UTJECAJ UDALJENOSTI OD DIOKLECIJANOVE PALAČE NA CIJENE NOĆENJA: PRIMJENA HEDONIČKE METODE

Radman, Lucija

Master's thesis / Diplomski rad

2017

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:124:965826

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET SPLIT

DIPLOMSKI RAD

UTJECAJ UDALJENOSTI OD DIOKLECIJANOVE PALAČE NA CIJENE NOĆENJA: PRIMJENA HEDONIČKE METODE

MENTOR:

Doc. dr. sc. Slađana Pavlinović

STUDENT:

Lucija Radman

Split, svibanj, 2017.

SADRŽAJ:

1. UVOD 4

1.1. Problem, predmet i ciljevi istraživanja 4

1.2. Istraživačke hipoteze 7

1.3. Metodologija 7

1.4. Doprinos istraživanja 8

1.5. Struktura diplomskog rada 9

2. HEDONIČKA METODA 10

2.1. Primjena hedoničke metode – pregled literature 10

2.2. Teoretske varijable koje bi mogle utjecati na cijene noćenja 12

3. OBILJEŽJA SMJEŠTAJNIH KAPACITETA U SPLITU 15

3.1. Obilježja smještajnih kapaciteta u Hrvatskoj 15

3.2. Obilježja smještajnih kapaciteta u Splitu 16

4. UDALJENOST OD DIOKLECIJANOVE PALAČE I CIJENA NOĆENJA 19

4.1. Empirijski model 19

4.2. Prikupljanje podataka 20

4.3. Odabir varijabli 22

4.4. Očekivani utjecaj varijabli 23

4.5. Testiranje hipoteza 24

4.5.1. Deskriptivna statistika 24

4.5.2. Regresijska analiza 30

5. REZULTATI 39

6. ZAKLJUČAK 43

LITERATURA 45

POPIS GRAFOVA, SLIKA I TABLICA 47

PRILOZI **49**

SAŽETAK **51**

SUMMARY **51**

1. UVOD

U uvodnom dijelu rada definirat će se problem, predmet, te cilj ovog rada. Također je predstavljen ogledni plan rada i metode kojima će se provesti empirijsko testiranje, te potencijalni doprinos ovog istraživanja.

1.1. Problem, predmet i ciljevi istraživanja

U ovom radu istražit će se način na koji se formiraju cijene noćenja u turističkim smještajnim jedinicama uz pomoć hedoničke metode. Hedoničkom metodom vrednovanja okoliša procjenjuje se ekonomska vrijednost usluga okoliša čije postojanje izravno utječe na tržišne cijene. Kao što joj i samo ime kaže hedonička metoda procjenjuje zadovoljstvo ili korisnost s povećanjem kakvoće okoliša, a moguće ju je primijeniti i na primjere vrednovanja izgrađenog okoliša poput Dioklecijanove palače. Spomenuta metoda i načini njene primjene, detaljnije su opisani u drugoj cjelini rada. Osnovna pretpostavka ovog rada jest kako lokacija ima utjecaja na cijene turističkog smještaja. Istraživanje će se provesti na području grada Splita

Grad Split kao kulturno i povijesno središte Dalmacije, zasigurno je među najpopularnijim destinacijama u Hrvatskoj. Osim prirodnih ljepota, nudi i raznorazne zabavne i kulturne sadržaje. Centar Splita zasigurno je Dioklecijanova palača, gotovo 2000 godina stara palača koja se nalazi pod zaštitom UNESCO-a, jedna je od najbolje sačuvanih antičkih građevina na svijetu. Palača predstavlja jednu od najvećih turističkih atrakcija u cijeloj Dalmaciji, te ju godišnje obiđe preko 1000 000 posjetitelja.

Jednostavnom pretragom internetskih stranica koje nude opciju rezervacije smještaja u Splitu, lako je uočiti da je u opisu gotovo svakog smještajnog objekta naznačeno koliko je udaljen od Dioklecijanove palače. Prema podacima Turističke zajednice grada Splita (2015), tijekom godine kroz njega prođe preko 1 000 000 posjetitelja, a samo prošle 2015. godine broj noćenja se povećao za nešto više od 200 000 u odnosu na prethodnu 2014.Paralelno sa brojem posjetitelja rastu i smještajni kapaciteti. Ponuda tih istih smještajnih jedinica je iznimno heterogena, te posjetitelji imaju široku paletu izbora, od ekskluzivnih hotela sa 5 zvjezdica do iznajmljivanja sobe u autohtonim splitskim domaćinstvima. Baš poput ponude postoje i razlike u cijenama. Uobičajeno je da ukoliko netko želi rezervirati smještaj u centru bilo kojeg svjetskog grada, mora platiti više nego netko tko odsjeda nešto dalje od centra. Ništa drugačije nije ni u Splitu.

Primjena hedoničke metode za analiziranje turističkog sektora nije strana, što je vidljivo iz radova brojnih autora: Andersson (2013), Fleischer (2012) ili Thrane (2006), koji u svojim istraživanjima ispituju kretanje cijena noćenja u hotelima. Prvi put u literaturi ovu metodu koristi Rosen (1974) koji skicira model diferencijacije proizvoda bazirane na hedoničkoj hipotezi da je vrijednost dobara određena njihovom korisnošću.

Fleischer (2012) ispituje hipotezu da je vrijednost Mediteranskog mora jednaka u svim regijama. Fleischer je provela istraživanje na području deset regija uključujući i Francusku i Talijansku rivijeru te brojna druga mediteranska područja. Osim pogleda na more neka od relevantnih obilježja sobe bila su i veličina sobe, koliko osoba je smješteno u sobi itd. Pomoću regresijske analize dobiveni su rezultati kojima se dolazi do zaključka kako nema signifikantne dodatne vrijednosti za pogled na more na npr. Cipru ili u nekoj drugoj regiji, te se ne odbacuje hipoteza da pogled na Mediteransko more ima jednaku vrijednost u svim regijama. Rezultati dobiveni u ovom članku mogu pomoći u izračunu krajobrazne vrijednosti Mediteranskog mora, budući da su sobe sa pogledom na more bile znatno skuplje od onih koje nemaju pogled na more.

Hedoničko određivanje cijena pristup je koji se često koristi u istraživanju cijena hotelskog smještaja, pa tako Andersson (2013) analizira stockholmsko tržište hotela pomoću ovog pristupa. Andersson (2013:25) dolazi do zaključka kako u Stockholmu kupac dobiva ono što je platio, te premda na cijenu noćenja utječu mnogobrojni faktori, upravo lokacija je faktor koji najviše izaziva rast cijene noćenja. Espinet et al (2003) zajedno s nekolicinom znalaca istražuje tržište hotela u Španjolskoj kako bi došli do zaključaka što utječe na formiranje cijene noćenja u španjolskim hotelima koji se nalaze u blizini plaže i sunca. Istraživanje je dovelo do zaključka kako postoje velike razlike u cijenama između hotela s četiri zvjezdice i ostalih hotela, te gotovo nikakva razlika između hotela s jednom ili dvije zvjezdice. Od karakteristika koje imaju velikog utjecaja na cijenu čak dvije su lokacijskog tipa: udaljenost od plaže i grad u kojem se hotel nalazi, a druge karakteristike su još veličina hotela i dostupnost parkirnog mjesta (Espinet et al 2003:175).

Osim dokaza koji idu u prilog pretpostavci kako centar znači i višu cijenu, postoje situacije u kojima ovo nije slučaj. Istražujući cijene hotelskih soba u glavnom gradu Tajvana, Chen i Rothschild (2010:691) dolaze do zaključka da blizina centra Taipei-a ima negativan utjecaj na cijenu, no objašnjenje se krije u tome da je većina resorta smještena izvan centra.

Što se tiče primjene hedoničke metode u Hrvatskoj, uglavnom je riječ o ispitivanju cijena nekretnina, za područje čitave Hrvatske (Kunovacetal. 2008) ili samo grada Zagreba (Boras i Tica 2013).

Vidljivo je iz prethodno navedenih primjera kako je u gotovo svim istraživanjima uz poneke druge varijable, lokacija bila bitan faktor. Ovakvi rezultati nisu iznenađujući, te se objašnjenje može pronaći u različitim faktorima. Prvo, blizina centra znači i više vremena za obilaženje destinacije i razgledavanje znamenitosti. U današnje doba, u kojem vrijeme ima iznimno bitnu ulogu, pola sata ili sat više, mnogo znači. Drugi razlog, osim uštede vremena može se tražiti i u uštedi novca koji bi se potencijalno potrošio na gradski prijevoz. Ukoliko se izdvoji malo više novca za smještaj u blizini centra, trošak za prijevoz do tog istog centra biti će smanjen.

Slijedeći prethodno navedene primjere formirat će se istraživanje zasnovano na cijenama smještaja (hoteli, apartmani itd.) ovisno o najprikladnijim podacima koji budu dostupni. Predmet istraživanja biti će smještajni kapaciteti oko Dioklecijanove palače, te posebno njihova lokacija i cijena smještaja. Osim ove karakteristike, u model će biti uključene i druge varijable koje bi potencijalno mogle utjecati na cijene noćenja. Testirat će se utjecaj pojedinačnih varijabli na cijenu, te u kolikoj mjeri i koje varijable najviše utječu. Budući da do sada nije provedeno istraživanje ovog tipa na području grada Splita, biti će zanimljivo doznati koliko bitnu ulogu lokacija ima za posjetitelje prilikom odabira smještaja. Kao i kod ostalih radova, već postoje neka očekivanja što se tiče toga koje varijable bi potencijalno mogle imati najveći utjecaj, što je i opisano u nastavku. Isto je tako moguće da nakon statističke obrade neke neplanirane karakteristike ispadnu iznimno bitne. Rad je baziran na pretpostavci kako je lokacija bitan faktor. Konačno, važno je napomenuti da je ovaj rad prvenstveno usmjeren na procjenu krajobrazne vrijednosti okoliša gdje se na temelju stvarnog ponašanja tržišnih sudionika nastoje donijeti zaključci o vrijednosti određenog okoliša što je u ovom slučaju Dioklecijanova palača.

Ciljevi istraživanja

Cilj ovog istraživanja je empirijski ispitati u kolikoj mjeri udaljenost smještajne jedinice od Dioklecijanove palače utječe na njegovu cijenu. Važno je napomenuti da premda je područje rada usko isprepleteno sa turizmom konačni ciljevi su malo drugačiji. Bit rada nije doznati koje karakteristike bi smještajni kapaciteti trebali imati kako bi mogli postaviti veću cijenu, već kako lokacija definira cijenu. Rezultati bi trebali poslužiti za vrednovanje izgrađenog

okoliša. Empirijski ciljevi odnose se na ispitivanje zadanih istraživačkih hipoteza, te njihovo prihvaćanje ili odbacivanje koristeći statističke i ekonometrijske metode.

1.2. Istraživačke hipoteze

Uvidom u problem i predmet istraživanja definirane su sljedeće hipoteze:
H1: Postoji statistički značajna veza između udaljenosti od Dioklecijanove palače i cijene noćenja.
H2: Smještajni kapaciteti manje udaljenosti od Dioklecijanove palače imaju višu cijenu noćenja.

1.3. Metodologija

Koristeći se deskriptivnom statistikom i višestrukom regresijskom analizom, detaljno će se istražiti u kolikoj mjeri i koje odabrane varijable utječu na formiranje cijene noćenja.

Potrebni podaci su manualno prikupljeni s odabrane mrežne stranice za rezervaciju smještaja (Booking.com). Smještajne jedinice predstavljaju opservaciju, tj. jedinicu promatranja, čija će se obilježja trebati prikupiti. Na svim mrežnim stranicama koje nude rezervaciju smještaja, uz svaku smještajnu jedinicu navedene su i njene karakteristike (cijena, veličina, lokacija, raspoloživost na određeni dan, itd.). Ponuđena cijena koja je navedena predstavlja transakcijsku cijenu, s obzirom da ne postoji mogućnost pregovora između ponuđača i prodavača. Razmotreno je više mrežnih stranica, te su podaci preuzeti sa one koja se pokazala najprikladnijom obzirom na metodološke zahtjeve istraživanja, te mogućnost pristupa podacima. Premda postoji više mrežnih stranica putem kojih je moguće rezervirati smještaj, kako bi se izbjegle pogreške i odstupanja zbog mogućih različitih promotivnih ponuda koje ovise od stranice do stranice, te kako bi se osigurao homogeni uzorak koji dopušta izvođenje relevantnih usporedbi koristio se samo jedan izvor za prikupljanje podataka. Samo prikupljanje podataka je manualno, te se nastojalo izvesti u što kraćem vremenskom periodu kako bi informacije o ponuđenim smještajnim jedinicama bile usporedive.

Uz svaku jedinicu promatranja na mrežnim stranicama naznačena je i njena adresa. Kako bi se što preciznije procijenila udaljenost od Dioklecijanove palače, razmotrit će se korištenje tehnologije besplatnih digitalnih mrežnih karata, GoogleMaps. U sklopu GoogleMapsa, moguće je procijeniti koliko je približno minuta hoda potrebno do neke lokacije. Upravo to će

se napraviti i za ovo istraživanje, unijeti će se adresa smještajne jedinice i Dioklecijanove palače, za svaku smještajnu jedinicu zasebno,te će se dobiti varijabla udaljenost od Dioklecijanove palače. Isti postupak primijeniti će se i za varijablu udaljenost od plaže, osim što će se u tom slučaju staviti adresa smještajne jedinice i adresa najbliže plaže. Iako se ispituje utjecaj lokacije na cijenu noćenja, potrebno je promatrati i ostale varijable (odnosno atribute opservacije) koje u većoj ili manjoj mjeri utječu na zavisnu varijablu (cijenu noćenja).Za zavisnu varijablu biti će korištena cijena noćenja u HRK, dok će se kao eksplanatorne varijable razmotriti one koje su se u dosadašnjim istraživanjima pokazale najznačajnijima: veličina smještaja, dostupno parkirno mjesto, lokacija (udaljenost od Dioklecijanove palače i plaže), besplatni Wifi, kabelska televizija, maksimalan broj osoba, pogled na more, klima uređaj, parkirno mjesto, sušilo za kosu, prosječna recenzija smještaja i uključeni doručak. Za ovaj rad najvažnije varijable svakako su one lokacijske, a to su udaljenost od Dioklecijanove palače i udaljenost od najbliže plaže. Razlog zbog kojeg se udaljenost od plaže neće uzimati kao glavna lokacijska varijabla, već je ta uloga prepuštena udaljenosti od Dioklecijanove palače, je taj što u Splitu postoji više plaža različitog sadržaja pa bi se time izgubilo na homogenosti uzorka. No, istražujući i oslanjajući se na postojeću literaturu postoji opravdana sumnja kako bi blizina bilo koje plaže mogla imati utjecaja na cijenu noćenja, pa je i uključena u model.

