Istraživanje funkcionalnosti upravljanja europskim zračnim prostorom

Rezo, Zvonimir

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:119:268179

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

Zvonimir Rezo

ISTRAŽIVANJE FUNKCIONALNOSTI UPRAVLJANJA EUROPSKIM ZRAČNIM PROSTOROM

DIPLOMSKI RAD

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 16. ožujka 2018.

Zavod: **Zavod za zračni promet**
Predmet: **Planiranje u zračnom prometu**

DIPLOMSKI ZADATAK br. 4485

Pristupnik: **Zvonimir Rezo (0135233911)**
Studij: Promet
Smjer: Zračni promet

Zadatak: **Istraživanje funkcionalnosti upravljanja europskim zračnim prostorom**

Opis zadatka:

Uvodno opisivanje predmeta istraživanja. Postavljanje svrhe i cilja istraživanja. Pregled strukture diplomskog rada.
Pretraživanje i obrada bibliografskih izvora u tematici rada.
Analiza sustava upravljanja zračnim prostorom u Europi.
Elaboracija problematike fragmentiranosti europskoga zračnog prostora.
Pregled statusa funkcionalne regionalizacije europskog zračnog prostora.
Opis metodologije istraživanja homogenosti i fragmentiranosti zračnog prostora.
Koncepcijska postavka alata za valorizaciju prometnog učinka i njegove aplikacije u zrakoplovnoj operativi.
Sintetiziranje rezultata istraživanja i zaključno rezimiranje diplomskog rada.
Specifikacija korištene literature i izvora.

Mentor:

prof. dr. sc. Sanja Steiner

Predsjednik povjerenstva za diplomski ispit:

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

DIPLOMSKI RAD

ISTRAŽIVANJE FUNKCIONALNOSTI UPRAVLJANJA EUROPSKIM ZRAČNIM PROSTOROM

RESEARCH OF EUROPEAN AIRSPACE MANAGEMENT FUNCTIONALITY

Mentor: prof.dr.sc. Sanja Steiner

Student: Zvonimir Rezo

JMBAG: 0135233911

Zagreb, rujan 2018.

Sažetak

Prostorno neuravnotežen razvoj zračnog prometa na području Europe rezultirao je eskalacijom negativne dimenzije zračnog prometa koja se ponajbolje očitava kašnjenjima zrakoplova zbog nedostatka kapaciteta zračnog prostora. Provedeno istraživanje funkcionalnosti upravljanja europskim zračnim prostorom temelji se na metodologiji istraživanja prostorne autokorelacije 39 područja odgovornosti europskih pružatelja usluga u zračnoj plovidbi. U okviru provedenog istraživanja analizirana je ukupna površina europskog zračnog prostora veličine 17.917.600 km^2 na kojoj je tijekom 2017. godine ostvaren promet u veličini od 10,6 milijuna letova te je ukupno generirano 9.258.980 minuta rutnih kašnjenja zrakoplova. Na temelju provedenih 15 istraživanja, odnosno 45 analiza podataka i 43.860 matematičkih operacija omogućen je detaljan prikaz razine funkcionalnosti upravljanja europskim zračnim prostorom tijekom 2017. godine, kao i donošenje odgovarajućih zaključaka.

Ključne riječi: upravljanje zračnim prostorom; europski zračni prostor; pružatelji usluga u zračnoj plovidbi; prostorna autokorelacija;

Summary:

Spatially unbalanced development of air traffic in Europe has resulted in escalation of negative air traffic dimension which is most evident in aircraft delays due to lack of airspace capacity. The conducted research of European airspace management functionality is based on the spatial autocorrelation methodology of 39 European Air Navigation Service Providers' responsibility areas. The research covered 17,917,600 km^2 of the European airspace with turnover of 10.6 million flights in 2017 and 9,258,980 minutes of en-route aircraft delays. Taking into consideration 15 prior surveys, i.e. 45 data analyzes and 43,860 mathematical operations, an adequate European airspace management functionality level and appropriate conclusions have been provided.

Key words: Airspace Management; European airspace; Air Navigation Service Providers; Spatial autocorrelation;

Sadržaj

1. UVOD 1
1.1. Struktura rada 2
1.2. Pregled bibliografskih izvora 3
1.3. Svrha i ciljevi istraživanja 3
2. SUSTAV UPRAVLJANJA ZRAČNIM PROSTOROM (ASM) U EUROPI 6
3. PROBLEMATIKA FRAGMENTIRANOSTI EUROPSKOG ZRAČNOG PROSTORA 10
4. FUNKCIONALNA REGIONALIZACIJA EUROPSKOG ZRAČNOG PROSTORA 12
5. ISTRAŽIVANJE FUNKCIONALNOSTI UPRAVLJANJA ZRAČNIM PROSTOROM 14
5.1. Pristup modeliranja stvarnog okruženja 14
5.1.1. Tehnička izrada i praktični dio rada programa 16
5.1.2. Opis skupa podataka 20
5.1.3 Analitičko istraživanje skupa podataka 24
5.1.3.1. Analiza žarišnih područja europskog zračnog prostora 25
5.1.3.2. Analiza prostornog klasteriranja europskog zračnog prostora 26
5.1.3.3. Analiza prostorno atipičnih vrijednosti europskog zračnog prostora 28
5.2. Rezultati istraživanja 29
5.2.1. Rezultati analize žarišnih područja europskog zračnog prostora 30
5.2.2. Rezultati analize prostornog klasteriranja europskog zračnog prostora 34
5.2.3. Rezultati analize prostorno atipičnih vrijednosti europskog zračnog prostora 38
5.3. Analiza rezultata istraživanja 42
6. PRIJEDLOG OPERATIVNOG KONCEPTA ZA UNAPRJEĐENJE ASM SUSTAVA 47
7. ZAKLJUČAK 50
LITERATURA 53
POPIS KRATICA 58
POPISA SLIKA 61
POPIS GRAFIKONA 62
POPIS TABLICA 63
PRILOZI 64

1. UVOD

Zračni prostor predstavlja ograničen resurs, te način na koji je organiziran kao i struktura ruta koju sadrži utječe na kapacitet zračnog prostora. Sustav upravljanja zračnim prostorom može biti više ili manje učinkovit, a kao jedna od najočitijih posljedica neučinkovitog upravljanja, odnosno nedostatka kapaciteta jest pojava kašnjenja zrakoplova i s njima povezanih troškova. Zbog izrazito neprihvatljive razine kašnjenja zrakoplova tijekom 1990-ih godina, na razini cjelokupne europske rutne mreže uložena su znatna financijska sredstva s ciljem minimiziranja njihove buduće pojavnosti. Od tada je kao preventivna mjera praćenja učinkovitosti sustava uvedena kontinuirana kontrola mjerenja kašnjenja zrakoplova na razini cjelokupne europske rutne mreže.

Na području europskog zračnog prostora prometna potražnja već se godinama kontinuirano povećava te se kao jedan od budućih glavnih izazova europskog sustava upravljanja zračnim prostorom javlja pitanje razvoja novog koncepta koji će imati mogućnost odgovoriti na buduću prometnu potražnju. No prije ciljane implementacije novih rješenja i provedbe različitih projekata unaprjeđenja trenutnog sustava, potrebno je unaprijediti razinu učinkovitosti upravljanja zračnim prostorom na disfunkcionalnim područjima. Disfunkcionalnost sustava se ponajprije može očitati na područjima izloženosti korisnika zračnog prostora velikim dodatnim financijskim troškovima uzrokovanih kašnjenjima zrakoplova.

U okviru provedenog istraživanja analizirana je ukupna površina europskog zračnog prostora veličine od 17.917.600 km^2 na kojoj je tijekom 2017. godine ostvaren promet u veličini od 10,6 milijuna letova, te je ukupno generirano 9.258.980 minuta rutnih kašnjenja zrakoplova. Istraživanje se temelji na metodologiji istraživanja prostorne autokorelacije 39 područja odgovornosti europskih pružatelja usluga u zračnoj plovidbi. Osnovu istraživanja predstavlja matematički model iz kojeg je kasnije kreiran program AirStat, koji se dugoročno može primjenjivati za vrednovanje učinaka zračnog prometa na području Europe, a u sklopu metodologije strateškog planiranja prometa zračnih prijevoznika, pružatelja usluga u zračnoj plovidbi, agencija civilnog zrakoplovstva, akademskih i istraživačkih ustanova te ostalih zainteresiranih dionika.

1.1. Struktura rada

Rad pod naslovom *Istraživanje funkcionalnosti upravljanja europskim zračnim prostorom* sastoji se od sljedećih sedam poglavlja:

1. Uvod
2. Sustav upravljanja zračnim prostorom (ASM) u Europi
3. Problematika fragmentiranosti europskog zračnog prostora
4. Funkcionalna regionalizacija europskog zračnog prostora
5. Istraživanje funkcionalnosti upravljanja zračnim prostorom
6. Prijedlog operativnog koncepta za unaprjeđenje ASM sustava
7. Zaključak.

Nakon uvodnog dijela rada, opisa svrhe i ciljeva istraživanja te pregleda korištenih bibliografskih izvora, slijedi drugo poglavlje u kojemu je opisan europski sustav upravljanja zračnim prostorom *(engl. Airspace Management - ASM).*

U trećem poglavlju opisana je problematika fragmentiranosti europskog zračnog prostora, dok je u nastavku rada četvrtim poglavljem definirana razina funkcionalne regionalizacije europskog zračnog prostora.

U petom poglavlju opisana je metodologija istraživanja, tj. novokreirani programa AirStat, njegova tehnička izrade te praktičnog dio rada programa. Nakon opisa skupa podataka na temelju kojih je provedeno istraživanje, slijedi opis korištenih analitičkih metoda integriranih u okviru programa AirStat. Također, u sklopu petog poglavlja prikazani su rezultati istraživanja funkcionalnosti upravljanja europskim zračnim prostorom za 2017. godinu koji se u nastavu istog poglavlja interpretiraju.

U okviru šestog poglavlja definirane su smjernice operativnog koncepta za unaprjeđenje ASM sustava na području Europe, dok su u zaključnom sedmom poglavlju sintetizirani najvažniji rezultati istraživanja.

1.2. Pregled bibliografskih izvora

U okviru provedenog istraživanja korišteni su različiti bibliografski izvori poput znanstvenih i stručnih radova, zakonodavni akti, smjernice kojima je globalno, regionalno i nacionalno definiran sustav upravljanja zračnim prostorom, te različita izvješća s kojima su uspoređeni rezultati istraživanja. U odnosu na ukupno korištenu literaturu, većinski dio odnosi se na znanstvene i stručne radove čime je osigurana adekvatna metodološka podloga istraživanju. Od preostalog dijela korištene literature, najveći dio referira Eurocontrolova izvješća, priručnike i smjernice, kojima je opisano područje istraživanja i koji su usko vezani uz temu istraživanja. Sveobuhvatno gledano, zajedničke karakteristike korištene literature jesu provjerljivost te vjerodostojnost publiciranih informacija i podataka čime je osigurana reprezentativnost provedenog istraživanja.

1.3. Svrha i ciljevi istraživanja

Sustav upravljanja zračnim prometom *(engl. Air Traffic Management - ATM)* predstavlja kompleksni sustav u kojem je potrebno prije bilo kakvog donošenja odluka ili prihvaćanja promjena u okviru postojećeg sustava, primjenom različitih simulacijskih modela provesti prognoziranja i ispitivanja funkcionalnosti novog sustava.

Dosadašnja primjena strategijskog planiranja operacija zračnog prometa rezultirala je stvaranjem neuravnoteženog razvoja zračnog prometa na području Europe. Europska komisija, različiti predstavnici zračnih prijevoznika, kao i mnogi autori različitih stručnih i znanstvenih radova prepoznaju fragmentiranost europskog zračnog prostora kao jedan od uzroka neučinkovitosti i disfunkcionalnosti europskog sustava upravljanja zračnim prometom.

Zbog kontinuiranog porasta potražnje za uslugama zračnog prometa, planiranje zračnog prometa više se ne može temeljiti na zadovoljavanju prometne potražnje samo u bliskoj budućnosti. Rast zračnog prometa mora se kontrolirati i ciljano kanalizirati modeliranjem različitih opcija s ciljem upravljanja budućom potražnjom. Eurocontrol *(engl. European Organisation for the Safety of Air Navigation)* u studiji *Challenges of Air Transport 2030: Survey of expert' views* zaključuje da bi u budućnosti potražnja za uslugama zračnog prometa

mogla biti izrazito prostorno promjenjiva [1] što čini istraživanja na temu funkcionalnosti upravljanja europskim zračnim prostorom vrlo važnima.

Također, neuravnotežen razvoj zračnog prometa na području Europe rezultirao je eskalacijom negativne dimenzije zračnog prometa (što se ponajbolje očituje u zagušenjima zračnih prostora i ruta te kašnjenjima letova) što pridonosi izravnoj ekološkoj škodljivosti zračnog prometa. Uz već spomenute negativne dimenzije zračnog prometa, želja zrakoplovnih operatora da lete na ekonomičnim i nerijetko dužim rutama dodatno pridonosi negativnom utjecaju zračnog prometa na okoliš.

Izbor teme istraživanja temeljen je na aktualnosti problematike i važnosti praćenja promjena koje se javljaju u okviru sustava upravljanja zračnim prometom na regionalnoj i europskoj razini, a koje se odražavaju i na koncepcije nacionalnih programa razvoja i upravljanja zračnim prometom i prostorom. Svrha rada jest razviti metodologiju i prikazati mogućnosti primjene programa AirStat na primjeru istraživanja funkcionalnosti upravljanja europskim zračnim prostorom tijekom 2017. godine.

S naprednim razvojem računala, stvoreni su ili ponovno uvedeni mnogi prostorno-tehnički algoritmi s ciljem statističkih mjerenja različitih vrsta prostorne disperzije. Primjenom računala olakšana je identifikacija i rješavanje prostornih problema uključujući rješenje problema sakupljanja, spremanja, vizualizacije i analize prostornih podataka. Program AirStat, izrađen za potrebe ovog istraživanja, temelji se na matematičkom modelu koji istražuje prostornu autokorelaciju područja odgovornosti 39 europskih pružatelja usluga u zračnoj plovidbi. Prostornom autokorelacijom mjeri se i homogenost europskog zračnog prostora, stupanj po kojemu je neki prostorni fenomen u korelaciji sam sa sobom u prostoru te razina ovisnosti susjednih vrijednosti.

U sklopu rada provedeno je kvantitativno istraživanje koje za cilj ima odgovoriti na sljedeća istraživačka pitanja:

- kakve karakteristike vrijednosti obuhvaćaju određena područja europskog zračnog prostora,
- gdje su javljaju klasteri i koliki je intenzitet grupiranja (klasteriranja),
- razlikuju li se prostorne vrijednosti (indikatori) i koje su najčešće vrijednosti (indikatori),

- gdje se javljaju prostorno atipične vrijednosti i koliki je njihov obuhvat,
- gdje se nalaze žarišta izrazito visokih ili niskih vrijednosti,
- postoji li prostorna autokorelacija i kolika je jačina povezanosti pružatelja usluga u zračnoj plovidbi u ovisnosti o prostornoj disperziji istraživnih vrijednosti,
- jesu li odnosi konzistentni na cijelom području istraživanja, tj. postoji li jednoobrazan prostorni uzorak.

2. SUSTAV UPRAVLJANJA ZRAČNIM PROSTOROM (ASM) U EUROPI

Zračnim prostorom neke države smatra se prostor iznad kopna i mora koji se podudara s državnom granicom, a visinom od površine mora ili kopna je neograničen. U tom prostoru država ima potpun i nepovrediv suverenitet [2]. Zračni prostor predstavlja ograničen resurs, te način na koji je organiziran i struktura ruta koju sadrži utječe na kapacitet zračnog prostora. Kapacitet zračnog prostora veći je od kapaciteta kontrole zračnog prometa *(engl. Air Traffic Control - ATC)* utoliko što se zračni prostor dijeli na kontrolirani i nekontrolirani te se za izračun kapaciteta kontrole zračnog prometa uzima u obzir samo kontrolirani zračni prostor [3]. Kapacitet zračnog prostora predstavlja maksimalni broj zrakoplova koji može ući u određeni zračni prostor zadajući kontrolu zračnog prometa *(engl. Air Traffic Control Officer - ATCO)* određeni nivo radnog opterećenja koji on mora odraditi na siguran način u određenom vremenskom razdoblju [4].

Današnja podjela zračnog prostora i zračnih puteva evoluirala je u skladu s fiksnim rutnim strukturama temeljenim na zemaljskim komunikacijskim, navigacijskim i nadzornim *(engl. Communication, Navigation and Surveillance - CNS)* sustavima. Unapređenja koja su se dogodila u zrakoplovnim sustavima i sustavima samo-određivanja pozicije zrakoplova, omogućila su zrakoplovima manju ovisnost o fiksnim navigacijskim pomagalima i rutama, te povećala mogućnost letenja fleksibilnijim, ekonomičnijim, preciznijim i slučajnim putanjama.

Svrha upravljanja zračnim prometom je ostvarivanje ravnoteže između potražnje i kapaciteta sustava zračnog prometa kako bi se osiguralo optimalno i učinkovito korištenje zračnog prostora. Upravljanje zračnim prostorom može se opisati kao proces pomoću kojeg se zračni prostor organizira u skladu sa zahtjevima korisnika zračnog prostora *(engl. Airspace Users - AU)*. Također, ASM sustav za cilj ima održavanje efikasne razine korištenja zračnog prostora na temelju trenutnih potreba, gdje je to moguće, uz izbjegavanje trajnog odvajanja određenih struktura zračnog prostora.

Potreba za unaprjeđenjem sustava upravljanja zračnim prostorom prepoznata je krajem 1990-ih godina. Zbog povećanja potražnje za uslugama zračnog prometa premašeni su kapaciteti europskih centara oblasnih kontrola zračnog prometa *(engl. Area Central Centre - ACC)* što je za posljedicu imalo veliki broj kašnjenja letova. Početkom 1990-ih Europska konferencija civilnog

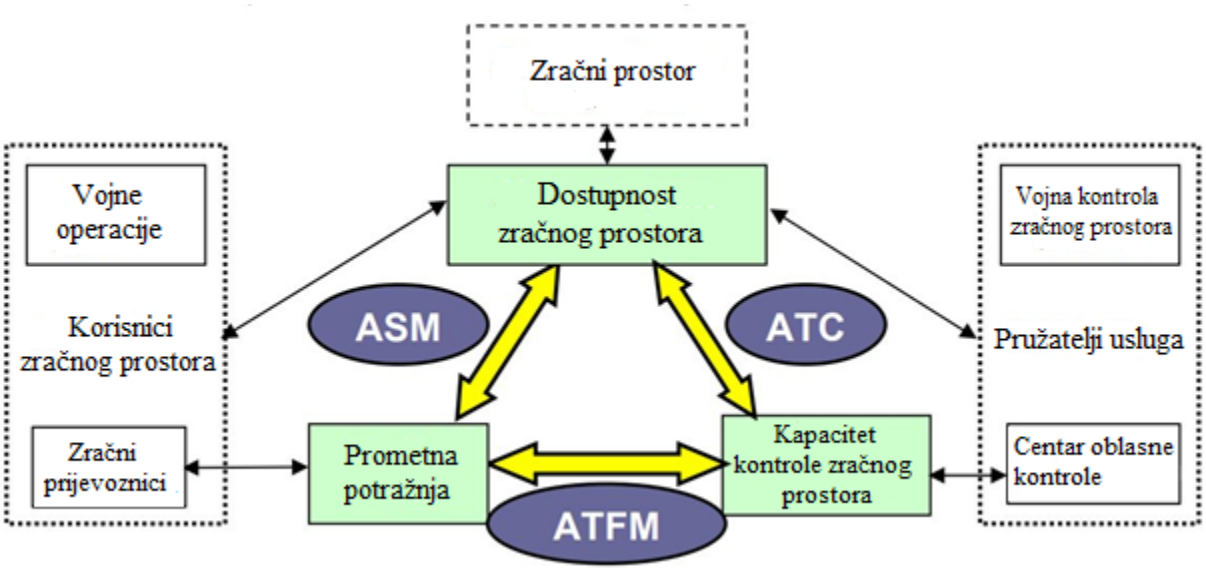
zrakoplovstva *(engl. European Civil Aviation Conference - ECAC)* je usvojila „En-route“ strategiju i europski harmonizacijski i integracijski program kontrole zračnog prometa *(engl. European Air Traffic Control Harmonisation and Integration Programme - EATCHIP)* s ciljem povečanja kapaciteta europskog zračnog prostora. Od tada se pri upravljanju europskim zračnim prostorom primjenjuju sljedeći principi [3]:

- zračni prostor treba biti fleksibilan i dinamički upravljan,
- struktura zračnog prostora temeljit će s na prometnoj potražnji dok će se sektorske granice prilagoditi prevladavajućim tokovima,
- zračni prostor bit će nadziran i koordiniran,
- rezervacije zračnog prostora planirat će se unaprijed,
- fleksibilno upravljanje zračnim prostorom evoluirat će u dinamičko upravljanje zračnim prostorom,
- strukturirani tokovi zračnog prometa primjenjivat će se na prostoru gdje je potrebno povećanje kapaciteta ili gdje se pokušava izbjeći prostor s ograničenim pristupom,
- slobodan odabir putanja leta zrakoplova poticat će razvoj novih alata i tehnologija.

Iako se uz domenu upravljanja zračnim prostorom uglavnom vežu poslovi civilno-vojne suradnje te fleksibilne upotrebe struktura zračnog prostora, provedeno istraživanje funkcionalnosti upravljanja europskim zračnim prostorom temelji se na podacima koji nisu isključivo vezani uz navedene elemente sustav upravljanja zračnim prostorom. S obzirom na to da je u okviru europskog ATM sustava izrazito naglašena uzročno-posljedična veza i da je nekad teško jasno definirati što je uzrok, a što posljedica neučinkovitosti ATM sustava, kao referentni podaci korištene su vrijednosti rutnih kašnjenja zrakoplova koje su zabilježene u sklopu sustava upravljanja protokom i kapacitetima zračnog prostora *(engl. Air Traffic Flow and Capacity Management - ATFCM)*.

Analizom spomenutih podataka omogućeno je sveobuhvatno istraživanje funkcionalnosti upravljanja europskim zračnim prostorom koje ne istražuje uzroke kašnjenja (bilo to kriva alokacija struktura zračnog prostora, vojne aktivnosti/letovi, rezervacije zračnog prostora...) nastale primjenom mjera ASM sustava ili primjena regulacija na letova koje su rezultat primjene mjera ATFCM sustava, već pregled trenutnog stanja uzimajući sve navedene elemente u obzir.

Slika 1 prikazuje međuovisnost elemenata sustava upravljanja zračnim prometom i interakciju glavnih elemenata.



Slika 1. ATM/ASM/ATFCM odnos, [5]

Proces upravljanja zračnim prostorom, kao i proces upravljanja protokom i kapacitetima zračnog prostora, čine tri faze upravljanja (strateška, pred-taktička i taktička) koje za cilj imaju maksimizirati iskorištenje raspoloživog zračnog prostora putem [3]:

- aktiviranja i deaktiviranja dijelova zračnog prostora u određenim vremenskim razdobljima (tzv. dinamička sektorizacija i fleksibilno upravljanje zračnim prostorom),
- podjele zračnog prostora između različitih kategorija korisnika na bazi kratkoročnih potreba (npr. za vojno letenje i za komercijalni promet).

Proces planiranja sustava upravljanja zračnim prostorom počinje i do sedam godina prije dana izvršenja leta zrakoplova strateškim planiranjem zračnog prometa. Upravljanje zračnim prostorom na strateškoj razini sastoji se od zajedničkog civilno-vojnog procesa upravljanja koji je uspostavljen u svim državama članicama ECAC-a od strane Nacionalnog povjerenstva za upravljanje zračnim prostorom *(engl. High Level Airspace Policy Body).* Nacionalno povjerenstvo formulira politiku upravljanja zračnim prostorom, te se bavi strateškim planiranjem uzimajući u obzir zahtjeve nacionalnih i međunarodnih korisnika zračnog prostora te pružatelja usluga u zračnoj plovidbi.

Pred-taktička faza sustava upravljanja zračnim prostorom sastoji se od dnevnog upravljanja i privremene alokacije zračnog prostora kroz nacionalne i subregionalne Jedinice za upravljanje zračnim prostorom *(engl. Airspace Management Cell - AMC)*. Procesi na pred-taktičkoj razini planiranja zračnog prometa nastavak su i nadogradnja procesa strateškog planiranja. Na ovoj razini svi sudionici unapređuju Plan mrežnih operacija *(engl. Network Operations Plan – NOP)*:

- identifikacijom rješenja za detekciju manjka kapaciteta,
- planiranjem rizika za taktičku razinu,
- dogovorom o vrijednostima prometne potražnje i kapaciteta.

Razlika pred-taktičke i strateške faze planiranja očituje se u varijacijama sljedećih podataka:

- prometne potražnje koja je izražena kao 4D planirana putanja leta zrakoplova, gdje zrakoplovni operateri korištenjem sustava za planiranje leta proračunavaju 4D profil leta te ga pohranjuju u sustav upravljanja letom *(engl. Flight Management System - FMS),*
- kapaciteti zračnih luka pouzdanije reflektiraju dostupnost usluga i objekata,
- vremenska prognoza je pouzdanija sa svakim satom bliže operaciji.

Nedostaci kapaciteta koji ne mogu biti riješeni na pred-taktičkoj razini riješit će se na taktičkoj razini. Taktička faza planiranja pokriva period od 2 sata prije operacije pa do polijetanja zrakoplova. Procesi taktičke faze uzimaju u obzir realne podatke i događaje, te konstantno nadopunjuju Plan mrežnih operacija i prate trenutnu situaciju s ciljem minimiziranja potencijalnih negativnih posljedica. Taktičko upravljanje zračnim prostorom sastoji se od aktivacije, deaktivacije ili realokacije zračnog prostora u stvarnom vremenu alociranom na pred-taktičkoj razini, te rješavanja specifičnih problema zračnog prostora i prometnih situacija između civilnih i vojnih jedinica kontrole zračnog prometa. Dostupnost podataka u realnom vremenu, kao i aktivnosti kontrolora zračnog prometa omogućavaju optimizirano korištenje zračnog prostora što smanjuje potrebu za razdvajanjem zračnog prostora [6]

3. PROBLEMATIKA FRAGMENTIRANOSTI EUROPSKOG ZRAČNOG PROSTORA

U 2017. godini na području europskog zračnog prostora ostvareno je 10,6 milijuna letova s prosječnim vremenom polijetanja svake 3 sekunde [7] što odgovara zaključcima Miheteca i suautora u [8] koji zaključuju da se uz trenutnu zadaću sigurnog razdvajanja zrakoplova pred budući sustav upravljanja zračnim prometom postavlja imperativ osiguranja dodatnog kapaciteta zračnog prostora kako bi se pariralo prognoziranom povećanju prometne potražnje. Predviđeni rast zračnog prometa u narednih dvadeset godina zahtijeva implementaciju inovativnih metoda, rješenja i procedura kojima bi se trenutna učinkovitost sustava upravljanja zračnim prometom poboljšala.

Europski sustav upravljanja zračnim prometom izrazito je fragmentiran s obzirom na broj pružatelja usluga u zračnoj plovidbi, brojne ranije aktivnosti i inicijative Europske komisije i uvođenja različitih regulatornih paketa kojima se nastojala umanjiti fragmentiranost i pospješiti učinkovitost i homogenost sustava. Prema Strategiji zrakoplovstva za Europu [9], troškovi rascjepkanog europskog zračnog prostora procjenjuju se na najmanje pet milijardi eura godišnje te imaju negativni utjecaj na kompetitivnost zračnih prijevoznika.

Različiti autori definiraju različite uzroke, posljedice i smjernice razvoja europskog zračnog prometa s ciljem nadvladavanja trenutne fragmentiranosti europskog zračnog prostora. Steiner i suautori [10] zaključuju da problem fragmentiranosti treba biti riješen sveobuhvatnim programima dinamičke harmonizacije koji mogu pridonijeti efektivnom povećanju kapaciteta zračnog prometa. Eurocontrol smatra da je fragmentaciju teško prevladati zbog postojanja različitih interesnih skupina na području Europe. Očekuje da će europski zračni prostor biti fragmentiran sve dok Europa ne bude imala integrirani europski obrambeni sustav, te da će države i dalje preko vlastitih pružatelja usluga u zračnoj plovidbi nadzirati i upravljati zračnim prostorima s ciljem zaštite vlastitog državnog suvereniteta [1].

Mnoge razvojne inicijative predviđaju smanjenje fragmentarnosti europskog sustava upravljanja zračnim prometom kroz sinkronizaciju i integraciju planova i aktivnosti kroz dvije faze - od istraživanja i tehničke implementacije do operativne provedbe programa. K tome, strateški razvojni programi europskog zračnog prostora za cilj imaju rješavanje problema fragmentiranosti regionalizacijom ATM sustava [11].

Jedan od takvih primjera jest i inicijativa „Jedinstveno europsko nebo“ *(engl. Single European Sky - SES)* kojom se nastoji povećati učinkovitost upravljanja zračnim prometom i uslugama u zračnoj plovidbi restrukturiranjem i smanjenjem rascjepkanosti europskog zračnog prostora na temelju zračnih tokova, a ne na temelju nacionalnih granica. U okviru zakonodavnog paketa „Jedinstvenog europskog neba“ definiran je koncept Funkcionalnih blokova zračnog prostora *(engl. Functional Airspace Block - FAB)* koji predstavljaju glavni alat za smanjenje rascjepkanosti europskog zračnog prostora. Mihetec i suautori u radu iz 2017. godine ističu da iako je planiranje inicijative „Jedinstveno europsko nebo“ temeljeno na zajedničkoj implementaciji ATM Master Plan projekata na razini Funkcionalnih blokova zračnih prostora, stvarna provedba i dalje fragmentirana i temeljena na nacionalnim razinama [12]. K tome, mnogi nacionalni dionici europskog zračnog prometa uglavnom ne mogu odgovarajuće parirati razvojne potrebe ATM sustava [8,10,11]. Uzimajući u obzir da je unutar zadnjih dvadeset godina kao najuočljivija slabost ATM sustava prepoznat problem donošenja odluka na nacionalnim razinama [8], može se zaključiti da taj problem i dalje postoji što za posljedicu ima izrazito fragmentiran europski zračni prostor i veliki broj „decision makera“.

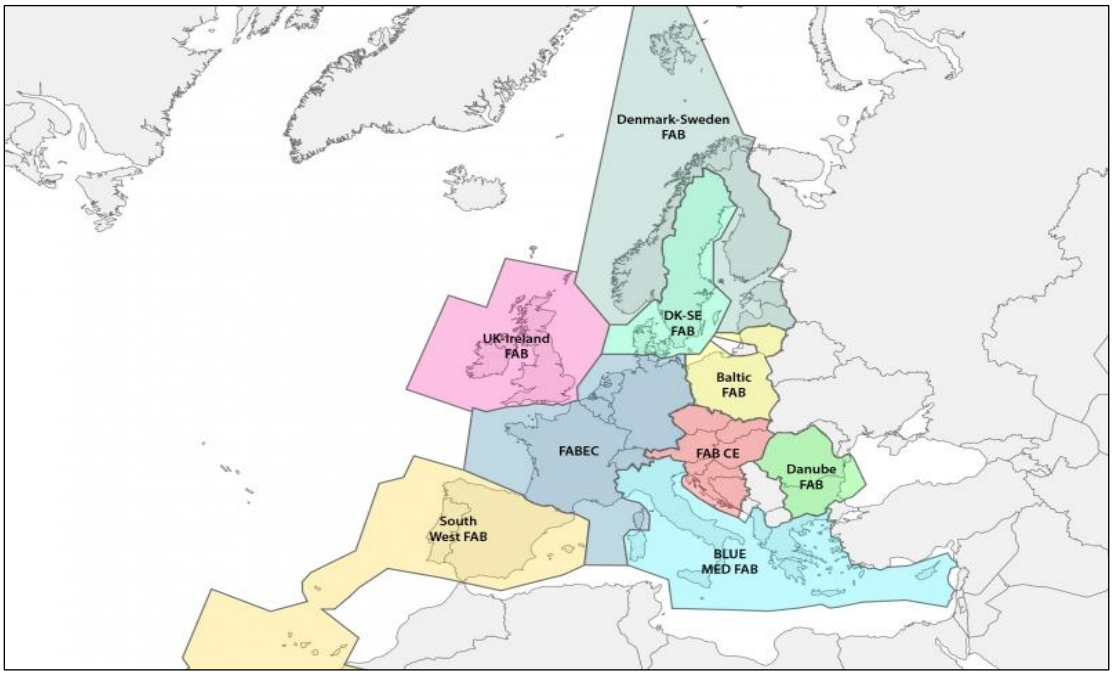
Prema Grebenšek i Magisteru [13], troškovi europskog ATM sustava u usporedbi s drugim sličnim sustavima na svijetu veći su za oko 2-3 milijarde eura godišnje, dok Europska komisija procjenjuje da godišnji promet europskih pružatelja usluga u zračnoj plovidbi iznosi oko sedam milijardi eura, te da 6% prosječne cijene zrakoplovne karte otpada na usluge zračne plovidbe [14].

Strategijsko prometno planiranje temelji se na kompleksu utjecajnih čimbenika te podrazumijeva sustavno izučavanje šire problematike - od geoprometne analize i dinamike prometnih tokova do elemenata prometne politike. Takav opsežan pristup primijenjen je u okviru ovog istraživanja koje predstavlja nastavak prethodno elaboriranih radova te podlogu za buduća ciljana istraživanja. Pri tome, rad se temelji na metodologiji istraživanja prostorne autokorelacije koja se javlja kada su slučajne vrijednosti susjednih varijabli sličnije od vrijednosti udaljenijih varijabli [15, 16] što odgovara Toblerovoj definiciji „prvog zakona geografije“. Sveobuhvatnim pristupom, u okviru istraživanja funkcionalnosti upravljanja europskim zračnim prostorom primijenjena su znanja i metode iz zračnog prometa, geostatistike i ekonometrije.

4. FUNKCIONALNA REGIONALIZACIJA EUROPSKOG ZRAČNOG PROSTORA

Ključ racionalnije organizacije europskog zračnog prostora leži u integraciji pograničnih prostora kroz funkcionalne blokove zračnog prostora. Program razvitka devet funkcionalnih blokova zračnog prostora predstavlja se kao glavna pokretačka snaga u implementaciji inicijative „Jedinstveno europsko nebo“. Funkcionalni blokovi zračnog prostora predstavljaju zračni prostor koji se temelji na operativnim zahtjevima, upućujući na potrebu za integriranim pristupom upravljanja zračnim prostorom, unatoč postojećim državnim granicama. Općenito se FAB-ovi, prikazani slikom 2, smatraju alatom kojim se nastoji reducirati fragmentacija europskog zračnog prostora povećavajući pri tome razinu sigurnosti i ukupnu učinkovitost ATM sustava optimizirajući rast potražnje za kapacitetom, te minimizirajući kašnjenja zrakoplova [17].

Pravilnik o upravljanju zračnim prostorom [18] definira FAB kao „blok zračnog prostora utvrđen na temelju operativnih zahtjeva, zbog potrebe osiguranja cjelovitijeg upravljanja zračnim prostorom bez obzira na postojeće državne granice“. Definicija FAB-a uključuje proces zajedničkog donošenja odluka svih sudionika u procesu implementacije i operativnog djelovanja funkcionalnog bloka zračnog prostora. Dok države članice ECAC-a pružaju kontinuiranu političku podršku razvoju FAB-ova, tehnički dio razvoja provodi se od strane pružatelja usluga u zračnoj plovidbi.

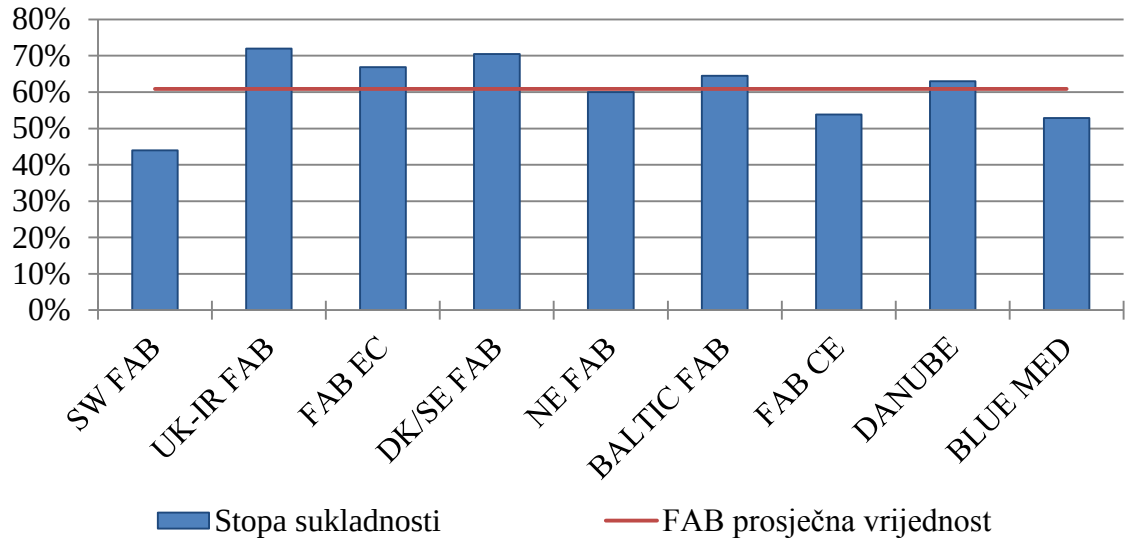


Slika 2. Funkcionalni blokovi zračnog prostora, [19]

Europska komisija dala je mandat Eurocontrolu za pružanje podrške državama članicama i pružateljima usluga u zračnoj plovidbi pri implementaciji funkcionalnih blokova zračnog prostora. Države koje participiraju u FAB-u moraju osigurati da blokovi zračnog prostora [3]:

- budu podržani sigurnosnim planovima,
- osiguraju optimum zračnog prostora (uzimajući u obzir tokove zračnog prometa),
- budu opravdani dodatnom vrijednosti (optimalno iskorištenje tehničkih i ljudskih resursa)
- osiguraju fleksibilan prijenos odgovornosti između jedinica kontrole zračne prometa,
- osiguraju kompatibilnost konfiguracije gornjeg i donjeg zračnog prostora.

