

Videostručanje u 5G mrežama

Babić, Mislav

Master's thesis / Diplomski rad

2025

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://um.nsk.hr/um:nbn:hr:200:851779>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom](#).

Download date / Datum preuzimanja: **2025-03-20**

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 diplomski studij Elektrotehnika

VIDEOSTRUJANJE U 5G MREŽAMA

Diplomski rad

Mislav Babić

Osijek, 2025.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**Obrazac D1: Obrazac za ocjenu diplomskog rada na sveučilišnom diplomskom studiju****Ocjena diplomskog rada na sveučilišnom diplomskom studiju**

Ime i prezime pristupnika:	Mislav Babić
Studij, smjer:	Sveučilišni diplomski studij Elektrotehnika, Komunikacije i Informatika
Mat. br. pristupnika, god.	D-1481, 07.10.2022.
JMBAG:	0165081186
Mentor:	prof. dr. sc. Snježana Rimac-Drlje
Sumentor:	
Sumentor iz tvrtke:	
Predsjednik Povjerenstva:	doc. dr. sc. Denis Vranješ
Član Povjerenstva 1:	prof. dr. sc. Snježana Rimac-Drlje
Član Povjerenstva 2:	dr. sc. Jelena Šuljug
Naslov diplomskog rada:	Videostrujanje u 5G mrežama
Znanstvena grana diplomskog rada:	Telekomunikacije i informatika (zn. polje elektrotehnika)
Zadatak diplomskog rada:	Videostrujanje je usluga koja zauzima sve veći udio ukupnog internet prometa, a posebno zahtjevno je ostvarivanje ove sluge putem mobilnih mreža. Mobilni korisnik prolazi kroz područja s velikom razlikom u propusnosti mreže, tako da aplikacija za videostrujanje mora dinamički mijenjati parametre prenesenog videa u ovisnosti o trenutnoj propusnosti. 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 5G
Datum ocjene pismenog dijela diplomskog rada od strane mentora:	13.02.2025.
Ocjena pismenog dijela diplomskog rada od strane mentora:	Izvrstan (5)
Datum obrane diplomskog rada:	26.2.2025.
Ocjena usmenog dijela diplomskog rada (obrane):	Izvrstan (5)
Ukupna ocjena diplomskog rada:	Izvrstan (5)
Datum potvrde mentora o predaji konačne verzije diplomskog rada čime je pristupnik završio sveučilišni diplomski studij:	26.02.2025.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK****IZJAVA O IZVORNOSTI RADA**

Osijek, 26.02.2025.

Ime i prezime Pristupnika:	Mislav Babić
Studij:	Sveučilišni diplomski studij Elektrotehnika, Komunikacije i informatika
Mat. br. Pristupnika, godina upisa:	D-1481, 07.10.2022.
Turnitin podudaranje [%]:	7

Ovom izjavom izjavljujem da je rad pod nazivom: **Videostrujanje u 5G mrežama**

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
2. POSTOJEĆE METODE OPTIMIZACIJE VIDEOSTRUJANJA	3
3. PRILAGODLJIVO VIDEOSTRUJANJE.....	11
3.1. MPEG DASH norma	13
3.1.1. Algoritam za prilagodljivo videostrujanje	17
3.2. Metrike kvalitete videostrujanja	18
3.3. Videostrujanje u 5G mobilnim mrežama	21
4. UMJETNO GENERIRANJE 5G ISPITNIH MREŽNIH ZAPISA	24
4.1. Statistička analiza propusnosti	24
4.1.1. Baza podataka.....	24
4.1.2. Matematički modeli.....	25
4.1.3. Programsko rješenje	27
4.1.4. Rezultati statističke analize propusnosti	30
4.2. Generiranje sintetičkih mrežnih zapisa	46
4.3. Usporedba izmjerenih i sintetičkih mrežnih zapisa.....	48
5. ZAKLJUČAK.....	60
LITERATURA	61
SAŽETAK.....	64
ABSTRACT	65
ŽIVOTOPIS.....	66
PRILOZI	67
P.3.1. Izvorni programski kod	67
P.4.1. Statistička analiza	68
P.4.2. Sintetički mrežni zapisi	82

1. UVOD

Videostrujanje je kontinuirani prijenos videozapisa od poslužitelja do klijenta koji korisnicima omogućuje gledanje videozapisa bez potrebe za preuzimanjem. To je usluga koja u suvremenom svijetu zauzima sve veći udio ukupnog internetskog prometa. Videostrujanje uključuje sadržaj poput filmova, TV emisija, *YouTube* videozapisa te prijenosa uživo (engl. *live streaming*). Razvojem usluge videostrujanja dolazi do globalnog porasta broja pretplatnika na *streaming* platforme kao što su *Netflix*, *Max*, *Amazon Prime Video* i *Disney+*. Porastu popularnosti videostrujanja pridonijele su prednosti kao što je prikazivanje sadržaja na zahtjev korisnika (engl. *video on-demand* - VoD), visoka rezolucija prikazivanja u odnosu na zemaljsku televiziju, mogućnost odabira sadržaja kojeg korisnik želi gledati u tom trenutku te koju platformu za strujanje želi plaćati. Također jedan od najvažnijih razloga rasta jest širenje širokopojsnih internetskih mreža te napredak u tehnologiji prijenosa podataka. Veća dostupnost brze i stabilne internetske veze omogućila je korisnicima pristup visokokvalitetnim videosadržajima koji se prenose u stvarnom vremenu.

Implementacija videostrujanja u mobilnim mrežama nosi velike tehničke izazove. Najveći izazov jest postići zadovoljavajuću kvalitetu usluge (engl. *Quality of Service*- QoS) mobilnom korisniku koji prolazi kroz područja s različitim uvjetima u mreži. Kretanjem korisnika kroz prostor mijenja se propusnost mreže (engl. *bandwidth*), dolazi do pojave kašnjenja (engl. *delay*) i kolebanja (engl. *jitter*) te gubitaka paketa (engl. *packet loss*) što zajedno uzrokuje nedovoljnu popunjenost međuspremnika (engl. *buffer*) i dovodi do pojave zapinjanja videa (engl. *buffering*). Prethodno navedeni problemi negativno utječu na kvalitetu korisničkog iskustva. Istraživanja su pokazala da uz QoS parametre vrlo važnu ulogu ima i kvaliteta korisničkog iskustva (engl. *Quality of Experience* – QoE). Tehnologija prilagodljivog videostrujanja mora pružiti korisniku najbolju moguću ravnotežu između QoE i mogućnosti neprekidnog strujanja videosignala. Zbog toga je vrlo važna implementacija MPEG standarda i algoritma za prilagodbu prijenosne brzine (engl. *Adaptive Bitrate* - ABR). MPEG standard za dinamičko prilagodljivo strujanje videosignala (engl. *MPEG Dynamic Adaptive Streaming over HTTP* – MPEG DASH) razvijen je kako bi se osiguravalo krajnjim korisnicima glatko strujanje s najmanjim mogućim brojem prekida u reprodukciji bez ovisnosti o sklopovlji s korisničke strane. Algoritmi za prilagodbu prijenosne brzine na temelju uvjeta u mreži te popunjenosti međuspremnika odlučuju koja će se reprezentacija videozapisa korisniku prikazati tako da kvaliteta usluge ostane visoka. Visoka je kvaliteta usluge osiguranje reprodukcije videosadržaja s najkraćim mogućim razdobljem pokretanja, najmanjim

mogućim brojem zaustavljanja i prebacivanja na nižu razinu kvalitete. Kako bi se razvili pouzdani i kvalitetni algoritmi za prilagodbu prijenosne brzine potrebni su mrežni ispitni zapisi (engl. *network traces*) pomoću kojih je moguće testiranje algoritama. Mogu biti umjetno generirani odnosno sintetički ili izmjereni koji su dobiveni snimanjem realnog prometa u komunikacijskim mrežama.

U ovom diplomskom radu stavljen je naglasak na stvaranje umjetno generiranih 5G mrežnih ispitnih zapisa za testiranje algoritma za prilagodbu prijenosne brzine. Napravljena je statistička analiza izmjerenih 5G mrežnih ispitnih zapisa kako bi se dobili teorijski modeli za generiranje umjetnih mrežnih zapisa. Kroz poglavlja rada opisana je MPEG DASH norma, videostrujanje preko mobilnih mreže te praktični dio koji se sastoji od statističke analize baza 5G mrežnih ispitnih zapisa te usporedba sintetičkih mrežnih zapisa s izmjerenim vrijednostima propusnosti.

2. POSTOJEĆE METODE OPTIMIZACIJE VIDEOSTRUJANJA

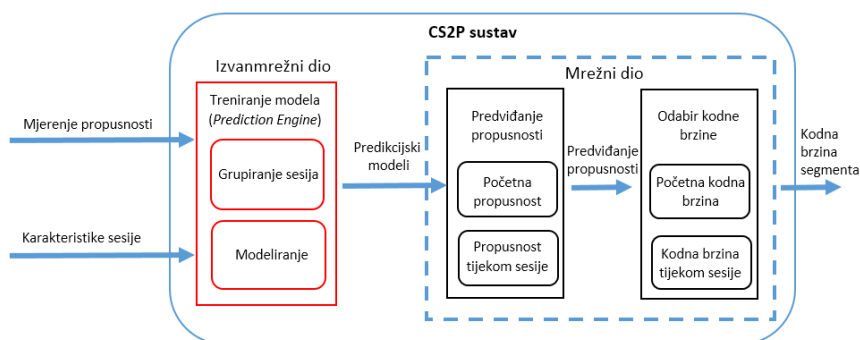
Napretkom u suvremenim bežičnim mrežama i mobilnim pametnim uređajima povećava se broj pretplatnika usluga za videostrujanje. Mrežni operateri i pružatelji usluga imaju zadatak održati visoku razinu korisničkog iskustva bez obzira na veličinu sustava. Veliki izazov predstavlja mobilni korisnik koji prolazi kroz različite mrežne uvjete što za posljedicu ima promjenjivu propusnost. Promjenjiva propusnost uzrokuje zastoje u reprodukciji i nagla prebacivanja razine kvalitete, što negativno utječe na korisničko iskustvo. Ključnu ulogu u poboljšanju korisničkog iskustva imaju algoritmi za prilagodljivo videostrujanje koji su vrlo aktivno područje istraživanja. Algoritmi za prilagodljivo videostrujanje analiziraju statističko kretanje propusnosti te na taj način predviđaju prilagodbu kvalitete videosignala dostupnoj propusnosti mreže. Statistička analiza podataka o propusnosti pruža uvide o ponašanju mreže te omogućava poduzimanje mjera koje smanjuju negativne efekte promjenjive propusnosti. Za provedbu kvalitetne i sustavne analize potrebne su baze podataka s mrežnim zapisima koji mogu biti realni odnosno izmjereni te umjetno generirani odnosno sintetički. Prednost izmjerenih mrežnih zapisa jest da su prikupljeni u realnim uvjetima te najbolje opisuju stvarno ponašanje mreža, ali postoji nedostatak kvalitetnih i javno dostupnih baza podataka te sami izmjereni zapisi imaju promjenjive statističke karakteristike koje nisu pogodne za sustavnu analizu. Zbog toga je potrebno generirati umjetne mrežne zapise koji su pogodni za kvalitetnu i sustavnu analizu. U ovom poglavlju kroz dostupnu literaturu razmotrene su postojeće metode optimizacije videostrujanja s naglaskom na prikupljanje izmjerenih mrežnih zapisa, statističku analizu propusnosti te metode modeliranja sintetičkih mrežnih zapisa.

U 2013. godini objavljen je rad [1] koji stavlja naglasak na prikupljanje i analizu mrežnih zapisa. Provedena su mjerenja propusnosti u realnim uvjetima 3G mreže tijekom adaptivnog HTTP videostrujanja. Prilikom snimanja mrežnih zapisa korištene su prometne rute u glavnom gradu Norveške, Oslu, s različitim prijevoznim sredstvima poput metroa, autobusa, trajekta, tramvaja, vlaka i automobila. Interval mjerenja iznosio je jednu sekundu te je ukupno snimljeno 86 mrežnih zapisa. Svaki mrežni zapis sadrži vremensku tablicu, podatke o GPS koordinatama i izmjereni broj preuzetih bajtova. U slučaju kada se koristi metro javni prijevoz te se on nalazi iznad zemlje prosječna propusnost iznosi 1 Mbit/s, a kada ruta pređe pod zemlju u tunele dolazi do pucanja internetske veze. Prilikom korištenja trajekta pokazalo se da je signal najjači kada se trajekt nalazi blizu kopna te se postiže prosječna propusnost od 2 Mbit/s. Udaljavanjem od kopna smanjuje se snaga i kvaliteta signala. Tijekom snimanja u tramvaju propusnost nije prelazila 1 Mbit/s. Iz ovih rezultata zaključeno je da propusnost ima velike oscilacije ovisno o brzini kretanja mobilnog korisnika i geografskom položaju.

U [2] istraživači su također provodili automobilima vlastito prikupljanje podataka o propusnosti u Australiji na području grada Sydneya. Istraživanje je provedeno u dva vremenska razdoblja. Prvo 2008. godine gdje su prikupljeni podaci iz 3G mreže te drugo 2015. godine s prikupljanjem podataka iz 3G i 4G mreže. Poseban naglasak stavljen je na ponavljanje mjerenja duž unaprijed definiranih ruta čime se postiže veća preciznost i pozuđanost podataka. U provedenom istraživanju 2008. godine ukupno je prikupljeno 56 754 uzorka pri čemu svaki uzorak sadrži podatke o vrijednosti propusnosti, geografskom položaju uređaja, vremena mjerenja, vremena dohvaćanja određene datoteke. Godine 2015. pomoću dva različita *Android* uređaja prikupljeno je ukupno 15 624 uzoraka unutar 72 putovanja u različito doba dana. Autori navode da je ova baza podataka propusnosti pogodna za statističke analize ponašanja mreže koja omogućava optimizaciju sustava različitih usluga te boljeg korisničkog iskustva.

Uz provedbu prikupljanja podataka o propusnosti u 4G mrežama u istraživanju [3] predstavljeno je rješenje za strujanje videosignala uživo koje se temelji na HTTP/2 *push* pristupu. Ovo rješenje koristi H.265/HEVC koder koji omogućuje smanjenje prijenosne brzine te smanjenje pojedinog segmenta. Mjerenje dostupne propusnosti provedeno je u gradu Gentu u Belgiji 2016. godine s ciljem testiranja predloženog rješenja za smanjenje RTT (engl. *Round Trip Time*) ciklusa za dohvaćanje pojedinog segmenta videozapisa. Mjerenje je provedeno na više unaprijed definiranih ruta pri čemu je korišten pristup preuzimanja velike datoteke putem HTTP protokola. Prilikom mjerenja korištena su različita prijevozna sredstva poput bicikla, tramvaja, vlaka, autobusa, automobila te pješaćenje. Korišten je poslužitelj-klijent pristup pri čemu je klijent *Android* aplikacija na pametnom telefonu *Huawei P8 Lite*. Poslužiteljski dio sastojao se od konfiguriranog poslužitelja na infrastrukturi *iLab.t Virtual Wall* povezan preko 100 Mbit/s Ethernet veze. Ukupno je prikupljeno 40 mrežnih zapisa tijekom pet sati praćenja. Zabilježeni su podaci o GPS koordinatama, broj primljenih bajtova od posljednje podatkovne točke i broj milisekundi od posljednje podatkovne točke. Rezultati pokazuju da se za odabranu rutu u automobilu izmjerena propusnost smanjuje kada je povezanost ograničena zbog prepreka poput tunela, velikih zgrada te loše pokrivenosti. Autori navode da vrsta prijevoza i odabrani put snažno utječu na raspoloživu propusnosti te za primjer uspoređuju prosječnu propusnost vlaka po gradu koja je iznosila $22,8 \pm 14,6$ Mbit/s dok je za automobil vožen obilaznicom iznosila $33,9 \pm 15,8$ Mbit/s. Ukupna izmjerena propusnost kretala se u rasponu od 0 do 111 Mbit/s.

Sljedeće rješenje objavljeno u [4] donosi detaljnu analizu karakteristika propusnosti u skupu podataka s preko 20 milijuna sesija te predstavlja vlastito rješenje za sustav predviđanja propusnosti naziva CS2P (engl. *Cross Session Stateful Predictor*). Podaci su prikupljeni na principu klijent-poslužitelj s uspostavljenom HTTP vezom te su preuzimani videosegmenti bili kodirani s fiksnom kodnom brzinom koju korisnik može birati. Unutar svake sesije bilježena je prosječna propusnost u razdoblju od šest sekundi. Točna predviđanja propusnosti mogu značajno poboljšati kvalitetu iskustva korisnika. Istaknute su dvije faze u kojima je potrebno izračunati točna predviđanja propusnosti, a to je faza pokretanja videostrujanja te faza tijekom videostrujanja. Pri pokretanju videostrujanja algoritmi za prilagodljivo strujanje odabiru odgovarajuću početnu kodnu brzinu te obično započinju s malom kodnom brzinom i polako podižu kvalitetu videosadržaja kako ne bi došlo do pražnjenja međuspremnika i ostalih negativnih posljedica. Također točna predviđanja tijekom videostrujanja pozitivno utječu na pružanje bolje kvalitete iskustva korisnika. Autori analiziraju veliku bazu podataka dobavljača komercijalnih videozapisa u Kini naziva iQIYI. Analizom dolaze do četiri opažanja. Prvo opažanje navodi da slične sesije koje dijele iste značajke kao što su lokacija i IP adresa obično imaju slične početne i prosječne vrijednosti propusnosti te slične varijacije propusnosti. Analizom varijacija u propusnosti unutar više sesija videostrujanja zaključeno je da propusnost ima značajne varijacije unutar pojedine sesije te zbog toga problem odabira prijenosne brzine nije trivijalan. Drugo opažanje navodi da evolucija propusnosti unutar sesije pokazuje trajne karakteristike koje je moguće kategorizirati što dovodi do poboljšanog predviđanja propusnosti. U navedenom primjeru statističkom analizom autori su uspjeli mrežni zapis propusnosti podijeliti u 11 segmenata prema zajedničkim karakteristikama te se pokazalo da unutar svakog stanja propusnost je uglavnom distribuirana prema Gaussovoj raspodjeli. Treće opažanje navodi da sesije sa sličnim značajkama obično pokazuju slične početne uvjete propusnosti i obrasce evolucije propusnosti. Na navedenim primjerima zaključeno je da „bliski susjedi“ odnosno sesije koje imaju iste značajke dijele slično ponašanje propusnosti. Slične sesije moguće je kategorizirati u različite klastere prema IP adresi klijenta pomoću kojih su dobivena tri različita klastera. Iz ovih rezultata vidljivo je da sesije u različitim klasterima imaju značajne razlike u početnoj propusnosti te da unutar svakog klastera veliki broj sesija ima sličnu početnu propusnost. Posljednje je opažanje da jednostavni modeli nisu dovoljno prilagodljivi da mogu uspješno odlučivati o sličnosti različitih sesija te se pokazalo da odnos između karakteristika sesije i propusnosti može biti složen. Autori navode da na propusnost često istodobno utječe više čimbenika kao što su opterećenje poslužitelja, zagušenje i loš signal, što dovodi do zaključka da sesije koje dijele jednaku značajku možda neće imati slično ponašanje propusnosti.




Slika 2.1. Shematski prikaz CS2P sustava [4]

Na temelju prethodno navedenih opažanja autori predstavljaju rješenje naziva CS2P čiji je cilj poboljšanje odabira i prilagodbe brzine prijenosa što je prikazano slikom 2.1. CAS2P sustav posrednik je između poslužitelja koji pohranjuje videosadržaj te klijenta koji reproducira isti. Sustav koristi algoritam koji podatke o propusnosti koristi za učenje početnog prediktora propusnosti, klasteriranja sličnih sesija te učenje prediktora tijekom strujanja. CAS2P koristi takozvani Prediction Engine koji izrađuje modele predviđanja pomoću prethodno zabilježenih podataka propusnosti. Prediction Engine koristi se izvanmrežno te se sastoji od modula za klasteriranje te modela za učenje. Modul za klasteriranje identificira sesije koje će pokazati slične obrasce ponašanja propusnosti. Na svakom klasteru modul proračunava srednju vrijednost kako bi predvidio početnu propusnost. Za poboljšanje predviđanja tijekom videostrujanja algoritam uči Hidden-Markov model za svaki klaster. Uz Prediction Engine u mrežnom načinu rada koriste se dva koraka koji predviđaju propusnost te odabiru pogodnu prijenosnu brzinu. S ovim rješenjem autori su uspjeli su nadmašiti postojeće pristupe predviđanju propusnosti od 40 % do 50 % u smislu srednje pogreške predviđanja propusnosti za obje faze procesa videostrujanja.

