Metode prognoziranja zračnog prometa u kontekstu upravljanja zračnim prometom

Lonjak, Ivan

Master's thesis / Diplomski rad

2017

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:119:776962

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Ivan Lonjak

METODE PROGNOZIRANJA ZRAČNOG PROMETA U KONTEKSTU UPRAVLJANJA ZRAČNIM PROMETOM

DIPLOMSKI RAD

Zagreb, 2017.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 24. travnja 2017.

Zavod: **Zavod za zračni promet**
Predmet: **Upravljanje zračnom plovidbom**

DIPLOMSKI ZADATAK br. 4033

Pristupnik: **Ivan Lonjak (0135229093)**
Studij: Promet
Smjer: Zračni promet

Zadatak: **Metode prognoziranja zračnog prometa u kontekstu upravljanja zračnim prometom**

Opis zadatka:

U diplomskom radu je potrebno identificirati metode prognoziranja u zračnom prometu, s posebnim osvrtom na metode prognoziranja u kontroli zračnog prometa s aspekta praćenja IFR kretanja i prognoza jedinica usluge. Na temelju izvršene identifikacije potrebno je analizirati metode prognoziranja s aspekta inputa koji se koriste prilikom definiranja određene metode prognoziranja (kratkoročne, srednjoročne i dugoročne prognoze). Na temelju identifikacije i analize odabranih metoda prognoziranja, potrebno je dati pregled/prognoze IFR kretanja i jedinica usluge, za odabrane pružatelje usluga u zračnoj plovidbi.

Zadatak uručen pristupniku: 28. travnja 2017.

Mentor:

doc. dr. sc. Tomislav Mihetec

Predsjednik povjerenstva za diplomski ispit:

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

DIPLOMSKI RAD

METODE PROGNOZIRANJA ZRAČNOG PROMETA U KONTEKSTU UPRAVLJANJA ZRAČNIM PROMETOM

AIR TRAFFIC FORECASTING METHODOLOGIES IN CONTEXT OF AIR TRAFFIC MANAGEMENT

Mentor: doc. dr. sc. Tomislav Mihetec
Student: bacc. ing. traff. Ivan Lonjak
JMBAG: 0135229093

Zagreb, 2017.

SAŽETAK

Raspoloživi statistički podaci trenutnog stanja zračnog prometa omogućavaju adekvatno razumijevanje prošlih događaja. Prije odabira adekvatne prognostičke metode, evaluiraju se ulazni podaci koji najefikasnije odražavaju prometne pokazatelje u kontekstu upravljanja zračnim prometom u predviđenom razdoblju prognoze. Nije točno definirana univerzalna primjena određene metode, ali se u praktičnoj primjeni koristi kombinacija srodnih kvantitativnih metoda prognoziranja koje događaje iskazuju u numeričkom obliku i pomoću analiza iskazuju prošle pojave te čimbenike koji su utjecali na njih. Ocjena odabira adekvatne prognostičke metode zavisi o korelaciji trenutnog stanja i predviđanja prometnih pokazatelja. Prognoza se izrađuje za određenu državu ili regiju koja je predmetom prognoze IFR kretanja zrakoplova (domaći, dolazni i odlazni, preleti) i broja jedinica usluge (rutne i terminalne jedinice usluge). Na području Europe koriste se tri vremenska razdoblja prognoziranja. Vremensko razdoblje od dvije godine unaprijed integrirano u srednjoročnu prognozu, zatim vremensko razdoblje od sedam godina zasnovano na kratkoročnoj prognozi i naposljetku, vremensko razdoblje u narednih 20 godina koje uzima u obzir niz mogućih scenarija koji će odražavati budući izgled industrije zračnog prometa.

KLJUČNE RIJEČI: statistički podaci; ulazni podaci; kvantitativne metode; prognoza; vremensko razdoblje; IFR kretanja zrakoplova; broj jedinica usluge

SUMMARY

Available statistical data of the actual air traffic status provide an adequate understanding of past events. Prior to selecting an adequate forecast method, input data are evaluated, which most efficiently reflect traffic indicators in context of air traffic management to predicted period of the forecast. There is no universal agreement about the application of a particular method, but in practice a combination of related quantitative forecasting methods is applied. They express events in numerical form and by analysis show past phenomena and the factors influencing them. The selection of an adequate prognostic method depends on the correlation of the actual state and prediction of traffic indicators. The forecast is made for a particular country or region that is subject to the IFR flight movements (internal, arrival and departure, overflight) and number of service units (en-route and terminal navigation service units). Three time horizons forecasting periods are used in Europe. The two-year timeframe pre-integrated into the mid-term forecast, followed by a seven-year time horizon based on short-term forecasts and, finally, a time horizon over the next 20 years that takes into account a number of possible scenarios that will reflect the future appearance of the aviation industry.

KEY WORDS: statistical data; input data; quantitative methods; forecast; time horizon; flights movements; service units

SADRŽAJ

1. UVOD 1

2. ICAO METODOLOGIJA PROGNOZIRANJA 3

2.1. Metode analize vremenskih nizova 3

2.1.1. Trend projekcija 3

2.1.1.1 Klasifikacija trend krivulja 4

2.1.1.2 Statistička procjena 6

2.1.2. Metode dekompozicije vremenskih nizova 6

2.1.2.1 Jednostavno eksponencijalno izglađivanje 6

2.1.2.2 Metoda eksponencijalnog izglađivanja s trendom i sezonalnošću (Holt-Winter) 7

2.1.2.3 Metoda pomičnog prosjeka 8

2.1.2.4 Auto regresivni model koji integrira pomični prosjek (ARIMA) 8

2.2. Ekonometrijska analiza 9

3. METODOLOGIJA PROGNOZIRANJA ATM-a U EUROPI 11

3.1. Mrežni upravitelj (NM) 12

3.2. Centralni ured za naplatu rutnih naknada (CRCO) 14

3.2.1. Naplata rutnih jedinica usluge 14

3.2.2. Naplata terminalnih jedinica usluge 16

3.3. STATFOR 17

3.3.1. Metodologija izrade kratkoročne prognoze (2017-2018) 19

3.3.1.1 Prognoza IFR kretanja zrakoplova 19

3.3.1.2 Prognoza rutnih jedinica usluge 23

3.3.1.3 Prognoza terminalnih jedinica usluge 28

3.3.2. Metodologija izrade srednjoročne prognoze (2017-2023) 29

3.3.2.1 Godišnja prognoza prometa 32

3.3.2.2 Mjesečna prognoza prometa 33

3.3.2.3 Ulazni podaci 35

3.3.2.3.1 Gospodarski rast 35

3.3.2.3.2 Kapacitet zračnih luka 37

3.3.2.3.3 Razvoj faktora popunjenosti 38

3.3.2.3.4 Događanja i trendovi 39

3.3.2.3.5 Red letenja zračnog prijevoznika 40

3.3.2.3.6 Razvoj niskotarifnih zračnih prijevoznika 41
3.3.2.3.7 Demografija i sklonost prema letenju 41
3.3.2.3.8 Razvoj željeznica velikih brzina 42
3.3.2.4 Prognoza IFR kretanja zrakoplova 44
3.3.2.4.1 Ograničenja kapaciteta zračnih luka 47
3.3.2.4.2 Utjecaj željeznica velikih brzina 49
3.3.2.4.3 Utjecaj rizika na prognozu 50
3.3.2.5 Prognoza rutnih jedinica usluge 53
3.3.2.6 Prognoza terminalnih jedinica usluge 58
3.3.3. Metodologija izrade dugoročne prognoze (2013-2035) 60
3.3.3.1 Scenarij budućeg razvoja 62
3.3.3.1.1 Scenarij A 63
3.3.3.1.2 Scenarij C 64
3.3.3.1.3 Scenarij C' 66
3.3.3.1.4 Scenarij D 66
3.3.3.2 Rezultati dugoročne prognoze 67
3.3.3.2.1 Kapacitet zračne luke 68
3.3.3.2.2 Mreža zračnih luka i zračnih prijevoznika 69
3.3.3.2.3 Udaljenost prijevoza i veličina zrakoplova 70
3.3.3.2.4 Utjecaj vlakova velikih brzina 73
3.3.3.3 Utjecaj rizika na dugoročnu prognozu 74
4. ANALIZA ATM PROMETNIH POKAZATELJA U REPUBLICI HRVATSKOJ .. 75
4.1. Satno IFR kretanje zrakoplova 75
4.2. Mjesečno IFR kretanje zrakoplova 76
4.3. Godišnje IFR kretanje zrakoplova 77
4.4. Potražnja IFR kretanja zrakoplova 79
4.5. Traženi profil kapaciteta za LDZO ACC 81
4.6. Analiza rutnih jedinica usluge 82
4.7. Analiza terminalnih jedinica usluge 86
5. ZAKLJUČAK 87
LITERATURA 90
POPIS KRATICA 93
POPIS SLIKA 98
POPIS TABLICA 100
POPIS GRAFIKONA 102

1. UVOD

Zračni promet[1] neprestano raste te se suočava s nizom zahtjeva koji se treba savladati u budućem vremenskom razdoblju[2]. Iz tog razloga, potrebno je unaprijed predviđati buduće scenarije razvoja zračnog prometa u kontekstu upravljanja zračnim prometom (engl. *Air Traffic Management* – ATM[3]) primjenom različitih metoda prognoziranja zračnog prometa. Prognoza[4] zračnog prometa izrađuju se za određenu državu (prometnu zonu) ili regiju. Prognoze se projiciraju za kratkoročno, srednjoročno ili dugoročno vremensko razdoblje te je najbolji odabir prognostičke metode koja najpreciznije određuje približnu vrijednost ostvarenog prometa. Metodologija prognoziranja zračnog prometa temelji se na raspoloživim statističkim podacima te je neizbježna prilikom izrade budućih ATM prometnih trendova.

Diplomski rad sastoji se od tri strukturne cjeline. Prva cjelina, pod nazivom ***ICAO metodologija prognoziranja***, podrazumijeva pristup koji se koristi pri modeliranju i prognoziranju specifičnih zahtijeva u kontekstu upravljanja u zračnom prometu. Pristupi su razjašnjeni u prvom dijelu priručnika za prognoziranje zračnog prometa (engl. *Manual of Air Traffic Forecasting Part I* – Doc 8991) kroz kvantitativne metode prognoziranja zračnog prometa, gdje svaka metoda odražava potrebe prognoziranja određenog segmenta zračnog prometa (IFR kretanja zrakoplova[5] i broj jedinica usluge[6]). Metode su klasificirane u dvije glavne pod kategorije: metode analize vremenskih nizova i kauzalne metode. Metode analize vremenskih nizova temelje se na pretpostavci da uzorak povijesnih podataka ima svoju vjerodostojnost. U istom poglavlju bit će objašnjena trend projekcija te metode dekompozicije vremenskih nizova, dok će u kontekstu kauzalnih metoda biti obrađena samo ekonometrijska analiza koja prikazuje odnos ponude i potražnje u zračnom prometu koja je izazvana promjenama nezavisnih varijabli i cijene usluga zračnog prometa.

[1] Podrazumijeva letenje zrakoplova i kretanje zrakoplova po operativnim površinama aerodroma [1].
[2] Podrazumijeva vremensko razdoblje između posljednjih stvarnih podataka koji su korišteni pri izradi prognoze i zadnjih podataka prognoze [2].
[3] engl. *Air Traffic Management* – Upravljanje zračnim prometom predstavlja dinamični integrirani način upravljanja zračnim prometom i zračnim prostorom – sigurno, ekonomski i efikasno – koji se postiže pružanjem sredstava i usluga u kolaboraciji svih učesnika zračnog prometa [3].
[4] Podrazumijeva skup budućih vrijednosti za mjerenje. Prognoza obično uključuje niz vrijednosti za određeno vremensko razdoblje [2].
[5] Podrazumijeva suradnju faza leta u volumenu zračnog prostora ili dvodimenzionalnom području. Takva suradnja je vremenski ograničena s dva stanja tijekom faza leta: početak/ulazak i izlazak/kraj. U odnosu na volumen zračnog prostora, kretanje se može prekinuti. U odnosu na dvodimenzionalno područje, kretanje ne može biti prekinuto. Kretanja su podijeljena na: domaći, dolazni, odlazni i preleti [2].
[6] Podrazumijeva množenje faktora mase zrakoplova s faktorom duljine leta [2].

U drugoj cjelini, ***Metodologija prognoziranja ATM-a u Europi***, identificirat će se metodologija prognoziranja ATM-a na području Europe te ulazni podaci koji se valoriziraju za određeno vremensko razdoblje. Pomoću dostupnih statističkih podataka i raznih analiza dobivenih od vladinih organizacija, omogućuje se dobivanje pouzdanih prognoza prometa visoke točnosti za određeni segment zračnog prometa. Obradom trenutnog stanja podataka, omogućeno je mjerenje i razumijevanje očekivanog razvoja zračnog prometa. U istom poglavlju bit će navedeni i objašnjeni trendovi prometnih pokazatelja IFR kretanja zrakoplova te njihov godišnji rast. Nakon toga bit će pobliže objašnjeno kretanje brojeva jedinica usluge na području Europe s naglaskom na rutne i terminalne jedinice usluga.

U trećoj cjelini, ***Analiza ATM prometnih pokazatelja u Republici Hrvatskoj***, na temelju izvršene analize prikazat će se evolucija zračnog prometa i odstupanje trenutnog stanja ATM prometnih pokazatelja zabilježenih od Hrvatske kontrole zračnog prometa od raspoloživih podataka dobivenim od službi koje se bave statistikom i prognozom (engl. *Statistics and Forecast Service* – STATFOR) i Centralnog ureda koji se bavi naplatom rutnih naknada (engl. *Central Route Charge Office* – CRCO). Pomoću analiza ATM prometnih pokazatelja dat će se odgovor na pitanje o budućim trendovima rasta zračnog prometa u Republici Hrvatskoj.

Cilj ovog diplomskog rada je utvrditi na koji se način provodi metodologija prognoziranja ATM-a na području Europe, koji su ulazni podaci potrebni da bi se utvrdili budući prometni trendovi te na temelju kojih kriterija STATFOR segmentira prognozu prometa s obzirom na vremensko razdoblje.

2. ICAO METODOLOGIJA PROGNOZIRANJA

Prije odabira adekvatne prognoze potrebno je utvrditi njezinu primarnu namjenu. Kao takva, prognoza uzima u razmatranje kratkoročno, srednjoročno ili dugoročno vremensko razdoblje. Izlazni podaci, razina detalja i metode prognoziranja međusobno se razlikuju. U području civilnog zrakoplovstva, prognoza se koristi kao:

1) pomoć državama pri odvijanju urednog razvitka civilnog zrakoplovstva, kao i pomoć na svim razinama vladinih organizacija u pogledu planiranja zračnog prostora i infrastrukture zračnih luka;
2) pomoć zračnim prijevoznicima pri planiranju opreme i strukture ruta u dugoročnom razdoblju;
3) pomoć proizvođačima zrakoplova pri planiranju budućih tipova zrakoplova (u smislu veličine i doleta) i određivanju vremena za njihov razvoj [4].

2.1. Metode analize vremenskih nizova

Metode analize vremenskih nizova temelje se na pretpostavkama povijesnih podataka koje imaju tendenciju daljnjeg nastavka te se oslanjaju se na raspoložive povijesne podatke [4]. Koriste se u okruženju koje odražava stabilnost ulaznih parametara koji se evaluiraju u kratkoročnom razdoblju prognoze.

2.1.1. Trend projekcija

Prvi korak pri prognoziranju aktivnosti zračnog prometa je pregled povijesnih podataka tj. vremenskih nizova te određivanje njihovih trendova. U kontekstu srednjoročnog ili dugoročnog prognoziranja, trend predstavlja evoluciju prometa tijekom dužeg vremenskog razdoblja, isključujući oscilacije prometa za kratkoročne prognoze [4].

Analizom trendova ucrtavaju se nizovi povijesnih podataka na grafikon. Zavisna varijabla koja je predmetom prognoze prometa prikazuje se na okomitoj osi, a nezavisna varijabla koja predstavlja vrijeme prikazuje se na vodoravnoj osi. U trenutku, kad sve točke bude iscrtane za svaki vremenski niz, izglađena krivulja približava se točkama. Trend se može iskazati u apsolutnom obliku kao linearni rast ili u postotnom obliku kao eksponencijalni rast.

Nadalje, može se predložiti konačna granica rasta, posebno ako se vremensko razdoblje proteže tijekom nekoliko desetljeća [4].

2.1.1.1 Klasifikacija trend krivulja

Različiti izgledi trend krivulja (slika 1) mogu se prikazati pomoću odnosa matematičkih veličina. U većini slučajeva, promet predstavlja zavisna varijabla ***Y***, vrijeme predstavlja nezavisna varijabla ***T*** često mjerena u godinama, a tri konstante ***a***, ***b*** i ***c*** (često se koristi naziv koeficijent) dobiju se procjenom vrijednosti iz raspoloživih povijesnih podataka [4]. U nastavku teksta priložene formule definiraju pojedinu trend krivulju:

1) linearna trend krivulja ima formulu koja glasi:

$$Y = a + b^T. \tag{1}$$

podrazumijeva konstantno godišnje povećanje koeficijenta ***b*** na razini prometa i smanjenje stopa rasta.

2) eksponencijalna trend krivulja sadrži formule koje glase:

$$Y = a * (1 + b)^T, \tag{2}$$

$$log\ Y = log\ a + T * log\ (1 + b). \tag{3}$$

ako je koeficijent ***b*** pozitivan i manji od jedan, podrazumijeva konstantan godišnji prirast prometa iskazan pomoću stope od 100***b***. Logaritmiranjem, eksponencijalni oblik prelazi u linearni oblik.

3) parabolična trend krivulja ima formulu koja glasi:

$$Y = a + b * T + c * T^2. \tag{4}$$

koja sadrži tri konstante i oblikuju krivulju koja pokriva različite oblike krivulja (konkavne ili konveksne). Za koeficijente veće od nule, krivulja rasta ima svojstvo da

apsolutna veličina u jedinici vremena ima linearan rast tijekom vremena, a stopa rasta ima pad tijekom vremena.

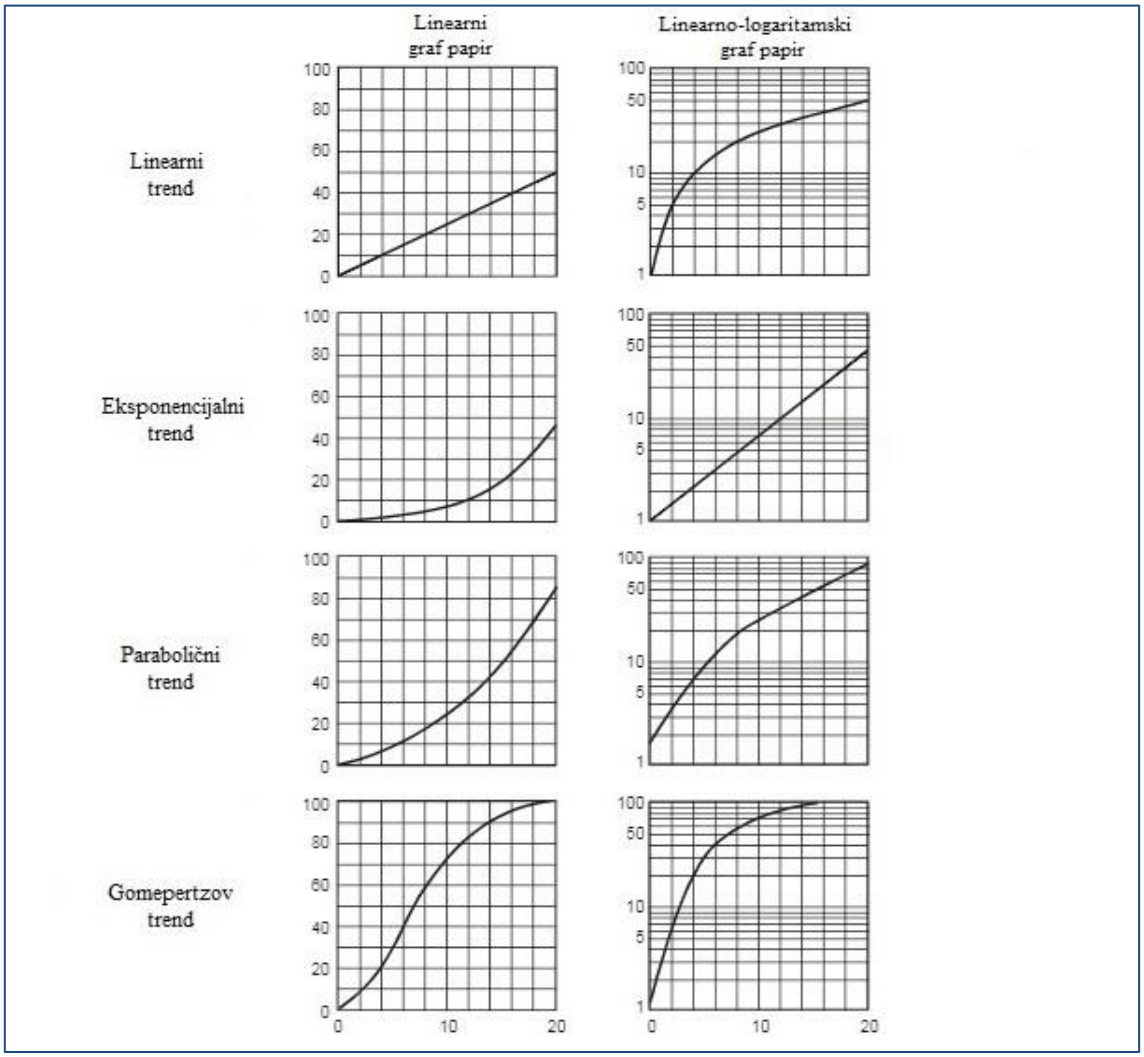
4) Gomepertzova trend krivulja sadrži formule koje glase:

$$Y = a * b^{-c^T}, \tag{5}$$

$$log\ Y = log\ a - c^T\ log\ b, \tag{6}$$

$$0 < c < 1. \tag{7}$$

i kada se ova krivulja približava razini zasićenja, može biti prikladna za pregled razvoja prometa u dugoročnom razdoblju [4].



Slika 1: *Shematski prikaz tipičnih trend krivulja [4] (prilagodio autor).*

2.1.1.2 Statistička procjena

Poteškoća koja se javlja pri grafičkoj ekstrapolaciji[7] je nepostojanje objektivnih kriterija za određivanje trend krivulje koja bi „najbolje odgovarala“ danim podacima. Ako je vizualni pregled prognostičara jedan od kriterija procjene, postoji velika vjerojatnost da će veliki broj prognostičara iznaći različite krivulje za isti set podataka. Objektivniji način određivanja trend krivulje je korištenje statističkih tehnika. Za svaku matematičku formulu (vidi poglavlje 2.1.1.1.) postoji skup konstanti (***a***, ***b*** i ***c***) koje omogućuju bolju prilagodbu jednadžbi za isti set podatka u odnosu na ostale skupove konstantnih vrijednosti [4].

Na primjer, ako se utvrdi da linearna jednadžba odgovara podacima vremenskih nizova, postupak jednostavne linearne regresije može se iskoristiti pri određivanju vrijednosti koeficijenata ***a*** i ***b*** koji najbolje odgovaraju tim podacima. Takav način procjene provodi se na temelju kriterija najmanjeg kvadrata koji zahtijeva da zbroj kvadrata bude prikladan uzorcima podataka te da vertikalno odstupanje od trend linije bude minimalno [4].

2.1.2. Metode dekompozicije vremenskih nizova

Metode dekompozicije vremenskih nizova razlučuju problem pomoću različitih komponenti. Osobito su relevantne kada u povijesnim podacima postoji velika sezonska ili ciklička komponenta. Metode se koristite pri identifikaciji tri temeljne komponente: trend, sezonska komponenta i ciklička komponenta ako postoji [4].

2.1.2.1 Jednostavno eksponencijalno izglađivanje

Metoda izglađivanja pokušava riješiti uzroke fluktuacija vremenskih nizova (trend, sezonska i ciklička komponenta). Dvije najčešće tehnike izglađivanja su pomični prosjeci i eksponencijalno izglađivanje. Eksponencijalno izglađivanje se općenito oslanja na filozofiju dekompozicije. Metoda stavlja veći naglasak na najnovije podatke, kako bi se povećala svoj utjecaj na prognozu. Pri tome je važno prepoznati sezonsku komponentu u podacima zračnih

[7] Podrazumijeva matematičko određivanje vrijednosti iz nekoga nepoznatog područja pomoću onih iz poznatoga, uz pretpostavku da zakonitosti utvrđene u poznatom vrijede i u nepoznatom području (interpolacija) [5].

prijevoznika, ako se uzimaju u obzir mjesečne ili kvartalne prognoze. Komponenta izglađivanja određuje koliko pondera je smješteno u različitom mjesecu ili godini [4].

2.1.2.2 Metoda eksponencijalnog izglađivanja s trendom i sezonalnošću (Holt-Winter)

Holt-Winterova metoda pripada skupini metoda eksponencijalnog izglađivanja koje imaju za cilj uhvatiti ponašanje vremenskih nizova podjelom na trend komponentu, sezonsku komponentu i komponentu prognostičke pogreške. Aditivna inačica Holt-Winterove metode može se definirati na sljedeći način:

$$l_t = \alpha * (y_t - s_{t-m}) + (1 - \alpha) * (l_{t-1} + b_{t-1}), \quad (8)$$

$$b_t = \beta * (l_t - l_{t-1}) + (1 - \beta) * b_{t-1}, \quad (9)$$

$$s_t = \gamma * (y_t - l_{t-1} - b_{t-1}) + (1 - \gamma) * s_{t-m}, \quad (10)$$

$$\hat{y}_{t+h} = l_t + hb_t + s_{t-m+h}. \quad (11)$$

Multiplikativna inačica Holt-Winterove metode može se definirati na sljedeći način:

$$l_t = \alpha * \left(\frac{y_t}{s_{t-m}}\right) + (1 - \alpha) * (l_{t-1} + b_{t-1}), \quad (12)$$

$$b_t = \beta * (l_t - l_{t-1}) + (1 - \beta) * b_{t-1}, \quad (13)$$

$$s_t = \gamma * \left(\frac{y_t}{l_{t-1} - b_{t-1}}\right) + (1 - \gamma) * s_{t-m}, \quad (14)$$

$$\hat{y}_{t+h} = (l_t + hb_t) * s_{t-m+h}. \quad (15)$$

gdje $\boldsymbol{l_t}$, $\boldsymbol{b_t}$, $\boldsymbol{s_t}$ predstavljaju komponente trenda i sezonalnosti u trenutku $\boldsymbol{t}$. $\boldsymbol{M}$ označava trenutak trajanja sezonalnosti, $\boldsymbol{h}$ označava vremensko razdoblje prognoze dok su $\boldsymbol{\alpha}$, $\boldsymbol{\beta}$ i $\boldsymbol{\gamma}$ konstante izglađivanja [6].

2.1.2.3 Metoda pomičnog prosjeka

Metoda pomičnog prosjeka slična je eksponencijalnom izglađivanju. Jedina razlika u pojmovima da je svako opažanje jednako ponderiranom. Na primjer, pomični prosjek od četiri opažanja bio bi [4]:

$$Y_{t+1} = \frac{Y_{t-3} + Y_{t-2} + Y_{t-1} + Y_t}{4}. \tag{16}$$

Zbog jednakih veličina pondera pomični prosjeci skloni su zaostatku za trenutnom situacijom u odnosu na eksponencijalno izglađivanje. Prednost pomičnih prosjeka u usporedbi s eksponencijalnim izglađivanjem je mnogo jednostavnija upotreba podataka. Nedostatak pomičnih prosjeka je da zahtijeva duži niz podataka za analizu. Prilikom izrade prognoze u kratkoročnom razdoblju mogu se koristiti metode pomičnog prosjeka kao i metode eksponencijalnog izglađivanja. Takav pristup može se ostvariti primjenom podataka koji će odstupati od standardne formule i dodjelom relativno većih pondera na najčešće promatrani niz podataka, pod uvjetom da postoji opravdanost za takvom primjenom [4].

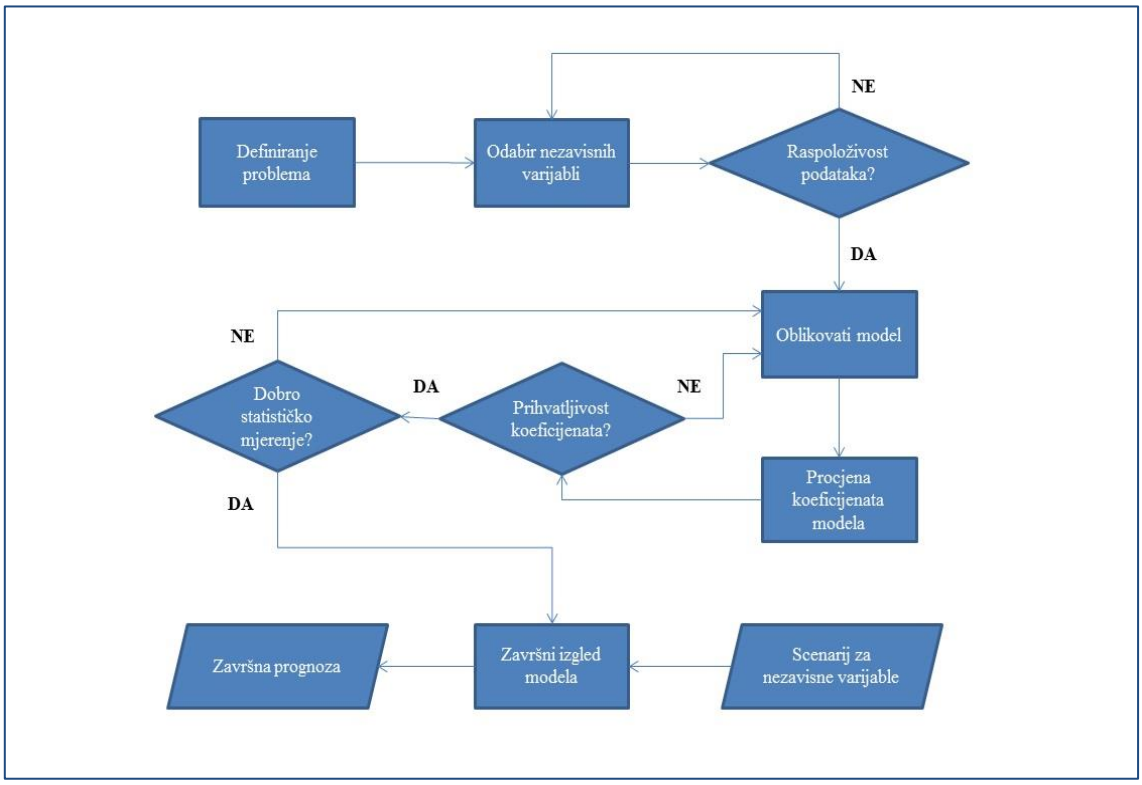
2.1.2.4 Auto regresivni model koji integrira pomični prosjek (ARIMA)

Svaki niz podataka može se upotrijebiti pomoću auto regresivnog modela koji integrira pomični prosjek (engl. *Auto Regressive Integrated Moving Average* – ARIMA), kolokvijalno poznato kao Box-Jenkins metoda koja je prikladna za prognoziranje isključivo u kratkoročnom razdoblju. Također, metoda je prikladna za obradu složenih podataka pomoću vremenskih nizova u kojima postoje različiti uzorci podataka, kao što su trend, sezonska i ciklička komponenta. Najčešće se koristi nedavna veličina podataka kao referentna vrijednost, a zatim se analizira nedavna prognostička pogreška, kako bi se razradila prilagodba komponenti u budućem vremenskom razdoblju. Metoda omogućuje veliku fleksibilnost, ali zahtijeva mnogo subjektivnosti. Na primjer, ako je prognoza za 10 % manja u odnosu na prethodno prognostičko razdoblje, prognoza u budućem razdoblju mogla bi se prilagoditi pogreškom u intervalu od 5 % do 7 % [4].

2.2. Ekonometrijska analiza

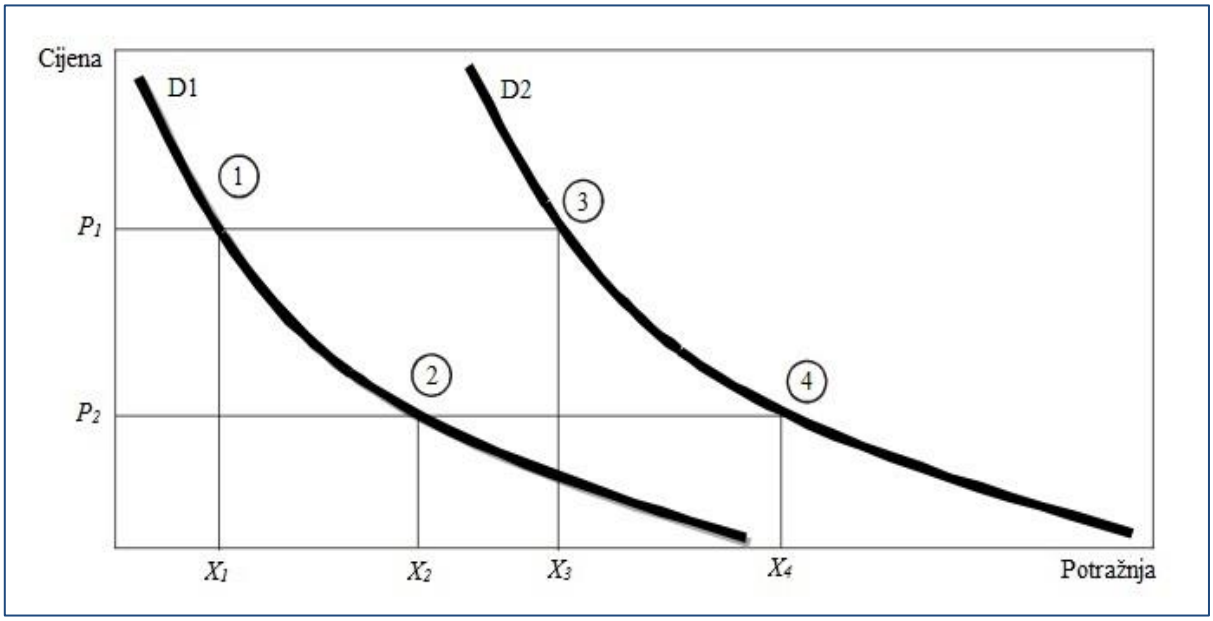
Glavni koraci izrade prognoze pomoću ekonometrijskog modela (slika 2) su:

1) definiranje problema;
2) odabir relevantnih uzročnih ili nezavisnih varijabli;
3) nakon odabira relevantnih varijabli, na temelju prosudbe ili prethodne analize, utvrđuje se raspoloživost podataka ili izbor zamjenskih ili zastupljenih varijabli, ako takvi podaci nisu dostupni;
4) kada se utvrdi raspoloživost podataka, oblikuje se model koji određuje vrstu funkcionalnog odnosa između zavisne varijable i odabranih nezavisnih (uzročnih) varijabli;
5) provedba analize, kako bi se testirao odnos koji se pretpostavlja, uključujući procjenu koeficijenata modela, njihove veličine i oznake te statističko mjerenje;
6) kada se postignu gore navedeni kriteriji, potrebno je utvrditi model u završnom obliku;
7) razvoj prognoza budućeg scenarija za nezavisne varijable iz kojih se kasnije izvodi prognoza prometa [4].



Slika 2: *Dijagram toka prilikom izrade ekonometrijskog modela [4] (prilagodio autor).*

Upotreba višestruke regresijske analize koja sadrži u sebi strukturu cijena i prihoda naziva se ekonometrijska analiza. Polazna točka za ekonometrijsku analizu je model regresijske jednadžbe koji postavlja uzročni odnos između zavisne varijable i jedne ili više nezavisnih varijabli. Ekonometrijski model pokušava objasniti potražnju za zračnim prometom (slika 3) koji je izazvan promjenama nezavisnih varijabli [4].



Slika 3: *Shematski prikaz krivulje potražnje [4] (prilagodio autor).*

Ako se dogodi pad cijene i poveća ekonomska aktivnost, potražnja se povećava od X_1 do X_4. Stoga, pomak od X_1 do X_4 objašnjava kombinirano povećanje potražnje od razdoblja (1) do razdoblja (2) uslijed smanjenja prosječnih cijena i povećanja gospodarske aktivnosti, kao i promjena u demografiji. Isto tako, rast cijena smanjit će potražnju, a pad gospodarske aktivnosti pomaknut će krivulju potražnje prema lijevo, a ne prema desno. Povećanje potražnje od X_1 do X_2 može se objasniti kao utjecaj cijena, a povećanje potražnje od X_2 do X_4 može se objasniti kao učinak prihoda. Veličina promjene duž krivulje potražnje je mjera elastičnosti cijena, dok je veličina pomaka krivulje mjera elastičnosti prihoda. Promjena duž krivulje potražnje od (1) do (2) posljedica je pada cijene (prosječna cijena), što ukazuje na rast potražnje od X_1 do X_2. Isto tako, pomak krivulje potražnje od (1) do (3) može se objasniti promjenom gospodarske aktivnosti koja ukazuje na porast potražnje od X_1 do X_3, pod uvjetom da je prosječna cijena ostala nepromijenjena. Promjena potražnje od X_1 do X_4 osigurava kombinirani učinak promjena prosječne cijene i gospodarske aktivnosti, a vjerojatno i ostalih demografskih čimbenika [4].

3. METODOLOGIJA PROGNOZIRANJA ATM-a U EUROPI

Europska organizacija za sigurnost zračne plovidbe (engl. *European Organisation for the Safety of Air Navigation* – EUROCONTROL[8]) koristi kvantitativne metode prognoziranja općeg zračnog prometa (engl. *General Air Traffic* – GAT[9]) na području Europe u određenom vremenskom razdoblju.

Statistike i prognoze neophodne su EUROCONTROL-u, njegovim članovima i dionicima zračnog prometa jer:

1) statistika dopušta mjerenje i razumijevanje onoga što se događa u industriji zračnog prometa;
2) kvantitativne prognoze omogućuju planiranje odgovora za buduću potražnju zračnog prometa [7].

Prilikom prognoziranja, koriste se visoko automatizirani i strukturirani procesi, ali zbog raznovrsnih čimbenika, koriste se različite metode prognoziranja kao što su:

1) **metoda vremenskih nizova** (engl. *time series methods*) za ekstrapolaciju uzoraka povijesnih podataka;
2) **ekonometrijske analize** (engl. *econometric analyses*) koje uzimaju u obzir kako ekonomski, društveni i operativni uvjeti utječu na razvoj prometa;
3) **scenariji temeljeni na ulaznim podacima** (engl. *scenario-based inputs*) koji služe za opisivanje budućeg razvoja odnosno, što će biti u Europi u narednih deset godina;
4) **specifični modeli temeljeni na podacima** (engl. *data-driven models*) prilikom razvoja modela željeznice velikih brzina. Metode se oslanjaju na povijesne podatke ili na praćenje najnovijih trendova [8].

[8] engl. *European Organisation for the Safety of Air Navigation* – Europska organizacija za sigurnost zračne plovidbe utemeljena Međunarodnom konvencijom o suradnji s ciljem postizanja sigurnosti zračne plovidbe od 13. prosinca 1960. godine [1].

[9] engl. *General Air Traffic* – Opći zračni promet su svi letovi civilnih zrakoplova, kao i letovi državnih zrakoplova koji se obavljaju sukladno postupcima ICAO-a [1].

3.1. Mrežni upravitelj (NM)

Mrežni upravitelj (engl. *Network Manager* – NM) pruža prognozu prometa i kašnjenja koje kasnije analizira u svrhu podrške globalnim performansama Europske zrakoplovne mreže usklađenim s „provedbenim pravilom“ Europske Komisije kako bi:

1) kontinuirano procjenjivao rad mrežnih funkcija i praćenje pan-mrežnih procesa, analizirao te izvještavao o svim aspektima operativnih učinaka mreže;
2) preporučio mjere i/ili poduzeo potrebne radnje osiguranja izvedbe mreže;
3) usporedio učinke s ciljevima utvrđenim u Mrežnom strateškom planu (engl. *Network Strategy Plan* – NSP[10]), Operativnom planu europske ATM mreže (engl. *Network Operational Plan* – NOP[11]) i Mrežnom izvedbenom planu (engl. *Network Performance Plan* – NPP[12]) koji identificira nedostatke i predlaže korektivne radnje [12].

Na takav način, NM osigurava konsolidirani i koordinirani pristup svim planiranim i operativnim aktivnostima mreže. Tri aktivnosti koje su integrirane u ovaj pristup i tijekom donošenja odluka iz NPP-a i NSP-a su:

1) STATFOR prognoze koje se koriste kao izravni ulazi u NSP, NOP, Mrežni i lokalni izvedbeni plan kojeg zahtijeva Provedbeno pravilo funkcije Mrežnog upravitelja (engl. *Network Manager Functions Implementing Rule* – NMF IR[13]). Ove prognoze prometa preduvjet su za uspostavu jediničnih cijena naplate prilikom izračuna rutnih i terminalnih naknada. Prognozu prometa

[10]Proces planiranja u kontekstu Jedinstvenog europskog neba (engl. *Single European Sky* – SES); ima za cilj „definirati vodeća načela mrežnih operacija i njihovu dugoročnu perspektivu“sa svrhom postizanja ciljeva mrežne učinkovitosti u svim državama članicama Europske Unije i trećim zemljama, pridonoseći pan-europskoj dimenziji SES-a [9].

[11]Omogućuje zajednički pogled na situaciju europske ATM mreže koja se dijeli sa cjelokupnom zrakoplovnom zajednicom. EUROCONTROL-ova provedba NOP-a putem NOP portala ukazuje na potrebu jedinstvene ulazne točke u kontekstu ATM operacija, okupljajući različite alate i informacijske usluge EUROCONTROL-a [10].

[12]Sadrži ciljeve izvedbe za sva relevantna ključna područja učinkovitosti (engl. *Key Performance Area* – KPA) i ključne indikatore učinkovitosti (engl. *Key Performance Indicator* – KPI) u skladu s ciljevima izvedbe na razini EU i šire za cijelo referentno razdoblje. Također, dodatno sadrži ključne indikatore učinkovitosti i ciljeve koji se smatraju nužnim za postizanje ciljeva NM-a u drugom referentnom razdoblju (engl. *Reference Period 2* – RP2) [11].

[13]Integrirana ATM aktivnost s ciljem osiguranja optimalnih mrežnih operacija i pružanje ATM usluga u skladu s mrežnim ciljevima izvedbe [13].

koriste zračni prijevoznici[14] (engl. *airlines*), pružatelji usluga u zračnoj plovidbi (engl. *Air Navigation Service Provider* – ANSP[15]), zračne luke[16] (engl. *airport*), vladine organizacije i mnogi drugi sa svrhom općeg planiranja;

2) Operativna analiza i izvještavanje (engl. *Operational Analysis and Reporting* – OAR) koristi godišnja izvješća NM-a koja opisuju provedbu NSP-a i NOP-a te izvedbu svih mrežnih aspekata u usporedbi s ciljevima izvedbe i planovima učinkovitosti. Objavljuje sveobuhvatan skup detaljnijih izvješća koja pokrivaju sve operacije, performanse i aspekte usklađenosti mreže;
3) Centralni ured za analizu kašnjenja (engl. *Central Office for Delay Analysis* – CODA) prati i izvještava performanse ATM mreže u kontekstu kašnjenja i usklađuje s propisima o upravljanju protokom zračnog prometa. Mrežni upravitelj osigurava funkciju praćenja i analize svih razloga kašnjenja (upravljanje protokom i kapacitetom zračnog prometa, zračni prijevoznici, zračne luke i drugi). Time se omogućava korelacija ostvarenog kašnjenja između zračnog prijevoznika i mreže te se koristi prilikom planiranja reda letenja[17] i vremena opsluživanja zrakoplova (engl. *turnaround time*) kako bi se ostvarila veća točnost [12].

[14]Poduzetnik koji posjeduje valjanu Operativnu licenciju ili jednakovrijedan dokument kojim je ovlašten za obavljanje komercijalnog zračnog prijevoza [1].
[15]Podrazumijeva svaki javni ili privatni subjekt koji pruža usluge u zračnoj plovidbi [1].
[16]Podrazumijeva aerodrom posebno prilagođen za usluge u zračnom prijevozu [1].
[17]Podrazumijeva utvrđeno vrijeme uzlijetanja i slijetanja zrakoplova u linijskom zračnom prijevozu [1].

3.2. Centralni ured za naplatu rutnih naknada (CRCO)

Korisnici zračnog prostora[18] (engl. *Airspace Users* – AU) koji lete u kontroliranom zračnom prostoru[19] država članica EUROCONTROL-a plaćaju operativne usluge u zračnom prometu (engl. *Air Traffic Services* – ATS[20]) koje koriste. Centralni ured za naplatu rutnih naknada (engl. *Central Route Charging Office* – CRCO[21]) naplaćuje korisnicima zračnog prostora svoje usluge u ime država članica. Izračunava rutne naknade za pružene usluge državama članicama, naplaćuje korisnicima zračnog prostora i distribuira rutne naknade dotičnim državama [14].

Pružatelji usluga u zračnoj plovidbi naplatu troškova naplaćuju korisnicima zračnog prostora tj. zračnim prijevoznicima, pomoću dva režima naplate:

1) naplata **rutnih usluga** zračnim prijevoznicima u zračnom prostoru u kojem se odvija *en-route* profil leta;
2) naplata **terminalnih usluga** zračnim prijevoznicima koji obavljaju odlazne i dolazne operacije na zračnu luku [3].

3.2.1. Naplata rutnih jedinica usluge

Rutna naplata je produkt tri glavna elementa:

1) faktor mase zrakoplova (engl. *weight factor*) $\boldsymbol{p}$ je kvadratni korijen količnika dobivenog dijeljenjem maksimalne propisane težine zrakoplova pri uzlijetanju (engl. *Maximum Take-Off Weight* – MTOW) sa zrakoplovom od 50 metričkih tona. Formula glasi:

$$p = \sqrt{\frac{MTOW}{50}} \tag{17}$$

[18]Podrazumijeva operatore zrakoplova koji lete u općem ili operativnom zračnom prometu [1].

[19]Podrazumijeva dio zračnog prostora u kojem djeluje služba kontrole zračnog prometa u skladu s ICAO klasifikacijom zračnog prostora [3].

[20]Podrazumijeva različite usluge uspostavljene u svrhu prosljeđivanja letnih informacija, uzbunjivanja, savjetodavne usluge u zračnom prometu, usluge kontrole zračnog prometa (aerodromske, prilazne i oblasne kontrole) [1].

[21]Države koje sudjeluju u multilateralnom sustavu rutnih naknada od 2014. godine pod nazivom CRCO14 koji uključuje popis država unutar CRCO11-a plus Gruzija [8].

2) faktor duljine leta *(engl. distance factor)* $\boldsymbol{d_i}$ podrazumijeva udaljenost u kilometrima (podijeljena sa 100) između aerodroma polijetanja unutar ili točke ulaska u zračni prostor države i aerodroma slijetanja ili izlaza iz tog zračnog prostora. Izuzeti vrijednost od 20 nautičkih milja[22] (engl. *Nautical Mile* – NM) za svako polijetanje i slijetanje unutar teritorija država članica;
3) cijena jedinične naknade (engl. *unit rate of charge*) $\boldsymbol{t_i}$ je tarifa za letenje na udaljenosti leta od 100 kilometara (faktor duljine leta na dvije decimale) za zrakoplov od 50 metričkih tona (faktor mase na dvije decimale) u naplatnoj zoni države. Jedinične naknade za naplatne zone država samo se godišnje revidiraju, a neke se prilagođavaju mjesečno kako bi uzele u obzir promjene u razmjeni naknada između nacionalne valute i eura [2].

Kada zrakoplov leti u zračnom prostoru CRCO naplatne zone (slika 4) pod nadležnošću EUROCONTROL-a, naplaćuje se jedinstvena naknada za rutnu zračnu plovidbu $\boldsymbol{R}$ koja je jednaka sumi produkata naknada $\boldsymbol{r_i}$ za pojedinačne naplatne zone $\boldsymbol{i}$ kroz koje je dotični zrakoplov letio. Formula glasi [3]:

$$R = \sum_n r_i \tag{18}$$

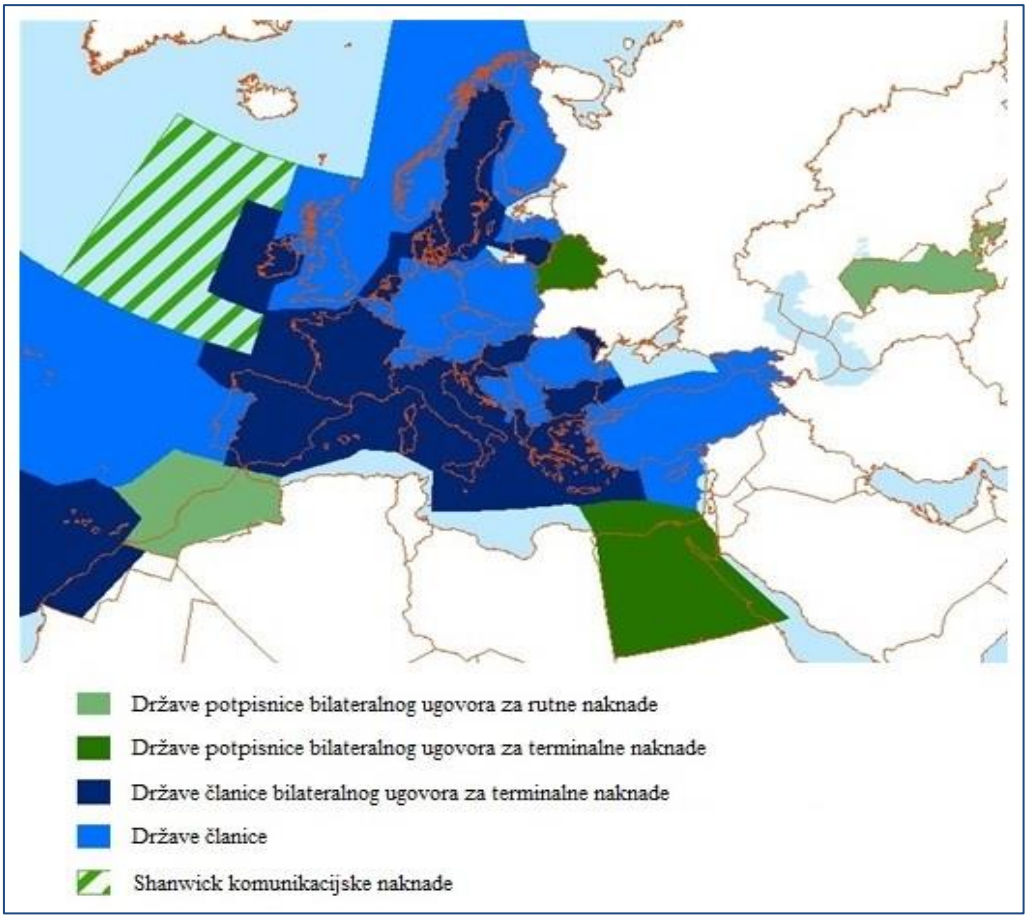
Naknada za svaku pojedinačnu naplatnu zonu $\boldsymbol{r_i}$ računa se kao produkt jedinične naknade $\boldsymbol{t_i}$ i broja jedinica usluge $\boldsymbol{s_i}$ koji odgovara danom letu u danoj naplatnoj zoni. Formula glasi [3]:

$$r_i = t_i * s_i \tag{19}$$

Broj jedinica usluge $\boldsymbol{s_i}$ računa se kao produkt faktora duljine leta $\boldsymbol{d_i}$ i faktora mase $\boldsymbol{p}$ za promatrani let. Formula glasi [3]:

$$s_i = d_i * p \tag{20}$$

[22]Podrazumijeva duljinu od točno 1.852 metara [15].



Slika 4: *Shematski prikaz CRCO naplatne zone [16] (prilagodio autor).*

3.2.2. Naplata terminalnih jedinica usluge

Za pružene usluge u završnim kontroliranim oblastima (engl. *Terminal Control Area* – TMA[23]) plaćaju naknade oni korisnici zračnog prostora koji koriste usluge prilazne kontrole zračnog prometa (engl. *Approach Control Service* – APP[24]) i aerodromske kontrole zračnog prometa (engl. *Aerodrome Control Service* – TWR[25]). Terminalna naknada izračunava se za svaki let koji je predmetom ICAO pravila i propisa u kontekstu GAT prometa, koji započinje IFR kretanjem zrakoplova s aerodroma ili određenog aerodroma koji se nalazi u djelokrugu područja letnih informacija (engl. *Flight Information Region* – FIR[26]) [3].

[23]Predstavlja zračni prostor u koji ulazi više zračnih putova te u kojem se nalazi jedna ili više zračnih luka. Oblik i veličinu završne kontrolirane oblasti određuju brojni parametri: broj zračnih luka smještenih u toj oblasti, broj zračnih putova koji ulaze u oblast, intenzitet prometa te broj i raspored radionavigacijskih sredstava [3].