U sklopu rada „Assessment of Single European Sky implementation in Functional Airspace Block Central Europe“ [12] komparativnom analizom devet funkcionalnih blokova zračnog prostora, odnosno primjenom metodologije praćenja stope sukladnosti, prikazana je razina implementacije projekata definiranih ATM Master Planom. Na temelju podataka iz navedenog rada, grafikon 1 prikazuje status funkcionalne regionalizacije europskog zračnog prostora.



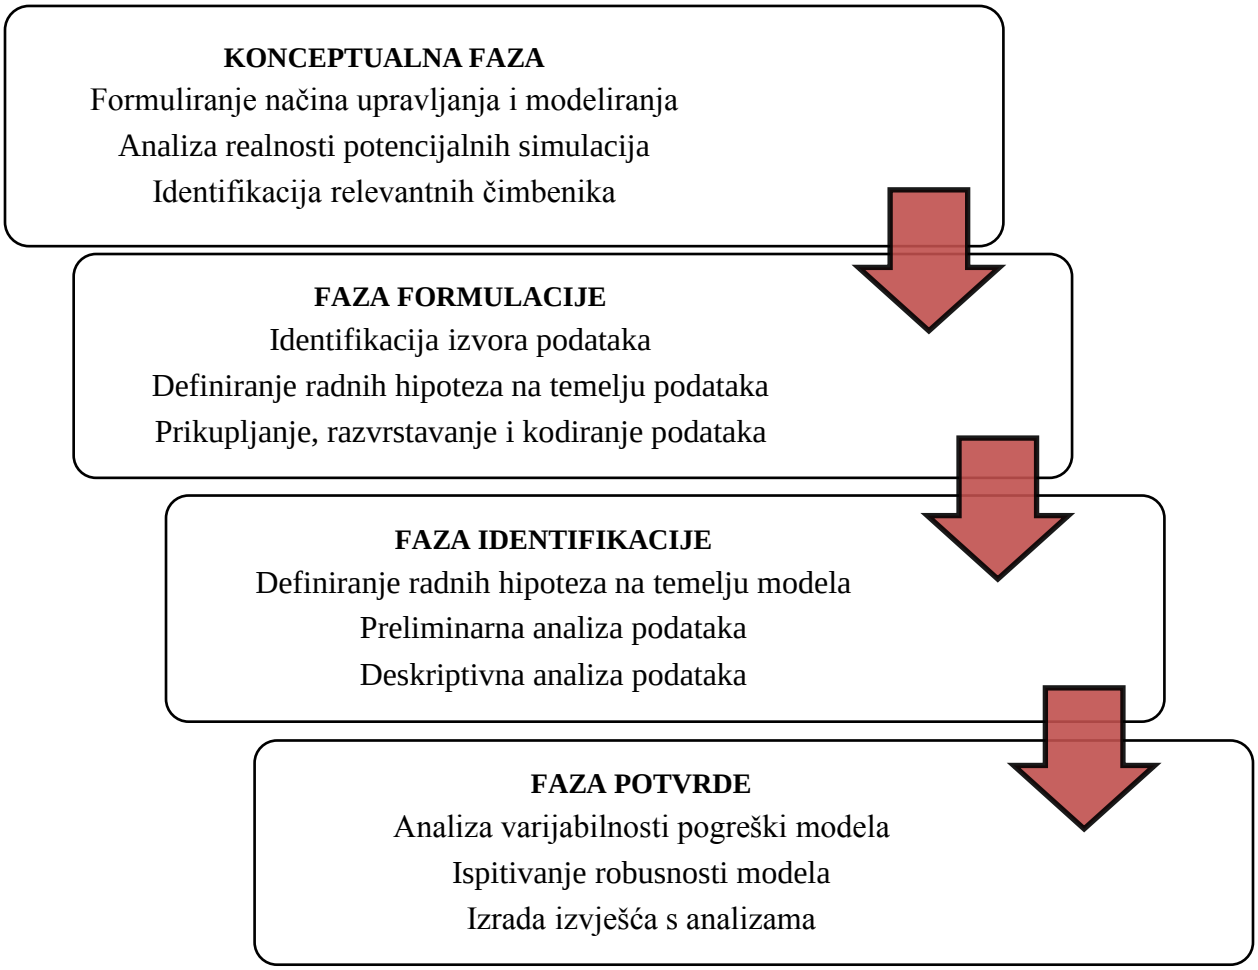
Grafikon 1. FAB razina implementacije ATM Master Plan Level 3 projekata (2015), [12]

Na temelju prikazanih podataka moguće je zaključiti da je razina implementacije projekata definiranih ATM Master Planom nije jednolika u svim područjima europskog zračnog prostora. Stoga će države članice, ukoliko žele poduprijeti inicijativu „Jedinstveno europsko nebo“ kroz dogledno vrijeme trebati uložiti dodatne napore s ciljem reduciranja trenutne razine fragmentiranosti europskog zračnog prostora.

5. ISTRAŽIVANJE FUNKCIONALNOSTI UPRAVLJANJA ZRAČNIM PROSTOROM

5.1. Pristup modeliranja stvarnog okruženja

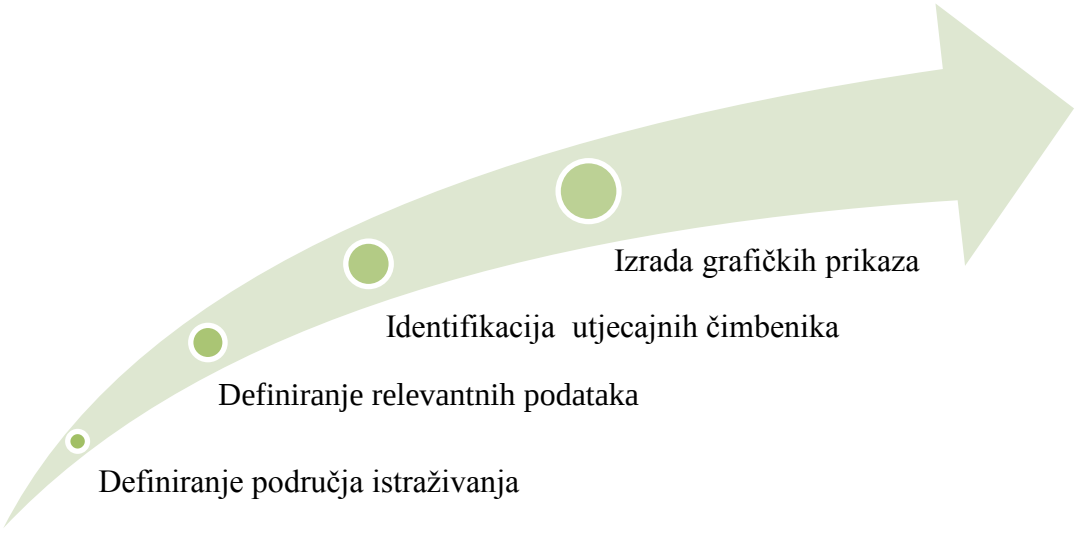
U svrhu istraživanja funkcionalnosti upravljanja europskim zračnim prostorom kreiran je program AirStat koji predstavlja alat za modeliranje i simuliranje učinaka zračnog prometa nad europskim zračnim prostorom. Program se temelji na matematičkom modelu i kvantitativnom istraživanju detaljnije opisanim poglavljem 5.1.3. Primijenjeni matematički model predstavlja osnovni koncept programa koji osvjetljava i pojednostavljuje proces proučavanja interakcija i učinaka između različitih varijabli skupa podataka. Navedeni model u okviru programa ne istražuje uzroke određenih pojava već istraživanjem prostorne autokorelacije analizira njihov prostorni utjecaj, tj. istražuje posljedice onog što se dogodilo te kako se to odražava na cjelokupni promatrani sustav. Primijenjeni model grafički je opisan slikom 3 koja prikazuje četiri razvojne faze sa svojim podsustavima te ujedno i slijed procesa modeliranja i izrade programa.



Slika 3. Pregled slijeda procesa modeliranja i izrade programa AirStat

Prema Chou u [20], pri istraživanju prostorne autokorelacije istraživač je odgovoran za odgovarajuću statističku analizu referentnih podataka te je važno da shvaća i mjeri parametre koji opisuju promatrana područja. Uzimajući u obzir navedeno, primjenom programa AirStat osigurana je adekvatna tehnička podrška koju karakterizira niz postupaka prikupljanja, obrade i interpretiranja prikupljenih podataka koji ograničavaju izvore pogrešaka.

U okviru posljednje faze procesa modeliranja i izrade simulacija, na temelju ulaznih podataka automatski se kreira izvješće s analizama. Pored uvodnog dijela, izvješća se još sastoje od tri poglavlja gdje svako poglavlje označava jednu od analiza europskog zračnog prostora. Svaka od provedenih analiza služi kao zasebni filter ulaznih podataka te se tako kreiraju tri različite analize: analiza žarišnih područja europskog zračnog prostora, analiza klasteriranja i grupiranja europskog zračnog prostora te analiza prostorno atipičnih vrijednosti europskog zračnog prostora. Podaci prikazani u okviru kreiranih izvješća proizlaze izravno iz skupa podataka koji je povezan s područjima odgovornosti različitih ANSP-ova. Slika 4 prikazuje funkcionalne faze izrade izvješća. Primjena takve prakse rezultira učinkovitim prikazom prostornih podataka vezanih uz područje i svrhu istraživanja.



Slika 4. Funkcionalne faze izrade izvješća

Primjenom statističkih metoda u okviru programa AirStat omogućena je obrada velikog broja prikupljenih podataka na način koji je primjeren svrsi istraživanja. Pri tome AirStat zadovoljava općenito prihvatljive mjerne karakteristike te karakteristike znanstvene metodologije:

- *validnost* - program je dizajniran tako da zaista mjeri ono što želimo mjeriti,
- *pouzdanost* - sposobnost da se primjenom programa pri ponovljenom mjerenju iste pojave u idućim istraživanjima dobiju jednaki ili slični rezultati,
- *osjetljivost* - izražena kao razina točnosti i preciznosti dobivenih vrijednosti pri ispisu rezultata istraživanja,
- *objektivnost* - rezultati dobiveni primjenom programa ne ovise o onome tko provodi istraživanje, tj. o onome tko mjeri, već samo o prikupljenim podacima koji se obrađuju (eliminira se subjektivna percepcija istraživača).

5.1.1. Tehnička izrada i praktični dio rada programa

Program AirStat izrađen je u C# programskom jeziku odnosno primjenom alata Microsoft Visual Studio. Korišteni programski jezik C# proizvod je tvrtke Microsoft unutar .NET inicijative i nastao je kao odgovor na nedostatke koje su imali drugi programski jezici kao što su C, C++, Visual Basic, itd. Programski jezik C# je jednostavan, moderan, objektno-orijentirani programski jezik opće namjene. Microsoft Visual Studio jest integrirano razvojno okruženje (IDE) koje razvija Microsoft te se koristi za razvoj računalnih programa za Windows okruženje, te izradu web-stranica, aplikacija i usluga. Visual Studio podržava različite programske jezike pod uvjetom da usluga za taj jezik postoji. Ugrađeni jezici su C, C++ i C++/CLI (preko Visual C++), VB.NET-a (preko Visual Basic .NET), C# (preko Visual C#) i F# (počevši od programa Visual Studio 2010).

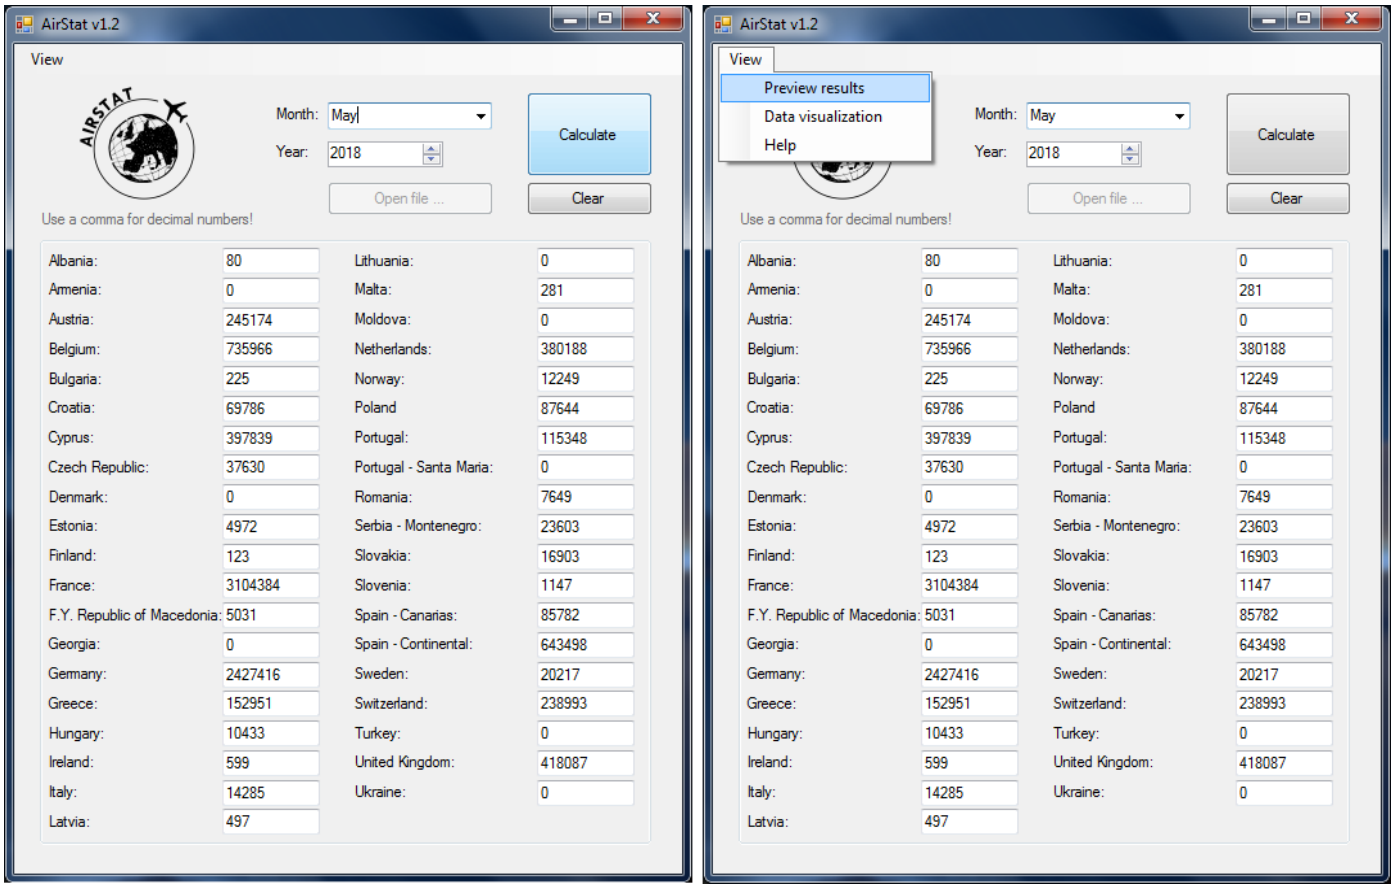
Izvorni kod programa napisan je u klasama prateći pravila objektno-orijentiranog programiranja. Svaka klasa u programu je deklarirana unutar datoteke sufiksom *.cs*. Nakon tablice 1 koja prikazuje korištene klase slijedi njihov kratki opis.

Tablica 1. Korištene klase programa

Redni broj	Naziv klase
1.	Program.cs
2.	AirStat.cs
3.	Country.cs
4.	NeighborhoodMatrix.cs
5.	Neighbors.cs
6.	Calculation.cs
7.	Report.cs
8	Graphs.cs

Klasa *Program.cs* kreira se prilikom kreiranja Windows Form aplikacije i ona sadrži glavnu *(engl. main)* metodu za pokretanje programa odnosno forme. U pravilu se sadržaj ove klase ne mijenja stoga ima isti izgled od početka kreiranja.

Kreiranjem glavne forme stvara se zasebna klasa koja upravlja formom prikazanom slikom 5.



Slika 5. Početna forma programa AirStat

U *AirStat.cs* klasi generiraju se metode za sve akcije od strane korisnika povezane s formom. Dakle, korisnik prilikom unosa vrijednosti za svaku državu (ili učitavanjem TXT datoteke s vrijednostima, npr. jediničnih naknada preuzetih sa službene stranice Eurocontrola pritiskom na gumb „Open file …“) može pokrenuti proces izračuna koji se obavlja unutar druge klase. Prije pokretanja izračuna korisnik treba odabrati mjesec i godinu za koje se radi izvješće. U okviru ove klase također se provjerava je li korisnik upisao točne unose, odnosno provjerava se jesu li decimalni brojevi napisani sa zarezom (jer C# ne obrađuje decimalne brojeve s točkom). Ukoliko je unos ispravan, podaci se obrađuju te se korisniku programa vraća povratna informacija o uspješnosti ispisa.

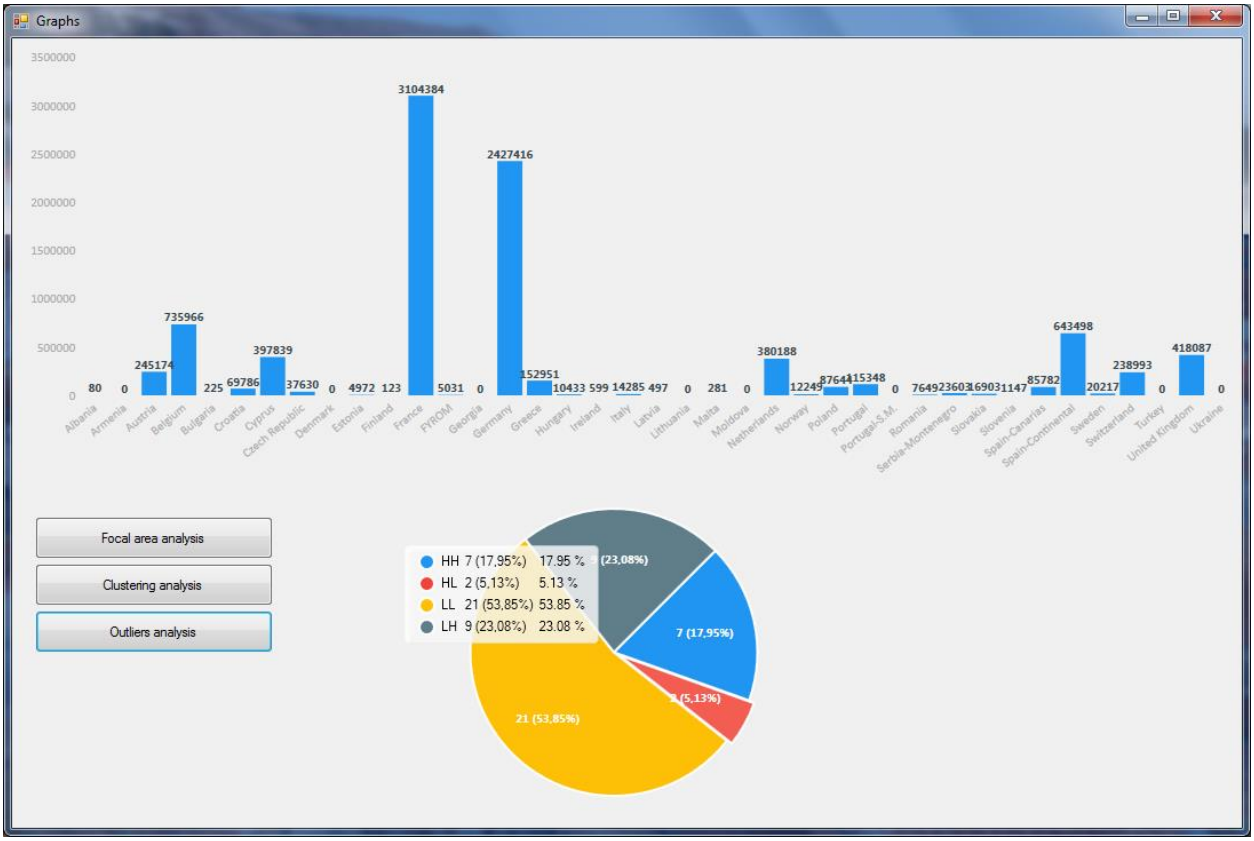
Pritiskom na gumb Calculate pokreće se unos svih država i njihovih unesenih vrijednosti u listu koja se nalazi u klasi *Country.cs*. Osim unosa, u ovoj klasi nalaze se metode getFullName() za dohvaćanje imena i getValue() za dohvaćanje vrijednosti država, te metoda clearList() za brisanje sadržaja liste ukoliko korisnik ponovno zatraži izvještaj s novim vrijednostima.

Kako bi programu bilo poznato koja su područja susjedna, potrebno je kreirati matricu susjedstva koja se kreira u klasi NeighborhoodMatrix.cs. Program podatke učitava iz datoteke matrica-susjedstva.txt te zatim kreira matricu gdje se susjedna područja označavaju s vrijednosti 1, a ukoliko nemaju zajedničku granicu dodjeljuje se vrijednost 0.

U klasi *Neighbors.cs* se praktički događa isto, no ona se pokreće unutar klase NeighborhoodMatrix.cs te služi za unos svih područja odgovornosti i njihovih susjeda u listu. Na taj način je pomoću metode getNeighbors() moguće dohvatiti sva susjedna područja.

Klasa *Calculation.cs* ima najbitniju ulogu jer se u njoj provodi obrada podataka. Sve kasnije spomenute formule u radu nalaze se u ovoj klasi. Nakon obrade podataka, program sprema rezultate u liste i varijable. Jedna metoda služi za izračun jedne varijable ili elementa liste zbog preglednosti i jednostavnosti. Za pokretanje ove klase potrebno je pokrenuti njegov konstruktor Calculation() u kojem se onda izvršavaju sve matematičke operacije. Nakon što je obrada podataka uspješno obavljena slijedi kreiranje izvješća u klasi *Report.cs*. Izvješće kreira TXT datoteku u direktoriju gdje se program nalazi te mu se pridružuje ime koje sadrži mjesec i godinu koje je korisnik odabrao u početnoj formi. Kreirano izvješće tablično prikazuje sve rezultate analiza koje su dobivene primjenom programa AirStat.

Posljednja klasa *Graphs.cs* omogućuje grafičku vizualizaciju obrađenih podataka. Navedenoj klasi se pristupa pomoću opcije View i padajućeg izbornika u kojemu je potrebno izabrati opciju Data visualization. Time se u novom prozoru prikazuju četiri vrste grafikona pri čemu stupičasti grafikon prikazuje korelaciju unesenih podataka te omogućuje lakše prepoznavanje dominantnih vrijednosti, dok ostala tri tortna grafikona prikazuju podatke vezane uz tri provedene analize. Spomenuti grafikoni su uključeni pomoću biblioteke Live Charts [21]. U nastavku rada, slika 6 prikazuje primjer vizualizacije obrađenog skupa podataka primjenom navedenih grafikona.



Slika 6. Vizualizacija obrađenog skupa podataka

5.1.2. Opis skupa podataka

Zadnjih godina s ciljem zadovoljavanja i usklađivanja operativnih, strateških i razvojnih planova različitih dionika europskog zračnog prometa postoji povećana potreba za kvalitetnim studijama koje se temelje na statističkoj obradi stvarnih podataka. Takva izvješća najčešće uključuju predviđanja prometa te prometnih učinaka od strane različitih dionika zračnog prometa te tako olakšavaju proces donošenja odluka. Unos i opcija dohvaćanja podataka za obradu u okviru programa AirStat postavljeni su na optimalno sučelje čovjeka i stroja, osiguravajući pri tome najvišu kvalitetu, provjerenost i točnost podataka. Standardizirana metoda unosa podataka, zajedno s mogućnošću provjere i ispravljanja netočnih podataka omogućuje vremenske uštede pri manipulaciji podacima te brzu obradu podataka.

Jedna od glavnih vrijednosti programa AirStat jest obrada podataka koja omogućuje prikaz stanja pri tome uzimajući u obzir cjelokupnu (tzv. veću sliku) europskog sustava upravljanja zračnim prostorom. K tome u prilog ide i činjenica da svi europski pružatelji usluga u zračnoj plovidbi upotrebljavaju standardizirana pravila i postupke uvedene od različitih globalnih ili regionalnih organizacija (npr. Eurocontrola) pri prikupljanju i publiciranju vlastitih podataka.

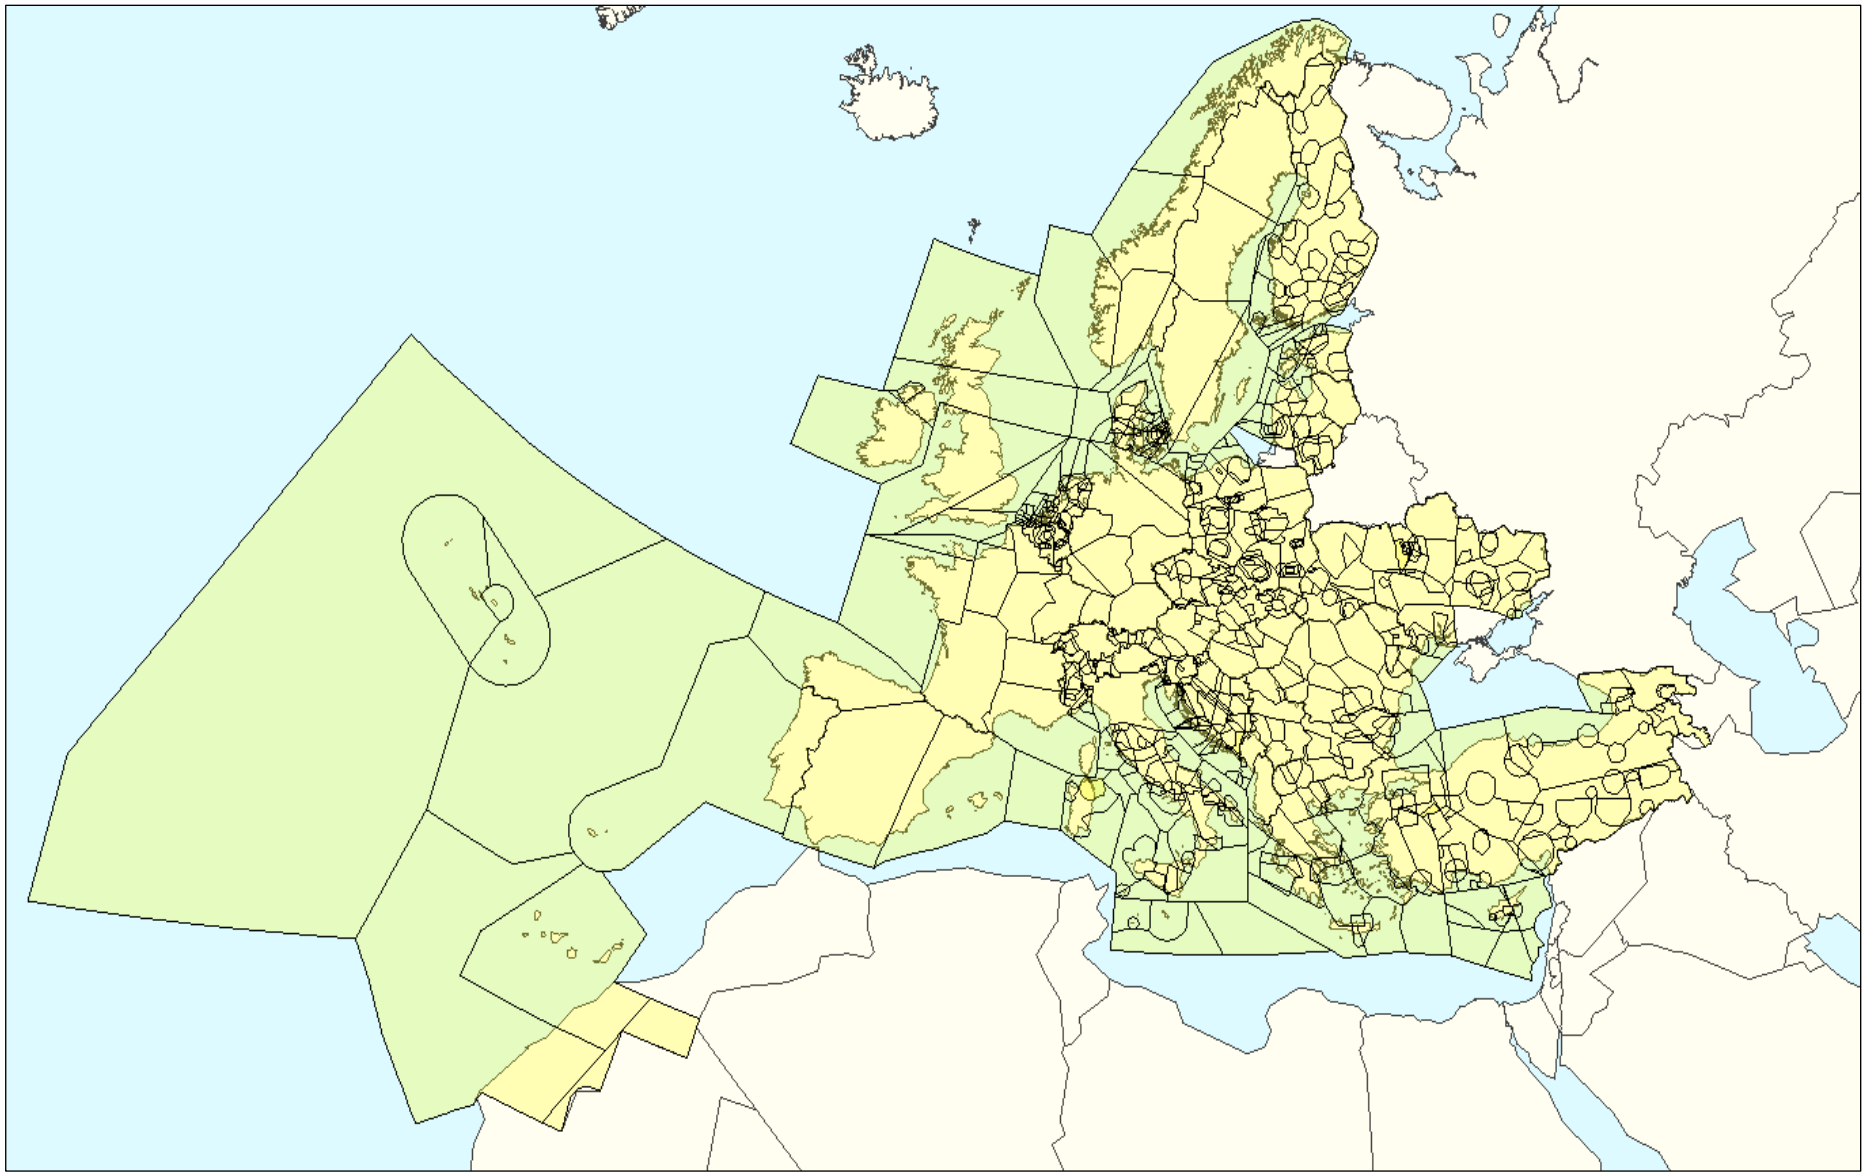
Završetkom obrade podataka, AirStat kreira TXT izvješće s pregledom analiza cjelokupnog europskog zračnog prostora. Izvješće s analizama ovisi o skupu podataka i fazi procesa upravljanja zračnim prostorom (strateškoj, pred-taktičkoj ili taktičkoj) u kojoj su prikupljeni. Pri tome je moguće skup podataka vezanih uz zračne prostore i/ili pružatelje usluga u zračnoj plovidbi podijeliti na:

- statičke podatke - poput podataka o kompleksnosti zračnog prostora, jediničnih naknada itd. koji ne zahtijevaju dnevne ili satne izmjene podataka,
- dinamičke podatke - poput podataka o dostupnim kapacitetima zračnog prostora, zagušenjima zračnih prostora itd. koji zahtijevaju dnevne ili satne izmjene podataka.

U okviru rada i kasnijih analiza kao referentni podaci korišteni su podaci publicirani od strane Jedinice za nadzor učinkovitosti *(engl. Performance Review Unite - PRU)* o vrijednostima rutnih kašnjenja zrakoplova izraženih u minutama, a ostvarenih tijekom 2017. godine. Navedeni podaci prikazani su tablicom 2 te su im pridruženi podaci o pripadajućim državama, pružateljima usluga u zračnoj plovidbi i veličini područja odgovornosti pružatelja usluga u zračnoj plovidbi gdje su navedene vrijednosti ostvarene, dok slika 7 prikazuje prostorni prikaz područja istraživanja.

Tablica 2. Skup podataka s popratnim podacima, [22],[23]

Država	ANSP	Promatrano područje odgovornosti [km^2]	Zbir rutnih kašnjenja zrakoplova [min]
Republika Albanija	Albcontrol	36 000	80
Republika Armenija	ARMATS	29 700	0
Republika Austrija	Austro Control	80 900	245 174
Kraljevina Belgija	Belgocontrol	39 500	735 966
Republika Bugarska	BULATSA	145 000	225
Republika Hrvatska	Croatia Control	129 000	69 786
Republika Cipar	DCAC Cyprus	174 000	397 839
Češka Republika	ANS CR	76 300	37 630
Kraljevina Danska	NAVIAIR	158 000	0
Republika Estonija	EANS	77 400	4 972
Republika Finska	ANS Finland	409 000	123
Republika Francuska	DSNA	1 010 000	3 104 384
Republika Makedonija	M-NAV	24 700	5 031
Gruzija	Sakaeronavigatsia	88 700	0
Savezna Republika Njemačka	DFS	390 000	2 427 416
Helenska Republika	HCAA	537 000	152 951
Mađarska	HungaroControl	92 600	10 433
Republika Irska	IAA	457 000	599
Republika Italija	ENAV	732 000	14 285
Republika Latvija	LGS	95 900	497
Republika Litva	Oro Navigacija	74 800	0
Republika Malta	MATS	231 000	281
Republika Moldavija	MoldATSA	34 800	0
Kraljevina Nizozemska	LVNL	53 100	380 188
Kraljevina Norveška	AVINOR	728 000	12 249
Republika Poljska	PANSA	334 000	87 644
Republika Portugal	NAV Portugal	671 000	115 348
Republika Portugal - S.Maria		5 180 000	0
Rumunjska	ROMATSA	254 000	7 649
Republika Srbija, Crna Gora	SMATSA	127 000	23 603
Slovačka Republika	LPS	48 700	16 903
Republika Slovenija	Slovenia Control	20 400	1 147
Kraljevina Španjolska	ENAIRE	505 957	643 498
Kraljevina Španjolska - Kanari		1 684 043	85 782
Kraljevina Švedska	LFV	627 000	20 217
Švicarska konfederacija	Skyguide	69 700	238 993
Republika Turska	DHMI	982 000	0
Ujedinjeno Kraljevstvo	NATS	880 000	418 087
Ukrajina	UkSATSE	776 000	0



Slika 7. Prostorni prikaz istraživanog zračnog prostora

U slučaju nedostatka kapaciteta zračnog prostora, nakon koordinacije s Pozicijom upravljanja protokom *(engl. Flow Management Position - FMP)*, Mrežni upravitelj *(engl. Network manager)* odlučuje o aktivaciji regulacija na određenom prostoru. Regulacija predstavlja zaštitnu mjeru koja se primjenjuje na određeni tok prometa u određenom vremenskom razdoblju za dani kapacitet sektora kontrole zračnog prostora [24]. Prilikom planiranja kada prometna potražnja premaši deklarirani kapacitet sektora, Mrežni upravitelj regulira određeni broj zrakoplova koji planiraju ući u isti sektor zračnog prostora dodjeljujući letovima nove slotove tako stvarajući dodatna kašnjenja zrakoplova. Ranije prikazane referentne vrijednosti rutnih kašnjenja zrakoplova predstavljaju zbroj svih vrijednosti rutnih kašnjenja zrakoplova nastalih zbog različitih uzroka. Klasifikacija vrijednosti rutnih kašnjenja zrakoplova prema uzročnosti nastanka kašnjenja prikazana je tablicom 3.

