Analiza zapisa propusnosti 3G i 4G mreža za uslugu videostrujanja

Ivanić, Marija

Undergraduate thesis / Završni rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:961589

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2025-03-23**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Sveučilišni prijediplomski studij

ANALIZA ZAPISA PROPUSNOSTI 3G I 4G MREŽA ZA USLUGU VIDEOSTRUJANJA

Završni rad

Marija Ivanić

Osijek, 2024.

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac Z1P: Obrazac za ocjenu završnog rada na sveučilišnom prijediplomskom studiju

Ocjena završnog rada na sveučilišnom prijediplomskom studiju

Ime i prezime pristupnika:	Marija Ivanić
Studij, smjer:	Sveučilišni prijediplomski studij Elektrotehnika i informacijska tehnologija
Mat. br. pristupnika, god.	4962, 27.07.2021.
JMBAG:	0165089457
Mentor:	prof. dr. sc. Snježana Rimac-Drlje
Sumentor:	
Sumentor iz tvrtke:	
Naslov završnog rada:	Analiza zapisa propusnosti 3G i 4G mreža za uslugu videostrujanja
Znanstvena grana završnog rada:	**Telekomunikacije i informatika (zn. polje elektrotehnika)**
Zadatak završnog rada:	Prijenos videa zauzima više od 70% ukupnog internet prometa, pri čemu se veliki dio odnosi na promet preko mobilnih mreža. U radu je potrebno opisati sustav videostrujanja prema MPEG DASH normi te karakteristike videostrujanja preko mobilnih mreža. U praktičnom dijelu rada potrebno je napraviti statističku analiza baza 3G i 4G mrežnih ispitnih zapisa te usporediti dobivene raspodjele izmjerenih propusnosti s teorijskim Nakagami, Weibull, Rician, Gamma i Gauss raspodjelama. Nadalje, potrebno je odrediti raspodjelu koja najbolje opisuje realne podatke te odrediti parametre za umjetno generiranje 3G i 4G mrežnih

Datum prijedloga ocjene završnog rada od strane mentora:	19.09.2024.
Prijedlog ocjene završnog rada od strane mentora:	Izvrstan (5)
Datum potvrde ocjene završnog rada od strane Odbora:	25.09.2024.
Ocjena završnog rada nakon obrane:	Izvrstan (5)
Datum potvrde mentora o predaji konačne verzije završnog rada čime je pristupnik završio sveučilišni prijediplomski studij:	29.09.2024.

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

IZJAVA O IZVORNOSTI RADA

Osijek, 29.09.2024.

Ime i prezime Pristupnika:	Marija Ivanić
Studij:	Sveučilišni prijediplomski studij Elektrotehnika i informacijska tehnologija
Mat. br. Pristupnika, godina upisa:	4962, 27.07.2021.
Turnitin podudaranje [%]:	11

Ovom izjavom izjavljujem da je rad pod nazivom**: Analiza zapisa propusnosti 3G i 4G mreža za uslugu videostrujanja**

izrađen pod vodstvom mentora prof. dr. sc. Snježana Rimac-Drlje

i sumentora

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.
Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis pristupnika:

SADRŽAJ

1. UVOD 1
1.1. Zadatak završnog rada 3
2. PREGLED RELEVANTNIH ISTRAŽIVANJA 4
3. PRILAGODLJIVO VIDEOSTRUJANJE 6
3.1. MPEG DASH norma 9
3.2. Parametri kvalitete korisničkog iskustva u prilagodljivom videostrujanju 11
4. TEORIJSKI PREGLED STATISTIČKIH RASPODJELA 14
4.1. Gaussova raspodjela 14
4.2. Nakagami raspodjela 16
4.3. Gamma raspodjela 18
4.4. Weibull raspodjela 20
4.5. Rician raspodjela 22
5. STATISTIČKA ANALIZA PROPUSNOSTI 3G I 4G MREŽA 25
5.1. 3G skup podataka 25
5.2. 4G skup podataka 38
5.3. Analiza Weibull raspodjele za 3G i 4G skupove podataka 51
6. ZAKLJUČAK 54
LITERATURA 55
SAŽETAK 57
ŽIVOTOPIS 59
PRILOZI 60

1. UVOD

U svijetu komunikacija koji se neprestano razvija, prilagodljivo videostrujanje (engl. *Adaptive Bitrate Streaming* – ABR) predstavlja ključnu tehnologiju za prijenos video sadržaja. S obzirom na to da videostrujanje čini više od 70% ukupnog internetskog prometa, nužno je osigurati visokokvalitetno i besprijekorno iskustvo za korisnike bez obzira na vrstu uređaja, programsku podršku ili povezanost. Tehnologije temeljene na HTTP protokolu, poput MPEG DASH (engl. *Moving Picture Experts Group Dynamic Adaptive Streaming over HTTP Dynamic Adaptive Streaming*), omogućuju glatko videostrujanje prilagođavajući kvalitetu videozapisa u realnom vremenu prema promjenjivim mrežnim uvjetima.

Ovaj rad daje pregled MPEG DASH norme, njezina razvoja te načina na koji doprinosi poboljšanju kvalitete korisničkog iskustva (engl. *Quality of Experience* – QoE). Analiziraju se i faktori koji utječu na korisničko iskustvo te kako različiti algoritmi za prilagodbu prijenosne brzine mogu optimizirati performanse videostrujanja u različitim mrežnim okruženjima. Pri tome je od posebne važnosti poznavanje karakteristika mreže, među kojima su od posebne važnosti statistička svojstva propusnosti.

Analiza statističkih svojstava propusnosti 3G i 4G mreže kod videostrujanja, što je fokus ovog rada, provedena je korištenjem različitih statističkih raspodjela uključujući Gaussovu, Nakagami, Gamma, Weibull i Rician raspodjelu. Svaka od ovih raspodjela ima specifične parametre i karakteristike koje omogućuju modeliranje propusnosti u različitim okruženjima.

U drugom poglavlju dan je pregled novijih istraživanja koja se bave analizom i optimizacijom propusnosti u različitim mrežnim okruženjima. Ovo poglavlje pruža pregled ključnih radova koji se bave empirijskim i teorijskim aspektima HTTP prilagodljivog videostrujanja s posebnim naglaskom na evaluaciju performansi, kvalitetu korisničkog iskustva te metode za odabir optimalnih razina kvalitete tijekom kodiranja i segmentacije videosignala.

U trećem poglavlju detaljno će se razmotriti prilagodljivo videostrujanje, ključna tehnologija za optimizaciju kvalitete videa na temelju mrežnih uvjeta i uređaja. Fokus je na MPEG DASH normi, koja omogućuje glatko videostrujanje putem HTTP-a prilagođavanjem kvalitete videozapisa u stvarnom vremenu. Opisat će se osnovni parametri koji utječu na kvalitetu videozapisa i korisničko iskustvo te različiti algoritmi za prilagodljivo videostrujanje.

U četvrtom poglavlju opisat će se Gaussova, Nakagami, Gamma, Weibull i Rician raspodjela te njihove karakteristike koje omogućuju precizno modeliranje i analizu podataka o propusnosti mreže u različitim uvjetima, što je ključno za optimizaciju ABR algoritama i poboljšanje korisničkog iskustva u videostrujanju.

Peto poglavlje fokusirat će se na procjenu i usporedbu performansi 3G i 4G mreža te uključuje procjenu parametara teorijskih statističkih raspodjela opisanih u četvrtom poglavlju ovog rada. Za procjenu usklađenosti između izmjerenih podataka i teorijskih raspodjela koristit će se Kolmogorov-Smirnov test, koji omogućuje usporedbu uzorka s referentnom raspodjelom. Analiza će pružiti uvid u varijabilnost i stabilnost mrežnih performansi omogućavajući bolje razumijevanje učinkovitosti 3G i 4G mreža u različitim uvjetima.

1.1. Zadatak završnog rada

Prijenos videa zauzima više od 70% ukupnog internet prometa, pri čemu se veliki dio odnosi na promet preko mobilnih mreža. U radu je potrebno opisati sustav videostrujanja prema MPEG DASH normi te karakteristike videostrujanja preko mobilnih mreža. U praktičnom dijelu rada potrebno je napraviti statističku analizu baza 3G i 4G mrežnih ispitnih zapisa te usporediti dobivene raspodjele izmjerenih propusnosti s teorijskim Nakagami, Weibull, Rician, Gamma i Gauss raspodjelama. Nadalje, potrebno je odrediti raspodjelu koja najbolje opisuje realne podatke te odrediti parametre za umjetno generiranje 3G i 4G mrežnih ispitnih zapisa.

2. PREGLED RELEVANTNIH ISTRAŽIVANJA

Propusnost u mreži jedan je od ključnih parametara koji utječe na iskustvenu kvalitetu kod videostrujanja, a dobra predikcija propusnosti omogućava algoritmima za prilagodljivo videostrujanje osiguranje maksimalne kvalitete videa u danim uvjetima. Stoga je poznavanje statističkih karakteristika propusnosti izuzetno važno za razvoj ovih algoritama i njihov ispravan rad, posebno u mobilnim mrežama gdje su fluktuacije propusnosti velike. S razvojem mobilnih mreža i sve većom upotrebom aplikacija koje koriste tehnike videostrujanja, intenzivirana su istraživanja različitih aspekata videostrujanja, uključujući i istraživanja propusnosti, u 3G, 4G i 5G mrežama u različitim okruženjima.

U [1], autori predstavljaju empirijsku evaluaciju HTTP prilagodljivog strujanja u uvjetima mobilnosti vozila, što je čest slučaj kada se koriste 3G i 4G mreže. Analizirane su performanse prilagodljivog videostrujanja dok se korisnici kreću u vozilima, što uključuje promjene mrežnih uvjeta kao što su varijacije propusnosti, latencija i gubitak paketa. Rad pokazuje kako mobilnost utječe na kvalitetu videa i nudi rješenja za poboljšanje prilagodljivog videostrujanja u dinamičkim mrežnim uvjetima.

U [2] analizirani su različiti aspekti kvalitete iskustva korisnika prilikom upotrebe HTTP prilagodljivog strujanja. Autori istražuju faktore koji utječu na kvalitete iskustva kao što su rezolucija videa, kašnjenje i gubitak paketa, što je ključno za analizu propusnosti mreža jer se same performanse videostrujanja direktno odnose na zadovoljstvo korisnika. Rad pregledava različite metodologije za mjerenje kvalitete iskustva i predlaže određene mjere koje najbolje reflektiraju korisničko iskustvo.

J. Vlaović [3] istražuje metode za odabir optimalnih razina kvalitete tijekom kodiranja i segmentacije videosignala za prilagodljivo videostrujanje. Rad se fokusira na algoritme koji određuju kako izabrati kodne brzine i prostorne rezolucije u ovisnosti o kompleksnosti video sadržaja. Također, predlaže simulacijski okvir koji omogućava testiranje različitih metoda segmentacije i adaptacijskih algoritama na izmjerenim mrežnim zapisima, ali zapisima sintetiziranim uz primjenu Nakagami raspodjele.

Rad L. F. Huanga [4] istražuje Nakagami raspodjelu i njene srodne raspodjele, koje se koriste u modeliranju karakteristika bežičnih kanala. Nakagami raspodjela često se koristi za modeliranje varijacija signala u bežičnim komunikacijama, posebno u slučajevima gdje postoji višestazno rasprostiranje signala.

U [5], autori ispituju performanse adaptivnog videostrujanja u mobilnim mrežama kroz upotrebu prediktivnih algoritama. Rad se fokusira na predikciju mrežne propusnosti koristeći povijesne podatke o protoku i dinamički odabir kvalitete videa kako bi se poboljšala kvaliteta korisničkog iskustva. Implementirajući NEIVA tehniku, koja je temeljena na identifikaciji okruženja za adaptivno predviđanje budućeg protoka, postižu 20 do 25 % poboljšanja u točnosti predviđanja propusnosti te 11 do 20 % poboljšanja kvalitete korisničkog iskustva.

U [6], autori istražuju problem točnog predviđanja propusnosti za prilagodljivo videostrujanje u mobilnim mrežama. Fokusiraju se na izradu prediktivnog modela koji uzima u obzir sve ključne komponente, uključujući ulazne značajke, ciljne varijable i funkcije mapiranja. Kroz teorijski okvir identificiraju faktore koji utječu na propusnost i vrijeme isporuke. Autori predlažu Lumos, prediktor propusnosti temeljen na stablu odlučivanja koji može biti integriran u postojeće algoritme. Lumos značajno poboljšava točnost predviđanja te unapređuje kvalitetu korisničkog iskustva za 6,3 %.

U [7], autori istražuju primjenu metoda analize podataka vođene umjetnom inteligencijom za predviđanje propusnosti silazne veze u mobilnim mrežama. Rad se bavi izazovima predviđanja propusnosti u dinamičnim uvjetima mobilnih mreža, gdje varijabilnost stanične povezanosti, mobilnost uređaja i promjenjivi zahtjevi prometa otežavaju precizna predviđanja. Rad također obrađuje izazove prilikom primjene predviđanja u stvarnim uvjetima, poput uzorkovanja podataka, promjene raspodjele i označavanja podataka te nudi praktična rješenja za te probleme.

U [8], autori proučavaju utjecaj predviđanja propusnosti na dinamiku adaptivnog videostrujanja u DASH-u. Njihovo istraživanje pokazuje kako točno predviđanje propusnosti može poboljšati odabir brzine prijenosa videozapisa, s ciljem maksimiziranja kvalitete videostrujanja. Predlažu metodu mapiranja odluka, koja u obzir uzima zauzetost međuspremnika pri odabiru kodne brzine te je kvaliteta korisničkog iskustva poboljšana za 32,1 %.

U [9], autori istražuju kako računalno generirani tragovi propusnosti mogu poslužiti kao prikladan alat za sustavnu analizu algoritama za videostrujanje. U radu je korištena Nakagami raspodjela za statističko modeliranje izmjerenih tragova propusnosti 3G i 4G mreža te na temelju parametara raspodjele generirani su sintetički tragovi. Rezultati pokazuju da Nakagami raspodjela pruža dobar model za generiranje sintetičkih tragova omogućujući stvaranje širokog raspona realističnih tragova promjenom parametara oblika i širenja raspodjele.

3. PRILAGODLJIVO VIDEOSTRUJANJE

Prilagodljivo videostrujanje najčešće je korišteni način prijenosa video sadržaja. Rezultira najboljom mogućom kvalitetom videa, a ujedno i najbolje iskustvo za korisnika, bez obzira na povezanost, programsku podršku ili uređaj. Većina prijenosa vrši se putem tehnologija zasnovanih na HTTP-u (engl. *HyperText Transfer Protocol*), a jedna od njih je *Moving Picture Experts Group Dynamic Adaptive Streaming over HTTP Dynamic Adaptive Streaming* - MPEG DASH. Osigurava glatko videostrujanje s najvećom mogućom kvalitetom iskustva – QoE (engl. *Quality of Experiance*) kod promjenjivih uvjeta u mreži, [3] [10].

Kodna brzina (engl. *bitrate*) videozapisa je prosječni broj bitova za jednu sekundu prikaza videosekvence dobiven kodiranjem. Obično se kreće od nekoliko stotina kilobita u sekundi (kb/s) do nekoliko megabita po sekundi (Mb/s), ali može doseći i više desetaka megabita u sekundi ako se radi o videosekvenci visoke rezolucije i kvalitete. Na kodnu brzinu utječe nekoliko faktora, [10]:

- Video rezolucija – broj elemenata slike; većina videozapisa ima rezoluciju 1280×720, 1920×1080 (engl. *FullHD*) ili 2560×1440 (4K) elemenata slike.
- Broj izmjena slika u sekundi (engl. *frame rate*) – većinom se koristi 25 ili 30 izmjena slika u sekundi (fps) (engl. *Frames per second*), ali sve više sustava koristi 50 i 60 fps - veći broj slika u sekundi bolje prikazuje pokret, no sadrži više podataka, a time i zahtjeva veću kodnu brzinu za traženu kvalitetu.
- Vrsta i parametri kodera (engl. *encoder*) – koderi se koriste za sažimanje (kompresiju) videozapisa pri čemu su određene vrste kodera efikasnije od drugih; noviji kodeci kao što su H.264 i H.265 povećali su kvalitetu videa i smanjili kodnu brzinu u odnosu na starije kodeke.

Video s većom kvalitetom, rezolucijom i većim brojem slika u sekundi ima i veću kodnu brzinu.

Najučinkovitija rješenja za pravovremenu isporuku video sadržaja predstavlja usluga adaptivnog/prilagodljivog mrežnog strujanja temeljena na HTTP-u, odnosno HAS (engl. *HTTP Adaptive Streaming*). Sva ta rješenja mogu se predstaviti kao sustav koji se sastoji od klijentske i poslužiteljske strane, [3] [10].

Poslužiteljska strana koristi se za pohranu video sadržaja kojeg dijeli na segmente (engl. *chunks*) određenog trajanja, dok se kodiranje provodi za različite razine kvalitete – VQL (engl.

Video Quality Level). VQL-ovi imaju različite kodne brzine (engl. *bitrates*) te je podržana promjena i prostorne i vremenske rezolucije videa. Klijent na klijentskoj strani bira segment koji ima odgovarajuću kvalitetu koja se može prenijeti u zadanom vremenu na temelju parametara kao što su popunjenost međuspremnika (engl. *buffer*), prethodno dostupne i procjene buduće mrežne propusnosti s ciljem postizanja najbolje QoE, [1].

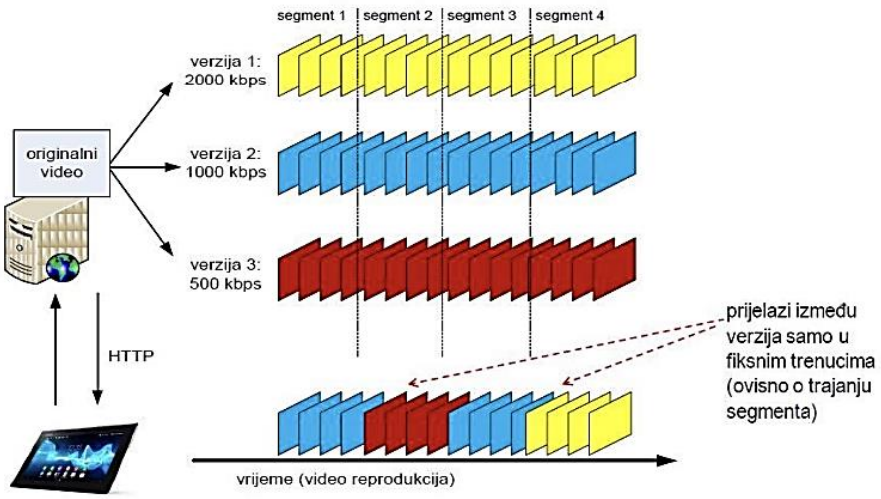

Slika 3.1 *Prikaz tehnologije HAS.* [11]

Neki od parametara koji utječu na QoE korisnika kod videostrujanja su, [10]:

- Početno kašnjenje reprodukcije – uključuje vrijeme koje je potrebno za preuzimanje HTML (engl. *HyperText Markup Language*) stranice, učitavanje dodataka za video player i dekodiranje početnog dijela videozapisa.
- Broj i duljina prekida reprodukcije videozapisa.
- Razina kvalitete video sadržaja – kvaliteta sekvence videosadržaja na poslužitelju, ovisi o kodnoj brzini, vremenskoj i prostornoj rezoluciji, gdje je kodna brzina prosječna količina podataka potrebna za reprodukciju jedne sekunde videozapisa.
- Promjena razine kvalitete.

Prilikom videostrujanja prijemnik reproducira videozapis kada je dio datoteke preuzet i pohranjen u međuspremnik (engl. *Initial buffering*) stvarajući zalihu, čime osigurava izbjegavanje ili smanjenje vremena zastoja reprodukcije koje nastaje zbog pražnjenja međuspremnika ispod minimuma potrebnog za dekodiranje. Za HAS videozapise, klijent u većini slučajeva bira niže razine kvalitete na samom početku reprodukcije videozapisa te ju s vremenom povećava do odgovarajuće kodne brzine, [2] [10].

Slika 3.2 prikazuje funkcionalnost prilagodljivog videostrujanja, odnosno prilagođavanje razina kvalitete videa (VQL) brzini internetske veze kod putovanja automobila. Ako se ne koristi prilagodba videostrujanja, odnosno uz progresivno videostrujanje, videozapis bi se zaustavio i počeo s reprodukcijom tek onda kada se poboljša internetska veza. Prilagodljivo mrežno strujanje prepozna sporiji dolazak podataka te smanjuje video sadržaj i kvalitetu, osiguravajući prikazivanje videozapisa bez prekida, [10].

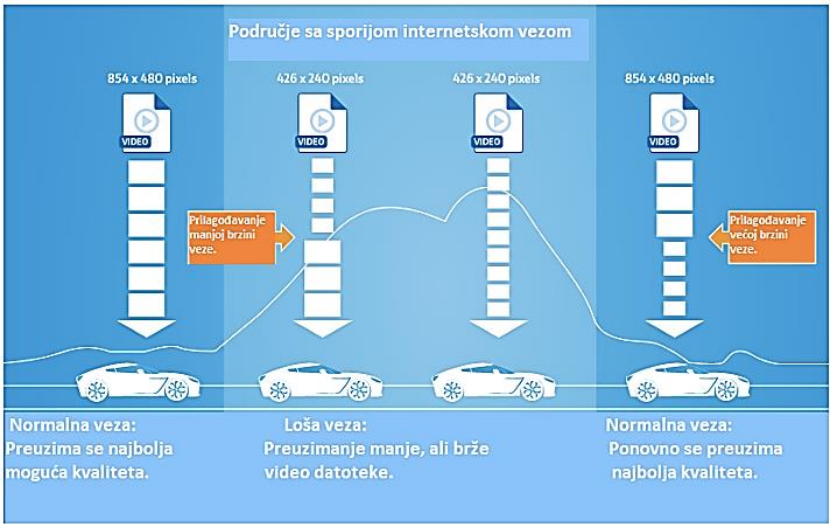

Slika 3.2 *Primjer prilagodljivog mrežnog videostrujanja.* [10]

Privatna poduzeća razvila su nekoliko rješenja za prilagodljivo videostrujanje kao što su, [3]:

1. HTTP Live Streaming (HLS) - Apple
2. Microsoft Smooth Streaming (MSS) - Microsoft
3. HTTP Dynamic Streaming (HDS) - Adobe

Navedena rješenja osiguravaju prilagodljivo videostrujanje tako da koriste različite varijante istog video signala, kodirane različitim prijenosnim brzinama i dodatno podijeljene u male segmente. Ovisno o uvjetima, aplikacija bira odgovarajuću varijantu video signala kako bi se prilagodila uvjetima mreže. Korisnički uređaji morali su podržavati korisnički protokol proizvođača, [5]. Ova rješenja su zaštićena autorskim pravima, a budući da koriste različite formate segmenata i manifest datoteka nisu interoperabilna. Stoga su MPEG i 3rd *Generation Partnership Project* (3GPP) razvili globalnu normu pod nazivom MPEG DASH (engl. *Moving Picture Experts Group Dynamic Adaptive Streaming over HTTP Dynamic Adaptive Streaming*), [3].

3.1. MPEG DASH norma

Travnja 2009. godine MPEG grupacija objavljuje poziv za dostavu prijedloga za prilagodljivo videostrujanje bazirane na HTTP-u. Na osnovi petnaest prijedloga uz pomoć stručnjaka i suradnje s 3GPP razvijena je specifikacija MPEG DASH norme, [3].

Razvoj prve završne verzije norme, danas poznata kao ISO/IEC 23009-1, bio je završen u kolovozu 2011. godine, a ratificirana je prije 98. sastanaka MPEG-a, koji je održan u prosincu iste godine. MPEG DASH objavljen je kao norma od strane Međunarodne organizacije za standardizaciju (engl. *International Standardization Organization* – ISO) u travnju 2012. godine, [3].

MPEG DASH specifikacija sadrži opis sadržaja pohranjenog na HTTP poslužitelju. Sadržaj koji se sprema na poslužitelj može se podijeliti na dva dijela, [3]:

1. Datoteka za opis prikaza medija (engl. *Media Presentation Description* – MPD).
2. Video segmenti.

MPEG DASH norma određuje način obavještavanja korisnika o dostupnosti niza prijenosnih tokova različite kvalitete informacijama potrebnih za odabir odgovarajućeg prijenosnog toka. Definira formate medijskih datoteka u svrhu prilagodljivog videostrujanja. Različiti formati datoteka omogućuju učinkovito i neprimjetno prebacivanje između prijenosnih tokova različitih kvaliteta. Navedeno rezultira prilagodbom promjenjivim uvjetima u internetskoj mreži bez prekida u reprodukciji video signala, [3] [10].

Ova je norma razvijena radi pojednostavljenja održavanja aplikacija, smanjenja troškova razvoja i osiguranja interoperabilnosti korisničkih aplikacija i poslužitelja. Svaki sustav koji je razvijen u skladu s ovom normom pruža korisniku glatku reprodukciju zahvaljujući algoritmu za prilagodljivo videostrujanje koji bira odgovarajuće video segmente, kodirane različitim prostornim rezolucijama i kodnim brzinama ovisno o karakteristikama uređaja. Glatka reprodukcija osigurana je praćenjem dostupne propusnosti i brzine preuzimanja kodiranog sadržaja, [3].

U slučaju smanjene dostupne propusnosti, korisnička aplikacija može odabrati odgovarajuće video segmente s nižom kvalitetom te tako spriječiti stanje nedovoljne popunjenosti međuspremnika i prekid reprodukcije video signala. Također može birati tok s većom kodnom brzinom, ako je brzina preuzimanja veća od kodne brzine trenutnog toka. To znači da se prilagodba

videostrujanja u MPEG DASH normi temelji na parametrima dostupne popunjenosti i popunjenosti međuspremnika, a sve u svrhu pružanja najbolje kvalitete korisničkog iskustva, [3].

Na slici 3.3 može se vidjeti kako MPEG DASH funkcionira. Prvo proces započinje pakiranje kodiranih videozapisa tako da je svaki dio podijeljen na manje dijelove – segmente, specifične duljine trajanja reprodukcije. U tekstualnoj datoteci MPD zapisuje se na koliko je segmenata podijeljen video i redoslijed kojem se pojedini segmenti dostavljaju, kao i URL adresa svakog segmenta. Tako upakirani video i MPD se pohranjuju na poslužitelj te čekaju trenutak kada klijent zatraži njihov prijenos, [3] [10].

Kada korisnik pokrene reprodukciju, klijentska aplikacija zahtjeva MPD datoteku. Kada klijent primi tu datoteku, rastavlja ju kako bi dobio informaciju o postojećim verzijama (reprezentacijama) videosignala poredak, dekodira i prikazuje videozapis korisniku. Pri tome, player konstantno proučava uvjete mreže i zahtjeva od poslužitelja idući segment te se proces ponavlja sve dok videozapis ne završi ili korisnik prekine reprodukciju istog, [10].

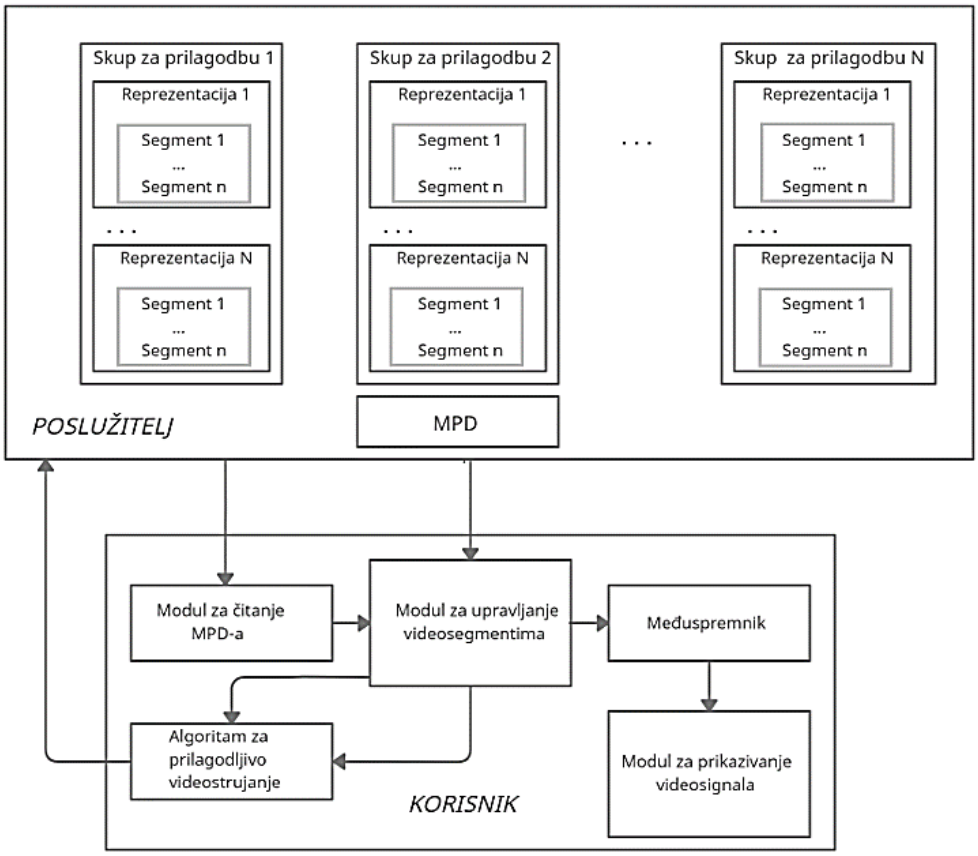

Slika 3.3 *Rad MPEG DASH sustava.* [10]

MPEG DASH specifikacija definira i mnogo dodatnih značajki, a neke od njih su, [12]:

- Prebacivanje i odabir tokova – primjerice odabir jezika za titlove, dinamično izmjenjivanje brzine prijenosa videozapise jedne video kamere ili izbor zapisa kamere koja snima pod određenim kutom, biranje audio toka između tokova koje prenose govor na različitim jezicima i sl.
- Uključivanje oglasa – mogu biti uključeni kao razdoblje između nekog razdoblja ili segment između video segmenata.
- Kompaktna manifest datoteka (engl. *compact manifest*) – URL (engl. *Uniform Resource Locator*) adresa segmenta može biti predstavljena s pomoću sheme koja rezultira kompaktnim MPD-om.
- Fragmentirana manifest datoteka – MPD može biti podijeljen na nekoliko dijelova ili neki od dijelova mogu biti referencirani izvana, što omogućava da se MPD može preuzeti u više koraka.
- Kontrola pomaka sata za prijenose uživo – podatak o UTC vremenu može biti uključen u svaki segment kako bi klijent mogao kontrolirati pomak sata.

Algoritmi prilagodljivog videostrujanja istražuju se i dan danas, istraživači ih pokušavaju unaprijediti radi boljih performansi kako bi se ostvarila bolja kvaliteta korisničkog iskustva. Cilj je osigurati najvišu moguću kvalitetu korisničkog iskustva. ABR algoritmi za prilagodljivo videostrujanje koji se koriste u korisničkim aplikacijama temeljenim na MPEG DASH normi dijele se u tri glavne skupine, [3]:

1. Algoritmi zasnovani na dostupnoj propusnosti – koriste vrijeme dohvaćanja prethodnih segmenata za mjerenje srednje vrijednosti propusnosti te na osnovu tih podataka biraju reprezentaciju za sljedeći video segment.
2. Algoritmi zasnovani na popunjenosti međuspremnika i dostupnoj propusnosti – uz procjenu dostupne propusnosti uzimaju u obzir i donju graničnu vrijednost popunjenosti međuspremnika; noviji algoritmi analiziraju i kvalitetu korisničkog iskustva.
3. Hibridni algoritmi – osim procijenjene propusnosti i popunjenosti međuspremnika, uzimaju u obzir i veličinu pojedinog segmenta, karakteristike video sadržaja, itd.

3.2. Parametri kvalitete korisničkog iskustva u prilagodljivom videostrujanju

Kako bi se provjerila i dokazala poboljšanja u algoritmima za prilagodljivo videostrujanje, potrebno je ispitati kvalitetu rezultirajućih videosignala. Specifikacija kvalitete usluge (engl. *Quality of Service* – QoS) obično ovisi o vrsti aplikacije čiji se parametri analiziraju i povezani su s tehničkim aspektima aplikacije. Koristila se za kvantificiranje kvalitete u multimedijskim uslugama i bila je u fokusu istraživanja u području mrežnih komunikacija. No, s obzirom na to da QoS ne uzima u obzir subjektivnost korisnika, postavlja se pitanje da li tehnički parametri mreže zadovoljavaju potrebe krajnjih korisnika, [3].

Prema grupaciji *Human-Computer Interaction* – HCI, kvaliteta korisničkog iskustva uzima u obzir emocije, odnose, kontekst i očekivanja te *ITU Telecommunication Standardization Sector* definira QoE kao subjektivno prihvaćanje usluge od strane korisnika i podrazumijeva da se mjerenje QoE vrši kroz subjektivne eksperimente. Na QoE utječu različiti čimbenici kao što su, [3]:

- Ljudski čimbenici – korisnikove preferencije, različiti osjetilni i kognitivni procesi.
- Čimbenici konteksta – ekonomski i socijalni aspekti, vrijeme i prostor u kojem se usluga videostrujanja koristi.
- Programska i sklopovska ograničenja elektroničkih uređaja.

Prilagodljivo videostrujanje treba pružiti najbolju ravnotežu između QoE i mogućnosti neprekidnog strujanja videosignala. Kako bi se osigurala najviša razina QoE kod videostrujanja potrebno je uzeti u obzir sljedeće parametre, koji utječu na kvalitetu korisničkog iskustva, [3]:

- Broj i dubina prebacivanja razine kvalitete (engl. *switching*) – korisnici reagiraju negativno na promjene ponašanja sustava, posebice kada se daje bolja usluga drugom korisniku, kao npr. prijelaz na nižu razinu kvalitete signala.
- Početno kašnjenje (engl. *initial delay*) – u prilagodljivom videostrujanju, uvijek je prisutno i opisuje se kao vrijeme potrebno za preuzimanje dovoljne količine podataka koji trebaju biti preneseni prije dekodiranja i početka prikazivanja videosignala. Time se smanjuje učestalost budućih zastoja, ali povećanje početnog kašnjenja može dovesti do korisnikovog odustajanja od korištenja usluge.
- Zastoji u reprodukciji (engl. *stalling*) – događaju se prilikom prikazivanja videosignala zbog nedovoljne popunjenosti međuspremnika.

- Prosječna razina kvalitete (engl. *mean quality level*) – bolje je imati stabilan prijenos, ali niže razine kvalitete nego imati prijenos s velikim brojem prebacivanja razine kvalitete, iako se u prosjeku ostvaruje viša razina kvalitete.

Utjecaj broja i dubine prebacivanja razina kvalitete na QoE posebno je važan za sustave zasnovane na MPEG DASH normi te pogrešne odluke u odabiru razine kvalitete mogu imati veliki utjecaj na kvalitetu korisničkog iskustva, [10].

4. TEORIJSKI PREGLED STATISTIČKIH RASPODJELA

S obzirom na to da se izbor razine kvalitete videosignala u HAS sustavima prilagođava propusnosti mreže, poznavanje statističkih karakteristika promjena propusnosti mreže od velike je važnosti za razvoj i optimizaciju ABR algoritama. Promjene propusnosti nastaju zbog promjene opterećenja mreže, a kod mobilnih korisnika i zbog promjene uvjeta propagacije uslijed promjene položaja mobilnog uređaja u odnosu na baznu postaju. Na temelju izmjerenih podataka o propusnosti na nekoj ruti mobilnog uređaja moguće je napraviti statističku analizu te odrediti da li određena teorijska raspodjela dobro modelira te podatke. Neke od raspodjela koje se najčešće koriste u različitim analizama podataka izmjerenim u komunikacijskim sustavima (kao što su jakost električnog polja, propusnost, razina interferencije i sl.) su Gaussova (normalna), Nakagami, Gamma, Weibull i Rician raspodjela.

4.1. Gaussova raspodjela

Gaussova raspodjela vjerojatnosti najčešća je funkcija raspodjele za slučajno generirane varijable. Funkciju gustoće vjerojatnosti ove raspodjele, predstavljena izrazom (4-1), karakteriziraju dva parametra, srednja vrijednost μ i standardna devijacija σ, koja određuje količinu raspršenosti od srednje vrijednosti:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \tag{4-1}$$

gdje x predstavlja slučajnu varijablu, [13].

Promjene parametara i njihov utjecaj na izgled funkcije gustoće vjerojatnosti Gaussove raspodjele prikazan je na slici 4.1. Graf na slici 4.1 (a) prikazuje tri Gaussove raspodjele sa srednjom vrijednošću $\mu = 0$ i standardnim devijacijama $\sigma = 1, 2, 3$. Vidljivo je da veća standardna devijacija rezultira širim i nižim krivuljama, što označava veću raspršenost podataka oko sredine. Na slici 4.1 (b) predstavljen je graf koji također prikazuje tri Gaussove raspodjele, no razlika je u tome što je fiksna vrijednost standardne devijacije $\sigma = 1$, a varijabilna srednja vrijednost $\mu = -2, 0, 2$. Funkcije raspodjele imaju jednaku raspršenost, ali su pomaknute duž x osi zbog različitih srednjih vrijednosti.

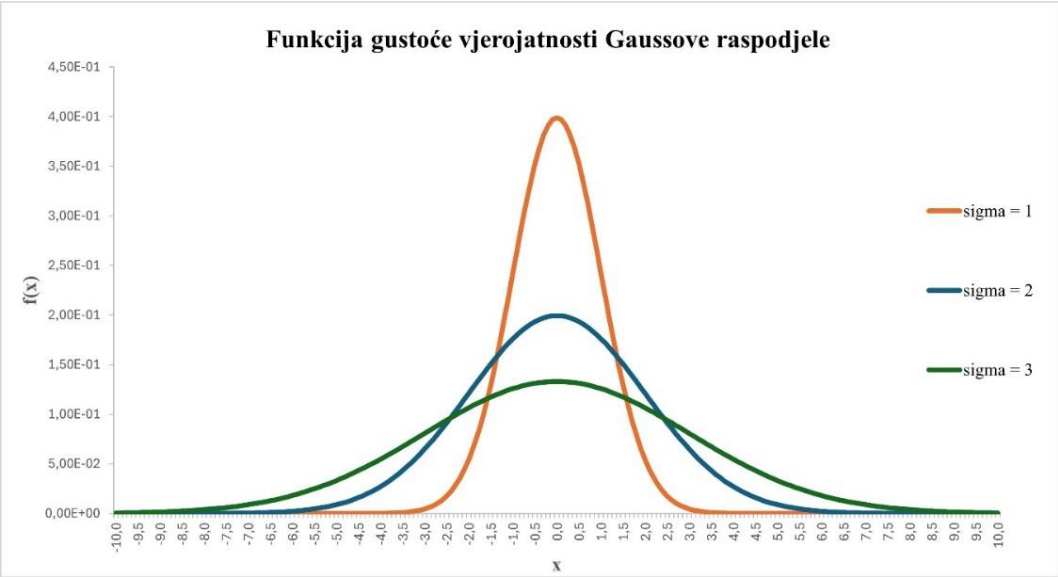

(a)

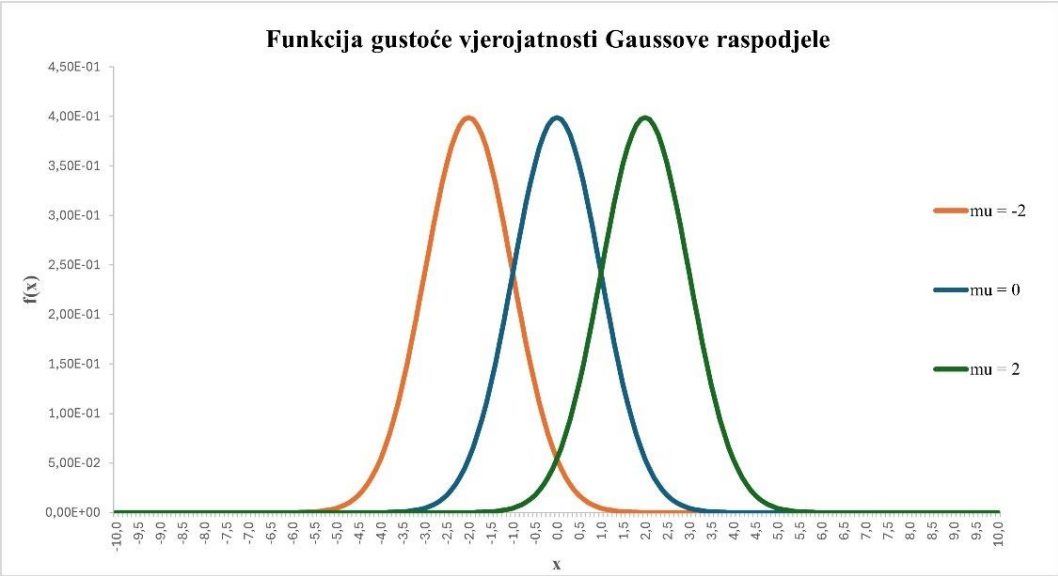

(b)

Slika 4.1 *Funkcija gustoće vjerojatnosti Gaussove raspodjele;*
(a) – fiksna srednja vrijednost $\mu = mu = 0$*, varijabilne standardne devijacije;*
(b) – fiksna standardna devijacija $\sigma = sigma = 1$*, varijabilne srednje vrijednosti.*

Srednja vrijednost μ i varijanca, definirane su sljedećim izrazima (4-2) i (4-3), [13]:

$$E(X) = \mu \tag{4-2}$$

$$Var(X) = \sigma^2 \tag{4-3}$$

U slučaju kada je vrijednost standardne devijacije mala, krivulja gustoće vjerojatnosti će biti visoka i uska, a u slučaju većih vrijednosti, krivulja će biti široka i niska. Posebni oblik ove raspodjele jest kada je vrijednost varijance $\sigma^2 = 1$, a srednje vrijednosti $\mu = 0$, tada se radi o standardnoj normalnoj raspodjeli vjerojatnosti, [13].

4.2. Nakagami raspodjela

Nakagami raspodjela vjerojatnosti često se koristi za modeliranje podataka o jakosti prijemnog signala u uvjetima višestaznog slabljenja signala (engl. *multipath fading*) u mobilnim komunikacijama. gdje se snaga primljenog signala vrlo brzo mijenja uz velike oscilacije, [5]. S parametrom oblika $m > 0{,}5$ i parametrom širenja $\omega > 0$, funkcija gustoće vjerojatnosti Nakagami raspodjele dana je izrazom (4-4):

$$f(x) = \frac{2}{\Gamma(m)}\left(\frac{m}{\omega}\right)^m x^{2m-1} e^{-\frac{m}{\omega}x^2} \tag{4-4}$$

gdje x predstavlja pozitivnu slučajnu varijablu, [4].

Promjene parametara i njihov utjecaj na funkciju gustoće vjerojatnosti Nakagami raspodjele prikazan je na slici 4.2. Graf na slici 4.2 (a) prikazuje tri funkcije Nakagami raspodjele s parametrom oblika $m = 2$ i parametrom širenja $\omega = 1, 2, 3$ te prema grafu možemo zaključiti da veći parametar širenja rezultira širim i nižim krivuljama, što označava raspršenost podataka. Na slici 4.2 (b) prikazane su također tri funkcije gustoće vjerojatnosti Nakagami raspodjele, ali s fiksnim parametrom širenja $\omega = 1$ te varijabilnim vrijednostima parametra oblika $m = 1, 2, 3$. Iz grafa se može vidjeti da što je parametar oblika manji, to je krivulja niža i šira.

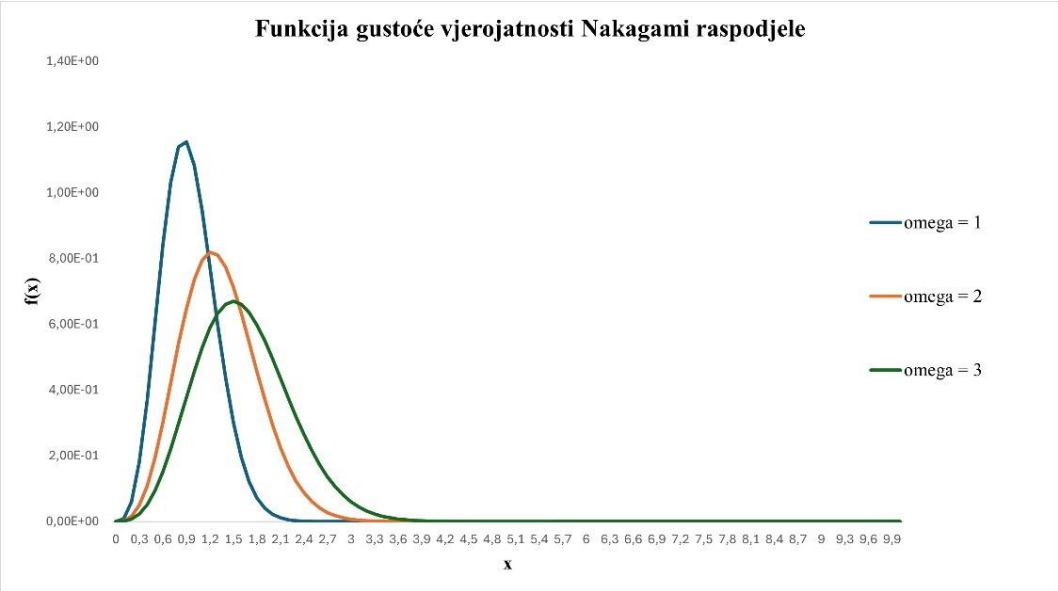

(a)

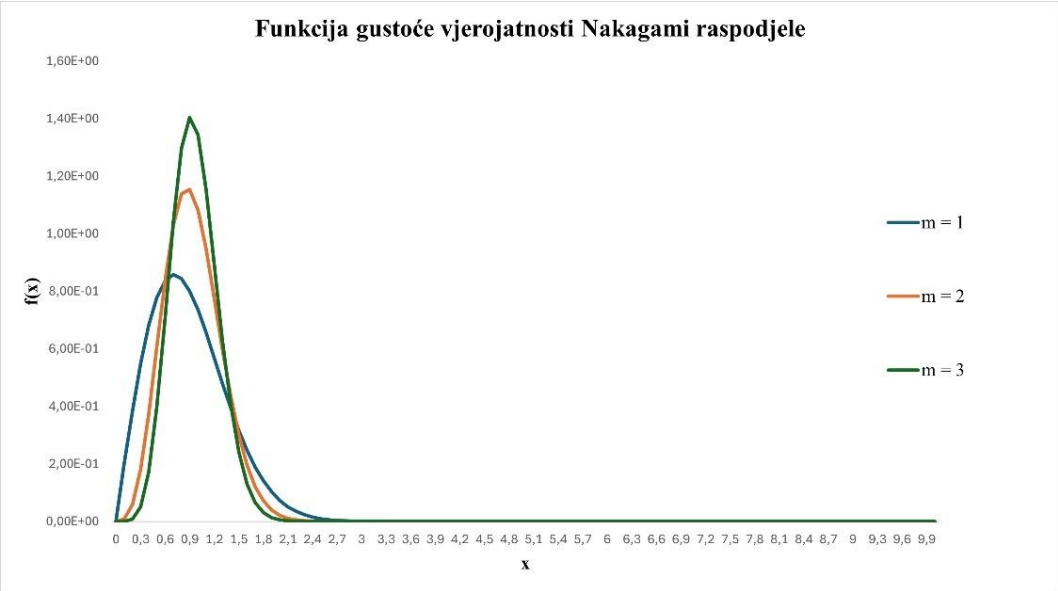

(b)

Slika 4.2 *Funkcija gustoće vjerojatnosti Nakagami raspodjele;*

(a) – fiksni parametar oblika $m = 2$*, varijabilni parametar širenja;*

(b) – fiksni parametar širenja $\omega = omega = 1$*, varijabilni parametar oblika.*

Parametri Nakagami raspodjele vjerojatnosti definiraju srednju vrijednost $E(X)$ i varijancu $Var(X)$ Nakagami slučajne varijable X prema izrazima (4-5) i (4-6):

$$E(X) = \frac{\Gamma\left(m + \frac{1}{2}\right)}{\Gamma(m)} \sqrt{\frac{\omega}{m}} \tag{4-5}$$

$$Var(X) = E(X^2) - E(X)^2 = \omega \left[1 - \frac{1}{m} \left(\frac{\Gamma\left(m + \frac{1}{2}\right)}{\Gamma(m)} \right)^2 \right] \tag{4-6}$$

gdje $\Gamma(\bullet)$ predstavlja *gamma* funkciju, [3].

Parametri se također mogu odrediti s pomoću izraza (4-7) i (4-8):

$$m = \frac{E(X^2)^2}{Var(X^2)} \tag{4-7}$$

$$\omega = E(X^2) \tag{4-8}$$

U slučaju kada je $m = 1$, Nakagami raspodjela jednaka je Rayleighovoj raspodjeli, a u slučaju kada je $m = 0.5$ jednaka je jednostranoj Gaussovoj raspodjeli, [4].

4.3. Gamma raspodjela

Gamma raspodjela je raspodjela vjerojatnosti, koja se sastoji od dva parametra, parametar mjerila $\beta > 0$ i parametar oblika $\gamma > 0$. Funkcija gustoće vjerojatnosti ove raspodjele dana je izrazom (4-9):

$$f(x) = \frac{1}{\beta^{\gamma}\Gamma(\gamma)} x^{\gamma-1} e^{-\frac{x}{\beta}} \tag{4-9}$$

gdje je $x > 0$ slučajna varijabla, a $\Gamma(\bullet)$ predstavlja *gamma* funkciju, [14].

Promjene parametara i njihov utjecaj na funkciju gustoće vjerojatnosti Gamma raspodjele prikazan je na slici 4.3. Graf na slici 4.3 (a) prikazuje utjecaj promjene parametra mjerila $\beta = 1, 2, 3$ na funkciju gustoće uz parametar oblika $\gamma = 2$, dok je na grafu (b) prikazan utjecaj parametra oblika $y = 1, 2, 3$ na funkciju gustoće uz parametar mjerila $\beta = 2$. Raspodjela s većim parametrom mjerila imaju šire i niže krivulje, odnosno prikazuju veću raspršenost podataka, a promjena parametra oblika rezultira raspodjelom iste širine, ali različitog oblika.

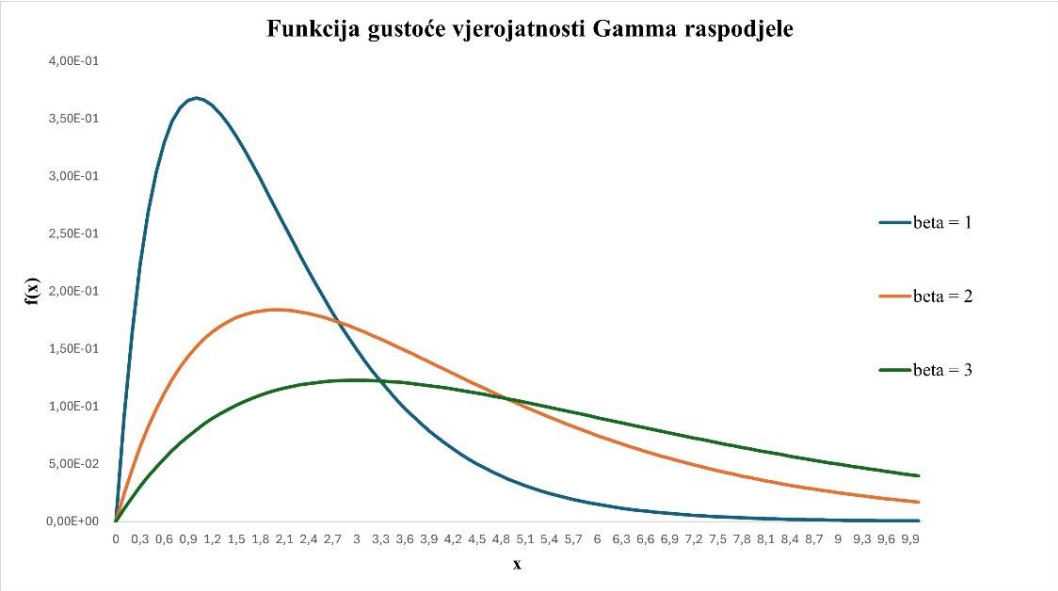

(a)

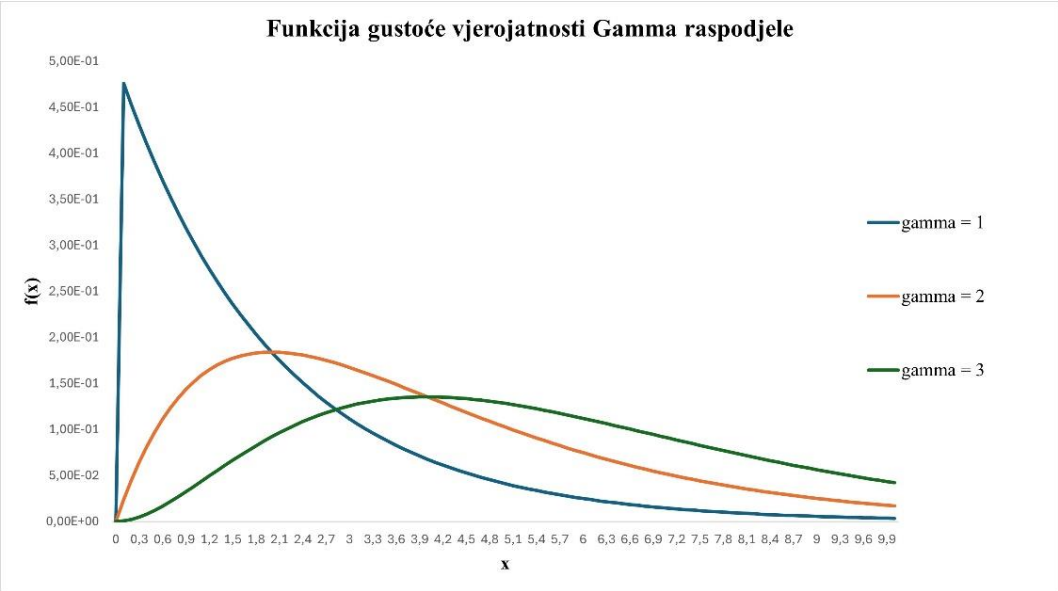

(b)

Slika 4.3 *Funkcija gustoće vjerojatnosti Gamma raspodjele;*
(a) – fiksni parametar oblika $\gamma = gamma = 2$*, varijabilni parametar mjerila;*
(b) – fiksni parametar mjerila $\beta = beta = 2$*, varijabilni parametar oblika.*

Funkcija gustoće vjerojatnosti Gamma raspodjele može se iskazati i preko funkcije gustoće vjerojatnosti Nakagami raspodjele izrazom (4-10). Ako je N slučajna varijabla s Nakagami

raspodjelom te s parametrima m i ω i vrijedi $G = N^2$, tada je $n = x^{\frac{1}{2}}$ te $G = N^2$ je varijabla koja ima Gamma raspodjelu s parametrima m i $\frac{\omega}{m}$, [4]:

$$f(n) = \frac{2}{\Gamma(m)}\left(\frac{m}{\omega}\right)^m n^{2m-1} e^{-\frac{m}{\omega}n^2} \rightarrow f(x) = \frac{2}{\Gamma(m)}\left(\frac{m}{\omega}\right)^m x^{\frac{2m-1}{2}} e^{-\frac{m}{\omega}x} \frac{1}{2} x^{-\frac{1}{2}}$$
$$= \frac{1}{\Gamma(m)}\left(\frac{m}{\omega}\right)^m x^{m-1} e^{-\frac{m}{\omega}x} \tag{4-10}$$

Parametri se mogu odrediti i s pomoću izraza (4-11) i (4-12):

$$\gamma = \frac{E(X^2)^2}{Var(X^2)} \tag{4-11}$$

$$\beta = \frac{Var(X)}{E(X)} \tag{4-12}$$

Gamma raspodjela često se koristi za modeliranje vremena između događaja te trajanja veza u komunikacijskim mrežama.

4.4. Weibull raspodjela

Weibull raspodjela jedna je od najčešće korištenih raspodjela za modeliranje pojave kvarova različitih vrsta tehničkih komponenti te različitih pojava. S parametrom skale $\alpha > 0$, parametrom oblika $\beta > 0$ i parametrom lokacije $\tau > 0$, funkcija gustoće vjerojatnosti Weibull raspodjele dana je izrazom (4-13), [15]:

$$f(x) = \beta\alpha^{-\beta}(x-\tau)^{\beta-1} e^{\left[-\left(\frac{x-\tau}{\alpha}\right)^{\beta}\right]}; x \geq \tau \tag{4-13}$$

gdje x predstavlja slučajnu varijablu.

Budući da parametar λ kombinira parametre skale i oblika izrazom (4-14), tada će funkcija gustoće vjerojatnosti ove raspodjela biti izražena izrazom (4-15), [15]:

$$\lambda = \alpha^{-\beta} \tag{4-14}$$

$$f(x) = \beta\lambda(x-\tau)^{\beta-1} e^{\left[-\lambda(x-\tau)^{\beta}\right]};\ x \geq \tau \tag{4-15}$$

Promjena parametara Weibullove raspodjele značajno utječe na oblik funkcije gustoće vjerojatnosti. Na slici 4.4 (a) prikazan je graf s parametrom oblika $\beta = 2$ i različitim parametrima skale $\alpha = 1, 2, 3$ te je vidljivo da parametar skale utječe na širinu raspodjele podataka. Na slici 4.4 (b) prikazan je graf s parametrom skale $\alpha = 2$ te parametrom oblika $\beta = 1, 2, 3$. Vidi se da što je veći parametar skale to je krivulja šira s nižim maksimumom.

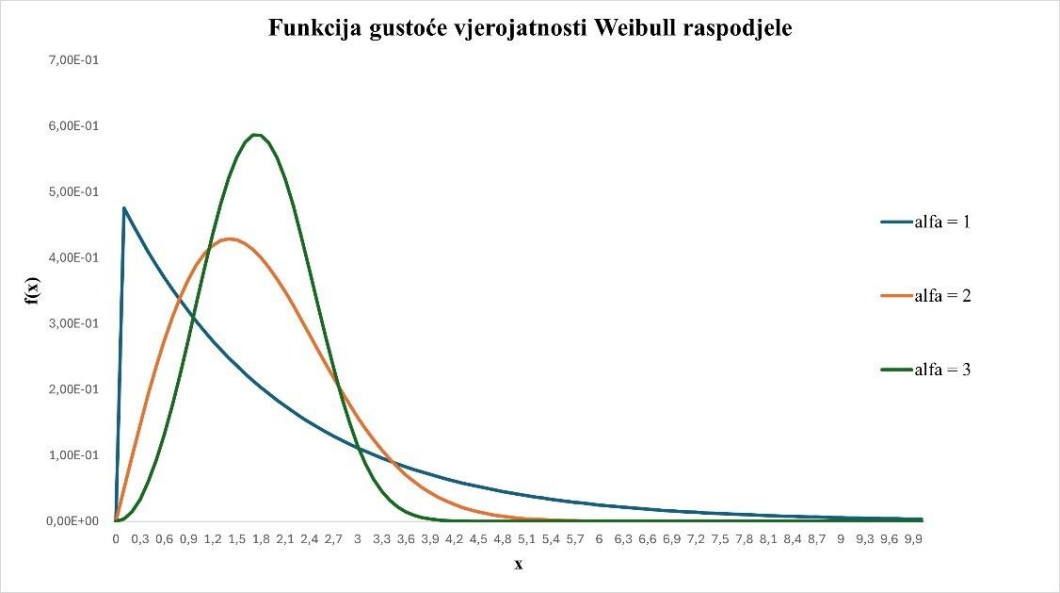

(a)

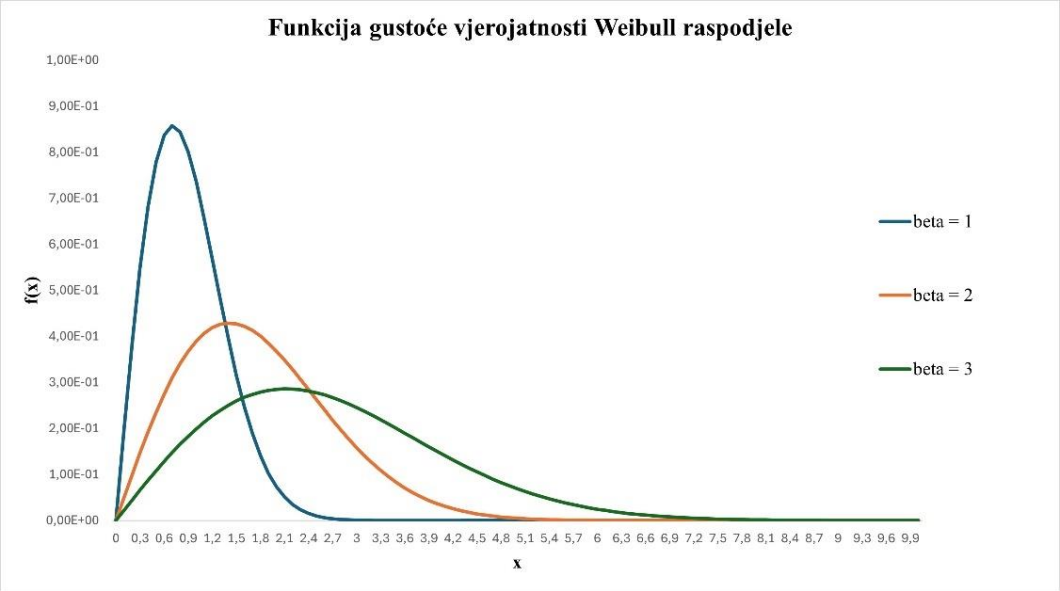

(b)

Slika 4.4 *Funkcija gustoće vjerojatnosti Weibull raspodjele;*
(a) – fiksni parametar oblika $\beta = beta = 2$, *varijabilni parametar skale;*
(b) – fiksni parametar skale $\alpha = alfa = 2$, *varijabilni parametar oblika.*

Prema parametrima Weibullove raspodjele može se definirati srednja vrijednost $E(X)$ i varijanca $Var(X)$ slučajne varijable X prema izrazima (4-16) i (4-17), [15]:

$$E(X) = \Gamma\left(\frac{1}{\beta} + 1\right) \tag{4-16}$$

$$Var(X) = \Gamma\left(\frac{2}{\beta} + 1\right) - \left[\Gamma\left(\frac{1}{\beta} + 1\right)\right]^2 \tag{4-17}$$

Raspodjela je pozitivna za manje vrijednosti parametra oblika β, a indeks zakrivljenosti $\sqrt{\beta}$ opada i jednak je nuli za $\beta = 3{,}6$ te je tada Weibull raspodjela slična oblikom normalnoj, odnosno Gaussovoj raspodjeli.

Također se može iskazati preko Nakagami raspodjele s parametrima $m = 1$ i ω te vrijedi $W = N$ tada je $W = N$ Weibull raspodjela s parametrima $m = 2$ i ω izrazom (4-18), [4]:

$$f(n) = 2\left(\frac{1}{\omega}\right) n e^{-\frac{1}{\omega}n^2} \rightarrow f(x) = \frac{2}{\omega} x^{2-1} e^{-\frac{x^2}{\omega}} \tag{4-18}$$

4.5. Rician raspodjela

Rician raspodjela jedna je od najpoznatijih raspodjela koja opisuje amplitudu signala koji prolazi kroz složeno okruženje s više putanja i u uvjetima višestaznog slabljenja signala (engl. *multipath fading*). S parametrom lokacije s, koji određuje centar raspodjele podataka, i standardnom devijacijom σ, koja predstavlja raspršenost raspodjele podataka, funkcija gustoće vjerojatnosti Rician raspodjele dana je izrazom (4-19):

$$f(x) = \frac{x}{\sigma^2} e^{\frac{-(x^2+s^2)}{2\sigma^2}} \mathrm{I}_0\left(\frac{xs}{\sigma^2}\right) \tag{4-19}$$

gdje je x slučajna varijabla, a I_0 modificirana Besselova funkcija nultog reda prve vrste, [16].

Promjena parametara ima velik utjecaj na oblik funkcije gustoće vjerojatnosti Rician raspodjele. Slika 4.5 (a) prikazuje graf s parametrom lokacije $s = 1$ i vrijednostima standardnih devijacija $\sigma = 2, 3, 4$ te je vidljivo da veća standardna devijacija rezultira širim i nižim krivuljama, što pokazuje veću raspršenost podataka. Slika 4.5 (b) predstavlja graf s standardnom devijacijom $\sigma = 2$ i različitim vrijednostima parametra lokacije $s = 1, 2, 3$ gdje se može vidjeti da veći parametar lokacije daje krivulju manjih vrijednosti.

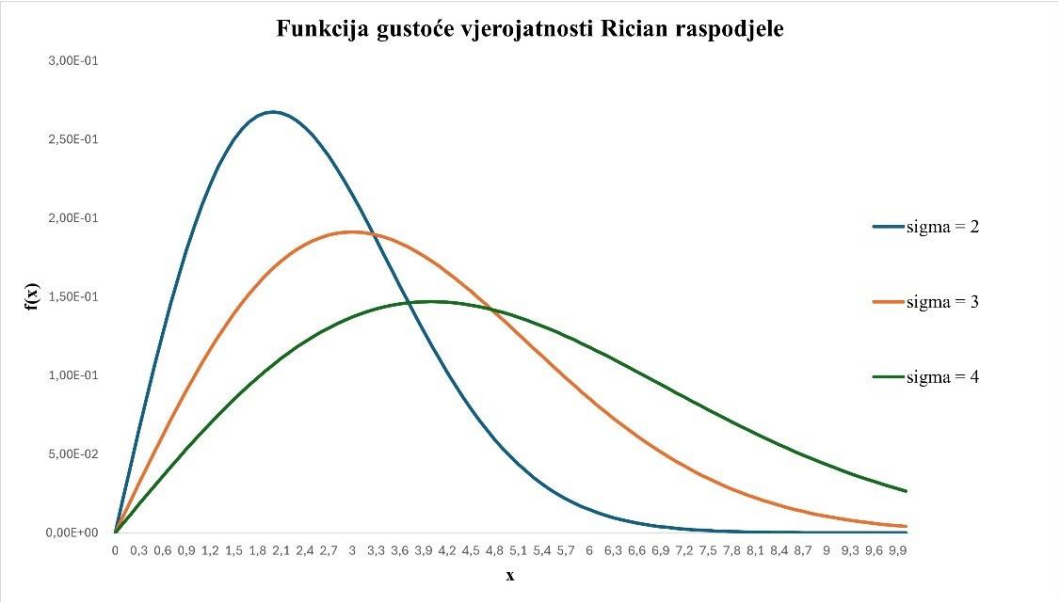

(a)

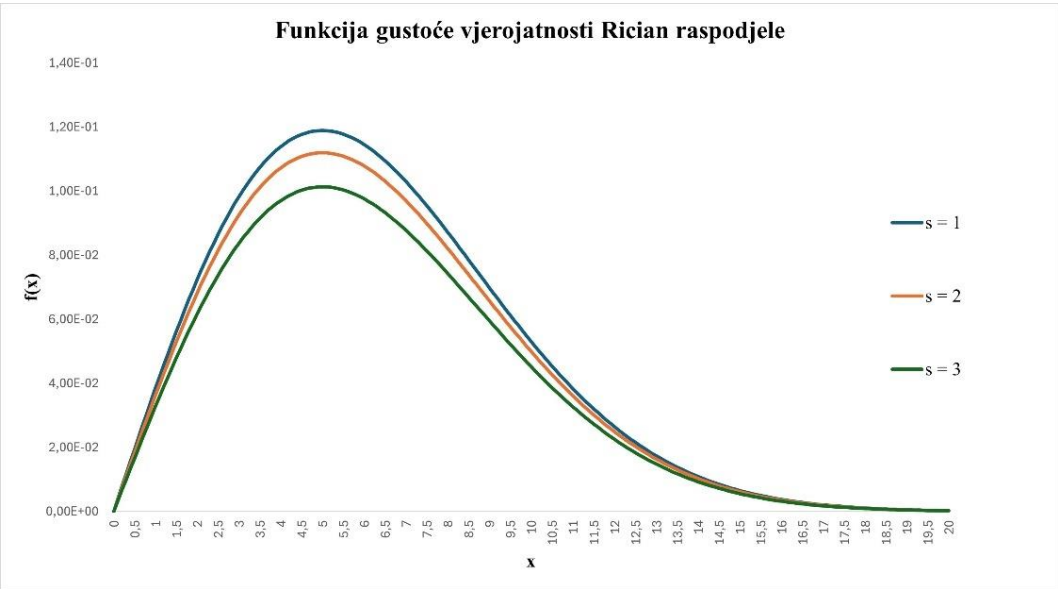

(b)

Slika 4.5 *Funkcija gustoće vjerojatnosti Rician raspodjele;*
(a) – fiksni parametar lokacije $s = 1$*, varijabilne vrijednosti standardne devijacije;*
(b) – fiksna standardna devijacija $\sigma = sigma = 2$*, varijabilni parametar lokacije.*

Prema parametrima Rician raspodjele može se definirati srednja vrijednost $E(X)$ i varijanca $Var(X)$ slučajne varijable X prema izrazima (4-20) i (4-21), [16]:

$$E(X) = \sigma\sqrt{\frac{\pi}{2}}L_{\frac{1}{2}}\left(-\frac{s^2}{2\sigma^2}\right) \tag{4-20}$$

$$Var(X) = 2\sigma^2 + s^2 - [E(X)]^2 = 2\sigma^2 + s^2 - \frac{\pi\sigma^2}{2}L^2_{\frac{1}{2}}\left(-\frac{s^2}{2\sigma^2}\right) \tag{4-21}$$

gdje je $L^2_{\frac{1}{2}}(\bullet)$ predstavlja kvadrat Laguerreovog polinoma $L_{\frac{1}{2}}(\bullet)$.

Parametar s može se odrediti s pomoću izraza (4-22):

$$s = \sqrt{[E(X)]^2 - 2Var(X)} \tag{4-22}$$

Rician raspodjela je ključna u mnogim praktičnim aplikacijama gdje je modeliranje određenog signala pod utjecajem različitih vrsta šuma velikog značaja, [16].

5. STATISTIČKA ANALIZA PROPUSNOSTI 3G I 4G MREŽA

Na temelju izmjerenih propusnosti tijekom videostrujanja putem mobilnih uređaja provedena je statistička analiza te usporedba performansi 3G i 4G mreže. Statistička analiza daje uvid u varijabilnost i stabilnost mrežnih performansi u različitim okruženjima. Analiza je provedena na način da su iz izmjerenih podataka propusnosti procijenjeni parametri različitih teorijskih statističkih raspodjela (Gaussove, Nakagami, Gamma, Weibull i Ricianove) za koje se može pretpostaviti da bi mogle dobro modelirati izmjerene podatke. Za provjeru podudaranja između raspodjela izmjerenih podataka i teorijskih raspodjela korišten je Kolmogorov-Smirnov test (KS test).

Kolmogorov-Smirnov test je neparametrijski test koji se koristi za usporedbu uzorka s referentnom vjerojatnosnom raspodjelom ili za usporedbu dva uzorka. Glavna svrha testa je utvrditi koliko se podaci iz uzorka uklapaju u određenu teorijsku raspodjelu, što je ključno za razumijevanje koliko dobro podaci predstavljaju određeni model. Rezultati KS testa sadrže dvije ključne vrijednosti za svaku raspodjelu, [17]:

1. H vrijednost (engl. *Hypothesis test result*):
   - Ako je rezultat $H = 0$ – tada se ne može odbaciti nul-hipoteza, odnosno teorijska raspodjela dobro opisuje podatke.
   - Ako je rezultat $H = 1$ – može se odbaciti nul-hipoteza, odnosno teorijska raspodjela ne opisuje dobro podatke.
2. p vrijednost – označava vjerojatnost da podaci slijede teorijsku funkciju raspodjele pod pretpostavkom da je nul-hipoteza istinita, ako je p vrijednost mala (obično manja od 0.05), onda postoji statistički značajan dokaz protiv nul-hipoteze.

Za provedbu statističke analize korišten je programski paket MATLAB.

5.1. 3G skup podataka

Statistička analiza izmjerene propusnosti u 3G mrežama izvršena je na skupu podataka koji se sastoji od mjerenja prikupljenih tijekom videostrujanja korištenjem HTTP-a putem 3G mreže s pomoću mobilnih uređaja. Skup podataka sastoji se od 24 mrežnih ispitnih zapisa različitih vrsta javnog prijevoza u Oslu (Norveška) kao što su automobil, autobus, tramvaj te vlak. Podaci su pohranjeni kao tekstualne datoteke te uz vremenske oznake i GPS koordinate, izmjerena je i propusnost kao broj kilobitova preuzetih za približno svaku sekundu rute, [18].

Ovaj skup podataka omogućuje analizu i usporedbu utjecaja različitih mrežnih uvjeta na algoritme za prilagodljivo videostrujanje u situacijama s niskom dostupnom propusnošću. Tablica 5.1 prikazuje prosječnu izmjerenu propusnost i standardnu devijaciju propusnosti za različite vrste javnog prijevoza, koje su izračunate s pomoću izraza (5-1) i (5-2):

$$\bar{x} = \frac{1}{n}\sum_{i=1}^{n} x_i = \frac{x_1 + x_2 + \cdots + x_n}{n} \tag{5-1}$$

$$\sigma = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(x_i - \bar{x})^2} \tag{5-2}$$

Iz podataka u tablici 5.1 vidljivo je da propusnost i standardna devijacija značajno variraju ovisno o vrsti prijevoza:

- Grupa Automobili – najmanja prosječna propusnost iznosi $726{,}14\ kbps$ (zapis Automobil 2), dok najveća iznosi $1\,995{,}27\ kbps$ (zapis Automobil 7). Standardna devijacija varira od $785{,}14\ kbps$ (zapis Automobil 2) do $1\,171{,}14\ kbps$ (zapis Automobil 7), što ukazuje na značajnu varijabilnost u mrežnim uvjetima.
- Grupa Autobusi – najmanja prosječna propusnost je $1\,718{,}95\ kbps$ (zapis Autobus 4), dok najveća iznosi $2\,719{,}21\ kbps$ (zapis Autobus 1). Standardna devijacija se kreće od $873{,}22\ kbps$ (zapis Autobus 3) do $1\,545{,}10\ kbps$ (zapis Autobus 1), što ukazuje na još veću nestabilnost mrežnih uvjeta u usporedbi s automobilima.
- Grupa Tramvaji – najmanja prosječna propusnost iznosi $679{,}36\ kbps$ (zapis Tramvaj 3), dok najveća iznosi $982{,}56\ kbps$ (zapis Tramvaj 2). Standardna devijacija u tramvajima varira od $354{,}00\ kbps$ (zapis Tramvaj 1) do $467{,}31\ kbps$ (zapis Tramvaj 2), što sugerira stabilnije mrežne uvjete u usporedbi s automobilima i autobusima.
- Grupa Vlakovi – najmanja prosječna propusnost iznosi $1\,123{,}83\ kbps$ (zapis Vlak 1), dok najveća iznosi $1\,463{,}69\ kbps$ (zapis Vlak 4). Standardna devijacija varira od $806{,}93\ kbps$ (zapis Vlak 2) do $1\,010{,}03\ kbps$ (zapis Vlak 4), što ukazuje na relativno stabilne mrežne uvjete sa srednjim vrijednostima propusnosti.

Usporedbom različitih grupa prijevoza, Grupa Autobusi imaju najvišu prosječnu propusnost, ali i najvišu standardnu devijaciju. što ukazuje na nestabilnije mrežne uvjete. Grupe Automobili i Vlakovi imaju nešto niže vrijednosti prosječne propusnosti, ali također visoke

standardne devijacije. Grupa Tramvaji imaju najniže prosječne propusnosti, ali i najniže standardne devijacije, što sugerira najstabilnije mrežne uvjete.

U prilogu 1 dani su histogrami svih mrežnih zapisa propusnosti za 3G mrežu.

Tablica 5.1 *Prosječna propusnost i standardna devijacija propusnosti 3G ispitnih zapisa.*

3G mrežni ispitni zapisi	Prosječna propusnost $[kbps]$	Standardna devijacija propusnosti $[kbps]$
Automobil 1	726,49	831,60
Automobil 2	726,14	785,48
Automobil 3	1765,78	959,68
Automobil 4	1828,94	1005,49
Automobil 5	1889,42	922,02
Automobil 6	1900,17	995,16
Automobil 7	1995,27	1171,14
Autobus 1	2719,21	1545,10
Autobus 2	2617,20	1175,74
Autobus 3	1830,51	873,22
Autobus 4	1718,95	907,53
Autobus 5	2291,11	1172,44
Autobus 6	2528,67	1094,49
Tramvaj 1	777,33	354,00
Tramvaj 2	982,56	467,31
Tramvaj 3	679,36	365,45
Tramvaj 4	738,63	401,12
Tramvaj 5	762,77	438,95
Tramvaj 6	838,27	453,33
Vlak 1	1123,83	945,48
Vlak 2	1402,47	806,93
Vlak 3	1393,67	959,91
Vlak 4	1463,69	1010,03
Vlak 5	1406,75	859,99

Za daljnju su analizu propusnosti, za svaki od ispitnih zapisa 3G mreže, primjenom MATLAB *fitdist* funkcije, napravljene procjene parametara Gaussove, Nakagami, Gamma, Weibull i Rician raspodjele tako da daju najmanje odstupanje dane teorijske raspodjele od raspodjele podataka koji se njome modeliraju. Sljedeće tablice prikazuju parametre navedenih raspodjela za 3G mrežne ispitne zapise različitih vrsta javnog prijevoza te rezultate KS testa – programski kod napravljen za proračun ovih parametara i KS test prikazan je na slici 5.1 do 5.3.

Slika 5.1 prikazuje MATLAB skriptu za učitavanje i statističku analizu podataka o propusnosti mreže 3G mrežnih ispitnih zapisa. Funkcija *fitdist* koristi se za procjenu parametara definirane raspodjele iz izmjerenih podataka.

```
% Učitavanje 3G mrežnih ispitnih zapisa
    file_path = 'D:\MATLAB\3G.xlsx';
    sheets = sheetnames(file_path);
    for i = 1:length(sheets)
    sheet_name = sheets{i};
    data = xlsread(file_path, sheet_name);
    data = data(:, 1); % Prvi stupac

% Gauss raspodjela
    pdf_gauss = fitdist(data, 'Normal');

% Nakagami raspodjela
    data_positive = data(data > 0); % Nakagami raspodjela zahtjeva pozitivne vrijednosti
    pdf_nakagami = fitdist(data_positive, 'Nakagami');

% Gamma raspodjela
    pdf_gamma = fitdist(data_positive, 'Gamma');

% Weibull raspodjela
    pdf_weibull = fitdist(data_positive, 'Weibull');

% Rician raspodjela
    pdf_rician = fitdist(data_positive, 'Rician');
```

Slika 5.1 *MATLAB skripta za učitavanje podataka te procjenu parametara raspodjela.*

Slika 5.2 prikazuje MATLAB skriptu za prikaz histograma podataka s pripadajućim funkcijama gustoće vjerojatnosti za svaku raspodjelu. Pomoću funkcije *subplot* kreirani su višestruki grafovi unutar jedne slike kako bi se dao vizualni uvid u to koliko dobro različite statističke raspodjele odgovaraju stvarnim podacima o propusnosti 3G mreže, omogućujući lakše razumijevanje mrežnih performansi i varijabilnosti u različitim uvjetima.

Slika 5.3 prikazuje MATLAB skriptu koja dodatno analizira podatke o propusnosti 3G mreže koristeći KS test. Nakon što izračuna parametre statističkih raspodjela na temelju podataka, provjerava koliko dobro svaka raspodjela odgovara stvarnim podacima. Rezultati testa se ispisuju na ekran.

```
    figure;
    x = linspace(min(data), max(data), 100);

% Gauss raspodjela
    subplot(3, 2, 1);
    histogram(data, 'Normalization', 'pdf');
    hold on;
    y_gauss = pdf(pdf_gauss, x);
    plot(x, y_gauss, 'LineWidth', 2, 'DisplayName', 'Gauss');
    title(['Gauss raspodjela za ', sheet_name]);
    hold off;

% Nakagami raspodjela
    subplot(3, 2, 2);
    histogram(data_positive, 'Normalization', 'pdf');
    hold on;
    y_nakagami = pdf(pdf_nakagami, x);
    plot(x, y_nakagami, 'LineWidth', 2, 'DisplayName', 'Nakagami');
    title(['Nakagami raspodjela za ', sheet_name]);
    hold off;

% Gamma raspodjela
    subplot(3, 2, 3);
    histogram(data_positive, 'Normalization', 'pdf');
    hold on;
    y_gamma = pdf(pdf_gamma, x);
    plot(x, y_gamma, 'LineWidth', 2, 'DisplayName', 'Gamma');
    title(['Gamma raspodjela za ', sheet_name]);
    hold off;

% Weibull raspodjela
    subplot(3, 2, 4);
    histogram(data_positive, 'Normalization', 'pdf');
    hold on;
    y_weibull = pdf(pdf_weibull, x);
    plot(x, y_weibull, 'LineWidth', 2, 'DisplayName', 'Weibull');
    title(['Weibull raspodjela za ', sheet_name]);
    hold off;

% Rician raspodjela
    subplot(3, 2, 5);
    histogram(data_positive, 'Normalization', 'pdf');
    hold on;
    y_rician = pdf(pdf_rician, x);
    plot(x, y_rician, 'LineWidth', 2, 'DisplayName', 'Rician');
    title(['Rician raspodjela za ', sheet_name]);
    hold off;
```

Slika 5.2 *MATLAB skripta za vizualizaciju histograma i funkcija gustoće vjerojatnosti.*

```
% Kolmogorov-Smirnov test
    [h_gauss, p_gauss] = kstest(data, 'CDF', pdf_gauss);
    [h_nakagami, p_nakagami] = kstest(data, 'CDF', pdf_nakagami);
    [h_gamma, p_gamma] = kstest(data, 'CDF', pdf_gamma);
    [h_weibull, p_weibull] = kstest(data, 'CDF', pdf_weibull);
    [h_rician, p_rician] = kstest(data, 'CDF', pdf_rician);

% Ispis rezultata
    fprintf('Kolmogorov-Smirnov test rezultati za %s:\n', sheet_name);
    fprintf('Gauss raspodjela: H = %d, p = %f\n', h_gauss, p_gauss);
    fprintf('Nakagami raspodjela: H = %d, p = %f\n', h_nakagami, p_nakagami);
    fprintf('Gamma raspodjela: H = %d, p = %f\n', h_gamma, p_gamma);
    fprintf('Weibull raspodjela: H = %d, p = %f\n', h_weibull, p_weibull);
    fprintf('Rician raspodjela: H = %d, p = %f\n', h_rician, p_rician);
    end
```

Slika 5.3 *MATLAB skripta za provedbu Kolmogorov-Smirnovljeva testa te ispis rezultata.*

U tablici 5.2 prikazani su procijenjeni parametri teorijskih raspodjela za 3G mrežne zapise prikupljene pri vožnji automobilom, a tablica 5.3 prikazuje rezultate KS testa za iste zapise.

Tablica 5.2 *Procijenjeni parametri raspodjela za 3G mrežne zapise grupe Automobili.*

3G mrežni ispitni zapisi		Grupa Automobili						
		1	2	3	4	5	6	7
Gaussova raspodjela	μ	726,49	726,14	1765,78	1828,94	1889,42	1900,17	1995,27
	σ	831,68	785,53	960,89	1006,79	923,11	996,46	1172,64
Nakagami raspodjela	m	0,2592	0,2253	0,9961	0,9059	1,1101	0,9215	0,7803
	ω	$1{,}22 \cdot 10^6$	$1{,}14 \cdot 10^6$	$4{,}04 \cdot 10^6$	$4{,}36 \cdot 10^6$	$4{,}42 \cdot 10^6$	$4{,}60 \cdot 10^6$	$5{,}35 \cdot 10^6$
Gamma raspodjela	β	1121,80	1398,16	539,49	657,41	541,56	699,09	869,89
	γ	0,6476	0,5195	3,2731	2,7821	3,4889	2,7181	2,2937
Weibull raspodjela	β	0,7473	0,6566	1,9300	1,8601	2,1167	1,9248	1,7166
	λ	611,83	572,14	1992,61	2051,23	2126,38	2127,44	2226,06
Rician raspodjela	s	41,31	46,55	134,02	138,36	1201,15	168,71	119,07
	σ	780,39	755,90	1418,36	1473,00	1220,13	1512,44	1634,13

Tablica 5.3 *Rezultati Kolmogorov-Smirnov testa za 3G mrežne zapise grupe Automobili.*

3G mrežni ispitni zapisi		Grupa Automobili						
		1	2	3	4	5	6	7
Gaussova raspodjela	H	1	1	1	1	1	0	1
	p	0,0000	0,0000	0,0274	0,0000	0,0104	0,1059	0,0000
Nakagami raspodjela	H	1	1	0	1	0	1	1
	p	0,0000	0,0000	0,2525	0,0122	0,2754	0,0097	0,024
Gamma raspodjela	H	1	1	0	1	0	1	1
	p	0,0000	0,0000	0,3848	0,0314	0,0695	0,0000	0,0000
Weibull raspodjela	H	1	1	0	1	0	1	1
	p	0,0000	0,0000	0,1226	0,0248	0,2252	0,011	0,018
Rician raspodjela	H	1	1	0	1	0	1	1
	p	0,0000	0,0000	0,2469	0,0040	0,1791	0,037	0,0000

Analiza procijenjenih parametara teorijskih raspodjela za 3G mrežne zapise prikupljene tijekom vožnje automobilom, zajedno s rezultatima Kolmogorov-Smirnov (KS) testa, otkriva koji su modeli prikladni za različite skupove podataka.

Za zapis 1, niti jedna od raspodjela ne odgovara dobro prikupljenim podacima. Gaussova raspodjela je odbačena s p-vrijednošću od $0{,}0000$, što ukazuje na to da podaci značajno odstupaju od normalne raspodjele. Razlog za to je asimetričnost raspodjele podataka što je u suprotnosti s Gaussovom raspodjelom koja pretpostavlja simetričnu raspodjelu oko srednje vrijednosti.

Za zapis 3 (slika 5.4), Gaussova raspodjela je jedina koja nije dobro modelirala podatke, zbog svojih ograničenja u modeliranju podataka s asimetričnom raspodjelom i većom varijabilnošću, što dokazuje visoka standardna devijacija za zapis 3, $\sigma = 960{,}89\ kbps$.

S druge strane, za zapis 6, Gaussova raspodjela je jedina koja nije odbačena. Ovdje je standardna devijacije također relativno visoka, $\sigma = 996{,}46\ kbps$, ali raspodjela podataka (prilog 1) je simetrična i približno odgovara teorijskoj Gaussovoj raspodjeli, zbog čega ona i najbolje opisuje ovaj zapis. Ostale teorijske raspodjele koje dobro modeliraju asimetrične raspodjele podataka nisu povoljne za modeliranje ovog simetričnog skupa podataka.

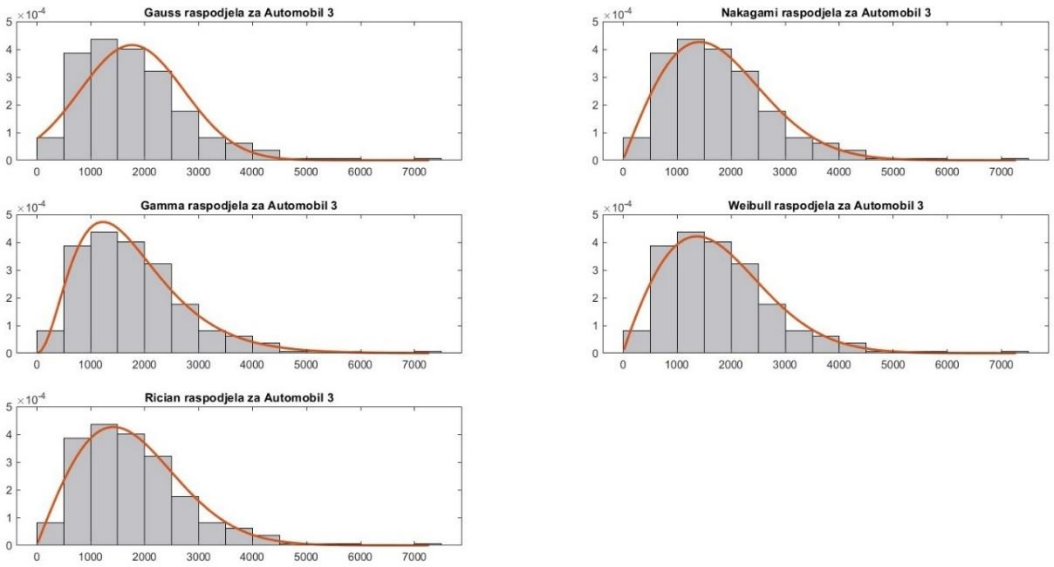

Slika 5.4 *Histogram za zapis Automobil 3 (3G mreža) i grafovi prilagođenih raspodjela.*

U tablici 5.4 prikazani su procijenjeni parametri teorijskih raspodjela za 3G mrežne zapise prikupljene pri vožnji autobusom, a tablica 5.5 prikazuje rezultate KS testa za iste zapise.

Tablica 5.4 *Procijenjeni parametri raspodjela za 3G mrežne zapise grupe Autobusi.*

3G mrežni ispitni zapisi		Grupa Autobusi					
		1	2	3	4	5	6
Gaussova raspodjela	μ	2719,22	2617,20	1830,51	1718,95	2291,11	2528,67
	σ	1546,79	1176,19	873,65	908,25	1173,21	1095,52
Nakagami raspodjela	m	0,6434	1,1640	1,1329	0,9807	0,9254	1,3081
	ω	$9{,}78 \cdot 10^6$	$8{,}23 \cdot 10^6$	$4{,}11 \cdot 10^6$	$3{,}78 \cdot 10^6$	$6{,}62 \cdot 10^6$	$7{,}59 \cdot 10^6$
Gamma raspodjela	β	1660,63	758,45	519,85	561,19	856,75	624,09
	γ	1,6375	3,4507	3,5213	3,0631	2,6742	4,0518
Weibull raspodjela	β	1,5828	2,3229	2,1834	1,9647	1,9813	2,4480
	λ	2980,95	2938,08	2061,45	1936,24	2569,03	2843,39
Rician raspodjela	s	1748,26	2164,82	1370,49	163,55	1538,97	2135,35
	σ	1833,75	1331,48	1057,14	1370,07	1458,69	1231,34

Tablica 5.5 *Rezultati Kolmogorov-Smirnov testa za 3G mrežne zapise grupe Autobusi.*

3G mrežni ispitni zapisi		Grupa Autobusi					
		1	2	3	4	5	6
Gaussova raspodjela	H	1	1	1	1	1	0
	p	0,0004	0,0171	0,0246	0,0167	0,0033	0,3045
Nakagami raspodjela	H	1	1	1	0	1	0
	p	0,0000	0,0033	0,0343	0,7779	0,0035	0,1324
Gamma raspodjela	H	1	1	1	0	1	1
	p	0,0000	0,0000	0,0000	0,1868	0,0000	0,0030
Weibull raspodjela	H	1	0	0	0	1	0
	p	0,0000	0,0802	0,0967	0,7769	0,0144	0,5840
Rician raspodjela	H	1	0	0	0	1	0
	p	0,0000	0,0944	0,1475	0,7999	0,0260	0,9008

Analiza rezultata procjene parametara teorijskih raspodjela za 3G mrežne zapise prikupljene tijekom vožnje autobusom, zajedno s rezultatima Kolmogorov-Smirnov (KS) testa, pruža uvid u prilagođenost različitih raspodjela podacima te ukazuje na varijabilnost među različitim zapisima.

Za zapis 1, sve su raspodjele odbačene, s tim da je Gaussova raspodjela odbačena s p-vrijednošću 0,004 pa se čini da je Gaussova raspodjela nešto bolja od ostalih teorijskih raspodjela.

Za zapis 4, Gaussova raspodjela je odbačena, p-vrijednost 0,0167, što ukazuje na to da podaci značajno odstupaju od normalne raspodjele. S druge strane, Weibull i Rician raspodjele gotovo savršeno modeliraju podatke, s p-vrijednostima 0,7769 i 0,7999. Ovo je potkrijepljeno time što podaci imaju karakteristike koje ove raspodjele mogu bolje obuhvatiti, poput određene asimetrije ili specifične strukture varijabilnosti.

Za zapis 6 (slika 5.5), Gaussova raspodjela nije odbačena s p-vrijednošću 0,3045, što ukazuje na to da ova raspodjela relativno dobro modelira podatke, što može biti povezano sa simetričnošću raspodjele podataka. Weibull i Rician također nisu odbačene s p-vrijednostima 0,5840 i 0,9008, što ukazuje na njihovu sposobnost prilagođavanja raspodjelama podataka s malom asimetrijom.

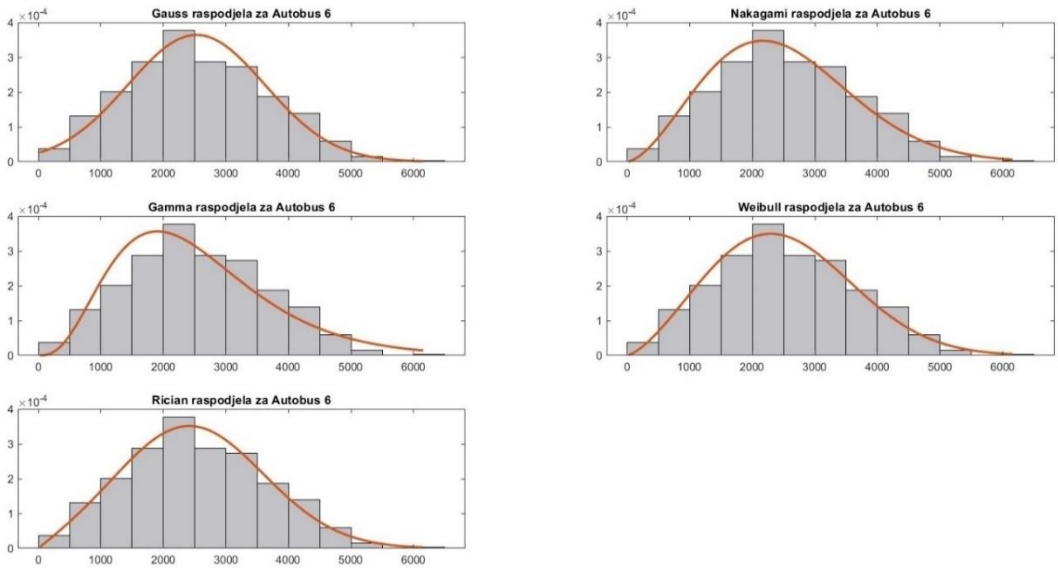

Slika 5.5 *Histogram za zapis Autobus 6 (3G mreža) i grafovi prilagođenih raspodjela.*

U tablici 5.6 prikazani su procijenjeni parametri teorijskih raspodjela za 3G mrežne zapise prikupljene pri vožnji tramvajem, a tablica 5.7 prikazuje rezultate KS testa za iste zapise.

Tablica 5.6 *Procijenjeni parametri raspodjela za 3G mrežne zapise grupe Tramvaji.*

3G mrežni ispitni zapisi		Grupa Tramvaji					
		1	2	3	4	5	6
Gaussova raspodjela	μ	777,33	982,56	679,36	738,64	762,77	838,27
	σ	354,00	467,50	365,58	401,31	438,15	453,50
Nakagami raspodjela	m	1,1615	1,0245	0,9539	0,8063	0,7134	0,9316
	ω	$7{,}30 \cdot 10^5$	$1{,}18 \cdot 10^6$	$5{,}95 \cdot 10^5$	$7{,}06 \cdot 10^5$	$7{,}74 \cdot 10^5$	$9{,}08 \cdot 10^5$
Gamma raspodjela	β	222,81	333,07	228,11	328,37	393,25	291,99
	γ	3,4888	2,9500	2,9782	2,2494	1,9397	2,8708
Weibull raspodjela	β	2,2917	2,1316	1,9364	1,8232	1,6699	1,9126
	λ	873,51	1100,20	765,93	825,01	845,68	943,54
Rician raspodjela	s	633,36	772,44	95,59	471,73	296,23	103,92
	σ	405,23	541,83	541,69	491,91	586,16	670,09

Tablica 5.7 *Rezultati Kolmogorov-Smirnov testa za 3G mrežne zapise grupe Tramvaji.*

3G mrežni ispitni zapisi		Grupa Tramvaji					
		1	2	3	4	5	6
Gaussova raspodjela	H	0	0	1	1	1	1
	p	0,2639	0,0556	0,0000	0,0005	0,0009	0,0000
Nakagami raspodjela	H	1	1	0	1	1	1
	p	0,0001	0,0000	0,7114	0,0000	0,0000	0,0004
Gamma raspodjela	H	1	1	0	1	1	1
	p	0,0000	0,0000	0,1898	00000	0,0000	0,0101
Weibull raspodjela	H	1	1	0	1	1	1
	p	0,0042	0,0000	0,8291	0,0000	0,0000	0,0008
Rician raspodjela	H	0	1	0	1	1	1
	p	0,1073	0,0007	0,2966	0,0000	0,0000	0,0000

Analiza rezultata procjene parametara teorijskih raspodjela za 3G mrežne zapise prikupljene tijekom vožnje tramvajem, zajedno s rezultatima Kolmogorov-Smirnov (KS) testa, pružaju uvid u prilagođenost različitih raspodjela podacima i ukazuju na varijabilnost među različitim zapisima. Može se uočiti da za zapise 4, 5 i 6 niti jedna teorijska raspodjela nije dobar model, a da samo za zapis 3 više teorijskih raspodjela dobro modelira podatke.

Za zapis 2, Gaussova raspodjela je jedina koja nije odbačena s p-vrijednošću 0,0556.

Za zapis 3 (slika 5.6), Gaussova raspodjela je odbačena, što sugerira da podaci značajno odstupaju od normalne raspodjela. Ovaj zapis je poseban slučaj gdje Nakagami, Gamma, Weibull i Rician raspodjele uspijevaju modelirati podatke s visokim p-vrijednostima od 0,7114 do 0,8291.

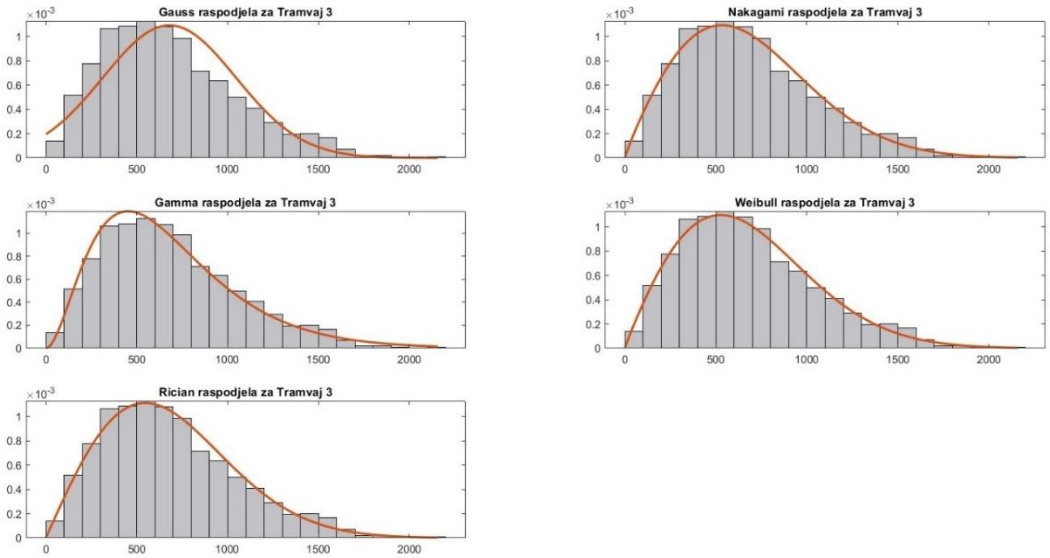

Slika 5.6 *Histogram za zapis Tramvaj 3 (3G mreža) i grafovi prilagođenih raspodjela.*

U tablici 5.8 prikazani su procijenjeni parametri teorijskih raspodjela za 3G mrežne zapise prikupljene pri vožnji vlakom, a tablica 5.9 prikazuje rezultate KS testa za iste zapise.

Tablica 5.8 *Procijenjeni parametri raspodjela za 3G mrežne zapise grupe Vlakovi.*

3G mrežni ispitni zapisi		Grupa Vlakovi				
		1	2	3	4	5
Gaussova raspodjela	μ	1123,83	1402,47	1393,67	1463,69	1406,75
	σ	945,76	807,09	960,18	1010,34	860,26
Nakagami raspodjela	m	0,4533	0,7129	0,5714	0,5160	0,6783
	ω	$2{,}16 \cdot 10^6$	$2{,}62 \cdot 10^6$	$2{,}86 \cdot 10^6$	$3{,}16 \cdot 10^6$	$2{,}72 \cdot 10^6$
Gamma raspodjela	β	886,71	723,99	886,32	1092,98	747,62
	γ	1,2674	1,9372	1,5724	1,3392	1,8816
Weibull raspodjela	β	1,1789	1,6650	1,4049	1,3096	1,5877
	λ	1187,40	1551,47	1517,94	1571,72	1555,08
Rician raspodjela	s	45,54	117,99	62,58	99,29	124,14
	σ	1038,10	1141,18	1195,95	1255,85	1163,01

Tablica 5.9 *Rezultati Kolmogorov-Smirnov testa za 3G mrežne zapise grupe Vlakovi.*

3G mrežni ispitni zapisi		Grupa Vlakovi				
		1	2	3	4	5
Gaussova raspodjela	H	1	1	1	1	1
	p	0,0000	0,0006	0,0000	0,0000	0,0000
Nakagami raspodjela	H	1	1	1	1	0
	p	0,0320	0,0000	0,0000	0,0000	0,0740
Gamma raspodjela	H	0	1	1	1	1
	p	0,0569	0,0000	0,0000	0,0000	0,0000
Weibull raspodjela	H	0	1	1	1	0
	p	0,3425	0,0000	0,0000	0,0000	0,1717
Rician raspodjela	H	1	1	1	1	1
	p	0,0000	0,0000	0,0000	0,0000	0,0000

Kolmogorov-Smirnov test pokazuje da zapise iz grupe Vlakovi većinom ne mogu dobro modelirati razmatrane teorijske raspodjele.

Za zapis 1, Gaussova raspodjela je odbačena, što sugerira značajnu varijabilnost podataka. Međutim, Gamma i Weibull raspodjele nisu odbačene, što sugerira da su ove raspodjele adekvatne za modeliranje ovog skupa podataka.

Za zapis 5 (slika 5.7), samo su Nakagami i Weibull raspodjele dobro prilagođene za modeliranje ovog skupa podataka p-vrijednostima 0,0740 i 0,1717.

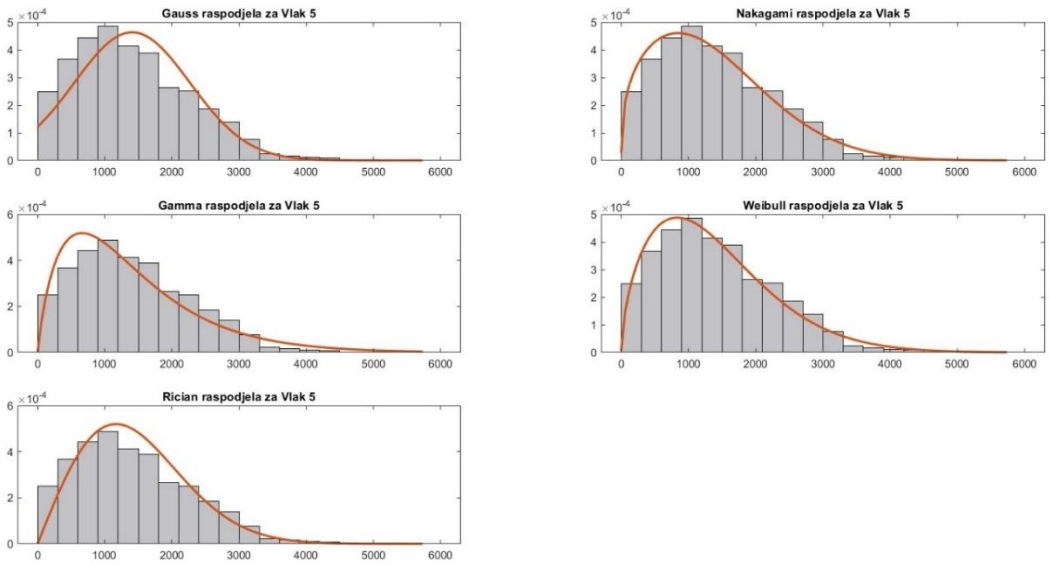

Slika 5.7 *Histogram za zapis Vlak 5 (3G mreža) i grafovi prilagođenih raspodjela.*

Kolmogorov-Smirnov (KS) test je korišten za ocjenu prikladnosti različitih statističkih raspodjela (Gaussove, Nakagami, Gamma, Weibull, Rician) za 3G mrežne ispitne zapise prikupljene iz različitih vozila (automobili, autobusi, tramvaji, vlakovi). Na temelju rezultata, mogu se donijeti sljedeći zaključci:

- Gaussova raspodjela – skupovi podataka vozila pokazuju značajno odstupanje od Gaussove raspodjele, osim u nekoliko rijetkih slučajeva (4 od ukupno 24). Niske p-vrijednosti za većinu ispitivanja ukazuju na to da raspodjela ne može adekvatno opisati varijacije u 3G mrežnim ispitnim zapisima.
- Nakagami raspodjela – u nekoliko slučajeva (6 od ukupno 24), osobito za određena ispitivanja u grupama Autobusi i Vlakovi, pokazala se kao dobar model (npr. ispitivanje 5 za vlak). Međutim, u većini slučajeva, rezultati pokazuju da raspodjela nije pogodna za modeliranje izmjerenih propusnosti.
- Gamma raspodjela – ova je raspodjela imala nekoliko dobrih prilagodbi (5 od ukupno 24), osobito za ispitivanja u grupama Autobusi i Vlakovi, međutim rezultati su pokazali da Gamma raspodjela ne može biti odgovarajući model za većinu skupova podataka.
- Weibull raspodjela – pokazala je dobru prilagodbu za najveći broj ispitivanja u usporedbi s ostalim raspodjelama (9 od ukupno 24), osobito u grupama Autobusi i Tramvaji.
- Rician raspodjela – za 8 od 24 skupova podataka, osobito za određena ispitivanja u grupi Autobusi, Rician raspodjela se pokazala kao dobar model. Međutim, sva ispitivanja u vlaku pokazuje značajno odstupanje od Rician raspodjele.

Prema KS testu niti jedna raspodjela nije se pokazala kao dobar model za podatke o propusnosti za 3G mrežne zapise. Pri tome je najbolja Weibull raspodjela koja je prošla KS test za 9 od ukupno 24 zapisa, što je 37,5 % zapisa. Nešto bolji rezultat je postigla ako se gledaju samo zapisi za mjerena u grupi Autobusi (4 od ukupno 6 ili 67 %), što je rezultat koji je postigla i Rician raspodjela za tu kategoriju zapisa.

5.2. 4G skup podataka

Statistička analiza izmjerenih mrežnih ispitnih zapisa 4G mreže izvršena je na skupu podataka od ukupno 24 mrežnih ispitnih zapisa nastalih mjerenjem propusnosti u stvarnim mrežnim uvjetima u Gentu (Belgija) u siječnju i veljači 2016. godine. Više ruta unutar ovog grada korišteno je kako bi se osigurao reprezentativan uzorak različitih mrežnih uvjeta u različitim vremenskim razdobljima kako bi se obuhvatile promjene u mrežnim uvjetima tijekom dana.

Također je korišteno nekoliko vrsta prijevoza, kao što su bicikl, automobil, autobus, tramvaj, vlak te su napravljeni i mrežni ispitni zapisi za pješake. Korišten je pametni telefon povezan na 4G mrežu, uz korištenje namjenskog poslužitelja za minimaliziranje smetnji žičane mreže, [19].

Tablica 5.10 prikazuje prosječnu propusnost i standardnu devijaciju propusnosti za 4G mrežnih ispitnih zapisa, čije su vrijednosti izračunate pomoću formula (5-1) i (5-2).

Iz podataka u tablici 5.10 vidljivo je da propusnost u 4G mrežama značajno varira ovisno o vrsti prijevoza, ali i za različite zapise za istu vrstu prijevoza:

- Grupa Pješaci – imala je najmanju prosječnu propusnost od $17\,542{,}48\ kbps$ (zapis Pješak 2), dok je najveća prosječna propusnost iznosila $41\,564{,}30\ kbps$ (zapis Pješak 1). Standardna devijacija varirala je između $5\,630{,}18\ kbps$ (zapis Pješak 4) i $13\,378{,}77\ kbps$ (zapis Pješak 1), što ukazuje na značajnu promjenu u stabilnosti mreže pri kretanju.
- Grupa Bicikli – najmanja prosječna propusnost iznosila je $25\,441{,}10\ kbps$ (zapis Bicikl 2), dok je najveća bila $31\,565{,}72\ kbps$ (zapis Bicikl 1). Standardna devijacija kretala se od $12\,562{,}79\ kbps$ (zapis Bicikl 1) do $16\,528{,}26\ kbps$ (zapis Bicikl 2), što ukazuje na nešto veće varijacije propusnosti u odnosu na grupu Pješaci.
- Grupa Automobili – imala je najmanju prosječnu propusnost od $28\,838{,}54\ kbps$ (zapis Automobil 4) i najveću od $36\,905{,}18\ kbps$ (zapis Automobil 5). Standardna devijacija varirala je između $12\,299{,}99\ kbps$ (zapis Automobil 5) i $21\,755{,}30\ kbps$ (zapis Automobil 1), puno veća vrijednost nego kod grupa Pješaci i Bicikli što se može objasniti većom brzinom automobila, a time i bržim promjenama uvjeta propagacije.
- Grupa Autobusi – prosječne propusnosti bile su vrlo promjenjive, s najnižom vrijednošću od $3\,729{,}29\ kbps$ (zapis Autobus 2) do najviše od $59\ 524{,}80\ kbps$ (zapis Autobus 4). Standardna devijacija bila je također vrlo raznolika, krećući se od $10\,354{,}30\ kbps$ (zapis Autobus 1) do $27\,278{,}81\ kbps$ (zapis Autobus 4).
- Grupa Tramvaji – imala je najmanju prosječnu propusnost od $14\,053{,}39\ kbps$ (zapis Tramvaj 2) i najveću od $45\,875{,}65\ kbps$ (zapis Tramvaj 4). Standardna devijacija kretala se od $10\,966{,}82\ kbps$ (zapis Tramvaj 3) do $15\,950{,}72\ kbps$ (zapis Tramvaj 1).
- Grupa Vlakovi – prosječne propusnosti bile su između $21\,261{,}63\ kbps$ (zapis Vlak 3) i $24\,006{,}76\ kbps$ (zapis Vlak 2). Standardna devijacija varirala je između $13\,878.98\ kbps$ (zapis Vlak 1) i $15\,591{,}85\ kbps$ (zapis Vlak 3).

U prilogu 2 dani su histogrami svih mrežnih zapisa propusnosti za 4G mrežu.

Tablica 5.10 *Prosječna propusnost i standardna devijacija propusnosti 4G ispitnih zapisa.*

4G mrežni ispitni zapisi	Prosječna propusnost $[kbps]$	Standardna devijacija propusnosti $[kbps]$
Pješak 1	41564,30	13378,77
Pješak 2	17542,48	12141,04
Pješak 3	31670,87	13044,98
Pješak 4	17814,40	5630,18
Bicikl 1	31565,72	12562,79
Bicikl 2	25441,10	16528,26
Automobil 1	35758,33	21755,30
Automobil 2	29618,13	13877,73
Automobil 3	33858,02	15281,44
Automobil 4	28838,54	14197,36
Automobil 5	36905,18	12299,99
Autobus 1	27601,53	10354,30
Autobus 2	3729,29	13462,11
Autobus 3	19693,08	11164,11
Autobus 4	59524,80	27278,81
Autobus 5	40469,38	16261,23
Tramvaj 1	21630,48	15950,72
Tramvaj 2	14053,39	11486,44
Tramvaj 3	35524,72	10966,82
Tramvaj 4	45875,65	14974,25
Tramvaj 5	37931,99	13846,00
Vlak 1	23082,73	13878,98
Vlak 2	24006,76	15056,12
Vlak 3	21261,63	14591,85

Kako bi se mogli detaljnije analizirati i usporediti 4G mrežni ispitni zapisi s 3G mrežnim ispitnim zapisima, izračunati su parametri teorijskih raspodjela (Gaussova, Nakagami, Gamma, Weibull, Rician) te je proveden Kolmogorov-Smirnovljev test.

U tablici 5.11 prikazani su procijenjeni parametri teorijskih raspodjela za 4G mrežne zapise prikupljene za grupu Pješaci, a tablica 5.12 prikazuje rezultate KS testa za iste zapise.

Tablica 5.11 *Procijenjeni parametri raspodjela za 4G mrežne zapise grupe Pješaci.*

4G mrežni ispitni zapisi		Grupa Pješaci 1	2	3	4
Gaussova raspodjela	μ	41564,30	17542,48	31670,87	17814,40
	σ	13395,40	12150,86	13057,33	5642,84
Nakagami raspodjela	m	2,3999	0,6399	1,4082	2,3510
	ω	$1{,}91 \cdot 10^9$	$0{,}46 \cdot 10^9$	$1{,}19 \cdot 10^9$	$0{,}35 \cdot 10^9$
Gamma raspodjela	β	5051,20	9580,86	7845,96	2394,53
	γ	8,2286	1,8641	4,0986	7,4732
Weibull raspodjela	β	3,5304	1,4937	2,7141	3,5633
	λ	46269,03	19764,86	35856,30	19773,27
Rician raspodjela	s	38966,46	223,93	28824,09	16886,75
	σ	13931,95	15220,63	13424,00	5721,09

Tablica 5.12 *Rezultati Kolmogorov-Smirnov testa za 4G mrežne zapise grupe Pješaci.*

4G mrežni ispitni zapisi		Grupa Pješaci 1	2	3	4
Gaussova raspodjela	H	1	1	0	0
	p	0,0003	0,0010	0,2041	0,1107
Nakagami raspodjela	H	1	0	1	1
	p	0,0004	0,0567	0,0001	0,0046
Gamma raspodjela	H	1	1	1	1
	p	0,0007	0,0368	0,0000	0,0003
Weibull raspodjela	H	1	1	1	0
	p	0,0004	0,0259	0,0254	0,0696
Rician raspodjela	H	1	1	0	0
	p	0,0003	0,0000	0,1812	0,1275

Analiza procijenjenih parametara teorijskih raspodjela za 4G mrežne zapise prikupljene tijekom kretanja pješaka, zajedno s rezultatima Kolmogorov-Smirnov (KS) testa, otkriva koji su modeli prikladni za različite skupove podataka.

Za zapis 2, Gaussova raspodjela s p-vrijednošću od 0,0010 je odbačena, što sugerira da ona nije prikladna za modeliranje ovog zapisa te isto vrijedi za Gamma, Weibull i Rician raspodjele, budući da su im p-vrijednosti ispod 0,05. No, Nakagami raspodjela nije odbačena s

p-vrijednošću 0,0567, što znači da je prikladna za modeliranje ovog zapisa, iako je na granici prihvatljivosti.

Za zapis 3 (slika 5.8), Gaussova raspodjela nije odbačena s p-vrijednošću 0,2041 te isto vrijedi i za Rician raspodjelu s p-vrijednošću od 0,1812, što sugerira da su prikladne za modeliranje ovog zapisa.

Za zapis 4, Gaussova, Weibull i Rician raspodjele s p-vrijednošću 0,1107, 0,0696 i 0,1275 nisu odbačene, što znači da su prikladne za modeliranje ovog skupa podataka.

Ovi rezultati ukazuju na to da 4G mrežni zapisi za grupu Pješaci pokazuju varijabilnost i složenost koja zahtijeva pažljiv odabir statističkih modela za adekvatno modeliranje.

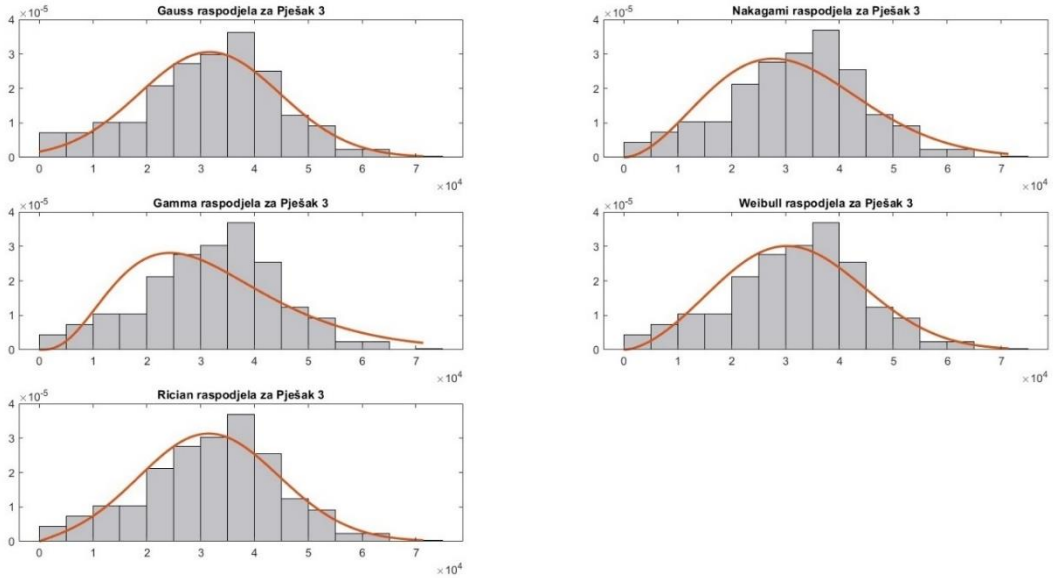

Slika 5.8 *Histogram za zapis Pješak 3 (4G mreža) i grafovi prilagođenih raspodjela.*

U tablici 5.13 prikazani su procijenjeni parametri teorijskih raspodjela za 4G mrežne zapise prikupljene pri vožnji biciklom, a tablica 5.14 prikazuje rezultate KS testa za iste zapise.

Tablica 5.13 *Procijenjeni parametri raspodjela za 4G mrežne zapise grupe Bicikli.*

4G mrežni ispitni zapisi		Grupa Bicikli 1	Grupa Bicikli 2
Gaussova raspodjela	μ	31565,72	25441,10
	σ	12574,64	16540,84
Nakagami raspodjela	m	1,6017	0,7161
	ω	$1{,}15 \cdot 10^9$	$0{,}94 \cdot 10^9$
Gamma raspodjela	β	6013,36	12376,36
	γ	5,2493	2,1036
Weibull raspodjela	β	2,7481	1,6187
	λ	35503,67	29020,59
Rician raspodjela	s	27868,96	810,46
	σ	13739,35	21694,11

Tablica 5.14 *Rezultati Kolmogorov-Smirnov testa za 4G mrežne zapise grupe Bicikli.*

4G mrežni ispitni zapisi		Grupa Bicikli 1	Grupa Bicikli 2
Gaussova raspodjela	H	0	1
	p	0,2702	0,0021
Nakagami raspodjela	H	0	0
	p	0,3143	0,2709
Gamma raspodjela	H	0	0
	p	0,1179	0,1672
Weibull raspodjela	H	0	0
	p	0,3852	0,3506
Rician raspodjela	H	0	1
	p	0,3567	0,0007

Za zapis 1 (slika 5.9), Gaussova raspodjela nije odbačena, p-vrijednost 0,2702, što znači da Gaussova raspodjela može biti prikladna za modeliranje ovog zapisa. Nakagami, Gamma, Weibull i Rician raspodjele su također prihvaćene prema KS testu, s tim da je od njih najprikladnija Weibull raspodjela s p-vrijednošću od 0,3852.

Za zapis 2, Gaussova i Rician raspodjela su odbačene s p-vrijednostima 0,0021 i 0,0007 te nisu prikladne za modeliranje ovog skupa podataka. Dok su Nakagami, Gamma i Weibull raspodjele prihvaćene prema KS testu s p-vrijednostima iznad 0,05, što znači da su prikladne za

modeliranje ovog skupa podataka. No, Weibull raspodjela i ovdje postiže najvišu p-vrijednost 0,3506, sugerirajući da je ovaj model vrlo prikladan.

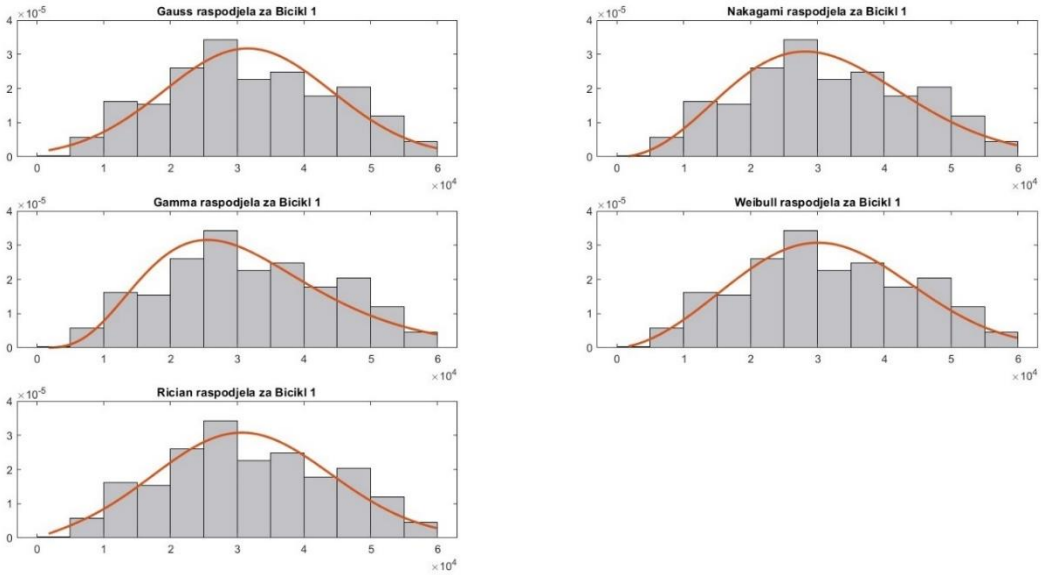

Slika 5.9 *Histogram za zapis Bicikl 1 (4G mreža) i grafovi prilagođenih raspodjela.*

U tablici 5.15 prikazani su procijenjeni parametri teorijskih raspodjela za 4G mrežne zapise prikupljene pri vožnji automobilom, a tablica 5.16 prikazuje rezultate KS testa za iste zapise.

Tablica 5.15 *Procijenjeni parametri raspodjela za 4G mrežne zapise grupe Automobili.*

4G mrežni ispitni zapisi		Grupa Automobili				
		1	2	3	4	5
Gaussova raspodjela	μ	35758,33	29618,13	33858,02	28838,54	36905,18
	σ	21778,58	13890,00	15296,90	14209,59	12313,56
Nakagami raspodjela	m	0,7272	1,1941	1,3163	1,2054	2,2290
	ω	$1{,}79 \cdot 10$ˇ9	$1{,}07 \cdot 10^9$	$1{,}39 \cdot 10^9$	$1{,}04 \cdot 10^9$	$1{,}51 \cdot 10^9$
Gamma raspodjela	β	18146,38	7942,11	7994,06	7339,30	4890,99
	γ	2,0180	3,7425	4,2526	3,9703	7,5456
Weibull raspodjela	β	1,6763	2,2795	2,3629	2,2260	3,3659
	λ	40655,26	33520,27	38311,04	32972,87	41148,10
Rician raspodjela	s	5089,16	23169,87	27650,14	20236,97	34380,15
	σ	25576,67	16382,66	17620,38	17811,18	12869,87

Tablica 5.16 *Rezultati Kolmogorov-Smirnov testa za 4G mrežne zapise grupe Automobili.*

4G mrežni ispitni zapisi		Grupa Automobili				
		1	2	3	4	5
Gaussova raspodjela	H	1	0	1	1	1
	p	0,0038	0,0560	0,0000	0,0000	0,0062
Nakagami raspodjela	H	1	0	1	1	1
	p	0,0000	0,5847	0,0068	0,0000	0,0186
Gamma raspodjela	H	1	0	1	1	1
	p	0,0000	0,1356	0,0106	0,0054	0,0235
Weibull raspodjela	H	1	0	1	1	1
	p	0,0000	0,4990	0,0020	0,0000	0,0078
Rician raspodjela	H	1	0	1	1	1
	p	0,0000	0,4879	0,0005	0,0001	0,0078

Za zapis 2, sve teorijske raspodjele su prema rezultatima KS testa prihvaćene za modeliranje ovog skupa podataka. Sve raspodjele imaju p-vrijednost veću od 0,05, s tim da Nakagami raspodjela ima najveću p-vrijednost 0,5847, što sugerira da je posebno prikladna za modeliranje ovog zapisa.

Za zapis 4 (slika 5.10), sve teorijske raspodjele su odbačene, što znači da niti jedna raspodjela nije prikladna za modeliranje ovog skupa podataka. Histogram za zapis Automobil 4 dodatno potvrđuje da niti jedna raspodjela nije povoljna za modeliranje tog zapisa.

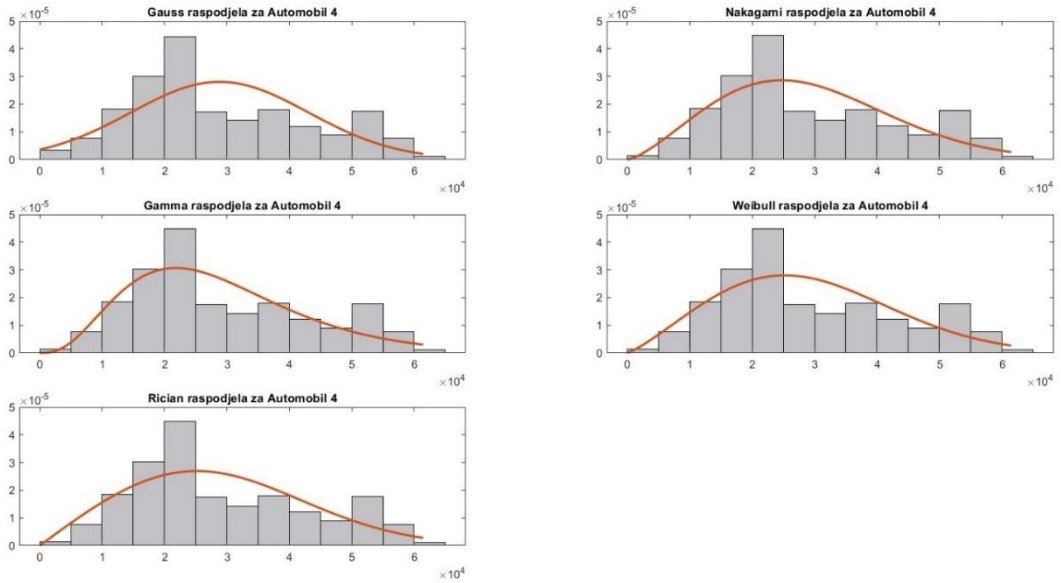

Slika 5.10 *Histogram za zapis Automobil 4 (4G mreža) i grafovi prilagođenih raspodjela.*

U tablici 5.17 prikazani su procijenjeni parametri teorijskih raspodjela za 4G mrežne zapise prikupljene pri vožnji autobusom, a tablica 5.18 prikazuje rezultate KS testa za iste zapise.

Tablica 5.17 *Procijenjeni parametri raspodjela za 4G mrežne zapise grupe Autobusi.*

4G mrežni ispitni zapisi		Grupa Autobusi 1	2	3	4	5
Gaussova raspodjela	μ	27601,53	30729,29	19693,08	59524,80	40469,38
	σ	10354,30	13474,46	11171,48	27427,66	16285,34
Nakagami raspodjela	m	1,8290	1,2818	0,8517	1,3690	1,5991
	ω	$0{,}87 \cdot 10^9$	$1{,}13 \cdot 10^9$	$0{,}52 \cdot 10^9$	$4{,}31 \cdot 10^9$	$1{,}91 \cdot 10^9$
Gamma raspodjela	β	4465,89	8017,91	8216,66	12660,23	7904,52
	γ	6,1805	3,8609	2,4517	4,7185	5,1503
Weibull raspodjela	β	2,9055	2,5248	1,8472	2,3955	2,8334
	λ	30968,10	34759,43	22502,71	67746,79	45766,64
Rician raspodjela	s	24917,61	26400,10	344,25	45776,66	6151,25
	σ	11108,69	14779,37	16187,98	33262,25	17415,63

Tablica 5.18 *Rezultati Kolmogorov-Smirnov testa za 4G mrežne zapise grupe Autobusi.*

4G mrežni ispitni zapisi		Grupa Autobusi 1	2	3	4	5
Gaussova raspodjela	H	0	1	0	1	1
	p	0,4775	0,0115	0,1219	0,0000	0,0000
Nakagami raspodjela	H	0	1	1	1	1
	p	0,5109	0,0001	0,0100	0,0000	0,0000
Gamma raspodjela	H	1	1	1	1	1
	p	0,0386	0,0000	0,0000	0,0000	0,0000
Weibull raspodjela	H	0	1	1	1	1
	p	0,9163	0,0009	0,0124	0,0000	0,0000
Rician raspodjela	H	0	1	0	1	1
	p	0,8687	0,0039	0,2574	0,0000	0,0000

Za zapis 1 (slika 5.11), sve teorijske raspodjele su prihvaćene osim Gamma raspodjele s obzirom na to da je p-vrijednost manja od 0,05. Najprikladnija raspodjela za modeliranje ovog zapisa je Weibull raspodjela s p-vrijednošću od 0,9163.

Za zapise 2, 4 i 5 niti jedna od raspodjela nije prikladna za njihovo modeliranje, budući da je p-vrijednost svake od teorijskih raspodjela manja od 0,05.

Za zapis 3, Gaussova i Rician raspodjela su prihvaćene za modeliranje ovog skupa podataka s p-vrijednostima 0,1219 i 0,2574.

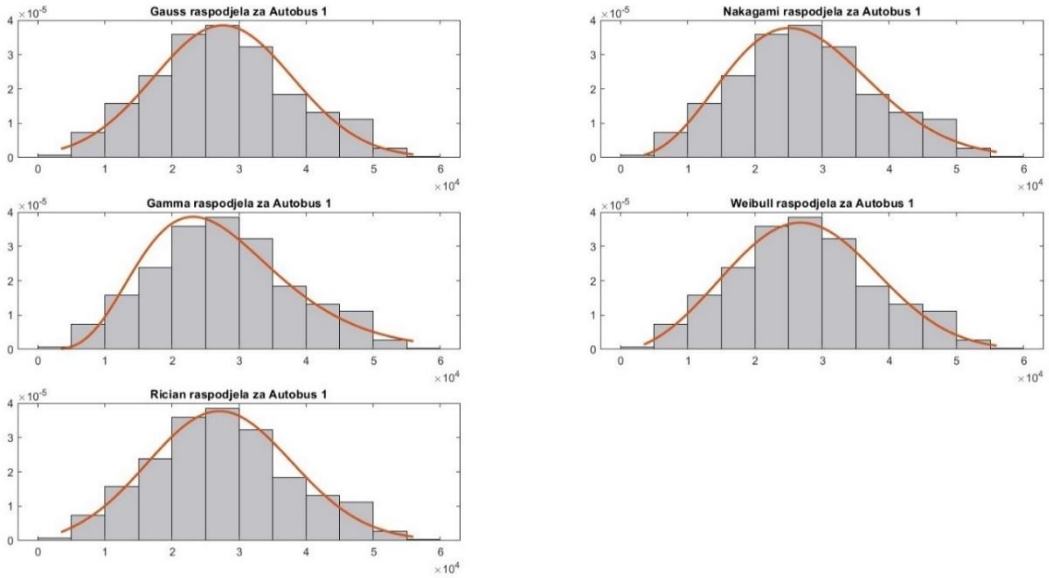

Slika 5.11 *Histogram za zapis Autobus 1 (4G mreža) i grafovi prilagođenih raspodjela.*

U tablici 5.19 prikazani su procijenjeni parametri teorijskih raspodjela za 4G mrežne zapise prikupljene pri vožnji tramvajem, a tablica 5.20 prikazuje rezultate KS testa za iste zapise.

Tablica 5.19 *Procijenjeni parametri raspodjela za 4G mrežne zapise grupe Tramvaji.*

4G mrežni ispitni zapisi		Grupa Tramvaji				
		1	2	3	4	5
Gaussova raspodjela	μ	21630,48	14053,39	35524,72	45875,66	37931,99
	σ	15964,68	11495,47	10978,45	14994,80	13861,69
Nakagami raspodjela	m	0,5416	0,5364	2,5611	2,2023	1,6630
	ω	$0{,}72 \cdot 10^9$	$0{,}35 \cdot 10^9$	$1{,}39 \cdot 10^9$	$2{,}34 \cdot 10^9$	$1{,}64 \cdot 10^9$
Gamma raspodjela	β	14175,67	9852,68	4397,17	6534,30	7715,79
	γ	1,5259	1,5234	8,1480	7,0400	4,9385
Weibull raspodjela	β	1,3188	1,3245	3,7490	3,6170	3,0134
	λ	23497,05	16273,72	39467,72	51058,57	42371,09
Rician raspodjela	s	304,54	250,08	34052,42	43138,88	34988,25
	σ	19002,88	13262,92	10828,76	15398,68	14383,71

Tablica 5.20 *Rezultati Kolmogorov-Smirnov testa za 4G mrežne zapise grupe Tramvaji.*

4G mrežni ispitni zapisi		Grupa Tramvaji				
		1	2	3	4	5
Gaussova raspodjela	H	1	1	1	1	1
	p	0,0000	0,0000	0,0011	0,0000	0,0273
Nakagami raspodjela	H	1	0	1	1	1
	p	0,0000	0,1945	0,0000	0,0000	0,0142
Gamma raspodjela	H	1	0	1	1	1
	p	0,0000	0,5324	0,0000	0,0000	0,0003
Weibull raspodjela	H	1	0	1	1	1
	p	0,0000	0,7989	0,0016	0,0000	0,0288
Rician raspodjela	H	1	1	1	1	1
	p	0,0000	0,0000	0,0039	0,0000	0,0262

Za zapis 2 (slika 5.12), Gaussova raspodjela je odbačena s p-vrijednošću 0,0000, zbog izrazite asimetričnosti histograma, ali ni Rician raspodjela nije uspjela dobro modelirati podatke. Ostale teorijske raspodjele su prikladne za modeliranje, od kojih je najprikladnija Weibull raspodjela s p-vrijednošću od 0,5325.

Za zapis 5, niti jedna od raspodjela nije prikladan za modeliranje ovog skupa podatka, budući da su im p-vrijednosti manje od 0,05. Weibull raspodjela je pri tome najbliža, s p-vrijednošću jednakom 0,0288.

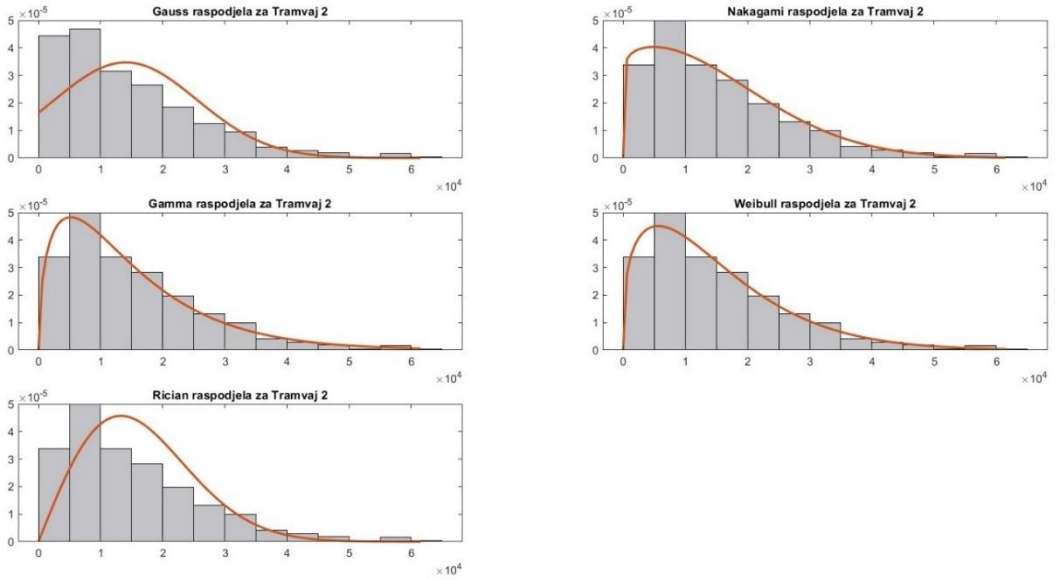

Slika 5.12 *Histogram za zapis Tramvaj 2 (4G mreža) i grafovi prilagođenih raspodjela.*

U tablici 5.21 prikazani su procijenjeni parametri teorijskih raspodjela za 4G mrežne zapise prikupljene pri vožnji vlakom, a tablica 5.22 prikazuje rezultate KS testa za iste zapise.

Tablica 5.21 *Procijenjeni parametri raspodjela za 4G mrežne zapise grupe Vlakovi.*

4G mrežni ispitni zapisi		Grupa Vlakovi 1	2	3
Gaussova raspodjela	μ	23082,73	24006,76	21261,63
	σ	13892,72	15071,32	14605,59
Nakagami raspodjela	m	0,7128	0,8197	0,5669
	ω	$0{,}75 \cdot 10^9$	$0{,}83 \cdot 10^9$	$0{,}70 \cdot 10^9$
Gamma raspodjela	β	12368,56	9912,72	15372,27
	γ	1,9193	2,5078	1,4542
Weibull raspodjela	β	1,6752	1,7544	1,4212
	λ	26282,53	27904,27	24220,14
Rician raspodjela	s	14218,49	335,45	243,62
	σ	16497,11	20388,89	18696,20

Tablica 5.22 *Rezultati Kolmogorov-Smirnov testa za 4G mrežne zapise grupe Vlakovi.*

4G mrežni ispitni zapisi		Grupa Vlakovi 1	2	3
Gaussova raspodjela	H	0	1	1
	p	0,1824	0,0011	0,0068
Nakagami raspodjela	H	1	0	1
	p	0,0293	0,1474	0,0029
Gamma raspodjela	H	1	0	1
	p	0,0002	0,2007	0,0000
Weibull raspodjela	H	1	0	1
	p	0,0277	0,3199	0,0060
Rician raspodjela	H	1	1	1
	p	0,0012	0,0137	0,0035

Za zapis 1, sve teorijske raspodjele su odbačene osim Gaussove raspodjele, čija je p-vrijednost 0,1824.

Za zapis 2 (slika 5.13), Gaussova i Rician raspodjele su odbačene s p-vrijednošću manjom od 0,05. Sve ostale teorijske raspodjele su prihvaćene za modeliranje ovog skupa podataka, najprikladnija raspodjela je Weibull s p-vrijednošću od 0,3199.

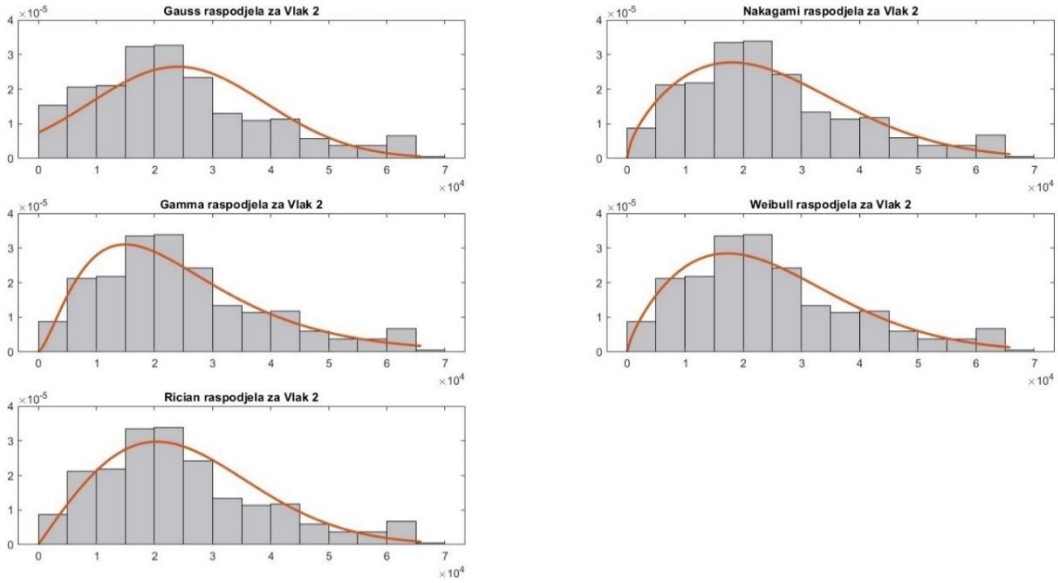

Slika 5.13 *Histogram za zapis Vlak 2 (4G mreža) i grafovi prilagođenih raspodjela.*

Kolmogorov-Smirnov test je korišten za ocjenu prikladnosti različitih statističkih raspodjela (Gaussova, Nakagami, Gamma, Weibull, Rician) za 4G mrežne ispitne zapise prikupljene uz korištenje različitih načina prijevoza (pješaci, bicikli, automobili, autobusi, tramvaji, vlakovi). Na temelju rezultata, mogu se donijeti sljedeći zaključci:

- Gaussova raspodjela – za razliku od podataka izmjerenih u 3G mreži, za skupove podataka izmjerenih u 4G mreži Gaussova se raspodjela pokazala jednako uspješnim modelom kao i Nakagami i Weibull raspodjele, odnosno kao jedna od tri najpogodnije raspodjele za modeliranje podataka. Prema KS testu ova raspodjela je dobar model za 7 od 24 ispitna zapisa.
- Nakagami raspodjela – Prema KS testu ova raspodjela je dobar model za 7 od 24 ispitna zapisa.
- Gamma raspodjela – Prema KS testu ova raspodjela je dobar model za 5 od 24 ispitna zapisa.
- Weibull raspodjela – Prema KS testu ova raspodjela je dobar model za 7 od 24 ispitna zapisa, pri čemu je u većini slučajeva imala najveću vrijednost p parametra što ukazuje na veću pouzdanost KS testa.
- Rician raspodjela – Prema KS testu ova raspodjela je dobar model za 6 od 24 ispitna zapisa.