[24]Pruža usluge kontrole zračnog prometa dolaznih i odlaznih letova s aerodroma.

[25]Pruža usluge kontrole zračnog prometa na aerodromima.

[26]Zračni prostor određenih dimenzija u kojem se pružaju usluge letnih informacija i obavlja uzbunjivanje [1].

Za izračun terminalnih naknada ***R***, koristi se formula koja glasi [3]:

$$R = t * N \tag{21}$$

gdje ***t*** predstavlja jediničnu cijenu naknade, a ***N*** predstavlja broj jedinica usluge (zaokruženo na dvije decimale) koja se definira kao kvocijent maksimalne propisane težine zrakoplova pri uzlijetanje (MTOW) i zrakoplova od 50 metričkih tona na potenciju 0,70.

$$R = t * \left(\frac{MTOW}{50}\right)^{0,70} \tag{22}$$

3.3. STATFOR

STATFOR ured u sklopu EUROCONTROL-a objavljuje prognoze zračnog prometa na području Europe, država ili regija koje sagledava na razini glavnih prometnih tokova (npr. transatlantski[27] prometni tok). Svrha izrade prognoze prometa je potpora pri planiranju i praćenju ATM sustava koji se specijalizirano bavi IFR kretanjima zrakoplova, a ne brojem putnika ili količinom tereta [4].

Uslugu statistike i prognoze raspravlja i pregledava STATFOR-ova korisnička skupina (engl. *STATFOR User Group* – SUG). Referentna svrha korisničke skupine je obuhvatiti metodološke i praktične aspekte statistike i prognoziranja, razmjena informacija i stajališta o sadašnjoj i budućoj situaciji u zračnom prometu te o aktivnostima u nacionalnim upravama i međunarodnim organizacijama. [7].

STATFOR prognoza opslužuje europsko ATM područje od 1970-ih do danas te je jedina prognoza zračnog prometa koja pokriva područje Europe [8].

Za potrebe statistike, prognoze i analize, STATFOR koristi tri različita izvora podataka o letu:

[27]Podrazumijeva prometni tok između parova zona (engl. *Origin-Destination Zones* – ODZ) koji počinje i završava na transatlantskom paru. Podjela na istočni i zapadni transatlantski tok [2].

1) iz državnih uprava Azerbajdžana, Bjelorusije, Estonije, Gruzije, Islanda, Latvije i Litve, sa svrhom popunjavanja geografskog područja koje obuhvaća STATFOR. Neobrađeni podaci prometa koji lete po pravilima uz pomoć instrumenata (engl. *Instrument Flight Rules* – IFR[28]), agregirani podaci[29] na različitim razinama ili statistika pružena od država, predmetom su obrade te se uključuju u završnu STATFOR prognozu. Tijekom vremena se države dodaju ili uklanjaju s popisa, ako se već nalaze unutar područja nadležnosti NM-a;
2) EUROCONTROL-ova Jedinica za upravljanje mrežom (engl. *Network Management Unit* – NMU) je zadužena za pružanje ATFM[30] usluga u zračnom prostoru europskih država koje su glavni izvori podataka o letu s kojima se služi STATFOR. Baza podataka NM-a odražava posljednje ispunjene planove leta[31] (engl. *flight plan*) podržane od integriranog sustava početne obrade plana leta (engl. *Integrated Initial Flight Plan Processing System* – IFPS[32]), ali tijekom vremena, postojeće rute na kojima se odvija let postaju raspoložive. Za promet koji koristi pravila za let s vidljivošću (engl. *Visual Flight Rules* – VFR[33]) nema obradu podataka, a za vojne GAT letove se obrađuju podaci;
3) Centralni ured za naplatu rutnih naknada u sklopu EUROCONTROL-a harmonizirano upravlja regionalnim sustavom naplate u zračnom prostor gdje se odvijaju preleti/krstarenja (engl. *En-route* – ENR) u ime država i ključan je izvor podataka za STATFOR. CRCO podaci o letu koriste se prilikom obračuna naplate zračnim prijevoznicima. Uključuju sve IFR letove i samo one VFR letove koji su predmetom naplate. CRCO podaci koriste se prilikom revizije pojedinih podataka o letu koje pruža NM [19].

[28]Podrazumijeva skup pravila koja reguliraju vođenje leta pod uvjetima za letenje uz pomoć instrumenata [17].
[29](lat. *aggregare* – pridružiti) skupiti, ujediniti, spojiti, nagomilati, nakupiti, udružiti odnosno podaci koji se sjedinjuju u jednu bazu podataka [5].
[30]*engl. Air Traffic Flow Management* – Upravljanje protokom zračnog prometa je funkcija uspostavljena u svrhu podrške odvijanja sigurnog, redovitog i ubrzanog protoka zračnog prometa uz maksimalno korištenje kapaciteta kontrole zračnog prometa i uz opseg prometa sukladan kapacitetima koje su objavili određeni pružatelji usluga kontrole zračnog prometa [1].
[31]Podrazumijeva skup određenih informacija o namjeravanom letu ili dijelu leta zrakoplova koje se podnose nadležnoj kontroli zračnog prometa [1].
[32]Dizajniran je u svrhu racionalizacije, procesiranja i isporuke IFR GAT plana leta u IFPS zoni. IFPS zona je područje pokriveno sustavima kontrole zračnog prometa na prostoru ECAC-a [3].
[33]Podrazumijeva skup pravila koja reguliraju vođenje leta pod uvjetima za letenje s vidljivošću [18].

3.3.1. Metodologija izrade kratkoročne prognoze (2017-2018)

Kratkoročna prognoza (engl. *Short-Term Forecast* – STF) prometa promatra vremensko razdoblje od dvije godine unaprijed te se integrira u srednjoročnu prognozu. Objavljuje se dvaput godišnje, u veljači i rujnu [20].

Kratkoročna prognoza prometa izrađuje se pomoću **metoda vremenskih nizova**. Koraci uključeni u izradu prognoze su:

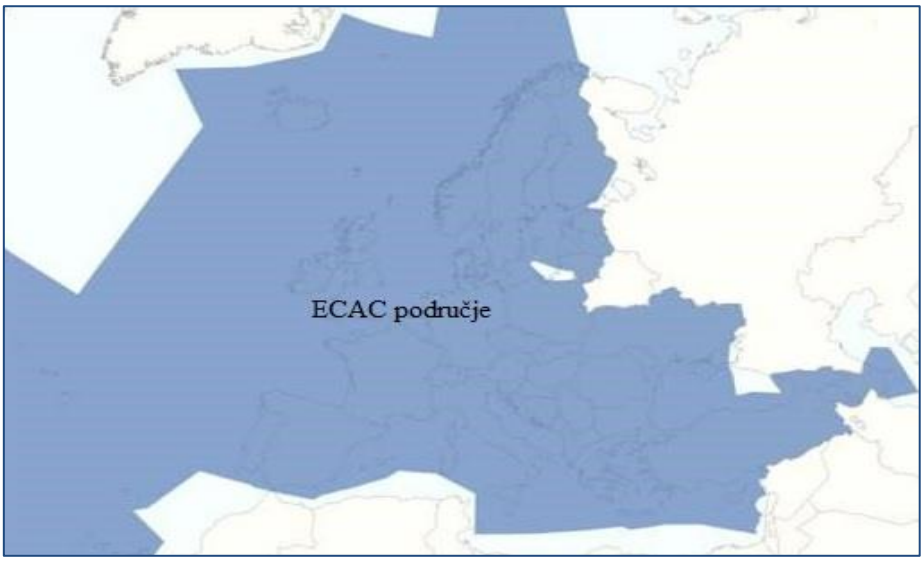
1) uzimanje prošlih vremenskih nizova za svaki mjesec. Obično su dostupni deset godina, a u nekim slučajevima dvije ili tri godine;
2) podesiti niz pogrešaka (npr. praćenje podataka) uzrokovano izvanrednim događajima (npr. kriza na Kosovu 1999. godine), duljina mjeseca, pomak praznika zbog Uskrsa i sl.;
3) upotreba niza podataka pomoću auto regresivnog modela koji integrira pomični prosjek (engl. *Auto Regressive Integrated Moving Average* – ARIMA) ili ako je potrebno, jednostavniji modeli (jednostavno eksponencijalno izglađivanje (engl. *simple exponential smoothing*) ili Holt-Winterova metoda);
4) odrediti intervale prognoza, izračunati točnost modela za svako razdoblje prognoziranja, ako se već koristio u prethodnim mjesecima;
5) nametnuti dosljednost unutar hijerarhije nizova (npr. prognoza ukupnog prometa treba biti jednaka prognozi domaćih letova, međunarodnih dolazaka i odlazaka te preletima) [4].

3.3.1.1 Prognoza IFR kretanja zrakoplova

U 2016. godini, na području Europe (ECAC[34]) (slika 5) ostvareno je 10,2 milijuna IFR kretanja zrakoplova, približno trenutnom stanju iz 2008. godine. Relativno visoka stopa rasta od 1,5 % posljedica je trenutnog stanja nedavnih trendova visokog rasta IFR kretanja

[34]engl. *European Civil Aviation Conference* – Europska konferencija civilnog zrakoplovstva je međuvladina organizacija osnovana od Međunarodne organizacije civilnog zrakoplovstva (engl. *International Civil Aviation Organisation* – ICAO) i Vijeća Europe. ECAC trenutno broji 44 države članice, uključujući sve države članice EU-28, 31 od 32 zemlje članice Europske agencije za sigurnost zračnog prometa (engl. *European Aviation Safety Agency* – EASA) osim Lihtenštajna i 41 državu članicu EUROCONTROL-a kao osnova za komparaciju prognoza na europskoj razini umjesto EUROCONTROL-ovog statističkog referentnog područja (engl. *EUROCONTROL Statistical Reference Area* – ESRA08) [8].

zrakoplova u sjeverozapadnoj regiji potaknut rastom tržišnog udjela niskotarifnih zračnih prijevoznika (engl. *Low Cost Carrier* – LCC[35]). Takvu tržišnu igru je potaknuo stalan rast tradicionalnih zračnih prijevoznika (engl. *Full Service Network Carrier* – FSNC[36]) započet još 2016. godine [8].

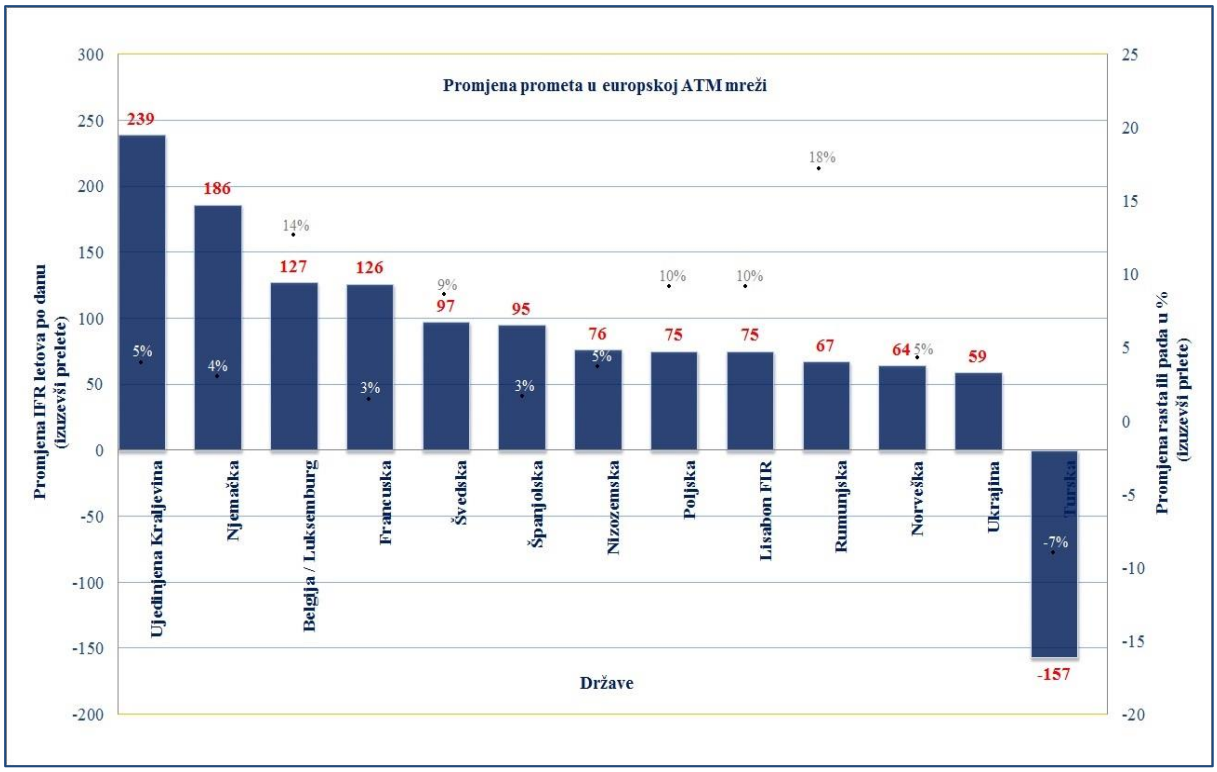


Slika 5: *Shematski prikaz ECAC područja [8] (prilagodio autor).*

U ožujku 2017. godine, prikazano je 12 država (grafikon 1) koje su najviše pridonijele rastu lokalnog prometa (izuzevši prelete) s dodatnih 50 letova u europskoj ATM mreži u odnosu na ožujak 2016. godine. Ujedinjena Kraljevina zadržava vodeću poziciju u dnevnom ostvarivanju IFR letova s dodatna 239 leta nakon kojeg slijedi Njemačka s ostvarenih 186 dnevnih letova. Na području Belgije i Luksemburga ostvareno je dodatnih 127 dnevnih letova i po prvi put se pridružuju vodećih tri, zahvaljujući robusnom protoku međunarodnih odlazaka i dolazaka koji je porastao za 15 %, a stopa rasta djelomično se povećala zbog privremenog zatvaranja zračne luke Bruxelless u ožujku 2016. godine. Francuska ostvaruje dodatnih 126 dnevnih letova zahvaljujući dinamičnom unutarnjem protoku. Švedska ostvaruje 97 dnevnih letova, a Španjolska 95 dodatnih dnevnih letova. Norveška se prvi put vratila na rast od srpnja 2014. godine i ostvaruje dodatna 64 dnevna leta na ATM mreži, prvenstveno zbog snažnog unutarnjeg protoka koji je porastao za 8 %. Nastavlja se smanjenje negativnog trend broja letova u Turskoj od ožujka 2016. godine te je zabilježeno dodatnih 157 dnevnih letova u ožujku 2017. godine [22].

[35]Podrazumijeva zrakoplovne kompanije s izrazito niskim tarifama i troškovima prijevoza [21].

[36]Podrazumijeva pružanje široke lepeze usluga prije i za vrijeme leta, uključujući različite klase usluga i transferne letove. Većina tradicionalnih zračnih prijevoznika operira po *hub-and-spoke* mrežnom transportnom modelu pokrivajući relativno široka geografska područja [21].



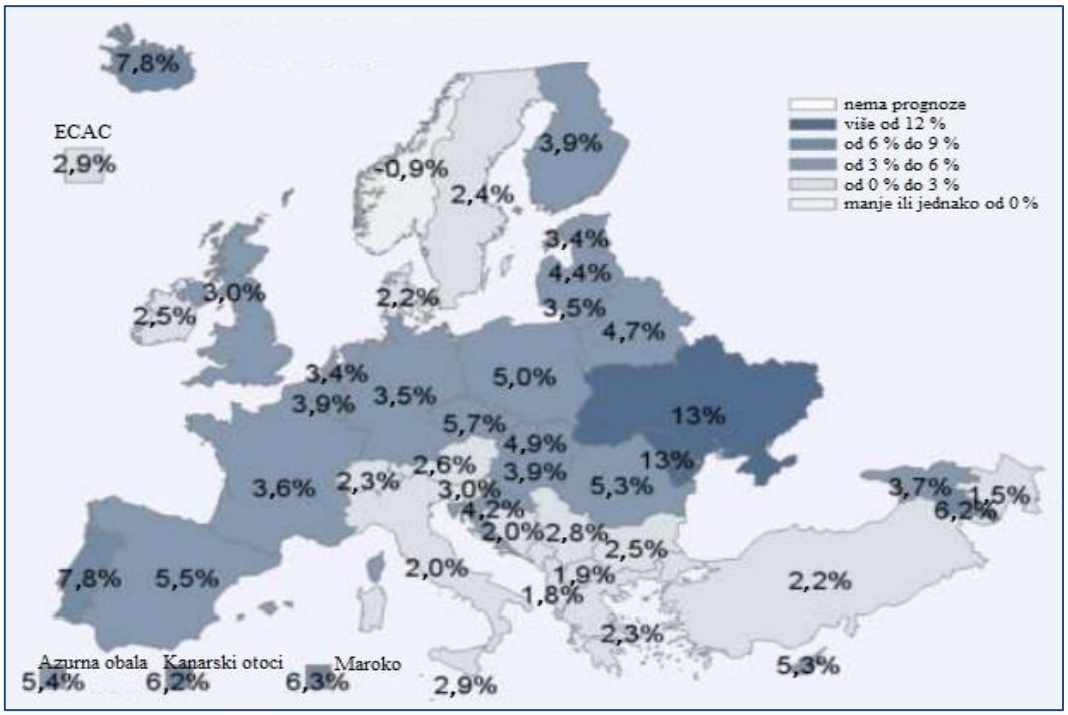
Grafikon 1. *Glavne promjene IFR kretanja zrakoplova u europskoj ATM mreži revidirane u ožujku 2017. godine [22] (prilagodio autor).*

Gledajući daljnji razvoj događaja Brexit-a[37], rezultata izbora SAD-a i nadolazećih izbora ove godine u Francuskoj, Njemačkoj i Nizozemskoj pri tome dodajući političku nesigurnost, jasno se ulazi u vrijeme velike političke nesigurnosti na gospodarskoj razini vjerujući da su te nesigurnosti obuhvaćene rasponom prognoziranja [8].

Strah od terorističkih napada još uvijek je prisutan u Egiptu, Tunisu i Turskoj koji preusmjeravaju turistički promet prema jugoistoku Europe. Očekuje se nastavak ubrzanog rasta prometa u 2017. godini na jugozapadu Europe tijekom prvih mjeseci 2017. godine, a tijekom ljeta učinak će opadati zbog preusmjeravanja glavnih prometnih tokova započetih još prije 12 mjeseci. Blokirani zračni prostor[38] (engl. *airspace blockage*) na istoku Ukrajine, prostoru Sirije i Libije još uvijek je na snazi te će nastaviti generirati neuobičajene prometne tokove na jugoistoku Europe [8]. Na sljedećim slikama 6 i 7 priložen je numerički prikaz IFR kretanja zrakoplova na području ECAC-a u razdoblju kratkoročne prognoze.

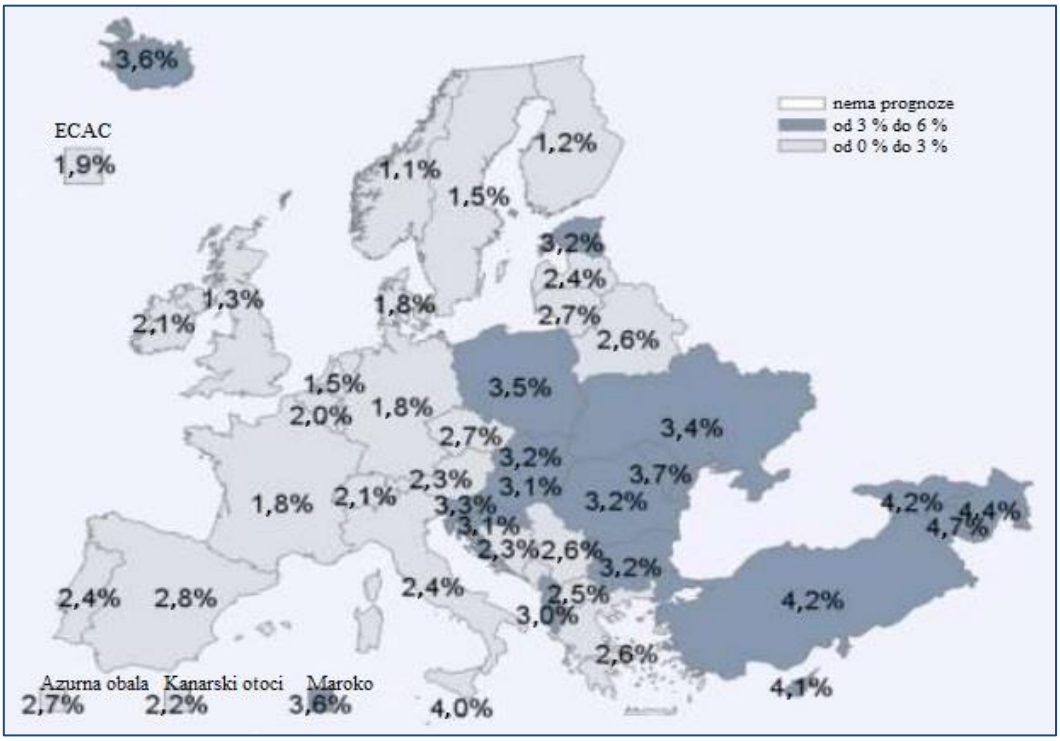
[37]Brexit je kratica za „britanski izlaz“ koji se odnosi na odluku građana Ujedinjenog Kraljevstva na referendumu 23. lipnja 2016. godine o napuštanju Europske unije [23].

[38]Podrazumijeva zračni prostor iznad određene države u koju zrakoplov iz druge države ne može ući bez rizika od napada [24].



Slika 6: *Shematski prikaz prognoze IFR kretanja zrakoplova po državama za 2017. godinu (osnovna referenca, s rasponom od + ili - 1,5 %) [8] (prilagodio autor).*

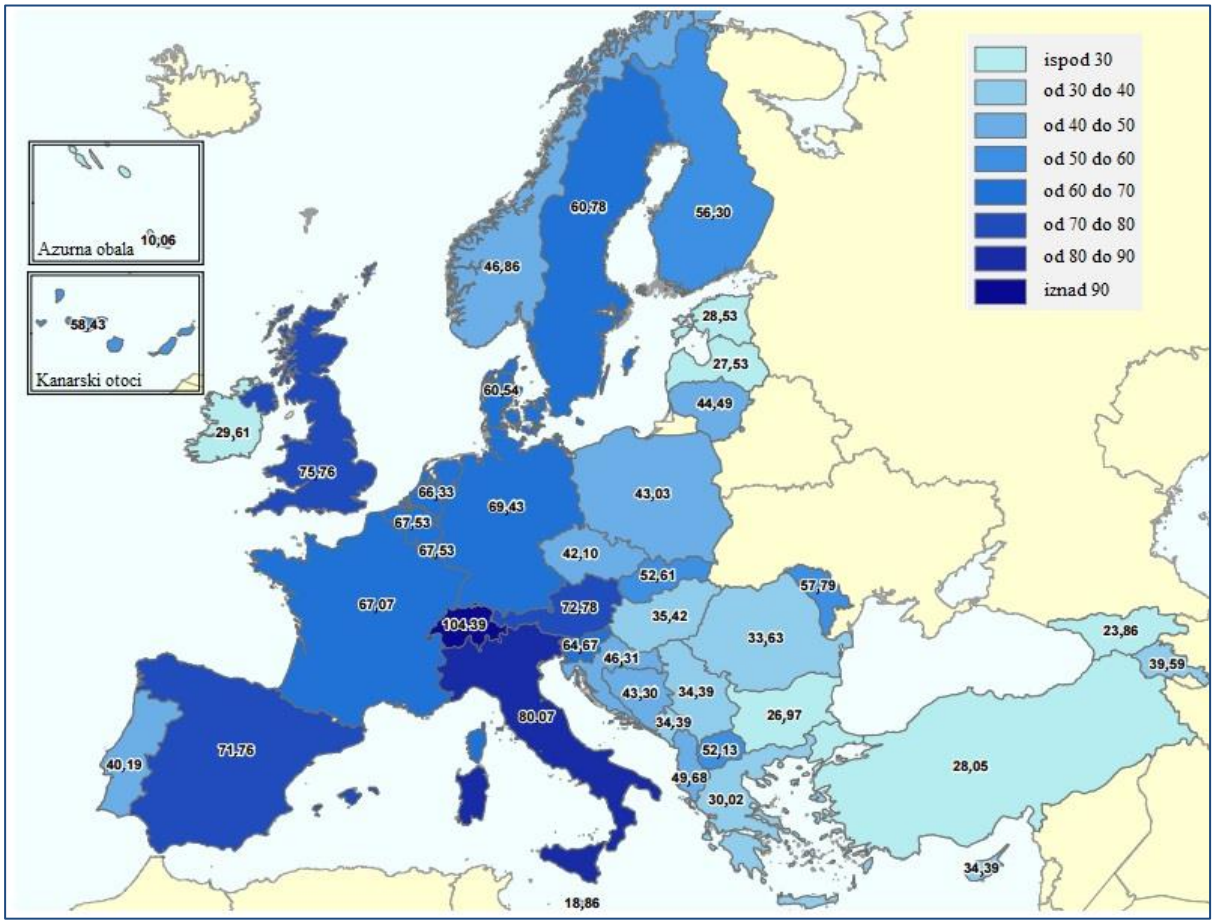
Rast IFR kretanja zrakoplova u 2017. godini očekuje rast od 2,9 % (+ ili - 1,4 %), što odgovara scenariju visokog rasta iz rujna 2016. godine. Za 2018. godinu, prognozira se rast od 1,9 % (+ ili - 1,3 %).



Slika 7: *Shematski prikaz prognoze IFR kretanja zrakoplova po državama za 2018. godinu (osnovna referenca, s rasponom od + ili - 1,5 %) [8] (prilagodio autor).*

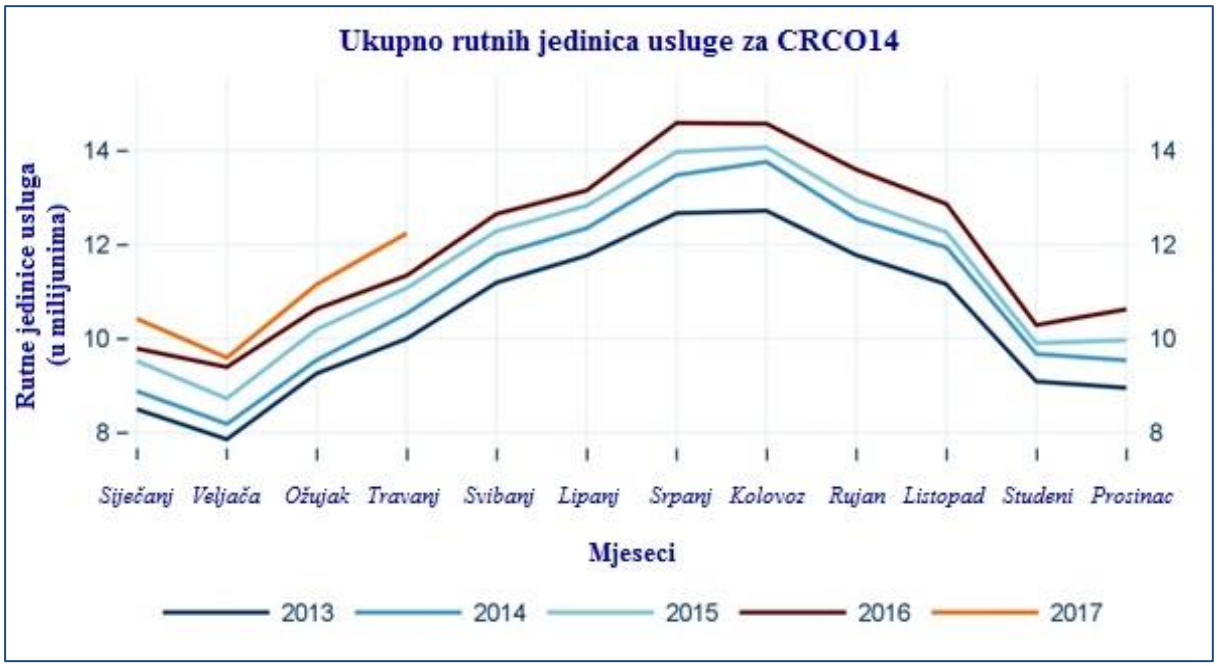
3.3.1.2 Prognoza rutnih jedinica usluge

Dugi niz godina, CRCO osigurava kratkoročnu prognozu ukupnog broja jedinica usluga (engl. *Total En-Route Service Units* – TSU) (tablica 1 i 2) svim dionicima ATM procesa. CRCO blisko surađuje sa STATFOR-om u cilju kvalitetnog razumijevanja prometnih trendova i komparacije s prognozom IFR kretanja zrakoplova. Danas, STATFOR preuzima vodeću ulogu i objavljuje kratkoročnu prognozu TSU-a (slika 8) za naplatna područja država koja su obuhvaćena Multilateralnim ugovorom [20]. Metodologija se prvenstveno temelji na analizi vremenskih nizova ili statističkim prognozama [25].



Slika 8: *Shematski prikaz područja Europe u kojom se primjenjuju jedinične naknade (engl. unit rates) rutnih jedinica usluge po svakoj državi članici CRCO naplatne zone u 2017. godini [26] (prilagodio autor).*

Od početka 2017. godine, odnosno od siječnja do travnja zabilježen je rast TSU-a od 5,5 % u CRCO14 naplatnoj zoni [27]. Mjesečna evolucija TSU-a od 2013. do 2017. godine za CRCO14 naplatnu zonu prikazana je na grafikonu 2.



Grafikon 2: *Mjesečna evolucija TSU-a (u milijunima) u 2013., 2014., 2015., 2016. i 2017. godini za CRCO14 zonu [27] (prilagodio autor).*

U 2017. godini, prognozira se rast TSU-a od 5 % (+ ili – 0,9 %) ako usporedimo s 2017. godinom, odnosno 150,6 milijuna rutnih jedinica usluga. Ako usporedimo prognozu za 2018. godinu s objavljenom prognozom iz veljače 2017. godine, stopa rasta iznosi 0,2 %, a ukupan TSU iznosi 154,9 milijuna jedinica usluge što predstavlja stopu rasta od 2,9 % (+ ili -1,4 %) [27].

Veliki rast IFR kretanja zrakoplova u zapadnoj Europi može se pripisati LCC prijevozu i stalnom rastu FSNC-a. Zabilježen je rast TSU-a u zapadnoj Europi (Velika Britanija, Španjolska, Njemačka, Francuska i Portugal) u razdoblju od siječnja do travnja 2017. godine. Ujedinjena Kraljevina zabilježila je rast TSU-a od 9,3 %, Španjolska, Njemačka, Francuska i Portugal zabilježili su rast TSU-a od 7,4 %, 5,7 %, 5,7 % i 10,6 % (u odnosu na isto razdoblje 2016. godine). Visoka stopa rasta u Velikoj Britaniji pripisuje se povećanju prosječne duljine leta na transatlantskim letovima tijekom veljače i ožujka. Ovakav tijek transatlantskih letova, s druge strane, negativno je utjecao na Irsku. Budući da su letovi povezani s meteorološkim utjecajima, neizvjesna je njihova evolucija na sjeveru [27].

Tablica 1: *Trenutno stanje, prognoza i odstupanje TSU-a na godišnjoj razini prema STATFOR-u i državama*

ICAO kod	Naplatno područje	STATFOR					Država	STATFOR vs. Država
		Trenutno stanje TSU-a [c]	Prognoza TSU-a	Odstupanje	Prognoza TSU-a	Odstupanje	Prognoza TSU-a	
	Država	2016	2017	2017 vs. 2016	2018	2018 vs. 2017	2017	2017
LA	Albanija	441.921	447.166	1,2%	460.968	3,1%	455.000	-1,7%
UD	Armenija	111.253	119.243	7,2%	121.015	1,5%	120.110	-0,7%
LO	Austrija	2.749.376	2.832.984	3,0%	2.903.388	2,5%	2.850.000	-0,6%
EB	Belgija i Luksemburg	2.499.815	2.582.557	3,3%	2.645.884	2,5%	2.580.000	0,1%
LQ	Bosna i Hercegovina	866.111	895.619	3,4%	915.643	2,2%	911.092	-1,7%
LB	Bugarska	3.412.444	3.508.788	2,8%	3.651.540	4,1%	3.439.000	2,0%
LC	Cipar	1.540.027	1.622.562	5,4%	1.684.276	3,8%	1.457.140	11,4%
LK	Češka	2.736.758	2.899.898	6,0%	2.978.625	2,7%	2.717.000	6,7%
EK	Danska	1.621.291	1.668.811	2,9%	1.709.083	2,4%	1.589.000	5,0%
EE	Estonija	834.306	843.851	1,1%	868.454	2,9%	827.117	2,0%
EF	Finska	763.909	815.773	6,8%	825.906	1,2%	827.000	-1,4%
LF	Francuska	19.881.540	20.721.725	4,2%	21.168.592	2,2%	19.300.000	7,4%
LG	Grčka	4.673.679	4.866.284	4,1%	5.027.326	3,3%	4.404.929	10,5%
UG	Gruzija	791.272	816.329	3,2%	847.133	3,8%	833.000	-2,0%
LD	Hrvatska	1.787.148	1.810.067	1,3%	1.870.350	3,3%	1.808.000	0,1%
EI	Irska	4.467.620	4.575.913	2,4%	4.664.236	1,9%	4.113.288	11,2%
LI	Italija	8.299.670	8.528.380	2,8%	8.725.977	2,3%	9.207.393	-7,4%
GC	Kanarski otoci	1.484.714	1.597.248	7,6%	1.637.489	2,5%	1.531.000	4,3%
EV	Latvija [c]	789.173	835.256	5,8%	848.342	1,6%	844.000	-1,0%
LP	Lisabon FIR	3.509.288	3.742.265	6,6%	3.843.755	2,7%	3.122.232	19,9%
EY	Litva	507.501	522.492	3,0%	537.777	2,9%	524.877	-0,5%
LH	Madarska	2.788.088	2.924.778	4,9%	2.997.454	2,5%	2.413.812	21,2%
LW	Makedonija	249.896	258.687	3,5%	264.177	2,1%	272,2	-5,0%
LM	Malta	903.789	902.432	-0,2%	930.307	3,1%	880.000	2,5%
LU	Moldavija	59.848	68.282	14,1%	70.421	3,1%	63,5	7,5%
EH	Nizozemska	3.099.831	3.247.332	4,8%	3.315.296	2,1%	2.845.616	14,1%
EN	Norveška	2.492.818	2.537.408	1,8%	2.597.273	2,4%	2.438.992	4,0%
ED	Njemačka [a]	13.560.219	14.217.510	4,8%	14.540.058	2,3%	13.122.000	8,3%
EP	Poljska	4.175.067	4.329.200	3,7%	4.463.399	3,1%	4.299.929	0,7%
LR	Rumunjska	4.442.828	4.598.009	3,5%	4.710.823	2,5%	4.219.063	9,0%
LZ	Slovačka	1.138.250	1.186.310	4,2%	1.222.984	3,1%	1.186.000	0,0%
LJ	Slovenija	501.673	513.936	2,4%	533.473	3,8%	514.217	-0,1%
LY	Srbija i Crna Gora - KFOR [b]	2.129.915	2.194.204	3,0%	2.257.644	2,9%	2.167.500	1,2%
AZ	Sveta Marija FIR	5.039.401	5.310.360	5,4%	5.467.566	3,0%	4.387.946	21,0%
LE	Španjolska	9.760.665	10.261.512	5,1%	10.548.927	2,8%	9.018.000	13,8%
ES	Švedska	3.402.102	3.484.196	2,4%	3.536.968	1,5%	3.341.000	4,3%
LS	Švicarska	1.492.882	1.525.105	2,2%	1.568.332	2,8%	1.490.591	2,3%
LT	Turska	14.370.242	15.138.265	5,3%	15.821.216	4,5%	14.974.104	1,1%
EG	Ujedinjena Kraljevina	10.874.603	11.301.068	3,9%	11.517.679	1,9%	10.583.000	6,8%
UK	Ukrajina [d]	1.016.864	1.131.871	11,3%	1.170.861	3,4%	.	.
	CRCO14	143.416.625	149.407.955	4,2%	153.431.301	2,7%	140.851.532	6,1%
	RP1 Regija [a]	118.403.924	123.193.584	4,0%	126.203.623	2,4%	115.686.197	6,5%
	RP2 Regija [a]	120.191.072	125.003.651	4,0%	128.073.972	2,5%	117.494.197	6,4%
	UKUPNO [d]	145.267.795	151.383.677	4,2%	155.470.616	2,7%	141.678.649	6,9%

(**a**) Za Njemačku, RP1 i RP2 regiju, rutne jedinice usluge uključuju segmente leta koji se obavljaju kao operativni zračni promet (engl. *Operational Air Traffic* – OAT[39]). Trenutno stanje za 2016. godinu iznosi 73.165 rutnih jedinica usluge. U narednim godinama očekuje se 75.000 rutnih jedinica usluge godišnje.

(**b**) Naplatna zona iznad Srbije i Crne Gore preimenovana je u Srbija i Crna Gora – KFOR[40] (nakon izmjene konvencije o imenovanju, vidi završne zapisnike 103. zasjedanja Proširenog odbora od 19. do 20. 11. 2014.).

(**c**) Jedino se Latvija pridružila državama članicama EUROCONTROL-a 2011. godine. Prije tog datuma, samo su godišnji podaci dostupni za TSU.

(**d**) Ukrajina nije dio CRCO-a, ali je zatražila od STATFOR-a da izrađuje pojedinačnu prognozu za nju jer nisu imali tu sposobnost u 2012 godini. U stupcu UKUPNO za prognozu po državama i postotna razlika između njih te prognoza STATFOR-a i država ne uračunavaju Ukrajinu u 2016. godini.

(**e**) Treba imati na umu da stvarni rezultati u 2016. godini možda ne odgovaraju službenim godišnjim podatcima CRCO-a jer ove brojke uzimaju u obzir napomenu Ryanair-a koja bi trebala biti uključena u podatke nakon travnja 2017. godine.

Izvor: *[8] (prilagodio autor).*

[39]Svi letovi koji nisu u skladu s odredbama utvrđenim za opći zračni promet te pravila i procedure koje su odredile odgovarajuće državne vlasti [28].

[40]engl. *Kosovo Force* – Kosovske snage [8].

Tablica 2: *Godišnja naplata rutnih jedinica usluge za naplatno područje država (2017-2018)*

ICAO kod	Naplatno područje	STATFOR			Izuzeta naplata TSU-a	Naplata TSU-a	Naplata TSU-a	
		Trenutno stanje TSU-a [c]	Prognoza TSU-a		Trenutno stanje TSU-a		Procjena	
	Država	2016	2017	2018	2016	2016	2017	2018
LA	Albanija	441.921	447.166	460.968	0,7%	99,3%	444.000	457.700
UD	Armenija	111.253	119.243	121.015	0,1%	99,9%	119.100	120.900
LO	Austrija	2.749.376	2.832.984	2.903.388	0,5%	99,5%	2.819.500	2.889.600
EB	Belgija i Luksemburg	2.499.815	2.582.557	2.645.884	0,7%	99,3%	2.564.900	2.627.800
LQ	Bosna i Hercegovina	866.111	895.619	915.643	0,1%	99,9%	894.600	914.600
LB	Bugarska	3.412.444	3.508.788	3.651.540	1,2%	98,8%	3.467.400	3.608.400
LC	Cipar	1.540.027	1.622.562	1.684.276	1,6%	98,4%	1.597.100	1.657.800
LK	Češka	2.736.758	2.899.898	2.978.625	1,8%	98,2%	2.846.400	2.923.700
EK	Danska	1.621.291	1.668.811	1.709.083	0,7%	99,3%	1.657.400	1.697.400
EE	Estonija	834.306	843.851	868.454	0,0%	100,0%	843.800	868.400
EF	Finska	763.909	815.773	825.906	0,3%	99,7%	813.400	823.500
LF	Francuska	19.881.540	20.721.725	21.168.592	1,0%	99,0%	20.524.800	20.967.500
LG	Grčka	4.673.679	4.866.284	5.027.326	2,1%	97,9%	4.762.00	4.919.600
UG	Gruzija	791.272	816.329	847.133	1,4%	98,6%	805.100	835.500
LD	Hrvatska	1.787.148	1.810.067	1.870.350	0,2%	99,8%	1.805.600	1.865.800
EI	Irska	4.467.620	4.575.913	4.664.236	1,2%	98,8%	4.521.900	4.609.200
LI	Italija	8.299.670	8.528.380	8.725.977	1,8%	98,2%	8.377.100	8.571.200
GC	Kanarski otoci	1.484.714	1.597.248	1.637.489	0,9%	99,1%	1.583.700	1.623.600
EV	Latvija	789.173	835.256	848.342	0,7%	99,3%	829.500	842.500
LP	Lisabon FIR	3.509.288	3.742.265	3.843.755	1,0%	99,0%	3.703.800	3.804.300
EY	Litva	507.501	522.492	537.777	0,6%	99,4%	519.500	534.700
LH	Mađarska	2.788.088	2.924.778	2.997.454	1,3%	98,7%	2.887.500	2.959.200
LW	Makedonija	249.896	258.687	264.177	0,1%	99,9%	258.500	264.000
LM	Malta	903.789	902.432	930.307	3,3%	96,7%	872.300	899.200
LU	Moldavija	59.848	68.282	70.421	0,1%	99,9%	68.200	70.300
EH	Nizozemska	3.099.831	3.247.332	3.315.296	1,3%	98,7%	3.206.100	3.273.200
EN	Norveška	2.492.818	2.537.408	2.597.273	0,9%	99,1%	2.515.300	2.574.700
ED	Njemačka [a]	13.560.219	14.217.510	14.540.058	1,0%	99,0%	14.077.700	14.397.100
EP	Poljska	4.175.067	4.329.200	4.463.399	0,6%	99,4%	4.301.700	4.435.000
LR	Rumunjska	4.442.828	4.598.009	4.710.823	1,3%	98,7%	4.539.900	4.651.300
LZ	Slovačka	1.138.250	1.186.310	1.222.984	1,5%	98,5%	1.168.300	1.204.500
LJ	Slovenija	501.673	513.936	533.473	0,3%	99,7%	512.200	531.700
LY	Srbija i Crna Gora - KFOR [b]	2.129.915	2.194.204	2.257.644	0,1%	99,9%	2.192.200	2.255.500
AZ	Sveta Marija FIR	5.039.401	5.310.360	5.467.566	2,0%	98,0%	5.204.500	5.358.500
LE	Španjolska	9.760.665	10.261.512	10.548.927	0,9%	99,1%	10.169.100	10.453.900
ES	Švedska	3.402.102	3.484.196	3.536.968	0,5%	99,5%	3.466.700	3.519.200
LS	Švicarska	1.492.882	1.525.105	1.568.332	0,3%	99,7%	1.521.200	1.564.300
LT	Turska	14.370.242	15.138.265	15.821.216	0,9%	99,1%	14.996.000	15.672.500
EG	Ujedinjena Kraljevina	10.874.603	11.301.068	11.517.679	1,5%	98,5%	11.131.800	11.345.200
UK	Ukrajina	1.016.864	1.131.871	1.170.861	0,5%	99,5%	1.125.800	1.164.600
	CRCO14	143.416.625	149.407.955	153.431.301	1.1%	98,9%	147.746.200	151.724.800
	RP1 Regija [a]	118.403.924	123.193.584	126.203.623	1.1%	98,9%	121.801.600	124.777.600
	RP2 Regija [a]	120.191.072	125.003.651	128.073.972	1.1%	98,9%	123.607.600	126.643.700
	UKUPNO	145.267.795	151.383.677	155.470.616	1.1%	98,9%	149.715.700	153.757.600

(**a**) Za Njemačku, RP1 i RP2 regiju, rutne jedinice usluge uključuju segmente leta koji se obavljaju kao OAT. Trenutno stanje za 2016. godinu iznosi 73.165 rutnih jedinica usluge. U narednim godinama očekuje se 75.000 rutnih jedinica usluge godišnje.

(**b**) Naplatna zona iznad Srbije i Crne Gore preimenovana je u Srbija i Crna Gora – KFOR (nakon izmjene konvencije o imenovanju, vidi završne zapisnike 103. zasjedanja Proširenog odbora od 19. do 20. 11. 2014.).

(**c**) Treba imati na umu da stvarni rezultati u 2016. godini možda ne odgovaraju službenim godišnjim podatcima CRCO-a jer ove brojke uzimaju u obzir napomenu Ryanair-a koja bi trebala biti uključena u podatke nakon travnja 2017. godine.

Izvor: *[8] (prilagodio autor).*

U istočnoj Europi, na rast TSU-a utjecale su sljedeće promjene:

1) promjena u tokovima letova iz zapadne Europe prema Grčkoj, Cipru i Izraelu i manjoj mjeri prema Srednjem istoku, letjeli su više preko južnih ruta (iznad Slovenije, Bosne i Hercegovine, Srbije i Crne Gore – KFOR i Makedonije), ako se usporedi s istim razdobljem prošle godine. To bi moglo biti rezultat implementacije slobodnog odabira putanje leta zrakoplova (engl. *Free Route Airspace* – FRA[41]) u Jugoistočnoj regiji na kraju 2016. godine. Rast TSU-a za Sloveniju, Bosnu i Hercegovinu, Srbiju i Makedoniju bio je 8,4 %, 14,5 % 7,5 % i 24,4 % od početka godine (u odnosu na isto razdoblje 2016. godine);
2) treba imati na umu da je rast navedenih država jugoistočne Europe bio pozitivan zbog utjecaja ponovnog povratka prometa prema Egiptu i od njega. Povećanje broja letova između Ukrajine i Egipta imao je pozitivan utjecaj na rast Cipra kao i na sve države centralne Europe za dvosmjerne letove i TSU. Osim toga, oporavak prometa između Europe i Ruske Federacije (oko 10 % rasta letova u 2016. godini) pozitivno je utjecalo na rast TSU-a zemalja Istočne Europe (npr. Moldavija sa 11,3 % i Ukrajina sa 21,1 %);
3) zabilježen rast TSU-a u Armeniji od početka 2017. godine iznosi 59,1 %, a posebno za travanj 2017. godine od 182,5 % u odnosu na travanj 2016. godine. Kao objašnjenje je snažan porast broja letova prema Srednjem Istoku i povrat prometa prema Ruskoj Federaciji i od nje. Što se tiče rasta u travnju, kao odgovor na učinak ogromnog pada preleta iznad Armenije u travnju 2016. godine je gubitak tokova između Srednjeg Istoka i Ruske Federacije, kao i rerutiranje ruta koje su zračni prijevoznici na Srednjem Istoku preusmjerili iznad Azerbajdžana;
4) broj preleta iznad Malte i dalje je nizak zbog zatvorenog libijskog zračnog prostora te bilježi smanjenje TSU-a od 2,3 % od početka godine, kao jedino smanjenje TSU-a u državama CRCO14 naplatne zone [27].

[41]Podrazumijeva određeni zračni prostor unutar kojeg korisnici zračnog prostora slobodno planiraju svoje rute između ulaznih i izlaznih točaka, bez oslanjanja na ATS mrežu ruta (engl. *ATS Route Network* – ARN). U ovom zračnom prostoru, letovi podliježu kontroli zračnog prometa [29].

3.3.1.3 Prognoza terminalnih jedinica usluge

Glavna promjena u prognozi terminalnih jedinica usluga (engl. *Terminal Navigation Service Units* – TNSU) koja se odnosi na terminalnu naplatnu zonu (engl. *Terminal Charging Zone* – TCZ[42]) u RP2 regiji[43] je podjela poljskog TCZ-a (EP_TCZ) i francuskog TCZ-a (LF_TCZ) na dva odvojena dijela kako bi se omogućilo praćenje prognoza glavnih zračnih luka u odnosu na ostale zračne luke unutar iste države [8]. Popis država i pripadajuće terminalne naplatne zone za jedan ili više aerodroma u Programu mjerenja učinkovitosti za RP2 regiju je priloženo u tablici 3.

Tablica 3: *Popis država i pripadajuće terminalne naplatne zone za jedan ili više aerodroma u RP2 regiji*

Država	ICAO kod države za terminalnu naplatnu zonu	ICAO kod aerodroma	Država	ICAO kod države za terminalnu naplatnu zonu	ICAO kod aerodroma	Država	ICAO kod države za terminalnu naplatnu zonu	ICAO kod aerodroma
Austrija	LO_TCZ	LOWG	Francuska	LF_TCZ_2	LFOB	Njemačka	ED_TCZ	EDDM
		LOWI			LFOH			EDDN
		LOWK			LFOK			EDDP
		LOWL			LFOT			EDDR
		LOWS			LFPB			EDDS
		LOWW			LFPN			EDDT
Belgija	EB TCZ EBAW	EBAW			LFQQ			EDDV
	EB TCZ EBBR	EBBR			LFRB			EDDW
	EB TCZ EBCI	EBCI			LFRD		EP TCZ EPWA	EPWA
	EB TCZ EBLG	EBLG			LFRG			EPBY
	EB TCZ EBOS	EBOS			LFRH			EPGD
Bugarska	LB TCZ	LBSF			LFRK			EPKK
Cipar	LC_TCZ	LCLK			LFRN			EPKT
		LCPH			LFRO			EPLB
Češka	LK_TCZ	LKKV			LFRQ			EPLL
		LKMT			LFRS	Poljska	EP TCZ OTHR	EPMO
		LKPR			LFRZ			EPPO
		LKTB			LFSB			EPRA
Danska	EK TCZ	EKCH			LFSD			EPRZ
Estonija	EE_TCZ	EETN			LFSL			EPSC
		EETU			LFST			EPSY
Finska	EF TCZ	EFHK			LFTH			EPWR
	LF_TCZ_1	LFPG			LFTW			EPZG
		LFPO	Grčka	LG_TCZ	LGAV	Portugal	LP_TCZ	LPAZ
		LFAQ	Hrvatska	LD_TCZ	LDZA			LPFL
		LFBA			LDZL			LPFR
		LFBD	Irska	EI_TCZ	EICK			LPHR
		LFBE			EIDW			LPMA
		LFBH			EINN			LPPD
		LFBI	Italija	LI TCZ 1	LIRF			LPPR
		LFBL		LI_TCZ_2	LIMC			LPPS
		LFBO			LIME			LPPT
		LFBP			LIML	Rumunjska	LR_TCZ	LRBS
		LFBT			LIPZ			LROP
		LFBZ	Latvija	EV_TCZ	EVLA	Slovačka	LZ TCZ	LZIB
		LFCR			EVRA	Slovenija	LJ_TCZ	LJLJ
		LFGJ			EVVA			LJMB
		LFJL	Litva	EY_TCZ	EYKA			LJPZ
		LFJR			EYPA	Španjolska	LE_TCZ	GCLP
		LFKB			EYSA			LEBL
		LFKC			EYVI			LEMD
		LFKF	Luksemburg	EL TCZ	ELLX			LEMG
Francuska	LF TCZ 2	LFKJ	Mađarska	LH TCZ	LHBP			LEPA
		LFLB	Malta	LM TCZ	LMML	Švedska	ES TCZ A	ESSA
		LFLC	Nizozemska	EH_TCZ	EHAM	Švicarska	LS_TCZ	LSGG
		LFLL			EHBK			LSZH
		LFLP			EHGG	Ujedinjena Kraljevina	EG_TCZ_B	EGBB
		LFLS			EHRD			EGCC
		LFLX	Norveška	EN_TCZ	ENBR			EGGW
		LFLY			ENGM			EGKK
		LFMD			ENVA			EGLC
		LFMH			ENZV			EGLL
		LFMI	Njemačka	ED_TCZ	EDDB			EGPF
		LFMK			EDDC			EGPH
		LFML			EDDE			EGSS
		LFMN			EDDF		EG_TCZ_C	EGGW
		LFMP			EDDG			EGKK
		LFMT			EDDH			EGLC
		LFMU			EDDK			EGLL
		LFMV			EDDL			EGSS

Izvor: *[8] (prilagodio autor).*

[42]Zračna luka ili grupa zračnih luka za koje se uspostavlja cijena jedinične naknade [8].

[43]SES-RP2 regija obuhvaća 30 država koje uključuju postavljene ciljeve učinkovitosti na području EU-a za drugo referentno razdoblje tj. 28 država članica EU-a plus Norveška i Švicarska. SES-RP2 uključuje Kanarske otoke, ali Azurnu obalu ne. SES-RP2 područje zove se još i RP2 regija [8]

3.3.2. Metodologija izrade srednjoročne prognoze (2017-2023)

Srednjoročna prognoza (*Medium-Term Forecast* – MTF) prometa promatra vremensko razdoblje od sedam godina i zasniva se na kratkoročnoj prognozi. Srednjoročna prognoza kombinira statistiku IFR kretanja zrakoplova s gospodarskim rastom i modelima važnih čimbenika u industriji zračnog prometa kao što su: troškovi, kapacitet zračnih luka[44], putnici, faktori popunjenosti, veličina zrakoplova i slično. MTF daje sveobuhvatnu sliku očekivanog razvoja zračnog prometa na području Europe uporabom scenarija visokog i niskog rasta, s najvjerojatnijom osnovnom referencom prometa. Srednjoročna prognoza objavljuje se dvaput godišnje, u veljači i rujnu [20].

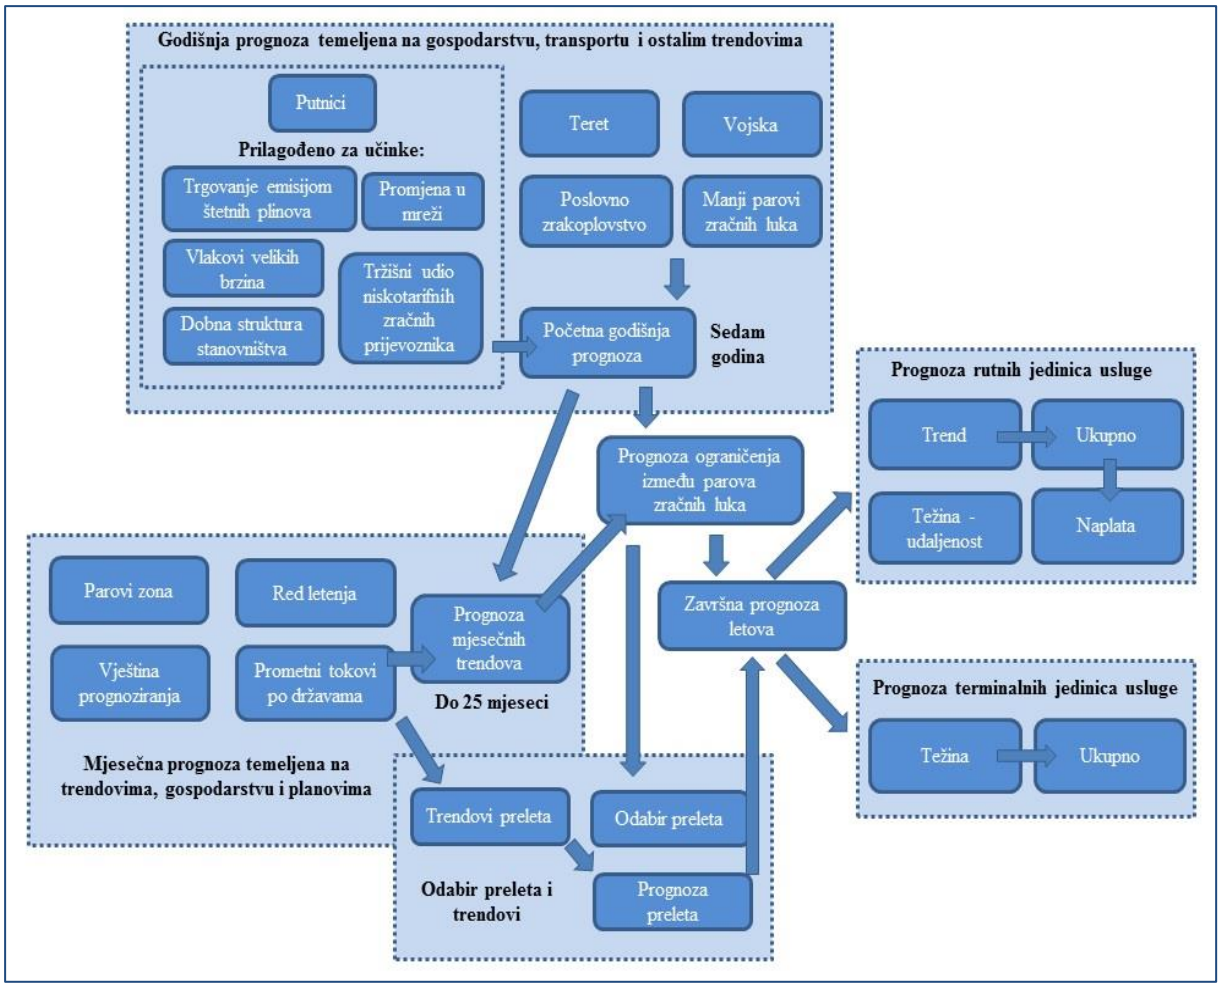
Srednjoročna prognoza u svojoj srži ima prognozu prometa između parova zračnih luka za svaki scenarij te pruža dosljedan temelj za niz različitih prognoza:

1) obujam prometa na ODZ paru uz pretpostavku trenutnog stanja rutiranja;
2) obujam prometa na ODZ paru uz pretpostavku najkraće rute na mreži ruta;
3) sati naleta[45] (engl. *flight hour*) po centrima oblasne kontrole zračnog prometa (engl. *Area Control Service* – ACC[46]) [4].

Ukupno gledajući, prognostičke komponente se grupiraju na pet elemenata (slika 9):

1) **godišnja prognoza** za narednih sedam godina koja se temelji na gospodarskim, transportnim i drugim trendovima;
2) **mjesečna prognoza** koja se temelji na trendovima, gospodarstvu i planovima zračnih prijevoznika;
3) **ograničenja kapaciteta zračnih luka**;
4) **IFR kretanja zrakoplova** u državama za dvosmjerno rutiranje kroz zračni prostor dobiven na temelju povijesnih podataka i najnovijih trendova;
5) **broj jedinca usluge** u naplatnoj zoni ovisi o broju IFR kretanja zrakoplova, masi zrakoplova ili u slučaju rute, duljini leta. Obje prognoze jedinica usluge uzimaju prognozu IFR kretanja zrakoplova kao ulazni podatak i kombinira se s prognozom vremenskih nizova težine i udaljenosti [8].

[44]Maksimalan broj IFR operacija koje je moguće opslužiti u jedinici vremena na određenoj zračnoj luci [2].
[45]Podrazumijeva sate naleta u fazi krstarenja plus odlazne i dolazne IFR operacije u zračnoj luci koje su opterećene faktorom terminalnih i rutnih troškova [30].
[46]Pruža usluge kontrole zračnog prometa preletima u kontroliranom zračnom prostoru.



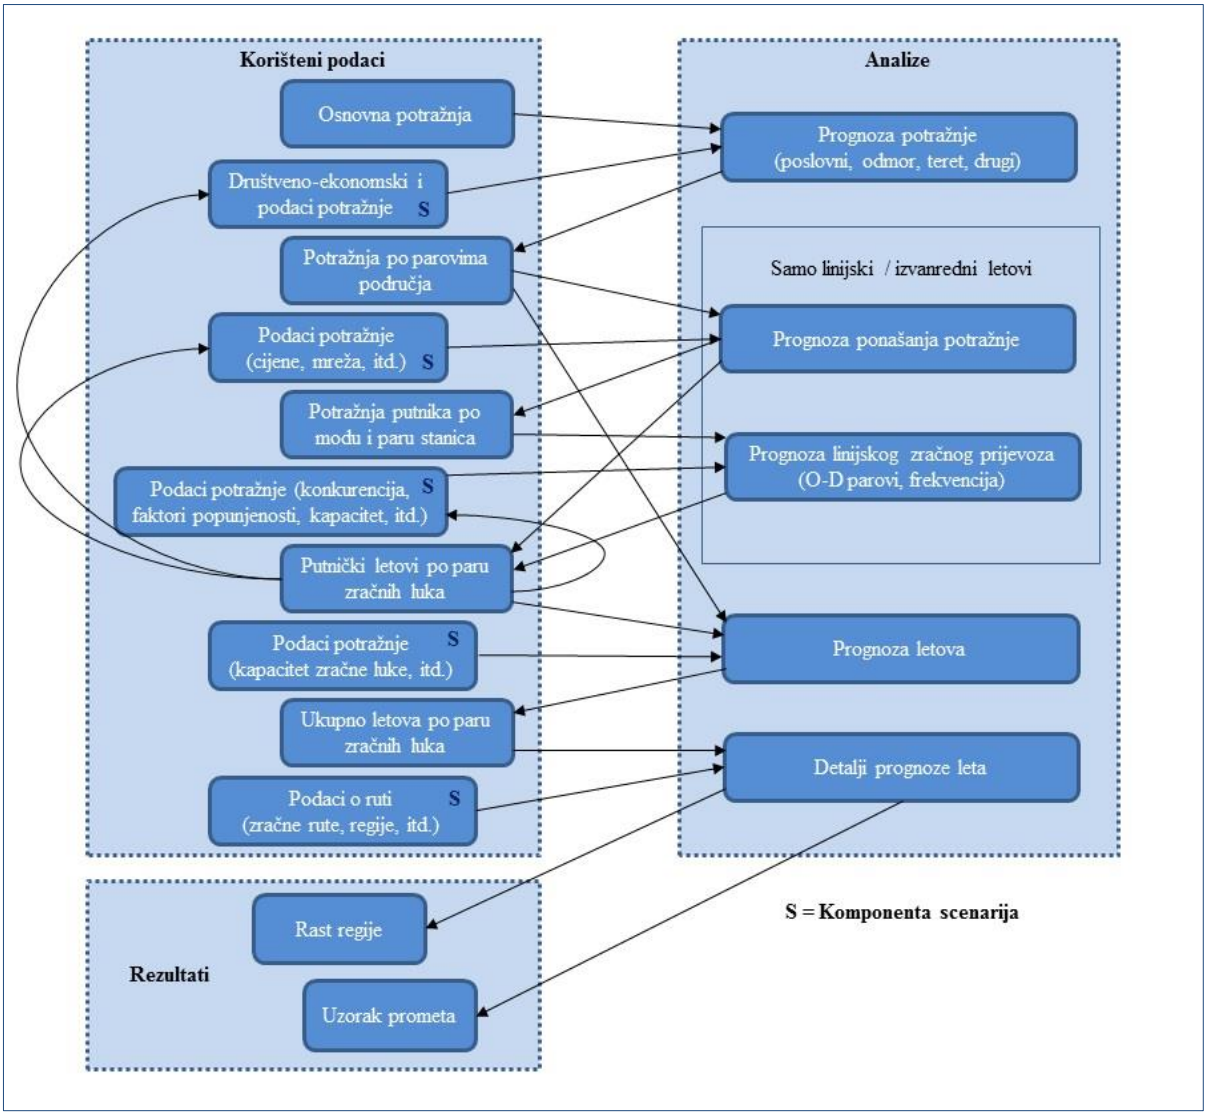
Slika 9: *Komponente koje STATFOR uzima pri izradi sedmogodišnje prognoze prometa [8] (prilagodio autor).*

Pet procesa koja se koriste pri izradi MTF-a (slika 10) su:

1) **prognoza potražnje** – osnovna referenca potražnje je let između parova područja (jedno ili više područja po državi, jedna ili više zračnih luka po području). Za putničke letove, pretvara se broj putnika u nekoliko kategorija. Upotrebom društveno-ekonomskih podataka i podataka o potražnji osigurava se buduća potražnja (broj putnika ili broj letova, ovisno o vrsti leta);
2) **prognoza ponašanja potražnje** – za putničke letove, pretvara putničku potražnju prema modu transporta i odabiru parova stanica[47] uzimajući u obzir dostupne veze između parova stanica i ostalih čimbenika (npr. trošak);
3) **prognoza linijskog zračnog prijevoza**[48] – upotreba putničke potražnje i drugih informacija, kao što su informacije o kapacitetu zračne luke i flote, poboljšava strukturu veza između parova stanica (i strukture flote);

[47]Stanica podrazumijeva zračnu luku ili željezničku stanicu za vlakove velikih brzina [4].

4) **prognoza letova** – kombinira putničke letove i druge prognoze IFR kretanja zrakoplova u svrhu izrade završne prognoze parova zračnih luka;
5) **detalji prognoze letova** – upotrebom određene mreže ruta i pravila rutiranja (npr. najkraća ruta) pretvara se u prognozu parova zračnih luka za određeni set podataka. Mjeri se utjecaj IFR kretanja zrakoplova (domaći letovi, međunarodni dolasci i odlasci te preleti) za svaku regiju koja je predmetom izvještavanja [4].



Slika 10: *Shematski prikaz korištenih podataka, komponenti analize i njihovih rezultata u srednjoročnom razdoblju prognoze [4] (prilagodio autor).*

[48] *engl. Scheduled air service* – Linijski zračni prijevoz podrazumijeva serije letova koje imaju sljedeće karakteristike: a) na svakom letu sjedala i/ili kapacitet za prijevoz tereta i/ili pošte dostupni su javnosti za individualnu nabavu (bilo izravno od zračnog prijevoznika ili od njegovih ovlaštenih zastupnika; b) obavlja se za prometovanje između istih dviju ili više zračnih luka, bilo: prema objavljenom redu letenja ili letovima koji su toliko redoviti ili česti tako da predstavljaju prepoznatljivo sistematične serije [1].

3.3.2.1 Godišnja prognoza prometa

Ulazni podaci koji se koriste pri izradi početne godišnje prognoze (slika 11) su:

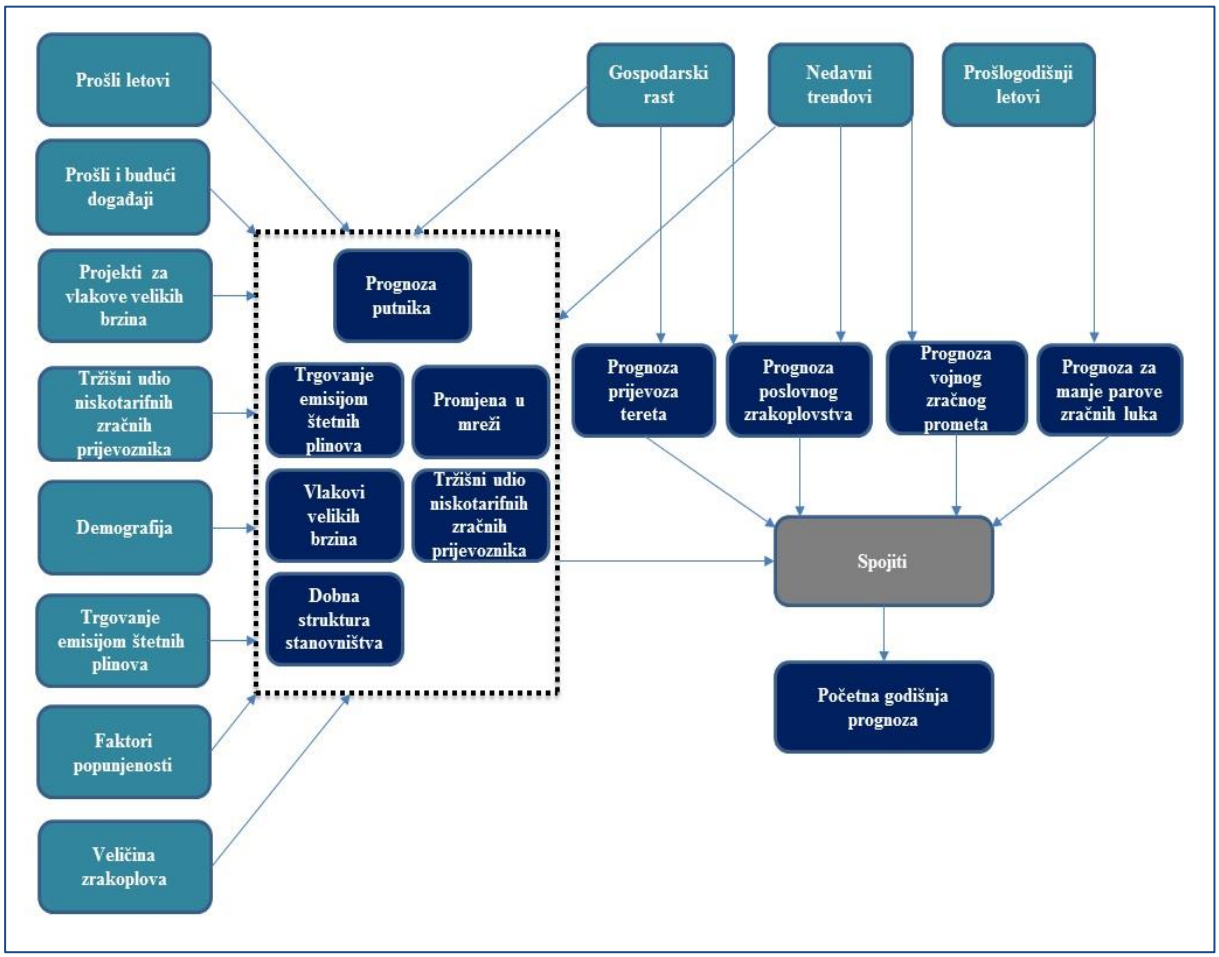
1) **gospodarski rast**, prognoza rasta (bruto domaćeg proizvoda – BDP-a[49]) prema realnom tečaju eura;
2) **nedavni trendovi** u godišnjem prometu;
3) **povijesni podaci** o broju letova za različite vrste letova između zračnih luka;
4) **prošli i budući trendovi**, postotna prilagodba kretanja između prometnih zona, kao potpora podacima koji predstavljaju konsolidirane učinke u modelu ili nepravilnosti prema osnovnoj referenci ili su jednokratni događaji na lokalnoj razini;
5) **mreža vlakova velikih brzina**, udaljenosti i promjene u vremenu putovanja između parova gradova koji su opsluženi vlakovima velikih brzina;
6) **tržišni udio niskotarifnih zračnih prijevoznika**, dodavanjem dodatnog broja IFR kretanja zrakoplova;
7) **demografija**, ima mali utjecaj na kratkoročno i srednjoročno razdoblje. Podaci su dobiveni na temelju prognoze stanovništva od Ujedinjenih Naroda (UN);
8) **trgovanje emisijom štetnih plinova**, prognoza pretpostavlja da većina troškova se prenaša na putnike koji generiraju manju potražnju za putovanjima;
9) **veličina zrakoplova**, iskazano kroz broj sjedala, koristi se prilikom pretvaranja broja letova u broj sjedala;
10) **faktori popunjenosti**, koriste se prilikom pretvaranja broja sjedala u broj putnika [31].

Ulazni podaci dijele se u pet segmenata, gdje svaki segment predstavlja povećanje letova između parova zračnih luka (slika 11):

1) prijevoz tereta ovisi o rastu BDP-a;
2) promet između manjih parova zračnih luka (manje od 25 letova godišnje) još uvijek se održava konstantnim;
3) vojni letovi bilježe rast od 5 % unutar prometne zone u odnosu na prethodne tri godine;

[49]Ukupna tržišna vrijednost robe i usluga proizvedenih u određenoj regiji u određenom vremenskom razdoblju izuzevši trošak robe koji se koristio tijekom proizvodnje [2].

4) rast poslovnog zrakoplovstva temelji se na trendovima na državnoj razini i rastu BDP-a;
5) ostali promet („ostali“ većinom podrazumijeva putničke letove) u razmatranje uzima ponudu ili potražnju [31].



Slika 11: *Ulazni podaci koji se uzimaju pri izradi sedmogodišnje prognoze prometa [31] (prilagodio autor).*

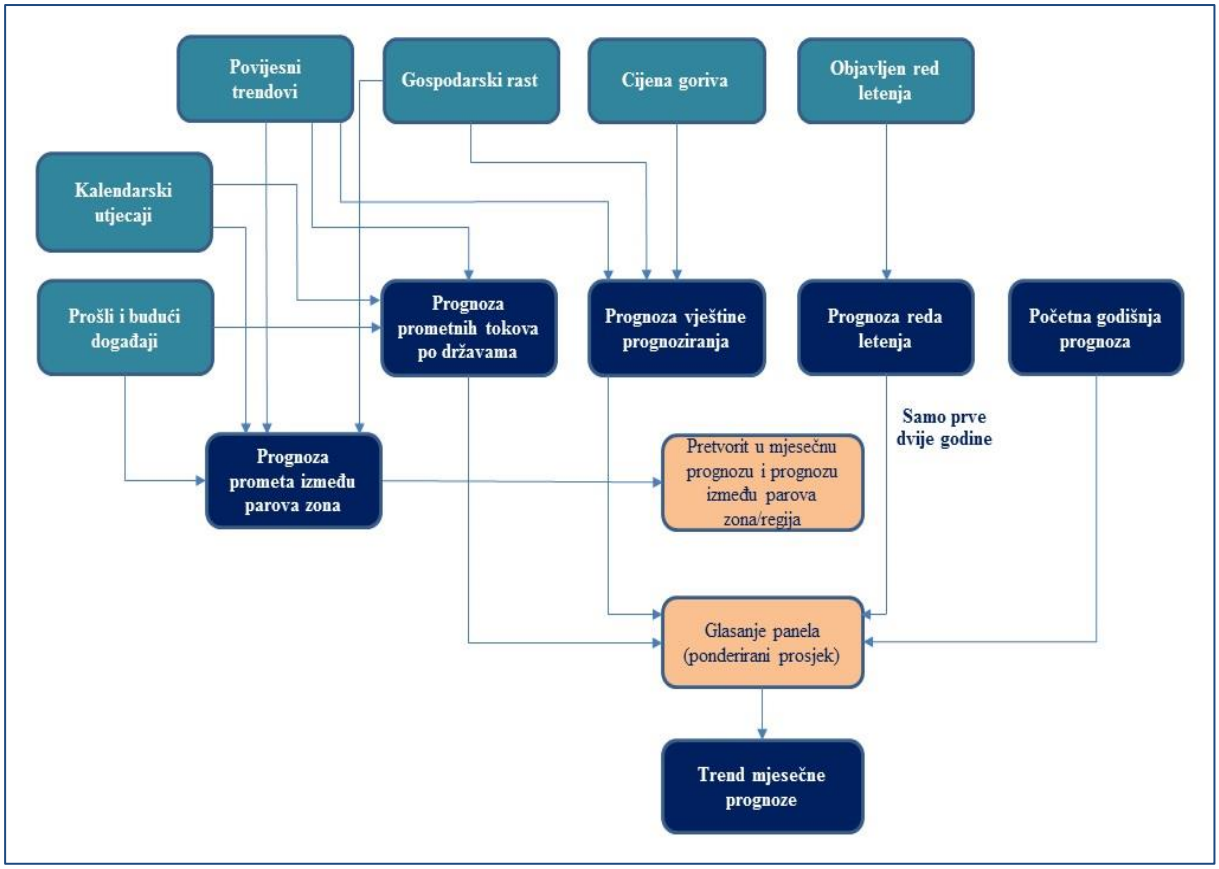
3.3.2.2 Mjesečna prognoza prometa

Konačan rezultat je mjesečni broj letova između parova zona ili regija:

1) unutar EU koriste se prometni tokovi između parova zona (grupa zračnih luka često je manja od država);
2) izvan Europe, koriste se velike regije (grupe država) [31].

Pet zasebnih prognoza koje doprinose prognozi u cijelosti (slika 12):

1) metoda prognoziranja prometnih tokova po svakoj državi je zasebna te se unutar država prognozira odvojeno za nekoliko glavnih prometnih tokova (domaći, odlazni i dolazni te preleti);
2) prognoza između parova zona ili regija, temelji se većinom na metodama vremenskih nizova za više od 9.000 nizova;
3) metoda prognoziranja reda letenja koristi objavljene podatke reda letenja za naredne mjesece te komparira prethodno objavljeni red letenja s trenutnim stanjem IFR kretanja zrakoplova;
4) komponenta vještog prognoziranja koristi podatke gospodarskog rasta i cijene goriva kao nezavisne varijable prilikom određivanja budućeg modela koji bi trebao biti sličan izlaznim veličinama prognoze. Model se primjenjuje na državnoj razini u kratkoročnom razdoblju;
5) prve godine početne prognoze prometa pridonose razvoju mjesečne prognoze [31].



Slika 12: *Ulazni podaci koji se uzimaju pri izradi mjesečne prognoze [31] (prilagodio autor).*

3.3.2.3 Ulazni podaci

Za pripremu sedmogodišnje prognoze prometa koriste se ulazni podaci kao što su: gospodarski rast, kapacitet zračnih luka, faktori popunjenosti, događanja i trendovi, red letenja zračnih prijevoznika, razvoj niskotarifnih zračnih prijevoznika, demografija i sklonost prema letenju te razvoj željeznica velikih brzina koji se sagledavaju nakon sveobuhvatnog savjetovanja svih dionika zračnog prometa [8].

Postoje tri scenarija koja se koriste u sedmogodišnjoj prognozi:

1) najviša stopa rasta (engl. *High-Growth Scenario* – H) temelji se na pretpostavkama snažnog ekonomskog rasta, snažnijeg rasta niskotarifnog tržišnog segmenta, snažnijeg utjecaja događanja i sporog razvoja željeznica velikih brzina;
2) najniža stopa rasta (engl. *Low-Growth Scenario* – L) temelji se na pretpostavkama slabog ekonomskog rasta, slabijeg rasta niskotarifnog tržišnog segmenta, slabijeg utjecaja događaja i bržeg razvoja željeznica velikih brzina;
3) osnovna referenca (engl. *Baseline Scenario* – B) predstavlja najvjerojatniju srednju vrijednost između visokog i niskog scenarija [8].

3.3.2.3.1 Gospodarski rast

Srednjoročna prognoza kretanja gospodarskog rasta u 28 država članica EU-a (grafikon 3) očekuje pad BDP-a u vremenskom razdoblju od 2019. do 2022. godine, zadnja revizija podataka u veljači 2017. godine (tablica 4). Kao glavni uzrok, pripisuje se nepovoljno političko okruženje na području Europe.

Grčka je dosegla najveću stopu BDP-a zahvaljujući turističkom sektoru i polaganom oporavku tržišta rada. Ujedinjena Kraljevina također revidira visoku stopu BDP-a zbog šoka uzrokovanog Brexit-om na gospodarstvo. S druge strane, Turska revidira smanjenju stopu BDP-a zbog političkih previranja i zabrinutosti za nacionalnu sigurnost. BDP multiplikator[50] ili „elastičnost“ pretvara gospodarski rast u rast putnika [8].

[50] Broj kojim se množi tzv. množitelj [5].

Tablica 4: *Rast BDP-a u prometnim zonama na području Europe (ECAC)*

Država	Trenutno stanje BDP-a			Osnovna referenca BDP-a						
	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023
Albanija	1,8%	2,8%	3,4%	3,7%	4,0%	4,1%	4,1%	4,1%	4,1%	4,1%
Armenija	3,6%	3,0%	2,0%	2,5%	3,0%	3,5%	4,3%	4,3%	4,3%	4,3%
Austrija	0,8%	0,8%	1,5%	1,2%	1,1%	1,3%	1,6%	1,6%	1,6%	1,6%
Azerbajdžan	2,7%	1,7%	-2,4%	1,4%	1,8%	2,8%	3,4%	3,4%	3,4%	3,4%
Belgija i Luksemburg	1,7%	1,5%	1,2%	1,5%	1,5%	1,6%	1,6%	1,6%	1,6%	1,6%
Bjelorusija	1,7%	-3,9%	-2,8%	0,8%	1,2%	1,5%	2,2%	2,2%	2,2%	2,2%
Bosna i Hercegovina	1,1%	3,2%	2,9%	3,0%	3,0%	3,0%	3,0%	3,0%	3,0%	3,0%
Bugarska	1,5%	3,6%	3,4%	2,9%	2,4%	2,3%	2,1%	2,1%	2,1%	2,1%
Cipar	-2,5%	1,6%	2,6%	2,2%	2,0%	2,0%	1,7%	1,7%	1,7%	1,7%
Češka	2,7%	4,6%	2,4%	2,4%	2,2%	2,0%	1,9%	1,9%	1,9%	1,9%
Danska	1,7%	1,6%	1,1%	1,6%	1,8%	1,8%	1,7%	1,7%	1,7%	1,7%
Estonija	2,8%	1,4%	1,2%	3,3%	4,0%	4,0%	3,8%	3,8%	3,8%	3,8%
Finska	-0,7%	0,2%	1,4%	1,2%	1,5%	1,7%	1,8%	1,8%	1,8%	1,8%
Francuska	0,7%	1,2%	1,1%	1,5%	1,5%	1,5%	1,2%	1,2%	1,2%	1,2%
Grčka	0,4%	-0,3%	0,4%	1,5%	1,5%	2,1%	2,7%	2,7%	2,7%	2,7%
Gruzija	4,2%	2,8%	3,1%	4,5%	5,0%	5,1%	4,4%	4,4%	4,4%	4,4%
Hrvatska	-0,5%	1,6%	2,6%	2,4%	2,1%	1,9%	1,8%	1,8%	1,8%	1,8%
Irska	8,4%	26,0%	4,2%	3,5%	3,4%	3,2%	2,8%	2,6%	2,6%	2,6%
Island	1,9%	4,2%	3,5%	2,5%	2,5%	2,5%	2,5%	2,5%	2,5%	2,5%
Italija	0,2%	0,6%	0,9%	0,6%	1,1%	1,1%	0,9%	0,9%	0,9%	0,9%
Kanarski otoci	1,4%	3,2%	3,3%	2,5%	2,0%	1,7%	1,4%	1,4%	1,4%	1,4%
Latvija	2,1%	2,7%	0,9%	2,7%	3,8%	3,9%	2,9%	2,9%	2,9%	2,9%
Lisabon FIR	0,9%	1,6%	1,2%	1,3%	1,1%	1,1%	1,0%	1,0%	1,0%	1,0%
Litva	3,5%	1,8%	2,0%	2,8%	3,3%	3,2%	2,5%	2,5%	2,5%	2,5%
Mađarska	4,0%	3,1%	1,4%	2,3%	2,5%	2,0%	1,3%	1,3%	1,3%	1,3%
Makedonija	3,5%	3,7%	2,4%	3,3%	3,7%	3,3%	2,9%	2,9%	2,9%	2,9%
Malta	8,3%	7,4%	3,5%	2,7%	2,5%	2,5%	2,1%	2,1%	2,1%	2,1%
Maroko	2,4%	4,4%	1,0%	3,7%	3,9%	4,0%	4,1%	4,1%	4,1%	4,1%
Moldavija	4,8%	-0,5%	2,0%	3,0%	3,7%	3,4%	4,3%	4,3%	4,3%	4,3%
Nizozemska	1,4%	2,0%	2,0%	1,7%	1,4%	1,3%	1,1%	1,1%	1,1%	1,1%
Norveška	1,9%	1,6%	0,7%	1,1%	1,7%	2,0%	1,5%	1,5%	1,5%	1,5%
Njemačka	1,6%	1,5%	1,8%	1,4%	1,6%	1,4%	1,4%	1,4%	1,4%	1,4%
Poljska	3,3%	3,9%	2,4%	2,4%	3,0%	3,0%	2,6%	2,6%	2,6%	2,6%
Rumunjska	3,1%	3,8%	4,8%	3,1%	2,1%	2,0%	1,8%	1,8%	1,8%	1,8%
Slovačka	2,6%	3,8%	3,4%	2,6%	2,9%	2,8%	2,2%	2,2%	2,2%	2,2%
Slovenija	2,9%	2,1%	2,5%	2,3%	2,3%	2,5%	3,1%	3,1%	3,1%	3,1%
Srbija i Crna Gora	-1,8%	0,7%	2,0%	2,2%	3,0%	3,5%	3,2%	3,2%	3,2%	3,2%
Sveta Marija FIR	0,9%	1,6%	1,2%	1,3%	1,1%	1,1%	1,0%	1,0%	1,0%	1,0%
Španjolska	1,4%	3,2%	3,3%	2,5%	2,0%	1,7%	1,4%	1,4%	1,4%	1,4%
Švedska	2,7%	3,8%	3,1%	2,1%	1,8%	1,4%	1,1%	1,1%	1,1%	1,1%
Švicarska	2,0%	0,8%	1,4%	1,8%	1,8%	1,6%	1,3%	1,3%	1,3%	1,3%
Turska	5,2%	6,1%	2,0%	2,4%	3,3%	3,7%	3,2%	3,2%	3,2%	3,2%
Ukrajina	-6,6%	-9,9%	1,1%	2,5%	3,0%	3,0%	2,5%	2,5%	2,5%	2,5%
Ujedinjena Kraljevina	3,1%	2,2%	2,0%	1,5%	1,3%	1,6%	2,2%	2,2%	2,2%	2,2%
Europa	1,6%	2,1%	1,8%	1,6%	1,6%	1,5%	1,5%	1,5%	1,5%	1,5%

Izvor: *[8] (prilagodio autor).*



Grafikon 3: *Kretanje BDP-a u 28 država članica EU-a do 2022. godine [8] (prilagodio autor).*

3.3.2.3.2 Kapacitet zračnih luka

Model kapaciteta zračne luke u MTF-u temelji se na „efektivnom godišnjem kapacitetu“ koji se primjenjuje pri prognoziranju ukupne godišnje potražnje na zračnim lukama te smanjuje ukupan broj IFR kretanja zrakoplova unutar kapaciteta zračnih luka na godišnjoj razini. Sveobuhvatan skup podataka o kapacitetu, prikuplja se putem EUROCONTROL-ove jedinice zadužene za zračne luke u sklopu NM-a. Informacije se izravno pružaju sa zračnih luka te ako su potvrđene od jedinice, smatraju se cjelovitim, pouzdanim, stvarnim i visoke kvalitete. Za nepotpune podatke, skup podataka dovršava se korištenjem informacija izravno zaprimljenih od dionika zračnog prometa. Prikupljeni podaci pokrivaju 108 zračnih luka. Da bi se poštivala komercijalna osjetljivost informacija o zračnim lukama, nisu javno dostupne [8].

Pretpostavke prikazane u tablici 5 predstavljaju očekivanu promjenu prometa u vremenskom razdoblju prognoze (nema razlike u odnosu na scenarij). Ove pretpostavke temelje se na informacijama iz vijesti i / ili informacija pruženih od članova SUG-a:

1) zatvaranje zračne luke Berlin / Tegel (EDDT) premješta promet na novu zračnu luku Berlin / Brandenburg (EDDB) tijekom 2018. godine prema osnovnoj referenci i scenariju visokog rasta. U scenariju niskog rasta, nova zračna luka planira biti operativna godinu dana kasnije;

2) također, nova (treća) zračna luka u Istanbulu očekuje operativnost tijekom 2018. godine te modelira progresivno povećanje kapaciteta zračne luke Istanbul / Atatürk (LTBA[51]) do kraja prognostičkog razdoblja. Pretpostavka je nastavak rada LTBA (u manjoj mjeri) nakon otvaranja treće zračne luke [8].

Tablica 5: *Premještanje zračnog prometa s jedne zračne luke na drugu*

Vrsta prometa	ICAO kod zračne luke		Najniža stopa rasta		Osnovna referenca		Najviša stopa rasta	
	Od	Do	2019	2020	2018	2019	2018	2019
Svi	EDDT	EDDB	60%	100%	40%	100%	40%	100%

Izvor: *[8] (prilagodio autor).*

3.3.2.3.3 Razvoj faktora popunjenosti

Pretpostavke oko razvoja faktora popunjenosti (engl. *load factors*) temelje se na STATFOR analizama povijesnih podataka pruženih od Europskog udruženja zračnih prijevoznika (engl. *Association of European Airlines* – AEA[52]). MTF izrađuje na temelju trenutnog stanja nedavnih trendova iskazanih pomoću godišnjih podataka i koriste se kao ulazni podaci u prognostičku metodu [8].

Prognoza faktora popunjenosti (tablica 6) po ICAO prometnim regijama (engl. *Traffic Region* – TR[53]) (slika 13) temelji se na trenutnom stanju nedavnih trendova u kombinaciji s pretpostavkama maksimalnog ograničenja kojeg zračni prijevoznici mogu održavati u sedmogodišnjem razdoblju. Osnovna referenca faktora popunjenosti u 2023. godini revidira relativno visoku stopu rasta i kreće se u intervalu od 75 % do 90 %. MTF pretpostavlja da maksimalno 85 % kratko-linijskih i 90 % dugo-linijskih letova može biti ostvareno [8].

[51]Iz tehničkih razloga, raspoloživi dodatni kapacitet za treću zračnu luku smatra se pod nadležnošću LTBA [8].

[52]Okuplja 22 glavna zračna prijevoznika te više od 60 godina predstavlja pouzdan glas europske industrije zračnih prijevoznika. AEA okuplja bogato iskustvo svojih članova koje se redovito sastaje na tzv. „stručnim sastancima“. Radni dokumenti razvijaju se u suradnji sa stručnjacima kako bi se odrazili stavovi svih zračnih prijevoznika koji su članovi AEA-e [32].

[53]Sačinjena od prometne(ih) zone(a) država koje su klasificirane ICAO kodom. Područje Europe je segmentirano na ESRA sjeverozapad, ESRA Mediteran, ESRA istok i ostatak Europe [8].



Slika 13: *Shematski prikaz devet svjetskih ICAO prometnih regija korištenih u svrhu prometne statistike, prognoze i analize [8] (prilagodio autor).*

Tablica 6: *Faktori popunjenosti po ICAO prometnim regijama*

ICAO prometna regija	Trenutno stanje											Najniža stopa rasta	Osnovna referenca	Najviša stopa rasta
	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2023	2023	2023
Azija i Pacifik	80,7%	83,2%	80,9%	80,4%	83,4%	79,9%	81,4%	81,8%	82,7%	83,0%	82,3%	87,2%	84,6%	82,1%
ESRA Istok	**68,6%**	**69,2%**	**67,9%**	**68,1%**	**70,1%**	**72,1%**	**73,7%**	**74,7%**	**76,0%**	**77,2%**	**76,5%**	**85,0%**	**83,0%**	**80,9%**
ESRA Mediteran	**68,6%**	**69,2%**	**67,9%**	**68,1%**	**70,1%**	**72,1%**	**73,7%**	**74,7%**	**76,0%**	**77,2%**	**76,5%**	**85,0%**	**83,0%**	**80,9%**
ESRA Sjeverozapad	**68,6%**	**69,2%**	**67,9%**	**68,1%**	**70,1%**	**72,1%**	**73,7%**	**74,7%**	**76,0%**	**77,2%**	**76,5%**	**85,0%**	**83,0%**	**80,9%**
Južna Afrika	78,0%	79,2%	79,1%	77,7%	77,3%	77,7%	78,6%	79,8%	80,1%	77,8%	77,8%	81,0%	79,1%	77,2%
Južni Atlantik	86,3%	85,0%	81,1%	80,2%	85,0%	85,0%	84,7%	85,1%	84,2%	82,7%	82,2%	89,0%	85,6%	82,1%
Ostatak Europe	**68,6%**	**69,2%**	**67,9%**	**68,1%**	**70,1%**	**72,1%**	**73,7%**	**74,7%**	**76,0%**	**77,2%**	**76,5%**	**85,0%**	**83,0%**	**80,9%**
Sjeverna Afrika	68,5%	69,9%	70,9%	68,4%	70,7%	68,0%	72,4%	71,6%	71,4%	75,0%	76,2%	80,0%	79,3%	76,4%
Sjeverni Atlantik	81,5%	82,2%	81,4%	82,7%	84,0%	83,1%	84,8%	85,6%	85,3%	85,0%	83,7%	89,6%	87,4%	85,2%
Srednji Atlantik	82,1%	84,4%	83,4%	81,7%	82,7%	82,4%	83,9%	84,1%	85,1%	86,0%	86,4%	90,0%	90,0%	88,2%
Srednji Istok	70,9%	73,8%	74,0%	69,5%	71,5%	70,1%	71,6%	73,1%	74,9%	75,4%	73,6%	80,0%	77,3%	74,3%

Izvor: *[8] (prilagodio autor).*

3.3.2.3.4 Događanja i trendovi

Srednjoročna prognoza uzima u obzir sljedeća događanja kao što su:

1) sportska događanja: svjetsko nogometno prvenstvo 2018. godine i europsko nogometno prvenstvo 2020. godine;
2) negativni učinci za Tursku i sjevernoafričke države (Tunis i Egipat) zbog povećanih prijetnji terorističkih skupina;

3) porast sjevernoatlantskih tokova (Sjedinjene Američke Države i Kanada) zbog novih dugo-linijskih letova niskotarifnih zračnih prijevoznika (Norwegian, WOW Air);
4) utjecaj povećanih naknada Norveške vlade na sve odlazne letove (domaći i međunarodni letovi) [8].

3.3.2.3.5 Red letenja zračnog prijevoznika

Iskustvo pokazuje da podaci o redu letenja mogu biti korišteni samo za nekoliko mjeseci. U ovoj prognozi korišteni su rasporedi do travnja 2017. godine. Tablica 7 prikazuje očekivani rast po zemljama na temelju dostupnih podataka. Raspored za svibanj i kolovoz u 2017. godini nije uzet u obzir za ovu prognozu [8].

Tablica 7: *Rast odlaznog reda letenja za referentnu 2017. godinu na području ECAC-a, ESRA08 i EU-27*

Država	Rast odlaznog reda letenja (u postocima) Referentna 2017. godina						
	Veljača	Ožujak	Travanj	Svibanj	Lipanj	Srpanj	Kolovoz
Albanija	2%	0%	4%	9%	12%	9%	10%
Armenija	24%	36%	72%	35%	27%	31%	13%
Austrija	2%	4%	9%	15%	15%	14%	16%
Belgija i Luksemburg	1%	0%	0%	3%	3%	3%	3%
Bosna i Hercegovina	-3%	8%	37%	20%	23%	21%	18%
Bugarska	25%	24%	23%	20%	13%	8%	9%
Cipar	24%	17%	18%	11%	8%	1%	-1%
Češka	9%	7%	9%	11%	10%	9%	11%
Danska	1%	7%	-2%	0%	0%	2%	4%
Estonija	-8%	0%	-13%	-10%	-9%	-7%	7%
Finska	3%	8%	0%	0%	6%	11%	9%
Francuska	6%	3%	4%	4%	3%	3%	3%
Grčka	9%	6%	3%	3%	5%	4%	4%
Gruzija	17%	28%	36%	35%	34%	23%	22%
Hrvatska	1%	4%	12%	9%	7%	7%	7%
Irska	2%	1%	2%	2%	2%	2%	3%
Italija	1%	0%	4%	5%	4%	4%	3%
Kanarski otoci	11%	8%	12%	11%	10%	7%	3%
Latvija	5%	3%	4%	7%	10%	11%	10%
Lisabon FIR	14%	10%	12%	11%	11%	10%	9%
Litva	12%	14%	11%	11%	12%	-3%	-3%
Mađarska	10%	4%	4%	5%	3%	2%	3%
Makedonija	1%	-2%	4%	2%	1%	2%	1%
Malta	29%	19%	14%	12%	10%	11%	7%
Moldavija	31%	27%	38%	21%	21%	9%	9%
Nizozemska	6%	6%	6%	5%	7%	3%	3%
Norveška	-3%	9%	-11%	-2%	-6%	-7%	-7%
Njemačka	2%	4%	3%	6%	3%	6%	7%
Poljska	11%	9%	6%	7%	7%	7%	6%
Rumunjska	22%	21%	26%	25%	21%	22%	21%
Slovačka	6%	4%	-1%	-4%	-9%	-7%	-8%
Slovenija	15%	9%	10%	13%	7%	6%	5%
Srbija i Crna Gora	4%	5%	7%	7%	5%	2%	1%
Sveta Marija FIR	11%	5%	19%	20%	26%	11%	11%
Španjolska	5%	2%	7%	7%	6%	4%	3%
Švedska	-6%	2%	-2%	3%	5%	13%	14%
Švicarska	14%	15%	18%	19%	18%	17%	17%
Turska	0%	-1%	2%	-1%	0%	-3%	-4%
Ujedinjena Kraljevina	3%	2%	3%	3%	1%	2%	2%
Ukrajina	16%	15%	16%	7%	4%	-1%	-2%
ECAC	4%	4%	4%	5%	4%	4%	4%
ESRA08	4%	4%	4%	5%	4%	4%	4%
EU-27	4%	4%	5%	5%	4%	5%	5%

Izvor: *[8] (prilagodio autor).*

3.3.2.3.6 Razvoj niskotarifnih zračnih prijevoznika

Dodatan rast IFR kretanja zrakoplova generiran od strane niskotarifnih zračnih prijevoznika predstavlja ulazni podatak. U tablici 8 priloženo je trenutno stanje dodatnog rasta niskotarifnih zračnih prijevoznika u 2016. godini i očekivani tržišni udio LCC-a za svaki scenarij iskazan u postocima za 2023. godinu.

Tablica 8: *Dodatan rast IFR kretanja zrakoplova u % zbog utjecaja LCC-a u prometnim zonama*

Država	Trenutno stanje 2016	Najniža stopa rasta 2023	Osnovna referenca 2023	Najviša stopa rasta 2023
Albanija	6%	6%	8%	11%
Armenija	6%	6%	7%	8%
Austrija	22%	21%	26%	32%
Azerbajdžan	2%	2%	4%	7%
Bjelorusija	0%	0%	2%	5%
Belgija i Luksemburg	19%	18%	23%	29%
Bosna i Hercegovina	29%	28%	33%	38%
Bugarska	24%	23%	28%	33%
Kanarski otoci	51%	51%	54%	59%
Hrvatska	25%	24%	29%	35%
Cipar	28%	27%	36%	46%
Češka	30%	29%	38%	48%
Danska	23%	22%	27%	33%
Estonija	19%	18%	27%	37%
Makedonija	44%	40%	44%	49%
Finska	11%	10%	16%	21%
Francuska	28%	27%	32%	37%
Gruzija	16%	16%	19%	24%
Njemačka	33%	33%	34%	35%
Grčka	28%	27%	32%	37%
Mađarska	46%	45%	52%	60%
Island	17%	16%	21%	26%
Irska	38%	37%	42%	47%
Italija	41%	38%	43%	48%
Latvija	71%	55%	65%	75%
Lisabon FIR	37%	36%	41%	46%
Litva	45%	44%	49%	54%
Malta	36%	35%	44%	54%
Moldavija	7%	7%	9%	12%
Maroko	25%	23%	37%	52%
Nizozemska	27%	26%	31%	37%
Norveška	22%	21%	26%	32%
Poljska	36%	35%	46%	59%
Rumunjska	29%	28%	33%	38%
Sveta Marija FIR	10%	8%	9%	10%
Srbija i Crna Gora	12%	11%	17%	22%
Slovačka	35%	34%	42%	51%
Slovenija	5%	4%	13%	23%
Španjolska	52%	52%	54%	56%
Švedska	20%	20%	23%	27%
Švicarska	18%	17%	22%	28%
Turska	30%	29%	34%	39%
Ujedinjena Kraljevina	46%	45%	48%	50%
Ukrajina	6%	5%	11%	17%

Izvor: *[8] (prilagodio autor).*

3.3.2.3.7 Demografija i sklonost prema letenju

Demografski model kombinira evoluciju dobne strukture populacije s dobnom strukturom putnika. Podaci se temelje na prognozi dobne strukture populacije iz 2015. godine objavljene od strane Ujedinjenih Naroda [8]. Ulazni podaci u prometnim zonama na području Europe su priloženi u tablici 9.

Tablica 9: *Dobna raspodjela populacije po prometnim zonama*

Država	Trenutno stanje od 2015. godine										Osnovna referenca do 2025. godine									
	Dobna struktura										Dobna struktura									
	od 0 do 14	od 15 do 19	od 20 do 24	od 25 do 34	od 35 do 44	od 45 do 54	od 55 do 59	od 60 do 64	od 65 do 74	75 +	od 0 do 14	od 15 do 19	od 20 do 24	od 25 do 34	od 35 do 44	od 45 do 54	od 55 do 59	od 60 do 64	od 65 do 74	75 +
Albanija	19%	8,9%	9,4%	14%	11%	14%	6,6%	5,4%	7,4%	5%	19%	5,1%	6,2%	17%	13%	11%	6%	6,5%	10%	6,5%
Armenija	18%	5,9%	8,5%	18%	12%	13%	7,3%	5,5%	4,9%	6%	18%	6,1%	5%	14%	17%	12%	5,3%	7,1%	11%	4,9%
Austrija	14%	5,4%	6,3%	13%	13%	16%	6,9%	5,4%	10%	8,7%	14%	4,6%	5%	12%	13%	13%	8%	7,6%	11%	11%
Azerbajdžan	22%	7,2%	9,3%	19%	13%	14%	5,4%	4,4%	2,8%	2,9%	24%	5,8%	5,5%	15%	17%	12%	5,5%	6,4%	7,3%	2,1%
Belgija i Luksemburg	17%	5,5%	6,1%	13%	13%	15%	6,7%	5,9%	9,2%	8,8%	17%	5,7%	5,5%	12%	13%	13%	6,7%	6,6%	11%	9,9%
Bjelorusija	16%	4,6%	6,7%	16%	14%	15%	7,7%	6,3%	7%	7,0%	18%	5,4%	4,8%	12%	16%	14%	6,1%	7,1%	11%	6,1%
Bosna i Hercegovina	13%	5,8%	6%	15%	14%	15%	7,5%	6,9%	8,6%	6,8%	13%	4,8%	4,5%	12%	16%	15%	6,8%	7,7%	13%	8,1%
Bugarska	14%	4,5%	5,2%	14%	15%	14%	7%	6,9%	12%	8,3%	15%	5,3%	4,5%	9,9%	14%	15%	7,1%	6,5%	12%	10%
Cipar	17%	6,5%	8,4%	17%	15%	13%	6%	5,1%	7,6%	5,3%	16%	5,5%	6,2%	15%	16%	14%	6%	5,7%	9,4%	6,9%
Češka	15%	4,3%	5,8%	14%	17%	13%	6,3%	6,9%	11%	7%	15%	5,4%	4,7%	10%	14%	17%	6,4%	6%	12%	10%
Danska	17%	6,3%	6,8%	12%	13%	14%	6,3%	5,7%	11%	7,5%	16%	5,9%	6%	13%	12%	12%	7,1%	6,3%	10%	11%
Estonija	16%	4,2%	6,1%	14%	14%	13%	6,8%	6,5%	9,5%	9,3%	16%	6%	4,8%	10%	15%	14%	6%	6,6%	12%	10%
Finska	16%	5,5%	6,3%	13%	12%	13%	6,7%	6,7%	12%	8,7%	16%	5,6%	5,3%	12%	13%	12%	6,3%	6,3%	12%	12%
Francuska	18%	5,9%	5,7%	12%	13%	13%	6,3%	6,1%	9,7%	9,5%	17%	6%	6,1%	12%	12%	12%	6,2%	6,1%	11%	11%
Grčka	15%	4,7%	5,5%	13%	15%	14%	6,5%	5,6%	10%	11%	13%	5,1%	5,1%	11%	13%	15%	7,4%	6,8%	11%	12%
Gruzija	17%	6,1%	7,5%	16%	14%	14%	6,6%	5,2%	6,8%	7,2%	19%	5,7%	4,5%	13%	15%	13%	6,3%	6,8%	10%	6,4%
Hrvatska	15%	5,7%	5,5%	13%	14%	14%	7,3%	7%	9,9%	9%	**14%**	**5,3%**	**5%**	**12%**	**14%**	**14%**	**6,5%**	**7%**	**13%**	**9,9%**
Irska	22%	5,7%	5,4%	14%	16%	13%	5,5%	5,2%	7,9%	5,3%	19%	7,1%	6,4%	11%	13%	15%	6%	5,8%	9,2%	7,4%
Island	20%	6,7%	7,7%	14%	13%	13%	6,3%	5,4%	7,7%	6,0%	19%	6,6%	6%	14%	13%	12%	5,9%	6%	10%	7,8%
Italija	14%	4,7%	4,9%	11%	14%	16%	6,8%	6,2%	11%	11%	13%	4,8%	4,9%	10%	11%	15%	8%	7,6%	12%	14%
Kanarski otoci	15%	4,5%	4,8%	12%	17%	16%	6,8%	5,6%	9,4%	9,4%	13%	5,3%	5,1%	9,7%	12%	17%	7,9%	7,4%	11%	11%
Latvija	15%	4%	6,4%	14%	13%	14%	7,3%	6,3%	10%	9,4%	15%	5,7%	4,9%	11%	15%	14%	6,4%	7,1%	12%	9,6%
Lisabon FIR	14%	5,3%	5,2%	12%	15%	15%	6,7%	6,3%	11%	10%	12%	4,9%	5,3%	11%	12%	16%	7,3%	7,2%	12%	13%
Litva	15%	5,5%	7,2%	12%	13%	15%	7,2%	6,1%	9,3%	9,5%	16%	4,9%	4,8%	13%	13%	13%	6,8%	7,7%	12%	8,7%
Madarska	15%	5,1%	6,1%	14%	16%	13%	6,8%	7,1%	10%	7,7%	14%	5,2%	5,1%	12%	14%	16%	6,5%	5,4%	12%	9,2%
Makedonija	17%	6,6%	7,3%	15%	15%	14%	6,6%	6,2%	7,6%	4,8%	16%	5,3%	5,9%	14%	15%	14%	6,8%	6,2%	11%	5,8%
Malta	14%	6,3%	6,8%	13%	15%	13%	6,7%	6,3%	12%	7,4%	14%	4,7%	5,4%	13%	13%	14%	6,1%	6,5%	12%	11%
Moldavija	16%	6%	8,2%	19%	14%	13%	6,9%	6,6%	5,6%	4,3%	15%	5,4%	5%	14%	19%	14%	5,6%	6,7%	11%	4,1%
Nizozemska	17%	5,9%	6,1%	12%	13%	15%	6,9%	6,3%	11%	7,6%	16%	5,3%	5,9%	12%	12%	12%	7,3%	7,1%	12%	11%
Norveška	18%	6,3%	6,8%	14%	14%	14%	6,1%	5,4%	9,5%	6,8%	18%	5,9%	5,8%	13%	13%	13%	6,6%	5,7%	9,7%	9%
Njemačka	13%	5%	5,4%	13%	12%	17%	7,5%	6,4%	10%	11%	13%	4,3%	4,7%	11%	13%	12%	8,2%	8,3%	13%	12%
Poljska	15%	5,1%	6,4%	16%	15%	12%	7,7%	7,1%	8,5%	7%	14%	5,3%	4,6%	12%	16%	15%	5,7%	5,8%	13%	8,8%
Rumunjska	16%	5,4%	5,1%	13%	16%	14%	7,1%	7,1%	9,3%	8%	14%	5,7%	5,4%	10%	13%	16%	8,2%	5,4%	13%	8,8%
Ruska Federacija	17%	4,4%	6,2%	17%	14%	14%	7,5%	6,7%	6,8%	6,5%	18%	5,7%	5%	11%	17%	14%	5,5%	6,7%	11%	5,9%
Slovačka	15%	5,3%	6,6%	16%	16%	13%	7%	6,7%	8,4%	5,5%	15%	5,2%	4,8%	12%	16%	16%	6,1%	6,2%	12%	7,1%
Slovenija	15%	4,5%	5,1%	14%	15%	15%	7,3%	7,2%	9,4%	8,5%	15%	5%	4,5%	10%	14%	15%	7,2%	7%	13%	10%
Srbija i Crna Gora	16%	6,3%	6,4%	13%	14%	13%	6,3%	7,3%	9,8%	7,0%	16%	5,5%	6%	13%	13%	14%	6,5%	6,1%	12%	8,2%
Sveta Marija FIR	14%	5,3%	5,2%	12%	15%	15%	6,7%	6,3%	11%	10%	12%	4,9%	5,3%	11%	12%	16%	7,3%	7,2%	12%	13%
Španjolska	15%	4,5%	4,8%	12%	17%	16%	6,8%	5,6%	9,4%	9,4%	13%	5,3%	5,1%	9,7%	12%	17%	7,9%	7,4%	11%	11%
Švedska	17%	5,2%	7,1%	13%	13%	13%	5,9%	5,6%	11%	8,5%	18%	5,9%	5,4%	12%	13%	12%	6,6%	5,6%	10%	11%
Švicarska	15%	5,2%	6,1%	14%	14%	16%	6,6%	5,5%	9,7%	8,3%	15%	4,8%	5,2%	12%	14%	13%	7,5%	7,1%	11%	10%
Turska	26%	8,5%	8,1%	16%	15%	11%	4,6%	3,7%	4,6%	2,9%	22%	7,6%	7,6%	15%	15%	13%	5,2%	4,5%	6,7%	3,7%
Ujedinjena Kraljevina	18%	5,8%	6,5%	14%	13%	14%	6%	5,2%	9,8%	7,9%	18%	6%	5,4%	13%	13%	12%	6,7%	6,5%	9,7%	9,8%
Ukrajina	15%	4,7%	6,2%	16%	15%	14%	6,9%	7,3%	7,7%	7,6%	16%	5,6%	4,3%	11%	17%	15%	6,1%	7%	12%	6,6%

Izvor: *[8] (prilagodio autor).*

3.3.2.3.8 Razvoj željeznica velikih brzina

Vrijeme putovanja vlakova velikih brzina (engl. *High-Speed Train* – HST**)** dobiveno je na temelju izvora podataka iz DGAC Francuska, DFS Njemačka i DHMI Turska. Željeznički projekti navedeni u tablici 10 odnose se samo na parove gradova koji će ubrzati vrijeme putovanja HST-a unutar prognostičkog razdoblja.

Tablica 10: *Vrijeme putovanja po paru gradova, a udaljenost je procijenjena na temelju lokacija zračnih luka*

Par gradova HST-a		Stopa rasta	Udaljenost (u kilometrima)	Vrijeme putovanja (u minutama)								Brzina (u kilometrima na sat)							
				2016	2017	2018	2019	2020	2021	2022	2023	2016	2017	2018	2019	2020	2021	2022	2023
Amsterdam	London	Najviša	359	286	.	240	.	.	.	.	.	75	.	90	.	.	.	.	.
		Osnovna referenca	359	286	240	.	.	.	.	.	.	75	90	.	.	.	.	.	.
		Najniža	359	286	240	.	.	.	.	.	.	75	90	.	.	.	.	.	.
Ankara	Sivas	Najviša	354	600	.	.	120	.	.	.	.	35	.	.	177	.	.	.	.
		Osnovna referenca	354	600	.	120	.	.	.	.	.	35	.	177	.	.	.	.	.
		Najniža	354	600	.	120	.	.	.	.	.	35	.	177	.	.	.	.	.
	Bursa	Najviša	318	240	.	135	.	.	.	.	.	79	.	141	.	.	.	.	.
		Osnovna referenca	318	240	135	.	.	.	.	.	.	79	141	.	.	.	.	.	.
		Najniža	318	240	135	.	.	.	.	.	.	79	141	.	.	.	.	.	.
	Izmir	Najviša	519	900	.	.	.	.	.	.	210	35	.	.	.	.	.	.	148
		Osnovna referenca	519	900	.	.	.	.	.	.	210	35	.	.	.	.	.	.	148
		Najniža	519	900	.	.	.	.	.	.	210	35	.	.	.	.	.	.	148
Barcelona	Lyon	Najviša	530	300	.	180	.	.	.	.	.	106	.	177	.	.	.	.	.
		Osnovna referenca	530	300	180	.	.	.	.	.	.	106	177	.	.	.	.	.	.
		Najniža	530	300	180	.	.	.	.	.	.	106	177	.	.	.	.	.	.
Brussels	Luksemburg	Najviša	176	135	.	90	.	.	.	.	.	78	.	117	.	.	.	.	.
		Osnovna referenca	176	135	90	.	.	.	.	.	.	78	117	.	.	.	.	.	.
		Najniža	176	135	90	.	.	.	.	.	.	78	117	.	.	.	.	.	.
	Strasbourg	Najviša	337	270	.	180	.	.	.	.	.	75	.	112	.	.	.	.	.
		Osnovna referenca	337	270	180	.	.	.	.	.	.	75	112	.	.	.	.	.	.
		Najniža	337	270	180	.	.	.	.	.	.	75	112	.	.	.	.	.	.
Erfurt	Leipzig	Najviša	102	72	.	39	.	.	.	.	.	85	.	156	.	.	.	.	.
		Osnovna referenca	102	72	39	.	.	.	.	.	.	85	156	.	.	.	.	.	.
		Najniža	102	72	39	.	.	.	.	.	.	85	156	.	.	.	.	.	.
	Munchen	Najviša	307	300	.	.	150	.	.	.	.	61	.	.	123	.	.	.	.
		Osnovna referenca	307	300	.	150	.	.	.	.	.	61	.	123	.	.	.	.	.
		Najniža	307	300	.	150	.	.	.	.	.	61	.	123	.	.	.	.	.
	Nurnberg	Najviša	165	172	.	.	66	.	.	.	.	57	.	.	150	.	.	.	.
		Osnovna referenca	165	172	.	66	.	.	.	.	.	57	.	150	.	.	.	.	.
		Najniža	165	172	.	66	.	.	.	.	.	57	.	150	.	.	.	.	.
Frankfurt	Bern	Najviša	348	230	.	.	.	.	200	.	.	91	.	.	.	.	105	.	.
		Osnovna referenca	348	230	.	.	.	200	.	.	.	91	.	.	.	105	.	.	.
		Najniža	348	230	.	.	.	200	.	.	.	91	.	.	.	105	.	.	.
	Bale Mulhouse	Najviša	274	170	.	.	.	.	140	.	.	97	.	.	.	.	118	.	.
		Osnovna referenca	274	170	.	.	.	140	.	.	.	97	.	.	.	118	.	.	.
		Najniža	274	170	.	.	.	140	.	.	.	97	.	.	.	118	.	.	.
	Pariz	Najviša	444	230	.	215	.	.	.	.	.	116	.	124	.	.	.	.	.
		Osnovna referenca	444	230	215	.	.	.	.	.	.	116	124	.	.	.	.	.	.
		Najniža	444	230	215	.	.	.	.	.	.	116	124	.	.	.	.	.	.
	Stuttgart	Najviša	154	77	.	.	53	.	.	.	.	120	.	.	175	.	.	.	.
		Osnovna referenca	154	77	.	53	.	.	.	.	.	120	.	175	.	.	.	.	.
		Najniža	154	77	.	53	.	.	.	.	.	120	.	175	.	.	.	.	.
Hannover	Munchen	Najviša	488	290	.	.	.	.	.	.	200	101	.	.	.	.	.	.	146
		Osnovna referenca	488	290	.	.	.	.	.	.	200	101	.	.	.	.	.	.	146
		Najniža	488	290	.	.	.	.	.	.	200	101	.	.	.	.	.	.	146
Istanbul	Ankara	Najviša	335	250	.	180	.	.	.	.	.	80	.	112	.	.	.	.	.
		Osnovna referenca	335	250	180	.	.	.	.	.	.	80	112	.	.	.	.	.	.
		Najniža	335	250	180	.	.	.	.	.	.	80	112	.	.	.	.	.	.
	Konya	Najviša	454	275	.	205	.	.	.	.	.	99	.	133	.	.	.	.	.
		Osnovna referenca	454	275	205	.	.	.	.	.	.	99	133	.	.	.	.	.	.
		Najniža	454	275	205	.	.	.	.	.	.	99	133	.	.	.	.	.	.
	Sivas	Najviša	682	1260	.	300	.	.	.	.	.	32	.	136	.	.	.	.	.
		Osnovna referenca	682	1260	300	.	.	.	.	.	.	32	136	.	.	.	.	.	.
		Najniža	682	1260	300	.	.	.	.	.	.	32	136	.	.	.	.	.	.
Karlsruhe	Bern	Najviša	239	180	.	.	.	.	150	.	.	80	.	.	.	.	96	.	.
		Osnovna referenca	239	180	.	.	.	150	.	.	.	80	.	.	.	96	.	.	.
		Najniža	239	180	.	.	.	150	.	.	.	80	.	.	.	96	.	.	.
	Bale Mulhouse	Najviša	166	100	.	.	.	.	69	.	.	100	.	.	.	.	145	.	.
		Osnovna referenca	166	100	.	.	.	69	.	.	.	100	.	.	.	145	.	.	.
		Najniža	166	100	.	.	.	69	.	.	.	100	.	.	.	145	.	.	.
Koln / Bonn	Bale Mulhouse	Najviša	361	230	.	.	.	.	200	.	.	94	.	.	.	.	108	.	.
		Osnovna referenca	361	230	.	.	.	200	.	.	.	94	.	.	.	108	.	.	.
		Najniža	361	230	.	.	.	200	.	.	.	94	.	.	.	108	.	.	.
Kopenhagen	Hamburg	Najviša	286	270	.	.	.	.	.	180	.	64	.	.	.	.	.	95	.
		Osnovna referenca	286	270	.	.	.	.	180	.	.	64	.	.	.	.	95	.	.
		Najniža	286	270	.	.	.	.	180	.	.	64	.	.	.	.	95	.	.
Leipzig	Frankfurt	Najviša	310	210	.	.	180	.	.	.	.	89	.	.	103	.	.	.	.
		Osnovna referenca	310	210	.	180	.	.	.	.	.	89	.	103	.	.	.	.	.
		Najniža	310	210	.	180	.	.	.	.	.	89	.	103	.	.	.	.	.
	Munchen	Najviša	354	345	.	.	190	.	.	.	.	62	.	.	112	.	.	.	.
		Osnovna referenca	354	345	.	190	.	.	.	.	.	62	.	112	.	.	.	.	.
		Najniža	354	345	.	190	.	.	.	.	.	62	.	112	.	.	.	.	.
Lille	Rennes	Najviša	448	237	.	200	.	.	.	.	.	114	.	135	.	.	.	.	.
		Osnovna referenca	448	237	200	.	.	.	.	.	.	114	135	.	.	.	.	.	.
		Najniža	448	237	200	.	.	.	.	.	.	114	135	.	.	.	.	.	.
Madrid	Bilbao	Najviša	327	300	.	.	.	.	.	130	.	65	.	.	.	.	.	151	.
		Osnovna referenca	327	300	.	.	.	.	130	.	.	65	.	.	.	.	151	.	.
		Najniža	327	300	.	.	.	.	130	.	.	65	.	.	.	.	151	.	.
	Bordeaux	Najviša	543	495	.	.	.	.	.	260	.	66	.	.	.	.	.	125	.
		Osnovna referenca	543	495	.	.	.	.	260	.	.	66	.	.	.	.	125	.	.
		Najniža	543	495	.	.	.	.	260	.	.	66	.	.	.	.	125	.	.
	San Sebastian	Najviša	363	300	.	.	.	.	.	135	.	73	.	.	.	.	.	161	.
		Osnovna referenca	363	300	.	.	.	.	135	.	.	73	.	.	.	.	161	.	.
		Najniža	363	300	.	.	.	.	135	.	.	73	.	.	.	.	161	.	.
	Santiago	Najviša	476	330	.	.	180	.	.	.	.	87	.	.	159	.	.	.	.
		Osnovna referenca	476	330	.	180	.	.	.	.	.	87	.	159	.	.	.	.	.
		Najniža	476	330	.	180	.	.	.	.	.	87	.	159	.	.	.	.	.
	Vigo	Najviša	455	372	.	.	230	.	.	.	.	73	.	.	119	.	.	.	.
		Osnovna referenca	455	372	.	230	.	.	.	.	.	73	.	119	.	.	.	.	.
		Najniža	455	372	.	230	.	.	.	.	.	73	.	119	.	.	.	.	.
Munchen	Berlin	Najviša	481	360	.	.	245	.	.	.	.	80	.	.	118	.	.	.	.
		Osnovna referenca	481	360	.	245	.	.	.	.	.	80	.	118	.	.	.	.	.
		Najniža	481	360	.	245	.	.	.	.	.	80	.	118	.	.	.	.	.
	Zurich	Najviša	260	250	.	.	.	.	195	.	.	62	.	.	.	.	80	.	.
		Osnovna referenca	260	250	.	.	.	195	.	.	.	62	.	.	.	80	.	.	.
		Najniža	260	250	.	.	.	195	.	.	.	62	.	.	.	80	.	.	.
Pariz	Bordeaux	Najviša	519	182	.	125	.	.	.	.	.	171	.	249	.	.	.	.	.
		Osnovna referenca	519	182	125	.	.	.	.	.	.	171	249	.	.	.	.	.	.
		Najniža	519	182	125	.	.	.	.	.	.	171	249	.	.	.	.	.	.
	Brest	Najviša	511	250	.	180	.	.	.	.	.	123	.	170	.	.	.	.	.
		Osnovna referenca	511	250	180	.	.	.	.	.	.	123	170	.	.	.	.	.	.
		Najniža	511	250	180	.	.	.	.	.	.	123	170	.	.	.	.	.	.
	Madrid	Najviša	1062	595	.	565	.	.	.	445	.	107	.	113	.	.	.	143	.
		Osnovna referenca	1062	595	565	.	.	.	445	.	.	107	113	.	.	.	143	.	.
		Najniža	1062	595	565	.	.	.	445	.	.	107	113	.	.	.	143	.	.
	Montpellier	Najviša	600	210	.	180	.	.	.	.	.	171	.	200	.	.	.	.	.
		Osnovna referenca	600	210	180	.	.	.	.	.	.	171	200	.	.	.	.	.	.
		Najniža	600	210	180	.	.	.	.	.	.	171	200	.	.	.	.	.	.
	Rennes	Najviša	326	127	.	90	.	.	.	.	.	154	.	217	.	.	.	.	.
		Osnovna referenca	326	127	90	.	.	.	.	.	.	154	217	.	.	.	.	.	.
		Najniža	326	127	90	.	.	.	.	.	.	154	217	.	.	.	.	.	.
	Toulouse	Najviša	596	296	.	243	.	.	.	.	190	121	.	147	.	.	.	.	188
		Osnovna referenca	596	296	243	.	.	.	.	.	190	121	147	.	.	.	.	.	188
		Najniža	596	296	243	.	.	.	.	.	190	121	147	.	.	.	.	.	188
Strasbourg	Pariz	Najviša	381	140	110	.	.	.	.	.	.	163	208	.	.	.	.	.	.
		Osnovna referenca	381	140	110	.	.	.	.	.	.	163	208	.	.	.	.	.	.
		Najniža	381	140	110	.	.	.	.	.	.	163	208	.	.	.	.	.	.
Tours	Bordeaux	Najviša	314	155	.	90	.	.	.	.	.	122	.	210	.	.	.	.	.
		Osnovna referenca	314	155	90	.	.	.	.	.	.	122	210	.	.	.	.	.	.
		Najniža	314	155	90	.	.	.	.	.	.	122	210	.	.	.	.	.	.
Zurich	Milan	Najviša	221	220	.	.	.	.	160	.	.	60	.	.	.	.	83	.	.
		Osnovna referenca	221	220	.	.	.	160	.	.	.	60	.	.	.	83	.	.	.
		Najniža	221	220	.	.	.	160	.	.	.	60	.	.	.	83	.	.	.

Izvor: *[8] (prilagodio autor).*

3.3.2.4 Prognoza IFR kretanja zrakoplova

Broj IFR kretanja zrakoplova ovisi o odnosu ponude i potražnje te na njih utječe velik broj čimbenika kao što su: gospodarstvo, propisi, demografija, poslovni razvoj, cijena goriva te razvoj brze željeznice. Prilikom prognoziranja, koriste se čimbenici i podaci koji govore o sadašnjoj i budućoj potražnji (trenutno stanje IFR kretanja zrakoplova i budući red letenja). Jedni su podaci važni za kratkoročno razdoblje (npr. red letenja zračnog prijevoznika), dok su drugi podaci bitni u srednjoročnom razdoblju (npr. demografija). Tri najutjecajnija ulazna podatka za prognozu su:

1) **prognoza ekonomskog rasta** dobivena od vanjskih stručnjaka koja često pokazuje varijacije, usporeni rast na temelju podataka ili bez ikakvih naznaka da bi rast IFR kretanja zrakoplova mogao odstupati od gospodarskog rasta;
2) **propisi**, npr. pravila o vizama, sporazum o zračnom prometu između EU-a i SAD-a (engl. *Open Skies*[54] *agreement*), financiranje zračnih luka, zrakoplovni porezi;
3) **preleti**[55] (engl. *Overflight* – O), jer su zastupljeni u većini država [8].

Prognoza IFR kretanja zrakoplova izrađuje se u četiri faze:

1) početna godišnja prognoza uzima u obzir širok raspon gospodarskih, transportnih i drugih trendova;
2) kombinacija godišnje prognoze s trendovima mjesečne prognoze koja je pod utjecajem analiza nedavnih trendova, gospodarstva i planova te promatra vremensko razdoblje od dvije godine;
3) ograničenje kapaciteta zračnih luka koja generiraju promet između parova zračnih luka;
4) mreža zračnog prostora omogućava brojanje IFR kretanja zrakoplova u svakom zračnom prostoru države ili regije [31].

[54]Odluka Europske unije koja odobrava potpisivanje Sporazuma o zračnom prometu koji je uspostavljen sa Sjedinjenim Američkim Državama. Sporazumom se omogućuje otvaranje svih transatlantskih ruta zračnih prijevoznika iz EU-a i SAD-a. Također uključuje dogovor o dodatnom razvijanju sporazuma o temama vlasništva i kontrole nad zračnim prijevoznicima [33].

[55]Podrazumijeva IFR kretanje zrakoplova koje započinje ulazom i završava izlazom zrakoplova iz određenog volumena zračnog prostora koji je predmetom zrakoplovnih usluga [2].

Prognostički trendovi IFR kretanja zrakoplova (tablica 11 i 14):

1) očekuju rast broja letova u Europi[56] od 2,9 % u 2017. godini (+ ili - 1,4 %);
2) za 2018. godinu predviđaju rast od 1,9 % (+ ili - 1,3 %);
3) očekuju stabilan europski rast broja letova na godišnjoj razini od 1,7 % u vremenskom periodu od 2019. do 2023. godine;
4) prognoziraju za 2023. godinu 11,6 milijuna IFR kretanja zrakoplova (+ ili - 1,2 milijuna) na području Europe, što je 14 % više u odnosu na 2016. godinu;
5) nastavljaju promatrati različite stope rasta po državama, potaknuti različitim trendovima gospodarskog rasta i promjenama u turističkoj potražnji i odabiru ruta [8].

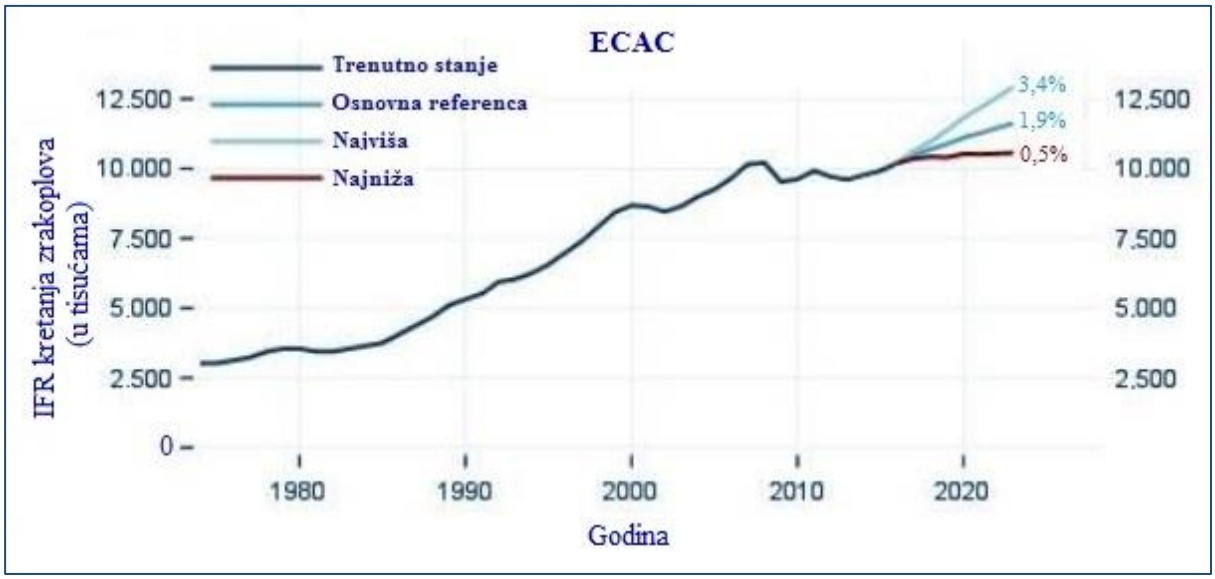
Tablica 11: *Prognostički trendovi IFR kretanja zrakoplova i njihov godišnji rast na području Europe*

IFR kretanja zrakoplova	Stopa rasta	IFR kretanja zrakoplova (u tisućama)											Prosječna godišnja stopa rasta (2023-2016)	Prosječna godišnja stopa rasta za RP2 (2019-2014)
		2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023		
Domaći	Najviša	.	.	.	.	8.442	8.683	8.965	9.271	9.506	9.743	9.980	3,0%	3,1%
	Osnovna referenca	7.576	7.681	7.856	8.141	8.330	8.460	8.584	8.734	8.823	8.933	9.036	1,5%	2,2%
	Najniža	.	.	.	.	8.224	8.249	8.206	8.287	8.254	8.245	8.235	0,2%	1,3%
Odlazni i dolazni	Najviša	.	.	.	.	1.999	2.084	2.192	2.321	2.431	2.547	2.669	5,1%	2,8%
	Osnovna referenca	1.863	1.908	1.890	1.884	1.975	2.036	2.095	2.166	2.226	2.292	2.357	3,3%	1,9%
	Najniža	.	.	.	.	1.948	1.985	2.004	2.040	2.062	2.089	2.117	1,7%	1,0%
Preleti	Najviša	.	.	.	.	191	200	212	225	239	255	272	6,8%	3,2%
	Osnovna referenca	165	181	177	172	187	193	210	209	217	226	236	4,7%	2,1%
	Najniža	.	.	.	.	182	187	191	196	200	205	210	2,9%	1,0%
Ukupno	Najviša	.	.	.	.	10.632	10.967	11.369	11.818	12.176	12.545	12.920	3,4%	3,1%
	Osnovna referenca	9.603	9.770	9.923	10.197	10.492	10.689	10.880	11.109	11.266	11.451	11.629	1,9%	2.2%
	Najniža	.	.	.	.	10.355	10.421	10.401	10.523	10.516	10.539	10.561	0,5%	1,3%

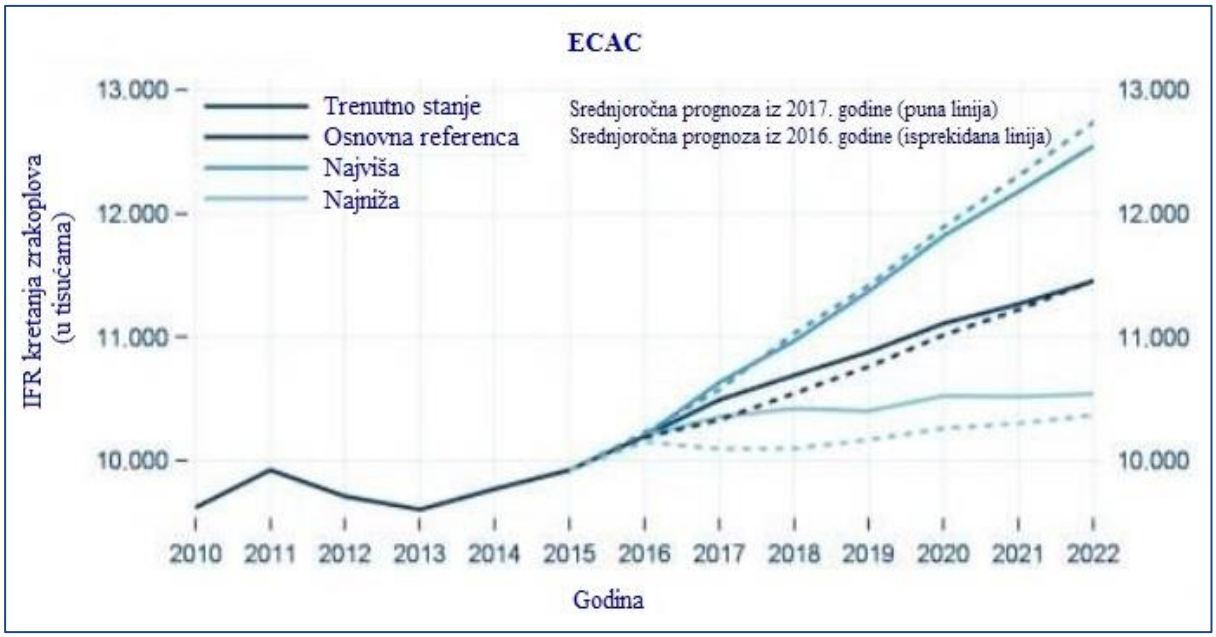
Izvor: *[8] (prilagodio autor).*

[56]Podrazumijeva ECAC područje, osim ako nije drugačije navedeno [8].

Na grafikonu 4 i 5 prikazana je krivulja IFR kretanja zrakoplova u tisućama koja se temelji na raspoloživim povijesnim podacima. Krivulja prikazuje približno linearan trend rasta do 2008. godine, nakon kojeg dolazi do naglog pada IFR kretanja zrakoplova do sljedeće godine. Nakon 2009. godine započinje blagi rast IFR kretanja zrakoplova sve do 2017. godine. Referentna godina za koju su iskazane stope rasta na krivulji je 2017. godina. Najveća stopa rasta je 3,4 % s osnovnom referencom između njih od 1,9 % i najmanjom stopom rasta od 0,5 %.

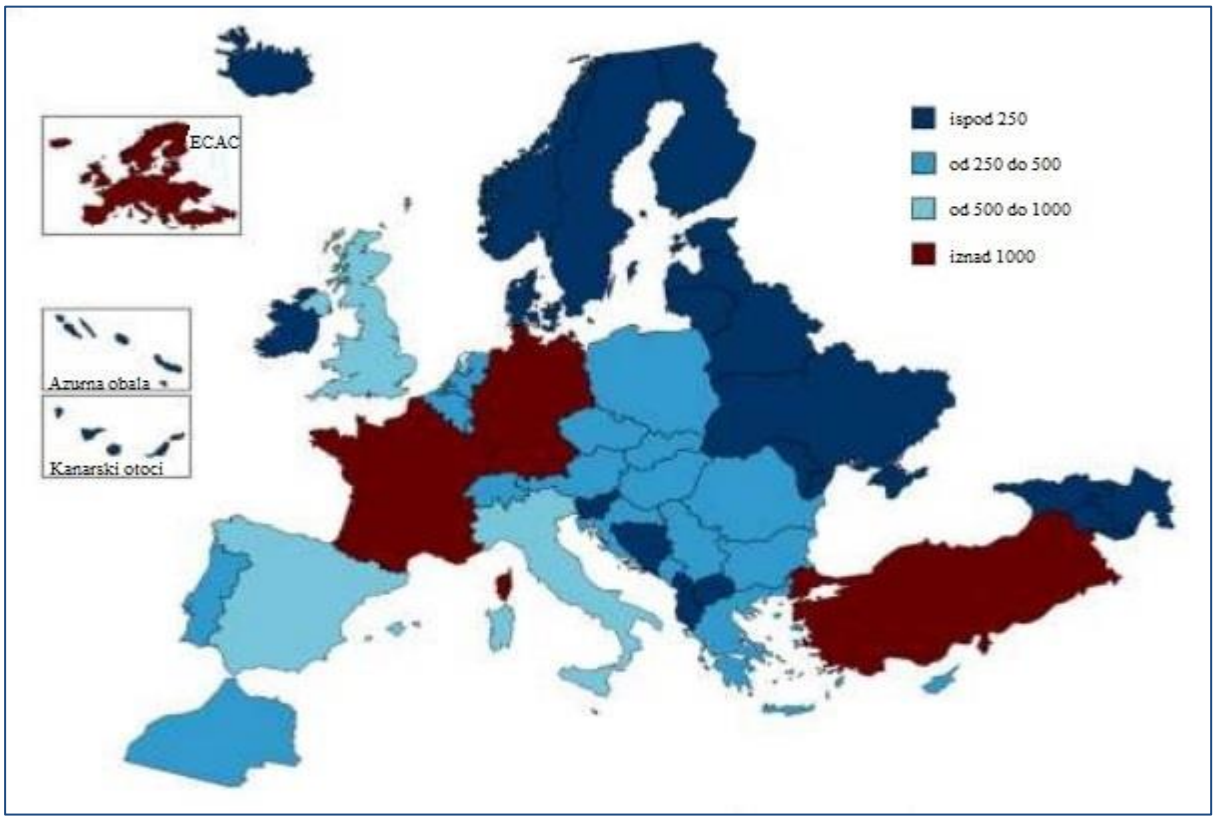


Grafikon 4: *Shematski prikaz godišnjeg rasta IFR kretanja zrakoplova tijekom prethodna četiri desetljeća na području Europe (ECAC), referentna godina za tri scenarija rasta je 2017. godina [8] (prilagodio autor).*



Grafikon 5: *Shematski prikaz očekivanog broja IFR kretanja zrakoplova na području ECAC-a u komparaciji s prethodnom sedmogodišnjom prognozom iz rujna 2016. godine [8] (prilagodio autor).*

Stopa rasta IFR kretanja zrakoplova na većini tržišta zapadne Europe je puno manja u odnosu na ostatak Europe. Najprometnije države su još uvijek Francuska, Njemačka, Španjolska, Velika Britanija i Italija (slika 14) koje se suočavaju s najvećim brojem dodatnih letova dnevno. Turska će i dalje imati jednu od najbržih stopa rasta (prosječna godišnja stopa rasta od 3,8 % u razdoblju od sedam godina) s najvećim brojem dodatnih letova dnevno (dodatnih 1.089 letova dnevno u 2023. godini) [8].



Slika 14: *Shematski prikaz dodatnog broja IFR kretanja zrakoplova po danu od 2016. do 2023. godine [8] (prilagodio autor).*

3.3.2.4.1 Ograničenja kapaciteta zračnih luka

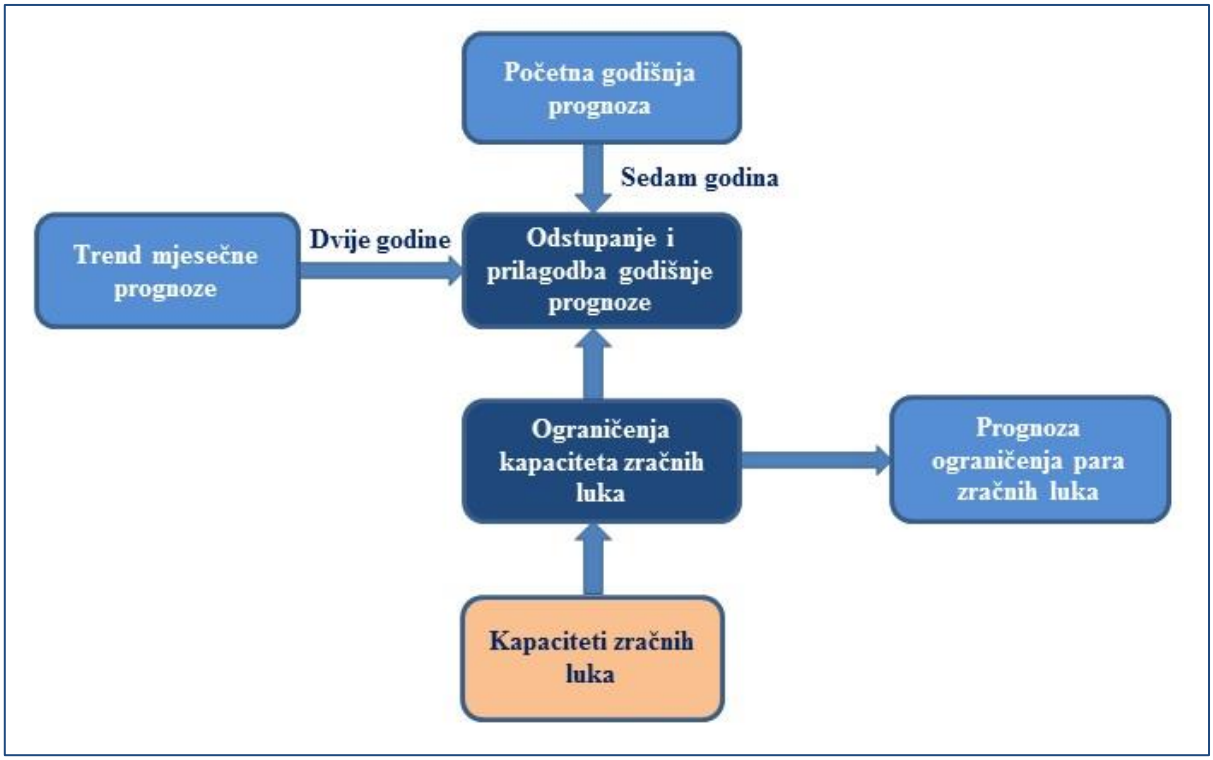
Zbog ograničenja kapaciteta u zračnim lukama (tablica 12), potražnja od 197.000 IFR kretanja zrakoplova neće moći biti opslužena do 2023. godine, što predstavlja manju stopu rasta od 1,7 % odnosno oko 0,2 % manje na godišnjoj razini. Zračne luke predaju planove kapaciteta EUROCONTROL-ovoj jedinici koja se prvenstveno bavi zračnim lukama u sklopu NM-a. Izračunava učinke ograničenja kapaciteta zračne luke uspoređujući objavljene prognoze s onim „što ako“. Pretpostavka je da zračne luke žele isporučiti vlastiti plan kapaciteta, što do sada nije bilo uobičajeno [8].

Tablica 12: *Utjecaj ograničenja zračnih luka na IFR kretanja zrakoplova*

Ograničenja zračne luke		Promjena IFR kretanja zrakoplova (u tisućama)							Promjena IFR kretanja zrakoplova (u postotcima)						
		2017	2018	2019	2020	2021	2022	2023	2017	2018	2019	2020	2021	2022	2023
Stopa rasta	Najviša	26,3	62,5	137,9	165,0	231,0	340,4	449,6	0,2%	0,6%	1,2%	1,4%	1,9%	2,7%	3,4%
	Osnovna referenca	**9,3**	**22,6**	**51,5**	**74,2**	**105,3**	**145,9**	**197,3**	**0,1%**	**0,2%**	**0,5%**	**0,7%**	**0,9%**	**1,3%**	**1,7%**
	Najniža	1,3	1,9	0,1	4,8	14,7	26,6	40,0	0,0%	0,0%	0,0%	0,0%	0,1%	0,3%	0,4%

Izvor: *[8] (prilagodio autor).*

Početna godišnja prognoza usklađuje se s trendom mjesečne prognoze. Rezultat rasta između para zračnih luka za sve vrste letova (putnici, teret i sl.) uspoređuje se s budućim kapacitetima zračnih luka (slika 15). Rast je ograničen kapacitetima zračnih luka [31].



Slika 15: *Metoda prognoziranja ograničenja po parovima zračnih luka [31] (prilagodio autor).*

Završni korak je izračun koliko će se letova generirati u zračnom prostoru između parova zračnih luka. Takav izračun moguće je obaviti na temelju kombinacije rutiranja kroz zračni prostor za navedenu godinu i trendova rasta preleta zabilježenih između prometnih zona [31].

3.3.2.4.2 Utjecaj željeznica velikih brzina

Proširenje željeznica velikih brzina smanjuje rast IFR kretanja zrakoplova od 0,5 % u narednih sedam godina prognoze. U prognostičkom modelu, smanjeno vrijeme putovanja uzrokovano vlakovima velikih brzina dovelo je do smanjenja broja IFR kretanja zrakoplova na istom paru gradova [8].

U tablici 13 je prikazan ukupan broj izgubljenih IFR kretanja zrakoplova uzrokovano modernizacijom željezničke mreže primjenom HST-a. Do 2023. godine procjenjuje se gubitak od 58.400 letova, što je učinak od 0,5 % u narednih sedam godina prognoze. Utjecaj HST-a smanjuje se u usporedbi s apsolutnim rezultatima prognoze objavljene u veljači 2016. godine, koja ukazuje na 64.600 letova manje u narednih sedam godina prognoze. Međutim, na određenim parovima gradova učinak može biti poprilično velik, posebno na kraju prognostičkog razdoblja [8]. Što se tiče država, Turska, Francuska, Španjolska i Njemačka osjetit će najveći utjecaj na mrežu IFR kretanja zrakoplova s manje od 16.200 letova, 15.000 letova, 11.900 letova i 11.300 letova koji će biti preusmjereni s mreže zbog utjecaja HST-a do 2023. godine, što odgovara stopama od 1,8 %, 1,4 %, 1,4 % i 0,9 % njihovog unutarnjeg prometa.

Tablica 13: *Utjecaj vlakova velikih brzina na IFR kretanja zrakoplova*

Vlakovi velikih brzina		Promjena IFR kretanja zrakoplova (u tisućama)							Promjena IFR kretanja zrakoplova (u postotcima)						
		2017	2018	2019	2020	2021	2022	2023	2017	2018	2019	2020	2021	2022	2023
Stopa rasta	Najviša	0,0	15,3	46,5	54,8	57,9	66,6	81,8	-0,1%	0,1%	0,4%	0,5%	0,5%	0,5%	0,6%
	Osnovna referenca	0,9	27,4	35,4	38,1	45,1	50,4	58,4	0,0%	0,3%	0,3%	0,3%	0,4%	0,4%	0,5%
	Najniža	0,9	26,7	33,4	35,8	41,3	45,3	51,4	0,0%	0,3%	0,3%	0,3%	0,4%	0,4%	0,5%
Osnovna referenca	Francuska	0,8	11,5	11,6	11,9	12,2	12,2	15,0	0,1%	1,2%	1,2%	1,2%	1,2%	1,2%	1,4%
	Njemačka	.	3,9	8,8	9,4	10,2	10,5	11,3	.	0,3%	0,7%	0,8%	0,8%	0,9%	0,9%
	Španjolska	.	2,1	4,1	4,1	7,9	11,8	11,9	.	0,3%	0,5%	0,5%	0,9%	1,4%	1,4%
	Turska	.	7,8	9,0	9,9	10,8	11,8	16,2	.	1,1%	1,2%	1,3%	1,3%	1,3%	1,8%

Izvor: *[8] (prilagodio autor).*

3.3.2.4.3 Utjecaj rizika na prognozu

U pojedinim državama odabir ruta zračnog prijevoznika smanjuje rizik, dok u drugim državama povećava rizik, stoga je neophodna ravnoteža europskog područja kao cjeline:

1) do 2023. godine postoji velika vjerojatnost povratka letova iznad Ukrajine;
2) zatvaranje libijskog zračnog prostora smanjio je broj preleta iznad Malte i preusmjerio promet prema južnoj Africi. Broj preleta za Maltu djelomično je nadoknađen snažnim rastom prometa između Rusije i Tunisa;
3) sirijski sukob ima značajan utjecaj na broj preleta diljem jugoistočne Europe. U prognozu nije uključen ni prekid niti jačanje sukoba, iako se u nekom trenutku očekuje poremećaj mreže i smanjenje broja preleta. Zaobilaženje Iraka i u manjoj mjeri Sinai-a ima manji značaj na prognozu;
4) migracijska kriza potaknuta sirijskim i libijskim sukobima te odgovor vlada na obustavu Schengenskog sustava barem na dvije godine kako bi se ostvario povratak putničkih putovanja;
5) prethodnih godina zabilježen je manji *en-route* kapacitet zbog uvođenja novih sustava ATC-a. Rezultira taktičkim i strateškim rerutiranjem prometa, dovoljno da utječe na godišnji iznos. Niz promjena koje slijede predstavljaju daljnji rizik, posebno za Njemačku, Gruziju, Maltu i Rumunjsku;
6) strujanje vjetra[57] (engl. *jet stream*) također utječe na izbor rute, iako je češći učinak tijekom dana ili tjedana nego tijekom cijele godine;
7) broj jedinica usluge je jedan od čimbenika koji utječe na izbor ruta zračnog prijevoznika. Velike promjene u naknadama mogu prouzročiti manje postotne promjene u broju letova;
8) cijene nafte su i dalje promjenjive. S obzirom na to da se na gorivo odnosi oko 20% operativnih troškova, postoji mogućnost utjecaja na cijenu i putne troškove korisnika. U kratkoročnom razdoblju postoji veći rizik ako zračni prijevoznici krenu odražavati pad troškova goriva na cijenu karata;
9) općenito govoreći, buduće promjene u rutnoj mreži (npr. nove rute) i promjene u izboru ruta zračnih prijevoznika ne uzimaju se u obzir za prognozu [8].

[57] Svjetska meteorološka organizacija definira kao ravna cjevasta struja zraka, kvazi-horizontalna, čija os je duž linije maksimalne brzine i koju ne karakteriziraju samo velike brzine već i snažne poprečne (horizontalne i vertikalne) gradijente brzine [34].

Tablica 14: *Sedmogodišnja prognoza IFR kretanja zrakoplova po državama na području Europe*

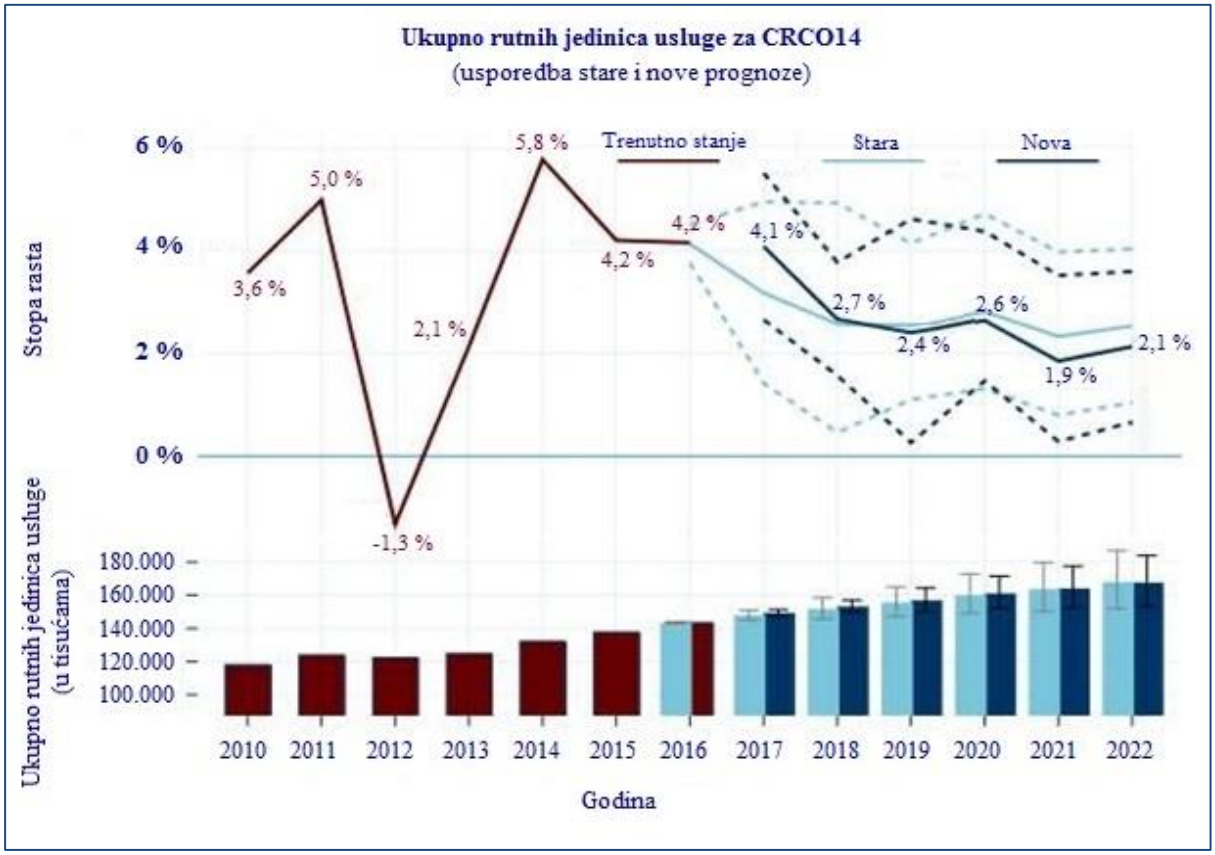
Država	Stopa rasta	IFR kretanja zrakoplova (u tisućama)												Prosječna godišnja stopa rasta (2023-2016)	Prosječna godišnja stopa rasta za RP2 (2019-2014)
		2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023		
Albanija	Najviša	.	.	.	.	.	193	202	214	226	236	248	259	4,8%	.
	Osnovna referenca	195	201	198	202	187	190	196	202	209	214	221	227	2,8%	.
	Najniža	.	.	.	.	.	187	190	191	194	196	199	201	1,0%	.
Armenija	Najviša	.	.	.	.	.	42	44	45	47	48	49	51	3,8%	.
	Osnovna referenca	56	52	51	42	39	41	43	44	45	46	46	47	2,8%	.
	Najniža	.	.	.	.	.	41	42	43	43	44	44	45	2,0%	.
Austrija	Najviša	.	.	.	.	.	1.222	1.266	1.323	1.379	1.426	1.473	1.520	3,8%	2,8%
	Osnovna referenca	1.333	1.114	1.152	1.168	1.174	1.205	1.232	1.257	1.285	1.305	1.328	1.351	2,0%	1,8%
	Najniža	.	.	.	.	.	1.187	1.197	1.194	1.208	1.207	1.210	1.212	0,5%	0,7%
Azerbajdžan	Najviša	.	.	.	.	.	139	147	156	167	177	187	198	5,6%	.
	Osnovna referenca	130	129	127	129	135	137	143	149	156	162	169	176	3,8%	.
	Najniža	.	.	.	.	.	135	140	143	147	150	154	158	2,2%	.
Belgija i Luksemburg	Najviša	.	.	.	.	.	1.248	1.285	1.327	1.380	1.414	1.442	1.471	3,1%	3,2%
	Osnovna referenca	1.089	1.101	1.133	1.165	1.188	1.234	1.259	1.276	1.300	1.316	1.335	1.351	1,9%	2,4%
	Najniža	.	.	.	.	.	1.219	1.229	1.222	1.232	1.230	1.231	1.231	0,5%	1,5%
Bjelorusija	Najviša	.	.	.	.	.	295	307	321	335	348	361	374	4,4%	.
	Osnovna referenca	240	255	269	263	278	291	298	304	311	317	324	330	2,5%	.
	Najniža	.	.	.	.	.	286	290	289	291	292	293	295	0,9%	.
Bosna i Hercegovina	Najviša	.	.	.	.	.	330	343	362	380	396	412	430	4,3%	.
	Osnovna referenca	268	262	298	311	319	325	333	342	352	360	368	377	2,4%	.
	Najniža	.	.	.	.	.	320	323	324	328	330	332	334	0,7%	.
Bugarska	Najviša	.	.	.	.	.	787	823	868	917	959	1.004	1.050	4,8%	4,9%
	Osnovna referenca	540	551	683	767	758	777	801	826	851	873	897	921	2,8%	3,9%
	Najniža	.	.	.	.	.	765	779	785	801	807	815	824	1,2%	2,8%
Cipar	Najviša	.	.	.	.	.	347	367	395	424	451	482	515	6,9%	5,3%
	Osnovna referenca	270	277	304	319	322	339	354	369	385	400	417	434	4,4%	3,9%
	Najniža	.	.	.	.	.	332	341	346	354	360	368	375	2,2%	2,6%
Češka	Najviša	.	.	.	.	.	855	891	934	978	1.016	1.053	1.089	4,5%	5,9%
	Osnovna referenca	679	680	700	746	797	843	865	883	905	921	939	957	2,6%	4,7%
	Najniža	.	.	.	.	.	830	840	838	859	860	862	865	1,2%	3,7%
Danska	Najviša	.	.	.	.	.	661	680	699	725	743	760	778	2,8%	2,5%
	Osnovna referenca	605	618	619	626	640	654	666	674	685	691	699	706	1,4%	1,7%
	Najniža	.	.	.	.	.	646	651	647	650	647	645	644	0,1%	0,9%
Estonija	Najviša	.	.	.	.	.	210	220	230	242	252	262	273	4,5%	3,7%
	Osnovna referenca	189	183	191	194	200	207	214	218	224	229	234	240	2,6%	2,7%
	Najniža	.	.	.	.	.	204	208	207	210	211	212	213	0,9%	1,6%
Finska	Najviša	.	.	.	.	.	260	266	273	282	289	297	305	3,1%	2,0%
	Osnovna referenca	252	243	248	248	247	256	259	262	266	268	271	274	1,5%	1,1%
	Najniža	.	.	.	.	.	253	253	250	251	249	248	247	0,0%	0,2%
Francuska	Najviša	.	.	.	.	.	3.279	3.372	3.475	3.611	3.690	3.774	3.857	3,1%	3,3%
	Osnovna referenca	2.923	2.902	2.947	2.992	3.124	3.235	3.293	3.339	3.411	3.453	3.501	3.539	1,8%	2,5%
	Najniža	.	.	.	.	.	3.192	3.210	3.194	3.209	3.200	3.201	3.200	0,3%	1,6%
Grčka	Najviša	.	.	.	.	.	728	758	803	851	894	941	991	5,1%	3,4%
	Osnovna referenca	633	623	678	713	700	717	735	757	784	807	832	857	2,9%	2,2%
	Najniža	.	.	.	.	.	705	713	717	729	736	745	755	1,1%	1,1%
Gruzija	Najviša	.	.	.	.	.	132	139	149	159	168	178	189	6,0%	.
	Osnovna referenca	108	110	116	122	126	130	136	142	148	154	160	167	4,1%	.
	Najniža	.	.	.	.	.	128	132	135	140	143	146	150	2,5%	.
Hrvatska	Najviša	.	.	.	.	.	571	597	630	662	689	718	747	4,7%	3,9%
	Osnovna referenca	495	492	520	535	540	563	580	596	613	626	641	656	2,8%	2,8%
	Najniža	.	.	.	.	.	554	563	564	571	573	577	581	1,1%	1,7%
Irska	Najviša	.	.	.	.	.	631	650	670	688	699	711	722	2,4%	4,5%
	Osnovna referenca	521	522	537	566	610	625	638	650	665	673	680	686	1,7%	3,9%
	Najniža	.	.	.	.	.	618	625	626	632	635	639	642	0,7%	3,1%
Island	Najviša	.	.	.	.	.	196	205	214	225	234	244	255	5,1%	.
	Osnovna referenca	123	131	145	160	180	194	201	206	212	218	224	230	3,5%	.
	Najniža	.	.	.	.	.	192	197	198	202	204	206	209	2,2%	.
Italija	Najviša	.	.	.	.	.	1.795	1.867	1.959	2.047	2.119	2.196	2.275	4,0%	3,1%
	Osnovna referenca	1.685	1.648	1.680	1.696	1.734	1.768	1.811	1.847	1.888	1.916	1.950	1.983	1,9%	1,9%
	Najniža	.	.	.	.	.	1.741	1.755	1.743	1.751	1.745	1.745	1.744	0,1%	0,7%
Kanarski otoci	Najviša	.	.	.	.	.	335	347	363	377	389	402	416	4,3%	5,1%
	Osnovna referenca	275	265	284	281	310	330	337	343	348	352	357	362	2,2%	3,9%
	Najniža	.	.	.	.	.	325	327	325	325	323	322	321	0,5%	2,8%
Latvija	Najviša	.	.	.	.	.	261	271	284	298	309	321	333	4,4%	3,2%
	Osnovna referenca	233	236	243	244	246	257	263	268	273	278	282	287	2,2%	2,0%
	Najniža	.	.	.	.	.	253	255	253	255	254	254	254	0,4%	0,8%
Lisabon FIR	Najviša	.	.	.	.	.	612	637	665	690	712	735	759	4,5%	6,7%
	Osnovna referenca	438	449	480	505	559	603	617	627	639	647	656	665	2,5%	5,5%
	Najniža	.	.	.	.	.	594	599	593	593	590	588	586	0,7%	4,3%
Litva	Najviša	.	.	.	.	.	274	286	298	312	323	335	346	4,1%	3,0%
	Osnovna referenca	236	242	257	260	261	270	277	282	288	292	297	302	2,1%	1,9%
	Najniža	.	.	.	.	.	265	269	267	269	268	268	269	0,4%	0,7%

Država	Stopa rasta	IFR kretanja zrakoplova (u tisućama)												Prosječna godišnja stopa rasta (2023-2016)	Prosječna godišnja stopa rasta za RP2 (2019-2014)
		2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023		
Mađarska	Najviša	.	.	.	.	.	818	855	900	948	990	1.033	1.077	4,8%	6,1%
	Osnovna referenca	589	600	670	744	776	806	831	853	877	897	919	942	2,8%	4,9%
	Najniža	.	.	.	.	.	794	807	810	824	829	835	841	1,2%	3,9%
Makedonija	Najviša	.	.	.	.	.	151	157	165	173	180	188	196	4,3%	.
	Osnovna referenca	113	113	146	152	146	148	152	157	161	165	169	173	2,5%	.
	Najniža	.	.	.	.	.	146	147	148	150	152	153	155	0,9%	.
Malta	Najviša	.	.	.	.	.	115	122	132	143	153	165	178	7,2%	5,4%
	Osnovna referenca	97	109	102	102	110	113	117	123	129	134	141	147	4,3%	3,8%
	Najniža	.	.	.	.	.	111	113	115	118	121	123	126	2,0%	2,5%
Maroko	Najviša	.	.	.	.	.	414	437	470	503	536	573	615	7,0%	.
	Osnovna referenca	324	334	359	361	383	407	422	438	455	471	488	506	4,0%	.
	Najniža	.	.	.	.	.	401	408	411	418	422	427	432	1,7%	.
Moldavija	Najviša	.	.	.	.	.	48	51	54	58	61	64	68	7,2%	.
	Osnovna referenca	64	74	56	45	42	47	49	51	53	54	56	58	4,8%	.
	Najniža	.	.	.	.	.	46	47	48	49	49	50	51	2,8%	.
Nizozemska	Najviša	.	.	.	.	.	1.293	1.321	1.351	1.388	1.416	1.442	1.468	2,4%	3,5%
	Osnovna referenca	1.083	1.109	1.138	1.176	1.241	1.284	1.302	1.316	1.333	1.345	1.358	1.370	1,4%	3,0%
	Najniža	.	.	.	.	.	1.273	1.282	1.278	1.290	1.287	1.288	1.288	0,5%	2,4%
Norveška	Najviša	.	.	.	.	.	600	613	622	647	660	675	690	2,1%	0,1%
	Osnovna referenca	587	610	619	603	599	593	600	605	611	613	617	621	0,5%	-0,4%
	Najniža	.	.	.	.	.	587	588	583	581	574	570	566	-0,8%	-1,2%
Njemačka	Najviša	.	.	.	.	.	3.295	3.391	3.499	3.621	3.713	3.806	3.896	3,1%	2,9%
	Osnovna referenca	3.018	2.990	3.030	3.080	3.146	3.256	3.314	3.354	3.415	3.454	3.501	3.546	1,7%	2,1%
	Najniža	.	.	.	.	.	3.215	3.234	3.219	3.295	3.289	3.292	3.295	0,7%	1,2%
Poljska	Najviša	.	.	.	.	.	806	848	899	948	992	1.028	1.065	5,0%	5,1%
	Osnovna referenca	684	692	702	699	755	792	820	843	868	887	908	930	3,0%	3,7%
	Najniža	.	.	.	.	.	779	793	793	808	809	813	817	1,1%	2,5%
Rumunjska	Najviša	.	.	.	.	.	663	694	733	773	810	847	885	5,2%	4,1%
	Osnovna referenca	487	513	598	635	621	654	674	694	714	732	751	771	3,2%	3,0%
	Najniža	.	.	.	.	.	644	655	658	670	674	680	686	1,5%	1,9%
Slovačka	Najviša	.	.	.	.	.	530	554	584	615	642	670	698	5,0%	6,0%
	Osnovna referenca	381	397	436	468	498	522	538	552	568	581	595	610	2,9%	4,8%
	Najniža	.	.	.	.	.	514	523	524	534	537	541	545	1,3%	3,7%
Slovenija	Najviša	.	.	.	.	.	369	386	406	425	441	458	475	4,3%	3,1%
	Osnovna referenca	346	329	348	347	353	364	376	385	395	403	412	421	2,5%	2,0%
	Najniža	.	.	.	.	.	358	365	365	370	371	373	375	0,9%	1,0%
Srbija i Crna Gora	Najviša	.	.	.	.	.	646	673	709	745	776	809	843	4,5%	.
	Osnovna referenca	535	518	554	605	619	637	653	672	691	707	724	741	2,6%	.
	Najniža	.	.	.	.	.	627	634	637	646	649	654	660	0,9%	.
Sveta Marija FIR	Najviša	.	.	.	.	.	161	167	174	181	186	192	199	4,0%	6,9%
	Osnovna referenca	118	121	125	136	151	159	164	167	171	174	177	181	2,6%	6,0%
	Najniža	.	.	.	.	.	157	160	160	162	163	164	165	1,2%	5,2%
Španjolska	Najviša	.	.	.	.	.	1.891	1.974	2.065	2.148	2.219	2.292	2.365	4,3%	5,4%
	Osnovna referenca	1.557	1.528	1.587	1.640	1.766	1.863	1.915	1.953	1.997	2.026	2.058	2.094	2,5%	4,2%
	Najniža	.	.	.	.	.	1.836	1.861	1.852	1.864	1.860	1.861	1.865	0,8%	3,1%
Švedska	Najviša	.	.	.	.	.	795	817	839	867	887	910	932	2,8%	2,6%
	Osnovna referenca	724	730	739	751	767	786	798	809	822	830	840	850	1,5%	1,8%
	Najniža	.	.	.	.	.	776	779	775	780	776	774	772	0,1%	1,0%
Švicarska	Najviša	.	.	.	.	.	1.108	1.144	1.183	1.227	1.257	1.286	1.311	3,0%	2,8%
	Osnovna referenca	1.045	1.019	1.033	1.046	1.069	1.094	1.117	1.132	1.152	1.163	1.179	1.193	1,6%	1,8%
	Najniža	.	.	.	.	.	1.078	1.087	1.080	1.085	1.080	1.079	1.078	0,1%	0,9%
Turska	Najviša	.	.	.	.	.	1.388	1.467	1.566	1.668	1.765	1.866	1.975	5,7%	.
	Osnovna referenca	1.066	1.142	1.269	1.356	1.336	1.365	1.422	1.492	1.554	1.610	1.672	1.733	3,8%	.
	Najniža	.	.	.	.	.	1.345	1.382	1.417	1.461	1.487	1.518	1.546	2,1%	.
Ukrajina	Najviša	.	.	.	.	.	224	236	254	270	285	300	316	7,2%	.
	Osnovna referenca	466	494	320	213	195	219	227	236	245	253	261	270	4,8%	.
	Najniža	.	.	.	.	.	215	218	220	225	227	230	233	2,6%	.
Ujedinjena Kraljevina	Najviša	.	.	.	.	.	2.546	2.603	2.672	2.758	2.817	2.875	2.930	2,6%	3,3%
	Osnovna referenca	2.211	2.225	2.269	2.322	2.449	2.523	2.556	2.584	2.627	2.653	2.683	2.707	1,4%	2,6%
	Najniža	.	.	.	.	.	2.496	2.505	2.492	2.509	2.508	2.513	2.518	0,4%	1,9%
ECAC	Najviša	.	.	.	.	.	10.632	10.967	11.369	11.818	12.176	12.545	12.920	3,4%	3,1%
	Osnovna referenca	9.710	9.603	9.770	9.923	10.197	10.492	10.689	10.880	11.109	11.266	11.451	11.629	1,9%	2,2%
	Najniža	.	.	.	.	.	10.355	10.421	10.401	10.523	10.516	10.539	10.561	0,5%	1,3%
ESRA08	Najviša	.	.	.	.	.	10.427	10.752	11.143	11.580	11.927	12.284	12.647	3,4%	3,0%
	Osnovna referenca	9.548	9.447	9.604	9.752	10.014	10.289	10.480	10.665	10.888	11.040	11.219	11.391	1,9%	2,1%
	Najniža	.	.	.	.	.	10.155	10.219	10.198	10.317	10.308	10.329	10.349	0,5%	1,2%
EU-28	Najviša	.	.	.	.	.	9.605	9.893	10.243	10.629	10.932	11.242	11.555	3,3%	3,1%
	Osnovna referenca	8.779	8.634	8.797	8.934	9.207	9.481	9.647	9.794	9.988	10.115	10.264	10.408	1,8%	2,2%
	Najniža	.	.	.	.	.	9.356	9.405	9.362	9.461	9.441	9.448	9.457	0,4%	1,3%
SES-RP2	Najviša	.	.	.	.	.	9.900	10.190	10.540	10.934	11.239	11.552	11.868	3,2%	3,0%
	Osnovna referenca	9.087	8.946	9.114	9.243	9.507	9.773	9.939	10.086	10.279	10.403	10.551	10.694	1,7%	2,0%
	Najniža	.	.	.	.	.	9.646	9.692	9.646	9.741	9.715	9.718	9.721	0,3%	1,1%

Izvor: *[8] (prilagodio autor).*

3.3.2.5 Prognoza rutnih jedinica usluge

Na temelju komparativnog prikaza TSU-a (grafikon 6) može se uočiti odnos stare sedmogodišnje prognoze TSU-a iz veljače 2016. godine s trenutnim stanjem iz rujna te iste godine na području CRCO14. Ako promatramo trend liniju od rujna 2016. godine, možemo uočiti pad stopa rasta do kraja prognostičkog razdoblja. Nova MTF iz veljače 2017. godine prati trend liniju prethodne godine, ali s malim rastom u odnosu na staru prognozu. Od 2018. godine smanjuje se stopa rasta TSU-a te se u vremenskom razdoblju od 2019. do 2022. godine i kreće u rasponu od 0,2 % do 0,4 %. Ako usporedimo novu MTF sa starom, vidljiva je manja stopa rasta od 0,4 milijuna TSU-a na kraju prognostičkog razdoblja. Stupčasti grafikon predstavlja godine koje su segmentirane na dva dijela. Svaki dio predstavlja sedmogodišnju prognozu TSU-a koju STATFOR objavljuje dva puta godišnje, za veljaču i rujan. Nadalje, stupci prikazuju odstupanje nove prognoze TSU-a u odnosu na staru za ukupan očekivani broj TSU-a izražen u tisućama. Detaljniji pregled podataka TSU-a po godinama može se iščitati u tablici 15.



Grafikon 6: *Komparativni prikaz objavljene sedmogodišnje prognoze TSU-a iz veljače 2017. godine s rujnom 2016. godine na području EUROCONTROL-a (CRCO14) [8] (prilagodio autor).*

Prema zadnjoj reviziji iz veljače 2017. godine (tablica 15 i 16 te grafikon 7) očekuje se ukupan TSU u državama članicama EUROCONTROL-a (CRCO14) od 170,9 milijuna u 2023. godini te se očekuje prosječna godišnja stopa rasta od 2,5 % te ukupan rast rutnih jedinica usluge od 19 % u odnosu na prethodnu 2016. godinu.

Tablica 15: *Sažetak prognoze rutnih jedinica usluge CRCO14 na području RP2 regije*

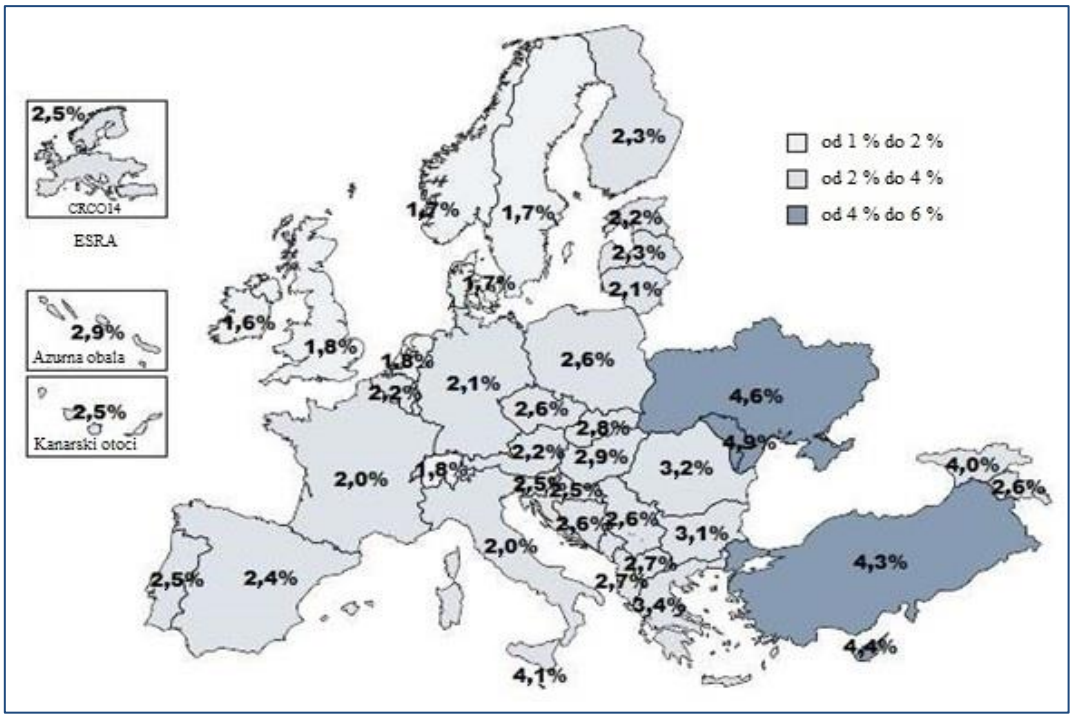
Naplatno područje	Stopa rasta	Ukupan broj rutnih jedinica usluge (u tisućama)												Ukupan rast (2023-2016)	Prosječna godišnja stopa rasta za RP2 (2019-2014)
		2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023		
CRCO14 *	Najviša	.	.	.	.	.	151.265	157.208	164.075	171.532	177.619	183.946	190.434	33%	4,4%
	Osnovna referenca	122.298	124.910	132.130	137.689	143.417	149.408	153.431	156.917	160.994	164.066	167.531	170.885	19%	3,5%
	Najniža	.	.	.	.	.	147.542	149.654	149.989	152.007	152.591	153.578	154.552	8%	2,6%
RP2 regija °	Najviša	.	.	.	.	.	126.469	131.081	136.417	142.227	146.824	151.571	156.387	30%	4,1%
	Osnovna referenca	105.251	106.930	111.670	115.063	120.191	125.004	128.074	130.554	133.630	135.820	138.315	140.711	17%	3,2%
	Najniža	.	.	.	.	.	123.524	125.049	124.909	126.308	126.483	126.997	127.514	6%	2,3%
Naplatno područje	Stopa rasta	Ukupan broj rutnih jedinica usluge (u postotcima)												Ukupan rast (2023-2016)	Prosječna godišnja stopa rasta za RP2 (2019-2014)
		2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023		
CRCO14 *	Najviša	.	.	.	.	.	5,5%	3,9%	4,4%	4,5%	3,5%	3,6%	3,5%	4,1%	4,4%
	Osnovna referenca	-1,3%	2,1%	5,8%	4,2%	4,2%	4,2%	2,7%	2,3%	2,6%	1,9%	2,1%	2,0%	2,5%	3,5%
	Najniža	.	.	.	.	.	2,9%	1,4%	0,2%	1,3%	0,4%	0,6%	0,6%	1,1%	2,6%
RP2 regija °	Najviša	.	.	.	.	.	5,2%	3,6%	4,1%	4,3%	3,2%	3,2%	3,2%	3,8%	4,1%
	Osnovna referenca	-1,4%	1,6%	4,4%	3,0%	4,5%	4,0%	2,5%	1,9%	2,4%	1,6%	1,8%	1,7%	2,3%	3,2%
	Najniža	.	.	.	.	.	2,8%	1,2%	-0,1%	1,1%	0,1%	0,4%	0,4%	0,8%	2,3%

* CRCO14 označava zbroj svih država koje sudjeluju u multilateralnom sustavu naplate rutnih naknada iz 2014. godine izmjerenih ili prognoziranih za odgovarajuću godinu.

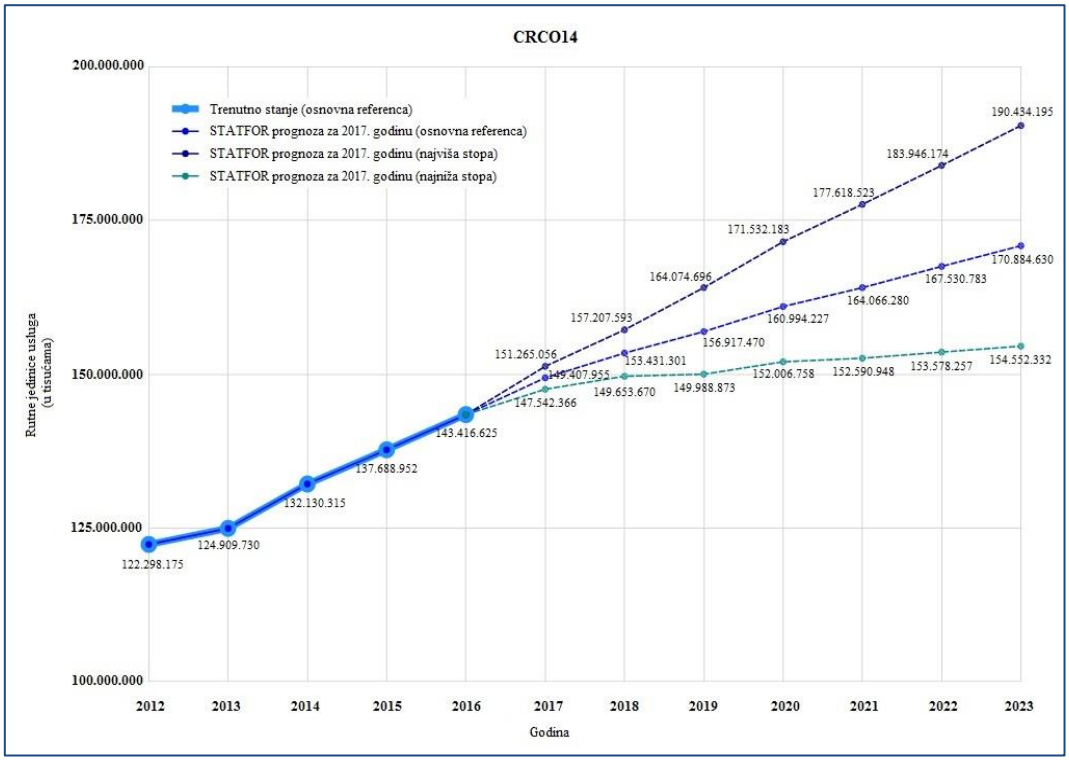
° RP2 regija broji 30 država uključene u program mjerenja učinkovitosti EU, uključujući Hrvatsku od 2014. godine (28 država članica EU plus Norveška i Švicarska). RP2 Regija uključuje rutne jedinice usluge za segmente leta koji se obavlja kao OAT na području Njemačke.

Izvor: *[8] (prilagodio autor).*

Na slici 16 prikazano je područje ESRA-e (CRCO14) koje očekuje prosječnu godišnju stopu rasta TSU-a od 2,5 % u sedmogodišnjem razdoblju. Očekuju se veće stope rasta u regiji ESRA Istok u odnosu na ostatak CRCO14. Najveće stope rasta TSU-a očekuju se u Moldavija koja bi mogla ostvarila najveću stopu rasta TSU-a od 4,9 % na ukupnom području CRCO14. Nakon Moldavije slijedi Ukrajina sa 4,6 % TSU-a, Cipar sa 4,4 % TSU-a i Turska sa 4,3 % TSU-a. Ako usporedimo najveću stopu rasta od 4,9 % s osnovnom referencom od 2,5 % može se uvidjeti skoro dvostruko veći rast TSU-a u odnosu na prosječan rast država CRCO14. Regija ESRA Mediteran očekuje malo odstupanje stopa rasta TSU-a u odnosu na osnovnu referencu, a regija ESRA Sjeverozapad očekuje manju godišnju stopu rasta TSU-a.



Slika 16: *Prosječna godišnja stopa rasta TSU-a u sedmogodišnjem razdoblju (2016-2023) po državama članicama EUROCONTROL-a (CRCO14) [8] (prilagodio autor).*



Grafikon 7: *STATFOR prognoza rutnih jedinica usluga prema prvoj reviziji za CRCO14 naplatnu zonu u 2017. godini prema osnovnoj referenci, najvišoj i najnižoj stopi rasta [45] (prilagodio autor).*

Tablica 16: *Sedmogodišnja prognoza rutnih jedinica usluge na području Europe*

Država	Stopa rasta	Ukupan broj rutnih jedinica usluge (u tisućama)												Ukupan rast (2023-2016)	Prosječna godišnja stopa rasta za RP2 (2019-2014)
		2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023		
Albanija	Najviša	.	.	.	.	.	452	470	497	525	549	575	601	36%	.
	Osnovna referenca	443	456	469	484	442	447	461	475	491	505	519	534	21%	.
	Najniža	.	.	.	.	.	442	452	455	463	467	473	479	8%	.
Armenija	Najviša	.	.	.	.	.	124	127	131	134	138	141	145	31%	.
	Osnovna referenca	154	149	142	126	111	119	121	124	126	128	131	133	20%	.
	Najniža	.	.	.	.	.	114	115	118	119	120	122	123	11%	.
Austrija	Najviša	.	.	.	.	.	2.873	2.983	3.119	3.253	3.364	3.478	3.589	31%	3,3%
	Osnovna referenca	2.469	2.456	2.645	2.739	2.749	2.833	2.903	2.965	3.033	3.082	3.139	3.195	16%	2,3%
	Najniža	.	.	.	.	.	2.793	2.823	2.818	2.853	2.855	2.863	2.872	4%	1,3%
Belgija i Luksemburg	Najviša	.	.	.	.	.	2.609	2.698	2.798	2.923	3.007	3.082	3.157	26%	3,4%
	Osnovna referenca	2.232	2.277	2.362	2.454	2.500	2.583	2.646	2.695	2.760	2.806	2.859	2.908	16%	2,7%
	Najniža	.	.	.	.	.	2.555	2.590	2.590	2.624	2.632	2.647	2.661	6%	1,9%
Bosna i Hercegovina	Najviša	.	.	.	.	.	912	944	994	1.044	1.087	1.133	1.180	36%	.
	Osnovna referenca	680	654	783	870	866	896	916	942	968	990	1.014	1.037	20%	.
	Najniža	.	.	.	.	.	879	888	892	903	908	915	921	6%	.
Bugarska	Najviša	.	.	.	.	.	3.552	3.731	3.939	4.157	4.348	4.547	4.754	39%	7,5%
	Osnovna referenca	2.020	2.058	27.444	3.223	3.412	3.509	3.652	3.772	3.892	3.992	4.103	4.214	23%	6,6%
	Najniža	.	.	.	.	.	3.466	3.572	3.612	3.687	3.720	3.761	3.802	11%	5,7%
Cipar	Najviša	.	.	.	.	.	1.644	1.730	1.858	1.994	2.124	2.266	2.419	57%	5,0%
	Osnovna referenca	1.303	1.327	1.452	1.548	1.540	1.623	1.684	1.759	1.839	1.912	1.993	2.076	35%	3,9%
	Najniža	.	.	.	.	.	1.602	1.640	1.669	1.713	1.746	1.783	1.821	18%	2,8%
Češka	Najviša	.	.	.	.	.	2.940	3.059	3.195	3.335	3.457	3.577	3.694	35%	5,9%
	Osnovna referenca	2.305	2.374	2.393	2.532	2.737	2.900	2.979	3.036	3.108	3.161	3.222	3.282	20%	4,9%
	Najniža	.	.	.	.	.	2.860	2.900	2.894	2.971	2.975	2.986	2.996	9%	3,9%
Danska	Najviša	.	.	.	.	.	1.686	1.739	1.785	1.852	1.897	1.941	1.986	22%	3,1%
	Osnovna referenca	1.429	1.525	1.532	1.583	1.621	1.669	1.709	1.732	1.762	1.780	1.802	1.823	12%	2,5%
	Najniža	.	.	.	.	.	1.651	1.677	1.672	1.682	1.678	1.677	1.677	3%	1,8%
Estonija	Najviša	.	.	.	.	.	855	891	931	979	1.020	1.062	1.106	33%	3,3%
	Osnovna referenca	725	741	790	816	834	844	868	888	912	931	953	975	17%	2,4%
	Najniža	.	.	.	.	.	832	845	846	858	861	867	873	5%	1,4%
Finska	Najviša	.	.	.	.	.	827	846	875	904	931	959	989	29%	1,9%
	Osnovna referenca	790	770	796	760	764	816	826	842	857	870	884	898	18%	1,1%
	Najniža	.	.	.	.	.	804	806	807	812	812	813	815	7%	0,3%
Francuska	Najviša	.	.	.	.	.	20.879	21.521	22.260	23.133	23.711	24.311	24.906	25%	3,8%
	Osnovna referenca	17.515	17.900	18.497	18.868	19.882	20.722	21.169	21.485	21.953	22.250	22.590	22.879	15%	3,0%
	Najniža	.	.	.	.	.	20.563	20.804	20.708	20.834	20.805	20.834	20.857	5%	2,3%
Grčka	Najviša	.	.	.	.	.	4.949	5.205	5.514	5.847	6.148	6.473	6.822	46%	3,6%
	Osnovna referenca	4.358	4.216	4.618	4.899	4.674	4.866	5.027	5.192	5.381	5.543	5.724	5.906	26%	2,4%
	Najniža	.	.	.	.	.	4.783	4.852	4.897	4.992	5.050	5.122	5.194	11%	1,2%
Gruzija	Najviša	.	.	.	.	.	873	958	1.019	1.086	1.149	1.218	1.290	63%	.
	Osnovna referenca	709	747	752	805	791	816	847	884	924	959	999	1.040	31%	.
	Najniža	.	.	.	.	.	760	736	756	779	797	817	838	6%	.
Hrvatska	Najviša	.	.	.	.	.	1.841	1.933	2.035	2.140	2.229	2.322	2.416	35%	2,9%
	Osnovna referenca	1.679	1.695	1.760	1.790	1.787	1.810	1.870	1.922	1.979	2.023	2.073	2.120	19%	1,8%
	Najniža	.	.	.	.	.	1.779	1.808	1.816	1.839	1.849	1.863	1.876	5%	0,6%
Irska	Najviša	.	.	.	.	.	4.644	4.786	4.928	5.059	5.144	5.228	5.310	19%	4,7%
	Osnovna referenca	3.806	3.813	3.922	4.182	4.468	4.576	4.664	4.748	4.856	4.914	4.963	5.006	12%	3,9%
	Najniža	.	.	.	.	.	4.507	4.538	4.549	4.594	4.611	4.639	4.666	4%	3,0%
Italija	Najviša	.	.	.	.	.	8.662	9.007	9.437	9.856	10.201	10.572	10.951	32%	2,6%
	Osnovna referenca	8.139	8.117	8.314	8.172	8.300	8.528	8.726	8.898	9.096	9.236	9.403	9.564	15%	1,4%
	Najniža	.	.	.	.	.	8.394	8.446	8.398	8.441	8.419	8.424	8.430	2%	0,2%
Kanarski otoci	Najviša	.	.	.	.	.	1.626	1.694	1.771	1.838	1.898	1.963	2.031	37%	3,5%
	Osnovna referenca	1.599	1.516	1.492	1.402	1.485	1.597	1.637	1.667	1.698	1.719	1.744	1.768	19%	2,2%
	Najniža	.	.	.	.	.	1.569	1.583	1.575	1.577	1.570	1.566	1.561	5%	1,1%
Latvija	Najviša	.	.	.	.	.	851	880	919	963	999	1.037	1.075	36%	3,7%
	Osnovna referenca	707	734	767	802	789	835	848	863	991	894	910	925	17%	2,4%
	Najniža	.	.	.	.	.	820	817	811	817	815	814	814	3%	1,1%
Lisabon FIR	Najviša	.	.	.	.	.	3.782	3.936	4.106	4.259	4.392	4.536	4.686	34%	6,3%
	Osnovna referenca	2.782	2.877	3.020	3.150	3.509	3.742	3.844	3.907	3.985	4.040	4.104	4.165	19%	5,3%
	Najniža	.	.	.	.	.	3.703	3.755	3.729	3.739	3.727	3.725	3.722	6%	4,3%
Litva	Najviša	.	.	.	.	.	532	554	578	603	625	646	668	32%	3,5%
	Osnovna referenca	430	451	487	492	508	522	538	546	558	566	576	585	15%	2,3%
	Najniža	.	.	.	.	.	513	521	517	522	521	521	521	3%	1,2%
Mađarska	Najviša	.	.	.	.	.	2.970	3.071	3.234	3.407	3.558	3.712	3.868	39%	6,1%
	Osnovna referenca	2.023	2.101	2.406	2.695	2.788	2.925	2.997	3.079	3.169	3.242	3.323	3.403	22%	5,1%
	Najniža	.	.	.	.	.	2.879	2.924	2.937	2.992	3.010	3.034	3.059	10%	4,1%
Makedonija	Najviša	.	.	.	.	.	263	273	288	302	314	328	341	37%	.
	Osnovna referenca	174	178	246	264	250	259	264	273	281	287	294	302	21%	.
	Najniža	.	.	.	.	.	254	255	257	261	264	267	270	8%	.
Malta	Najviša	.	.	.	.	.	925	978	1.058	1.146	1.237	1.340	1.457	61%	7,8%
	Osnovna referenca	641	735	727	823	904	902	930	978	1.031	1.082	1.139	1.199	33%	6,1%
	Najniža	.	.	.	.	.	880	885	907	937	962	991	1.021	13%	4,5%

Država	Stopa rasta	Ukupan broj rutnih jedinica usluge (u tisućama)												Ukupan rast (2023-2016)	Prosječna godišnja stopa rasta za RP2 (2019-2014)
		2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023		
Moldavija	Najviša	.	.	.	.	.	75	80	86	92	96	102	107	79%	.
	Osnovna referenca	206	240	131	74	60	68	70	74	76	78	81	84	40%	.
	Najniža	.	.	.	.	.	62	60	62	63	64	64	65	9%	.
Nizozemska	Najviša	.	.	.	.	.	3.278	3.376	3.464	3.579	3.661	3.740	3.818	23%	4,6%
	Osnovna referenca	2.587	2.702	2.767	2.893	3.100	3.247	3.315	3.356	3.408	3.444	3.485	3.523	14%	3,9%
	Najniža	.	.	.	.	.	3.216	3.252	3.244	3.279	3.279	3.286	3.292	6%	3,2%
Norveška	Najviša	.	.	.	.	.	2.569	2.656	2.728	2.846	2.932	3.026	3.123	25%	4,2%
	Osnovna referenca	1.846	2.051	2.221	2.314	2.493	2.537	2.597	2.640	2.691	2.726	2.769	2.813	13%	3,5%
	Najniža	.	.	.	.	.	2.507	2.540	2.537	2.550	2.546	2.551	2.555	2%	2,7%
Njemačka (i)	Najviša	.	.	.	.	.	14.332	14.803	15.295	15.863	16.282	16.702	17.107	26%	3,5%
	Osnovna referenca	12.513	12.570	12.881	19.976	13.560	14.218	14.540	14.738	15.023	15.207	15.431	15.639	15%	2,7%
	Najniža	.	.	.	.	.	14.099	14.269	14.217	14.396	14.391	14.426	14.459	7%	2,0%
Poljska	Najviša	.	.	.	.	.	4.370	4.555	4.792	5.032	5.242	5.437	5.633	35%	4,0%
	Osnovna referenca	3.854	3.984	3.931	3.880	4.175	4.329	4.463	4.572	4.695	4.787	4.892	4.997	20%	3,1%
	Najniža	.	.	.	.	.	4.288	4.373	4.367	4.456	4.463	4.480	4.499	8%	2,1%
Rumunjska	Najviša	.	.	.	.	.	4.688	4.883	5.158	5.466	5.745	6.036	6.337	43%	4,3%
	Osnovna referenca	3.575	3.752	4.182	4.571	4.443	4.598	4.711	4.865	5.035	5.184	5.351	5.521	24%	3,1%
	Najniža	.	.	.	.	.	4.507	4.539	4.589	4.705	4.765	439	4.912	11%	1,9%
Slovačka	Najviša	.	.	.	.	.	1.205	1.260	1.325	1.394	1.457	1.519	1.582	39%	4,9%
	Osnovna referenca	922	985	1.044	1.071	1.138	1.186	1.223	1.254	1.290	1.319	1.351	1.384	22%	3,7%
	Najniža	.	.	.	.	.	1.168	1.186	1.189	1.213	1.220	1.229	1.239	9%	2,6%
Slovenija	Najviša	.	.	.	.	.	522	548	574	602	624	647	670	34%	4,6%
	Osnovna referenca	425	411	459	466	502	514	533	546	561	572	584	596	19%	3,5%
	Najniža	.	.	.	.	.	506	519	519	526	528	531	534	6%	2,5%
Srbija i Crna Gora - KFOR (ii)	Najviša	.	.	.	.	.	2.230	2.328	2.442	2.562	2.664	2.772	2.882	35%	.
	Osnovna referenca	1.719	1.639	1.752	1.975	2.130	2.194	2.258	2.315	2.380	2.431	2.489	2.545	19%	.
	Najniža	.	.	.	.	.	2.158	2.187	2.194	2.225	2.237	2.253	2.270	7%	.
Sveta Marija FIR	Najviša	.	.	.	.	.	5.386	5.595	5.821	6.061	6.257	6.469	6.692	33%	6,9%
	Osnovna referenca	3.874	4.021	4.166	4.662	5.039	5.310	5.468	5.604	5.758	5.879	6.011	6.138	22%	6,1%
	Najniža	.	.	.	.	.	5.235	5.339	5.397	5.468	5.513	5.571	5.628	12%	5,3%
Španjolska	Najviša	.	.	.	.	.	10.362	10.785	11.268	11.729	12.115	12.517	12.929	32%	5,1%
	Osnovna referenca	8.444	8.447	8.768	8.997	9.761	10.262	10.549	10.745	10.990	11.153	11.341	11.539	18%	4,2%
	Najniža	.	.	.	.	.	10.162	10.322	10.268	10.337	10.318	10.328	10.353	6%	3,2%
Švedska	Najviša	.	.	.	.	.	3.529	3.629	3.741	3.882	3.988	4.101	4.216	24%	2,6%
	Osnovna referenca	3.126	3.209	3.285	3.355	3.402	3.484	3.537	3.597	3.665	3.709	3.763	3.818	12%	1,8%
	Najniža	.	.	.	.	.	3.439	3.445	3.437	3.469	3.460	3.460	3.461	2%	0,9%
Švicarska	Najviša	.	.	.	.	.	1.544	1.607	1.664	1.729	1.771	1.815	1.855	24%	3,1%
	Osnovna referenca	1.399	1.385	1.427	1.455	1.493	1.525	1.568	1.591	1.623	1.642	1.666	1.687	13%	2,2%
	Najniža	.	.	.	.	.	1.505	1.527	1.520	1.529	1.524	1.524	1.524	2%	1,3%
Turska	Najviša	.	.	.	.	.	15.335	16.242	17.310	18.477	19.560	20.701	21.914	52%	.
	Osnovna referenca	9.813	10.637	12.809	14.182	14.370	15.138	15.821	16.561	17.273	17.919	18.632	19.337	35%	.
	Najniža	.	.	.	.	.	14.947	15.417	15.796	16.274	16.598	16.967	17.317	21%	.
Ujedinjena Kraljevina	Najviša	.	.	.	.	.	11.423	11.733	12.068	12.457	12.720	12.979	13.233	22%	3,9%
	Osnovna referenca	9.608	9.755	9.979	10.154	10.875	11.301	11.518	11.679	11.901	12.036	12.181	12.303	13%	3,2%
	Najniža	.	.	.	.	.	11.176	11.292	11.271	11.364	11.374	11.413	11.447	5%	2,5%
Ukrajina	Najviša	.	.	.	.	.	1.208	1.302	1.400	1.487	1.571	1.654	1.741	71%	.
	Osnovna referenca	4.588	4.931	2.771	1.286	1.017	1.132	1.171	1.220	1.265	1.305	1.349	1.395	37%	.
	Najniža	.	.	.	.	.	1.056	1.042	1.054	1.074	1.086	1.101	1.117	10%	.
CRCO14	Najviša	.	.	.	.	.	151.265	157.208	164.075	171.532	177.619	183.946	190.434	33%	4,4%
	Osnovna referenca	122.298	124.910	132.130	137.689	143.417	149.408	153.431	156.917	160.994	164.066	167.531	170.885	19%	3,5%
	Najniža	.	.	.	.	.	147.542	149.654	149.989	152.007	152.591	153.578	154.552	8%	2,6%
RP1 Regija (i)	Najviša	.	.	.	.	.	124.628	129.148	134.381	140.087	144.595	149.248	153.970	30%	4,1%
	Osnovna referenca	103.572	105.235	109.910	113.273	118.404	123.194	126.204	128.632	131.651	133.797	136.242	138.591	17%	3,2%
	Najniža	.	.	.	.	.	121.745	123.241	123.094	124.469	124.634	125.134	125.637	6%	2,3%
RP2 Regija (i)	Najviša	.	.	.	.	.	126.469	131.081	136.417	142.227	146.824	151.571	156.387	30%	4,1%
	Osnovna referenca	105.251	106.930	111.670	115.063	120.191	125.004	128.074	130.554	133.630	135.820	138.315	140.711	17%	3,2%
	Najniža	.	.	.	.	.	123.524	125.049	124.909	126.308	126.483	126.997	127.514	6%	2,3%
Ukupno	Najviša	.	.	.	.	.	153.329	159.401	166.405	173.998	180.209	186.662	193.281	33%	4,3%
	Osnovna referenca	127.611	130.582	135.692	139.790	145.268	151.384	155.471	159.025	163.171	166.302	169.834	173.255	19%	3,2%
	Najniža	.	.	.	.	.	149.431	151.541	151.889	153.939	154.538	155.547	156.542	8%	2,3%

(i) Za Njemačku, RP1 i RP2 regiju, rutne jedinice usluge uključuju segmente leta koji se obavljaju kao OAT. Trenutno stanje za 2016. godinu iznosi 73.165 rutnih jedinica usluge. U narednim godinama očekuje se 75.000 rutnih jedinica usluge godišnje.

(ii) Naplatna zona iznad Srbije i Crne Gore preimenovana je u Srbija i Crna Gora – KFOR (nakon izmjene konvencije o imenovanju, vidi završne zapisnike 103. zasjedanja Proširenog odbora od 19. do 20. 11. 2014.).

Izvor: *[8] (prilagodio autor).*

3.3.2.6 Prognoza terminalnih jedinica usluge

Praćenjem trenda prognoze IFR kretanja zrakoplova, prognoza TNSU-a očekuje rast u 2017. godini. Očekivana stopa rasta TNSU-a u TCZ-ima zemalja članica obuhvaćene Programom mjerenja učinkovitosti u RP2 regiji očekuju rast od 3,9 % (+ ili - 1,3 %) odnosno 8,2 milijuna TNSU-a u 2017. godini. Do 2023. godine očekuje se rast TNSU-a u RP2 regiji od 2,4 % odnosno 9,3 milijuna TNSU-a [8]. Vidi tablicu 17 i 18.

Tablica 17: *Sažetak prognoze terminalnih jedinica usluge na području RP2 regije*

RP2 Regija	Stopa rasta	Prognoza terminalnih jedinica usluge												Prosječna godišnja stopa rasta (2023-2016)	Prosječna godišnja stopa rasta za RP2 (2019-2014)
		2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023		
Ukupan TNSU (u tisućama)	Najviša	.	.	.	.	.	8.268,2	8.551,2	8.913,0	9.344,3	9.675,5	10.028,1	10.365,9	4,0%	4,2%
	Osnovna referenca	7.234	7.224	7.267	7.484	7.855	8.162,9	8.342,4	8.531,4	8.760,3	8.919,7	9.110,5	9.302,5	2,4%	3,3%
	Najniža	.	.	.	.	.	8.058,5	8.134,2	8.146,9	8.306,4	8.335,0	8.390,2	8.444,4	1,0%	2,3%
Godišnji rast TNSU-a (u postotcima)	Najviša	.	.	.	.	.	5,3%	3,4%	4,2%	4,8%	3,5%	3,6%	3,4%	4,0%	4,2%
	Osnovna referenca	-1,9%	-0,1%	0,6%	3,0%	5,0%	3,9%	2,2%	2,3%	2,7%	1,8%	2,1%	2,1%	2,4%	3,3%
	Najniža	.	.	.	.	.	2,6%	0,9%	0,2%	2,0%	0,3%	0,7%	0,6%	1,0%	2,3%

Izvor: *[8] (prilagodio autor).*

Tablica 18: *Sedmogodišnja prognoza terminalnih jedinica usluge za terminalnu naplatnu zonu država*

Država	ICAO kod države za terminalnu naplatnu zonu	Stopa rasta	Ukupan broj terminalnih jedinica usluge (u tisućama)											Prosječna godišnja stopa rasta (2023-2016)
			2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023	
Austrija	LO_TCZ	Najviša	.	.	.	.	.	187,7	193,5	202,9	213,0	222,5	230,7	239,3	4,0%
		Osnovna referenca	179,1	175,5	178,4	180,7	181,5	185,1	187,9	192,3	196,6	199,8	205,3	209,8	2,1%
		Najniža	.	.	.	.	.	182,3	182,3	182,2	184,7	184,5	185,9	186,1	0,4%
Belgija	EB_TCZ_EBAW	Najviša	.	.	.	.	.	3,2	3,3	3,4	3,6	3,8	4,0	4,2	5,9%
		Osnovna referenca	1,9	1,9	1,7	2,6	2,8	3,1	3,2	3,3	3,4	3,4	3,5	3,6	3,6%
		Najniža	.	.	.	.	.	3,1	3,1	3,1	3,2	3,2	3,2	3,2	2,2%
	EB_TCZ_EBBR	Najviša	.	.	.	.	.	153,6	160,5	169,5	179,0	185,8	187,6	189,3	3,8%
		Osnovna referenca	150,8	142,3	146,6	154,6	145,9	151,0	155,2	159,9	164,5	168,1	172,4	176,5	2,8%
		Najniža	.	.	.	.	.	148,5	150,5	150,6	152,6	152,9	154,3	155,2	0,9%
	EB_TCZ_EBCI	Najviša	.	.	.	.	.	32,2	34,0	36,4	38,7	41,1	43,6	46,2	6,2%
		Osnovna referenca	27,9	30,2	28,1	29,1	30,3	31,7	32,9	34,1	35,4	36,5	37,7	39,0	3,7%
		Najniža	.	.	.	.	.	31,2	31,9	32,1	32,6	33,0	33,4	33,8	1,6%
	EB_TCZ_EBLG	Najviša	.	.	.	.	.	30,5	32,8	35,0	37,3	39,5	42,0	44,6	6,5%
		Osnovna referenca	23,5	22,9	24,7	27,6	28,7	30,0	31,8	33,2	34,7	36,1	37,7	39,4	4,6%
		Najniža	.	.	.	.	.	29,6	30,6	31,2	32,5	33,3	34,1	35,0	2,9%
	EB_TCZ_EBOS	Najviša	.	.	.	.	.	3,9	4,1	4,2	4,4	4,6	4,6	4,8	5,3%
		Osnovna referenca	3,4	3,2	2,4	2,3	3,3	3,9	4,0	4,1	4,2	4,3	4,4	4,4	4,1%
		Najniža	.	.	.	.	.	3,8	3,9	3,9	3,9	3,9	4,0	4,0	2,7%
Bugarska	LB_TCZ	Najviša	.	.	.	.	.	32,3	33,9	35,7	37,7	39,4	41,2	43,1	6,0%
		Osnovna referenca	41,5	41,7	44,2	24,1	28,6	31,8	32,8	33,7	34,8	35,7	36,6	37,7	4,0%
		Najniža	.	.	.	.	.	31,3	31,8	32,0	32,6	32,7	33,0	33,4	2,2%
Cipar	LC_TCZ	Najviša	.	.	.	.	.	52,5	55,8	60,8	65,9	70,9	76,8	84,0	8,6%
		Osnovna referenca	42,5	39,0	40,0	40,4	47,3	51,6	53,4	55,7	58,2	60,3	63,0	65,8	4,8%
		Najniža	.	.	.	.	.	50,4	51,4	51,5	52,3	52,8	53,4	54,0	1,90%
Češka	LK_TCZ	Najviša	.	.	.	.	.	90,2	96,1	105,0	113,5	122,6	131,3	137,9	7,8%
		Osnovna referenca	75,3	73,7	72,9	75,5	81,5	87,4	91,8	96,0	100,2	104.0	108,2	112,0	4,6%
		Najniža	.	.	.	.	.	85,2	87,7	87,9	89,9	90,6	91,4	92,3	1,8%
Danska	EK_TCZ	Najviša	.	.	.	.	.	174,9	181,3	191,0	200,5	208,0	217,0	225,0	4,2%
		Osnovna referenca	143,7	148,1	154,5	158,2	168,8	171,7	175,9	180,8	185,4	188,2	192,6	196,1	2,2%
		Najniža	.	.	.	.	.	169,4	171,2	172,4	174,7	173,2	173,7	174,8	0,5%
Estonija	EE_TCZ	Najviša	.	.	.	.	.	16,7	19,5	21,9	23,9	25,6	28,3	30,6	9,7%
		Osnovna referenca	18,9	14,6	15,1	15,9	16,0	16,6	18,1	19,2	20,2	21,0	21,8	23,8	5,8%
		Najniža	.	.	.	.	.	16,2	16,6	16,5	16,8	17,0	17,5	17,8	1,6%
Finska	EF_TCZ	Najviša	.	.	.	.	.	110,0	113,8	119,0	125,9	130,1	134,8	140,6	4,6%
		Osnovna referenca	97,6	97,9	99,4	100,5	102,6	108,7	110,7	112,9	115,6	117,7	120,0	122,2	2,5%
		Najniža	.	.	.	.	.	107,2	107,8	107,5	108,6	108,6	108,8	109,1	0,9%

Država	ICAO kod države za terminalnu naplatnu zonu	Stopa rasta	Ukupan broj terminalnih jedinica usluge (u tisućama)											Prosječna godišnja stopa rasta (2023-2016)
			2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023	
Francuska (*)	LF_TCZ_1	Najviša	.	.	.	.	.	603,2	613,3	618,4	670,0	673,2	682,7	694,3	2,7%
		Osnovna referenca	606,9	604,0	555,7	568,6	575,7	595,3	607,9	618,2	650,2	666,7	682,7	693,7	2,7%
		Najniža	.	.	.	.	.	587,5	591,9	595,4	604,3	603,4	609,4	615,8	1,0%
	LF_TCZ_2	Najviša	.	.	.	.	.	514,9	525,1	538,1	558,7	573,8	590,9	607,5	2,9%
		Osnovna referenca	485,8	486,6	475,4	480,3	496,7	505,6	509,6	519,4	531,6	539,2	549,0	555,5	1,6%
		Najniža	.	.	.	.	.	499,3	497,0	497,7	502,6	503,4	506.0	506,9	0,3%
Grčka	LG_TCZ	Najviša	.	.	.	.	.	112,3	117,5	125,8	135,5	144,3	154,5	164,7	6,2%
		Osnovna referenca	83,0	74,5	86,0	100,1	108,3	110,6	113,6	117,4	122,6	127,4	132,3	137,8	3,5%
		Najniža	.	.	.	.	.	108,6	109,9	110,2	112,5	114,3	116,4	118,3	1,3%
Hrvatska	LD_TCZ	Najviša	.	.	.	.	.	18,9	19,6	21,6	23,0	24,3	25,4	26,4	5,4%
		Osnovna referenca	16,0	15,8	16,3	17,4	18,3	18,6	19,1	19,7	20,2	20,6	21,3	22,8	3,2%
		Najniža	.	.	.	.	.	18,4	18,6	18,7	18,9	19,0	19,1	19,3	0,8%
Irska	EI_TCZ	Najviša	.	.	.	.	.	172,1	179,8	187,9	190,4	192,1	194,2	196,0	2,6%
		Osnovna referenca	129,5	136,7	137,5	149,6	163,3	169,6	175,0	180,3	185,8	188,4	189,6	191,4	3,3%
		Najniža	.	.	.	.	.	167,3	170,4	171,5	174,0	175,3	177,0	179,0	1,3%
Italija	LI_TCZ_1	Najviša	.	.	.	.	.	231,1	240,4	254,7	269,0	281,8	296,5	310,4	4,7%
		Osnovna referenca	217,7	210,0	218,5	221,9	225,8	228,0	233,0	238,7	244,8	249,3	254,7	260,3	2,1%
		Najniža	.	.	.	.	.	224,4	225,7	223,7	224,6	223,7	223,3	223,4	-0,2%
	LI_TCZ_2	Najviša	.	.	.	.	.	311,2	324,8	345,0	363,9	380,2	398,6	416,3	4,8%
		Osnovna referenca	285,7	275,3	275,1	286,0	300,4	306,4	314,0	321,6	330,1	335,3	342,7	350,1	2,2%
		Najniža	.	.	.	.	.	301,8	303,2	300,6	300,7	299,5	299,5	300,3	0,0%
Latvija	EV_TCZ	Najviša	.	.	.	.	.	35,8	37,8	40,2	42,4	44,7	47,2	49,6	6,3%
		Osnovna referenca	31,5	32,4	31,4	32,4	32,4	35,0	35,8	36,4	37,2	37,6	38,3	38,8	2,6%
		Najniža	.	.	.	.	.	34,1	34,4	33,6	33,6	33,1	32,8	32,5	0,1%
Lisabon FIR	LP_TCZ	Najviša	.	.	.	.	.	257,5	269,2	283,8	296,4	308,4	321,5	334,5	5,4%
		Osnovna referenca	175,7	180,3	191,8	205,6	230,7	253,1	260,3	265,0	271,4	276,0	281,4	286,5	3,1%
		Najniža	.	.	.	.	.	248,4	250,7	248,3	248,9	248,1	247,9	247,8	1,0%
Litva	EY_TCZ	Najviša	.	.	.	.	.	29,8	31,9	34,9	38,3	41,1	43,7	47,0	8,3%
		Osnovna referenca	19,2	21,0	23,6	25,1	26,8	29,2	30,6	31,8	33,2	34,3	35,5	37,6	4,9%
		Najniža	.	.	.	.	.	28,6	29,4	29,6	30,1	30,4	30,7	31,1	2,1%
Madarska	LH_TCZ	Najviša	.	.	.	.	.	62,9	68,1	75,5	81,1	86,5	92,7	98,5	7,6%
		Osnovna referenca	49,6	49,2	50,7	55,2	59,0	61,7	65,3	68,6	71,4	73,8	77,0	80,0	4,4%
		Najniža	.	.	.	.	.	60,5	62,3	62,9	64,4	65,4	66,6	67,3	1,9%
Malta	LM_TCZ	Najviša	.	.	.	.	.	31,6	33,8	38,1	41,0	43,8	47,8	51,2	9,6%
		Osnovna referenca	20,7	22,7	23,9	25,4	26,9	31,1	32,4	34,6	36,5	38,3	39,8	41,4	6,3%
		Najniža	.	.	.	.	.	30,4	31,3	31,6	32,3	32,8	34,2	34,8	3,7%
Nizozemska	EH_TCZ	Najviša	.	.	.	.	.	399,5	405,1	411,1	417,4	422,6	428,1	434,3	1,5%
		Osnovna referenca	339,2	345,0	356,6	369,2	390,2	400,0	404,9	410,4	416,1	421,2	427,0	432,7	1,5%
		Najniža	.	.	.	.	.	399,9	405,0	408,5	414,2	416,1	419,4	422,7	1,1%
Norveška	EN_TCZ	Najviša	.	.	.	.	.	244,1	250,3	253,4	267,8	275,4	288,7	297,9	3,0%
		Osnovna referenca	242,4	255,4	247,9	241,7	242,1	242,0	245,5	249,1	252,7	254,9	258,3	269,2	1,5%
		Najniža	.	.	.	.	.	239,5	240,4	239,6	240,3	247,3	246,3	246,3	0,2%
Njemačka	ED_TCZ	Najviša	.	.	.	.	.	1.457,4	1.494,4	1.554,7	1.608,6	1.661,4	1.716,5	1.770,6	3,5%
		Osnovna referenca	1.295,5	1.282,3	1.311,6	1.338,8	1.387,9	1.439,9	1.459,2	1.488,7	1.521,6	1.543,4	1.573,0	1.603,1	2,1%
		Najniža	.	.	.	.	.	1.422,6	1.425,3	1.429,8	1.506,1	1.511,2	1.521,5	1.532,1	1,4%
Poljska (*)	EP_TCZ_EPWA	Najviša	.	.	.	.	.	89,5	96,8	106,0	114,5	122,6	124,7	125,5	6,9%
		Osnovna referenca	65,3	70,0	69,0	70,8	78,7	87,5	92,5	96,1	100,2	103,6	107,7	111,5	5,1%
		Najniža	.	.	.	.	.	85,8	88,9	89,1	90,3	90,8	91,6	91,9	2,2%
	EP_TCZ_OTHR	Najviša	.	.	.	.	.	115,9	126,2	138,3	149,1	161,1	172,7	185,6	8,6%
		Osnovna referenca	83,6	79,9	87,5	96,4	103,9	113,6	120,8	128,1	135,1	139,9	145,9	152,2	5,6%
		Najniža	.	.	.	.	.	111,3	116,2	118,3	122,3	124,5	127,0	129,8	3,2%
Rumunjska	LR_TCZ	Najviša	.	.	.	.	.	71,5	75,4	80,0	84,6	88,6	93,7	99,6	7,1%
		Osnovna referenca	45,1	47,3	50,3	54,6	61,6	70,2	72,8	74,6	76,7	78,4	80,5	82,4	4,2%
		Najniža	.	.	.	.	.	69,0	70,1	70,0	70,7	70,8	71,1	71,4	2,1%
Slovačka	LZ_TCZ	Najviša	.	.	.	.	.	11,5	12,9	14,0	15,1	16,2	17,4	18,5	8,8%
		Osnovna referenca	8,7	8,6	8,3	9,4	10,3	11,2	11,9	13,1	13,7	14,3	14,9	15,6	6,2%
		Najniža	.	.	.	.	.	11,0	11,4	11,7	12,1	12,4	12,7	13,0	3,5%
Slovenija	LJ_TCZ	Najviša	.	.	.	.	.	12,9	13,5	14,5	15,7	16,6	18,4	19,4	7,6%
		Osnovna referenca	11,1	11,3	11,1	12,0	11,6	12,7	13,1	13,5	14,1	14,8	15,6	16,2	4,9%
		Najniža	.	.	.	.	.	12,4	12,6	12,8	13,2	13,5	13,8	14,1	2,8%
Španjolska	LE_TCZ	Najviša	.	.	.	.	.	796,2	836,2	880,8	922,2	958,8	1002,8	1045,2	5,0%
		Osnovna referenca	725,6	700,4	651,2	680,5	741,1	784,7	810,6	832,2	854,5	871,3	890,3	910,8	3,0%
		Najniža	.	.	.	.	.	773,4	788,2	788,1	798,1	800,3	804,2	809,1	1,3%
Švedska	ES_TCZ_A	Najviša	.	.	.	.	.	149,8	155,1	158,1	160,6	163,1	166,4	169,2	2,3%
		Osnovna referenca	121,7	128,6	135,6	137,1	143,9	148,4	150,8	153,3	156,8	158,5	160,5	162,6	1,8%
		Najniža	.	.	.	.	.	146,7	147,6	147,0	148,1	147,3	147,1	146,6	0,3%
Švicarska	LS_TCZ	Najviša	.	.	.	.	.	291,5	302,8	316,4	330,0	341,5	355,2	362,0	3,7%
		Osnovna referenca	254,4	252,1	262,2	266,6	279,8	287,6	294,8	302,0	309,1	313,5	320,0	326,5	2,2%
		Najniža	.	.	.	.	.	284,1	287,2	287,9	292,8	292,1	293,0	294,2	0,7%
Ujedinjena Kraljevina	EG_TCZ_B	Najviša	.	.	.	.	.	1.307,9	1.338,1	1.379,4	1.444,0	1.494,5	1.537,5	1.580,4	3,3%
		Osnovna referenca	1.079,6	1.106,0	1.142,7	1.187,0	1.256,1	1.298,2	1.318,8	1.339,5	1.365,6	1.386,1	1.409,7	1.431,9	1,9%
		Najniža	.	.	.	.	.	1.285,7	1.297,0	1.298,3	1.314,7	1.322,0	1.333,1	1.343,1	1,0%
	EG_TCZ_C (**)	Najviša	.	.	.	.	.	973,9	993,6	1.021,2	1.071,6	1.108,6	1.138,6	1.167,4	3,0%
		Osnovna referenca	826,5	843,8	877,1	907,6	946,8	968,4	981,9	997,3	1.015,4	1.030,4	1.047,0	1.060,4	1,6%
		Najniža	.	.	.	.	.	959,6	968,3	970,3	984,1	990,6	999,8	1.008,0	0,9%

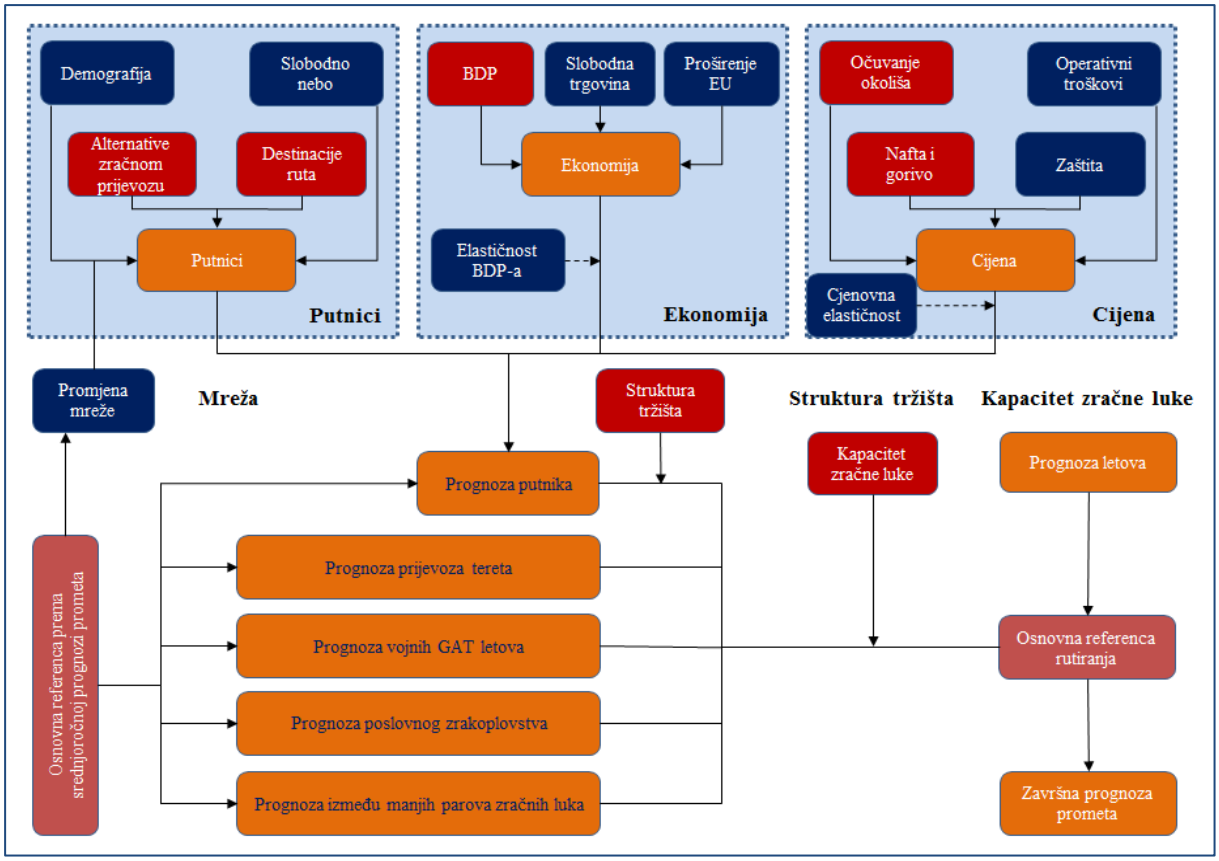
(*) Od 2017. godine, Francuska i Poljska podijelili su TCZ na dvije TCZ-e.

(**) Velika Britanija definirala je UK_TCZ_C kao zasebnu terminalnu naplatnu zonu koja pokriva (engl. *London Approach Service* – LAS) za pet londonskih zračnih luka (Heathrow, Gatwick, Stansted, Luton i London City). Ovih pet zračnih luka su dio devet zračnih luka koje čine UK_TCZ_B.

Izvor: *[8] (prilagodio autor).*

3.3.3. Metodologija izrade dugoročne prognoze (2013-2035)

Dugoročna prognoza (engl. *Long-Term Forecast – LTF*) prometa razmatra niz scenarija, kako će industrija zračnog prometa izgledati u sljedećih 20 godina. Omogućava niz pitanja „što ako“ koja treba istražiti unutar industrije zračnog prometa (npr. rast malih poslovnih zrakoplova ili direktni letovi (engl. *point-to-point*)) ili izvan nje (npr. cijena nafte ili ograničenja okoliša) [20].



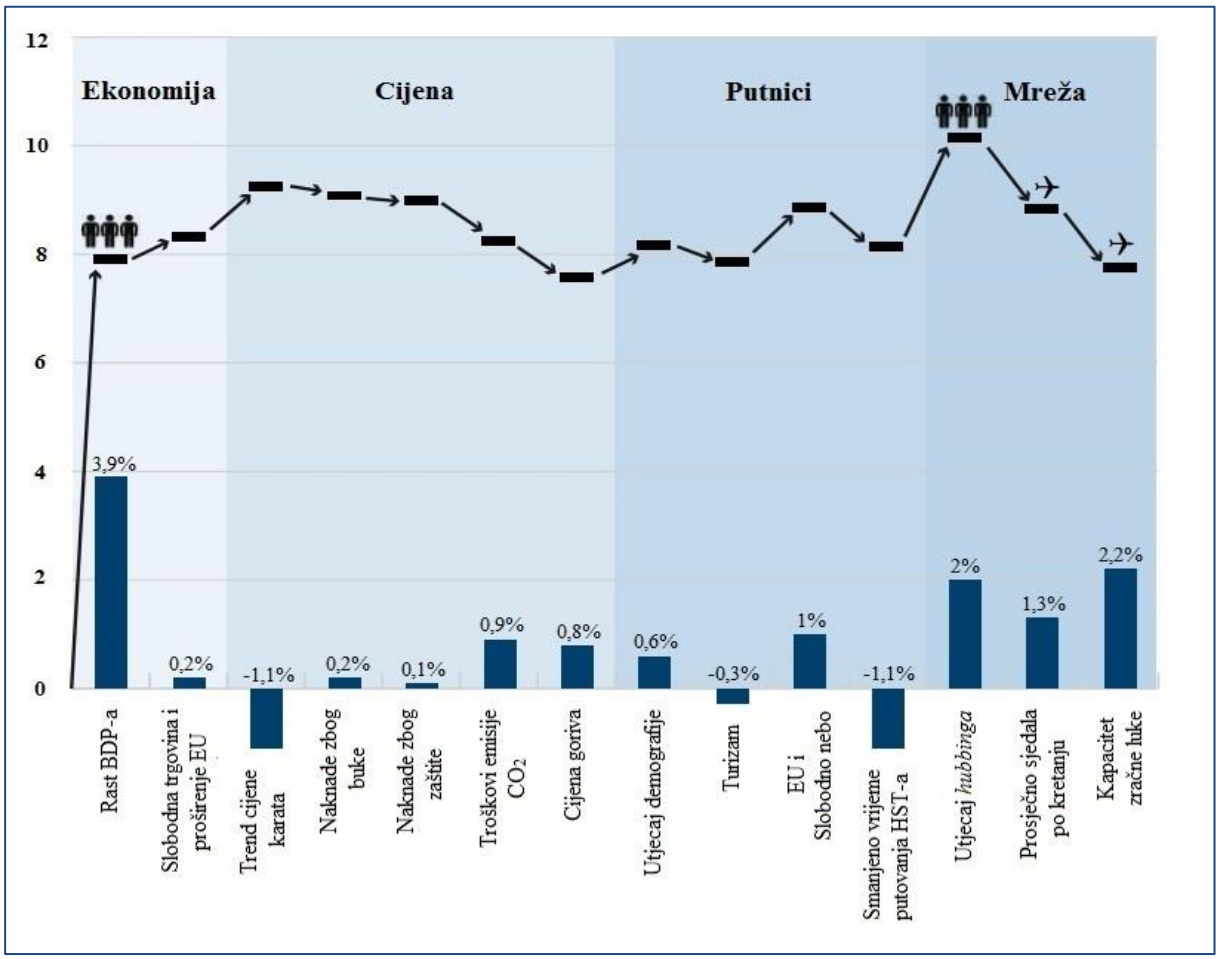
Slika 17: *Shematski prikaz strukture modela za dugoročnu prognozu [36] (prilagodio autor).*

Model dugoročne prognoze (slika 17) i njegovi pod-modeli služe za izradu prognoza između malih parova zračnih luka, putničkih, teretnih i vojnih letova te letova poslovnog zrakoplovstva koji se naposljetku sjedinjuju u završnu prognozu letova. Putnički letovi tradicionalno predstavljaju najveći udio svih IFR kretanja zrakoplova, stoga pod-model putničkog prometa je najdetaljniji i strukturiran pomoću pet glavnih skupina čimbenika:

1) čimbenici globalne ekonomije predstavljaju ključne gospodarske trendove koji utječu na potražnju za zračnim prijevozom;
2) čimbenici koji karakteriziraju putnike i njihove preferencije putovanja, koji utječu na potražnju za putovanjem i krajnjim odredištima;

3) cijena karata objavljena od zračnih prijevoznika, kojom se pokrivaju troškovi poslovanja i koja utječe na odluke putnika prilikom putovanja i odabira prijevoza;
4) veća zastupljenost *hub-and-spoke*[58] ili *point-to-point* mreže ima utjecaj na broj konekcija i letova između početno-završnih točaka;
5) struktura tržišta opisuje veličinu zrakoplova koja se koristi pri zadovoljavanju putničkih potreba i pretvara broj putnika u broj letova [36].

U grafikonu 8 prikazani su čimbenici koji se koriste kao ulazni podaci u model te se na temelju njih može predvidjeti putnička potražnja i IFR kretanja zrakoplova iskazano kroz rast ili pad prometa tijekom dugoročnog razdoblja.



Grafikon 8: *Niz čimbenika koji utječu na putničku potražnju i IFR kretanja zrakoplova, iskazano kroz rast ili pad prometa [36] (prilagodio autor).*

[58]Podrazumijeva sustav u kojem letovi dolaze iz raznih središta tzv. *spoke-ova* u zajedničko čvorište tzv. *hub* iz kojeg odlaze prema drugim središtima u što kraćem vremenskom intervalu [37]. Takav sustav prijevoza većinom koriste tradicionalni zračni prijevoznici.

3.3.3.1 Scenarij budućeg razvoja

Gledajući dvadeset ili više godina unaprijed potrebno je razmotriti više prognoza, pomoću niza scenarija i čimbenika koji utječu na njih, na temelju kojih se može približno odrediti budući razvoj zračnog prometa na području Europe (tablica 19 i grafikon 9). Prema tome, dugoročna prognoza koristi četiri scenarija, kako slijedi:

1) scenarij A: globalni rast;
2) scenarij C: regulirani rast (najvjerojatniji);
3) scenarij C': *happy localism*;
4) scenarij D: fragmentiranje svijeta [36].

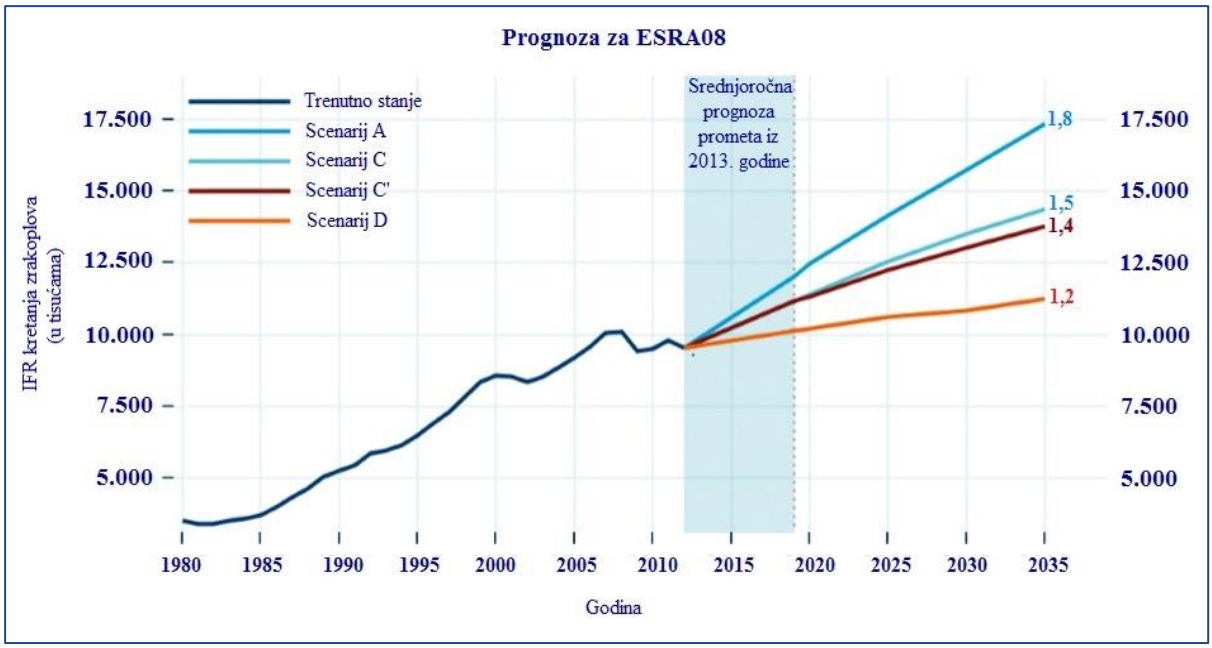
Svaki scenarij koristi različiti niz ulaznih pretpostavki: ekonomski rast, cijenu goriva, faktor popunjenosti, *hub-and-spoke* u odnosu na *point-to-point* prijevoz itd. Na temelju tih pretpostavki, kreira se različit volumen zračnog prometa i različit oblik rasta: dugi dolet[59] (engl. *long-haul*) u odnosu na kratki dolet[60] (engl. *short-haul*), stope podizanja veličine zrakoplova itd. [36].

Tablica 19: *Sažetak prognoze IFR kretanja zrakoplova i njihov godišnji rast u ESRA08 do 2035. godine*

ESRA08		IFR kretanja zrakoplova (u tisućama)									Više prometa (2035-2012)
Scenarij		2009	2010	2011	2012	2019	2020	2025	2030	2035	
A	Globalni rast	9.413	9.493	9.784	9.548	12.045	12.485	14.139	15.749	17.338	**1,8**
C	Regulirani rast	.	.	.	.	11.169	11.411	12.561	13.520	14.356	**1,5**
C'	*Happy Localism*	.	.	.	.	11.169	11.338	12.236	13.015	13.769	**1,4**
D	Fragmentiranje svijeta	.	.	.	.	10.132	10.194	10.612	10.840	11.249	**1,2**
ESRA08		**Prosječna godišnja stopa rasta (u postotcima)**									**Prosječna godišnja stopa rasta (2035-2012)**
Scenarij		**2009**	**2010**	**2011**	**2012**	**2019-2012**	**2020-2019**	**2025-2021**	**2030-2026**	**2035-2031**	
A	Globalni rast	-6,6%	0,8%	3,1%	-2,4%	3,4%	3,7%	2,5%	2,2%	1,9%	**2,6%**
C	Regulirani rast	.	.	.	.	2,3%	2,2%	1,9%	1,5%	1,2%	**1,8%**
C'	*Happy Localism*	.	.	.	.	2,3%	1,5%	1,5%	1,2%	1,1%	**1,6%**
D	Fragmentiranje svijeta	.	.	.	.	0,9%	0,6%	0,4%	0,4%	0,7%	**0,7%**

Izvor: *[36] (prilagodio autor).*

[59]Prometni tok između zračnih luka na udaljenosti većoj od 4.000 kilometara [2].
[60]Prometni tok između zračnih luka na udaljenosti manjoj ili jednakoj od 1.500 kilometara [2].



Grafikon 9: *IFR kretanja zrakoplova i njihovo uvećanje u vremenskom razdoblju prognoze do 2035. godine [36] (prilagodio autor).*

3.3.3.1.1 Scenarij A

Prema scenariju A, scenarij visokog rasta iz MTF-a predstavlja najizazovniju prometnu situaciju na području cijele Europe potpomognutu snažnim gospodarskim rastom, niskim cijenama goriva i Sporazumom o zračnom prometu između EU-a i SAD-a (engl. *Open Skies agreement*). U Europi, do 2035. godine očekuje se oko 17,3 milijuna letova, odnosno 1,8 puta veća razina prometa u odnosu na 2012. godinu. Očekuje se prosječni godišnji rast od 2,6 % u vremenskom razdoblju od 20 godina koji ima najveću stopu rasta u odnosu druge scenarije [36].

Udio domaćih letova očekuje smanjenje prometa od dvije trećine ukupnog prometa (tablica 20). Scenarij se više zalaže za promet dugog doleta nego za promet kratkog doleta. Scenarij govori o razvoju *hub-ova* na Srednjem Istoku koji potiskuju konekcije prometa izvan Europe. Očekivana prosječna stopa rasta domaćih tokova nešto je manja od 2 % u vremenskom razdoblju LTF-a [36].

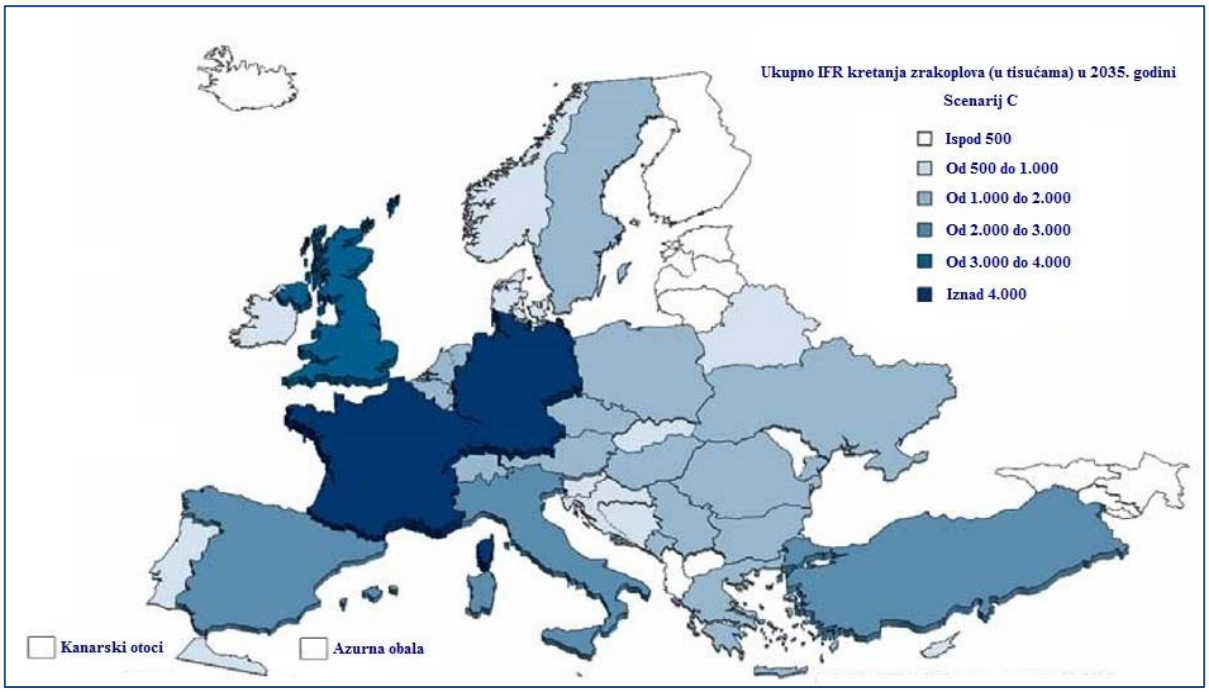
Tablica 20: *Rast domaćeg prometa bit će manji od prosjeka u ESRA Sjeverozapad i ESRA Mediteran. Napomena:* Ukupno *ne uključuje prelete*

Regija	Scenarij		Prosječna godišnja stopa rasta IFR kretanja zrakoplova (u postotcima)		
			Domaći	Odlazni i dolazni	Ukupno
ESRA Sjeverozapad	A	Globalni rast	0,9%	3,1%	**2,1%**
	C	Regulirani rast	0,5%	2,1%	**1,4%**
	C'	*Happy Localism*	0,4%	1,8%	**1,2%**
	D	Fragmentiranje svijeta	-0,3%	0,8%	**0,3%**
ESRA Mediteran	A	Globalni rast	2,1%	3,6%	**3,1%**
	C	Regulirani rast	1,4%	2,6%	**2,2%**
	C'	*Happy Localism*	1,4%	2,4%	**2,0%**
	D	Fragmentiranje svijeta	0,6%	1,4%	**1,1%**
ESRA Istok	A	Globalni rast	3,1%	4,2%	**4,0%**
	C	Regulirani rast	2,2%	3,2%	**3,0%**
	C'	*Happy Localism*	2,3%	3,1%	**2,9%**
	D	Fragmentiranje svijeta	1,4%	2,0%	**1,6%**

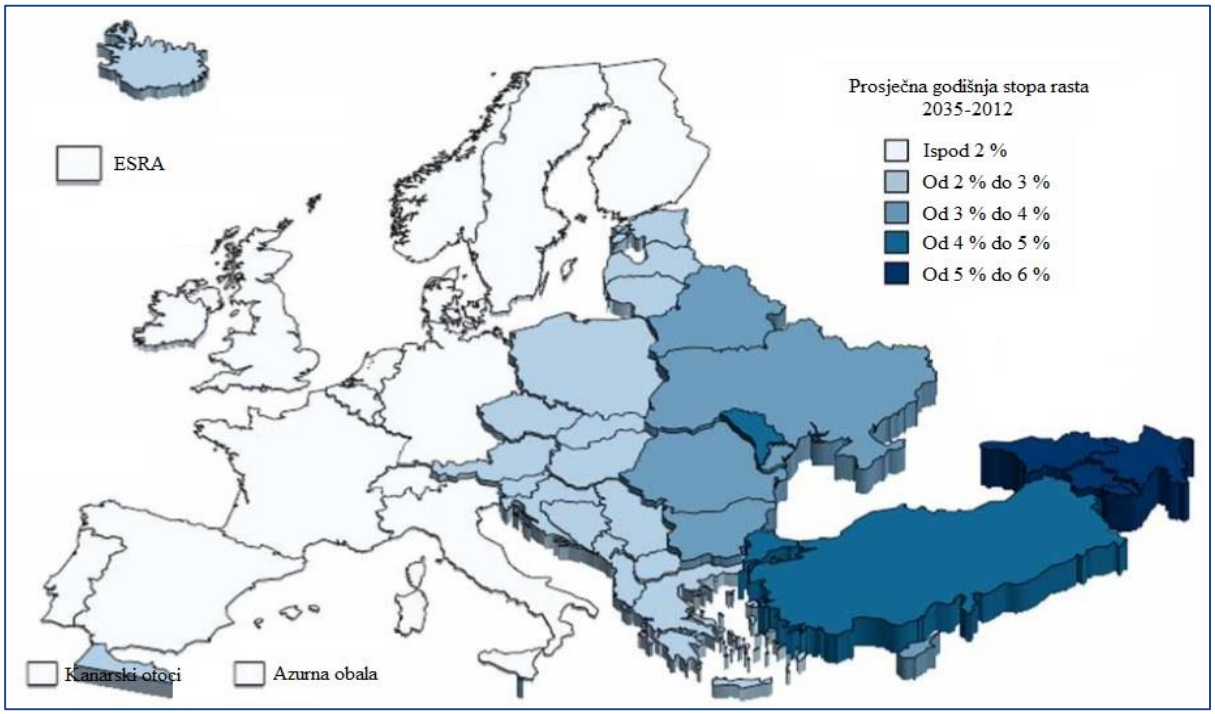
Izvor: *[36] (prilagodio autor).*

3.3.3.1.2 Scenarij C

Prema „najvjerojatnijem“ scenariju (scenarij C) očekuje se oko 14,4 milijuna IFR kretanja zrakoplova (slika 18) na području Europe u 2035. godini, što je 1,5 puta više nego za 2012. godinu. Prosječni godišnji rast (slika 19) trebao bi iznositi 1,8 %, biti intenzivniji u Istočnoj Europi i ekspanzivniji za promet prema Europi i od nje Turska će biti najveći generator dodatnih letova u Europi i imat će najveći broj dodatnih letova u svom zračnom prostoru. Scenarij A i D u odnosu na scenarij C i C' prognozira različite volumene prometa u iznosu od 17,3 i 11,2 milijuna letova [36]. Za pojedine države zapadne Europe poput Njemačke i Francuske očekuje se daljnji nastavak visokog intenziteta prometa od četiri milijuna IFR kretanja zrakoplova. Slijedit će Ujedinjena Kraljevina i Turska s oko tri milijuna IFR kretanja zrakoplova u svom zračnom prostoru u 2035. godini.

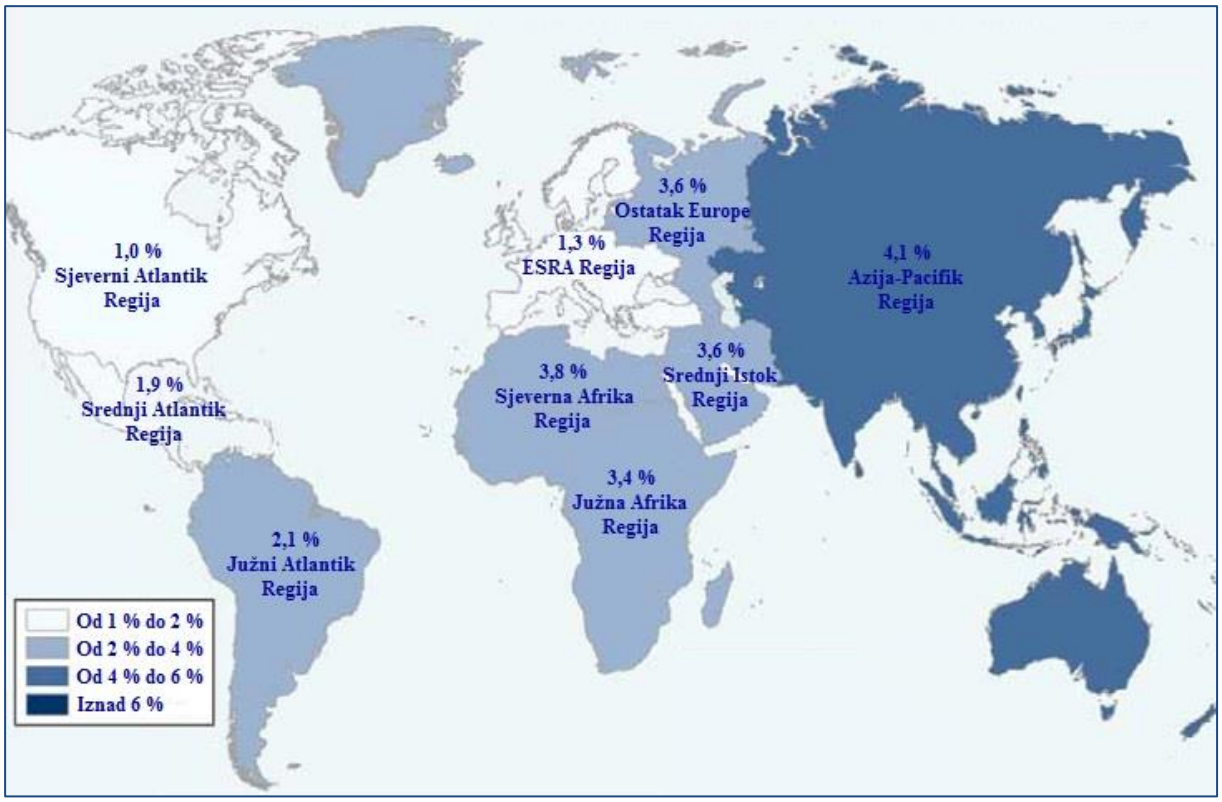


Slika 18: *Ukupno IFR kretanja zrakoplova (u tisućama) na području Europe prema „najvjerojatnijem" scenariju [36] (prilagodio autor).*



Slika 19: *Prosječna godišnja stopa rasta IFR kretanja zrakoplova na području Europe (ESRA08) prema „najvjerojatnijem" scenariju [36] (prilagodio autor).*

Azija-Pacifik regija pružat će najveću suradnju s ESRA regijom koja očekuje prosječnu stopu rasta odlaznih letova od 4,1 % prema scenariju C. Regije kao što su: Sjeverna Afrika, Srednji Istok i Ostatak Europe (uključujući Rusiju) daju mogućnost privlačenja europskog zračnog prometa.



Slika 20: *Prosječna godišnja stopa rasta glavnih prometnih tokova po ICAO prometnim regijama u vremenskom razdoblju od 2012. godine do 2035. godine prema „najvjerojatnijem" scenariju [36] (prilagodio autor).*

3.3.3.1.3 Scenarij C'

Scenarij C' slijedi gotovo istu stopu rasta scenarija C, ali se rast prometa razvija sporije u scenariju C' od 2020. godine kao rezultat usporenog gospodarskog rasta, većih cijena goriva i većih faktora popunjenosti (usporedba sa scenarijem C). Usporena stopa rasta od 2025. godine, rezultira razlikom od 0,6 milijuna manje IFR kretanja zrakoplova u scenariju C' (uspoređeno sa scenarijem C) u 2035. godini [36].

3.3.3.1.4 Scenarij D

Scenarij D počinje s najnižom stopom rasta koja se temelji na MTF prometu u Europi koji pokušava već duži niz godina uspostaviti rastući trend. Nizak rast podrazumijeva visoke cijene nafte, labilan gospodarski rast, bez migracije stanovništva i sporazuma o slobodnoj trgovini s izvaneuropskim partnerima, visoke cijene putovanja itd. Ovaj scenarij očekuje 11,2 milijuna letova u Europi do 2035. godine, što odgovara prosječnoj godišnjoj stopi rasta od 0,7 % [36].

Scenarij D izražava napetosti u svijetu, unutar i izvan Europe. Ako ovaj scenarij pokazuje sličnu distribuciju tokova prometa kao scenariji C i C' (približno 70 % domaći, 28 % dolazni i odlazni te 2 % preleti), razvoj unutarnjeg prometa u Europi do 2035. godine trebao bi biti oko nule (0,3 %), dok bi prosječna stopa rasta međunarodnog prometa iznosila 1,8 % [36].

3.3.3.2 Rezultati dugoročne prognoze

Tablica 21: *IFR kretanja zrakoplova (domaći, odlazni i dolazni te preleti) i njihov godišnji rast na području Europe (ESRA08) do 2035. godine*

ESRA08	Scenarij	IFR kretanja zrakoplova (u tisućama)									Prosječna godišnja stopa rasta (2035-2012)	Veći promet (2035-2012)
		2009	2010	2011	2012	2019	2020	2025	2030	2035		
Domaći	A	7.602	7.562	7.790	7.514	9.091	9.359	10.208	10.934	11.510	1,9%	1,5
	C	.	.	.	.	8.474	8.625	9.265	9.735	10.068	1,3%	1,3
	C'	.	.	.	.	8.474	8.576	9.095	9.495	9.855	1,2%	1,3
	D	.	.	.	.	7,71	7.733	7.918	7.947	8.102	0,3%	1,1
Odlazni i dolazni	A	1.711	1.815	1.883	1.916	2,76	2.921	3.660	4.461	5.366	4,6%	2,8
	C	.	.	.	.	2.520	2.605	3.074	3.518	3.966	3,2%	2,1
	C'	.	.	.	.	2.520	2.582	2.928	3.271	3.621	2,8%	1,9
	D	.	.	.	.	2.261	2.295	2.506	2.684	2.911	1,8%	1,5
Preleti	A	100	116	112	119	194	205	271	354	461	6,1%	3,9
	C	.	.	.	.	175	182	222	267	321	4,4%	2,7
	C'	.	.	.	.	175	180	213	249	292	4,0%	2,5
	D	.	.	.	.	161	165	188	209	236	3,0%	2,0
Ukupno	A	9.413	9.493	9.784	9.548	12.045	12.485	14.139	15.749	17.338	2,6%	**1,8**
	C	.	.	.	.	11.169	11.411	12.561	13.520	14.356	1,8%	1,5
	C'	.	.	.	.	11.169	11.338	12.236	13.015	13.769	1,6%	**1,4**
	D	.	.	.	.	10.132	10.194	10.612	10.840	11.249	0,7%	1,2
ESRA08	**Scenarij**	**Godišnji rast IFR kretanja zrakoplova (u postotcima)**									**Prosječna godišnja stopa rasta (2035-2012)**	**Veći promet (2035-2012)**
		2009	**2010**	**2011**	**2012**	**2019**	**2020**	**2025**	**2030**	**2035**		
Domaći	A	.	-0,5%	3,0%	-3,5%	2,8%	2,9%	1,8%	1,4%	1,0%	1,9%	1,5
	C	.	.	.	.	1,7%	1,8%	1,4%	1,0%	0,7%	1,3%	1,3
	C'	.	.	.	.	1,7%	1,2%	1,2%	0,9%	0,7%	1,2%	1,3
	D	.	.	.	.	0,4%	0,3%	0,5%	0,1%	0,4%	0,3%	1,1
Odlazni i dolazni	A	.	6,1%	3,7%	1,7%	5,4%	5,8%	4,6%	4,0%	3,8%	4,6%	2,8
	C	.	.	.	.	4,0%	3,4%	3,4%	2,7%	2,4%	3,2%	2,1
	C'	.	.	.	.	4,0%	2,5%	2,5%	2,2%	2,1%	2,8%	1,9
	D	.	.	.	.	2,4%	1,5%	1,8%	1,4%	1,6%	1,8%	1,5
Preleti	A	.	15,0%	-3,4%	6,6%	7,2%	5,7%	5,8%	5,5%	5,4%	6,1%	3,9
	C	.	.	.	.	5,6%	4,0%	4,1%	3,8%	3,7%	4,4%	2,7
	C'	.	.	.	.	5,6%	3,3%	3,4%	3,1%	3,3%	4,0%	2,5
	D	.	.	.	.	4,4%	2,5%	2,6%	2,2%	2,4%	3,0%	2,0
Ukupno	A	.	0,8%	3,1%	-2,4%	3,4%	3,7%	2,5%	2,2%	1,9%	2,6%	**1,8**
	C	.	.	.	.	2,3%	2,2%	1,9%	1,5%	1,2%	1,8%	1,5
	C'	.	.	.	.	2,3%	1,5%	1,5%	1,2%	1,1%	1,6%	**1,4**
	D	.	.	.	.	0,9%	0,6%	0,8%	0,4%	0,7%	0,7%	1,2

Izvor: *[36] (prilagodio autor).*

3.3.3.2.1 Kapacitet zračne luke

Utjecaj ograničenja kapaciteta zračne luke na mrežu (tablica 22) procjenjuje:

1) u scenariju C oko 1,9 milijuna letova koji će biti izgubljeni što odgovara ukupnoj potražnji od 12 % u 2035. godini;
2) u scenariju A oko 4,4 milijuna letova koji će biti izgubljeni zbog nedostatka kapaciteta na zračnim lukama što odgovara stvarnoj potražnji[61] (engl. *unconstrained demand*) od 20 % u 2035. godini;
3) u scenarij C' i D smanjit će se potražnja u zračnim lukama u odnosu na ostala dva scenarija. U 2035. godini, sustav neće moći opslužiti potražnju (engl. *unaccommodated demand*)[62] od milijun letova u scenariju C' i potražnju od 0,2 milijuna letova u scenariju D [36].

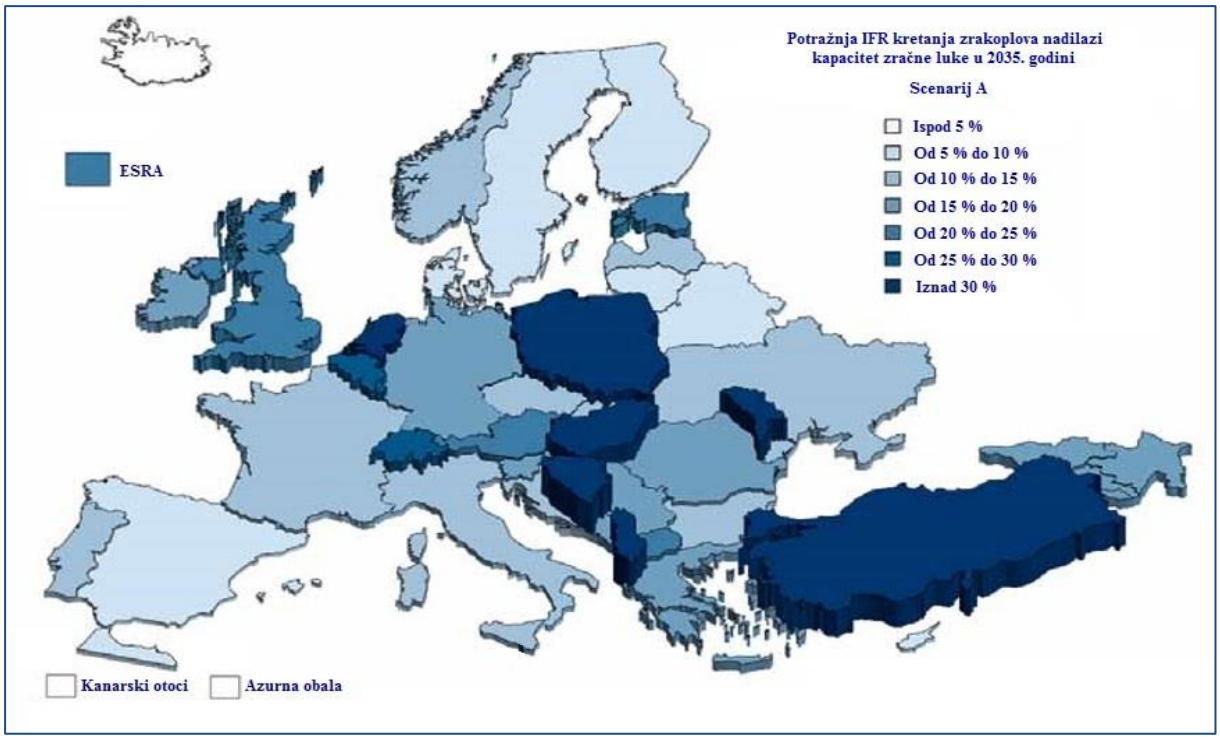
Tablica 22: *Prema „najvjerojatnijem" scenariju oko dva milijuna IFR kretanja zrakoplova bit će odbijeno zbog ograničenja kapaciteta zračnih luka*

ESRA08		Neopslužena IFR kretanja zrakoplova (u milijunima)				Neopslužena potražnja (u postotcima)			
Scenarij		2020	2025	2030	2035	2020	2025	2030	2035
A	Globalni rast	0,4	1,3	2,3	4,4	3%	8%	13%	20%
C	Regulirani rast	0,2	0,5	1,2	1,9	1%	4%	8%	12%
C'	*Happy Localism*	0,1	0,3	0,6	1,0	1%	2%	5%	7%
D	Svjetska fragmentiranost	0,0	0,1	0,1	0,2	0%	1%	1%	2%

Izvor: *[36] (prilagodio autor).*

Neusklađenost između kapaciteta i potražnje nije ista na području cijele Europe. Turska će imati oko 30 % više dolaznih i odlaznih letova na svojim zračnim lukama prema „najvjerojatnijem" scenariju C u 2035. godini. Države koje se nalaze na području istočne Europe, poput Bugarske, Mađarske i Rumunjske imat će od 17 % do 22 % više potražnje (svaka država) koja se neće moći opslužiti u 2035. godini (slika 21).

[61]Podrazumijeva prognozu koja nije ograničena kapacitetom na glavnim zračnim lukama [36].
[62]Podrazumijeva prognozu letova koja nadilazi deklarirani kapacitet zračnih luka [36].



Slika 21: *Potražnja IFR kretanja zrakoplova (ne uključuje prelete) koja nadilazi kapacitet zračnih luka u 2035. godini prema scenariju A [36] (prilagodio autor).*

3.3.3.2.2 Mreža zračnih luka i zračnih prijevoznika

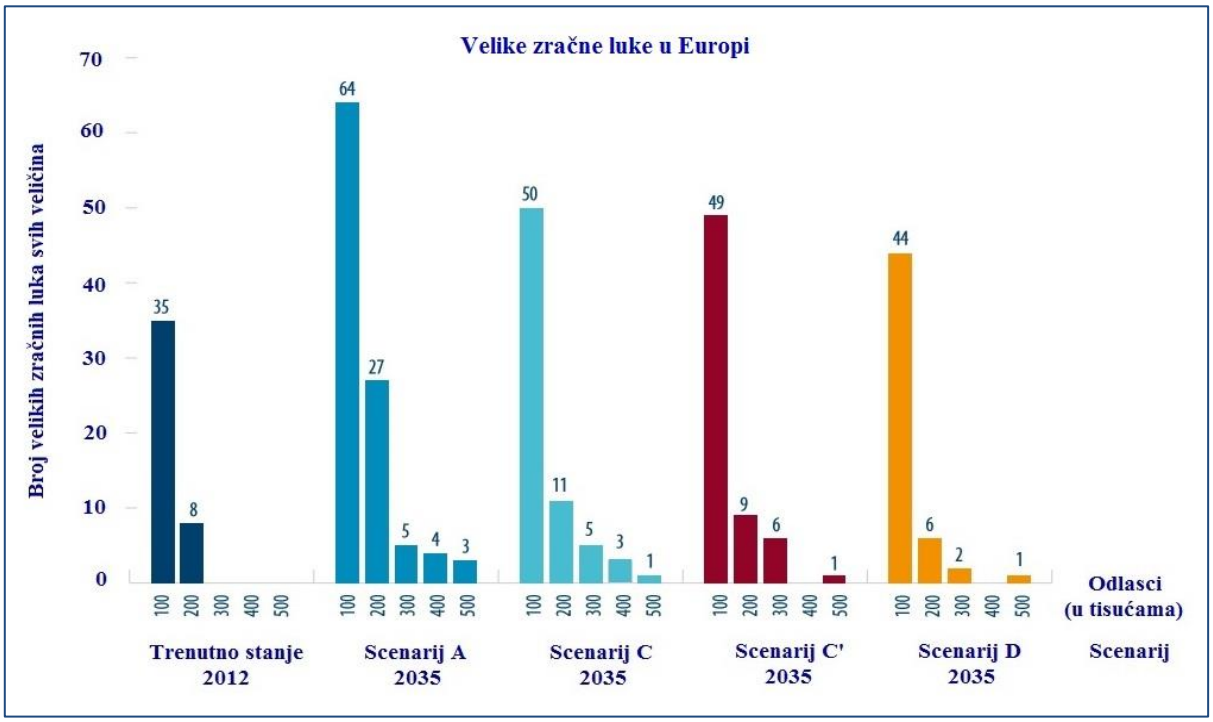
Različite zračne luke igraju različitu ulogu u europskoj ATM mreži, od kojih se neke usmjeravaju na ciljane grupe potrošača (npr. zračne luke niskotarifnih zračnih prijevoznika pružaju usluge *point-to-point* prijevoza na destinacijama kratkog doleta, dok gradske zračne luke uglavnom posjećuju poslovni putnici koji rade u industrijama smještenim u gradu), dok druge zračne luke privlače dodatne putnike ili služe kao čvorišta za glavne zračne prijevoznike [36].

Strategija zračnog prijevoznika mijenja se prilikom odabira tržišnog udjela te se razvija tijekom vremena. Prilikom dizajniranja i modernizacije mreže opsluživanja u zračnom prometu, zračni prijevoznici odlučuju se za *hub-and-spoke* ili *point-to-point* prijevoz ovisno o čimbenicima: ciljano tržište putnika, profil operativnih troškova, raspoloživosti *slot-ova*[63] na

[63]Slot odlaska (engl. *Calculated Take-Off Time* – CTOT) operator zrakoplova (engl. *Aircraft Operator* – AO) mora poštivati u vremenskom okviru CTOT-a koji je unaprijed zadan te unutar kojeg mora poletjeti. Vremenski okvir koristi se za nizanje odlaznih letova [38].

zračnim lukama, strategija zajedničkog kodiranog leta[64] (engl. *code sharing)* za povećanje potencijalnih destinacija itd. Zbog teške gospodarske situacije, zračni prijevoznici imaju trend formiranja alijansi, kako bi stvorili veću kooperaciju odnosa i dobili pristup na *hub-ovima* od strana svojih partnera [36].

Grafikon 10 prikazuje, kako će se broj zauzetih zračnih luka povećavati u Europi u sljedećih 20 godina. Na primjer, u najvjerojatnijem scenariju C bit će 20 zračnih luka s više od 150.000 odlaznih IFR operacija godišnje, takvu razinu prometa održava samo osam zračnih luka na području Europe u 2012. godini [36].



Grafikon 10: *Broj odlaznih IFR operacija u većim zračnim lukama na području Europe prema četiri scenarija prognoze u 2035. godini [36] (prilagodio autor).*

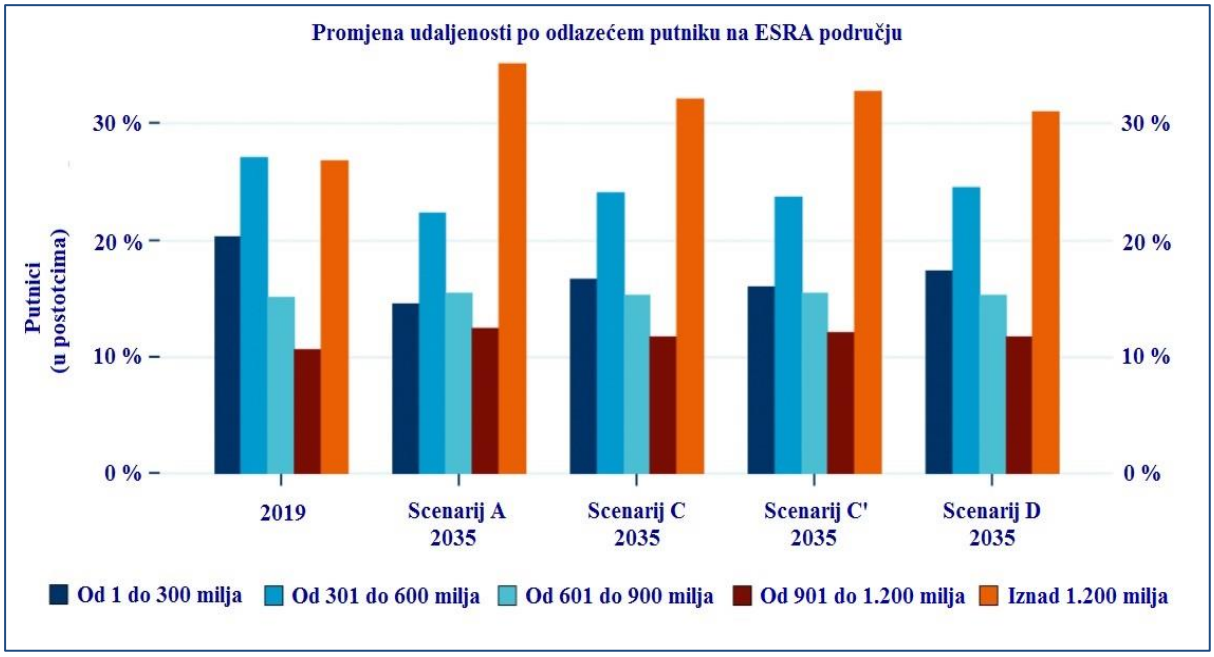
3.3.3.2.3 Udaljenost prijevoza i veličina zrakoplova

Prosječna udaljenost putovanja bit će veća za 8 % u vremenskom razdoblju od 2019. do 2035. godine za odlazne letove na području Europe. Flota će evoluirati i bit će sve veća potražnja za letovima dugog doleta koji će biti opsluženi s „velikim ili vrlo velikim“

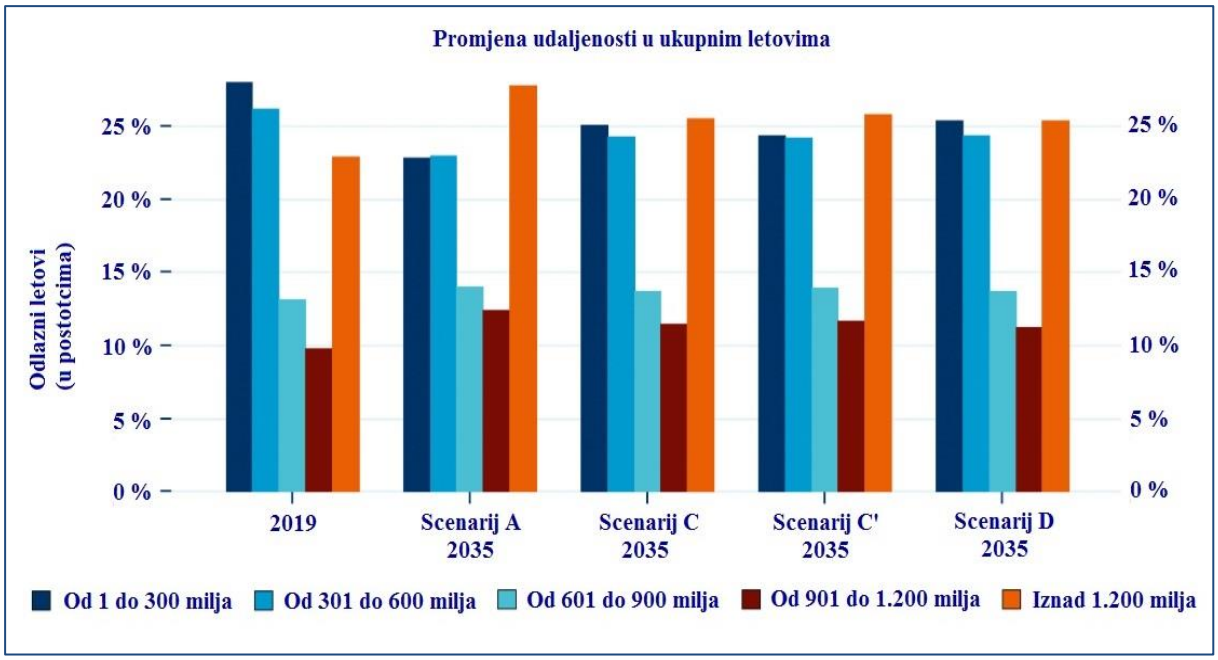
[64]engl. *Code Sharing Agreement* – komercijalni sporazum o zajedničkom kodiranom letu koji se temelji na zajedničkom dogovoru o plasmanu kapaciteta na tržištu s vidljivom kodnom oznakom dvaju ili više partnera u prodajnim, distribucijskim i rezervacijskim kanalima [21].

zrakoplovima. Postoji niz čimbenika koji utječu na udaljenost prijevoza: slobodna trgovina i sporazumi o slobodnom nebu, nove države članice EU, promjena *hub-ova* i preferencije u odabiru odmorišnih destinacija, slabost domaćih tokova itd.. Svi ti čimbenici, integrirani u metodu prognoziranja, međusobno povezuju učinke potražnje putnika [36].

Grafikon 11 prikazuje povećanje duljine putovanja u četiri scenarija. Očekuje se relativno manje putovanja na udaljenostima do 900 milja (oko 1.500 kilometara, u zoni kratkog doleta) u 2035. godini, usporedba s 2019. godinom. Veći broj putnika letjet će na udaljenostima većim od 900 kilometara. Kao rezultat tome, prosječna udaljenost po putovanja povećat će se za 8 % u vremenskom razdoblju od 2019. do 2035. godine prema scenariju C [36].



Grafikon 11: *Promjena udaljenosti po odlaznom putniku u ESRA području prema srednjoročnoj prognozi prometa iz 2013. godine. Sve veći broj putnika koji lete na dugo-linijskim letovima [36] (prilagodio autor).*



Grafikon 12: *Promjena udaljenosti ukupnih letova prema srednjoročnoj prognozi prometa iz 2013. godine. Povećanje odlaznih letova na dugo-linijskim letovima [36] (prilagodio autor).*

U tablici 23, priloženi su podaci koji iskazuju kako raste prosječna veličina zrakoplova. Za sva četiri scenarija na ESRA području letovi dugog doleta opslužuju se zrakoplovima većeg kapaciteta. Za najvjerojatniji scenarij, prosječan zrakoplov ponudit će od 1 % do 1,3 % veći kapacitet sjedala po letu. Veći zrakoplovi koriste za letove kratkog doleta prema scenariju C odnosno regulirani rast. Tehnološki i stabilan gospodarski rast u scenariju A tj. globalni rast bilježi više putnika na letovima kratkog doleta pružajući veći kapacitet sjedala [36].

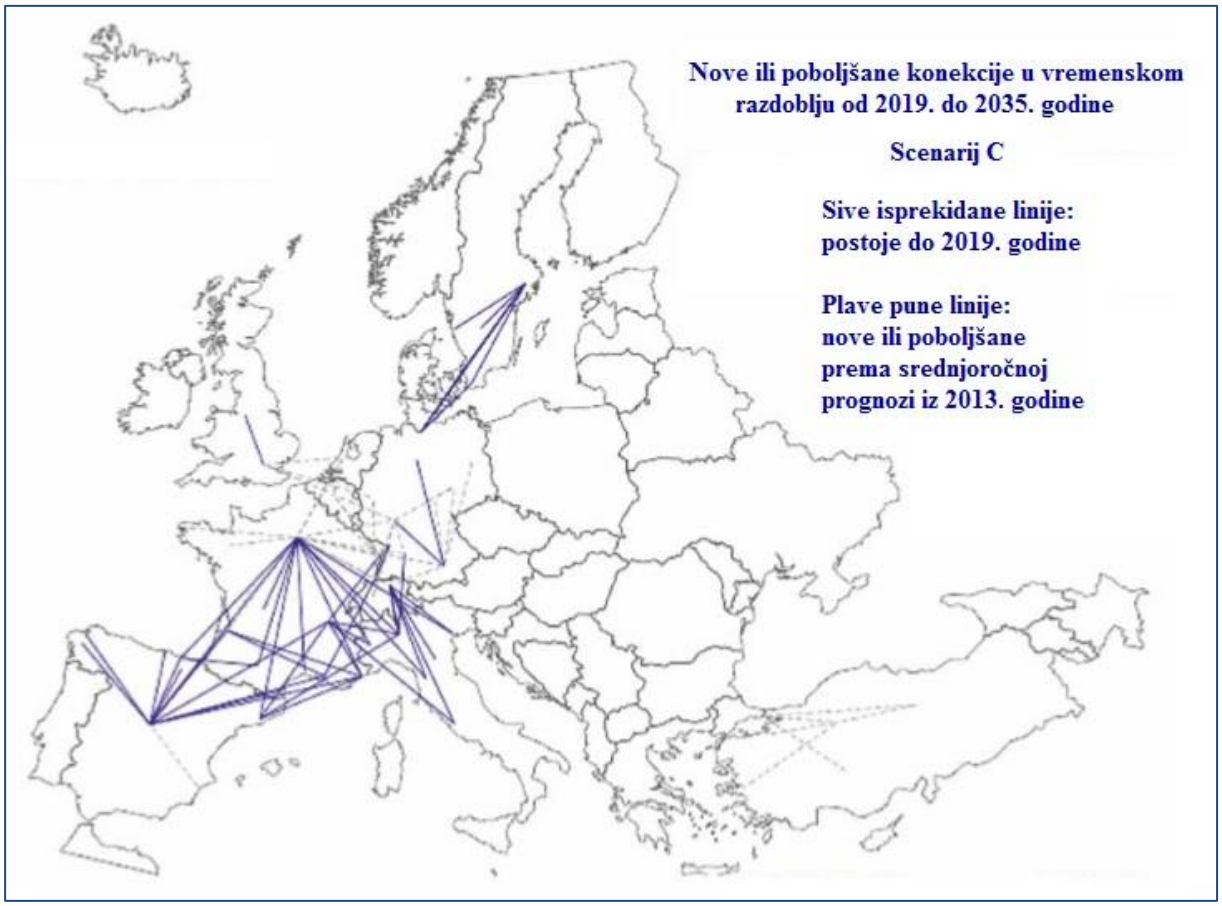
Tablica 23: *Veličina zrakoplova brže raste za dugo-linijske letove*

ESRA08		Prosječna godišnja promjena u veličini zrakoplova (sjedala po letu)					
Scenarij		Od 1 do 300 milja	Od 301 do 600 milja	Od 601 do 900 milja	Od 901 do 1.200 milja	Iznad 1.200 milja	Ukupno
A	Globalni rast	1,1%	0,8%	0,6%	0,5%	1,3%	**1,2%**
C	Regulirani rast	1,3%	1,1%	0,9%	0,8%	1,3%	**1,3%**
C'	*Happy Localism*	0,1%	0,9%	0,6%	0,5%	1,6%	**1,0%**
D	Fragmentiranje svijeta	0,4%	1,2%	0,8%	0,7%	1,7%	**1,1%**

Izvor: *[36] (prilagodio autor).*

3.3.3.2.4 Utjecaj vlakova velikih brzina

Više od 50 parova gradova bit će povezano novom ili poboljšanom vezom u vremenskom razdoblju od 2019. do 2035. godine. Putnici koji se opredjeljuju za željeznicu velikih brzina (slika 22), smanjit će potražnju za zračnim prometom za nešto više od 0,5 % do 2035. godine [36].



Slika 22: *Mreža željeznica velikih brzina uglavnom je razvijena na području zapadne Europe [36] (prilagodio autor).*

Jedan od glavnih konkurenata zračnom prijevozu na letovima kratkog doleta su vlakovi velikih brzina. Razvojem vlakova velikih brzina, može se ponuditi slično vrijeme prijevoza na udaljenostima do 800 kilometara [36].

3.3.3.3 Utjecaj rizika na dugoročnu prognozu

Glavni izvori nesigurnosti u dugoročnoj prognozi su:

1) **gospodarstvo** ostaje neizvjesno i povrat ka rastu je odgođen. Iskustvo posljednjih godina sugerira da još uvijek možemo vidjeti daljnje smanjenje u rastu i daljnje odgode oporavka;
2) **buduće izmjene u mreži** (npr. nove rute) za prognozu se ne modeliraju. Otvaranje Kosovskog zračnog prostora povećalo je rizik u nekim državama, dok je u drugim smanjilo rizik;
3) **turistički trendovi** su vrlo promjenjivi. Srednjoročna prognoza treba biti točna tijekom sedmogodišnjeg razdoblja, a ne utvrditi koja će destinacija biti preferencija putnika za odmor u određenoj godini. Nedavna politička nestabilnost u Egiptu i Tunisu dovela je do veće varijabilnosti turističkih destinacija;
4) **cijene nafte** ostaju promjenjive te nafta sve više postaje špekulacija i investicija. Budući da se gorivo odnosi na od 25 % do 35 % ili čak više operativnih troškova zračnih prijevoznika, takva situacija može imati utjecaj na cijenu i troškove putovanja korisnika prijevoza.
5) **trgovanje emisijom štetnih plinova** (engl. *Emission Trading Scheme* – ETS[65]), trenutno pod intenzivnom raspravom zašto nije bilo integrirano u sedmogodišnju prognozu, ali je uključeno u dugoročnu prognozu putem pretpostavki oko troškova CO_2 od 2020. godine pa nadalje. Međutim, takve regulatorne mjere (npr. novi porezni režimi ili buduća ograničenja očuvanja okoliša) pridonose neizvjesnosti rasta zračnog prometa i mogu brzo uvesti i mijenjati lokalni izgled rasta letova;
6) **teroristički napadi, ratovi i prirodne katastrofe**. Posljednjih sedam godina nisu bile mirne za zrakoplovstvo. Nema razloga vjerovati da će u idućih sedam godina biti bez poteškoća od npr. posljedica erupcije vulkana ili gripe H_1N_1 itd. [36].

[65]Uspostavljena shema funkcionira kroz dodjelu i trgovinu emisijskim jedinicama (mjerljivo u tonama CO_2). Ovisno o ostvarenim stvarnim emisijama i dodijeljenim kvotama, obveznici imaju fleksibilnost za kupnju nedostajućih ili prodaju viška prava na emisiju [21].

4. ANALIZA ATM PROMETNIH POKAZATELJA U REPUBLICI HRVATSKOJ

U kontekstu upravljanja zračnim prometom, Hrvatska kontrola zračne plovidbe (engl. *Croatia Control Ltd.* – CCL) pruža operativne usluge u zračnom prometu u suradnji s relevantnim državnim tijelima, korisnicima zračnog prostora i međunarodnim organizacijama koje sudjeluju u upravljanju zračnim prostorom i upravljanju protokom zračnog prometa [40]. Na temelju raspoloživih statističkih vrijednosti omogućava se izrada trend krivulja sa svrhom jednostavnijeg razumijevanja budućih ATM prometnih pokazatelja na području Republike Hrvatske. Vrijednosti se odnose na opći zračni promet (engl. *General Air Traffic* – GAT) koji koristi pravila za let uz pomoć instrumenata (engl. *Instrument Flight Rules* – IFR).

4.1. Satno IFR kretanje zrakoplova

U sljedećoj tablici 24 priloženi su podaci za satno IFR kretanje zrakoplova u vremenskom razdoblju od 2017. do 2019. godine. Može se iščitati trenutno stanje kapaciteta od 148 zrakoplova po satu do najviše 163 zrakoplova koja se predviđaju za 2019. godinu u području odgovornosti (engl. *Area of Responsibility* – AoR) LDZO ACC. Kako bi traženi profil kapaciteta bio zadovoljen, zahtijeva se stopa rasta od 12 % u odnosu na trenutno stanje 2016. godine. Najveći broj otvorenih sektora u takvom trenutku mora biti 12 tzv. konfiguracija „c12a“.

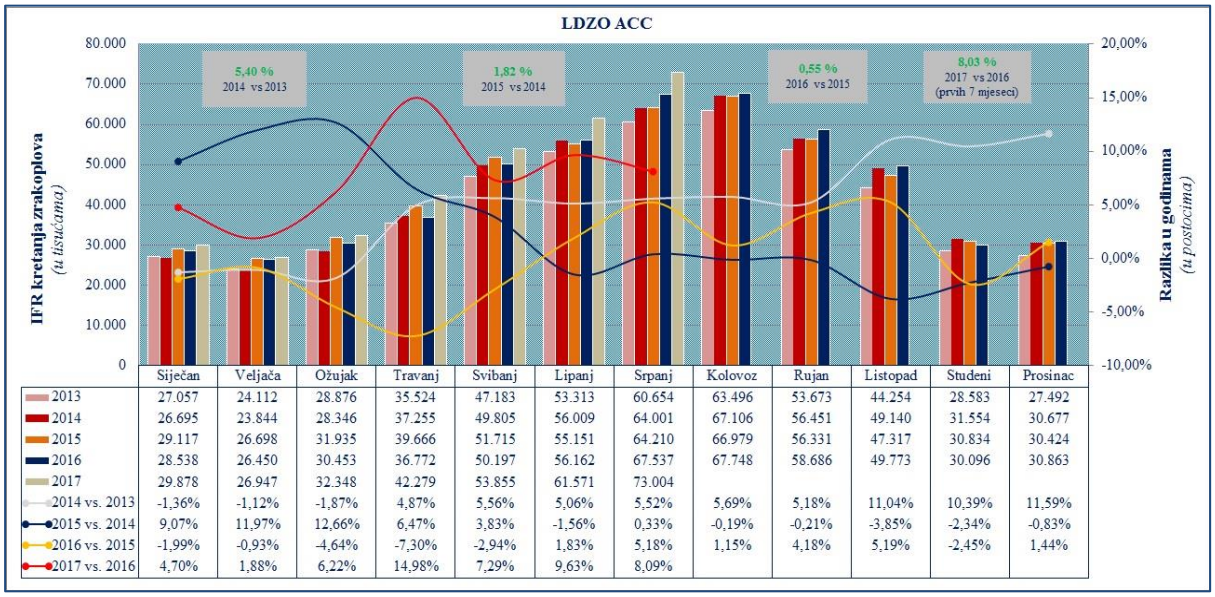
Tablica 24: *Traženi profil kapaciteta za ACC Zagreb*

Država	ACC/APP	Kapacitet 2016	Stopa rasta prometa	Kretanje prometa po satu i povećanje u % u odnosu na 2016. godinu					
				2017		2018		2019	
Hrvatska	Zagreb LDZO ACC	145	Najviša	149	3%	157	8%	**163**	12%
			Osnovna referenca	147	1%	149	3%	152	5%
			Najniža	145	0%	145	0%	146	1%
			Otvoreno	**147**	**1%**	**149**	**3%**	**152**	**5%**
			Trenutno stanje	**148**	**2%**	**150**	**3%**	**153**	**6%**

Izvor: *[31] (prilagodio autor).*

4.2. Mjesečno IFR kretanje zrakoplova

Trenutno stanje IFR kretanja zrakoplova po mjesecima u nadležnosti ACC Zagreb za područje letnih informacija (engl. *Flight Information Region* – FIR) u vremenskom razdoblju od 2013. do 2017. godine (prvih sedam mjeseci) prikazano je na grafikonu 13.



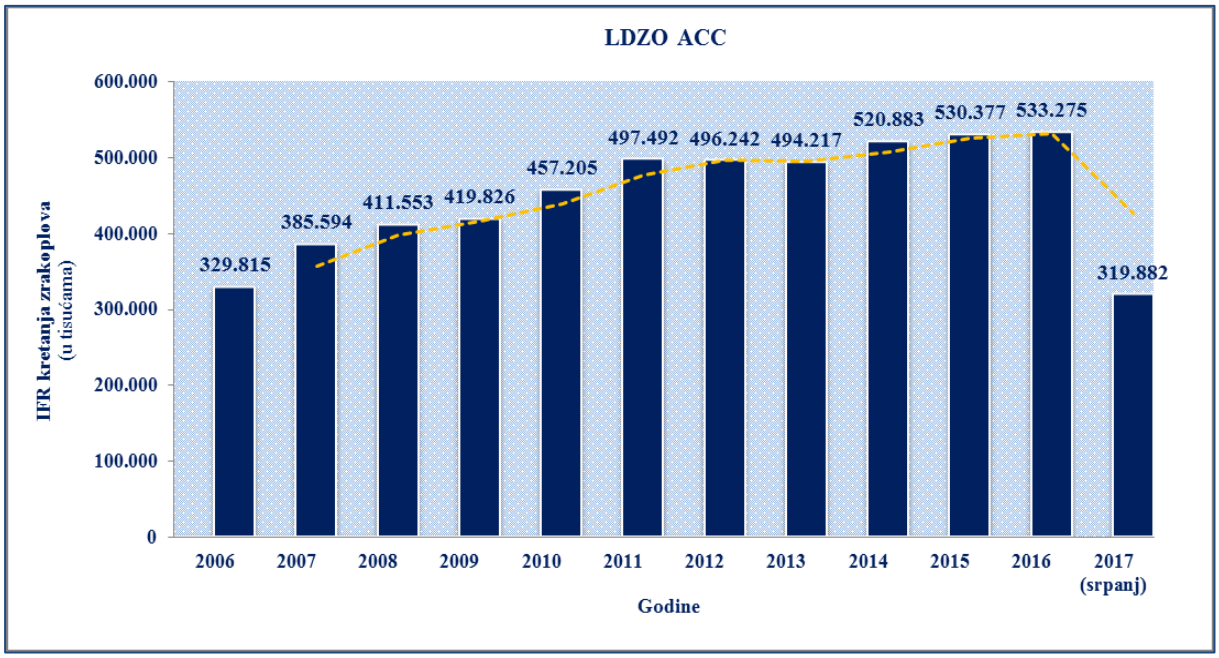
	Siječan	Veljača	Ožujak	Travanj	Svibanj	Lipanj	Srpanj	Kolovoz	Rujan	Listopad	Studeni	Prosinac
2013	27.057	24.112	28.876	35.524	47.183	53.313	60.654	63.496	53.673	44.254	28.583	27.492
2014	26.695	23.844	28.346	37.255	49.805	56.009	64.001	67.106	56.451	49.140	31.554	30.677
2015	29.117	26.698	31.935	39.666	51.715	55.151	64.210	66.979	56.331	47.317	30.834	30.424
2016	28.538	26.450	30.453	36.772	50.197	56.162	67.537	67.748	58.686	49.773	30.096	30.863
2017	29.878	26.947	32.348	42.279	53.855	61.571	73.004					
2014 vs. 2013	-1,36%	-1,12%	-1,87%	4,87%	5,56%	5,06%	5,52%	5,69%	5,18%	11,04%	10,39%	11,59%
2015 vs. 2014	9,07%	11,97%	12,66%	6,47%	3,83%	-1,56%	0,33%	-0,19%	-0,21%	-3,85%	-2,34%	-0,83%
2016 vs. 2015	-1,99%	-0,93%	-4,64%	-7,30%	-2,94%	1,83%	5,18%	1,15%	4,18%	5,19%	-2,45%	1,44%
2017 vs. 2016	4,70%	1,88%	6,22%	14,98%	7,29%	9,63%	8,09%					

Grafikon 13: *Komparativni prikaz ostvarenog IFR kretanja zrakoplova po mjesecima u vremenskom razdoblju od 2013. do 2017. godine (do srpnja) [41] (izradio autor).*

Na temelju promatrane analize (grafikon 13) može se uvidjeti rast IFR kretanja zrakoplova u 2015. godini do svibnja nakon kojeg dolazi do pada IFR kretanja zrakoplova od 1,56 %, ako se komparira s prethodnom 2014. godinom. Od lipnja 2015. godine do kraja godine bilježe se stope pada IFR kretanja u intervalu od 0,19 % do 3,85 % te se negativni trend nastavlja do lipnja 2016. godine nakon kojeg počinju pozitivne stope rasta. Značajan porast IFR prometa bilježi se u kolovozu tijekom sve tri godine, zbog velike turističke potražnje na hrvatskom priobalju. Najveći mjesečni porast prometa u odnosu na prethodnu godinu zabilježen je u travnju 2017. godine s porastom od 14,98 %. Na razini ukupnog IFR kretanja zrakoplova (domaći, dolazni i odlazni, preleti) u Republici Hrvatskoj u prvih sedam mjeseci 2017. godine zabilježeno je 319.882 letova, što je u usporedbi s prethodnom 2016. godinom, u kojoj se za isto vremensko razdoblje ostvarilo 296.109 letova, porast od 8,03 % kao posljedica većeg obujma ACC prometa. Značajno povećanje zabilježeno je tijekom najprometnijih ljetnih mjeseci kao razlog dolazaka velikog broja turista na hrvatski Jadran. U srpnju 2017. godine je zabilježen najveći mjesečni IFR promet do sada od 73.004 letova, što je porast od 8,10 % u odnosu na prošlu godinu [41].

4.3. Godišnje IFR kretanje zrakoplova

Usporedni prikaz trenutnog stanja IFR kretanja zrakoplova pomoću okomitih pravokutnika u vremenskom razdoblju od 2006. do tekuće 2017. godine prikazan je na grafikonu 14. Isprekidana žuta linija predstavlja pomični prosjek (vidi poglavlje 2.1.2.3.). Iz priloženog grafikona može se uočiti blagi linearni rast IFR kretanja zrakoplova po godinama.

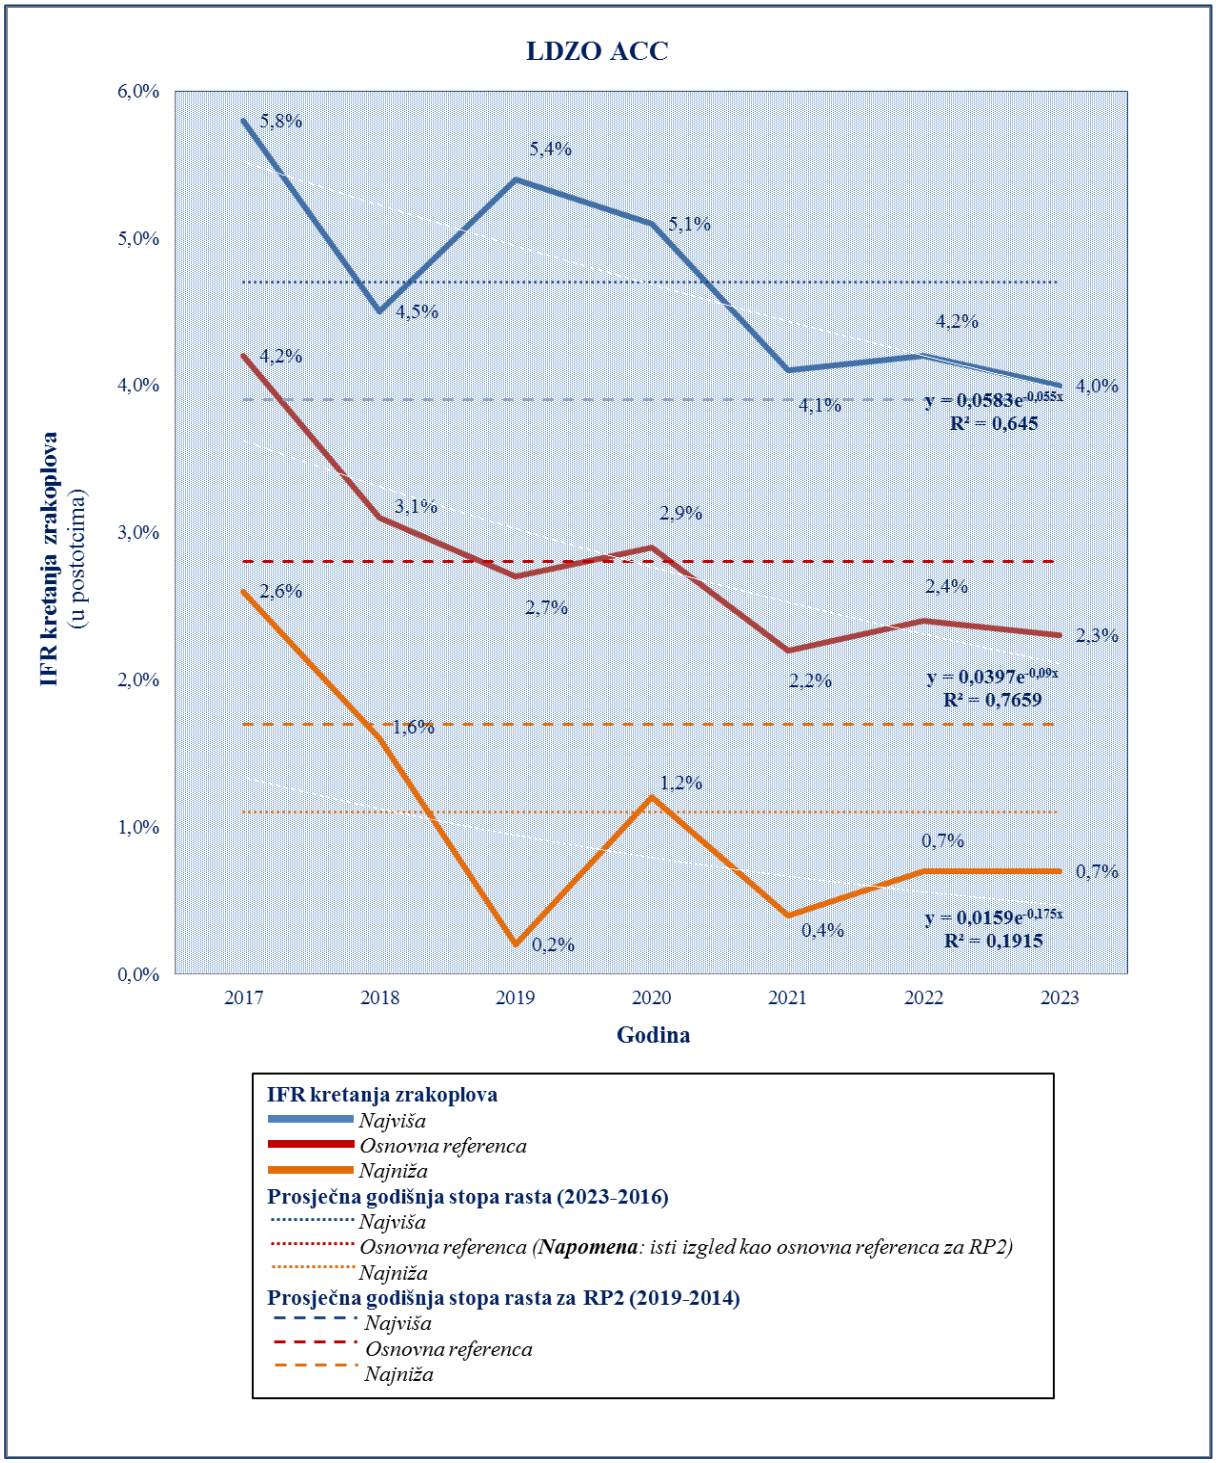


Grafikon 14: *Trenutno stanje IFR kretanja zrakoplova u vremenskom razdoblju od 2006. godine do 2017. godine na području Republike Hrvatske (do srpnja) [41] (izradio autor).*

Najveći porast IFR kretanja zrakoplova zabilježen je 2007. godine, ako se usporedi s 2006. godinom te iznosi 17 %. Tekuća 2017. godina trenutno ne može pružiti završni pregled ostvarenog broja IFR kretanja zrakoplova, ali može indicirati daljnji razvoj prometa u odnosu na isto razdoblje prethodnih godina. Prethodne 2016. godine zabilježen je porast IFR kretanja zrakoplova od 0,55 % u odnosu na 2015. godinu. U vremenskom razdoblju od 2012. do 2013. godine bilježi se pad IFR kretanja zrakoplova s prosječnom stopom rasta od 0,25 % odnosno 0,41 %, ovisno kako se uzima.

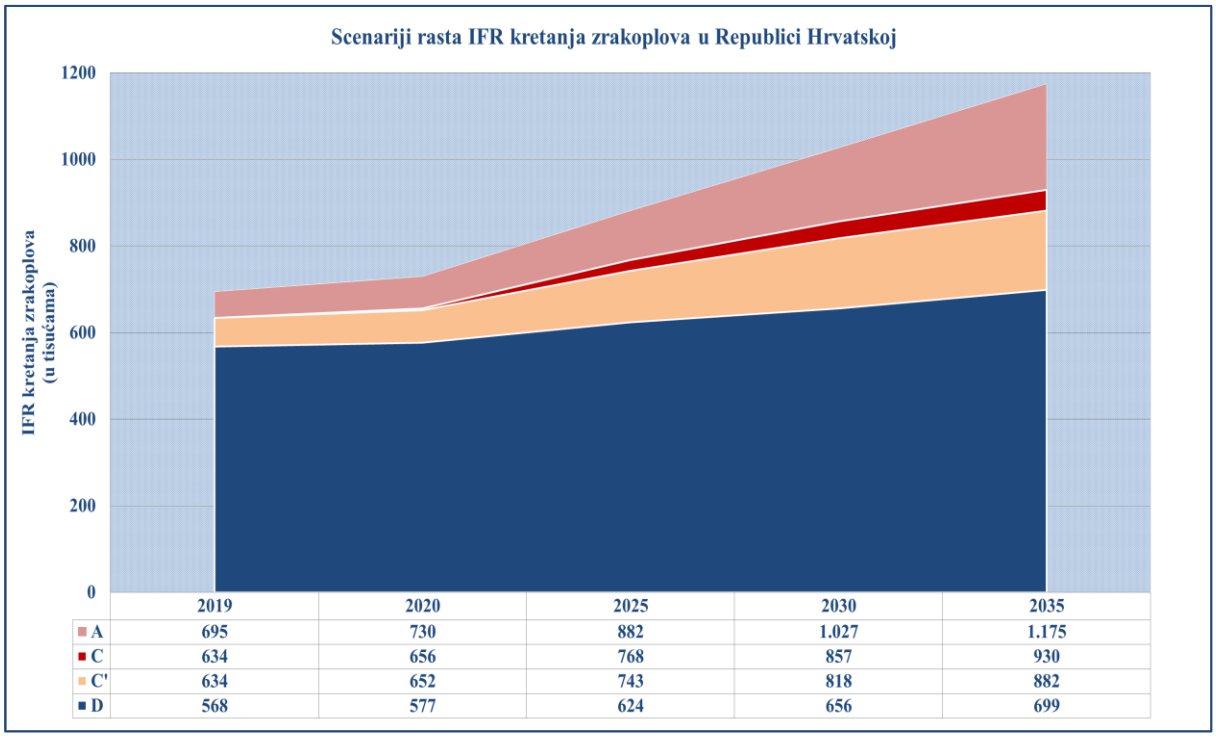
Na grafikonu 15 odabrana je eksponencijalna trend krivulja koja iskazuje postotnu vrijednost IFR kretanja zrakoplova u grafičkom obliku i pomoću numeričke jednadžbe koja objašnjava razvoj tih vrijednosti u narednih sedam godina, kao njihova R-kvadratna vrijednost. Uporabom linijskog grafikona prikazani su trendovi vrijednosti u odnosu na vrijeme tj. vremensko razdoblje u narednih sedam godina i drugo referentno razdoblje (RP2).

Kako bi se dobio jasan vizualni osjećaj rasta ili pada vrijednosti na području Republike Hrvatske, vrijednosti su iskazane pomoću tri scenarija rasta (najviša, osnovna referenca i najniža) u odnosu na prosječne vrijednosti u srednjoročnom i RP2 razdoblju. U ovom slučaju, očekuje se umjerena stopa pada IFR kretanja zrakoplova na području odgovornosti LDZO ACC. Prikazane vrijednosti nalaze se u tablici 14.



Grafikon 15: *Sedmogodišnja prognoza IFR kretanja zrakoplova u području odgovornosti LDZO ACC (Hrvatska) iskazana eksponencijalnom trend krivuljom i linijskim grafikonom (izradio autor).*

Na temelju niza scenarija koji promatraju vremensko razdoblje od dvadeset godina mogu približno odrediti budući razvoj zračnog prometa na području Republike Hrvatske. Dugoročna prognoza koristi četiri scenarija rasta gdje svaki scenarij odražava trend rasta. Iz priloženog grafikona 16 može se vidjeti najveći rast IFR kretanja zrakoplova prema scenariju A koji iznosi 1.175 IFR kretanja zrakoplova što je 480 više u odnosu za isti scenarij u 2019. godini. Ako promatramo najveće vrijednosti za scenarij A i scenarij D, razlika iznosi 476 letova.



	2019	2020	2025	2030	2035
A	695	730	882	1.027	1.175
C	634	656	768	857	930
C'	634	652	743	818	882
D	568	577	624	656	699

Grafikon 16: *Scenariji rasta IFR kretanja zrakoplova prema dugoročnoj prognozi na području Republike Hrvatske u sklopu ESRA08 [36] (izradio autor).*

4.4. Potražnja IFR kretanja zrakoplova

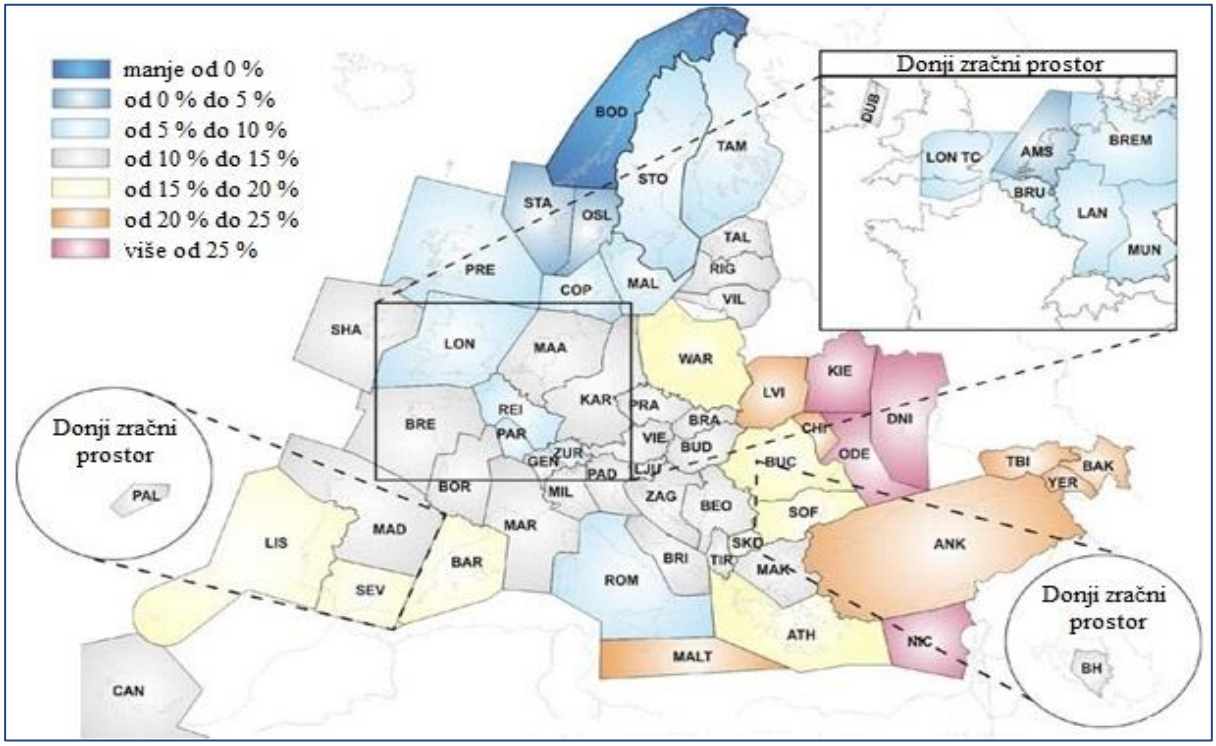
STATFOR izrađuje prognozu prometa na razini država (prometne zone), u ovom slučaju za Republiku Hrvatsku. Rast prometa po centrima oblasne kontrole zračnog prometa prolazi kroz proces planiranja kapaciteta kojeg provodi Mrežni upravitelj na temelju prometnih tokova između parova zona. U svrhu izrade prognoza prometa i traženog kapaciteta na razini ACC-a, vrijednosti se diseminiraju od strane pružatelja usluge u zračnoj plovidbi. U sljedećoj tablici 25 priloženi su podaci očekivanog povećanja prometa za LDZO ACC u vremenskom razdoblju od 2017. do 2021. godine, komparirano s 2016. godinom.

Tablica 25: *Očekivana prometna potražnja u % za LDZO ACC do 2021. godine, komparirano s 2016. godinom*

Država	ACC/APP	Stopa rasta	2017	2018	2019	2020	2021
Hrvatska	Zagreb LDZO ACC	Najviša	3,2%	7,2%	12,9%	19,0%	23,5%
		Osnovna referenca	1,9%	4,4%	7,4%	10,3%	12,8%
		Najniža	-0,2%	1,3%	1,2%	2,2%	2,4%
				Najkraće rute: Nemaju značajan utjecaj			

Izvor: *[31] (prilagodio autor).*

Najkraća ruta podrazumijeva dio Ukrajine, Libije, Iraka te zatvoreni sirijski zračni prostor ili zračni prostor koji nije u upotrebi od korisnika zračnog prostora [31]. LDZO ACC očekuje (slika 23) promjenu područja odgovornosti s oblasnom kontrolom zračnog prometa Bosne i Hercegovine (engl. *Bosnia and Herzegovina Air Traffic Control C*entre – BH ACC[66]) u vremenskom razdoblju od 2019. i 2020. godine, implementaciju prekograničnog područja (engl. *Cross Border Area* – CBA[67]) slobodnog odabira putanje leta zrakoplova te modernizaciju ATM sustava u vremenskom razdoblju od 2019. i 2020. godine [31].

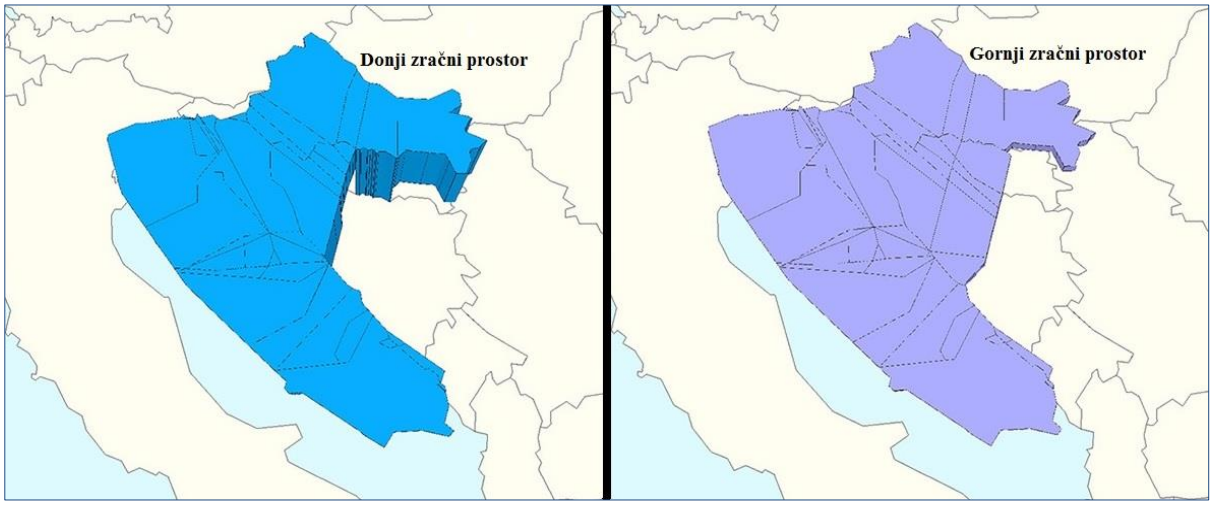


Slika 23: *Shematski prikaz stopa rasta po ACC-ima u vremenskom razdoblju od 2016. do 2021. godine. Osnovna referenca evolucije prometa na razini Europe iznosi 10,5 % [31] (prilagodio autor).*

[66]Novi centar oblasne kontrole zračnog prometa Bosne i Hercegovine započinje pružati ATS iznad FIR Sarajevo do razine leta (engl. *Flight Level* – FL) FL325, dok će ATS iznad FL325 nastavit pružati beogradski i zagrebački ACC [42].

[67]Predstavlja privremeno ograničeno ili rezervirano područje uspostavljeno iznad međunarodnih granica s ciljem zadovoljavanja specifičnih operativnih zahtijeva [3].

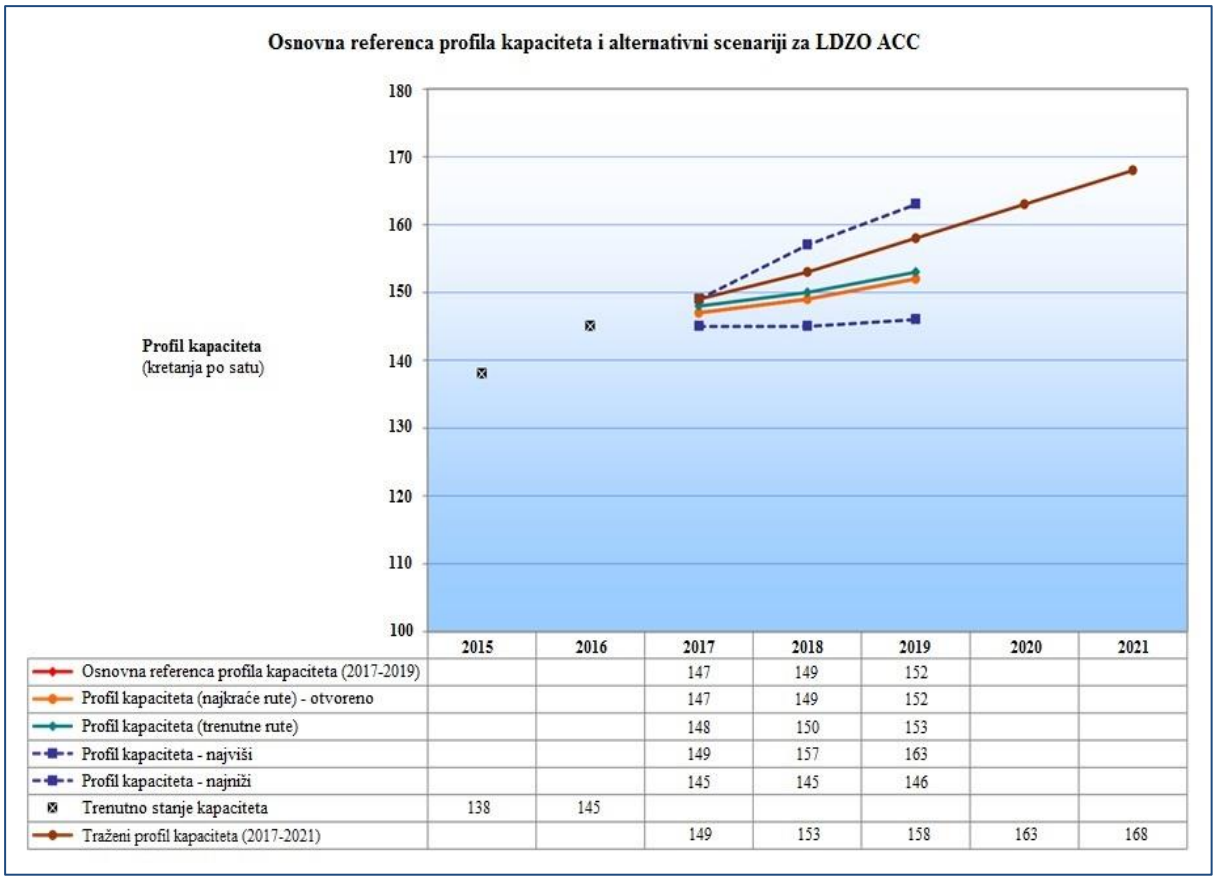
Na temelju shematskog prikaza 23 mogu se iščitati vrijednosti osnovne reference IFR kretanja zrakoplova na području odgovornosti (engl. *Area of Responsibility* – AoR) LDZO ACC (slika 24) u vremenskom razdoblju do 2021. godine, uspoređeno s 2016. godinom do kraja promatranog perioda. Očekuje se interval od 10 % do 15 % i koji indicira poduzimanje potrebnih akcija modernizacije sustava kontrole zračnog prometa, a pogotovo licenciranja novih kontrolora zračnog prometa koji određuju budući kapacitet zračnog prostora te o njihovom operativnom broju ovisi planiranje budućeg kapaciteta. Prikazane su visoke stope rasta na području Jugoistočne regije u kojoj se očekuje najveći porast IFR kretanja zrakoplova uzrokovano rerutiranjem glavnih prometnih tokova iznad tih prometnih zona.



Slika 24: *Područje odgovornosti LDZO ACC za donji i gornji zračni prostor [43] (prilagodio autor).*

4.5. Traženi profil kapaciteta za LDZO ACC

Poboljšanje profila kapaciteta oblasne kontrole zračnog prometa (grafikon 17) kontinuirano se planira i ne smije sadržavati praznine unutar kapaciteta tijekom planiranog razdoblja. Ograničenja kapaciteta mogu doseći visoke stope rasta i/ili značajne promjene u distribuciji prometa za ACC Zagreb tijekom implementacije slobodnog odabira putanje leta zrakoplova (engl. *Free Route Airspace* – FRA) u europskom zračnom prostoru [31].

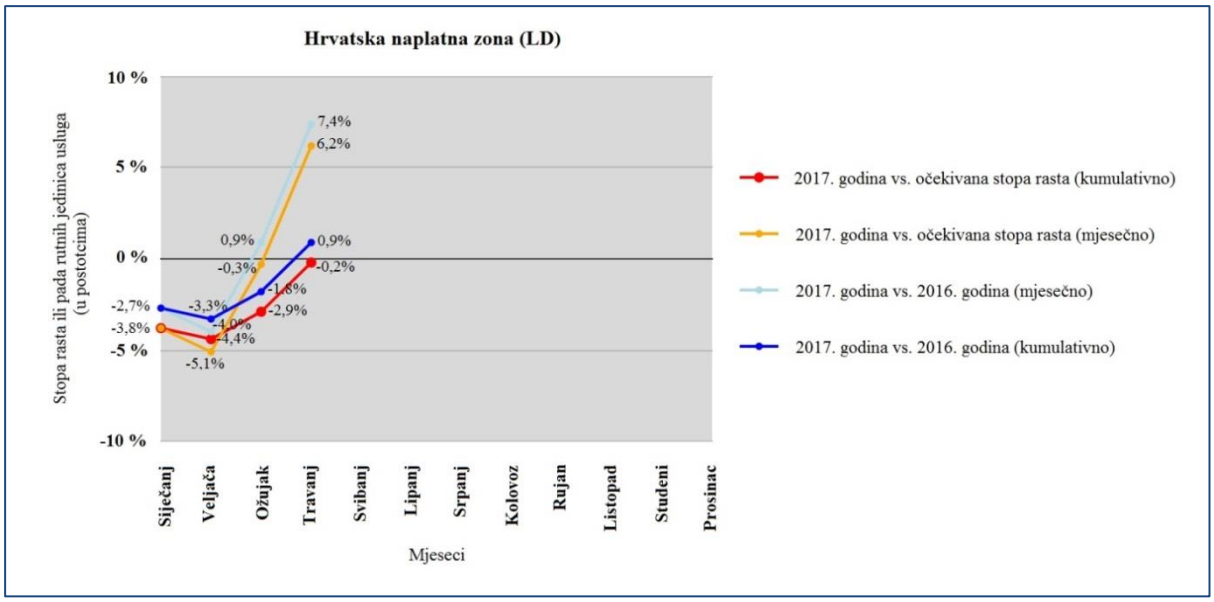


	2015	2016	2017	2018	2019	2020	2021
Osnovna referenca profila kapaciteta (2017-2019)			147	149	152		
Profil kapaciteta (najkraće rute) - otvoreno			147	149	152		
Profil kapaciteta (trenutne rute)			148	150	153		
Profil kapaciteta - najviši			149	157	163		
Profil kapaciteta - najniži			145	145	146		
Trenutno stanje kapaciteta	138	145					
Traženi profil kapaciteta (2017-2021)			149	153	158	163	168

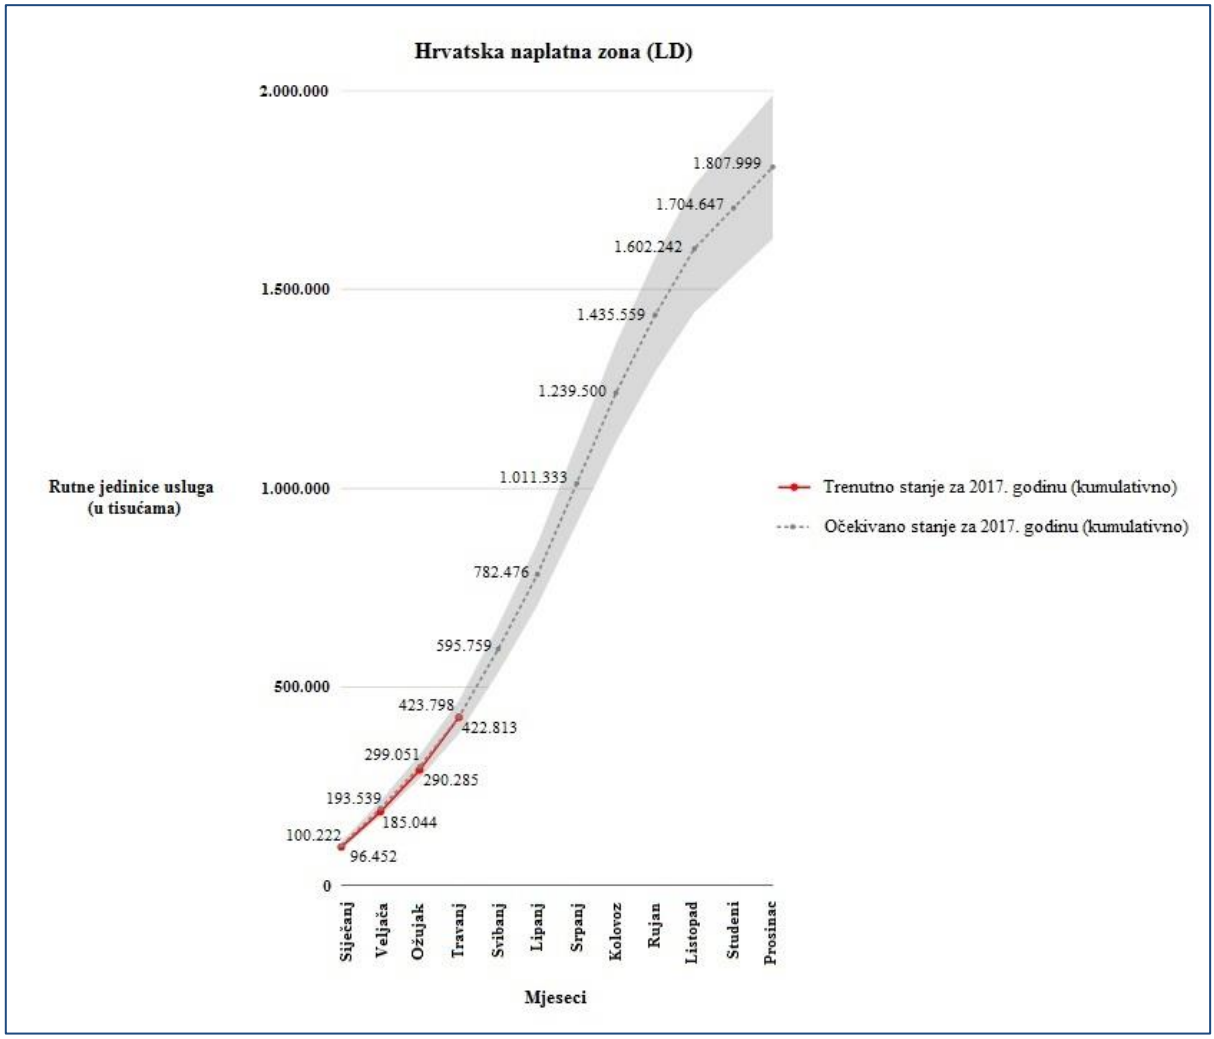
Grafikon 17: *Profil kapaciteta i alternativni scenarij LDZO ACC (osnovna referenca) [31] (prilagodio autor).*

4.6. Analiza rutnih jedinica usluge

Svaka naplatna zona u sklopu EUROCONTROL-a zahtijeva vrijednosti koje su dostupne CRCO14 za obračun TSU-a. Iz grafikona 18 i 19 može se iščitati trenutno stanje TSU-a zabilježeno po mjesecima rutne naplate u 2017. godini (do svibnja). Prognoza TSU-a po mjesecima uzima u izračun jediničnu naknadu za 2017. godinu. Iskaz vrijednosti jedinične naknade (engl. *unit rates*) za Republiku Hrvatsku priložen je na slici 8.



Grafikon 18: *STATFOR prognoza TSU-a prema prvoj reviziji vrijednosti iz ožujka 2017. godine za naplatnu zonu Republike Hrvatske, usporedba s trenutnim stanjem iz 2016. godine [35] (prilagodio autor).*



Grafikon 19: *Ukupan broj TSU-a za Hrvatsku naplatnu zonu (LD) za trenutno stanje i očekivano stanje prema osnovnoj referenci u 2017. godini po mjesecima [35] (prilagodio autor).*

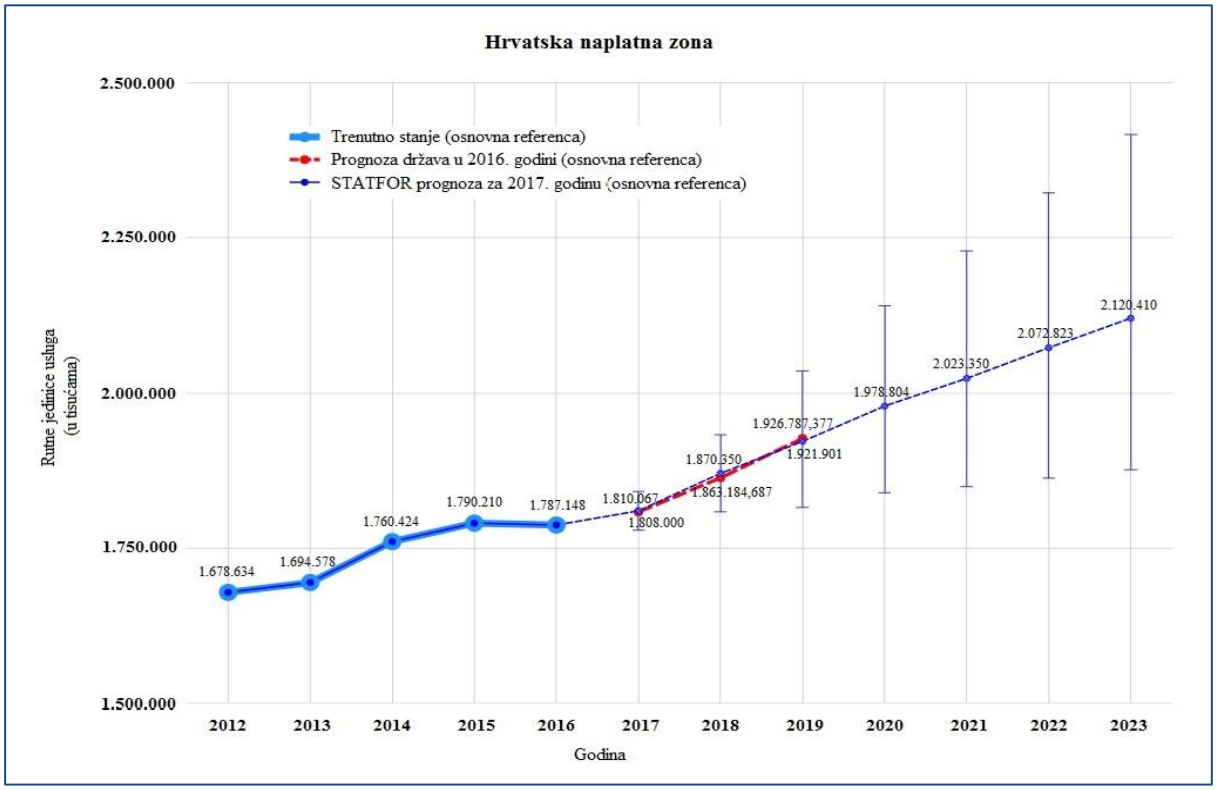
Na kraju svakog mjeseca naplate, CRCO ažurira mjesečne podatke TSU-a prema mjesečnim letovima tekuće godine kako bi izračunao dodatnu naplatu letova te ih odobrio. Ukupno TSU-a po mjesecima dobije se kao zbroj naplativih i izuzetih jedinica usluge [44].

STATFOR u cilju kvalitetnog razumijevanja prometnih trendova preuzima vodeću ulogu i objavljuje kratkoročnu prognozu TSU-a za naplatno područje LDZO ACC (tablica 26 i grafikon 20). Kao što je navedeno na slici 8, jedinična naknada TSU-a na području Republike Hrvatske iznosi 46,30 € te očekuje rast TSU-a u 2017. i 2018. godini, ali s nešto manjom stopom rasta u odnosu na CRCO14 i RP2.

Tablica 26: *Kratkoročna prognoza TSU-a za naplatno područje Republike Hrvatske do 2018. godine*

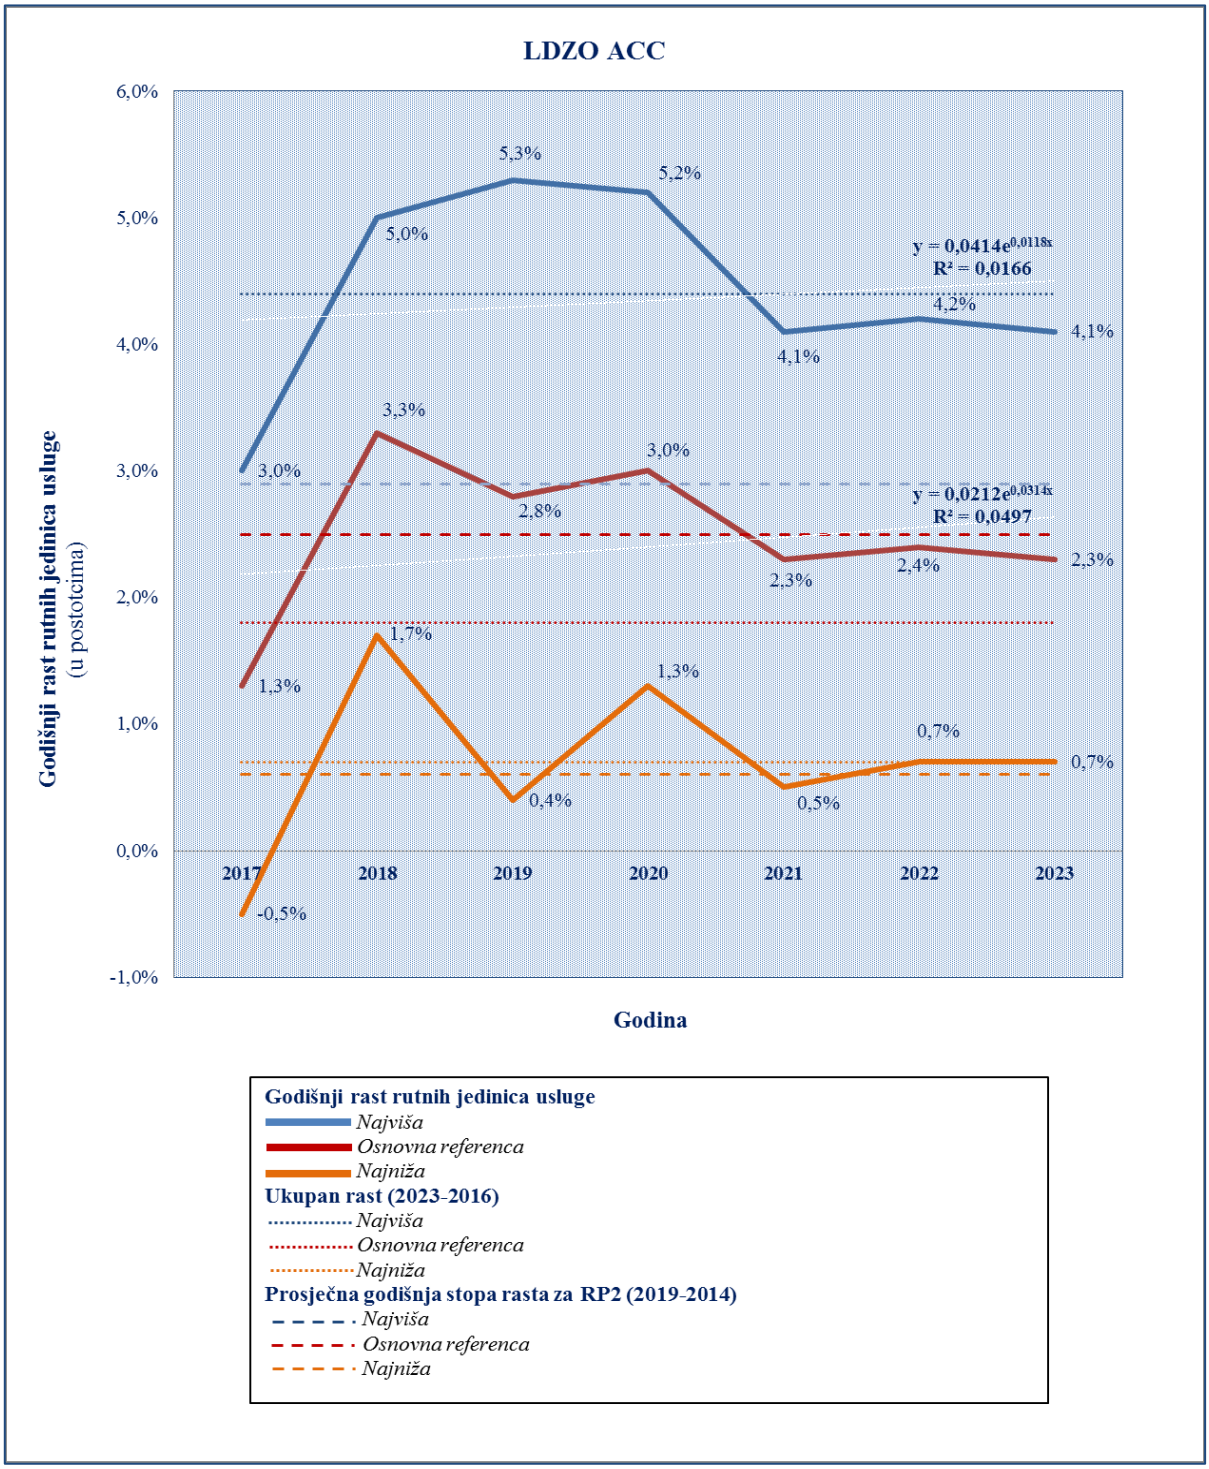
ICAO kod	Naplatno područje	STATFOR					Država	STATFOR vs. Država
		Trenutno stanje TSU-a [€]	Prognoza TSU-a	Odstupanje	Prognoza TSU-a	Odstupanje	Prognoza TSU-a	
	Država	2016	2017	2017 vs. 2016	2018	2018 vs. 2017	2017	2017
LD	Hrvatska	1.787.148	1.810.067	1,3%	1.870.350	3,3%	1.808.000	0,1%
Europa	CRCO14	143.416.625	149.407.955	4,2%	153.431.301	2,7%	140.851.532	6,1%
	RP1 Regija	118.403.924	123.193.584	4,0%	126.203.623	2,4%	115.686.197	6,5%
	RP2 Regija	120.191.072	125.003.651	4,0%	128.073.972	2,5%	117.494.197	6,4%
	UKUPNO	145.267.795	151.383.677	4,2%	155.470.616	2,7%	141.678.649	6,9%

Izvor: *[8] (prilagodio autor).*



Grafikon 20: *Srednjoročna STATFOR prognoza TSU-a prema prvoj reviziji vrijednosti u ožujku 2017. godine u naplatnoj zoni Republike Hrvatske za osnovnu referencu, najvišu i najnižu stopu rasta [45] (prilagodio autor).*

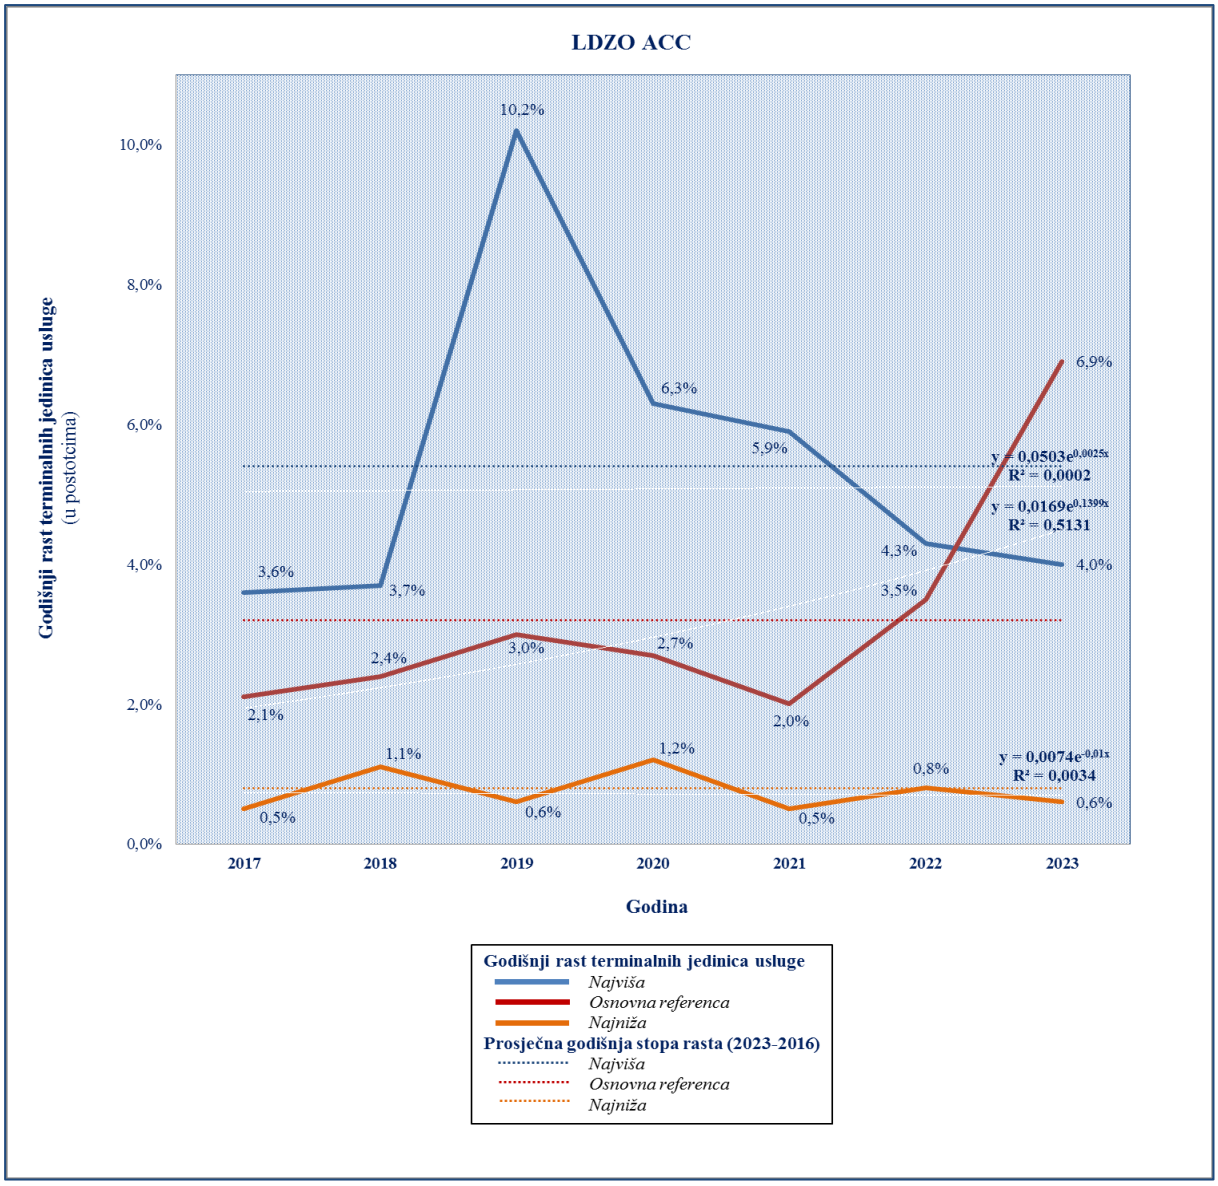
Na temelju prethodnog grafikona 20, vrijednosti su iskazane u postotnom obliku na grafikonu 21 pomoću tri scenarija rasta (najviša, osnovna referenca i najniža) koji odstupaju u odnosu na ukupan rast TSU-a u srednjoročnom razdoblju i prosječnu godišnju stopu rasta za RP2 u području odgovornosti LDZO ACC. Prema navedenom grafikonu, očekuju se varijacije u vrijednostima u odnosu na ukupan rast i prosječnu godišnju stopu rasta za RP2.



Grafikon 21: *Sedmogodišnja prognoza rutnih jedinica usluge u području odgovornosti LDZO ACC (Hrvatska) iskazano eksponencijalnom trend krivuljom i linijskim grafikonom [8] (izradio autor).*

4.7. Analiza terminalnih jedinica usluge

ICAO uvrštava Republiku Hrvatsku u ESRA Istok prometnu regiju s ICAO kodom[68] „LD“. Naplatna zona Republike Hrvatske je LD_TCZ koja se segmentira na LDZA[69] i LDZL[70]. Na temelju grafikona 22 mogu se iščitati prosječne godišnje stope rasta u srednjoročnom razdoblju za LDZO ACC. Iz priloženog se mogu vidjeti stalne varijacije u vrijednostima u odnosu na prosječnu godišnju stopu rasta.



Grafikon 22: *Sedmogodišnja prognoza terminalnih jedinica usluge u Hrvatskoj naplatnoj zoni (LD) iskazano eksponencijalnom trend krivuljom i linijskim grafikonom [8] (izradio autor).*

[68]Podrazumijeva alfanumerički kod koji olakšava razumijevanje podataka na temelju početnih slogova, u ovom slučaju je analogija za ICAO državu (prometnu zonu) odnosno Republiku Hrvatsku.
[69]Podrazumijeva ICAO kod za zračnu luku Zagreb (Puni naziv je „Međunarodna zračna luka Franjo Tuđman“).
[70]Podrazumijeva ICAO kod za aerodrom Zagreb/Lučko.

5. ZAKLJUČAK

Prilikom odabira adekvatne prognostičke metode mora se utvrditi njezina primarna namjena. Odabirom kvantitativnih metoda prognoziranja mogu se odrediti približne vrijednosti budućih trendova. Metode se oslanjaju prema raspoloživim statističkim podacima koji omogućavaju izradu završnih prognoza prometa i njihovih trend krivulja. Budući da ne postoji najbolji način prognoziranja, pokušava se različitim metodologijama približiti očekivanim vrijednostima što preciznije. Najviše se pridodaje pažnja metodama vremenskih nizova koje u kontekstu upravljanja zračnim prometom najopsežnije odražavaju kvantitativnu točnost prognoza. Potrebno je naglasiti da prognostička točnost u prethodnim razdobljima nije garancija ostvarivanja istih vrijednosti u narednom periodu.

Tijekom razmatranja vremenskog razdoblja prognoze, potrebno je odabrati adekvatni niz ulaznih podataka i raščlaniti njihovu razinu detalja jer svako prognostičko razdoblje vrednuje različite ulazne podatke. Prognoza mora sagledavati razinu glavnih prometnih tokova koji se kontinuirano prate i analiziraju. U razmatranje se treba uzeti niz scenarija i potencijalni rizici koji mogu utjecati na budući razvoj zračnog prometa. Iako postoji cijeli niz čimbenika koji utječu na izradu završne prognoze zračnog prometa, najveći utjecaj na veličinu prometne potražnje imaju: gospodarski rast, kapacitet zračnih luka, faktori popunjenosti, događanja i trendovi, red letenja zračnih prijevoznika, razvoj niskotarifnih zračnih prijevoznika, demografija i sklonost prema letenju te razvoj željeznica velikih brzina. Takvi ulazni podaci sagledavaju sveobuhvatno industriju zračnog prometa i osiguravaju najnovije vrijednosti o prometnoj situaciji kako bi se omogućila vjerodostojnost izlaznih veličina, o kojima ovisi budući razvoj zračnog prometa. Ako promatramo projekciju dugoročnog razdoblja, nužno je sagledavati četiri scenarija koji uzimaju u obzir širok niz ulaznih pretpostavki. Svaki scenarij odražava zasebnu projekciju, što upućuje na odstupanje pojedinačnog scenarija u odnosu na druge. Međusobno podudaranje omogućava bolju predodžbu budućih ATM prometnih pokazatelja. Scenariji preferiraju letove dugog doleta na glavnim prometnim tokovima opslužene „velikim ili vrlo velikim“ zrakoplovima između glavnih *hub-ova* u odnosu na letove kratkog doleta.

Zrakoplovna industrija mora pružiti odgovor na ograničenja kapaciteta na način da zračni prijevoznici povećavaju broj zrakoplova s kojim opslužuju ATS mrežu ruta, zračne

luke da proširuju ili povećavaju infrastrukturu, a vladine organizacije da ulažu u alternativne načine eksploatacije zračnog prometa. Isto tako, trebaju zahtijevati od zračnih luka isporuku planova kapaciteta koji će poslužiti kao pouzdani ulazni podaci tijekom izrada završnih prognoza zračnog prometa u svrhu prevencije nadilaženja deklariranog kapaciteta zbog robusnog IFR GAT prometa na dotičnim zračnim lukama. Politička nesigurnost unutar i izvan Europe, Brexit i nekoliko predsjedničkih izbora u 2017. godini potencijalno mogu utjecati na budući gospodarski razvoj država koji korelira s putničkom potražnjom koja posljedično smanjuje faktor popunjenosti zračnim prijevoznicima. Isto tako, željeznice velikih brzina kao glavni konkurent zračnom prijevozu na udaljenostima od 400 do 800 kilometara, a poglavito na udaljenostima od 150 do 400 kilometara pružaju bolju dostupnost i povezanost između parova gradova, što za posljedicu ima smanjenje vremena putovanja u odnosu na zračni promet. Nadalje, strah od posljedica terorističkih djelovanja značajno utječe na ATS mrežu ruta koja mora omogućiti fleksibilnost i brz odgovor rerutiranjem prometnih tokova tijekom izvanrednih situacija. Povrh toga, utječe i na turističke trendove koji se mijenjaju iz godine u godinu.

STATFOR prognoza kao jedina prognoza ATM prometnih pokazatelja na području Europe mora sveobuhvatno sagledavati niz čimbenika koji su u doticaju s industrijom zračnog prometa. Izradom završne prognoze prometa na razini Europe, prometnih zona ili regija omogućava se pravovremeno poduzimanje adekvatnih mjera implementacije i modernizacije sustava pružatelja usluga u zračnoj plovidbi. CRCO14 kao glavni izvor obračuna naplate na području Europe mora pravično i transparentno obračunavati naplatu rutnih i terminalnih jedinica usluge svim zračnim prijevoznicima.

Na području ECAC-a bilježi se porast ATM prometnih pokazatelja, ali nedostatno u odnosu na najprometnije ICAO prometne regije (Azija-Pacifik, Sjeverna Afrika, Srednji i Bliski Istok i Ostatak Europe). Sjeverozapadna regija bilježi porast IFR kretanja zrakoplova zbog intenzivnog rasta niskotarifnih zračnih prijevoznika. Potrebno je sagledavati prometne tokove između parova zona, a posebno u državama koje generiraju veću stopu rasta poput Francuske, Italije, Njemačke i Ujedinjene Kraljevine. Također, treba naglasiti nagli rast IFR kretanja zrakoplova na području Jugoistočne regije koja indicira rast prometa uslijed rerutiranja glavnih prometnih tokova iznad svojeg područja, a posebno iznad Turske koja se nalazi na rutnom području između ponovno otvorenih zračnih prostora Ukrajine i Egipta.

Pružatelji usluga u zračnoj plovidbi opslužuju više od 33.000 letova dnevno na području Europe, što upućuje na visoku koncentraciju prometa. Ako usporedimo 2023. godinu s 2016. godinom, razdoblje srednjoročne prognoze, rast bi iznosio oko 14 % više letova. Povrh toga, korisnici zračnog prostora moraju dati siguran, brz i efikasan odgovor na takvu situacije jer njihova suradnja utječe na cjelokupan proces zračnog prometa. Porastom obujma zračnog prometa dolazi do povećanja troškova za pružatelje usluge u zračnoj plovidbi, što uvjetuje usklađivanje troškova s trenutnim stanjem zračnog prometa. Prema tome, jedinična cijena naplate koja ovisi o jediničnoj naplati u pojedinom volumenu zračnog prostora varira u državama članicama CRCO14 i RP2 regije te je potrebno usklađivati jedinične cijene naplate za pružene usluge zračnog prometa. Nadalje, rutne jedinice usluga u naplatnom području očekuju umjerenu godišnju stopu rasta od 2,5 %, što je ukupan rast od 19 % do kraja srednjoročnog razdoblja, u odnosu na rujan 2016. godine. Isto tako, očekuju se porast terminalnih jedinica usluge u terminalnim naplatnim zonama koje su predmetom Programa mjerenja učinkovitosti u RP2 regiji do 2023. godine i iznosi 2,4 %, što je oko 9,3 milijuna terminalnih jedinica usluge.

U Republici Hrvatskoj, CROCONTROL kao jedini pružatelj usluga u zračnoj plovidbi odgovoran je podnositi podatke prema EUROCONTROL-u u svrhu izrada prometnih statistika, prognoza i analiza na području odgovornosti LDZO ACC i donjeg zračnog prostora Bosne i Hercegovine. Prognostički podaci prikazani na grafikonima ukazuju na pozitivan rast svih ATM prometnih pokazatelja. Potrebno je naglasiti da Republika Hrvatska ima prostor za daljnji rast ATM prometnih pokazatelja jer ESRA Istok prometna regija u kojoj se Hrvatska nalazi generira najveći porast zračnog prometa u odnosu na ostale europske prometne regije, prema posljednjoj objavljenoj prognozi prometa.

LITERATURA

[1] Narodne Novine, 2014. *Zakon o zračnom prometu,* pročišćeni tekst, 2014, Zagreb, Hrvatska

[2] EUROCONTROL, 2005. *Glossary for Flight Statistics & Forecasts,* Issue: v1.0, January 2005, Brussels, Belgium

[3] Mihetec, T.: *Upravljanje zračnom plovidbom*, Fakultet prometnih znanosti, Zagreb, 2014.

[4] ICAO, 2006. *Manual of Air Traffic Forecasting, Doc 8991,* 3rd Edition – 2006, Montreal, Canada

[5] Klaić, B.: *Rječnik stranih riječi, Tuđice i posuđenice,* Tisak: Grafički zavod Hrvatske, Zagreb, 1987.

[6] Dantas, M. T., Oliveira, F. L. C., Repolho, H. M. V.: 2016. *Air transportation demand forecast through Bagging Holt Winters methods*, Journal of Air Transport Management 59 (2017) 116 – 123, ISBN: 0969-6997, Department of Industrial Engineering, PUC-RIO, 2017, Rio de Janeiro, Brazil, p. 118

[7] EUROCONTROL, http://www.eurocontrol.int/statfor (6. svibnja 2017.)

[8] EUROCONTROL, 2017. *Seven-Year Forecast: Flight Movements and Service Units 2017-2023*, February 2017, Brussels, Belgium

[9] Network Manager, 2014. *Network Strategy Plan 2015-2019, Approved through Commission Decision C (2014) 4660,* July 2014, Brussels, Belgium

[10] EUROCONTROL, http://www.eurocontrol.int/services/network-operations-portal (10. svibnja 2017.)

[11] Network Manager, 2016. *Network Performance Plan 2015-2019, Approved by Commission Implementing Decision (EU) 2016/1373,* August 2016, Brussels, Belgium

[12] EUROCONTROL, http://www.eurocontrol.int/forecast-monitoring-analysis (25. travnja 2017.)

[13] EUROCONTROL, *ATM Lexicon, SESAR Joint Undertaking,* https://ext.eurocontrol.int/lexicon/index.php/Network_Management_Function (11. svibnja 2017.)

[14] EUROCONTROL, *Route Charges,* http://www.eurocontrol.int/crco (10. lipnja 2017.)

[15] EUROCONTROL, *ATM Lexicon,* https://ext.eurocontrol.int/lexicon/index.php/Nautical_mile (19. lipnja 2016.)

[16] European Organisation for the Safety of Air Navigation, 2016. *Central Route Charge Office (CRCO), Report on the Operation of the Route Charges System in 2016*, March 2017, Brussels, Belgium

[17] EUROCONTROL, *ATM Lexicon*, https://ext.eurocontrol.int/lexicon/index.php/Instrument_Flight_Rules (11. svibnja 2017.)

[18] EUROCONTROL, *ATM Lexicon*, https://ext.eurocontrol.int/lexicon/index.php/Visual_Flight_Rules (11. svibnja 2017.)

[19] EUROCONTROL, http://www.eurocontrol.int/articles/statistics (8. svibnja 2017.)

[20] EUROCONTROL, http://www.eurocontrol.int/articles/forecasts (4. svibnja 2017.)

[21] Tatalović, M., Mišetić, I., Bajić, J.: *Menadžment zrakoplovne kompanije*, MATE d.o.o., Zagreb, 2012.

[22] Network Manager, 2017. *Industry Monitor, The EUROCONTROL bulletin on air transport trends*, Issue N°193, April 2017, Brussels, Belgium

[23] Investopedia, http://www.investopedia.com/terms/b/brexit.asp (12.svibnja 2017.)

[24] Cambridge Dictionary, http://dictionary.cambridge.org/dictionary/english/no-fly-zone (12. svibnja 2017.)

[25] EUROCONTROL, *En Route Service Units Forecasts, 13 March 2017*, http://www.eurocontrol.int/publications/en-route-service-units-forecasts (10. lipnja 2017.)

[26] EUROCONTROL, http://www.eurocontrol.int/sites/default/files/content/documents/route-charges/unit-rates-and-tariffs/global-unit-rates-2017.pdf (11. lipnja 2017.)

[27] Network Manager, 2017. *EUROCONTROL Intermediate two-year Forecast, Service Units 2017-2018*, May 2017, Brussels, Belgium

[28] EUROCONTROL, *ATM Lexicon*, https://ext.eurocontrol.int/lexicon/index.php/Operational_Air_Traffic (23. svibnja 2017.)

[29] EUROCONTROL, *ATM Lexicon*, https://ext.eurocontrol.int/lexicon/index.php/Free_Route_Airspace (10. lipnja 2017.)

[30] EUROCONTROL, *ATM Lexicon*, https://ext.eurocontrol.int/lexicon/index.php/Composite_flight_hour (11. lipnja 2017.)

[31] Network Manager, 2017. *European Network Operations Plan 2017-2019/21, Approved by the Network Management Board on 28 April 2017*, Edition April 2017, April 2017, Brussels, Belgium

[32] AEA, http://www.aea.be/about-us/aea%E2%80%99s-role.html (7. lipnja 2017.)

[33] Decision (EU) No 2007/339/EC on the Air Transport Agreement between the EU and its Member States and the United States of America, 2007, Brussels, Belgium

[34] SKYBRARY, 2015. *Jet Stream*, http://www.skybrary.aero/index.php/Jet_Stream (4. lipnja 2017.)

[35] EUROCONTROL, *En-route Service Units Dashboard, Main Dashboard 2017 vs. 2016,* http://www.eurocontrol.int/ServiceUnits/Dashboard/Selection2017vs2016.html (10. lipnja 2017.)

[36] Network Manager, 2013. *Challenges of Growth 2013, Task4: European Air Traffic in 2035,* Brussels, Belgium

[37] EUROCONTROL, *ATM Lexicon,* https://ext.eurocontrol.int/lexicon/index.php/Hub_and_spoke_system (18. lipnja 2017.)

[38] EUROCONTROL, *ATM Lexicon,* https://ext.eurocontrol.int/lexicon/index.php/Slot (18. lipnja 2017.)

[39] EUROCONTROL, *ATM Lexicon,* https://ext.eurocontrol.int/lexicon/index.php/Upper_Flight_Information_Region (29. svibnja 2017.)

[40] Hrvatska kontrola zračne plovidbe, http://www.crocontrol.hr/mobile/default.aspx?id=11 (5. svibnja 2017.)

[41] Hrvatska kontrola zračne plovidbe, *Pregled IFR prometa po godinama – korigirana verzija,* http://www.crocontrol.hr/mobile/default.aspx?id=321 (22. kolovoza 2017.)

[42] EUROCONTROL, http://www.eurocontrol.int/press-releases/new-actor-european-network-%E2%80%93-bh-acc-0 (18. lipnja 2017.)

[43] Hrvatska kontrola zračne plovidbe, http://www.crocontrol.hr/UserDocsImages/SUZP/ACC_Zagreb_AoR.jpg (5. svibnja 2017.)

[44] EUROCONTROL, *En-route Service Units Monitoring,* http://www.eurocontrol.int/publications/en-route-service-units-monitoring (8. lipnja 2017.)

[45] EUROCONTROL, *En-route Service Units Dashboard, STATFOR and States' Forecasts,* http://www.eurocontrol.int/ServiceUnits/Dashboard/Forecasts.html (10. lipnja 2017.)

POPIS KRATICA

AAGR – prosječna godišnja stopa rasta (engl. *Average Annual Growth Rate* – AAGR)

ACC – oblasna kontrola zračnog prometa (engl. *Area Control Service* – ACC)

AD – aerodrom (engl. *Aerodrome* – AD)

A/D – dolazak (engl. *Arrival* – A) / odlazak (engl. *Departure* – D)

AEA – Europsko udruženje zračnih prijevoznika (engl. *Association of European Airlines* – AEA)

ANSP – pružatelji usluga u zračnoj plovidbi (engl. *Air Navigation Service Provider* – ANSP)

AO – operator zrakoplova (engl. *Aircraft Operator* – AO)

AoR – područje odgovornosti (engl. *Area of Responsibility* – AoR)

APP – prilazna kontrola zračnog prometa (engl. *Approach Control Service* – APP)

ARIMA – auto regresivni model koji integrira pomični prosjek (engl. *Auto Regressive Integrated Moving Average* – ARIMA)

ARN – ATS mreža ruta (engl. *ATS Route Network* – ARN)

ASM – upravljanje zračnim prostorom (engl. *Airspace Management* – ASM)

ATC – kontrola zračnog prometa (engl. *Air Traffic Control Services* – ATC)

ATFM – upravljanje protokom zračnog prometa (engl. *Air Traffic Flow Management* – ATFM)

ATM – upravljanje zračnim prometom (engl. *Air Traffic Management* – ATM)

ATS – usluge u zračnoj plovidbi (engl. *Air Traffic Services* – ATS)

AU – korisnici zračnog prostora (engl. *Airspace Users* – AU)

B – osnovna referenca (engl. *Baseline Scenario* – B)

BDP – bruto domaći proizvod (engl. *Gross Domestic Product* – GDP)

BH ACC – oblasna kontrola zračnog prometa Bosne i Hercegovine (engl. *Bosnia and Herzegovina Air Traffic Control C*entre – BH ACC)

CBA – prekogranično područje (engl. *Cross Border Area* – CBA)

CCL – Hrvatska kontrola zračne plovidbe (engl. *Croatian Control Ltd.* – CCL)

CODA – Centralni ured za analizu kašnjenja (engl. *Central Office for Delay Analysis* – CODA)

CRCO14 – Centralni ured za naplatu rutnih naknada (engl. *Central Route Charge Office* – CRCO (2014))

CTA – kontrolirani zračni prostor (engl. *Control Area* – CTA)

CTOT – slot odlaska (engl. *Calculated Take-Off Time* – CTOT)

Doc 8991 – Priručnik za prognoziranje zračnog prometa (engl. *Manual of Air Traffic Forecasting* – Doc 8991)

EASA – Europska agencija za sigurnost zračnog prometa (engl. *European Aviation Safety Agency* – EASA)

ECAC – Europska konferencija civilnog zrakoplovstva (engl. *European Civil Aviation Conference* – ECAC)

ENR – zračni prostor gdje se odvijaju preleti/krstarenja (engl. *En-route* – ENR)

ESRA08 – EUROCONTROL-ovo statističko referentno područje (engl. *EUROCONTROL Statistical Reference Area* – ESRA (2008))

ETS – trgovanje emisijom štetnih plinova (engl. *Emission Trading Scheme* – ETS)

EU-28 – Europska Unija (28 država) (engl. *European Union (28 States)* – EU-28)

EUROCONTROL – Europska organizacija za sigurnost zračne plovidbe (engl. *European Organization for the Safety of Air Navigation* – EUROCONTROL)

FIR – područje letnih informacija (engl. *Flight Information Region* – FIR)

FL – razina leta (engl. *Flight Level* – FL)

FRA – slobodni odabir putanje leta zrakoplova (engl. *Free Route Airspace* – FRA)

FSNC – tradicionalni zračni prijevoznici (engl. *Full Service Network Carrier* – FSNC)

GAT – opći zračni promet (engl. *General Air Traffic* – GAT)

H – najviša stopa rasta (engl. *High-Growth Scenario* – H)

HST – vlakovi velikih brzina (engl. *High-Speed Train* – HST)

I – domaći letovi (engl. *Internals* – I)

IFPS – integrirani sustav početne obrade plana leta (engl. *Integrated Initial Flight Plan Processing System* – IFPS)

ICAO – Međunarodna organizacija za civilno zrakoplovstvo (engl. *International Civil Aviation Organization* – ICAO)

IFR – pravila za let uz pomoć instrumenata (engl. *Instrument Flight Rules* – IFR)

KFOR – Kosovske snage (engl. *Kosovo Force* – KFOR)

KPA – ključna područja učinkovitosti (engl. *Key Performance Area* – KPA)

KPI – ključni indikatori učinkovitosti (engl. *Key Performance Indicator* – KPI)

L – najniža stopa rasta (engl. *Low-Growth Scenario* – L)

LAS – (engl. *London Approach Service* – LAS)

LCC – niskotarifni zračni prijevoznik (engl. *Low Cost Carrier* – LCC)

LTF – dugoročno prognoziranje (engl. *Long-Term Forecast* – LTF)

MTF – srednjoročno prognoziranje (engl. *Medium-Term Forecast* – MTF)

MTOW – maksimalna težina zrakoplova pri uzlijetanju (engl. *Maximum Take Off Weight* – MTOW)

NM – Mrežni upravitelj (engl. *Network Manager* – NM)

NM – nautička milja (engl. *Nautical Mile* – NM)

NMF IR – Provedbeno pravilo funkcije Mrežnog upravitelja (engl. *Network Manager Functions Implementing Rule* – NMF IR)

NMU – Jedinica za upravljanje mrežom (engl. *Network Management Unit* – NMU)

NOP – operativni plan europske ATM mreže (engl. *Network Operational Plan* – NOP)

NPP – mrežni izvedbeni plan (engl. *Network Performance Plan* – NPP)

NSP – mrežni strateški plan (engl. *Network Strategy Plan* – NSP)

O – preleti (engl. *Overflights* – O)

OAR – operativna analiza i izvještavanje (engl. *Operational Analysis and Reporting* – OAR)

OAT – operativni zračni promet (engl. *Operational Air Traffic* – OAT)

ODZ – prometni tokovi između parova zona (engl. *Origin-Destination Zones* – ODZ)

RP2 – drugo referentno razdoblje (2015-2019) u programu mjerenja učinkovitosti za SES (engl. *Second Period of Reference (2015-2019) for the Performance Scheme of the SES* – RP2)

RP2Region – države uključene u program mjerenja učinkovitosti za drugo referentno razdoblje (Europska Unija (28 država) plus Norveška i Švicarska) engl. *States involved in the Performance Scheme second period of reference (engl. European Union (28 States) plus Norway and Switzerland* – RP2Region)

SES – Jedinstveno europsko nebo (engl. *Single European Sky* – SES)

STATFOR – služba za statistiku i prognozu (engl. *Statistics and Forecast Service* – STATFOR)

SU – broj jedinica usluge (engl. *Service Units* – SU)

SUG – STATFOR-ova korisnička skupina (engl. *STATFOR User Group* – SUG)

TCZ – terminalna naplatna zona (engl. *Terminal Charging Zone* – TCZ)

TMA – završne kontrolirane oblasti (engl. *Terminal Control Area* – TMA)

TNSU – terminalne jedinice usluga (engl. *Terminal Navigation Service Units* – TNSU)

TR – prometna tona (engl. *Traffic Region* – TR)

TSU – ukupan broj rutnih jedinica usluga (engl. *Total En-Route Service Units*)

TWR – aerodromska kontrola zračnog prometa (engl. *Aerodrome Control Service* – TWR)

TZ – prometna zona (engl. *Traffic Zone* – TZ)

UIR – područje letnih informacija u gornjem zračnom prostoru (engl. *Upper Flight Information Region* – UIR)

VFR – pravila za let s vidljivošću (engl. *Visual Flight Rules* – VFR)

POPIS SLIKA

Slika 1: *Shematski prikaz tipičnih trend krivulja* 5

Slika 2: *Dijagram toka prilikom izrade ekonometrijskog modela* 9

Slika 3: *Shematski prikaz krivulje potražnje* 10

Slika 4: *Shematski prikaz CRCO naplatne zone* 16

Slika 5: *Shematski prikaz ECAC područja* 20

Slika 6: *Shematski prikaz prognoze IFR kretanja zrakoplova po državama za 2017. godinu (osnovna referenca, s rasponom od + ili - 1,5 %)* 22

Slika 7: *Shematski prikaz prognoze IFR kretanja zrakoplova po državama za 2018. godinu (osnovna referenca, s rasponom od + ili - 1,5 %)* 22

Slika 8: *Shematski prikaz područja Europe u kojom se primjenjuju jedinične naknade (engl. unit rates) rutnih jedinica usluge po svakoj državi članici CRCO naplatne zone u 2017. godini* 23

Slika 9: *Komponente koje STATFOR uzima pri izradi sedmogodišnje prognoze prometa* 30

Slika 10: *Shematski prikaz korištenih podataka, komponenti analize i njihovih rezultata u srednjoročnom razdoblju prognoze* 31

Slika 11: *Ulazni podaci koji se uzimaju pri izradi sedmogodišnje prognoze prometa* 33

Slika 12: *Ulazni podaci koji se uzimaju pri izradi mjesečne prognoze* 34

Slika 13: *Shematski prikaz devet svjetskih ICAO prometnih regija korištenih u svrhu prometne statistike, prognoze i analize* 39

Slika 14: *Shematski prikaz dodatnog broja IFR kretanja zrakoplova po danu od 2016. do 2023. godine* 47

Slika 15: *Metoda prognoziranja ograničenja po parovima zračnih luka* 48

Slika 16: *Prosječna godišnja stopa rasta TSU-a u sedmogodišnjem razdoblju (2016-2023) po državama članicama EUROCONTROL-a (CRCO14)* 55

Slika 17: *Shematski prikaz strukture modela za dugoročnu prognozu* 60

Slika 18: *Ukupno IFR kretanja zrakoplova (u tisućama) na području Europe prema „najvjerojatnijem“ scenariju* 65

Slika 19: *Prosječna godišnja stopa rasta IFR kretanja zrakoplova na području Europe (ESRA08) prema „najvjerojatnijem“ scenariju* 65

Slika 20: *Prosječna godišnja stopa rasta glavnih prometnih tokova po ICAO prometnim regijama u vremenskom razdoblju od 2012. godine do 2035. godine prema „najvjerojatnijem“ scenariju* 66

Slika 21: *Potražnja IFR kretanja zrakoplova (ne uključuje prelete) koja nadilazi kapacitet zračnih luka u 2035. godini prema scenariju A* 69

Slika 22: *Mreža željeznica velikih brzina uglavnom je razvijena na području zapadne Europe* 73

Slika 23: *Shematski prikaz stopa rasta po ACC-ima u vremenskom razdoblju od 2016. do 2021. godine. Osnovna referenca evolucije prometa na razini Europe iznosi 10,5 %* 80

Slika 24: *Područje odgovornosti LDZO ACC za donji i gornji zračni prostor* 81

POPIS TABLICA

Tablica 1: *Trenutno stanje, prognoza i odstupanje TSU-a na godišnjoj razini prema STATFOR-u i državama* 25

Tablica 2: *Godišnja naplata rutnih jedinica usluge za naplatno područje država (2017-2018)* 26

Tablica 3: *Popis država i pripadajuće terminalne naplatne zone za jedan ili više aerodroma u RP2 regiji* 28

Tablica 4: *Rast BDP-a u prometnim zonama na području Europe (ECAC)* 36

Tablica 5: *Premještanje zračnog prometa s jedne zračne luke na drugu* 38

Tablica 6: *Faktori popunjenosti po ICAO prometnim regijama* 39

Tablica 7: *Rast odlaznog reda letenja za referentnu 2017. godinu na području ECAC-a, ESRA08 i EU-27* 40

Tablica 8: *Dodatan rast IFR kretanja zrakoplova u % zbog utjecaja LCC-a u prometnim zonama* 41

Tablica 9: *Dobna raspodjela populacije po prometnim zonama* 42

Tablica 10: *Vrijeme putovanja po paru gradova, a udaljenost je procijenjena na temelju lokacija zračnih luka* 43

Tablica 11: *Prognostički trendovi IFR kretanja zrakoplova i njihov godišnji rast na području Europe* 45

Tablica 12: *Utjecaj ograničenja zračnih luka na IFR kretanja zrakoplova* 48

Tablica 13: *Utjecaj vlakova velikih brzina na IFR kretanja zrakoplova* 49

Tablica 14: *Sedmogodišnja prognoza IFR kretanja zrakoplova po državama na području Europe* 51

Tablica 15: *Sažetak prognoze rutnih jedinica usluge CRCO14 na području RP2 regije* 54

Tablica 16: *Sedmogodišnja prognoza rutnih jedinica usluge na području Europe* 56

Tablica 17: *Sažetak prognoze terminalnih jedinica usluge na području RP2 regije* 58

Tablica 18: *Sedmogodišnja prognoza terminalnih jedinica usluge za terminalnu naplatnu zonu država* 58

Tablica 19: *Sažetak prognoze IFR kretanja zrakoplova i njihov godišnji rast u ESRA08 do 2035. godine* 62

Tablica 20: *Rast domaćeg prometa bit će manji od prosjeka u ESRA Sjeverozapad i ESRA Mediteran. Napomena: Ukupno ne uključuje prelete* 64

Tablica 21: *IFR kretanja zrakoplova (domaći, odlazni i dolazni te preleti) i njihov godišnji rast na području Europe (ESRA08) do 2035. godine* 67

Tablica 22: *Prema „najvjerojatnijem" scenariju oko dva milijuna IFR kretanja zrakoplova bit će odbijeno zbog ograničenja kapaciteta zračnih luka* 68

Tablica 23: *Veličina zrakoplova brže raste za dugo-linijske letove* 72

Tablica 24: *Traženi profil kapaciteta za ACC Zagreb* 75

Tablica 25: *Očekivana prometna potražnja u % za LDZO ACC do 2021. godine, komparirano s 2016. godinom* 80

Tablica 26: *Kratkoročna prognoza TSU-a za naplatno područje Republike Hrvatske do 2018. godine* 84

POPIS GRAFIKONA

Grafikon 1. *Glavne promjene IFR kretanja zrakoplova u europskoj ATM mreži revidirane u ožujku 2017. godine.* 21

Grafikon 2: *Mjesečna evolucija TSU-a (u milijunima) u 2013., 2014., 2015., 2016. i 2017. godini za CRCO14 zonu.* 24

Grafikon 3: *Kretanje BDP-a u 28 država članica EU-a do 2022. godine.* 37

Grafikon 4: *Shematski prikaz godišnjeg rasta IFR kretanja zrakoplova tijekom prethodna četiri desetljeća na području Europe (ECAC), referentna godina za tri scenarija rasta je 2017. godina.* 46

Grafikon 5: *Shematski prikaz očekivanog broja IFR kretanja zrakoplova na području ECAC-a u komparaciji s prethodnom sedmogodišnjom prognozom iz rujna 2016. godine* 46

Grafikon 6: *Komparativni prikaz objavljene sedmogodišnje prognoze TSU-a iz veljače 2017. godine s rujnom 2016. godine na području EUROCONTROL-a (CRCO14).* 53

Grafikon 7: *STATFOR prognoza rutnih jedinica usluga prema prvoj reviziji za CRCO14 naplatnu zonu u 2017. godini prema osnovnoj referenci, najvišoj i najnižoj stopi rasta.* 55

Grafikon 8: *Niz čimbenika koji utječu na putničku potražnju i IFR kretanja zrakoplova, iskazano kroz rast ili pad prometa* 61

Grafikon 9: *IFR kretanja zrakoplova i njihovo uvećanje u vremenskom razdoblju prognoze do 2035. godine* 63

Grafikon 10: *Broj odlaznih IFR operacija u većim zračnim lukama na području Europe prema četiri scenarija prognoze u 2035. godini.* 70

Grafikon 11: *Promjena udaljenosti po odlaznom putniku u ESRA području prema srednjoročnoj prognozi prometa iz 2013. godine. Sve veći broj putnika koji lete na dugo-linijskim letovima* 71

Grafikon 12: *Promjena udaljenosti ukupnih letova prema srednjoročnoj prognozi prometa iz 2013. godine. Povećanje odlaznih letova na dugo-linijskim letovima* 72

Grafikon 13: *Komparativni prikaz ostvarenog IFR kretanja zrakoplova po mjesecima u vremenskom razdoblju od 2013. do 2017. godine (do kolovoza)* 76

Grafikon 14: *Trenutno stanje IFR kretanja zrakoplova u vremenskom razdoblju od 2006. godine do 2017. godine na području Republike Hrvatske (do srpnja).* 77

Grafikon 15: *Sedmogodišnja prognoza IFR kretanja zrakoplova u području odgovornosti LDZO ACC (Hrvatska) iskazana eksponencijalnom trend krivuljom i linijskim grafikonom*.. 78

Grafikon 16: *Scenariji rasta IFR kretanja zrakoplova prema dugoročnoj prognozi na području Republike Hrvatske u sklopu ESRA08* 79

Grafikon 17: *Profil kapaciteta i alternativni scenarij LDZO ACC (osnovna referenca)*..... 82

Grafikon 18: *STATFOR prognoza TSU-a prema prvoj reviziji vrijednosti iz ožujka 2017. godine za naplatnu zonu Republike Hrvatske, usporedba s trenutnim stanjem iz 2016. godine* 83

Grafikon 19: *Ukupan broj TSU-a za Hrvatsku naplatnu zonu (LD) za trenutno stanje i očekivano stanje prema osnovnoj referenci u 2017. godini po mjesecima* 83

Grafikon 20: *Srednjoročna STATFOR prognoza TSU-a prema prvoj reviziji vrijednosti u ožujku 2017. godine u naplatnoj zoni Republike Hrvatske za osnovnu referencu, najvišu i najnižu stopu rasta* 84

Grafikon 21: *Sedmogodišnja prognoza rutnih jedinica usluge u području odgovornosti LDZO ACC (Hrvatska) iskazano eksponencijalnom trend krivuljom i linijskim grafikonom*.. 85

Grafikon 22: *Sedmogodišnja prognoza terminalnih jedinica usluge u Hrvatskoj naplatnoj zoni (LD) iskazano eksponencijalnom trend krivuljom i linijskim grafikonom* 86

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10 000 Zagreb
Vukelićeva 4

METAPODACI

Naslov rada: Metode prognoziranja zračnog prometa u kontekstu upravljanja zračnim prometom

Autor: Ivan Lonjak

Mentor: doc. dr. sc. Tomislav Mihetec

Naslov na drugom jeziku (engleski): Air Traffic Forecasting Methodologies in Context of Air Traffic Management

Povjerenstvo za obranu:

- izv. prof. dr. sc. Andrija Vidović (predsjednik)
- doc. dr. sc. Tomislav Mihetec (mentor)
- mag. ing. traff. Arijana Modić (član)
- prof. dr. sc. Sanja Steiner (zamjena)

Ustanova koja je dodijelila 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 2017.

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10 000 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 prognoziranja zračnog prometa u kontekstu upravljanja zračnim prometom** na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 6. rujna 2017.

Student:

