Model učinaka troposferskog kašnjenja satelitskog signala na kvalitetu satelitskog određivanja položaja u pomorskoj površinskoj navigaciji

Rumora, Ivan

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Maritime Studies, Rijeka / Sveučilište u Rijeci, Pomorski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:187:562399

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Image not found or type unknown

Repository / Repozitorij:

Repository of the University of Rijeka, Faculty of Maritime Studies - FMSRI Repository

Image not found or type unknown

DIGITALNA KNJIŽNICA

SVEUČILIŠTE U RIJECI
POMORSKI FAKULTET

Ivan Rumora

MODEL UČINAKA TROPOSFERSKOG KAŠNJENJA SATELITSKOG SIGNALA NA KVALITETU SATELITSKOG ODREĐIVANJA POLOŽAJA U POMORSKOJ POVRŠINSKOJ NAVIGACIJI

DOKTORSKA DISERTACIJA

Rijeka, 2021.

SVEUČILIŠTE U RIJECI
POMORSKI FAKULTET

Ivan Rumora

MODEL UČINAKA TROPOSFERSKOG KAŠNJENJA SATELITSKOG SIGNALA NA KVALITETU SATELITSKOG ODREĐIVANJA POLOŽAJA U POMORSKOJ POVRŠINSKOJ NAVIGACIJI

DOKTORSKA DISERTACIJA

Mentor: prof. dr. sc. Serđo Kos
Komentor: prof. dr. sc. Renato Filjar

Rijeka, 2021.

UNIVERSITY OF RIJEKA
FACULTY OF MARITIME STUDIES

Ivan Rumora

MODEL OF GNSS TROPOSPHERIC DELAY EFFECTS ON QUALITY OF SATELLITE POSITIONING IN MARITIME SURFACE NAVIGATION

DOCTORAL THESIS

Rijeka, 2021.

Mentor: prof. dr. sc. Serđo Kos

Komentor: prof. dr. sc. Renato Filjar

Doktorski rad obranjen je dana _____ u/na_____

_____ pred povjerenstvom u sastavu:

1. doc. dr. sc. David Brčić
2. prof. dr. sc. Boris Sviličić
3. doc. dr. sc. Sanjin Valčić
4. izv. prof. dr. sc. Kristijan Lenac

POSVETA

Posebna zahvala ide supruzi Ireni i sinu Noi koji su uvijek bili uz mene, a posebno kada je to bilo najpotrebnije.

Ovom prilikom želio bih se zahvaliti roditeljima i bratu Luki koji su mi pružili podršku tijekom pohađanja doktorskog studija.

Isto tako, želio bih se posebno zahvaliti mentoru prof. dr. sc. Serđu Kosu i komentoru prof. dr. sc. Renatu Filjaru koji nisu ni u jednom trenutku odustajali od mene i koji su me bezrezervno podržavali tijekom svih ovih godina doktorskog studija.

Dragoj baki od srca zahvaljujem na velikom i nesebičnom trudu koji je uložila u mene tijekom cijelog života.

Edinu i Sabini, kao i naravno dobrom prijatelju Martinu, želim također od svega srca zahvaliti što su uvijek vjerovali u mene i nikada u tome nisu posustali.

Također bih želio zahvaliti general pukovniku dr. sc. Slavku Bariću i viceadmiralu Zdenku Simičiću koji su mi pružili kolegijalnu i stručnu pomoć tijekom pohađanja doktorskog studija.

Svojoj najdražoj sestri također odajem posebno priznanje za trenutke u kojima nisam vidio izlaz, a ona je bila tu za mene, uvijek nasmijana, raširenih ruku te povrh svega toplog i srdačnog pogleda.

SAŽETAK

Točnost određivanja položaja satelitskim navigacijskim sustavom određena je učincima koji nastaju u prostoru širenja satelitskog signala. Troposfera, kao Zemljinoj površini najbliži sloj atmosfere, izaziva pojavu troposferskog kašnjenja satelitskog signala zbog svojih nehomogenih fizikalnih obilježja. Troposfersko kašnjenje pojavljuje se kao utjecajna veličina u mjerenju pseudoudaljenosti te time određuje točnost određivanja položaja satelitskim sustavom.

Opisnom statističkom analizom identificirana su meteorološka obilježja te određena statistička narav doprinosa troposferskih učinaka ukupnoj horizontalnoj pogreški određivanja položaja. Navedeno je iskorišteno u razvoju kandidata modela za procjenu troposferskog doprinosa ukupnoj pogreški satelitskog određivanja položaja. Kandidati modela analizirani su prema definiranim mjerilima uspješnosti. Izabran je i predložen prognostički model zasnovan na metodi linearne regresije kao najuspješniji od razmotrenih kandidata modela.

Nadalje, predlaže se novi pristup opisu i prognozi pogreške satelitskog određivanja položaja temeljem poznavanja trenutnog stanja troposfere u neposrednoj okolini satelitskog navigacijskog prijamnika, izraženoj vrijednostima opisnih varijabli: temperature, tlaka zraka i vlažnosti zraka.

U radu su analizirani postojeći modeli popravaka pogreške mjerenja pseudoudaljenosti uslijed troposferskog kašnjenja satelitskog signala, uzroka narušavanja točnosti određivanja položaja satelitskim sustavom te razmotreni njihovi nedostaci i ograničenja. Raščlanjen je postupak procjene položaja. Teorijskim razmatranjem u disertaciji je identificirana suštinska razlika između pogreške mjerenja pseudoudaljenosti i pogreške određivanja položaja. Predložen je novi model matematičke transformacije pogreške mjerenja pseudoudaljenosti u pogrešku određivanja položaja.

U disertaciji je predložen novi model, zasnovan na nadziranom statističkom učenju, koji izravno povezuje troposfersko kašnjenje satelitskog signala za određivanje položaja sa zahtjevima za točnost određivanja položaja pojedinih osnovnih navigacijskih zadataka u pomorskoj površinskoj navigaciji. Također, predložen je novi model klasifikacije navigacijskih zadataka u pomorskoj površinskoj navigaciji prema zahtjevima o potrebnoj točnosti određivanja položaja. Naposljetku, u disertaciji je predložen model matematičke transformacije troposferskog kašnjenja satelitskog signala za određivanje položaja u pogrešku određivanja položaja satelitskim sustavom uslijed troposferskih učinaka. Navedeni modeli predstavljaju ostvarene znanstvene doprinose disertacije.

Predloženi modeli su vrednovani na primjeru dugoročnih eksperimentalnih opažanja. Kritički su razmotrena njihova potencijalna ograničenja u primjeni (točnost, sveobuhvatnost, primjenjivost računalne izvedbe i dr.) čime su izdvojene teme mogućih budućih istraživanja.

Naposljetku, rezultati su razmotreni sa stajališta primjena u pomorskoj površinskoj navigaciji, posebno u navigacijskim postupcima za potrebe ratne i trgovačke mornarice.

KLJUČNE RIJEČI: satelitska navigacija, troposferski učinci, određivanje položaja, pogreška određivanja položaja, troposferski doprinos ukupnoj pogreški određivanja položaja, klasifikacija primjena satelitske navigacije, pomorska površinska navigacija, statističko učenje, prognostički model

ABSTRACT

Positioning accuracy in a specific area using a satellite navigation system is based on satellite signal propagation. The troposphere, as the atmospheric layer closest to the Earth's surface, causes a tropospheric delay of the satellite signal due to its inhomogeneous physical properties. The tropospheric delay occurs as an influential quantity in measuring pseudoranges, and determines positioning accuracy of the satellite navigation system.

Descriptive statistical analysis identified meteorological features and established the statistical nature of tropospheric effects on the total horizontal positioning error. These findings were used to develop candidate models for estimating the tropospheric contribution to total satellite positioning errors. The above candidate models were analyzed based on predetermined performance criteria. A prognostic model obtained using the linear regression method was chosen as the best candidate model.

Furthermore, the dissertation proposes a new approach to describing and predicting satellite positioning errors based on the known current state of the troposphere in the immediate vicinity of the satellite navigation receiver, and expressed using descriptive variables: temperature, air pressure and humidity.

The dissertation analyzes existing error correction models in measuring pseudoranges based on tropospheric delays of satellite signals, occurring as indirect causes of degradation in positioning accuracy using the satellite navigation system, and discusses associated shortcomings and limitations. The position estimation process is also analyzed in the dissertation. Based on theoretical considerations, the dissertation identifies the essential difference between measurements of pseudo-distance errors and position determination errors, and subsequently proposing a new model for mathematical transformation (transition) of pseudo-distance measurement errors into position determination errors.

The dissertation proposes a new model, based on supervised statistical learning, which directly connects the tropospheric delay of a satellite signal in determining position along with the accuracy requirements in determining the position of individual basic navigation tasks in marine surface navigation. Moreover, a new model for classifying navigation tasks in marine surface navigation based on position accuracy requirements is proposed. Finally, the dissertation proposes a model for the mathematical transformation of the tropospheric delay of a satellite positioning signal into a satellite-based positioning error caused by tropospheric effects. These models are the scientific contributions of the dissertation.

The proposed models were evaluated using the example of long-term experimental observations. Their potential limitations in application (accuracy, comprehensiveness, applicability of computer performance, etc.) were considered in a critical manner, thus highlighting potential topics for future research.

Finally, the results have been considered in terms of various applications in maritime surface navigation, especially in navigation procedures for the requirements of the navy.

KEYWORDS: satellite navigation, tropospheric effects, positioning, positioning error, tropospheric contribution to the total positioning error, classification of satellite navigation applications, marine surface navigation, statistical learning, prognostic model

SADRŽAJ

1. UVOD 1

2. OPIS PROBLEMA 7

2.1. Osnove satelitskog određivanja položaja 7

2.2. Arhitektura satelitskog navigacijskog prijamnika 22

2.3. Postupak određivanja položaja satelitskim navigacijskim sustavom 25

2.4. Proračun pogrešaka procjene položaja satelitskim navigacijskim sustavom..... 32

2.5. Troposferski učinci na prolaz satelitskog signala..... 37

2.5.1. Obilježja troposfere..... 37

2.5.2. Propagacija radiovala troposferom 43

2.6. Točnost određivanja položaja za pojedine klase primjena satelitskih navigacijskih sustava..... 44

3. PREGLED PRETHODNIH ISTRAŽIVANJA 49

3.1. Sistematizacija navigacijskih zadataka u pomorskoj navigaciji prema potrebnoj točnosti položaja 49

3.2. Postupak procjene položaja satelitskim sustavom..... 53

3.3. Model pogrešaka procjene položaja satelitskim sustavom..... 53

3.4. Modeli popravaka troposferskog kašnjenja satelitskog signala za određivanja položaja..... 58

3.5. Nedostaci postojećih modela 74

4. PRIJEDLOG PROGNOSTIČKOG MODELA TROPOSFERSKOG DOPRINOSA UKUPNOJ POGREŠKI SATELITSKOG ODREĐIVANJA POLOŽAJA ZA POMORSKU POVRŠINSKU NAVIGACIJU 75

4.1. Prijedlog klasifikacije navigacijskih zadataka u pomorskoj površinskoj navigaciji ……75

4.2. Model preslikavanja troposferskog kašnjenja satelitskog signala za određivanje položaja i točnosti određivanja položaja satelitskim sustavom 79

4.3. Model povezivanja troposferskog kašnjenja signala za satelitsko određivanje položaja s pogreškom satelitskog određivanja položaja i zahtjevima za točnost određivanja položaja pojedinih klasa navigacijskih zadataka u pomorskoj površinskoj navigaciji 81

5. METODOLOGIJA RAZVOJA MODELA 83

5.1. Struktura modela 83

5.2. Prediktori i ishodi modela 86

5.3. Postupci razvoja modela zasnovani na statističkom učenju nad eksperimentalnim opažanjima 86

5.3.1. Razvoj modela metodom linearne regresije 86

5.3.2. Model zasnovan na metodama stabla odlučivanja i slučajne šume 88

5.3.3. Model zasnovan na metodi umjetne neuronske mreže 89

5.4. Vrednovanje prognostičkog modela 91

5.4.1. Odnos prognoziranih i stvarno opaženih vrijednosti 93

5.4.2. Koeficijent određenja R^2 93

5.4.3. Podešeni koeficijent određenja 94

5.4.4. Akaikeov informacijski kriterij 95

5.4.5. Bayesov informacijski kriterij 95

5.4.6. Analiza reziduala 96

5.5. Eksperimentalna opažanja za potrebe razvoja i vrednovanja prognostičkog modela 96

5.6. Preslikavanje ostvarene točnosti određivanja položaja uz djelovanje troposferskih učinaka na zahtjeve kategorija navigacijskih zadataka u pomorskoj površinskoj navigaciji 105

6. REZULTATI ISTRAŽIVANJA 108

6.1. Prognostički model zasnovan na linearnoj regresiji 108

6.1.1. Jednostavni prognostički model linearne regresije s dva prediktora i bez slobodnog člana 108

6.1.2. Mješoviti prognostički model linearne regresije s tri prediktora i bez slobodnog člana 111

6.2. Prognostički model zasnovan na metodi slučajne šume 113

6.3. Prognostički model zasnovan na metodi umjetne neuronske mreže 116

6.3.1. Neuronska mreža s jednim skrivenim slojem 116

6.3.2. Neuronska mreža s dva skrivena sloja 116

6.3.3. Neuronska mreža s tri skrivena sloja 117

6.3.4. Analiza modela zasnovanih na umjetnoj neuronskoj mreži 118

6.4. Zbirna ocjena sukladnosti sa zahtjevima za točnost određivanja položaja za navigacijske postupke u pomorskoj površinskoj navigaciji 120

7. DISKUSIJA 125

8. ZAKLJUČAK 128

9. LITERATURA 130

10. POPIS KRATICA 140

11. POPIS SLIKA 142

12. POPIS TABLICA 145

13. ŽIVOTOPIS 147

14. BIOGRAPHY 148

1. UVOD

Navigacijski postupci u pomorskoj površinskoj navigaciji podržani su suvremenim tehnološkim sustavima među kojima se nalazi i satelitska navigacija. Kvaliteta izvršavanja navigacijskih zadataka u pomorskoj površinskoj navigaciji ovisi o kvaliteti tehnologije koje podržavaju njihovo izvršavanje. Satelitski navigacijski sustavi pružaju usluge određivanja položaja, brzine i točnog vremena, s određenom kvalitetom (točnost, dostupnost, integritet i kontinuitet).

Problem definicije gdje je potrebna točnost određivanja položaja za navigacijske postupke u pomorskoj površinskoj navigaciji razmatrale su različite međunarodne organizacije koje se bave pomorstvom, uključujući Međunarodnu pomorsku organizaciju (engl. International Maritime Organisation – IMO) i Agenciju za europski GNSS (engl. GNSS Agency – GSA). Međunarodne organizacije koje se bave problematikom pomorstva izložile su mišljenja i preporuke za postavljanje definicije potrebne točnosti određivanja položaja za pojedinačne navigacijske zadatke u pomorskoj površinskoj navigaciji. Pregledom literature ustanovljeno je kako navedena mišljenja i preporuke imaju jedan ili više nedostataka i ograničenja, kako slijedi: (i) prevelika općenitost, (ii) nedostatak sveobuhvatnosti, (iii) mišljenja i preporuke nisu isključivi rezultat znanstvenih istraživanja, već kompromis koji u većoj mjeri obuhvaća političke, strateške, lobističke i nacionalne interese.

Rezolucija Međunarodne pomorske organizacije (IMO, 2001) daje okvire potrebne točnosti određivanja položaja za pojedine osnovne navigacijske zadatke. Međutim, rezolucija predstavlja rezultat kompromisnog pregovaranja. Rezolucija razmatra navigacijske zadatke koji se tek u većem ili manjem dijelu mogu povezati s osnovnim navigacijskim zadacima prikazanim u rezoluciji. Također, zbog svoje dugotrajnosti, rezolucija ne uzima u obzir tehnološki napredak satelitskih navigacijskih sustava te ostalih odnosnih tehnologija, moderne tehnološke primjene i nove načine korištenja tehnologija za potrebe pomorske površinske navigacije.

Pojedinačne klase navigacijskih zadataka pokušali su povezati Thomas i suradnici (2011) u različitim područjima primjene, uključivo i pomorsku površinsku navigaciju s potrebama za točnošću određivanja položaja. Studija je pružila konkretne numeričke potrebe, ali i općenite kvalitativne zahtjeve koji se do jedne mjere mogu povezati s pojedinačnim kvantitativnim procjenama kvalitete određivanja položaja satelitskim sustavima.

Europska agencija za satelitsku navigaciju predstavila je do sad najkvalitetniji pokušaj postavljanja definicije potrebne kvalitete točnosti satelitskog određivanja položaja uz prilično detaljnu klasifikaciju primjena u različitim segmentima i disciplinama. Izvješće o pomorskim zahtjevima i potrebama tijekom plovidbe unutarnjim plovnim putevima (GSA, 2018) predstavlja cijelu knjižnicu rezultata istraživanja koje prepoznate klase konkretnih navigacijskih zadataka povezuju s potrebama za točnošću određivanja položaja. Klasifikacija i potrebe za točnošću dobiveni su kao rezultat znanstvenih istraživanja metodologijom koja je uključivala procjenu kvalitete položaja u eksperimentalnim uvjetima i prikupljanjem iskustva praktičara pomoću anketa ili intervjua. Izvješće o pomorskim zahtjevima i potrebama tijekom plovidbe unutarnjim plovnim putevima (GSA, 2019) razmatra potrebe za točnošću određivanja položaja u pomorskoj površinskoj navigaciji. Usprkos velikom trudu, studija još uvijek ne obuhvaća neke postojeće i nadolazeće navigacijske zadatke, ostavljajući otvorenim dovršetak klasifikacije navigacijskih zadataka u pomorskoj površinskoj navigaciji i definiranje potreba za točnošću određivanja položaja za svaku klasu navigacijskih zadataka.

Istraživanje prikazano ovom disertacijom bavi se utjecajem troposferskih učinaka na kvalitetu određivanja položaja satelitskim sustavom te njihovim doprinosom narušavanju točnosti određivanja položaja kao potencijalnog rizika primjene u pojedinim klasama navigacijskih zadataka za potrebe pomorske površinske navigacije. Istraživanje je usredotočeno na segment jednofrekvencijskog određivanja položaja satelitskim sustavom.

Predmet istraživanja je opis učinaka stanja troposfere na pojavu troposferskog kašnjenja satelitskog signala, pojavu troposferskog doprinosa ukupnoj pogreški satelitskog određivanja položaja te narušavanja točnosti procjene položaja za pojedinačne klase navigacijskih zadataka u pomorskoj površinskoj navigaciji.

Ukupna pogreška određivanja položaja satelitskim navigacijskim sustavom nastaje kao rezultat istovremenog djelovanja različitih uzroka koji se dijele u dvije statistički neovisne skupine: korisničku razdiobu pogrešaka (engl. User Equivalent Range Error – UERE) i geometrijsku degradaciju točnosti (engl. Geometric Dilution of Precision – GDOP). Skupinu UERE čine (i) pogreške uslijed kojih izmjereno vrijeme propagacije, odnosno ekvivalentna tzv. pseudoudaljenost između satelitske i korisničke antene, sadrži pogreške mjerenja, (ii) pogreške nastale korištenjem netočnih podataka o satelitskim orbitama (satelitske efemeride), (iii) pogreške nastale uslijed neispravljenih odstupanja satelitskog sata od zajedničkog vremena sustava. Učinci troposfere pripadaju UERE (i) skupini. Geometrijska degradacija točnosti

nastaje uslijed međusobnih prostornih odnosa položaja korisnika i položaja iz korisničkog stajališta vidljivih satelita.

Problem istraživanja obuhvaća (i) razvoj matematičke transformacije pogreške mjerenja pseudoudaljenosti uslijed troposferskih učinaka u troposferski doprinos ukupnoj pogreški određivanja položaja satelitskim navigacijskim sustavom, (ii) klasifikaciju navigacijskih zadataka u pomorskoj površinskoj navigaciji prema potrebnim točnostima određivanja položaja te (iii) definiciju modela popravaka učinaka troposferskog kašnjenja na mjerenje pseudoudaljenosti.

Hipoteza ove disertacije je: Postoji model koji povezuje troposfersko kašnjenje satelitskog signala za određivanje položaja s točnošću određivanja položaja i zahtjevima za točnost određivanja položaja pojedinih osnovnih navigacijskih zadataka u pomorskoj površinskoj navigaciji.

Nastavno na postavljeno hipotezu, definirane su i dvije podhipoteze istraživanja:

1. Postoji klasifikacija navigacijskih zadataka u pomorskoj površinskoj navigaciji prema zahtjevima za potrebnu točnost određivanja položaja (Taksonomija osnovnih navigacijskih zadataka u pomorskoj površinskoj navigaciji) te
2. Postoji model preslikavanja troposferskog kašnjenja satelitskog signala za određivanje položaja u točnost određivanja položaja satelitskim sustavom.

Prikazanim istraživanjem ostvareni su sljedeći izvorni znanstveni doprinosi:

1. Razvijen je model koji povezuje troposfersko kašnjenje satelitskog signala za određivanje položaja sa zahtjevima za točnost određivanja položaja pojedinih osnovnih navigacijskih zadataka u pomorskoj površinskoj navigaciji.
2. Razvijen je model klasifikacije navigacijskih zadataka u pomorskoj površinskoj navigaciji prema zahtjevima za potrebnu točnost određivanja položaja.
3. Razvijen je model matematičke transformacije troposferskog kašnjenja satelitskog signala za određivanje položaja u pogrešku određivanja položaja satelitskim sustavom.

Svrha istraživanja je razvoj prognostičkog modela doprinosa troposferskih učinaka ukupnoj pogreški određivanja položaja satelitskim sustavom u stanjima troposfere u okolici satelitskog navigacijskog prijamnika, za definirane klase primjena satelitske navigacije u pomorskoj površinskoj navigaciji.

Ciljevi istraživanja uključuju: razvoj detaljnije klasifikacije primjena satelitske navigacije u pomorskoj površinskoj navigaciji, definiciju zahtjeva za točnost određivanja položaja satelitskim sustavom po pojedinim klasama primjena u pomorskoj površinskoj navigaciji, razvoj modela procjene narušavanja točnosti određivanja položaja uslijed troposferskog kašnjenja satelitskog signala radi zadovoljavanja zahtjeva za točnost pojedinih klasa primjena u pomorskoj površinskoj navigaciji te vrednovanje modela na eksperimentalnim podacima o stanju vremena prikupljenim tijekom duljeg vremenskog razdoblja (4 mjeseca).

Istraživanjem su razmatrane sljedeće teme: obilježja meteoroloških pojava, obilježja vrijednosti i dinamike troposferskog kašnjenja tijekom promatranih meteoroloških pojava u scenarijima primjene satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, troposferskog doprinosa ukupnoj pogreški određivanja položaja te povezivanje (preslikavanje) obilježja vrijednosti i dinamike troposferskog doprinosa ukupnoj pogreški satelitskog sustava, te model (izbora) popravaka troposferskog kašnjenja, odnosno, troposferskog doprinosa ukupnoj pogreški određivanja položaja satelitskim sustavom.

Pregledom prethodnih istraživanja i postavljanjem problema povezano je opće narušavanje kvalitete satelitskog određivanja položaja s meteorološkim pojavama na moru različite naravi i intenziteta te su istražene potrebe za kvalitetom satelitskog određivanja položaja u različitim scenarijima primjene satelitskog određivanja položaja u pomorskoj površinskoj navigaciji.

Znanstveno-istraživački rad proveden je u programskom okruženju otvorenog koda za statističko računarstvo R.

Statistička analiza podataka primijenjena je na vremenske nizove prikupljenih opažanja koji su analizirani postupcima opisne statističke analize kako bi se razlučila priroda procesa koji ih je izazvao te bio izabran odgovarajući pristup razvoju modela. Korištena je opisna (eksploratorna) statistička analiza podataka, analiza i karakterizacija vremenskih nizova u vremenskoj i frekvencijskoj domeni, analizirane su eksperimentalne statističke razdiobe, reziduali i njihove varijance. Temeljem rezultata opisne statističke analize, donesena je odluka o pristupu razvoja modela u prostorno-vremenskoj domeni. Predložen je pokazatelj uspješnosti kojim je izvršena validacija razvijenih modela.

U prvom poglavlju (Uvodu) sadržani su predmet istraživanja, problem istraživanja, hipoteza i pripadajuće podhipoteze istraživanja, svrha istraživanja, ciljevi istraživanja, pregled prethodnih istraživanja, opis statističke analize podataka, razmatranje kandidata modela, izbor najuspješnijeg od modela te originalni znanstveni doprinosi.

U drugom poglavlju (Opis problema) obuhvaćeni su elementi opisa problema uključujući prikaz osnova satelitskog određivanja položaja, pregled arhitekture satelitskog navigacijskog prijamnika, opis postupka satelitskog određivanja položaja, proračun pogrešaka procjene položaja satelitskim navigacijskim sustavom, troposferske učinke na propagaciju satelitskog signala te točnost određivanja položaja za ciljanu primjenu satelitskih navigacijskih sustava.

U trećem poglavlju (Pregled prethodnih istraživanja) predstavljen je pregled prethodnih istraživanja uključujući sistematizaciju navigacijskih zadataka u pomorskoj površinskoj navigaciji prema potrebnoj točnosti procjene položaja, metodologiju procjene položaja satelitskim sustavom, model pogrešaka procjene položaja satelitskim sustavom, modele popravaka troposferskog kašnjenja satelitskog signala za određivanje položaja te nedostatke postojećih modela popravaka.

Unutar četvrtog poglavlja (Prijedlog prognostičkog modela troposferskog doprinosa ukupnoj pogreški satelitskog određivanja položaja za pomorsku površinsku navigaciju) predložen je istoimeni model. Ovdje su klasificirani zadaci u pomorskoj površinskoj navigaciji. Predložen je model preslikavanja troposferskog kašnjenja satelitskog signala za određivanje položaja i točnosti određivanja položaja satelitskim sustavom te model povezivanja troposferskog kašnjenja signala za satelitsko određivanje položaja i zahtjevima za točnost određivanja položaja pojedinih klasa.

Peto poglavlje (Metodologija razvoja modela) obrađuje metodologiju rada i obuhvaća: strukturu modela popravaka, opis prediktora i ishoda modela te postupak razvoja modela zasnovanih na statističkom učenju nad eksperimentalnim opažanjima, razmatranja uspješnosti razvijenih modela, eksperimentalna opažanja za potrebe razvoja i vrednovanja modela.

Šesto poglavlje (Rezultati istraživanja) predstavlja razvijene potencijalne modele za odabir koji opisuju troposferski doprinos ukupnoj pogreški određivanja položaja kao rezultat djelovanja prediktora (varijabli stanja troposfere). Potencijalni modeli za odabir su prognostičke naravi, zasnovani na postupku linearne regresije, postupku slučajne šume i postupku neuronske mreže. Na kraju je prikazana zbirna ocjena sukladnosti obilježja potencijalnih modela za odabir zahtjeva za točnost određivanja položaja za navigacijske postupke u pomorskoj površinskoj navigaciji.

Sedmo poglavlje (Diskusija) razmatra rezultate disertacije, njihovu praktičnu primjenu u površinskoj pomorskoj navigaciji te prikazuje nedostatke i ograničenja razmatranog modela kao teme budućih istraživanja izvan dosega ove disertacije.

Osmo poglavlje (Zaključak) sažima koncizno problem, metodologiju, hipotezu i pomoćne hipoteze, izvodi znanstvene doprinose prikazanog znanstveno-istraživačkog rada u potvrdi hipoteze i pomoćnih hipoteza i primjeni istraživanja te upućuje na teme budućih istraživanja.

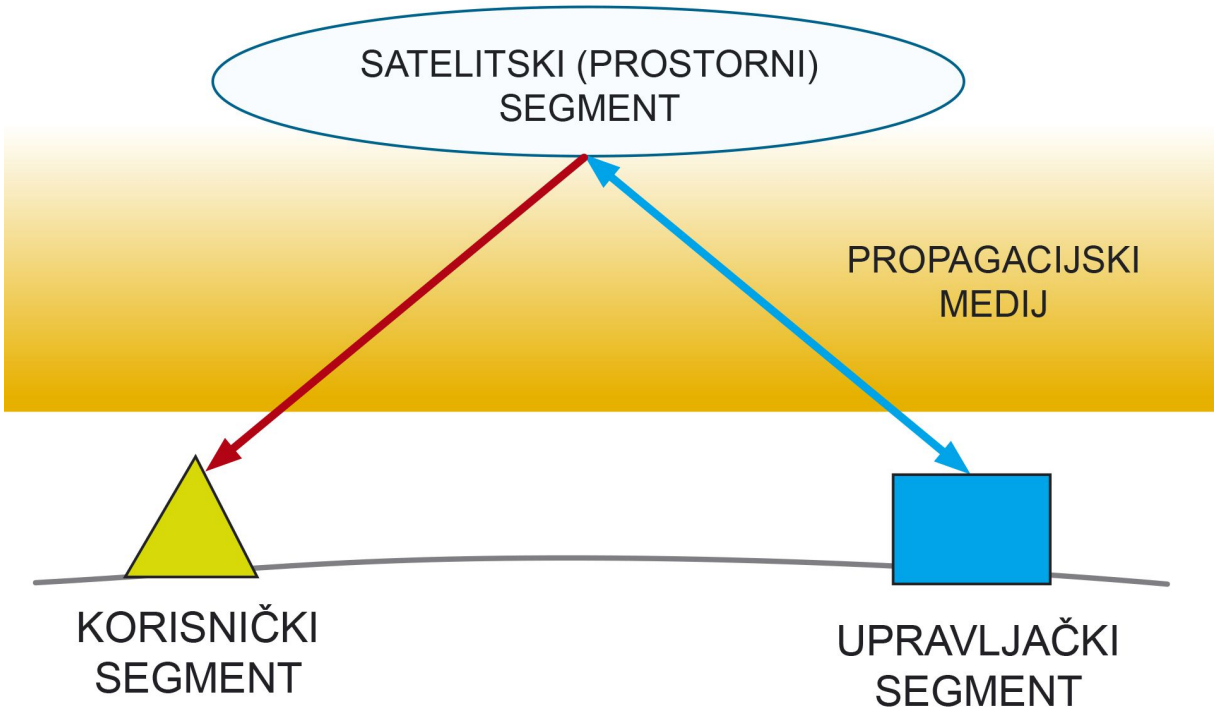
2. OPIS PROBLEMA

U ovom poglavlju razmotrene su osnove satelitskog određivanja položaja. Kao i u cijeloj disertaciji, razmotren je slučaj jednofrekvencijskog određivanja položaja, budući da većina satelitskih navigacijskih prijemnika na tržištu podržava upravo navedeni način rada. Nisu razmatrani napredni postupci satelitskog određivanja položaja, poput preciznog određivanja položaja (engl. Precise Point Positioning – PPP), zatim kinematike u stvarnom vremenu (engl. Real-Time Kinematics – RTK) te diferencijska usluga GPS sustava (engl. Differential Global Positioning System – DGPS). Prikazana je arhitektura satelitskog navigacijskog prijamnika. Predstavljen je postupak određivanja položaja satelitskim putem. Razmotren je proračun pogrešaka procjene položaja satelitskim navigacijskim sustavom, uz poseban osvrt na troposferske učinke na propagaciju satelitskog signala. Na kraju, diskutirani su zahtjevi za točnost određivanja položaja satelitskim sustavom za izabrane primjene.

2.1. Osnove satelitskog određivanja položaja

Satelitsko određivanje položaja je suvremen postupak određivanja položaja, zasnovan na mjerenju vremena potrebnog da satelitski signal u obliku radiovala propagira od satelitske antene do antene korisničkog prijamnika za satelitsko određivanje položaja (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997; Teunissen, Montenbruck, 2017; Filić, 2017). Pri tome se mjerenje obavlja isključivo unutar prijamnika za satelitsko određivanje položaja, čime se onemogućuje razotkrivanje informacije o procijenjenom položaju bez suglasnosti korisnika čiji se položaj određuje (Parkinson, Spilker, Jr, 1996).

U istraživanju provedenom u okviru ove doktorske disertacije razmatran je problem udjela u ukupnoj pogreški satelitskog određivanja položaja uslijed troposferskih učinaka iz perspektive nepotpomognutog, samostalnog određivanja položaja izvornim pristupom satelitske navigacije (Filić, Filjar, Ruotsalainen, 2016; Filić, Filjar 2017; Filić, 2018a; Filjar, 2019).



Slika 1. Arhitektura satelitskog navigacijskog sustava (izvor: Parkinson, Spilker, Jr, 1996)

Satelitsko određivanje položaja zasniva se na postavljenoj arhitekturi satelitskog navigacijskog sustava (slika 1) koja se sastoji od sljedećih osnovnih segmenata (Parkinson, Spilker, Jr, 1996):

1. prostorni (satelitski) segment,
2. kontrolni segment,
3. korisnički segment te
4. prijenosni medij.

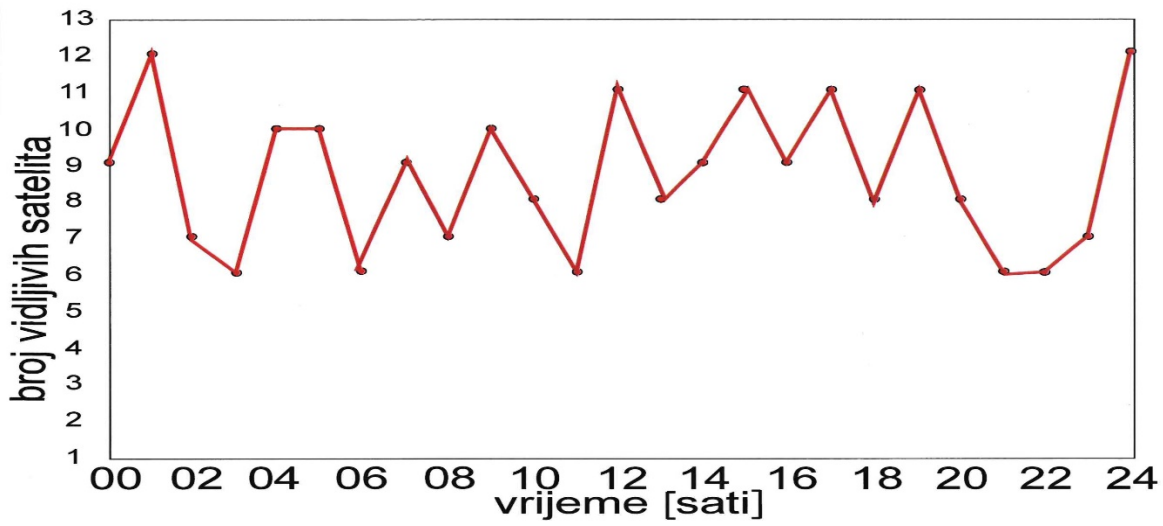
Prijenosni medij i njegovi učinci predmet su posebnog razmatranja ove disertacije i bit će detaljnije objašnjeni u nastavku teksta.

Prostorni (satelitski) segment čine svi sateliti sustava, postavljeni po orbitama oko Zemlje tako da omogućuju prijam dovoljnog broja satelitskih signala bilo gdje na i oko površine Zemlje, čime se postiže globalno pokrivanje (Parkinson, Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013). Osnovne informacije o prostornim segmentima pojedinih globalnih navigacijskih satelitskih sustava prikazane su u tablici 1.

Tablica 1. Obilježja prostornih segmenata globalnih navigacijskih satelitskih sustava (izvor: GLONASS-IAC, 2020.).

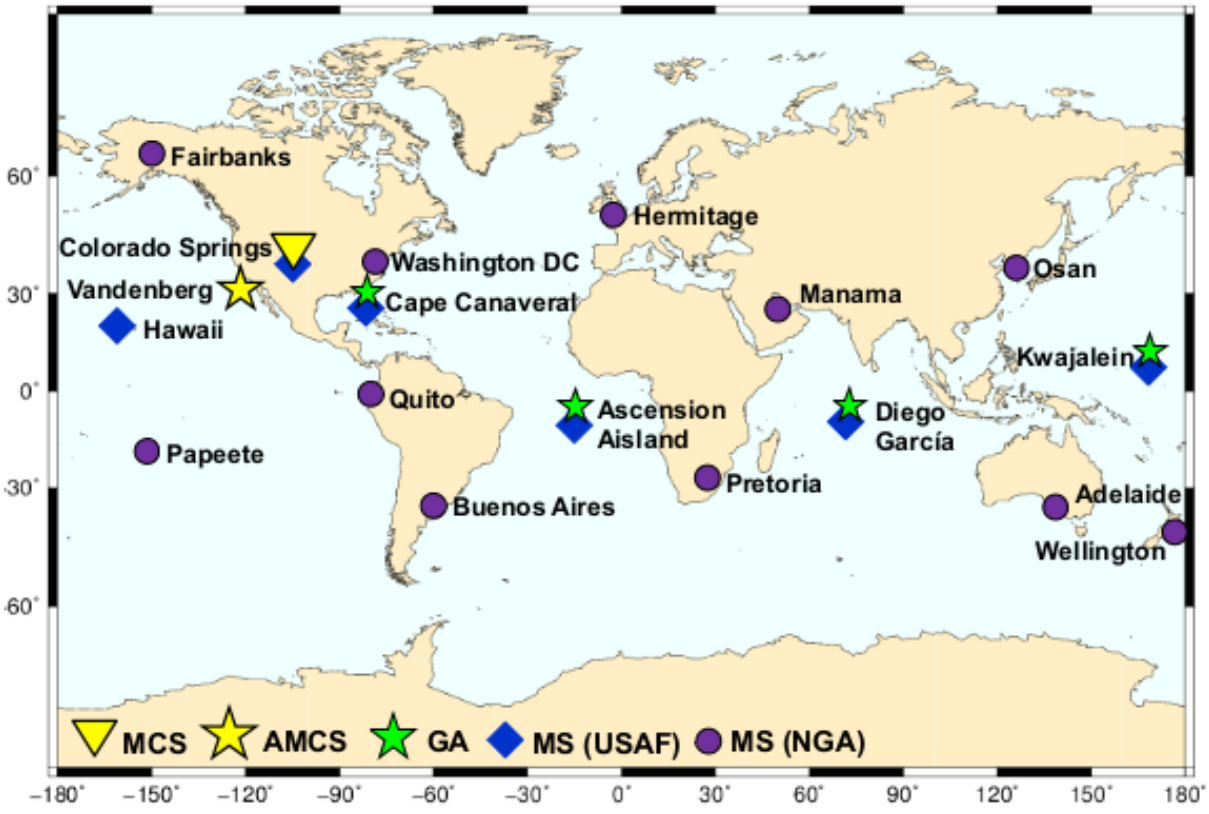
	GPS	GLONASS	BEIDOU	GALILEO
Broj operativnih satelita	31	23	35	21
Ukupni broj satelita	33	28	48	25
Približna visina iznad razine mora	20 180 km	19 130 km	21 150 km (sateliti u geostacionarnoj orbiti: 35,786 km)	23 222 km
Period ophoda	11 h 58 min	11 h 16 min	12 h 38 min (sateliti u geostacionarnoj orbiti stalno su vidljivi, ovisno o ograničenju vidljivosti nebeskog svoda)	14 h 5 min

Satelitske orbite su definirane na visinama koje sa stajališta korisnika stvaraju dojam relativnog gibanja satelita u odnosu na promatrača. Dojam relativnog gibanja je posljedica namjerne konstrukcije sustava kako bi se pružila optimalna pokrivenost satelitskim signalima i izbjegli dugoročni problemi s prihvatom signala u zahtjevnim okruženjima za satelitsko određivanje položaja, kao što su: urbane sredine, planinski krajolici, šume i parkovi (Sanz Subirana i suradnici, 2013). Zbog činjenice kako satelitske orbite nisu geostacionarne, broj vidljivih satelita, gledano s nepromjenjivog položaja korisnika, stalno se mijenja tijekom jednog dana (prikaz na x-osi označava dijelove unutar jednog dana) sukladno prikazano vlastitom programskom podrškom (slika 2).



Slika 2. Broj vidljivih satelita gledano s položaja korisnika tijekom jednog dana (dobiveno analizom eksperimentalnih opažanja vlastitom programskom podrškom) razvijenom u okruženju za statističko računarstvo R

Kontrolna komponenta satelitskog navigacijskog sustava ostvarena je u obliku skupa promatračkih stanica koje kontinuirano prate stanje satelitske komponente te kvalitetu određivanja položaja, brzine i vremena u različitim dijelovima svijeta (Parkinson, Spilker, Jr, 1996; Teunissen, Montenbruck, 2017). Promatračke stanice također se koriste za prosljeđivanje popravaka rada satelita te osvježavanje programske podrške (Parkinson, Spilker, Jr, 1996). Opažanja s promatračkih stanica se prikupljaju u glavnoj kontrolnoj stanici, gdje služe za procjenu stanja sustava, izdavanje odgovarajućih upozorenja korisnicima, ispravke satelitskih orbita (sateliti su opremljeni mikro-motorima za povratak u zadane orbite) te proračun parametara modela popravaka učinaka ionosfere i troposfere te pogrešaka satelitskih atomskih satova (Parkinson, Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013; Teunissen, Montenbruck, 2017). Globalni sustav za određivanje položaja (engl. Global Positioning System – GPS) omogućuje korisniku određivanje koordinata njegovog trenutnog položaja u jedinstvenom globalnom koordinatnom sustavu. Primjer prostornog rasporeda glavne kontrolne i promatračke stanice za GPS sustav prikazan je na slici 3 (Sanz Subirana i suradnici, 2013). Glavna kontrolna stanica sustava GPS nalazi se u Coloradu Springsu, CO.



Slika 3. Kontrolna komponenta sustava GPS (izvor: Sanz Subirana i suradnici, 2013)

Kontrolna komponenta GPS sustava (Sanz Subirana i suradnici, 2013) sastoji se od glavne kontrolne stanice (engl. Master Control Station – MCS), zamjenske glavne kontrolne stanice (engl. Alternate Master Control Station – AMCS) i baze dodijeljenih i zajedničkih zemaljskih antena (engl. Ground Antennas – GA). Zemaljski sustav sastoji se od namjenski nadzornih stanica koje se odnose na promatračke stanice Zračnih snaga Sjedinjenih Američkih Država (engl. Monitoring Stations from United States Air Force – MS (USAF)). Pridodan je i određeni broj zajedničkih država članica koje čine dio promatračkih stanica Nacionalne geoprostorne obavještajne agencije (NGA) Sjedinjenih Američkih Država (engl. Monitoring Stations from National Geospatial-Intellingence Agency – MS (NGA)) kako bi se povećala ukupna točnost GPS sustava za sve korisnike (slika 3).

Korisničku komponentu satelitskog navigacijskog sustava čine svi korisnici sustava opremljeni odgovarajućom opremom za provedbu postupka određivanja položaja, brzine i vremena satelitskim sustavom (Parkinson, Spilker, Jr, 1996; Teunissen, Montenbruck, 2017). Korisnička oprema općenito sadrži (Parkinson, Spilker, Jr, 1996):

1. antenu za prihvat satelitskih signala,
2. korisnički prijamnik za procesiranje signala i provedbu postupka procjene položaja te pogreške određivanja položaja,
3. dodatnu opremu kao npr. izvori napajanja, kabeli, elementi za prikaz (monitori i dr.), elementi za komunikaciju čovjeka i stroja (tipkovnica i dr.) te
4. posebnu opremu koja se povezuje ili razmjenjuje informacije s korisničkim prijamnikom (2):
    a. prijamnici dodatnih izvora informacija za korištenje pomoćnih satelitskih sustava za određivanje položaja (engl. Satellite-Based Augmentation System – SBAS, npr. EU European Geostationary Navigation Overlay Service – EGNOS (Sanz Subirana i suradnici, 2013),
    b. prijamnici ostalih pomoćnih navigacijskih sustava (engl. Loran-C, Inertial Navigation System – INS i dr.) (Parkinson, Spilker, Jr, 1996),
    c. sustavi za integriranu navigaciju (Gustafsson, 2010), komunikacijska oprema (engl. Automatic Identification System – AIS, Automatic Dependent Surveillance–Broadcast – ADS-B, javne pokretne mreže),

d. prostorni informacijski sustavi (engl. Geospatial Information Systems – GIS) i

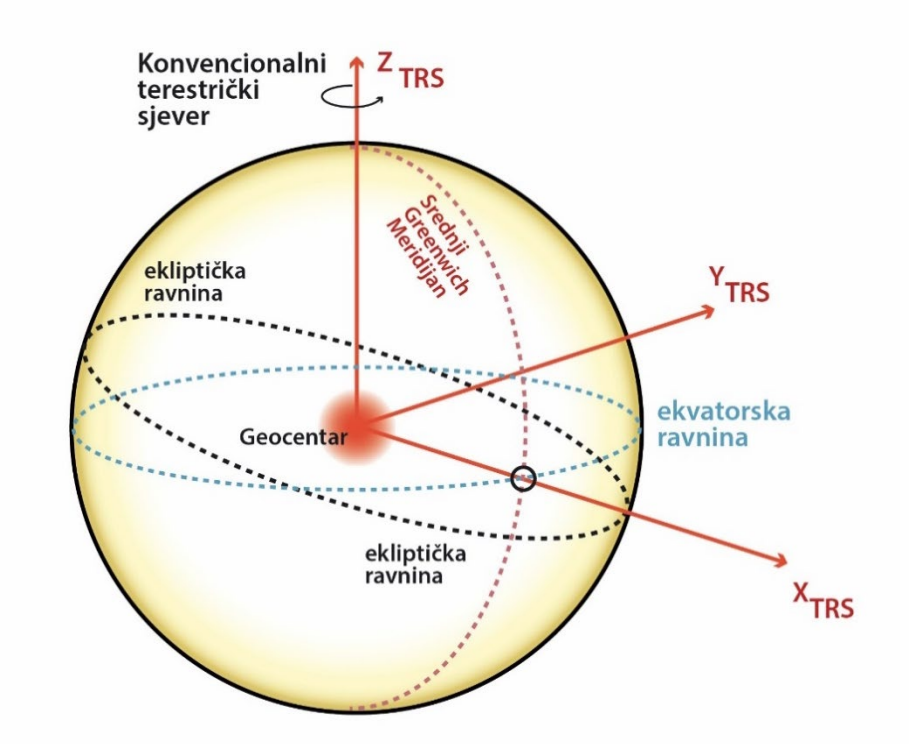
e. ostalo.

Korisnički prijamnik je središnji element svake korisničke opreme koji obavlja procesiranje signala, izdvajanje potrebnih informacija i provedbu postupka određivanja položaja (Parkisnon, Spilker, Jr, 1996.), kako je objašnjeno u potpoglavlju 2.3. Korisnički prijamnik radi s tri osnovne domene signala i informacija (Filić, Filjar, Ruotsalainen, 2016; Filić, Filjar 2018a).

Uspješna provedba postupka satelitskog određivanja položaja traži ispunjavanje triju osnovnih preduvjeta (Parkinson, Spilker, Jr, 1996):

1. korištenje jedinstvenog (zajedničkog) referentnog koordinatnog sustava, kao što je World Geodetic System 84 (WGS84) razvijen za potrebe sustava GPS (Parkinson, Spilker, Jr, 1996),
2. sorištenje jedinstvenog (zajedničkog) sustava GNSS vremena (Parkinson, Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013) te
3. ispunjenje pretpostavke o stalnoj (nepromjenjivoj) brzini propagacije satelitskog radiovala (signala) tijekom njegovog putovanja od satelitske antene do antene korisničke opreme (prijamnika za satelitsko određivanje položaja (Feynman, Lengthon, Sands, 1963).

Korištenje zajedničkog referentnog koordinatnog sustava znači kako će svi elementi sustava za satelitsko određivanje položaja izražavati na isti jedinstveni način koordinate položaja bilo koje točke u prostoru, izbjegavajući tako probleme nesuglasja zbog korištenja različitih koordinatnih sustava i potrebe za njihovim usuglašavanjem (Parkinson, Spilker, Jr, 1996; Teunissen, Montenbruck, 2017). Satelitski navigacijski sustavi koriste WGS84 zajednički koordinatni sustav (Sainz Subirana i suradnici, 2013), definiran kako je prikazano slikom 4.



Slika 4. WGS84 koordinatni sustav je sustav s ishodištem u težištu Zemlje i s kutnom brzinom identičnom kutnoj brzini Zemlje (engl. Earth-Centred-Earth-Fixed – ECEF system) (izvor: Sanz Subirana i suradnici, 2013)

U sustavu WGS84, Zemlja je aproksimirana elipsoidom čiji su parametri prikazani tablicom 2 (Sanz Subirana i suradnici, 2013).

Tablica 2. Parametri Zemlje kao elipsoida u sustavu WGS84 (izvor: Sanz Subirana i suradnici, 2013)

Elipsoid		
Sporedna os elipse	a	6 378 137,0 m
Faktor spljoštenosti	f	1/298,257223563
Kutna brzina Zemlje	ω_e	$7\,292\,115{,}0 \cdot 10^{-11}$ rad/s
Gravitacijska konstanta	M	$3\,986\,004{,}418 \cdot 10^{8}$ m^3/s^2
Brzina svjetlosti u vakuumu	c	$2{,}99792458 \cdot 10^{8}$ m/s

Sustav WGS84 je definiran tako što je njegova rotacija izjednačena s rotacijom Zemlje (Sanz Subirana i suradnici, 2013). Na taj način izbjegnuta je potreba posebnog računalnog usklađivanja i uzimanja u obzir rotacije Zemlje. Sustav WGS84 ima ishodište u središtu

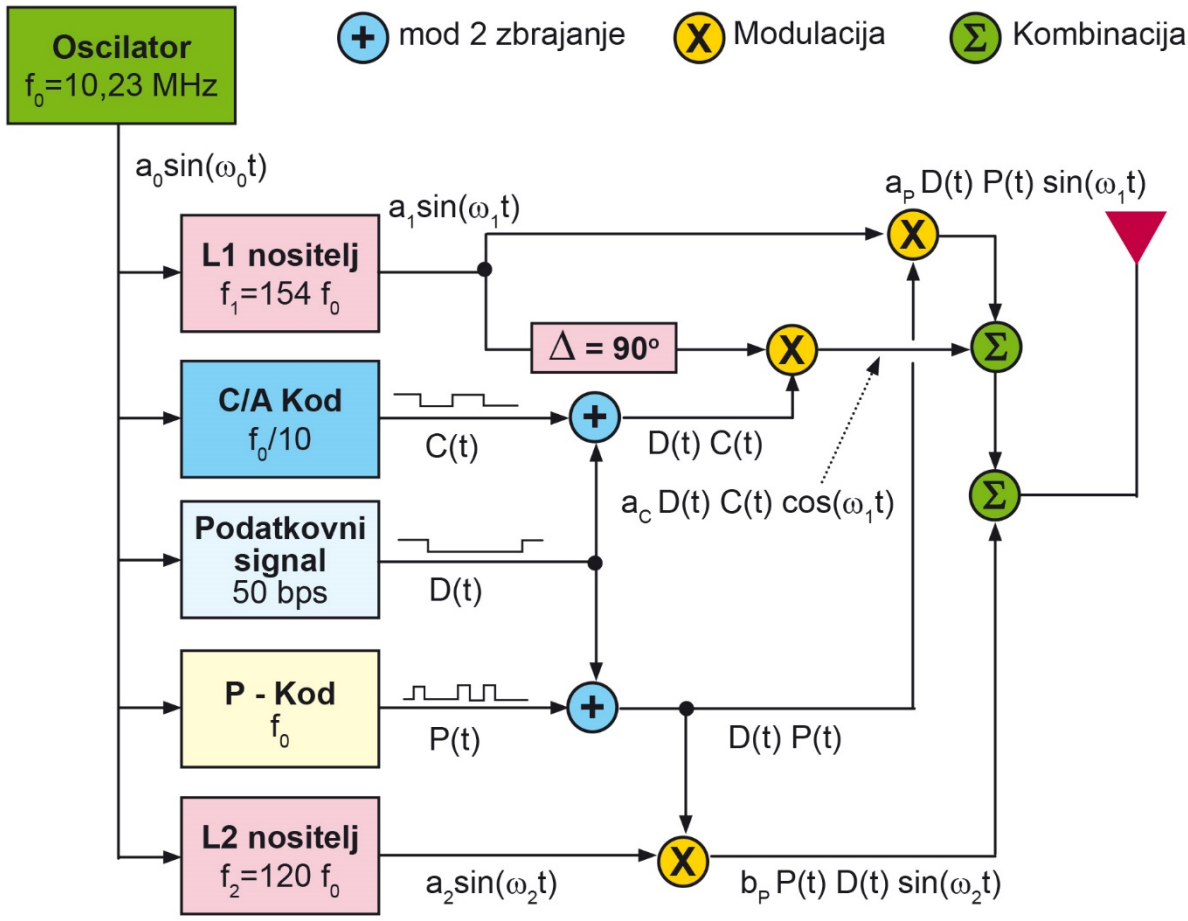
(težištu) Zemlje. Zbog navedenih razloga, sustav pripada klasi tzv. ECEF (engl. Earth-Centred, Earth-Fixed - ECEF) koordinatnih sustava (Sanz Subirana i suradnici, 2013).