Niti jedna raspodjela se nije pokazala kao dobar izbor za modeliranje svih mrežnih zapisa za 4G mrežu. Čak i najbolje raspodjele prema broju zapisa koje mogu modelirati (Gaussova, Nakagami i Weibull), dobar su model za svega 29% zapisa (7 od ukupno 24).

5.3. Analiza Weibull raspodjele za 3G i 4G skupove podataka

Weibull raspodjela je prema rezultatima Kolmogorov-Smirnov testa identificirana kao jedna od najprikladnijih za modeliranje određenih mrežnih zapisa u 3G i 4G mrežama. U nastavku slijedi detaljna analiza raspona parametara za Weibull raspodjelu, s posebnim naglaskom na one zapise za koje je p-vrijednost bila najviša, odnosno gdje je $KS = 0$. Weibull raspodjela definirana je parametrom oblika β i parametrom skale λ.

Parametar β kontrolira oblik raspodjele te igra ključnu ulogu u određivanju oštrine vrha i duljine repova:

- Kada je $\beta < 1$, raspodjela je karakterizirana dugim lijevim repom, što znači da je velika vjerojatnost za pojavu manjih vrijednosti. Ova raspodjela često ima oblik padajuće krivulje s produženim desnim repom.
- Kada je $\beta = 1$, raspodjela postaje identična eksponencijalnoj raspodjeli, što rezultira krivuljom koja konstantno opada s malim vrhom.
- Kada je $\beta > 1$, raspodjela ima jasno izražen vrh, a što je β veća, raspodjela postaje više koncentrirana oko srednjih vrijednosti. Vrh postaje oštriji, a repovi kraći.

Parametar λ određuje širinu raspodjele i ponaša se kao faktor skaliranja. Veća vrijednost parametra skale rezultira širenjem krivulje duž osi x, zbog čega će raspodjela biti rastegnutija, dok će manja vrijednost parametra skale dovesti do užeg raspona. Kontrolira poziciju sredine krivulje, odnosno gdje je najveća koncentracija vjerojatnosti.

U tablici 5.23 prikazani su zapisi za 3G mrežu kod kojih je $KS = 0$, zajedno s pripadajućim vrijednostima parametara oblika i skale Weibull raspodjele.

Najveća vrijednost parametra oblika β zabilježena je kod zapisa Autobus 6 i iznosi 2,4480, dok je najmanja vrijednost parametra oblika β prisutna kod zapisa Vlak 1 i iznosi 1,1789. Najveća vrijednost parametra skale λ zabilježena je kod zapisa Autobus 2 i iznosi 2 938,08, a najmanja vrijednost parametra skale λ prisutna je kod zapisa Tramvaj 3 i iznosi 765,93 (slika 5.14).

Tablica 5.23 *Vrijednosti parametara Weibull raspodjele te p-vrijednosti za 3G mrežne zapise.*

3G mrežni ispitni zapisi	p-vrijednost	β	λ
Automobil 3	0,1226	1,9300	1992,61
Automobil 5	0,2252	2,1167	2126,38
Autobus 2	0,0802	2,3229	2938,08
Autobus 3	0,0967	2,1834	2061,45
Autobus 4	0,7769	1,9647	1936,24
Autobus 6	0,5840	2,4480	2843,39
Tramvaj 3	0,8291	1,9364	765,93
Vlak 1	0,3425	1,1789	1187,40
Vlak 5	0,1717	1,5877	1555,08

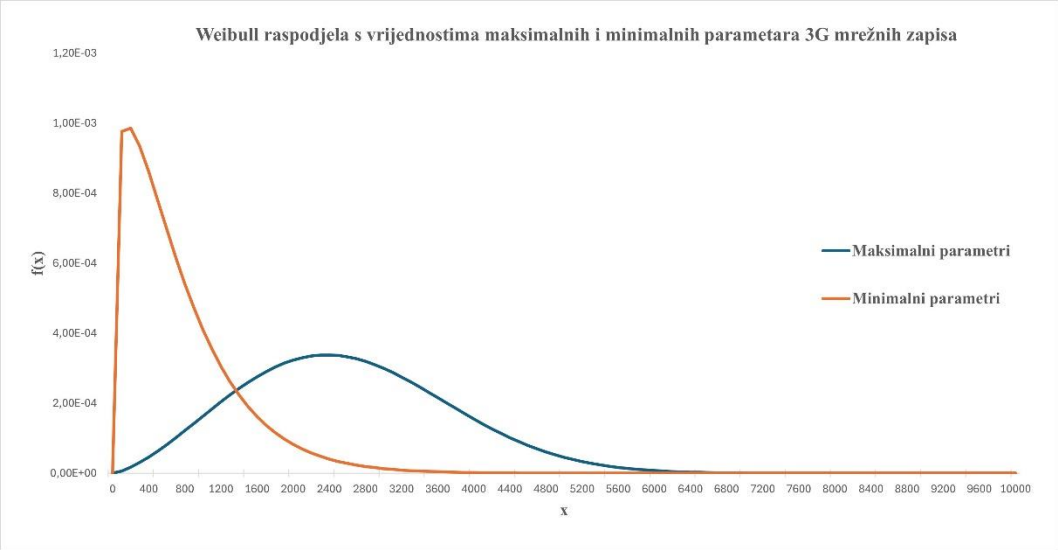

Slika 5.14 *Weibull raspodjela s vrijednostima maksimalnih* $\beta = 2{,}4480, \lambda = 2938{,}08$ *i minimalnih* $\beta = 1{,}1789, \lambda = 765{,}93$ *parametara 3G mrežnih zapisa.*

Za zapise 3G mreže, slučaj s najvećom vrijednošću parametra oblika pokazuje jasno definiran vrh, a zbog većeg parametra skale događa se širenje krivulje duž x osi. Najmanja vrijednost parametra oblika također pokazuje jasno definiran vrh budući da je $\beta > 1$. No, zbog manje vrijednosti parametra skale, krivulja je uža.

U tablici 5.24 prikazani su zapisi za 4G mrežu kod kojih je $KS = 0$, zajedno s pripadajućim vrijednostima parametara oblika i skale Weibull raspodjele.

Najveća vrijednost parametra oblika β zabilježena je kod zapisa Pješak 4 i iznosi 3,5633, dok je najmanja vrijednost parametra oblika β prisutna kod zapisa Tramvaj 2 i iznosi 1,3245. Najveća vrijednost parametra skale λ zabilježena je kod zapisa Bicikl 1 i iznosi 35 503,67, a najmanja vrijednost parametra skale λ prisutna je kod zapisa Tramvaj 2 i iznosi 16 273,72 (slika 5.15).

Tablica 5.24 *Vrijednosti parametara Weibull raspodjele te p-vrijednosti za 4G mrežne zapise.*

4G mrežni ispitni zapisi	p-vrijednost	β	λ
Pješak 4	0,0696	3,5633	19773,27
Bicikl 1	0,3852	2,7481	35503,67
Bicikl 2	0,3506	1,6187	29020,59
Automobil 2	0,4990	2,2795	33520,27
Autobus 1	0,9163	2,9055	30968,10
Tramvaj 2	0,7989	1,3245	16273,72
Vlak 2	0,3199	1,7544	27904,72

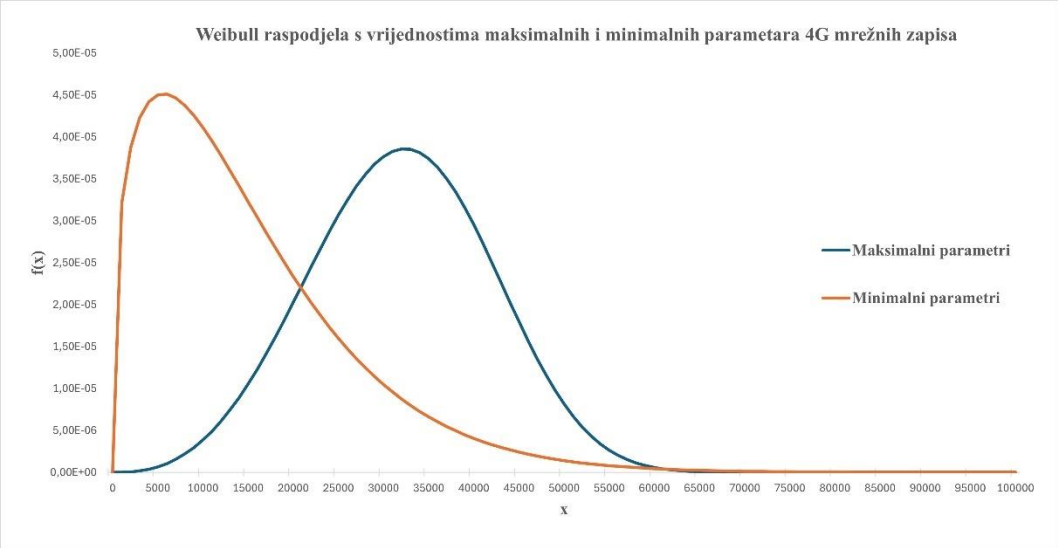

Slika 5.15 *Weibull raspodjela s vrijednostima maksimalnih* $\beta = 3{,}5633, \lambda = 35503{,}67$ *i minimalnih* $\beta = 1{,}3245, \lambda = 16273{,}72$ *parametara 4G mrežnih zapisa*

Za zapise 4G mreže, oba slučaja pokazuju jasno definiran vrh na krivuljama. Unatoč relativno visokom parametru skale, slučaj s manjom vrijednošću parametra oblika rezultira užom krivuljom.

6. ZAKLJUČAK

U ovom radu prikazano je kako prilagodljivo videostrujanje, posebno tehnologija MPEG DASH, predstavlja ključan element za postizanje visokokvalitetnog korisničkog iskustva u dinamičnim mrežnim uvjetima. MPEG DASH omogućuje glatku reprodukciju videozapisa putem prilagodbe kvalitete u stvarnom vremenu uzimajući u obzir promjene mrežne propusnosti i popunjenost međuspremnika. Analizirani su različiti faktori i algoritmi koji utječu na kvalitetu korisničkog iskustva uključujući početno kašnjenje, zastoje u reprodukciji i promjene razine kvalitete. Razvoj globalne MPEG DASH norme značajno je unaprijedio interoperabilnost i smanjio troškove razvoja aplikacija za videostrujanje. Iako su postignuti značajni pomaci, daljnja istraživanja i optimizacije algoritama za prilagodljivo videostrujanje ključni su za kontinuirano poboljšanje korisničkog iskustva i prilagodbu sve zahtjevnijim mrežnim uvjetima. Jedna od važnih pretpostavki za daljnja unaprjeđenja algoritama jest i dobro poznavanje mrežnih uvjeta te kvalitetno modeliranje propusnosti mreže.

U ovom je radu analizirana primjena teorijskih raspodjela u modeliranju propusnosti u različitim okruženjima. U analizi su korištene raspodjele koje se uobičajeno koriste u komunikacijama. Gaussova raspodjela, s jednostavnim parametrima srednje vrijednosti i standardne devijacije, često se koristi za modeliranje varijacija u mrežnim performansama pod normalnim uvjetima. Nakagami raspodjela je ključna za razumijevanje višestaznog slabljenja signala u mobilnim komunikacijama, dok Gamma raspodjela omogućuje modeliranje vremena između događaja i trajanja veza. Weibull raspodjela, s parametrima skale i oblika, često se koristi za analizu pouzdanosti komponenti i sustava, dok Rician raspodjela omogućuje modeliranje promjene amplitude signala u složenim okruženjima. Kroz detaljnu analizu ovih raspodjela, ovaj rad pruža temelj za daljnje istraživanje i primjenu statističkih metoda u optimizaciji videostrujanja i drugih aplikacija u 3G i 4G mrežama.

Na temelju provedenih Kolmogorov-Smirnov testova za ocjenu prikladnosti različitih statističkih raspodjela za 3G i 4G mrežne ispitne zapise može se zaključiti da su Nakagami, Gamma i Weibull raspodjele pokazale određeni potencijal za modeliranje specifičnih skupova podataka. Međutim, niti jedna od razmatranih raspodjela nije univerzalno prikladna za sve ispitne zapise. Gaussova i Rician raspodjela posebno su se pokazale neprikladnima. Može se zaključiti da će za modeliranje varijacija u 3G i 4G mrežnim ispitnim zapisima biti potrebno razmotriti kombinacije postojećih raspodjela.

LITERATURA

[1] J. Yao, S. Kanhere, I. Hossain i M. Hassan, "Empirical Evaluation of HTTP Adaptive Streaming under Vehicular Mobility," NETWORKING 2011: 10th International IFIP TC 6 Networking Conference, Valencia, Španjolska, sv. 1, str. 92-105, svibanj 2011.

[2] M. Seufert, S. Egger, M. Slanina, T. Zinner, T. Hoßfeld, P. Tran-Gia, "A Survey on Quality of Experience of HTTP Adaptive Streaming," IEEE Communications Surveys & Tutorials, br. 1, sv. 17, str. 469–492, rujan 2014.

[3] J. Vlaović, „Metoda za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje", Doktorska disertacija, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, 2022., https://dr.nsk.hr/islandora/object/etfos:3425., pristup 29. kolovoz 2024.

[4] L.-F. Huang, "The Nakagami and its related distributions," WSEAS Trans. Math, sv. 15, str. 477- 485, 2016.

[5] C. Qiao, G. Li, Q. Ma, J. Wang i Y. Liu, "Trace-Driven Optimization on Bitrate Adaptation for Mobile Video Streaming," IEEE Transactions on Mobile Computing, br. 21, sv. 6, str. 2243-2256, jun 2022.

[6] G. Lv, Q. Wu, Q. Tan, W. Wang, Z. Li and G. Xie, "Accurate Throughput Prediction for Improving QoE in Mobile Adaptive Streaming," IEEE Transactions on Mobile Computing, br. 23, sv. 5, str. 5799-5817, svibanj 2024.

[7] D. Raca, A. H. Zahran, C. J. Sreenan, R. K. Sinha, E. Halepovic i V. Gopalakrishnan, "Device-based Cellular Throughput Prediction for Video Streaming: Lessons from a RealWorld Evaluation," IEEE Transactions on Machine Learning in Communications and Networking, br. 2, str. 318-334, 2024.

[8] B. Wei, H. Song, S. Wang, K. Kanai i J. Katto, "Evaluation of throughput prediction for adaptive bitrate control using trace-based emulation," IEEE Access, br. 7, str. 51346-51356, 2019.

[9] S. Rimac-Drlje i J. Vlaović, "Network Throughputs Modelling for Mobile Video Streaming Analysis," u 2021 16th International Conference on Telecommunications (ConTEL), Zagreb, Hrvatska, 2021, str. 115-121.

[10] F. Falat, „Analiza parametara prilagodljivog mrežnog video strujanja“, završni rad, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, https://repozitorij.etfos.hr/islandora/object/etfos:3592., pristup 29. kolovoz 2024.

[11] K. Slovjak, "Web aplikacija za pregled video sadržaja na zahtjev s podrškom za prilagodljivo strujanje," završni rad, Fakultet elektrotehnike i računarstva Zagreb, lipanj 2016.

[12] I. Sodagar, „The MPEG-DASH Standard for Multimedia Streaming Over the Internet“, IEEE MultiMedia, br. 4, sv. 18, str. 62-67, studeni 2011.

[13] M. I. Ribeiro, "Gaussian probability density functions: Properties and error characterization," Institute for Systems and Robotics, tehničko izvješće, Lisabon, Portugal, veljača 2004.

[14] H. C. Thom, "A note on the gamma distribution," Monthly weather review, str. 117-122, 1958.

[15] C.-D. Lai, D. Murthy i M. Xie, "Weibull distributions and their applications," u Springer Handbooks, Springer, str. 63-78, 2006.

[16] K. K. Talukdar i W. D. Lawing, "Estimation of the parameters of the Rice distribution," the Journal of the Acoustical Society of America, str. 1193-1197, 1991.

[17] F. J. Massey Jr, "The Kolmogorov-Smirnov test for goodness of fit," Journal of the American statistical Association, br. 253, sv. 46, str. 68-78, 1951.

[18] H. Riiser, P. Vigmostad, C. Griwodz, P. Halvorsen, “Commute path bandwidth traces from 3G networks: analysis and applications”, 4th ACM Multimedia Systems Conference, str. 114–118, Oslo, 2013.

[19] J. van der Hooft, S. Petrangeli, T. Wauters, R. Huysegems, P. R. Alface, T. Bostoen, F. De Turck, "HTTP/2-Based Adaptive Streaming of HEVC Video Over 4G/LTE Networks", IEEE Communications Letters, br. 11, sv. 20, str. 2177-2180, kolovoz 2016.

SAŽETAK

U radu se opisuje prilagodljivo videostrujanje putem HTTP-a te MPEG DASH norma koja osigurava glatko videostrujanje s najvećom mogućom kvalitetom korisničkog iskustva. Rad se bavi analizom propusnosti 3G i 4G mreža za uslugu videostrujanja. Analizirano je pet statističkih raspodjela: Gaussova, Nakagami, Gamma, Weibull i Rician. Rezultati Kolmogorov-Smirnovog testa pokazali su da nijedna od ispitivanih raspodjela ne odgovara svim podacima. Ipak Nakagami, Gamma i Weibull su bolje prilagođene određenim skupovima podataka. Dodatno je analizirana Weibull raspodjela za 3G i 4G mrežne zapise kod kojih je Kolmogorov-Smirnov test istinit. Ova analiza pruža važan uvid u ponašanje propusnosti 3G i 4G mreža za usluge videostrujanja.

Ključne riječi: Prilagodljivo videostrujanje, MPEG DASH, QoE, Gaussova raspodjela, Nakagami raspodjela, Gamma raspodjela, Weibull raspodjela, Rician raspodjela

ABSTRACT

The paper describes adaptive video streaming via HTTP and the MPEG DASH standard, which ensures smooth video streaming with the highest possible quality of user experience. The paper deals with the analysis of the bandwidth of 3G and 4G networks for the video streaming service. Five statistical distributions were analyzed: Gaussian, Nakagami, Gamma, Weibull and Rician. The results of the Kolmogorov-Smirnov test showed that none of the examined distributions fit all the data. However, Nakagami, Gamma and Weibull are better adapted to certain data sets. Additionally, the Weibull distribution was analyzed for 3G and 4G network records where the Kolmogorov-Smirnov test is true. This analysis provides important insight into the bandwidth behavior of 3G and 4G networks for video streaming services.

Key words: Adaptive bitrate streaming, MPEG DASH, QoE, Gauss distribution, Nakagami distribution, Gamma distribution, Weibull distribution, Rician distribution

ŽIVOTOPIS

Marija Ivanić rođena je 20. svibnja 2003. godine u Novoj Biloj, Bosna i Hercegovina. Godine 2017. završava „Osnovnu školu Brestovsko“ u Brestovskom, Kiseljak te iste godine započinje srednjoškolsko obrazovanje u Visokom u „Franjevačkoj klasičnoj gimnaziji“. Tijekom školovanja sudjelovala je na raznim natjecanjima, među kojima je najuspješnije međunarodno natjecanje iz klasičnih jezika „Euroclassica“ na kojem je osvojila srebrenu medalju iz latinskog jezika razina Ianua te brončanu medalju iz starogrčkog jezika razina Vestibulum. Srednju školu završila je 2021. godine, nakon čega upisuje sveučilišni prijediplomski studij Elektrotehnike i informacijskih tehnologija, smjer Komunikacije i informatika na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija sveučilišta Josipa Jurja Strossmayera u Osijeku.

PRILOZI

Prilog P.1. Histogram 3G ispitnih zapisa

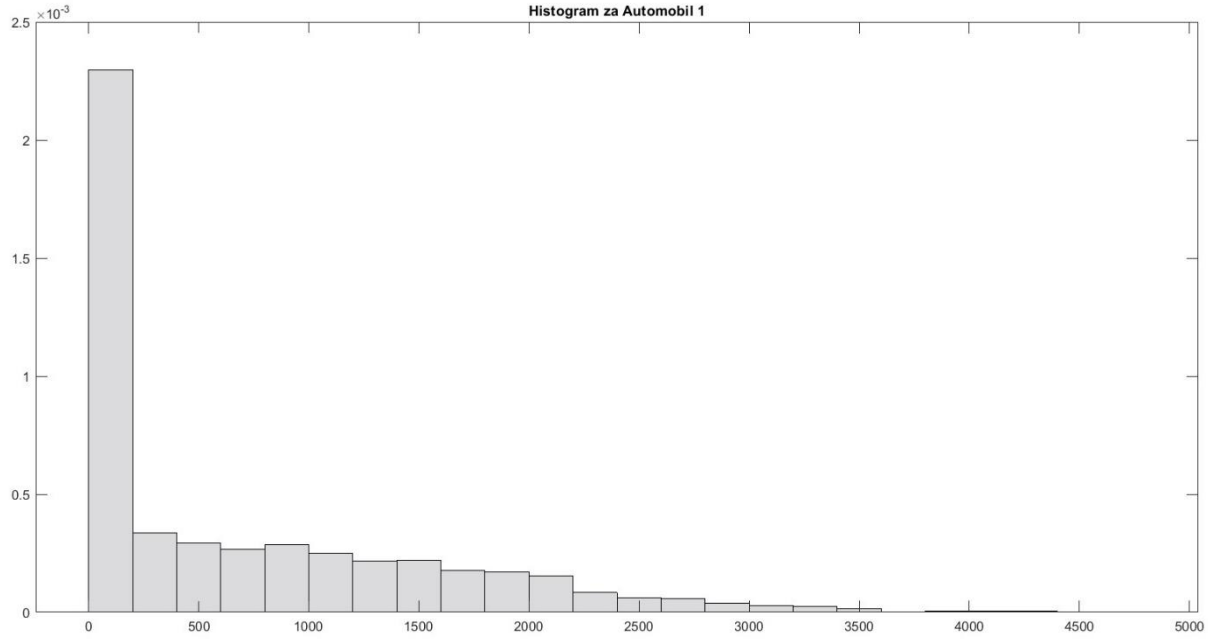

Slika P.1.1 *Histogram za zapis Automobil 1 (3G mreža).*

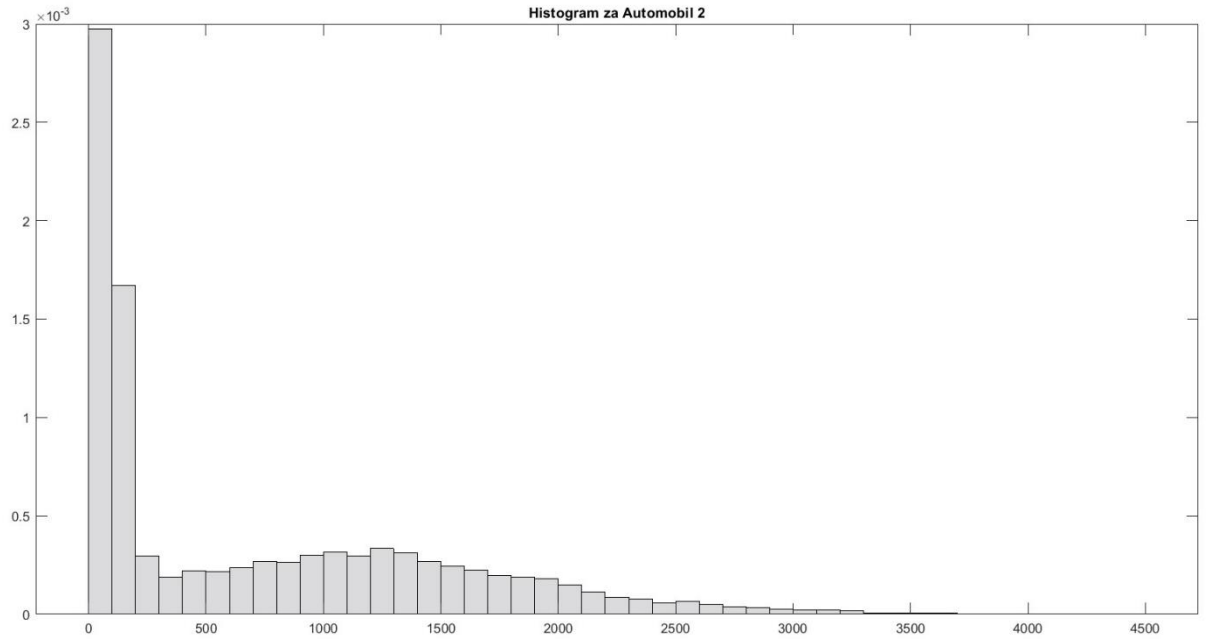

Slika P.1.2 *Histogram za zapis Automobil 2 (3G mreža).*

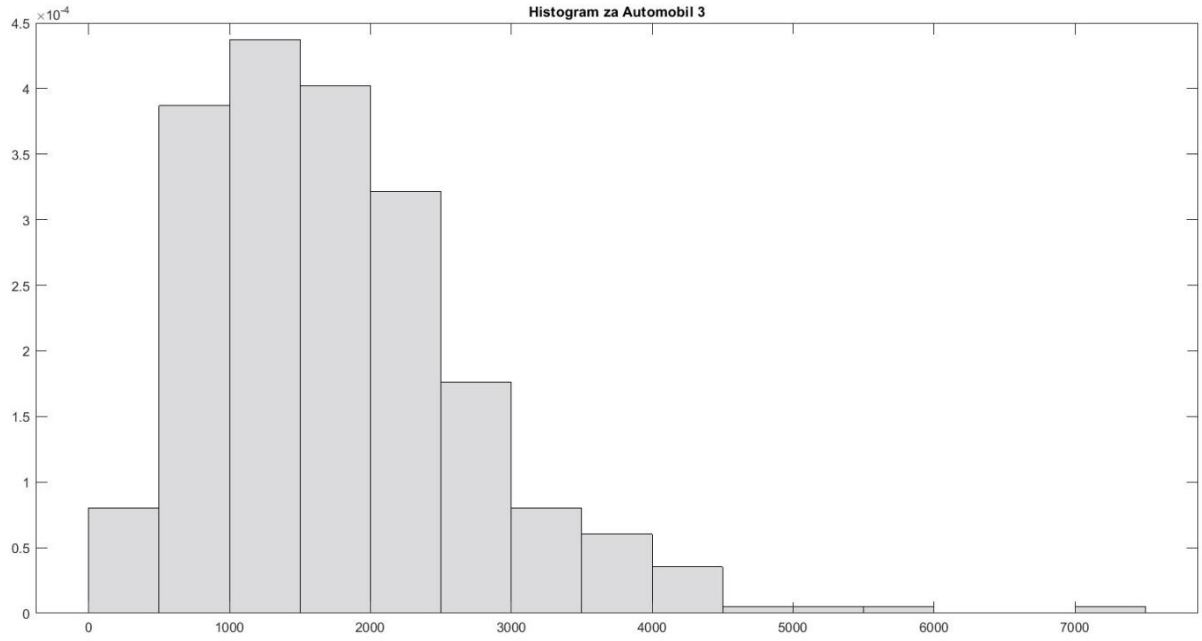

Slika P.1.3 *Histogram za zapis Automobil 3 (3G mreža).*

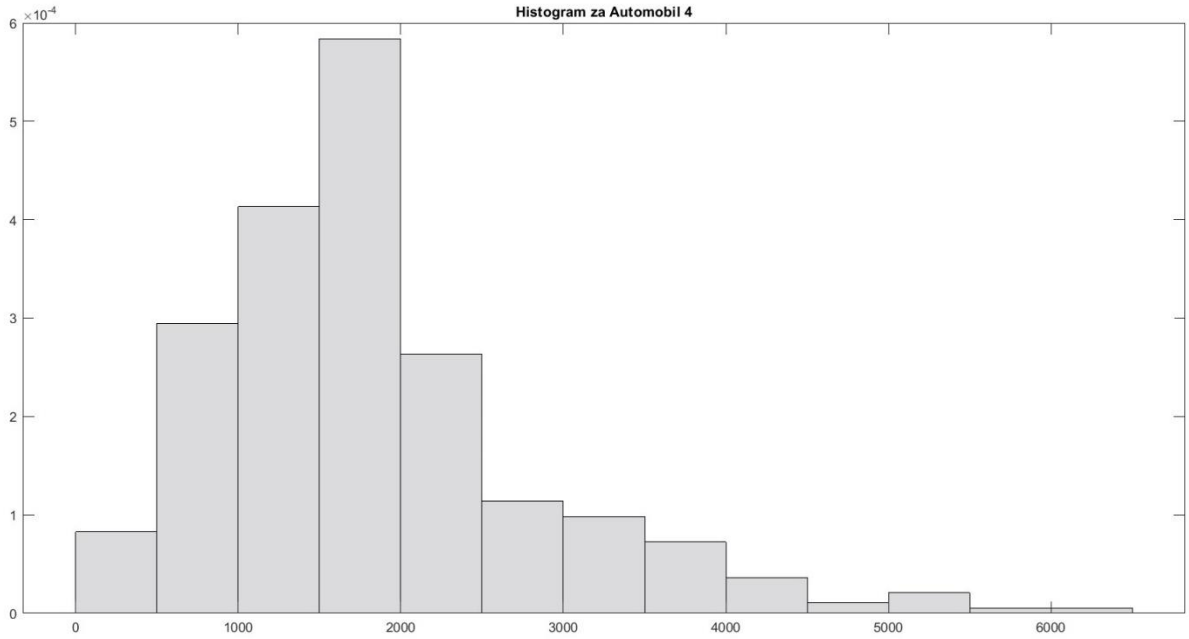

Slika P.1.4 *Histogram za zapis Automobil 4 (3G mreža).*

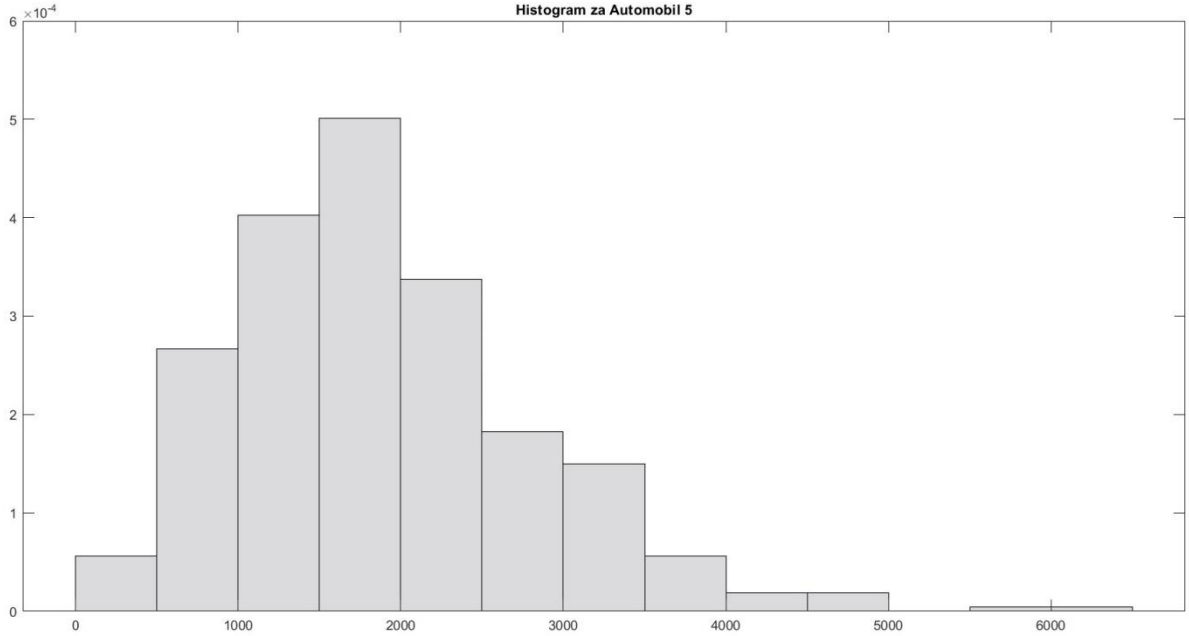

Slika P.1.5 *Histogram za zapis Automobil 5 (3G mreža).*

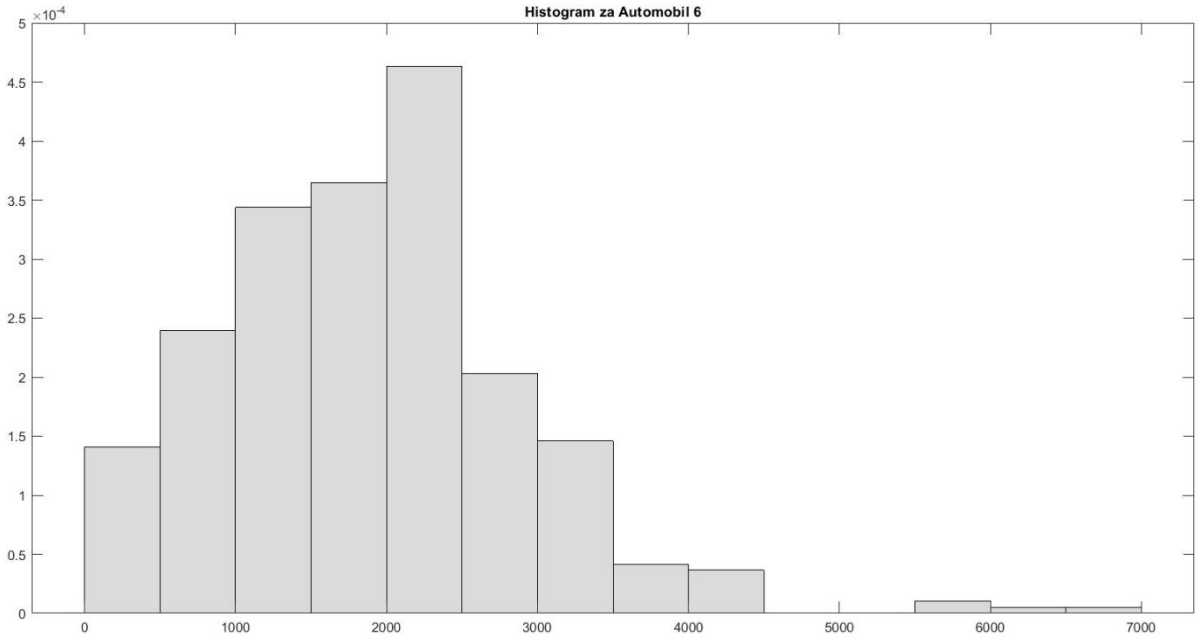

Slika P.1.6 *Histogram za zapis Automobil 6 (3G mreža).*

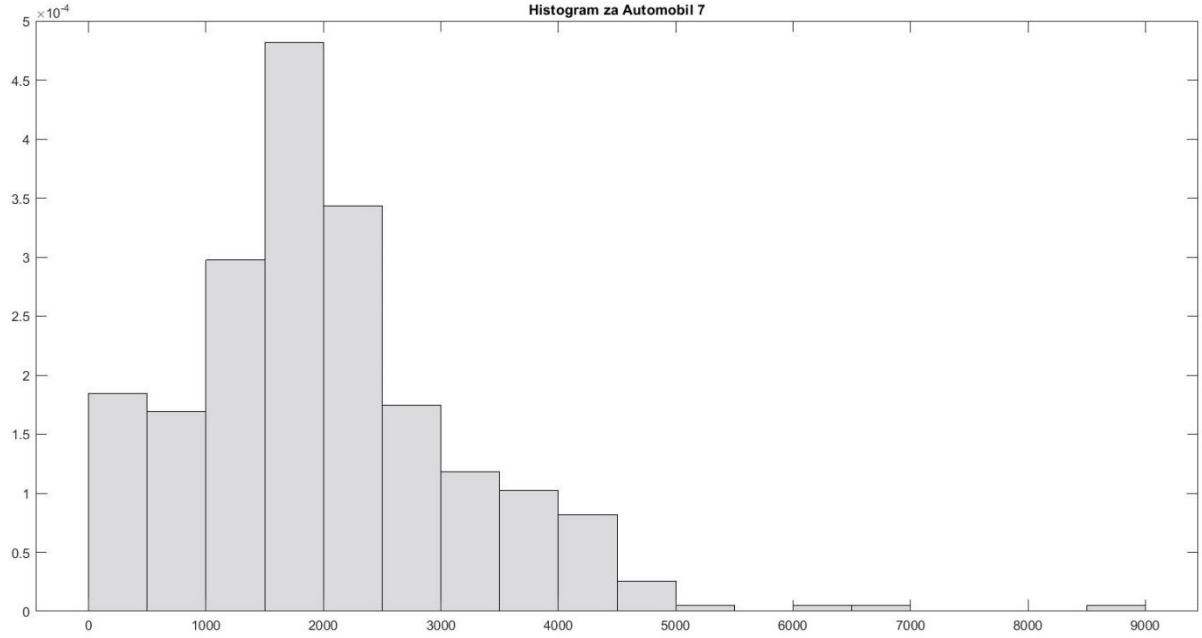

Slika P.1.7 *Histogram za zapis Automobil 7 (3G mreža).*

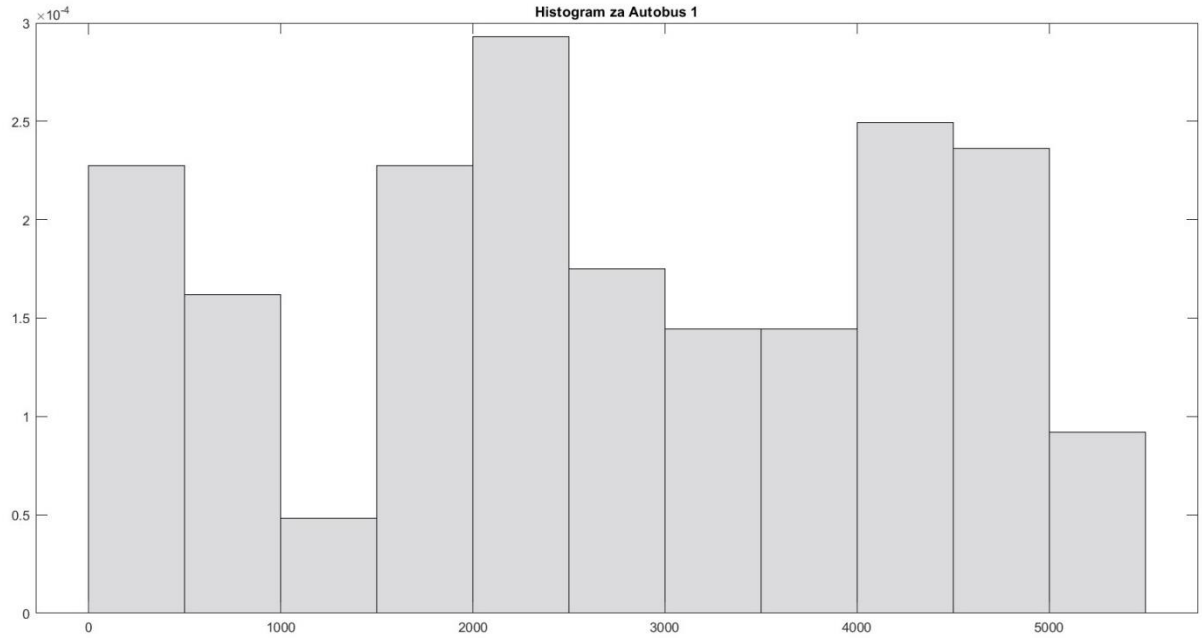

Slika P.1.8 *Histogram za zapis Autobus 1 (3G mreža).*

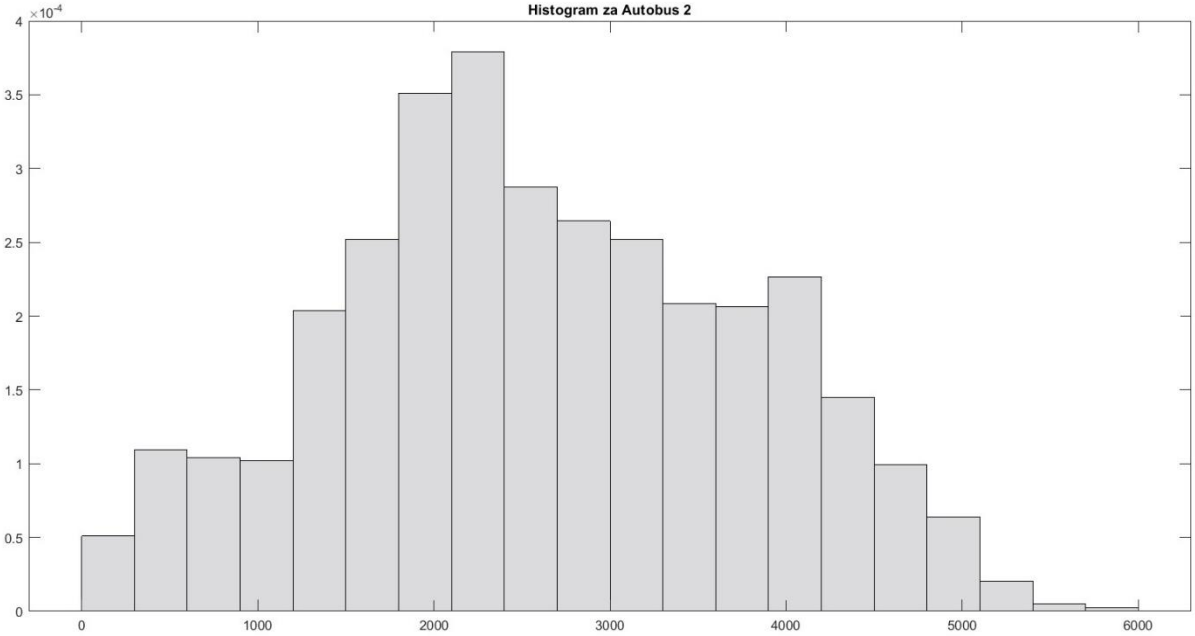

Slika P.1.9 *Histogram za zapis Autobus 2 (3G mreža).*

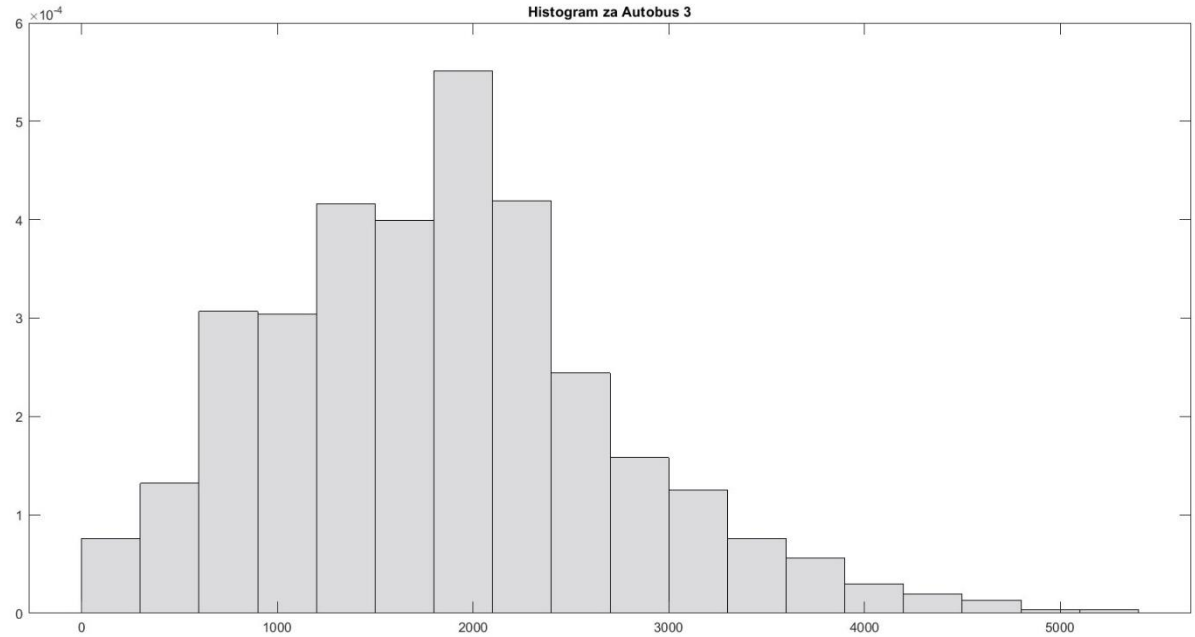

Slika P.1.10 *Histogram za zapis Autobus 3 (3G mreža).*

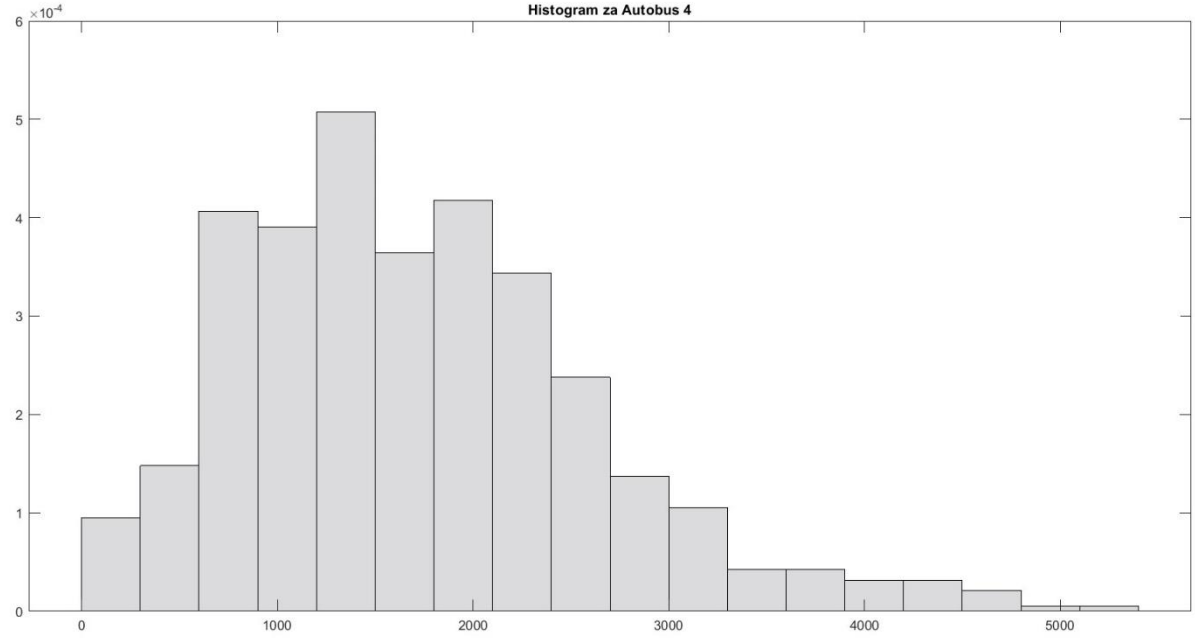

Slika P.1.11 *Histogram za zapis Autobus 4 (3G mreža).*

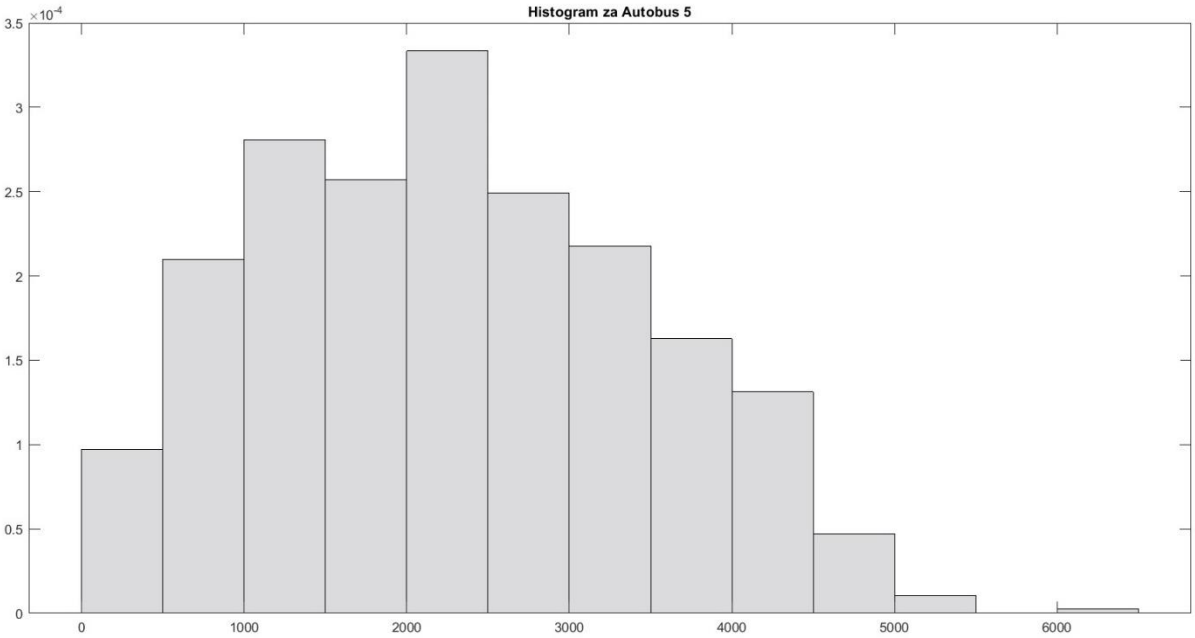

Slika P.1.12 *Histogram za zapis Autobus 5 (3G mreža).*

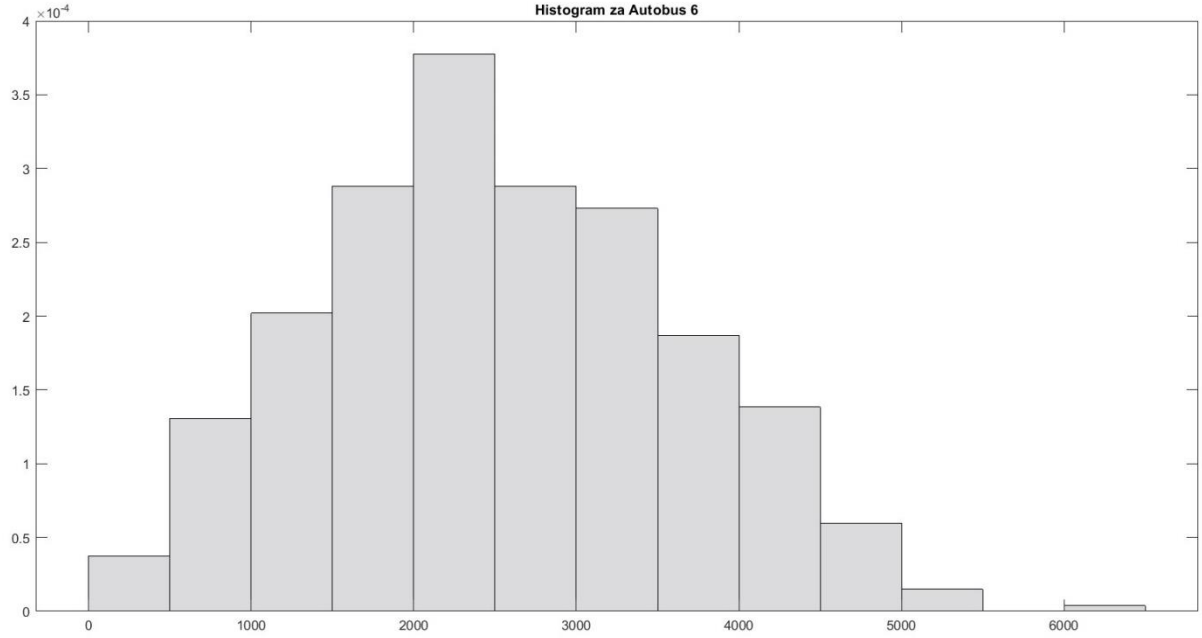

Slika P.1.13 *Histogram za zapis Autobus 6 (3G mreža).*

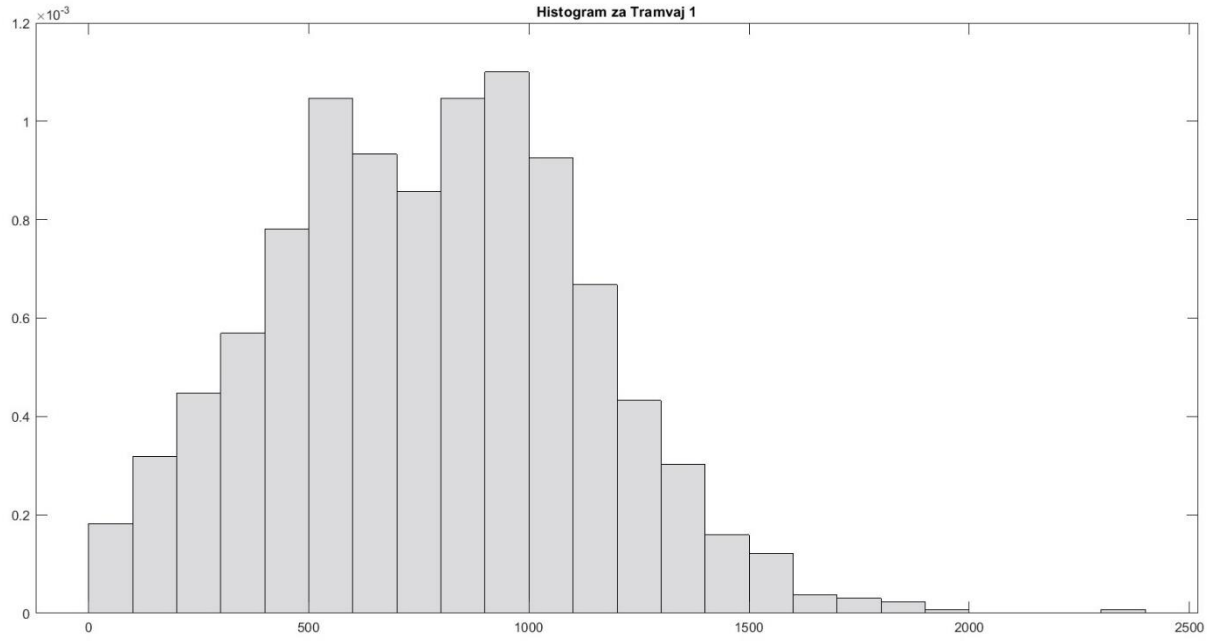

Slika P.1.14 *Histogram za zapis Tramvaj 1 (3G mreža).*

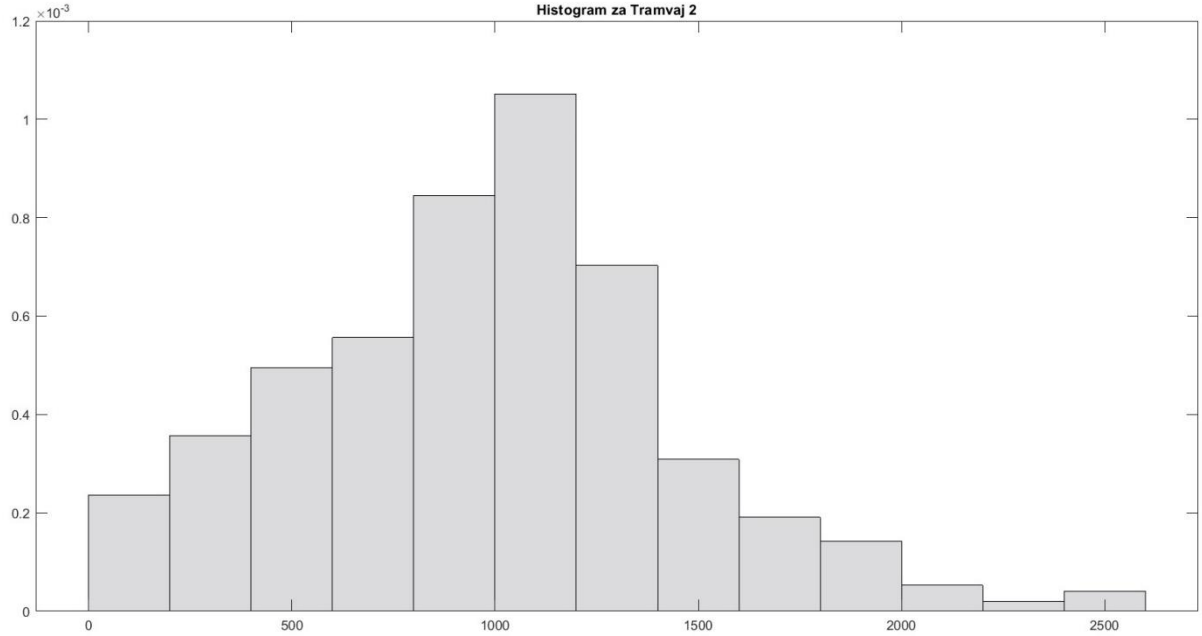

Slika P.1.15 *Histogram za zapis Tramvaj 2 (3G mreža).*

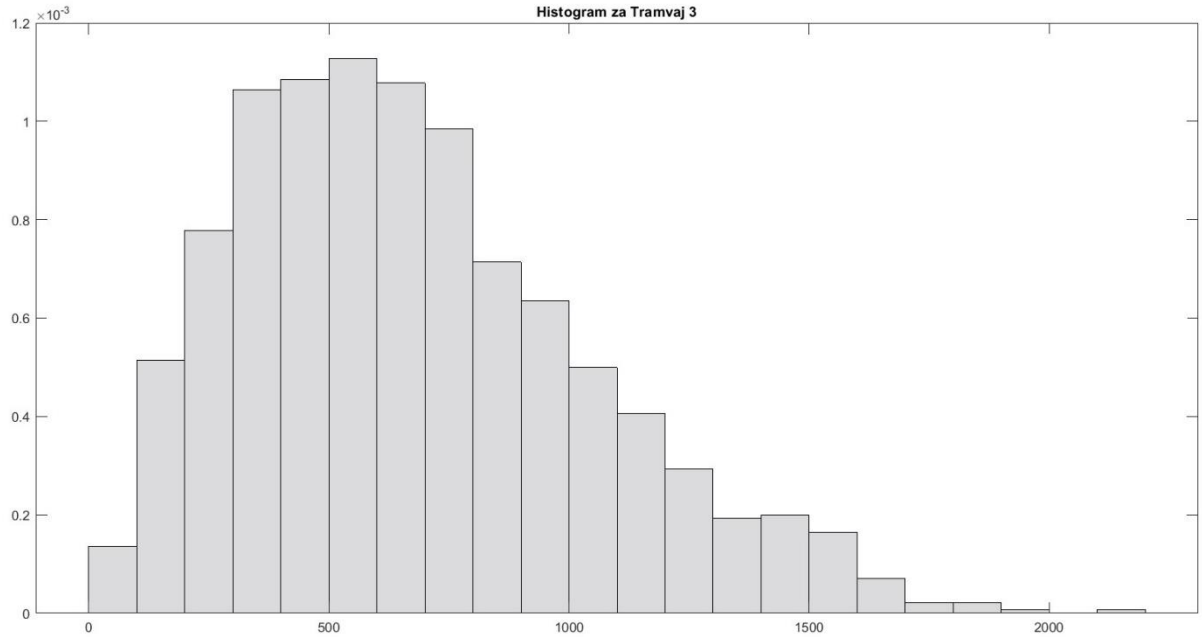

Slika P.1.16 *Histogram za zapis Tramvaj 3 (3G mreža).*

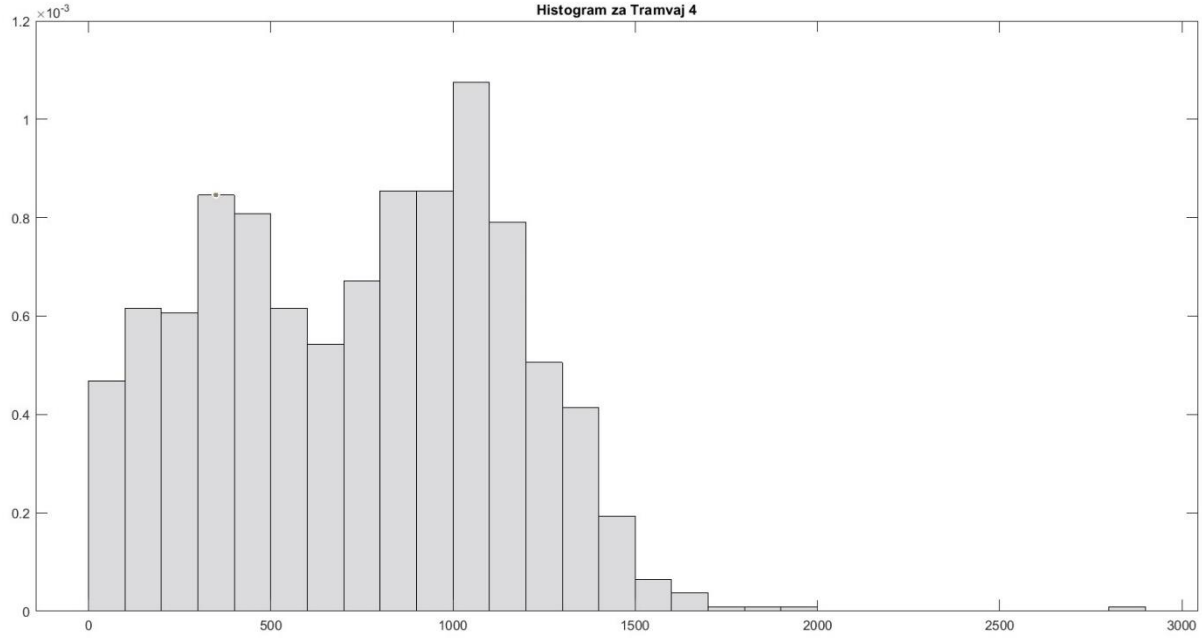

Slika P.1.17 *Histogram za zapis Tramvaj 4 (3G mreža).*

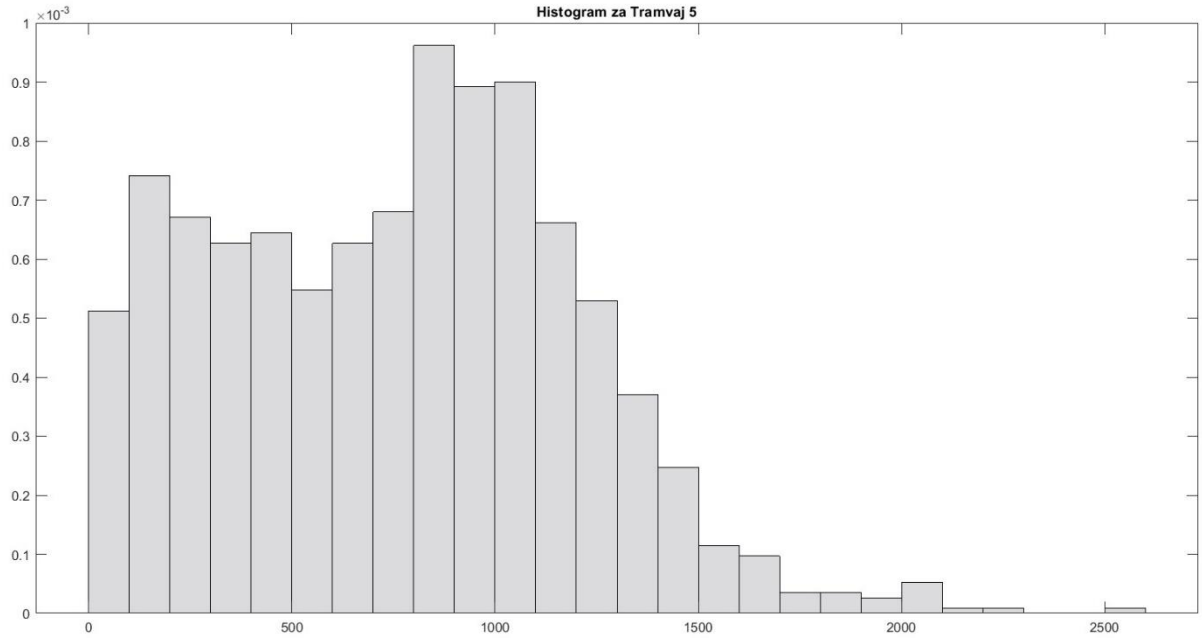

Slika P.1.18 *Histogram za zapis Tramvaj 5 (3G mreža).*

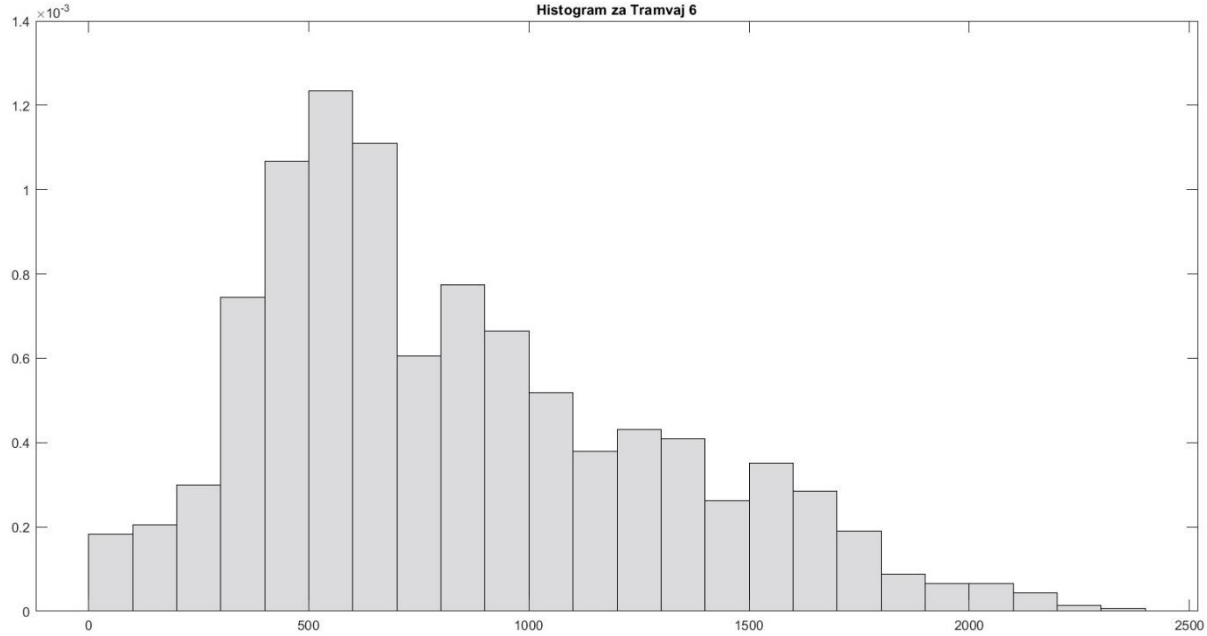

Slika P.1.19 *Histogram za zapis Tramvaj 6 (3G mreža).*

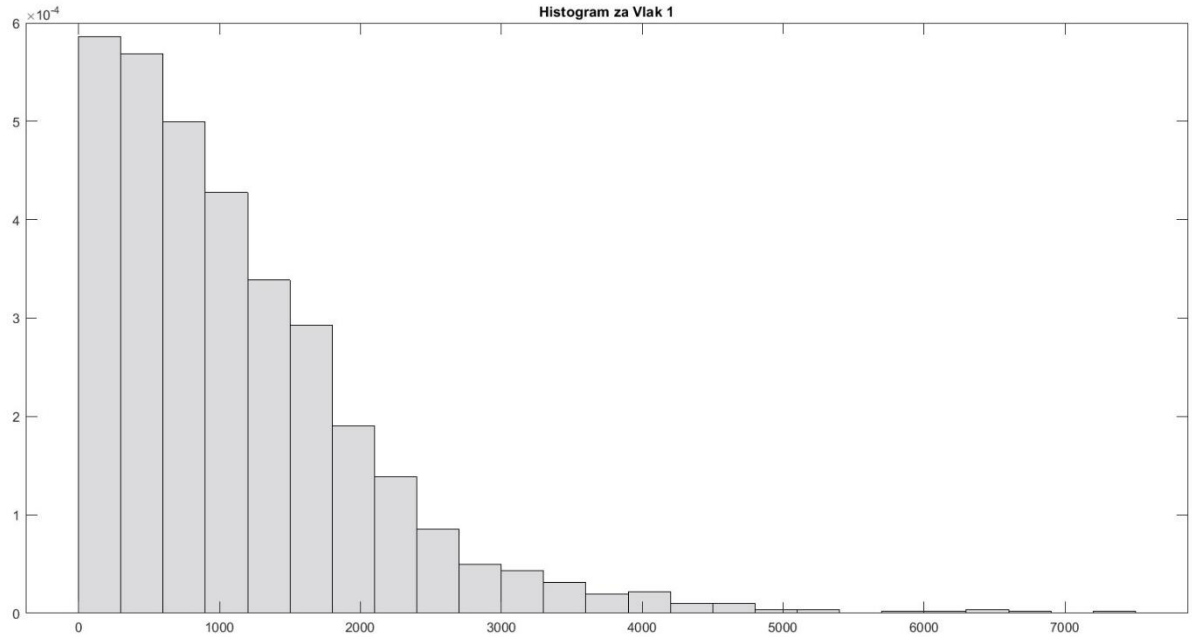

Slika P.1.20 *Histogram za zapis Vlak 1 (3G mreža).*

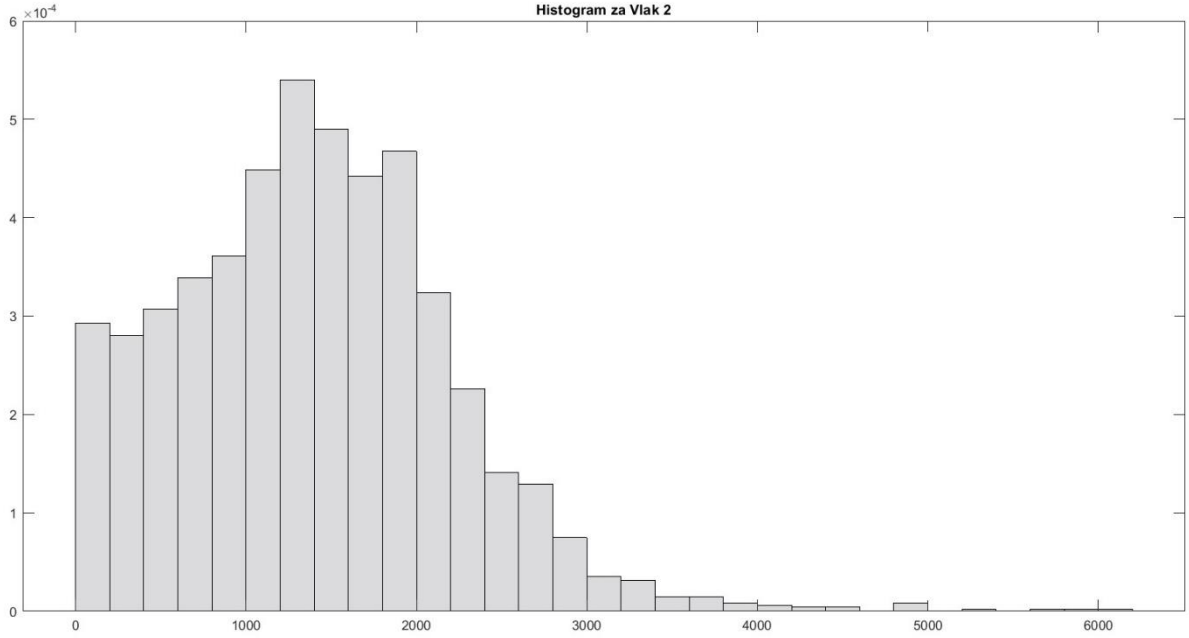

Slika P.1.21 *Histogram za zapis Vlak 2 (3G mreža).*

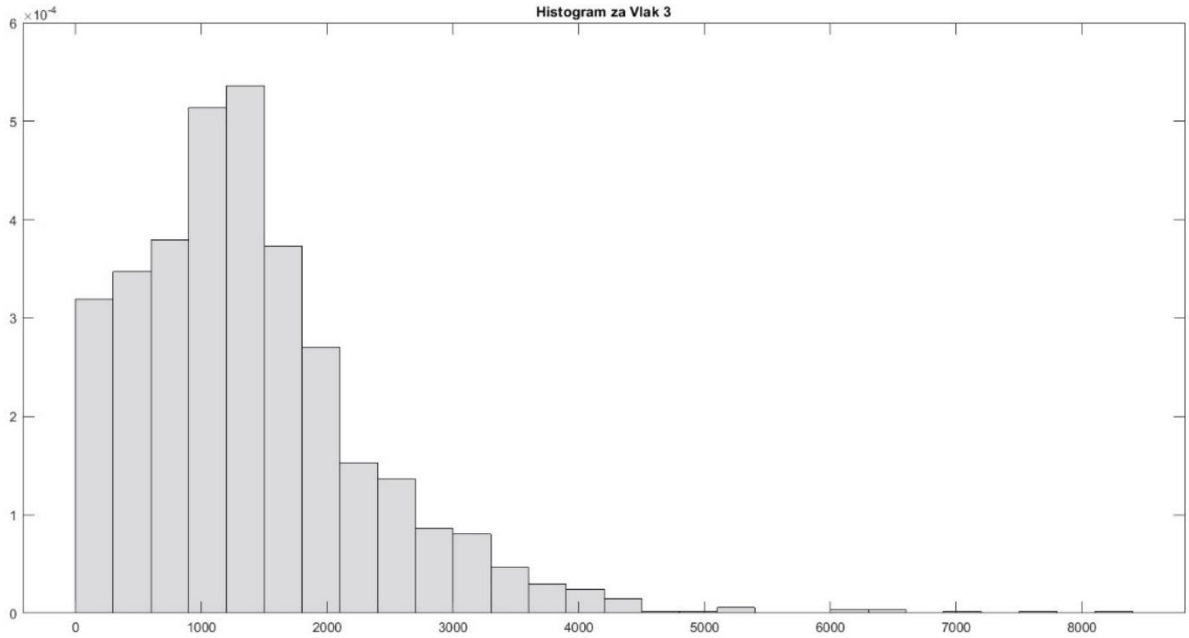

Slika P.1.22 *Histogram za zapis Vlak 3 (3G mreža).*

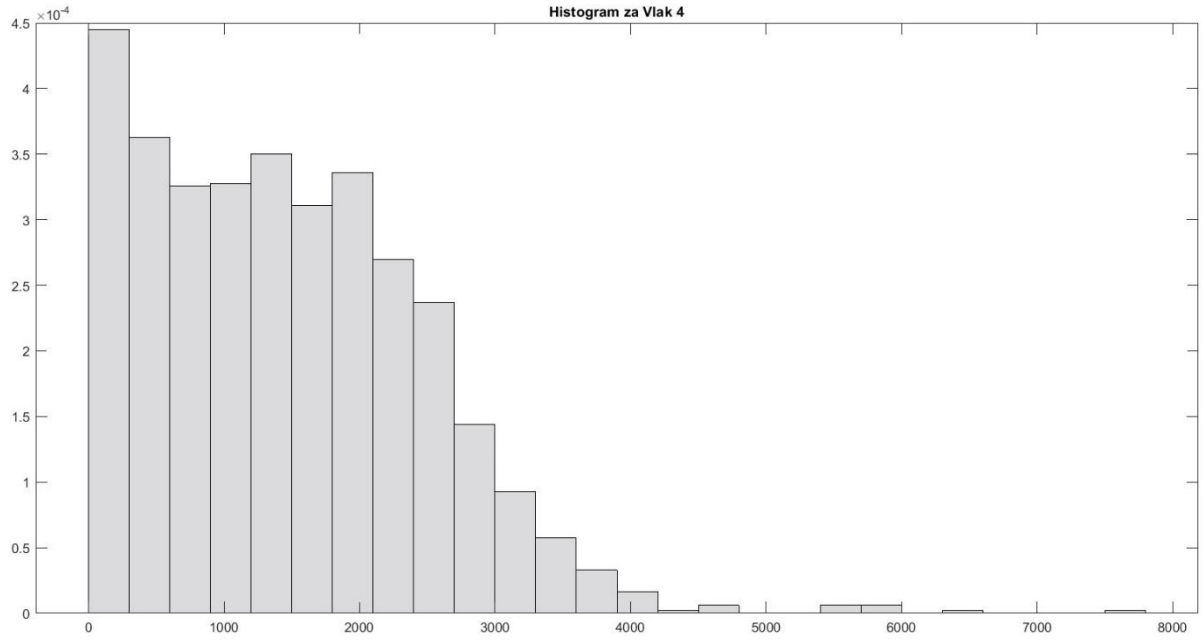

Slika P.1.23 *Histogram za zapis Vlak 4 (3G mreža).*

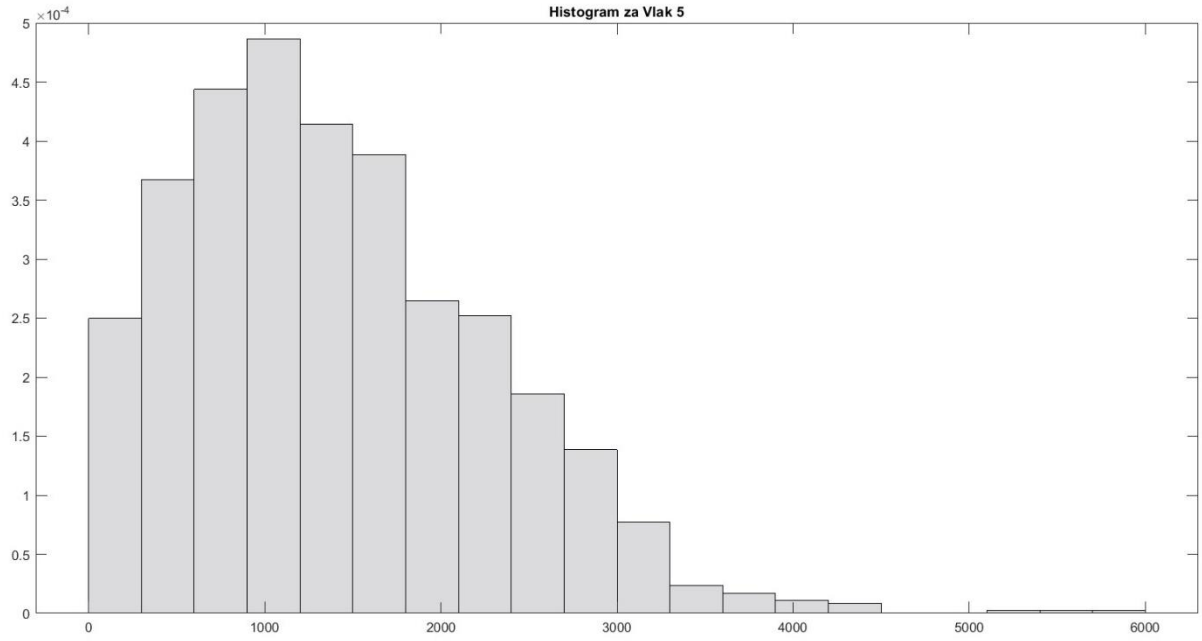

Slika P.1.24 *Histogram za zapis Vlak 5 (3G mreža).*

Prilog P.2. Histogram 4G ispitnih zapisa

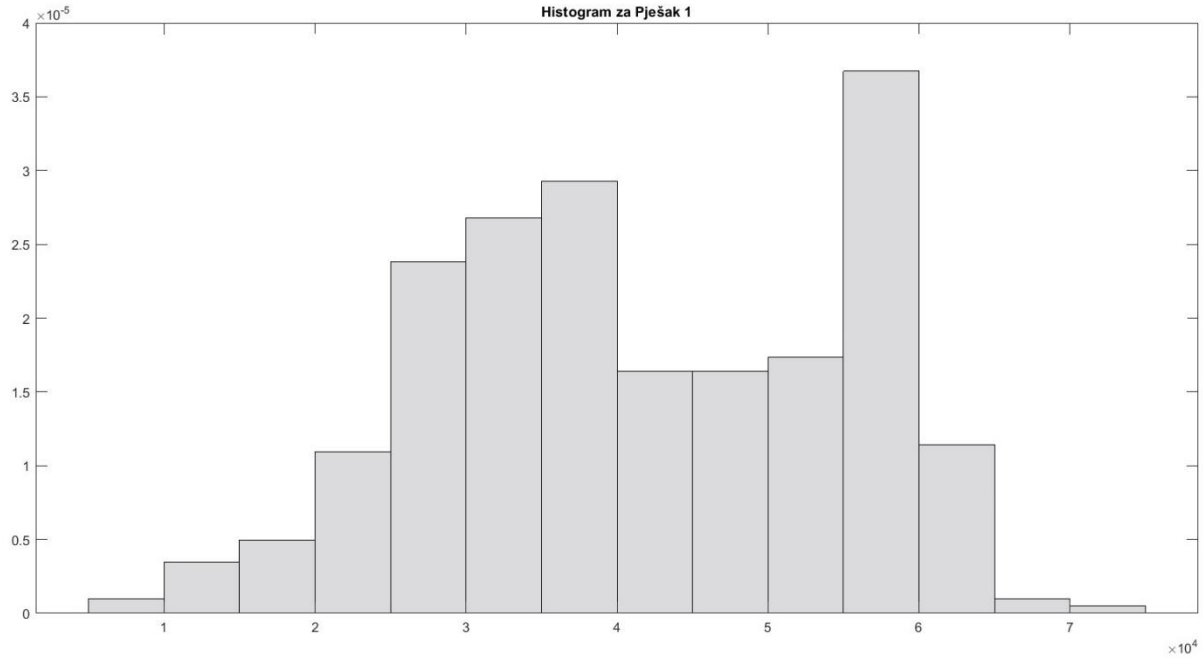

Slika P.2.1 *Histogram za zapis Pješak 1 (4G mreža).*

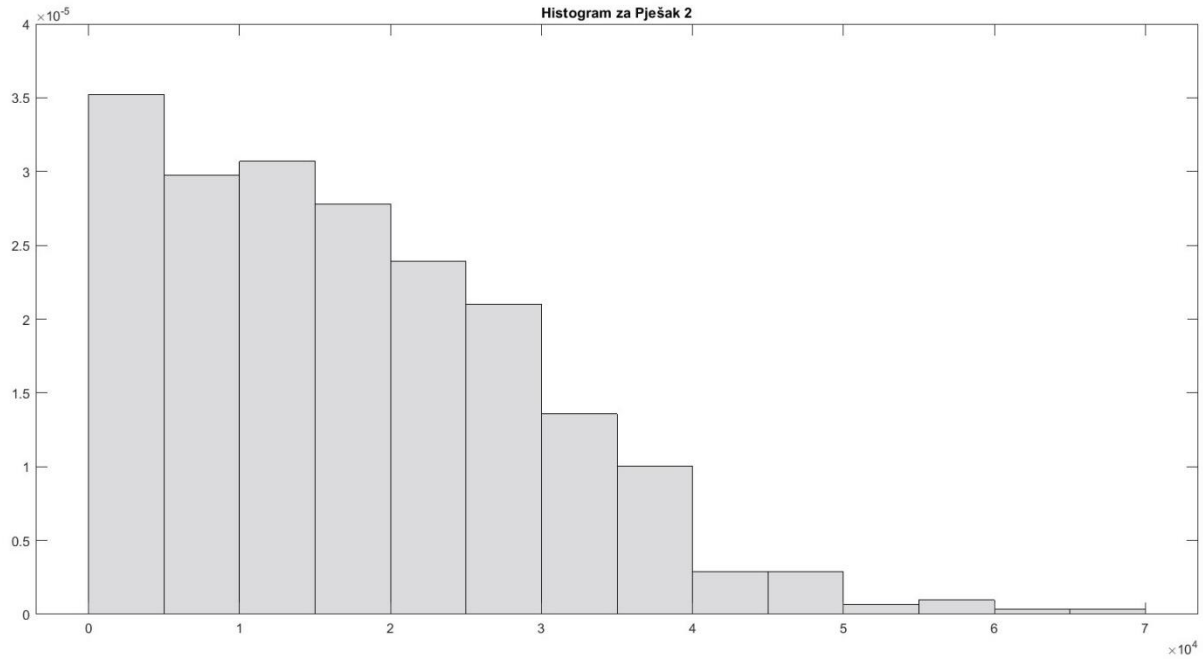

Slika P.2.2 *Histogram za zapis Pješak 2 (4G mreža).*

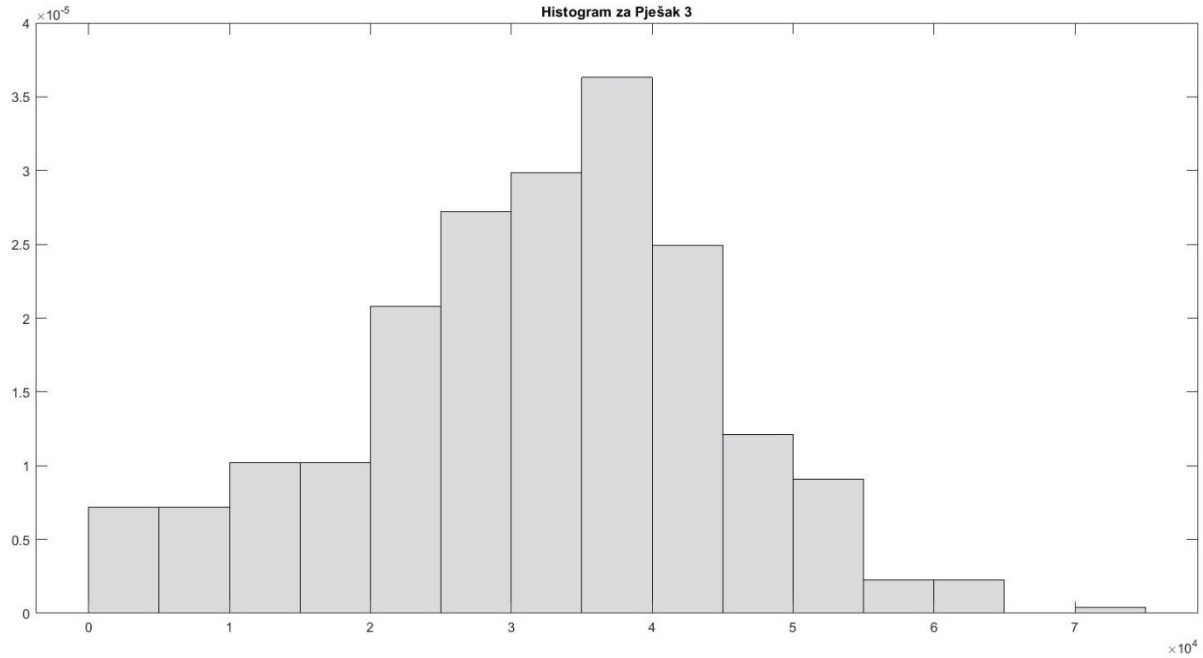

Slika P.2.3 *Histogram za zapis Pješak 3 (4G mreža).*

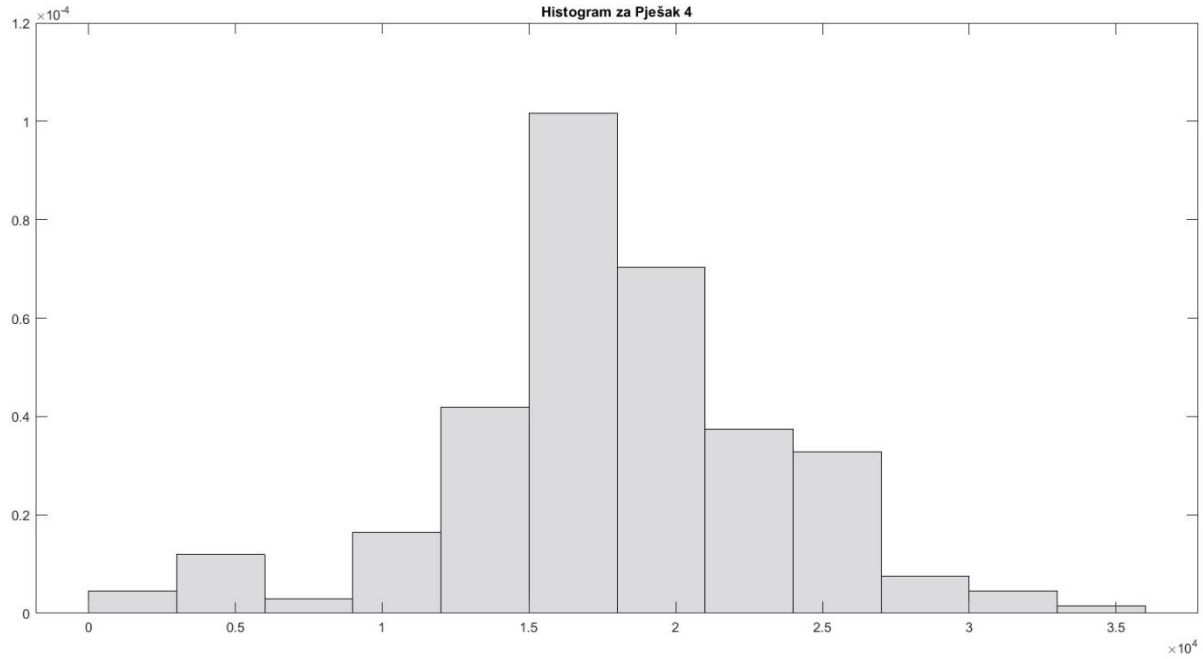

Slika P.2.4 *Histogram za zapis Pješak 4 (4G mreža).*

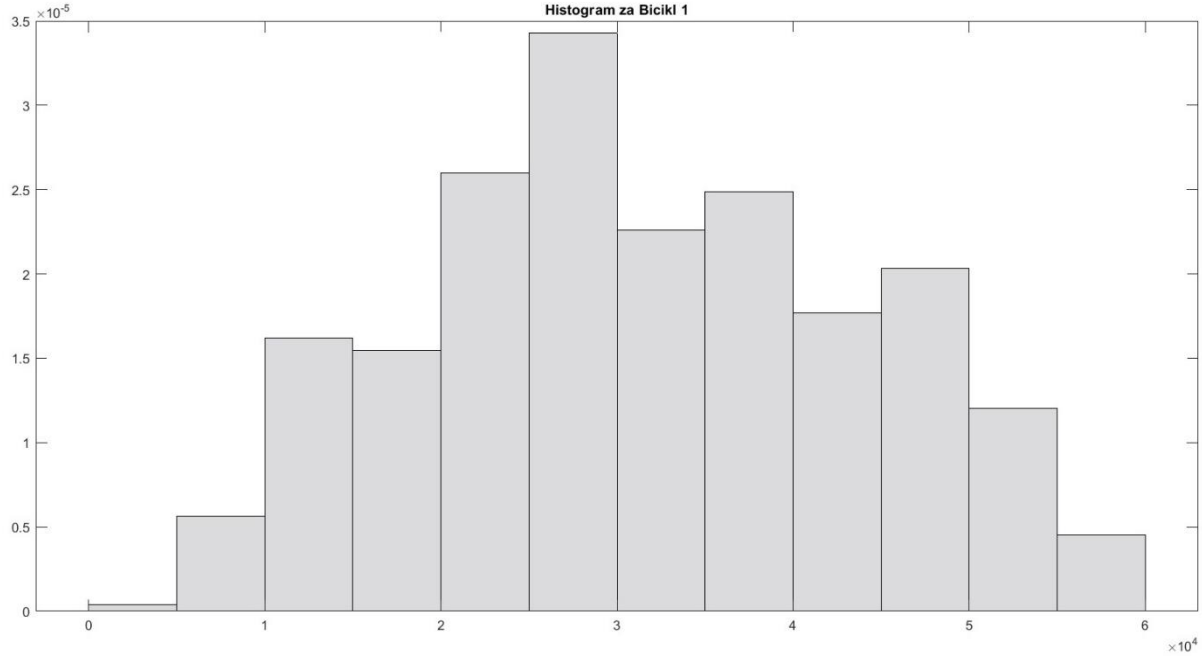

Slika P.2.5 *Histogram za zapis Bicikl 1 (4G mreža).*

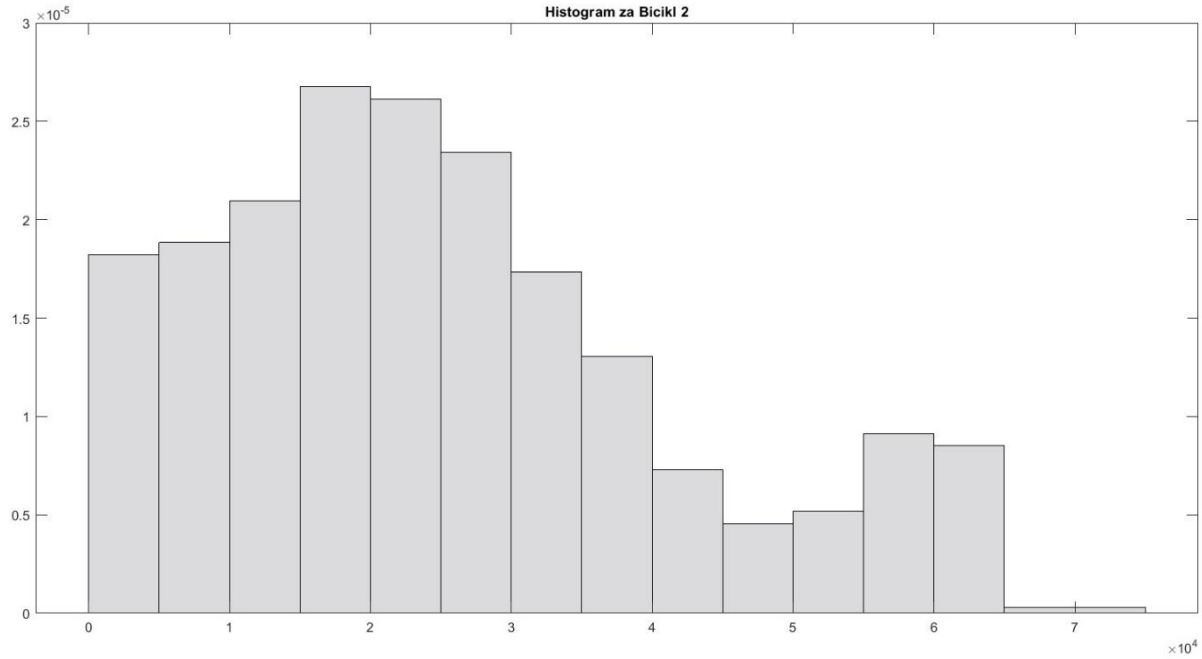

Slika P.2.6 *Histogram za zapis Bicikl 2 (4G mreža).*

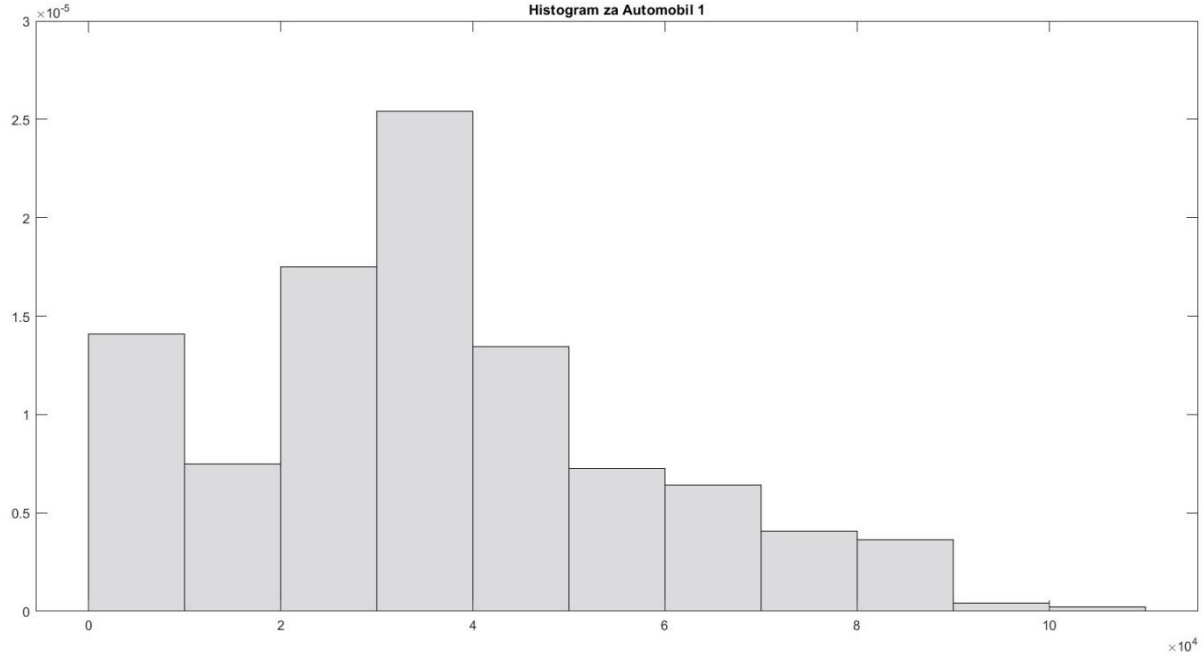

Slika P.2.7 *Histogram za zapis Automobil 1 (4G mreža).*

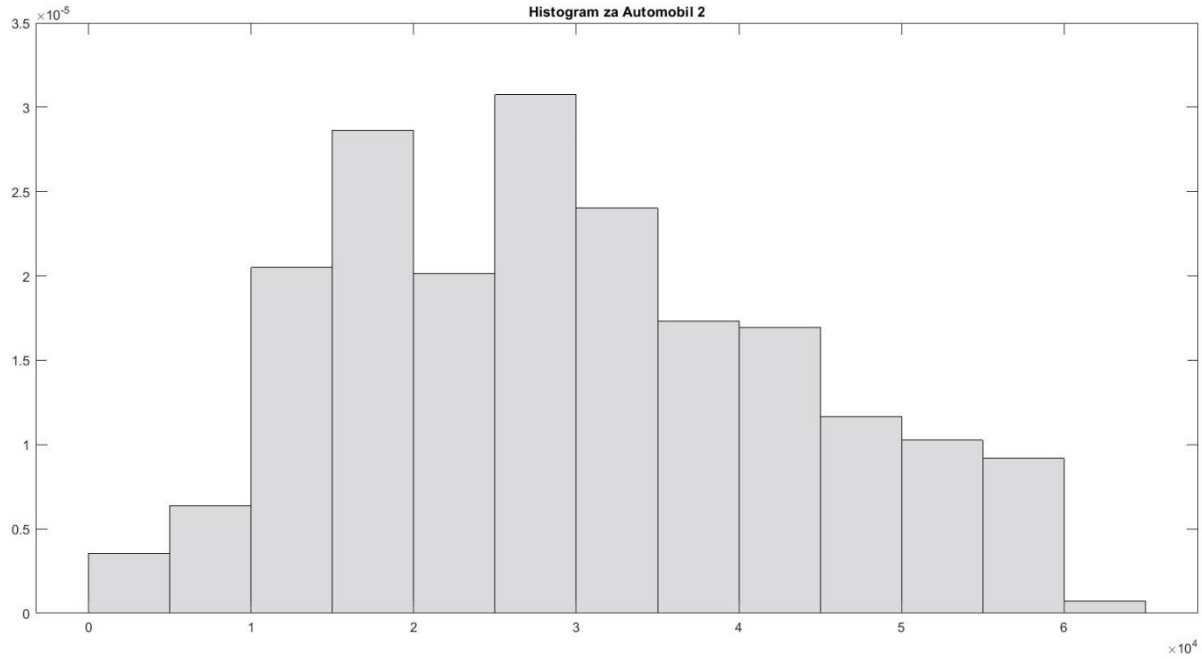

Slika P.2.8 *Histogram za zapis Automobil 2 (4G mreža).*

