ANALIZA POKAZATELJA TURIZMA U REPUBLICI HRVATSKOJ I USPOREDBA S ODABRANIM KONKURENTIMA

Vulić, Antonia

Undergraduate thesis / Završni rad

2019

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:124:780284

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

ZAVRŠNI RAD

ANALIZA POKAZATELJA TURIZMA U REPUBLICI HRVATSKOJ I USPOREDBA S ODABRANIM KONKURENTIMA

Mentor:

prof. dr. sc. Snježana Pivac

Student:

Antonia Vulić 1160885

Split, rujan 2019.

Sadržaj

1.Uvod 1
2. Turizam u Republici Hrvatskoj 2
2.1. Trend analiza dolazaka u Republici Hrvatskoj 5
2.2. Dekompozicija vremenskog niza broja dolazaka 8
2.3. Regresijski model s trendom i sezonskom komponentom 11
2.2.1. Upotreba modela u prognostičke svrhe 16
3. Kretanja u turizmu u odabranim konkurentskim zemljama 24
4. Zaključak 30
Popis tablica 31
Popis grafova 32
Popis slika 32
Sažetak 33
Summary 33
Literatura 34

1.Uvod

Kretanja u djelatnosti turizma u Republici Hrvatskoj predstavljaju jedan od važnijih faktora ukupnog gospodarskog kretanja.

Upotrebom primijenjenih statističkih modela provodi se trend analiza broja dolazaka i broja noćenja u odabranom razdoblju od 2013. godine (godine kada je Republika Hrvatska pristupila Europskoj Uniji) do zadnje dostupnih podataka za travanj 2019. godine.

Rad je podijeljen u 4 dijela, i to prvi dio koji predstavlja uvodni dio, drugi dio u kojem se prezentiraju kretanja u odabranim pokazateljima djelatnosti turizma. Upotrebom trend modela u drugom poglavlju napravljena je projekcija broja dolazaka do kraja 2019. godine.

Treći dio u kojem se uspoređuju kretanja u djelatnosti turizma u Republici Hrvatskoj sa odabranim mediteranskim konkurentima Grčka, Italija, Francuska, Španjolska i Portugal, te zadnjeg zaključnog dijela u kojem se prezentiraju utvrđene činjenice, te daje preporuka donositeljima političkih odluka.

2. Turizam u Republici Hrvatskoj

Turizam se može definirati na više načina jer postoje brojni faktori koje turizam sadrži i koji imaju utjecaj na njega. Turizam predstavlja skup odnosa i pojava koje su posljedice putovanja i boravka posjetitelja u nekom mjestu, ukoliko boravak ne prelazi u stalno prebivalište i ukoliko boravak nema veze s privrednom djelatnosti posjetitelja. [1]

Prema Svjetskoj turističkoj agenciji „Turizam uključuje sve aktivnosti proizašle iz putovanja i boravaka osoba izvan njihove uobičajene sredine ne dulje od jedne godine radi odmora, poslovnog putovanja i drugih razloga nevezanih uz aktivnosti za koje bi primili ikakvu naknadu u mjestu koje posjećuju. Turist je osoba koja putuje izvan svoje sredine kraće od 12 mjeseci i glavna svrha njezina putovanja nije vezana za obavljanje neke lukrativne aktivnosti u mjestu koje posjećuje.“[2]

Turizam u gospodarstvu ima veliku ulogu te se sa tog stajališta može definirati kao kombinacija odnosa, usluga i ostalih pogodnosti koje turisti koriste, stvorenih zbog potrebe privremenog premještanja ljudi. [3]

Turizam se u Republici Hrvatskoj razvijao u nekoliko faza a Čavlek i Bartoluci (2011) smatraju da se razvoj Hrvatskog turizma može promatrati kroz 6 faza:

1. FAZA (razdoblje preteča turističkog razvoja ili pojava sličnih turizmu)
2. FAZA (kraj 19.stoljeća, odnosno faza znatiželje)
3. FAZA (razdoblje od početka 20. stoljeća do kraja Prvog svjetskog rata, odnosno faza „osvješćivanja“)
4. FAZA (razdoblje između dva svjetska rata, odnosno faza prvih postignuća)
5. FAZA (razdoblje nakon Drugog svjetskog rata, odnosno faza intenzivnog turističkog
1. razvoja)
6. FAZA (razdoblje od 1991. godine do početka 21. stoljeća, odnosno faza oporavka i
2. konsolidacije turističkog života u Hrvatskoj).

Prva faza se temelji na robnoj razmjeni kada su stari Rimljani odlazili u druga mjesta potaknuti željom za nečim što do sada nisu vidjeli. Tako su privukli na putovanja i domaće stanovništvo. Druga faza je vezana za prve ugostiteljske objekte i razvoj turizma i

[1] Marković, S. (1970): "Osnove turizma", Školska knjiga, Zagreb, str. 17.
[2] UNWTO, World Tourism Organization, Turizam, Internet, raspoloživo na: [http://www2.unwto.org/] [25.8.2019.]
[3] Marković, S.(1970): "Osnove turizma", Školska knjiga, Zagreb, str. 29.

infrastrukture u srednjoj Dalmaciji. Na treću fazu su utjecaj imala društveno politička zbivanja i razvoj turizma u zdravstveno-turističkim centrima na Jadranu. Četvrta faza bilježi porast turističkog prometa u RH i otvaranje velikog broja smještajnih kapaciteta. Peta faza je faza nakon Drugog svjetskog rata pa do 1991. godine i može se podijeliti u dvije etape: prva etapa industrijalizacije kada turizam nije u prvom planu i druga etapa koja je poznata kao i zlatno razdoblje za Hrvatsku turizam i traje do 1975. godine. Zadnja šesta etapa obuhvaća razdoblje od samostalnosti do kraja 20. stoljeća i njome dominira privatizacija i restrukturiranje turističkog sustava.[4]

Već u šestoj fazi i dalje, turizam Republike Hrvatske je prošao dugotrajni proces tranzicije usporedno s problemima razvoja zemlje i gospodarstva. Nakon ulaska u Europsku Uniju, 2013. godine, Hrvatski turizam ima priliku razvoja. Hrvatska ima na snazi strategiju razvoja turizma do 2020. godine koja predstavlja konceptualni okvir koji omogućava[5]:

- koordinirano djelovanje nositelja turističke politike i sustavno usuglašavanje mjera turističke politike,
- cjelovito razumijevanje ključnih pravaca razvoja turizma kao preduvjet privlačenja interesa potencijalnih domaćih i stranih ulagača,
- ciljano usmjeravanje razvojno-investicijskog procesa i efikasno povlačenje sredstava EU fondova.

Iz godine u godinu Hrvatska bilježi porast dolazaka i noćenja domaćih i stranih turista. Prema Državnom zavodu za statistiku 2018. godini je u komercijalnim smještajnim objektima ostvareno je 18,7 milijuna dolazaka i 89,7 milijuna noćenja turista. U odnosu na 2017. ostvaren je porast dolazaka turista za 7,1%, te porast noćenja za 4,0%.[6]

Domaći turisti su ostvarili 2,0 milijuna dolazaka i 6,5 milijuna noćenja, što je porast dolazaka za 10,0% i porast noćenja za 8,3% u odnosu na 2017. Strani turisti ostvarili su 16,6 milijuna dolazaka i 83,2 milijuna noćenja, što je 6,7% više dolazaka i 3,7% više noćenja u usporedbi s 2017..[7]

[4] Ibdem.
[5] Ministarstvo turizma RH (2018): Strategija razvoja turizma RH, Narodne novine, Zagreb, 1. polazište
[6] Državni zavod za statistiku (2019): Dolaski i noćenja turista u 2018., Internet, raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/04-03-02_01_2018.htm, [25.8.2019.]
[7] Ibidem.

Najviše noćenja u 2018. godini od strane domaćih turista je zabilježeno u gradu Zagrebu, Crikvenici, Malom Lošinju, Zadru i Vodicama, dok su strani turisti najviše noćili u Dubrovniku, Rovinju, Poreču i Splitu.

Na slici 1 je prikazana struktura noćenja stranih turista prema zemlji prebivališta te je vidljivo da je uvjerljivo najveći broj stranih turista iz Njemačke.

Slika 1: Struktura noćenja stranih turista prema zemlji prebivališta



Izvor: Državni zavod za statistiku (2019): Dolasci i noćenja turista u 2018., Internet, raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/04-03-02_01_2018.htm

Prema podacima sustava eVisitor, tijekom razdoblja siječanj-srpanj 2019. broj dolazaka stranih turista u RH iznosio je 10.109.370 (indeks 103,2) dok je istovremeno zabilježeno 1.390.645 dolazaka domaćih turista (indeks 107,1). U spomenutom vremenskom intervalu ostvareno je 49.961.782 noćenja stranih turista (indeks 100,2) kao i 6.905.465 noćenja domaćih turista (indeks 105,4). Sveukupni (strani i domaći) broj dolazaka u promatranom razdoblju iznosio je za 11.500.015 dolazaka (indeks 103,7), dok je zabilježeno 56.867.247 noćenja (indeks 100,8).[8]

Prema zadnjim aktualnim podacima za srpanj 2019. godine ukupni turistički promet (strani i domaći turisti), u srpnju iznosi 4.596.685 dolazaka (indeks 99,3) i 30.525.549 noćenja (indeks 98,7). Većina turističkog prometa u srpnju 2019. je registrirana u komercijalnim smještajnim objektima. Najviše turističkog prometa u hotelskom smještaju ostvareno je u objektima s 4 zvjezdice (44 %), a potom slijede objekti s 3 zvjezdice (34 %).