Udaljenost od Dioklecijanove palače se smatra da će imati pozitivan utjecaj na cijene. Udaljenost od plaže bi ovisno o periodu za koji se budu prikupljali podaci mogla imati pozitivan utjecaj, posebice ako promatrano razdoblje budu ljetni mjeseci. Vodeći se Fleischerovim (2012) rezultatima, u model su uključene varijable pogleda na more i broja osoba koje bi trebale utjecati na rast cijene. Varijable klima uređaj, kabelska TV i Wifi su poprilično učestale, pa s obzirom da gotovo sve smještajne jedinice posjeduju ova obilježja ne bi trebale previše utjecati na cijenu. Grad Split ima problem nedovoljnih parkirnih mjesta, posebice tijekom ljetnih mjeseci pa je opcija parkirnog mjesta jedna od varijabli za koju se očekuje da će imati pozitivan utjecaj, kao što je bio slučaj kod Thrane (2007) i Espinet et al (2003).

1.4. Doprinos istraživanja

Do sada nije provedeno ovakvo istraživanje za grad Split, te će zasigurno biti zanimljivo doći do nekih novih zaključaka i podataka. Dobiveni rezultati dat će do znanja koliko lokacija i blizina centra utječu na cijenu smještaja u Splitu. Osim doprinosa po pitanju primjene

hedoničke metode, dobiveni rezultati mogli bi biti od koristi vlasnicima ugostiteljskih objekata. Također, ukoliko se postavljene pretpostavke ispostave točnima, rezultati se mogu koristiti za pokušaj procijenjene vrijednosti Dioklecijanove palače kao izgrađenog okoliša.

1.5. Struktura diplomskog rada

Uvod: U uvodnom dijelu rada, definirati će se problem i predmet istraživanja, te postaviti istraživački ciljevi, oslanjajući se na postojeću relevantnu literaturu.

Teorijski dio rada: Teorijski dio rada ima za svrhu prezentirati relevantnu literaturu koja predstavlja temelje za ovaj rad. Također, u ovome dijelu detaljno će biti objašnjeno što je zapravo hedonička metoda, te na koji način se sve može primjenjivati. S obzirom da je tema ovog rada utjecaj udaljenosti od Dioklecijanove palače na cijene noćenja, biti će istraženo tržište smještajnih jedinica u Splitu, što bi trebalo pridonijeti boljem razumijevanju i interpretiranju rezultata koji slijede u empirijskom dijelu.

Empirijski dio rada: U sklopu empirijskog dijela rada, prvo će se prikupiti potrebni podaci. Potom slijedi testiranje postavljenih hipoteza, vodeći se prethodno definiranom metodologijom.

Rezultati: Ovaj dio rada namijenjen je interpretaciji i analizi dobivenih rezultata empirijskog istraživanja. Donose se zaključci i analizira u kolikoj mjeri empirijski rezultati prate prethodno postavljena teorijska očekivanja.

2. HEDONIČKA METODA

Prije formiranja modela za empirijski dio rada, potrebno se upoznati sa definicijom hedoničke metode, te njenim mogućim primjenama. Ova cjelina sastoji se od dva dijela. Prvi dio usredotočen je na upoznavanje sa hedoničkom metodom, nakon čega slijedi pregled istraživanja koja se služe navedenom metodom. Drugi dio koncipiran je sa svrhom pružanja teoretske osnove za odabir varijabli. Kao cjelina, ovaj dio rada trebao bi poslužiti za bolje razumijevanje istoga, ali i za što bolje shvaćanje hedoničke metode općenito.

2.1. Primjena hedoničke metode – pregled literature

Kao što joj i samo ime kaže hedoničkom metodom se procjenjuje zadovoljstvo ili korisnost s malim promjenama atributa određenog dobra. Hedonički modeli vrijednosti nekretnina koriste tržišnu cijenu nekretnine koju potom razlome na komponente (karakteristike nekretnine, karakteristike naselja u kojem se nalazi nekretnina, ekološki uvjeti naselja itd.). Pomoću njih moguće je izmjeriti graničnu spremnost na plaćanje za malene promjene atributa. Hedonički modeli, bilo da se radi o vrednovanju nekretnina ili nadnicama, imaju zajedničku osobinu a to je da koriste statističku metodu višestruke regresijske analize. Pomoću ove metode može se izmjeriti u kojoj mjeri pojedine karakteristike utječu na cijene, odnosno nadnice (Tietenberg i Lewis 2009). Koristeći se ovom metodom moguće je ispitati koliko i na koji način, misleći pritom na pozitivan ili negativan utjecaj, utječe pojedina karakteristika nekretnine. Ovaj pristup koristan je za pomoć u formiranju cijena, pomoću njega mogu se iščitati potrošačke preferencije, te rezultati i zaključci doneseni na ovaj način imaju zaista široko područje primjene.

Prvi put u literaturi ovu metodu koristi Sherwin Rosen 1974. godine. Rosen (1974) skicira model diferencijacije proizvoda bazirane na hedoničkoj hipotezi da je vrijednost dobara određena njihovom korisnošću. Hedonički modeli mogu se koristiti za ispitivanje cijena gotovo bilo kojeg dobra. S obzirom da ne postoji zadani oblik hedoničkih modela, osnovne pretpostavke ovog rada formirane su pozivajući se na druge stručne radove koji su se koristili ovom metodom. Najveću pomoć ponudili su radovi formirani na sličan način, odnosno koji ispituju utjecaj lokacije na cijenu.

U Hrvatskoj do sada nije provedeno puno istraživanja slične tematike, a u trenutku pisanja ovog rada teorijsko uporište o hedoničkoj metodi na području RH pronalazi se tek u

nekolicini radova. Boras i Tica (2013), Kunovac et al (2008), Botrić i Kordej de Villa (2005). Boras i Tica (2013) istražuju koliko prostorna udaljenost utječe na cijene nekretnina u Zagrebu. Model formiraju s tri kvantitativne i dvadeset tri lokacijske dummy varijable, te potvrđuju svoje pretpostavke kako veća udaljenost od centra znači i nižu cijenu. Kunovac et al (2008) koriste se ovom metodom kako bi izračunali indeks cijena nekretnina u Hrvatskoj. Dok Botrić i Kordej de Villa (2005) nastoje ispitati regionalne razlike koje se javljaju na tržištu nekretnina u Hrvatskoj.

Premda navedeni radovi nude dobre smjernice, ipak nisu dovoljni, ali na sreću strana literatura nudi pomoć. Espinet et al (2003) i Fleischer (2012) osim što svoja istraživanja fokusiraju na turistički smještaj, bave se i sličnim geografskim područjima (Mediteranom), što je posebice od pomoći kod formiranja nezavisnih varijabli, no o tome više u nastavku. Jedan od problema hedoničke metode, kao što Thrane (2005) zaključuje, je činjenica da teorija nudi malo smjernica za odabir nezavisnih varijabli koje se koriste u ovakvim istraživanjima. Thrane (2005) ispituje koji atributi najviše utječu na cijene organiziranih putovanja u Norveškoj. Prilikom formiranja modela Thrane veliku pozornost posvećuje homogenosti uzorka, na način da su u istraživanje uključena samo putovanja Oslo - Kanarsko otočje. Nadalje, sve opservacije odnose se na isto vremensko razdoblje (u ovom slučaju to je prvi tjedan u studenom 2003) kako bi se izbjegle sezonske oscilacije u cijenama. Prilikom izbora varijabli za zavisnu je uzeta ukupna cijena jednotjednog putovanja za jednu osobu prema već prethodno navedenim kriterijima.

Autori koji su se poprilično pozabavili pitanjem nezavisnih varijabli, drugim riječima atributima koji bi mogli značajno utjecati na cijene su Espinet et al (2003). U svom radu iz 2003. godine, definirali su ukupno 55 atributa, te se daljnjom selekcijom odlučili za 12 koje koriste u modelu. Neki od razmatranih atributa bili su: pogled na more, balkon, televizija u sobi, sušilo za kosu, parkirno mjesto, broj soba, broj zvjezdica, blizina plaže, blizina centra grada. Kod definiranja ovakvih istraživanja ne postoje strogo zadane smjernice budući da nisu sva istraživanja smještena u isto geografsko područje, niti su pretpostavke i okviri istraživanja uvijek isti. Drugi problem koji se može pojaviti je dostupnost i kvaliteta podataka, kao kod Papatheodorou (2002). Pokušavajući prikupiti podatke o putovanjima diljem Mediterana, koje organiziraju britanske putničke agencije, nailazi na zatvorena vrata. Većina agencija odbija mu ustupiti podatke, pa su podaci korišteni u istraživanju prikupljeni iz brošura različitih putničkih agencija. Međutim, Haroutunian et al (2005) ispituju koliko je učinkovito prikupljati podatke iz različitih brošura, smatrajući kako cijene i karakteristike organiziranih

putovanja variraju ovisno o agenciji koja ih nudi. Također dolaze do zaključka kako na cijene putovanja diljem Mediterana više utječe lokacija odnosno zemlja za koju se nudi putovanje, nego konkretne karakteristike smještajnih kapaciteta (veličina sobe, privatna kupaonica itd.). U nastavku pregleda literature posebna pozornost posvećena je varijablama koje su se u prethodnim radovima pokazale bitnima.

2.2. Teoretske varijable koje bi mogle utjecati na cijene noćenja

Prije no što se započne regresijska analiza prvo je potrebno odabrati varijable. Kako je tema rada ispitivanje udaljenosti od Dioklecijanove palače na cijene noćenja, prve dvije varijable su upravo cijena noćenja i udaljenost od Dioklecijanove palače. Kod hedoničke regresije osim numeričkih varijabli kao što su npr. veličina nekretnine/hotela, udaljenost ili blizina određenoj lokaciji i slično, vrlo su učestale i dummy varijable. Te varijable ukazuju na postojanje ili nepostojanje određenog obilježja, gdje varijabla poprima vrijednost 1 ili 0, ovisno o postojanju ili ne postojanju obilježja (Gujarati 2004:298). One omogućavaju da se u model uvrste inače opisne varijable koje su se pokazale značajne u dosadašnjim istraživanjima, kao što su npr. dostupnost parkirnog mjesta (Espinet et al 2003) ili pogled na more (Fleischer 2012). Zavisna varijabla cijena noćenja ne zahtijeva mnogo objašnjavanja, no koje varijable uvrstiti kao regresorske iziskuje malo istraživanja.

Udaljenost od Dioklecijanove palače odabrana je zbog lakšeg prikupljanja podataka. Dioklecijanova palača odabrana je budući da se nalazi u samom centru, te je zbog korištenja tehnologije GoogleMaps za računanje udaljenosti bilo bitno definirati točnu lokaciju. Tehnologija Googlemaps izvrsno je poslužila za mjerenje približne udaljenosti u minutama hoda, te su ovaj pristup koristili i Boras i Tica (2013).

Prilikom odabira nezavisnih varijabli veliku pomoć nude Andersson (2013), Chen i Rothschild (2010), Espinet et al (2003) i Thrane (2007). Istražujući tržište hotela u Španjolskoj Espinet et al (2003) dolaze do zaključka da na cijenu veliki utjecaj imaju čak dvije lokacijske varijable: udaljenost od plaže i grad u kojem se hotel nalazi. Ostale karakteristike su još veličina hotela i dostupnost parkirnog mjesta. Kod Anderssona (2013:25) najvažnija varijabla je lokacija, te zaključuje kako su sobe u centru Stockholma gotovo 30% skuplje od soba koje su udaljene od centra. Ostale varijable koje u njegovom radu pozitivno utječu na cijenu su: privatna kupaonica, uključen doručak, lanac hotela, starost zgrade (hoteli koji su smješteni u zgradama izgrađenim prije Drugog svjetskog rata su skuplji), povrat

novca, veličina sobe i broj zvjezdica. Chen i Rothschild (2010) istražuju hotele u Tajvanu, te u svom radu imaju dva modela, jedan za radne dane i drugi za vikende. Kao najznačajnije karakteristike koje utječu na cijenu tijekom radnog tjedna su: lanac hotela, veličina sobe, lokacija u centru, Tv, bar, Internet, dostupnost shuttle prijevoza, konferencijska sala i teretana. Za drugi model koji ispituje cijene vikendom samo pet varijabli ispostavilo se značajno: lokacija, TV, internet, konferencijska sala i teretana. Ono što je bitno napomenuti za ovo istraživanje jest da centra Tajvana zapravo negativno utječe na cijenu, budući je većina resorta smještena izvan grada. Osim navedenih varijabli koje su se pokazale signifikantnima u prethodno spomenutim radovima, razmotren je i veliki broj drugih varijabli, koje nisu bile značajne. Obzirom da su navedena istraživanja najsličnija ovome, kao i činjenica da su autori značajnu pažnju posvetili definiranju nezavisnih varijabli, njihovi radovi poslužili su kao izvrsna teorijska smjernica za odabir nezavisnih varijabli. Uspoređujući njihove rezultate ali i teorijske pretpostavke, prezentirano je 8 varijabli koje su se pokazale najznačajnijima, te su korištene kao smjernica u definiranju nezavisnih varijabli za ovaj rad. U tablicu nisu uključene lokacijske varijable, budući da je fokus u ovom trenutku bio na ostale karakteristike smještajnih kapaciteta.

