Određivanje indikatora kompleksnosti i radnog opterećenja na sektorima oblasne kontrole Zagreb programom NEST

Bazina, Mia

Master's thesis / Diplomski rad

2018

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:119:869190

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 6. travnja 2018.

Zavod: **Zavod za aeronautiku**
Predmet: **Upravljanje kapacitetom i protokom zračnog prometa**

DIPLOMSKI ZADATAK br. 4876

Pristupnik: **Mia Bazina (0135232204)**
Studij: Aeronautika

Zadatak: **Određivanje indikatora kompleksnosti i radnog opterećenja na sektorima oblasne kontrole Zagreb programom NEST**

Opis zadatka:

Uvodno navesti cilj, teze i djelokrug istraživanja. Obraditi podatke o zračnom prometu u Europi i Hrvatskoj. Analizirati metodologiju određivanja vrijednosti indikatora kompleksnosti i radnog opterećenja sektora koju primjenjuje program NEST. Primijeniti program NEST i odrediti indikatore kompleksnosti sektora oblasne kontrole Zagreb za zadani uzorak prometa. Primijeniti program NEST i odrediti radon opterećenje sektora oblasne kontrole Zagreb za zadani uzorak prometa.
Analizirati dobivene rezultate. Dati zaključna razmatranja.

Mentor:

doc. dr. sc. Biljana Juričić

Predsjednik povjerenstva za diplomski ispit:

Sveučilište u Zagrebu

Fakultet prometnih znanosti

DIPLOMSKI RAD

ODREĐIVANJE INDIKATORA KOMPLEKSNOSTI I RADNOG OPTEREĆENJA NA SEKTORIMA OBLASNE KONTROLE ZAGREB PROGRAMOM NEST

DETERMINATION OF THE COMPLEXITY INDICATORS AND THE SECTOR WORKLOAD OF THE ZAGREB AREA CONTROL USING NEST APPLICATION

Mentorica: doc. dr. sc. Biljana Juričić

Studentica: Mia Bazina

JMBAG: 0135232204

Zagreb, rujan 2018.

SAŽETAK

Kompleksnost označava težinu nadzora i upravljanja specifične situacije u zračnom prometu. Prema EUROCONTROL organizaciji kompleksnost predstavlja broj potencijalnih odnosa između dva zrakoplova i odnosa između zrakoplova s okolinom tijekom određenog vremena. Kompleksnost ima i znatan utjecaj na radno opterećenje kontrolora zračnog prometa te postoji uvriježena pretpostavka da postoji korelacija između ta dva pojma, no nije nigdje precizno definirana. Ovaj diplomski rad potvrđuje pretpostavku povećanja radnog opterećenja s porastom kompleksnosti. Određena je kompleksnost sektora oblasne kontrole Zagreb te radno opterećenje za zadani uzorak prometa koristeći analitički program NEST.

KLJUČNE RIJEČI: kompleksnost; radno opterećenje; NEST; indikator; oblasna kontrola

SUMMARY

Complexity is the difficulty of monitoring and managing a specific air traffic situation. According to EUROCONTROL, complexity represents the number of potential interactions between two aircraft and aircraft-environment interactions during a determined time period. Complexity also has a significant influence on air traffic contoller's workload and there's a popular hypothesis that there's a corellation between those two concepts only it isn't precisely defined. This thesis confirms the assumption that by increasing complexity, workload is increased as well. Complexity of Zagreb area control sectors and the workload for a given traffic sample has been determined using the analytical application NEST.

KEY WORDS: complexity; workload; NEST; indicator; area control

SADRŽAJ

1. Uvod 1
2. Zračni promet u Europi i Hrvatskoj s obzirom na kapacitet i prometnu potražnju 3
2.1. Jedinstveno europsko nebo 4
2.2. Istraživanje Jedinstvenog europskog neba o upravljanju zračnim prometom 6
2.3. Statistike o kapacitetu u Europi i Hrvatskoj 7
2.4. Kapacitet i zagušenja na zračnim lukama 10
3. Metodologija određivanja vrijednosti indikatora kompleksnosti sektora koju primjenjuje program NEST 13
3.1. Dimenzije kompleksnosti 14
3.1.1. Dimenzije kompleksnosti prometnih karakteristika 14
3.1.2. Dimenzije kompleksnosti zračnog prostora 15
3.1.3. Dimenzije kompleksnosti vanjskih ograničenja 16
3.2. Značaj dimenzija kompleksnosti 16
3.3. Ćelije 17
3.4. Interakcije 18
3.5. Prilagođena gustoća 19
3.6. Vertikalne interakcije 20
3.7. Horizontalne interakcije 22
3.8. Interakcije brzine 23
3.9. Rezultat kompleksnosti 23
3.10. Strukturalni indeks 24
3.11. Indikatori kompleksnosti 25
3.12. Program NEST 25
3.12.1. Kompleksnost u NEST programu 25
3.12.2. Sadržaj datoteke s rezultatima 26
3.12.3. Završni indikatori kompleksnosti 27
3.12.4. Računanje kompleksnosti 28
3.12.5. Parametri 28
3.12.6. Zadana mreža 29
4. Metodologija određivanja radnog opterećenja sektora kontrole zračnog prometa koju primjenjuje program NEST 30
4.1. Temeljna formula za radno opterećenje 32
4.2. Makroskopska formula za radno opterećenje 33
5. Određivanje indikatora kompleksnosti sektora oblasne kontrole Zagreb za zadani uzorak prometa 35

5.1. Siječanj 35
5.2. Travanj 36
5.3. Srpanj 36
5.4. Kolovoz 37
6. Određivanje radnog opterećenja sektora oblasne kontrole Zagreb za zadani uzorak prometa .. 38
6.1. Siječanj 38
6.2. Travanj 42
6.3. Srpanj 45
6.4. Kolovoz 48
7. Analiza rezultata 52
8. Zaključak 54
Literatura 55
Popis kratica 56
Popis slika 59
Popis tablica 59
Popis grafikona 60

1. Uvod

Kompleksnost, kao težina obavljanja određene operacije, usko je povezana s radnim opterećenjem kontrolora. Jedan od ograničavajućih faktora razvoja i širenja zračnog prostora je broj kontrolora i njihovo radno opterećenje, a samim time i kompleksnost prometa koji prolazi prostorom kojeg nadziru. Povezanost između pojmova kompleksnosti i radnog opterećenja nije temeljito istražena ali je dovoljno dobro poznata da bi se znalo raditi na izazovima koji su neminovni u budućnosti brzorastućeg zračnog prometa u svijetu, Europi, a time i u Hrvatskoj. Povećanjem kompleksnosti povećava se i radno opterećenje što za posljedicu ima ograničenost kapaciteta zračnog prostora kojeg kontrolor može kontrolirati, stoga je neophodno barem povećati propusnost prostora ukoliko se ne može smanjiti njegova kompleksnost.

Ovaj diplomski rad sastoji se od osam zasebnih cjelina:

1. Uvod
2. Zračni promet u Europi i Hrvatskoj s obzirom na kapacitet i prometnu potražnju
3. Metodologija određivanja vrijednosti indikatora kompleksnosti sektora koju primjenjuje program NEST
4. Metodologija određivanja radnog opterećenja sektora kontrole zračnog prometa koju primjenjuje program NEST
5. Određivanje indikatora kompleksnosti sektora oblasne kontrole Zagreb za zadani uzorak prometa
6. Određivanje radnog opterećenja sektora oblasne kontrole Zagreb za zadani uzorak prometa
7. Analiza rezultata
8. Zaključak

U ovom uvodu je tek kratak opis tematike diplomskog rada i njegovih pripadajućih cjelina.

Drugo poglavlje pomnije objašnjava situaciju u zračnom prometu u Europi i Hrvatskoj s naglaskom na kapacitet i prometnu potražnju.

Metodologija određivanja vrijednosti indikatora kompleksnosti sektora tema je trećeg poglavlja i pojašnjava način na koji program NEST (Network Simulation Testbed - NEST) daje tražene rezultate.

Četvrto poglavlje pomnije objašnjava metodologiju određivanja radnog opterećenja sektora kontrole zračnog prometa koju primjenjuje program NEST kako bi se kasnije dobiveni rezultati mogli bolje razumjeti.

U petom poglavlju određeni su i predstavljeni indikatori kompleksnosti sektora oblasne kontrole Zagreb za zadani uzorak prometa.

Kroz šesto poglavlje prikazuje se radno opterećenje sektora oblasne kontrole Zagreb, također za zadani uzorak prometa.

Sedmo poglavlje daje kratku analizu već predstavljenih i dobivenih rezultata i pojašnjava njihovo značenje.

Posljednje osmo poglavlje sažet je prikaz svih prethodnih poglavlja koji ističe najbitnije zaključke iz rada.

U izradi diplomskog rada korištena je dostupna relevantna literatura vezana za kompleksnost i radno opterećenje kontrolora koja je objavljena prethodnih godina te se većinom sastoji od izvješća, osvrta i istraživanja. Sva korištena literatura nabrojana je pod naslovom poglavlja Literatura pred kraj diplomskog rada.

2. Zračni promet u Europi i Hrvatskoj s obzirom na kapacitet i prometnu potražnju

Kapacitet se generalno definira kao broj operacija koje subjekt može pružiti u definiranom vremenskom periodu u određenim uvjetima. Protok bi bio broj operacija koje mogu proći jediničnom površinom ili volumenom u definiranom vremenskom periodu u određenim uvjetima. Kapacitet zračnog prostora određuje se za svaku česticu zračnog prostora određenih granica i karakteristika. Razlikuju se dva različita pristupa proučavanja modela izračuna kapaciteta od kojih se oba proučavaju u ovom radu: fizički kapacitet prostora (volumen prometa) i kapacitet prostora koji se određuje na temelju razine pružanja usluge (radno opterećenje kontrolora) [1].

Ponuda, odnosno kapacitet u zračnom prometu predstavlja maksimalan broj zrakoplova koji mogu ući u neki prostor u promatranom vremenskom periodu. Prometna potražnja označava ukupan broj zrakoplova koji žele ući u neki prostor u promatranom vremenskom periodu. Uspoređivanjem ovih dvaju pojmova dolazi se do interakcije između ponude i potražnje. Kada je potražnja manja od ponude nema zastoja i čekanja, a ako su jednake dolazi do pojave idealnog homogenog toka. Kada je potražnja veća od ponude pojavljuju se red čekanja i kašnjenja. Razlog zbog kojeg dolazi do pojave kašnjenja neuravnoteženje je između ponude i potražnje (nekompatibilnost ATM sustava (Air Traffic Management - ATM) i rascjepkanost prostora, te zasićenje manevarskih površina aerodroma) [1].

Upravljanje protokom zračnog prometa (Air Traffic Flow Management – ATFM) usluga je koja je uspostavljena u svrhu postizanja sigurnog, redovitog i učinkovitog odvijanja zračnog prometa, te se maksimalno koriste kapaciteti kontrole zračnog prometa i osigurava kompatibilnost između potražnje i proglašenog kapaciteta relevantnih jedinica kontrole zračnog prometa. Kapacitet se najčešće označava kao broj zrakoplova koji ulaze u definirani zračni prostor u određenom vremenskom razdoblju, s tim da se uzimaju u obzir svi faktori koji mogu utjecati na radno opterećenje kontrolora zračnog prometa koji su odgovorni za taj zračni prostor. Zadužen za uslugu upravljanja protokom zračnog prometa na području Europe je NMOC (Network Manager Operations Centre - NMOC) u EUROCONTROL organizaciji, i to uravnoteženjem planirane potražnje (u vidu predanih planova) i planova kapaciteta relevantnih jedinica kontrole zračnog prometa, kao i zračnih luka, uzimajući u obzir i događaje koji bi mogli značajnije utjecati na protok zračnog prometa (poput svjetskih ili europskih sportskih natjecanja, priljeva turista tijekom ljetnih i zimskih praznika i slično) [2].

2.1. Jedinstveno europsko nebo

Inicijativa Jedinstvenog europskog neba (Single European Sky - SES) započeta je 2000. godine od strane Europske Komisije nakon velikih kašnjenja u Europi godinu ranije. Legislativni paket izrađen je već krajem 2001. te su ga prihvatili Europski parlament i Europsko vijeće u ožujku 2004. godine. SES je stupio na snagu u travnju iste godine [3].

SES paket nastoji:

- Povećati sigurnost i učinkovitost zračnog prijevoza u Europi;
- Smanjiti kašnjenja poboljšanjem korištenja zračnog prostora i resursa zračnih luka;
- Unaprijediti usluge i smanjiti troškove zračnog prijevoza putnika reducirajući fragmentaciju ATM sustava u Europi;
- Poboljšati integraciju vojnih sustava u europski ATM sustav [3].

Unatoč velikom trudu što se tiče modernizacije i njenog pojednostavljivanja, europski sustav je ostao siguran ali i skup. Također je sputan raznovrsnim radnim praksama i ograničen zračnim rutnim mrežama koje su većinski bazirane na nacionalnim granicama umjesto na protoku zračnog prometa. SES inicijativa trudi se riješiti sve navedene probleme i omogućiti ATM sustavu da se nosi s budućom predviđenom prometnom potražnjom [3]. Ciljevi same uspostave SES inicijative su:

- efikasniji zračni prostor (veći profit zrakoplovnih kompanija, smanjenje troškova, zadovoljstvo putnika, smanjenje vremena putovanja),
- uvođenje velikog broja direktnih linija DEP-ARR (odlazak-dolazak - departure-arrival),
- *gate-to-gate* prijevoz [1].

Rješenja koja su data u regulativi Jedinstvenog europskog neba 2004. spominju uvođenje Europskog gornjeg područja letnih informacija (European Upper Flight Information Region - EUIR), mrežno upravljanje i dizajn zračnog prostora u funkciji tokova zračnog prometa, te uvođenje koncepta fleksibilne upotrebe zračnog prostora (Flexible Use of Airspace - FUA). Osnova FUA koncepta je da zračni prostor više ne bude samo vojni ili samo civilni zračni prostor, već da bude jedan prostor te da se fleksibilno koristi na dnevnoj bazi. Bilo kakva podjela zračnog prostora trebala bi biti privremena. Još jedan koncept kojeg se nastoji sve više uvesti je koncept zračnog prostora slobodnih ruta (Free Route Airspace - FRA) - način letenja u kojem operatori zrakoplova mogu slobodno planirati svoju rutu između definirane ulazne i izlazne točke. Unutar FRA zračnog prostora pruža se usluga kontrole zračnog prometa uz davanje odobrenja i instrukcija. Neke od prednosti uvođenja FRA koncepta su:

- smanjenje količine izgaranja goriva,
- smanjenje emisija CO_2,
- smanjenje prijeđenih milja,

- skraćeno vrijeme leta,
- bolja učinkovitost u planiranju letenja [1].

EUROCONTROL je 2008. godine inicirao koordinirani razvoj i implementaciju FRA u suradnji s raznim stručnjacima iz država članica ECAC područja (European Civil Aviation Conference - ECAC) i ANSP (Air Navigation Service Provider - ANSP) stručnjaka. Do kraja 2017. godine već je 51 ACC (Area Control Center - ACC) ili djelomično ili u potpunosti implementirao FRA operacije, što je premašilo inicijalni cilj od njih 35 [4]. Unutar godine dana od potpisivanja memoranduma o suradnji s ciljem spajanja SAXFRA (Slovenian Austrian Cross-border Free Route Airspace - SAXFRA) i SEAFRA (South-East Axis Free Route Airspace - SEAFRA), inicijativa SECSI FRA (South East Common Sky Initiative Free Route Airspace - SECSI FRA) uspješno je implementirana s početkom veljače 2018. godine. SECSI FRA je operativno krenula u rad 01.02. nudeći korisnicima zračnog prostora značajne pogodnosti duž jugoistočne osi s najkraćim rutnim opcijama od centralne Europe do Jugoistočne Europe (slika 1.). Korist koja će se steći kroz SECSI FRA je znatna te su potencijalne dnevne uštede do 1940 NM udaljenosti leta, 285 minuta leta, smanjenje potrošnje goriva od 8000 kg i smanjenje CO_2 emisija od 25500 kg. Očekuje se da će SECSI FRA uštedjeti između 600000 i 700000 NM udaljenosti leta godišnje. Bit će dostupno i više opcija kod odlučivanja oko putanje koju preferira korisnik. FRA dozvoljava aviokompanijama da bolje iskoriste vjetar ili da se bolje prilagode mrežnim prekidima. Korištenje FRA opcija na razini planiranja letova također poboljšava predvidljivost i smanjuje radno opterećenje kontrolora [5].

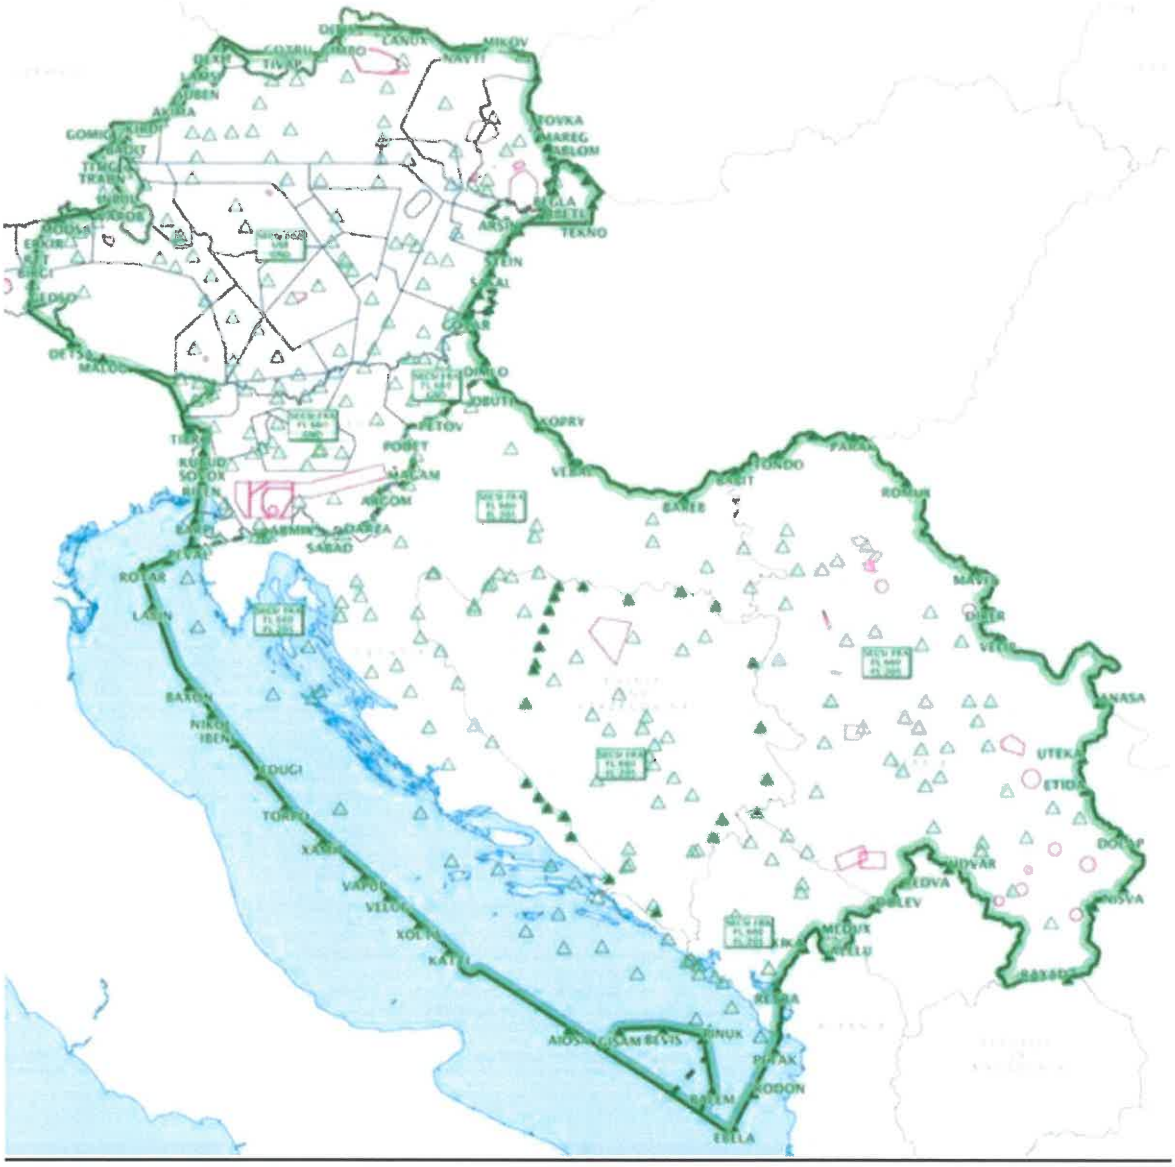

Slika 1. SECSI FRA, [5]

2.2. Istraživanje Jedinstvenog europskog neba o upravljanju zračnim prometom

Projekt istraživanja Jedinstvenog europskog neba o upravljanju zračnim prometom (Single European Sky ATM Research - SESAR) europski je program modernizacije ATC (Air Traffic Control - ATC) infrastrukture, i ne samo nje već cijelog ATM sustava. Cilj mu je razviti novu generaciju ATM sustava koja može osigurati sigurnost i fluidnost zračnog prijevoza u sljedećih 30 godina [6].

Projekt modernizacije upravljanja zračnim prometom u Europi (odnosno projekt SESAR) tehnološki je element Jedinstvenog europskog neba (SES). Cilj mu je do 2020. godine osigurati visoko učinkovitu infrastrukturu za kontrolu zračnog prometa koja će omogućiti siguran, i za okoliš prihvatljiv, razvoj zračnog prijevoza koristeći u cijelosti tehnološke

prednosti programa poput Galileo. SESAR se oformio u listopadu 2005. kada je i započela faza definiranja, dok je tri godine kasnije, 2008., oformljen i SES II [1].

SES II drugi je regulatorni paket Jedinstvenog europskog neba koji je uveden radi održivije i bolje avijacije budućnosti. Temelji se na 4 faktora razvoja:

- regulacija izvedbe
- jedinstveni sigurnosni okvir kojeg predstavlja Europska agencija za zrakoplovnu sigurnost (European Aviation Safety Agency - EASA)
- nove tehnologije (SESAR)
- upravljanje kapacitetom na zračnim lukama.

Regulacija izvedbe podrazumijeva uvođenje sljedećih mjera:

- vođenje izvedbe sustava kontrole zračnog prometa (donošenje glavnog europskog plana upravljanja zračnim prometom)
- olakšavanje integracije pružanja usluga kroz uspostavu funkcionalnih blokova zračnog prostora (Functional Airspace Block – FAB)
- ojačavanje funkcije upravljanja mrežom ruta (dizajn ruta i mreže ruta, koordinacija i dodjeljivanje *slotova* i upravljanje korištenjem različitih novih SESAR tehnologija) [1].

Postoji i najnoviji SESAR projekt nazvan SESAR 2020 koji se nadograđuje na dosadašnji. Planirani početak projekta bila je već 2015. godina ali potpisivanje članstva bilo je u srpnju 2016. dok je glavno potpisivanje ugovora koje je označilo početak projekta privedeno kraju tek u siječnju 2017. godine. Struktura radnog programa SESAR 2020 razlikuje se od samog početka SESAR projekta. Najveće su razlike u dijelovima koji se tiču istraživanja i validacija, te umjesto dosadašnjih stotina nepovezanih projekata svi su kategorizirani unutar 25 glavnih projekata. Ti projekti okupljaju sva potrebna istraživanja koja su potrebna kako bi se ispunila glavna SESAR rješenja. Glavni ciljevi programa mogu se podijeliti na četiri područja:

- visokoučinkovite operacije zračnih luka,
- optimizirana ATM mreža usluga,
- napredne usluge zračnog prometa,
- omogućavanje zrakoplovne infrastrukture [7].

2.3. Statistike o kapacitetu u Europi i Hrvatskoj

Prema službenim statistikama zračni promet u Europi, a i u Hrvatskoj, u konstantnom je porastu što pokazuje i slika 2. S obzirom na prosječni porast prometa 28 članica EU

(Europska Unija - EU) koji je dat kao referentni na slici, većina je država u porastu, i to znatnom od očekivanoga. Broj putnika u RH, primjerice, porastao je za čak 14% od 2015. do 2016. godine.

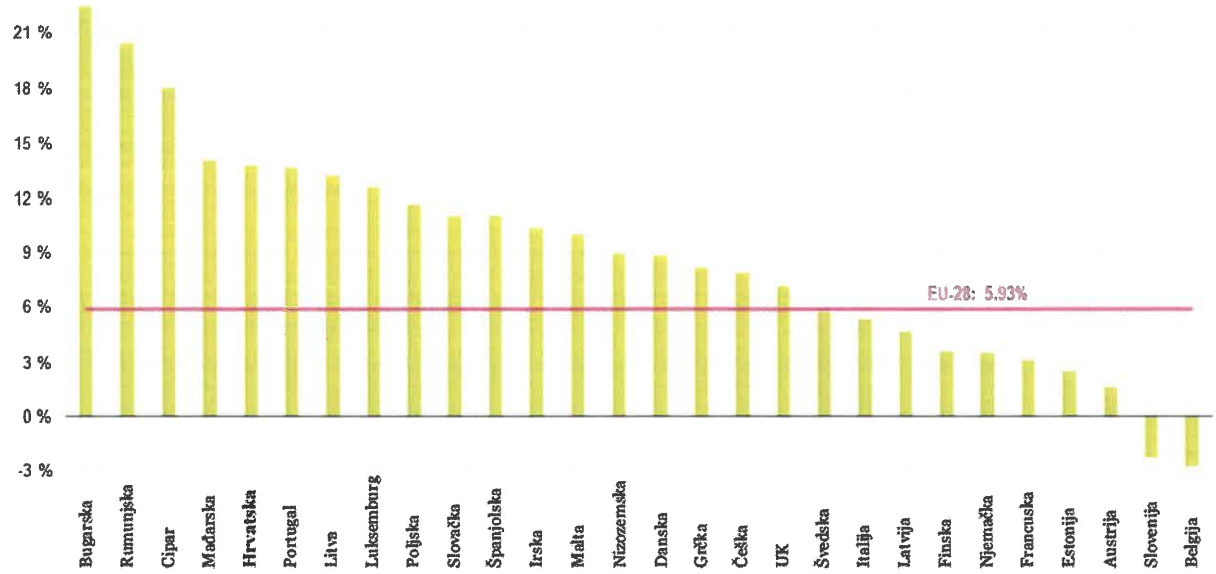

Slika 2. 2015/2016 rast u broju ukupnog broja putnika u zračnom prijevozu po državama članicama
Izvor: [8]

Tijekom 2016. godine broj putnika unutar Europske Unije iznosio je 973 milijuna što je porast od 5.9% s obzirom na 2015. godinu. London (Heathrow) je ostao najveća zračna luka po prijevozu putnika u 2016. dok je na drugom mjestu Pariz (Charles de Gaulle) [8].

Komercijalna avijacija pruža ogromne prilike za ekonomski rast i pritom zapošljava velik broj ljudi te bi unutar sljedećih 20 godina komercijalna avijacija mogla povećati broj poslova koje nudi za čak trećinu. Kako će se i broj putnika povećati u sljedećih 20 godina, točnije vjerojatno će se udvostručiti, porast će i broj zrakoplovnih operacija. Zbog toga je potrebno izraditi dobar plan, što se tiče izgradnje zračnih luka s dovoljno kapaciteta, koji bi podnio buduće zahtjeve. Unatoč tomu, u bliskoj će budućnosti mnoge zračne luke biti ograničene *slotovima* [9].

Zračni promet na EUROCONTROL području nastavio je rasti i 2017. godine što je četvrta godina za redom. Time je premašio broj letova iz 2008. godine koja je do sada imala najviše letova. U prosjeku je broj kontroliranih letova u 2017. narastao za 4.3% u odnosu na prethodnu 2016. godinu. Takav rast odgovara optimističnoj STATFOR prognozi (Statistics and Forecasts - STATFOR). Do najveće razine prometa došlo je 30.06.2017. kada je uslužen 35251 let unutar EUROCONTROL područja. Taj dan bio je prometniji od prosječnog dana za 23.8%. Jedini ANSP koji nije zabilježio porast u prometu u odnosu na prethodnu godinu bio je Avinor (Norveška) dok su najveći porast u 2017. zabilježili DSNA (Francuska), ENAIRE (Španjolska), DFS (Njemačka) i NATS (Ujedinjeno Kraljevstvo) [10].

Zadnja STATFOR prognoza iz veljače 2018. predviđa rast od 3.1% na razini sustava i prosječnu godišnju stopu rasta od 2.3% u razdoblju od 2016. do 2024. godine. Zbog sve većeg porasta prometa, kvaliteta usluge sve više se smanjuje. Postotak letova koji slijeću unutar 15 minuta od predviđenog vremena slijetanja smanjio se za 0.9% i sada je 79.6% (za 2017. godinu). Prosječno kašnjenje u polasku povećalo se za jednu minutu, sa 11.2 minute po odlasku u 2016. na 12.2 minute u 2017. godini [10].

Kako je zračni promet u paneuropskom prostoru nastavio rasti četvrtu godinu za redom to je za područje Europske konferencije civilne avijacije (European Civil Aviation Conference – ECAC) značilo dodatan 1191 let po danu, u prosjeku. Na slici 3. uspoređeni su vrhunci u danu s prosječnim dnevnim brojem letova na razini sustava. Na slici je vidljiv i 23.8% prometniji dan od prosječnog za 2017., odnosno 30.06. [10].

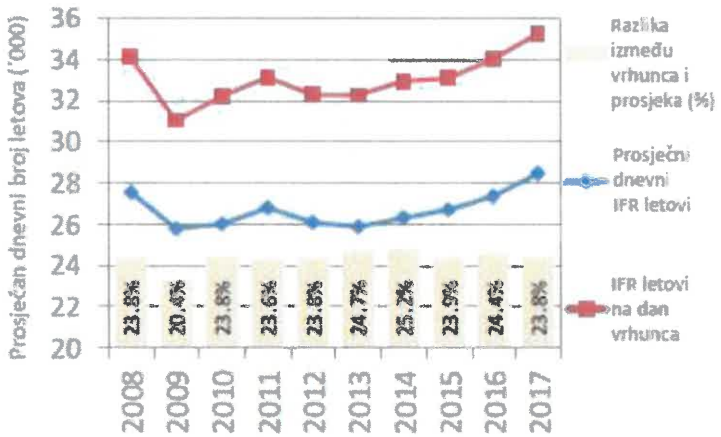

Slika 3. Razvoj prosječnog broja dnevnih letova na EUROCONTROL području
Izvor: [10]

Prema Europskom internacionalnom vijeću zračnih luka (Airports Council International Europe - ACI) [10], predviđa se porast zračnog prometa za čak 50% do 2035. godine. Kapacitet zračnih luka stoga predstavlja jedan od većih izazova budućnosti budući da EUROCONTROL procjenjuje da će manjak kapaciteta doseći i 12%. Postoji više problema na koje Europa nailazi u pokušaju širenja kapaciteta poput ekonomske regulacije, pravila planiranja, raznih političkih upletavanja i financijskih izazova. Iako je kapacitet jedna od najbitnijih stvari na kojoj se treba poraditi u budućnosti potrebno je i iskoristiti postojeći kapacitet što je najbolje moguće, pogotovo u vezi *slotova* [11].

Najnovija studija koju je proveo EUROCONTROL predviđa da bez hitnog djelovanja europska mreža zračnih luka neće biti u mogućnosti opsluživati broj letova predviđen u regiji do 2040. godine. U prvih pet mjeseci 2018. godine bilo je puno više kašnjenja nego prethodnih godina. Dok se promet povećao za 3.4% tijekom 2017., *en route* ATFM kašnjenja porasla su s 0.46 minuta po letu na 1.05 minuta po letu. Ciljano maksimalno kašnjenje EU je samo 0.5 minuta. Osnovni scenarij za Europu predviđa porast prometa od 1.9% godišnje do

2040. što je 16.2 milijuna letova godišnje ili porast od čak 53%. Gledajući pak optimistični scenarij rasta, taj bi broj mogao biti i 19.5 milijuna letova godišnje. Prema ovim prognozama 16 zračnih luka u regiji radit će na skoro cijelom kapacitetu većinu dana, što je porast od trenutnih šest, te bi to dovelo do procijenjenog gubitka ekonomske aktivnosti od 88.1 milijarde eura zbog nezadovoljene potražnje i smanjene zračne povezanosti. Stvaranje većeg kapaciteta je zbog svega navedenog neophodno, pogotovo na ovoj razini, i to bi se trebalo dugoročno planirati te što hitnije adresirati i riješiti [13].

2.4. Kapacitet i zagušenja na zračnim lukama

Prometna situacija u Hrvatskoj uznapredovala je od 177000 IFR GAT (Instrument Flight Rules General Air Traffic - IFR GAT) operacija 2000. godine do skoro pola milijuna 2011. Ovaj trend dosegao je svoj vrhunac te se stabilizirao u godinama nakon toga, većinom i zbog svjetske ekonomske krize, pa se i broj operacija zadržao na otprilike 500000 svake godine. U 2016. godini taj broj iznosio je 533275 IFR GAT operacija. Očekuje se postupni rast ali unutar operacijskih ograničenja (2,9% AAGR – Average Annual Growth Rate 2023/2016). To predviđanje temelji se na raznim faktorima, od migracija zračnih puteva zbog troškova i razvoja FRA do geo-političkih razloga donedavnih konflikata izvan ECAC područja koja također utječu na budući zračni promet [14]. Na slici 4. prikazane su već postojeće hrvatske godišnje operacije, kao i predviđene. Postoje uvijek tri vrste predviđanja, Baseline, High i Low (osnovno, optimistično i pesimistično).

Slika 4. Svarno i predviđeno kretanje IFR prometa u Hrvatskoj (2012 - 2022)
Izvor: [14]

Ukoliko promatramo Zračnu luku Zagreb, to jest Zračnu luku Franjo Tuđman, ona prema dostupnim podacima nema utjecaj na zračnu mrežu što se tiče ATFM kašnjenja pogotovo odnedavno otkako se otvorio novi terminal sa zgradom za putnike 21.03.2017. [14].

Kako je vidljivo iz slike 5., planiraju se konstantna poboljšanja te ne bi trebalo doći do praznina u kapacitetu tijekom planiranog vremena što ne znači da neće doći do ograničenja kapaciteta prilikom visokog rasta prometa ili tijekom bitnije promjene u rasporedu zračnog prometa. Od 2017. do 2021. godine planiraju se kontinuirana poboljšanja te se ne očekuje nedostatak u kapacitetu. Ograničenja kapaciteta mogu se pojaviti jedino u slučaju visokog porasta prometa te se očekuje malo veće kašnjenje tijekom implementacije FRA (koji je trenutno u potpunosti implementiran), no kašnjenja ne bi trebala prelaziti referentne vrijednosti. Tijekom bliske suradnje s hrvatskim upraviteljem mreže (Network Manager - NM) identificirana su poboljšanja u kapacitetu i potom implementirana, a performanse bi trebale ostati unutar referentnih vrijednosti kašnjenja [14].

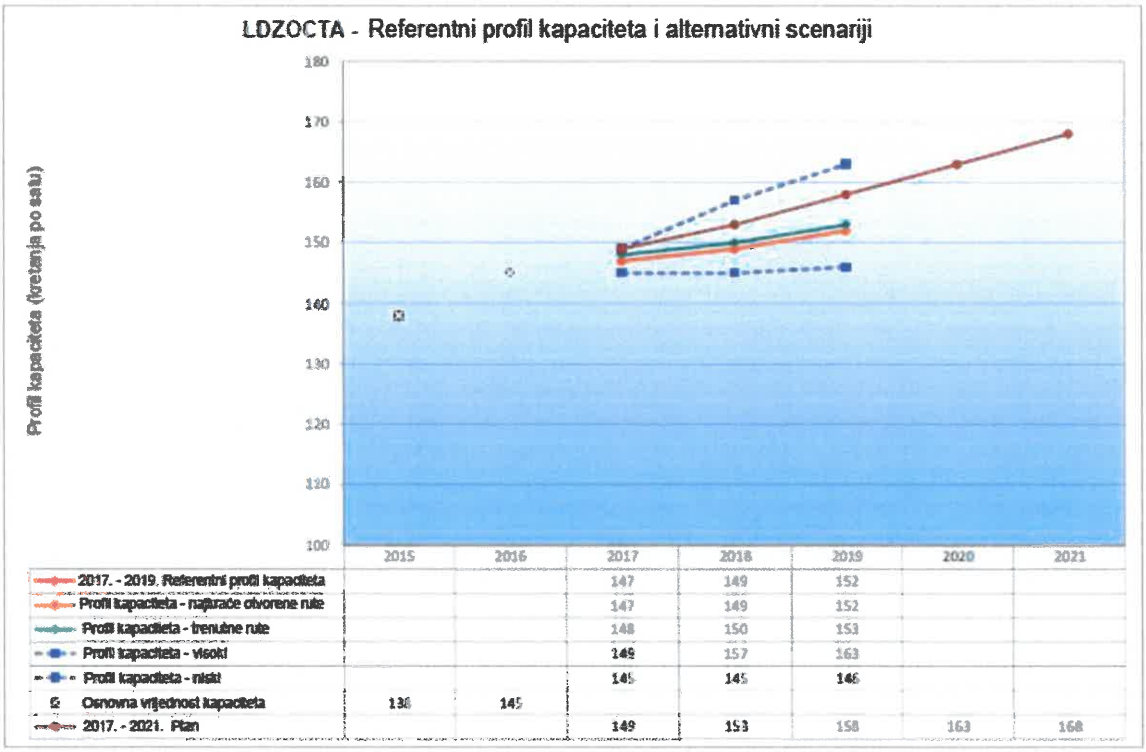

Slika 5. LDZOCTA referentni i alternativni scenariji
Izvor: [14]

Kada se govori o kapacitetu i sve većoj potrebi za njime, bitno je napomenuti koliko je on u biti važan za kompleksnost i radno opterećenje. Naime, ukoliko kontrolori ne raspolažu s kapacitetom koji im je potreban za održavanje sigurnog protoka prometa tada im se može povećati radno opterećenje jer rade na granicama svojih sposobnosti. Veća kompleksnost iziskuje veće opterećenje kontrolora, odnosno kontrolori mogu jednako učinkovito raditi na manjem prostoru kako bi se zadržala jednaka razina sigurnosti. Na slici 6. prikazana je međuovisnost kompleksnosti, radnog opterećenja i kapaciteta te je vidljivo koliko su ti pojmovi povezani i ovisni jedno o drugome.

Slika 6. Zavisnost kompleksnosti, radnog opterećenja i kapaciteta
Izvor: [1]

U sljedeća dva poglavlja pomnije je objašnjeno kako se obrađuju relevantni podaci vezani za kompleksnost i radno opterećenje u programu NEST.

3. Metodologija određivanja vrijednosti indikatora kompleksnosti sektora koju primjenjuje program NEST

Kompleksnost se najčešće definira kao razina težine obavljanja nekog posla iako ne postoji univerzalna definicija koja je primjenjiva na ATM. Uz tu razinu težine u definiciju se može ubaciti i dodatno radno opterećenje kontrolora van onoga koje je direktno povezano s brojem letova [15].

Definicija kompleksnosti pak ovisi i o njenoj namjeni. Studija koja je provedena 2006. godine [15] imala je za namjeru ujednačiti definicije kompleksnosti i njenih indikatora. Indikatori kompleksnosti uzimali su u obzir vanjske faktore koji utječu na radno opterećenje kontrolora te na težinu obavljanja određenog ATC (Kontrola zračne plovidbe - KZP) zadatka. Unutarnji faktori i faktori vezani za ATC procedure nisu uzeti u obzir u toj studiji budući da je glavni cilj bio *benchmarking*. Pokušalo se jasno razdvojiti što je zasluga ANSP, a što se treba pripisati smanjenju kompleksnosti. Neki unutarnji faktori nisu se mogli isključiti iz analize, poput strukture ruta, budući da su veoma usko vezani za uzorke prometa [15].

Aspekti kompleksnosti bi bili:

- Kompleksnost vezana za ATC procedure – dodatno opterećenje kontrolora koje se javlja zbog prometa, mogu biti i ATC procedure u prometu, organizacija zračnog prostora, strukture ruta i slično; Ovi su aspekti većinom unutarnji ANSP faktori
- Kompleksnost prometnih karakteristika – dodatno opterećenje kontrolora zbog koncentracije, vrste interakcije prometa; Većinom vanjski ANSP faktori
- Vanjska kompleksnost – dodatno opterećenje kontrolora zbog strukture zračnog prostora kroz koju prolazi zračni promet; Također većinom vanjski ANSP faktori [15].

Ovi aspekti kompleksnosti doprinose radnom opterećenju kontrolora kao što je prikazano na slici 7. gdje je kompleksnost vezana za ATC procedure podijeljena na dvije komponente: problemi vezani za zračni prostor i koncept operacija/tehnologije.

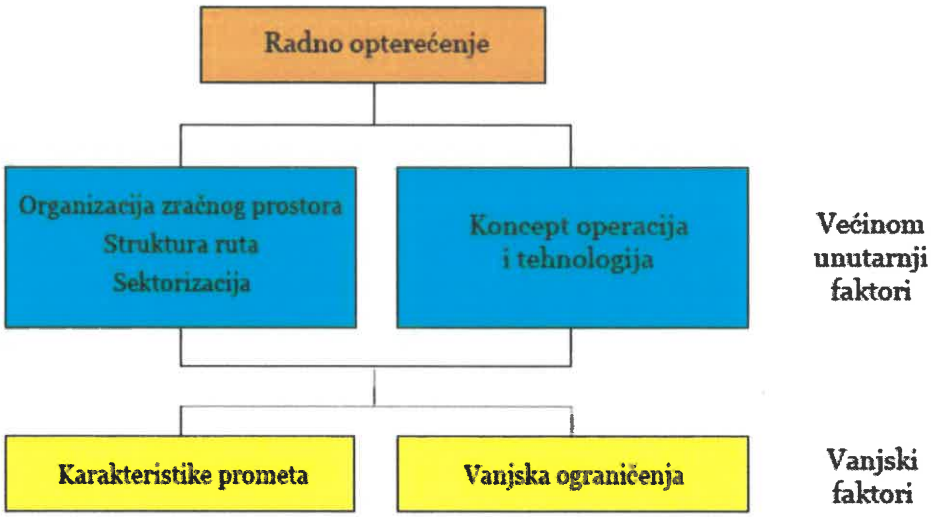

Slika 7. Ilustracija unutarnjih i vanjskih faktora kompleksnosti
Izvor: [15]

Zbog svega navedenog kompleksnost se definira kao skup vanjskih faktora koji utječu na radno opterećenje kontrolora i/ili razinu težine obavljanja ATC zadataka, s tim da se ne uzimaju u obzir unutarnji faktori vezani za ATC procedure [15].

3.1. Dimenzije kompleksnosti

Svaka dimenzija kompleksnosti dio je ATM okoline i može se objasniti kao doživljaj koji osjeća kontrolor. Te dimenzije mogu se podijeliti u tri kategorije: karakteristike prometa, ograničenja zračnog prostora te vanjska ograničenja. U nastavku se nalaze najbitnije dimenzije kompleksnosti [15].

3.1.1. Dimenzije kompleksnosti prometnih karakteristika

Gustoća prometa (Traffic density) – ova dimenzija obuhvaća raspored zrakoplova u zračnom prostoru. Potrebno je imati na umu da se zrakoplovi geografski mogu nalaziti u određenim dijelovima zračnog prostora ali mogu biti i koncentrirani unutar nekog vremenskog razdoblja. Tijekom dana ta koncentracija varira te postoje određeni maksimumi i minimumi koji se pojavljuju. Kompleksnost se generalno povećava kada zrakoplovi nisu ravnomjerno raspoređeni pa se kontrolor mora snalaziti s više zrakoplova u manjem volumenu zračnog prostora i to u kraćem vremenskom razdoblju. Na gustoću prometa mogu utjecati i unutarnji faktori poput strukture ruta no nejednak raspored letova većinom je takav zbog vanjskih faktora. Dva su najbitnija i najutjecajnija unutarnja faktora, a to su osnovna prometna potražnja (može biti usmjerena samo na određene dijelove zračnog prostora i/ili određeno vremensko razdoblje dana) i vojna područja koja ograničavaju

dostupni zračni prostor i time otežavaju posao kontrolorima ali i povećavaju gustoću prometa u drugim dijelovima zračnog prostora [15].

