Predviđanje turističke potražnje – analiza pojmova i modela

Strunje, Petra

Undergraduate thesis / Završni rad

2020

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:671172

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

ZAVRŠNI RAD

Predviđanje turističke potražnje – analiza pojmova i modela

Mentor:
doc. dr. sc. Blanka Šimundić

Student:
Petra Strunje

Split, rujan, 2020.

SADRŽAJ

1. UVOD 1

1.1. Predmet i cilj rada 1

1.2. Izvori podataka i metode prikupljanja 1

1.3. Sadržaj i struktura rada 1

2. DEFINICIJA I ODREDNICE TURISTIČKE POTRAŽNJE 2

2.1. Turizam 3

2.2. Potražnja 4

2.3. Turistička potražnja 5

2.3.1. Ekonomske odrednice turističke potražnje 6

2.3.2. Neekonomske odrednice turističke potražnje 7

2.4. Važnost predviđanja turističke potražnje 10

3. ANALIZA TURISTIČKE POTRAŽNJE - ANALIZA POJMOVA I MODELA 13

3.1. Kvalitativno predviđanje 15

3.2. Kvantitativno predviđanje 15

4. OSNOVNE METODE PROGNOZIRANJA TURISTIČKE POTRAŽNJE 17

4.1. Ekstrapolacijska metoda 17

4.1.1. Jednostavne ekstrapolacijske metode 18

4.1.2. Napredna ekstrapolacijska metoda 23

4.2. Uzročni modeli 23

4.2.1. Uzročna regresija 23

4.2.2. Uzročna strukturna 26

4.3. Metode kvalitativnog predviđanja 26

4.3.1. Panel-konsenzus metoda 27

4.3.2. Delfi metoda 31
4.3.3. Planiranje scenarija 31
5. ZAKLJUČAK 33
6. LITERATURA 34
POPIS ILUSTRACIJA 38
SAŽETAK 39
SUMMARY 39

1. UVOD

1.1. Predmet i cilj rada

Cilj ovog završnog rada je definirati turističku potražnju, objasniti načine i važnost predviđanja iste te pružiti različite primjere predviđanja razine turističke potražnje na temelju dostupnih podataka za određene destinacije.

Turistička potražnja jedno je od osnovnih područja znanstvenih istraživanja u turizmu. S obzirom da predstavlja segment tržišta koji određuje turističku ponudu i politike razvoja turizma, iznimno je važno kako nositeljima odluka, tako i poduzećima koji se bave turizmom, da mogu predviđati kretanja turističke potražnje, a u svrhu donošenja ispravnih poslovnih i razvojnih odluka i planova. U ovom završnom radu obradit će se određeni broj metodoloških pristupa u predviđanju turističke potražnje.

1.2. Izvori podataka i metode prikupljanja

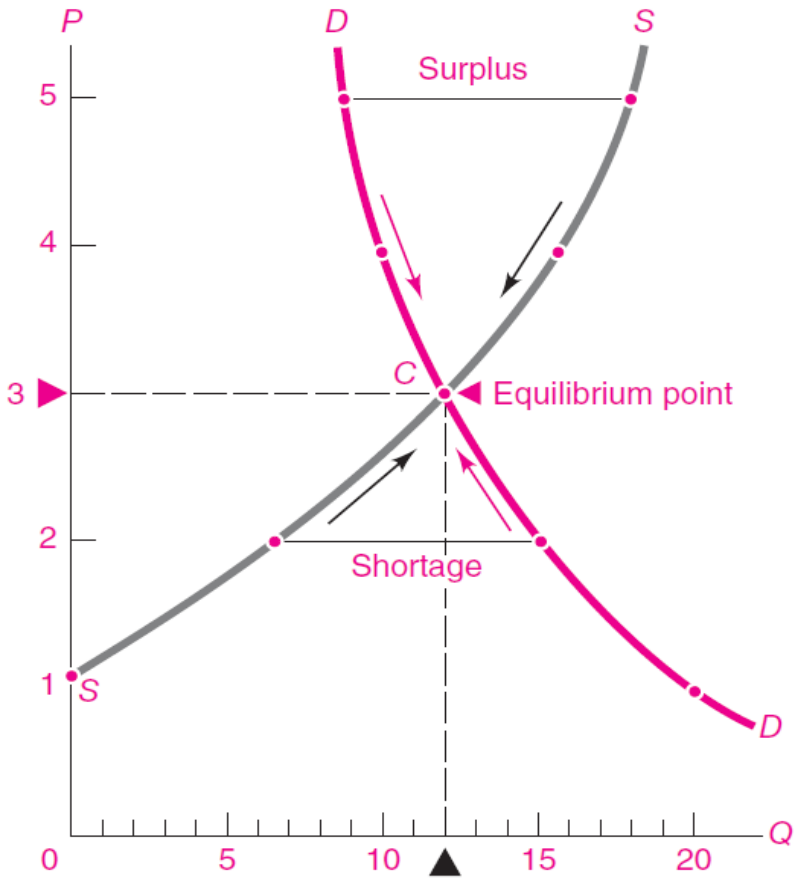
Osim istraživanja za stolom temeljem kojeg će se analizirati dosadašnji znanstveni radovi koji su istraživali, definirali i predviđali turističku potražnju, u svrhu ostvarivanja ciljeva rada, u radu će se koristiti i različite statističke metode kojima će se obraditi metodološki pristupi predviđanja turističke potražnje i dati osvrt na prednosti i nedostatke svake od obrađenih metoda.

1.3. Sadržaj i struktura rada

Rad je podijeljen u pet poglavlja uključujući uvod i zaključak. Rad započinje definiranjem pojma turizma te turističke potražnje, analiziraju se čimbenici koji utječu na potražnju te se istražuje važnost predviđanja turističke potražnje. Nakon toga objašnjene su metode predviđanja iste. Nadalje, u radu su prikazani primjeri korištenja metoda za izračun turističke potražnje. Na kraju je izveden zaključak na temelju obrađene literature i primjera.

2. DEFINICIJA I ODREDNICE TURISTIČKE POTRAŽNJE

Opće poznato je kako je tržište promjenjivo. Samuelson ga uspoređuje s vremenom - ponekad je mirno, a ponekad olujno, ali uvijek je promjenjivo. Ipak, uvjeren je kako je moguće pomnim proučavanjem tržišta prepoznati sile koje djeluju na naoko slučajne događaje. Smatra kako je upravo analizom ponude i potražnje moguće predvidjeti cijene i outpute na individualnim tržištima.[1]



Graf 1: Odnos ponude i potražnje na tržištu

Izvor: Samuelson, P. and Nordhaus, W., 2010. Economics. Boston: McGraw-Hill, str. 55.

Na grafikonu je prikazan odnos ponude i potražnje. Engleska riječ „Surplus" na grafikonu označava višak, „Equilibrium point" označava točku ravnoteže, a riječ „Shortage" se odnosi na manjak robe ili usluga na tržištu.

[1] Samuelson, P. and Nordhaus, W., 2010. *Economics.* Boston: McGraw-Hill, str. 45.

Kako bi se objasnio pojam turističke potražnje te predviđanje iste, bitno je razumjeti pojam potražnje, sastavnice, okolinu u kojoj je prisutan te što sve na njega utječe.

2.1. Turizam

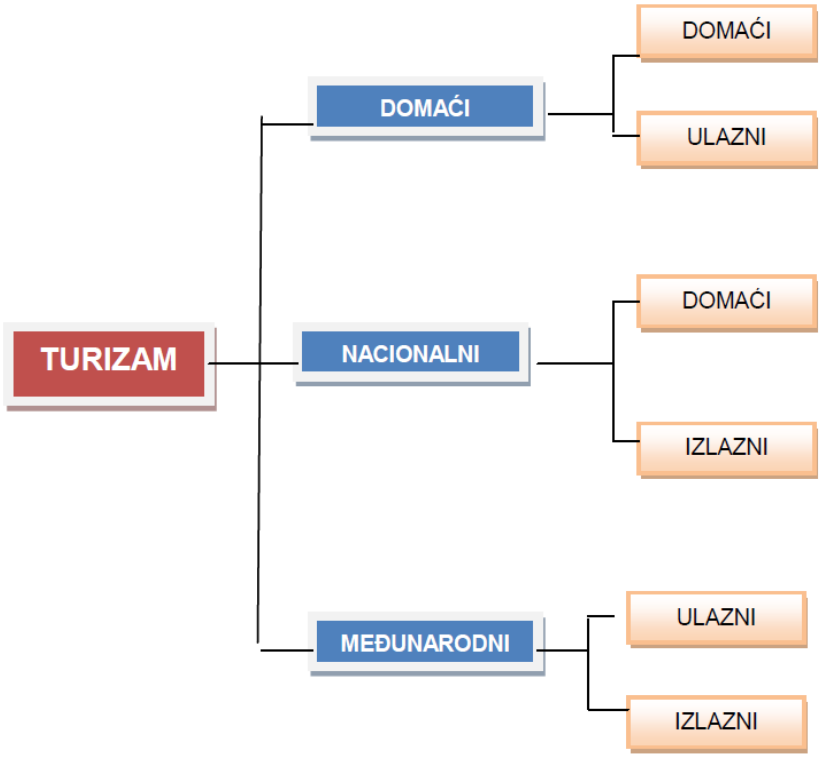
Postoji mnogo definicija turizma. Prema definiciji Svjetske Turističke Organizacije (UNWTO), turizam predstavlja društveni, kulturni i ekonomski fenomen koji podrazumijeva kretanje ljudi u zemlje ili mjesta izvan njihovog uobičajenog okruženja zbog osobnih ili poslovnih razloga. Ti ljudi, koji mogu biti ili turisti ili izletnici ili stanovnici ili nerezidenti, nazivaju se posjetiteljima, a njihove aktivnosti su povezane s turizmom te neke uključuju turističke troškove.[2]

Nadalje, turizam se definira i kao skup različitih individualnih iskustava o odnosima koji nastaju kada se zadovolje turističke potrebe pojedinca.[3]

Po samoj definiciji turizma bitno je naglasiti kako turizam nije industrija. Iz tog razloga turizam nije prisutan u sustavima nacionalnih računa kao što je Nacionalna klasifikacija djelatnosti u Republici Hrvatskoj. Ipak djelatnosti i proizvodi koji sačinjavaju turistički proizvod prikazani su kroz različita područja i razrede.[4]

Kada se govori o turizmu iz percepcije tokova kretanja turista, razlikuje se domaći turizam koji se odnosi na kretanje putnika u granicama određene zemlje, međunarodni turizam koji obuhvaća i ulazni i izlazni turizam te nacionalni turizam koji podrazumijeva domaći i izlazni turizam stanovnika pojedine nacije.[5]

[2] Unwto.org. 2020. *Glossary Of Tourism Terms | UNWTO*. [Internet] raspoloživo na: https://www.unwto.org/glossary-tourism-terms [12.08.2020.].
[3] Dulčić, A., Turizam-načela razvoja i praksa, Ekonomski fakultet Split i Institut za turizam Zagreb, 1991., str. 27.
[4] Petrić L. 2019. *Uvod u turizam*, Split: Ekonomski fakultet Split, str. 40.
[5] Ibid. str. 35-36.



Slika 1: Vrste turizma

Izvor: Weber, S. Mikačić, V., Osnove turizma, Školska knjiga, Zagreb 1999. str. 17.