Tablica 1: Varijable koje bi mogle imati utjecaja na cijenu noćenja

Varijabla	Opis varijable
Mini bar	Dostupnost mini bara (1)
Doručak	Doručak uključen u cijenu (1)
Sušilo za kosu	Dostupno sušilo za kosu (1)
Veličina sobe	Mjereno u m^2
TV	Dostupan TV (1)
Wifi	Dostupan wifi (1)
Parking	Dostupno parkirno mjesto (1)
Broj zvjezdica	Klasifikacija hotela (od 1 do 5 zvjezdica)

Izvor: Izrada autorice

Prethodno definirane varijable koristile su se samo kao smjernica budući da dostupnost podataka ali i specifičnosti promatranog područja ne dozvoljavaju slijepo praćenje. Uzimajući u obzir gore prezentirane varijable ali i dostupnost podataka biti će odabrane varijable za

model. Varijable korištene u modelu, njihov odabir i karakteristike pobliže su opisane u četvrtom poglavlju ovog rada.

Nakon upoznavanja s osnovnim pretpostavkama hedoničke metode, jasno je kako ista nalazi svoju primjenu u različitim kontekstima (turizam, tržište nekretnina, itd.). Što se tiče nezavisnih varijabli i njihova odabira, jedino pravilo je da ne postoji univerzalno pravilo. Kod formiranja ekonometrijskog modela potrebno je, kako brojni autori navode, uzeti u obzir različite faktore. U nastavku rada pobliže će se predstaviti neke od osnovnih karakteristika smještajnih kapaciteta u Splitu, nakon čega će se uzimajući u obzir zaključci doneseni u ovoj i sljedećoj cjelini, formirati ekonometrijski model.

3. OBILJEŽJA SMJEŠTAJNIH KAPACITETA U SPLITU

Kako je spomenuto u prethodnom dijelu rada, prije provedbe istraživanja potrebno je upoznati se s područjem rada. U cilju što boljeg razumijevanja cjelokupnog rada, u nastavku su prezentirane neke od osnovnih karakteristika smještajnih kapaciteta u Splitu, ali i u cijeloj Hrvatskoj.

3.1. Obilježja smještajnih kapaciteta u Hrvatskoj

Sve veća popularnost Hrvatske kao turističke destinacije tijekom godina, rezultirala je konstantnim rastom turizma, te iz godine u godinu povećanjem dostupnih smještajnih kapaciteta.

Prema Zakonu o ugostiteljskoj djelatnosti (NN, br.121/16) smještajni objekti razvrstani su na sljedeće kategorije: hoteli, kampovi i ostali ugostiteljski objekti za smještaj. Članak 16 prethodno spomenutog zakona kaže: "Pojedine vrste ugostiteljskih objekata iz skupina »Hoteli«, »Kampovi« i »Ostali ugostiteljski objekti za smještaj« kategoriziraju se u kategorije ovisno o uređenju, opremi, uređajima, uslugama, održavanju i ostalim propisanim elementima" Odnosno, daljnja kategorizacija smještajnih objekata definira se različitim pravilnicima. Prema podacima Državnog zavoda za statistiku (2016a) prikazanih u tablici niže može se vidjeti trend porasta ponude smještajnih kapacitet u razdoblju od 2010. – 2015. U 2015. je ukupno bilo raspoloživo preko milijun kreveta.

Tablica 2: Broj soba i postelja prema vrstama turističkog smještaja od 2010 – 2015 (u 000)

	Sobe			**Postelje**		
	Ukupno	U kolektivnom smještaju	U privatnom smještaju	Ukupno	U kolektivnom smještaju	U privatnom smještaju
2010	316	171	145	910	470	440
2011	321	170	151	934	469	465
2012	305	172	133	881	472	409
2013	322	185	133	962	527	435

2014	336	185	151	1002	515	487
2015	348	189	159	1062	528	534

Izvor: DZS RH 2016

Tablica je podijeljena na kolektivni smještaj i privatni smještaj. "Kolektivni smještajni objekti jesu oni objekti u kojima se pruža noćenje turistima u sobi ili nekoj drugoj jedinici, ali broj mjesta koje osiguravaju mora biti veći od određenog minimuma za skupine osoba koje premašuju jednu obitelj, odnosno više od 20postelja, a sva mjesta u objektu moraju biti pod istim zajedničkim komercijalnim tipom rukovođenja, čak i ako objekt ne stvara profit. Privatni smještajni objekti prema Zakonu o ugostiteljskoj djelatnosti (NN, br. 49/03.) jesu oni objekti u kojima se pruža ograničen broj mjesta koji ne prelazi utvrđeni nacionalni minimum (do ukupno 8 soba, tj. do najviše 16 postelja za sobe)" (DZS 2016a).

Broj ukupnih postelja je u razdoblju od pet godina porastao za nešto više od sto. Porast je zabilježen u kolektivnom i u privatnom smještaju. Porast ukupnog broja postelja u razdoblju od pet godina, veći je u privatnom nego li u kolektivnom smještaju. Broj raspoloživih soba također je porastao u promatranom razdoblju. Međutim, ovdje se bilježi manji ukupni rast, što je i logično, uzme li se u obzir kako u jednu sobu stane veći broj kreveta. Ukupni porast bio je veći kod kolektivnog smještaja. Također, treba uzeti u obzir kako je ovdje riječ o statističkim podacima u koje nisu uključeni neprijavljeni iznajmljivači, pa je moguće da je stvarni broj raspoloživih soba i kreveta veći.

3.2. Obilježja smještajnih kapaciteta u Splitu

Grad Split po veličini je drugi grad u Hrvatskoj i prema posljednjem popisu stanovništva iz 2011. godine, te broji 178.102 stanovnika. Središte je Splitsko-dalmatinske županije, te najveći grad u Dalmaciji. Split predstavlja jednu od najznačajnijih turističkih destinacija u Republici Hrvatskoj. Osim sunca i mora, posjetiteljima nudi šetnju tisućama godina starom gradskom jezgrom, te obilje dobre hrane i kulturnih manifestacija. Splitski turizam, svake godine bilježi porast noćenja i smještajnih kapaciteta, a dolaskom popularnog festivala Ultra Europe, taj rast se samo ubrzao. Podaci Turističke zajednice grada Splita (2016) pokazuju kako je u 2016. godini u Splitu je zabilježeno 1 763 174 noćenja. Usporedbe radi u 2015. godini zabilježeno je 1 337 535 noćenja (Turistička zajednica grada Splita 2015). Turizam

predstavlja jednu od važnijih okosnica splitskog proračuna pa ne čudi činjenica da se iz proračuna izdvaja više milijuna kuna godišnje za različite turističke svrhe. Prema prijedlogu proračuna (2016) samo za održavanje plaža u 2017. godini planirano je 4 080 000 HRK, dok je za poticanje razvoja turizma predviđeno dodatnih 4 620 000 HRK, s tendencijom rasta tog iznosa u sljedeće dvije godine. Prema analizi Turističke zajednice Splitsko–dalmatinske županije (2016), ista je ostvarila 19% udjela u ukupnim noćenjima u Hrvatskoj, a najpopularnija destinacija bila je Splitska rivijera u kojoj je ostvareno 38,71% od ukupnih noćenja u Splitsko–dalmatinskoj županiji. Grad Split je prema podacima Državnog zavoda za statistiku (2016b) u 2015. godini raspolagao s ukupno 21 413 postelja.

Tablica 3: Smještajni kapaciteti po vrstama objekata u Splitu 2015.

	Hoteli	**Kućanstva**	**Kampovi**	**Ostali objekti**	**Ukupno**
Sobe	1201	5522	380	1252	8355
Kreveti	2476	14718	1140	3079	21413

Izvor: DZS RH 2016

Prema metodologiji Državnog zavoda za statistiku (2016b), objašnjenja za kategorije smještaja su:

Hoteli – Hoteli i slično uključuju podatke za hotele, hotele baštine, aparthotele, integralne hotele, difuzne hotele, lječilišne hotele, turistička naselja, turističke apartmane, pansione i guesthouse

Kućanstva - uključuju podatke za sobe, apartmane, studio-apartmane, kuće za odmor u kućanstvima i seljačka kućanstva

Kampovi - uključuju podatke za kampove, kampirališta, kamp-odmorišta i kampove u kućanstvima.

Ostali objekti za kolektivni smještaj- uključuju podatke za sobe za iznajmljivanje, apartman, studio-apartman, kuće za odmor, prenoćišta, odmarališta, hostele, planinarske domove, lovačke domove, objekte za robinzonski turizam, gostionice s pružanjem usluge smještaja, lječilišta, brodske kabine, spavaće i kušet-vagone, učeničke domove ili studentske domove te nekategorizirane objekte.

Više od polovice ukupnih smještajnih kapaciteta otpada na kućanstva. Popularnost ovog oblika smještaja raste iz godine u godinu. Ovakav oblik smještaja osim što stanovništvu omogućava dodatan izvor zarade, sve popularniji postaje i zbog dostupnosti novih tehnologija koje su poprilično pojednostavnile oglašavanje privatnim iznajmljivačima. Ipak, sve veća popularnost smještaja u kućanstvu dolazi sa određenim posljedicama. Kao što Zahedi (2008) napominje, turizam sa sobom povlači razne ekološke i sociološke posljedice. Nerijetko je jedna od posljedica premještanje lokalnog stanovništva u korist turizma. Posljednjih godina sve više utjecaja na popularnost nekog smještajnog objekta imaju i društvene mreže te mnogobrojne mobilne aplikacije za ocjenjivanje turističke usluge, kao što su; TripAdvisor, Yelp itd. Istražujući ponudu smještaja na različitim mrežnim izvorima moguće je pronaći zaista sve, od luksuznih vila s bazenom i više spavaonica pa sve do vrlo povoljnog smještaja u zajedničkim spavaonicama hostela. Posljednjih godina na popularnosti su dobili upravo hosteli koji su prvenstveno usmjereni na mlađu populaciju koja nastoji proći što povoljnije.

Većina mrežnih izvora za rezervaciju smještaja također pruža mogućnost filtriranja ponude. Pa je tako moguće izabrati cjenovni razred za noćenje, broj osoba, vrstu smještaja itd., odnosno moguće je prilagoditi pretragu individualnim preferencijama. Ovakav pristup pruža potrošaču veliku kontrolu, te uvelike utječe na ponudu. U prilog ovome ide i činjenica kako je na navedenim stranicama moguće i ocijeniti smještaj, a na nekima čak i ocijeniti nekoliko atributa smještaja, npr. zasebno ocijeniti zadovoljstvo s lokacijom, zasebno ocijeniti ljubaznost osoblja itd. Rastuća prisutnost društvenih mreža pruža posjetiteljima platformu da iznesu svoje dojmove o usluzi za koju su platili, te je u interesu iznajmljivača kontinuirano voditi računa o zadovoljstvu posjetitelja. Iz priloženog je jasno kako je struktura smještajnih kapaciteta u Splitu poprilično šarolika, te će bit zanimljivo u nastavku istraživanja otkriti za koji atribut su potrošači spremni potrošiti malo više.

4. UDALJENOST OD DIOKLECIJANOVE PALAČE I CIJENA NOĆENJA

Nakon upoznavanja sa osnovnim karakteristikama smještajnih objekata u Hrvatskoj i Splitu, empirijski će se ispitati postoji li statistički značajna veza između udaljenosti od Dioklecijanove palače i cijene noćenja, te uvjetuje li blizina Palače višu cijenu noćenja. U nastavku je objašnjen proces prikupljanja podataka i odabira varijabli, nakon čega slijedi prikaz pokazatelja deskriptivne statistike. Pretpostavljene hipoteze ispitati će se višestrukom regresijskom analizom.

4.1. Empirijski model

Empirijski dio ovog rada je regresijska analiza kojom će se testirati postavljene hipoteze. Zadaća regresijske analize je da pronađe analitičko-matematički oblik veze između jedne ovisne ili regresand varijable i jedne ili više neovisnih ili regresorskih varijabli (Pivac 2010:253). Model koji će se upotrebljavati u ovom radu je model višestruke regresije koji se sastoji od jedne zavisne (regresand) varijable i *k* nezavisnih (regresorskih) varijabli.

Hipoteze su sljedeće (kao što je već i navedeno u prethodnom dijelu rada):
H1: Postoji statistički značajna veza između udaljenosti od Dioklecijanove palače i cijene noćenja.
H2: Smještajni kapaciteti manje udaljenosti od Dioklecijanove palače imaju višu cijenu noćenja.

Opći oblik modela višestruke regresije glasi:

$$y_i = \beta_0 + \beta_1 * x_{1,i} + \beta_2 * x_{2,i} + ... + \beta_k * x_{k,i} + e_i$$

y_i - su vrijednosti zavisne varijable, tzv. regresand varijable

x_i - su vrijednosti nezavisnih varijabli

e_i - vrijednost slučajne varijable, za koju se pretpostavlja da ima normalnu distribuciju s konstantnom varijancom i očekivanjem jednakim nuli.

β_0 - konstantni član, tj. očekivana vrijednost zavisne varijable u originalnim jedinicama mjere kada su sve nezavisne varijable jednake nuli

β_j - regresijski koeficijent, pokazuje prosječnu promjenu zavisne varijable u originalnim jedinicama mjere kada odgovarajuća nezavisna varijabla poraste za 1 jedinicu, uz uvjet da su sve ostale neovisne varijable neizmijenjene (Pivac, 2010).

Kako bi regresijski model imao konzistentne, nepristrane i efikasne procjene vrijednosti parametara potrebno je provjeriti da procijenjeni model nema problem multikolinearnosti nezavisnih varijabli, heteroskedastičnosti varijance reziduala i autokorelacije grešaka relacije.

Problem multikolinearnosti prisutan je ako su dvije ili više regresorskih varijabli približno linearno zavisne. Ukoliko postoji, dovodi do:

1. problema invertiranja matrice X^TX
2. velikih standardnih grešaka parcijalnih regresijskih koeficijenata,
3. nepouzdanih vrijednosti parcijalnih regresijskih koeficijenata, možda i netočnih predznaka
4. isključivanja teorijski relevantnih varijabli koje nisu statistički značajne. (Jurun, 2007)

Problem heteroskedastičnosti postoji kada nije ispunjena pretpostavka o konstantnosti varijance. Heteroskedastičnost dovodi do linearnih i nepristranih, ali ne i efikasnih procjena parametara. Odnosno uzrokuje niske ili podcijenjene standardne greške parametara, visoke vrijednosti t-omjera, odnosno F-testa i netočne zaključke da su ocijenjeni parametri statistički značajni (Jurun, 2007).

Problem autokorelacije se javlja ako nije ispunjena pretpostavka o nezavisnosti slučajnih varijabli.

4.2. Prikupljanje podataka

Podaci su prikupljeni u razdoblju od 02. prosinca 2016. do 08. prosinca 2016. Sa stranice *booking.com* uz pisano dopuštenje navedene web stranice. Prikupljeni su manualno te prema različitim kriterijima uvršteni u Excel tablicu kako bi se mogli dalje analizirati pomoću programa IBM SPSS Statistics.

Web stranica *booking.com* nudi različite opcije unutar svoje tražilice, pa je tako za željeni datum noćenja zatražen 01. lipnja 2017. Sve promatrane opservacije u ovom istraživanju odnose se na isti datum. Prema Pravilniku o razdobljima glavne sezone, predsezone, posezone

i izvansezone u turističkim općinama i gradovima (2009.) trajanje glavne sezone u gradu Splitu je tijekom cijele godine, no uzimajući u obzir da je glavna sezona u ostalim općinama i gradovima Splitsko-dalmatinske županije od 01. lipnja do 30. rujna, odabran je datum koji se nalazi unutar tog vremenskog okvira.

Ostali kriteriji koji su uneseni u tražilicu su bili lokacija smještaja gdje je odabran grad Split, te broj osoba, odnosno noćenje za dvije osobe. Razlog zbog kojeg je odabrano noćenje za dvije osobe je zbog jednostavnosti pretrage, kako ne bi bilo velikih oscilacija kod dobivenih rezultata što je moguće ako se ne definira broj osoba. Smještajni objekti uključeni u ovo istraživanje su privatni apartmani i sobe. U istraživanje su uključeni samo navedeni objekti kako bi se ostvarila homogenost uzorka te izbjegle moguće pogreške u daljnjem istraživanju, što bi se moglo pojaviti kada bi bili uključeni i hoteli sa različitim brojem zvjezdica. U nastavku je prikazana Slika 1, koja prikazuje tražilicu sa *booking.com* web stranice s odabranim kriterijima tražilice. Kao što je već i navedeno, traženo odredište je Split, dok je za datum prijave odabran 01. lipnja 2017.

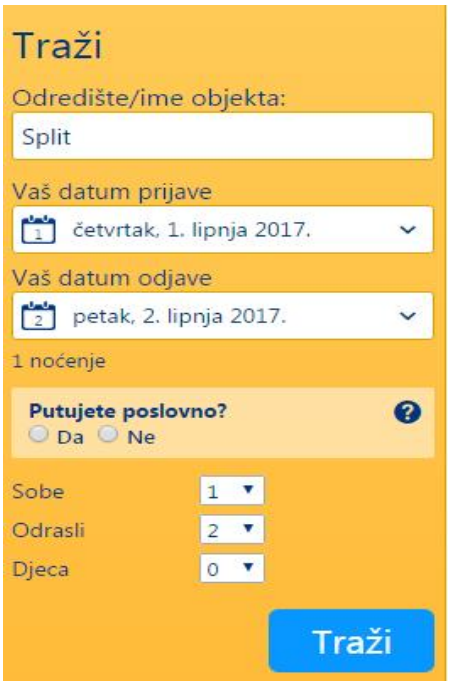

Slika 1: Tražilica sa web stranice booking.com

Izvor: booking.com

Nakon odabranih kriterija pretrage, od ponuđenih rezultata nisu svi uključeni u model. Problem kod nekih dobivenih rezultata bio je u tome što nisu imali naznačene sve varijable koje su bitne za ovo istraživanje, npr. u nekim slučajevima nije bila naznačena veličina

smještajnog objekta ili recenzija. Također u model nisu uključeni smještajni objekti koji su u trenutku pretrage imali različite popuste ili akcije, kako bi uzorak bio što homogeniji.

4.3. Odabir varijabli

Kako je za zavisnu varijablu definirana cijena noćenja izražena u HRK, a glavno polazište rada je udaljenost od Dioklecijanove palače, za prve dvije varijable odabrane su upravo te. Nadovezujući se na tablicu prikazanu u drugom dijelu ovog rada, odabrane su ostale varijable. U Splitu su brojniji privatni smještaji i hosteli nego klasični hoteli zbog čega u model neće biti uključena varijabla broj zvjezdica. Kao svojevrsna alternativa ovoj varijabli, odabrana je varijabla *Prosječna recenzija.* Booking.com web stranica nudi korisnicima mogućnost ocjenjivanja smještaja u kojem su boravili ocjenama od 1 do 10. Pokraj gotovo svakog ponuđenog smještajnog objekta naznačena je i njegova prosječna recenzija. Kako je riječ o ocjenama posjetitelja, a ne samoprocjeni iznajmljivača, varijabla je uvrštena u model uz pretpostavku da bi mogla pridonijeti porastu cijene. Varijabla *Pogled na more* uključena je u model budući da je istražujući ponudu na različitim izvorima, često opcija pogleda na more posebno naznačena, pa je za pretpostaviti da bi mogla imati utjecaj na cijenu. Udaljenost od plaže je uvrštena kao druga lokacijska varijabla. Vodeći se pretpostavkom da velika većina posjetitelja odabire Split za destinaciju jer se nalazi na moru, blizina plaže bi mogla imati utjecaja na porast cijene noćenja. Od osam potencijalnih varijabli prezentiranih u drugom dijelu rada, u model ih je uključeno šest: *Wifi, Doručak, Sušilo, Parking, Tv(kabelski programi)* i *Veličina sobe u metrima kvadratnim.*

Pozivajući se na relevantnu literaturu u model je uključeno ukupno trinaest varijabli:

1. **Cijena noćenja izražena u HRK,** zavisna je varijabla formirana na način da su sa booking.com web stranice preuzeti podaci o transakcijskoj cijeni noćenja u određenom smještajnom objektu. Osim zavisne varijable u model je uključeno još 12 nezavisnih varijabli.
2. **Veličina smještaja,** predstavlja veličinu smještajnog objekta izraženu u metrima kvadratnim.
3. **Parkirno mjesto,** ovdje je riječ o dummy varijabli koja predstavlja dostupnost parkirnog mjesta (1) ili nedostatak istoga (0).
4. **Udaljenost od Dioklecijanove palače (izražena u minutama hoda),** vrijednosti za ovu varijablu izračunate su pomoću tehnologije besplatnih digitalnih mrežnih karata, GoogleMaps. Unesena je adresa lokacije a kao tražena lokacija upisana je ključna riječ

Dioklecijanova palača, nakon čega se može vidjeti kolika je približna udaljenost između ta dva odredišta izražena u minutama hodanja.

5. **Udaljenost od plaže (izražena u minutama hoda),** vrijednosti za ovu varijablu izračunate su kao i u prethodnom slučaju pomoću tehnologije besplatnih digitalnih mrežnih karata, GoogleMaps. Kod ove varijable je također unesena adresa lokacije a potom se traži najbliža plaža, te se dobije informacija o približnoj vremenskoj udaljenosti između dva odredišta izraženoj u minutama hodanja.
6. **Wi-fi,** dummy varijabla koja predstavlja dostupnost wi-fi-a u promatranom smještajnom objektu (1) ili nedostatak istoga (0).
7. **Kabelska,** još jedna dummy varijabla koja predstavlja dostupnost kabelskih programa (1) ili njihov nedostatak (0).
8. **Maksimalan broj osoba,** predstavlja maksimalan broj osoba koje mogu boraviti u smještajnom objektu**,** s obzirom da se u pretrazi smještaja za dvije osobe nerijetko u rezultatima pronađe smještaj koji nudi mogućnost smještaja za dvije ali i više osoba.
9. **Pogled na more,** dummy varijabla kod koje 1 označava da smještajni objekt ima pogled na more a 0 da nema.
10. **Klima uređaj,** dummy varijabla, 1 predstavlja dostupnost klima uređaja unutar smještajnog objekta a 0 ne postojanje klima uređaja.
11. **Sušilo za kosu,** dummy varijabla koja se odnosi na postojanje (1) sušila za kosu ili ne postojanje (0).
12. **Prosječna recenzija,** ova varijabla predstavlja prosječnu recenziju smještajnog objekta koju su mu posjetitelji dodijelili, te je preuzeta sa booking.com stranice.
13. **Doručak,** dummy varijabla koja označava dostupnost doručka koji je uključen u cijenu smještaja (1) odnosno opcija u kojoj doručak nije uključen (0).

4.4. Očekivani utjecaj varijabli

Tablica 4: Očekivani utjecaj nezavisnih varijabli

Varijabla	Očekivani utjecaj
Veličina smještaja	+
Parkirno mjesto	+
Udaljenost od Dioklecijanove palače	-

Udaljenost od plaže	-
Wi-fi	+
Kabelska	+
Maksimalan broj osoba	+
Pogled na more	+
Klima uređaj	+
Sušilo za kosu	+
Prosječna recenzija	+
Doručak	+

Izvor: Izrada autorice

Oslanjajući se na postojeću literaturu i prikupljene podatke sastavljena je tablica očekivanog utjecaja nezavisnih varijabli na zavisnu. Gotovo sve varijable bi trebale imati pozitivan utjecaj, osim dviju lokacijskih varijabli, koje zbog pretpostavke da će manja udaljenost utjecati na porast cijene imaju predznak minus.

4.5. Testiranje hipoteza

Testiranje hipoteza podijeljeno je na deskriptivnu statistiku i regresijsku analizu. Nakon prezentiranja osnovnih pokazatelja deskriptivne statistike, slijedi regresijska analiza pomoću koje će se prihvatiti ili odbaciti pretpostavljene hipoteze.

4.5.1. Deskriptivna statistika

U istraživanje su uključene ukupno 73 opservacije, odnosno N=73. U program IBM SPSS Statistics kao zavisna varijabla je unesena Cijena noćenja (HRK), dok su sve ostale varijable unesene kao nezavisne varijable. Prije analiza koje su provedene u svrhu odgovaranja na postavljene probleme, kratko ćemo se osvrnuti na deskriptivne podatke o promatranim varijablama. Predmet analize je međuovisnost cijena noćenja u Splitu (u HRK) i 12 prediktorskih varijabli (sedam dihotomnih i pet diskretnih). Prediktorske varijable u modelu

su: veličina smještaja (u metrima kvadratnim), posjeduje li određeni smještaj parkirno mjesto, udaljenost od Dioklecijanove palače (u minutama, prema Google mapsu), udaljenost do plaže (u minutama, prema Google mapsu), posjeduje li određeni smještaj wifi, posjeduje li određeni smještaj kabelsku televiziju, maksimalan kapacitet (broj osoba), posjeduje li određeni smještaj pogled na more, posjeduje li određeni smještaj klima uređaj, posjeduje li određeni smještaj sušilo, prosječna ocjena prema recenzijama i nudi li određeni smještaj doručak.

Kako su skale podijeljene na diskretne i dihotomne, analiza je podijeljena na način da u prvom dijelu numerički opisuje diskretne varijable, a potom distribucijom frekvencija i grafičkom analizom opisuje dihotomne varijable. Kao što se može vidjeti iz Tablice 5., prikazane su osnovne mjere centralne tendencije, disperzije i asimetrije za promatrane varijable (cijena noćenja, veličina smještaja, udaljenost od Dioklecijanove palače, udaljenost od plaže i prosječna recenzija smještajnog prostora.

Tablica 5: Pregled rezultata deskriptivne statistike diskretnih varijabli u istraživanju

	N	***R***	***Min***	***Max***	***Me***	***SD***	***Sk***
Cijena noćenja	73	1682,00	316,00	1998,00	768,51	338,37	1,22
Veličina smještaja	73	70,00	26,00	96,00	40,38	14,00	1,68
Udaljenost od DP	73	60,00	1,00	61,00	16,11	16,60	1,42
Udaljenost od plaže	73	26,00	1,00	27,00	15,58	6,57	-0,64
Prosječna recenzija	73	2,90	6,90	9,80	8,83	0,80	-0,86

Izvor: Izrada autorice

Prosječna cijena smještaja iznosila je 768,51 kunu, uz prosječno odstupanje od 338,37 kuna, pri čemu se može zaključiti da pokazatelj prosječne cijene nije reprezentativan (V>30%). Raspon cijena kretao se unutar 1682 kune, a maksimalan iznos cijene smještaja iznosila je 1998 kuna, te se taj podatak može smatrati netipičnom vrijednošću (z>3). Distribucija cijena smještajnih kapaciteta po simetriji je desnostrano asimetrična, odnosno može se zaključiti da se većina cijena smještajnih kapaciteta nalazi desno od očekivane vrijednosti distribucije.

Prosječna veličina smještajnog kapaciteta iznosi 40,38 metara kvadratnih uz prosječno odstupanje od 14 metara kvadratnih, pa se može zaključiti da je taj pokazatelj prosjeka nereprezentativan (V>30%). Raspon kvadrature smještajnih kapaciteta kreće se unutar 70 metara kvadratnih, a maksimalna kvadratura smještajnog kapaciteta u istraživanju (Max=96)

smatra se netipičnom vrijednošću (z>3). Distribucija kvadrature smještajnih kapaciteta, također je desnostrano asimetrična.

Prosječna udaljenost (u minutama) od smještajnog kapaciteta (prema Google mapsu) do centra grada (Dioklecijanova palača) kao i do plaže prema rezultatima analize je slična. U prvom slučaju 16,11 minuta, a u drugom 15,58 minuta. Oba su pokazatelja prosjeka nereprezentativna (V>30%), uz puno veći raspon varijacije prisutan kod udaljenosti od smještajnog kapaciteta do centra grada ($R_{centar} = 60; R_{plaža} = 26$). Distribucija udaljenosti od smještajnog kapaciteta do centra grada je desnostrano asimetrična, dok je distribucija udaljenosti od smještajnog kapaciteta do plaže ljevostrano asimetrična.

Prosječna vrijednost prosječne recenzije od strane turista iznosi 8,83 uz prosječno odstupanje od prosječne vrijednosti od 0,8 te se može zaključiti da je pokazatelj prosječne ocjene reprezentativan (V<30%). Raspon prosječnih ocjena smještajnih kapaciteta nalazi se unutar 2,90, a distribucija prosječnih ocjena prema simetriji je ljevostrano asimetrična.

Deskriptivni pokazatelji dihotomnih varijabli raspoređeni su tabele distribucije apsolutnih i relativnih frekvencija, te su dodatno grafički prikazane strukturnim krugovima.

Tablica 6: Distribucija frekvencija dihotomnih varijabli u istraživanju

Varijabla	Odgovori	Frekvencije	Postotak
Parkirno mjesto	Ne	10	13,7
	Da	63	86,3
	Ukupno	73	100,0
Wifi	Ne	2	2,7
	Da	71	97,3
	Ukupno	73	100,0
Kabelska	Ne	16	21,9
	Da	57	78,1
	Ukupno	73	100,0
Pogled na more	Ne	54	74,0
	Da	19	26,0
	Ukupno	73	100,0
Klima uređaj	Ne	1	1,4
	Da	72	98,6
	Ukupno	73	100,0
Sušilo	Ne	6	8,2
	Da	67	91,8

	Ukupno	73	100,0
Doručak	Ne	61	83,6
	Da	12	16,4
	Ukupno	73	100,0

Izvor: Izrada autorice

Rezultati analize ukazuju na zaključak da većina smještajnih kapaciteta posjeduje većinu dodatnih vrijednosti koje su uključene u sam prijedlog vrijednosti (smještajni kapacitet). Tako 86% smještajnih kapaciteta posjeduje parkirno mjesto.

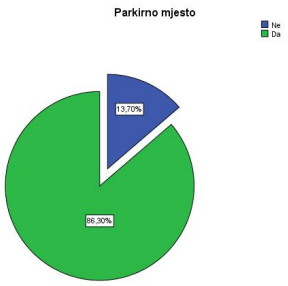

Graf 1:Strukturni krug varijable 'parkirno mjesto'

Izvor: Izrada autorice

Gotovo 100% smještajnih kapaciteta posjeduje Wifi (97%).

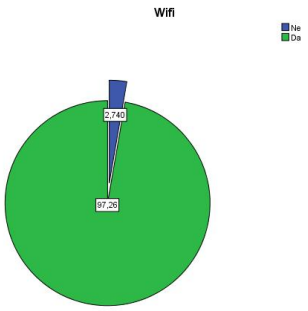

Graf 2:Strukturni krug varijable 'Wifi'

Izvor: Izrada autorice

Kabelsku televiziju posjeduje 78% smještajnih kapaciteta, što je u skladu s globalnim trendovima koji ukazuju na konstantan porast Internet i mobilne telefonije te opadanje trenda tele-medija.

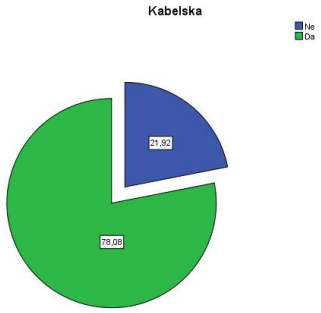

Graf 3: Strukturni krug varijable 'kabelska'

Izvor: Izrada autorice

Pogled na more ima samo 26% smještajnih kapaciteta, što je u skladu s rezultatima udaljenosti smještajnih kapaciteta od plaže.

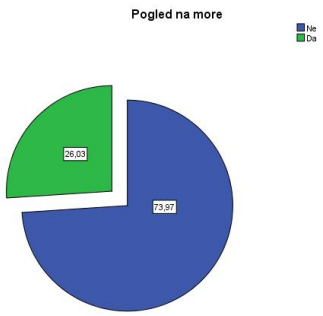

Graf 4: Strukturni krug varijable 'pogled na more'

Izvor: Izrada autorice

Klima uređaj posjeduje 91% smještajnih kapaciteta dok više od 98% smještajnih kapaciteta posjeduje klima uređaj (više nego Wifi).

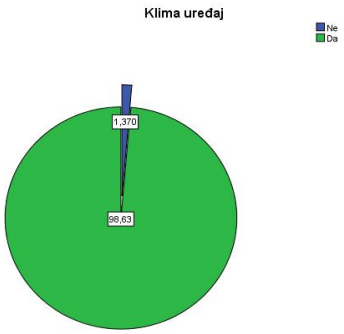

Graf 5:Strukturni krug varijable 'klima uređaj'

Izvor: Izrada autorice

Sušilo prema očekivanjima posjeduje više od 90% smještajnih kapaciteta.

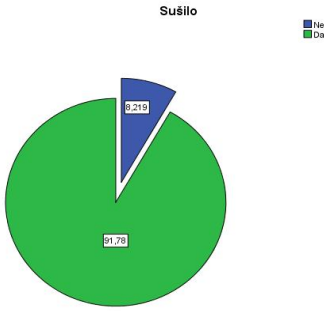

Graf 6: Strukturni krug varijable 'sušilo'

Izvor: Izrada autorice

Nastavno na prethodno, samo 16% smještajnih kapaciteta nudi uključen doručak u cijenu.

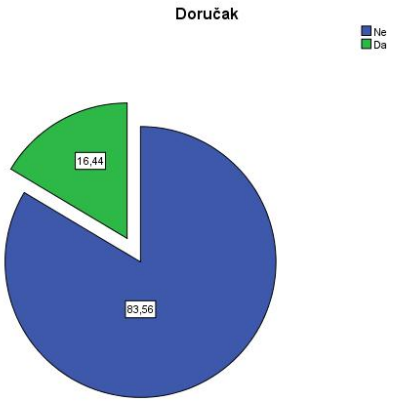

Graf 7: Strukturni krug varijable 'doručak'

Izvor: Izrada autorice

4.5.2. Regresijska analiza

H1: Postoji statistički značajna veza između udaljenosti od Dioklecijanove palače i cijene noćenja

H2: Smještajni kapaciteti manje udaljenosti od Dioklecijanove palače imaju višu cijenu noćenja

Za testiranje hipoteza korištena je višestruka regresijska analiza, sa jednom zavisnom i dvanaest nezavisnih varijabli.

$$\mathbf{Y} = \boldsymbol{\beta}_0 + \boldsymbol{\beta}_1 * x1 + \boldsymbol{\beta}_2 * x2 + \boldsymbol{\beta}_3 * x3 + \boldsymbol{\beta}_4 * x4 + \boldsymbol{\beta}_5 * x5 + \boldsymbol{\beta}_6 * x6 + \boldsymbol{\beta}_7 * x7 + \boldsymbol{\beta}_8 * x8 +$$

$$\boldsymbol{\beta}_9 * x9 + \boldsymbol{\beta}_{10} * x10 + \boldsymbol{\beta}_{11} * x11 + \boldsymbol{\beta}_{12} * x12 + e_i$$

Gdje je:

Y –Zavisna varijabla, noćenje u HRK

x1 – veličina smještaja

x2 – parkirno mjesto

x3 – udaljenost od Dioklecijanove palače

x4 – udaljenost od plaže

x5 – Wi-fi

x6 – kabelska

x7 – maksimalan broj osoba

x8 – pogled na more

x9 – klima uređaj

x10 – sušilo

x11 – prosječna recenzija

x12 – doručak

U svrhu detaljnije analize o dinamici odnosa između varijabli u modelu, inicijalno je provedena korelacijska analiza kako bi se detektirali ključni i statistički značajni odnosi u modelu cijene smještajnog kapaciteta. Prema Gujarati (2004), korelacijska matrica prikazuje linearnu jačinu između dviju varijabli. Premda su usko povezane, regresijska i korelacijska analiza konceptualno su veoma različite. Korelacija mjeri jačinu ili stupanj linearne povezanosti između dvije varijable. U regresijskoj analizi ova mjera nije od velike važnosti. Regresijska analiza nastoji procijeniti odnosno predvidjeti prosječnu vrijednost jedne varijable na temelju fiksnih vrijednosti drugih varijabli. Jedna od fundamentalnih razlika između korelacije i regresije je i ponašanje varijabli. U regresijskoj analizi za zavisnu varijablu se pretpostavlja da je statistička, slučajna ili stohastička, dok se za nezavisne varijable pretpostavlja da imaju fiksne vrijednosti. U korelacijskoj analizi sve varijable se tretiraju jednako. Točnije, za sve varijable se pretpostavlja da su slučajne, za razliku od regresijske analize gdje se pretpostavlja stohastičnost zavisne i nestohastičnost nezavisnih varijabli. U nastavku je prikazana korelacijska matrica varijabli inicijalnog modela, u kojoj se mogu vidjeti linearni odnosi među varijablama.

Tablica 7: Korelacijska matrica varijabli u inicijalnom modelu

	y	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12
Cijena noćenja	1	-,025	,002	-,137	,003	,165	,159	,040	-,104	-,127	,109	**,316****	**,531****
Veličina smještaja		1	,120	**,345****	-,166	,101	-,214	,205	,148	,046	,073	,022	-,286*
Parkirno mjesto			1	,223	-,160	-,067	,174	,120	,146	,296*	,171	,191	-,038
Udaljenost od DP				1	-,555**	**-,294***	-,209	,207	**,331****	,079	-,007	-,023	-,301**
Udaljenost od plaže					1	,246*	,092	-,048	-,306**	-,116	-,019	-,129	,080
Wifi						1	,114	,105	-,092	-,020	-,050	,176	,074
Kabelska							1	,007	,012	,222	,083	,213	,146
Maksimalan broj osoba								1	,036	,074	-,139	,082	-,157
Pogled na more									1	,070	,178	,149	-,179
Klima uređaj										1	,394**	,271*	-,266*
Sušilo											1	**,476****	-,002
Prosječna recenzija												1	,089
Doručak													1

**- korelacija je signifikantna na razini od 0.01
*- korelacija je signifikantna na razini od 0.05
Izvor: Izrada autorice

Na temelju korelacijske analize detektirani su neki statistički značajni odnosi u modelu cijene smještajnog kapaciteta. Prema rezultatima korelacijske matrice može se zaključiti da su veći (po kvadraturi) smještajni kapaciteti udaljeniji od centra (Dioklecijanova palača), odnosno što smo udaljeniji od centra to će se smještajni kapacitet biti veći (r=0,345; p<0,01). Također, što je smještajni kapacitet udaljeniji od centra grada, smanjuje se vjerojatnost da će posjedovati wifi (r=-0,294; p<0,05). Udaljavanjem od centra grada, pospješuje se vjerojatnost da će smještajni kapacitet imati pogled na more (r=0,331; p<0,01). Cijena noćenja statistički značajno korelira s prosječnom ocjenom kojom je sam smještajni kapacitet ocijenjen. Ovaj je koeficijent korelacije pozitivan, što znači da s većom prosječnom ocjenom, raste i cijena smještajnog kapaciteta (r=0,316; p<0,01). Prosječna recenzija će rasti ukoliko smještajni kapacitet posjeduje sušilo. Koeficijent korelacije je pozitivan i statistički značajan na razini značajnosti od 1% (r=0,476; p<0,01). Cijena noćenja u pozitivnoj je korelaciji s opcijom doručka u smještajnom kapacitetu. Ukoliko smještajni kapacitet posjeduje opciju doručka prosječna cijena će biti viša (r=0,531; p<0,01). Pregled preostalih rezultata koeficijenata korelacije između promatranih varijabli nalazi se u tablici 7.

Inicijalni rezultati analize, prikazani gore, pokazali su statističku neznačajnost između cijene smještajnog kapaciteta i udaljenosti do Dioklecijanove palače (r=-0,137; p>0,05). Nastavno, varijabla udaljenost do Dioklecijanove palače transformirana je po principu prirodnog logaritma u svrhu postizanja statističke značajnosti u odnosu cijena – udaljenost. Nakon transformacije, rezultati analize pokazuju statističku značajnost na razini signifikantnosti od 1% (r=-0,304; p<0,01). Ostali odnosi među varijablama ostali su gotovo ne promijenjeni, te se mogu vidjeti u tablici 8.

Tablica 8: Korelacijska matrica varijabli nakon transformacije varijable *Udaljenost od Dioklecijanove palače*

	y	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12
Cijena noćenja	1	-,025	,002	**-,304****	,003	,165	,159	,040	-,104	-,127	,109	**,316****	**,531****
Veličina smještaja		1	,120	**,396****	-,166	,101	-,214	,205	,148	,046	,073	,022	-,286*
Parkirno mjesto			1	,180	-,160	-,067	,174	,120	,146	,296*	,171	,191	-,038
LOG_Udaljenost od DP				1	-,388**	**-,240***	-,177	,206	**,346****	,073	-,003	-,116	-,393**
Udaljenost od					1	,246*	,092	-	-	-,116	-,019	-,129	,080

plaže								,048	,306**				
Wifi						1	,114	,105	-,092	-,020	-,050	,176	,074
Kabelska							1	,007	,012	,222	,083	,213	,146
Maksimalan broj osoba								1	,036	,074	-,139	,082	-,157
Pogled na more									1	,070	,178	,149	-,179
Klima uređaj										1	,394**	,271*	-,266*
Sušilo											1	**,476****	-,002
Prosječna recenzija												1	,089
Doručak													1

**- korelacija je signifikantna na razini od 0.01
*- korelacija je signifikantna na razini od 0.05
Izvor: Izrada autorice

Rezultati regresijske analize ukazuju na samo neke od statistički značajnih prediktora u modelu cijena smještajnih kapaciteta. Prethodno regresijskoj analizi napravljena je provjera homoskedastičnosti i multikolinearnosti varijabli u modelu. Inicijalno je napravljena vizualna analiza homoskedastike, a na temelju dijagrama rasipanja moguće je pretpostaviti mogući problem narušavanja teorema homoskedastičnosti.

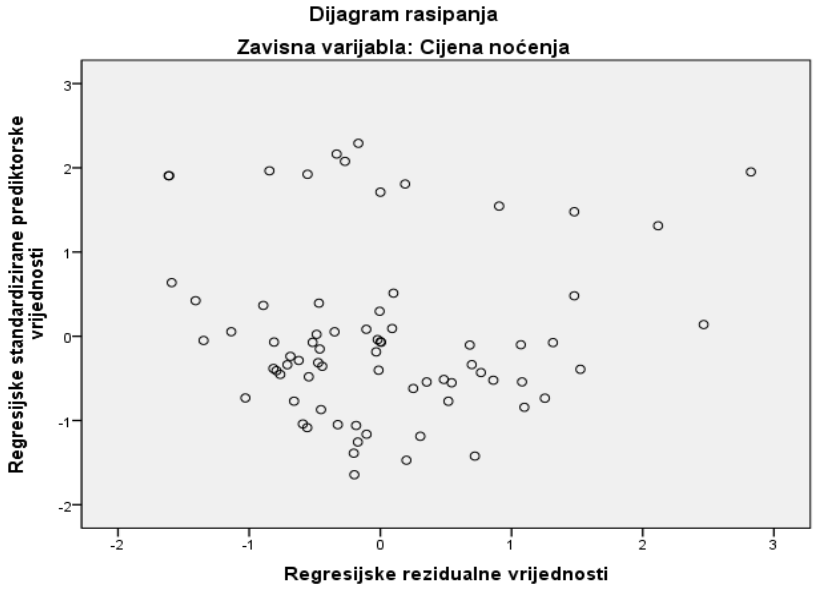

Graf 8: Dijagram rasipanja

Izvor: Izrada autorice

Na temelju dijagrama rasipanja zaključuje se da bi u inicijalnom regresijskom modelu mogao postojati problem heteroskedastičnosti. U tu svrhu provodi se Breusch-Pagan i Koenker test o narušenosti homoskedastičnosti modela. Rezultati analize ukazuju da nije prisutan problem heteroskedastičnosti modela (BP=19,66; p>0,05, K=14,61; p>0,05).

Također, u modelu nije prisutan problem multikolinearnosti (*VIFi*<5; i=1,…,12). Rezultati regresijske analize nalaze se u tablici 9. gdje je vidljivo da su varijable *Prosječna recenzija* (*B11*=107,32; *p*<0,05) i *Doručak* u sklopu smještajnog kapaciteta (*B12*=458,69; *p*<0,05) statistički značajne u modelu predviđanja cijene smještajnog kapaciteta. Od ukupno dvanaest regresorskih varijabli, samo dvije su se pokazale signifikantne.

Tablica 9: Tablica koeficijenata varijabli u modelu cijena smještajnih kapaciteta

	β	*SE*	*T*	*p*	*VIF*
Konstanta	-354,38	523,96	-0,68	0,501	
Veličina smještaja	2,70	2,80	0,96	0,339	1,331
Parkirno mjesto	-37,88	108,49	-0,35	0,728	1,221
Udaljenost od DP	0,54	2,89	0,19	0,852	1,996
Udaljenost od plaže	-1,57	6,58	-0,24	0,812	1,615
Wifi	122,59	233,56	0,52	0,602	1,275
Kabelska	66,14	91,03	0,73	0,470	1,244
Maksimalan broj osoba	45,58	60,00	0,76	0,450	1,180
Pogled na more	-62,09	85,62	-0,73	0,471	1,238
Klima uređaj	-281,27	357,32	-0,79	0,434	1,513
Sušilo	57,80	157,62	0,37	0,715	1,644
Prosječna recenzija	107,32	52,84	2,03	0,047	1,549
Doručak	458,69	105,88	4,33	0,000	1,351

Izvor: Izrada autorice

Dobiveni rezultati mogu se objasniti na sljedeći način: ukoliko prosječna recenzija poraste za jednu ocjenu cijena noćenja će u prosjeku porasti za 107,32 HRK. Odnosno, za dummy varijablu *Doručak:* ako smještajni objekt u cijenu ima uključen i doručak to će dovesti do porasta cijene noćenja od prosječno 458,69 HRK. Oslanjajući se na rezultate u gore prikazanoj tablici mogle bi se odbaciti obje hipoteze. Naime, varijabla *Udaljenost od Dioklecijanove palače* nije statistički značajna što se može i vidjeti u gore prikazanoj tablici. Međutim, u nastavku će biti prikazano nekoliko modificiranih oblika inicijalnog modela, zbog čega ne treba brzati sa zaključcima.

Nastavno na rezultate inicijalnog modela: modelom je protumačeno 39,4% ukupnih odstupanja ($R^2 = 0{,}394$), pri čemu se zaključuje da je regresijski model granično reprezentativan. Prikladnijim pokazateljem reprezentativnosti (korigirani koeficijent determinacije) zaključuje se da je narušena reprezentativnost regresijskog modela ($\bar{R}^2 = 0{,}273$).Skupnim testom dokazana je značajnost minimalno jednog prediktora modela cijene

smještajnog kapaciteta (F=3,256; p<0,01). Prethodno navedeni pokazatelji iskazani su u tablici 10.

Tablica 10:Tablica analize varijance regresijskog modela i tablica sažetka modela višestruke regresije

	Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	*F*	*p*	Koeficijent multiple korelacije	Koeficijent determinacije	Korigirani koeficijent determinacije
Protumačena odstupanja	3251112,38	12	270926,03	3,26	<0,01	0,63	0,39	0,27
Neprotumačena odstupanja	4992443,86	60	83207,40					
Ukupna odstupanja	8243556,25	72						

Izvor: Izrada autorice

Temeljem rezultata inicijalnog modela, predložen je modificirani model sa statistički značajnim varijablama u modelu u svrhu veće reprezentativnosti modela cijena smještajnih kapaciteta. U modelu nije prisutan problem heteroskedastičnosti čime je očuvano osnovno regresijsko načelo homoskedastičnosti (K=5,61; p>0,05). Rezultati modificiranog modela nalaze se u tablici 11.

Tablica 11:Tablica koeficijenata varijabli u prvom modificiranom modelu cijena smještajnih kapaciteta

	β	*SE*	*T*	*p*	*VIF*
Konstanta	-317,820	360,191	-,882	>0,05	
Prosječna recenzija	114,450	40,734	2,810	<0,05	1,008
Doručak	459,636	87,394	5,259	<0,05	1,008

Izvor: Izrada autorice

Može se zaključiti da u modelu nije prisutan problem multikolinearnosti ($VIFi$<5; i=1,2). Ukoliko prosječna recenzija poraste za jednu ocjenu cijena noćenja će u prosjeku porasti za 114,45 HRK. Odnosno, za dummy varijablu *Doručak:* ako smještajni objekt u cijenu ima uključen i doručak to će dovesti do porasta cijene noćenja od prosječno 459,636 HRK. Isključivanjem ostalih varijabli, utjecaj na cijenu se malo povećao što je i očekivano. Modelom je protumačeno 34% ukupnih odstupanja prema korigiranom koeficijentu

determinacije ($\bar{R}^2 = 0{,}34$), što je povećanje od 6,7%. Regresijski model prelazi marginalnu granicu reprezentativnosti od 30%. Preostali rezultati regresijske analize nalaze se u tablici 12.

Tablica 12:Tabela analize varijance modificiranog regresijskog modela i tabela sažetka modela višestruke regresije

	Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	*F*	*p*	Koeficijent multiple korelacije	Koeficijent determinacije	Korigirani koeficijent determinacije
Protumačena odstupanja	2925261,74	2	1462630,87	19,25	<0,01	0.60	0,36	0,34
Neprotumačena odstupanja	5318294,51	70	75975,64					
Ukupna odstupanja	8243556,25	72						

Izvor: Izrada autorice

Nakon testiranja modificiranog modela sa dvjema signifikantnim varijablama, u nastavku je testiran model sa logaritmiranom varijablom.

Tablica 13:Tablica koeficijenata varijabli u drugom modificiranom modelu cijena smještajnih kapaciteta

	β	*SE*	*T*	*p*	*VIF*
Konstanta	-223,379	378,161	-,591	>0,05	
Prosječna recenzija	111,414	40,982	2,719	<0,05	1,016
Doručak	428,743	95,146	4,516	<0,05	1,185
Log_Udaljenost od DP	-64,995	75,861	-,838	>0,05	1,192

Izvor: Izrada autorice

Nakon logaritmiranja varijable *Udaljenost od Dioklecijanove palače,* predložen je modificirani model sa prethodno spomenutom logaritmiranom varijablom, te dvjema signifikantnim varijablama iz inicijalnog modela.

Kao što je vidljivo iz prikazane tablice, u modelu ne postoji problem multikolinearnosti (VIF< 5). Kako iz dolje prikazanog grafa rasipanja nije bilo moguće precizno odrediti postoji li problem heteroskedastičnosti, napravljen je Breusch-Pagan i Koenker test.

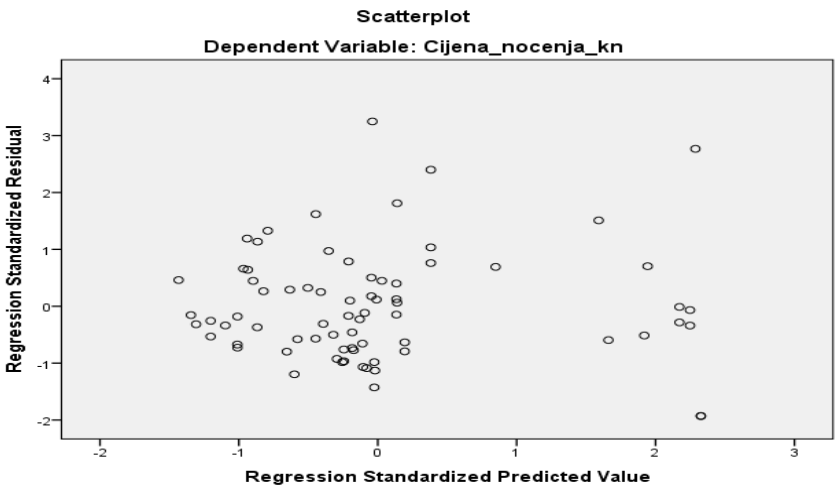

Graf 9: Dijagram rasipanja u modificiranom modelu

Izvor: Izrada autorice

Nakon provedenog testa, ustanovljeno je kako ne postoji problem heteroskedastičnosti (K=6,303; p>0,05).

Tablica 14:Tabela analize varijance drugog modificiranog regresijskog modela i tabela sažetka modela višestruke regresije

	Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	*F*	*p*	Koeficijent multiple korelacije	Koeficijent determinacije	Korigirani koeficijent determinacije
Protumačena odstupanja	2978793,583	3	,270	13,013	<0,01	0.60	0,36	0,33
Neprotumačena odstupanja	5264762,664	69	,022					
Ukupna odstupanja	8243556,247	72						

Izvor: Izrada autorice

Prema koeficijentu determinacije (R^2 = 0,36) i korigiranom koeficijentu determinacije ($\bar{R}^2 = 0{,}33$), može se zaključiti kako je model granično reprezentativan. Skupnim testom dokazana je značajnost minimalno jednog prediktora modela cijene smještajnog kapaciteta (F=13,013; p<0,01). Prethodno navedeni pokazatelji iskazani su u tablici 14.

U tablici 13. može se vidjeti kako varijabla *Udaljenost od DP* i nakon provedene logaritamske transformacije nije signifikantna,p>0,05. Nakon provjere modela, ipak se odbacuje hipoteza o statistički značajnoj vezi između cijene noćenja i udaljenosti od Dioklecijanove palače. Druge dvije varijable *Doručak* i *Prosječna recenzija* signifikantne su i u ovom modelu,te se njihov utjecaj nije puno promijenio.

Nakon definiranja varijabli i prikupljanja podataka, prezentirani su rezultati deskriptivne statistike provedeni na uzorku od sedamdeset tri opservacije. Prikaz pokazatelja deskriptivne i regresijske analize omogućava širu sliku za donošenje zaključaka. S obzirom da u nastavku rada slijedi detaljniji osvrt na dobivene rezultate, kratko će se rezimirati empirijsko testiranje. Prosječna cijena noćenja iznosi 768,51 kunu, dok većina smještajnih kapaciteta posjeduje većinu dodatnih karakteristika sadržanih u dummy varijablama. Rezultati inicijalnog modela višestruke regresije pokazuju da na cijene noćenja utjecaj imaju varijable *Prosječna recenzija* i *Doručak*. U cilju postizanja statističke značajnosti, logaritmirana je varijabla *Udaljenost od Dioklecijanove palače*, no bez većeg utjecaja na rezultate. Zbog tog razloga odbacuju se obje hipoteze.

5. REZULTATI

Nakon iscrpne empirijske analize predstavljene u prethodnom poglavlju rada slijedi osvrt na rezultate. Prvi dio empirijske analize koji se odnosi na deskriptivnu statistiku, dovodi do informacije kako prosječna cijena noćenja iznosi 768,51 HRK. Najviša cijena noćenja u istraživanju iznosila je 1998,00 HRK a najniža 316 HRK. Ostatak rezultata deskriptivne statistike detaljnije je pojašnjen na početku empirijskog istraživanja, zbog čega će u nastavku fokus biti na rezultatima regresijske analize. Konkretnije, pomnije će se razmotriti hipoteze, njihovo prihvaćanje i odbacivanje, te objašnjenja dobivenih rezultata.

Dvije hipoteze definirane na početku rada su:

H1: Postoji statistički značajna veza između udaljenosti od Dioklecijanove palače i cijene noćenja

H2: Smještajni kapaciteti manje udaljenosti od Dioklecijanove palače imaju višu cijenu noćenja

Prethodno empirijskom testiranju prezentirani su očekivani utjecaji nezavisnih varijabli na zavisnu varijablu. Zbog što preglednijeg prikaza, u tablici 15 prikazana je usporedba očekivanog utjecaja varijabli i dobivenih rezultata. Gdje *nz* označava statističku neznačajnost, a *z* značajnost. Od dvanaest regresorskih varijabli u inicijalnom modelu, statistički značajnima pokazale su se *Prosječna recenzija i Doručak.*

Tablica 15:Usporedba očekivanih utjecaja varijabli i dobivenih rezultata

Varijabla	Očekivani utjecaj	Rezultati
Veličina smještaja	+	nz
Parkirno mjesto	+	nz
Udaljenost od Dioklecijanove palače	-	Nz
Udaljenost od plaže	-	Nz

Wi-fi	+	nz
Kabelska	+	Nz
Maksimalan broj osoba	+	Nz
Pogled na more	+	Nz
Klima uređaj	+	Nz
Sušilo za kosu	+	Nz
Prosječna recenzija	+	z +
Doručak	+	z+

Izvor: Izrada autorice

Lokacijska varijabla *Udaljenost od Dioklecijanove palače,* nije se pokazala signifikantnom u inicijalnom modelu. Shodno tome, ne mogu se prihvatiti pretpostavljene hipoteze. Premda rezultati nisu u skladu sa očekivanjima, uvijek postoji prostor za nadogradnju modela, što bi možda u konačnici dovelo i do drugačijih rezultata. U svrhu postizanja statističke značajnosti u odnosu cijena – udaljenost, logaritmirana je varijabla *Udaljenost od Dioklecijanove palače.* Međutim, rezultati regresijske analize pokazali su kako varijabla i dalje nije signifikantna. Uzimajući u obzir prezentirane rezultate odbacuju se obje hipoteze.

Iako hipoteze nisu potvrđene, ne treba zanemariti dobivene rezultate. U inicijalnom modelu statistički značajnima pokazale su se varijable *Prosječna recenzija* i *Doručak*. Iz tog razloga testiran je i modificirani model s navedenim varijablama u svrhu veće reprezentativnosti. Rezultati pokazuju da ukoliko prosječna recenzija poraste za jednu ocjenu cijena noćenja će u prosjeku porasti za 114,45 HRK. Ako smještajni objekt u cijenu ima uključen i doručak to će dovesti do porasta cijene noćenja od prosječno 459,636 HRK. Zanimljivo je bilo doći do spoznaje kako su upravo ovo, dva atributa koja su najviše utjecala u cijenu. Prosječna recenzija nekog objekta predstavlja prosjek ocjena koje su mu dodijelili posjetitelji. "Word of mouth" odavno je poznata kao najbolja marketinška strategija, a sve veći razvoj tehnologije izvrsna joj je platforma. Naime, ako je vjerovati prezentiranim rezultatima potrošači uvelike vjeruju ostalim potrošačima. Što se tiče doručka, rezultat je veoma logičan. Budući da je u cijenu uključen i obrok, očekivano je da će i sama cijena biti viša.

Osim što nisu potvrđene hipoteze, rezultati upućuju kako ni druga lokacijska varijabla *Udaljenost od plaže* također nema utjecaja na cijenu noćenja. Ova varijabla uvrštena je u model, s pretpostavkom kako bi trebala imati pozitivan utjecaj na cijene. Iako uvijek postoji mogućnost unaprjeđenja modela, nesignifikantnost lokacijskih varijabli pomalo je iznenađujuća.

Glede dummy varijabli,*Doručak, Parkirno mjesto, Klima uređaj, Tv, Sušilo, wifi*, ispostavilo se da većina smještajnih kapaciteta posjeduje većinu dodatnih karakteristika. Ovo je posebice zanimljivo glede wifi-a, kojeg posjeduju gotovo svi smještajni kapaciteti. Očito je kako iznajmljivači nastoje što bolje opremiti svoje objekte, kao rezultat sve veće konkurencije.

Rezultati ovog istraživanja pokazali su kako dostupnost parkirnog mjesta nema utjecaja na cijenu noćenja. Osim što se ova karakteristika pokazala značajnom u prethodnim istraživanjima, nemogućnost pronalaska parkirnog mjesta čest je problem tijekom ljetnih mjeseci. Zbog tog razloga očekivano je bilo kako će se dostupnost parkirnog mjesta pokazati signifikantnom. Jedan od razloga može biti i rastuća popularnost niskobudžetnih prijevoznika. Ovakav oblik prijevoza većinom je namijenjen mlađoj populaciji, koja nerijetko posjeti više destinacija u kratkom vremenskom roku, pa im u konačnici parkirno mjesto i nije potrebno.

U uvodnom dijelu rada definiran je cilj istraživanja, koji je bio empirijski ispitati u kolikoj mjeri udaljenost smještajne jedinice od Dioklecijanove palače utječe na njegovu cijenu. Cilj istraživanja je postignut, premda dobiveni rezultati nisu u skladu sa početnim očekivanjima. Također, bit rada nije bilo doznati koje karakteristike bi smještajni kapaciteti trebali imati kako bi mogli postaviti veću cijenu, već kako cijenu definira lokacija. Budući da početne pretpostavke nisu potvrđene, dobiveni rezultati nisu od velike pomoći pri pokušaju vrednovanja okoliša.

Premda nisu strogo vezani u početni cilj, rezultati donose neke nove informacije. Lokacija se ne bi trebala odbaciti kao bitan faktor u potpunosti, ali također treba gledati i širu sliku. Istraživanje je pokazalo kako ponuđači prilikom formiranja cijene smještaja, uvelike u obzir uzimaju recenzije prethodnih posjetitelja. Također, ukoliko u svojoj ponudi imaju i doručak, vrlo je vjerojatno kako će ta dodatna karakteristika značiti i višu cijenu. Zanimljivo je kako varijabla *Prosječna recenzija* predstavlja relativno novu varijablu u ovakvom istraživanju. U prethodnim istraživanjima nije pronašla svoje mjesto, što se može objasniti drugačijim načinom i izvorom prikupljanja podataka. Naime, kako booking.com stranica nudi smještaj koji ne mora nužno biti hotelski, umjesto uobičajene klasifikacije na broj zvjezdica, prosječna

recenzija predstavlja svojevrsnu alternativu za vrednovanje usluge i kvalitete. Može se gotovo reći kako je uvelike i reprezentativnija, budući da dolazi direktno od kupca usluge, te se odnosi na njegovo individualno iskustvo, koje ne mora nužno biti veće samo zbog kategorizacije određenog smještajnog objekta.

Ne treba zaboraviti ni zaključak spomenut na početku rada, a to je da na cijenu često utječe zemlja a ne karakteristike smještajnog objekta (Haroutunian et al 2005). Posljednjih godina Hrvatska je postala iznimno popularno turističko odredište, pa je moguće da na cijenu ima utjecaja i sama popularnost Hrvatske, koja nije uključena u ovaj model.

6. ZAKLJUČAK

Kao što je i na početku rada rečeno, formiranje cijena noćenja turističkog smještaja poprilično je složeno, te se u obzir uzimaju mnogobrojni faktori. Svrha ovog istraživanja bila je ispitati postoji li statistički značajna veza između udaljenosti od Dioklecijanove palače i cijene noćenja u gradu Splitu. Iako pretpostavke o odnosu cijena – lokacija nisu potvrđene, dobiveni su zanimljivi rezultati.
Prethodno provedbi empirijskog istraživanja, istražene su karakteristike smještajnih kapaciteta u Splitu i Hrvatskoj, te predstavljeni brojni radovi koji se koriste hedoničkom metodom za različite svrhe. Baš kao što je i teorija pretpostavila, prilikom provedbe istraživanja nailazi se na nekoliko zapreka. Prvi izazov javio se već pri prikupljanju podataka. Premda postoji veliki broj mrežnih ali i drugih izvora, poprilično je teško pronaći potrebne podatke sve na jednom mjestu. Upravo to bio je razlog zbog kojeg su neki smještajni objekti morali biti ispušteni iz modela. Usprkos početnim problemima,u konačnici je uspješno prikupljen dovoljan broj opservacija za nastavak istraživanja.

Empirijsko testiranje nije potvrdilo dvije pretpostavljene hipoteze. Unatoč tome, dobiveni su zanimljivi rezultati. Premda je prvotan smjer istraživanja bio usmjeren na vezu između lokacije i cijene, empirijsko testiranje dovelo je do malo drugačijih spoznaja. Varijable *Prosječna recenzija* i *Doručak* ispostavile su se signifikantnima. Kao što je i u prethodnoj cjelini rada spomenuto, prosječna recenzija jest prosjek ocjena koje posjetitelji dodijele smještaju na mrežnoj stranici booking.com. Rezultati pokazuju kako upravo ova karakteristika utječe na porast cijena. Isto vrijedi i za smještajne objekte koji u ponudu imaju uključen doručak. Dobiveni rezultati u skladu su s teorijskim očekivanjima varijabli.

Unatoč tome što hipoteze nisu potvrđene, ne treba u potpunosti odbaciti pretpostavku kako lokacija nema utjecaja na cijene noćenja u Splitu. Prostora za nadogradnju modela uvijek ima. Osim potencijalnog većeg uzorka, koji bi moguće doveo do drugačijih rezultata, postoje i druge modifikacije koje bi se mogle primijeniti. Rezultati empirijskog testiranja pokazali su kako većina smještajnih objekata posjeduje poprilično slične karakteristike. Više od 50% smještajnih kapaciteta posjedovalo je sušilo, klima uređaj i pristup wifi-u.

Iako je riječ o varijablama koje su se ispostavile bitnima u prethodnim istraživanjima, očito je kako sve veća konkurencija vodi i do unaprjeđenja karakteristika. Također, ako se povežu dobiveni rezultati, koji kažu da na cijenu ima utjecaj i prosječna recenzija, jasno je kako za što

višu recenziju trebaju i bolje karakteristike. Zbog tog razloga, u budućim istraživanjima trebale bi se razmotriti navedene varijable i njihova eventualna zamjena. Također, bilo bi zanimljivo usporediti cijene noćenja u Splitu i npr. Dubrovniku ili nekom drugom popularnom turističkom središtu. Takvo istraživanje pokazalo bi u kolikoj mjeri su lokacija i popratne karakteristike uopće bitne, te utječe li na cijenu i u kolikoj mjeri popularnost određene destinacije.

LITERATURA

1. Andersson, F. (2013): Determining Room Rates in Sweden–a Hedonic prices Approach of the Stockholm Hotel Market, *Master Thesis,*University Lund, Lund.
2. Boras, T., Tica, J. (2013): Prostorna elastičnost traženih cijena stanova na stambenom tržištu Grada Zagreba. *Serija članaka u nastajanju Ekonomskog fakulteta u Zagrebu,*br.13-04.
3. Chen,C., Rothschild, R. (2010): An Application of Hedonic Pricing Analysis to the Case of Hotel Rooms in Taipei. *Tourism Economics,* 16(3), str. 685 – 694.
4. Državni zavod za statistiku (2016a): Turizam u 2015, raspoloživo na: http://www.dzs.hr/Hrv_Eng/publication/2016/SI-1564.pdf [01.02.2017.]
5. Državni zavod za statistiku (2016b): Turizam u primorskim gradovima i općinama u 2015, raspoloživo na: http://www.dzs.hr/Hrv_Eng/publication/2016/SI-1565.pdf [02.02.2017.]
6. Espinet, J. M., Saez, M., Coenders, G., Fluvia, M. (2003): Effects on Prices of the Attributes of Holiday Hotels: A Hedonic Prices Approach. *Tourism Economics*, 9(2), str. 165-177.
7. Fleischer, A. (2012): A room with a view - A valuation of the Mediterranean Sea view, *Tourism Management*33(3), str. 598 – 602.
8. Fuhrer, R. (2012): A Hedonic Rental Price Model for the Canton Zurich, *Master of Science,* Institute for Transport Planning and Systems (IVT), ETH Zurich, Zurich.
9. Gujarati, D. N., (2004): Basic econometrics, 4.izd., McGraw-Hill Companies, New York.
10. Haroutunian, S., Mitsis, P., Pashardes, P., (2005): Using brochure information for the hedonic analysis of holiday packages, *Tourism economics,* 11(1), str. 69–84.
11. Jurun, E. (2007): Kvantitativne metode u ekonomiji, Sveučilište u Splitu, Ekonomski fakultet, Split.
12. Kolbe, J., Wustemann, H. (2015): Estimating the Value of Urban Green Space: A Hedonic Pricing Analysis of the Housing Market in Cologne, Germany. SFB 649 Discussion Paper 2015-002, University of Berlin, Berlin.
13. Kunovac, D., Đozović, E., Lukinić, G., Pufnik, A. (2008): Primjena hedonističke metode za izračunavanje indeksa cijena nekretnina u Hrvatskoj. *Istraživanja* (I-20) Hrvatska narodna banka, Zagreb.

14. Narodne Novine (2009): Pravilnik o razdobljima glavne sezone, predsezone, posezone i izvansezone u turističkim općinama i gradovima, Narodne novine d.d. Zagreb, broj 92.
15. Narodne Novine (2016): Zakon o ugostiteljskoj djelatnosti - neslužbeno pročišćeni tekst,Narodne novine d.d. Zagreb, broj 121.
16. Papatheodorou, A., (2002): Exploring competitiveness in Mediterranean resorts, *Tourism economics,* 8(2), str. 133-135.
17. Pivac, S. (2010): Statističke metode, Sveučilište u Splitu, Ekonomski fakultet Split, Split.
18. Prijedlog proračuna Grada Splita za 2017. godinu sa projekcijama za 2018. i 2019. godinu, raspoloživo na: http://www.split.hr/Default.aspx?art=8577&sec=1768 [02.02.2017.]
19. Thrane, C. (2005): Hedonic Price Models and Sun-and-Beach Package Tours: The Norwegian Case, *Journal of Travel Research*, 43 str. 302-308.
20. Thrane, C. (2007): Examining the determinants of room rates for hotels in capital cities: the Oslo experience, *Journal of Revenue and Pricing Management*, 5(4), str. 315–323.
21. Tietenberg, T., Lewis, L. (2009): Environmental & Natural Resource Economics, 9.izd., Pearson Education Inc., New Jersey.
22. Turistička zajednica grada Splita (2015): Dolasci i noćenja na području TZG Split, dostupno na: http://www.visitsplit.com/hr/1868/2015-godina [14.01.2016].
23. Turistička zajednica grada Splita (2016): 2016. - Dolasci i noćenja na području TZG Split, dostupno na: http://www.visitsplit.com/hr/2145/2016-godina [02.02.2016].
24. Turistička zajednica Splitsko - dalmatinske županije (2016): Statistička analiza turističkog prometa 2015, raspoloživo na: https://www.dalmatia.hr/hr/statistike/statisticka-analiza-turistickog-prometa-2015-godine[02.02.2017.]
25. Zahedi, S., (2008): Tourism impact on coastal environment, *WIT Transactions on The Built Environment,* 99 str. 45-47,raspoloživo na: https://www.witpress.com/Secure/elibrary/papers/CENV08/CENV08005FU1.pdf[02.02.2017.]

POPIS GRAFOVA, SLIKA I TABLICA

Graf 1: Strukturni krug varijable 'parkirno mjesto' 28

Graf 2: Strukturni krug varijable 'Wifi' 28

Graf 3: Strukturni krug varijable 'kabelska' 29

Graf 4: Strukturni krug varijable 'pogled na more' 29

Graf 5: Strukturni krug varijable 'klima uređaj' 29

Graf 6: Strukturni krug varijable 'sušilo' 30

Graf 7: Strukturni krug varijable 'doručak' 30

Graf 8: Dijagram rasipanja 34

Graf 9: Dijagram rasipanja u modificiranom modelu 38

Slika 1: Tražilica sa web stranice booking.com 22

Tablica 1: Varijable koje bi mogle imati utjecaja na cijenu noćenja 14

Tablica 2: Broj soba i postelja prema vrstama turističkog smještaja od 2010 – 2015 (000) .. 16

Tablica 3: Smještajni kapaciteti po vrstama objekata u Splitu 2015. 18

Tablica 4: Očekivani utjecaj nezavisnih varijabli 24

Tablica 5: Pregled rezultata deskriptivne statistike diskretnih varijabli u istraživanju..... 26

Tablica 6: Distribucija frekvencija dihotomnih varijabli u istraživanju 27

Tablica 7: Korelacijska matrica varijabli u inicijalnom modelu 32

Tablica 8: Korelacijska matrica varijabli nakon transformacije varijable *Udaljenost od Dioklecijanove palače.* 33

Tablica 9: Tablica koeficijenata varijabli u modelu cijena smještajnih kapaciteta..... 35

Tablica 10: Tablica analize varijance regresijskog modela i tablica sažetka modela višestruke regresije 36

Tablica 11: Tablica koeficijenata varijabli u prvom modificiranom modelu cijena smještajnih kapaciteta 36

Tablica 12: Tabela analize varijance modificiranog regresijskog modela i tabela sažetka modela višestruke regresije 37

Tablica 13: Tablica koeficijenata varijabli u drugom modificiranom modelu cijena smještajnih kapaciteta 37

Tablica 14: Tabela analize varijance drugog modificiranog regresijskog modela i tabela sažetka modela višestruke regresije 38

Tablica 15: Usporedba očekivanih utjecaja varijabli i dobivenih rezultata 40

PRILOZI

Prilog 1: Popis korištenih varijabli i njihovih izvora

Varijabla	Izvor
Cijena noćenja	Booking.com
Veličina smještaja	Booking.com
Parkirno mjesto	Booking.com
Udaljenost od Dioklecijanove palače	Booking.com/ GoogleMaps
Udaljenost od plaže	Booking.com/ GoogleMaps
Wi-fi	Booking.com
Kabelska	Booking.com
Maksimalan broj osoba	Booking.com
Pogled na more	Booking.com
Klima uređaj	Booking.com
Sušilo za kosu	Booking.com
Prosječna recenzija	Booking.com
Doručak	Booking.com

Izvor: Izrada autorice

Prilog 2: Odobrenje booking.com-a za korištenje podataka sa njihove mrežne stranice

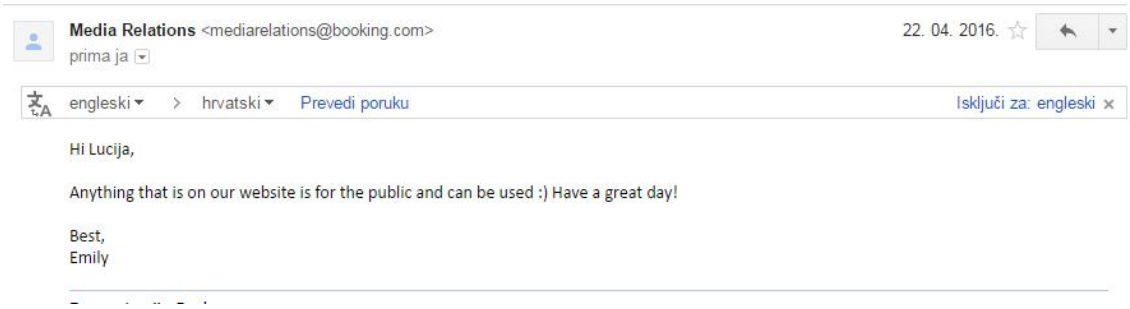
Media Relations <mediarelations@booking.com>
prima ja
22. 04. 2016.
engleski > hrvatski Prevedi poruku
Isključi za: engleski

Hi Lucija,

Anything that is on our website is for the public and can be used :) Have a great day!

Best,
Emily

Prilog 3: Primjer prikupljanja podataka sa stranice booking.com

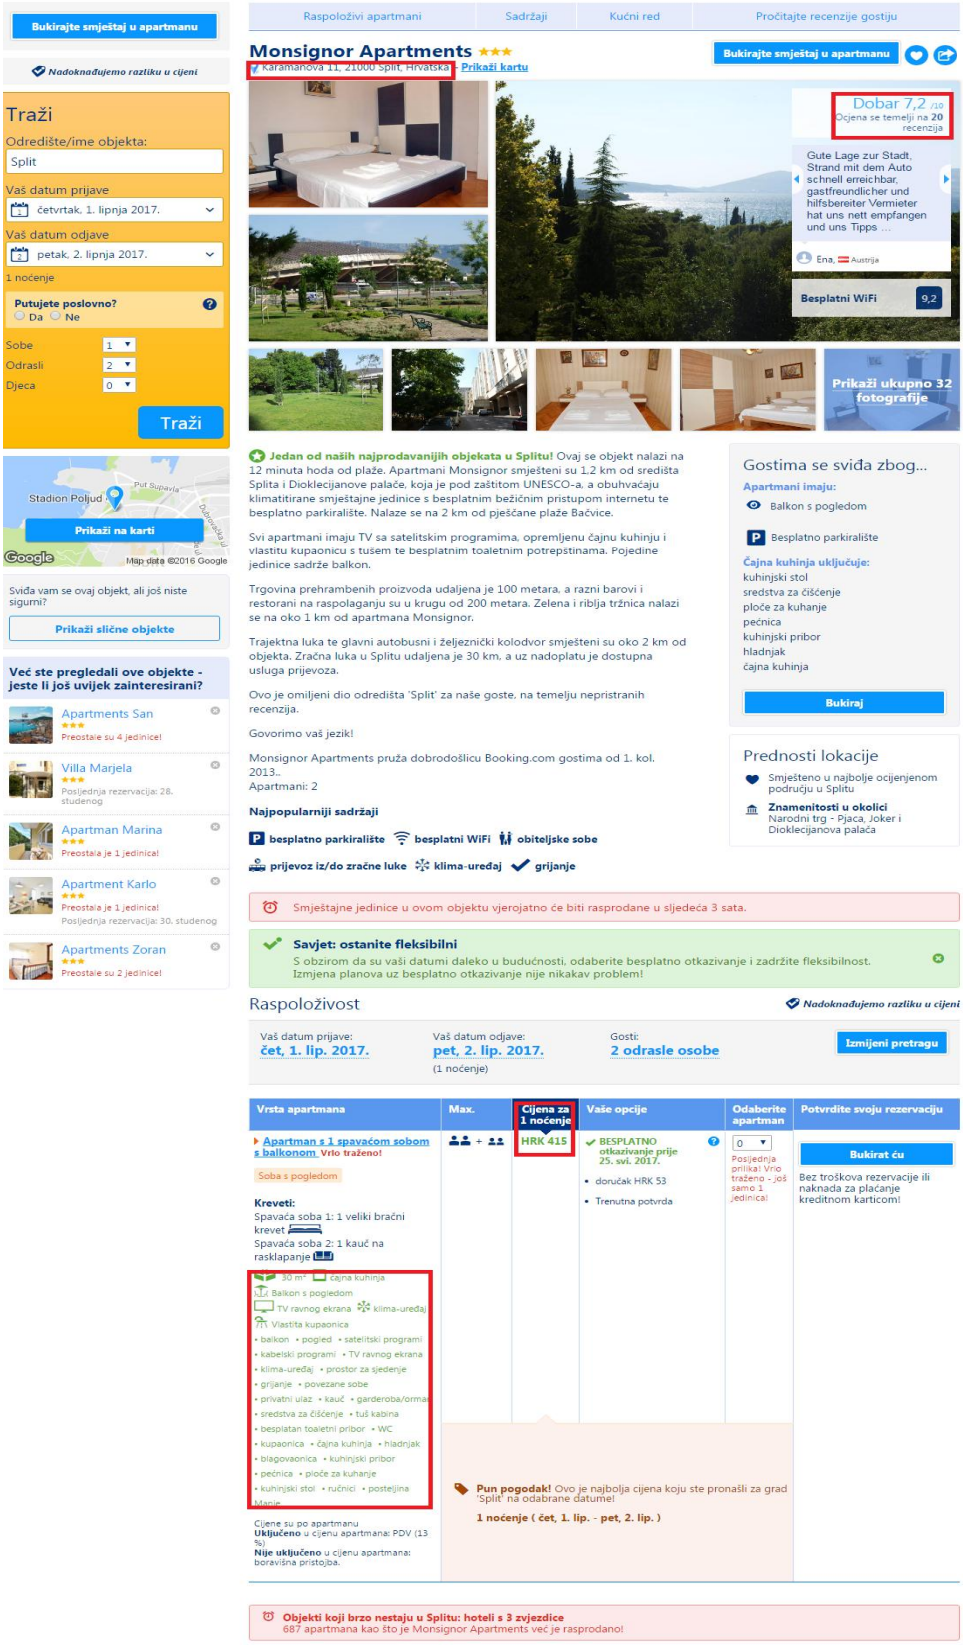

Izvor: booking.com

SAŽETAK

Cilj ovog rada bio je ispitati ima li lokacija utjecaja na cijene noćenja u Splitu. Rad je formiran koristeći se pretpostavkama hedoničke metode i oslanjajući se na prethodna slična istraživanja. Kao odlučujuća lokacija definirana je udaljenost od Dioklecijanove palače. Model je formiran s ukupno trinaest varijabli (jednom zavisnom i dvanaest nezavisnih). Inicijalni model pokazuje kako na cijenu, suprotno teorijskim pretpostavkama, najviše utječu prosječna recenzija i doručak uključen u cijenu. Od ukupno dvanaest regresorskih varijabli u inicijalnom modelu, samo dvije su se pokazale signifikantnima (*Prosječna recenzija* i *Doručak)*. Kako inicijalni model nije potvrdio predložene hipoteze, preispitana su i dva modificirana modela. Modificirani modeli potvrdili su prvotne rezultate, te se odbacuju obje hipoteze.

Ključne riječi: Hedonička metoda, lokacija, cijene noćenja, Split

SUMMARY

The aim of this paper was to investigate if location affects prices of overnight stay in Split. The paper is formed using hedonic pricing approach and former similar papers. Distance from Diocletians palace was used as a main location variable. Thirteen variables were included in the model (one dependent and twelve independent). The initial model demonstrated that only two out of twelve variables were significant. *Avarage rating* and *Breakfast*. Because the initial model did not confirm the theoretical assumptions, two modified models were tested. Results of modified models confirm initial results; and both hypotheses are rejected.

Keywords: Hedonic method, location, Split, price of overnight stay

.