Korištenje zajedničkog sustava vremena znači kako svi elementi sustava moraju biti usklađeni na zajedničko vrijeme sustava (Parkinson, Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013). Zahtjev je postavljen kako bi se omogućio postupak mjerenja vremena propagacije satelitskog signala (ekvivalentno mjerenju pseudoudaljenosti, ukoliko se satelitski signal tijekom propagacije širi istom poznatom brzinom) (Parkinson, Spilker, Jr, 1996), kako je opisano u potpoglavlju 2.3. Elementi satelitske i kontrolne komponente satelitskog navigacijskog sustava (sateliti te upravljačke i promatračke stanice) usklađeni su na zajedničko vrijeme sustava korištenjem preciznih atomskih satova s malom pogreškom za koju su poznate ispravke (Parkinson, Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013). Usklađivanje korisničkog prijamnika za satelitsko određivanje položaja sa zajedničkim vremenom sustava obavlja se istovremeno s postupkom određivanja položaja (Parkinson, Spilker, Jr, 1996), kako je objašnjeno u potpoglavlju 2.3. Kao zajedničko vrijeme satelitskih navigacijskih sustava izabrano je univerzalno koordinirano vrijeme (engl. Universal Time Co-ordinated - UTC) koje se redovito usklađuje s opaženim astronomski definiranim vremenom pomoću tzv. prijestupne sekunde (engl. Leap Second) (Sanz Subirana i suradnici, 2013; Teunissen, Montenbruck, 2017).

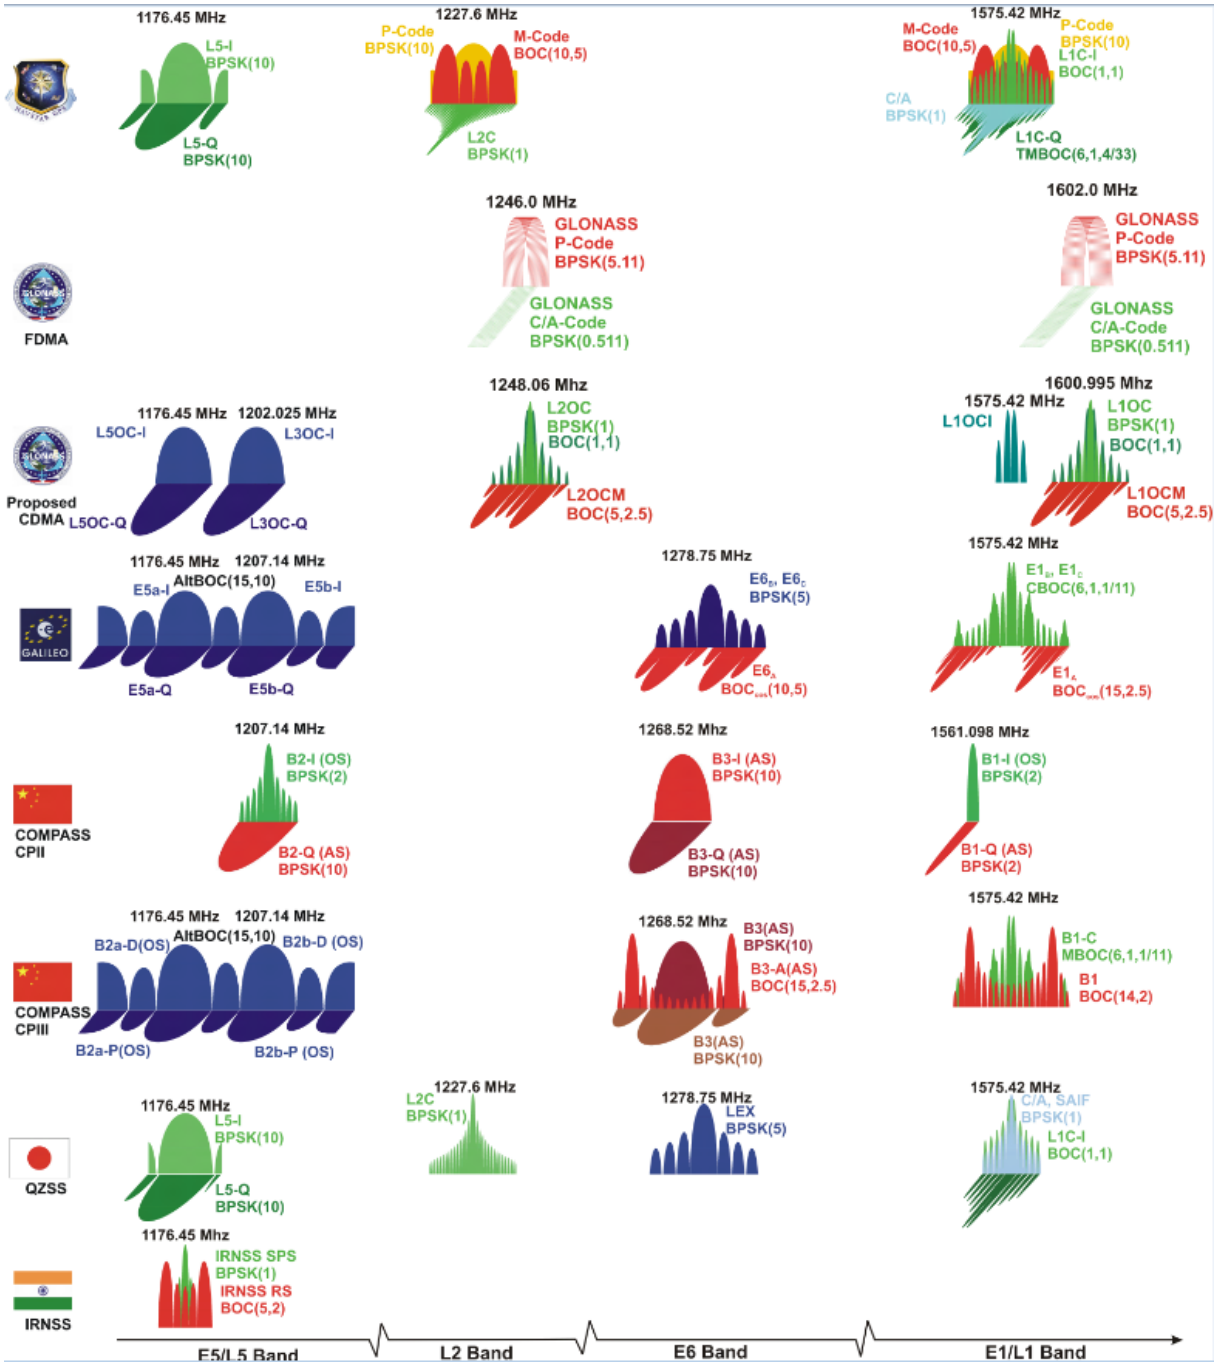
Valovi nositelji moduliraju se pomoću dva sinkronizirana PRN-koda gdje C/A kod modulira val nositelj L1. Svakom satelitu je dodijeljen jedinstven C/A kod. C/A kodovi su dostupni svim prijemnicima koji ih koriste za razlikovanje satelita i mjerenje vremena širenja signala od satelita do prijemnika. P(Y) kod modulira oba vala nositelja.

Sateliti sustava za satelitsko određivanje položaja odašilju u prostor kompozitni signal (Slika 5) koji se sastoji od nekoliko komponenata (Parkinson, Spilker, Jr, 1996: Sanz Subirana i suradnici, 2013; Filić, 2017). Dobiveni GPS signali prenose se na dvije frekvencije u L opsegu, koje se nazivaju Link 1 (L1) i Link 2 (L2), ili L1 i L2 opsezi. Sljedeće vrste (engl. Pseudo Random Noise – PRN) kodova i poruka moduliraju se preko dvaju nositelja: C / A kod, poznat još i kao civilni kod C (t). Ovaj kod moduliran je samo na L1 dok C/A kod definira standardnu uslugu određivanja položaja (engl. Standard Positioning Service - SPS). Precizni kod, P (t) je rezerviran za vojnu upotrebu i ovlaštene civilne korisnike (Sanz Subirana i suradnici, 2013). Slijed se ponavlja svakih 266 dana i tjedni dio ovog koda dodjeljuje se svakom satelitu koji se naziva PRN slijed te je moduliran preko oba nositelja L1 i L2. Ovaj kod definira uslugu preciznog pozicioniranja (engl. Precise Positioning Service - PPS) dok je navigacijska poruka, D (t), modulirana na oba nositelja te između svih ostalih informacija izvještava i o zanosima

efemerida i satelitskog sata (Parkinson, Spilker, Jr, 1996: Sanz Subirana i suradnici, 2013) kako je prikazano slikom 5.



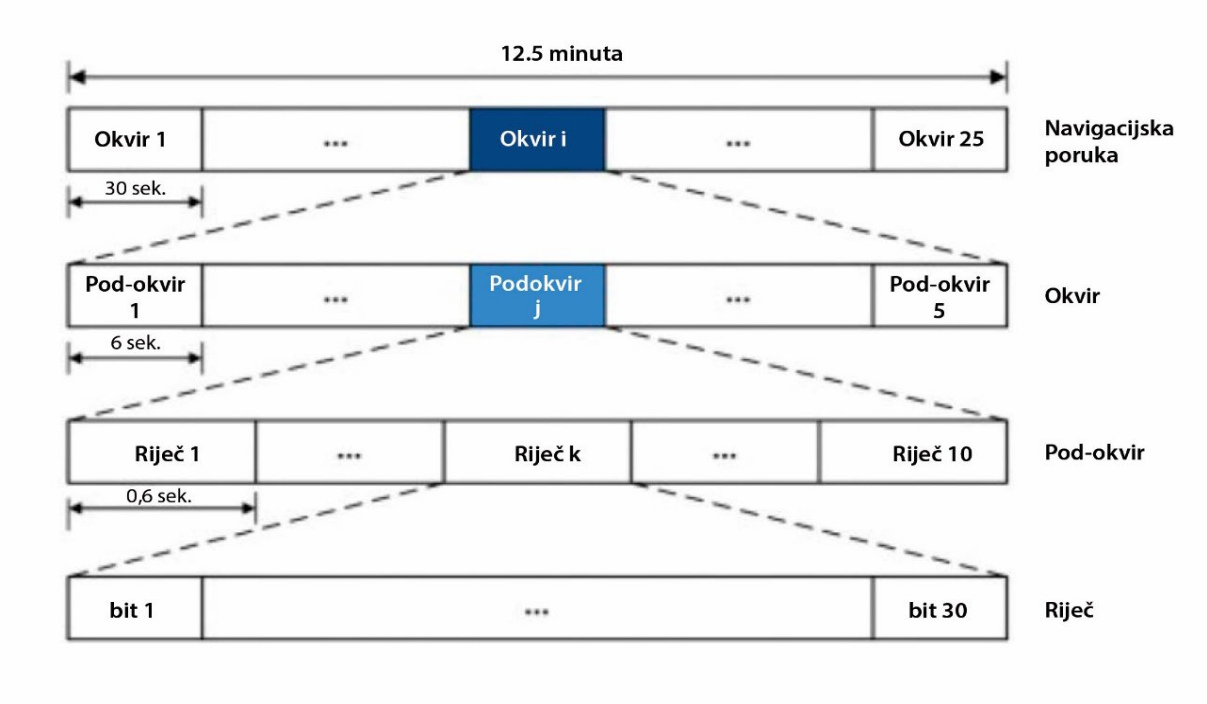
Slika 5. Komponente kompozitnog satelitskog signala na primjeru sustava GPS (izvor: Sanz Subirana i suradnici, 2013)



Slika 6. Spektralna slika signala za satelitsko određivanje položaja različitih satelitskih navigacijskih sustava (kineski sustav Beidou prikazan je ovdje kao Compass) (izvor: Geospatial Web, 2018)

Val nositelj je visokofrekventni signal koji osigurava doseg satelitskih signala relativno malih snaga (svega približno 9 W) do korisnika uz korištenje frekvencijskog područja iznad 1 GHz (mikrovalovi koji se šire izravnim, pravocrtnim valom) (Parkinson, Spilker, Jr, 1996; Davies, 1990; Sanz Subirana i suradnici, 2013), kako je za razne satelitske navigacijske sustave prikazano slikom 6.

Navigacijska poruka sadrži točne i približne parametre orbita satelita (satelitske efemeride i almanah) potrebne za precizno određivanje položaja satelita u trenutku odašiljanja satelitskog signala s kodnom sekvencom za određivanje položaja (Parkinson, Spilker, Jr, 1996). Navigacijska poruka se šalje u obliku binarnih okvira trajanja 30 s brzinom prijenosa 50 bita/s. Okvirna struktura navigacijske poruke sustava GPS prikazana je na slici 7 (Parkinson, Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013).



Slika 7. Struktura navigacijske poruke sustava GPS (izvor: Sanz Subirana i suradnici, 2013)

U primjeru sustava GPS, niz kodnih sekvenci odašilje se sa satelita za potrebe mjerenja pseudoudaljenosti. Sastoji se od PRN koda za C/A, PRN koda za P i vala nosioca. P (engl. Precise) kodne sekvence namijenjene su posebnim, autoriziranim korisnicima. Širokopristupne C/A (engl. Coarse Acquisition) kodne sekvence namijenjene su svim korisnicima. Svaki satelit ima svoje jedinstvene P i C/A kodne sekvence što omogućuje raspoznavanje satelita koji je sekvencu odaslao. Kodne sekvence su binarne sekvence (nizovi nula i jedinica) generirane pseudo-slučajnim postupkom (engl. Pseudo-Random Number - PRN) (Goldov kod) (Parkinson, Spilker, Jr, 1996). P i C/A sekvence razlikuju se po svojim obilježjima, usporedba koja je predstavljena tablicom 3 za satelitski sustav za određivanje položaja GPS (Parkinson, Spilker, Jr, 1996).

Tablica 3. Usporedba obilježja PRN kodnih sekvenca

Parametar	**P-kod**	**C/A kod**
Frekvencija bitova sekvence	1,023 MHz	1,023 MHz
Valna duljina koda	29,31 m	293,1 m
Razdoblje ponavljanja kodne sekvence	266 dana, 7 dana po satelitu	1 ms

Prijamnik za satelitsko određivanje položaja mora poznavati sve kodne sekvence satelita sustava za koje je omogućen kako bi mogao provesti postupak mjerenja vremena propagacije, odnosno ekvivalentnih pseudoudaljenosti. U istom trenutku kad i sateliti, prijamnik generira iste kodne sekvence svih satelita sustava za koje je prijamnik konstruiran. I sateliti i prijamnici trebaju započeti s generiranjem kodnih sekvenci u istom trenutku, prethodno određenim načinom rada samog sustava. Zato je važna potpuna usklađenost na zajednički vremenski sustav. Satelitske kodne sekvence za mjerenje pseudoudaljenosti doći će u prijamnik s faznim pomakom koji odgovara vremenskom kašnjenju proporcionalnom prijeđenom putu između satelitske i prijamne antene. Usporedbom primljene satelitske kodne sekvence i lokalno generirane kodne sekvence mjeri se fazna razlika, a time i vrijeme propagacije satelitskog signala (Parkinson, Spilker, Jr, 1996). Uobičajeni postupak mjerenja zasniva se na primjeni metode unakrsne korelacije (Parkinson, Spilker, Jr, 1996) kako je objašnjeno u potpoglavlju 2.3.

Ispunjavanje pretpostavke o stalnoj (nepromjenjivoj) brzini propagacije satelitskog signala omogućuje transformaciju varijabli vezanih za postupak određivanja položaja koja preslikava područja vrijednosti u računalno optimalnu domenu (Filić, 2017; Filić, Grubišić, Filjar 2017). Naime, vrijeme propagacije satelitskih signala vrlo je kratko, budući da se satelitski signal širi kao elektromagnetski (radio) val (Davies, 1990; Strang, Borre, 1997). Računalni uređaji, uključivo GNSS prijamnici traže nepotrebno robusno računalno okruženje za procesiranje vremena propagacije koji se mjere desecima nanosekunda. Korištenjem ekvivalentnih pseudoudaljenosti, varijable poprimaju numeričke vrijednosti preslikane u područja s kojima računala barataju bez potrebe za snažnim procesorima, dugačkim registrima i velikim memorijama. Dakle, područja vrijednosti preslikana su u računalno optimalnu domenu.

Ovisno o fizikalnim obilježjima sredstva, brzina širenja radiovala ima različite vrijednosti (Davies, 1990; Strang, Borre, 1997). Brzina širenja radiovala određena je električnim i magnetskim obilježjima sredstva u kojem se radioval širi, izraženim pomoću električne

permitivnosti ϵ i magnetske permeabilnosti μ, kako je pokazao J. C. Maxwell (Feynman, Leighton, Sands, 1963; Davies, 1990) izrazom (1).

$$v_{EM} = \frac{1}{\sqrt{\epsilon \cdot \mu}} \frac{1}{\sqrt{\epsilon \cdot \mu}} \tag{1}$$

Električna permitivnost sredstva ϵ može se prikazati izrazom (2), (Feynman, Leighton, Sands, 1963; Davies, 1990).

$$\epsilon = \epsilon_{\mathrm{r}} \cdot \epsilon_0 \tag{2}$$

gdje su:

ϵ_r ... *relativna električna permitivnost prostora u odnosu na apsolutnu električnu permitivnost vakuuma,*

ϵ_0 ... *apsolutna električna permitivnost vakuuma, koja iznosi* $\epsilon_0 = 8{,}854\ x\ 10^{-12}\ [F/m]$

Magnetska permeabilnost prostora μ može se prikazati izrazom (3), (Feynman, Leighton, Sands, 1963; Davies, 1990).

$$\mu = \mu_r \cdot \mu_0 \tag{3}$$

gdje su:

μ_r ... *relativna magnetska permeabilnost prostora u odnosu na apsolutnu magnetsku permeabilnost vakuuma,*

μ_0 ... *apsolutna magnetska permeabilnost vakuuma, koja iznosi* $\mu_0 = 4\pi\ x\ 10^{-7}\ [H/m]$

Kako u vakuumu vrijedi $\epsilon_r = 1$ i $\mu_r = 1$ brzina širenja radiovala u vakuumu *c* dobiva se kao najveća brzina kojom radioval može propagirati (Feynman, Leighton, Sands, 1963; Davies, 1990), prema izrazu (4).

$$c = v_{vakuum} = \frac{1}{\sqrt{\epsilon \cdot \mu}} = \frac{1}{\sqrt{\epsilon_0 \cdot \mu_0}} = 2{,}99792458 \cdot 10^8 [m \cdot s^{-1}] \tag{4}$$

Navedena vrijednost brzine propagacije radiovala je standard koji se koristi za potrebe satelitskog određivanja položaja.

Ukoliko radioval propagira u jednom mediju (u ovom slučaju u slobodnom prostoru) s jednom faznom brzinom te prilikom upada na granicu s drugim medijem (u ovom slučaju troposferu) fazna brzina u tom mediju se mijenja ovisno o fizikalnim svojstvima tog medija. U slučaju

satelitskog radiovala, na granici zrakopraznog prostora i atmosferskog sloja doći se do refrakcije satelitskog radiovala gdje će on i dalje propagirati brzinom svjetlosti u vakuumu c, ali unutar troposfere neće, već manjom brzinom, određenom fizikalnim obilježjima atmosferskog sloja (slika 8) (Feynman, Leighton, Sands, 1963; Davies, 1990). Snellov zakon refrakcije (loma) predstavlja mjeru opisane pojave. Snellov zakon refrakcije definiran je izrazom (5).

$$\frac{sin\Theta_1}{sin\Theta_2} = \frac{v_1}{v_2} = \frac{n_1}{n_2} \tag{5}$$

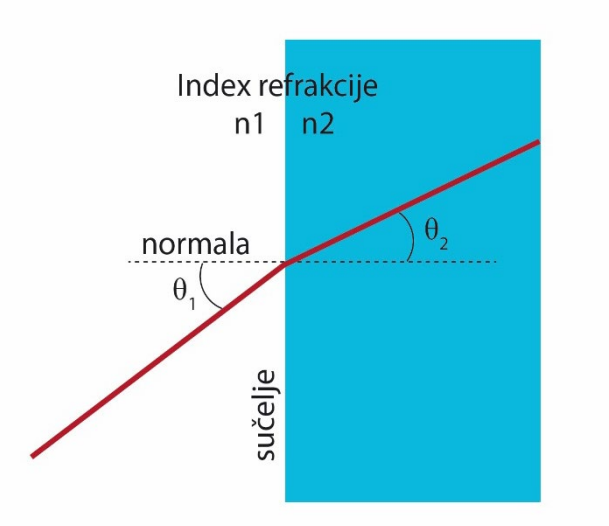
gdje su:

Θ_1… kut upadne zrake svjetlosti

Θ_2… kut loma

v_1, v_2…brzine vala

n_1, n_2…indeksi loma



Slika 8. Refrakcija radiovala

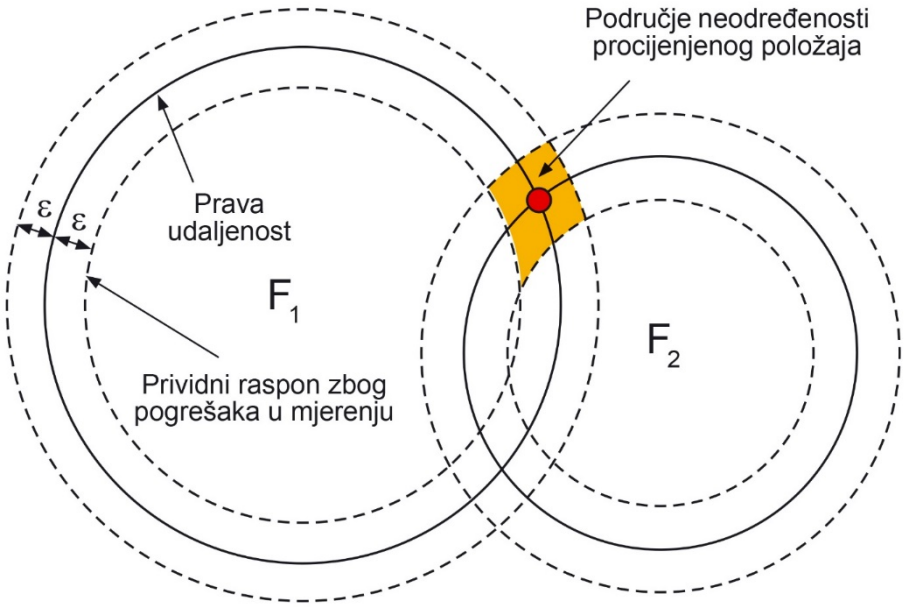
Uslijed nehomogenosti Zemljine atmosfere i neujednačenih fizikalnih obilježja pojedinih susjednih slojeva, satelitski signal na svom putu nailazi na potencijalne uzroke refrakcije u ionosferi i troposferi (Davies, 1990; Strang, Borre, 1997). Iako približno 90 % svog puta satelitski signal prolazi zrakopraznim prostorom gdje je treći preduvjet operativnosti

satelitskog određivanja položaja ispunjen, preostalih 10 % prostora izaziva najznačajnije pogreške u procjeni položaja satelitskim sustavom (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997).

Izmjereno vrijeme propagacije množeno s brzinom širenja radiovala u vakuumu daje pseudoudaljenost, s mjernom jedinicom udaljenosti (Parkisnon, Spilker, Jr, 1996; Strang, Borre, 1997). Pseudoudaljenost je u promatranom trenutku izmjerena udaljenost između satelitske antene i antene korisničkog prijamnika za satelitsko određivanje položaja (Sanz Subirana i suradnici, 2013). Kako je nastala postupkom mjerenja, pseudoudaljenost u sebi sadrži i učinke utjecajnih veličina kao pogreške mjerenja te se razlikuje od stvarne (prave) udaljenosti između dviju antena (Strang, Borre, 1997).

U postupku satelitske navigacije određuju se tri nepoznate koordinate položaja korisničke antene te nepoznata pogreška korisničkog sata koji jedini nije usklađen sa zajedničkim vremenom sustava (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997; Filić, 2017; Filić, Grubišić, Filjar 2017). Na taj način je definiran vektor stanja korisnika $\vec{x} = (x_u, y_u, z_u, b_u)$, elementi kojeg se određuju satelitskim određivanjem položaja, uz korištenje barem četiriju istovremeno izmjerenih pseudoudaljenosti s različitih satelita te uz poznate koordinate navedenih satelita u trenutku odašiljanja satelitskih signala (pomoću satelitskih efemerida) (Strang, Borre, 1997; Filić, 2017; Filić, Filjar 2018a; Sanz Subirana i suradnici, 2013).

Svaka izmjerena pseudoudaljenost definira oko satelita kuglu radijusa jednakog izmjerenoj pseudoudaljenosti, kao potencijalno mjesto položaja korisničke antene te se istovremenim mjerenjem pseudoudaljenosti definiraju barem četiri kugle s jedinstvenim presjecištem, u idealnom slučaju (Sanz Subirana i suradnici, 2013). U stvarnosti, uslijed djelovanja utjecajnih veličina, pseudoudaljenosti će biti opterećene pogreškama pa kugle neće imati dobro definirano presjecište već će dati prostor neodređenosti u kojem će se s naznačenom vjerojatnosti nalaziti pravi položaj (slika 9) (Parkinson, Spilker, Jr, 1996).



Slika 9. Područje neodređenosti procijenjenog položaja satelitskim sustavom

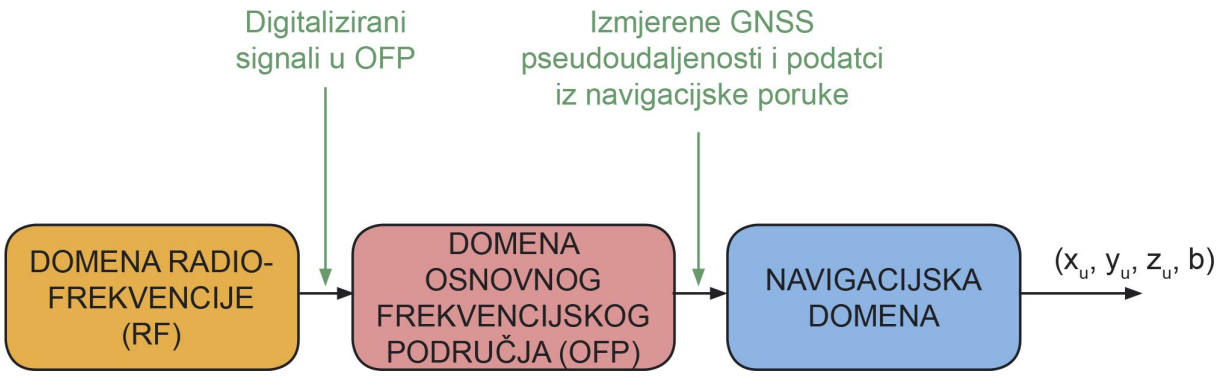
Satelitsko određivanje položaja omogućilo je kvalitetu određivanja položaja na globalnoj razini nedostižnu bilo kojim drugim sustavom određivanja položaja (Parkinson, Spilker, Jr, 1996).

Konkurentni globalni sustavi za određivanje položaja ne omogućuju postizanje točnosti ni približne onoj dobivenoj satelitskim navigacijskim sustavom. Razlozi ovise o izvornom konceptu svakog konkurentnog globalnog sustava za određivanje položaja.

Međutim, prevladavanje uzroka privremenih ispada satelitskog navigacijskog sustava ili privremenih smanjenja točnosti određivanja položaja traže dodatne istraživačke i operativne napore, kako bi se omogućio održivi razvoj zasnovan na sustavu koji je već postao dio nacionalne infrastrukture (Thomas i suradnici, 2011).

2.2. Arhitektura satelitskog navigacijskog prijamnika

Opis arhitekture satelitskog navigacijskog prijamnika pomoću triju osnovnih domena (slika 10) objašnjava njegove funkcionalnosti u postupku određivanja rješenja navigacijskog problema (određivanje vektora stanja korisnika: triju komponenata položaja i pogreške korisničkog sata (Parkinson, Spilker, Jr, 1996). Određivanje brzine gibanja ostvaruje se neovisnim postupkom, zasnovanim na korištenju Dopplerovog učinka) (Sanz Subirana i suradnici, 2013).



Slika 10. Tri osnovne radne domene satelitskog navigacijskog prijamnika

Domena radio-frekvencije obuhvaća postupke procesiranja moduliranih satelitskih signala (Parkinson, Spilker, Jr, 1996; Filić, Filjar 2018a), poput:

1. osnovnog pojačavanja primljenog kompozitnog satelitskog signala,
2. poboljšanja odnosa signal-šum,
3. izdvajanja spektralnih komponenata smetnje i šuma te
4. demodulacije kompozitnog satelitskog signala uz analogno-digitalnu pretvorbu.

Domena osnovnog frekvencijskog područja (OFP) (Parkinson, Spilker, Jr, 1996; Filić, Filjar 2018a) obuhvaća postupke:

1. lokalnog generiranja PRN sekvenci za mjerenje pseudoudaljenosti,
2. vremenskog usklađivanja prijamnika s primljenim satelitskim signalom,
3. prihvata i razdvajanja PRN kodnih sekvenci za mjerenje pseudoudaljenosti i navigacijske poruke,
4. prihvata i slijeđenja PRN kodnih sekvenci,
5. mjerenja pseudoudaljenosti primjenom postupka unakrsne korelacije na odgovarajuće PRN kodne sekvence primljene sa satelita i generirane lokalno (potpoglavlje 2.3) te
6. Izdvajanja elemenata navigacijske poruke (satelitskih efemerida, statusnih zastavica valjanosti satelitskih signala te parametara modela popravaka ionosferskog i troposferskog kašnjenja te pogreške satelitskog sata). Statusna zastavica valjanosti satelitskih signala (engl. Signal Health) predstavlja oznaku definiranu kontrolnom komponentom koja pruža informaciju o trenutnoj primjenjivosti satelitskih PRN signala u postupku procjene položaja (Parkinson i Spilker, Jr, 1996).

Navigacijska domena (Sanz Subirana i suradnici, 2013; Filić, 2017; Filić, Filjar, 2018a; Filić, Filjar, 2018b) obuhvaća postupke:

1. popravaka učinaka ionosferskog i troposferskog kašnjenja na izvorno izmjerene (nepopravljene, sirove) GNSS pseudoudaljenosti na ionosfersko i troposfersko kašnjenje te pogreške satelitskih satova (slika 11),
2. izračuna položaja satelita u trenucima odašiljanja satelitskih kompozitnih signala temeljem satelitskih efemerida,
3. mjerenja brzine gibanja u trenutku uzimanja pseudoudaljenosti,
4. određivanja (procjenu, estimaciju) položaja i pogreške procjene položaja temeljem izmjerenih i popravljenih pseudoudaljenosti (potpoglavlje 2.3) te
5. pripreme izlaznih podataka i predstavljanje rezultata procjene položaja i procjene pogreške položaja korisniku ili uslugama zasnovanim na korištenju satelitskog određivanja položaja.



Slika 11. Model popravka izvornih (nepopravljenih) izmjerenih GNSS pseudoudaljenosti u navigacijskoj domeni GNSS prijamnika za satelitsku navigaciju

Izvorni rezultat procjene položaja, brzine i vremena naziva se jednostruko rješenje navigacijskog problema ili pojedinačna procjena položaja (engl. Single Point Solution – SPS) ili pojedinačna procjena vektora stanja korisnika (Parkinson, Spilker, Jr, 1996; Filić, 2017; Strang, Borre, 1997). GNSS prijamnici uobičajeno ne predstavljaju SPS, već nizove procjena položaja i točnog vremena, koriste za dodatno poboljšavanje kvalitete određivanja položaja uklanjanjem ili barem ublažavanjem učinaka preostalih pogrešaka. Uobičajeni postupak nalaže filtriranje vremenskih nizova procijenjenih položaja Kalmanovim filtrom, čime se uklanjaju

preostale sistemske pogreške određivanja položaja opisane Gaussovom (normalnom) statističkom razdiobom (Parkinson, Spilker, Jr, 1996).

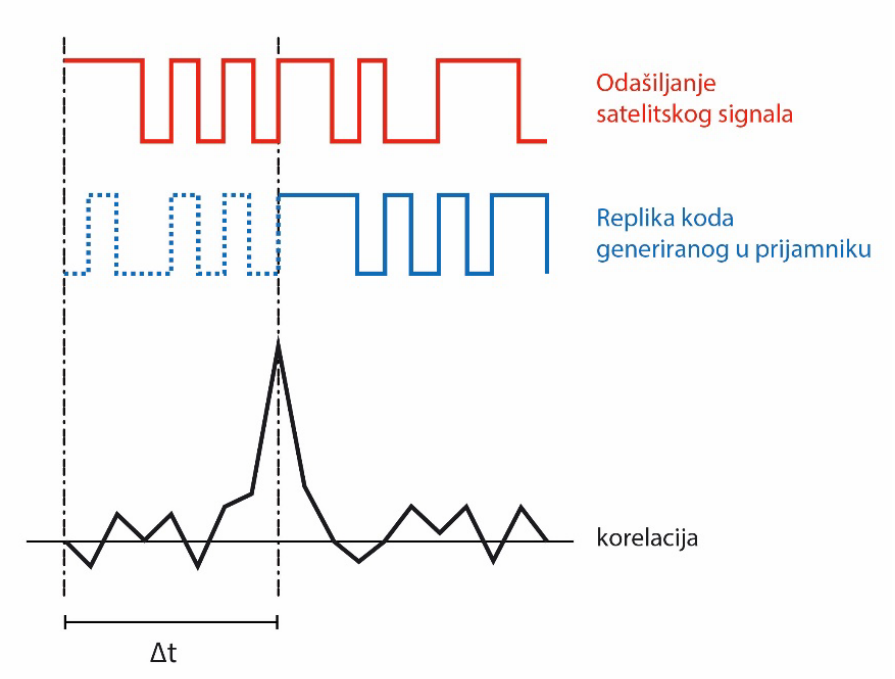
Procjene položaja i kvalitete određivanja položaja predstavljaju podatke koji se mogu iskoristiti za potrebe naprednog određivanja položaja putem integracije s izlazima drugih postupaka i sustava za određivanja položaja (Filjar, Ježić, Matijašević, 2008; Filjar, Huljenić, 2012; Filjar, Huljenić, Lenac, 2013; Filić, Filjar, 2018a; Filić, Filjar, 2018b), kao što su: inercijski navigacijski sustavi, javne pokretne mreže, Loran ili radar. Isti izlazni GNSS podaci mogu biti integrirani u različite sustave koji pružaju usluge zasnovane na lokaciji, kao što su: 112 pozivi u javnoj pokretnoj mreži u slučaju opasnosti, automatski sustav za identifikaciju plovila (engl. Automatic Identification System – AIS), automatski sustav za identifikaciju zrakoplova (engl. Automatic Dependent Surveillance – Broadcast – ADS-B) i drugo (Young, 2017; Filić, Filjar, 2018b). Za potrebe razmjene izlaznih podataka iz GNSS prijamnika s drugim računalnim sustavima, razvijeni su standardizirani žični i bežični postupci prijenosa podataka koji obuhvaćaju korištenje posebnih protokola za razmjenu podataka kao što je NMEA-0183. Završne procjene, ali i međurezultati GNSS postupka određivanja položaja mogu se pohraniti za potrebe znanstvenih istraživanja ili industrijskog razvoja uz korištenje standardiziranih postupaka i oblikovanja zapisa kao što je u prijamniku neovisni format za razmjenu (engl. Receiver INdependent EXchange format – RINEX) (IGS, 2018).

Primjena programski određenih (engl. Software-Defined Radio – SDR) GNSS prijamnika omogućuje postavljanje modela procjene položaja satelitskim sustavom zasnovanim na mjerenim pseudoudaljenostima i postojećem okruženju za određivanje položaja, primjerenog konkretnoj aplikaciji satelitskog navigacijskog sustava i njenim zahtjevima za kvalitetu određivanja položaja (Filić, 2017). Podešavanje postupaka procjene položaja satelitskim sustavom i razvoj pripadnih postupaka popravaka pogrešaka ostaje važiti kao područje budućih istraživanja (Filić, 2017; Filić, Filjar, 2018a).

2.3. Postupak određivanja položaja satelitskim navigacijskim sustavom

Postupak određivanja položaja satelitskim sustavom uključuje istovremeno mjerenje GNSS pseudoudaljenosti od barem četiriju vidljivih satelita, ispravljanje mjerenih pseudoudaljenosti od sistemskih pogrešaka (ionosfersko kašnjenje, troposfersko kašnjenje i pogreška satelitskog sata), procjenu položaja zasnovanu na matematičkoj metodi razvijenoj kao rješenje optimizacijskog problema i uz korištenje izmjerenih i popravljenih pseudoudaljenosti te procjenu točnosti rezultata procjene položaja (Parkinson, Spilker, Jr, 1996).

Postupak mjerenja pseudoudaljenosti zasniva se na mjerenju fazne razlike između lokalno generirane PRN sekvence i primljenog satelitskog signala, za isti satelit, postupkom unakrsne korelacije te izračunava vrijednost koeficijenta unakrsne korelacije (Parkinson, Spilker, Jr, 1996). Navedeni postupak je iteracijske prirode (Sanz Subirana i suradnici, 2013). Unakrsna korelacija primjenjuje se na PRN kodne sekvence. Međutim, mjerenje fazne razlike još se rafinira proširenjem postupka koji uključuje i provjeru valnog oblika navigacijske poruke u domeni osnovnog frekvencijskog područja te vremensku sinkronizaciju SDR prijamnika pomoću vala nosioca. Detalji izlaze iz područja razmatranja ove disertacije. Valni oblik primljene PRN kodne sekvence drži se stalnim, dok se valni oblik lokalno generirane PRN kodne sekvence pomiče u vremenskim koracima koji određuju rezoluciju mjerenja pseudoudaljenosti (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997). U slučaju dobivanja koeficijenta unakrsne korelacije jednakog jedinici, postignuto je savršeno poklapanje valnih oblika (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997). Tada se prebroji broj pomaka lokalne PRN sekvence i pomnoži s vrijednošću vremenskog pomaka svakog koraka, čime se dobiva vremenski pomak jednak vremenu propagacije satelitskog signala od satelitske antene do antene korisničkog prijamnika (slika 12) (Parkinson, Spilker, Jr, 1996).



Slika 12. Mjerenje GNSS pseudoudaljenosti postupkom unakrsne korelacije (izvor: Sanz Subirana i suradnici, 2013)

Izmjerene pseudoudaljenosti popravljaju se prikladnim modelima popravaka za poznate uzroke pogrešaka mjerenja (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997; Sanz Subirana i suradnici, 2013; Teunisson, Montenbruck, 2017; Filić, 2017; Filić, Filjar 2018a). Satelitski navigacijski sustavi omogućavaju popravak učinaka utjecajnih veličina putem standardnih modela popravaka (slika 12) (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997; Sanz Subirana i suradnici, 2013; Teunisson, Montenbruck, 2017):

1. učinaka ionosferskog kašnjenja (sustav Galileo koristi tzv. NeQuick prognostički model popravaka, sustavi GPS i Beidou koriste tzv. Klobucharov model, a sustav GLONASS po svojoj naravi odmah popravlja navedene učinke) (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997; Sanz Subirana i suradnici, 2013; Teunisson, Montenbruck, 2017),
2. učinaka troposferskog kašnjenja (modeli popravaka bit će detaljnije razmotreni u potpoglavlju 2.4) (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997; Sanz Subirana i suradnici, 2013; Teunisson, Montenbruck, 2017) te
3. pogrešaka satelitskih satova (svaki satelit ima svoj model popravaka svog atomskog sata) (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997; Sanz Subirana i suradnici, 2013; Teunisson, Montenbruck, 2017).

Satelitske efemeride iz navigacijske poruke koriste se za preciznu procjenu položaja satelita u trenutku odašiljanja satelitskog signala (satelit i prijamnik u istom trenutku započinju generiranje PRN kodne sekvence) (Parkinson, Spilker, Jr, 1996). Procijenjeni položaji satelita, zajedno s izmjerenim ispravljenim pseudoudaljenostima, predstavljaju ulazne veličine postupka procjene položaja satelitskim sustavom (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997; Sanz Subirana i suradnici, 2013; Teunisson, Montenbruck, 2017; Filić, 2017; Filić, Filjar, 2018a).

Matematički gledano, problem procjene položaja može se promatrati kao problem kontinuirane optimizacije (Boyd, Vandenberghe, 2004) vezan za vektor stanja korisnika, prema izrazu (6),

$$\vec{x} = (x_u, y_u, z_u, b)^\tau \tag{6}$$

gdje je:

$\vec{x}$ ... *vektor stanja korisnika, određen koordinatama položaja korisnika u referentnom koordinatnom sustavu,* x_u, y_u *i* z_u *te pogreškom njegovog korisničkog sata b (četiri*

nepoznanice koje određuju stanje GNSS korisnika u promatranom trenutku vremena) kao prema izrazu (7):

$$\vec{\rho} = h(\vec{x}) + \vec{v} \tag{7}$$

gdje su:

$\vec{\rho}$… vektor izmjerenih i popravljenih pseudoudaljenosti

h … *funkcija transformacije vektora stanja korisnika u vektor izmjerenih i popravljenih pseudoudaljenosti,*

$\vec{v}$ … vektor pogrešaka (slučajna varijabla) (Filić, 2017).

Rješenje optimizacijskog problema je argument koji minimizira ciljnu funkciju (8) (Filić, 2017), uz uvjete optimizacije zadane činjenicom kako se položaj korisnika nalazi na ili u blizini površine Zemlje (Parkinson i Spilker, Jr, 1996), (Strang, and Borre, 1997), (Filić, 2017).

$$\vec{x}_c := arg\min_{\vec{x}} \; p(\vec{x})^{\tau}(\vec{x})^{\tau}p(\vec{x}) \tag{8}$$

Uz oznaku prema izrazu (9),

$$J := p'(\vec{x}) = h'(\vec{x}) \tag{9}$$

Izraz (8) prelazi u (10) (Filić, 2017). Simbol τ korišten je u cijelom tekstu u oznaci transpozicije matrice.

$$\vec{x} := arg\min_{\vec{x}} \; p(\vec{x})^{\tau}p(\vec{x}) = arg\min_{\vec{x}}\left(J \cdot \Delta\vec{x} + p(\vec{x})\right) \tag{10}$$

Rješenje optimizacijskog problema (10) je (11) (Gustafsson, 2010; Filić, 2017).

$$\vec{x}_{k+1} = \vec{x}_k - (J_k^{\tau}J_k)^{-1}J_k^{\tau}p(\vec{x}_k) \tag{11}$$

Postupak daje pojedinačnu procjenu vektora stanja korisnika *(x_u, y_u, z_u, b)* (Filić, 2017). Rješenje optimizacijskog problema (11) može se razviti u algoritam procjene položaja satelitskim sustavom (Filić, 2017), kako je prikazano u nastavku.

Vremenska skala na strani satelitskog navigacijskog prijamnika pomaknuta je za iznos pogreške korisničkog sata *b*. Za toliko je uvećano mjereno vrijeme (12), kako ga mjeri prijamnik, t_m, u odnosu na pravo vrijeme sustava *t* (Sanz Subirana i suradnici, 2013; Filić, 2017).

$$t_m = t + b \tag{12}$$

Uslijed pogreške korisničkog sata, prijamnik mjeri pseudoudaljenost prema izrazu (13),

$$\rho = t_m \cdot c = (t + b) \cdot c \tag{13}$$

gdje su:

ρ ... izmjerena pseudoudaljenost,
c ... brzina propagacije satelitskog signala (brzina svjetlosti u vakuumu) (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997).

Izraz (13) može se zapisati kao (14), uz uvođenje stvarne udaljenosti između satelitske i korisničke antene R (Sanz Subirana i suradnici, 2013; Filić, 2017).

$$\rho = R + b \cdot c \tag{14}$$

U konkretnom pojedinačnom slučaju, stvarna udaljenost između satelitske antene i-tog satelita i korisničke antene R_i može se prikazati pomoću komponenata vektora položaja i-tog satelita (x_{si}, y_{si}, z_{si}) (poznato) i vektora položaja korisnika (x_k, y_k, z_k) (15) (Sanz Subirana i suradnici, 2013).

$$R_i = \sqrt{(x_{si} - x_k)^2 + (y_{si} - y_k)^2 + (z_{si} - z_k)^2} \tag{15}$$

Izmjerena i popravljena pseudoudaljenost između satelitske antene i-tog satelita i korisničke antene može se prikazati na isti način izrazom (16), gdje je:

$$\rho = \sqrt{(x_{si} - x_k)^2 + (y_{si} - y_k)^2 + (z_{si} - z_k)^2} + b \cdot c \tag{16}$$

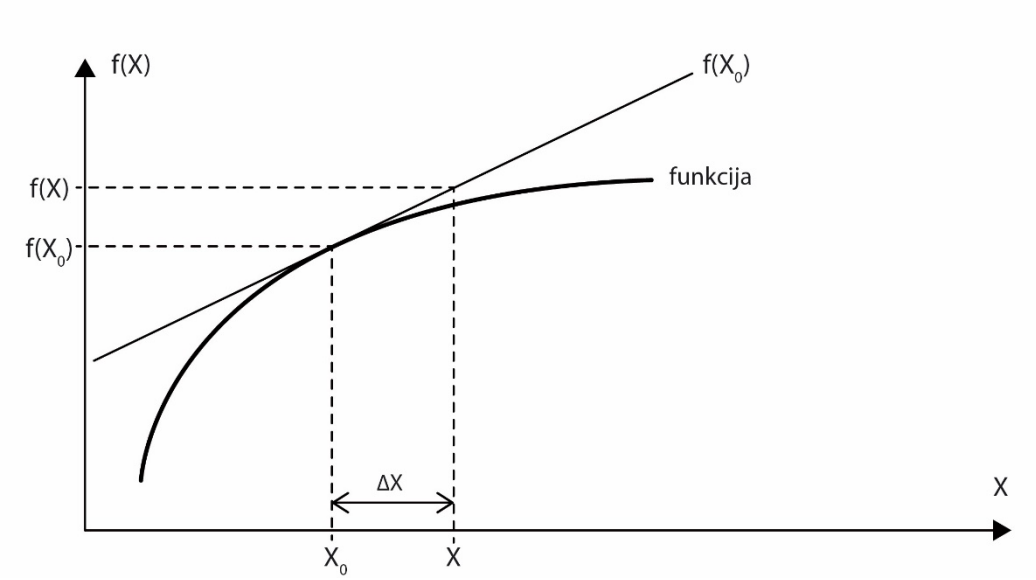
gdje su:

b ... pogreška korisničkog sata (neovisna o satelitu)
c ... brzina propagacije satelitskog signala (Sanz Subirana i suradnici, 2013).

Izraz (16) predstavlja matematički model za procjenu položaja satelitskim sustavima (Parkinson, Spilker, Jr, 1996). Modelom su povezane nepoznanice (nepoznata pogreška

korisničkog sata i nepoznate koordinate položaja korisnika), poznate veličine (položaj satelita u trenutku odašiljanja satelitskog signala) te mjerene veličine (izmjerene i ispravljene pseudoudaljenosti). Izraz (16) povezuje konkretan slučaj mjerenja pseudoudaljenosti vezan za jedan konkretni satelit. Istovremenim mjerenjem *N* pseudoudaljenosti dobiva se N izraza oblika (16) s istim nepoznanicama koji tvore sustav *N* jednadžbi s četiri nepoznanice (Parkinson, Spilker, Jr, 1996). Sustav je potpuno određen za N=4 pa većina komercijalnih prijamnika prethodno izabire četiri satelita koji svojim položajima stvaraju najmanju tzv. geometrijsku degradaciju točnosti te pomoću njihovih pseudoudaljenosti rješava problem procjene položaja (Parkinson, Spilker, Jr, 1996; Filić, 2017). Model (16) je nelinearna funkcija koju je potrebno linearizirati radi postizanja numeričkog rješenja (Parkinson, Spilker, Jr, 1996).

Linearizacija nelinearnog modela satelitskog određivanja položaja obavlja se u okolišu položaja korisnika, uz uobičajeno korištenje razvoja nelinearne funkcije s desne strane znaka jednakosti (16) pomoću Taylorovog reda (Slika 13) (Gustafsson, 2020; Higham i suradnici, 2015; Filić, 2017). Postoje i drugi postupci linearizacije (Gustafsson, 2010), ali su kompleksniji za primjenu u satelitskim navigacijskim prijamnicima, sa stajališta njihovih računalnih sposobnosti i racionalnog korištenja dostupne energije.



Slika 13. Linearizacija nelinearne funkcije u okolišu točke (x_0, $f(x_0)$) primjenom Taylorovog reda (prema: Higham, N J i suradnici, 2015)

Općenito, linearizacija derivabilne ograničene funkcije *f(x)* primjenom Taylorovog reda obavlja se prema izrazu (17) (Higham i suradnici, 2015).

$$f(x) = f(x_0) + \frac{f'(x_0)}{1!} \cdot \Delta x + \frac{f''(x_0)}{2!} \cdot (\Delta x)^2 + \frac{f'''(x_0)}{3!} \cdot (\Delta x)^3 + \ldots \tag{17}$$

Izraz (17) može se skratiti na po volji izabran broj prvih članova, ukoliko pogreška aproksimacije ne prelazi postavljenu zahtijevanu točnost (Feynman, 2018). Može se pokazati kako je očekivana točnost satelitskog određivanja položaja postignuta približenjem (18) sa samo dva prva člana Taylorovog reda (17) (Higham i suradnici, 2015; Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997).

$$f(x) \approx f(x_0) + f'(x_0) \cdot \Delta x \tag{18}$$

Primjenom linearizacije Taylorovim redom s dva člana (18), GNSS algoritam određivanja položaja prelazi u iteracijski postupak opisan izrazom, gdje se nepoznate koordinate položaja u (k+1)-om koraku određuju iz iteriranih vrijednosti u k-tom koraku prema izrazu (19).

$$\begin{aligned} x_{k+1} &= x_k + \Delta x \\ y_{k+1} &= y_k + \Delta y \\ z_{k+1} &= z_k + \Delta z \end{aligned} \tag{19}$$

Razlike Δx, Δy i Δz određuju se postupkom zasnovanim na linearizaciji Taylorovim redom s dva člana, kako slijedi.

Iterirana vrijednost stvarne udaljenosti između satelitske antene i-tog satelita i korisničke antene prema komponentama položaja u k-tom koraku iteracije određena je izrazom (20).

$$R_{i,k} = \sqrt{(x_{si} - x_k)^2 + (y_{si} - y_k)^2 + (z_{si} - z_k)^2} \tag{20}$$

Matematički model određivanja položaja (16) približenjem Taylorovim redom s dva člana na funkciji s tri varijable može se prikazati izrazom (21) (Higham i suradnici, 2015).

$$\rho = R_{i,k} + \frac{\partial R_{i,k}}{\partial x} \cdot \Delta x + \frac{\partial R_{i,k}}{\partial y} \cdot \Delta y + \frac{\partial R_{i,k}}{\partial z} \cdot \Delta z \tag{21}$$

Uvrštavanjem vrijednosti parcijalnih derivacija funkcije $R_{i,k}$ u (21) dobiva se izraz (22) u kojem se kao nepoznanice pojavljuju vrijednosti Δx, Δy i Δz (Parkinson, Spilker, Jr, 1996; Filić, 2017).

$$\rho_i = R_{i,k} + \frac{x_k - x_{si}}{R_{i,k}} \cdot \Delta x + \frac{y_k - y_{si}}{R_{i,k}} \cdot \Delta y + \frac{z_k - z_{si}}{R_{i,k}} \cdot \Delta z \tag{22}$$

Za slučaj istovremenog mjerenja pseudoudaljenosti s četiriju različitih satelita poznatih koordinata položaja u trenutku odašiljanja satelitskog signala, dobiven je sustav jednadžbi

oblika (22), koji se u matričnom obliku može predstaviti izrazom (23) (Parkinson, Spilker, Jr, 1996).

$$\begin{bmatrix} \rho_1 - R_{k,1} \\ \rho_2 - R_{k,2} \\ \rho_3 - R_{k,3} \\ \rho_4 - R_{k,4} \end{bmatrix} = \begin{bmatrix} \frac{x_k - x_{s1}}{R_{1,k}} & \frac{y_k - y_{s1}}{R_{1,k}} & \frac{z_k - z_{s1}}{R_{1,k}} & c \\ \frac{x_k - x_{s2}}{R_{2,k}} & \frac{y_k - y_{s2}}{R_{2,k}} & \frac{z_k - z_{s2}}{R_{2,k}} & c \\ \frac{x_k - x_{s3}}{R_{i,k}} & \frac{y_k - y_{si}}{R_{i,k}} & \frac{x_k - x_{si}}{R_{i,k}} & c \\ \frac{x_k - x_{si}}{R_{i,k}} & \frac{y_k - y_{si}}{R_{i,k}} & \frac{x_k - x_{si}}{R_{i,k}} & c \end{bmatrix} \cdot \begin{bmatrix} \Delta x \\ \Delta y \\ \Delta z \\ b \end{bmatrix} \tag{23}$$

Postavljanjem nepoznanica na lijevu stranu matrične jednadžbe, izraz (23) poprima oblik (24).

$$\begin{bmatrix} \Delta x \\ \Delta y \\ \Delta z \\ b \end{bmatrix} = \begin{bmatrix} \frac{x_k - x_{s1}}{R_{1,k}} & \frac{y_k - y_{s1}}{R_{1,k}} & \frac{z_k - z_{s1}}{R_{1,k}} & c \\ \frac{x_k - x_{s2}}{R_{2,k}} & \frac{y_k - y_{s2}}{R_{2,k}} & \frac{z_k - z_{s2}}{R_{2,k}} & c \\ \frac{x_k - x_{s3}}{R_{i,k}} & \frac{y_k - y_{si}}{R_{i,k}} & \frac{x_k - x_{si}}{R_{i,k}} & c \\ \frac{x_k - x_{si}}{R_{i,k}} & \frac{y_k - y_{si}}{R_{i,k}} & \frac{x_k - x_{si}}{R_{i,k}} & c \end{bmatrix}^{-1} \cdot \begin{bmatrix} \rho_1 - R_{k,1} \\ \rho_2 - R_{k,2} \\ \rho_3 - R_{k,3} \\ \rho_4 - R_{k,4} \end{bmatrix} \tag{24}$$

Nakon konvergencije postupka iteracije, procjena vektora stanja korisnika (x_u, y_u, z_u, b) jednaka je vrijednostima dobivenim u zadnjem koraku $k+1$, kako je prikazano izrazom (25).

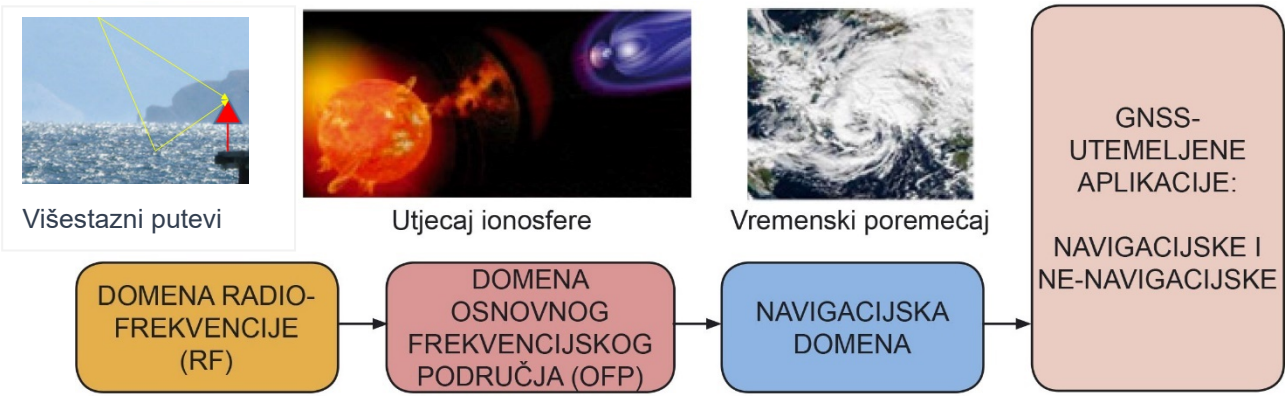
$$\vec{x} = (x_u, y_u, z_u, b)^\tau = (x_{k+1}, y_{k+1}, z_{k+1}, b)^\tau \tag{25}$$

Tako su definirani svi elementi iteracijskog postupka.

2.4. Proračun pogrešaka procjene položaja satelitskim navigacijskim sustavom

Satelitski navigacijski prijamnik je uređaj koji obavlja postupak procjene stanja korisnika (koordinata položaja i nepoznate pogreške korisničkog sata) zasnovano na izmjerenim pseudoudaljenostima od satelita u trenutnom području vidljivosti, poznatim parametrima satelitskih orbita i na postupku vremenskog usklađivanja (sinkronizacije) kao rezultatu samog rada prijamnika (Sainz Subirana i suradnici, 2013). U svom radu je satelitski navigacijski prijamnik izložen brojnim potencijalnim prirodnim i umjetnim uzrocima pogrešaka nastalim u

okruženju za satelitsko određivanje položaja (Parkinson, Spilker, Jr, 1996;), kako je prikazano slikom 14 i tablicom 4.



Slika 14. Izloženost satelitskog navigacijskog prijamnika raznim utjecajima okoline

Slikom 14 prikazani su različiti elementi okoliša koji sadrže izvore učinaka za točnost određivanja položaja satelitskim sustavom. Satelitski navigacijski prijamnik prikazan je svojim domenama, budući da svaka od njih u određenom smislu osjeća posljedice izvora učinaka iz okoliša satelitskog određivanja položaja. Narušavanje kvalitete satelitskog određivanja položaja preslikava se u područje navigacijskih i nenavigacijskih primjena satelitske navigacije (tehnološki i društveno-ekonomski sustavi te usluge koje oni pružaju).

Ukupna pogreška određivanja položaja satelitskim sustavom rezultat je djelovanja dviju osnovnih klasa uzroka pogrešaka (Parkinson, Spilker, Jr, 1996):

1. geometrijske degradacije točnosti te
2. korisničke razdiobe pogrešaka.

Geometrijska degradacija točnosti i korisnička razdioba pogrešaka su statistički neovisni uzroci pa se ukupna pogreška određivanja položaja dobiva množenjem doprinosa dviju osnovnih klasa uzroka pogrešaka (Parkinson, Spilker, Jr, 1996).

Geometrijska degradacija točnosti nastaje uslijed međusobnih prostornih odnosa položaja korisnika i položaja iz korisničkog stajališta vidljivih satelita (Parkinson, Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013). Navedeni položaji mogu biti shvaćeni kao odrednica geometrijskog tijela kojem se u vrhovima nalaze korisnik i iz korisničkog stajališta vidljivi sateliti. Što je veći volumen tako zamišljenog geometrijskog tijela, to će geometrijska degradacija točnosti biti manja (Sainz Subirana i suradnici, 2013).

Geometrijska degradacija točnosti može se analitički odrediti pomoću matrice *D* izvedene iz geometrijske matrice *G*, (26) definirane u postupku određivanja položaja satelitskim sustavom (potpoglavlje 2.1) (Parkinson, Spilker, Jr, 1996; Strang, Borre, 1997), kako je prikazano slikom 15.

$$G = \begin{bmatrix} \frac{x_u - x_{s1}}{\rho_1} & \frac{y_u - y_{s1}}{\rho_1} & \frac{z_u - z_{s1}}{\rho_1} & 1 \\ \frac{x_u - x_{s2}}{\rho_2} & \frac{y_u - y_{s2}}{\rho_2} & \frac{z_u - z_{s2}}{\rho_2} & 1 \\ \frac{x_u - x_{s3}}{\rho_3} & \frac{y_u - y_{si}}{\rho_3} & \frac{x_u - x_{si}}{\rho_3} & 1 \\ \frac{x_u - x_{si}}{\rho_4} & \frac{y_u - y_{si}}{\rho_4} & \frac{x_u - x_{si}}{\rho_4} & 1 \end{bmatrix} \tag{26}$$

Matrica D određuje se izrazom (27) (Parkinson, Spilker, Jr, 1996):

$$D = (G^{\tau} G)^{-1} \tag{27}$$

Elementi na glavnoj dijagonali matrice *D* (28)

$$D = \begin{bmatrix} NDOP & .. & .. & .. \\ .. & EDOP & .. & .. \\ .. & .. & VDOP & .. \\ .. & .. & .. & TDOP \end{bmatrix} \tag{28}$$

su osnovne komponente geometrijske degradacije točnosti (Parkinson, Spilker, Jr, 1996), redom:

1. geometrijska degradacija točnosti u smjeru sjevera (NDOP),
2. geometrijska degradacija točnosti u smjeru istoka (EDOP),
3. geometrijska degradacija točnosti u vertikalnom smjeru (VDOP) te
4. geometrijska degradacija točnosti određivanja vremena (pogreške korisničkog sata) i TDOP.

Navedene elementarne degradacije točnosti koriste se za određivanje izvedenih: horizontalne degradacije točnosti (HDOP), prostorne degradacije točnosti (PDOP) i ukupne geometrijske degradacije točnosti (GDOP) (Parkinson, Spilker, Jr, 1996), kako je prikazano izrazima (29) – (31).

$$HDOP = \sqrt{NDOP^2 + EDOP^2} \tag{29}$$

$$PDOP = \sqrt{HDOP^2 + VDOP^2} \tag{30}$$

$$GDOP = \sqrt{PDOP^2 + TDOP^2} \tag{31}$$

Korisnička razdioba pogrešaka obuhvaća sve uzroke kašnjenja satelitskog signala za mjerenje pseudoudaljenosti koje tako unose pogrešku u izmjerenu udaljenost između satelita i korisničke opreme, kao i izvore netočnih informacija za potrebe postupka određivanja položaja (pogreške satelitske efemeride, satelitskih satova, nepotpune popravke modela i dr.) (Parkinson, Spilker, Jr, 1996).

Pojedinačni uzroci pogreške u klasi korisničke razdiobe pogrešaka navedeni su zajedno sa svojim pretpostavljenim doprinosima ukupnoj pogreški u tablici 4 (Parkinson, Spilker, Jr, 1996). Najveći pojedinačni doprinos korisničkoj razdiobi pogrešaka donose ionosfersko kašnjenje i učinci višestaznih (višestrukih) puteva (Parkinson, Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013). Problem navedenih dvaju učinaka posebno je naglašen činjenicom kako oni izazivaju velike apsolutne pogreške, ali mogu izazvati i pojavu izrazito velikih slučajnih komponenata koje je teško identificirati i opisati prikladnim modelima popravaka (Parkinson, Spilker, Jr, 1996; Filić, Filjar, 2018a).

Tablica 4. Proračun pogrešaka satelitskog određivanja položaja (Parkinson, Spilker, Jr, 1996)

Izvor pogreške	**Uzrok**	**Vrijednost pogreške, 1σ (m)**		
		Stalna	**Slučajna**	**Ukupna**
Satelitska komponenta	Satelitske efemeride	2,1	0,0	2,1
	Satelitski sat	2,0	0,7	2,1
Prijenosni medij (atmosfera)	Ionosfersko kašnjenje	4,0	0,5	4,0
	Troposfersko kašnjenje	0,5	0,5	0,7
Korisnička komponenta i mikrookoliš	Višestruki putovi	1,0	1,0	1,4
	Šum prijamnika	0,5	0,2	0,5
Korisnička razdioba pogrešaka (UERE). Rms		5,1	1,4	5,3
Vertikalna pogreška 1σ uz parametar VDOP = 2,5				12,8
Horizontalna pogreška 1σ uz parametar HDOP = 2,0				10,2

Kako su pojedinačni uzroci statistički neovisni, njihov ukupni doprinos proračunat je na prikladan način, korištenjem pristupa prikazanog izrazom (32) (Parkinson, Spilker, Jr, 1996;

Maindonald, Brown, 2010; Dalpiaz, 2019). Ukupni učinak p_{ukupno} pojedinačnih statistički neovisnih učinaka x_i dobiva se pomoću navedenog izraza (32).

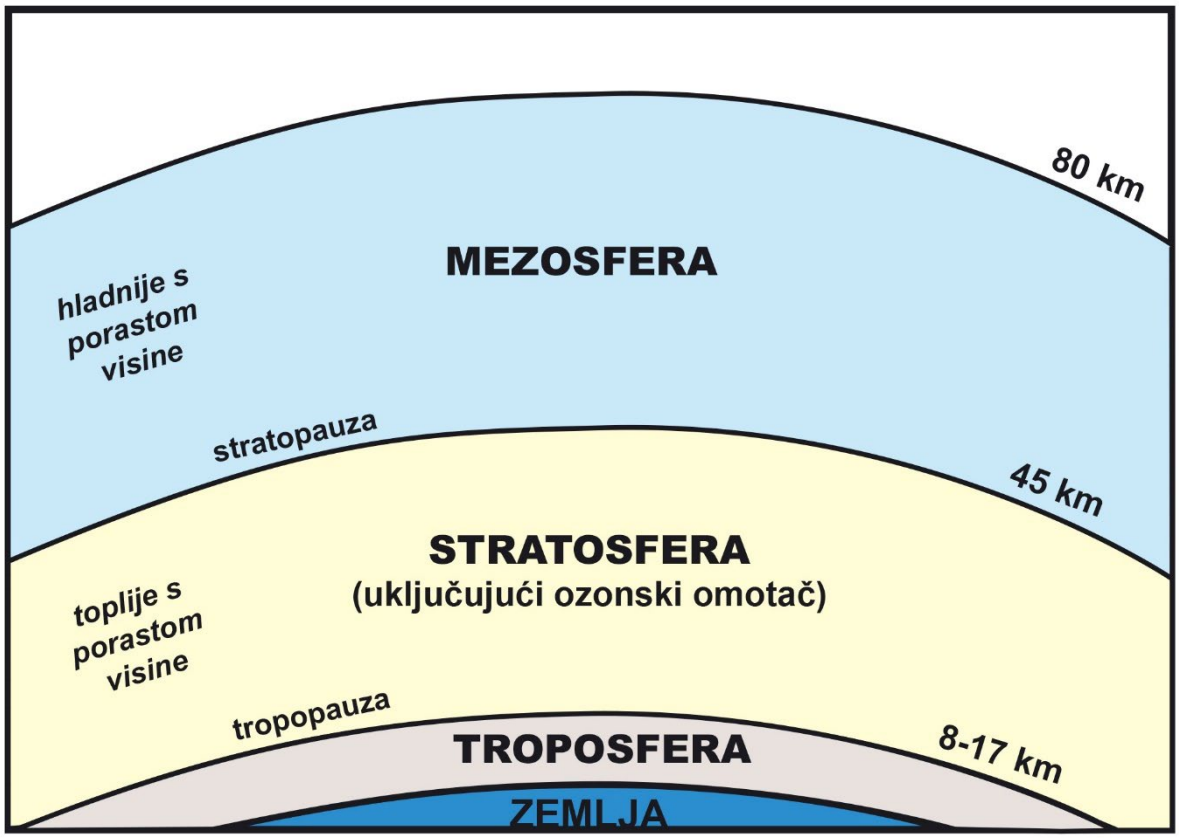
$$p_{ukupno} = \sqrt{\sum_{i=1}^{N} x_i^2} \tag{32}$$

U ovom potpoglavlju prikazane su općenite matematičke osnove postupka procjene (određivanja) položaja satelitskim navigacijskim sustavima. Također, prikazana je jedna izvedba navedenog postupka koja pretpostavlja jednaku statističku težinu svih pojedinačnih uzroka narušavanja točnosti određivanja položaja satelitskim sustavima. Područje budućih istraživanja obuhvaća razvoj novih postupaka određivanja položaja koji uzimaju u obzir statističku značajnost pojedinačnih uzroka narušavanja točnosti određivanja položaja i obavljaju samopodešavanje s ciljem dobivanja optimalne procjene položaja, ovisno o zadanom stanju okoliša za određivanje položaja.

2.5. Troposferski učinci na prolaz satelitskog signala

2.5.1. Obilježja troposfere

Troposfera je nehomogeni, električki neutralan najniži sloj Zemljine atmosfere. Proteže se od površine Zemlje s gornjom granicom ovisnom o geografskoj širini mjesta s kojeg se promatra: (i) na ekvatoru oko 16 km, (ii) na srednjim geografskim širinama oko 11 km, (iii) na polovima oko 8 km (Stull, 2015; ICAO, 1993).



Slika 15. Vertikalni profil atmosfere (prema: Gelo,2000)

Atmosfera Zemlje (slika 15) je nehomogena, što znači kako se s visinom od razine mora (površine Zemlje) mijenjaju fizikalne karakteristike atmosfere (Stull, 2015; ICAO, 1993; Schueler, 2001), posebno:

1. gustoća zraka,
2. tlak zraka,
3. temperatura zraka te
4. vlažnost zraka.

Za potrebe znanstvenih istraživanja i operativnog rada brojnih sustava, razvijena je tzv. standardna Zemljina atmosfera (engl. International Standard Atmosphere - ISA), koja opisuje stacionarna obilježja atmosfere na globalnoj razini (ISO, 2007). Model standardne atmosfere opisuje promjenu temperature zraka i tlaka zraka u ovisnosti o nadmorskoj visini za stabilnu (nepobuđenu) atmosferu, kako je prikazano slikom 17. Profesionalne organizacije vezane za različite discipline također su razvile svoje matematičke modele standardne atmosfere. Ističe se Međunarodna organizacija civilnog zrakoplovstva (engl. International Civil Aviation Organisation - ICAO) koja je razvila globalni matematički model Zemljine atmosfere za visine do 80 km (ICAO, 1993).

Vrijednosti tlaka zraka i temperature zraka u ovisnosti o nadmorskoj visini za stabilnu atmosferu izražavaju se pomoću fizikalnih zakona (Feynman, Leighton, Sands, 1963). Ovisnost tlaka zraka *p(h)* na nadmorskoj visini *h* definirana je izrazom (33), uz poznat tlak zraka na razini mora p_0. Izraz (33) koristi sljedeće fizikalne konstante:

$$p(h) = p_0 \cdot exp(-\frac{M \cdot g}{R \cdot T}) \tag{33}$$

gdje su:

p_0 … srednja vrijednost tlaka zraka na razini mora (= 1013,25 hPa)

g … akceleracija sile teže (= 9,807 m/s^2)

M … molarna masa zraka u Zemljinoj atmosferi (= 0,02896 kg/mol)

T … standardna temperatura zraka u Zemljinoj atmosferi (= 288,15 K)

Uvrštavanjem gornjih koeficijenata u izraz (33) te podešavanjem koeficijenata za dobivanje rezultata u (hPa), izraz za tlak zraka *p(h)* na nadmorskoj visini *h* poprima oblik prema izrazu (34). Izraz (34) poznat je i pod nazivom barometarska jednadžba (Stull, 2015; Feynman, Leighton, Sands, 1963).

$$p(h) = 1013.25 \cdot exp(0.00012 \cdot h)(hPa) \tag{34}$$

Ovisnost temperature zraka T o nadmorskoj visini h u stabilnoj atmosferi određuje se prema izrazu (35) koji uvažava iskustveno opažanje kako temperatura zraka stabilne atmosfere opada približno 6,5 K za svaki porast nadmorske visine od 1 km u području troposfere (0 km – 11 km), uz standardnu temperaturu na razini mora od 288,15 K (15 °C) (Stull, 2015).

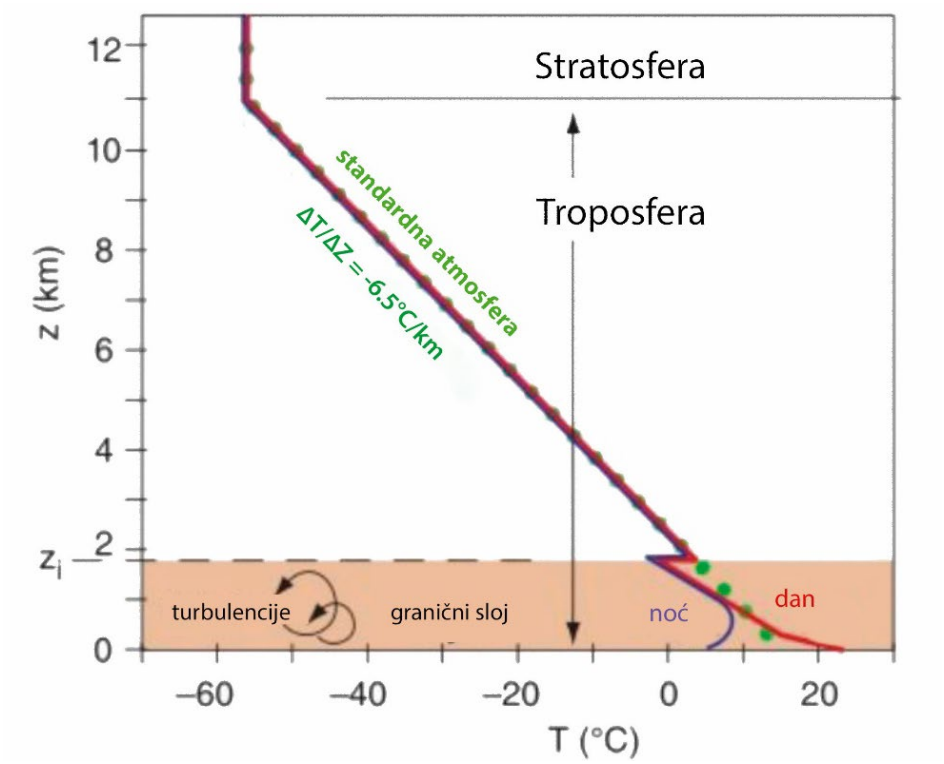
Nadmorska visina h u izrazu (35) izražava se u (m).

$$T(h) = 288.15 - 0.0065 \cdot h(K) \tag{35}$$

U višim slojevima atmosfere, temperatura zraka se mijenja s različitim gradijentima, kako je prikazano tablicom 5 i slikom 16 (Stull, 2015).

Tablica 5. Ovisnost temperature zraka o nadmorskoj visini

Razina atmosfere	Osnovna temperatura, Tb (K)	Osnovna temperatura Stopa kašnjenja po kilometru geopotencijalne visine, Lp (K/km)
Troposfera	288,15	–6,5
Tropopauza (Stratosfera I)	216,65	0,0
	216,65	+1,0
Stratosfera II	228,65	+2,8
Stratosfera III	270,65	0
Stratopauza (Mezosfera I)	270,65	–2,8
Mezosfera II	214,65	–2,0
Mezosfera III	186,87	–



Slika 16. Vertikalni profil temperature u troposferi Zemlje (prema: Stull, 2015)

Model standardne atmosfere daje sljedeću razdiobu osnovnih obilježja atmosfere po visini, kako je prikazano tablicom 6 (ICAO, 1993; Schueler, 2001).

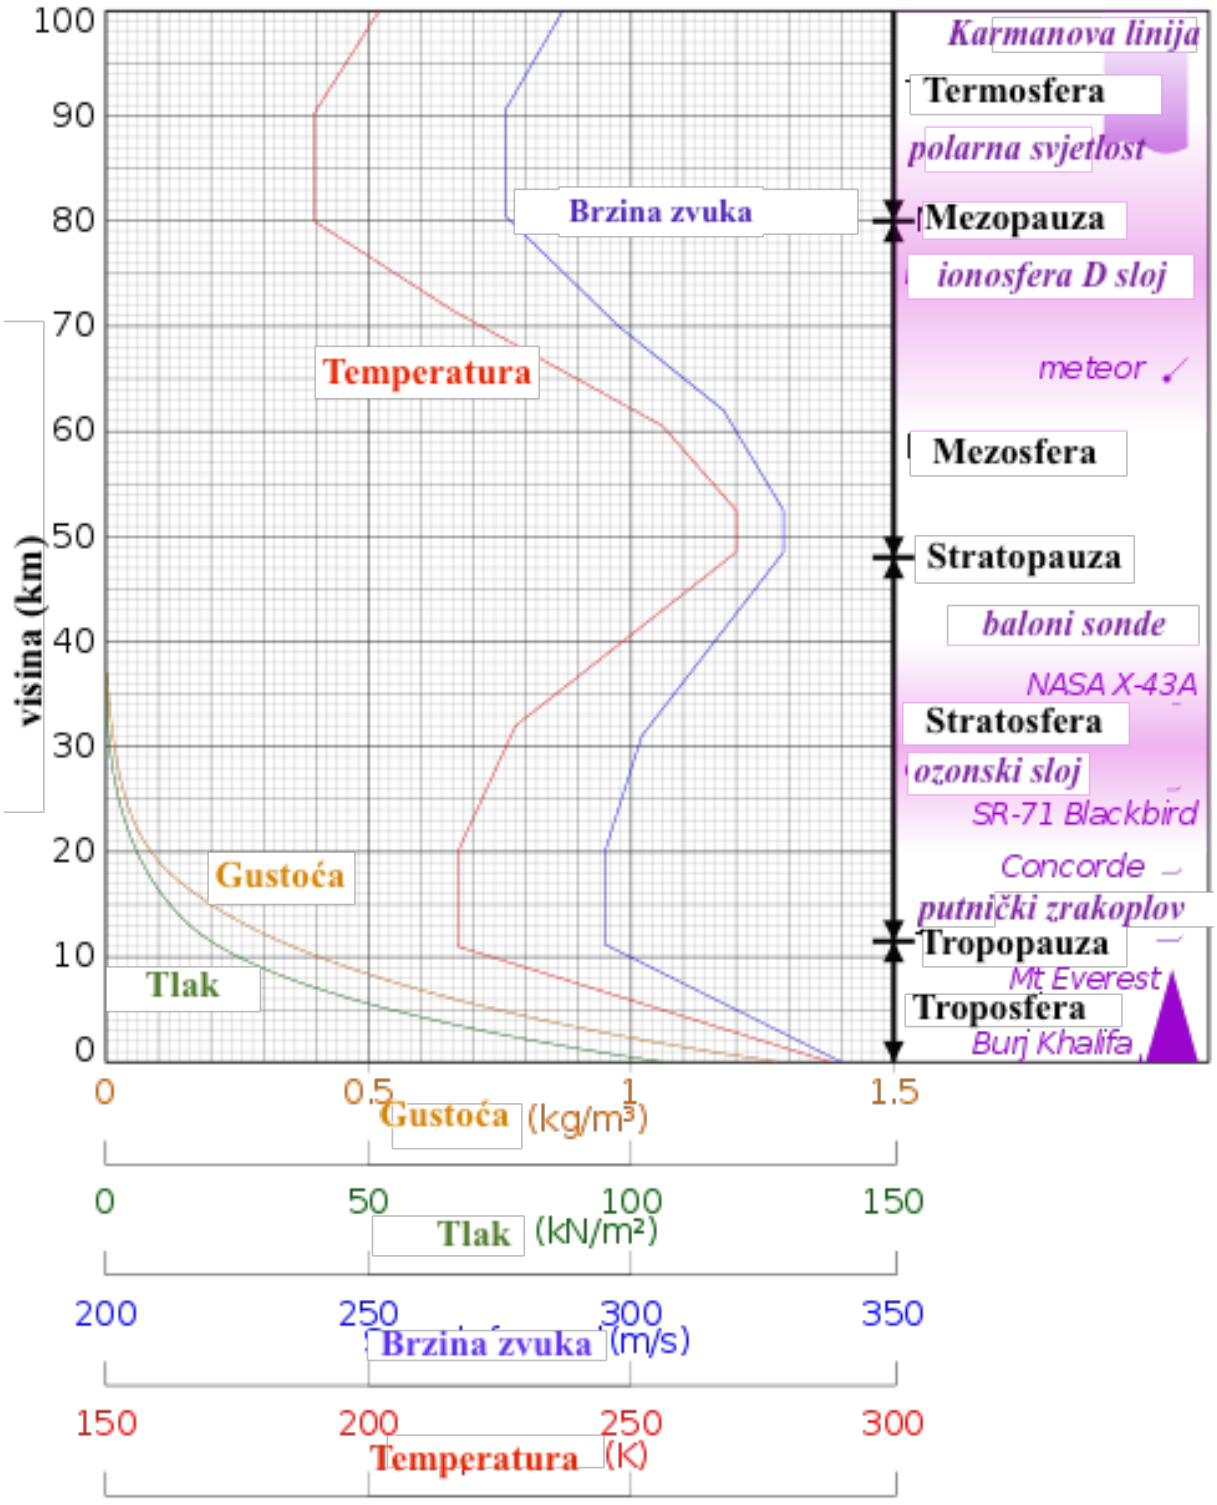
Tablica 6. Obilježja stabilne Zemljine atmosfere (prema: ICAO, 1993 i Schueler, 2001)

Visina (ft) (m)	**Tlak (mmHg) (hPa)**	**Temperatura (°F) (°C)**	**Gustoća (%)**
morska površina	29,92 1013,21	59,00 15	100,00
2000 609,60	27,82 942,09	51,90 11,06	94,30
4000 1219,20	25,84 875,04	44,70 7,06	88,80
6000 1828,80	23,98 812,06	37,60 3,11	83,60
8000 2438,40	22,22 752,46	30,50 –0,83	78,60
10000 3048,00	20,57 696,58	23,30 –4,83	73,80
12000 3657,60	19,02 644,09	16,20 –8,78	69,30
14000 4267,20	17,57 594,99	9,10 –12,72	65,00
16000 4876,80	16,21 548,93	1,90 –16,72	60,90

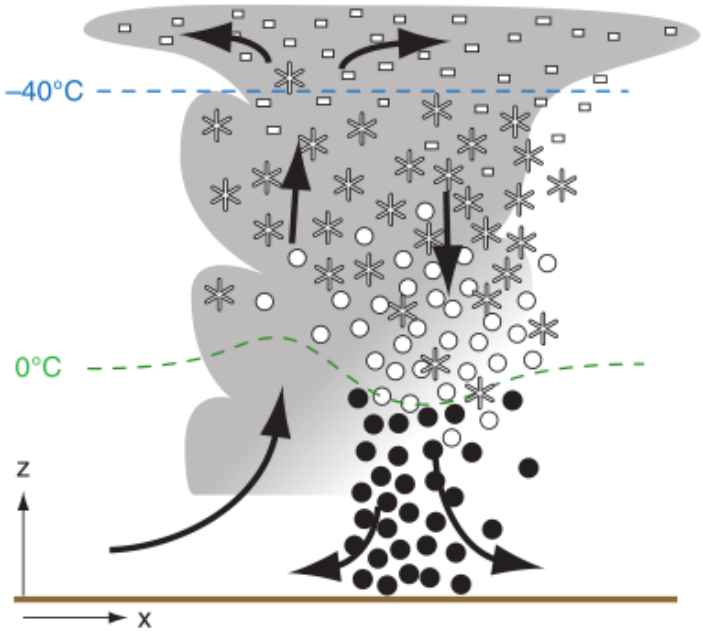
Navedeni modeli prikazuju statičke karakteristike usrednjene Zemljine atmosfere na globalnoj razini, ne uzimajući u obzir lokalne i regionalne posebnosti, niti dinamiku atmosfere.

Atmosferska dinamika obilježava stanje atmosfere promatrano s lokalnog stajališta. Kombinacija horizontalnog i vertikalnog gibanja zračnih masa na različitim opsezima (skalama) određuje stanje i razvoj vremena (Simović, 1970; Gelo, 2000; Stull, 2015). Kompleksnost dinamike u Zemljinoj atmosferi naglašena je pojavama različite naravi koje se događaju u prostoru. Vertikalni profil promjene vremena ukazuje na pojave vezane za pojedine slojeve zraka koji pri intenzivnijem razvoju vremena započinju međusobnu interakciju.

Standardna atmosfera je međunarodno prihvaćen model stanja Zemljine atmosfere i okomite raspodjele temperature i tlaka zraka do 90 kilometara visine koja se uzima kao svjetski prosjek vrijednosti tih veličina kako je prikazano slikom 17 (Krleža, 2018) te razvoj turbulencija po vertikalnom profilu troposfere povezivanjem laminarnih slojeva stabilne troposfere kako je prikazano slikom 18.

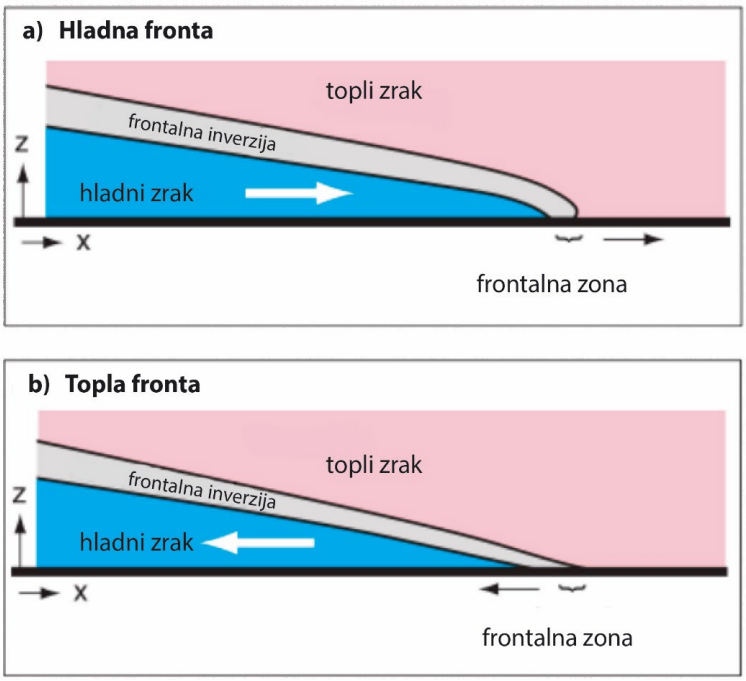


Slika 17. Standardna atmosfera (ISA), (prema: Hrvatska enciklopedija, Leksikografski zavod Miroslav Krleža, 2018.)



Slika 18. Razvoj turbulencija po vertikalnom profilu troposfere povezivanjem laminarnih slojeva stabilne troposfere (prema: Stull, 2015, Simović, 1970)

Razvoj vremena uslijed gibanja zračnih masa također će prouzročiti značajne lokalne promjene osnovnih obilježja atmosfere u nižim slojevima (troposfera), kako je prikazano slikom 19 (Stull, 2015; Schueler, 2001).



Slika 19. Frontalna kretanja zračnih masa različitih temperatura i gustoća, kao uzrok razvoja vremenske situacije (prema: Stull, 2015, Simović, 1970)

2.5.2. Propagacija radiovala troposferom

Troposfera utječe na propagacije radiovalova iako je električki neutralna. Posebno je naznačen utjecaj troposfere na propagacije mikrovalova (radiovalova frekvencija većih od 1 GHz) (Ajayi, 1989; Zhang, 1999). Oblikovanje te kombinirano horizontalno i vertikalno gibanje zračnih masa uzrokuju pojavu prostornih područja različitih fizikalnih obilježja zraka, a time i različitih indeksa loma (Feynman, Leighton, Sands, 1963), prema izrazima (36) i (37), uz oznake:

$$N = (n - 1) \cdot 10^6 \tag{36}$$

gdje su:

n ... indeks loma dvaju sredstava s brzinama širenja elektromagnetskog vala, u kojima nastaje lom (refrakcija) elektromagnetskog vala, bezdimenzionalan
N ... reducirani indeks loma, s naglašenim decimalnim dijelom n, bezdimenzionalan
p ... tlak zraka (atmosferski tlak) (Pa)
T ... temperatura zraka (K)

Reducirani indeks loma može se izraziti pomoću parametara stanja troposfere (Feynman, Leighton, Sands, 1963), kao u izrazu (37).

$$N = \frac{77.6}{T}(p + 4810 \cdot \frac{e}{T}) \tag{37}$$

gdje je:

e ... parcijalni tlak vodene pare u (hPa), vezan s vlažnošću zraka H (%) izrazom (38) koji uključuje parcijalni tlak zasićene vodene pare e_s u (hPa) (Schueler, 2001):

$$H = \frac{100 \cdot e}{e_s(t)} \tag{38}$$

Parcijalni tlak zasićene vodene pare moguće je odrediti eksperimentalnim modelom (39) (Schueler, 2001):

$$e_s(t) = a \cdot exp(\frac{bt}{t + c}) \tag{39}$$

pri čemu parametri modela *a*, *b* i *c* predstavljaju regresijske koeficijente zasnovane na eksperimentalnim opažanjima te imaju vrijednosti ovisno o agregatnom stanju vode ispod zračne mase sa zasićenom vodenom parom, kako je prikazanom tablicom 7 (Grabner, Kvicera, 2011).

Tablica 7. Obilježja vodene pare u Zemljinoj atmosferi

	a (hPa)	b (1)	c (°C)
Zasićena vodena para iznad tekuće vode	6,1121	17,502	240,97
Zasićena vodena para iznad leda	6,1115	22,452	272,55

Model podrazumijeva uobičajeno stanje stabilne (nepomućene) atmosfere. Standardna Zemljina atmosfera često se uzima kao polazni opis atmosfere ukoliko ne postoje rezultati mjerenja stvarnog stanja atmosfere (Sanz Subirana i suradnici, 2013).

Promjena indeksa loma uslijed različitih fizikalnih obilježja zračnih masa u troposferi izazvat će refrakciju satelitskih radiovalova (Feynman, Leighton, Sands, 1963). U slučaju satelitskih signala za određivanje položaja (GNSS), pojavit će se učinak ekvivalentan kašnjenju, nazvan troposfersko kašnjenje (Hopfield, 1971; Saastamoinen, 1971; Parkinson, Spilker, Jr, 1996). Troposfersko kašnjenje pojavljuje se kao utjecajna veličina u mjerenju pseudoudaljenosti te time određuje točnost određivanja položaja satelitskim sustavom (Hopfield, 1971; Saastamoinen, 1971; Parkinson, Spilker, Jr, 1996). Analiza proračuna pogrešaka određivanja položaja satelitskim navigacijskim sustavom razotkriva doprinos troposferskog kašnjenja ukupnoj pogrešci mjerenja pseudoudaljenosti i korisničkoj razdiobi pogrešaka (Parkinson, Spilker, Jr, 1996; Filić, Filjar, 2018a; Markežić, Filjar, Juričić, 2001; Rumora, Jukić, Filić, Filjar, 2018; Filić, Filjar 2018c). Identificirane su obje komponente pogreške: sistemska (sezonalna) i slučajna. Međutim, literatura ne navodi ni jedan model transformacije kojim bi bilo moguće objasniti preslikavanje pogreške mjerenja pseudoudaljenosti uslijed troposferskog kašnjenja u doprinos ukupnoj pogreški određivanja položaja uslijed učinaka troposferskog kašnjenja.

2.6. Točnost određivanja položaja za pojedine klase primjena satelitskih navigacijskih sustava

Primjerena analiza ranjivosti i ograničenja temeljnih tehnologija je suštinska osnova razvoja i operativnosti svake usluge ili sustava (Filić, 2017; Parkinson, Spilker, Jr, 1996; Volpe, 2001;

Thomas i suradnici, 2011; Filjar, Huljenić, 2012; SaPPART, 2017; HMGOS, 2018). Zbog toga su analize narušavanja kvalitete određivanja položaja temelj svake primjene satelitskog određivanja položaja uključujući i one u pomorskoj navigaciji.

Kvaliteta satelitskog određivanja položaja zasniva se na opažanju četiriju osnovnih elemenata (Parkinson i Spilker, Jr, 1996):

1. točnost određivanja položaja tijekom duljeg vremena,
2. dostupnost usluge satelitskog određivanja položaja,
3. integritet satelitskog određivanja položaja te
4. kontinuitet satelitskog određivanja položaja.

Navedena obilježja kvalitete satelitskog određivanja položaja mogu se definirati na načine, kako slijedi (definicije su izvedene temeljem više dokumenata, uključivo (Parkinson i Spilker, Jr, 1996; Thomas i suradnici, 2011; Sanz Subirana i suradnici, 2013).

Definicija 1. Točnost određivanja položaja je sposobnost sustava i usluge da omogući procjenu položaja uz zajamčenu neodređenost procjene na definiranom području i u definiranom vremenskom razdoblju, uz uvjet korištenja specificirane korisničke opreme u definiranim stanjima okoliša satelitskog određivanja položaja.

Definicija 2. Dostupnost određivanja položaja je sposobnost sustava i usluge da omogući dovoljan broj specificiranih satelitskih signala i odnosnih informacija za potrebe procjene položaja na definiranom području i u definiranom vremenskom razdoblju, uz uvjet korištenja specificirane korisničke opreme u definiranim stanjima okoliša satelitskog određivanja položaja.

Definicija 3. Integritet sustava i usluge određivanja položaja je sposobnost sustava i usluge da u zadanom roku obavijesti ciljanu skupinu korisnika o privremenoj nedostupnosti ili narušavanju kvalitete usluge određivanja položaja na definiranom području i u definiranom vremenskom razdoblju, uz uvjet korištenja specificirane korisničke opreme u definiranim stanjima okoliša satelitskog određivanja položaja.

Definicija 4. Kontinuitet određivanja položaja je sposobnost sustava i usluge da omogući neprekidnost usluge procjene položaja uz zajamčenu neodređenost procjene putem neprekidnog praćenja dovoljnog broja satelitskih signala i odnosnih informacija potrebnih za procjenu položaja korisničkom opremom na

definiranom području i u definiranom vremenskom razdoblju, uz uvjet korištenja specificirane korisničke opreme u definiranim stanjima okoliša satelitskog određivanja položaja.

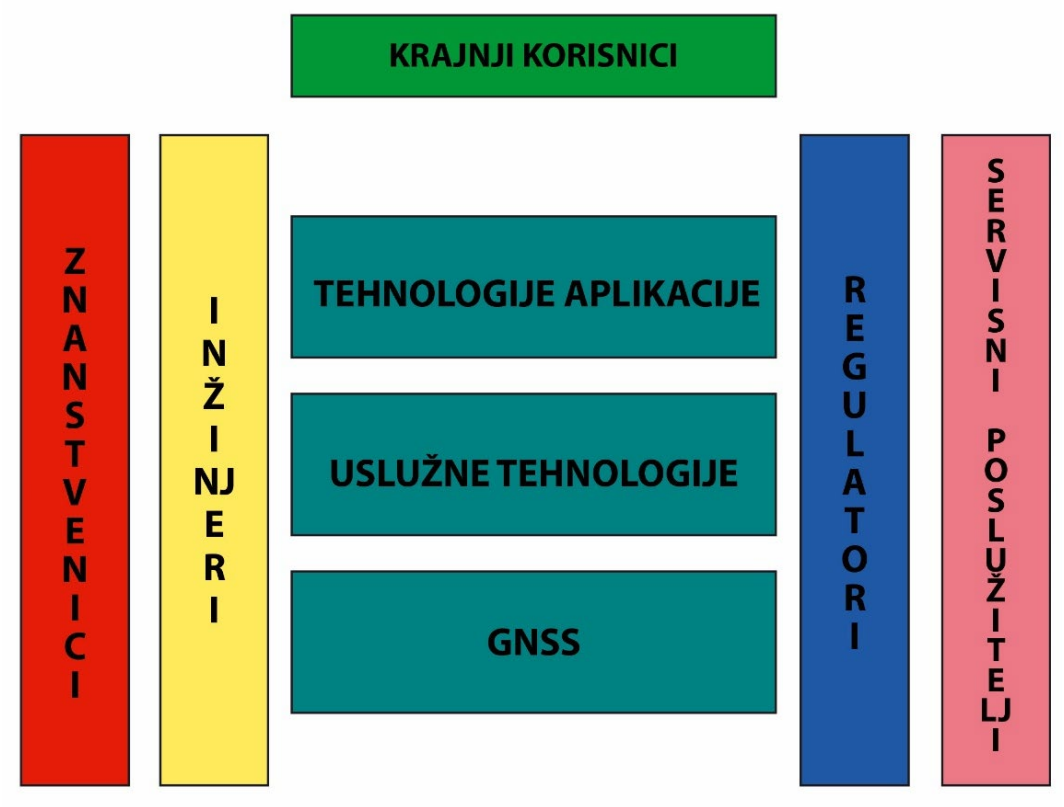
U razmatranju troposferskih učinaka kao utjecajnih veličina za rad satelitskih navigacijskih sustava, utjecaj troposfere pretežno je vidljiv kao utjecajna veličina koja djeluje na točnost satelitskog određivanja položaja (Parkinson i Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013). Zbog toga će troposfersko kašnjenje satelitskog signala biti razmatrano kao utjecajna veličina na točnost satelitskog određivanja položaja, kao obilježja kvalitete satelitskog određivanja položaja, u nastavku ovog istraživanja i ove disertacije.

Satelitski navigacijski sustavi konstruirani su tako da pružaju zajamčenu točnost određivanja položaja u zadanim uvjetima okoliša navedenog postupka (Parkinson i Spilker, Jr, 1996; Filjar, Gold, Markežić, 2011; Filić, Filjar, 2018a). Okoliš postupka određivanja položaja predstavlja ključni čimbenik u naporima održavanja kvalitete određivanja položaja. Neovisnost kvalitete određivanja položaja satelitskim sustavom od stanja okoliša postavljena je kao primarni znanstveni cilj unaprjeđenja satelitskih navigacijskih sustava (Thomas i suradnici, 2011; Filić, Filjar, 2018a).

Zajamčena točnost određivanja položaja satelitskim sustavom definirana je obilježjima samog sustava i izabranim stanjem okoliša postupka određivanja položaja koji minimizira lokalne utjecaje (Parkinson i Spilker, Jr, 1996; Sanz Subirana i suradnici, 2013). Na taj način, operator satelitskog navigacijskog sustava preuzima odgovornost za kvalitetu određivanja položaja u dijelu arhitekture na koji može utjecati. Unutar postojećeg modela korištenja, korisnik satelitskog navigacijskog sustava preuzima na sebe odgovornost korištenja sustava na način koji će minimizirati učinke lokalnog okoliša te tako omogućiti postizanje kvalitete određivanja položaja satelitskim sustavom s obilježjima bliskim onim zajamčenim (Filjar, Huljenić, 2012; Filjar, Luttenberger, Kos, 2013).

Postojeći model korištenja satelitskih navigacijskih sustava preuzet je iz izvornog modela vojnog korištenja koji je uslugu određivanja položaja, brzine i vremena (engl. Positioning, Navigation, and Timing – PNT) usluga shvaćao konačnom uslugom. Suvremene primjene satelitskih navigacijskih sustava shvaćaju PNT uslugu kao infrastrukturnu uslugu na kojoj se grade napredne navigacijske i nenavigacijske usluge (Filjar, Ježić i Matijašević, 2008; Thomas i suradnici, 2011; Filjar, Huljenić, 2012), kao što je prikazano slikom 20. Okruženje za razvoj i pružanje usluga zasnovanih na primjeni satelitskog određivanja položaja obuhvaća tehnološki

orijentirane subjekte, ali i subjekte koji definiraju poslovnu stranu komercijalizacije takvih usluga, poput regulatora (regulatornih tijela) koji uređuju pravnu stranu i odnose u postupku komercijalizacije primjena zasnovanih na satelitskoj navigaciji. Korisnici navedenih usluga su sve fizičke i pravne osobe opremljene odgovarajućom potrebnom opremom koje su s pružateljem usluga postigle dogovor i potpisale ugovor o sadržaju i načinu korištenja usluge.



Slika 20. Poslovno (razvojno) okruženje za razvoj usluga zasnovanih na GNSS PNT uslugama satelitske navigacije (prema: Filjar, Luttenberger, Kos, 2012)

PNT usluga tako postaje omogućavajuća usluga drugim, hijerarhijski višim navigacijskim i nenavigacijskim uslugama, pri čemu korisnik sve manje izravno koristi PNT uslugu satelitskog navigacijskog sustava jer je ona postavljena u temelje napredne usluge koju korisnik izravno upotrebljava (Filjar, Huljenić, 2012; Anđelini, Lučić, Filjar, 2014). Kako je korisnik sve manje svjestan činjenice koristi li ili ne satelitsku navigacijsku tehnologiju za potrebe konkretne usluge, prestaje biti u mogućnosti, a često nije ni dovoljno pripremljen, posvetiti pažnju ispunjenju uvjeta za optimalno određivanje položaja satelitskim sustavom (Filjar, Ježić, Matijašević, 2008; Filjar, Huljenić, 2012). Narušavanje kvalitete određivanja položaja satelitskim sustavom prenosi se na uslugu zasnovanu na satelitskom određivanju položaja, narušavajući njenu kvalitetu (Filjar, Huljenić, 2012; Filjar, Kos, Luttenberger, 2013). U

navedenom procesu, satelitsko određivanje položaja postaje heurističko (suboptimalno), zbog čega nastaju problemi u operativnosti i kvaliteti određivanja položaja satelitskim sustavom pa time i kvaliteti naprednih viših usluga zasnovanih na satelitskoj navigaciji kao temeljnoj tehnologiji. Optimizacija postupka određivanja položaja prema stanju okoliša za određivanje položaja ostaje iznimno važna tema budućih istraživanja.

Usluge zasnovane na satelitskoj navigaciji imaju različite interne zahtjeve za točnost određivanja položaja, bez obzira određuje li se položaj satelitskim ili nekim drugim postupkom. U određenom broju slučajeva, usluge zasnovane na satelitskoj navigaciji mogu tražiti manju točnost od one koju pruža postupak satelitskog određivanja položaja, uz cijenu dodatnih zahtjeva za iskorištavanje resursa potrebnih za procjenu položaja. Na primjer, telekomunikacijska usluga za pametne telefone koja će uputiti korisnika do najbliže benzinske stanice ne traži centimetarsku točnost određivanja položaja, ali može tražiti ubrzano određivanje položaja, uz štednju energije i manje opterećenje mikroprocesora – jednostavniju metodu određivanja položaja. Optimizacija postupka satelitskog određivanja položaja prema zahtjevima usluga koje koriste procjenu položaja također je iznimno važna tema budućih istraživanja, uz potrebu za kvalitetnom definicijom zahtijevane točnosti određivanja položaja satelitskim sustavima za pojedine klase primjena i zahtjevima o potrebnoj točnosti određivanja položaja (tablica 17 i tablica 18) satelitske navigacije (Filjar, Ježić, Matijašević, 2008; Thomas i suradnici, 2011; Filjar, Huljenić, 2012; GSA, 2018).

3. PREGLED PRETHODNIH ISTRAŽIVANJA

Navedeno poglavlje sastoji se od sistematizacije navigacijskih zadataka u pomorskoj površinskoj navigaciji prema potrebnoj točnosti položaja, postupaka procjene položaja satelitskim sustavom, modela pogrešaka procjene položaja satelitskim sustavom, modela popravaka troposferskog kašnjenja satelitskog signala za određivanje položaja te nedostataka postojećih modela.

3.1. Sistematizacija navigacijskih zadataka u pomorskoj navigaciji prema potrebnoj točnosti položaja

Brojna istraživanja napravljena su s ciljem povezivanja točnosti određivanja položaja satelitskim sustavima i zahtjeva za točnošću određivanja položaja za potrebe pojedinih primjena (sustava i usluga). U narednom će poglavlju biti prikazan pregled i klasifikacija navigacijskih zadataka (tablica 17) kao i potrebna točnost određivanja položaja koji će nakon toga biti nadopunjen konkretnim primjerima navigacijskih zadataka kako u trgovačkoj tako i u ratnim mornaricama i obalnim stražama širom svijeta (poglavlje 4.1 i tablica 18). Početna klasifikacija u izvješću o pomorskim zahtjevima i potrebama sudionika u plovidbi brodova unutarnjim plovnim putevima (Report on maritime and inland waterways user needs and requirements - GSA 2018) odnosi se na navigacijske zadatke podijeljene u klase od A do B uz određene dodatne podjele unutar samih klasa u izvješću o pomorskim zahtjevima i potrebama sudionika u plovidbi brodova unutarnjim plovnim putevima (Report on maritime and inland waterways user needs and requirements - GSA, 2019). Isto tako, u radu su konzultirane rezolucije Međunarodne pomorske organizacije (engl. The International Maritime Organisation - IMO) (A.915(22); A.1046(27) te dodatak 17 rezolucije MSC.401(95)) s detaljnim prikazom općenitih navigacijskih zadataka u trgovačkoj mornarici s potrebnom točnošću određivanja položaja a što predstavlja važnu podlogu za daljnju razradu i nadopunu s navigacijskim zadacima u ratnim mornaricama i obalnim stražama diljem svijeta kao i potrebnom točnošću određivanja položaja. U dokumentu Volpe (2001) je sustavno ukazano na ranjivost satelitskog određivanja položaja te su predložene mjere za njihovo prevladavanje, posebno u području prometa i vezano za prometnu infrastrukturu. Studija nije razmatrala klasifikaciju usluga zasnovanih na satelitskoj navigaciji ni pojedinačne potrebe za točnošću određivanja položaja. Thomas i suradnici (2011) razmotrili su opću načelnu klasifikaciju usluga i sustava koji primjenjuju satelitsku navigaciju

i pokušali je povezati s potrebama za točnost određivanja položaja putem kategoričkih (kvalitativnih) zahtjeva. Studija nije sustavno obuhvatila potencijalne primjene satelitske navigacije, već je pružila tek holističku analizu potencijalnih klasa primjena satelitske navigacije bez egzaktnih numeričkih vrijednosti u zahtjevima za točnost satelitskog određivanja položaja po pojedinim klasama primjena satelitske navigacije (Rumora, Jukić, Filić, Filjar, 2018). Međunarodna pomorska organizacija napravila je klasifikaciju pomorskih primjena satelitske navigacije u nizu svojih rezolucija, kako je prikazano u GSA (2018). Rezolucije Međunarodne pomorske organizacije obuhvatile su cijeli niz navigacijskih zadataka s potrebnom točnošću određivanja položaja, definirale su klasifikaciju primjene satelitske navigacije u pomorskoj površinskoj navigaciji i iskazale potrebe za točnošću određivanja položaja za pojedine zadatke u pomorskoj površinskoj navigaciji. Klase navigacijskih zadataka odnose se na oceansku i obalnu navigaciju, plovidbu u lukama i unutarnjim plovnim putovima kao i plovidbu kod prilaza lukama i morskom prostoru s ograničenom mogućnošću manevriranja, kako je prikazano u GSA (2018). Međunarodno udruženje uprava pomorske signalizacije i sredstava za pomorsku organizaciju (engl. International Association of Marine Aids to Navigation and Lighthouse Authorities - IALA) također je u svojim priručnicima (IALA Navguide, 2018) i (VTS Manual, 2016) pokušalo raspodijeliti primjene satelitske navigacije u pomorskoj površinskoj navigaciji po određenim klasama te definirati tražene točnosti satelitskog određenog položaja, uz iskazivanje potreba za točnošću određivanja položaja. Navedeno međunarodno pomorsko udruženje obuhvaća navigacijske zadatke (Specht, 2018) na koje će biti nadograđeni kako navigacijski zadaci u ratnim mornaricama svijeta tako i na navigacijske zadatke u trgovačkoj mornarici s potrebnom točnošću određivanja položaja. Pomoć u navigaciji (obalna navigacija i plovidba unutarnjim plovnim putevima) koje pruža IALA sustav (Lopez, 2018) doprinijet će u velikoj mjeri izradi tablice 17 i 18 te konačnim prijedlogom navigacijskih zadataka i točnosti određivanja položaja uz daljnji razvoj i razmatranje u radovima koji slijede. Na kraju, Agencija za europski GNSS (GSA, 2018) napravila je vrlo sustavno istraživanje postojećih dokumenata i organizirala široku stručnu raspravu s ciljem sustavne i jasne definicije klasa primjena satelitske navigacije u pomorskoj površinskoj navigaciji te preslikavanja konkretnih kvantitativnih zahtjeva za točnost satelitskog određivanja položaja na definirane klase primjena u pomorskoj površinskoj navigaciji. Primjenom transparentne i na znanosti zasnovane metodologije, studija (GSA, 2018) je ujedno identificirala brojne nedostatke prethodnih pokušaja klasifikacije primjena satelitske navigacije u pomorskoj navigaciji, kao što su:

1. nemogućnost usporedbe različitih prijedloga za klasifikaciju primjena satelitske navigacije u pomorskoj površinskoj navigaciji uslijed nedostatka zajedničkog nazivlja, sustavnosti i objektivnosti pristupa, neuvažavanja različitih skupina korisnika,
2. nemogućnost identifikacije jedinstvenog međunarodno priznatog dokumenta ili standarda koji bi sustavno obuhvatio sve primjene satelitske navigacije u pomorskoj površinskoj navigaciji,
3. nedosljednost i ozbiljne razlike u iskazanim zahtjevima za točnost satelitskog određivanja položaja za iste i slične vrste zadataka u pomorskoj površinskoj navigaciji,
4. nedostatak sljedivosti i dokaza za iskazane zahtjeve za točnost satelitskog određivanja položaja za pojedine primjene u pomorskoj površinskoj navigaciji,
5. postojanje generičkog prikaza do određene razine razmatranja navigacijskih zadataka s potrebnom točnošću određivanja položaja u dokumentima IMO, pripremljenim od strane iste organizacije,
6. pravno važeći dokumenti (IMO) uvažavaju u većoj mjeri temeljne i relevantne navigacijske zadatke i njihovu točnost određivanja položaja te
7. nepostojanje scenarija primjene i opisa okoliša za određivanje položaja koji bi trebali pratiti specifikacije traženih točnosti za pojedine zadatke u pomorskoj površinskoj navigaciji.

Studija je (GSA, 2018) metodički analizirala različite prijedloge klasifikacija i zahtjeva za kvalitetu određivanja položaja satelitskim sustavima u pomorskoj površinskoj navigaciji te napravila njihovu međusobnu usporedbu, kako je prikazano tablicom 8. Klasifikacija po operativnim pomorskim područjima nametnula se kao prirodna tijekom analize i usporedbe različitih prijedloga zahtjeva za kvalitetu određivanja položaja u pomorskoj površinskoj navigaciji. Analiza je obuhvatila sva četiri parametra kvalitete određivanja položaja satelitskim sustavima: točnost određivanja položaja, dostupnost usluge određivanja položaja, integritet sustava i usluge određivanja položaja te kontinuitet određivanja položaja. Kao rezultat, studija je predstavila vlastiti prijedlog klasifikacije primjena satelitske navigacije u pomorskoj navigaciji s konkretnim kvantitativnim zahtjevima za sva četiri obilježja kvalitete određivanja položaja, zasnovano na pregledu literature i odzivima anketiranih i intervjuiranih stručnjaka. Studija je pridonijela razumijevanju problema uvažavajući najnoviji napredak u razvoju jezgrenih satelitskih navigacijskih sustava, poput uvođenja trofrekvencijskih sustava. Međutim, studija je ostala ograničena na relativno uski skup sudionika ankete, čime nije obuhvatila brojna

iskustva pomoraca i njihove potrebe u specifičnim scenarijima primjene satelitske navigacije u pomorskoj površinskoj navigaciji. Posebno, studija (GSA, 2018) nije razmatrala primjenu satelitske navigacije u području rada ratne mornarice i obalne straže što je u ovom slučaju napravljeno temeljem operativnog iskustva sudionika u brojnim operacijama (EU vođene operacije, NATO standardi (engl. NATO Standard Agreement – NATO STANAG)) diljem svijeta (konkretni operativni rad na navedenim navigacijskim zadacima (tablica 18) i potrebnom točnošću određivanja položaja (tablica 17) na brodovima saveznika u multinacionalnom okruženju) iz kojeg su i proistekli navigacijski zadaci (tablica 18) s potrebnom točnošću određivanja položaja (tablica 17), već je do sada prikazana samo osnovna i esencijalna primjena navigacijskih zadataka s potrebnom točnošću određivanja položaja koja se odnosi na civilne primjene u pomorskoj površinskoj navigaciji.

Tablica 8. Usporedna analiza zahtjeva za kvalitetom određivanja položaja satelitskim sustavima različitih izvora, kao rezultat studije (izvor: GSA, 2018)

Faza navigacije	**Točnost (metar, 2DRMS)**				**Dostupnost %/period**		**Kontinuitet (iznad 15 min)**		**Integritet (zona alarma/za 3 sata)**			**Vrijeme do alarma (s)**	
	IMO	**MAR**	**FRP**	**IHO**	**IMO**	**FRP**	**IMO**	**FRP**	**IMO**	**MAR**	**FRP**	**IMO**	**FRP**
Oceanska	10 – 100	10	1800 – 3700	30 – 420	99,8 30 dana	99 12 h	N/A	*	25/ 10^{-5}	25/ 10^{-5}	TBD	10	TBD
Obalna	10	10	460	5 – 10	99,8 30 dana	99,7	N/A	*	25/ 10^{-5}	25/ 10^{-5}	TBD	10	TBD
Prilaz lukama i ograničenim vodama	10	10	8 – 20**	5 – 10	99,8 30 dana	99,7	99,97	*	25/ 10^{-5}	25/ 10^{-5}	TBD	10	TBD
Plovidba u lukama	1	1	–	2	99,8 30 dana	–	99,97	*	2,5/ 10^{-5}	2,5/ 10^{-5}	–	10	–
Plovidba unutarnjim plovnim putovima	10	3	2 – 5	2	99,8 30 dana	99,9	99,97	*	25/ 10^{-5}	7,5/ 10^{-5}	TBD	10	TBD

Međunarodna pomorska organizacija ima za cilj razvijanje i održavanje sveobuhvatnog okvira za pomorsku plovidbu. Pomorski korisnički segment (engl. Maritime user segment - MARUSE) usredotočen je na razvoj tehnologije kao i njene primjene u ključnim pomorskim aplikacijama. Savezni plan za radionavigaciju (engl. Federal US Radionavigation Plan - FRP) službeni je izvor kod planiranja za pozicioniranje, navigaciju i vremensko određivanje savezne vlade. Međunarodna hidrografska organizacija (engl. International Hydrographic Organisation - IHO)

osigurava da se sva svjetska mora, oceani i plovni putevi pregledaju i ucrtaju na karti, podržavajući tako sigurnost plovidbe i zaštitu morskog okoliša.

Uvažavanjem ranijih navoda, metodologija razvoja klasifikacije korištena za potrebe studije (GSA, 2018) prepoznata je kao razumna, sustavna i objektivna te je tako iskorištena i u ovom istraživanju, kao što je predstavljeno u poglavlju 4.

3.2. Postupak procjene položaja satelitskim sustavom

Opći postupak procjene (određivanja) položaja satelitskim navigacijskim sustavom prikazan je u potpoglavlju 2.3, i zasnovan na prikazanoj literaturi (Parkinson, Spilker, Jr, 1996) koji pokazuje kako je metoda procjene položaja satelitskim sustavom rješenje optimizacijskog problema sa zadanom funkcijom troška i ograničenjima. Filić (2017) pokazuje kako se prikladnom definicijom optimizacijskog problema mogu postići učinci popravaka ciljanih utjecajnih veličina, u navedenom slučaju ionosferskog kašnjenja, unutar postupka procjene položaja, umjesto prethodnim popravcima izmjerenih pseudoudaljenosti pomoću modela popravaka. Filić, Filjar, Ruotsalainen (2016) razvili su trodomenski model postupka procjene položaja satelitskim sustavom, koji rastavlja postupak na sljedeće tri domene:

1. domena radiofrekvencija,
2. domena osnovnog frekvencijskog područja te
3. domena procjene položaja (navigacijska domena).

Prikazan je trodomenski model postupka procjene položaja u programski određenom GNSS prijamniku te potencijali iskorištavanja nepopravljenih (izvornih) mjerenih pseudoudaljenosti za određivanje položaja uz korištenje posebno biranih postupaka popravaka rezultata mjerenja pseudoudaljenosti i postupaka određivanja položaja vezano za zahtjeve primjene (Filić, Filjar, 2018b). Na kraju, Filjar, Huljenić i Lenac (2013) predložili su fleksibilnu raspodijeljenu arhitekturu GNSS prijamnika koji u izabranim područjima primjena ne treba nužno biti izveden kao samostojeći.

3.3. Model pogrešaka procjene položaja satelitskim sustavom

Tradicionalni pristup analizi pogrešaka procjene položaja satelitskim sustavom zasnovan je na eksperimentalnim opažanjima ukupnih pogrešaka određivanja položaja, njihovom rastavu na geometrijsku degradaciju točnosti (GDOP) i komponente korisničke razdiobe pogrešaka (UERE), kako je prikazano u potpoglavlju 2.4. Popravci mjerenih pseudoudaljenosti izvedeni

su u obliku ciljanih eksperimentalnih fizikalnih modela za svaki pojedinačni uzrok, odnosno utjecajnu veličinu koja ga je izazvala (Sanz Subirana i suradnici, 2013).

Karakterizaciju pogrešaka određivanja položaja satelitskim sustavom i pogrešaka mjerenja pseudoudaljenosti postiže se korištenjem aditivnog modela, kako je prikazano izrazom (40) (Filić, Filjar, 2018a).

$$p_{GNSS} = \epsilon_{trend} + \epsilon_{sezonalna} + \epsilon_{slučajna} \tag{40}$$

Model pretpostavlja tri komponente ε_{trend}, $\varepsilon_{sezonalna}$, i $\varepsilon_{slučajna}$, koje zbrojene daju ukupnu pogrešku određivanja položaja p_{GNSS}, kako slijedi.

Komponenta trenda ε_{trend} obuhvaća linearni doprinos ukupnoj pogreški koji tijekom vremena ostaje nepromijenjen, odnosno raste ili pada konstantnom brzinom rasta ili opadanja.

Sezonalna komponenta $\varepsilon_{sezonalna}$ obuhvaća doprinos ukupnoj pogreški čiji se uzorak dinamike ponavlja tijekom odgovarajućeg dužeg vremenskog razdoblja.

Slučajna komponenta $\varepsilon_{slučajna}$ obuhvaća sve doprinose ukupnoj pogreški koji imaju stohastičku (slučajnu) narav i ne mogu se obuhvatiti prethodnim komponentama.

Primjer proračuna pogrešaka zasnovan na načelnim karakterističnim doprinosima ukupnoj pogreški određivanja položaja prikazan je u potpoglavlju 2.4. Navedeni primjer treba shvatiti okvirno, s obzirom kako postoji vrlo široki raspon događaja u okolišu postupka za određivanje položaja, u kojem udjeli pojedinih uzroka pogrešaka mogu biti različiti i po apsolutnom i po relativnom iznosu.

Razumijevanje proračuna pogrešaka satelitskog određivanja položaja u različitim uvjetima okoliša za određivanje položaja od fundamentalnog je značaja za održivu primjenu satelitske navigacije kao temeljnog stupa suvremene civilizacije koja sve više ovisi o navedenoj tehnologiji. Znanstvenici diljem svijeta istražuju obilježja kvalitete satelitske navigacije u različitim scenarijima stanja okoliša za određivanje položaja i scenarijima primjene GNSS sustava, kako bi pronašli zajednička obilježja i na njima zasnovane modele procjene pogreške.

Satelitski navigacijski prijamnik (korisnički uređaj) pristupa problemu pogrešaka određivanja položaja na jedan od četiri tradicionalna načina:

1. Ne poduzima ništa, jer je postignuta pogreška određivanja položaja satelitskim sustavom u granicama prihvatljivosti.

2. Koristi standardne modele popravaka pogrešaka mjerenja pseudoudaljenosti: model popravaka ionosferskog kašnjenja, model popravaka troposferskog kašnjenja i model popravaka pogreške satelitskog sata (Parkinson, Spilker, Jr, 1996; Teunissen, Montenbruck, 2017).
3. Koristi napredne samostojeće postupke određivanja položaja (npr. postupak procjene položaja zasnovan na metodi najmanjih kvadrata s težinskim koeficijentima (Filić, 2017).
4. Koristi dodatne satelitske navigacijske sustave (engl. Satellite-Based Augmentation System – SBAS), integrirane sustave ili postupke zasnovane na dodatnim izvorima informacija trećih strana (diferencijski GNSS, lokalni ili regionalni modeli popravaka pogrešaka mjerenja pseudoudaljenosti, kinematičko određivanje položaja u stvarnom vremenu, engl. Real-Time Kinematics – RTK) (Sanz Subirana i suradnici, 2013; Smart, 2013; GSA, 2018).

U nastavku će biti ukratko prikazani standardni modeli popravaka mjerenja pseudoudaljenosti.

Pogreška satelitskog sata (posmak) δt_{sat} može se popravljati standardnim modelom čiji su parametri dostavljani putem navigacijske poruke. Za sustav GPS, model je predstavljen polinomom drugog stupnja, oblika prikazanog izrazom (41),

$$\delta t_{sat} = a_0 + a_1 \cdot (t - t_0) + a_2 \cdot (t - t_0)^2 \tag{41}$$

gdje su:

δt_{sat^t} … pogreška satelitskog sata (posmak)

t_0 … referentno vrijeme epohe (Sanz Subirana i suradnici, 2013),

t *… vremenski trenutak u kojem se određuje posmak satelitskog sata,*

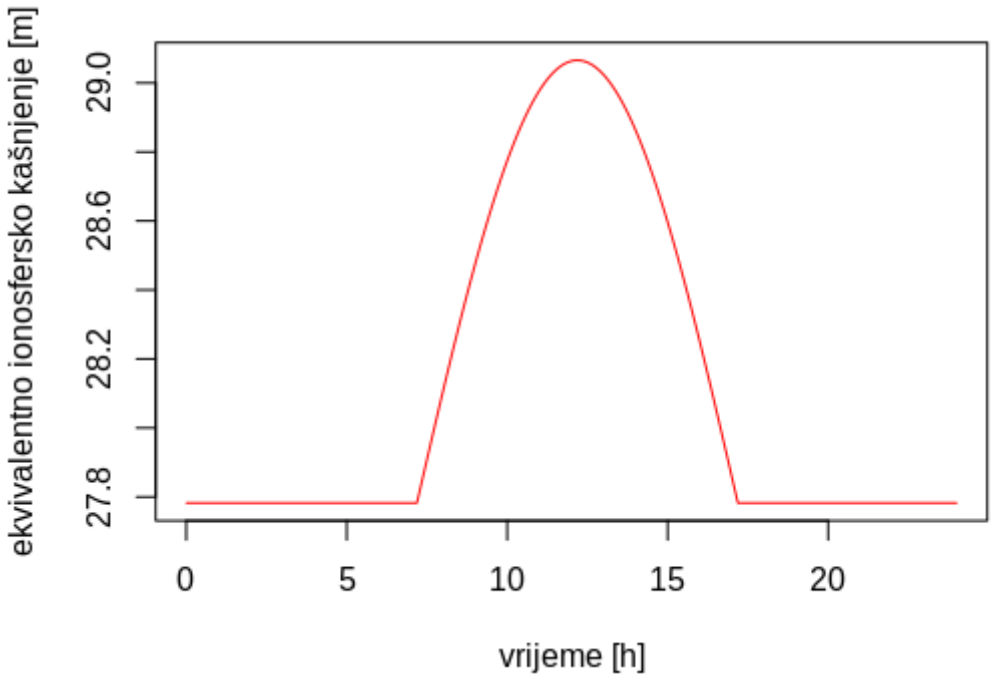
a_0, a_1, a_2 … koeficijenti modela poslani navigacijskom porukom.

Kako je troposfersko kašnjenje tema razmatranja ove disertacije, modeli popravaka troposferskog kašnjenja bit će razmotreni u zasebnom narednom poglavlju.

Ionosfersko kašnjenje predstavlja najznačajniji pojedinačni uzrok pogrešaka određivanja položaja satelitskim sustavom. GNSS prijamnici koji istovremeno rade na dvije frekvencije valova nositelja primat će istovremeno dvije različite kodne sekvence za mjerenje

pseudoudaljenosti. Time se postiže gotovo potpuno uklanjanje učinaka ionsoferskog kašnjenja (Sanz Subirana i suradnici, 2013).

Jednofrekvencijski prijamnici koji koriste sustave GPS i Beidou imaju na raspolaganju standardni model popravaka ionosferskog kašnjenja, nazvanog još i Klobucharov model prema tvorcu modela J. A. Klobucharu (Parkinson, Spilker, Jr, 1996). Model je eksperimentalne naravi i koristi uočenu pravilnost u dnevnom hodu ionosferskog kašnjenja, prikazanog slikom 21, uz pretpostavku koncentracije cjelokupne ionosfere u infinitezimalno tankom sloju na visini od 350 km iznad razine mora.



Slika 21. Klobucharov model dnevnog hoda ionosferskog kašnjenja satelitskog signala za određivanje položaja

Stvarno ionosfersko kašnjenje izraženo ekvivalentnom pogreškom mjerenja udaljenosti Δd_{iono} izražava se umnoškom vertikalnog ionosferskog kašnjenja Δd_{vert} i vrijednosti funkcije preslikavanja koja za argument ima elevacijski kut *el* pod kojim korisnički GNSS prijamnik vidi satelit s kojeg prima signal za mjerenje pseudoudaljenosti *m(el)*, kako je prikazano izrazom (42). Funkcija preslikavanja preslikava stvarni put satelitskog signala (satelitske zrake) na okomicu (normalu) na tangentu u točki u kojoj se nalazi GNSS prijamnik (Parkinson i Spilker, Jr, 1996; Higham i suradnici, 2015). Vrijednost funkcije preslikavanja je bezdimezionalna.

$$\Delta d_{iono} = m(el) \cdot \Delta d_{vert} \tag{42}$$

Funkcija preslikavanja *m(el)* određena je izrazom (43), gdje su:

$$m(el) = (1 - (\frac{R_E}{R_E + h} \cdot cos(h))^2)^{\frac{-1}{2}} \tag{43}$$

gdje su:

el ... elevacijski kut satelita,

R_E *... polumjer Zemlje (= 6378 km),*

h ... visina koncentriranog infinitezimalnog ionosferskog sloja (za GPS = 350 km, za Beidou = 375 km).

Vertikalno ionosfersko kašnjenje satelitskog signala za mjerenje pseudoudaljenosti (izraženo vremenskim jedinicama) može se odrediti temeljem eksperimentalnog modela (npr. Klobucharov model za sustave GPS, Beidou i Glonass (Parkinson i Spilker, Jr, 1996)), koji uvažava dnevni hod ionosferskog kašnjenja sa slike 21, prema izrazu (44), pri čemu je t vremenski trenutak za koji se određuje vertikalno ionosfersko kašnjenje satelitskog signala, ϕ = 1400 sati lokalnog vremena, a amplituda A i period P sezonalne kosinusne komponente dnevnog hoda ionosferskog kašnjenja satelitskog signala određeni izrazima (45) i (46), uz korištenje parametara $(\alpha_i, i = 1, \dots, 4)$ i $(\beta_i, i = 1, \dots, 4)$, odaslanih u navigacijskoj poruci (Parkinson, Spilker, Jr, 1996). Trenutak u kojem se pojavljuje vršna dnevna vrijednost ionosferskog kašnjenja (1400 h lokalnog vremena) definiran je Klobucharovim modelom, na temelju eksperimentalnih opažanja. Iako je Sunce u zenitu u 1200 h lokalnog vremena, zbog vremenske konstante ionizacijskih procesa, maksimum ionizacije postiže se približno dva sata kasnije (Davies, 1990; Parkinson i Spilker, Jr, 1996).

$$\begin{gathered} \Delta \mathrm{d}_{\mathrm{vert}} = 5\mathrm{ns}, \mathrm{za} \frac{2 \cdot \pi \cdot (\mathrm{t} - \phi)}{\mathrm{P}} \geq \frac{\pi}{2} \\ \Delta \mathrm{d}_{\mathrm{vert}} = 5\mathrm{ns} * \mathrm{A} \cdot \cos \frac{2 \cdot \pi \cdot (\mathrm{t} - \phi)}{\mathrm{P}}, \mathrm{za} \frac{2 \cdot \pi \cdot (\mathrm{t} - \phi)}{\mathrm{P}} < \frac{\pi}{2} \end{gathered} \tag{44}$$

$$A = \sum_{i=1}^{4} \cdot \alpha_i \cdot \phi_m^{n-1} \tag{45}$$

$$P = \sum_{i=1}^{4} \cdot \beta_i \cdot \phi_m^{n-1} \tag{46}$$

Parametri modela su globalne naravi, pa i sam model ima globalno pokrivanje, uz nemogućnost opisivanja lokalnih anomalija (Parkinson i Spilker, Jr, 1996).

Parametar ϕ_m predstavlja geomagnetsku širinu položaja korisnika (približna vrijednost još uvijek će dati dovoljno dobre rezultate procjene ionosferskog kašnjenja).

Nedostaci globalnog Klobucharovog modela vidljivi su čim nastupe značajniji ionosferski poremećaji ili pri pojavi lokalnih poremećaja koje globalni model teško obuhvaća. Njihovo prevladavanje je moguće korištenjem lokalnih ili regionalnih modela, kao što je regionalni model korišten u dodatnom sustavu (engl. European Geostationary Navigation Overlay Service – EGNOS).

Satelitski navigacijski sustav Galileo koristi klimatski model prognoze ionosferskog kašnjenja satelitskog signala za mjerenje pseudoudaljenosti poznat kao NeQuick (Sanz Subirana i suradnici, 2013). Satelitski navigacijski sustav GLONASS u dijelu satelita koji koriste frekvencijski dijeljen višestruki pristup (engl. Frequency Division Multiple Access – FDMA). Korištenje većeg broja frekvencija vala nosioca omogućilo je potpuno prevladavanje učinaka ionosferskog kašnjenja pri mjerenju pseudoudaljenosti unutar domene osnovnog frekvencijskog područja (Sanz Subirana i suradnici, 2013). Modernizacija sustava GLONASS znači prijelaz na kodno dijeljen višestruki pristup (engl. Code Division Multiple Access – CDMA) kao npr. i kod GPS-a i to na frekvencijama L1 i L5 (najmanji šum od GPS signala ima signal na navedenoj frekvenciji), što će značiti kako modernizirani GLONASS traži primjenu odgovarajućeg modela popravaka ionosferskog kašnjenja za koji je izabran Klobucharov model.

3.4. Modeli popravaka troposferskog kašnjenja satelitskog signala za određivanja položaja

Popravak učinaka troposferskog kašnjenja na točnost određivanja položaja satelitskim sustavom predstavlja zahtjevan problem zbog dvaju složenih čimbenika:

1. Ne postoji referentni način određivanja stvarnog troposferskog kašnjenja s kojim bi bilo moguće usporediti prognoze dobivene kandidatima modela na širim geografskim područjima, za razliku od npr. ionosferskog kašnjenja gdje dvofrekvencijski način rada u potpunosti uklanja neželjene učinke ionosfere.
2. Dinamika promjena vremena odvija se na vrlo malom prostoru, što izaziva neočekivanu povremenu pojavu izražene slučajne komponente troposferskog kašnjenja, koja uz to

jako ovisi o putanji dolaska satelitske zrake na korisničku antenu (elevacijski i azimutalni kut).

Satelitska zraka dolazi do antene GNSS prijamnika pod različitim elevacijskim i azimutalnim kutevima, ovisno o trenutnom položaju satelita gledano iz perspektive GNSS prijamnika. Slično problemu ionosferskog kašnjenja, različiti elevacijski kutevi značit će kako satelitska zraka prolazi različiti stvarni put kroz troposferu, što je važno jer u području troposfere uvjet širenja zrake brzinom svjetlosti u vakuumu nije zadovoljen (Parkinson i Spilker, Jr, 1996). Također, zbog dinamike troposfere i promjena fizikalnih obilježja zračnih masa, elevacijski i azimutalni kut odredit će i prolaz kroz područja s nepovoljnim obilježjima propagacije satelitske zrake (Parkinson i Spilker, Jr, 1996; Grabner i Kvicera, 2011; Sanz Subirana i suradnici, 2013). Sve navedeno rezultira vrlo promjenjivim vrijednostima troposferskog kašnjenja koje je teško modelirati i prognozirati. Preslikavanje stvarnog troposferskog kašnjenja po stvarnom putu zrake na normalizirano troposfersko kašnjenje na normali na tangentu u točki položaja GNSS prijamnika (Higham i suradnici, 2015) putem funkcije preslikavanja omogućuje objektivnu usporedbu troposferskih učinaka koji nastaju pod različitim elevacijskim i azimutalnim kutevima (Marini, 1971; Niell, 1996; Parkinson i Spilker, Jr, 1996; Gavranić, 2019).

Slično modelu ionosferskog kašnjenja, eksperimentalni modeli troposferskog kašnjenja određuju ukupno kašnjenje kao umnožak vertikalnog troposferskog kašnjenja i parametra ovisnog o elevacijskom kutu prijama satelitskog signala (Hopfield, 1971; Parkinson i Spilker, Jr, 1996; Schueler, 2001; Gavranić, 2019). Atipično, vertikalno troposfersko kašnjenje i težinski faktor ovisan o kutu elevacije određuju se za suhi i mokri zrak na međusobno neovisne načine, kako će biti predstavljeno za Saastamoinenov model kao standardni model troposferskog kašnjenja satelitskog navigacijskog signala u nastavku teksta (Saastamoionen, 1971; Parkinson i Spilker, Jr, 1996; Zhang, 1999; Sanz Subirana i suradnici, 2013; Gavranić, 2019).

Znanstveni rad na razvoju modela popravaka troposferskog kašnjenja nastavlja se na podlozi istraživanja propagacija radiovalova troposferom, koje su u XX. stoljeću izvodile najprije vojne snage svjetskih velesila, a zatim i velike telekomunikacijske kompanije. Sedamdesetih godina XX. stoljeća nastali su i danas standardni eksperimentalni modeli vertikalnog troposferskog kašnjenja satelitskog signala, koje su razvili Helen S. Hopfield (Hopfield, 1971) i Jaakka Saastamoinena (Saastamoinen, 1972). Njihovi radovi su sažeti, provjereni i dodatno razmotreni u nizu kasnijih publikacija, poput Ajayi (1989) i Schueler (2001). Oba autora koristila su slične pristupe modeliranja troposferskog kašnjenja razdvajajući učinke uslijed suhe i mokre komponente zraka te na opažanjima podešavali vrijednosti koeficijenata modela.

Određivanje težinskog faktora ovisnog o elevacijskom kutu razmatrao je Marini (1971). Na temelju njegovih razmatranja, Niell (1996) i (2000) je definirao eksperimentalnu funkciju preslikavanja koja vertikalno troposfersko kašnjenje satelitske zrake preslikava na stvarni troposferski put (stvarno troposfersko kašnjenje) čime je odredio težinski koeficijent za izračun ukupnog troposferskog kašnjenja za promatrani elevacijski kut.

Satelitski navigacijski prijamnici danas uobičajeno koriste Niellovu funkciju preslikavanja (Niell, 1996; Gavranić, 2019) i Saastamoinenov model (Saastamoinen, 1971; Parkinson i Spilker, Jr, 1996) za procjenu troposferskog kašnjenja satelitskog signala. Međutim, kako GNSS prijamnici za komercijalne negeodetske potrebe obično nemaju mogućnost mjerenja osnovnih meteoroloških parametara, GNSS prijamnici ih uzimaju na temelju standardne Zemljine atmosfere (ICAO, 1993). Takav pristup ostavlja dio sezonalne i slučajne pogreške mjerenja pseudoudaljenosti uslijed troposferskog kašnjenja satelitskog signala nepopravljenim (Schueler, 2001; Filić, Filjar, 2018c; Jukić, Rumora, Filić, Filjar, 2018).

Teorija nastanka troposferskog kašnjenja zasniva se na pojavi refrakcije (loma) satelitskog signala tijekom prolaska kroz troposferske slojeve, slično ionosferskom kašnjenju. Razlika postoji u naravi pojave refrakcije koja se u ionosferi javlja uslijed pojave nehomogenih ioniziranih slojeva, dok se u troposferi refrakcija javlja u neioniziranom mediju s različitim fizikalnim obilježjima (tlak, temperatura, parcijalni tlak vodene pare) (Stull, 2015).

Teorijski modeli obilježja troposfere vezani za propagaciju radio valova prikazani su u potpoglavlju 2.5. Međutim, provjere modela pokazale su nedostatke u praktičnoj primjeni teorijskih modela. Brojna eksperimentalna istraživanja pokazala su kako se reducirani indeks loma u troposferi može prikazati regresijskim izrazom (47) s koeficijentima određenim eksperimentalnim podacima, gdje su:

Parametri modela K_1, K_2 i K_3 određeni su eksperimentalnim istraživanjima (Schueler, 2001; Sanz Subirana i suradnici, 2013), čiji primjeri su prikazani tablicom 9.

$$N = K_1(p - e) + K_2\frac{e}{T} + K_3\frac{e}{T^2} \tag{47}$$

gdje su:

N ... reducirani indeks loma,

p ... tlak zraka,

T ... temperatura zraka te

e … parcijalni tlak vodene pare na mjestu određivanja položaja satelitskim sustavom (Schueler, 2001; Sanz Subirana i suradnici, 2013).

Tablica 9. Parametri modela reduciranog indeksa loma u troposferi, prema različitim autorima (preuzeto iz Martellucci, 2012).

Autori	**K_1 (1/hPa)**	**K_2 (K/hPa)**	**$K_3 \cdot 10^{-5}$ (K^2/hPa)**
Smith & Wintraub	77,607 ± 0,013	71,6 ± 8,5	3,747 ± 0,013
Thayer	77,64 ± 0,014	64,79 ± 0,08	3,776 ± 0,004
Hasegawa & Strokesb	77,6 ± 0,032	69,4 ± 0,146	3,701 ± 0,003
Liebe	77,676 ± 0,023	71,631	3,74656
Bevis weighted	77,6	69,4	3,701
Bevis unweighted	77,6 ± 0,05	70,4 ± 2,2	3,739 ± 0 012
Rueger best available	77,695 ± 0,013	71,97 ± 10,5	3,75406 ± 0,03
Rueger best average	77,689 ± 0,0094	71,295 ± 1,3	3,75463 ± 0,0076

Opći model troposferskog kašnjenja GNSS satelitskog signala aditivne je prirode. Ukupni iznos troposferskog kašnjenja T_{ukupno} obuhvaća komponente troposferskog kašnjenja uslijed suhog ($T_{suhogzraka}$) i vlažnog (mokrog, $T_{vlažnogzraka}$) zraka (Schueler, 2001; Sanz Subirana i suradnici, 2013), kako je prikazano izrazom (48).

$$T_{ukupno} = T_{suhogzraka} + T_{vlažnogzraka} \tag{48}$$

Kao što je već ranije rečeno, ukupno stvarno troposfersko kašnjenje (STK) sastoji se od suhog i mokrog vertikalnog troposferskog kašnjenja (VTK), ponderiranog odgovarajućim težinskim funkcijama preslikavanja (Schueler, 2001; Sanz Subirana i suradnici, 2013), kako je prikazano izrazom (49).

$$STK(E,h) = m_s(E,h) \cdot ZSK + m_m(E,h) \cdot ZMK \tag{49}$$

gdje su:

ZSK … zenitno suho (hidrostatičko) kašnjenje

ZMK … zenitno mokro kašnjenje

E … kut elevacije

h … nadmorska visina prijamnika izražena u (km)

m_s (E, h)… funkcija preslikavanja vertikalnog na stvarno suho (hidrostatičko) troposfersko kašnjenje

$m_v(E, h)$ … funkcija preslikavanja vertikalnog na stvarno vlažno (mokro) troposfersko kašnjenje

Funkcija preslikavanja prema Niellu (Niell, 1996; Niell, 2000) definirana je pomoću prikaza na slici 22, gdje su:

α ... *azimut*

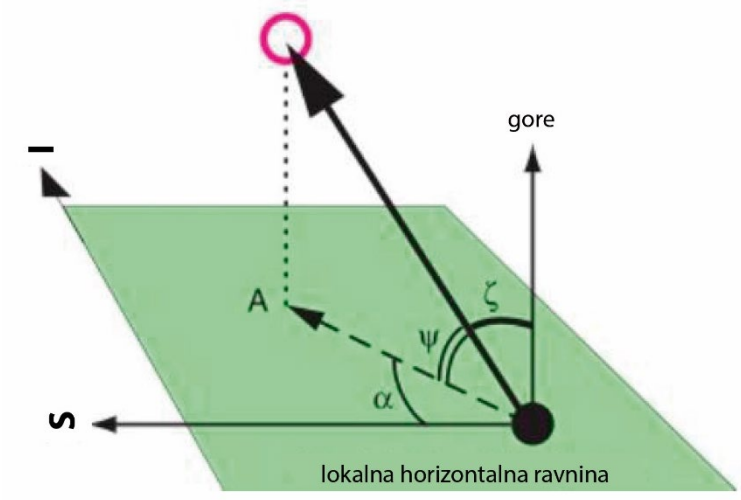
ψ ... *elevacija*

ζ ... *zenitni kut* ($\zeta = \pi/2 - \psi$)

S ... smjer sjevera

A ... smjer azimuta

I ... smjer istoka



Slika 22. Definicija Niellove funkcije preslikavanja

Niellova funkcija preslikavanja za suhi zrak definirana je kako je prikazano izrazom (50), gdje su:

E … kut elevacije (rad),

h … nadmorska visina (km) te

a_d, b_d, c_d … eksperimentalno dobiveni regresijski koeficijenti modela komponente suhog zraka, s detaljima u nastavku teksta.

$$m_s(E,h) = m(E, a_d, b_d, c_d) + \frac{dm}{dh}(E,h) \tag{50}$$

Pri tome se drugi član na desnoj strani izraza (50) određuje prema (51), gdje su:

E … kut elevacije (rad),

h … nadmorska visina (km) te

a_{ht}, b_{ht}, c_{ht} … eksperimentalno dobiveni regresijski koeficijenti modela suhog zraka, s detaljima u nastavku teksta.

$$\frac{dm}{dh}(E,h) = (\frac{1}{sin(E)} - m(E, a_{ht}, b_{ht}, c_{ht})) \cdot h \tag{51}$$

Niellova funkcija preslikavanja za mokri zrak određuje se prema izrazu (52), gdje su:

E … kut elevacije (rad),

h … nadmorska visina (km) te

a_w, b_w, c_w … eksperimentalno dobiveni regresijski koeficijenti modela suhog zraka, s detaljima u nastavku teksta.

$$m_v(E,h) = m(E, a_w, b_w, c_w) \tag{52}$$

Odnosni koeficijenti *ai, bi, ci,*$i \in \{d, ht, w\}$ obiju Niellovih funkcija preslikavanja određuju se interpolacijom iz tablice 10 (suhi zrak) i tablice 11 (mokri zrak), prema parametru $\xi(\phi, t)$ definiranom izrazom (53),

$$\xi(\phi, t) = \xi(\phi) - \xi(\phi) cos\left(2\frac{\pi \cdot t - \phi_0}{365{,}25}\right) \tag{53}$$

gdje su:

ϕ *... geografska širina mjesta za koje se određuje troposfersko kašnjenje,*

t ... broj dana od 1. siječnja tekuće godine (DOY ... Day Of the Year),

ϕ_0 *... ima vrijednost 28 (sjeverne geografske širine), odnosno 211 (južne geografske širine) (Schueler, 2001; Sanz Subirana i suradnici, 2013).*

Funkcija *m(E, a, b, c)* naziva se Marinijevo preslikavanje i općenito se definira analitički kako je prikazano u (54) (Schueler, 2001; Sanz Subirana i suradnici, 2013; Gavranić, 2019).

$$m(E,a,b,c) = \frac{1 + \dfrac{a}{1 + \dfrac{b}{1+c}}}{sin(E) + \dfrac{a}{sin(E) + \dfrac{b}{sin(E)+c}}} \tag{54}$$

Za određivanje vrijednosti komponenata mokrog i suhog zraka ukupnog troposferskog kašnjenja potrebno je uzeti odgovarajuće parametre iz donjih tablica.

Tablica 10. Koeficijenti funkcije preslikavanja za mokri zrak (prema: Sanz Subirana i suradnici, 2013)

Koeficijent Ξ	**Širina (φ)**				
	15°	**30°**	**45°**	**60°**	**75°**
A	5,8021897e-4	5,6794847e-4	5,8118019e-4	5,9727542e-4	6,1641693e-4
B	1,4275268e-3	1,5138625e-3	1,4572752e-3	1,5007428e-3	1,7599082e-3
C	4,347296 le-2	4,6729510e-2	4,3908931e-2	4,4626982e-2	5,4736038e-2

Tablica 11. Koeficijenti funkcije preslikavanja za suhi zrak (prema: Sanz Subirana i suradnici, 2013)

Koeficijent	**Širina (φ)**				
Ξ	**15°**	**30°**	**45°**	**60°**	**75°**
	Prosječna				
A	1,2769934e-3	1,2683230e-3	1,2465397e-3	1,2196049e-3	1,2045996e-3
B	2,9153695e-3	2,9152299e-3	2,9288445e-3	2,9022565e-3	2,9024912e-3
C	62,610505e-3	62,837393e-3	63,721774e-3	63,824265e-3	64,258455e-3
	Amplituda				
A	0,0	1,2709626e-5	2,6523662e-5	3,4000452e-5	4,1202191e-5
B	0,0	2,1414979e-5	3,0160779e-5	7,2562722e-5	11,723375e-5
C	0,0	9,0128400e-5	4,3497037e-5	84,795348e-5	170,37206e-5
	Korekcija visine				
a_{ht}			2,53e-5		
b_{ht}			5,49e-3		
C_{ht}			1,14e-3		

Vrijednosti komponenata vertikalnog troposferskog kašnjenja mogu se odrediti na temelju opaženog stanja troposfere pomoću eksperimentalnih modela predstavljenih u nastavku. Vertikalna (zenitna) komponenta suhog zraka određena je izrazom (55),

$$ZSK = \frac{0.0022767 \cdot p}{1 - 0.00266 \cdot cos(2\phi) - 0.00028 \cdot h} \tag{55}$$

gdje su:

p … tlak zraka,

ϕ … geografska širina na kojoj se nalazi korisnički prijamnik te

h … nadmorska visina antene korisničkog prijamnika (Schueler, 2001; Sanz Subirana i suradnici, 2013).

Zenitna komponenta mokrog zraka ima složeniji karakter, kako je prikazano definicijskim izrazom (56) koji akumulira učinke mokrog zraka po putu (visini) prolaza satelitskog signala (Schueler, 2001; Sanz Subirana i suradnici, 2013). Komponenta mokrog zraka određena je

temperaturom zraka T i parcijalnim tlakom vodene pare e, koji se mijenjaju s nadmorskom visinom (Schueler, 2001; Sanz Subirana i suradnici, 2013).

$$ZMK = 10^{-3} \cdot \int_{h_0}^{\infty} \cdot (K_2{}' \frac{e}{T} + K_3 \frac{e}{T^2}) dh \tag{56}$$

Parametri modela (56) vezani su izrazom (57), gdje su:

M_s = 28,9644 g/mol,
M_v = 18,0152 g/mol (Schueler, 2001; Sanz Subirana i suradnici, 2013).

$$K_2{}' = K_2 - K_1 \frac{M_v}{M_s} \tag{57}$$

Korištenjem standardnog modela atmosfere, meteorološki parametri mogu se odrediti bez stvarnog mjerenja interpolacijama prema tablici 12 (Schueler, 2001; Sanz Subirana i suradnici, 2013), gdje su:

P … tlak zraka (hPa),

T … temperatura zraka (K),

e … parcijalni tlak vodene pare (hPa),

β … stopa opadanja temperature (K/m) te

λ … stopa opadanja parcijalnog tlaka vodene pare (bezdimenzionalno)

Tablica 12. Meteorološki parametri modela za eksperimentalno određivanje troposferskog kašnjenja

Geografska širina (°)	**Srednja vrijednost**				
	P_0 (hPa)	**T_0 (K)**	**e_0 (hPa)**	**B_0 (K/m)**	**λ_0**
15 ili manje	1013,25	299,65	26,31	$6{,}30 \cdot 10^{-3}$	2,77
30	1017,25	294,15	21,79	$6{,}05 \cdot 10^{-3}$	3,15
45	1015,75	283,15	11,66	$5{,}58 \cdot 10^{-3}$	2,57
60	1011,75	272,15	6,78	$5{,}39 \cdot 10^{-3}$	1,81
75 ili više	1013,00	263,65	4,11	$4{,}53 \cdot 10^{-3}$	1,55
Geografska širina (°)	**Srednja vrijednost**				
	ΔP (hPa)	**ΔT (K)**	**Δe (hPa)**	**$\Delta\beta$ (K/m)**	**$\Delta\lambda$**
15 ili manje	0,00	0,00	0,00	$0{,}00 \cdot 10^{-3}$	0,00
30	–3,75	7,00	8,85	$0{,}25 \cdot 10^{-3}$	0,33
45	–2,25	11,00	7,24	$0{,}32 \cdot 10^{-3}$	0,46
60	–1,75	15,00	5,36	$0{,}81 \cdot 10^{-3}$	0,74
75 ili više	–0,50	14,50	3,39	$0{,}62 \cdot 10^{-3}$	0,30

U navedenom pristupu, određivanje vertikalnih (zenitnih) vrijednosti troposferskog kašnjenja može se napraviti primjenom izraza (58) i (59). Izrazi (58) i (59) prikazuju vrijednosti suhog i mokrog kašnjenja na nadmorskoj visini h=0 (Schueler, 2001; Sanz Subirana i suradnici, 2013).

$$ZSK(h=0) = \frac{10^{-6} \cdot k_1 \cdot R_d \cdot P}{g_m} \tag{58}$$

$$ZMK(h=0) = \frac{10^{-6} \cdot k_2 \cdot R_d \cdot P}{(\lambda+1) \cdot g_m - \beta \cdot R_d} \frac{e}{T} \tag{59}$$

Komponente zenitnog troposferskog kašnjenja na nadmorskoj visini h tada se mogu odrediti prema eksperimentalnim izrazima (60) i (61) (Schueler, 2001; Sanz Subirana i suradnici, 2013).

$$ZSK(h) = (1 - \frac{\beta \cdot h}{T})^{\frac{g}{R_d \cdot \beta}} \cdot ZSK(h=0) \tag{60}$$

$$ZMK(h) = (1 - \frac{\beta \cdot h}{T})^{\frac{(\lambda+1)\cdot g}{R_d \cdot \beta} - 1} \cdot ZSK(h = 0) \tag{61}$$

Odgovarajući koeficijenti gornjih modela definirani su kako slijedi: h je nadmorska visina korisničke antene izražena u (m), k_1 = 77,604 (K/hPa), k_2 = 382000 (K^2/hPa), R_d = 287,054 J/(kg K), g_m = 9,784 m/s^2 i g=9,80665 m/s^2 (Schueler, 2001; Sanz Subirana i suradnici, 2013).