U istraživanju [5] predloženo je rješenje koje za cilj ima predviđanje propusnosti mreže pomoću prethodnih mjerenja. Autori pristupaju analiziranju propusnosti pomoću ARIMA (engl. *Autoregressive Integrated Moving Average*) i FARIMA (engl. *Fractional Autoregressive Integrated Moving Average*) modela. Ovaj postupak temelji se na predviđanju propusnosti dugog dometa odnosno LDR (engl. *Long-Range Dependence*) te ovaj pristup ne zahtijeva izmjene na mrežnoj infrastrukturi. Navedeni modeli koriste se na mrežnim zapisima dobivenim iz mjerenja propusnosti stvarne mobilne mreže. U ovom radu stavljen je naglasak na procijeni karakteristike te izrađivanju modela mrežnog prometa koji prima klijentska aplikacija. Budući da se usluga videostrujanja temelji na preuzimanju videosegmenata autori su izradili bazu podataka na temelju preuzimanja podataka pri čemu je izmjereno pet mrežnih zapisa u trajanju između 34 i 48 minuta. Izračunate su distribucije intenziteta prometa, autokorelacija te provedeno testiranje ovisnosti o LRD-u. Pomoću tih rezultata prilagođeni su ARIMA i FARIMA modeli. ARIMA i FARIMA služe


za modeliranje podataka u vremenskoj domeni. ARIMA modeli koriste cjelobrojno diferenciranje te jednostavniji za primjenu. Imaju mogućnost opisivanja linearne i kratkotrajne ovisnosti koje se pojavljuju u podacima u vremenskoj domeni. Primjenom na podatke s LRD karakteristikama pokazuju slabe performanse. Kako bi se postigla bolja točnost modela potrebno je koristiti FARIMA model. Taj model koristi frakcionalno diferenciranje zbog čega pokazuje bolje rezultate na podacima s dugoročnom ovisnošću. Nedostatak je FARIMA modela što je računalno zahtjevniji što znači da koristi kompliciranije algoritme za procjenu parametara. Rezultati analize pokazuju da FARIMA model postiže mnogo bolje prosječne rezultate u usporedbi s modelom ARIMA. Varijabilnost rezultata veća je za FARIMA modele te se pojavljuju slučajevi kada su procjene netočne i pogoršavaju kvalitetu strujanja.

Glavni je cilj pružatelja usluga videostrujanja omogućavanje isporuke videosadržaja s visokim QoE za sve korisnike. Autori istraživanja [6] navode da suvremeni ABR algoritmi ne pokrivaju dovoljno veliki broj mrežnih uvjeta te zbog toga pokazuju loše performanse za pojedine korisnike. ABR algoritmi moraju imati podršku za mnogo različitih vrsta mreža od kućnih WiFi mreža do širokopojasnih mreža. Zbog toga nailaze na različite mrežne uvjete poput propusnosti s velikim varijacijama u kojima je srednja vrijednost propusnosti dvostruko manja nego maksimalne vrijednosti. Također mnogo ABR algoritama koristi jednostavne pristupe za predikciju propusnosti te statičke konfiguracije ABR parametara. Postoje različite konfiguracije parametara poput konzervativnog, umjerenog ili agresivnog koje su prikladne za određene uvjete propusnosti. Zbog toga je potrebno implementirati dinamičke promjene konfiguracija u ovisnosti o uvjetima u mreži poput rješenja predstavljenog u [6] naziva *Oboe*. *Oboe* omogućava automatsko podešavanje ABR parametara za različite mrežne uvjete. Sastoji se od izvanmrežnog i mrežnog dijela. Izvanmrežni dio sadrži module koji unaprijed izračunavaju najbolju konfiguraciju parametara za određeno stanje mreže iz prethodno prikupljenih mrežnih zapisa.



Slika 2.2. Izvanmrežni algoritam Oboe sustava [6]

Slika 2.2. predstavlja izvanmrežni algoritam *Oboe* sustava koji se sastoji od triju modula evaluator konfiguracije (engl. *ConfigEvaluator*), virtualni *player* (engl. *VirtualPlayer*) i modul za odabir konfiguracije (engl. *ConfigSelector*). Evaluator konfiguracije kao ulazne podatke prima izmjerene mrežne zapise propusnosti koje dijeli na manje vremenske intervale nazvane mrežnim stanjima. Mrežno stanje karakterizira svojstvo stacionarnosti odnosno stanje sa zajedničkim statističkim svojstvima. Mrežna stanja izdvojena su pomoću metode detekcije točaka promjene (engl. *change point detection*). Ova metoda bilježi točke u kojima se statistička svojstva podatka poput srednje vrijednosti naglo mijenjaju. Nakon što su dobivena mrežna stanja, pomoću njih generirani su sintetički mrežni zapisi temeljeni na Gaussovoj raspodjeli. Sintetički mrežni zapisi pokazuju slična statistička svojstva kao i stvarni te je odlučeno da se u ostatku izvanmrežnog procesa analize koriste sintetički mrežni zapisi. Nakon toga podaci se šalju u virtualni *player*, modul koji oponaša ponašanje stvarnog *videoplayera* bez preuzimanja stvarnih videosegmenata. Ulazni su podaci mrežni zapisi, a kao izlazne podatke izračunava vektore QoE metrike sesije za određene parametre ABR algoritma. Virtualni *player* sadrži implementiranu logiku ABR algoritma te također sadrži specifikacije izdavača za veličine međuspremnika, brzine prijenosa i veličine videosegmenata. Virtualni *player* šalje skup vektora QoE vrijednosti s odgovarajućim vrijednostima parametara modul za odabir konfiguracije koji uspoređuje različite konfiguracije parametara i gradi mapu (engl. *ConfigMap*) najboljih vrijednosti.



Slika 2.3. Mrežni algoritam *Oboe* sustava [6]

Mrežni dio prikazan na slici 2.3. prima podatke od klijentske aplikacije o propusnosti te ih šalje u detektor promjena propusnosti (engl. *Change Detector*). Ovaj modul koristi algoritam detekcije točaka promjena pomoću kojih su označena mjesta promjena propusnosti. Provodi se segmentacija u mrežna stanja te se proračunava srednja vrijednost i standardna devijacija. Usto *Oboe* sustav koristi podatke iz prethodno generiranog *ConfigMap*-a. Modul rekonfiguracije (engl. *Reconf Engine*) provodi ažuriranje ABR konfiguracije na temelju novog stanja mreže te na taj način ABR algoritam donosi odluku o promjeni prijenosne brzine. Korištenjem *Oboe* sustava značajno su uspjeli poboljšati postojeće ABR algoritme za gotovo 80 % sesija.

Povećanjem pokrivenosti i dostupnosti mobilnih uređaja koji podržavaju 5G, istraživači se okreću prikupljanju 5G mrežnih zapisa koji se mogu koristiti za daljnje analize ponašanja nove generacije mobilne mreže. U objavljenom istraživanju [7] 2020. godine autori izvode mjerenja kako bi se zabilježile promjene u uvjetima radijskog kanala prilikom strujanja videosadržaja preko 5G mobilne mreže. Podaci su prikupljeni prilikom strujanja videozapisa i preuzimanja datoteke te sa statičnim i mobilnim korisnikom. Za strujanje videozapisa korištene su dvije platforme za videostrujanje *Amazon Prime Video* i *Netflix* pomoću kojih je strujan animirani sadržaj i videosadržaj uživo. Ovi podaci snimljeni su pomoću *Android* aplikacije za praćenje mreže naziva *G-NetTrack Pro*. Snimljena su ukupno 83 mrežna zapisa. Rezultati mjerenja pokazuju karakteristike da platforma *Netflix* troši značajno više propusnosti u usporedbi s *Amazon Prime* platformom u oba scenarija mobilnosti korisnika. Autori navode da kontinuirano preuzimanje datoteka pokazuje najveću prosječnu propusnost te veliki raspon njezine vrijednosti. U usporedbi s preuzimanjem datoteka strujanje platformama *Netflix* i *Amazon Prime* koristi znatno manje propusnosti. Iz rezultata je vidljivo da platforma *Netflix* koristi veću kvalitetu kodiranja i veće veličine videosegmenata. Usto količina propusnosti ograničena je maksimalnom kvalitetom kodiranog videosadržaja. Karakteristika preuzimanja videosegmenata je skokovita te se preuzimanje odvija samo tijekom faze punjenja međuspremnika. Uz prikupljene podatke o propusnosti u 5G mreži autori predstavljaju 5G/mmWave simulacijsko okruženje u kojem je moguće provoditi simulaciju 5G mreže koja se sastoji od korisničke opreme (engl. *User Equipment* - UE) te baznih stanica. Područje simulacije sadrži mnogo UE koji su nasumično raspoređeni te je korisnicima omogućena promjena njihova broja. Korisnik također može mijenjati brzinu kretanja UE-a. Ovo simulacijsko okruženje omogućuje analiziranje snimljenih mrežnih zapisa te utvrđivanje odnosa parametara kvalitete kanala između mreže i klijenta.

Za optimizaciju različitog prometa kroz mobilnu mrežu potrebno je provoditi analize na vrlo prometnim pravcima i rutama. U [8] stavljen je naglasak na snimanje ponašanja 4G mreže na unaprijed poznatim rutama javnog prijevoza. Navedeno je da putnici u javnom prijevozu generiraju ogromne količine mobilnog prometa zbog upotrebe aplikacija koje troše veliku količinu podatka kao što je videostrujanje. Snimanje takvih ruta omogućava izradu skupa podataka različitih parametara kvalitete. U ovom istraživanju baza podataka sastoji se od 30 ponovljenih vožnji autobusom javnog prijevoza u tri različita doba dana u trajanju od jednog sata. Ukupno je prikupljeno više od 190 tisuća podataka koje predstavljaju 30 ponovljenih snimanja. Analizom rezultata autori zaključuju da postoje značajne promjene u mrežnoj povezanosti i propusnosti u različito doba dana. Pokazano je da u 9:00 i 12:00 sati srednja snaga signala i mjerena propusnost


ima značajno veće vrijednosti nego u 18:00 sati. Također neke lokacije duž autobusne rute pokazuju značajno nižu snagu signala i vrijednosti propusnosti loše pokrivenosti baznim stanicama u usporedbi s drugim područjima duž autobusne rute.

