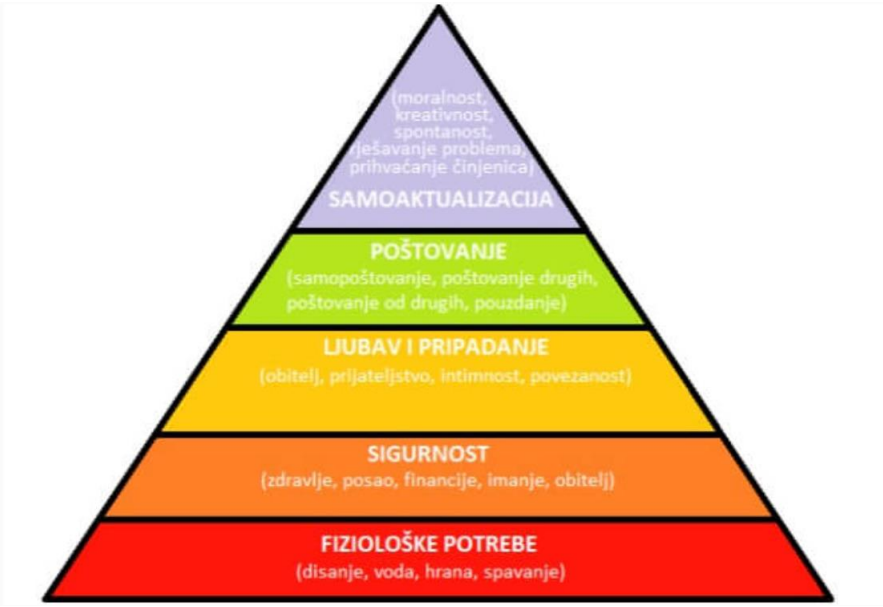
Turistička motivacija predstavlja dinamičan proces unutarnjih psiholoških čimbenika (potreba i želja turista) koji generiraju stanje napetosti ili neravnoteže unutar svakog pojedinca. Te unutarnje potrebe i rezultirajuća neravnoteža dovode do akcija namijenjenih obnovi ravnoteže kroz zadovoljenje potreba (Crompton, 1979). Navedena konceptualizacija razrađena je i supstituirana pojmom optimalne razine uzbuđenja. Kako Iso Aholi (1989, str. 249) ističe „danas se psiholozi uglavnom slažu da potraga za optimalnom razinom uzbuđenja ili općom stimulacijom stoji u osnovi većine psiholoških motiva“. Navedeno potvrđuje kako ljudi ne traže izostanak ili višak stimulacije, već optimalnu razinu. Može se smatrati da motivacija za turističko putovanje upućuje na skup potreba koje predisponiraju osobu za sudjelovanje u turističkim aktivnostima (Yuan i McDonald, 1990). Navedeni motivacijski čimbenici elementi

su psiholoških faktora, poput potreba, očekivanja, traženih koristi i dostignuća, za koje je vjerojatno da će biti zadovoljeni turističkim aktivnostima (Formica i Uysal, 1998). Osnovni princip koji stoji iza teorije jest da osoba traži razinu stimulacije koja za nju/njega kao pojedinca predstavlja najbolju opciju. Fridgin (1991, str. 57-58) navodi kako „osobe čiji je svakodnevni život smireniji i tiši mogu tražiti stimulaciju kroz aktivnosti. S druge strane ako je svakodnevni život osobe prepun aktivnosti, onda ta osoba teži mirnijem okruženju".

Načini aktiviranja motiva konceptualizirani su kroz tri alternativna taksonomska okvira koja razgraničavaju i razvrstavaju pojedine motive u kategorije: Maslowljeva hijerarhija, Iso-Aholaova dihotomija koja traži bijeg i teorija faktora guranja i privlačenja (*push-pull*) (Crompton i McKay, 1997). Uslijed velikoga izbora turisti preferiraju onakve odmore koji im nude maksimalno ostvarenje njihovih očekivanja i potreba. Valja naglasiti čimbenike koji motivirajuće djeluju na pojedinca „tjerajući" ga na odmor, te uloge koje članovi obitelji ili drugi mogu imati u procesu odlučivanja o odmoru (Hall i Page, 2000).

Maslowljeva teorija (1943) hijerarhijskih potreba, iako razvijena u području kliničke psihologije, postala je jedna od najprihvaćenijih teorija motivacije. Često se koristi kao uporište u objašnjavanju motivacije u mnogim društvenim disciplinama i područjima kao što su poslovanje, marketing i turizam. Maslow (1943) potrebe hijerarhijski razrađuje kroz pet faza.

Shema 2 Maslowljeva hijerarhija potreba



Izvor: Maslows Hierarchy of Needs

Navedene faze (shema 2) predstavljaju različite kriterije ili „potrebe“. Uspinjanje po piramidi podrazumijeva ispunjavanje potreba redoslijedom odozdo prema gore. Najniža razina predstavlja ujedno i najkritičniju fazu zadovoljenja, a ona se odnosi na najosnovnije fiziološke ljudske potrebe kao što su potreba za hranom, vodom, zrakom i slično. Jednom kada je ta potreba zadovoljena, pojedinac će pokušati zadovoljiti svoje druge potrebe (Huang i Hsu, 2009). Navedeno može pomoći prilikom određivanja čimbenika koje turisti uzimaju u obzir tijekom procesa odlučivanja o odlasku na godišnji odmor (Kurtzman i Zauhar, 2005).
Istraživanja u turizmu kao i ona koja se odnose na potrošačku motivaciju često kritiziraju pristup teorije motivacije temeljene na konceptu potreba.

Motivaciju za putovanjem moguće je opisati i kroz čimbenike guranja i privlačenja (*push-pull*). Koncept je razvio Crompton (1979), a čimbenike identificira putem devet ključnih motiva za putovanjem., od kojih je sedam socio-psiholoških (faktori guranja / *push*) Faktori guranja uključuju bijeg, istraživanje, relaksaciju, prestiž, socijalnu interakciju te jačanje srodstva. Čimbenici guranja prethode čimbenicima privlačenja (Dann, 1981). Ljudi putuju iz razloga što ih unutrašnje snage dovuku do odredišta (Dann, 1981; Oh, Uysal i Weaver, 1995). Faktori guranja objašnjavaju želju za stvarnim putovanjem, dok faktori privlačenja objašnjavaju što je ljude privuklo određenim destinacijama odnosno odredišnom atributu (Oh, Uysal i Weaver, 1995).

Faktori guranja i privlačenja u turizmu postaju vrlo popularni te omogućuju razumijevanje kako i zašto ljudi osjećaju potrebu za putovanjem (Michael, Wien, Reisinger, 2017). Faktori guranja obično se temelje na osobnim motivima želje za putovanjem. Na primjer, to može uključivati osjećaj potrebe za bijegom od svakodnevnice i pritiska rada pa ljudi traže emocionalno olakšanje u obliku odmora (Pesonene et al., 2011). Faktori privlačenja s druge strane sastojali bi se od stvari koje su vidljive i koje se dodatno podstiču kroz medije putem marketinga. To najčešće uključuje imidž destinacije, dostupnost popusta i ponuda, atraktivnost aktivnosti i sadržaja koje destinacija može ponuditi poput vodenih parkova i još mnogo toga (Prayag i Ryan, 2011). Čimbenici privlačenja manje su određeni osobama i osjećajima, a više pristupnošću destinacije. Odredišni atributi sami su po sebi motivacijski adekvatno objašnjenje zašto pojedinci ili grupa gravitiraju jednom mjestu, a ne nekom drugom (Dann, 1996.). Kada se potencijalni turisti približe konačnom izboru destinacije, fundamentalne prednosti te destinacije su one koje postaju važne.

Iso-Ahola (1982) je sugerirao da je središnja osnova u studiji ponašanja turista ta da se identificiraju motivacijski čimbenici koji su razlozi i smjer ponašanja. Predložio je dvije osnovne motivacijske dimenzije ponašanja u slobodno vrijeme ili u turizmu, *bijeg i traženje*, koje istovremeno utječu na slobodno ponašanje ljudi. Na primjer, turist može htjeti otići na putovanje kako bi pobjegao od svog osobnog ili međuljudskog okruženja (npr. bijeg od svakodnevnog života) i potražiti psihološke nagrade na osobnoj ili međuljudskoj dimenziji (npr. izgradnja avanture ili prijateljstva).

2.3. Teorijske odrednice eksternih šokova

Svjetska znanstvena i stručna literatura selektivno obrađuje šokove koji negativno utječu na razvoj gospodarstva pa tako i na razvoj turizma nazivajući iste krizama, katastrofama, događajima, vijestima, eksternim i internim šokovima, egzogenim i endogenim šokovima. Eksterni šok, bez obzira je li prolazan ili trajan, utječe na prirodu, vrstu i reakciju politike. Mnogi autori eksterne šokove definiraju upravo s obzirom na prirodu nastanka.

Eksterni šokovi, bilo da su nastali prirodno, tržišno, ljudskim činom ili odlukom nositelja politike, oduvijek su bili zanimljivo područje istraživanja zbog njihovoga učinka na gospodarstvo i društvo u cjelini. U znanstvenoj literaturi nije postignut koncensus oko jedinstvene definicije eksternih šokova. Turistička potražnja iznimno je osjetljiva na raznorazne šokove uzrokovane sigurnosnim rizicima, prirodnim katastrofama, ratom, terorističkim aktima i političkom nestabilnošću (Sonmez, 1998; Pizam i Smith, 2000; Webber, 2001; Querfelli, 2008; Saha i Yap, 2014).

Izvješće Svjetske banke (2004), Konferencija Ujedinjenih naroda o trgovini i razvoju (eng. United Nations Conference on Trade and Development – UNCTAD (2002)) i Međunarodni monetarni fond (International monetary fund – IMF (2003)) u kategoriju egzogenih šokova, koji imaju značajan negativan utjecaj na razvoj, makroekonomsku stabilnost, održivost duga i siromaštvo, ubrajaju redom: prirodne katastrofe, trgovinske šokove, sukobe i krize u susjednim zemljama. Polazeći od činjenice različitog definiranja eksternog šoka, važno je istaknuti definiciju koja će se koristiti u ovom istraživanju, a koja se uklapa u definiciju kreiranu upravo od strane IMF-a (2003, str. 4) koji objašnjava egzogeni šok kao „iznenadni događaj izvan kontrole vlasti koji ima značajan negativan utjecaj na ekonomiju. Takvi šokovi odnose se na šokove uzrokovane promjenom uvjeta trgovine (izvozni šokovi), prirodne katastrofe, šokove ponude robe za domaću potrošnju ili izvoz, šokove potražnje za izvoznim dobrima, šokove

vezane uz dostupnost financijskih sredstava i šokove uzrokovane sukobima i građanskim nemirima“. Izvješća iz 2003. i 2011. (IMF 2003, 2011) navode:

- Šokovi vezani uz izvozne cijene i prirodne katastrofe najzastupljenija su vrsta šokova kod zemalja s niskim dohotkom.
- Zemlje niskoga dohotka osjetljivije su i manje otporne na šokove u odnosu na razvijene zemlje.
- Ukupan apsolutni broj šokova i razina štete veća je kod zemalja niskoga dohotka.
- Zemlje niskoga dohotka više su izložene šokovima cijena roba.

Prema saznanju autorice u svjetskoj literaturi ne postoji cjelokupan pregled eksternih šokova. Nekolicina autora u svojim istraživanjima (regionalna razina) koristi pojam „eksterni šokovi“, a u nastavku rada istaknuti će se neki od njih kako bi bilo jasnije što zaista eksterni šokovi obuhvaćaju. Matos, Camacho i Soma (2011) u svom istraživanju analiziraju usklađenost gospodarskih aktivnosti između zemalja SADC-a (engl. Southern African Development Community) i razvijenih gospodarstava te utjecaj eksternih šokova na gospodarstva SADC zemalja. Autori kronološki prikazuju eksterne šokove koji su izravno ili neizravno utjecali na gospodarstva SADC članica (tablica 1).

Tablica 1 Kronološki prikaz eksternih šokova koji su pogodili zemlje SADC-a

Godina	Eksterni šok	Analizirane makroekonomske varijable
1971.	Obustava konvertibilnosti američkoga dolara	Obustava konvertibilnosti dolara (posljedica)
1973.	Fluktuiranje glavnih europskih valuta	Suspenzija konvertibilnosti dolara
1973.	Šok cijena nafte	Prekid trgovinskih tokova i kapitala
1973. – 1977.	Rast cijena nafte i rast cijena roba i hrane	Ekonomska recesija
1979.	Šok cijene nafte	Štetni utjecaji, velike posljedice na manje razvijena gospodarstva, nedovoljna količina nafte
1980.	Rast kamatnih stopa i povećani tok kapitala (petrodolar) u cijelom svijetu dovodi do rasta cijene nafte	Dužnička kriza zemalja koje su ranije imale koristi od obilne ponude resursa iz petrodolara.
1988. – 1989.	Kriza štednje i kredita	Ekonomija SAD-a i globalna ekonomija u depresiji
2001.	Geopolitički šokovi (koji nisu povezani s napadima 11. rujna) u SAD-u	Ekonomija SAD-a- depresija
2005.	Rastuće cijene nafte i hrane	Ekonomija SAD-a- depresija
2008.	Međunarodna financijska kriza	Globalna ekonomija u depresiji
2009./2010.	Međunarodna financijska kriza	Značajni makroekonomski učinci u SADC-ovim zemljama

2009./2010.	Međunarodna financijska kriza (kreditna kriza i recesija u SAD-u)	Kolaps sjevernoameričkog tržišta nekretnina, kolaps američkog financijskog tržišta

Izvor: Matos, Camacho Monteiro i Soma (2011)

Eksterni šokovi u razdoblju 1973. – 1978. i 1978. – 1983. godine uzrokovali su: promjene uvjeta u međunarodnoj trgovini, uglavnom povezanih s povećanjem cijena nafte; učinke na količine izvoza kao posljedica usporavanja svjetske trgovine uzrokovane recesijom; efekte na kamatnim stopama nastale zbog povećanja kamatnih stopa na svjetskim financijskim tržištima. Valja napomenuti i neke poteze nositelja ekonomske politike kao odgovore na eksterne šokove: dodatno neto vanjsko financiranje u obliku povećanog zaduživanja; poticanje izvoza (povećanje udjela na izvoznom tržištu); supstitucija uvoza u vidu smanjenja dohodovne elastičnosti uvozne potražnje; deflatorne makroekonomske politike koje rezultiraju padom rasta potražnje za uvozom (Balassa, 1989).

Turizam je vrlo osjetljiv na eksterne šokove kao što su prirodne katastrofe, terorizam i politička nestabilnost, iz razloga što se potrošnja temelji na vjeri i povjerenju (Mansfeld i Pizam, 2006). Aktivnosti koje štete toj vjeri destabiliziraju turistički sustav i utječu na osnove unutar strukture i susjednih okruženja uslijed fluktuacija potražnje (Blake i Sinclar, 2003; Neumayer, 2004). Neumayer (2004) navodi kako su turisti podložni vijestima o nasilju i političkim nemirima na ciljanim turističkim destinacijama. Raddatz (2007) u eksterne šokove ubraja fluktuacije cijena robe, prirodne katastrofe i ulogu međunarodne ekonomije, dok Barnichon (2008) ubraja uvjete trgovačkih šokova i prirodne katastrofe. U radu Strobl, Bazoumana Ouattara i Akassi Kablan (2020) eksterni šok predstavlja prirodnu katastrofu, točnije uragan.

Eksterne šokove u obliku SARS-a, građanskog rata, genocidnog režima i političke nestabilnosti te njihov utjecaj na dolaske turista u Kambodžu u svom radu istražuju Azad, Chheang i Ahsan (2014). Verma, Saleh i Ihalanayake (2011) eksterne šokove promatraju kroz varijable kao što su azijska financijska kriza (1997. – 1998.), napad 11. rujna 2001., izbijanje SARS-a 2003., ptičja gripa 2004. te svjetska financijska kriza iz 2008. godine. Slično eksterne šokove definiraju Kosová i Enz (2012) te Lanouar i Goaied (2019) gdje su eksterni šokovi promatrani kroz varijable napad 11. rujna 2001. i globalnu financijsku krizu 2008.

2.3.1. Terorizam

Izraz „terorizam“ latinskog je podrijetla, a korijen proizlazi iz riječi „teror“ što znači „fizičko nasilje, strah, strah namjerno izazvan javnim nasilnim djelima, namjerna uporaba određenih sredstava koja mogu dovesti do kolektivne propasti“ (Oxford, 2017, Jongman, 2017, str. 2). Terorizam se smatra jednom od najznačajnijih suvremenih prijetnji globalnoj sigurnosti, no bez obzira na navedeno ne predstavlja novu pojavu današnjice. Uništavanje političkog sustava primjenom nasilja između vođa država i njihovih vlada može se pratiti daleko u povijest (Martin, 2003).
Zapisi vezani uz terorizam kao oblik političkog izražavanja sežu u 6. godinu kada su se židovski domoljubi suprotstavili rimskoj vlasti u Palestini. Organizirali su se pod imenom zeloti i pokrenuli terorističku kampanju za protjerivanje Rimljana iz Palestine (Poland, 1988). Izraz terorizam u službeni je rječnik evidentiran tek u 18. stoljeću, kada je Edmund Burke dao kritiku na „vladavinu terora“ netom nakon Francuske revolucije 1792. – 1794. U to vrijeme francuska je vlada koristila sustavni teror za zastrašivanje i uklanjanje svojih neprijatelja (Murphy, 1989; Poland, 1988). Novija povijest bilježi kasne 1960-e, početak 1970-ih te 1980-e kao razdoblja intenzivnih terorističkih napada (D'Amore i Anuza 1986).

U svjetskoj literaturi ne postoji široko prihvaćena definicija terorizma s obzirom na to da je fenomen otvoren za mnoga značenja koja ovise o perspektivi (Norris, Kern i Just, 2004). Dakle, između autora ne postoji konsenzus vezan uz adekvatnu i općeprihvaćenu društveno-znanstvenu definiciju terorizma kao taktike i kao doktrine, što omogućava različite interpretacije navedenog ovisno o namjeni interpretatora i političkim zahtjevima tog trenutka. Stoga se u nastavku navode neke od definicija terorizma.

Merriam-Webster (2017) terorizam definira kao „sustavno korištenje terora kao sredstva prisile“ dok Larobina i Pate (2009, str. 153) navode kako „teroristički akt za cilj ima uništiti vladu, tržište i kulturu“. Ministarstvo vanjskih poslova SAD-a (1996, str. 4) terorizam definira kao „pred-namjerno, politički motivirano nasilje nad civilima i nenaoružanim vojnim osobljem od strane subnacionalnih skupina obično namijenjeno zastrašivanju javnosti“. S druge strane autori Enders i Sandler (2002, str. 145-146) definiraju terorizam kao „pred-umišljenu upotrebu ili prijetnju korištenjem ekstremnoga nasilja ili brutalnosti od strane subnacionalnih skupina radi postizanja političkog, vjerskog ili ideološkog cilja zastrašivanjem javnosti, koja obično nije izravno uključena u kreiranje politike na koju teroristi žele utjecati“. Agnew (2010, str. 132)

pod terorizmom smatra „počinjenje kaznenih djela, obično nasilnih, koja ciljaju civile ili krše ratne konvencije prilikom ciljanja vojnog osoblja; i one su počinjene barem djelomično za društvene, političke ili vjerske ciljeve“.
Corbet et al. (2019) definiraju terorizam u kontekstu turističke destinacije na sljedeći način: „Terorizam predstavlja stvaranje straha bilo nasilnim aktom ili prijetnjom destinaciji činom nasilja koji uzrokuje poremećaje u turizmu, infrastrukturi i ukupnom poslovanju.“ (Corbet et al. 2019, str. 1)

Najčešće korištena tipologija terorizma je podjela na domaći i međunarodni terorizam (Stepanova, 2008). Prema istoimenom autoru „međunarodni terorizam“ predstavlja „terorističku aktivnost koja se provodi na teritoriju više država ili uključuje više država“ (kao žrtve ili počinitelje) dok domaći terorizam obuhvaća teritorij jedne države (2008, str. 5). Mnoga znanstvena istraživanja nastoje identificirati glavne uzroke terorizma. Najčešće navedeni uzroci zbog kojih se događa teroristička aktivnost su: stupanj demokracije, siromaštvo i nezaposlenost, veličina zemlje i sukoba, razina obrazovanja, internetska dostupnost i sukob identiteta (Enders i Hoover, 2012; Frey et al., 2007; Llussá i Tavares, 2008; Campos i Gassebner, 2009; Gassebner i Luechinger, 2011; Schumacher i Schraeder, 2019).

Teroristički napadi i akti, za razliku od slučajnih kaznenih djela nasilja, su planirani i vođeni u skladu s određenim ciljevima (Hoffman, 2006). Ciljevi mogu biti usko ili široko postavljeni, a ovisit će o temeljnoj motivaciji i ideologiji. Hoffman (2006) u svom radu ističe potrebu razumijevanja spomenutih razlika i njihovih utjecaja na percipirani rizik. Temeljna podjela koju autor navodi jest sekularni i vjerski terorizam. Sekularni terorizam prema Hoffmanu (2006) rijetko pokušava masovno ubijanje, a razlog tome jest što je takav oblik taktike suprotan moralu i političkim ciljevima terorista. S druge strane, Simon (2003), navodi kako vjerski terorizam nije politički motiviran, već za konačni cilj ima masovno ubijanje. Temeljna razlika između spomenuta dva oblika terorizma jest što je unazad nekoliko desetljeća evidentiran porast vjerskog terorizma popraćen većim brojem smrtnosti kao i širim globalnim dosegom (Simon (2003, str. 18).

Dok Hoffman (2006) opisuje učinke etno-nacionalističkog, separatističkog, međunarodnog, vjerskog terorizma i terorizma pod pokroviteljstvom države, Crenshaw (1981) i Agnew (2010) u svojim istraživanjima u terorističke ciljeve osim političkog i vjerskog ubrajaju i društvene.

Najčešće se takvi napadi događaju iz vjerovanja da je viša sila sankcionirala i zapovjedila terorističko nasilje za veću slavu svoje vjere (Martin, 2017).
Autor ističe kako do terorizma dolazi nakon „kolektivnog i nepravednog napada“ vlasti, napada koji ostavlja velike posljedice za civile, a uključuje apsolutnu ili relativnu materijalnu oskudicu. Osim do sada navedenih, razloge pojave terorizma moguće je pronaći u: apsolutnoj ili relativnoj materijalnoj oskudici; problemima vezanim uz globalizaciju i modernizaciju; problemima koji proizlaze iz teritorijalnih, etničkih i vjerskih sporova; uskraćivanju osnovnih ljudskih prava, ekonomskoj, političkoj ili drugoj diskriminaciji na temelju rase, etničke pripadnosti ili religije (Agnew, 2010).

Kršenje ljudskih prava jedan je od glavnih razloga za nastanak terorizma (Callaway i Harrelson-Stephens, 2006). Callaway i Harrelson-Stephens (2006) navode kako negiranje ljudskih prava, kao što su pravo na političko izražavanje, pravo na osobnu sigurnost te osnovna ljudska prava, stvara uvjete za pojavu terorizma.
Terorizam je moguće promatrati i s komunikacijskog aspekta „kao simbolički čin“ koji se „može analizirati slično kao i drugi mediji komunikacije“ (Kaber, 1971, str. 9). Konceptualizaciju prate četiri osnovne komponente komunikacijskoga procesa u kontekstu terorizma:

(1) prijenosnik poruke (teroristički)
(2) planirani primatelj poruke (cilj terorističke poruke)
(3) poruka (teroristički akt u koji su uključene pojedinačne ili institucionalne žrtve)
(4) povratne informacije (reakcija primatelja).

Medijsko izvještavanje o terorističkim incidentima koji se redovito ponavljaju pojačava psihološku traumu koju terorizam nastoji stvoriti (Mitra, Pham, Bandyopadhyay, 2018). Mediji predstavljaju alat teroristima kako bi uspješno prenijeli svoje ciljeve široj publici kojoj inače ne bi pristupili.
Mitra, Pham, Bandyopadhyay (2018) navode kako teroristički napadi postaju smrtonosniji iz razloga što teroristi ciljaju na gusto naseljene i popularne lokacije u većim gradovima kako bi maksimizirali učinak svojih napada. Prema istoimenim autorima terorizam nepovoljno utječe na međunarodni putnički tok, a poticanje širokog straha i nesigurnosti među stanovništvom ključni su ciljevi terorističkih napada te ujedno i temeljne prepreke međunarodnim putovanjima (Buckley i Klemm, 1993; Pain, 2014). Terorizam ostavlja značajan psihološki efekt na stanovništvo unošenjem nemira u svakodnevnicu (Wimann, 2008) kao rezultat nasumično ili

selektivno odabranih meta u svrhu širenja poruke (Albu, 2016). Teroristi koriste prijetnju i nasilje kao komunikacijski kanal u manipulaciji glavne mete – javnosti (Schmid i Jongman, 1988, str. 28).

Teroristički napad na Sjedinjene Američke Države koji se dogodio 11. rujna 2001. godine promijenio je lice i razumijevanje termina terorizam te nije rijedak slučaj da se iznova i iznova analiziraju reakcije gradova, zemalja i njihovih ljudi (Naumann, Edmonds i Frear, 2018).

2.3.2. Politička nestabilnost

S ciljem boljeg razumijevanja političke nestabilnosti, potrebno je najprije pojmovno odrediti političku stabilnost. Politička stabilnost predstavlja važan kriterij gospodarskog rasta neke države (Oliva i Rivera-Batiz, 2002). Chourci et al. (2006, str. 1), navode kako je „stabilnost proces, u kojem države mogu biti u različitim fazama stabilnosti, podložne različitim pritiscima prema nestabilnosti“. Autori navode kako istraživanja vezana uz stabilnost države analiziraju aspekte građanskog rata, političke mobilizacije, socijalnih poremećaja, institucionalnog razvoja, ekonomskih rezultata, socijalne kohezije, etničkog nasilja itd. Prema njihovim tvrdnjama prepoznatljiviji pokazatelj nestabilnosti države jest početak građanskog rata. Hall i O'Sullivan (1996, str. 108, citirano u Ryu, 2005) sagledavaju političku stabilnost u kontekstu turizma te u svome radu tvrde kako se „unutar međunarodnog turizma može prepoznati niz različitih dimenzija političke nestabilnosti kao što su međunarodni i građanski rat, državni udar, terorizam, neredi, politički i socijalni nemiri i štrajkovi“.

Istraživanje McMahona (2010) ističe da politička stabilnost u velikoj mjeri ovisi o stupnju obrazovanja, dohotku po glavi stanovnika, vojnim izdacima i razini demokracije.

Stabilnost neke zemlje mjeri Međunarodni indeks rizika zemlje (International Country Risk Guide Methodology, 2012) koji uključuje, politički, ekonomski i financijski rizik. Političku nestabilnost moguće je definirati kao „situaciju u kojoj je politički sustav izložen izazovima ili promjenama u obliku unutarnjeg sukoba, unutarnjih promjena i vanjskih sukoba“ Theocharous (2010, str. 358). Politička nestabilnost inherentno je nestabilna (Rotunno, 2016, str. 133), sklona promjeni izvršne vlasti, bilo ustavnim bilo neustavnim načinom (Alesina et al., 1996, str. 191), a njeno postojanje i utjecaj u raznim zemljama je višerazinsko i višedimenzionalno“ (Seddighi, Theocharous i Nuttall, 2002, str. 61). Politička nestabilnost najčešće se „pojavljuje tamo gdje je vlada srušena ili je pod kontrolom frakcija nakon državnog udara ili gdje su osnovni funkcionalni preduvjeti za kontrolu i održavanje društvenog poretka nestabilni i povremeno se narušavaju“ (Cook, 1990, citirano u Sonmez, 1998, str. 420; Ingram et al., 2013). William

(2012) političku nesigurnost definira kao situaciju u kojoj su upravljanje, vladavina i politički legitimitet dovedeni pred izazov, aktivnostima koje djeluju izvan uobičajenih operacija političkog sustava.

Promjene u narušenom političkom sustavu moguće je ostvariti mirnim ili nasilnim putem. Mirno djelovanje uključuje prosvjede, štrajkove, kritike i druge aktivnosti koje ne rezultiraju uništavanjem imovine, ozljedama ili gubicima života (Kapuscinski, 2014). Alternativno, promjene je moguće ostvariti kroz nasilne radnje kao što su ratovi ili nemiri (Gurr, 1972).
Cook (1990, str.14, citirano u Kapucinski, 2014) u svom istraživanju navodi kako su „osnovni funkcionalni preduvjeti za kontrolu i održavanje društvenog poretka nestabilni i povremeno se prekidaju“. Dužina trajanja razdoblja političke nestabilnosti ovisi o intenzitetu napetosti i sukoba te sposobnosti vlade da upravlja kriznom situacijom (Neumayer, 2004).
Zaključno je moguće ustvrditi kako je politička nestabilnost države situacija u kojoj je sustav izložen i ugrožen unutarnjim ili vanjskim poremećajima u sferi političkog, ekonomskog, financijskog ili društvenog života, a sve s ciljem pokretanja promjena.

2.3.3. Rat

Terorizam, ratovi i politička nestabilnost međusobno su povezani, a razlog navedenom jest to što utjecaji ratova i terorizama posljedično mogu dovesti do političke nestabilnosti pogođene zemlje. Smith (1998, str. 202) navodi kako rat predstavlja „veliko moderno sigurnosno pitanje, koje se razlikuje od kriminala i terorizma dubokim društvenim prodorom i dugoročnim posljedicama“. Autor ističe vrijeme kao važan kulturološki pokazatelj kroz koji stanovništvo segmentira svoju povijest u tri faze – „prije rata“, „tijekom rata“ i „nakon rata“. Povezanost turizma i rata moguće je objasniti kroz koncept „mračnoga turizma“. Butler i Suntikul (2013) navode kako se istraživanja o „mračnom turizmu“ uglavnom ne fokusiraju na odnos između rata i turizma, već prvenstveno na posljedice rata i sukoba, uz privlačenje gostiju na mjesta smrti i drugih tragedija i brutalnosti.
Nadalje, autori tvrde kako rat ograničava razvoj turizma, ali u mirnodopskim vremenima stvara poticaje za kasniji razvoj turizama u područjima koja su prethodno bila nedostupna ili previše opasna tijekom ratnoga razdoblja.
Tragični događaji, kao neizravni ishodi ratnih djelovanja, mogu postati izvori poticaja razvoja turizma na lokalitetima povijesnoga značaja (Bigley et al., 2010, str. 372). Prideaux (2007) u

svojoj knjizi navodi kako je rat jedinstvena ljudska pojava u kojoj često nedostaje logike, no kako je uvijek karakterizirana paradoksom.

Hertzog (2012, str. 1) rat naziva „traumom koja duboko utječe na doživljaj lokalnoga mjesta; predstavlja ključnu prekretnicu u percepciji lokalnog identiteta s posljedicama koje postaju dio turističkoga prostora“. Za Vukonića (2001, str. 65) „rat je vrijeme paradoksa, rat je vrijeme bezumlja: ali rat je istom vrijeme znanja i zaborava“.
Melander, Pettersson i Themner (2016) tipologiju ratova promatraju kroz tri dimenzije nasilja povezanog sa sukobima:

(1) Državni oružani sukob – odnosi se na situacije gdje je minimalno jedna strana u sukobu predstavnik vlasti. Riječ je o sukobima između država i unutar neke države koji rezultiraju s najmanje 25 smrtnih slučajeva u jednoj kalendarskoj godini. Državni oružani sukob naziva se unutardržavnim ili građanskim sukobom kada se jedna ili više nedržavnih skupina bore protiv vlasti.
(2) Nedržavni sukobi – sukobi između dvije organizirane oružane skupine, od kojih nijedna nije predstavnik vlasti, a rezultira s najmanje 25 smrtnih slučajeva unutar jedne kalendarske godine. Nedržavni sukobi uključuju borbe između pobunjeničkih skupina i narodne vojske, sukobe između neformalno organiziranih skupina, posebno između skupina sa zajedničkom identifikacijom etničke, klanske, vjerske, nacionalne ili plemenske pripadnosti. Nedržavni sukobi obično su manje nasilni od državnih sukoba.
(3) Jednostrano nasilje – ciljano ubijanje najmanje 25 nenaoružanih civila, unutar jedne kalendarske godine, od strane vlasti ili formalno organiziranih nevladinih skupina. Većina smrtnih slučajeva u jednostranom nasilju obično se događa u kontekstu državnoga oružanog sukoba.

Sličnu tipologiju, uz dodatno proširenje, primjenjuje i WorldBank (2017) unutar svoje metodologije i baze podataka (Global Spread Of Conflict By Country And Population). Proširena tipologija obuhvaća četiri temeljne kategorije:

(4) međunarodni ratovi (tip rata 1)
(5) izvandržavni ratovi unutar kojih su:
    a. kolonijalni – sukobi s kolonijom (tip rata 2)
    b. imperijalni – država protiv nedržave (tip rata 3)
(6) unutardržavni ratovi unutar kojih su:
    a. građanski ratovi

i. za središnju kontrolu (ratni tip 4)
ii. o lokalnim pitanjima (ratni tip 5)

b. regionalni unutarnji (ratni tip 6)
c. interkomunalni (ratni tip 7)

(7) nedržavni ratovi

a. na nedržavnom teritoriju (ratni tip 8)
b. preko državnih granica (ratni tip 9).

2.3.4. Migracije

Goldstein (1978) ističe kako su vremenska i prostorna dimenzija osnova razlikovanja migracija od ostalih oblika putovanja. U tom kontekstu moguće je postaviti dva pitanja – koliko (vremenski) netko mora putovati i koliko trajno mora biti navedeno putovanje.
Privremeni i fluidni oblici mobilnosti posljednjih su godina sve važniji, dok međunarodne migracije postaju sve složeniji proces, koji je teško definirati i izmjeriti (Górny i Kindler, 2016, str. 91). Autori navode kako su definicije privremene i dugotrajne (trajne) migracije ili nedovoljno jasne ili previše determinirane kako bi bile u mogućnosti zahvatiti različite vrste popratnih mobilnosti.

Priručnik za edukatore (2014, str. 16) koji se odnosi na Zaštitu za izbjeglice i ranjivih skupina migranata (2014) definira migracije kao kretanje pojedinaca ili grupa unutar ili izvan graničnog teritorija, a najčešća kategorizacija migracije jest imigracija i emigracija. Imigracija predstavlja ulazak i nastanjivanje nerezidenta u zemlji primateljici, a emigracija predstavlja odlazak ili izlazak iz jedne zemlje s namjerom nastanjivanja u drugoj. Utjecaj migracija ovisi o opsegu, strukturi i karakteristikama emigranata i imigranata.

Kategorizacija „izbjeglica“ i „migranata“ u svrhu razlikovanja između onih koji su u pokretu i legitimiteta njihovih zahtjeva za međunarodnom zaštitom snažno je obilježena tijekom europske „migracijske krize“ i korištena je za opravdavanje politike isključenja i obuzdavanja (Crawley i Skleparis, 2017). Autori naglašavaju kako ove kategorije ne uspijevaju adekvatno objasniti složen odnos između političkih, socijalnih i ekonomskih pokretača migracija ili njihov značaj za pojedince u vremenu i prostoru.

„Prisilnu“ i „dobrovoljnu“ migraciju ističu i Zetter (2007) te Long (2013). Razumijevanje tko je „izbjeglica“, a tko „migrant“ jasnije je kroz pozicioniranje granice, faktora, mjesta i iskustva koji se povezuju s kategorijama.

Najistaknutija razlika između izbjeglice i migranta prvenstveno jest motiv pokreta koji je kod navedenih itekako različit. Migranti se odlučuju na pokretanje svojevoljno s ciljem poboljšanja životnog standarda, dok s druge strane izbjeglice predstavljaju pojedinci koji su prisiljeni bježati kako bi spasili vlastiti život i očuvali slobodu.

Nekolicina autora tako će ustanoviti da je razlika između „izbjeglica“ i „migranata“ upravo u tome što se ne odražava način na koji migracijski procesi djeluju u stvarnom svijetu, tvrdeći da ne uzimaju u obzir činjenicu da ljudi s različitim motivacijama putuju zajedno i da pojedinci mogu promijeniti status ili se istovremeno uklopiti u dvije postojeće kategorije (Koser i Martin, 2011; Collyer i de Haas, 2012; Zetter, 2015).

Spomenute kategorije često se temelje na mjestu na kojem se migracija događa, uzrocima kretanja i vremenu ili trajanju migracije. Znanstvenici koji se bave proučavanjem migracija dugi niz godina su problematizirali stupanj u kojem je jasno i lako moguće razlikovati različite vrste migranata i tvrdili su da je potrebno prijeći izvan suprotnih binarnih izvora. Iako ne postoji definicija koja je definirana međunarodnim pravom, pojam migrant (International Organization for Migration (IOM), 2019) predstavlja osobu koja se udaljava iz svog uobičajenog mjesta stanovanja, bilo u zemlji, bilo preko međunarodne granice, privremeno ili trajno i iz različitih razloga.

Migrante čine dobro definirane pravne kategorije kao što su radnici migranti: osobe čije su posebne vrste kretanja zakonski definirane, poput krijumčarenih migranata; kao i oni čiji status ili sredstva za kretanje nisu posebno definirana međunarodnim pravom poput međunarodnih studenata.

Najčešća kategorizacija (Priručnik za edukatore, 2014, str. 14.) migracija jest prema:

(1) motivu
(2) prostoru te
(3) prema legalnosti.

Prema kriteriju motiva jest:

(1) ekonomska
(2) neekonomska
(3) obiteljska

(4) obrazovna itd.

Prema prostoru razlikujemo:

(1) unutarnje migracije (unutar države)
(2) vanjske (izvan-granične migracije) te
(3) tranzitne (oblik u kojem migranti prelaze nekoliko država da bi došli do ciljanog odredišta).

Prema kriteriju legalnosti moguće su:

(1) zakonite ili legalne migracije koje su popraćene svim potrebnim i važećim dokumentima i
(2) nezakonite ili neregularne migracije popraćene nedopuštenim prelaskom granice i boravkom u drugoj državi.

2.3.5. Prirodne katastrofe

Prirodne katastrofe predstavljaju jedan od najvećih izazova s kojima se susreće čovječanstvo, donose ogromnu ljudsku patnju te uzrokuju znatnu fizičku i ekonomsku štetu koja se može preliti izvan područja katastrofe u ostatak zemlje. Na taj način, katastrofe mogu privremeno ili čak trajno ugroziti cjelokupni gospodarski razvoj zemlje (Loayza et al., 2012). Mnogi autori pokušali su razumjeti prirodne katastrofe na način da ih definiraju, objašnjavajući njihovu prirodu, njihov životni ciklus ili anatomiju s ciljem poboljšanja razumijevanja takvih pojava, pritom skrećući pažnju na složenost i kaotičnost prirode takvih događaja koji predstavljaju izazove za upravljanje ili sprečavanje prirodnih katastrofa (Ritche, 2004).

Prirodne katastrofe predstavljaju katastrofalne događaje atmosferskog, geološkog i hidrološkog podrijetla (Cavallo, Gallini i Pantano, 2013). Katastrofe uključuju zemljotrese, vulkanske erupcije, klizišta, tsunamije, oluje i sušu (Watson, Gayer i Connolly, 2007; Cavallo, Gallini i Pantano, 2013). Unazad nekoliko desetljeća prirodne su katastrofe usmrtile milijune ljudi, nepovoljno utjecale na živote najmanje milijardu ljudi i rezultirale znatnom ekonomskom štetom (Watson, Gayer i Connolly, 2007).

Geofizički događaji, kako ih u svom istraživanju naziva Alcántara Ayala (2002, str. 108), imaju karakteristiku da predstavljaju „opasnost za različite društvene cjeline našeg planeta, no ta opasnost nije samo rezultat procesa samog po sebi (prirodna ranjivost), već je rezultat ljudskog sustava i s njim povezanih ranjivosti prema njima (ranjivost ljudi)“. Kod istih koordinata u

vremenu i prostoru, spomenutih ranjivosti mogu se dogoditi prirodne katastrofe. Utjecaj istih veći je u zemljama u razvoju, gdje se događaju često, a razlog jest veza s geografskim položajem i geološko-geomorfološkim postavkama. Siromašnije zemlje ili one u razvoju u velikoj su mjeri smještene u zonama koje su pod velikim utjecajem vulkanske aktivnosti, seizmičnosti, poplava i slično.

Sljedeći razlog vezan je uz povijesni razvoj siromašnih zemalja, gdje ekonomski, socijalni, politički i kulturni uvjetni nisu zadovoljavajući te posljedično djeluju kao faktori velike ranjivosti na prirodne katastrofe (ekonomska, socijalna, politička i kulturna ranjivost). S obzirom na to da prirodne katastrofe devastiraju zemlje u razvoju, glavni naglasak na prevenciji trebao bi biti u uključivanju institucija na svim razinama, međunarodnoj, nacionalnoj, regionalnoj, lokalnoj.

Strategija za sprečavanje prirodnih katastrofa univerzalni je alat, a primjena iste u obzir bi trebala uzeti posebne karakteristike ugroženih subjekta, razlog navedenom jest bolje razumijevanje ranjivosti društvenog entiteta (prirodnog i ljudskog). Razlog za veći broj katastrofa u zemljama u razvoju Strömberg (2007, str. 200) vidi u objašnjenju u kojem su „zemlje s niskim dohotkom više izložene prirodnim opasnostima ili su smrtni slučajevi u nedemokratskim zemljama veći samo zato što su te zemlje također siromašnije“. „Znatno je više ljudi pogođeno i ubijeno u katastrofama u zemljama s niskim ili srednjim dohotkom, uzimajući u obzir vrstu katastrofe i stanovništvo u riziku“ (Strömberg 2007, str. 221).

Za potrebe planiranja, Foster (2012) katastrofe razvrstava u četiri glavne faze:

(1) procjena
(2) upozorenje
(3) utjecaj i
(4) oporavak.

Faza procjene identificira i procjenjuje potencijalni rizik. Faza upozorenja lokalne vlasti upozorava na opasnosti i savjetuje ih kako ukloniti opasnost, izbjeći njezine posljedice ili ublažiti njezine učinke. Fazu utjecaja karakterizira prijetnja izazvana katastrofom po život i imovinom te javnom i privatnom provedbom hitnih službi spašavanja. Tijekom spomenute faze mogu se pojaviti problemi s medijskim izvještavanjem i radoznalim posjetiteljima, što je čest fenomen koji se u literaturi o planiranju katastrofa naziva konvergencijom. U posljednjoj fazi oporavka prioritet je uklanjanje otpada, preseljenje stanovnika i obnova lokalne ekonomije. Navedeni procesi često se protežu kroz nekoliko desetljeća, s obzirom na to da zahtijevaju

velika sredstva i ponekad saveznu ili čak međunarodnu pomoć. Prema istoimenom autoru faza oporavka podijeljena je u četiri razdoblja od kojih svako obično traje deset puta duže od prethodnog. Hitno razdoblje traje dok se ne obnove osnovne službe i dok ne prođe opasnost od sekundarnih učinaka poput potresa. Nakon toga slijedi razdoblje obnove, tijekom kojeg se izbjeglice vraćaju i ulažu se napori za nastavak normalnih ekonomskih i socijalnih aktivnosti. Treće razdoblje, razmjena i obnova, omogućuje lokalnom stanovništvu ne samo obnovu već i poboljšanje njihovih pred-katastrofalnih uvjeta ponovnim obnavljanjem i preuređivanjem.

Katastrofe su također identificirane po brzini njihovog razvoja, javljaju se iznenada bez ikakvog upozorenja, poput tsunamija ili šumskih požara, a događaju se brzo. Spomenuta vrsta katastrofa zahtijeva drugačije mjere pripreme i od onih za katastrofe poput suše ili odstupanja obale. Prirodne katastrofe, ovisno o intenzitetu „udara“ na sustav kao što je turizam, mogu ostaviti drastično negativne posljedice. Istraživanja su pokazala da iako katastrofe ne možemo zaustaviti, njihov utjecaj može biti ograničen od strane privatnog i javnog sektora.

Razumijevanje i upravljanje tim pojavama mogu se poboljšati primjenom proširenja i primjenom teorije i koncepata upravljanja krizama i katastrofama iz drugih disciplina, zajedno s razvojem specifičnih istraživanja i okvira za upravljanje turizmom. Neki od možebitnih razloga porasta prihodnih katastrofa potaknuti su našim okruženjem koje postaje svijetom gužve. Nadalje, stanovništvo koje povećava pritiske poput urbanizacije, širenja ljudskih naselja i veće uporabe i ovisnosti o tehnologiji (Richardson, 1994).

Unazad nekoliko desetljeća turizam biva pogođen raznim krizama i prirodnim katastrofama. Lee i Harrald (1999, str. 184) navode kako „prirodne katastrofe mogu poremetiti lance opskrbe i distribucije; čak i najbolje pripremljena poduzeća koja pružaju uslužne djelatnosti sve su ranjivija zbog kvarova na električnoj, komunikacijskoj ili drugoj kritičnoj infrastrukturi“. Nekolicina autora mišljenja je kako je za porast katastrofa i kriza izravno odgovorno trenutno stanje u svijetu (Blaikie et al., 2014; Berke, 1998). Nadalje, povezivanje geomorfologije (Enciklopedija) i prirodnih katastrofa također je provedeno putem nekoliko istraživanja. Istraživanja povezana s prirodnim opasnostima predstavljaju značaj geomorfologije za polje prirodne katastrofe. Geomorfolozi su zaokupljeni razumijevanjem, analizom i prognoziranjem opasnosti poput poplava, zemljotresa i vulkana. Pristupi za razumijevanje prirodnih katastrofa uključuju proučavanje prošlih događaja (Kale et al., 1997).

Slijedeći Rousseauovu misao, analitičar rizika od katastrofe (Mileti, 1999) navodi te razlikuje tri temeljna čimbenika koji pridonose katastrofi:

(1) potaknuti događaj od prirodne opasnosti (poput potresa koji je pogodio Atlantski ocean izvan Portugala)
(2) stanovništvo izloženo ovom događaju (poput 275.000 građana Lisabona)
(3) ranjivost tog stanovništva.

Tijekom posljednjih nekoliko desetljeća bilježi se stalan porast pojave prirodnih katastrofa što je potaklo na interes za boljim razumijevanjem njihovih učinaka na ekonomski rast i stanovništvo kako bi se kreatori politike informirali o koristima od prirodnih katastrofa i ublažavanjima njihovih negativnih posljedica.

Prema Uredu Ujedinjenih naroda za smanjenje rizika od katastrofa (eng. United Nations Office for Disaster Risk Reduction (UNDRR)) katastrofe su kategorizirane prema dvije temeljne skupine: prirodne i tehnološke (tablica 2). Postoji i treća skupina „Složene katastrofe“ koja uključuje neke velike situacije gladi kojima suša nije bila glavni uzročnik (The international disasters database).

U nastavku poglavlja navedena je tablica 2 koja prikazuje kategorizaciju prirodnih i tehnoloških katastrofa i njihovih podvrsta. Temeljna podjela prirodnih katastrofa dijeli ih na prirodne na koje čovjek ne može utjecati i tehnološke koje nastaju upravo ljudskom pogreškom.

Tablica 2 Klasifikacija katastrofa

Grupa katastrofe	***Podgrupa katastrofe***	***Tip katastrofe***	***Podvrsta katastrofe***	***Podpodvrsta katastrofe***
PRIRODNA	*Geofizički*	Potres	Zemljotres	
			Tsunami	
		Vulkanska aktivnost	Pad pepela	
			Lahar	
			Piroklastički tok	
			Protok lave	
		Masovni pokret		
	Meteorološki	Oluja	Tropska oluja	
			Ekstratropska oluja	

			Konvektivna oluja	Derecho[1]
				Tuča
				Munja/grmljavina
				Kiša
				Tornado
				Pješčana/prašnjava oluja
				Zimska oluja/mećava
				Olujna bura

Tablica 2 (nastavak) Klasifikacija prirodnih katastrofa

				Vjetar
				Jaka oluja
		Ekstremne temperature	Hladna fronta	
			Toplinski val	
			Teški zimski uvjeti	Snijeg/led
				Mraz/zamrzavanje
		Magla		
	Hidrološka	Poplava	Obalna poplava	
			Riječna poplava	
			Bujica	
			Poplava ledenih jama	
		Klizište	Lavina (snijeg, krhotine, blato, pad stijena)	
		Valne akcije	Sirovi[2] valovi	
			Seiche[3]	
	Klimatološka	Suša	Suša	
		Izljev glacijalnog jezera		
		Požar	Šumski požari	
			Kopnena vatra: grm, pašnjaci	

[1] Derecho - široko rasprostranjena, dugotrajna pravolinijska oluja koja je povezana s brzorastućom skupinom jakih grmljavinskih oluja i pojavom pljuskova.
[2] Nazvani još i kao valovi čudovišta, ubojiti valovi, ekstremni valovi, nenormalni valovi. Neobično su veliki, neočekivani i iznenada se pojavljuju te mogu biti izuzetno opasni, čak i na velikim brodovima poput oceanskih.
[3] Stojeći val koji oscilira u vodenom tijelu.

	Biološka	Epidemija	Virusne bolesti	
			Bakterijske bolesti	
			Parazitske bolesti	
			Gljivične bolesti	
			Prionske[4] bolesti	
		Insektne infekcije	Skakavci i kobilice	
			Infekcije uzrokovane životinjama	

Tablica 2 (nastavak) Klasifikacija prirodnih katastrofa

	Izvan-zemaljski	Udar	Zračni napad ili eksplozija u zraku	
		Svemirsko vrijeme	Energetske čestice	
			Geomagnetska oluja	
			Udarni val	
TEHNOLOŠKA	*Tehnološka*	Industrijske nesreće	Kemijsko izlijevanje	
			Kolaps	
			Eksplozija	
			Vatra	
			Curenje plina	
			Trovanje	
			Radijacija	
			Ostalo	
		Razne nesreće	Kolaps	
			Eksplozija	
			Vatra	
			Ostalo	
		Transportne/prometne nesreće	Zrak	
			Željeznica	
			Cesta	
			Voda	

Izvor: izrada autora prema United Nations Office for Disaster Risk Reduction

[4] Prionske bolesti ili transmisivne spongiformne encefalopatije (TSE) su obitelj rijetkih progresivnih neurodegenerativnih poremećaja koji pogađaju ljude i životinje. Odlikuju ih dugi inkubacijski periodi, karakteristične spongiformne promjene povezane s gubitkom neurona i neuspjeh u izazivanju upalnog odgovora.

2.3.6. Zdravstvene krize

Pri definiranju kriza koje se odnose na područje zdravstva, a koje će ujedno biti obuhvaćene u istraživanju, fokus će biti na epidemijama i pandemijama. Pojmovi epidemija i pandemija su u 17. i 18. stoljeću korišteni nejasno i vrlo često međusobno na različite načine u različitim socijalnim i medicinskim okvirima. Riječ pandemija prvi se put spominje u 1666. godini i to kao „pandemik ili endemik, ili vernakularna bolest". Dvjestotinjak godina kasnije, u prvom izdanju Websterovog rječnika epidemiologa i leksikografa, epidemija i pandemija navode se kao sinonimi (Webster, 1828).

Početkom 19. stoljeća izraz epidemija postaje općeprihvaćen pojam za ono što se danas naziva epidemija i pandemija. Razvojem ljudskoga društva evoluiraju i uzroci bolesti kao i znanstveno razumijevanje širenja istih. Pojava industrijske revolucije dovodi do migracije milijuna ljudi u urbane centre, a lokomotive i brodice do širenja sve većeg broja ljudi globalno (Moren, Folkers i Fauci, 2009). „Pandemija kolere koja je harala 1831. – 1832. godine predstavljala je globalno širenje zarazne bolesti za koju je dnevni tisak intenzivno pisao iz dana u dan više od godinu dana. Bolest je napredovala i širila se iz Azije prema Europi. Glavni prijenosnici širenja bili su putnici. Koncept pandemije već je postojao u trenutku pojave pandemije gripe 1889. godine. Pandemija gripe koja se pojavila 1889. i 1918. godine privremeno je odredila značenje riječi pandemija. Ubrzo se pojam počeo koristiti neprecizno i to najčešće s označavanjem velikih pojava neinfluenznih infekcija i kroničnih bolesti povezanih sa životnim stilom. Na taj način pandemija označava gotovo sve što se povećalo i činilo se da se širi unutar ili među skupinama ljudi, poput pušenja, prometnih nesreća, tvorničkih zatvaranja, pa čak i straha." (Dictionary)

Valja spomenuti i bolesti za koje se obično kaže da su pandemije i pokušati ih bolje razumjeti ispitivanjem sličnosti i razlike među njima. Bolesti koje su „empirijski odabrane da održavaju spektar etiologije, mehanizma širenja i razdoblje nastanka uključuju akutni hemoragični konjuktivitis (AHC), AIDS (eng. Acquired Immunodeficiency Syndrome), mangan, bolest zapadnog Nila, pretilost. Gotovo svaka upotreba termina pandemija odnosi se na bolesti koje se šire na velikim geografskim područjima, na primjer kuga u 14. stoljeću koju su nazivali crna smrt, kolera, gripa i virus ljudske imunodeficijencije (HIV/AIDS)" (Moris et al., 2009, str. 1019).

Ne postoji jedinstvena općeprihvaćena definicija termina pandemija, navode Moren et al., (2009). Uobičajene komponente pandemije prema Morensu et al., (2009) su:

- široko geografsko širenje – široko su prostorno rasprostranjene ili su globalne
- kretanje ili širenje bolesti prijenosom koji se može pratiti od lokacije do mjesta
- visoke stope napada i eksplozivnosti (pojavljuju se u više slučajeva u kratkom periodu)
- minimalni imunitet stanovništva
- novosti, oni su novi i/ili povezani s novim varijantama postojećih organizma
- zaraznost, te mogućnost prijenosa s čovjeka na čovjeka.

Konfuzija se i dalje događa, a razlog tomu jest što pojam pandemije može biti senzacionaliziran ili pogrešno shvaćen. Model pandemijskih faza objavljen od strane World Healt Organization (2009) naveden za rješavanje epidemije gripe osmišljen je za informiranje i priopćavanje odgovora javnog zdravlja, a ne za naznačavanje ozbiljnosti neke bolesti (Watson, 2011). Pandemije, epidemije i nove bolesti dugi niz godina postižu transformacijski učinak na okruženje i društvo. Radi se o učinku koji ljudi ne mogu razumjeti, kao na primjer europeizacija Novog svijeta i drugih kolonijalnih osvajanja bez razmatranja prenošenja bolesti Starog svijeta koje su ubile mnoge autohtone stanovnike Amerike, Australije i Tihog oceana (Crosby, 2004). Wolfe et al., (2007) u svom istraživanju navodi kako vodeći uzrok ljudske smrtnosti i društvenog strahopoštovanja predstavljaju takozvane zarazne bolesti koje su dugo pokazivale važne selektivne snage u politici, društvu, ekonomiji i ljudskom stavu prema prirodi, kao i ljudskom genomu.

Epidemija nastaje kada se zarazna bolest brzo širi na mnoge ljude ili drugim riječima kada se evidentira nagli porast broja slučajeva bolesti. Može trajati nekoliko dana ili tjedana, pa čak i nekoliko godina, obuhvaćeno područje može biti unutar zajednice na nekom zemljopisnom području, a može zahvatiti čak i nekoliko zemalja (Association for Professional in Infection Control and Epidemiology). Epidemija predstavlja pojavu koja istovremeno pogađa mnogo ljudi i širi se od osobe do osobe u lokalitetu gdje bolest nije trajno rasprostranjena, odnosno nazivamo je privremena rasprostranjenost bolesti. Metaforički, epidemija je „brzo širenje ili povećanje pojave nečega“ obično s negativnom konotacijom. Na primjer epidemija gentrifikacije utjecala je na zajednice s niskim dohotkom (Dictionary by Farlex).
Epidemija je pojava određenog zdravstvenog ponašanja ili drugih zdravstvenih događaja u nekoj zajednici ili regiji koja prelazi uobičajenu očekivanu vrijednost (World Health Organizaton). Zajednica ili regija te period u kojem se slučajevi događaju precizno su određeni. Broj slučajeva koji ukazuju na prisutnost epidemije varira o uzročniku, veličini i vrsti izložene

populacije, prethodnom iskustvu ili nedostatku izloženosti bolesti te vremenu i mjestu nastanka. Prag epidemije predstavlja razinu pri kojoj se potvrđuje pojava epidemije na nekom području kako bi se pojačale odgovarajuće mjere. Uzorak i brzina kojom se bolest kreće (stopa razmnožavanja) i gustoća osjetljivih domaćina (poznata kao kritična veličina zajednice) mjerni su faktori kojima se određuje postojanje epidemije na nekom području.

Center for Disease, Control and Prevention provodi studiju koja se bavi proučavanjem epidemija. Navode kako je količina određene bolesti koja je obično prisutna u zajednici zapravo početna ili endemična razina bolesti. Navedena razina nije nužno željena razina, koja može biti jednaka nuli, već je promatrana razina. U nedostatku intervencije i pod pretpostavkom da razina nije dovoljno visoka da bi ispraznila bazen osjetljivih osoba, bolest se može nastaviti pojavljivati na ovoj razini unedogled.

S obzirom na navedeno često osnovnu razinu smatraju očekivanom razinom. Epidemiolozi su osobe koje se bave proučavanjem pojave, ponašanja te prevencije epidemije. Na temelju prevalencije bolesti, učestalosti i poznatih ili nepoznatih puteva bolesti, postoji nekoliko načina kako epidemiolog može opisati događaj bolesti (Centers for Disease):

- mjestimičan – odnosi se na bolest koja se javlja rijetko ili nepravilno (Riely, 2019),
- patogeni koji se prenose hranom poput salmonele ili E-coli, često mogu uzrokovati sporadično izbijanje bolesti,
- klaster (Dictionary by Farlex) koji se odnosi na bolest koja se javlja u većem broju iako stvarni broj ili uzorak mogu biti nesigurni. Primjer su velik broj slučajeva s konstatiranim karcinomom, o kojem se često izvještava nakon katastrofe kemijskih ili nuklearnih postrojenja,
- endemija se odnosi na stalnu prisutnost ili uobičajenu rasprostranjenost bolesti ili infektivnih uzročnika u populaciji unutar geografskog područja (Riely, 2019),
- hipendemija (Center for Strategic & International Studies) se odnosi na trajnu, visoku razinu bolesti koja je znatno viša od onoga što je vidljivo u drugim populacijama. Na primjer, HIV je hiperendemičan u dijelovima Afrike, gdje je jedna od petero odraslih osoba zaražena spomenutom bolešću, a endemičan u SAD-u, gdje je HIV-om zaražena jedna od 300 odraslih osoba.
- epidemija (Merriam-Webster dictionary) se odnosi na nagli porast broja slučajeva bolesti iznad onoga što se obično očekuje,

- izbijanje (World Health Organization) nosi istu definiciju kao epidemija, no često se koristi za opisivanje ograničenog geografskog događaja,
- pandemija (Association for Professional in Infection Control and Epidemiology) se odnosi na epidemiju koja se proširila na više zemalja ili kontinenata, a obično pogađa velik broj ljudi,
- hiperepidemija se odnosi na trajne, visoke razine pojave bolesti.

Iako je evidentan napredak u javnom zdravstvu, paralelno je evidentno i postupno povećanje prijetnje od pandemija, posebice od druge polovice dvadesetog stoljeća. Na prvom mjestu kao razlog navedenom jest proces globalizacije i globalnih promjena kojih su putovanja i turizam sastavni dio (Allen et al., 2017).

Nekoliko je faktora utjecalo na povećanje rizika od pandemije:

- visok stupanj urbanizacije s više od polovice svjetskog stanovništva koje živi u urbanim centrima (Connolly et al., 2020)
- iznimno dobra povezanost gradskih središta (zrakoplovna, željeznička, pomorska i cestovna povezanost). Putnik, a samim time i bolest može putovati iz jednog urbanog centra u drugi za jedan dan (Connolly et al., 2020)
- rastuća potražnja za mesom, uništavanje divljine i gubitak biološke raznolikosti dovode ljude u bliži kontakt sa životinjskim patogenima koji se, kada jednom uđu u gradsku populaciju, mogu brzo raširiti (Mossoun et al., 2015).

Epidemija predstavlja pojavu koja istovremeno pogađa mnogo ljudi i širi se od osobe do osobe u lokalitetu gdje bolest nije trajno rasprostranjena (Dictionary by Farlex).
World Health Organization navodi kako je „epidemija pojava određenog zdravstvenog ponašanja ili drugih zdravstvenih događaja u nekoj zajednici ili regiji koja prelazi uobičajenu očekivanu vrijednost. Zajednica ili regija te period u kojem se slučajevi događaju precizno su određeni. Broj slučajeva koji ukazuju na prisutnost epidemije varira o uzročniku, veličini i vrsti izložene populacije, prethodnom iskustvu ili nedostatku izloženosti bolesti te vremenu i mjestu nastanka“. Prag epidemije predstavlja razinu pri kojoj se potvrđuje pojava epidemije na nekom području kako bi se pojačale odgovarajuće mjere. Uzorak i brzina kojom se bolest kreće (stopa razmnožavanja) i gustoća osjetljivih domaćina (poznata kao kritična veličina zajednice) mjerni su faktori kojima se određuje postojanje epidemije na nekom području.

2.3.7. Cijena nafte

„Naftno čudo učinilo je dvadeseto stoljeće neviđenim razdobljem za bogatstvo i osobnu slobodu u razvijenim narodima, promijenivši gotovo svaki aspekt načina na koji živimo, putujemo i jedemo“ (Simmons, 2005, str. 342). Volatilnost cijena odnosi se na stupanj rasta cijena ili pada tijekom nekog vremena. Na učinkovitom tržištu cijene odražavaju poznate i očekivane buduće okolnosti ponude i potražnje i čimbenike koji bi mogli utjecati na njih.

Kad se tržišne cijene mijenjaju tijekom relativno kratkog vremena, za tržište se kaže da ima visoku volatilnost. Kada prevladavaju relativno stabilne cijene, tržište će imati nisku volatilnost (Chatziantoniou et. al, 2013). Energetska tržišta bilježe imovinu koju čine velike investicije izražene u milijunima i milijardama. Upravo sposobnost tih ulaganja s ciljem da se ostvari povrat ovisi o sposobnosti proizvodnje goriva ili energije kako bi se prodali po održivoj cijeni. Budući da tvrtke ulažu na temelju očekivanja u pogledu cijena, visoka volatilnost cijena stvara nesigurnost i rizik, a premije rizika rastu kako bi se nadoknadile. Volatilne cijene također mogu utjecati na tržište rada, povećavajući privremena otpuštanja ili kroz poticanje zapošljavanja (Simmons, 2006).

Nestabilnost energetskih tržišta, što je čest slučaj s tržištem nafte, promjene u ukupnim troškovima iz godine u godinu mogu predstavljati značajan zaokret za gospodarstvo. Kad kućanstva odjednom moraju platiti više troškova energije, u proračunima kućanstava dostupno je manje novaca za druge konkretne potrebe. A s velikim dijelom naše uporabe energije koji se sastoji od uvoza goriva, volatilnost na tržištima predstavlja iznenadne i velike pomake (Institute for 21st Century Energy). Visoke cijene nafte čine cestovni, zračni i pomorski promet skupljim, što posljedično utječe na smanjenje želje za putovanjem i kupovinom u slobodno vrijeme (Jalkh, Bouri i Dutta, 2020; Shahzad i Coporin, 2019). Isprepletenost prometa i turizma čini turizam uvelike ovisnim o nafti i njenim derivatima (Becken, 2011). Turisti se kreću između mjesta podrijetla i odredišta koristeći usluge koje često nude tvrtke povezane s turizmom, a odluke o kupnji turističkih usluga mogu dijelom biti potaknute fluktuacijama cijena nafte.

U razdobljima velikih cjenovnih oscilacija duža putovanja postaju manje atraktivna. Unatoč važnosti nafte, modeli koji prognoziraju prihode od turizma ili kretanje cijena dionica povezanih s turizmom rijetko razmatraju utjecaj varijacija u cijenama nafte. Promjene u cijeni

nafte mogu naštetiti turističkim aktivnostima zbog utjecaja cijena nafte na raspoloživi dohodak, troškove proizvodnje, transporta i ekonomsku nesigurnost. Više cijene nafte čine turizam skupljom aktivnošću i negativno utječu na globalnu turističku potražnju (Yeoman et al., 2007). Zalik (2010) navodi tri glavna izazova povezna s naftom:

(1) rastuća potražnja iz Indije i Kine
(2) pad konvencionalnih izvora nafte
(3) zabrinutost zbog klimatskih utjecaja stakleničkih plinova.

2.3.8. Volatilnost tečaja

Turizam je značajan izvor prihoda od usluga u mnogim zemljama. Snažna domaća valuta može imati negativne učinke na međunarodne dolaske turista kroz mehanizam cijena i raspoloživih sredstava za potrošnju. Empirijska istraživanja ističu važnost tečaja kao varijable pri modeliranju turističke potražnje (Karimi, Khan i Karamelikli, 2019), bilo u kombinaciji s relativnim cijenama kao stvarnim efektivnim tečajem ili zasebno (De Vita, 2014; Muhammad i Andrews, 2008). U situaciji domaće inflacije i aprecijacije domaće valute u odredišnoj zemlji turisti moraju više potrošiti kako bi kupili istu robu i usluge što posljedično utječe na smanjenje privlačnosti odredišta. Deprecijacija domaće valute može povećati spremnost turista za putovanjem (Gan, 2015).

McKenzie (1999, str. 71) navodi kako je raspad Bretton-Woodsovog[5] sporazuma nagovijestio „dolazak nove ere za globalnu ekonomiju u kojoj će mnoge velike svjetske trgovinske sile prihvatiti režim određivanja promjenjivog tečaja. Ekonomisti su *laissez-faire* pristup određivanju tečaja prihvatili kao novu paradigmu. Nisu svi bili takvog razmišljanja, neki su tvrdili da će prijelaz na slobodno promjenjive tečajeve negativno utjecati na svjetsku trgovinu. Njihova se argumentacija temeljila na ideji da će izvoznici skloni riziku smanjiti svoju proizvodnju kada se suoče s povećanjem volatilnosti tečaja uzrokovanog prelaskom na promjenjive tečajeve. Volatilnost tečaja u tom se smislu može definirati kao rizik povezan s neočekivanim kretanjima tečaja“.

Troškovi prijevoza, koji ujedno pripadaju u skupinu ukupnih troškova putovanja do finalnog odredišta, negativno su povezani s turističkim tokovima (Agiomirgianakis, 2015). U studiji provedenoj od strane Webbera (2001) volatilnost tečaja biva prepoznata kao signifikantna

[5] Bretton Woodsovim sporazumom 1944. godine uspostavljen je novi globalni monetarni sustav. Zamijenio je zlatni standard američkim dolarom kao globalnom valutom. Time je utvrdio Ameriku kao dominantnu silu u svjetskoj ekonomiji. Nakon potpisivanja sporazuma Amerika je bila jedina zemlja koja ima mogućnost ispisivanja dolara (Federal Reserve History).

odrednica dugoročne turističke potražnje budući da u nekim slučajevima volatilnost tečaja može biti povezna s političkom nestabilnošću ili društvenim nemirima u odredišnoj zemlji koji mogu odvraćati turiste.

3. ULOGA MEĐUNARODNOG TURIZMA U GLOBALNOJ EKONOMIJI

Počeci 21. stoljeća vežu se uz turizam koji se pretvara u globalni fenomen današnjice koji postaje moćna komponenta gospodarskog razvoja i čimbenik oblikovanja imidža mnogih zemalja (Hall, 2019). Globalizacija je dovela do povećanja međuovisnosti između zemalja, ljudi i gospodarstva. Taj proces također dovodi i do stvaranja te djelovanja globalnog turističkog tržišta i turističkih destinacija od kojih se očekuje da će ravnopravno konkurirati jedna drugoj bez obzira na zemlju podrijetla te da funkcioniraju interaktivno (Perić, 2005). U nastavku poglavlja slijedi prikaz ekonomskih i socio-kulturnih učinaka turizma, kao i prikaz učinaka turizma na njegovo okruženje, odnosno okoliš.

3.1. Ekonomski učinci turizma na svjetsko gospodarstvo

Turizam kao važna gospodarska aktivnost u velikom broju zemalja donosi prihode, no uz to također razvija infrastrukturu, razvija nova radna mjesta i mogućnost ulaganja (Nadeem et al., 2020). Njegova važnost ogleda se u području ekonomije, kulture i društva (International Labor Organization, 2013). Međunarodni turizam predstavlja osnovni izvor rasta mnogih zemalja (Brakke, 2004), a smatra se jednom od poluga globalizacije (Ranabhat, 2015). Turizam nije samo pokretač gospodarskog rasta (Fayissa, Nsiah i Tadasse, 2007; Martins, Gan, Ferreira-Lopes, 2017) već i izvoza (Adnan Hye, Ali Khan, 2013) i to posebno za one zemlje koje su blagoslovljene prirodnim ljepotama (Pablo Romero i Molina, 2013; Chaisumpunsakul i Pholphirul, 2017).

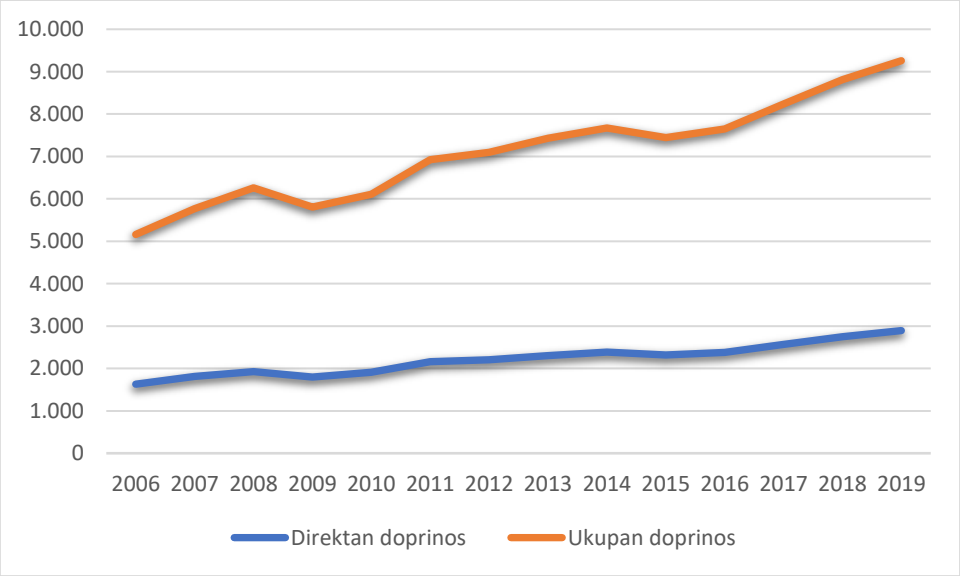
Mnoga znanstvena istraživanja u predviđanju međunarodne turističke potražnje koriste varijable poput tečaja, BDP-a u zemlji podrijetla, indeksa potrošačkih cijena (CPI), prihoda, troškova prijevoza, posebnih događaja, stope kriminala, vremenskih uvjeta, veličina stanovništva (Hiemstra i Wong 2002; Kim i Qu 2002; Tan i Wong 2003), stope nezaposlenosti, novčane mase (Halicioglu, 2010; Smeral, 2012; Seetaram, Forsyth i Dwyer, 2016).

Prilikom mjerenja utjecaja turizma na nacionalna gospodarstva moraju se definirati izravni, neizravni i inducirani učinci turističke potražnje. Izravni učinci odnose se na dodanu vrijednost u sektoru, lokalne poslovne transakcije i poreze. Izjednačeni su s ukupnim prometom u turističkom sektoru, ne računajući iznos izgubljenog novca zbog uvoza robe i isplate dobiti subjektima izvan nacionalnog gospodarstva. Neizravni učinci mjere sve kupovine iz drugih industrija u nacionalnom gospodarstvu potrebne za postizanje rezultata turističke aktivnosti.

Inducirani učinci nastaju kao rezultat povećane potrošnje unutar nacionalnog gospodarstva. Ta potrošnja doprinosi povećanju dohotka, od čega se dio troši na druge proizvode i usluge proizvedene u nacionalnom gospodarstvu (Vanhove, 2005, str. 183-184).

U nastavku (grafikonu 1) prikazan je direktan i ukupan doprinos međunarodnog turizma u BDP-u ostvaren od putovanja i turizma. Iz grafikona 1 vidljiv je uzastopan rast unazad nekoliko godina. Direktni doprinos turizma svjetskom BDP-u iznosio je nešto manje od 2.893 milijarde američkih dolara u 2019. godini. Nasuprot tome, ukupni doprinos svjetskom BDP-u za 2019. godinu iznosi nešto više od 9.258 milijardi američkih dolara.

Grafikon 1 Ekonomski doprinos od putovanja i turizma u svjetskom BDP-u od 2006. do 2019. godine (u milijardama $)



Izvor: izradila autorica prema podacima STATISTA

Zbog tih međusobno ovisnih struktura, svaka promjena turističke potražnje utječe na nacionalno gospodarstvo na različite načine i uzrokuje promjene u gospodarstvu, nivou zaposlenosti i vladinim prihodima. Značajan doprinos turizma BDP-u u nekim zemljama iznosi više od 25 – 30% (Abuharris, 2005). Mjerenje tih učinaka predstavlja vrlo složen zadatak zbog višestrukog i višerazinskog karaktera kojim turizam doprinosi nacionalnim ekonomijama.

Kumulativni učinak prihoda od turizma kroz izravne, neizravne i inducirane učinke opisan je korištenjem multiplikatora prihoda od turizma, koji pokazuje odnose između dodatne jedinice turističke potrošnje i promjena koje rezultiraju u visini prihoda u gospodarstvu (Vanhove,

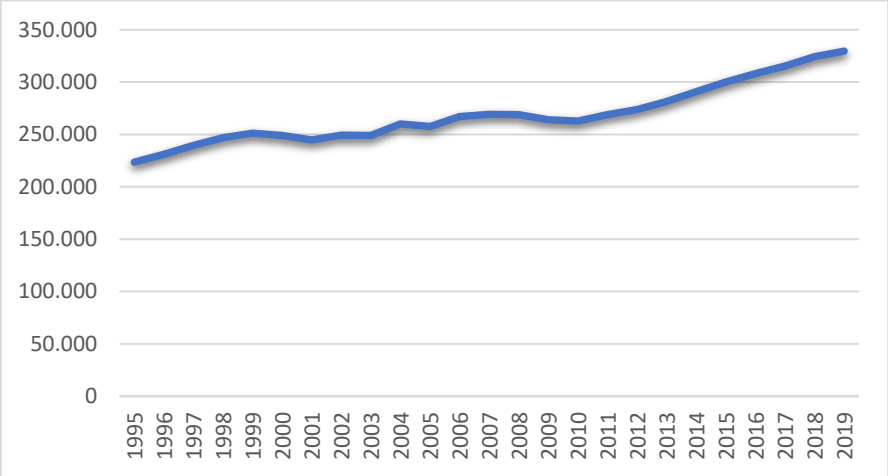
2005:185). Kao što je već navedeno, većina empirijskih istraživanja ističe pozitivan učinak turizma na gospodarski razvoj kroz državne prihode, zaposlenost, infrastrukturu, širi društveno-ekonomski rast i diversifikaciju gospodarskih aktivnosti (Li, Blake i Cooper, 2011). Hipoteza rasta temeljena na turizmu (engl. tourism-led growth hypothesis) široko je potvrđena u empirijskim studijima Balageer i Cantavella-Jorda (2002), Durbarry (2004), Skerritt i Huybers (2005), Kim et al., (2007), Lee i Chang (2008), Seetanah (2011), Dogru, McGinley, Kim (2020), Gnangnon (2020), Wahyuni, Sara (2020). S druge strane Oh (2005) i Katircioglu (2009) nalaze malo dokaza koji podupiru hipotezu o gospodarskom rastu induciranim turizmom.