Izraz (61) može se aproksimirati izrazom (62) (Schueler, 2001; Sanz Subirana i suradnici, 2013),

$$ZVK \approx \frac{\frac{10^{-6} \cdot R_d}{g_m} \cdot K_3}{\frac{T_M}{\lambda + 1}} \cdot e_0 \tag{62}$$

gdje je:

T_M *... efektivna srednja temperatura stupca zraka iznad prijamnika (K) i ostali elementi kako je navedeno u ranijim izrazima.*

Gornji izraz (62) vrijedi uz uvjet (63), gdje su:

e_0 *... parcijalni tlak vodene pare na nadmorskoj visini h=0 te*

p_0 *... tlak zraka na nadmorskoj visini h=0 (Schueler, 2001; Sanz Subirana i suradnici, 2013).*

$$e = e_0(\frac{p}{p_0})^{\lambda+1} \tag{63}$$

Efektivna srednja temperatura stupca zraka iznad prijamnika određuje se prema izrazu (64) (Schueler, 2001; Sanz Subirana i suradnici, 2013)

$$T_M = \frac{\int_{h_0}^{\infty} \cdot \frac{e}{T} dh}{\int_{h_0}^{\infty} \cdot \frac{e}{T^2} dh} \tag{64}$$

Akceleracija sile teže u središtu mase zraka g_m (m/s^2) određena je eksperimentalnim izrazom (65) (Schueler, 2001; Sanz Subirana i suradnici, 2013).

$$g_m g(\phi, h_0) = 9{,}784 \cdot (1 - 0{,}00266 \cdot cos(2\phi) - 0{,}00028 \cdot h_0) \tag{65}$$

Pitanje je očekivane točnosti modela. Neki modeli podrazumijevaju nepromjenjivu vrijednost akceleracije sile teže dok je drugi uzimaju kao odnosni parametar pa uključuju eksperimentalne modele za njeno detaljno određenje. Tijekom razvoja satelitskih navigacijskih sustava, razvijeno je nekoliko eksperimentalnih modela za prognozu troposferskog kašnjenja GNSS

signala. Hopfield (1971) uvodi jednostavan model popravaka GNSS troposferskog kašnjenja, prikladan za primjenu u jednostavnim satelitskim navigacijskim prijamnicima tadašnjeg doba. Model je predstavljen izrazima za hidrostatičku (suhi zrak, ZHD) (66) i hidrodinamičku (vlažni zrak, ZWD) komponentu (67).

$$ZHD = 0{,}62291\left[\frac{m \cdot K}{hPa}\right] \cdot \frac{1}{T_0} + 0{,}0023081\left[\frac{m}{hPa}\right] \cdot p_0 \tag{66}$$

$$ZWD = 0{,}07402\left[\frac{K^2}{hPa}\right] \cdot \frac{e_0}{T_0^2} \cdot H^2 \tag{67}$$

Otprilike u isto vrijeme razvijen je i nešto kompleksniji Saastamoinen model (Saastamoinen, 1971) koji je tijekom razvoja satelitske navigacije postao standardni model popravaka GNSS troposferskog kašnjenja (Teunissen iMontenbruck, 2017). Saastamoinenov model je analitički prikazan izrazom (68).

$$d_{Saast}[m] = \frac{2{,}277 \cdot 10^{-3}}{cos(z)} \cdot \left(p_0 + \left(\frac{1255}{T_0} + 0{,}005\right) \cdot e_0 - 1{,}16tan^2(z)\right) \tag{68}$$

Zenitni kut *z* određen je izrazom (69) (Schueler, 2001; Sanz Subirana i suradnici, 2013), gdje je :

E … elevacijski kut (slika 23).

$$z = \frac{\pi}{2} - E \tag{69}$$

Ostali elementi Saastamoinenovog modela određeni su prema (70) (Schueler, 2001; Sanz Subirana i suradnici, 2013).

$$\begin{gathered} h_0 = 0\ m \\ p_0 = 1013{,}25\ hPa \\ T = 273{,}15\ K + t_0\ [°C] \end{gathered} \tag{70}$$

Meteorološki elementi na traženoj nadmorskoj visini i u uvjetima prijamnika određeni su prema referentnim vrijednostima (indeks r) izrazima (71) – (73) (Schueler, 2001; Sanz Subirana i suradnici, 2013).

$$p = p_r \cdot \left(1 - 0{,}0000226 \cdot (h - h_r)\right)^{5{,}225} \tag{71}$$

$$T = T_r - 0{,}0065 \cdot (h - h_r) \tag{72}$$

$$H = H_r \cdot e^{-0{,}0006396 \cdot (h - h_r)} \tag{73}$$

Gravitacijski popravak je određen izrazom (74) (Schueler, 2001; Sanz Subirana i suradnici, 2013):

$$D = 0{,}0026 \cdot cos\left(2 \cdot \phi + 0{,}00028 \left[\frac{1}{km}\right] \cdot h_0\right) \tag{74}$$

Hopfieldin (60-61) i Saastamoinenov model (62) daju vrijednosti zenitnog troposferskog kašnjenja kakvo bi djelovalo na satelitski signal koji na granicu troposfere dolazi pod pravim kutom (Parkinson, Spilker, Jr, 1996; Schueler, 2001). U praksi, satelitski signali dolaze pod različitim zenitnim kutovima. Stvarno troposfersko kašnjenje dobiva se prema izrazu (75) (Schueller, 2001):

$$t_{tropo} = m(\theta_{suho}) \cdot tropo_{zen,suho} + m(\theta_{mokro}) \cdot tropo_{zen,mokro} \tag{75}$$

gdje su:

t_{tropo} … *ukupno troposfersko kašnjenje GNSS signala*

$m(\theta_{suho})$ … *funkcija preslikavanja sa zenitne suhe na stvarnu suhu komponentu*

$tropo_{zen,\ suho}$ … *zenitno troposfersko kašnjenje suhog zraka, dobiveno odgovarajućim modelom popravaka troposferskog kašnjenja*

$m(\theta_{mokro})$ … *funkcija preslikavanja sa zenitne mokre na stvarnu mokru komponentu*

$tropo_{zen,\ mokro}$ … *zenitno troposfersko kašnjenje vlažnog zraka, dobiveno odgovarajućim modelom popravaka troposferskog kašnjenja*

Već je navedeno kako je (Niell, 1996; Niell, 2000) predstavio danas najčešće korištenu funkciju preslikavanja, kako za mokri, tako i za suhi zrak. Praktična izvedba Niellove funkcije preslikavanja ima jedinstveni oblik (76) za obje komponente GNSS troposferskog kašnjenja. Njeni koeficijenti definirani su izrazima (77) – (79). Vrijednosti osnovnih parametara za suhi, odnosno mokri zrak predstavljeni su u tablicama 13 i 14 za pojedinačne vrijednosti zenitnog kuta (Sanz Subirana i suradnici, 2013; Schueller, 2001) te koeficijenti visine prikazani tablicom 15.

$$m(z) = \frac{1 + \frac{a}{1 + \frac{b}{1 + c}}}{sin(\epsilon) + \frac{a}{sin(\epsilon) + \frac{b}{sin(\epsilon) + c}}} \tag{76}$$

$$\Delta m(\epsilon) = dm\frac{(\epsilon)}{dh} \cdot H_0 \tag{77}$$

$$a(\phi, DoY) = a(\phi, DoY)_{average} + a(\phi, DoY)_{amplitude} \cdot cos(\frac{2 \cdot DoY}{DoY_0}) \tag{78}$$

gdje su:

$a(\phi, DoY)$... *koeficijent funkcije preslikavanja (Niellove funkcije) (istosmjerna komponenta i amplituda)*

ϕ ... *geografska širina mjesta na kojem se određuje koeficijent a Niellove funkcije*

DoY ... dan u godini

DoY_0 ... dan u godini u koji pada 'vrhunac zime'

$$\frac{dm(\epsilon)}{dh} = \frac{1}{sin(\epsilon)} - f(\epsilon, a_{ht}, b_{ht}, c_{ht}) \tag{79}$$

Tablica 13. Vrijednosti parametara za suhi zrak za pojedinačne vrijednosti zenitnog kuta (izvor: Sanz Subirana i suradnici, 2013, Schueller, 2001)

$a_{sr.\ vrijednost}$	$\phi = 15°$	$\phi = 30°$	$\phi = 45°$	$\phi = 60°$	$\phi = 90°$
A	$1{,}2769934 \cdot 10^{-3}$	$1{,}2683230 \cdot 10^{-3}$	$1{,}2465397 \cdot 10^{-3}$	$1{,}2196049 \cdot 10^{-3}$	$1{,}2045996 \cdot 10^{-3}$
B	$2{,}9153695 \cdot 10^{-3}$	$2{,}9152299 \cdot 10^{-3}$	$2{,}9288445 \cdot 10^{-3}$	$2{,}9022565 \cdot 10^{-3}$	$2{,}9024912 \cdot 10^{-3}$
C	$62{,}610505 \cdot 10^{-3}$	$62{,}837393 \cdot 10^{-3}$	$63{,}721774 \cdot 10^{-3}$	$63{,}824265 \cdot 10^{-3}$	$62{,}258455 \cdot 10^{-3}$
$a_{mplituda}$	$\phi = 15°$	$\phi = 30°$	$\phi = 45°$	$\phi = 60°$	$\phi = 90°$
A	0,00	$1{,}2709626 \cdot 10^{-5}$	$2{,}6523662 \cdot 10^{-5}$	$3{,}4000452 \cdot 10^{-5}$	$4{,}1202191 \cdot 10^{-5}$
B	0,00	$2{,}1414979 \cdot 10^{-5}$	$3{,}0160779 \cdot 10^{-5}$	$7{,}2562722 \cdot 10^{-5}$	$11{,}723375 \cdot 10^{-5}$
C	0,00	$9{,}0128400 \cdot 10^{-5}$	$63{,}721774 \cdot 10^{-5}$	$84{,}795348 \cdot 10^{-5}$	$170{,}37206 \cdot 10^{-5}$

Tablica 14. Vrijednost parametara za mokri zrak za pojedinačne vrijednosti zenitnog kuta (izvor: Sanz Subirana i suradnici, 2013; Schueller, 2001)

$A_{vlažni\ zrak}$	ϕ = 15°	ϕ = 30°	ϕ = 45°	ϕ = 60°	ϕ = 90°
A	5,8021897 10^{-4}	5,6794847 10^{-4}	5,8118019 10^{-4}	5,9727542 10^{-4}	6,1641693 10^{-4}
B	1,4275268 10^{-3}	1,5138625 10^{-3}	1,4572752 10^{-3}	1,5007428 10^{-3}	1,7599082 10^{-3}
C	4,3472961 10^{-2}	4,6729510 10^{-2}	4,3908931 10^{-2}	4,4626982 10^{-2}	5,4736038 10^{-2}

Tablica 15. Koeficijenti visine

	Koeficijent visine
a_{ht}	2,53 10^{-3}
b_{ht}	5,49 10^{-3}
c_{ht}	1,14 10^{-3}

Prediktori (opisne, ulazne veličine) koji određuju GNSS troposfersko kašnjenje opisani su u tablici 16.

Tablica 16. Prediktori troposferskog kašnjenja GNSS signala

Prediktor	**Oznaka (Mjerna jedinica)**	**Uobičajeno područje vrijednosti**
Temperatura zraka	T (°C)	(-40, 50)
Atmosferski tlak	p (hPa)	(880, 1060)
Vlažnost zraka	H (%)	(40, 100)
Parcijalni tlak vodene pare	e (hPa)	Određeno trenutnim atmosferskim tlakom i vlažnošću zraka
Parcijalni tlak zasićene vodene pare	e_s (hPa)	Određeno trenutnim atmosferskim tlakom, temperaturom zraka i vlažnošću zraka
Zenitni kut	Θ (rad)	(0, π/2)

Postoji nekoliko izvora meteoroloških opažanja prikladnih za korištenje u znanstvenim istraživanjima. Neke GNSS referentne stanice međunarodne GNSS mreže (IGS, 2019) su opremljene meteorološkim stanicama koje kontinuirano opažaju vrijednosti prediktora iz

tablice 16 i pohranjuju dnevna opažanja meteoroloških parametara s razdobljem uzimanja uzoraka od 15 minuta (IGS, 2018). Internetska baza na istoj internetskoj stranici međunarodne GNSS mreže (IGS, 2019) omogućuje pristup meteorološkim opažanjima prikupljenim meteorološkim stanicama nacionalnih meteoroloških ureda diljem svijeta. Internetska baza je uređena na volonterskoj osnovi.

Istraživanja su pokazala kako je komponenta suhog zraka slabo promjenjiva i svojim doprinosom uglavnom dominira u ukupnom GNSS troposferskom kašnjenju (Sanz Subirana i suradnici, 2013; Schueller, 2001). Vlažna komponenta iskazuje znatno veću varijabilnost. Njezin doprinos ukupnom GNSS troposferskom kašnjenju postaje usporediv s doprinosom suhe komponente u razdobljima brzih i velikih promjena vremena, kad ukupno GNSS troposfersko kašnjenje počinje iskazivati povećanu dinamiku slučajne naravi (Sanz Subirana i suradnici, 2013; Schueller, 2001; Filić, Filjar, 2018a; Filić, Filjar, 2018c; Rumora, Jukić, Filić, Filjar, 2018). Vrijednosti ekvivalentnog GNSS troposferskog kašnjenja (vremensko kašnjenje množeno s vrijednosti brzine svjetlosti u vakuumu) uobičajeno se nalaze u rasponu (0, 4) m (Filić, Filjar, 2018c).

Na kraju je potrebno napomenuti kako su od tri glavna pojedinačna doprinosa pogreški određivanja položaja uz troposfersko i ionosfersko kašnjenje zasigurno i višestazni put. Glavni uzrok nastajanja višestaznog puta je bliskost antene s reflektirajućim strukturama što posebno dolazi do izražaja kada signal dolazi sa satelita na male nadmorske visine odnosno na morsku površinu pri valovitom moru (Soubielle i Fijalkow, 2002; Duvaut i Bibaut, 2002).

Višestazni odraz izvornog satelitskog signala koji putuje kao ravna linija uzrokuje primanje određenog broja signala s istom frekvencijom vala nositelja i različitim prijeđenim putovima u anteni prijamnika. Kao rezultat toga, primljeni signal izgleda kao da je prešao veću udaljenost nego što je zapravo slučaj, uzrokujući pritom pogrešku mjerenja pseudoudaljenosti, a time i točnost određivanja položaja (Brown, 2000).

Morski valovi povećavaju vjerojatnost odbijanja satelitskog signala, čineći tako pomorsko okruženje sklonom višestaznim putanjama (Brown, 2000).
Pogoršanje signala uslijed višestaznih putanja može potjecati od različitih vrsta refleksije. Signal se može odražavati preprekama poput zgrada ili površinom tla i mora. Na temelju geometrijskih uvjeta u blizini antene, jedan satelitski signal može se odraziti nekoliko puta (Sanz Subirana i suradnici, 2013).

Parametar kuta maske, koji se obično koristi za suzbijanje efekata višestaznih putova, postavljen je na 15 ° (Brown, 2000).

3.5. Nedostaci postojećih modela

Iz razmatranja u ovom poglavlju može se uočiti visoki stupanj složenosti troposferskog kašnjenja, ali i postojećih eksperimentalnih modela koji ga opisuju. Općenito, troposfersko kašnjenje doprinosi ukupnoj pogreški određivanja položaja manje nego neki drugi uzroci (ionosfersko kašnjenje i višestazni putovi). Međutim, složenost pojave i naznačena slučajna komponenta kašnjenja, posebno u kritičnim scenarijima razvoja vremenske nepogode, može izazvati zamjetan doprinos troposferskih učinaka ukupnoj pogreški satelitskog određivanja položaja (Filić, Filjar, 2018c; Rumora, Jukić, Filić, Filjar, 2018). Postojeći tradicionalni modeli troposferskog kašnjenja imaju prema van okrenutu složenost koja je izražena velikim brojem parametara korištenim u složenim analitičkim izrazima. Matematička složenost za sobom povlači i složenost u praktičnoj provedbi i operativnoj primjeni, s obzirom na to da algoritamske i kodne izvedbe postaju vrlo složene. Na kraju, navedena analitička složenost znači zadržavanje izvorne strukture modela, bez prostora za fleksibilnost i adaptivnost različitim stanjima troposfere i mogućnostima uspješnog modeliranja.

Primjena standardnih modela troposferskog kašnjenja također ima svoje nedostatke. Standardni modeli razvijeni su tako da sadržavaju globalnu narav, iako s naglaskom na ponašanje vremena na srednjim geografskim širinama. Usprkos navedenom blagom otklonu, modeli ne opisuju ni jednu konkretnu okolinu, budući da su razvijeni usrednjavanjem lokalnih meteoroloških obilježja s različitih krajeva svijeta. Rezultat je to i primjene standardne Zemljine atmosfere za opis trenutne meteorološke situacije, jer su u trenucima razvoja modela bili pretpostavljeni korisnički prijamnici za satelitsku navigaciju bez mogućnosti mjerenja stvarnih meteoroloških parametara (Filić, Filjar, 2018c). Također, postojeći eksperimentalni modeli troposferskog kašnjenja imaju visoku razinu složenosti zbog velikog broja parametara ugrađenih u čvrstu (nepromjenjivu) strukturu koja treba biti poznata analitički kako bi model bio ispravno primijenjen.

Navedeno prilično ograničava uspješan popravak učinaka troposfere i ostavlja otvorenim pitanje stvarnog doprinosa (udjela) troposferskih učinaka u ukupnoj pogreški satelitskog određivanja položaja. Slijedom razmatranja, navedene nejasnoće preslikavaju se u područje navigacijskih i nenavigacijskih primjena satelitskih navigacijskih sustava u smislu održivosti kvalitete na satelitskoj navigaciji zasnovanih usluga i sustava (Filić, Filjar, 2018a).

4. PRIJEDLOG PROGNOSTIČKOG MODELA TROPOSFERSKOG DOPRINOSA UKUPNOJ POGREŠKI SATELITSKOG ODREĐIVANJA POLOŽAJA ZA POMORSKU POVRŠINSKU NAVIGACIJU

Navedeno poglavlje odnosi se na klasifikaciju navigacijskih zadataka u pomorskoj površinskoj navigaciji, zatim na model preslikavanja troposferskog kašnjenja satelitskog signala za određivanje položaja i točnosti određivanja položaja satelitskim sustavom te model povezivanja troposferskog kašnjenja signala za satelitsko određivanje položaja i zahtjevima za točnost određivanja položaja pojedinih klasa. U ovoj disertaciji razmatraju se učinci troposferskog kašnjenja na točnost određivanja položaja satelitskim sustavom, kao i posljedice narušavanja točnosti određivanja položaja satelitskim sustavom na rizike korištenja satelitske navigacije za potrebe klasa navigacijskih i nenavigacijskih zadataka u pomorskoj površinskoj navigaciji s ciljem razvoja prognostičkog modela. Provedeno istraživanje predstavljeno u ovoj disertaciji povezuje do sad nepovezane elemente lanca okoliš-tehnologija-primjena-korisnici, čime disertacija ostvaruje znanstveni doprinos teorijskom razumijevanju održive kvalitete primjene satelitske navigacije u različitim segmentima, s izravnom primjenom i učincima na procese u praksi pomorske navigacije. Istraživanje je razmatrano isključivo samostalno, nepotpomognuto određivanje položaja satelitskim navigacijskim sustavom, uz korištenje jednofrekvencijske korisničke opreme komercijalne naravi za potrebe u pomorskoj površinskoj navigaciji.

4.1. Prijedlog klasifikacije navigacijskih zadataka u pomorskoj površinskoj navigaciji

Pregledom prethodnih istraživanja u potpoglavlju 3.1. ustanovljena je potreba za klasifikacijom navigacijskih usluga i sustava (zadataka, primjena) zasnovanih na satelitskoj navigaciji prema zahtjevima za točnost određivanja položaja, kako bi se procijenila izloženost usluga i sustava narušavanju točnosti satelitskog određivanja položaja te razmotreni potencijalni učinci korištenja satelitskog navigacijskog sustava s narušenom kvalitetom određivanja položaja u pomorskoj površinskoj navigaciji koji nastaju uslijed navedenog uzroka.

Thomas i suradnici (2011) pokazali su kvalitativnu podjelu navigacijskih i nenavigacijskih zadataka u pomorskoj površinskoj navigaciji po klasama s kategoričkim vrijednostima traženih točnosti određivanja položaja. GSA (2018) je dala sustavan i metodičan prijedlog numeričkih (kvantitativnih) zahtjeva za točnost satelitskog određivanja položaja na temelju dobrovoljne ankete pozvanih stručnjaka, uzimajući u obzir i neke nove očekivane usluge i sustave čija se izvedba još nalazi u pripremi.

U okviru istraživanja predstavljenih u ovoj disertaciji, napravljen je novi prijedlog klasifikacije navigacijskih i nenavigacijskih primjena satelitske navigacije s pripadnim zahtjevima za točnost određivanja položaja satelitskim sustavom. Klasifikacija primjena te procjena potrebne točnosti određivanja položaja napravljeni su na osnovi razmatranja GSA (2018), sudjelovanju u operativnom radu izvršavanja konkretnih navigacijskih zadataka na brodovima saveznika u multinacionalnom okruženju (tablica 18) s potrebnom točnošću određivanja položaja (tablica 17) kao i intenzivnoj suradnji s pomorcima koji koriste satelitsku navigaciju u operativnim poslovima u brojnim državama svijeta. Napravljena je provjera klasifikacije GSA (2018) te su dodane primjene, posebno u smislu mornaričkih zadataka, koje GSA (2018) nije obuhvatila. Klasifikacija GSA (2018) je korištena pri izboru uobičajenih navigacijskih zadataka (kao npr. kod klase 1 za traganje i spašavanje te oceansku i obalnu navigaciju, zatim klase 2 kod različitih operacija na brodovima u lukama i plovidbi kod prilaza lukama, te kod klase 3 za brodove koji se bave jaružanjem) s potrebnom točnošću određivanja položaja (tablica 17). Sve gore navedeno predstavlja temelj na kojem je ista nadograđena pojedinim specifičnim navigacijskim zadacima kako u trgovačkoj mornarici (bočno tegljenje, traganje i spašavanje za imigrantima u području Libije, naplavljivanje prostora ispod glavne palube kod RO-RO brodova, prekrcaj ljudstva i tehnike kod RO-RO brodova u plovidbi i dr.) tako i s obzirom na navigacijske zadatke (plovidba u konvojima, prekrcaj goriva s mornaričkih brodova u plovidbi, plovidba u radar masci obale kod mornaričkih brodova i dr.) s potrebnom točnošću određivanja položaja u mornaricama i obalnim stražama diljem svijeta. Za sve identificirane klase primjena satelitskog određivanja položaja u pomorskoj površinskoj navigaciji određeni su zahtjevi za točnost određivanja položaja međusobnom usporedbom iskazanih zahtjeva i njihovih obrazloženja u GSA (2018), iskustvu pomoraca i vlastitom iskustvu autora disertacije.

Kao rezultat istraživanja i razmatranja predstavljenih u potpoglavlju 3.1, predlaže se sljedeća klasifikacija navigacijskih i nenavigacijskih primjena satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, zajedno s predloženim kritičnim razinama pogrešaka kao zahtjevima za točnost, kako je predstavljeno tablicom 17. Zahtjevi za točnost određivanja

položaja za pojedine klase izraženi su najvećom prihvatljivom ukupnom pogreškom određivanja položaja. Prijedlog klasifikacije pojedinih navigacijskih zadataka u pomorskoj površinskoj navigaciji prema zahtjevima za točnost određivanja položaja satelitskim sustavom (tablica 18) potvrđuje se preko pomoćne hipoteze 1, dio hipoteze disertacije te predstavlja novi znanstveni doprinos.

Tablica 17. Klasifikacija navigacijskih zadataka u pomorskoj površinskoj navigaciji prema odgovarajućim zahtjevima za točnost satelitskog određivanja položaja

Klasa navigacijskih zadataka	Najveća prihvatljiva ukupna pogreška određivanja horizontalnog položaja u (m), u 95 % vremena i na 95 % površine Zemlje	Dodatni zahtjevi za točnost određivanja položaja
Klasa 1	10	Klasa 1 i Klasa 1+ iz (GSA, 2018)
Klasa 1A	3	Klasa 1++ iz (GSA, 2018)
Klasa 1B	10	Vertikalna točnost od 10 m, 95 % vremena, 95 % površine Zemlje. Klasa 1+++ iz (GSA, 2018)
Klasa 2	1	Klasa 2 i Klasa 2+ iz (GSA, 2018)
Klasa 2A	1	Vertikalna točnost od 1 m, 95 % vremena, 95 % površine Zemlje. Klasa 2++ iz (GSA, 2018)
Klasa 2B	1	Ublažena horizontalna točnost od 1 m do 2 m, 95 % vremena, 95 % površine Zemlje, vertikalna točnost od 0,1 m, 95 % vremena, 95 % površine Zemlje. Klasa 2+++ iz (GSA, 2018)
Klasa 3	0,1	Klase 3 i 3+ iz (GSA, 2018)
Klasa 3A	0,1	Točnost određivanja brzine 0,1 m/s. Klasa 3++ iz (GSA, 2018)

Tablica 18. Prijedlog klasifikacije pojedinih navigacijskih zadataka u pomorskoj površinskoj navigaciji prema zahtjevima za točnost određivanja položaja satelitskim sustavom

Prikaz klasa navigacijskih zadataka (uključujući zadatke ratne i trgovačke mornarice te navigacijske zadatke obalne straže)		
1	**2**	**3**
Traganje i spašavanje na moru	Polaganje podmorskih kabela i prekrcaj goriva s ratnih brodova u plovidbi	Jaružanje i konstrukcijski radovi
1A	**2A**	**3A**
Plovidba prilaza lukama i ograničenom području manevriranja (pratnja i osiguranje konvoja)	Operacija tegljača u lukama (uključujući i bočni tegalj)	Operacije: aktivnosti desantnih (ili RO-RO) brodova u plovidbi koji prekrcavaju ljudstvo i tehniku
1B	**2B**	**3B**
Plovidba unutarnjim plovnim putevima (plovidba u radar-masci obale za ratne/mornaričke brodove)	Lučke operacije (postavljanje brane za uljna onečišćenja)	Operacije: aktivnosti brodova kod naplavljivanja teretnog prostora ispod glavne palube

Navedeni navigacijski zadaci (tablica 18) odnose se na zadatke kako u trgovačkoj mornarici tako i u ratnim mornaricama i obalnim stražama diljem svijeta. Navigacijski zadaci u tablici 18 klasificirani su od broja 1 do broja 3 s obzirom na razinu točnosti određivanja položaja prema tablici 17 te sukladno operativnom iskustvu (konkretni operativni rad na brodovima posebno vezan za izvršavanje specifičnih navigacijskih zadataka s potrebnom točnošću određivanja položaja u multinacionalnom okruženju) s časnicima koji obnašaju visoke zapovjedne dužnosti na brodovima diljem svijeta.

Navigacijski zadaci klasificirani su s obzirom na konkretne zadaće koje izvode autor disertacije i gore navedeni časnici tijekom dužeg vremenskog razdoblja (od 2008. do 2017. godine) a što se između ostaloga odnosi i na specifične i intenzivne aktivnosti traganja i spašavanja na Mediteranu u području Libije, zatim plovidbi na brodovima u Velikoj Britaniji (ophodni brod i ratni/mornarički RO-RO brod, Royal Navy), trgovačkoj mornarici (putnički brodovi i brodovi za rasuti teret) kao i brodovi Obalne straže u RH i Obalne straže iz Turske kao i brojne druge plovidbe izvršene u RH i izvan nje a koje su dale doprinos za dobivene rezultate istraživanja odnosno specifične navigacijske zadatke i potrebnu točnost određivanja položaja a temeljenu na osnovnim navigacijskim zadacima prema tablici 17.

Prikazanim prijedlogom modela klasifikacije pomorskih primjena satelitske navigacije i povezivanja sa zahtjevima za točnost određivanja položaja prevladani su nedostaci modela GSA (2018), model je usredotočen na zahtjeve za točnost satelitskog određivanja položaja u pomorskim primjenama te obuhvaća i navigacijske zadatke i njihove zahtjeve za točnost određivanja položaja za potrebe ratne mornarice. Predloženi model uvažava najnovija postignuća u modernizaciji satelitskih navigacijskih sustava (uvođenje trofrekvencijskog rada i naprednih modulacijskih postupaka), novim konceptima prijamnika za satelitsku navigaciju koji omogućuju konstrukciju prijamnika s adaptivnim modelima popravaka (Filić Filjar, 2018a) i postupcima estimacije položaja (Filić, 2017) zasnovanim na mjerenjima neispravljenih pseudoudaljenosti (Filić, Filjar, 2018b) te transparentnost postupka određivanja položaja u raspodijeljenom smislu (Filjar, Huljenić i Lenac, 2013). Predloženi model obuhvaća i zahtjeve posebnih navigacijskih zadataka u pomorskoj površinskoj navigaciji, poput dinamičkog određivanja položaja (engl. Dynamic Positioning) (DNV, 2015; IMCA, 2006) za potrebe automatiziranog zadržavanja plovila iznad iste točke na dnu mora, kao i nadolazeće scenarije primjena u pomorskoj površinskoj navigaciji, kao što su ultra-brza plovila i bespilotna plovila (Hoppe, H., 2005; Smart, A., 2013; DNV, 2018; Bureau Veritas, 2017). Potrebe novih navigacijskih zadataka, poput prethodno navedenih, uvažene su prilikom razrade prijedloga klasifikacije.

4.2. Model preslikavanja troposferskog kašnjenja satelitskog signala za određivanje položaja i točnosti određivanja položaja satelitskim sustavom

Pogreška procjene položaja satelitskim navigacijskim sustavom je rezultat (Parkinson i Spilker, Jr, 1996):

1. pogreške u mjerenju pseudoudaljenosti,
2. pogreške u procjeni položaja satelita zasnovane na satelitskim efemeridama,
3. pogreške satelitskog sata.

Uz pretpostavku potpunog popravka učinaka pod (2) i (3) gore, u ovoj disertaciji je razvijen model propagacija pogreške mjerenja pseudoudaljenosti u pogrešku određivanja položaja, kako slijedi:

Definicija 5. Model procjene položaja satelitskim sustavom je model linearne regresije oblika (80),

$$\Delta\vec{y} = G \cdot \Delta\vec{x} + \vec{e} \tag{80}$$

gdje su:

$\Delta\vec{x}$ *... vektor pogrešaka varijabli stanja korisnika (koordinata procijenjenog položaja i nepoznate pogreške korisničkog sata),*

G ... matrica transformacija pseudoudaljenosti u položaj (geometrijska matrica),

$\Delta\vec{x}$ *... vektor pogrešaka izmjerenih pseudoudaljenosti te*

$\vec{e}$ *... vektor slučajnih pogrešaka uobičajeno opisan poznatim statističkim obilježjima: srednjom vrijednosti m = E(ε) i matricom kovarijanci R = E(εεT) (Sanz Subirana i suradnici, 2013).*

Problem određivanja vektora pogrešaka varijabli stanja korisnika $\Delta\vec{x}$ temeljem izraza (80) predstavlja optimizacijski problem (Boyd, Vandenberghe, 2004). Problem se formalno izražava na način prikazan izrazom (81), gdje je:

Rezultat optimizacijskog postupka je vektor pogrešaka varijabli stanja korisnika $\Delta\vec{x}$ za koji funkcija troška V($\vec{x}$) postiže svoj minimum.

$$\underset{\Delta\vec{x}}{argmin} V(\Delta\vec{x}) \tag{81}$$

gdje je:

$V(\vec{x})$ *... funkcija cilja.*

Postupak optimizacije eksperimentalnog modela obično se definira preko analize reziduala. Rezidual predstavlja razliku između vrijednosti prognozirane modelom i stvarno opažene vrijednosti za isti slučaj skupa vrijednosti ulaznih varijabli (prediktora). Funkcija cilja u konkretnom se slučaju može zapisati kao što je prikazanom izrazom (82) (Gustafsson, 2010).

$$V(\Delta\vec{x}) = (\Delta\vec{y} - H\Delta\vec{x})^{\tau} R^{-1} (\Delta\vec{y} - H\Delta\vec{x}) \tag{82}$$

U postupku pronalaženja minimuma funkcije cilja, njena prva derivacija može se prikazati kao u izrazu (83) (Gustafsson, 2010).

$$V'(\Delta\vec{x}) = 2 \cdot (-H^{\tau} R^{-1} \Delta\vec{y} + H^{\tau} R^{-1} \Delta\vec{x}) \tag{83}$$

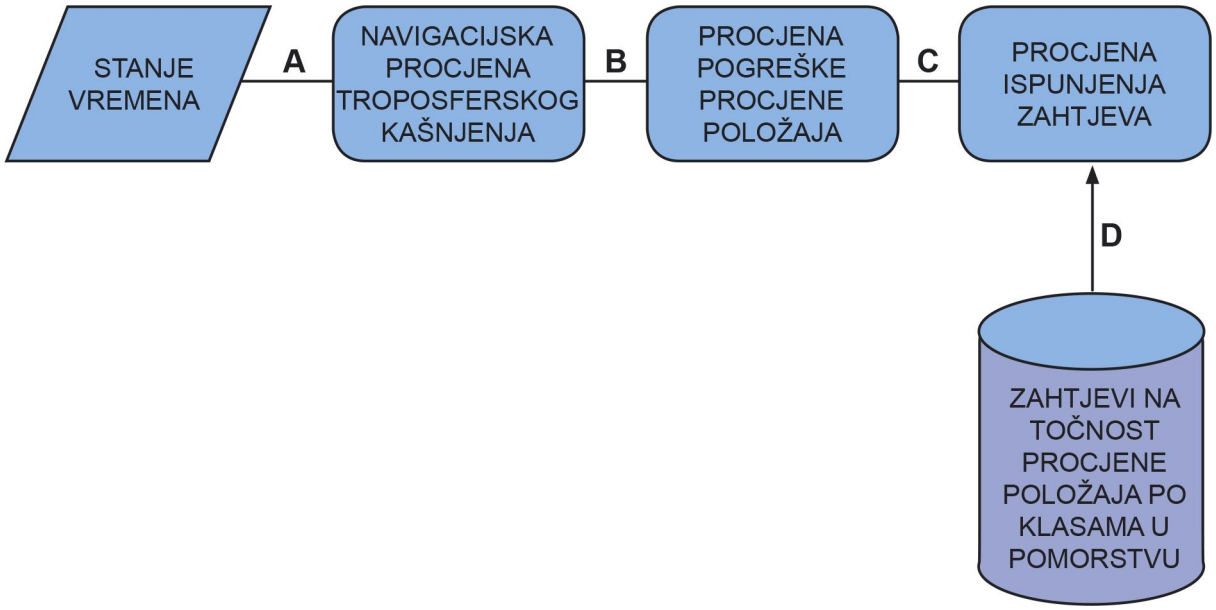
Izjednačavanjem lijeve strane (83) s nulom i rješenjem tako dobivene jednadžbe po $\Delta\vec{x}$, dobiva se izraz (84).

$$\Delta\vec{x} = (H^{\tau}R^{-1}H)^{-1}H^{\tau}R^{-1}\Delta\vec{y} \tag{84}$$

Izraz (84) predstavlja model propagacije pogrešaka mjerenja pseudoudaljenosti $\Delta\vec{y}$ na pogrešku određivanja položaja satelitskim navigacijskim sustavom $\Delta\vec{x}$.

4.3. Model povezivanja troposferskog kašnjenja signala za satelitsko određivanje položaja s pogreškom satelitskog određivanja položaja i zahtjevima za točnost određivanja položaja pojedinih klasa navigacijskih zadataka u pomorskoj površinskoj navigaciji

U ovoj disertaciji se predlaže model povezivanja troposferskog kašnjenja signala za satelitsko određivanje položaja s pogreškom satelitskog određivanja položaja i zahtjevima za točnost određivanja položaja pojedinih klasa navigacijskih zadataka, kako je prikazano slikom 23.



Slika 23. Model povezivanja troposferskog kašnjenja signala za satelitsko određivanje položaja s pogreškom satelitskog određivanja položaja i zahtjevima za točnost određivanja položaja pojedinih klasa navigacijskih zadataka

Predloženi model sastoji se od elemenata objašnjenih u poglavljima 2 i 3. Procjena troposferskog kašnjenja na temelju opažanja meteoroloških parametara može se obaviti u analitičkom obliku definiranim eksperimentalnim modelima, kao što je primjerice

Saastamoinenov model. Prijedlog postupka procjene pogreške određivanja položaja temeljem poznate pogreške mjerenja pseudoudaljenosti uslijed troposferskih učinaka prikazan je u ovoj disertaciji kao znanstveni doprinos koji proizlazi iz podhipoteze 2. Klasifikacija zadataka u pomorskoj površinskoj navigaciji prema zahtjevima za točnost određivanja položaja prikazana je u ovoj disertaciji kao znanstveni doprinos koji proizlazi iz podhipoteze 1.

U nastavku disertacije predstavljen je jedinstveni prognostički model udjela pogreške zbog troposferskih učinaka u ukupnoj pogreški satelitskog određivanja položaja.

Prognostički model je zasnovan na primjeni statističkog učenja na opažanjima meteoroloških parametara na području Jadranskog mora. Predloženim modelom moguće je izravno procijeniti pogrešku određivanja položaja zbog troposferskih učinaka i izravno je primijeniti na popravak procjene položaja, bez potrebe parcijalnog korištenja nefleksibilnih globalnih standardnih modela troposferskog kašnjenja. Predloženim pristupom model sa slike 23 postaje jednostavniji i izravno primjenjiv, uz uvažavanje lokalnih obilježja vremenskih promjena, budući da je razvijen na skupu opažanja prikupljenih na području Jadrana tijekom dužeg vremenskog razdoblja (siječanj – travanj 2019. godine). Metoda razvoja i provjere klimatološkog prognostičkog modela te izvorna opažanja korištena za razvoj modela opisani su u poglavlju 5. Iskorišteno je nekoliko metoda razvoja modela, zasnovano na statističkim obilježjima opažanja i nadziranom strojnom učenju, čime su dobiveni kandidati traženog modela udjela pogreške određivanja položaja satelitskim sustavom uslijed troposferskih učinaka. Izabran je najbolji model prema kriterijima uspješnosti u opisu sistematskih i slučajnih obilježja pogreške određivanja položaja uslijed troposferskog kašnjenja (sistematska pogreška i varijanca). Izbor najboljeg modela između niza kandidata razvijenih tijekom prikazanog istraživanja, kao i obilježja uspješnosti razmotreni su u poglavlju 6.

5. METODOLOGIJA RAZVOJA MODELA

U poglavlju je razmotren postupak razvoja predloženog prognostičkog modela kao i razmatranja kandidata modela putem korištenja metoda razvoja zasnovanih na nadziranom strojnom učenju i eksperimentalnim opažanjima. Prikazana je struktura modela. Definirani su prediktori (ulazne, opisne varijable) i ishod (ciljna, izlazna varijabla) modela. Razmotrene su tri osnovne metode nadziranog strojnog učenja iskorištene za razvoje modela (poglavlje 6). Definiran je postupak vrednovanja razvijenih modela i indikatori uspješnosti. Opisana je baza izvornih eksperimentalnih opažanja, okupljena u okviru istraživanja prikazanih ovom disertacijom. Na kraju, predložen je i izveden model preslikavanja ostvarene točnosti određivanja položaja uz djelovanje troposferskih učinaka na zahtjeve kategorija navigacijskih zadataka u pomorskoj površinskoj navigaciji.

5.1. Struktura modela

Prognostički model udjela pogreške satelitskog određivanja položaja zbog troposferskih učinaka satelitskog signala je u ovom radu zasnovan na opisnim parametrima stanja troposfere. Navedeni parametri koji izazivaju pojavu troposferskog kašnjenja GNSS satelitskih signala pojavljuju se kao prediktori modela prognoze udjela pogreške u određivanju položaja uslijed utjecaja troposfere. Prognostički model može se izraziti oblikom (85) (Strang, Borre, 1997; Filić, Grubišić, Filjar, 2017).

$$\vec{\epsilon}_{GNSS,tropo} = f(p, T, H) \tag{85}$$

gdje su:

$\vec{\epsilon}_{GNSS,tropo}$ *... vektor udjela pogreške zbog troposferskih učinaka, s komponentama izraženim u (m)*

p ... tlak zraka (hPa)

T ... temperatura zraka (°C)

H ... relativna vlažnost zraka (%)

f ... funkcija matematičkog modela.

U tradicionalnoj perspektivi, funkcija *f* definirana je kao kompozicija funkcija *g* i *h*, prema izrazima (86) – (88), uz d_{tropo} definiran kao ekvivalentno troposfersko kašnjenje izraženo u (m).

$$\vec{\epsilon}_{GNSS,tropo} = g \cdot h(p, T, H) = g(h(p, T, H)) \tag{86}$$

gdje su:

g ... funkcija koja definira doprinos troposferskog kašnjenja u ukupnoj pogreški satelitskog određivanja položaja d_{tropo} (89), uzimajući u obzir trenutnu geometriju satelita i korisničke opreme G (88)

h ... funkcija kojom se definira ekvivalentno troposfersko kašnjenje u (m), ovisno o prediktorima stanja troposfere (troposfersko kašnjenje pojavljuje se kao izlaz modela) (89)

$$\vec{\epsilon}_{GNSS,tropo} = g(d_{tropo}, G) \tag{87}$$

Matrica *G* ima komponente vezane za trenutne položaje satelita i korisničke opreme, prema (88).

$$G = \begin{pmatrix} \frac{x_u - x_{S1}}{R_1} & \frac{y_u - y_{S1}}{R_1} & \frac{z_u - z_{S1}}{R_1} & 1 \\ \frac{x_u - x_{S2}}{R_2} & \frac{y_u - y_{S2}}{R_2} & \frac{z_u - z_{S2}}{R_2} & 1 \\ \frac{x_u - x_{S3}}{R_3} & \frac{y_u - y_{S3}}{R_3} & \frac{z_u - z_{S3}}{R_3} & 1 \\ \frac{x_u - x_{S4}}{R_4} & \frac{y_u - y_{S4}}{R_4} & \frac{z_u - z_{S4}}{R_4} & 1 \end{pmatrix} \tag{88}$$

$$d_{tropo} = h(p, T, H) \tag{89}$$

Ulogu funkcije *h* u izrazu (89) može preuzeti Saastamoinenov model ili bilo koji drugi model troposferskog kašnjenja.

Ovim istraživanjem predložen je sljedeći model transformacije (preslikavanja) pogrešaka mjerenja pseudoudaljenosti ρ_i, i = 1, 2, …, *N*,

$$\vec{\epsilon}_{GNSS} \equiv \vec{\epsilon}_{GNSS,hor} + \vec{\epsilon}_{GNSS,ver} = \epsilon_{GNSS,x}\vec{\imath} + \epsilon_{GNSS,y}\vec{\jmath} + \epsilon_{GNSS,ver}\vec{k} \tag{90}$$

gdje je:

N ... broj satelitskih pseudoudaljenosti korištenih u procjeni položaja, na vektor pogreške određivanja položaja satelitskim sustavom određen izrazom (90).

Opaženo troposfersko kašnjenje određuje doprinos ukupnoj pogreški određivanja položaja satelitskim sustavom uslijed troposferskog kašnjenja (udio pogreške procjene položaja zbog troposferskog kašnjenja). Odnos nije linearan i definiran je prostornim odnosom između

položaja satelita čiji su signali korišteni za procjenu položaja i položaja korisnika, izraženim geometrijskom matricom *G* (88).

Općenito, pogreška određivanja položaja $\Delta\vec{\epsilon}_{GNSS}$ može se prikazati u ovisnosti o pogreški mjerenja pseudoudaljenosti $\Delta\vec{\rho}$ izrazom (91).

$$\Delta\vec{\epsilon} = G^{\tau}(WG)^{-1}G^{\tau}W\Delta\vec{\rho} \tag{91}$$

U izrazu (91), *W* predstavlja dijagonalnu matricu težinskih koeficijenata dobivenih rješenjem optimizacijskog problema čiji je oblik zadan izrazom (92).

$$\underset{W}{argmin}\|y - \hat{y}\|^2 = \underset{W}{argmin}\|\sum_{i=1}^{N} \cdot w_i \cdot (y_i - \hat{y})^2\| \tag{92}$$

Izraz (92) uključuje učinke svih pogrešaka određivanja položaja satelitskim sustavom.

Neka je moguće u potpunosti odrediti, a time i eliminirati učinke svih uzroka pogrešaka određivanja položaja satelitskim sustavom, osim učinaka troposferskog kašnjenja. Izmjerene pseudoudaljenosti sa satelita tada će sadržavati samo stvarne udaljenosti uvećane za pogreške mjerenja pseudoudaljenosti nastale isključivo uslijed učinaka troposferskog kašnjenja $\Delta\vec{\rho} = \Delta\vec{\rho}_{tropo}$. Navedena pogreška može se procijeniti npr. Saastamoinenovim modelom popravaka troposferskog kašnjenja, uz poznate prediktore stvarne vremenske situacije. Također, ukupna pogreška određivanja položaja satelitskim sustavom sadržavat će samo doprinos uslijed troposferskog kašnjenja $\vec{\epsilon}_{GNSS} = \vec{\epsilon}_{tropo}$. Uz uvažavanje gornje pretpostavke, moguće je definirati izraz za izračun udjela pogreške određivanja položaja uslijed troposferskog kašnjenja u ukupnoj pogreški određivanja položaja satelitskim sustavom $\Delta\vec{\epsilon}_{tropo}$, na temelju pogreške mjerenja pseudoudaljenosti zbog troposferskog kašnjenja $\Delta\vec{\rho}_{tropo}$, korištenjem izraza (93).

$$\Delta\vec{\epsilon}_{tropo} \equiv \vec{x}_{tropo} - \vec{x}_{pravo} = (G^{\tau}WG)^{-1}G^{\tau}W\Delta\vec{\rho}_{tropo} \tag{93}$$

Izrazom (93) definirano je preslikavanje pogreške mjerenja pseudoudaljenosti uslijed troposferskog kašnjenja na doprinos (udio) pogreške određivanja položaja satelitskim sustavom uslijed učinaka troposferskog kašnjenja (podhipoteza 2).

Ovo istraživanje usredotočeno je na primjenu satelitskih navigacijskih sustava u pomorskoj površinskoj navigaciji pa će se u nastavku teksta uzimati horizontalna pogreška određivanja položaja $\epsilon_{GNSS,hor}$ (94) kao izlazna vrijednost jedinstvenog izravnog modela (95).

$$\epsilon_{GNSS,hor} \equiv \|\vec{\epsilon}_{GNSS,hor}\| = \|\epsilon_{GNSS,x}\vec{\imath} + \epsilon_{GNSS,y}\vec{\jmath}\| = \sqrt{\epsilon_{GNSS,x}{}^2 + \epsilon_{GNSS,y}{}^2} \quad (94)$$

$$\epsilon_{GNSS,hor} = f(p,T,H) \quad (95)$$

Odnos između prediktora stanja troposfere $\{p_1, T_1, H_1\}$ i doprinosa horizontalnoj pogreški određivanja položaja $\epsilon_{GNSS,hor,tropo}$, kao izlazne (prognozirane) varijable modela, bit će određen trima kandidatima modela, definiranim postupcima strojnog učenja primijenjenim na masivne skupove eksperimentalnih opažanja oblika (96).

$$O = \begin{pmatrix} p_1 & T_1 & H_1 & \epsilon_{GNSS,hor,tropo,1} \\ . & . & . & . \\ p_N & T_N & H_N & \epsilon_{GNSS,hor,tropo,N} \end{pmatrix} \quad (96)$$

5.2. Prediktori i ishodi modela

Prediktori su ulazne veličine modela. Ishodi su izlazne veličine modela. U predloženom modelu prediktori su opisne veličine stanja troposfere koje definiraju vrijednost troposferskog kašnjenja: tlak zraka, temperatura zraka i relativna vlažnost zraka. Ishod predloženog modela, kao novi znanstveni doprinos je udio pogreške uslijed troposferskih učinaka u ukupnoj pogreški satelitskog određivanja položaja.

5.3. Postupci razvoja modela zasnovani na statističkom učenju nad eksperimentalnim opažanjima

Razvijeni kandidati modela zasnovani su na primjeni sljedećih postupaka strojnog učenja: (i) linearni model, (ii) model slučajne šume te (iii) model umjetne neuronske mreže s jednim, dvama i trima skrivenim slojevima. Navedeni postupci bit će razloženi u nastavku teksta.

5.3.1. Razvoj modela metodom linearne regresije

Procijenjena vrijednost izlazne varijable $\hat{y}$ određuje se iz vrijednosti ulaza (prediktora) pomoću modela zasnovanog na metodi linearne regresije (linearnog modela) (97), za jedinstveni prediktor opisan skalarnom vrijednošću x, odnosno (98), za višestruki prediktor predstavljen vektorom vrijednosti $\vec{x}$ (Efron, Hastie, 2016; Maindonald, Brown, 2010; Dalpiaz, 2019).

$$\hat{y} = f(x) = a \cdot x + b \quad (97)$$

$$\hat{y} = f(\vec{x}) = \vec{a} \cdot \vec{x} + b \tag{98}$$

Višestruki linearni model s *N* prediktora (ulaznih, neovisnih varijabli) može se prikazati poopćenim analitičkim izrazom (99) (Efron, Hastie, 2016; Maindonald, Brown, 2010; Dalpiaz, 2019).

$$\hat{y} = b + a_1 x_1 + a_2 x_2 + \cdots + a_N x_N = b + \sum_{i=1}^{N} \cdot a_i \cdot x_i \tag{99}$$

Linearni model u potpunosti je određen svojim koeficijentima *b, a_i, i = 1, …, N*. Koeficijenti eksperimentalnih modela određuju se na temelju matrice eksperimentalnih opažanja oblika (100) (Efron, Hastie, 2016; Dalpiaz, 2019):

$$O = \begin{pmatrix} x_{1,1} & x_{2,1} & \dots & x_{N,1} & y_1 \\ . & . & . & . & . \\ X_{1,p} & x_{2,p} & . & x_{N,p} & y_p \end{pmatrix} \tag{100}$$

Koeficijenti linearnog modela određeni su kao rješenje optimizacijskog problema minimizacije preostalih pogrešaka prognostičkog modela (reziduala) (Boyd, Vandenberghe, 2004; Efron, Hastie, 2016; Dalpiaz, 2019).

$$\underset{b,a_i,i=1,\dots,N}{argmin} \|\hat{y_i} - y_i\| \tag{101}$$

Rezidual je definiran kao razlike između prognozirane i stvarne vrijednosti ishoda, izrazom (102) uz korištenje *p* pojedinačnih prediktora (Efron, Hastie, 2016; Dalpiaz, 2019).

$$\epsilon_i = \|\hat{y_i} - y_i\| = \|(\sum_{j=1}^{N} \cdot a_j x_j) - y_j\|, i = 1, \dots, p \tag{102}$$

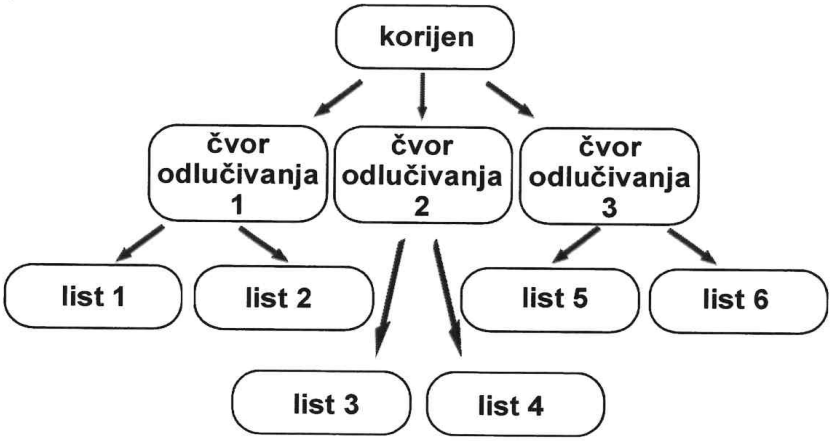
U jednostavnom slučaju jednostrukog prediktora, rješenje optimizacijskog problema daje vrijednosti koeficijenata *a* (103) i *b* (104) prema navedenim izrazima (Efron, Hastie, 2016; Dalpiaz, 2019).

$$a = \frac{\sum_{i=1}^{N} \cdot x_i \cdot y_i - \frac{1}{N} \cdot (\sum_{i=1}^{N} \cdot x_i \cdot \sum_{i=1}^{N} \cdot y_i)}{\sum_{i=1}^{N} \cdot x_i^2 - \frac{1}{N} \cdot (\sum_{i=1}^{N} \cdot x_i)^2} \tag{103}$$

$$b = \frac{\sum_{i=1}^{N} \cdot y_i - b \cdot \sum_{i=1}^{N} \cdot x_i}{N} \tag{104}$$

5.3.2. Model zasnovan na metodama stabla odlučivanja i slučajne šume

Model je zasnovan na strukturi koje podsjeća na stablo (slika 24) (Loupe, 2015; Efron, Hastie, 2016). Struktura se sastoji od korijena, čvorova grananja i listova, kao završnih odluka.