Promet u penjanju ili spuštanju (evolucija) – ili ukratko dimenzija vertikalnog kretanja zračnog prometa. Kada se kontrolor mora baviti zrakoplovima u penjanju, krstarenju i spuštanju to mu predstavlja kompleksniju smjenu od one u kojoj upravlja samo penjućim i spuštajućim zrakoplovima. Količina zrakoplova u penjanju i spuštanju dakako ovisi o blizini zračnih luka, pogotovo većih, gdje je izmiješanost svih vrsta kretanja zrakoplova (razni stavovi). Lokacije zračnih luka su u ovom primjeru vanjski faktor, dok na ovu dimenziju mogu utjecati i uvjeti transfera gdje se zrakoplovi moraju predati na dogovorenim visinama (na granicama) [15].

Struktura toka prometa (Flow structure) – dimenzija koja promatra horizontalno kretanje prometa. Smatra se kako su protoci prometa u križanju kompleksniji od paralelnih. Kada dođe do pojave križanja protoka prometa takav se smatra vanjskim faktorom, ali na lokaciju pak može utjecati struktura ruta koja je unutarnji faktor. Ako neki ANSP odluči promijeniti svoju strukturu i zbog njega se točka na kojoj se križaju zrakoplovi premjesti iz jednog ACC prostora u drugi to će utjecati na radno opterećenje obaju kontrolora (jednom će se smanjiti opterećenje a drugom povećati i to je onda unutarnji faktor). Vanjski je pojava lokacija novih točaka križanja zbog ANSP strukture ruta u blizini [15].

Izmiješanost prometa (Traffic mix) – ovdje se promatraju varijacije u brzinama zrakoplova. Zbog razlika u performansama svakog zrakoplova bitno je uvidjeti na koji način te karakteristike utječu na kompleksnost. Pretpostavka je da je situacija manje kompleksna kada zrakoplovi imaju slične brzine i da će dolazak zrakoplova sa znatno drugačijim brzinama povećati kompleksnost. Budući da su razlike u brzinama zrakoplova vezane za karakteristike tipa zrakoplova smatraju se vanjskim faktorom [15].

3.1.2. Dimenzije kompleksnosti zračnog prostora

Sektorizacija – kod ove dimenzije razmatra se koji su efekti sektorizacije na kompleksnost. Odluka o tome kako razdvojiti zračni prostor može povećati ali i smanjiti kompleksnost, nezavisno o tome što je povezana i s rutnom strukturom. ANSP u biti može izmijeniti svoju sektorizaciju pa se zato to smatra unutarnjim faktorom jer može smanjiti kompleksnost. Mogućnost optimizacije sektorizacije ne može uvijek biti provedena zbog raznih vanjskih ograničenja, poput vojnog zračnog prostora i suverenih granica [15].

Struktura ruta – u ovoj dimenziji bavi se strukturom ruta unutar zračnog prostora. Postoji razlika između strukture ruta koja teži prikazivanju osnovne prometne potražnje njene optimizacije budući da je sama optimizacija većinom unutarnji faktor, a struktura vanjski faktor. ANSP ima mogućnost restrukturiranja ruta unutar svog zračnog prostora ili čak

promjene dvosmjernih ruta, koje su kompleksnije, u jednosmjerne. I kod optimizacije ruta ANSP često nailazi na ograničenja zbog vanjskih faktora poput vojnih područja [15].

3.1.3. Dimenzije kompleksnosti vanjskih ograničenja

Vojna područja – kod ove dimenzije promatra se utjecaj vojnog zračnog prostora. Kada su vojna područja u igri kompleksnost se može povećati jer kontrolor ima manji zračni prostor u kojem upravlja prometom ili je potrebno koristiti alternativne rute kako bi se zaobišlo ta područja. Lokacija i opseg vojnih područja najčešće su vanjska ograničenja i na njih ANSP ne može utjecati, ali ono na što utječu ta područja jest kompleksnost koju osjeća kontrolor. Utjecaj vojnog područja na radno opterećenje kontrolora ovisi i o vrsti i kvaliteti vojno-civilne koordinacije i sporazuma [15].

Sučelje sa susjednim jedinicama – u ovoj dimenziji promatra se utjecaj veze između susjednih ACC prostora. Kada postoji sučelje koje dijele dva različita okruženja, od kojih svatko obavlja operacije, tada može doći do povećanja kompleksnosti. Ovo pogotovo dolazi do izražaja kada je potrebno povećati standarde razdvajanja, poput transfera zrakoplova iz radarske separacije u proceduralnu ili iz RVSM (Reduced Vertical Separation Minima - RVSM) područja u ono gdje se RVSM ne primjenjuje. Ovakvo sučelje većinom je vanjski faktor iako se mogu uvesti mjere koje bi bolje usmjerile transfer zrakoplova između dva ACC prostora i smanjile kompleksnost i doživljaj kompleksnosti kontrolora koji rade na istom sučelju, na primjer preko međusobnog sporazuma (Letter of Agreement - LoA) [15].

3.2. Značaj dimenzija kompleksnosti

Prva spomenuta kategorija iz prethodnog potpoglavlja, prometne karakteristike, sadrži sve dimenzije relevantne za takozvani *benchmarking* u skladu s ACE (ATM Cost-Effectiveness - ACE) dok druga navedena (zračni prostor) više teži grupiranju dimenzija kompleksnosti koje su vezane za ATC procedure. Iako ove dimenzije mogu pridonijeti povećanju ili smanjenju kompleksnosti prometa koju doživljava kontrolor, to su ipak redom unutarnji faktori koje većinskim dijelom može kontrolirati ANSP. Ukoliko dođe do poboljšanja performansi zbog učinkovitije postavljene rutne strukture tada se to treba pripisati boljem upravljanju prometa (ANSP), a ne smanjenju kompleksnosti. Navedeni unutarnji faktori trebali bi biti što manje zastupljeni tijekom izračuna indikatora kompleksnosti (barem u kontekstu ACE *benchmarkinga*). Unatoč njihovoj nepoželjnosti tijekom izračuna struktura ruta ne može se u potpunosti izuzeti iz izračuna budući da je usko povezana s uzorcima prometa [15].

Što se tiče dimenzija vanjskih ograničenja, one također utječu na kompleksnost prometa iako njihov doprinos nije uvijek moguće točno definirati. Utjecaj vojnog zračnog prostora svejedno se uzima u obzir jer ima indirektan utjecaj na indikatore prometnih karakteristika, a pogotovo na prilagođenu gustoću. Ostala vanjska ograničenja (prijelaz iz RVSM u ne-RVSM prostor i obrnuto, prijelaz iz metričkih standarada separacije u imperijski i obrnuto, i slično) također postoje ali ih je gotovo nemoguće točno kvantificirati kako bi se mogla uzeti u obzir. Postoji i utjecaj posebnih događaja koji također nije uzet u obzir za izračun, kao i varijabilnost prometa i atmosferske prilike. Posebni događaji imaju najveći utjecaj na dnevnu kompleksnost prometa (poput vojnih vježbi preko velikog područja ili dodatan promet tijekom svjetskog nogometnog prvenstva). Unatoč navedenome posebni događaji u biti ne utječu bitno na prosječnu produktivnost tijekom godine, odnosno njihov je utjecaj zanemariv [15].

3.3. Ćelije

Na slici 8. prikazani su prostorni (dx, dy i dz) i vremenski (dt) parametri ćelija koji se koriste za izračun kompleksnosti. Ćelija veličine 20 NM podudara se s granicama ACC prostora bolje od ćelija većih parametara koje su preglomazne za ovakve precizne izračune.

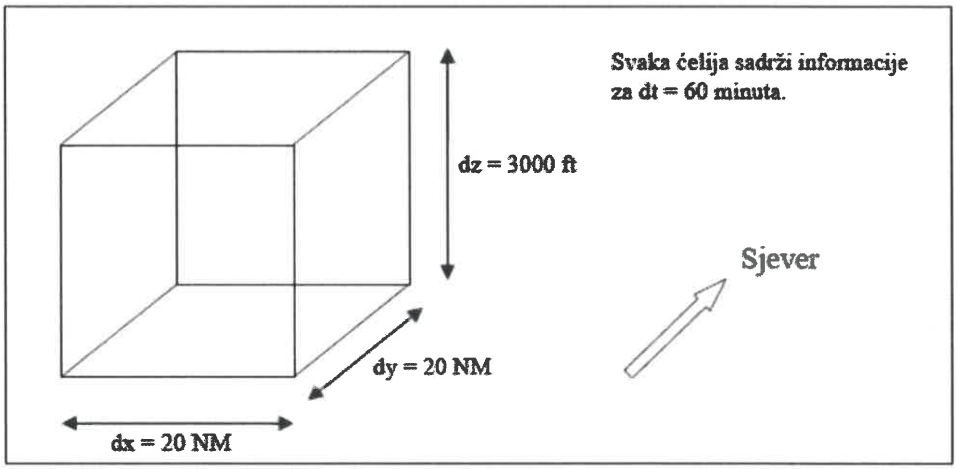

Slika 8. Dimenzije 4D ćelije
Izvor: [15]

Podaci o prometu unutar svake ćelije skupljaju se tijekom razdoblja od 60 minuta stoga postoje 24 seta podataka za svaku ćeliju (jedan set podataka = 1 h). Kako bi se izračunale vrijednosti ANSP indikatora prvi korak koji program radi jest određivanje pripadnosti ćelija budući da svaka ćelija ima svoj ANSP i to samo jedan. Podaci iz ćelija koje su na granicama zračnog prostora pridružuju se ANSP području u kojem se nalazi središnja točka ćelije [15].

Nakon određivanja pripadnosti računaju se vrijednosti za svaki ANSP, koristeći podatke iz relevantnoga, a na isti način dobivaju se i vrijednosti za ACC prostore. Potrebno je smanjiti utjecaj granica na mrežu u kojoj se obavljaju izračuni, stoga se koristi 12 mreža za izračun indikatora. Postoje četiri horizontalna pomaka mreža - veličina pomaka kombinacija je 0 i 10 NM u x i y dimenziji, pa bi koordinate tih pomaka bile: (0,0), (0,10), (10,0), (10,10). Svaka od ovih mreža pomiče se i vertikalnom osi u koracima od 3 puta po 1000 ft jer su u vertikalnoj ravnini ćelije visoke 3000 ft. Za prvu mrežu započinju na FL85 i nastavljaju se do FL415. Naposlijetku su rezultati izračuna prikazani kao prosjek vrijednosti svih 12 mreža [15].

3.4. Interakcije

Interakcije su izvor cijele kompleksnosti i njenog računanja jer prisutnost više zrakoplova u istom prostoru u isto vrijeme stvara kompleksnost, a pogotovo ako su ti zrakoplovi u različitim fazama leta, imaju različite pravce kretanja (headinge) ili različite brzine kretanja. Definicija interakcije je stoga istovremena prisutnost dva zrakoplova u istoj ćeliji kada se gleda iz perspektive svakog zrakoplova. Na slici 9. to je objašnjeno prikazom zrakoplova u ćelijama. Ćelija k ima dva zrakoplova i dvije interakcije dok ćelija k+1 ima tri zrakopolova ali šest interakcija. Svaka interakcija računa se samo između dva zrakoplova.

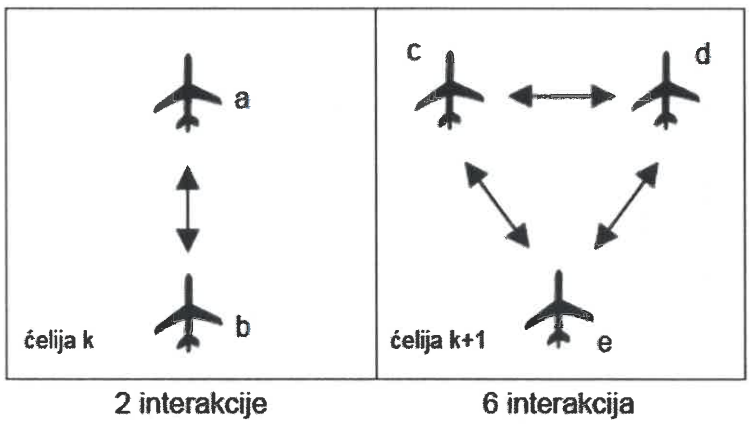

Slika 9. Prikaz interakcija
Izvor: [15]

Tijekom svih izračuna promatraju se samo potencijalne interakcije, a ne stvarne budući da cilj prikaza indikatora nije stvarni broj interakcija u danu već samo vjerojatnosti interakcija koje su moguće za zadani protok prometa. Jedino što je bitno i što se promatra je koliko dugo se svaki zrakoplov nalazi u ćeliji tijekom izabranog sata. K tome se uzima u obzir da je svaki zrakoplov možda prošao kroz tu ćeliju u bilo kojem trenutku tijekom tih sat vremena. Prema primjeru sa slike 9. vremena t_a i t_b predstavljaju duljinu trajanja boravka zrakoplova a i zrakoplova b u ćeliji tijekom sata. Očekivano trajanje (koje je izraženo u satima) interakcije između zrakoplova jednako je umnošku t_a i t_b. Ako na primjer svaki zrakoplov provede tri minute unutar ćelije (ili 1/20 sati kako bi se računalo u satima) trajanje interakcije bit će:

$$\left(\frac{1}{20} \times \frac{1}{20}\right) = \frac{1}{400} \text{ ili } 0.0025 \text{ sati}$$

Ako dva prikazana zrakoplova iz ćelije k provedu tri minute u ćeliji tada je očekivano trajanje interakcije (zrakoplova a sa zrakoplovom b i obrnuto) tijekom jednog sata:

$$2 \times \left(\frac{1}{20} \times \frac{1}{20}\right) = \frac{1}{200} \text{ ili } 0.005 \text{ sati}$$

Ako pretpostavimo da svaki zrakoplov u ćeliji k+1 također provede tri minute unutar ćelije, radi lakše usporedbe, onda je očekivano šest interakcija iz ćelije k+1:

$$6 \times \left(\frac{1}{20} \times \frac{1}{20}\right) = \frac{3}{200} \text{ ili } 0.015 \text{ sati}$$

Program NEST obavlja ove izračune za svaki par zrakoplova u ćeliji, potom zbroj trajanja interakcija daje sate potencijalnih interakcija za tu ćeliju. Kako bi se došlo do rezultata za ANSP ili ACC potrebno je sakupiti sve vrijednosti do te razine [15].

3.5. Prilagođena gustoća

Gustoća prometa je mjera količine prometa koji se nalazi unutar zadane jedinice volumena tijekom zadanog vremena. Ako je riječ o prilagođenoj gustoći onda je to još preciznija mjera od obične neprilagođene gustoće koja predstavlja omjer broja zrakoplova (ili sati leta) i zadanog volumena (bio to ANSP ili ACC). Gustoća prometa ne uzima u obzir ravnomjernost prometa ili njegovu zgusnutost na nekom dijelu kao kod najprometnijih sektora. Kod obične gustoće prometa nije moguće iščitati ni vrhunce u danu (peak periods). Prilagođena gustoća definira se kao omjer između sati interakcija i sati leta:

$$\textbf{Adjusted density (Prilagođena gustoća)} = \frac{\textbf{Hours of interactions (Sati interakcija)}}{\textbf{Flight hours (Sati leta)}} \qquad (1)$$

Sati interakcije dobiju se zbrajanjem trajanja svih interakcija u svim ćelijama koje su vezane za traženi ANSP ili ACC. Taj zbroj potom se dijeli ukupnim brojem sati leta unutar određenog prostora i pritom se dolazi do indikatora za prilagođenu gustoću. U Europi taj broj iznosi oko 0.11 sati interakcija po satu leta [15].

Na rezultat koji se dobije može se gledati i skraćeno kao na interakcije po letu budući da ta vrijednost predstavlja prosječan broj zrakoplova u interakciji, odnosno broj zrakoplova koji su prisutni u istoj ćeliji, na koje let koji prolazi odabranim zračnim prostorom može naići. Gustoću nazivamo „prilagođenom“ jer ćelije bez letova ne doprinose izračunu (ne sadrže ni interakcije niti sate leta). Ako postoji ćelija sa samo jednim letom, ona ne sadrži interakcije

ali doprinosi satima leta. Na ovaj način bolje je prikazan raspored zrakoplova u krajnjem izračunu [15].

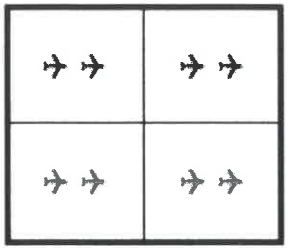

Centar 1

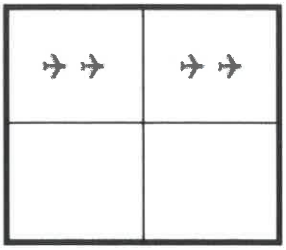

Centar 2

2+2+2+2=8	**Broj interakcija**	2+2=4
Prilagođena gustoća = sati interakcija / sati leta		
$8 \times \frac{1}{400} = 0.02$	**Sati interakcija**	$4 \times \frac{1}{400} = 0.01$
$8 \times \frac{1}{20} = 0.4$	**Sati leta**	$4 \times \frac{1}{20} = 0.2$
$\frac{0.02}{0.4} = 0.05$	**Prilagođena gustoća**	$\frac{0.01}{0.2} = 0.05$

Slika 10. Indikator prilagođene gustoće
Izvor: [15]

Na slici 10. nalazi se primjer izračuna prilagođene gustoće za dva različita slučaja. U drugom slučaju na desnoj strani slike broj zrakoplova je upola manji od onoga u prvom slučaju, stoga je i gustoća upola manja. Prilagođena gustoća je pak jednaka za oba slučaja što dokazuje koliko se točniji rezultati mogu dobiti kada se koristi prilagođena gustoća. Prilagođena gustoća u biti opisuje gustoću koju doživljava zrakoplov čime se i dobivaju točniji rezultati vezani za kompleksnost [15].

3.6. Vertikalne interakcije

Indikator za vertikalno različite protoke u interakciji (Vertical Different Interacting Flows - VDIF) mjera je kompleksnosti koja se pojavljuje kada dođe do interakcije letova u različitim fazama leta. Izražava se kao trajanje potencijalne vertikalne interakcije (u satima) po satu leta. Dva zrakoplova su u vertikalnoj interakciji ako se istovremeno nalaze u istoj ćeliji i imaju različite stavove (penjanje, krstarenje i/ili spuštanje). Stav zrakoplova koji se

uzima u obzir za izračun definira se u trenutku u kojem ulazi u ćeliju. Let je u krstarenju ako mu je stopa penjanja ili spuštanja manja od 500 ft/min [15].

Na slici 11. prikazan je prethodno opisan koncept vertikalnih interakcija. U ćeliji su prikazana četiri zrakoplova od kojih su dva u penjanju, jedan je u krstarenju i jedan u spuštanju. Svaki zrakoplov koji je u penjanju u interakciji je s još dva zrakoplova (onim u krstarenju i spuštanju, ali ne i drugim u penjanju). Zrakoplov u krstarenju je u interakciji s tri zrakoplova (dva u penjanju i jedan u spuštanju), a ista logika primjenjuje se i na zrakoplov u spuštanju. Kada su zrakoplovi u istom stavu onda nisu u interakciji.

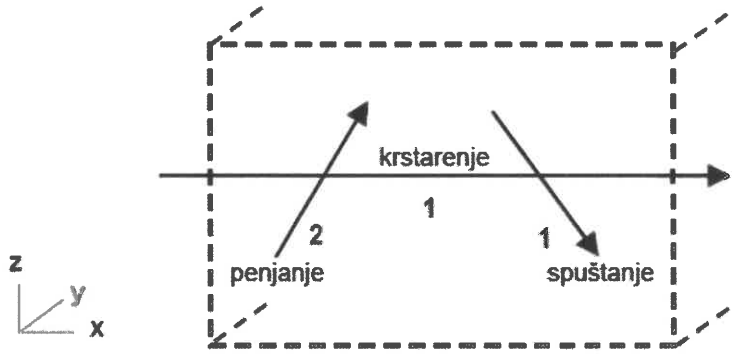

Vertikalne interakcije = (2 x 2) + (1 x 3) + (1 x 3) = 10

Slika 11. Potencijalne vertikalne interakcije
Izvor: [15]

U primjeru sa slike 11. broj interakcija je 10. Ove interakcije su samo potencijalne jer je moguće da su zrakoplovi možda bili prisutni u ćeliji u različitim vremenima čime ne bi došlo do interakcije. Kao što je i prethodno napomenuto, indikator ne teži izračunu pravog broja interakcija koje su se dogodile na određeni dan nego vjerojatnosti da će do interakcija koje proizlaze iz prometnih tokova doći. Ako ponovno računamo da je svaki zrakoplov ostao u ćeliji tri minute (1/20 sata) tada je očekivano trajanje svake interakcije 1/400 sata (1/20 x 1/20). Ukupno očekivano trajanje vertikalnih interakcija onda je:

$$10 \times \frac{1}{400} = 0.025 \text{ sati}$$

VDIF indikator dobiva se zbrajanjem očekivanih trajanja svih potencijalnih interakcija u svim ćelijama vezanima za odabrani ANSP/ACC. Taj broj potom se dijeli s ukupnim brojem sati leta unutar ANSP/ACC.

$$\text{VDIF} = \frac{\text{Hours of vertical interactions (Sati vertikalnih interakcija)}}{\text{Flight hours (Sati leta)}} \qquad (2)$$

Ta vrijednost u europskom sustavu je otprilike 0.03 sata vertikalnih interakcija po satu leta [15].

3.7. Horizontalne interakcije

Horizontalno različiti protoci u interakciji (Horizontal Different Interacting Flows - HDIF) mjera je kompleksnosti koja se pojavljuje interakcijom letova koji imaju različite pravce kretanja. HDIF je izražen kao trajanje potencijalne horizontalne interakcije (u satima) po satu leta. Definira se kao istovremena prisutnost dva zrakoplova različitih *headinga* u ćeliji. *Heading* koji se koristi u izračunu je onaj kojim je zrakoplov letio prilikom ulaska u ćeliju. Jednu interakciju podrazumijeva razlika *headinga* između dva zrakoplova koja je veća od 20°. Na slici 12. nalazi se pet zrakoplova i svi su ušli u ćeliju tijekom jednog sata. Gledaju se samo *headinzi* između zrakoplova kako bi se vidjelo jesu li manji ili veći od 20° jer stavovi i visine zrakoplova nisu bitni za ovaj indikator.