Adamou i Clerides (2010) ističu da doprinos turizma gospodarskom rastu ovisi o razini turističke specijalizacije te se stoga odnos između turizma i gospodarskog rasta ne bi trebao smatrati linearnim. Njegov ekonomski značaj širom svijeta bio je razlog zbog kojeg su mnoge zemlje odabrale turizam kao ključnu opciju za gospodarski rast.

Važnost turizma dokumentirana je u izvješću Svjetskog vijeća za putovanja i turizam (2019) (engl. World Travel and Tourism Council – WTTC) iz kojeg je kvantitativno prikazan utjecaj na gospodarstvo. Pojava koja se sastoji od širokog spektra aktivnosti namijenjena je usluživanju i pružanju podrške domaćim, međunarodnim i poslovnim posjetiteljima. Prema podacima Svjetskoga vijeća za putovanja i turizam, u 2019. godini turizam je činio 10,3% svjetskog BDP-a i osiguravao 330 milijuna radnih mjesta (10% ukupne zaposlenosti) (citat). Međunarodni dolasci turista širom svijeta porasli su za 4% u 2019. godini te dosegli 1,5 milijardi dolazaka. Stopa rasta međunarodnih dolazaka u 2019. bila je nešto manja u odnosu na prethodne godine – 2017. godina +7% i 2018. godina +6%. Analizirana (2019.) godina pokazuje da sve regije u svijetu bilježe porast dolazaka: Bliski istok (+8%), Azija i Tihi ocean (+5%), Europa (4%), Afrika (+4%) te Amerika (+2%) (WTTC, 2019). Usporedivši pokazatelje s prethodnom 2018. godinom vidljiv je pomak u 2019. godini i to u povećanju radnih mjesta. U 2018. godini oko 319 milijuna radnih mjesta bilo je izravno ili neizravno vezano uz turizam što predstavlja 1/5 svih globalnih neto radnih mjesta stvorenih u posljednjih pet godina u turizmu, dok se u 2019. godini taj broj povećao na 1/4 (World Travel & Tourism Council – WTTC).

U nastavku slijedi grafikon 2 koji obuhvaća podatke o radnim mjestima generiranim iz turističkih aktivnosti. Iz grafikona je vidljivo uzastopno povećanje radnih mjesta u području turizma unazad dvadesetak godina. Tijekom promatranog perioda vidljiv je i primjetan pad koji se povezuje s periodom financijske krize 2008. godine.

Grafikon 2 Radna mjesta generirana direktno, indirektno i potaknuto od strane turizma i putovanja



Izvor: izrada autorice prema dobivenim podacima od strane World Travel & Tourism Organization (WTTC)

3.1.1. Pozitivni ekonomski učinci turizma

Pozitivnim ekonomskim učincima turizma smatraju se aktivnosti koje u kvantitativnom smislu pozitivno utječu na rast gospodarstva kroz varijable kao što su BDP, zaposlenost, potrošnja te kapitalne investicije.

Turizam djeluje kao „gurajući“ faktor na gospodarske aktivnosti u zemlji kao što su razina prihoda i stopa zaposlenosti (Hawkins, 1982; Adrian, 2017). Do sličnoga zaključka dolazi i Kreag (2001) koji objašnjava kako rast turizma pozitivno utječe na povećanje interesa zajednice, što pak pozitivno utječe na turističku vrijednost u zemlji. Autor navodi deset pozitivnih učinaka koji se ostvaruju putem turizma:

- veći dohodak i postizanje višega životnog standarda
- poboljšanje lokalnoga gospodarstva
- povećavanje mogućnosti zapošljavanja
- ulaganje, razvoj i korištenje infrastrukture
- povećanje poreznih prihoda
- razvoj komunalne infrastrukture
- razvoj prometne infrastrukture
- rast potrošnje
- ekonomski utjecaj (izravna, neizravna i potaknuta potrošnja) u zajednici i
- stvaranje novih poslovnih prilika.

Hall (2007) navodi sljedeće pozitivne utjecaje turizma:

- Međunarodni turizam ostvaruje devizne prihode.
- Ulazni trošak za posjetitelje predstavlja: prihode od oporezivanja, prihode za tvrtke, kupovina više roba i usluga.
- Prihodi povezani s turizmom mogu se koristiti za poboljšanje infrastrukture i usluga koje se pružaju u destinaciji kao što su ceste, zračne luke i protupožarna zaštita te druge atrakcije kao što su parkovi i kazališta.
- Ulagački imidž destinacije također se može poboljšati razvojem, privlačenjem poduzeća ili novih stanovnika koji traže veću kvalitetu života.
- Turizam pruža način diversifikacije ekonomske osnove zajednice, posebno kada se zajednica uvelike može osloniti na uzak niz aktivnosti ili usluga.
- Turizam dovodi do otvaranja novih radnih mjesta.

Vellas (2011) navodi direktne i indirektne utjecaje turizma na ekonomski rast. Kao direktne utjecaje navodi: smještaj, restorane, transportne usluge, kulturne objekte, slobodno vrijeme i zabavu te pružanje raznih usluga, s druge strane neizravni učinci tiču se međupotrošnje za proizvodnju dobara i usluga u sektoru turizma. Riječ je o robama i uslugama koje turističke tvrtke kupuju od svojih dobavljača, čineći turistički lanac opskrbe. Neizravni učinci mogu biti osobito važni za proizvodnju domaćih proizvoda. Takozvane *frontline* tvrtke donose početne odluke o kupnji koje određuju što posjetitelji mogu konzumirati.

Slično prethodno navedenim istraživanjima Brida, Cortes-Jimenez i Pulina (2017) zaključuju kako turizam djeluje na dugoročan ekonomski rast putem sljedećih kanala:

- Turizam je signifikantan izvor deviznih prihoda.
- Turizam potiče investiranje u infrastrukturu, ljudski kapital i tehnološki razvoj.
- Turizam putem direktnih, indirektnih i induciranih učinaka pozitivno djeluje na druge djelatnosti.
- Turizam pozitivno utječe na povećanje stope zaposlenosti, a posljedično tome i na povećanje dohotka stanovništva.
- Turizam pozitivno utječe na ekonomiju razmjera i obujma.
- Turizam pozitivno utječe na značajan i brz rast BDP-a koji, posljedično, pozitivno utječe na još češća međunarodna kretanja.

WTTC (2019) navodi četiri temeljne kategorije kroz koje turizam utječe na ekonomski rast. Tablica 3 prikazuje spomenute kategorije podijeljene na direktan, indirektan, inducirani i ukupan utjecaj putovanja i turizma (engl. Travel & Tourism – T&T).

Tablica 3 Klasifikacija ekonomskih utjecaja turizma prema World Travel & Tourism Organization

DIREKTAN UTJECAJ	***INDIREKTAN UTJECAJ***	***INDUCIRANI UTJECAJ (potrošnja direktnih i indirektnih zaposlenika)***	***UKUPAN UTJECAJ***
ROBA	Troškovi ulaganja u T&T	Hrana i piće	Na BDP
Smještaj	Vladini kolektivni troškovi za T&T	Rekreacija	Na zaposlenost
Prijevoz	Utjecaj potrošnje dobavljača	Odjeća	
Atrakcije		Kuća/stan	
Zabava		Proizvodi za domaćinstvo	
INDUSTRIJA			
Usluge smještaja			
Usluga hrane i pića			
Trgovina na malo			
Prijevozne usluge			
Kulturne, sportske i rekreacijske usluge			
IZVORI POTROŠNJE			
Potrošnja domaćih turista na T&T povezana s odmorom			
Potrošnja domaćih turista na T&T povezana s poslovnim putovanjem			
Potrošnja inozemnih turista			
Individualna potrošnja države na T&T			

Izvor: izrada autorice prema uzoru na World Travel & Tourism Organization, (2019)

Uz pregršt pozitivnih utjecaja turizma koji su evidentni i potvrđeni od strane mnogih istraživanja, treba navesti i drugu stranu, onu negativnu. Turizam kao aktivnost također donosi i ima negativne utjecaje koji će biti prikazani u nastavku rada.

3.1.2. Negativni ekonomski učinci turizma

Osim pozitivnih učinaka turizma valja istaknuti i negativne posljedice koje turizam ostavlja na gospodarstvo, okoliš i društvo. S jedne strane turizam pozitivno utječe na kreiranje novih radnih mjesta, ali s druge strane negativno utječe na zaposlenost u nekim tradicionalnim primarnim djelatnostima kao što su poljoprivreda, šumarstvo i rudarstvo (migracija ovih zaposlenika u uslužne djelatnosti). Također treba napomenuti i izvansezonsku nezaposlenost koja predstavlja problem nositeljima lokalne i državne politike.

Butler (2001) ističe kako upravo sezonalnost predstavlja temeljni problem zbog ograničenja perioda unutar kojeg turisti mogu putovati odnosno posjetiti određenu turističku destinaciju, kao na primjer sunce i more unutar ljetnih mjeseci, a zimske aktivnosti unutar zimskih mjeseci. Istoimeni autor uz sezonalnost navodi povećanje cijena proizvoda u vrijeme sezone što negativno utječe na lokalno stanovništvo kod kojeg standard ostaje isti. Potražnja za određenim proizvodom ili uslugom se povećava što dovodi do povećanja cijena. Posljedično navedenom, dolazi do povećanja cijena smještaja, odjeće, transportnih usluga, hrane i pića i slično.

Nadalje, istraživanja Tsai, Huang i Li (2016) pokazuju kako uz sve navedeno dolazi i do povećanja cijena stambenih nekretnina, što također negativno utječe na lokalno stanovništvo. Veći stupanj razvoja turizma u destinaciji dovodi do prepoznatljivog destinacijskog imidža koji povećava turističku potražnju što rezultira višim cijena nekretnina. U nastavku se navode istraživanja raznih autora koja navode načine putem kojih sve turizam može negativno utjecati na razvoj gospodarstva i lokalnih zajednica.

Prema Kreag (2001) negativni se učinci mogu odraziti na sljedeće načine:

- povećanje cijena robe i usluga
- povećanje cijena zemljišta i stanovanja
- povećanje životnih troškova
- potencijalno povećanje uvoza radne snage
- dodatni trošak za komunalnu i javnu infrastrukturu (voda, kanalizacija, električna energija, gorivo)

- uvećani trošak održavanja prometne infrastrukture
- sezonalnost koja je karakteristična za turizam stvara visoki rizik (kroz nezaposlenost)
- konkurencija za zemljišta s drugim gospodarskim korisnicima
- izvoz dobiti od strane ne-lokanih vlasnika i
- nisko plaćeni poslovi.

Hall (2007) u kategoriji negativnih učinaka koji se ostvaruju putem turizma navodi pet temeljnih kanala putem kojih se isti ostvaruju:

- povećana stopa kriminala u turističkim destinacijama dovodi do povećanja potrošnje za prevenciju kriminala i policijskih usluga
- oportunitetni trošak, iz razloga što ulaganje u turizam ostavlja manju količinu novca za druge investicije
- obećanja o dobiti i zapošljavanju gube na značenju zbog propuštanja i slabo plaćenog posla
- radna mjesta u turizmu mogu se smatrati „lošima“ zbog sezonalnosti (nezaposlenost izvan sezone).

Vukadinović i et al., (2017) navode sedam kanala putem kojih turizam kao aktivnost negativno utječe na razvoj gospodarstva:

- velika ovisnost o turizmu
- povećani životni troškovi u obliku smještaja, hrane i usluga
- zbog povećane koncentracije ljudi dolazi do većeg zagađenja okoliša te prometnih zagušenja
- nacionalne tvrtke dominiraju na turističkom tržištu
- izražena osjetljivost poslovnih ciklusa te promjene poslovnog stava
- niska kontrola razvoja turizma
- neprihvatljiv oblik i obujam razvojne invazije na otvorene prostore.

3.2. Socio-kulturni učinci turizma

Socijalni učinci turizma najčešće su posljedica razvoja turizma ili prisutnosti turista u destinaciji. Spomenuti učinci nastaju kao ishod interakcije turista, lokalnog stanovništva i kulturnih lokaliteta. Socijalni i kulturni utjecaji turizma mogu se promatrati kroz dimenziju pozitivnih i negativnih učinaka. Interakcija između lokalnog stanovništva i turista može dovesti do kreativnog izražavanja pružanjem novih mogućnosti što se reflektira kroz pozitivne aspekte

ili može dovesti do gušenja individualnosti s novim ograničenjima što reflektira negativne učinke.

Učinak socijalnih učinaka na turistički razvoj proučavali su Ogechi i Oyinkansola (2012). Jedan od ciljeva njihova istraživanja bio je utvrditi kako turističke atrakcije destinacije utječu na društveni život zajednice, a pri istraživanju autori su primijenili analizu varijance (ANOVA, eng. Analysis of variance). Rezultati njihova istraživanja pokazuju da turistički razvoj ima signifikantan utjecaj na društveni i kulturni život lokalnog stanovništva (Ogechi i Oyinkansola, 2012) te da on predstavlja glavni katalizator promjena moralnih vrijednosti lokalnog stanovništva (Zhuang et al., 2019).

Društveno-kulturalni utjecaj turizma prvenstveno se odnosi na ljudski utjecaj fokusiran na promjene u kvaliteti svakodnevnog života stanovnika turističkih destinacija te na promjene kulturnih vrijednosti koje su povezane s transformacijom tradicionalnih vrijednosti, normi i identiteta koji proizlaze iz turističkih aktivnosti (Hashimoto, 2002). Nastavno na navedeno Cooper et al., (2013) tvrde kako su promjene normi i tradicionalnih vrijednosti u kratkom periodu očite, no isto tako autori navode kako postoje i dugoročne i postupne promjene u vrijednostima, kulturnim praksama i vjerovanjima. Jadrešić (1999) navodi kako turizam negativno utječe na kulturni život turističke destinacije na način da potiče razne konfliktne situacije lokalnog stanovništva, turističkih zaposlenika i turista iskrivljavanjem objektivne i subjektivne kulture. Autor zaključuje kako turizam kroz turističku rentu i kroz model brzog bogaćenja ugrožava moralni dignitet čovjeka te razvija osjećaj frustracije i to posebice kod lokalnog stanovništva.

Na primjeru Hrvatske, Kožić (2019) analizira utjecaj razvoja turizma na kvalitetu ljudskog kapitala u hrvatskim gradovima i općinama. Rezultati njegova istraživanja pokazuju kako razvoj turizma može utjecati na pogoršanje ljudskog kapitala. Društveni utjecaj turizma na društveni kapital održivog turizma na primjeru Kine proučavan je od strane Zhang et al. (2021). Provedena studija otkriva kako se društveni utjecaj turizma odnosi uglavnom na tradicionalne vrijednosti, odgovornosti i obveze iz razloga što predstavljaju ključne elemente društvenog kapitala. Primjenom dinamičkog panela Mikulić et al. (2021) analiziraju odnos između turističke aktivnosti i dostupnosti smještaja na uzorku hrvatskih općina. Istraživanje pokazuje prisutnost loših učinaka pojačanog turizma na mogućnost lokalnog stanovništva u kupnji smještaja. Autori ističu kako sezonski karakter ima jak utjecaj koji je vidljiv putem negativnih eksternih učinaka u obliku nestabilnosti prihoda, fluktuacije zaposlenosti, nemogućnosti

održavanja ekonomskog statusa. Pičuljan, Težak Damijanić i Šergo (2018) sagledavaju utjecaje turizma s makrorazine i mikrorazine. U sferi sociokulturnih utjecaja turizma na rezidente, autori ističu pozitivne i negativne utjecaje. Negativni utjecaji istaknuti su kroz povećanje kriminaliteta, propadanje tradicionalne kulture i navika, iskrivljavanje društvenih vrijednosti, prisilnu promjenu načina života, povećanje inozemne radne snage te pogoršanje javne sigurnosti. Pozitivni učinci iskazani su u vidu povećanja animacijskih sadržaja, jačanja imidža lokalne zajednice, jačanja društvenog i kulturnog života rezidenata, upoznavanje novih kultura, jačanja kulturnog identiteta, te jačanja kvalitete javnih usluga.

3.3. Učinci turizma na okoliš

Čist okoliš, bilo da je prirodno stvoren bilo od strane čovjeka, predstavlja važan resurs za turizam. Štetni utjecaji turizma na okoliš mogu biti povezani s ulaganjem u poboljšavanje infrastrukture kao što su prometnice, zračne luke, turistički objekti, turistički hoteli, odmarališta, igrališta, trgovine, restorani.

Prema Wongu (2004, str. 452) štetne utjecaje turizma na okoliš moguće je klasificirati na sljedeći način:

(1) Pritisak na prirodne resurse
- iscrpljivanje izvora energije
- opskrba vodom
- korištenje zemlje
- erozija tla

(2) Šteta za divlje životinje/stanište i gubitak biološke raznolikosti
- uništavanje i čišćenje vegetacije
- gubitak šumskog pokrivača
- izazivanje poremećaja u prirodnom staništu i uznemiravanje divljine
- ugrožavanje koraljnih grebena
- ugrožavanje životnih vrsta

(3) Zagađenje
- zagađenje zraka
- nepročišćene otpadne vode
- kruti otpad i smeće
- zagađenje bukom.

Istraživanje Pickering (2007), na primjeru Australskih Alpa, ukazuje na negativne učinke turizma na okoliš. Naime, menadžeri zaštićenih područja Australskih Alpa ocjenjuju da skijališta i njihova povezana infrastruktura imaju veći negativni utjecaj na susjedna prirodna područja od turističkih aktivnosti izvan odmarališta.

Kreag (2001) navodi pozitivne i negativne utjecaje turizma na okoliš. Autor navodi kako odredišta koja posjeduju prirodne resurse (oceani, slapovi, jezera, flore i faune, planine) privlače turističku potražnju. Turizam se smatra „čistom" aktivnošću temeljenoj na restoranima, hotelima, trgovinama i atrakcijama, no s druge strane može negativno utjecati na okoliš. Posjetitelji direktno mogu štetiti okolišu turističke destinacije stvarajući otpad i zagađivanjem zraka. Degradacija krajolika moguća je uz nekontrolirano posjećivanje ili pretjeranu uporabu krajolika, spomenika ili nalazišta. U nastavku slijedi tablica 4 koja prikazuje pozitivne i negativne učinke prema Kreag (2001).

Tablica 4 Pozitivni i negativni utjecaji turizma na okoliš

POZITIVNI UTJECAJI	**NEGATIVNI UTJECAJI**
Zaštita odabranih prirodnih lokaliteta ili sprečavanje daljnjeg ekološkog propadanja	Zagađenje (zrak, voda, kruti otpad, buka)
Očuvanje povijesnih građevina i spomenika	Gubitak prirodnog krajolika i poljoprivrednog zemljišta u korist razvoja turizma
Poboljšanje izgleda područja	Gubitak otvorenog prostora
Čista aktivnost (u smislu bez dimnjaka i zagađivanja)	Uništavanje flore i faune
	Degradacija krajolika, povijesnih nalazišta i spomenika
	Nedostatak vode
	Unošenje egzotičnih vrsta
	Kršenje ciklusa i ponašanja uzgoja divljih životinja

Izvor: Kreag, (2001, str. 8)

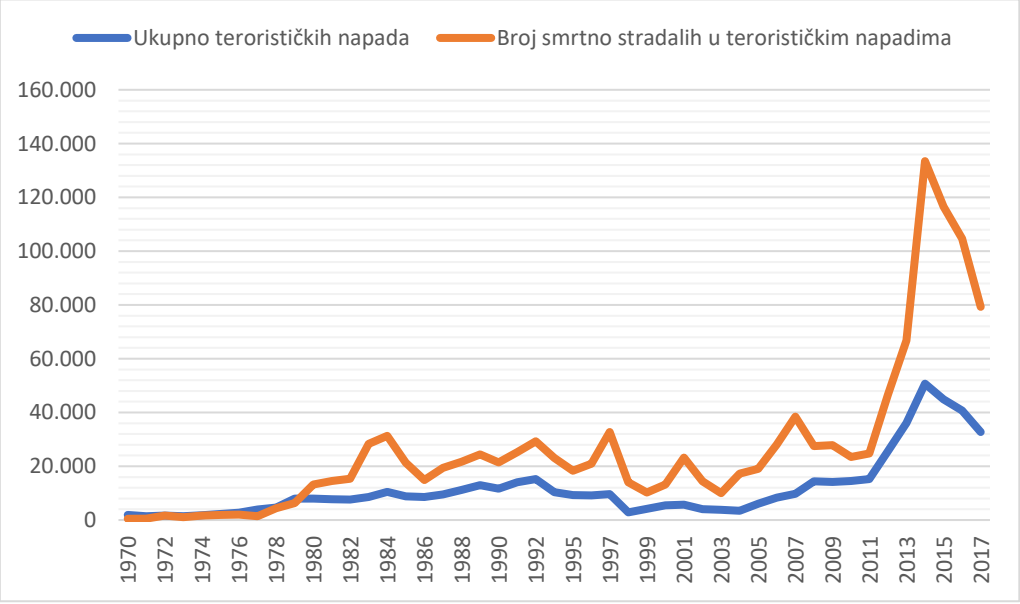
4. UTJECAJ EKSTERNIH ŠOKOVA NA TURIZAM

Promatrajući događaje kroz povijest i dostupnu literaturu može se zaključiti kako je utjecaj eksternih šokova na turizam kao aktivnost tema brojnih istraživanja, a upravo ovo poglavlje donosi pregled rezultata dosadašnjih istraživanja raznih autora na spomenutu temu. Istraživanja novijeg datuma fokusirana su na modeliranje volatilnosti u slučajnim poremećajima kao što je izbijanje eksternog šoka, a taj se interes pripisuje povećanim fluktuacijama globalne ekonomske aktivnosti, klimatskim promjenama, prirodnim katastrofama, kriminalu te terorizmu (Shareef i McAleer 2005).

4.1. Terorizam i turizam

Turistička potražnja je nestabilna i vrlo osjetljiva na rizike vezane uz sigurnost, prirodne katastrofe, rat, terorističke napade i političku nestabilnost (Pizam i Smith, 2000; Ouerfelli, 2008; Saha i Yap, 2014). Vijesti i događaji mogu povećati ili smanjiti turističku potražnju, te na taj način utjecati na razvoj destinacije (Gunduz i Hatemi, 2005; Wang, 2009). Kao što je već u prethodnom poglavlju spomenuto, međunarodni turizam predstavlja jednu od najvećih svjetskih aktivnosti te se mnogo malenih i otvorenih gospodarstava uvelike oslanja na devizne prihode ostvarene od turizma u pogledu temeljnog prihoda. Unazad nekoliko godina na globalnoj razini evidentira se značajan porast terorističkih napada (grafikon 3).

Grafikon 3 Prikaz ukupnog broja terorističkih napada posljednjih 50 godina na svjetskoj razini



Izvor: izrada autorice prema podacima dobivenim od strane Global Terrorism database

Grafikon 3 prikazuje povećanje broja terorističkih napada te porast smrtno stradalih tijekom spomenutih napada na svjetskoj razini. U razdoblju od 1970. do 2018. godine ukupno je evidentirano 545.073 terorističkih napada s ukupno 1.235.604 smrtno stradalih.

Teroristički napadi obično su motivirani unutardržavnim političkim previranjima ili međunarodnim geopolitičkim razlozima (Samitas, Asteriou i Polyzos, 2018). Posljedice koje terorizam ostavlja na aktivnosti vezane uz turizam prvenstveno su vidljive kroz smanjenje dolazaka turista (Drakos i Kutan 2003). Padash i Khodapanah (2018) u svom istraživanju navode kako terorizam u svojoj osnovi predstavlja upotrebu straha, prisile i zastrašivanja kako bi se ostvarili politički i gospodarski ciljevi. Autori tvrde kako u nekim zemljama negativan utjecaj terorizma može povećati političke rizike i dovesti do izolacije tih zemalja od ostatka svijeta. Nakon napada na „World Trade Center“ 11. rujna 2001. godine, sigurnost još više dobiva na važnosti i u spektru turizma iz razloga što turisti prvenstveno žele posjetiti sigurna odredišta koja im mogu pružiti bezbrižnost tijekom njihova boravka (Butnaru et al., 2018).

Danas su teroristički napadi sve češća pojava koja je eskalirala i mjesta koja su donedavno bila sigurna sada su meta terorista. Naime, u razdoblju od 1960. do 1980. godine u Europi se dogodilo samo pet terorističkih napada od čega jedan u Francuskoj, jedan u Njemačkoj te tri u Italiji (Engene, 2011). Istraživanje na primjeru Španjolske, za razdoblje od 1970. do 1988. godine, potvrđuje negativnu vezu terorizma i turizma (Enders i Sandler, 1991). Autori u svom istraživanju koriste vektorsku autoregresiju (VAR) kako bi dokazali da teroristički napadi imaju značajan negativan utjecaj na broj turista koji posjećuju Španjolsku. Veza između terorizma i turizma je jednosmjerna i to smjera terorizam – turizam. Empirijski rezultati ukazuju kako tipičan teroristički napad, a da se pri tomu kontroliraju svi drugi utjecajni elementi, smanjuje broj turista za 140 000. Primjer Kenije potvrđuje negativan učinak terorizma na turističku potražnju (Buigut i Amendah, 2016). Rezultati provedene panel analize pokazuju kako porast smrtnih slučajeva, uslijed terorističkoga napada, od 1% smanjuje dolaske turista za oko 0,13%, što znači gubitak prihoda od turizma u iznosu od 157,1 milijuna kenijskih šilinga.

Jednosmjernu uzročnost u smjeru od terorizma k turizmu, putem VAR modela, potvrđuju Samitas et al., (2018). Godinu dana kasnije Samitas et al., (2018) analiziraju europske zemlje koje ovise o deviznom prihodu ostvarenom od turizma te navode kako zbog terorističkih napada iste mogu ostati bez spomenutih prihoda. U istraživanju koriste ARIMA model s transfernom funkcijom utemeljenom na terorističkim napadima. Istraživanje je provedeno na turističkim

destinacijama Europe: Grčka, Italija, Austrija i kontinentalna Europa. Za svaku državu procijenjen je ukupan gubitak prihoda. Rezultati koje su dobili zapravo su dvojaki, odnosno isti su pokazali kako neke države, kao što je na primjer Francuska koja je svojedobno pretrpjela terorističke napade koji su bili fokusirani na turiste, u konačnici nisu imale značajan utjecaj na turističke prihode. Studija također pokazuje i da su teroristi bili uspješni u odvraćanju od turizma i da je prisutan učinak generalizacije u smislu da incident u jednoj zemlji djeluje negativno i na turizam susjednih zemalja odvraćajući turiste od njihova posjeta.

Terorizam djeluje i na smanjenje prihoda od turizma na što upućuju i dokazi iz Austrije, Grčke i kontinentalne Europe (Enders, Sandler i Parise, 1992). Posljedice terorizma prelijevaju se i na turizam susjednih zemalja. Teroristički akt u jednoj zemlji može rezultirati negativno na turizam cijele regije (Neumayer, 2004). Teroristički napadi koji su fokusirani na turistička odredišta u jednoj zemlji ne smanjuju samo turističke dolaske napadnute zemlje ili zemlje čiji su državljani napadnuti već takvi napadi uzrokuju efekte prostornoga prelijevanja, tj. smanjuju turističke dolaske i kod susjednih zemalja (Neumayer, 2016). Do sličnih zaključaka dolaze i Drakos i Kutan (2003). Autori primjenjuju SURE metodu kako bi istražili mogući negativni utjecaj terorizma na turističku konkurenciju među turističkim destinacija Mediterana – Grčka, Izrael, Turska i Italija. Autori dezagregiraju komponentu terorističkih napada kako bi testirali postoji li statistički signifikantna razlika s obzirom na geografsku lokaciju napada (urbana ili seoska sredina) te intenzitet napada (niski, srednji i visoki). Rezultati njihova istraživanja ukazuju na to da, kada se varijabla terorističkoga napada dezagregira prema intenzitetu, postoji statistički signifikantan učinak terorizma na turizam u samoj destinaciji, ali i značajan učinak prelijevanja na druge destinacije. Dezagregiranje prema geografskoj lokaciji ukazuje da su teroristički napadi u samoj destinaciji značajniji prediktor smanjenja turističkoga udjela u odnosu na učinak prelijevanja.

Bassil (2014) varijablu terorističkoga napada dezagregira s obzirom na intenzitet i porijeklo napada (domaći ili transnacionalni terorizam). Predmet istraživanja su sljedeće turističke destinacije: Libanon, Turska i Izrael. Učinak terorizma na turizam ovisi o intenzitetu terorističkih napada. Temeljem rezultata, autor zaključuje kako postoji negativan učinak prelijevanja terorizma između svih zemalja, osim Libanona u Izrael i Libanona u Tursku. Najveći negativni učinak prelijevanja ide od Izraela prema druge dvije zemlje.
Istraživanje Arana i León (2008) pokazuje kako šok nakon terorističkih napada utječe na donošenje odluke za putovanjem, ali i na preferencije samih turista u pogledu glavnih sastavnica

turističkoga proizvoda. Negativan utjecaj terorizma na turizam realizira se u dugom roku (Feridun, 2011; Arunatilake et al., 2001; Concepcion et al., 2003), u kratkom roku (Masinde et al, 2016) te u dugom i kratkom roku (Raza i Jawaid, 2013; Brunt i Cousins, 2002).

Prema Thompsonu (2011) turizam zemalja u razvoju teže se oporavlja od terorističkih napada. Autor primjenom regresijske analize, na uzorku od 60 zemalja, dolazi do rezultata koji upućuju na veći učinak terorizma na turizam zemalja u razvoju u odnosu na turizam razvijenih zemalja. Porast terorističkih napada od 1% smanjuje dolazak turista po glavi stanovnika za 0,07% u razvijenim zemljama i za 0,38% u zemljama u razvoju. Nepostojanje uzročnosti između direktnih stranih ulaganja u području turizma te terorizma potvrđuju Nikšić Radić, Dragičević i Barkiđija Stošek (2019) te Nikšić Radić (2018). Nadalje, Saha i Yap (2014) analiziraju učinke interakcije političke nestabilnosti i terorizma na razvoj turizma. Istraživači koriste analizu regresije efekata moderatora[6]; panel analizu fiksnih efekata (FE) i slučajnih efekata (RE) te OLS. Rezultati ukazuju kako je učinak političke nestabilnosti na turizam daleko snažniji od posljedica jednokratnih terorističkih napada. Prema autorima, teroristički napadi povećavaju turističku potražnju za zemljama s niskim do umjerenim političkim rizikom, ali uzrokuju značajno smanjenje kada je riječ o zemljama s visokom razinom političkoga rizika.

Prema Freyeru (2007) teroristi u mnogo slučajeva svjesno i namjerno biraju turistički sektor kao metu svojih napada. Vremenska dimenzija bilo u pogledu vremenskog odmaka ili trajanja učinaka nakon terorističkog napada ukazuje da rezultati istraživanja nizu jednoznačni (Enders i Sandler, 1991; Enders et al., 1992; Soboda, 2003; Neumayer, 2004; Pizam i Smith, 2000). Rezultati istraživanja ovise o analiziranom odredištu, vremenskom okviru i vrsti, učestalosti i težini terorističkih napada. Enders i Sandler (1991) i Enders et al., (1992) utvrđuju da je vremenski odmak između terorističkih napada i pada turističkog prometa od 3 do 21 mjeseci. Sloboda (2003) u svom istraživanju procjenjuje da se negativni učinak terorizma na turizam ne smanjuje i godinu dana nakon napada. Analiza Pizam i Smitha (2000) pokazuje da je prosječna dužina pada turizma, nakon terorističkoga napada, od 1 do 3 mjeseca te da učinak terorizma blijedi nakon 6 mjeseci u većini slučajeva. Uz do sada elaborirane utjecaje terorizma na turizam valja napomenuti još neke varijable od interesa kao što su turističke sklonosti i percepcije (Coshall, 2003; Floyd i Pennington-Gray, 2004; Uriely, Maoz, i Reichel, 2007; Araña i León, 2008; Fuchs et al. 2013; Wolff i Larsen, 2014), imidž destinacije odnosno turistički marketing

[6] Moderator effects regresion analysis

i upravljanje (Hurley, 1988; Taylor & Enz, 2002; Stafford, Yu, & Armoo, 2002; Taylor, 2006) te perspektiva ublažavanja terorističkih napada. Ublažavanje terorističkih napada uglavnom se usredotočuje na strategije spremnosti i reakcije, koje mogu spriječiti pojavu samih napada i općenito kroz upravljanje turističkom potražnjom (Walters, Wallin, i Hartley, 2019). Neke od metoda koje se koriste su metoda planiranja scenarija s ciljem predviđanja kako će ekonomsko ponašanje turističkih segmenata vjerojatno utjecati na odredište u raznim uvjetima rata i terorizma (Yeoman, Galt i Mcmahon-Beattie, 2005), opisni prikaz problema i izazova s kojim se odredište suočava u razvoju i provedbi odredišne antiterorističke strategije (Paraskevas i Arendell, 2007).

Većina istraživanja na temu terorizma i turizma temelje se na hipotezi da je terorizam taj koji negativno djeluje na turizam. Radovi Goldman i Neubauer-Shani (2016) te Nikšić Radić, Dragičević i Barkiđija Sotošek (2018) upućuju na to da povećani broj dolazaka turista povećava vjerojatnost terorističkih napada u destinaciji.

4.2. Politička nestabilnost i turizam

Nastavno na prethodno poglavlje, valja spomenuti kako brojna istraživanja ističu vezu između političke nestabilnosti i terorizma. Turizam uspijeva u politički stabilnom i sigurnom okruženju (Sonmez i Graefe, 1998; Santana, 2001; Tarlow i Santana, 2002; Mansfeld i Pizam, 2006; Edgellet al., 2008; Bayar i Yener, 2018; Baig i Zehra, 2020). Većina empirijskih rezultata ukazuje da su zemlje s višom razinom domaće političke nestabilnosti podložne većem obujmu terorističkih aktivnosti (Abadie, 2006; Fahey, 2010; Compos i Gassebner, 2013; Scumacher i Schraeder, 2018).

Teroristički napadi mogu posljedično uzrokovati političku nestabilnost, što dovodi do pada ili nestanka turističke potražnje u nekim turističkim destinacijama (Seddighi et al., 2001; Stafford et al., 2002; Asongu et al., 2019; Saglam i Ampountolas, 2020). Nekoliko studija identificira negativan utjecaj političke nestabilnosti i terorizma na turističku potražnju u raznim destinacijama: Grčka, Izrael i Turska (Drakos i Kutan, 2003); Nepal (Bhattarai et al., 2005); Italija (Greenbaum i Hultquist, 2006); Indija (Bhattacharya i Basu, 2010); Turska (Feridun, 2011); Pakistan (Raza i Jawaid, 2013); Libanon (Bassil et al., 2015); Kenija (Buigut i Amendah, 2016); SAD (Payne i Gil Alana, 2017); Grčka (Samitas et al., 2018); Afrika (Adeola et al., 2018). Politička nestabilnost u određenim regijama utječe na odluku o putovanju turista, a mnoge zemlje izdaju upozorenje svojim građanima (Gan, 2015). Ovo poglavlje nastoji

razjasniti političku dimenziju turizma, doprinoseći i poboljšavajući razumijevanje institucionalnih dimenzija političke nestabilnosti i turizma. Prema Theocharous (2010) turizam je često rezultat politike koja je neraskidivo isprepletena ponekad s nacionalnom politikom, a često s međunarodnom politikom te društvenim i okolišnim pitanjima. Politička stabilnost, mir i sigurnost važne su teme za većinu turista pa se stoga mogu smatrati i ključnim za razvoj turizma (Cui et al., 2016; Seabra et al., 2018).

Pregled postojeće literature otkriva dva glavna smjera istraživanja. Prvo, postoje studije koje istražuju učinke političkih kriza na turističku djelatnost (Drakos i Kutan, 2003; Neumayer, 2004; Arana i Leon, 2008; Causevic i Lynch, 2013; Alvarez i Campo, 2014; Saha i Yap, 2014). Ova istraživanja zaključuju da politička nestabilnost ima negativan utjecaj na turističke dolaske i imidž destinacije. Drugi smjer istraživanja usredotočuje se na utvrđivanje potencijalnih reakcija turista neposredno nakon krize (Hajibaba et al., 2015). Političke krize dovode do izravnog negativnog utjecaja na turizam (Alvarez i Campo, 2014; Neumayer, 2004). Rezultati istraživanja Yap i Saha (2013), na uzorku 139 zemalja, pokazuju da politička nestabilnost ima snažniji negativni utjecaj na turističku potražnju od terorističkih napada i korupcije. Prema autorima, porast političke nestabilnosti za jednu jedinicu uzrokuje smanjenje turističkih dolazaka (24 – 31%) i prihoda (30 – 36%). Isti autori međudjelovanje političke nestabilnosti i terorizma na razvoj turizma prikazuju i godinu dana kasnije (Saha i Yap, 2014) s uzorkom od 139 zemalja primjenjujući PANEL analizu. Autori su u svom istraživanju prikazali u kojoj mjeri politički sukobi i terorizam u zemlji mogu negativno utjecati na njenu turističku aktivnost. Njihovi rezultati pokazuju kako je učinak političke nestabilnosti na turizam daleko teži od posljedica jednokratnih terorističkih napada. Uz navedeno rezultati ističu da teroristički napadi povećavaju turističku potražnju u zemljama s niskim do umjerenim političkim rizikom, dok smanjuju kod zemalja s visokim političkim rizikom.

Posljedice ratnih i političkih sukoba na turističku potražnju mnogo su veće od utjecaja terorističkih napada (Neumayer, 2004; Mansfeld i Pizam, 2006; Fletcher i Morakabati 2008; Saha i Yap 2014). Građanski ratovi mogu imati trajne efekte na turizam za razliku od terorističkih napada čiji su učinci prolazni. Hamadeh i Bassil (2017), na primjeru Libanona, istražuju utjecaj terorističkih napada i sirijskoga građanskoga rada na turizam. Autori koriste GARCH model, a rezultati pokazuju značajan negativan granični učinak terorizma na turističku potražnju međunarodnih i arapskih dolazaka, ali pozitivni učinak na turističku potražnju europskih dolazaka. Autori zaključuju da sirijski građanski rat ima trajan učinak na turističku

aktivnost u Libanonu, a da su učinci terorizma samo privremeni. Novija istraživanja (Dibeh et al., 2020) na primjeru Libanona u suprotnosti su s prethodno navedenim rezultatima. Autori u svom radu testiraju postojanje hipoteze gospodarskoga rasta temeljene na turizmu (engl. tourism-led growth hypothesis – TLGH) i postojanje hipoteze rasta turizma temeljene na rastu gospodarstva (engl. growth-led tourism hypothesis – GLTH) kontrolirajući pritom nestabilnost uzrokovanu sirijskom krizom. U članku su korištene sljedeće varijable: mjesečni bruto domaći proizvod, broj turističkih dolazaka, broj sirijskih izbjeglica te broj stradalih u Libanonu i Siriji. Rezultati pokazuju kako je libanonska ekonomija bila otporna na političku nestabilnost nastalu zbog sirijske krize.

Dramatične fluktuacije zbog promjena u ekonomskom, financijskom i političkom okruženju doživljava međunarodna turistička potražnja Australije. Rad Chan, Lim i McAleer (2005) modelira uvjetnu i srednju varijancu logaritma mjesečne stope dolaska turista iz četiri vodeće zemlje izvora turizma u Australiji. Radi se o Japanu, Novom Zelandu, Velikoj Britaniji i SAD-u. Autori pri tome koriste CCC (eng. constant conditional correlation volatility model) model, točnije CCC-MGARCH (MGARCH eng. multivariate generalized autoregressive conditional heteroskedasticity) model i ARMA-GARCH (eng. ARIMA – Autoregressive Moving Average, eng. GARCH – Generalized Autoregressive Conditional Heterocedasticity). Rezultati sugeriraju prisutnost međuovisnih učinaka u uvjetnim varijacijama između četiri vodeće zemlje i asimetrične učinke šokova u dvije od četiri zemlje. Dobiveni rezultati naglašavaju međuovisnost između glavnih zemalja izvora turizma, kao i asimetrične učinke pozitivnih i negativnih šokova u turističkoj potražnji.

Politička nestabilnost ima široke učinke na turističku aktivnost ne samo u zemlji u kojoj se događa već i u susjednim državama (Henderson, 2004). To potvrđuje primjer Turske i smanjenja broja međunarodnih dolazaka tijekom rata u Iraku 2003. godine (Eryigit et al., 2010). Smanjenje turističke potražnje može biti uvjetovano nizom različitih nepoželjnih političkih faktora (kršenje ljudskih prava, sukoba i drugih političkih/nasilnih događaja) (Neumayer, 2004).

Turisti izbjegavaju odlaske u politički nestabilne turističke destinacije koje njima izazivaju osjećaje nelagode (Clements i Georgiou. 1998; Llorca-Vivero, 2008). Turizam se često opisuje kao učinkovit instrument koji promiče mir i koji je pokretač kulturnog razumijevanja među narodima. Putovanja mogu smanjiti napetost i uskladiti odnose između društva koja su prošla

kroz dugotrajni sukob, poboljšavajući negativne percepcije i stavove posjetitelja prema posjećenoj zajednici (Guo et al., 2006; Chen, 2010; Durko i Petrick, 2015).

Politička nestabilnost djeluje na turizam na način da smanjuje broj dolazaka, ali i potrošnju turista (Ivanov et al., 2016). Empirijski rezultati potvrđuju spomenuto u slučaju Katalonije. Perles-Ribes et al. (2019), primjenom ARIMA modela, dolaze do rezultata koji pokazuju da su tijekom posljednjeg tromjesečja 2017. godine politički događaji doveli do smanjenja dolazaka i potrošnje turista u regiji. Theocharous et al., (2018) provode ekonometrijsku studiju koristeći VAR-GARCH-DCC (eng. Vector autoregression – Generalized AutoRegressive Conditional Heteroskedasticity – Dynamic Conditional Correlation) model kako bi ispitali odnos političke nestabilnosti i regionalne volatilnosti turizma između četiriju zemalja istočnog Mediterana: Grčke, Turske, Cipra i Izraela. Rezultati potvrđuju pozitivan učinak na turističku potražnju uz prisutnost verbalne ili materijalne suradnje između odredišne zemlje i drugih. Verbalni sukob između odredišne zemlje i drugih negativno utječe na dolazak turista i povećava volatilnost u odredišnoj zemlji.

Kada je riječ o materijalnim sukobima, utvrđen je snažan negativan utjecaj na dolaske turista, praćen značajnim povećanjem volatilnosti. Modeli volatilnosti mogu kvantificirati učinke pozitivnih i negativnih šokova na turističku potražnju (Coshall, 2009). Model volatilnost, na primjeru britanske potražnje, dokazuje da negativni šokovi više utječu na turističku potražnju nego pozitivni šokovi jednake veličine (Coshall, 2009). Utjecaj političkog rizika i ekonomske nestabilnosti na turističke dolaske u Tunis putem ARDL (eng. Autoregressive-Distributed Lag) modela istražuju Aloui, Hamida i Hkiri (2020). Njihovi rezultati otkrivaju značajan učinak političkog rizika u kratkom i srednjem roku, dok je rizik ekonomske nestabilnosti bio vidljiv u dugom roku. Autori tvrde kako teroristički napadi i politička nestabilnost povećavaju percepciju rizika te u kratkom roku utječu na prihode od turizma.

Politička klima na regionalnoj razini postaje sve značajnija sila koja utječe na ponašanje na putovanjima u mnogim turističkim destinacijama. Alvarez-Diaz et al. (2019) istražuju utjecaj regionalne političke stabilnosti na dolaske ruskih turista u Španjolsku. Otvorenost viza, kao i politička nestabilnost te građanski nemiri u alternativnim destinacijama privlače više ruskih turista u Španjolsku, potičući tako ekonomski rast i zaposlenost. Linearna i višestruka regresija statističkog predviđanja korištena je za modeliranje odnosa političke nestabilnosti i terorizma

te turizma na primjeru Turske (Koyuncu, 2020). Rezultati studije pokazuju kako su sukobi 2016. godine uzrokovali promjene u turističkom ponašanju kroz smanjenje turističke potražnje.

4.3. Ratovi i turizam

Kada je riječ o utjecaju ratova na turizam, istraživanja proučavaju kontekst percepcije odnosa tijekom rata i nakon rata. Utjecaj ratova, građanskih ratova, političkih i geopolitičkih sukoba na turizam izazvali su zanimanje mnogih autora (Currie et al., 2004; Harb, 2016; Pokharel et al., 2018). Turizam je nestabilna aktivnost, podložna mnogim vanjskim utjecajima. Jedna od glavnih briga ljudi tijekom putovanja jest njihova osobna sigurnost, stabilno političko okruženje i dobronamjerni odnosi među narodima koji su gotovo uvijek potrebni za uspješan razvoj turizma. Čak i tračak sumnje na rat ili političku nestabilnost može se negativno odraziti na turističku potražnju pogođene regije, no isto tako i susjednih područja (Timothy, 2006; Mansfeild i Pizam 2006: Metreveli i Timothy, 2010). Negativne implikacije rata na turizam, posebno brz pad turističke potražnje u ratnim uvjetima, dobro su dokumentirani (Neumayer, 2004; Hitchcock i Darma Putra, 2005; Fleischer i Buccola, 2006; Müller i Hoppler, 2013). Nekoliko radova navodi kako rat promatran kroz kratak rok ima negativne utjecaje (Mihalić, 1996).

Currie, Skare i Loncar, (2004) procjenjuju da je ekonomski trošak pada prihoda od turizma zbog rata u Hrvatskoj iznosio oko 5 milijardi američkih dolara. Autori potvrđuju tvrdnju kako je pad turizma odnosno turističkih dolazaka nakon krize prisutan čak i nakon 4 godine. Mjesta koja su se razvila jer prethodna alternativna odredišta više nisu bila dostupna zbog rata brzo mogu postati neprivlačna kada ta ograničenja prestanu postojati i stoga se bore za opstanak kao odredišta u današnje vrijeme (Butler i Suntikul, 2013). Ratovi imaju duži i snažniji utjecaj na turističku potražnju (Fernanda et al., 2013; Buultjens et al., 2016) i sam razvoj turizma (Harb, 2016).

Utjecaji rata imaju dalekosežne posljedice u usporedbi s kratkim negativnim učincima terorističkih napada. Rat može utjecati i na strukturalnu promjenu turizma na što upućuju dokazi iz Ukrajine (Sass, 2020). Statistički podaci svjedoče o činjenici da je turistički promet Ukrajine doživio strukturalnu promjenu usko vezanu sa sukobom u istočnoj Ukrajini koji je započeo 2014. godine. Posljedica rata deset godina kasnije dovodi do činjenice da je broj odlaznih turista premašio broj ulaznih te ta tendencija i dalje ostaje nepromijenjena.

U većini slučajeva rat i turizam u zajedničkoj kombinaciji predstavljaju nespojive sile, no evidentirane su i situacije u kojoj posljedice rata postaju turističke atrakcije, poput grobnica ili područja na kojima su se vodili ratovi (Henderson, 2000; Fyall et al., 2006; Lunn, 2007). Rat je

jedna od velikih svjetskih tragedija, ali je jasno da povijesni i socijalni ishodi rata (ljudsko iskustvo) kao i neizravni ishodi rata (artefakti, nostalgija, ponovna spajanja i fizička mjesta s većim povijesnim ili okolišnim značenjem) služe kao resursi koji mogu poticati razvoj turizma u ratom razorenim regijama (Bigley, 2010). Ratno nasljeđe može predstavljati snažan motiv za putovanje i dolazak u destinaciju bilo da je riječ o radoznalosti, uzbuđenju, hodočašću ili razgledavanju kulturno-povijesne baštine. Nekadašnja bojišta i grobišta izazivaju snažne osobne emocije među potomcima onih koji su se borili i umrli na takvim mjestima, ali i među onima koji su preživjeli i žele ponovno posjetiti takva mjesta.

Pojedina istraživanja sugeriraju da su rat i turizam nespojivi, tj. da je mir nužni minimalni uvjet za razvoj turizma. Međutim, novija istraživanja ukazuju na značajnu ulogu rata kao „resursa“ za turizam (Smith, 1998; Henderson, 2000; Hannam, 2006). Aktivno ratovanje može biti turistička atrakcija (Laderman, 2013). To dokazuje primjer Afganistana gdje postoje posebne specijalizirane turističke niše koje pružaju mogućnost skupinama (turističke ture) da obilaze ratišta, ograničena područja, napuštene kampove i skrovišta Al Qaide (Adams, 2001; Lew et al., 2011).

Mnogo studija proučavalo je posljedice ratnih djelovanja, odnosno bojišta, spomenike i groblja kao važne znamenitosti baštine (Henderson, 2000; Agrusa et al., 2006; Cooper, 2006; Thi Le i Pearce, 2011, Daniels, Dieke, Barrow 2013; Miles, 2014). Također, neki turisti posjećuju zemlje tijekom ratnih uvjeta, ali njihova osnovna svrha ima malo ili gotovo nikakve veze s ratom, poput Iraka gdje turisti posjećuju područja koja nisu izravno pogođena aktivnom borbom (McGahey, 2006). Turizam je moguće promatrati kao alat za stvaranje mirnijih odnosa između zaraćenih strana (Guo et al., 2006; Gelbman i Timothy, 2010; Moufakkir i Kelly, 2010; Prideaux et al., 2010) ili sredstvo za suzbijanje potencijalnih sukoba (Hall 2003; Lee i Kang, 2013). Negativne posljedice rata, a povezane s turizmom, očituju se i u uništavanju prirodnih resursa i kulturne baštine. (Metreveli i Timothy, 2010; Timothy, 2011).

Turizam se često koristi u promidžbene svrhe kao sredstvo, u vrijeme političkih kriza i previranja, radi isticanja dobročinstva i autoriteta stranaka na vlasti ili za promjenu imidža mjesta u sukobu i nakon završetka sukoba (Cohen-Hattab, 2004; Lee, 2006; Rivera, 2008). Rat i njegova povijest često se koriste u spomen na nacionalnu veličinu i heroizaciju važnih ličnosti i memorizaciju događaja kao društvenih sjećanja na rat (Winter, 2009; West, 2010). Pri pregledu literature može se zaključiti kako autori najčešće proučavaju kombinaciju utjecaja

terorističkih napada i ratova (Rahman, Holdschlag i Ahmad, 2011; Mohamad, Charabel, 2017; Muhamad i Mhmet, 2020) ili političke nestabilnosti i ratova na turizam (Ioannides i Apostolopoulos, 1999; Seddighi i Theocharous, 2002; Lepp i Gibson, 2003; Thapa, 2004). Prema tvrdnjama Smitha (1998) rat predstavlja veliko moderno sigurnosno pitanje koje se razlikuje od kriminala i terorizma s obzirom na svoje duboke i dugoročne društvene posljedice. Rezultati njegova istraživanja pokazuju kako rat potiče promotivni, emotivni, vojni i politički turizam, te da su turističke atrakcije povezane s ratom najveća poznata kategorija.

Dugo poslijeratno razdoblje u zemlji pogođenoj ratnim zbivanjima može dovesti do razvoja oblika turizma koji se naziva mračni turizam (eng. Dark tourism). Izuzetna otpornost i prilagodljivost turističke aktivnosti može se vidjeti u činjenici da razaranja uzrokovana terorizmom, prirodnim katastrofama, ratovima mogu sama po sebi postati glavna turistička atrakcija. Sredinom osamdesetih godina prošlog stoljeća dolazi do pojave „novog turizma“, tzv. „mračnog turizma“ u turističkom leksikonu koji je opisao atribute turizma malih razmjera i koji je minimalan u socijalnom i okolišnom utjecaju (Conway i Timms, 2010; Dürr i Jaffe, 2012). Početak pojave mračnog turizma u stručnoj literaturi i akademsko zanimanje za navedenu tematiku prema mišljenju nekih autora veže se uz rad Tunbridge i Ashworth, (1952). S druge strane Tunbridge i Ashworth (2017) navode kako su pojam mračnog turizma uveli Lennon i Folley (2000) u svojoj knjizi *Mračni turizam*. Mračni turizam, u svojim raznim oblicima, razvija se još od drevnih morbidnih spektakala kao što su javna gladijatorska natjecanja, javna pogubljenja, obilazak mrtvačnica i ranokršćanska hodočašća. Suvremena pojava termina mračnog turizma (1990-ih) temeljila se na teoriji fascinacije patnjom (Nhlabathi i Maharaj, 2019).

Mračni turizam definiran je kao putovanje na odredišta povezana sa smrću, katastrofom i bijedom (Strange i Kempa, 2003; Stone i Sharpley, 2008). Popularan je i značajan motiv putovanja (Stone, 2006). Jamal i Lelo (2010) ističu da prihvatljiva definicija mračnog turizma mora obuhvatiti motive posjeta, a mjesta se ne mogu okarakterizirati na temelju povijesti ljudske patnje na samo mjesto. Autori navode kako umjetnik ili arhitekt na primjer može posjetiti koncentracijski logor Dachu kako bi, osim povijesti tog mjesta, bolje razumio arhitektonske značajke građevina na tom mjestu. Prema istraživanjima nekolicine autora može se zaključiti kako manji broj ljudi posjećuje „mračna“ turistička mjesta s izraženim zanimanjem za smrt ili zadovoljenje morbidne znatiželje (Sharpley, 2012; Stone, 2012), dok je veći broj onih koji su željni učenja i boljeg razumijevanja prošlih događaja (Dunkley et al. 2011; Sharpley, 2012; Nhlabathi, 2018). Motivacijska osnova posjeta mora uključivati istaknuti

narativ ugrađen u povijest mjesta (Butler et al., 2008). Smrt je jedino nasljeđe koje dijele svi i, prema tome, to je najstariji aspekt turizma u odnosu na bilo koji drugi oblik baštine (Seaton, 1996). Prema Lennonu i Foleyu (2010) hodočašća predstavljaju jedan od najstarijih oblika turizama povezanih sa smrću. Unutar judeokršćanstva smrt se može pronaći na posebnim mjestima i ona se obilježavaju nadgrobnim spomenicima. Oni koji se žele prisjetiti umrlih mogu doći do nadgrobnog spomenika. Oko ovakve prakse razvijena je čitava industrija, posebno u onim područjima gdje ljudi vjeruju u odvajanje duše od tijela (Mionel, 2019). Ovaj mračni turizam ili još nazvan tanatoturizam pripisuje se transformacijama u turizmu, posebno prateći kritike društvenih, kulturnih i pridruženih procesa individualizacije društva (Amin, 1994; Gilbert, 2011).

Devedesete su zabilježile rast broja turista na mjestima koja su se definirala kao mjesta mračnog turizma ili tanatoturizma. Mračni turizam ili tanatoturizam označava posjete mjestima koja su povezana s ljudskom patnjom, progonom ili smrću (Nhlabathi i Maharaj, 2019). Miles (2002) navodi tipologiju mračnoga turizma prema kojoj se mjesta mračnoga turizma dijele na „tamnija“ i „svjetlija“. „Tamnija“ mjesta su ona na kojima je smrt i patnja doista nastupila, dok su „svjetlija“ mjesta ona koja su povezana sa smrću i patnjom. Stone (2006) razliku između „mračnijih“ i „svjetlijih mjesta“ mračnog turizma temelji na devet dimenzija. Na primjer, mračnija mjesta imaju veću autentičnost, zaštitu, komemorativnu funkciju, kraće razdoblje događaja i usmjerenost na obrazovanje. Svjetlija mjesta imaju manju autentičnost, zabavnu funkciju, komercijalnu/romantičarsku orijentaciju i duži vremenski raspon od događaja.

Međunarodna potražnja za mračnim turističkim iskustvima vidljiva je na različitim primjerima. Mjesto i muzej koncentracijskog logora Auschwitz-Birkenau u Poljskoj u 2019. godini posjetilo je 2 milijuna i 320 tisuća posjetitelja (Auschwitz-Birkenau). Preko 3,5 milijuna turista posjetilo je Ground Zero tijekom godine nakon zloglasnog terorističkog napada na New York City (Blair, 2002), dok je 4 milijuna posjetilo Memorijal i muzej 9/11 tijekom prve godine nakon njegova završetka. Memorijal i muzej 9/11 (9/11 Memorial & Museum) i dalje privlači veliku javnu podršku te je u 2018. godini evidentirao ukupno 6,6 milijuna posjetitelja, čime se ukupan broj posjetitelja od dana otvorenja popeo na više od 43 milijuna. Mračni turizam pripada kategoriji koju je teško precizno kvantificirati (Harmann, 2018). Znanstvenici se slažu kako je mračni turizam doživio snažan rast (Amirtha, 2015; Aharony i Rosenfeld, 2016; Millan et al., 2019) te da ima značajan potencijal za budući rast i razvoj (Reynolds, 2018). Unatoč prethodno navedenom moguće je zaključiti kako su znanstvena istraživanja o mračnom turizmu oskudna (Smith, 1998; Knox, 2006; Biran, Poria, i Oren, 2011; Minic, 2012; Biran i Hyde, 2013; Carrigan, 2014; Yan, Zhang, Zhang, Lu, i Guo, 2016) te da konceptualizacija mračnog turizma

i dalje ostaje teoretski krhka (Stone, 2006; Stone i Sharpley, 2008; Biran i Poria, 2012; Dürr i Jaffe, 2012; Benckendorff i Zehrer, 2013; Biran i Hyde, 2013; Buda i McIntosh, 2013).

4.3. Migracije i turizam

Tijekom posljednjih desetljeća literatura o trgovini i mobilnosti faktora pokazuje sve veći interes za povezanost migracija i turizma (Etzo, Massidda i Piras, 2014). Širom svijeta oko 20,4 milijuna migranata u potrazi je za boljim životom pokušavajući izbjeći otežane životne uvjete izazvane političkom nestabilnošću, ratom i drugim katastrofama koje su pogodile njihove zemlje podrijetla (The UN Refugee Agency). Ljudske tragedije udaljuju ljude od njihovih rodnih mjesta u potrazi za socijalnom i ekonomskom sigurnošću. Europa je svjedok migracijskih pritisaka iz Sirije, Afganistana i drugih područja s nasilnim sukobima (Center for Analysis of Terrorism, CAT, 2017).

Turizam kao oblik privremene međunarodne migracije može poput ostalih oblika kretanja promijeniti strukturu stanovništva (Leitão i Shahbaz, 2012). Povijest migracija naziva se poviješću borbe za opstanak ljudi i pokušajem izbjegavanja siromaštva i nesigurnosti u kojoj žive, iseljavanjem iz svojih životnih mjesta i u potrazi za boljim mogućnostima (House of Commons, 2004). U istom izvještaju (2004, str. 9), ekonomist Galbraith migracije naziva „najstarijom akcijom protiv siromaštva“. Prema Sriskandarajah (2005) od svih uzajamnih utjecaja između zemalja – trgovine, pomoći, stranih ulaganja, komunikacija, transporta itd., moguće da migracije imaju najznačajnije i trajne posljedice. Imigracije i međunarodna trgovina ujedno i promoviraju turizam (Eliat i Einav, 2004; Phakdisoth i Kim, 2007; Mervar i Payne, 2007; Fischer, 2007; Vogt, 2008).

Migracije mogu transformirati pojedince koji se kreću, društva u kojima se kreću, pa čak i društva koja ostavljaju za sobom. Iz navedenog migracije također mogu biti politički najkontroverznije pitanje, posebno u društvima u kojima se doseljenici naseljavaju. Oigenblick i Kirschenbaum (2002) navode kako turizam olakšava imigraciju. Unazad nekoliko desetljeća primijećeno je povećanje akademskog interesa oko navedene tematike, što potvrđuje i činjenica mnogobrojnih radova koji se baziraju na istraživanju međusobne povezanosti migracija i razvoja te migracija i turizma.

Radovi koji se bave tematikom međuodnosa turizma i migracija ističu pozitivne (Jackson, 1990; King, 1994; Williams i Hall, 2002; Boyne, Carswell i Hall, 2002; WTO, 2009; Seetaram i

Dwyer, 2009; Seetaram, 2012a; 2012b) i negativne efekte (WTO, 2009; Nail, 2016). Nail, (2016) u svom istraživanju, koje se odnosi na izbjegličku krizu koja je pogodila Europu, ističe negativne strane migracija. Autor tvrdi kako se nakon terorističkog napada koji se dogodio u Parizu 2015. godine izbjegličku krizu više ne može shvaćati kao odvojenu od krize terorizma. On navodi kako je migrant potencijalni terorist koji se krije među gomilom migranata, a terorist potencijalni migrant koji je u svakom trenutku spreman ući u Europu.

Svjetska turistička organizacija (WTO, 2009) u svom istraživanju proučava odnosa migracija i turizma te navodi i negativne aspekte i posljedice spomenutog odnosa (tablica 5). Istraživanje u negativne posljedice ubraja „odljev mozgova“, smanjenje poreznih prihoda u zemljama podrijetla, politiku plaća i socijalnu napetost u odredišnim zemljama.

Tablica 5 UTJECAJ TURIZMA I MIGRACIJA

	ZEMLJA PODRIJETLA	**ZEMLJA ODREDIŠTA**
MIGRACIJA	Ekonomski doprinos kroz financijske doznake i migrantska ulaganja. Kulturna razmjena. Odljev mozgova (kratkoročni/srednjoročni). Ušteda na zdravstvu i socijalnoj sigurnosti. Smanjenje poreznih prihoda.	Ekonomski doprinos. Kulturno uzdizanje. Dodatni pritisak na socijalne i ekonomske strukture. Natjecanje koje vodi kratkoročnom smanjenju plaća. Suprotstavljanje padu i starenju stanovništva. Povećani porezni prihodi i potrošnja korisnika. Kriminal i trgovina ljudima. Društveni sukob.
VFR (posjet prijateljima i obitelji) TURIZAM	Povećana vidljivost na odredišnom tržištu. Povećani povratak VFR turizmu. Smanjenje domaćeg tržišta.	Povećanje potencijalnoga međunarodnog tržišta. Poboljšana vidljivost na tržištima porijekla.
VJEŠTINE I LJUDSKI KAPITAL	Povećani pristup znanju putem mreža dijaspore. Buduće poboljšanje vještina i pojava nove klase poduzetnika (ako se migranti vrate). Gubitak profesionalnih vještina. Poboljšana tehnologija putem prijenosa znanja od strane migranata.	Paketi za privlačenje svježih talenata. Poboljšanje jezičnih vještina. Pojačana kulturna osjetljivost u turističkim aktivnostima. Povećane inozemne naknade za obrazovne institucije.

NOVČANE DOZNAKE	Dodatni prihod koji doprinosi povećanju potrošnje.	Potražnja za financijskim uslugama.
FDI (direktne strane investicije)	Dobro informirana ulaganja u putovanja, turizam i ugostiteljstvo. Novi tokovi ulaganja.	Novi odnosi i mogućnosti investicijskog partnerstva.
EMIGRACIJSKI TURIZAM	Posjetitelji veće platežne moći.	Rast putničkih usluga.

Izvor: izradila autorica prema United Nations World Tourism Organization, Tourism and Migration, (2009)

Williams i Hall (2002) u provedenom istraživanju ističu kako se povezanost između turizma i migracija može objasniti putem tri različita mehanizma:

(1) Uzročni odnos koji kreće od turizma do migracije i za rad i za potrošnju, poznat kao hipoteza o migraciji koja vodi turizam.

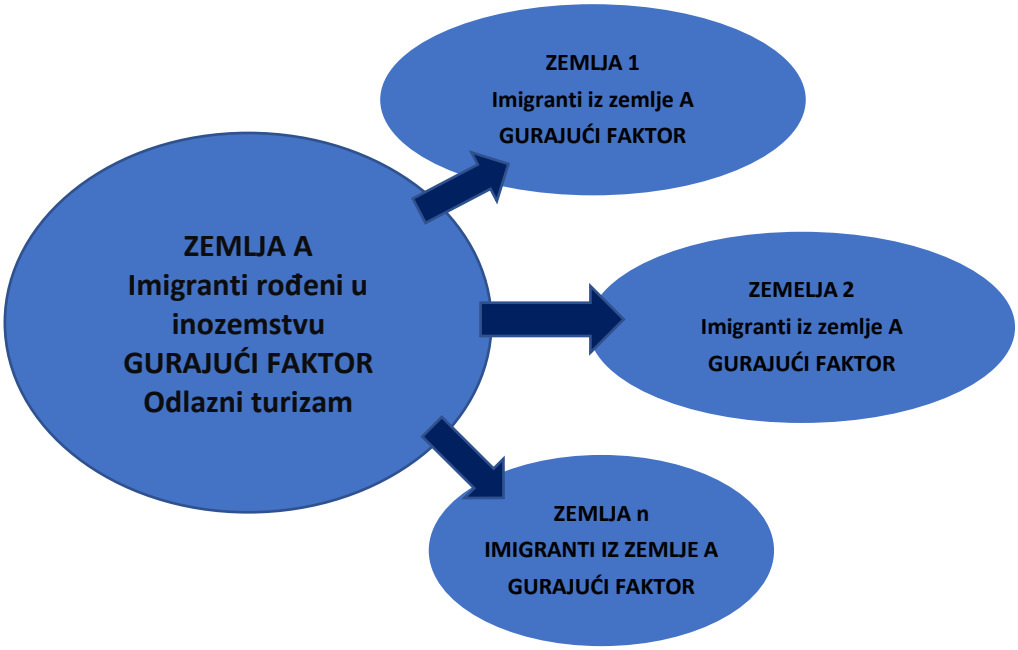
(2) Drugi mehanizam invertira ovu uzročno-posljedičnu vezu i prema tome podrazumijeva da migracija vodi turizam (eng. migration leads tourism – MLT) poticanjem putovanja posjetom prijateljima i obitelji (engl. Visiting Firends and Relatives – VFR).

(3) Treći je mehanizam za jačanje koji objašnjava dvosmjernu uzročno-posljedičnu vezu između ta dva pojma.

Prema navedenom, zaključuje se kako je migracija jedan od glavnih preduvjeta za VFR putovanja (Williams i Hall, 2002; Dragičević, Nikšić Radić, Herman, 2019). Osim posjete prijateljima i obitelji imigranti mogu povećati privlačnost destinacije na nekoliko načina: obogaćuju kulturni život destinacije pružajući širi spektar mogućnosti potrošnje, motiviraju sunarodnjake za etnička spajanja i zadržavaju poslovne veze sa svojom državom podrijetla, te na taj način potiču poslovna putovanja (Seetaram, 2012a; Massidda i Piras, 2014).

Imigranti utječu na izlazne turističke tokove potičući odlaske drugih koji borave u zemljama domaćinima (Etzo, Massidda i Piras, 2014). Iz perspektive zemlje domaćina, imigranti djeluju kao vučni faktor turističkih dolazaka (ulazni) i kao potisni faktor za odlaske turista (odlazni), nevezano uz to je li VFR glavna motivacijska sila. Zemlja A prima imigrante iz zemlje *n* i šalje emigrante u svaku od tih zemalja. S obzirom na zemlju A, odlazni turistički tokovi koji su prikazani u grafikonu 4 potiskuju se od ljudi rođenih u inozemstvu s prebivalištem u zemlji A i povlače se od strane stanovništva rođenog u zemlji A, koji žive u *n* državama (Etzo, Massidda i Piras, 2014).

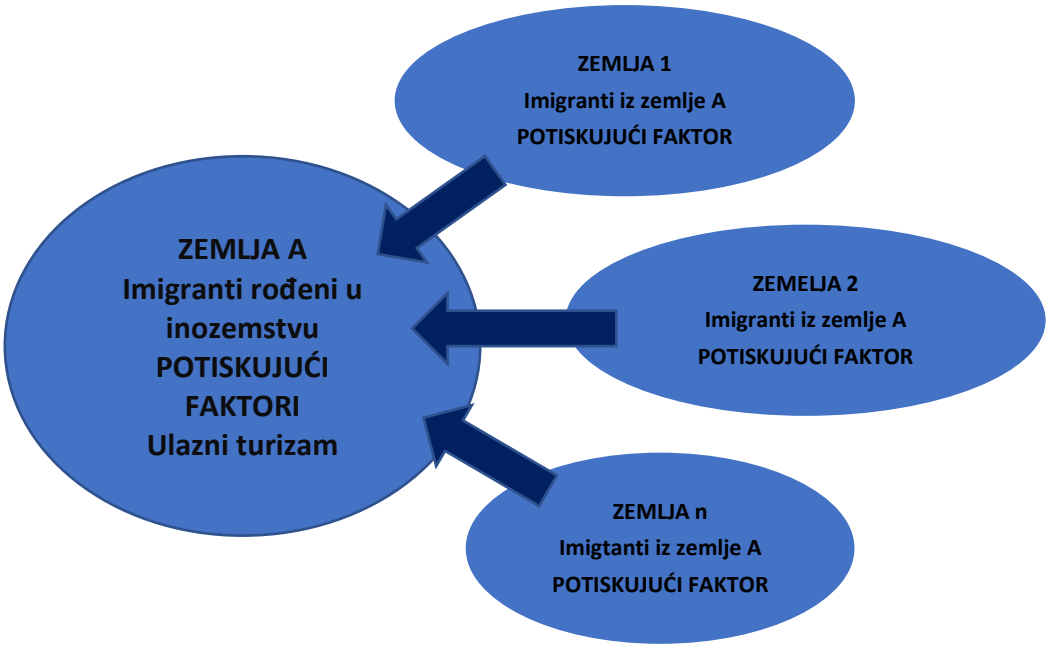
Grafikon 4 Odlazni turizam – mapa povezivanja migracija i turizma



Izvor: izradila autorica prema uzoru na Etzo, Massidda i Piras, (2014, str. 236)

S druge strane, ulazni turistički tokovi koji su prikazani u grafikonu 5 dolaze od strane osoba koje su rođene u inozemstvu s prebivalištem u zemlji A, a potiču ga osobe rođene u zemlji A koje žive u *n* zemlji.

Grafikon 5 Ulazni turizam – mapa povezivanja turizma i migracija



Izvor: izradila autorica prema uzoru na Etzo, Massidda i Piras, (2014, str. 236)

Istraživanje provedeno od strane Leitão i Shahbaz, (2012) razmatra odnos između imigracije i turističke potražnje Portugala. Rezultati pokazuju kako su dohodak, šok imigracije, stanovništvo i zemljopisna udaljenost između Portugala i zemlje podrijetla glavne odrednice portugalskog turizma. Turizam i migracije predstavljaju dva strogo povezana oblika ljudske mobilnosti. Pozitivni učinci migracija na turizam dokazani su i na primjeru Italije (Etzo et al., 2014). Autori u svom istraživanju primjenjuju panel analizu kako bi proučili utjecaj migracija na talijanska turistička putovanja u inozemstvo. Putovanja su kategorizirali prema svrsi putovanja. Talijani s prebivalištem u inozemstvu imaju pozitivan utjecaj na odlazni turizam neovisno o svrsi putovanja. Imigranti s prebivalištem u Italiji djeluju kao faktor guranja talijanskoga odlaznog turizma za sve svrhe putovanja: poslovna putovanja, posjeti prijateljima i rodbini, odmorišna putovanja (Etzo, Massidda i Piras, 2014).

Stalna međunarodna migracija kreira i potiče turističke tokove (Williams i Hall, 2000). Migracija je jedan od razloga posjeta prijatelja i rodbine zbog posebnih i neponovljivih događaja (rođenja, rođendani, diplome, vjenčanja, sprovodi) (Jackson, 1990). Statistički značajnu vezu između imigracijskih kretanja i ulaznoga i odlaznog turizma za Australiju potvrđuju istraživanja King (1994), Seetaram (2012a) i Seetaram (2012b). Australija uvelike ovisi o imigraciji kao izvoru rasta stanovništva, a što može imati posljedice i na njegov turizam (Seetarm i Dwyer, 2014). Autori su proveli panel analizu za devet glavnih tržišta Australije (Novi Zeland, Velika Britanija, SAD, Japan, Kina, Hong Kong, Singapur, Malezija i Južna Koreja). Rezultati snažno potkrjepljuju postavljenu hipotezu koja tvrdi da je imigracija jedna od najvažnijih odrednica ukupnih turističkih dolazaka u Australiju. Do sličnih zaključaka dolazi i istraživanje Dwyer et al. (2014). Studija pokazuje kako migracije mogu potaknuti VFR (posjet prijateljima i obitelji) turizam te kako postoji snažna vezu između migracija i drugih oblika turizma.

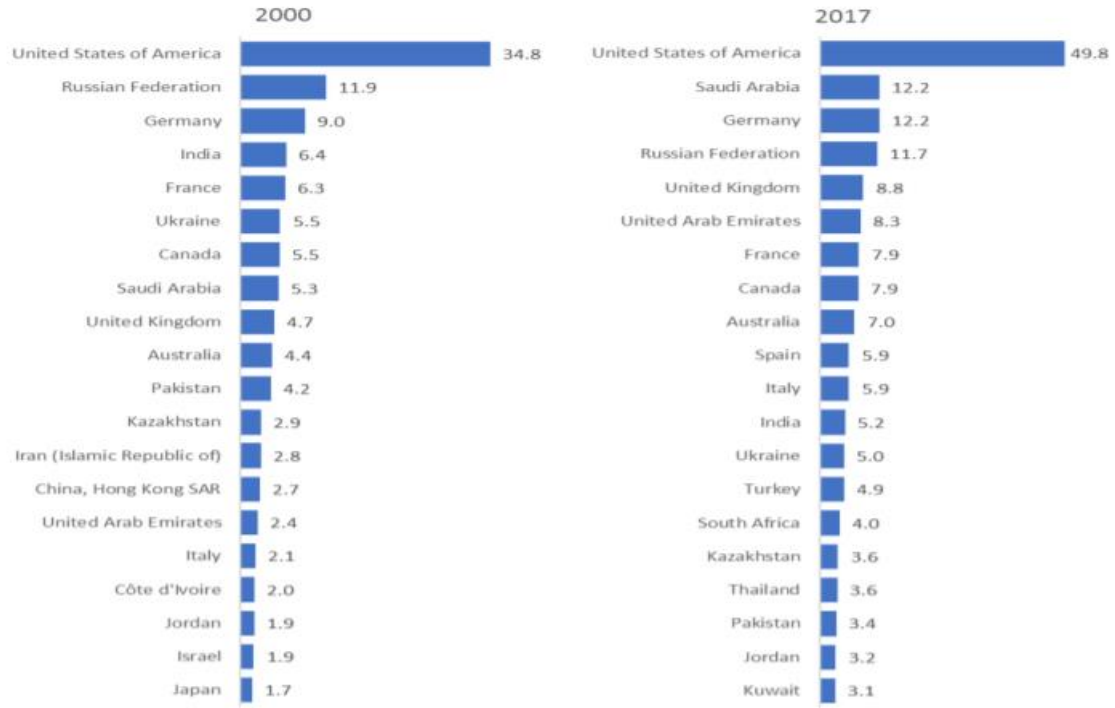
Želja za posjetom prijateljima i obitelji (VFR) temeljni je pokretač velikog dijela globalnog turizma (Griffin, 2013). Signifikantan utjecaj imigranata na ulaznu turističku potražnju potvrđena je i na primjeru Novog Zelanda (Feng i Page, 2000; Genç, 2013). Povezanost turizma i migracija dokazana je i za područje Europske unije (Dragičević, Nikšić Radić, Herman 2019). Rezultati istraživanja pokazuju značajnu povezanost između turizma i imigracija za 18 zemalja. Provenzano (2020) također provodi istraživanje odnosa migracija i turizma unutar Europe. U svom radu autor koristi Complex-network analizu te gravitacijski model. Rezultati pokazuju prilično sličnu topološku strukturu za turističku i migracijsku mrežu kao i signifikantan i

recipročan izravan utjecaj između turizma i migracijskih kretanja unutar Europske unije. Imigranti djeluju kao ambasadori svojih matičnih država. Balli et al. (2016) dokazuju da, izuzev afričkih zemalja, imigranti koji borave u zemljama OECD-a imaju pozitivan oglašivački učinak na svoju matičnu zemlju, potičući turističke tokove iz zemalja OECD-a. Poduzetništvo kreativnih migranata ima važnu ulogu u organizacijskim inovacijama u turizmu odredišne zemlje te značajno doprinosi njenoj održivoj konkurentskoj prednosti (Xiong, Zhang i Lee, 2019).

ILO (2010) (eng. International Labour Organization) u svojim istraživanjima dolazi do zaključka kako migracije imaju veliki potencijal da potaknu razvoj na različite načine, a novčane su pošiljke jedan od najvažnijih načina rada. Na mikro ili pojedinačnoj razini novčanih pošiljki to se očituje u obliku potpora dohotku kućanstva, povećavanja potrošnje na zdravstvo, obrazovanje i potrošnju. Na makrorazini u pogledu kolektivnog ulaganja novčanih pošiljki u izgradnju cesta ili izgradnju drugih društveno važnih objekata što ima izravan utjecaj na razvoj kroz poboljšanu infrastrukturu. Nail (2016).

U nastavku slijedi grafički prikaz 6 koji objedinjuje dvadeset vodećih država po broju međunarodnih migranata u razdoblju od 2000. do 2017. godine.

Grafikon 6 Dvadeset država u kojima živi najveći broj međunarodnih migranata 2000. i 2017. godine (broj migranata u milijunima)

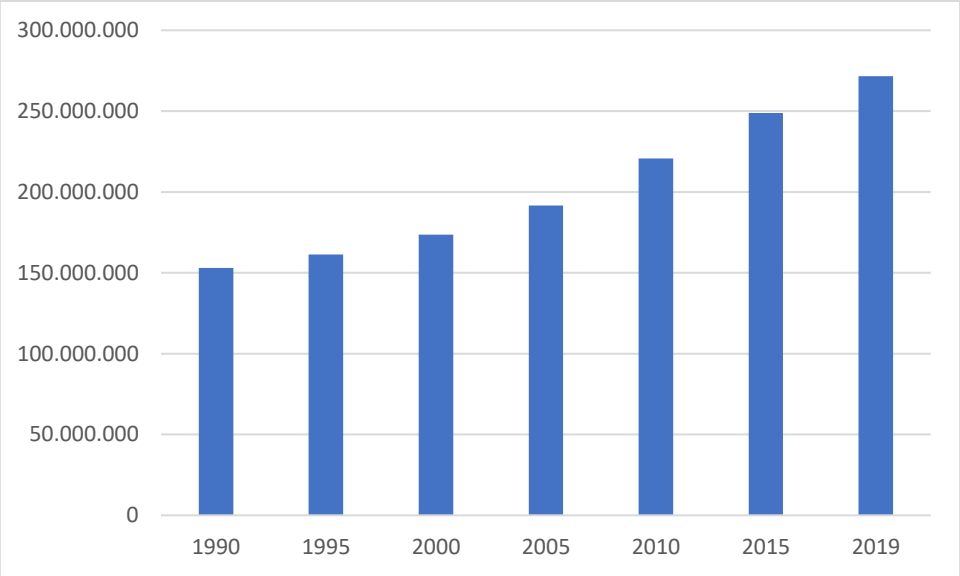


Izvor: Migration Report 2017

Grafikon 6 prikazuje presjek ranga država s najvećim brojem međunarodnih migranata 2000. godine te komparacija istog s 2017. godinom. Ono što je primjetno jest da Sjedinjene Američke Države predstavljaju lidere u prihvatu migranata. Također, vidljiv je i skok Saudijske Arabije, Ujedinjenog Kraljevstva te Ujedinjenih Arapskih Emirata.

U nastavku slijedi grafikon 7 iz kojeg se može zaključiti kako se migracijska kretanja (podaci dostupni na petogodišnjoj razini) povećavaju uzastopno. Valja napomenuti kako unutar navedene skupine ne ulaze samo dobrovoljna migracijska kretanja već i ona prisilna koja su uzrokovana ratnim stanjima, političkom nestabilnošću, potragom za boljim životom.

Grafikon 7 Međunarodna migrantska kretanja tijekom godina



Izvor: izrada autora prema podacima United Nations, International migration report (2017)

4.4. Prirodne katastrofe i turizam

Prirodne katastrofe s jedne strane i turizam s druge strane predstavljaju dva potpuno različita pojma. Kad se govori o turizmu, većini na pamet padne misao o odmoru, relaksaciji, zabavi, opuštanju, razgledavanju, dok s druge strane prirodne katastrofe donose slike razaranja, smrti i tragedija. Prirodne katastrofe i turizam djeluju kao dva elementa na suprotnim krajevima spektra i zato su međusobno isključivi, a ne komplementarni (Beattie, 1992).

Turizam predstavlja jednu od aktivnosti koja je najosjetljivija na vremenske uvjete (Prettenthaler et al., 2016), a globalno promatrano godišnji broj službeno zabilježenih prirodnih katastrofa brzo raste (Ritchie i Roser, 2019), što utječe na promjenu prirodnog okoliša čije su posljedice vidljive kroz ozbiljne ekonomske izazove (Schmude et al., 2018). Posljedice su

ponekad katastrofalne za zemlje kao što su Maldivi, Sejšeli i Karipski otoci koje se u velikoj mjeri oslanjaju na turizam (Shareef i McAller, 2008; Seraphin, 2019).

Volumen poslovanja u području turizma jednak je ili čak veći od izvoza nafte, prehrambenih proizvoda ili automobila. Rast turizma kreće se paralelno sa sve većom diverzifikacijom i konkurencijom među destinacijama, no kako turizam raste, povećava se i klimatski rizik (De Almeida i Machado 2019).

Poplave, veliki požari, uragani, zemljotresi, suše, tsunamiji i toplinski valovi predstavljaju dio šireg „rizičnog scenarija“ s kojima su ljudi naučili živjeti i upravljati (Rosselló, Becken i Santana-Gallego, 2020). Razumijevanje utjecaja i rizika koje vremenska varijabilnost predstavlja za turizam važno je za učinkovito kreiranje suvremenih ekonomskih politika i strategija upravljanja rizikom, kao i za procjenu potencijalnih ekonomskih utjecaja budućih klimatskih promjena (Prettenthaler et al., 2016). Konkretno, poljoprivreda, energetika, trgovina na malo, putovanja, slobodno vrijeme za zabavu spadaju u djelatnosti podložne vremenskim uvjetima (Chicago Meracantile Exchange, CME, 2005).

Utjecaji katastrofa u posljednje vrijeme znatno su porasli zbog pogoršavajućih učinaka klimatskih promjena i zbog rastuće složenosti socioekoloških sustava u izuzetno povezanom i globaliziranom svijetu (Becken et al., 2014). Klimatske promjene koje su ujedno posljedica promjena temperature zraka, oborina, porasta razine mora, povećane učestalosti toplinskih valova, uragana, tropskih oluja, viših stopa oborina povezanih s tropskim ciklonama (Knutson et al., 2010; Trenberth, 2011), industrijalizacija i urbanizacija ubrzale su pojavu prirodnih katastrofa širom svijeta i povećale opseg nastalih šteta (Park i Reisinger, 2010; Becken et al., 2015).

Rast stanovništva smatra se jednim od ključnih razloga zašto su posljedice prirodnih katastrofa na društvo sve značajnije (Wachinger et al., 2012). Katastrofe i drugi oblici kriza dovode do smanjenja posjeta pogođenog područja (Bhati et al., 2016). U mnogim slučajevima, katastrofe predstavljaju značajna fizička ograničenja u pružanju turističkih usluga te ozbiljno ograničavaju turističku ponudu (Shaw, Saayman i Saayman, 2012). Poremećen prometni sustav i uništeni turistički resursi predstavljaju prijetnju za razvoj turizma. Unazad dvadesetak godina, negativni učinci prirodnih katastrofa na turizam evidentirani su u zemljama kao što su Japan, Novi Zeland, Kina, Sjedinjene Američke Države, Australija, Peru (Huang i Min, 2002; Sharpley, 2005; Ritchie, 2008; Yang et al., 2011; Orchiston, 2012). Među raznim prirodnim katastrofama, zemljotres se smatra jednim od najtežih katastrofalnih događaja (Becken i Hughey, 2013).

Njegove posljedice mogu dovesti do nesagledive štete u okolišu, na infrastrukturi, gubitka života, iseljavanja stanovništva i epidemija koje prijete ljudskom zdravlju (Zhao et al., 2018). Jedan od takvih primjera prirodnih katastrofa jest zemljotres u talijanskoj regiji Umbria u rujnu 1997. godine. Mazzocchi i Montini (2001) utvrđuju kako su dolasci turista značajno pali prvog mjeseca nakon velikog šoka. Navedeno potvrđuju i Huang i Min (2002) u istraživanju koje je provedeno na primjeru Tajvana primjenom modela vremenske serije. Analiziran je tajvanski zemljotres u rujnu 1999. godine kako bi istražili postupak oporavka. Prilikom navedenog događaja 2400 ljudi je smrtno stradalo, 8000 ih je bilo ranjeno, a 100 000 ljudi je u tom zemljotresu postalo beskućnicima. Studija otkriva da se inozemni turistički dolasci na otok nisu u potpunosti oporavili od posljedica zemljotresa čak ni nakon 11 mjeseci od samog događaja.

U proteklom desetljeću katastrofe u obliku zemljotresa uzrokovale su ogromne gubitke turističkim destinacijama uvelike smanjivši broj turista koji posjećuju relevantna turistička mjesta i ozbiljno oštećujući turističke atrakcije i sadržaje. Rezultat toga je da zajednice teško mogu održavati životno okruženje (Nian et al., 2019). Najistaknutiji primjer je zemljotres u Japanu 2011. godine. Zemljotres koji je tada pogodio Japan bio je jačine 9,0 po Richterovoj skali. Zemljotres je pokrenuo tsunami, a posljedično tome dogodila se i nuklearna nesreća što je rezultiralo ogromnim žrtvama i imovinskom štetom. Navedeni primjer smatra se najgorom prirodnom katastrofom u povijesti Japana (Hasegawa et al., 2018).

Kritične infrastrukture kao što su zračne luke, morske luke, kopnena prometna infrastruktura i električne i telekomunikacijske mreže ovisno o vrsti i opsegu katastrofe mogu biti ugrožene i nefunkcionalne (Parajuli i Haynes, 2016). Izuzev navedenog, osnovna turistička imovina kao što su smještajni objekti ili neke ključne atrakcije mogu biti oštećeni i nespremni za poslovanje. Turizam oblikuje širok spektar faktora i sila, uključujući i egzogene koji nemaju izravnu vezu s turističkim aktivnostima. Primjer takvog odlučujućeg čimbenika su prirodne katastrofe jer imaju duboke učinke na pojedince i društvo, te samim time mogu utjecati na tokove turizma (Rosselló, Becken i Santana-Gallego, 2020). Utjecaj vremenskih neprilika značajan je za turistička poduzeća koja svoje usluge pružaju u prirodi iz razloga što je prirodno okruženje najvažniji faktor u određivanju dužine sezone i kvalitete turističkih proizvoda (Scott, 2003). Toeglihofer et al., (2012) uz vremensku vrijednost s rizikom (vrijeme-VaR), uvode jednostavan koncept za mjerenje ekonomskih rizika povezanih s vremenskim fluktuacijama, a Prettenthaler et al., (2016) proširuju koncept vrijeme-VaR kako bi opisali i usporedili sektorske rizike prihoda od klimatskih promjena, pritom koristeći primjere uzgoja pšenice i ljetnog turizma.

Damm et al., (2017) u svom istraživanju prvi primjenjuju Vrijeme-VaR koncept na međunarodnoj razini, koristeći primjer zimskog alpskog turizma. Autori analiziraju skijališne turističke regije Europe na način da procjenjuju gubitke u broju ostvarenih noćenja uzrokovanim globalnim zagrijavanjem za +2 °C. Rezultati pokazuju da će ostvarenje scenarija od +2 °C smanjiti broj noćenja u europskim skijališnim destinacijama za 10,1 milijun tijekom zimske sezone. Najveći gubitak u referentom razdoblju kao i u scenarijima od +2 °C evidentirani su u Austriji i Italiji. Povezanost sveukupne turističke potražnje i klimatskih čimbenika proučavano je od strane nekolicine autora (Lise i Tol, 2002; Hamilton et al., 2005; Amelung i Moreno, 2012; Goh, 2012; Ridderstaat et al., 2014).

Analize iz makroekonomske perspektive procjenjuju opće utjecaje na lokalna gospodarstva u smislu troškova i posljedica pojedinih katastrofa na lokalna gospodarstva (Baade, Baumann i Matheson, 2007; Vigdor, 2008), uključujući čitave zemlje ili kontinente (Cavallo, Powell i Becerra, 2010). Varijable koje su najčešće korištene za procjenu ekonomske štete su broj smrtno stradalih ili broj pogođenih osoba (Noy, 2009; Kim i Marcouiller, 2015), porast plaćanja vanjskim transferima (West i Lenze, 1994), novčane odštete (Cavallo et al., 2010; Kim i Marcouiller, 2015), gubici proizvodnje (Hallegatte i Przylusky, 2010), smanjene makroekonomske stope rasta BDP-a (Strobl, 2012) i promjene zaposlenosti (Coffman i Noy, 2011).

Procjenu utjecaja različitih vrsta katastrofa (suše, zemljotres, tsunami, hladni i toplinski udari, epidemija, poplave, industrijske nesreće, klizišta, požari, oluje i vulkanske aktivnosti) na međunarodne turističke dolaske na nacionalnoj razini proučavaju Rosselló, Becken i Santana-Gallego (2020). Autori koriste tri različite varijable za mjerenje prirodnih katastrofa: broj smrtnih slučajeva, pogođenih ljudi i ekonomski troškovi. Rezultati pokazuju kako pojava različitih vrsta događaja u različitim stupnjevima mijenja turističke tokove na način da smanjuje dolaske turista. Nestašica vode također pripada u kategoriju prirodnih katastrofa. Postojanje nestašice djeluje na smanjenje turističke potražnje i gubitka prihoda lokalnih turističkih poduezća (Wendell, 2018). Prirodne katastrofe djeluju putem mehanizma afektivne reakcije turista i na buduće namjere putovanja (Lehto, Douglas i Park, 2008).

Do sada izneseni rezultati jasno ukazuju na negativan utjecaj prirodnih katastrofa na turizam. Barbhuiya i Chatterjee (2020) naglašavaju kako je domaći turizam otporniji od inozemnoga kada je riječ o prirodnim katastrofama.
Prirodne katastrofe poput zemljotresa imaju jači učinak na turistička kretanja od tragedija uzrokovanih ljudskim djelovanjem (terorizam) (Ma et al. 2020).
Oporavak od prirodne katastrofe uvjetovan je među ostalim i geografskim položajem turističke destinacije kao i stupnjem razvoja postojeće infrastrukture (Schmude et al., 2018).

Malene otočne države u razvoju posebno su osjetljive na katastrofe poput uragana i tropskih oluja (Briguglio, 2003; Meheux, Dominey-Howes i Lloyd, 2007; Collymore, 2011; Forbes, James, Sutherland, i Nichols, 2013). Turizam ovakvih destinacija posebno je izložen opasnostima klimatskih promjena (Tsao i Ni, 2016). Poseban izazov predstavljaju oštećenja na turističkoj infrastrukturi (Ibarrarán et al., 2009). Za ovakva (otočna) turistička odredišta smatra se da imaju „ugroženu budućnost“ pošto je malo vjerojatno da će turisti birati destinacije na kojima su prisutni poveći rizici od pojave prirodnih katastrofa (Foster et al., 2012).

Velik dio analize i glavni fokus u procjeni prirodnih katastrofa bavi se problemima klizišta (Maharaj, 1993; DeGraff, James i Breheny, 2010; DeGraff, Romesburg, Ahmad, i McCalpin, 2012). Razvijene zemlje s raznolikom gospodarskom strukturom manje su osjetljive na prirodne katastrofe, dok su zemlje s visokim udjelom turizma u gospodarstvu pod većim utjecajem posljedica katastrofalnih događaja (Kim i Marcouiller).

Izuzev izravnoga utjecaja prirodnih katastrofa na turizam (Schmude et al., 2018), prirodne katastrofe djeluju negativno i na destinacijski imidž (Insch i Avraham, 2014; Alvarez i Campo, 2014; Park et al., 2017; Promsivapallop i Kannaovakun, 2017; Tan i Wu, 2016). Promjena odredišnog imidža nakon prirodne katastrofe različita je za turiste različitih zemlja porijekla (Wu i Shimizu, 2020). Prirodne katastrofe mogu pogoršati razinu percipiranog rizika putovanja iako turistička destinacija nije pretrpjela ozbiljnu fizičku štetu (Lehto et al., 2008). Percepcija rizika jedan je od najutjecajnijih čimbenika pri odlučivanju turista o putovanju i odabiru odredišta (Karl, 2018).

Planiranje oporavka prije i nakon prirodne katastrofe važan je element teorije oporavka od katastrofa u održivim zajednicama (Smith i Wenger, 2007). Turizam kao aktivnost često je loše

pripremljen za katastrofe bez obzira na znanje o postojećim ranjivostima (Becken i Hughey, 2013).

Tablica 6 Ukupan broj smrtno stradalih od 1974. do 2020. godine od prirodnih ili tehnoloških katastrofa

Natpisi redaka	Ukupno smrtno stradalih
Biološke katastrofe	**255340**
Incidenti sa životinjama	12
Epidemije	255328
Insektne infekcije	
Klimatološke katastrofe	**584493**
Suša	581729
Divlji požari	2764
Složena opasna katastrofa učinjena od strane čovjeka	**610000**
Geofizičke katastrofe	**1259010**
Potresi	1229615
Masovni pokreti (suhi)	2293
Vulkanske aktivacije	27102
Hidrološke katastrofe	**349392**
Poplava	314364
Klizišta	35028
Meteorološke katastrofe	**675042**
Ekstremne temperature	181344
Oluje	493698
Tehnološke katastrofe	**318082**
Industrijske nesreće	46811
Razne nesreće	48267
Prometne/transportne nesreće	223004
Ukupni zbroj	**4051359**

Izvor: izrada autora prema podacima The international disaster database

Tablica 6 prikazuje ukupan broj smrtno stradalih od posljedica prirodnih katastrofa koje su kategorizirane prema podgrupama katastrofa u razdoblju od 1974. do 2020. godine. Broj prirodnih katastrofa se uzastopno povećava, a posljedice su sve rigoroznije. Ukupan broj smrtno stradalih iznosi 4 051 359. Najveći broj smrtno stradalih evidentiran je pri geofizičkim katastrofama te iznosi 1 259 010 smrtno stradalih od posljedica spomenutog.

4.5. Zdravstvene krize

U aspektu međunarodne i nacionalne sigurnosti, zarazne bolesti imaju nešto zajedničko s prirodnim katastrofama. Oboje nisu podložne političkim i prirodnim granicama i šire se mnogo

brže od ostalih oblika prijetnji (Kurež i Prevolšek, 2015). Hall et al., (2003) tvrde da turizam predstavlja jedan od glavnih kanala širenja zaraznih bolesti. „Upravo bezgranična priroda turizma pomaže prenošenju virusa s jednog na drugo područje“ (Rittichainuwat i Chakraborty, 2009:412; Camitz i Liljeros, 2006; Baker, 2015). Suprotno navedenoj tvrdnji, analize provedene od strane WHO (2009:1) navode kako „znanstvena istraživanja zasnovana na matematičkom modeliranju pokazuju da će ograničavanje putovanja imati ograničeni efekt ili neće imati koristi u zaustavljanju širenja bolesti. Povijesni zapisi o ranijim pandemijama gripa kao i iskustvo sa SARS-om potvrdili su navedeno. Pokazalo se da ograničenja putovanja imaju ograničene efekte u sprečavanju širenja zaraznih infekcija te da bi umjesto toga informiranje prije polaska bilo puno učinkovitije“ (Lam, 2008).

Izbijanje epidemioloških bolesti može stvoriti međunarodnu anksioznost zbog njihove novosti, lakoće prenošenja u određenim sredinama i brzine širenja zračnim putovanjem u kombinaciji s velikim medijskim izvještajima (Wilder-Smith et al., 2003). Unazad nekoliko godina proučavane su mnoge krize i katastrofe koje utječu na turizam (Breitshol i Garrod, 2016), no malo njih izričito istražuje krizu povezanu uz zdravstvene katastrofe odnosno epidemije poput teškog akutnog respiratornog sindroma (SARS) u jugoistočnoj Aziji (McKercher i Chon, 2004), bolesti stopala i usta u Ujedinjenom Kraljevstvu (Frisby, 2003; Irvine i Anderson, 2004), gripe u Meksiku (Monterrubio, 2010), problema sa stjenicama (Liu, Kim i Pennington-Gray, 2015). Jasno je kako su takvi događaji odstupanja od trenda, no kratkoročni ekonomski učinci takvih prirodnih pojava predstavljaju ozbiljan problem (Chang, 2016). Tijekom posljednjih dvadesetak godina došlo je do pojava više zdravstvenih kriza koje su uzrokovale rizike za lokalne zajednice i značajnu štetu u turizmu (Smith, 2006; Glaesser, 2006; Kuo et al., 2008).

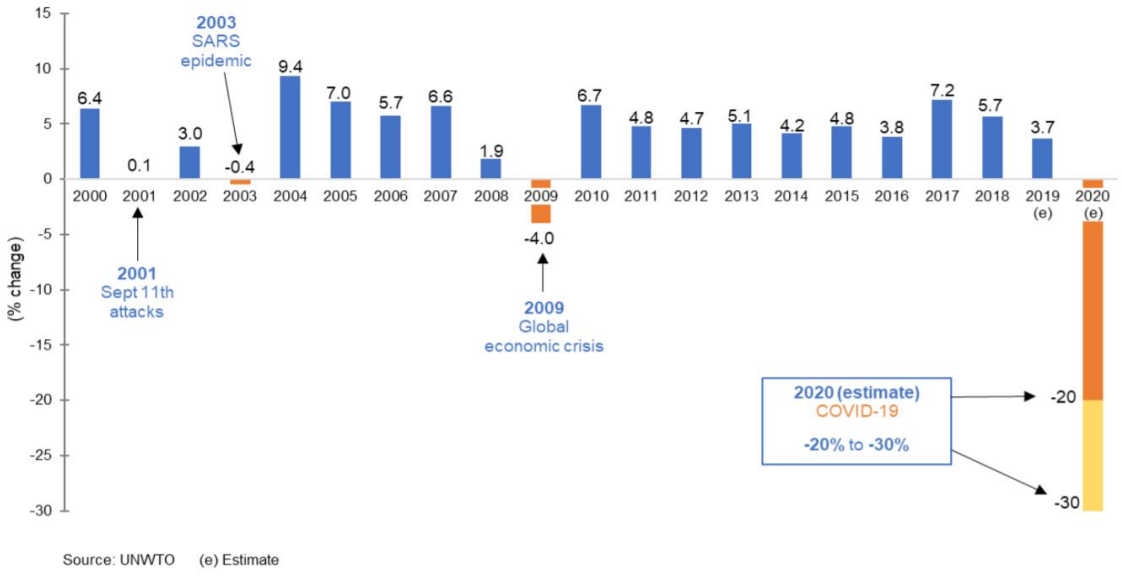
Izbijanje SARS-a predstavlja konkretan primjer povezanosti putovanja, turizma i zarazne bolesti (Washer, 2004). Međunarodni turisti bili su mehanizam prijenosa zaraze u trenutku kada su se nakon putovanja, iz epidemijom zahvaćenih područja, vraćali u mjesto prebivališta (Mason et al., 2005; Hung et al., 2018). Epidemije imaju neposredan negativan ekonomski utjecaj na turizam (Monterrubio, 2010). Povezanost putovanja, turizma i epidemije proučava i Monterrubio, (2010). Autor navodi kako epidemije mogu imati negativan ekonomski utjecaj na turizam kao aktivnost. Na temelju analize novinskih članaka i ostalih medijskih izvještaja, istraživanje Monterrubio, (2010) ima za cilj identificirati kratkoročne ekonomske učinke gripe A (H1N1) na meksičku turističku aktivnost, s posebnim naglaskom na ulogu vladine prevelike reakcije. Istraživanje Monterrubio (2010), na primjeru meksičke (svinjske) gripe A (H1N1),

otkriva kako su hotelska, ugostiteljska i zrakoplovna industrija pretrpjele značajne štete tijekom prvih tjedana epidemije. Terorizam, epidemije i ekonomske krize imaju različit utjecaj na kretanje turista iz različitih zemalja podrijetla u različite destinacije odredišta (Teitler-Regev et al., 2014).

Epidemiološka zdravstvena kriza, uzrokovana COVID-19 virusom, od 2020. drastično povećava interes znanstvenika za istraživanje posljedica koje ova zdravstvena katastrofa ostavlja na gospodarstvo, turizam, investicije, trgovinu. Učinci epidemije istražuju se u području turizma (Gossling, 2002; Page i Yeoman, 2007; Scott i Gossling, 2015), zdravstva (Fauci i Morens, 2012; Bloom i Cadarette, 2019), institucionalnih i državnih sektora (Nacionalne akademije znanosti, inženjerstva i medicine, 2018; Svjetska banka, 2012). Patel et al., (2020) ispituju u kojoj mjeri epidemija COVID-19 može utjecati na globalnu turističku industriju. Rezultati istraživanja pokazuju kako turisti odluke o otkazivanju putovanja prilagođavaju trenutnom stupnju pandemije u određenoj destinaciji.

Dosad neviđena globalna ograničenja putovanja i „ostani kod kuće“ mjere uzrokuju najoštrije poremećaje svjetske ekonomije od Drugog svjetskog rata. Međunarodnim zabranama putovanja koje su pogodile preko 90% svjetske populacije i široko rasprostranjenim ograničenjima na javna okupljanja i mobilnost zajednice, turizam je u velikoj mjeri prestao u ožujku 2020. godine (Gössling, Scott i Hall, (2020). Rane projekcije UNWTO-a za 2020. godinu sugeriraju kako bi se međunarodni dolasci mogli smanjiti za 20% do 30% u odnosu na 2019. godinu (Grafikon 8).

Grafikon 8 Predviđanja 2020: Međunarodni turistički dolasci - svijet - (% promjena)

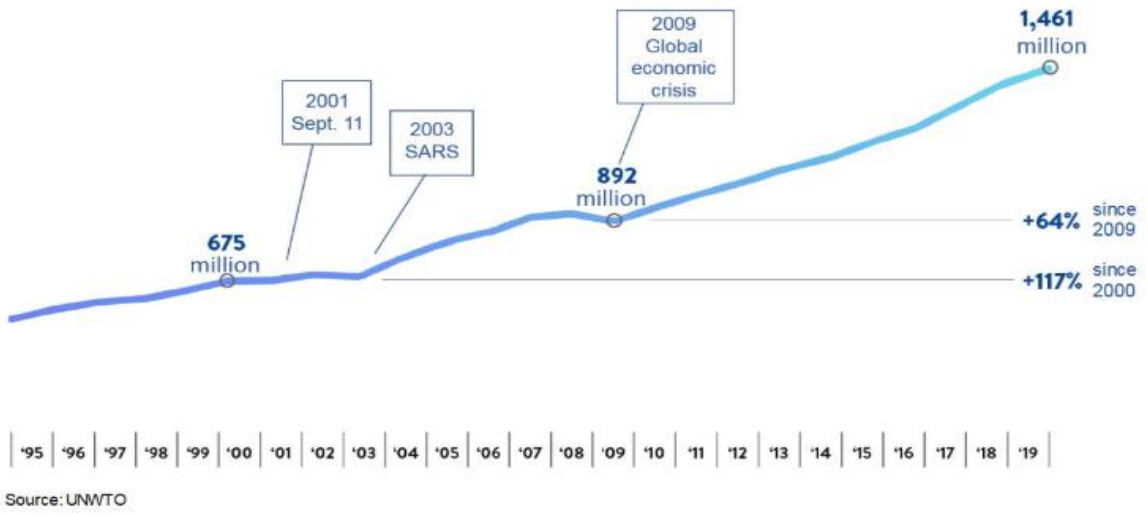


Izvor: preuzeto s UNWTO (2020)

Izbijanje korona virusne bolesti (COVID-19) u siječnju 2020. godine u Wuhanu ostavlja značajan utjecaj na kinesko gospodarstvo, posebice na mala i srednja poduzeća (Lu et al., 2020). Autori su prilikom svog istraživanja proveli internetski anketni upitnik i intervjue na 4807 malih i srednjih poduzeća u Sichuanu kako bi se procijenio izazov vezan uz daljnji nastavak rada. Rezultati njihova istraživanja pokazali su kako većina malih i srednjih poduzetnika nije mogla nastaviti posao zbog nedostatka materijala za ublažavanje epidemija, nemogućnosti zaposlenika da se vrate na posao, poremećenih lanaca opskrbe i smanjene potražnje na tržištu, te suočavanje s rizikom novčanog toka iz razloga što su poduzetnici morali nastaviti plaćati razne fiksne rashode iako su imali malen ili nikakav prihod (Lu et al., 2020). Ključnu ulogu pri oporavku svjetske ekonomije i postizanju dugoročne održivosti ugostiteljstva od COVID-19 imaju fleksibilnije cijene, politika otkazivanja rezervacija, fleksibilno radno okruženje.

Međunarodni turizam (UNWTO, 2020) unazad desetak godina bilježi stalnu ekspanziju, usprkos povremenim šokovima, pokazujući snagu i otpornost sektora te evidentnu korist svim regijama svijeta (Grafikon 9). Kriza potaknuta pandemijom COVID-19 nije kao nijedna do sada te zahtijeva snažne i koordinirane akcije.

Grafikon 9 Deset godina kontinuiranog rasta turizma



Izvor: preuzeto s UNWTO (2020)

4.6. Volatilnost tečaja i turizam

Tečaj predstavlja važan faktor zarade za turizam (Becken, Carboni, Vuletich i Schiff, 2008; Blake, Arbache, Sinclair i Teles, 2008). Ostvarenje punog potencijala i prednosti turističke aktivnosti u improvizaciji gospodarskog blagostanja odredišne zemlje uvelike ovisi o fluktuacijama tečaja (Webber, 2001; Croes i Vanegas, 2005; Mangion et al., 2005; De Vita i Kyaw, 2013; De Vita, 2014).

Volatilnost tečaja između valute odredišne države s onom zemljom podrijetla ili drugih međunarodnih valuta negativno utječe na ukupni priljev turista i tako negativno utječe na zaradu od deviza. Pojava deprecijacije valute odredišne zemlje međunarodni turizam čini jeftinijim što može pozitivno utjecati na broj dolazaka. To se najčešće događa zato što međunarodne turiste više brinu tečajevi valuta nego cijene (životni troškovi) u odredišnoj zemlji (Sharma i Pal, 2019). Rezultati istraživanja na temu tečaja i turističke potražnje nisu jednoznačni (Crouch 1994a; Crouch 1994b). Neka su empirijska istraživanja utvrdila kako tečaj nema značajne učinke na turističku potražnju. Quayson i Var (1982) sugeriraju da je turistička potražnja u Okanaganu BC slabo povezana s volatilnošću tečaja. Slab utjecaj fluktuacije tečaja na turističku potražnju potvrđen je za Italiju (Quadri i Zheng,2010) i Australiju (Pham et al., 2017). Tečaj se nije pokazao statistički signifikantnom varijablom u procjeni turističke potražnje Arube od strane američkih turista (Vanegas i Croes, 2000). Rezultati istraživanja Quadri i Zheng (2010) na primjeru 19 različitih zemalja ukazuju da tečaj nema utjecaj na turizma kod 11 od 19 zemalja.

U svom drugom istraživanju Croes i Vanegas, (2005) dolaze do oprečnih rezultata. U svojoj studiji koriste dinamički ekonometrijski model Box-Cox. Iz rezultata je vidljivo da tečaj pozitivno utječe na dolazak turista u Arubu iz Venezuele, SAD-a i Nizozemske, ali koeficijent varijable tečaja statistički je signifikantan samo za Venezuelu. Do sličnih rezultata dolaze i Patsouratis, Frangouli i Anastasopoulos (2005) koji utvrđuju kako je jedna od glavnih odrednica grčkog međunarodnog turističkog priljeva tečaj. Koristeći godišnje podatke za razdoblje od 1960. do 2001. godine Roselló-Villalonga, Aguiló-Pérez i Riera (2005) tvrde da turisti koji putuju na Balearske otoke iz Njemačke i Ujedinjenog Kraljevstva prikupljaju informacije o nestabilnosti tečaja. Radeći na skupu podataka s presjekom od 84 zemlje Chiu i Yeh (2017) utvrđuju da je tečaj glavni faktor koji utječe na turističku potražnju. Nadalje, koristeći skupinu od 218 zemalja od 1995. do 2012. godine Martins, Gan i Ferreira-Lopes (2017) utvrdili su da je tečaj signifikantna odrednica svjetske turističke potražnje. Webber (2001) proučava

volatilnost i kointegraciju deviznih tečajeva u australskoj turističkoj potražnji. Fluktuacija pri tečaju predstavlja signifikantan faktor koji određuje čak 50% dugoročne turističke potražnje. Nestabilan tečaj ima snažan prigušujući utjecaj na australijske turiste koji putuju na Filipine, Singapur, Tajland i Maleziju. Gan (2015) navodi kako prihod predstavlja kritičnu varijablu koju turisti moraju uzeti u obzir za donošenje odluke o putovanju. Gospodarski rast dovodi do rasta raspoloživog dohotka, što pozitivno utječe na povećanje budžeta za putovanja i rekreaciju. Tečaj i cijene robe (stopa inflacije) u odredišnoj zemlji igraju važnu ulogu. Domaća inflacija i aprecijacija domaće valute u odredišnoj zemlji nalažu da turisti trebaju potrošiti više kako bi kupili istu robu i usluge, što slabi privlačnost odredišta. Kod deprecijacije domaće valute potencijalni posjetitelji spremni su putovati (Wang et al., 2008; Gan, 2015).

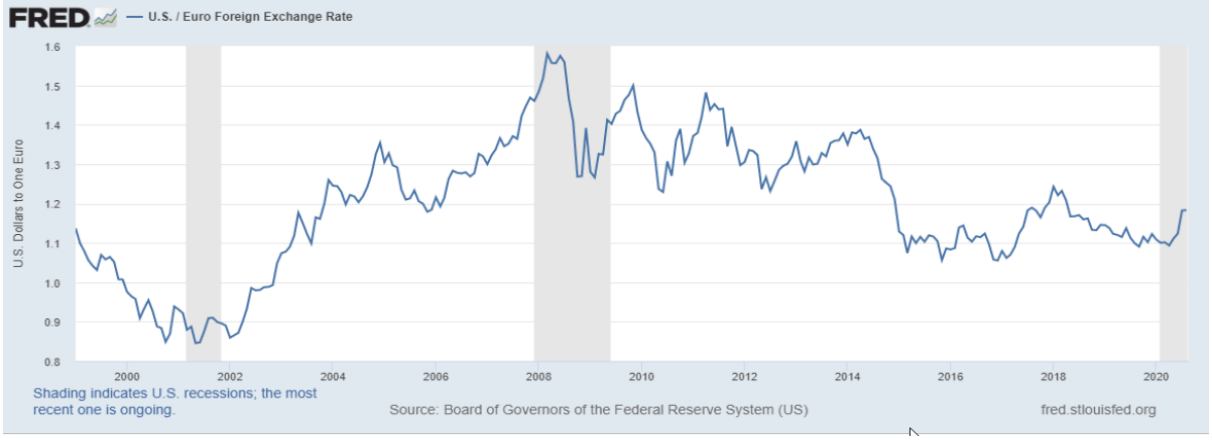
Song i Li (2008) tvrde kako postoje dvije perspektive iz kojih se može procijeniti ovisnost (pozitivna ili negativna) između međunarodne turističke potražnje i deprecijacije valute. Prva perspektiva razmatra reakciju turista na tečaj. Tečajevi putem učinka relativnih cijena imaju utjecaj na putovanje (Webber, 2001; Chang i McAleer, 2012). Turisti će radije posjetiti zemlje s nižom vrijednosti valute, u usporedbi s njihovom vlastitom valutom. Stoga se uspostavlja odnos pozitivne (negativne) ovisnosti između međunarodnog turizma i deprecijacije valute. Druga perspektiva na tu ovisnost razmatra reakciju turista na fluktuiranje tečaja. Promjene u fluktuacijama tečaja utječu na troškove racionalnog turista kao i broj dolazaka. Nagle fluktuacije mogu biti signal nestabilnosti ili nereda uslijed događaja kao što su prirodne katastrofe, teroristički napadi ili društveni razvoj (Chang i Chang, 2020). Reakcija turista na promjene tečaja ovisi o njihovom stavu prema riziku (De Vita i Kyaw, 2013; Perpiña et al., 2019). Tečaj i stopa inflacije vjerojatnije će utjecati na inozemne turiste (Gan, 2015). Kuo et al., (2009) također koriste panel analizu kako bi istražili utjecaj tečaja na turističku potražnju u osam azijskih zemalja. Oni utvrđuju da je valuta odredišne zemlje koja se deprecira u odnosu na valutu zemlje podrijetla dobra za međunarodno turističko poslovanje zemlje i obrnuto.
Prema Chao et al. (2013) tečaj ima dominantan učinak na broj dolaznih turista. Efekt povećanja domaće inflacije cijena može se prenijeti na inozemne goste dok borave u zemlji. Slijedom navedenog, deprecijacija domaće valute može naštetiti prihodu od inozemnog turizma. Autori zaključuju kako volatilnost valute utječe ne samo na troškove posjetitelja već i na dolaske, a dugoročno i na prihode. Empirijske studije koje istražuju turizam otkrivaju da deprecijacija tečaja u odredišnoj zemlji privlači turističke tokove, dok aprecijacija tečaja smanjuje odljeve iz turizma (Garin-Munoz i Amaral, 2000; Agiomirgianakis et al., 2012; Patsouratis, 2005). Kako jaka domaća valuta može imati negativne učinke na međunarodne dolaske turista kroz utjecaj

cijena evidentiraju Chang i McAleer (2012). Približni učinci cijena i nestabilnosti cijena obično su različiti, s tim da tečaj obično ima očekivani negativan utjecaj na dolazak turista na Tajvan, dok volatilnost tečaja može imati pozitivne i negativne učinke na dolaske turista na Tajvan (Chang i McAleer, 2012). Istraživanje dinamičkog dugoročnog i kratkoročnog odnosa između broja međunarodnih dolazaka turista iz šest europskih zemalja i četiri odabrane ekonomske varijable (tečaj, BDP, relativna cijena i zamjenska relativna cijena) temeljni je cilj studije Borhan i Arsad (2016). Autori koriste ARDL model, a rezultati ispitivanja pokazuju da postoji dugotrajna kointegracija između broja međunarodnih turističkih dolazaka i tečaja, razine prihoda, turističke cijene i zamjenske turističke cijene za sve zemlje.

Fluktuacije tečaja mogu biti identificirane kao jedini faktor koji određuje turističke tokove što potvrđuje slučaj s njemačkim priljevima turizma u Grčkoj. Istraživanje Chang i Chang (2020) ukazuje da politika deviznog tečaja utječe na turističku aktivnost u stanju visoke volatilnosti, ali ne i u stanju niske volatilnosti.
Meurer (2010) analizira ponašanje stranih putnika u Brazil i ostvarene prihode u platnoj bilanci. Dobiveni rezultati ukazuju da je broj putnika prilično osjetljiv na svjetski prihod i manje osjetljiv na tečaj. Prihodi ne reagiraju na tečaj. Tečaj ima utjecaj na prihode sa zaostatkom od četiri tromjesečja. Autor zaključuje kako dobiveni rezultati mogu značiti da na troškove inozemnih putnika ne utječu njihovi troškovi mjereni u valuti zemlje podrijetla.

Assaf et al., (2018) također pronalaze potkrepljujuće dokaze o značajnom utjecaju fluktuacija tečaja na priljev turista u devet država jugoistočne Azije. Studija uvodi sveobuhvatan pristup analizi potražnje turizma, temeljen na Bayesovom globalnom vektorskom autoprogresivnom modelu (BGVAR). Studija međunarodnih turističkih tokova pokazuje sposobnost BGVAR modela da zabilježi prelijevajuće efekte međunarodne turističke potražnje u spomenutoj regiji.

Grafikon 10 Kretanje tečaja dolar/euro tijekom godina (1999. – 2020.)



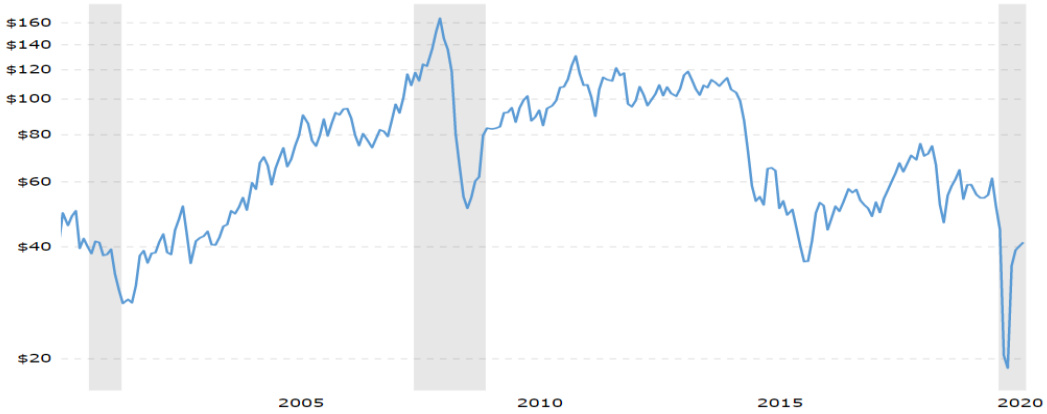
Izvor: FRED (Economic Research Federal Reserve Bank of St. Louis)

Grafikon 10 preuzet je sa stranica FRED kako bi se prikazalo kretanje tečaja dolar/euro unazad dvadesetak godina. Vidljive su oscilacije odnosno izražena volatilnost tečaja na raznorazne situacije i šokove u okruženju.

4.7. Cijena nafte i turizam

Ovisnost turizam je naftno intenzivan sektor, a ovisnost turizma o nafti posljedica je njegove prometne sastavnice (Shahzad i Caporin, 2020). Dostupnost i cijena nafte važni su čimbenici koji su usko povezani s globalnom ekonomijom pa tako i turizmom. Turizam se u velikoj mjeri oslanja na naftu, ne samo zbog transportnih komponenti veći i za mnoge druge dijelove turističkog proizvoda, kao što je smještaj, rekreacijske aktivnosti. Globalna potražnja za naftom neprestano raste, a cijena nafte vrlo je nestabilna (Grafikon 11) (Becken, 2011).

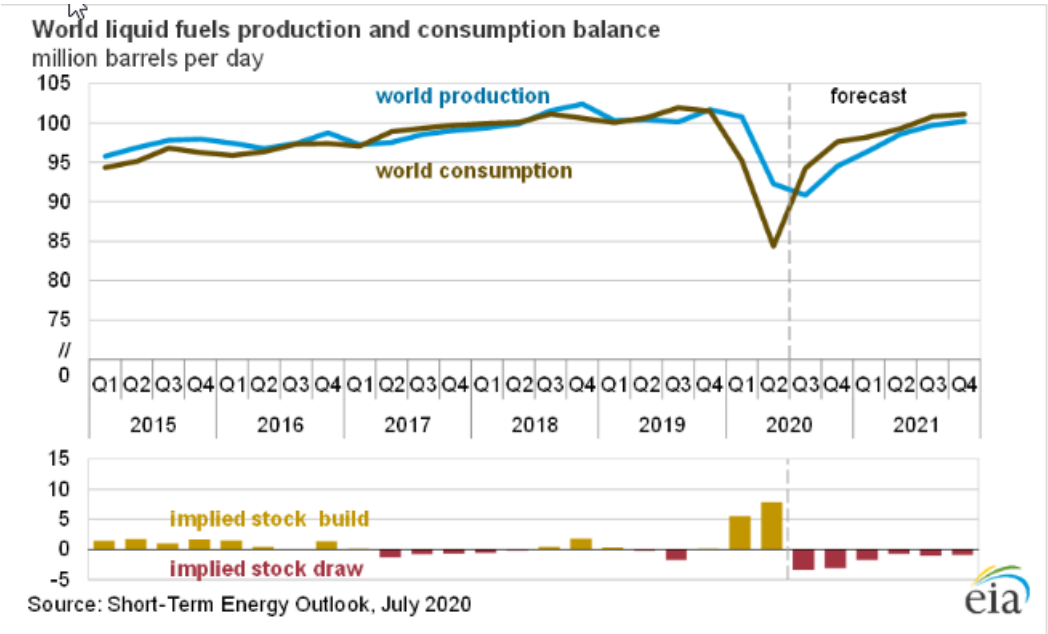
Grafikon 11 Cijena sirove nafte (WTI-west Texas intermediate) po barelu



Izvor: Energy Information Administration (EIA)

Prekidi u opskrbi i potrošnji nafte na globalnoj razini 2020. godine rezultat su pandemije COVID-19. S obzirom na to da su cestovni i zračni promet naglo stagnirali, globalna potrošnja tekućih goriva pala je brže od proizvodnje. EIA (Energy Infromation Administration) temeljem neujednačenosti proizvodnje i potrošnje tekućih goriva procjenjuje kako su se globalne zalihe nafte povećale za gotovo 1,3 milijarde barela. Akumulacija zaliha uzrokovala je pad cijena Brent sirove nafte u mjesecu siječnju sa 64 $ po barelu na 18 $ po barelu u travnju 2020. godine (Grafikon 12).

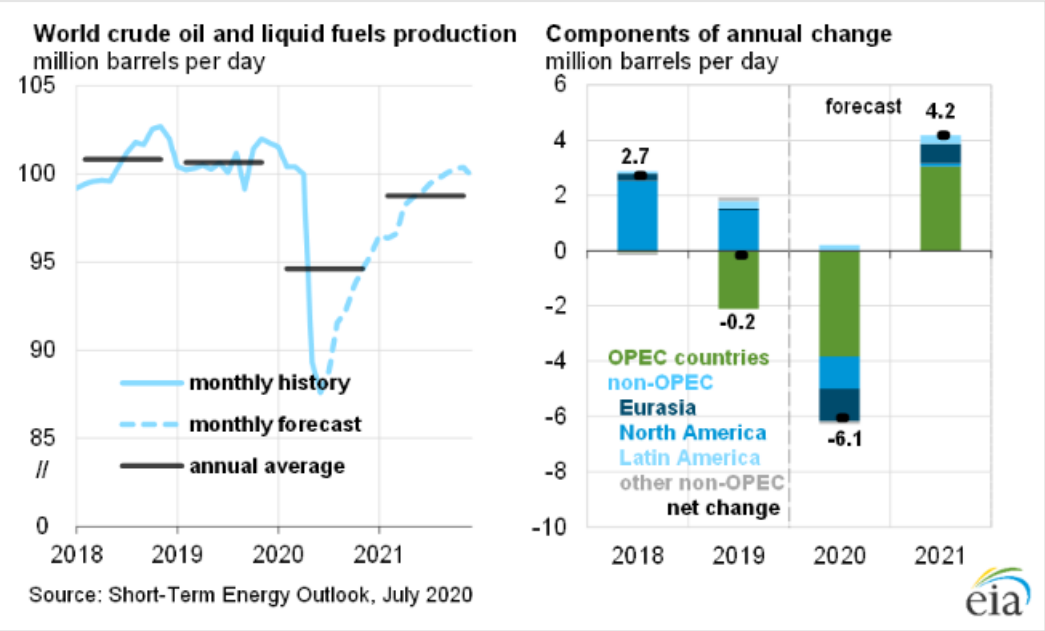
Grafikon 12 Proizvodnja i potrošnja tekućih goriva na svjetskog razini



Izvor: Energy Information Administration (EIA)

Navedeni pad cijene nije mogao pozitivno djelovati na povećanje turističkih kretanja iz razloga što je spomenuta epidemija uzrokovala stagnaciju prometa. EIA (Energy Infromation Administration) procjenjuje da će se globalne zalihe nafte povući do kraja 2021. godine, te da će se globalna potražnja za naftom nastaviti oporavljati iako će procijenjena potrošnja globalnih tekućih goriva za 2021. godinu još uvijek manja no što je bila u istom razdoblju za 2019. godinu (Grafikon 13).

Grafikon 13 Predviđanja svjetske potrošnje sirovih i tekućih goriva



Izvor: Energy Information Administration (EIA)

Odnos cijena nafte i turističkih dolaska privlači značajnu pažnju iz razloga što točno otkrivanje uzročno-posljedičnog odnosa cijena nafte i dolazaka turista može pomoći procesu planiranja turizma i pomoći u poboljšanju kvalitete predviđanja turističkih dolazaka i povezanih upravljačkih odluka (Goh, 2012). Promjena cijena nafte može naštetiti gospodarskim i turističkim aktivnostima zbog učinka koji imaju na prijevoz, troškove proizvodnje, ekonomsku nesigurnost i raspoloživi prihod (Becken, 2008). Veće cijene nafte čine turizam skupljim i negativno utječu na globalnu turističku potražnju (Yeoman et al., 2007).

Zemljama koje su ovisne o turizmu prihodi iz turističkih aktivnosti mogu potencijalno pomoći u olakšanju budućih razvojnih strategija i ciljeva ili pomoći u stvaranju otporne ekonomije. Važno je naglasiti činjenicu da su zemlje s velikom ovisnošću o turističkim aktivnostima neravnomjerno izložene naglim oscilacijama u cijenama nafte (Becken i Lennox, 2012). Prethodna istraživanja pokazuju da veće cijene nafte negativno utječu na turizam (Yeoman et al., 2007; Becken, 2011; Becken i Lennox, 2012). Makroekonomske i mikroekonomske učinke cijene nafte istražuje Becken (2011). Promatrano s makroekonomskog aspekta, veće cijene nafte uglavnom dovode do veće inflacije. Iz mikroekonomske perspektive, pozitivni šokovi cijene nafte dovode do pada raspoloživog dohotka. Navedena kretanja imaju neposredan i negativan utjecaj na turizam, uglavnom zbog činjenice da se turizam smatra luksuznim dobrom

(Lim, Min i McAleer, 2008; Nicolau, 2008). Chatziantoniou et al., (2013) u svom istraživanju koriste VAR model kako bi istražili odnos između šokova cijena nafte, turističkih varijabli i ekonomskih pokazatelja u četiri europske mediteranske zemlje (Francuska, Italija, Španjolska i Grčka). Autori razlikuju tri vrste šoka cijene nafte: šok ponude, šok agregata i specifični šok potražnje. Rezultati njihova istraživanja pokazuju kako specifični šokovi potražnje za naftom istovremeno utječu na inflaciju i indeks kapitalnog učinka turističkog sektora. Zaključuju kako šokovi cijene nafte u agregatnoj potražnji djeluju izravno ili neizravno, na prihod ostvaren od turizma i na gospodarski rast. Na primjeru Malezije i Indonezije istraživanje provede Loganathan, Yuliza, Subramaniam i Ibrahim (2020). U studiji autori koriste mjesečne podatke za razdoblje od 1995. godine do 2016. godine primjenom koncepta gotovo idealnog sustava potražnje kako bi istražili u kojoj mjeri turističke cijene i volatilnost globalnih cijena nafte određuju bilateralnu turističku potražnju između ovih dviju zemalja. Autori na temelju dobivenih rezultata zaključuju kako bilateralna turistička potražnja između Malezije i Indonezije nema utjecaj na turističku cjenovnu elastičnost potražnje.

Nadalje, Hassani et al., (2020) također istražuju uzročni odnos između cijene nafte i dolaska turista na primjeru SAD-a i devet europskih zemalja kako bi dodatno objasnili utjecaj volatilnosti cijena nafte na gospodarske aktivnosti povezane s turizmom. Analiza koju su proveli u obzir je uzimala vremenske domene, frekvencijske domene i perspektivne domene teorije informacija te CCM (eng. Convergent Cross Mapping). Tehnika CCM pokazala se pouzdanom i učinkovitom metodom otkrivanja uzročno-posljedične situacije kada se suoči sa složenim i nelinearnim scenarijima o kojima svjedoče naftno-turističke studije. Rezultati istraživanja dokazuju postojanje jednosmjerne uzročnosti od cijena nafte do dolazaka turista za sve zemlje.

Malezija je bila predmet istraživanja i u slučaju Yap et al., (2020) koji navode kako će procjena značajnih ekonomskih koristi od *event* turizma pružiti uvid u učinkovitost turističkih događanja. Njihova studija empirijski istražuje odrednice turističke potražnje u Maleziji u razdoblju od 1991. godine do prvog kvartala 2016. godine. Dugoročni odnos kointegracije modela autori provode uz ARDL model koji se dalje testira primjenom dijagnostičkih testova (RESET test, eng. Regression Specification Error Test) i testova stabilnosti (CUSUM test, eng. Cumulative Sum Control Chart). Rezultati studije upućuju na to da se potražnja za *eventima* može značajno poboljšati kada se povećavaju vladina potrošnja, tečajni i turistički prihodi te kada se smanji cijena sirove nafte. Isti model (ARDL model) korišten je bio i u slučaju studije Muchapondwa

i Pimhidzai (2011). Autori su istraživali čimbenike koji utječu na dolazak turista u Zimbabwe u periodu od 1998. do 2005. godine. Rezultati pokazuju kako troškovi prijevoza i promjene u prihodima turista imaju značajan utjecaj na turističku potražnju. Ispitivanje asimetričnog učinka cijena nafte na prihode od turizama uz pomoć NARDL modela, testirajući pritom je li pozitivne inovacije u cijenama nafte imaju isti učinak kao i njihove negativne usporedbe, provode Kisswani et al., (2020). Analiza se provodi na 19 nasumično odabranih međunarodnih destinacija za razdoblje od 1995. do 2015. godine. Empirijski nalazi dokumentiraju dugoročno asimetrični učinak u slučaju Austrije, Francuske, Velike Britanije, Grčke, Islanda, Italije, Luksemburga, Norveške, Portugala, Švedske i Sjedinjenih Američkih Država, dok za Finsku nije uspostavljen dugoročni odnos. S druge strane, kratkoročni asimetrični utjecaj otkriven je u slučaju Austrije, Velike Britanije, Portugala, Švedske i Sjedinjenih Američkih Država.

Jeřábek (2019) provodi istraživanje utjecaja prihoda kroz bruto domaći proizvod, turističke cijene kroz stvarni tečaj i putnih troškova kroz cijene Brent nafte na ulaznu turističku potražnju Češke iz Poljske, Slovačke, Njemačke, Austrije u Južnoj Moravskoj (regiji) za razdoblje od 2002. do 2018. godine. Za provedbu analize autor koristi VECM model čiji rezultati pokazuju kako slovački, poljski, austrijski i njemački turisti pozitivno reagiraju na promjene svojih prihoda, dok na promjene u turističkim cijenama Češke negativno reagiraju samo austrijski i slovački turisti. Promjene u troškovima putovanja negativno utječu na njemačke, austrijske i slovačke turiste, dok poljski turisti ne reagiraju na promjene troškova prijevoza.

5. EMPIRIJSKA ANALIZA UTJECAJA EKSTERNIH ŠOKOVA NA TURIZAM

Po završetku teorijskog prikaza problematike rada te definirane metode rada, poglavlje pet testirat će postavljene istraživačke hipoteze za vremensku komponentu promatranja koja započinje od 1995. do 2019. godine *(T = 25)*, pokušati razjasniti (1) koliko je zapravo turizam osjetljiv na pojedine eksterne šokove, (2) utjecaj eksternih šokova na turizam unutar dugog i kratkog roka te (3) postoji li međuovisnost turizma i postavljenih nezavisnih varijabli.

Prostorna komponenta istraživanja obuhvaća analizu podataka na ukupno 168 zemalja (popis svih država u prilogu 2) *(n = 168)* za koje su dostupni podaci uključeni u model. Korišteni izvori podataka prikupljeni su iz sljedećih baza podataka: (1) WorldBank, (2) World Travel & Tourism Council (WTTC), (3) Satellite Account methodology, (4) World Tourism Organization (UNWTO), (5) International disaster database (EM-DAT), (6) Global Terrorism database, (7) Global Health Data Exchange (GBD), (8) United Nations – Total international migrant stock, (9) Worldwide Governance Indicator, (10) Uppsala Conflict Data Program, (11) British Petroleum.

Empirijska analiza podijeljena je na tri potpoglavlja koja se odnose na primjenu odabranih modela u svrhu testiranja postavljenih hipoteza. Svako potpoglavlje započinje detaljnim objašnjenjem odabranih modela koji se primjenjuju u svrhu testiranja postavljenih hipoteza. Provedeno istraživanje kvantitativnog je oblika s obzirom na to da je proces istraživanja unaprijed definiran i strukturiran, dok faza prikupljanja podataka ujedno prethodi i fazi analiziranja podataka. Istraživanje polazi od pretpostavke kako je panel modelom vremenskih serija moguće identificirati utjecaj eksternih šokova na turizam. Panel analiza vremenskih serija te ocjena utjecaja eksternih šokova na turizam, odnosno ocjena njegove volatilnosti provest će se putem ekonometrijskog softvera STATA.

Utjecaj eksternih šokova na turizam ispituje se regresijskom analizom veze ukupnog broja ostvarenih noćenja (lnTTons) koji ujedno predstavljaju zavisnu varijablu te skupa nezavisnih varijabli od interesa koje direktno ili indirektno utječu na turizam kao aktivnost, a te varijable su redom: (1) teroristički napadi (lnTAnd), (2) zdravstvena pitanja (lnHQnd), (3) prirodne katastrofe (lnNDnd), (4) migracije (lnMig), (5) politička nestabilnost (PII), (6) ratovi (lnWar), (7) cijena nafte (lnAPO), (8) volatilnost tečaja (lnVER) te kontrolnih varijabli koje izravno ili posredno utječu na aktivnost turizma, a to su bruto domaći proizvod prema paritetu kupovne

moći (lnGDPp), rast bruto domaćeg proizvoda (GDPgrowth) te broj stanovništva odnosno populacija svake zemlje (POP). Detalji odabranih varijabli prikazani su u tablici 7.

S ciljem testiranja prve postavljene hipoteze provodi se panel analiza unutar čijeg modela je uključeno 168 zemalja na cjelokupnom uzorku.

S obzirom na to da između nezavisnih i zavisnih varijabli postoji nelinearni odnos logaritamskog pretvaranja varijabli unutar regresijskog modela, vrlo je čest način rješavanja takvih problema. Logaritamske transformacije predstavljaju prikladno sredstvo za pretvaranje visokoiskrivljene varijable u onu koja je približno normalna (Benoit, 2011). Prema uzoru na istraživanje spomenutog autora za svaku varijablu unutar modela kreiran je histogram kako bi se utvrdila distribucija podataka. Za visokoiskrivljene varijable primijenjen je prirodni logaritam kako bi se distribucija podataka normalizirala. Varijable koje su logaritmirane su sljedeće:

- ukupno ostvaren broj noćenja (lnTTons)
- teroristički napadi (lnTAnd)
- zdravstvena pitanja (lnHQnd)
- prirodne katastrofe (lnNDnd)
- migracije (lnMig)
- cijena nafte (lnAPO)
- volatilnost tečaja (lnVER)
- rat (lnWar)
- rast bruto domaćeg proizvoda (GDPgrowth)
- bruto domaći proizvod pariteta kupovne moći (lnGDPp) te
- populacija (POP).

Tablica 7 Varijable kvantitativnog istraživanja

Naziv varijable	Oznaka varijable	Vrsta varijable	Definicija varijable	Način mjerenja varijable
Ukupno ostvarena noćenja (u tisućama)	**lnTTons**	Zavisna varijabla	Međunarodni turizam obuhvaća ulazni turizam i izlazni turizam, odnosno aktivnosti rezidencijalnih posjetitelja izvan referentne zemlje bilo u sklopu domaćih bilo odlaznih turističkih putovanja i aktivnosti nerezidentnih posjetitelja u zemlji referentne zemlje na ulaznim turističkim putovanjima.	Podatak dobiven temeljem zbroja ulaznog turizma (dolasci nerezidentnih posjetitelja – turista) s ostvarenim noćenjem evidentiranim na državnim granicama te domaćeg turizma (ukupan broj gostiju u svim uslugama komercijalnog smještaja). Podaci o spomenutim varijablama preuzeti su od World Tourism Organization[7] (UNWTO) za period od 1995. do 2019., a frekvencija podataka je godišnja.
Izravan doprinos turizma % od BDP-a	**TGDP2**	Nezavisna varijabla	Izravan doprinos turizma obuhvaća sve sektore koji se izravno bave turistima, uključujući hotele, putničke agencije, zrakoplovne tvrtke i druge usluge prijevoza putnika kao i djelatnosti restoranske i turističke aktivnosti koje se izravno bave turistima.	Podaci su izraženi kao postotak koji predstavlja ekvivalent ukupnoj unutarnjoj potrošnji za putovanja i turizam u zemlji umanjenoj za kupovine te aktivnosti. Metodologija UN-ovog satelitskog računa za turizam (TSA) u skladu je s ukupnim BDP-om izračunatim u tablici 6. TSA-a. Podaci su prikupljeni iz statističke baze podataka World Travel & Tourism Council za period od 1995. do 2019. te je frekvencija podataka godišnja.

[7] Podaci o dolascima – mjere protok međunarodnih posjetitelja u referentnu zemlju: svaki dolazak odgovara jednom turističkom putovanju. Ako osoba posjeti nekoliko zemalja tijekom jednog putovanja, njezin se dolazak u svaku zemlju bilježi zasebno. U obračunskom razdoblju dolasci nisu nužno jednaki broju osoba koje putuju (kada osoba posjeti istu zemlju nekoliko puta godišnje, svako putovanje iste osobe računa se kao zasebni dolazak). Podaci o dolascima trebaju odgovarati dolaznim posjetiteljima, uključujući oboje, i turiste i nerezidentne posjetitelje unutar jednog dana. Sve ostale vrste putnika (poput graničnih, sezonski i drugih kratkotrajnih radnika, dugogodišnjih studenata i ostalih) treba izuzeti jer se ne kvalificiraju kao posjetitelji.
Ulazni turizam obuhvaća aktivnosti nerezidentnog posjetitelja unutar referentne zemlje na putovanju dolaznog turizma. Odgovarajući izdaci takvog posjetitelja identificiraju se kao izdaci za ulazni turizam.
Domaći turizam obuhvaća aktivnosti rezidencijalnog posjetitelja unutar referentne zemlje (bilo kao domaćeg turističkog putovanja ili dio inozemnog turističkog putovanja). Odgovarajući izdaci u referentnom gospodarstvu takvog posjetitelja identificiraju se kao izdaci za domaći turizam. Također, izdaci odlaznih posjetitelja na proizvode dobivene od rezidentnih poduzeća uključeni su u domaće izdatke.

				U modelu se provodi panel analiza na temelju dva skupa podjele uzorka podataka koji su definirani prema visini izravnog doprinosa ostvarenog od strane turizma u BDP-u. Da bi se kreirali skupovi, za svaku državu je za spomenuto razdoblje izračunat prosjek izravnog udjela turizma u BDP-u. U nastavku slijede spomenuti skupovi podataka prema postotku : • (I. skup podjele uzorka podataka) 0% – 5% izravnog doprinosa od strane turizma u BDP-u • (II. skup podjele uzroka podataka) 5,01% – 10% izravnog doprinosa od strane turizma u BDP-u
% rasta BDP-a (godišnje)	**GDPgrowth**	Kontrolna varijabla	BDP predstavlja zbroj bruto dodane vrijednosti svih rezidentnih proizvođača u gospodarstvu uvećan za sve poreze na proizvode i umanjen za sve subvencije koje nisu uključene u vrijednost proizvoda. Izračunava se bez odbitka za amortizaciju proizvedene imovine ili za trošenje i degradaciju prirodnih resursa.	Podaci predstavljaju godišnju postotnu stopu rasta BDP-a po tržišnim cijenama na temelju konstantne lokalne valute. Agregati se temelje na stalnim američkim dolarima s baznom 2010. godinom. Podaci su prikupljeni iz statističke baze podataka WorldBank za period od 1995. do 2019. te je frekvencija podataka godišnja.
BDP (paritet kupovne moći) u stalnim cijenama s baznom godinom 2017. ($)	**lnGDPp**	Kontrolna varijabla	Pariteti kupovne moći predstavljaju oblik mjerenja razlika u cijenama između zemalja.	BDP paritet kupovne moći bruto je domaći proizvod pretvoren u međunarodne dolare koristeći paritet kupovne moći. Međunarodni dolar ima istu kupovnu moć nad BDP-om kao američki dolar u Sjedinjenim Državama. Agregati se temelje na stalnim međunarodnim dolarima s baznom 2017. godinom, a frekvencija podataka je godišnja. Podaci su prikupljeni iz

				statističke baze podataka WorldBank za period od 1995. do 2019.
Populacija	**POP**	Kontrolna varijabla	Broj stanovnika svake države	Ukupna populacija temelji se na *de facto* definiciji stanovništva, koja broji sve stanovnike bez obzira na pravni status ili državljanstvo. Prikazane vrijednosti su srednje-godišnje procjene. Podaci su prikupljeni iz statističke baze podataka WorldBank.
Prirodne katastrofe (broj smrtno stradalih i nestalih)	**lnNDnd**	Nezavisna varijabla	Prirodne katastrofe predstavljaju katastrofalne događaje atmosferskog, geološkog i hidrološkog podrijetla (Cavallo, Gallini i Pantano, 2013).	Podaci koji su uključeni, a koji ujedno bilježe katastrofe, ispunjavaju jedan od sljedećih kriterija: (1) smrtno stradalih 10 ili više ljudi, (2) pogođenih 100 ili više osoba (pogođenih, ozlijeđenih, beskućnika), (3) izjava/međunarodna žalba, izjava o izvanrednom stanju i/ili apel za međunarodnu pomoć. Podaci uključeni u model obuhvaćaju broj smrtno stradalih slučajeva te nestalih osoba svih triju glavnih skupina katastrofa: (1) prirodnih, (2) tehnoloških i (3) složenih katastrofa[8]. Podaci uključuju period od 1995. do 2019. godine. Podaci su preuzeti sa statističke baze International disaster database (EM-DAT), a frekvencija podataka je godišnja.
	lnTAnd	Nezavisna varijabla	Prijetnja ili stvarna uporaba ilegalne sile i nasilja[9] od strane nedržavnog aktera u	Podaci uključuju ukupno potvrđenih smrtnih slučajeva za incident. Broj uključuje sve žrtve i napadače koji su umrli kao izravna posljedica incidenta. Podaci koji ne ulaze u bazu su oni u kojima postoje dokazi o smrtnim slučajevima, ali brojka nije prijavljena ili je previše nejasna da bi bila korisna. Ako nedostaju

[8] Složene katastrofe uključuju neke velike situacije gladi kojima suša nije bila glavni uzročnik.

[9] Da bi podaci bili uključeni u GTD, moraju biti prisutna sljedeća tri uvjeta: (1) incident mora biti namjeran – rezultat svjesne kalkulacije počinitelja, (2) incident mora podrazumijevati određenu razinu nasilja ili neposrednu prijetnju nasiljem, uključujući nasilje nad imovinom, kao i nasilje nad ljudima, (3) počinitelji incidenta moraju biti pod-nacionalni akteri.
Baza podataka ne uključuje djela državnog terorizma. Uz navedeno, najmanje dva od sljedeća tri kriterija moraju biti prisutna da bi se incident uključio u GTD: (1) čin mora biti usmjeren na postizanje političkog, ekonomskog, vjerskog ili socijalnog cilja, (2) moraju postojati dokazi o namjeri prisile, zastrašivanje ili prenošenja neke druge poruke široj publici od neposrednih žrtava. Čin se uzima kao cjelina koja se uzima u obzir, bez obzira je li svaki pojedinac koji je sudjelovao u izvršenju djela bio svjestan te namjere. Kriterij namjernosti zadovoljen je sve dok bilo tko od planera ili donositelja odluke koji stoje iz napada namjeravaju prisiliti, zastrašiti ili objaviti, (3) djelovanje mora biti izvan

Teroristički napadi (broj smrtno stradalih)			svrhu postizanja političkog, ekonomskog, vjerskog ili socijalnog cilja strahom, prisilom ili zastrašivanjem (GTD, 2019)	podaci o broju žrtava ubijenih u napadu, ali su poznati smrtni slučajevi počinitelja, ova će vrijednost odražavati samo broj počinitelja koji su umrli kao rezultat incidenta. Isto tako, ako nedostaju podaci o broju počinitelja ubijenih u napadu, a poznati su smrtni slučajevi žrtava, podaci uključuju samo broj žrtava ubijenih u incidentu. Napadi koji su se realizirali bez smrtnih slučajeva označeni sa 0.01. Podaci uključuju period od 1995. do 2019. godine. Podaci su preuzeti sa statističke baze Global Terrorism database (GTD), a frekvencija podataka je godišnja.
Zdravstvena pitanja (broj smrtno stradalih)	**lnHQnd**	Nezavisna varijabla	Uzroci smrti zaraznim bolestima i majčinim, prenatalnim i prehrambenim uvjetima.	Podaci uključuju broj smrtno stradalih od posljedica zaraznih bolesti te majčinih, prenatalnih i prehrambenih uvjeta (Communicable diseases and maternal, prenatal and nutrition, CMNN – bolesti koje uključuju zarazne i parazitske bolesti, respiratorne infekcije i prehrambene nedostatke poput nedovoljno težine i zaostajanje u razvoju) tijekom određenog razdoblja. Podaci su preuzeti sa statističke baze Global Health Data Exchange (GHDx). Spomenuta baza usko surađuje s World Health Organization i WorldBank koji ih također navode kao izvor unutar svojih izvora podataka. Podaci se odnose na period od 1995. do 2019., a frekvencija podataka je godišnja.
Migracije	**lnMig**	Nezavisna varijabla	Međunarodna migrantska kretanja predstavlja broj ljudi rođenih u zemlji koja nije ona u kojoj žive.	Podaci su prikupljeni sa statističke baze podataka Ujedinjenih naroda (UN), a frekvencija podataka jest svakih pet (5) godina (1995; 2000; 2005;2010;2015;2019). Međunarodna migrantska kretanja predstavlja broj ljudi rođenih u zemlji koja nije ona u kojoj žive. Uključuje i izbjeglice. Podaci korišteni za procjenu međunarodnog broja migranata u određeno vrijeme dobivaju se uglavnom iz popisa stanovništva. Prikupljeni podaci čine zbroj migrantskih kretanja oba spola.
				Politička stabilnost i odsutnost nasilja/terorizma mjere percepciju političke nestabilnosti i/ili politički motivirano nasilje. Procjena

konteksta legitimnih ratnih aktivnosti. Odnosno, akt mora biti izvan parametra dopuštenih međunarodnim humanitarnim pravom, ako cilja na neborce. Svaki od ova posljednja tri filtera kriterija mogu se primijeniti na bazu podataka na web-mjestu GTD-a.

Procjena političke (ne)stabilnosti	**PII**	Nezavisna varijabla	Politička nestabilnost države predstavlja situaciju u kojoj je sustav (koji ujedno predstavlja stabilnost države) izložen i ugrožen unutarnjim ili vanjskim poremećenim izazovima političkog, ekonomskog, financijskog ili društvenog spektra, s ciljem pokretanja promjena.	daje ocjenu zemlje na agregatnom pokazatelju u jedinicama standardne normalne raspodjele, tj. u rasponu od približno -2,5 do 2,5. Podaci se odnose na period od 1996. do 2019., no dostupnost istih je zabilježena 1996., 1998., 2000. te nakon 2002. godine frekvencija podataka je godišnja sve do 2019. godine. Podaci su preuzeti sa statističke baze Worldwide Governance Indicator. Za upotrebu navedenih podataka kreirane su ocjene političke stabilnosti i/ili nestabilnost u rasponu 1 do 4. Za sve vrijednosti od 1 pa sve što je < od 2 definirano je kao vrlo stabilna zemlja i dodijeljena ocjena 4, za sve vrijednosti od 0 pa do 1 definiraju stabilne zemlje i dodijeljena ocjena je 3, vrijednosti od 0 od – 1 definiraju nestabilne zemlje i ocjena 2 i vrijednosti od – 1 pa sve do < -3 definiraju vrlo nestabilne zemlje i dodijeljena ocjena je 1.
Rat	**lnWar**	Nezavisna varijabla	Oružani sukobi zasnovani na državi – oružani sukob zasnovan na državi, a odnosi se na vladu i/ili teritorij gdje upotreba oružane sile između dviju strana, od kojih je barem jedna država, rezultira s najmanje 25 smrtnih slučajeva povezanih s oružanim bitkama unutar jedne kalendarske godine. Oružani nedržavni sukobi – primjena oružane sile između dvije organizirane oružane skupine, a nijedna nije vlada države, te rezultira s najmanje 24 smrtnih slučajeva povezanih s bitkama unutar jedne kalendarske godine. Jednostrani oružani sukobi – primjena oružane sile od strane vlade države ili formalno organizirane skupine protiv	Podatak uključuje procjenu smrtnih slučajeva unutar sve tri kategorije nasilja (nedržavnom, državnom i jednostranom) koju je zabilježila statistička baza Uppsala Conflict Data Program (UCDP) u zemlji na temelju UCDP GED skupa podataka. Podaci se odnose na period od 1995. do 2019, a frekvencija podataka je godišnja. U podacima oznaka 1 predstavlja oružanu silu koja je bila evidentirana, no broj smrtno stradalih nije premašio 25, 2 predstavlja oružanu silu s najmanje 25 smrtno stradalih te klasifikaciju rata, 3 nije bilo evidentiranog ratnog stanja.

			civila, što rezultira s najmanje 25 smrtnih slučajeva unutar jedne kalendarske godine.	
Prosjek cijena nafte ($)	**lnAPO**	Nezavisna varijabla	Cijena nafte obično se odnosi na cijenu po barelu referentne sirove nafte (referentna cijena za kupce i prodavače sirove nafte).	Volatilnost cijena nafte odnosi se na prosjek rasta cijena ili pada tijekom nekog vremena. Podaci su preuzeti sa statističke baze British Petroleum te je frekvencija podataka godišnja. Podaci se odnose na prosjek cijene nafte po barelu izražen u dolarima ($). Podaci su dobiveni na način da se prosječna cijena nafte na globalnoj razini dijeli s indeksom potrošačkih cijena (CPI) te pomnoži s 100. Podaci o CPI-ju preuzeti su sa stranica WorldBank, dok su podaci vezani uz globalni prosjek cijene nafte preuzeti s bp (The British Petroleum).
Volatilnost tečaja (domaća valuta naspram $, prosjek)	**lnVER**	Nezavisna varijabla	Tečaj – vrijednost jedne valute u svrhu konverzije u drugu valutu.	Službeni tečaj odnosi se na devizni tečaj koji određuju nacionalne vlasti ili na tečaj utvrđen na zakonski sankcioniranom deviznom tržištu. Izračunava se kao godišnji prosjek na temelju mjesečnih prosjeka (jedinice lokalne valute u odnosu na američki dolar). Podaci su preuzeti sa statističke baze World Bank database. Odnose se na period od 1995. do 2019., te je frekvencija podataka godišnja.

Izvor: World Travel & Torurism Council, Satellite Account methodology, WorldBank database, World Tourism Organisation (UNWTO), International disaster database (EM-DAT), Global Terrorism database, Global Health Data Exchange (GBD), United Nations – Total international migrant stock, Worldwide Governance Indicator, Uppsala Conflict Data Program, British Petroleum, WorldBank data base_Official Exchange rate, World Bank, Number of population

Nadalje, tablica 8 prikazuje deskriptivnu statistiku svih postavljenih varijabli koje su obuhvaćene modelom. Navedena analiza prikazuje primjenu statističkih pokazatelja na odabrani skup podataka s ciljem da se utvrde i prikažu kretanja vrijednosti promatranih varijabli u modelu. Unutar deskriptivne statistike najčešće se za svaku varijablu analizira maksimalna, minimalna i srednja vrijednost skupa podataka, standardna devijacija te broj promatranja.

Tablica 8 Deskriptivna statistika

Varijable	Promatranja	Mean	Std. Dev.	Min	Max
lnTTons	3.623	7.46	2.40	1.06	13.30
lnTAnd	1,814	.44	3.89	-4.60	9.54
lnHQnd	4,125	8.89	8.89	3.82	15.24
lnNDnd	2,961	2.93	3.42	-4.60	12.34
lnAPO	3,809	4.25	.50	.53	7.69
lnVER	3,807	3.02	2.70	-6.76	10.64
lnWar	4,200	.92	.32	0	1.09
PII	3,509	-.03	.94	-3.18	1.76
lnMig	1,005	12.40	1.94	7.70	17.74
lnGDPp	4,111	24.94	2.16	18.89	30.74
GDPgrowth	4,102	3.75	5.09	-62.07	123.13
POP	4,200	3.83	1.40	42077	1.41

Izvor: izračun autorice

5.1. Hipoteza 1: *Postoji statistički signifikantna razlika u stupnju osjetljivosti turizma na odabrane eksterne šokove*

Na temelju prikupljenih podataka odredit će se i procijeniti koje varijable utječu na volatilnost turizma. Efekt utjecaja eksternih šokova na osjetljivost turizma procijenit će se primjenom panel analize podataka. U svrhu testiranja postavljenje hipoteze primijenit će se: (1) združeni model, (2) model s fiksnim efektima te (3) model sa slučajnim efektima u promatranom razdoblju od 24 godine. Model se primjenjuje unutar kreirane dvije skupine podjele uzorka podataka temeljene na izravnom doprinosu turizma u strukturi BDP-a kako bi se utvrdilo koliko razina ovisnosti o turizmu utječe na njegovu volatilnost na eksterne šokove. Analiza podataka kao i samo modeliranje u potpunosti će se napraviti u programu STATA 16.

Nastavno na navedeno slijede jednadžbe spomenutih modela:

(1) **Združeni model** (eng. Pooled OLS model) koji je zapravo isti kao što je i klasični linearni model koji uzima u obzir heterogenosti između promatranih jedinica što znači da sve promatrane jedinice reagiraju isto. Pri ovom modelu polazi se od pretpostavke da su svi parametri nepromjenjivi, te se vrijeme (T) i promatrane jedinice (N) spajaju U NT Cross-podatke (Mitrović, 2002).

$$y_{it} = \alpha + \beta_1 x_{1,it} + \beta_2 x_{2,it} + \cdots \beta_K x_{K,it} + \epsilon_{it}, i = 1, \dots, t = 1, \dots . T \quad (1)$$

gdje je

- T broj vremenskih promatranja, 1,….25 (1=1995.; 2=1996.; 3=1997….25=2019.)
- *i* broj jedinica promatranja, 1,….168 (1=Albanija; 2=Algeria; 3=Angola….168=Zimbabwe)
- y_{it} zavisna varijabla za svaku jedinicu promatranja u trenutku,
- $x_{K,it}$ nezavisna varijabla za svaku jedinicu promatranja u trenutku,
- α slobodni član,
- ϵ_{it} slučajna greška s očekivanjem 0 i varijance σ^2

ili promatrano matrično

$$\boldsymbol{y} = \boldsymbol{x\beta} + \boldsymbol{\epsilon} \quad (2)$$

gdje je

- $\mathbf{y} = (y1, \dots y_N)^t$ Nt x 1 vektor zavisne varijable,
- $\boldsymbol{\epsilon} = (\epsilon_1, \dots \epsilon_N)^t$ Nt x 1 vektor slučajne greške,
- $\boldsymbol{\beta} = (\alpha, \beta_1, \dots \beta_k)^t$ (K + 1) x 1 vektor parametra modela (nezavisnih i kontrolnih varijabli),

Nakon što se u model uvrste korištene varijable u istraživanju, jednadžba modela glasi:

(3)

$$lnTTons_{it} = \alpha + \beta_1 lnTAnd_{it} + \beta_2 lnNDnd_{it} + \beta_3 lnHQnd_{it} + \beta_4 lnMig_{it} + \beta_5 lnVER_{it} + \beta_6 lnAPO_{it} + \beta_7 lnWar_{it} + \beta_8 PII_{it} + \epsilon_{it}, i = 1, \dots, N, t = 1, \dots . T,$$

gdje

- $lnTTons_{it}$ predstavlja zavisnu varijablu,
- $lnTAnd_{it}$; $lnNDnd_{it}$; $lnHQnd_{it}$; $lnMig_{it}$; $lnVER_{it}$; $lnAPO_{it}$; $lnWar_{it}$; PII_{it} predstavljaju nezavisne varijable,
- T *broj vremenskih promatranja*,

- N broj jedinica promatranja,
- α slobodni član,
- ϵ_{it} slučajna greška

Model 2 pri kojem su dodane kontrolne varijable glasi:

$$lnTTons_{it}=\alpha + \beta_1 lnTAnd_{it} + \beta_2 lnNDnd_{it} + \beta_3 lnHQnd_{it} + \beta_4 lnMig_{it} + \beta_5 lnVER_{it} + \beta_6 lnAPO_{it} + \beta_7 lnWar_{it} + \beta_8 PII_{it+} + \beta_9 lnGDPp + \beta_9 POP + \beta_{10} GDPgrowth + \in_{it}, i = 1, \dots, N, t = 1, \dots . T, \quad \textbf{(4)}$$

(1) **Model fiksnih efekata** (eng. Fixed effect model) predstavlja model pri kojem su pojedinačni efekti izravno uključeni u model u obliku fiksnih parametara koristeći pritom varijabilne slobodne članove. Model pretpostavlja nekoreliranost grešaka i nezavisnih varijabli dok s druge strane dopušta korelaciju individualnih efekata i nezavisnih varijabli zbog čega bi procjenitelj kod združenog modela bio pristran i nekonzistentan. Jednadžba modela fiksnih efekata glasi (Torres-Reyna, 2007):

$$y_{it} = \alpha_i + \beta_1 x_{1,it} + \beta_2 x_{2,it} + \cdots \beta_K x_{K,it} + \epsilon_{it}, i = 1, \dots, N, t = 1, \dots . T \quad \textbf{(5)}$$

gdje je

- ϵ_{it} normalno distribuirana slučajna greška s očekivanjem $\mathbb{E}(\epsilon_{it})$=0 i varijancom $\text{Var}(\epsilon_{it}) = \sigma_\epsilon^2$
- α_i slučajna varijabla koja opisuje utjecaj *i*-te jedinice opažanja

$$lnTTons_{it}=\alpha_i + \beta_1 lnTAnd_{it} + \beta_2 lnNDnd_{it} + \beta_3 lnHQnd_{it} + \beta_4 lnMig_{it} + \beta_5 lnVER_{it} + \beta_6 lnAPO_{it} + \beta_7 lnWar_{it} + \beta_8 PII_{it} + \in_{it}, i = 1, \dots, N, t = 1, \dots . T, \quad \textbf{(6)}$$

Model 2 pri kojem su dodatne kontrolne varijable glasi:

$$lnTTons_{it}=\alpha_i + \beta_1 lnTAnd_{it} + \beta_2 lnNDnd_{it} + \beta_3 lnHQnd_{it} + \beta_4 lnMig_{it} + \beta_5 lnVER_{it} + \beta_6 lnAPO_{it} + \beta_7 lnWar_{it} + \beta_8 PII_{it} + \beta_9 lnGPDp + \beta_{10} POP + \beta_{11} GDPgrowth + \in_{it}, i = 1, \dots, N, t = 1, \dots . T, \quad \textbf{(7)}$$

(2) **Model slučajnih efekata** (eng. Random effects model) je model kod kojeg se, za razliku od modela s fiksnim učincima, pretpostavlja da je varijacija među entitetima slučajna i nekorelirana s prediktorom ili nezavisnim varijablama koje su uključene u model. Temeljna razlika između fiksnih i slučajnih efekata je u tome je li neopaženi pojedinačni učinak utjelovljuje elemente koji su u korelaciji s regresorima u modelu, a ne jesu li ti

učinci stohastički ili ne (Green, 2008, str.183). Model pretpostavlja nekoreliralnost komponenata greške te njihovu nekoreliranost s nezavisnim varijablama. Jednadžba modela slučajnih efekata glasi (Torres-Reyna, 2007):

$$y_{it} = \alpha + \beta_1 x_{1,it} + \beta_2 x_{2,it} + \cdots \beta_K x_{K,it} + v_{it,} v_{it} = \alpha_i + \epsilon_{it}, i = 1, \dots, N, t = 1, \dots . T \quad \textbf{(8)}$$

gdje je

- α_i i ϵ_{it} s očekivanjem $\mathbb{E}(\alpha_i) = \mathbb{E}(\epsilon_{it}) = 0$ *i varijancijama* $Var(\alpha_i) = \sigma_\epsilon^2$ te su normalno distribuirani

$$lnTTons_{it} = \alpha + \beta_1 lnTAnd_{it} + \beta_2 lnNDnd_{it} + \beta_3 lnHQnd_{it} + \beta_4 lnMig_{it} + \beta_5 lnVER_{it} + \beta_6 lnAPO_{it} + \beta_7 lnWar_{it} + \beta_8 PII_{it} + v_{it}, i = 1, \dots, N, t = 1, \dots . T \quad \textbf{(9)}$$

Model 2 pri kojem su dodane kontrolne varijable glasi:

$$lnTTons_{it} = \alpha + \beta_1 lnTAnd_{it} + \beta_2 lnNDnd_{it} + \beta_3 lnHQnd_{it} + \beta_4 lnMig_{it} + \beta_5 lnVER_{it} + \beta_6 lnAPO_{it} + \beta_7 lnWar_{it} + \beta_8 PII_{it} + \beta_9 lnGDPp + \beta_{10} POP + \beta_{11} GDPgrowth + v_{it}, i = 1, \dots, N, t = 1, \dots . T \quad \textbf{(10)}$$

S obzirom na to da greške sadrže nepromjenjivu komponentu u vremenu α_i, one postaju korelirane, stoga procjene uz pomoć OLS-a ne pokazuju efikasnost. Moguće rješenje navedenog predstavlja generalizirana metoda najmanjih kvadrata (eng. Generalized least sqares – GLS) koja eliminira korelaciju između grešaka istih jedinica promatranja te primjenjuje GLS procjenitelj ili procjenitelj slučajnih efekata na novi model koji je dan jednadžbom (Hsiao, 2014):

$$\beta_{RE} = (\sum_{i=1}^{N} \sum_{t=1}^{T} (x_{it-} \bar{x}_i)(x_{it} - \bar{x}_i)^{\mathrm{T}} + \lambda \sum_{i=1}^{N} T\,(\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^{\mathrm{T}})^{-1} \mathrm{x} (\sum_{i=1}^{N} \sum_{t=1}^{T} (x_{it} - \bar{x}_i)(y_{it} - \bar{y}_i) + \lambda \sum_{i=1}^{N} T\,(\bar{x}_i - \bar{x})(\bar{y}_i - \bar{y})) \quad \textbf{(11)}$$

gdje je

- β_{RE} procjenitelj slučajnih efekata,
- za λ = 0 dobiveni procjenitelj jednak procjenitelju fiksnih efekata, dok je za $\lambda = 1$ jednak procjenitelju združenog modela.

Kako je pri izboru najprikladnijeg modela prisutno više mogućnosti, nužno je i neophodno provesti testove putem kojih će se odlučiti koji je model najadekvatniji. U svrhu odabira najadekvatnijeg modela provest će se tri testa:

(1) F-test koji čini usporedbu modela fiksnih efekata te združenog modela gdje nulta hipoteza glasi kako su svi osim jednog individualnog koeficijenta jednaki nuli.

Prvi korak empirijskog dijela je provesti testove s ciljem odabira modela. F-test služio je kako bi se odabrao odgovarajući model između združenog modela i fiksnog modela.

Rezultati provedenog testa za oba testirana modela impliciraju na odabir fiksnog modela, odnosno nulta hipoteza se odbacuje (prilog 4 tablica 14).

(2) Breusch-Pagan (LM) test (Breusch i Pagan, 1980) pomaže u odabiru između združenog modela i modela slučajnih efekata. Nulta hipoteza u LM testu je da su varijance između entiteta nula.

Nulta hipoteza provedenog LM testa odbacuje se ako je dobiveni rezultat $p<0.05$. Dobiveni rezultati prikazani u prilogu 4 (tablica 15) impliciraju odabir modela slučajnih efekata za bazni model i za model s uključenim kontrolnim varijablama. Rezultati provedenog LM testa impliciraju korištenje modela slučajnih efekata, čime se nultu hipotezu temeljem $p>0.05$ odbacuje za sve modele.

(3) Hausmanov test – koji će odlučiti je li prikladniji model s fiksnim efektima ili model sa slučajnim efektima. Hausman je 1978. godine kreirao test koji služi upravo procjeni i odabiru adekvatnijeg modela. Test je baziran na razlici između procijenjenih vrijednosti modela fiksnog efekta i modela slučajnog efekta (Baltagi, 2008). Nulta hipoteza navedenog testa podrazumijeva kako se procijenjene vrijednosti modela slučajnih efekata i modela fiksnih efekata zapravo ne razlikuju u velikoj mjeri. Ako se nulta hipoteza odbaci, tada je zaključak da je model fiksnih efekata onaj koji je prikladniji te se model slučajnih efekata odbacuje. Također, odbacivanje nulte hipoteze podrazumijeva kako je pretpostavka modela slučajnih efekata o nepostojanju korelacije između zavisnih varijabli i komponente slučajne greške pogrešna te je prihvatljivije koristiti model fiksnih efekata (Wooldridge, 2015).

Rezultat provedenog Hausmanovog testa prikazan u Prilogu 4 (tablica 16) ukazuje kako se nulta hipoteza baznog modela kao i modela s uključenim kontrolnim varijablama odbija. Procjena koeficijenata varijabli unutar oba modela provedena je primjenom modela fiksnih efekata s vjerojatnošću $p>chi^2= 0.0000$.

Nakon provedbe Hausmanovog testa provode se testovi dijagnostike.

- AUTOKORELACIJA (Wooldrige test, 2002.) – prisutnost autokorelacije kao i kod heteroskedastičnosti posljedično izaziva neefikasnost procijenjenih vrijednosti metodom najmanjih kvadrata. Autokorelacija je česta pojava u podacima vremenskih serija, u slučajevima kada opservacija u nekom periodu ovisi o promatranoj opservaciji u prethodnim periodima. Pojavljuje se u vremenskim serijama gdje su slučajne greške između perioda u korelaciji pa se takva situacija naziva serijska korelacija ili autokorelacija (Ajmani, 2009). S obzirom na to da serijska korelacija u linearnim modelima panel podataka otklanja standardne greške i uzrokuje manje učinkovite rezultate, nužno je identificirati serijsku korelaciju u pojmu idiosinkratične greške u modelu panel podataka. Unutar STATA programa predloženi su brojni testovi za serijsku korelaciju, a za ovo je istraživanje odabran Wooldridge (2002) test koji zahtijeva vrlo malo pretpostavki i jednostavan je za provedbu. Spomenuti test koristi se za provjeru nulte hipoteze kako bi se utvrdilo nepostojanje serijske korelacije.

Prilog 5 (tablica 17) prikazuje rezultate testa koji testira serijsku korelaciju. Vidljivo je kako rezultat daje jake dokaze o postojanju serijske korelacije u pogreškama. Nulta hipoteza navedenog testa koja kaže kako nema serijske autokorelacije snažno se odbacuje kod oba testirana modela.

- MULTIKOLINEARLNOST (VIF test i test tolerancije) – pretpostavka korištenja metode najmanjih kvadrata za procjenu koeficijenata je da nezavisne varijable nisu ujedno i međusobno povezane odnosno da su ortogonalne jedna u odnosu na drugu. Ako je u modelu takav slučaj, izostavljanje jedne varijable iz modela neće utjecati na poremećaj procijenjenih koeficijenata preostalih varijabli. Multikolinearnost se javlja kada postoji značajno velika korelacija između dviju varijabli, a navedeno se smatra problemom vezanim uz podatke (problem nije vezan uz model ili procjenu koeficijenata) (Brooks, 2008).

Rezultati VIF testa i testa tolerancije prikazani u prilogu 5 (tablica 18) pokazuju kako u panel podacima baznog modela ne postoji problem multikolinearnosti iz razloga što vrijednost VIF-a ne prelazi vrijednost 10 kod promatranja svake varijable zasebno kao i kod promatranja svih varijabli modela zajedno. Općeprihvaćeno pravilo je da ako je VIF>10, tada je multikolinearnost visoka (Hair et al., 2014). Rezultat prosječnog VIF testa baznog modela iznosi 1.61, dok kod modela s uključenim kontrolnim varijablama iznosi 1.77 što ukazuje da nema korelacije između zavisne varijable i bilo koje druge varijable u modelu.

- TESTIRANJE MODELA NA UNAKRSNU KORELACIJU (Pesaran test; Portmaneteau test) – ovisnost o presjeku može nastati zbog prostornih ili prelijevajućih učinaka ili može biti posljedica neprimijećenih uobičajenih čimbenika. Unakrsna kointegracija bez potrebe za poznavanjem koeficijenata i rangova kointegracije je dopuštena (Baltagi i Pesaran, 2007). Ovisnost o presjeku može se mjeriti kao korelacija između jedinica, npr. može se izračunati korelacija pogrešaka jedinice *i* i *j*, stoga ako je korelacija velika, prisutna je ovisnost o presjeku. Pesaran razvija test za slabu ovisnost o presjeku na temelju ovog načela. Slaba ovisnost o presjeku znači da se korelacija konvergira u konstantu. Nulta hipoteza testa je da izraz pogreške (ili varijabla) slabo ovisi o presjeku. To znači da je korelacija između promatranja jedinice i u vremenu *t* i jedinice *j* u vremenu *t* nula. Pesaran izvodi testnu statistiku koja zbraja koeficijente korelacije različitih jedinica (Pesaran, 2015). Greške u modelu panelnih podataka slabo su ovisne o presjeku, koristeći eksponent ovisnosti o presjeku (Baileyju, Kapetaniosu i Pesaranu, 2012).

S obzirom na rezultate Pesaranovog testa prikazane u Prilogu 5 (tablica 19) gdje je $p < 0.05$, odbacuje se nulta hipoteza o nekoreliranosti reziduala između prostornog presjeka unutar oba testirana modela.

- HETEROSKEDASTIČNOST (modificirani Wald test) – s obzirom na to da je mogući scenarij u kojem se slučajna greška modela promatra kao homoskedastična iako je zapravo heteroskedastična te su procijenjeni koeficijenti dobiveni provedenom regresijom i dalje konzistentni no istodobno neefikasni, dok će pristranost kao i neobjektivnost biti vidljiva i kod standardne greške procijenjenih vrijednosti (Baltagi, 2005) nužno je detektirati postoji li heteroskedastičnost u panel podacima modela. Navedeno će se testirati uz pomoć modificiranog Wald testa za heteroskedastičnost.

Prilog 5 (tablica 20) pokazuje da je vrijednost hi-kvadrata statistike manja od 0.05. Stoga se nulta hipoteza o stalnoj varijanci može odbaciti na razini značajnosti od 5% za oba testirana modela.

Sljedeći korak je primjena metode generaliziranih najmanjih kvadrata (FGLS – eng. Feasible generalized least square) koja dozvoljava prisutnost autokorelacije unutar panel podataka, heteroskedastičnost te isto tako i korelaciju prostornog presjeka (Nguyen i Nguyen, 2021).

Jednadžba iz koje je kreiran model glasi (STATA manuals):

$$y_{it} = x_{it}\beta + \epsilon_{it} \quad \textbf{(12)}$$

gdje je

y_{it} = zavisna varijabla za svaku jedinicu promatranja u trenutku,

x_{it} = nezavisna varijabla za svaku jedinicu promatranja

i=1,….,*m* je broj panela odnosno promatranih jedinica, a

t=1,….,T_i je broj promatranja za panel *i*.

S obzirom na to da se u ovom istraživanju radi o nebalansiranom panelu, broj opažanja se smanjuje. Kod kreiranja modela kojim se testira prva postavljena hipoteza obuhvaćen je cjelokupni uzorak (168 država), no prilikom procjene panela dolazi do smanjenja uzorka s obzirom na to da za pojedine varijable koje su korištene u radu nema opservacija (npr. podaci za nezavisnu varijablu teroristički napad dostupni su samo za države u kojima se dogodio kao i godine kada se dogodio), stoga procjena panela ne uzima u obzir ostale podatke za navedenu zemlju. Nastavno na navedeno, procjena panela prikazana u tablici 9 unutar modela 1 temelji se na ukupno 877 promatranja što čini prosječno 55 zemalja, dok u modelu 2 broj promatranja biva nešto niži te se temelji na ukupno 837 promatranja.

Tablica 9 Rezultati provedene FGLS analize na cjelokupnom uzorku

	MODEL 1 Rezultati FGLS analize baznog modela	**MODEL 2** Rezultati FGLS analize modela s uključenim kontrolnim varijablama
Zavisna varijabla	Ukupno ostvarena noćenja (lnTTons)	Ukupno ostvarena noćenja (lnTTons)
Broj promatranja	877	837
Broj grupa	121	118
Wald chi2	787.27	3148.55
Prob>chi2	0.000***	0.000***
Nezavisna varijabla	Teroristički napad (lnTAnd)	Teroristički napad (lnTAnd)
Coef.	.14	-.02
Str.Err.	.021	.01
p	0.000***	0.043**
Prob>chi2	Zdravstvena pitanja (lnHQnd)	Zdravstvena pitanja (lnHQnd)
Coef.	.07	-.21
Str.Err.	.04	.03
p	0.084*	0.000***
Nezavisna varijabla	Prirodna katastrofa (lnNDnd)	Prirodna katastrofa (lnNDnd)
Coef.	.07	-.04
Str.Err.	.025	.01
p	0.004***	0.009***
Nezavisna varijabla	Prosječna cijena nafte (lnAPO)	Prosječna cijena nafte (lnAPO)

Coef.	-.19	-.12
Str.Err.	.11	.07
p	0.084*	0.113
Nezavisna varijabla	Volatilnost tečaja (lnVER)	Volatilnost tečaja (lnVER)
Coef.	-.37	-.11
Str.Err.	.02	.01
p	0.000***	0.000***
Nezavisna varijabla	Politička nestabilnost (PII)	Politička nestabilnost (PII)
Coef.	1.53	.55
Str.Err.	.09	.06
p	0.000***	0.000***
Nezavisna varijabla	Rat (lnWar)	Rat (lnWar)
Coef.	.25	.21
Str.Err.	.17	.10
p	0.145	0.008***
Nezavisna varijabla		Ukupna populacija (POP)
Coef.		-1.11
Str.Err.		1.91
p		0.000***
Nezavisna varijabla		BDP po stanovniku (lnGDPp)
Coef.		1.01
Str.Err.		.02
p		0.000***
Nezavisna varijabla		BDP rast (GDPgrowth)
Coef.		-.01
Str.Err.		.01
p		0.154

*Note: *** p<0.01, ** p<0.05, * p<0.1*

Izvor: izračun autorice

Interpretacija procijenjenog panela prikazana u tablici 9 pokazuju sljedeće zaključke:

(a) Nezavisna varijabla teroristički napad (lnTA) unutar oba procijenjena modela pokazuje statistički signifikantnu vezu. Procjena modela s uključenim kontrolnim varijablama izražava statistički negativnu i signifikantnu vezu utjecaja terorizma na turističku potražnju. Procijenjeni rezultati u skladu su s rezultatima istraživanja provedenim od strane Mushtaq i Zaman, (2014) te Buigut i Amendah (2016).

(b) Nezavisna varijabla vezana uz zdravstvena pitanja (lnHQ) u sklopu baznog modela pokazuje pozitivnu, no slabu signifikantnu vezu, dok se ubacivanjem kontrolnih

varijabli u model mijenja predznak i utvrđuje se snažna negativna i signifikantna veza. Negativnu i signifikantnu vezu utjecaja zdravstvenih pitanja na turističku potražnju potvrđuje i istraživanje Monterrubio (2010).

(c) Nezavisna varijabla prirodne katastrofe (lnND) u procjeni baznog modela bilježi pozitivnu i signifikantnu vezu, dok se u procjeni modela s uključenim kontrolnim varijablama ističe negativan i signifikantan utjecaj prirodnih katastrofa na turističku potražnju. Rezultati istraživanja u skladu su s dobivenim rezultatima Rosselló, Becken i Santana-Gallego (2020) koji u svom istraživanju također ispituju utjecaj prirodnih katastrofa na turizam te njihovi rezultati pokazuju kako na većini procijenjenih modela prirodne katastrofe bilježe negativan utjecaj na turističke dolaske.

(d) Nezavisna varijabla prosječna cijena nafte (lnAPO) u procjeni baznog modela bilježi negativnu i slabu signifikantnu vezu, dok se unutar modela s uključenim kontrolnim varijablama može zaključiti kako nema statistički značajne i signifikantne veze.

(e) Nezavisna varijabla volatilnost tečaja (lnVER) u procjeni oba modela bilježi snažnu negativnu signifikantnu vezu utjecaja tečaja na turističku potražnju. Dobivene rezultate potvrđuju i brojna prethodna istraživanja koja su također tečaj kategorizirali kao signifikantnu odrednicu svjetske turističke potražnje (Martins, Gan i Ferreira-Lopes, 2017).

(f) Nezavisna varijabla politička (ne)stabilnost (PII) pokazuje snažnu, pozitivnu signifikantnu vezu unutar oba modela. Dobiveni rezultati u skladu su s istraživanjem Bayar i Yener (2019) i Theocharous et al. (2018) koji ističu pozitivnu vezu utjecaja politički stabilnih zemalja i turističke potražnje.

(g) Nezavisna varijabla rat (lnWar) u procjeni panela pokazuje značajnu i signifikantnu pozitivnu vezu unutar modela koji uključuje kontrolne varijable. Neuobičajen rezultat pozitivnog smjera kosi se s dosadašnjim istraživanjima koja potvrđuju upravo suprotno, ističu negativan efekt rata na turističke dolaske i preusmjeravanje turista na druge, sigurne turističke destinacije (Pandey i Kumar, 2022; Harb, 2016; Currie, Skare i Loncar, 2004).

Nastavno na dobivene rezultate može se zaključiti kako se temeljem provedenih analiza i procjena modela te dobivenih rezultata FGLS analize postavljena istraživačka hipoteza H1 *Postoji statistički signifikantna razlika u stupnju osjetljivosti turizma na odabrane eksterne šokove* prihvaća s obzirom na činjenicu kako od ukupno 7 nezavisnih varijabli od interesa u modelu koji uključuje kontrolne varijable, njih 6 pokazuju statistički signifikantnu vezu.

Dobiveni rezultati pokazuju kako turizam kao aktivnost različito reagira na različite eksterne šokove s pozitivnim ili negativnim predznakom.

Dodatno, u svrhu procjene utjecaja eksternih šokova na države koje više ili manje ovise o turizmu, odnosno ovisno o visini priljeva od strane turizma u strukturi BDP-a provodi se procjena panela na način da se cjelokupni uzorak podataka (168 zemalja) podijeli na dva temeljna skupa podataka. Skupovi su podijeljeni na temelju varijable devizni prihod ostvaren od turizma u strukturi BDP-a. Skup uzorka podjele podataka definiran je na način da je egzogeno (arbitrarno) pretpostavljen prag. Pri egzogenom pretpostavljenom pragu koji je kreiran unutar STATA programa valja istaknuti kako se isti kreirao temeljem svake godine unutar modela, što uzrokuje pomak pojedinih država iz jednog skupa (priljev od turizma do 5%) u drugi definirani skup (priljev turizma 5 – 10%), ovisno o visini priljeva po godinama. Ovako arbitrarno definirani pragovi mogu predstavljati ograničenje unutar modela.

Prvotno su se pri kreiranju modela uzorci podataka podijelili na tri skupa (I. skup – podjela uzorka podataka do 5%, II. skup – podjela uzorka podataka 5% – 10% te III. skup – podjela uzorka podataka više od 10%), no zbog premalog broja promatranja u podjeli uzorka podataka III. skupa nije bilo moguće provesti daljnje korake, stoga se svi modeli panel analize temelje na podjeli uzorka podatka na dva skupa (I. i II.) koji su kreirani temeljem varijable postotak udjela deviznog prihoda ostvarenog od turizma unutar BDP-a (TGDP2): što može

(1) I. skup podjele uzorka podataka obuhvaća zemlje unutar kojih je devizni prihod ostvaren od turizma unutar BDP-a do 5% te
(2) II. skup podjele uzorka podataka: obuhvaća zemlje unutar kojih je devizni prihod ostvaren od turizma u BDP strukturi viši od 5%.

Izračunom prosjeka učešća turizma unutar BDP-a rezultati pokazuju kako većina zemalja skupine do 5% pripada skupini razvijenih zemalja, dok većina država koje ovise o turizmu u većem postotku bivaju zemlje u razvoju (prilog 3).

U svrhu odabira najadekvatnijeg modela provodi se F-test, Breusch-Pagan (LM) test (Breusch i Pagan, 1980) te Hausman test.

Analiza se provodi unutar dva skupa podjele uzorka podatka: (I. skup) TGDP2==1 unutar kojeg su države s deviznim prihodom ostvarenim od turizma unutar BDP-a do 5% i (II. skup) TGDP2==2 unutar kojeg su države s deviznim prihodom ostvarenim od turizma unutar BDP-a većim od 5%.

(1) Rezultati svih modela skupova F-testa prikazani u prilog 6 (tablica 21), a iz istih se zaključuje kako se nulta hipoteza odbacuje što implicira odabir modela fiksnih efekata za sve modele redom:

- I. skup podjele uzorka podataka baznog modela,
- II. skup podjele uzorka podataka baznog modela,
- I. skup podjele uzorka podataka modela s uključenim kontrolnim varijablama,
- II. skup podjele uzroka podataka modela s uključenim kontrolnim varijablama,
- I. skup podjele uzroka podataka baznog modela s uključenom varijablom migracije,
- I. skup podjele uzroka podataka modela s uključenim kontrolnim varijablama i varijablom migracije.

Odabir združenog modela pri kojem se nulta hipoteza prihvaća implicira se za modele:

- II. skup podjele uzorka podataka baznog modela s varijablom migracije varijablama te
- II. skup podjele uzorka podataka modela s uključenim kontrolnim varijablama i varijablom migracije.

Provedeni testovi za odabir prikladnog modela pružaju sljedeće rezultate:

(2) Nulta hipoteza provedenog LM testa odbacuje se ako je dobiveni rezultat $p<0.05$. Dobiveni rezultati prikazani u prilogu 6 (tablica 22) impliciraju odabir modela slučajnih efekata za sve testirane modele. Rezultati provedenog LM testa impliciraju korištenje modela slučajnih efekata, čime se nultu hipotezu temeljem $p>0.05$ odbacuje za sve modele.

(3) Rezultat provedenog Hausmanovog testa prikazan u prilogu 6 (tablica 23) ukazuje kako se nulta hipoteza za sve modele I. skupa podjele uzorka podataka te modela II. skupa podjele uzorka podataka baznog modela odbija. Procjena koeficijenata varijabli unutar baznog modela I. i II. skupa provedena je primjenom modela fiksnih efekata s vjerojatnošću $p>chi^2= 0.0000$. Varijable baznog modela s uključenim kontrolnim varijablama I. skupa podjele uzorka podataka također su procijenjene primjenom modela fiksnih efekata s vjerojatnošću $p>chi^2= 0.0276$. Procjena II. skupa podjele uzorka podataka bilježi drugačije rezultate, odnosno procjena se temelji na modelu slučajnih efekata. Procjena oba modela I. skupa podjele uzorka podataka s uključenom varijablom migracije procijenjena je primjenom fiksnih efekata. Nadalje, oba modela s uključenom varijablom migracije, a unutar II. skupa podjele uzroka podataka procjenu koeficijenata varijabli vrše primjenom modela slučajnih efekata, stoga se nulta hipoteza prihvaća.

Nakon provedbe Hausmanovog testa provode se testovi dijagnostike.

- AUTOKORELACIJA (Wooldrige test, 2002. - Portmanteau test) – u sklopu ovog modela provode se dva testa za provjeru prisutnosti autokorelacije (1) Wooldridge (2002) test te (2) Portmanteau test. Na modelu s uključenom varijablom migracija koja je na petogodišnjim podacima proveden Portmanteau test. Korištenje Portmanteau testa od interesa je ako se ne može zauzeti čvrst stav o određenom obliku korelacije koji bi trebao poslužiti kao alternativa. To relativno mogu u mnogim aplikacijama za panel podatke osobito kada opažanja za datu skupnu podataka nemaju prirodni redoslijed kao što je na primjer vrijeme. Test je dizajniran za krake panele i može se baviti općim obrascima nedostajućih podataka. Postupak testira serijsku korelaciju proizvoljnog oblika u pogreškama linearnog modela panela nakon procjene koeficijenata regresije unutar grupnog procjenitelja (Jochmans i Verardi, 2020). Wooldridge test proveden je na baznom modelu i modelu s uključenim kontrolnim varijablama, dok je Portmanteau test zbog specifičnosti panel podataka proveden na baznom modelu skupa I. i II. podjele uzorka podataka te modelu s uključenim kontrolnim varijablama s varijablom migracije.

Prilog 7 (tablica 24) prikazuje rezultate testa koji testira serijsku korelaciju. Vidljivo je kako rezultat daje jake dokaze o postojanju serijske korelacije u pogreškama. Navedeni rezultat identičan je unutar oba skupa modela koji su obuhvaćeni testiranjem. Nulta hipoteza navedenog testa koja kaže kako nema serijske autokorelacije snažno se odbacuje.

- MULTIKOLINEARLNOST (VIF test i test tolerancije) – Rezultati VIF testa i testa tolerancije prikazani u prilogu 7 (tablica 25) pokazuju kako u panel podacima baznog modela ne postoji problem multikolinearnosti iz razloga što vrijednost VIF-a ne prelazi vrijednost 10 kod promatranja svake varijable zasebno kao i kod promatranja svih varijabli modela zajedno. Opće prihvaćeno pravilo je da ako je VIF>10, tada je multikolinearnost visoka (Hair et al., 2014). Rezultat prosječnog VIF testa baznog modela I. skupa iznosi 1.57 što ukazuje da nema korelacije između zavisne varijable i bilo koje druge varijable u modelu.

Nadalje, rezultat VIF testa primijenjenog na modelu I. skupa koji uključuje kontrolne varijable također pokazuje kako nije prisutan problem multikolinearnosti. Prosječni VIF iznosi 1.77 što implicira na neprisutnost korelacije između zavisne varijable i preostalih varijabli uključenih u model. Bazni model II. skupa bilježi također prihvatljive rezultate, vrijednost prosječnog VIF testa iznosi 2.05. Nakon ubacivanja kontrolnih varijabli u model vrijednost VIF testa iznosila

je 2.03 što je još uvijek u okviru prihvatljivoga, odnosno rezultat pokazuje kako ne postoji problem multikolinearnosti. Multikolinearnost nije utvrđena ni unutar modela koji uključuju varijablu migracije, točnije rezultati svih modela na prihvatljivoj su razini te su njihove vrijednosti 1.88 – 7.15.

- TESTIRANJE MODELA NA UNAKRSNU KORELACIJU – S obzirom na rezultate Pesaranovog testa prikazane u prilogu 7 (tablica 26) gdje je $p < 0.05$, odbacuje se nulta hipoteza o nekoreliranosti reziduala između prostornog presjeka unutar oba obuhvaćena skupa.
- HETEROSKEDASTIČNOST (modificirani Wald test) – Prilog 7 (tablica 27) pokazuje da je vrijednost hi-kvadrata statistike manja od 0.05. Stoga se nulta hipoteza o stalnoj varijanci može odbaciti na razini značajnosti od 5% za sve modele I. skupa te sve modele II. skupa (izuzev modela II. skupa s uključenom varijablom migracije) što potvrđuje odnosno podrazumijeva heteroskedastičnost. Procjena maksimalne vrijednosti u modelu slučajnih efekata II. skupa (za model s uključenim kontrolnim varijablama, bazni model s uključenom varijablom migracije te model s uključenom varijablom migracije i kontrolnim varijablama) kao i testiranje multiplikativne heteroskedastičnosti provedeni su uz primjenu koda *xtreghet* prema uzoru na Shehata (2013). Rezultati testa ukazuju na prisutnost heteroskedastičnosti kod svih modela izuzev modela s uključenom varijablom migracije (II. skup podjele uzorka podataka). Sljedeći korak je primjena metode generaliziranih najmanjih kvadrata (FGLS – eng. Feasible generalized least square) koja dozvoljava prisutnost autokorelacije unutar panel podataka, heteroskedastičnost te isto tako i korelaciju prostornog presjeka (Nguyen i Nguyen, 2021).

Kao i u prethodno provedenom modelu, procjena modela temelji se na nebalansiranim panel podacima koji su podijeljeni na dva temeljena skupa uzorka podjele podataka. Procjena panela temelji se na manjem broju opažanja do čijeg smanjenja dolazi zbog nedostataka podataka za pojedine varijable unutar modela. Tablica 10 prikazuje kako se procjena panel podataka unutar baznog modela 1 temelji na 742 opažanja (skup 1) i 135 opažanja (skup 2). Nadalje, procjena modela 2 koji u procjenu uključuje i kontrolne varijable temelji se na 702 opažanja (skup 1) te 135 opažanja (skup 2). Cjelokupna procjena panela koja se temelji na modelu 3 i 4 bazira se na petogodišnjim podacima za sve varijable unutar modela te samim time broj opažanja znatno opada. Razlog procjene panela koja se temelji na petogodišnjim podacima jest dostupnost

podataka za varijablu migracije koji su dostupni svakih pet godina, dakle ukupan *n* kod modela 3 i modela 4 je 5 godina. Procjena panela za model 3 temelji se na 162 opažanja (skup 1) te 28 opažanja (skup 2), dok se kod modela 4 procjena temelji na 155 opažanja (skup 1) te 28 opažanja (skup 2).

Tablica 10 Rezultati provedene FGLS analize

	MODEL 1 Rezultati FGLS analize baznog modela		MODEL 2 Rezultati FGLS analize modela s uključenim kontrolnim varijablama		MODEL 3 Rezultati FGLS analize baznog modela s uključenom varijablom migracije temeljeno na petogodišnjim panel podacima		MODEL 4 Rezultati FGLS analize modela s uključenim kontrolnim varijablama i varijablom migracije temeljeno na petogodišnjim panel podacima	
Zavisna varijabla	Ukupno ostvarena noćenja (lnTTons)		Ukupno ostvarena noćenja (lnTTons)		Ukupno ostvarena noćenja (lnTTons)		Ukupno ostvarena noćenja (lnTTons)	
	I. skup podjele uzorka podataka	II. skup podjele uzorka podataka	I. skup podjele uzorka podataka	II. skup podjele uzorka podataka	I. skup podjele uzorka podataka	II. skup podjele uzorka podataka	I. skup podjele uzorka podataka	II. skup podjele uzorka podataka
Broj promatranja	742	135	702	135	162	28	155	28
Broj grupa	106	26	103	26	70	16	67	16
Wald chi2	770,52	140.51	2709.82	344.40	373.58	167.95	842.46	152.71
Prob>chi2	0.0000***	0.0000***	0.0000***	0.0000***	0.0000***	0.0000***	0.0000***	0.0000***
Nezavisna varijabla	Teroristički napad (lnTAnd)		Teroristički napad (lnTAnd)		Teroristički napad (lnTAnd)		Teroristički napad (lnTAnd)	
Coef.	.16	-.08	.03	-.03	.14	-.12	.04	-.07
Str.Err.	.024	.022	.016	.020	.041	.030	.031	.035
p	**0.000*** **	**0.000*** **	**0.021** **	**0.058***	**0.001*** **	**0.000*** **	0.148	**0.041** **
Nezavisna varijabla	Zdravstvena pitanja (lnHQnd)		Zdravstvena pitanja (lnHQnd)		Zdravstvena pitanja (lnHQnd)		Zdravstvena pitanja (lnHQnd)	
Coef.	.027	.33	-.18	-.21	-.19	.35	-.24	-.13
Str.Err.	.049	.039	.034	.063	.084	.079	.064	.150
p	0.578	**0.000*** **	**0.000*** **	**0.001*** **	**0.024** **	**0.000*** **	**0.000*** **	0.366
Nezavisna varijabla	Prirodna katastrofa (lnNDnd)		Prirodna katastrofa (lnNDnd)		Migracije (lnMig)		Migracije (lnMig)	
Coef.	.08	.04	-.04	-.02	.69	.55	.25	.06
Str.Err.	.028	.021	.018	.020	.081	.068	.068	.144
p	**0.004*** **	**0.053***	**0.015** **	0.333	**0.000*** **	**0.000*** **	**0.000*** **	0.652
Nezavisna varijabla	Prosječna cijena nafte (lnAPO)		Prosječna cijena nafte (lnAPO)		Prirodne katastrofe (lnNDnd)		Prirodne katastrofe (lnNDnd)	
Coef.	-.21	-.31	-.12	-.15	.06	.02	-.01	.12
Str.Err.	.124	.153	.087	.122	.042	.067	.030	.091
p	**0.083***	**0.041** **	0.148	0.213	0.121	0.723	0.599	0.160
Nezavisna varijabla	Volatilnost tečaja (lnVER)		Volatilnost tečaja (lnVER)		Prosječna cijena nafte (lnAPO)		Prosječna cijena nafte (lnAPO)	
Coef.	-.37	-.15	-.11	-.06	-.25	-1.02	-.13	-.66
Str.Err.	.027	.029	.019	.030	.253	.335	.209	.347

p	**0.000**	**0.000**	**0.000**	**0.051**	0.312	**0.002**	0.528	**0.054**
Nezavisna varijabla	Politička nestabilnost (PII)		Politička nestabilnost (PII)		Volatilnost tečaja (lnVER)		Volatilnost tečaja (lnVER)	
Coef.	1.65	.02	.62	.06	-.24	-.22	-.12	-.16
Str.Err.	.098	.120	.072	.099	.049	.059	.037	.048
p	**0.000*** **	0.853	**0.000*** **	0.483	**0.000*** **	**0.000*** **	**0.001*** **	**0.001*** **
Nezavisna varijabla	Rat (lnWar)		Rat (lnWar)		Politička nestabilnost (PII)		Ukupna populacija (POP)	
Coef.	.27	.06	.26	.26	1.23	.17	-7.00	-1.42
Str.Err.	.185	.232	.121	.192	.178	.181	3.87e	7.67e
P	0.135	0.772	**0.027** *	0.166	**0.000*** **	0.327	**0.070** *	**0.065** *
Nezavisna varijabla			Ukupna populacija (POP)		Rat (lnWar)		BDP po stanovništvu (lnGDPp)	
Coef.			-1.15	-1.86	.042	1.28	.83	.90
Str.Err.			2.11e	5.85e	.320	.362	.070	.296
p			**0.000*** **	**0.061***	0.894	**0.000*** **	**0.000*** **	**0.002*** **
Nezavisna varijabla			BDP po stanovništvu (lnGDPp)				BDP rast (GDPgrowth)	
Coef.			1.01	.88			-.01	-.04
Str.Err.			.032	.066			.026	.062
p			**0.000*** **	**0.000*** **			0.486	0.447
Nezavisna varijabla			BDP rast (GDPgrowth)				Politička nestabilnost (PII)	
Coef.			-.01	-.00			.62	.04
Str.Err.			.011	.019			.138	.159
p			0.099	0.710			**0.000*** **	0.786
							Rat (lnWar)	
							.08	-.00
							.230	.406
							0.727	0.999

*Note: *** p<0.01, ** p<0.05, * p<0.1*
Izvor: izračun autorice

Procjena panela prikazana u tablici 10 obuhvaća države I. i II. skupa, ovisno o visini deviznog prihoda ostvarenog od turizma unutar BDP-a.

Rezultati provedene analize pokazuju kako nezavisna varijabla *teroristički napad (lnTAnd)* izražava statistički pozitivnu i signifikantnu vezu unutar svih modela (izuzev modela 4) I. skupa podjele uzorka podataka (učešće do 5%), što je u skladu s rezultatima istraživanja provedenim od strane Mushtaq i Zaman, (2014). S druge strane, statistički negativna i signifikantna veza uočena je unutar svih modela II. skupa podjele uzorka podataka (učešće iznad 5%), a dobiveni rezultati u skladu su s rezultatima istraživanja Enders i Sandler (1991) koji ističu značajan negativan utjecaj terorizma na dolaske turista.

Nezavisna varijabla *zdravstvena pitanja (lnHQ)* unutar većine modela pokazuje statistički negativnu i signifikantnu vezu (izuzev modela 1 unutar I. skupa podjele uzorka podataka te modela 4 unutar II. skupa podjele uzorka podataka). Model 1, II. skupa i model 3, II. skupa podjele uzorka podataka pokazuju statistički pozitivnu i signifikantnu vezu između varijabli zdravstvena pitanja i turizam.

Prirodne katastrofe (lnNDnd) ne pokazuju značajnu signifikantnost unutar većine modela izuzev modela 1 unutar kojeg je evidentirana statistički pozitivna i signifikantna veza, te modela 2 unutar II. skupa podjele uzorka podataka gdje je utvrđena statistički negativna i signifikantna veza.

Prosječna cijena nafte (lnAPO) unutar modela 1 (oba skupa) te modela 3 i 4 u sklopu II. skupa podjele uzorka podataka pokazuje statistički negativnu i signifikantnu vezu što će posljedično dovesti do smanjenja turističke potražnje.

Nezavisna varijabla *volatilnost tečaja (lnVER)* unutar svih modela pokazuje statistički negativnu i signifikantnu vezu. Dobiveni rezultati potvrđuju i brojna prethodna istraživanja koja su također kategorizirala tečaj kao signifikantnu odrednicu svjetske turističke potražnje (Martins, Gan i Ferreira-Lopes, 2017).

Politička nestabilnost (PII) pokazuje statistički pozitivnu signifikantnu vezu unutar svih modela I. skupa podjele uzorka podataka (učešće do 5%).

Rezultati provedene analize pokazali su kako kod nezavisne varijable *rat (lnWar)* nema statistički značajne i signifikantne veze.

Nezavisna varijabla *migracije (lnMig)*, čija je procjena rađena na temelju petogodišnjih podataka, unutar većine modela (izuzev modela 2, II. skupa podjele uzorka podataka) pokazuje

statistički pozitivnu i signifikantnu vezu. Slične rezultate unutar svojih istraživanja dobivaju i Boyne, Carswell i Hall, 2002; WTO, 2009; Seetaram i Dwyer, 2009; Seetaram, 2012a; 2012b, Dragičević, Nikšić Radić, Herman (2019).

S ciljem procjene utjecaja eksternih šokova na turizam samo mediteranskih zemalja proveo se još jedan dodatan model koji je uključivao samo odabrane zemlje Mediterana i to redom: Albanija, Hrvatska, Cipar, Italija, Grčka, Malta, Španjolska, Francuska, Portugal, Slovenija, Turska, Bosna i Hercegovina, Crna Gora i Egipat. Prilog 8 (tablica 28) prikazuje provedene testove na baznom modelu (MODEL 1) i modelu koji uključuje kontrolne varijable (MODEL 2).

Procjena modela temelji se na nebalansiranom panelu na uzorku od 14 odabranih mediteranskih zemalja ($n = 14$) za promatrano razdoblje 1995. – 2019. ($T = 25$). Prilikom procjene panela dolazi do smanjenja uzorka s obzirom na to da za pojedine varijable koje su korištene u radu nema opservacija, stoga procjena panela ne uzima u obzir ostale podatke za navedenu zemlju. Nastavno na navedeno, procjena panela prikazana u tablici 9 unutar modela 1 i modela 2 temelji se na ukupno 82 promatranja.

Regresijska analiza obaju modela upućuje na korištenje fiksnih efekata, dok je LM test za oba modela definirao primjenu modela slučajnih efekata. Rezultat Hausmanova test za oba modela implicira odabir modela fiksnih efekata. Wooldridge test pokazuje snažnu prisutnost autokorelacije unutar oba modela. Rezultat VIF testa pruža dokaz koji potvrđuje kako ne postoji multikorelacija u modelima. Pesaranov test pokazuje kako se odbacuje nulta hipoteza provedenog testa o nekoreliranosti reziduala između prostornog presjeka obaju modela. Rezultati modificiranog Wald testa ukazuju na prisutnost heteroskedastičnosti unutar modela pa se shodno tome nulta hipoteza testa može odbaciti.

Kao i u prethodno provedenom modelu, zbog prisutnosti autokorelacija te heteroskedastičnosti provodi se FGLS analiza (tablica 11). Rezultati provedene FGLS analize pokazuju kako nezavisna varijabla *zdravstvena pitanja (lnHQnd)* bilježi statistički signifikantnu vezu unutar obaju modela. Nadalje, varijabla *prosječna cijena nafte (lnAPO)* pokazuje statistički pozitivnu i signifikantnu vezu unutar modela 2 koji uključuje kontrolne varijable. Varijabla *volatilnost tečaja (lnVER)* pokazuju statistički negativnu i signifikantnu vezu unutar baznog modela 1, dok je unutar modela 2 koji obuhvaća kontrolne varijable uočena statistički pozitivna i signifikantna veza. Rezultati provedene analize pokazuju kako varijabla *politička nestabilnost (PII)* bilježi

statistički pozitivnu i signifikantnu vezu unutar modela 1. Dobiveni rezultati poprilično odstupaju od agregatnih rezultata, a razlog navedenom može biti evidentiran u tome što u promatranom periodu u većini odabranih mediteranskih zemalja nije bilo evidentirano više eksternih šokova (npr. prirodnih katastrofa, pandemija..).

Tablica 11 Rezultati provedene FGLS analize

	MODEL 1 Rezultati FGLS analize baznog modela	MODEL 2 Rezultati FGLS analize s uključenim kontrolnim varijablama
Zavisna varijabla	lnTTons	lnTTons
Broj promatranja	82	82
Broj grupa	11	11
Wald chi2	168.48	1675.72
Prob>chi2	0.0000***	0.0000***
Nezavisna varijabla	lnTAnd	lnTAnd
Coef.	.03	-.02
Str.Err.	.046	.017
p	0.499	0.234
Nezavisna varijabla	lnHQnd	lnHQnd
Coef.	.73	.28
Str.Err.	.101	.084
p	**0.000*** **	**0.001*** **
Nezavisna varijabla	lnNDnd	lnNDnd
Coef.	.06	.02
Str.Err.	.058	.022
p	0.274	0.310
Nezavisna varijabla	lnAPO	lnAPO
Coef.	-.34	.18
Str.Err.	.220	.091
p	0.116	**0.044** **
Nezavisna varijabla	lnVER	lnVER
Coef.	-.16	.14
Str.Err.	.072	.031
p	**0.024** **	**0.000*** **
Nezavisna varijabla	PII	PII
Coef.	1.43	.01
Str.Err.	.213	.118
p	**0.000*** **	0.919
Nezavisna varijabla	lnWar	lnWar
Coef.	.09	-.05
Str.Err.	.388	.147
p	0.806	0.712
Kontrolna varijabla		POP
Coef.		2.06
Str.Err.		5.10e
p		0.000***
Kontrolna varijabla		lnGDPpc
Coef.		1.39
Str.Err.		.067
p		0.000***

*Note: *** p<0.01, ** p<0.05, * p<0.1*

Izvor: izračun autorice

Zaključno se može konstatirati kako je turizam kao aktivnost poprilično otporan na eksterne šokove što je vidljivo iz danih rezultata. Prilog 13 daje uvid u bombaške napade koji su evidentirani u odabranim mediteranskim zemljama. Uočljivo je kako je svaka mediteranska

država pretrpjela barem neki oblik napada. Valja napomenuti kako se grafički prikazi temelje na podacima dostupnim iz Global terrorism database te se odnose na sve vrste bombaških napada, pa čak i kad pojedini napad nije kategoriziran kao teroristički.

5.2. Hipoteza 2: *Kratkoročni i dugoročni efekti šokova na turizam različiti su po tipu eksternih šokova*

Kako bi se izradila procjena utjecaja varijabli od interesa unutar dugog i kratkog perioda, predviđena je primjena autoregresivne distribucije pomaka (ARDL), no s obzirom na to da unutar podataka postoje varijable s nedostatnim podacima, isti nije bilo moguće provesti. Nastavno na istraživanja drugih autora kao zamjena za navedeni model primijenit će se panel vektorske autoregresije. Potpoglavlje koje slijedi prema uzoru na Abrigo i Love (2015) razmatra procjenu i testiranje koeficijenata vektorske autoregresije u panel podacima unutar generalizirane metode momenata – GMM (eng. Generalized Method of Moments), te primjenjuje tehnike za analizu dinamičkih odnosa između eksternih šokova i njihovih efekata na turizam.

Prema Sims (1980) vektorski autoregresivni modeli (VAR) postaju široko korišteni alat u svrhu modeliranja u makroekonomskoj literaturi. Istoimeni autor navodi kako VAR modeli mogu biti postulirani poput ekonometrijskog modela smanjenog oblika ili kreirani kako bi ispitali dugoročna ograničenja koja sugerira ekonomska teorija uz dopuštanje neograničene kratkoročne dinamike. Sve varijable, bilo da se radi o dinamičkom bilo o statičkom VAR modelu, tretiraju kao endogene i međuovisne, no definiranje ograničenja koje se temelji na teoretskim modelima ili na statističkim postupcima može se nametnuti kako bi se razdvojio utjecaj egzogenih šokova turizam (Canova i Ciccarelli, 2013). Panel VAR modeli nude rješenja za izračun procjene ekonomskih pitanja zbog toga što su u mogućnosti procijeniti dinamičku međuovisnost (Canova i Ciccarelli, 2013) te procijeniti utjecaj idiosinkratičnih šokova kroz jedinice i vrijeme, odnosno utjecaj šoka jedne varijable na drugu što se postiže funkcijama impulzivnog odaziva (Grossmann, et al., 2014). O prednostima navedenog testa naspram drugih detaljnije u svom istraživanju iznose Maddala i Wu (1999). Navedeni model će u svrhu procjene parametara panel VAR modela primijeniti Arellano i Bond (1991) GMM procjenitelja u prvim diferencijama.

Model dinamičkog panel podataka prikazan je u jednadžbi koja slijedi (Abrigo i Love, 2015):

$$Y_{it} = Y_{it-1}A_1 + Y_{it-2}A_2 + \cdots + Y_{it-p}A_p + \alpha_i + e_{it}$$

$$i \in \{1,2,\dots,N\}, t \in \{1,2,\dots,T_i\} \quad (13)$$

gdje je,

Y_{it} $(1xk)$ vektor zavisne varijable,
X_{it} $(1xk)$ vektor egzogenih kovarijata,
e_{it} su $(1xk)$ vektori zavisne varijable specifičnih panela fiksnih učinaka i pogrešaka
(kxk) matrica $A_2, A_2, \dots A_{P-1}$ i (Ixk) matrica B su parametri koje treba procijeniti.

Procjena panel VAR modela kreirana je na nebalansiranim panel podacima tako da se ukupan broj država ($N = 168$) koje su uvrštene u model prilikom procjene smanjivao ovisno o dostupnosti podataka za sve varijable u modelu. Varijable uključene u procjenu su redom: (1) ukupno ostvarena noćenja, (2) teroristički napad, (3) prirodne katastrofe, (3) zdravstvena pitanja, (4) rat, (5) politička nestabilnost, (6) prosječna cijena nafte, (7) te volatilnost tečaja. Varijabla migracije zbog dostupnosti podataka koja je na petogodišnjoj razini nije ušla u procjenu panel VAR modela. Točnije, procjenu nije bilo moguće provesti zbog premalog broja promatranja. Prvenstveno se panel VAR modelom promatra koje varijable imaju najveći utjecaj na turističke aktivnosti odnosno na ukupno ostvarena noćenja. Kako bi se proveo panel VAR model, nužno je testirati stacionarnost varijabli na način da se provede test jediničnih korijena (eng. unit root test) na panel podacima.

Postoji nekoliko testova koji su implementirani unutar programa STATA, a odabrani test je Fisherov test koji je temeljen na proširenim Dickey Fullerovim testovima. Razlog odabira upravo navedenog testa je što on omogućuje procjene i na podacima koji su neuravnoteženi odnosno i pri slučaju kada nisu dostupni svi podaci varijabli od interesa (STATA). Fisherov test je ne-parametarski te se može koristiti s bilo kojim testom jediničnog korijena. Također, ne postoji ograničenje veličine uzoraka za različite uzorke (mogu varirati ovisno o dostupnosti podataka). Nulta hipoteza spomenutog testa tvrdi kako svi paneli sadrže jedinični korijen. Rezultati provedenog testa pokazuju kako je *p* vrijednost niža od 0.01 te se nulta hipoteza može odbaciti na razini statističke značajnosti od 1% što potvrđuje kako u panelu nema jediničnih korijena te kako su sve varijable zapravo stacionarne u razinama (prilog 9, tablica 29).
Sljedeći korak je pokretanje panel VAR modela s ciljem definiranja koji broj pomaka je optimalan za panel VAR, a navedeno će se procijeniti testom procjene redoslijeda vremenskog pomaka unazad na uzroku[10]. Sintaksa *pvarsoc* izvještava o ukupnom koeficijentu determinacije modela Hansenovoj (1982) J statistici, i odgovarajućoj *p* vrijednosti te kriterijima odabira modela momenata koji su razvili Andrews i Lu (2001). Kod izračuna *pvarsoc* koristi uzorak

[10] Kod za procjenu navedenog unutar STATA-e je varsoc

procjene najmanje restriktivnog panel VAR modela, tj. s najvećim korištenim redoslijedom vremenskog pomaka unazad, za sve modele koje bi program procijenio. Navedeni postupak pruža rezultate koeficijenta determinacije (CD), Hansenovu J statistiku (J) i njegovu p vrijednost (J p) (Hansen, 1982), te Bayesov informacijski kriterij (MBIC), Akaikeov informacijski kriterij (MAIC) i Quinnov informacijski kriterij (MQIC) koji su uveli Andrews i Lu (2001). Test je proveden za panel VAR od prvog do četvrtog reda koristeći prvih 8 vremenskih pomaka unazad regresora kao instrumente. Optimalna duljina redoslijeda vremenskih pomaka unazad trebala bi biti ona koja minimizira MBIC, MAIC i MQIC informacijske kriterije (Andrews i Lu 2001). Iz podataka koji su prikazani u prilogu 10 (tablici 30) vidljivo je kako su MBIC, MAIC i MQIC kriteriji niži s 1 zaostatkom. Ovaj rezultat dovodi do procjene PVAR-a prvog reda za sve varijable izuzev varijable prosječna cijena nafte (lnAPO) gdje je optimalan broj zaostataka 4 te varijable zdravstvena pitanja (lnHQnd) gdje je procjena kriterija optimalna s 2 zaostatka.

Panel VAR model s GMM procjenom unutar jednog pomaka uz pomoć Helmertove transformacije gdje se koriste prva tri zaostajanja kao instrumenti definiran je s dvije varijable unutar svakog modela, odnosno predviđena analiza obuhvaća 7 različitih panel VAR unutar kojih su endogene varijable postavljene tako da se na prvom mjestu nalazi varijabla ukupno ostvarena noćenja. Sintaksa *pvar* procjenjuje modele autoregresije panela vektora na način da uklopi multivarijantnu panel regresiju svake zavisne varijable na redoslijed vremenskih pomaka unazad njih samih, redoslijed vremenskih pomake unazad svih ostalih zavisnih varijabli i egzogenih varijabli (prilog 11, grafikon 15).

Jednadžbe navedenih 7 panel VAR modela slijede u nastavku:

$$\Delta lnTTons_{i,t} = \alpha_1 lnTTons_{i,t-1} + \alpha_1 \Delta lnTAnd_{i,t-1} + \in_{i,t} \quad (14)$$

$$\Delta lnTTons_{i,t} = \alpha_1 lnTTons_{i,t-1} + \alpha_1 \Delta lnNDnd_{i,t-1} + \in_{i,t} \quad (15)$$

$$\Delta lnTTons_{i,t} = \alpha_1 lnTTons_{i,t-1} + \alpha_1 \Delta lnHQnd_{i,t-1} + \in_{i,t} \quad (16)$$

$$\Delta lnTTons_{i,t} = \alpha_1 lnTTons_{i,t-1} + \alpha_1 \Delta lnAPO_{i,t-1} + \in_{i,t} \quad (17)$$

$$\Delta lnTTons_{i,t} = \alpha_1 lnTTons_{i,t-1} + \alpha_1 \Delta lnVER_{i,t-1} + \in_{i,t} \quad (18)$$

$$\Delta lnTTons_{i,t} = \alpha_1 lnTTons_{i,t-1} + \alpha_1 \Delta lnWar_{i,t-1} + \in_{i,t} \quad (19)$$

$$\Delta lnTTons_{i,t} = \alpha_1 lnTTons_{i,t-1} + \alpha_1 \Delta PII_{i,t-1} + \in_{i,t} \quad (20)$$

Kako bi se provjerila stabilnost panel VAR modela prvog reda, nakon procjene parametara izračunava se uvjet svojstvene vrijednosti. Rezultati prikazani u prilogu 12 (Grafikon 16)

pokazuju kako se sve vlastite vrijednosti nalaze unutar jediničnog kruga, čime se može zaključiti kako je uvjet stabilnosti modela potvrđen, a navedeno također ukazuje kako su varijable modela stacionarne (Lütkepohl 2005). Choleskyjeva dekompozicija A = $R^T R$ pozitivno određene matrice A unutar koje je R gornji trokut s pozitinim dijagonalnim elementima temeljni je alat u matričnim proračunima. Standardni algoritam za njegovo izračunavanje datira iz ranog dijela ovog stoljeća (Householder, 1964) i predstavlja jedan od numerički najstabilnijih od svih matričnih algoritama (Kiełbasiński, 1987). Upravo je Choleskyjeva dekompozicija najčešće korištena metoda za rješavanje linearnih sustava.

Kako bi se odredilo koliki dio varijabilnosti zavisne varijable zaostaje za vlastitom varijancom kao i koja je od nezavisnih varijabli "snažnija" u objašnjavanju varijabilnosti zavisnih varijabli tijekom vremena, primijenit će se dekompozicija varijance (eng. Forecast-error variance decomposition, FEVD). Dekompozicija varijance (FEVD) prikazuje rezultate za 10 razdoblja unaprijed te pokazuju kako za svih 7 modela u 10. godini zavisna varijabla lnTTons objašnjava varijance svoje prognostičke pogreške za 99%. Uz navedeno, rezultati pokazuju kako teroristički napad u istom periodu objašnjava varijance prognostičke pogreške zavisne varijable za 0,99% (prilog 13, tablica 31). Nakon što se provede procjena VAR-a, izrazi strukturne pogreške identificiraju se pomoću Choleskyjeve dekompozicije i generiraju se funkcije impulsnog odaziva.

Procjena funkcije impulsnog odaziva temelji se na nebalansiranim panel podacima za razdoblje 1995. – 2019.

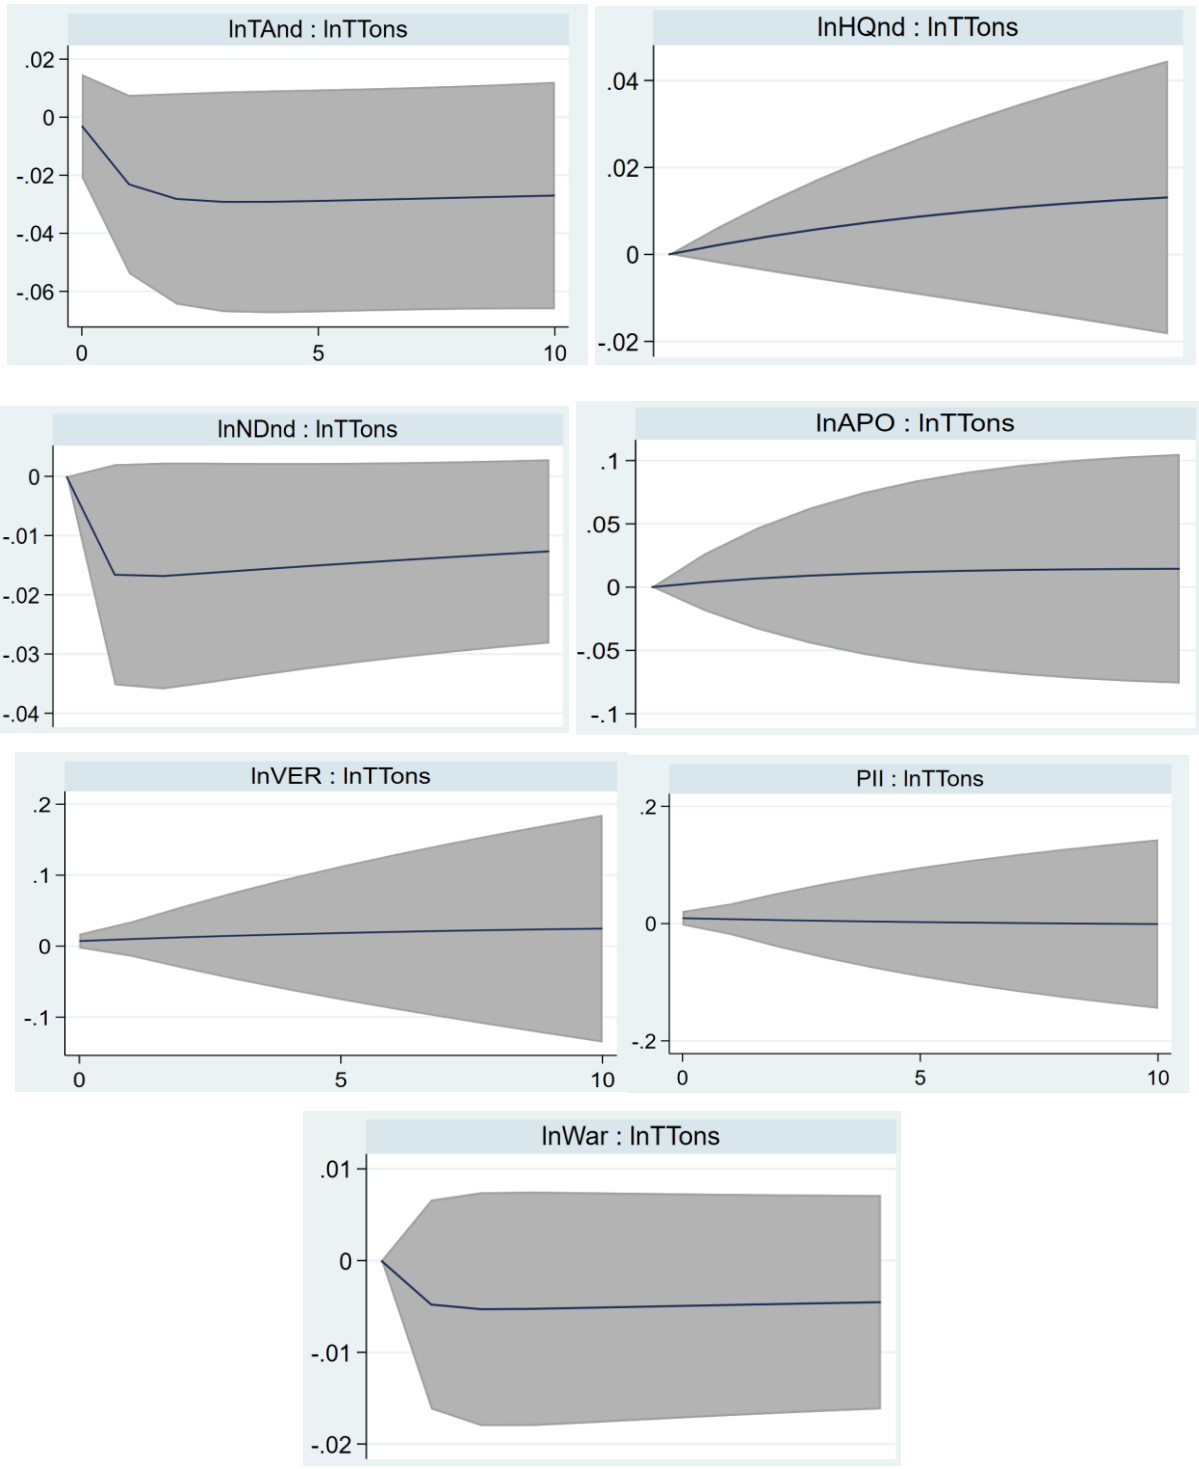
Procjene funkcije impulsnog odaziva za varijable od interesa temelje se na sljedećim promatranjima:

a) utjecaj terorističkog napada na turizam temelji se na 668 promatranja
b) utjecaj zdravstvenih pitanja na turizam temelji se na 2867 promatranja
c) utjecaj prirodnih katastrofa na turizam temelji se na 1373 promatranja
d) utjecaj prosječne cijene nafte na turizam temelji se na 2635 promatranja
e) utjecaj volatilnost tečaja na turizam temelji se na 2578 promatranja
f) utjecaj političke (ne)stabilnosti na turizam temelji se na 1909 promatranja
g) utjecaj rata na turizam temelji se na 2924 promatranja.

Unutar okvira panel vektorske autoregresije procjenjuje se i prikazuje funkcija impulzivnog odaziva (eng. Impulse-response functions) uz pomoću koje se provodi procjena ortogonalnih šokova s ciljem procjene šoka jedne varijable na drugu, a da se pritom sve ostale varijable

održavaju konstantnima. Funkcija impulzivnog odaziva, osim što provodi procjenu šokova, ujedno mjeri smjer, jačinu i trajanje reakcije na šok u modelu (Jovančević, Arčabić i Globan, 2012, str. 8). U daljnjem slijedu rada bit će prikazane impulsne funkcije varijabli korištenih unutar modela.

Grafikon 14 IMPULSNE REAKCIJE TURIZMA NA TERORISTIČKI NAPAD, ZDRAVSTVENA PITANJA, PRIRODNE KATASTROFE, PROSJEČNU CIJENU NAFTE, VOLATILNOST TEČAJA, POLITIČKU NESTABILNOST I RAT



Note: impulse:response
Izvor: izračun autorice

Grafikon 14 prikazuje reakcije turizma na eksterne šokove, a kao što je i očekivano, najznačajnija negativna reakcija na turizam uočljiva je pri šokovima od stane terorističkih napada, prirodne katastrofe te rata. Funkcijama impulzivnog odaziva promatraju se reakcije u trenutku nastanka šoka u odnosu na period od 10 godina nakon nastanka šoka. Rasponi pouzdanosti generirani su metodama Monte Carlo simulacije koja je temeljena na 200 izvlačenja (eng. draws). Iz prikazanih rezultata vidljivo je kako ni jedna reakcija nije statistički signifikantna. Intervali pouzdanosti unutar svih sedam modela obuhvaćaju pozitivne i negativne vrijednosti.

Shodno prikazanim rezultatima istraživačka hipoteza 2 koja tvrdi: *Kratkoročni i dugoročni efekti razlikuju se po tipu eksternog šoka* ne prihvaća se s obzirom na to da su rezultati provedene analize pokazali kako ni jedna reakcija nije statistički signifikantna odnosno rezultati funkcije impulsnog odaziva statistički nisu različiti. Procjena kratkoročnih efekata pokazuje kako na turizam negativno utječu teroristički napadi, prirodne katastrofe i rat, dok procjena dugog roka nije izvršena zbog ograničenja u vidu nedostataka podataka za sve varijable.

5.3. Hipoteza 3: *Postoji međuovisnost eksternih šokova i turizma*

Nastavno na sve prethodno provedene testove, a u svrhu dokazivanja treće postavljane hipoteze koja će pružiti odgovore na pitanja o tome postoji li međuovisnost između zavisne i nezavisnih varijabli, provest će se Grangerov test uzročnosti (eng. Granger Causality Test). Da bi se proveo spomenuti test, prethodno je potrebno provesti stacionarnost varijabli na način da se provede test jediničnih korijena (eng. unit root test) na panel podacima, zatim test procjene redoslijeda vremenskih pomaka unazad na uzroku, te zatim za svaki panel VAR model koji je proveden u prethodnom potpoglavlju provesti Grangerov test uzročnosti.

Sve procjene modela vrše se za razdoblje 1995. – 2019.

Procjena uzročnosti za varijable:

a) teroristički napad i turizam temelji se na 668 promatranja
b) zdravstvena pitanja i turizam temelji se na 2867 promatranja
c) prirodne katastrofe i turizam temelji se na 1373 promatranja
d) prosječna cijena nafte i turizam temelji se na 2635 promatranja
e) volatilnost tečaja i turizam temelji se na 2578 promatranja
f) politička (ne)stabilnost i turizma temelji se na 1909 promatranja

g) rat i turizam temelji se na 2924 promatranja.

U definiciji se uzročnost temelji na predvidljivosti nizova (Granger, 1969). Grangerov test kaže da niz X uzrokuje drugi niz Y ako se Y može bolje predvidjeti (u smislu manje varijacije predviđene pogreške) koristeći pritom prošlost X. Pojam međuovisnost može se proširiti i na skup nizova $\{Y_{1,\ldots\ldots}Y_l\}$ tako da se za njih kaže Grangerov niz Y_k samo ako se Y_k može bolje predvidjeti korištenjem prošlih vrijednosti skupa (Gregorova, Kalousis i Marchand-Maillet (2015). Grangerov test uzročnosti (prema uzoru na Abrigo i Love, 2015) u okviru panel VAR-a primijenit će se kako bi se istražila uzročna veza koja može postojati između varijabli. Nulta hipoteza Grangerovog testa uzročnosti je odsutnost uzročnosti, tj. ona glasi, H0: *izuzeta varijabla ne uzrokuje Grangerovu varijablu jednadžbe* ako se odbacuje nulta hipoteza, to znači da postoji uzročnost između varijabli. Tablica 12 pokazuje rezultate jesu li koeficijenti nezavisnih varijabli na 1 pomaku (zaostajanju) zajedno jednaki nuli. Obostrana uzročna veza utvrđena je pri varijabli prirodne katastrofe. Na razini signifikantnosti do 1% (*p<0.01)* uzročna veza utvrđena je pri smjeru prirodnih katastrofa prema turizmu, dok je na razini signifikantnosti do 5% (*p<0.05)* utvrđena veza smjera turizma prema prirodnim katastrofama. Za neuobičajen smjer uzročnosti utjecaja turizma na prirodne katastrofe objašnjenje se može povezati s istraživanjem od strane Wu et al. (2020.) koji tumače kako razvoj turizma utječe na povećanje urbanizacije, a povećanje urbanizacije dovodi do posljedica povećanog razvoja emisija ugljika. Nadalje, jednosmjerna uzročna veza na razini do 10% (*p<0.10)* utvrđena je pri smjeru turizam prema zdravstvenim pitanjima slično istraživanju Uzuner i Ghosh, (2021). Jednosmjerna uzročna veza na razini signifikantnosti do 1% (*p<0.01)* utvrđena je i pri varijabli prosječna cijena nafte. Dakle, za varijable zdravstvena pitanja, prirodne katastrofe te prosječna cijena nafte nulta hipoteza se odbacuje, dok se za varijable teroristički napad, volatilnost tečaja, politička nestabilnost te rad nulta hipoteza prihvaća. Shodno prikazanim rezultatima postavljena hipoteza 3 koja glasi: Postoji međuovisnost eksternih šokova i turizma djelomično se prihvaća.

Tablica 12 Grangerov test uzročnosti

Equation / jednadžba	Excluded / izuzeta varijabla	chi2	df	Prob>chi2
lnTTons	lnTAnd	2.266	1	0.132
lnTAnd	lnTTons	2.430	1	0.119
lnTTons	lnHQnd	0.960	1	0.327
lnHQnd	lnTTons	3.270	1	**0.071***
lnTTons	lnNDnd	3.884	1	**0.049****

lnNDnd	lnTTons	27.107	1	**0.000*** **
lnTTons	lnAPO	0.110	1	0.740
lnAPO	lnTTons	15.746	1	**0.000*** **
lnTTons	lnVER	0.067	1	0.795
lnVER	lnTTons	1.922	1	0.166
lnTTons	PII	0.014	1	0.905
PII	lnTTons	0.556	1	0.456
lnTTons	lnWar	0.674	1	0.412
lnWar	lnTTons	2.822	1	0.093

H0: Izuzeta varijabla ne uzrokuje Grangerovu varijablu jednadžbe;
*Note: *** p<0.01, ** p<0.05, * p<0.1*
Izvor: izračun autorice

Finalno, nakon pregleda svih procijenjenih modela, panel analize s uključenim testovima dijagnostike, panel VAR modela te *Granger casualityja* zaključuje se kako je specifikacija unutar istih dobro definirana pa samim time rezultati procijenjene panel analize pružaju mogućnost za interpretaciju rezultata istraživanja u ekonomskom pogledu. Interpretacija rezultata istraživanja predstavlja ujedno i temelj zaključnih razmatranja vezanih uz postavljene hipoteze.

6. ZAKLJUČCI I SMJERNICE DALJNJIH ISTRAŽIVANJA

Turizam kao gospodarska, kulturna i socijalna pojava predstavlja važnu ulogu suvremenog društva receptivnih zemalja. Jedan od glavnih pokretača turizma je globalizacija čiji je utjecaj unazad tridesetak godina uvelike doprinio povećanju turističkih kretanja odnosno potražnje. Uz snažan rast, kroz povijest predmet brojnih istraživanja bivaju i tzv. turističke krize koje ostavljaju značajne posljedice. Upravo takve krize koje se nalaze u sferi turizma bivaju razlog smanjenja međunarodne turističke potražnje odnosno turističkih aktivnosti na način da turist gubi povjerenje u turističku destinaciju. Istraživanja pokazuju kako su posljedice kriznih situacija na turističke aktivnosti blažeg intenziteta za razvijene zemlje nego za receptivne zemlje u razvoju.

Eksterni šokovi poput prirodnih katastrofa, pandemija, ratova, migracija, terorizma, političkih nestabilnosti, volatilnosti tečaja, rasta cijene nafte bivaju sve učestaliji, a negativne se posljedice evidentiraju u svim sferama pa tako i u turističkim aktivnostima koje doprinose povećanju zaposlenosti, povećanju deviznog prihoda ostvarenog od turizma u strukturi BDP-a, smanjenju međunarodnih turističkih kretanja i slično. Međunarodni turisti percipiraju sigurnost i osobno blagostanje s najvećim rangom zabrinutosti. Upravo situacija u kojoj turisti odabiru neku turističku destinaciju zapravo znači da donose procjenu sigurnosti i neizvjesnosti turističkih aktivnosti, odnosno percepciju turističkog rizika. Percepcija o nekoj turističkoj destinaciji ključan je faktor u svijetu turizma zbog svog izravnog utjecaja na odabir turističke destinacije. Konstantna izloženost riziku može utjecati na promjenu tolerancije na rizik te na taj način povećati i razinu rizika koji se toleriraju. Upravo je modeliranje volatilnosti turizma ključno za olakšavanje donošenja odluka unutar mnogih gospodarstava, a posebice onih zemalja koje uvelike ovise o turizmu.

Postavljeni aplikativni ciljevi rada temeljili su se na detaljnom objašnjenju odabranih varijabli kako bi se, s ciljem podizanja svijesti o prisutnosti eksternih šokova, veći fokus usmjerio upravo na njihovo praćenje. Aplikativni doprinos rada očituje se u provedbi empirijskog istraživanja utjecaja raznih eksternih šokova na turistička kretanja odnosno na ostvarena noćenja.
Doprinosi rada ekonomskim znanostima u teorijskom smislu određuju se u sistematizaciji i teorijskom definiranju turističkih kretanja te eksternih šokova teroristički napad, prirodne katastrofe, zdravstvena pitanja, politička nestabilnost, volatilnost tečaja, cijena nafte, rat i migracije. Doprinos se također određuje u analizi i sistematizaciji značaja utjecaja eksternih

šokova na turizam te afirmaciji i razvoju znanja o važnosti i razumijevanju njihovog međuodnosa. Nadalje, doprinos rada počiva u razvoju i afirmaciji znanstvenih znanja o analiziranju i ocjenjivanju utjecaja eksternih šokova na turizam i turistička kretanja te u razvoju i primjeni ekonometrijskog modela panel analize kojim je u značajnoj mjeri moguće procijeniti osjetljivost turizma na eksterne šokove te pružiti odgovore na istraživačka pitanja.

Znanstveni ciljevi rada pružaju detaljan uvid u rezultate istraživanja drugih autora na temu osjetljivost turizma na eksterne šokove te također, primjena ekonometrijskih modela u cilju potvrđivanja ili odbacivanja postavljenih hipoteza.

Znanstveni doprinos ove doktorske disertacije proizlazi u proučavanju eksternih šokova i turizma te njihovom povezivanju i procjeni osjetljivosti turizma na iste. Rezultati empirijskog dijela istraživanja opravdavaju očekivanja koja se temelje na teorijskim pretpostavkama. Empirijski dio istraživanja obuhvaćao je provedbu panel analize s ciljem utvrđivanja utjecaja odabranih eksternih šokova na turizam. Panel analiza provodila se na uzorku od 168 zemalja koje su predstavljale prostornu komponentu, kroz period od 25 godina (1995. – 2019.). S obzirom na nebalansirane panel podatke tijekom procjene modela, uzorak se smanjuje ovisno o dostupnosti podataka za varijable obuhvaćene istraživanjem. Nezavisne varijable u modelu bile su teroristički napadi, prirodne katastrofe, zdravstvena pitanja, politička nestabilnost, rat, migracije, volatilnost tečaja i cijena nafte, dok je zavisna varijabla ukupno ostvarena noćenja.

Hipoteza 1: ***Postoji statistički signifikantna razlika u stupnju osjetljivosti turizma na odabrane eksterne šokove*** **u potpunosti se prihvaća.**

U sklopu istraživanja, hipoteza 1 se prihvaća s obzirom na to da rezultati svih eksternih šokova bilježe signifikantnu značajnost negativnog ili pozitivnog predznaka unutar testiranih modela.

S ciljem procjene utjecaja eksternih šokova na turističke dolaske rezultati provedene panel analize pokazuju snažnu i signifikantnu vezu kod 6 varijabli od interesa (od ukupno testiranih 7) i to redom: teroristički napad, prirodne katastrofe, zdravstvena pitanja, volatilnost tečaja, rata te politička (ne)stabilnost.

Kako bi se utvrdile razlike u dobivenim rezultatima u zemljama koje su više ili manje ovisne o turizmu, definirale su se dvije skupine.

Iz provedene analize mogu se prezentirati sljedeći zaključci:

- Kada je u pitanju teroristički napad i njegov utjecaj na turizam, rezultati istraživanja pokazuju da se unutar svih modela (izuzev modela 4) I. skupa podjele uzorka podataka (devizni prihod ostvaren od turizma do 5% u strukturi BDP-a) ostvaruje pozitivan efekt. Skup II (devizni prihod ostvaren od turizma od 5% do 10% u strukturi BDP-a) s druge strane bilježi unutar svih modela negativan efekt terorističkih napada. Dakle, zaključak

je da su države koje više ovise o turizmu kao aktivnosti osjetljivije na terorističke napade nego što je slučaj s državama koje ostvaruju manje prihode od turizma.

- Zdravstvena pitanja predstavljaju varijablu eksternog šoka koja pokazuju dvojake rezultate. Države koje ostvaruju niži stupanj ovisnosti u modelu 2, modelu 3 te modelu 4 bilježe negativan utjecaj na turizam. Model 1 te model 3 u sklopu skupa II pri kojoj države više ovise o turizmu, bilježi pozitivan utjecaj na varijablu turizam. Model 2 istog skupa negativno se odražava na turizam.
- Prirodne katastrofe predstavljaju eksterni šok na koji turizam reagira samo u sklopu baznog modela, odnosno modela s varijablama od interesa gdje je utvrđen pozitivan efekt. Negativan efekt utvrđen je ubacivanjem kontrolnih varijabli u model država koje bilježe niži stupanj ovisnosti o turizmu.
- Migracije za koje je rađen model na petogodišnjem vremenskom promatranju pokazuje kako unutar oba modela gdje je evidentirana niža ovisnost o turizmu migracije pozitivno utječu na turizam. Isti efekt utvrđen je i kod država koje više ovise o turizmu, ali samo u sklopu baznog modela.
- Prosječna cijena nafte eksterni je šok koji se u sklopu baznog modela negativno odražava na turizam. Negativan efekt evidentiran je unutar država koje bilježe višu ovisnost o turizmu, unutar modela 1, modela 3 i modela 4. Od država koje ostvaruju niži devizni prihod negativan efekt evidentiran je samo u sklopu baznog modela.
- Volatilnost tečaja predstavlja eksterni šok koji se unutar svih modela i definiranih skupova (I. i II.) negativno odražava na turizam.
- Politička nestabilnost pozitivno se odražava na turizam kada su u pitanju države koje manje ovise o turizmu, u sklopu modela 1 te modela 2 i modela 3, dok je u sklopu država koje ostvaruju niži postotak deviznog prihoda također utvrđen pozitivan efekt na turizam.
- Rat kao eksterni šok bilježi pozitivan efekt na turizam u modelu 2 koji uključuje kontrolne varijable, a odnosi se na države koje ostvaruju niži postotak deviznog prihoda, te isto tako pozitivan ishod utvrđen je u sklopu modela 3, no ovog puta za države koje ostvaruju viši postotak deviznog prihoda.

Kako bi se utvrdilo je li mediteranske zemlje isto reagiraju na eksterne šokove, kreiran je model odabranih mediteranskih zemalja te su rezultati pokazali kako eksterni šok zdravstvenih pitanja pozitivno utječe na turizam. Eksterni šok u obliku rasta cijene nafte u modelu koji uključuje

kontrolne varijable prikazuje pozitivan utjecaj na turizam. Eksterni šok volatilnost tečaja u baznom modelu negativnog je predznaka, dok se uključivanjem kontrolnih varijabli mijenja u pozitivan utjecaj na turizam. Politička nestabilnost također (kada su u pitanju mediteranske zemlje u sklopu baznog modela) pozitivno djeluje na turizam.

Hipoteza 2: ***Kratkoročni efekti šokova na turizam različiti su po tipu eksternih šokova*** **se ne prihvaća.**

Hipoteza 2 ne prihvaća se s obzirom na to da su rezultati provedene analize pokazali kako ni jedna reakcija nije statistički signifikantna odnosno rezultati funkcije impulsnog odaziva statistički nisu različiti od 0. S obzirom na to da se uz pomoć funkcije impulsnog odaziva promatrala reakcija u trenutku nastanka šoka u odnosu na period od 10 godina nakon nastanka šoka te su reakcije pokazale kako ni jedna reakcija nije statistički signifikantna odnosno u svih sedam slučajeva intervali pouzdanosti obuhvaćaju i pozitivne i negativne vrijednosti.

Nadalje, rezultati panel vektorske autoregresije odnosno procjene pokazali su kako od analiziranih utjecaja eksternih šokova prirodne katastrofe, povećanje cijene nafte, zdravstvena pitanja te ratno stanje imaju najznačajniji utjecaj pri smanjenju ukupno ostvarenih noćenja.

Utjecaj eksternih šokova bio je testiran uz pomoć ortogonalne funkcije impulsnog odaziva u sklopu panel VAR modela. Iz prikazanih rezultata očituje se kako zapravo ni jedna reakcija nije statistički signifikantna. Intervali pouzdanosti unutar svih sedam modela obuhvaćaju pozitivne i negativne vrijednosti.

Hipoteza 3: ***Postoji međuovisnost eksternih šokova i turizma*** **djelomično se prihvaća.**

Hipoteza 3 djelomično se prihvaća iz razloga što rezultati (panel VAR Grangera) pokazuju međuovisnost eksternih šokova utvrđena je u oba smjera pri eksternom šoku prirodne katastrofe. Neobičan rezultat postojanja uzročnosti iz smjera turizma k prirodnim katastrofama može se prema pojedinim istraživanjima objasniti kroz intenzivan razvoj urbanizacije koja je posljedica razvoja turizma. Urbanizacija može uzrokovati povećanje emisije ugljika u zraku koji utječe na klimatsko okruženje. Jednosmjerna veza utvrđena je i od strane turizma prema zdravstvenim pitanjima. Turizam upravo zahvaljujući globalizaciji i statičnosti turističke ponude utječe na mobilnost turista te stoga prijenos raznih zaraznih bolesti može biti uzrokovan upravo turističkim kretanjima. Prosječna cijena nafte eksterni je šok koji također utječe na turizam, točnije pad cijene nafte pozitivno će se odraziti na turističku potražnju i njena kretanja te posljedično tome i niže cijene karata prijevoznih sredstava.

Provedeno istraživanje ima stanovita ograničenja iz kojih proizlaze smjernice za buduća istraživanja. Prvo ograničenje utvrđeno je s aspekta uzorka pri čemu je nekoliko zemalja bilo

isključeno iz modela iz razloga nepotpunih podataka (smrtno stradali kod varijabli terorističkih napada, zdravstvenih pitanja i prirodnih katastrofa). Razlog navedenom je što kod nekih zemalja nije bilo evidentiranih npr. terorističkih napada ili prirodnih katastrofa. Prvotni plan bio je također i provedba ARDL modela s ciljem utvrđivanja utjecaja postavljenih nezavisnih varijabli kroz dugi i kratki rok, no iz razloga nedostataka podataka za sve zemlje u sklopu svih varijabli procjena nije bila moguća.

Autorica je uvjerenja kako prikazano istraživanje i rezultati mogu pridonijeti kreatorima politike u donošenju odluka i mjera kako bi se osjetljivost turizma na eksterne šokove svela na prihvatljivu razinu za receptivne zemlje u razvoju te za razvijene zemlje.
Buduća istraživanja trebala bi biti usmjerena na proširivanje uzorka na novim periodima s ciljem utvrđivanja pouzdanosti dobivenih rezultata, zatim na provedbu analize s ubacivanjem dodatnih varijabli koje bi predstavljale eksterne šokove, npr. razina kriminala u turističkoj destinaciji, financijska kriza, geopolitički šokovi. Također bi trebala biti usmjerena i na provedbu analize na odabranom manjem uzorku ciljem utvrđivanja i potvrđivanja već postojećih rezultata. Buduća istraživanja trebala bi procijeniti trajanje pojedinih šokova, odnosno istražiti koliko je vremena potrebno receptivnim zemljama za oporavak od pojedinog šoka.

LITERATURA

1. Abadie, A. (2006). Poverty, political freedom, and the roots of terrorism. *American Economic Review*, *96*(2), 50-56., dostupno na: https://pubs.aeaweb.org/doi/pdf/10.1257/000282806777211847, (10.07.2020.)
2. Abrigo, M. R., & Love, I. (2015). Estimation of panel vector autoregression in Stata. *The Stata Journal*, *16*(3), 778-804., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1536867X1601600314, (28.02.2022.)
3. Abuharris, A. T. (2005). *Tourism and sustainable economic development: Marketing implications and strategic framework: the case study of Libya* (Doctoral dissertation, Salford: University of Salford)., dostupno na: http://usir.salford.ac.uk/id/eprint/26495/, (22.06.2020.)
4. Adamou, A., & Clerides, S. (2009). Prospects and limits of tourism-led growth: The international evidence. *The Rimini Centre for Economic Analysis WP*, 41-09., dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1495747, (22.06.2020.)
5. Adams, K. M. (2001) „Danger-zone tourism: prospects and problems for tourism in tumultuous times“, in P. Teo, T. C. Chang, and K. C. Ho (eds) Interconnected Worlds: Toruism in Southeast Asia, Oxford: Elsevier, 265-281, dostupno na: https://books.google.si/books?hl=hr&lr=&id=ZhGpAgAAQBAJ&oi=fnd&pg=PA265&dq=Adams,+K.M.+2001+danger+zone+tourism,+prospects+and+problems+for+tourism&ots=N7I73SN4rz&sig=e4IqftlARjCUyBmfv4aq0CFquyg&redir_esc=y#v=onepage&q&f=false, (21.07.2020.)
6. Adeola, O., Boso, N., & Evans, O. (2018). Drivers of international tourism demand in Africa. *Business Economics*, *53*(1), 25-36., dostupno na: https://link.springer.com/article/10.1057/s11369-017-0051-3, (13.07.2020.)
7. Adnan Hye, Q. M., & Ali Khan, R. E. (2013). Tourism-led growth hypothesis: A case study of Pakistan. *Asia Pacific Journal of Tourism Research*, *18*(4), 303-313., https://www.tandfonline.com/doi/abs/10.1080/10941665.2012.658412, (23.06.2020.)
8. Adrian, S. C. (2017). The Impact of Tourism on the Global Economic System. *Ovidius University Annals, Economic Sciences Series*, *17*(1), 384-387., dostupno na: http://stec.univ-ovidius.ro/html/anale/ENG/2017/Section-IV/22.pdf, (18.08.2020.)
9. Agarwal, M. K., & Upadhyay, R. P. (2006). *Tourism and economic development in Nepal*. Northern Book Centre., dostupno na: Tourism and economic development in Nepal, (07.04.2020)
10. Agiomirgianakis, G. M., Magoutas, A. I., & Sfakianakis, G. (2012). Determinants of profitability and the decision-making process of firms in the tourism sector: the case of Greece. *International Journal of Decision Sciences, Risk and Management*, *4*(3-4), 294-299., dostupno na: https://www.inderscienceonline.com/doi/abs/10.1504/IJDSRM.2012.053381, (07.08.2020.)
11. Agiomirgianakis, G., Serenis, D., & Tsounis, N. (2015). Effects of exchange rate volatility on tourist flows into Iceland. *Procedia Economics and Finance*, *24*, 25-34., dostupno na: https://doi.org/10.1016/S2212-5671(15)00608-5
12. Agnew, R. (2010). A general strain theory of terrorism. *Theoretical Criminology*, *14*(2), 131-153., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1362480609350163, (14.04.2020.)
13. Agrusa, J., Tanner, J., & Dupuis, J. (2006). Determining the potential of American Vietnam veterans returning to Vietnam as tourists. *International Journal of Tourism*

Research, *8*(3), 223-234., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.565, (21.07.2020.)

14. Aharony, M., & Rosenfeld, G. D. (2016). Holocaust commemoration: New trends in museums and memorials., dostupno na: https://www.tandfonline.com/doi/full/10.1080/23256249.2016.1271088, (23.07.2020.)
15. Ajmani, V. (2011). *Applied econometrics using the SAS system*. John Wiley & Sons. Dostupno na: https://books.google.hr/books?hl=hr&lr=&id=HS2CxsiZjXMC&oi=fnd&pg=PT9&dq=Ajmani,+V.B.+(2009).+Applied+econometrics+using+the+SAS+system.+Hoboken,+New+Jersey:+John+Wiley+%26+Sons,+Inc.+&ots=KTKfvZqZJ_&sig=e_3itqvIbDGFYSQRjQm2BUmrWxw&redir_esc=y#v=onepage&q&f=false
16. Akar, C. (2012). Modeling Turkish tourism demand and the exchange rate: the bivariate Garch approach. *European Journal of Economics, Finance and Administrative Science*, (50)., dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2914133, (06.08.2020.)
17. Alan, C. B., So, S., & Sin, L. (2006). Crisis management and recovery: how restaurants in Hong Kong responded to SARS. *International Journal of Hospitality Management*, *25*(1), 3-11., dosupno na: https://www.sciencedirect.com/science/article/pii/S0278431904001203, (26.06.2020.)
18. Albu, C. E. (2016). Tourism and terrorism: A worldwide perspective. *CES Working Papers*, *8*(1), 1., dostupno na: https://search.proquest.com/openview/ef8f62ef9dbd4d97b7999947439e8d73/1?pq-origsite=gscholar&cbl=2035671, (14.04.2020.)
19. Alcántara-Ayala, I. (2002). Geomorphology, natural hazards, vulnerability and prevention of natural disasters in developing countries. *Geomorphology*, *47*(2-4), 107-124., dostupno na: https://www.sciencedirect.com/science/article/pii/S0169555X02000831?casa_token=CxwADeYM8m4AAAAA:KE3mGVhUJPJfdxr60XTgpORqO9YNB_1mBDyPa-Zpojk4nGAtKNFdW-QRuXsnJh_VSAiQwyeDx3A, (27.04.2020.)
20. Alesina, A., Özler, S., Roubini, N., & Swagel, P. (1996). Political instability and economic growth. *Journal of Economic growth*, *1*(2), 189-211., dostupno na: https://link.springer.com/article/10.1007/BF00138862, (18.04.2020.)
21. Ali, R., Munandar, J. M., & Syamsun, M., (2019), The Effect of Green Perceived Quality, Green Perceived Value, Green Perceived Risk, Green Satisfaction and Green Trust in Stimulating Green Brand Equity Starbucks, West Java., dostupno na: http://ijrrjournal.org/IJRR_Vol.6_Issue.2_Feb2019/IJRR0012.pdf, (18.06.2020.)
22. Allen, T., Murray, K. A., Zambrana-Torrelio, C., Morse, S. S., Rondinini, C., Di Marco, M., ... & Daszak, P. (2017). Global hotspots and correlates of emerging zoonotic diseases. *Nature communications*, *8*(1), 1-10., dostupno na: https://www.nature.com/articles/s41467-017-00923-8, (04.06.2020.)
23. Aloui, C., Hamida, H. B., & Hkiri, B. (2020). Democratic transition, political risk, economic instability, and tourist inflows: The case of Tunisia. *Tourism Economics*, 1354816620913372., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1354816620913372, (15.07.2020.)
24. Alvarez, M. D., & Campo, S. (2014). The influence of political conflicts on country image and intention to visit: A study of Israel's image. *Tourism Management*, *40*, 70-78., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517713001155, (11.07.2020.)

25. Amara, D. (2012). Tourists' risk aversion and willingness to take risks: the case of tourists visiting Egypt after 25th January revolution. *6th World Conference for Graduate Research in Tourism, Hospitality and Leisure.22*.
26. Amelung, B., & Moreno, A. (2012). Costing the impact of climate change on tourism in Europe: results of the PESETA project. *Climatic Change*, *112*(1), 83-100., dostupno na: https://link.springer.com/article/10.1007/s10584-011-0341-0, (28.07.2020.)
27. Amin, A. (1994). Post-Fordism: models, fantasies and phantoms of transition. *Post-Fordism: a reader*, *1*, 1-7., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/9780470712726#page=10, (23.07.2020.)
28. An, M., Lee, C., & Noh, Y. (2010). Risk factors at the travel destination: their impact on air travel satisfaction and repurchase intention. *Service Business*, *4*(2), 155-166., dostupno na: https://link.springer.com/article/10.1007/s11628-010-0094-2, (16.06.2020.)
29. Andrews, D. W., & Lu, B. (2001). Consistent model and moment selection procedures for GMM estimation with application to dynamic panel data models. *Journal of econometrics*, *101*(1), 123-164., dostupno na: https://www.sciencedirect.com/science/article/pii/S0304407600000774, (03.03.2022.)
30. Arana, J. E., & León, C. J. (2008). The impact of terrorism on tourism demand. *Annals of tourism research*, *35*(2), 299-315., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738307001120?casa_token=1V94_qkfW2kAAAAA:fOa0HihkOhdnNzGJMUJwBs9ISO5LoRHVJLHjh-qeyjh9nylKJo2Mqah9RlTbzmzoZSMEAFARdA, (12.06.2020.)
31. Arellano, M., & Bond, S. (1991). Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations. *The review of economic studies*, *58*(2), 277-297., dostupno na: https://academic.oup.com/restud/article-abstract/58/2/277/1563354, (15.03.2022.)
32. Arunatilake, N., Jayasuriya, S., & Kelegama, S. (2001). The economic cost of the war in Sri Lanka. *World Development*, *29*(9), 1483-1500., dostupno na: https://www.sciencedirect.com/science/article/pii/S0305750X01000560?casa_token=86yXG4GHteIAAAAA:dfjMarPujSSUUa1yG4rwq6oHPX26KbSXG6L1rLyt5xOw018s6HZrumRNhV0rZr-AvRjvmXXS69Y, (29.06.2020.)
33. Asongu, S. A., Nnanna, J., Biekpe, N., & Acha-Anyi, P. N. (2019). Contemporary drivers of global tourism: evidence from terrorism and peace factors. *Journal of Travel & Tourism Marketing*, *36*(3), 345-357., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/10548408.2018.1541778, (11.07.2020.)
34. Assaf, A. G., Li, G., Song, H., & Tsionas, M. G. (2019). Modeling and forecasting regional tourism demand using the Bayesian global vector autoregressive (BGVAR) model. *Journal of Travel Research*, *58*(3), 383-397., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287518759226, (10.08.2020.)
35. Avraham, E., & Ketter, E. (2008). Will we be safe there? Analysing strategies for altering unsafe place images. *Place Branding and Public Diplomacy*, *4*(3), 196-204., dostupno na: https://link.springer.com/article/10.1057/pb.2008.10, (07.07.2020.)
36. Azad, A. S. M., Chheang, V., & Ahsan, A. (2014). External shocks and tourist arrivals to Cambodia. *Tourism analysis*, *19*(3), 311-321., dostupno: https://www.ingentaconnect.com/content/cog/ta/2014/00000019/00000003/art00005, (23.03.2020.)
37. Baade, R. A., Baumann, R., & Matheson, V. (2007). Estimating the economic impact of natural and social disasters, with an application to Hurricane Katrina. *Urban*

Studies, *44*(11), 2061-2076., dostupno na: https://journals.sagepub.com/doi/abs/10.1080/00420980701518917, (01.08.2020.)

38. Baig, S., & Zehra, S. (2020). China-Pakistan economic corridor, governance, and tourism nexus: evidence from Gilgit-Baltistan, Pakistan. *Current Issues in Tourism*, 1-6., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500.2020.1763266, (15.07.2020.)
39. Bailey, N., Kapetanios, G., & Pesaran, M. H. (2012). *VExponent of Cross&sectional Depen& dence: Estimation and InferenceV*. University of Cambridge Working Papers in Economics 1206, Faculty of Economics, University of Cambridge.
40. Baker, D. M. A. (2015). Tourism and the Health Effects of Infectious Diseases: Are There Potential Risks for Tourists?. *International Journal of Safety and Security in Tourism and Hospitality*, *1*(12), 1., dostupno na: https://search.proquest.com/openview/15914cacd010e97c978f9197f6a3ef0e/1?pq-origsite=gscholar&cbl=2035879, (02.08.2020.)
41. Balassa, B. (1989). Policy responses to exogenous shocks in developing countries. In *New Directions in the World Economy* (pp. 32-38). Palgrave Macmillan, London. , dostupno na: https://link.springer.com/chapter/10.1007/978-1-349-10588-5_2 (22.03.2020.)
42. Balli, F., Balli, H. O., & Louis, R. J. (2016). The impacts of immigrants and institutions on bilateral tourism flows. *Tourism Management*, *52*, 221-229., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517715001454, (24.07.2020.)
43. Baltagi, B. H. (2008). *Econometric analysis of panel data* (Vol. 4). Chichester: John wiley & sons.
44. Baltagi, B. H., & Hashem Pesaran, M. (2007). Heterogeneity and cross section dependence in panel data models: theory and applications introduction., https://onlinelibrary.wiley.com/doi/full/10.1002/jae.955 (14.09.2021.)
45. Baltagi, B. H., Bresson, G., & Pirotte, A. (2005). Adaptive estimation of heteroskedastic error component models. *Econometric Reviews*, *24*(1), 39-58., dostupno na: https://doi.org/10.1081/ETC-200049131 (02.02.2022.)
46. Bartoluci, M., Čavlek, N., Kesar, O., & Prebežac, D. (2011). Turizam-ekonomske osnove i organizacijski sustav. *Školska knjiga dd, Zagreb str*, *415*.
47. Bassil, C. (2014). The effect of terrorism on tourism demand in the Middle East. *Peace Economics, Peace Science and Public Policy*, *20*(4), 669-684., dostupno na: https://www.degruyter.com/view/journals/peps/20/4/article-p669.xml, (30.06.2020.)
48. Bassil, C., Hamadeh, M., & Samara, N. (2015). The tourism led growth hypothesis: the Lebanese case. *Tourism Review*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/TR-05-2014-0022/full/html, (13.07.2020.)
49. Bauer, R. A. (1960). Consumer behavior as risk taking. *Chicago, IL*, 384-398., dostupno na: https://books.google.si/books?hl=hr&lr=&id=HLuo1sawoAYC&oi=fnd&pg=PA13&dq=Bauer,+R.+Consumer+behavior+as+risk+taking.+In+Dynamic+Marketing+for+a+Changing+World%3B+Hancock,+R.S.,+Ed.%3B+American+Marketing+Association:+Chicago,+IL,+USA,+1960%3B+pp.+389%E2%80%93398.&ots=IerzbT1zVu&sig=2xEpVJRHqn2rjmPq9KictOLvodE&redir_esc=y#v=onepage&q&f=false, (15.06.2020.)
50. Bayar, Y., & Yener, B. (2019). Political stability and tourism sector development in Mediterranean countries: a panel cointegration and causality analysis. *European Journal of Tourism Research*, *21*, 23-32., dostupno na:

https://books.google.si/books?hl=hr&lr=&id=RqWLDwAAQBAJ&oi=fnd&pg=PA23&dq=Political+stability+and+tourism+sector+development+in+Mediterranean+countries:+a+panel+cointegration+and+causality+analysis&ots=cE536xKisS&sig=zvCWYiY6RXgQdmkLp19dbQmND1Y&redir_esc=y#v=onepage&q=Political%20stability%20and%20tourism%20sector%20development%20in%20Mediterranean%20countries%3A%20a%20panel%20cointegration%20and%20causality%20analysis&f=false, (15.07.2020.)

51. Beattie, M. A. (1992). The effect of natural disasters on tourism a study of Mount Saint Helens and Yellowstone National Park., dostupno na: https://scholarworks.rit.edu/cgi/viewcontent.cgi?article=8433&context=theses, (30.07.2020.)
52. Becken, S. (2008). Developing indicators for managing tourism in the face of peak oil. *Tourism Management*, *29*(4), 695-705., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517707001641?casa_token=ZQX2My9fbf8AAAAA:1dmxpjgLKAHfXGKrLa3u1wsb4UNbIAudiOpzyRMSysjIbuC1AJxpM1W5TQd0GbDc8OR2-sy_8rM, (10.08.2020.)
53. Becken, S. (2011). A critical review of tourism and oil. *Annals of Tourism Research*, *38*(2), 359-379., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738310001246?casa_token=grU8mDJODuQAAAAA:8YmqAcbwN7sx2UGdLplpanwDxT6wJgU1RmZ7P1saLA0Ec1SWJt9MZqBh4zrY2RUOOsS6L3005uA, (05.06.2020.)
54. Becken, S. (2011). Oil, the global economy and tourism. *Tourism Review*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/16605371111175339/full/html, (10.08.2020.)
55. Becken, S., & Hughey, K. F. (2013). Linking tourism into emergency management structures to enhance disaster risk reduction. *Tourism Management*, *36*, 77-85., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517712002063, (30.07.2020.)
56. Becken, S., & Lennox, J. (2012). Implications of a long-term increase in oil prices for tourism. *Tourism Management*, *33*(1), 133-142., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517711000562?casa_token=yST9OTdzXXgAAAAA:2tPhcZfY_q4FNrxLMGe8gvYGRov-tbOkHSjJ2tBLx0s9mW0bZ-TqOejSthnxT38yIs7-6hsyZ2Y, (10.08.2020.)
57. Becken, S., Carboni, A., Vuletich, S., & Schiff, A. (2008). Analysis of tourist consumption, expenditure and prices for key international visitor segments: technical report., dostupno na: http://researcharchive.lincoln.ac.nz/handle/10182/710, (07.08.2020.)
58. Becken, S., Jin, X., Zhang, C., & Gao, J. (2017). Urban air pollution in China: Destination image and risk perceptions. *Journal of Sustainable Tourism*, *25*(1), 130-147., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/09669582.2016.1177067, (15.06.2020.)
59. Becken, S., Mahon, R., Rennie, H. G., & Shakeela, A. (2014). The tourism disaster vulnerability framework: An application to tourism in small island destinations. *Natural Hazards*, *71*(1), 955-972., dostupno na: https://link.springer.com/article/10.1007%2Fs11069-013-0946-x, (29.07.2020.)
60. Becken, S., Zammit, C., & Hendrikx, J. (2015). Developing climate change maps for tourism: Essential information or awareness raising?. *Journal of Travel Research*, *54*(4), 430-441., dostupno na: https://journals.sagepub.com/doi/10.1177/0047287514528286, (15.06.2020.)

61. Benckendorff, P., & Zehrer, A. (2013). A network analysis of tourism research. *Annals of Tourism Research*, *43*, 121-149., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0160738313000662, (23.07.2020.)
62. Benoit, K. (2011). Linear regression models with logarithmic transformations. *London School of Economics, London*, *22*(1), 23-36., https://links.sharezomics.com/assets/uploads/files/1600247928973-from_slack_logmodels2.pdf, (16.08.2021.)
63. Berke, P. R. (1998). Reducing natural hazard risks through state growth management. *Journal of the American Planning Association*, *64*(1), 76-87., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/01944369808975958, (25.04.2020.)
64. Bhati, A., Upadhayaya, A., & Sharma, A. (2016). National disaster management in the ASEAN-5: an analysis of tourism resilience. *Tourism Review*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/TR-12-2015-0062/full/html, (15.06.2020.)
65. Bhattacharya, M., & Basu, K. (2010). Impact of terror incidents on the foreign tourist arrivals in India: An econometric exploration. *International Journal of Tourism Policy*, *3*(3), 213-222., dostupno na: https://www.inderscienceonline.com/doi/abs/10.1504/IJTP.2010.037993, (13.07.2020.)
66. Bhattarai, K., Conway, D., & Shrestha, N. (2005). Tourism, terrorism and turmoil in Nepal. *Annals of Tourism Research*, *32*(3), 669-688., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738305000563?casa_token=gLZwB_D3CiUAAAAA:UV2bcfwPxVpLHICJDS3nat__kRuiumB9XF_gFsvTdRMsGzxvSpI9gfHB-06hgeRWCC7TLvK_11c, (13.07.2020.)
67. Bigley, J. D., Lee, C. K., Chon, J., & Yoon, Y. (2010). Motivations for war-related tourism: A case of DMZ visitors in Korea. *Tourism Geographies*, *12*(3), 371-394., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/14616688.2010.494687, (20.04.2020.)
68. Biran, A., & Hyde, K. F. (2013). New perspectives on dark tourism. *International Journal of Culture, Tourism and Hospitality Research*, *7*(3), 191-198., dostupno na: https://www.ingentaconnect.com/content/mcb/ijcthr/2013/00000007/00000003/art00001, (23.07.2020.)
69. Biran, A., Poria, Y., & Oren, G. (2011). Sought experiences at (dark) heritage sites. *Annals of tourism research*, *38*(3), 820-841., dostupno na: https://www.sciencedirect.com/science/article/pii/S016073831000160X?casa_token=BqXGkUgYHHAAAAAA:ygpPtwKgnHiKoYzNIBgtaCahor68XTWGYrdiL5HQAaahH8tVzLRQqrv6gDvMlBb98Flx14F_A8g, (23.07.2020.)
70. Blaikie, P., Cannon, T., Davis, I., & Wisner, B. (2014). *At risk: natural hazards, people's vulnerability and disasters*. Routledge., dostupno na: https://books.google.si/books?hl=hr&lr=&id=AyCyDwAAQBAJ&oi=fnd&pg=PP1&dq=Blaikie,+P.,+Cannon,+T.,+Davis,+I.,+%26+Wisner,+B.+(1994).+At+risk:+Natural+hazards+people%E2%80%99s+vulnerability+and+disasters&ots=bnArAHrkQ5&sig=v6Yjs013A8j-SCNsf7B3Xp_5Pqc&redir_esc=y#v=onepage&q=Blaikie%2C%20P.%2C%20Cannon%2C%20T.%2C%20Davis%2C%20I.%2C%20%26%20Wisner%2C%20B.%20(1994).%20At%20risk%3A%20Natural%20hazards%20people%E2%80%99s%20vulnerability%20and%20disasters&f=false, (25.04.2020.)
71. Blake, A., & Sinclair, M. T. (2003). Tourism crisis management: US response to September 11. *Annals of Tourism Research*, *30*(4), 813-832. dostupno na:

https://is.muni.cz/el/1431/podzim2006/Z0042/um/2510689/TOURISM_CRISIS_MANAGEMENT__US_Response_to_September_11_.pdf

72. Blake, A., Arbache, J. S., Sinclair, M. T., & Teles, V. (2008). Tourism and poverty relief. *Annals of Tourism Research*, *35*(1), 107-126., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738307000916?casa_token=4LXrMg7OooIAAAAA:gkYuEH5rb41179OgON63JLxMUeaEz7Pa_N3ngNHw_i0rxSPYA9ohDCVqvP5OGyk0Nz9C7_5OPg, (07.08.2020.)
73. Bloom, D. E., & Cadarette, D. (2019). Infectious disease threats in the twenty-first century: strengthening the global response. *Frontiers in immunology*, *10*, 549., dostupno na: https://www.frontiersin.org/articles/10.3389/fimmu.2019.00549/full, (02.08.2020.)
74. Boksberger, P. E., Bieger, T., & Laesser, C. (2007). Multidimensional analysis of perceived risk in commercial air travel. *Journal of Air Transport Management*, *13*(2), 90-96., dostupno na: https://www.sciencedirect.com/science/article/pii/S0969699706000901?casa_token=GjofoQGMtugAAAAA:tfkk1_MzLfYItOOzLU_JN4hacpp4E3N-EcPtHGmItpsNpihTNqYgGd2i_wHBTzzgandK9QCAoy4, (16.06.2020.)
75. Borhan, N., & Arsad, Z. (2016, October). Determining factors affecting tourism demand for Malaysia using ARDL modeling: A case of Europe countries. In *AIP Conference Proceedings* (Vol. 1782, No. 1, p. 050005). AIP Publishing LLC., dostupno na: https://aip.scitation.org/doi/abs/10.1063/1.4966095, (06.08.2020.)
76. Boyne, S., Carswell, F., & Hall, D. (2002). Reconceptualising VFR tourism. In *Tourism and migration* (pp. 241-256). Springer, Dordrecht., dostupno na: https://link.springer.com/chapter/10.1007/978-94-017-3554-4_13, (26.07.2020.)
77. Brakke, M. (2004). International tourism, demand, and GDP implications: a background and empirical analysis. *Undergraduate Economic Review*, *1*(1), 2., dostupno na: https://digitalcommons.iwu.edu/uer/vol1/iss1/2/, (22.06.2020.)
78. Breusch, T. S., & Pagan, A. R. (1979). A simple test for heteroscedasticity and random coefficient variation. *Econometrica: Journal of the econometric society*, 1287-1294., dostupno na: https://www.jstor.org/stable/1911963?seq=1#metadata_info_tab_contents
79. Breusch, T. S., & Pagan, A. R. (1980). The Lagrange multiplier test and its applications to model specification in econometrics. *The review of economic studies*, *47*(1), 239-253., dostupno na; https://www.jstor.org/stable/2297111?seq=1#metadata_info_tab_contents
80. Brida, J. G., Cortes-Jimenez, I., & Pulina, M. (2016). Has the tourism-led growth hypothesis been validated? A literature review. *Current Issues in Tourism*, *19*(5), 394-430., dostupno na: https://scholar.google.si/scholar?hl=hr&as_sdt=0%2C5&as_vis=1&q=Has+the+tourism-led+growth+hypothesis+been+validated%3F+A+literature+review&btnG=#d=gs_cit&u=%2Fscholar%3Fq%3Dinfo%3ArWi8Q5dhVUQJ%3Ascholar.google.com%2F%26output%3Dcite%26scirp%3D0%26hl%3Dhr, (18.08.2020.)
81. Briguglio, L. (2003, September). The vulnerability index and small island developing states: A review of conceptual and methodological issues. In *AIMS Regional Preparatory Meeting on the Ten Year Review of the Barbados Programme of Action: Praia, Cape Verde.*, dostupno na: https://www.semanticscholar.org/paper/THE-VULNERABILITY-INDEX-AND-SMALL-ISLAND-DEVELOPING-Briguglio/add10617fdab11e938a236a1ec10cb67b32abae9, (01.08.2020.)

82. Brooks, C. (2008). RATS Handbook to accompany introductory econometrics for finance. *Cambridge Books*., dostupno na: https://ideas.repec.org/b/cup/cbooks/9780521721684.html
83. Brunt, P., & Cousins, K. (2002). The extent of the impact of terrorism on international travel and tourism at specific tourist destinations. *Crime prevention and community safety*, *4*(3), 7-21., dostupno na: https://link.springer.com/article/10.1057/palgrave.cpcs.8140127, (29.06.2020.)
84. Buckley, P. J., & Klemm, M. (1993). The decline of tourism in Northern Ireland: The causes. *Tourism Management*, *14*(3), 184-194., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/026151779390019H, (13.04.2020.)
85. Buigut, S., & Amendah, D. D. (2016). Effect of terrorism on demand for tourism in Kenya. *Tourism Economics*, *22*(5), 928-938., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/te.2015.0467, (29.03.2020.)
86. Butler, D. L., Carter, P. L., & Dwyer, O. J. (2008). Imagining plantations: Slavery, dominant narratives, and the foreign born. *southeastern geographer*, *48*(3), 288-302., dostupno na: https://www.jstor.org/stable/26225534, (23.07.2020.)
87. Butler, R. W. (2001). Seasonality in tourism: Issues and implications. In *Seasonality in tourism* (pp. 5-21). Routledge.
88. Butler, R., & Suntikul, W. (Eds.). (2013). *Tourism and war*. Routledge., dostupno na: Tourism and war, (19.04.2020.)
89. Butnaru, G. I., Mironiuc, M., Huian, C., & Haller, A. P. (2018). Analysis of Economic Growth in Tourism Under the Impact of Terrorism and of the Waves of Refugees. *Amfiteatru Economic*, *20*(12), 885-904., dostupno na: https://www.ceeol.com/search/article-detail?id=708522, (27.06.2020.)
90. Buultjens, J. W., Ratnayake, I., & Gnanapala, W. A. C. (2016). Post-Conflict tourism development in Sri Lanka: implications for building resilience. *Current Issues in Tourism*, *19*(4), 355-372., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500.2014.1002760, (20.07.2020.)
91. Callaway, R. L., & Harrelson-Stephens, J. (2006). Toward a theory of terrorism: Human security as a determinant of terrorism. *Studies in Conflict & Terrorism*, *29*(8), 773-796., dostupno na: https://www.tandfonline.com/doi/full/10.1080/10576100600701974A?casa_token=QWTmRmyyPaUAAAAA%3AWlUSjZnRZJcQnXlvFdwHwNQBbVV9dpl2bkUGMN4gSSuAbWZfM8xP69wRRHULKXb5zpaBhrj2sPMNlQ, (14.04.2020.)
92. Camitz, M., & Liljeros, F. (2006). The effect of travel restrictions on the spread of a moderately contagious disease. *BMC medicine*, *4*(1), 32., dostupno na: https://link.springer.com/article/10.1186/1741-7015-4-32, (01.08.2020.)
93. Campos, N. F., & Gassebner, M. (2009). International terrorism, political instability and the escalation effect., dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1372546, (10.07.2020.)
94. Candela, G., & Figini, P. (2012). The economics of tourism destinations. In *The economics of tourism destinations* (pp. 73-130). Springer, Berlin, Heidelberg., dostupno na: https://link.springer.com/chapter/10.1007/978-3-642-20874-4_4, (07.04.2020.)
95. Canova, F., & Ciccarelli, M. (2013). *Panel Vector Autoregressive Models: A Survey✩ The views expressed in this article are those of the authors and do not necessarily reflect those of the ECB or the Eurosystem*. Emerald Group Publishing Limited., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/S0731-9053(2013)0000031006/full/html, (04.03.2022.)

96. Carrigan, A. (2014). Dark tourism and postcolonial studies: Critical intersections. *Postcolonial Studies*, *17*(3), 236-250., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13688790.2014.993425?journalCode=cpcs20, (23.07.2020.)
97. Causevic, S., & Lynch, P. (2013). Political (in) stability and its influence on tourism development. *Tourism Management*, *34*, 145-157., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517712000829, (11.07.2020.)
98. Cavallo, E., Galiani, S., Noy, I., & Pantano, J. (2013). Catastrophic natural disasters and economic growth. *Review of Economics and Statistics*, *95*(5), 1549-1561., dostupno na: https://www.mitpressjournals.org/doi/abs/10.1162/REST_a_00413, (27.04.2020.)
99. Cavallo, E., Powell, A., & Becerra, O. (2010). Estimating the direct economic damages of the earthquake in Haiti. *The Economic Journal*, *120*(546), F298-F312., dostupno na: https://academic.oup.com/ej/article-abstract/120/546/F298/5089603, (01.08.2020.)
100. Chaisumpunsakul, W., & Pholphirul, P. (2018). Does international trade promote international tourism demand? Evidence from Thailand's trading partners. *Kasetsart Journal of Social Sciences*, *39*(3), 393-400., dostupno na: https://www.sciencedirect.com/science/article/pii/S2452315116301448, (22.06.2020.)
101. Chan, F., Lim, C., & McAleer, M. (2005). Modelling multivariate international tourism demand and volatility. *Tourism Management*, *26*(3), 459-471., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517704000408?casa_token=wbwK_ct3MIMAAAAA:m_kJLVo6So7Locsqe5AelJ9KebYio6RjciMHENXXpoAzcYXIWbLG_C3BxKx_bZMjd9PClbkEnws, (13.07.2020.)
102. Chang, C. L., & McAleer, M. (2012). Aggregation, heterogeneous autoregression and volatility of daily international tourist arrivals and exchange rates. *The Japanese Economic Review*, *63*(3), 397-419., dostupno na: https://link.springer.com/article/10.1111/j.1468-5876.2011.00563.x, (06.08.2020.)
103. Chang, C. L., Hsu, H. K., & McAleer, M. (2013). Is small beautiful? Size effects of volatility spillovers for firm performance and exchange rates in tourism. *The North American Journal of Economics and Finance*, *26*, 519-534., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S106294081300034X, (07.08.2020.)
104. Chang, C. L., Khamkaew, T., Tansuchat, R., & McAleer, M. (2011). Interdependence of international tourism demand and volatility in leading ASEAN destinations. *Tourism Economics*, *17*(3), 481-507., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/te.2011.0046, (01.08.2020.)
105. Chang, C., & Zeng, Y. Y. (2011). Impact of terrorism on hospitality stocks and the role of investor sentiment. *Cornell Hospitality Quarterly*, *52*(2), 165-175., dostupno: https://journals.sagepub.com/doi/abs/10.1177/1938965510392915, (30.06.2020.)
106. Chang, K. L., & Chang, J. C. D. (2020). Dynamic Dependence Between US Inbound Visits and Exchange Rate. *Journal of Hospitality & Tourism Research*, 1096348020913084., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1096348020913084, (07.08.2020.)
107. Chao, C. C., Lu, L. J., Lai, C. C., Hu, S. W., & Wang, V. (2013). Devaluation, pass-through and foreign reserves dynamics in a tourism economy. *Economic Modelling*, *30*, 456-461., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0264999312003252, (06.08.2020.)
108. Chatziantoniou, I., Filis, G., Eeckels, B., & Apostolakis, A. (2013). Oil prices, tourism income and economic growth: A structural VAR approach for European Mediterranean

countries. *Tourism Management*, *36*, 331-341., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517712001926, (10.08.2020.)

109. Chen, C. C., Lai, Y. H. R., Petrick, J. F., & Lin, Y. H. (2016). Tourism between divided nations: An examination of stereotyping on destination image. *Tourism Management*, *55*, 25-36., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517716300115, (13.07.2020.)

110. Chen, C. M. (2010). Role of tourism in connecting Taiwan and China: Assessing tourists' perceptions of the Kinmen–Xiamen links. *Tourism Management*, *31*(3), 421-424., dostupno na: https://www.sciencedirect.com/science/article/pii/S026151770900083 1?casa_token=dBbgwOoz9acAAAAA:fq_gYMC6OW6jlpcxOtnimei91QQrB9OlvZM1vEqJQh6t7T9KbWP0NvmiUHAEyNy6Q7yu0EaYXjI, (13.07.2020.)

111. Chen, N., Qiao, G. H., & Liu, L. (2009). Tourism association studies risk perception and outbound tourists travel preferences *Tourists in Beijing. Geography, 6, 97–102*

112. Chen, Y. Q., & Zhang, H. (2012). Investigation of sports tourism visitors risk perception and coping behavior. *Journal of Hebei Institute of Physical Education*, *26*(3), 38-43.

113. Chiu, S. P., & Lin, S. Y. (2010). A study on myth about tourism crime victim: An example of Taiwan tourists. *Police Science Bimonthly, 40(4), 201-218.*

114. Chiu, Y. B., & Yeh, L. T. (2017). The threshold effects of the tourism-led growth hypothesis: Evidence from a cross-sectional model. *Journal of Travel Research*, *56*(5), 625-637., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287516650938, (10.08.2020.)

115. Cho, M. (2007). A re-examination of tourism and peace: The case of the Mt. Gumgang tourism development on the Korean Peninsula. *Tourism Management*, *28*(2), 556-569., dostupno na: https://www.sciencedirect.com/science/article/pii/S026151770600074 4?casa_token=uDk22ydnd9wAAAAA:MI3094XehGVPuerjP0Tj9lVXU2Y55kmhsk__iPqvarTvkflzLRFEjOzNUIfjr2s6C4DEnhQCDwM, (13.07.2020.)

116. Clements, M. A., & Georgiou, A. (1998). The impact of political instability on a fragile tourism product. *Tourism Management*, *19*(3), 283-288., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517798000120, (11.07.2020.)

117. Coffman, M., & Noy, I. (2012). Hurricane Iniki: measuring the long-term economic impact of a natural disaster using synthetic control. *Environment and Development Economics*, *17*(2), 187-205., dostupno na: https://www.jstor.org/stable/26265508, (01.08.2020.)

118. Cohen, E. (1974). Who is a tourist?: A conceptual clarification. *The sociological review*, *22*(4), 527-555., dostupno na: https://journals.sagepub.com/doi/abs/10.1111/j.1467-954X.1974.tb00507.x?journalCode=sora, (09.04.2020.)

119. Cohen, E. (1979). A phenomenology of tourist experiences. *Sociology*, *13*(2), 179-201., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/003803857901300203, (07.04.2020.)

120. Cohen-Hattab, K. (2004). Historical research and tourism analysis: the case of the tourist-historic city of Jerusalem. *Tourism Geographies*, *6*(3), 279-302., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/1461668042000249629, (21.07.2020.)

121. Collymore, J. (2011). Disaster management in the Caribbean: Perspectives on institutional capacity reform and development. *Environmental Hazards*, *10*(1), 6-22.,

dostupno na: https://www.tandfonline.com/doi/abs/10.3763/ehaz.2011.0002, (01.08.2020.)

122. Concepcion, S., Digal, L., Guiam, R., De La Rosa, R., & Stankovitch, M. (2003, December). Breaking the links between economics and conflict in Mindanao. In *Waging Peace'Conference, Manila*., dostupno na: https://pdfs.semanticscholar.org/82fb/a4fec90db1d599dd44b1a37f40b75cde595f.pdf, (29.06.2020.)
123. Connolly, C., Keil, R., & Ali, S. H. (2020). Extended urbanisation and the spatialities of infectious disease: Demographic change, infrastructure and governance. *Urban Studies*, 0042098020910873., https://journals.sagepub.com/doi/full/10.1177/0042098020910873, (04.06.2020.)
124. Conway, D., & Timms, B. F. (2010). Re-branding alternative tourism in the Caribbean: The case for 'slow tourism'. *Tourism and Hospitality Research*, *10*(4), 329-344., dostupno na: https://journals.sagepub.com/doi/abs/10.1057/thr.2010.12, (23.07.2020.)
125. Cooper, C. (2008). *Tourism: Principles and practice*. Pearson education., dostupan na: Tourism: Principles and practice. Pearson education, (10.04.2020.)
126. Cooper, M. (2006). The Pacific War battlefields: tourist attractions or war memorials?. *International Journal of Tourism Research*, *8*(3), 213-222., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.566, (21.07.2020.)
127. Corbet, S., O'Connell, J. F., Efthymiou, M., Guiomard, C., & Lucey, B. (2019). The impact of terrorism on European tourism. *Annals of Tourism Research*, *75*, 1-17., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0160738318301440, (07.07.2020.)
128. Coshall, J. T. (2003). The threat of terrorism as an intervention on international travel flows. *Journal of Travel Research*, *42*(1), 4-12., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287503253901, (30.06.2020.)
129. Coshall, J. T. (2009). Combining volatility and smoothing forecasts of UK demand for international tourism. *Tourism Management*, *30*(4), 495-511., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517708001520?casa_token=TUjtdC-BU40AAAAA:ehQZ1-HA2Eav5Wn-8Yg8IclQTy3Ps8mTSi5cy8GbzE9DtuMbUUW9F4E9tVNtxQoK9xFW6zaTZPw, (13.07.2020.)
130. Crawley, H., & Skleparis, D. (2018). Refugees, migrants, neither, both: Categorical fetishism and the politics of bounding in Europe's 'migration crisis'. *Journal of Ethnic and Migration Studies*, *44*(1), 48-64., dostupno na: https://www.tandfonline.com/doi/full/10.1080/1369183X.2017.1348224, (21.04.2020.)
131. Crenshaw, M. (1981). The causes of terrorism. *Comparative politics*, *13*(4), 379-399., dostupno na: https://www.jstor.org/stable/421717?casa_token=asUj4up3h5YAAAAA:UW3plkTK3ntYIQpG46rQeQrT2xXh2c22Af9chr_x68LqzSK3ddPbmWWzNmkQwlaF6Nf4tznnQMI56LERJfv5szjf5JkTZDM7R-pMhlA1TPsz27YzylWJ&seq=1#metadata_info_tab_contents, (14.04.2020.)
132. Croes, R. R., & Vanegas Sr, M. (2005). An econometric study of tourist arrivals in Aruba and its implications. *Tourism management*, *26*(6), 879-890., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517704001244?casa_token=4jlXjxZyLeIAAAAA:fduFGKS9QbWd4w5k_RQXJbx9LisQarKAbOrJiIEJay1ZTKMprvwFC-HwyikB56IF5gKIZWg, (06.08.2020.)

133. Crompton, J. L. (1979). Motivations for pleasure vacation. *Annals of tourism research*, *6*(4), 408-424., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/0160738379900045, (10.04.2020.)
134. Crompton, J. L., & McKay, S. L. (1997). Motives of visitors attending festival events. *Annals of tourism research*, *24*(2), 425-439., dostupno na: http://agrilife.org/cromptonrpts/files/2011/06/Full-Text52.pdf, (10.04.2020.)
135. Crosby, A. W. (2004). *Ecological imperialism: the biological expansion of Europe, 900-1900*. Cambridge University Press., dostupno na: https://books.google.si/books?hl=hr&lr=&id=Phtqa_3tNykC&oi=fnd&pg=PR13&dq=Crosby,+A.+W.+(2004).+Ecological+imperialism:+The+biological+expansion+of+Europe,+900-1900.+(2nd+ed.).+Cambridge+University+Press.&ots=9WYNuR0qYM&sig=s8nDLJsb0mxoSY9pzm5dpeVunVQ&redir_esc=y#v=onepage&q&f=false, (04.06.2020.)
136. Crouch, G. I. (1994a). The study of international tourism demand: A survey of practice. *Journal of Travel research*, *32*(4), 41-55., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/004728759403200408, (06.08.2020.)
137. Crouch, G. I. (1994b). The study of international tourism demand: A review of findings. *Journal of Travel research*, *33*(1), 12-23., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/004728759403300102, (06.08.2020.)
138. Cui, F., Liu, Y., Chang, Y., Duan, J., & Li, J. (2016). An overview of tourism risk perception. *Natural Hazards*, *82*(1), 643-658., dostupno na: https://link.springer.com/article/10.1007/s11069-016-2208-1, (16.06.2020.)
139. Currie, D. M., Skare, M., & Loncar, J. (2004). The impact of War on Tourism: the case of Croatia. In *Conference on Tourism Economics, Palma de Mallorca*., dostupno na: https://www.researchgate.net/profile/Marinko_Skare2/publication/228423759_The_impact_of_War_on_Tourism_the_case_of_Croatia/links/00b7d5228532ac12e0000000.pdf, (17.07.2020.)
140. D'Amore, L. J., and T. E. Anuza (1986) International Terrorism: Implications and Challenge for Global Tourism. *Business Quarterly* (November):20-29., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/0160738388901296?via%3Dihub, (13.04.2020.)
141. Damm, A., Greuell, W., Landgren, O., & Prettenthaler, F. (2017). Impacts of+ 2 C global warming on winter tourism demand in Europe. *Climate Services*, *7*, 31-46., dostupno na: https://www.sciencedirect.com/science/article/pii/S2405880715300297, (28.07.2020.)
142. Damodar N, Gujarati. (2004). Basic econometrics.
143. Daniels, M., Dieke, P., & Barrow, M. (2013). 18 Civil war tourism Perspectives from Manassas National Battlefield Park. *Tourism and War*, 232., dostupno na: https://books.google.si/books?hl=hr&lr=&id=wDCKEW_3ujgC&oi=fnd&pg=PA232&dq=Daniels,+2013+war+tourism&ots=Mr69eHBo5o&sig=9hVtn3OjcxRIhbuDKjnUnfM4L4c&redir_esc=y#v=onepage&q=Daniels%2C%202013%20war%20tourism&f=false, (21.07.2020.)
144. Dann, G. M. (1981). Tourist motivation an appraisal. *Annals of tourism research*, *8*(2), 187-219., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/0160738381900827, (10.04.2020.)
145. Dann, G. M. (1996). Tourists' images of a destination-an alternative analysis. *Journal of Travel & Tourism Marketing*, *5*(1-2), 41-55., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J073v05n01_04, (10.04.2020.)

146. de Almeida, A. M. M., & Machado, L. P. (2019). Madeira island: Tourism, natural disasters and destination image. In *Climate Change and Global Development* (pp. 285-301). Springer, Cham., dostupno na: https://link.springer.com/chapter/10.1007/978-3-030-02662-2_14, (30.07.2020.)
147. De Vita, G. (2014). The long-run impact of exchange rate regimes on international tourism flows. *Tourism Management*, *45*, 226-233., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517714000946, (08.06.2020.)
148. Degraff, J. V., James, A., & Breheny, P. (2010). The formation and persistence of the Matthieu landslide-dam lake, Dominica, WI. *Environmental and Engineering Geoscience*, *16*(2), 73-89., dostupno na: https://pubs.geoscienceworld.org/aeg/eeg/article-abstract/16/2/73/60381/The-Formation-and-Persistence-of-the-Matthieu?redirectedFrom=fulltext, (01.08.2020.)
149. Dibeh, G., Fakih, A., & Marrouch, W. (2020). Tourism–growth nexus under duress: Lebanon during the Syrian crisis. *Tourism Economics*, *26*(3), 353-370., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1354816619836338, (15.07.2020.)
150. Dogru, T., McGinley, S., & Kim, W. G. (2020). The effect of hotel investments on employment in the tourism, leisure and hospitality industries. *International Journal of Contemporary Hospitality Management*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/IJCHM-11-2019-0913/full/html, (22.06.2020.)
151. Dragičević, D., Radić, M. N., & Grbić, L. (2018, January). Terrorism as security challenge in tourism development. In *24th Biennial International Congress Tourism and Hospitality Industry 2018: Trends and Challenges*., dostupno na: https://bib.irb.hr/datoteka/953151.6_Dragicevic_NiksicRadic_Grbic.pdf, (30.06.2020.)
152. Dragičević, D., Radić, M. N., & Herman, S. (2019). MIGRATION IMPACT AS A POSITIVE CHANGE IN TOURISM DEMAND. *Tourism in South East Europe...*, *5*, 205-217., dostupno na: https://pdfs.semanticscholar.org/4ef8/23f6582af3586745e43758a069435f98b8bf.pdf, (24.07.2020.)
153. Drakos, K., & Kutan, A. M. (2003). Regional effects of terrorism on tourism in three Mediterranean countries. *Journal of Conflict Resolution*, *47*(5), 621-641., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0022002703258198, (27.06.2020.)
154. Drew, M., Woodside, A., & Uriely, N. (2009). Deconstructing tourist typologies: the case of backpacking. *International Journal of Culture, Tourism and Hospitality Research*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/17506180910994523/full/html, (07.04.2020.)
155. Dunkley, R., Morgan, N., & Westwood, S. (2011). Visiting the trenches: Exploring meanings and motivations in battlefield tourism. *Tourism management*, *32*(4), 860-868., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517710001585?casa_token=QX_Ct7MSNa0AAAAA:MYJWbhqd2w2pj4mixqsFr0gYQ0fEd9JIANfBDYwZOmhHWMGHm8gEPNuoU6ouILmtx7XQnpTp7Ls, (23.07.2020.)
156. Durbarry, R. (2004). Tourism and economic growth: the case of Mauritius. *Tourism Economics*, *10*(4), 389-401., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/0000000042430962, (22.06.2020.)
157. Durko, A., & Petrick, J. (2016). The Nutella project: an education initiative to suggest tourism as a means to peace between the United States and Afghanistan. *Journal of*

Travel Research, *55*(8), 1081-1093., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287515617300, (13.07.2020.)

158. Dürr, E., & Jaffe, R. (2012). Theorizing slum tourism: Performing, negotiating and transforming inequality. *European Review of Latin American and Caribbean Studies/Revista Europea de Estudios Latinoamericanos y del Caribe*, 113-123., dostupno na: https://www.jstor.org/stable/23294474, (23.07.2020.)
159. Dwyer, L., Edwards, D. C., Mistilis, N., Roman, C., Scott, N., & Cooper, C. (2008). Megatrends underpinning tourism to 2020: analysis of key drivers for change., dostupno na: https://opus.lib.uts.edu.au/handle/10453/17701, (12.06.2020.)
160. Dwyer, L., Edwards, D., Mistilis, N., Roman, C., & Scott, N. (2009). Destination and enterprise management for a tourism future. *Tourism management*, *30*(1), 63-74., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517708000745?casa_token=s2YcXmmOX3YAAAAA:fNXSWSaX2enIy8Q3Lgq22x61pS6lORLJzOVQuIXWxuloFGPxDt0Fh2JoXTHafIwYlkdO25SKDw, (12.06.2020.)
161. Dwyer, L., Seetaram, N., Forsyth, P., & King, B. (2014). Is the migration-tourism relationship only about VFR?. *Annals of tourism research*, *46*, 130-143., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S016073831400036X, (24.07.2020.)
162. Edgell, D. L., Allen, M. D., Smith, G., & Swanson, J. (2008). *Tourism policy and planning: Yesterday, today, and tomorrow*. Routledge., dostupno na: https://books.google.si/books?hl=hr&lr=&id=JbwJBAAAQBAJ&oi=fnd&pg=PP1&dq=Edgell,+D.,+L.,+,+Del+Maestro-Allen,+M.,+Smith,+G.+and+Swanson,+J.,+2008.+Tourism+policy+and+planning:+yesterday,+today+and+tomorrow,+Butterworth-Heinemann.+&ots=LDoIxBfXH9&sig=FiVjTG7J9HL21YXjn-bYIKANbkw&redir_esc=y#v=onepage&q&f=false, (11.07.2020.)
163. Enders, W., & Hoover, G. A. (2012). The nonlinear relationship between terrorism and poverty. *American Economic Review*, *102*(3), 267-72., dostupno na: https://www.aeaweb.org/articles?id=10.1257/aer.102.3.267, (10.07.2020.)
164. Enders, W., & Sandler, T. (1991). Causality between transnational terrorism and tourism: The case of Spain. *Studies in Conflict & Terrorism*, *14*(1), 49-58., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/10576109108435856, (28.06.2020.)
165. Enders, W., & Sandler, T. (2002). Patterns of transnational terrorism, 1970–1999: Alternative time-series estimates. *International Studies Quarterly*, *46*(2), 145-165., dostupno na: https://academic.oup.com/isq/article-abstract/46/2/145/1792587, (13.04.2020.)
166. Enders, W., Sandler, T., & Parise, G. F. (1992). An econometric analysis of the impact of terrorism on tourism. *Kyklos*, *45*(4), 531-554., dostupno na: https://www.cabdirect.org/cabdirect/abstract/19931803541, (08.07.2020.)
167. Engene, J. O. (2011). The Extreme Right in West European Terrorism. In *Conference on The Extreme Right in Norway* (p. 3)., dostupno na: https://www.ps.au.dk/fileadmin/site_files/filer_statskundskab/subsites/cir/pdf-filer/The_Extreme_Right_in_West_European_TerrorismJAN_OSKAR_ENGENE.pdf , (27.06.2020.)
168. Enz, C. A., & Canina, L. (2002). The best of times, the worst of times: Differences in hotel performance following 9/11. *Cornell Hotel and Restaurant Administration Quarterly*, *43*(5), 41-52., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0010880402435004?journalCode=cqxa, (30.06.2020.)

169. Etzo, I., Massidda, C., & Piras, R. (2014). Migration and outbound tourism: Evidence from Italy. *Annals of Tourism Research*, *48*, 235-249., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0160738314000899, (28.07.2020.)
170. Fahey, S. (2010). *State instability and terrorism*. MARYLAND UNIV COLLEGE PARK., dostupno na: https://drum.lib.umd.edu/handle/1903/10789, (10.07.2020.)
171. Fauci, A. S., & Morens, D. M. (2012). The perpetual challenge of infectious diseases. *New England Journal of Medicine*, *366*(5), 454-461., dostupno na: https://www.nejm.org/doi/full/10.1056/nejmra1108296, (02.08.2020.)
172. Fayissa, B., Nsiah, C., & Tadasse, B. (2008). Impact of tourism on economic growth and development in Africa. *Tourism Economics*, *14*(4), 807-818., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/000000008786440229, (23.06.2020.)
173. Feng, K., & Page, S. J. (2000). An exploratory study of the tourism, migration–immigration nexus: Travel experiences of Chinese residents in New Zealand. *Current Issues in tourism*, *3*(3), 246-281., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500008667875, (10.04.2020.)
174. Feridun, M. (2011). Impact of terrorism on tourism in Turkey: empirical evidence from Turkey. *Applied Economics*, *43*(24), 3349-3354., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/00036841003636268, (29.06.2020.)
175. Fischer, A. M. (2007). Measuring Income Elasticity for Swiss Money Demand: What do the cantons say about financial innovation?. *European Economic Review*, *51*(7), 1641-1660., dostupno na: https://www.sciencedirect.com/science/article/pii/S0014292106001590?casa_token=lB-NbjY2JjcAAAAA:xDgQEzknhZJ8fOrUip0laKiBBVUeG4PVZ3MgbYT_8_ROiNNXyFo4lnyb9EUafiELqRwkXQ7EQKk, (24.07.2020.)
176. Fleischer, A., & Buccola, S. (2002). War, terror, and the tourism market in Israel. *Applied Economics*, *34*(11), 1335-1343., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/00036840110099252, (21.07.2020.)
177. Fletcher, J., & Morakabati, Y. (2008). Tourism activity, terrorism and political instability within the Commonwealth: The cases of Fiji and Kenya. *International Journal of Tourism Research*, *10*(6), 537-556., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.699, (13.07.2020.)
178. Floyd, M. F., & Pennington-Gray, L. (2004). Profiling risk perceptions of tourists. *Annals of Tourism Research*, *31*(4), 1051-1054., dostupno na: Profiling risk perceptions of tourists, (14.06.2020.)
179. Floyd, M. F., Gibson, H., Pennington-Gray, L., & Thapa, B. (2004). The effect of risk perceptions on intentions to travel in the aftermath of September 11, 2001. *Journal of Travel & Tourism Marketing*, *15*(2-3), 19-38., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J073v15n02_02, (12.06.2020.)
180. Floyd, M., Pennington-Gray, L., & Thapa, B. (2003). The Effects of Risk Perception on Intention to Travel in the Aftermath of September 11, 2001. *Safety and Security in Tourism: relationships. Management and Marketing.*
181. Forbes, D. L., James, T. S., Sutherland, M., & Nichols, S. E. (2013). Physical basis of coastal adaptation on tropical small islands. *Sustainability Science*, *8*(3), 327-344., dostupno na: https://link.springer.com/article/10.1007%252Fs11625-013-0218-4, (01.08.2020.)
182. Formica, S., & Uysal, M. (1998). Market segmentation of an international cultural-historical event in Italy. *Journal of travel research*, *36*(4), 16-24., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/004728759803600402, (10.04.2020.)

183. Foster, H. D. (2012). *Disaster planning: The preservation of life and property*. Springer Science & Business Media., dostupno na: https://books.google.si/books?hl=hr&lr=&id=SnMoBgAAQBAJ&oi=fnd&pg=PT11&dq=H.+D.+Foster,+Disaster+Planning:+The+Preservation+of+Life+and+Property+(New+York:+Springer+Verlag,+1980)%3B+Healy,+footnote+3+above%3B+Laube+and+Murphy,+footnote+3+above.+&ots=fXwL_X19FO&sig=CDZQgJ-smJ3tcN1EnAzl3iszB1Q&redir_esc=y#v=onepage&q&f=false, (27.04.2020.)
184. Frey, B. S., Luechinger, S., & Stutzer, A. (2007). Calculating tragedy: Assessing the costs of terrorism. *Journal of Economic Surveys*, *21*(1), 1-24., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1467-6419.2007.00505.x, (10.07.2020.)
185. Freyer, W. A. L. T. E. R., & Schroder, A. (2007). Tourism and terrorism: an analytical framework with special focus on the media. *B. Laws, & B. Prideaux, Crisis Management in Tourism. Oxon: CAB International*, 129-141., dostupno na: https://books.google.hr/books?hl=hr&lr=&id=8fiUSRATLIUC&oi=fnd&pg=PA129&dq=Freyer,+W.,+and+A.+Schroder.+2007.+%E2%80%9CTourism+and+Terrorism:+An+Analytical+Framework+with+Special+Focus+on+the+Media.%E2%80%9D+In+Crisis+Management+in+Tourism,+edited+by+E.+Laws,+B.+Prideaux,+and+K.+S.+Chon,+129%E2%80%9341.+Oxon:+CAB+International&ots=xmkuGi26hr&sig=iRLh7JFY5QzXWkXbg8BcQ_SFeNs&redir_esc=y#v=onepage&q&f=false, (01.07.2020)
186. Fridgin, J, D, (1991),Dimensions of Tourism, Educational Institute of the American Hotel and Motel Association, East Lansing MI
187. Frisby, E. (2003). Communicating in a crisis: The British Tourist Authority's responses to the foot-and-mouth outbreak and 11th September, 2001. *Journal of Vacation Marketing*, *9*(1), 89-100., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/135676670200900107, (01.08.2020.)
188. Fuchs, G., Uriely, N., Reichel, A., & Maoz, D. (2013). Vacationing in a terror-stricken destination: Tourists' risk perceptions and rationalizations. *Journal of Travel Research*, *52*(2), 182-191., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287512458833, (30.06.2020.)
189. Fyall, A., Prideaux, B., & Timothy, D. J. (2006). War and tourism. *International Journal of Tourism Research*, *8*(3), 153-246., dostupno na: https://www.cabdirect.org/cabdirect/abstract/20063174641, (17.07.2020.)
190. Galbraith, J. K. (2012). Who are these economists, anyway?. In *Contributions in Stock-flow Modeling* (pp. 63-75). Palgrave Macmillan, London., dostupno na: https://link.springer.com/chapter/10.1057%2F9780230367357_4, (11.06.2020.)
191. Gan, Y. (2015). *An empirical analysis of the influence of exchange rate and prices on tourism demand* (Doctoral dissertation)., dostupno na: https://repositorio.iscte-iul.pt/handle/10071/8971, (08.06.2020.)
192. Garin-Munoz, T., & Amaral, T. P. (2000). An econometric model for international tourism flows to Spain. *Applied Economics Letters*, *7*(8), 525-529., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13504850050033319, 07.08.2020.)
193. Gassebner, M., & Luechinger, S. (2011). Lock, stock, and barrel: A comprehensive assessment of the determinants of terror. *Public Choice*, *149*(3-4), 235., dostupno na: https://link.springer.com/article/10.1007/s11127-011-9873-0, (10.07.2020.)
194. Gelbman, A., & Timothy, D. J. (2010). From hostile boundaries to tourist attractions. *Current issues in tourism*, *13*(3), 239-259., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500903033278, (21.07.2020.)

195. Genç, M. (2013). Migration and tourism flows to New Zealand. In *Quantitative methods in tourism economics* (pp. 113-126). Physica, Heidelberg., dostupno na: https://link.springer.com/chapter/10.1007/978-3-7908-2879-5_7, (24.07.2020.)
196. Gilbert, J. (2011). After individualism: The unfinished business of New Times. *Public Policy Research*, *18*(3), 158-165., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1744-540X.2011.00658.x, (23.07.2020.)
197. Glaesser, D. (2006). *Crisis management in the tourism industry*. Routledge., dostupno na: https://books.google.hr/books?hl=hr&lr=&id=bdwZ6lDZLDEC&oi=fnd&pg=PP1&ots=3kT5zHYgOi&sig=fsDSF_UNdcSv09UkCp1F92rh3R8&redir_esc=y#v=onepage&q&f=false, (01.08.2020.)
198. Gnangnon, S. K. (2020). Impact of international tourism receipts on public revenue in developed and developing countries. *Tourism Review*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/TR-07-2018-0090/full/html, (22.06.2020.)
199. Goh, C. (2012). Exploring impact of climate on tourism demand. *Annals of tourism research*, *39*(4), 1859-1883., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0160738312000837, (28.07.2020.)
200. Goldman, O. S., & Neubauer-Shani, M. (2017). Does international tourism affect transnational terrorism?. *Journal of Travel Research*, *56*(4), 451-467., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287516649059, (06.07.2020.)
201. Goldstein, S. (1978). Circulation in the context of total mobility in Southeast Asia., dostupno na: https://scholarspace.manoa.hawaii.edu/handle/10125/23009, (20.04.2020.)
202. Górny, A., & Kindler, M. (2016). The temporary nature of Ukrainian migration: Definitions, determinants and consequences. In *Ukrainian Migration to the European Union* (pp. 91-112). Springer, Cham.,dostupno na: http://library.oapen.org/bitstream/id/bceafb82-b66d-4210-9c30-74bb61a373b5/1002061.pdf#page=96, (20.04.2020.)
203. Gössling, S., Scott, D., & Hall, C. M. (2020). Pandemics, tourism and global change: a rapid assessment of COVID-19. *Journal of Sustainable Tourism*, 1-20., dostupno na: https://www.tandfonline.com/doi/full/10.1080/09669582.2020.1758708, (04.06.2020.)
204. Gray, J. M., & Wilson, M. A. (2009). The relative risk perception of travel hazards. *Environment and Behavior*, *41*(2), 185-204., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0013916507311898, (13.06.2020.)
205. Greenbaum, R. T., & Hultquist, A. (2006). The economic impact of terrorist incidents on the Italian hospitality industry. *Urban Affairs Review*, *42*(1), 113-130., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1078087406290116, (13.07.2020.)
206. Gregorova, M., Kalousis, A., & Marchand-Maillet, S. (2015). Learning coherent Granger-causality in panel vector autoregressive models. In *Proceedings of the Demand Forecasting Workshop of the 32nd International Conference on Machine Learning* (No. CONFERENCE). ICML., dostupno na: http://cui.unige.ch/~kalousis/papers/2015/GregorovaKalousisMarchandMaillet-ICML2015-WorkshopOnDemandForecasting.pdf, (14.03.2022.)
207. Griffin, T. (2013). Research note: A content analysis of articles on visiting friends and relatives tourism, 1990–2010. *Journal of Hospitality Marketing & Management*, *22*(7), 781-802., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/19368623.2012.708960, (24.07.2020.)

208. Grossmann, A., Love, I., & Orlov, A. G. (2014). The dynamics of exchange rate volatility: A panel VAR approach. *Journal of International Financial Markets, Institutions and Money*, *33*, 1-27., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S1042443114000924, (04.03.2022.)
209. Gul, K., Asik, N. A., & Gurbuz, A. K. (2014). The effect of global economic crisis on Turkish tourism demand and a review for the period 2003-2013. *Journal of World Economic Research*, *3*(6-1), 22-32., dostupno na: https://d1wqtxts1xzle7.cloudfront.net/39426555/KG-Kriz.pdf?1445870804=&response-content-disposition=inline%3B+filename%3DThe_effect_of_global_economic_crisis_on.pdf&Expires=1597391471&Signature=R5q9Z5BObinVYdAY2lwGi2Yag-rYw-wN8FikV3gS2jIS5DYjc~FNsXptNPMdwJ-Fb0QRcIK6l5Hvy5vMV-SkGScbXqKGAUMzwaXo6Axib4Rs07pd4pnyFL2v6YVInz139KUWbpJ0mN1upAPLEAcLwMRZEpCHpByuoB~mZ53ETr0b5003u-EQeWEAqeDCPqdVOvXyt29VVJeC6eDl3hZiPmrHn0k83rv8Goxy8rlVGDwU5PvBxS8yQV2yL~gZqIVjSRNENAoWf9z04Fco5K2pErHhghe-dQBWLUeA8pVNaPs-~OeFwyRyaYNgZvWyMLeawWFS99zHK93-j6mQ7trfGw__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA, (14.08.2020.)
210. Gunduz, L., & Hatemi-J, A. (2005). Is the tourism-led growth hypothesis valid for Turkey?. *Applied Economics Letters*, *12*(8), 499-504., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13504850500109865, (15.07.2020.)
211. Guo, Y., Kim, S. S., Timothy, D. J., & Wang, K. C. (2006). Tourism and reconciliation between Mainland China and Taiwan. *Tourism Management*, *27*(5), 997-1005., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517705001664?casa_token=0nUGyUejHGwAAAAA:0ear21JLGTPpYMH9CaA7EsXa5DTv5dpJQVuLi-vtSPQFHQuLThFfhCkgjAFc2FTTYjPP8BnRvgE, (13.07.2020.)
212. Gurr, T. R. (1972). The Calculus of Civil Conflict 1. *Journal of social issues*, *28*(1), 27-47., dostupno na: https://spssi.onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-4560.1972.tb00003.x, (17.04.2020.)
213. Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E., & Tatham, R. L. (2014). Pearson new international edition. *Multivariate data analysis, Seventh Edition. Pearson Education Limited Harlow, Essex.*, https://doc1.bibliothek.li/acd/FLMF050541.pdf, (19.09.2021.)
214. Hajibaba, H., Gretzel, U., Leisch, F., & Dolnicar, S. (2015). Crisis-resistant tourists. *Annals of Tourism Research*, *53*, 46-60., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0160738315000511, (11.07.2020.)
215. Hale, J. E., Dulek, R. E., & Hale, D. P. (2005). Crisis response communication challenges: Building theory from qualitative data. *The Journal of Business Communication (1973)*, *42*(2), 112-134., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0021943605274751, (21.06.2020.)
216. Halicioglu, F. (2010). An econometric analysis of the aggregate outbound tourism demand of Turkey. *Tourism Economics*, *16*(1), 83-97., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/000000010790872196, (23.06.2020.)
217. Hall, C. M. (2002). Travel safety, terrorism and the media: The significance of the issue-attention cycle. *Current Issues in Tourism*, *5*(5), 458-466., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500208667935, (13.06.2020.)

218. Hall, C. M. (2019). Constructing sustainable tourism development: The 2030 agenda and the managerial ecology of sustainable tourism. *Journal of Sustainable Tourism*, *27*(7), 1044-1060., https://doi.org/10.1080/09669582.2018.1560456
219. Hallegatte, S., & Przyluski, V. (2010). *The economics of natural disasters: concepts and methods*. The World Bank., dostupno na: https://elibrary.worldbank.org/doi/abs/10.1596/1813-9450-5507, (01.08.2020.)
220. Hamadeh, M., & Bassil, C. (2017). Terrorism, war, and volatility in tourist arrivals: The case of Lebanon. *Tourism Analysis*, *22*(4), 537-550., dostupno na: https://www.ingentaconnect.com/content/cog/ta/2017/00000022/00000004/art00007, (13.07.2020.)
221. Hamilton, J. M., Maddison, D. J., & Tol, R. S. (2005). Climate change and international tourism: a simulation study. *Global environmental change*, *15*(3), 253-266., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0959378004000883, (28.07.2020.)
222. Hannam, K. (2006). Contested representations of war and heritage at the Residency, Lucknow, India. *International Journal of Tourism Research*, *8*(3), 199-212., dostupno na. https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.567, (21.07.2020.)
223. Hansen, L. P. (1982). Large sample properties of generalized method of moments estimators. *Econometrica: Journal of the econometric society*, 1029-1054., dostupno na: https://www.jstor.org/stable/1912775, (03.03.2022.)
224. Harb, A. (2016). Impact of War And Terrorism on Tourism and Hospitality Sector in Lebanon. *Annual of Sofia University" ST. KLIMENT OHRIDSKI*, *109*(2)., dostupno na: file:///C:/Users/Korisnik/Downloads/22_Ann_Tom_109_geography_339-355%20(1).pdf, (17.07.2020.)
225. Hasegawa, M., Murakami, M., Takebayashi, Y., Suzuki, S., & Ohto, H. (2018). Social capital enhanced disaster preparedness and health consultations after the 2011 Great East Japan Earthquake and nuclear power station accident. *International journal of environmental research and public health*, *15*(3), 516., dostupno na: https://www.mdpi.com/1660-4601/15/3/516, (30.07.2020.)
226. Hashimoto, A. (2002). Tourism and sociocultural development issues. *Tourism and development: Concepts and issues*, 202-230., dostupno na: https://www.cabdirect.org/cabdirect/abstract/20023115741, (19.08.2020.)
227. Hassani, H., Ghodsi, M., Huang, X., & Silva, E. S. (2020). Is there a causal relationship between oil prices and tourist arrivals?. *Journal of Applied Statistics*, 1-12., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/02664763.2020.1720625, (11.08.2020.)
228. Hausman, J. A. (1978). Specification tests in econometrics. *Econometrica: Journal of the econometric society*, 1251-1271.
229. Hawkins, D. E. (1982). Tourism policy considerations. *Social and economic impact of tourism on the Asian Pacific Region.*, 158-206., dostupno na: https://www.cabdirect.org/cabdirect/abstract/19841810424, (18.08.2020.)
230. Henderson, J. (2004). Managing the aftermath of terrorism: The Bali bombings, travel advisories and Singapore. *International journal of hospitality & tourism administration*, *4*(2), 17-31., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J149v04n02_02, (13.07.2020.)
231. Henderson, J. C. (2000). War as a tourist attraction: the case of Vietnam. *International Journal of Tourism Research*, *2*(4), 269-280., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/1522-1970(200007/08)2:4%3C269::AID-JTR219%3E3.0.CO;2-A, (17.07.2020.)

232. Hertzog, A. (2012). War Battlefields, tourism and imagination. *Via. Tourism Review*, (1)., dostupno na: https://journals.openedition.org/viatourism/1283, (20.04.2020.)
233. Hiemstra, S., & Wong, K. K. (2002). Factors affecting demand for tourism in Hong Kong. *Journal of Travel & Tourism Marketing*, *13*(1-2), 41-60., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J073v13n01_04, (22.06.2020.)
234. Hitchcock, M., & Darma Putra, I. N. (2005). The Bali bombings: Tourism crisis management and conflict avoidance. *Current Issues in Tourism*, *8*(1), 62-76., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500508668205, (21.07.2020.)
235. Hoffman, B. (2006). *Inside terrorism*. Columbia university press., dostupno na: https://books.google.si/books?hl=hr&lr=&id=_ayrAgAAQBAJ&oi=fnd&pg=PR1&dq=Hoffman,+B.,+2006b.+Inside+Terrorism,+Revised+and+Expanded+Edition+New+York,+Columbia+University+Press&ots=qVbblDrSnY&sig=sY9kgk2_U91LlrHzVj6f5kigcf8&redir_esc=y#v=onepage&q&f=false, (14.04.2020.)
236. Holden, A., & Fennell, D. A. (Eds.). (2012). *The Routledge handbook of tourism and the environment*. Routledge., dostupno na: he Routledge handbook of tourism and the environment, (07.04.2020.)
237. Holtz-Eakin, D., Newey, W., & Rosen, H. S. (1988). Estimating vector autoregressions with panel data. *Econometrica: Journal of the econometric society*, 1371-1395., https://doi.org/10.2307/1913103
238. Hoti, S., McAleer, M., & Shareef, R. (2007). Modelling international tourism and country risk spillovers for Cyprus and Malta. *Tourism Management*, *28*(6), 1472-1484., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517707000258?casa_token=7Dl6pj2Ptc4AAAAA:2bvXPNmk1WwzfJ-MdeVYwg-RorZywaGTrse5LVWg766k4q8INuuEYvAMyY3B_chDb-4RY0hzXQU, (14.08.2020.)
239. Householder, A. S. (1964). The theory of matrices in numerical analysis, Blaisdell Publ. *Co., New York*.
240. Hsiao, C. (2005). Why panel data?. *The Singapore Economic Review*, *50*(02), 143-154.
241. Hsiao, C. (2014). *Analysis of panel data* (No. 54). Cambridge university press.
242. Huang, J. H., & Min, J. C. (2002). Earthquake devastation and recovery in tourism: the Taiwan case. *Tourism Management*, *23*(2), 145-154., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517701000516?casa_token=9JoF4WQsg3IAAAAA:A6IACDiBWm1cs-JREWDBKEm0n8pF36hNj6AcLYbUXqywxPY5TBg0T9LBfmFMR8-WiUq5XYT4, (29.07.2020.)
243. Hung, K. K., Mark, C. K., Yeung, M. P., Chan, E. Y., & Graham, C. A. (2018). The role of the hotel industry in the response to emerging epidemics: a case study of SARS in 2003 and H1N1 swine flu in 2009 in Hong Kong. *Globalization and health*, *14*(1), 117., dostupno na: https://link.springer.com/article/10.1186/s12992-018-0438-6, (02.08.2020.)
244. Hurley, J. A. (1988). The hotels of Rome: Meeting the marketing challenge of terrorism. *Cornell Hotel and Restaurant Administration Quarterly*, *29*(1), 70-79., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/001088048802900119?journalCode=cqxa, (30.06.2020.)
245. Ibarrarán, M. E., Ruth, M., Ahmad, S., & London, M. (2009). Climate change and natural disasters: macroeconomic performance and distributional impacts. *Environment, development and sustainability*, *11*(3), 549-569., dostupno na: https://link.springer.com/article/10.1007/s10668-007-9129-9, (01.08.2020.)

246. Ingram, H., Grieve, D., Ingram, H., Tabari, S., & Watthanakhomprathip, W. (2013). The impact of political instability on tourism: case of Thailand. *Worldwide hospitality and tourism themes*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/17554211311292475/full/html, (17.04.2020.)
247. Insch, A., & Avraham, E. (2014). Managing the reputation of places in crisis. *Place Branding and Public Diplomacy*, *10*(3), 171-173., dostupno na: https://link.springer.com/article/10.1057/pb.2014.18, (01.08.2020.)
248. Ioannides, D., & Apostolopoulos, Y. (1999). Political instability, war, and tourism in Cyprus: Effects, management, and prospects for recovery. *Journal of Travel Research*, *38*(1), 51-56., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/004728759903800111, (21.07.2020.)
249. Irvine, W., & Anderson, A. R. (2006). The impacts of foot and mouth disease on a peripheral tourism area: The role and effect of crisis management. *Journal of Travel & Tourism Marketing*, *19*(2-3), 47-60., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J073v19n02_05, (01.08.2020.)
250. Iso-Ahola , S. E. (1989). Motivation for Leisure. In Jackson E.L. & Burton, T.L. (Eds.). Understanding Leisure and Recreation: Mapping the Past, Charting the Future. State College, PA: Venture Publishing, Inc., 247-271.
251. Iso-Ahola, S. E. (1982). Toward a social psychological theory of tourism motivation: A rejoinder. *Annals of tourism research*, *9*(2), 256-262., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/0160738382900494, (11.04.2020.)
252. Ivanov, S., Gavrilina, M., Webster, C., & Ralko, V. (2017). Impacts of political instability on the tourism industry in Ukraine. *Journal of Policy Research in Tourism, Leisure and Events*, *9*(1), 100-127., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/19407963.2016.1209677, (11.07.2020.)
253. Jackson, R. T. (1990). VFR tourism: is it underestimated?. *Journal of Tourism Studies*, *1*(2), 10-17., dostupno na: https://www.cabdirect.org/cabdirect/abstract/19911896687, (24.07.2020.)
254. Jalkh, N., Bouri, E., Vo, X. V., & Dutta, A. (2020). Hedging the risk of travel and leisure stocks: The role of crude oil. *Tourism Economics*, 1354816620922625., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1354816620922625, (05.06.2020.)
255. Jamal, T., & Lelo, L. (2010). Exploring the conceptual and analytical framing of dark tourism: From darkness to intentionality. In *Tourist Experience* (pp. 49-62). Routledge., dostupno na: https://books.google.si/books?hl=hr&lr=&id=h6CLAgAAQBAJ&oi=fnd&pg=PA29&dq=Jamal,+T.,+%26+Lelo,+L.+(2010).+Examining+the+conceptual+and+analytical+framing+of+dark+tourism:+From+darkness+to+intentionality.+In+R.+Sharpley,+%26+P.+Stone+(Eds.),+Tourist+experiences:+Contemporary+perspectives+(pp.+29%E2%80%9342).+Routledge.&ots=TmXrPgfybi&sig=RxYyT1WJyzYStzDDC9JCqO078JU&redir_esc=y#v=onepage&q&f=false, (23.07.2020.)
256. Jeřábek, T. (2019). The Effects of Selected Macroeconomic Variables on Tourism Demand for the South Moravian Region of the Czech Republic from Germany, Poland, Austria, and Slovakia. *Comparative Economic Research. Central and Eastern Europe*, *22*(3), 25-43., dostupno na: https://www.ceeol.com/search/article-detail?id=788502, (11.08.2020.)
257. Jochmans, K., & Verardi, V. (2020). A portmanteau test for serial correlation in a linear panel model. *The Stata Journal*, *20*(1), 149-161., dostupno na: https://journals.sagepub.com/doi/pdf/10.1177/1536867X20909695, (23.09.2021.)

258. Jongman, A. J. (2017). *Political terrorism: A new guide to actors, authors, concepts, data bases, theories, and literature*. Routledge., dostupno na: Political terrorism: A new guide to actors, authors, concepts, data bases, dostupno na: (13.04.2020.)
259. Jovančević, R., Arčabić, V., & Globan, T. (2012). Prijenos poslovnih ciklusa zemalja Europske unije na Republiku Hrvatsku. *Ekonomski pregled*, *63*(1-2), 3-21., dostupno na: https://hrcak.srce.hr/78927, (07.03.2022.)
260. Kale, V. S., Ely, L. L., Enzel, Y., & Baker, V. R. (1994). Geomorphic and hydrologic aspects of monsoon floods on the Narmada and Tapi Rivers in central India. In *Geomorphology and Natural Hazards* (pp. 157-168). Elsevier., dostupno na: https://www.sciencedirect.com/science/article/pii/B9780444820129500153, (02.05.2020.)
261. Kale, V. S., Hire, P., & Baker, V. R. (1997). Flood hydrology and geomorphology of monsoon-dominated rivers: the Indian Peninsula. *Water international*, *22*(4), 259-265., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/02508069708686717, (02.05.2020.)
262. Kamruzzaman, M. (2020). Tourism after Corona: Impacts of COVID 19 Pandemic and Way Forward For Tourism, Hotel and Mice Industry in Sri Lanka, dostupno na: https://vtechworks.lib.vt.edu/handle/10919/98012, (02.08.2020.)
263. Kapuscinski, G. (2014). *The Effects of news media on leisure tourists' perception of risk and willingness to travel, with specific reference to events of terrorism and political instability* (Doctoral dissertation, Bournemouth University)., dostupno na: http://eprints.bournemouth.ac.uk/21778/, (17.04.2020.)
264. Karimi, M. S., Khan, A. A., & Karamelikli, H. (2019). Asymmetric effects of real exchange rate on inbound tourist arrivals in Malaysia: An analysis of price rigidity. *International Journal of Tourism Research*, *21*(2), 156-164., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.2249, (08.06.2020.)
265. Khan, M. S., Karimi, I. A., & Wood, D. A. (2017). Retrospective and future perspective of natural gas liquefaction and optimization technologies contributing to efficient LNG supply: A review. *Journal of Natural Gas Science and Engineering*, *45*, 165-188.
266. Karl, M. (2018). Risk and uncertainty in travel decision-making: Tourist and destination perspective. *Journal of Travel Research*, *57*(1), 129-146., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287516678337, (01.08.2020.)
267. Katircioglu, S. T. (2009). Revisiting the tourism-led-growth hypothesis for Turkey using the bounds test and Johansen approach for cointegration. *Tourism Management*, *30*(1), 17-20., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517708000794?casa_token=cjNz-1Aont8AAAAA:vAcGGyaK3D2pyvquHOwz6OVMyDy-ggFP7M0Dt_vQSmf2okYBA02Om0KZKv-eho9KNmVFIl7USx0, (22.06.2020.)
268. Khan, A., Bibi, S., Lyu, J., Raza, A., Hayat, H., & Meo, M. S. (2020). Unraveling the Nexuses of Tourism, Terrorism, and Well-Being: Evidence from Pakistan. *Journal of Hospitality & Tourism Research*, 1096348020917742., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1096348020917742, (09.07.2020.)
269. Kiełbasiński, A. (1987). A note on rounding-error analysis of Cholesky factorization. *Linear Algebra and its applications*, *88*, 487-494.
270. King, B. (1994). What is ethnic tourism? An Australian perspective. *Tourism management*, *15*(3), 173-176., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/0261517794901015, (24.07.2020.)
271. Kisswani, K. M., Zaitouni, M., & Moufakkir, O. (2020). An examination of the asymmetric effect of oil prices on tourism receipts. *Current Issues in Tourism*, *23*(4),

500-522., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500.2019.1629578, (11.08.2020.)
272. Klevmarken, N. A. (1989). Panel studies: what can we learn from them?. *European Economic Review*, *33*, 523-529.
273. Knox, D. (2006). The sacralised landscapes of Glencoe: From massacre to mass tourism, and back again. *International Journal of Tourism Research*, *8*(3), 185-197., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.568, (23.07.2020.)
274. Knutson, T. R., McBride, J. L., Chan, J., Emanuel, K., Holland, G., Landsea, C., ... & Sugi, M. (2010). Tropical cyclones and climate change. *Nature geoscience*, *3*(3), 157-163., dostupno na: https://www.nature.com/articles/ngeo779, (01.08.2020.)
275. Koser, K., & Martin, S. (Eds.). (2011). *The migration-displacement nexus: patterns, processes, and policies* (Vol. 32). Berghahn Books., dostupno na: The migration-displacement nexus: patterns, processes, and policies , (21.04.2020.)
276. Kosová, R., & Enz, C. A. (2012). The terrorist attacks of 9/11 and the financial crisis of 2008: The impact of external shocks on US hotel performance. *Cornell Hospitality Quarterly*, *53*(4), 308-325.,dostupno na: http://apps.webofknowledge.com.ezproxy.nsk.hr/full_record.do?product=WOS&search_mode=GeneralSearch&qid=10&SID=D6C1FBtl8fCBLYUAIyU&page=1&doc=26, (23.03.2020.)
277. Kožić, I. (2019). Can tourism development induce deterioration of human capital?. *Annals of Tourism Research*, *77*, 168-170., dostupno na: https://doi.org/10.1016/j.annals.2018.12.018
278. Koyuncu, O. (2020). Effects of terrorism and political instability on tourist behavior: 2016 conflicts in Turkey. *The Central European Review of Economics and Management*, *4*(2), 21-40., dostupno na: https://ojs.wsb.wroclaw.pl/index.php/WSBRJ/article/view/866, (15.07.2020.)
279. Kreag, G. TheImpacts of Tourism., dostupno na: http://www.seagrant.umn.edu/downloads/t13.pdf, (18.08.2020.)
280. Kuo, H. I., Chen, C. C., Tseng, W. C., Ju, L. F., & Huang, B. W. (2008). Assessing impacts of SARS and Avian Flu on international tourism demand to Asia. *Tourism Management*, *29*(5), 917-928., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517707002191?casa_token=GwWzGrsJkBMAAAAA:FMjZ_PqsGNNVXijWnWiE28koR8-v0THdYvyyVufhulsvDeuPkIiA7ySQH_mXiCwehtjHUmfzjQ, (01.08.2020.)
281. Kuo, H. I., Wang, H. C., Hwang, W. Y., & Ye, C. Y. (2009, March). Tourism demand and exchange rates in Asian countries: Evidence from a panel data approach. In *2009 WRI World Congress on Computer Science and Information Engineering* (Vol. 4, pp. 508-512). IEEE., dostupno na: https://ieeexplore.ieee.org/abstract/document/5171048, (06.08.2020.)
282. Kurež, B., & Prevolšek, B. (2015). Influence of security threats on tourism destination development. *Tims. Acta: naučni časopis za sport, turizam i velnes*, *9*(2)., dostupno na: https://aseestant.ceon.rs/index.php/timsacta/article/view/8126, (01.08.2020.)
283. Kurtzman, J., & Zauhar, J. (2005). Sports tourism consumer motivation. *Journal of Sport Tourism*, *10*(1), 21-31., dostupno na: https://www.tandfonline.com/doi/full/10.1080/14775080500101478?casa_token=kp3zuNTzU-8AAAAA:bX_RtyZP4XANO6kGRSNha2Qu4WudY5AYkCP8UmtV7scDwLKqwnngRO5Mup343ZhsBm6-r0Wsnoe6NQ, (10.04.2020.)
284. Laderman, S. (2013). From the Vietnam War to the "war on terror": tourism and the martial fascination: Scott Laderman. In *Tourism and war* (pp. 42-51). Routledge.,

dostupno na: https://books.google.si/books?hl=hr&lr=&id=gQL-i1txd-gC&oi=fnd&pg=PA26&dq=Laderman,+2013+war&ots=VUH2cUzlBx&sig=xJzG7-RllUQcNNNsOf3yqSTEKtA&redir_esc=y#v=onepage&q=Laderman%2C%202013%20war&f=false, (21.07.2020.)

285. Lam, P. Y. (2008). Avian influenza and pandemic influenza preparedness in Hong Kong. *Annals academy of medicine Singapore*, *37*(6), 489., dostupno na: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.180.2444&rep=rep1&type=pdf, (01.08.2020.)
286. Lanouar, C., & Goaied, M. (2019). Tourism, terrorism and political violence in Tunisia: Evidence from Markov-switching models. *Tourism Management*, *70*, 404-418., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517718302103, (23.03.2020.)
287. Larobina, M. D., & Pate, R. L. (2009). The impact of terrorism on business. *Journal of Global Business Issues*, *3*(1), 147., dostupno na: https://search.proquest.com/openview/e25abef31ee4ef76b6c7a8daeb6cd887/1?pq-origsite=gscholar&cbl=39974, (14.04.2020.)
288. Le, D. T. T., & Pearce, D. G. (2011). Segmenting visitors to battlefield sites: International visitors to the former demilitarized zone in Vietnam. *Journal of Travel & Tourism Marketing*, *28*(4), 451-463., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/10548408.2011.571583, (21.07.2020.)
289. Lee, Y. S. (2006). The Korean War and tourism: legacy of the war on the development of the tourism industry in South Korea. *International Journal of Tourism Research*, *8*(3), 157-170., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.569, (15.07.2020.)
290. Lehto, X., Douglas, A. C., & Park, J. (2008). Mediating the effects of natural disasters on travel intention. *Journal of Travel & Tourism Marketing*, *23*(2-4), 29-43., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J073v23n02_03, (30.07.2020.)
291. Leitão, N. C., & Shahbaz, M. (2012). Migration and tourism demand. *Theoretical and Applied Economics*, 39-48., dostupno na: https://repositorio.ipsantarem.pt/handle/10400.15/599, (24.07.2020.)
292. Lennon, J. J., & Foley, M. (2000). *Dark tourism*. Cengage Learning EMEA., dostupno na: https://books.google.si/books?hl=hr&lr=&id=ZY6Xn4DmuCoC&oi=fnd&pg=PP8&dq=Lennon,+J.+J.+%26+Foley,+M.+(2000).+Dark+tourism&ots=lAXerMMGzB&sig=UcGTC1zoYSOQ4FHrG59lthDbGD0&redir_esc=y#v=onepage&q=Lennon%2C%20J.%20J.%20%26%20Foley%2C%20M.%20(2000).%20Dark%20tourism&f=false, (23.07.2020.)
293. Lepp, A., & Gibson, H. (2003). Tourist roles, perceived risk and international tourism. *Annals of tourism research*, *30*(3), 606-624., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738303000240?casa_token=x2dhHJtY5EkAAAAA:xr98zhbgXlWQ_b-7h4h3_7UJwUXMcqkQJ6-IXy1ccZ0LO8XsP_Jwa3nEzd9ieft276Z1YVS5bDA, (16.06.2020.)
294. Lew, H. L., Kraft, M., Pogoda, T. K., Amick, M. M., Woods, P., & Cifu, D. X. (2011). Prevalence and characteristics of driving difficulties in Operation Iraqi Freedom/Operation Enduring Freedom combat returnees. *Journal of Rehabilitation Research & Development*, *48*(8)., dostupno na: https://web.b.ebscohost.com/abstract?direct=true&profile=ehost&scope=site&authtype=crawler&jrnl=07487711&AN=70406034&h=3n0ma5f9Z4g20pI3EOzHFPTHj1VLiz%2frNPsH4cgxpU7dVuUDdzEQv3RnDQfiIRUjh%2fgDCyddpub48LbTSSXmgA%

3d%3d&crl=c&resultNs=AdminWebAuth&resultLocal=ErrCrlNotAuth&crlhashurl=login.aspx%3fdirect%3dtrue%26profile%3dehost%26scope%3dsite%26authtype%3dcrawler%26jrnl%3d07487711%26AN%3d70406034, (21.07.2020.)

295. Li, S., Blake, A., & Cooper, C. (2011). Modelling the economic impact of international tourism on the Chinese economy: A CGE analysis of the Beijing 2008 Olympics. *Tourism Economics*, *17*(2), 279-303., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/te.2011.0025,m (22.06.2020.)
296. Lim, C., Min, J. C., & McAleer, M. (2008). Modelling income effects on long and short haul international travel from Japan. *Tourism Management*, *29*(6), 1099-1109., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517708000289?casa_token=pRGS4QnUStgAAAAA:WhJ7UAda0ktjqFqOUwFarUUDRd_HOxGsHV6IgPDuzEA3jzfqbLKo-vYaygXN1ha60kDQHSBTrZY, (10.08.2020.)
297. Lise, W., & Tol, R. S. (2002). Impact of climate on tourist demand. *Climatic change*, *55*(4), 429-449., dostupno na: https://link.springer.com/article/10.1023/A:1020728021446, (28.07.2020.)
298. Liu, A., & Pratt, S. (2017). Tourism's vulnerability and resilience to terrorism. *Tourism Management*, *60*, 404-417., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517717300018, (12.06.2020.)
299. Liu, B., Kim, H., & Pennington-Gray, L. (2015). Responding to the bed bug crisis in social media. *International Journal of Hospitality Management*, *47*, 76-84., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0278431915000365, (01.08.2020.)
300. Llussá, F., & Tavares, J. (2008). Economics and terrorism: what we know, what we should know and the data we need., dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1140036, (10.07.2020.)
301. Loayza, N. V., Olaberria, E., Rigolini, J., & Christiaensen, L. (2012). Natural disasters and growth: Going beyond the averages. *World Development*, *40*(7), 1317-1336., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0305750X12000393, (02.05.2020.)
302. Loganathan, N., Yuliza, N. A. Y. N. A., Subramaniam, T., & Ibrahim, Y. (2020). Permintaan Pelancongan Bilateral Antara Malaysia Dan Indonesia (Bilateral Tourism Demand between Malaysia and Indonesia). *Akademika*, *90*(1)., dostupno na: http://ejournal.ukm.my/akademika/article/view/30564, (11.08.2020.)
303. Long, K. (2013). When refugees stopped being migrants: Movement, labour and humanitarian protection. *Migration Studies*, *1*(1), 4-26., dostupno na: https://academic.oup.com/migration/article-abstract/1/1/4/940995, (21.04.2020.)
304. Lunn, K. (2007). War memorialisation and public heritage in Southeast Asia: Some case studies and comparative reflections. *International Journal of Heritage Studies*, *13*(1), 81-95., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13527250601010893, (17.07.2020.)
305. Lütkepohl, H. (2005). *New introduction to multiple time series analysis*. Springer Science & Business Media., dostupno na: https://books.google.si/books?hl=hr&lr=&id=COUFCAAAQBAJ&oi=fnd&pg=PR4&dq=L%C3%BCtkepohl+H+(2005)+New+introduction+to+multiple+time+series+analysis.+Springer,+Berlin&ots=wG4GdxUMDp&sig=NU1jRTOOZ7rwwRj4kbj1EcKNQZI&redir_esc=y#v=onepage&q=L%C3%BCtkepohl%20H%20(2005)%20New%20i

ntroduction%20to%20multiple%20time%20series%20analysis.%20Springer%2C%20Berlin&f=false, (04.03.2022.)

306. Ma, H., Chiu, Y. H., Tian, X., Zhang, J., & Guo, Q. (2020). Safety or Travel: Which Is More Important? The Impact of Disaster Events on Tourism. *Sustainability*, *12*(7), 3038., dostupno na: https://www.mdpi.com/2071-1050/12/7/3038, (30.07.2020.)
307. Maddala, G. S., & Wu, S. (1999). A comparative study of unit root tests with panel data and a new simple test. *Oxford Bulletin of Economics and statistics*, *61*(S1), 631-652., https://onlinelibrary.wiley.com/doi/abs/10.1111/1468-0084.0610s1631 (03.03.2022.
308. Maharaj, R. J. (1993). Landslide processes and landslide susceptibility analysis from an upland watershed: a case study from St. Andrew, Jamaica, West Indies. *Engineering Geology*, *34*(1-2), 53-79., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/001379529390043C, (01.08.2020.)
309. Mangion, M. L., Durbarry, R., & Sinclair, M. T. (2005). Tourism competitiveness: price and quality. *Tourism economics*, *11*(1), 45-68., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/0000000053297202, (10.08.2020.)
310. Mansfeld, Y., & Pizam, A. (Eds.). (2006). *Tourism, security and safety*. Routledge., dostupno na: https://books.google.si/books?hl=hr&lr=&id=TGQABAAAQBAJ&oi=fnd&pg=PP1&dq=Mansfeld,+Y.+and+Pizam,+A.,+2006.+Tourism,+security+and+safety:+from+the+theory+to+practice,+Butterworth-Heinemann.+&ots=zvwCsOV4QY&sig=_vI98dPsF6WFOZJPGvekvhkxL9g&redir_esc=y#v=onepage&q=Mansfeld%2C%20Y.%20and%20Pizam%2C%20A.%2C%202006.%20Tourism%2C%20security%20and%20safety%3A%20from%20the%20theory%20to%20practice%2C%20Butterworth-Heinemann.&f=false, (11.07.2020.)
311. Martin, G., 2003. Understanding Terrorism: Challenges, Perspectives and Issues, Thousand Oaks, *CA*, *Sage*, dostupno na: https://books.google.si/books?id=XdXpn6NH2GcC&printsec=frontcover&hl=hr&source=gbs_ViewAPI&redir_esc=y#v=onepage&q&f=false, (13.04.2020.)
312. Martins, L. F., Gan, Y., & Ferreira-Lopes, A. (2017). An empirical analysis of the influence of macroeconomic determinants on World tourism demand. *Tourism Management*, *61*, 248-260., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517717300110, (22.06.2020.)
313. Maser, B., & Weiermair, K. (1998). Travel decision-making: From the vantage point of perceived risk and information preferences. *Journal of Travel & Tourism Marketing*, *7*(4), 107-121., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J073v07n04_06, (14.06.2020.)
314. Masinde, B. K., Buigut, S., & Mungatu, J. K. (2016). Modelling the temporal effect of terrorism on tourism in Kenya. *International Journal of Economics and Finance*, *8*(12), 10., dostupno na: https://www.researchgate.net/profile/Joseph_Mungatu/publication/310743276_Modelling_the_Temporal_Effect_of_Terrorism_on_Tourism_in_Kenya/links/583db8c408aeda69680707af/Modelling-the-Temporal-Effect-of-Terrorism-on-Tourism-in-Kenya.pdf, (08.07.2020.)
315. Maslow, A. H. (1943). A theory of human motivation. *Psychological review*, *50*(4), 370., dostupno na: https://psycnet.apa.org/record/1943-03751-001(10.04.2020.).
316. Mason, P., Grabowski, P., & Du, W. (2005). Severe acute respiratory syndrome, tourism and the media. *International Journal of Tourism Research*, *7*(1), 11-21., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.519, (01.08.2020.)

317. Massidda, C., & Piras, R. (2015). Does internal migration affect Italian domestic tourism? A panel data analysis. *Tourism Economics*, *21*(3), 581-600., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/te.2013.0362, (28.07.2020.)
318. Matos, O., Camacho Monteiro, S., & Soma, D. (2011). External shocks and policy responses in the Southern African Development Community (SADC) countries. *Banco Nacional de Angola*, dostupno na: https://www.bna.ao/uploads/%7Bf48e141b-2d01-43f3-b79a-6d3e0815b87f%7D.pdf (16.03.2020.)
319. Mazzocchi, M., & Montini, A. (2001). Earthquake effects on tourism in central Italy. *Annals of Tourism Research*, *28*(4), 1031-1046., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738301000081?casa_token=adEYK028YOIAAAAA:8LGo2wJe0epSHS3kr2_RhiV9DPcnXRt4Tq_GcN_c9iMqM4r-I3XWBqSqtl7grWlZsNtZEWJu, (29.07.2020.)
320. McGahey, S. (2006). Tourism development in Iraq: the need for support from international academia. *International Journal of Tourism Research*, *8*(3), 235-239., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.571, (21.07.2020.)
321. McKercher, B., & Chon, K. (2004). The over-reaction to SARS and the collapse of Asian tourism. *Annals of tourism research*, *31*(3), 716., dostupno na: https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7148758/, (01.08.2020.)
322. McMahon, W. W. (2010). The external benefits of education. *Economics of education*, 68-79., dostupno na: https://scholar.google.com/scholar?hl=hr&as_sdt=0%2C5&q=The+External+Benefits+of+Education+W+W+McMahon&btnG=, (16.04.2020.)
323. Melander, E., Pettersson, T., & Themnér, L. (2016). Organized violence, 1989–2015. *Journal of Peace Research*, *53*(5), 727-742., dostupno na: https://journals.sagepub.com/doi/full/10.1177/0022343316663032, (11.12.2020.)
324. Mervar, A., & Payne, J. E. (2007). An analysis of foreign tourism demand for Croatian destinations: long-run elasticity estimates. *Radni materijali EIZ-a*, (1), 5-21., dostupno na: https://hrcak.srce.hr/71591, (24.07.2020.)
325. Metreveli, M., & Timothy, D. J. (2010). Effects of the August 2008 War in Georgia on tourism and its resources. *Tourism, progress and peace*, 134-147., dostupno na: https://books.google.si/books?hl=hr&lr=&id=DT2UGhE4COoC&oi=fnd&pg=PA134&dq=Metreveli+and+Timothy,+2008&ots=x8_vxU2r1a&sig=fefw7e1NCe0q-AUOKgSRnpZ4ohs&redir_esc=y#v=onepage&q=Metreveli%20and%20Timothy%2C%202008&f=false, (17.07.2020.)
326. Meurer, R. (2010). Research note: International travel: The relationship between exchange rate, world GDP, revenues and the number of travellers to Brazil. *Tourism Economics*, *16*(4), 1065-1072., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/te.2010.0011, (07.08.2020.)
327. Michael, N., Wien, C., & Reisinger, Y. (2017). Push and pull escape travel motivations of Emirati nationals to Australia. *International Journal of Culture, Tourism and Hospitality Research.*, dostupno na: https://www.emerald.com/insight/content/doi/10.1108/IJCTHR-04-2016-0039/full/html?fullSc=1, (10.04.2020.)
328. Mikulić, J., Vizek, M., Stojčić, N., Payne, J. E., Časni, A. Č., & Barbić, T. (2021). The effect of tourism activity on housing affordability. *Annals of Tourism Research*, *90*, 103264., dostupno na: https://doi.org/10.1016/j.annals.2021.103264
329. Miles, S. (2014). Battlefield sites as dark tourism attractions: An analysis of experience. *Journal of Heritage Tourism*, *9*(2), 134-147., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/1743873X.2013.871017, (21.07.2020.)

330. Miles, W. F. (2002). Auschwitz: Museum interpretation and darker tourism. *Annals of tourism research*, *29*(4), 1175-1178., dostupno na: http://193.40.254.28/public/k/Kuressaare-kolledz/Kolledz/Summer_school/Miles_2002_Auschwitz_Museum_Interpretation_and_Darker_Tourism.pdf, (23.07.2020.)
331. Mileti, D. (1999). *Disasters by design: A reassessment of natural hazards in the United States*. Joseph Henry Press., dostupno na: https://books.google.si/books?hl=hr&lr=&id=Atw7c6vshAYC&oi=fnd&pg=PT21&dq=Mileti,+Dennis+S.+1999+Disasters+by+Design:+A+Reassessment+of+Natural+Hazards+in+the+United+States.%E2%80%9D+Washington,+DC:+Joseph+Henry+Press.&ots=agaq47dDEB&sig=3ny2I8sPX70_iwf6q5U9fE6QWIc&redir_esc=y#v=onepage&q&f=false, (02.05.2020.)
332. Mionel, V. (2019). Dark tourism and thanatourism: Distinct tourism typologies or simple analytical tools?. *Turizam: međunarodni znanstveno-stručni časopis*, *67*(4), 423-437., dostupno na: https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=335270, (23.07.2020.)
333. Mitra, D., Pham, C. S., & Bandyopadhyay, S. (2018). Terrorism and international air travel: A gravity approach. *The World Economy*, *41*(11), 2852-2882., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1111/twec.12680, (14.04.2020.)
334. Mitrović, R. S. D. (2002). *Analiza panel serija* (Vol. 64). FON., dostupno na: https://books.google.hr/books?hl=hr&lr=&id=-xA-Og1DehsC&oi=fnd&pg=PA17&dq=771.%09Mitrovi%C4%87,+R.+S.+D.+(2002).+Analiza+panel+serija+(Vol.+64).+FON.&ots=_mqUQEc9V4&sig=0R2Eo6iiCwIwDRqmA3yEY_9bGkU&redir_esc=y#v=onepage&q&f=false,
335. Monterrubio, J. C. (2010). Short-term economic impacts of influenza A (H1N1) and government reaction on the Mexican tourism industry: an analysis of the media. *International Journal of Tourism Policy*, *3*(1), 1-15., dostupno na: https://www.inderscienceonline.com/doi/abs/10.1504/IJTP.2010.031599, (01.08.2020.)
336. Morens, D. M., Folkers, G. K., & Fauci, A. S. (2009). What is a pandemic?., dostupno na: https://academic.oup.com/jid/article/200/7/1018/903237, (04.06.2020.)
337. Mossoun, A., Pauly, M., Akoua-Koffi, C., Couacy-Hymann, E., Leendertz, S. A. J., Anoh, A. E., ... & Schubert, G. (2015). Contact to non-human primates and risk factors for zoonotic disease emergence in the Taï region, Côte d'Ivoire. *EcoHealth*, *12*(4), 580-591., dostupno na: https://link.springer.com/article/10.1007/s10393-015-1056-x, (04.06.2020.)
338. Mowforth, M., & Munt, I. (2015). *Tourism and sustainability: Development, globalisation and new tourism in the third world*. routledge. https://doi.org/10.4324/9780203891056
339. Muchapondwa, E., & Pimhidzai, O. (2011). Modelling international tourism demand for Zimbabwe. *International journal of business and social science*, *2*(2)., dostupno na: https://efdinitiative.org/sites/default/files/ijbss20muchapondwa20and20pimhidzai2028201129.pdf, (11.08.2020.)
340. Muckley, C. B. (2010). Terrorism, Tourism and FDI: Estimating a lower bound on the Peace Dividend in Northern Ireland. *Available at SSRN 1689510*., dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1689510, (29.06.2020.)
341. Muhammad, A., & Andrews, D. (2008). Determining tourist arrivals in Uganda: The impact of distance, trade and origin-specific factors. *African Journal of Accounting, Economics, Finance and Banking Research*, *2*(2)., dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1534166, (08.06.2020.)

342. Müller, H., & Hoppler, A. A. (2013). 9 Tourism in a neutral country surrounded by war. *Tourism and War*, *34*, 106., dostupno na: https://books.google.si/books?hl=hr&lr=&id=wDCKEW_3ujgC&oi=fnd&pg=PA106&dq=M%C3%BCller+and+Hoppler+(2013)+war+tourism&ots=Mr69eHysai&sig=8Np11bFFyQ4_1cbb-2qI1jRIiFA&redir_esc=y#v=onepage&q=M%C3%BCller%20and%20Hoppler%20(2013)%20war%20tourism&f=false, (21.07.2020.)
343. Murphy, P. E., & Bayley, R. (1989). Tourism and disaster planning. *Geographical Review*, 36-46., dostupno na: https://www.jstor.org/stable/215681?seq=1#metadata_info_tab_contents, (25.04.2020.)
344. Mushtaq, A., & Zaman, K. (2014). The relationship between political instability, terrorism and tourism in SAARC region. *Journal of Economic Info*, *1*(1), 23-40., dostupno na: https://pdfs.semanticscholar.org/6051/3eb4f980e842cffd649cd7b8cfa84cafc071.pdf, (11.07.2020.)
345. Nadeem, M. A., Liu, Z., Xu, Y., Nawaz, K., Malik, M. Y., & Younis, A. (2020). Impacts of terrorism, governance structure, military expenditures and infrastructures upon tourism: empirical evidence from an emerging economy. *Eurasian Business Review*, *10*(1), 185-206., dostupno na: https://link.springer.com/article/10.1007/s40821-020-00152-y, (09.07.2020.)
346. Naumann, A., Edmonds, J. J., & Frear, D. (2018). Terrorism vs. Tourism: How Terrorism Affects the Tourism Industry. In *Global Business Value Innovations* (pp. 129-139). Palgrave Pivot, Cham., dostupno na: https://link.springer.com/chapter/10.1007/978-3-319-77929-4_10, (14.04.2020.)
347. Neumayer, E. (2004). The impact of political violence on tourism: Dynamic cross-national estimation. *Journal of conflict resolution*, *48*(2), 259-281., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0022002703262358, (29.06.2020.)
348. Neumayer, E., & Plümper, T. (2016). Spatial spill-overs from terrorism on tourism: Western victims in Islamic destination countries. *Public Choice*, *169*(3-4), 195-206., dostupno na: https://link.springer.com/article/10.1007/s11127-016-0359-y, (30.06.2020.)
349. Nguyen, L. P., & Nguyen, H. T. (2021). Factors Impacting Tourism Demand: An Analysis of 10 ASEAN Countries. *The Journal of Asian Finance, Economics, and Business*, *8*(1), 385-393. https://www.koreascience.or.kr/article/JAKO202100569412306.page , (17.09.2021.)
350. Nhlabathi, S. S. (2017). *Motivations to engage in dark tourism: the case of selected sites in South Africa* (Doctoral dissertation)., dostupno na: http://ukzn-dspace.ukzn.ac.za/handle/10413/15771, (23.07.2020.)
351. Nhlabathi, S. S., & Maharaj, B. (2019). The dark tourism discipline: a creative brand in a competitive academic environment?. *Current Issues in Tourism*, 1-12., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500.2019.1636770, (23.07.2020.)
352. Nian, S., Zhang, J., Zhang, H., Zhang, J., Li, D., Wu, K., ... & Yang, L. (2019). Two sides of a coin: a crisis response perspective on tourist community participation in a post-disaster environment. *International journal of environmental research and public health*, *16*(12), 2073., dostupno na: https://www.mdpi.com/1660-4601/16/12/2073, (30.07.2020.)
353. Nicolau, J. L. (2008). Characterizing tourist sensitivity to distance. *Journal of Travel Research*, *47*(1), 43-52., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287507312414, (10.08.2020.)

354. Nikšić Radić, M., Dragičević, D., & Barkiđija Sotošek, M. (2019). Causality between Terrorism and FDI in Tourism: Evidence from Panel Data. *Economies*, *7*(2), 38., dostupno na: https://www.mdpi.com/2227-7099/7/2/38, (30.06.2020.)
355. Nikšić, R. M., Dragičević, D., & Barkiđija, S. M. (2018). The tourism-led terrorism hypothesis–evidence from Italy, Spain, UK, Germany and Turkey. *Journal of International Studies*, *11*(2)., dostupno na: https://www.ceeol.com/search/article-detail?id=718086, (08.07.2020.)
356. Norris, P., Kern, M., & Just, M. (Eds.). (2004). *Framing terrorism: The news media, the government and the public*. Routledge., dostupno na: Framing terrorism: The news media, the government and the public, (13.04.2020.)
357. Novelli, M. (Ed.). (2005). *Niche tourism: Contemporary issues, trends and cases*. Routledge., dostupno na: Niche tourism: Contemporary issues, trends and cases, (07.04.2020.)
358. Novelli, M., Burgess, L. G., Jones, A., & Ritchie, B. W. (2018). 'No Ebola… still doomed'–The Ebola-induced tourism crisis. *Annals of Tourism Research*, *70*, 76-87., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738318300306, (01.08.2020.)
359. Noy, I. (2009). The macroeconomic consequences of disasters. *Journal of Development economics*, *88*(2), 221-231., dostupno na: https://www.sciencedirect.com/science/article/pii/S030438780800031X?casa_token=19J-z6T7_CkAAAAA:do6m5lEx7IwhWsCd_d5k0abUOntm4-rrYknAZuTsGP88wWFLVvBTCfymoQAssIpabrN2icPc, (01.08.2020.)
360. Ogilvie, F. W. (1933). *The tourist movement: An economic study*. PS King & son, ltd.., dostupno na: https://www.jstor.org/stable/2225409?seq=1, (07.04.2020.)
361. Oh, H. C., Uysal, M., & Weaver, P. A. (1995). Product bundles and market segments based on travel motivations: A canonical correlation approach. *International Journal of Hospitality Management*, *14*(2), 123-137., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/027843199500010A, (10.04.2020.)
362. Oigenblick, L., & Kirschenbaum, A. (2002). Tourism and immigration: Comparing alternative approaches. *Annals of tourism research*, *29*(4), 1086-1100., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738302000233?casa_token=TXGU6458x3oAAAAA:x--ad9QrrcQ5b3_rbjeG35lUPMolFGsK9JylT-ScZdPjoV-lkMQFgxKVHvAVr3Y4whubWXMpGJ8, (24.07.2020.)
363. Oliva, M. A., & Rivera-Batiz, L. A. (2002). Political institutions, capital flows, and developing country growth: An empirical investigation. *Review of Development Economics*, *6*(2), 248-262., dostupan na: https://onlinelibrary.wiley.com/doi/abs/10.1111/1467-9361.00152, (16.04.2020.)
364. Omer, A. M., & Yeşiltaş, M. Modeling the impact of wars and terrorism on tourism demand in Kurdistan region of Iraq. *Portuguese Economic Journal*, 1-22., dostupno na: https://link.springer.com/article/10.1007/s10258-020-00178-0, (21.07.2020.)
365. Orchiston, C. (2012). Seismic risk scenario planning and sustainable tourism management: Christchurch and the Alpine Fault zone, South Island, New Zealand. *Journal of Sustainable Tourism*, *20*(1), 59-79., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/09669582.2011.617827, (31.07.2020.)
366. Ouerfelli, C. (2008). Co-integration analysis of quarterly European tourism demand in Tunisia. *Tourism Management*, *29*(1), 127-137., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517707000933, (23.03.2020.)

367. Pablo-Romero, M. D. P., & Molina, J. A. (2013). Tourism and economic growth: A review of empirical literature. *Tourism Management Perspectives*, *8*, 28-41., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S221197361300041X, (22.06.2020.)
368. Padash, H., & Khodapanah, B. (2018). An Exploration into How Terrorism Impacts Business Environment in MENA Region. In *Entrepreneurship Ecosystem in the Middle East and North Africa (MENA)* (pp. 167-187). Springer, Cham., dostupno na: https://link.springer.com/chapter/10.1007/978-3-319-75913-5_6, (27.06.2020.)
369. Page, S., & Yeoman, I. (2007). How VisitScotland prepared for a flu pandemic. *Journal of Business Continuity & Emergency Planning*, *1*(2), 167-182., dostupno na: https://www.ingentaconnect.com/content/hsp/jbcep/2007/00000001/00000002/art00006, (02.08.2020.)
370. Pandey, D. K., & Kumar, R. (2022). Russia-Ukraine War and the global tourism sector: A 13-day tale. *Current Issues in Tourism*, 1-9., dostupno na: https://www.tandfonline.com/doi/full/10.1080/13683500.2022.2081789
371. Pain, R. (2014). Everyday terrorism: Connecting domestic violence and global terrorism. *Progress in Human Geography*, *38*(4), 531-550., dostupno na: https://journals.sagepub.com/doi/full/10.1177/0309132513512231?casa_token=mLSLXqQy7doAAAAA%3A9bBh9aAh3VqPnv3Nu8riR5INbZgeLgCnlpwq6Kty_ZiE5FbNQxyzaVAjjGM7Ak0bXgr014xyFdV0JQ, (14.04.2020.)
372. Parajuli, J., & Haynes, K. E. (2016). The earthquake impact on telecommunications infrastructure in Nepal: a preliminary spatial assessment. *Regional Science Policy & Practice*, *8*(3), 95-109., dostupno na: https://rsaiconnect.onlinelibrary.wiley.com/doi/abs/10.1111/rsp3.12075, (30.07.2020.)
373. Paraskevas, A., & Arendell, B. (2007). A strategic framework for terrorism prevention and mitigation in tourism destinations. *Tourism Management*, *28*(6), 1560-1573., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517707000374?casa_token=MTamLA8cJl4AAAAA:QktjojdwXf0-lp8ccPfR27Q1Yo5JezvFBAEiS31Zx-VTYtVwFIxPUgUxIIeFvi0B5kd0sdqvQg, (13.06.2020.)
374. Park, K., & Reisinger, Y. (2010). Differences in the perceived influence of natural disasters and travel risk on international travel. *Tourism Geographies*, *12*(1), 1-24., dostupno na: https://www.tandfonline.com/doi/full/10.1080/14616680903493621, (29.07.2020.)
375. Park, S. H., Hsieh, C. M., & Lee, C. K. (2017). Examining Chinese college students' intention to travel to Japan using the extended theory of planned behavior: Testing destination image and the mediating role of travel constraints. *Journal of Travel & Tourism Marketing*, *34*(1), 113-131., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/10548408.2016.1141154, (01.08.2020.)
376. Patel, P. K., Sharma, J., Kharoliwal, S., & Khemariya, P. (2020). The effects of nobel corona virus (COVID-19) in the tourism industry in India. *International Journal of Engineering Research & Technology (IJERT)*, *9*(05), 2278-0181.
377. Patsouratis, V., Frangouli, Z., & Anastasopoulos, G. (2005). Competition in tourism among the Mediterranean countries. *Applied economics*, *37*(16), 1865-1870., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/00036840500217226, (07.08.2020.)
378. Payne, J. E., & Gil-Alana, L. A. (2018). Data measurement and the change in persistence of tourist arrivals to the United States in the aftermath of the September 11th terrorist attacks. *Tourism Economics*, *24*(1), 41-50., dostupno na: https://journals.sagepub.com/doi/full/10.1177/1354816617719161, (13.07.2020.)

379. Perić, J., Blažević, B., & Dragičević, D. (2014). Utjecaj mjera ekonomske politike na ekonomski položaj i konkurentnost hotelskih poduzeća. *Ekonomski pregled*, *65*(5), 416-452., dostupno na: https://hrcak.srce.hr/file/189163 (22.07.2020.)
380. Perić, V. (2005, November). Tourism and globalization. In *Proceedings of the 6th International Conference of the Faculty of Management Koper* (pp. 24-26).
381. Perles-Ribes, J. F., Ramón-Rodríguez, A. B., Rubia, A., & Moreno-Izquierdo, L. (2017). Is the tourism-led growth hypothesis valid after the global economic and financial crisis? The case of Spain 1957–2014. *Tourism Management*, *61*, 96-109., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517717300031, (13.08.2020.)
382. Perles-Ribes, J. F., Ramón-Rodríguez, A. B., Sevilla-Jiménez, M., & Rubia, A. (2016). The effects of economic crises on tourism success: An integrated model. *Tourism Economics*, *22*(2), 417-447., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/te.2014.0428, (13.08.2020.)
383. Perles-Ribes, J. F., Ramón-Rodríguez, A. B., Such-Devesa, M. J., & Moreno-Izquierdo, L. (2019). Effects of political instability in consolidated destinations: The case of Catalonia (Spain). *Tourism Management*, *70*, 134-139., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517718301729, (11.07.2020.)
384. Perpiña, L., Camprubí, R., & Prats, L. (2019). Destination image versus risk perception. *Journal of Hospitality & Tourism Research*, *43*(1), 3-19., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1096348017704497, (15.06.2020.)
385. Pesaran, M. H. (2015). Testing weak cross-sectional dependence in large panels. *Econometric reviews*, *34*(6-10), 1089-1117., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/07474938.2014.956623 (14.09.2021.)
386. Pesonen, J., Komppula, R., Kronenberg, C., & Peters, M. (2011). Understanding the relationship between push and pull motivations in rural tourism. *Tourism Review*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/16605371111175311/full/html?mobileUi=0&fullSc=1&mbSc=1&fullSc=1&fullSc=1, (10.04.2020.)
387. Phakdisoth, L., & Kim, D. (2007). The determinants of inbound tourism in Laos. *ASEAN Economic Bulletin*, 225-237., dostupno na: https://www.jstor.org/stable/41316966, (24.07.2020.)
388. Pham, T. D., Nghiem, S., & Dwyer, L. (2017). The determinants of Chinese visitors to Australia: A dynamic demand analysis. *Tourism Management*, *63*, 268-276., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517717301383, (10.08.2020.)
389. Pickering, C. (2007). Climate change and other threats in the Australian Alps. *Protected Areas: Buffering nature against climate change*, *18*, 28.
390. Pizam, A., & Smith, G. (2000). Tourism and terrorism: A quantitative analysis of major terrorist acts and their impact on tourism destinations. *Tourism Economics*, *6*(2), 123-138., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/000000000101297523, (23.03.2020.)
391. Pičuljan, M., Težak Damijanić, A., & Šergo, Z. (2018). Identifikacija i sistematizacija utjecaja turizma. *Ekonomska misao i praksa*, (2), 585-602., dostupno na: https://hrcak.srce.hr/213316
392. Pokharel, R., Poudel, J., & Grala, R. K. (2018). Impact of economic factors and a political conflict on international tourism demand in Nepal: a vector error correction model. *International Journal of Tourism Policy*, *8*(1), 18-41., dostupno na:

https://www.inderscienceonline.com/doi/abs/10.1504/IJTP.2018.090319, (20.07.2020.)

393. Poland, J. M. (1988). *Understanding terrorism: Groups, strategies, and responses*. Englewood Cliffs: Prentice Hall., dostupno na: https://www.ncjrs.gov/App/abstractdb/AbstractDBDetails.aspx?id=134630, (13.04.2020.)
394. Prayag, G., & Ryan, C. (2011). The relationship between the 'push'and 'pull'factors of a tourist destination: The role of nationality–an analytical qualitative research approach. *Current Issues in Tourism*, *14*(2), 121-143., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683501003623802, (10.04.2020.)
395. Prettenthaler, F., Köberl, J., & Bird, D. N. (2016). 'Weather Value at Risk': A uniform approach to describe and compare sectoral income risks from climate change. *Science of the Total Environment*, *543*, 1010-1018., dostupno na: https://www.sciencedirect.com/science/article/pii/S0048969715004842, (28.07.2020.)
396. Price, R. (2017). The Alert Collector: Dark Tourism: A Guide to Resources. *Reference & User Services Quarterly*, *57*(2), 97-101., dostupno na: https://www.journals.ala.org/index.php/rusq/article/view/6525, (23.07.2020.)
397. Prideaux, B. (2007). Echoes of war: battlefield tourism. In *Battlefield tourism* (pp. 39-50). Routledge., dostupno na: https://www.taylorfrancis.com/books/e/9780080548340/chapters/10.4324/9780080548340-10, (20.04.2020.)
398. Prideaux, B., Prideaux, J., & Kim, S. (2010). 16 Does Tourism have in Promoting Peace on the Korean Peninsula?. *Tourism and Political Change*, 189., dostupno na: http://perpus.univpancasila.ac.id/repository/EBUPT180275.pdf#page=192, (21.07.2020.)
399. Promsivapallop, P., & Kannaovakun, P. (2017). A comparative assessment of destination image, travel risk perceptions and travel intention by young travellers across three ASEAN countries: a study of German students. *Asia Pacific Journal of Tourism Research*, *22*(6), 634-650., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/10941665.2017.1308391, (01.08.2020.)
400. Provenzano, D. (2020). The migration–tourism nexus in the EU28. *Tourism Economics*, 1354816620909994., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1354816620909994, (24.07.2020.)
401. Quadri, D. L., & Zheng, T. (2010). A revisit to the impact of exchange rates on tourism demand: The case of Italy. *The Journal of Hospitality Financial Management*, *18*(2), 47-60., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/10913211.2010.10653894, (06.08.2020.)
402. Quayson, J., & Var, T. (1982). A tourism demand function for the Okanagan, BC. *Tourism Management*, *3*(2), 108-115., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/0261517782900061, (10.08.2020.)
403. Raddatz, C. (2007). *Are external shocks responsible for the instability of output in low-income countries? Journal of Development Economics, 84(1), 155–187.*, dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0304387806001842, (23.03.2020.)
404. Rahman, F., Holdschlag, A., Ahmad, B., & Qadir, I. (2011). War, terror and tourism: Impact of violent events on international tourism in Chitral, Pakistan. *Turizam: međunarodni znanstveno-stručni časopis*, *59*(4), 465-479., dostupno na: https://hrcak.srce.hr/75721, (21.07.2020.)

405. Ranabhat, K. (2015). Effects of terrorism in tourism industry: A case study of 9/11 terrorist attacks in World Trade Center., dostupno na: https://www.theseus.fi/handle/10024/103202, (22.06.2020.)
406. Raza, S. A., & Jawaid, S. T. (2013). Terrorism and tourism: A conjunction and ramification in Pakistan. *Economic Modelling*, *33*, 65-70., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0264999313001120, (29.06.2020.)
407. Reichel, A., Fuchs, G., & Uriely, N. (2007). Perceived risk and the non-institutionalized tourist role: The case of Israeli student ex-backpackers. *Journal of Travel Research*, *46*(2), 217-226., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287507299580, (13.06.2020.)
408. Ren, C. H. (2000). Understanding and managing the dynamics of linked crisis events. *Disaster Prevention and Management: An International Journal*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/09653560010316023/full/html, (12.08.2020.)
409. Richardson, B. (1994). Crisis Management and Management Strategy-Time to "Loop the Loop"?. *Disaster Prevention and Management: An International Journal*., dosupno na: https://www.emerald.com/insight/content/doi/10.1108/09653569410795632/full/html, (25.04.2020.)
410. Ridderstaat, J., Oduber, M., Croes, R., Nijkamp, P., & Martens, P. (2014). Impacts of seasonal patterns of climate on recurrent fluctuations in tourism demand: Evidence from Aruba. *Tourism Management*, *41*, 245-256., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517713001672, (28.07.2020.)
411. Ritchie, B. (2008). Tourism disaster planning and management: From response and recovery to reduction and readiness. *Current issues in Tourism*, *11*(4), 315-348., dostupno na: https://www.tandfonline.com/doi/full/10.1080/13683500802140372, (31.07.2020.)
412. Ritchie, B. W. (2004). Chaos, crises and disasters: a strategic approach to crisis management in the tourism industry. *Tourism management*, *25*(6), 669-683., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517703001845?casa_token=CiAYYMQyV9kAAAAA:5ntt2F54H8Wah-zta_VHo9F39iiP6-YZ4moY3WcGGBT-Cm04mw9epjPkt0UPeKWS4jAxAgu0GQ, (25.04.2020.)
413. Rittichainuwat, B. N., & Chakraborty, G. (2009). Perceived travel risks regarding terrorism and disease: The case of Thailand. *Tourism Management*, *30*(3), 410-418., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517708001222?casa_token=Nk0dTkE45a0AAAAA:samsb652wXZ1YiJbvGQCiVavwKxYgdZEYfP1edOWNHDjrqBoVts1BuFz9wSJKjD3BnELgpekN9s, (16.06.2020.)
414. Rivera, L. A. (2008). Managing "spoiled" national identity: War, tourism, and memory in Croatia. *American Sociological Review*, *73*(4), 613-634., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/000312240807300405, (21.07.2020.)
415. Rosselló, J., Aguiló, E., & Riera, A. (2005). Modeling tourism demand dynamics. *Journal of Travel Research*, *44*(1), 111-116., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287505276602, (10.08.2020.)
416. Rosselló, J., Becken, S., & Santana-Gallego, M. (2020). The effects of natural disasters on international tourism: A global analysis. *Tourism management*, *79*, 104080.,

dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517720300066, (16.06.202.)

417. Rosselló, J., Becken, S., & Santana-Gallego, M. (2020). The effects of natural disasters on international tourism: A global analysis. *Tourism management*, *79*, 104080., dostupno na: https://doi.org/10.1016/j.tourman.2020.104080, (11.01.2020.)

418. Rotunno, L. (2016). Political stability and trade agreements: Evidence for 'endgame FTAs'. *European Journal of Political Economy*, *45*, 133-148., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0176268016302348, (16.04.2020.)

419. Ryan, C. (1993). Crime, violence, terrorism and tourism: an accidental or intrinsic relationship?. *Tourism Management*, *14*(3), 173-183., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/026151779390018G, (30.06.2020.)

420. Saglam, Y., & Ampountolas, A. (2020). The effects of shocks on Turkish tourism demand: Evidence using panel unit root test. *Tourism Economics*, 1354816619899831., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1354816619899831, (15.07.2020.)

421. 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), 509-521., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287513496472, (23.03.2020.)

422. 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), 509-521., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287513496472, (29.06.2020.)

423. Samitas, A., Asteriou, D., Polyzos, S., & Kenourgios, D. (2018). Terrorist incidents and tourism demand: Evidence from Greece. *Tourism management perspectives*, *25*, 23-28., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S2211973617301101, (30.06.2020.)

424. Santana, G. (2001). 10 Globalisation, safety and national security. *Tourism in the Age of Globalisation*, *10*, 213., dostupno na: https://books.google.si/books?hl=hr&lr=&id=fw2EAgAAQBAJ&oi=fnd&pg=PA213&dq=Santana,+G.,+2001.+Globalisation,+safety+and+national+security.+In:+Wahab,+S.,+%26+Cooper,+C.+(ed.)+Tourism+in+the+age+of+globalisation.+London:+Routledge&ots=XZM9egpwB-&sig=LoQdyr2gQGXTG0laLvjJb7T1PcM&redir_esc=y#v=onepage&q&f=false, (11.07.2020.)

425. Santana, G. (2004). Crisis management and tourism: Beyond the rhetoric. *Journal of Travel & Tourism Marketing*, *15*(4), 299-321., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J073v15n04_05, 26.06.2020.)

426. Sass, E. (2020). THE IMPACT OF EASTERN UKRAINIAN ARMED CONFLICT ON TOURISM IN UKRAINE. *GeoJournal of Tourism and Geosites*, *30*, 880-888., dostupno na: http://gtg.webhost.uoradea.ro/PDF/GTG-2spl-2020/gtg.302spl14-518.pdf, (21.07.2020.)

427. Schmid, A. P., & Jongman, A. J. (1988). Political Terrorism: A New Guide to Actors. *Authors, Concepts, Data Bases, Theories and Literature, Amsterdam*.

428. Schmude, J., Zavareh, S., Schwaiger, K. M., & Karl, M. (2018). Micro-level assessment of regional and local disaster impacts in tourist destinations. *Tourism*

Geographies, *20*(2), 290-308., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/14616688.2018.1438506, (01.08.2020.)

429. Schott, C. (2002). *Motivation and lifestyles amongst young holidaymakers: a case study of Exeter* (Doctoral dissertation, University of Exeter)., dostupno na: https://europepmc.org/article/eth/248478, (10.04.2020.)
430. Schumacher, M. J., & Schraeder, P. J. (2019). Does Domestic Political Instability Foster Terrorism? Global Evidence from the Arab Spring Era (2011–14). *Studies in Conflict & Terrorism*, 1-25., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/1057610X.2018.1538124, (10.07.2020.)
431. Scott, D. (2003, April). Climate change and tourism in the mountain regions of North America. In *1st International Conference on Climate Change and Tourism* (pp. 9-11)., dostupno na: https://www.researchgate.net/profile/Daniel_Scott9/publication/267198542_Climate_Change_and_Tourism_in_the_Mountain_Regions_of_North_America/links/54b674ae0cf24eb34f6d1ee1.pdf, (29.07.2020.)
432. Scott, D., & Gössling, S. (2015). What could the next 40 years hold for global tourism?. *Tourism Recreation Research*, *40*(3), 269-285., dostupno na: https://www.tandfonline.com/doi/full/10.1080/02508281.2015.1075739, (02.08.2020.)
433. Scott, N., Laws, E., & Boksberger, P. (2009). The marketing of hospitality and leisure experiences. *Journal of Hospitality Marketing & Management*, *18*(2-3), 99-110., dostupno na: https://www.tandfonline.com/doi/full/10.1080/19368620802590126, (07.04.2020.)
434. Seabra, C., Kastenholz, E., Abrantes, J. L., & Reis, M. (2018). Peacefulness at home: impacts on international travel. *International Journal of Tourism Cities*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/IJTC-10-2017-0050/full/html, (13.07.2020.)
435. Seaton, A. V. (1996). Guided by the dark: From thanatopsis to thanatourism. *International Journal of Heritage Studies*, *2*(4), 234-244., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13527259608722178, (23.07.2020.)
436. Seddighi, H. R., Nuttall, M. W., & Theocharous, A. L. (2001). Does cultural background of tourists influence the destination choice? An empirical study with special reference to political instability. *Tourism management*, *22*(2), 181-191., dostupno na: https://scholar.google.com/scholar?hl=hr&as_sdt=0%2C5&q=Seddighi%2C+M.W.+Nuttall%2C+A.L.+Theocharous+H.R.+%282001%29.+Does+cultural+background+of+tourists+influence+the+destination+choice%3F+An+empirical+study+with+special+reference+to+political+instability.+Tourism+management%2C+22%282%29%2C+pp.+181-191&btnG=, (10.07.2020.)
437. Seddighi, H. R., Theocharous, A. L., & Nuttall, M. W. (2002). Political instability and tourism: an empirical study with special reference to the microstate of Cyprus. *International Journal of Hospitality & Tourism Administration*, *3*(1), 61-84., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J149v03n01_04, (17.04.2020.)
438. Seetanah, B. (2011). Assessing the dynamic economic impact of tourism for island economies. *Annals of tourism research*, *38*(1), 291-308., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738310001106?casa_token=25PZuguvbu4AAAAA:qg7LW39gk0mvVpwxFfEDqmnr-3Sb8dGHzY0YSdI9SK4Qx1wBvTRelzZAzA-2OHw-6xB09C5-Gp4, (22.06.2020.)
439. Seetaram, N. (2012a). Immigration and international inbound tourism: Empirical evidence from Australia. *Tourism Management*, *33*(6), 1535-1543., dostupno na:

https://www.sciencedirect.com/science/article/abs/pii/S0261517712000428?via%3Dihub, (24.07.2020.)

440. Seetaram, N. (2012b). Estimating demand elasticities for Australia's international outbound tourism. *Tourism Economics*, *18*(5), 999-1017., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/te.2012.0161, (24.07.2020.)
441. Seetaram, N., & Dwyer, L. (2009). Immigration and tourism demand in Australia: A panel data analysis. *Anatolia*, *20*(1), 212-222., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13032917.2009.10518905, (24.07.2020.)
442. Seetaram, N., Forsyth, P., & Dwyer, L. (2016). Measuring price elasticities of demand for outbound tourism using competitiveness indices. *Annals of Tourism Research*, *56*, 65-79., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0160738315001449, (23.06.2020.)
443. Seo, J. H., Park, S. Y., & Yu, L. (2009). The analysis of the relationships of Korean outbound tourism demand: Jeju Island and three international destinations. *Tourism Management*, *30*(4), 530-543., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517708001477?casa_token=I3YvybBUGVEAAAAA:neHXlPb_V_e2bdVYjFCZDZ591WN1Oi_uhVAHLW8hbAqybWmO4iN9xVpG8_HpjW3E7xR-wY4, (06.08.2020.)
444. Seraphin, H. (2019). Natural disaster and destination management: The case of the Caribbean and hurricane Irma. *Current Issues in Tourism*, *22*(1), 21-28., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500.2017.1422483, (01.08.2020.)
445. Shahzad, S. J. H., & Caporin, M. (2019). On the volatilities of tourism stocks and oil. *Annals of Tourism Research*., https://www.researchgate.net/publication/332243968_On_the_volatilities_of_tourism_stocks_and_oil, (05.06.2020.)
446. Shahzad, S. J. H., & Caporin, M. (2020). On the volatilities of tourism stocks and oil. *Annals of Tourism Research*, *81*(C)., dostupno na: https://ideas.repec.org/a/eee/anture/v81y2020ics0160738319300465.html, (10.08.2020.)
447. Shareef, R., & McAleer, M. (2005). Modelling international tourism demand and volatility in small island tourism economies. *International Journal of Tourism Research*, *7*(6), 313-333., dostupno na: https://doi.org/10.1002/jtr.538
448. Shareef, R., & McAleer, M. (2008). Modelling international tourism demand and uncertainty in Maldives and Seychelles: A portfolio approach. *Mathematics and Computers in Simulation*, *78*(2-3), 459-468., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0378475408000566, (01.08.2020.)
449. Sharma, C., & Pal, D. (2019). Exchange Rate Volatility and Tourism Demand in India: Unraveling the Asymmetric Relationship. *Journal of Travel Research*, 0047287519878516., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287519878516, (10.08.2020.)
450. Sharpley, R. (2005). The tsunami and tourism: A comment. *Current issues in Tourism*, *8*(4), 344-349., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500508668222, (31.07.2020.)
451. Sharpley, R., & Stone, P. (2014). Reconceptualising dark tourism AvITAL BIRAN AND YANIv PORIA. In *Contemporary Tourist Experience* (pp. 75-86). Routledge., dostupno na: https://books.google.si/books?hl=hr&lr=&id=3eHgAwAAQBAJ&oi=fnd&pg=PA59

&dq=Biran,+A.,+%26+Poria,+Y.+(2012).+Reconceptualising+dark+tourism.+In+R.+Sharpley+%26+P.+R.+Stone+(Eds.),+Contemporary+tourist+experience:+Concepts+and+consequence+(pp.+45%E2%80%9356).+London:+Routledge&ots=D_43wB9F0v&sig=xLbdJAQ5k_0iBQ6tnqTuqHP2okk&redir_esc=y#v=onepage&q&f=false, (23.07.2020.)

