Tonći Svilokos, dipl. oec.
Znanstveni novak
Fakultet za turizam i vanjsku trgovinu Dubrovnik
E-mail: tonci.svilokos@ftvt.hr

PREDVIĐANJE TURISTIČKOG PROMETA GRADA DUBROVNIKA PRIMJENOM ODABRANIH MODELA PROGNOZIRANJA

UDK/UDC: 796.5
JEL klasifikacija/JEL classification: C13, L83
Stručni rad/Professional paper
Primljeno/Received: 12. rujan 2003./September 12, 2003
Prihvaćeno za tisak/Accepted for publishing: 26. studenog 2003/November 26, 2003

Sažetak

U radu se prezentira način korištenja složenijih modela za prognoziranje sezonskih pojava. U prvom dijelu se kratko opisuju prognozirana pojava te političko i ekonomsko stanje u kojem se nalazi turizam grada Dubrovnika. Uz to se daje pristup koji se koristi u analizi vremenske serije. Promet turista je izrazito sezonska pojava, stoga se prikazuju načini utvrđivanja prisutnosti sezonske komponente u vremenskoj seriji pomoću odgovarajućih testova sezonalnosti. U radu se opisuju dva modela prognoziranja sezonske pojave. To su model pomičnih prosjeka i Holt-Wintersov multiplikativni model eksponencijalnog izglađivanja. Primjenom navedenih modela prognozira se broj dolazaka turista na područje grada Dubrovnika. Uz pomoć standardnih pokazatelja uspješnosti prognoze vrednuje se uspješnost modela.

Ključne riječi: turistički promet, modeli prognoziranja, komponente vremenske serije.

UVOD

Prognoziranje je aktivnost kojom se nastoji predvidjeti neki događaj, vrijeme kada će do toga doći, kao i njegov intenzitet i posljedice. Čovjek oduvijek nastoji predvidjeti budućnost. Nastoji doći do informacija koje su ključne za njegove akcije. Razvojem statistike, matematike i informatike ovo se područje ljudskog djelovanja tretira sa znanstvenog gledišta te se odgovori na postavljena pitanja nastoje dati znanstvenim metodama.

Danas su poznate brojne metode prognoziranja a njihov odabir ovisi o troškovima njihove implementacije, o vrsti pojave koja se prognozira, o raspoloživim informacijama kao temelju prognoze kao i o osposobljenosti osoblja u poduzeću da primjeni određenu metodologiju rada. Odluku o odabiru pristupa donosi manager. Da bi on mogao donijeti pravu odluku u svezi s ovim pitanjem mora znati kakve su mu informacije potrebne, način kako do njih doći i procijeniti troškove.

Osnovna podjela metoda prognoziranja je podjela na kvalitativne i kvantitativne metode. Kvalitativne metode često se još nazivaju i subjektivne ili metode procjene jer se temelje na mišljenju, procjeni, stečenom iskustvu i poznavanju pojava. Najpoznatije kvalitativne metode koje se koriste u praksi su metoda prosudbe uprave i Delphi metoda.

Što se tiče kvantitativnih metoda, prvenstveno može se reći da se one temelje na znanstvenom pristupu, u analizi vremenskih serija uzimaju u obzir razinu prognozirane pojave u prošlosti. Dakle, metode se baziraju na uspostavi obrasca ponašanja pojave u tom vremenu, te na primjeni tako dobivenog modela u prognozi. Dijelimo ih na analizu vremenskih serija i kauzalne tehnike.

Cilj ovog rada je da pokaže način korištenja kvantitativne metode analize vremenske serije na primjeru prognoziranja turističkog prometa grada Dubrovnika. Postoje brojni modeli prognoziranja, od naivnih status quo modela pa do ARIMA (p, d, q)(P, D, Q) modela koji su znatno kompleksniji, i mogu se koristiti u tu svrhu. Svrha ovog rada nije da samo navede vrste modela ili da ukaže na njihove dobre i loše strane, već da predoči detaljniju analizu nekih od njih i da pokaže tehniku izračuna koju je također prilikom odabira i uporabe modela potrebno dobro poznavati.

1. TURIZAM GRADA DUBROVNIKA

Turizam je vodeći pokretač gospodarstva grada Dubrovnika. Izuzetne prirodne atraktivnosti, kultura, povijesna baština razlogom su razvitka turizma kao zamašnjaka razvoja cijele Dubrovačko – neretvanske županije. Tradicionalno opredjeljenje za turizam te usmjeravanje ostalih gospodarskih aktivnosti prema iskorištavanju komparativnih prednosti kao osnove za njegov razvoj dovelo je do izgradnje brojnih turističkih kapaciteta. Turistički kapaciteti i njihov daljnji razvoj su pretpostavka za jačanje turističkog prometa.

Turističko gospodarstvo grada Dubrovnika ostvarivalo je u prošlosti značajan devizni priljev. U 1990. godini ostvaren je devizni priljev iz turizma u iznosu od 315 milijuna USD, što je činilo 16 % deviznog priljeva u turizmu Republike Hrvatske[1]. Navedeni podaci se odnose na predratno stanje. Međutim, od 1990. do 1995. godine Dubrovnik je bio gotovo izbrisan s turističke karte. Zbog ratnih aktivnosti takvi rezultati se ni približno nisu mogli ponoviti. Primjerice u 1991. godini ostvareno je svega 14,6 % ukupnih noćenja iz 1990. godine[2]. Nastala šteta nije samo u izgubljenom prometu iz tih ratnih godina. Posljedice su se osjećale i znatno kasnije, poslije 1995. godine. Razlog tome je ogromno razaranje i totalno uništenje mnogih hotelskih i ugostiteljskih kapaciteta. Osim materijalne štete, ovo područje je pretrpjelo i velike kadrovske gubitke. Stručna radna snaga je dijelom otišla u inozemstvo i u razvijenije dijelove Hrvatske, neki pojedinci su se prekvalificirali. Odljevom radne snage, koja je bila uglavnom kvalitetnija od prosjeka, smanjila se ukupna usluga u turizmu.

U svezi s tim, može se reći da je uz ulaganje u hotelsku, prometnu i ostalu infrastrukturu u funkciji turizma potrebno ulagati i u kadrove. Turizam je radno intenzivna djelatnost. Profitabilan turizam počiva na kvalitetnom kadru i to ne samo na nižoj razini usluge, već i na višoj razini donošenja odluka. Stoga je poznavanje načina upotrebe ekonometrijskih alata koji nam služe u pribavljanju ključnih informacija kako na mikro tako i na makro razini donošenje odluka od izuzetnog značenja. U svakodnevnoj poslovnoj praksi uočava se da većina managera nevoljko koristi

[1] Grupa autora, Turizam kao pokretač razvoja općine Dubrovnik, Zavod za društveno planiranje, ekonomiku i statistiku općine Dubrovnik, Dubrovnik, studeni 1989. str. 58.

[2] Grupa autora, Đ. Benić, red., Strategija razvoja županije Dubrovačko-neretvanske, FTVT, Dubrovnik, 2002. str. 133.

ekonometrijske modele. Razlozi za to su brojni, ali najznačajniji je njihova nedovoljna obrazovanost glede korištenja modela. Mnogi nisu upoznati s tehnikom rada ekonometrijskih modela i prednostima koje se njihovom uporabom mogu ostvariti.

Kada analiziramo podatke o dolasku turista na područje grada Dubrovnika, potrebno je imati u vidu tempo obnavljanja oštećenih kapaciteta i tempo njihove privatizacije. U 1996. godini za prihvat turista je bilo spremno tek 35% kreveta u odnosu na prijeratno razdoblje. Za očekivati je da će se u doglednoj budućnosti ostvariti obnova već postojećih kapaciteta, dodatno ulaganje u već obnovljene, prvenstveno u cilju povećanja kategorizacije objekata, jer bi se na taj način mogli postići viša cijena i veća mogućnost za ostvarivanje profita. U tom smislu od izuzetnog značenja je i privatizacija hotela kao temelja za ostvarivanje boljeg turističkog prometa. Za sada privatizacija nije provedena na planirani način. Privatizirana su 1996. godine samo tri hotela i to hotel "Petka", "Jadran" i "Villa Dubrovnik". U daljnjem razdoblju su privatizirani: "HTC Babin Kuk", te hoteli "Excelsior" i "Dubravka" u cijelosti, a u mnogim hotelima država kontrolira većinski dio upravljačkog paketa dionica[3]. Za očekivati je da će se nastaviti privatizacija preostalih kapaciteta, a samim tim i dodatna ulaganja novih vlasnika koji će zasigurno morati uložiti određen kapital u funkciji poboljšanja kategorizacije i povećanja ukupnih smještajnih kapaciteta.