Istraživanje predstavljeno u [9] ima cilj poboljšati postojeće ABR algoritme u mobilnim mrežama kako bi se postigle točnije predikcije propusnosti. Autori provode prikupljanje mrežnih zapisa propusnosti u 4G mobilne mreže. Mjerenje je trajalo više od četiri mjeseca u dvama kineskim gradovima, Pekingu i Suzhou. Pokriveno je mnogo okruženja poput otvorenih prostora koji uključuju parkove, ulice i igrališta te unutarnjih lokacija kao što su uredi, blagovaonice i laboratoriji. Također podaci su prikupljeni vozeći se autobusom po unaprijed poznatim rutama. Mjerenje je provedeno pomoću mobilnih telefona koji predstavljaju klijentsku stranu. Rezultati mjerenja pokazuju da propusnost mobilnih mreža ima nagle i iznenadne promjene vrijednosti. Podaci prikupljeni vožnjom u autobusu pokazuju da se propusnost ravnomjerno distribuira između 0 do 25 Mbit/s te u rasponu od 3 do 12 Mbit/s pokazuju stacionarno svojstvo. U zatvorenim prostorima propusnost postiže visoke vrijednosti u rasponu od 14 Mbit/s do 25 Mbit/s. Na otvorenim prostorima propusnost se kreće od 0 do 20 Mbit/s sa stacionarnosti između 0 i 8 Mbit/s. Na navedenim podacima provedena je statistička analiza gdje je utvrđeno Markovljevo svojstvo za specifično okruženje. Markovljevo svojstvo predstavlja svojstvo stohastičkog procesa bez memorije gdje buduća stanja istog procesa ovise samo o sadašnjem stanju bez utjecaja prethodnih stanja. Ovo svojstvo može se iskoristiti za točniju predikciju propusnosti u ABR algoritmima. Nedostatak je ovog pristupa da klijentske aplikacije ne bilježe informacije o okruženju u kojem se korisnik nalazi te je potrebno iz samih podataka o propusnosti kategorizirati lokacije. Budući da se Markovljevo svojstvo pokazuje za određeno okruženje moguće ga je iskoristiti za identifikaciju okruženja u kojem se nalazi korisnik. Kategoriziranje je provedeno pomoću algoritma klasteriranja *k-means*, *hierarchical* i *birch* algoritma. Također predstavljeno je novo rješenje nazvano NEIVA koja provodi predviđanje propusnosti te nadograđuje suvremeni ABR algoritam naziva MPC (engl. *Model Predictive Control*). NEIVA se sastoji od dvaju dijelova, mrežnog i izvanmrežnog. Izvanmrežni dio sastoji se od modula koji trenira Markovljev model na prethodno izmjerenim mrežnim zapisima određenog okruženja i modula koji služi kao identifikator okruženja. Prilikom same reprodukcije videozapisa NEIVA koristi mrežni dio koji unutar sebe sadrži modele trenirane u izvanmrežnom dijelu. Provodi se identifikacija okruženja u kojem se korisnik nalazi te primjenjuje Markovljev model specifičan za okruženje za predviđanje buduće propusnosti. Rezultati pokazuju da NEIVA postiže 20-25 % povećanja točnosti predviđanja propusnosti u odnosu na osnovne prediktore i 11-20 % poboljšanja QoE u odnosu na MPC.

3. PRILAGODLJIVO VIDEOSTRUJANJE

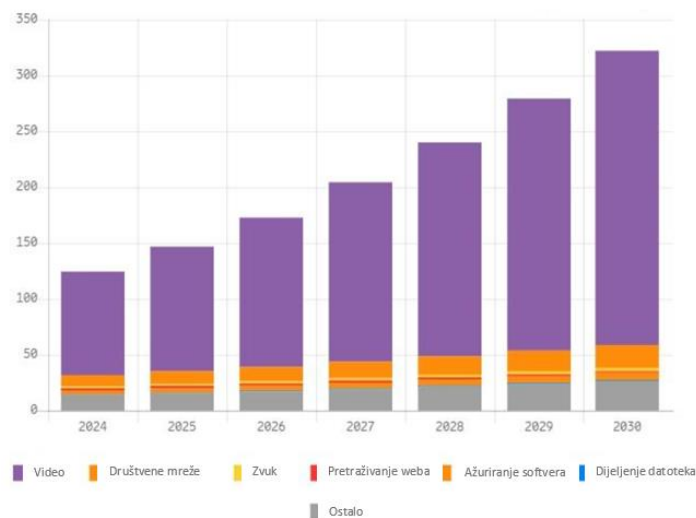
Kako bi se moglo govoriti o tehnologiji strujanja videosadržaja putem interneta potrebno je definirati pojam strujanja. Strujanje (engl. *streaming*) digitalnog sadržaja općenito je pružanje ili slanje pohranjenog sadržaja na zahtjev udaljenih korisnika [10]. To je kontinuirani tok digitalnih podataka koji se prenose od poslužitelja do krajnjeg korisnika bez značajnog kašnjenja. Kako bi se usluga strujanja omogućila korisnik mora imati ostvarenu internetsku vezu putem koje može slati odnosno primiti podatke s platformi specijaliziranih za strujanje digitalnog sadržaja. Strujanje se razlikuje od preuzimanja (engl. *download*) tako što se sadržaj prenosi na korisnički uređaj, ali se ne pohranjuje u njegov prostor za pohranu podataka [10].

Strujanje multimedijskog sadržaja internetom započelo je 1990-ih godina s nekoliko eksperimentalnih prijenosa uživo. U istraživačkom centru *Xerox Palo Alto* razvijala se tehnologija strujanja *MBone* (engl. *Multicast Backbone*) te je razvojni tim htio pokazati mogućnosti *MBone* tehnologije tako što je u lipnju 1990. godine. omogućio *rock* bendu *Severe Tire Damage* prijenos njegovog koncerta uživo. Taj događaj ostao je zabilježen u povijesti kao prvi prijenos glazbenog koncerta uživo [11]. Mediji i platforme za videostrujanje nastavili su dobivati popularnost u 2000-ima godinama. Prva popularna *web*-stranica za videostrujanje postala je *YouTube* koji je osnovan je 2005. godine. Zatim 2007. godine *Netflix* je uveo usluge videostrujanja koje su pretplatnicima omogućile pristup sadržaju izravno internetskim putem [12]. Razvojem tehnologije za videostrujanje dolazi do pojave usluga kao što su *Skype*, *WhatsApp* i *Viber* pomoću kojih je moguće ostvarivati videopozive na velikim udaljenostima s vrlo prihvatljivim kvalitetama. Televizijske usluge počinju koristiti televizijski internetski protokol (engl. *Internet Protocol Television* - IPTV) koji je potpuno temeljen na tehnologiji za videostrujanje te se očekuje da će u sljedećem desetljeću gotovo sve televizijske usluge biti strujane. Tijekom 2019. godine započeli su takozvani „Ratovi strujanja“ (engl. *“Streaming wars”*), doba intenzivnog natjecanja među tvrtkama na tržištu za strujanje videosadržaja [11]. Katalizator je bio *Disney+*, platforma koja je bila objavljena u studenom te godine što je potaknulo druge tvrtke da se uključe u tržište videostrujanja. Tvrtke su se počele boriti za tržišni udio na način da osim popularnih televizijskih i filmskih naslova pružaju ekskluzivni sadržaj vlastite produkcije. Ovakva tržišna utrka dovela je do povećanja broja servisa za videostrujanje poput *Prime Video*, *Max*, *Apple TV+* i *Hulu*, ali i do pretrpanosti i zasićenosti tržišta istima (engl. *Subscription Fatigue*).



Slika 3.1. Postotak osoba u pojedinoj zemlji koje koriste strujanje televizije ili videa u 2022. godini [13]

Strujanje je u suvremenom svijetu postalo dio svakodnevnice. Prema Eurostat-u [13] godine 2022. u Europskoj Uniji 65% pojedinaca koristilo je strujanje za gledanje televizije ili videozapisa na internetu. U 24 od 27 zemalja EU-a, više od polovice pojedinaca u dobi od 16 do 74 godine koristilo se internetskim strujanjem za gledanje televizije ili videozapisa. Slika 3.1. prikazuje da se Finska može pohvaliti najvećim udjelom od 93 %, a slijede je Nizozemska (90 %) i Danska (89 %). U Hrvatskoj je 70 % pojedinaca koristilo usluge strujanja za gledanje televizije ili videozapisa što je vidljivo na slici 3.1.



Slika 3.2. Predikcija mobilnog prometa za različite aplikacije [14]

Ericsson Mobility Report [14] procjenjuje da će videopromet činiti 74 % ukupnog mobilnog podatkovnog prometa na kraju 2024. godine, a predviđa se da će taj udio porasti na oko 80 % 2030. godine što je vidljivo na slici 3.2. Navodi se da su glavni pokretači rasta videoprometa usluge dijeljenja videa, usluge videostrujanja te većina online sadržaja kao što su vijesti, oglasi i društvene mreže. Uz novi videosadržaj dolazi do promjena ponašanja i navika korisnika odnosno gledanje videozapisa bilo kada i bilo gdje (engl. *On Demand*). Suvremeni pametni mobilni uređaji razvijaju se s većim zaslonima i razlučivostima što dodatno povećava zahtjeve u mrežama. Uz klasične multimedijske tehnologije pojavljuju se i novi medijski formati i aplikacije poput videozapisa s prikazom od 360 stupnjeva i tehnologije proširene stvarnosti (engl. *Augmented Reality* - AR), virtualne stvarnosti (engl. *Virtual Reality* - VR) i mješovite stvarnosti (engl. *Mixed Reality* - MR).

3.1. MPEG DASH norma


U počecima usluge videostrujanja svaka platforma bila je zatvoreni sustav sa svojim protokolima za strujanje i formatima sadržaja [15]. Interoperabilnost među tim sustavima nije postojala što je otežavalo implementaciju na poslužitelje i klijentske uređaje. Tijekom 1990-ih godina *Internet Engineering Task Force* dizajnirao je RTP protokol (engl. *Real-Time Transport Protocol*) koji je služio za definiranje formata paketa za audio i videosadržaj uz upravljanje sesijama strujanja te omogućavanje isporuke paketa s niskim troškovima [15]. RTP protokol dobro je funkcionirao u upravljanim IP mrežama, ali daljnjim razvojem upravljane IP mreže zamijenjene su mrežama za isporuku sadržaja (engl. *Content Delivery Network* - CDN) od kojih mnoge ne podržavaju RTP strujanje. U CDN mrežama RTP protokokol pokazao je svoje nedostatke. RTP paketi često nisu dopušteni kroz vatrozide mreža te RTP strujanje zahtijeva da poslužitelj upravlja zasebnom sesijom strujanja za svakog klijenta, što je resursno zahtjevno [15]. Daljnjim razvojem pojavljuje se mogućnost prijenosa multimedijskog sadržaja pomoću HTTP (engl. *Hyper Text Transfer Protocol*) protokola [15]. Sva današnja mrežna infrastruktura pruža podršku za HTTP protokol te su paketi HTTP protokola prilagođeni suvremenim vatrozidima. Također prilikom HTTP strujanja klijent upravlja strujanjem bez potrebe za održavanjem sesije na poslužitelju što smanjuje troškove i uporabu resursa poslužitelja [15].

Prema [16] prvotni pristup videostrujanju temeljen na HTTP-u temeljio se na progresivnom načinu preuzimanja. Progresivni način preuzimanja radio je na principu što bržeg preuzimanja sadržaja. Problem je s ovim pristupom da svi klijenti primaju jednako kodirani videozapis odnosno jednaku kvalitetu bez obzira na dostupne propusnosti unutar mreže. Suvremeni pristup temelji se na prilagodljivom videostrujanju (engl. *adaptive streaming*). Prilagodljivo videostrujanje koristi

HTTP protokol koji dopušta klijentu korištenje maksimalne dostupne propusnosti za pružanje boljeg korisničkog iskustva i kvalitete usluge, kao i specijalizirane aplikacije za reprodukciju te algoritme za prilagodbu prijenosne brzine (engl. *Adaptive Bitrate Algorithm* - ABR). Također HTTP poslužitelj ima pohranjene višestruke profile istog videozapisa koji je kodiran u različitim kodnim brzinama (engl. *bitrate*), prostornim rezolucijama i različitim kvalitetama [16]. Na taj način postiže se učinkovito korištenje dostupnih resursa. *Microsoft Smooth Streaming*, *Apple HTTP Live Streaming (HLS)* i *Adobe HTTP Dynamic Streaming* neka su od rješenja koja su razvile privatne tvrtke, a koriste pristup prilagodljivog videostrujanja [17]. Među tim rješenjima nije postojala interoperabilnost jer su korišteni različiti formati videosegmenata i različite manifest datoteke. Također su bila zaštićena autorskim pravima te su klijentski uređaji morali posjedovati podršku za svako od ovih rješenja kako bi se usluga videostrujanja mogla pružiti korisniku. Zbog navedenih problema nametnula se potreba univerzalnog standarda za videostrujanje. Organizacije MPEG i *3rd Generation Partnership Project (3GPP)* zajedno s više od 50 tvrtki uključujući *Microsoft*, *Adobe* i *Netflix* predložile su MPEG DASH globalni standard (engl. *MPEG Dynamic Adaptive Streaming over HTTP*) [15]. MPEG standard za dinamičko prilagodljivo strujanje videosignala razvijen je kako bi se pojednostavilo održavanje aplikacija, smanjili troškovi razvoja i osigurala njihova interoperabilnost. Sustavi zasnovani na MPEG DASH normi osiguravaju krajnjim korisnicima glatko strujanje videosignala s najmanjim mogućim brojem prekida u reprodukciji, ne ovise o sklopovlju s korisničke strane i jednostavni su za održavanje [17]. MPEG DASH standard omogućio je nesmetan razvoj i mogućnost da se ostvari puni potencijal tehnologije strujanja videosadržaja.

Prema [17] MPEG DASH specifikacija daje opis sadržaja pohranjenog na HTTP poslužitelju odnosno definira format videosegmenata i MPD (engl. *Media Presentation Description*) datoteke. Sadržaj koji je spremljen na poslužitelju dijeli se na dva dijela, a to su MPD datoteka i videosegmenti. MPD datoteka sadrži informacije o koderu, trajanju videosignala, vremenskom rasponu (engl. *timescale*), dostupnim skupovima prilagodbe, skupovima reprezentacija, prostornim rezolucijama, dostupnim prijenosnim brzinama, URL adresama za svaki medijski videosegment i početni segment za inicijalizaciju dekodera [17]. Za MPD datoteku MPEG DASH norma propisuje šest profila. Propisani profili definirani su kako bi se omogućila interoperabilnost i signalizacija. Oni nameću niz posebnih ograničenja kao što su format MPD datoteke i segmenata, vrstu medijskog sadržaja, medijskih formata, kodeka i zaštite i drugih [17].

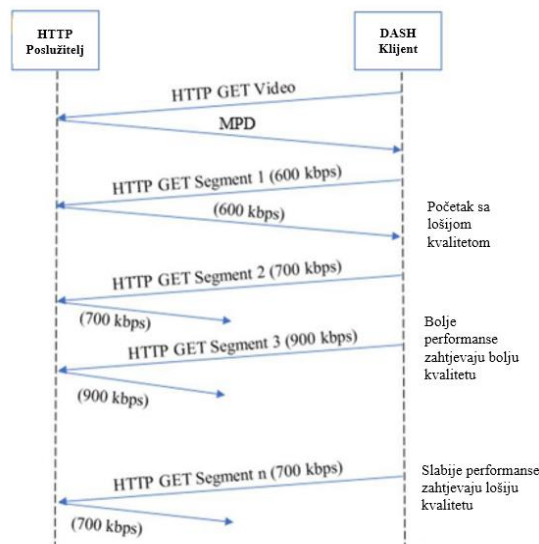
Prije pohranjivanja videosignala na poslužitelj potrebno je provesti kodiranje pomoću određenih parametara odnosno različitih razina kvaliteta. Nakon toga slijedi segmentacija pomoću koje se videozapis dijeli u manje segmente trajanja 1, 2, 4, 6, 8, 10 ili 12 sekundi [17]. Broj segmenata za određeni videozapis definiran je trajanjem videosignala i unaprijed definiranom vrijednošću trajanja svakog videosegmenta. Rezultat je svakog procesa segmentacije MPD datoteka, početni segment i videosegmenti koji sadrže medijske podatke. Svaki skup prilagodbe ima svoj početni segment. Inicijalizacijski ili početni segment prvi je stvoreni segment. On ne sadrži medijske podatke, ali je neophodan jer sadrži sve informacije potrebne za inicijalizaciju dekodera na korisničkoj strani. Pohranjivanje videosegmenata u različitim formatima i razinama kvalitete omogućuje MPEG DASH sustavu brzu prilagodbu trenutnim uvjetima u mreži kako bi se kvaliteta za korisnika ostala na najvišoj mogućoj razini.



Slika 3.3. Prikaz MPEG DASH adaptivnog videostrujanja [17]

Slika 3.3. prikazuje sustav za prilagodljivo videostrujanje temeljen na MPEG DASH standardu. Ovakav sustav sastoji se od klijentske aplikacije i poslužitelja. Na poslužitelju pohranjen je multimedijски sadržaj odnosno segmentirani i kodirani videosignali te MPD datoteka zapisana je u XML formatu (engl. *Extensible Markup Language*) [17]. Videosegmenti raspoređeni su na poslužitelju u skupove za prilagodbu unutar kojih se nalazi više reprezentacija istog sadržaja. Skupovi prilagodbe mogu se razlikovati prema prostornoj rezoluciji ili prema vrsti multimedijске komponente što uključuje video, zvuk te podnaslove [17]. Svaki skup za prilagodbu sadrži više reprezentacija unutar kojih se nalaze videosegmenti. Za svaki videosignal unutar pojedine reprezentacije se koristila drukčija kodna brzina te različite prostorne i vremenske rezolucije.

Na klijentskoj strani nalazi se modul za čitanje MPD datoteke, modul za upravljanje videosegmentima, modul koji sadrži algoritam za prilagodljivo videostrujanje, međuspremnik i modul za prikazivanje videosignala. Modul za analizu MPD datoteke obavlja čitanje (engl. *parsing*) MPD datoteke i pohranjuje informacije koje se nalaze unutar nje. Ovisno o uvjetima u mreži modul koji sadrži algoritam za prilagodljivo strujanje prilagođava kvalitetu strujanih videosegmenata odnosno prijenosnu brzinu kako bi se održala ravnoteža između kvalitete usluge i zastoja u reprodukciji. Modul za upravljanje segmentima kao izlaznu informaciju šalje videosegmente spremne za reprodukciju u međuspremnik. Videosegmente iz međuspremnika uzima modul za prikazivanje videosignala koji ih prosljeđuje na zaslon korisničkog uređaja. Svaki modul mora imati jednostavno i jasno definirano sučelje za komunikaciju s ostalim modulima. Modul za upravljanje segmentima specifičan je za svaki pojedini profil dok ostali moduli nisu specifični za svaki profil MPEG DASH standarda.




Slika 3.4. HTTP komunikacija MPEG DASH sustava [18]

Poslužitelj i klijent međusobno komuniciraju putem HTTP protokola te preko *proxy* poslužitelja i vatrozida [17]. Slika 3.4. prikazuje HTTP komunikaciju MPEG DASH sustava [18]. Komunikacija između klijenta i poslužitelja započinje slanjem HTTP GET zahtijeva za MPD datotekom željenog videosignala. Korisnik na temelju dobivenih podataka odabire skup prilagodbe koji najbolje odgovara trenutnim uvjetima u kojim se strujanje započinje. Zatim se unutar odabranog skupa prilagodbe odabire reprezentacija. Nakon što je odabrana odgovarajuća reprezentacija za prvi segment unutar skupa prilagodbe, stvara se lista dostupnih segmenata za svaku pojedinu reprezentaciju i preuzima se segment za inicijalizaciju dekodera za odabrani skup prilagodbe [17]. Slijedi preuzimanje svih ostalih videosegmenta koji sadrže stvarne videosegmente.

3.1.1. Algoritam za prilagodljivo videostrujanje

Prema [17] cilj je algoritama za prilagodbu prijenosne brzine osigurati što bolju kvalitetu korisničkog iskustva što znači smanjiti početno kašnjenje, pružiti najbolju moguću kvalitetu videosignala i izbjeći ili smanjiti broj prekida u reprodukciji videosignala. Svojim djelovanjem direktno utječu na kvalitetu strujanja videosignala i percepciju korisnika na uslugu videostrujanja. Odabiru sljedeći segment iz neke od dostupnih reprezentacija koje se razlikuju po kodnoj brzini određenoj prilikom kodiranja. Odluku o promjeni kvalitete videosegmenata kojim se puni međuspremnik najčešće donosi analizom popunjenosti međuspremnika i dostupne propusnosti mreže dok neki algoritmi također uzimaju u obzir parametre poput veličine segmenta, vremena potrebnog za preuzimanje određenog segmenta kao i parametre kvalitete korisničkog iskustva.



Slika 3.5. Princip rada algoritma za prilagodljivo videostrujanje [10]

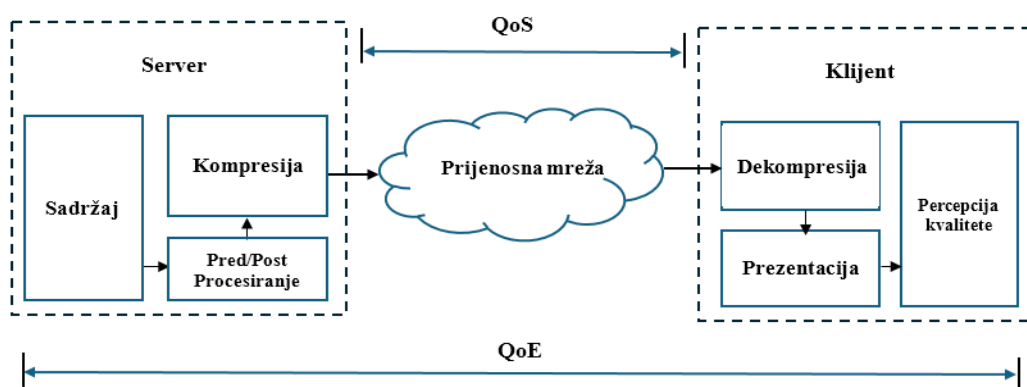
Na slici 3.5. prikazan je primjer principa rada sustava temeljenog na MPEG DASH normi te način funkcioniranja algoritma za prilagodljivo videostrujanje [19]. Videosegmenti pohranjeni su na poslužitelju te kodirani na tri različite kodne brzine 5 Mbit/s, 2 Mbit/s, 500 kbit/s i *trick mode*. *Trick mode* omogućava korisniku zaustavljanje reprodukcije, vraćanje unazad te odabir drugog jezika. Audiosegmenti su kodirani na engleskom i francuskom jeziku, ali i u različitim kvalitetama: *Surround sound*, AAC (engl. *Advanced Audio Coding*) sa 128 kbit/s i 48 kbit/s. Klijent pokreće strujanje s najvećom mogućom kvalitetom videozapisa od 5 Mbit/s te 128 kbit/s AAC kvalitetom audiosignala što je na slici 3.5. označeno brojem jedan. Paralelno sa strujanjem videosegmenata i zvuka algoritam za prilagodljivo videostrujanje prati efektivnu propusnost mreže i popunjenost međuspremnik. Analizom dobiva rezultat da je stvarna dostupna propusnost manja od 5 Mbit/s te donosi odluku da se u sljedećem mogućem trenutku kvaliteta videozapisa smanjuje na 2 Mbit/s. Nakon smanjivanja na kvalitetu od 2 Mbit/s algoritam donosi odluku da se efektivna propusnost u

mreži dodatno smanjila te u trećem koraku nastavlja smanjivati kvalitetu na 500 kbit/s te audiokvalitetu na 48 kbit/s. U četvrtom koraku se propusnost u mreži povećala te se kvaliteta povećava na 2 Mbit/s. U petom koraku aktivira se *trick mode* jer korisnik koristi opciju pauziranja i vraćanja unazad. U željenom trenutku korisnik ponovno započinje reprodukciju videozapisa s najvišom kvalitetom te odabranim podnaslovom na francuskom jeziku – peti i šesti korak.

3.2. Metrike kvalitete videostrujanja


Prijenos tekstualnih poruka, glasovnih i videopoziva te strujanje videosignala zahtijeva različite mrežne kapacitete, prioritete te određenu razinu kvalitete koju korisnik očekuje. Zbog ograničenosti resursa sustav mora poznavati kakav promet će prenositi prije nego može garantirati određenu razinu kvalitete usluge.

Videozapis je po svojoj definiciji niz slika reproduciranih na način kako bi se dobio efekt vizualnog kretanja. Veliki broj slika unutar jednog videosignala značajno povećava njegovu memorijsku veličinu. Sustavi za pohranu videosignala imaju ograničenu količinu memorijskog prostora za pohranu. Također prijenosni kanali u radijskoj pristupnoj mreži (engl. *Radio Access Network*) imaju ograničenu širinu prijenosnog pojasa. Iako se s povećanjem broja podatkovnih centara prostor za pohranu povećava te svakom novom generacijom mobilnih mreža brzine prijenosa podataka značajno rastu, sve to još uvijek nije dovoljno da bi se nekomprimirani videosignal mogao prenijeti u stvarnom vremenu. Zbog prethodno navedenih problema potrebno je definirati metrike i tehnike kojima se zahtjevi za resursima smanjuju.




Slika 3.6. Utjecaj QoS i QoE parametara na kvalitetu strujanja [18]

Prema [17] glavni je cilj usluga videostrujanja mogućnost pružanja najbolje ravnoteže između kvalitete korisničkog iskustva i mogućnosti neprekidnog strujanja videosignala. Slika 3.6. prikazuje shematski prikaz sustava za videostrujanje te sve komponente koje mogu utjecati na kvalitetu usluge. Ključni su parametri koji se uzimaju u obzir parametri kvalitete usluge (engl. *Quality of Service* - QoS) i korisničkog iskustva (engl. *Quality of Experience* – QoE). Na ovoj je slici vidljivo da je percepcija korisnika o ukupnoj kvaliteti usluge videostrujanja pod utjecajem QoS parametara u prijenosnoj mreži te da kvaliteta iskustva QoE uključuje sve korake obrade i prijenosa videosignala od kraja do kraja (engl. *end-to-end*) sustava, ali i subjektivnu percepciju korisnika. U MPEG DASH sustavu videosadržaj sprema se na poslužitelje. Poslužitelji imaju ograničen prostor za pohranu te je zbog tog razloga potrebno koristiti tehnike predprocesiranja te proces kompresije. Ovi postupci negativno utječu na kvalitetu samog videosadržaja na način da se gube informacije kako bi se smanjile potrebe za resursima pohrane i smanjilo zauzimanje širine prijenosnog pojasa kod prijenosa. Algoritmi kompresije poput HEVC iskorištavaju sličnost između susjednih slika i time smanjuju veličinu videozapisa. Prilikom kodiranja videosekvence se dijeli u grupe slika (eng. *Group of Pictures* – GOP) od kojih svaka sadrži tri tipa slika: I (eng. *intra*), P (eng. *predictive*) i B (eng. *bidirectionally predictive*) slike. Veličinu GOP-a definira se kao udaljenost između dvije najbliže I-slike što je vidljivo na slici 3.7.



Slika 3.7. Grupa slika (GoP)

Slika 3.7. pokazuje da tijekom prijenosa mrežom različit tip slike zahtijeva različitu količinu zauzimanja širine prijenosnog pojasa zbog načina kompresije. I slike sadrže najviše detalja slike te samim time potrebna im je veća propusnost za prijenos dok P i B slike sadrže malo detalja te im je potrebno manje. Zbog te činjenice dolazi do naglog povećanja potrebne propusnosti za I slike, nakon čega slijedi naglo smanjenje potrebne propusnosti za P i B slike. Iz ovog primjera moguće je vidjeti da videosignali imaju promjenjivu brzinu prijenosa (engl. *Variable Bit Rate* - VBR). Brzina prijenosa neće nužno biti konstantna pogotovo ako je potrebno postići određenu kvalitetu usluge.



Slika 3.8. Karakteristike prijenosa pojedinih slika u videu [20]


QoS parametri su objektivni pokazatelji performansi prijenosne mreže, a oni uključuju širinu prijenosnog pojasa, kašnjenje, kolebanje kašnjenja te gubitke paketa. Mrežni operateri koriste QoS parametre kako bi zadovoljili prometne zahtjeve osjetljivih aplikacija te kako bi spriječili degradaciju kvalitete. Prilikom određivanja QoS parametara važno je navesti da se ne uzima u obzir subjektivnost krajnjeg korisnika odnosno kvaliteta korisničkog iskustva usluge za videostrujanje. Prema [20] QoS zahtjevi za uslugu videostrujanja su visoka potrošnja širine pojasa, mala osjetljivost na kašnjenje (< 5 s), uglavnom neosjetljiv na varijaciju kašnjenja, gubitak paketa ne smije prelaziti 5 %. Prema navedenim QoS zahtjevima za videostrujanje može se zaključiti da je videostrujanje osjetljivo na gubitak paketa. Veliki gubitak paketa utječe negativno na proces rekonstrukcije videosignala na klijentskoj strani zato što međuslike zahtijevaju informacije iz prethodnih slika. Osjetljivost na kašnjenje je manje izražena zato što postoji međuspremnik u kojem se međuslike spremaju. Potrebno je nekoliko sekundi za pražnjenje međuspremnika što daje vremena da paketi koji imaju kašnjenje ipak stignu na vrijeme za prikaz. Jednako vrijedi i za kolebanje kašnjenja što je zapravo razlika u kašnjenju između paketa te ono uzrokuje zapinjanje reprodukcije. Općenito je poželjno da je vrijednost *jittera* nula, ali u slučaju njegove pojave međuspremnik omogućuje smanjenje efekta. Na količinu zauzimanja širine prijenosnog kanala utječe vrsta kodeka (HEVC ili AV1), broj slika u sekundi (engl. *frames per second* – FPS) i rezolucija pojedine slike [20]. Uz QoS parametre najvažniju ulogu ima kvaliteta korisničkog iskustva QoE. Istraživanja su pokazala da QoE ima veliku ulogu na korisničku percepciju. ITU (engl. *International Telecommunications Union*) organizacija definira QoE kao „ukupnu prihvatljivost aplikacije ili usluge, kako je subjektivno percipira krajnji korisnik”. Na QoE utječu sve značajke sustava poput klijentske aplikacije, mrežne infrastrukture te očekivanja i kontekst u kojem korisnik koristi uslugu videostrujanja. Stoga QoE subjektivno mjeri krajnji korisnik i može se razlikovati od jednog do drugog korisnika, ali se često procjenjuje pomoću objektivnih mjerenja. Kako bi se moglo izmjeriti iskustvo korisnika definirani su QoE parametri, a to su prebacivanje razine kvalitete (engl. *switching*), početno kašnjenje (engl. *initial delay*), zastoji u reprodukciji (engl. *stalling*) i prosječna razina kvalitete (engl. *mean quality level*) [17].

3.3. Videostrujanje u 5G mobilnim mrežama

Pametni mobilni uređaji nezaobilazan su dio suvremenog načina života. Omogućuju jednostavan pristup, stvaranje i dijeljenje informacija. Zajedno s komercijalizacijom usluga mobilnih mreža omogućena je komunikacija između pojedinca i čitavih zajednica ljudi. Svakom novom generacijom pametnih uređaja proširuju se njihove mogućnosti i kvaliteta korisničkog iskustva. Proizvođači ugrađuju zaslone visoke rezolucije s OLED ili AMOLED tehnologijom što daje prikaz sadržaja sa živopisnim bojama i beskonačnim kontrastom. Jedna od ključnih značajki pametnih mobilnih uređaja jest mogućnost snimanja visokokvalitetnih fotografija i videozapisa. Kamere koje se ugrađuju u uređaje konkuriraju profesionalnoj opremi. Pružaju mogućnost snimanja u vrlo visokim rezolucijama poput 4K ili 8K te posjeduju optičku stabilizaciju slike i algoritme umjetne inteligencije za uređivanje osvjetljenja i boja. Ovaj tehnološki napredak u prikazu i snimanju videozapisa donosi sve veću potrebu za memorijskim prostorom, a sukladno tome i veće opterećenje za mobilnu mrežu koja mora imati mogućnost prijenosa takvih visokokvalitetnih videosignala. Današnje mreže suočavaju se s problemom porasta broja korisnika i uređaja koji prenose više podataka nego ikada prije. Svi korisnici koriste resurse prijenosnih kanala koji su u jednakom frekvencijskom pojasu kao i prije, što za posljedicu ima da pojedini korisnik ima manju širinu prijenosnog pojasa te sukladno tome sporiju i manje kvalitetnu uslugu. Paralelno s tehnološkim napretkom očekivanja korisnika rastu. Suvremeni korisnik zahtijeva visoku kvalitetu i pouzdanost usluge koju plaća. Kako bi kvaliteta korisničkog iskustva ostala visoka od ključne važnosti je implementacija nove generacije mobilnih mreža kao što je 5G.

Organizacija 3GPP 2018. godine objavila je prvi globalni standard za 5G generaciju mobilnih mreže u kojem je naglasak stavljen na definiranje tehničke specifikacije sastavnih dijelova 5G-a koje proizvođači opreme i mrežni operateri mogu implementirati u svoje komercijalne mreže [21]. Ovaj standard uključuje specifikacije za pristupnu mrežu koja se naziva novi radio (engl. *New Radio* - NR), jezgrenu mrežu, sigurnost i zahtjeve za uređaje. Godine 2021. organizacija ITU objavila je standard *International Mobile Telecommunications-2020* (IMT-2020 Standard) u kojem su definirani minimalni zahtjevi za performanse i mogućnosti koje mobilna mreža mora postići kako bi se mogla klasificirati kao 5G mreža. Implementacija i usvajanje 5G mreža započela je u ranim 2020-tim te se odvijala postepeno. Prve zemlje koje su uvele 5G bile su Južna Koreja i SAD te Kina koja trenutno ima najveći broj korisnika i najveću infrastrukturu. U odnosu na prethodne generacije, 5G donosi veću propusnost, manje kašnjenje, veću mobilnost i stabilnost te veću dostupnost. Također omogućuje pristup internetu bilo gdje neovisno o mobilnosti, gustoći populacije ili putovanju kroz ćelije. Neke od karakteristika 5G mreže definirane IMT 2020

standardom jesu, prema [22], brzina prijenosa 1-20 Gbit/s do ruba ćelije, kašnjenje od 1 do 4 ms, prometni kapacitet područja jednak 10 Mbit/s/m², povećana širina pojasa do 400 MHz, 1 000 000 uređaja/km², 99,999% dostupnost, 100% pokrivenost te 90% smanjenja korištenja energije u mreži u odnosu na 2010. godinu. Slika 3.9. prikazuje predviđanja tvrtke *Ericsson* [14] koja govore kako će 5G postati dominantna tehnologija mobilnog pristupa putem pretplate 2027. godine. Do 2028. godine 5G će preći 4G generaciju mreža po broju pretplata. Uz nagli tržišni rast 5G tehnologije dolazi do pada broja pretplata za 4G, 3G i 2G tehnologije. *Ericsson Mobility Report* navodi da je tijekom trećeg tromjesečja 2024. godine broj 4G pretplata pao za 69 milijuna, 3G pretplate pale su za 31 milijun dok su 2G pretplate pale za 34 milijuna [14]. Ovi podaci pokazuju da mobilni operateri diljem svijeta pa tako i u Hrvatskoj postepeno gase 2G i 3G mreže kako bi se oslobodio frekvencijski spektar za 4G i 5G tehnologije. U nekim primjenama 2G mreža će se i dalje koristiti za IoT (engl. *Internet of Things*) uređaje koji ne zahtijevaju veliku propusnost i širinu prijenosnog kanala jer šalju senzorske podatke male veličine uz minimalnu potrošnju energije. U postupku razvoja 5G mobilne mreže posebni naglasak stavljen je na prijenos multimedijskog sadržaja [19]. Zahtjevi koji su postavljeni za prijenos prometa videosignala jesu veći broj videozapisa u strujanju, dulje vrijeme gledanja te prelazak na više rezolucije i složene formate. Sama visoka propusnost 5G mreže nije dovoljna za učinkovito videostrujanje. Uz veliku propusnost potrebno je vrlo nisko kašnjenje i malo kolebanje kašnjenja, ali i načinu pohrane videosignala. Zbog navedenih razloga 5G donosi nove tehnologije koje omogućavaju pouzdano videostrujanje, a to su milimetarski valovi (engl. *millimeter wave*), male ćelije, masivni MIMO sustavi (engl. *Multiple-Input Multiple-Output*), oblikovanje snopa (engl. *beamforming*) te arhitekturu jezgrene mreže u oblaku (engl. *cloudification*) [10] [23].



Slika 3.9. Predviđanja mobilnih pretplata za različite tehnologije [14]

Tehnologija milimetarskih valova omogućuje korištenje potpuno novog područja spektra koje nikad prije nije bilo korišteno za mobilne usluge. 3GPP *Release 15* [21] definira dva frekvencijska pojasa naziva FR1 i FR2. Područje FR1 obuhvaća frekvencijski pojas od 410 MHz do 7,125 GHz dok FR2 od 24,25 GHz do 52,6 GHz. Također ove frekvencijske pojaseve moguće je razdvojiti po karakteristikama na tri manja, a to su 5G *low-band*, *mid-band* i *high-band*. Low-band obuhvaća frekvencije ispod 2 GHz. Ovaj frekvencijski pojas pruža široku pokrivenost zbog velikog dometa te koristi LTE jezgrenu arhitekturu za 5G bazne postaje. *Mid-band* pojas obuhvaća frekvencije od 2 do 6 GHz te pruža veliki kapacitet za urbana i prigradska područja i vršne brzine u stotinama Mbit/s. Posljednji pojas jest *High-band* koji obuhvaća frekvencije milimetarskih valova od 24 GHz do 100 GHz. U ovom području moguće je postići prave 5G performanse jer na visokim frekvencijama širina pojasa može biti velika što povećava brzine prijenosa i kapacitet mreže. Nedostatak elektromagnetskih valova visokih frekvencija jest taj da imaju mali domet odnosno veliko gušenje kod prolaska kroz prepreke zbog čega je potrebna gusta infrastruktura malih ćelija i baznih stanica. U 5G mrežama koriste se masivni MIMO sustavi. U odnosu na 4G koji koristi 2x2 MIMO konfiguraciju, u 5G mrežama postoje konfiguracije antena 64x64 ili čak višeg reda [10]. Kako ne bi dolazilo do pojave destruktivne interferencije, masivni MIMO sustavi koriste tehniku oblikovanja snopa. Tehnika oblikovanja snopa omogućuje baznoj stanici slanje usmjerenog toka podataka korisničkom prijemu što donosi smanjenje šuma i smetnji, povećanu spektralnu učinkovitost i veći kapacitet kanala [24]. Jedna od ključnih karakteristika 5G generacije mreža jest arhitektura temeljena na oblaku. Ovaj proces obuhvaća tehniku mrežnog raslojavanja (engl. *network slicing*) te odjeljivanje kontrolne i korisničke ravnine (engl. *Control Plane/User-Plane Split*). Mrežno raslojavanje predstavlja tip virtualizacije mrežne arhitekture koji omogućava postojanje više logičkih slojeva (engl. *slices*) čije su funkcionalnosti optimizirane za određenu namjenu te imaju mogućnost komuniciranja s drugim susjednim slojevima. Virtualizacija omogućuje apstrakciju mrežnih resursa, može kombinirati više fizičkih mreža u jednu virtualnu mrežu koja se temeljeni na softveru te može podijeliti jednu fizičku mrežu u zasebne neovisne virtualne mreže. Pomoću virtualizacije moguće je razviti softversku platformu koju višestruke aplikacije za videostrujanje mogu dijeliti. Svaka od tih aplikacija može implementirati vlastite mrežne funkcije prema svojim zahtjevima [24]. Također na temelju trenutnog opterećenja videostrujanja omogućuje dodjeljivanje resursa za svaku aplikaciju zasebno. Tehnika odjeljivanja kontrolne i korisničke ravnine omogućuje različita sučelja za ove dvije ravnine. Funkcija kontrolne ravnine jest upravljanje sesijom, IP alokacija adresa, signalizacija između jezgre i uređaja, sigurnost, upravljanje mobilnošću i autentifikacija. Zadatak korisničke ravnine jest usmjeravanje paketa i prosljeđivanje, filtriranje paketa, inspekcija paketa te održavanje razine kvalitete usluge.

4. UMJETNO GENERIRANJE 5G ISPITNIH MREŽNIH ZAPISA

Algoritmi za prilagodbu prijenosne brzine koriste informacije o propusnosti unutar mreže kako bi pružili korisniku najbolju moguću kvalitetu usluge videostrujanja. Ovisno o povećanju ili smanjenju propusnosti, kvaliteta videozapisa se smanjuje ili povećava na način da se postigne brzo pokretanje sadržaja te izbjegne zapinjanje i učitavanje tijekom reprodukcije videozapisa. Kako bi se mogli analizirati algoritmi za prilagodbu prijenosne brzine, potrebni su mrežni ispitni zapisi propusnosti. Izmjereni mrežni zapisi optimalno opisuju uvjete u mreži prilikom izvođenja videostrujanja, ali njihov je nedostatak ograničena dostupnost te nepredvidljive statističke karakteristike koje ih čine neprikladnim za pravilnu i sustavnu analizu. Zbog prethodno navedenih razloga, za sustavnu analizu algoritama za prilagodbu prijenosne brzine mogu bolje poslužiti umjetno generirani mrežni ispitni zapisi koji dobro aproksimiraju stvarne mrežne zapise. Prednosti korištenja sintetičkih mrežnih zapisa jesu mogućnost generiranja prema zadanim parametrima, neovisnost o dostupnosti baza podataka mrežnih zapisa, dobro oponašanje stvarnih uvjeta u mreži te predvidljivost ponašanja koja je ključna za sustavnu analizu. Kako bi se generirali kvalitetni sintetički mrežni zapisi, potrebno je prvo provesti statističku analizu realnih mrežnih zapisa. Statistička analiza omogućava predstavljanje i istraživanje velikih količina mrežnih ispitnih zapisa na način da se otkriju temeljna svojstva i trend kretanja podataka te na taj način omogućuje optimiziranje ABR algoritama.