Slika 24. Struktura modela stabla odlučivanja

Razvoj modela stabla odlučivanja zasniva se na podjeli izvornog skupa opažanja na podskupove, pri čemu svaki podskup služi za razvoj modela po jednog stabla odlučivanja slučajne šume. Nakon razvoja modela, svaki novi slučaj daje se na odlučivanje svim stablima, a završni ishod (rezultat modela slučajne šume) dobiva se ili većinskim glasovanjem ili korištenjem modela odluke s težinskim koeficijentima. Općenito, postupak razvoja modela predstavlja rješenje optimizacijskog problema minimizacije zbroja kvadrata reziduala, kako je prikazano izrazom (105) (Hastie, Tibshirani, Friedman, 2008).

$$min\| \sum_{b=1}^{B} \cdot \left(f_B\,(X') - \widehat{f_1}\right)^2 + \sum_{b=1}^{B} \cdot (f_B\,(X') - \widehat{f_2})^2 \| \tag{105}$$

gdje su:

B *... optimalan broj uzoraka/stabala*

f_B *... stablo klasifikacije ili regresije, za b=1,...,B*

$\hat{f}$ *... predviđanja za nevidljive uzorke X' mogu se dobiti usrednjavanjem*

predviđanja iz svih pojedinačnih stabala regresije X':

X' ... pojedinačna stabla regresije ... predviđanja za nevidljive uzorke

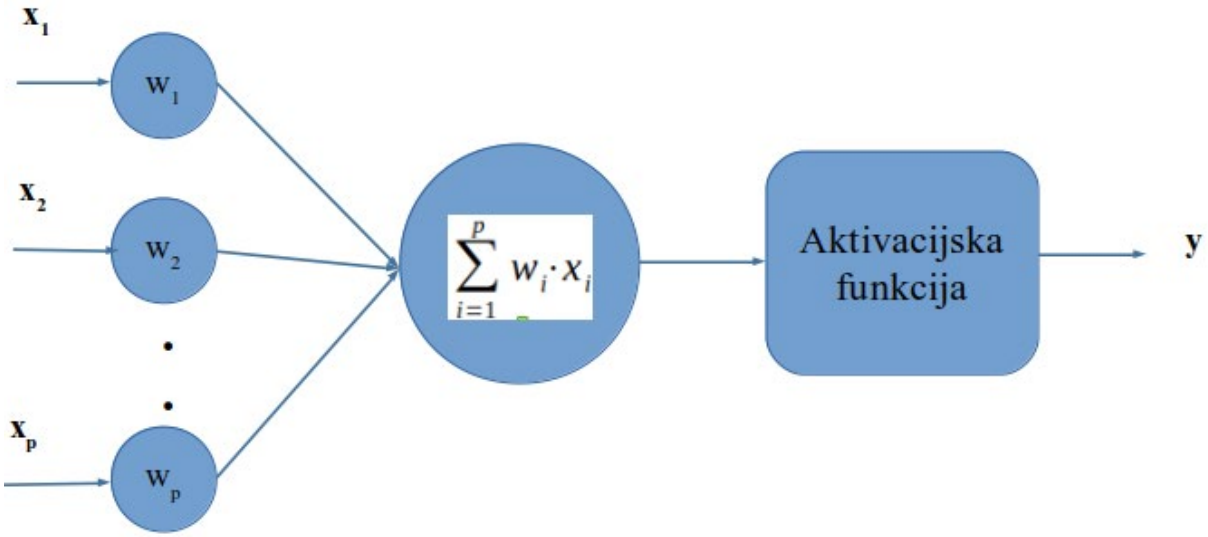
Postoji više načina izbora vodećeg prediktora po kojem će se obavljati dioba izvorne populacije (elemenata matrice *O*) u odgovarajuća područja. Najčešće korišten je tzv. *Gini-indeks*, definiran na sljedeći način. Neka je $p_{m,k}$ udio ulaznih opažanja u podskupu za razvoj modela u *m*-toj regiji (području) koji pripadaju *k*-toj klasi odziva (izlaznih veličina). Tada je *Gini-indeks G* definiran kako je prikazano izrazom (106) (Maindonald, Browm, 2010; Dalpiaz, 2019).

$$G = \sum_{k=1}^{K} \cdot p_{m,k} \cdot (1 - p_{m,k}) \tag{106}$$

5.3.3. Model zasnovan na metodi umjetne neuronske mreže

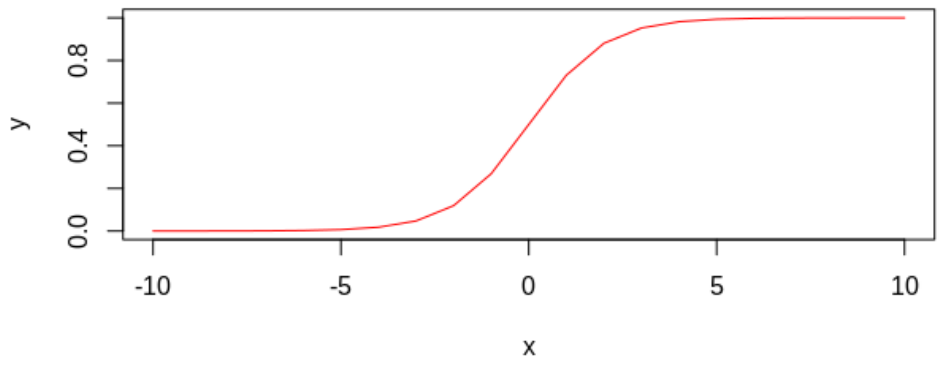
Umjetna neuronska mreža (slika 29) je računalna struktura preuzeta iz biološkog modela neuronske mreže. Sastoji se od pojedinačnih elemenata umjetnih neurona, međusobno povezanih poveznicama određenim težinskim faktorima koji iskazuju težinu (vrijednost) izlaza pojedinih modela, te neovisnim elementima koji definiraju slobodne (nevezane) ulazne veličine neurona (Efron, Hastie, 2016).

Umjetni neuron (slika 27) je osnovna gradbena jedinica umjetne neuronske mreže. Umjetni neuron preuzima konceptualnu funkcionalnost od biološkog neurona i izvodi je u okviru procesa strojnog učenja. U funkcionalnom smislu, ulazne veličine (prediktori) najprije se naglašavaju množenjem s odgovarajućim težinskim faktorima. Težinski naglašene vrijednosti prediktora zatim se zbrajaju kako bi definirale ulaznu veličinu aktivacijske funkcije. Odziv aktivacijske funkcije na pobudu vrijednostima prediktora se potom uspoređuje s aktivacijskom razinom te, ovisno o rezultatu usporedbe, aktivira neuron radi prijenosa signala u naredni sloj umjetne neuronske mreže (slika 25) (Efron, Hastie, 2016).



Slika 25. Model neurona

Postoji nekoliko uobičajenih aktivacijskih funkcija. Najčešće korištena je tzv. sigmoidna funkcija (slika 26) analitički definirana izrazom (107).



Slika 26. Sigmoidna funkcija

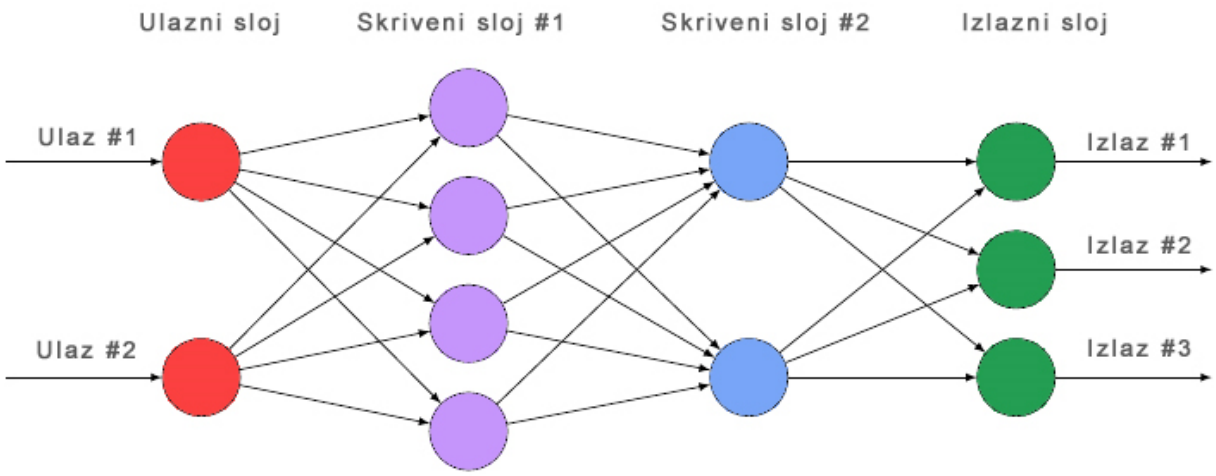
$$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}} \tag{107}$$

Neuroni su postavljeni u slojeve. Svaka umjetna neuronska mreža sastoji se od ulaznog sloja neurona, koji izravno preuzimaju ulazne veličine procesa te izlaznog sloja, obično sastavljenog od samo jednog neurona. Između ulaznog i izlaznog sloja neurona mogu se postaviti jedan ili više tzv. skrivenih slojeva neurona (Efron, Hastie, 2016).

Razvoj modela umjetne neuronske mreže zasnovan je na statističkom učenju, pri čemu se u postupku učenja (spoznaje promatranog procesa) određuju i u svakoj novoj iteraciji optimiziraju težinski parametri i slobodni članovi (Efron, Hastie, 2016).

Model zasnovan na umjetnoj neuronskoj mreži je prognostički (prediktivni) model (Kuhn, 2019). Takav model ne objašnjava proces koji se modelira, već daje prognozu ponašanja procesa zasnovanu na modelu (iskustvu s prethodno razmatranim slučajevima). Umjetne neuronske mreže koriste se za modeliranje složenih procesa velike razine složenosti koja može nastati ili zbog velikog broja prediktora ili zbog višestrukih veza između prediktora (Efron, Hastie, 2016; Kuhn, 2019).

Izbor arhitekture umjetne neuronske mreže mora biti zasnovan na jednostavnosti, tj. korištenju čim manjeg broja skrivenih slojeva neurona, uz istu kvalitetu modela (Kuhn, 2019). U praksi, dva do četiri skrivena sloja neurona predstavljaju optimalni izbor u smislu prevladavanja nadmodeliranja, postizanja točnosti i računalne učinkovitosti modela. Korištenje velikog skupa za učenje osigurava potrebnu kvalitetu razvijenog modela (Kuhn, 2019). Obilježja modela moraju se provjeriti prikladno izabranim skupom podataka za provjeru, kako bi se na vrijeme uočilo i ispravilo nadmodeliranje (engl. Overfitting) (Kuhn, 2019).



Slika 27. Struktura umjetne neuronske mreže

5.4. Vrednovanje prognostičkog modela

Statističar George Box naveo je u nekoliko navrata kako su svi modeli pogrešni, ali su neki ipak korisni (Box, 1976). Vrednovanje modela je heuristički zadatak, čije rješenje govori koliko je razvijeni model sposoban zadovoljiti zahtjeve za točnost opisa promatrane pojave ili procesa.

Stvarne pojave i procesi složene su naravi i općenito ih je nemoguće opisati egzaktnim modelom s apsolutnom točnošću. Neravnomjernosti i varijance postaju ciljane pojave kojima se bavi statistika, nastojeći njihove učinke za točnost opisa pojave ili procesa učiniti minimalnim, odnosno unutar granica prihvatljivosti. Zbog tog se vrednovanje modela pojavljuje kao optimizacijski problem.

Statistika pruža niz postupaka za vrednovanje razvijenog modela. Neki od njih usmjeravaju pozornost na sposobnost modela da opiše neravnomjernost sistemske pogreške (engl. bias). Drugi za svoj cilj imaju varijancu (engl. variance), odnosno sposobnost modela da opiše postotak varijance.

U izboru metoda za procjenu uspješnosti razvijenog modela, ovaj rad pretpostavio je usklađeni pristup koji će pružiti informaciju o statističkom opisu obiju naravi stvarne pojave doprinosa ukupnoj pogreški određivanja položaja satelitskim sustavom uslijed troposferskog kašnjenja satelitskog signala. Vrednovanje razvijenih modela provjeravano je prema sljedećim statističkim pokazateljima:

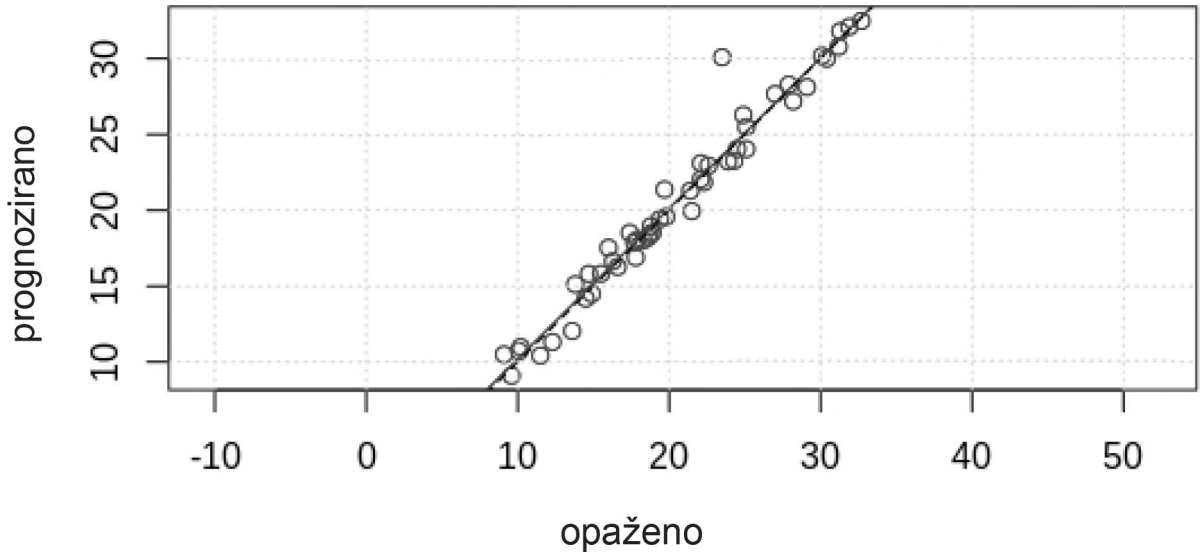
1. odnos prognoziranih i opaženih vrijednosti (engl. Predicted vs Observed Diagram - PO),
2. koeficijent određenja R^2,
3. podešeni koeficijent određenja (engl. Adjusted - R^2) $adj\ R^2$,
4. Akaikeov informacijski kriterij (engl. Akaike Information Criterion - AIC),
5. Bayesov informacijski kriterij (engl. Bayes Information Criterion - BIC) te
6. analiza reziduala (skup razlika između prognoziranih i opaženih ishoda), posebno: srednja kvadratna vrijednost reziduala te statistička razdioba reziduala.

Navedeni statistički pokazatelji uspješnosti modela bit će definirani u nastavku ovog poglavlja.

Praktična izvedba vrednovanja razvijenih modela izvedena je vlastitom programskom podrškom razvijenom u programskom okruženju za statističko računarstvo R, zasnovanom na osnovnoj i dodatnim R knjižnicama: *caret* (Kuhn, 2019)*, forecast* (Hyndman i suradnici, 2020)*, stat* (Bolar, 2019)*, DataExplorer* (Cui, 2020).

5.4.1. Odnos prognoziranih i stvarno opaženih vrijednosti

Navedeni odnos analizira se pomoću grafičkog prikaza parova opaženih i odnosnih prognoziranih vrijednosti *(x_{obs}, x_{pred})*. Primjer P-O dijagrama prikazan je na slici 28. Ucrtani pravac koeficijenta smjera *a = 1* predstavlja idealni P-O dijagram u kojem su sve prognozirane vrijednosti jednake stvarno opaženim (*adj R^2 = 1*). Odmak od najboljeg pravca, grozdovi eksperimentalnih vrijednosti oko pojedinih dijelova pravca te pojedinačne iznimke od standardnih statističkih razdioba (engl. Outliers) ukazuju na potrebu promjene strukture ciljanog modela radi potpunog obuhvaćanja odnosa prediktora i ishoda.



Slika 28. Primjer P-O dijagrama

5.4.2. Koeficijent određenja R^2

Koeficijent određenja R^2 pokazuje udio originalne varijance obuhvaćen (opisan) razvijenim modelom. Definiran je na osnovi analize varijance, kako slijedi.

Definicija 6. Neka originalni skup opažanja sadrži prediktore i vektor ishoda $Y = \{y_i, i = 1, \dots, N\}$ sa srednjom vrijednosti određenom prema (108):

$$\bar{y} = \frac{1}{N}\sum_{i}^{N} \cdot y_i \tag{108}$$

Neka je na originalnom skupu opažanja definiran model ishoda f koji za i-ti vektor vrijednosti prediktora $(\mathrm{x_{i,1}}, \mathrm{x_{1,2}}, \dots, \mathrm{x_{i,p}})$ daje prognozu i-tog ishoda $\widehat{y_i} = f(x_{i,1}, x_{1,2}, \dots, x_{i,p})$ (za oba

izraza i = 1, 2, …, N). Tada je moguće odrediti sljedeće apsolutne mjere pogreške modela u odnosu na stvarna opažanja ishoda:

1. Ukupni zbroj kvadrata (109), određen kao:

$$SS_{tot} = \sum_{i=1}^{N} \cdot (y_i - \bar{y})^2 \tag{109}$$

2. Objašnjeni zbroj kvadrata, određen kao:

$$SS_{reg} = \sum_{i=1}^{N} \cdot (\hat{y}_i - \bar{y})^2 \tag{110}$$

3. Zbroj kvadrata reziduala, određen kao:

$$SS_{res} = \sum_{i=1}^{N} \cdot (\hat{y}_i - y_i)^2 = \sum_{i} \cdot e^2 \tag{111}$$

Definicija 7. Koeficijent određenja R^2 (112) definira se pomoću apsolutnih mjera pogreške modela u odnosu na stvarna opažanja ishoda (definicija 6) kao:

$$R^2 \equiv 1 - \frac{SS_{res}}{SS_{tot}} \tag{112}$$

5.4.3. Podešeni koeficijent određenja

Koeficijenta određenja R^2 (poglavlje 5.4.2) ovisi o broju opažanja N i broju prediktora p, što onemogućuje izravnu usporedbu modela zasnovanih na različitim skupovima opažanja. Problem je moguće prevladati normiranjem koeficijenta određenja, tako da on omogućuje objektivnu usporedbu modela iste pojave ili procesa razvijenih na različitim skupovima eksperimentalnih opažanja. Postupkom normiranja dobiva se podešeni koeficijent određenja, definiran prema (113).

$$adjR^2 = 1 - (1 - R^2) \cdot \frac{N - 1}{N - p - 1} \tag{113}$$

5.4.4. Akaikeov informacijski kriterij

Akaikeov informacijski kriterij (AIC) predstavlja numeričku (kvantitativnu) relativnu mjeru količine originalnih informacija izgubljenih u modelu zasnovanom na eksperimentalnim opažanjima. Na taj način, AIC određuje uspješnost modela u pokrivanju i neravnomjernosti i varijance originalnih opažanja. AIC je definiran, kako slijedi.

Definicija 8. Neka je zadan eksperimentalni model f određen s k koeficijenata, slobodnim članom i s $(k-1) = p$ koeficijenata prediktora.

Neka je definirana derivabilna vjerojatnostna funkcija (engl. Likelyhood Function, *LF*) koja daje vjerojatnost pojave koeficijenata modela zasnovanih na opažanjima, uz fiksne vrijednosti opažanja. Neka vjerojatnostna funkcija LF ima procijenjeni maksimum $\hat{L} = max(LF)$. Akaikeov informacijski kriterij definira se tada kako je prikazano izrazom (114).

$$AIC = 2 \cdot k + 2 \cdot ln(L) \tag{114}$$

Akaikeov informacijski kriterij informacija uspoređuje kvalitetu skupa eksperimentalnih modela. Za skup od regresijskih modela s različitim brojem prediktora, AIC će razvrstati modele iz skupa od najboljeg do najgoreg. Najbolji model bit će onaj koji niti nadmodelira niti podmodelira skup opažanja na kojem je razvijen. AIC nije primjenjiv na neparametarske modele, kao što su modeli zasnovani na metodi slučajne šume (potpoglavlje 5.3.2).

5.4.5. Bayesov informacijski kriterij

Slično Akaikeovom, Bayesov informacijski kriterij (BIC) također opisuje relativni gubitak originalnih informacija u eksperimentalnom modelu, odnosno sposobnost obuhvaćanja relevantnih informacija bez uvažavanja onih koje to nisu (signal bez šuma). Bayesov informacijski kriterij je varijanta AIC-a s većom kaznom u optimizacijskoj funkciji cilja za uključivanje dodatnih varijabli u model.

Definicija 9. Neka je zadan eksperimentalni model određen s k koeficijenata, s $(k-1) = p$ prediktora i slobodnim članom te s N opažanja. Bayesov informacijski kriterij definiran je izrazom (115).

$$BIC = ln(N) \cdot k + 2 \cdot ln(L) \tag{115}$$

Kao i u slučaju AIC-a, BIC nije primjenjiv na neparametarske modele, kao što su modeli zasnovani na metodi slučajne šume.

5.4.6. Analiza reziduala

Postupak vrednovanja modela obuhvaća analizu reziduala, definiranih kako slijedi.

Definicija 10. Neka je zadan skup eksperimentalnih opažanja koji sadrži vrijednosti p prediktora te odgovarajuće ishode. Neka je svakom vektoru prediktora $(x_{i,1}, x_{1,2}, \dots, x_{i,p}), i = 1, \dots, N$ pridružen odgovarajući ishod y_i.

Neka je na originalnom skupu opažanja definiran model ishoda f koji za i-ti vektor vrijednosti prediktora $(x_{i,1}, x_{1,2}, \dots, x_{i,p})$ daje prognozu i-tog ishoda $\widehat{y_i} = f(x_{i,1}, x_{1,2}, \dots, x_{i,p}), i = 1, \dots, N$. Rezidual r_i tada je određen razlikom prognoziranog ishoda $\widehat{y_i}$ i opaženog ishoda y_i, kako je definirano izrazom (116).

$$r_i = \widehat{y_i} - y_i = f(x_{i,1}, x_{1,2}, \dots, x_{i,p}) - y_i \tag{116}$$

Općenito, skup reziduala može se shvatiti kao skup opažanja slučajne varijable te se na njega može primijeniti formalni postupak statističke analize, uključujući i razvoj eksperimentalnog statističkog modela reziduala. Potrebe ovog rada zadovoljava određivanje srednje kvadratne pogreške reziduala (engl. Residual Standard Error - RSE), kao apsolutne mjere pogreške, zatim korijen srednje kvadratne pogreške (engl. Root mean Square error - RMSE) te procjena funkcije gustoće vjerojatnosti statističke razdiobe reziduala, koja će biti uspoređena s ekvivalentnom teoretskom normalnom (Gaussovom) razdiobom primjenom Shapiro-Wilk statističkog testa. Sukladnost funkcije gustoće vjerojatnosti statističke razdiobe reziduala s onom teoretske normalne razdiobe interpretira se u smislu potpune sposobnosti opisa varijance i neravnomjernosti u promatranoj pojavi ili procesu. Normalna razdioba tada proizlazi kao isključivi rezultat pogreške nastale zbog šuma (irelevantnih informacija).

5.5. Eksperimentalna opažanja za potrebe razvoja i vrednovanja prognostičkog modela

Prognostički modeli udjela pogreške zbog troposferskih učinaka u ukupnoj pogreški satelitskog određivanja položaja razvijeni su u ovom radu na pripremljenoj bazi eksperimentalnih opažanja oblikovanoj i strukturiranoj tijekom prikazanog istraživanja. Originalna opažanja preuzeta su s

provjerenih izvora (ICG, 2020) i pripremljena kako bi oblikovala bazu opažanja primjerenu potrebama istraživanja.

Baza dnevnih opažanja pokriva područje grada Matera u Italiji u razdoblju od 1. siječnja 2019. do 10. travnja 2019.

U istraživanju su korištena izvorna (nepopravljena) dnevna opažanja jednofrekvencijskih GPS pseudoudaljenosti bilježena svakih 30 s, prikupljena eksperimentalno na referentnoj stanici Matera, Italija međunarodne mreže International GNSS Service (IGS, 2020). Opažene GPS pseudoudaljenosti pohranjene su strukturirano u RINEX (IGS, 2018). Navigacijske poruke odašiljane sustavom GPS u promatranom razdoblju (preuzete pomoću internetskog sučelja (GNSS Calendar, 2020). GPS pseudoudaljenosti i navigacijske poruke iskorištene su za:

1. generiranje skupova procjena položaja te
2. skupova koordinata vektora pogrešaka određivanja položaja (u smjeru sjevera, istoka i vertikalno) u dva scenarija, pomoću programski određenog GNSS prijamnika RTKLIB/RTKPOS u radu odgođene analize (engl. Post-processing mode).

U scenariju I, eksperimentalno opažene pseudoudaljenosti su prije postupka određivanja položaja ispravljane za sve poznate uzroke sistemskih pogrešaka korisničke razdiobe pogrešaka, pomoću odgovarajuće programske podrške u programskom paketu RTKLIB, kako slijedi:

1. ionosfersko kašnjenje, korištenjem Klobucharovog modela,
2. troposfersko kašnjenje, korištenjem Saastamoinenovog modela,
3. učinke višestaznih puteva, putem postavljanja optimalnog maskirnog kuta od 15°, čime je postignuto optimalno ublažavanje navedenih učinaka.

   Prijamnik ne može mijenjati ukupni DOP. Postupak određivanja položaja je optimizacijski postupak. Zaključeno je kako se nešto pogoršani GDOP kompenzira znatnim smanjenjem učinaka višestaznih puteva (i bias i varijanca) (Parkinson i Spilker, Jr., 1996; Sanz Subirana i suradnici, 2013). Za potrebe ovih razmatranja, nije kritično, jer se sve vrste pogrešaka drže čvrstima, dok se odvojeno razmatraju tek varijante sa i bez troposferskog učinaka te

   Pogreške satelitskih satova, korištenjem parametara modela popravaka odaslanih putem navigacijske poruke (Parkinson i Spilker, Jr., 1996; Sanz Subirana i suradnici, 2013).

Navigacijska poruka sadrži parametre modela popravaka točnosti satelitskog sata, dok daljnja objašnjenja izlaze iz okvira rasprave u ovoj disertaciji.

Navedenim pristupom, scenarij I je omogućio dobivanje skupa procjena položaja i pogrešaka određivanja položaja koje su pretpostavljene kao točne.

U scenariju II, eksperimentalno opažene pseudoudaljenosti su prije postupka određivanja položaja ispravljane za sve poznate uzroke sistemskih pogrešaka korisničke razdiobe pogrešaka, osim troposferskog kašnjenja. Popravak je proveden pomoću odgovarajuće programske podrške u programskom paketu RTKLIB uz korištenje vrijednosti parametara modela popravaka iz GPS navigacijske poruke. Na taj način je scenarijem II dobiven skup procjena položaja i pogrešaka određivanja položaja koje su sadržavale samo učinke troposferskog kašnjenja.

Udio troposferskog kašnjenja po komponentama vektora pogreške određivanja položaja dobiven je kao razlika odnosnih elemenata (ista koordinata vektora pogreške, isti trenutak mjerenja pseudoudaljenosti) iz skupa scenarija II i scenarija I za potrebe razvoja prognostičkih klimatskih modela. Komponente vektora pogrešaka iskorištene su za određivanje horizontalne pogreške određivanja položaja, od interesa u pomorskoj površinskoj navigaciji, kako je prikazano u potpoglavlju 4.2.

Istovremeno, referentna IGS stanica u Materi, Italija prikupljala je i lokalna meteorološka opažanja, uključivo temperaturu, tlak i vlažnost zraka. Usrednjene vrijednosti za 15-minutna razdoblja tijekom cijelog dana pohranjivane su u posebno strukturirane meteorološke RINEX m datoteke (IGS, 2018), koje su za potrebe ovog istraživanja također bile preuzete s internetske arhive (IGS, 2020).

U postupku pripreme podataka za razvoj modela, vrijednosti komponenata GPS pogreške određivanja položaja određene GNSS prijamnikom RTKLIB svedene su na niz s istim vremenskim razmakom između susjednih očitanja svakih 15 min kao što je slučaj kod meteoroloških opažanja i gdje se vrijeme neće bitnije u tom razdoblju promijeniti. Korištena je transformacija komponenata pogreške određivanja položaja metodom pomičnih prosjeka (engl. Moving Average - MA) izvedena zasebnim programom u okruženju za statističko računarstvo R.

Zahtjevi za točnost određivanja položaja za potrebe primjena u pomorskoj površinskoj navigaciji izraženi su horizontalnom točnošću određivanja položaja. Zbog toga je na izvorne vrijednosti komponenata vektora pogreške određivanja položaja satelitskim sustavom

primijenjena i transformacija (117) kojom su komponenta vektora pogreške u smjeru sjevera, x_{sjever} i komponenta vektora pogreške u smjeru istoka y_{istok} prevedene u zajedničku varijablu udjela horizontalne pogreške određivanja položaja uslijed troposferskih učinaka ϵ_{hor}.

$$\epsilon_{hor} = \sqrt{x_{sjever}^2 + y_{istok}^2}(m) \tag{117}$$

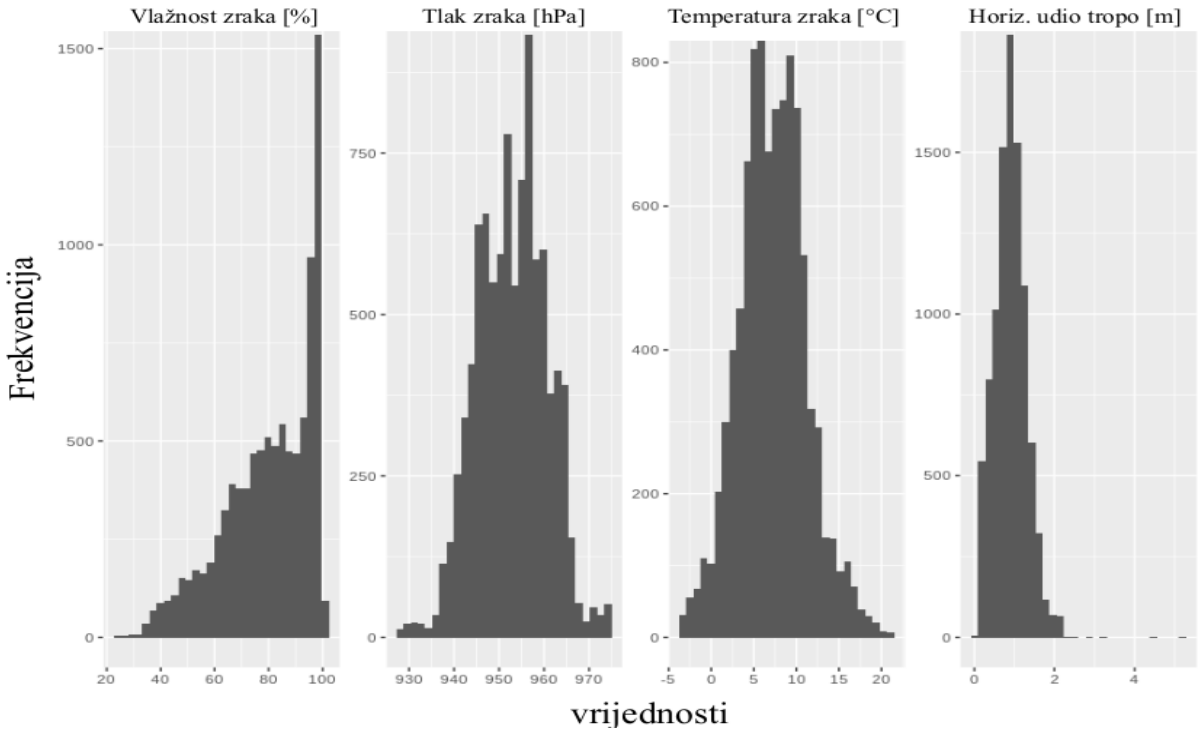
Prikazanom metodologijom oblikovan je skup opažanja prikupljenih na referentnoj GNSS stanici Matera, Italija u razdoblju od 1. siječnja 2019. do 10. travnja 2019.

Osnovna statistička obilježja troposferskog doprinosa horizontalnoj pogreški određivanja položaja satelitskim sustavom, usrednjenog tlaka zraka, usrednjene temperature zraka i usrednjene vlažnosti zraka preuzeti su kao ulazni parametar i gdje se pritom nije radilo o konkretnom istraživanju već o korištenim podacima i potrebnim intervalima kako je prikazano u tablici 19.

Tablica 19. Statistička obilježja troposferskog doprinosa horizontalnoj pogreški određivanja položaja satelitskim sustavom

	Minimum	Aritmetička srednja vrijednost	Medijan	Standardna devijacija	Maksimum
Troposferski doprinos pogreški (m)	0,05015	0,89976	0,89574	0,39924	5,24197
Temperatura (°C)	-3,507	7,263	7,213	3,97643	20,893
Tlak zraka (hPa)	928,1	952,9	953,1	7,716986	974,3
Vlažnost zraka (%)	22,98	79,97	82,93	16,40634	100,00

Slika 29. prikazuje histograme odnosnih veličina iz pripremljenog skupa opažanja s referentne stanice Matera, Italija.



Slika 29. Histogrami relativne vlažnosti zraka, tlaka zraka, temperature zraka i doprinosa troposferskih učinaka ukupnoj pogreški satelitskog određivanja položaja opaženih na referentnoj stanici Matera, Italija u razdoblju 1. siječnja 2019. – 30. travnja 2019.

Eksploratorna analiza skupa opažanja obuhvatila je veliki broj potencijalnih meteoroloških scenarija u kojima je primijenjena satelitska navigacija za potrebe pomorske površinske navigacije. Dugotrajnost razdoblja u kojem su opažane vrijednosti prediktora i ishoda osigurala je obuhvaćanje širokog raspona meteoroloških promjena, različitih intenziteta i trajanja. Za razvoj modela bilo je značajnije promatrati statističke razdiobe. Položaj referentne stanice klimatski je određen kao područje s relativno velikom vlažnosti zraka, što je vidljivo iz statističke razdiobe navedenog meteorološkog parametra. Na kraju, temperaturno područje obuhvaćeno skupom opažanja karakteristično je za zimsko i proljetno vrijeme. Usprkos tome, nekoliko snažnih promjena vremena (slika 29) obuhvaćeno je opažanjima i vidljivim padom tlaka zraka u pojedinim trenucima što je pomoglo u definiranju podloge za razvoj prognostičkog modela.

Analiza ukupne pogreške određivanja položaja satelitskim sustavom obavljen je uz korištenje numeričkih vrijednosti pojedinačnih opažanja prediktora i vrijednosti ishoda izvedenih iz eksperimentalnih opažanja korištenjem metodologije opisane u potpoglavljima 2.4 (tablica 4) i 4.2. Navedena analiza omogućila je procjenu raspona ukupnih pogrešaka određivanja položaja i udjela u ukupnoj pogreški zbog troposferskih učinaka. U analizi je korištena vrijednost

horizontalne geometrijske degradacije točnosti HDOP = 1.5, primjerena scenarijima pomorske površinske navigacije, zbog pretežito vrlo dobre vidljivosti nebeskog svoda i odsutnosti fizičkih prepreka toj vidljivosti.

Tablica 20. Granične vrijednosti doprinosa troposferskih učinaka ukupnoj pogreški i odgovarajuća ukupna pogreška satelitskog određivanja položaja za razmatrani eksperimentalni skup opažanja

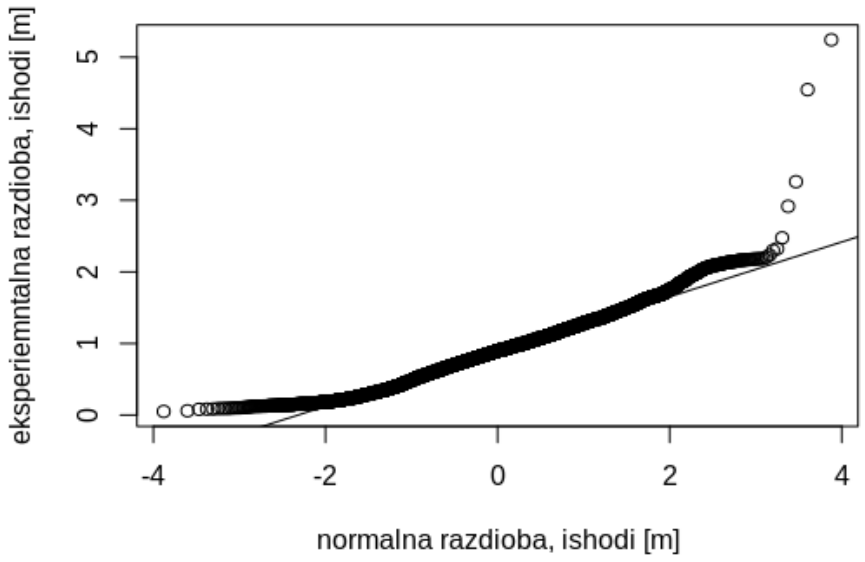
	Vrijednost udjela troposferskog kašnjenja u (m)	
	Minimalna	**Maksimalna**
Udio troposferskog kašnjenja (m)	0,05015	5,24197
Ukupna pogreška određivanja položaja satelitskim sustavom (m)	7,79892	11,07446

Ekstremne vrijednosti udjela troposferskih učinaka na ukupnu pogrešku određivanja položaja satelitskim sustavom (slika 29). Navedeni podaci (tablica 20) pokazuju kako ekstremni meteorološki uvjeti (slika 29) mogu izazvati povećanje udjela troposferskog kašnjenja koje će povećati ukupnu pogrešku satelitskog određivanja položaja iznad vrijednosti zahtjeva za točnost klasa 1, 1A i 1B predloženog modela klasifikacije navigacijskih zadataka u pomorskoj površinskoj navigaciji.

Statistička obilježja doprinosa troposferskih učinaka ukupnoj pogreški određivanja položaja ukazuju na normalnu razdiobu, koja je blago razvučena na desno, s izraženim desnim repom razdiobe. Medijan i aritmetička srednja vrijednost su bliski po svojim vrijednostima. Raspršenje pojedinačnih opažanja doprinosa troposferskih učinaka ukupnoj pogreški određivanja položaja oko aritmetičke srednje vrijednosti je relativno veliko, što je vidljivo iz vrijednosti standardne devijacije. Navedeno vodi k zaključku o mogućnosti uspješnog modeliranja doprinosa troposferskih učinaka ukupnoj pogreški određivanja položaja pomoću jednostavnijih linearnih modela.

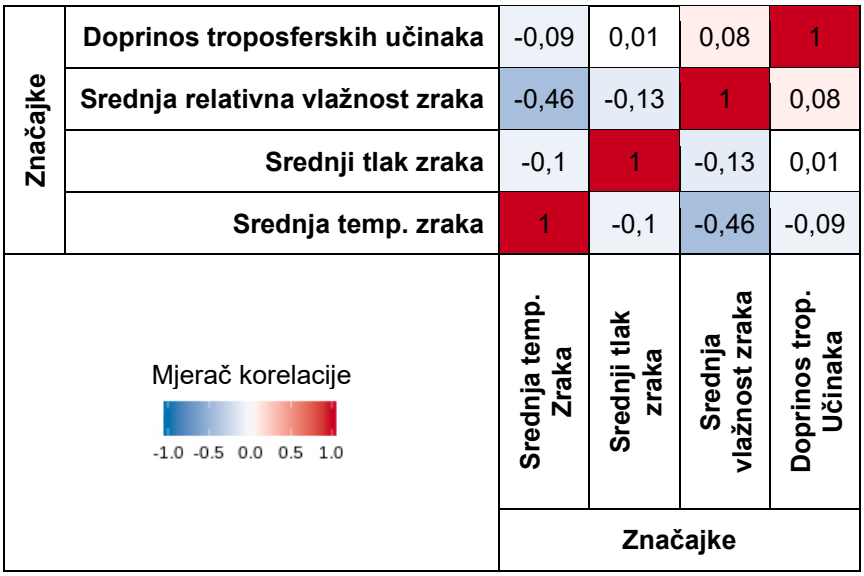
U statističkoj analizi su korišteni kvanti-kvantil (Q-Q) dijagrami, kao postupak usporedbe dviju statističkih razdioba (ovdje: Gaussove i eksperimentalne) na način da se iscrtavaju njihove međusobne kvantile (Maindonald i Brown, 2010; Dalpiaz, 2019). Eventualno suglasje s teorijskom Gaussovom razdiobom sugeriralo bi linearnost procesa i mogućnost njegovog opisa linearnim modelima. U suprotnom trebala bi biti razmotrena primjena složenijih nelinearnih modela treba (Efron i Hastie, 2016; Maindonald i Brown, 2010; Dalpiaz, 2019). Detaljnija analiza korištenih eksperimentalnih opažanja putem Q-Q dijagrama (slika 30) otkriva kako

doprinos troposferskih učinaka u ukupnoj horizontalnoj pogreški satelitskog određivanja položaja ima izražene iznimke statističke distribucije (engl. outliers) izražene na oba repa eksperimentalne razdiobe, što je vidljivo iz slike 30. Konačna potvrda kako doprinos troposferskih učinaka ukupnoj pogreški satelitskog određivanja položaja ne slijedi normalnu razdiobu dolazi rezultatom primjene Kolmogorov-Smirnovljevog (K-S) statističkog testa (Maindonald i Brown, 2010; Dalpiaz, 2019) za jednu varijablu, uz statističku značajnost p < 2,2e-16. Dobivena vrijednost statističkog parametra p je rezultat statističkog K-S testa kojim se određuje slijedi li eksperimentalna razdioba referentnu (u ovom slučaju Gaussovu) razdiobu.



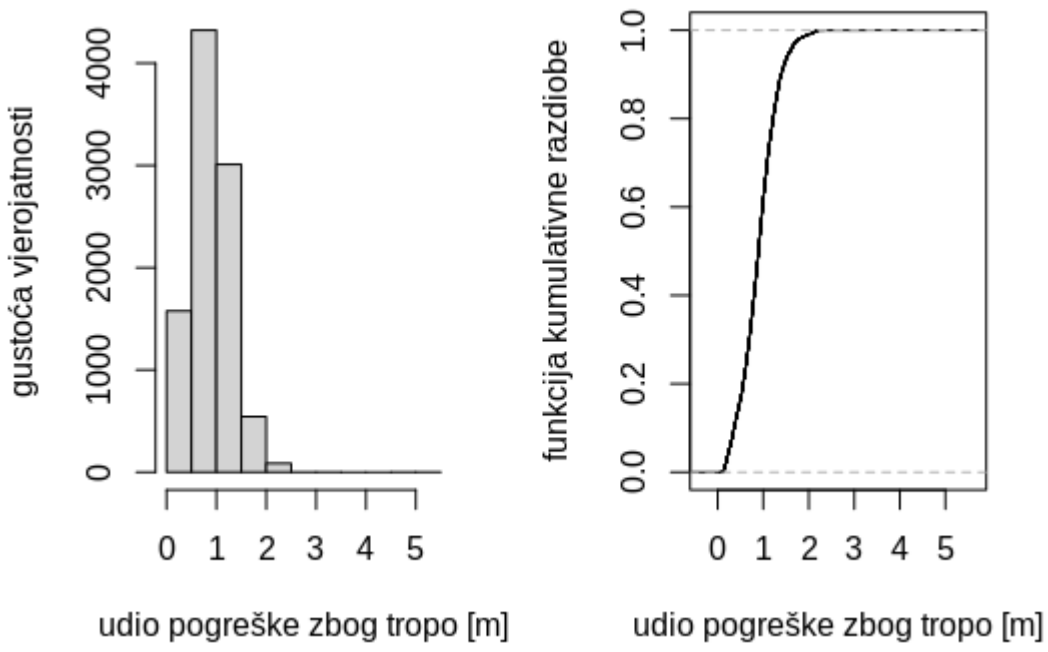
Slika 30. Q-Q dijagram doprinosa ukupnoj horizontalnoj pogreški određivanja položaja uslijed troposferskih učinaka ne slijedi normalnu razdiobu na repovima razdiobe

Analiza asocijacija (korelacija) između odnosnih veličina ukazuje na gotovo zanemarivu linearnu povezanost između ciljne varijable (doprinosa ukupnoj horizontalnoj pogreški satelitskog određivanja položaja uslijed troposferskih učinaka) i prediktora (tlak zraka, temperatura zraka i relativna vlažnost zraka), kao što je pokazano slikom 31.



Slika 31. Korelacijski dijagram ciljane varijable i prediktora, izvedeno vlastitom programskom podrškom u okruženju za statističko računarstvo R i uz korištenje R knjižnice DataExplorer

Eksploratorna statistička analiza doprinosa ukupnoj horizontalnoj pogreški satelitskog određivanja položaja uslijed troposferskog kašnjenja pružila je procjenu funkcije gustoće statističke razdiobe te kumulativne funkcije statističke razdiobe, prema slici 32. Dobivena empirička kumulativna funkcija razdiobe omogućuje procjenu vjerojatnosti pojave određene vrijednosti doprinosa ukupnoj horizontalnoj pogreški određivanja položaja uslijed troposferskog kašnjenja.



Slika 32. Funkcija gustoće statističke razdiobe (lijevo) te kumulativne funkcije statističke razdiobe (desno), izvedena u programskom okruženju za statističko računarstvo R vlastitom programskom podrškom

Jednom svedeni na isti interval susjednih opažanja, vrijednosti očitanja meteoroloških parametara (prediktori) i udjela horizontalne pogreške određivanja položaja uslijed troposferskih učinaka (ishod) tvore skup prediktora i ishoda za razvoj modela. Takav izvorni skup opažanja je razdijeljen postupkom slučajnog odabira u podskup za učenje (engl. Training set, 80 % elemenata izvornog skupa) te podskup za vrednovanje (engl. Test set, 20 % elemenata izvornog skupa). Kao što je navedeno ranije, za potrebe razvoja prognostičkih modela vektori opažanja su pretpostavljeni neovisnim o drugim vektorima i nisu razmatrani vezano za njihovo stvarno vrijeme pojavljivanja u smislu vremenskih nizova.

Vrednovanje modela izvedeno je uz korištenje podskupa za vrednovanje. Vrednovanje modela je provedeno pomoću postupka i statističkih testova opisanih u poglavlju 5.3.

Horizontalna pogreška određivanja položaja uslijed troposferskih učinaka (ishod) i opažanja meteoroloških prediktora za potrebe razvoja kratkoročnog prognostičkog modela izvedeni su na isti način i iz istih izvora kao i u slučaju opažanja za razvoj i vrednovanje prognostičkog klimatološkog modela, kako je prikazano u poglavlju 5.4.2.

5.6. Preslikavanje ostvarene točnosti određivanja položaja uz djelovanje troposferskih učinaka na zahtjeve kategorija navigacijskih zadataka u pomorskoj površinskoj navigaciji

Zasnovano na prethodnim istraživanjima i praktičnim iskustvima operatera i pomoraca koji obnašaju razne zapovjedne i druge dužnosti na brodovima diljem svijeta (poglavlje 4.1 i tablice 17 i 18), predložena je sistematizacija navigacijskih zadataka u pomorskoj površinskoj navigaciji sukladno zahtjevima za potrebnu točnost određivanja položaja, izraženu najvećom prihvatljivom pogreškom određivanja položaja u horizontalnoj ravnini. Praktična iskustva operatera vezana su izravno za ukrcaj na razne vrste brodova kako predstavnika Republike Hrvatske tako i drugih sudionika iz brojnih mornarica i obalnih straža u svijetu poradi izvršavanja specifičnih navigacijskih zadataka s potrebnom točnošću određivanja položaja prilikom plovidbe broda kako u Velikoj Britaniji tako i u Turskoj obalnoj straži te na španjolskom ratnom/mornaričkom brodu kao i brojnim drugim plovidbama broda.

Specifični navigacijski zadaci odnose se između ostaloga na prekrcaj goriva između dva broda u plovidbi, zatim naplavljivanje teretnog prostora ispod glavne palube na brodu i prekrcaj ljudstva i razne tehnike prilikom plovidbe dva broda te intenzivne i specifične akcije traganja i spašavanja u području Libije kao i brojne druge navigacijske zadatke koji su bili temeljeni na osnovnim i esencijalnim navigacijskim zadacima kako je prikazano u tablici 17.

Izvršavanje svakog pojedinog navigacijskog zadatka na brodu bilo je pomno isplanirano prema zahtjevima o potrebnoj točnosti određivanja položaja (tablica 18) s obzirom da se radi o vrlo zahtjevnim navigacijskim zadacima koji nisu prisutni i zastupljeni u svakodnevnim i uobičajenim redovnim navigacijskim zadacima svakog pojedinog broda u plovidbi.

Uobičajeni i redovni navigacijski zadaci (GSA, 2018) navedeni u tablici 17 odnose se na klasu 1, 1A i 1B (navigacijski zadaci vezani za plovidbu broda otvorenim morem i unutrašnjim plovnim putevima kao i aktivnosti traganja i spašavanja) zatim navigacijski zadaci navedeni u klasi 2, 2A i 2B (navigacijski zadaci pojedinih lučkih operacija, zatim prilaza broda luci u ograničenom području za manevriranje kao i navigacijski zadaci brodova ledolomaca te plovidba broda poradi pripreme za dokovanje) te na kraju navigacijski zadaci vezani za klasu 3 i 3A (navigacijski zadaci vezani za brod koji se bavi jaružanjem te automatsko dokovanje broda i operacije u lukama i rukovanja teretom).

Na svakom pojedinom brodu operativno se izvršavao jedan do eventualno dva specifična navigacijska zadatka (ablica 18) dok su ostali navigacijski zadaci bili osnovni ili temeljni sukladno tablici 17.

Praktično i operativno iskustvo stjecani su dugogodišnjim radom na brodovima prilikom izvršavanja kako osnovnih navigacijskih zadataka tako i specifičnih navigacijskih zadataka kao i potrebnu točnost određivanja položaja za pojedinu vrstu broda i potrebnih operativnih zahtjeva na brodu između ostaloga i sa časnicima koji obnašaju razne zapovjedne i druge dužnosti na brodovima ratnih mornarica i obalnih straža diljem svijeta kako slijedi: 1 časnik iz Malezije, 1 časnik iz Libanona, 4 časnika iz Velike Britanije, 1 časnik iz Njemačke, 2 časnika iz Francuske, 3 časnika iz Španjolske, 1 časnik iz Saudijske Arabije, 4 časnika iz Omana, 4 časnika iz SAD-a, 3 časnika iz Trinidad i Tobaga, 2 časnika s Filipina, 4 časnika sa Šri Lanke, itd.

Prognoze prognostičkih i kratkoročnih modela udjela učinaka troposferskog kašnjenja u ukupnoj pogreški određivanja položaja satelitskim sustavom moguće je izravno vezati na tražene zahtjeve za točnost određivanja položaja u navigacijskim zadacima u pomorskoj površinskoj navigaciji. Za potrebe predstavljenog istraživanja korištene su metode povezivanja kako je objašnjeno u ostatku ovog poglavlja.

Svaki i-ti vektor opažanja sastoji se od vektora vrijednosti prediktora (t_i, p_i, h_i), opaženog ishoda $\epsilon_{t,herr,i}$ te prognoze ishoda $\hat{\epsilon}_{t,herr,i}$ zasnovane na modelu koji uzima vektor vrijednosti prediktora kao ulaz. Kao što je ranije objašnjeno, ishodi su udjeli troposferskih učinaka u ukupnoj pogreški određivanja položaja. Vektor vrijednosti prediktora čine opažanja temperature zraka, tlaka zraka i parcijalnog tlaka vodene pare (vlažnosti zraka) u istom trenutku u kojem je određen udio troposferskih učinaka u ukupnoj pogreški određivanja položaja u horizontalnoj ravnini satelitskim sustavom.