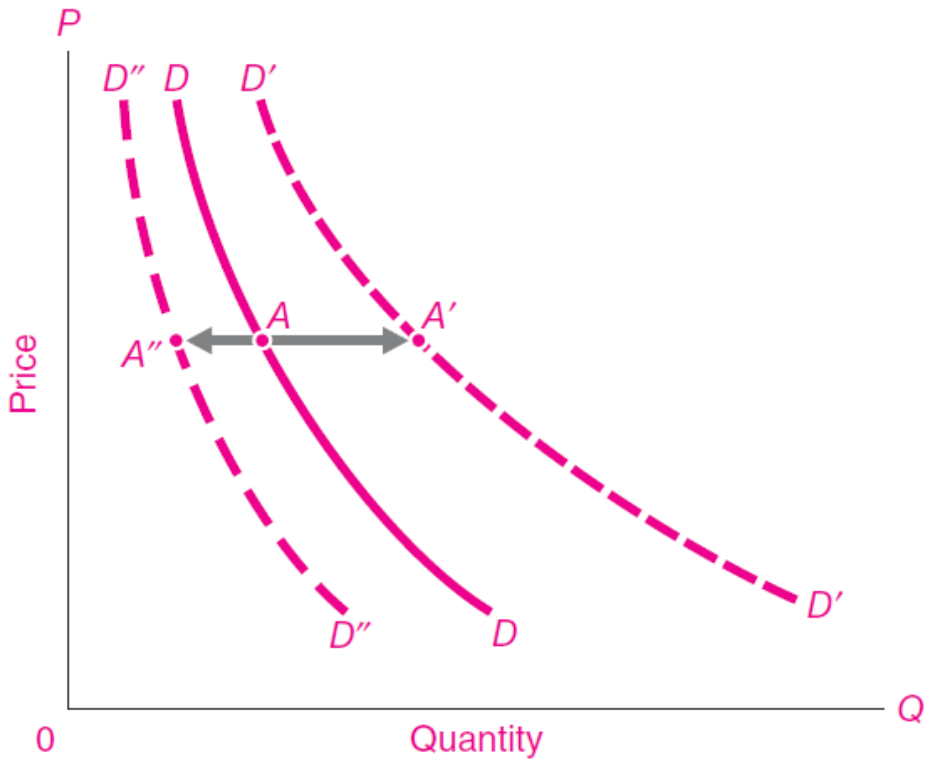
2.2. Potražnja

Potražnja, zajedno s ponudom, predstavlja jednu od osnovnih sila koje djeluju na tržištu. Ona predstavlja spremnost na kupnju roba i usluga po određenoj cijeni. Ono što se zapravo može primijetiti i pratiti jest tržišna potražnja (eng. *market demand*) koja se definira kao ukupnost svih pojedinačnih potražnji. Dakle, krivulja tržišne potražnje dobiva se zbrajanjem količina koje traže svi pojedinci po svakoj cijeni.[6] Krivulja potražnje pada prema dolje desno te pokazuje kako tražena količina reagira na promjenu cijene.

Ukoliko je cijena za određenu količinu dobra ili usluge manja, pojedinci su spremni platiti više jedinica dobra ili usluge. Uz cijenu dobara i usluga, utjecaj na potražnju imaju i cijene ostalih roba, dohodak potrošača i posebni utjecaji što je prikazano na grafikonu broj 2. Ukoliko primjerice dohodak potrošača poraste, uz nepromijenjenu cijenu, krivulja potražnje (D) se u potpunosti

[6] Samuelson, P. and Nordhaus, W., Op. cit, str. 46-47.

pomiče u desno (D') što označava povećanje potražnje. Na grafikonu na osi y imamo cijenu, a na osi x količinu.[7]



Graf 2: Kretanje krivulje potražnje zbog promjena u dohotku potrošača

Izvor: Samuelson, P. and Nordhaus, W., 2010. Economics. Boston: McGraw-Hill, str. 91-92.

2.3. Turistička potražnja

Uzevši u obzir definicije iznesene u prethodnim odlomcima, može se zaključiti kako turistička potražnja predstavlja ukupnu spremnost svih pojedinaca da plate jedinice dobara i usluga u turizmu po određenim cijenama.

Osim cijena roba i usluga, dohotka, cijena ostalih roba i usluga (supstituta) i posebnih utjecaja, koji utječu na krivulju potražnje pa time i na potražnju u turizmu, postoje i još neki faktori koji određuju potražnju.

Ti faktori se mogu podijeliti na ekonomske i neekonomske odrednice.

[7] Ibid. str. 91-92.

2.3.1. Ekonomske odrednice turističke potražnje

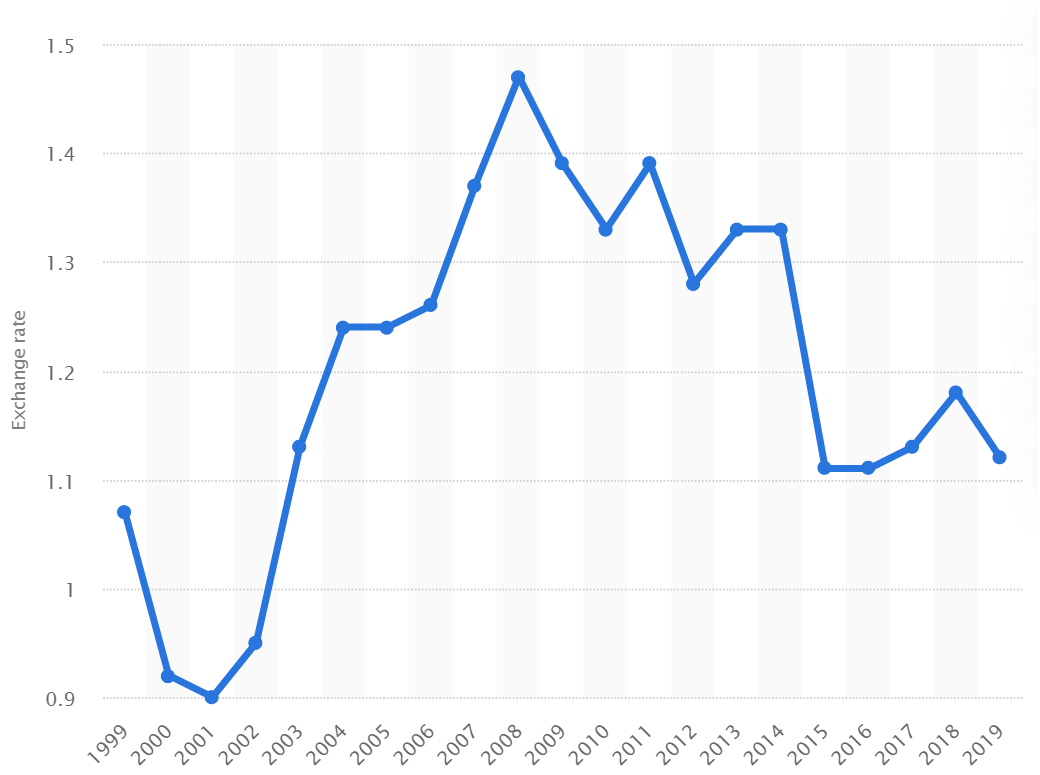
Pod ekonomske odrednice, između ostalog, podrazumijeva se financijska sposobnost za financiranje putovanja. Putovanja se dijele na osobna i poslovna putovanja.

Osobna putovanja označavaju putovanja u slobodno vrijeme, a potražnja za takvom vrstom usluga pod snažnim je utjecajem razine raspoloživog dohotka. Diskrecijski dohodak je preostali iznos dohotka koji pojedinac može potrošiti na željena dobra ili usluge, ili pak na dodatnu štednju, nakon podmirenja osnovnih životnih troškova kao što su hrana, najam, grijanje, kredit i slično. Postojanje raspoloživog diskrecijskog dohotka direktno utječe na turističku potražnju u pozitivnom smislu. Štoviše, slučajeve kada postoji ta financijska mogućnost i slobodno vrijeme, kao što je u slučaju 90% Amerikanaca koji se zbog nekih određenih razloga ipak ne odlučuju na međunarodna putovanja, treba tretirati kao potencijalna tržišta prema kojima marketinške mjere trebaju biti usmjerene.

S druge strane, postoje poslovna putovanja na koje ekonomski učinci nemaju veliki utjecaj. Primjetno je kako i u primjerice doba recesije, poduzeća i dalje šalju svoje zaposlenike na poslovna putovanja budući da su ta putovanja organizirana iz potrebe, a ne zbog luksuznih razloga. Dakle, u takvim je razdobljima vjerojatnije kako će poduzeća promijeniti izbor hotela i avionske kompanije u smislu izbora povoljnije opcije niže kategorije te ograničiti trajanje i broj putovanja.

Osim toga, bitno je naglasiti kako i ponuda na tržištu kao što su smještaj i pogodnosti te lak pristup odredištu imaju utjecaj na turističku potražnju. Ipak, iako se neko tržište čini jako atraktivno pojedincu, ukoliko on nema financijske mogućnosti za putovanje, neće se odlučiti na odlazak u tu turističku destinaciju, tj. na određenu turističku uslugu. Boljim riječima, opciju koja prelazi iznos raspoloživog budžeta za potrošnju na određenu turističku uslugu, pojedinac vjerojatno neće niti razmotriti.

Nadalje, utjecaj na potražnju ima i tečaj valuta. Primjer toga vidljiv je na primjeru razlike tečaja eura i američkog dolara. U slučaju kada američki dolar jača, a euro slabi, primjetno je kako se više Amerikanaca odlučuje na odlazak u Europu budući da se tada Europa čini kao povoljnija destinacija.



Slika 2: Prosječni godišnji tečaj eura prema američkom dolaru 1999-2019.

Izvor: Cherowbrier, J., 2020. Euro To U.S. Dollar Exchange Rate 1999-2018 | Statista. [Internet] Statista. raspoloživo na: https://www.statista.com/statistics/412794/euro-to-u-s-dollar-annual-average-exchange-rate/

Naravno i same cijene bitni su faktori, a najzanimljivije cijene pri planiranju putovanja su cijene boce vina, večere za četvero, paketa cigareta i slično.

Kvaliteta pogodnosti i smještaja na odredištu također će utjecati na turističku potražnju. Ukoliko se ponuda bazira isključivo na primjerice pješčanim plažama kao što je to slučaj na Karipskom otočju, postoji velika vjerojatnost supstitucije između odredišta.

Mogućnost transporta također je bitan faktor koji utječe na turističku potražnju. Za najveću promjenu u cijelom sektoru turizma zaslužan je zasigurno razvoj putničkog zračnog prometa. Primjerice, sada je moguće u roku od samo 13 sati doći do Hong Konga direktnim letom iz Londona. Znatnim skraćivanjem vremena putovanja u destinaciju, produljuje se vrijeme koje turisti mogu provesti u određenoj destinaciji čime se postiže povećanje potražnje za takvom uslugom.

2.3.2. Neekonomske odrednice turističke potražnje

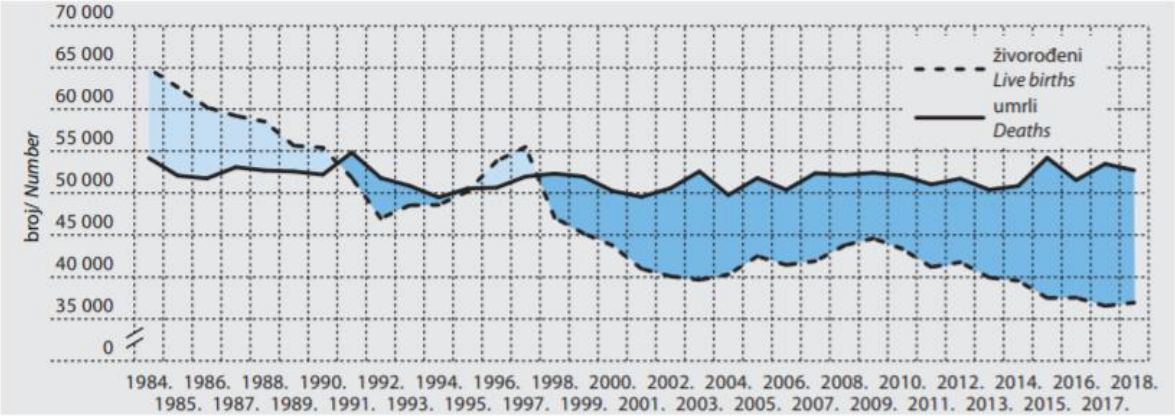
Neekonomske odrednice potražnje mogu se podijeliti na strukturne i na motivacijske odrednice.

Stanovništvo i aktivnosti u slobodnom vremenu spadaju pod strukturne odrednice.

Za stanovništvo se može reći kako je ono sirovina u turizmu. Nije važna samo veličina stanovništva već i mogućnost stanovništva priuštiti si godišnji odmor i putovanja. Neke od najmnogoljudnijih zemalja svijeta su jedne i od najsiromašnijih. Naspram toga, neke od najmanjih zemalja svijeta imaju stanovništvo najsklonije putovanjima. Kada se govori o stanovništvu bitno je naglasiti kako postoje tri trenda.

Prvi trend je očito starenje populacije što podrazumijeva rast broja stanovništva treće dobi. To je zapravo jedna od prilika u turizmu budući da ta skupina stanovništva većinom nema obitelj o kojoj se treba brinuti te imaju vremena i financijske mogućnosti za putovanja.

Drugi trend se također odnosi na natalitet, ali u ovom slučaju na veličinu obitelji. Budući da obitelji većinom imaju manje djece nego što je to bio slučaj u prijašnjim godinama, prosječna obitelj ima manje članova, što rezultira znatnim diskrecijskim dohotkom na raspolaganju koji mogu potrošiti na praznike i putovanja.