Prilikom donošenja odluka o ulaganju u neko područje investitori su zainteresirani za podatke o očekivanom broju dolazaka turista. Isto tako, prilikom donošenja ukupne makropolitike regije, političari su također zainteresirani za podatke o očekivanom broju dolazaka turista. I za donošenje odluke u hotelskom managementu potrebni su isti podaci. Dakle, za spomenute pokazatelje su zainteresirane brojne strane, a do njih se dolazi pomoću ekonometrijskih modela.

2. DEKOMPONIRANJE VREMENSKE SERIJE – POLAZNA TOČKA ANALIZE VREMENSKE SERIJE

Početak analize svake vremenske serije karakterizira dekomponiranje tj. pokušaj da se odrede njezine četiri komponente. Komponente vremenske serije su: trend, sezona, ciklus, koje spadaju u sistematske komponente i slučajna komponenta tj.

[3] Bukvić I. Utjecaj strukture smještajnih kapaciteta na efikasnost turističke ponude Dubrovnika, Ekonomska misao i praksa, Dubrovnik, god XI. (2002) br. 2 str. 264

nesistematska komponenta. Ove se komponente mogu najlakše primijetiti promatranjem grafičkog prikaza vremenske serije. Svaka vremenska serija se ne mora sastojati od svih navedenih komponenata. Međutim, u prvom susretu s vremenskom serijom potrebno ih je identificirati.

Trend se odnosi na dugotrajnu razvojnu tendenciju serije. On se najčešće prikazuje linearnom ili eksponencijalnom funkcijom.

Sezonska komponenta obuhvaća periodično fluktuiranje serije unutar jedne godine. Sezonsko fluktuiranje uglavnom prati društvene pojave kao što su turizam, gustoću prometa na nekoj prometnici, određene gospodarske aktivnosti, zatim, promjene u meteorološkom vremenu itd.[4]

Ciklička komponenta obuhvaća periodično fluktuiranje vremenske serije u periodu dužem od jedne godine dana. Dakle, vrlo je slična periodičnom kretanju sezonske komponente, a glavna razlika je u trajanju. Druga razlika između ovih dvaju komponenata je činjenica da kod cikličnog kretanja kretanje nije striktno vezano za jednake vremenske razmake. Takvo kretanje je poznato u gospodarskom ciklusu, a sastoji se od ekspanzije, recesije, oporavka te ponovno ekspanzije. Utvrđivanje ovakvog kretanja je u praksi vrlo teško jer se često ne raspolaže s dovoljno dugim nizom podataka neophodnih za primjećivanje takvog kretanja. Iz tih se razloga trend komponenta može smatrati cikličnom komponentom beskonačnog perioda i često se ciklična i trend komponenta ne razdvajaju.

Slučajna ili nesistematska komponenta obuhvaća sve ono što je preostalo nakon izdvajanja trenda, sezonske i ciklus komponente. Često se ta komponenta naziva i šum. Ona obuhvaća neregularne promjene.

Vremenska serija se može prikazati dekomponirano aditivnim ili multiplikativnim modelom:

Aditivni model: $Y_t = \hat{T}_t + \hat{S}_t + \hat{C}_t + \hat{I}_t$ (1)

Multiplikativni model: $Y_t = \hat{T}_t \cdot \hat{S}_t \cdot \hat{C}_t \cdot \hat{I}_t$ (2)

Gdje su:

[4] Šošić I., Serdar V. Uvod u statistiku, Školska knjiga, Zagreb 1994. str. 200

$\hat{T}_t$: Procijenjena trend komponenta

$\hat{S}_t$: Procijenjena sezonska komponenta

$\hat{C}_t$: Procijenjena ciklus komponenta

$\hat{I}_t$: Procijenjena slučajna komponenta

U aditivnom modelu komponente se zbrajaju i izražene su u mjernim jedinicama kojima se pojava mjeri. U multiplikativnom modelu samo se trend komponenta mjeri u mjernim jedinicama, a sve ostale komponente su indeksi. Bazna vrijednost indeksa je 1 ili 100.

3. ODABIR MODELA I TEHNIKE PROGNOZIRANJA

U odabiru metode prognoziranja potrebno je voditi računa o troškovima prognoziranja u odnosu na njezinu korisnost. Kada se govori o troškovima onda se prvenstveno misli na troškove novca i vremena. Troškovi nastaju prilikom prikupljanja podataka, njihovog unošenja i čuvanja. U troškove se također ubrajaju trošak upotrebe kompjutora i statističkih programa, trošak obrazovanja stručnjaka koji koriste programe, upotrebljavaju metode, i interpretiraju podatke, razumiju ih i prenose ih managementu u razumljivom i korisnom obliku.

Neki podaci se mogu dobiti prilično jednostavno, dostupni su preko Interneta i besplatni su, dok se do nekih drugih podataka dolazi znatno teže te je potrebno platiti značajan iznos da bi ih se moglo dobiti. Podaci prikupljeni unutar poduzeća nisu besplatni. Njihovo bilježenje zahtjeva određen trošak i taj se trošak mora uzeti u obzir. Trošak vremena rada brzih računala više nije toliko relevantan, ali je trošak nabave statističkih programa važan, a obrazovanja stručnjaka još i više.

Da bi se govorilo o uspješnosti prognoze potrebno je izmjeriti točnost prognoziranja. Dakle, odabiremo takav model koji će nam dati željenu ili prihvatljivu razinu točnosti s obzirom na trošak prognoziranja.

Često u upotrebi unutar poduzeća već postoji neki model prognoziranja. Tada, za odluku o zamjeni tekućeg modela novim treba usporediti korisnost koja bi se mogla ostvariti upotrebom novog modela s obzirom na trenutno upotrebljavani. U analizu se uključuju dodatni troškovi implementacije novog modela. Odluka o vrsti modela koji će se primijeniti ovisi o tome da li nam je potrebna kratkoročna prognoza za kratkoročno planiranje ili, pak, dugoročna za dugoročno planiranje. Na kraju, možemo dodati da su struktura podataka, veličina serije kao i njezine osobine osnova za prognozu i značajno utječu na odabir modela.

Odabir modela možemo prikazati dijagramom toka:

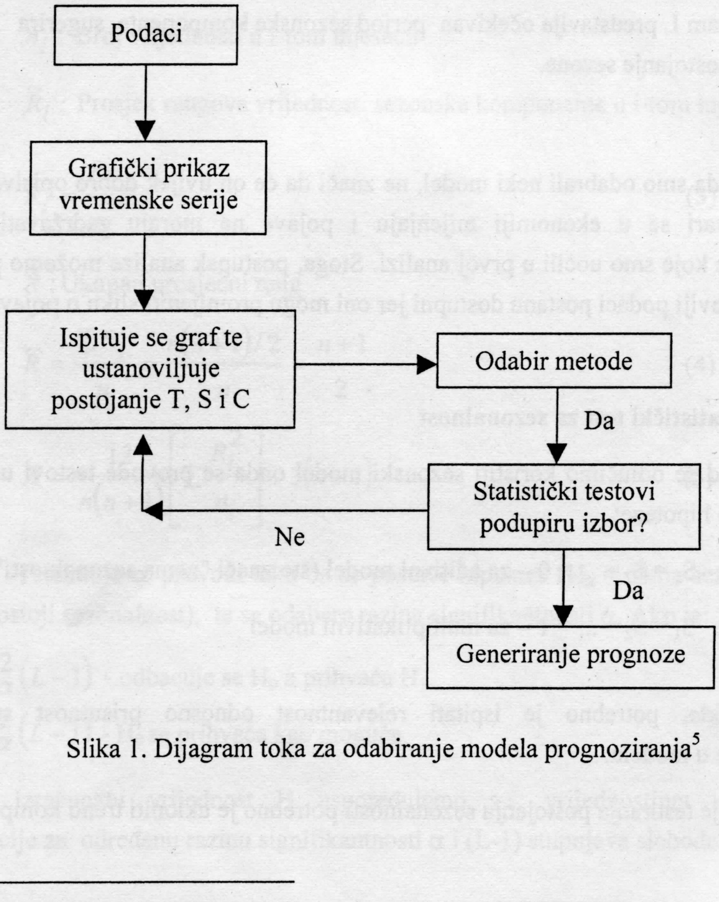

Slika 1. Dijagram toka za odabiranje modela prognoziranja[5]

[5] Farnum, N., R., Stanton L. W., Quantitative forecasting methods, IRWIN, 1987, str. 39.

Na primjer, kad se donosi odluka o uporabi sezonskih modela, vodi se računa o slijedećem:

1. Što nam sugerira naše prethodno znanje i iskustvo koje imamo u svezi pojave? Je li nam iz prijašnjih iskustava poznato da je pojava pod utjecajem vremenskih ili nekih drugih sezonskih činitelja?

2. Proučiti grafički prikaz serije i utvrditi što nam on sugerira. Ako možemo primijetiti kretanje s redovitim periodičnim rastom i padom, prikaz će nam sugerirati postojanje sezonalnosti.

3. Ako je razlika u vrijednosti između Y_i i Y_{i+L} približno konstantna, gdje nam L predstavlja očekivan period sezonske komponente sugerira postojanje sezone.

Kada smo odabrali neki model, ne znači da će on uvijek dobro opisivati neku pojavu. Stvari se u ekonomiji mijenjaju i pojave ne moraju zadržavati uvijek komponente koje smo uočili u prvoj analizi. Stoga, postupak analize možemo provesti kada nam noviji podaci postanu dostupni jer oni mogu promijeniti sliku o pojavi.

Statistički test za sezonalnost

Kad se odlučimo koristiti sezonski model onda se provode testovi u kojima postavljamo hipoteze:

H_0: $S_1 = S_2 = ... = 0$ – za aditivni model (što znači "nema sezonalnosti") ili

H_0: $S_1 = S_2 = ... = 1$ – za multiplikativni model

Dakle, potrebno je ispitati relevantnost odnosno prisutnost sezonske komponente u modelu.

Prije testiranja postojanja sezonalnosti potrebno je ukloniti trend komponentu.

Postoji više metoda kojima se postojanje sezonalnosti može testirati. Jedan od zanimljivijih je Kruskal-Wallisova jednosmjerna analiza varijance (ili Kruskal-Wallis test). Model polazi od činjenice da, ako pojava ne sadrži sezonsku komponentu, njezina distribucija treba biti ista za sve unutar L perioda. Analiza se provodi rangiranjem vrijednosti y'_t pojave (slično kao kod računanja Spearmanovog koeficijenta koleracije ranga), $y'_t = \hat{S}_t + \hat{I}_t = y_t - \left(\hat{T}_t - \hat{C}_t\right)$. Vjerojatnost većeg ili manjeg ranga za svaki dio sezone je jednaka. Prosječni rang u svim sezonama (npr. prosječni rang svih prvih mjeseci u n godina) je statistički isti.

R_i : Zbroj rangova od y'_t u istoimenim mjesecima

n : Duljina sezonske komponente

n_i : Broj vrijednosti u i-tom mjesecu

$\overline{R}_i$: Prosjek rangova vrijednosti sezonske komponente u i-tom mjesecu

$$\overline{R}_i = \frac{R_i}{n_i} \tag{3}$$

$\overline{R}$: Ukupan prosječni rang

$$\overline{R} = \frac{\sum R_i}{n} = \frac{n(n+1)/2}{n} = \frac{n+1}{2} \tag{4}$$

$$H = \frac{12}{n(n+1)}\left[\sum \frac{R_i^2}{n_i}\right] - 3(n+1) \tag{5}$$

Testiranje se provodi tako da se postave hipoteze (H_0 – nema sezonalnosti) i (H_1 – postoji sezonalnost), te se odabere razina signifikantnosti α. Ako je:

$H > \chi_\alpha^2(L-1)$ - odbacuje se H_0 a prihvaća H_1

$H < \chi_\alpha^2(L-1)$ - H_0 se prihvaća kao moguća

Izračunatu vrijednost H uspoređujemo s vrijednostima hi-kvadrat distribucije za određenu razinu signifikantnosti α i (L-1) stupnjeva slobode.

Da bi se utvrdilo, odnosno dokazalo prisustvo sezonske komponente u podacima o broju dolazaka turista na dubrovačko područje može se upotrijebiti navedeni Kurskal – Wallisov test.

U tablici 1. navode se podaci o broju dolazaka turista na dubrovačko područje po mjesecima, od siječnja 1996. godine do ožujka 2003.

Tablica 1.

Dolazak turista u grad Dubrovnik od siječnja 1996 do ožujka 2003.

	1996	1997	1998	1999	2000	2001	2002	2003
siječanj	1 258	2 100	3 641	4 149	4 742	5 553	4 632	4 771
veljača	1 856	3 051	4 610	4 863	5 298	5 766	5 172	5 115
ožujak	1 930	3 890	5 010	4 908	7 313	7 936	9 751	8 417
travanj	6 031	7 320	12 743	10 490	15 548	18 511	16 545	
svibanj	6 799	10 300	14 026	9 858	18 736	23 744	26 538	
lipanj	9 132	15 618	21 547	13 035	23 108	31 840	29 013	
srpanj	17 215	18 700	21 857	19 301	32 651	37 555	40 039	
kolovoz	19 582	31 454	33 524	26 966	42 048	50 504	54 457	
rujan	8 460	14 942	18 923	17 025	28 271	31 905	32 672	
listopad	5 532	10 454	9 718	10 081	14 714	15 253	17 258	
studeni	3 373	6 024	5 625	5 598	4 516	5 000	4 722	
prosin.	3 008	7 585	7 047	8 368	7 444	4 003	4 616	

Izvor: Statistički zavod RH priopćenja od 1996. do 2003. godine

U tablici 2. Izračunati su centrirani pomični prosjeci kao i rangovi za pojedinu sezonu.

Tablica 2.

Izračunati podaci potrebni za provedbu Kruskal - Wallisov test

		t	Dolasci turista	Centrirani pom. prosj.	Pojedinačne sezone y'$_t$	R_i
1996	siječanj	0	1 258			
	veljača	1	1 856			
	ožujak	2	1 930			
	travanj	3	6 031			
	svibanj	4	6 799			
	lipanj	5	9 132			
	srpanj	6	17 215	7 049,75	10 165	61
	kolovoz	7	19 582	7 134,625	12 447	66
	rujan	8	8 460	7 266,0833	1 194	46
	listopad	9	5 532	7 401,4583	-1 869	36
	studeni	10	3 373	7 601,0417	-4 228	31
	prosinac	11	3 008	8 017,1667	-5 009	29
1997	siječanj	12	2 100	8 349,2917	-6 249	24
	veljača	13	3 051	8 905,8333	-5 855	26
	ožujak	14	3 890	9 670,5833	-5 781	27
	travanj	15	7 320	10 145,75	-2 826	34
	svibanj	16	10 300	10 407,042	-107	44
	lipanj	17	15 618	10 530,25	5 088	51
	srpanj	18	18 700	10 661,458	8 039	56
	kolovoz	19	31 454	10 790,625	2 663	72
	rujan	20	14 942	10 902,25	4 040	50
	listopad	21	10 454	11 174,875	-721	41
	studeni	22	4 722	11 556,083	-6 834	22
	prosinac	23	4 616	11 958,375	-7 342	21
1998	siječanj	24	3 641	12 336,958	-8 696	14
	veljača	25	4 610	12 554,75	-7 945	16
	ožujak	26	5 010	12 806,875	-7 797	17

Nastavak na slijedećoj stranici.

Nastavak tablice 2.

1998	travanj	27	12 743	12 942,083	-199	43
	svibanj	28	14 026	12 923	1 103	45
	lipanj	29	21 547	12 909,042	8 638	59
	srpanj	30	21 857	12 904,667	8 952	60
	kolovoz	31	33 524	12 936,375	20 588	71
	rujan	32	18 923	12 942,667	5 980	55
	listopad	33	9 718	12 844,542	-3 127	33
	studeni	34	5 000	12 577	-7 577	19
	prosinac	35	4 003	12 048,667	-8 046	15
1999	siječanj	36	4 149	11 587,5	-7 439	20
	veljača	37	4 863	11 207,75	-6 345	23
	ožujak	38	4 908	10 855,417	-5 947	25
	travanj	39	10 490	10 791,458	-301	42
	svibanj	40	9 858	10 786,417	-928	40
	lipanj	41	13 035	10 909,625	2 125	48
	srpanj	42	19 301	11 077,708	8 223	57
	kolovoz	43	26 966	11 120,542	15 845	68
	rujan	44	17 025	11 238,875	5 786	52
	listopad	45	10 081	11 549,833	-1 469	38
	studeni	46	4 516	12 130,5	-7 615	18
	prosinac	47	7 444	12 920,125	-5 476	28
2000	siječanj	48	4 742	13 896,083	-9 154	12
	veljača	49	5 298	15 080,75	-9 783	11
	ožujak	50	7 313	16 177,75	-8 865	13
	travanj	51	15 548	16 839,375	-1 291	39
	svibanj	52	18 736	17 077,5	1 659	47
	lipanj	53	23 108	17 161,083	5 947	54
	srpanj	54	32 651	17 233,375	15 418	67
	kolovoz	55	42 048	17 286,667	24 761	73
	rujan	56	28 271	17 332,125	10 939	62

Nastavak na slijedećoj stranici.

Nastavak tablice 2.

2000	listopad	57	14 714	17 481,542	-2 768	35
	studeni	58	5 598	17 813,667	-12 216	7
	prosinac	59	8 368	18 386,167	-10 018	10
2001	siječanj	60	5 553	18 954,333	-13 401	5
	veljača	61	5 766	19 511	-13 745	4
	ožujak	62	7 936	20 014,75	-12 079	8
	travanj	63	18 511	20 188,625	-1 678	37
	svibanj	64	23 744	20 212,208	3 532	49
	lipanj	65	31 840	20 158,292	11 682	63
	srpanj	66	37 555	20 064,875	17 490	69
	kolovoz	67	50 504	20 001,75	30 502	74
	rujan	68	31 905	20 052,625	11 852	64
	listopad	69	15 253	20 046,333	-4 793	30
	studeni	70	5 625	20 080,833	-14 456	3
	prosinac	71	7 047	20 079,458	-13 032	6
2002	siječanj	72	4 632	20 065,167	-15 433	1
	veljača	73	5 172	20 333,375	-15 161	2
	ožujak	74	9 751	20 530,042	-10 779	9
	travanj	75	16 545	20 645,542	-4 101	32
	svibanj	76	26 538	20 745,708	5 792	53
	lipanj	77	29 013	20 784,75	8 228	58
	srpanj	78	40 039	20 812,958	19 226	70
	kolovoz	79	54 457	20 816,375	33 641	75
	rujan	80	32 672	20 758,42	11 914	65
	listopad	81	17 258			
	studeni	82	6 024			
	prosinac	83	7 585			
2003	siječanj	84	4 771			
	veljača	85	5 115			
	ožujak	86	8 417			

Izvor: vlastiti izračun

Pojedine sezone za aditivni model izračunate su po:

$$\hat{S}_t + \hat{I}_t = y_t - \left(\hat{T}_t + \hat{C}_t\right) \tag{6}$$

Tablica 3.

Izračunati podaci potrebni za provedbu Kruskal - Wallisov test

Mjes.	1	2	3	4	5	6	7	8	9	10	11	12
	76	82	99	227	278	333	440	499	394	213	100	109

Izračunajmo sada H:

$$H = \frac{12}{69 \cdot (69+1)} \left(\frac{76^2}{6} + \frac{82^2}{6} + \frac{99^2}{6} + \Lambda + \frac{109^2}{6} \right) - 3 \cdot (69+1) = 138{,}52$$

Tablična vrijednost hi kvadrat distribucije za $\alpha = 5\ \%$ i broj stupnjeva slobode L = (12 -1) iznosi $\chi^2_{.05}(11) = 19{,}6751$

Pošto je $H > \chi^2_{.05}(11) = 19{,}6751$ odbacuje se H_0 što znači da bi ovu pojavu trebalo analizirati sezonskim modelima.

4. PROGNOZIRANJE SEZONSKIH POJAVA

Ako se kod serije može primijetiti sezonalno kretanje tj. sezonalnost ili jednostavno sezona tada se za prognoziranje takvih pojava koriste modeli specijalizirani za njihovo prognoziranje ili su modeli dodatno prilagođeni takvim pojavama. Za opisivanje tih modela, potrebno je prethodno opisati prirodu sezonske pojave. Ako sumnjamo u postojanje sezone, proces modeliranja se provodi izborom aditivnog ili multiplikativnog modela. Nakon toga procjenjujemo niz sezonskih indeksa iz povijesnih podataka. Indekse možemo koristiti za inkorporiranje sezonskog utjecaja u prognozi, ili pak za odstranjivanje tog istog utjecaja iz povijesnih podataka kako bi se mogao primijetiti eventualni trend.

Osnovna obilježja sezone su pravilnost i predvidljivost gibanja po obrascu koji se ponavlja godišnje, tako da je razlika odstupanja između godišnjih vrijednosti pojave jednaka nuli (kada se odstrani trend i slučajna komponenta).

Godišnja pravilnost se najviše može uočiti kod društvenih i nekih prirodnih pojava. Međutim, postoje i sezonske pojave kod kojih period ne traje godinu dana nego je kraći npr., mjesec dana (osobni dohodak), tjedan dana (televizijski program) ili samo jedan dan (kretanja na burzi pri otvaranju i zatvaranju burze)[6]. Pojave s pravilnim kretanjem, koje se realiziraju u periodu dužem od godine dana opisujemo indeksom ciklusa. Problem uočavanja ciklusa je u tome što je potrebno imati podatke za veći broj godina. Tom zahtjevu često se ne može udovoljiti, stoga se ta komponenta inkorporira u trend komponentu i slučajni indeks.

Obilježja modela sa sezonskom komponentom mogu se iskazati na slijedeći način:

Aditivni model: $E(y_t) = f(\hat{b}_0, \hat{b}_1, \ldots; t) + S_t + e_t \quad t = 1, 2, \ldots$ (7)

ili

Multiplikativni model: $E(y_t) = f(\hat{b}_0, \hat{b}_1, \ldots, t) \cdot S_t \cdot \varepsilon_t \quad t = 1, 2, \ldots$ (8)

U ovim modelima $\hat{b}_0, \hat{b}_1, \ldots$ predstavljaju procijenjene vrijednosti parametara regresijske funkcije koja opisuje trend. S_t predstavlja sezonski dio pojave i to u aditivnom modelu u apsolutnom iznosu, a u multiplikativnom to je sezonski indeks pa se prikazuje promjena u relativnom iznosu. e_t je slučajna komponenta, a t je varijabla vrijeme. Karakteristika e_t komponente je da je njezina aritmetička sredina u aditivnom modelu jednaka nuli, a u multiplikativnom modelu jednaka jedinici.

Ako se sezonska pojava ponavlja u vremenskom intervalu L onda vrijedi:

$S_t = S_{t+L} = S_{t+2L} = \ldots$ i kod aditivnog: $\sum_{1}^{L} S_t = 0$

a kod multiplikativnog $\sum_{1}^{L} S_t = L$

To znači da kod sezonske pojave, bilo koje dvije vremenske komponente između kojih se nalazi jedan ili više L perioda pokazuju rast ili pad u odnosu na druge periode što je rezultat sezonalnog djelovanja.

[6] Op. cit. Šošić, I., Serdar, V. str. 200.

4.1. Metoda pomičnih prosjeka s trendom u funkciji prognoziranja

Metoda se bazira na izračunavanju pomičnih prosjeka za niz izmjerenih podataka po formuli:

$$\frac{y_1 + y_2 + \Lambda + y_L}{L}, \frac{y_2 + y_3 + \Lambda + y_{L+1}}{L} \text{ itd.} \tag{9}$$

Na taj način smo, uvažavajući činjenicu da se sezonski učinak u tako agregiranim vrijednostima poništava, odstranili u pomičnim prosjecima sezonsku komponentu. Niz takvih podataka sadržava samo trend i ciklus komponentu (ako te komponente uopće postoje u analiziranoj seriji). Oduzimanjem vrijednosti pomičnih prosjeka (ili dijeljenjem kod multiplikativnog modela) od stvarnih vrijednosti, možemo iz početne serije izdvojiti sezonsku komponentu. Kod rada s pomoćnim prosjecima pojavljuju se dva manja problema. Prvi se pojavljuje ako je dužina sezone L paran broj. Pa tako npr. prosjek od 12 mjerenja (što je uobičajeno ako neku pojavu mjerimo dvanaest puta godišnje, dakle po mjesecima) daje vrijednost pomičnog prosjeka koju pripisujemo t = 6,5 tom članu niza. Međutim potrebna nam je vrijednost diskontinuiranog niza, dakle vrijednost za t = 7. Stoga je potrebno provesti postupak centriranja

Drugi problem je kako utvrditi vrijednost pomičnih prosjeka za veličine od 1. do 6. te kako utvrditi te veličine za zadnjih šest perioda (u ovom primjeru gdje je L=12[7]). Iz tog problema proizlazi zahtjev za znatno većim nizom podataka s kojim moramo raspolagati ako želimo kvalitetno primijeniti metodu pomičnih prosjeka. Dakle, problem je riješen automatski ako se osigura dovoljan broj mjerenja. Naravno, uvijek se može očekivati bolja prognoza u slučaju da raspolažemo većim nizom povijesnih podataka.

Na primjeru se može pokazati na koji način izračunati pomične prosjeke i na koji način ih iskoristiti za desezoniranje pojave. Koristimo podatke iz tablice 1. i tablice 2.[8]

[7] Da je npr. L = 4, onda bi nam nedostajale veličine pomičnih prosjeka za t=1 do 2 i vrijednosti pomičnih prosjeka za zadnja dva perioda

[8] Podaci od siječnja do srpnja 1997 nisu dostupni, a u cilju izrade ovog rada na osnovu drugih podataka procijenio sam njihovu veličinu

Nacrtamo li vrijednost pomičnih prosjeka s obzirom na vrijeme dobivamo grafikon iz kojeg se jasno vidi da analizirana pojava u sebi sadrži visoko naglašenu trend komponentu:

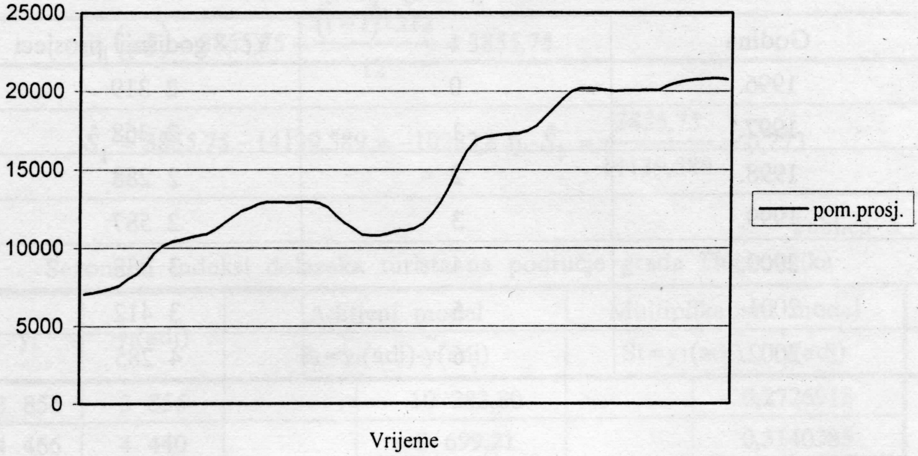

Slika 2. Centrirani pomični prosjeci

Isto tako, s obzirom na činjenicu da smo računali dvanaestočlane pomične prosjeke nećemo dobiti podatke pomičnih prosjeka za prvih šest i zadnjih šest mjerenja. Ovdje se može primijeniti aditivni ili multiplikativni model.

Iz grafikona 1. može se zaključiti da postoji trend element u pojavi. Stoga se za prognoziranje može koristiti metoda jednostavnih prosjeka s linearnim trendom. Za multiplikativni model potrebno je logaritmirati jednadžbu, odnosno linearizirati je. Dakle, imamo:

Za aditivni model: $y_t = b_0 + b_1 t + S_t + e_t$ (10)

Za multiplikativni model: $y_t = b_0 \cdot (b_1)^t \cdot S_t \cdot \varepsilon_t$ \log $\log \varepsilon_t' = e_t'$ (11)

$$y_t' = \log(y_t) = b_0' + b_1' t + S_t' + e_t'$$

Da bismo procijenili parametre trend modela moramo izračunati godišnje prosjeke pojave, gdje ćemo sada u modelu sa t = 1 označiti prosječni iznos pojave u godini 1., sa t = 2 prosječni iznos pojave u godini 2. itd. Dakle izračunavamo tablicu 4.:

Tablica 4.

Izračunani godišnji prosjeci

Godina	t	Y_t - godišnji prosjeci
1996.	0	2 319
1997.	1	2 368
1998.	2	2 288
1999.	3	2 587
2000.	4	3 038
2001.	5	3 412
2002.	6	4 285

Regresijska jednadžba za aditivni model:

$$\hat{y} = 1963{,}57 + 312 \cdot t$$
$$b_0 = 1963{,}57$$
$$b_1 = 312$$

Dalje računamo:

Za aditivni model:

$$\hat{S}_i = \overline{y}_i(adj) - \overline{y}(adj) \qquad i = 1,2,\mathrm{K}, L$$

$$\overline{y}_i = \frac{y_1 + y_{L+1} + y_{2L+1} + \Lambda}{n_i}$$

$$\overline{y}_i(adj) = \overline{y}_i - \frac{(i-1)b_1}{L} \qquad (12)$$

$$\overline{y}(adj) = \frac{\overline{y}_1(adj) + \overline{y}_2(adj) + \Lambda + \overline{y}_L(adj)}{L}$$

Za multiplikativni model:

$$\hat{S}_i = \frac{\overline{y}_i}{\overline{y}} \qquad (13)$$

U tablici 5. izračunano je 12 sezonskih indeksa po (12) i (13).

Npr. za siječanj:

$$\bar{y}_1 = \frac{1258 + 2100 + \Lambda\ + 4771}{8} = 3855{,}75,$$

$$\bar{y}_1(adj) = 3855{,}75 - \frac{(1-1)\cdot 312}{12} = 3855{,}75$$

$$\hat{S}_1 = 3855{,}75 - 14139{,}589 = -10283{,}8 \text{ tj. } \hat{S}_1 = \frac{3855{,}75}{14139{,}589} = 0{,}273$$

Tablica 5.

Sezonalni indeksi dolazaka turista na područje grada Dubrovnika

$\bar{y}_t$	$\bar{y}_t(adj)$	Aditivni model $S_t = \bar{y}_t(adj) - \bar{y}(adj)$	Multiplikativni model $S_t = \bar{y}_1(adj) \,/\, \bar{y}(adj)$
3 856	3 856	-10 283,80	0,2726918
4 466	4 440	-9 699,21	0,3140385
6 144	6 092	-8 047,21	0,4308735
12 455	12 377	-1 762,16	0,875374
15 714	15 610	1 470,839	1,1040228
20 470	20 340	6 200,839	1,4385445
26 760	26 604	12 464,13	1,8815054
36 934	36 752	22 611,98	2,5991965
21 743	21 535	7 394,982	1,5229984
11 859	11 625	-2 515,02	0,8221294
4 980	4 720	-9 419,88	0,3337943
6010	5 724	-8 415,45	0,4048309

$$\bar{y}(adj) = 14139{,}589$$

Izvor: vlastiti izračun

Pomoću izračunatih sezonskih komponenti tj. sezonskih indeksa za svaki mjesec, desezoniramo originalnu seriju i iz tih podataka izračunajmo parametre regresijske jednadžbe:

Tablica 6.

Desezonirani stvarni podaci o dolascima uz pomoć aditivnog modela.

God.	Mjeseci											
	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.	12.
1996.	11542	11555	9977	7793	5328	2931	4751	-3030	1065	8047	12793	11423
1997.	12384	12750	11937	9082	8829	9417	6236	8842	7547	12969	14142	13031
1998.	13925	14309	13057	14505	12555	15346	9393	10912	11528	12233	14420	12418
1999.	14433	14562	12955	12252	8387	6834	6837	4354	9630	12596	13936	15859
2000.	15026	14997	15360	17310	17265	16907	20187	19436	20876	17229	15018	16783
2001.	15837	15465	15983	20273	22273	25639	25091	27892	24510	17768	15045	15462
2002.	14916	14871	17798	18307	25067	22812	27575	31845	25277	19773	15444	16000
2003.	15055	14814	16464									

Podaci iz tablice 6. potrebni su nam za izračunavanje regresijske jednadžbe. Postavljen je model jednostavne linearne regresije. Metodom najmanjih kvadrata dobiva se regresijska jednadžba.[9]

Regresijska jednadžba dobivena iz tablice 6: T = 6966,15+173,38×t

Na osnovu izračunatih podataka iz modela može se prognozirati broj dolazaka turista za ostale mjesece 2003 godine kao i za 2004. godinu:

$$\hat{y}_t = \hat{b}_0 + \hat{b}_1 t + \hat{S}_t \qquad (14)$$

Prognoza za travanj 2003.:

$$\hat{y}_{87} = 6823{,}15 + 173{,}38 \cdot 87 + (-1762) = 20145$$

9 Za izračun upotrebljen je excel iz programskog paketa Microsoft office, prilagođen za izračun pravca jednostavne regresije

Tablica 7.

Prognoza broja dolazaka turista na područje grada Dubrovnika za period od travnja 2003. do prosinca 2004. godine

God.	Mjeseci											
	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.	12.
2003.				20145	23551	28455	34891	45213	30169	20432	13701	14879
2004.	13184	13942	15767	22226	25632	30535	36972	47293	32250	22513	15782	16959

4.2. Eksponencijalno izglađivanje u funkciji prognoziranja sezonske pojave

Metoda eksponencijalnog izglađivanja je zapravo metoda ažuriranja prethodnih prognoza. Tu se izračunava nova prognoza (npr. za period t + 1) tako što se izračuna vagana sredina nove i stare informacije o pojavi s koeficijentom α. Taj se koeficijent naziva konstanta izglađivanja. Drugim riječima, to je zapravo prilagođavanje stare prognoze u smjeru koji će reducirati tekuću pogrešku u prognozi. Dakle, koncept eksponencijalnog izglađivanja za stacionirane serije može se predočiti ovako:

Ažurirana procjena = (konstanta α) × (procjena bazirana na novim podacima) + (1 – konstanta α) × stara procjena

Ili napisano na drugi način u obliku ispravljanja pogreške u zadnjoj procjeni:

Ažurirana procjena = (stara procjena) + (konstanta α) × (greška prognoze)

Kada se ova metoda koristi u prognoziranju sezonske pojave s trendom, potrebno je osim konstante izglađivanja α uvesti i još dvije konstante. Dakle, u modelu imamo:

α - konstanta izglađivanja za razinu

γ - konstanta izglađivanja za nagib

δ - konstanta izglađivanja za sezonu

Dakle, ako nam je u određenom trenutku na raspolaganju podatak o razini pojave y_t, onda se procjena tekuće desezonirane razine pojave računa po:

$$\hat{T}_t(t) = \alpha \cdot (y_t') + (1 + \alpha) \cdot \hat{T}_t \cdot (t-1) \tag{15}$$

Gdje je:

$\hat{T}_t(t)$: Ažurirana procjena tekućeg desezonaliziranog nivoa serije (bazirane na y_1, y_2, ..., y_t)

y'_t : Sezonalno prilagođeni podaci o pojavi y_t uz pomoć aditivnog ili multiplikativnog modela po formuli:

$$y'_t = y_t - \hat{S}_t(t-1) \text{ - za aditivni model ili} \tag{16}$$

$$y'_t = \frac{y_t}{\hat{S}_t(t-1)} \text{ - za multiplikativni model} \tag{17}$$

$\hat{T}_t(t-1)$: Stara procjena tekućeg desezonaliziranog nivoa serije (bazirane na y_1, y_2, ..., y_{t-1})

Procjena za $\hat{T}_t(t-1)$ može se računati na dva načina, ovisno o tome da li smo u modelu kod grafičkog prikazivanja desezonalizirane pojave primijetili postojanje trend komponente pa stoga primjenjujemo trend model ili smatramo da je trend komponenta neznačajna pa primjenjujemo horizontalni model. Stoga $\hat{T}_t(t-1)$ računamo po formuli:

$$\hat{T}_t(t-1) = \hat{T}_{t-1}(t-1) \text{ - za horizontalni model} \tag{18}$$

$$\hat{T}_t(t-1) = \hat{T}_{t-1}(t-1) + \hat{b}_1(t-1) \text{ - za trend model} \tag{19}$$

Ako postoji trend, onda je potrebno procijeniti i $\hat{b}_1(t)$ po formuli (20) u kojoj se pojavljuje konstanta izglađivanja za nagib γ:

$$\hat{b}_1(t) = \gamma\left[\hat{T}_t(t) - \hat{T}_{t-1}(t-1)\right] + (1-\gamma)\cdot\hat{b}_1(t-1) \tag{20}$$

Prilagođeni sezonski indeksi se izračunavaju po formuli (21) ako t nije u i-toj sezoni, odnosno po formuli (22) ako je t u i-toj sezoni:

$$\hat{S}_i(t) = \hat{S}_i(t-1) \tag{21}$$

$$\hat{S}_t(t) = \gamma\cdot(\text{det}.\, y_t) + (1+\gamma)\cdot\hat{S}_i(t-1) \tag{22}$$

U formuli (22) detrendirani y_t je vrijednost koja se dobiva po formuli (23) za aditivni model, odnosno po formuli (24) za multiplikativni model:

$$\det y_t = y_t - \hat{T}_t(t) \tag{23}$$

$$\det . y_t = \frac{y_t}{\hat{T}_t(t)} \tag{24}$$

Za proračun u modelu ključna je i pogreška prethodne prognoze e_t kojom se popravlja buduća prognoza.

$$e_t = y_t - \hat{y}_t(t-1) \tag{25}$$

Pogrešku e_t dobivenu po formuli (25) je potrebno sezonalno prilagoditi. Ako se koristi aditivni model to radimo po formuli (26), a ako se rabi multiplikativni po formuli (27)

$$sez.pril.\, e_t = e_t \tag{26}$$

$$sez.pril.\, e = \frac{e_t}{\hat{S}_t(t-1)} \tag{27}$$

U upotrebi modela polazi se najprije od izmjerenih vrijednosti $y_1, y_2, ..., y_n$. Da bismo mogli upotrebljavati sezonalni model potrebno je da je n > L. Nakon početno procijenjenih vrijednosti, metodom izglađivanja "popravljamo" početne procjene iz čega dobivamo potrebne podatke za prognoziranje.

Sada možemo primijeniti multiplikativni Holt – Wintersov model eksponencijalnog izglađivanja za prognozu prometa turista na području grada Dubrovnika. Podatke iz tablice 1. preformulirat ćemo po kvartalima, pa će svaki kvartal predstavljati jednu sezonu. Dobivamo tablicu 8. Dakle, imamo 4 sezone, za svaki kvartal po jednu tj. L = 4. Model glasi:

$$y_t = (b_0 + b_1 \cdot t) \cdot S_t + e_t \tag{28}$$

Tablica 8.

Dolasci turista na područje grada Dubrovnika po kvartalima

Godina	Kvartal	t	Y_t	Centrirano pom. prosj.	Indeksi
1996.	I	1	5 044		
	II	2	9 817		
	III	3	14 760	16 409	0,8995
	IV	4	21 962	24 435	0,8988
1997.	I	5	33 146	32 761	1,0118
	II	6	45 929	38 025	1,2079
	III	7	45 257	37 504	1,2067
	IV	8	33 574	31 279	1,0734
1998.	I	9	17 365	22 430	0,7742
	II	10	11 913	14 656	0,8128
	III	11	8 481	10 439	0,8124
	IV	12	8 159	9 692	0,8418
1999.	I	13	9 041	11 614	0,7785
	II	14	14 261	16 378	0,8707
	III	15	21 510	23 960	0,8977
	IV	16	33 238	34 846	0,9539
2000.	I	17	44 618	46 733	0,9547
	II	18	65 772	55 133	1,1930
	III	19	65 096	56 272	1,1568
	IV	20	56 850	48 712	1,1671
2001.	I	21	30 118	36 449	0,8263
	II	22	19 792	24 437	0,8099
	III	23	12 979	16 832	0,7711
	IV	24	12 867	15 046	0,8552
2002.	I	25	13 261	17 718	0,7484
	II	26	22 363	24 499	0,9128
	III	27	31 779	34 451	0,9224
	IV	28	48 316		
	I	29	57 430		

Izvor: Statistički zavod RH - priopćenja (agregirani podaci)

$S_1 = 0{,}89300 \qquad S_2 = 1{,}01035 \qquad S_3 = 1{,}05310 \qquad S_4 = 0{,}98610$

Za izračunavanje sezonskih indeksa upotrebljene su samo prve tri godine iz tablice 8, jer one čine dvije potpune godine nakon izglađivanja. Pomoću ovih indeksa desezonirani su podaci za godinu 1996. do 1999. dijeljenjem stvarne vrijednosti odgovarajućim indeksom (s obzirom da koristimo multiplikativni model). Dobiveni rezultati prikazani su u tablici 9.

Tablica 9.

Desezonalizirani podaci 1996. - 1999.

Godina/mjesec	I	II	III	IV
1996.	5 648,4	9 716,4	14 015,8	22 271,6
1997.	37 117,6	45 458,5	42 975,0	34 047,3
1998.	19 445,7	11 791,0	8 053,4	8 274,0

Izvor: vlastiti izračun

Započinjemo s procesom izračunavanja početnih vrijednosti. Proces se može započeti korištenjem metode pomičnih prosjeka. Pomoću nje se dobivaju početne procjene parametara b_0 i b_1 po formulama (29) i (30) potrebne za procjenu prve trend vrijednosti.

$$\hat{b}_1 = \frac{2 \cdot \left(\bar{y}2 - \bar{y}1\right)}{n} \tag{29}$$

$$\hat{b}_0 = \bar{y}1 - \frac{n+2}{L}\hat{b}_1 \tag{30}$$

$$\bar{y}1 = \frac{y_1 + y_2 + \Lambda + y_{(n/2)}}{n/2}, \qquad \bar{y}2 = \frac{y_{(n/2)+1} + y_{(n/2)+2} + \Lambda + y_n}{n/2}$$

Kao osnovu za prvu procjenu uzeli smo podatke za prve tri godine. Podaci su kvartalni što nam daje n = 12 podataka (mjerenja).

$$\bar{y}1 = \frac{5648{,}4 + 9716{,}4 + \Lambda + 45458{,}5}{6} = 22371{,}4,$$

$$\bar{y}2 = \frac{42975{,}0 + 34047{,}3 + \Lambda + 8274{,}0}{6} = 20764{,}4$$

$$\hat{b}_1 = \frac{2 \cdot (20764{,}4 - 22371{,}4)}{12} = -267{,}8667,$$

$$\hat{b}_0 = 22371{,}4 - \frac{12-2}{4} \cdot (-267{,}333) = 23308{,}82$$

Prognoziranje ex-post za I 1999 tj. t = 12:

$$\hat{T}_{12}(12) = \hat{b}_0 + \hat{b}_1 \cdot t = 23308{,}82 + (-267{,}33) \cdot 12 = 20094{,}81$$

$$\hat{b}_1(12) = -267{,}8667$$

$$\hat{T}_{13}(12) = \hat{T}_{12}(12) + \hat{b}_1(12) = 20094{,}81 + (-267{,}8667) = 19826{,}97$$

$$\hat{y}_{13}(12) = \hat{T}_{13}(12) \cdot \hat{S}_{13}(12) = \hat{T}_{13}(12) \cdot \hat{S}_1(12) = 19826{,}97 \cdot 0{,}9300 = 17704{,}87$$

Nakon izračunavanja početne prognoze, na osnovu prognoze ex post i stvarne vrijednosti y_{12} vršimo izglađivanje. Da bi se izglađivanje moglo izvršiti potrebno je odabrati vrijednosti za konstante izglađivanja α, γ i δ. Vrlo je popularno u praksi da se odrede vrijednosti za α i γ između 0,1 i 0,3, a za δ vrijednost oko 0,4[10]. Konačni odabir moguće je odrediti određivanjem standardnih pokazatelja točnosti modela (MAD, MSE itd.) za različite kombinacije vrijednosti tih konstanti, te na osnovu toga odabrati pravu kombinaciju. Za takav pristup potrebno je koristiti računalo koje određuje konstante izglađivanja iterativnim putem. Za potrebe ovog izračuna uzima se:

$\alpha = 0{,}1$, $\gamma = 0{,}1$ i $\delta = 0{,}4$

$y_{13} = 9041$ $\hat{y}_{13} = 17705$

$$e_{13} = y_{13} - \hat{y}_{13} = 9041 - 17704{,}87 = -8664$$

$$\hat{T}_{13}(13) = \hat{T}_{13}(12) + \frac{\alpha \cdot e_{13}}{\hat{S}_1(12)} = 19826{,}97 + \frac{0{,}1 \cdot (-8664)}{0{,}8929} = 18856{,}72$$

[10] Farnum, N., R., Stanton L., W., Op. cit., str. 379.

$$\hat{b}_1(13) = \hat{b}_1(12) + \frac{\alpha \cdot \gamma \cdot e_{13}}{\hat{S}_1(12)} = -267,87 + \frac{0,1 \cdot 0,1 \cdot (-8664)}{0,8929} = -364,89$$

$$\hat{S}_1(13) = \hat{S}_1(12) + \frac{\delta \cdot (1-\alpha) \cdot e_{13}}{\hat{T}_{13}(13)} = 0,8929 + \frac{0,4 \cdot (1-0,1) \cdot (-8664)}{18856,72} = 0,7275$$

$$\hat{T}_{14}(13) = \hat{T}_{13}(13) + \hat{b}_1(13) = 18856,72 + (-364,89) = 18491,83$$

$$\hat{y}_{14} = \hat{T}_{14}(13) \cdot \hat{S}_{14}(13) = \hat{T}_{14}(13) \cdot \hat{S}_2(13) = 18491,83 \cdot 1,01035 = 18683,26$$

Na isti način izračunava se ex-post prognoziranje za sve kvartale od I 1999. do I 2003. Rezultati tog računa nalaze se u tablici 10.

Tablica 10.

Ex-post izračun prognoze za period I 1999. do I 2003. godine

Godina	Kvart.	t	y1	(t-1)	e1	(t)	(t)	(t)	(t)
1999.	I	13	9 041	17 704,868	-8 663,868	18 856,735	-364,890	18 491,845	0,728
	II	14	14 261	18 683,276	-4 422,276	18 419,039	-539,969	17 879,070	0,924
	III	15	21 510	18 828,726	2 681,274	18 673,643	-438,127	18 235,516	1,105
	IV	16	33 238	17 981,720	15 256,280	20 220,804	180,737	20 401,541	1,258
2000.	I	17	44 618	14 852,322	29 765,678	24 309,496	1 816,214	26 125,710	1,169
	II	18	65 772	24 140,156	41 631,844	28 815,107	3 618,458	32 433,565	1,444
	III	19	65 096	35 839,089	29 256,911	31 462,791	4 677,532	36 140,323	1,440
	IV	20	56 850	45 464,526	11 385,474	32 367,837	5 039,550	37 407,387	1,385
2001.	I	21	30 118	43 729,235	-13 611,235	31 203,488	4 573,811	35 777,299	1,012
	II	22	19 792	51 662,420	-31 870,420	28 996,395	3 690,974	32 687,369	1,048
	III	23	12 979	47 069,811	-34 090,811	26 628,978	2 744,007	29 372,985	0,979
	IV	24	12 867	40 681,584	-27 814,584	24 620,705	1 940,698	26 561,403	0,978
2002.	I	25	13 261	26 880,140	-13 619,140	23 274,940	1 402,392	24 677,332	0,801
	II	26	22 363	25 861,844	-3 498,844	22 941,081	1 268,848	24 209,929	0,993
	III	27	31 779	23 701,520	8 077,480	23 766,156	1 598,878	25 365,034	1,101
	IV	28	48 316	24 807,003	23 508,997	26 169,939	2 560,391	28 730,330	1,301
2003.	I	29	57 430	23 012,994	34 417,006	30 466,694	4 279,093	34 745,787	1,208

Izvor: vlastiti izračun

Sada je moguće prognozirati broj dolazaka turista na dubrovačko područje za iduća tri kvartala 2003. Za prognozu za 2004. potrebno je ponovno izgladiti parametre sa stvarnim podacima u 2003.

II kvartal 2003.:

$$\hat{y}_{29}(28) = \left(\hat{T}_{29}(29) + \hat{b}_1(29)\right) \cdot \hat{S}_2(29) = (30466{,}69 + 4279{,}09) \cdot 0{,}993 = 34502{,}56$$

III kvartal 2003.:

$$\hat{y}_{30}(28) = \left(\hat{T}_{29}(29) + 2 \cdot \hat{b}_1(29)\right) \cdot \hat{S}_3(29) = (30466{,}69 + 2 \cdot 4279{,}09) \cdot 1{,}101 = 42966{,}39$$

IV kvartal 2003.:

$$\hat{y}_{31}(28) = \left(\hat{T}_{29}(29) + 3 \cdot \hat{b}_1(29)\right) \cdot \hat{S}_4(29) = (30466{,}69 + 3 \cdot 4279{,}09) \cdot 1{,}301 = 56338{,}45$$

5. MJERE USPJEŠNOSTI PROGNOZIRANJA I NJEGOVOG PRAĆENJA

Mjere uspješnosti modela se baziraju na greški prognoze e_t. Prognoza ne bi smjela biti neobjektivna, a što bi značilo da bi greške precjenjivanja i podcjenjivanja trebale biti jednake. U statističkom smislu očekuje se prosjek grešaka prognoze jednak nuli. Kada mjerimo uspješnost modela mjerimo zapravo koliko uspješno model reproducira podjednako zastupljene već poznate podatke. Na osnovu ovakvih pokazatelja može se ocijeniti koliko će on dobro funkcionirati i u prognozi novih podataka. Postoje više pokazatelja uspješnosti a najčešće su u uporabi slijedeći[11]:

MAD je prosječno apsolutno odstupanje:

$$\text{MAD} = \frac{1}{N} \sum_{i=1}^{N} \left| y_i - \hat{y} \right| \tag{31}$$

MAPE je prosječno apsolutno odstupanje u postocima.

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^{N} \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100 \tag{32}$$

[11] Siegel, F., A., Practical Business Statistics, IRWIN, Massachusetts, 1992.., str. 372

RMSE je korijen iz prosječnog kvadratnog odstupanja

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^{N}\left(y_i - \hat{y}_i\right)^2}{N}} \tag{33}$$

Tablica 11.

Mjere uspješnosti prognoziranja

Metoda	MAD	MAPE	RMSE
Pomični prosjek s trendom	3 249,59	42,00160472	4 133,663809
Multiplikativno eksponencijalno izglađivanje s trendom	19 621,88	77,51	23 106,35

Izvor: vlastiti izračun

S obzirom na dobivene pokazatelje može se reći da se modelom pomičnih prosjeka s trendom dobivaju bolji rezultati nego li modelom multiplikativnog eksponencijalnog izglađivanja. Bez obzira na to, ne može se sa sigurnošću tvrditi da model multiplikativnog eksponencijalnog izglađivanja ne bi mogao dati bolje rezultate kad bi se u njemu koristile druge vrijednosti za konstante izglađivanja α, γ i δ. Međutim, do bolje kombinacije se može doći samo iterativnim putem uz pomoć računala kojim bi se ispitala svaka kombinacija od 1.000.000.000 mogućih za već spomenute vrijednosti te bi se odredila najbolja.

ZAKLJUČAK

Turistički promet na području grada Dubrovnika je sezonska pojava, kao što su i mnoge druge pojave koje se analiziraju u turizmu. Stoga mu je kao takvom potrebno pristupiti na specifičan i odgovarajući način. Slobodno se može kazati da je postupak predviđanja sezonske pojave izuzetno složen. On zahtjeva dobro poznavanje kako kompjutorskih programa za statističku analizu tako i poznavanje same pojave. Međutim, bez obzira na veliku pomoć koju možemo dobiti uporabom računala, razumijevanje logike na kojoj se bazira pojedini model je imperativ pred kojim se analitičar nađe. Potrebno je razumjeti sam model, njegove prednosti i mane kao i mehanizam izračuna. Bez toga ćemo biti samo korisnici alata, ali samu bit njegovog funkcioniranja nećemo shvatiti. Potrebno je poznavati osobine same pojave, problematiku sezonalnosti i druge osobine vezane uz nju.

Svaki od modela prognoziranja ima svoje prednosti i nedostatke. Prednost modela je u njegovoj jednostavnosti, lakoći izračuna i jasnoći logike na kojoj se bazira kao i u niskoj cijeni implementacije koja iz toga proizlazi. Ali u ovom slučaju vrlo često, ovisno o složenosti pojave njegova je efikasnost upitna. S druge strane, model može biti vrlo složen s kompliciranim postupkom izračuna, vrlo složene logike, skupe implementacije, ali u pravilu daje bolje rezultate. Međutim, ovo nas ni u kojem slučaju ne bi trebalo ponukati da pod svaku cijenu izbjegavamo jednostavne metode uporabe modela. Dapače, njihovom uporabom možemo znatno skratiti vrijeme izračuna i dosta brzo doći do dovoljno preciznih rezultata.

U praksi se analiza vremenskih pojava, pa tako i sezonskih, temelji na njihovoj analizi pomoću statističkih programa. Podaci se unesu, odaberu modeli, donesu se odluke o upotrebi odgovarajućih konstanti (kao što su to npr. α, γ i δ kod modela izglađivanja) te se na temelju pokazatelja opisanih u zadnjem dijelu rada donose odluke. Konačnu odluku o uporabi pojedinih modela donosi analitičar uz suglasnost managera ,a odluka će biti uspješnija ukoliko se dobro poznaju pojedini modeli.

Ipak, na kraju je potrebno zaključiti da su prognostički modeli alati kojima se utvrđuje osnovni obrazac kretanja pojave u vremenu. Oni se baziraju na pretpostavci o ponavljanju obrasca u budućnosti, ali ne uzimaju u obzir brojne druge parametre o kojima pojava ovisi. Promet turista u gradu Dubrovniku, kao ekonomska pojava ovisi o razini investicija, tempu privatizacije hotelskih kapaciteta, o obnovi itd. Ona, dakle, ovisi o elementima navedenim u prvom dijelu rada. Stoga je analiza i prognoza pomoću statističkih metoda samo jedan od podataka koje treba uključiti u sustav informacija kojima raspolaže manager i koje su u funkciji donošenja odluka i planiranja. Analiza i prognoza, utemeljene na statističkim podacima, ne bi smjele biti isključiva odrednica pri donošenju managerskih odluka.

LITERATURA

Borković, V., Račić, M., Predviđanje prodaje u hotelijerstvu primjenom odabranih metoda prognoziranja, Ekonomska misao i praksa, Dubrovnik god. V br. 2 1996

Bukvić, I., Utjecaj strukture smještajnih kapaciteta na efikasnost turističke ponude Dubrovnika, Ekonomska misao i praksa, Dubrovnik, god XI. (2002) br. 2

Farnum, N., R., Stanton L., W., Quantitative forecasting methods, IRWIN 1987.

Grupa autora, Đ. Benić, red., Strategija razvoja županije Dubrovačko-neretvanske, FTVT, Dubrovnik, 2002.

Grupa autora, Turizam kao pokretač razvoja općine Dubrovnik, Zavod za društveno planiranje, ekonomiku i statistiku općine Dubrovnik, Dubrovnik, studeni 1989.

Njegić, R., Žižić M., Osnovi statističke analize, Savremena administracija, Beograd 1980.

Siegel, F., A., Practical Business Statistics, IRWIN, Massachusetts 1992.

Šošić I., Serdar V., Uvod u statistiku, Školska knjiga, Zagreb 1994.

Tonći Svilokos, B. Sc.
Junior researcher
Faculty of Tourism and Foreign Trade
E-mail: tonci.svilokos@ftvt.hr

FORECASTING TOURIST FLOW OF THE CITY OF DUBROVNIK BY APPLYING CHOSEN FORECASTING MODELS

Summary

This paper presents how to use some of the complicated models to forecast seasonal phenomenon. The first part of the paper briefly describes the forecasted phenomenon as well as the economic and political situation of the City of Dubrovnik. Method used when analyzing time series is also described. Tourist flow is particularly a seasonal phenomenon; therefore, some of the models for establishing the existence of the seasonal component in the time sequence are presented, using corresponding tests for seasonality. Two models for forecasting seasonal phenomena are described in the paper. Those are: the model of the moving average with a trend and Holt-Winters multiplier model of the exponential smoothing with a trend. Using these models, the number of tourist arrivals to the City of Dubrovnik has been forecasted. By means of standard index of success of the forecast, the successfulness of the model has been evaluated.

Key words: tourist turnover, forecasting models, time sequence components

JEL classification: C13, L83