Metode za procjenu stvarne potražnje u sustavima za upravljanje kapacitetima zrakoplova

Medved, Petra

Master's thesis / Diplomski rad

2016

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:690658

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

Petra Medved

METODE ZA PROCJENU STVARNE POTRAŽNJE U SUSTAVIMA ZA UPRAVLJANJE KAPACITETIMA ZRAKOPLOVA

DIPLOMSKI RAD

Zagreb, 2016.

Sveučilište u Zagrebu

Fakultet prometnih znanosti

DIPLOMSKI RAD

METODE ZA PROCJENU STVARNE POTRAŽNJE U SUSTAVIMA ZA UPRAVLJANJE KAPACITETIMA ZRAKOPLOVA

UNCONSTRAINING METHODS FOR TRUE DEMAND ESTIMATION IN AIRLINE REVENUE MANAGEMENT SYSTEMS

Mentor: doc. dr. sc. Ružica Škurla Babić

Student: Petra Medved

JMBAG: 0135223042

Zagreb, rujan 2016.

METODE ZA PROCJENU STVARNE POTRAŽNJE U SUSTAVIMA ZA UPRAVLJANJE KAPACITETIMA ZRAKOPLOVA

SAŽETAK

Prognoziranje buduće potražnje za zračnim prijevozom predstavlja područje na kojem postoji velika mogućnost pogreške i velika nesigurnost. Ne postoji niti optimalna, niti jedinstvena metoda prognoziranja potražnje za zračnim prijevozom, već se radi o kombinacijama i varijacijama vrlo složenih metoda s ciljem što realnijeg predviđanja. Podaci o potražnji na realiziranim letovima u prošlosti, na kojima se temelji predviđanje buduće potražnje, najčešće ne predstavljaju stvarnu potražnju. Naime, kada se dosegne rezervacijski limit broj odbijenih zahtjeva se ne bilježi, a upravo ti podaci su bitni kako bi se dobila procijenjena stvarna potražnja. Učinkovitost neke prognostičke metode najčešće se određuje prema kriteriju točnosti, a ocjena prikladnosti izabranih metoda prognoziranja buduće potražnje zasniva se na promatranju razlika između stvarnih i predviđenih vrijednosti potražnje. Cilj rada je opisati elemente sustava za upravljanje kapacitetima zrakoplova i njihovu ulogu u procesu dodjele sjedala u pojedine klase prijevoza, te analizirati i usporediti metode za procjenu stvarne potražnje za uslugama u zračnom prometu.

KLJUČNE RIJEČI: prognoziranje potražnje; upravljanje kapacitetima zrakoplova; cenzuriranje podataka; metode nadogradnje; statističke metode

UNCONSTRAINING METHODS FOR TRUE DEMAND ESTIMATION IN AIRLINE REVENUE MANAGEMENT SYSTEMS

SUMMARY

Forecasting future demand for air transport is a domain where there's a high possibility of mistake and great uncertainty. There's no optimal or unique method of forecasting demand for air transportation, it's about combinations and variations of very complex methods with a goal to have a more realistic prediction. Forecasting future demand, based on data demand on realized flights in the past, usually do not represent actual demand. As a matter of fact, when it reaches the reservation limit the number of refusals is not recorded, but these data are essential in order to obtain the estimated actual demand. The effectiveness of some forecasting method is usually determined by the criteria of accuracy, and rating the suitability of the selected method of forecasting future demand is based on the observation of the difference between actual and predicted values demand. The goal is to describe elements of Airline Revenue Management and their role in the allocation of seats in individual classes of transport, analyze and compare the methods for evaluating the actual demand for air services in air traffic.

KEY WORDS: forecasting demand; airline revenue management; constraining data; unconstraining methods; statistical methods

SADRŽAJ

1. UVOD 1
2. SUSTAVI ZA UPRAVLJANJE KAPACITETIMA ZRAKOPLOVA 3
2.1. Aspekti pokretanja sustava za upravljanje kapacitetima zrakoplova 5
2.1.1. Segmentacija 5
2.1.2. Upravljanje cijenama 6
2.1.3. Prognoziranje potražnje 6
2.1.4. Kontrola raspoloživih sjedala 7
2.2. Koraci implementacije sustava za upravljanje kapacitetima zrakoplova 8
2.2.1. Izrada strategije i analiza poslovanja 8
2.2.2. Određivanje cijene proizvoda 9
2.2.3. Kupnja ili izrada sustava za upravljanje kapacitetima zrakoplova 9
2.2.4. Pohranjivanje podataka i prognoziranje 11
3. MODUL ZA PROGNOZIRANJE POTRAŽNJE U SUSTAVU ZA UPRAVLJANJE KAPACITETIMA ZRAKOPLOVA 13
3.1. Uloga prognoziranja potražnje 13
3.2. Važnost nadogradnje cenzuriranih podataka 15
3.3. Kvantitativne metode prognoziranja potražnje 18
3.3.1. Analiza vremenskih nizova 18
3.3.1.1. Metoda pomičnog prosjeka 19
3.3.1.2. Metoda eksponencijalnog izglađivanja 20
3.3.1.3. Metoda linearne regresije 21
3.3.1.4. „Pickup“ metoda 22
3.3.1.5. Metoda za mjerenje točnosti prognoziranja - MAE 22
3.3.2. Regresijska analiza 23
3.4. Kvalitativne metode prognoziranja potražnje 24
3.4.1. Metoda stručne procjene 24
3.4.2. Metoda istraživanja tržišta 25
3.4.3. Delphi metoda 25
4. JEDNOSTAVNE METODE ZA PROCJENU STVARNE POTRAŽNJE 26
4.1. Metode za procjenu stvarne potražnje koje koriste isključivo raspoložive podatke 26
4.2. Metode za procjenu stvarne potražnje koje zamjenjuju cenzurirane podatke novim vrijednostima 27

4.2.1. Metoda zamjene cenzuriranih podataka aritmetičkom sredinom necenzuriranih podataka 27
4.2.2. Metoda zamjene cenzuriranih podataka medijanom, gornjim kvartilom ili percentilom necenzuriranih podataka 28
5. STATISTIČKE METODE ZA PROCJENU STVARNE POTRAŽNJE 30
5.1. Metoda dogradnje krivulje rezervacija 34
5.2. EM metoda 36
5.2.1. Koraci EM algoritma 37
5.2.2. Numerički primjer EM algoritma 40
5.3. PD metoda 41
5.3.1. Koraci PD metode 42
5.3.2. Numerički primjer PD algoritma 43
5.3.3. Procjena konstante τ 44
6. USPOREDBA METODA ZA PROCJENU STVARNE POTRAŽNJE 46
7. ZAKLJUČAK 50
Literatura 51
Popis kratica 53
Popis slika 54
Popis tablica 54
Popis grafikona 54

1. UVOD

Metode za procjenu stvarne potražnje su osnova sustava za upravljanje kapacitetima zrakoplova radi ostvarenja maksimalnog prihoda (engl. *airline revenue management*). Sustav za upravljanje kapacitetima zrakoplova inzistira na maksimalnom prihodu po letu, odnosno cjelokupnoj rutnoj mreži opsluživanja. Taj sustav je razvijen od strane zračnih prijevoznika kako bi se povećali prihodi i konkurentnost na tržištu. Tako su zračni prijevoznici putnike podijelili u dvije široke kategorije, na temelju vrste putovanja i njihove osjetljivosti na cijenu, na visokoplatežne i niskoplatežne putnike.

Kako bi se broj zabilježenih zahtjeva uvećao za broj zahtjeva koji su zbog rezervacijskog limita bili odbijeni i kao takvi nisu nigdje zabilježeni, zračni prijevoznici se služe metodama za procjenu stvarne potražnje. Svrha korištenja metoda je nadogradnja nepotpunih podataka iz raspoloživih podataka (od kojih su neki cenzurirani) s ciljem procjene kumulativne krivulje potražnje za svaki cjenovni razred. Buduća potražnja se procjenjuje na temelju trenutnog broja potvrđenih rezervacija i potvrđenih podataka o potražnji. Kako bi se odredio broj potvrđenih rezervacija, vrše se konstantne provjere u određenim vremenskim točkama provjere prije predviđenog leta te se reoptimiraju rezervacijski limiti.

Cilj diplomskog rada je usporediti metode za procjenu stvarne potražnje u sustavima za upravljanje kapacitetima zrakoplova. Potrebno je opisati elemente sustava za upravljanje kapacitetima zrakoplova i njihovu ulogu u procesu raspodjele sjedala u pojedine klase prijevoza. Važno je odrediti stvarnu potražnju u prošlosti, odnosno potražnju koja bi postojala da nisu postavljeni rezervacijski limiti za pojedine cjenovne razrede. Rad je podijeljen u sedam cjelina:

1. Uvod
2. Sustavi za upravljanje kapacitetima zrakoplova
3. Modul za prognoziranje potražnje u sustavu za upravljanje kapacitetima zrakoplova
4. Jednostavne metode za procjenu stvarne potražnje
5. Statističke metode za procjenu stvarne potražnje
6. Usporedba metoda za procjenu stvarne potražnje
7. Zaključak

U drugom poglavlju je opisan sustav za upravljanje kapacitetima zrakoplova. U aspektima pokretanja sustava veliku važnost imaju razvrstavanje kupaca prema grupama, upravljanje cijenama, kontrola raspoloživih sjedala i sl. Koraci sustava za upravljanje kapacitetima zrakoplova obuhvaćaju izradu strategije, analizu poslovanja, određivanje cijena, te pohranjivanje podataka.

Treće poglavlje opisuje modul za prognoziranje potražnje u sustavu za upravljanje kapacitetima zrakoplova. Opisana je uloga prognoziranja potražnje, važnost nadogradnje cenzuriranih podataka, te se opisuju kvantitativne i kvalitativne

metode prognoziranja potražnje poput regresijske analize, metode stručne procjene i Delphi metode.

Metode za procjenu stvarne potražnje imaju značajan utjecaj na učinkovitost ukupnog sustava za upravljanje kapacitetima zrakoplova. Četvrto poglavlje obuhvaća relativno jednostavne metode za procjenu stvarne potražnje koje koriste isključivo raspoložive podatke i metode koje zamjenjuju cenzurirane podatke novim vrijednostima. Takve metode koriste algoritme na različite načine i upravo način procjene tih vrijednosti čini razliku između pojedinih metoda u tim skupinama. Tako je opisana metoda zamjene cenzuriranih podataka aritmetičkom sredinom necenzuriranih podataka te metoda zamjene cenzuriranih podataka medijanom, gornjim kvartilom ili percentilom necenzuriranih podataka.

Peto poglavlje opisuje statističke metode za procjenu stvarne potražnje koje se temelje na vjerojatnosti i statistici. U te metode pripadaju metoda dogradnje krivulje rezervacija, metoda maksimizacije očekivanja i metoda projiciranja stvarne potražnje. Takve metode uglavnom zahtijevaju kompleksnije izračune koji se često sastoje od više iteracija te im je potrebno više vremena za proračune, što se može vidjeti i kroz prikazane primjere.

U šestom poglavlju uspoređuju se metode za procjenu stvarne potražnje. Niti jedna metoda nije dovoljno pouzdana niti točna da bi se moglo reći da je ona najbolja ili da bi se mogla koristiti zasebno, već je korištenje više metoda najpouzdaniji način za procjenu stvarne potražnje.

2. SUSTAVI ZA UPRAVLJANJE KAPACITETIMA ZRAKOPLOVA

Sustav za upravljanje kapacitetima zrakoplova predstavlja sinergijski pokušaj optimizacije mrežnih rezultata, pri čemu se ne inzistira na maksimalnom faktoru popunjenosti putničke kabine, niti na maksimalnom prihodu po putniku (sjedalu), već na maksimalnom prihodu po letu, odnosno cjelokupnoj rutnoj mreži opsluživanja.[1]

Sustav za upravljanje kapacitetima zrakoplova zahtijeva potpuni sustav, a on uključuje sljedeće elemente:

- prikupljanje podataka iz prošlosti
- klasifikaciju i uređivanje podataka
- procjenu stvarne potražnje u slučajevima „zatvorenih" klasa prijevoza (klasa prijevoza kod kojih je dosegnut rezervacijski limit te je došlo do odbijanja zahtjeva)
- izradu prognoze za buduće letove
- procjenu točnosti prognoza.[2]

Sustav također predstavlja tehniku koja pomaže velikim kompanijama ili malim i srednjim poduzećima, da postignu najviše prihode ispravnim identificiranjem grupe kupaca kojima kompanije nude proizvode i usluge, utvrđujući pravu količinu proizvoda i usluga, kao i postavljanje optimalne cijene koja bi se ponudila kupcima.

Često korištena istoznačnica za upravljanje kapacitetima je upravljanje jediničnim prinosima (engl. *yield management*). Postoje neke razlike između upravljanja kapacitetima i upravljanja prinosima, a jedna od tih razlika je u tome što je upravljanje kapacitetima dio strateškog planiranja, tj. odnosi se na predviđanje zahtjeva i ponašanja kupaca te prodaju i raspoloživost proizvoda po odgovarajućoj cijeni, dok je upravljanje prinosima dio taktičkog planiranja, tj. više je usmjereno na prodavanje određene usluge određenim kupcima po pravoj cijeni. Druga razlika je u tome što je upravljanje kapacitetima primjenjivo na cjelokupni proces i uzima u obzir ukupne prinose, dok je upravljanje prinosima primjenjivo na određeni dio procesa i njegove prinose i troškove.[3]

To se može prikazati na primjeru prodaje karata za jedan let, gdje se karte za taj let mogu prodati po različitim cijenama. Različitost cijena ovisi o ograničenjima proizvoda kao i preostalom vremenu do odlaska i broju prodanih karata. Ovim načinom prodaje karata prijevoz postaje jeftiniji i pristupačniji, a uslužne djelatnosti postaju sve važnije u maloprodaji, telekomunikaciji, zabavi, financijskoj ulozi, zdravstvu, hrani itd.

[1] Tatalović, M., Mišetić, I., Bajić, J.: *Menadžment zrakoplovne kompanije*, MATE d.o.o., Zagreb, 2012., p. 717.
[2] Belobaba, P. P., Weatherford, L.: *Demand Forecasting in RM Systems*, STAR Alliance RM Educational Program, Taipei, 2016., p. 4.
[3] Gökşen, S.: *Implementing Revenue Management*, BMI – Paper, Amsterdam, 2011., p. 13.

Sustav za upravljanje kapacitetima zrakoplova započinje s temeljitom i što preciznijom metodologijom promatranja ponašanja putnika u povijesnoj vremenskoj odrednici koja je primjerena i prihvatljiva s pozicije komparabilnosti. Pri tome je važno prepoznati i izdvojiti posebne, neplanirane i izvanredne okolnosti koje su utjecale na razinu prometnog učinka na svakoj liniji u zavisnosti od vršnih sati, dana i godišnjih doba. Dnevne i sezonske oscilacije prometa moraju biti procijenjene i prepoznate, kako bi matematički model u svojim početnim pretpostavkama bio vjerodostojan u predviđanju budućih očekivanih i procijenjenih parametara. Simulacija sadašnjeg i budućeg ponašanja putnika mora biti što realnija.[4]

Ključni čimbenici sustava za upravljanje kapacitetima su prisutni u:

- kvalitetnoj prognozi veličine potražnje;
- optimizaciji prihoda na letu;
- efikasnom planiranju razine prekomjernih rezervacija.

Dobra provedba navedenih čimbenika prema mjerenjima korisnika utječe na razinu povećanja prihoda zračnih prijevoznika u rasponu 2-6%. Prema mnogim analizama i izvorima presudna je prva navedena faza precizne prognoze veličine potražnje.[5]

Implementacija sustava za upravljanje kapacitetima zrakoplova trebala bi se posebno orijentirati na zračne prijevoznike. Zračni prijevoznici imaju puno zajedničkih obilježja koji su važni za sustav za upravljanje kapacitetima (npr. potražnja za kartama, operativni troškovi), ali se razlikuju u proizvodima i uslugama koje oni nude. Ti proizvodi i usluge zahtijevaju posebnu pažnju tijekom primjene sustava za upravljanje kapacitetima. Zračni prijevoznici razmatraju uvođenje sustava za upravljanje kapacitetima kada žele povećati prihod. Većina prijevoznika smatra da postoji jedinstvena strategija za određivanje cijene karata uz koju bi ostvarili maksimalnu zaradu. Naime, takva strategija ne postoji jer se karte ovisno o potražnji mogu prodavati po različitoj cijeni.

Sustav za upravljanje kapacitetima se ne temelji na postavljanju i ažuriranju cijena, već na postavljanju i ažuriranju dostupnosti cijena određenih klasa, gdje svaki razred ima pridruženu cijenu koja ostaje konstantna kroz razdoblje rezervacije. Sustav za upravljanje kapacitetima zrakoplova istovremeno pruža obostranu korist i kupcima i zračnim prijevoznicima. Kupcima kojima je bitno dobiti sjedalo na prvotno željenom letu, u pravilu nije bitna cijena, a onima kojima je bitna cijena nije toliko bitna razina usluge odnosno spremni su odustati od najpoželjnijeg datuma putovanja.

[4] Tatalović, M., Mišetić, I., Bajić, J.: *Menadžment zrakoplovne kompanije*, MATE d.o.o., Zagreb, 2012., p. 717.
[5] Ibidem

2.1. Aspekti pokretanja sustava za upravljanje kapacitetima zrakoplova

Sustav za upravljanje kapacitetima zrakoplova je razvijen od strane zračnih prijevoznika kako bi se povećali prihodi i konkurentnost. Zračnim prijevoznicima je bilo očito da se putnici mogu podijeliti u dvije osnovne kategorije, na temelju vrste putovanja i njihove osjetljivosti na cijenu, na visokoplatežne i niskoplatežne putnike. Visokoplatežni putnici imaju tendenciju kupovanja karata blizu datuma polaska te borave u odredištu relativno kratko vrijeme. U njihovim planovima je obično malo fleksibilnosti te su spremni platiti višu cijenu karte. S druge strane, niskoplatežni putnici, rezerviraju svoj let puno prije njihovog datuma putovanja. Oni ostaju duže u odredištu i imaju mnogo više fleksibilnosti u svojim planovima te često odluče putovati nekoliko dana ranije ili kasnije ako to znači manju cijenu putovanja.[6]

Zračni prijevoznici često imaju problem s prodajom karata kojima je ograničen broj i koje moraju prodati u određenom razdoblju. Ako je tržište sastavljeno od kupaca koji su osjetljivi na cijene i onih koji nisu, tada se stvara prilika za prodaju karata različitim kupcima po različitim cijenama. Zračni prijevoznici su uspješno odradili posao podjele svojih putnika prema spremnosti za plaćanje te nastoje svakom tržišnom segmentu ponuditi tarifni proizvod koji je u skladu s osjetljivošću putnika na cijenu i fleksibilnost kod promjene vremena leta.