[8] Hrvatska turistička zajednica (2019): Informacija o statističkim pokazateljima turističkog prometa, Internet, raspoloživo na: https://htz.hr/sites/default/files/2019-08/Informacija%20o%20statisti%C4%8Dkim%20pokazateljima%20-%20srpanj%202019.pdf ,[1.9.2019.]

2.1. Trend analiza dolazaka u Republici Hrvatskoj

U ovom dijelu rada upotrebom trend analize promatra se kretanje broja dolazaka u Republici Hrvatskoj.

Tablica 1: Linearni trend model

Regression Summary for Dependent Variable: Broj dolazaka R= ,11102470 R2= ,01232648 Adjusted R2= ----- F(1,74)=,92354 p

	b*	Std.Err. - of b*	b	Std.Err. - of b	t(74)	p-value
Intercept			980602,5	289530,3	3,386873	0,001135
Vrijeme	0,111025	0,115529	6404,4	6664,2	0,961012	0,339676

Izvor: Eurostat, obrada autora

Iz tablice se može utvrditi da je očekivan broj dolazaka 980.602,5 turista u ishodišnom mjesecu. Parametar beta nula je statistički značajan (empirijska p vrijednost 0,0011), dok parametar beta jedan nije statistički značajan (emp. p=0,340). Vrijednost koeficijenta determinacije (R^2) 0,0123 upućuje na zaključak da svega 1,23% sume kvadrata odstupanja ostvarenog broja dolazaka od aritmetičke sredine je protumačeno modelom. Model nije reprezentativan. Statistička značajnost modela kao cjeline testira se ANOVA testom.

Tablica 2: ANOVA

Analysis of Variance; DV: Republika Hrvatska (Kopija datoteke BAZA PODATAKA ++ trend (B2:BY77))

	Sums of - Squares	df	Mean - Squares	F	p-value
Regress.	1,500179E+12	1	1,500179E+12	0,923544	0,339676
Residual	1,202035E+14	74	1,624372E+12		
Total	1,217037E+14				

Izvor: Eurostat, obrada autora

Na temelju empirijske F vrijednosti 0,92 može se donijeti zaključak da model kao cjelina nije statistički značajan. Zaključak je donesen na temelju empirijske p vrijednosti 0,340. Kretanje broja dolazaka i modelom pretpostavljen broj dolazaka prikazan je grafički.

Outliersi – vrijednosti koje bitno odstupaju od očekivanih vrijednosti

Outliersi su ostvareni brojevi noćenja koji značajno odstupaju modelom predviđenih vrijednosti. U ovom radu je korišten kriterij dvaju vrijednosti standardne devijacije.

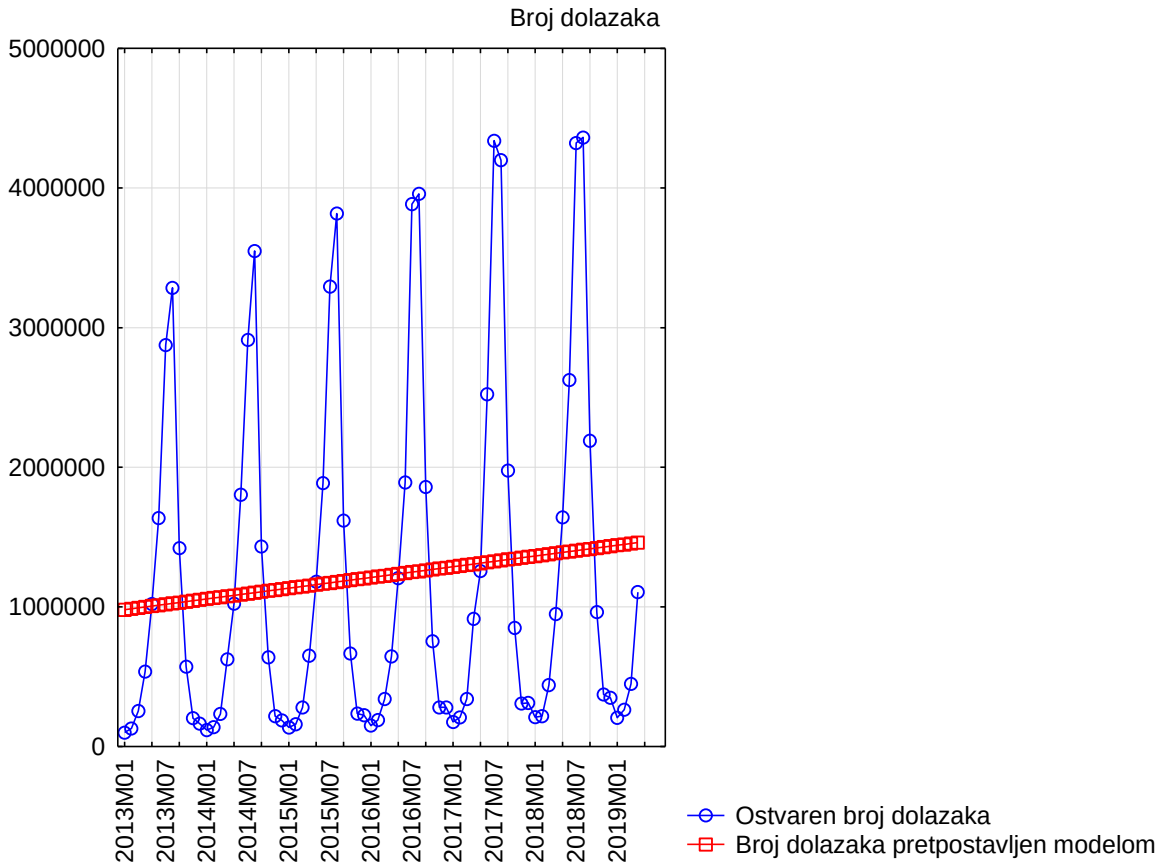
Kao outliersi se javljaju ostvareni brojevi dolazaka za kolovoz 2015; 2016; 2017 i 2018, te srpanj 2016; 2017 i 2018. godine.

Tablica 3: Outliers vrijednosti

Standard Residual: Republika Hrvatska Outliers						
	Observed - Value	**Predicted - Value**	**Residual**	**Standard - Pred. v.**	**Standard - Residual**	**Std.Err. - Pred.Val**
2015M08 . . . |* . . .	3816778	1179139	2637639	-0,294342	2,069534	152478,6
2016M07 . . . |* . . .	3884757	1249588	2635169	0,203775	2,067596	149240,3
2016M08 . . . |* . . .	3957707	1255992	2701715	0,249058	2,119809	150720,9
2017M07 . . . | * . . .	4339219	1326441	3012778	0,747175	2,363875	182933,1
2017M08 . . . |* . . .	4198752	1332845	2865907	0,792458	2,248637	187014,7
2018M07 . . . |* . . .	4323635	1403294	2920341	1,290575	2,291347	239681,1
2018M08 . . . |* . . .	4362735	1409698	2953037	1,335859	2,317001	244995,8
Minimum . . . |* . . .	3816778	1179139	2635169	-0,294342	2,067596	149240,3
Maximum . . . | * . . .	4362735	1409698	3012778	1,335859	2,363875	244995,8
Mean . . . |* . . .	4126226	1308143	2818084	0,617794	2,211114	186723,5
Median . . . |* . . .	4198752	1326441	2865907	0,747175	2,248637	182933,1

Izvor: Eurostat, obrada autora

Graf 1: Ostvareni broj dolazaka i broj dolazaka pretpostavljen modelom



Izvor: Eurostat, obrada autora

Iz grafičkog prikaza se može utvrditi da najniže i najviše vrijednosti imaju tendenciju porasta, no postoje značajne sezonske oscilacije unutar svake od promatranih godina, slijedom čega se u nastavku radi dekompozicija vremenskog niza.

2.2. Dekompozicija vremenskog niza broja dolazaka

Za potrebe dekompozicije vremenskog niza radi se multiplikativni model gdje se vremenski niz razlaže na trend komponentu, cikličku komponentu, sezonsku komponentu, te slučajnu (iregularnu) komponentu.