Slika 3: Prirodno kretanje stanovništva od 1984. do 2018.

Izvor: Rogić-Hadžalić D., Primorac Čačić M., Omerzo E., 2019. *Hrvatska u brojkama 2019.* Zagreb: Hrvatski zavod za statistiku Republike Hrvatske, str. 5.

I konačno treći trend se odnosi na dostupno vrijeme za putovanja budući da zaposlenici u razvijenim dijelovima svijeta imaju pravo na plaćene slobodne dane tj. na godišnji odmor. Primjetno je kako se broj slobodnih dana povećao kroz zadnje vrijeme.

Na to se direktno nadovezuju aktivnosti koje se obavljaju u slobodno vrijeme. Budući da zaposlenici imaju više slobodnog vremena jer se broj radnih sati tjedno i godišnje smanjio, a broj slobodnih dana povećao, stanovništvo ima više slobodnog vremena za aktivnosti, tj. za putovanja.

Štoviše, zbog radnih uvjeta kao što su i mogućnost ranijeg odlaska u mirovinu i zbog boljih životnih uvjeta, sve je više ljudi koji imaju vremena, zdravlja, želje i financijskih mogućnosti za putovanjima.

Pod motivacijske odrednice spadaju:

- obrazovanje,
- urbanizaciju,
- marketing,
- ponudu turističkih agencija i turoperatora te
- atrakcije odredišta.

Što se tiče utjecaja obrazovanja na turističku ponudu, dokazano je kako postoji korelacija između stupnja obrazovanja koji je postigla osoba i njegove sklonosti putovanjima i kulturne znatiželje osobe.

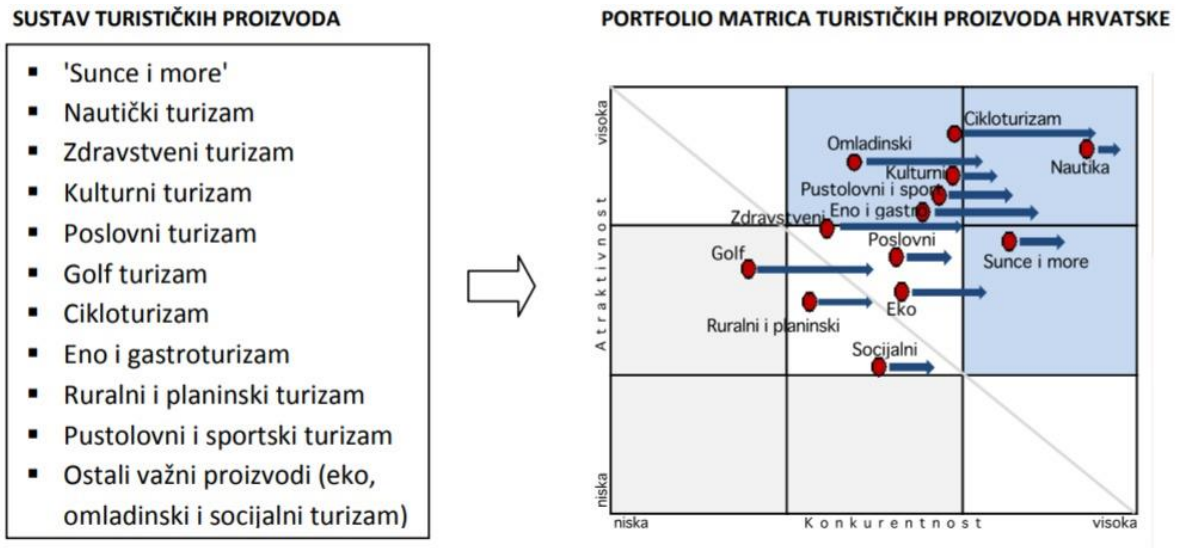
Nadalje, primjetno je kako najveći dio stanovništva koji putuje stanuje u urbanim dijelovima te većinom traži turističke odrednice s drugačijim okruženjem. U tom slučaju, ti turisti se odlučuju na destinacije u prirodi.

Za marketing je zapravo već dobro poznato kako je jedan od najutjecajnijih čimbenika na odabir destinacije za odmor. Na potencijalne turiste utječe reklamni materijal, drugi mediji i preporuke turističke trgovine.

Nadalje, ponuda turističkih agencija i turoperatora također ima značajan utjecaj budući da kada zainteresirani potencijalni putnici od njih traže savjete, imaju mogućnost uvjeriti, tj. razuvjeriti ih i time promijeniti njihove početne percepcije predloženog odredišta.

Atrakcije u odredištima od velike su važnosti budući da putnici biraju odredišta kako bi zadovoljili određene potrebe bilo da su to psihičke ili fizičke. Pa tako za primjer mogu se uzeti kockanje u Las Vegasu i planinarenje u Nepalu. Zbog različitih potreba bitno je omogućiti različite atrakcije u destinacijama kako bi one zadovoljile određene potrebe potencijalnih putnika.[8]

[8] LICKORISH, L., 2007. *INTRODUCTION TO TOURISM.* Abingdon: ROUTLEDGE, str. 52-63.



Slika 4: Diverzifikacija turističkih proizvoda u Hrvatskoj

Izvor: Mint.gov.hr. 2020. *Prijedlog strategije razvoja turizma Republike Hrvatske do 2020. godine* [Internet] raspoloživo na: https://mint.gov.hr/UserDocsImages/dokumenti/Strategija-turizam-2020-veljaca2013.pdf

2.4. Važnost predviđanja turističke potražnje

Predviđanje turističke potražnje od iznimne je koristi kako bi se pravovremeno i efikasno planiralo poslovanje. Primjerice, ukoliko se predviđa kako će iznadprosječan broj posjetitelja posjetiti neki grad, može se planirati s aktivnostima koje će pridonijeti kvaliteti turističke ponude u vidu zaposlenja više ljudi u sektoru turizma, organiziranja izleta i paketa, povećanju smještajnih kapaciteta i slično.[9]

Gledajući cjelokupnu sliku, bitno je precizno predviđati turističku potražnju budući da turizam kao sektor inače igra važnu ulogu u kreiranju politike turizma i oblikovanju turističke ponude, a samim time i u cjelokupnom gospodarstvu države.

Iz izvješća Svjetskog vijeće za putovanja i turizam (WTTC) za 2019. godinu vidljivo je kako su aktivnosti iz područja putovanja i turizma ostvarile sljedeće utjecaje na ekonomiju svijeta:

- Doprinos od 8,9 bilijuna američkih dolara svjetskom BDP-u
- prihodi od turizma i putovanja čine 10,3% globalnog BDP-a
- u području turizma i putovanja ostvareno je 330 milijuna radnih mjesta što čini čak jedno od 10 radnih mjesta širom svijeta

[9] WTO 2008. *Handbook On Tourism Forecasting Methodologies*. Madrid: World Tourism Organization, str. vii

- Izvoz posjetitelja u iznosu od 1,7 bilijuna američkih dolara
- Kapitalna ulaganja u iznosu od 948 milijardi američkih dolara (4,3% ukupnih ulaganja).[10]

Još veću važnost prognoziranju turističke potražnje imaju zemlje kao Hrvatska koje svoje gospodarstvo uvelike oslanjaju na profite i potrošnju u turizmu. Upravo zbog proteklih rekordnih godina po broju posjećenosti od strane inozemnih putnika, Hrvatska je na samom vrhu liste željenih destinacija. Samim time, prihodi iz turizma najbitniji su čimbenici koji imaju direktan utjecaj na bruto domaći proizvod. U situaciji pandemije koja je obilježila 2020. godinu, primjećuje se izrazito negativan učinak na cjelokupnu ekonomiju, a posebice u sektoru turizma. Primjer učinka vidljiv je u izjavi Hrvatske Narodne Banke (HNB) u kojoj glasi kako iako se: „domaća potražnja počela oporavljati nakon popuštanja strogih epidemioloških mjera, očekivano smanjenje inozemne potražnje, osobito prihoda od turizma, usporit će i produžiti razdoblje oporavka, pa bi se realni BDP Hrvatske na razini cijele 2020. mogao smanjiti za 9,7%."[11]

Kada se pogleda izvješće WTTC-a za 2019. godinu za Hrvatsku, uočljivi su rekordni podaci. Evidentirano je kako je ukupni udio turizma u BDP-u narastao za 2.9% u odnosu na prijašnju godinu te time čini 25% BDP-a. Procijenjeno je kako je u sektoru turizma bilo zaposleno 3 834 000 ljudi te kako su profiti od turizma iznosili 80 247 500 kuna.[12] Na temelju toga, Ministarstvo turizma Republike Hrvatske je bilo uvjereno kako će se u 2020. godinu ostvariti novi rekordi kojima će se poboljšati ekonomija.[13] S obzirom na ovu optimističnu prognozu i nedavnu izjavu HNB-a u kojoj stoji kako su se prihodi od turizma ipak znatno smanjili i time uzrokovali možebitno smanjenje BDP-a na razini cijele 2020. godine, jasno je kako postoji značajno odstupanje od prognoziranih vrijednosti te je vidljivo koliko snažan utjecaj na gospodarstvo Hrvatske ima razina inozemne turističke potražnje.

Što se tiče dugoročnih prognoza, WTTC je u svojem izvješću iz 2018. godine prognozirao kako će u 2028. godini udio prihoda od turizma u BDP-u Hrvatske činiti 31.7% što je za 6.7% više od 2017.

[10] Wttc.org. 2020. *Economic Impact | World Travel & Tourism Council (WTTC)*. [Internet] raspoloživo na: https://wttc.org/Research/Economic-Impact [14.09.2020.].
[11] Hnb.hr. 2020. *Savjet HNB-A: Realni BDP U 2020. Mogao Bi Pasti Za 9,7%, A U 2021. Očekuje Se Rast Ekonomske Aktivnosti Za 6,2%.* [Internet] raspoloživo na: https://www.hnb.hr/-/savjet-hnb-a-realni-bdp-u-2020-mogao-bi-pasti-za-9-7-a-u-2021-ocekuje-se-rast-ekonomske-aktivnosti-za-6-2- [13.07.2020.].
[12] Wttc.org. 2020. *CROATIA 2020 ANNUAL RESEARCH: KEY HIGHLIGHTS | World Travel & Tourism Council (WTTC)*. [Internet] raspoloživo na: https://wttc.org/Research/Economic-Impact [14.09.2020.].
[13] vlada.gov.hr. 2020. Cappelli: 2020. *Za Turizam I Gospodarstvo Posebna Zbog Niza Međunarodnih Događanja*. [Internet] raspoloživo na: https://vlada.gov.hr/vijesti/cappelli-2020-za-turizam-i-gospodarstvo-posebna-zbog-niza-medjunarodnih-dogadjanja/28411 [14.09.2020.].

godine kada je udio bio 25%. Štoviše, WTTC prognozira i rast od 3.7% ukupnog doprinosa zapošljavanju u 2028. godini.[14]