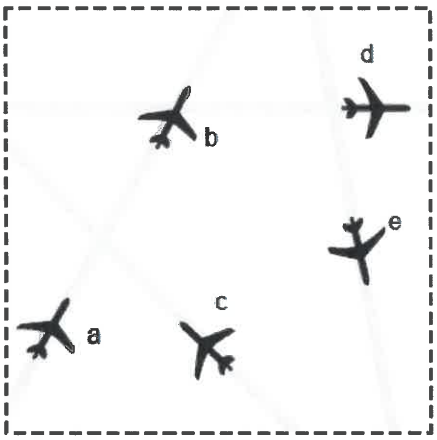

Slika 12. Potencijalne horizontalne interakcije, [15]

Kut između zrakoplova a i pravca kretanja zrakoplova b manji je od 20° stoga tu nema nikakve interakcije. Kut između zrakoplova a i zrakoplova b je pak veći od 20° pa je to jedna potencijalna interakcija. Potencijalnih interakcija ima i između zrakoplova a i zrakoplova d kao i zrakoplova a i zrakoplova e. Samo zrakoplov a ima tri potencijalne interakcije, a kada se odredi broj potencijalnih interakcija za svaki zrakoplov tada dolazimo do ukupno 18 interakcija na primjeru sa slike 12. [15].

Kao i sa VDIF indikatorom i kod HDIF indikatora potrebno je uzeti u obzir očekivano trajanje interakcija. Ukoliko pomnožimo broj interakcija u ćeliji sa slike 12. i očekivano trajanje interakcija iz početnog primjera sa satima interakcije dolazimo do:

$$18 \times \frac{1}{400} = 0.045 \text{ sati}$$

HDIF indikator definira se kao:

$$\text{HDIF} = \frac{\text{Hours of horizontal interactions (Sati horizontalnih interakcija)}}{\text{Flight hours (Sati leta)}} \qquad (3)$$

Očekivano trajanje svih potencijalnih horizontalnih interakcija u svim ćelijama vezanim za ANSP/ACC zbraja se te se taj zbroj potom dijeli s ukupnim brojem sati leta unutar tog područja i tako dolazimo do vrijednosti HDIF indikatora. U Europi taj broj je na otprilike 0.05 sati horizontalnih interakcija po satu leta [15].

3.8. Interakcije brzine

Protoci u interakciji zbog različitih brzina (Speed Different Interacting Flows - SDIF) mjera je kompleksnosti između zrakoplova s različitim brzinama te se izražava u trajanju potencijalnih interakcija brzine (u satima) po satu leta. Da bi interakcija brzine postojala razlika u brzini između para zrakoplova mora biti veća od 35 čvorova, inače se to ne klasificira interakcijom. Za brzinu u izračunima potrebni su podaci za brzinu leta za određeni tip zrakoplova na toj visini, a za to je potrebna BADA (Base of Aircraft Data - BADA) u kojoj se takvi podaci nalaze. Za određivanje brzine prema visini na kojoj se nalazi taj tip zrakoplova gleda se samo ona visina zrakoplova u trenutku kada se zrakoplov nalazi u središtu ćelije radi pojednostavljivanja. Slična logika koja se primjenjuje kod određivanja horizontalnih interakcija primjenjiva je i za SDIF proces, samo se ovdje gleda je li brzina između zrakoplova veća ili manja od 35 čvorova, odnosno smatra li se potencijalnom interakcijom ili ne.

$$\mathrm{SDIF} = \frac{\text{Hours of speed interactions (Sati interakcija brzine)}}{\text{Flight hours (Sati leta)}} \qquad (4)$$

Za europski sustav SDIF vrijednost je oko 0.03 sata interakcije brzine po satu leta [15].

3.9. Rezultat kompleksnosti

Kompleksnost je moguće prikazati samo jednim brojem koji bi predstavljao rezultat kompleksnosti, ali najbolje je prikazati i individualne indikatore radi boljeg razumijevanja situacije u određenom ANSP ili ACC zračnom prostoru budući da dva različita mogu imati veoma sličnu kompleksnost. Kada se podrobnije pregledaju svi rezultati i svi indikatori onda se može na primjer primijetiti kako je kod jednoga na rezultat kompleksnosti uvelike utjecala struktura prometnih tokova (DIF indikatori) dok je na drugi utjecao većinom volumen prometa (prilagođena gustoća) [15].

Svi DIF indikatori usko su povezani s prilagođenom gustoćom i to zato što su vertikalne, horizontalne i interakcije brzine takoreći dijelovi prilagođene gustoće jer ona sadrži sve interakcije. Korelacije s prilagođenom gustoćom mogu se ukloniti ukoliko se koriste relativni indikatori (r_VDIF, r_HDIF i r_SDIF) koji se dobivaju dijeljenjem indikatora interakcije za svaki ANSP/ACC s pripadajućom prilagođenom gustoćom:

$$r_VDIF = \frac{VDIF}{\text{Adjusted density (Prilagođena gustoća)}} \quad (5)$$

$$r_HDIF = \frac{HDIF}{\text{Adjusted density (Prilagođena gustoća)}} \quad (6)$$

$$r_SDIF = \frac{SDIF}{\text{Adjusted density (Prilagođena gustoća)}} \quad (7)$$

Vrijednosti dobivene ovim formulama mogu se interpretirati i kao postotak interakcija koje su vertikalne, horizontalne ili zbog razlike u brzini. Jedna interakcija prilagođene gustoće može pripadati i vertikalnim, horizontalnim i kategorijama brzine ovisno o stavovima, visinama i brzinama zrakoplova. Zbog tog razloga zbroj postotaka nije 100% već bi maksimalan zbroj bio 300% kad bi svaka interakcija zadovoljila sve kriterije [15].

3.10. Strukturalni indeks

Dvije stvari utječu na rezultat kompleksnosti: struktura prometnih tokova i prometni volumen. Kada se koriste r_DIF indikatori tada se ta dva pojma mogu razdvojiti. Prilagođena gustoća odražava prometni volumen, a strukturalni indeks predstavlja strukturu prometnih tokova:

$$\text{Strukturalni indeks} = r_VDIF + r_HDIF + r_SDIF \quad (8)$$

Oba aspekta utječu na sveukupnu kompleksnost pa se mogu zajedno prikazati u sklopu rezultata kompleksnosti:

$$\text{Rezultat kompleksnosti} = \text{Prilagođena gustoća} \times \text{Strukturalni indeks} \quad (9)$$

U Europi ova vrijednost rezultata kompleksnosti je oko 0.10 [15].

Dodavanje određene težine svakom indikatoru na temelju njegove važnosti bi možda dalo relevantnije rezultate kompleksnosti ali budući da nije primjenjivo za svaki zračni prostor, ipak nije implementirano. Čak se usporedbom indikatora koji su dobili na težini i običnih rezultata došlo do veoma sličnih rezultata. Postojala je i ideja normalizacije indikatora kako bi rezultat svakog indikatora bio normaliziran s relevantnim vrijednosnim sustavom radi jednostavne usporedbe ANSP/ACC zračnih prostora. Na primjer, ANSP s vrijednošću od 1 bi bio prosječan, onaj s vrijednošću 1.5 bi bio 50% kompleksniji i tako dalje. Ovaj sustav nažalost nije trenutno u uporabi jer bi se za njega trebao koristiti isti vrijednosni sustav i to svake godine kako bi se i rezultati mogli uspoređivati iz godine u godinu što trenutno nije izvedivo [15].

3.11. Indikatori kompleksnosti

Iz studije [10] su proizašla četiri glavna indikatora kompleksnosti prikazana na slici 13.

Dimenzija kompleksnosti	Indikator	Opis
Gustoća prometa	Prilagođena gustoća	Mjera potencijalnog broja interakcija između zrakoplova u zadanom volumenu zračnog prostora.
Promet u evoluciji	Potencijalne vertikalne interakcije (VDIF)	Potencijalne interakcije zrakoplova u penjanju, krstarenju i spuštanju.
Struktura protoka	Potencijalne horizontalne interakcije (HDIF)	Mjera potencijalnih interakcija temeljena na pravcima kretanja zrakoplova.
Mješavina prometa	Potencijalne interakcije brzine (SDIF)	Potencijalne interakcije temeljene na brzinama zrakoplova.

Slika 13. Indikatori kompleksnosti
Izvor: [15]

Prikazani indikatori pružaju konzistentne rezultate kada se za definiciju interakcije uzima istovremena prisutnost dva zrakoplova u ćeliji obujma 20x20 NM i 3000 ft u visinu. Iz pojma interakcije proizlazi činjenica da je prisutnost nekoliko zrakoplova na istom području u isto vrijeme ono što čini kompleksnost, pogotovo ako su ti zrakoplovi u različitim fazama leta, imaju različite pravce kretanja i/ili različite performanse. Imajući na umu širi pogled na situaciju, indikatori nisu fokusirani na stvarne interakcije zrakoplova već na one potencijalne između protoka zrakoplova. To se postiže uzimajući potencijalne interakcije u razdoblju od jednog sata [15].

3.12. Program NEST

NEST je simulacijski alat koji je razvijen radi planiranja kapaciteta mreže i dizajna zračnog prostora te je nastao spajanjem dvaju alata – SAAM (System for traffic Assignment and Analysis at a Macroscopic level - SAAM) i NEVAC (The Network Estimation & Visualisation of ACC Capacity - NEVAC). Temelji se na modeliranju scenarija kojeg koriste Network Manager, ANSP više država i ostali za razne aktivnosti poput: dizajniranja strukture zračnog prostora, planiranja kapaciteta, analiza operacija, organiziranja prometnog protoka, pripremanja scenarija i *ad-hoc* studija [16].

3.12.1. Kompleksnost u NEST programu

Kako bi se dobila kompleksnost, NEST generira sažetke vrijednosti za izabrani ACC, sektor ili volumen prometa (Traffic Volume - TV). Vrijednosti kompleksnosti mogu se dobiti za bilo koji tip putanje i za bilo koju filtriranu listu letova ukoliko se koriste opcije:

- "Traffic Type" (tip prometa),
- "Traffic Filter" (prometni filter).

Vrsta kompleksnosti bira se opcijom "Indicator" (indikator) dok se biranjem opcije "all" (sve) generiraju vrijednosti za sve dostupne indikatore:

- prosječna udaljenost preleta po letu,
- prosječno vrijeme preleta po letu,
- prosječan broj promjene visine (Flight level - FL) po letu,
- postotak letova u penjanju, krstarenju i spuštanju,
- postotak lakih, srednjih i teških letova,
- prosječan broj ulazaka po satu.

Zadano razdoblje promatranja u NEST programu je cijeli dan, ukoliko se radi o statistici vezanoj za kompleksnost, no može se izmijeniti ručno korištenjem opcija "Start" i "End" (početak i kraj) [17].

Prosječne vrijednosti kompleksnosti računaju se tijekom cijelog razdoblja promatranja te se u završnoj tablici dodaju stupcima sažetaka. Stupci sažetaka temelje se ili na prosjecima letova ili vremena. Zadani raspon visina za kompleksnost postavljen je od 0 do 999. Ovaj raspon se isto može postaviti ručno koristeći opcije za minimalnu i maksimalnu visinu. Odabrani raspon visina određuje listu letova koji ulaze u izračun indikatora kompleksnosti. Indikatori kompleksnosti mogu se generirati i na temelju konfiguracije sheme otvaranja izabranog ACC prostora ukoliko se postavi opcija "All Open Sectors" (svi otvoreni sektori). U tom slučaju indikatori se računaju za sve sektore koji su bili otvoreni u ACC prostoru na taj datum. Razdoblje izračuna kompleksnosti temelji se na razdoblju promatranja koje je definirano "Start" i "End" opcijama ali i stvarnih vremena otvaranja definiranih shemom otvaranja izabranog ACC prostora [17].

3.12.2. Sadržaj datoteke s rezultatima

Završni izračuni programa za traženi dan spremaju se u obliku excel datoteke te su rezultati (indikatori kompleksnosti) grupirani po ACC prostorima i visinama (FL). Indikatori kompleksnosti za zadani ACC dostupni su za svaki FL s korakom od 10 te započinju s prosječnim visinom na kojem je došlo do interakcije letova unutar ACC prostora (to je najčešće FL100).

Excel datoteka s indikatorima sadrži sljedeće stupce:

- **UNIT_CODE** – ID (identifikacija) ACC prostora
- **FL** - Flight Level
- **TIME** - Vrijeme u danu (samo za računanja po satu)

- **FT** - Sati leta
- **FD** - Udaljenost letova u ćeliji
- **DH** - Vertikalna udaljenost u ćeliji
- **TX** - Sati interakcija
- **TXH** - Sati horizontalnih interakcija
- **TXV** - Sati vertikalnih interakcija
- **TXS** - Sati interakcija brzine
- **N** - Broj sakupljenih (obrađenih) letova
- **NCELL** - Ukupan broj aktivnih ćelija podijeljen s ukupnim brojem pomaknute mreže [17].

3.12.3. Završni indikatori kompleksnosti

Završne indikatore kompleksnosti (prilagođena gustoća, RVdif, RHdif i ostali) ne računa algoritam već osoba koja traži podatke pomoću ručne operacije. Prednost ovakvog načina dolaska do krajnjeg rezultata je sloboda izbora korisnika koji može izabrati onu količinu podataka koju želi uzeti u obzir u krajnjem rezultatu i koja je njemu relevantna. Formule potrebne za izračun završnih indikatora kompleksnosti su sljedeće:

$$\text{Prilagođena gustoća} = \frac{\text{suma(TX)}}{\text{suma(FT)}} \qquad (10)$$

$$\text{RVdif} = \frac{\text{suma(TXV)}}{\text{suma(TX)}} \qquad (11)$$

$$\text{RHdif} = \frac{\text{suma(TXH)}}{\text{suma(TX)}} \qquad (12)$$

$$\text{RSdif} = \frac{\text{suma(TXS)}}{\text{suma(TX)}} \qquad (13)$$

$$\text{Strukturalni indeks} = \frac{\text{suma(TXV+TXH+TXS)}}{\text{suma(TX)}} \qquad (14)$$

$$\text{Kompleksnost} = \frac{\text{suma(TXV+THX+TXS)}}{\text{suma(FT)}} \qquad (15)$$

Rezultati dobiveni pomoću ovog modula mogu neznatno odstupati i vjerojatno će odstupati od službenih rezultata. Iako je algoritam identičan ulazni podaci su najvjerojatnije malo drugačiji. Službena PRU jedinica (Performance Review Unit - PRU) ima svoj zračni promet, zračni prostor i BADA bazu podataka te se njihovi službeni rezultati izražavaju u minutama interakcije po kompleksnom satu leta. Vrijednosti kompleksnosti izračunate pomoću gore navedenih formula izražene su u satima interakcija po kompleksnom satu leta i stoga da se dobiju službeni rezultati potrebno ih je pomnožiti s brojem 60 [17].

3.12.4. Računanje kompleksnosti

Prilikom pokretanja algoritma PRU kompleksnosti sa zadanim uzorkom prometa dolazi se do više indikatora kompleksnosti koji se kasnije mogu primijeniti u raznim analizama. Kako bi se došlo do indikatora potrebno je u prozor PRU kompleksnosti učitati datoteku s prometom kao i datoteke o zračnom prostoru (ACC). Nakon pokretanja izračuna pritiskom na tipku "Run" (pokreni) program će nakon izvjesnog vremena izbaciti izvješće koje sadrži indikatore kompleksnosti u obliku excel tablice [17].

Općenita procedura koja je potrebna za jedan takav izvještaj kreće sa specifikacijom datoteke koja sadrži ulazne podatke o prometu. Nakon toga je bitno provjeriti datum koji bi trebao odgovarati već izabranoj datoteci s prometom. Potom je potrebno još ubaciti i datoteke koje sadrže sektore od interesa (poželjno je prvo se pozabaviti stvaranjem scenarija s izabranim tokovima i zračnim blokovima bitnim za izračun). Na kraju se još mogu promijeniti zadani parametri ukoliko je potrebno, odnosno bitno za izračun [17].

3.12.5. Parametri

U nastavku se nalazi popis parametara koji se mogu birati i mijenjati po volji za izračun indikatora kompleksnosti.

- **Traffic frame** – Pretraživanje datoteka sa zračnim prometom
- **Date drop-down list** – Biranje datuma koji će se obrađivati unutar datoteke sa zračnim prometom; dostupni izbori pojavljuju se tek kada se odabere datoteka sa zračnim prometom
- **Airblocks frame** – Pretraživanje datoteka sa zračnim blokovima
- **Sectors frame** – Pretraživanje datoteka sa sektorima
- **Centers frame** – Pretraživanje datoteka sa zračnim prostorom koji sadrži i ACC prostore
- **Generate the results per hours checkbox** – Razdioba rezultata po satima
- **Custom INI file frame** – Pretraživanje datoteka kod napredne postavke; ukoliko nije odabrana niti jedna datoteka, klikom na opciju "new" (novo) kreira se konfiguracijska datoteka sa zadanim parametrima
- **Complexity indicators frame** – Biranje imena i lokacije izlazne excel datoteke [17].

Spomenuti parametri su i prikazani na slici 14.

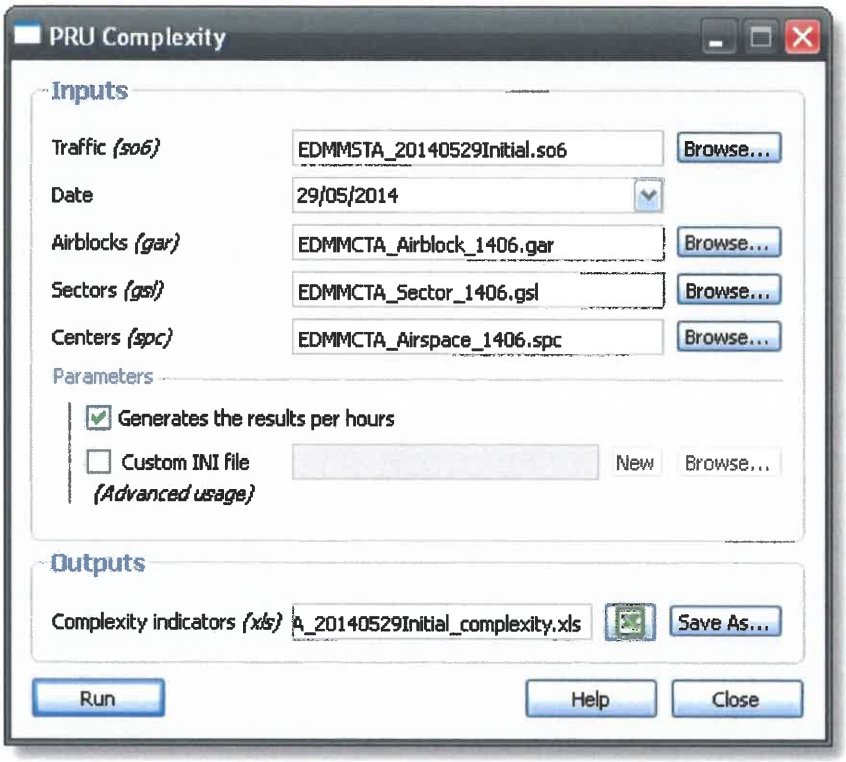

Slika 14. PRU kompleksnost – parametri, [17]

3.12.6. Zadana mreža

Izračun kompleksnosti uvijek se provodi na mreži koja pokriva Europu na visini između FL85 i FL415. Njene 4D ćelije su, kao što je već spomenuto, veličine 20 NM, visine FL30 i trajanja od 1 h. Prema zadanim parametrima promet ispod FL85 neće biti uzet u obzir prilikom izračuna. Algoritam računa na više mreža koje su pomaknute za malu vrijednost na svim osima (osim vremena) kako bi se smanjio utjecaj granica. Tih mreža ima 12: dvije na x-osi, dvije na y-osi i tri na vertikalnoj osi [17].

4. Metodologija određivanja radnog opterećenja sektora kontrole zračnog prometa koju primjenjuje program NEST

Radno opterećenje obično se definira kao fizički ili mentalni napor usmjeren na ostvarivanje nečega ili kao količina posla dodijeljenog pojedincu za izvršavanje unutar određenog roka. U kontroli zračnog prometa radno opterećenje kontrolora je izuzetno važna tema te je oko njega već izrađeno mnoštvo studija, izvještaja i osvrta [18]. Radno opterećenje kontrolora glavni je čimbenik određivanja kapaciteta sektora u kontroli zračnog prometa. Na slici 15. prikazani su neki aspekti radnoga opterećenja kontrolora.

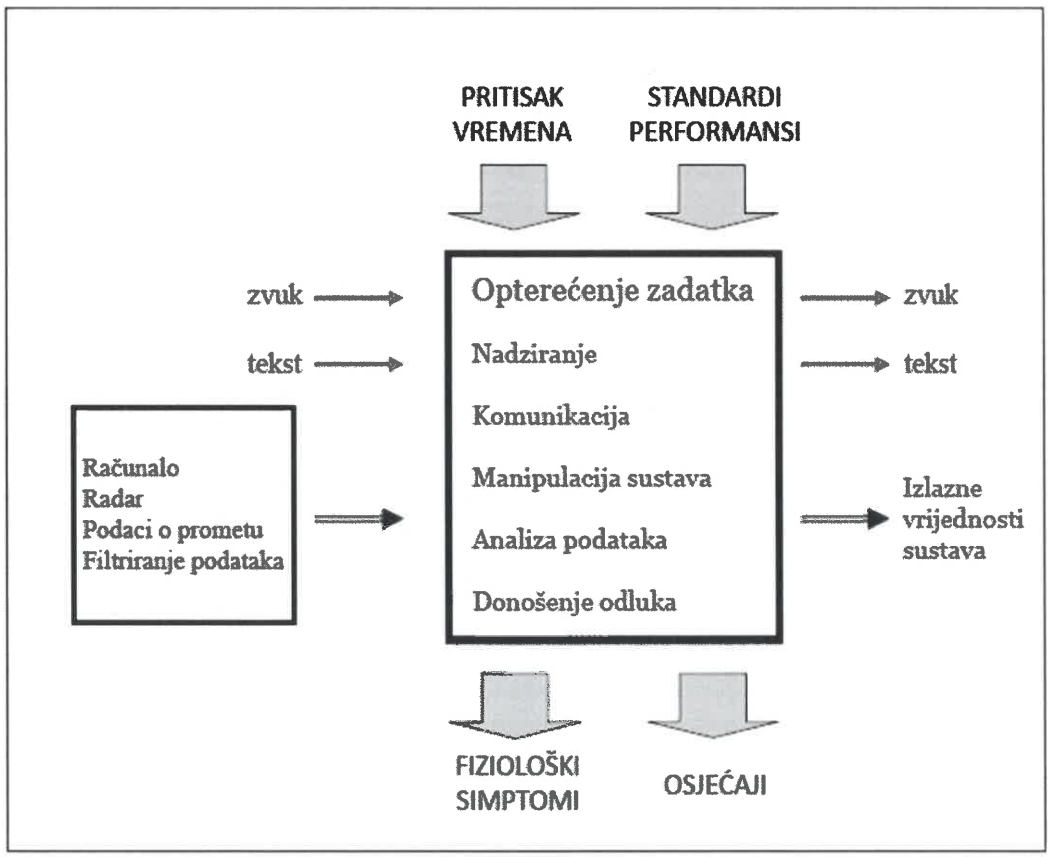

Slika 15. Aspekti radnog opterećenja kontrolora
Izvor: [18]

Kontrola zračnog prometa je veoma kompleksan sustav ljudi i strojeva koji se isprepliću kroz strukture i procese. Kontrolore zapošljava organizacija koja mora funkcionirati unutar industrijskog okvira koji se razvija, te se upoznavanje s promjenama u sustavu mora pregovarati, a ne nametnuti [18].

Kada je riječ o radnom opterećenju potrebno ga je razložiti na komponente kako bi se razumjelo koje radnje mogu utjecati na poboljšanje performansi. Jedan način na koji je to moguće razložiti jest na dizajn, osposobljavanje i same operacije. Radno opterećenje je samo jedan element u situaciji koja utječe na performanse i na mogućnost pogrešaka. Imajući sigurnost na umu, svima je u interesu minimizirati pogreške i osigurati da se one koje se dogode mogu prepoznati i riješiti. Na slici 16. prikazano je radno opterećenje i način na koji se mijenja prilikom raznih grešaka. Linija predstavlja način na koji se radno opterećenje pomiče od niskog do visokog. Postoje mnogi faktori koji definiraju točku na spomenutoj liniji na kojoj će se radno opterećenje zadržati u jednom trenutku. Ta se točka mijenja zajedno s promjenom zadataka i situacije. Dvije uspravne linije prikazuju prag radnog opterećenja koji se ne bi trebao prijeći jer se kod njega vjerojatnost pogreške povećava. Postoji pogreška i na pragu kada je radno opterećenje prenisko i kada je previsoko. Kada trenutna razina radnog opterećenja prijeđe bilo koju liniju praga, vjerojatnost pogreške je puno veća. Izazov u preciznom određivanju radnog opterećenja je taj da se sve linije pomiču: radno opterećenje se pomiče gore i dolje, dok se pragovi pomiču na temelju određenih faktora [19].

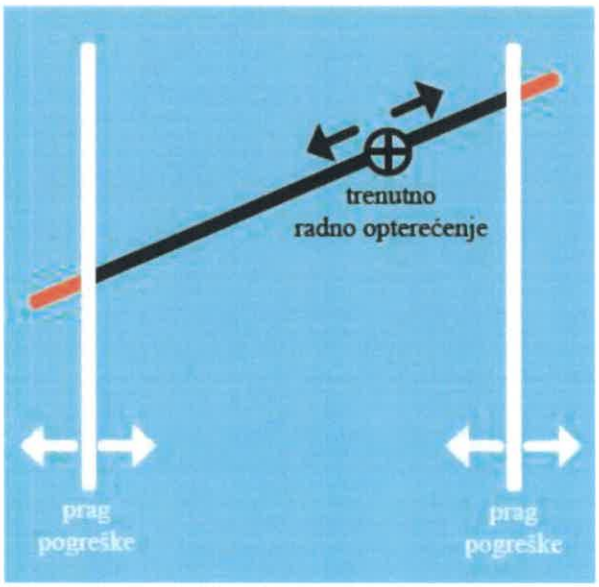

Slika 16. Oscilacije radnog opterećenja
Izvor: [19]

Trenutna točka radnog opterećenja određuje se kombinacijom više faktora, neki od njih su:

- Ostvareni zadaci
- Dizajn sustava i opreme
- Procesi i procedure
- Situacija i okolina [19].

Zadaci: neki zadaci su teži za ostvarivanje od drugih jer zahtjevaju više mentalnih ili fizičkih resursa što povećava radno opterećenje u trenutku njihovog ostvarivanja. Ti zadaci dakako nisu nezavisni i nepovezani [19].

Dizajn sustava i opreme: na radno opterećenje utječe i dizajn sustava kao i oprema koja se koristi u obavljanju zadataka. Ukoliko je dizajn loš i potrebno je puno vremena da ga se razumije da bi se sustav uopće upotrebljavao, to znatno utječe na trenutno radno opterećenje i povećava ga. Na radno opterećenje utječe sve, od sustava i njegovog zaslona, načina kontroliranja sustava do opreme koja se koristi. Ukoliko sve navedeno znatno utječe na radno opterećenje to može dovesti do kritičnih pogrešaka u obavljanju zadataka. Razumijevanje ljudskih faktora u dizajnu uspjelo je poboljšati ga te smanjiti potencijal pogrešaka izazvanih lošim dizajnom [19].

Procesi i procedure: dostupnost i dizajn bilo kojih procesa ili procedura također utječe na radno opterećenje budući da su performanse u hitnoj situaciji puno bolje ako postoji prikladna *checklista* za tu situaciju. Kada je ta *checklista* potrebna, trud uložen u njeno pronalaženje, razumijevanje i korištenje utjecat će na trenutno radno opterećenje [19].

Situacija i okolina: kao i svi prethodno nabrojani faktori, i situacija u kojoj se zadatak mora obaviti utjecat će na radno opterećenje. Neke od karakteristika situacije koja utječe na razinu radnog opterećenja uključuju hitnost, konkurentne zadatke, vrijeme dana, osvjetljenje u prostoriji, buku te dostupnost kolega koji mogu pomoći [19].

Svaki od navedenih faktora varira tijekom radnog vremena što uzrokuje variranja radnog opterećenja (gore dolje) kada se bilo koji od četiri pojavi u određenom trenutku [19].

Prema navedenom može se zaključiti da je radno opterećenje subjektivna veličina, no može se aproksimirati modelima.

4.1. Temeljna formula za radno opterećenje

Postoji više modela i metoda za određivanje radnog opterećenja, na jednoj od njih se i temelji izračun u programu NEST. Najpoznatija metoda za izračun radnog opterećenja je CAPAN (ATC Capacity Analyser tool - CAPAN) razvijena od EUROCONTROL-a. Budući da se način određivanja radnog opterećenja u NEST-u temelji na simplificiranoj CAPAN metodi, najprije je potrebno objasniti tu simplificiranu formulu.

CAPAN je metodologija dobivanja radnog opterećenja koja koristi simulacije i matematičke modele kako bi mjerila radno opterećenje i definirala kapacitet. Ima veliki nedostatak, a to je njegov kompleksan i dugačak proces budući da je sama priprema za proces veoma zahtjevna. CAPAN koristi čak dvije vrijednosti kapaciteta dobivene dvjema različitim metodama, oslanja se na procjenu radnog opterećenja kontrolora i potrebno joj je

nekoliko iteracija kako bi došla do konačnog rezultata. Te dvije vrijednosti kapaciteta su često prilično različite stoga je razvijeno poboljšanje ove metode, odnosno pesimistična metoda [20].

Kontrolori moraju primarno paziti na sigurnost prometa, njihova je zadaća da predvide sve moguće situacije i pobrinuti se da se one nepoželjne ne dogode. Kako bi se koristila pojednostavljena formula, ATC zadaci dijele se na tri kategorije:

- rutinski zadaci
- zadaci nadgledanja promjene visine
- zadaci nadgledanja konflikata [20].

Za svaki je zadatak potrebno znati trajanje zadatka (u sekundama) i broj zadataka (rutinskih, konfliktnih, penjanja ili spuštanja), te dobivamo formulu:

$$WL = t_{Fl} \times O_{Fl} + t_{Cnf} \times O_{Cnf} + t_{Cl} \times O_{Cl} \quad (16)$$

WL – radno opterećenje
O_{Fl} – rutinski zadaci
O_{Cnf} – zadaci penjanja/spuštanja
O_{Cl} – zadaci konflikata
t_{Fl} – trajanje rutinskih zadataka
t_{Cnf} – trajanje zadataka penjanja/spuštanja
t_{Cl} – trajanje zadataka konflikata [20].

4.2. Makroskopska formula za radno opterećenje

Svrha makroskopske formule za radno opterećenje sektora je ta da izračunava procjenu radnog opterećenja i pruža prikaz krivulje radnog opterećenja. Do radnog opterećenja dolazi se preko jednostavne formule:

$$\begin{aligned}\text{Workload(Radno opterećenje)} &= \text{Hourly Entry Rate(Stopa ulazaka po satu)} \times 1 + \\ &+ \text{Average Time spent in Sector(Prosječno vrijeme provedeno u sektoru)} \times 2 + \\ &+ \text{Number of potential conflicts detected in the sector(Broj potencijalnih konflikata)} \times 2\end{aligned} \quad (17)$$

Ova formula procjenjuje rad kontrolora temeljen na broju kontroliranih zrakoplova (Entry rate), zadatku nadgledanja (Average time spent in the sector) i zadataka rješavanja konflikata (Number of potential conflicts) [17]. Preuzeta je iz aplikacije SAAM koji je preteča aplikacije NEST. SAAM metodologija temelji se na izračunu koji dijeli radno opterećenje na spomenuta tri parametra: kliznu stopu ulazaka po satu (Sliding Hourly Entry Rate – SHER), prosječno

vrijeme provedeno u sektoru izraženo u minutama i broj konflikata. Svakom od parametara pridružena je prikladna konstanta dobivena iz simulacija (k_1=1, k_2=2, k_3=2) [21].

Budući da je radno opterećenje usko povezano s kompleksnošću, a time i njegov izračun, većina karakteristika opisana je u prethodnom poglavlju zajedno s kompleksnošću. Jedino je još bitno napomenuti koji su točno pragovi radnog opterećenja kako bi se lakše razumjeli grafikoni u sljedećem poglavlju. U tablici 1. prikazani su pragovi radnog opterećenja i kojem vremenskom periodu rada odgovaraju. Prag radnog opterećenja predstavlja postotak vremena provedenog radeći na ATC zadacima tijekom jednog sata.

Tablica 1. Pragovi radnog opterećenja

PRAG RADNOG OPTEREĆENJA	TUMAČENJE	VRIJEME RADA NA ATC ZADACIMA TIJEKOM JEDNOG SATA
70% ili iznad	preopterećenje	42 minute +
54% - 69%	teško opterećenje	32 – 41 minuta
30% - 53%	srednje opterećenje	18 – 31 minuta
18% - 29%	lagano preopterećenje	11 – 17 minuta
0% - 17%	veoma lagano opterećenje	0 – 10 minuta

Izvor: [20]

5. Određivanje indikatora kompleksnosti sektora oblasne kontrole Zagreb za zadani uzorak prometa

Kao uzorci prometa koji će se obrađivati u ovom poglavlju izabrani su najreprezentativniji vikendi mjeseca siječnja, travnja, srpnja i kolovoza 2017. godine. Tijekom izabranog vikenda u siječnju kroz zračni prostor Hrvatske, odnosno kroz LDZOCTA (LDZO Control Area - LDZOCTA), prošlo je 2838 letova, u travnju 4189, srpnju 6930, te u kolovozu 7085. Izračuni kompleksnosti odrađeni su za ukupno 12 datuma, svaki zasebno od 0 do 24 h, i od FL85 do FL415.

5.1. Siječanj

U tablici 2. prikazani su rezultati izračuna PRU kompleksnosti od strane programa NEST. Kao što je već spomenuto, kratice redom označavaju sate leta, sate interakcija, sate horizontalnih interakcija, sate vertikalnih interakcija i sate interakcija brzine.

Tablica 2. Prikaz rezultata za vikend u siječnju

DATUM	FT	TX	TXH	TXV	TXS
27.01.2017.	4055.59	319.95	194.08	22.30	89.94
28.01.2017.	4080.36	331.77	215.73	18.08	99.21
29.01.2017.	4345.38	412.31	262.23	26.62	102.34

Nakon uvrštavanja dobivenih sumiranih podataka u odgovarajuće formule dobivaju se željeni indikatori prikazani u tablici 3.

Tablica 3. Indikatori kompleksnosti za vikend u siječnju

	27.01	*28.01.*	*29.01.*
Prilagođena gustoća	0.0789	0.0813	0.0949
VDIF	0.0055	0.0044	0.0061
HDIF	0.0479	0.0529	0.0603
SDIF	0.0222	0.0243	0.0236
r_VDIF	0.0697	0.0545	0.0646
r_HDIF	0.6066	0.6502	0.636
r_SDIF	0.2811	0.299	0.2482
Strukturalni indeks	0.9574	1.0038	0.9488
Rezultat kompleksnosti	0.0755	0.0816	0.09
Konačni rezultat kompleksnosti	4.53	4.9	5.4

5.2. Travanj

U tablici 4. nalaze se sumirani rezultati dobivenih vrijednosti za odabrani vikend u travnju gdje je već primjetan porast prometa. Tablica 5. prikazuje indikatore dobivene uvrštavanjem u već spomenute formule iz 3. poglavlja koje odgovaraju rezultatima iz programa NEST.

Tablica 4. Prikaz rezultata za vikend u travnju

DATUM	FT	TX	TXH	TXV	TXS
14.04.2017.	5659.82	632.00	403.77	48.68	272.24
15.04.2017.	6589.72	847.65	543.47	63.65	265.02
16.04.2017.	6208.33	798.90	502.44	58.51	351.02

Tablica 5. Indikatori kompleksnosti za vikend u travnju

	14.04.	*15.04.*	*16.04.*
Prilagođena gustoća	0.1117	0.1286	0.1287
VDIF	0.0086	0.01	0.0094
HDIF	0.0713	0.0825	0.0809
SDIF	0.0481	0.0402	0.0565
r_VDIF	0.0770	0.0751	0.0732
r_HDIF	0.6389	0.6411	0.6289
r_SDIF	0.4308	0.3127	0.4394
Strukturalni indeks	1.1467	1.0289	1.1415
Rezultat kompleksnosti	0.128	0.1323	0.1469
Konačni rezultat kompleksnosti	7.68	7.94	8.81

5.3. Srpanj

Na jednak način na koji su dobiveni rezultati u prethodnim potpoglavljima izračunate su vrijednosti i indikatori za izabrani vikend u srpnju te su rezultati prikazani u tablicama 6. i 7.

Tablica 6. Prikaz rezultata za vikend u srpnju

DATUM	FT	TX	TXH	TXV	TXS
07.07.2017.	8826.96	1336.92	848.42	133.42	674.08
08.07.2017.	11287.37	2108.42	1318.62	224.76	593.15
09.07.2017.	9895.55	1635.70	1033.50	160.49	446.07

Tablica 7. Indikatori kompleksnosti za vikend u srpnju

	07.07.	*08.07.*	*09.07.*
Prilagođena gustoća	0.1515	0.1868	0.1653
VDIF	0.0151	0.0199	0.0162
HDIF	0.0961	0.1168	0.1044
SDIF	0.0764	0.0525	0.0451
r_VDIF	0.0998	0.1066	0.0981
r_HDIF	0.6346	0.6254	0.6318
r_SDIF	0.5042	0.2813	0.2727
Strukturalni indeks	1.2386	1.0133	1.0027
Rezultat kompleksnosti	0.1876	0.1893	0.1657
Konačni rezultat kompleksnosti	11.26	11.36	9.94

5.4. Kolovoz

U tablicama 8. i 9. prikazani su rezultati za datume 11.08., 12.08. i 13.08. u kojima je bio najveći promet od dosad izabranih vikenda, a time i najveća kompleksnost.

Tablica 8. Prikaz rezultata za vikend u kolovozu

DATUM	FT	TX	TXH	TXV	TXS
11.08.2017.	9232.61	1543.99	1003.56	134.54	639.54
12.08.2017.	11528.20	2221.76	1379.98	234.65	814.01
13.08.2017.	9654.07	1710.35	996.40	177.67	745.50

Tablica 9. Indikatori kompleksnosti za vikend u kolovozu

	11.08.	*12.08.*	*13.08.*
Prilagođena gustoća	0.1672	0.1927	0.1772
VDIF	0.0146	0.0204	0.0184
HDIF	0.1087	0.1197	0.1032
SDIF	0.0693	0.0706	0.0772
r_VDIF	0.0871	0.1056	0.1039
r_HDIF	0.65	0.6211	0.5826
r_SDIF	0.4142	0.3664	0.4359
Strukturalni indeks	1.1513	1.9031	1.1223
Rezultat kompleksnosti	0.1925	0.2107	0.1988
Konačni rezultat kompleksnosti	11.55	12.64	11.93

6. Određivanje radnog opterećenja sektora oblasne kontrole Zagreb za zadani uzorak prometa

Program NEST koristi već spomenutu makroskopsku formulu u izračunu radnog opterećenja kontrolora za pojedini dan. Program izlista radno opterećenje izraženo brojem koji je onda usporediv s ostalim danima, a i s kompleksnošću. Uz radno opterećenje za svaki sektor prikazani su i brojevi koji predstavljaju radno opterećenje veće od kapaciteta (>capa), radno opterećenje veće od 70% (workload>70%) i radno opterećenje veće od 90% (workload>90%). Za radno opterećenje kao reprezentativni uzorci uzeti su oni za LDZOFIR - hrvatski FIR (Flight Information Region - FIR) i ukupno radno opterećenje (LDZOTOT) za cijeli ACC prostor Hrvatske, uključujući Bosnu. Nisu izabrani pojedinačni sektori radi usporedivosti s prethodno izračunatom kompleksnošću, a i zbog uspoređivanja ANSP područja na razini ACC prostora. Niti sam program NEST ne preporučuje računanje na sektorima budući da se ne bi dobili toliko precizni rezultati kao na ACC razini.

6.1. Siječanj

U tablici 10. prikazani su rezultati za datum 27.01.2017. te se u njoj nalazi radno opterećenje za izabrane sektore kao i dodatni već navedeni parametri.

Tablica 10. Radno opterećenje za 27.01.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	8321	4510	2162	1111
LDZOLN	1759	464	0	0
LDZOLS	1415	276	0	0
LDZOLW	1721	376	0	0
LDZOTNN	2813	548	0	0
LDZOTOT	8578	4101	2313	1172
LDZOTS	3086	445	0	0
LDZOTWW	2339	469	0	0
LDZOUN	2280	534	0	0
LDZOUS	2684	609	0	0
LDZOUW	2916	732	0	0

Na izabranim grafikonima koji prikazuju hrvatski FIR i ukupno radno opterećenje (TOT) nalaze se legende koje označavaju što koja krivulja predstavlja:

- **SHER** (skraćeno od Sliding Hourly Entry Rate – klizna stopa ulazaka po satu) predstavlja upravo to što i znači, stopu ulazaka po satu izraženu u broju zrakoplova koji ulaze u sektor po satu

- **Average Time** (prosječno vrijeme) jednostavno je prosječan broj minuta provedenih u sektoru ali za sve zrakoplove koji prolaze tim sektorom u zadanom satu
- **Conf** je skraćenica za konlikte i označava broj potencijalnih konflikata u sektoru tijekom zadanog sata
- **Wkl** (odnosno workload ili radno opterećenje) efektivna je krivulja radnog opterećenja koja je izražena u postocima (smatra se da je maksimalan kontinuirani rad za kontrolora oko 42 minute po satu, dakle 70%)
- **Capa** ili capacity (kapacitet) prikazan je na grafikonu ukoliko je određen kapacitet za taj dan što nije slučaj u ovom radu
- **70** je spomenuta granica za radno opterećenje kontrolora
- **90** prikazuje apsolutnu granicu koju kontrolor ne bi trebao prijeći što se tiče radnog opterećenja (90% ili 54 minute kontinuiranog rada po satu) [9].

U grafikonima 1. i 2. grafički je prikazano radno opterećenje za 27.01.2017. za LDZOFIR i LDZOTOT. Vidljivo je kako i SHER i radno opterećenje imaju visoke vrijednosti što je i logično budući da se u obzir uzimalo cijelo kontrolirano područje (Control area – CTA), a ne pojedinačni sektori.

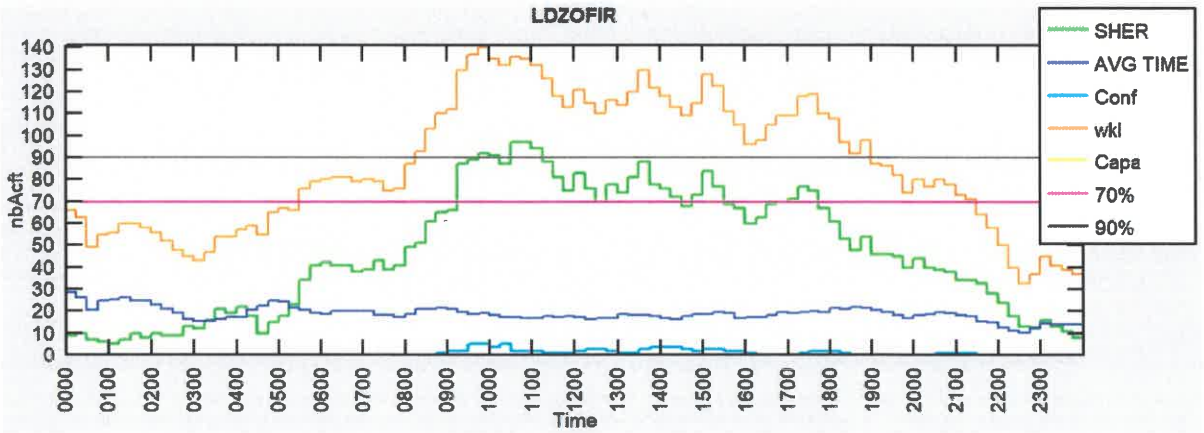

Grafikon 1. Prikaz radnog opterećenja za LDZOFIR za 27.01.

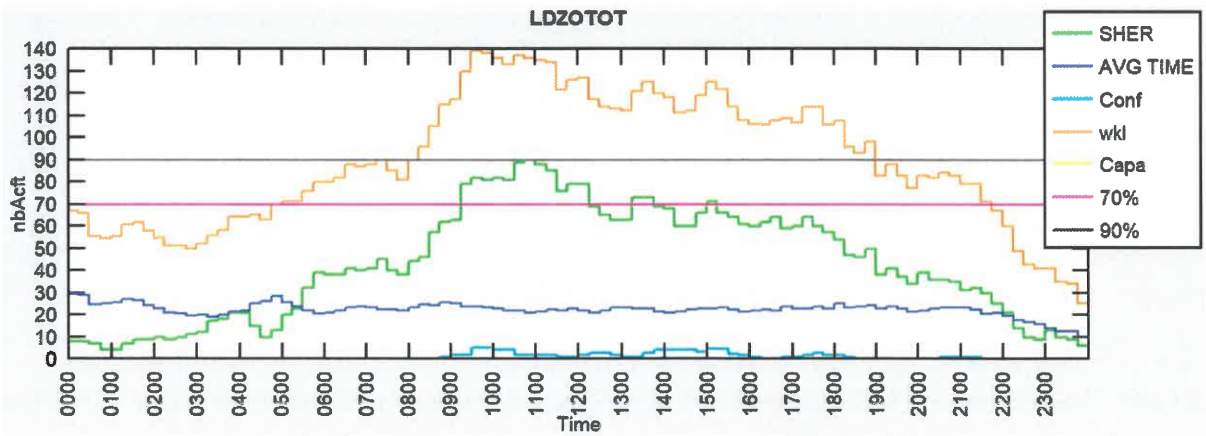

Grafikon 2. Prikaz radnog opterećenja za LDZOTOT za 27.01.

Tablica 11. Radno opterećenje za 28.01.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	8387	4616	2126	969
LDZOLN	1430	336	0	0
LDZOLS	1189	244	0	0
LDZOLW	1754	316	0	0
LDZOTNN	2586	460	0	0
LDZOTOT	8710	4181	2274	1069
LDZOTS	3175	567	0	0
LDZOTWW	2434	505	0	0
LDZOUN	2190	572	0	0
LDZOUS	2413	599	0	0
LDZOUW	2956	756	0	0

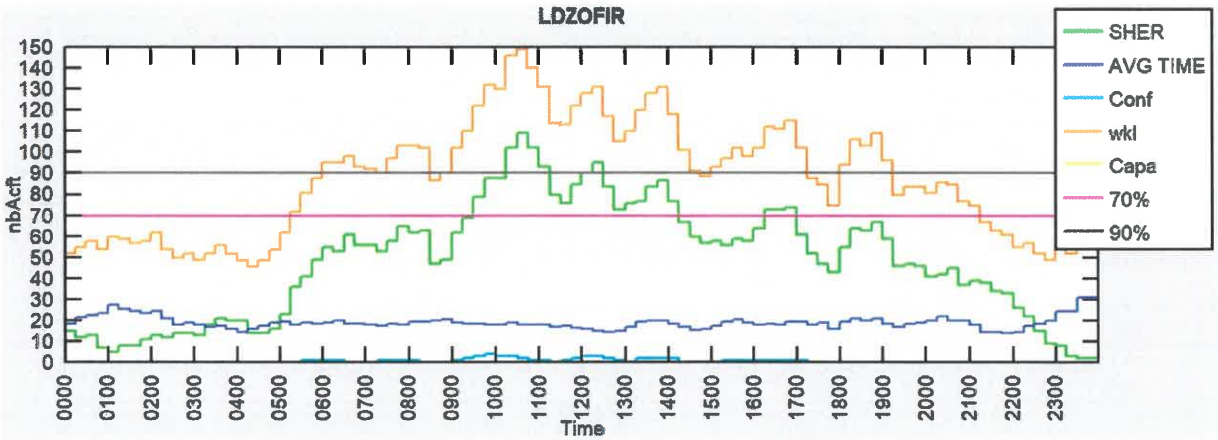

Grafikon 3. Prikaz radnog opterećenja za LDZOFIR za 28.01.

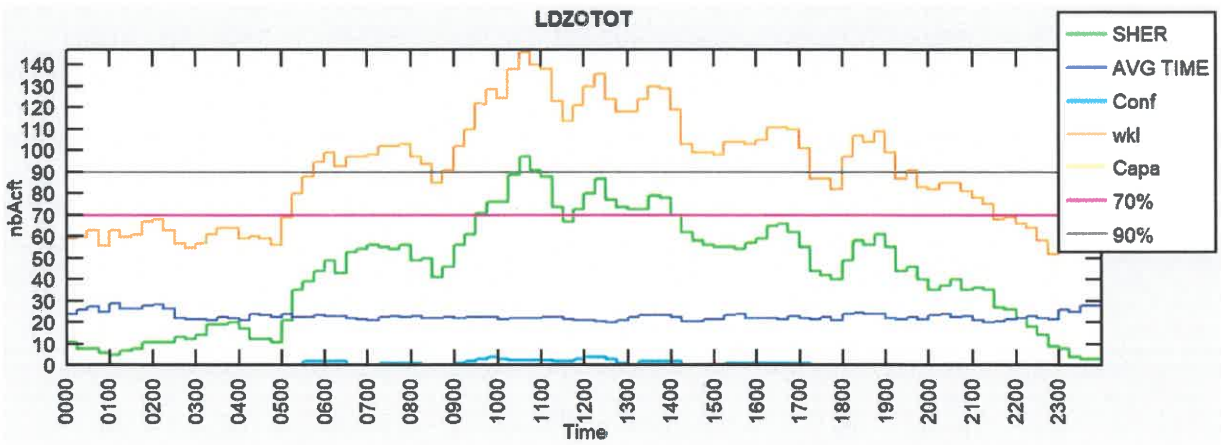

Grafikon 4. Prikaz radnog opterećenja za LDZOTOT za 28.01.

Tablica 12. Radno opterećenje za 29.01.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	8722	4906	2400	1303
LDZOLN	1507	376	0	0
LDZOLS	1876	288	80	0
LDZOLW	2308	375	40	0
LDZOTNN	2614	489	0	0
LDZOTOT	9137	4520	2670	1447
LDZOTS	2939	463	0	0
LDZOTWW	2265	454	0	0
LDZOUN	2532	614	0	0
LDZOUS	2722	684	0	0
LDZOUW	3449	1035	0	0

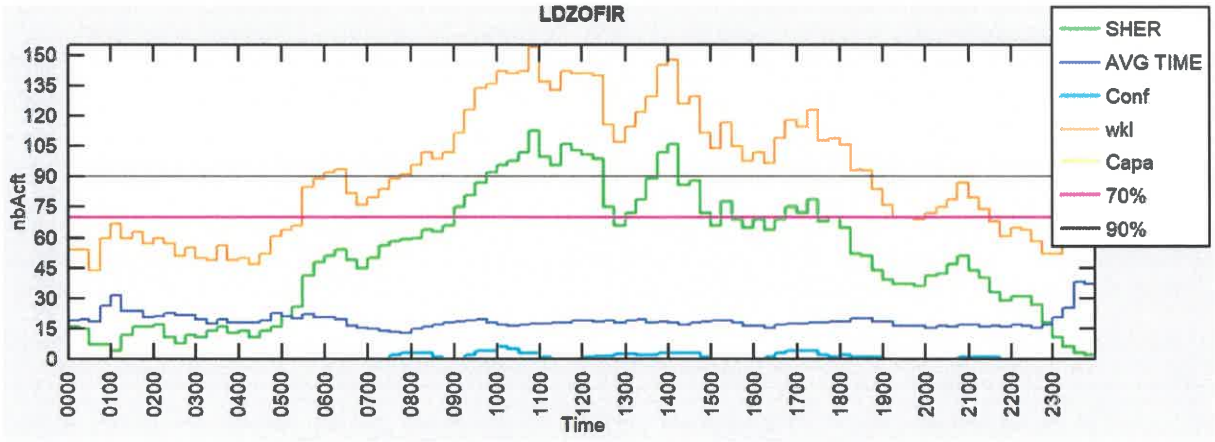

Grafikon 5. Prikaz radnog opterećenja za LDZOFIR za 29.01.

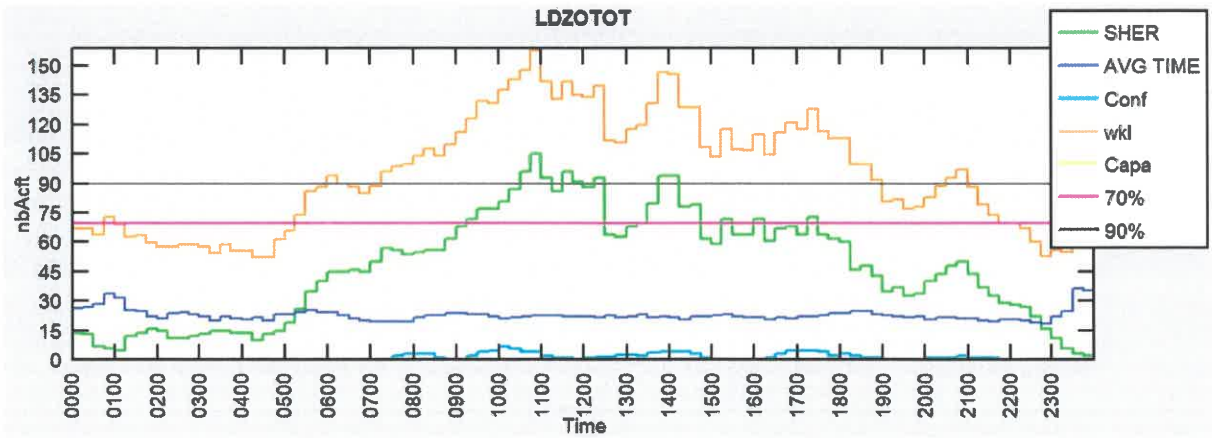

Grafikon 6. Prikaz radnog opterećenja za LDZOTOT za 29.01.

6.2. Travanj

U nastavku se nalaze tablice i grafikoni koji prikazuju radno opterećenje u pojedinim sektorima za datume 14., 15. i 16.04.2017.

Tablica 13. Radno opterećenje za 14.04.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	10191	6333	4019	2634
LDZOLN	1514	636	0	0
LDZOLS	1595	428	0	0
LDZOLW	1863	572	0	0
LDZOTNN	3125	658	0	0
LDZOTOT	10339	5724	3994	2589
LDZOTS	3410	575	0	0
LDZOTWW	2790	648	0	0
LDZOUN	2679	964	0	0
LDZOUS	2820	815	0	0
LDZOUW	3386	1124	0	0

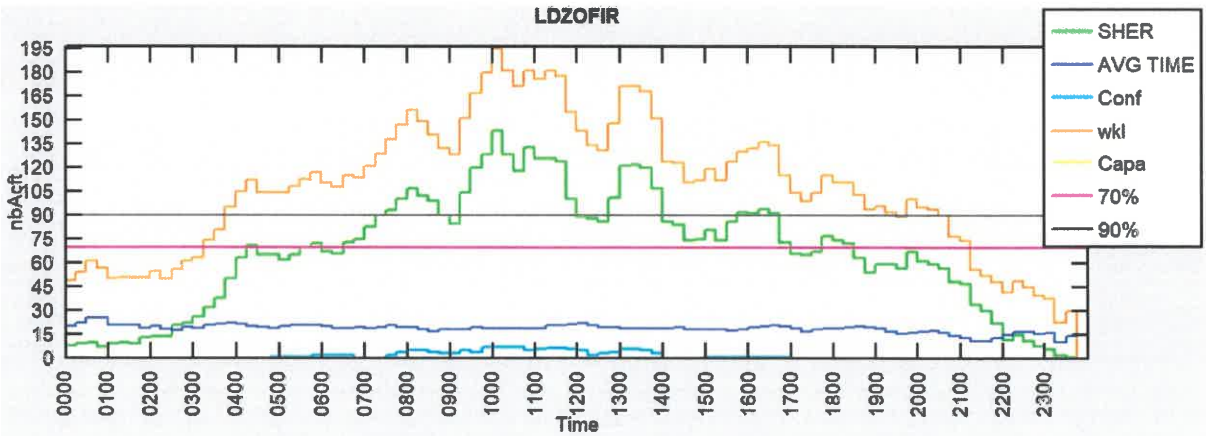

Grafikon 7. Prikaz radnog opterećenja za LDZOFIR za 14.04.

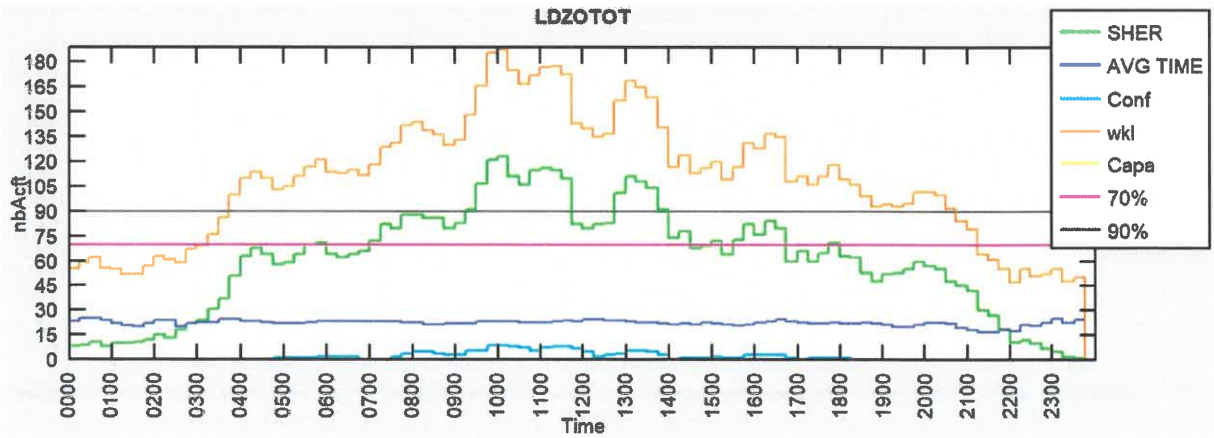

Grafikon 8. Prikaz radnog opterećenja za LDZOTOT za 14.04.

Tablica 14. Radno opterećenje za 15.04.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	11613	7423	5174	3774
LDZOLN	1704	546	0	0
LDZOLS	1657	552	0	0
LDZOLW	2037	736	0	0
LDZOTNN	2694	716	0	0
LDZOTOT	11398	6519	4882	3453
LDZOTS	3575	824	0	0
LDZOTWW	2822	900	0	0
LDZOUN	2621	879	0	0
LDZOUS	2960	1054	0	0
LDZOUW	3403	1343	0	0

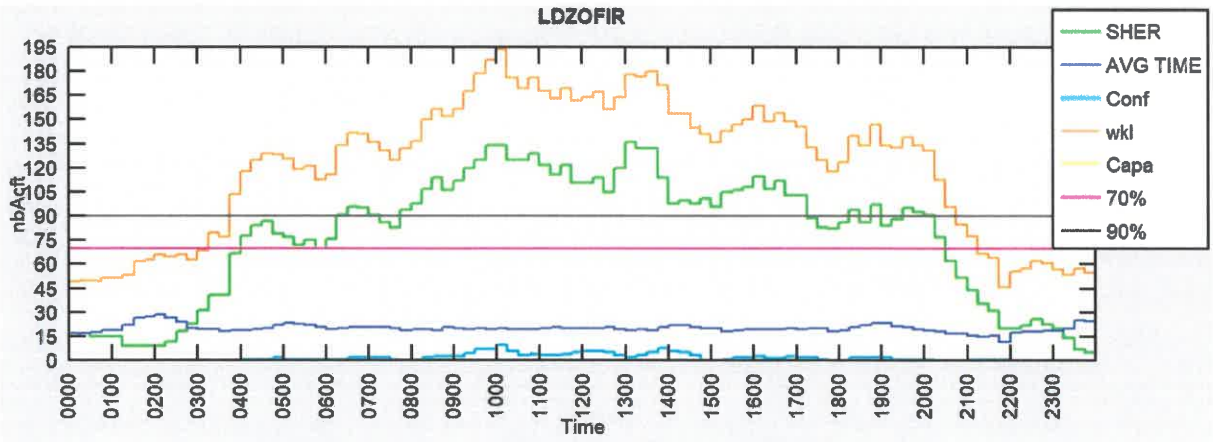

Grafikon 9. Prikaz radnog opterećenja za LDZOFIR za 15.04.

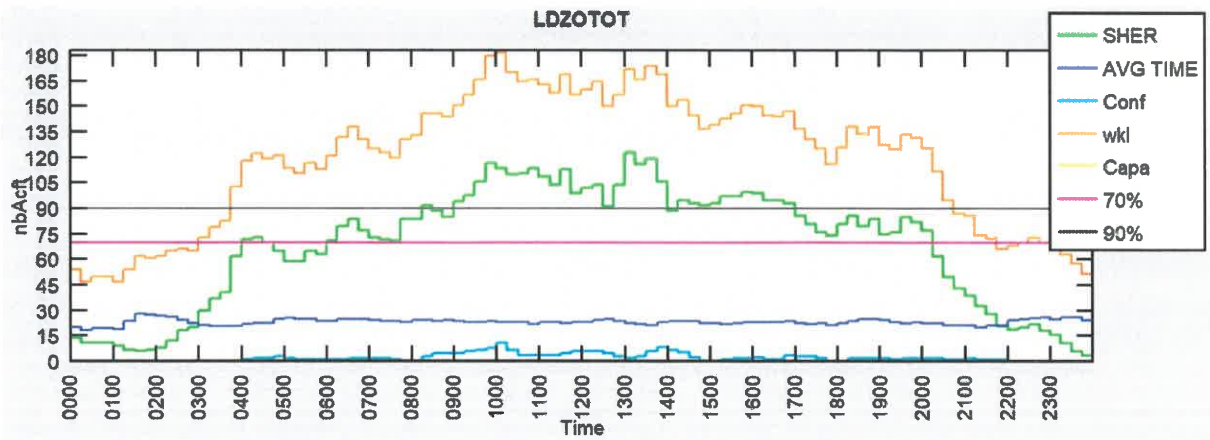

Grafikon 10. Prikaz radnog opterećenja za LDZOTOT za 15.04.

Tablica 15. Radno opterećenje za 16.04.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	11050	7090	4682	3276
LDZOLN	1505	457	0	0
LDZOLS	1499	470	0	0
LDZOLW	2372	594	0	0
LDZOTNN	3040	744	0	0
LDZOTOT	11112	6341	4596	3180
LDZOTS	3549	730	0	0
LDZOTWW	2509	739	0	0
LDZOUN	2571	773	0	0
LDZOUS	2777	922	0	0
LDZOUW	3426	1304	0	0

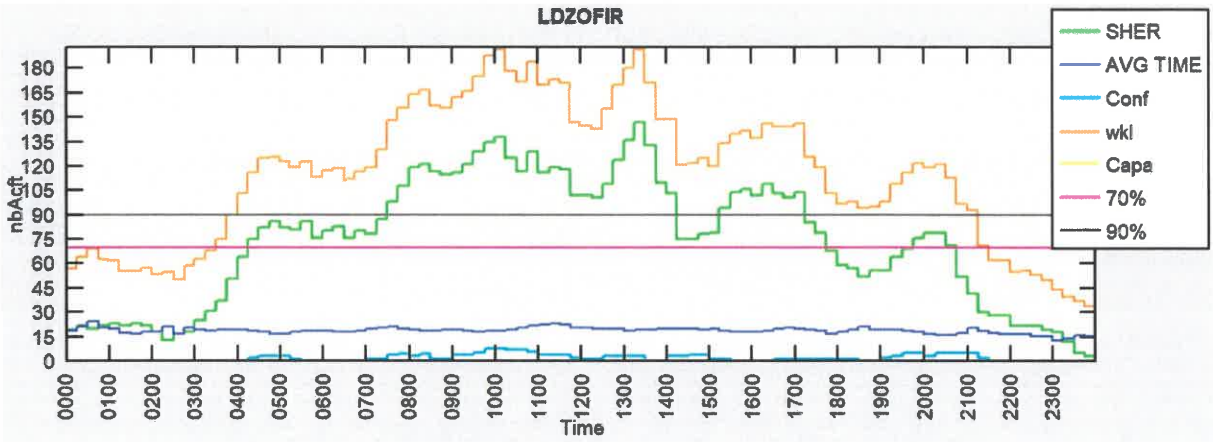

Grafikon 11. Prikaz radnog opterećenja za LDZOFIR za 16.04.

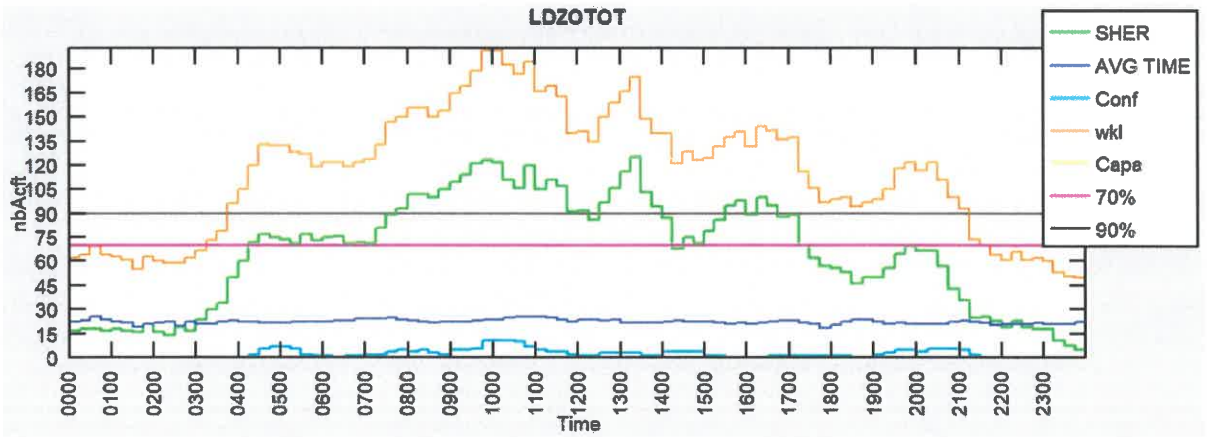

Grafikon 12. Prikaz radnog opterećenja za LDZOTOT za 16.04.

6.3. Srpanj

U ovom potpoglavlju nalaze se tablice s radnim opterećenjima za odabrani vikend u srpnju kao i grafikoni za LDZOFIR i LDZOTOT za svaki datum. Primjetne su sve veće vrijednosti kako se promet povećava u ljetnim mjesecima za razliku od prethodna dva obrađena.

Tablica 16. Radno opterećenje za 07.07.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	14723	10362	8234	6699
LDZOLN	1975	912	0	0
LDZOLS	1886	740	0	0
LDZOLW	3004	1428	0	0
LDZOTNN	3344	1003	0	0
LDZOTOT	14193	8918	7610	6037
LDZOTS	3940	876	0	0
LDZOTWW	2899	944	0	0
LDZOUN	3060	1405	0	0
LDZOUS	3544	1311	0	0
LDZOUW	4223	2002	0	0

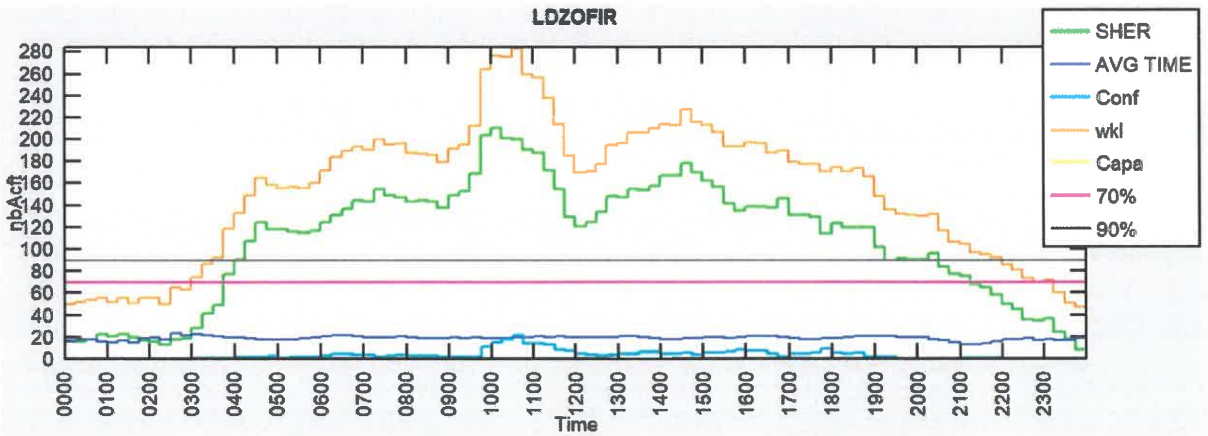

Grafikon 13. Prikaz radnog opterećenja za LDZOFIR za 07.07.

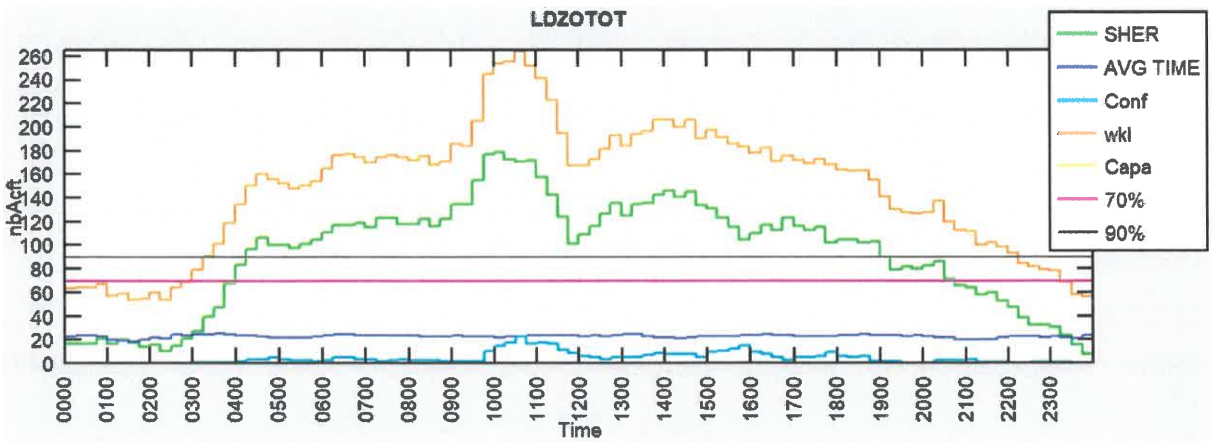

Grafikon 14. Prikaz radnog opterećenja za LDZOTOT za 07.07.

Tablica 17. Radno opterećenje za 08.07.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	17911	12928	11354	9734
LDZOLN	2436	1148	0	0
LDZOLS	2469	1090	0	0
LDZOLW	3474	1991	0	0
LDZOTNN	3330	990	0	0
LDZOTOT	17230	11286	10602	8949
LDZOTS	3803	1050	0	0
LDZOTWW	3276	1186	0	0
LDZOUN	3761	1882	0	0
LDZOUS	4078	1935	0	0
LDZOUW	4887	2665	47	0

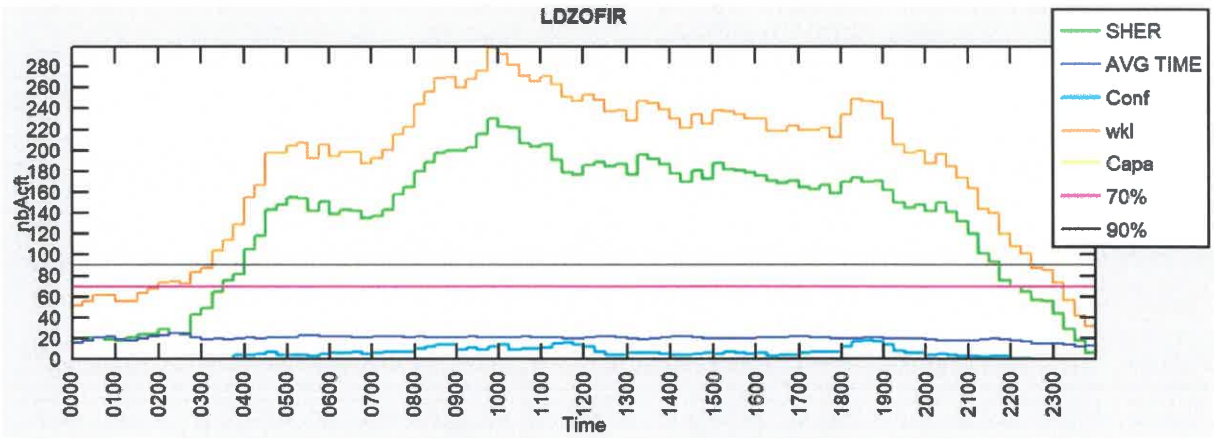

Grafikon 15. Prikaz radnog opterećenja za LDZOFIR za 08.07.

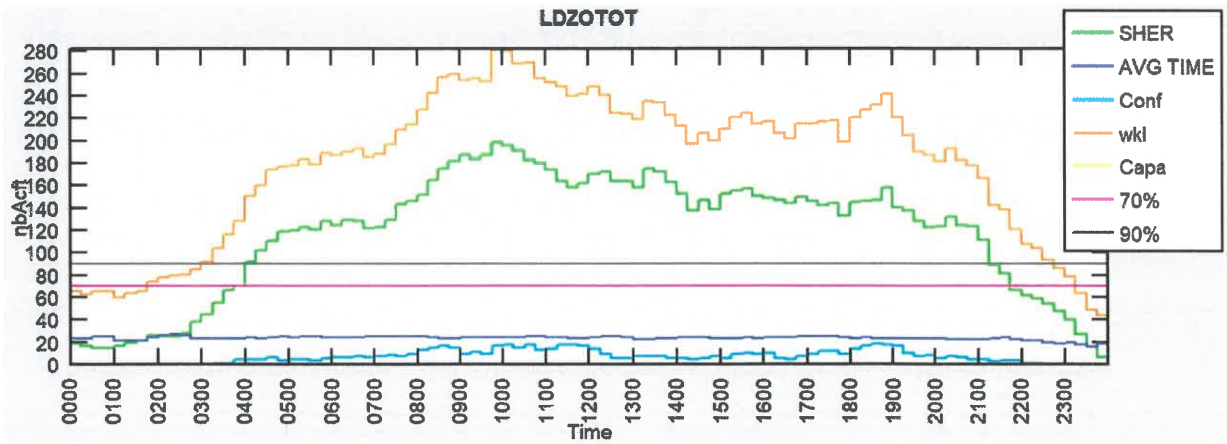

Grafikon 16. Prikaz radnog opterećenja za LDZOTOT za 08.07.

Tablica 18. Radno opterećenje za 09.07.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	16192	11709	9596	7994
LDZOLN	2130	888	0	0
LDZOLS	2055	924	0	0
LDZOLW	3522	1588	0	0
LDZOTNN	3409	1044	0	0
LDZOTOT	15515	10200	8869	7216
LDZOTS	3454	959	0	0
LDZOTWW	3062	1033	0	0
LDZOUN	3518	1635	0	0
LDZOUS	3834	1799	0	0
LDZOUW	4829	2517	0	0

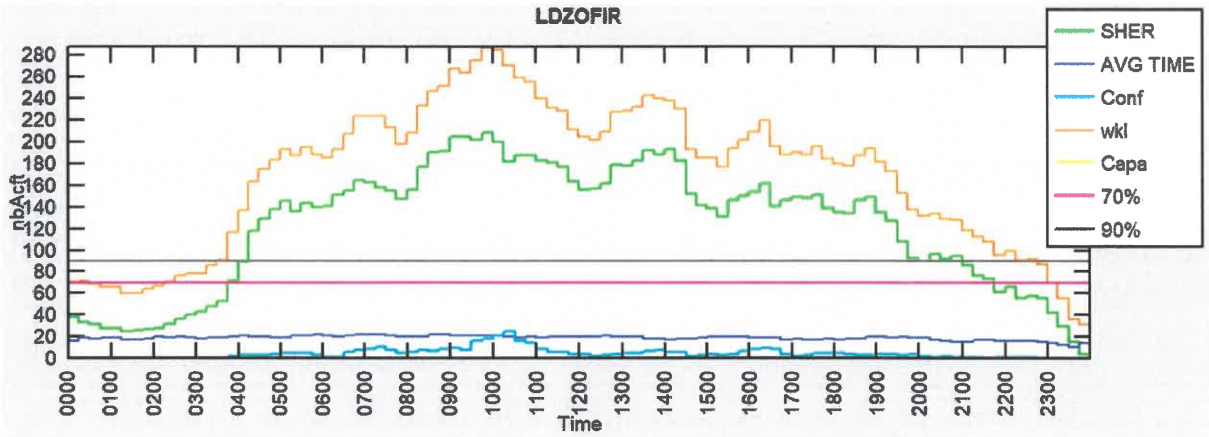

Grafikon 17. Prikaz radnog opterećenja za LDZOFIR za 09.07.

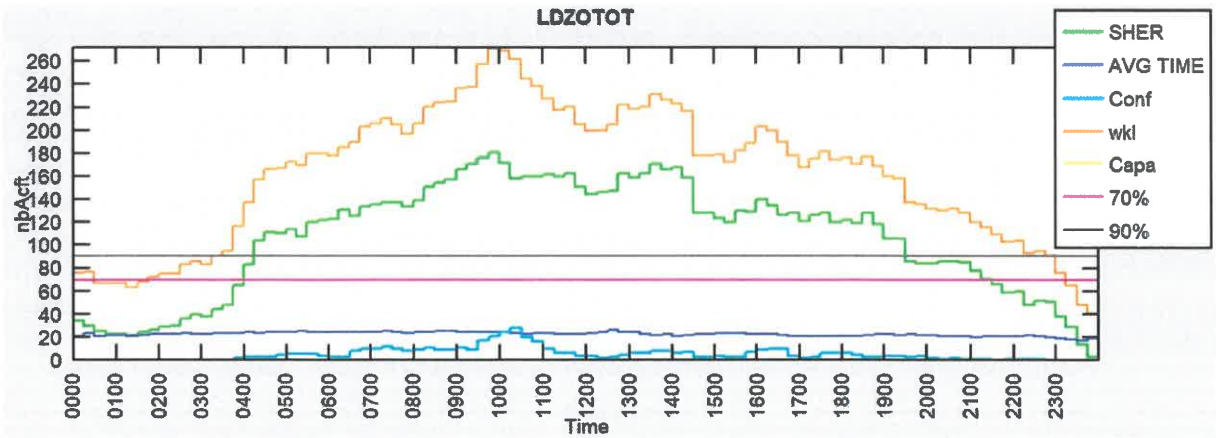

Grafikon 18. Prikaz radnog opterećenja za LDZOTOT za 09.07.

6.4. Kolovoz

Za zadnji obrađeni vikend odabrani su datumi 11., 12. i 13.08. te su za njih izračunate vrijednosti radnog opterećenja kao i prikazane grafički u grafikonima 19.-24.

Tablica 19. Radno opterećenje za 11.08.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	15644	11107	9053	7488
LDZOLN	2478	961	0	0
LDZOLS	1833	696	0	0
LDZOLW	3086	1320	0	0
LDZOTNN	2732	850	0	0
LDZOTOT	15058	9676	8397	6802
LDZOTS	3604	832	0	0
LDZOTWW	2619	827	0	0
LDZOUN	3715	1826	0	0
LDZOUS	3619	1471	0	0
LDZOUW	4580	2102	12	0

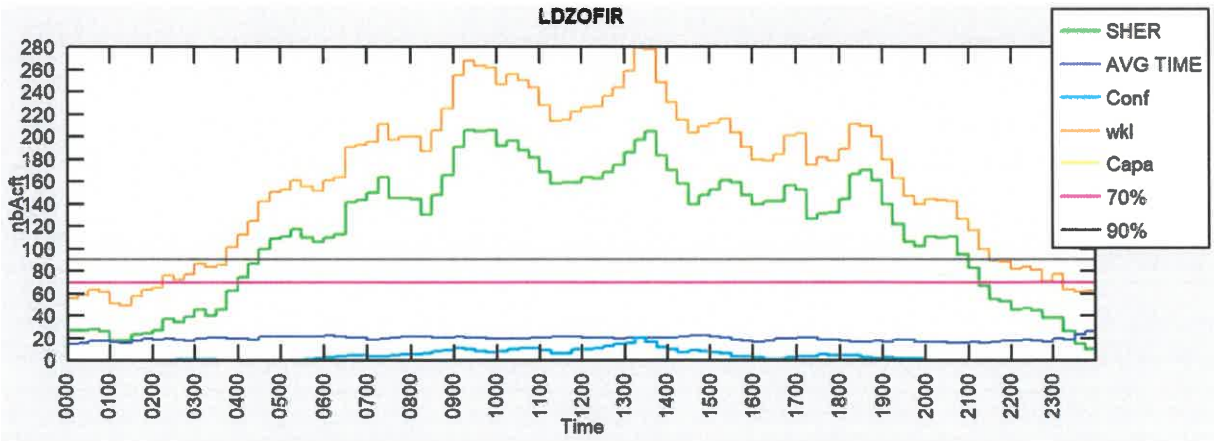

Grafikon 19. Prikaz radnog opterećenja za LDZOFIR za 11.08.

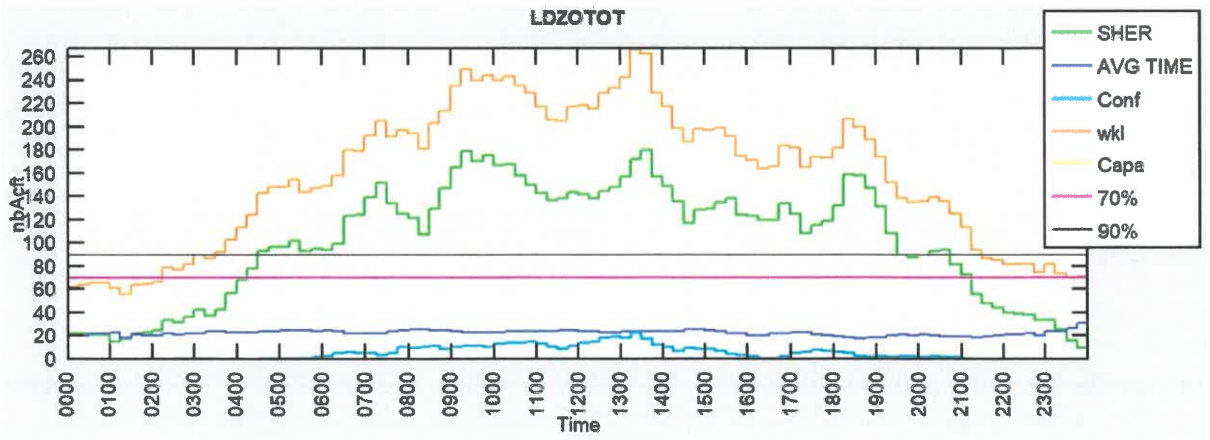

Grafikon 20. Prikaz radnog opterećenja za LDZOTOT za 11.08.

Tablica 20. Radno opterećenje za 12.08.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	18454	13482	11897	10248
LDZOLN	2656	1144	0	0
LDZOLS	2394	1139	0	0
LDZOLW	3909	2016	0	0
LDZOTNN	3085	860	0	0
LDZOTOT	17670	11857	11059	9403
LDZOTS	3554	900	0	0
LDZOTWW	2923	1031	0	0
LDZOUN	3980	1999	0	0
LDZOUS	4508	2145	0	0
LDZOUW	5181	2966	69	0

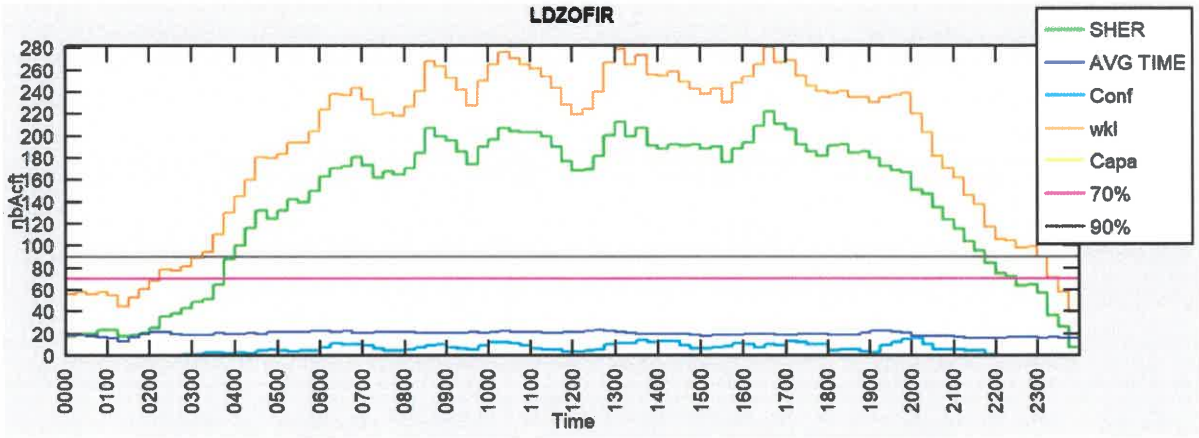

Grafikon 21. Prikaz radnog opterećenja za LDZOFIR za 12.08.

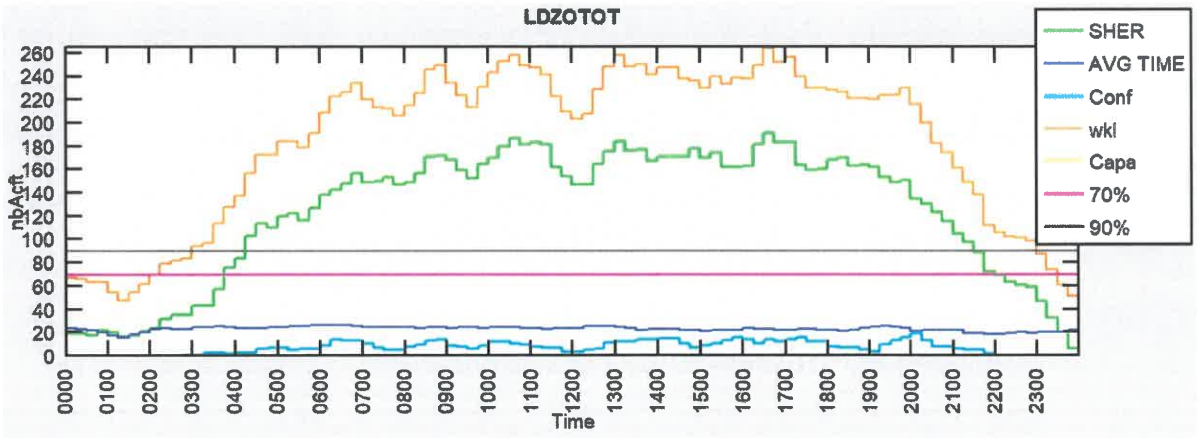

Grafikon 22. Prikaz radnog opterećenja za LDZOTOT za 12.08.

Tablica 21. Radno opterećenje za 13.08.

SEKTOR	RADNO OPTEREĆENJE	RADNO OPTEREĆENJE>KAPACITET	RADNO OPTEREĆENJE>70%	RADNO OPTEREĆENJE>90%
LDZOFIR	15742	11225	9133	7611
LDZOLN	2180	867	0	0
LDZOLS	2268	1030	0	0
LDZOLW	3347	1532	0	0
LDZOTNN	2784	725	0	0
LDZOTOT	15208	9823	8573	6986
LDZOTS	3488	910	0	0
LDZOTWW	3017	1012	0	0
LDZOUN	3608	1658	0	0
LDZOUS	3885	1797	0	0
LDZOUW	4773	2540	44	0

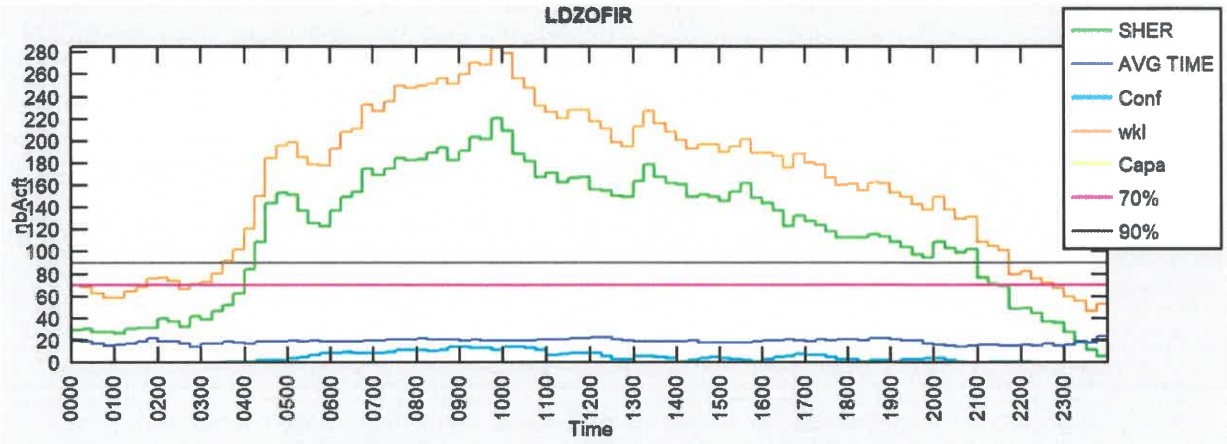

Grafikon 23. Prikaz radnog opterećenja za LDZOFIR za 13.08.

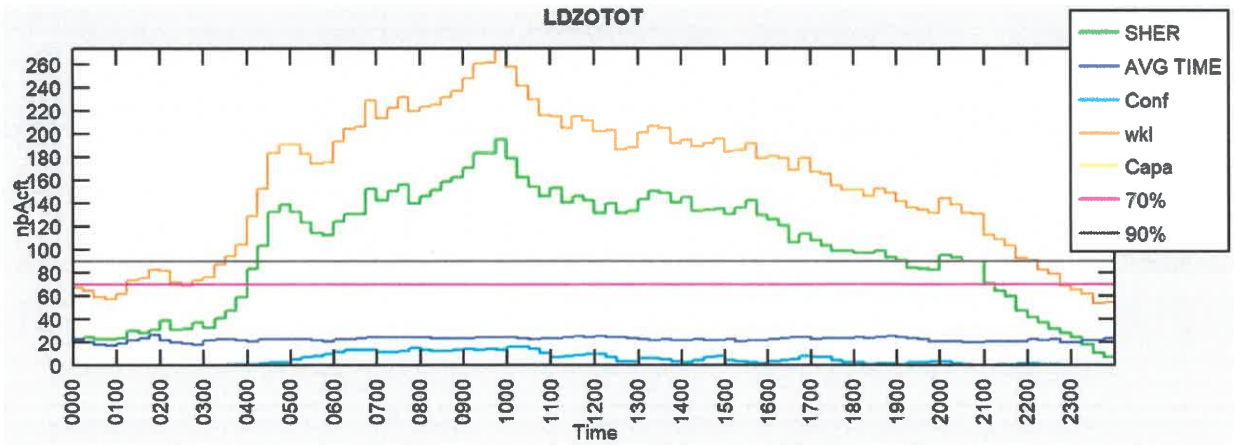

Grafikon 24. Prikaz radnog opterećenja za LDZOTOT za 13.08.

Radi boljeg razumijevanja visokog radnog opterećenja na grafikonu 25. prikazana je konfiguracija sektora i njihovo otvaranje po satima. Visoko radno opterećenje pojavljuje se zbog otvaranja novih sektora, na primjer od 9 do 10 sati bila je konfiguracija C8I koja uključuje čak 8 sektora: LDZOUW, LDZOULS, LDZOULN, LDZOTHN, LDZOTA, LDZOLW,

LDZOHW, LDZOHS. Radi usporedbe konfiguracija C1 ima samo jedan globalni sektor (LDZOGACC) i tada je radno opterećenje bilo najmanje (između ponoći i 1 h), dok je od 9 do 10 sati tijekom konfiguracije C8I bilo najveće opterećenje.

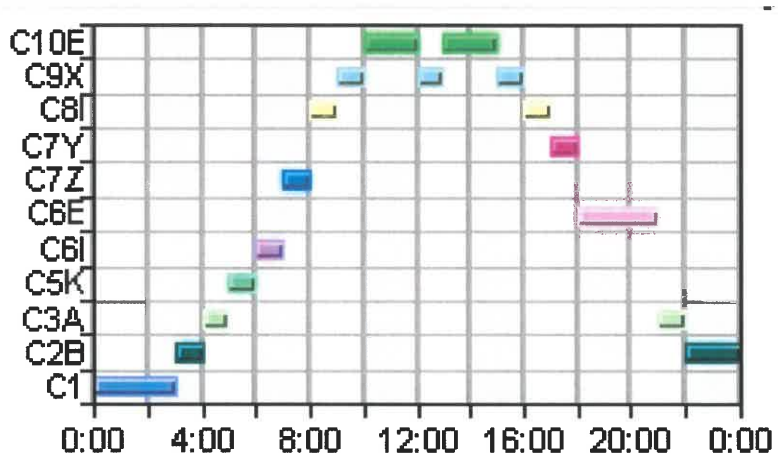

Grafikon 25. Konfiguracije sektora 13.08.

7. Analiza rezultata

U 5. i 6. poglavlju dobiveni su rezultati za kompleksnost i radno opterećenje u vidu brojeva koji ih predstavljaju. Za kompleksnost su izračunati razni indikatori kompleksnosti, kao i naposljetku konačni rezultat kompleksnosti koji se može usporediti sa službenim (pomnožen je sa 60). U izračunu radnog opterećenja program NEST koristio je makroskopsku formulu kojom se dobio rezultat koji prikazuje radno opterećenje kontrolora na zadani dan u tom sektoru. Radi lakše usporedbe najbitniji podaci iz oba poglavlja prikazani su u tablici 22.

Tablica 22. Usporedba kompleksnosti, radnog opterećenja i prometa

	Službeni rezultat kompleksnosti	*Radno opterećenje (LDZOTOT)*	*Broj letova*
27.01.	4.53	8578	914
28.01.	4.9	8710	922
29.01.	5.4	9137	1002
14.04.	7.68	10339	1291
15.04.	7.94	11398	1485
16.04.	8.81	11112	1413
07.07.	11.26	14193	2044
08.07.	11.36	17230	2571
09.07.	9.94	15515	2315
11.08.	11.55	15058	2163
12.08.	12.64	17670	2660
13.08.	11.93	15208	2262

Kao što je vidljivo iz tablice 22., porastom prometa rasla je i kompleksnost i radno opterećenje kontrolora. Korelacija kompleksnosti i radnog opterećenja s prometom još je primjetnija u tablici 23. s usrednjenim vrijednostima za svaki mjesec.

Tablica 23. Kompleksnost, radno opterećenje i promet po mjesecima

	Službeni rezultat kompleksnosti	*Radno opterećenje (LDZOTOT)*	*Broj letova*	*Omjer kompleksnosti i radnog opterećenja*
siječanj	4.94	8808	946	1 : 1783
travanj	8.14	10950	1396	1 : 1345
srpanj	10.85	15646	2310	1 : 1442
kolovoz	12.04	15979	2362	1 : 1327

Iz tablice 23. može se lakše primijetiti i izražena sezonalnost Hrvatske, dok je službena kompleksnost Hrvatske za 2017. godinu između 4 i 6 [10], iz tablice se vidi da je u siječnju kompleksnost bila samo 4.94, a u kolovozu čak 12.04 što je više nego dvostruka vrijednost.

Isto se može reći i za radno opterećenje: naraslo je za skoro dvostruko od siječnja do kolovoza što odgovara hipotezi da ta dva pojma koreliraju, a iz omjera kompleksnosti i radnog opterećenja iz tablice može se primijetiti i da ti omjeri ne odstupaju previše.

Ukoliko se izračuna srednja vrijednost rezultata kompleksnosti, on iznosi 9 za ova četiri vikenda iz četiri različita mjeseca tijekom godine što je puno više od službenog godišnjeg rezultata za Hrvatsku ali to je i za očekivati budući da u uzetim mjesecima čak dva od četiri, odnosno polovica je izuzetno sezonalno, što nije slučaj tijekom cijele godine budući da izražena sezona ne traje punih 6 mjeseci.

8. Zaključak

U ovom radu obrađena je tematika određivanja kompleksnosti i radnog opterećenja koristeći program NEST. Za izračun su odabrani najreprezentativniji vikendi mjeseca siječnja, travnja, srpnja i kolovoza 2017. godine. Izračuni kompleksnosti odrađeni su za ukupno 12 datuma, svaki zasebno od 0 do 24 h, i od FL85 do FL415 za prostor LDZOCTA.

Kako bi se došlo do kompleksnosti i njenih vrijednosti potrebno je dobro razumijeti interakcije koje su izvor cijele kompleksnosti i njenog računanja jer prisutnost više zrakoplova u istom prostoru u isto vrijeme stvara kompleksnost, a pogotovo ako su ti zrakoplovi u različitim fazama leta, imaju različite pravce kretanja ili različite brzine kretanja. Interakcija je istovremena prisutnost dvaju zrakoplova u istoj ćeliji kada se gleda iz perspektive svakog zrakoplova. Razlikujemo vertikalne, horizontalne i interakcije brzine kojima pripadaju indikatori VDIF, HDIF i SDIF (kao i relativni r_VDIF, r_HDIF i r_SDIF) dok su najbitniji indikatori kompleksnosti prilagođena gustoća i navedena tri indikatora - VDIF, HDIF i SDIF, te dakako rezultat kompleksnosti.

Kao što je ranije objašnjeno, radno opterećenje predstavlja fizički ili mentalni napor usmjeren na ostvarivanje nečega, te je ono količina posla dodijeljenog pojedincu za izvršavanje unutar određenog roka. U kontroli zračnog prometa radno opterećenje kontrolora je izuzetno važna tema te je oko njega već izrađeno mnoštvo studija, izvještaja i osvrta. Do radnog opterećenja dolazi se preko jednostavne formule koja procjenjuje rad kontrolora temeljen na broju kontroliranih zrakoplova, zadatku nadgledanja i zadacima rješavanja konflikata što sve predstavlja kompleksnost zračnog prometa.

Iz analize dobivenih rezultata izračuna kompleksnosti i radnog opterećenja u programu NEST može se zaključiti kako radno opterećenje raste s kompleksnošću te su stoga ti pojmovi međusobno povezani. Na primjer omjer kompleksnosti i radnog opterećenja za mjesec srpanj iznosi 1 : 1442. Ni kod ostalih obrađenih mjeseci taj omjer ne varira previše. Dakako porastom prometa i povećanjem broja specifičnih interakcija zrakoplova, rastu i kompleksnost i radno opterećenje. Vidljivo je i da u Hrvatskoj postoji problem visoke sezonalnosti zbog koje kontrolori tijekom ljetnih mjeseci doživljavaju iznimno visoku kompleksnost kao i radno opterećenje što nikako nije poželjno, dok je tijekom ostatka godine taj broj umjeren što loše utječe na kontrolore radi toliko velikih razlika u prometu.

Budući da se na temelju kompleksnosti i radnog opterećenja te predikcije prometne potražnje određuje kapacitet sektora, istraživanja vezana za kompleksnost i radno opterećenje imaju veliku važnost u daljnjem razvoju cjelokupnog sustava upravljanja zračnim prometom.

Literatura

[1] Juričić, B.: Upravljanje kapacitetom i protokom zračnog prometa – autorizirana predavanja, 2018.

[2] http://www.crocontrol.hr/default.aspx?id=171, srpanj 2018.

[3] https://www.skybrary.aero/index.php/Single_European_Sky_(SES), srpanj 2018.

[4] http://www.eurocontrol.int/articles/free-route-airspace, kolovoz 2018.

[5] http://www.crocontrol.hr/default.aspx?id=3780, srpanj 2018.

[6] https://www.skybrary.aero/index.php/SESAR, srpanj 2018.

[7] Interim evaluation of the SESAR Joint Undertaking (2014-2016) operating under Horizon 2020, European Commission, 2017.

[8] http://ec.europa.eu/eurostat/statistics-explained/index.php/Air_transport_statistics, srpanj 2018.

[9] IATA annual review, IATA, 2017.

[10] Performance review report, Performance Review Commission, 2017.

[11] https://www.aci-europe.org/policy/position-papers.html?view=group&group=1&id=1, srpanj 2018.

[12] Transport development strategy of the Republic of Croatia (2014. – 2030.), Ministarstvo mora, prometa i infrastrukture, 2014.

[13] Aviation International News - AIN Alerts, 06.07.2018.

[14] LSSIP - The Local Single Sky ImPlementation, 2016.

[15] Complexity Metrics for ANSP Benchmarking Analysis, ACE Working Group on Complexity, 2006.

[16] http://www.eurocontrol.int/services/nest-modelling-tool, srpanj 2018.

[17] NEST User Guide, 2017.

[18] Brooker, P.: Control workload, airspace capacity and future systems, Cranfield University, UK, 2003.

[19] Lyall, B.: Workload levels and their impact, Hindsight21 str. 63., Eurocontrol, 2015.

[20] Pessimistic sector capacity estimation, Eurocontrol, 2003.

[21] Comparison of Different Workload and Capacity Measurement Methods Used in CEATS Simulations, EUROCONTROL, 2007.

POPIS KRATICA

AAGR	(Average Annual Growth Rate) prosječna godišnja stopa rasta
ACC	(Area Control Center) centar oblasne kontrole
ACE	(Air Traffic Management Cost-Effectiveness) troškovna učinkovitost upravljanja zračnim prometom
ACI	(Airports Council International Europe) Europsko internacionalno vijeće zračnih luka
ANSP	(Air Navigation Service Provider) pružatelj usluga zračne navigacije
ARR	(arrival) dolazak
ATC	(Air Traffic Control) Kontrola zračne plovidbe
ATFM	(Air Traffic Flow Management) Upravljanje protokom zračnog prometa
ATM	(Air Traffic Management) Upravljanje zračnim prometom
BADA	(Base of Aircraft Data) baza zrakoplovnih podataka
c	(capacity) kapacitet
Capa	(Capacity) kapacitet
CO_2	(carbon dioxide) ugljikov dioksid
Conf	(Conflicts) konflikti
CTA	(control area) kontrolirano područje
d	(demand) potražnja
DEP	(departure) odlazak
DH	vertikalna udaljenost u ćeliji
EASA	(European Aviation Safety Agency) Europska agencija za zrakoplovnu sigurnost
ECAC	(European Civil Aviation Conference) Europska konferencija civilne avijacije
ESRA08	(EUROCONTROL Statistical Reference Area 2008.) referentno područje za EUROCONTROL statistiku 2008. godine
EU	(European Union) Europska Unija
EUIR	(European Upper Flight Information Region) Europsko gornje područje letnih informacija
FAB	(Functional Airspace Block) funkcionalni blok zračnog prostora

FD	(flight distance) udaljenost letova u ćeliji
FIR	(Flight Information Region) regija za izdavanje informacija o letovima
FL	(Flight Level) razina leta
ft	(feet) stopa
FT	(flight time) sati leta
FRA	(Free Route Airspace) zračni prostor slobodnih ruta
FUA	(Flexible Use of Airspace) fleksibilna upotreba zračnog prostora
h	(hour) sat
HDIF	(Horizontal Different Interacting Flows) horizontalno različiti protoci u interakciji
IATA	(International Air Transport Association) Međunarodna udruga za zračni prijevoz
ID	(identification) identifikacija
IFR GAT	(Instrument Flight Rules General Air Traffic) instrumentalna pravila letenja kod generalne avijacije
kg	(kilogram) kilogram
KZP	Kontrola zračne plovidbe
LDZOCTA	(LDZO Control Area) LDZO kontrolno područje
LDZOTOT	(LDZO Total) LDZO ukupno područje
LoA	(Letter of Agreement) međusobni sporazum
min	(minutes) minute
N	(Number) broj obrađenih letova
NCELL	(Number of Cells) ukupan broj aktivnih ćelija podijeljen s ukupnim brojem pomaknute mreže
NEST	(Network Simulation Testbed) ispitni stol za simulacije mreže
NEVAC	(The Network Estimation & Visualisation of ACC Capacity) procjena mreže i vizualizacija kapaciteta centra oblasne kontrole
NM (x2)	(nautical mile; Network Manager) milja; upravitelj mreže
NMOC	(Network Manager Operations Centre) operacijski centar voditelja mreže
PRU	(Performance Review Unit) jedinica za pregled performansi

RVSM	(Reduced Vertical Separation Minima) smanjena minimalna vertikalna separacija
SAAM	(System for traffic Assignment and Analysis at a Macroscopic level) sustav za dodjelu prometa i analize na makroskopskoj razini
SAXFRA	(Slovenian Austrian Cross-border Free Route Airspace) slovensko austrijski prekogranični zračni prostor slobodnih ruta
SDIF	(Speed Different Interacting Flows) protoci u interakciji zbog različitih brzina
SEAFRA	(South-East Axis Free Route Airspace) zračni prostor slobodnih ruta jugoistočne osi
SECSI FRA	(South East Common Sky Initiative Free Route Airspace) zračni prostor slobodnih ruta zajedničke nebeske incijative jugoistoka
SES	(Singel European Sky) Jedinstveno europsko nebo
SESAR	(Single European Sky ATM Research) istraživanje Jedinstvenog europskog neba o upravljanju zračnim prometom
STATFOR	(Statistics and Forecasts) statistike i prognoze
TV	(Traffic Volume) volumen prometa
TX	sati interakcija
TXH	sati horizontalnih interakcija
TXS	sati interakcija brzine
TXV	sati vertikalnih interakcija
VDIF	(Vertical Different Interacting Flows) vertikalno različiti protoci u interakciji
Wkl	(Workload) radno opterećenje

POPIS SLIKA

Slika 1. SECSI FRA, str 6.

Slika 2. 2015/2016 rast u broju ukupnog broja putnika u zračnom prijevozu po državama članicama, str. 8.

Slika 3. Razvoj prosječnog broja dnevnih letova na EUROCONTROL području, str. 9.

Slika 4. Svarno i predviđeno kretanje IFR prometa u Hrvatskoj (2012 - 2022), str. 10.

Slika 5. LDZOCTA referentni i alternativni scenariji, str. 11.

Slika 6. Zavisnost kompleksnosti, radnog opterećenja i kapaciteta, str. 12.

Slika 7. Ilustracija unutarnjih i vanjskih faktora kompleksnosti, str. 14.

Slika 8. Dimenzije 4D ćelije, str. 17.

Slika 9. Prikaz interakcija, str. 18.

Slika 10. Indikator prilagođene gustoće, str. 20.

Slika 11. Potencijalne vertikalne interakcije, str. 21.

Slika 12. Potencijalne horizontalne interakcije, str. 22.

Slika 13. Indikatori kompleksnosti, str. 25.

Slika 14. PRU kompleksnost – parametri, str. 29.

Slika 15. Aspekti radnog opterećenja kontrolora, str. 30.

Slika 16. Oscilacije radnog opterećenja, str. 31.

POPIS TABLICA

Tablica 1. Pragovi radnog opterećenja, str. 34.

Tablica 2. Prikaz rezultata za vikend u siječnju, str. 35.

Tablica 3. Indikatori kompleksnosti za vikend u siječnju, str. 35.

Tablica 4. Prikaz rezultata za vikend u travnju, str. 36.

Tablica 5. Indikatori kompleksnosti za vikend u travnju, str. 36.

Tablica 6. Prikaz rezultata za vikend u srpnju, str. 36.

Tablica 7. Indikatori kompleksnosti za vikend u srpnju, str. 37.

Tablica 8. Prikaz rezultata za vikend u kolovozu, str. 37.

Tablica 9. Indikatori kompleksnosti za vikend u kolovozu, str. 37.

Tablica 10. Radno opterećenje za 27.01., str. 38.

Tablica 11. Radno opterećenje za 28.01., str. 40.

Tablica 12. Radno opterećenje za 29.01., str. 41.

Tablica 13. Radno opterećenje za 14.04., str. 42.

Tablica 14. Radno opterećenje za 15.04., str. 43.

Tablica 15. Radno opterećenje za 16.04., str. 44.

Tablica 16. Radno opterećenje za 07.07., str. 45.

Tablica 17. Radno opterećenje za 08.07., str. 46.

Tablica 18. Radno opterećenje za 09.07., str. 47.

Tablica 19. Radno opterećenje za 11.08., str. 48.

Tablica 20. Radno opterećenje za 12.08., str. 49.

Tablica 21. Radno opterećenje za 13.08., str. 50.

Tablica 22. Usporedba kompleksnosti, radnog opterećenja i prometa, str. 52.

Tablica 23. Kompleksnost, radno opterećenje i promet po mjesecima, str. 52.

POPIS GRAFIKONA

Grafikon 1. Prikaz radnog opterećenja za LDZOFIR za 27.01., str. 39.

Grafikon 2. Prikaz radnog opterećenja za LDZOTOT za 27.01., str. 39.

Grafikon 3. Prikaz radnog opterećenja za LDZOFIR za 28.01., str. 40.

Grafikon 4. Prikaz radnog opterećenja za LDZOTOT za 28.01., str. 40.

Grafikon 5. Prikaz radnog opterećenja za LDZOFIR za 29.01., str. 41.

Grafikon 6. Prikaz radnog opterećenja za LDZOTOT za 29.01, str. 41.

Grafikon 7. Prikaz radnog opterećenja za LDZOFIR za 14.04., str. 42.

Grafikon 8. Prikaz radnog opterećenja za LDZOTOT za 14.04., str. 42.

Grafikon 9. Prikaz radnog opterećenja za LDZOFIR za 15.04., str. 43.

Grafikon 10. Prikaz radnog opterećenja za LDZOTOT za 15.04., str. 43.

Grafikon 11. Prikaz radnog opterećenja za LDZOFIR za 16.04., str. 44.

Grafikon 12. Prikaz radnog opterećenja za LDZOTOT za 16.04., str. 44.

Grafikon 13. Prikaz radnog opterećenja za LDZOFIR za 07.07., str. 45.

Grafikon 14. Prikaz radnog opterećenja za LDZOTOT za 07.07., str. 45.

Grafikon 15. Prikaz radnog opterećenja za LDZOFIR za 08.07., str. 46.

Grafikon 16. Prikaz radnog opterećenja za LDZOTOT za 08.07., str. 46.

Grafikon 17. Prikaz radnog opterećenja za LDZOFIR za 09.07., str. 47.

Grafikon 18. Prikaz radnog opterećenja za LDZOTOT za 09.07., str. 47.

Grafikon 19. Prikaz radnog opterećenja za LDZOFIR za 11.08., str. 48.

Grafikon 20. Prikaz radnog opterećenja za LDZOTOT za 11.08., str. 48.

Grafikon 21. Prikaz radnog opterećenja za LDZOFIR za 12.08., str. 49.

Grafikon 22. Prikaz radnog opterećenja za LDZOTOT za 12.08., str. 49.

Grafikon 23. Prikaz radnog opterećenja za LDZOFIR za 13.08., str. 50.

Grafikon 24. Prikaz radnog opterećenja za LDZOTOT za 13.08., str. 50.

Grafikon 25. Konfiguracije sektora 13.08., str. 51.

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

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

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

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

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu diplomskog rada pod naslovom **Određivanje indikatora kompleksnosti i radnog opterećenja na sektorima oblasne kontrole Zagreb programom NEST** na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, 12.9.2018

Ria Bazina
(potpis)