452. Shaw, G., & Williams, A. M. (1994). *Critical issues in tourism: A geographical perspective*. Blackwell Publishers., dostupno na: https://www.cabdirect.org/cabdirect/abstract/19941805547, (07.04.2020)
453. Shaw, G., Saayman, M., & Saayman, A. (2012). Identifying risks facing the South African tourism industry. *South African Journal of Economic and Management Sciences*, *15*(2), 190-206., dostupno na: http://www.scielo.org.za/scielo.php?pid=S2222-34362012000200005, (30.0.2020.)
454. Simmons, M. R. (2006). *Twilight in the desert: The coming Saudi oil shock and the world economy*. John Wiley & Sons., dosupno na: https://books.google.si/books?hl=hr&lr=&id=rlcfvVhb24cC&oi=fnd&pg=PR9&dq=Simmons,+M.+(2005).+Twilight+in+the+desert.+The+coming+Saudi+oil+shock+and+the+World+economy.+New+Jersey:+John+Wiley+%26+Sons.&ots=nnR2vNBOf7&sig=mNRB67wGlOlbhdnYj9MOU0OtbIA&redir_esc=y#v=onepage&q&f=false, (05.06.2020.)
455. Simon, S. (2003). The new terrorism: Securing the nation against a messianic foe. *The Brookings Review*, *21*(1), 18-24.dostupno na: https://www.brookings.edu/articles/the-new-terrorism-securing-the-nation-against-a-messianic-foe/, (14.04.2020.)
456. Sims, C. A. (1980). Macroeconomics and reality. *Econometrica: journal of the Econometric Society*, 1-48., dostupno na: https://www.jstor.org/stable/1912017, (28.02.2022.)
457. Sinclair, T. J. (2000). Reinventing authority: embedded knowledge networks and the new global finance. *Environment and Planning C: Government and Policy*, *18*(4), 487-502., dostupno na: https://journals.sagepub.com/doi/abs/10.1068/c10c, (06.06.2020.)
458. Skerritt, D., & Huybers, T. (2005). The effect of international tourism on economic development: An empirical analysis. *Asia Pacific Journal of Tourism Research*, *10*(1), 23-43., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/1094166042000330209, (22.06.2020.)
459. Škrabić Perić, B. (2012). Utjecaj stranog vlasništva banke na njezin kreditni rizik u zemljama srednje i istočne Europe: dinamički panel modeli. *Doc. dr. sc. Ekonomski fakultet u Splitu*.
460. Sloboda, B. W. (2003). Assessing the effects of terrorism on tourism by use of time series methods. *Tourism Economics*, *9*(2), 179-190., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/000000003101298349, (30.06.2020.)
461. Smeral, E. (2012). International tourism demand and the business cycle. *Annals of Tourism Research*, *39*(1), 379-400., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738311001277?casa_token=2S_w3k6KEogAAAAA:caxEE_12Zdu3OcOoBZ7AL-Sg6RVFbJRKAvkK0EtbCCqt4tv8_M36palbO7ELjVEvI4NbB1c7TH0, (23.06.2020.)
462. Smith, G. P., & Wenger, D. (2007). Sustainable disaster recovery: Operationalizing an existing agenda. In *Handbook of disaster research* (pp. 234-257). Springer, New York, NY., dostupno na: https://link.springer.com/chapter/10.1007/978-0-387-32353-4_14, (01.08.2020.)
463. Smith, R. D. (2006). Responding to global infectious disease outbreaks: lessons from SARS on the role of risk perception, communication and management. *Social science & medicine*, *63*(12), 3113-3123., dostupno na:

https://www.sciencedirect.com/science/article/pii/S0277953606004060?casa_token=ti3y0DFTe7EAAAAA:-yybOl3aQ-vv4z1K893uis1xa8EEmyY2zHjehjzsqr6a3EwzSbmBuBqU1CfCmrQHmYnyNAKiZA, (01.08.2020.)

464. Smith, S. L. (2014). *Tourism analysis: A handbook*. Routledge., dostupno na: Tourism analysis: A handbook, (07.04.2020.)
465. Smith, V. L. (1998). War and tourism: An American ethnography. *Annals of tourism research*, *25*(1), 202-227., https://www.sciencedirect.com/science/article/abs/pii/S0160738397000868, (19.04.2020.)
466. Smith, V. L. (Ed.). (1989). *Hosts and guests: The anthropology of tourism*. University of Pennsylvania Press., dostupno na: Hosts and guests: The anthropology of tourism, (09.04.2020.)
467. Smith, V. L., & Eadington, W. R. (Eds.). (1992). *Tourism alternatives: Potentials and problems in the development of tourism*. University of Pennsylvania Press., dostupno na: Tourism alternatives: Potentials and problems in the development of tourism, (10.04.2020.)
468. Sriskandarajah, D. (2005). Migration and development. *A paper prepared for the Policy Analysis and Research Programme of the Global Commission on International Migration. Global Commission on International Migration, September*., dostupno na: https://www.iom.int/jahia/webdav/site/myjahiasite/shared/shared/mainsite/policy_and_research/gcim/tp/TP4.pdf, (24.07.2020.)
469. Stafford, G., Yu, L., & Armoo, A. K. (2002). Crisis management and recovery how Washington, DC, hotels responded to terrorism. *The Cornell Hotel and Restaurant Administration Quarterly*, *43*(5), 27-40., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0010880402800544, (30.06.2020.)
470. Stepanova, E. A. (2008). *Terrorism in asymmetrical conflict: Ideological and structural aspects* (Vol. 23). Oxford University Press., dostupno na: Terrorism in asymmetrical conflict: Ideological and structural aspects, (14.04.2020.)
471. Stone, P. R. (2006). A dark tourism spectrum: Towards a typology of death and macabre related tourist sites, attractions and exhibitions. *Turizam: međunarodni znanstveno-stručni časopis*, *54*(2), 145-160., dostupno na: https://hrcak.srce.hr/161464, (23.07.2020.)
472. Stone, P. R. (2012). Dark tourism and significant other death: Towards a model of mortality mediation. *Annals of tourism research*, *39*(3), 1565-1587., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0160738312000564, (23.07.2020.)
473. Stone, P., & Sharpley, R. (2008). Consuming dark tourism: A thanatological perspective. *Annals of tourism Research*, *35*(2), 574-595., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738308000261?casa_token=v3wmTXE8SiQAAAAA:nEHMHfVMQSDlHiuzPE93bRM5oUWYzzEIKyG3xGWWPwxaRpxemyv6OyxmqrKi1a65ItztLB_H5_Y, (23.07.2020.)
474. Strange, C., & Kempa, M. (2003). Shades of dark tourism: Alcatraz and Robben Island. *Annals of tourism research*, *30*(2), 386-405., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738302001020?casa_token=OUyuShtDeBcAAAAA:zlBdWzZb4DmhLZOkrKpsmRanRkqOiZ0SE_P84mIm-cUtNy-M2QPitmIDmQUAA-SHUF26JpQzg6w, (23.07.2020.)
475. Strobl, E. (2012). The economic growth impact of natural disasters in developing countries: Evidence from hurricane strikes in the Central American and Caribbean

regions. *Journal of Development economics*, *97*(1), 130-141., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0304387810001331, (01.08.2020.)

476. Strobl, E., Ouattara, B., & Kablan, S. A. (2020). Impact of hurricanes strikes on international reserves in the Caribbean. *Applied Economics*, 1-11., dostupno na: http://apps.webofknowledge.com.ezproxy.nsk.hr/full_record.do?product=WOS&search_mode=GeneralSearch&qid=10&SID=D6C1FBtl8fCBLYUAIyU&page=1&doc=1, (23.03.2020.)
477. Strömberg, D. (2007). Natural disasters, economic development, and humanitarian aid. *Journal of Economic perspectives*, *21*(3), 199-222., dostupno na: https://www.aeaweb.org/articles?id=10.1257/jep.21.3.199, (02.05.2020.)
478. Tan, A. Y., & Wong, K. K. (2003). Structural Change in Hong Kong's Inbound Tourism Demand Model: The Impact of the Asian Financial Crisis. *Tourism Review International*, *7*(3-4), 123-128., dostupno na: https://www.ingentaconnect.com/content/cog/tri/2003/00000007/f0020003/art00002, (22.06.2020.)
479. Tan, A. Y., McCahon, C., & Miller, J. (2002). Modeling tourist flows to Indonesia and Malaysia. *Journal of Travel & Tourism Marketing*, *13*(1-2), 61-82., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J073v13n01_05, (12.08.2020.)
480. Tan, W. K., & Wu, C. E. (2016). An investigation of the relationships among destination familiarity, destination image and future visit intention. *Journal of Destination Marketing & Management*, *5*(3), 214-226., dostupno na: https://www.sciencedirect.com/science/article/pii/S2212571X15000761, (01.08.2020.)
481. Tang, C. H., & Jang, S. (2012). Hedging weather risk in nature-based tourism business: An example of ski resorts. *Journal of Hospitality & Tourism Research*, *36*(2), 143-163., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1096348010388655, (29.07.2020.)
482. Tang, J., Sriboonchitta, S., Ramos, V., & Wong, W. K. (2016). Modelling dependence between tourism demand and exchange rate using the copula-based GARCH model. *Current Issues in Tourism*, *19*(9), 876-894., dostupno na: https://www.tandfonline.com/doi/full/10.1080/13683500.2014.932336, (07.08.2020.)
483. Tarlow, P. E., & Santana, G. (2002). Providing safety for tourists: A study of a selected sample of tourist destinations in the United States and Brazil. *Journal of Travel Research*, *40*(4), 424-431., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287502040004009, (11.07.2020.)
484. Taylor, M. S., & Enz, C. A. (2002). Voice from the field: GMs' responses to the events of September 11, 2001. *The Cornell Hotel and Restaurant Administration Quarterly*, *43*(1), 7-20., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0010880402800040, (30.06.2020.)
485. Taylor, P. A. (2006). Getting them to forgive and forget: Cognitive based marketing responses to terrorist acts. *International Journal of Tourism Research*, *8*(3), 171-183., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.570, (30.06.2020.)
486. Teitler-Regev, S., Shahrabani, S., & Goziker, O. (2014). The effect of economic crises, epidemics and terrorism on tourism. *UTCC International Journal of Business and Economics*, *5*(2), 19-32., dostupno na: http://www.ijbts-journal.com/images/column_1359163804/9%20Sharon.pdf, (02.08.2020.)
487. Thapa, B. (2004). Tourism in Nepal: Shangri-La's troubled times. *Journal of Travel & Tourism Marketing*, *15*(2-3), 117-138., dostupno na: https://www.tandfonline.com/doi/abs/10.1300/J073v15n02_07, (21.07.2020.)

488. Theocharous, A. L. (2010). A contextual typology for the study of the relationship between political instability and tourism. *International Journal of Tourism Policy*, *3*(4), 354-363., dostupno na: https://www.inderscienceonline.com/doi/abs/10.1504/IJTP.2010.040394, (13.07.2020.)
489. Thompson, A. (2011). Terrorism and tourism in developed versus developing countries. *Tourism Economics*, *17*(3), 693-700., dostupno na: https://journals.sagepub.com/doi/abs/10.5367/te.2011.0064, (29.06.2020.)
490. Timothy, D. J. (2006). Safety and security issues in tourism. *Tourism Management Dynamics: Trends, management, and tools*, 19-28., dostupno na: https://books.google.si/books?hl=hr&lr=&id=1KDZdmYp67MC&oi=fnd&pg=PA19&dq=Timothy,+D.J.+2006+safety+and+&ots=n1-eyuAQmP&sig=wyjhWSTbf73urVi9wSCZiT_-LdA&redir_esc=y#v=onepage&q=Timothy%2C%20D.J.%202006%20safety%20and&f=false, (17.07.2020.)
491. Timothy, D. J. (2011). *Cultural heritage and tourism: An introduction* (Vol. 4). Channel View Publications., dostupno na: https://books.google.si/books?hl=hr&lr=&id=oADPBQAAQBAJ&oi=fnd&pg=PR5&dq=timothy+2011+tourism+war&ots=uS7e2-6ZgN&sig=Lo0QQLvnY30CmUumdIUlyfOq4l4&redir_esc=y#v=onepage&q=timothy%202011%20tourism%20war&f=false, (21.07.2020.)
492. Torres-Reyna, O. (2007). Panel data analysis fixed and random effects using Stata (v. 4.2). *Data & Statistical Services, Priceton University*, *112*., dostupno na: https://d1wqtxts1xzle7.cloudfront.net/57152357/-_Panel101-with-cover-page-v2.pdf?Expires=1630921136&Signature=E1q7io5vY2Wsq8m98n0pSBj9XHGkZgPpDVyi6AMjLf2KOayotLbwyy3spLZiSs3eIO6TAtZ4XxWHkQKSwreic4UKB5JCREEMmKuVIirTh-XHbNOPVxvdD6LFFfVQ-5V1P1TjEd336-NqQTBrk9NXPUC~T20hk9scv6sT0dkn6mWCObYPkV~EGJZ5gYOFaFtY5COWPZufdx6Dt5gfE0x7Vj045SUiya0y5e6W5L-m3O4w2RBkfm2Gx~1geDzZ5g7FFpgmMH3AfvB6tA7vyXFl-AgZE3nWzo3isBdQHjU2wpYqUls-LrYI19IfnmxiqntW3Gk356B06qZEfO-qRBXHIA__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA
493. Trenberth, K. E. (2011). Changes in precipitation with climate change. *Climate Research*, *47*(1-2), 123-138., dostupno na: https://www.int-res.com/abstracts/cr/v47/n1-2/p123-138, (01.08.2020.)
494. Tsai, H., Huang, W. J., & Li, Y. (2016). The impact of tourism resources on tourism real estate value. *Asia Pacific Journal of Tourism Research*, *21*(10), 1114-1125., https://doi.org/10.1080/10941665.2015.1107602
495. Tsao, C. Y., & Ni, C. C. (2016). Vulnerability, resilience, and the adaptive cycle in a crisis-prone tourism community. *Tourism Geographies*, *18*(1), 80-105., dostupno na: https://www.tandfonline.com/doi/full/10.1080/14616688.2015.1116600, (01.08.2020.)
496. Tunbridge, J. (2017). Gregory Ashworth: personal reflections from a long partnership. *Tourism Geographies*, *19*(2), 301-304., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/14616688.2017.1283645?journalCode=rtxg20, (23.07.2020.)
497. Tunbridge, J. E., & Ashworth, G. J. (1952). *Dissonant heritage: The management of the past as a resource in conflict*. John Wiley & Sons., dostupno na: https://www.cabdirect.org/cabdirect/abstract/19961802342, (23.07.2020.)

498. Tureac, C. E., & Turtureanu, A. (2010). Types and forms of tourism. *Acta Universitatis Danubius. Œconomica*, *4*(1)., dostupno na: http://www.journals.univ-danubius.ro/index.php/oeconomica/article/view/60, (11.06.2020.)
499. Uriely, N. (2009). „Deconstructing tourist typologies: the case of backpacking“, *International Journal of Culture, Tourism and Hospitality Research*, Vol. 3 No.4, pp. 306-312. dostupno na: https://www.emerald.com/insight/content/doi/10.1108/17506180910994523/full/html, (07.04.2020.)
500. Uriely, N., Maoz, D., & Reichel, A. (2007). Rationalising terror-related risks: The case of Israeli tourists in Sinai. *International Journal of Tourism Research*, *9*(1), 1-8., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1002/jtr.587, (30.06.2020.)
501. Uzuner, G., & Ghosh, S. (2021). Do pandemics have an asymmetric effect on tourism in Italy?. *Quality & Quantity*, *55*(5), 1561-1579., dostupno na: https://link.springer.com/article/10.1007/s11135-020-01074-7, (12.03.2022.)
502. Vanegas Sr, M., & Croes, R. R. (2000). Evaluation of demand: US tourists to Aruba. *Annals of Tourism Research*, *27*(4), 946-963., dostupno na: https://www.sciencedirect.com/science/article/pii/S0160738399001140?casa_token=sWWUVUcefZgAAAAA:nzhVisVP5q3OBrreI0DoQTJN0C6So0dkXJiKmwWYzne8RFG5mIIZmOvHoscQqjLQGIPY1ao, (06.08.2020.)
503. Vanhove, N. (2011). *The economics of tourism destinations*. Routledge., dostupno na: https://books.google.si/books?hl=hr&lr=&id=plDlGVtajnMC&oi=fnd&pg=PR1&dq=Vanhove,+N.+(2005):+The+Economics+of+Tourism+Destinations.+Oxford:+Elsevier&ots=7Sg0N0MNAb&sig=Bs9PtRLxUs-7LcSvhhOWUo6bp8I&redir_esc=y#v=onepage&q=Vanhove%2C%20N.%20(2005)%3A%20The%20Economics%20of%20Tourism%20Destinations.%20Oxford%3A%20Elsevier&f=false, (22.06.2020.)
504. Vellas, F. (2011, October). The indirect impact of tourism: an economic analysis. In *Third Meeting of T20 Tourism Ministers. Paris, France*.
505. Verma, R., Saleh, A. S., & Ihalanayake, R. (2011). Do External Shocks Have a Permanent or a Transitory Effect on Thailand's Tourism Industry?., dostupno na: https://ro.uow.edu.au/cgi/viewcontent.cgi?article=2990&context=commpapers, (23.03.2020.)
506. Vigdor, J. (2008). The economic aftermath of Hurricane Katrina. *Journal of Economic Perspectives*, *22*(4), 135-54., dostupno na: https://www.aeaweb.org/articles?id=10.1257/jep.22.4.135, (01.08.2020.)
507. Vijayamohanan Pillai, N. (2016). Panel data analysis with Stata Part 1 fixed effects and random effects models. *MPRA Paper*, *76869*., https://mpra.ub.uni-muenchen.de/76869/1/MPRA_paper_76869.pdf, (16.08.2021.)
508. Vita, G. D., & Kyaw, K. S. (2013). Role of the exchange rate in tourism demand. *Annals of Tourism Research*, *43*, 624-627., dostupno na: https://www.cabdirect.org/cabdirect/abstract/20133412993, (06.08.2020.)
509. Vogt, M. G. (2008). Determinants of the demand for US exports and imports of tourism. *Applied Economics*, *40*(6), 667-672., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/00036840600749698, (24.07.2020.)
510. Vukadinović, P., Damnjanović, A., & Jovanović, Z. (2017). Position of tourism in global economy and its impact on GDP, employment and investments. *Vojno delo*, *69*(4), 263-278., dostupno na: http://scindeks.ceon.rs/article.aspx?artid=0042-84261704263V, (18.08.2020)

511. Vukonić, B. (2001). Some reflections on tourism, war and peace. *Acta Turistica*, *13*(1), 64-79., dostupno na: https://www.cabdirect.org/cabdirect/abstract/20013105315, (20.08.2020.)
512. Wachinger, G., Renn, O., Begg, C., & Kuhlicke, C. (2013). The risk perception paradox—implications for governance and communication of natural hazards. *Risk analysis*, *33*(6), 1049-1065., dostupno na: https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1539-6924.2012.01942.x, (29.07.2020.)
513. Wahyuni, N. M., & Sara, I. M. (2020). The effect of entrepreneurial orientation variables on business performance in the SME industry context. *Journal of Workplace Learning*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/JWL-03-2019-0033/full/html, (22.06.2020.)
514. Walters, G., Wallin, A., & Hartley, N. (2019). The threat of terrorism and tourist choice behavior. *Journal of travel research*, *58*(3), 370-382., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287518755503, (03.07.2020.)
515. Wang, H. C., Chen, N. H., Lu, C. L., & Hwang, T. C. (2008, November). Tourism demand and exchange rates in Asian countries: New evidence from copulas approach. In *2008 Third International Conference on Convergence and Hybrid Information Technology* (Vol. 2, pp. 1188-1193). IEEE., dostupno na: https://ieeexplore.ieee.org/abstract/document/4682409/, (06.08.2020.)
516. Wang, Y. S. (2009). The impact of crisis events and macroeconomic activity on Taiwan's international inbound tourism demand. *Tourism Management*, *30*(1), 75-82., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517708000800?via%3Dihub, (15.07.2020.)
517. Washer, P. (2004). Representations of SARS in the British newspapers. *Social science & medicine*, *59*(12), 2561-2571., dostupno na: https://www.sciencedirect.com/science/article/pii/S0277953604001704?casa_token=HaAFmbLC8lsAAAAA:qW_yO0xNcvgjmO_RV3xWP1wyUZWV3BZVFqhhF7IhnFtWiJjhd-ENXesv7gsjDzCv7MkVaLU5-w, (01.08.2020.)
518. Watson, J. T., Gayer, M., & Connolly, M. A. (2007). Epidemics after natural disasters. *Emerging infectious diseases*, *13*(1), 1., dostupno na: https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2725828/, (27.04.2020.)
519. Watson, R. (2011). European parliament criticises H1N1 pandemic response. *BMJ: British Medical Journal (Online)*, *342*., dostupno na: https://search.proquest.com/openview/90dcbf1a5f7d13331dacc0c6ef20cabd/1?pq-origsite=gscholar&cbl=2040978, (04.06.2020.)
520. Webber, A. G. (2001). Exchange rate volatility and cointegration in tourism demand. *Journal of Travel research*, *39*(4), 398-405., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/004728750103900406, (23.03.2020.)
521. West, B. (2010). Dialogical memorialization, international travel and the public sphere: A cultural sociology of commemoration and tourism at the First World War Gallipoli battlefields. *Tourist Studies*, *10*(3), 209-225., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/1468797611407756, (21.07.2020.)
522. West, C. T., & Lenze, D. G. (1994). Modeling the regional impact of natural disaster and recovery: A general framework and an application to Hurricane Andrew. *International regional science review*, *17*(2), 121-150., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/016001769401700201, (01.08.2020.)
523. Wickens, E. (2002). The sacred and the profane: A tourist typology. *Annals of tourism research*, *29*(3), 834-851., dostupno na:

https://www.sciencedirect.com/science/article/abs/pii/S0160738301000883, (07.04.2020.)

524. Wilder-Smith, A., Goh, K. T., & Paton, N. I. (2003). Experience of severe acute respiratory syndrome in Singapore: importation of cases, and defense strategies at the airport. *Journal of Travel Medicine*, *10*(5), 259-262., dostupno na: https://academic.oup.com/jtm/article/10/5/259/1847565, (01.08.2020.)
525. Williams, A. M., & Baláž, V. (2013). Tourism, risk tolerance and competences: Travel organization and tourism hazards. *Tourism Management*, *35*, 209-221., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517712001331, (26.06.2020.)
526. Williams, A. M., & Hall, C. M. (2000). Tourism and migration: new relationships between production and consumption. *Tourism geographies*, *2*(1), 5-27., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/146166800363420, (24.07.2020.)
527. Williams, A. M., & Hall, C. M. (2002). Tourism, migration, circulation and mobility. In *Tourism and migration* (pp. 1-52). Springer, Dordrecht., dostupno na: https://link.springer.com/chapter/10.1007/978-94-017-3554-4_1, (26.07.2020.)
528. Williams, K. S. (2012). *Textbook on criminology*. Oxford University Press, USA., dostupno na: Textbook on criminology, (17.04.2020.)
529. Williams, S. (Ed.). (2004). *Tourism: The nature and structure of tourism* (Vol. 1). Taylor & Francis., dostupno na: Tourism: The nature and structure of tourism , (09.04.2020.)
530. Winter, C. (2009). Tourism, social memory and the Great War. *Annals of Tourism Research*, *36*(4), 607-626., dostupno na: https://www.sciencedirect.com/science/article/pii/S016073830900067X?casa_token=7HyF6T1pjy0AAAAA:2IRbFjUG9eT441nK39X4wiGTNZYZgSsNBvwGXZG1rTVPZzvlHhqu6OLBt-13wwi0CCRj1BPvW_Q, (21.07.2020.)
531. Wolfe, N. D., Dunavan, C. P., & Diamond, J. (2007). Origins of major human infectious diseases. *Nature*, *447*(7142), 279-283., dostupno na: https://www.nature.com/articles/nature05775, (04.06.2020.)
532. Wolff, K., & Larsen, S. (2014). Can terrorism make us feel safer? Risk perceptions and worries before and after the July 22nd attacks. *Annals of Tourism Research*, *44*, 200-209., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0160738313001345, (13.06.2020)
533. Wong, P. P. (2004). Environmental impacts of tourism. *A companion to tourism*, 450., dostupno na: https://books.google.si/books?hl=hr&lr=&id=nePEB4e3Y0EC&oi=fnd&pg=PA450&dq=environmental+impacts+of+tourism&ots=62b4AXK9Od&sig=Ux3T5heLiTPJcDzA8SgFJ9JWrUA&redir_esc=y#v=onepage&q=environmental%20impacts%20of%20tourism&f=false, (19.08.2020.)
534. Woodside, A. G., & Martin, D. (Eds.). (2008). *Tourism management: analysis, behaviour and strategy*. Cabi., dostupno na: Tourism management: analysis, behaviour and strategy, (09.04.2020.)
535. Wooldridge, J. M. (2015). *Introductory econometrics: A modern approach*. Cengage learning.
536. Wooldridge, J. M. 2002. Econometric Analysis of Cross Section and Panel Data. *Cambridge, MA: MIT Press*., dostupno na: https://mitpress.mit.edu/books/econometric-analysis-cross-section-and-panel-data-second-edition, (20.09.2021.)
537. Wu, L., & Shimizu, T. (2020). Analyzing dynamic change of tourism destination image under the occurrence of a natural disaster: evidence from Japan. *Current Issues in*

Tourism, 1-17., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/13683500.2020.1747993, (31.07.2020.)

538. Wu, T., Perrings, C., Kinzig, A., Collins, J. P., Minteer, B. A., & Daszak, P. (2017). Economic growth, urbanization, globalization, and the risks of emerging infectious diseases in China: a review. *Ambio*, *46*(1), 18-29., dostupno na: https://link.springer.com/article/10.1007/s13280-016-0809-2, (04.06.2020.)
539. Wu, W., Su, Q., Li, C., Yan, C., & Gozgor, G. (2020). Urbanization, disasters, and tourism development: evidence from RCEP countries. *Sustainability*, *12*(3), 1221., dostupno na: https://www.mdpi.com/2071-1050/12/3/1221, (12.03.2022.)
540. Xiong, Y., Zhang, Y., & Lee, T. J. (2020). The rural creative class: An analysis of in-migration tourism entrepreneurship. *International Journal of Tourism Research*, *22*(1), 42-53., dostupno na: https://onlinelibrary.wiley.com/doi/full/10.1002/jtr.2317, (26.07.2020.)
541. Yan, B. J., Zhang, J., Zhang, H. L., Lu, S. J., & Guo, Y. R. (2016). Investigating the motivation–experience relationship in a dark tourism space: A case study of the Beichuan earthquake relics, China. *Tourism Management*, *53*, 108-121., dostupno na: https://www.sciencedirect.com/science/article/abs/pii/S0261517715300145, (23.07.2020.)
542. Yang, C. L., & Nair, V. (2014). Risk perception study in tourism: Are we really measuring perceived risk. *Procedia-Social and Behavioral Sciences*, *144*(1), 322-327., dostupno na: https://www.researchgate.net/profile/Vikneswaran_Nair/publication/265253207_Risk_Perception_Study_in_Tourism_Are_we_Really_Measuring_Perceived_Risk/links/544fb7730cf201441e934b62.pdf, (15.06.2020.)
543. Yang, E. C. L., & Nair, V. (2014). Tourism at risk: A review of risk and perceived risk in tourism. *Asia-Pacific Journal of Innovation in Hospitality and Tourism (APJIHT)*, *3*(2), 1-21., dostupno na: https://d1wqtxts1xzle7.cloudfront.net/37648420/2014_-_APJIHT.pdf?1431753224=&response-content-disposition=inline%3B+filename%3DTourism_at_risk_A_review_of_risk_and_per.pdf&Expires=1593159867&Signature=Sw0xpWNh~BeT-eExb6evTp7gvZ7Mspyckma0va~h4QvsdRvr2u17Sx2ygF8V5wINf3qdP-lm7XmaYr0A5biNWCSqUAnH~04DsTDbsMkmKYUESXNvSI403xatVdfBVkf017Vgk8LawXWi0WFsk3Xgg-KWInMdG2cayZVY8md2iHsj2zH30Tk7A06jTZsU-6w0wrREZMXtal38KpmF9LVq0ZJchsrlZhHa7Te4AmLfnKWG-kprOm5VLP83ivx1yAIbNna2wzDmKtUX~DcyjRcVPJwUwgl5PAsuoAAGX2ePPYyILc0KeoObzwCKA7ym6JNqB35966JofgjFZgnBhKvEXA__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA, (26.06.2020.)
544. Yang, Y., & Wong, K. K. (2012). The influence of cultural distance on China inbound tourism flows: A panel data gravity model approach. *Asian Geographer*, *29*(1), 21-37., dostupno na: https://www.tandfonline.com/doi/abs/10.1080/10225706.2012.662314, (01.08.2020.)
545. Yap, G., & Saha, S. (2013). Do political instability, terrorism, and corruption have deterring effects on tourism development even in the presence of UNESCO heritage? A cross-country panel estimate. *Tourism Analysis*, *18*(5), 587-599., dostupno na: https://www.ingentaconnect.com/content/cog/ta/2013/00000018/00000005/art00008, (29.06.2020.)
546. Yap, S. A., Ayob, N., & Puah, C. H. (2020). Event Tourism Demand and Selected Macroeconomic Variables: An Econometrics View of the Long-Run and Short-Run Relationships. *International Journal of Business and Society*, *21*(1), 183-196., dostupno

na: https://search.proquest.com/openview/e44f16ffbbe9f138a98439a7c79f398f/1?pq-origsite=gscholar&cbl=28871, (11.08.2020.)

547. Yeoman, I., Galt, M., & McMahon-Beattie, U. (2005). A case study of how VisitScotland prepared for war. *Journal of Travel Research*, *44*(1), 6-20., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/0047287505276587, (03.07.2020.)
548. Yeoman, I., Lennon, J. J., Blake, A., Galt, M., Greenwood, C., & McMahon-Beattie, U. (2007). Oil depletion: What does this mean for Scottish tourism?. *Tourism Management*, *28*(5), 1354-1365., dostupno na: https://www.sciencedirect.com/science/article/pii/S0261517706001828?casa_token=Ewsmj8lyiroAAAAA:QLy_bGm8yrU4qyz_u81CQj2KuWrK3l0ft0_Lj3cAs0ftBY3ytQU1uOGohJGW8lL-vqhKMSMvl3k, (05.06.2007.)
549. Yeung, R. M., & Yee, W. M. (2019). Travel destination choice: does perception of food safety risk matter?. *British Food Journal*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/BFJ-09-2018-0631/full/html, (16.06.2020.)
550. Yoo, C. K., Yoon, D., & Park, E. (2018). Tourist motivation: an integral approach to destination choices. *Tourism review*., dostupno na: https://www.emerald.com/insight/content/doi/10.1108/TR-04-2017-0085/full/html, (10.04.2020.)
551. Yuan, S., & McDonald, C. (1990). Motivational determinates of international pleasure time. *Journal of Travel Research*, *29*(1), 42-44., dostupno na: https://journals.sagepub.com/doi/abs/10.1177/004728759002900109, (10.04.2020.)
552. Zalik, A. (2010). Oil 'futures': Shell's Scenarios and the social constitution of the global oil market. *Geoforum*, *41*(4), 553-564., dostupno na: https://www.sciencedirect.com/science/article/pii/S0016718509001791?casa_token=rE8_GMXWj1YAAAAA:e-iRrFOLk29-xZjZf5YRiVhwRDrEIOBPngi3ywPofR_z1wMbAZwxMseKwBwfKYSOVFynCMbNXlg, (05.06.2020.)
553. Zetter, R. (2007). More labels, fewer refugees: Remaking the refugee label in an era of globalization. *Journal of refugee studies*, *20*(2), 172-192., dostupno na: https://academic.oup.com/jrs/article-abstract/20/2/172/1539814, (21.04.2020.)
554. Zetter, R. (2015). Protection in crisis. *Forced Migration and Protection in a Global Era*., dostupno na: https://domide.colmex.mx/Archivos/Doc_6707.pdf, (21.04.2020.)
555. Zhang, H., Li, L., Yang, Y., & Zhang, J. (2018). Why do domestic tourists choose to consume local food? The differential and non-monotonic moderating effects of subjective knowledge. *Journal of Destination Marketing & Management*, *10*, 68-77., dostupno na: https://www.sciencedirect.com/science/article/pii/S2212571X17302147, (18.06.2020.)
556. Zhao, J., Ding, F., Wang, Z., Ren, J., Zhao, J., Wang, Y., ... & Li, Q. (2018). A rapid public health needs assessment framework for after major earthquakes using high-resolution satellite imagery. *International journal of environmental research and public health*, *15*(6), 1111., dostupno na: https://www.mdpi.com/1660-4601/15/6/1111, (30.07.2020.)
557. Zhang, Y., Xiong, Y., Lee, T. J., Ye, M., & Nunkoo, R. (2021). Sociocultural sustainability and the formation of social capital from community-based tourism. Journal of Travel Research, 60(3), 656-669., dostupno na: https://doi.org/10.1177/004728752093367
558. Zhuang, X., Yao, Y., & Li, J. J. (2019). Sociocultural impacts of tourism on residents of world cultural heritage sites in China. *Sustainability*, *11*(3), 840., dostupno na: https://www.mdpi.com/2071-1050/11/3/840, (19.08.2020.)

Internetski izvori:

1. 9/11 Memorial & Museum: https://www.911memorial.org/connect/blog/reflecting-2018-see-911-memorial-museums-year-review, (23.07.2020.)
2. 9/11 Memorial & Museum: https://www.911memorial.org/connect/blog/reflecting-2018-see-911-memorial-museums-year-review, (23.07.2020.)
3. Amirtha, T. (2015, October 30). Dystopia, death, and the growing popularity of dark tourism. https://www.atlasobscura.com/articles/dystopia-death-and-the-growing-popularity-of-dark-tourism, (23.07.2020.)
4. Annual Energy Review 2006, Figure 5.21" (PDF). U.S. Energy Information Administration, Department of Energy. June 2007. Retrieved 30 May 2016., dostupno na: https://www.eia.gov/totalenergy/data/annual/archive/038406.pdf, (12.08.2020.)
5. Association for Professional in Infection Control and Epidemiology, dostupno na: https://apic.org/monthly_alerts/outbreaks-epidemics-and-pandemics-what-you-need-to-know/, (03.05.2020.)
6. Association for Professional in Infection Control and Epidemiology, dostupno na: https://apic.org/monthly_alerts/outbreaks-epidemics-and-pandemics-what-you-need-to-know/, (03.05.2020.)
7. Auschwitz-Birkenau: http://auschwitz.org/en/museum/news/2-million-320-thousand-visitors-at-the-auschwitz-memorial-in-2019,1400.html, (23.07.2020.)
8. Australian Disaster Resilience: Criminal- Bali Bombings: dostupno na: https://knowledge.aidr.org.au/resources/criminal-bali-bombings/, (12.08.2020.)
9. Australian National University: https://i2s.anu.edu.au/resources/schwartz-theory-basic-values
10. Barnichon, R. 2008. "International Reserves and self-Insurance against External Shocks." IMF Working paper, N° WP/08/149. Washington DC: International Monetary fund. dostupno na: https://www.imf.org/en/Publications/WP/Issues/2016/12/31/International-Reserves-and-Self-Insurance-against-External-Shocks-22001, (20.08.2020.)
11. Becken, S. (2015). What can tourists do to help, not hinder, Nepal's quake recovery?, dostupno na: https://theconversation.com/what-can-tourists-do-to-help-not-hinder-nepals-quake-recovery-41514, (30.07.2020.)
12. Blair, J. (2002, June 29). Tragedy turns to tourism at Ground Zero. The Age, 29. Retrieved from: https://www.theage.com.au/world/tragedy-turns-to-tourism-at-ground-zero-20020629-gducga.html, (23.07.2020.)
13. British Petroleum: Statistical Review of World Energy | Energy economics | Home (bp.com);
14. CDC Centers for Disease Control and Pervention, dostupno na: https://www.cdc.gov/globalhealth/infographics/global-health-security/global-disease-detection-timeline.html, (14.08.2020.)
15. Center for Strategic & International Studies, dostupno na: https://www.csis.org/analysis/worlds-largest-hiv-epidemic-crisis-hiv-south-africa, (03.05.2020.)
16. Center for the Analysis of Terrorism (CAT), 2017. Terrorist Attacks, Failed Attacks and Plots in the West linked to the Syrian - Iraqi Context (2013-2016): http://cat-

int.org/index.php/2017/04/11/terrorist-attacks-failed-attacks-and-plots-in-the-west-linked-to-the-syrian-iraqi-context-2013-2016/?lang=en, (27.06.2020.)
17. Center for the Analysis of Terrorism (CAT), 2017. Terrorist Attacks, Failed Attacks and Plots in the West linked to the Syrian - Iraqi Context (2013-2016): http://cat-int.org/index.php/2017/04/11/terrorist-attacks-failed-attacks-and-plots-in-the-west-linked-to-the-syrian-iraqi-context-2013-2016/?lang=en, (23.07.2020.)
18. Centers for Disease Control and Pervention (CDC), Centers for Disease Control and Pervention, https://www.cdc.gov/globalhealth/infographics/global-health-security/global-disease-detection-timeline.html, (23.01.2020.)
19. Centers for Disease Control and Prevention; Prion Diseases, dostupno na: https://www.cdc.gov/prions/index.html, (16.08.2020.)
20. Centers for Disease Control and Prevention; Prion Diseases, dostupno na: https://www.cdc.gov/prions/index.html, (16.08.2020.)
21. Centers for Disease, Section 11, Epidemic Disease Occurrence, dostupno na: https://www.cdc.gov/csels/dsepd/ss1978/lesson1/section11.html, (03.04.2020.)
22. Chicago Meracantile Exchange. (2005). An introduction to CME weather products: https://www.cmegroup.com/trading/weather/files/WT-124_WeatherBrochure_r11.pdf, (28.07.2020.)
23. Chicago Meracantile Exchange. (2005). An introduction to CME weather products: https://www.cmegroup.com/trading/weather/files/WT-124_WeatherBrochure_r11.pdf, (28.07.2020.)
24. Commonwealth of Australia. 2017. "National Security and Counter Terrorism Law.", dostupno na: https://www.ag.gov.au/NationalSecurity/Counterterrorismlaw/Pages/Australiascounterterrorismlaws.aspx, (14.04.2020.)
25. Council on Foreign Relations, Oil Dependence and U.S. Foreign Policy (1850-2017), https://www.cfr.org/timeline/oil-dependence-and-us-foreign-policy, (02.02.2020.)
26. Derecho- široko rasprostranjena, dugotrajna pravolinijska oluja koja je povezana s brzorastućom skupinom jakih grmljavinskih oluja i pojavom pljuskova. Dostupno na: https://www.weather.gov/lmk/derecho, (16.08.2020.)
27. Dictionary by Farlex: dostupno na: https://medical-dictionary.thefreedictionary.com/Disease+Cluster, (03.05.2020.)
28. Dictionary by Farlex: dostupno na: https://www.dictionary.com/e/epidemic-vs-pandemic/, (03.05.2020.)
29. EIA- U.S. Energy Infromation Administration: https://www.eia.gov/outlooks/steo/report/global_oil.php, (11.08.2020.)
30. EIA, U.S. Energy Infromation Administration: https://www.eia.gov/outlooks/steo/report/global_oil.php, (11.08.2020.)
31. EIA, U.S. Energy Infromation Administration: https://www.eia.gov/outlooks/steo/report/global_oil.php, (11.08.2020.)
32. Encyclopedia Britannica: Arab Oil Embargo, dostupno na: https://www.britannica.com/event/Arab-oil-embargo, (12.08.2020.)
33. Encyclopedia Britannica: Intifada, dostupno na: https://www.britannica.com/topic/intifadah, (12.08.2020.)
34. Enders, W., Sandler, T., & Parise, G. F. (1992). An econometric analysis of the impact of terrorism on tourism. *Kyklos*, *45*(4), 531-554., dostupno na: https://www.cabdirect.org/cabdirect/abstract/19931803541, (28.06.2020.)

35. Energy Information Administration (EIA): https://www.eia.gov/outlooks/steo/data/browser/#/?v=8&f=A&s=&start=2000&end=2021&id=&maptype=0&ctype=linechart&linechart=WTIPUUS
36. Energy Information Administration (EIA): https://www.eia.gov/outlooks/steo/data/browser/#/?v=8&f=A&s=&start=2000&end=2021&id=&maptype=0&ctype=linechart&linechart=WTIPUUS, (11.08.2020.)
37. Europol(2017), "Terrorism situation and trend report (TE SAT)2017", Europol, The Hague, dostupno na: https://www.europol.europa.eu/activities-services/main-reports/eu-terrorism-situation-and-trend-report-te-sat-2017, (12.06.2020.)
38. Federal reserve banko of St. Louis (FRED): https://www.stlouisfed.org/, (11.02.2020)
39. FRED-Economic Research Federal Reserve Bank of St. Louis, dostupno na: https://fred.stlouisfed.org/series/DEXUSEU#0, (18.08.2020)
40. Geomorfologija (geo+mofrologija), znanost o oblicima ili reljefu krute Zemljine površine, njihovu podrijetlu (genezi) i razvoju (morfološkoj evoluciji), dostupno na: https://www.enciklopedija.hr/natuknica.aspx?id=21716, (02.05.2020.)
41. Global Health Data Exchange (GBD): http://ghdx.healthdata.org/gbd-results-tool; http://ghdx.healthdata.org/gbd-results-tool?params=gbd-api-2019-public/4f477b5b2159f265fba5a957e071c3eb;
42. Global terrorism database, dostupno na: https://www.start.umd.edu/gtd/, (13.08.2020.)
43. Global terrorism database, dostupno na: https://www.start.umd.edu/gtd/search/Results.aspx?chart=country&casualties_type=&casualties_max=&count=100, (13.08.2020.)
44. Global Terrorism database: https://gtd.terrorismdata.com/;
45. Global Terrorism Database: https://gtd.terrorismdata.com/app/uploads/_mediavault/securepdfs/2019/10/Codebook.pdf
46. Historical exchange rates: https://fxtop.com/en/historical-exchange-rates.php?A=1&C1=USD&C2=EUR&DD1=&MM1=&YYYY1=1974&B=1&P=&I=1&DD2=&MM2=&YYYY2=2020&btnOK=Go%21, (17.08.2020.)
47. History of war, dostupno na: http://publish.uwo.ca/~acopp2/historyofwar/timeline.html, (17.08.2020)
48. House of Commons_ Migration and Development: How to make migration work povrety reduction: https://publications.parliament.uk/pa/cm200304/cmselect/cmintdev/79/79.pdf, (24.07.2020.)
49. House of Commons_ Migration and Development: How to make migration work povrety reduction: https://publications.parliament.uk/pa/cm200304/cmselect/cmintdev/79/79.pdf, (24.07.2020.)
50. https://books.google.si/books?id=82bTH7oFu-QC&pg=PA1&lpg=PA1&dq=list+of+external+shocks&source=bl&ots=2XETRxWpZb&sig=ACfU3U0HEVkgkGMY_mppl1ZJ5Jd1THsA3w&hl=hr&sa=X&ved=2ahU

KEwj9qKvYoOLoAhVPr4sKHf0kDUY4FBDoATABegQICxAo#v=onepage&q=list%20of%20external%20shocks&f=false

51. ILO (2010) Making migration a development factor: The case of North and West Africa: https://www.ilo.org/wcmsp5/groups/public/---dgreports/---dcomm/documents/publication/wcms_126482.pdf, (24.07.2020.)
52. ILO (International Labour Organization, 2010) Making migration a development factor, The case of North and West Africa, https://www.ilo.org/wcmsp5/groups/public/---dgreports/---dcomm/documents/publication/wcms_126482.pdf, (24.07.2020.)
53. IMF, 2003, "Fund Assistance for Countries Facing Exogenous Shocks", Policy Development and Review Department, *International Monetary Fund*., dostupno na: https://www.imf.org/en/Publications/Policy-Papers/Issues/2016/12/31/Fund-Assistance-for-Countries-Facing-Exogenous-Shocks-PP231, (12.04.2020.)
54. Imperial War Museum (IWM), Time line of 20th and 21st Century Wars: https://www.iwm.org.uk/history/timeline-of-20th-and-21st-century-wars, (13.04.20210)
55. Indeks volatilnosti Cboe Crude Oil ETF mjeri tržišno očekivanje 30-dnevne volatilnosti cijena sirovine nafte primjenom metodologije VIX na američki naftni fond: http://www.cboe.com/products/vix-index-volatility/volatility-on-etfs/cboe-crude-oil-etf-volatility-index-ovx, (05.06.2020.)
56. Institute for 21st Century Energy- Crude Oil Price Volatility: https://www.globalenergyinstitute.org/sites/default/files/file-tool/MetricoftheMonthMAY12CrudeOilPriceVolatility.pdf, (05.06.2020.)
57. International Country Risk Guide Methodology, dostupno na: https://www.prsgroup.com/wp-content/uploads/2012/11/icrgmethodology.pdf, (17.04.2020.)
58. International Country Risk Guide Methodology, dostupno na: https://www.prsgroup.com/wp-content/uploads/2012/11/icrgmethodology.pdf, (17.04.2020.)
59. International disaster database (EM-DAT): https://public.emdat.be/data;
60. International Labor Organization, Economic Crisis, International Tourism Decline and its Impact on the Poor: https://www.ilo.org/wcmsp5/groups/public/---ed_dialogue/---sector/documents/publication/wcms_214576.pdf
61. International migrant stock (2019), https://www.un.org/en/development/desa/population/migration/data/estimates2/estimates19.asp, (02.02.2020.)
62. International Monetary Fund, 2011, "Managing Volatility: A Vulnerability Exercise for LowIncome Countries.", dostupno na: https://www.imf.org/external/np/pp/eng/2011/030911.pdf, (12.04.2020.)
63. International Monetary fund: https://data.imf.org/?sk=4c514d48-b6ba-49ed-8ab9-52b0c1a0179b&sId=1409151240976, (10.02.2020.)
64. International Organization for Migraation (IOM), (2019)., https://www.iom.int/who-is-a-migrant, (21.04.2020.)
65. International Organization for Migraation (IOM), https://www.iom.int/who-is-a-migrant, (21.04.2020.)
66. International Organization for Migration, Glossary on migration, IML Series No. 34, 2019, iml_34_glossary.pdf (iom.int)
67. International Recommendations of Tourism Statistics, 2008; dostupno na: https://unstats.un.org/unsd/publication/seriesm/seriesm_83rev1e.pdf, (11.06.2020.)

68. International Tourism receipts (1995-2018) dostupno na: https://data.worldbank.org/indicator/ST.INT.RCPT.CD (22.03.2020.)
69. Israel Ministry of Foreign Affairs: The Second Lebanon War (2006), dostupno na: https://mfa.gov.il/mfa/aboutisrael/history/pages/hizbullah%20attack%20in%20northern%20israel%20and%20israels%20response%2012-jul-2006.aspx, (12.08.2020.)
70. Lippi, F., & Nobili, A. (2009). Oil and the macroeconomy: A quantitative structural analysis. *Bank of Italy working paper series*, no. 704., https://www.semanticscholar.org/paper/Oil-and-the-Macroeconomy%3A-A-Quantitative-Structural-Lippi-Nobili/dff009ac56cfd2f9c9e10cde26405a980b9e513b, (10.08.2020.)
71. List of wars, dostupno na: https://www.britannica.com/topic/list-of-wars-2031197#ref328529, (17.08.2020.)
72. Making histories:Migration timeline, dostupno na: http://www.makinghistories.org.uk/about-the-project/migration-timeline.html, (17.08.2020.)
73. Međunarodna preporuka za statistiku turizma, (2008) dostupno na: https://unstats.un.org/unsd/publication/Seriesm/SeriesM_83rev1e.pdf#page=26, (24.03.2020.)
74. Merriam-Webster. (2017, 12 18). Definition of terror . Retrieved from MerriamWebster, dostupno na: https://www.merriam-webster.com/dictionary/terror, (14.04.2020.)
75. Merriam-Webster. When does an outbreak become an epidemic?, dostupno na: https://www.merriam-webster.com/words-at-play/spanish-flu, (03.05.2020.)
76. Migration dana portal, dostupno na: https://migrationdataportal.org/data?i=stock_abs_&t=2019#, (17.08.2020.)
77. Migration data portal, https://migrationdataportal.org/data?i=stock_abs_&t=2019#, (08.09.2020.)
78. Migration Report 2017, dostupno na: https://www.un.org/en/development/desa/population/migration/publications/migrationreport/docs/MigrationReport2017_Highlights.pdf, (17.08.2020.)
79. Moufakkir, O., & Kelly, I. (2010). Introduction peace and tourism: friends not foes. *Tourism, progress and peace*., dostupno na: https://www.cabdirect.org/cabdirect/abstract/20103161239, (21.07.2020.)
80. National Ocean Service: What is a Seiche?, dostupno na: https://oceanservice.noaa.gov/facts/seiche.html, (16.08.2020)
81. National Ocean Service: What is a Seiche?, dostupno na: https://oceanservice.noaa.gov/facts/seiche.html, (16.08.2020)
82. National Weather Service: Derecho, dostupno na: https://www.weather.gov/lmk/derecho, (16.08.2020.)
83. National Weather Service: Derecho, dostupno na: https://www.weather.gov/lmk/derecho, (16.08.2020.)
84. Natural catastrophe review: Series of hurricanes makes (2017) year of highest insured losses ever: https://www.munichre.com/us-non-life/en/company/media-relations/press-releases/2018/2018-01-04-natcat-2018.html, (29.07.2020.)
85. Natural catastrophe review: Series of hurricanes makes 2017 year of highest insured losses ever: https://www.munichre.com/us-non-life/en/company/media-relations/press-releases/2018/2018-01-04-natcat-2018.html, (29.07.2020.)
86. Office of the Historian: The First Gulf War, dostupno na: https://history.state.gov/departmenthistory/short-history/firstgulf, (12.08.2020.)
87. Our Worl in Data, https://ourworldindata.org/grapher/crude-oil-prices?time=1974..latest, (02.02.2020.)

88. Oxford, D. (2017, 10 25). English Oxford Living Dictionaries, dostupno na: https://www.lexico.com/definition/terror,(14.04.2020.)
89. Pandemic (definition). The Free Dictionary., dostupno na: https://www.thefreedictionary.com/pandemic, (04.06.2020.)
90. Pandemic (definition): https://www.thefreedictionary.com/pandemic, (04.06.2020.)
91. Panel-data unit-root tests, https://www.stata.com/features/overview/panel-data-unit-root-tests/, (20.02.2022.)
92. Peril Classification and Hazard Glossary: http://www.irdrinternational.org/wp-content/uploads/2014/04/IRDR_DATA-Project-Report-No.-1.pdf, (16.08.2020.)
93. Political Risk Map: https://www.marsh.com/kr/en/insights/research/political-risk-map-2020.html, (22.09.2020.)
94. Priručnik za edukatore, „Zaštita za izbjeglice i ranjive skupine migranata“ (2014), https://www.irh.hr/dokumenti/12-zastita-izbjeglica-i-ranjivih-skupina-migranata-prirucnik-za-edukatore, (21.04.2020.)
95. Priručnik za edukatore, „Zaštita za izbjeglice i ranjive skupine migranata“ (2014:16), https://www.irh.hr/dokumenti/12-zastita-izbjeglica-i-ranjivih-skupina-migranata-prirucnik-za-edukatore, (21.04.2020.)
96. Priručnik za edukatore, „Zaštita za izbjeglice i ranjive skupine migranata“ (2014:16), https://www.irh.hr/dokumenti/12-zastita-izbjeglica-i-ranjivih-skupina-migranata-prirucnik-za-edukatore, (21.04.2020.)
97. Priručnik za edukatore, „Zaštita za izbjeglice i ranjive skupine migranata“ (2014:16), https://www.irh.hr/dokumenti/12-zastita-izbjeglica-i-ranjivih-skupina-migranata-prirucnik-za-edukatore, (21.04.2020.)
98. Ritchie i Roser, (2019) Natural Disasters: https://ourworldindata.org/natural-disasters, (30.07.2020.)
99. Ritchie i Roser, (2019) Natural Disasters: https://ourworldindata.org/natural-disasters, (30.07.2020.)
100. Rogue Waves- Monster of the deep: Huge, freak waves man not be as rare as once thought“-Economist Magazine., dostupno na: https://www.economist.com/science-and-technology/2009/09/17/monsters-of-the-deep, (16.08.2020.)
101. Rogue Waves- Monster of the deep: Huge, freak waves man not be as rare as once thought“-Economist Magazine., dostupno na: https://www.economist.com/science-and-technology/2009/09/17/monsters-of-the-deep, (16.08.2020.)
102. Satellite Account methodology: https://www.oecd.org/cfe/tourism/TSA_EN.pdf;
103. Since 9/11, Terrorism timeline, dostupno na: https://since911.com/explore-911/terrorism-timeline#jump_time_item_686, (13.08.2020.)
104. Since 9/11, Terrorism timeline, https://since911.com/explore-911/terrorism-timeline#jump_time_item_686, (08.09.2020.)
105. Start study of terrorism and responses to terrorism, https://www.start.umd.edu/data-tools/global-terrorism-database-gtd, (08.09.2020.)
106. START_study of terrorism and responses to terrorism, dostupno na: https://www.start.umd.edu/data-tools/global-terrorism-database-gtd, (13.08.2020.)
107. STATA, Panel-data unit-root tests, https://www.stata.com/features/overview/panel-data-unit-root-tests/, (03.03.2022.)

108. STATA: https://www.statista.com/statistics/233223/travel-and-tourism--total-economic-contribution-worldwide/, (22.06.2020.)
109. STATISTA - Total contribution of travel and tourism to gross domestic product (GDP) worldwide from 2006 to 2021: https://www.statista.com/statistics/233223/travel-and-tourism--total-economic-contribution-worldwide/
110. Systemic Risk and Systematic Value: http://www.sr-sv.com/explosive-dynamics-in-exchange-rates/, (07.06.2020.)
111. The Hike in Oil Prices: Speculation – But Not Manipulation". Archived from the original on 18 May 2012. Retrieved 27 December 2008., dostupno na: https://www.spiegel.de/consent-a-?targetUrl=https%3A%2F%2Fwww.spiegel.de%2Finternational%2Fbusiness%2Fthe-hike-in-oil-prices-speculation-but-not-manipulation-a-556519.html&ref=https%3A%2F%2Fwww.google.com%2F, (12.08.2020.)
112. The international disaster database: https://public.emdat.be/data, (16.08.2020.)
113. The international disasters database, EM-DAT Guidelines: https://public.emdat.be/about (20.12.2020.)
114. The UN Refugee Agency: https://www.unhcr.org/refugees.html?gclid=EAIaIQobChMI5b_80_Dl6gIVkakYCh2IhgY3EAAYASAAEgLmevD_BwE, (24.07.2020.)
115. The UN Refugee Agency: https://www.unhcr.org/refugees.html?gclid=EAIaIQobChMI5b_80_Dl6gIVkakYCh2IhgY3EAAYASAAEgLmevD_BwE, (24.07.2020.)
116. The World Bank, Pandemic risk (2013): https://www.worldbank.org/content/dam/Worldbank/document/HDN/Health/WDR14_bp_Pandemic_Risk_Jonas.pdf, (02.08.2020.)
117. Timeline of migration, dostupno na: http://www.globalwords.edu.au/units/Refugees_UPY6_html/documents/Timeline.pdf, (17.08.2020.)
118. Tourism highlight, (2009), UNWTO, dostupno na: https://www.e-unwto.org/doi/pdf/10.18111/9789284413591, (24.03.2020.)
119. Tourism, Instability and Regional Interdependency: Evidence from the Eastern-Mediterranean, dostupno na: https://www.tandfonline.com/doi/abs/10.1080/10242694.2018.1501531, (13.07.2020.)
120. Travel&Tourism, Economic impact (2019) World, dostupno na: https://www.slovenia.info/uploads/dokumenti/raziskave/raziskave/world2019.pdf, (18.08.2020.)
121. True size of border: https://thetruesize.com/#?borders=1~!MTU1NTQ0Njg.NDkxODQyNw*MzIwOTg0MDk(NTM5MzcyMA~!CONTIGUOUS_US*MTAwMjQwNzU.MjUwMjM1MTc(MTc1)MA~!IN*NTI2NDA1MQ.Nzg2MzQyMQ)Mg~!CN*OTkyMTY5Nw.NzMxNDcwNQ(MjI1)MQ
122. U.S. Energy Information Administration (EIA): https://www.eia.gov/outlooks/steo/data/browser/#/?v=8&f=A&s=&start=2000&end=2021&id=&maptype=0&ctype=linechart&linechart=WTIPUUS, (11.08.2020.)
123. UNCTAD, 2002. "The least developed countries report 2002: Escaping the Poverty Trap", United Nations Conference on Trade and Development., dostupno na: https://unctad.org/en/Pages/ALDC/Least%20Developed%20Countries/The-Least-Developed-Countries-Report.aspx, (19.08.2020)

124. United Nations (2017); Migration Report 2017, dostupno na: https://www.un.org/en/development/desa/population/migration/publications/migrationreport/docs/MigrationReport2017_Highlights.pdf, (17.08.2020.)
125. United Nations Office for Disaster Risk Reduction: https://public.emdat.be/about, (16.08.2020.)
126. United Nations Office for Disaster Risk Reduction: https://public.emdat.be/about, (16.08.2020.)
127. United Nations Office for Disaster Risk Reduction: https://public.emdat.be/about, (16.08.2020)
128. United Nations World Tourism Organistion, Tourism and Migration, (2009), https://www.e-unwto.org/doi/pdf/10.18111/9789284413140, (24.07.2020.)
129. United Nations World Tourism Organization (NWTO) Tourism Highlights (2006), https://www.e-unwto.org/doi/pdf/10.18111/9789284413492 , (12.12.2020.)
130. United Nations World Tourism Organization (NWTO) Tourism Highlights (2007), https://www.e-unwto.org/doi/book/10.18111/9789284413539, 12.11.2020.)
131. United Nations World Tourism Organization (NWTO) Tourism Highlights (2008), https://www.e-unwto.org/doi/pdf/10.18111/9789284413560, (12.11.2020.)
132. United Nations World Tourism Organization (NWTO) Tourism Highlights (2010), https://www.e-unwto.org/doi/pdf/10.18111/9789284413720, (02.02.2020.)
133. United Nations World Tourism Organization (NWTO) Tourism Highlights (2009), https://www.e-unwto.org/doi/pdf/10.18111/9789284413591, 02.02.2020.)
134. United Nations World Tourism Organization (NWTO) Tourism Highlights (2017), https://www.e-unwto.org/doi/pdf/10.18111/9789284419029, 15.03.2020.)
135. United Nations World Tourism Organization. (2008). GLOSSARY OF TOURISM TERMS: https://www.unwto.org/glossary-tourism-terms (11.05.2022.)
136. United Nations World Travel & Tourism organization (UNWTO) (2020), https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-03/24-03Coronavirus.pdf, (02.08.2020.)
137. United Nations World Travel & Tourism organization (UNWTO) (2020), https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-03/24-03Coronavirus.pdf, (02.08.2020.)
138. United Nations, International migration report 2017, dostupno na: https://www.un.org/en/development/desa/population/migration/publications/migrationreport/index.asp, (17.08.2020.)
139. United Nations, International migration report 2017, dostupno na: https://www.un.org/en/development/desa/population/migration/publications/migrationreport/index.asp, (17.08.2020.)
140. United Nations, Migration Report (2017), https://www.un.org/en/development/desa/population/migration/publications/migrationreport/docs/MigrationReport2017_Highlights.pdf, (01.08.2020.)
141. United Nations-Total international migrant stock: https://www.un.org/en/development/desa/population/migration/data/estimates2/estimates19.asp;
142. UNWTO- Economic Crisis, International Tourism Decline and its Imapct on the Poor, dostupno na: https://www.ilo.org/wcmsp5/groups/public/---ed_dialogue/---sector/documents/publication/wcms_214576.pdf, (14.08.2020.)
143. UNWTO, World Tourism Baromer (2019), https://www.unwto.org/world-tourism-barometer-2019-nov, (13.05.2021.)

144. UNWTO. (2020b). International tourist arrivals could fall by 20-30% in 2020., https://www.unwto.org/news/international-tourism-arrivals-could-fall-in-2020, (01.08.2020.)
145. UNWTO: Impact assessment of the COVID-19 outbreak on international tourism: https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-03/24-03Coronavirus.pdf, (02.08.2020.)
146. UNWTO: Impact assessment of the COVID-19 outbreak on international tourism: https://webunwto.s3.eu-west-1.amazonaws.com/s3fs-public/2020-03/24-03Coronavirus.pdf, (02.08.2020.)
147. Uppsala Conflict Data Program: https://ucdp.uu.se/;
148. US Department of State. (1996), Patterns of Global Terrorism: 1995. Washington DC: US Department of State. vanRaaij, W. F., and D. A. Francken, dostupno na: https://1997-2001.state.gov/global/terrorism/1996Report/1996index.html, (13.04.2020.)
149. Webster, N. (1828). An American dictionary of the English language (éd. s/n, Vol. I). *New York, US: S. Converse*., dostupno na: http://webstersdictionary1828.com/Dictionary/epidemic, (04.06.2020.)
150. Wendell, R. (2018). Cape town's water crisis hitting tourism: Officials. 2 february 2018. Available (20/04/18), dostupno na: https://www.reuters.com/article/us-safrica-drought-tourism/cape-towns-water-crisis-hitting-tourism-officials-idUSKBN1FM1PO, (30.07.2020.)
151. WHO (2009) No Rationale for Travel Restrictions: https://www.who.int/csr/disease/swineflu/guidance/public_health/travel_advice/en/, (01.08.2020.)
152. WHO MERS Global Summary and Assessment of Risk, dostupno na: https://apps.who.int/iris/bitstream/handle/10665/326126/WHO-MERS-RA-19.1-eng.pdf?ua=1, (14.08.2020.)
153. World Bank, 2004. "Global Monitoring Report. Policies and Actions for Achieving the Mileium Development Goals and Related Outcomes", The International Bank for Reconstruction and Development, Washington, D.C.
154. World Bank, Number of population: https://data.worldbank.org/indicator/SP.POP.TOTL
155. World Bank. (2012). People, pathogens and our planet: Volume 2 – the economics of One Health. World Bank: https://openknowledge.worldbank.org/handle/10986/11892, (02.08.2020.)
156. World Bank: The Great Plunge in Oil Prices: Causes, Consequences and Policy Responses, http://pubdocs.worldbank.org/en/339801451407117632/PRN01Mar2015OilPrices.pdf, (02.02.2020.)
157. World Health Organization (2009) Pandemic Infulenza Preparedness and Response: https://apps.who.int/iris/bitstream/handle/10665/44123/9789241547680_eng.pdf?sequence=1, (04.06.2020.)
158. World Health Organization (WHO). (2009). Pandemic influenza preparedness and response: a WHO guidance document. WHO, dosupno na: https://apps.who.int/iris/bitstream/handle/10665/44123/9789241547680_eng.pdf?sequence=1, (04.06.2020.)
159. World Health Organization, Data and Statistics, https://www.who.int/hiv/data/en/, (08.09.2020.)

160. World Health Organization, Definitions dostupno na: https://www.who.int/hac/about/definitions/en/, (03.05.2020.)
161. World Health Organization, Disease outbreaks, dostupno na: https://www.who.int/environmental_health_emergencies/disease_outbreaks/en/, (03.05.2020.)
162. World health organization, Global Summary and Assessment of Risk, https://apps.who.int/iris/bitstream/handle/10665/326126/WHO-MERS-RA-19.1-eng.pdf?ua=1; https://www.who.int/emergencies/diseases/en/, (08.09.2020.)
163. World Tourism Organisation (UNWTO), Data for Inbound Tourism & Domestic Tourism: https://www.e-unwto.org/toc/unwtotfb/current;
164. World Tourism Organization (2009): https://www.e-unwto.org/doi/pdf/10.18111/9789284413140, (24.07.2020.)
165. World Tourism Organization. (1995b). Concepts, definitions and classifications for tourism statistics. *Madrid: Author*. https://www.e-unwto.org/doi/pdf/10.18111/9789284401031, (06.04.2020.)
166. World Tourism Organization: https://www.e-unwto.org/doi/pdf/10.18111/wtobarometereng.2019.17.1.2, (23.06.2020.)
167. World Tourism Organization: https://www.e-unwto.org/doi/pdf/10.18111/wtobarometereng.2019.17.1.2
168. World Tourism Organization: https://www.unwto.org/glossary-tourism-terms, (06.04.2020)
169. World Trade Statistical Review 2017., dostupno na: https://www.wto.org/english/res_e/statis_e/wts2017_e/wts17_toc_e.htm, (08.06.2020.)
170. World Trade Statistical Review 2017., https://www.wto.org/english/res_e/statis_e/wts2017_e/wts17_toc_e.htm, (08.06.2020.)
171. World Travel & Torurism Council, izravan doprinos turizma https://tool.wttc.org/;
172. World Travel & Tourism Council: https://wttc.org/Research/Economic-Impact
173. World Travel & Tourism Council: https://wttc.org/Research/Economic-Impact, (23.06.2020.)
174. World Travel & Tourism Council: https://wttc.org/Research/Economic-Impact
175. World Travel & Tourism Organization - WTTO: https://tool.wttc.org/, (19.08.2020.)
176. World Travel & Tourism Organization (WTTO), (2019) dostupno na: https://www.slovenia.info/uploads/dokumenti/raziskave/raziskave/world2019.pdf, (18.08.2020.)
177. World Travel and Tourism Council (WTTC). (2018). Travel and Tourism Economic Impact 2018. https://wttc.org/Research/Economic-Impact, (08.06.2020.)
178. World Travel and Tourism Council (WTTC). (2018). Travel and Tourism Economic Impact 2018. https://wttc.org/Research/Economic-Impact, (08.06.2020.)
179. WorldBank data base_Official excange rate: https://data.worldbank.org/indicator/PA.NUS.FCRF
180. WorldBank database, BDP (paritet kupovne moći): https://data.worldbank.org/indicator/NY.GDP.MKTP.PP.KD;
181. WorldBank database, BDP po stanovniku: https://data.worldbank.org/indicator/NY.GDP.PCAP.KD;

182. WorldBank database, Postotak rasta BDP-a godišnje: https://data.worldbank.org/indicator/NY.GDP.MKTP.KD.ZG;

183. WorldBank database-CPI: https://data.worldbank.org/indicator/FP.CPI.TOTL?end=2019&start=1993;

184. WorldBank, (Global Spread Of Conflict By Country And Population) https://datacatalog.worldbank.org/dataset/spread-conflict-data, (11.12.2020.)

185. Worldwide Governance Indicator: https://info.worldbank.org/governance/wgi/

POPIS TABLICA

Tablica 1 Kronološki prikaz eksternih šokova koji su pogodili zemlje SADC-a 22
Tablica 2 Klasifikacija katastrofa 35
Tablica 3 Klasifikacija ekonomskih utjecaja turizma prema World Travel & Tourism Organization 50
Tablica 4 Pozitivni i negativni utjecaji turizma na okoliš 55
Tablica 5 UTJECAJ TURIZMA I MIGRACIJA 69
Tablica 6 Ukupan broj smrtno stradalih od 1974. godine do 2020. godine od prirodnih ili tehnoloških katastrofa 79
Tablica 7 Varijable kvantitativnog istraživanja 93
Tablica 8 Deskriptivna statistika 99
Tablica 9 Rezultati provedene FGLS analize na cjelokupnom uzorku 106
Tablica 10 Rezultati provedene FGLS analize 114
Tablica 11 Rezultati provedene FGLS analize 118
Tablica 12 Granger-ov test uzročnosti 125
Tablica 13 Mapiranje šokova na globalnoj razini kroz povijest 193
Tablica 14 Rezultati F-testa regresijske analize 212
Tablica 15 Rezultati Breusch – Pagana LM testa regresijske analize 212
Tablica 16 Rezultati Hausman testa regresijske analize 212
Tablica 17 Rezultati Woodridge testa 213
Tablica 18 Rezultati VIF- testa 213
Tablica 19 Rezultati Pesaran testa 213
Tablica 20 Rezultati testa Wald testa za testiranje heteroskedastičnosti 213
Tablica 21 Rezultati F-testa regresijske analize 214
Tablica 22 Rezultati Breusch – Pagana LM testa regresijske analize 214
Tablica 23 Rezultati Hausman testa regresijske analize 215
Tablica 24 Rezultati Woodridge i Portmanteau testa 216
Tablica 25 Rezultati VIF- testa 216
Tablica 26 Rezultati Pesaran testa 217
Tablica 27 Rezultati testa Wald testa za testiranje heteroskedastičnosti 217
Tablica 28 Panel analiza sa testovima dijagnostike - Mediteranske zemlje 219
Tablica 29 Rezultati testa jediničnih korijena 220
Tablica 30 PANEL VAR odabir redoslijeda vremenskih pomaka unazad na uzroku procjene 223
Tablica 31 Dekompozicija varijance 227
Tablica 32 Definiranje prirodnih katastrofa 230

POPIS SHEMA

Shema 1 Alocentrična i psihocentrična distribucija 16
Shema 2 Maslow-ljeva hijerarhija potreba 19

POPIS GRAFIKONA

Grafikon 1 Ekonomski doprinos od putovanja i turizma u svjetskom BDP-u od 2006-2019 godine (u milijardama $) 46
Grafikon 2 Radna mjesta generirana izravno, neizravno i potaknuto od strane turizma i putovanja 48
Grafikon 3 Prikaz ukupnog broja terorističkih napada posljednjih 50 godina na svjetskoj razini 56
Grafikon 4 Odlazni turizam- mapa povezivanja migracija i turizma 71
Grafikon 5 Ulazni turizam- mapa povezivanja turizma i migracija 71
Grafikon 6 Dvadeset država u kojima živi najveći broj međunarodnih migranata 2000. godine i 2017. godine (broj migranata u milijunima 73
Grafikon 7 Međunarodna migrantska kretanja tijekom godina 74
Grafikon 8 Predviđanja 2020: Međunarodni turistički dolasci - svijet - (% promjena) . 81
Grafikon 9 Deset godina kontinuiranog rasta turizma 82
Grafikon 10 Kretanje tečaja dolar/euro tijekom godina (1999.-2020) 86
Grafikon 11 Cijena sirove nafte (WTI-west Texas intermediate) po barelu 86
Grafikon 12 Proizvodnja i potrošnja tekućih goriva na svjetskog razini 87
Grafikon 13 Predviđanja svjetske potrošnje sirovih i tekućih goriva 88
Grafikon 14 IMPULSNE REAKCIJE TURIZMA NA TERORISTIČKI NAPAD, ZDRAVSTVENA PITANJA, PRIRODNE KATASTROFE, PROSJEČNU CIJENU NAFTE, VOLATILNOST TEČAJA, POLITIČKU NESTABILNOST I RAT 123
Grafikon 15 Rezultati panel VAR modela 224
Grafikon 16 Uvjet stabilnosti vlastitih vrijednosti 226
Grafikon 17 Evidentirani bombaški napadi odabranih mediteranskih zemalja 228

PRILOG 1 Mapiranje značajnih šokova kroz povijest

U prilogu 1 nalazi se tablica 12 koja prikazuje povijesni prikaz eksternih šokova koji su pogodili određene zemlje ili regije te su uz navedeno prikazani i međunarodnih dolazaka turista iste godine.

Podaci koji se odnose na pitanja vezana uz naftu evidentirana su prema većim šokovima koji su utjecali na cijenu nafte kroz povijest, dakle drastičan rast ili pad cijena nafte uzrokovan raznim krizama kao što su ekonomska/financijska kriza, politički šokovi i slično.

Podaci vezani uz migracije vezani su uz povijesne podatke vezane uz kretanje migranata (izbjeglica) čije je kretanje najčešće uzrokovano ratnim stanjem u državi, prirodnim katastrofama te migriranje u potrazi za boljim životnim uvjetima.

S obzirom na veliku količinu podataka dobivenih od stane GTD, a koji se odnose na terorističke napade kroz povijest sa brojem smrtno stradalih u tabeli su istaknuti teroristički napadi koji su medijski bili popraćeni što je bilo omogućeno uz pomoć informacija dobivenih od strane SINCE 9/11 (dobrotvorna obrazovna organizacija Velike Britanije osnovana na desetu obljetnicu napada 9/11.

Podaci vezani uz zdravstvena pitanja preuzeti su sa stranice WHO, a u tabeli su evidentirane virusne bolesti kako su se pojavljivale po godinama i državama. Nadalje, podaci vezani uz političku nestabilnost i ratove navedeni su redoslijedom kako su se događali te su bili evidentirani kroz povijest po godinama. Vezano uz prirodne katastrofe podaci su kategorizirani na prirodne i tehnološke, a u tabeli su s obzirom na veliku bazu podataka istaknuti oni koji su evidentirali minimalno 1500 smrtnih slučajeva pa na više

Tablica 13 Mapiranje šokova na globalnoj razini kroz povijest

Godina	*Međunarodni dolasci turista u mil*	*% Promjena u odnosu na prethodnu godinu*	*Ekonomska recesija/financijska kriza*	*Pitanja Nafte/Energije*	*Politička pitanja/ratovi/migracije*	*Terorizam*	*Zdravstvena pitanja*	*Prirodne katastrofe*	*Migracije*
1974	205,3		zapadna Europa/ Sjeverna Amerika	Naftna kriza (povećanje cijena za 400%) *Embargo Arabske nafte		Dublin i Monaghan pub bombaški napad, Irska		Poplava u Bangladešu *Potres u Kini *Oluja "Fifi", Honduras, SAD *Potres u Pakistanu, Azija	Ciparski Grci napuštaju otok i migriraju u Britaniju (20 000)
1975	222,3	8%			Libanski građanski rat *Angolanski građanski rat			*Poplava u Kini, Azija *Potres u Kini, Azija *Potres u Turskoj	Preko 90 000 izbjeglica iz Indokina (Vijetnam, Kambodža, Laos) dolaze u Australiju
1976	227,4	2%			Prljavi rat Španjolska Guerra Sucia *Približno 16 000 Linanonskih izbjeglica pobjeglo zbog građanskog rata			*Potres u kineskom Tangshanu *Potres u Guatemala, SAD *Potres na Filipinama, Azija *Potres u Turskoj	
1977	246,1	8%			Kambodžanski-Vijetnamski rat			Tropska oluja u Indiji, Azija *Potres u Romaniji, Europa	

1978	260,1	6%			Početak Afganistanskog rata		Epidemija virusa Encephalitis, Indija, Azija	Oluja u Bangladešu *Poplava u Indiji, Azija *Potres u Iraku, Azija	Vijetnamska migracija u Cardiff
1979	272,1	5%		Energetska kriza (povećanje cijena za 100%)	Revolucija u Iranu, Sovjetski rat u Afganistanu ; USSR upada u Afganistan	Grand Mosque Siege, Mecca (oduzimanje Velike džamije)		Tropska oluja u Dominikanskoj Republici, SAD *Tehnološka nesreća, Kolaps "Dam" u Indiji	Za vrijeme vladavine Sadama Huseina stanovnici Iraka imigriraju u Veliku Britaniju
1980	278,1	2%	SAD		Rat između Iraka i Irana *Građanski rat u Somaliji			*Potres u Algeriji, Afrika *Poplava u Kini, Azija *Poplava u Indiji, Azija *Potres u Italiji, Europa Ekstremne temperature Ujedinjeni narodi, SAD *Suša u Chad, Afrika	Izbjeglice iz Irana stižu u Veliku Britaniju *Kineska migracija u Veliku Britaniju tražeći bolju karijeru *Australska, Novo Zelandska i Južno Afrička imigracija u Veliku Britaniju za boljom karijerom *Somalijska migracija u Veliku Britaniju *Migracija Afganistanaca u Pakistan
1981	278,6	0%	zapadna Europa/ Sjeverna Amerika					Potres u Bangladešu, Azija *Poplava u Kini, Azija *Potres u Iranu, Azija *Potres u Iranu, Azija *Suša u Mozambiku	

1982	276,9	-1%	zapadna Europa/ Sjeverna Amerika		Falklandski rat nazvan još Malvinas ili Južnoatlantski rat između Argenitine i Velike Britanije		Kolera epidemija, Bangladeš, Azija	Poplava u Bangladešu, Azija	
1983	281,8	2%			Građanski rat na Šri Lanki	*Bombaški napad US ambasade, Bejrut *Harrods bombaški napad, London		Suša u Etiopiji, Afrika *Suša u Sudan, Afrika	Rezultat građanskog rata na Šri Lanki bio je odlazak izbjeglica u Veliku Britaniju
1984	306,8	9%					Epidemija Dizenterija u Indiji, Azija *Epidemija Kolera, Mali u Africi	Industrijska nesreća u Bhopalu *Poplava u Bangladešu, Azija *Industrijska nesreča, curenje benzina u Indiji, Azija *Tropska oluja "Ike" na Filipinama u Aziji	
1985	320,1	4%		Pad cijene nafte povezana sa OPEC politikom		Bombaški napad na zrakoplov Air India 182	Epidemija kolere, Etiopija, Afrika * Epidemija virusa Encaphalitis, Indija, Azija Epidemija kolere u Somalia, Afrika	Tropska oluja u Bangladešu, Azija Aktivacija vulkana u Kolumbiji, SAD *Potres u Meksiku, SAD	
1986	330,2	3%					AIDS pandemija *Epidemija "Yellow fever" Nigerija, Afrika *Epidemija kolera u Somaliji, Afrika	Černobilska katastrofa, Ukrajina *Vulkanska aktivnost "Lake Nyos" u Kameronu, Afrika *Potres u El Salvadoru, SAD	Sudanska migracija u Veliku Britaniju

1987	359,7	9%				Bombaški napad trgovačkog centra Hipercor u Barceloni		*Potres na Ekvadoru, SAD *Poplava u Bangdalešu, Azija *Ekstremne temperature-toplinski val u Grčkoj, Europa *Poplave u Indiji, Azija *Transportna nesreća na Filipinama, Azija	
1988	385	7%			Prva intifada		Epidemija Encaphalitis, Indija, Azija *Bakterijska infeskica u Sudanu, Afrika	*Tropska oluja u Bangladešu *Poplava u Bangladešu, Azija *Potres u Kini, Azija *Potres u Sovjetksom savezu, Europa *Epidemija bakterijske zaraze, Etiopija, Afrika	Azija
1989	410,1	7%				Lockerbie bombaški napad na zrakoplov, Škotska	Poplava u Kini, Azija		
1990	439,5	7%	Globalna	Pad cijene nafte zbog američke recesije	Građanski rat u Ruandi			Naftni požar u Kuvajtu *Potres u Iranu, Azija *Potres u Filipinama, Azija	
1991	442,5	1%	Globalna		rat u Perzijskom zaljevu, Perzijski zaljev *Domovinski rat u Hrvatskoj		Kolera (pandemija) Kina, Bangladeš, Bolivia,Nigerija, Kameron, Peru, Kolumbija, Ekvador,	Tropska oluja "Gorky" u Bangladešu *Suša u Kini, Azija *Tropska oluja "Thelma" na Filipinama, Azija	Izbjeglice sa Balkana (Srbija, Hrvatska) sele u zapadnu Europu i Veliku Britaniju *Sukob u Kongu dovodi do iseljavanja ljudi u Veliku Britaniju *Nakon raspada Sovjetskog Saveza, malen broj Mongoljaca seli u Veliku Britaniju

1992	479,8	8%	Globalna		Bosanski rat	Tarata bombaški napad u poslovnom djelu Peruanskog glavnog grada Lime	Epidemija bakterijskog virsa Kolera u Tanzaniji, Afrika		
1993	495,7	3%	Globalna			Bombaški napad ispod World Trade Center, Manhattan, NYC		Potres u Indiji, Azija	
1994	519,8	5%			Građanski rat u Jemanu	*Masakar u Pećini patrijaha, poznat kao masakar Ibrahimi džamije ili masakar Herbona, West Bank *Bombaški napad AMIA na židovski centar Asociacion Israelita Argenitina u Buenos Aires-u	Infekcija virusom Hendra (HeV), (epidemija, Australija) *Epidemija, Parazitska bolest u Kenya, Afrika	Tropska oluja "Gordon" na Haitiju, SAD *Poplava u Indiji, Azija *	Jemanska migracija u Sheffield
1995	540,6	4%				*Bombaški napad u Tokyo podzemnoj željeznici, Japan *Bombaški napad na Alfred P. Murrah Federalnu zgradu u Oklahoma City-u, SAD	Drakunkulija (GWD-GVINEJA CRV BOLEST), Ženeva, Švicarska *Bakterijska zaraza u Niger, Afrika *Kompleksna katastrofa-glad u Koreji, Azija	Potres u Japanu, Azija *Poplava u Indiji, Azija *Potres u Rusiji, Europa	

1996	575	6%			Prvi rat u Kongu	*Kolombo, bombaški napad na Centralnu banku, Šri Lanka *Arndale Centar, Mancehester, Engleska *Parazitska bolest u Zimbabwe, Afrika	Bakterijska zaraza u Burkina Faso, Afrika *Bakterijska zaraza "Cerebro spinal" Nigerija, Afrika Bakterijska zaraza Kolera, Nigerija, Afrika	*Poplava u Kini	
1997	598,6	4%	Azija	Utjecaj azijske krize na pad cijene nafte		Bombaški napad u egipatskom ljetovalištu Luxor, Egipat	Bakterijska zaraza u Burkina Faso, Afrika *Bakterijska zaraza "Cerebro spinal" Nigerija, Afrika Bakterijska zaraza Kolera, Nigerija, Afrika *Baktrijska zaraza Kolerom u Tanzaniji, Afrika	Potres u Iranu, Azija *Poplava u Indiji, Azija *Potres u Iranu, Azija *Poplava u Somaliji, Afrika *Tropska oluja u Vijetnamu, Azija	
1998	616,7	3%	Globalna		Recesija, azijska ekonomska kriza koja je pogodila gospodarstvo tzv. Azijskih tigrova, Azija *Kosovski sukob *Rat između Eritreje i Etiopije	*Bombaški napad na dva istočno Afrička grada, pored ambasade SAD-a, Nairobi i Dar es Salaam *Bombaški napad na Omagh, Sjeverna Irska	Bakterijska zaraza u Mali, Afrika *Akutni dijarejski sindrom u Sudan Afrika	Potres u Afganistanu, Azija *Poplava u Kini, Azija *Potres u Afganistanu, Azija *Poplava u Bangladešu, Azija *Tropska oluja "Mitch", Nikaragva, SAD *Tropska oluja "Mitch" Honduras, SAD *Tropska oluja "03A" u Indiji, Azija *Ekstremne temperature, Indija, Azija *Industrijska nesreća "Oil pipeline" Nigerija, Afrika *Poplava u Pakistanu, Azija *Potres/tsunami u Papa New Guiena, Oceanija	Rat na Kosovu stvara brojne izbjeglice *Etiopska migracija u Sheffield

1999	639,6	4%			Političko gospodarski nemiri na jugoistoku Europe	Bombaški napad na Brixton, Brick Lane i Soho, London ("London nail bomber")	Nipah virus, Malazija, Bangladeš *Bakterijska Meningokokna bolest u Sdan, Afrika	Tropska oluja "05B" u Indiji, Azija *Potres u Turskoj, Azija *Poplava u Venezueli, SAD	Zimbabvejska migracija u Britaniju
2000	687	7%			Druga intifada *Od 2000. godine Australija preuzima migrante iz širokog spektra zemalja: Mjanmar, Afganistan, Sudan, Indiju, Šri Lanku no većina ih je iz Novog Zelanda i Velike Britanije		Groznica Rift Valley (RVF), Subsaharska Afrika, Sjeverna Afrika, Saudijska Arabija, Jemen		
2001	686,7	0%	Globalna		9/11 napad *Afganistanski rat	*9/11 New York, the Pentagon i Pennsylvania, SAD *Američki odgovor na agresiju napadom na Afganistan *"The Shoe Bomber" pokušaj bombaškog napada na američki zrakoplov Flight 63	Izbijanje zarazne bolesti slinavke kod goveda i ovaca u Ujedinjenom Kraljevstvu	Potres u Indiji, Azija	

2002	707	3%	Globalna			*Pasharski masakar u hotelu Park u Netanyi, Izrael, *Bojaya masakar, Kolombia *Bombardiranje Bali, Indonezija *Talačka kriza u Moskvi, Rusija	Epidemija gripe u Kongu, Afrika	Velike poplave u središnjoj Europi *Ekstremne temperature u Indiji, Azija *Eksplozija u Nigeriji, Afrika *Transportna neseća "Ferry Joola" u Senegal, Afrika *Potres u Algeriji, Afrika	
2003	694,6	-2%			*Drugi Perzijski Zaljevski rat *Rat i poratna kriza u Iraku		*SARS (Pandemija) *Majmunska groznica	Potres u Algeriji, Afrika *Ekstremne temperature u Belgiji, Europa *Ekstremne temperature u Švicarskoj, Europa *Ekstremne temperature u Njemačkoj, Europa *Ekstremne temperature u Španjolskoj, Europa *Ekstremne temperature u Franuskoj, Europa *Ekstremne temperature u Indiji, Azija *Ekstremne temperature u Italiji, Europa *Potres u Iranu, Azija *Ekstremne temperature u Portugalu, Europa	Iračka migracija u Britaniju

2004	765,1	10%				*Bombardiranje vlaka, Madrid, Španjolska *Bombardiranje u Ba'qubah, Irak *Opsada škole u Beslanu, Rusija	Epidemija pričje grijep u azijskim zemljama	Plimni val na jugoistoku Azije *Potres i tsunami na Sumatri *Tropska oluja "Jeanne" na Haitiju, SAD *Potres u Indoneziji, Azija *Poplave na Haitiju, SAD *Tsunami u Indiji, Azija *Tropska oluja "Winnie" na Filipinama, Azija *Potres i Tsunami na Tajlandu, Azija *Potres i Tsunami na Šri Lanki, Azija	Istočnoeuropska migracija
2005	806,8	5%			Bombardiranje Bali	*Bombaški napad na javnom prijevozu, London, Engleska *Bombaški napad željezničke pruge u Mumbai, Indija *Bombaški napad u egipatskom ljetovalištu Šarm-el-Šeiku, Egipat *Samoubilački napad na tri hotela u Jordanskom Ammanu, Jordan	Chikungunya virus komaraca (pandemija)	Uragan Katrina na jugu Amerike, SAD *Poplava u Indiji, Azija *Tropska oluja "Stan" u Guatemali, SAD, *Potres u Indiji, Azija *Tehnološka katastrofa u Iraku, Azija *Tropska oluja "Katrina" SAD *Potres u Pakistanu, Azija	
2006	842	4%			Izraelska invazija na Lebanon *Eskalacija sukoba Izraela i Palestine	Bombaški napad u turiskom ljetovalištu Marmarisu, Turska	Epidemija bakterijskog virsa Kolera u Angoli, Afrika	Transportna nesreća "Ferry Al-Salam 98" u Egiptu, Afrika Ekstremne temperature u Francuskoj, Europa *Potres u Indoneziji, Azija *Tropska oluja "Durian" na Filipinama, Azija Ekstremne temperature, Nizozemska *Klizište na Filipinama, Azija	

2007	898	7%			Političko nasilje u Keniji	Bombaški napad na zajednicu Yazidi u gradovima Kahtaniya i Jezeera u Ninawa, Irak	ZIKA virus (epidemija) *Bakterijska bolest Meningococcal " u Burkina Faso, Afrika	Požar na grčkom poluotoku Peloponezu, Grčka *Poplava u Bngladešu, Azija, *Tropska oluja "Sidr" u Bangladešu	
2008	924	3%	Globalna	Cijena nafte viša od 147$	Financijska kriza i recesija u svijetu	*Napad na učenike vjerske škole Mercaz HaRaz yeshiva u Jeruzalemu, Izrael *Niz kooridniranih napada i bombardiranja tijekom četiri dana širom Mumbaija, Indija	Epidemija Meningococcal u Nigeriji, Afrika *Epidemija bakterijke bolest Kolera u Zimbabwe, Afrika	Ekstremne temperature u Afganistanu, Azija Potres u Kini, Azija *Tropska oluja "Cyclone Nargis" u Myanmar, Azija	
2009	880	-5%	Globalna				H1N1 svinjska gripa u Meksiku (pandemija) *Lassa groznica (zapadno afričke zemlje)	Potres u Indoneziji, Azija *Poplava u Indiji, Azija	
2010	953	8%	Globalna	Cijena nafte ponovno oko 80$	Ekonomska kriza u Grčkoj *Arapsko proljeće		Kuga, (Demokratska Republika Kongo, Madagaskar i Peru) *Epidemija bakterijske bolesti Kolera na Haitiju, Amerika *Epidemija bakterijske bolesti Kolera u Nigeriji, Afrika	*Izlijevanje nafte u Meksičkom zaljevu *Erupcija islandskog vulkana Island, svijet *Poplava u Kini, Azija *Potres u Kini, Azija *Klizište u Kini, Azija *Suša u Somalili, Afrika *Potres na Haitiju, Amerika *Poplava u Pakistanu, Azija *Ekstremne temperature u Rusiji, Europa	

2011	998	5%			Sirijski civilni rat	Pucnjava u Beriviku Oslo and Utøya, Norway		Potres i Tsunami u Japanu te eksplozija nuklearne elektrane, Japan *Tropska oluja na Filipinama, Azija	
2012	1045	5%				Bombaški napad na Mayama Mosque, Afganistan	MERS CoV (epidemija) Algeria, Austrija, Bahrain, Kina, Egipat, Francuska, Njemačka, Grčka, Iran, Italija, Jordan, Kuwait, Lebanon, Malaysia, Nizozemska, Oman, Filipine, Katar, Republika Koreja, Sudijska Arabija, Tajland, Tunis, Turska, UK, Arapske Države, SAD, Yemen	*Havarija kruzera Costa Condorida uz talijansku obalu, Italija *uragan Sandy pogodio SAD, Kanadu, Bahame i Karibe *Tropska oluja "Typhoon Bopha" na Filipinama, Azija	
2013	1094	5%			Politički nemiri u Egiptu *Eskalacija građanskog rata u Siriji	*Napad na željezničkoj stanici Kunming u provinciji Yunnan, Kina *Bombaški napad tijekom maratona u Bostonu, SAD *Terorističko ubojstvo Rigby Lee-a, Woolwich, Engleska *Pucnjave u Westgate šoping centru, Nairobi, Kenya		Tropski tajfun i potres na Filipinama *Poplava u Indiji, Azija *Industrijska nesreća, Bangdaleš, Azija *Tropska oluja "Typhoon Haiyan" na Filipinama, Azija	

2014	1138	4%		Pad cijene nafte	Nemiri u Ukrajini, uzrokovane napetosti između NATO-saveza i Ruske Federacije	*Otmica 276 djevojčica iz državne škole Chibok u Nigeriji *Zločin na Sveučilištu Kalifornija u kampusu Santa Barbara, Isla Vista *Napad na vojnu školu na sjeverozapadu Pakistana. Peshawar, Pakistan	Pojava EBOLE u Africi (Gvineja, Liberija, Sijera Leone, Nigerija..)(epidemija)		
2015	1189	4%				*Napad na francuski satirični tjednik Charlie Hebdo u Parizu, Francuska *Napad na trgovinu košer hrane u Parizu Porte de Vincennes, Francuska *Masakar u Sousse plaži, Tunis *Bombaški napad u Bankoku, Tajland *Bombaški napad u Ankari, Turska *Napad na zrakoplov Metrojet 9268, Sinai, Egipat *Bombaški napad na Beirut, Lebanon *Bombaški napadi u blizini Stade de France u Saint-Denisu, Francuska *Pucnjava u San Bernardinu, Kalifornija		Potres u Nepalu, Azija *Ekstremne temperature u Francuskoj, Europa *Ekstremne temperature u Indiji, Azija *Transportna nesreća sa migrantima Libija, Afrika *Ekstremne temperature u Pakistanu, Azija *Tehnološka nesreća "Stampede at la Mecque" u Saudijskoj Arabiji, Azija	Migrantska kriza 2015, Afričkih i Azijskih zemalja u Europu

2016	1235	4%				*Tri bombaška napada: dva u zračnoj luci Brussels u Zaventemu i jedan u metrou Maalebeek u Brusseles, Belgija *Pucnjava u gay noćnom klubu Pulse u Orlandu, Florida, SAD *Ubojstvo Jo Cox, Bristal, West Yorkshire *Napad u pekari Dhaka, Bangladeš *Bombaški napad u Qatif, Medina i Jeddah, Saudijska Arabija *Napad na šetalištu Anglais u Nici, Francuska * Napad na božićnom sajmu u Berlinu, Njemačka	Epidemija Meningitisa u Nigeriji, Afrika		

2017	1332	8%				*Pucnjava u noćnom klubu u Istanbulu *Napad na južnoj strani mosta Westminister, London, Engleska *Bombaški napad u Manchester Areni u Engleskoj za vrijeme koncerta, Engleska *Napad na Londonskom mostu, Engleska *Napad na džamiju Finsbury Park, London, Engleska *Napad na La Ramblas u Barceloni, Španjolska *Bombaški napad u podzemnoj željeznici u Londonu, Engleska *Napad nožem u Marseille, Francuska *Bombaški napad u Somaliji u glavnom gradu Mogadishu, Somalija *Napad na školski bus na Manhattanu, New Yorku, SAD *Bombaški napad u džamiji al Rawda u Bir al-Abedu, Egipat		Klizište blata u Sierra Leone, Afrika	

2018	1407	6%				*Napad u Carcasonne-u i supermarketu u Trèbes, Francuska *Napad kombijem u Torontu, Kanada *Bombaški napad u Surabaya, Indonezija *Napad u Parizu, Francuska *Pucnjava u Liège u Belgiji *Bombaški napad Mastung područja od Balochistan provnicije, Pakistan *Napad u gradu Sweida, Islamska država *Ubojstva četvero stranih biciklista u Danghari u Tadžikistanu *Pucnjava u Synagogi u Pittsburghu, Pennsylvanija	Epidemija virusne bolesti Ebola u Kongu, Afrika	Potres i Tsunami u Indoneziji, Azija	
2019	1461	4%					Covid-19, Pandemija *Epidemija Ospica u Kongu, Afrika	Poplava u Indiji, Azija	

Izvor: United Nations World Tourism Organization (NWTO) Tourism Highlights (2006; 2007; 2008; 2009; 2010; 2017), UNWTO, World Tourism Baromer (2019); Our Worl in Data, World Bank: The Great Plunge in Oil Prices: Causes, Consequences and Policy Responses, Council on Foreign Relations, Oil Dependence and U.S. Foreign Policy (1850-2017), International migrant stock (2019), Britannica, Human migration, Timeline of migration, United Nations, Migration Report (2017), Migration data portal; Global terrorism database (GTD), Since 9/11, Terrorism timeline, Start study of terrorism and responses to terrorism, World Health Organization, Data and Statistics, World health organization, Global Summary and Assessment of Risk, CDC (Centers for Disease Control and Pervention), FRED (Federal reserve banko of St. Louis), International Monetary fund, Imperial War Museum (IWM), Time line of 20th and 21st Century Wars, History of War in the 20th Century, Political Risk Map

PRILOG 2 POPIS SVIH ZEMALJA OBUHVAĆENIH ISTRAŽIVANJEM

Albania
Algeria
Angola
Antigua and Barbuda
Argentina
Armenia
Australia
Austria
Azerbaijan
Bahamas
Bahrain
Bangladesh
Barbados
Belarus
Belgium
Belize
Benin
Bolivia
Bosnia-Herzegovina
Botswana
Brazil
Brunei
Bulgaria
Burkina Faso
Burundi
Cambodia
Cameroon
Canada
Cape Verde
Central African Republic
Chad
Chile
China
Colombia
Comoros
Costa Rica
Côte d'Ivoire
Croatia
Cuba
Cyprus
Czech Republic
Denmark
Dominica
Dominican Republic
Ecuador
Egypt
El Salvador
Estonia
Eswatini
Ethiopia
Fiji
Finland
France
Gabon
Gambia
Georgia
Germany
Ghana
Greece
Grenada
Guatemala
Guinea
Guyana
Haiti
Honduras
Hungary
Iceland
India
Indonesia
Iran
Iraq
Ireland
Israel
Italy
Jamaica
Japan
Jordan
Kazakhstan
Kenya
Kiribati
Kuwait
Kyrgyzstan
Latvia
Lebanon
Lesotho
Libya
Lithuania
Luxembourg
Madagascar

Malawi
Malaysia
Maldives
Mali
Malta
Mauritius
Mexico
Moldova
Mongolia
Montenegro
Morocco
Mozambique
Myanmar
Namibia
Nepal
Netherlands
New Zealand
Nicaragua
Niger
Nigeria
North Macedonia
Norway
Oman
Pakistan
Panama
Papua New Guinea
Paraguay
Peru
Philippines
Poland
Portugal
Puerto Rico
Qatar
Republic of Congo
Romania
Russian Federation
Rwanda
Saudi Arabia
Senegal
Serbia
Seychelles
Sierra Leone
Singapore
Slovakia
Slovenia
Solomon Islands

South Africa
Spain
Sri Lanka
St Kitts and Nevis
St Lucia
St Vincent and the Grenadines
Sudan
Suriname
Sweden
Switzerland
Tajikistan
Tanzania
Thailand
Togo
Tonga
Trinidad and Tobago
Tunisia
Turkey
Uganda
Ukraine
United Arab Emirates
United Kingdom
United States
Uruguay
Uzbekistan
Vanuatu
Venezuela
Vietnam
Yemen
Zambia
Zimbabwe

PRILOG 3 UDIO TURIZMA U STRUKTURI BDP-a (podjela skupova I i II)

Country	Tourism share in GDP
Albania	6,5814928
Algeria	2,0960608
Angola	1,0630238
Antigua and Barbuda	16,44788
Argentina	3,6456148
Armenia	2,9425856
Australia	3,1330984
Austria	6,2628788
Azerbaijan	2,5706956
Bahamas	19,91884
Bahrain	7,3208408
Bangladesh	1,03897372
Barbados	11,5375152
Belarus	2,2301164
Belgium	2,0140628
Belize	9,7448284
Benin	1,9255728
Bolivia	2,344014
Bosnia-Herzegovina	2,78130272
Botswana	3,2908592
Brazil	2,6990476
Brunei	1,7772036
Bulgaria	3,4653292
Burkina Faso	1,22373216
Burundi	1,67512964
Cambodia	9,861918
Cameroon	2,1996936
Canada	1,9374632
Cape Verde	9,1151196
Central African Republic	1,7379952
Chad	0,91574392
Chile	3,2985372
China	2,2238552
Colombia	1,7726772
Comoros	3,0046016
Costa Rica	4,9490504
Côte d'Ivoire	2,7440836
Croatia	9,6133252
Cuba	3,395884
Cyprus	6,2459808
Czech Republic	3,0489868
Denmark	2,1163424
Dominica	13,900052
Dominican Republic	5,835878
Ecuador	3,4631048
Egypt	7,0874332
El Salvador	3,081084
Estonia	5,4752856
Eswatini	2,2215972
Ethiopia	2,6820184
Fiji	7,5793752
Finland	2,4366884
France	3,698946
Gabon	1,24198776
Gambia	3,74468
Georgia	6,4312168
Germany	3,8370664
Ghana	2,0497644
Greece	5,3711296
Grenada	15,808656
Guatemala	2,6245612
Guinea	1,28626508
Guyana	2,8209344
Haiti	3,0486624
Honduras	4,3030752
Hungary	2,624998
Iceland	4,4019244
India	3,5321412
Indonesia	2,4789344
Iran	2,1724224
Iraq	2,5090572
Ireland	1,7509548
Israel	1,9586488
Italy	4,7466372
Jamaica	9,3575412
Japan	2,6086832
Jordan	5,395602
Kazakhstan	1,8125756
Kenya	3,177242
Kiribati	5,661772
Kuwait	2,0411784
Kyrgyzstan	2,942552
Latvia	3,174124
Lebanon	6,722018
Lesotho	4,2370076
Libya	1,46623448
Lithuania	1,9591636

Luxembourg	4,8826732
Madagascar	2,6253364
Malawi	2,3908396
Malaysia	6,0038676
Maldives	23,263316
Mali	2,8179904
Malta	4,424654
Mauritius	7,6377856
Mexico	7,9583704
Moldova	3,2912228
Mongolia	3,1639132
Montenegro	6,8162952
Morocco	5,3037376
Mozambique	2,0203168
Myanmar	1,77634856
Namibia	4,7723784
Nepal	2,6282036
Netherlands	1,9790236
New Zealand	5,3582384
Nicaragua	3,8744792
Niger	1,4671816
Nigeria	1,35978192
North Macedonia	1,36907268
Norway	3,6327236
Oman	3,1559876
Pakistan	1,833528
Panama	4,5871044
Papua New Guinea	1,07366924
Paraguay	1,3549584
Peru	3,4898584
Philippines	7,1911028
Poland	2,2908272
Portugal	4,0162076
Puerto Rico	2,7371548
Qatar	2,17796648
Republic of Congo	1,3528472
Romania	1,6864976
Russian Federation	1,7061932
Rwanda	2,60451944
Saudi Arabia	3,3516132
Senegal	3,288902
Serbia	1,38720508
Seychelles	14,529948
Sierra Leone	1,89731128
Singapore	4,253652
Slovakia	2,1983084
Slovenia	3,5876156
Solomon Islands	2,57781592
South Africa	2,6664376
Spain	5,1736464
Sri Lanka	2,3390392
St Kitts and Nevis	10,3711316
St Lucia	15,214912
St Vincent and the Grenadines	11,05143
Sudan	1,35102016
Suriname	1,7328404
Sweden	2,3019616
Switzerland	2,7091684
Tajikistan	2,707686
Tanzania	3,2488184
Thailand	8,1516448
Togo	1,95951592
Tonga	3,2673612
Trinidad and Tobago	3,1221116
Tunisia	6,0014952
Turkey	3,4422812
Uganda	2,0839132
Ukraine	2,6046496
United Arab Emirates	3,267636
United Kingdom	3,2186228
United States	2,9182816
Uruguay	6,5256544
Uzbekistan	0,97049348
Vanuatu	13,934776
Venezuela	2,7582224
Vietnam	5,56302
Yemen	2,3238244
Zambia	2,3713608
Zimbabwe	2,9673964

PRILOG 4 ODABIR MODELA ZA CJELOKUPAN UZORAK

Tablica 14 Rezultati F-testa regresijske analize

Regresijska analiza baznog modela	
F-test	
Prob>F	0.000
Odabrani model	FE
Regresijska analiza sa uključenim kontrolnim varijablama	
F-test	
Prob>F	0.000
Odabrani model	FE

Izvor: izrada autorice

Tablica 15 Rezultati Breusch – Pagana LM testa regresijske analize

Rezultati Breusch - Pagana LM testa regresijske analize baznog modela	
Prob>chibar2	0.000
Odabrani model	RE
Rezultati Breusch - Pagana LM testa regresijske analize s uključenim kontrolnim varijablama	
Prob>chibar2	0.000
Odabrani model	RE

Izvor: izrada autorice

Tablica 16 Rezultati Hausman testa regresijske analize

Rezultati Hausman testa regresijske analize baznog modela	
Prob>chi2	0.000
Odabrani model	FE
Rezultati Hausman testa regresijske analize baznog modela s uključenim kontrolnim varijablama	
Prob>chi2	0.000
Odabrani model	FE

Izvor: izrada autorice

PRILOG 5 TESTOVI DIJAGNOSTIKE ZA CJELOKUPAN UZORAK

Tablica 17 Rezultati Woodridge testa

Rezultati Wooldridge testa baznog modela	
Prob>chi-sq	0.000
Rezultati Wooldridge testa s uključenim kontrolnim varijablama	
Prob>chi-sq	0.000

Izvor: izrada autorice

Tablica 18 Rezultati VIF- testa

Rezultati VIF testa baznog modela	
Mean VIF	1.61
Rezultati VIF testa s uključenim kontrolnim varijablama	
Mean VIF	1.77

Izvor: izrada autorice

Tablica 19 Rezultati Pesaran testa

Rezultati Pesaran testa baznog modela	
Prob>chi-sq	0.000
Rezultati Pesaran testa s uključenim kontrolnim varijablama	
Prob>chi-sq	0.000

Tablica 20 Rezultati testa Wald testa za testiranje heteroskedastičnosti

Rezultati modificiranog Wald testa regresijske analize baznog modela	
Prob>chi2	0.000
Rezultati modificiranog Wald testa regresijske analize s uključenim kontrolnim varijablama	
Prob>chi2	0.000

PRILOG 6 ODABIR MODELA PREMA SKUPINAMA

Tablica 21 Rezultati F-testa regresijske analize

Regresijska analiza baznog modela		
F-test	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>F	0.0000	0.0000
Odabrani model	FE	FE
Regresijska analiza sa uključenim kontrolnim varijablama		
F-test	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>F	0.0000	0.0000
Odabrani model	FE	FE
Regresijska analiza baznog modela sa uključenom varijablom migracije temeljeno na petogodišnjim panel podacima		
F-test	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>F	0.0000	0.0651
Odabrani model	FE	OLS
Regresijska analiza modela sa uključenim kontrolnim varijablama i varijablom migracije temeljeno na petogodišnjim panel podacima		
F-test	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>F	0.0000	0.4881
Odabrani model	FE	OLS

Izvor: izrada autorice

Tablica 22 Rezultati Breusch – Pagana LM testa regresijske analize

Rezultati Breusch - Pagana LM testa regresijske analize baznog modela		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chibar2	0.0000	0.0000
Odabrani model	RE	RE
Rezultati Breusch - Pagana LM testa regresijske analize s uključenim kontrolnim varijablama		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chibar2	0.0000	0.0000
Odabrani model	RE	RE
Rezultati Breusch – Pagana LM testa regresijske analize baznog modela sa uključenom varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chibar2	0.0000	0.0000
Odabrani model	RE	RE

Rezultati Breusch – Pagana LM testa regresijske analize modela sa uključenim kontrolnim varijablama i varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chibar2	0.0000	0.0000
Odabrani model	RE	RE

Napomena: Nulta hipoteza u LM testu je da su varijance između entiteta nula.

Izvor: izračun autorice.

Tablica 23 Rezultati Hausman testa regresijske analize

Rezultati Hausman testa regresijske analize baznog modela		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi2	0.0000	0.0000
Odabrani model	FE	FE
Rezultati Hausman testa regresijske analize baznog modela s uključenim kontrolnim varijablama		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi2	0.0276	0.1272
Odabrani model	FE	RE
Rezultati Hausman testa regresijske analize baznog modela sa uključenom varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi2	0.0100	0.5840
Odabrani model	FE	RE
Rezultati Hausman testa regresijske analize modela sa uključenim kontrolnim varijablama i varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi2	0.0214	0.4026
Odabrani model	FE	RE

Izvor: izračun autorice

PRILOG 7 TESTOVI DIJAGNOSTIKE (PREMA SKUPINAMA)

Tablica 24 Rezultati Woodridge i Portmanteau testa

Rezultati Wooldridge testa baznog modela		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi-sq	0.0000	0.0000
Rezultati Wooldridge testa s uključenim kontrolnim varijablama		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi-sq	0.0000	0.0000
Rezultati Portmanteau testa baznog modela sa uključenom varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi-sq	1.0000	1.0000
Rezultati Portmanteau testa modela sa uključenim kontrolnim varijablama i varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi-sq	1.0000	1.0000

Izvor: izračun autorice

Tablica 25 Rezultati VIF- testa

Rezultati VIF testa baznog modela		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Mean VIF	1.57	2.05
Rezultati VIF testa s uključenim kontrolnim varijablama		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Mean VIF	1.77	2.67
Rezultati VIF testa baznog modela sa uključenom varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Mean VIF	1.88	2.03
Rezultati VIF testa modela sa uključenim kontrolnim varijablama i varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka

Mean VIF	2.04	7.15

Izvor: izračun autorice

Tablica 26 Rezultati Pesaran testa

Rezultati Pesaran testa baznog modela		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi-sq	0.0000	0.0000
Rezultati Pesaran testa s uključenim kontrolnim varijablama		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi-sq	0.0000	0.0000
Rezultati Pesaran testa baznog modela sa uključenom varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi-sq	0.0000	0.0000
Rezultati Pesaran testa modela sa uključenim kontrolnim varijablama i varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi-sq	0.0000	0.0000

Izvor: izračun autorice

Tablica 27 Rezultati testa Wald testa za testiranje heteroskedastičnosti

Rezultati modificiranog Wald testa regresijske analize baznog modela		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi2	0.0000	0.0000
Rezultati modificiranog Wald testa regresijske analize s uključenim kontrolnim varijablama		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi2	0.0000	0.0000
Rezultati modificiranog Wald testa baznog modela sa uključenom varijablom migracije temeljeno na petogodišnjim panel podacima		
	I skup podjele uzorka podataka	II skup podjele uzorka podataka

Prob>chi2	0.0000	0.9982

Rezultati modificiranog Wald testa modela sa uključenim kontrolnim varijablama i varijablom migracije temeljeno na petogodišnjim panel podacima

	I skup podjele uzorka podataka	II skup podjele uzorka podataka
Prob>chi2	0.0000	0.0000

Izvor: izračun autorice

PRILOG 8 ODABIR MODELA I TESTOVI DIJAGNOSTIKE (ZA MEDITERANSKE ZEMLJE)

Tablica 28 Panel analiza sa testovima dijagnostike - Mediteranske zemlje

Regresijska analiza modela		
	MODEL 1	**MODEL 2**
F- test	Regresijska analiza bazni model	Regresijska analiza model sa uključenim kontrolnim varijablama
Prob>F Odabrani model	0.000 FE	0.000 FE
Rezultati Breusch - Pagana LM testa regresijske analize modela		
	Regresijska analiza bazni model	Regresijska analiza model sa uključenim kontrolnim varijablama
Prob>F Odabrani model	0.000 RE	0.000 RE
Rezultati Hausman testa regresijske analize modela		
	Hausman test bazni model	Hausman test model s uključenim kontrolnim varijablama
Prob>chi2 Odabrani model	0.000 FE	0.0059 FE
Rezultati Wooldridge testa		
	Wooldridge test bazni model	Wooldridge test model s uključenim kontrolnim varijablama
Prob>chi-sq	0.5737	0.9620
Rezultati VIF testa		
	VIF test bazni model	VIF test s uključenim kontrolnim varijablama
Mean VIF	1.95	4.84
Rezultati Pesaran testa		
	Pesaran test bazni model	Pesaran test model s uključenim kontrolnim varijablama
Prob>chi-sq	0.000	0.000
Rezultati modificiranog Wald testa regresijske analize		
	Wald test bazni model	Wald test model s uključenim kontrolnim varijablama
Prob>chi2	0.000	0.000

Izvor: izračun autorice

PRILOG 9 REZULTATI TESTA JEDINIČNIH KORIJENA (*UNIT ROOT TEST)*

Tablica 29 Rezultati testa jediničnih korijena

xtunitroot fisher lnTTons, dfuller drift lags(1) (577 missing values generated)		
Fisher-type unit-root test for lnTTons Based on augmented Dickey-Fuller tests		
Ho: All panels contain unit roots	Number of panels = 164	
Ha: At least one panel is stationary	Avg. number of periods = 22.09	
AR parameter: Panel-specific	Asymptotics: T -> Infinity	
Panel means: Included		
Time trend: Not included		
Drift term: Included	ADF regressions: ***1 lag***	
	Statistic	***p-value***
Inverse chi-squared(326) P	814.1411	0.0000
Inverse normal Z	-13.7805	0.0000
Inverse logit t(819) L*	-14.8248	0.0000
Modified inv. chi-squared Pm	19.1171	0.0000
P statistic requires number of panels to be finite.		
Other statistics are suitable for finite or infinite number of panels.		

xtunitroot fisher lnHQnd, dfuller drift lags(1) (75 missing values generated)		
Fisher-type unit-root test for lnHQnd Based on augmented Dickey-Fuller tests		
Ho: All panels contain unit roots	Number of panels = 165	
Ha: At least one panel is stationary	Avg. number of periods = 25	
AR parameter: Panel-specific	Asymptotics: T -> Infinity	
Panel means: Included		
Time trend: Not included		
Drift term: Included	ADF regressions: ***1 lag***	
	Statistic	***p-value***
Inverse chi-squared(330) P	921.8010	0.0000
Inverse normal Z	-15.0488	0.0000
Inverse logit t(829) L*	-16.5290	0.0000
Modified inv. chi-squared Pm	23.0358	0.0000
P statistic requires number of panels to be finite.		
Other statistics are suitable for finite or infinite number of panels.		

xtunitroot fisher lnAPO, dfuller drift lags(1) (391 missing values generated) could not compute test for panel 5	
Fisher-type unit-root test for lnAPO Based on augmented Dickey-Fuller tests	
Ho: All panels contain unit roots	Number of panels = 162
Ha: At least one panel is stationary	Avg. number of periods = 23.51

AR parameter: Panel-specific	Asymptotics: T -> Infinity	
Panel means: Included		
Time trend: Not included		
Drift term: Included	ADF regressions: ***1 lag***	
	Statistic	***p-value***
Inverse chi-squared(322) P	976.8411	0.0000
Inverse normal Z	-20.1303	0.0000
Inverse logit t(809) L*	-20.5015	0.0000
Modified inv. chi-squared Pm	25.8044	0.0000
P statistic requires number of panels to be finite.		
Other statistics are suitable for finite or infinite number of panels.		

xtunitroot fisher lnVER, dfuller drift lags(1)		
(393 missing values generated)		
Fisher-type unit-root test for lnVER		
Based on augmented Dickey-Fuller tests		
Ho: All panels contain unit roots	Number of panels = 166	
Ha: At least one panel is stationary	Avg. number of periods = 22.93	
AR parameter: Panel-specific	Asymptotics: T -> Infinity	
Panel means: Included		
Time trend: Not included		
Drift term: Included	ADF regressions: ***1 lag***	
	Statistic	***p-value***
Inverse chi-squared(284) P	1015.5697	0.0000
Inverse normal Z	-20.0103	0.0000
Inverse logit t(714) L*	-20.0103	0.0000
Modified inv. chi-squared Pm	30.6960	0.0000
P statistic requires number of panels to be finite.		
Other statistics are suitable for finite or infinite number of panels.		

xtunitroot fisher PII, dfuller drift lags(1)		
(691 missing values generated)		
Fisher-type unit-root test for PII		
Based on augmented Dickey-Fuller tests		
Ho: All panels contain unit roots	Number of panels = 168	
Ha: At least one panel is stationary	Avg. number of periods = 20.89	
AR parameter: Panel-specific	Asymptotics: T -> Infinity	
Panel means: Included		
Time trend: Not included		
Drift term: Included	ADF regressions: ***1 lag***	
	Statistic	***p-value***
Inverse chi-squared(336) P	1165.7513	0.0000
Inverse normal Z	-22.4344	0.0000
Inverse logit t(844) L*	-24.0315	0.0000
Modified inv. chi-squared Pm	32.0084	0.0000
P statistic requires number of panels to be finite.		
Other statistics are suitable for finite or infinite number of panels.		

xtunitroot fisher lnTAnd, dfuller drift lags(1)		
(2,386 missing values generated)		
Fisher-type unit-root test for lnTAnd		
Based on augmented Dickey-Fuller tests		
Ho: All panels contain unit roots	Number of panels = 148	
Ha: At least one panel is stationary	Avg. number of periods = 12.26	
AR parameter: Panel-specific	Asymptotics: T -> Infinity	
Panel means: Included		
Time trend: Not included		
Drift term: Included	ADF regressions: ***1 lag***	
	Statistic	***p-value***
Inverse chi-squared(158) P	506.3399	0.0000
Inverse normal Z	-14.2348	0.0000
Inverse logit t(399) L*	-15.0399	0.0000
Modified inv. chi-squared Pm	19.5956	0.0000
P statistic requires number of panels to be finite.		
Other statistics are suitable for finite or infinite number of panels.		

xtunitroot fisher lnNDnd, dfuller drift lags(1)		
(1,239 missing values generat		
Fisher-type unit-root test for lnNDnd		
Based on augmented Dickey-Fuller tests		
Ho: All panels contain unit roots	Number of panels = 167	
Ha: At least one panel is stationary	Avg. number of periods = 17.73	
AR parameter: Panel-specific	Asymptotics: T -> Infinity	
Panel means: Included		
Time trend: Not included		
Drift term: Included	ADF regressions: ***1 lag***	
	Statistic	***p-value***
Inverse chi-squared(232) P	1143.3356	0.0000
Inverse normal Z	-24.8956	0.0000
Inverse logit t(584) L*	-28.9518	0.0000
Modified inv. chi-squared Pm	42.3077	0.0000
P statistic requires number of panels to be finite.		
Other statistics are suitable for finite or infinite number of panels.		

Izvor: izračun autorice

PRILOG 10 PANEL VAR odabir redoslijeda vremenskih pomaka unazad na uzroku procjene

Tablica 30 PANEL VAR odabir redoslijeda vremenskih pomaka unazad na uzroku procjene

Varijabla: teroristički napad (lnTAnd)

lag	CD	J	J pvalue	MBIC	MAIC	MQIC
1	**.9979959**	**14.42105**	**.5673779**	**-77.15632**	**-17.57895**	**-41.40601**
2	.9972645	9.619042	.6493423	-59.06398	-14.38096	-32.25125
3	.9937019	.5755723	.9997727	-45.21311	-15.42443	-27.33795
4	.9870098	.1103872	.9985317	-22.78395	-7.889613	-13.84638

Varijabla: prosječna cijena nafte (lnAPO)

lag	CD	J	J pvalue	MBIC	MAIC	MQIC
1	.9951565	145.4112	6.25e-23	25.0788	113.4112	80.8458
2	.9926235	69.78533	3.51e-10	-20.46399	45.78533	21.36126
3	.9906024	43.18393	8.11e-07	-16.98228	27.18393	10.90122
4	**.9251366**	**5.842188**	**.2112478**	**-24.24092**	**-2.157812**	**-10.29917**

Varijabla: rat (lnWar)

lag	CD	J	J pvalue	MBIC	MAIC	MQIC
1	**.9929319**	**17.74007**	**.3393361**	**-104.5096**	**-14.25993**	**-47.33118**
2	.9876379	8.26441	.7641413	-83.42284	-15.73559	-40.53903
3	.9794718	3.441224	.9037031	-57.68361	-12.55878	-29.0944
4	.9421323	1.65311	.7992165	-28.90931	-6.34689	-14.6147

Varijabla: volatilnost tečaja (lnVER)

lag	CD	J	J pvalue	MBIC	MAIC	MQIC
1	**.9999523**	**12.89572**	**.6803663**	**-107.0862**	**-19.10428**	**-51.57635**
2	.9999461	7.577297	.81723	-82.40914	-16.4227	-40.77676
3	.9999324	3.123428	.9263745	-56.86753	-12.87657	-29.11261
4	.9999162	2.622093	.6229146	-27.37339	-5.377907	-13.49593

Varijabla: prirodne katastrofe (lnNDnd)

lag	CD	J	J pvalue	MBIC	MAIC	MQIC
1	**.9922895**	**7.265397**	**.9678**	**-99.11836**	**-24.7346**	**-53.35746**
2	.9870993	3.520893	.9906157	-76.26692	-20.47911	-41.94625
3	.9728438	1.803915	.9864444	-51.38796	-14.19609	-28.50751
4	.9496959	1.24143	.8712314	-25.35451	-6.75857	-13.91428

Varijabla: prosječna cijena nafte (lnHQnd)

lag	CD	J	J pvalue	MBIC	MAIC	MQIC
1	.9999983	45.90553	.0001007	-76.01791	13.90553	-19.08021
2	**.9999976**	**5.215541**	**.9503894**	**-86.22704**	**-18.78446**	**-43.52377**
3	.9999929	.0656169	1	-76.13653	-19.93438	-40.55047
4	.9999963	.0346732	.9999991	-45.68662	-11.96533	-24.33498

Varijabla: politička nestabilnost (PII)

lag	CD	J	J pvalue	MBIC	MAIC	MQIC
1	**.9996396**	**13.28908**	**.6515151**	**-98.94795**	**-18.71092**	**-49.04769**
2	.9996336	8.040538	.7819545	-76.13723	-15.95946	-38.71204
3	.999573	6.35228	.6078352	-49.76624	-9.64772	-24.81611
4	.9980109	6.077426	.1934402	-21.98183	-1.922574	-9.506768

Izvor: izračun autorice

PRILOG 11 PANEL VAR MODELI REZULTATI

Grafikon 15 Rezultati panel VAR modela

MODEL 1		
VARIABLES	(1) lnTTons	(2) lnTAnd
L.lnTTons	0.992***	0.439
	(0.0264)	(0.282)
L.lnTAnd	-0.00897	0.257***
	(0.00596)	(0.0712)
Observations	668	668

MODEL 2		
VARIABLES	(1) lnTTons	(2) lnHQnd
L.lnTTons	0.991***	-0.0257*
	(0.0205)	(0.0142)
L.lnHQnd	0.0654	0.897***
	(0.0668)	(0.0542)
Observations	2,867	2,867

Standardne greške (zagrada)
*** p<0.01, ** p<0.05, * p<0.1

MODEL 3		
VARIABLES	(1) lnTTons	(2) lnAPO
L.lnTTons	0.988***	-0.140***
	(0.0234)	(0.0352)
L.lnAPO	0.0142	0.781***
	(0.0428)	(0.0544)
Observations	2,635	2,635

MODEL 4		
VARIABLES	(1) lnTTons	(2) lnNDnd
L.lnTTons	0.955***	-0.983***
	(0.0269)	(0.189)
L.lnNDnd	-0.00861**	0.0576
	(0.00437)	(0.0544)
Observations	1,373	1,373

Standardne greške (zagrada)
*** p<0.01, ** p<0.05, * p<0.1

MODEL 5		
VARIABLES	(1) lnTTons	(2) lnVER
L.lnTTons	0.975***	0.0276
	(0.0399)	(0.0199)
L.lnVER	0.0206	0.925***
	(0.0793)	(0.0452)
Observations	2,578	2,578

MODEL 6		
VARIABLES	(1) lnTTons	(2) PII
L.lnTTons	0.966***	-0.0163
	(0.0380)	(0.0219)
L.PII	-0.00787	0.894***
	(0.0662)	(0.0547)
Observations	1,909	1,909

Standardne greške (zagrada)
*** p<0.01, ** p<0.05, * p<0.1

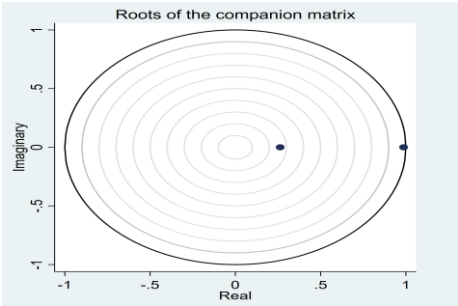
MODEL 7		
VARIABLES	(1) lnTTons	(2) lnWar
L.lnTTons	0.978***	-0.0234*
	(0.0172)	(0.0139)
L.lnWar	-0.0209	0.128***
	(0.0255)	(0.0493)
Observations	2,924	2,924

Standardne greške (zagrada)
*** p<0.01, ** p<0.05, * p<0.1

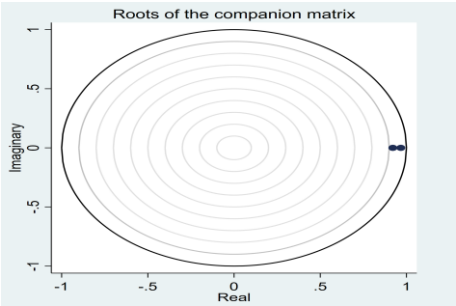
PRILOG 12 PROCJENA STABILNOSTI VAR MODELA

Grafikon 16 Uvjet stabilnosti vlastitih vrijednosti

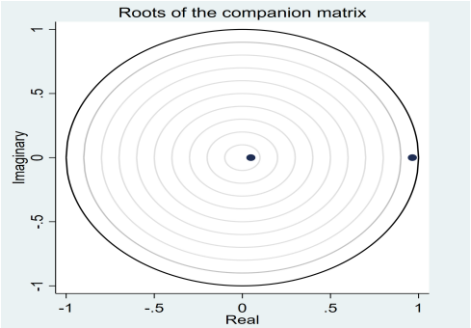
lnTTons, lnTAnd



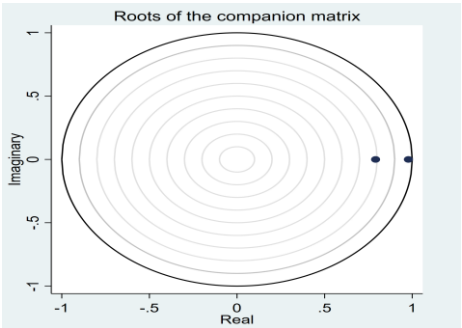
lnTTons, lnHQnd



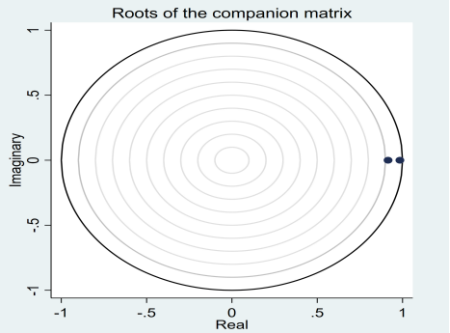
lnTTons, lnNDnd



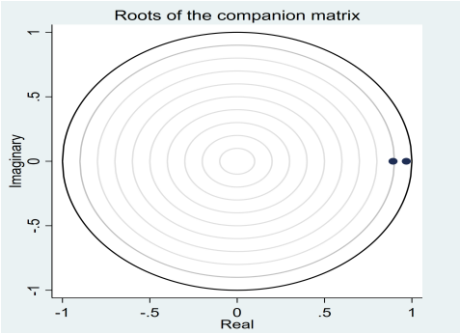
lnTTons, lnAPO



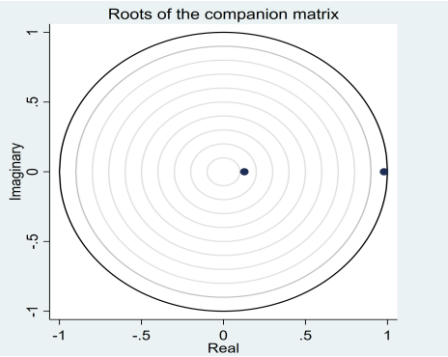
lnTTons, lnVER



lnTTons, PII



lnTTons, lnWar



Izvor: izračun autorice

PRILOG 13 DEKOMPOZICIJA VARIJANCE (FEVD)

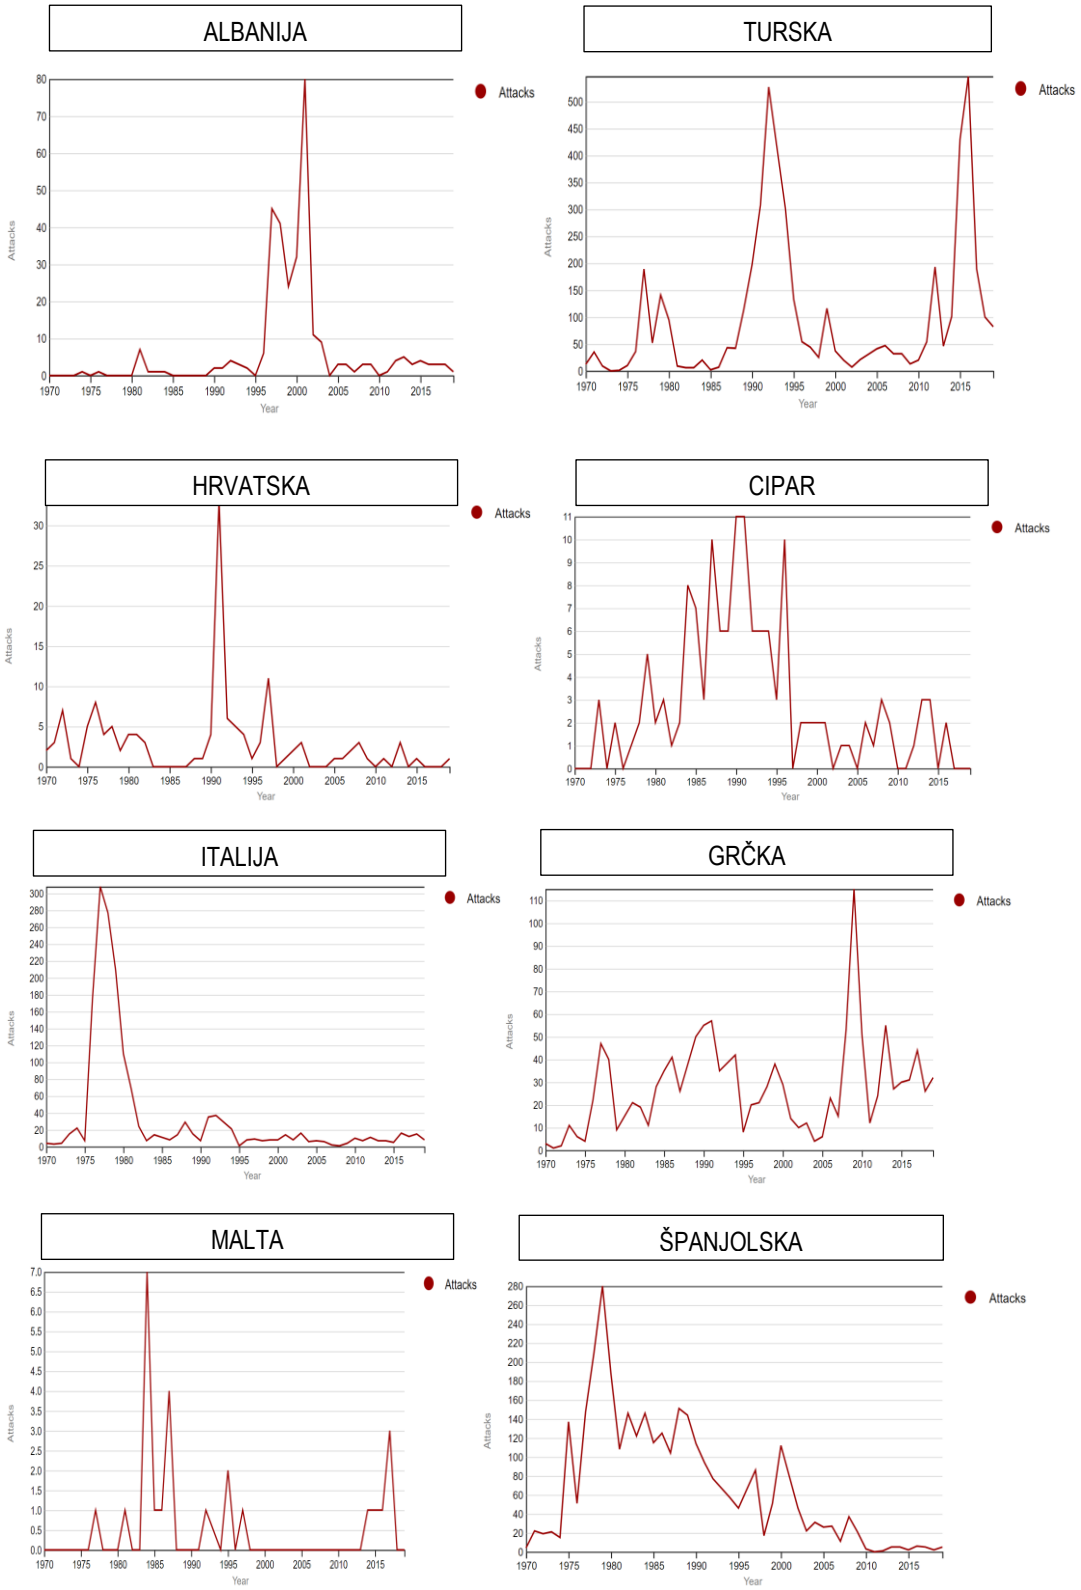
Tablica 31 Dekompozicija varijance

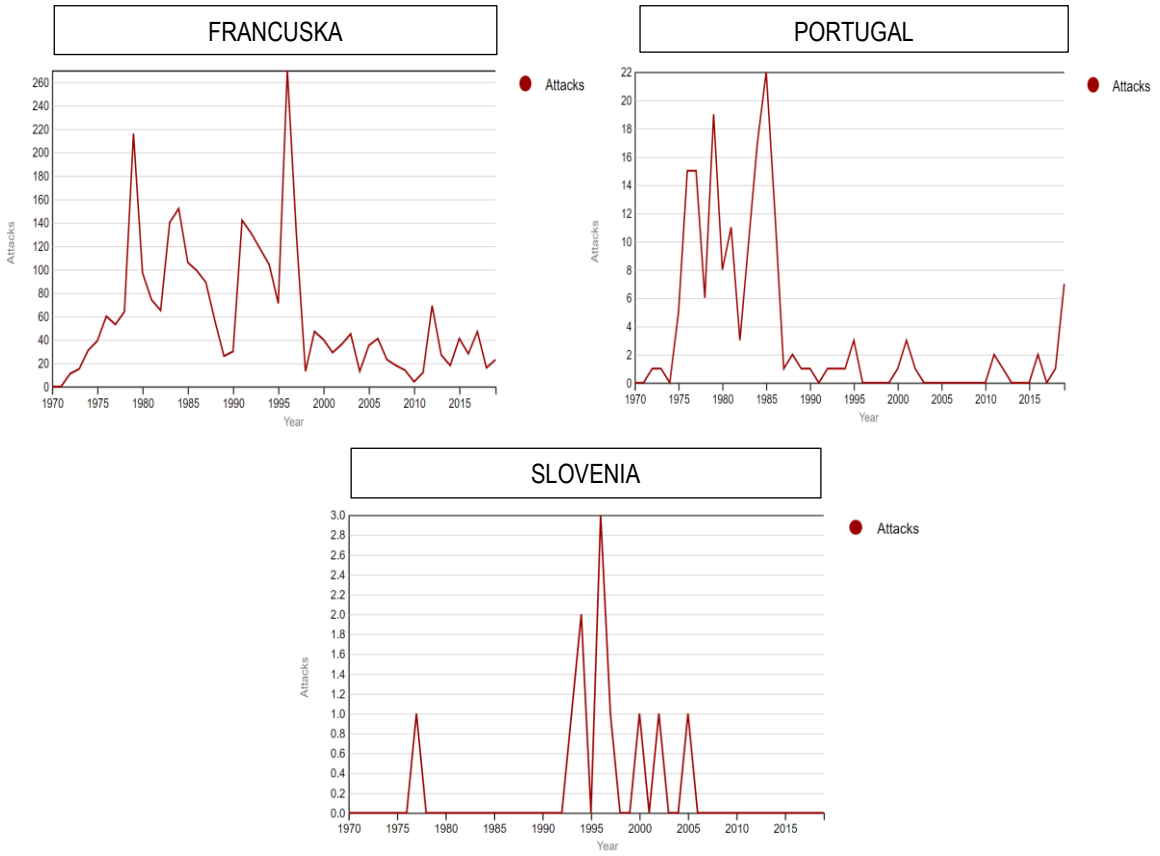
Ukupno ostvarena noćenja (lnTTonsI)	Teroristički napad (lnTAnd)	Zdravstvena pitanja (lnHQnd)	Prirodne katastrofe (lnNDnd)	Prosječna cijena nfte (lnAPO)	Volatilnost tečaja (lnVER)	Politička nestabilnost (PII)	Rat (lnWar)
0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0
2	0.32831	0.00359	0.14593	0.01206	0.00611	0.00135	0.01763
3	0.56491	0.001103	0.20428	0.003365	0.001923	0.00415	0.02669
4	0.7111	0.002148	0.23378	0.006002	0.003825	0.00808	0.03154
5	0.80457	0.003423	0.25144	0.00882	0.006219	0.01286	0.03448
6	0.86801	0.004873	0.26317	0.11641	0.009018	0.01829	0.03644
7	0.91349	0.004873	0.27151	0.1436	0.12147	0.02417	0.03784
8	0.94759	0.008116	0.27772	0.16921	0.1554	0.03035	0.03889
9	0.97406	0.00984	0.28253	0.19297	0.19138	0.03672	0.0397
10	0.9952	0.0011597	0.28634	0.21479	0.22892	0.04317	0.04035

Izvor: izračun autorice

PRILOG 14 PRIKAZ TERORISTIČKIH NAPADA U ODABRANOM RAZDOBULJU ZA MEDITERINSKE ZEMLJE

Grafikon 17 Evidentirani bombaški napadi odabranih mediteranskih zemalja





Izvor: Global terorrism database

PRILOG 15 DEFINICIJA PRIHODNIH KATASTROFA

Tablica 32 Definiranje prirodnih katastrofa

POJAM	DEFINICIJA
Zračna eksplozija	Eksplozija komete ili meteoroida u Zemljinoj atmosferi bez udara o tlo
Incidenti sa životinjama	Čovjek se susreće sa opasnim ili egzotičnim životinjama u gradskim i seoskim sredinama
Pad pepela	Nekonsolidirane vulkanske krhotine ispuhane u atmosferu tijekom erupcije; mogu dugo ostati u zraku i putovati znatnu udaljenost od izvora
Lavina	Masa rastresitog zemljinog materijala, snijega ili leda koji klizi, teče ili pada brzo niz padinu, pod silom gravitacije
Snježna lavina	Brzi pokret spuštanja mješavine snijega i leda
Lavina krhotina	Naglo i brzo kretanje silaznog tlaka nesortirane mase stijena i tla. Postoje dvije opće vrste lavina krhotina- hladna lavina otpada obično proizlazi iz nestabilne padine koja se iznenada urušava, dok vruća lavina rezultira vulkanskom aktivnošću koja dovodi do nestabilnosti padina i urušavanja
Bakterijska bolest	Neobičan porast broj incidenata uzrokovanih izlaganjem bakterijama bilo putem kontakta s kožom, gutanjem ili udisanjem. Primjeri su salomonela, MRSA i kolera
Biološka opasnost	Opasnost nastala izlaganjem živim organizmima i njihovim otrovnim tvarima (npr. plijesan) ili vektorskim bolestima koje mogu prenijeti. Primjeri su otrovne divlje životinje i insekti, otrovne biljke i komarci koji nose uzročnike bolesti poput parazita, bakterija ili virusa (npr. Malarija)
Klimatološka opasnost	Opasnost koju uzrokuju dugotrajni atmosferski procesi od mezo i makro razmjera u rasponu unutar-sezonske do multidekadne varijabilnosti klime.
Obalna erozija	Privremeni ili trajni gubitak sedimenata ili kopna u obalnim rubovima uslijed djelovanja valova, vjetrova, plima ili antropogenih aktivnosti.
Obalna poplava	Viši vodostaj iznad obale duž obale uzrokovan plimnim promjenama ili grmljavinom koje rezultiraju poplavama koje mogu trajati više dana ili tjedana
Hladni Val	Razdoblje nenormalno hladnog vremena. Obično hladni val traje dva ili više dana, a mogu ga pogoršati jaki vjetrovi. Točni temperaturni kriterij za ono što predstavlja hladni val rezlikuju se ovisno o lokaciji.
Konvektivna oluja	Vrsta meteorološke opasnosti koja nastaje zagrijavanjem zraka i dostupnošću vlažnih i nestabilnih zračnih oluja (s jakom kišom i/ili tučom, grmljavinom, jakim vjetrovima, tornadom) do mezo-mjerenja, višednevnih događaja.
Tekući otpad/protok blata/ odron stijena	Vrste klizišta koja nastaju kod jakih kiša ili brzo otapanje snijega/leda šalju velike količine vegetacije, blata ili stijena niz gravitacijske sile
Derecho	Raširene i obično brzo pokretne oluje povezane s konvekcijskom/konvektvnom olujom. Derechosi uključuju

	vjetrove i pljuskove. Šteta od derechosa često se miješa sa štetom od tornada
Bolesti	Neobično, često naglo, brojčano povećanje broja incidenata zarazne bolesti koja je već postojala u regiji (npr. gripa, esherihija coli) ili pojava zarazne bolesti koja je prethodno bila pristna iz regije (npr. kuga)
Suša	Produljeno razdoblje neobično male količine oborina koje uzrokuju manjak vode za ljude, životinje i biljke. Suša se razlikuje od većine drugih opasnosti po tome što se razvija sporo. Suša nije fizička pojava, jer se njezini utjecaji mogu pogoršati ljudskim aktivnostima i potrebama opskrbe vodom. Suša se često definira konceptualno i operativno. Operativno predstavlja stupanj smanjenja oborina što predstavlja sušu, a razlikuje se po lokalitetu, klimi i okolišnom sektoru.
Potres	Iznenadno kretanje bloka Zemljine kore uzduž geoloških rasjeda i s tim povezano pomicanje tla.
Energetske čestice	Emisije nastale iz oluje sunčevog zračenja koja se sastoje od komada materije koji se kreću velikom brzinom. Magnetosfera i atmosfera blokiraju (solarne) energetske čestice da dođu do ljudi na Zemlji, ali oni štete elektronici svemirske tehnologije (poput satelita) i predstavljaju opasnost od zračenja za život u svemiru i zrakoplovima koji putuju na velikim visinama.
Ekspanzivni zemljani	Zemljani materijal, posebno glina koja se vlaženjem, smrzavanjem ili sušenjem naizmjenično proširuje ili skuplja što oštećuje temelje graševina i drugih struktura. Sakupljanje se općenito naziva isušivanje.
Opasnost	Opasnost koju uzrokuju asteroidi, meteoridi i kometi dok prolaze blizu zemlje, ulaze u Zemljinu atmosferu i /ili udaraju u Zemlju i promjenama među-planetnih uvjeta koji utječu na zemljinu magnetosferu, ionosferu i termosferu.
Ekstratropska oluja	Vrsta ciklonskog sustava niskog tlaka u srednjim i visoko zemljopisnim širinama (koji se naziva i ciklona srednje geografske širine) koji svoju energiju prvenstveno dobiva iz horizontalnih kontrasta temperature (fronte) u atmosferi. Kada se povezuju s hladnim prednjačama, ekstrotropski cikloni mogu biti posebno štetni (npr. Europska zima/vjetrovita oluja)
Požar uslijed potresa	Gradski požari potaknuti potresima. Posebno osjetljiva područja uključuju guste drvene građevine koje dominiraju lokalnom arhitegturom gdje je potres oštetio ili puknuo cjevovod za vodu i plin. Mali lokalni požari mogu se stopiti u plamenove koji uništavaju mnoge gradske blokove
Bujica	Obilne ili prekomjerne kiše u kratkom vremenskom periodu koje stvaraju trenutni odljev, stvarajući uvjete poplave u roku od nekoliko minuta ili nekoliko sati tijekom ili nakon kiše
Poplava	Općeniti pojam za prelijevanje vode iz potoka na normalno suho zemljište u poplavnoj razini (poplava rijeka), viši od nenormalnih razina duž obale i u jezerima ili akumulacijama (obalna poplava), kao i ispuštanje vode na ili u blizini mjesta tamo gdje je padala kiša

Magla	Kapi vode suspendirane u zraku u blizini Zemljine površine. Magla je jednostavno oblak koji je u kontaktu sa tlom
Šumski požar	Vrsta divlje vatre u šumovitom području
Mraz/Zamrzavanje	Mraz je posljedica zračenja hlađenja što rezultira stvaranjem tankih kristala leda na tlu ili drugim površinama u obliku igala, perja, ljuskica. Mraz se javlja kada je temperaturna površina ispod smrzavanja, a vodena para iz vlažnog zraka stvara hladne naslage na hladnoj površini. Zamrzavanje se događa kada je temperatura zraka na 0 stupnjeva ili niže na širem području tijekom klimatološki značajnog vremenskog razdoblja. Upotreba izraza obično je ograničena na situacije advetive ili na slučajeve kada vjetar ili drugi uvjeti sprečavaju mraz.
Gljivična bolest	Izloženost gljivicama bilo kroz kontakt s kožom, gutanje ili udisanje spora što rezultira neobičnim povećanjem broja incidenta. Primjeri su gljivična upala pluća ili gljivični meningitis
Geomagnetska oluja	Vrsta vanzemaljske opasnosti koju uzrokuju udarni valovi sunčevog vjetra koji privremeno narušavaju magnetosferu Zemlje. Geomagnetske oluje mogu poremetiti elektroenergetske mreže, operacije svemirskih letjelica i satelitsku komunikaciju.
Geofizička opasnost	Opasnost potječe od čvrste zemlje. Ovaj se izraz upotrebljava naizmjenično s izrazom geološka opasnost
Izljev ledenog jezera	Poplava koja nastaje kada se iznenada izlije voda koju ispusti ledenik. Ledena jezera mogu biti na prednjem dijelu ledenjaka ili ispod ledenog pokrivača.
Potres / prizemni poret	Površinsko istiskivanje zemljinih materijala zbog potresa tla uzrokovanog zemljotresima ili vulkanskim erupcijama
Tuča	Čvrsta oborina u obliku nepravilnih peleta ili kuglica leda promjera većih od 5 mm
Toplinski val	Razdoblje nenormalno vrućeg ili neobično vlažnog vremena. Obično toplinski val traje dva ili više dana. Točni temperaturni kriteriji za ono što predstavlja toplinski val razliku se ovisno o lokaciji
Hidrološka opasnost	Opasnost nastala pojavom, kretanjem i distribucijom površinske i podzemne slatke i slane vode
Ledeni jamski potop	Akumulacija plutajućeg leda koji ograničava ili blokira tok i drenažu rijeke. Ledene gužve imaju tendenciju razvijanja u blizini riječnih zavoja i mostova
Udar	Vrsta vanzemaljske opasnosti izazvane sudarom Zemlje s meteoritom, asteroidom ili kometom
Insekcija insekata	Sveprisutni priliv, rojenje i/ili izlijevanje insekata koji utječu na ljude, životinje, usjeve i pokvarljivu robu. Primjeri su skakavci i afričke pčele.
Lahar	Vruća ili hladna mješavina zemljanog materijala koja teče na padini vulkana za vrijeme ili između erupcija vulkana
Klizište nakon potresa	Neovisno o prisutnosti vode, poticanje mase također može biti potaknuto potresima

Tok lave	Izbačena magma koja se kreće poput tekuće mase koja silazi s vulkana tijekom erupcije
Munja	Visokonaponski, vidljivi električno pražnjenje izazvano grmljavinom i praćen grmljavinom
Rastapanje	Transformacija vode zasićenog tla iz čvrstog stanja u tekuće stanje uzrokovano potresom. Ukapljivanje smanjuje čvrstoću i krutost tla što uzrokuje prevrtanje zgrada
Masovno kretanje	Bilo koja vrsta pomicanja zemljanih materijala
Meteorološka opasnost	Opasnost koju uzrokuju kratkotrajni ekstremni vremenski i atmosferski uvjeti od mikro do mezo razmjera koji traju od minute do dana
Parazitksa bolest	Izloženost parazitu-organizmu koji živi na domaćinu ili u njemu. Uzrokuje neobičan porast broja incidenata. Izloženost parazitima javlja se uglavnom putem kontaminirane vode, hrane ili kontakta s insektima, životinjama, kućnim ljubimcima. Primjeri su malarija, bolest loša, giardijaza, trihineloza.
Prionska bolest	Vrsta biološke opasnosti koju uzrokuju prionski proteini. Prionske bolesti ili transmisivna spongifomna encefalopatija (TSE) su obitelj rijetkih progresivnih neurodegenerativnih poremećaja koji pogađaju ljude i životinje, a karakteriziraju ih dugi inkubacijski periodi i neuralni gubitak
Piroklastični tok	Izuzetno vrući plinovi, pepeo i drugi materijali sa višim temperaturama od 1000 Celzijevih stupnjeva, koji tijekom erupcije brzo teče niz bok vulkana (više od 700km/h)
Radio smetnja	Potaknuta rendgenskim emisijama Sunca koje udaraju u Zemljinu atmosferu i uzrokuju poremećaje u ionosferi kao što je zastoj visokih i niskofrekventnih radio signala. To utječe na satelitsku radio komunikaciju i globalne sustave za pozicioniranje (GPS)
Riječna poplava	Vrsta poplave koja je posljedica prelijevanja vode iz potoka ili riječnog kanala na normalno suho zemljište u poplavnom slivu pored kanala
Sirovi valovi	Neobičan pojedinačni greben oceanskog vala daleko na mogu koje je mnogo viši i strmiji od drugih valova u brovladavajućem sustavu bubrenja
Pješčana oluja/prašnjava oluja	Jaki vjetrovi nose čestice pijeska na visini, ali općenito ograničene na manje od 15 metara, posebno uobičajene u sušnim i polusušnim okruženjima. Za prašnjavu oluju su također karakteristični jaki vjetrovi, ali nose veće čestice prašine
Seiche	Stojeći val u velikom polu ili potpuno zatvorenom vodenom tijelu stvoren jakim vjetrovima i velikim gradijentom barometrijskog tlaka
Udarni val	Valovi koji prenose energiju iz poremećaja kroz medij sličan valu iako putuje mnogo većom brzinom. To može biti vrsta izvanzemaljske opasnosti uzrokovane eksplozijom (zračni udar) ili utjecajem meteorita koji stvaraju energetske udarne valove sposobne za razbijanje stakla, urušavanje zidova

Ponor	Kolaps kopnene površine zbog otapanja podzemnih stijena poput vapnenca ili karbonate stijene u vodi
Svemirsko vrijeme	Općenit pojam za izvanzemaljske vremenske uvjete potaknute solarnim erupcijama kao što su geomagnetske oluje, radio poremećaji i čestice solarne energije
Olujni nalet	Nenormalni porast razine mora generiran tropskim ciklonama ili drugim intenzivnim olujama
Tornado	Nasilno rotirajući stup zraka koji dopire do tla ili otvorene vode
Tropska ciklona	Tropska ciklona potječe od tropskih ili suptropskih voda. Karakterizira ju toplo-jezgra, nefrontalna sinoptička ciklona s ciklom niskog tlaka, spiralnim pojasevima kiše i jakim vjetrovima. Ovisno o njihovom položaju, tropski cikloni nazivaju se uraganima (Atlantik, sjeveroistočni Pacifik), tajfunom (sjeverozapadni Tihi ocean) ili ciklonima (Južni Tihi i Indijski ocean).
Tsunami	Niz valova koji nastaju premještanjem ogromnih količina vode kroz podvodne potrese, vulkanske erupcije ili klizišta. Valovi tsunamija putuju velikom brzinom preko oceana, ali kako počnu dopirati do pitke vode oni usporavaju i val postaje strmiji
Vulkanska aktivnost	Vrsta vulkanskog događaja blizu otvora na Zemljinoj površini, uključujući vulkanske erupcije lave, pepela, vruće pare, plina i piroklastičnog materijala
Valna akcija	Površinski valovi generirani vjetrom koji se mogu pojaviti na površini bilo kojeg otvorenog vodenog tijela poput oceana, rijeka i jezera.
Divlji požar	Svako nekontrolirano sagorijevanje ili spaljivanje biljaka u prirodnom okruženju kao što je šuma, travnjak. Divlji požar može biti pokrenut gromom ili ljudskom radnjom
Zimska oluja/mećeva	Sustav niskog tlaka u zimskim mjesecima sa značajnim nakupljanjem snijega, kišom smrzavanjem, susnježicom ili ledom. Oluja je jaka snježna oluja s vjetrovima većim od 56 km/h tijekom tri ili više sati, proizvodeći pritom smanjenu vidljivost

Izvor: prijevod autora prema, Peril Classification and Hazard Glossary (2014)