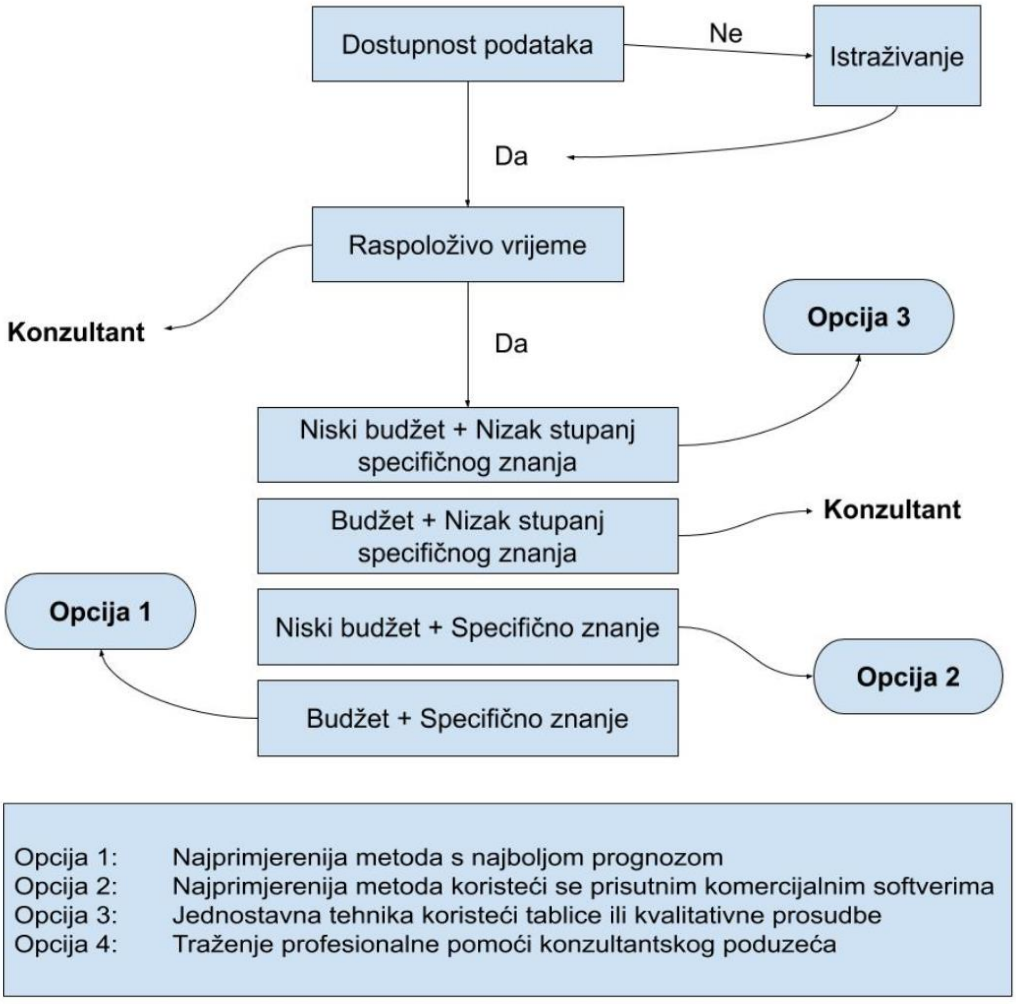
Dakle, od iznimne je važnosti pravilno prognozirati turističku potražnju kako bi se poticala ulaganja, rastao BDP te sačuvala radna mjesta.

[14] Wttc.org., Op. Cit, [Internet] raspoloživo na: https://wttc.org/Research/Economic-Impact [14.09.2020.].

3. ANALIZA TURISTIČKE POTRAŽNJE - ANALIZA POJMOVA I MODELA

Turistička potražnja mjeri se različitim varijablama. Neke od varijabli su prihodi od turizma, broj zaposlenih, izdaci za turizam u destinacijama te broj noćenja. Kako bi se uklonili trendovi i sezonalnost, neke studije prilikom predviđanja turističke potražnje filtriraju podatke.[15]

Postavlja se pitanje kako pravilno odabrati metodu za predviđanje turističke potražnje. Na sljedećoj mapi prikazan je proces donošenja odluke.



Slika 5: Proces donošenja odluke u vezi izbora metode predviđanja

Izvor: izrada autorice prema WTO 2008. *Handbook On Tourism Forecasting Methodologies*. Madrid: World Tourism Organization, str. 37.

[15] Vortelinos D., Vasiliadis L., Gkillas K. 2019. *Forecasting tourism demand in Europe*. ResearchGate. str. 5.

Na samom početku donošenja odluke valja ocijeniti dostupnost podataka. Ukoliko ne postoji dovoljna količina podataka ili je kvaliteta podataka nezadovoljavajuća, potrebno je provesti istraživanje ili kupiti podatke.

Nakon toga potrebno je ocijeniti koliko je vremena za prognoziranje na raspolaganju. Ukoliko nema dovoljno vremena na raspolaganju, preporučuje se traženje pomoći od nekog eksternog konzultanta koji je stručnjak u određenom polju.

Ukoliko je pak dovoljno vremena na raspolaganju, postoje četiri opcije na odabir.

1. Ukoliko je budžet za analizu i prognoziranje nizak, a znanje ograničeno preporuča se odabir opcije broj 3 te se koriste tablice, Microsoft Excel ili kvalitativne prosudbe što predstavlja jednostavnu i povoljnu metodu.
2. U slučaju kada ima dovoljno novca za ulaganje u potrebe prognoziranja, a jedini resurs koji je na nedovoljnoj razini je specifično znanje, preporuča se unajmljivanje konzultanta.
3. Sljedeći slučaj se odnosi na obrnutu situaciju kada postoji dovoljna količina specifičnog znanja uz nedovoljne resurse za financiranje. U toj situaciji najbolji izbor se čini korištenje dostupnih komercijalnih softvera.
4. Najbolji slučaj je kada su resursi za financiranje i specifično znanje u izobilju budući da se tada mogu postići najbolji rezultati. Tada poduzeće može razviti vlastite modele i/ili softversko rješenje kako bi primijenili najprimjereniju metodologiju.

Nakon ovih koraka potrebno je odlučiti koja će se metodologija koristiti prema razini sljedećih kriterija: specifično znanje koje poduzeće posjeduje, vrsti podataka, podacima koji ovise o vremenskim razdobljima, znanje o internim procesima, odgovarajućem horizontu prognoze, težini implementacije, troškovima razvoja, točnosti, veličini, lakoći interpretacije, troškovima održavanja, fleksibilnosti, potencijalnoj razini uštede te predmetu i cilju istraživanja.

Prema tome, može se odlučiti hoće li se koristiti metoda ekstrapolacije, uzročna metoda ili kvalitativna metoda. Jedan od načina po kojima se jednostavnije može odlučiti koja će se metoda prognoziranja koristiti je izrada matrice. Takva jedna matrica predstavlja jednu jednostavnu tablicu u kojoj se koriste zvjezdice (***) kako bi se objasnile potrebe korisnika, tj. ponašanje metode prema potrebama/zahtjevima:

- jedna zvjezdica (*): slabo ili nisko,
- dvije zvjezdice (**): umjereno ili srednje,

- tri zvjezdice (***): jako ili visoko.

Ti simboli većinom se dodjeljuju prema zahtjevima kao što su fleksibilnost, točnost, priuštivost, mogućnost nadogradnje, težina korištenja, kredibilitet, brzina, potreba za uključivanjem dodatnog mišljenja stručnjaka, održavanje, potreba za zaposlenicima, popularnost te zadovoljstvo korisnika.[16]

S obzirom na vrstu metode koju je moguće izabrati za predviđanje, dijele se na kvantitativne i kvalitativne metode predviđanja.

3.1. Kvalitativno predviđanje

Kvalitativno predviđanje ne oslanja se na brojke kao što je to slučaj s kvantitativnim predviđanjem. Ono se većinom koristi u kompliciranim i nepredviđenim slučajevima kao što su teroristički napadi. U takvim slučajevima, daje se veća važnost mišljenju i prijedlozima raznih stručnjaka.

Primjeri metoda kvalitativnog predviđanja su:

- Panel-konsenzus metoda (eng. *Jury of Executive Opinion*)
- Delfi metoda (eng. *The Delphi Method*)
- Planiranje scenarija (eng. *Scenario Planning*)

3.2. Kvantitativno predviđanje

Kao što je već rečeno, kvantitativno predviđanje se temelji na brojevima tj. na numeričkim vrijednostima. Postoje dva glavna tipa takvog predviđanja:

- metode ekstrapolacije (eng. *extrapolative methods*) - u tom tipu povijesni slijed se ekstrapolira u budućnost. Ovaj tip još se dijeli i na:
    - jednostavnu metodu ekstrapolacije (eng. *simple extrapolative methods*)
    - naprednu metodu ekstrapolacije (eng. *advanced extrapolative methods*)
- uzročne metode (eng. *causal methods*) - u tom tipu se za predviđanje koristi odnos turističke potražnje i nekog drugog faktora, primjerice tečaja.[17] Ovaj tip se još dijeli i na:

[16] WTO 2008., Op. cit, str. 37-40.
[17] Ibid. str. 2-3.

- uzročnu regresiju (eng. *causal regression*)
- uzročnu strukturnu (eng. *causal structural*).[18]

Postoji mnogo različitih metodologija kojima se može mjeriti turistička potražnja. Osnovne metodologije prognoziranja turističke potražnje uključuju

- jednostavnu linearnu regresiju (eng. *Simple Linear Regression*),
- metodu dekompozicije (eng. *Decomposition*),
- metodu bez promjenjivih varijabli (eng. *No-change models*),
- metodu s prosječnim kretanjem (eng. *Moving Average models*) te
- jednostavnu eksponencijalnu metodu zaglađivanja (eng. *Single Exponential Smoothing*).[19]

U sljedećem poglavlju obraditi će se različite vrste kvantitativnih i kvalitativnih metoda predviđanja.

[18] Ibid. str. 40.
[19] Ibid. str. vii

4. OSNOVNE METODE PROGNOZIRANJA TURISTIČKE POTRAŽNJE

Kod prognoziranja bitno je znati neke osnove kao što su pojmovi zavisnih i nezavisnih varijabli.

Zavisne varijable pri predviđanju uključuju ukupne dolaske, dolaske putnika iz stranih zemalja, dolaske putnika koji su rezidenti zemlje u kojoj putuju, broj noćenja, broj prodanih izleta, podatke o popunjenosti hotela, doprinos turizma u ukupnom bruto nacionalnom proizvodu i slično. Zavisne varijable su zapravo ono što se predviđa.[20]

S druge strane imamo nezavisne varijable koje se koriste kako bi se napravile prognoze, a one obuhvaćaju vrijeme, ekonomske varijable, demografske varijable, cijenu putovanja, tržišne varijable, političke varijable, klimu i ostalo.[21]

4.1. Ekstrapolacijska metoda

Ekstrapolacija označava: „općenito, proširivanje zakonitosti utvrđene u jednom užem području na šire područje. U matematici, određivanje nepoznatih veličina izvan jednog intervala na temelju poznatih vrijednosti u tom intervalu i poznate funkcionalne zavisnosti s pretpostavkom da funkcionalna zavisnost u poznatom području vrijedi i u nepoznatom".[22]

U području turizma cilj korištenja ove metode je „proširiti" povijesne podatke u budućnost. Na primjer, mogu se koristiti podaci o broju noćenja u prethodnim sezonama kako bi se predvidio broj noćenja u nadolazećoj sezoni s ciljem bolje pripreme.

Postoje jednostavna i napredne ekstrapolacijske metode.[23]

[20] Ibid. str. 2.
[21] Ibid. str. vii
[22] Enciklopedija.hr. 2020. *Ekstrapolacija | Hrvatska Enciklopedija*. [Internet] raspoloživo na: https://www.enciklopedija.hr/natuknica.aspx?ID=17472 [15.07.2020.].
[23] WTO 2008. Op. cit, str. 6.

4.1.1. Jednostavne ekstrapolacijske metode

Jednostavne ekstrapolacijske metode (eng. *simple extrapolative methods*) jednostavne su za korištenje te se baziraju na vremenskim razdobljima. Prema tome, najčešće se koriste za predviđanje podataka u vremenskim razdobljima.[24]

4.1.1.1. Ekstrapolacijska metoda bez promjene

Ekstrapolacijska metoda bez promjene (eng. *No-Change Extrapolation Method*) koristit će se u sljedećem zadatku kako bi se prognozirao broj noćenja u gradu Zadru za srpanj 2019. godine prema podacima iz srpnja 2016. i 2017. godine.

Ova vrsta naziva se još i naivna (naïve) metoda. Ova vrsta predviđanja često se koristi i najčešće daje najpreciznije podatke. [25]

Tablica 1: Broj noćenja u srpnju u gradu Zadru i predviđanje broja noćenja za srpanj 2019.

Godina	Broj noćenja
Srpanj 2016	90911
Srpanj 2017	108752
Srpanj 2018	109348

Izvori: Stranica Državnog zavoda za statistiku Republike Hrvatske i službena internetska stranice ministarstva turizma i sporta.[26]

Za vrijednost prognoze ($\mathbf{F_t}$) uzima se stvarni broj ostvarenih noćenja u ranijem vremenskom razdoblju ($\mathbf{A_{t-1}}$), tj. iz 2018. godine.

[24] Ibid. str. 40.
[25] Ibid. str. 6.
[26]
D4zs.hr. 2016. TURIZAM U SRPNJU 2016./TOURISM, JULY 2016. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2016/04-04-01_07_2016.htm [13.8.2020.].
Dzs.hr. 2017. TURIZAM U SRPNJU 2017./TOURISM, JULY 2017. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2017/04-04-01_07_2017.htm [13.08.2020.].
Dzs.hr. 2018. TURIZAM U SRPNJU 2018./TOURISM, JULY 2018. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/04-04-01_07_2018.htm [13.08.2020].
Dzs.hr. 2019. TURIZAM U SRPNJU 2019./TOURISM, JULY 2019. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2019/04-04-01_07_2019.htm [13.08.2020].

$\mathbf{F_t = A_{t-1}}$

= 109348

Nadalje, prognoza broja noćenja za 2019. godinu izračunava se na sljedeći način:

$\mathbf{F_t = A_{t-1} * (A_{t-1} / A_{t-2})}$

= 109348 * (109348/108752)

= **109947**

Dakle, ekstrapolacijskom metodom dobije se prognoza od 109 947 broja noćenja na području Zadra za srpanj 2019. godine. Stvarno ostvareni broj noćenja u tom periodu je 115 427.

4.1.1.2. Jednostavna metoda ekstrapolacije pokretnog prosjeka

Jednostavna metoda ekstrapolacije pokretnog prosjeka (eng. *Simple Moving Average Extrapolation Method*) koristi se na način da se uzmu vrijednosti od nekoliko prethodnih razdoblja i pronađe srednja vrijednost kako bi se prognozirala buduća vrijednost.

Uzevši podatke iz prethodnog primjera, broj noćenja na području Zadra za srpanj 2019. godine prognozirat će se na sljedeći način:

$\mathbf{F_t = (A_{t-1} + A_{t-2} + A_{t-2}) / n}$

= (90911 + 108752 + 109348) / 3

= 103004

Kako bi se usporedila točnost prognoze ekstrapolacijske metode bez promjene i jednostavne metode ekstrapolacije pokretnog prosjeka, može se izračunati magnituda točnosti pogreške (eng. Error Magnitude Accuracy) na sljedeći način:

$$\mathbf{e_t = (A_t - F_t)}$$

Pri tome, "t" predstavlja vremensko razdoblje, "e" pogrešku prognoze, "A" ostvarenu vrijednost, a "F" prognoziranu vrijednost.

Izračun pogreške za prognozu ekstrapolacije metode bez promjene:

$$e_{2019} = (115427 - 109947) = 5\ 480$$

Izračun pogreške za prognozu jednostavne metode ekstrapolacije pokretnog prosjeka:

$$e_{2019} = (115427 - 103004) = 12\ 423$$

Nadalje, postotnu promjenu izračunavamo na sljedeći način koji se naziva MAPE pri čemu "n" označava broj vremenskih razdoblja:

$$\mathbf{MAPE = 1 / n * (e_t / A_t) * 100}$$

Izračun MAPE za prognozu ekstrapolacije metode bez promjene:

$$MAPE = 1 / 3 * (5480 / 115427) * 100$$

$$= 1{,}6\ \%$$

Izračun MAPE za prognozu jednostavne metode ekstrapolacije pokretnog prosjeka:

$$MAPE = 1 / 3 * (12423 / 115427) * 100$$

$$= 3{,}6\ \%$$

Dakle, može se zaključiti kako točniju, tj. precizniju prognozu na ovom primjeru daje ekstrapolacijska metoda bez promjene s greškom od 1,6%.

4.1.1.3. Metoda eksponencijalnog zaglađivanja

Predviđanje metodom eksponencijalnog zaglađivanja (eng. *Exponential Smoothing Extrapolation method*) često se koristi u turizmu za srednjoročna predviđanja i planiranja. Nešto manje je točna kada se radi u dugoročnom planiranju.

Pri korištenju te metode uzimaju se u obzir vrijednosti nekoliko prošlih vremenskih razdoblja, ali se najviše vrijednosti pridaje najnovijim podacima.[27]

Primjer korištenja ove metode možemo vidjeti na prognozi dolazaka turista u republiku Hrvatsku u rujnu 2020. na temelju podataka o dolascima u proteklim mjesecima.

Tablica 2: Broj dolazaka turista po mjesecima u 2020. godini i prognoza broja dolazaka

[27]WTO 2008. Op. cit, str. 9-12.

	Dolasci Turista u 2020. godini	Prognoza
Siječanj	207,643	-
Veljača	278,741	207,643
Ožujak	104,391	271,631
Travanj	2,241	121,115
Svibanj	62,049	14,128
Lipanj	797,696	57,257
Srpanj	2,245,831	723,652
Kolovoz	2,700,000	2,093,613
Rujan	-	2,639,361

Izvori: Stranica Državnog zavoda za statistiku Republike Hrvatske i službena internetska stranice ministarstva turizma i sporta. [28]

Na početku prognoziranja potrebno je prikupiti stvarne podatke za proteklih nekoliko razdoblja. Za ovaj primjer uzeti su mjeseci 2020. godine. Za prvu prognoziranu vrijednost u veljači 2020. godine uzeta je prva stvarna vrijednost iz siječnja 2020. godine, a za vrijednost parametra izglađivanja alfa uzeta je vrijednost od 0.9. Ovaj parametar kreće se između nule (0) i jedan (1) koji se inače koristi za najnovije promatrane podatke. Prognozirana vrijednost označava se slovom „F", a stvarna vrijednost slovom „A".

[28] Dzs.hr. 2020. TURIZAM U SIJEČNJU 2020./TOURISM, Siječanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_01_2020.htm [13.09.2020.].
Dzs.hr. 2020. TURIZAM U VELJAČI 2020./TOURISM, Veljača 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-02_01_2020.htm [13.09.2020.].
Dzs.hr. 2020. TURIZAM U OŽUJKU 2020./TOURISM, Ožujak 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_03_2020.htm [13.09.2020.].
Dzs.hr. 2020. TURIZAM U TRAVNJU 2020./TOURISM, Travanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_04_2020.htm [13.09.2020.].
Dzs.hr. 2020. TURIZAM U SVIBNJU 2020./TOURISM, Svibanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_05_2020.htm [13.09.2020.].
Dzs.hr. 2020. TURIZAM U LIPNJU 2020./TOURISM, Lipanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_06_2020.htm [13.09.2020.].
Dzs.hr. 2020. TURIZAM U SRPNJU 2020./TOURISM, Srpanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_07_2020.htm [13.09.2020.].
mint.hr. 2020. Hrvatski Turizam Premašio Očekivanja: Do Kraja Kolovoza Ostvareno 53 Posto Lanjskog Rezultata. [Internet] raspoloživo na: https://mint.gov.hr/vijesti/hrvatski-turizam-premasio-ocekivanja-do-kraja-kolovoza-ostvareno-53-posto-lanjskog-rezultata/21821 [13.09.2020.].

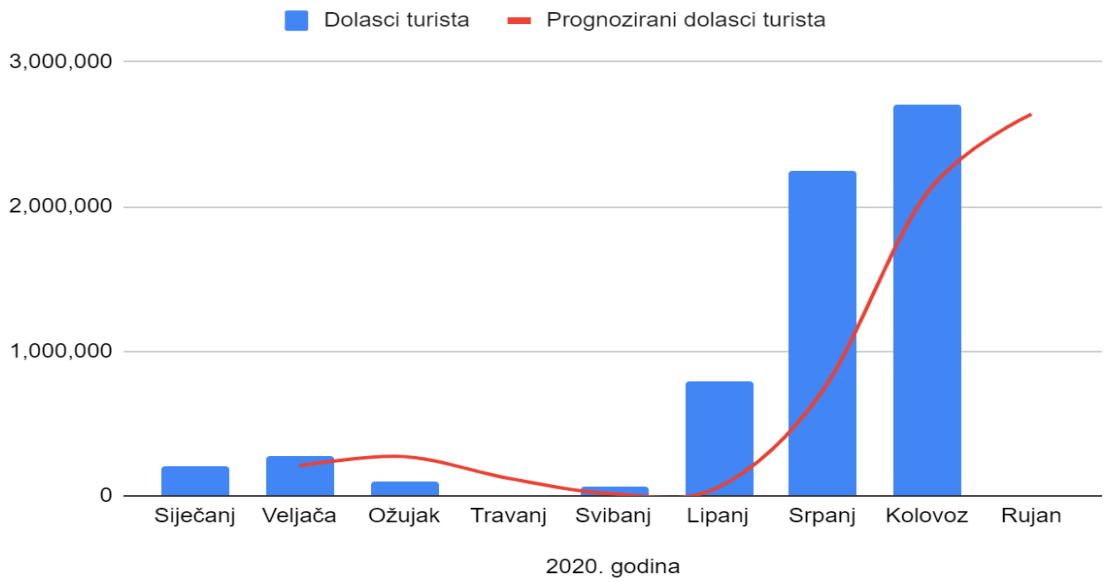
Predviđena vrijednost izračunava se sljedećom formulom:[29]

$$F_t = \alpha * AL_{t-1} + (1-\alpha) * F_{t-1}$$

= 0.9 * 2 700 000 + (1-0.9) * 2 093 613

= 2 639 361 (prognozirana vrijednost za rujan 2020. godine)

Odnos ostvarenih dolazaka turista naspram prognoziranih možemo grafički prikazati na sljedećem grafikonu.



Graf 3: Stvarni broj dolazaka turista po mjesecima u 2020. godini naspram prognoziranog broja dolazaka

Izvor: izrada autorice prema podacima DZS

4.1.1.4. Dekompozicijske metode

Dekompozicijske metode (eng. *Decomposition Methods*) koriste se kako bi se uzeli u obzir jedinstveni trendovi i nepravilnosti uzrokovane različitim događanjima (eng. *events*) koje imaju direktan utjecaj na primjerice činjenicu hoće li turisti posjetiti neku destinaciju u određeno vrijeme u godini. Ova metoda razlaže vremenske serije na sastavne dijelove.[30]

[29] WTO 2008. Op. cit, str. 9-12.

[30] Ibid. str. 13

4.1.2. Napredna ekstrapolacijska metoda

Drugi tip ekstrapolacijske metode je napredna ekstrapolacijska metoda. Ona se također koristi za predviđanje podataka u vremenskim razdobljima, ali u usporedbi s jednostavnom ekstrapolacijskom metodom, koristi se za strateški razvoj na temelju podataka predviđanja. Glavna značajka ove metode je preciznost koja se postiže simulirajući povijesne podatke u budućnosti.[31]

4.1.2.1. Metoda autoregresivnog pokretnog prosjeka

Metoda autoregresivnog pokretnog prosjeka (eng. *Autoregressive Moving Average (ARMA) Method*) naziva se još i Box-Jenkins metoda te se najčešće koristi za kompleksnije modele. Ovom metodom se traži najbolja kombinacija autoregresivne metode (eng. *Autoregressive Method*) i metode pokretnog prosjeka (eng. *Moving Average Method*).[32]

4.2. Uzročni modeli

Uzročni modeli u usporedbi s ekstrapolacijskim metodama ne uzimaju u obzir samo zavisnie varijable, već i nezavisne.[33]

4.2.1. Uzročna regresija

Uzročna regresija (eng. *Causal regression*) ocjenjuje međuodnose između varijabli kako bi se shvatio njihov utjecaj. U obzir se uzimaju push i pull faktori te faktori otpora.[34]

4.2.1.1. Metoda linearne regresije

Metoda linearne regresije koristi se za analiziranje teorijskih tvrdnji odnosa među pojedinim varijablama. U slučaju jednostavne linearne regresijske analize pretpostavljaju se sljedeći odnosi između varijabli:

$$\mathbf{Y = \alpha + \beta x}^{35}$$

[31] Ibid. str. 40
[32] Ibid. str. 17
[33] Ibid. str. 18
[34] Ibid. str. 40
[35] Zaspan L., Đukec D. 2016. *Procjena i prognoza potražnje metodom regresijske analize: studija slučaja zaštitarska tvrtka Alzas alarms d.o.o.* Čakovec: Međimursko veleučilište u Čakovcu, str. 2-3.

S ciljem pojašnjenja korištenja ove metode, u sljedećem primjeru uzeti će se vrijeme od 11 godina kao nezavisnu varijablu i korištenjem Microsoft Excela prognozirati podatke za srpanj 2020. godine.

Tablica 3: Broj noćenja u Splitsko-dalmatinskoj županiji u mjesecu srpnju od 2010. do 2020. godine

Godina	Period	Broj noćenja
Srpanj 2010	1	3,072,588
Srpanj 2011	2	3,295,486
Srpanj 2012	3	3,309,222
Srpanj 2013	4	3,583,033
Srpanj 2014	5	12,134,612
Srpanj 2015	6	13,288,805
Srpanj 2016	7	4,648,671
Srpanj 2017	8	5,185,544
Srpanj 2018	9	5,390,710
Srpanj 2019	10	5,341,711
Srpanj 2020	11	**7,554,757**

Izvor: Priopćenje ostvarenih rezultata za srpanj od godine 2010. do 2020. [36]

[36] Dzs.hr. 2010. TURIZAM U SRPNJU 2010./TOURISM, JULY 2010. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2010/04-04-01_07_2010.htm [13.09.2020.].
Dzs.hr. 2011. TURIZAM U SRPNJU 2011./TOURISM, JULY 2011. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2012/04-04-01_07_2011.htm [13.09.2020.].
Dzs.hr. 2012. TURIZAM U SRPNJU 2012./TOURISM, JULY 2012. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2012/04-04-01_07_2012.htm [13.09.2020.].
Dzs.hr. 2013. TURIZAM U SRPNJU 2013./TOURISM, JULY 2013. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2013/04-04-01_07_2013.htm [13.09.2020.].
Dzs.hr. 2014. TURIZAM U SRPNJU 2014./TOURISM, JULY 2014. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2014/04-04-01_07_2014.htm [13.09.2020.].
Dzs.hr. 2015. TURIZAM U SRPNJU 2015./TOURISM, JULY 2015. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2015/04-04-01_07_2015.htm [13.09.2020.].
Dzs.hr. 2016. TURIZAM U SRPNJU 2016./TOURISM, JULY 2016. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2016/04-04-01_07_2016.htm [13.09.2020.].
Dzs.hr. 2017. TURIZAM U SRPNJU 2017./TOURISM, JULY 2017. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2017/04-04-01_07_2017.htm [13.09.2020.].
Dzs.hr. 2018. TURIZAM U SRPNJU 2018./TOURISM, JULY 2018. [Internet] raspoloživo na:

Metodom linearne regresijske analize, prognoza za ukupan broj noćenja je 7 554 757.

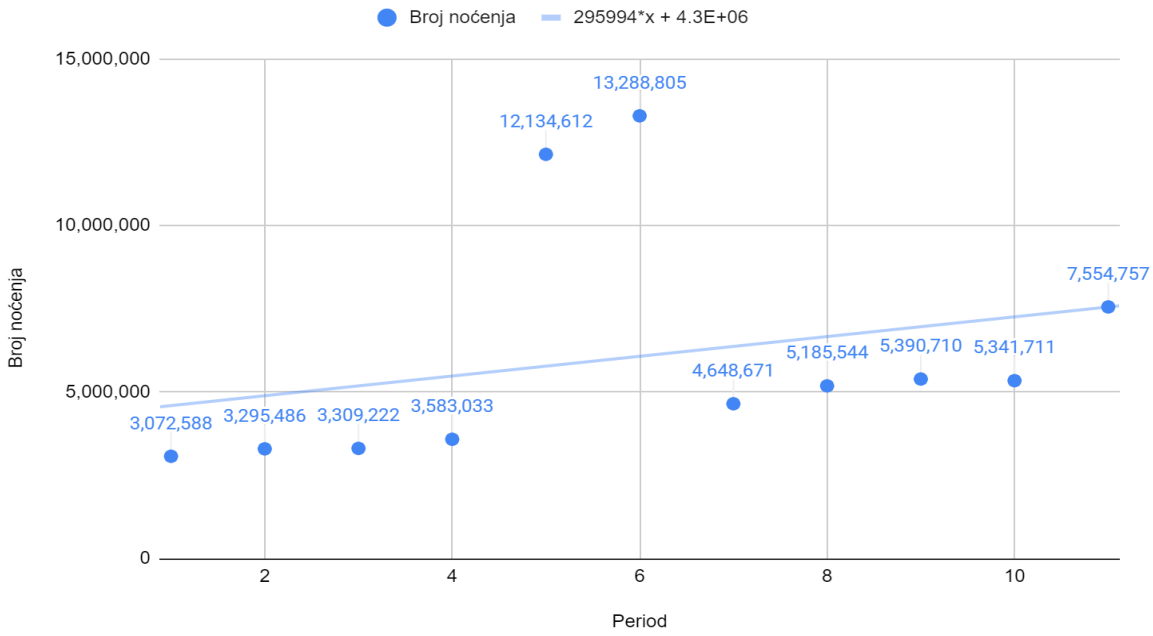
Ovaj broj dobiven je sljedećom jednadžbom:

Y = 295 887 * x + 4 300 000

= **7 554 757** (kada uzmemo u obzir da je x = 11)

Vrijednosti parametara alfa (α) i beta (β) dobiveni su korištenjem dodatka u Microsoft Excel programu na temelju podataka o broju noćenja od 2010. do 2019. godine.

Stvaran broj noćenja ostvaren u srpnju 2020. godine iznosi 2 897 370.



Graf 4: Predviđanje broja noćenja koristeći se jednostavnom linearnom regresijskom ekstrapolacijskom metodom

Izvor: izrada autorice prema podacima DZS

S druge strane, ako bismo ovaj isti model iskoristili i prognozirali broj noćenja u srpnju 2019. godine na temelju podataka od 2016. godine, izostavivši godine kada su na turističku potražnju

https://www.dzs.hr/Hrv_Eng/publication/2018/04-04-01_07_2018.htm [13.09.2020.].
Dzs.hr. 2019. TURIZAM U SRPNJU 2019./TOURISM, JULY 2019. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2019/04-04-01_07_2019.htm [13.09.2020.].
Dzs.hr. 2020. TURIZAM U SRPNJU 2020./TOURISM, JULY 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-04-01_07_2020.htm [13.09.2020.].

snažan utjecaj imali vanjski utjecaji, procijenjeni broj noćenja za srpanj 2019. godine ne bi jako odstupao od ostvarenog broja noćenja. Korištenjem jednadžbe:

Y = 371 020 * 4 + 4 330 000

dobivamo prognozu od 5 814 080 noćenja za srpanj 2019. godine dok ostvareni broj noćenja iznosi 5 341 711.

4.2.1.2. Višestruke regresijske metode

Višestruke regresijske metode (eng. *Multiple Regression Methods*) dio su općih linearnih procedura modeliranja (eng. *General Liner Modeling (GLM)*), a u današnje vrijeme dostupni su putem mnogih statističkih programa kao što je SPSS. Bitna značajka korištenja ove metode je kako je veći naglasak na odabiru nezavisnih varijabli, odabiru metode i interpretaciji rezultata, a ne na izvođenju računskih operacija.[37]

4.2.2. Uzročna strukturna

Uzročna strukturna metoda (eng. *Causal Structural*) koristi se kada se želi ispitati međuovisnost varijabli pri čemu se ispituju push, pull te faktori otpora kao i kod metode uzročna regresije. Cilj korištenja ove metode je donošenje odluka u vezi razvoja politika bazirajući se na ekonomskim utjecajima.[38]

4.3. Metode kvalitativnog predviđanja

Što više vremena prolazi, tradicionalne metode predviđanja nisu u mogućnosti dati dobre rezultate zbog sve većeg raspona neizvjesnosti. Iz tog razloga potrebno je potražiti pomoć od najpreciznijeg i najsnažnijeg računala, a to je ljudski mozak. Stručnjaci koji imaju veliko iskustvo u dosta slučajeva mogu predvidjeti mnoge događaje koje niti jedna matematička jednadžba nije u mogućnosti izračunati. Štoviše, ova vrsta predviđanja uz jednostavne metode ekstrapolacije su najčešće korištene budući da su povoljne te daju odlične rezultate.[39]

[37] WTO 2008. Op. cit, str. 21.
[38] Ibid. str. 40.
[39] Ibid. str. 27-28.

4.3.1. Panel-konsenzus metoda

Panel-konsenzus metoda (eng. *Jury of Executive Opinion*) vrlo je fleksibilna metoda koja se koristi za predviđanje jednostavne turističke potražnje. Kao što i samo ime metode govori, ključnu ulogu u ovoj metodi ima stručno znanje i iskustva sudionika koji donose odluku. Ova se metoda najčešće koristi u vremenima kada ne postoji dovoljno informacija iz prošlosti, primjerice u slučajevima prirodnih katastrofa, kako bi se predvidjeli podaci. [40]

Postoje tri koraka koja se slijede:

1. Identificirati pojedince unutar ili van organizacije za koje se smatra da imaju dovoljno stručnog mišljenja i iskustva u polju koje se želi analizirati.
2. Ukoliko je primjereno, izvršiti kvantitativnu analizu kako bi rezultati te analize pomogli pri odluci.
3. Organizirati sastanke za cijeli period sve dok se ne donese odluka.[41]

Primjer korištenja ove metode može se vidjeti na primjeru prognoziranja broja dolazaka stranih turista u Republiku Hrvatsku u kolovozu 2020. godine s obzirom na pandemiju Korona virusa koja ima izrazito negativan utjecaj na turizam u smislu nemogućnosti putovanja, epidemioloških mjere itd.

Za potrebe objašnjenja ovog zadatka i s obzirom da autorica izvršava kompletnu analizu, preskače se prvi korak te se prelazi na drugi gdje se izvršava kvantitativna analiza.

Koristit će se ekstrapolacijskom metodom uzimajući u obzir podatke iz srpnja i kolovoza od 2018. do 2020. godine.

Tablica 4: Broj dolazaka stranih turista tijekom srpnja i kolovoza od 2018. do 2020. godine

Godina	**Mjesec**	**Broj dolazaka stranih turista u RH**
2018	Srpanj	4088802
2019	Srpanj	4067804
2020	Srpanj	1968427

[40] Ibid. str. 40.
[41] Ibid. str. 28.

2018	Kolovoz	3953327
2019	Kolovoz	4085443
2020	Kolovoz	2227561

Izvor: Izrada autorice prema podacima iz priopćenja o ostvarenim rezultatima Državnog zavoda za statistiku i Hrvatske turističke zajednice.[42]

Izračun prognoziranog broja dolaska stranih turista u kolovozu 2020. godine i odstupanja od ostvarenih vrijednosti:

$\mathbf{F_{2020} = A_{2019} * (A_{2019} / A_{2018})}$

= 4 085 443 * (4 085 443 / 3 953 327)

= 4 221 974

$\mathbf{e_{2020} = (A_{2020} - F_{2020})}$

= (2 227 561 - 4 221 974)

= -1 994 413

$\mathbf{MAPE = 1 / n * (e_{2020} / A_{2020}) * 100}$

= 1 / 2 * (-1 994 413 / 2 227 561) * 100

= -44,77%

42

Dzs.hr. 2018. TURIZAM U SRPNJU 2018./TOURISM, Srpanj 2018. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/04-03-01_07_2018.htm [13.09.2020.].
Dzs.hr. 2019. TURIZAM U SRPNJU 2019./TOURISM, Srpanj 2019. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2019/04-03-01_07_2019.htm [13.09.2020.].
Dzs.hr. 2020. TURIZAM U SRPNJU 2020./TOURISM, Srpanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_07_2020.htm [13.09.2020.].
Dzs.hr. 2018. TURIZAM U KOLOVOZU 2018./TOURISM, Kolovoz 2018. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/04-03-01_08_2018.htm [13.09.2020.].
Dzs.hr. 2019. TURIZAM U KOLOVOZU 2019./TOURISM, Kolovoz 2019. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2019/04-03-01_08_2019.htm [13.09.2020.].
Htz.hr. 2020. [Internet] raspoloživo na: https://www.htz.hr/sites/default/files/2020-09/Informacija%20o%20statistickim%20pokazateljima%20-%20kolovoz%202020.pdf [13.09.2020.].

Izračun prognoziranog broja dolaska stranih turista u srpnju 2020. godine i odstupanja od ostvarenih vrijednosti:

$\mathbf{F_{2020}} = \mathbf{A_{2019}} * (\mathbf{A_{2019}} / \mathbf{A_{2018}})$

$= 4\,067\,804 * (4\,067\,804 / 4\,088\,802)$

$= 4\,046\,914$

$\mathbf{e_{2020}} = (\mathbf{A_{2020}} - \mathbf{F_{2020}})$

$= (1\,968\,427 - 4\,046\,914)$

$= -2\,078\,487$

$\mathbf{MAPE} = \mathbf{1 / n * (e_{2020} / A_{2020}) * 100}$

$= 1 / 2 * (-2\,078\,487 / 1\,968\,427) * 100$

$= -52{,}8\%$

Kada se u prognoziranu vrijednost za kolovoz 2020. godine uračuna pogreška za srpanj 2020. godine (4 046 914*(1-0,528)), može se zaključiti kako bi Republika Hrvatska mogla očekivati oko 1 910 143 dolazaka stranih turista.

Nakon kvantificiranja očekivanog broja stranih turista treba uzeti vanjske učinke u obzir koji se ne mogu izračunati matematički, a to su:

- popuštanje epidemioloških mjera tijekom srpnja
- Republika Hrvatska ima izrazito nizak broj zaraženih Koronavirusom
- zbog strogih epidemioloških mjera tijekom početka 2020. mnogi ljudi nisu imali priliku iskoristiti slobodne dane, tj. godišnji odmor koji su se u većini slučajeva do sada akumulirali
- mnogi ljudi žele putovanje u mjesta u prirodi, kao što je Hrvatska obala s obzirom da su veliku većinu 2020. godine proveli kod kuće
- cijene avionskih karata su zbog neizvjesnosti dosta povoljnije
- U zemljama kao što je Njemačka koja je jedna od Hrvatskoj najbližih zemalja i iz koje značajan broj turista dolazi, testiranje na Koronavirus je besplatno[43]

[43]Bundesgesundheitsministerium. 2020. *Fragen Und Antworten*. [Internet] raspoloživo na: https://www.bundesgesundheitsministerium.de/coronavirus-infos-reisende/faq-tests-

- Hrvatska Turistička Zajednica uložila je mnogo sredstava i provela kampanje „*Vacation you deserve is closer than you think*" i „*Enjoy the view from Croatia*" koje je vidjelo više od 100 milijuna ljudi[44]
- Već 1. srpnja prodano je svih 30.000 karata direktnog vlak koji kreće iz Praga i vozi direktno do Rijeke[45]
- zabilježeno je znatno povećanje turističke potražnje za ponudama usluga Dalmatinske zagore gdje turisti mogu boraviti u prirodi i boraviti u luksuznim smještajnim objektima na osami te time svesti mogućnost zaraze Koronosavirusom na minimum[46]

Na temelju svega toga, autorica zaključuje kako se na prognoziranu vrijednost od 1 910 143 može zasigurno dodati 10% (1 910 143*1.1) nakon čega se dobije prognoza od **2 101 157** potencijalnih posjetitelja iz stranih zemalja.

Nadalje, budući kako autorica sama prognozira vrijednost, nije potrebno organizirati sastanke iz koraka broj 3.

Ipak, potrebno je izmjeriti kvalitetu autoričine prognoze izračunavši pogrešku, tj. postotno odstupanje prognozirane od ostvarene vrijednosti.

$$\mathbf{e_{2020} = (A_{2020} - F_{2020})}$$

$$= (2\ 227\ 561 - 2\ 101\ 157)$$

$$= 126\ 404$$

$$\mathbf{MAPE = 1 / n * (e_{2020} / A_{2020}) * 100}$$

$$= 1 / 2 * (126\ 404 / 2\ 227\ 561) * 100$$

$$= 2{,}84\%$$

einreisende.html#:~:text=Wo%20k%C3%B6nnen%20sich%20Einreisende%20testen,bei%20einem%20niedergelassenen%20Arzt%20erfolgen. [14.09.2020.].

[44] Mint.gov.hr. 2020. *Analiza turističkog prometa i pregled provedenih aktivnosti tijekom srpnja i kolovoza 2020. godine*. [Internet] raspoloživo na: https://mint.gov.hr/UserDocsImages//AAA_2020_MINTIS/dokumenti//200911_sezona_press.pdf [14.09.2020.].

[45] Dnevnik.hr. 2020. *Česi Stižu Vlakom U Hrvatsku, Sve Su Karte Rasprodane: "30.000 Prodanih Karata Je Nešto Fantastično"*. [Internet] raspoloživo na: https://dnevnik.hr/vijesti/hrvatska/vlakom-za-odmor-cesti-dolaze-na-ljetovanje-u-hrvatskoj---611276.html [14.09.2020.].

[46] gradonacelnik.hr. 2020. *Vile s bazenima lansirale Imotski među nove turističke hit destinacije, a mogle bi spasiti i sezonu nakon korone*. [Internet] raspoloživo na: https://gradonacelnik.hr/vijesti/imotski-lani-su-imali-16-posto-vise-turistickih-dolazaka-i-30-posto-vise-nocenja/ [14.09.2020.]

Iz ovog primjera možemo vidjeti kako ponekad za vrijeme vremenskih nepogoda, ili u ovom primjeru pandemije virusa, kada povijesni podaci nisu dovoljni, ljudska komponenta pri predviđanju turističke potražnje ključna je za dobivanje preciznijih vrijednosti. U ovom primjeru, pogreška prognoze iznosi 2,84% što je značajno preciznije od prognoze koju daje ekstrapolacijska metoda s pogreškom od -44.77%.

4.3.2. Delfi metoda

Delfi metoda (eng. *The Delphi Method*), kao i panel-konsenzus metoda fleksibilna je, ovisi o iskustvu i znanju pojedinaca koji sudjeluju pri donošenju odluke te se koristi za predviđanje jednostavne turističke potražnje.[47]

Ovom metodom može se koristi za mnogo različitih tematika, od predviđanja terorističkih napada do predviđanja prihoda od turizma u sljedećim godinama. Baza ove metode su upitnici kojima se pokušava postići konsenzus, tj. zajednički dogovor o vrijednostima predviđanja od strane grupe stručnjaka.

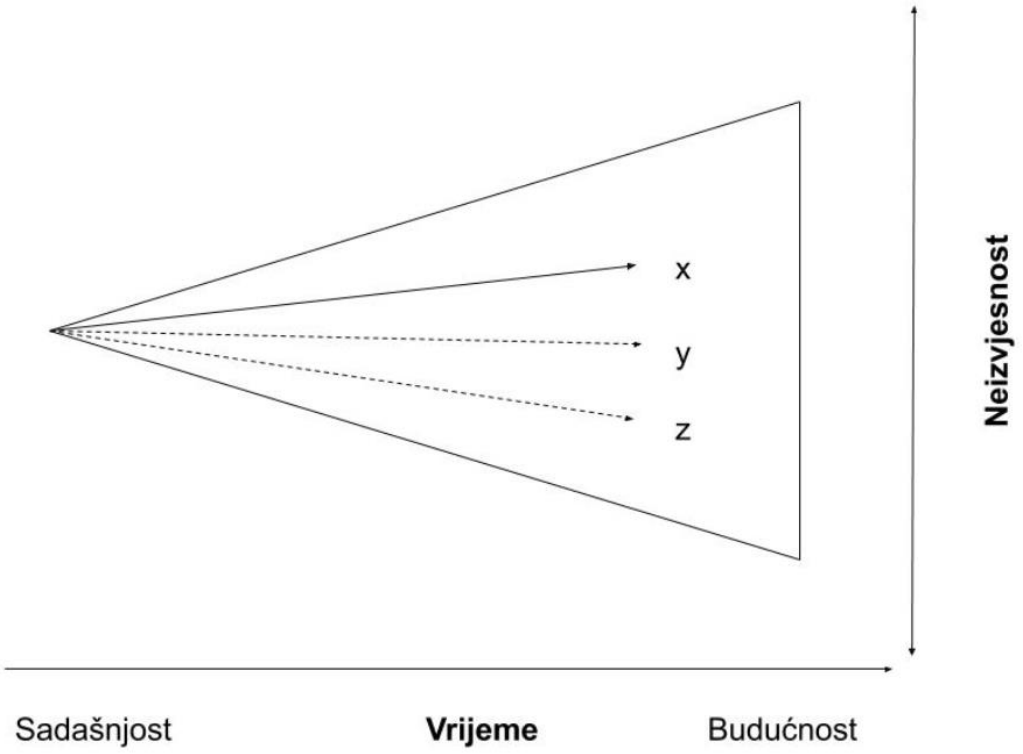
4.3.3. Planiranje scenarija

Metoda planiranja scenarija (eng. *Scenario Planning*) koristi se za predviđanje složenih i nesigurnih budućnosti i provjeravanje budućnosti. Ova metoda je fleksibilna te su za njenu kvalitetu ključni stručno znanje i informacije kako bi se razvili scenariji.[48]

Dakle, cilj ove metode je prikazati realistični set mogućih scenarija koji se mogu dogoditi u budućnosti kako bi organizacije znale kako odgovoriti na izazove koje takvi scenariji nose.

To se može prikazati na sljedećem grafikonu.

[47] WTO 2008. Op. cit, str. 40.
[48] Ibid. str. 40.



Graf 5: Raspon neizvjesnosti

Izvor: izrada autorice prema WTO 2008. *Handbook On Tourism Forecasting Methodologies*. Madrid: World Tourism Organization, str. 30.

Koraci provođenja ove metode su:

1. određivanje vremenskog razdoblja od primjerice 5 ili 10 godina
2. identificiranje sila koje mogu utjecati na turističku potražnju
3. izrada alternativnih scenarija
4. prezentacija scenarija vanjskim stručnjacima i stručnjacima unutar organizacije
5. usavršavanje i rekonstrukcija scenarija protekom vremena
6. kvantificiranje efekata svakog scenarija koristeći se uzročnim strukturnim modelima.[49]

[49] Ibid. str. 30-31.

5. ZAKLJUČAK

Turistička potražnja jedna je od ključnih odrednica razvoja politike turizma. Prilikom analize turističke potražnje i razvoja strategija turizma koriste se razni podaci poput broja dolazaka i noćenja domaćih i stranih turista, broja dolazaka i noćenja prema smještajnim kapacitetima i zemljama prebivališta te se analiziraju postojeća i potencijalna tržišta, konkurentske destinacije, određuju se ciljna tržišta i segmenti, određuju se smjernice za razvoj turističkog proizvoda, donose se investicijske strategije te se na kraju iznosi akcijski plan.[50]

Kako bi se prognozirala turistička potražnja koriste se razne metodologije. Postoje kvantitativne i kvalitativne metode. Kvantitativne metode se temelje na podacima i preciznim izračunima dok se kvalitativne temelje na stručnom mišljenju i iskustvu ljudi. Odabir metode ovisi o nekoliko faktora, a neki od najbitnijih su dostupnost podataka, raspoloživo vrijeme te znanje. Nadalje, odabir određene metode može se temeljiti na karakteristikama koju su bitne za istraživanje kao što su točnost, težina uporabe i interpretacije, fleksibilnost, brzina, kredibilitet i drugo.

S obzirom na provedena istraživanja u ovom radu, primjena kombinacije kvantitativnih i kvalitativnih metoda čini se kao najbolji mogući odabir. Činjenica je kako niti jedna jednadžba ne može u izračun uzeti toliko različitih varijabli koje u obzir može uzeti najmoćnije računalo na svijetu, ljudski mozak. Dakako je od iznimne koristi dobiti okvirne brojeve nekom od kvantitativnih metoda, ali zaključak je kako se najtočniji rezultati dobivaju kada se dobivena vrijednost kvantitativnom metodom poboljša i unaprijedi znanjem dobivenim jednom od kvalitativnih metoda.

Kao što je već objašnjeno, turizam igra bitnu ulogu u bruto domaćem proizvodu, a posebice u Republici Hrvatskoj. Zbog pandemije Koronavirusa, sektor turizma je pretrpio veliki negativni utjecaj što će u mnogim zemljama izravno prouzročiti usporavanje rasta BDP-a, zaposlenosti i sveukupnog ekonomskog rasta. Upravo iz tog razloga je ključno sada analizirati turističku potražnju kako bi se predvidjeli trendovi, donijeli strateški akcijski planovi te time očuvali gospodarstvo i prosperitet zemalja.

[50] Mint.gov.hr. 2020. *Prijedlog strategije razvoja turizma Republike Hrvatske do 2020. godine* [Internet] raspoloživo na: https://mint.gov.hr/UserDocsImages/dokumenti/Strategija-turizam-2020-veljaca2013.pdf [14.09.2020.].

6. LITERATURA

1. Bundesgesundheitsministerium. 2020. Fragen Und Antworten. [Internet] raspoloživo na: https://www.bundesgesundheitsministerium.de/coronavirus-infos-reisende/faq-tests-einreisende.html#:~:text=Wo%20k%C3%B6nnen%20sich%20Einreisende%20testen,bei%20einem%20niedergelassenen%20Arzt%20erfolgen. [14.09.2020.].
2. Cherowbrier, J., 2020. Euro To U.S. Dollar Exchange Rate 1999-2018 | Statista. [Internet] Statista. raspoloživo na: https://www.statista.com/statistics/412794/euro-to-u-s-dollar-annual-average-exchange-rate/ [12.08.2020.].
3. D4zs.hr. 2016. TURIZAM U SRPNJU 2016./TOURISM, JULY 2016. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2016/04-04-01_07_2016.htm [13.8.2020.].
4. Dnevnik.hr. 2020. Česi Stižu Vlakom U Hrvatsku, Sve Su Karte Rasprodane: „30.000 Prodanih Karata Je Nešto Fantastično". [Internet] raspoloživo na: https://dnevnik.hr/vijesti/hrvatska/vlakom-za-odmor-cesti-dolaze-na-ljetovanje-u-hrvatskoj---611276.html [14.09.2020.].
5. Dulčić, A., Turizam-načela razvoja i praksa, Ekonomski fakultet Split i Institut za turizam Zagreb, 1991., str. 27.
6. Dzs.hr. 2010. TURIZAM U SRPNJU 2010./TOURISM, JULY 2010. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2010/04-04-01_07_2010.htm [13.09.2020.].
7. Dzs.hr. 2011. TURIZAM U SRPNJU 2011./TOURISM, JULY 2011. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2012/04-04-01_07_2011.htm [13.09.2020.].
8. Dzs.hr. 2012. TURIZAM U SRPNJU 2012./TOURISM, JULY 2012. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2012/04-04-01_07_2012.htm [13.09.2020.].
9. Dzs.hr. 2013. TURIZAM U SRPNJU 2013./TOURISM, JULY 2013. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2013/04-04-01_07_2013.htm [13.09.2020.].
10. Dzs.hr. 2014. TURIZAM U SRPNJU 2014./TOURISM, JULY 2014. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2014/04-04-01_07_2014.htm [13.09.2020.].
11. Dzs.hr. 2015. TURIZAM U SRPNJU 2015./TOURISM, JULY 2015. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2015/04-04-01_07_2015.htm [13.09.2020.].
12. Dzs.hr. 2016. TURIZAM U SRPNJU 2016./TOURISM, JULY 2016. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2016/04-04-01_07_2016.htm [13.09.2020.].
13. Dzs.hr. 2017. TURIZAM U SRPNJU 2017./TOURISM, JULY 2017. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2017/04-04-01_07_2017.htm [13.08.2020.].

14. Dzs.hr. 2018. TURIZAM U KOLOVOZU 2018./TOURISM, Kolovoz 2018. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/04-03-01_08_2018.htm [13.09.2020.].
15. Dzs.hr. 2018. TURIZAM U SRPNJU 2018./TOURISM, JULY 2018. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/04-04-01_07_2018.htm [13.08.2020].
16. Dzs.hr. 2018. TURIZAM U SRPNJU 2018./TOURISM, Srpanj 2018. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/04-03-01_07_2018.htm [13.09.2020.].
17. Dzs.hr. 2019. TURIZAM U KOLOVOZU 2019./TOURISM, Kolovoz 2019. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2019/04-03-01_08_2019.htm [13.09.2020.].
18. Dzs.hr. 2019. TURIZAM U SRPNJU 2019./TOURISM, JULY 2019. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2019/04-04-01_07_2019.htm [13.08.2020].
19. Dzs.hr. 2019. TURIZAM U SRPNJU 2019./TOURISM, Srpanj 2019. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2019/04-03-01_07_2019.htm [13.09.2020.].
20. Dzs.hr. 2020. TURIZAM U LIPNJU 2020./TOURISM, Lipanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_06_2020.htm [13.09.2020.].
21. Dzs.hr. 2020. TURIZAM U OŽUJKU 2020./TOURISM, Ožujak 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_03_2020.htm [13.09.2020.].
22. Dzs.hr. 2020. TURIZAM U SIJEČNJU 2020./TOURISM, Siječanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_01_2020.htm [13.09.2020.].
23. Dzs.hr. 2020. TURIZAM U SRPNJU 2020./TOURISM, JULY 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-04-01_07_2020.htm [13.09.2020.].
24. Dzs.hr. 2020. TURIZAM U SRPNJU 2020./TOURISM, Srpanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_07_2020.htm [13.09.2020.].
25. Dzs.hr. 2020. TURIZAM U SVIBNJU 2020./TOURISM, Svibanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_05_2020.htm [13.09.2020.].

26. Dzs.hr. 2020. TURIZAM U TRAVNJU 2020./TOURISM, Travanj 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-01_04_2020.htm [13.09.2020.].
27. Dzs.hr. 2020. TURIZAM U VELJAČI 2020./TOURISM, Veljača 2020. [Internet] raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2020/04-03-02_01_2020.htm [13.09.2020.].
28. Enciklopedija.hr. 2020. Ekstrapolacija | Hrvatska Enciklopedija. [Internet] raspoloživo na: https://www.enciklopedija.hr/natuknica.aspx?ID=17472 [15.07.2020.].
29. gradonacelnik.hr. 2020. *Vile s bazenima lansirale Imotski među nove turističke hit destinacije, a mogle bi spasiti i sezonu nakon korone*. [Internet] raspoloživo na: https://gradonacelnik.hr/vijesti/imotski-lani-su-imali-16-posto-vise-turistickih-dolazaka-i-30-posto-vise-nocenja/
30. Hnb.hr. 2020. Savjet HNB-A: Realni BDP U 2020. Mogao Bi Pasti Za 9,7%, A U 2021. Očekuje Se Rast Ekonomske Aktivnosti Za 6,2%. [Internet] raspoloživo na: https://www.hnb.hr/-/savjet-hnb-a-realni-bdp-u-2020-mogao-bi-pasti-za-9-7-a-u-2021-ocekuje-se-rast-ekonomske-aktivnosti-za-6-2- [13.07.2020.].
31. Htz.hr. 2020. [Internet] raspoloživo na: https://www.htz.hr/sites/default/files/2020-09/Informacija%20o%20statistickim%20pokazateljima%20-%20kolovoz%202020.pdf [13.09.2020.].
32. LICKORISH, L., 2007. INTRODUCTION TO TOURISM. Abingdon: ROUTLEDGE, str. 52-63.
33. Mint.gov.hr. 2020. *Prijedlog strategije razvoja turizma Republike Hrvatske do 2020. godine* [Internet] raspoloživo na: https://mint.gov.hr/UserDocsImages/dokumenti/Strategija-turizam-2020-veljaca2013.pdf [14.09.2020.].
34. Mint.gov.hr. 2020. *Analiza turističkog prometa i pregled provedenih aktivnosti tijekom srpnja i kolovoza 2020. godine*. [Internet] raspoloživo na: https://mint.gov.hr/UserDocsImages//AAA_2020_MINTIS/dokumenti//200911_sezona_press.pdf [14.09.2020.].
35. mint.hr. 2020. Hrvatski Turizam Premašio Očekivanja: Do Kraja Kolovoza Ostvareno 53 Posto Lanjskog Rezultata. [Internet] raspoloživo na: https://mint.gov.hr/vijesti/hrvatski-turizam-premasio-ocekivanja-do-kraja-kolovoza-ostvareno-53-posto-lanjskog-rezultata/21821 [13.09.2020.].

36. Petrić L. 2019. Uvod u turizam, Split: Ekonomski fakultet Split, str. 40.
37. Rogić-Hadžalić D., Primorac Čačić M., Omerzo E., 2019. Hrvatska u brojkama 2019. Zagreb: Hrvatski zavod za statistiku Republike Hrvatske, str. 5.
38. Samuelson, P. and Nordhaus, W., 2010. Economics. Boston: McGraw-Hill, str.45.
39. Unwto.org. 2020. Glossary Of Tourism Terms | UNWTO. [Internet] raspoloživo na: https://www.unwto.org/glossary-tourism-terms [12.08.2020.].
40. vlada.gov.hr. 2020. Cappelli: 2020. *Za Turizam I Gospodarstvo Posebna Zbog Niza Međunarodnih Događanja*. [Internet] raspoloživo na: https://vlada.gov.hr/vijesti/cappelli-2020-za-turizam-i-gospodarstvo-posebna-zbog-niza-medjunarodnih-dogadjanja/28411 [14.09.2020.].
41. Vortelinos D., Vasiliadis L., Gkillas K. 2019. Forecasting tourism demand in Europe. ResearchGate. str. 5.
42. Weber, S. Mikaĉić, V., Osnove turizma, Školska knjiga, Zagreb 1999. str. 17.
43. WTO 2008. Handbook On Tourism Forecasting Methodologies. Madrid: World Tourism Organization, str.vii
44. Wttc.org. 2020. CROATIA 2020 ANNUAL RESEARCH: KEY HIGHLIGHTS | World Travel & Tourism Council (WTTC). [Internet] raspoloživo na: https://wttc.org/Research/Economic-Impact [14.09.2020.].
45. Wttc.org. 2020. Economic Impact | World Travel & Tourism Council (WTTC). [Internet] raspoloživo na: https://wttc.org/Research/Economic-Impact [14.09.2020.].
46. Zaspan L., Đukec D. 2016. Procjena i prognoza potražnje metodom regresijske analize: studija slučaja zaštitarska tvrtka Alzas alarms d.o.o. Čakovec: Međimursko veleučilište u Čakovcu, str. 2-3.

POPIS ILUSTRACIJA

Graf 1: Odnos ponude i potražnje na tržištu 2
Graf 2: Kretanje krivulje potražnje zbog promjena u dohotku potrošača 5
Graf 3: Stvarni broj dolazaka turista po mjesecima u 2020. godini naspram prognoziranog broja dolazaka 22
Graf 4: Predviđanje broja noćenja koristeći se jednostavnom linearnom regresijskom ekstrapolacijskom metodom 25
Graf 5: Raspon neizvjesnosti 32

Slika 1: Vrste turizma 4
Slika 2: Prosječni godišnji tečaj eura prema američkom dolaru 1999-2019. 7
Slika 3: Prirodno kretanje stanovništva od 1984. do 2018. 8
Slika 4: Diverzifikacija turističkih proizvoda u Hrvatskoj 10
Slika 5: Proces donošenja odluke u vezi izbora metode predviđanja 13

Tablica 1: Broj noćenja u srpnju u gradu Zadru i predviđanje broja noćenja za srpanj 2019. 18
Tablica 2: Broj dolazaka turista po mjesecima u 2020. godini i prognoza broja dolazaka 20
Tablica 3: Broj noćenja u Splitsko-dalmatinskoj županiji u mjesecu srpnju od 2010. do 2020. godine 24
Tablica 4: Broj dolazaka stranih turista tijekom srpnja i kolovoza od 2018. do 2020. godine 27

SAŽETAK

Turistička potražnja definira se kao ukupna spremnost svih pojedinaca da plate jedinice dobara i usluga u turizmu po određenim cijenama te predstavlja jedno od značajnijih područja znanstvenih istraživanja u turizmu. Zbog svoje važnosti igra ključnu ulogu u kreiranju politike turizma, a time i na rezultate cjelokupnog gospodarstva država. Predviđanje turističke potražnje dobiva se podacima dobivenim kvantitativnim ili kvalitativnim metodama istraživanja ili kombinacijom obje. Odabir metode ovisi o različitim faktorima među kojima se ističu raspoloživi budžet, dostupnost podataka, raspoloživo vrijeme te ljudsko znanje. S obzirom na te faktore, nadalje se analiziraju različiti aspekti pojedinih metoda kao što su točnost, težina uporabe i interpretacije, fleksibilnost, brzina te kredibilitet kako bi se konačno izabrala metoda predviđanja turističke potražnje. U ovom radu definirane su i objašnjene osnovne kvantitativne i kvalitativne metode te su na primjerima podataka Državnog zavoda za statistiku testirane neke odrednice kao što su točnost, prednosti i nedostatci.

Ključne riječi: *turizam, predviđanje turističke potražnje, planiranje, kvantitativne metode, kvalitativne metode, učinak turističke potražnje na gospodarstvo*

SUMMARY

Tourism demand can be defined as total consumer's willingness to pay for goods or services at each price. It is one of significant fields of science research in tourism. Tourism demand plays a key role in the creation of tourism policy and thus on the results of the entire economy of the country. The choice of method depends on various factors, among which the available budget, data availability, available time and human knowledge stand out. With regard to these factors, various aspects of individual methods such as accuracy, difficulty of use and interpretation, flexibility, speed and credibility are further analyzed in order to finally choose the method of forecasting tourist demand. In this paper, the basic quantitative and qualitative methods are defined and explained, and some determinants such as accuracy, advantages and disadvantages are tested on the examples of data from the Central Bureau of Statistics.

Key words: *tourism, tourist demand forecasting, planning, quantitative methods, qualitative methods, effect of tourist demand on the economy*