Tablica 4: Dekompozicija vremenskog niza

Seasonal Decomposition: Multipl. season (12) Republika Hrvatska							
	Republika Hrvatska	**Moving - Averages**	**Ratios**	**Seasonal - Factors**	**Adjusted - Series**	**Smoothed - Trend-c.**	**Irreg. - Compon.**
1	101384			12,6265	802946	885527	0,906744
2	130245			14,4365	902195	906977	0,994728
3	254308			25,0355	1015791	949878	1,069391
4	536681			58,4979	917437	977294	0,938752
5	1021223			96,4034	1059322	1002687	1,056483
6	1638619			165,3643	990914	1011018	0,980116
7	2875790	1017142	282,7323	283,6855	1013725	1026762	0,987303
8	3285818	1018532	322,6032	309,1409	1062887	1029309	1,032622
9	1421317	1019223	139,4511	137,6238	1032755	1023652	1,008893
10	572883	1017440	56,3063	57,7941	991248	995017	0,996212
11	203606	1024919	19,8656	20,5122	992607	962637	1,031134
12	163834	1025086	15,9825	18,8793	867797	934393	0,928728
13	118066	1038936	11,3641	12,6265	935064	931428	1,003905
14	138526	1041882	13,2957	14,4365	959557	949793	1,010280
15	232915	1063852	21,8936	25,0355	930340	983146	0,946289
16	626430	1064916	58,8244	58,4979	1070859	1027448	1,042251
17	1023225	1070477	95,5859	96,4034	1061399	1051699	1,009223
18	1804824	1071631	168,4185	165,3643	1091423	1074274	1,015963
19	2911143	1073567	271,1655	283,6855	1026187	1073463	0,955959
20	3549453	1075205	330,1189	309,1409	1148167	1086564	1,056695
21	1434081	1076977	133,1580	137,6238	1042030	1080239	0,964629
22	639619	1080973	59,1707	57,7941	1106720	1073718	1,030736
23	217451	1083034	20,0779	20,5122	1060103	1056469	1,003440
24	187070	1096135	17,0663	18,8793	990874	1054205	0,939925
25	137717	1103014	12,4855	12,6265	1090697	1072179	1,017272
26	159797	1135055	14,0783	14,4365	1106899	1094428	1,011395
27	280865	1157332	24,2683	25,0355	1121868	1124540	0,997624
28	651167	1172681	55,5281	58,4979	1113146	1142262	0,974511
29	1180431	1175081	100,4553	96,4034	1224470	1162887	1,052957
30	1887375	1176626	160,4057	165,3643	1141343	1171578	0,974193

31	3295638	1179752	279,3500	283,6855	1161722	1181940	0,982894
32	3816778	1180812	323,2334	309,1409	1234640	1186332	1,040721
33	1618262	1183317	136,7564	137,6238	1175859	1180243	0,996285
34	668424	1188277	56,2516	57,7941	1156560	1171842	0,986959
35	235991	1187812	19,8677	20,5122	1150488	1167887	0,985102
36	224581	1189981	18,8726	18,8793	1189562	1191574	0,998312
37	150434	1190392	12,6373	12,6265	1191414	1232632	0,966561
38	189856	1239485	15,3173	14,4365	1315115	1260061	1,043692
39	340382	1251229	27,2038	25,0355	1359599	1262127	1,077228
40	645592	1271408	50,7777	58,4979	1103616	1221381	0,903580
41	1206463	1278692	94,3513	96,4034	1251473	1219921	1,025864
42	1892303	1282500	147,5480	165,3643	1144324	1228726	0,931309
43	3884757	1287216	301,7953	283,6855	1369389	1284505	1,066083
44	3957707	1289425	306,9358	309,1409	1280227	1303911	0,981836
45	1860406	1291025	144,1030	137,6238	1351805	1330455	1,016047
46	755835	1291157	58,5393	57,7941	1307806	1349227	0,969300
47	281679	1313633	21,4427	20,5122	1373224	1385236	0,991328
48	281177	1317781	21,3372	18,8793	1489340	1419232	1,049399
49	176942	1370422	12,9115	12,6265	1401353	1424236	0,983933
50	209055	1408294	14,8446	14,4365	1448105	1436994	1,007732
51	341973	1428381	23,9413	25,0355	1365954	1425320	0,958349
52	915303	1438130	63,6454	58,4979	1564677	1445175	1,082691
53	1256237	1445967	86,8787	96,4034	1303104	1442984	0,903062
54	2523994	1448136	174,2926	165,3643	1526323	1463026	1,043265
55	4339219	1450828	299,0857	283,6855	1529588	1455302	1,051045
56	4198752	1453631	288,8458	309,1409	1358200	1444917	0,939985
57	1977390	1454474	135,9523	137,6238	1436808	1444180	0,994895
58	849882	1462664	58,1051	57,7941	1470534	1478237	0,994789
59	307713	1465581	20,9960	20,5122	1500143	1540764	0,973635
60	313477	1497710	20,9304	18,8793	1660427	1589521	1,044608
61	210575	1506205	13,9805	12,6265	1667721	1624332	1,026712
62	219167	1504907	14,5635	14,4365	1518150	1632433	0,929992
63	440255	1518572	28,9914	25,0355	1758525	1659076	1,059942
64	950314	1536270	61,8585	58,4979	1624527	1655869	0,981072
65	1641784	1545704	106,2159	96,4034	1703035	1646302	1,034461
66	2625937	1551086	169,2966	165,3643	1587971	1583771	1,002651
67	4323635	1554078	278,2122	283,6855	1524095	1540542	0,989324
68	4362735	1553831	280,7728	309,1409	1411245	1524284	0,925841
69	2189770	1557607	140,5856	137,6238	1591127	1585311	1,003669
70	963084	1558382	61,8003	57,7941	1666405	1674817	0,994977
71	372302	1571332	23,6934	20,5122	1815023	1746051	1,039502
72	349379			18,8793	1850593	1774302	1,042998
73	207613			12,6265	1644263	1767622	0,930211

74	264471			14,4365	1831966	1790729	1,023028
75	449555			25,0355	1795672	1839278	0,976292
76	1105724			58,4979	1890195	1863552	1,014297

Izvor: Eurostat, obrada autora

Pomični prosjek (CMA)

Vrijednost pomičnog prosjeka se dobije kao aritmetička sredina od 6 vrijednosti prije razdoblja za koje se računa pomični prosjek, broja dolazaka u razdoblju za koje se računa pomični prosjek, te 6 razdoblja nakon razdoblja za koje se računa pomični prosjek gdje se prvom i zadnjem promatranom mjesecu dodjeljuje ponder 1/24, dok se ostalim mjesecima dodjeljuje ponder 1/12.

Sezonski faktor:

U drugom koraku postupka se računa sezonski faktor pomoću omjera između izvornih i vrijednosti pomičnih prosjeka.

Tablica 5: Sezonski faktor

Mjesec	Seasonal - Factors
1	12,6265
2	14,4365
3	25,0355
4	58,4979
5	96,4034
6	165,3643
7	283,6855
8	309,1409
9	137,6238
10	57,7941
11	20,5122
12	18,8793

Izvor: Eurostat, obrada autora

Sezonski faktor ukazuje na kretanje broja noćenja uz uključeno djelovanje sezone, pa tako npr. za mjesec siječanj će broj noćenja biti za 87,37% manji zbog djelovanja sezonskog faktora.

Isključivanjem sezonske komponente iz kretanja dobije se „adjusted“ kretanje koje uz korekciju za iregularnu komponentu (neobjašnjiva komponenta) daje kretanje pročišćeno od sezonskih utjecaja (smoothed values).

2.3. Regresijski model s trendom i sezonskom komponentom

Upotrebom regresijske analize testira se utjecaj trenda i sezonskih kretanja na broj dolazaka.

U prvom koraku se kreira dummy matrica sa brojem mjeseci za jedan manjim u odnosu na broj dummy razdoblja gdje se ispušta prvi mjesec kao mjesec sa najmanje ostvarenih noćenja, te se parametri uz ostale dummy varijable tumače kao promjena u odnosu na ispušteni mjesec promatranja (siječanj).

Tablica 6: Dummy matrica

Regression Summary for Dependent Variable: Republika Hrvatska R= ,98956105 R2= ,97923107 Adjusted R2= ,97527509 F(12,63)=247,53 p

	b*	Std.Err. - of b*	b	Std.Err. - of b	t(63)	p-value
Intercept			-146594	84643,7	-1,73190	0,088186
M2	0,004872	0,024468	21321	107071,9	0,19913	0,842801
M3	0,036538	0,024471	159893	107087,4	1,49311	0,140401
M4	0,135512	0,024477	593010	107113,2	5,53630	0,000001
M5	0,230336	0,023751	1080923	111458,4	9,69799	0,000000
M6	0,407663	0,023748	1913090	111443,6	17,16645	0,000000
M7	0,734632	0,023747	3447497	111438,6	30,93629	0,000000
M8	0,787563	0,023748	3695893	111443,6	33,16381	0,000000
M9	0,335784	0,023751	1575775	111458,4	14,13778	0,000000
M10	0,119064	0,023756	558744	111483,2	5,01191	0,000005
M11	0,016720	0,023764	78465	111518,0	0,70361	0,484266
M12	0,011396	0,023773	53480	111562,6	0,47937	0,633333
Vrijeme	0,146451	0,018228	8448	1051,5	8,03425	0,000000

Izvor: Eurostat, obrada autora

Vrijednost parametra 8.884 uz varijablu trend znači da se u svakom narednom mjesecu može očekivati porast broja dolazaka u prosjeku za 8.448 dolazaka. Parametar je statistički značajan (emp. p <0,001).

Parametri uz dummy varijablu veljača, ožujak, studeni i prosinac nisu statistički značajne, iz čega se može donijeti zaključak da u navedenim mjesecima se ne ostvaruje statistički značajno veći broj dolazaka u odnosu na mjesec siječanj (emp. p vrijednosti > 0,050).

Parametri uz varijable travanj, svibanj, lipanj, srpanj, kolovoz, rujan i listopad su statistički značajni gdje je najviša vrijednost parametra utvrđena za mjesec kolovoz gdje je zabilježena vrijednost 3.695.893 što znači da se u kolovozu može očekivati za 3.695.893 dolazaka u odnosu na siječanj zbog sezonskih utjecaja (emp. p<0,001).

Tablica 7: Rezidualna odstupanja

Standard Residual: Republika Hrvatska Outliers

	Observed - Value	Predicted - Value	Residual	Standard - Pred. v.	Standard - Residual	Std.Err. - Pred.Val
2013M08 . . . * | . . .	2875790	3351591	-475801	1,690377	-2,37540	87646,99
2014M08 . . . * | . . .	2911143	3452967	-541824	1,770798	-2,70501	83935,37
2017M08 . . . | *. . .	4339219	3757094	582125	2,012061	2,90622	83935,37
2018M08 . . . |* . . .	4323635	3858470	465166	2,092482	2,32230	87646,99
Minimum . . . * | . . .	2875790	3351591	-541824	1,690377	-2,70501	83935,37
Maximum . . . | *. . .	4339219	3858470	582125	2,092482	2,90622	87646,99
Mean . . . |* . . .	3612447	3605030	7416	1,891430	0,03703	85791,18
Median . . . |* . . .	3617389	3605030	-5318	1,891430	-0,02655	85791,18

Izvor: Eurostat, obrada autora

Prognostičke vrijednosti značajnije odstupaju od ostvarenih vrijednosti u kolovozima, i to 2013., 2014., 2017., te 2018. godine.

Tablica 8: Analiza varijance

Analysis of Variance; DV: Republika Hrvatska

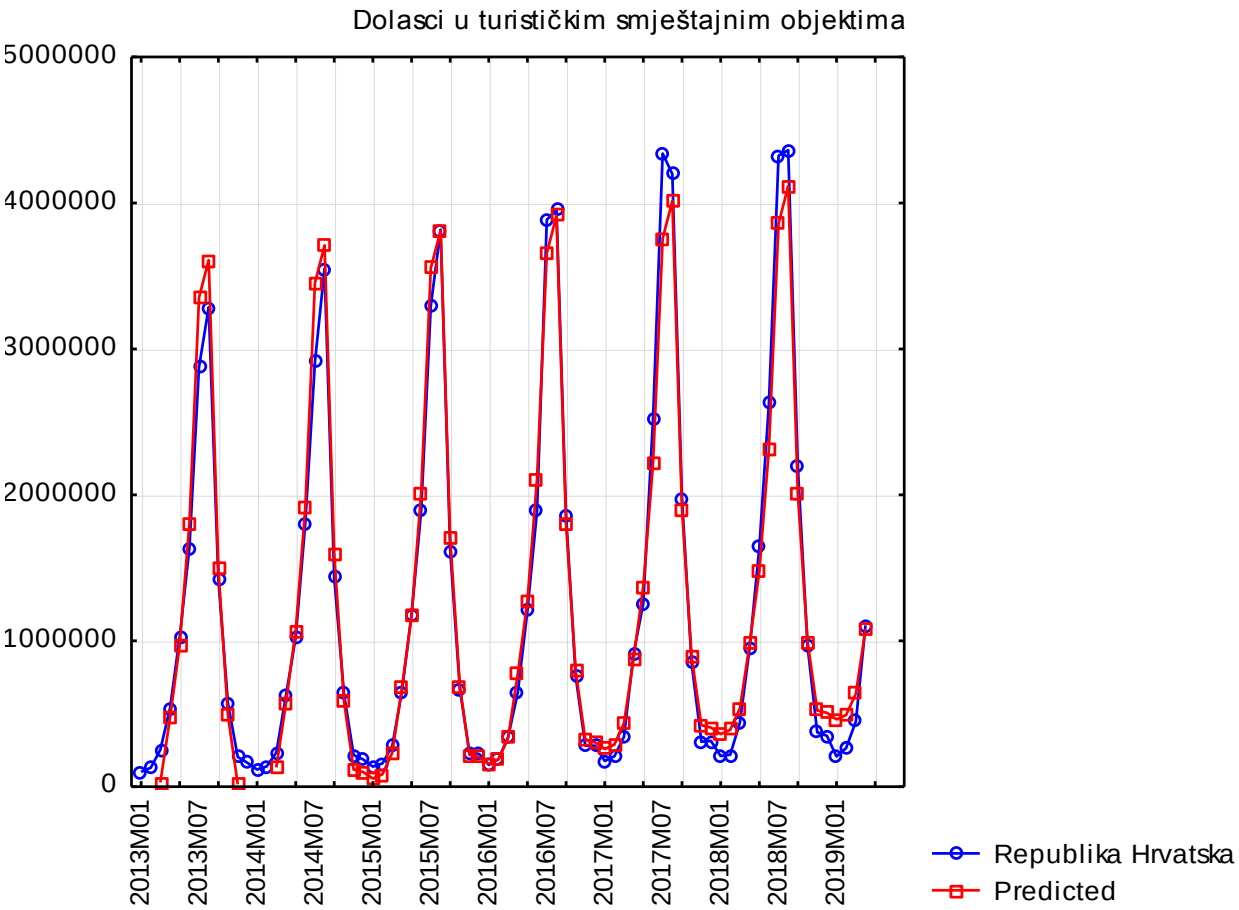
	Sums of - Squares	df	Mean - Squares	F	p-value
Regress.	1,191760E+14	12	9,931337E+12	247,5315	<0,001
Residual	2,527655E+12	63	4,012151E+10		
Total	1,217037E+14				

Izvor: Eurostat, obrada autora

Na temelju empirijske F vrijednosti 247,53 može se donijeti zaključak da je procijenjeni model kao cjelina statistički značajan. Zaključak je donesen na temelju empirijske p vrijednosti <0,001. Kretanje ostvarenog broja noćenja i projekcije upotrebom modela prikazan je grafički.

Procijenjeni model tumači 97,53% sume kvadrata odstupanja broja noćenja od aritmetičke sredine. Riječ je o reprezentativnom modelu (R^2=97,53%).

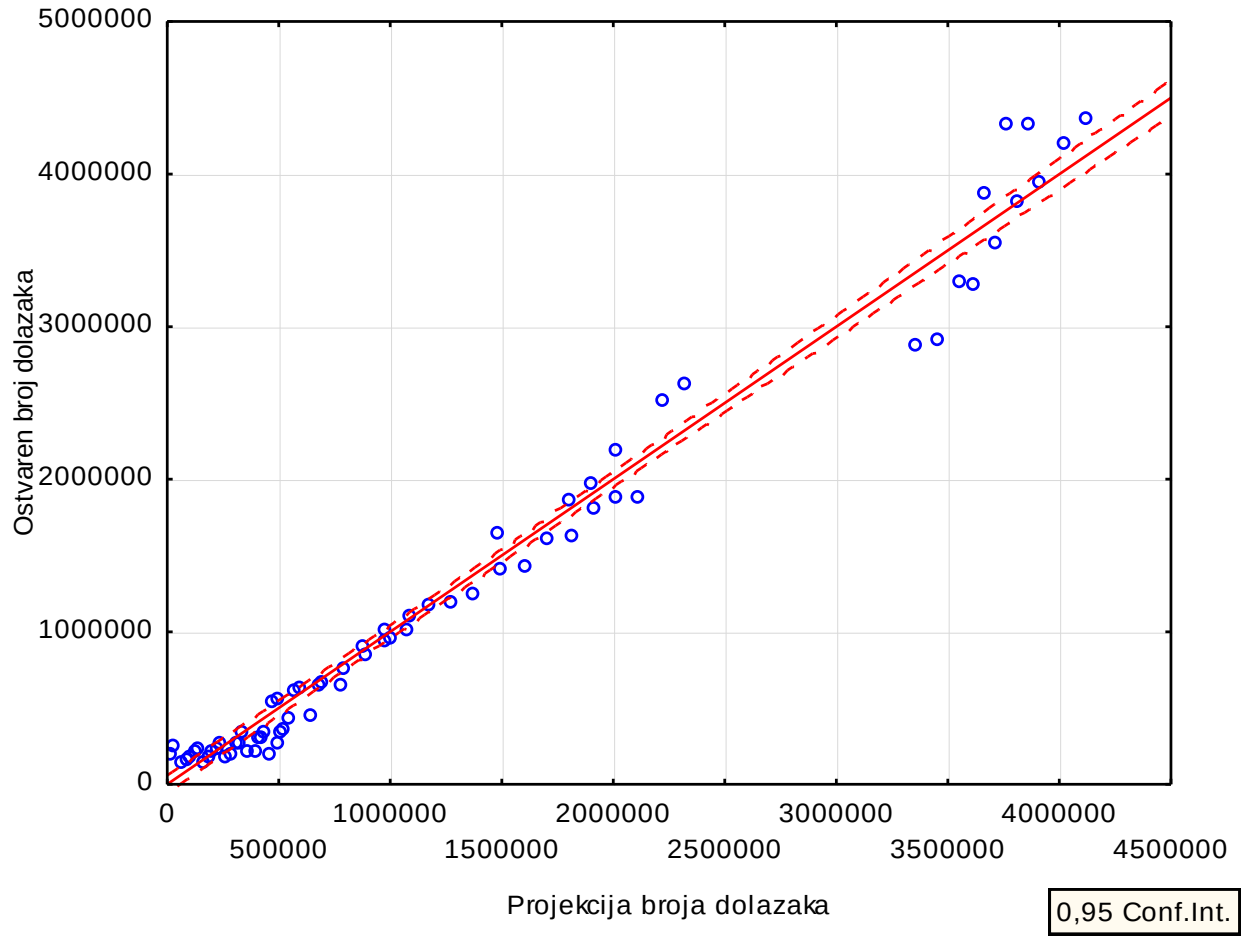
Graf 2: Ostvaren i očekivan broj dolazaka



Izvor: Eurostat, obrada autora

Iz grafičkog prikaza se može utvrditi da procijenjeni regresijski model pobliže prati ostvarena kretanja broja dolazaka, zbog čega je primjeren za korištenje za projekcije u budućnosti.

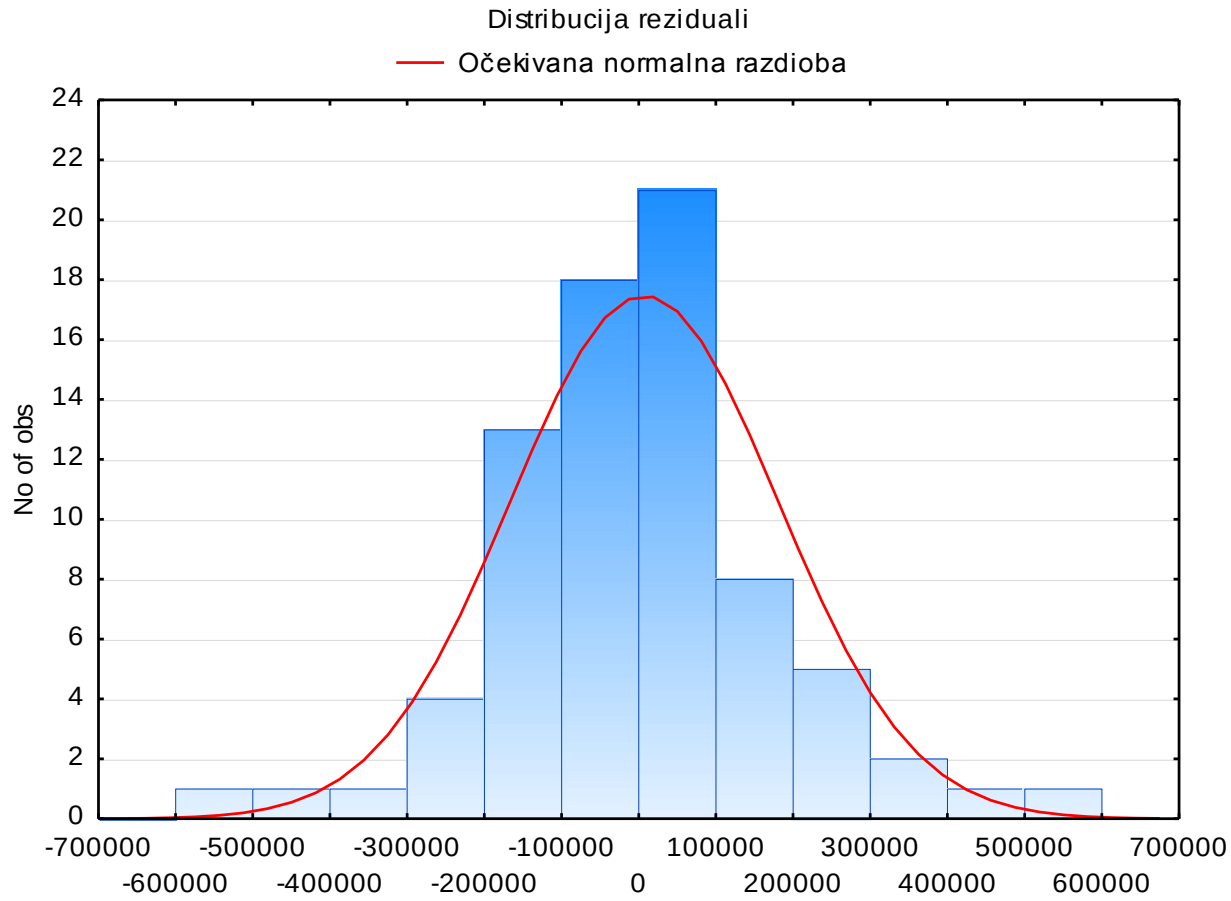
Graf 3: Odstupanja ostvarenog i očekivanog broja dolazaka



Izvor: Eurostat, obrada autora

Iz grafičkog prikaza se može utvrditi da prognoza broja dolazaka upotrebom modela pobliže prati ostvaren broj noćenja gdje je utvrđena veća preciznost kod ostvarenog manjeg broja dolazaka u odnosu na mjesece kada je zabilježen veći broj dolazaka, odnosno u mjesecima srpanj i kolovoz.

Graf 4: Rezidualna odstupanja broja dolazaka



Izvor: Eurostat, obrada autora

Rezidualna odstupanja su približno normalno distribuirana sa očekivanom vrijednosti nula.

2.2.1. Upotreba modela u prognostičke svrhe

Tablica 9: Prognoza broja dolazaka u svibnju 2019. godine upotrebom modela

Predicting Values for variable: Republika Hrvatska			
	b-Weight	**Value**	**b-Weight - * Value**
M2	21321	0,00000	0
M3	159893	0,00000	0
M4	593010	0,00000	0
M5	1080923	1,00000	1080923
M6	1913090	0,00000	0
M7	3447497	0,00000	0
M8	3695893	0,00000	0
M9	1575775	0,00000	0
M10	558744	0,00000	0
M11	78465	0,00000	0
M12	53480	0,00000	0
Vrijeme	8448	76,00000	642046
Intercept			-146594
Predicted			1576375
-95,0%CL			1390656
+95,0%CL			1762095

Izvor: Eurostat, obrada autora

Prema procijenjenom modelu se u svibnju 2019. godine može očekivati 1.576.375 dolazaka, dok će se broj dolazaka pri razini pouzdanosti od 95% kretati u rasponu od 1.390.656 do 1.762.095 dolazaka.

Tablica 10: Prognoza broja dolazaka u lipnju 2019. godine upotrebom modela

Predicting Values for variable: Republika Hrvatska			
	b-Weight	**Value**	**b-Weight - * Value**
M2	21321	0,00000	0
M3	159893	0,00000	0
M4	593010	0,00000	0
M5	1080923	0,00000	0
M6	1913090	1,00000	1913090
M7	3447497	0,00000	0
M8	3695893	0,00000	0
M9	1575775	0,00000	0
M10	558744	0,00000	0
M11	78465	0,00000	0
M12	53480	0,00000	0
Vrijeme	8448	77,00000	650494
Intercept			-146594
Predicted			2416990
-95,0%CL			2231271
+95,0%CL			2602710

Izvor: Eurostat, obrada autora

Prema procijenjenom modelu se u lipnju 2019. godine može očekivati 2.416.990 dolazaka, dok će se broj dolazaka pri razini pouzdanosti od 95% kretati u rasponu od 2.231.271 do 2.602.710 dolazaka.

Tablica 11: Prognoza broja dolazaka u srpnju 2019. godine upotrebom modela

Predicting Values for variable: Republika Hrvatska			
	b-Weight	**Value**	**b-Weight - * Value**
M2	21321	0,00000	0
M3	159893	0,00000	0
M4	593010	0,00000	0
M5	1080923	0,00000	0
M6	1913090	0,00000	0
M7	3447497	1,00000	3447497
M8	3695893	0,00000	0
M9	1575775	0,00000	0
M10	558744	0,00000	0
M11	78465	0,00000	0
M12	53480	0,00000	0
Vrijeme	8448	78,00000	658942
Intercept			-146594
Predicted			3959845
-95,0%CL			3774126
+95,0%CL			4145565

Izvor: Eurostat, obrada autora

Prema procijenjenom modelu se u srpnju 2019. godine može očekivati 3.959.845 dolazaka, dok će se broj dolazaka pri razini pouzdanosti od 95% kretati u rasponu od 3.774.126 do 4.145.565 dolazaka.

Tablica 12: Prognoza broja dolazaka u kolovozu 2019. godine upotrebom modela

Predicting Values for variable: Republika Hrvatska			
	b-Weight	**Value**	**b-Weight - * Value**
M2	21321	0,00000	0
M3	159893	0,00000	0
M4	593010	0,00000	0
M5	1080923	0,00000	0
M6	1913090	0,00000	0
M7	3447497	0,00000	0
M8	3695893	1,00000	3695893
M9	1575775	0,00000	0
M10	558744	0,00000	0
M11	78465	0,00000	0
M12	53480	0,00000	0
Vrijeme	8448	79,00000	667390
Intercept			-146594
Predicted			4216689
-95,0%CL			4030969
+95,0%CL			4402408

Izvor: Eurostat, obrada autora

Prema procijenjenom modelu se u kolovozu 2019. godine može očekivati 4.216.689 dolazaka, dok će se broj dolazaka pri razini pouzdanosti od 95% kretati u rasponu od 4.030.969 do 4.402.408 dolazaka.

Tablica 13: Prognoza broja dolazaka u rujnu 2019. godine upotrebom modela

Predicting Values for variable: Republika Hrvatska			
	b-Weight	**Value**	**b-Weight - * Value**
M2	21321	0,00000	0
M3	159893	0,00000	0
M4	593010	0,00000	0
M5	1080923	0,00000	0
M6	1913090	0,00000	0
M7	3447497	0,00000	0
M8	3695893	0,00000	0
M9	1575775	1,00000	1575775
M10	558744	0,00000	0
M11	78465	0,00000	0
M12	53480	0,00000	0
Vrijeme	8448	80,00000	675838
Intercept			-146594
Predicted			2105019
-95,0%CL			1919300
+95,0%CL			2290739

Izvor: Eurostat, obrada autora

Prema procijenjenom modelu se u rujnu 2019. godine može očekivati 2.105.019 dolazaka, dok će se broj dolazaka pri razini pouzdanosti od 95% kretati u rasponu od 1.919.300 do 2.290.739 dolazaka.

Tablica 14: Prognoza broja dolazaka u listopadu 2019. godine upotrebom modela

Predicting Values for variable: Republika Hrvatska			
	b-Weight	**Value**	**b-Weight - * Value**
M2	21321	0,00000	0
M3	159893	0,00000	0
M4	593010	0,00000	0
M5	1080923	0,00000	0
M6	1913090	0,00000	0
M7	3447497	0,00000	0
M8	3695893	0,00000	0
M9	1575775	0,00000	0
M10	558744	1,00000	558744
M11	78465	0,00000	0
M12	53480	0,00000	0
Vrijeme	8448	81,00000	684286
Intercept			-146594
Predicted			1096436
-95,0%CL			910716
+95,0%CL			1282156

Izvor: Eurostat, obrada autora

Prema procijenjenom modelu se u listopadu 2019. godine može očekivati 1.096.436 dolazaka, dok će se broj dolazaka pri razini pouzdanosti od 95% kretati u rasponu od 910.716 do 1.282.156 dolazaka.

Tablica 15: Prognoza broja dolazaka u studenom 2019. godine upotrebom modela

Predicting Values for variable: Republika Hrvatska			
	b-Weight	**Value**	**b-Weight - * Value**
M2	21321	0,00000	0
M3	159893	0,00000	0
M4	593010	0,00000	0
M5	1080923	0,00000	0
M6	1913090	0,00000	0
M7	3447497	0,00000	0
M8	3695893	0,00000	0
M9	1575775	0,00000	0
M10	558744	0,00000	0
M11	78465	1,00000	78465
M12	53480	0,00000	0
Vrijeme	8448	82,00000	692734
Intercept			-146594
Predicted			624605
-95,0%CL			438886
+95,0%CL			810325

Izvor: Eurostat, obrada autora

Prema procijenjenom modelu se u studenom 2019. godine može očekivati 624.605 dolazaka, dok će se broj dolazaka pri razini pouzdanosti od 95% kretati u rasponu od 438.886 do 810.325 dolazaka.

Tablica 16: Prognoza broja dolazaka u prosincu 2019. godine upotrebom modela

Predicting Values for variable: Republika Hrvatska			
	b-Weight	**Value**	**b-Weight - * Value**
M2	21321	0,00000	0
M3	159893	0,00000	0
M4	593010	0,00000	0
M5	1080923	0,00000	0
M6	1913090	0,00000	0
M7	3447497	0,00000	0
M8	3695893	0,00000	0
M9	1575775	0,00000	0
M10	558744	0,00000	0
M11	78465	0,00000	0
M12	53480	1,00000	53480
Vrijeme	8448	83,00000	701182
Intercept			-146594
Predicted			608068
-95,0%CL			422348
+95,0%CL			793787

Izvor: Eurostat, obrada autora

Prema procijenjenom modelu se u prosincu 2019. godine može očekivati 608.068 dolazaka, dok će se broj dolazaka pri razini pouzdanosti od 95% kretati u rasponu od 422.348 do 793.787 dolazaka.

3. Kretanja u turizmu u odabranim konkurentskim zemljama

U ovom dijelu rada promatraju se kretanja u pokazateljima turizma, te se promatra položaj Republike Hrvatske u odnosu na odabrane mediteranske zemlje (Grčka, Italija, Francuska, Španjolska i Portugal).

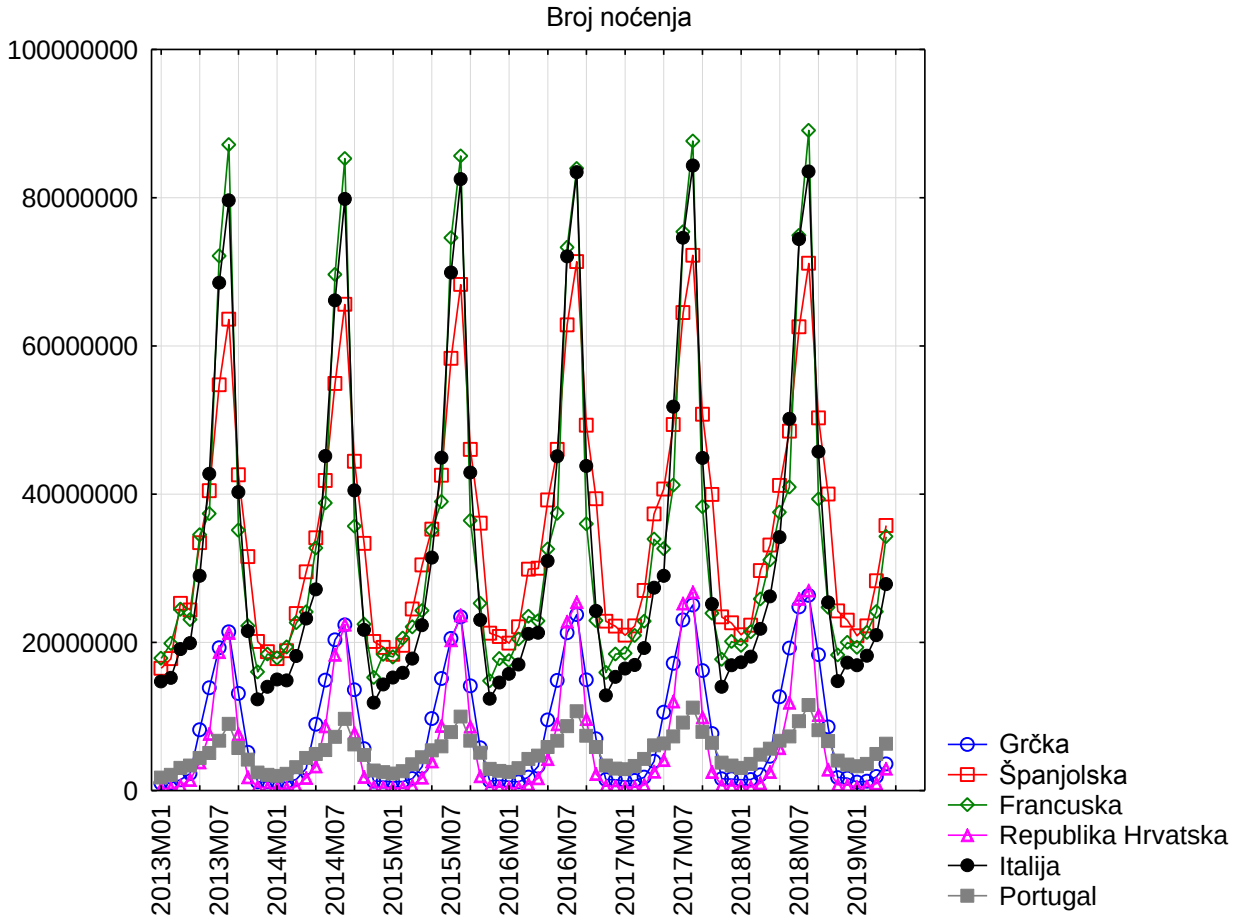
Tablica 17: Broj noćenja u odabranim zemljama za razdoblje od siječnja 2013. do travnja 2019.

	N	Mean	Std.Dev.	Median	Minimum	Maximum	Q1	Q3	V (%)
Grčka	76	8248976	8133485	3763096	995142	26324192	1458313	14871383	98,60
Španjolska	76	35717931	15672886	32358175	16507093	72232990	22227435	45232250	43,88
Francuska	76	34259057	21344952	24210955	14822874	89076280	19906603	37469078	62,30
Republika Hrvatska	76	6057118	8157442	1815801	266707	27015502	538065	8692004	134,68
Italija	76	32681023	21831319	22679199	11848965	84301529	16887117	44346880	66,80
Portugal	76	5201451	2420624	4823426	1761303	11529632	3186133	6701740	46,54

Izvor: Eurostat, obrada autora

Najveći prosječan mjesečni broj noćenja u promatranom razdoblju je imala Španjolska gdje je utvrđen prosječan broj dolazaka 35.717.931 sa prosječnim odstupanjem od aritmetičke sredine 15.572.886 noćenja. Riječ je o velikoj disperziji (V=62,30). Republika Hrvatska je uz Portugal ostvarila najmanji broj noćenja, te su u Republici Hrvatskoj utvrđene najveće oscilacije u broju dolazaka (V=134,68%).

Graf 5: Kretanje broja noćenja u odabranim zemljama



Izvor: Eurostat, obrada autora

Iz grafičkog prikaza se može utvrditi da je broj noćenja u Republici Hrvatskoj imao ciklična kretanja unutar svake kalendarske godine, te je navedeno specifično za sve odabrane mediteranske zemlje. Prema obujmu broja noćenja Francuska ostvaruje veći broj noćenja u ljetnim mjesecima u odnosu na ostale promatrane zemlje, dok prema broju noćenja prednjači Španjolska, odnosno Francuska ima izražene godišnje cikluse.

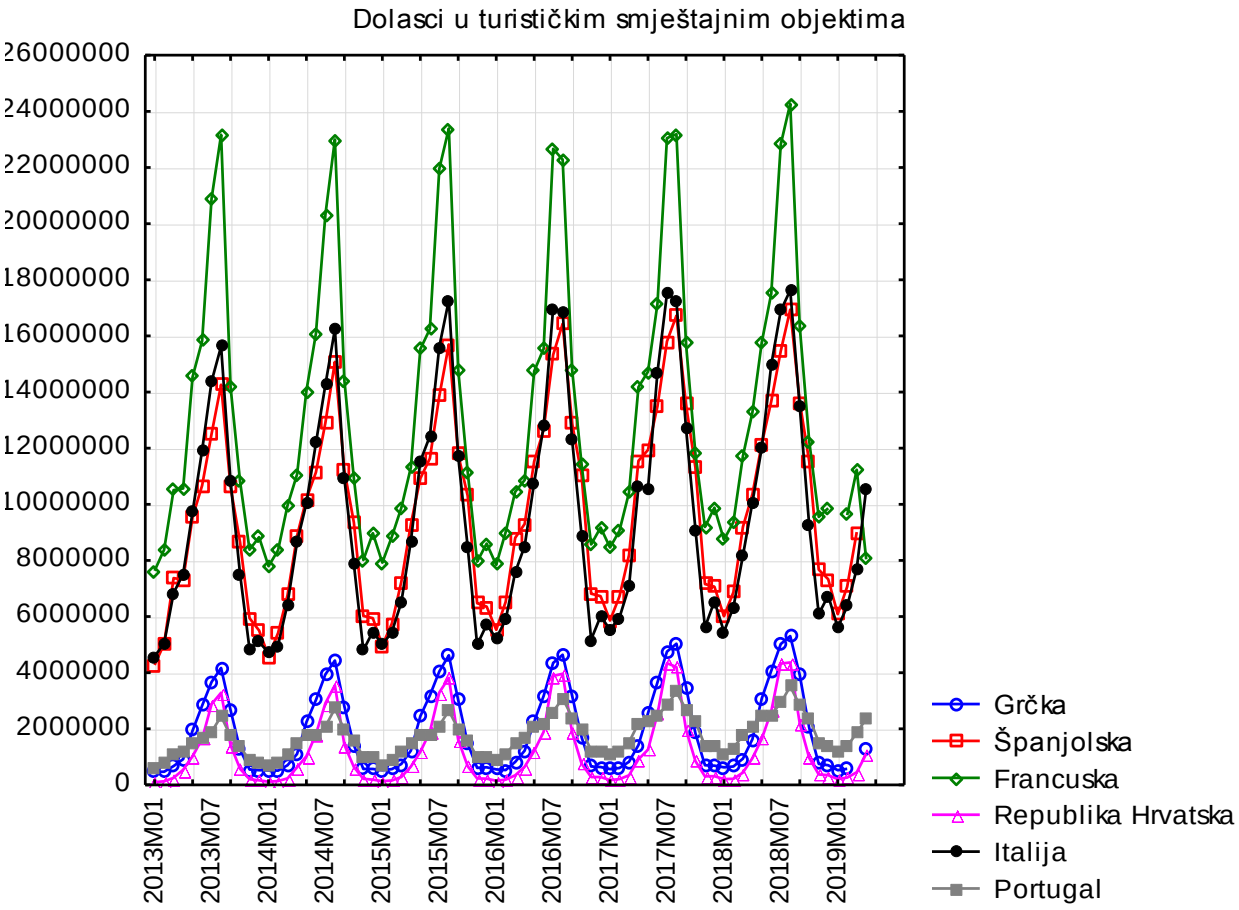
Tablica 18: Dolasci u turističkim smještajnim objektima za razdoblje od siječnja 2013. do travnja 2019.

	N	Mean	Std.Dev.	Median	Minimum	Maximum	Q1	Q3	V (%)
Grčka	75	1946563	1499605	1284531	467136	5302134	627417	3172791	77,04
Španjolska	75	9723814	3432186	9299163	4272599	16935719	6724608	12154208	35,30
Francuska	75	13183504	4943301	11228915	7630563	24274193	9055287	15774208	37,50
Republika Hrvatska	76	1220768	1273859	648380	101384	4362735	234453	1832615	104,35
Italija	76	9490525	4013636	8583862	4577247	17626911	5924597	12229112	42,29
Portugal	76	1725720	686705	1620148	618486	3513152	1160053	2231646	39,79

Izvor: Eurostat, obrada autora

Najveći broj dolazaka u turističke smještajne objekte je imala Francuska (prosječan mjesečni broj 13.183.504), dok je Republika Hrvatska bilježila u prosjeku najmanji broj gostiju (1.220.768 dolazaka) uz izražena odstupanja (V=104,35%). Najmanje oscilacije u dolascima ostvaruje Španjolska (V=35,30).

Graf 6: Kretanje broja dolazaka u odabranim zemljama



Izvor: Eurostat, obrada autora

Broj dolazaka je najveći u Francuskoj, te bilježi oscilacije u cijelom promatranom razdoblju kao i ostale promatrane zemlje. Republika Hrvatska u zimskim mjesecima ostvaruje manji broj dolazaka u odnosu na sve promatrane mediteranske zemlje.

Tablica 19: Prosječan broj noćenja po dolasku u odabranim zemljama za razdoblje od siječnja 2013. do travnja 2019.

	N	Mean	Std. Dev.	Median	Minimum	Maximum	Q1	Q3	V(%)
Grčka	75	3,43	1,21	2,79	2,12	5,25	2,24	4,71	35,25
Španjolska	75	3,59	0,36	3,50	3,13	4,46	3,31	3,79	10,01
Francuska	75	2,46	0,56	2,29	1,86	4,26	2,15	2,41	22,66
Republika Hrvatska	76	3,51	1,51	2,72	2,06	6,50	2,31	4,74	42,90
Italija	76	3,19	0,74	2,86	2,43	5,10	2,69	3,55	23,20
Portugal	76	2,95	0,30	2,86	2,46	3,77	2,74	3,10	10,15

Izvor: Eurostat, obrada autora

Najveći broj noćenja po dolasku se ostvaruje u Španjolskoj gdje je utvrđen prosječan broj noćenja, nakon čega slijedi Republika Hrvatska sa prosječnim brojem noćenja 3,51. Najmanji prosječan broj noćenja ostvaren je u Francuskoj gdje je utvrđen prosječan broj 2,46. Španjolska uz najveći prosječan broj noćenja ostvaruje i najmanje oscilacije (V=10,01%), dok su najveće oscilacije utvrđene u Republici Hrvatskoj (V=42,90%).

Tablica 20: Korelacija broja dolazaka među odabranim zemljama

	Grčka	Španjolska	Francuska	Republika Hrvatska	Italija	Portugal
Grčka	1					
	p= ---					
Španjolska	0,9603	1				
	p=0,00	p= ---				
Francuska	0,9713	0,9465	1			
	p=0,00	p=0,00	p= ---			
Republika Hrvatska	0,9737	0,9282	0,9795	1		
	p=0,00	p=0,00	p=0,00	p= ---		
Italija	0,9842	0,9763	0,9837	0,9683	1	
	p=0,00	p=0,00	p=0,00	p=0,00	p= ---	
Portugal	0,9103	0,9708	0,8815	0,8758	0,9207	1
	p=0,00	p=0,00	p=0,00	p=0,00	p=0,00	p= ---

Izvor: Eurostat, obrada autora

Testiranjem povezanosti između ostvarenog broja dolazaka među odabranim Europskim zemljama je utvrđeno postojanje statistički značajne jake korelacije, odnosno porast broja noćenja u svakoj od promatranih zemlja je praćen porastom broja dolazaka u ostalim promatranim zemljama. Svi koeficijenti korelacije (r) prelaze vrijednost 0,80, dok su sve empirijske p vrijednosti <0,001.

Tablica 21: Korelacija broja noćenja među odabranim zemljama

	Grčka	Španjolska	Francuska	Republika Hrvatska	Italija	Portugal
Grčka	1					
	p= ---					
Španjolska	0,972	1				
	p=0,00	p= ---				
Francuska	0,9214	0,9368	1			
	p=0,00	p=0,00	p= ---			
Republika Hrvatska	0,9518	0,946	0,9792	1		
	p=0,00	p=0,00	p=0,00	p= ---		
Italija	0,9699	0,9695	0,9824	0,9878	1	
	p=0,00	p=0,00	p=0,00	p=0,00	p= ---	
Portugal	0,9321	0,981	0,8942	0,8998	0,9251	1
	p=0,00	p=0,00	p=0,00	p=0,00	p=0,00	p= ---

Izvor: Eurostat, obrada autora

Testiranjem povezanosti između ostvarenog broja noćenja među odabranim Europskim zemljama je utvrđeno postojanje statistički značajne jake korelacije, odnosno porast broja noćenja u svakoj od promatranih zemlja je praćen porastom broja noćenja u ostalim promatranim zemljama. Svi koeficijenti korelacije (r) prelaze vrijednost 0,80, dok su sve empirijske p vrijednosti <0,001.

4. Zaključak

U ovom radu na temelju podataka o broju dolazaka i broju noćenja napravljena je trend analiza u svrhu prognoze, te su uspoređene vrijednosti koje se odnose na Republiku Hrvatsku sa odabranim mediteranskim zemljama Grčka, Italija, Francuska, Španjolska i Portugal.

Nakon provedene analize utvrđeno je postojanje značajnih sezonskih oscilacija u broju dolazaka i broju noćenja u Republici Hrvatskoj. Jednaka kretanja su utvrđena i u ostalim odabranim europskim zemljama, no uz manje sezonske oscilacije u odnosu na Republiku Hrvatsku koja je bilježila najveće vrijednosti relativnog pokazatelja koeficijenta varijacije.

Republika Hrvatska je površinski manja, te posjeduje i bitno manji broj smještajnih jedinica, bitno manji broj dolazaka i broj noćenja u odnosu na odabrane zemlje izuzev Portugala kod pokazatelja broja noćenja koji je ostvario manji broj noćenja u odnosu na Republiku Hrvatsku.

Španjolska je ostvarila veći broj noćenja u odnosu na Francusku koja je imala veći broj dolazaka.

Kad se stavi u omjer broj noćenja i broj dolazaka Francuska kao zemlja sa najvećim brojem dolazaka je ostvarila najmanji broj noćenja, odnosno turisti koji posjećuju Francusku se najmanje zadržavaju u Francuskoj. Francuska kao lider među odabranim zemljama u broju dolazaka ne pruža dovoljno sadržaja koji bi pružili dodatne dane boravka.

Republika Hrvatska nakon Španjolske je zauzela drugo mjesto sa prosječnim brojem noćenja od 3,51 noćenje po dolasku.

Testiranjem povezanosti između broja dolazaka među odabranim zemljama utvrđena je jaka korelacija jednako kao i kod broja noćenja.

Republika Hrvatska bi trebala provoditi mjere fiskalne politike koje će poticati razvoj oblika turizma u zimskim mjesecima u kojima je utvrđen bitno manji broj dolazaka u odnosu na ljetne mjesece.

Popis tablica

Tablica 1: Linearni trend model 5
Tablica 2: ANOVA 5
Tablica 3: Outliers vrijednosti 6
Tablica 4: Dekompozicija vremenskog niza 8
Tablica 5: Sezonski faktor 10
Tablica 6: Dummy matrica 11
Tablica 7: Rezidualna odstupanja 12
Tablica 8: Analiza varijance 12
Tablica 9: Prognoza broja dolazaka u svibnju 2019. godine upotrebom modela 16
Tablica 10: Prognoza broja dolazaka u lipnju 2019. godine upotrebom modela 17
Tablica 11: Prognoza broja dolazaka u srpnju 2019. godine upotrebom modela 18
Tablica 12: Prognoza broja dolazaka u kolovozu 2019. godine upotrebom modela 19
Tablica 13: Prognoza broja dolazaka u rujnu 2019. godine upotrebom modela 20
Tablica 14: Prognoza broja dolazaka u listopadu 2019. godine upotrebom modela 21
Tablica 15: Prognoza broja dolazaka u studenom 2019. godine upotrebom modela 22
Tablica 16: Prognoza broja dolazaka u prosincu 2019. godine upotrebom modela 23
Tablica 17: Broj noćenja u odabranim zemljama 24
Tablica 18: Dolasci u turističkim smještajnim objektima 26
Tablica 19: Prosječan broj noćenja po dolasku u odabranim zemljama. 27
Tablica 20: Korelacija broja dolazaka među odabranim zemljama 28
Tablica 21: Korelacija broja noćenja među odabranim zemljama 29

Popis grafova

Graf 1: Ostvareni broj dolazaka i broj dolazaka pretpostavljen modelom 7

Graf 2: Ostvaren i očekivan broj dolazaka 13

Graf 3: Odstupanja ostvarenog i očekivanog broja dolazaka 14

Graf 4: Rezidualna odstupanja broja dolazaka 15

Graf 5: Kretanje broja noćenja u odabranim zemljama 25

Graf 6: Kretanje broja dolazaka u odabranim zemljama 27

Popis slika

Slika 1: Struktura noćenja stranih turista prema zemlji prebivališta 4

Sažetak

Republika Hrvatska ima gospodarstvo orijentirano prema turističkoj djelatnosti. Uspoređujući podatke o broju dolazaka utvrđeno je da Republika Hrvatska bilježi manji broj dolazaka u odnosu na Grčku, Italiju, Francusku, Španjolsku i Portugal. Broj noćenja je veći od ostvarenog broja noćenja Portugala. Najveće oscilacije u promatranom razdoblju su utvrđene u Republici Hrvatskoj, dok je po pokazatelju broja noćenja po dolasku Republika Hrvatska na drugom mjestu nakon Španjolske u kojoj turisti u prosjeku najdulje borave po dolasku.

Summary

The Republic of Croatia has a tourism-oriented economy. Comparing data on the number of arrivals, Croatia found that the number of arrivals was lower than in Greece, Italy, France, Spain and Portugal. The number of nights is higher than the number of nights spent in Portugal. The largest oscillations in the observed area were determined in the Republic of Croatia, while the number of overnight stays upon arrival of the Republic of Croatia came second after Spain, where the tourist average is the longest stay by arrival.

Literatura

1. Bartoluci M., i Čavlek N. (2011) Turizam - ekonomske osnove i organizacijski sustav. Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu, Zagreb
2. Državni zavod za statistiku (2019): Dolasci i noćenja turista u 2018., Internet, raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/04-03-02_01_2018.htm, [25.8.2019.]
3. Eurostat, www.eurostat.eu [25.8.2019.]
4. Hrvatska turistička zajednica (2019): Informacija o statističkim pokazateljima turističkog prometa, Internet, raspoloživo na: https://htz.hr/sites/default/files/2019-08/Informacija%20o%20statisti%C4%8Dkim%20pokazateljima%20-%20srpanj%202019.pdf ,[1.9.2019.]
5. Marković, S. (1970): "Osnove turizma", Školska knjiga, Zagreb
6. Ministarstvo turizma RH (2018): Strategija razvoja turizma RH, Narodne novine, Zagreb, 1. polazište
7. Pivac S. (2010), Statističke metode, e-nastavni materijali, Ekonomski fakultet u Splitu, Split
8. Rozga, A: Statistika za ekonomiste, EFST 2017
9. UNWTO, World Tourism Organization, Turizam, Internet, raspoloživo na: [http://www2.unwto.org/] [25.8.2019.]