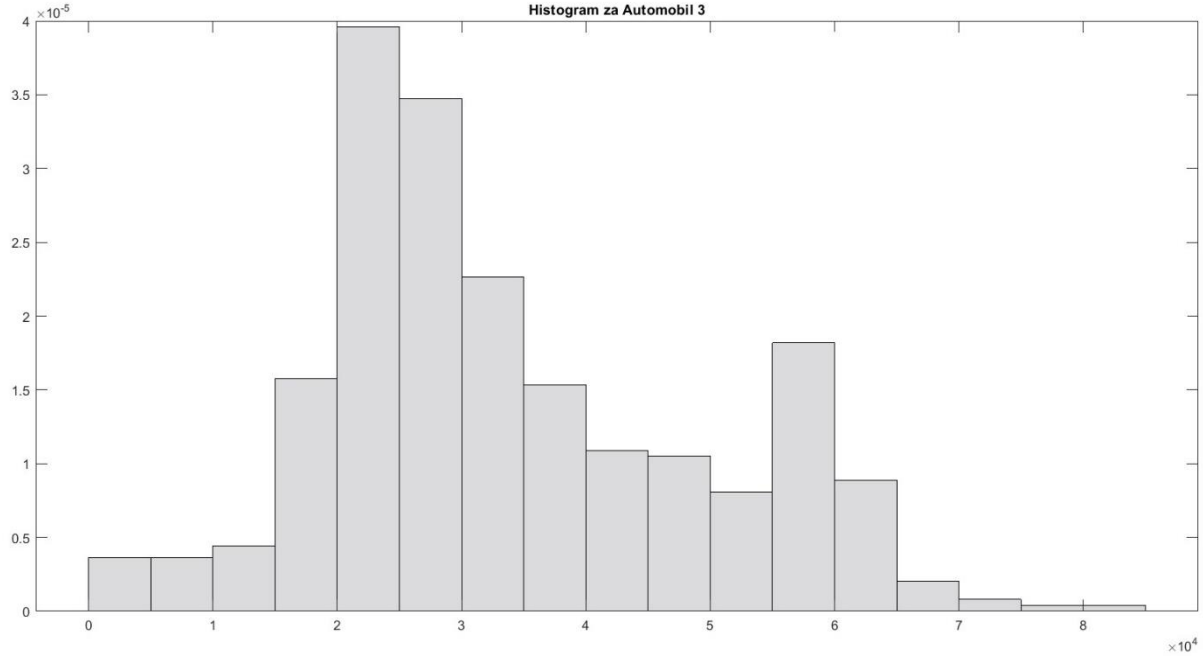

Slika P.2.9 *Histogram za zapis Automobil 3 (4G mreža).*

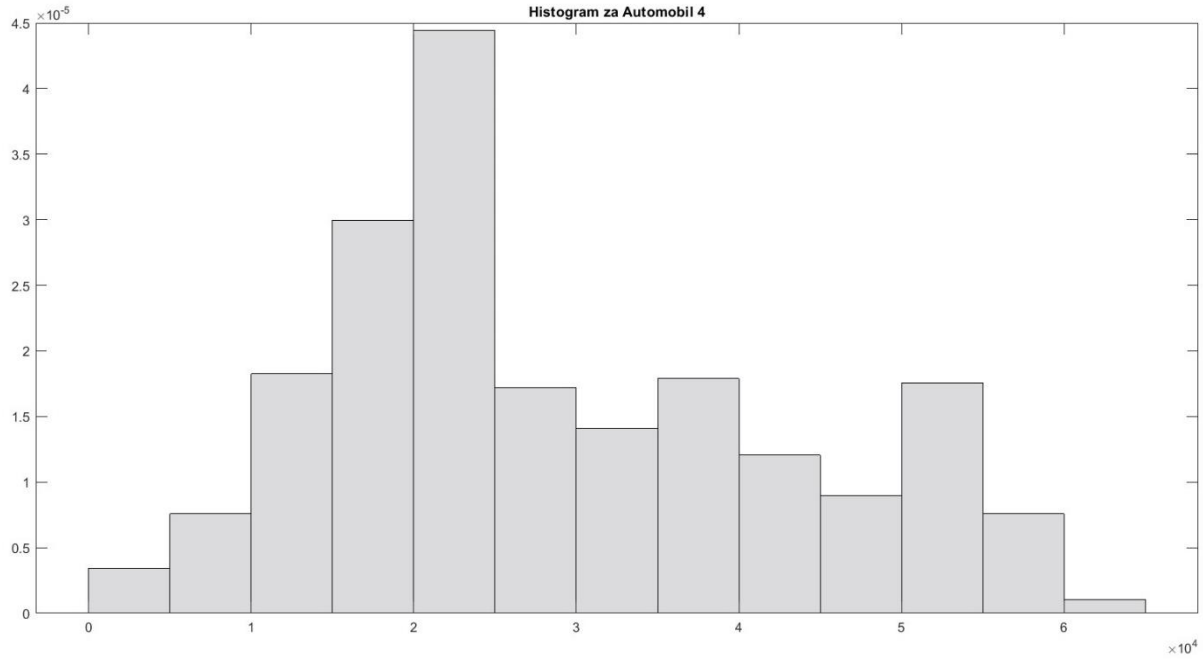

Slika P.2.10 *Histogram za zapis Automobil 4 (4G mreža).*

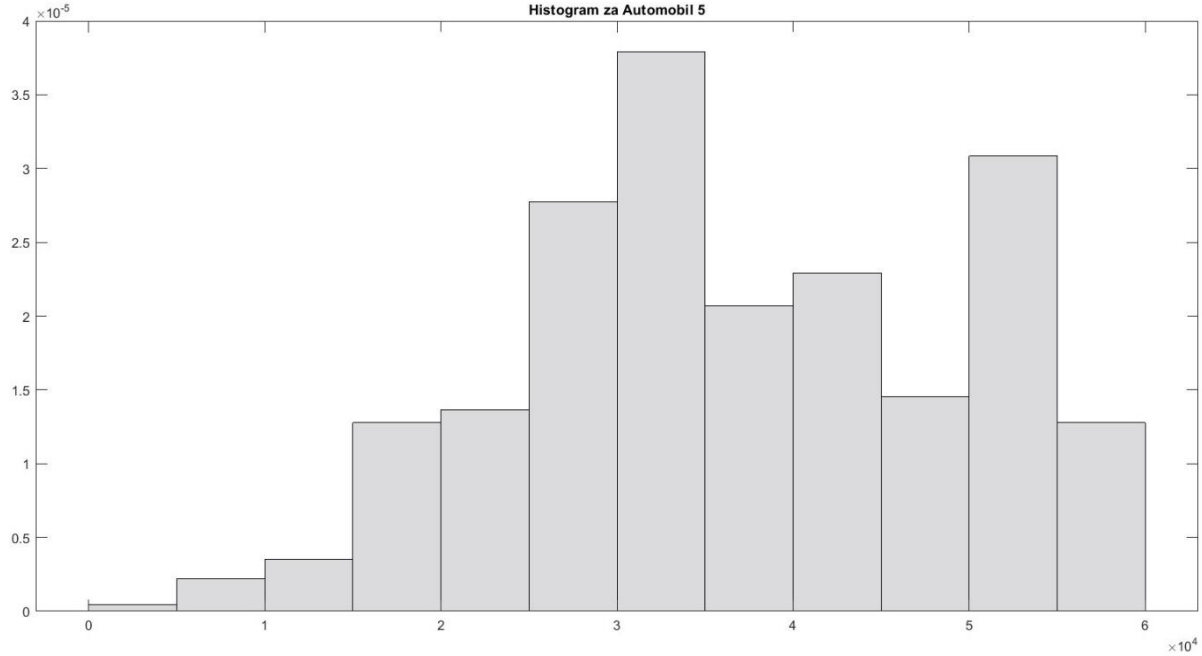

Slika P.2.11 *Histogram za zapis Automobil 5 (4G mreža).*

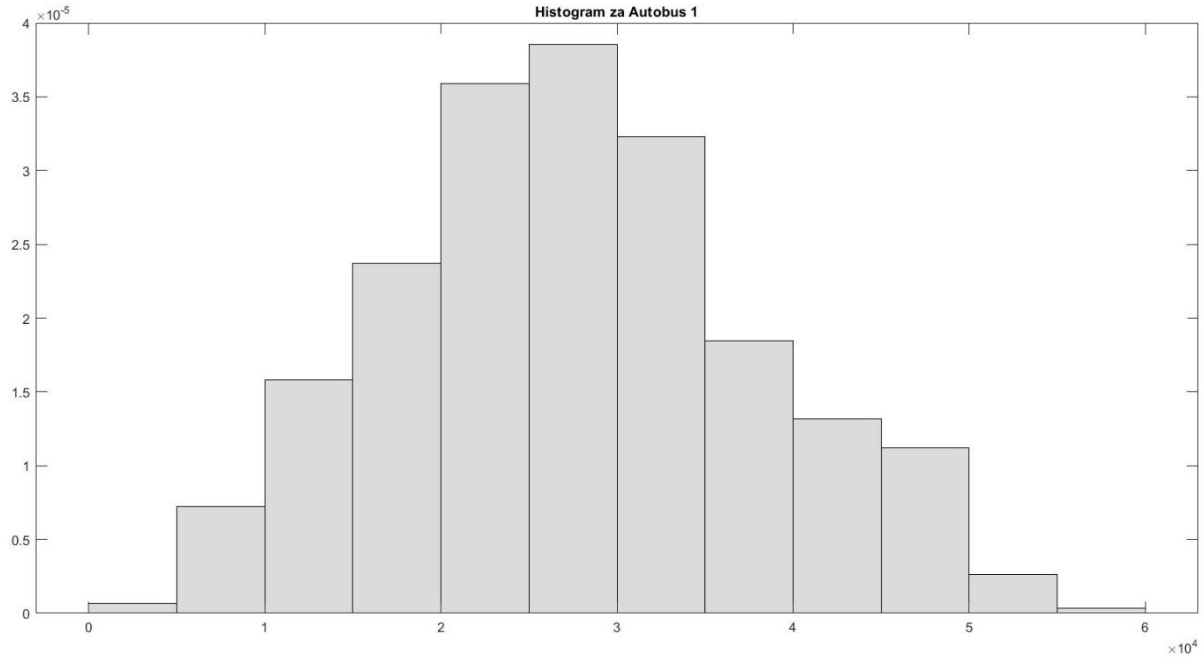

Slika P.2.12 *Histogram za zapis Autobus 1 (4G mreža).*

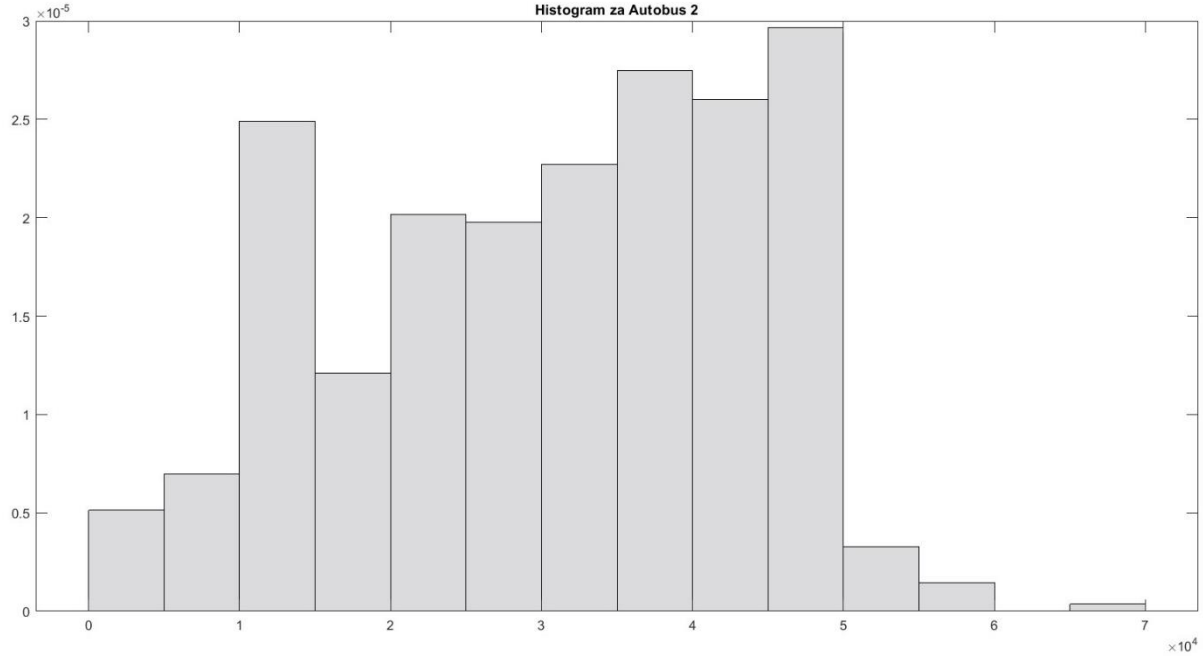

Slika P.2.13 *Histogram za zapis Autobus 2 (4G mreža).*

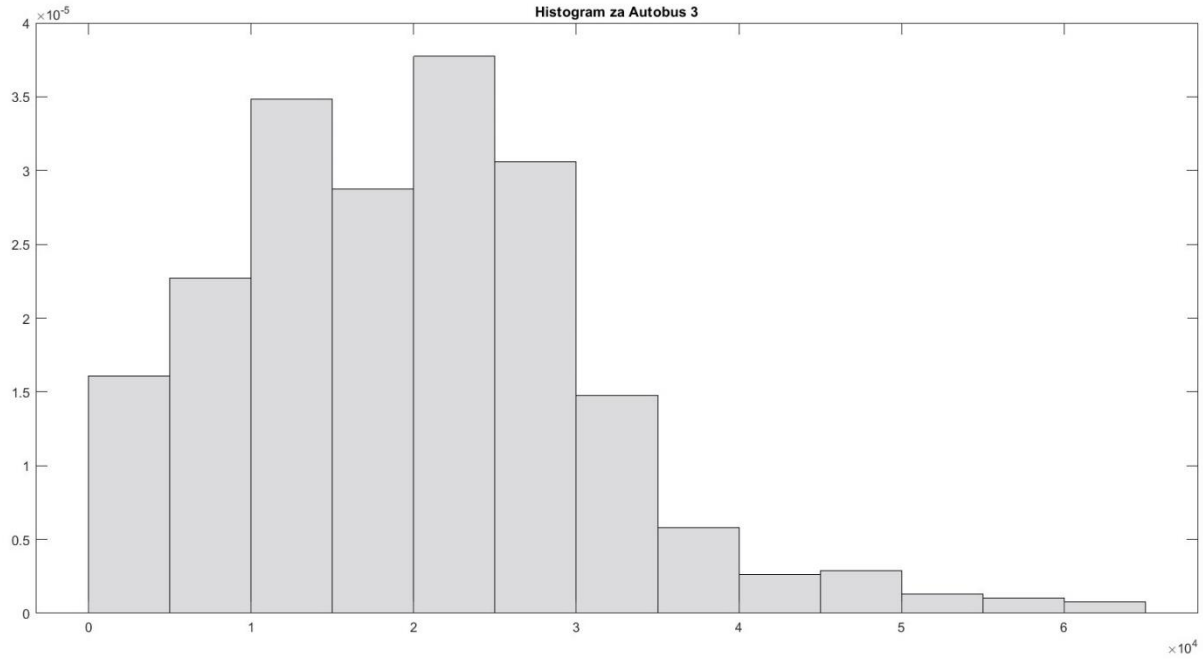

Slika P.2.14 *Histogram za zapis Autobus 3 (4G mreža).*

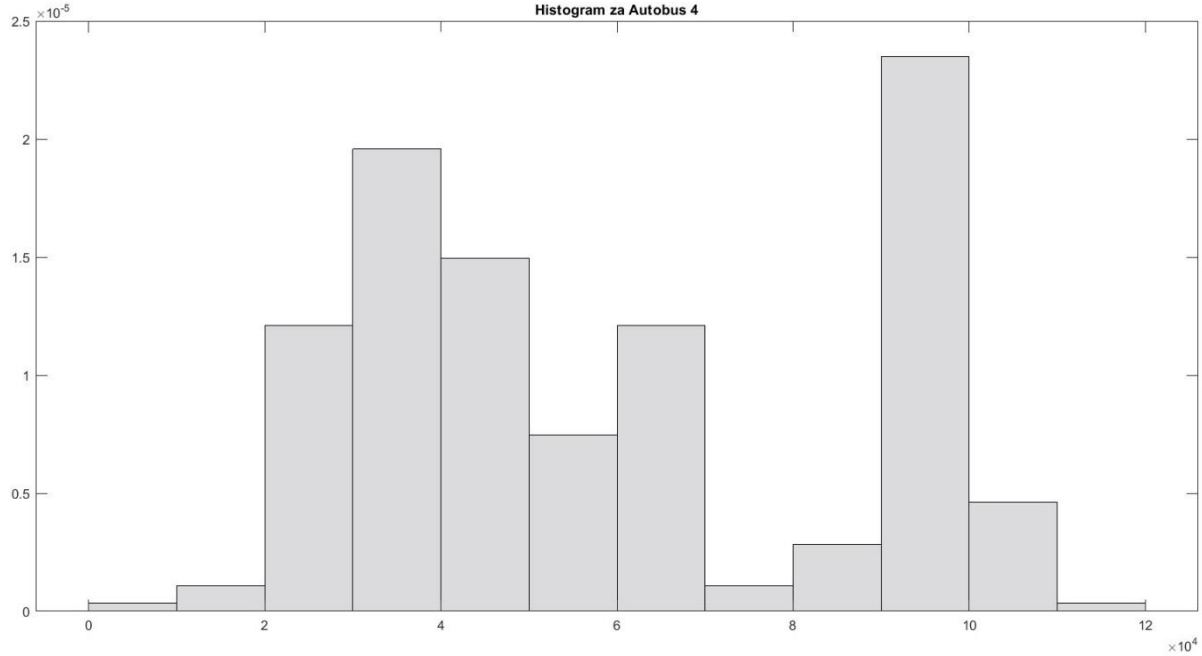

Slika P.2.15 *Histogram za zapis Autobus 4 (4G mreža).*

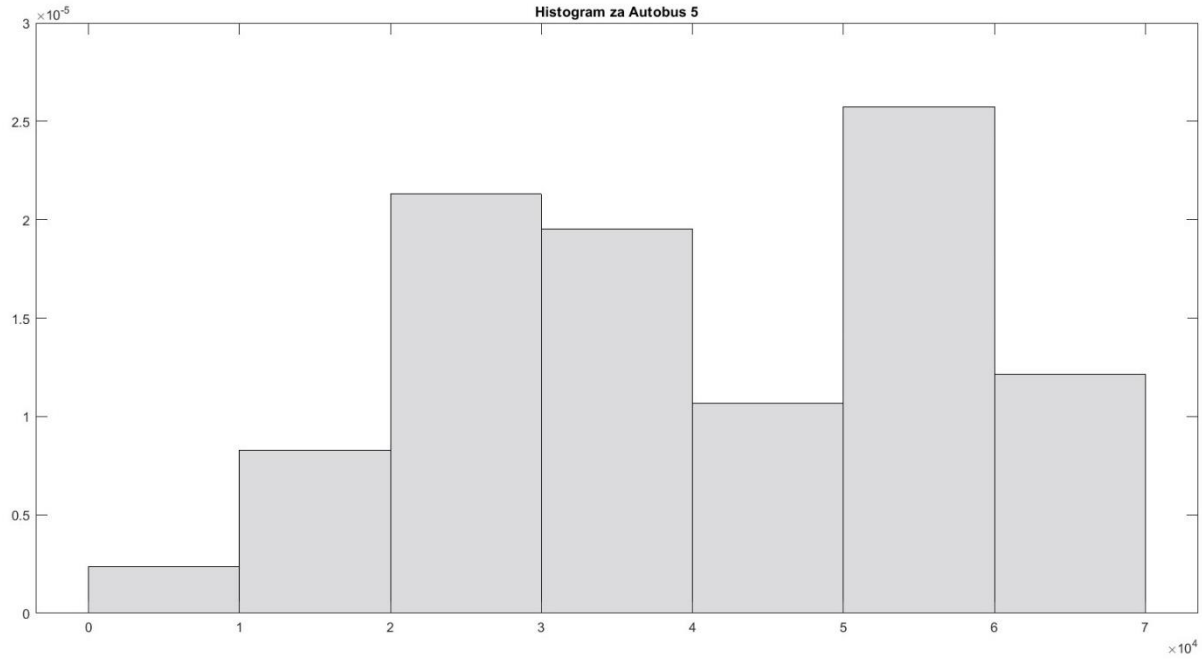

Slika P.2.16 *Histogram za zapis Autobus 5 (4G mreža).*

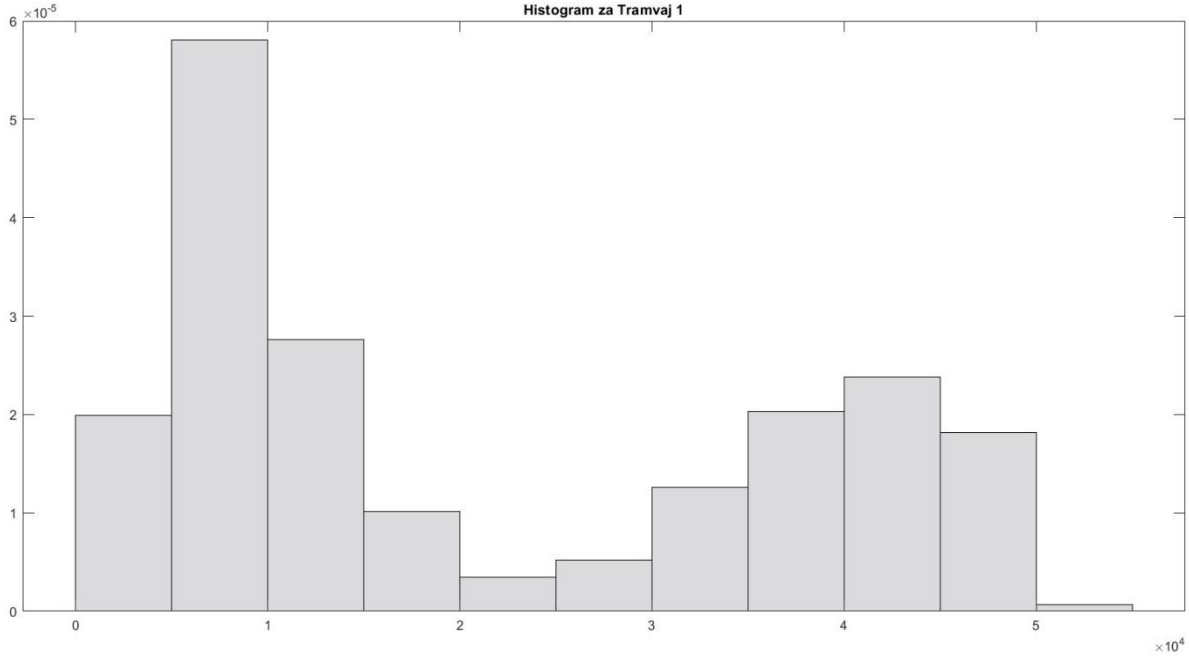

Slika P.2.17 *Histogram za zapis Tramvaj 1 (4G mreža).*

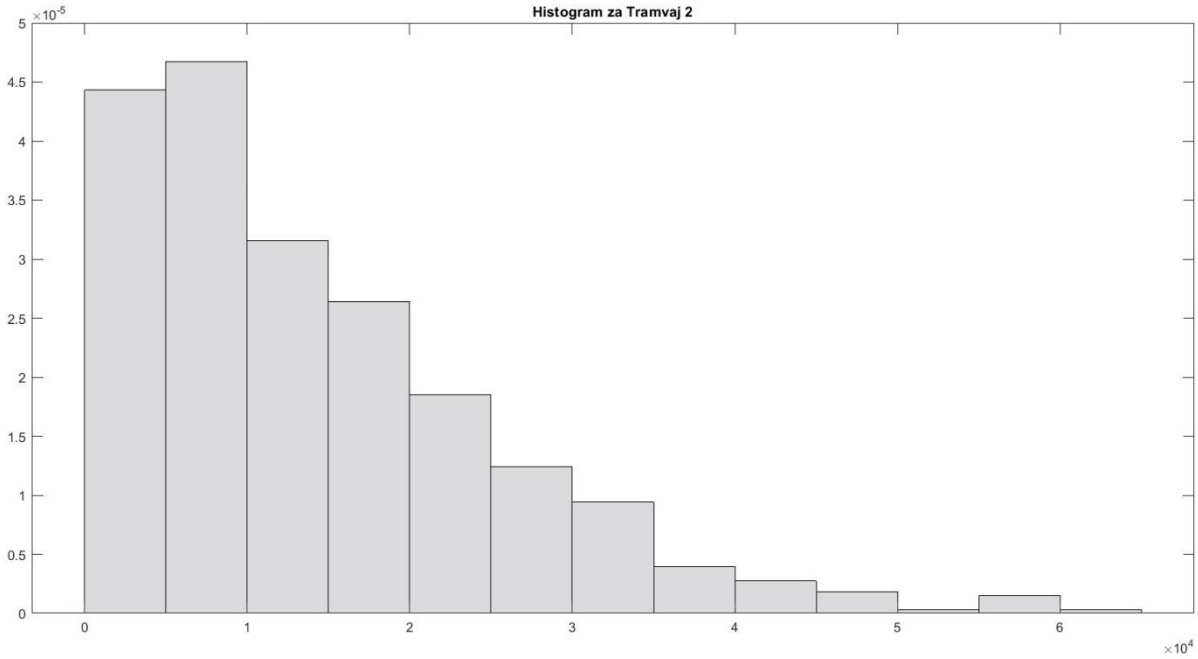

Slika P.2.18 *Histogram za zapis Tramvaj 2 (4G mreža).*

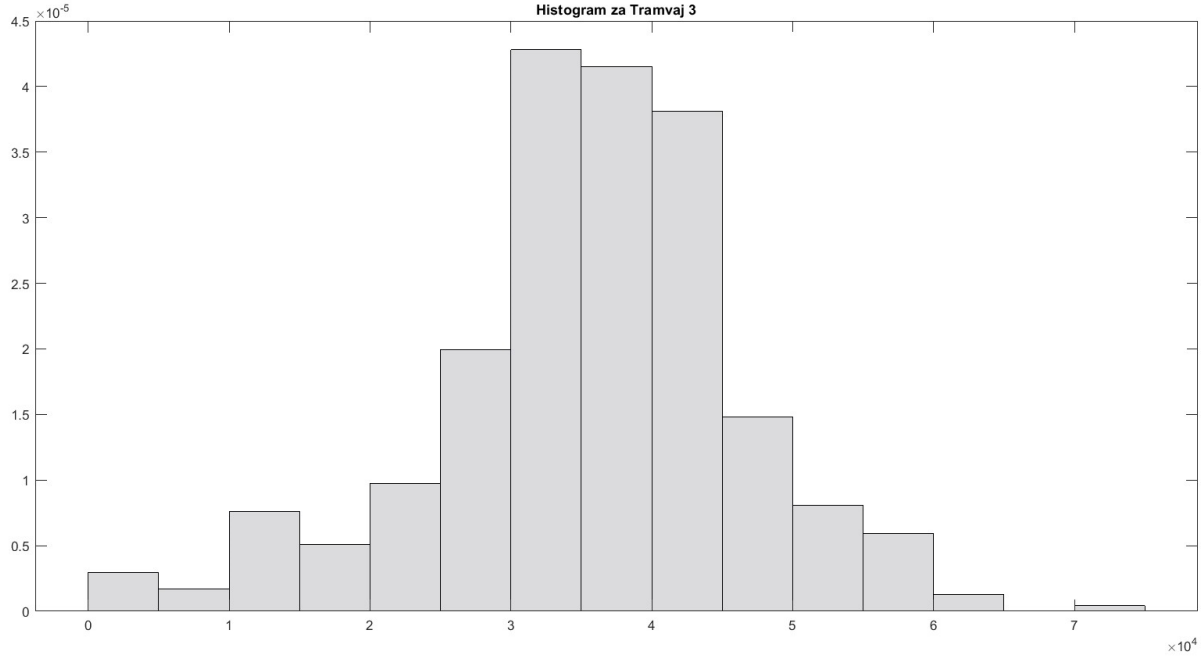

Slika P.2.19 *Histogram za zapis Tramvaj 3 (4G mreža).*

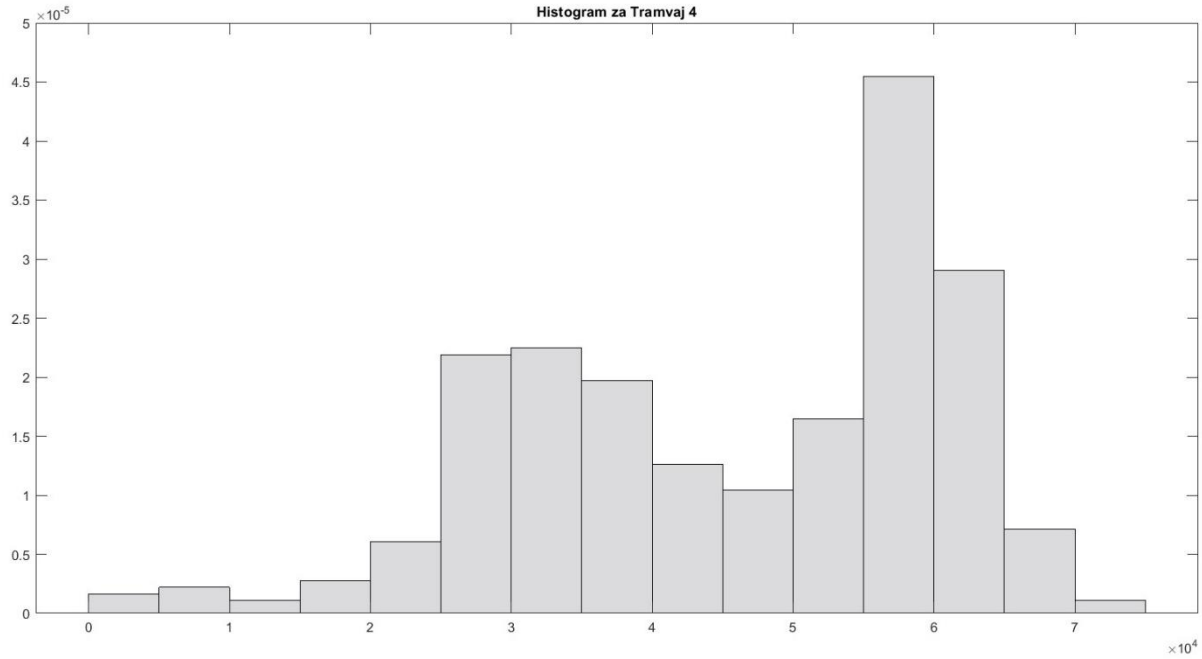

Slika P.2.20 *Histogram za zapis Tramvaj 4 (4G mreža).*

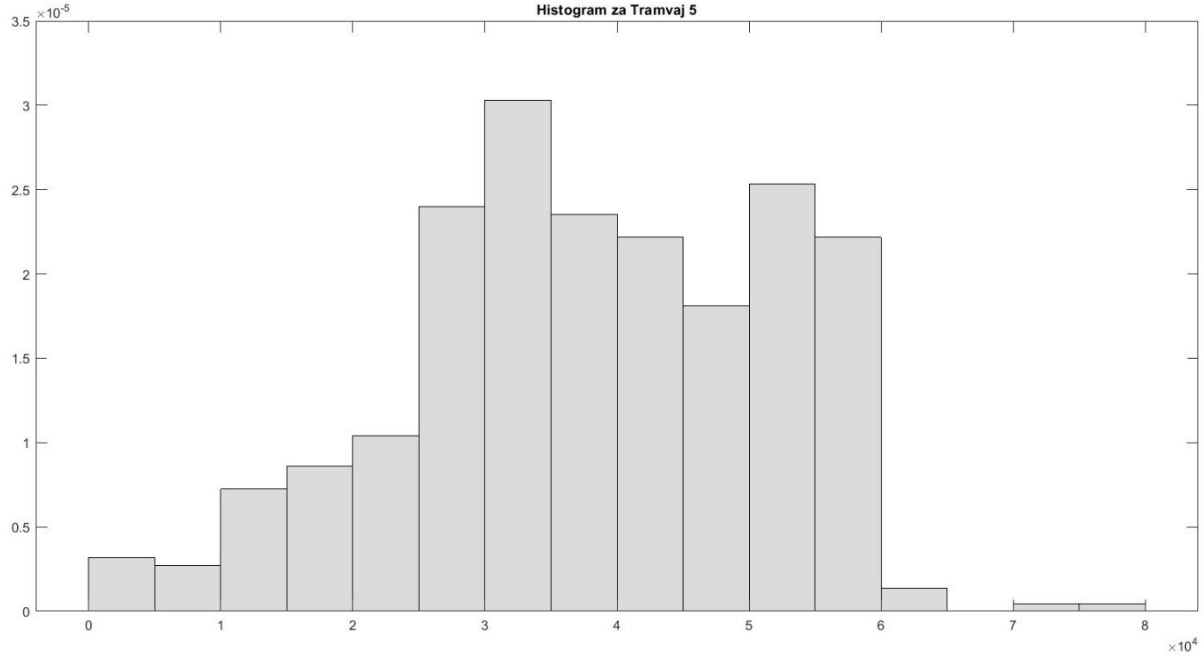

Slika P.2.21 *Histogram za zapis Tramvaj 5 (4G mreža).*

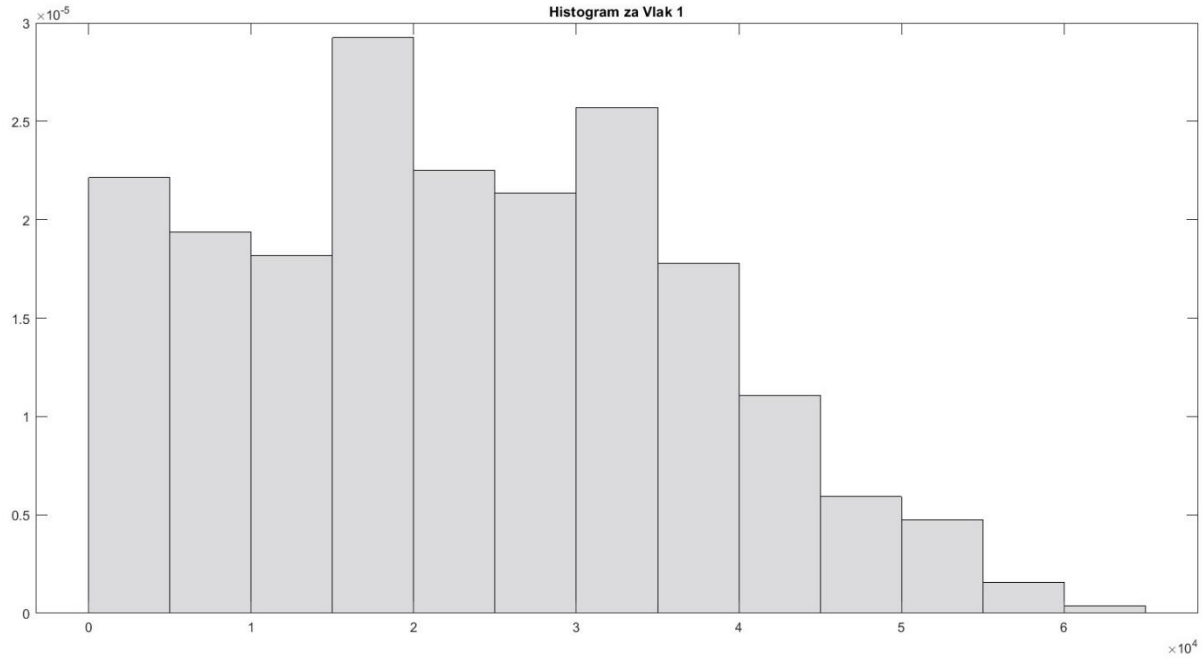

Slika P.2.22 *Histogram za zapis Vlak 1 (4G mreža).*

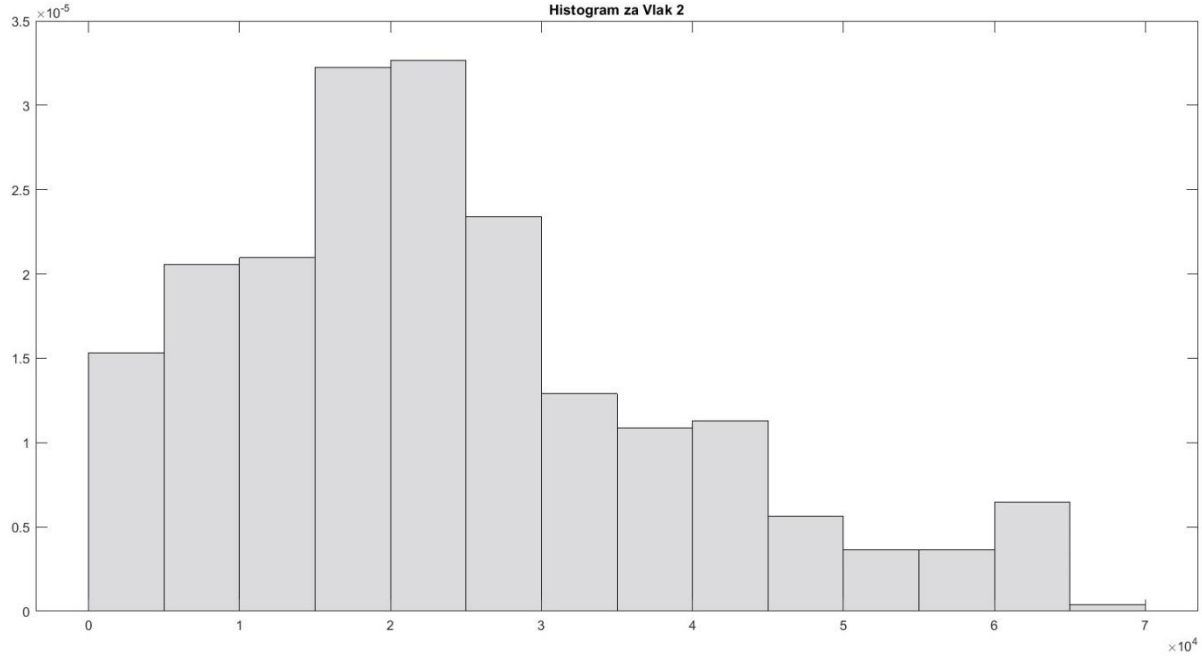

Slika P.2.23 *Histogram za zapis Vlak 2 (4G mreža).*

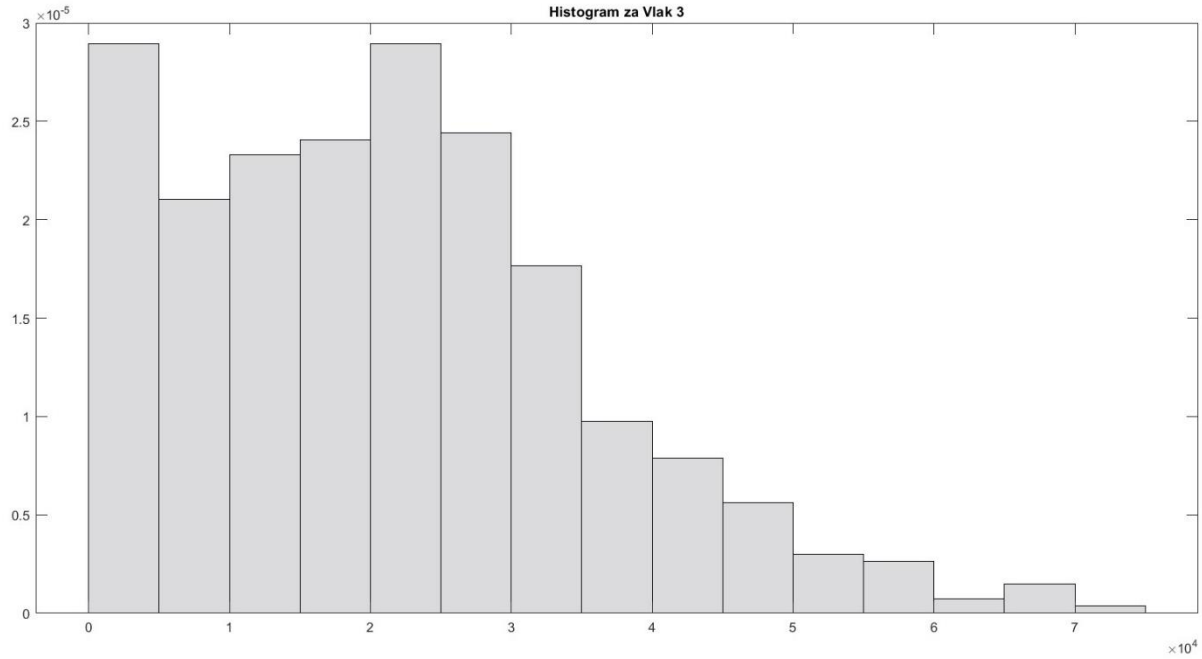

Slika P.2.24 *Histogram za zapis Vlak 3 (4G mreža).*