Vektor ishoda u apsolutnom iznosu ($\epsilon_{t,herr,i}$, i = 1, …, N) i u postotnom iznosu u odnosu na ukupnu opaženu pogrešku određivanja položaja u horizontalnoj ravnini ($\frac{\epsilon_{t,herr,i}}{\epsilon_{tot,herr,i}}$, i = 1, …, N) uspoređivan je s prihvatljivom najvećom pogreškom određivanja položaja u horizontalnoj ravnini za pojedine navigacijske zadatke u pomorskoj površinskoj navigaciji $\epsilon_{max}(task)$. Svaki slučaj u kojem je opažena ukupna pogreška određivanja položaja u horizontalnoj ravnini bila veća od najveće prihvatljive za pojedini navigacijski zadatak u pomorskoj površinskoj navigaciji $\epsilon_{tot,herr,i} > \epsilon_{max}(task)$ posebno je razmotren. U svakom takvom slučaju zabilježena je opažena i prognozirana apsolutna i relativna vrijednost udjela troposferskih

učinaka u ukupnoj pogrešci satelitskog određivanja položaja. Tako su dobivena po dva vektora, apsolutnih ($\epsilon_{t,herr,i} \mid i \in arg(\epsilon_{tot,herr,i} \mid \epsilon_{tot,herr,i} > \epsilon_{max}(task))$) i relativnih ($\frac{\epsilon_{t,herr,i}}{\epsilon_{tot,herr,i}} \mid i \in arg(\epsilon_{tot,herr,i} \mid \epsilon_{tot,herr,i} > \epsilon_{max}(task))$) vrijednosti udjela troposferskih učinaka u ukupnoj pogreški satelitskog određivanja položaja, za opažene i prognozirane vrijednosti.

Primjenom opisne statističke analize dobiveni su za svaki vektor:

1. aritmetička srednja vrijednost, kao mjera neravnomjernosti,
2. standardna devijacija, kao mjera raspršenosti (varijabilnosti), te
3. procijenjena gustoća vjerojatnosti statističke razdiobe, kao pokazatelj prirode statističkog procesa.

U analizu su uključeni svi vektori opažanja u promatranom vremenskom razdoblju. Opisna statistička analiza vektora opaženih i prognoziranih ishoda pruža mogućnost procjene općeg doprinosa učinaka troposfere na kvalitetu određivanja položaja satelitskim sustavom za potrebe pojedinačnih navigacijskih zadataka u pomorskoj površinskoj navigaciji kako je definirano sistematizacijom u poglavlju 4.

6. REZULTATI ISTRAŽIVANJA

U ovom poglavlju prikazani su rezultati razvoja i procjene uspješnosti prognostičkih i kratkotrajnih prognostičkih modela prema metodologiji prikazanoj u potpoglavljima 5.1 – 5.4 i 5.6, uz korištenje eksperimentalnih opažanja opisanih u potpoglavlju 5.5. Modeli su razvijani na skupu eksperimentalnih opažanja, opisanom u potpoglavlju 5.4, pri čemu je doprinos ukupnoj horizontalnoj pogreški određivanja položaja uslijed troposferskog kašnjenja u pojedinim trenucima dobiven kao razlika pogreške određivanja položaja bez popravaka troposferskog kašnjenja i pogreške s popravcima troposferskog kašnjenja prema Saastamoinenu (ostali standardni modeli popravaka bili su uključeni u oba scenarija).

Razvoj i provjera modela obavljeni su korištenjem razvijene programske podrške u programskom okruženju za statističko računarstvo R. Rezultati razvoja modela prikazani su zbirnim izvještajem dobivenim analizom unutar programske podrške u R-u te komentirani u odnosnim potpoglavljima ovog poglavlja. Razmatranja i usporedba rezultata vrednovanja modela dovela je do zaključka o najboljem od promatranih modela.

6.1. Prognostički model zasnovan na linearnoj regresiji

Razmotrena su dva kandidata strukture modela:

1. jednostavni model linearne regresije s dva prediktora i bez slobodnog člana te
2. djelomični mješoviti model linearne regresije s tri prediktora i bez slobodnog člana.

Prethodni statistički testovi pokazali su kako je slobodni član u oba modela statistički nevažan.

6.1.1. Jednostavni prognostički model linearne regresije s dva prediktora i bez slobodnog člana

Na eksperimentalnim opažanjima (potpoglavlje 5.5) razvijen je prognostički model prikazan izrazom (118), s prediktorima temperatura zraka, izražena (°C), te relativna vlažnost, izražena (%).

$$\epsilon_{hor}\,[m] = 0{,}0169484\,\left[\frac{m}{^\circ C}\right]\cdot t\,[^\circ C] + 0{,}0094744\,[m]\cdot h[\%] \qquad (118)$$

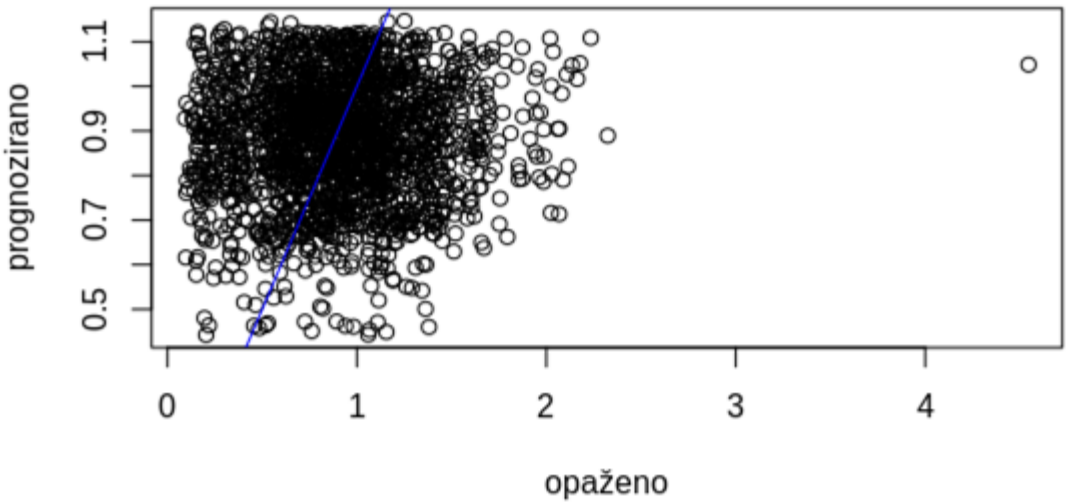
Zbirni izvještaj razvoja i vrednovanja jednostavnog modela linearne regresije s dva prediktora i bez slobodnog člana prikazan je u tablici 21.

Tablica 21. Granični zbirni izvještaj razvoja i vrednovanja jednostavnog model linearne regresije s dva prediktora (temperatura zraka, t (°C) i relativna vlažnost zraka (%)), bez slobodnog člana

Analitički oblik modela: $horiztropoudio = a_1 \cdot t + a_2 h$				
Analiza reziduala				
Minimum	**Prvi kvartil**	**Medijan**	**Treći kvartil**	**Maksimum**
-1,0917	-0,2677	0,0088	0,2854	4,1942
Koeficijenti modela				
	Vrijednost	**Standardna pogreška vrijednosti koeficijenta**	**Statistička značajnost, p<**	
a_1	0,0169484	0,0009934	2E-16 (statistički značajan)	
a_2	0,0094744	0,0001004	2E-16 (statistički značajan)	
Standardna pogreška reziduala (mjera opisa sistematske pogreške) (m)			0,4145	
R^2	0,8223	**Adj R^2**	0,8222	

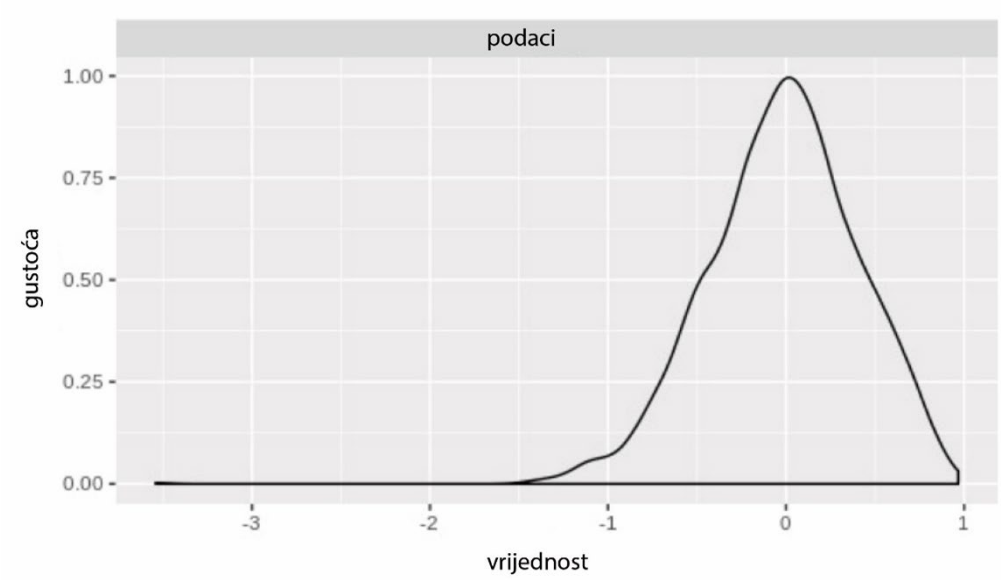
Zbirni izvještaj pokazuje kako su oba koeficijenta prediktora, a time i sami prediktori, statistički značajni ($p < 2{,}2e\text{-}16$). Dobivena p vrijednost je rezultat statističkog teksta kako je objašnjeno u dodanim referencama. Kolmogorov-Smirnovljev statistički test predstavlja test kojim se određuje slijedi li eksperimentalna razdioba referentnu (u ovom slučaju: Gaussovu) razdiobu. K-S test je elementarni standard u znanstvenom istraživanju i ne traži posebne opise (vidjeti brojne primjere u korištenja znanstvenoj literaturi). Standardna pogreška reziduala iznosi 0,4145 m. Podešeni koeficijent određenja *adj* R^2 = 0,8222, što odgovara 82,22 % pokrivene originalne varijance u eksperimentalnim opažanjima. Informacijski kriteriji navedenog modela iznose AIC = 8224,51, BIC = 8245,331, što ukazuje na relativno veliki gubitak informacija o procesu u slučaju primjene navedenog modela (Maindonald i Brown, 2010). Vrijednosti reziduala nalaze se u intervalu (-1,0197, 4,1942).

Slika 33 prikazuje P-O dijagram razvijenog eksperimentalnog modela. Plavom bojom označen je P-O dijagram najboljeg prognostičkog modela.



Slika 33. P-O dijagram jednostavnog modela linearne regresije s dva prediktora i bez slobodnog člana

Slika 34 prikazuje procijenjenu funkciju gustoće vjerojatnosti eksperimentalne statističke razdiobe reziduala razvijenog modela, uz prognozirane vrijednosti dobivene modelom linearne regresije s dva prediktora i bez slobodnog člana te uz opažene vrijednosti dobivene postupkom opisanim u potpoglavlju 5.5. U odnosu na normalnu, gustoća funkcije vjerojatnosti eksperimentalne statističke razdiobe je asimetrična, uz naglašeni donji (lijevi) rep razdiobe.



Slika 34. Procjena funkcije gustoće vjerojatnosti eksperimentalne statističke razdiobe reziduala jednostavnog modela linearne regresije s dva prediktora i bez slobodnog člana

6.1.2. Mješoviti prognostički model linearne regresije s tri prediktora i bez slobodnog člana

Na eksperimentalnim opažanjima (potpoglavlje 5.5) razvijen je prognostički model prikazan izrazom (119), s prediktorima temperatura zraka, izražena (°C), tlak zraka, izražen (hPa) te relativna vlažnost, izražena (%). Uočena blaga korelacija između dvaju prediktora, iskorištena je ovdje u definiciji mješovitog modela koji sadrži aditivni član sastavljen kao umnožak tlaka zraka i relativne vlažnosti.

$$\epsilon_{hor}[m] = 0{,}017222147\left[\frac{m}{°C}\right] \cdot t[°C] - 0{,}039668805\,[m] \cdot h[\%] + 0{,}000051570\left[\frac{m}{hPa}\right] \cdot p[hPa] \cdot h[\%] \tag{119}$$

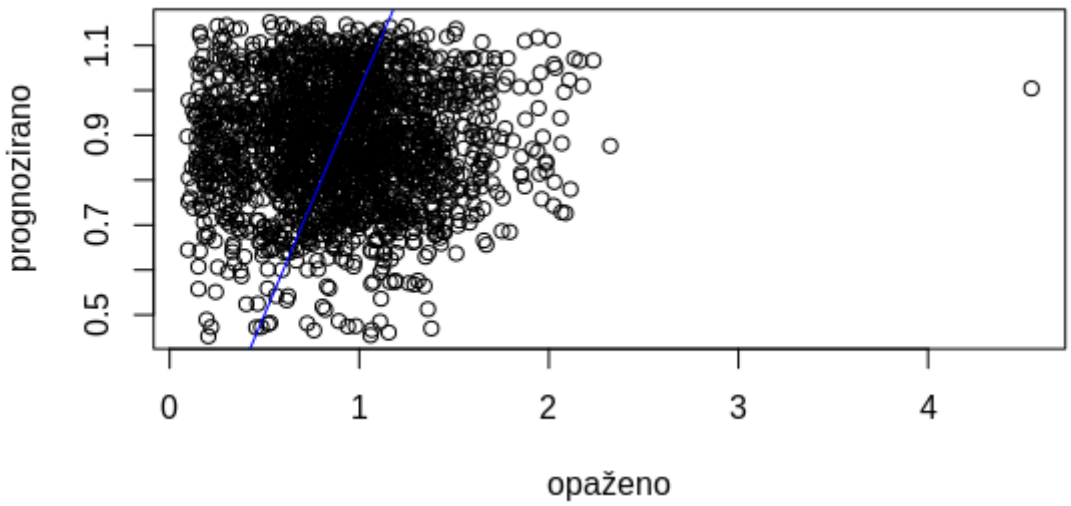
Zbirni izvještaj razvoja i vrednovanja djelomičnog mješovitog modela linearne regresije s tri prediktora i bez slobodnog člana prikazan u tablici 22.

Tablica 22. Zbirni izvještaj razvoja i vrednovanja mješovitog modela linearne regresije s tri prediktora (temperatura zraka, t (°C), tlaka zraka, p (hPa) i relativna vlažnost zraka h (%), bez slobodnog člana

Analitički oblik modela: $horiztropoudio = a_1 \cdot t + a_2 h + a_3 h \cdot p$				
Analiza reziduala				
Minimum	**Prvi kvartil**	**Medijan**	**Treći kvartil**	**Maksimum**
-1.0076	-0,2641	0,0065	0,2830	4,2392
Koeficijenti modela				
	Vrijednost	**Standardna pogreška vrijednosti koeficijenta**	**Statistička značajnost, p**	
a_1	0,017222147	0,000991138	< 2E-16 (statistički značajan)	
a_2	-0,03966881	0,007083407	= 2,21E-08 (statistički značajan)	
a_3	0.000051570	0,000007432	= 4,29E-12 (statistički značajan)	
Standardna pogreška reziduala (mjera opisa sistematske pogreške) (m)			0,4133	
R^2	0,8234		**Adj R^2**	0.8233

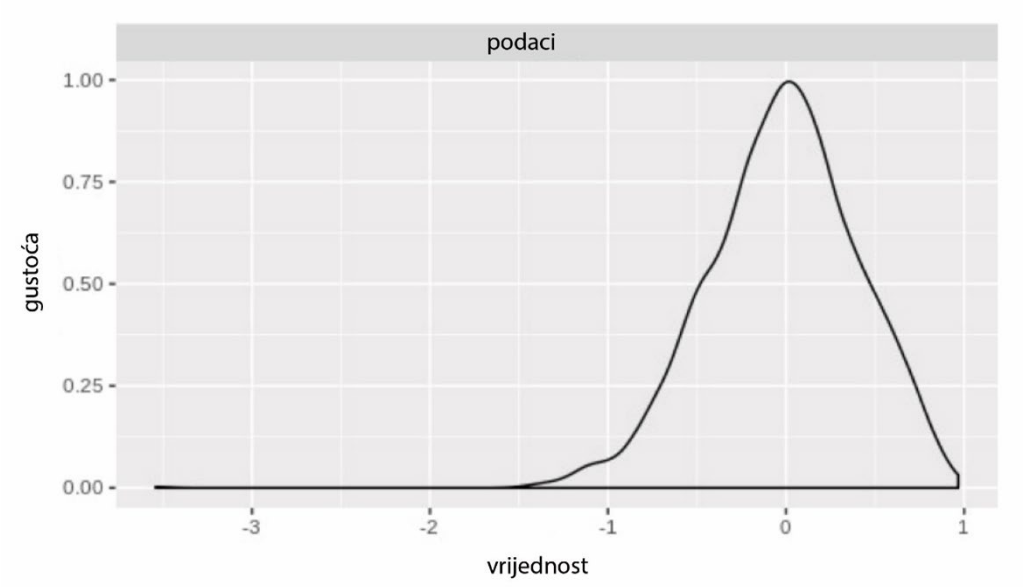
Zbirni izvještaj pokazuje kako su sva tri koeficijenta prediktora statistički značajna ($p < 2{,}2e\text{-}16$). Standardna pogreška reziduala iznosi 0,4133 m. Podešeni koeficijent određenja *adj* R^2 = 0,8233, što odgovara 82,33 % pokrivene originalne varijance u eksperimentalnim opažanjima. Informacijski kriteriji navedenog modela iznose AIC = 8178,500, BIC = 8206,262, što ukazuje na relativno veliki gubitak informacija o procesu uslijed primjene ovog prognostičkog modela. Vrijednosti reziduala nalaze se u intervalu (-1,0197, 4,1942).

Slika 35 prikazuje P-O dijagram razvijenog eksperimentalnog modela. Plavom bojom označen je P-O dijagram najboljeg modela. Kao i u prethodnom modelu (6.1.1), vidljivo je opsežno rasipanje dobivenih prognoza oko krivulje idealnog modela.



Slika 35. P-O dijagram mješovitog modela linearne regresije s tri prediktora i bez slobodnog člana

Slika 36. prikazuje procijenjenu funkciju gustoće vjerojatnosti eksperimentalne statističke razdiobe reziduala razvijenog mješovitog modela linearne regresije s tri prediktora i bez slobodnog člana. U odnosu na normalnu, gustoća funkcije vjerojatnosti eksperimentalne statističke razdiobe je asimetrična, uz naglašeni donji (lijevi) rep razdiobe.



Slika 36. Procjena funkcije gustoće vjerojatnosti eksperimentalne statističke razdiobe reziduala mješovitog modela linearne regresije s tri prediktora i bez slobodnog člana

Usporedba dvaju konkurentnih modela linearne regresije daje vrlo slična obilježja uspješnosti. Unošenje trećeg prediktora u postupak modeliranja stoga nije osnovano, budući da je poboljšanje kvalitete modela s tri prediktora u odnosu na model s dva zanemarivo malo ($\delta adjR^2 \ll 1\ \%$). Primjenom načela Occamove britve (oštrice) (Dalpiaz, 2019), kvalitetnijim modelom smatrat će se jednostavni prognostički model linearne regresije s dva prediktora i bez slobodnog člana.

6.2. Prognostički model zasnovan na metodi slučajne šume

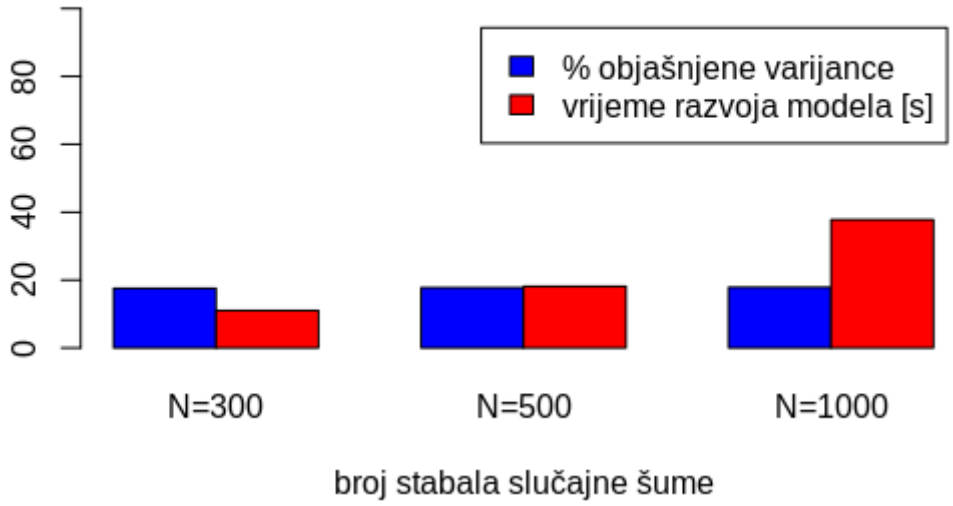
Model razvijen metodom slučajne šume je neparametarski model koji obuhvaća definirani broj stabala odlučivanja te daje izlaz na temelju većine glasova pojedinačnih stabala odlučivanja. Za potrebe ovog istraživanja, razvijena su tri klimatološka modela zasnovana na metodi slučajne šume s 300, 500 i 1000 stabala odlučivanja. Razmotrena su njihova obilježja uspješnosti uz korištenje skupa opažanja za vrednovanje te na temelju razmatranja izabran najbolji model prema kriterijima točnosti, složenosti modela i računalne učinkovitosti (vrijeme razvoja modela) na istom ulaznom skupu od 6680 vektora opažanja. Svaki vektor opažanja sadrži vrijednosti prediktora i ciljne varijable u jednom trenutku vremena. U promatranom razdoblju (1. siječnja – 30. travnja) očitano je 6680 vremenskih trenutaka u kojima su bila dostupna sva potrebna opažanja te je sukladno prethodnoj definiciji dobiven upravo taj broj vektora opažanja (iz raznih razloga u pojedinim trenucima opažanja nekih varijabli nisu bila dostupna u

korištenim bazama). Srednja kvadratna pogreška reziduala iznosila je približno 0,135 m za sva tri modela, što pokazuje kako modeli zasnovani na metodi slučajne šume izvanredno opisuju neravnomjernosti u doprinosu troposferskih učinaka ukupnoj pogreški određivanja položaja satelitskim sustavom. Međutim, za sva tri modela karakterističan je mali postotak pokrivene izvorne varijance. Uz male pojedinačne razlike, vrijednost objašnjene izvorne varijance iznosi tek oko 17,5 %. Navedeni rezultati, kao i njihova velika sličnost u konkurentnim modelima, upućuju na zaključak o preslikavanju naravi opažanja na cilj modela. Troposfersko kašnjenje, koje djeluje kao osnovni uzročnik pojave udjela troposferskih učinaka u ukupnoj horizontalnoj pogreški određivanja položaja, sastoji se od komponenata uslijed suhog i mokrog zraka. Komponenta suhog zraka je pretežno dominantna i zaslužna za neravnomjernosti. Komponenta mokrog zraka je pretežno minornog utjecaja pri čemu dolazi do izražaja uglavnom pri jačem razvoju promjena vremena, donoseći varijancu u troposferske učinke na ukupnu horizontalnu pogrešku satelitskog određivanja položaja. Postupak razvoja modela slučajne šume raspoznao je statističku značajnost dominantne komponente i posvetio se razvoju modela koji će dobro opisati upravo navedenu komponentu (slika 37).

Razmatranje računalne učinkovitosti razvoja promatranih modela (tablica 23) koji pokazuje očekivano kako je vrijeme razvoja povezano s kompleksnosti modela, izraženoj pomoću broja stabala odlučivanja. Model s više stabala traži veće vrijeme razvoja.

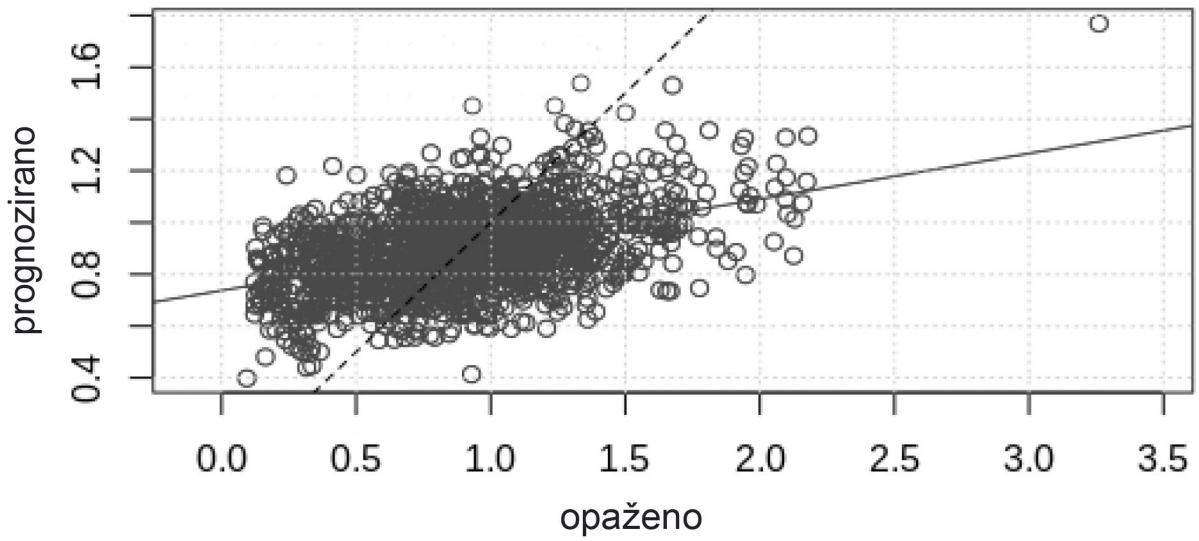
Tablica 23. Uspješnost modela slučajne šume

Struktura modela	**Vrsta modela**	**Model slučajne šume, regresijski**
	Broj stabala slučajne šume	1000
	Broj vektora opažanja	6880
Rezultati vrednovanja modela	**Srednja kvadratna pogreška reziduala (m), mjera opisa sistematske pogreške**	0,1326487
	Postotak objašnjene izvorne varijance (%)	17,87



Slika 37. Usporedba računalne učinkovitosti razvoja modela slučajne šume

Vođeni načelom Occamove britve (oštrice) (Dalpiaz, 2019) te uvažavajući ravnomjernost između kompleksnosti modela i odgovarajućeg poboljšanja njegovih obilježja uspješnosti, moguće je zaključiti kako najjednostavniji model udjela troposferskih učinaka na ukupnu horizontalnu točnost određivanja položaja zasnovan na slučajnoj šumi od 300 stabala odlučivanja može biti proglašen najboljim od predloženih kandidata. P-O dijagram navedenog modela prikazan je na slici 38. Vidljivo je kako model ima poboljšano poravnanje u odnosu na liniju pravca najmanjih kvadrata (puna linija), ali ne i poravnanje s P-O dijagramom idealnog modela (isprekidana linija).



Slika 38. P-O dijagram najboljeg modela udjela troposferskih učinaka na ukupnu horizontalnu točnost određivanja položaja zasnovan na slučajnoj šumi, od 300 stabala odlučivanja

6.3. Prognostički model zasnovan na metodi umjetne neuronske mreže

Razvijena su tri modela neuronskih mreža, s jednim, dva i tri skrivena sloja. Razvoj modela bio je zasnovan na korištenju istog eksperimentalnog skupa opažanja, opisanog u potpoglavlju 5.5. Strukture i obilježja modela te rezultati njihovog vrednovanja, predstavljeni su u ostatku potpoglavlja.

6.3.1. Neuronska mreža s jednim skrivenim slojem

Neuronska mreža s jednim skrivenim slojem, kao prognostički model udjela u ukupnoj horizontalnoj pogreški satelitskog određivanja položaja uslijed troposferskih učinaka, koristi strukturu kako je prikazano u tablici 24. U istoj tablici navedeni su težinski koeficijenti poveznica pojedinačnih neurona, kao i posmaci (dvije istosmjerne komponente ulaza u neurone, engl. bias).

Tablica 24. Obilježja neuronske mreže s jednim skrivenim slojem

Struktura mreže: 3-1-1	**Ulazni sloj s tri ulazna neurona (i1, i2, i3)**	**1 skriveni sloj, s 1 neuronom (h1), posmak bh1**	**1 izlazni neuron (o), posmak bo**
Prediktori	**Temperatura zraka (°C)**	**Tlak zraka (hPa)**	**Relativna vlažnost zraka (%)**
Vrijednosti težinskih koeficijenata			
b → h1	**i1 → h1**	**i2 → h1**	**i3 → h1**	
-0,66	0,23	0,29	-0,31	
b → o	**h1 → o**	**i1 → o**	**i2 → o**	**i3 → o**
0,26	0,59	-0,01	0,00	0,00

6.3.2. Neuronska mreža s dva skrivena sloja

Neuronska mreža s dva skrivena sloja, kao prognostički model udjela u ukupnoj horizontalnoj pogreški satelitskog određivanja položaja uslijed troposferskih učinaka, koristi strukturu kako je prikazano u tablici 25. U istoj tablici navedeni su težinski koeficijenti poveznica pojedinačnih neurona, kao i posmaci (tri istosmjerne komponente ulaza u neurone).

Tablica 25. Obilježja neuronske mreže s dva skrivena sloja

Struktura mreže: 3-2-1	**Ulazni sloj s tri ulazna neurona (i1, i2, i3)**	**1 skriveni sloj, s 2 neurona (h1, h2), 2 posmaka (bh1, bh2)**	**1 izlazni neuron (o), posmak bo**
Prediktori	**Temperatura zraka (°C)**	**Tlak zraka (hPa)**	**Relativna vlažnost zraka (%)**
Vrijednosti težinskih koeficijenata			
b → h1	**i1 → h1**	**i2 → h1**	**i3 → h1**	
-0,66	0,23	0,29	-0,31	
b → h2	**i1 → h2**	**i2 → h2**	**i3 → h2**	
-0,68	-0,36	0,27	0,23	
b → o	**h1 → o**	**h2 → o**	**i1 → o**	**12 → o**
0,04	0,17	0.65	-0,01	0,00

6.3.3. Neuronska mreža s tri skrivena sloja

Neuronska mreža s tri skrivena sloja, kao prognostički model udjela u ukupnoj horizontalnoj pogreški satelitskog određivanja položaja uslijed troposferskih učinaka, koristi strukturu kako je prikazano u tablici 26. U istoj tablici navedeni su težinski koeficijenti poveznica pojedinačnih neurona, kao i posmaci (četiri istosmjerne komponente ulaza u neurone).

Tablica 26. Obilježja neuronske mreže s tri skrivena sloja

Struktura mreže: 3-3-1	**Ulazni sloj s tri ulazna neurona (i1, i2, i3)**	**1 skriveni sloj, s 3 neurona (h1, h2), 2 posmaka (bh1, bh2, bh3)**	**1 izlazni neuron (o), posmak bo**
Prediktori	**Temperatura zraka (°C)**	**Tlak zraka (hPa)**	**Relativna vlažnost zraka (%)**
Vrijednosti težinskih koeficijenata			
b → h1	**i1 → h1**	**i2 → h1**	**i3 → h1**	
-0,66	0,23	0,29	-0,31	
b → h2	**i1 → h2**	**i2 → h2**	**i3 → h2**	
-0,68	-0,36	0,27	0,23	
b → h3	**i1 → h3**	**i2 → h3**	**i3 → h3**	
-0,31	-0,18	0,31	-0,02	
b → o	**h1 → o**	**h2 → o**	**h3 → o**	**i1 – > o**
0,40	-0,39	0.49	0,35	-0,01

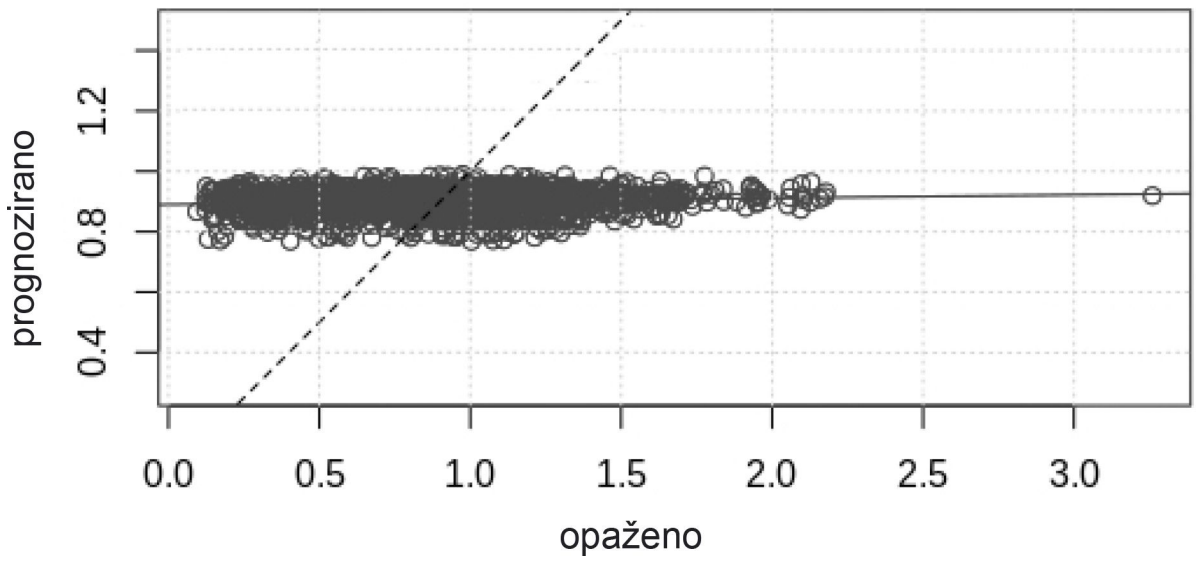
6.3.4. Analiza modela zasnovanih na umjetnoj neuronskoj mreži

Sva tri modela definiraju istu standardnu pogrešku reziduala (zbroj kvadrata pogrešaka reziduala) od 1067,9773 m te podešeni koeficijent određenja adj R^2 od 0,01169 (tablica 27). Također, iz tablice 27 vidljivo je kako s povećanjem kompleksnosti mreže blago rastu vrijednosti informacijskih statističkih kriterija AIC i BIC dok je suma kvadrata pogreške (engl. Sum of Square error - SSE) ili zbroja svih kvadratnih odstupanja u sva tri slučaja s jednim, dva i tri skrivena sloja navedena u tablici 27 s vremenom (T) potrebnim za razvoj modela označenim u sekundama.

Tablica 27. Obilježja uspješnosti modela zasnovanih na metodi umjetne neuronske mreže

Skriv. slojeva	P	SSE (m)	AIC	BIC	T_{razv} (s)
n = 1	9	1067,9773	-402,0136	-354,6121	0,12
n = 2	14	1067,9773	-392,0136	-318,278	0,15
n = 3	19	1067,9773	-382,0136	-281,9439	0,17

Rezultati vrednovanja modela pokazuju kako povećanje kompleksnosti ne doprinosi značajnijem poboljšanju kvalitete modela. AIC i BIC pokazatelji imaju minimalne vrijednosti u slučaju najjednostavnijeg modela umjetne neuronske mreže s jednim skrivenim slojem. Temeljem navedenih argumenata zaključuje se kako je najjednostavniji model udjela troposferskih učinaka na ukupnu horizontalnu točnost određivanja položaja zasnovan na umjetnoj neuronskoj mreži s jednim skrivenim slojem najbolji model od razmotrenih kandidata kako je prikazano na slici 39.



Slika 39. P-O dijagram modela udjela troposferskih učinaka na ukupnu horizontalnu točnost određivanja položaja zasnovan na umjetnoj neuronskoj mreži, s jednim skrivenim slojem

6.4. Zbirna ocjena sukladnosti sa zahtjevima za točnost određivanja položaja za navigacijske postupke u pomorskoj površinskoj navigaciji

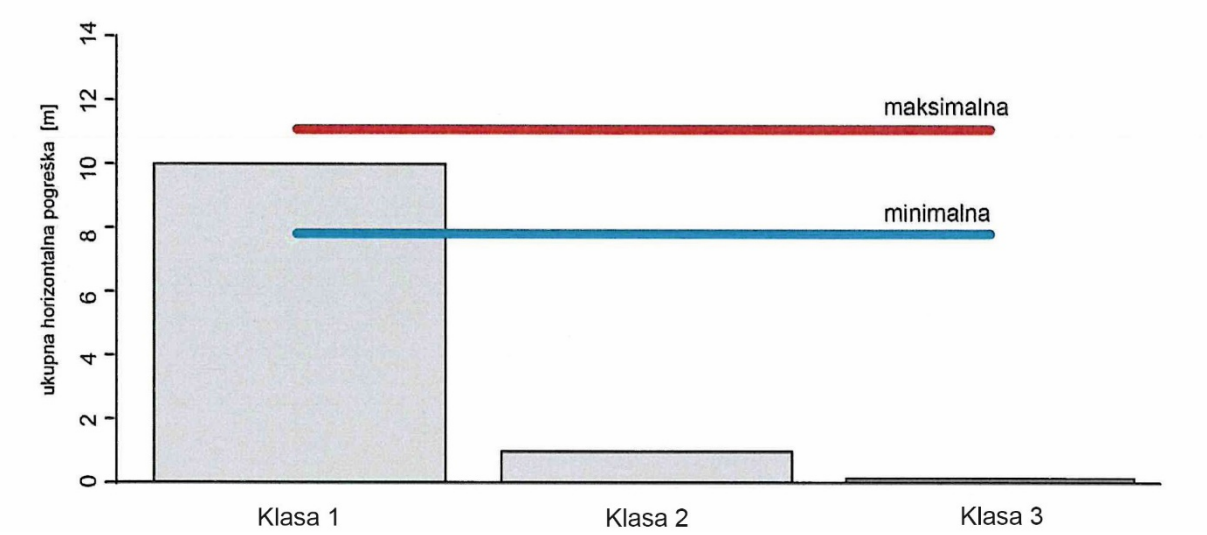
Analiza dugoročne kvalitete određivanja položaja satelitskim navigacijskim sustavom u pomorskoj površinskoj navigaciji (potpoglavlje 5.5) i uspješnosti razvijenih modela doprinosa troposferskih učinaka ukupnoj pogreški satelitskog određivanja položaja (potpoglavlja 6.1 – 6.3) te klasifikacijski model primjena satelitske navigacije u pomorskoj površinskoj navigaciji (potpoglavlje 4.1) omogućuju zbirnu ocjenu sukladnosti sa zahtjevima za točnost određivanja položaja za navigacijske postupke u pomorskoj površinskoj navigaciji. Navedena zbirna ocjena određena je temeljem četiri graničnih scenarija:

1. Scenarij A, uz pretpostavku eksperimentalnih nepopravljenih vrijednosti udjela troposferskih učinaka i maksimalnih doprinosa ostalih učinaka ukupnoj pogreški satelitskog određivanja položaja (prema tablici 4, potpoglavlje 2.4),
2. Scenarij B, uz pretpostavku eksperimentalnih nepopravljenih vrijednosti udjela troposferskih učinaka i potpuno popravljenih doprinosa ostalih učinaka ukupnoj pogreški satelitskog određivanja položaja,
3. Scenarij C, uz pretpostavku eksperimentalnih vrijednosti udjela troposferskih učinaka popravljenih najboljim modelom (linearna regresija, potpoglavlje 6.1) i maksimalnih doprinosa ostalih učinaka ukupnoj pogreški satelitskog određivanja položaja (prema tablici 4, potpoglavlje 2.4) te
4. Scenarij D, uz pretpostavku eksperimentalnih vrijednosti udjela troposferskih učinaka popravljenih najboljim modelom (linearna regresija, potpoglavlje 6.1) i potpuno popravljenih doprinosa ostalih učinaka ukupnoj pogreški satelitskog određivanja položaja.

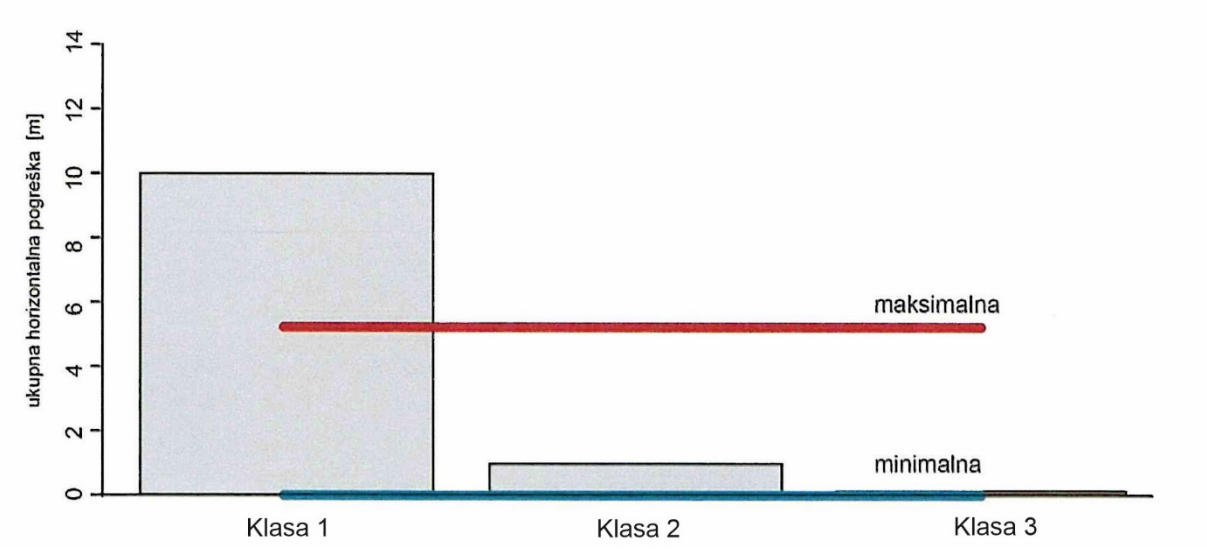
Scenarij A predstavlja ekstremni slučaj potpunog zanemarenja troposferskih učinaka u istovremeno ekstremnim uvjetima ostalih utjecajnih veličina. Iako najmanje vjerojatan, ovakav scenarij treba biti razmotren sa stajališta rizika korištenja satelitske navigacije. Rezultat ocjene sukladnosti sa zahtjevima za točnost određivanja položaja za navigacijske postupke u pomorskoj površinskoj navigaciji prikazan je slikom 40. Vidljivo je kako postignuta horizontalna točnost određivanja položaja u svojoj maksimalnoj vrijednosti ne omogućuje zadovoljavanje zahtjeva točnosti određivanja položaja ni za jednu klasu primjena u pomorskoj površinskoj navigaciji. Postignuta horizontalna točnost određivanja položaja u svojoj

minimalnoj vrijednosti omogućuje zadovoljavanje zahtjeva za točnost satelitskog određivanja položaja tek za klasu 1 primjena u pomorskoj površinskoj navigaciji.

Scenarij B obuhvaća slučajeve u kojima su učinci svih utjecajnih veličina osim troposferskog kašnjenja uspješno popravljeni, a troposferski učinci ostavljeni kao nepopravljeni. Scenarij je moguć uz korištenje dodatnih izvora i potpomognute informacije o stanju ionosfere i satelitskih satova te uz napredne mjere potiskivanja učinaka višestaznih puteva. Ocjena sukladnosti sa zahtjevima izvedena je na temelju dijagrama sa slike 41. Zahtjevi klase 1 pomorskih navigacijskih postupaka (primjena) ispunjeni su neovisno o rasponu vrijednosti doprinosa ukupnoj pogreški određivanja položaja satelitskim sustavom zbog troposferskih učinaka. Zahtjevi klase 2 ispunjeni su uz minimalni doprinos ukupnoj pogreški određivanja položaja satelitskim sustavom zbog troposferskih učinaka. Zahtjevi klase 3 nisu ispunjeni.



Slika 40. Preslikavanje graničnih vrijednosti ukupne pogreške satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, procijenjene pomoću stvarnog doprinosa uslijed troposferskih učinaka i uobičajenih vrijednosti ostalih doprinosa, na zahtjeve za točnost određivanja položaja klasa primjena u pomorskoj površinskoj navigaciji

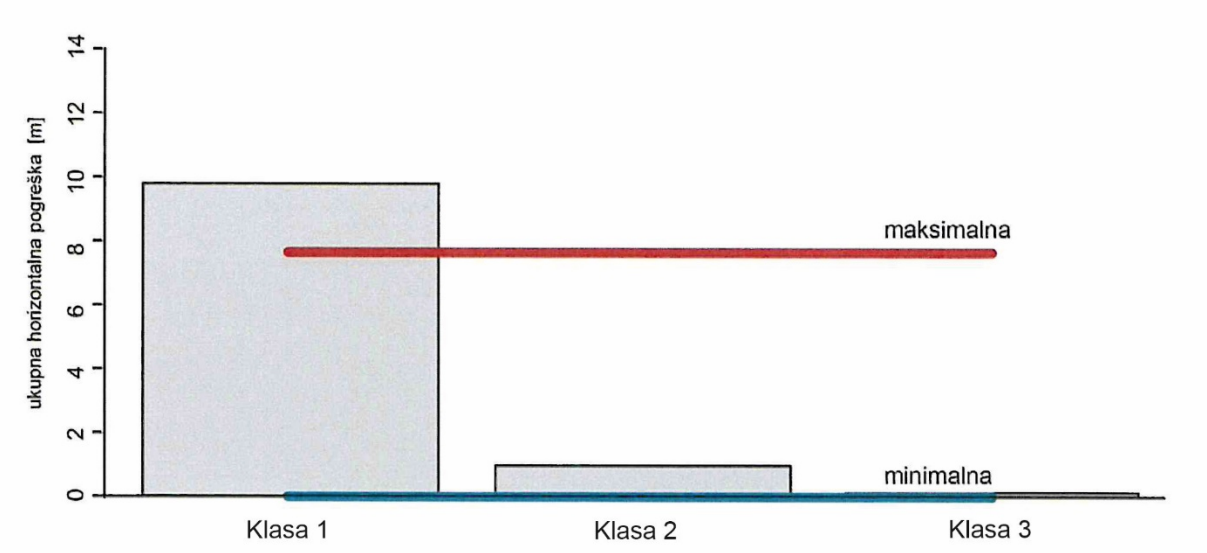


Slika 41. Preslikavanje graničnih vrijednosti ukupne pogreške satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, u scenariju jedinog doprinosa uslijed troposferskih učinaka i bez ostalih doprinosa, na zahtjeve za točnost određivanja položaja klasa primjena u pomorskoj površinskoj navigaciji

U scenarijima C i D pretpostavljeni su popravci učinaka troposfere postignuti najboljim modelom od razmotrenih kandidata u potpoglavljima 6.1 – 6.3 Prognostički model popravaka zasnovan na metodi linearne regresije bez mješovitog člana dao je srednju pogrešku reziduala od približno 0,4145 m, što je uzeto kao doprinos ukupnoj pogreški satelitskog određivanja položaja uslijed troposferskih učinaka. Potrebno je naglasiti kako je primjenom klimatološkog modela popravaka omogućen izravan popravak pogreške određivanja položaja satelitskim sustavom, u usporedbi s postojećim uobičajenim postupkom popravljanja mjerenih pseudoudaljenosti modelom po Saastamoinenu.

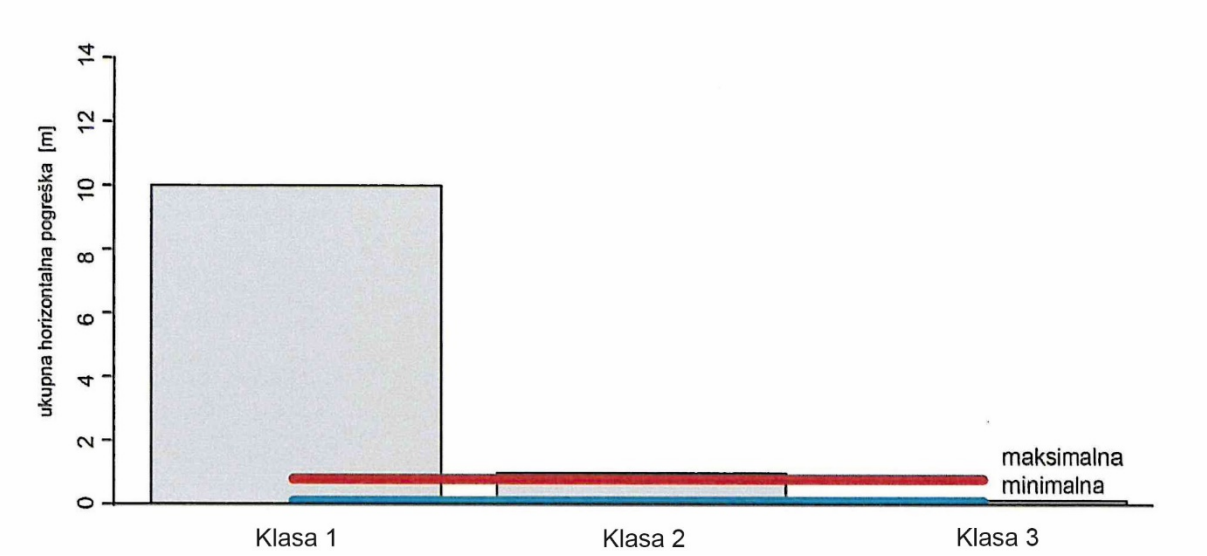
U scenariju C (slika 42) popravljeni doprinos troposferskih učinaka ukupnoj pogreški satelitskog određivanja položaja manji je od karakteristične vrijednosti (potpoglavlje 2.4, tablica 4).

Međutim, primjena modela nije znatno smanjila ukupnu pogrešku satelitskog određivanja položaja u odnosu na slučaj iz tablice 4, potpoglavlje 2.4, osim zbog smanjene vrijednosti horizontalne geometrijske degradacije točnosti što je vidljivo u navedenoj tablici (HDOP = 2,0). Zbog tog, ciljani popravak doprinosa uslijed troposferskog kašnjenja ukupnoj pogreški određivanja položaja zadovoljava jedino zahtjeve za točnošću klase 1 (slika 42).



Slika 42. Preslikavanje vrijednosti ukupne pogreške satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, u scenariju popravljenog doprinosa uslijed troposferskih učinaka i uobičajenih doprinosa uslijed učinaka ostalih utjecajnih veličina, na zahtjeve za točnost određivanja položaja klasa primjena u pomorskoj površinskoj navigaciji.

Scenarij D obuhvatio je ukupnu pogrešku satelitskog određivanja položaja koja obuhvaća samo doprinos uslijed troposferskih učinaka, čime je postignuto zadovoljavanje zahtjeva za ukupnom točnošću klasa 1 i 2 (slika 43).



Slika 43. Preslikavanje graničnih vrijednosti raspona ukupne pogreške satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, u scenariju popravljenog doprinosa uslijed troposferskih učinaka ali bez drugih doprinosa kao i troposferskog udjela, na zahtjeve za točnost određivanja položaja klasa primjena u pomorskoj površinskoj navigaciji

Prijedlog klasifikacije navigacijskih postupaka u pomorskoj površinskoj navigaciji, zajedno sa zahtjevima na najveće prihvatljive pogreške u određivanju položaja zasnovan je na prethodnim istraživanjima i standardima, ali i operativnom iskustvu autora i drugih relevantnih čimbenika koji svakodnevno izvršavaju navigacijske zadatke (poglavlje 4.1, 5.6 i tablice 17 i 18) u pomorskim operacijama. Za razliku od većine drugih prijedloga klasifikacije, predloženi model klasifikacije uveo je uvažavanje zahtjeva za točnošću određivanja položaja u navigacijskim postupcima ratne mornarice (poglavlje 4.1, poglavlje 5.6 i tablice 17 i 18), unutar dosega javno dostupnih informacija, čime je obuhvatio daleko veći broj navigacijskih postupaka u pomorskoj površinskoj navigaciji i omogućio njihovo daljnje poopćavanje.

7. DISKUSIJA

Predstavljeno istraživanje razmotrilo je važne neodgovorene probleme vezane za održivu i sustavnu primjenu satelitske navigacije u pomorskoj površinskoj navigaciji, za potrebe razvoja sustava i usluga zasnovanih na satelitskoj navigaciji.

Izvedeno u suglasju s uobičajenim praksama znanstveno-istraživačkog rada, istraživanje je predložilo odgovore na probleme klasifikacije navigacijskih postupaka u pomorskoj površinskoj navigaciji, razumijevanja prirode doprinosa troposferskih učinaka na ukupnu točnost određivanja položaja satelitskim sustavom te povezivanje zahtjeva za točnost određivanja položaja za navigacijske postupke u pomorskoj površinskoj navigaciji s mogućnosti koje pruža satelitska navigacija.

Temeljem rezultata opisne statističke analize, donesena je odluka o pristupu razvoja modela u vremenskoj domeni gdje je predložen pokazatelj uspješnosti kojim je izvršena validacija razvijenih modela na eksperimentalnim podacima prikupljenim za ekstremne promjene meteorološkog vremena. Korištena je opisna (eksploratorna) statistička analiza podataka, analizirani su reziduali i njihove varijance te je donesena odluka o pristupu razvoja modela u vremenskoj i frekvencijskoj domeni gdje je predložen pokazatelj uspješnosti kojim je izvršena validacija razvijenih modela. Praktična izvedba provjere uspješnosti razvijenih modela izvedena je vlastitom programskom podrškom razvijenom u programskom okruženju za statističko računarstvo R.

Analiza prirode doprinosa troposferskih učinaka ukupnoj horizontalnoj pogreški određivanja položaja zasnovana je na eksperimentalnim opažanjima na jednoj referentnoj stanici u širem području Jadranskog mora. Opažanja su pokrila četveromjesečno razdoblje uz pretpostavku pokrivanja svih karakterističnih scenarija promjena meteoroloških prilika koje se preslikavaju na uvjete satelitskog određivanja položaja. Razvijen je niz prognostičkih modela koji su uglavnom naglasili sistematsku pogrešku troposferskog kašnjenja kao dominantnu, dok je varijanca nastala kao rezultat slučajne pogreške znatno lošije objašnjena. Modeli su razvijeni postupcima strojnog učenja u programskom okruženju R. Razmotren je niz pokazatelja vrednovanja modela, s posebnim naglaskom na ocjenu opisa sistematske pogreške i varijance, očuvanje informacijskog sadržaja izvornog procesa nakon primjene modela, složenost modela, kao i ravnomjernost kvalitete modela po rasponu očekivanih vrijednosti prognozirane veličine udjela u ukupnoj horizontalnoj pogreški određivanja položaja satelitskim sustavom, nastalog

uslijed djelovanja troposferskih učinaka. Najuravnoteženija obilježja po definiranim kriterijima vrednovanja iskazao je višestruki model linearne regresije (poglavlje 4).

Razmotrena je vremenska komponenta pogreške određivanja položaja dok je razmatranje prostorne naravi pogreške određivanja položaja satelitskim sustavom ostavljeno za daljnja istraživanja. Nastavak istraživanja izvan dosega ove disertacije posvetit će se oblikovanju baze podataka koja će obuhvatiti višegodišnje vremensko razdoblje, kao još bolji predstavnik statističkih obilježja analiziranih pokazatelja točnosti satelitskog određivanja položaja. Na takav povećani skup vektora opažanja, koji će još potpunije obuhvatiti ukupnu populaciju meteoroloških pojava, ponovo će biti primijenjen niz postupaka za razvoj prognostičkih modela zasnovanih na statističkom učenju. Iako će ponovo znantno povećanje obujma podataka dovesti do novih istraživačkih izazova, metodologija prikupljanja, razvoja i vrednovanja modela prikazana u ovoj disertaciji i dalje ostaje primjenjiva.

Razumijevanje doprinosa troposferskih učinaka na ukupnu pogrešku satelitskog određivanja položaja poboljšano je metodom izravnog izdvajanja navedenog doprinosa pomoću naknadne procjene položaja iz izmjerenih pseudoudaljenosti i na njoj zasnovane analize točnosti određivanja položaja, umjesto analize troposferskih učinaka na samo mjerenje pseudoudaljenosti. Radi potpunosti predložen je i teorijski model transformacije pogreške mjerenja pseudoudaljenosti u doprinos troposferskih učinaka ukupnoj pogreški određivanja položaja satelitskim sustavom. Troposferski učinci najteži su za proučavanje, jer ne postoji jedinstveni i prihvatljivi objektivni način za određivanje bilo troposferskog kašnjenja bilo troposferskog doprinosa ukupnoj pogreški određivanja položaja satelitskim sustavom koji bi bio neovisan o geografskim koordinatama položaja na kojem su uzimana opažanja. Kao referenca, ovdje su uzete procjene položaja dobivene pseudoudaljenostima popravljenim pomoću Saastamoinenovog modela. U nastavku istraživanja, razmotreno je korištenje drugih postupaka preciznog određivanja položaja referentnih stanica pomoću kojih bi se definirao točan položaj i time dobio standard (referentni položaj) potreban za određivanje troposferskog doprinosa ukupnoj pogrešci satelitskog određivanja položaja. Međutim, neovisno o tome, u ovoj disertaciji je prikazana metodologija razvoja modela popravaka troposferskog doprinosa ukupnoj pogreški određivanja položaja, zasnovana na metodama strojnog učenja na eksperimentalnim opažanjima.

Razvijeni modeli su visoke interne razine kompleksnosti, ali ona nije izražena prema van. Samim postupkom razvoja modela postignuta je i optimizirana izgradnja njegove unutarnje strukture, pri čemu je rezultat model tipa crne kutije. Prikazani modeli razvijeni postupcima

strojnog učenja nude brojne operativne prednosti nad postojećim tradicionalnim modelima: adaptivnost uvjetima i stanjima troposfere, fleksibilnost, samopodešavanje, učenje na novim slučajevima te znančajno lakšu operativnu provedbu u odgovarajućem računalnom okruženju.

Kontinuirano i dosljedno opažanje odnosnih meteoroloških prediktora i pogreške određivanja položaja s i bez popravaka mjerenih pseudoudaljenosti zbog troposferskog kašnjenja, omogućit će i provjeru ispravnosti Saastamoinenovog modela popravaka, ali i razvoj ciljanih modela popravaka pogreške određivanja položaja za pojedine klase navigacijskih postupaka u pomorskoj površinskoj navigaciji.

Prikazani modeli razvijeni su na eksperimentalnim opažanjima s jedne promatračke stanice. Troposfersko kašnjenje, kao i pogreška određivanja položaja satelitskim sustavom imaju prostorno-vremensku narav (Baddeley, Rubak, Turner, 2015). Zbog toga će nastavak istraživanja obuhvatiti i razmatranje prostorne asocijacije varijabli te prostorne naravi pogreške određivanja položaja satelitskim sustavom.

Na kraju, predloženi model klasifikacije omogućio je povezivanje zahtjeva za točnost određivanja položaja s kvalitetom određivanja položaja (prije svega točnosti) koje pruža jezgrena satelitska navigacija, čime je objektivno ukazano na potrebe korištenja naprednih satelitskih navigacijskih postupaka (podupirući sustavi, kao EGNOS, precizno određivanje položaja s dodatnim informacijama trećih strana, kao RTK i dr.), odnosno fuzije očitanja osjetila (rezultata procjena položaja individualnim postupcima određivanja položaja) za potrebe ostvarenja zahtijevane točnosti pojedinih klasa. Istraživačka tema ostaje otvorena za nastavak istraživanja kao i mogućnost daljnjeg istraživanja koja se odnose na proširenje baze podataka na veće vremensko razdoblje te preuzimanje podataka s drugih neovisnih stanica kako bi se dodatno verificirali rezultati istraživanja. Buduća će istraživanja razmotriti i druge modele osim Saastamoinenovog i Niellovog modela te će također obuhvatiti razvoj novih postupaka određivanja položaja koji uzimaju u obzir statističku značajnost pojedinačnih uzroka narušavanja točnosti određivanja položaja i obavljaju samopodešavanje s ciljem dobivanja optimalne procjene položaja, ovisno o zadanom stanju okoliša za određivanje položaja.

Optimizacija postupka satelitskog određivanja položaja prema zahtjevima usluga koje koriste procjenu položaja također je iznimno važna tema budućih istraživanja, uz potrebu za kvalitetnom definicijom zahtijevane točnosti određivanja položaja satelitskim sustavima za pojedine klase primjena i zahtjevima o potrebnoj točnosti određivanja položaja (tablica 17 i tablica 18) satelitske navigacije.

8. ZAKLJUČAK

Disertacija predstavlja rezultate istraživanja doprinosa učinaka troposferskog kašnjenja ukupnoj pogreški određivanja položaja satelitskim navigacijskim sustavima kao i potencijalno narušavanje točnosti određivanja položaja i neispunjavanje zahtjeva za točnost određivanja položaja uslijed učinaka troposfere za klase navigacijskih postupaka (primjena) u pomorskoj površinskoj navigaciji. Istraživanje je napravljeno uz pretpostavku korištenja samostalnog, nepotpomognutog postupka određivanja položaja satelitskim navigacijskim sustavom, uz korištenje jednofrekvencijske korisničke opreme komercijalne naravi konstruirane za potrebe u pomorskoj površinskoj navigaciji. Istraživanjem nisu obuhvaćeni napredni postupci satelitskog određivanja položaja, poput preciznog određivanja točke položaja i kinematike u stvarnom vremenu te diferencijalnog GPS sustava. Također, razmotrena je vremenska komponenta pogreške dok je razmatranje prostorne naravi pogreške određivanja položaja satelitskim sustavom ostavljeno za nastavak istraživanja izvan dosega ove disertacije.

Razmotrene su matematičke i fizikalne osnove satelitskog određivanja položaja te proračun pogrešaka, s posebnim naglaskom na razumijevanje nastanka i pojavnosti troposferskih učinaka. Analizirani su postojeći modeli popravaka mjerenja pseudoudaljenosti, kao posrednih uzroka narušavanja točnosti određivanja položaja satelitskim sustavom. Raščlanjen je postupak procjene položaja. Uočena je suštinska razlika između pogreške mjerenja pseudoudaljenosti i pogreške određivanja položaja te predložen novi model transformacija (prijelaza) pogreške mjerenja pseudoudaljenosti u pogrešku određivanja položaja. Temeljem analize prethodnih istraživanja, anketa i razgovora te vlastitog iskustva predložen je model klasifikacije navigacijskih postupaka (primjena) u pomorskoj površinskoj navigaciji, zajedno sa zahtjevima za točnost određivanja položaja za pojedine klase. Oblikovana je baza odnosnih opažanja prediktora (opisnih veličina) stanja troposfere te opaženih doprinosa ukupnoj pogreški određivanja položaja u četveromjesečnom vremenskom razdoblju na temelju opažanja na referentnoj stanici Matera (Italija) u regiji Jadranskog mora u razdoblju 1. siječnja 2019. – 10. travnja 2019. Opisnom statističkom analizom identificirana su meteorološka obilježja te određena statistička narav doprinosa troposferskih učinaka ukupnoj horizontalnoj pogreški određivanja položaja. Navedeno je iskorišteno u razvoju kandidata modela za procjenu troposferskog doprinosa ukupnoj pogreški određivanja položaja satelitskim sustavom, uz primjenu metoda razvoja modela zasnovanih na statističkom učenju i eksperimentalnim opažanjima. Kandidati modela za procjenu troposferskog doprinosa ukupnoj pogreški

određivanja položaja satelitskim sustavom analizirani su prema definiranim mjerilima uspješnosti. Izabran je model zasnovan na metodi linearne regresije kao najuspješniji od razmotrenih kandidata. Model je iskorišten za ocjenu ispunjavanja zahtjeva za točnost određivanja položaja satelitskim sustavom za različite klase navigacijskih postupaka u pomorskoj površinskoj navigaciji. Pokazano je kako primjena modela omogućuje ispunjavanje zahtjeva za točnost određivanja položaja satelitskim sustavom za dvije od tri klase navigacijskih postupaka u pomorskoj površinskoj navigaciji. Razmotrena su ograničenja postignutih rezultata uključujući i prognostičke modele, čime su određene teme budućih istraživanja. Na kraju, rezultati su razmotreni sa stajališta primjena u pomorskoj površinskoj navigaciji, posebno u navigacijskim postupcima za potrebe ratne mornarice.

Prikazanim istraživanjem ostvaren je izvorni znanstveni doprinos razvoja modela koji povezuje troposfersko kašnjenje satelitskog signala za određivanje položaja sa zahtjevima za točnost određivanja položaja pojedinih osnovnih navigacijskih zadataka u pomorskoj površinskoj navigaciji,

Drugi znanstveni doprinos je model klasifikacije navigacijskih zadataka u pomorskoj površinskoj navigaciji prema zahtjevima o potrebnoj točnosti određivanja položaja,

U zadnjem znanstvenom doprinosu predstavljan je razvijen model matematičke transformacije troposferskog kašnjenja satelitskog signala za određivanje položaja u pogrešku određivanja položaja satelitskim sustavom.

Buduća istraživanja primijenit će metodologiju prikazanu u ovom radu na još širu bazu eksperimentalnih opažanja i vrijednosti udjela u horizontalnoj pogreški satelitskog određivanja položaja uslijed troposferskih učinaka dobivenih preciznijim modelima i postupcima izravnog mjerenja. Napredni postupci strojnog učenja koji će uvažiti nove detalje statističkog opisa eksperimentalnih opažanja omogućit će razvoj još kvalitetnijih prognostičkih modela. Na kraju, disertacija je naglasila značaj motrenja stvarnog stanja atmosfere i korištenja stvarnih pokazatelja u trenutku izračuna prognoze na kvalitetniji ispravak pogreške uslijed učinka troposfere na raznim konkretnim pojedinačnim navigacijskim zadacima u pomorskoj površinskoj navigaciji. Novi zadaci proizašli iz primjene novih i nadolazećih tehnologija učinit će navedeno istraživačko područje i dalje otvorenim.

9. LITERATURA

[1] Anđelini M., Lučić A., Filjar R. (2014). Satellite positioning error model for Location-Based Services. *Proc of 10th Annual Baška GNSS Conference*, 105-110. Baška, Krk Island, Croatia.

[2] Ajayi G. O. (1989). Physics of the Tropospheric Radiopropagation. International Centre for Theoretical Physics (ICTP). Miramare, Trieste, Italy. Dostupno na: https://inis.iaea.org/collection/NCLCollectionStore/_Public/20/052/20052042.pdf

[3] Baddeley A., Rubak E., Turner R. (2015). Spatial Point Patterns: Methodology and Applications with R. Chapman & Hall/CRC. Batton Rouge, FL.

[4] Bolar K. (2019). STAT: Interactive Document for Working with Basic Statistical Analysis (R knjižnica). Dostupno na: https://cran.r-project.org/web/packages/STAT/index.html

[5] Box G. E. P. (1976). Science and statistics. Journal of the American Statistical Association, 71(356): 791–799. doi: 10.1080/01621459.1976.10480949

[6] Boyd S., Vandenberghe L. (2004). Convex Optimization. Cambridge University Press. Cambridge, UK. Dostupno na: https://stanford.io/1FPvwqC

[7] Brown A. (2000). Multipath Rejection Through Spatial Processing, dostupno na: https://www.semanticscholar.org/paper/Multipath-Rejection-Through-Spatial-Processing-Brown/85cef622b2ab49a6206167f5f0e9fc5de0385d4c

[8] COST Action TU 132 SaPPART. (2017). SaPPART Handbook: Assessment of positioning performance in ITS applications. IFSTTAR. Marne-la-Vallee, France. Dostupno na: https://infoscience.epfl.ch/record/229198.

[9] Cui B. (2020). DataExplorer: Automate Data Exploration and Treatment (R knjižnica). Dostupno na: https://cran.r-project.org/web/packages/DataExplorer/index.html

[10] Dalpiaz D. (2019). Applied Statistics with R. University of Illinois. Urbana-Champain, IL. Dostupno na: https://daviddalpiaz.github.io/appliedstats/

[11] Davies K. (1990). Ionospheric Radio. Peter Peregrinus Ltd. London, UK.

[12] De Norske Veritas. Høvik, Norveška. (Dynamic positioning vessel – DNV), (DNV, 2018). Autonomous and remotely operated ships (DNVGL-CG-0264) – Class

Guideline. Dostupno na: http://rules.dnvgl.com/docs/pdf/dnvgl/cg/2018-09/dnvgl-cg-0264.pdf

[13] Efron B., Hastie T. (2016). Computer Age Statistical Inference: Algorithms, Evidence, and Data Science. Cambridge University Press. Cambridge, UK. Dostupno na: https://web.stanford.edu/~hastie/CASI_files/PDF/casi.pdf

[14] Feynman R. P. (2018). Feynman Lectures on Computation (edited by T. Hey and R. W. Allen). CRC Press. Boca Ratton, FL.

[15] Feynman R. P., Leighton R., Sands M. (1963). Lectures on Physics, Vol. II., Mainly Electromagnetism and Matter. California Institute of Technology (CalTech). Pasadena, CA. Dostupno na: https://www.feynmanlectures.caltech.edu/II_toc.html

[16] Filić M. (2019). GNSS Navigation Message Authentication Using TESLA. Proc 13th Baška GNSS Conference, 29-45. Baška, Krk Island, Croatia. Dostupno na: https://www.pfri.uniri.hr/web/hr/dokumenti/13-GNSS-2019_Final.pdf

[17] Filić M. (2018). Foundations of GNSS spoofing detection and mitigation with distributed GNSS SDR receiver. TransNav, 12(4), 649-656. doi: 10.12716/1001.12.04.01

[18] Filić M., Dimc F. (2019). Logistic map-encrypted PRN code as a proposed alternative to GNSS PRN pseudo-range code. TransNav, 13(3), 587-590. doi: 10.12716/1001.13.03.14

[19] Filić M., Filjar R. (2018a). Forecasting model of space weather-driven GNSS positioning performance. Lambert Academic Publishing. Riga, Latvia. ISBN 978-613-9-90118-0.

[20] Filić M., Filjar R. (2018b). Smartphone GNSS positioning performance improvements through utilisation of Google Location API. *Proc of 41 st International Convention MIPRO/CTI*, 507-510. Opatija, Croatia. doi: 10.23919/MIPRO.2018.8400087

[21] Filić M., Filjar R. (2018c). A South Pacific Cyclone-Caused GPS Positioning Error and Its Effects on Remote Island Communities. TransNav, 12(4), 663-670. doi: 10.12716/1001.12.04.03

[22] Filić M., Filjar R., Ševrović M. (2018). Expression of GNSS Positioning Error in Terms of Distance. *Promet – Traffic & Transportation*, 30(3), 305-310. doi:10.7307/ptt.v30i3.2304

[23] Filić M., Špoljar D., Filjar R. (2018). GNSS positioning performance monitoring using anonymised raw pseudoranges in ITS. *Proc of 38th KoREMA Automation in Transportation Conference*, 127 – 131. Osijek, Croatia, and Budapest, Hungary.

[24] Filić M. (2017). Analiza postupka procjene položaja temeljem zadanih pseudoudaljenosti u programski određenom prijamniku za satelitsku navigaciju (diplomski rad). Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Matematički odsjek. Dostupno na: https://zir.nsk.hr/islandora/object/pmf%3A3230

[25] Filić M., Grubišić L., Filjar R. (2018). Improvement of standard GPS position estimation algorithm through utilization of Weighted Least-Square approach. *Proc of 11th Annual Baška GNSS Conference*, 7–19. Baška, Krk Island, Croatia. Dostupno na: https://www.researchgate.net/publication/328860394_Improvement_of_standard_GPS_position_estimation_algorithm_through_utilization_of_Weighted_Least-Square_approach

[26] Filić M., Filjar R., Ruotsalainen L. (2016). An SDR-Based Study of Multi-GNSS Positioning Performance During Fast-Developing Space Weather Storm. *TRANSNAV*, 10(3), 395-400. doi: 10.12716/1001.10.03.03. Dostupno na:https://www.transnav.eu/Article_An_SDR-based_Study_of_Multi-GNSS_Fili%C4%87,39,660.html

[27] Filjar R. (2019). On suitability of massive GNSS pseudorange data for GNSS positioning performance studies. Proc of 12th Baška GNSS Conference, 7-27. Baška, Krk Island, Croatia. Dostupno na: https://www.navnin.nl/new/wpcontent/uploads/2017/12/12th-Annual-RIN-Baska-GNSS-Conference_2018_rev_0.6.pdf

[28] Filjar R., Luttenberger A., Kos S. (2013). A proposal for GNSS failure legal liabilities scheme. *Proc of 6th GNSS Vulnerabilities and Solutions Conference*, 77-87. Baška, Krk Island, Croatia. Dostupno na: https://www.pfri.uniri.hr/web/hr/dokumenti/zbornici-gnss/2012-GNSS-6.pdf

[29] Filjar R., Huljenić D., Lenac K. (2013). Enhancing Performance of GNSS Position Estimation by Cloud-based GNSS SDR Receiver Architecture Utilization. *Proc of International ELMAR 2013 Symposium*, 315-318. Zadar, Croatia.

[30] Filjar R., Huljenić D. (2012). The importance of mitigation of GNSS vulnerabilities and risks. *Coordinates*, 8(5), 14 – 16. Dostupno na: https://www.unoosa.org/documents/pdf/icg/ISWI/2017/Available_Info/Abstracts.pdf

[31] Filjar R., Gold H., Markežić I. (2011). GNSS – the risk of the underlying technology. *Proc of 5th GNSS Vulnerabilities and Solutions Conference* (on-line version hosted by RIN). Baška, Krk Island, Croatia.

[32] Filjar R., Ježić G., Matijašević M. (2008). Location-Based Services: A Road Towards Situation Awareness. Journal of Navigation, 61, 573-589. doi:10.1017/S0373463308004864

[33] Filjar R., Dešić S., Pokrajac D., Čubić I. (2005). Internet AIS. *Journal of Navigation*, 58, 197-206. doi:10.1017/S0373463305003255

[34] Gavranić V. (2019). Primjena Niellove funkcije u modelu troposferskog kašnjenja satelitskog signala za određivanje položaja (diplomski rad). Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Matematički odsjek. Zagreb, Hrvatska. Dostupno na: https://zir.nsk.hr/islandora/object/pmf%3A8375

[35] Gelo B. (2000). Opća i prometna meteorologija – II. dio. HNUS. Zagreb.

[36] Geospatial Web. (2018). GNSS frequency bands for constellations. Dostupno na: https://www.geospatialworld.net/blogs/gnss-frequency-bands-for-constellations

[37] GLONASS-IAC. (2020). GLONASS (Information Analytical Center - IAC). https://www.glonass-iac.ru/en/, pristup u trenutku pisanja: 25. siječnja 2020.

[38] Grabner M., Kvicera V. (2011). Atmospheric Refraction and Propagation in Lower Troposphere. In: Zhurbenko V. (ed). (2011). Electromagnetic Waves. InTechOpen. Rijeka. Dostupno na: https://www.intechopen.com/books/electromagnetic-waves/atmospheric-refraction-and-propagation-in-lower-troposphere

[39] (European GNSS Agency GSA) (GSA 2018). GNSS User Needs and Requirements Library (Agriculture, Aviation, Location-Based Services, Maritime and Inland Waterways, Rail, Road, Surveying, Time and Synchronisation). European GNSS Agency. Prag, Češka. Dostupno na: https://www.gsc-europa.eu/sites/default/files/sites/all/files/Report_on_User_Needs_and_Requirements_Maritime.pdf

[40] Gustafsson F. (2010). Statistical Signal Fusion. Studentlitteratur. Linkoepping University. Linkoepping, Sweden

[41] Hastie T., Tibshirani R. i Friedman J. (2009). The elements of Statistical Learning. Dana Mining, Inference and Prediction. Dostupno na: https://web.stanford.edu/~hastie/ElemStatLearn/

[42] Higham N. J. i suradnici. (2015). Princeton Companion to Applied Mathematics. Princeton University Press. Princeton, NJ.

[43] HM Government Office for Science (HMGOS). (2018). Satellite-derived Time and Position: A Study of Critical Dependencies. HM Government. London, UK. Dostupno na: https://www.nicofe.com/2018/01/30/satellite-derived-time-position-study-critical-dependencies/

[44] Hopfield H. S. (1971). Tropospheric Effect on Electromagnetically Measured Range: Prediction from Surface Weather Data. Radio Science, 6(3), 357-367. doi: 10.1029/RS006i003p00357

[45] Hoppe H. (2005). International Regulations for High-Speed Craft: An Overview. Proc of International Conference on Fast Sea Transportation FAST'2005, Sankt Peterburg, Rusija.

[46] Hyndman R i suradnici. (2020). forecast: Forecasting Functions for Time Series and Linear Models (R knjižnica). Dostupno na: https://cran.r-project.org/web/packages/forecast/index.html

[47] Introduction to Dynamic Positioning. (The International Marine Contractors Association – IMCA), (IMCA, 2006) London, UK. Dostupno na: http://marineengineering. co.za/lectures/technical-information/general-docs/dynamic-positioning.pdf

[48] Javna internetska arhiva dnevnih GNSS opažanja u obliku RINEX datoteka. NASA. (International GNSS Service – IGS), (IGS, 2020). Dostupno na: ftp://cddis.nasa.gov/gnss/data/daily/

[49] Kuhn M. (2019). The caret package. Dostupno na: https://topepo.github.io/caret/index.html

[50] Lopez M. (2018). Support to maritime and Inland Waterways Service providers for the Transmission of EGNOS Corrections via IALA Beacons and AIS/VDES Stations.

Dostupno na: https://www.transnav.eu/Article_Support_to_Maritime_and_Inland_L%C3%B3pez,49,873.html

[51] Loupe G. (2015). Understanding Random Forests: From Theory to Practice (doktorska disertacija). University of Liege. Liege, Francuska. Dostupno na: https://arxiv.org/abs/1407.7502

[52] Maindonald J., Brown W. J. (2010). Data Analysis and Graphics Using R: An Example-Based Approach (3rd ed). Cambridge University Press. Cambridge, UK.

[53] Manual of the ICAO Standard Atmosphere (extended to 80 kilometres) (3rd ed). (International Civil Aviation Organisation – ICAO), (ICAO, 1993). Montreal, Kanada

[54] Marini J. W. (1971). Closed form satellite tracking data corrections for an arbitrary tropospheric profile (NASA Technical Report). NASA Goddard Space Flight Center. Greenbelt, MD. Dostupno na: https://ntrs.nasa.gov/search.jsp?R=19710016213

[55] Martellucci A. (2012). Galileo Tropospheric Correction Model. Navipedia. ESA. Nordwijk, Nizozemska. Dostupno na: https://gssc.esa.int/navipedia/index.php/Galileo_Tropospheric_Correction_Model

[56] Markežić I., Filjar R., Juričić I. (2002). Time distribution of the GPS signal tropospheric delay during passage of the warm front. *Proc of the 2nd Congress Transport and Logistics*, 345-348. Portorož, Slovenija.

[57] Niell A. E. (2000). Improved atmospheric mapping functions for VLBI and GPS. Earth, Planets and Space, 52, 699-702. doi: 10.1186/BF03352267

[58] Niell A. E. (1996). Global mapping functions for the atmosphere delay at radio wavelengths. *J of Geoph Res*, 101(B2), 3227-3246. Dostupno na: file:///D:/Documents/Downloads/NMF_JGR.pdf

[59] Parkinson B. W., Spilker Jr. J. J. (1996). Global Positioning System: Theory and Applications (Vol. I.). AIAA, Washington, DC.

[60] Perfomance standards for multi-system shipborne radionavigation receivers, Resolution MSC.401(95); (Adopted on 8 June 2015), (International Maritime Organisation - IMO): Dostupno na: https://puc.overheid.nl/nsi/doc/PUC_243535_14/1/

[61] Recommended Practice. De Norske Veritas. Høvik, Norveška, (Dynamic positioning vessel – DNV), (DNV, 2015). design philosophy guidelines (DNVGL-RP-E306) – Dostupno na: http://rules.dnvgl.com/docs/pdf/dnvgl/RP/2015-07/DNVGL-RP-E306.pdf

[62] Report on maritime and inland waterways user needs and requirements - GSA 2019, (Europen GNSS Agency – GSA), (GNSS, 2018). Dostupno na: https://www.gsc-europa.eu/sites/default/files/sites/all/files/Report_on_User_Needs_and_Requirements_Maritime.pdf

[63] Revised maritime policy and requirements for a future global navigation satellite system (GNSS); Resolution A. 915(22) Adopted on 29 November 2001, (Agenda item 9), (International Maritime Organisation – IMO). Dostupno na: http://docs.yasinskiy.net/books/imo-a/A915(22).pdf

[64] RINEX Working Group and Radio Technical Commission for Maritime Services Special Committee 104 (RTCM-SC104), 2018, (Global Navigation Satellite System - GNSS), (GNSS Calendar, 2020). International GNSS Service (IGS), Dostupno na: http://www.gnsscalendar.com/

[65] RINEX Working Group and Radio Technical Commission for Maritime Services Special Committee 104 (RTCM-SC104),(2018), (International GNSS Service - IGS). Dostupno na: https://kb.igs.org/hc/en-us/articles/202044736-RINEX-Working-Group-Charter-and-Members

[66] RINEX Working Group and Radio Technical Commission for Maritime Services Special Committee 104 (RTCM-SC104). (2018). RINEX – The Receiver Independent Exchange Format, Version 3.04., (International GNSS Service - IGS). Dostupno na: http://acc.igs.org/misc/rinex304.pdf

[67] Rp5.ru. (2020). Internetska baza povijesti opažanja s meteoroloških stanica u svijetu. Raspisaniye Pogodi Ltd. St. Petersburg, Russia Dostupno na: https://rp5.ru

[68] Rumora I., Jukić O., Filić M., Filjar R. (2018). A study of GPS positioning error associated with tropospheric delay during Numa Mediterranean cyclone. *Int J for Transp and Traff Eng*, 8(3), 282-293. doi: 10.7708/ijtte.2018.8(3).03. Dostupno na: https://bit.ly/2umGAeD

[69] Rumora I., Sikirica N., Filjar R. (2018). An Experimental Identification of Multipath Effect in GPS Positioning Error. *TRANSNAV*, 12(1), 29-32. doi: 10.12716/1001.12.01.02. Dostupno na: https://www.transnav.eu/pdf/0783.pdf

[70] Saastamoinen J. (1972). Atmospheric Correction for the Troposphere and Stratosphere in Radio Ranging Satellites. In: Henriksen, S. W., Mancini, A., Chovitz, B. H. (1972). The Use of Artificial Satellites for Geodesy (Vol. 15). John Wiley & Sons. Hoboken, NJ. doi: 10.1029/GM015p0247

[71] Sadlier G. i suradnici. (2017). The economic impact on the UK of a disruption to GNSS. London Economics. London, UK. Dostupno na: https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/619544/17.3254_Economic_impact_to_UK_of_a_disruption_to_GNSS_-_Full_Report.pdf

[72] Sanz Subirana J. i suradnici. (2013). GNSS Data Processing – Vol. I: Fundamentals and Algorithms. European Space Agency (ESA). Nordwijk, The Netherlands. Dostupno na: https://gssc.esa.int/navipedia/GNSS_Book/ESA_GNSS-Book_TM-23_Vol_I.pdf

[73] Schueler T. (2001). On Ground-Based GPS Tropospheric Delay Estimation (PhD thesis). Universitaet der Bundeswehr Muenchen. Neubiberg, Germany. Dostupno na: https://d-nb.info/963624393/34

[74] Sikirica N., Malić E., Rumora I., Filjar R. (2017). Exploitation of Google GNSS measurement API for risk assessment of GNSS applications. *Proc of 25th Telecommunications Forum (TELFOR) 2017*, 293-296. Belgrade, Serbia. doi: 10.1109/TELFOR.2017.8249343

[75] Simović A. I. (1970). Meteorologija: udžbenik za pomorske škole i priručnik za pomorce. Školska knjiga. Zagreb.

[76] Smart A. (2013). The Value of Augmented GNSS in Australia. Acil Allen Consulting. Melbourne, VIC. Dostupno na: http://www.ignss.org/LinkClick.aspx?fileticket=dKQ6MsXGBAw%3D&tabid=56

[77] Standard atmosphere (ISO2533:1975). Geneva, Švicarska, (International Organisation for Standardisation – ISO), (ISO, 2007). Dostupno uz naplatu na: https://www.iso.org/standard/7472.html

[78] Soubielle J., Fijalkow I., Duvaut P., and Bibaut A. (2002). GPS Positioning in a Multipath Environment, dostupno na: https://ieeexplore.ieee.org/abstract/document/972490

[79] Specht M. (2018). Method of evaluating the positioning system capability for complying with the minimum accuracy requirements for the International Hydrographic Organization orders. Dostupno na: https://europepmc.org/article/PMC/6767266

[80] Strang G., Borre K. (1997). Linear Algebra, Geodesy, and GPS. Wellesley-Cambridge Press. Wellesley, MA.

[81] Stull R. (2015). Practical Meteorology: An Algebra-based Survey of Atmospheric Science. University of British Columbia. Vancouver, BC. Dostupno na: https://www.eoas.ubc.ca/books/Practical_Meteorology/prmet/PracticalMet_WholeBook-v1_00b.pdf

[82] Teunissen P. J. G., Montenbruck O. (eds). (2017). Springer Handbook of Global Navigation Satellite Systems. Springer International Publishing AG. Cham, Switzerland.

[83] Thomas M. i suradnici. (2011). Global Navigation Space Systems: reliance and vulnerabilities. The Royal Academy of Engineering. London, UK. Dostupno na: https://www.raeng.org.uk/publications/reports/global-navigation-space-systems

[84] Volpe. (2001). Vulnerability Assessment of the Transportation Infrastructure Relying on the Global Positioning System. John A. Volpe National Transportation Systems Center. Cambridge, MA. Dostupno na: https://www.navcen.uscg.gov/pdf/ vulnerability_assess_2001.pdf

[85] Worldwide radionavigation system; Resolution A. 1046(27); Adopted on 30 November 2011 (Agenda item 9), (International Maritime Organization – IMO). Dostupno na: https://wwwcdn.imo.org/localresources/en/KnowledgeCentre/IndexofIMOResolutions/AssemblyDocuments/A.1046(27).pdf

[86] Wu X., Wang X., Lu D. R. (2014). Retrieval of vertical distribution of tropospheric refractivity through ground based GPS observation. Adv. Atmos. Sci., 31(1), 37–47, doi: 10.1007/s00376-013-2215-z.

[87] Young B. L. (2017). Predicting vessel trajectories from AIS data using R (thesis). Naval Postgraduate School. Monterey, CA. Dostupno na: https://apps.dtic.mil/dtic/tr/fulltext/u2/1046595.pdf

[88] Zhang J. H. (1999). Investigations into the Estimation of Residual Tropospheric Delays in a GPS Network. University of Calgary. Calgary, AL. Dostupno na: https://www.ucalgary.ca/engo_webdocs/GL/99.20132.JZhang.pdf

10. POPIS KRATICA

IMO – International Maritime Organization

GNSS – Global Navigation Satellite System

GSA – European GNSS Agency

UERE - User Equivalent Range Error

GDOP - Geometric Dilution of Precision

PPP - Precise Point Positioning

RTK - Real-Time Kinematics

DGPS - Differential Global Positioning System

GPS - Global Positioning System

SBAS - Satellite-Based Augmentation System

EGNOS - European Geostationary Navigation Overlay Service

INS - Inertial Navigation System

AIS - Automatic Identification System

ADS-B - Automatic Dependent Surveillance–Broadcast

GIS - Geospatial Information Systems

WGS84 - World Geodetic System 84

ECEF - Earth-Centred, Earth-Fixed

UTC - Universal Time Co-ordinated

P - Precise

C/A - Coarse Acquisition

PRN - Pseudo-Random Number

RINEX - Receiver Independent Exchange format

SDR - Software-Defined Radio

ISA - International Standard Atmosphere

ICAO - International Civil Aviation Organisation

IALA - International Association of Marine Aids to Navigation and Lighthouse Authorities,

NATO STANAG - NATO Standard Agreement

DRMS – Distance Root Mean Square error

IHO – International Hydrographic Organization

FDMA - Frequency Division Multiple Access

CDMA - Code Division Multiple Access

RSE - Residual Standard Error

RMSE - Root Mean Square Error

HMGOS – HM Government Office for Science

SSE - Sum of Square Error

MARUSE – Maritime User Segment

11. POPIS SLIKA

Slika 1. Arhitektura satelitskog navigacijskog sustava (izvor: Parkinson, Spilker, Jr, 1996) 8
Slika 2. Broj vidljivih satelita gledano s položaja korisnika tijekom jednog dana (dobiveno analizom eksperimentalnih opažanja vlastitom programskom podrškom) razvijenom u okruženju za statističko računarstvo R 9
Slika 3. Kontrolna komponenta sustava GPS (izvor: Sanz Subirana i suradnici, 2013) 10
Slika 4. WGS84 koordinatni sustav je sustav s ishodištem u težištu Zemlje i s kutnom brzinom identičnom kutnoj brzini Zemlje (engl. Earth-Centred-Earth-Fixed – ECEF system) (izvor: Sanz Subirana i suradnici, 2013) 13
Slika 5. Komponente kompozitnog satelitskog signala na primjeru sustava GPS (izvor: Sanz Subirana i sur., 2013) 15
Slika 6. Spektralna slika signala za satelitsko određivanje položaja različitih satelitskih navigacijskih sustava (kineski sustav Beidou prikazan je ovdje kao Compass) (izvor: Geospatial Web, 2018) 16
Slika 7. Struktura navigacijske poruke sustava GPS (izvor: Sanz Subirana i suradnici, 2013) 17
Slika 8. Refrakcija radiovala 20
Slika 9. Područje neodređenosti procijenjenog položaja satelitskim sustavom 22
Slika 10. Tri osnovne radne domene satelitskog navigacijskog prijamnika 23
Slika 11. Model popravka izvornih (nepopravljenih) izmjerenih GNSS pseudoudaljenosti u navigacijskoj domeni GNSS prijamnika za satelitsku navigaciju 24
Slika 12. Mjerenje GNSS pseudoudaljenosti postupkom unakrsne korelacije (izvor: Sanz Subirana i suradnici, 2013) 26
Slika 13. Linearizacija nelinearne funkcije u okolišu točke (x_0, $f(x_0)$) primjenom Taylorovog reda (prema: Higham, N. J. i suradnici, 2015) 30
Slika 14. Izloženost satelitskog navigacijskog prijamnika raznim utjecajima okoline 33
Slika 15. Vertikalni profil atmosfere (prema: Gelo, 2000) 37
Slika 16. Vertikalni profil temperature u troposferi Zemlje (prema: Stull, 2015) 39
Slika 17. Standardna atmosfera (ISA), (prema: Hrvatska enciklopedija, Leksikografski zavod Miroslav Krleža, 2018.) 41

Slika 18. Razvoj turbulencija po vertikalnom profilu troposfere povezivanjem laminarnih slojeva stabilne troposfere (prema: Stull, 2015, Simović, 1970) 42
Slika 19. Frontalna kretanja zračnih masa različitih temperatura i gustoća, kao uzrok razvoja vremenske situacije (prema: Stull, 2015, Simović, 1970) 42
Slika 20. Poslovno (razvojno) okruženje za razvoj usluga zasnovanih na GNSS PNT uslugama satelitske navigacije, (prema: Filjar, Luttenberger, Kos, 2012) 47
Slika 21. Klobucharov model dnevnog hoda ionosferskog kašnjenja satelitskog signala za određivanje položaja 56
Slika 22. Definicija Niellove funkcije preslikavanja 62
Slika 23. Model povezivanja troposferskog kašnjenja signala za satelitsko određivanje položaja s pogreškom satelitskog određivanja položaja i zahtjevima za točnost određivanja položaja pojedinih klasa navigacijskih zadataka 81
Slika 24. Struktura modela stabla odlučivanja 88
Slika 25. Model neurona 90
Slika 26. Sigmoidna funkcija 90
Slika 27. Struktura umjetne neuronske mreže 91
Slika 28. Primjer P-O dijagrama 93
Slika 29. Histogrami relativne vlažnosti zraka, tlaka zraka, temperature zraka i doprinosa troposferskih učinaka ukupnoj pogreški satelitskog određivanja položaja opaženih na referentnoj stanici Matera, Italija u razdoblju 1. siječnja 2019. – 30. travnja 2019. 100
Slika 30. Q-Q dijagram doprinosa ukupnoj horizontalnoj pogreški određivanja položaja uslijed troposferskih učinaka ne slijedi normalnu razdiobu na repovima razdiobe 102
Slika 31. Korelacijski dijagram ciljane varijable i prediktora, izvedeno vlastitom programskom podrškom u okruženju za statističko računarstvo R i uz korištenje R knjižnice DataExplorer 103
Slika 32. Funkcija gustoće statističke razdiobe (lijevo) te kumulativne funkcije statističke razdiobe (desno), izvedena u programskom okruženju za statističko računarstvo R vlastitom programskom podrškom 104
Slika 33. P-O dijagram jednostavnog modela linearne regresije s dva prediktora i bez slobodnog člana 110

Slika 34. Procjena funkcije gustoće vjerojatnosti eksperimentalne statističke razdiobe reziduala jednostavnog modela linearne regresije s dva prediktora i bez slobodnog člana 110
Slika 35. P-O dijagram mješovitog modela linearne regresije s tri prediktora i bez slobodnog člana 112
Slika 36. Procjena funkcije gustoće vjerojatnosti eksperimentalne statističke razdiobe reziduala mješovitog modela linearne regresije s tri prediktora i bez slobodnog člana 113
Slika 37. Usporedba računalne učinkovitosti razvoja modela slučajne šume 115
Slika 38. P-O dijagram najboljeg modela udjela troposferskih učinaka na ukupnu horizontalnu točnost određivanja položaja zasnovan na slučajnoj šumi, od 300 stabala odlučivanja 115
Slika 39. P-O dijagram modela udjela troposferskih učinaka na ukupnu horizontalnu točnost određivanja položaja zasnovan na umjetnoj neuronskoj mreži, s jednim skrivenim slojem 119
Slika 40. Preslikavanje graničnih vrijednosti ukupne pogreške satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, procijenjene pomoću stvarnog doprinosa uslijed troposferskih učinaka i uobičajenih vrijednosti ostalih doprinosa, na zahtjeve za točnost određivanja položaja klasa primjena u pomorskoj površinskoj navigaciji..... 121
Slika 41. Preslikavanje graničnih vrijednosti ukupne pogreške satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, u scenariju jedinog doprinosa uslijed troposferskih učinaka i bez ostalih doprinosa, na zahtjeve za točnost određivanja položaja klasa primjena u pomorskoj površinskoj navigaciji..... 122
Slika 42. Preslikavanje vrijednosti ukupne pogreške satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, u scenariju popravljenog doprinosa uslijed troposferskih učinaka i uobičajenih doprinosa uslijed učinaka ostalih utjecajnih veličina, na zahtjeve za točnost određivanja položaja klasa primjena u pomorskoj površinskoj navigaciji..... 123
Slika 43. Preslikavanje graničnih vrijednosti raspona ukupne pogreške satelitskog određivanja položaja u pomorskoj površinskoj navigaciji, u scenariju popravljenog doprinosa uslijed troposferskih učinaka ali bez drugih doprinosa kao i troposferskog udjela, na zahtjeve za točnost određivanja položaja klasa primjena u pomorskoj površinskoj navigaciji 124

12. POPIS TABLICA

Tablica 1. Obilježja prostornih segmenata globalnih navigacijskih satelitskih sustava (izvor: GLONASS-IAC, 2020.). 9
Tablica 2. Parametri Zemlje kao elipsoida u sustavu WGS84 (izvor: Sanz Subirana i suradnici, 2013) 13
Tablica 3. Usporedba obilježja PRN kodnih sekvenca 18
Tablica 4. Proračun pogrešaka satelitskog određivanja položaja (Parkinson, Spilker, Jr, 1996) 35
Tablica 5. Ovisnost temperature zraka o nadmorskoj visini 39
Tablica 6. Obilježja stabilne Zemljine atmosfere (prema: ICAO, 1993 i Schueler, 2001) 40
Tablica 7. Obilježja vodene pare u Zemljinoj atmosferi 44
Tablica 8. Usporedna analiza zahtjeva za kvalitetom određivanja položaja satelitskim sustavima različitih izvora, kao rezultat studije (izvor: GSA, 2018) 52
Tablica 9. Parametri modela reduciranog indeksa loma u troposferi, prema različitim autorima (preuzeto iz Martellucci, 2012). 60
Tablica 10. Koeficijenti funkcije preslikavanja za mokri zrak, (prema Sanz Subirana i suradnici, 2013)..... 64
Tablica 11. Koeficijenti funkcije preslikavanja za suhi zrak, (prema: Sanz Subirana i suradnici, 2013)..... 65
Tablica 12. Meteorološki parametri modela za eksperimentalno određivanje troposferskog kašnjenja 67
Tablica 13. Vrijednosti parametara za suhi zrak za pojedinačne vrijednosti zenitnog kuta (izvor: Sanz Subirana i suradnici, 2013, Schueller, 2001)..... 71
Tablica 14. Vrijednost parametara za mokri zrak za pojedinačne vrijednosti zenitnog kuta (izvor: Sanz Subirana i suradnici, 2013; Schueller, 2001) 72
Tablica 15. Koeficijenti visine 72
Tablica 16. Prediktori troposferskog kašnjenja GNSS signala 72
Tablica 17. Klasifikacija navigacijskih zadataka u pomorskoj površinskoj navigaciji prema odgovarajućim zahtjevima za točnost satelitskog određivanja položaja..... .76

Tablica 18. Prijedlog klasifikacije pojedinih navigacijskih zadataka u pomorskoj površinskoj navigaciji prema zahtjevima za točnost određivanja položaja satelitskim sustavom (tablica 17) ..... ….77
Tablica 19. Statistička obilježja troposferskog doprinosa horizontalnoj pogreški određivanja položaja satelitskim sustavom 99
Tablica 20. Granične vrijednosti doprinosa troposferskih učinaka ukupnoj pogreški i odgovarajuća ukupna pogreška satelitskog određivanja položaja, za razmatrani eksperimentalni skup opažanja 101
Tablica 21. Granični zbirni izvještaj razvoja i vrednovanja jednostavnog model linearne regresije s dva prediktora (temperatura zraka, t (°C) i relativna vlažnost zraka (%)), bez slobodnog člana 109
Tablica 22. Zbirni izvještaj razvoja i vrednovanja mješovitog modela linearne regresije s tri prediktora (temperatura zraka, t (°C), tlaka zraka, p (hPa) i relativna vlažnost zraka h (%), bez slobodnog člana 111
Tablica 23. Uspješnost modela slučajne šume 114
Tablica 24. Obilježja neuronske mreže s jednim skrivenim slojem 116
Tablica 25. Obilježja neuronske mreže s dva skrivena sloja 117
Tablica 26. Obilježja neuronske mreže s tri skrivena sloja 118
Tablica 27. Obilježja uspješnosti modela zasnovanih na metodi umjetne neuronske mreže 119

13. ŽIVOTOPIS

Pristupnik Ivan Rumora rođen je 1982. godine u Zagrebu, RH. Diplomirao je godine 2006. na Pomorskom fakultetu u Rijeci, stekavši naslov diplomirani inženjer pomorskog prometa, smjer: nautika. Nakon diplome zapošljava se u Hrvatskoj ratnoj mornarici (HRM) gdje obnaša dužnosti pomorskog časnika, oružnog časnika, zamjenika zapovjednika broda i zapovjednika broda (sve dužnosti obnašane su na brodovima Obalne straže RH). Godine 2009. završio je temeljnu časničku izobrazbu časnika HRM na Hrvatskom vojnom učilištu u Zagrebu, RH. Godine 2011. proveo je nepunih 8 mjeseci na časničkoj izobrazbi na Britannia Royal Naval College u Dartmouthu, UK. Godine 2013. završio je International Navigating Officer's Course u HMS Collingwood, Portsmouth, UK. Godine 2015. završava naprednu časničku izobrazbu na US Coast Guard Training Center, Yorktown, VA, te nastavlja raditi u Obalnoj straži Republike Hrvatske na dužnosti zapovjednika broda.

Znanstveno-istraživačke aktivnosti izvodio je sudjelovanjem u znanstveno-istraživačkom projektu „Istraživanje korelacije maritimno-transportnih elemenata u pomorskom prometu“ pod vodstvom prof. dr. sc. Serđa Kosa, FRIN od 2015. godine. U područje znanstvenih interesa pristupnika Ivana Rumora spadaju: satelitska navigacija, identifikacija uzroka, modeliranje i korekcije pogrešaka satelitskih navigacijskih sustava, analiza rizika korištenja satelitske navigacije za potrebe pomorske površinske navigacije, posebno u ratnoj mornarici.

Ivan Rumora je izvanredni član Kraljevskog instituta za navigaciju (The Royal Institute of Navigation) iz Londona, UK. Pozvani je suradnik Radne skupine za spektar i signale satelitskih navigacijskih sustava Međunarodnog odbora za satelitsku navigaciju (ICG) organizacije Ujedinjenih naroda (Beč, Austrija) te je bio član Međunarodnog programskog i organizacijskog odbora tradicionalne godišnje konferencije Baška GNSS Conference, koja se u organizaciji Kraljevskog instituta za navigaciju iz Londona, UK održava u Baški, na otoku Krku, RH. Objavio je 2 znanstvena članka u znanstvenim časopisima indeksiranim u vodećim svjetskim bazama i 5 radova na međunarodnim konferencijama s međunarodnom recenzijom. Trenutno završava doktorski studij i nastavlja se i dalje razvijati u struci.

14. BIOGRAPHY

Candidate Ivan Rumora was born in 1982 in Zagreb, Croatia. He graduated in 2006 from the Faculty of Maritime Studies in Rijeka and obtained the title of maritime transport engineer, course of study: nautical studies. After graduation, he started working in the Croatian Navy (HRM), where he served as a naval officer, an armed officer, a deputy commander (XO-executive officer) and a ship commander (CO-commanding officer). In 2009, he completed his basic officer training as an HRM officer at the Croatian Military College in Zagreb, Croatia. In 2011, he attended for almost 8 months the Officer Training at Britannia Royal Naval College in Dartmouth, UK. In 2013, he completed the International Navigating Officer's Course at HMS Collingwood, Portsmouth, UK. In 2015, he completed advanced officer training at the US Coast Guard Training Centre, Yorktown, VA, and continued working in the Coast Guard in the Republic of Croatia as a ship's captain.

Since 2015 he has been performing his scientific research activities by participating in a scientific-research project "Investigation of the correlation of maritime transport elements in maritime transport" under the guidance of Full Professor Serđo Kos, Ph. D., FRIN. The scientific interests of candidate Ivan Rumora include: satellite navigation, cause identification, modelling and error correction of satellite navigation systems, risk analysis of the use of satellite navigation for naval surface navigation, especially in the Navy.

Ivan Rumora is an Associate Fellow of The Royal Institute of Navigation in London, UK. He is an invited contributor to the Working Party on Spectrum and Signal Satellite Navigation Systems of the International Committee on Satellite Navigation (ICG) of the United Nations (Vienna, Austria) and he was a member of the International Programming and Organizing Committee of the traditional annual Baška GNSS Conference, organized by the Royal Institute of Navigation in London, UK, in Baška, Krk Island, Croatia. He has published 2 scientific articles in scientific journals indexed in leading world databases and 5 papers at international conferences with international peer review. He is currently completing his doctoral studies and continues to further develop in the maritime profession.