2.1.1. Segmentacija

Segmentacija se može definirati kao proces razvrstavanja kupaca u različite grupe ili segmente na temelju njihovih promatranih obilježja. Cilj segmentacije je identificirati tko kupuje proizvod, kako će ih kupci kupiti, kad će ih kupiti i koji su im atributi važni. Na temelju vlastitih preferencija, neki kupci će više cijeniti proizvod koji je predložen od strane zračnih prijevoznika nego od strane kupaca i zbog toga će biti spremni potrošiti više novaca na taj proizvod.

Da bi bili uspješni, zračni prijevoznici razvrstavaju svoje kupce u skupine po cjenovnoj i po vremenskoj osjetljivosti. Tablica 2.1. prikazuje razvrstavanje kupaca za određenu industriju.

[6] Zeni, R. H.: *Improved Forecast Accuracy in Airline Revenue Management by Unconstraining Demand Estimates from Censored Dana, Dissertation.com*, USA, 2001., p. 2.

Tablica 2.1. Segmentacija kupaca prema industriji

Industrija	Segmentacija kupaca
Hoteli	Turisti, visokoplatežni, kupci kojima je bitna lokacija, broj kreveta itd.
Zračni prijevoznici	Visokoplatežni, turisti, studenti, djeca, mladi, veterani, grupni, vojni.
Teret	Male, srednje, velike količine.
Energija	Visokoplatežni, maloprodajni, restorani, trgovine itd.

Izvor: Gökşen, S.: *Implementing Revenue Management*, BMI – Paper, Amsterdam, 2011., p. 18.

2.1.2. Upravljanje cijenama

Prema nekim istraživanjima, u sustavima za upravljanje kapacitetima zrakoplova može doći do pojave „nepoštenih“ cijena - primjena različitih cijena za slične proizvode prema različitim skupinama kupaca. Nudeći različite cijene različitim skupinama kupaca, zračni prijevoznici nadaju se povećanju svojih prihoda ili zadržavanju postojeće razine prihoda. Upravljanje cijenama znači sustavno nuđenje različitih cijena različitim skupinama kupaca kao odgovor na promjene u potražnji i njihovim karakteristikama.[7]

Putnici koji su orijentirani na kvalitetu, mogu utjecati na potražnju određenog proizvoda nekog zračnog prijevoznika, prema njihovim osobnim karakteristikama i spremnosti na plaćanje ovisno o njihovoj cjenovnoj elastičnosti. Niskoplatežni putnici su u pravilu vrlo cjenovno elastični, dok su visokoplatežni putnici više vremenski osjetljivi i manje cjenovno elastični.

Zračni prijevoznik može dati određeni popust putnicima koji ranije rezerviraju svoje karte. Na taj način prijevoznik može pokriti neke fiksne troškove i koncentrirati se na skuplje ponude kako bi ostvario veći prihod. Shodno tome, upravljanje cijenama igra važnu ulogu kod sustava za upravljanje kapacitetima zrakoplova.

2.1.3. Prognoziranje potražnje

Točna prognoza potražnje je neophodna kod sustava za upravljanje kapacitetima zrakoplova. Ingold[8] tvrdi da prognoziranjem potencijalne potražnje na temelju povijesnih podataka o prodaji i predviđenih budućih događaja, zračni prijevoznici mogu predvidjeti: veličinu ciljanih tržišnih segmenata i cijenu koju će svaki segment biti spreman platiti za proizvod ili uslugu. Ako zračni prijevoznik ima podatke o potražnji na određenim linijama u prethodnom razdoblju, tada može

[7] Gökşen, S.: *Implementing Revenue Management*, BMI – Paper, Amsterdam, 2011., p. 19.
[8] Ibidem

procijeniti potražnju za buduće letove, uzimajući u obzir situaciju na tržištu, ekonomsku situaciju u zemlji ili svijetu i predviđenom povećanju potražnje. U tome mu može pomoći segmentacija kupaca jer omogućuje određivanje potrebnog broja mjesta u svakoj klasi i razlike u cijeni između klasa. Na taj način zračni prijevoznik može razvrstati svoje kupce i dodijeliti konkretnu cijenu za svaku pojedinu klasu, moguće popuste i sl., te tako povećati prihod kompanije. Međutim, svaka industrija se mora suočiti s teškoćama u predviđanju potražnje. U zračnom prijevozu, važno je uzeti u obzir sezonske varijacije u potražnji.

2.1.4. Kontrola raspoloživih sjedala

Osnovni element sustava za upravljanje kapacitetima zrakoplova jest podjela sjedala u različite klase prijevoza. Primjerice, jedna klasa može dopustiti zamjenu karte ili odustajanje od leta tjedan dana prije polaska, dok druga klasa to ne dopušta. Nakon kupnje karte, nije moguće napraviti promjene u toj klasi ili otkazati i dobiti povrat novca. Dizajniranje tarifnih proizvoda se može temeljiti na datumu rezervacije obzirom na datum polaska ili duljini boravka putnika u odredištu. Putnici u istoj klasi dobivaju istu kvalitetu usluge, ali ne moraju nužno sjedati jedan pored drugoga. Među prijevoznicima nema istih standarda, tj. svaki prijevoznik postavlja vlastitu klasifikaciju klasa.[9]

Kod sustava za upravljanje kapacitetima zrakoplova, važno je ograničavanje ili pomicanje dostupnosti određenih proizvoda odnosno usluga prema zahtjevu kupaca u određenom razdoblju. Npr. ako nema interesa za boljim sjedalima, a potražnja za standardnim sjedalima premašuje ponudu, zračni prijevoznik može prodavati bolja sjedala za istu cijenu kao i standardna, inače bi sjedala bila prazna i zračni prijevoznik bi imao gubitak. Može se zaključiti da je bolje prodati sjedalo po manjoj cijeni, nego ne prodati uopće.[10]

Isto tako, postoji mogućnost da će na zrakoplovu biti rezervirana sva sjedala, ali će poletjeti s par praznih mjesta. Putnici koji su rezervirali svoje sjedalo, a ne pojave se, zovu se „no-show“ putnici. Jedno rješenje ovog problema je „overbooking“ odnosno kada zračni prijevoznici dozvoljavaju prodaju više karata nego što je broj mogućih sjedala. U slučaju da se putnik ne pojavi, dopušta se sljedećem putniku da zauzme njegovo mjesto, a ako se svi putnici pojave i nema mjesta za neke putnike, njima se nalazi drugi let ili im se rezervira hotel gdje mogu prespavati. Postoji i druga skupina putnika, tzv. „go-show“ putnici, a to su putnici koji se predbilježe za let na kojem više nema mjesta u nadi da se neki putnici neće pojaviti. Ti putnici dobivaju „standby“ kartu i čekaju nadajući se da će im se osloboditi mjesto.[11]

[9] Ibidem, p. 22.
[10] Ibidem, p. 20.
[11] Ibidem

2.2. Koraci implementacije sustava za upravljanje kapacitetima zrakoplova

Zračni prijevoznik mora imati na umu da ne postoji jedinstvena strategija koja se može primijeniti na svaki posao. Isto tako, prijevoznik mora postaviti jasne ciljeve koji se moraju priopćiti u kompaniji kako bi ih svi postali svjesni i kako bi ih svi izvršavali. Na temelju tih utvrđenih ciljeva, učinkovita prilagodba njegovih tehnika do vlastitog tržišta, proizvoda, natjecanja, kulture, korporativne misije i ograničenja može igrati ulogu za postizanje ciljeva. Stoga je važno da se poduzmu neki koraci za implementaciju sustava za upravljanje kapacitetima kako bi uspjeli.

Važni koraci za implementaciju sustava za upravljanja kapacitetima su:

- izrada strategije i analiza poslovanja
- procjena cijene proizvoda
- kupnja ili izrada sustava
- pohranjivanje podataka i prognoziranje.[12]

2.2.1. Izrada strategije i analiza poslovanja

Kao jedan od prvih koraka u implementaciji sustava za upravljanje kapacitetima zrakoplova, priprema strategije može biti presudan faktor u pomaganju zračnim prijevoznicima kako bi razumjeli razinu ulaganja i napravili dobre odluke. Tijekom razvoja strategije može se i odlučiti za odgodu implementacije, stoga bi strategija trebala predstavljati jasan pregled implementacije s troškovima i mogućom dobiti. Pritom je važno uzeti u obzir opterećenost i potrebne resurse koji su dostupni odnosno koje je potrebno nabaviti za provedbu strategije.

Za zračnog prijevoznika je važno da analizira svoje poslovanje prije implementiranja sustava za upravljanje kapacitetima, jer je implementacija skup i dugotrajan proces. Potrebno je uvesti organizacijske promjene, te je važno uključiti i informirati cijeli tim o tom procesu. Tim mora razmišljati zajedno jer na taj način kompanija razmatra svoj položaj na tržištu i određuje buduće ciljeve. Iduća važna stvar pri izradi strategije je određivanje cijene proizvoda. Zračni prijevoznik mora odlučiti želi li koristiti drugačije taktike ponude za cijene svojih proizvoda. Jedna od mogućih taktika mogla bi biti „differential pricing“. „Differential pricing“ je taktika ponude istog proizvoda s različitim cijenama različitim skupinama kupaca. Ideja se zasniva na ponudi niže cijene kupcima koji nisu spremni platiti veću cijenu i više cijene onima koji jesu. Druga taktika se zove „channel pricing“, što znači da zračni prijevoznici prodaju iste proizvode po različitim cijenama ovisno o prodajnom mjestu. Primjer za to je putovanje New York-Tokio, gdje karta koja je kupljena od zračnog prijevoznika u Japanu obično košta više od iste karte kupljene u SAD-u.[13]

[12] Gökşen, S.: *Implementing Revenue Management*, BMI – Paper, Amsterdam, 2011., p. 27.
[13] Ibidem

2.2.2. Određivanje cijene proizvoda

U implementaciji sustava za upravljanje kapacitetima zrakoplova određivanje cijene proizvoda igra jednu od važnih uloga. Za prijevoznike je važno shvatiti koliko proizvoda i usluga njihovi kupci kupuju u odnosu na cijene koje kompanija nudi. Cijena je postala važniji čimbenik u poslovanju, jer je jedna od učinkovitih varijabli koju prijevoznici koriste kako bi promovirali ili degradirali svoje proizvode. Cijena je važna ne samo s financijskog, već i s operativnog stajališta.

Prilikom implementacije sustava za upravljanje kapacitetima, menadžeri trebaju odrediti strukturu i razine cijena koje će biti ponuđene kupcima. Shaw[14] ističe da bi se popusti koji se daju putnicima trebali stalno kontrolirati jer će u suprotnom putnici s niskom cjenovnom elastičnošću stalno iskorištavati prednost snižene cijene. Kontrola sniženih cijena se može vršiti na dva načina. Prvi način korištenja sustava za upravljanje kapacitetima zrakoplova je kako bi se odredio broj sjedala po najnižim cijenama koje mogu biti ponuđene na različitim letovima. Drugi način je određivanje restriktivnih uvjeta koji utječu na cijenu i pomažu zračnom prijevozniku da ponudi nisku cijenu za cjenovno osjetljive kupce. Restriktivne uvjete treba pažljivo dizajnirati, a neki od njih su:

- minimalna/maksimala duljina boravka;
- obaveza kupnje karte unaprijed;
- povlaštene cijene;
- cijena karte kao dio šire usluge.

2.2.3. Kupnja ili izrada sustava za upravljanje kapacitetima zrakoplova

Zračni prijevoznik se može odlučiti za kupnju sustava za upravljanje kapacitetima zrakoplova od specijaliziranih tvrtki, npr. ORTEC ili se može odlučiti na izradu vlastitog sustava za upravljanje kapacitetima. Kupnja takvog sustava podrazumijeva dolazak vanjskih stručnjaka, te treba uzeti u obzir da oni neće odmah razumjeti način poslovanja, proizvode (usluge) i njihove cijene. Odabir vanjskih stručnjaka nije uvijek najbolja opcija jer se prijevoznik izlaže raznim rizicima. Uz to, prijevoznik treba uzeti u obzir troškove za plaćanje njihovog rada tijekom cijele implementacije kao i tijekom korištenja kupljenog sustava. Iako izrada sustava za upravljanje kapacitetima može izgledati kao jeftinija alternativa od kupnje gotovog sustava, prilikom izrade može doći do puno pogrešnih koraka zbog manjka iskustva i korištenja krivih podataka, a rezultat može biti skuplji od kupnje gotovog sustava. Stoga bi najbolja opcija bila izraditi sustav za upravljanje kapacitetima uz pomoć stručnjaka i to korak po korak, prilagođen potrebama prijevoznika.

Rezervacijski sustav je osnovna pretpostavka za implementaciju sustava za upravljanje kapacitetima, jer prijevoznik dobiva sve podatke i informacije iz

[14] Ibidem, p. 29.

rezervacijskog sustava. Na primjer, American Airlines je bila u mogućnosti da to učini bolje od People Express-a, jer su imali računalni rezervacijski sustav SABRE (engl. *Semi-automated Business Research Environment)* koji omogućuje da se iskoriste prazna sjedala za putnike koji rezerviraju u posljednjim trenucima. SABRE kombinira funkcije računalnog rezervacijskog sustava CRS (engl. *Computerized Reservation System*) i globalnog distribucijskog sustava GDS (engl. *Global Distribution System*). Najvažniji dio rezervacijskog sustava je dio gdje se kontroliraju rezervacije i gdje rezervacijski sustav određuje dostupnost rezervacija pojedinih klasa.[15]

Sustav za upravljanje kapacitetima u pravilu je povezan s prijevoznicima koji posjeduju vlastiti rezervacijski sustav. Prije početka prognoziranja, sustav za upravljanje kapacitetima treba imati pristup trenutnom broju ukupnih rezervacija i preostalog kapaciteta, te dobru povezanost s GDS-om kako bi imao pristup najnovijim informacijama. Potencijalni problem za zračne prijevoznike je zlouporaba od strane putničkih agencija, npr. putnička agencija može rezervirati uslugu leta, a kasnije ju otkaže jer je našla jeftiniju opciju. Postoji puno takvih zlouporaba i to dovodi do gubitka prihoda zračnih prijevoznika, jer putnička agencija otkaže prekasno pa prijevoznik ne uspije popuniti let.

Pouzdanost, redundancija i iskustvo su dobra podloga za primjenu sustava za upravljanje kapacitetima zrakoplova. Na primjer, ako sustav za upravljanje kapacitetima nije u funkciji, upravljanje klasama neće biti moguće, a to može dovesti do značajnog gubitka prihoda. Korisničko sučelje je također važan sastavni dio sustava i vrlo je važno da je učinkovito. Korisničko sučelje može podržavati izradu cijena, prognoza, stvaranje grupa, raspoloživosti i smjernice za primjenu sustava.[16]

Ako se zračni prijevoznik odluči izraditi sustav za upravljanje kapacitetima, mora imati na umu da se sustav treba provoditi na tri razine:

- na *strateškoj razini* - zahtijeva identifikaciju segmenata kupaca i stvaranje diferenciranih cijena;
- na *razini kontrole rezervacija* - zahtijeva odluke u realnom vremenu, tj. treba li se zahtjev za rezervacijom prihvatiti ili odbiti; rezervacijski sustav uključuje rezervacijske limite za svaku klasu; kada se zahtjev za rezervaciju primi, rezervacijski sustav provjerava rezervacijski limit te klase; ako ima dovoljno mjesta, zahtjev će biti prihvaćen, a sustav će automatski ažurirati zauzetost, dok će u suprotnom biti odbijen;
- na *srednjoj razini* - taktičko upravljanje kapacitetima periodično, tj. u točkama provjere, izračunava i ažurira rezervacijske limite koji se koriste za kontrolu raspoloživih sjedala.[17]

[15] Ibidem
[16] Ibidem, p. 30.
[17] Ibidem, p. 31.

2.2.4. Pohranjivanje podataka i prognoziranje

Sustav za upravljanje kapacitetima predstavlja dio računalnog sustava koji zahtijeva različite unose podataka kako bi se napravila prognoza buduće potražnje. Potrebno je učinkovito prikupljanje i pohranjivanje podataka u sustavu za upravljanje kapacitetima kako bi se mogle napraviti pouzdane i što točnije prognoze. Prikupljene povijesne podatke treba oprezno analizirati i pregledati, a pogrešne podatke treba eliminirati. Nakon što su podaci pohranjeni, prijevoznik može započeti s procesom prognoziranja buduće potražnje.

Prognoziranje je bitno za svakodnevno poslovanje prijevoznika jer informira upravu o budućim poslovnim izgledima. Proces prognoziranja obično se temelji na pomno utvrđenom modelu prognoze koji se odnosi na podatke prijevoznika stare najmanje dvanaest mjeseci. Prognoziranje buduće potražnje se treba prilagoditi svakom prijevozniku i treba uzeti u obzir moguće greške koje su se pojavile u procesu prikupljanja podataka.

Ukoliko je prognostički sustav ispravno postavljen, proces prognoziranja neće biti kompliciran i težak, no postizanje dobre i točne prognoze nije lako jer postoje mnogi čimbenici koji utječu na njezinu točnost. Cross[18], predlaže korištenje sljedećih pravila za dobru prognozu:

- prognoza treba biti što detaljnija;
- u analizi treba koristiti što veću količinu podataka;
- stalno prilagođavanje prognoze zbog mogućih ekonomskih ili specifičnih promjena prijevoznika.

Talluri[19] prepoznaje dvije vrste prognoze sustava za upravljanje kapacitetima zrakoplova:

- kvantitativno utemeljene prognoze sustava za upravljanje kapacitetima
- cjenovno utemeljene prognoze sustava za upravljanje kapacitetima.

Prvi tip uglavnom primjenjuju zračni prijevoznici i hoteli. Osim podataka potražnje, kvantitativno utemeljena prognoza sustava za upravljanje kapacitetima zahtijeva informacije o izgledu kumulativne krivulje rezervacija za različite vrste kupaca koji dolaze tijekom rezervacijskog procesa. Ova vrsta prognoze treba procjenu broja otkazanih rezervacija i vjerojatnosti nepojavljivanja putnika. Drugi tip se temelji na procjeni parametara funkcije potražnje gledajući povijesni omjer cijene i potražnje za uslugama. Dakle, da bi implementacija sustava za upravljanje kapacitetima zrakoplova bila uspješno provedena nužno je razviti dobar prognostički sustav.

Raza[20] ističe da je za kompaniju važno usklađivanje rezultata prognoze s ekonomskim, financijskim ili operativnim promjenama koji mogu utjecati na potražnju.

[18] Gökşen, S.: *Implementing Revenue Management*, BMI – Paper, Amsterdam, 2011., p. 32.
[19] Ibidem, p. 31.

Takve prognoze nije uvijek lako izraditi, a osobe koje su odgovorne za njih su dužne predočiti podatke objektivno i iskreno. Često je potrebno ponovno izraditi prognoze buduće potražnje jer neki slučajni događaji mogu umanjiti točnost prognoze unatoč razumnoj količini podataka koja se koristi, točnosti podataka, pa čak i metodologiji prognoziranja. Kako bi se prognoze buduće potražnje zadržale ažuriranima, potrebno je ponovno prognoziranje, pregledavanje i preispitivanje podataka.

[20] Ibidem

3. MODUL ZA PROGNOZIRANJE POTRAŽNJE U SUSTAVU ZA UPRAVLJANJE KAPACITETIMA ZRAKOPLOVA

Specifičnosti prognoziranja potražnje za potrebe upravljanja kapacitetima zrakoplova prikazuju se kroz četiri stavke:

1. Predviđanje potražnje je potrebno napraviti na mikrorazini, tj. na razini cjenovnog razreda.
2. Povijesni podaci, tj. podaci o broju rezervacija u pojedinom cjenovnom razredu često ne predstavljaju ukupnu potražnju jer rezervacijski sustavi ne arhiviraju odbijene zahtjeve pa umjesto stvarne imamo cenzuriranu potražnju.
3. Pored konačnog broja rezervacija po pojedinom cjenovnom razredu, potrebno je predvidjeti i broj rezervacija u podintervalima rezervacijskog procesa koji započinje nekoliko mjeseci prije datuma leta kako bi se u određenim točkama provjere reoptimirali rezervacijski limiti cjenovnih razreda.
4. Osim broja rezervacija, za svaki je cjenovni razred nekog leta potrebno predvidjeti i broj putnika koji se neće pojaviti na odletu, broj otkazanih rezervacija, broj putnika koji će se pojaviti u zadnji trenutak kako bi otputovali tim letom, broj putnika koji su spremni prihvatiti mogućnost „vertikalnog pomaka“.[21]

Metode kojima se predviđa prometna potražnja dijele se u dvije skupine:

1. **Kvantitativne metode** → odnose se na događaje čija se veličina može brojčano izraziti.
2. **Kvalitativne metode** → predviđaju vjerojatnost pojave nekog događaja u budućnosti; oslanjaju se na iskustvo stručnjaka i koriste se u slučajevima nedostatka povijesnih podataka (npr. tehnike izvještaja, ankete, upitnici, savjetnički timovi, Delphi metoda i sl.); svrsishodne su za kratkoročne prognoze; mogu poslužiti i kao podloga za kvantitativne metode koje se koriste za dugoročno prognoziranje.[22]

3.1. Uloga prognoziranja potražnje

Razlike između prognozirane i stvarne potražnje su najvidljivije kad se odnose na ukupnu razinu poslovanja. Prognoziranje potražnje nije umjetnost niti znanost, a svako prognoziranje koje uključuje ljude je nepouzdano i vjerojatno krivo, zato jer uključuju brojne proizvoljne pretpostavke i mišljenja. Zbog toga analitičari koji prognoziraju potražnju moraju razumjeti i cijeniti činjenicu da prognoziranje potražnje nije uvijek točno.

[21] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 79.
[22] Ibidem, p. 80.

Osnovni koncept prognoziranja je procijeniti dosadašnje trendove te ih usmjeriti prema budućim zahtjevima. Na prvi pogled taj zadatak može izgledati jednostavno, no on je zapravo vrlo kompleksan jer analitičari moraju napraviti različite pretpostavke za procjenu prošlih trendova. Potrebno je odabrati raspon korištenih podataka, ovisno o vremenskom periodu ili različitim okolnostima, i osnovne elemente prognoziranja te vrste tih elemenata. Drugi analitičari mogu odabrati iste elemente, ali primjenom drugačijeg pristupa mogu dobiti poprilično različite rezultate.[23]

Matematički postupci koji su primijenjeni u prognoziranju potražnje mogu izgledati zastrašujuće i komplicirano, ali svi postupci predstavljaju jednu jednostavnu ideju. Cilj ideje je stvoriti formulu koja dobro korelira s prošlim iskustvima. Analitičari to čine podešavanjem parametara formula, oblikovanjem tih formula i uključivanjem svih promjenjivih varijabli. Može se zaključiti da matematički odabir nije odlučujući faktor.

Uspješan sustav za upravljanje kapacitetima zrakoplova zahtijeva točno prognoziranje potražnje za svaki tržišni segment. Prognoze se koriste kako bi zračni prijevoznici postavili rezervacijske limite niskoplatežnim korisnicima te istovremeno osigurali adekvatnu ponudu za visokoplatežne korisnike. Sama upotreba rezervacijskih limita ograničava podatke o potražnji na realiziranim letovima u prošlosti, a koji su potrebni za točno prognoziranje potražnje. Ignoriranje ove interakcije dovodi do smanjenja budućih prihoda prijevoznika.[24]

Najveći izazov kod sustava za upravljanje kapacitetima zrakoplova je ostaviti dovoljno praznih mjesta po nižim cijenama, te ujedno spriječiti visokoplatežne putnike da kupe kartu po nižim cijenama. Budući da niskoplatežni putnici obično rezerviraju mjesta prije visokoplatežnih putnika, sustav za upravljanje kapacitetima mora predvidjeti koliko će visokoplatežnih putnika htjeti rezervirati let. Stoga se ta mjesta moraju izdvojiti ili „zaštiti“, tako da budu na raspolaganju kad ih visokoplatežni putnici zatraže. Ako je prognoza za visokoplatežne putnike previsoka, onda će previše mjesta biti zaštićeno, a zrakoplov će odletjeti s praznim mjestima koja su mogla biti prodana niskoplatežnim putnicima i na taj način bi se ostvarila barem neka vrsta prihoda. Ako je prognoza za visokoplatežne putnike preniska, onda će premalo mjesta biti zaštićeno, te će se sjedala prodavati drugim putnicima po nižoj cijeni, a mogla su biti prodana visokoplatežnim putnicima po višoj cijeni. Rezultat takve prognoze je smanjenje ukupnog prihoda na letu.

[23] De Neufville, R., Odoni, A.: *Airport systems: Planning, Design and Management*, the McGraw-Hill Companies, 2003., p. 765.
[24] Crystal Queenan, C., Ferguson, M., Higbie, J., Kapoo, R.: *A Comparison of Unconstraining Methods to Improve Revenue Management Systems*, Production and Operations Management Society, Vol. 16, No. 6, 2007., p. 729.

3.2. Važnost nadogradnje cenzuriranih podataka

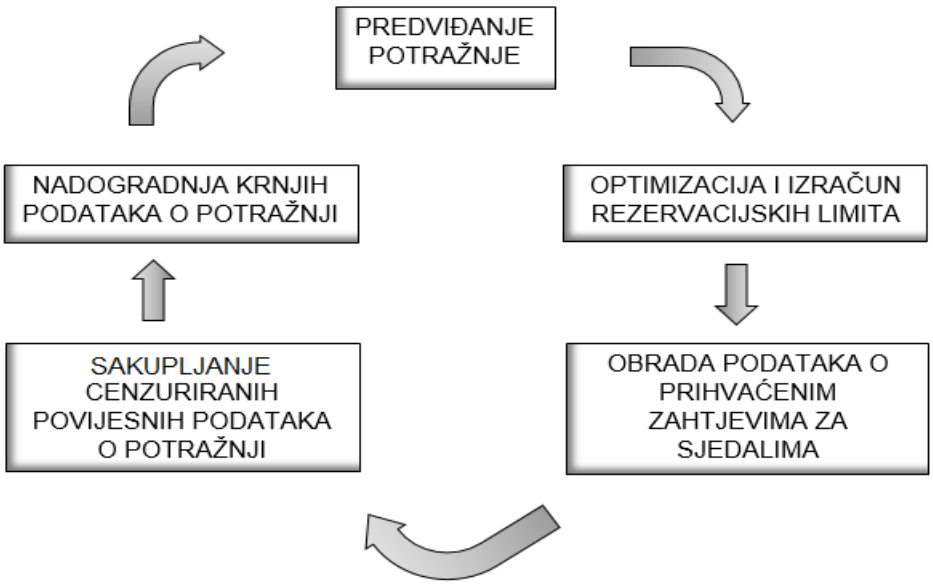
Točne prognoze su od ključne važnosti za sustav upravljanja kapacitetima. Loše procjene potražnje mogu dovesti do neadekvatne kontrole resursa i gubitka prihoda. Konkurentna djelovanja, sezonski faktori, gospodarsko okruženje i stalne promjene cijena neke su od prepreka koje se moraju prevladati pri prognoziranju u sustavu za upravljanje kapacitetima zrakoplova. Prognoziranje otežava i činjenica da je većina podataka o potražnji u prošlosti cenzurirana.

Broj mjesta koje zračni prijevoznik može prodavati na letu određen je rezervacijskim limitima u sustavu za upravljanje kapacitetima. Zračni prijevoznici prihvaćaju rezervacije u klasi dok se ne postigne rezervacijski limit. U tom trenutku, prijevoznik prestaje s prodajom mjesta u toj klasi, prikupljanjem i bilježenjem vrijednih podataka, tj. brojem zahtjeva koje nije bilo moguće potvrditi. Dakle, podaci su cenzurirani ili „ograničeni“ rezervacijskim limitima. Iako postoje neki modeli koji daju približne prognoze koje su dobivene korištenjem cenzuriranih podataka, svakako je poželjno bilježenje svih opažanja i podataka koji bi omogućili dobivanje točnije prognoze.[25]

Kada se cenzurirani podaci o potražnji u prošlosti koriste za procjenu stvarne potražnje, prognoza često rezultira netočnim predviđanjem. Ako sustav za upravljanje kapacitetima koristi takve prognoze, tada će kontrola kapaciteta biti usmjerena na čuvanje mjesta za visokoplatežne putnike. Sjedala koja bi mogla biti prodana visokoplatežnim putnicima, prodat će se niskoplatežnim putnicima, a dio prihoda će biti izgubljen. Procijenjeno je da se do 3,0% potencijalnih prihoda može izgubiti, ako prognoze koje koriste sustav za upravljanje kapacitetima bazirane na cenzuriranim podacima, imaju veliko odstupanje.[26]

Zračni prijevoznici koriste složene sustave za upravljanje kapacitetima zrakoplova kako bi sjedala mogli staviti na raspolaganje po različitim cijenama. Prognoziranje potražnje se temelji na raspoloživim, tj. cenzuriranim podacima. Rezervacije koje su prihvaćene postaju povijesni podaci za sljedeću prognozu, a rezervacije koje su odbijene se ne evidentiraju, stoga dolazi do cenzuriranja podataka. Cenzurirani podaci koji se nadograde s procijenjenim brojem odbijenih zahtjeva predstavljaju povijesnu potražnju koja se zatim koristi za predviđanje buduće potražnje. Ovaj postupak se ponavlja pri prognoziranju potražnje te čini petlju povratne veze koja je prikazana na slici 3.1.[27]

[25] Zeni, R. H.: *Improved Forecast Accuracy in Airline Revenue Management by Unconstraining Demand Estimates from Censored Dana, Dissertation.com*, USA, 2001., p. 1.
[26] Ibidem, p. 2.
[27] Ibidem, p. 4.



Slika 3.1. Tijek podataka o učinjenim rezervacijama

Izvor: Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 135.

Uporaba rezervacijskih limita i neevidentiranje zahtjeva nakon dosezanja postavljenog limita, razlog je cenzuriranih povijesnih podataka o potražnji i nepotpunih ulaznih podataka za pouzdano predviđanje budućih potražnji. U slučaju nedostatka podataka o stvarnoj potražnji, moguć je jedan od triju ishoda:

1. zadržavanje cenzuriranih podataka, tj. podataka koji ne sadrže zahtjeve za jedinicom kapaciteta nakon što je dosegnut rezervacijski limit,
2. izravno bilježenje skrivene (nezadovoljene) potražnje,
3. procjenjivanje stvarne potražnje statističkim metodama, tj. „nadogradnja“ cenzuriranih podataka.[28]

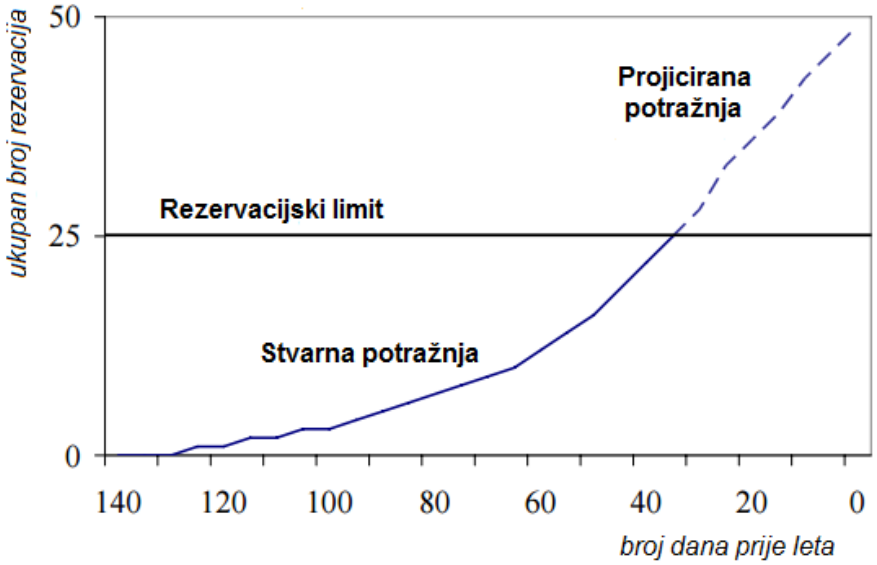
U prvom slučaju dolazi do tzv. *spiral down* efekta i monotonog pada prihoda s vremenom, a takva se praksa koristi kod primitivnih i nedovoljno sofisticiranih sustava za upravljanje kapacitetima zrakoplovima.

Učinak *spiral down* efekta se događa kada netočne pretpostavke o ponašanju kupaca uzrokuju prodaju karata po visokim cijenama, te se prihodi sustavno smanjuju tijekom vremena. Ako zračni prijevoznik na temelju dosadašnjih prodaja po visokim cijenama odluči zaštititi određen broj mjesta po visokim cijenama, ujedno zanemaruje činjenicu da će dostupnost karata po niskim cijenama smanjiti prodaju karata po visokim cijenama, što rezultira lošom procjenom za buduću potražnju karata po visokim cijenama.[29]

[28] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 133.
[29] Cooper, W. L., Homem-de-Mello, T., Kleywegt, A.: *Models of the Spiral-Down Effect in Revenue Management*, Operations research Vol. 54, No. 5, September–October, 2006., p. 968.

Izravno bilježenje odbijenih zahtjeva zbog specifičnih distribucijskih kanala koji uključuju prodaju posredstvom agencija i interneta ne predstavlja realnu mogućnost za zračne prijevoznike. Procjenjivanje stvarne potražnje statističkim metodama obuhvaća niz metoda koje se oslanjaju na cenzurirane podatke, tj. podatke o zabilježenoj potražnji te na indikatore stanja pojedinih cjenovnih razreda koji razlikuju dva osnovna slučaja: kada je rezervacijski limit neke klase dosegnut i kada nije.

Grafikon 3.1. prikazuje slučaj u kojem stvarna potražnja za prijevozom u određenom cjenovnom razredu ne odgovara potražnji koju je zabilježio i arhivirao rezervacijski sustav. Zahtjevi za rezervacijom su pristizali i nakon što je cjenovni razred „zatvoren“, odnosno nakon što je prestala prodaja sjedala u njemu. To znači da je stvarna potražnja nadmašila rezervacijski limit koji je dobiven korištenjem cenzuriranih podataka. Metode za procjenu stvarne potražnje nastoje predvidjeti ukupan broj zahtjeva za određeni cjenovni razred, bili oni prihvaćeni ili odbijeni.[30]



Grafikon 3.1. Kumulativna krivulja rezervacija za „zatvoreni“ cjenovni razred

Izvor: URL: https://smartech.gatech.edu/bitstream/handle/1853/13600/RM_unconstrain_021507_crc.pdf, (pristupljeno: srpanj 2016.)

Profesor L. R. Weatherford je još 1997. godine demonstrirao utjecaj korištenja podataka koji podcjenjuju potražnju na konačnu učinkovitost sustava za upravljanje kapacitetima zrakoplova. Prema rezultatima tog istraživanja, ako je predviđena potražnja za 12,5% manja od stvarne potražnje, prihod na letu se smanjuje za 0,7% do 1,2%. Razlozi za to mogu se sažeti u dva osnovna naglaska:

[30] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 133.

- ako podaci o broju rezervacija nisu nadograđeni, model za predviđanje potražnje će podcijeniti stvarnu potražnju i zaštitit će premali broj sjedala za više klase prijevoza;
- zračni prijevoznici, tržišni konkurenti na liniji koji koriste metode za nadogradnju podataka i potražnji, odbit će zahtjeve za sjedalima u nižim klasama prijevoza te će oni biti preusmjereni prema prijevozniku koji ne prakticira metode za neutraliziranje cenzuriranja podataka o potražnji.[31]

3.3. Kvantitativne metode prognoziranja potražnje

Kvantitativne metode predviđanja prognoze analiziraju kretanja neke pojave u prošlosti i čimbenike koji su na njezino kretanje utjecali. Pokušavaju se kvantificirati ovisnosti među njima, a sama predviđanja budućih kretanja te pojave zasnivaju se na nastavku dosadašnjeg trenda. Sustavi za upravljanje kapacitetima zrakoplova, unatoč razvijenosti metoda predviđanja, uglavnom koriste varijacije standardnih, tj. jednostavnijih metoda. Zbog korištenja cenzuriranih povijesnih podataka, koriste se metode za prognoziranje stvarne potražnje koje analiziraju kretanja pojave u prošlosti i uzroke tih pojava. Tim metodama pokušavaju se utvrditi zakonitosti pojave tih kretanja i razloge koji izazivaju takve pojave. Uglavnom se koriste standardne metode, one metode koje omogućuju općenito predviđanje, ali uvijek postoji mogućnost korištenja metoda usmjerenih isključivo na predviđanje potražnje unutar sustava za upravljanje kapacitetima.

Kvantitativne metode predviđanja se općenito dijele u dvije grupe:

- *metode analize vremenskih nizova* – za kratkoročna predviđanja u nepromjenjivom okruženju;
- *regresijske analize* – uzimaju u obzir jednu ili više zasebnih varijabli koje utječu na potražnju.[32]

3.3.1. Analiza vremenskih nizova

Vremenski niz predstavlja skup kronološki uređenih vrijednosti pojave, a vrijednosti promatrane pojave vremenskog niza zovu se frekvencije. Statistička analiza vremenskih nizova služi za opisivanje razvoja promatrane pojave u određenom vremenskom razdoblju, te pokušava objasniti promjene pojave koristeći neke druge pojave. Analiza vremenskih nizova pokušava predvidjeti ali i kontrolirati dinamične procese.[33]

[31] Ibidem, p. 135.
[32] Ibidem, p. 81.
[33] Šošić, I.: *Primijenjena statistika*, Školska knjiga, Zagreb, 2006., p. 549.

Na temelju vremenskih nizova analiziraju se modeli, odnosno analitički izrazi pomoću kojih se opisuje razvoj pojava u nekom vremenu. Ovisno o statističko teoretskim obilježjima modele vremenskih serija moguće je podijeliti na modele u vremenskoj domeni i modele u domeni frekvencija. Analizom vremenskih nizova potrebno je istražiti utjecaj pojedinih komponenti vremenskog niza te utvrditi veličinu utjecaja svake komponente.

Ciljevi analize vremenskih nizova su:

- opisivanje i objašnjavanje ponašanja pojave tokom vremena;
- određivanje modela kojim se opisuje generirajući proces pojave u vremenu;
- predviđanje budućeg razvoja pojave;
- kontrola.[34]

U klasičnom pristupu vremenskog niza komponente se dijele na:

- T_t - *trend komponenta:* izražava osnovnu dugoročnu tendenciju razvoja pojave u vremenu, odnosno izbor matematičke funkcije trenda koja se najbolje prilagođava razdiobi vremenskog niza, te se utvrđuje pomoću razlika podataka uzastopnih vremenskih jedinica;
- C_t - *ciklička komponenta:* izražava periodično ponavljanje određenih vrijednosti svakih dvije i više godina (u vremenskim nizovima koji predstavljaju potražnju za uslugama u zračnom prometu u kontekstu sustava za upravljanje kapacitetima zrakoplova, u pravilu se ne pojavljuje);
- S_t - *sezonska komponenta:* izražava promjene oko trenda koje se ponavljaju na sličan način u periodu koji je jednak godini dana ili kraći (uočavanje ove komponente ima važnu ulogu za točnost predviđanja buduće potražnje!);
- e_t - *slučajna (iregularna ili rezidualna) komponenta:* izražava nesistematske utjecaje na razvoj pojave, a ostaje nakon uklanjanja sistematskih komponenti (trend, sezonska i ciklička).[35]

3.3.1.1. Metoda pomičnog prosjeka

U nastavku rada koristit će se sljedeće notacije:

- r_i – *i*-ta točka provjere (kronološki)
- $OB(r_i)$ – broj potvrđenih rezervacija u točki provjere r_i (engl. ***o**bserved **b**ookings*)
- $BL(r_i)$ – rezervacijski limit u točki provjere r_i (engl. ***b**ooking **l**imit*)
- $AD(r_i)$ – stvarna, necenzurirana potražnja u točki provjere r_i (engl. ***a**ctual **d**emand*)

[34] URL: http://web.efzg.hr/dok/sta/vbahovec/statistika%20za%20poduzetnike/11_PREDAVANJE_ANALIZA%20VREMENSKOG%20NIZA.pdf, (pristupljeno: kolovoz 2016.)

[35] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 81.

- ***UD(r_i)*** – procijenjena (nadograđena) stvarna potražnja u točki provjere r_i (engl. ***u****nconstrained* ***d****emand*)
- ***AFD(r_i)*** – stvarna buduća potražnja u točki provjere r_i (engl. ***a****ctual* ***f****uture* ***d****emand*)
- ***I(r_i)*** – indikator raspoloživosti sjedala u točki provjere r_i i vrijedi:[36]

$$I(r_i) = \begin{cases} 0, za\ OB(r_i) = BL(r_i) \\ 1, za\ OB(r_i) < BL(r_i) \end{cases} \quad (1)$$

Vrijednost indikatora je 0 ako je dosegnut rezervacijski limit i cjenovni razred je „zatvoren“, a 1 je ako je cjenovni razred „otvoren“ i u njemu ima još raspoloživih sjedala.

Kod metode *pomičnog prosjeka*[37] treba samo izabrati jedan parametar gdje vrijednost n označava period, a t vrijeme promatranja. Što je vrijednost varijable n veća, predviđanje će biti stabilnije. Formula za izračun pomičnog prosjeka glasi:

$$UD_{t+1} = (AD_t + AD_{t-1} + AD_{t-2} + \cdots + AD_{t-n+1})/n \quad (2)$$

Primjer: ako je stvarna rezervacija za odlazak u trećem tjednu 50, četvrtom tjednu 52, a petom tjednu 60, tada bi koristeći tri tjedna, pomični prosjek generirao prognozu za šesti tjedan kako slijedi (tablica 3.1.):

$$UD_6 = \frac{50 + 52 + 60}{3} = 54. \quad (3)$$

3.3.1.2. Metoda eksponencijalnog izglađivanja

Kod metode *eksponencijalnog izglađivanja*[38] treba izabrati samo jedan parametar gdje α označava težinu zadnjeg razmatranja. Što je vrijednost parametra α manja, to je predviđanje stabilnije. Formula za izračun metode eksponencijalnog izglađivanja je:

$$UD_{t+1} = \alpha * A_t + (1 - \alpha) * UD_t. \quad (4)$$

Primjer: ako je prognoza rezervacija za odlazak u petom tjednu bila 50,3, a ispostavilo se da je stvarna rezervacija za taj tjedan bila 60, koristeći vrijednost α=0,2 generirala bi se prognoza za šesti tjedan kako slijedi (tablica 3.1.):

[36] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 137.
[37] Belobaba, P. P., Weatherford, L.: *Demand Forecasting in RM Systems*, STAR Alliance RM Educational Program, Taipei, 2016., p. 6.
[38] Ibidem, p. 7.

$$UD_6 = 0{,}2 * 60 + (1 - 0{,}2) * 50{,}3 = 52{,}2. \quad (5)$$

Na taj način se poboljšava prognoza za slijedeći tjedan, pretpostavljajući da će potražnja u idućem tjednu biti veća nego u prošlom tjednu.

Tablica 3.1. Usporedba rezultata pomičnog prosjeka i eksponencijalnog izglađivanja

		n = 3	α = 0,2	α = 0,8
Tjedan	**Stvarna rezervacija**	**Pomični prosjek**	**Eksponencijalno izglađivanje**	**Eksponencijalno izglađivanje**
1	49		49	49
2	53		49	49
3	50		49,8	52,2
4	52	50,7	49,8	50,4
5	60	51,7	50,2	51,7
6		54,0	52,2	58,3

Izvor: Belobaba, P. P, Weatherford, L.: *Demand Forecasting in RM Systems*, STAR Alliance RM Educational Program, Taipei, 2016., p. 8.

3.3.1.3. Metoda linearne regresije

Kod *linearne regresije*[39] pretpostavlja se da postoji povezanost između potvrđenih rezervacija x i konačnih rezervacija y. Biraju se dva parametra, a (odsječak na osi y) i b (smjer pravca). Formula glasi:

$$y = a + b * x, \text{ ili primjerice} \quad (6)$$

$$BL_{16} = a + b * OB_x. \quad (7)$$

- a – odsječak na osi y;
- b – koeficijent smjera pravca.

Primjer: pod pretpostavkom da se predviđa veza između rezervacija u točki provjere 5 (OB_5) i rezervacija na odlasku (BL_{16}):

[39] Ibidem, p.9.

$$BL_{16} = 26{,}982 + 1{,}4755 * OB_5. \quad (8)$$

Ako za budući let zapravo ima 21 potvrđena rezervacija u točki provjere 5, predvidjet će se rezervacije na odlasku kako slijedi:

$$BL_{16} = 26{,}982 + 1{,}4755 * (21) = 57{,}97\ ili\ 58\ putnika. \quad (9)$$

3.3.1.4. „Pickup“ metoda

Kod *„Pickup“* metode[40], sadašnjim rezervacijama x se dodaje a - prosječni povijesni prirast rezervacija iz broja rezervacija u točki provjere do rezervacijskog limita u točki provjere 16. Zatim treba samo izračunati prosječni prirast rezervacija. Formula glasi:

$$y = a + 1 * x, \quad (10)$$

$$BL_{16} = Avg.Pickup\ (OB_x\ to\ BL_{16}) + OB_x. \quad (11)$$

Primjer: pretpostavlja se (koristeći povijesne podatke) da je prosječni prirast rezervacija između rezervacija u točki provjere 8 i rezervacijskog limita jednak 18. Ako za budući let zapravo postoje 34 potvrđene rezervacije u točki provjere 8, predvidjet će se rezervacije na odlasku kako slijedi:

$$BL_{16} = 18 + 34 = 52. \quad (12)$$

3.3.1.5. Metoda za mjerenje točnosti prognoziranja - MAE

Metoda za mjerenje točnosti predviđanja je MAE (engl. *Mean Absolute Error*) - srednja apsolutna pogreška. Ova metoda mjeri prosječnu vrijednost pogreške unutar prognoze, bez obzira gdje se pogreška pojavila, te se time pokušava odrediti točnost i pouzdanost nepromjenjivih varijabli.[41] Na primjeru je prikazano kako se računa MAE za zadnja četiri tjedna uz dane podatke (tablica 3.2.) o predviđanju i stvarnoj potražnji. Formula za izračun MAE glasi:

[40] Ibidem, p. 10.
[41] URL: http://www.eumetcal.org/resources/ukmeteocal/verification/www/english/msg/ver_cont_var/uos3/uos3_ko1.htm, (pristupljeno: rujan 2016.)

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|f_i - y_i| = \frac{1}{n}\sum_{i=1}^{n}|e_i|. \quad (13)$$

Kao što samo ime sugerira, srednja apsolutna pogreška prosjek je svih apsolutnih pogrešaka $|e_i| = |f_i - y_i|$, gdje je f_i predviđanje, a y_i prava vrijednost odnosno stvarna potražnja.

Tablica 3.2. Primjer izračuna srednje apsolutne pogreške – MAE

Tjedan	Predviđanje	Stvarna potražnja
1	75	80
2	78	72
3	74	75
4	75	79

Izvor: Belobaba, P. P., Weatherford, L.: *Demand Forecasting in RM Systems*, STAR Alliance RM Educational Program, Taipei, 2016., p. 13.

$$MAE = \frac{\{|80-75|+|72-78|+|75-74|+|79-75|\}}{4} = \frac{\{5+6+1+4\}}{4} = \frac{16}{4} = 4{,}0. \quad (14)$$

3.3.2. Regresijska analiza

Regresijska analiza bavi se određivanjem ovisnosti između dviju ili više varijabli, a analitički izraz te zavisnosti zove se regresijski model. Ako model izražava vezu između zavisne i jedne nezavisne varijable, govori se o jednostavnom regresijskom modelu, dok model koji izražava vezu između zavisne i dviju ili više nezavisnih varijabli, ukazuje ne model višestruke regresije. Regresijski modeli mogu izražavati linearne i nelinearne veze između promatranih pojava, odnosno varijabli.[42]

Za prognoze u zračnom prijevozu koristi se regresijski model, a mnogi regresijski modeli baziraju se na jednostavnom ili složenijem regresijskom modelu, gdje je promet putnika funkcija jedne ili više nezavisnih varijabli. Najčešće korištene varijable su cijene zrakoplovnih karata i dohodak po stanovniku.[43]

[42] URL: http://veleri.hr/~ljstambuk/Kvantitativne%20za%20web/Korelacija%20i%20regresija_pod.pdf, (pristupljeno: kolovoz 2016.)
[43] Čekolj, B.: *Modeli procjene potražnje i konkurentnost zračnog prijevoza u Republici Hrvatskoj*, magistarski rad, Zagreb, 2008., p. 47.

$$T = f(F, Y, t) \tag{15}$$

gdje je:

- T – broj putnika koji putuju na relaciji;
- F – prosječna cijena prijevoza;
- Y – BDP ili potrošnja po glavi stanovnika;
- t – vremenski period.

Cijene zrakoplovnih karata i dohodak moraju biti izraženi u konstantnim vrijednostima. Idealno bi bilo pratiti najnižu cijenu, jer ona ima najveći utjecaj na tržište, dok analitičari radije uzimaju prosječan prinos, jer je broj sjedala s najnižom cijenom ograničen.

3.4. Kvalitativne metode prognoziranja potražnje

Prognostičari moraju odabrati jednu od brojnih ponuđenih metoda, a na taj izbor utječe nekoliko čimbenika. Prvo je potrebno odrediti predmet prognoziranja, tj. da li se prognozira reakcija potražnje na promjenu cijena, na promjenu reda letenja ili se radi o prognozi prometa na nekoj liniji. Ukoliko prijevoznik planira otvoriti novu liniju, za procjenu buduće potražnje nabolje je koristiti kvalitativne metode, te je kao i za svaku metodu potrebno utvrditi raspoloživost podataka. Ukoliko je do podataka potrebno doći u jako kratkom periodu, najbolje je primijeniti metodu stručne procjene.

Ukoliko su neki od podataka nedostupni, npr. podaci o socioekonomskim varijablama, potrebno je koristiti kvalitativne metode. Bitnu stavku kod odabira metode predstavljaju troškovi, zato jer si mali zračni prijevoznici troškove istraživanja tržišta ne mogu priuštiti. Najčešće korištene metode su metoda stručne procjene, metoda istraživanja tržišta i Delphi metoda.

3.4.1. Metoda stručne procjene

Metoda stručne procjene je jedna od najčešće korištenih metoda od mnogobrojnih prognostičkih tehnika koje se upotrebljavaju. Temelji se na intuiciji pojedinaca, te iako je najmanje rigorozna predstavlja snažan faktor kod donošenja odluka. Intuicija je jedino sredstvo koje pojedinac posjeduje i ona može biti jako točna. U praksi se koristi od strane stručnjaka zaduženih za neku liniju ili tržište, a koji nisu prognostičari, ali najbolje poznaju trenutnu situaciju pa mogu razmjerno brzo i pouzdano procijeniti mogući rast poznavajući detaljnije situaciju, od mogućeg prognozera koji bolje rukovodi matematičko-statističkim prognostičkim metodama.[44]

Prihvaćanje ili odbijanje neke prognoze ovisi o ugledu prognostičara, te ne postoje statistike koje bi potvrdile određenu odluku. Podaci za navedenu vrstu

[44] Ibidem, p. 58.

procjene mogu se uzeti iz raznih izvora, a najčešće su to mišljenja stručnjaka, ili prognoze od strane prodaje. Mišljenje stručnjaka može se uzeti ili od stručnjaka iz kompanije ili od vanjskih suradnika.

3.4.2. Metoda istraživanja tržišta

Metoda istraživanja tržišta obuhvaća sociološke, demografske i ekonomske poticaje kojima se predviđa budući rast. Ona se ne zadržava samo na putniku i robi kao predmetu istraživanja već obuhvaća turističke, hotelske, agentske, trgovačke, distribucijske i ostale analize. Vrlo je korisna kada su raspoloživi prognostički alati neadekvatni i nepouzdani, odnosno kad ne postoje podaci iz prethodnih razdoblja, kao npr. istraživanje potencijala neke nove linije u nepoznatom okruženju nerazvijenih zemalja (u izvanrednim okolnostima ratnog ili globalnog kriznog okruženja).[45]

U takvim slučajevima istraživanje tržišta može biti jedini način kojim se može prognozirati potražnja. Također, navedena metoda pomaže zračnim prijevoznicima kako će promjene u ponudi usluge utjecati na potražnju.

3.4.3. Delphi metoda

Delphi metoda započinje s individualnim prognozama skupine stručnjaka. Zatim se obavljaju međusobne konzultacije i harmonizacije prognoza nakon čega se obavljaju moguće korekcije i na taj način se dobiva završna prognoza. U praksi proces konzultacije može biti manje ili više složen, ovisno o količini informacija kojima stručnjaci raspolažu i koje međusobno razmjenjuju. Delphi metoda je prikladnija za agregatne prognoze rasta na glavnim tržištima ili regijama, nego za individualne prognoze na pojedinim linijama. Stoga se jako malo upotrebljava među zračnim prijevoznicima, ali zato predstavlja bazu za prognoze napravljene od strane IATA-e (engl. *International Air Transport Association*), međunarodne udruge za zračni prijevoz.[46]

U zračnom prometu često se koriste IATA-ine petogodišnje prognoze koje se rade za svako rutno područje posebno, pri čemu se često koristi Delphi metoda u kojoj sudjeluju stručnjaci za makro gospodarska istraživanja zajedno sa stručnjacima zrakoplovnih tvrtki, zračnih luka, proizvođača zrakoplova, te pojedinih vlada zrakoplovnog ovlaštenja i odgovornosti. Nakon usklađivanja svih navedenih manje ili više optimističnih, realnih i pouzdanih izvora dobivaju se objektivni elementi za prognoziranje dinamike rasta zračnog prijevoza za svako svjetsko rutno područje.

[45] Ibidem, p. 60.
[46] Ibidem

4. JEDNOSTAVNE METODE ZA PROCJENU STVARNE POTRAŽNJE

Kada potražnja za određenom klasom prijevoza dosegne rezervacijski limit, podatak o broju ostvarenih rezervacija neće predstavljati stvarnu potražnju nego samo jedan njezin dio. Razlog tome je da se broj odbijenih zahtjeva zbog zatvaranja klase cenzurira u rezervacijskim sustavima zračnih prijevoznika. Sukladno tome, ti podaci se ne mogu koristiti kao osnova za optimalnu raspodjelu sjedala po klasama prijevoza. Metode za procjenu stvarne potražnje služe za procjenjivanje potražnje kakva bi bila da rezervacijski limiti nisu postojali. U nastavku poglavlja koristit će se notacije koje su definirane u poglavlju 3.3.1.1.

4.1. Metode za procjenu stvarne potražnje koje koriste isključivo raspoložive podatke

Metode koje koriste isključivo raspoložive podatke ne pokušavaju cenzurirane podatke zamijeniti novim vrijednostima. Postoje dvije takve metode:

1. metoda koja ignorira postojanje cenzuriranja (u nastavku I1 metoda) jednostavno zanemaruje činjenicu da dio raspoloživih podataka o zabilježenoj potražnji ne predstavlja stvarnu potražnju; koristi sve raspoložive podatke, pa tako i one koji su arhivirani u sustavu nakon „zatvaranja“ određenog cjenovnog razreda, dakle, vrijedi:

$$AD(r) = \begin{cases} OB(r), & I(r) = 1 \\ OB(r), & I(r) = 0. \end{cases} \tag{16}$$

2. metoda odbacuje cenzurirane vrijednosti (u nastavku I2 metoda) i limitira set raspoloživih podataka o zabilježenoj potražnji na one vrijednosti koje nisu cenzurirane, dakle, vrijedi:[47]

$$AD(r) = \begin{cases} OB(r), & I(r) = 1 \\ - \quad , & I(r) = 0. \end{cases} \tag{17}$$

U tablici 4.1. prikazan je jednostavan primjer nadogradnje metodama I1 i I2 za skup od 10 zabilježenih vrijednosti (redak *OB(r)*). Žuta polja označavaju cenzurirane vrijednosti. Izračunati su prosjek i standardna devijacija odnosno parametri potražnje, za obje metode.

[47] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 138.

Tablica 4.1. Primjer nadogradnje cenzuriranih vrijednosti za I1 i I2 metodu

OB(r)	10	15	12	22	13	18	21	17	23	19	**prosjek**	**standardna devijacija**
***UD(r)* – I1**	10	15	12	22	13	18	21	17	23	19	17,000	4,422
***UD(r)* – I2**	10	–	12	22	–	18	–	17	23	19	17,286	4,821

Ove metode prikladne su samo ako se cenzurirane vrijednosti pojavljuju stohastički i ako ne postoji nikakva povezanost između njihova pojavljivanja i vrijednosti ostalih varijabli u promatranom rezervacijskom procesu. Iako je implementacija tih metoda jednostavna, njihova primjena u modulu za predviđanje potražnje unutar sustava za upravljanje kapacitetima zrakoplova, može biti opravdana samo ako je broj cenzuriranih podataka ekstremno malen.[48]

4.2. Metode za procjenu stvarne potražnje koje zamjenjuju cenzurirane podatke novim vrijednostima

Metode za procjenu stvarne potražnje koje zamjenjuju cenzurirane podatke novim vrijednostima, zamjenjuju novim vrijednostima sve podatke o broju rezervacija u slučajevima kada je došlo do odbijanja zahtjeva za rezervacijama zbog dosegnutog rezervacijskog limita. Takve metode se izračunavaju na različite načine i upravo način procjene tih vrijednosti čini razliku između pojedinih metoda u toj skupini. Velika prednost ove metode je da se nepotpuni podaci zamjenjuju novim podacima s kojima se dalje postupa kao s podacima o stvarnoj potražnji.

4.2.1. Metoda zamjene cenzuriranih podataka aritmetičkom sredinom necenzuriranih podataka

Metoda zamjene cenzuriranih podataka aritmetičkom sredinom, odnosno prosjekom necenzuriranih podataka, uobičajena je i često korištena metoda u slučaju nadopunjavanja podataka koji nedostaju. Ta metoda se još naziva i RWA (engl. *Replace With Average*) metoda. U modulu za predviđanje stvarne potražnje ta metoda funkcionira na sljedeći način:

- ako indikator raspoloživosti sjedala pokazuje da je u određenoj točki provjere cjenovni razred bio „otvoren“, zabilježeni broj rezervacija predstavlja stvarnu potražnju;
- ako indikator raspoloživosti sjedala pokazuje da je u određenoj točki provjere cjenovni razred bio „zatvoren“, zabilježeni broj rezervacija, tj. rezervacijski limit, predstavlja cenzuriranu potražnju. Ta vrijednost se uspoređuje s prosjekom necenzuriranih vrijednosti unutar skupa podataka na temelju kojeg

[48] Ibidem

se treba predvidjeti buduća potražnja u toj točki provjere. Ako je cenzurirana vrijednost veća od tako izračunatog prosjeka, ona se uzima kao podatak o stvarnoj potražnji, a ako je manja, zamjenjuje se s prosjekom necenzuriranih vrijednosti.[49]

Za tu metodu vrijedi sljedeća notacija:

$$AD(r) = \begin{cases} OB(r), & I(r) = 1 \\ \max\{OB(r), AV(r)\}, & I(r) = 0 \end{cases} \quad (18)$$

pri čemu je:

$$AV(r) = \frac{\sum_{k=1}^{n} OB(r,k) * I(r,k)}{\sum_{k=1}^{n} I(r,k)}, \quad (19)$$

odnosno aritmetička sredina svih necenzuriranih vrijednosti broja rezervacija u točki provjere *r* na *n* sličnih letova na temelju kojih se radi procjena buduće potražnje. Osnovni nedostatak te jednostavne metode je u tome što je tako nadograđena potražnja u pravilu manja od aktualne potražnje.[50]

4.2.2. Metoda zamjene cenzuriranih podataka medijanom, gornjim kvartilom ili percentilom necenzuriranih podataka

Metoda zamjene cenzuriranih podataka medijanom necenzuriranih podataka odnosno RWM (engl. *Replace With Median*) metoda slična je metodi zamjene cenzuriranih podataka aritmetičkom sredinom necenzuriranih podataka. U modulu za predviđanje stvarne potražnje ta metoda funkcionira na sljedeći način:

- ako indikator raspoloživosti sjedala pokazuje da je u određenoj točki provjere cjenovni razred bio „otvoren“, zabilježeni broj rezervacija ujedno je i podatak o stvarnoj potražnji;
- ako indikator raspoloživosti sjedala pokazuje da je u određenoj točki provjere cjenovni razred bio „zatvoren“, zabilježeni broj rezervacija, tj. rezervacijski limit, predstavlja cenzuriranu potražnju i uspoređuje se s medijanom necenzuriranih vrijednosti unutar skupa podataka na temelju kojeg se treba predvidjeti buduća potražnja u toj točki provjere; ako je cenzurirana vrijednost veća od medijana, ona se uzima kao podatak o stvarnoj potražnji, u suprotnom, zamjenjuje se medijanom.

Za tu metodu vrijedi sljedeća notacija:

[49] Ibidem, p. 139.
[50] Ibidem

$$AD(r) = \begin{cases} OB(r), & I(r) = 1 \\ \max\{OB(r), Med(r)\}, & I(r) = 0 \end{cases} \quad (20)$$

pri čemu je *Med(r)* medijan svih necenzuriranih vrijednosti broja rezervacija u točki provjere *r* za *n* sličnih letova na temelju kojih će se izračunati parametri buduće potražnje.[51]

Medijan je srednja vrijednost obilježja koja statistički niz dijeli na dva jednaka dijela pri čemu pola jedinica statističkog skupa ima vrijednost obilježja manju ili jednaku medijanu, a pola jedinica veću ili jednaku medijanu.[52]

Ako podaci teže prema rezervacijskom limitu, medijan je bolja mjera centralne tendencije što RWM metodu čini prikladnijom od RWA metode. Potpuno analogno, umjesto medijana se može koristiti i treći ili gornji kvartil (RWP75 metoda) ili drugi *P* percentil, ako je moguće empirijskom analizom utvrditi prikladniji *P* parametar. Percentil je vrijednost statističkog obilježja ispod koje se nalazi P% svih elemenata statističkog niza. Treći ili gornji kvartil je srednja vrijednost obilježja koja statistički niz dijeli na četiri jednaka dijela u omjeru 3:1, tako da 75% jedinica statističkog skupa ima vrijednost obilježja manju ili njoj jednaku.[53]

U tablici 4.2. prikazan je primjer nadogradnje metodama RWA, RWM i RWP75, za vrijednosti zabilježene potražnje definirane u tablici 4.1.

Tablica 4.2. Primjer nadogradnje cenzuriranih vrijednosti za RWA, RWM i RWP75 metodu

OB(r)	10	15	12	22	13	18	21	17	23	19	**prosjek**	**standardna devijacija**
UD(r)-RWA	10	17	12	22	17	18	21	17	23	19	17,66	4,107
UD(r)-RWM	10	18	12	22	18	18	21	17	23	19	17,8	4,104
UD(r)-RWP75	10	21	12	22	21	18	21	17	23	19	18,3	4,264

[51] Ibidem, p. 140.
[52] URL: http://slidegur.com/doc/1095599/statistika3, (pristupljeno: srpanj 2016.)
[53] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 140.

5. STATISTIČKE METODE ZA PROCJENU STVARNE POTRAŽNJE

Statističke metode za procjenu stvarne potražnje obuhvaćaju niz metoda koje se oslanjaju na podatke o zabilježenoj potražnji i na pokazatelje zatvorenosti pojedinih cjenovnih razreda. Statističke metode za procjenu stvarne potražnje koriste algoritme koji se temelje na vjerojatnosti i statistici. Te metode koriste jednostavnije modele kojima procjenjuju stvarnu vrijednost potražnje na osnovi prosječnog prirasta rezervacija necenzuriranih letova. Također se koriste i složenijim modelima koji uključuju procjenu najveće vjerojatnosti razdiobe nepotpunih podataka. Metode zahtijevaju kompleksnije izračune koji se često sastoje od više iteracija i trebaju više vremena za procjenu i snažnu računalnu podršku.

Unatoč dobrim načinima predviđanja buduće potražnje, uvijek postoje naznake nesigurnosti. Najbolji način rješavanja tog problema je da treba ići dalje od predložene najbolje dobivene procjene buduće potražnje. Na taj način bi se uključila promjenjivost potražnje u raspodjeli sjedala po klasama prijevoza. Ako se pretpostavi da predviđanje za potražnjom u Y klasi na letu LH 422 iznosi 82 putnika, treba pretpostaviti kolika je vjerojatnost da će potražnja biti točno 82. Zbog nesigurnosti i slučajnih događaja koji se mogu pojaviti u bilo kojem trenutku i koji mogu umanjiti točnost prognoziranja, treba pretpostaviti da vrijednost potražnje može biti 81 ili 83, odnosno neka druga vrijednost koja je različita od 82. Povijesni podaci potražnje (tablica 5.1.) u ovom primjeru su:

- LH 422, utorak, popodnevni let;
- podaci o popunjenosti za 10 tjedana od 05. ožujka do 07. svibnja.[54]

Tablica 5.1. Povijesni podaci o potražnji

Datum leta	Zabilježena potražnja - x_i
05. ožujak	62
12. ožujak	75
19. ožujak	96
26. ožujak	84
02. travanj	70
09. travanj	81
16. travanj	81
23. travanj	87
30. travanj	93
07. svibanj	91

Izvor: Belobaba, P. P., Weatherford, L.: *Applications of Statistics and Probability to Revenue Management*, STAR Alliance RM Educational Program, Taipei, 2016., p. 3.

[54] Belobaba, P. P., Weatherford, L.: *Applications of Statistics and Probability to Revenue Management*, STAR Alliance RM Educational Program, Taipei, 2016., p. 3.

Zatim je potrebno izračunati prosjek $\bar{X}$ i standardnu devijaciju σ (tablica 5.2.) za podatke zadane u tablici 5.1.

$$\bar{X} = \frac{\sum_{i=1}^{n} X_i}{n}. \tag{21}$$

$$\bar{X} = \frac{62 + 75 + 96 + 84 + 70 + 81 + 81 + 87 + 93 + 91}{10} = \frac{820}{10} = 82 \tag{22}$$

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^{n} (\bar{X} - X_i)^2}{n-1}. \tag{23}$$

$$\hat{\sigma} = \sqrt{\hat{\sigma}^2}. \tag{24}$$

Tablica 5.2. Podaci za računanje standardne devijacije

X_i	$\bar{X} - X_i$	$(\bar{X} - X_i)^2$
62	20	400
75	7	49
96	-14	196
84	-2	4
70	12	144
81	1	1
81	1	1
87	-5	25
93	-11	121
91	-9	81

Izvor: Belobaba, P. P., Weatherford, L.: *Applications of Statistics and Probability to Revenue Management, STAR Alliance RM Educational Program*, Taipei, 2016., p. 6.

$$\sum_{i=1}^{10} (\bar{X} - X_i)^2 = 1022. \tag{25}$$

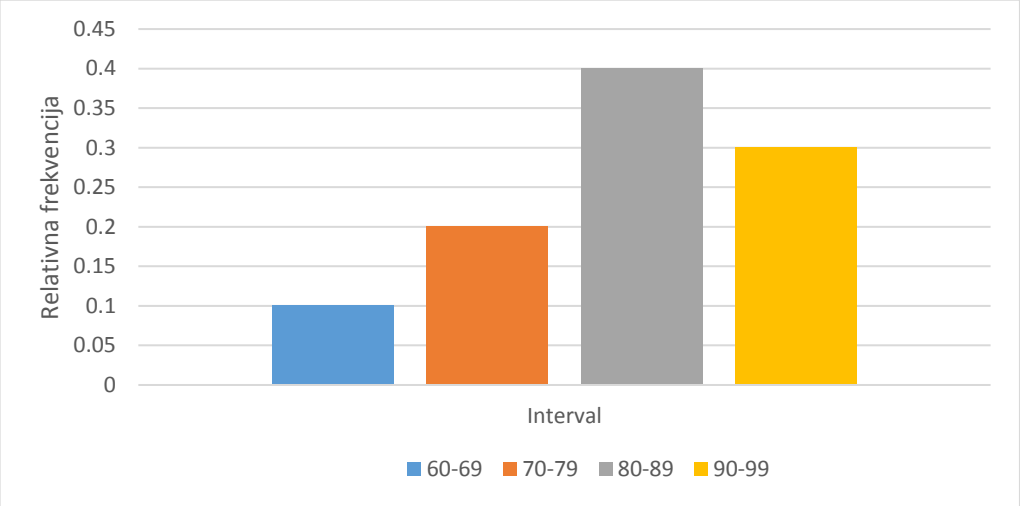
$$\hat{\sigma} = \sqrt{\frac{1022}{9}} = \sqrt{113{,}6} = 10{,}66. \tag{26}$$

Tablica 5.3. Distribucija frekvencije

Interval	Frekvencija	Relativna frekvencija
60-69	1	1/10 = 0,1
70-79	2	2/10 = 0,2
80-89	4	4/10 = 0,4
90-99	3	3/10 = 0,3
	10	1

Izvor: Belobaba, P. P., Weatherford, L.: *Applications of Statistics and Probability to Revenue Management, STAR Alliance RM Educational Program*, Taipei, 2016., p. 7.

Iz tablice 5.3. koja prikazuje distribuciju frekvencija, napravljen je histogram frekvencija, prikazan na grafikonu 5.1.



Grafikon 5.1. Histogram frekvencija

Izvor: Belobaba, P. P., Weatherford, L.: *Applications of Statistics and Probability to Revenue Management, STAR Alliance RM Educational Program*, Taipei, 2016., p. 7.

Pomoću relativnih frekvencija, mogu se odrediti vjerojatnosti koje primaju različite razine buduće potražnje, ako se pretpostavi da se temeljni proces nije promijenio. Vjerojatnost da će buduća potražnja poprimiti vrijednosti između 70 i 79 putnika je:

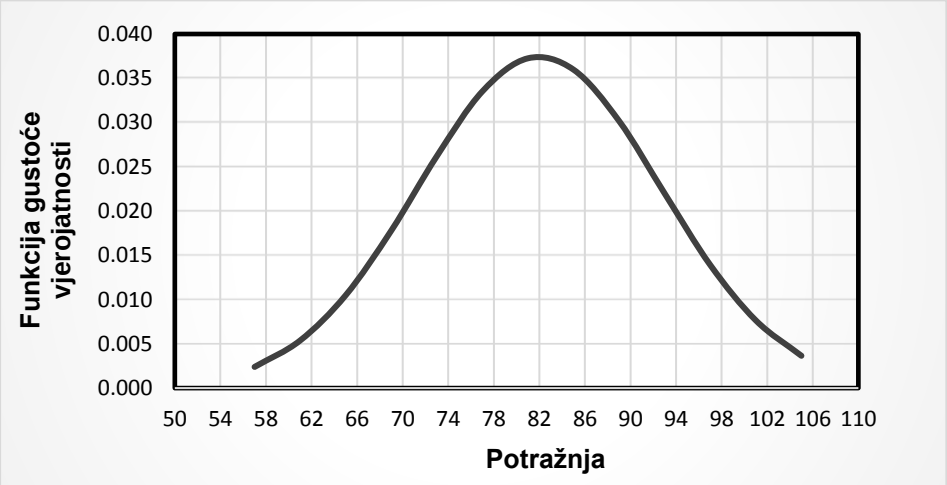
$$P\ (70 \leq \text{potražnja} \leq 79) = 0{,}2. \qquad (27)$$

Na grafikonu 5.2. prikazana je normalna razdioba za podatke prikazane u tablici 5.4., gdje μ predstavlja očekivanje, σ standardnu devijaciju, x potražnju, a f(x) funkciju gustoće vjerojatnosti. Funkcija gustoće vjerojatnosti se računa pomoću formule:

$$f(x) = \left(\frac{1}{\sigma 2\pi}\right) * e^{-\frac{1}{2}(\frac{x-\mu}{\sigma})^2}. \quad (28)$$

Tablica 5.4. Podaci za graf normalne razdiobe

μ	σ	x	f(x)
82	10,66	57	0,00239
82	10,66	61	0,00538
82	10,66	65	0,01049
82	10,66	69	0,01779
82	10,66	73	0,02620
82	10,66	77	0,03353
82	10,66	81	0,03726
82	10,66	85	0,03597
82	10,66	89	0,03017
82	10,66	93	0,02198
82	10,66	97	0,01391
82	10,66	101	0,00764
82	10,66	105	0,00365



Grafikon 5.2. Normalna razdioba

Izvor: Belobaba, P. P., Weatherford, L.: *Applications of Statistics and Probability to Revenue Management, STAR Alliance RM Educational Program*, Taipei, 2016., p. 9.

Vjerojatnost potražnje u bilo kojem intervalu je malo teže za izračunati, pa se za takve slučajeve koristi Excel. Kako bi se izračunala vjerojatnost da će potražnja biti manja ili jednaka od slučajne varijable x, primjenjuje se sljedeća formula:

= Normdist (x; očekivanje; standardna devijacija; TRUE). (29)

Na primjer, ako se želi izračunati vjerojatnost da je potražnja ≤ 80, u Excel treba upisati:

= Normdist (80; 82; 10,66; TRUE) (30)

Rezultat će biti 0,4256, dakle, vjerojatnost da će broj zahtjeva za Y klasom biti bilo koja vrijednost do 80 iznosi 0,4256.

5.1. Metoda dogradnje krivulje rezervacija

Metoda dogradnje krivulje rezervacija ili BP (engl. *Booking Profile*) metoda je najjednostavnija metoda za procjenu stvarne potražnje u prošlosti, a polazi od pretpostavke da je izgled krivulje rezervacija približno jednak za sve letove. Na temelju kretanja broja rezervacija na letovima kod kojih nije dosegnut limit i analiziranja prirasta rezervacija za svaki interval promatranja u odnosu na prethodni, procjenjuje se broj nezadovoljenih zahtjeva na „zatvorenim" letovima.[55]

To je metoda kojom se stvarna potražnja utvrđuje na temelju oblika krivulje kumulativnog broja rezervacija, a polazi od pretpostavke da za letove kod kojih broj rezervacija ne odstupa značajno od prosjeka broja rezervacija ostalih letova u skupini, izgled krivulje rezervacija određenog cjenovnog razreda ne ovisi o intenzitetu potražnje. To znači da je postotno povećanje između susjednih točaka provjere konstantno za skupinu sličnih letova i da se za slične letove oblik krivulje rezervacija za određene cjenovne razrede može precizno procijeniti uprosječivanjem potražnje u svakoj točki provjere.[56]

Necenzurirani podaci o broju rezervacija, koji vjerojatno predstavljaju letove s nižom potražnjom, uprosječuju se u svakoj točki provjere te se izračunavaju koeficijenti povećanja *PI* za svake dvije susjedne točke provjere. Cenzurirani se podaci nadograđuju tako da se zadnji necenzurirani podatak u nekoj prethodnoj točki provjere uvećava za utvrđene postotke *PI*.[57] U nastavku poglavlja koristit će se notacije koje su definirane u poglavlju 3.3.1.1.

Postupak metode dogradnje krivulje rezervacija može se opisati sljedećim hodogramom:

[55] Škurla Babić, R.: *Unapređenje sustava za upravljanje kapacitetima zrakoplova*, magistarski znanstveni rad, Zagreb, 2003., p. 17.
[56] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 141.
[57] Ibidem

1. Iz skupa podataka o broju rezervacija za n sličnih letova izdvoje se letovi na kojima nije bilo cenzuriranja podataka i izračuna se prosječan broj rezervacija u svakoj točki provjere pomoću sljedeće formule:

$$AB(r) = \frac{\sum_{k=1}^{n} OB(r,k) * I(r,k)}{\sum_{k=1}^{n} I(r,k)}. \tag{31}$$

2. Zatim se izračuna postotno povećanje rezervacija između svake dvije točke provjere, počevši od početka rezervacijskog procesa:

$$PI(r) = \frac{AB(r)}{AB(r-1)}. \tag{32}$$

3. Stvarna potražnja u svakoj točki provjere procjenjuje se notacijom:[58]

$$UD(r,k) = \begin{cases} OB(r,k), & I(r,k) = 1 \\ \max\{OB(r-1,k) * PI(r), OB(r,x)\}, & I(r,k) = 0 \end{cases} \tag{33}$$

BP metoda se najlakše može opisati pomoću primjera u nastavku odnosno tablice 5.5. Može se pretpostaviti da postoji deset točaka provjere, te se zatim pretpostavlja da se pojavio let kod kojeg je potražnja u određenom cjenovnom razredu dosegnula rezervacijski limit tog cjenovnog razreda u sedmoj točki provjere. Zabilježena potražnja u toj i u svim narednim točkama provjere zapravo je cenzurirana potražnja i iznosi 25.

Tablica 5.5. Primjer nadogradnje cenzuriranih podataka BP metodom

	r_1	r_2	r_3	r_4	r_5	r_6	r_7	r_8	r_9	r_{10}
PI	-	-	-	-	-	-	28%	19%	7%	2%
OB(r_i)	0	2	5	9	14	21	25	25	25	25
UD(r_i)	0	2	5	9	14	21	27	32	34	35

U točki r_7 zabilježena je vrijednost potražnje 25 što ujedno predstavlja i rezervacijski limit. Kako bi se procijenila potražnja u toj točki, necenzurirana vrijednost u prethodnoj točki provjere, dakle u r_6 koja iznosi 21, množi se s 1,28 jer postotno povećanje između točaka provjere r_6 i r_7 iznosi 28%, koje je izračunato na temelju necenzuriranih podataka sličnih letova. Time se dobije procijenjena vrijednost stvarne potražnje koja iznosi 26,88, te se cenzurirani podatak u r_7 zamjenjuje s 27.

Kako bi se procijenila vrijednost u sljedećoj točki provjere odnosno r_8, 26,88 se množi s postotnim povećanjem između točaka provjere r_7 i r_8, tj. s 1,19. Cenzurirani

[58] Ibidem, p. 142.

podatak u r_8 zamjenjuje se s 32 te tako redom do točke provjere r_{10} u kojoj se procjenjuje ukupna potražnja za određenim cjenovnim razredom promatranog leta.

5.2. EM metoda

EM metoda je ustvari EM (engl. *Expectation Maximization Method*) algoritam odnosno algoritam maksimizacije očekivanja. To je algoritam opće namjene za procjenu maksimalne vjerojatnosti razdiobe nepotpunih podataka. Primjenjuje se kada je potrebno izračunati skup parametara koji opisuju skrivenu razdiobu vjerojatnosti, a kada je dostupan samo dio podataka. U nastavku su opisani *EM algoritam* i njegovi koraci.[59]

Pretpostavlja se da postoji $M + N$ podataka o broju rezervacija određenog cjenovnog razreda, $z_1,...,z_{M+N}$ koji čine skup Z, $Z = Z_M \cup Z_n$. M podataka skupa Z_M je cenzurirano i ne predstavlja podatak o stvarnoj potražnji jer je cjenovni razred bio „zatvoren“ i daljnja prodaja ograničena postavljenim rezervacijskim limitom. Redoslijed pojavljivanja pojedinih podataka se ignorira i tretira se skup $z_1,...,z_{M+N}$ kao skup nezavisnih i slučajno poredanih podataka. Cilj je pronaći pripadajuću razdiobu vjerojatnosti za taj skup.

Zatim, pretpostavlja se normalna razdioba vjerojatnosti potražnje sa srednjom vrijednošću μ i standardnom devijacijom σ. Nadalje, pretpostavlja se da se sve vrijednosti ponašaju prema zajedničkoj razdiobi te da se cenzurirane vrijednosti pojavljuju stohastički. Može se pretpostaviti da su vrijednosti $z_1,...,z_M$ ograničene rezervacijskim limitima $b_1,...,b_M$, tako da vrijedi $z_1 = b_1,...,z_M = b_M$. Preostalih N vrijednosti skupa Z_N nije ograničeno rezervacijskim limitima i predstavlja stvarnu potražnju.[60]

Kada dio podataka o potražnji ne bi bio cenzuriran zbog postavljenih rezervacijskih limita, funkcija maksimalne vjerojatnosti (engl. *Maximum Likelihood*) za kompletan set podataka izgledala bi:

$$L(\mu, \sigma, M+N) = \prod_{I=1}^{M+N} \frac{1}{\sqrt{2\pi\sigma}} * e^{\frac{-(z_i-\mu)^2}{2\sigma^2}}, \tag{34}$$

s logaritamskom funkcijom najveće vjerojatnosti:

$$lnL(\mu, \sigma, M+N) = -\frac{M+N}{2} ln2\pi - (M+N)ln\sigma - \frac{\sum_{i=1}^{M+N}(z_i-\mu)^2}{2\sigma^2}. \tag{35}$$

Vrijednosti μ i σ koje maksimiziraju ln$L(\mu,\sigma,M + N)$ u jednakosti (33) dane su eksplicitnim analitičkim izrazima:

[59] Ibidem, p. 143.
[60] Ibidem

$$\hat{\mu} = \frac{1}{M+N}\sum_{i=1}^{M+N} z_i, \tag{36}$$

$$\hat{\sigma}^2 = \frac{1}{M+N}\sum_{i=1}^{M+N} (z_i - \overline{\mu})^2. \tag{37}$$

Kako prave vrijednosti M cenzuriranih podataka nisu poznate, taj se način ne može koristiti, nego se koristi *EM algoritam*.

EM metoda u iteracijskom algoritmu koristi funkciju najveće vjerojatnosti L(*μ,σ,M + N*) tako da se *E-korak* (korak procjene) i *M-korak* (korak maksimizacije) izmjenjuju. U *E-koraku* se sve cenzurirane vrijednosti zamjenjuju njihovim procijenjenim vrijednostima (uvjetnim očekivanjima) koristeći parametre trenutne hipoteze o normalnoj razdiobi μ i σ. U M-koraku se zatim maksimizira funkcija najveće vjerojatnosti ln*L(μ,σ,M + N)* temeljena na korigiranim vrijednostima i procjenjuju se nove vrijednosti za μ i σ. Koraci se izmjenjuju sve dok nizovi srednjih vrijednosti i standardnih devijacija koji se dobiju kroz iteracije ne počnu konvergirati.[61]

5.2.1. Koraci EM algoritma

Ako se s $\mu^{(k)}$ i $\sigma^{(k)}$ označe procjene parametara normalne razdiobe potražnje u *k*-toj iteraciji algoritma, *EM algoritam* je moguće prikazati u četiri koraka (slika 6.1.):

1. **Inicijalizacija** → inicijaliziraju se početne vrijednosti $\mu^{(0)}$ i $\sigma^{(0)}$ kao srednja vrijednost i standardna devijacija skupa svih necenzuriranih podataka ZN; definira se $\delta > 0$ kao uvjet zaustavljanja algoritma.
2. **E-korak** → izračuna se očekivana vrijednost cenzuriranih podataka pretpostavljajući normalnu razdiobu *X* s parametrima $\mu^{(k-1)}$ i $\sigma^{(k-1)}$ iz funkcije najveće vjerojatnosti:

$$\hat{Z}_i^{(k-1)} = E\left[X | X \geq b_i, X \sim N(\mu^{(k-1)}, \sigma^{(k-1)})\right], \tag{38}$$

$$\hat{Z}_i^{2(k-1)} = E\left[X^2 | X \geq b_i, X \sim N(\mu^{(k-1)}, \sigma^{(k-1)})\right]. \tag{39}$$

Izračun očekivanih vrijednosti (uvjetovanih činjenicom da je očekivana vrijednost veća od cenzurirane vrijednosti, tj. rezervacijskog limita b ili njemu jednaka) svodi se na rješavanje dvaju integrala (f(x) je Gaussova funkcija):

[61] Ibidem, p. 144.

$$E[X|X \geq b, X \sim N(\mu, \sigma)] = \frac{\int_b^\infty xf(x)dx}{\int_b^\infty f(x)dx} \tag{40}$$

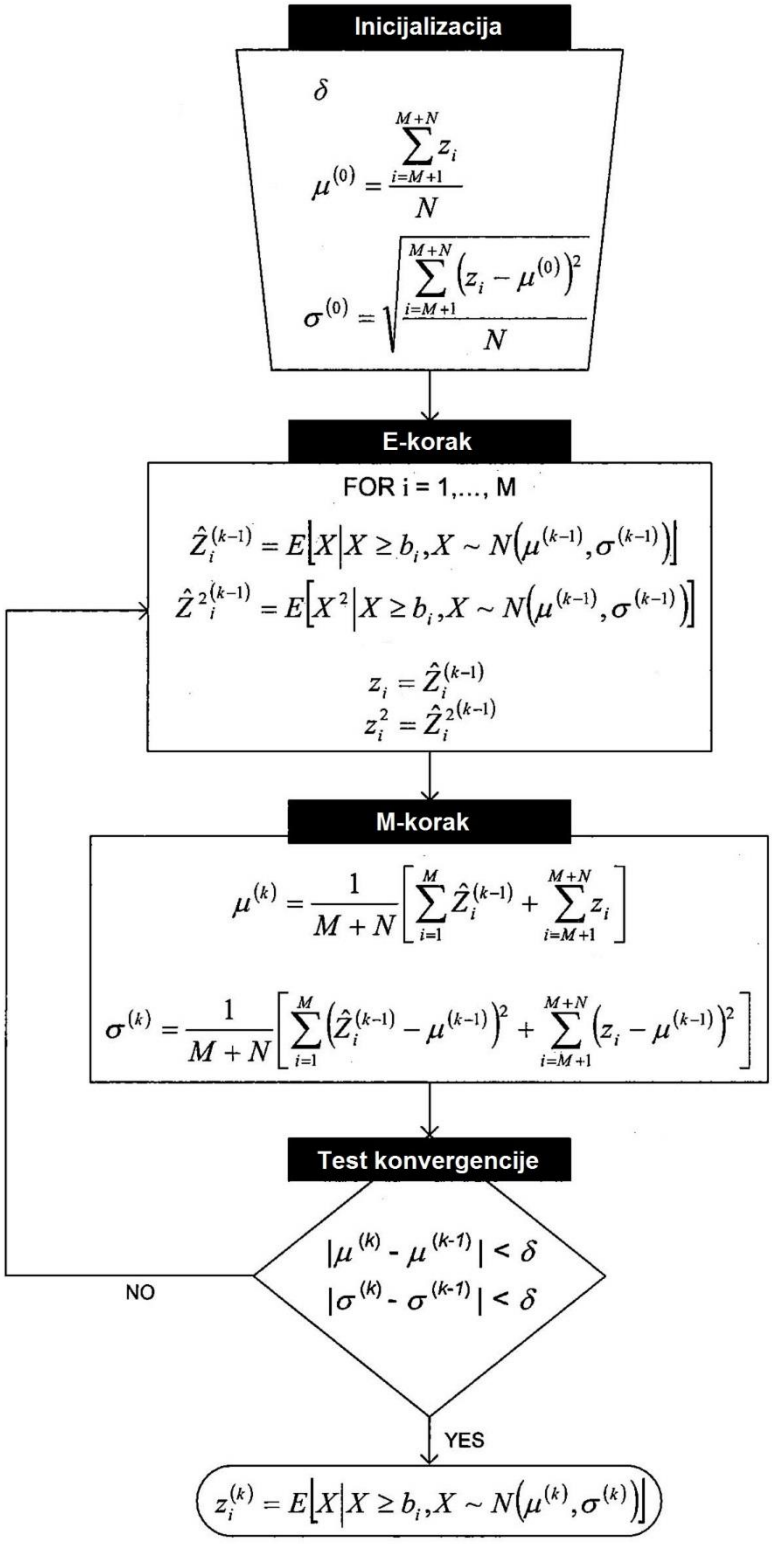
Svaka se *M* cenzurirana vrijednost z_i zamijeni očekivanim vrijednostima $\hat{Z}_i^{(k-1)}$ za trenutne $\mu^{(k-1)}$ i $\sigma^{(k-1)}$ te se dobije logaritamska funkcija najveće vjerojatnosti $Q(\mu, \sigma)$ kao u jednakosti (33), za kompletan skup podataka Z_{M+N}.

3. **M-korak** → maksimizira se $Q(\mu, \sigma)$ s ažuriranim podacima iz *E-koraka* kako bi se dobile nove procjene za srednju vrijednost i standardnu devijaciju $\mu^{(k)}$ i $\sigma^{(k)}$.
4. **Test konvergencije** → ako je $\left|\mu^{(k)} - \mu^{(k-1)}\right| < \delta|$ i $\left|\sigma^{(k)} - \sigma^{(k-1)}\right| < \delta$, algoritam je gotov i konvergencija postignuta. Za necenzurirane vrijednosti z_i, i=1,...,M uzimaju se vrijednosti $E[X|X \geq b_i]$, pri čemu je X normalna razdioba s parametrima $\mu^{(k)}$ i $\sigma^{(k)}$, odnosno:

$$z_i^{(k)} = E\left[X|X \geq b_i, X \sim N(\mu^{(k)}, \sigma^{(k)})\right] \tag{41}$$

U suprotnom, ponavljaju se koraci 2 i 3.[62]

[62] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 144.



Slika 5.1. Blok dijagram EM algoritma

Izvor: Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 145.

5.2.2. Numerički primjer EM algoritma

U nastavku slijedi primjer numeričke ilustracije *EM algoritma*.[63] Neka su u tablici 5.6. prikazani povijesni podaci o broju rezervacija u određenom trenutku provjere za *n* = 1,...,10 realiziranih letova.

Tablica 5.6. Uzorak za primjer EM algoritma

n	1	2	3	4	5	6	7	8	9	10
Broj rezervacija	20	28	21	17	18	26	19	14	17	23
Indikator zatvorenosti	0	0	0	0	0	0	0	0	0	1

Broj rezervacija za n = 10 je 23, a indikator zatvorenosti pokazuje da je podatak o potražnji cenzuriran, tj. da je broj zahtjeva dosegnuo postavljeni rezervacijski limit te da broj 23 predstavlja podatak o cenzuriranoj potražnji. Ta bi vrijednost predstavljala stvarnu potražnju, samo ako bi bila nadograđena, tj. uvećana za broj odbijenih zahtjeva.

Prvi korak *EM algoritma* je izračun očekivanja i standardne devijacije za necenzurirane podatke, tj. za skup {20, 28, 21, 17, 18, 26, 19, 14, 17}. Oni iznose:

$$\mu^{(0)} = 20,$$

$$\sigma^{(0)} = 4{,}472136.$$

Neka je kriterij konvergencije $\delta = 0{,}0001$. Za zadane inicijalne vrijednost μ i σ u *E-koraku* se računa:

$$\hat{Z}^{(1)} = E[X|X \geq 23] = \frac{\int_{23}^{\infty} x f(x)dx}{\int_{23}^{\infty} f(x)dx} = 25{,}67212. \tag{42}$$

U *M-koraku* se, u skupu svih zabilježenih vrijednosti, cenzurirana vrijednost koja iznosi 23 zamjenjuje s tako izračunatom očekivanom vrijednošću. Za taj skup podataka koji uz necenzurirane vrijednosti sadrži i $\hat{Z}^{(1)}$ računaju se vrijednosti očekivanja i standardne devijacije. One iznose:

$$\mu^{(1)} = 20{,}567212,$$

$$\sigma^{(2)} = 4{,}582038.$$

[63] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 146.-147.

E-korak i *M-korak* se izmjenjuju kroz *k* iteracija dok se ne zadovolji kriterij konvergencije, odnosno dok se vrijedi $\left|\mu^{(k)} - \mu^{(k-1)}\right| < 0{,}0001$. Rezultati *EM algoritma* prikazani su u tablici 5.7. Algoritam konvergira nakon pet iteracija i cenzurirana vrijednost 23 zamjenjuje se procijenjenom vrijednošću koju je generirao *EM algoritam* i koja iznosi 25,931883.

Tablica 5.7. Numerički primjer EM metode

Iteracija (k)	E[X|x>23]	$\mu^{(k)}$	$\sigma^{(k)}$	$\left\|\mu^{(k)} - \mu^{(k-1)}\right\|$	$\left\|\sigma^{(k)} - \sigma^{(k-1)}\right\|$
0	-	20	4,472136	-	-
1	25,672119	20,567212	4,582038	0,567211989	0,109902039
2	25,899735	20,589973	4,610690	0,022761491	0,028652284
3	25,927898	20,592789	4,614301	0,002816365	0,003610945
4	25,931438	20,593144	4,614756	0,000353906	0,00045477
5	25,931883	20,593188	4,614814	0,000044556	0,000057271
6	25,931939	20,593193	4,614820	0,000005611	0,000007212
7	25,931946	20,593195	4,614821	0,000000707	0,000000908
8	25,931947	20,593195	4,614821	0,000000089	0,000000114
9	25,931947	20,593195	4,614822	0,000000011	0,000000014
10	25,931947	20,593195	4,614822	0,000000001	0,000000002

5.3. PD metoda

Osnova metode projiciranja stvarne potražnje ili *PD* (engl. *Projection Detruncation*) *metode* polazi od činjenice da se analitičari oslanjaju na pretpostavku da je stvarna potražnja krivo procijenjena, odnosno manja od prave vrijednosti, a da je broj mjesta u pojedinoj klasi konstantna vrijednost. Jednostavno rečeno, to znači da se u točki provjere u kojoj je nastalo zatvaranje pojedine klase nalaze podaci o stvarnoj potražnji koja je bila veća od procijenjene (tj. potražnja je bila veća od kapaciteta). Zatvaranje pojedine klase predstavlja područje desno od linije kapaciteta na grafikonu 5.3. Podcjenjivanje potražnje tih promatranja odgovara području B, dakle, omjer τ je samo omjer područja B i područja A i B skupa. Korištenjem teorije vjerojatnosti, vrijednost τ može se ilustrirati s jednadžbom prikazanom na grafikonu 6.3. gdje je:

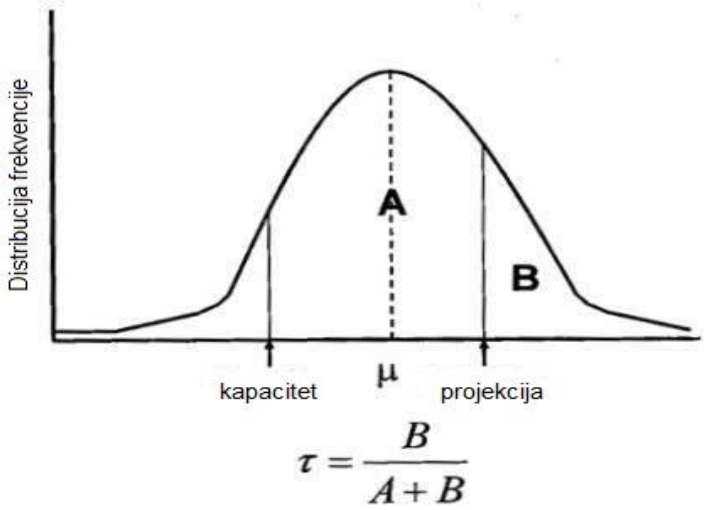
- τ - uvjetna vjerojatnost da je procijenjena stvarna potražnja podcijenjena;
- A + B - vjerojatnost da je potražnja veća od kapaciteta;
- B - vjerojatnost podcjenjivanja procijenjene stvarne potražnje.[64]

PD metoda je slična *EM algoritmu*. *PD algoritam* polazi od pretpostavke o normalnoj distribuciji potražnje te prvo računa prosječnu vrijednost broja zahtjeva za „otvorene“ letove. Zatim koristi proizvoljnu vrijednost τ za procjenu potražnje na

[64] Zickus, M.: *Forecasting for airline network revenue management: revenue and competitive impacts*, [M.S. thesis], Massachusetts Institute of Technology, Cambridge, Mass, USA, 1998., p. 38.

„zatvorenim“ letovima. Aktualna potražnja na zatvorenom letu zamjenjuje se novom vrijednošću tako da je omjer površine ispod krivulje normalne razdiobe desno od te nove vrijednosti i površine desno od originalne vrijednosti jednak τ (grafikon 6.3.).[65]

Zatim, za sve se promatrane letove, i „otvorene“ i one s projiciranom potražnjom računa očekivanje i standardna devijacija. Proces se ponavlja za „zatvorene“ letove dok projicirane vrijednosti (i očekivanje i standardna devijacija) ne počnu konvergirati.



Grafikon 5.3. Projiciranje stvarne potražnje PD metodom

Izvor: Belobaba, P. P., Weatherford, L.: *Advanced Topics in RM Forecasting*, STAR Alliance RM Educational Program, Taipei, 2016., p. 8.

5.3.1. Koraci PD metode

Razlika između *PD metode* i *EM metode* koja je prikazana u prethodnom poglavlju, je u izračunatim vrijednostima s kojima se u k-tom koraku iteracije zamjenjuju cenzurirane vrijednosti. Umjesto da se cenzurirani podaci zamjenjuju procjenom uvjetne srednje vrijednosti iz:

$$\hat{Z}_i^{(k-1)} = E\left[X|X \geq b_i, X \sim N(\mu^{(k-1)}, \sigma^{(k-1)})\right], \tag{43}$$

oni se zamjenjuju rješenjem sljedeće jednakosti za $\hat{Z}_i^{(k-1)}$:

$$\int_{\hat{Z}_i^{(k-1)}}^{\infty} f\left(x\middle|\left(\mu^{(k-1)}, \sigma^{(k-1)}\right)\right) dx = \tau \int_{b_i}^{\infty} f\left(x\middle|\left(\mu^{(k-1)}, \sigma^{(k-1)}\right)\right) dx, \tag{44}$$

gdje je vrijednost τ konstantna kroz cijeli algoritam (konstanta agresivnosti).

[65] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 148.

Jednakost (40) može se zapisati kao:

$$P(Z_i > \hat{Z}_i^{(k-1)} | Z_i > b_i, \mu^{(k-1)}, \sigma^{(k-1)}) = \tau, \tag{45}$$

odnosno $\hat{Z}_i^{(k-1)}$ odgovara izboru percentila uvjetne razdiobe za trenutne vrijednosti parametara $\mu^{(k-1)}, \sigma^{(k-1)}$. Primjerice, ako se uzme da je τ = 0,5, to bi značilo da se za $\hat{Z}_i^{(k-1)}$ uzima medijan uvjetne razdiobe, za razliku od *EM algoritma* koji koristi njezinu srednju vrijednost (za normalnu razdiobu zahtjeva te dvije vrijednosti su jednake).[66]

5.3.2. Numerički primjer PD algoritma

U nastavku rada prikazat će se numerički primjer *PD algoritma* (tablica 5.8.) na primjeru iz prethodnog poglavlja. Cilj je izračunati vrijednost stvarne potražnje za τ = 0,45, umjesto cenzurirane vrijednosti 23.

Prvi korak *PD algoritma* je izračun očekivanja i standardne devijacije iz necenzuriranog skupa podataka:

$$\mu^{(0)} = 20,$$

$$\sigma^{(0)} = 4{,}472136.$$

Neka je kriterij konvergencije $\delta = 0{,}0001$. Za zadane inicijalne vrijednosti μ i σ u *E-koraku* se računa $\hat{Z}^{(1)} = E[X|X > 22]$ tako da zadovoljava jednakost:

$$\int_{\hat{Z}^{(1)}}^{\infty} f(x)dx = \tau \int_{b_i}^{\infty} f(x)dx. \tag{46}$$

U *M-koraku* se cenzurirana vrijednost koja iznosi 23 zamjenjuje s tako izračunatom očekivanom vrijednošću koja iznosi 25,413945.

[66] Ibidem, p. 149.

Tablica 5.8. Numerički primjer PD algoritma za $\tau = 0{,}45$

Iteracija (k)	E[X|x>23]	$\mu^{(k)}$	$\sigma^{(k)}$	$\left\|\mu^{(k)} - \mu^{(k-1)}\right\|$	$\left\|\sigma^{(k)} - \sigma^{(k-1)}\right\|$
0	-	20	4,472136	-	-
1	25,413945	20,541394	4,550699	0,541394463	0,07856261
2	25,613252	20,561325	4,574783	0,019930781	0,02408428
3	25,636208	20,563621	4,577604	0,002295533	0,002821505
4	25,638889	20,563889	4,577935	0,000268129	0,000330202
5	25,639203	20,563920	4,577973	0,000031369	0,000038640
6	25,639239	20,563924	4,577978	0,000003671	0,000004521
7	25,639244	20,563924	4,577978	0,000000430	0,000000529
8	25,639244	20,563924	4,577978	0,000000050	0,000000062
9	25,639244	20,563924	4,577978	0,000000006	0,000000007
10	25,639244	20,563924	4,577978	0,000000001	0,000000001

5.3.3. Procjena konstante τ

Konstanta τ utječe na agresivnost nadogradnje. *PD metoda* se temelji na ideji da je vjerojatnost podcjenjivanja stvarne potražnje poznata i konstantna. Upravo je ta vjerojatnost konstanta agresivnosti. Primjerice, ako je τ jednaka 0,20, to znači da je u 20% slučajeva vrijednost stvarne potražnje podcijenjena. Ako se pretpostavi da je τ jednaka 1, procjena stvarne potražnje je podcijenjena sa 100 postotnom vjerojatnošću. To bi bilo istinito u slučaju da je procijenjena vrijednost jednaka cenzuriranoj vrijednosti, što predstavlja ekstreman slučaj te τ nikada nema vrijednost 1. Suprotan smjer, tj. $\tau = 0$, značilo bi da ne postoji vjerojatnost da je procijenjena vrijednost manja od stvarne vrijednosti, što se može tvrditi samo u slučaju da je procijenjena vrijednost vrlo velika i teži u beskonačnost.[67]

Za $\tau = 0{,}5$, *PD algoritam* će producirati procijenjenu vrijednost koja će u 50% slučajeva biti manja od stvarne vrijednosti potražnje, a u 50% slučajeva će biti veća od stvarne vrijednosti potražnje.

Općenito, za manje vrijednosti τ, *PD algoritam* će generirati veće vrijednosti procijenjene potražnje. Tablica 5.9. prikazuje iteracije *PD algoritma* na primjeru iz prethodnog poglavlja za $\tau = 0{,}15$. Algoritam konvergira nakon osam iteracija, a procijenjena vrijednost stvarne potražnje koja zamjenjuje cenzuriranu vrijednost 23, iznosi 27,952918, dok je za $\tau = 0{,}45$ iznosila 25,413945.

[67] Ibidem, p. 150.

Tablica 5.9. Numerički primjer PD algoritma za $\boldsymbol{\tau} = 0{,}15$

Iteracija (k)	E[X|x>23]	$\boldsymbol{\mu^{(k)}}$	$\boldsymbol{\sigma^{(k)}}$	$\left\|\boldsymbol{\mu^{(k)} - \mu^{(k-1)}}\right\|$	$\left\|\boldsymbol{\sigma^{(k)} - \sigma^{(k-1)}}\right\|$
0	-	20	4,472136	-	-
1	27,952918	20,795292	4,909447	0,7952917970	0,4373108776
2	28,918438	20,891844	5,072636	0,0965520234	0,1631887523
3	29,195126	20,919513	5,121798	0,0276688296	0,0491622354
4	29,278054	20,927805	5,136731	0,0082927269	0,0149332367
5	29,303211	20,930321	5,141279	0,0025156780	0,0045480086
6	29,310869	20,931087	5,142665	0,0007658771	0,0013862480
7	29,313203	20,931320	5,143088	0,0002334155	0,0004226378
8	29,313915	20,931392	5,143217	0,0000711610	0,0001288631
9	29,314132	20,931413	5,143256	0,0000216969	0,0000392915
10	29,314198	20,931420	5,143268	0,0000066156	0,0000119804

Prema Zickusu, najbolja vrijednost za τ je 0,15 ako zračni prijevoznik u svom sustavu za upravljanje kapacitetima zrakoplova koristi kombinaciju *PD metode* i *BP metode* te *EMSRb* (engl. *Expected Marginal Seat Revenue*) *model* upravljanja raspoloživim sjedalima zrakoplova.[68]

[68] Ibidem, p. 151.

6. USPOREDBA METODA ZA PROCJENU STVARNE POTRAŽNJE

Kako bi se usporedile različite metode za procjenu stvarne potražnje potrebno je dobro razumijevanje stvarne, odnosno necenzurirane potražnje. Bez mogućnosti usporedbe parametara procijenjene potražnje i parametara stvarne potražnje nije moguće ocijeniti učinkovitost pojedine metode. Zbog zatvaranja određenih cjenovnih razreda u kojima je došlo do cenzuriranja, korištenje podataka o realiziranoj potražnji i primjena metoda za procjenu stvarne potražnje, nije svrsishodno jer je nemoguće utvrditi koliko dobro procijenjeni parametri potražnje predočuju stvarnu potražnju.

Idealnu situaciju u kojoj bi stvarna potražnja na letu na kojem je došlo do zatvaranja određenih cjenovnih razreda jer je dosegnut rezervacijski limit, bila poznata, u praksi je nerealno očekivati jer se odbijeni zahtjevi ne bilježe i ne pohranjuju u bazi podataka. Isto tako, situaciju u kojoj niti jedan zahtjev na letu ne bi bio odbijen pa bi zabilježena i stvarna potražnja zapravo bile izjednačene, gotovo je nemoguće zamisliti jer i u slučajevima niske potražnje zahtjevi za nižim klasama prijevoza se u nekom trenutku rezervacijskog procesa redovito odbijaju. Najsličnija situacija bi bila ona u kojoj zračni prijevoznik na nekoj liniji pogrešno pretpostavi znatno veću potražnju i dodijeli toj liniji zrakoplov puno većeg kapaciteta od potrebnog. Odbijeni bi zahtjevi u tom slučaju bili rijetki, međutim, može se očekivati da bi na tu liniju vrlo brzo bio postavljen zrakoplov manjeg kapaciteta koji bi primjerenije zadovoljio prometnu potražnju pa opet ne bi postojao dovoljan broj letova za izračun parametara stvarne potražnje.[69]

Wickham tvrdi da procijenjenu stvarnu potražnju nije lako utvrditi. Smatra se da je ona osnova sustava za upravljanje kapacitetima zrakoplova, a mnogi analitičari su pokazali da točno procijenjena stvarna potražnja pruža bolje prognoze i povećava prihode. Na primjer, Skwarek je testirao sustave za upravljanje kapacitetima zrakoplova dva zračna prijevoznika. Jedan od njih koristi podatke procijenjene stvarne potražnje, dok drugi ne koristi. Rezultati pokazuju da čak i ako je stopa rezervacija niska, utjecaj nadograđenih podataka može povećati prihode do 3,5%. Osim toga, Weatherford i Pölt navode da s primjenom podataka o stvarnoj potražnji velike američke zrakoplovne tvrtke, nadograđeni proces rezultira povećanjem prihoda od 2-12%.[70]

S obzirom na porast prihoda, može se vidjeti da procijenjena stvarna potražnja zaslužuje pozornost istraživača i praktičara. Predviđanje na temelju nadograđenih podataka može prevladati ograničenja cenzurirane potražnje zbog rezervacijskih limita, bolje odražava stvarnu potražnju, te poboljšava točnost predviđanja. Osim toga, procijenjena stvarna potražnja također je korisna za raspodjelu kapaciteta flote.

[69] Ibidem

[70] Peng, G., Baichun, X., Jun L.: *Unconstraining Methods in Revenue Management Systems: Research Overview and Prospects*, Hindawi Publishing Corporation, Advances in Operations Research, Volume 2012, Article ID 270910, 2012., p. 2.

Weatherford i Pölt u svom su istraživanju najprije iz normalne distribucije generirali tri seta podataka koji su predstavljali stvarnu potražnju, a onda su za svaki od njih, nasumično, opet iz normalne distribucije sa sukcesivno manjim očekivanjima, generirali rezervacijske limite koji su rezultirali cenzuriranjem podataka u potražnji u postotku koji je varirao od 0 do 98%. Na tako dobivenim setovima podataka koji su predstavljali zabilježenu i cenzuriranu potražnju, testirali su više metoda za procjenu stvarne potražnje.[71]

Zeni je u svojoj doktorskoj disertaciji simulirao situaciju u kojoj nije bilo niti jednog odbijenog zahtjeva jer je kapacitet zrakoplova bio dovoljno velik. Zatim je analizirao što bi se dogodilo da je kapacitet zrakoplova bio manji od stvarnog.

Crystal, Ferguson, Higbie i Kapoor su u svom članku za potrebe analize različitih metoda procjene stvarne potražnje simulirali tri seta podataka koji predstavljaju tri oblika krivulja kumulativnih rezervacija: konkavni, konveksni i homogeni. Dolasci su konstruirani pomoću Poissonove distribucije: za homogenu krivulju kumulativnog broja rezervacija, srednje vrijeme međudolazaka je konstantno, za konveksnu, odnosno konkavnu krivulju kumulativnog broja rezervacija srednje vrijeme međudolazaka se s vremenom povećava, odnosno smanjuje. Nakon toga su, slično kao Weatherford i Pölt, za različite pretpostavljene razine cenzuriranja, tj. za različite postotke nepotpunih podataka, nasumično, iz normalne razdiobe za različite *z* vrijednosti generirali rezervacijske limite.[72]

Skwarek i Hopperstad su ispitali četiri metode za procjenu stvarne potražnje N2 (engl. *Naïve Method*) metodu, N3 metodu, BP metodu i PD metodu. Oni smatraju da su BP i PD metoda najbolje među ove četiri metode, ostvarujući 2-3% veći porast prihoda u odnosu na N2 metodu. Pölt i Weatherford su ispitali pet metoda (N1, N2, N3, BP i EM) i zaključili su da je EM metoda najrobusnija čak i ako je izmjerena na različite načine. Pölt mjeri pristranost uzorkovanja i srednju apsolutnu pogrešku, dok Weatherford ispituje koliko je procjena blizu prave srednje vrijednosti.

Zeni i Lawrence su usporedili šest metoda (N1, N2, N3, BP, PD, i EM). Zaključili su da je EM metoda, posebno prošireni EM algoritam, najrobusnija metoda u smanjenju pogrešaka. Njihovi zaključci su slični Pölt-u i Weatherford-u u određenoj mjeri. Weatherford i Pölt su ispitali iste metode za procjenu stvarne potražnje koje je ispitao i Zeni. Njihova simulacija je pokazala da su EM i PD metoda vrlo robusne. Na primjer, kako se postotak cenzuriranja povećava za 60-80%, njihove procjene stvarne potražnje rezultiraju povećanjem točnosti od 20-80% u odnosu na ostatak ispitanih metoda. Na temelju tih nalaza, Chen i Luo su dobili neke korisne rezultate koje se odnose na usporedbu EM i PD metode.[73]

---

[71] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 152.

[72] Ibidem

[73] Peng, G., Baichun, X., Jun L.: *Unconstraining Methods in Revenue Management Systems: Research Overview and Prospects*, Hindawi Publishing Corporation, Advances in Operations Research, Volume 2012, Article ID 270910, 2012., p. 11.

Kako današnja tehnologija i pohranjivanje podataka postaje jeftinije iz dana u dan, najbolja opcija za procjenu što točnije stvarne potražnje je da se istodobno koristi nekoliko metoda predviđanja, te da se odabere najbolja metoda. Naravno, određivanje najbolje metode postaje još jedan dodatni zadatak u predviđanju, pa ima mnogo prijedloga za razvoj takve strategije. No, ne mora ni biti potrebno odrediti najbolju metodu predviđanja, zato jer linearna kombinacija prognoze s odgovarajućom težinom može biti dosljedno superiornija od bilo kojih sastavnih metoda. Ova ideja je predložena u članku Bates-a i Granger-a, te je istodobno potaknula analitičare da više istražuju prognoziranje stvarne potražnje. Želi se postići da se pogreške dobivene pomoću dvije metode predviđanja negativno koreliraju i da se zatim kombiniraju, kako bi u konačnici rezultirali smanjenjem ukupne pogreške prognoziranja.

Slijedi primjer kombiniranja prognoze iz dva različita modela koje su predložili Bates i Granger. Neka je MSE_i srednja kvadratna pogreška modela *i, i* = 1,2, ρ koeficijent korelacije između pogrešaka u prognozama dva modela, te neka je $\hat{Z}$ prognoza. Zatim se vrijednost definira kao α i (1 - α), gdje je α određen izrazom:

$$\alpha = \frac{MSE_2 - \rho\sqrt{MSE_1}\sqrt{MSE_2}}{MSE_1 - MSE_2 - 2 - \rho\sqrt{MSE_1}\sqrt{MSE_2}} \tag{47}$$

Tada kombinacija dviju prognoza glasi:

$$\hat{Z} = \alpha\hat{Z}_1 + (1-\alpha)\hat{Z}_2. \tag{48}$$

Druga kombinacija, ovaj put uz pomoć prilagodljive vjerojatnosti koja se razlikuje s vremenom, je da se postavi $\alpha = \alpha(t)$ uz vrijeme *t*:

$$\alpha(t) = \sum_{i=1}^{t} \frac{MSE_2(t)}{MSE_1(t) + MSE_2(t)} \tag{49}$$

gdje je $MSE_i(t)$ srednja kvadratna greška modela *i* uz vrijeme *t*.[74]

Može se zaključiti da mješoviti skup prognoza može donijeti nižu srednju kvadratnu pogrešku nego bilo koja pojedinačna originalna prognoza. Prošle pogreške svake originalne prognoze se koriste za određivanje težine kako bi se dodale pojedinačnim prognozama koje se koriste za kombiniranje prognoza, te su ispitani različiti načini izvođenja tih vrijednosti.[75]

U slučajevima u kojima su napravljene dvije (ili više) prognoze istog događaja, reakcija većine statističara i poduzetnika je pokušavati otkriti koja je prognoza bolja

[74] Talluri, K. T., Van Ryzin, G. J.: *The Theory and Practice of Revenue Management*, Springer, New York, 2004., p. 473.
[75] Bates, J. M., Granger, C. W. J.: *The Combination of Forecasts*, OR, Vol. 20, No. 4,1969., p. 451.

(ili najbolja). Bolja prognoza je tada prihvaćena i korištena, a druga se odbacuje. Takav pristup ima svrhu ako je cilj analize provjera i vježba. Međutim, takav pristup nije primjenjiv ako je cilj razvoj i poboljšanje prognoze, budući da odbačena prognoza gotovo uvijek sadrži neke korisne nezavisne informacije.

Nezavisne informacije mogu biti:

- prognoza se temelji na varijablama ili informacijama koje druga prognoza nije uzela u obzir;
- prognoza čini drugu pretpostavku o formi odnosa između varijabli.

Drugi slučaj ne mora nužno dovesti do situacije u kojoj se kombinirana prognoza poboljšava nakon bolje pojedine prognoze, iako postoje prilike kada je to moguće. Treba napomenuti da je nametnut jedan uvjet o prirodi pojedinih prognoza, tj. da su nepristrane. Prema tome, prvi korak je provjeriti da su pojedine skupine prognoza nepristrane, a ako nisu potrebno ih je ispraviti za prosječni (ili apsolutni) postotak pristranosti.[76]

Način na koji će potpuni podaci, tj. podaci o stvarnoj potražnji biti umjetno cenzurirani predstavlja problem koji je usporediv s razvijanjem metode za procjenu stvarne potražnje. Cenzuriranje je važno provesti na način koji će simulirati tipično ponašanje zračnog prijevoznika, odnosno sustava za upravljanje kapacitetima zrakoplova. U protivnom, dobiveni rezultati o usporedbi metoda za procjenu stvarne potražnje neće biti realni i opravdano bi se moglo postaviti pitanje o tome kakvi bi oni bili da su podaci o stvarnoj potražnji cenzurirani na neki drugi način.[77]

[76] Ibidem
[77] Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013., p. 153.

7. ZAKLJUČAK

Na potražnju za zračnim prijevozom najveći utjecaj ima cijena, ali postoje i neki drugi faktori koji značajno utječu na veličinu prometne potražnje. Takvi faktori mogu biti broj putnika na određenom tržištu, platežna sposobnost i dohodak putnika, cijene konkurencije te očekivanja putnika u odnosu na cijene usluga. Osnovna uloga sustava za upravljanje kapacitetima zrakoplova je izračunati rezervacijske limite za sve cjenovne razrede kako bi očekivani ukupni prihod na svim budućim letovima bio što bliži maksimalnom prihodu. Rezervacijski limiti se računaju pomoću parametara potražnje, ali ne realizirane, nego stvarne potražnje odnosno potražnje koja predstavlja zbroj realizirane potražnje i odbijenih zahtjeva za prijevozom. Kako bi se to ostvarilo potrebno je odrediti najbolju metodu za procjenu stvarne potražnje u sustavima za upravljanje kapacitetima zrakoplova.

Metode za procjenu stvarne potražnje služe za procjenjivanje ukupne potražnje, odnosno onakve potražnje koja bi bila da rezervacijski limiti nisu postojali. Kada potražnja za određenom klasom prijevoza dosegne rezervacijski limit, ona ne predstavlja stvarnu potražnju, jer se broj zahtjeva koji su odbijeni zbog zatvaranja klase ne arhiviraju u rezervacijskim sustavima zračnih prijevoznika te dolazi do cenzuriranja podataka. Ti cenzurirani podaci su osnova prognoziranja potražnje, ali je nužna njihova nadogradnja brojem odbijenih zahtjeva za rezervacijom. Takvi nadograđeni podaci su nužni za pouzdano predviđanje buduće potražnje jer povećavaju točnost prognoziranja i smanjuju mogućnost pogreške.

Što se tiče prognoziranja potražnje za zračnim prijevozom, prognoziranje predstavlja vrlo kritičnu poslovnu funkciju zračnog prijevoznika s velikom mogućnošću pogreške i velikom nesigurnošću. Ona je jedna od najzahtjevnijih organizacijskih funkcija jer zahtijeva prognoziranje budućnosti i trenutno prilagođavanje budućnosti. Prognostičari koriste razne metode za procjenu potražnje, te svaka od njih ima određene prednosti i nedostatke. Budući da ne postoji najbolji način predviđanja prognoze, razvijeni su razni algoritmi kako bi se procijenile nadograđene vrijednosti s dobrom točnošću.

Kada se govori o izboru najbolje metode, uglavnom se govori o kombinacijama i varijacijama vrlo složenih metoda s ciljem što realnijeg predviđanja. Među najboljim metodama mogu se svrstati EM i PD metoda koje se smatraju vrlo robusnim. Učinkovitost prognostičkih metoda se najčešće ocjenjuje na temelju točnosti prognoziranja, tj. na razlici između prognoziranih i stvarnih vrijednosti pojave u prošlosti. Međutim, potrebno je naglasiti kako velika prognostička točnost metode u prošlosti nije garancija da će ista metoda u budućnosti dati jednako točne prognoze.

Literatura

1. Bates, J. M., Granger, C. W. J.: *The Combination of Forecasts*, OR, Vol. 20, No. 4 (Dec., 1969), pp. 451.-468., 1969.
2. Belobaba, P. P., Weatherford, L.: *Advanced Topics in RM Forecasting*, STAR Alliance RM Educational Program, Taipei, 2016
3. Belobaba, P. P., Weatherford, L.: *Applications of Statistics and Probability to Revenue Management*, STAR Alliance RM Educational Program, Taipei, 2016.
4. Belobaba, P. P., Weatherford, L.: *Demand Forecasting in RM Systems*, STAR Alliance RM Educational Program, Taipei, 2016.
5. Cooper, W. L., Homem-de-Mello, T., Kleywegt, A.: *Models of the Spiral-Down Effect in Revenue Management*, Operations research Vol. 54, No. 5, September–October, p. 968-987, 2006.
6. Crystal Queenan, C., Ferguson, M., Higbie, J., Kapoo, R.: *A Comparison of Unconstraining Methods to Improve Revenue Management Systems*, Production and Operations Management Society, Vol. 16, No. 6, November–December 2007, pp. 729 –746, 2007.
7. Čekolj, B.: *Modeli procjene potražnje i konkurentnost zračnog prijevoza u Republici Hrvatskoj*, magistarski znanstveni rad, Zagreb, 2008.
8. De Neufville, R., Odoni, A.: *Airport systems: Planning, Design and Management*, the McGraw-Hill Companies, 2003.
9. Gökşen, S.: *Implementing Revenue Management*, BMI – Paper, Amsterdam, 2011.
10. Peng, G., Baichun, X., Jun L.: *Unconstraining Methods in Revenue Management Systems: Research Overview and Prospects*, Hindawi Publishing Corporation, Advances in Operations Research, Volume 2012, Article ID 270910, 23 pages, 2012.
11. Škurla Babić, R.: *Model predviđanja potražnje u sustavu dinamičkog upravljanja kapacitetima zrakoplova*, doktorska disertacija, 2013.
12. Škurla Babić, R.: *Unapređenje sustava za upravljanje kapacitetima zrakoplova*, magistarski znanstveni rad, Zagreb, 2003.
13. Šošić, I.: *Primijenjena statistika*, Školska knjiga, Zagreb, 2006.
14. Talluri, K. T., Van Ryzin, G. J.: *The Theory and Practice of Revenue Management*, Springer, New York, 2004.
15. Tatalović, M., Mišetić, I., Bajić, J.: *Menadžment zrakoplovne kompanije*, MATE d.o.o., Zagreb, 2012.
16. URL: http://slidegur.com/doc/1095599/statistika3, (pristupljeno: srpanj 2016.)
17. URL: http://veleri.hr/~ljstambuk/Kvantitativne%20za%20web/Korelacija%20i%20regresija_pod.pdf, (pristupljeno: kolovoz 2016.)
18. URL: http://web.efzg.hr/dok/sta/vbahovec/statistika%20za%20poduzetnike/11_PRE

DAVANJE_ANALIZA%20VREMENSKOG%20NIZA.pdf, (pristupljeno: kolovoz 2016.)
19. URL: http://www.eumetcal.org/resources/ukmeteocal/verification/www/english/msg/ver_cont_var/uos3/uos3_ko1.htm, (pristupljeno: rujan 2016.)
20. URL: https://smartech.gatech.edu/bitstream/handle/1853/13600/RM_unconstrain_021507_crc.pdf, (pristupljeno: srpanj 2016.)
21. Zeni, R. H.: *Improved Forecast Accuracy in Airline Revenue Management by Unconstraining Demand Estimates from Censored Dana,* Dissertation.com, USA, 2001.
22. Zickus, M.: *Forecasting for airline network revenue management: revenue and competitive impacts,* [M.S. thesis], Massachusetts Institute of Technology, Cambridge, Mass, USA, 1998.

Popis kratica

BP	(Booking Profile) metoda dogradnje krivulje rezervacija
CRS	(Computerized Reservation System) računalni rezervacijski sustav
DCP	(Data Collection Point) prikupljanje podataka u točki provjere
EM	(Expectation Maximization) metoda maksimizacije očekivanja
EMSRb	(Expected Marginal Seat Revenue) model upravljanja raspoloživim sjedalima zrakoplova
GDS	(Global Distribution System) globalni distribucijski sustav
IATA	(International Air Transport Association) međunarodna udruga za zračni prijevoz
MAE	(engl. *Mean Absolute Error*) srednja apsolutna pogreška
N2	(Naïve #2 Method) naivna metoda 2
PD	(Projection Detruncation) metoda projiciranja stvarne potražnje
RWA	(Replace With Average) metoda zamjene cenzuriranih podataka aritmetičkom sredinom
RWM	(Replace With Median) metoda zamjene cenzuriranih podataka medijanom necenzuriranih podataka
SABRE	(Semi-automated Business Research Environment)

Popis slika

Slika 3.1. Tijek podataka o učinjenim rezervacijama 16
Slika 5.1. Blok dijagram EM algoritma 39

Popis tablica

Tablica 2.1. Segmentacija kupaca prema industriji.....6
Tablica 3.1. Usporedba rezultata pomičnog prosjeka i eksponencijalnog izglađivanja 21
Tablica 3.2. Primjer izračuna srednje apsolutne pogreške – MAE.....23
Tablica 4.1. Primjer nadogradnje cenzuriranih vrijednosti za I1 i I2 metodu.....27
Tablica 4.2. Primjer nadogradnje cenzuriranih vrijednosti za RWA, RWM i RWP75 metodu 29
Tablica 5.1. Povijesni podaci o potražnji.....30
Tablica 5.2. Podaci za računanje standardne devijacije 31
Tablica 5.3. Distribucija frekvencije 32
Tablica 5.4. Podaci za graf normalne razdiobe.....33
Tablica 5.5. Primjer nadogradnje cenzuriranih podataka BP metodom 35
Tablica 5.6. Uzorak za primjer EM algoritma.....40
Tablica 5.7. Numerički primjer EM metode.....41
Tablica 5.8. Numerički primjer PD algoritma za $\tau = 0{,}45$ 44
Tablica 5.9. Numerički primjer PD algoritma za $\tau = 0{,}15$.....45

Popis grafikona

Grafikon 3.1. Kumulativna krivulja rezervacija za „zatvoreni“ cjenovni razred.....17
Grafikon 5.1. Histogram frekvencija 32
Grafikon 5.2. Normalna razdioba 33
Grafikon 5.3. Projiciranje stvarne potražnje PD metodom.....42

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000Zagreb
Vukelićeva 4

METAPODACI

Naslov rada: **Metode za procjenu stvarne potražnje u sustavima za upravljanje kapacitetima zrakoplova**

Autor: **Petra Medved**

Mentor: **doc. dr. sc. Ružica Škurla Babić**

Naslov na drugom jeziku (engleski):

Unconstraining Methods for True Demand Estimation in Airline Revenue Management Systems

Povjerenstvo za obranu:

- **doc. dr. sc. Mirko Tatalović**, predsjednik
- **doc. dr. sc. Ružica Škurla Babić**, mentor
- **doc. dr. sc. Andrija Vidović**, član
- **prof. dr. sc. Stanislav Pavlin**, zamjena

Ustanova koja je dodjelila akademski stupanj: Fakultet prometnih znanosti Sveučilišta u Zagrebu
Zavod: Zavod za zračni promet
Vrsta studija: sveučilišni
Naziv studijskog programa: Promet
Stupanj: diplomski
Akademski naziv: mag. ing. traff.
Datum obrane diplomskog rada: 27. rujna 2016.

Napomena: pod datum obrane diplomskog rada navodi se prvi definirani datum roka obrane.

Sveučilište u Zagrebu
Fakultet prometnih
znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu diplomskog rada pod naslovom **Metode za procjenu stvarne potražnje u sustavima za upravljanje kapacitetima zrakoplova**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, 19.9.2016

(potpis)