Tablica 3. Klasifikacija vrijednosti rutnih kašnjenja zrakoplova prema uzročnosti nastanka kašnjenja, [25]

Oznaka kašnjenja	Nomenklatura	Uzrok kašnjenja
C	ATC kapacitet	Rutni kapacitet (ATC)
S	ATC osoblje	Rutni poremećaj (ATC)
I	ATC industrijska aktivnost	Rutni poremećaj (ATC)
T	ATC oprema	Rutni poremećaj (ATC)
G	Kapacitet zračne luke	Rutni kapacitet
M	Vojna aktivnost	Rutni kapacitet
R	ATC rutiranje	Rutni kapacitet
V	Okoliš	Rutni kapacitet
A	Nesreća/Nezgoda	Rutni poremećaj
E	Usluge na zračnoj luci	Rutni poremećaj
N	Industrijska aktivnost	Rutni poremećaj
O	Ostalo	Rutni poremećaj
P	Posebni događaji	Rutni događaji
W	Vremenske neprilike	Rutne vremenske neprilike

Iz prikazane klasifikacije i istraživanja izostavljeni su kategorije kašnjenja koja nisu specificirana *(engl. Not specified)* i koja se odnose na kašnjenja zbog odleđivanja *(engl. de-icing)* iz razloga što se tijekom 2017. godine kašnjenja zbog navedenih kategorija ne pojavljuju.

5.1.3 Analitičko istraživanje skupa podataka

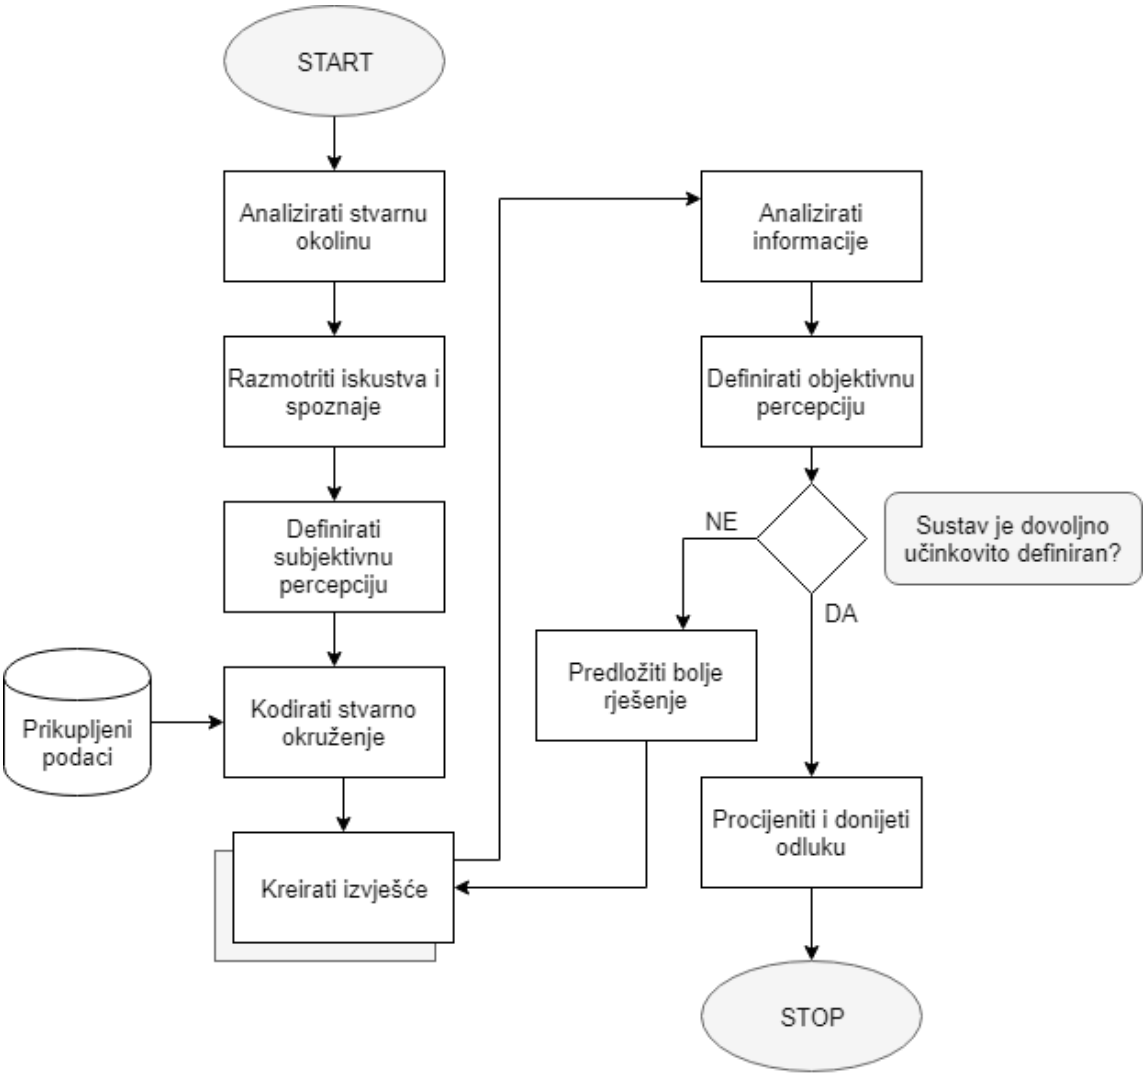
U okviru kvantitativnog istraživanja, korišteni podaci predstavljaju skup podataka prikupljenih u obliku numeričkih vrijednosti te je na temelju njihovih vrijendosti provedeno istraživanje funkcionalnosti upravljanja europskim zračnim prostorom.

Prostornom autokorelacijom istraživan je odnos vrijednosti rutnih kašnjenja zrakoplova i geoprostornog položaja pružatelja usluga u zračnoj plovidbi gdje su ta kašnjenja ostvarena. Tako je prostornom autokorelacijom mjerena i homogenost europskog zračnog prostora, stupanj po kojemu je neki prostorni fenomen u korelaciji sam sa sobom u prostoru, te razina ovisnosti vrijednosti ostvarenih kašnjenja u susjednim područjima.

Pri provedbi istraživanja i kreiranju programa AirStat ispoštovane su opće smjernice za najbolju praksu pri proučavanju prostorne autokorelacije, a one uključuju:

- studija treba sadržavati barem 30 ulaznih podataka,
- nepostojanje tzv. otoka - promatranog područja bez susjednih područja,
- svako promatrano područje treba imati minimalno jednog susjeda,
- nijedno promatrano područje ne bi smjelo imati susjednim sva ostala područja,
- provedbu standardizacije podatka.

U nastavku rada, slika 8 prikazuje slijed provedbe kvantitativnog istraživanja primjenom programa AirStat. Nakon prethodne analize stvarnog okruženja, razmotrenih iskustava i ranijih spoznaja vezanih uz tematiku funkcionalnosti upravljanja europskim zračnim prostorom, započet je proces kodiranja promatranog europskog zračnog prostora. Konačni rezultat kodiranja je stvaranje programa AirStat. Potom slijedi upis ili učitavanje prikupljenih ulaznih podataka u program AirStat te njihova obrada. Rezultati prikazani u okviru izvješća se potom analiziraju prema postavljenim indikatorima te se ranije upisani podaci primjenom statističkih metoda pretvaraju u korisne informacije. Na temelju dobivenih informacija eliminira se subjektivizam te se prikazuje objektivan prikaz stanja europskog zračnog prostora. Ukoliko se pri upisu podataka dogodila pogreška, omogućen je ponovni unos ulaznih podataka te se provedba kvantitativnog istraživanja ponavlja i rezultira izradom novog izvješća.



Slika 8. Prikaz procesa provedbe kvantitativnog istraživanja primjenom programa AirStat

5.1.3.1. Analiza žarišnih područja europskog zračnog prostora

Analiza žarišnih područja europskog zračnog prostora identificira područja prostornog grupiranja izrazito visokih *(engl. hot spots)* ili niskih *(engl. cold spots)* vrijednosti. Pri tome AirStat analizira podatke na temelju normalne ili Gaussove razdiobe unesenih podataka. Nakon izračuna aritmetičke sredine kojom se aproksimira očekivanje μ te standardne devijacije σ moguće je opisati vjerojatnost pojavljivanja vrijednosti funkcijom normalne razdiobe:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}}\, e^{-\frac{(x-\mu)^2}{2\sigma^2}} \qquad x \in \mathrm{R}. \tag{1}$$

Nadalje, položaj bilo koje vrijednosti u distribuciji moguće je odrediti pomoću z-vrijednosti. Tada je potrebno funkciju normalne razdiobe standardizirati kako slijedi:

$$f(z) = \frac{1}{\sqrt{2\pi}}\, e^{-\frac{z^2}{2}} \quad \mathrm{N}\,(0,1). \tag{2}$$

gdje z-vrijednost označava udaljenost dobivenog rezultata mjerenja od aritmetičke sredine iskazanog kao dio standardne devijacije skupa podataka:

$$z_i = \frac{x_i - \mu}{\sigma} \quad . \tag{3}$$

Izračunom z-vrijednosti istražuje se je li određena vrijednost jednaka srednjoj vrijednosti, ispod srednje vrijednosti ili iznad srednje vrijednosti promatranog skupa podataka. Izrazito visoke (pozitivne) ili izrazito niske (negativne) z-vrijednosti nalaze se pri krajevima normalne (Gaussove) razdiobe. Također, na temelju dobivene z-vrijednosti moguće je iz integrala vjerojatnosti očitati koliki se postotak podataka u distribuciji nalazi između određenog podatka pretvorenog u z-vrijednost i bližeg kraja krivulje.

5.1.3.2. Analiza prostornog klasteriranja europskog zračnog prostora

Modeliranje primjenom prostorne autokorelacije počelo se razvijati još krajem 1940-ih i tijekom 1950-ih radovima P. A. P. Morana i R. C. Gearya. Prostornu autokorelaciju može se računati globalno (na cijelom promatranom području) i lokalno (na dijelovima područja). Prema radovima [26-28], globalna prostorna autokorelacija koristi se za mjerenje ukupne sklonosti grupiranja u okviru istraživanog područja, dok se lokalna prostorna autokorelacija može koristiti za razjašnjavanje uzoraka i definiranje točne lokacije klastera među većim brojem susjednih lokacija.

Globalna prostorna autokorelacija otkriva i mjeri prostorni uzorak na cijelom području od interesa, pri čemu ne otkriva u kojem se dijelu značajni uzorak pojavljuje. Globalni indikator prostorne autokorelacije (*engl. Global Indicator of Spatial Autocorrelation - GISA*) je analogan Pearsonovom koeficijentu korelacije i u rasponu od -1 do +1, gdje -1 označava snažnu negativnu autokorelaciju, 0 potpuno slučajni raspored vrijednosti po lokacijama, a +1 snažnu prostornu autokorelaciju (klasteriranje sličnih vrijednosti u prostoru).

Istraživanja koja koriste lokalnu prostornu autokorelaciju smatraju se točnijima od istraživanja koja uzimaju u obzir isključivo globalni indikator prostorne autokorelacije. Primjenom lokalne prostorne autokorelacije identificiraju se varijacije na istraživanome području fokusirajući se na blisko susjedstvo. Određuju se lokalne strukture prostorno sličnih vrijednosti te se omogućuje dekomponiranje globalne statistike (Moranovog I koeficijenta) na lokalne indikatore. Lokalni indikatori prostorne autokorelacije *(engl. Local Indicator of Spatial Autocorrelation - LISA)* imaju dva osnovna cilja [29]:

- mogu se interpretirati kao pronalaženje lokalnih otoka nestacionarnih karakteristika,
- služe za određivanje značajnosti pojedine opservacije u globalnoj strukturi.

Moranov I koeficijent kao metoda mjerenja lokalne prostorne autokorelacije zahtjeva izradu matrice susjedstva koja definira lokalno okruženje oko svake geografske jedinice i prikazuje graniče li područja *i* i *j* međusobno:

$$w_{ij}{}^{*} = \begin{cases} 1, & i \text{ i } j \text{ imaju zajedničku granicu} \\ & i \neq j \\ 0, & i \text{ i } j \text{ nemaju zajedničku granicu} \end{cases} \quad . \tag{4}$$

Tumačenje lokalnog Moranovog I koeficijenta poboljšava se ako se matricu susjedstva $W_{ij}{}^{*}$ tako normira da suma retka bude jednaka jedan. Stoga je potrebno podijeliti svaki element s pripadajućom sumom reda:

$$\mathrm{w}_{ij} = \frac{\mathrm{w}_{ij}{}^{*}}{\sum_{\mathrm{j}=1}^{\mathrm{n}} \mathrm{w}_{ij}{}^{*}} \quad . \tag{5}$$

Time se dobiva standardizirana vagana matrica W_{ij}. Potom se mjeri produkt odstupanja od srednje vrijednosti u *i*-tom području sa srednjom vrijednosti svih odstupanja u susjednim područjima [30]:

$$(\mathrm{x}_i - \bar{\mathrm{x}}) \sum_{\mathrm{j}=1}^{\mathrm{n}} \mathrm{w}_{ij} \left(\mathrm{x}_j - \bar{\mathrm{x}}\right) \quad . \tag{6}$$

Fotheringham i suautori radom [31] definiraju formulu po kojoj se izračunavaju lokalni Moranovi koeficijenti *i*-tog područja:

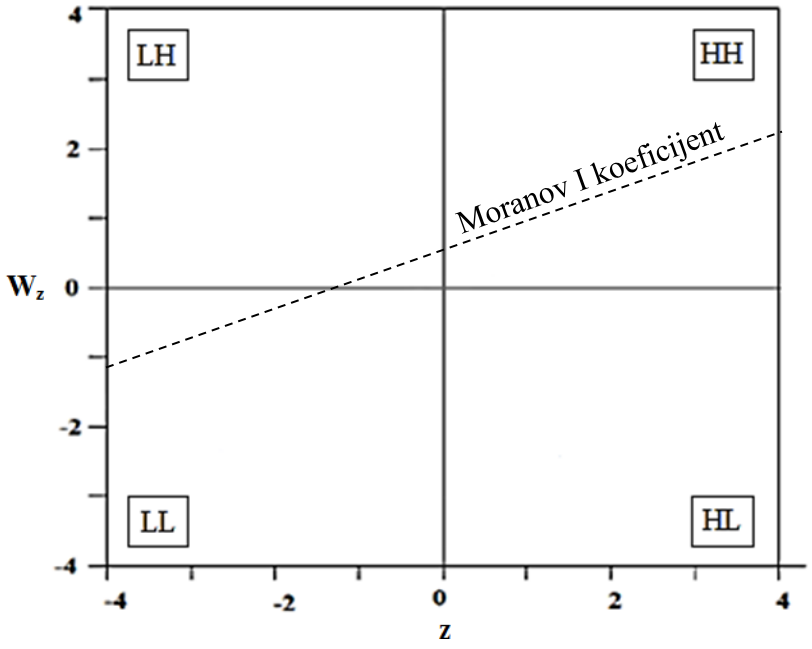
$$\mathrm{I}_i = \frac{(\mathrm{x}_i - \bar{\mathrm{x}}) \sum_{\mathrm{j}=1}^{\mathrm{n}} \mathrm{w}_{ij} \, (\mathrm{x}_j - \bar{\mathrm{x}})}{\sum_{\mathrm{j}=1}^{\mathrm{n}} (\mathrm{x}_j - \bar{\mathrm{x}})^2 / \mathrm{n}} \quad . \tag{7}$$

Kako se očekivane vrijednosti lokalnih i globalnih Moranovih I koeficijenata poklapaju, moguće je globalni Moranov I koeficijent (globalnu prostornu autokorelaciju) prikazati kao aritmetičku sredinu lokalnih pokazatelja:

$$I = \frac{1}{n}\sum_{i=1}^{n} I_i \quad . \tag{8}$$

5.1.3.3. Analiza prostorno atipičnih vrijednosti europskog zračnog prostora

Pri istraživanju prostorno atipičnih vrijednosti europskog zračnog prostora primijenjena je znanstvena metoda Moranovog dijagrama rasprostiranja. Anselin [32] opisuje Moranov dijagram rasprostiranja kao koristan vizualni alat pri provođenju istraživanja jer omogućava procjenu sličnosti promatrane vrijednosti sa susjednim vrijednostima. Horizontalna x-os Moranovog dijagrama rasprostiranja temelji se na vrijednostima promatranih prostornih područja te je također poznata kao „os odgovora“. Vertikalna y-os se temelji na ponderiranom prosjeku promatranih vrijednosti prikazanih horizontalnom x-osi. Horizontalna i vertikalna os dijele dijagram rasprostiranja na četiri kvadranta. Moranov dijagrama rasprostiranja prikazan je grafikonom 2.



Grafikon 2**.** Moranov dijagram rasprostiranja

Prema Anselinu i suautorima u [33], svaki kvadrant dijagrama rasprostiranja predstavlja različitu vrstu prostorne autokorelacije. Područja visokih susjednih vrijednosti *(engl. High-High - HH)* i područja niskih susjednih vrijednosti *(engl. Low-Low - LL)* ukazuju na pozitivnu prostornu autokorelaciju - pozitivnu prostornu povezanost vrijednosti koje su veće ili niže od prosjeka uzoraka. Područja visokih vrijednosti sa susjedstvom niskih vrijednosti *(engl. High-Low - HL)* i područja niskih vrijednosti sa susjedstvom visokih vrijednosti *(engl. Low-High - LH)* ukazuju na negativnu prostornu autokorelaciju - ove promatrane vrijednosti imaju malo sličnosti sa susjednim vrijednostima te predstavljaju prostorno atipične vrijednosti europskog zračnog prostora.

5.2. Rezultati istraživanja

Zadnjih godina mnoge studije su provedene od strane različitih organizacija te odgovaraju na pitanja koja se tiču regionalizacije ATM sustava; kakav je međusobni utjecaj regija; njihova jakost te postoje li među-regionalni utjecaji i interesi. Pri tome su uglavnom pri obradi podataka korištene različite statističke metode kao i matematički modeli. Izrada različitih matematičkih modela tijekom posljednja dva desetljeća postala je sve popularnija u primijenjenoj ekonometriji, a sukladno sve većoj popularnosti razvijala su se i razmišljanja o najboljem načinu uključivanja prostorne heterogenosti u ekonometrijske modele [34]. U okviru ovoga rada, na temelju kreiranog matematičkog modela, provedeno je istraživanje prostorne autokorelacije vrijednosti rutnih kašnjenja ostvarenih na području odgovornosti 39 europska pružatelja usluga u zračnoj plovidbi. Analizom žarišnih područja, analizom prostornog klasteriranja i analizom prostorno atipičnih vrijednosti europskog zračnog prostora prikazana je razina funkcionalnosti upravljanja europskim zračnim prostorom tijekom 2017. godine. Sveukupno istraživanje temeljeno je na provedbi 15 istraživanja i 45 analiza podataka. Primjenom programa AirStat i provedbom sveukupno 43 860 matematičkih operacija omogućen je prikaz rezultata istraživanja i donošenje odgovarajućih zaključaka. U nastavku rada prikazani su rezultati istraživanja gdje su u obzir uzete ukupne (sumirane) vrijednosti kašnjenja zrakoplova svih kategorija uzroka kašnjenja (prikazane tablicom 3), dok se u prilogu radu nalaze rezultati ostalih 14 istraživanja koja su temeljena na vrijednostima kašnjenja zrakoplova prema uzročnosti nastanka kašnjenja.

U okviru istraživanja poseban naglasak je stavljan na vizualizaciju rezultata istraživanja. Primjenom desktop aplikacije NEST *(engl. Network Strategic Tool)* osiguran je najbolji način prostorne vizualizacije numeričkih rezultata istraživanja dobivenih primjenom programa AirStat. NEST predstavlja kombinaciju bivših Eurocontrolovih alata SAAM-a *(engl. System for traffic Assignment and Analysis at a Macroscopic level)* i NEVAC-a *(engl. Network Estimation & Visualization of ACC Capacity)* te ga u okviru vlastitih djelatnosti koriste različiti dionici europskog ATM sustava.

5.2.1. Rezultati analize žarišnih područja europskog zračnog prostora

U sklopu analize žarišnih područja europskog zračnog prostora na temelju z-vrijednosti i normalne (Gaussove) razdiobe definirano je sedam indikatora. Dobivene z-vrijednosti unesenih podataka klasificiraju su prema sljedećim indikatorima:

1. izrazito visoka kritična vrijednost područja *(engl. Very High Critical Value - VHCV),*
2. visoko kritična vrijednost područja *(engl. High Critical Value - HCV),*
3. srednje visoka kritična vrijednost područja *(engl.Medium High Critical Value - MHCV),*
4. promatrano područje ne klasificira se kao žarišno područje *(engl. Nothing - NIL),*
5. srednje niska kritična vrijednost područja *(engl. Medium Low Critical Value - MLCV),*
6. niska kritična vrijednost područja *(engl. Low Critical Value - LCV),*
7. izrazito niska kritična vrijednost područja *(engl. Very Low Critical Value - VLCV),*

pri čemu za svaki od navedenih indikatora vrijedi uvjet:

- VHCV: $z\text{-}vrijednost \geq \mu+3\sigma$,
- HCV: $\mu+2\sigma \leq z\text{-}vrijednost < \mu+3\sigma$,
- MHCV: $\mu+\sigma \leq z\text{-}vrijednost < \mu+2\sigma$,
- NIL: $\mu-\sigma \leq z\text{-}vrijednost < \mu+\sigma$,
- MLCV: $\mu-\sigma \leq z\text{-}vrijednost < \mu-2\sigma$,
- LCV: $\mu-2\sigma \leq z\text{-}vrijednost < \mu-3\sigma$,
- VLCV: $z\text{-}vrijednost \leq \mu-3\sigma$.

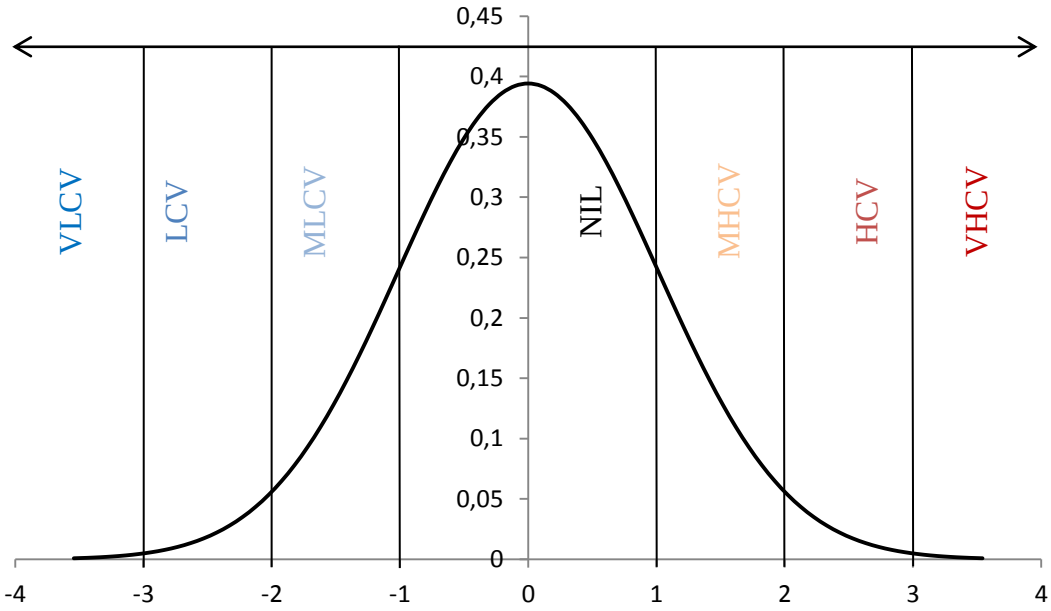
Za razliku od sljedeće dvije analize, analiza žarišnih područja europskog zračnog prostora ne uzima u obzir prostorni položaj pružatelja usluga u zračnoj plovidbi već je fokus na analizi promatranih vrijednosti. Stoga treba biti oprezan pri interpretiranju rezultata provedene analize.

Glavni razlog tome je što analiza žarišnih područja europskog zračnog prostora ne uzima u obzir vrijednosti ostvarene na području odgovornosti susjednih pružatelja usluga u zračnoj plovidbi. Pri tome se analizom promatra svaka varijabla zasebno te se dobivene rezultate uspoređuje s aritmetičkom sredinom promatranog skupa podataka, a ne sa susjednim vrijednostima kao u ostale dvije analize.

Izračunom standardne devijacije i aritmetičke sredine z-vrijednosti te uzimajući u obzir uvjete za određivanje granica indikatora dobivene su sljedeće vrijednosti područja primjenjivosti sedam indikatora:

- VHCV: z-vrijednost ≥ 3,
- HCV: 2 ≤ z-vrijednost < 3,
- MHCV: 1 ≤ z-vrijednost < 2,
- NIL: -1 ≤ z-vrijednost < 1,
- MLCV: -1 ≤ z-vrijednost < -2,
- LCV: -2 ≤ z-vrijednost < -3,
- VLCV: z-vrijednost ≤ -3.

Grafikon 3 prikazuje standardiziranu normalnu razdiobu promatranih vrijednosti s granicama sedam indikatora.



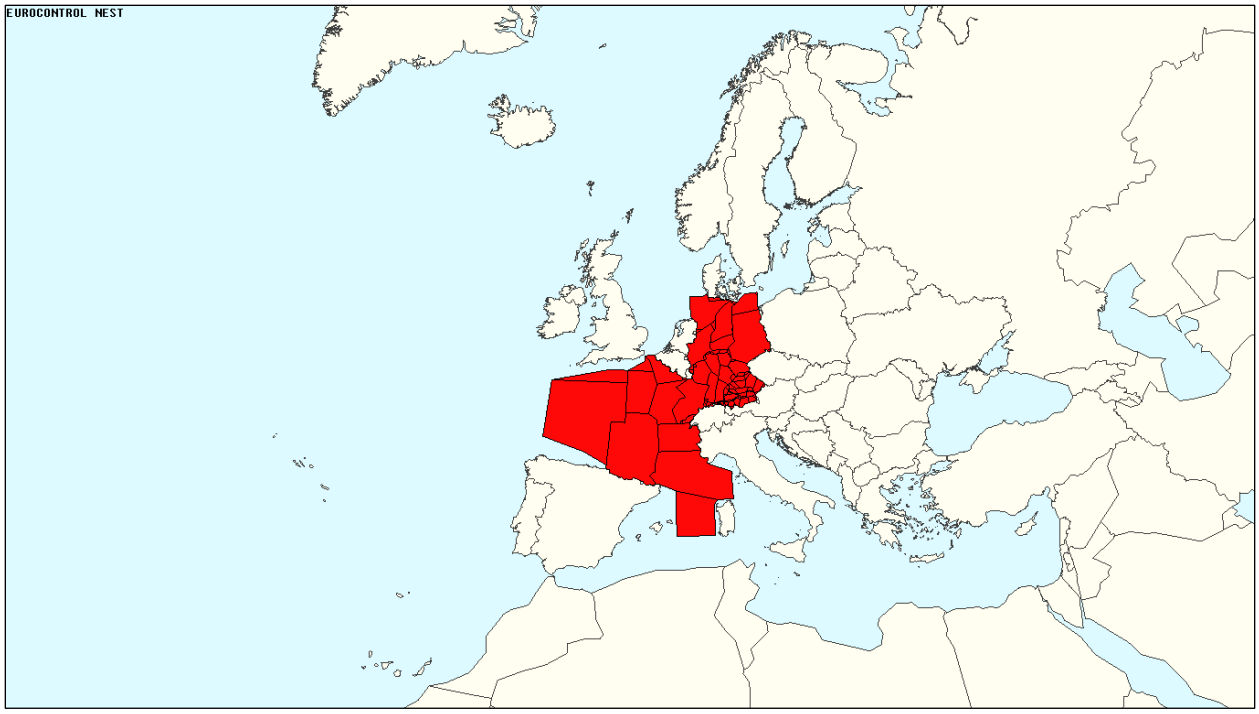
Grafikon 3. Prikaz standardizirane normalne razdiobe s uključenim granicama indikatora

U nastavku rada tablicom 4 prikazani su rezultati analize žarišnih područja europskog zračnog prostora dobiveni primjenom programa AirStat. Na temelju dobivenih rezultata, s ciljem prostorne vizualizacije rezultata, primjenom programa NEST kreirana je slika 9.

Tablica 4. Rezultati analize žarišnih područja europskog zračnog prostora

Airspace	Value	f(x)	z-score	f(z)	Type
Albania	80	0,000001	- 0,383427	0,370669	NIL
Armenia	0	0,000001	- 0,383556	0,370650	NIL
Austria	245174	0,000001	0,012544	0,398911	NIL
Belgium	735966	0,000000	0,805462	0,288424	NIL
Bulgaria	225	0,000001	- 0,383193	0,370702	NIL
Croatia	69786	0,000001	- 0,270811	0,384578	NIL
Cyprus	397839	0,000001	0,259188	0,385765	NIL
Czech Republic	37630	0,000001	- 0,322762	0,378694	NIL
Denmark	0	0,000001	- 0,383556	0,370650	NIL
Estonia	4972	0,000001	- 0,375524	0,371782	NIL
Finland	123	0,000001	- 0,383358	0,370679	NIL
France	3104384	0,000000	4,631851	0,000009	VHCV
FYROM	5031	0,000001	- 0,375428	0,371795	NIL
Georgia	0	0,000001	- 0,383556	0,370650	NIL
Germany	2427416	0,000000	3,538149	0,000763	VHCV
Greece	152951	0,000001	- 0,136451	0,395246	NIL
Hungary	10433	0,000001	- 0,366701	0,373001	NIL
Ireland	599	0,000001	- 0,382589	0,370788	NIL
Italy	14285	0,000001	- 0,360478	0,373846	NIL
Latvia	497	0,000001	- 0,382754	0,370764	NIL
Lithuania	0	0,000001	- 0,383556	0,370650	NIL
Malta	281	0,000001	- 0,383102	0,370715	NIL
Moldova	0	0,000001	- 0,383556	0,370650	NIL
Netherlands	380188	0,000001	0,230671	0,388469	NIL
Norway	12249	0,000001	- 0,363767	0,373401	NIL
Poland	87644	0,000001	- 0,241960	0,387434	NIL
Portugal	115348	0,000001	- 0,197202	0,391260	NIL
Portugal-S.M.	0	0,000001	- 0,383556	0,370650	NIL
Romania	7649	0,000001	- 0,371199	0,372383	NIL
Serbia-Montenegro	23603	0,000001	- 0,345424	0,375838	NIL
Slovakia	16903	0,000001	- 0,356248	0,374413	NIL
Slovenia	1147	0,000001	- 0,381703	0,370913	NIL
Spain-Canarias	85782	0,000001	- 0,244968	0,387150	NIL
Spain-Continental	643498	0,000001	0,656072	0,321694	NIL
Sweden	20217	0,000001	- 0,350894	0,375123	NIL
Switzerland	238993	0,000001	0,002558	0,398941	NIL
Turkey	0	0,000001	- 0,383556	0,370650	NIL
United Kingdom	418087	0,000001	0,291900	0,382303	NIL
Ukraine	0	0,000001	- 0,383556	0,370650	NIL

Standard deviation value: 618969,49
f(x)max value: 0,000001
f(z)max value: 0,398942

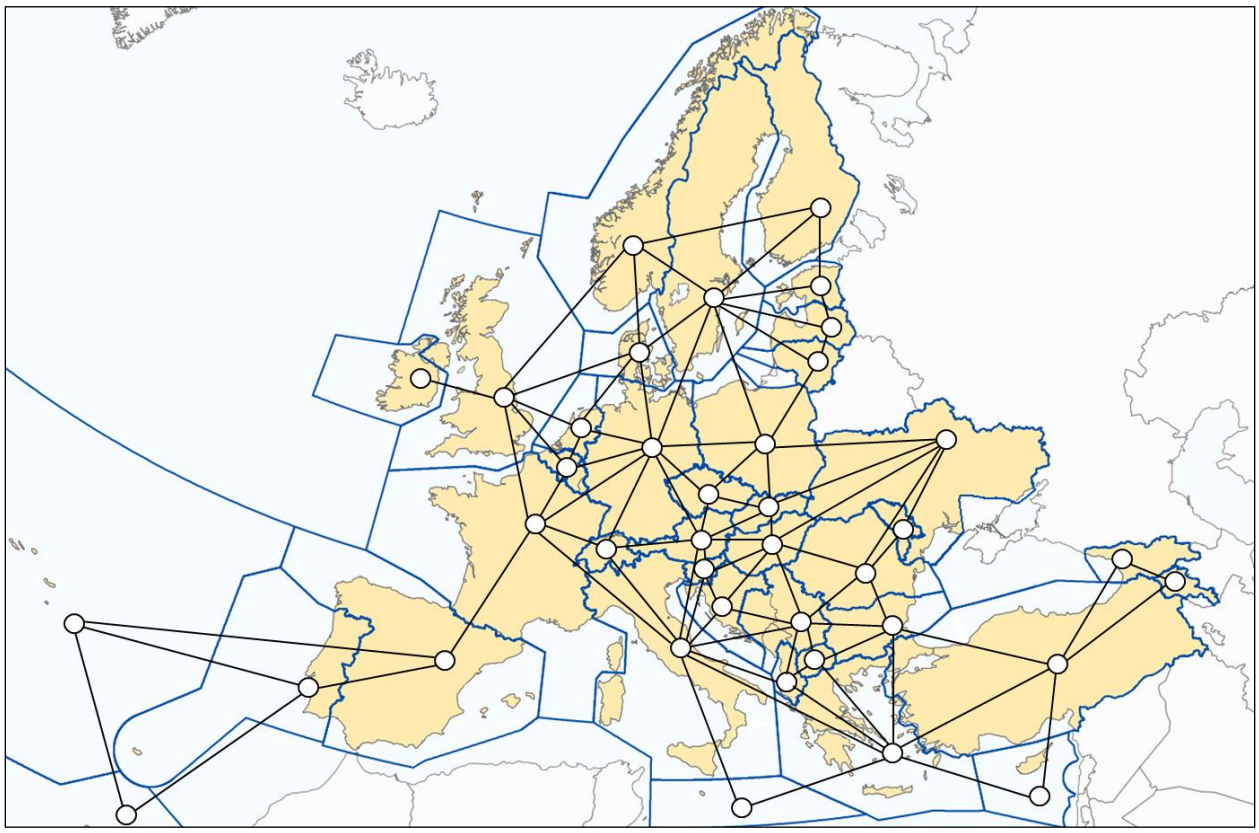


Slika 9. Prostorni prikaz rezultata analize žarišnih područja europskog zračnog prostora

U zrakoplovstvu profitne margine mogu biti često vrlo niske, pa čak i male promjene povećanja ukupnih troškova zračnih prijevoznika mogu imati veliki utjecaj na ukupni profit organizacije. Ukoliko se trend povećanja vrijednosti rutnih kašnjenja zrakoplova nastavi, navedeno će imati direktan utjecaj prvenstveno na niskotarifne prijevoznike jer su takve tvrtke već sada maksimalno optimizirale ostale komponente operativnih troškova. Na temelju dobivenih rezultata istraživanja može se zaključiti da postoje područja izrazito visokih kritičnih vrijednosti te da uključuju područja odgovornosti DSNA-e (Republika Francuska) i DFS-a (Savezna Republika Njemačka). Vrijednosti spomenutih područja najviše su udaljenje od aritmetičke sredine promatranog skupa vrijednosti te se klasificiraju VHCV indikatorom. U odnosu na promatrani skup vrijednosti, područja izrazito visokih kritičnih vrijednosti čine 5,13% ukupnih vrijednosti, dok se ostatak promatranog europskog zračnog prostora (94,87%) klasificira indikatorom NIL. Ukoliko dobivene postotne vrijednosti podataka pretvorimo u prostorne postotne vrijednosti, može se zaključiti da 8,1% ukupno promatrane površine europskog zračnog prostora čine područja izrazito visokih kritičnih vrijednosti.

5.2.2. Rezultati analize prostornog klasteriranja europskog zračnog prostora

Slika 10 prikazuje 39 područja odgovornosti europskih pružatelja usluga u zračnoj plovidbi s pripadajućim granicama. Na temelju prikazanih granica kreiran je graf susjedstva koji je također prikazan slikom 10.



Slika 10. Prikaz grafa susjedstva istraživanog područja

Na temelju kreiranog grafa susjedstva moguće je napraviti matricu susjedstva W_{ij}^{*}. Audretsch i suautori radom „Knowledge Spillovers and the Geography of Innovation“ [35] zaključuju da empirijske studije pokazuju kako „spillover“ efekt opada s prostornom udaljenosti. Time se i argumentira česta primjena binarne matrice susjedstva promatranih područja koje izravno graniče. Matricu susjedstva ispunjava se na način da ukoliko područje *i* graniči s područjem *j*, za elemente w_{12} i w_{21} unosi se jedinica. U skladu s tim na isti način povezana su i preostala područja, dok se na glavnu dijagonalu stavljaju nule:

$$W_{ij}{}^{*} = \begin{bmatrix} 0 & 1 & \cdots & w_{ij} \\ 1 & 0 & \cdots & w_{ij} \\ \vdots & \vdots & \ddots & w_{ij} \\ w_{ij} & w_{ij} & w_{ij} & 0 \end{bmatrix} \quad . \tag{13}$$

U obzir se dalje uzimaju samo susjedna područja koja su okviru matrice susjedstva obilježena s jedinicama. Potom se svaki element reda matrice susjedstva mora podijeliti sa sumom istog reda te se tako dobije standardizirana vagana matrica:

$$W_{ij} = \begin{bmatrix} 0 & 1/n & \cdots & w_{ij} \\ 1/n & 0 & \cdots & w_{ij} \\ \vdots & \vdots & \ddots & w_{ij} \\ w_{ij} & w_{ij} & w_{ij} & 0 \end{bmatrix} \quad . \tag{14}$$

Nakon provedene standardizacije podataka, moguće je primijeniti formulu za izračun lokalnih Moranovih koeficijenata te provesti analitičku obradu podataka. U nastavku rada, tablica 5 prikazuje rezultate istraživanja klasteriranja i grupiranja europskog zračnog prostora dobivene primjenom programa AirStat. Prvi stupac prikazuje nomenklaturu država, odnosno područje gdje su analizirane vrijednosti ostvarene, drugi stupac prikazuje broj susjednih pružatelja usluga u zračnoj plovidbi (n.FIRs), treći stupac prikazuje vrijednosti rutnih kašnjenja zrakoplova, dok četvrti stupac prikazuje lokalne indikatore prostorne autokorelacije (LISA I(i)). U nastavku tablice 5 prikazane su zajedničke vrijednosti globalnog indikatora prostorne autokorelacije (GISA I(i)) te očekivane vrijednost (E(i)), dok je na dnu tablice prikazana aritmetička vrijednost promatranog skupa podataka.

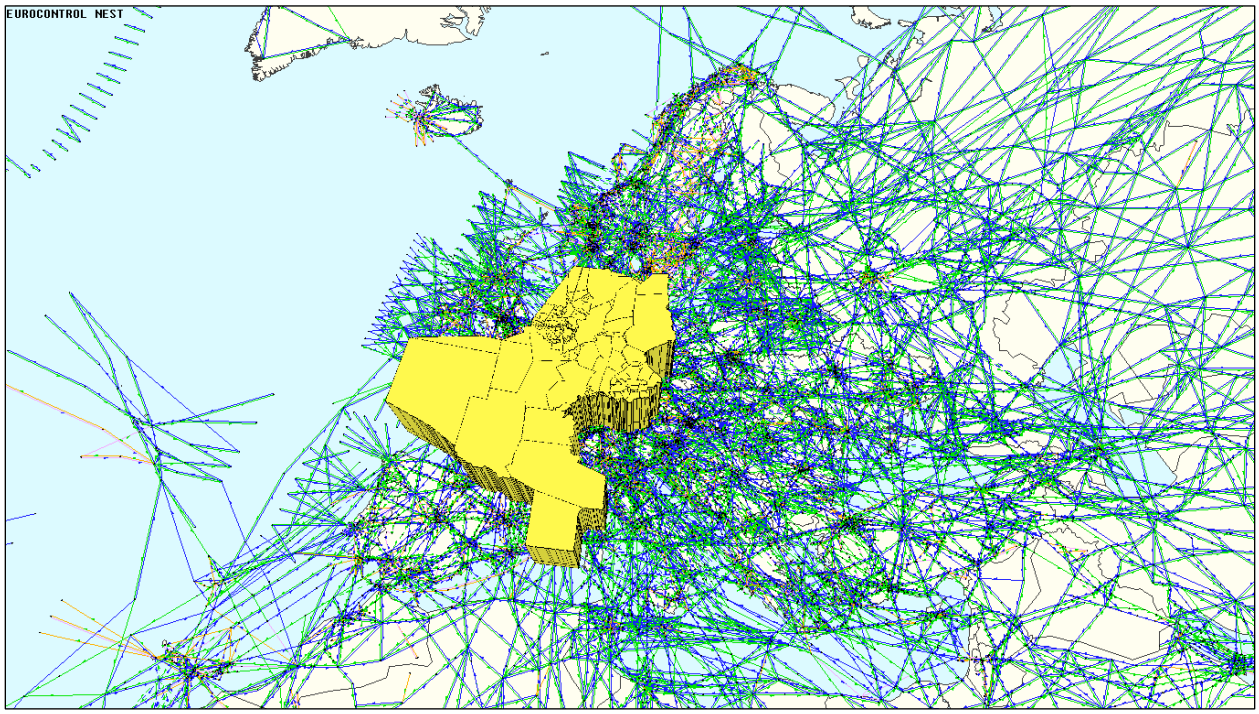
Tablica 5. Rezultati analize prostornog klasteriranja i grupiranja europskog zračnog prostora

Airspace	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	80	0,116733	0,223756	- 0,0263158
Armenia	2	0	0,147116	0,223756	- 0,0263158
Austria	7	245174	0,003141	0,223756	- 0,0263158
Belgium	4	735966	1,750383	0,223756	- 0,0263158
Bulgaria	5	225	0,123546	0,223756	- 0,0263158
Croatia	4	69786	0,098461	0,223756	- 0,0263158
Cyprus	2	397839	- 0,067390	0,223756	- 0,0263158
Czech Republic	4	37630	- 0,238237	0,223756	- 0,0263158
Denmark	5	0	- 0,256680	0,223756	- 0,0263158
Estonia	3	4972	0,139821	0,223756	- 0,0263158
Finland	3	123	0,139310	0,223756	- 0,0263158
France	6	3104384	3,808665	0,223756	- 0,0263158
FYROM	4	5031	0,117180	0,223756	- 0,0263158
Georgia	2	0	0,147116	0,223756	- 0,0263158
Germany	9	2427416	1,723437	0,223756	- 0,0263158
Greece	7	152951	0,039181	0,223756	- 0,0263158
Hungary	7	10433	0,109822	0,223756	- 0,0263158
Ireland	1	599	- 0,111678	0,223756	- 0,0263158
Italy	9	14285	- 0,109987	0,223756	- 0,0263158
Latvia	3	497	0,141616	0,223756	- 0,0263158
Lithuania	3	0	0,124734	0,223756	- 0,0263158
Malta	2	281	0,095187	0,223756	- 0,0263158
Moldova	2	0	0,144746	0,223756	- 0,0263158
Netherlands	4	380188	0,245201	0,223756	- 0,0263158
Norway	4	12249	0,075110	0,223756	- 0,0263158
Poland	6	87644	- 0,070214	0,223756	- 0,0263158
Portugal	3	115348	- 0,001811	0,223756	- 0,0263158
Portugal-S.M.	3	0	- 0,027348	0,223756	- 0,0263158
Romania	5	7649	0,138266	0,223756	- 0,0263158
Serbia-Montenegro	7	23603	0,123920	0,223756	- 0,0263158
Slovakia	5	16903	0,092798	0,223756	- 0,0263158
Slovenia	4	1147	0,094037	0,223756	- 0,0263158
Spain-Canarias	3	85782	- 0,330796	0,223756	- 0,0263158
Spain-Continental	2	643498	- 0,190509	0,223756	- 0,0263158
Sweden	8	20217	- 0,044900	0,223756	- 0,0263158
Switzerland	4	238993	0,005002	0,223756	- 0,0263158
Turkey	5	0	0,078826	0,223756	- 0,0263158
United Kingdom	6	418087	0,220777	0,223756	- 0,0263158
Ukraine	5	0	0,131918	0,223756	- 0,0263158

Data set arithmetic mean = 237409,74 [min]

Iz dobivenih rezultata može se zaključiti da je riječ o pozitivnoj autokorelaciji i da područja s natprosječnim vrijednostima područno graniče s regijama u kojima su iznosi promatranih

vrijednosti ispod dobivene aritmetičke sredine. Za razliku od negativne prostorne autokorelacije, koja označava uzorak gdje su geografske jedinice sličnih vrijednosti razasute po mapi (području istraživanja), kod pozitivne prostorne autokorelacije geografsko obličje sličnih vrijednosti teži grupiranju. Lokalni Moranovi koeficijenti pokazuju kako vrijednosti ostvarene u Belgiji, Francuskoj, Njemačkoj i Nizozemskoj daju najveći doprinos pozitivnoj vrijednosti Moranovog koeficijenta. Pri tome navedena područja u usporedbi s područjima odgovornosti susjednih pružatelja usluga u zračnoj plovidbi ne pokazuju otklon u istom smjeru. Slika 11 prikazuje rutnu mrežu europskog zračnog prostora s prikazom zračnog prostora koji se prostorno klasterira, tj. područjem gdje lokalni Moranovi koeficijenti premašuju globalni Moranov koeficijent i očekivane vrijednosti.



Slika 11. Prikaz rutne mreže i područja prostornog klasteriranja europskog zračnog prostora

Anselin [36] klasteriranje definira kao uzorak koji je dio jedne veće cjeline - promatranog područja, dok za klaster navodi da označava specifično mjesto. Na osnovi Moranovih koeficijenata ne može se raspoznati o kojoj je vrsti klastera riječ. O tom problemu su Getis i Ord [37] dali izvještaj u svojim Getis-Ord statistikama. Daljnje istraživanje funkcionalnosti upravljanja europskim zračnim prostorom bavi se analizom atipičnih vrijednosti europskog zračnog prostora s ciljem utvrđivanja vrste klastera.

5.2.3. Rezultati analize prostorno atipičnih vrijednosti europskog zračnog prostora

Analizom prostorno atipičnih vrijednosti europskog zračnog prostora istraživano je da li se vrijednosti rutnih kašnjenja zrakoplova ostvarenih na području odgovornosti jednog pružatelja usluga u zračnoj plovidbi razlikuju od susjednih vrijednosti. Sukladno ranije prikazanom Moranovom dijagramu rasprostiranja (grafikon 2), u svrhu istraživanja funkcionalnosti upravljanja europskim zračnim prostorom, definirana su četiri prostorna indikatora:

1. područje visokih susjednih vrijednosti *(engl. High-High - HH),*
2. područje visokih vrijednosti sa susjedstvom niskih vrijednosti *(engl. High-Low - HL),*
3. područje niskih vrijednosti sa susjedstvom visokih vrijednosti *(engl. Low-High - LH),*
4. područje niskih susjednih vrijednosti *(engl. Low-Low - LL).*

Pri obradi numeričkih vrijednosti, iste su standardizirane i prikazane z-vrijednostima te klasificirane prema jednom od četiri ranije definirana prostorna indikatora. Svaki prostorni indikator opisan je i okarakteriziran njemu pripadajućim kriterijem:

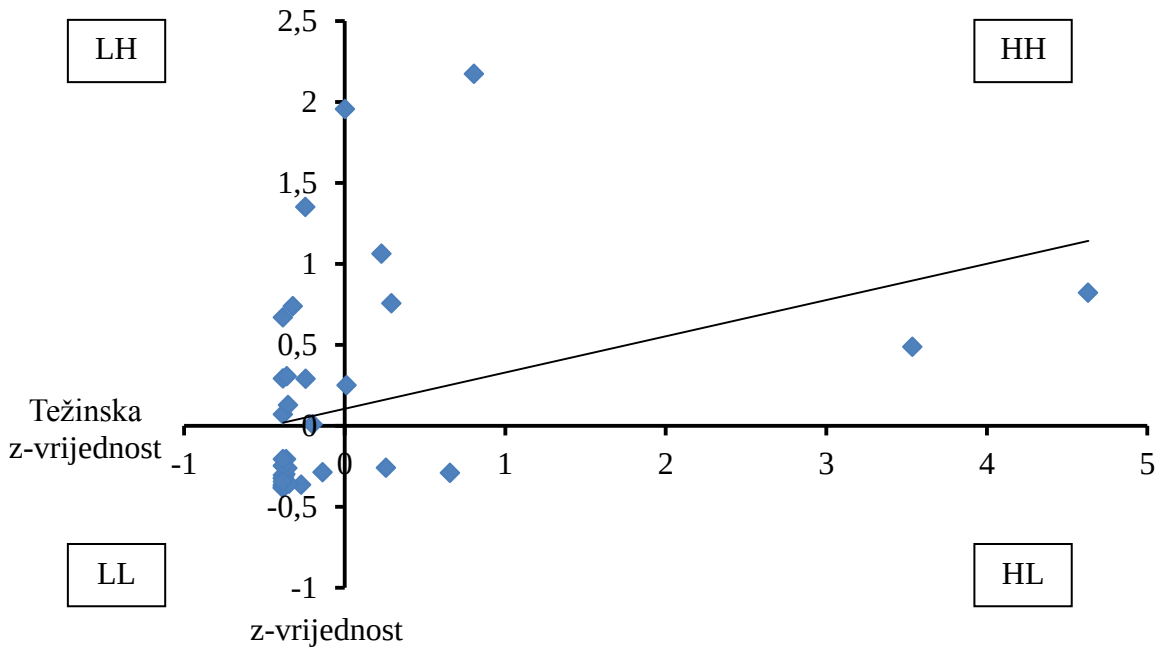
- HH indikator označava vrijednost koja je veća od ostalih vrijednosti i susjedstvo većih vrijednosti od ostalih susjedstva te je pri tome zadovoljen kriteriji; $(z > 0)$ && $(Wz > 0)$,
- HL indikator označava vrijednost koja je veća od ostalih vrijednosti i susjedstvo nižih vrijednosti od ostalih susjedstva te je pri tome zadovoljen kriteriji; $(z > 0)$ && $(Wz < 0)$,
- LH indikator označava vrijednost koja je niža od ostalih vrijednosti i susjedstvo većih vrijednosti od ostalih susjedstva te je pri tome zadovoljen kriteriji; $(z < 0)$ && $(Wz > 0)$,
- LL indikator označava vrijednost koja je niža od ostalih vrijednosti i susjedstvo nižih vrijednosti od ostalih susjedstva te je pri tome zadovoljen kriteriji; $(z < 0)$ && $(Wz < 0)$.

Tablica 6 prikazuje numeričke rezultate provedenog istraživanja prostorno atipičnih vrijednosti europskog zračnog prostora. Prikupljeni i prikazani rezultati produkt su primjene programa AirStat.

Tablica 6. Rezultati analize prostorno atipičnih vrijednosti europskog zračnog prostora

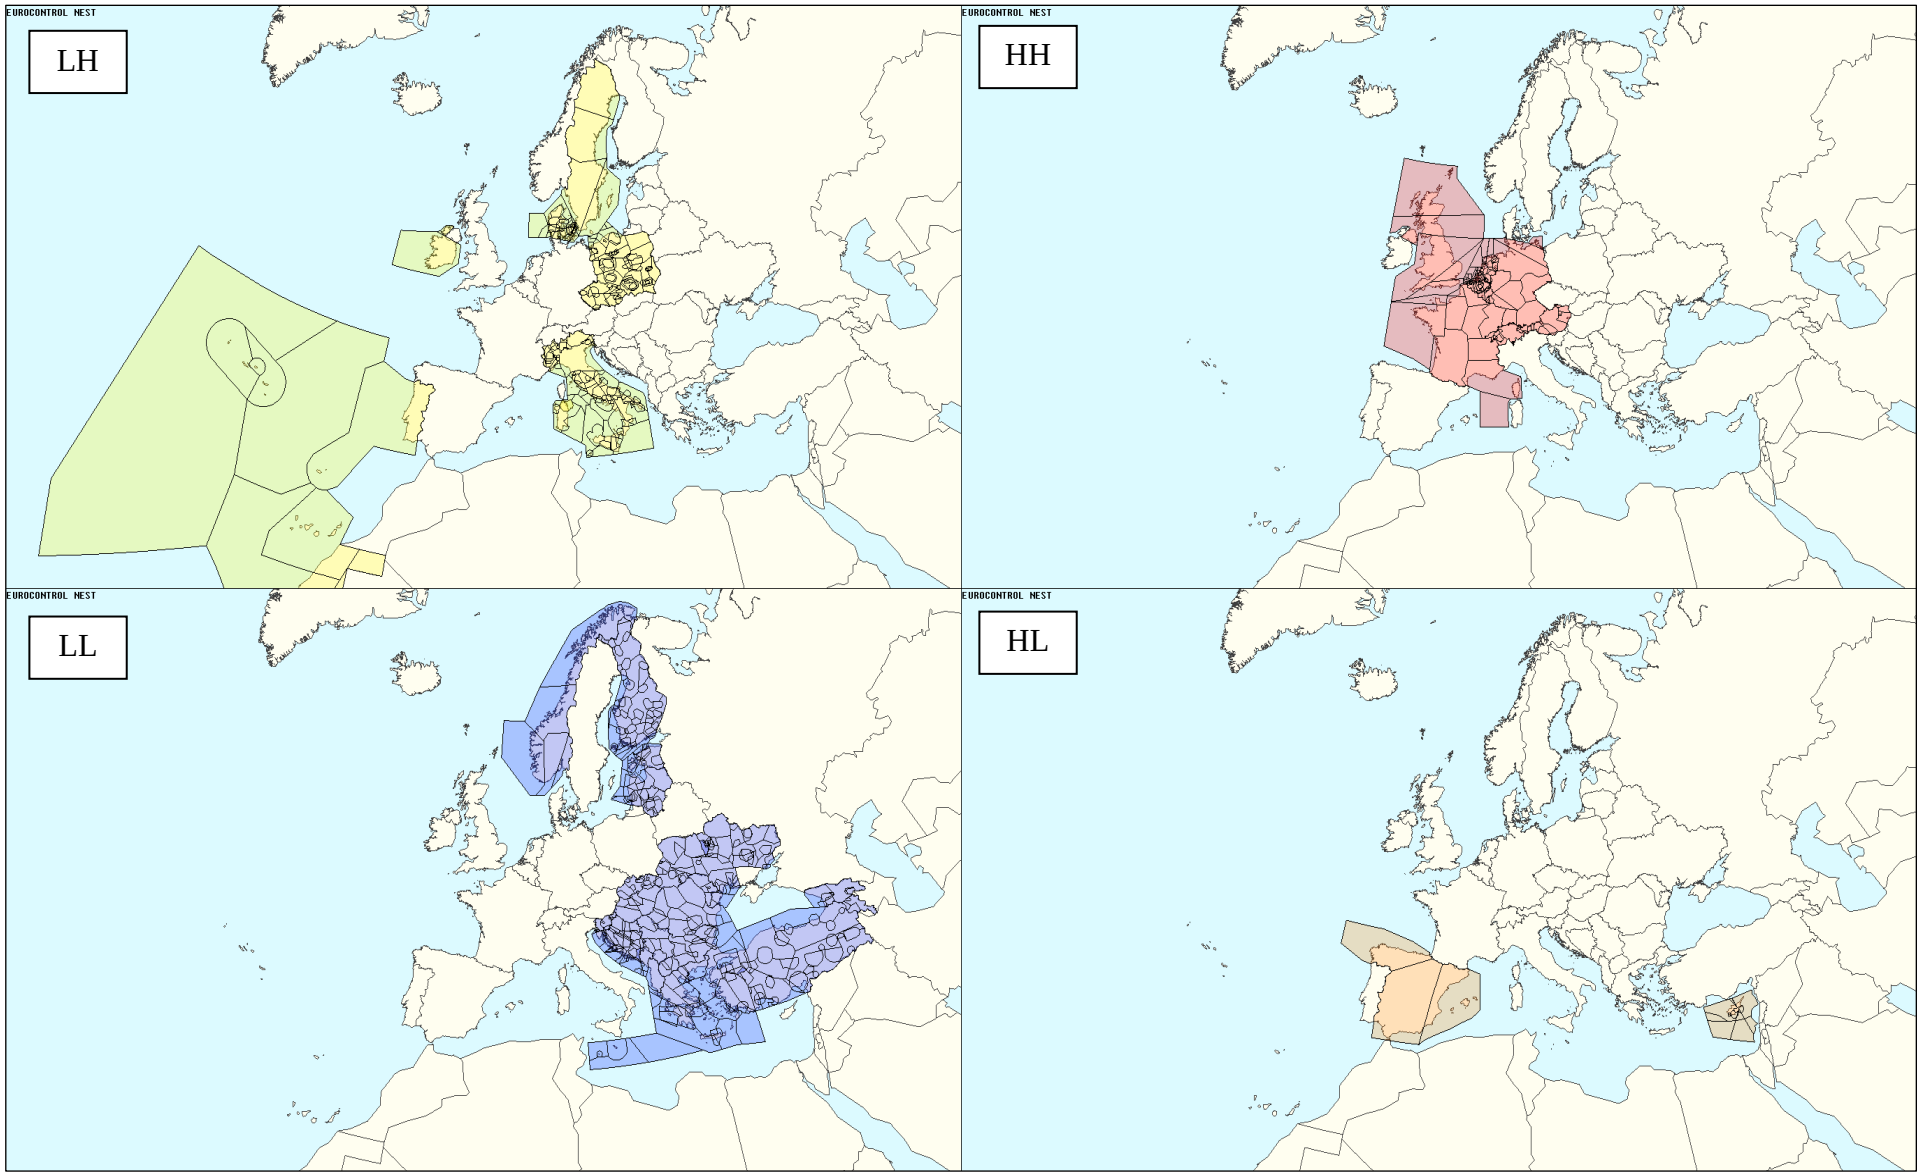
Airspace	Value	z-score(i)	W.value	Type
Albania	80	- 0,383427	- 0,304445	LL
Armenia	0	- 0,383556	- 0,383556	LL
Austria	245174	0,012544	0,250402	HH
Belgium	735966	0,805462	2,173143	HH
Bulgaria	225	- 0,383193	- 0,322412	LL
Croatia	69786	- 0,270811	- 0,363576	LL
Cyprus	397839	0,259188	- 0,260004	HL
Czech Republic	37630	- 0,322762	0,738121	LH
Denmark	0	- 0,383556	0,669212	LH
Estonia	4972	- 0,375524	- 0,372335	LL
Finland	123	- 0,383358	- 0,363395	LL
France	3104384	4,631851	0,822277	HH
FYROM	5031	- 0,375428	- 0,312124	LL
Georgia	0	- 0,383556	- 0,383556	LL
Germany	2427416	3,538149	0,487101	HH
Greece	152951	- 0,136451	- 0,287143	LL
Hungary	10433	- 0,366701	- 0,299485	LL
Ireland	599	- 0,382589	0,291900	LH
Italy	14285	- 0,360478	0,305115	LH
Latvia	497	- 0,382754	- 0,369991	LL
Lithuania	0	- 0,383556	- 0,325202	LL
Malta	281	- 0,383102	- 0,248464	LL
Moldova	0	- 0,383556	- 0,377378	LL
Netherlands	380188	0,230671	1,062989	HH
Norway	12249	- 0,363767	- 0,206477	LL
Poland	87644	- 0,241960	0,290189	LH
Portugal	115348	- 0,197202	0,009182	LH
Portugal-S.M.	0	- 0,383556	0,071301	LH
Romania	7649	- 0,371199	- 0,372486	LL
Serbia-Montenegro	23603	- 0,345424	- 0,358748	LL
Slovakia	16903	- 0,356248	- 0,260487	LL
Slovenia	1147	- 0,381703	- 0,246361	LL
Spain-Canarias	85782	- 0,244968	1,350364	LH
Spain-Continental	643498	0,656072	- 0,290379	HL
Sweden	20217	- 0,350894	0,127959	LH
Switzerland	238993	0,002558	1,955516	HH
Turkey	0	- 0,383556	- 0,205514	LL
United Kingdom	418087	0,291900	0,756345	HH
Ukraine	0	- 0,383556	- 0,343933	LL

Na temelju dobivenih rezultata kreiran je Moranov dijagram rasprostiranja koji je prikazan grafikonom 4. Nagib regresijskog pravaca koji prolazi kroz Moranov dijagram rasprostiranja predstavlja vrijednost Moranovog I koeficijenta.



Grafikon 4. Moranov dijagram rasprostiranja analiziranih vrijednosti

Na temelju provedene analize prostorno atipičnih vrijednosti europskog zračnog prostora može se zaključiti da je 17,95% ukupne vrijednosti promatranog skupa podataka svrstano prema indikatoru HH te označava područje visokih susjednih vrijednosti. Takvo područje obuhvaća 14,08% ukupne površine promatranog zračnog prostora. Područja niskih susjednih vrijednosti čine 53,85% ukupne vrijednosti promatranog skupa podataka te obuhvaćaju 26,76% površine promatranog zračnog prostora. Na područja visokih vrijednosti sa susjedstvom niskih vrijednosti (indikator HL) otpada 5,13% ukupne vrijednosti promatranog skupa podataka te obuhvaćaju zračni prostor veličine 679 957 km^2 (3,8% ukupne površine promatranog zračnog prostora). Ostatak europskog zračnog prostora svrstava se prema indikatoru LH te zajedno čine 23,08% ukupne vrijednosti promatranog skupa podataka odnosno 55,36% površine ukupno promatranog europskog zračnog prostora. U nastavku rada, slika 12 prikazuje prostorni prikaz dobivenih rezultata analize prostorno atipičnih vrijednosti europskog zračnog prostora.



Slika 12. Prikaz prostorno atipičnih vrijednosti europskog zračnog prostora

5.3. Analiza rezultata istraživanja

Dokument Međunarodne organizacije civilnog zrakoplovstva *(engl. International Civil Aviation Organisation - ICAO)* Doc 4444 „Air Traffic Management“ [38] definira da nadležno tijelo za operativne usluge u zračnoj plovidbi *(engl. Air Traffic Services - ATS)* treba periodično pratiti razinu kapaciteta u odnosu na potražnju te treba osigurati fleksibilnu upotrebu zračnog prostora kako bi se unaprijedila operativna učinkovitost i povećao kapacitet zračnog prostora. U slučaju da prometna potražnja redovito nadmašuje ATC kapacitet ili postane vidljivo da će ga premašiti, nadležno ATS tijelo treba poduzeti korake za maksimiziranje upotrebe postojećeg kapaciteta sustava i razviti planove povećanja kapaciteta kako bi se zadovoljilo buduću predviđenu potražnju.

Planiranje kapaciteta omogućava identifikaciju nedostataka kapaciteta i potencijalnih uskih grla s ciljem omogućavanja pravovremenog dijaloga i rješavanja situacija u kojima može doći do nedostatka kapaciteta. Planovi kapaciteta uglavnom su usredotočeni na ljetnu sezonu iz razloga što je u Europi to razdoblje najgušćeg prometa. Tijekom zime (zimskog reda letenja) analiziraju se i koordiniraju prijelazni planovi individualnih ANSP-ova s ciljem minimiziranja utjecaja na mrežne poslove uzrokovanih privremenim smanjenjem kapaciteta zračnog prostora [39].

U okviru ovog istraživanja primijenjena je metodologija istraživanja temeljena na proučavanju prostorne autokorelacije. Schabenberger i suautor [40] definiraju autokorelaciju kao korelaciju varijable sa samom sobom, dok prostornu autokorelaciju opisuju kao korelaciju varijable sa samom sobom na različitim prostornim lokacijama. Jedan od glavnih razloga zašto je istraživanje prostorne autokorelacije važno jest taj da se statistika oslanja na zapažanjima koja su neovisna jedno o drugome. Stoga, ukoliko postoji prostorna autokorelacija onda to krši činjenicu da su opažanja neovisna jedno o drugome.

Anselin [33] opisuje analizu prostornih podataka kao statističku studiju određenog fenomena koji se očituje u prostoru, dok Goodchild [41] navodi da "prvi zakon geografije", kojeg je definirao Tobler (1970.): „Sve je u određenom odnosu, ali su bliži objekti povezaniji od udaljenijih” opisuje prostornu autokorelaciju na najpreciznij način.

Zerrouki i suautori u [42] zaključuju da unutar rutne mreže europskog zračnog prometa postoji velika međuovisnost te da letovi na koje se djeluje regulacijama utječu i na druge

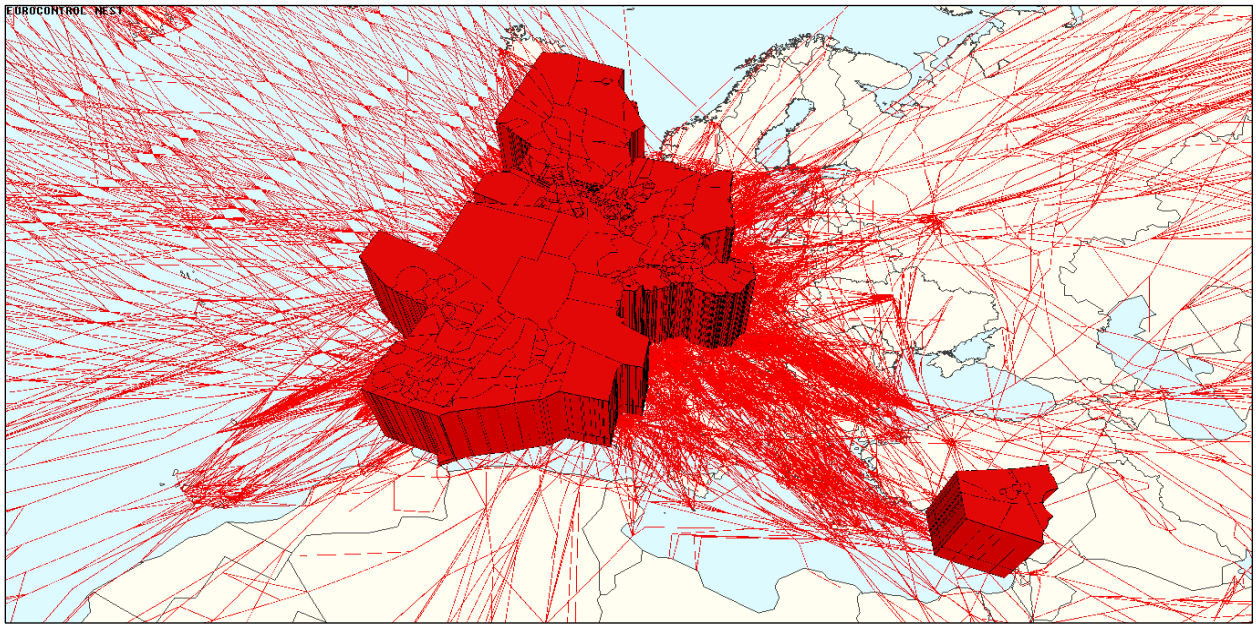
regulirane i neregulirane letove. Tako se stvara mogućnost pojave prekapacitiranosti te se posljedice mogu očitovati i u susjednim sektorima, unutar iste regije ili na udaljenim područjima.

Općenito, homogenim zračnim prostorom se smatra ATM prostor s jednakim ATM elementima koji se temelje na jednakim karakteristikama gustoće prometa, kompleksnosti, infrastrukturalnim zahtjevima i sličnom. Pri tome se granice homogenog zračnog prostora definiraju na temelju političkih ili ekonomskih uvjeta.

U okviru istraživanja funkcionalnosti upravljanja europskim zračnim prostorom, identificirana su homogena područja europskog zračnog prostora, čije se granice mogu definirati na temelju ekonomskih uvjeta. S obzirom na to da kapacitet ima cijenu, a da nedostatak kapaciteta, uslijed kojeg dolazi do nastanka kašnjenja, ima još veću cijenu, moguće je definirati ekonomičnost funkcionalnosti upravljanja europskim zračnim prostorom. Iznos troška kašnjenja zrakoplova temeljen je na studiji koju je za Eurocontrol provelo Sveučilište u Westminsteru u Ujedinjenom Kraljevstvu pod nazivom „European airline delay cost reference values“. Prema recentnoj studiji [43] iz 2018. godine, trošak jedne minute rutnog kašnjenja zrakoplova iznosi 100 EUR te se odnosi na prosječnu vrijednost, koja uzima u obzir sve uzroke kašnjenja. Uzimajući u obzir vrijednost troška jedne minute rutnog kašnjenja zrakoplova te ukupnu vrijednost rutnih kašnjenja zrakoplova generiranu tijekom 2017. godine, može se zaključiti kako je na istraživanom području dodatni operativni trošak korisnicima zračnog prostora evaluiran u vrijednosti od 925.898.000 EUR.

Slijedom sveukupno provedenih istraživanja može se zaključiti da postoji prostorno klasteriranje europskog zračnog prostora u ovisnosti o području nastanka i iznosu vrijednosti rutnih kašnjenja zrakoplova, no da uzorak nije izrazito velik (11,07% ukupne površine promatranog područja). Glavni razlog tome je izrazito velika razlika vrijednosti rutnih kašnjenja zrakoplova ostvarenih na području odgovornosti različitih pružatelja usluga u zračnoj plovidbi. Provedbom analize prostorno atipičnih vrijednosti europskog zračnog prostora identificirana su homogena područja europskog zračnog prostora. Pri tome se od ukupno promatranog skupa podataka 17,95% klasificira kao područje visokih susjednih vrijednosti, 53,85% kao područje niskih susjednih vrijednosti, 23,08% kao područje niskih vrijednosti sa susjedstvom visokih vrijednosti, dok ostalih 5,13% označava područje visokih vrijednosti sa susjedstvom niskih vrijednosti.

Usporedbom rezultata provedenih analiza može se zaključiti da prostorni uzorak, otkriven provedbom redoslijedno druge analize, označava prostorno grupiranje, koje se zbog visokih vrijednosti izrazito razlikuju od ostalih promatranih područja te je okarakterizirano HH indikatorom sa žarišnim područjem na području odgovornosti DSNA-e i DFS-a. Ekonomski promatrano, na spomenutom području generirano je 71,8% ukupnih dodatnih operativnih troškova korisnicima zračnog prostora, odnosno generiran je trošak u vrijednosti od 664.795.400 EUR od čega na definirana žarišna područja otpada 83,21% navedenog troška. Također, osim navedenih žarišnih područja kao i ostalih područja okarakteriziranih HH indikatorom, u obzir treba uzeti i kontinentalni dio područja odgovornosti ENAIRE u Kraljevini Španjolskoj, kao i područje odgovornosti DCAC Cyprus u Republici Cipar, koji su okarakterizirani kao područja visokih vrijednosti sa susjedstvom niskih vrijednosti. Na kontinentalnom području odgovornosti ENAIRE ostvarene su čak i veće vrijednosti rutnih kašnjenja u odnosu na neka od područja označenih indikatorom HH. Za razliku od područja odgovornosti ENAIRE, koje graniči sa HH/VHCV područjima, područje odgovornosti DCAC Cyprus u potpunosti graniči s područjem niskih susjednih vrijednosti (LL). Oba navedena područja izrazito utječu na rutnu mrežu promatranog zračnog prostora te su zbog geografskog položaja i dominantno nižih susjednih vrijednosti označeni HL indikatorom, a ne HH indikatorom. U nastavku, slika 13 prikazuje područja gdje je potrebno poboljšati razinu funkcionalnosti upravljanja zračnim prostorom.



Slika 13. Disfunkcionalna područja europskog zračnog prostora s prikazom zračnih tokova

Prema Eurocontrolovom izvješću [44], primjena rutnih restrikcija povećana je na više od milijun kontroliranih letova, što predstavlja povećanje od 30% u odnosu na 2016. godinu, te je oko 80% kontroliranih letova bilježilo kašnjenje manje od 15 minuta. Također, Eurocontrol navodi kako je tijekom 2017. godine Operativni centar upravitelja mreže *(engl. Network Manager Operations Centre - NMOC[1])* spriječio pojavu 2.1 milijuna minuta kašnjenja zrakoplova od čega na rutna kašnjenja zrakoplova otpada 71%, a na kašnjenja na aerodromima 29% ukupne veličine kašnjenja. Time je na razini rutne mreže spriječeno generiranje dodatnih operativnih troškova korisnicima europskog zračnog prostora u vrijednosti od 149.100.000 EUR.

Iako svrha istraživanja nije ispitivanje uzroka nastanka određenih vrijednosti kašnjenja, u nastavku rada ukratko je provedena elaboracija uzroka i područja nastanka izrazito visokih vrijednosti rutnih kašnjenja zrakoplova s ciljem potpore i obrazloženja dobivenih rezultata istraživanja.

Tijekom srpnja, kolovoza i rujna 2017. godine ostvarena je najveća razina prometa, gdje je tijekom svakog pojedinog mjeseca na razni rutne mreže ostvaren promet s više od milijun letova, dok je 30. lipnja 2017. godine bio najprometniji dan s 35.937 letova. Kao produkt povećanja razine prometa (prometne potražnje), povećala se i razina rutnih kašnjenja zrakoplova. Pri tome je veliki broj rutnih kašnjenja uzrokovan vremenskim neprilikama i nedostatkom kapaciteta zračnog prostora te ATC osoblja. Vrijednost rutnih kašnjenja zrakoplova uzrokovana vremenskim neprilikama povećala se za 30% u odnosu na vrijednost tijekom 2016. godine, te udvostručila u odnosu na vrijednost iz 2015. godine. Veliki broj rutnih kašnjenja rezultat je povećane prometne potražnje tijekom vikenda, a naročito tijekom nedjelja za vrijeme ljetnih mjeseci kada je ostvarivan vršni promet.

Od prikazanih područja s visokim vrijednostima kašnjenja, oblasne kontrole zračnog prometa s kapacitivnim nedostatcima - ACC Cipar i ACC Marseille, nisu ispunili ranije definirane obaveze što se prvenstveno odnosi na činjenicu da su otvorili manji broj sektora u odnosu na prethodnu godinu što je rezultiralo dodatnim generiranjem rutnih kašnjenja zrakoplova. Kao primjer dobre prakse oblasnih kontrola zračnog prometa, koje su tijekom 2017. godine implementirale odgovarajuće mjere i ostvarili bolji učinak od planiranog, navode se oblasne

[1] Ranije poznat kao i Središnja jedinica za upravljanje protokom *(engl. Central Flow Management Unit - CMFU)*

kontrole zračnog prometa Atena, Makedonija, Lisbon, Skopje i Zagreb. Navedeni ACC su tijekom ranijih kapacitivnih planiranja klasificirani kao područja gdje bi se tijekom ljetnog reda letenja trebao pojaviti nedostatak kapaciteta zračnog prostora, no unatoč 9% povećanju prometa izbjegnuta je dugoročna prekapacitiranost i zagušenost zračnih tokova.

Iako je Mrežni Upravitelj obaviješten o problemima nedostatka osoblja, ACC Karlsruhe nije implementirao predviđene kapacitivne planove, što je rezultiralo dodatnim generiranjem rutnih kašnjenja zrakoplova tijekom ljetnog reda letenja. Tijekom 2017. godine Brest i Bordeaux ACC ostvarili su bolje rezultate u odnosu na prethodnu godinu, prvenstveno zbog povećanog broja otvorenih sektora, no zbog izrazito velike potražnje za uslugama, posebno nedjeljama, te i nedostatka kapaciteta zračnog prostora, i dalje su generirane visoke vrijednosti rutnih kašnjenja zrakoplova [44].

ATC industrijske aktivnosti predstavljaju jedan od uzročnika nastanka rutnih kašnjenja zrakoplova, čijom bi se redukcijom, u odnosu na ostale uzročnike nastanka rutnih kašnjenja, moglo najbrže doći do veće razine funkcionalnosti upravljanja europskim zračnim prostorom. Redukcija pojavnosti navedenog uzročnika u širem smislu predstavlja interes cjelokupne europske zrakoplovne industrije. Zbog ATC industrijskih aktivnosti na razini promatranog europskog zračnog prostora generirano je 710.073 minuta rutnih kašnjenja zrakoplova, odnosno trošak od 71.007.300 EUR. Tijekom travnja, rujna, listopada i studenog 2017. godine zbog ATC industrijskih aktivnosti francuskog pružatelja usluga u zračnoj plovidbi (DSNA), generirana je vrijednost od 691.985 minuta rutnog kašnjenja zrakoplova, odnosno trošak korisnicima analiziranog zračnog prostora od 69.198.500 EUR[2]. Prema tome, može se zaključiti da od ukupno generiranih rutnih kašnjenja zbog ATC industrijskih aktivnosti 97,45% istih ostvareno je na području suvereniteta Republike Francuske. Stoga bi, kao što je ranije navedeno, uzimajući u obzir interese cjelokupne europske zrakoplovne industrije trebalo putem jačanja prekogranične suradnje i regionalizacije ATM sustava usuglasit odgovarajuće mjere unaprjeđenja budućeg koncepta upravljanja zračnim prostorom. Takva praksa bi za cilj imala minimiziranje utjecaja nacionalnih politika i parcijalnog nezadovoljstva određenih dionika na cjelokupnu učinkovitost i funkcionalnost europskog sustava upravljanja zračnim prostorom.

[2] Pri čemu se prikazana vrijednost odnosi na izravne operativne troškove korisnika zračnog prostora ostvarene tijekom leta zrakoplova na rutnoj mreži za vrijeme ATC industrijskih aktivnosti, te ne predstavlja ukupni trošak korisnika zračnog prostora uzrokovan ATC industrijskom aktivnosti iz razloga što ne uključuje posredne troškove otkazivanja letova, kompenzacija putnicima i slične troškove.

6. PRIJEDLOG OPERATIVNOG KONCEPTA ZA UNAPRJEĐENJE ASM SUSTAVA

S obzirom na to da bi se prema predviđanju prometa na području Europe tijekom 2035. godine trebalo ostvariti oko 14,4 milijuna letova [45], što predstavlja povećanje prometne potražnje za 26,39% u odnosu na promet ostvaren tijekom 2017. godine, te uzimajući u obzir već postojeće probleme, može se zaključiti da je potrebno nastaviti razvijati europski sustav upravljanja zračnim prostorom.

Steiner i suautori [46] navode da postoji nekoliko potencijalnih promjena kojima je moguće povećati kapacitete i učinkovitost ATM sustava. Pri tome navode da je poboljšanja moguće ostvariti promjenama koje se odnose na uvođenje cjelokupnih koncepata kao što su zajedničko donošenje odluka *(engl. Collaborative Decision Making - CDM)*, prostora slobodnih ruta *(engl. Free Route Airspace - FRA)* te implementacijom različitih tehnoloških rješenja i inovacija, ali i relativno jednostavnim poboljšanjima već postojećih procedura.

Rezultati istraživanja ukazuju na potrebu fleksibilnijeg korištenja resursa na području Funkcionalnog bloka zračnog prostora Srednja Europa. Također, predlaže se da bi unaprjeđenja trenutne razine funkcionalnosti sustava trebalo sve više razmatrati na razini cjelokupne rutne mreže te pojedinih Funkcionalnih blokova zračnog prostora. Takvim pristupom, smanjio bi se veliki broj „decision-makera“ i minimizirala izloženost sustava među-nacionalnim ili regionalnim neusklađenostima koje imaju utjecaj na cjelokupnu europsku zrakoplovnu industriju. Takvim pristupom, djelomično bi se osigurao prihvatljiv odgovor na budući porast prometne potražnje na području Europe. Sukladno navedenom pružatelji usluga u zračnoj plovidbi trebali bi i dalje nastaviti s:

- implementacijom suvremene radne prakse i upravljačkih procesa,
- unaprjeđenjem prakse implementiranja novih sustava i struktura zračnog prostora,
- kvalitetnijim upravljanjem i organizacijom rada te minimiziranjem problema nedostataka ATC osoblja s ciljem povećanja njihove dostupnosti u prometno zahtjevnom vremenu (pogotovo vikendima za vrijeme ljetnog reda letenja).

Budući koncept unaprjeđenja ASM sustava na području Europe trebao bi uključivati i provedbu dodatnih aktivnosti i mjera koje nisu izravno u nadležnosti pružatelja usluga u zračnoj plovidbi, ali koje bi utjecale na njihov operativni segment (i tako na sveukupni izgled europskog

sustava upravljanja zračnim prostorom). Skup takvih aktivnosti i mjera trebao bi biti usuglašen na razini cijele europske mreže, te se temeljiti na kvalitetnoj tehničkoj i regulatornoj podršci te učestaloj kontroli učinkovitosti i funkcionalnosti sustava. No, prije uvođenja novih regulatornih i operativnih mjera na razini Europe, potrebno je pospješiti provedbu već postojećih mjera i regulative, kao i odustati od mjera i projekata koji se već duži niz godina odgađaju ili nemaju realnu mogućnost implementacije. Navedeno se prvenstveno odnosi na implementaciju već postojećih projekata definiranih europskim ATM Master Planom. Stoga bi na razini promatranog europskog zračnog prostora trebalo primijeniti sljedeće:

- kratkoročna/srednjoročna mjera: zajednički definirati nove načine upravljanja zračnim prometom kroz suradnju susjednih centara oblasnih kontrola zračnog prometa,
- srednjoročna/dugoročna mjera: promijeniti trenutni koncept europskog sustava upravljanja i planiranja kapaciteta zračnog prostora s lokalnog na regionalni pristup planiranja koji bi se trebao temeljiti na što većoj prekograničnoj suradnji.

Na područjima s izrazito visokim vrijednostima rutnih kašnjenja zrakoplova (prikazanih ranije u radu), posebno se treba usredotočiti na implementaciju kratkoročnih mjera (čak i privremenih) kako bi se u područjima tzv. uskih grla povećao kapacitet zračnog prostora sve dok ne bude moguća implementacija dugoročnih rješenja. Pružatelji usluga u zračnoj plovidbi trebali bi težiti suradnji sa susjednim pružateljima usluga u zračnoj plovidbi kako bi se koncepcija fleksibilnog korištenja zračnog prostora primjenjivala trans-nacionalno i regionalno. Primjenom takvog pristupa dugoročno bi se olakšala kasnija regionalizacija cjelokupnog ATM sustava, dok bi se kratkoročno prekograničnom suradnjom olakšala alokacija traženog zračnog prostora na dnevnoj bazi s ciljem zadovoljavanja trenutne prometne potražnje.

Također, u okviru Eurocontrolovog dokumenta [47] navodi se da je potrebno uvesti i odgovarajuće mjere za poboljšanje djelotvornosti upravljanja protokom zračnog prometa s ciljem pomaganja postojećim operativnim jedinicama, uključujući i Eurocontrolovu središnju službu organizacije protoka zračnog prometa.

Na razini Europske unije trebalo bi razmotriti ulogu i odgovornosti određenih Nacionalnih povjerenstva za upravljanje zračnim prostorom, koji bi se trebali baviti formuliranjem nacionalnih politika upravljanja zračnim prostorom, te strateškim planiranjem zračnog prometa uzimajući u obzir zahtjeve nacionalnih i međunarodnih korisnika zračnog prostora, pružatelja

usluga u zračnoj plovidbi, kao i korisnika usluga zračnog prometa. S obzirom na izrazito velike vrijednosti rutnih kašnjenja zrakoplova nastalih zbog ATC industrijskih aktivnosti tijekom 2017. godine, na razini cjelokupnog europskog zračnog prostora potrebno je ojačati i implementirati dodatne zaštitne mjere, čime bi se korisnike zračnog prostora zaštitilo od budućih povećanja troškova prijevozništva uzrokovanih ATC industrijskim aktivnostima. Takve mjere prvenstveno bi se trebale odnositi na područja identificirana istraživanjem prikaznim u sklopu Priloga 3.

S ciljem rješavanja problema nedostataka kapaciteta i poboljšanja funkcionalnosti upravljanja europskim zračnim prostorom potrebno je također razmotriti i istovremenu primjenu sljedećih rješenja [48]:

- osoblje: dodatni kontrolori, unaprijeđeno planiranje osoblja, fleksibilnost rasporeda rada, dostupnost kontrolora,
- sustav: nadogradnja ATM sustava, Mode S/Datalink, ATC alati, sigurnosne mreže, dostupnost frekvencija s potrebnom pokrivenošću i zaštitom,
- procedure: ATC procedure, smanjenje separacije zrakoplova, procedure upravljanja zračnim prostorom, koordinacijske procedure, šira implementacija već postojećih najboljih rješenja, izmjene metoda rada kontrolora i unaprjeđenje procedura, revidiranje ugovora o koordinaciji kontrola zračnog prometa,
- zračni prostor i dizajn ruta: poboljšanja rutne mreže, optimizacija sektorizacije, izravne noćne/vikend rute, unaprjeđenje terminalnog zračnog prostora, poboljšanja prekogranične suradnje,
- suradnja civilnog i vojnog zrakoplovstva: unaprjeđenje fleksibilnog korištenja zračnog prostora, poboljšana koordinacija civilnog i vojnog zrakoplovstva,
- ATFCM: unaprijeđene ATFCM procedure, unaprijeđeno predviđanje prometa, poboljšanje koordinacije i radnih odnosa između Mrežnog upravitelja, pozicije kontrole protoka prometa i kontrolora zračnog prometa,
- kapacitet: dinamična sektorizacija, kreiranje dodatnih sektora, produljenje vremena otvorenosti sektora, dinamičko upravljanje konfiguracijom sektora, povećanje kapaciteta sektora.

7. ZAKLJUČAK

Prostorno neuravnotežen razvoj zračnog prometa na području Europe rezultirao je eskalacijom negativne dimenzije zračnog prometa, koja se ponajbolje očituje kašnjenjima zrakoplova zbog nedostatka kapaciteta. S obzirom na to da kapacitet ima cijenu, a da nedostatak kapaciteta, uslijed kojeg dolazi do nastanka kašnjenja, ima još veću cijenu, moguće je definirati ekonomičnost funkcionalnosti upravljanja europskim zračnim prostorom. Uzimajući u obzir vrijednost troška jedne minute rutnog kašnjenja zrakoplova te ukupno generiranu vrijednost kašnjenja tijekom 2017. godine, može se zaključiti kako je na istraživanom području evaluiran dodatni operativni trošak korisnicima zračnog prostora u veličini od 925.898.000 EUR.

U okviru rada, na temelju kreiranog matematičkog modela, provedeno je istraživanje koje se temelji na metodologiji istraživanja prostorne autokorelacije vrijednosti rutnih kašnjenja generiranih na području odgovornosti 39 pružatelja usluga u zračnoj plovidbi. Analizom žarišnih područja, analizom prostornog klasteriranja i analizom prostorno atipičnih vrijednosti europskog zračnog prostora prikazana je razina funkcionalnosti upravljanja europskim zračnim prostorom tijekom 2017. godine. Sveukupno istraživanje temeljeno je na provedbi 15 ciljanih istraživanja i 45 analiza podataka. Primjenom programa AirStat i provedbom sveukupno 43.860 matematičkih operacija omogućen je prikaz rezultata istraživanja i donošenje odgovarajućih zaključaka o razini funkcionalnosti upravljanja europskim zračnim prostorom.

Slijedom sveobuhvatno provedenih istraživanja, može se zaključiti kako je identificirano prostorno klasteriranje europskog zračnog prostora u ovisnosti o području nastanka i veličini rutnih kašnjenja zrakoplova, no da uzorak nije izrazito velik - 11,07% ukupne površine promatranog područja. Glavni razlog tome je izrazito velika razlika vrijednosti rutnih kašnjenja zrakoplova generiranih na različitim područjima odgovornosti pružatelja usluga u zračnoj plovidbi, pri čemu se ističu vrijednosti okarakterizirane VHCV indikatorom.

Provedbom analize prostorno atipičnih vrijednosti europskog zračnog prostora identificirana su homogena područja europskog zračnog prostora. Pri tome se od ukupno promatranog skupa podataka 17,95% klasificira kao područje visokih susjednih vrijednosti, 53,85% kao područje niskih susjednih vrijednosti, 23,08% kao područje niskih vrijednosti sa susjedstvom visokih vrijednosti, dok ostalih 5,13% označava područje visokih vrijednosti sa susjedstvom niskih vrijednosti.

Usporedbom rezultata provedenih analiza može se zaključiti da prostorni uzorak, detektiran provedbom redoslijedno druge analize, označava prostorno grupiranje koje se zbog visokih vrijednosti izrazito razlikuju od ostalih promatranih područja, te je okarakterizirano HH indikatorom sa žarišnim područjem na području odgovornosti DSNA-e i DFS-a. Ekonomski promatrano, na spomenutom području generirano je 71,8% ukupnih dodatnih operativnih troškova korisnicima zračnog prostora, odnosno generiran je trošak u vrijednosti od 664.795.400 EUR, od čega na žarišna područja otpada 83,21% navedenog troška. Osim navedenih žarišnih područja, kao i ostalih disfunkcionalnih područja okarakteriziranih HH indikatorom, u obzir treba uzeti i kontinentalni dio područja odgovornosti ENAIRE, kao i područje odgovornosti DCAC Cyprus, koji su okarakterizirani kao područja visokih vrijednosti sa susjedstvom niskih vrijednosti. Na kontinentalnom području odgovornosti ENAIRE ostvarene su čak i veće vrijednosti rutnih kašnjenja u odnosu na neka od područja označena indikatorom HH. Za razliku od područja odgovornosti ENAIRE, koje graniči sa HH/VHCV područjima, područje odgovornosti DCAC Cyprus u potpunosti graniči s područjem niskih susjednih vrijednosti (LL indikator). Navedena područja izrazito utječu na rutnu mrežu promatranog zračnog prostora, no zbog geografskog položaja i dominantno nižih susjednih vrijednosti označeni su HL indikatorom.

S naglaskom na međunarodnu dimenziju utjecaja proizašlih iz vrijednosti rutnih kašnjenja zrakoplova, u radu su predočen rezultati analiza statusa s preciznom detekcijom razine funkcionalnosti upravljanja europskim zračnim prostorom tijekom 2017. godine. Uzimajući u obzir da je u zadnje dvije dekade kao najuočljivija slabost sustava upravljanja zračnim prometom prepoznat problem donošenja odluka na nacionalnim razinama, ovim istraživanjem predložen je i mogući način, kojim se može osigurati kvalitetna valorizacija prometnih učinaka, te konzistentnije donošenje odluka, odgovarajućih mjera i aktivnosti u strateškom planiranju zračnog prometa. K tome, strategijsko planiranje prometnog razvitka mora biti u funkciji ukupnog gospodarskog razvitka, koje ne smije biti nacionalno ograničeno, već treba biti u kontekstu razvitka šire regije. Pri tome je važno uvažavati kohezijski potencijal regionalnog razvoja, a analiza prometno-prostorne korelacije upravo ukazuje na „gapove“ u razvojnoj policentrici.

Daljnjim razvojem i nadogradnjom, program AirStat bi se mogao primjenjivati u strateškom planiranju razvoja zračnog prometa, poglavito u prijevozničkoj zrakoplovnoj operativi i ATM operativi pružatelja usluga u zračnoj plovidbi, u djelokrugu agencija civilnog zrakoplovstva, te akademskih i istraživačkih ustanova.

LITERATURA

[1] Eurocontrol: „Challenges of Air Transport 2030: Survey of experts' views“, 2008., URL: https://www.eurocontrol.int/eec/gallery/content/public/document/eec/other_document/2009/003_Challenges_of_air_transport_2030_experts_view.pdf (pristupljeno: 26.2.2018.)

[2] International Civil Aviation Organisation: „Annex 11: Air Traffic Services“, 2001., URL: http://mid.gov.kz/images/stories/contents/an11_en.pdf (pristupljeno: 15.3.2018.)

[3] Mihetec, T.: „Upravljanje zračnom plovidbom“, Fakultet prometnih znanosti, Autorizirana predavanja, 2017.

[4] Majumdar, A.: „Framework for modeling the capacity of Europe's airspace using a model of air traffic controller workload“, University of London Center for Transport Studies Imperial college of Science, Technology and Medicine South Kensington, London, England, 2003.

[5] Eurocontrol: „Concept of operations for enhancing the ASM/ATFM/ATC processes“, URL: https://www.eurocontrol.int/sites/default/files/field_tabs/content/documents/nm/airspace/airspace-management-conops-fua-2008.pdf (pristupljeno: 8.5.2018.)

[6] Eurocontrol: „European Route Network Improvement Plan: Part III“, 2017., URL: http://www.eurocontrol.int/sites/default/files/publication/files/ernip-part-3-asm-handbook-edition-5-v5-4.pdf (pristupljeno: 20.4.2018.)

[7] Eurocontrol: „Network Manager handles record levels of traffic in 2017“, URL: http://www.eurocontrol.int/press-releases/network-manager-handles-record-levels-traffic-2017 (pristupljeno: 3.3.2018.)

[8] Mihetec, T., Božičević, A., Steiner, S.: „Sigurnosna domena europskog programa ATM 2000+“, Nezgode i nesreće u prometu i mjere za njihovo sprječavanje: zbornik radova sa znanstvenog skupa (Kaštela, S., Steiner, S.), Hrvatska akademija znanosti i umjetnosti, Zagreb, p. 108-115, 2007.

[9] Europska komisija: „Strategiji zrakoplovstva za Europu", Bruxelles, 2015., URL: http://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:52015DC0598&from=HR (pristupljeno: 10.2.2018.)

[10] Steiner, S., Mihetec, T., Božičević, A.: „Prospects of Air Traffic Management in South Eastern Europe“, Promet - Traffic&Transportation, vol. 22, no. 4, p. 293-302, 2010.

[11] Steiner, S., Galović, B., Radačić, Ž.: „Strategic Framework of Air Traffic Development“, Promet - Traffic&Transportation, vol. 20, no. 3, p. 157-167, 2008.

[12] Mihetec, T., Vidović, A., Rezo, Z.: „Assessment of Single European Sky implementation in Functional Airspace Block Central Europe“, Promet - Traffic&Transport, vol. 29, no. 6, p. 643-655, 2017.

[13] Grebenšek, A., Magister T.: „Traffic Variability in Benchmarking of Air Navigation Services Providers Cost-Effectiveness“, International Journal for Traffic and Transport Engineering, vol. 2, no. 3, p. 185 – 201, 2012.

[14] Europska komisija: „Single European Sky: Commission harmonises air navigation service charges“, Priopćenje za javnost IP/06/1693, URL: http://europa.eu/rapid/press-release_IP-06-1693_en.htm?locale=en (pristupljeno: 16.3.2018.)

[15] Liebhold, A. M., Sharov, A. A.: „Testing for correlation in the presence of spatial autocorrelation in insect count data“, Population and Community Ecology for Insect Management and Conservation, (Baumgartner, J., Brandmayr, P., Manly, B. F. J.) Rotterdam, p. 11-117, 1998.

[16] Legendre, P.: „Spatial Autocorrelation: Trouble or New Paradigm?“, Ecology, vol. 74, no. 6, p. 1659-1673, 1993.

[17] European Commission: „Functional airspace blocks (FABs)“, URL: https://ec.europa.eu/transport/modes/air/single-european-sky/functional-airspace-blocks-fabs_en (pristupljeno: 24.4.2018.)

[18] Pravilnik o upravljanju zračnim prostorom NN 58/2008, URL: https://narodne-novine.nn.hr/clanci/sluzbeni/full/2008_05_58_2002.html (pristupljeno 28.4.2018.)

[19] Eurocontrol: „Functional Airspace Block (FAB)“, URL: http://www.eurocontrol.int/articles/functional-airspace-block-fab (pristupljeno: 25.6.2018.)

[20] Chou, Y. H.: „Map Resolution and Spatial Autocorrelation“, Geographical Analysis, vol. 23, no. 3, p. 228 - 246, 1991.

[21] Live Charts, URL: https://lvcharts.net/ (pristupljeno: 24.3.2018.)

[22] Performance Review Unit: „Pan-European ANS Performance data repository“, URL: http://ansperformance.eu/data/performancearea/ (pristupljeno: 18.4.2018.)

[23] Eurocontrol: „ATM Cost-Effectiveness (ACE) 2015 Benchmarking Report with 2016-2020 outlook“, 2017., URL: http://www.eurocontrol.int/sites/default/files/publication/files/final-ace-2015-benchmarking-report.pdf (pristupljeno: 8.5.2018.)

[24] Eurocontrol: „ATFCM operations manual“, 2017., URL: http://www.eurocontrol.int/sites/default/files/content/documents/nm/network-operations/HANDBOOK/ATFCM-Operations-Manual-next.pdf (pristupljeno: 8.5.2018.)

[25] Performance Review Unit: „ATFM Delay Codes“, URL: http://ansperformance.eu/references/definition/atfm_delay_codes.html (pristupljeno: 9.5.2018.)

[26] Flahaut, B., Mouchart, M., San Martin, E., Thomas, I.: „The local spatial autocorrelation and the kernel method for identifying black zones. A comparative approach“, Accident; Analysis and Prevention, vol. 35, no. 6, p. 991–1004, 2003.

[27] Mattsson, B. J., Zipkin, E. F., Gardner, B., Blank, P. J., Sauer, J. R., Royle, J. A.: „Explaining local-scale species distributions: relative contributions of spatial autocorrelation and landscape heterogeneity for an avian assemblage“, PloS One, vol. 8, no. 2, e55097, 2013.

[28] Viladomat, J., Mazumder, R., McInturff, A., McCauley, D. J., Hastie, T.: „Assessing the significance of global and local correlations under spatial autocorrelation: a nonparametric approach“, Biometrics, vol. 70, no. 2, p. 409–18, 2014

[29] Srce: „Programski jezik R u vizualizaciji i analizi prostornih podataka“, Sveučilište u Zagrebu, 2015., URL: http://www.srce.unizg.hr/files/srce/docs/edu/R/s730_polaznik.pdf (pristupljeno: 25.11.2017.)

[30] Barković, D.: „Otkrivanje prostorne autokorelacije pomoću lokalnih indikatora“, Ekonomski vjesnik – časopis Ekonomskog fakulteta, Osijek, Vol. 22, No. 1, p. 23-32, 2009.

[31] Fotheringham, A. S., Brunsdon, C., Charlton, M. E.: „Quantitative Geography: Perspectives on Spatial Data Analysis“, Sage, London, 2000.

[32] Anselin, L.: „The Moran Scatterplot as an ESDA Tool to Assess Local Instability in Spatial Association, Spatial Analytical Perspectives on GIS“, Taylor and Francis, London, p. 111-125, 1996.

[33] Anselin, L., Syabri, I., Kho, Y.: „GeoDa: An Introduction to Spatial Data Analysis, Geographical Analysis“, vol. 38, no. 1, p. 5-22, 2006.

[34] Lacombe, D. J., McIntyre, S. G.: „Local and global spatial effects in hierarchical models“, Applied Economics Letters, vol. 23, no. 16, p. 1168–1172, 2016.

[35] Audretsch, D. B., Feldman, M. P.: „Knowledge Spillovers and the Geography of Innovation“, Handbook of Regional and Urban Economics, Amsterdam, p. 2713-2742, 2004.

[36] Anselin, L.: „Spatial Analysis with GeoDa Spatial Autocorrelation“, GeoDa Center for Geospatial Analysis and Computation, Arizona State University, SAD, 2008.

[37] Getis, A., Ord. J. K.: „The Analysis of Spatial Associatiion by Use of Distance Statistics“, Geographical Analysis, p. 189-206, 1992.

[38] International Civil Aviation Organisation: „Air Traffic Management“, 2001., URL: http://www.navcanada.ca/EN/media/Publications/ICAO-Doc-4444-EN.pdf (pristupljeno: 27.5.2018.)

[39] Eurocontrol: „Capacity assessment and planning guidance document“, 2013., URL: http://www1.atmb.net.cn/CD_web/UploadFile/2013121715034435.pdf (pristupljeno: 27.5.2018.)

[40] Schabenberger, O., Gotway, C. A.: „Statistical Methods for Spatial Data Analysis“, Chapman & Hall/CRC Press, 2005.

[41] Goodchild, M.: „A Spatial Analytical Perspective on Geographical Information Systems“, International Journal of Geographical Information Systems, p. 327-334, 1987.

[42] Zerrouki, L., Manchon, S., Dalichampt, M.: „A data clustering approach to identify Logical Functional ATFCM Areas, Digital Aviation Systems Conference 2007, IEEE/AIAA, p. 3.D.3.1 - 3.D.3-12

[43] Eurocontrol: „Standard Inputs for Eurocontrol, Cost-Benefit Analyses“, 2018., URL: http://www.eurocontrol.int/sites/default/files/publication/files/standard-input-for-eurocontrol-cost-benefit-analyses-2018-edition-8-version-2.6.pdf (pristupljeno: 27.5.2018.)

[44] Eurocontrol: „Network Operations Report“, 2017., URL: https://www.eurocontrol.int/sites/default/files/publication/files/nm-annual-network-operations-report-2017-main-report-for-consultation.pdf (pristupljeno: 23.4.2018.)

[45] Eurocontrol: „Challenges of growth 2013, Task 4: European Air Traffic in 2035“, 2013., URL:https://www.eurocontrol.int/sites/default/files/article/content/documents/official-documents/reports/201306-challenges-of-growth-2013-task-4.pdf (pristupljeno: 28.5.2018.)

[46] Steiner, S., Štimac, I., Melvan, M.: „Towards to collaborative air traffic and airport management“, 22nd International Symposium on Electronics in Transport ISEP 2014: ITS for Seamless and Energy Smart Transport, Proceedings (Rijavec, Robert et al. (ur.).) Electrotechnical Association of Slovenia, Ljubljana, 2014.

[47] Eurocontrol: „Directions of work for enhancig the ASM/ATFCM/ATS processes in the short to medium term 2012-2017“, 2011., URL: http://www.eurocontrol.int/sites/default/files/field_tabs/content/documents/nm/airspace/airspace-management-fua-asm-directions-work-2012-2017.pdf (pristupljeno: 14.5.2018.)

[48] Eurocontrol: „European Network Operations Plan 2014-2018/19“, 2014., URL: https://www.eurocontrol.int/sites/default/files/publication/files/european-network-operations-plan-2014-2018-2019.pdf (pristupljeno: 29.5.2018.)

POPIS KRATICA

ACC (Area Central Centre) - Centra oblasne kontrole zračnog prometa

AMC (Airspace Management Cell) - Jedinice za upravljanje zračnim prostorom

ANSP (Air Navigation Service Provider) - Pružatelj usluga u zračnoj plovidbi

ATC (Air Traffic Control) - kontrola zračnog prometa

ATCO (Air Traffic Control Officer) - Kontrolor zračnog prometa

ATFCM (Air Traffic Flow and Capacity Management) - Sustava upravljanja protokom i kapacitetima zračnog prostora

ATM (Air Traffic Management) - Upravljanje zračnim prometom

ATS (Air Traffic Services) - Operativne usluge u zračnoj plovidbi

AU (Airspace Users) - Korisnici zračnog prostora

CDM (Collaborative Decision Making) - Zajedničko donošenje odluka

CMFU (Central Flow Management Unit) - Središnja jedinica za upravljanje protokom

CNS (Communication, Navigation and Surveillance) - Komunikacijski, navigacijski i nadzorni sustavi

EATCHIP (European Air Traffic Control Harmonisation and Integration Programme) - Europski harmonizacijski i integracijski program kontrole zračnog prometa

ECAC (European Civil Aviation Conference) - Europska konferencija civilnog zrakoplovstva

Eurocontrol (European Organisation for the Safety of Air Navigation) - Europska organizacija za sigurnost zračne plovidbe

FAB (Functional Airspace Block) - Funkcionalni blok zračnog prostora

FIR (Flight Information Region) - Područje letnih informacija

FMP (Flow Management Position) - Pozicija upravljanja protokom

FMS (Flight Management System) - Sustav upravljanja letom

FRA (Free Route Airspace) Prostora slobodnih ruta

GISA (Global Indicator of Spatial Autocorrelation) - Globalni indikator prostorne autokorelacije

HCV (High Critical Value) - Visoka kritična vrijednost

HH (High-High) - Visoko-Visoki indikator

HL (High-Low) - Visoko-Niski indikator

ICAO (International Civil Aviation Organisation) -

LCV (Low Critical Value) - Niska kritična vrijednost

LH (Low-High) - Nisko-Visoki indikator

LISA (Local Indicator of Spatial Autocorrelation) - Lokalni indikator prostorne autokorelacije

LL (Low-Low) - Nisko-Niski indikator

MHCV (Medium High Critical Value) - Srednje visoka kritična vrijednost

MLCV (Medium Low Critical Value) - Srednje niska kritična vrijednost

MTOW (Maximum Take-Off Weight) - Najveća dopuštena masa zrakoplova u polijetanju

NIL (Nothing) - Prazno/Ništa

NM (Network Manager) - Mrežni upravitelj

NMOC (Network Manager Operating Centre) - Operativni centar upravitelja mreže

NOP (Network Operating Plan) - Plan mrežnih operacija

PRU (Performance Review Unite) - Jedinica za nadzor učinkovitosti

SES (Single European Sky) - Jedinstveno europsko nebo

VHCV (Very High Critical Value) - Izrazito visoka kritična vrijednost

VLCV (Very Low Critical Value) - Izrazito niska kritična vrijednost

POPISA SLIKA

Slika 1. ATM/ASM/ATFCM odnos 8
Slika 2. Funkcionalni blokovi zračnog prostora 12
Slika 3. Pregled slijeda procesa modeliranja i izrade programa AirStat..... 14
Slika 4. Funkcionalne faze izrade izvješća 15
Slika 5. Početna forma programa AirStat 17
Slika 6. Vizualizacija obrađenog skupa podataka..... 19
Slika 7. Prostorni prikaz istraživanog zračnog prostora 22
Slika 8. Prikaz procesa provedbe kvantitativnog istraživanja primjenom programa AirStat 25
Slika 9. Prostorni prikaz rezultata analize žarišnih područja europskog zračnog prostora 33
Slika 10. Prikaz grafa susjedstva istraživanog područja..... 34
Slika 11. Prikaz rutne mreže i područja prostornog klasteriranja europskog zračnog prostora ... 37
Slika 12. Prikaz prostorno atipičnih vrijednosti europskog zračnog prostora 41
Slika 13. Disfunkcionalna područja europskog zračnog prostora s prikazom zračnih tokova 44

POPIS GRAFIKONA

Grafikon 1. FAB razina implementacije ATM Master Plan Level 3 projekata (2015) 13
Grafikon 2. Moranov dijagram rasprostiranja 28
Grafikon 3. Prikaz standardizirane normalne razdiobe s uključenim granicama indikatora 31
Grafikon 4. Moranov dijagram rasprostiranja analiziranih vrijednosti 40

POPIS TABLICA

Tablica 1. Korištene klase programa 17
Tablica 2. Skup podataka s popratnim podacima 21
Tablica 3. Klasifikacija vrijednosti rutnih kašnjenja zrakoplova prema uzročnosti nastanka kašnjenja 23
Tablica 4. Rezultati analize žarišnih područja europskog zračnog prostora..... 32
Tablica 5. Rezultati analize prostornog klasteriranja i grupiranja europskog zračnog prostora... 36
Tablica 6. Rezultati analize prostorno atipičnih vrijednosti europskog zračnog prostora..... 39

PRILOZI

[1] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanog nedostatkom ATC kapaciteta

```
The results obtained from inserted data set indicate the following:
1. Critical airspace values
     1.1. Very high critical value:              2,56[%]
     1.2. High critical value:                   0,00[%]
     1.3. Medium high critical value:            5,13[%]
     1.4. Not significant area:                 92,31[%]
     1.5. Medium low critical value:             0,00[%]
     1.6. Low critical value:                    0,00[%]
     1.7. Very low critical value:               0,00[%]
2. Controlled airspace cluster analysis
     2.1. Non-clustered controlled airspace:    92,31[%]
     2.2. Clustered controlled airspace:         7,69[%]
3. Outliers airspace analysis
     3.1. High-High value:                      12,82[%]
     3.2. High-Low value:                        5,13[%]
     3.3. Low-Low value:                        61,54[%]
     3.4. Low-High value:                       20,51[%]
```

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000001	- 0,357765	0,374211	NIL
Armenia	0	0,000001	- 0,357765	0,374211	NIL
Austria	39762	0,000001	- 0,220181	0,389388	NIL
Belgium	353317	0,000001	0,864777	0,274485	NIL
Bulgaria	0	0,000001	- 0,357765	0,374211	NIL
Croatia	24682	0,000001	- 0,272360	0,384417	NIL
Cyprus	186462	0,000001	0,287428	0,382799	NIL
Czech Republic	14078	0,000001	- 0,309052	0,380338	NIL
Denmark	0	0,000001	- 0,357765	0,374211	NIL
Estonia	4343	0,000001	- 0,342737	0,376185	NIL
Finland	0	0,000001	- 0,357765	0,374211	NIL
France	1697809	0,000000	5,516969	0,000000	VHCV
FYROM	3461	0,000001	- 0,345789	0,375790	NIL
Georgia	0	0,000001	- 0,357765	0,374211	NIL
Germany	584700	0,000000	1,665406	0,099686	MHCV
Greece	64414	0,000001	- 0,134880	0,395330	NIL
Hungary	2779	0,000001	- 0,348149	0,375483	NIL
Ireland	0	0,000001	- 0,357765	0,374211	NIL
Italy	0	0,000001	- 0,357765	0,374211	NIL
Latvia	0	0,000001	- 0,357765	0,374211	NIL
Lithuania	0	0,000001	- 0,357765	0,374211	NIL
Malta	0	0,000001	- 0,357765	0,374211	NIL
Moldova	0	0,000001	- 0,357765	0,374211	NIL
Netherlands	192396	0,000001	0,307961	0,380466	NIL
Norway	2594	0,000001	- 0,348789	0,375399	NIL
Poland	36853	0,000001	- 0,230247	0,388507	NIL
Portugal	52331	0,000001	- 0,176690	0,392763	NIL
Portugal-S.M.	0	0,000001	- 0,357765	0,374211	NIL
Romania	388	0,000001	- 0,356422	0,374390	NIL
Serbia-Montenegro	199	0,000001	- 0,357076	0,374303	NIL
Slovakia	9015	0,000001	- 0,326571	0,378226	NIL
Slovenia	387	0,000001	- 0,356426	0,374390	NIL
Spain-Canarias	58854	0,000001	- 0,154119	0,394232	NIL
Spain-Continental	452957	0,000001	1,209550	0,191965	MHCV
Sweden	190	0,000001	- 0,357107	0,374299	NIL
Switzerland	89913	0,000001	- 0,046649	0,398508	NIL
Turkey	0	0,000001	- 0,357765	0,374211	NIL
United Kingdom	160509	0,000001	0,197626	0,391227	NIL
Ukraine	0	0,000001	- 0,357765	0,374211	NIL

Standard deviation value: 289001,87
f(x)max value: 0,000001
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,106928	0,185924	- 0,0263158
Armenia	2	0	0,127996	0,185924	- 0,0263158
Austria	7	39762	0,002491	0,185924	- 0,0263158
Belgium	4	353317	1,662094	0,185924	- 0,0263158
Bulgaria	5	0	0,111045	0,185924	- 0,0263158
Croatia	4	24682	0,096648	0,185924	- 0,0263158
Cyprus	2	186462	- 0,070800	0,185924	- 0,0263158
Czech Republic	4	14078	- 0,068641	0,185924	- 0,0263158
Denmark	5	0	- 0,104832	0,185924	- 0,0263158
Estonia	3	4343	0,122544	0,185924	- 0,0263158
Finland	3	0	0,125055	0,185924	- 0,0263158
France	6	1697809	3,248525	0,185924	- 0,0263158
FYROM	4	3461	0,104384	0,185924	- 0,0263158
Georgia	2	0	0,127996	0,185924	- 0,0263158
Germany	9	584700	0,956444	0,185924	- 0,0263158
Greece	7	64414	0,035593	0,185924	- 0,0263158
Hungary	7	2779	0,111746	0,185924	- 0,0263158
Ireland	1	0	- 0,070704	0,185924	- 0,0263158
Italy	9	0	- 0,135707	0,185924	- 0,0263158
Latvia	3	0	0,126125	0,185924	- 0,0263158
Lithuania	3	0	0,112710	0,185924	- 0,0263158
Malta	2	0	0,088126	0,185924	- 0,0263158
Moldova	2	0	0,127755	0,185924	- 0,0263158
Netherlands	4	192396	0,182470	0,185924	- 0,0263158
Norway	4	2594	0,076299	0,185924	- 0,0263158
Poland	6	36853	0,001645	0,185924	- 0,0263158
Portugal	3	52331	- 0,041090	0,185924	- 0,0263158
Portugal-S.M.	3	0	- 0,104794	0,185924	- 0,0263158
Romania	5	388	0,126781	0,185924	- 0,0263158
Serbia-Montenegro	7	199	0,122223	0,185924	- 0,0263158
Slovakia	5	9015	0,095711	0,185924	- 0,0263158
Slovenia	4	387	0,106790	0,185924	- 0,0263158
Spain-Canarias	3	58854	- 0,255967	0,185924	- 0,0263158
Spain-Continental	2	452957	- 0,323225	0,185924	- 0,0263158
Sweden	8	190	0,030686	0,185924	- 0,0263158
Switzerland	4	89913	- 0,077023	0,185924	- 0,0263158
Turkey	5	0	0,065882	0,185924	- 0,0263158
United Kingdom	6	160509	0,185287	0,185924	- 0,0263158
Ukraine	5	0	0,115855	0,185924	- 0,0263158

Data set arithmetic mean = 103394,69 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,357765	- 0,298878	LL
Armenia	0	- 0,357765	- 0,357765	LL
Austria	39762	- 0,220181	- 0,011315	LL
Belgium	353317	0,864777	1,921990	HH
Bulgaria	0	- 0,357765	- 0,310387	LL
Croatia	24682	- 0,272360	- 0,354854	LL
Cyprus	186462	0,287428	- 0,246323	HL
Czech Republic	14078	- 0,309052	0,222102	LH
Denmark	0	- 0,357765	0,293019	LH
Estonia	4343	- 0,342737	- 0,357546	LL
Finland	0	- 0,357765	- 0,349545	LL
France	1697809	5,516969	0,588824	HH
FYROM	3461	- 0,345789	- 0,301872	LL
Georgia	0	- 0,357765	- 0,357765	LL
Germany	584700	1,665406	0,574301	HH
Greece	64414	- 0,134880	- 0,263884	LL
Hungary	2779	- 0,348149	- 0,320972	LL
Ireland	0	- 0,357765	0,197626	LH
Italy	0	- 0,357765	0,379318	LH
Latvia	0	- 0,357765	- 0,352536	LL
Lithuania	0	- 0,357765	- 0,315040	LL
Malta	0	- 0,357765	- 0,246323	LL
Moldova	0	- 0,357765	- 0,357094	LL
Netherlands	192396	0,307961	0,592511	HH
Norway	2594	- 0,348789	- 0,218753	LL
Poland	36853	- 0,230247	- 0,007142	LL
Portugal	52331	- 0,176690	0,232555	LH
Portugal-S.M.	0	- 0,357765	0,292914	LH
Romania	388	- 0,356422	- 0,355704	LL
Serbia-Montenegro	199	- 0,357076	- 0,342288	LL
Slovakia	9015	- 0,326571	- 0,293079	LL
Slovenia	387	- 0,356426	- 0,299614	LL
Spain-Canarias	58854	- 0,154119	1,660838	LH
Spain-Continental	452957	1,209550	- 0,267227	HL
Sweden	190	- 0,357107	- 0,085928	LL
Switzerland	89913	- 0,046649	1,651107	LH
Turkey	0	- 0,357765	- 0,184149	LL
United Kingdom	160509	0,197626	0,937565	HH
Ukraine	0	- 0,357765	- 0,323831	LL

[2] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanog nedostatkom ATC osoblja

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 2,56[%]
    - 1.2. High critical value: 0,00[%]
    - 1.3. Medium high critical value: 2,56[%]
    - 1.4. Not significant area: 94,87[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 33,33[%]
    - 2.2. Clustered controlled airspace: 66,67[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 10,26[%]
    - 3.2. High-Low value: 7,69[%]
    - 3.3. Low-Low value: 58,97[%]
    - 3.4. Low-High value: 23,08[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000003	- 0,280483	0,383554	NIL
Armenia	0	0,000003	- 0,280483	0,383554	NIL
Austria	30742	0,000003	- 0,059371	0,398240	NIL
Belgium	49428	0,000003	0,075029	0,397821	NIL
Bulgaria	0	0,000003	- 0,280483	0,383554	NIL
Croatia	8859	0,000003	- 0,216764	0,389679	NIL
Cyprus	179591	0,000002	1,011228	0,239254	MHCV
Czech Republic	4319	0,000003	- 0,249418	0,386724	NIL
Denmark	0	0,000003	- 0,280483	0,383554	NIL
Estonia	0	0,000003	- 0,280483	0,383554	NIL
Finland	0	0,000003	- 0,280483	0,383554	NIL
France	113124	0,000002	0,533163	0,346085	NIL
FYROM	1570	0,000003	- 0,269191	0,384747	NIL
Georgia	0	0,000003	- 0,280483	0,383554	NIL
Germany	865225	0,000000	5,942660	0,000000	VHCV
Greece	81352	0,000003	0,304643	0,380853	NIL
Hungary	0	0,000003	- 0,280483	0,383554	NIL
Ireland	0	0,000003	- 0,280483	0,383554	NIL
Italy	0	0,000003	- 0,280483	0,383554	NIL
Latvia	397	0,000003	- 0,277627	0,383860	NIL
Lithuania	0	0,000003	- 0,280483	0,383554	NIL
Malta	0	0,000003	- 0,280483	0,383554	NIL
Moldova	0	0,000003	- 0,280483	0,383554	NIL
Netherlands	6284	0,000003	- 0,235285	0,388051	NIL
Norway	7887	0,000003	- 0,223755	0,389079	NIL
Poland	38055	0,000003	- 0,006772	0,398933	NIL
Portugal	3831	0,000003	- 0,252928	0,386383	NIL
Portugal-S.M.	0	0,000003	- 0,280483	0,383554	NIL
Romania	0	0,000003	- 0,280483	0,383554	NIL
Serbia-Montenegro	0	0,000003	- 0,280483	0,383554	NIL
Slovakia	0	0,000003	- 0,280483	0,383554	NIL
Slovenia	673	0,000003	- 0,275642	0,384071	NIL
Spain-Canarias	19	0,000003	- 0,280346	0,383569	NIL
Spain-Continental	7221	0,000003	- 0,228546	0,388658	NIL
Sweden	0	0,000003	- 0,280483	0,383554	NIL
Switzerland	48386	0,000003	0,067534	0,398034	NIL
Turkey	0	0,000003	- 0,280483	0,383554	NIL
United Kingdom	73900	0,000003	0,251044	0,386567	NIL
Ukraine	0	0,000003	- 0,280483	0,383554	NIL

Standard deviation value: 139033,44
f(x)max value: 0,000003
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,036849	0,011639	- 0,0263158
Armenia	2	0	0,078671	0,011639	- 0,0263158
Austria	7	30742	- 0,039385	0,011639	- 0,0263158
Belgium	4	49428	0,121764	0,011639	- 0,0263158
Bulgaria	5	0	0,045214	0,011639	- 0,0263158
Croatia	4	8859	0,060536	0,011639	- 0,0263158
Cyprus	2	179591	0,012216	0,011639	- 0,0263158
Czech Republic	4	4319	- 0,348938	0,011639	- 0,0263158
Denmark	5	0	- 0,305961	0,011639	- 0,0263158
Estonia	3	0	0,078404	0,011639	- 0,0263158
Finland	3	0	0,073367	0,011639	- 0,0263158
France	6	113124	0,517812	0,011639	- 0,0263158
FYROM	4	1570	0,036126	0,011639	- 0,0263158
Georgia	2	0	0,078671	0,011639	- 0,0263158
Germany	9	865225	- 0,287945	0,011639	- 0,0263158
Greece	7	81352	- 0,028740	0,011639	- 0,0263158
Hungary	7	0	0,067064	0,011639	- 0,0263158
Ireland	1	0	- 0,070414	0,011639	- 0,0263158
Italy	9	0	0,015205	0,011639	- 0,0263158
Latvia	3	397	0,077870	0,011639	- 0,0263158
Lithuania	3	0	0,052813	0,011639	- 0,0263158
Malta	2	0	- 0,003388	0,011639	- 0,0263158
Moldova	2	0	0,078671	0,011639	- 0,0263158
Netherlands	4	6284	- 0,352236	0,011639	- 0,0263158
Norway	4	7887	0,033027	0,011639	- 0,0263158
Poland	6	38055	- 0,005159	0,011639	- 0,0263158
Portugal	3	3831	0,066552	0,011639	- 0,0263158
Portugal-S.M.	3	0	0,071226	0,011639	- 0,0263158
Romania	5	0	0,078671	0,011639	- 0,0263158
Serbia-Montenegro	7	0	0,075665	0,011639	- 0,0263158
Slovakia	5	0	0,049170	0,011639	- 0,0263158
Slovenia	4	673	0,057685	0,011639	- 0,0263158
Spain-Canarias	3	19	0,000023	0,011639	- 0,0263158
Spain-Continental	2	7221	0,060954	0,011639	- 0,0263158
Sweden	8	0	- 0,151200	0,011639	- 0,0263158
Switzerland	4	48386	0,103597	0,011639	- 0,0263158
Turkey	5	0	- 0,026613	0,011639	- 0,0263158
United Kingdom	6	73900	- 0,017231	0,011639	- 0,0263158
Ukraine	5	0	0,063316	0,011639	- 0,0263158

Data set arithmetic mean = 38996,49 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,280483	- 0,131378	LL
Armenia	0	- 0,280483	- 0,280483	LL
Austria	30742	- 0,059371	0,663384	LH
Belgium	49428	0,075029	1,622896	HH
Bulgaria	0	- 0,280483	- 0,161199	LL
Croatia	8859	- 0,216764	- 0,279273	LL
Cyprus	179591	1,011228	0,012080	HH
Czech Republic	4319	- 0,249418	1,399009	LH
Denmark	0	- 0,280483	1,090836	LH
Estonia	0	- 0,280483	- 0,279531	LL
Finland	0	- 0,280483	- 0,261574	LL
France	113124	0,533163	0,971206	HH
FYROM	1570	- 0,269191	- 0,134201	LL
Georgia	0	- 0,280483	- 0,280483	LL
Germany	865225	5,942660	- 0,048454	HL
Greece	81352	0,304643	- 0,094339	HL
Hungary	0	- 0,280483	- 0,239101	LL
Ireland	0	- 0,280483	0,251044	LH
Italy	0	- 0,280483	- 0,054209	LL
Latvia	397	- 0,277627	- 0,280483	LL
Lithuania	0	- 0,280483	- 0,188294	LL
Malta	0	- 0,280483	0,012080	LH
Moldova	0	- 0,280483	- 0,280483	LL
Netherlands	6284	- 0,235285	1,497063	LH
Norway	7887	- 0,223755	- 0,147601	LL
Poland	38055	- 0,006772	0,761885	LH
Portugal	3831	- 0,252928	- 0,263125	LL
Portugal-S.M.	0	- 0,280483	- 0,253940	LL
Romania	0	- 0,280483	- 0,280483	LL
Serbia-Montenegro	0	- 0,280483	- 0,269767	LL
Slovakia	0	- 0,280483	- 0,175305	LL
Slovenia	673	- 0,275642	- 0,209275	LL
Spain-Canarias	19	- 0,280346	- 0,000083	LL
Spain-Continental	7221	- 0,228546	- 0,266706	LL
Sweden	0	- 0,280483	0,539072	LH
Switzerland	48386	0,067534	1,533993	HH
Turkey	0	- 0,280483	0,094884	LH
United Kingdom	73900	0,251044	- 0,068636	HL
Ukraine	0	- 0,280483	- 0,225741	LL

[3] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanog ATC industrijskim aktivnostima

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 2,56[%]
    - 1.2. High critical value: 0,00[%]
    - 1.3. Medium high critical value: 0,00[%]
    - 1.4. Not significant area: 97,44[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 17,95[%]
    - 2.2. Clustered controlled airspace: 82,05[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 0,00[%]
    - 3.2. High-Low value: 2,56[%]
    - 3.3. Low-Low value: 82,05[%]
    - 3.4. Low-High value: 15,38[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000004	- 0,166557	0,393447	NIL
Armenia	0	0,000004	- 0,166557	0,393447	NIL
Austria	0	0,000004	- 0,166557	0,393447	NIL
Belgium	0	0,000004	- 0,166557	0,393447	NIL
Bulgaria	0	0,000004	- 0,166557	0,393447	NIL
Croatia	0	0,000004	- 0,166557	0,393447	NIL
Cyprus	0	0,000004	- 0,166557	0,393447	NIL
Czech Republic	0	0,000004	- 0,166557	0,393447	NIL
Denmark	0	0,000004	- 0,166557	0,393447	NIL
Estonia	0	0,000004	- 0,166557	0,393447	NIL
Finland	0	0,000004	- 0,166557	0,393447	NIL
France	691985	0,000000	6,163711	0,000000	VHCV
FYROM	0	0,000004	- 0,166557	0,393447	NIL
Georgia	0	0,000004	- 0,166557	0,393447	NIL
Germany	0	0,000004	- 0,166557	0,393447	NIL
Greece	4092	0,000004	- 0,129124	0,395630	NIL
Hungary	0	0,000004	- 0,166557	0,393447	NIL
Ireland	0	0,000004	- 0,166557	0,393447	NIL
Italy	6735	0,000004	- 0,104946	0,396751	NIL
Latvia	0	0,000004	- 0,166557	0,393447	NIL
Lithuania	0	0,000004	- 0,166557	0,393447	NIL
Malta	0	0,000004	- 0,166557	0,393447	NIL
Moldova	0	0,000004	- 0,166557	0,393447	NIL
Netherlands	0	0,000004	- 0,166557	0,393447	NIL
Norway	0	0,000004	- 0,166557	0,393447	NIL
Poland	0	0,000004	- 0,166557	0,393447	NIL
Portugal	0	0,000004	- 0,166557	0,393447	NIL
Portugal-S.M.	0	0,000004	- 0,166557	0,393447	NIL
Romania	7261	0,000004	- 0,100134	0,396947	NIL
Serbia-Montenegro	0	0,000004	- 0,166557	0,393447	NIL
Slovakia	0	0,000004	- 0,166557	0,393447	NIL
Slovenia	0	0,000004	- 0,166557	0,393447	NIL
Spain-Canarias	0	0,000004	- 0,166557	0,393447	NIL
Spain-Continental	0	0,000004	- 0,166557	0,393447	NIL
Sweden	0	0,000004	- 0,166557	0,393447	NIL
Switzerland	0	0,000004	- 0,166557	0,393447	NIL
Turkey	0	0,000004	- 0,166557	0,393447	NIL
United Kingdom	0	0,000004	- 0,166557	0,393447	NIL
Ukraine	0	0,000004	- 0,166557	0,393447	NIL

Standard deviation value: 109313,68
f(x)max value: 0,000004
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,023617	- 0,031459	- 0,0263158
Armenia	2	0	0,027741	- 0,031459	- 0,0263158
Austria	7	0	0,026275	- 0,031459	- 0,0263158
Belgium	4	0	- 0,235847	- 0,031459	- 0,0263158
Bulgaria	5	0	0,024282	- 0,031459	- 0,0263158
Croatia	4	0	0,025176	- 0,031459	- 0,0263158
Cyprus	2	0	0,024624	- 0,031459	- 0,0263158
Czech Republic	4	0	0,027741	- 0,031459	- 0,0263158
Denmark	5	0	0,027741	- 0,031459	- 0,0263158
Estonia	3	0	0,027741	- 0,031459	- 0,0263158
Finland	3	0	0,027741	- 0,031459	- 0,0263158
France	6	691985	- 0,963319	- 0,031459	- 0,0263158
FYROM	4	0	0,026183	- 0,031459	- 0,0263158
Georgia	2	0	0,027741	- 0,031459	- 0,0263158
Germany	9	0	- 0,089409	- 0,031459	- 0,0263158
Greece	7	4092	0,020370	- 0,031459	- 0,0263158
Hungary	7	0	0,026161	- 0,031459	- 0,0263158
Ireland	1	0	0,027741	- 0,031459	- 0,0263158
Italy	9	6735	- 0,056772	- 0,031459	- 0,0263158
Latvia	3	0	0,027741	- 0,031459	- 0,0263158
Lithuania	3	0	0,027741	- 0,031459	- 0,0263158
Malta	2	0	0,019493	- 0,031459	- 0,0263158
Moldova	2	0	0,022210	- 0,031459	- 0,0263158
Netherlands	4	0	0,027741	- 0,031459	- 0,0263158
Norway	4	0	0,027741	- 0,031459	- 0,0263158
Poland	6	0	0,027741	- 0,031459	- 0,0263158
Portugal	3	0	0,027741	- 0,031459	- 0,0263158
Portugal-S.M.	3	0	0,027741	- 0,031459	- 0,0263158
Romania	5	7261	0,016678	- 0,031459	- 0,0263158
Serbia-Montenegro	7	0	0,024695	- 0,031459	- 0,0263158
Slovakia	5	0	0,027741	- 0,031459	- 0,0263158
Slovenia	4	0	0,025176	- 0,031459	- 0,0263158
Spain-Canarias	3	0	- 0,323710	- 0,031459	- 0,0263158
Spain-Continental	2	0	0,027741	- 0,031459	- 0,0263158
Sweden	8	0	0,027741	- 0,031459	- 0,0263158
Switzerland	4	0	- 0,238412	- 0,031459	- 0,0263158
Turkey	5	0	0,026494	- 0,031459	- 0,0263158
United Kingdom	6	0	- 0,147984	- 0,031459	- 0,0263158
Ukraine	5	0	0,025529	- 0,031459	- 0,0263158

Data set arithmetic mean = 18207,00 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,166557	- 0,141796	LL
Armenia	0	- 0,166557	- 0,166557	LL
Austria	0	- 0,166557	- 0,157756	LL
Belgium	0	- 0,166557	1,416010	LH
Bulgaria	0	- 0,166557	- 0,145786	LL
Croatia	0	- 0,166557	- 0,151154	LL
Cyprus	0	- 0,166557	- 0,147841	LL
Czech Republic	0	- 0,166557	- 0,166557	LL
Denmark	0	- 0,166557	- 0,166557	LL
Estonia	0	- 0,166557	- 0,166557	LL
Finland	0	- 0,166557	- 0,166557	LL
France	691985	6,163711	- 0,156289	HL
FYROM	0	- 0,166557	- 0,157199	LL
Georgia	0	- 0,166557	- 0,166557	LL
Germany	0	- 0,166557	0,536806	LH
Greece	4092	- 0,129124	- 0,157756	LL
Hungary	0	- 0,166557	- 0,157068	LL
Ireland	0	- 0,166557	- 0,166557	LL
Italy	6735	- 0,104946	0,540965	LH
Latvia	0	- 0,166557	- 0,166557	LL
Lithuania	0	- 0,166557	- 0,166557	LL
Malta	0	- 0,166557	- 0,117035	LL
Moldova	0	- 0,166557	- 0,133346	LL
Netherlands	0	- 0,166557	- 0,166557	LL
Norway	0	- 0,166557	- 0,166557	LL
Poland	0	- 0,166557	- 0,166557	LL
Portugal	0	- 0,166557	- 0,166557	LL
Portugal-S.M.	0	- 0,166557	- 0,166557	LL
Romania	7261	- 0,100134	- 0,166557	LL
Serbia-Montenegro	0	- 0,166557	- 0,148267	LL
Slovakia	0	- 0,166557	- 0,166557	LL
Slovenia	0	- 0,166557	- 0,151154	LL
Spain-Canarias	0	- 0,166557	1,943532	LH
Spain-Continental	0	- 0,166557	- 0,166557	LL
Sweden	0	- 0,166557	- 0,166557	LL
Switzerland	0	- 0,166557	1,431413	LH
Turkey	0	- 0,166557	- 0,159071	LL
United Kingdom	0	- 0,166557	0,888487	LH
Ukraine	0	- 0,166557	- 0,153273	LL

[4] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanog ATC opremom

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 5,13[%]
    - 1.2. High critical value: 2,56[%]
    - 1.3. Medium high critical value: 2,56[%]
    - 1.4. Not significant area: 89,74[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 87,18[%]
    - 2.2. Clustered controlled airspace: 12,82[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 12,82[%]
    - 3.2. High-Low value: 5,13[%]
    - 3.3. Low-Low value: 58,97[%]
    - 3.4. Low-High value: 23,08[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	80	0,000029	- 0,417924	0,365580	NIL
Armenia	0	0,000029	- 0,424235	0,364610	NIL
Austria	0	0,000029	- 0,424235	0,364610	NIL
Belgium	12752	0,000027	0,581715	0,336844	NIL
Bulgaria	0	0,000029	- 0,424235	0,364610	NIL
Croatia	0	0,000029	- 0,424235	0,364610	NIL
Cyprus	3998	0,000031	- 0,108850	0,396586	NIL
Czech Republic	606	0,000029	- 0,376430	0,371655	NIL
Denmark	0	0,000029	- 0,424235	0,364610	NIL
Estonia	207	0,000029	- 0,407906	0,367096	NIL
Finland	123	0,000029	- 0,414532	0,366097	NIL
France	49419	0,000000	3,474218	0,000955	VHCV
FYROM	0	0,000029	- 0,424235	0,364610	NIL
Georgia	0	0,000029	- 0,424235	0,364610	NIL
Germany	33845	0,000003	2,245652	0,032051	HCV
Greece	1252	0,000030	- 0,325470	0,378362	NIL
Hungary	0	0,000029	- 0,424235	0,364610	NIL
Ireland	0	0,000029	- 0,424235	0,364610	NIL
Italy	3102	0,000031	- 0,179532	0,392565	NIL
Latvia	0	0,000029	- 0,424235	0,364610	NIL
Lithuania	0	0,000029	- 0,424235	0,364610	NIL
Malta	281	0,000029	- 0,402068	0,367965	NIL
Moldova	0	0,000029	- 0,424235	0,364610	NIL
Netherlands	4760	0,000031	- 0,048739	0,398469	NIL
Norway	1768	0,000030	- 0,284765	0,383090	NIL
Poland	98	0,000029	- 0,416504	0,365797	NIL
Portugal	52329	0,000000	3,703775	0,000419	VHCV
Portugal-S.M.	0	0,000029	- 0,424235	0,364610	NIL
Romania	0	0,000029	- 0,424235	0,364610	NIL
Serbia-Montenegro	2165	0,000030	- 0,253448	0,386333	NIL
Slovakia	1461	0,000030	- 0,308983	0,380346	NIL
Slovenia	87	0,000029	- 0,417372	0,365665	NIL
Spain-Canarias	0	0,000029	- 0,424235	0,364610	NIL
Spain-Continental	8538	0,000031	0,249291	0,386737	NIL
Sweden	5636	0,000031	0,020365	0,398860	NIL
Switzerland	27229	0,000007	1,723744	0,090303	MHCV
Turkey	0	0,000029	- 0,424235	0,364610	NIL
United Kingdom	0	0,000029	- 0,424235	0,364610	NIL
Ukraine	0	0,000029	- 0,424235	0,364610	NIL

Standard deviation value: 12676,57
f(x)max value: 0,000031
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	80	0,123568	0,180065	- 0,0263158
Armenia	2	0	0,179976	0,180065	- 0,0263158
Austria	7	0	- 0,137140	0,180065	- 0,0263158
Belgium	4	12752	0,763050	0,180065	- 0,0263158
Bulgaria	5	0	0,157105	0,180065	- 0,0263158
Croatia	4	0	0,135181	0,180065	- 0,0263158
Cyprus	2	3998	0,040803	0,180065	- 0,0263158
Czech Republic	4	606	- 0,103135	0,180065	- 0,0263158
Denmark	5	0	- 0,127973	0,180065	- 0,0263158
Estonia	3	207	0,111277	0,180065	- 0,0263158
Finland	3	123	0,092898	0,180065	- 0,0263158
France	6	49419	2,430004	0,180065	- 0,0263158
FYROM	4	0	0,150718	0,180065	- 0,0263158
Georgia	2	0	0,179976	0,180065	- 0,0263158
Germany	9	33845	1,025489	0,180065	- 0,0263158
Greece	7	1252	0,110710	0,180065	- 0,0263158
Hungary	7	0	0,162224	0,180065	- 0,0263158
Ireland	1	0	0,179976	0,180065	- 0,0263158
Italy	9	3102	- 0,050532	0,180065	- 0,0263158
Latvia	3	0	0,114795	0,180065	- 0,0263158
Lithuania	3	0	0,116011	0,180065	- 0,0263158
Malta	2	281	0,101523	0,180065	- 0,0263158
Moldova	2	0	0,179976	0,180065	- 0,0263158
Netherlands	4	4760	- 0,024112	0,180065	- 0,0263158
Norway	4	1768	0,088465	0,180065	- 0,0263158
Poland	6	98	- 0,050823	0,180065	- 0,0263158
Portugal	3	52329	- 0,739742	0,180065	- 0,0263158
Portugal-S.M.	3	0	- 0,499018	0,180065	- 0,0263158
Romania	5	0	0,165485	0,180065	- 0,0263158
Serbia-Montenegro	7	2165	0,098433	0,180065	- 0,0263158
Slovakia	5	1461	0,127650	0,180065	- 0,0263158
Slovenia	4	87	0,151531	0,180065	- 0,0263158
Spain-Canarias	3	0	- 0,955061	0,180065	- 0,0263158
Spain-Continental	2	8538	0,408780	0,180065	- 0,0263158
Sweden	8	5636	- 0,001402	0,180065	- 0,0263158
Switzerland	4	27229	2,204713	0,180065	- 0,0263158
Turkey	5	0	0,144836	0,180065	- 0,0263158
United Kingdom	6	0	- 0,203206	0,180065	- 0,0263158
Ukraine	5	0	0,169541	0,180065	- 0,0263158

Data set arithmetic mean = 5377,85 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	80	- 0,417924	- 0,295671	LL
Armenia	0	- 0,424235	- 0,424235	LL
Austria	0	- 0,424235	0,323263	LH
Belgium	12752	0,581715	1,311724	HH
Bulgaria	0	- 0,424235	- 0,370325	LL
Croatia	0	- 0,424235	- 0,318647	LL
Cyprus	3998	- 0,108850	- 0,374853	LL
Czech Republic	606	- 0,376430	0,273982	LH
Denmark	0	- 0,424235	0,301655	LH
Estonia	207	- 0,407906	- 0,272801	LL
Finland	123	- 0,414532	- 0,224102	LL
France	49419	3,474218	0,699439	HH
FYROM	0	- 0,424235	- 0,355269	LL
Georgia	0	- 0,424235	- 0,424235	LL
Germany	33845	2,245652	0,456655	HH
Greece	1252	- 0,325470	- 0,340154	LL
Hungary	0	- 0,424235	- 0,382392	LL
Ireland	0	- 0,424235	- 0,424235	LL
Italy	3102	- 0,179532	0,281468	LH
Latvia	0	- 0,424235	- 0,270592	LL
Lithuania	0	- 0,424235	- 0,273458	LL
Malta	281	- 0,402068	- 0,252501	LL
Moldova	0	- 0,424235	- 0,424235	LL
Netherlands	4760	- 0,048739	0,494724	LH
Norway	1768	- 0,284765	- 0,310660	LL
Poland	98	- 0,416504	0,122022	LH
Portugal	52329	3,703775	- 0,199726	HL
Portugal-S.M.	0	- 0,424235	1,176277	LH
Romania	0	- 0,424235	- 0,390078	LL
Serbia-Montenegro	2165	- 0,253448	- 0,388376	LL
Slovakia	1461	- 0,308983	- 0,413128	LL
Slovenia	87	- 0,417372	- 0,363059	LL
Spain-Canarias	0	- 0,424235	2,251253	LH
Spain-Continental	8538	0,249291	1,639770	HH
Sweden	5636	0,020365	- 0,068845	HL
Switzerland	27229	1,723744	1,279026	HH
Turkey	0	- 0,424235	- 0,341405	LL
United Kingdom	0	- 0,424235	0,478993	LH
Ukraine	0	- 0,424235	- 0,399639	LL

[5] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanog nedostatkom aerodromskih kapaciteta

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 5,13[%]
    - 1.2. High critical value: 2,56[%]
    - 1.3. Medium high critical value: 0,00[%]
    - 1.4. Not significant area: 92,31[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 92,31[%]
    - 2.2. Clustered controlled airspace: 7,69[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 7,69[%]
    - 3.2. High-Low value: 2,56[%]
    - 3.3. Low-Low value: 64,10[%]
    - 3.4. Low-High value: 25,64[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000356	- 0,298212	0,381592	NIL
Armenia	0	0,000356	- 0,298212	0,381592	NIL
Austria	0	0,000356	- 0,298212	0,381592	NIL
Belgium	0	0,000356	- 0,298212	0,381592	NIL
Bulgaria	0	0,000356	- 0,298212	0,381592	NIL
Croatia	0	0,000356	- 0,298212	0,381592	NIL
Cyprus	0	0,000356	- 0,298212	0,381592	NIL
Czech Republic	0	0,000356	- 0,298212	0,381592	NIL
Denmark	0	0,000356	- 0,298212	0,381592	NIL
Estonia	0	0,000356	- 0,298212	0,381592	NIL
Finland	0	0,000356	- 0,298212	0,381592	NIL
France	5069	0,000000	4,432860	0,000022	VHCV
FYROM	0	0,000356	- 0,298212	0,381592	NIL
Georgia	0	0,000356	- 0,298212	0,381592	NIL
Germany	3986	0,000001	3,422058	0,001143	VHCV
Greece	0	0,000356	- 0,298212	0,381592	NIL
Hungary	0	0,000356	- 0,298212	0,381592	NIL
Ireland	599	0,000360	0,260855	0,385598	NIL
Italy	0	0,000356	- 0,298212	0,381592	NIL
Latvia	0	0,000356	- 0,298212	0,381592	NIL
Lithuania	0	0,000356	- 0,298212	0,381592	NIL
Malta	0	0,000356	- 0,298212	0,381592	NIL
Moldova	0	0,000356	- 0,298212	0,381592	NIL
Netherlands	2604	0,000038	2,132190	0,041087	HCV
Norway	0	0,000356	- 0,298212	0,381592	NIL
Poland	0	0,000356	- 0,298212	0,381592	NIL
Portugal	0	0,000356	- 0,298212	0,381592	NIL
Portugal-S.M.	0	0,000356	- 0,298212	0,381592	NIL
Romania	0	0,000356	- 0,298212	0,381592	NIL
Serbia-Montenegro	0	0,000356	- 0,298212	0,381592	NIL
Slovakia	0	0,000356	- 0,298212	0,381592	NIL
Slovenia	0	0,000356	- 0,298212	0,381592	NIL
Spain-Canarias	0	0,000356	- 0,298212	0,381592	NIL
Spain-Continental	36	0,000360	- 0,264612	0,385217	NIL
Sweden	0	0,000356	- 0,298212	0,381592	NIL
Switzerland	167	0,000369	- 0,142345	0,394921	NIL
Turkey	0	0,000356	- 0,298212	0,381592	NIL
United Kingdom	0	0,000356	- 0,298212	0,381592	NIL
Ukraine	0	0,000356	- 0,298212	0,381592	NIL

Standard deviation value: 1071,43
f(x)max value: 0,000372
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,088931	0,112470	- 0,0263158
Armenia	2	0	0,088931	0,112470	- 0,0263158
Austria	7	0	- 0,076200	0,112470	- 0,0263158
Belgium	4	0	- 0,722337	0,112470	- 0,0263158
Bulgaria	5	0	0,088931	0,112470	- 0,0263158
Croatia	4	0	0,088931	0,112470	- 0,0263158
Cyprus	2	0	0,088931	0,112470	- 0,0263158
Czech Republic	4	0	- 0,188427	0,112470	- 0,0263158
Denmark	5	0	- 0,277911	0,112470	- 0,0263158
Estonia	3	0	0,088931	0,112470	- 0,0263158
Finland	3	0	0,088931	0,112470	- 0,0263158
France	6	5069	1,566620	0,112470	- 0,0263158
FYROM	4	0	0,088931	0,112470	- 0,0263158
Georgia	2	0	0,088931	0,112470	- 0,0263158
Germany	9	3986	1,761763	0,112470	- 0,0263158
Greece	7	0	0,088931	0,112470	- 0,0263158
Hungary	7	0	0,088931	0,112470	- 0,0263158
Ireland	1	599	- 0,077790	0,112470	- 0,0263158
Italy	9	0	- 0,072997	0,112470	- 0,0263158
Latvia	3	0	0,088931	0,112470	- 0,0263158
Lithuania	3	0	0,088931	0,112470	- 0,0263158
Malta	2	0	0,088931	0,112470	- 0,0263158
Moldova	2	0	0,088931	0,112470	- 0,0263158
Netherlands	4	2604	1,347236	0,112470	- 0,0263158
Norway	4	0	0,088931	0,112470	- 0,0263158
Poland	6	0	- 0,095975	0,112470	- 0,0263158
Portugal	3	0	0,085591	0,112470	- 0,0263158
Portugal-S.M.	3	0	0,085591	0,112470	- 0,0263158
Romania	5	0	0,088931	0,112470	- 0,0263158
Serbia-Montenegro	7	0	0,088931	0,112470	- 0,0263158
Slovakia	5	0	0,088931	0,112470	- 0,0263158
Slovenia	4	0	0,088931	0,112470	- 0,0263158
Spain-Canarias	3	0	- 0,381357	0,112470	- 0,0263158
Spain-Continental	2	36	0,078911	0,112470	- 0,0263158
Sweden	8	0	- 0,049748	0,112470	- 0,0263158
Switzerland	4	167	- 0,258303	0,112470	- 0,0263158
Turkey	5	0	0,088931	0,112470	- 0,0263158
United Kingdom	6	0	- 0,294796	0,112470	- 0,0263158
Ukraine	5	0	0,088931	0,112470	- 0,0263158

Data set arithmetic mean = 319,51 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,298212	- 0,298212	LL
Armenia	0	- 0,298212	- 0,298212	LL
Austria	0	- 0,298212	0,255522	LH
Belgium	0	- 0,298212	2,422224	LH
Bulgaria	0	- 0,298212	- 0,298212	LL
Croatia	0	- 0,298212	- 0,298212	LL
Cyprus	0	- 0,298212	- 0,298212	LL
Czech Republic	0	- 0,298212	0,631855	LH
Denmark	0	- 0,298212	0,931922	LH
Estonia	0	- 0,298212	- 0,298212	LL
Finland	0	- 0,298212	- 0,298212	LL
France	5069	4,432860	0,353411	HH
FYROM	0	- 0,298212	- 0,298212	LL
Georgia	0	- 0,298212	- 0,298212	LL
Germany	3986	3,422058	0,514826	HH
Greece	0	- 0,298212	- 0,298212	LL
Hungary	0	- 0,298212	- 0,298212	LL
Ireland	599	0,260855	- 0,298212	HL
Italy	0	- 0,298212	0,244781	LH
Latvia	0	- 0,298212	- 0,298212	LL
Lithuania	0	- 0,298212	- 0,298212	LL
Malta	0	- 0,298212	- 0,298212	LL
Moldova	0	- 0,298212	- 0,298212	LL
Netherlands	2604	2,132190	0,631855	HH
Norway	0	- 0,298212	- 0,298212	LL
Poland	0	- 0,298212	0,321833	LH
Portugal	0	- 0,298212	- 0,287012	LL
Portugal-S.M.	0	- 0,298212	- 0,287012	LL
Romania	0	- 0,298212	- 0,298212	LL
Serbia-Montenegro	0	- 0,298212	- 0,298212	LL
Slovakia	0	- 0,298212	- 0,298212	LL
Slovenia	0	- 0,298212	- 0,298212	LL
Spain-Canarias	0	- 0,298212	1,278812	LH
Spain-Continental	36	- 0,264612	- 0,298212	LL
Sweden	0	- 0,298212	0,166822	LH
Switzerland	167	- 0,142345	1,814623	LH
Turkey	0	- 0,298212	- 0,298212	LL
United Kingdom	0	- 0,298212	0,988545	LH
Ukraine	0	- 0,298212	- 0,298212	LL

[6] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanog vojnim aktivnostima

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 2,56[%]
    - 1.2. High critical value: 2,56[%]
    - 1.3. Medium high critical value: 5,13[%]
    - 1.4. Not significant area: 89,74[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 89,74[%]
    - 2.2. Clustered controlled airspace: 10,26[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 10,26[%]
    - 3.2. High-Low value: 2,56[%]
    - 3.3. Low-Low value: 64,10[%]
    - 3.4. Low-High value: 23,08[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000030	- 0,351827	0,375000	NIL
Armenia	0	0,000030	- 0,351827	0,375000	NIL
Austria	0	0,000030	- 0,351827	0,375000	NIL
Belgium	9932	0,000029	0,448584	0,360756	NIL
Bulgaria	0	0,000030	- 0,351827	0,375000	NIL
Croatia	0	0,000030	- 0,351827	0,375000	NIL
Cyprus	24519	0,000009	1,624136	0,106688	MHCV
Czech Republic	0	0,000030	- 0,351827	0,375000	NIL
Denmark	0	0,000030	- 0,351827	0,375000	NIL
Estonia	0	0,000030	- 0,351827	0,375000	NIL
Finland	0	0,000030	- 0,351827	0,375000	NIL
France	33259	0,000002	2,328485	0,026520	HCV
FYROM	0	0,000030	- 0,351827	0,375000	NIL
Georgia	0	0,000030	- 0,351827	0,375000	NIL
Germany	65070	0,000000	4,892103	0,000003	VHCV
Greece	0	0,000030	- 0,351827	0,375000	NIL
Hungary	0	0,000030	- 0,351827	0,375000	NIL
Ireland	0	0,000030	- 0,351827	0,375000	NIL
Italy	0	0,000030	- 0,351827	0,375000	NIL
Latvia	0	0,000030	- 0,351827	0,375000	NIL
Lithuania	0	0,000030	- 0,351827	0,375000	NIL
Malta	0	0,000030	- 0,351827	0,375000	NIL
Moldova	0	0,000030	- 0,351827	0,375000	NIL
Netherlands	25805	0,000007	1,727774	0,089677	MHCV
Norway	0	0,000030	- 0,351827	0,375000	NIL
Poland	0	0,000030	- 0,351827	0,375000	NIL
Portugal	0	0,000030	- 0,351827	0,375000	NIL
Portugal-S.M.	0	0,000030	- 0,351827	0,375000	NIL
Romania	0	0,000030	- 0,351827	0,375000	NIL
Serbia-Montenegro	3395	0,000032	- 0,078227	0,397723	NIL
Slovakia	0	0,000030	- 0,351827	0,375000	NIL
Slovenia	0	0,000030	- 0,351827	0,375000	NIL
Spain-Canarias	0	0,000030	- 0,351827	0,375000	NIL
Spain-Continental	21	0,000030	- 0,350135	0,375223	NIL
Sweden	3545	0,000032	- 0,066139	0,398071	NIL
Switzerland	474	0,000031	- 0,313628	0,379796	NIL
Turkey	0	0,000030	- 0,351827	0,375000	NIL
United Kingdom	4242	0,000032	- 0,009968	0,398922	NIL
Ukraine	0	0,000030	- 0,351827	0,375000	NIL

Standard deviation value: 12408,63
f(x)max value: 0,000032
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,099717	0,159555	- 0,0263158
Armenia	2	0	0,123782	0,159555	- 0,0263158
Austria	7	0	- 0,141703	0,159555	- 0,0263158
Belgium	4	9932	1,002404	0,159555	- 0,0263158
Bulgaria	5	0	0,104530	0,159555	- 0,0263158
Croatia	4	0	0,099717	0,159555	- 0,0263158
Cyprus	2	24519	- 0,571415	0,159555	- 0,0263158
Czech Republic	4	0	- 0,337457	0,159555	- 0,0263158
Denmark	5	0	- 0,435699	0,159555	- 0,0263158
Estonia	3	0	0,090278	0,159555	- 0,0263158
Finland	3	0	0,090278	0,159555	- 0,0263158
France	6	33259	1,674619	0,159555	- 0,0263158
FYROM	4	0	0,099717	0,159555	- 0,0263158
Georgia	2	0	0,123782	0,159555	- 0,0263158
Germany	9	65070	1,477289	0,159555	- 0,0263158
Greece	7	0	0,024468	0,159555	- 0,0263158
Hungary	7	0	0,110031	0,159555	- 0,0263158
Ireland	1	0	0,003507	0,159555	- 0,0263158
Italy	9	0	0,006815	0,159555	- 0,0263158
Latvia	3	0	0,090278	0,159555	- 0,0263158
Lithuania	3	0	0,090278	0,159555	- 0,0263158
Malta	2	0	0,123782	0,159555	- 0,0263158
Moldova	2	0	0,123782	0,159555	- 0,0263158
Netherlands	4	25805	2,150600	0,159555	- 0,0263158
Norway	4	0	0,068585	0,159555	- 0,0263158
Poland	6	0	- 0,200463	0,159555	- 0,0263158
Portugal	3	0	0,123584	0,159555	- 0,0263158
Portugal-S.M.	3	0	0,123584	0,159555	- 0,0263158
Romania	5	0	0,104530	0,159555	- 0,0263158
Serbia-Montenegro	7	3395	0,027522	0,159555	- 0,0263158
Slovakia	5	0	0,123782	0,159555	- 0,0263158
Slovenia	4	0	0,123782	0,159555	- 0,0263158
Spain-Canarias	3	0	- 0,190553	0,159555	- 0,0263158
Spain-Continental	2	21	0,123187	0,159555	- 0,0263158
Sweden	8	3545	- 0,020084	0,159555	- 0,0263158
Switzerland	4	474	- 0,510973	0,159555	- 0,0263158
Turkey	5	0	- 0,015257	0,159555	- 0,0263158
United Kingdom	6	4242	- 0,005731	0,159555	- 0,0263158
Ukraine	5	0	0,123782	0,159555	- 0,0263158

Data set arithmetic mean = 4365,69 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,351827	- 0,283427	LL
Armenia	0	- 0,351827	- 0,351827	LL
Austria	0	- 0,351827	0,402763	LH
Belgium	9932	0,448584	2,234598	HH
Bulgaria	0	- 0,351827	- 0,297107	LL
Croatia	0	- 0,351827	- 0,283427	LL
Cyprus	24519	1,624136	- 0,351827	HL
Czech Republic	0	- 0,351827	0,959156	LH
Denmark	0	- 0,351827	1,238389	LH
Estonia	0	- 0,351827	- 0,256598	LL
Finland	0	- 0,351827	- 0,256598	LL
France	33259	2,328485	0,719188	HH
FYROM	0	- 0,351827	- 0,283427	LL
Georgia	0	- 0,351827	- 0,351827	LL
Germany	65070	4,892103	0,301974	HH
Greece	0	- 0,351827	- 0,069547	LL
Hungary	0	- 0,351827	- 0,312741	LL
Ireland	0	- 0,351827	- 0,009968	LL
Italy	0	- 0,351827	- 0,019370	LL
Latvia	0	- 0,351827	- 0,256598	LL
Lithuania	0	- 0,351827	- 0,256598	LL
Malta	0	- 0,351827	- 0,351827	LL
Moldova	0	- 0,351827	- 0,351827	LL
Netherlands	25805	1,727774	1,244723	HH
Norway	0	- 0,351827	- 0,194940	LL
Poland	0	- 0,351827	0,569776	LH
Portugal	0	- 0,351827	- 0,351263	LL
Portugal-S.M.	0	- 0,351827	- 0,351263	LL
Romania	0	- 0,351827	- 0,297107	LL
Serbia-Montenegro	3395	- 0,078227	- 0,351827	LL
Slovakia	0	- 0,351827	- 0,351827	LL
Slovenia	0	- 0,351827	- 0,351827	LL
Spain-Canarias	0	- 0,351827	0,541610	LH
Spain-Continental	21	- 0,350135	- 0,351827	LL
Sweden	3545	- 0,066139	0,303664	LH
Switzerland	474	- 0,313628	1,629233	LH
Turkey	0	- 0,351827	0,043366	LH
United Kingdom	4242	- 0,009968	0,574893	LH
Ukraine	0	- 0,351827	- 0,351827	LL

[7] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanog ATC rutiranjem

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 2,56[%]
    - 1.2. High critical value: 0,00[%]
    - 1.3. Medium high critical value: 5,13[%]
    - 1.4. Not significant area: 92,31[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 89,74[%]
    - 2.2. Clustered controlled airspace: 10,26[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 10,26[%]
    - 3.2. High-Low value: 5,13[%]
    - 3.3. Low-Low value: 56,41[%]
    - 3.4. Low-High value: 28,21[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000174	- 0,334136	0,377282	NIL
Armenia	0	0,000174	- 0,334136	0,377282	NIL
Austria	52	0,000175	- 0,310150	0,380209	NIL
Belgium	1408	0,000175	0,315331	0,379593	NIL
Bulgaria	0	0,000174	- 0,334136	0,377282	NIL
Croatia	0	0,000174	- 0,334136	0,377282	NIL
Cyprus	2605	0,000126	0,867470	0,273846	NIL
Czech Republic	123	0,000177	- 0,277400	0,383884	NIL
Denmark	0	0,000174	- 0,334136	0,377282	NIL
Estonia	0	0,000174	- 0,334136	0,377282	NIL
Finland	0	0,000174	- 0,334136	0,377282	NIL
France	12256	0,000000	5,319181	0,000000	VHCV
FYROM	0	0,000174	- 0,334136	0,377282	NIL
Georgia	0	0,000174	- 0,334136	0,377282	NIL
Germany	4729	0,000033	1,847206	0,072438	MHCV
Greece	131	0,000177	- 0,273710	0,384275	NIL
Hungary	0	0,000174	- 0,334136	0,377282	NIL
Ireland	0	0,000174	- 0,334136	0,377282	NIL
Italy	218	0,000179	- 0,233580	0,388206	NIL
Latvia	0	0,000174	- 0,334136	0,377282	NIL
Lithuania	0	0,000174	- 0,334136	0,377282	NIL
Malta	0	0,000174	- 0,334136	0,377282	NIL
Moldova	0	0,000174	- 0,334136	0,377282	NIL
Netherlands	709	0,000184	- 0,007096	0,398932	NIL
Norway	0	0,000174	- 0,334136	0,377282	NIL
Poland	0	0,000174	- 0,334136	0,377282	NIL
Portugal	152	0,000178	- 0,264023	0,385277	NIL
Portugal-S.M.	0	0,000174	- 0,334136	0,377282	NIL
Romania	0	0,000174	- 0,334136	0,377282	NIL
Serbia-Montenegro	0	0,000174	- 0,334136	0,377282	NIL
Slovakia	0	0,000174	- 0,334136	0,377282	NIL
Slovenia	0	0,000174	- 0,334136	0,377282	NIL
Spain-Canarias	197	0,000179	- 0,243266	0,387311	NIL
Spain-Continental	4524	0,000040	1,752646	0,085878	MHCV
Sweden	0	0,000174	- 0,334136	0,377282	NIL
Switzerland	4	0,000174	- 0,332291	0,377514	NIL
Turkey	0	0,000174	- 0,334136	0,377282	NIL
United Kingdom	1143	0,000181	0,193094	0,391574	NIL
Ukraine	0	0,000174	- 0,334136	0,377282	NIL

Standard deviation value: 2167,93
f(x)max value: 0,000184
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,098200	0,114076	- 0,0263158
Armenia	2	0	0,111647	0,114076	- 0,0263158
Austria	7	52	- 0,000068	0,114076	- 0,0263158
Belgium	4	1408	0,579608	0,114076	- 0,0263158
Bulgaria	5	0	0,107609	0,114076	- 0,0263158
Croatia	4	0	0,103247	0,114076	- 0,0263158
Cyprus	2	2605	- 0,263644	0,114076	- 0,0263158
Czech Republic	4	123	- 0,060250	0,114076	- 0,0263158
Denmark	5	0	- 0,091215	0,114076	- 0,0263158
Estonia	3	0	0,111647	0,114076	- 0,0263158
Finland	3	0	0,111647	0,114076	- 0,0263158
France	6	12256	3,140450	0,114076	- 0,0263158
FYROM	4	0	0,106599	0,114076	- 0,0263158
Georgia	2	0	0,111647	0,114076	- 0,0263158
Germany	9	4729	0,760467	0,114076	- 0,0263158
Greece	7	131	0,040540	0,114076	- 0,0263158
Hungary	7	0	0,110502	0,114076	- 0,0263158
Ireland	1	0	- 0,064520	0,114076	- 0,0263158
Italy	9	218	- 0,070913	0,114076	- 0,0263158
Latvia	3	0	0,111647	0,114076	- 0,0263158
Lithuania	3	0	0,111647	0,114076	- 0,0263158
Malta	2	0	0,084752	0,114076	- 0,0263158
Moldova	2	0	0,111647	0,114076	- 0,0263158
Netherlands	4	709	- 0,003586	0,114076	- 0,0263158
Norway	4	0	0,067605	0,114076	- 0,0263158
Poland	6	0	- 0,012990	0,114076	- 0,0263158
Portugal	3	152	- 0,103431	0,114076	- 0,0263158
Portugal-S.M.	3	0	- 0,138706	0,114076	- 0,0263158
Romania	5	0	0,111647	0,114076	- 0,0263158
Serbia-Montenegro	7	0	0,106847	0,114076	- 0,0263158
Slovakia	5	0	0,106253	0,114076	- 0,0263158
Slovenia	4	0	0,101244	0,114076	- 0,0263158
Spain-Canarias	3	197	- 0,382822	0,114076	- 0,0263158
Spain-Continental	2	4524	- 0,524181	0,114076	- 0,0263158
Sweden	8	0	0,020539	0,114076	- 0,0263158
Switzerland	4	4	- 0,550163	0,114076	- 0,0263158
Turkey	5	0	0,027309	0,114076	- 0,0263158
United Kingdom	6	1143	0,148844	0,114076	- 0,0263158
Ukraine	5	0	0,111647	0,114076	- 0,0263158

Data set arithmetic mean = 724,38 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,334136	- 0,293891	LL
Armenia	0	- 0,334136	- 0,334136	LL
Austria	52	- 0,310150	0,000218	LH
Belgium	1408	0,315331	1,838096	HH
Bulgaria	0	- 0,334136	- 0,322051	LL
Croatia	0	- 0,334136	- 0,308997	LL
Cyprus	2605	0,867470	- 0,303923	HL
Czech Republic	123	- 0,277400	0,217196	LH
Denmark	0	- 0,334136	0,272986	LH
Estonia	0	- 0,334136	- 0,334136	LL
Finland	0	- 0,334136	- 0,334136	LL
France	12256	5,319181	0,590401	HH
FYROM	0	- 0,334136	- 0,319030	LL
Georgia	0	- 0,334136	- 0,334136	LL
Germany	4729	1,847206	0,411685	HH
Greece	131	- 0,273710	- 0,148113	LL
Hungary	0	- 0,334136	- 0,330710	LL
Ireland	0	- 0,334136	0,193094	LH
Italy	218	- 0,233580	0,303594	LH
Latvia	0	- 0,334136	- 0,334136	LL
Lithuania	0	- 0,334136	- 0,334136	LL
Malta	0	- 0,334136	- 0,253645	LL
Moldova	0	- 0,334136	- 0,334136	LL
Netherlands	709	- 0,007096	0,505374	LH
Norway	0	- 0,334136	- 0,202329	LL
Poland	0	- 0,334136	0,038877	LH
Portugal	152	- 0,264023	0,391748	LH
Portugal-S.M.	0	- 0,334136	0,415119	LH
Romania	0	- 0,334136	- 0,334136	LL
Serbia-Montenegro	0	- 0,334136	- 0,319771	LL
Slovakia	0	- 0,334136	- 0,317992	LL
Slovenia	0	- 0,334136	- 0,303001	LL
Spain-Canarias	197	- 0,243266	1,573674	LH
Spain-Continental	4524	1,752646	- 0,299080	HL
Sweden	0	- 0,334136	- 0,061469	LL
Switzerland	4	- 0,332291	1,655664	LH
Turkey	0	- 0,334136	- 0,081730	LL
United Kingdom	1143	0,193094	0,770834	HH
Ukraine	0	- 0,334136	- 0,334136	LL

[8] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanog problematikom okoliša

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 2,56[%]
    - 1.2. High critical value: 0,00[%]
    - 1.3. Medium high critical value: 2,56[%]
    - 1.4. Not significant area: 94,87[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 30,77[%]
    - 2.2. Clustered controlled airspace: 69,23[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 2,56[%]
    - 3.2. High-Low value: 5,13[%]
    - 3.3. Low-Low value: 66,67[%]
    - 3.4. Low-High value: 25,64[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,003241	- 0,214685	0,389854	NIL
Armenia	0	0,003241	- 0,214685	0,389854	NIL
Austria	0	0,003241	- 0,214685	0,389854	NIL
Belgium	111	0,002581	0,708226	0,310451	NIL
Bulgaria	0	0,003241	- 0,214685	0,389854	NIL
Croatia	0	0,003241	- 0,214685	0,389854	NIL
Cyprus	0	0,003241	- 0,214685	0,389854	NIL
Czech Republic	0	0,003241	- 0,214685	0,389854	NIL
Denmark	0	0,003241	- 0,214685	0,389854	NIL
Estonia	0	0,003241	- 0,214685	0,389854	NIL
Finland	0	0,003241	- 0,214685	0,389854	NIL
France	0	0,003241	- 0,214685	0,389854	NIL
FYROM	0	0,003241	- 0,214685	0,389854	NIL
Georgia	0	0,003241	- 0,214685	0,389854	NIL
Germany	745	0,000000	5,979625	0,000000	VHCV
Greece	0	0,003241	- 0,214685	0,389854	NIL
Hungary	0	0,003241	- 0,214685	0,389854	NIL
Ireland	0	0,003241	- 0,214685	0,389854	NIL
Italy	0	0,003241	- 0,214685	0,389854	NIL
Latvia	0	0,003241	- 0,214685	0,389854	NIL
Lithuania	0	0,003241	- 0,214685	0,389854	NIL
Malta	0	0,003241	- 0,214685	0,389854	NIL
Moldova	0	0,003241	- 0,214685	0,389854	NIL
Netherlands	0	0,003241	- 0,214685	0,389854	NIL
Norway	0	0,003241	- 0,214685	0,389854	NIL
Poland	0	0,003241	- 0,214685	0,389854	NIL
Portugal	0	0,003241	- 0,214685	0,389854	NIL
Portugal-S.M.	0	0,003241	- 0,214685	0,389854	NIL
Romania	0	0,003241	- 0,214685	0,389854	NIL
Serbia-Montenegro	0	0,003241	- 0,214685	0,389854	NIL
Slovakia	0	0,003241	- 0,214685	0,389854	NIL
Slovenia	0	0,003241	- 0,214685	0,389854	NIL
Spain-Canarias	0	0,003241	- 0,214685	0,389854	NIL
Spain-Continental	151	0,001930	1,040806	0,232102	MHCV
Sweden	0	0,003241	- 0,214685	0,389854	NIL
Switzerland	0	0,003241	- 0,214685	0,389854	NIL
Turkey	0	0,003241	- 0,214685	0,389854	NIL
United Kingdom	0	0,003241	- 0,214685	0,389854	NIL
Ukraine	0	0,003241	- 0,214685	0,389854	NIL

Standard deviation value: 120,27
f(x)max value: 0,003317
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,046090	- 0,017771	- 0,0263158
Armenia	2	0	0,046090	- 0,017771	- 0,0263158
Austria	7	0	- 0,143885	- 0,017771	- 0,0263158
Belgium	4	111	0,944697	- 0,017771	- 0,0263158
Bulgaria	5	0	0,046090	- 0,017771	- 0,0263158
Croatia	4	0	0,046090	- 0,017771	- 0,0263158
Cyprus	2	0	0,046090	- 0,017771	- 0,0263158
Czech Republic	4	0	- 0,286367	- 0,017771	- 0,0263158
Denmark	5	0	- 0,219875	- 0,017771	- 0,0263158
Estonia	3	0	0,046090	- 0,017771	- 0,0263158
Finland	3	0	0,046090	- 0,017771	- 0,0263158
France	6	0	- 0,253493	- 0,017771	- 0,0263158
FYROM	4	0	0,046090	- 0,017771	- 0,0263158
Georgia	2	0	0,046090	- 0,017771	- 0,0263158
Germany	9	745	- 0,670551	- 0,017771	- 0,0263158
Greece	7	0	0,046090	- 0,017771	- 0,0263158
Hungary	7	0	0,046090	- 0,017771	- 0,0263158
Ireland	1	0	0,046090	- 0,017771	- 0,0263158
Italy	9	0	0,046090	- 0,017771	- 0,0263158
Latvia	3	0	0,046090	- 0,017771	- 0,0263158
Lithuania	3	0	0,046090	- 0,017771	- 0,0263158
Malta	2	0	0,046090	- 0,017771	- 0,0263158
Moldova	2	0	0,046090	- 0,017771	- 0,0263158
Netherlands	4	0	- 0,335900	- 0,017771	- 0,0263158
Norway	4	0	0,046090	- 0,017771	- 0,0263158
Poland	6	0	- 0,175548	- 0,017771	- 0,0263158
Portugal	3	0	- 0,043755	- 0,017771	- 0,0263158
Portugal-S.M.	3	0	- 0,043755	- 0,017771	- 0,0263158
Romania	5	0	0,046090	- 0,017771	- 0,0263158
Serbia-Montenegro	7	0	0,046090	- 0,017771	- 0,0263158
Slovakia	5	0	0,046090	- 0,017771	- 0,0263158
Slovenia	4	0	0,046090	- 0,017771	- 0,0263158
Spain-Canarias	3	0	0,046090	- 0,017771	- 0,0263158
Spain-Continental	2	151	- 0,223445	- 0,017771	- 0,0263158
Sweden	8	0	- 0,120138	- 0,017771	- 0,0263158
Switzerland	4	0	- 0,286367	- 0,017771	- 0,0263158
Turkey	5	0	0,046090	- 0,017771	- 0,0263158
United Kingdom	6	0	0,013067	- 0,017771	- 0,0263158
Ukraine	5	0	0,046090	- 0,017771	- 0,0263158

Data set arithmetic mean = 25,82 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,214685	- 0,214685	LL
Armenia	0	- 0,214685	- 0,214685	LL
Austria	0	- 0,214685	0,670216	LH
Belgium	111	0,708226	1,333893	HH
Bulgaria	0	- 0,214685	- 0,214685	LL
Croatia	0	- 0,214685	- 0,214685	LL
Cyprus	0	- 0,214685	- 0,214685	LL
Czech Republic	0	- 0,214685	1,333893	LH
Denmark	0	- 0,214685	1,024177	LH
Estonia	0	- 0,214685	- 0,214685	LL
Finland	0	- 0,214685	- 0,214685	LL
France	0	- 0,214685	1,180767	LH
FYROM	0	- 0,214685	- 0,214685	LL
Georgia	0	- 0,214685	- 0,214685	LL
Germany	745	5,979625	- 0,112139	HL
Greece	0	- 0,214685	- 0,214685	LL
Hungary	0	- 0,214685	- 0,214685	LL
Ireland	0	- 0,214685	- 0,214685	LL
Italy	0	- 0,214685	- 0,214685	LL
Latvia	0	- 0,214685	- 0,214685	LL
Lithuania	0	- 0,214685	- 0,214685	LL
Malta	0	- 0,214685	- 0,214685	LL
Moldova	0	- 0,214685	- 0,214685	LL
Netherlands	0	- 0,214685	1,564620	LH
Norway	0	- 0,214685	- 0,214685	LL
Poland	0	- 0,214685	0,817700	LH
Portugal	0	- 0,214685	0,203812	LH
Portugal-S.M.	0	- 0,214685	0,203812	LH
Romania	0	- 0,214685	- 0,214685	LL
Serbia-Montenegro	0	- 0,214685	- 0,214685	LL
Slovakia	0	- 0,214685	- 0,214685	LL
Slovenia	0	- 0,214685	- 0,214685	LL
Spain-Canarias	0	- 0,214685	- 0,214685	LL
Spain-Continental	151	1,040806	- 0,214685	HL
Sweden	0	- 0,214685	0,559604	LH
Switzerland	0	- 0,214685	1,333893	LH
Turkey	0	- 0,214685	- 0,214685	LL
United Kingdom	0	- 0,214685	- 0,060866	LL
Ukraine	0	- 0,214685	- 0,214685	LL

[9] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanih nesrećama i/ili nezgodama

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 2,56[%]
    - 1.2. High critical value: 0,00[%]
    - 1.3. Medium high critical value: 0,00[%]
    - 1.4. Not significant area: 97,44[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 17,95[%]
    - 2.2. Clustered controlled airspace: 82,05[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 0,00[%]
    - 3.2. High-Low value: 2,56[%]
    - 3.3. Low-Low value: 82,05[%]
    - 3.4. Low-High value: 15,38[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,006678	- 0,162221	0,393727	NIL
Armenia	0	0,006678	- 0,162221	0,393727	NIL
Austria	0	0,006678	- 0,162221	0,393727	NIL
Belgium	0	0,006678	- 0,162221	0,393727	NIL
Bulgaria	0	0,006678	- 0,162221	0,393727	NIL
Croatia	0	0,006678	- 0,162221	0,393727	NIL
Cyprus	0	0,006678	- 0,162221	0,393727	NIL
Czech Republic	0	0,006678	- 0,162221	0,393727	NIL
Denmark	0	0,006678	- 0,162221	0,393727	NIL
Estonia	0	0,006678	- 0,162221	0,393727	NIL
Finland	0	0,006678	- 0,162221	0,393727	NIL
France	0	0,006678	- 0,162221	0,393727	NIL
FYROM	0	0,006678	- 0,162221	0,393727	NIL
Georgia	0	0,006678	- 0,162221	0,393727	NIL
Germany	0	0,006678	- 0,162221	0,393727	NIL
Greece	0	0,006678	- 0,162221	0,393727	NIL
Hungary	0	0,006678	- 0,162221	0,393727	NIL
Ireland	0	0,006678	- 0,162221	0,393727	NIL
Italy	0	0,006678	- 0,162221	0,393727	NIL
Latvia	0	0,006678	- 0,162221	0,393727	NIL
Lithuania	0	0,006678	- 0,162221	0,393727	NIL
Malta	0	0,006678	- 0,162221	0,393727	NIL
Moldova	0	0,006678	- 0,162221	0,393727	NIL
Netherlands	0	0,006678	- 0,162221	0,393727	NIL
Norway	0	0,006678	- 0,162221	0,393727	NIL
Poland	0	0,006678	- 0,162221	0,393727	NIL
Portugal	0	0,006678	- 0,162221	0,393727	NIL
Portugal-S.M.	0	0,006678	- 0,162221	0,393727	NIL
Romania	0	0,006678	- 0,162221	0,393727	NIL
Serbia-Montenegro	0	0,006678	- 0,162221	0,393727	NIL
Slovakia	0	0,006678	- 0,162221	0,393727	NIL
Slovenia	0	0,006678	- 0,162221	0,393727	NIL
Spain-Canarias	0	0,006678	- 0,162221	0,393727	NIL
Spain-Continental	0	0,006678	- 0,162221	0,393727	NIL
Sweden	0	0,006678	- 0,162221	0,393727	NIL
Switzerland	0	0,006678	- 0,162221	0,393727	NIL
Turkey	0	0,006678	- 0,162221	0,393727	NIL
United Kingdom	373	0,000000	6,164414	0,000000	VHCV
Ukraine	0	0,006678	- 0,162221	0,393727	NIL

Standard deviation value: 58,95
f(x)max value: 0,006767
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,026316	- 0,055702	- 0,0263158
Armenia	2	0	0,026316	- 0,055702	- 0,0263158
Austria	7	0	0,026316	- 0,055702	- 0,0263158
Belgium	4	0	- 0,230263	- 0,055702	- 0,0263158
Bulgaria	5	0	0,026316	- 0,055702	- 0,0263158
Croatia	4	0	0,026316	- 0,055702	- 0,0263158
Cyprus	2	0	0,026316	- 0,055702	- 0,0263158
Czech Republic	4	0	0,026316	- 0,055702	- 0,0263158
Denmark	5	0	- 0,178947	- 0,055702	- 0,0263158
Estonia	3	0	0,026316	- 0,055702	- 0,0263158
Finland	3	0	0,026316	- 0,055702	- 0,0263158
France	6	0	- 0,144737	- 0,055702	- 0,0263158
FYROM	4	0	0,026316	- 0,055702	- 0,0263158
Georgia	2	0	0,026316	- 0,055702	- 0,0263158
Germany	9	0	0,026316	- 0,055702	- 0,0263158
Greece	7	0	0,026316	- 0,055702	- 0,0263158
Hungary	7	0	0,026316	- 0,055702	- 0,0263158
Ireland	1	0	- 1,000000	- 0,055702	- 0,0263158
Italy	9	0	0,026316	- 0,055702	- 0,0263158
Latvia	3	0	0,026316	- 0,055702	- 0,0263158
Lithuania	3	0	0,026316	- 0,055702	- 0,0263158
Malta	2	0	0,026316	- 0,055702	- 0,0263158
Moldova	2	0	0,026316	- 0,055702	- 0,0263158
Netherlands	4	0	- 0,230263	- 0,055702	- 0,0263158
Norway	4	0	- 0,230263	- 0,055702	- 0,0263158
Poland	6	0	0,026316	- 0,055702	- 0,0263158
Portugal	3	0	0,026316	- 0,055702	- 0,0263158
Portugal-S.M.	3	0	0,026316	- 0,055702	- 0,0263158
Romania	5	0	0,026316	- 0,055702	- 0,0263158
Serbia-Montenegro	7	0	0,026316	- 0,055702	- 0,0263158
Slovakia	5	0	0,026316	- 0,055702	- 0,0263158
Slovenia	4	0	0,026316	- 0,055702	- 0,0263158
Spain-Canarias	3	0	0,026316	- 0,055702	- 0,0263158
Spain-Continental	2	0	0,026316	- 0,055702	- 0,0263158
Sweden	8	0	0,026316	- 0,055702	- 0,0263158
Switzerland	4	0	0,026316	- 0,055702	- 0,0263158
Turkey	5	0	0,026316	- 0,055702	- 0,0263158
United Kingdom	6	373	- 1,000000	- 0,055702	- 0,0263158
Ukraine	5	0	0,026316	- 0,055702	- 0,0263158

Data set arithmetic mean = 9,56 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Indicator
Albania	0	- 0,162221	- 0,162221	LL
Armenia	0	- 0,162221	- 0,162221	LL
Austria	0	- 0,162221	- 0,162221	LL
Belgium	0	- 0,162221	1,419437	LH
Bulgaria	0	- 0,162221	- 0,162221	LL
Croatia	0	- 0,162221	- 0,162221	LL
Cyprus	0	- 0,162221	- 0,162221	LL
Czech Republic	0	- 0,162221	- 0,162221	LL
Denmark	0	- 0,162221	1,103106	LH
Estonia	0	- 0,162221	- 0,162221	LL
Finland	0	- 0,162221	- 0,162221	LL
France	0	- 0,162221	0,892218	LH
FYROM	0	- 0,162221	- 0,162221	LL
Georgia	0	- 0,162221	- 0,162221	LL
Germany	0	- 0,162221	- 0,162221	LL
Greece	0	- 0,162221	- 0,162221	LL
Hungary	0	- 0,162221	- 0,162221	LL
Ireland	0	- 0,162221	6,164414	LH
Italy	0	- 0,162221	- 0,162221	LL
Latvia	0	- 0,162221	- 0,162221	LL
Lithuania	0	- 0,162221	- 0,162221	LL
Malta	0	- 0,162221	- 0,162221	LL
Moldova	0	- 0,162221	- 0,162221	LL
Netherlands	0	- 0,162221	1,419437	LH
Norway	0	- 0,162221	1,419437	LH
Poland	0	- 0,162221	- 0,162221	LL
Portugal	0	- 0,162221	- 0,162221	LL
Portugal-S.M.	0	- 0,162221	- 0,162221	LL
Romania	0	- 0,162221	- 0,162221	LL
Serbia-Montenegro	0	- 0,162221	- 0,162221	LL
Slovakia	0	- 0,162221	- 0,162221	LL
Slovenia	0	- 0,162221	- 0,162221	LL
Spain-Canarias	0	- 0,162221	- 0,162221	LL
Spain-Continental	0	- 0,162221	- 0,162221	LL
Sweden	0	- 0,162221	- 0,162221	LL
Switzerland	0	- 0,162221	- 0,162221	LL
Turkey	0	- 0,162221	- 0,162221	LL
United Kingdom	373	6,164414	- 0,162221	HL
Ukraine	0	- 0,162221	- 0,162221	LL

[10] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanih aerodromskim uslugama

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 2,56[%]
    - 1.2. High critical value: 0,00[%]
    - 1.3. Medium high critical value: 0,00[%]
    - 1.4. Not significant area: 97,44[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 12,82[%]
    - 2.2. Clustered controlled airspace: 87,18[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 0,00[%]
    - 3.2. High-Low value: 2,56[%]
    - 3.3. Low-Low value: 87,18[%]
    - 3.4. Low-High value: 10,26[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,005115	- 0,162221	0,393727	NIL
Armenia	0	0,005115	- 0,162221	0,393727	NIL
Austria	0	0,005115	- 0,162221	0,393727	NIL
Belgium	0	0,005115	- 0,162221	0,393727	NIL
Bulgaria	0	0,005115	- 0,162221	0,393727	NIL
Croatia	0	0,005115	- 0,162221	0,393727	NIL
Cyprus	0	0,005115	- 0,162221	0,393727	NIL
Czech Republic	0	0,005115	- 0,162221	0,393727	NIL
Denmark	0	0,005115	- 0,162221	0,393727	NIL
Estonia	0	0,005115	- 0,162221	0,393727	NIL
Finland	0	0,005115	- 0,162221	0,393727	NIL
France	0	0,005115	- 0,162221	0,393727	NIL
FYROM	0	0,005115	- 0,162221	0,393727	NIL
Georgia	0	0,005115	- 0,162221	0,393727	NIL
Germany	0	0,005115	- 0,162221	0,393727	NIL
Greece	0	0,005115	- 0,162221	0,393727	NIL
Hungary	0	0,005115	- 0,162221	0,393727	NIL
Ireland	0	0,005115	- 0,162221	0,393727	NIL
Italy	0	0,005115	- 0,162221	0,393727	NIL
Latvia	0	0,005115	- 0,162221	0,393727	NIL
Lithuania	0	0,005115	- 0,162221	0,393727	NIL
Malta	0	0,005115	- 0,162221	0,393727	NIL
Moldova	0	0,005115	- 0,162221	0,393727	NIL
Netherlands	487	0,000000	6,164414	0,000000	VHCV
Norway	0	0,005115	- 0,162221	0,393727	NIL
Poland	0	0,005115	- 0,162221	0,393727	NIL
Portugal	0	0,005115	- 0,162221	0,393727	NIL
Portugal-S.M.	0	0,005115	- 0,162221	0,393727	NIL
Romania	0	0,005115	- 0,162221	0,393727	NIL
Serbia-Montenegro	0	0,005115	- 0,162221	0,393727	NIL
Slovakia	0	0,005115	- 0,162221	0,393727	NIL
Slovenia	0	0,005115	- 0,162221	0,393727	NIL
Spain-Canarias	0	0,005115	- 0,162221	0,393727	NIL
Spain-Continental	0	0,005115	- 0,162221	0,393727	NIL
Sweden	0	0,005115	- 0,162221	0,393727	NIL
Switzerland	0	0,005115	- 0,162221	0,393727	NIL
Turkey	0	0,005115	- 0,162221	0,393727	NIL
United Kingdom	0	0,005115	- 0,162221	0,393727	NIL
Ukraine	0	0,005115	- 0,162221	0,393727	NIL

Standard deviation value: 76,98
f(x)max value: 0,005183
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,026316	- 0,019152	- 0,0263158
Armenia	2	0	0,026316	- 0,019152	- 0,0263158
Austria	7	0	0,026316	- 0,019152	- 0,0263158
Belgium	4	0	- 0,230263	- 0,019152	- 0,0263158
Bulgaria	5	0	0,026316	- 0,019152	- 0,0263158
Croatia	4	0	0,026316	- 0,019152	- 0,0263158
Cyprus	2	0	0,026316	- 0,019152	- 0,0263158
Czech Republic	4	0	0,026316	- 0,019152	- 0,0263158
Denmark	5	0	- 0,178947	- 0,019152	- 0,0263158
Estonia	3	0	0,026316	- 0,019152	- 0,0263158
Finland	3	0	0,026316	- 0,019152	- 0,0263158
France	6	0	0,026316	- 0,019152	- 0,0263158
FYROM	4	0	0,026316	- 0,019152	- 0,0263158
Georgia	2	0	0,026316	- 0,019152	- 0,0263158
Germany	9	0	- 0,087719	- 0,019152	- 0,0263158
Greece	7	0	0,026316	- 0,019152	- 0,0263158
Hungary	7	0	0,026316	- 0,019152	- 0,0263158
Ireland	1	0	0,026316	- 0,019152	- 0,0263158
Italy	9	0	0,026316	- 0,019152	- 0,0263158
Latvia	3	0	0,026316	- 0,019152	- 0,0263158
Lithuania	3	0	0,026316	- 0,019152	- 0,0263158
Malta	2	0	0,026316	- 0,019152	- 0,0263158
Moldova	2	0	0,026316	- 0,019152	- 0,0263158
Netherlands	4	487	- 1,000000	- 0,019152	- 0,0263158
Norway	4	0	0,026316	- 0,019152	- 0,0263158
Poland	6	0	0,026316	- 0,019152	- 0,0263158
Portugal	3	0	0,026316	- 0,019152	- 0,0263158
Portugal-S.M.	3	0	0,026316	- 0,019152	- 0,0263158
Romania	5	0	0,026316	- 0,019152	- 0,0263158
Serbia-Montenegro	7	0	0,026316	- 0,019152	- 0,0263158
Slovakia	5	0	0,026316	- 0,019152	- 0,0263158
Slovenia	4	0	0,026316	- 0,019152	- 0,0263158
Spain-Canarias	3	0	0,026316	- 0,019152	- 0,0263158
Spain-Continental	2	0	0,026316	- 0,019152	- 0,0263158
Sweden	8	0	0,026316	- 0,019152	- 0,0263158
Switzerland	4	0	0,026316	- 0,019152	- 0,0263158
Turkey	5	0	0,026316	- 0,019152	- 0,0263158
United Kingdom	6	0	- 0,144737	- 0,019152	- 0,0263158
Ukraine	5	0	0,026316	- 0,019152	- 0,0263158

Data set arithmetic mean = 12,49 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,162221	- 0,162221	LL
Armenia	0	- 0,162221	- 0,162221	LL
Austria	0	- 0,162221	- 0,162221	LL
Belgium	0	- 0,162221	1,419437	LH
Bulgaria	0	- 0,162221	- 0,162221	LL
Croatia	0	- 0,162221	- 0,162221	LL
Cyprus	0	- 0,162221	- 0,162221	LL
Czech Republic	0	- 0,162221	- 0,162221	LL
Denmark	0	- 0,162221	1,103106	LH
Estonia	0	- 0,162221	- 0,162221	LL
Finland	0	- 0,162221	- 0,162221	LL
France	0	- 0,162221	- 0,162221	LL
FYROM	0	- 0,162221	- 0,162221	LL
Georgia	0	- 0,162221	- 0,162221	LL
Germany	0	- 0,162221	0,540738	LH
Greece	0	- 0,162221	- 0,162221	LL
Hungary	0	- 0,162221	- 0,162221	LL
Ireland	0	- 0,162221	- 0,162221	LL
Italy	0	- 0,162221	- 0,162221	LL
Latvia	0	- 0,162221	- 0,162221	LL
Lithuania	0	- 0,162221	- 0,162221	LL
Malta	0	- 0,162221	- 0,162221	LL
Moldova	0	- 0,162221	- 0,162221	LL
Netherlands	487	6,164414	- 0,162221	HL
Norway	0	- 0,162221	- 0,162221	LL
Poland	0	- 0,162221	- 0,162221	LL
Portugal	0	- 0,162221	- 0,162221	LL
Portugal-S.M.	0	- 0,162221	- 0,162221	LL
Romania	0	- 0,162221	- 0,162221	LL
Serbia-Montenegro	0	- 0,162221	- 0,162221	LL
Slovakia	0	- 0,162221	- 0,162221	LL
Slovenia	0	- 0,162221	- 0,162221	LL
Spain-Canarias	0	- 0,162221	- 0,162221	LL
Spain-Continental	0	- 0,162221	- 0,162221	LL
Sweden	0	- 0,162221	- 0,162221	LL
Switzerland	0	- 0,162221	- 0,162221	LL
Turkey	0	- 0,162221	- 0,162221	LL
United Kingdom	0	- 0,162221	0,892218	LH
Ukraine	0	- 0,162221	- 0,162221	LL

[11] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnimprostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanih industrijskim aktivnostima

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 2,56[%]
    - 1.2. High critical value: 2,56[%]
    - 1.3. Medium high critical value: 5,13[%]
    - 1.4. Not significant area: 89,74[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 89,74[%]
    - 2.2. Clustered controlled airspace: 10,26[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 10,26[%]
    - 3.2. High-Low value: 2,56[%]
    - 3.3. Low-Low value: 64,10[%]
    - 3.4. Low-High value: 23,08[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000030	- 0,351827	0,375000	NIL
Armenia	0	0,000030	- 0,351827	0,375000	NIL
Austria	0	0,000030	- 0,351827	0,375000	NIL
Belgium	9932	0,000029	0,448584	0,360756	NIL
Bulgaria	0	0,000030	- 0,351827	0,375000	NIL
Croatia	0	0,000030	- 0,351827	0,375000	NIL
Cyprus	24519	0,000009	1,624136	0,106688	MHCV
Czech Republic	0	0,000030	- 0,351827	0,375000	NIL
Denmark	0	0,000030	- 0,351827	0,375000	NIL
Estonia	0	0,000030	- 0,351827	0,375000	NIL
Finland	0	0,000030	- 0,351827	0,375000	NIL
France	33259	0,000002	2,328485	0,026520	HCV
FYROM	0	0,000030	- 0,351827	0,375000	NIL
Georgia	0	0,000030	- 0,351827	0,375000	NIL
Germany	65070	0,000000	4,892103	0,000003	VHCV
Greece	0	0,000030	- 0,351827	0,375000	NIL
Hungary	0	0,000030	- 0,351827	0,375000	NIL
Ireland	0	0,000030	- 0,351827	0,375000	NIL
Italy	0	0,000030	- 0,351827	0,375000	NIL
Latvia	0	0,000030	- 0,351827	0,375000	NIL
Lithuania	0	0,000030	- 0,351827	0,375000	NIL
Malta	0	0,000030	- 0,351827	0,375000	NIL
Moldova	0	0,000030	- 0,351827	0,375000	NIL
Netherlands	25805	0,000007	1,727774	0,089677	MHCV
Norway	0	0,000030	- 0,351827	0,375000	NIL
Poland	0	0,000030	- 0,351827	0,375000	NIL
Portugal	0	0,000030	- 0,351827	0,375000	NIL
Portugal-S.M.	0	0,000030	- 0,351827	0,375000	NIL
Romania	0	0,000030	- 0,351827	0,375000	NIL
Serbia-Montenegro	3395	0,000032	- 0,078227	0,397723	NIL
Slovakia	0	0,000030	- 0,351827	0,375000	NIL
Slovenia	0	0,000030	- 0,351827	0,375000	NIL
Spain-Canarias	0	0,000030	- 0,351827	0,375000	NIL
Spain-Continental	21	0,000030	- 0,350135	0,375223	NIL
Sweden	3545	0,000032	- 0,066139	0,398071	NIL
Switzerland	474	0,000031	- 0,313628	0,379796	NIL
Turkey	0	0,000030	- 0,351827	0,375000	NIL
United Kingdom	4242	0,000032	- 0,009968	0,398922	NIL
Ukraine	0	0,000030	- 0,351827	0,375000	NIL

Standard deviation value: 12408,63
f(x)max value: 0,000032
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,099717	0,159555	- 0,0263158
Armenia	2	0	0,123782	0,159555	- 0,0263158
Austria	7	0	- 0,141703	0,159555	- 0,0263158
Belgium	4	9932	1,002404	0,159555	- 0,0263158
Bulgaria	5	0	0,104530	0,159555	- 0,0263158
Croatia	4	0	0,099717	0,159555	- 0,0263158
Cyprus	2	24519	- 0,571415	0,159555	- 0,0263158
Czech Republic	4	0	- 0,337457	0,159555	- 0,0263158
Denmark	5	0	- 0,435699	0,159555	- 0,0263158
Estonia	3	0	0,090278	0,159555	- 0,0263158
Finland	3	0	0,090278	0,159555	- 0,0263158
France	6	33259	1,674619	0,159555	- 0,0263158
FYROM	4	0	0,099717	0,159555	- 0,0263158
Georgia	2	0	0,123782	0,159555	- 0,0263158
Germany	9	65070	1,477289	0,159555	- 0,0263158
Greece	7	0	0,024468	0,159555	- 0,0263158
Hungary	7	0	0,110031	0,159555	- 0,0263158
Ireland	1	0	0,003507	0,159555	- 0,0263158
Italy	9	0	0,006815	0,159555	- 0,0263158
Latvia	3	0	0,090278	0,159555	- 0,0263158
Lithuania	3	0	0,090278	0,159555	- 0,0263158
Malta	2	0	0,123782	0,159555	- 0,0263158
Moldova	2	0	0,123782	0,159555	- 0,0263158
Netherlands	4	25805	2,150600	0,159555	- 0,0263158
Norway	4	0	0,068585	0,159555	- 0,0263158
Poland	6	0	- 0,200463	0,159555	- 0,0263158
Portugal	3	0	0,123584	0,159555	- 0,0263158
Portugal-S.M.	3	0	0,123584	0,159555	- 0,0263158
Romania	5	0	0,104530	0,159555	- 0,0263158
Serbia-Montenegro	7	3395	0,027522	0,159555	- 0,0263158
Slovakia	5	0	0,123782	0,159555	- 0,0263158
Slovenia	4	0	0,123782	0,159555	- 0,0263158
Spain-Canarias	3	0	- 0,190553	0,159555	- 0,0263158
Spain-Continental	2	21	0,123187	0,159555	- 0,0263158
Sweden	8	3545	- 0,020084	0,159555	- 0,0263158
Switzerland	4	474	- 0,510973	0,159555	- 0,0263158
Turkey	5	0	- 0,015257	0,159555	- 0,0263158
United Kingdom	6	4242	- 0,005731	0,159555	- 0,0263158
Ukraine	5	0	0,123782	0,159555	- 0,0263158

Data set arithmetic mean = 4365,69 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,351827	- 0,283427	LL
Armenia	0	- 0,351827	- 0,351827	LL
Austria	0	- 0,351827	0,402763	LH
Belgium	9932	0,448584	2,234598	HH
Bulgaria	0	- 0,351827	- 0,297107	LL
Croatia	0	- 0,351827	- 0,283427	LL
Cyprus	24519	1,624136	- 0,351827	HL
Czech Republic	0	- 0,351827	0,959156	LH
Denmark	0	- 0,351827	1,238389	LH
Estonia	0	- 0,351827	- 0,256598	LL
Finland	0	- 0,351827	- 0,256598	LL
France	33259	2,328485	0,719188	HH
FYROM	0	- 0,351827	- 0,283427	LL
Georgia	0	- 0,351827	- 0,351827	LL
Germany	65070	4,892103	0,301974	HH
Greece	0	- 0,351827	- 0,069547	LL
Hungary	0	- 0,351827	- 0,312741	LL
Ireland	0	- 0,351827	- 0,009968	LL
Italy	0	- 0,351827	- 0,019370	LL
Latvia	0	- 0,351827	- 0,256598	LL
Lithuania	0	- 0,351827	- 0,256598	LL
Malta	0	- 0,351827	- 0,351827	LL
Moldova	0	- 0,351827	- 0,351827	LL
Netherlands	25805	1,727774	1,244723	HH
Norway	0	- 0,351827	- 0,194940	LL
Poland	0	- 0,351827	0,569776	LH
Portugal	0	- 0,351827	- 0,351263	LL
Portugal-S.M.	0	- 0,351827	- 0,351263	LL
Romania	0	- 0,351827	- 0,297107	LL
Serbia-Montenegro	3395	- 0,078227	- 0,351827	LL
Slovakia	0	- 0,351827	- 0,351827	LL
Slovenia	0	- 0,351827	- 0,351827	LL
Spain-Canarias	0	- 0,351827	0,541610	LH
Spain-Continental	21	- 0,350135	- 0,351827	LL
Sweden	3545	- 0,066139	0,303664	LH
Switzerland	474	- 0,313628	1,629233	LH
Turkey	0	- 0,351827	0,043366	LH
United Kingdom	4242	- 0,009968	0,574893	LH
Ukraine	0	- 0,351827	- 0,351827	LL

[12] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova svrstanih pod kategoriju „Ostalo“

```
The results obtained from inserted data set indicate the following:
1. Critical airspace values
     1.1. Very high critical value:              5,13[%]
     1.2. High critical value:                   0,00[%]
     1.3. Medium high critical value:            5,13[%]
     1.4. Not significant area:                 89,74[%]
     1.5. Medium low critical value:             0,00[%]
     1.6. Low critical value:                    0,00[%]
     1.7. Very low critical value:               0,00[%]
2. Controlled airspace cluster analysis
     2.1. Non-clustered controlled airspace:    89,74[%]
     2.2. Clustered controlled airspace:        10,26[%]
3. Outliers airspace analysis
     3.1. High-High value:                      15,38[%]
     3.2. High-Low value:                        5,13[%]
     3.3. Low-Low value:                        64,10[%]
     3.4. Low-High value:                       15,38[%]
```

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000041	- 0,397366	0,368657	NIL
Armenia	0	0,000041	- 0,397366	0,368657	NIL
Austria	96	0,000042	- 0,386573	0,370220	NIL
Belgium	17182	0,000014	1,534440	0,122924	MHCV
Bulgaria	0	0,000041	- 0,397366	0,368657	NIL
Croatia	0	0,000041	- 0,397366	0,368657	NIL
Cyprus	498	0,000042	- 0,341375	0,376361	NIL
Czech Republic	0	0,000041	- 0,397366	0,368657	NIL
Denmark	0	0,000041	- 0,397366	0,368657	NIL
Estonia	0	0,000041	- 0,397366	0,368657	NIL
Finland	0	0,000041	- 0,397366	0,368657	NIL
France	38346	0,000000	3,913950	0,000188	VHCV
FYROM	0	0,000041	- 0,397366	0,368657	NIL
Georgia	0	0,000041	- 0,397366	0,368657	NIL
Germany	11721	0,000029	0,920449	0,261178	NIL
Greece	0	0,000041	- 0,397366	0,368657	NIL
Hungary	0	0,000041	- 0,397366	0,368657	NIL
Ireland	0	0,000041	- 0,397366	0,368657	NIL
Italy	2508	0,000045	- 0,115387	0,396295	NIL
Latvia	0	0,000041	- 0,397366	0,368657	NIL
Lithuania	0	0,000041	- 0,397366	0,368657	NIL
Malta	0	0,000041	- 0,397366	0,368657	NIL
Moldova	0	0,000041	- 0,397366	0,368657	NIL
Netherlands	3621	0,000045	0,009750	0,398923	NIL
Norway	0	0,000041	- 0,397366	0,368657	NIL
Poland	345	0,000042	- 0,358577	0,374102	NIL
Portugal	1774	0,000044	- 0,197912	0,391205	NIL
Portugal-S.M.	0	0,000041	- 0,397366	0,368657	NIL
Romania	0	0,000041	- 0,397366	0,368657	NIL
Serbia-Montenegro	3579	0,000045	0,005028	0,398937	NIL
Slovakia	0	0,000041	- 0,397366	0,368657	NIL
Slovenia	0	0,000041	- 0,397366	0,368657	NIL
Spain-Canarias	14356	0,000021	1,216707	0,190305	MHCV
Spain-Continental	37271	0,000000	3,793085	0,000300	VHCV
Sweden	0	0,000041	- 0,397366	0,368657	NIL
Switzerland	354	0,000042	- 0,357565	0,374237	NIL
Turkey	0	0,000041	- 0,397366	0,368657	NIL
United Kingdom	6186	0,000043	0,298138	0,381600	NIL
Ukraine	0	0,000041	- 0,397366	0,368657	NIL

Standard deviation value: 8894,27
f(x)max value: 0,000045
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,089913	0,212136	- 0,0263158
Armenia	2	0	0,157900	0,212136	- 0,0263158
Austria	7	96	0,063065	0,212136	- 0,0263158
Belgium	4	17182	1,972632	0,212136	- 0,0263158
Bulgaria	5	0	0,125920	0,212136	- 0,0263158
Croatia	4	0	0,089913	0,212136	- 0,0263158
Cyprus	2	498	0,135651	0,212136	- 0,0263158
Czech Republic	4	0	0,022061	0,212136	- 0,0263158
Denmark	5	0	- 0,034460	0,212136	- 0,0263158
Estonia	3	0	0,157900	0,212136	- 0,0263158
Finland	3	0	0,157900	0,212136	- 0,0263158
France	6	38346	3,961673	0,212136	- 0,0263158
FYROM	4	0	0,117925	0,212136	- 0,0263158
Georgia	2	0	0,157900	0,212136	- 0,0263158
Germany	9	11721	0,323520	0,212136	- 0,0263158
Greece	7	0	0,138715	0,212136	- 0,0263158
Hungary	7	0	0,134445	0,212136	- 0,0263158
Ireland	1	0	- 0,118470	0,212136	- 0,0263158
Italy	9	2508	- 0,015231	0,212136	- 0,0263158
Latvia	3	0	0,157900	0,212136	- 0,0263158
Lithuania	3	0	0,152762	0,212136	- 0,0263158
Malta	2	0	0,101875	0,212136	- 0,0263158
Moldova	2	0	0,157900	0,212136	- 0,0263158
Netherlands	4	3621	0,005742	0,212136	- 0,0263158
Norway	4	0	0,088807	0,212136	- 0,0263158
Poland	6	345	0,063730	0,212136	- 0,0263158
Portugal	3	1774	- 0,304285	0,212136	- 0,0263158
Portugal-S.M.	3	0	- 0,637360	0,212136	- 0,0263158
Romania	5	0	0,125920	0,212136	- 0,0263158
Serbia-Montenegro	7	3579	- 0,001795	0,212136	- 0,0263158
Slovakia	5	0	0,153959	0,212136	- 0,0263158
Slovenia	4	0	0,128815	0,212136	- 0,0263158
Spain-Canarias	3	14356	1,345950	0,212136	- 0,0263158
Spain-Continental	2	37271	- 1,128971	0,212136	- 0,0263158
Sweden	8	0	0,090516	0,212136	- 0,0263158
Switzerland	4	354	- 0,387282	0,212136	- 0,0263158
Turkey	5	0	0,153450	0,212136	- 0,0263158
United Kingdom	6	6186	0,211978	0,212136	- 0,0263158
Ukraine	5	0	0,154817	0,212136	- 0,0263158

Data set arithmetic mean = 3534,28 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,397366	- 0,226273	LL
Armenia	0	- 0,397366	- 0,397366	LL
Austria	96	- 0,386573	- 0,163138	LL
Belgium	17182	1,534440	1,285572	HH
Bulgaria	0	- 0,397366	- 0,316887	LL
Croatia	0	- 0,397366	- 0,226273	LL
Cyprus	498	- 0,341375	- 0,397366	LL
Czech Republic	0	- 0,397366	- 0,055517	LL
Denmark	0	- 0,397366	0,086721	LH
Estonia	0	- 0,397366	- 0,397366	LL
Finland	0	- 0,397366	- 0,397366	LL
France	38346	3,913950	1,012193	HH
FYROM	0	- 0,397366	- 0,296768	LL
Georgia	0	- 0,397366	- 0,397366	LL
Germany	11721	0,920449	0,351481	HH
Greece	0	- 0,397366	- 0,349085	LL
Hungary	0	- 0,397366	- 0,338339	LL
Ireland	0	- 0,397366	0,298138	LH
Italy	2508	- 0,115387	0,132001	LH
Latvia	0	- 0,397366	- 0,397366	LL
Lithuania	0	- 0,397366	- 0,384437	LL
Malta	0	- 0,397366	- 0,256377	LL
Moldova	0	- 0,397366	- 0,397366	LL
Netherlands	3621	0,009750	0,588915	HH
Norway	0	- 0,397366	- 0,223490	LL
Poland	345	- 0,358577	- 0,177730	LL
Portugal	1774	- 0,197912	1,537475	LH
Portugal-S.M.	0	- 0,397366	1,603960	LH
Romania	0	- 0,397366	- 0,316887	LL
Serbia-Montenegro	3579	0,005028	- 0,357083	HL
Slovakia	0	- 0,397366	- 0,387450	LL
Slovenia	0	- 0,397366	- 0,324173	LL
Spain-Canarias	14356	1,216707	1,106224	HH
Spain-Continental	37271	3,793085	- 0,297639	HL
Sweden	0	- 0,397366	- 0,227791	LL
Switzerland	354	- 0,357565	1,083110	LH
Turkey	0	- 0,397366	- 0,386168	LL
United Kingdom	6186	0,298138	0,711007	HH
Ukraine	0	- 0,397366	- 0,389608	LL

[13] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanih posebnim događajima

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 5,13[%]
    - 1.2. High critical value: 2,56[%]
    - 1.3. Medium high critical value: 2,56[%]
    - 1.4. Not significant area: 89,74[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 87,18[%]
    - 2.2. Clustered controlled airspace: 12,82[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 15,38[%]
    - 3.2. High-Low value: 2,56[%]
    - 3.3. Low-Low value: 64,10[%]
    - 3.4. Low-High value: 17,95[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000019	- 0,380092	0,371141	NIL
Armenia	0	0,000019	- 0,380092	0,371141	NIL
Austria	0	0,000019	- 0,380092	0,371141	NIL
Belgium	77773	0,000000	3,676598	0,000463	VHCV
Bulgaria	0	0,000019	- 0,380092	0,371141	NIL
Croatia	0	0,000019	- 0,380092	0,371141	NIL
Cyprus	0	0,000019	- 0,380092	0,371141	NIL
Czech Republic	0	0,000019	- 0,380092	0,371141	NIL
Denmark	0	0,000019	- 0,380092	0,371141	NIL
Estonia	0	0,000019	- 0,380092	0,371141	NIL
Finland	0	0,000019	- 0,380092	0,371141	NIL
France	39830	0,000005	1,697467	0,094455	MHCV
FYROM	0	0,000019	- 0,380092	0,371141	NIL
Georgia	0	0,000019	- 0,380092	0,371141	NIL
Germany	70553	0,000000	3,299998	0,001723	VHCV
Greece	0	0,000019	- 0,380092	0,371141	NIL
Hungary	0	0,000019	- 0,380092	0,371141	NIL
Ireland	0	0,000019	- 0,380092	0,371141	NIL
Italy	0	0,000019	- 0,380092	0,371141	NIL
Latvia	0	0,000019	- 0,380092	0,371141	NIL
Lithuania	0	0,000019	- 0,380092	0,371141	NIL
Malta	0	0,000019	- 0,380092	0,371141	NIL
Moldova	0	0,000019	- 0,380092	0,371141	NIL
Netherlands	56527	0,000001	2,568393	0,014739	HCV
Norway	0	0,000019	- 0,380092	0,371141	NIL
Poland	0	0,000019	- 0,380092	0,371141	NIL
Portugal	2056	0,000020	- 0,272850	0,384365	NIL
Portugal-S.M.	0	0,000019	- 0,380092	0,371141	NIL
Romania	0	0,000019	- 0,380092	0,371141	NIL
Serbia-Montenegro	0	0,000019	- 0,380092	0,371141	NIL
Slovakia	0	0,000019	- 0,380092	0,371141	NIL
Slovenia	0	0,000019	- 0,380092	0,371141	NIL
Spain-Canarias	0	0,000019	- 0,380092	0,371141	NIL
Spain-Continental	7836	0,000021	0,028639	0,398779	NIL
Sweden	340	0,000019	- 0,362357	0,373592	NIL
Switzerland	7466	0,000021	0,009339	0,398925	NIL
Turkey	0	0,000019	- 0,380092	0,371141	NIL
United Kingdom	21810	0,000016	0,757532	0,299433	NIL
Ukraine	0	0,000019	- 0,380092	0,371141	NIL

Standard deviation value: 19171,54
f(x)max value: 0,000021
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,144470	0,500664	- 0,0263158
Armenia	2	0	0,144470	0,500664	- 0,0263158
Austria	7	0	- 0,076500	0,500664	- 0,0263158
Belgium	4	77773	7,650438	0,500664	- 0,0263158
Bulgaria	5	0	0,144470	0,500664	- 0,0263158
Croatia	4	0	0,144470	0,500664	- 0,0263158
Cyprus	2	0	0,144470	0,500664	- 0,0263158
Czech Republic	4	0	- 0,205223	0,500664	- 0,0263158
Denmark	5	0	- 0,447252	0,500664	- 0,0263158
Estonia	3	0	0,142223	0,500664	- 0,0263158
Finland	3	0	0,142223	0,500664	- 0,0263158
France	6	39830	2,091283	0,500664	- 0,0263158
FYROM	4	0	0,144470	0,500664	- 0,0263158
Georgia	2	0	0,144470	0,500664	- 0,0263158
Germany	9	70553	2,225325	0,500664	- 0,0263158
Greece	7	0	0,144470	0,500664	- 0,0263158
Hungary	7	0	0,144470	0,500664	- 0,0263158
Ireland	1	0	- 0,287932	0,500664	- 0,0263158
Italy	9	0	0,040283	0,500664	- 0,0263158
Latvia	3	0	0,142223	0,500664	- 0,0263158
Lithuania	3	0	0,142223	0,500664	- 0,0263158
Malta	2	0	0,144470	0,500664	- 0,0263158
Moldova	2	0	0,144470	0,500664	- 0,0263158
Netherlands	4	56527	4,722013	0,500664	- 0,0263158
Norway	4	0	0,034684	0,500664	- 0,0263158
Poland	6	0	- 0,089782	0,500664	- 0,0263158
Portugal	3	2056	0,066534	0,500664	- 0,0263158
Portugal-S.M.	3	0	0,079097	0,500664	- 0,0263158
Romania	5	0	0,144470	0,500664	- 0,0263158
Serbia-Montenegro	7	0	0,144470	0,500664	- 0,0263158
Slovakia	5	0	0,144470	0,500664	- 0,0263158
Slovenia	4	0	0,144470	0,500664	- 0,0263158
Spain-Canarias	3	0	- 0,132338	0,500664	- 0,0263158
Spain-Continental	2	7836	- 0,009350	0,500664	- 0,0263158
Sweden	8	340	- 0,028959	0,500664	- 0,0263158
Switzerland	4	7466	0,009893	0,500664	- 0,0263158
Turkey	5	0	0,144470	0,500664	- 0,0263158
United Kingdom	6	21810	0,858811	0,500664	- 0,0263158
Ukraine	5	0	0,144470	0,500664	- 0,0263158

Data set arithmetic mean = 7286,95 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,380092	- 0,380092	LL
Armenia	0	- 0,380092	- 0,380092	LL
Austria	0	- 0,380092	0,201268	LH
Belgium	77773	3,676598	2,080847	HH
Bulgaria	0	- 0,380092	- 0,380092	LL
Croatia	0	- 0,380092	- 0,380092	LL
Cyprus	0	- 0,380092	- 0,380092	LL
Czech Republic	0	- 0,380092	0,539931	LH
Denmark	0	- 0,380092	1,176695	LH
Estonia	0	- 0,380092	- 0,374180	LL
Finland	0	- 0,380092	- 0,374180	LL
France	39830	1,697467	1,232002	HH
FYROM	0	- 0,380092	- 0,380092	LL
Georgia	0	- 0,380092	- 0,380092	LL
Germany	70553	3,299998	0,674341	HH
Greece	0	- 0,380092	- 0,380092	LL
Hungary	0	- 0,380092	- 0,380092	LL
Ireland	0	- 0,380092	0,757532	LH
Italy	0	- 0,380092	- 0,105982	LL
Latvia	0	- 0,380092	- 0,374180	LL
Lithuania	0	- 0,380092	- 0,374180	LL
Malta	0	- 0,380092	- 0,380092	LL
Moldova	0	- 0,380092	- 0,380092	LL
Netherlands	56527	2,568393	1,838509	HH
Norway	0	- 0,380092	- 0,091252	LL
Poland	0	- 0,380092	0,236212	LH
Portugal	2056	- 0,272850	- 0,243848	LL
Portugal-S.M.	0	- 0,380092	- 0,208101	LL
Romania	0	- 0,380092	- 0,380092	LL
Serbia-Montenegro	0	- 0,380092	- 0,380092	LL
Slovakia	0	- 0,380092	- 0,380092	LL
Slovenia	0	- 0,380092	- 0,380092	LL
Spain-Canarias	0	- 0,380092	0,348175	LH
Spain-Continental	7836	0,028639	- 0,326471	HL
Sweden	340	- 0,362357	0,079919	LH
Switzerland	7466	0,009339	1,059320	HH
Turkey	0	- 0,380092	- 0,380092	LL
United Kingdom	21810	0,757532	1,133697	HH
Ukraine	0	- 0,380092	- 0,380092	LL

[14] Rezultati istraživanje funkcionalnosti upravljanja europskim zračnim prostorom na temelju kriterija nastanka kašnjenja zrakoplova uzrokovanih vremenskim neprilikama

The results obtained from inserted data set indicate the following:

1. Critical airspace values
    - 1.1. Very high critical value: 2,56[%]
    - 1.2. High critical value: 2,56[%]
    - 1.3. Medium high critical value: 2,56[%]
    - 1.4. Not significant area: 92,31[%]
    - 1.5. Medium low critical value: 0,00[%]
    - 1.6. Low critical value: 0,00[%]
    - 1.7. Very low critical value: 0,00[%]
2. Controlled airspace cluster analysis
    - 2.1. Non-clustered controlled airspace: 84,62[%]
    - 2.2. Clustered controlled airspace: 15,38[%]
3. Outliers airspace analysis
    - 3.1. High-High value: 17,95[%]
    - 3.2. High-Low value: 2,56[%]
    - 3.3. Low-Low value: 61,54[%]
    - 3.4. Low-High value: 17,95[%]

1. Analysis of critical airspace areas

Airspace/ANSP	Value	f(x)	z-score	f(z)	Type
Albania	0	0,000003	- 0,383145	0,370709	NIL
Armenia	0	0,000003	- 0,383145	0,370709	NIL
Austria	174522	0,000002	0,829826	0,282735	NIL
Belgium	213733	0,000002	1,102352	0,217289	MHCV
Bulgaria	225	0,000003	- 0,381581	0,370931	NIL
Croatia	36245	0,000003	- 0,131233	0,395522	NIL
Cyprus	166	0,000003	- 0,381991	0,370872	NIL
Czech Republic	18504	0,000003	- 0,254537	0,386226	NIL
Denmark	0	0,000003	- 0,383145	0,370709	NIL
Estonia	422	0,000003	- 0,380212	0,371124	NIL
Finland	0	0,000003	- 0,383145	0,370709	NIL
France	422932	0,000000	2,556336	0,015201	HCV
FYROM	0	0,000003	- 0,383145	0,370709	NIL
Georgia	0	0,000003	- 0,383145	0,370709	NIL
Germany	786509	0,000000	5,083284	0,000001	VHCV
Greece	1710	0,000003	- 0,371260	0,372374	NIL
Hungary	7654	0,000003	- 0,329947	0,377807	NIL
Ireland	0	0,000003	- 0,383145	0,370709	NIL
Italy	1722	0,000003	- 0,371176	0,372386	NIL
Latvia	100	0,000003	- 0,382450	0,370807	NIL
Lithuania	0	0,000003	- 0,383145	0,370709	NIL
Malta	0	0,000003	- 0,383145	0,370709	NIL
Moldova	0	0,000003	- 0,383145	0,370709	NIL
Netherlands	86995	0,000003	0,221492	0,389276	NIL
Norway	0	0,000003	- 0,383145	0,370709	NIL
Poland	12210	0,000003	- 0,298282	0,381584	NIL
Portugal	2875	0,000003	- 0,363163	0,373483	NIL
Portugal-S.M.	0	0,000003	- 0,383145	0,370709	NIL
Romania	0	0,000003	- 0,383145	0,370709	NIL
Serbia-Montenegro	14265	0,000003	- 0,283999	0,383174	NIL
Slovakia	6427	0,000003	- 0,338475	0,376732	NIL
Slovenia	0	0,000003	- 0,383145	0,370709	NIL
Spain-Canarias	12356	0,000003	- 0,297267	0,381699	NIL
Spain-Continental	124943	0,000002	0,485240	0,354635	NIL
Sweden	10506	0,000003	- 0,310125	0,380212	NIL
Switzerland	65000	0,000003	0,068621	0,398004	NIL
Turkey	0	0,000003	- 0,383145	0,370709	NIL
United Kingdom	149924	0,000002	0,658864	0,321104	NIL
Ukraine	0	0,000003	- 0,383145	0,370709	NIL

Standard deviation value: 143879,86
f(x)max value: 0,000003
f(z)max value: 0,398942

2. Controlled airspace cluster analysis

Airspace/ANSP	n.FIRs	Value	LISA I(i)	GISA I(i)	E(i)
Albania	4	0	0,135018	0,240992	- 0,0263158
Armenia	2	0	0,146800	0,240992	- 0,0263158
Austria	7	174522	0,411905	0,240992	- 0,0263158
Belgium	4	213733	2,348002	0,240992	- 0,0263158
Bulgaria	5	225	0,137727	0,240992	- 0,0263158
Croatia	4	36245	0,044890	0,240992	- 0,0263158
Cyprus	2	166	0,144088	0,240992	- 0,0263158
Czech Republic	4	18504	- 0,335757	0,240992	- 0,0263158
Denmark	5	0	- 0,403863	0,240992	- 0,0263158
Estonia	3	422	0,136334	0,240992	- 0,0263158
Finland	3	0	0,137100	0,240992	- 0,0263158
France	6	422932	2,993973	0,240992	- 0,0263158
FYROM	4	0	0,136015	0,240992	- 0,0263158
Georgia	2	0	0,146800	0,240992	- 0,0263158
Germany	9	786509	1,995210	0,240992	- 0,0263158
Greece	7	1710	0,141467	0,240992	- 0,0263158
Hungary	7	7654	0,050591	0,240992	- 0,0263158
Ireland	1	0	- 0,252440	0,240992	- 0,0263158
Italy	9	1722	- 0,062640	0,240992	- 0,0263158
Latvia	3	100	0,136851	0,240992	- 0,0263158
Lithuania	3	0	0,126547	0,240992	- 0,0263158
Malta	2	0	0,142230	0,240992	- 0,0263158
Moldova	2	0	0,146800	0,240992	- 0,0263158
Netherlands	4	86995	0,357784	0,240992	- 0,0263158
Norway	4	0	0,039996	0,240992	- 0,0263158
Poland	6	12210	- 0,169715	0,240992	- 0,0263158
Portugal	3	2875	0,023626	0,240992	- 0,0263158
Portugal-S.M.	3	0	0,022374	0,240992	- 0,0263158
Romania	5	0	0,135006	0,240992	- 0,0263158
Serbia-Montenegro	7	14265	0,095885	0,240992	- 0,0263158
Slovakia	5	6427	0,029521	0,240992	- 0,0263158
Slovenia	4	0	0,000242	0,240992	- 0,0263158
Spain-Canarias	3	12356	- 0,179354	0,240992	- 0,0263158
Spain-Continental	2	124943	- 0,181069	0,240992	- 0,0263158
Sweden	8	10506	- 0,096517	0,240992	- 0,0263158
Switzerland	4	65000	0,138928	0,240992	- 0,0263158
Turkey	5	0	0,145681	0,240992	- 0,0263158
United Kingdom	6	149924	0,299865	0,240992	- 0,0263158
Ukraine	5	0	0,132797	0,240992	- 0,0263158

Data set arithmetic mean = 55126,79 [min]

3. Analysis of outliners' airspace areas

Airspace/ANSP	Value	z-score	Wz(i)	Type
Albania	0	- 0,383145	- 0,352395	LL
Armenia	0	- 0,383145	- 0,383145	LL
Austria	174522	0,829826	0,496375	HH
Belgium	213733	1,102352	2,129994	HH
Bulgaria	225	- 0,381581	- 0,360939	LL
Croatia	36245	- 0,131233	- 0,342067	LL
Cyprus	166	- 0,381991	- 0,377202	LL
Czech Republic	18504	- 0,254537	1,319088	LH
Denmark	0	- 0,383145	1,054074	LH
Estonia	422	- 0,380212	- 0,358573	LL
Finland	0	- 0,383145	- 0,357827	LL
France	422932	2,556336	1,171197	HH
FYROM	0	- 0,383145	- 0,354996	LL
Georgia	0	- 0,383145	- 0,383145	LL
Germany	786509	5,083284	0,392504	HH
Greece	1710	- 0,371260	- 0,381047	LL
Hungary	7654	- 0,329947	- 0,153331	LL
Ireland	0	- 0,383145	0,658864	LH
Italy	1722	- 0,371176	0,168762	LH
Latvia	100	- 0,382450	- 0,357827	LL
Lithuania	0	- 0,383145	- 0,330286	LL
Malta	0	- 0,383145	- 0,371218	LL
Moldova	0	- 0,383145	- 0,383145	LL
Netherlands	86995	0,221492	1,615339	HH
Norway	0	- 0,383145	- 0,104388	LL
Poland	12210	- 0,298282	0,568976	LH
Portugal	2875	- 0,363163	- 0,065057	LL
Portugal-S.M.	0	- 0,383145	- 0,058397	LL
Romania	0	- 0,383145	- 0,352363	LL
Serbia-Montenegro	14265	- 0,283999	- 0,337625	LL
Slovakia	6427	- 0,338475	- 0,087217	LL
Slovenia	0	- 0,383145	- 0,000633	LL
Spain-Canarias	12356	- 0,297267	0,603343	LH
Spain-Continental	124943	0,485240	- 0,373154	HL
Sweden	10506	- 0,310125	0,311220	LH
Switzerland	65000	0,068621	2,024567	HH
Turkey	0	- 0,383145	- 0,380224	LL
United Kingdom	149924	0,658864	0,455124	HH
Ukraine	0	- 0,383145	- 0,346599	LL

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 **Istraživanje funkcionalnosti upravljanja europskim zračnim prostorom** na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 25.6.2018

Student: