PROFILIRANJE TURISTA TROGIRSKOG PODRUČJA POMOĆU METODA RUDARENJA PODATAKA

Žderić, Denis

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:124:433617

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

PROFILIRANJE TURISTA TROGIRSKOG PODRUČJA POMOĆU METODA RUDARENJA PODATAKA

Mentor : **Student :**

Dr. sc. Mario Jadrić **Denis Žderić**

Split, kolovoz, 2017.

SADRŽAJ

1. UVOD 3
1.1.Problem istraživanja 3
1.2.Predmet istraživanja 4
1.3.Istraživačke hipoteze 5
1.4.Ciljevi istraživanja 5
1.5.Metode istraživanja 6
1.6.Doprinos istraživanju 7
1.7.Struktura rada 8
2. ANALIZA TURIZMA NA TROGIRSKOM PODRUČJU 9
2.1. Definicije i pojmovi turizma 9
2.2. Analiza turizma u Hrvatskoj 12
2.3. Specifičnosti trogirskog područja 16
3.ODABRANE METODE RUDARENJA PODATAKA 18
3.1. Definicija rudarenja podataka 18
3.2. Metode rudarenja podataka 21
3.2.1. Klasteri 21
3.2.2. Stabla odlučivanja 23
3.2.3. Regresijska analiza 24
3.2.4. CN2 Pravila 25
4.VAŽNOST I ZNAČAJ PROFILIRANJA TURISTA 26
5. REZULTATI ISTRAŽIVANJA 31
5.1. Vizualizacija trendova i uzoraka 33
5.2. Demografski profil turista 41
5.3. Osvrt na hipoteze 44
SAŽETAK 47
SUMMARY 47
LITERATURA 48
POPIS SLIKA I GRAFIKONA 51

1. UVOD

1.1.Problem istraživanja

Turizam kao djelatnost je trenutno jedna od najvažnijih ekonomskih pokretača koje jedna zemlja ili regija može imati. Možemo ga opisati kao sve aktivnosti koje se obavljaju na području izvan našeg stalnog boravišnog mjesta. Prema Ministarstvu turizma(2010) turizam direktno i indirektno stvara 22% BDP-a , te preko 40% ukupnog izvoza što ga svrstava među najbitnije stavke nacionalne ekonomije i vanjsko-trgovinske razmjene. U smislu poslovnog okruženja turizam moramo promatrati mnogo šire zahvaljujući multiplikativnom efektu koji omogućuje svojim redovnim aktivnostima.

Prema UNWTO turizam kao industrija ima jednak ili veći obujam poslovanja od uvoza/izvoza nafte, proizvodnje hrane i automobilske industrije. Kao takav turizam je postao jedan od najvažnijih sudionika u međunarodnoj razmjeni i predstavlja najveći dio prihoda mnogih zemalja u razvoju. Hrvatska je turistički orijentirana zemlja sa stalnim turističkim rastom iz godine u godinu. Održavanje konstantnog rasta je jedini način ostvarivanja cjelokupne gospodarske koristi i oživljavanja stagnirajućeg tržišta. Hrvatska kao turistička zemlja posjetitelje privlači na temelju prirodnih bogatstava, ljepota i kulturne raznolikosti, a ne kvalitetnim i atraktivnim smještajnim jedinicama i uređenom infrastrukturom. Produljivanje turističke sezone, te nedostatna i siromašna infrastruktura ostaju jedan od gorećih problema na domaćem tržištu.

Pravilnim segmentiranjem tržišta dolazimo do konkretnih klasifikacijskih obilježja na temelju kojih možemo donositi važne strateške odluke.

U današnjem poslovnom okruženju informacija predstavlja glavni resurs za rast i napredak. Porastom važnosti koje informacije predstavljaju dolazimo do poslovne inteligencije, tj. poslovnog obavještavanja. Napretkom tehnologije poslovna inteligencija je poprimila mnogo oblika i načina na koji se manifestira ali je cilj ostao isti, prava informacija u pravo vrijeme.

1.2.Predmet istraživanja

U zadnja dva desetljeća hrvatskog turizma populacija koja posjećuje prostore Republike Hrvatske se u potpunosti izmijenila. Povećanjem općeg znanja, protoka informacija, te najviše zahvaljujući ubrzanoj informatizaciji i globalizaciji koja vlada u svijetu turisti su postali informiraniji i iskusniji. Kako je turizam relativno nova grana pred ostalim industrijama ne postoji veliki broj izvršenih istraživanja i analiza na području turizma kao što to prednjače područja ostalih djelatnosti. Iskorištavanje potencijala i stvaranje održive konkurentske prednosti na turističkom tržištu pridonosi stabilnosti gospodarstva u cjelini. Razumijevanje i identificiranje populacije turističkog tržišta stvara preduvjete za održivo poslovanje (Orellana,2011). Aktivnosti međunarodnog turizma su jednostavnije za izmjeriti zbog potrebe za prelaskom granice, evidentiranja gostiju i upotrebom mjenjačkih usluga. Ulaskom u EU i otvaranjem svojih granica gubimo takvu vrstu podataka, ali kroz druge izvore prikupljanja podataka poput rada turističkih zajednica i modernizacijom njihovog poslovanja nailazimo na potrebne podatke. Konstantna potreba za pretvaranjem podataka u znanje (Fayyad,1996), otvara mnogobrojne mogućnosti poduzećima iz svih industrija značajan napredak.

E-visitor kao novi informacijski sustav turističkih zajednica koji služi za prijavu i odjavu gostiju međusobno povezuje sve turističke zajednice u Hrvatskoj i na taj način omogućuje prikupljanje podataka na jednostavan i efikasan način. Na primjeru podataka TZ „Trogir“ vršiti će se istraživanja i prikazati rezultati kroz metode rudarenja podataka. Poslovno izvještavanje kao relativno mladi pojam u svijetu nailazi na ekspanziju svojih alata u zadnjem desetljeću, što može zahvaliti kvalitetnijem prikupljanju i analizi podataka u svrhu donošenja strateških odluka. Prema Hokey (2006) sva poduzeća bi trebala provoditi metode rudarenja podataka s ciljem provođenja efektivne CRM strategije.

Varijable koje ćemo koristiti u procesu istraživanja su demografske prirode. Segmentacijom navedenih varijabli usmjeravamo strateške odluke u određenom smjeru i pozicioniranju turističkih usluga prema individualnim korisnicima.

Metode rudarenja podataka su dio procesa unutar poslovnog obavještavanja koji je neizostavan dio svakog poduzeća okrenutog na maksimiziranje dobiti i zadovoljstva korisnika. (Dragičević, 2006).

1.3.Istraživačke hipoteze

Na temelju prethodno utvrđenih problema i predmeta istraživanja postavljaju se sljedeće istraživačke hipoteze :

H1…Metode rudarenja podataka omogućuju određivanje trendova i uzoraka na odabranom uzorku posjetitelja trogirskog područja

H2…Metode rudarenja podataka omogućuje određivanje demografskih osobina posjetitelja

Na temelju prikupljenih podataka i njihove analize donesene hipoteze će se prihvatiti ili odbaciti.

1.4.Ciljevi istraživanja

Cilj je u radu prikazati značaj koje metode rudarenja podataka imaju na konkretnom primjeru hrvatskog turizma. Profiliranjem domaćih i stranih posjetitelja nastoji se doći do jedinstvenog rješenja koji bi pomogao razvoju hrvatskog turizma i lakšem donošenju strateških odluka. Pomoću poslovne inteligencije i metoda rudarenja podataka prikupiti će se podaci iz različitih izvora, obraditi te potom analizirati uz metode kao što su klasteriranje, neuronske mreže,CN2 pravila, linearnih projekcija i dijagrama projekcije.

Ciljevi su :

- Teoretska obrada pojmova korištenih u istraživačkom radu
- Odrediti demografske osobine posjetitelja
- Odrediti moguće trendove i uzorke na odabranom uzorku posjetitelja
- Prikazati razlike u trendovima i obujmu poslovanja u 2014. i 2015. Godini
- Ponuditi primjerene zaključke i moguća rješenja navedenih problema

1.5.Metode istraživanja[1]

Metoda analize - postupak znanstvenog istraživanja putem raščlanjivanja složenih pojmova kao što su u našem slučaju baze podataka na jednostavne dijelove. Metoda analize i sinteze se preklapaju u svome djelovanju kroz cijeli rad. Na temelju skupnog uzorka posjetitelja nastojimo ga razlučiti na jednostavne dijelove prihvatljive i razumljive ljudskom umu

Metoda sinteze je postupak znanstvenog istraživanja i objašnjavanja stvarnosti putem spajanja jednostavnih misaonih tvorevina u složene, i složenijih u još složenije, povezujući izdvojene elemente, pojave, procese i odnose u jedinstvenu cjelinu u kojoj su njezini dijelovi uzajamno povezani

Metoda deskripcije - deskriptivnim pristupom će se istražiti i opisati situacije, stanja i procesi, uz pomoć tehnike promatranja kao glavnog načina prikupljanja podataka. Na jednostavan način se priopćava čitatelju misao i razmišljanje koje je pratilo autora kroz pisanje rada.

Induktivna metoda - sistematska i dosljedna primjena induktivnog zaključivanja gdje se na temelju analize pojedinih činjenica dolazi do općih zaključaka. Induktivna metoda se temelji na već utvrđenim i dokazanim činjenicama, te prema tome i vrijednost induktivnog zaključivanja ima veću težinu dokaza

[1] Zelenika, R. : Znanost o znanosti, Ekonomski fakultet u Rijeci, 2004

Deduktivna metoda - sustavna i dosljedna primjena deduktivnog načina zaključivanja u kojem se iz općih zaključaka izvode posebni i pojedinačni zaključci. Pomoću deduktivne metode izvodimo vlastite zaključke na temelju našeg viđenja, kretanja u turizmu i proučenih materijala. Izvedene hipoteze se dokazuju zaključcima kroz deduktivnu metodu.

Statistička metoda - Rezultati statistika, grafikoni, tablice i sl. u radu će se koristiti za analizu pojava, otkrivanje karakteristika, strukture i zakonitosti pojava u okruženju. Također, pomoću ove metode će biti moguće uočiti uzročno-posljedične veze između ispitivanih pojava

Metoda komparacije - postupak uspoređivanja istih ili srodnih činjenica, pojava, procesa i odnosa, odnosno utvrđivanje njihove sličnosti i razlike u njihovu ponašanju i intenzitetu. Navedena metoda je izrazito korisna u uspoređivanju vlastitih mišljenja sa drugim stručnjacima koji se bave sličnom problematikom. Uvidom u tuđe stavove dolazimo do raznih spoznaja koji se ne moraju slagati sa našim vlastitim rezultatima, ali ih kao takve također koristimo u svrhu samokritike

Metoda kompilacije – postupak preuzimanja tuđih stavova, zaključaka, spoznaja i rezultata znanstvenog istraživanja. Citiranjem drugih stručnjaka iz područja turizma, poslovne inteligencije i srodnih područja potkrepljujemo vlastita mišljenja i nailazimo na neslaganja u mišljenjima koja su kao takva prijeko potrebna u daljnjem razvoju

1.6.Doprinos istraživanju

Rezultati navedenog istraživanja bi trebali pridonijeti razumijevanju važnosti informatizacije i pojmova kao što su poslovna inteligencija/poslovno obavještavanje. Analizom svoje okoline i prihvaćanjem da se nalazimo u brzo promjenjivom okruženju popraćeno konstantnim razvojem tehnologije shvaćamo kako trebamo pratiti taj trend i koristiti sve mogućnosti koje nam se nude. Hrvatska kao zemlja koja se uvijek nalazi u vrhu turističkih zemalja mora ulagati u istraživanja koje će pridonijeti njenom daljnjem razvoju ili pak održavanju istoga Težnja za konkurentskom prednošću i poboljšanjem vlastite ponude je od izrazitog interesa svim korisnicima turističkih usluga.

U prvom redu rezultati rada pridonose razvoju lokalnog područja na kojem se istraživanje provodi. Lokalni iznajmljivači, hotelijeri, te svi direktno i indirektno zaposleni u turizmu će na vlastitom primjeru moći proširiti svijest o mogućnostima koje nam nove tehnologije nude. Doprinos istraživanja se ogleda u nastojanju razvoja turizma u pravom smjeru i dokazivanjem da metode rudarenja podataka pozitivno utječu na poslovno okruženje nebitno u kojoj se industriji provodi. Profiliranjem posjetitelja i otkrivanjem mogućih trendova i uzoraka omogućuje detaljne pripreme i individualni pristup svakom posjetitelju i prije nego što ostvari svoj posjet. Iskazane doprinose pokušavamo dokazati kroz postavljene hipoteze u radu.

1.7.Struktura rada

Rad je podijeljen u pet tematskih cjelina. U uvodnom dijelu rada obrađuje se problem istraživanja, predmet istraživanja, istraživačke hipoteze, ciljevi, metode i doprinos istraživanja. Druga cjelina obuhvaća teorijski pristup predmetu istraživanja, analiza turizma u Hrvatskoj u posljednjih deset godina potkrijepljeno sa numeričkim podacima, i kumulativnim pokazateljima, te specifičnostima trogirskom područja.

Treći odlomak sluzi za opisni dio metoda rudarenja podataka, tj. pobliže upoznavanje za lakše razumijevanje budućeg teksta. Upoznavanje sa metodama kojima ćemo se koristiti za obradu podataka.

Četvrti odlomak objašnjava zašto je ova tema značajna u poslovanju i efektivnom poslovanju budućih naraštaja.

Peti odlomak pobliže objašnjava rezultate dobivenih istraživanja. Potvrđivanje ili odbacivanje navedenih hipoteza, i konačnu diskusiju o rezultatima.

2. ANALIZA TURIZMA NA TROGIRSKOM PODRUČJU

2.1. Definicije i pojmovi turizma

Turizam se pojavio tek u 20. Stoljeću i prema tome ne postoji veliki broj znanstvenih istraživanja i analiza koje bi pridavale veliku važnost turizmu. Turizam možemo definirati na razne načine, ali opće prihvaćena definicija bi bila sve aktivnosti koje neka osoba provodi prilikom putovanja i noćenja na području drugačijem od uobičajenog prebivališta. Predložena definicija prema Čavleku (2011) objašnjava turizam kao privremeno kretanje u određenu destinaciju izvan uobičajenog mjesta stalnog boravka i rada koje uključuje aktivnosti za vrijeme boravka u destinaciji i usluge kojima se zadovoljavaju potrebe turista. Turizam je činjenica koju generiraju potrebe svakog čovjeka. (Dulčić,1991) Obuhvaća sve one koje putuju, kao i one koje primaju putnike. S jedne strane turizam predstavlja zadovoljstvo dok s druge strane označava ekonomsku dobit. Turizam možemo pronaći u različitim oblicima, te ga prema tome možemo podijeliti na turizam u svrhu odmora, kulture, društvenih interesa, posla ili jednostavno zabave. Prema korisnicima turističkih aktivnosti možemo ih podijeliti na mlade, odrasle, obitelji, parove, prijatelje, itd. Bez obzira na raznorazne podjele na koje možemo naići prilikom istraživanja turizma zaključak je uvijek isti, turizam se promiče kao jedan od glavnih uzroka razvoja određenih regija u vidu otvaranja novih radnih mjesta, jačanja domaće valute i izgradnje prometne te smještajne infrastrukture. Uzročno-posljedičnim vezama se lako može zaključiti kako se razvojem turizma razvija cjelokupno društvo koje je direktno i indirektno zahvaćeno njegovim aktivnostima.

Radnja potrošnje je osnova svih ekonomskih aspekata i funkcija turizma. Akt potrošnje turista i veličina te potrošnje jedina je poveznica između turizma i gospodarstva. Akt potrošnje nužno izaziva akt proizvodnje na jednoj strani te raspodjele i razmjene na drugoj strani.[2]

[2] Antunac I. : Turizam : Teorijsko znanstvene rasprave, Institut za turizam, Zagreb (2001), str. 93

Prema Čavleku i dr. (2011) da bi se neka osoba definirala kao turist mora zadovoljiti nekoliko kriterija :

a) prostorna komponenta : svako kretanje izvan uobičajene sredine navedene osobe

b) obilježja putovanja : glavno obilježje svakog putovanja je dvosmjernost puta, prema kojem turist ne ide na put s ciljem boravišta i privređivanja

c) vremenska komponenta : putnik se smatra turistom ukoliko boravi izvan svoje uobičajene sredine dulje od 24 sata

d) svrha putovanja : svako putovanje koje nije prouzročeno redovnim načinom života

Turist je svaka osoba neovisno o rasi, dobi, nacionalnosti i spolu koja boravi na nekom mjestu izvan svoga uobičajenog mjesta prebivališta duže od 24 sata i manje od šest mjeseci. Turizam je aktivnost koja motivira osobe da zadovolje svoje želje i potrebe. Najčešće ga klasificiramo prema aktivnosti koja se događa prilikom putovanja.

Prema Antunac (2001) turiste smatramo :

- Osobe koje putuju radi zabave, obiteljskih i zdravstvenih razloga, te slično
- Osobe koje putuju na skupštine ili sastanke bilo koje vrste (diplomatske, religiozne, sportske)
- Osobe na poslovnim putovanjima
- Osobe na kružnim putovanjima brodom
- Studente i mlade u školama van svog prebivališta

Ne smatraju se turistima :

- Osobe koje dolaze u jedno mjesto s ciljem preuzimanja određenog posla ili namjere bilo kakvog privređivanja
- Osobe koje dolaze s namjerom da tu ostvare stalni boravak
- Stanovnici pograničnih područja koji imaju prebivalište u jednoj državi a zaposlenje u drugoj
- Putnici u tranzitu bez zaustavljanja kroz jednu zemlju

Turizam je značajan faktor za socio-ekonomski i kulturni razvoj jedne države, uzimajući u obzir raznovrsne aktivnosti koje se generiraju kroz turizam. Kao sredstvo socijalne razmjene turizam efektivno razvija društvo, uči ga da prihvaća i razumije drugačije navike i kulture , te stvara pozitivna razmišljanja o drugim narodima. Kao instrument razvoja koji utječe na ekonomsku ekspanziju i generiranje vanjske razmjene turizam direktno povećava raznovrsnost tržišta i otvara radna mjesta sukladno novim potrebama. Mjerenje utjecaja turizma važno je za državne i gospodarske sektore. Postoje brojni sudionici koji imaju interes u razvijanju partnerskih odnosa radi unapređenja turizma. (Lickorish & Jenkins, 2006)

Doprinos turizma gospodarskom razvoju nekog područja očituje se u njegovu utjecaju na investicije, dohodak ili zaposlenost, uzrokujući njihov porast a samim tim i porast životnog standarda pojedinca i njegove zajednice u kojoj se nalazi. Turizam utječe i na rast platne bilance te razvoj nedovoljno razvijenih regija. Turizmu se pripisuje multiplikativna, akceleratorska i konverzijska funkcija, ali i mnoge druge kao što su funkcija zapošljavanja, poticanja međunarodne razmjene, itd. (Petrić, 2013)

Bit multiplikativne funkcije turizma kao značajne ekonomske funkcije turizma leži u činjenici da prelijevanje BDP-a jednog područja kroz turističku potrošnju, pokreće i stimulira nove gospodarske procese različitih grana, dok sva ova kretanja kroz nacionalnu i međunarodnu turističku potrošnju generiraju novu akceleratorsku funkciju turizma kroz ubrzanje gospodarskog rasta i opći društveni prosperitet. Konverzijska funkcija turizma omogućuje da se dobra koja inače nemaju svojstva dobara kao što su prirodna i društvena baština uključe u proces razmjene. (Geić, 2007)

Turizam isto tako mnogo pridonosi razvoju objektivne kulture. Omogućujući upoznavanje objektivnih i doživljavanje idealnih vrijednosti sadržanih u kulturnim dobrima turizam kod mnogih ljudi pobuđuje želju za stvaranjem dublje povezanosti i stjecanje saznanja o pojedinim kulturnim područjima. (Alfier, 1994) Umjetnost, kultura i povijest važni su motivi za putovanja mnogih turista koji posjećuju turističke destinacije i predstavljaju promotivnu snagu mnogih područja. Ono što jednu destinaciju čini drugačijom od drugih je njena kulturna baština. (Blažević, 2007) Međuzavisnost turizma i i kulture se pojavljuje od prve pojave turizma. Korelaciju između turizma i kulture susrećemo neovisno o tome da li promatramo pojam kulture izdvojeno ili u svezi s turizmom. (Geić, 2007)

Termin koji se često javlja prilikom istraživanja turizma i njegovih aktivnosti je sezonalost u turizmu. Sezonalnost je prepoznata kao jedna od najvažnijih značajki turizma, koja se definira kao povremena neravnoteža na tržištu prema broju posjetitelja, potrošnje, prometa i raznih drugih karakteristika. (Baum & Lundtorp,2001) Sezonalnost se javlja kao veliki problem na svim tržištima gdje se javlja težnja za konstantnim produživanjem turizma izvan okvira redovne sezone. Ne postoji znanstveni pristup koji bi na najbolji mogući način objasnio sezonalnost. Turizam je nastao kao sezonska pojava, te se još uvijek definira kao takav, uza sva nastojanja i mjere koje se poduzimaju radi ravnomjernije vremenske distribucije turističkog prometa. (Alfier, 1994)

2.2. Analiza turizma u Hrvatskoj

Hrvatska se sastoji od dvije regije potpuno različite po njihovim karakteristikama geografski i kulturološki. Kontinentalni sjeverni dio pripada srednjoj Europi dok južni priobalni dio pripada Mediteranu. Kombinacijom i spajanjem karakteristika Mediteranskog i kontinentalnog dolazimo do finalnog outputa kojeg možemo nazvati hrvatski turizam. Povoljan geografski položaj i prirodne ljepote su omogućile da se turizam u Hrvatskoj prakticira skoro 200 godina, dok se masovni turizam kakvog danas poznajemo počeo pojavljivati početkom 60-ih godina prošlog stoljeća. Ugodna klima i razvijena Jadranska obala su glavni razlozi što se turizam održao i u stalnom rastu tijekom svih ovih godina.

Turistička zajednica kao osnovna organizacijska forma kojoj je svrha promicanje, rast i napredak gospodarskih interesa osnovana je 1994. godine odlukom Hrvatskog sabora. (Geić,2007). Osnivaju se na lokalnoj, regionalnoj i državnoj razini uz iznimku potrebe za osnivanjem na području od posebnog interesa.

Glavne zadaće turističke zajednice su[3] :

Poticanje i unapređivanje izvornih vrijednosti - narodni običaji te tradicija koji pripadaju određenom kraju i njihova implementacija u sustav vrijednosti

Suradnja i koordinacija s pravnim i fizičkim osobama koji su uključeni u turističku razmjenu radi usuglašavanja zajedničke provedbe politike razvoja turizma

Poticanje, koordinacija i organiziranje kulturnih, umjetničkih, gospodarskih, sportskih i drugih događaja - organiziranje javnih događaja pridonosi obogaćivanju turističke ponude mjesta, općine i ostalih zajednica

Poticanje zaštite, održavanja i obnove kulturno povijesnih spomenika - uključivanje kulturnih dobara od interesa u turističku ponudu

Izrada programa i planova promocije - razvoj i promidžba turizma prema opće prihvaćenim smjernicama razvoja na razini Republike Hrvatske

Vođenje jedinstvenog popisa turista na određenom području - provedba nadzora radi prikupljanja statističkih podataka i kontrole plaćanja boravišne pristojbe

Izrada izvješća - opravdanost izvršenja postavljenih ciljeva, utvrđivanje sadašnjeg stanja programa rada i financijskog plana turističke zajednice

Turističke zajednice spadaju pod Ministarstvo turizma koje je krovna organizacija i službeni organ zadužen za provođenje turističke organizacije i planova od gospodarskog interesa.
Organizacija je jedno od najvažnijih sredstava (Alfier, 1990) svake turističke politike, djelotvornost i stupanj razvijenosti turističke politike pokazatelj su opće turističke razvijenosti neke zemlje.

[3] Geić, S. : Organizacija i politika turizma, Sveučilište u Splitu, 2007

Turizam kao djelatnost na prostorima Republike Hrvatske je doživio najveću ekspanziju 80-ih godina prošlog stoljeća koja je naglo prekinuta posljedicama rata i post-ratnog razdoblja na našim područjima.

Osnovni pokazatelji razvoja turizma

	1980.	1985.	1990.	1995.	2000.	2005.	2010.	2015.
Broj postelja (u 000)	692	820	863	609	710	909	910	1.029
Broj turista (u 000)	7.929	10.125	8.498	2.438	7.136	9.995	10.604	14.343
Broj noćenja (u 000)	53.600	67.665	52.523	12.885	39.183	51.421	56.416	71.605
Prosječni broj noćenja po postelji	77	83	61	21	55	57	62	70
Prosječni broj noćenja po dolasku turista	6,8	6,7	6,2	5,3	5,5	5,1	5,3	5,0

Slika 1. Pokazatelji razvoja turizma

Izvor : www.htz.hr Analiza sezonalnosti turističkog prometa

Prikazano kretanje broja turističkih dolazaka i noćenja na području Republike Hrvatske pokazuje stalnu tendenciju prema rastu i napredovanju u segmentima turizma i turističke potrošnje. Ulaganje u infrastrukturu i kvalitetu domaće ponude će još više poboljšati buduće stanje te privući nove potencijalne potrošače.

Dodatnim raščlanjivanjem analize dolazimo do gorućeg problema hrvatskog turizma, pojma sezonalnosti. Domaće tržište je podložno utjecajima sezonalnosti gdje većina turista dolazi u određenom vremenskom roku „sezoni“ dok ostala vremenska razdoblja u drastično smanjenim količinama sadržavaju turističke aktivnosti.

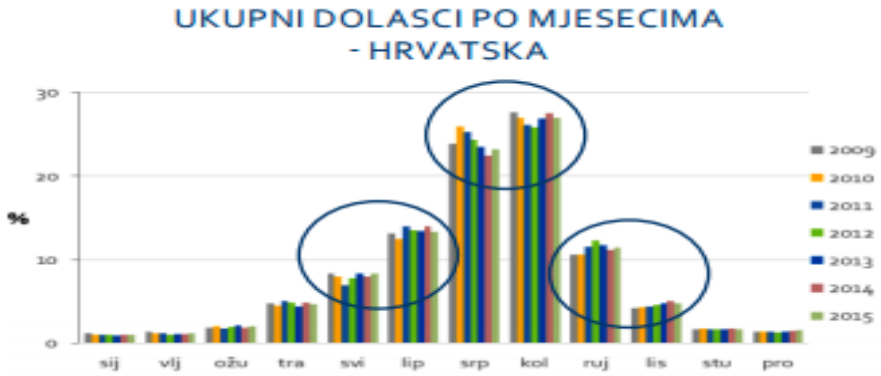

Slika 2. Ukupni dolasci po mjesecima

Izvor : www.htz.hr Analiza sezonalnosti turističkog prometa

Borba protiv sezonalnosti obuhvaća dodatno povećanje gospodarskog razvitka, turistički valorizirati tradicionalne čimbenike koji daju konkurentsku prednost komponirajući kroz izradu dugoročnih planova namijenjenim regionalnom razvoju.

Za proučavanje turizma povijest je poučna, ne samo zbog informacija o događajima iz prošlosti već prvenstveno zato što se u prošlim događajima krije uspjeh budućeg razvoja. (Lickorish & Jenkins, 2001)

Vukonić (2005) smatra dvojbenim cijelu hrvatsku povijest turizma odrediti prema ratova pa sukladno tome predlaže sljedeću raspodjelu :

Prva faza : razdoblje preteča turističkog razvoja ili pojava sličnih turizmu

Druga faza : kraj 19. stoljeća

- Pojava prvih ugostiteljskih i smještajnih objekata
- Početak prvih turističkih mjesta
- Dolazak stranih investicija i kapitala

Treća faza : razdoblje od početka 20. stoljeć do kraja Prvog svjetskog rata obilježavaju uzurbana politička zbivanja, te unatoč njima se razvijaju prvi turistički centri na područjima Hvara, Crikvenice, Opatije itd.

Četvrta faza : razdoblje između dva rata je obilježilo rast turističkog prometa na prostorima Republike Hrvatske . Otvaranje novih smještajnih kapaciteta i razvoj infrastrukture je pridonijelo dodatnom priljevu inozemnih turista i stranog kapitala.

Peta faza : Razdoblje nakon Drugog svjetskog rata do 1991. godine obilježava intenzivan razvoj turizma u Hrvatskoj. Navedeno razdoblje se može podijeliti u dvije etape. Kod prve etape razvoja, nakon obnavljanja porušene zemlje iza rata, turizam pada u drugi plan zbog promjene načina upravljanja gospodarstvom i poticanja razvoja poljoprivrede i industrijalizacije. Druga etapa počinje od 1965. godine nakon provođenja privredne reforme i obilježava je intenzivan razvoj turizma na područjima Republike Hrvatske.

Šesta faza : obilježava razdoblje od samostalnosti Republike Hrvatske do kraja 20. stoljeća. Glavne karakteristike toga razdoblja su restrukturiranje i privatizacija turističkog sektora. Cijeli proces su pratile afere koje su dodatno usporile razvoj domaćeg tržišta nakon burnog ratnog razdoblja. (Čavlek i dr., 2011)

2.3. Specifičnosti trogirskog područja

Grad Trogir zauzima površinu od 39,10 km2 i čini 0,86% ukupne površine županije. U Gradu Trogiru prema popisima iz 2001. godine živi 12.995 stanovnika, što predstavlja 0,79% stanovništva županije. Prosječna gustoća naseljenosti 2001. godine iznosila je oko 322,35 stanovnika na km2 , što je znatno više od državnog prosjeka (78 st/km2) te prosjeka županije (102,1 st/km2).[4]

Grad Trogir je povijesni grad i luka na Jadranskoj obali koji se nalazi u srednjoj Dalmaciji sa procijenjenim stanovništvom od deset tisuća stanovnika, dok se sa okolnim mjestima procjenjuje na trinaest tisuća stanovnika. Područje grada Trogira se nalazi između općine Rogoznica, grada Šibenika, općine Kaštelanska zagora na sjeveru, grada Kaštela na istoku te otočnom skupinom Šolta na jugu, dok se sama općina sastoji od osam naselja : Arbanija, Divulje, Drvenik Mali, Drvenik Veliki, Mastrinka, Plano, Trogir i Žedno. [5]

Glavno obilježje po kojem je trogirsko područje poznato je povijesna jezgra grada Trogira koja je uključena na UNESCO listu zaštićenih područja 1997. godine. Spomenuto područje predstavlja jedno od najbolje očuvanih primjera antičke romanske kulture izvan granica Italije. Povećanjem popularnosti i stalnim priljevom novih posjetitelja, turizam je postao najvažniji ekonomski faktor trogirskog područja. Svojim većim dijelom smješten je na malenom otoku. Jednim pješačkim i jednim većim kamenim mostom za vozila spojen je s kopnom, i kamenim mostom s otokom Čiovo. Trogir je jedinstveni primjer odlično očuvanog romaničkog otočnog grada. Trogir su osnovali grčki kolonisti s otoka Visa u 3. stoljeću prije Krista. Oktogonalni plan ulica datira iz doba stare Grčke i vidljiva je razlika u odnosu na

[4] http://www.trogir.hr/GradTrogir/images/stories/Statuti_grbovi_zakoni/Analiza_situacije_Trogir.pdf
[5] www.trogir.hr

rimske gradove.[6] Prepoznatljive znamenitosti su Katedrala Sv. Lovre sa portalom majstora Radovana, neprocijenjivom zbirkom Kapele Sv. Ivana Trogirskoga te jedinstvenim gotičkim kampanelom. Na obalnom dijelu sačuvao se veći dio obrambenih zidina, u kojima se u 13. stoljeću formirala stara gradska jezgra Traguriuma, dok se na rubu zidina nalazi tvrđava Kamerlengo i Kula Sv. Marka. S morske strane se ulazi u grad Trogir kroz Južna Gradska vrata, ogromna drvena vrata, ojačana čavlima, koja su ostala sačuvana od 1593 godine, dok je sa sjeverne strane ulaz kroz Renesansna Gradska vrata iznad kojih Trogir čuva Sv. Ivan Trogirski, zaštitnik grada. Na glavnom gradskom trgu, nasuprot katedrale stoji zavjetna Crkva Sv. Sebastijana, podignuta polovicom 15. st. u zahvalu za spas grada od kuge. Umjesto zvonika ima zadivljujući Toranj Gradskog Sata. Gradska Loža, odmah pored zavjetne crkve nekada je bila javni objekt, sklonište, okupljalište, a i sudnica. Bogati reljefi su djela Nikole Firentinca i Ivana Meštrovića. Velika i mala Palača Ćipiko sklop su zgrada (palača) koje je podigla istaknuta trogirska obitelj Čipiko. Na pročelju velike palače gotička je trifora, djelo Andrije Alešija, vrata je isklesao Ivan Duknović, a južni portal djelo je Nikole Firentinca.
Knežev Dvor, danas Gradska vijećnica spominje se u 13. st., a njegova obnova tijekom 19. stoljeća vratila mu je renesansni izgled i šarm.[7]

Kao glavni subjekti gospodarskog razvitka do sada su se isticali sljedeći sektori:
1. brodogradnja
2. turizam

Brodogradnja ima značajnu ulogu u razvitku ovog grada s obzirom da zapošljava 1.254 djelatnika i radi tijekom cijele godine. Turizam i ugostiteljstvo također imaju značajnu ulogu u gospodarstvu Grada Trogira no s obzirom na sezonski karakter i trajanje sezone od svega četiri mjeseca potrebno je poraditi na obogaćivanju ponude i produljenju sezone. Turizam je najveća industrija na trogirskom području, sa udjelom od oko 50% proračuna s više od 20.000 kreveta u hotelima i privatnim apartmanima. Ipak, postoji vrlo mnogo ljudi koji se bave ribarstvom i poljoprivredom što je tradicija među stanovništvom u okolnim područjima.[8]

[6] http://www.topdestinacije.hr/destinacija/srednja-dalmacija-trogir-31
[7] http://www.portal-trogir.com/hrvatska/trogir-rivijera/trogir/
[8] http://www.trogironline.com/hr/trogir.html

3.ODABRANE METODE RUDARENJA PODATAKA

3.1. Definicija rudarenja podataka

Rudarenje podataka je metoda koja se koristiti za analiziranje i dobivanje informacija iz velikih količina podataka. Upotreba informacijskih tehnologija je potrebna kako bi analizirali mnogobrojne podatke koji sadržavaju informacije i obrasce ponašanja značajne u procesu otkrivanja veza između različitih subjekata. Rudarenje podataka se primjenjuje u mnogim granama kao što su prodaja, marketing, medicina, biologija, bankarstvo, procjena rizika, meteorologija itd. (Akcetin, E., 2015)

Najvažnija značajka koja pridonosi poboljšanju poslovanja upotrebom rudarenja podataka je analiza potrošača, grupiranje i izrada profila kupaca. Pozicioniranjem proizvoda i usluga na pravom mjestu i u pravo vrijeme maksimiziramo profitabilnost i stvaramo kvalitetnu mrežu potrošača. Identificiranje obrazaca kupovine, utvrđivanje povezanosti između demografskih osobina, karakteristika kupaca i poznavanje svih detalja koji vode do kupovine dovodi do stvaranja kvalitetne mreže potrošača. Rudarenje podataka je termin koji se koristi za proces istraživanja velikih baza podataka i pronalaženja obrazaca ponašanja koji se mogu iskoristiti kao konkurentska prednost na tržištu. (Panian i suradnici, 2003)

Povećanom informatizacijom i uporabom baza podataka omogućava se svim zainteresiranim sudionicima pristup neograničenim resursima koji se mogu proučavati i analizirati u svrhu novim spoznaja, optimizacije poslovanja i pronalaska novim obrazaca ponašanja. Kako bi na najbolji način iskoristili podatke iz baza, istraživači imaju standardizirane algoritme koji su proizašli iz statistike, umjetne inteligencije i neuronskih mreža. Izgradnja sistema koji se mogu prilagoditi svojem okruženju i učiti iz svojih prošlih iskustava je privukla istraživače iz svih područja kao što su informatika , matematika, statistika, inženjerstvo, fizika, itd. Kombinacijom rezultata koje su proizvele sve ove grane danas imamo raznovrsnu lepezu metoda koje možemo koristiti prilikom istraživanja podatka. (Hand & Manila, 2001)

Rudarenje podataka je moguće sagledati kroz različite metodologije. Najzastupljenija metodologija koja se dana koristi je CRISP (Cross Industry Standard Process for data mining) . CRISP je nastao kao potreba za standardizacijom procesa rudarenja podataka. (M. Ćukušić /Garača & Jadrić, 2011)

CRISP metodologija se sastoji od šest sljedećih faza [9]:

1. Razumijevanje problema obuhvaća određivanje ciljeva istraživanja, procjenu trenutne situacije i razvoj plana projekta. Rudarenje podataka se često predstavlja kao tehnički problem pronalaženja modela koji objašnjavaju odnos ciljne varijable i grupe ulaznih varijabli.

2. Razumijevanje podataka uključuje početno prikupljanje podataka , opis, istraživanje i provjeru kvalitete podataka. Prikupljeni podaci se razlikuju ovisno o vrsti industrije i cilja istraživanja.

3.Priprema podataka se odvija nakon što su prikpljeni svi dostupni podaci. Podaci se moraju sortirati, pročistiti te transformirati u oblik prilagođen za daljnju uporabu. Podaci se obrađuju ovisno i o metodi koja će se primjenjivati na njima.

4. Modeliranje ovisi od o tehnici koja će se koristiti u procesu rudarenja. Kako proces napreduje, a podatke upoznajemo bolje moguće je s vremenom razviti bolji model za testiranje podataka

5. Evolucija modela se vrednuje prema postavljenim ciljevima. Boljim upoznavanjem podataka možemo identificirati nove potrebe, te se vratiti na početnu fazu s ciljem testiranja novih potreba

6. Razvijanje modela se koristi kako bi se potvrdile ili odbacile postavljene hipoteze. Kroz model je moguće doći do novih znanja, prediktivnih podataka i upotrijebiti stečeno znanje za izgradnju korisnih modela.

[9] Garača, Ž. & Jadrić, M. ; Rudarenje podataka - Različiti aspekti informacijskog društva, Sveučilište u Splitu , 2011

Kako bi rudarenje podataka bilo moguće moraju postojati razvijene baze podataka. Sustavnom informatizacijom i sve većom potrebom nastaju skladišta podataka (eng. Data warehouse) koja služe za prikupljanje i pročišćavanje podataka kako bi bili spremni za daljnju uporabu. (Fayyad, 1996) . Današnja informacijska tehnologija omogućila nam je bilježenje svake aktivnosti u obliku digitalnih podataka, a količina sakupljenih podataka u mnogim bazama mjeri se u gigabajtima ili terabajtima. Ogromne baze podataka bogate su podacima, ali siromašne informacijama koje su skrivene u pohranjenim podacima. Upravo je rudarenje podataka to koje pomaže otkriti važne informacije i znanje utkano u podatke, uvelike pridonoseći donošenju odluka, poslovanju i znanosti.[10]

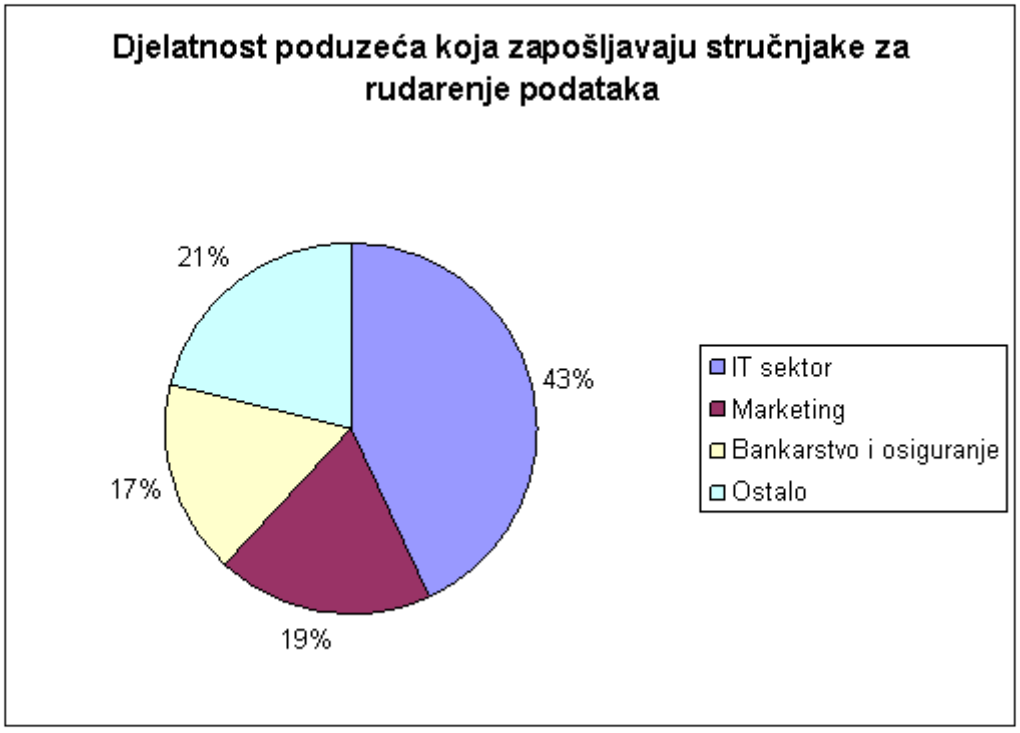

Slika 3. Djelatnosti koje zapošljavaju stručnjake za rudarenje podataka

Izvor : http://www.skladistenje.com/profil-strucnjaka/

[10] http://www.skladistenje.com/profil-strucnjaka/

Rudarenje podataka ima važnu ulogu u donošenju poslovnih odluka . Njegovo značenje se očituje u sljedećem (Javorovic & Bilandzic, 2007) :

- Omogućuje pristup podacima
- Jača sposobnosti poslovnog subjekta u pogledu razumijevanja rezultata
- Povećava stupanj znanja poslovnog subjekta
- Omogućuje definiranje i poduzimanje poslovnih akcija

3.2. Metode rudarenja podataka

Finalni rezultat korištenja rudarenja podataka je informacija. Kako bi se došlo do određenih zaključaka koristimo metode rudarenja podataka koje iz velikih baza podataka dolaze do relevantnih zaključaka. Pojavom „big data“ rudarenje podataka je doživilo veliki napredak u korištenju naprednijih metoda koje su više prilagođene data setovima sa velikim brojem podataka. Proces rudarenja podataka nije samo ograničen na komplekse baze podataka, prema tome rudarenja podataka ne ovisi o metodama i softverima koje koristimo u samom procesu. Glavni je cilj rudarenja podataka otkrivanje karakterističnih obrazaca i algoritama u već postojećim podacima, zahvaćenima obavljanjem rutinskih poslovnih aktivnosti, koji se mogu koristiti za predviđanje budućih događaja, procesa i rezultata upravo poduzimanih aktivnosti (Panian, 2003). Metode koje se koriste u tom procesu su metode kao što je regresija, segmentacija, klasteriranje, usporedno ocjenjivanje i predviđanje. Korištenjem različitih metoda iste podatke možemo analizirati pomoću različitih algoritama te na taj način sagledati rezultate iz drugačijih perspektiva. (M.Lenkić /Garača & Jadrić, 2011) Metodama rudarenja podataka možemo precizno segmentirati tržište, pronaći profil našeg kupca, njegove navike i potrebe. (Klepac & Mršić, 2006)

3.2.1. Klasteri

Klasteri ili metoda klasteriranja je grupiranje podataka prema karakteristikama ili sličnim osobinama podataka koji se testiraju. Klasteriranje je naišlo na široku upotrebu u današnjem svijetu zbog svoje jednostavnosti i praktične primjene. Najčešća upotreba metode klasteriranja

je segmentacija tržišta prema kupcima sličnih osobina kako bi se maksimiziralo pozicioniranje proizvoda na tržištu. U kontekstu rudarenja podataka klaster možemo prikazati kao skupinu atributa koji sadrže slične vrijednosti. (Klepac & Mršić, 2006) Metoda klasteriranja se koristi pri istraživanju različitih područja , no u poslovnom svijetu to je najčešće u svrhu početne segmentacije tržišta. Kao nedostatak klastera se može navesti jednostavnost prilikom provođenja analize podataka i mogućnost odstupajući varijabli koje dodatno imaju utjecaj na rezultat klasteriranja. (M.Lenkič/ Garača & Jadrić, 2011)

Primjer klasteriranja : Procesom klasteriranja grupirali smo najsličnije podatke u pet klastera na temelju kojih ćemo prikazati distribuciju klastera prema rasi.

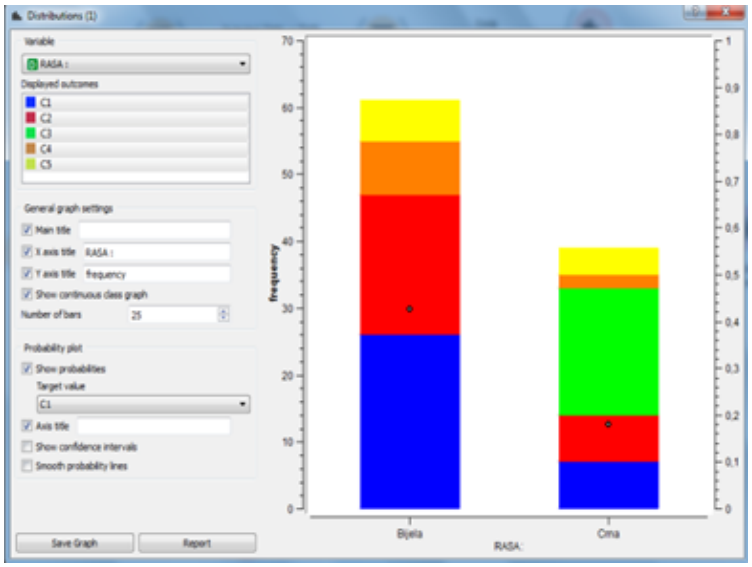

Slika 4. Izrada autora - primjer klastera

U primjeni su tri različite metode klasteriranja :

K- mean - najčešće korištena metoda klasteriranja primjenjuje se za procesuiranje velikih baza podataka gdje je brzina obrade jedan od bitnijih faktora za odabir metode. Broj klastera se definira unaprijed ograničavajući karakteristike podataka u zadani okvir rezultata. Osnovna značajka se svodi na dijeljenje osnovne populacije na k segmenata, pri čemu svaki od elemenata sadrži n sličnih elemenata (Klepac & Mršić , 2006)

Hijerarhijski klasteri - Metoda koja sortira podatke neovisno o mogućem broju klastera prema njihovim karakteristikama, ujedno je i najčešće korištena metoda.

Two-step cluster analiza kao što i samo ime kaže se provodi u dva dijela. Prvi dio analize podrazumijeva provođenje klasteriranja čiji se rezultati sortiraju hijerarhijskom metodom. Kombinacija ovih dviju metoda izvlači maksimalnu korist za korisnika analize.

Klasteriranje u turizmu se koristi s ciljem segmentacije tržišta na određene grupe sličnih karakteristika. Pojedinačne grupe je lakše promatrati i istraživati nego tržište u cjelini.

3.2.2. Stabla odlučivanja

Metoda rudarenja podataka koja na temelju određenih algoritama dolazi do pravila svrstavanja . Pravila svrstavanja nose određenu težinu te se prema tome mogu klasificirati kao niska, srednja i jaka pravila. Metoda stabla odlučivanja je predviđajuća metoda koja na temelju algoritama i međusobnih pravila predviđa mogući ishod. (Clarke, 1989)

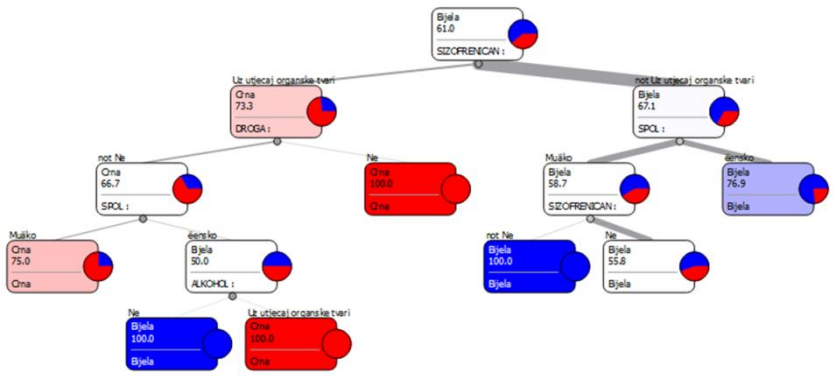

Slika 5 . Izrada autora - primjer stabla odlučivanja

Metodom se dobiva grafički prikaz utjecaja ulaznih varijabli na izlaznu, koja je izražena u obliku klasa ili kategorija. Svaki čvor u grafičkom stablu predstavlja jednu ulaznu varijablu, na čijim su rubovima označena „djeca- čvorovi“ za svaku moguću vrijednost neke ulazne varijable. Svaki list u stablu predstavlja vrijednost ciljne (izlazne) varijable ako su dane vrijednosti ulaznih varijabli predstavljene putom od korijena stabla do tog lista. Stablo se

dobiva „učenjem“ na podacima, na način da se vrši grananje izvornog skupa podataka u pod skupove na temelju testiranja vrijednosti varijabli. Proces se ponavlja na svakom izvedenom podskupu na rekurzivni način. Rekurzija je završena kada podskup određenog čvora ima sve iste vrijednosti izlazne varijable, ili kada daljnje grananje više ne pridonosi poboljšanju rezultata . [11]

3.2.3. Regresijska analiza

Regresijska analiza je jedna od najčešće korištenih statističkih metoda u procesu rudarenja podataka zbog njene široke primjenjivosti. Regresijskom analizom se pronalaze analitičko-matematičke veze između zavisne i jedne ili više nezavisnih varijabli. (M.Lenkić/Garača & Jadrić,2011) Kod regresijske analize se treba odrediti koja će varijabla biti zavisna, dok se nezavisne varijable inače nazivaju regresorskim varijablama. (Rozga, 2009) Ukoliko postoji samo jedna zavisna i jedna nezavisna varijabla onda govorimo o jednostrukoj regresiji, dok postojanjem više nezavisnih varijabli govorimo o višestrukoj regresiji. Primjenjivi regresijski oblici za korištenje u svrhu rudarenja podataka su linearna i logistička regresija. (M.Lenkić/ Garača & Jadrić, 2011)

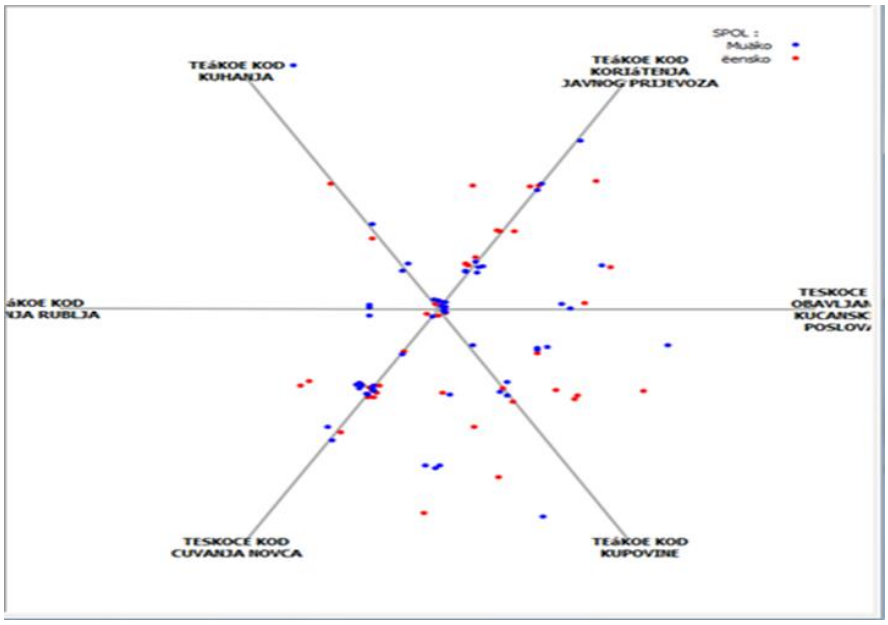

Slika 7 . Izrada autora - Primjer linearne regresije

[11] Zekić - Sušak,M. :Neuronske mreže i stabla odlučivanja za predviđanje uspješnosti studiranja, Osijek , 2009

Linearnom regresijom se modelira odnos između jedne ili više varijabli . Polazi se od pretpostavke da je veza između promatranih varijabli linearna, tj. jedna varijabla se može iskazati kao linearna funkcija druge varijable. (M.Lenkić/Garača & Jadrić, 2011). Ukoliko je slučajna varijabla normalno distribuirana, onda će i regresijski parametri biti normalno distribuirani. (Rozga, 2009). Logistička regresija je analiza asimetričnih relacija između dvaju skupova varijabli od kojih jedna im kriterijski a druga predikcijski status. Logističkim modelom se pretpostavlja da vrijednost ne može biti manja od 0 niti veća od1. (M.Lenkić/ Garača & Jadrić, 2011)

3.2.4. CN2 Pravila

CN2 su idealna metoda ukoliko želimo kvantificirati „snagu“ pravila koja proizlaze iz različitih baza podataka. Metoda se bazira na korištenju različitih algoritama s ciljem krajnjeg rezultata, pravila unutar pravila. (Washio, 2008)

Obilježja CN2 pravila su :

- Može procesuirati sve vrste podataka
- Prihvaća sva pravila uz određeno odstupanje
- Nisu zavisna o određenom uzorku

	IF conditions		THEN class	Distribution	Probabilities [%]	Quality	Length
0	Država rođenja=FRANCUSKA	→	Duljina boravka=< 2.5	[13659, 2578, 28...	71 : 13 : 15	-1.148	1
1	Država rođenja=POLJSKA	→	Duljina boravka=≥ 6.5	[3088, 4351, 155...	13 : 19 : 68	-1.226	1
2	Država rođenja=SJEDINJENE AMERIČKE DRŽAVE	→	Duljina boravka=< 2.5	[6251, 1215, 2163]	65 : 13 : 22	-1.265	1
3	Država rođenja=NJEMAČKA	→	Duljina boravka=≥ 6.5	[8335, 4407, 201...	25 : 13 : 61	-1.323	1
4	Država rođenja=AUSTRIJA	→	Duljina boravka=≥ 6.5	[3892, 2168, 8263]	27 : 15 : 58	-1.381	1
5	Država rođenja=AUSTRALIJA	→	Duljina boravka=< 2.5	[2741, 867, 1160]	57 : 18 : 24	-1.402	1
6	Država rođenja=ITALIJA	→	Duljina boravka=< 2.5	[6770, 2343, 2855]	57 : 20 : 24	-1.419	1
7	Država rođenja=MAĐARSKA	→	Duljina boravka=2.5 - 6.5	[1477, 4689, 4627]	14 : 43 : 43	-1.439	1
8	Država rođenja=ŠVEDSKA	→	Duljina boravka=≥ 6.5	[2740, 1761, 5090]	29 : 18 : 53	-1.450	1
9	Država rođenja≠HRVATSKA	→	Duljina boravka=≥ 6.5	[5238, 2749, 5617]	39 : 20 : 41	-1.523	1
10	TRUE	→	Duljina boravka=< 2.5	[4204, 2316, 2844]	45 : 25 : 30	-1.539	0

Slika8 . Izrada autora - primjer CN2 pravila

CN2 pravila uz određene kriterije klasificiraju promatrani uzorak podataka i svrstavaju ga na temelju zajedničkih pravila.

4.VAŽNOST I ZNAČAJ PROFILIRANJA TURISTA

Značaj profiliranja turista možemo promatrati kroz značaj istraživanja tržišta i njegovih primjena u poslovnom odlučivanju i donošenju odluka. Prema Marušić i Vranešević (2001) istraživanje tržišta je standardizirani postupak pomoću kojega se prikupljaju, obrađuju i prikazuju sve informacije kako bi se donijela potrebna odluka s ciljem rješavanja tržišnih problema. Istraživanje tržišta je proces pomoću kojeg upoznajemo sve aktivnosti i njihov utjecaj koji imaju na tržište. Cilj svakog istraživanja je razvoj strategije koja omogućuje konkurentsku prednost i bolje pozicioniranje proizvoda na tržištu. Malhotra (2010) ističe kako je istraživanje tržišta funkcija koja povezuje potrošače, ponuđače i ostale korisnike usluga pomoću informacija. Podaci se prikupljaju u realnom vremenu kako bi na što bolji način pridonijele povećanju konkurentske prednosti jer samo pravovremeni podatak možemo klasificirati kao informaciju. Svi podaci kojima raspolažemo ne znače ništa ukoliko nisu na pravilan način i sistematski obrađeni. Prije izlaska na tržište uvijek je potrebno provesti istraživanje kako bi otkrili sve specifičnosti i karakteristike potrošača, te postojeću konkurenciju. Spoznaje do kojih dolazimo su potrebe, navike i ponašanje potrošača.

Prednosti profiliranja turista kroz istraživanje tržišta se ogledaju u identificiranju potencijalnih problema, donošenju boljih poslovnih odluka, pružanju informacija u realnom vremenu i smanjivanju rizika. S obzirom na kompleksnost turizma kao poslovnog sektora promatramo ga kroz sve njegove direktne i indirektne veze koje ga karakteriziraju kao sustav. Segmentiranjem tržišta određujemo ciljnu skupinu koja će direktno koristiti određene proizvode i usluge, te na taj način pozicioniranjem konkretnih proizvoda na obostranu korist ponuđača i proizvođača zadovoljavamo želje i potrebe ciljanog segmenta potrošača. Informacije su bogatstvo iz kojega se znanje, njihovom obradom u informatičkom sustavu (prema određenim informacijsko-poslovnim zahtjevima), crpi i iskorištava za određene poslovne svrhe. Komunikacijski sustav sve to povezuje, omogućujući nesmetan i brz protok informacija u oba smjera. (Javorović, 2007)

Segmentacija turističkog tržišta treba biti jasno definirana načelima prema određenim karakteristikama[12] :

- Karakteristike segmenta se mogu identificirati :
  Segment obuhvaća turiste koji od turističke ponude očekuju iste ili slične koristi te se prema tome mogu zajedno identificirati

- Homogenost segmenta :
  Segment mora biti jasno identificiran i određen svojim karakterističnim varijablama kako bi se mogao razlikovati od ostalih segmenata

- Mjerljivost segmenta
  Mora se biti u mogućnosti procijeniti veličinu određenog segmenta i potencijalnu potrošnju o okviru tog segmenta

- Dostupnost segmenta
  Određeni segment je održiv samo ako do njega možemo doći različitim marketinškim alatima i naporima poduzeća

- Isplativost segmenta
  Neovisno o veličini segmenta on mora sadržavati dovoljnu financijski isplativost kako bi se opravdali troškovi provođenja istraživanja

- Ostvarivost segmenta
  Potrebe turista trebaju biti prilagođene financijskim mogućnostima poduzeća, razini profitabilnosti i ograničenjima na koja nailazimo tijekom redovnog poslovanja.

[12] Marušić,M & Prebežac, D. : Istraživanje turističkih tržišta Adeco, Zagreb, 2004

Ponašanje potrošača odnosi se na proces prikupljanja i organiziranja informacija u smjeru odluke o kupnji, te korištenja usluga i proizvoda u budućnosti. Odluka turista o kupnji sadrži neke jedinstvene aspekte, radi se o ulaganju bez vidljive stope povrata, a kupnja se često priprema i planira na osnovi novca uštođenog tijekom duljeg vremena. Da bi se poduzeli odgovarajući koraci na području marketinga u turizmu potrebno je razumjeti potrebno je razumjeti kako korisnici percipiraju usluge i proizvode. (Moutinho, 2005).

Načini na koje se provodi istraživanje je prikupljanjem primarnih i obradom već postojećih sekundarnih podataka. U Hrvatskoj postoji trenutno više od 30 tvrtki koje se bave istraživanjem tržišta, ali tek jedna od deset tvrtki koristi takve usluge.

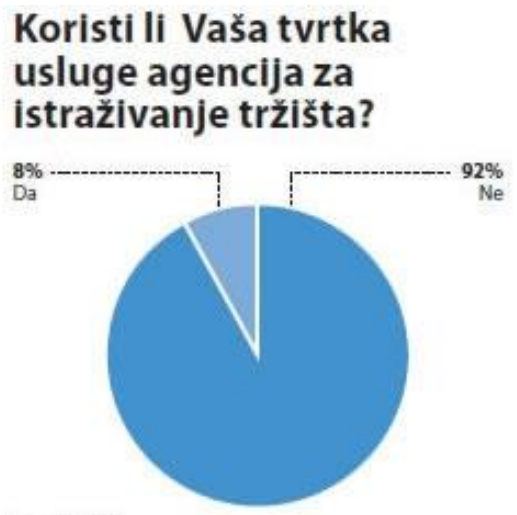

Izvor : Hendal

Slika 9 . Upotreba istraživanja tržišta u Hrvatskoj

Istraživanje tržišta se ogleda u otkrivanju uzoraka ponašanja odabranih ispitanika. Obrasci ponašanja se mogu kvantificirati pomoću različitih metoda rudarenja podataka, statističkih i drugih metoda. (Srivastava, 2000)

Poražavajući rezultati nisu začuđujući s obzirom na lošu poslovnu praksu koja vlada na domaćem tržištu kroz proteklo desetljeće

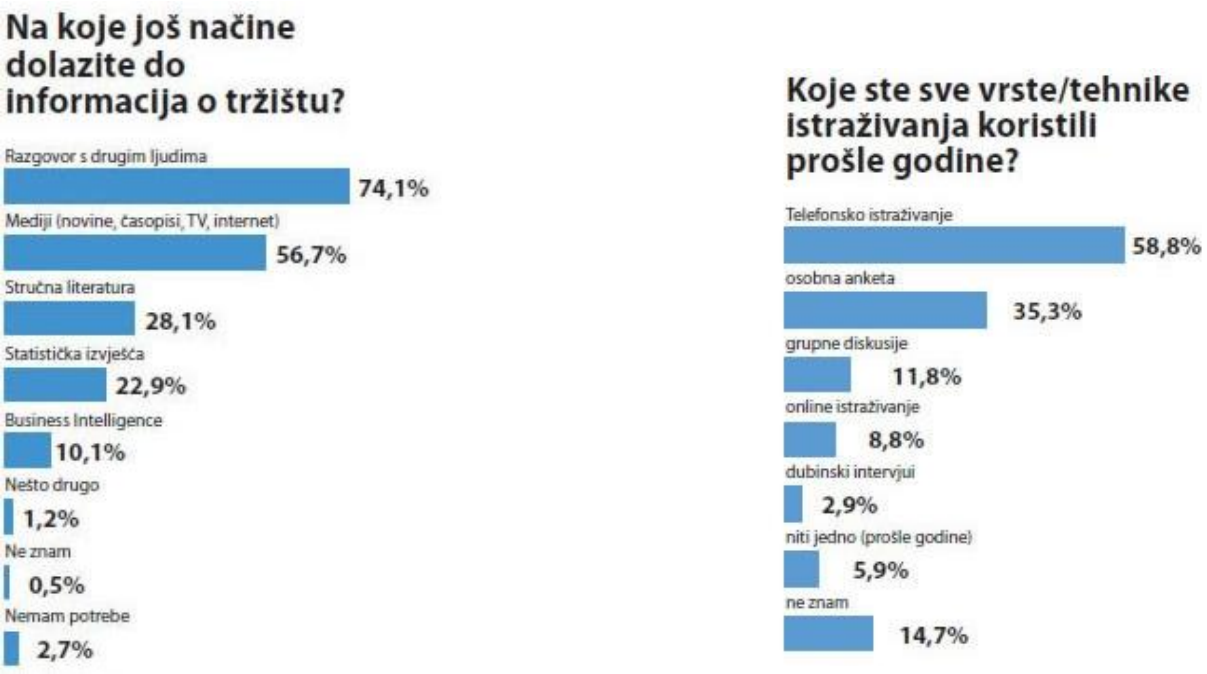

Izvor : Hendal

Slika 10. Navike istraživanja tržišta u Hrvatskoj

Segmentacija tržišta pomoću metoda poslovne inteligencije daje precizniju i jasniju sliku tržišta nego što je to kada se pri segmentaciji koristimo samo ekspertnim znanjem. Ekspert na osnovi intuicije većinom zahvaća širi segment pri čemu mu ostaje dosta nepoznanica koje nije uzeo u obzir. Nakon uspješne segmentacije tržišta moguće je znatno djelotvornije razraditi strategiju prema svakom određenom tržišnom segmentu (Klepac & Maršić, 2006) . Ukupnost informacija i znanja o klijentima koja omogućuju poduzimanje akcija s izgledima na uspješno obavljanje poslova s klijentima naziva se klijentskom inteligencijom tvrtke. Taj je oblik inteligencije sastavnica tržišne, a onda i ukupne poslovne inteligencije tvrtke. Klijentsku inteligenciju valja strukturirati u sustav koji će uključivati analitičke procese potrebne za oblikovanje, izvršavanje i vrednovanje svih inicijativa tvrtke koje imaju za cilj povećati zadovoljstvo klijenata, poticati njihovu lojalnost i, u konačnici, maksimalizirati profitabilnost klijenata tvrtke. (Panian i suradnici, 2003). Rezultati rudarenja podataka su dio strateškog planiranja pojedinog poslovnog subjekta, te podupiru donošenje poslovnih strategija i pridonose provođenju istih strategija. (Javorović & Bilandžić, 2007)

Budućnost turizma se može lako prognozirati na temelju prošlih podataka, ali se onda zanemaruje faktor napretka i novih razvojnih okolnosti. (Petrić, 2013)
Iako postoji mnogo načina da segmentiramo tržište nisu svi podjednako efektivni. Efektivnost ovisi o sljedećim kriterijima (Kotler i drugi, 2006) :

Mjerljivost : određena mjere do koje se veličina segmenta može kvantificirati. Određeni dijelovi tržišta su nemjerljivi iz različitih specifičnih razloga

Dostupnost : stupanj pristupa određenom segmentu

Održivost : da li su segmenti dovoljno veliki da se mogu smatrati kao zasebna tržišta . Segment kao jedinstvena homogena skupina koji sadrži jedinstveni ekonomski pristup prema tržištu

Produktivnost : mjera koja prikazuje koliki utjecaj imaju programi na privlačenje i zadržavanje novih kupaca

Loše planiranje, neadekvatan razvoj i nekompetentno upravljanje turističkim aktivnostima može sa sobom donijeti i različite negativne efekte za lokalno stanovništvo, kao i za cijelu zajednicu. Potencijalne negativnosti koje turizam može donijeti su (Marušić & Prebežac, 2004) :

- Nekontroliran razvoj turizma može donijeti prenapučenost prostora prometnim sredstvima
- Povećanje razine zagađenosti zraka radi povećanog broja prijevoznih sredstava kojima se koriste turisti, prijevozničke tvrtke i drugi
- Povećana razina zagađenosti površinskih i podzemnih voda kao rezultat neodgovarajuće infrastrukture
- Prevelik broj turista na najvažnijim lokalnim turističkim atrakcijama
- Nekontrolirano korištenje nacionalnih parkova, arheoloških i drugih povijesno kulturnih lokacija može dovesti do njihovog uništenja

5. REZULTATI ISTRAŽIVANJA

Završno poglavlje predstavlja proces provedenog istraživanja na odabranoj bazi podataka te prezentiranje dobivenih rezultata. Istraživanje se provodilo na temelju podataka koje je „TZ Trogir“ ustupila u svrhu izrade ovog diplomskog rada. Pomoću e-visitora (informacijski sustav za prijavu/odjavu turista) zabilježeni su točni podaci o priljevu i odljevu turista na području Grada Trogira kroz cijelu godinu. Prebacivanjem svih informacija u Excel tablicu omogućena je analiza i proces rudarenja podataka na spomenutoj bazi turista.

Baza podataka se sastoji od sljedećih varijabli :

- Kategorija smještaja
- Država rođenja
- Datum rođenja
- Starost gosta
- Državljanstvo
- Prebivalište
- Datum dolaska
- Datum odlaska
- Dan u tjednu
- Mjesec dolaska
- Godina dolaska
- Duljina boravka

Kategorija	Mjesto rođenja	Država rođenja	Datum rođenja	Starost gosta	Dob gosta	Državljanstvo	Prebivalište ulica	Prebivalište mjesto	Datum dolaska	Datum odlaska	dan
bez rješenja		BOSNA I HERCEGOVINA	10-pro-83	31	30	BOSNA I HERCEGOVINA	Trg Ivana Pavla II/1	Trogir	1-sij-14	4-sij-14	
bez rješenja		BOSNA I HERCEGOVINA	2-lip-79	35	40	BOSNA I HERCEGOVINA	Trg Ivana Pavla II/1	Trogir	1-sij-14	4-sij-14	
bez rješenja		SJEDINJENE AMERIČKE DRŽAVE	20-lip-92	22	20	SJEDINJENE AMERIČKE DRŽAVE	Trg Ivana Pavla II/1	Trogir	1-sij-14	6-sij-14	
bez rješenja		CRNA GORA	20-sij-68	46	50	CRNA GORA	Trg Ivana Pavla II/1	Trogir	2-sij-14	8-sij-14	
bez rješenja		SRBIJA	8-kol-66	48	50	SRBIJA	Trg Ivana Pavla II/1	Trogir	11-sij-14	21-sij-14	
bez rješenja		SJEDINJENE AMERIČKE DRŽAVE	20-lip-92	22	20	SJEDINJENE AMERIČKE DRŽAVE	Trg Ivana Pavla II/1	Trogir	13-sij-14	30-sij-14	
bez rješenja		BOSNA I HERCEGOVINA	17-ožu-81	33	30	BOSNA I HERCEGOVINA	Arbanija	Arbanija	10-sij-14	10-vlj-14	
bez rješenja		ALBANIJA	4-tra-58	56	60	ALBANIJA	Trg Ivana Pavla II/1	Trogir	7-vlj-14	12-vlj-14	
bez rješenja		BOSNA I HERCEGOVINA	19-lis-76	38	40	BOSNA I HERCEGOVINA	Drvenik Veli	Drvenik Veli	13-sij-14	13-vlj-14	
bez rješenja		BOSNA I HERCEGOVINA	3-stu-85	29	30	BOSNA I HERCEGOVINA	Mastrinka	Mastrinka	8-vlj-14	17-vlj-14	
bez rješenja		BOSNA I HERCEGOVINA	8-sij-72	42	40	BOSNA I HERCEGOVINA	Mastrinka	Mastrinka	8-vlj-14	17-vlj-14	
bez rješenja		SRBIJA	2-kol-41	73	70	SRBIJA	Mastrinka	Mastrinka	17-vlj-14	21-vlj-14	
bez rješenja		ŠVEDSKA	18-lip-65	49	50	ŠVEDSKA	Trg Ivana Pavla II/1	Trogir	16-sij-14	22-vlj-14	
bez rješenja		SRBIJA	30-kol-82	32	30	SRBIJA	Trg Ivana Pavla II/1	Trogir	17-vlj-14	24-vlj-14	
bez rješenja		BOSNA I HERCEGOVINA	30-ožu-62	52	50	BOSNA I HERCEGOVINA	Drvenik Veli	Drvenik Veli	9-sij-14	25-vlj-14	
bez rješenja		SRBIJA	19-tra-75	39	40	SRBIJA	Trg Ivana Pavla II/1	Trogir	28-sij-14	28-vlj-14	
bez rješenja		RUMUNJSKA	30-lip-86	28	30	RUMUNJSKA	Trg Ivana Pavla II/1	Trogir	3-ožu-14	7-ožu-14	
bez rješenja		KANADA	9-stu-79	35	40	KANADA	Trg Ivana Pavla II/1	Trogir	3-ožu-14	7-ožu-14	
bez rješenja		BOSNA I HERCEGOVINA	25-srp-46	68	70	BOSNA I HERCEGOVINA	Trg Ivana Pavla II/1	Trogir	8-ožu-14	12-ožu-14	
bez rješenja		BOSNA I HERCEGOVINA	24-srp-48	66	70	BOSNA I HERCEGOVINA	Trg Ivana Pavla II/1	Trogir	8-ožu-14	12-ožu-14	
bez rješenja		KOSOVO	16-lis-50	64	60	KOSOVO	Trg Ivana Pavla II/1	Trogir	15-sij-14	15-ožu-14	
bez rješenja		SRBIJA	19-tra-75	39	40	SRBIJA	Trg Ivana Pavla II/1	Trogir	28-vlj-14	15-ožu-14	
bez rješenja		SRBIJA	30-kol-82	32	30	SRBIJA	Trg Ivana Pavla II/1	Trogir	11-ožu-14	15-ožu-14	
bez rješenja		SRBIJA	10-ožu-61	53	50	SRBIJA	Trg Ivana Pavla II/1	Trogir	13-ožu-14	17-ožu-14	
bez rješenja		BOSNA I HERCEGOVINA	3-pro-63	51	50	BOSNA I HERCEGOVINA	Trg Ivana Pavla II/1	Trogir	20-ožu-14	23-ožu-14	
bez rješenja		BOSNA I HERCEGOVINA	25-vlj-68	46	50	BOSNA I HERCEGOVINA	Trg Ivana Pavla II/1	Trogir	20-ožu-14	23-ožu-14	
bez rješenja		SRBIJA	8-kol-66	48	50	SRBIJA	Trg Ivana Pavla II/1	Trogir	28-ožu-14	1-tra-14	
bez rješenja		BOSNA I HERCEGOVINA	20-svi-66	48	50	BOSNA I HERCEGOVINA	Trg Ivana Pavla II/1	Trogir	21-ožu-14	2-tra-14	
bez rješenja		CRNA GORA	6-stu-51	63	60	CRNA GORA	Trg Ivana Pavla II/1	Trogir	31-ožu-14	2-tra-14	
bez rješenja		BOSNA I HERCEGOVINA	30-tra-66	48	50	BOSNA I HERCEGOVINA	Trg Ivana Pavla II/1	Trogir	3-sij-14	3-tra-14	
bez rješenja		BOSNA I HERCEGOVINA	16-vlj-75	39	40	BOSNA I HERCEGOVINA	Trg Ivana Pavla II/1	Trogir	7-ožu-14	7-tra-14	
bez rješenja		BOSNA I HERCEGOVINA	2-lip-57	57	60	BOSNA I HERCEGOVINA	Drvenik Mali	Drvenik Mali	12-ožu-14	12-tra-14	
bez rješenja		SRBIJA	24-ožu-90	24	20	SRBIJA	Trg Ivana Pavla II/1	Trogir	10-tra-14	19-tra-14	

Slika 11 . Početna baza podataka u Excelu

Sirovu tablicu je potrebno formatirati, urediti ćelije sa nedostajućim podacima, ispraviti tipfelere, te pretvoriti u oblik prilagođen za daljnji proces analize i rudarenja podataka.

Programi korišteni prilikom istraživanja na zadanoj bazi podataka su „Orange Canvas“ i „Microsoft Excel (Pivot tablica). Orange Canvas je open- source program namijenjen početnicima i stručnjacima za analiziranje i rudarenje podataka.

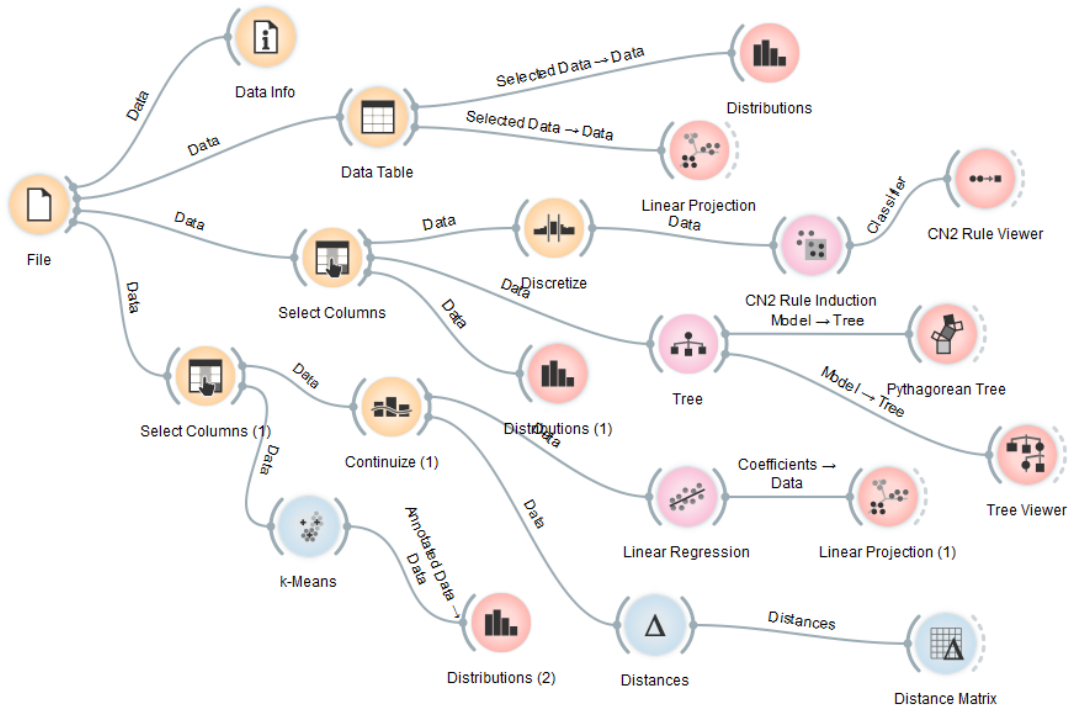

Slika 12. Model u Orange Canvasu

Slika prikazuje izgrađeni model u Orange Canvasu koji je korišten prilikom ovoga istraživanja. Metode koje su upotrebljavane : linearna regresija, CN2 pravila, stabla odlučivanja, k-mean, klasteriranje, matrica udaljenosti.

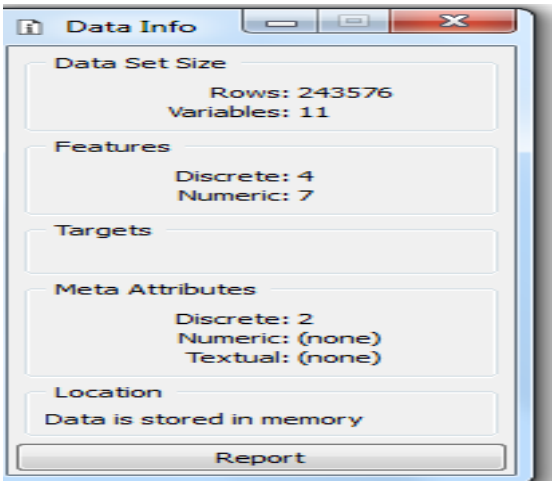

Slika 13. Informacije o modelu

Ubacivanjem prilagođene Excel tablice u Orange Canvas dobijemo sljedeći oblik.

	Država rođenja	Datum rođenja	Kategorija	Starost gosta	Državljanstvo	rebivalište mjest	Datum dolaska	Datum odlaska	n u tjednu brojkc	Dan u tjednu	Mjesec dolas
1	ITALIJA	22369.0	obrt	53.000	ITALIJA	Trogir	41641.000	41642.000	4.000	Četvrtak	1.
2	ITALIJA	21487.0	obrt	56.000	ITALIJA	Trogir	41641.000	41642.000	4.000	Četvrtak	1.
3	AUSTRALIJA	31754.0	hotel	28.000	AUSTRALIJA	Trogir	41642.000	41643.000	5.000	Petak	1.
4	AUSTRALIJA	31693.0	hotel	28.000	AUSTRALIJA	Trogir	41642.000	41643.000	5.000	Petak	1.
5	AUSTRALIJA	20530.0	hotel	58.000	AUSTRALIJA	Trogir	41642.000	41643.000	5.000	Petak	1.
6	AUSTRALIJA	10664.0	hotel	85.000	AUSTRALIJA	Trogir	41642.000	41643.000	5.000	Petak	1.
7	AUSTRALIJA	19676.0	hotel	61.000	AUSTRALIJA	Trogir	41642.000	41643.000	5.000	Petak	1.
8	ITALIJA	25540.0	obrt	45.000	ITALIJA	Trogir	41642.000	41643.000	5.000	Petak	1.
9	NJEMAČKA	23795.0	pr iznajmljivač	49.000	NJEMAČKA	Trogir	41645.000	41650.000	1.000	Ponedjeljak	1.
10	NJEMAČKA	21414.0	pr iznajmljivač	56.000	NJEMAČKA	Trogir	41645.000	41650.000	1.000	Ponedjeljak	1.
11	HRVATSKA	30931.0	obrt	30.000	HRVATSKA	Trogir	41646.000	41648.000	2.000	Utorak	1.
12	HRVATSKA	20985.0	pr iznajmljivač	57.000	HRVATSKA	Trogir	41647.000	41648.000	3.000	Srijeda	1.
13	HRVATSKA	30602.0	pr iznajmljivač	31.000	HRVATSKA	Trogir	41647.000	41648.000	3.000	Srijeda	1.
14	HRVATSKA	28723.0	pr iznajmljivač	36.000	HRVATSKA	Trogir	41647.000	41648.000	3.000	Srijeda	1.
15	ITALIJA	28188.0	obrt	37.000	ITALIJA	Trogir	41647.000	41648.000	3.000	Srijeda	1.
16	ŠVICARSKA	16105.0	pr iznajmljivač	70.000	ŠVICARSKA	Trogir	41647.000	41648.000	3.000	Srijeda	1.
17	AUSTRALIJA	31345.0	pr iznajmljivač	29.000	AUSTRALIJA	Trogir	41648.000	41651.000	4.000	Četvrtak	1.
18	AUSTRALIJA	31323.0	pr iznajmljivač	29.000	AUSTRALIJA	Trogir	41648.000	41651.000	4.000	Četvrtak	1.
19	AUSTRIJA	19478.0	obrt	61.000	AUSTRIJA	Trogir	41652.000	41654.000	1.000	Ponedjeljak	1.
20	HRVATSKA	20086.0	hotel	60.000	HRVATSKA	Trogir	41652.000	41654.000	1.000	Ponedjeljak	1.
21	RUSIJA	35157.0	obrt	18.000	RUSIJA	Trogir	41652.000	41653.000	1.000	Ponedjeljak	1.
22	RUSIJA	25843.0	obrt	44.000	RUSIJA	Trogir	41652.000	41653.000	1.000	Ponedjeljak	1.
23	HRVATSKA	29054.0	hotel	35.000	HRVATSKA	Trogir	41653.000	41654.000	2.000	Utorak	1.
24	HRVATSKA	29470.0	obrt	34.000	HRVATSKA	Trogir	41653.000	41656.000	2.000	Utorak	1.
25	HRVATSKA	22027.0	obrt	54.000	HRVATSKA	Trogir	41653.000	41656.000	2.000	Utorak	1.
26	HRVATSKA	31517.0	obrt	28.000	HRVATSKA	Trogir	41653.000	41656.000	2.000	Utorak	1.
27	HRVATSKA	26927.0	obrt	41.000	HRVATSKA	Trogir	41653.000	41656.000	2.000	Utorak	1.

Slika 14. Tablica u Orange Canvasu

5.1. Vizualizacija trendova i uzoraka

Istraživanjem se pokušava ustvrditi da li postoji trend ponašanja turista na trogirskom području ovisno iz koje države dolaze.

Kao prvo istraživanje prikazuje se primjer demografskog utjecaja ovisno o duljini boravka posjetioca, te razlike u 2014 i 2015 godini.

Sum of Duljina boravka	Column Labels										
Row Labels	AUSTRIJA	ČEŠKA	FRANCUSKA	ITALIJA	MAĐARSKA	NORVEŠKA	NJEMAČKA	POLJSKA	ŠVEDSKA	VELIKA BRITANIJA I SJ.IRSKA	Grand Total
1	1219	373	4322	2627	339	911	2778	1097	934	1723	16323
2	582	122	5208	1504	402	1102	1986	684	748	1348	13686
3	846	258	1794	1455	1086	873	1548	798	696	1413	10767
4	1052	504	1336	1292	2204	852	2068	1584	896	1116	12904
5	1115	1610	725	1020	3115	850	2515	3635	780	1040	16405
6	990	1440	672	1062	3222	1248	3198	4128	1242	1506	18708
7	19117	9856	5397	5348	9898	9639	33082	19999	10360	8512	131208
Grand Total	24921	14163	19454	14308	20266	15475	47175	31925	15656	16658	220001

Slika 15. Tablica duljine boravka 2014

Ovisno o duljini boravka većina posjetioca neovisno o državi ostaje preko šest dana, dok se može zaključiti kako posjetioci iz Francuske češće ostaju jedan ili dva dana . Najviše posjetioca je bilo iz Njemačke, Poljske i Mađarske.

Sum of Duljina boravka	Column Labels										
Row Labels	AUSTRIJA	FRANCUSKA	ITALIJA	MAĐARSKA	NORVEŠKA	NJEMAČKA	POLJSKA	SJEDINJENE AMERIČKE DRŽAVE	ŠVEDSKA	VELIKA BRITANIJA I SJ.IRSKA	Grand Total
1	2073	4164	2594	661	862	3515	1262	2673	1063	1987	20854
2	590	5126	1584	544	726	2018	730	1378	678	1680	15054
3	1119	2223	1545	1569	777	2145	1296	852	993	1878	14397
4	1448	1412	1204	2980	936	2336	1700	372	1032	1460	14880
5	915	895	1070	3315	1010	2925	3280	355	840	1245	15850
6	2058	834	1014	4590	1176	3432	4956	438	1290	1914	21702
7	28357	9625	7378	12516	11767	48664	26229	10934	19250	21812	196532
Grand Total	36560	24279	16389	26175	17254	65035	39453	17002	25146	31976	299269

Slika 16. Tablica duljine boravka 2015

Tablica prikazuje sumu ukupnih boravaka posjetioca ovisno o njihovim demografskim karakteristikama.

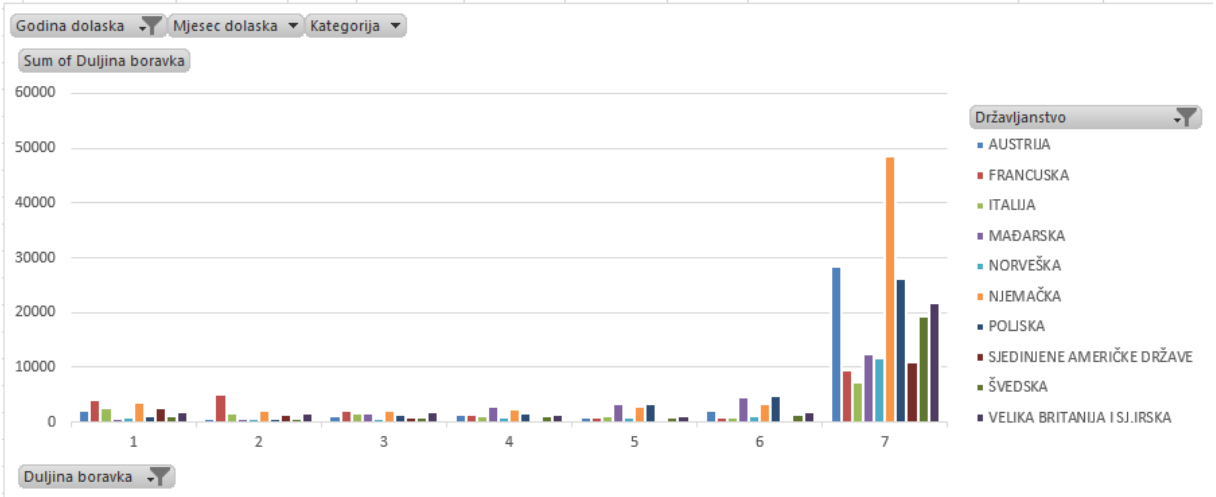

Slika 17. Grafikon duljine boravka prema nacionalnosti 2015

U 2015. godini se primijeti velika razlika, te većina gostiju neovisno o demografskom podrijetlu ostaje više od šest dana, čime ne postoji povezanost između nacionalnosti posjetioca i duljine boravka na trogirskom području.

Ovisno o demografskim karakteristikama prevladavaju posjetioci iz Njemačke, Austrije, Poljske, Švedske i Velike Britanije. Ostali posjetioci su ravnomjerno raspoređeni.

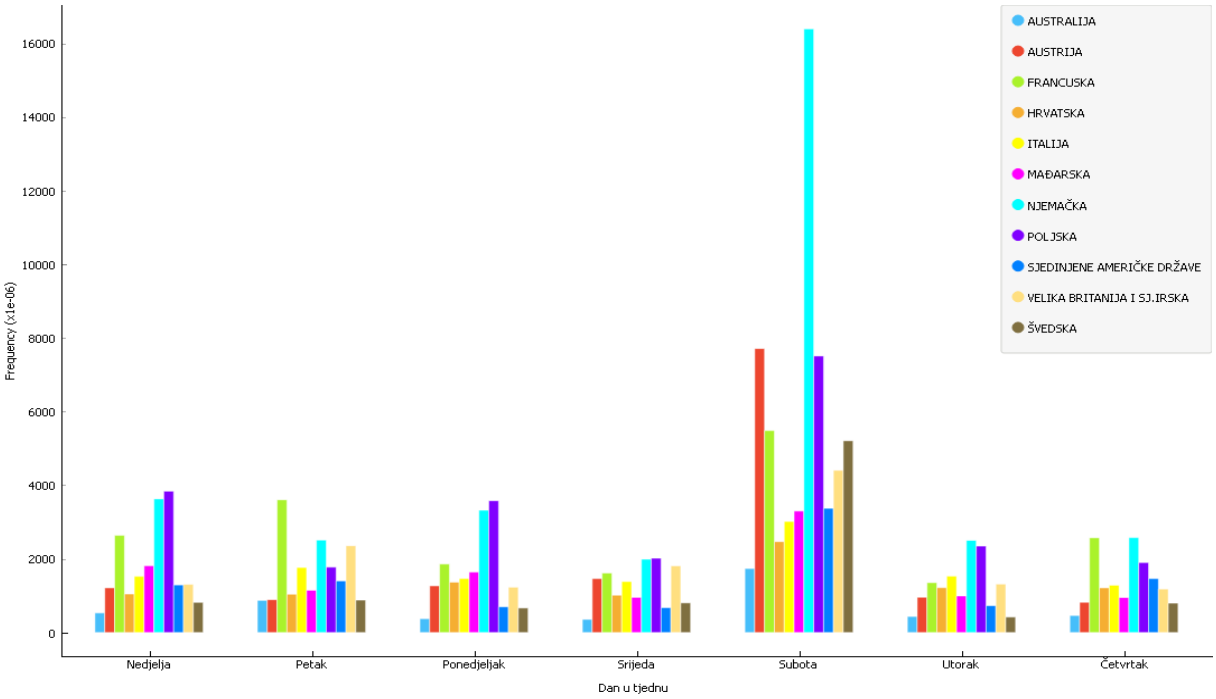

Slika 18. Grafikon prema danima dolaska ovisno o nacionalnosti

Ovisno o danu kojim posjetioci dolaze daje se zaključiti kako je subota centralni dan za priljev gostiju, dok su ostali dani ravnomjerno raspoređeni neovisno o demografskim karakteristikama posjetioca.

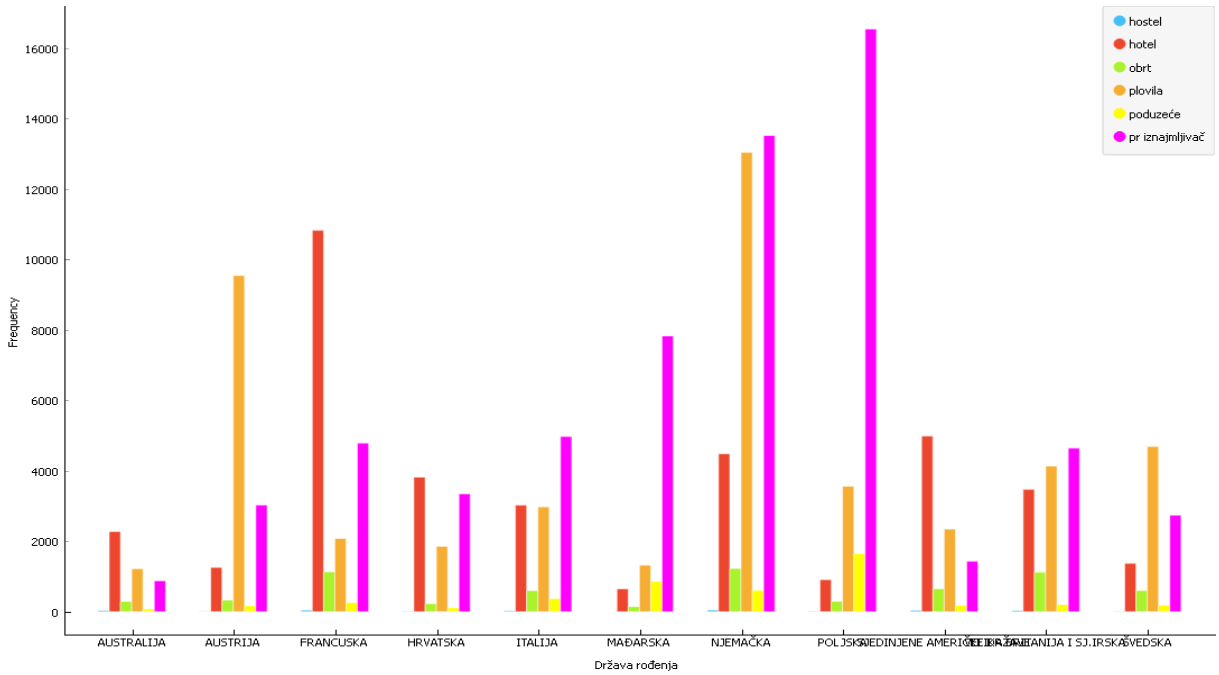

Slika 19. Grafikon prema nacionalnosti ovisno o kategoriji smještaja

Iz priloženog grafikona se zaključuje kako ovisno o kategoriji smještaja postoje različite karakteristike prema demografskim osobinama posjetitelja.

Kod gostiju iz Poljske i Mađarske prevladava smještaj kod privatnih iznajmljivača , gosti iz Francuske i Amerike preferiraju smještaj u hotelima, dok su Austrijanci najviše okrenuti nautičkom turizmu i smještajem na plovilima.

	IF conditions		THEN class	Distribution	Probabilities [%]	Quality	Length
0	Država rođenja=FRANCUSKA	→	Duljina boravka=< 2.5	[13659, 2578, 28...	71 : 13 : 15	-1.148	1
1	Država rođenja=POLJSKA	→	Duljina boravka=≥ 6.5	[3088, 4351, 155...	13 : 19 : 68	-1.226	1
2	Država rođenja=SJEDINJENE AMERIČKE DRŽAVE	→	Duljina boravka=< 2.5	[6251, 1215, 2163]	65 : 13 : 22	-1.265	1
3	Država rođenja=NJEMAČKA	→	Duljina boravka=≥ 6.5	[8335, 4407, 201...	25 : 13 : 61	-1.323	1
4	Država rođenja=AUSTRIJA	→	Duljina boravka=≥ 6.5	[3892, 2168, 8263]	27 : 15 : 58	-1.381	1
5	Država rođenja=AUSTRALIJA	→	Duljina boravka=< 2.5	[2741, 867, 1160]	57 : 18 : 24	-1.402	1
6	Država rođenja=ITALIJA	→	Duljina boravka=< 2.5	[6770, 2343, 2855]	57 : 20 : 24	-1.419	1
7	Država rođenja=MAĐARSKA	→	Duljina boravka=2.5 - 6.5	[1477, 4689, 4627]	14 : 43 : 43	-1.439	1
8	Država rođenja=ŠVEDSKA	→	Duljina boravka=≥ 6.5	[2740, 1761, 5090]	29 : 18 : 53	-1.450	1
9	Država rođenja≠HRVATSKA	→	Duljina boravka=≥ 6.5	[5238, 2749, 5617]	39 : 20 : 41	-1.523	1
10	TRUE	→	Duljina boravka=< 2.5	[4204, 2316, 2844]	45 : 25 : 30	-1.539	0

Slika 20. CN2 pravila prema nacionalnosti ovisno o duljini boravka

Prikaz rezultata metode CN2 pravila u odnosu utjecaja duljine boravka na demografske karakteristike posjetioca.

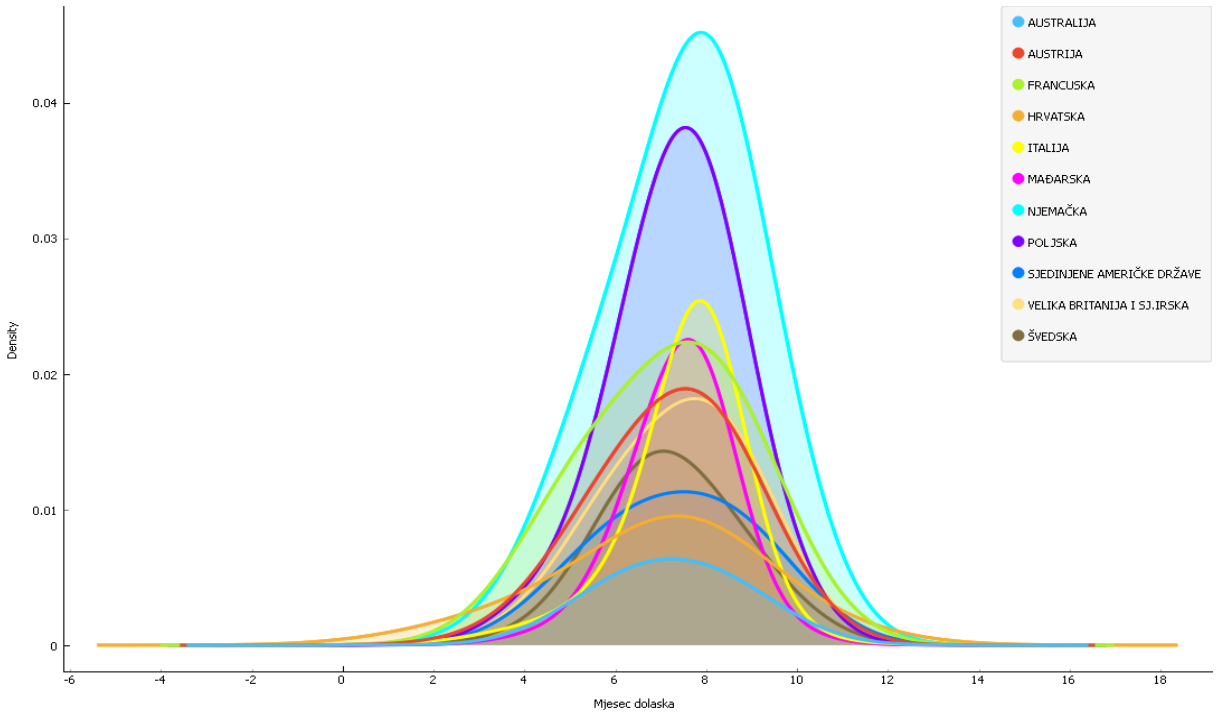

Slika 21. Mjesec dolaska prema nacionalnosti

	IF conditions		THEN class	Distribution	Probabilities [%]	Quality
0	Država rođenja=ITALIJA	→	Mjesec dolaska=≥ 7.5	[1604, 2109, 8255]	13 : 18 : 69	-1.200
1	Država rođenja=NJEMAČKA	→	Mjesec dolaska=≥ 7.5	[8403, 4970, 195...	26 : 15 : 59	-1.361
2	Država rođenja=MAĐARSKA	→	Mjesec dolaska=≥ 7.5	[1640, 3514, 5639]	15 : 33 : 52	-1.429
3	Država rođenja=VELIKA BRITANIJA I SJ.IRSKA	→	Mjesec dolaska=≥ 7.5	[3916, 2531, 7157]	29 : 19 : 53	-1.456
4	Država rođenja=FRANCUSKA	→	Mjesec dolaska=≥ 7.5	[6704, 3077, 9343]	35 : 16 : 49	-1.459
5	Država rođenja=POLJSKA	→	Mjesec dolaska=≥ 7.5	[4946, 6587, 114...	22 : 29 : 50	-1.495
6	Država rođenja=AUSTRIJA	→	Mjesec dolaska=≥ 7.5	[4389, 2956, 6978]	31 : 21 : 49	-1.498
7	Država rođenja=SJEDINJENE AMERIČKE DRŽAVE	→	Mjesec dolaska=≥ 7.5	[3086, 1925, 4618]	32 : 20 : 48	-1.499
8	Država rođenja=HRVATSKA	→	Mjesec dolaska=≥ 7.5	[3113, 2067, 4184]	33 : 22 : 45	-1.529
9	Država rođenja=AUSTRALIJA	→	Mjesec dolaska=≥ 7.5	[1497, 1169, 2102]	31 : 25 : 44	-1.543
10	TRUE	→	Mjesec dolaska=≥ 7.5	[2762, 3080, 3749]	29 : 32 : 39	-1.573

Slika 22. CN2 pravila nacionalnost prema mjesecu dolaska

Iz priloženih rezultata se zaključuje kako ne postoji dovoljno jako pravilo kako bi se konstatiralo da zemlja podrijetla ima utjecaj na mjesec dolaska posjetioca.

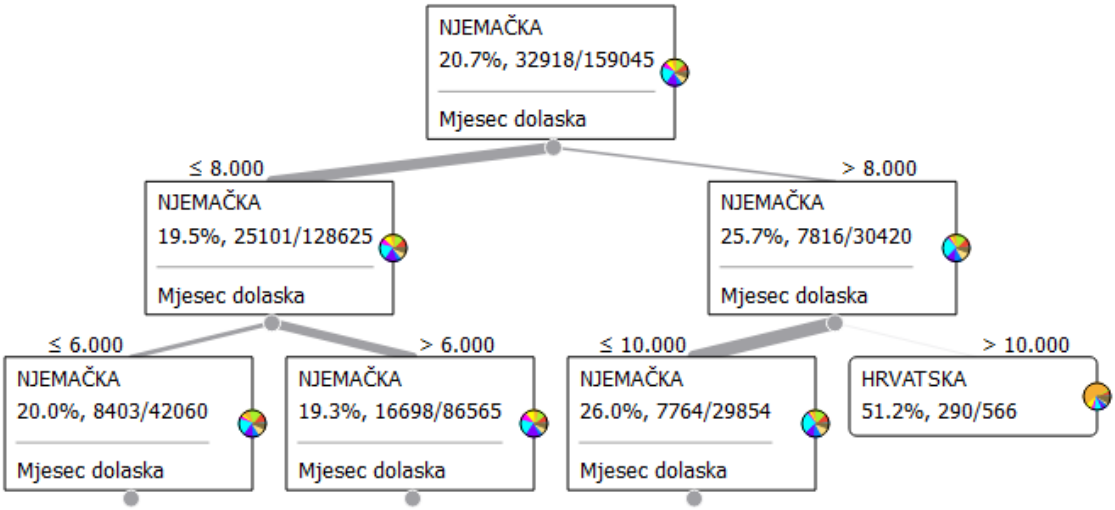

Slika 23. Stablo odlučivanja prema nacionalnosti u ovisnosti na mjesec dolaska

Kako bi rezultate mogli prikazati u prihvatljivijem obliku sortirani su i odabrani deset najvećih država koji predstavljaju relevantnu skupinu posjetioca područja grada Trogira.

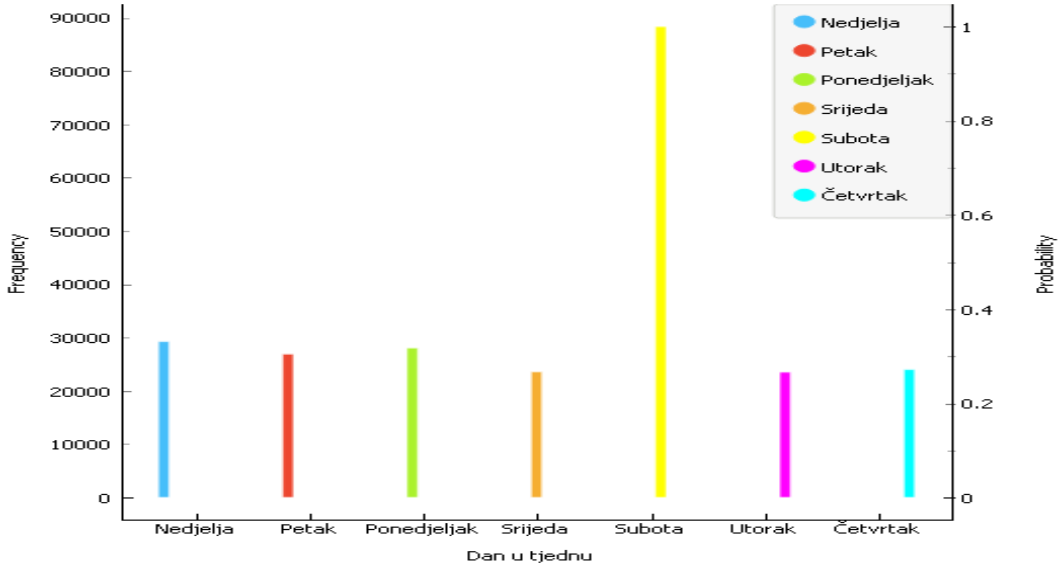

Slika 24. Analiza ovisno o danu dolaska

Uzimajući u obzir dane kojima turisti dolaze u posjetu, subota se ističe kao centralni dan, dok su ostali dani u tjedni ravnomjerno raspoređeni.

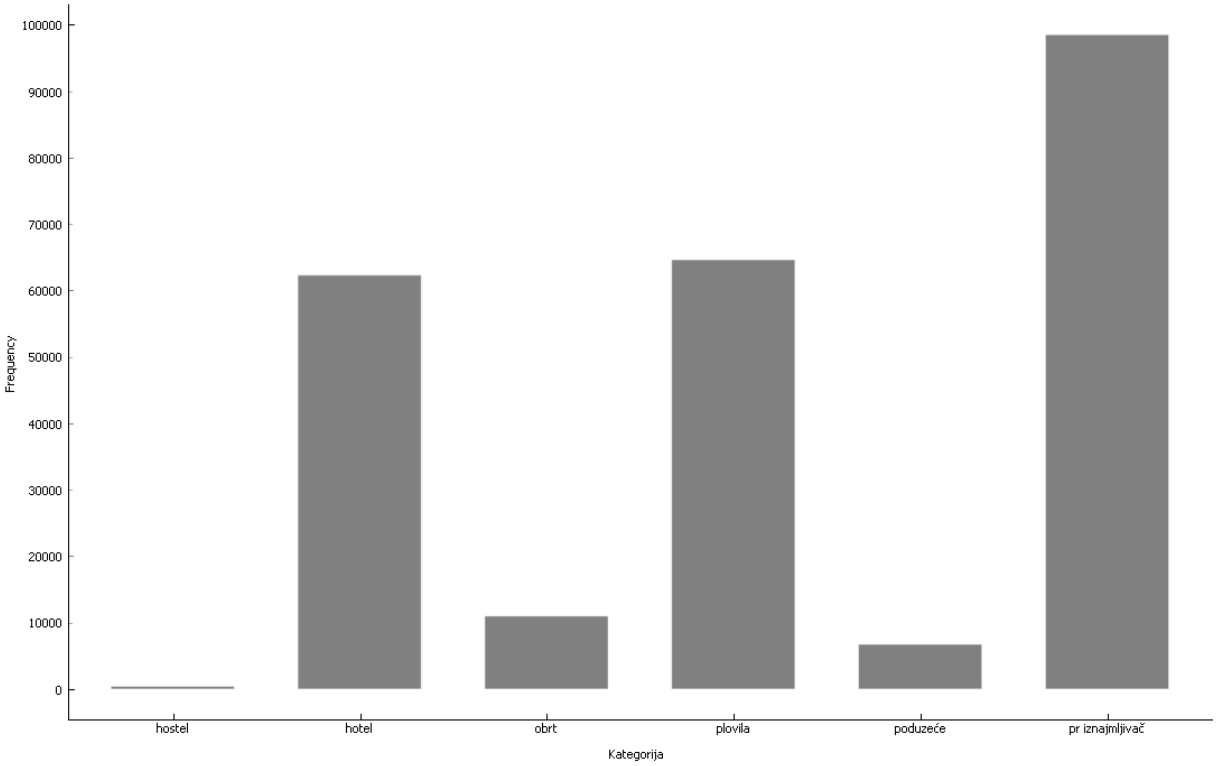

Slika 25. Analiza prema kategoriji smještaja

Deskriptivna metoda prikazivanja podataka pomoću jednostranih stupaca je idealna zbog svoje jednostavnosti i konkretnih rezultata prlikom korištenja. Prema kategoriji smještaja, privatni iznajmljivači imaju prednost pred ostalim kategorijama , dok su hoteli i plovila ravnomjerno visoko zastupljeni. Hosteli, obrti i poduzeća nemaju veliku zastupljenost na

trogirskom tržištu. Zahvaljujući trogirskoj marini koja se prometnula kao jedan od glavnih pokretača trogirskog turizma imamo visoku zastupljenost kategorije smještaja na plovilima.

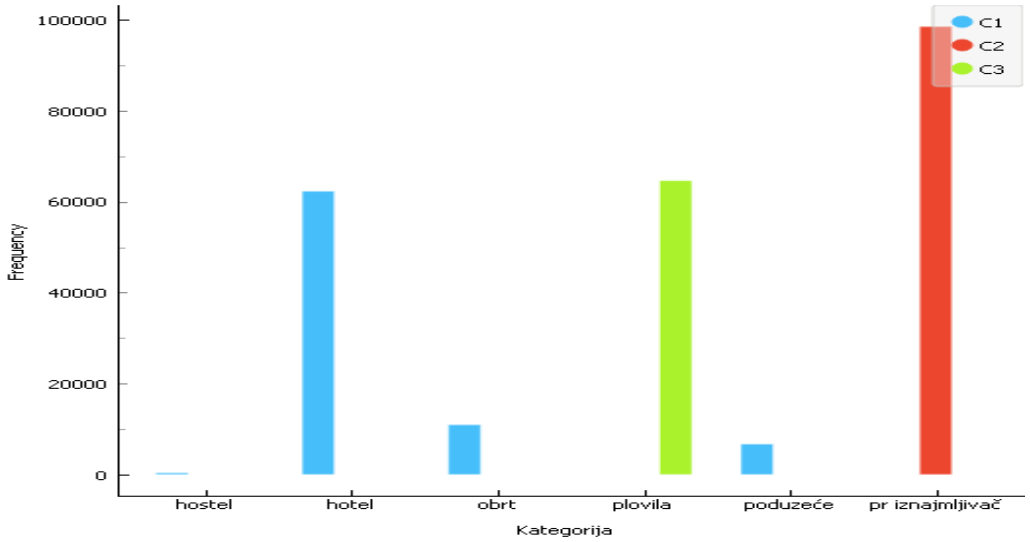

Slika 26. Klasteriranje prema kategoriji smještaja

Svrstavajući turiste po sličnim karakteristikama metodom klasteriranja za varijablu kategorija smještaja dobili smo tri moguća klastera :

- Privatni iznajmljivači
- Plovila
- Hotel, hostel, obrt, poduzeće

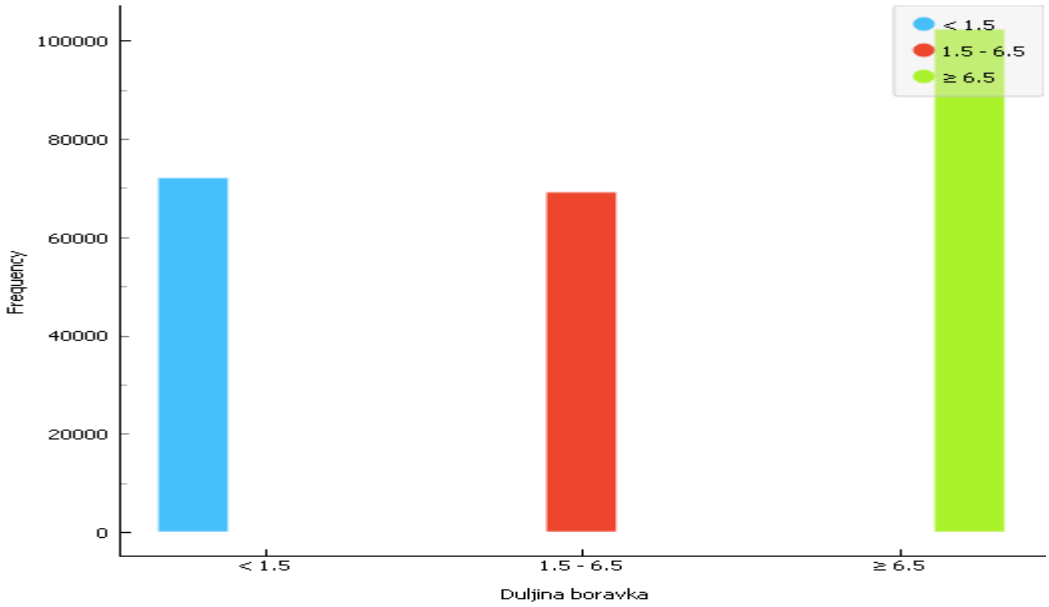

Slika 27. Analiza duljine boravka

Duljina boravka kao varijabla nema utjecaj na turizam trogirskog područja jer iz priložene tablice zaključujemo kako duljina nije relevantna iako prevladavaju turisti koji borave duže od šest dana. Područje Trogira je ravnomjerno bazirano na turiste koji su u prolazu i dolaze na jednodnevne izlete, te na turiste koji dolaze u Trogir s ciljem boravka duže od šest dana.

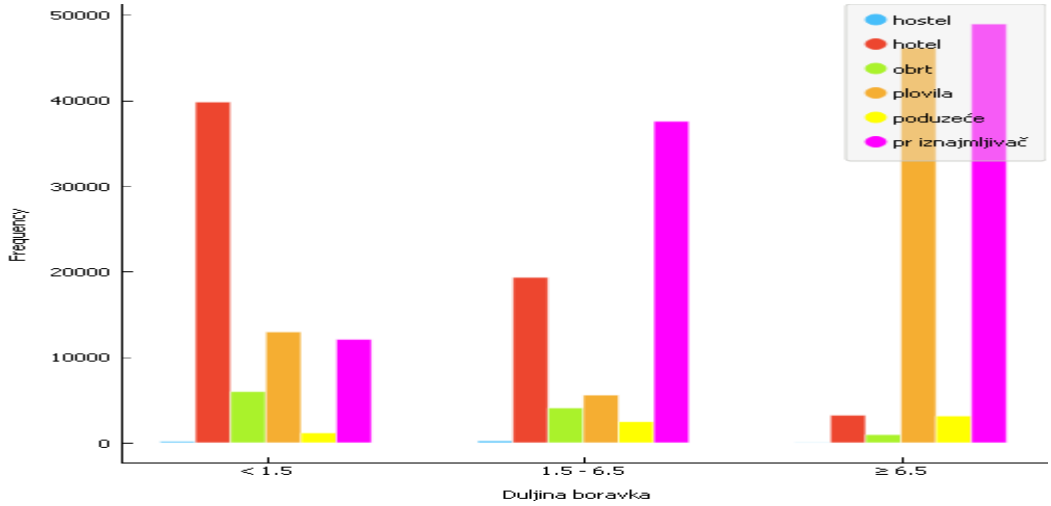

Slika 28. Analiza duljine boravka ovisno o kategoriji smještaja

Promatrajući u zajedničkom odnosu varijable „kategorija smještaja“ i „duljina boravka“ možemo zaključiti kako su pod-varijable „privatni iznajmljivači“ i „plovila“ obrnuto proporcionalni od ostalih promatranih varijabli. Navedene varijable su zastupljene na rok duži od šest dana, dok su ostale varijable zastupljenije na kraći rok.

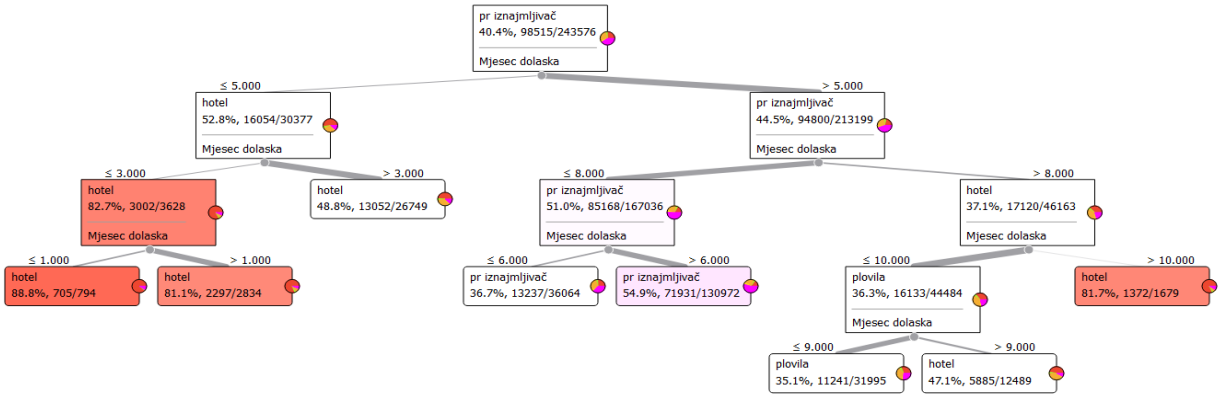

Slika 29. Stablo odlučivanja prema mjesecu dolaska ovisno o kategoriji smještaja

Stabla odlučivanja su prediktivna metoda koja kategoriziraju varijable prema sličnim karateristikama i odlukama. Koristeći metodu stabla odlučivanja i uzimajući u obzir „kategoriju smještaja“ i „mjesec dolaska“ možemo zaključiti kako u pred i post sezoni sa visokih 80% prevladavaju hoteli , dok za vrijeme visoke sezone privatni iznajmljivači predstavljaju 50% ukupnog tržišta.

5.2. Demografski profil turista

Na temelju dostupnih podataka se pokušava utvrditi da li postoje demografske karakteristike posjetioca koje utječu na njihove aktivnosti prilikom posjećivanja trogirskog područja.

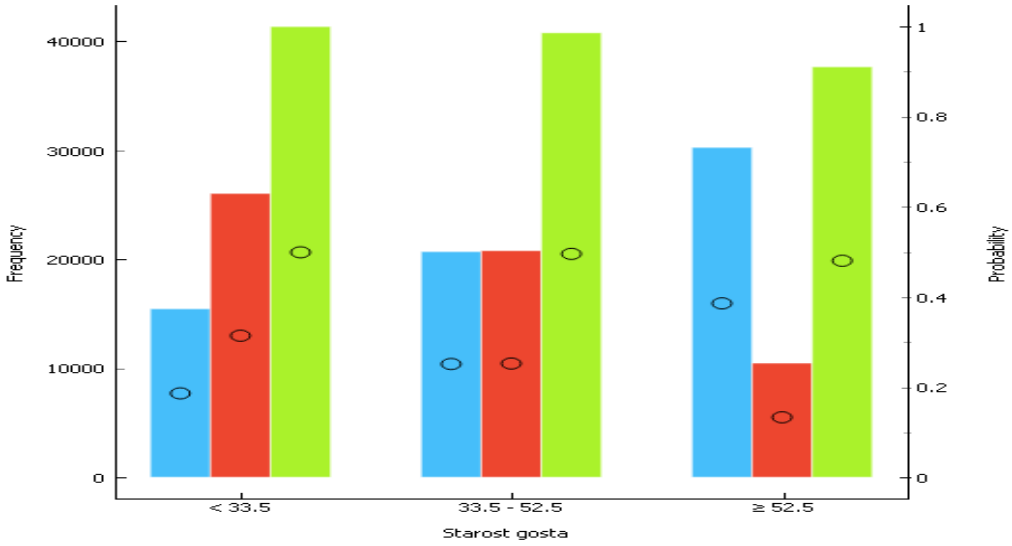

Slika 30. Analiza posjetioca prema starosti

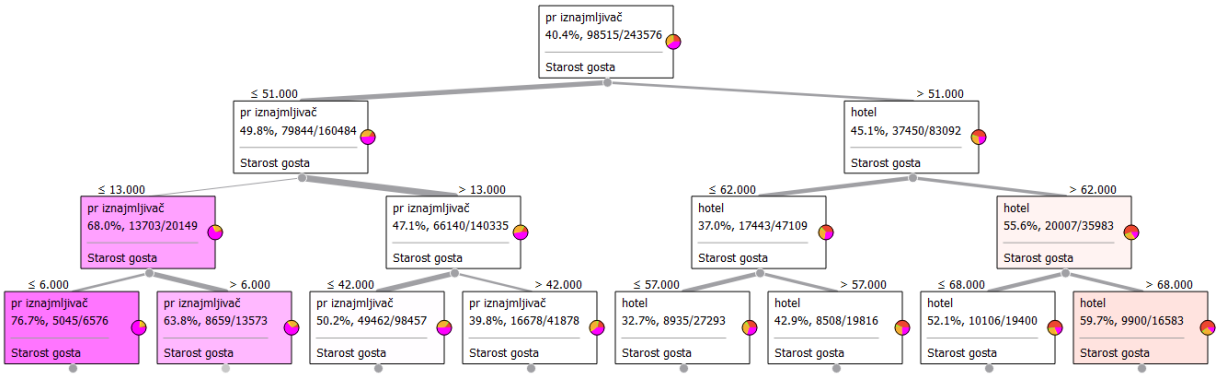

Slika 31. Stablo odlučivanje prema starosti gostiju ovisno o kategoriji smještaja

Korištenjem metode stabla odlučivanja, uzimajući u obzir varijable „starost gosta“ i „kategorija smještaja“ mozemo zakljuciti iz rezultata kako su se posjetioci podijeli na mlađe i starije od 51 godine. Kod svih posjetioca mlađih od 51 godine prevladava privatni smještaj, dok kod svih posjetioca starijih od 51 godine prevladava hotelski smještaj.

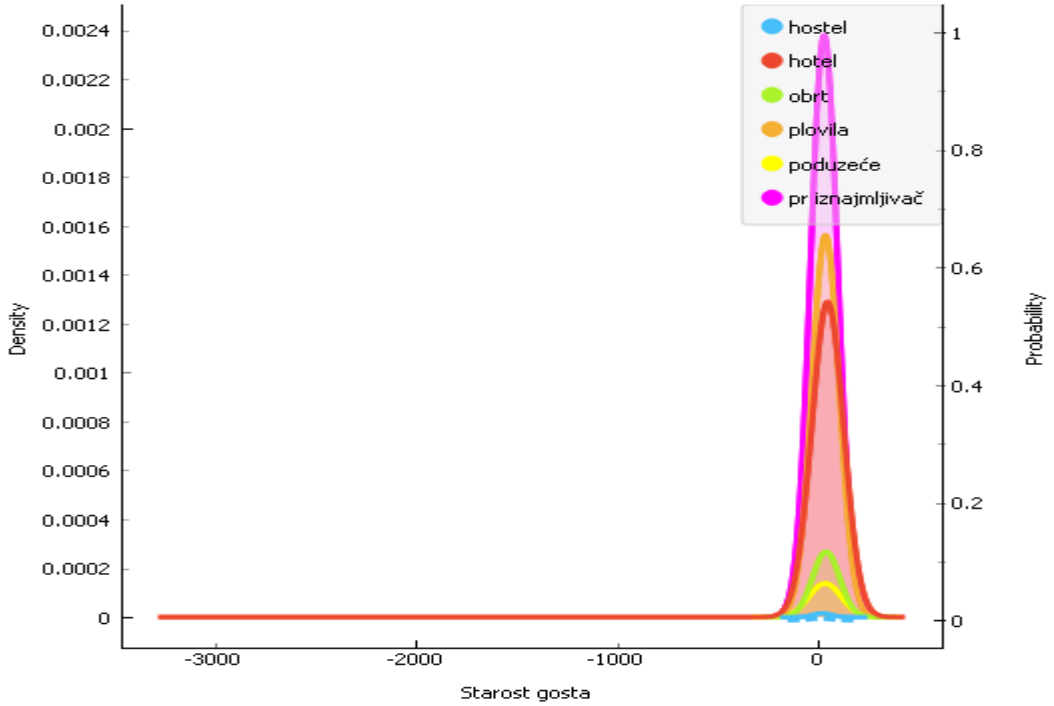

Slika 32. Grafikon starosti gostiju prema kategoriji smještaja

Prikazani grafikon predstavlja ravnomjernu raspoređenost ostalih kategorija smještaja, dok je linija koja predstavlja hotelski smještaj asimetrična na desnu stranu, predstavljajući preferenciju starije populacije kod izbora kategorije smještaja.

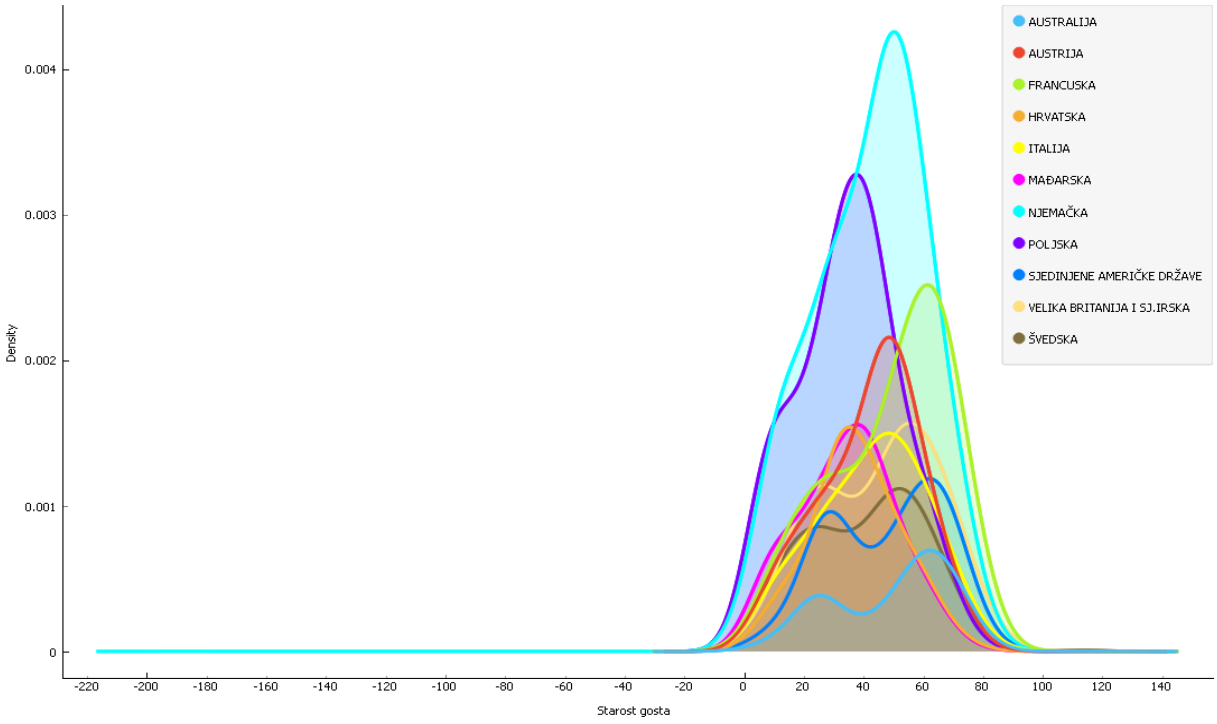

Slika 33. Starosna distribucija prema nacionalnosti

Od odabranih deset zemalja sa najvećim udjelom turista na trogirskom tržištu normalnu starosnu distribuciju ovisno iz države koje potječu imaju :

- Njemačka
- Poljska
- Austrija
- Mađarska
- Italija

Distribucija je lijevo asimetrična kod SAD-a, Švedske, Francuske, Velike Britanije i Australije predstavljajući veći broj mlađih posjetioca iz navedenih zemalja.

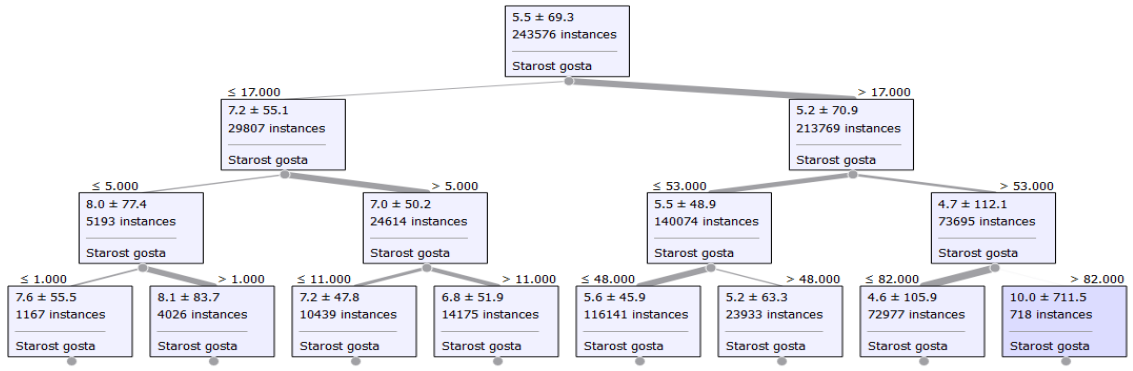

Slika 34. Stablo odlučivanja prema starosti posjetioca ovisno o duljini boravka

Koristeći metodu stabla odlučivanja zaključeno je kako starost posjetioca nema utjecaj na duljinu boravka na području grada Trogira.

	IF conditions		THEN class	Distribution	Probabilities [%]	Quality	Length
0	Starost gosta=< 33.5	→	Duljina boravka=≥ 6.5	[17360, 23910, 4...	21 : 29 : 50	-1.489	1
1	Starost gosta=33.5 - 52.5	→	Duljina boravka=≥ 6.5	[22639, 23325, 3...	28 : 28 : 44	-1.549	1
2	TRUE	→	Duljina boravka=< 1.5	[32085, 21924, 2...	41 : 28 : 31	-1.566	0

Slika 35. CN2 pravila duljina boravka

CN2 pravila potvrđuju zaključak kako ne postoji dovoljno jako pravilo između povezanosti duljine boravka i starosti gostiju.

5.3. Osvrt na hipoteze

H1…Metode rudarenja podataka omogućuju određivanje trendova i uzoraka na odabranom uzorku posjetitelja trogirskog područja

- Nacionalnost nema utjecaj o duljini boravka (str.34)
- Nacionalnost nema utjecaj na dan dolaska na trogirsko područje (str.35)
- Nacionalnost utječe na odabir smještaja
- Duljina boravka posjetioca utječe na odabir kategorije smještaja na trogirskom području (str.40)
- Mjesec dolaska utječe na odabir kategorije smještaja (str.40)

Iz prikazanih rezultata se zaključuje kako postoje određeni trendovi i uzorci prema kojem se mogu identificirati karakteristike određene populacije, te se prema tome navedena hipoteza prihvaća.

H2…Metode rudarenja podataka omogućuje određivanje demografskih osobina posjetitelja

- Starost posjetioca utječe na odabir kategorije smještaja (str.41)
- Starost posjetioca ne utječe na duljinu boravka na trogirskom području (str.43)

Iz prikazanih rezultata se zaključuje kako postoje određene demografske osobine posjetitelja prema kojem se mogu identificirati karakteristike određene populacije, te se prema tome navedena hipoteza prihvaća.

ZAKLJUČAK

Napretkom tehnologije i postupnom informatizacijom u svim procesima razmjene dobara i usluga došli smo do beskonačne baze podataka koja sadrži mnogobrojne informacije korisne za razvoj, napredak tržišta i stvaranje konkurentske prednosti pred ostalim tržišnim sudionicima. Rudarenje podataka je proces koje tvrtke koriste kako bi pretvorili sirove podatke u korisne informacije. Korištenjem određenih softvera za rudarenje podataka možemo pronaći uzorke ponašanja u velikim bazama podataka. Sa ovakvim podacima tvrtke mogu pravilno pozicionirati svoje strategije i smanjiti troškove poslovanja. (Fayyad, 1996)

Rudarenje podataka je prihvaćeno kao odlično rješenje za izvlačenje potrebnih informacija iz velikih i nesvrstanih baza podataka, ali nažalost još uvijek nije pronašlo svoje mjesto na hrvatskom tržištu. Protok informacija je bitna stavka na svakom tržištu koje želi maksimizirati sve svoje potencijale do kraja. Svakodnevno ljudi putuju od mjesta do mjesta, kupuju hranu, putne karte, smještaj i ostavljaju podatke koje vode do potrebnih informacija.

Metodama rudarenja podataka kao što su stabla odlučivanja, linearna regresija, neuronske mreže možemo prikazati utjecaje i odnose svih varijable koje promatramo. Vizualizacijom podataka prikazujemo rezultate na jednostavniji i prihvatljiviji način krajnjem korisniku. Metode stabla odlučivanja i CN2 pravila su korištene s ciljem klasifikacije varijabli prema sličnim karakteristikama i promatranja obrazaca ponašanja na zadanoj bazi podataka. Metode rudarenja podataka ne služe samo za otkrivanje novih uzoraka ponašanja, uspoređivajući prošle i sadašnje podatke možemo kvantificirati nastale promjene i poveznice između promatranih varijabli. (Hand & Manila, 2001)

Rudarenje podataka u turizmu je idealna metoda koja omogućuje korisnicima bolju pripremu i uslužniji pristup svojim klijentima. Istraživanjem tržišta i segmentiranjem turista možemo saznati specifične karakteristike određene populacije i prilagoditi se njihovim potrebama. Klijenti su postali više informiraniji, iskusniji i zahtjevniji, te se prema tome tržište prilagodilo svojim korisnicima. Segmentacijom tržišta prema korisnicima sličnih karakteristika nastupamo na tržištu sa individualnim strategijama koje su točno napravljene za određenu populaciju ili određenu osobu.

Rudarenje podataka je iterativna metoda koja najbolje djeluje u analitičkom okruženju gdje nije unaprijed definirano koji rezultat je zadovoljavajući. Ukoliko želimo da rudarenje podataka bude uspješno određeni kriteriji i pravila se moraju poštovati prilikom njihovog izvođenja (Kantaradžić, 2011) Ovisno u kakvu se svrhu koriste metode rudarenja podataka možemo se susresti sa različitim nedostacima u vidu nedostatka privatnosti, sigurnosti, nepotpunih podataka i samim time netočnih rezultata.

Svakodnevnim rastom tehnologije potreba za metodama rudarenja podataka će samo rasti iz dana u dan zbog konstantne uporabe interneta i društvenih mreža koje su neiscrpni izvor sirovih podataka. Ljudi dijele beskonačan broj podataka koji se lako može pretvoriti u korisnu informaciju. Svaki put kada ljudi posjete neku stranicu, kupe nešto online, kliknu na neki link šalju vrijedne podatke u bazu podataka. U prošlosti su se podaci čuvali isključivo u revizijske svrhe, dok danas zahvaljujući lakoj obradi i pohranjivanju podataka možemo koristiti takve podatke s lakoćom. (Pujari, 2001)

Rudarenje podataka kroz poslovnu inteligenciju mora pronaći svoje mjesto na svim tržištima kako bi pridonijelo boljem planiranju i lakšem donošenju odluka. Problem na hrvatskom tržištu predstavlja nedovoljna edukacija i svjesnost o prednostima koje rudarenje podataka može pridonijeti maksimizaciji dobiti i zadovoljstvu klijenata.

SAŽETAK

Postupnom modernizacijom i napretkom tehnologije ljudi su primorani koristiti nove metode kako bi ostali u korak sa vremenom. Rudarenje podataka se pojavilo kao potreba za lakšim obrađivanjem velikih ne sortiranih baza podataka. Primjenjivost rudarenja podataka se proteže na sve industrije. Pomoću metoda rudarenja podataka pokušava se doći do relevatnog zaključka na primjeru turizma i njegovih aktivnosti. Metode koje se koriste u ovom procesu su klasteri, stabla odlučivanja, regresijska analiza i druge. Uz pomoć deskriptivne statistike i vizualizacije podataka korisnicima se na najbolji način pokušavaju prikazati dobiveni rezultati. Profiliranje turista donosi prednosti u vidu maksimizacije profita kroz bolji i kvalitetniji odnos sa kupcima kroz konkurentsku prednost pred ostalim tržišnim sudionicima.

Ključne riječi: rudarenje podataka, turizam, profiliranje

SUMMARY

Technology is gradually advancing how the time goes by. People and companies are obligated to use new methods to keep the track with advances technologies and the changing market. Data mining appeared as a good way to analyze and work with big data in large data sets. The use of data mining is applicable in every industry that exists on the market. With the use of data mining methods we are trying to come to a conclusion based on the example of tourism and his activities. Methods that are used in this process are decision trees, regression analysis, clusters and others. The results are being showed with the use of descriptive statistics and visualization techniques to ease the understanding to the end user. Pattern recognition of tourist behavior is maximizing the profit with a better understanding of the market before the competition.

Key words: data mining, tourism, pattern recognition

LITERATURA

KNJIGE I ZNANSTVENI RADOVI

Akcetin.E, i grupa autora : Data mining: usage and applications in tourism industry, Turkey, 2015

Alfier, D.; Turizam – izbor radova, Institut za turizam, 1994

Antunac I. : Turizam : Teorijsko znanstvene rasprave, Institut za turizam, Zagreb (2001)

Bach P.M. : Rudarenje podataka u bankarstvu, Zbornik ekonomskog fakulteta u Zagrebu,2005

Baum, T., Lundtorp, S. : Seasonality in tourism, Pergamon, Amsterdam ,2001

Bilandžić, M., Čulig, B., Lucić, D., Novoselec, M.P. & Jakšić, J. : Business inteligence u Hrvatskom gospodarstvu, Poslovna izvrsnost, Zagreb (2012) Br. 1

Blažević, B.; Turizam u gospodarskom sustavu, Sveučilište u Rijeci, 2007

Clark, P., Niblett, T. : The CN2 Induction Algorithm , Machine learning, 1989

Cooper ,C. & Fletcher, J. : Tourism, principles and practice, Person Education, 2008

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

Dragutin, A. : Turizam - izbor radova, Institut za turizam , Zagreb , 1990

Javorović, B. & Bilandžić, M.: Poslovne informacije i business intelligence, Golden marketing, Zagreb, 2007

Dulčić A. : Turizam, Institut za turizam Zagreb , 1991

Geić S. : Organizacija i politika turizma, Kulturološki-ekologijski i sociogospodarski aspekti , Sveučilište u Splitu, 2007

Garača, Ž. & Jadrić, M. ; Rudarenje podataka - Različiti aspekti informacijskog društva, Sveučilište u Splitu , 2011

Hand,D. J., Mannila,H.,Smyth.P., : Principles of Data Mining, MIT Press,2001

Fayyad, U., Piatetsky, G., Smyth, and P.: From Data Mining to Knowledge Discovery in Databases, AI Magazine Volume 17 Number 3 (1996)

Kantaradžić, M.; Data Mining: Concepts, Models, Methods, and Algorithms, John Wiley & Sons, 2011

Kotler, P., Bowen, T.J., Makens, J.C.; Marketing for hospitality and Tourism, Pearson International Edition, 2006

Lickorish, L. & Jenkins, C.; Uvod u turizam, EKOKON, Split, 2001

Marušić, M. & Vranešević, T. : Istraživanje tržišta, Adeco, Zagreb, 2001

Marušić,M & Prebežac, D. : Istraživanje turističkih tržišta Adeco, Zagreb, 2004

Malhotra, K., N. : Marketing research, Pearson Education, New Jersey, 2010

Moutinho,L.; Strateški menadžment u turizmu, MASMEDIA, 2005

Panian, Ž., Klepac, G. : Poslovna inteligencija , Masmedia, Zagreb, 2003

Petrić, L.; Osnove turizma, Sveučilište u Splitu, 2013

Pujari, A.K. ; Data Mining Techniques, Universities Press, 2001

Rozga A. ; Statistika za ekonomiste , Ekonomski fakultet u Splitu, 2009

Srivastava, J.; Web Usage Mining: Discovery and Applications of Usage Patterns from Web Data, University of Minessota, 2000

Vukonić, B.: Povijest hrvatskog turizma, Prometej, Zagreb,2005

Washio, T. : Advances in Knowledge Discovery and Data Mining, Osaka, 2008

Zelenika, R. : Znanost o znanosti, Ekonomski fakultet u Rijeci, 2004

Zekić - Sušak,M. :Neuronske mreže i stabla odlučivanja za predviđanje uspješnosti studiranja, Osijek , 2009

ČLANCI

http://analytics.ncsu.edu/sesug/2006/ST16_06.PDF

http://www.skladistenje.com/profil-strucnjaka/

https://www.researchgate.net/publication/233752567_Exploring_visitor_movement_patterns_in_natural_recreational_areas

http://www.turizamiputovanja.com/zasto-je-segmentacija-turista-danas-obavezna/

http://www.unizd.hr/Portals/41/acta%20jadertina/6-leburic-majicafi.pdf

http://what-when-how.com/information-science-and-technology/data-mining-in-tourism-information-science/

http://www.jatrgovac.com/2011/02/istrazivanje-trzista-koristi-tek-jedna-od-10-hrvatskih-tvrtki/

https://www.ibm.com/developerworks/library/ba-data-mining-techniques/

http://www.trogir.hr/GradTrogir/images/stories/Statuti_grbovi_zakoni/Analiza_situacije_Trogir.pdf

WEB STRANICE

http://www.dzs.hr/

http://www.mint.hr/

http://www.iztzg.hr/hr/institut/o_nama/misija/

http://www.kdnuggets.com/

http://www.trackur.com/

http://www2.unwto.org/en

http://www.trogironline.com/hr/trogir.html

http://www.portal-trogir.com/hrvatska/trogir-rivijera/trogir/

POPIS SLIKA I GRAFIKONA

Slika 1. Pokazatelji razvoja turizma

Slika 2. Ukupni dolasci po mjesecima

Slika 3. Djelatnosti koje zapošljavaju stručnjake za rudarenje podataka

Slika 4. Izrada autora - primjer klastera

Slika 5 . Izrada autora - primjer stabla odlučivanja

Slika 6: Primjer neuronskih mreža

Slika 7 . Izrada autora - Primjer linearne regresije

Slika 8 . Izrada autora - Primjer CN2 pravila

Slika 9 . Upotreba istraživanja tržišta u Hrvatskoj

Slika 10. Navike istraživanja tržišta u Hrvatskoj

Slika 11 . Početna baza podataka u excelu

Slika 12. Model u Orange Canvasu

Slika 13. Informacije o modelu

Slika 14. Tablica u Orange Canvasu

Slika 15. Tablica duljine boravka 2014

Slika 16. Tablica duljine boravka 2015

Slika 17. Grafikon duljine boravka prema nacionalnosti 2015

Slika 18. Grafikon prema danima dolaska ovisno o nacionalnosti

Slika 19. Grafikon prema nacionalnosti ovisno o kategoriji smještaja

Slika 20. CN2 pravila prema nacionalnosti ovisno o duljini boravka

Slika 21. Mjesec dolaska prema nacionalnosti

Slika 22. CN2 pravila nacionalnost prema mjesecu dolaska

Slika 23. Stablo odlučivanja prema nacionalnosti u ovisnosti na mjesec dolaska

Slika 24. Analiza ovisno o danu dolaska

Slika 25. Analiza prema kategoriji smještaja

Slika 26. Klasteriranje prema kategoriji smještaja

Slika 27. Analiza duljine boravka

Slika 28. Analiza duljine boravka ovisno o kategoriji smještaja

Slika 29. Stablo odlučivanja prema mjesecu dolaska ovisno o kategoriji smještaja

Slika 30. Analiza posjetioca prema starosti

Slika 31. Stablo odlučivanje prema starosti gostiju ovisno o kategoriji smještaja

Slika 32. Grafikon starosti gostiju prema kategoriji smještaja

Slika 33. Starosna distribucija prema nacionalnosti

Slika 34. Stablo odlučivanja prema starosti posjetioca ovisno o duljini boravka

Slika 35. CN2 pravila duljina boravka