4.1. Statistička analiza propusnosti

4.1.1. Baza podataka

Baza podataka korištena u ovom diplomskom radu naziva *5G Dataset with Channel and Context Metrics* [7] sadrži mrežne zapise 5G mreže prikupljene od velikog irskog mobilnog operatera te sadrži ukupno 83 mrežna zapisa. Skup podataka generiran je iz dvaju scenarija mobilnosti, statični i kroz vožnju automobilom te kroz strujanje videozapisa i preuzimanje datoteke. Za strujanje videozapisa korištene su dvije platforme za videostrujanje, *Amazon Prime Video* i *Netflix*. Skup podataka sastavljen je od ključnih pokazatelja performansi mobilne mreže (engl. *Key Performance Indicator* - KPI) na strani klijenta. Ove metrike snimljene su pomoću *Android* aplikacije za praćenje mreže naziva *G-NetTrack Pro* na uređaju *Samsung Galaxy S10 5G*. Snimljeno je ukupno 26 KPI-a unutar baze podataka poput *Timestamp*, *Speed*, *RSRP*, *RSRQ*, *SNR*, *DL_bitrate* i *UL_bitrate*. Podaci su prikupljeni u vremenskom intervalu od jedne sekunde te su izraženi u kbit/s. U ovom diplomskom radu za analizu odabrana su oba obrasca mobilnosti te obrazac aplikacije vezan uz strujanje videozapisa s *DL_bitrate* pokazateljem performansi.

4.1.2. Matematički modeli

Kako bi se mogla provesti kvalitetna statistička analiza potrebno je definirati teorijske modele za opisivanje statističkog ponašanja dostupne propusnosti u mobilnim mrežama. U ovom radu korištene su Nakagami, Weibull, Rician, Gamma i Normalna (Gauss) raspodjela.

Nakagami raspodjela

Nakagami raspodjela teorijski je model koji se često koristi za opisivanje statističkog ponašanja dostupne propusnosti. U [25] navedeno je da se Nakagami raspodjela pokazala kao najbolja raspodjela za statističko modeliranje za 3G i 4G mrežne ispitne zapise. Također često se koristi za modeliranje anvelope prijamnog signala u uvjetima višestaznog slabljenja signala (engl. *multipath fading*) gdje se snaga primljenog signala vrlo brzo mijenja uz velike oscilacije. Nakagami funkcija gustoće definirana je prema izrazu

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

gdje je X pozitivna slučajna varijabla, m parametar oblika, a ω parametar širenja.

Nakagami raspodjela vjerojatnosti definirana je za $m > 0,5$ i $\omega > 0$

$$E(X) = \frac{\Gamma(m+\frac{1}{2})}{\Gamma(m)} \sqrt{\frac{\omega}{m}} \quad (4-2)$$

$$Var(X) = E(X^2) - E(X)^2 = \omega \left[1 - \frac{1}{m} \left(\frac{\Gamma(m+\frac{1}{2})}{\Gamma(m)} \right)^2 \right] \quad (4-3)$$

gdje $\Gamma(\cdot)$ predstavlja gamma funkciju.

Parametri m i ω mogu se odrediti pomoću sljedećih izraza:

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

$$\omega = E(X^2) \quad (4-5)$$

Weibull raspodjela

Weibull raspodjela kontinuirana je, unimodalna distribucija vjerojatnosti. Ima mogućnost modelirati asimetrično raspodjeljene podatke. Izuzetna fleksibilnost omogućuje modeliranje lijevo i desno iskrivljenih podataka. Također može aproksimirati normalnu distribuciju i druge distribucije. Weibull funkcija gustoće definirana je prema izrazu:

$$f(x) = \begin{cases} \frac{b}{a} \left(\frac{x}{a}\right)^{b-1} e^{-(x/a)^b}, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4-6)$$

gdje je a parametar skale i b parametar oblika.

Rice (Rician) raspodjela

Rician raspodjela također je poznata kao Nakagami- n distribucija. Ona je unimodalna s tankim repovima odnosno repovi se eksponencijalno smanjuju za velike x -vrijednosti. Ova distribucija modelira *line-of-sight scatter* – razine prijemne snage kod prijenosa između bazne i mobilne postaje koje imaju direktnu vidljivost. Funkcija gustoće Rician raspodjele definirana je izrazom:

$$f(x) = \frac{x}{\sigma^2} \exp\left(\frac{-(x^2+v^2)}{2\sigma^2}\right) I_0\left(\frac{xv}{\sigma^2}\right) \quad (4-7)$$

gdje je $I_0(z)$ modificirana Besselova funkcija prve vrste s nulnim redom, a v i σ su parametri oblika. Distribucija vrijedi za realne pozitivne brojeve $\{a, \infty\}$ gdje je a bilo koji realan pozitivan broj.

Gamma raspodjela

Gamma raspodjela je kontinuirana distribucija vjerojatnosti koja modelira podatke s desnom asimetričnom distribucijom podataka. Slična je eksponencijalnoj distribuciji. Najčešći je slučaj upotrebe Gamma distribucije modeliranje vremena između neovisnih događaja koji se javljaju konstantnom prosječnom brzinom. Gamma distribucija generalizacija je eksponencijalne distribucije. Gamma distribucija može modelirati proteklo vrijeme između različitih brojeva događaja. Funkcija gustoće vjerojatnosti Gamma distribucije definirana je izrazom:

$$f(x) = \frac{1}{b^a \Gamma(a)} x^{a-1} e^{-\frac{x}{b}} \quad (4-8)$$

gdje je $\Gamma()$ gama funkcija, parametar a određuje oblik funkcije dok parametar b mjerilo.

Normalna (Gauss) raspodjela

Funkcija gustoće Normalne raspodjele definirana je izrazom:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, x \in R \quad (4-9)$$

pri čemu je μ očekivanje, σ standardna devijacija. Očekivanje $E[X]=\mu$ te standardna devijacija σ definiraju se izrazima:

$$\underline{x} = \sum_{i=1}^n \frac{x_i}{n} \quad (4-10)$$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \underline{x})^2 \quad (4-11)$$

4.1.3. Programsko rješenje

Za primjenu matematičkih modela na odabranim podacima u ovom radu korišteno je MATLAB računalno okruženje. MATLAB je programska i numerička računalna platforma koja se koristi za analizu podataka, razvoj algoritama i stvaranje matematičkih modela. MATLAB obuhvaća radno okruženje za iterativnu analizu i procese dizajna s programskim jezikom. Također daje mogućnost poziva *Live Editor* funkcije pomoću koje se stvaraju skripte koje ispunjavaju određene zadatke. Svaka MATLAB skripta ima *.m* ekstenziju. MATLAB omogućava mnogo načina vizualizacije, analize i obrade različitih vrsta podataka kao što su slike, signali i tekst.

Pomoću MATLAB programskog okruženja razvijena je skripta naziva *Script_5G_Poisson.m*. čiji se programski kod nalazi u prilogu P.3.1. Glavni cilj ovog programa jest automatizacija statističke analize izmjerenih mrežnih zapisa propusnosti. Skripta učitava podatke mrežnih ispitnih zapisa koji su spremljeni u datoteke naziva *Netflix_driving.mat*, *Netflix_static.mat*, *Amazon_Prime_driving.mat*, *Amazon_Prime_static.mat*. Svaka od navedenih datoteka sadrži *DL_bitrate* podatke prikupljene iz baze podataka odgovarajuće aplikacije za videostrujanje.

```
%Učitavanje Netflix dataseta
load('Netflix_driving.mat');
load('Netflix_static.mat');
load('netflix-static-names.mat');
load('netflix-driving-names.mat');

%Učitavanje Amazon Prime dataseta
load('Amazon_Prime_driving.mat');
load('Amazon_Prime_driving-names.mat');
load('Amazon_Prime_static.mat');
load('Amazon_Prime_static-names.mat');
```


Nakon što su svi ulazni podaci učitani, korisnik dobiva mogućnost odabira na kojem skupu podataka želi napraviti statističku analizu te rezultate prikazati pomoću grafova. S obzirom da je uvidom u podatke utvrđena jasna razlika između perioda s visokom propusnosti od više Mbit/s i perioda s malom propusnosti do oko 200 kbit/s, statistička analiza započinje dijeljenjem odabranih podataka u dvama segmentima. Varijabla `segment_1` sadrži podatke s propusnosti manjom od 200 kbit/s dok varijabla `segment_2` sadrži propusnosti jednake ili veće od 200 kbit/s. Statistička analiza radi se odvojeno za ta dva segmenta. Zatim varijabla `raspodjela_t` sprema podatke o trajanju grupe uzastopnih zapisa propusnosti s vrijednostima manjim od 200 kbit/s, a varijabla `raspodjela_T` trajanje grupe uzastopnih zapisa većih ili jednakih 200 kbit/s.

```

vrijeme = zeros(1, rows);
z = 1; %indeks polja segment_1
w = 1; %indeks polja segment_2
t1 = 0; %varijabla koja prati trajanje segment_1
T1 = 0; %varijabla koja prati trajanje segment_2
p = 1; %indeks polja raspodjela_T
r = 1; %indeks polja raspodjela_t
column_data_1 = Network_trace(:,1)+1;
prvi=column_data_1(1);

if prvi<200
    redoslijed=0;
else
    redoslijed=1;
end
for k=1:(rows-1)
    radni=column_data_1(k);
    sljedeci=column_data_1(k+1);
    if isnan(radni)
        break
    end
    if radni<200
        Segment_1(z)=radni;
        z=z+1;
        vrijeme(k)=0;
        t1=t1+1;
        if or(sljedeci>=200, k==(rows-1))
            Raspodjela_t(r)=t1;
            r=r+1;
            t1=0;
        end
    else
        Segment_2(w)=radni;
        w=w+1;
        vrijeme(k)=1;
        T1=T1+1;
        if or(sljedeci<200, k==(rows-1))
            Raspodjela_T(p)=T1;
            p=p+1;
            T1=0;
        end
    end
end
end
end

```

Kada je mrežni zapis podijeljen na segmente provodi se proračun srednje vrijednosti i standardne devijacije na svakom segmentu pomoću funkcija `mean()` i `std()`.

```
%Izračun srednje vrijednosti i standardne devijacije
means = [];
std_devs = [];
fields = fieldnames(segments);

for i = 1:length(fields)
    segmentName = fields{i};
    means(i) = mean(segments.(segmentName), 'omitnan');
    std_devs(i) = std(segments.(segmentName), 'omitnan');
end
```

U sljedećim koracima program *Script_5G_Poisson.m* koristi nestandardne funkcije naziva `fitmethis()` te `plotdist()` [26]. Funkcija `fitmethis()` pronalazi distribuciju koja najbolje odgovara podacima u vektoru X između svih dostupnih distribucija. Koriste se kontinuirane ili diskretne distribucije na temelju korisničkog unosa ili vrste dostavljenih podataka. Funkcija vraća strukturni niz s poljima: `name` – naziv distribucije, `par` – vektor procjene parametara, `ci` – matrica granica pouzdanosti, jedan stupac po parametru, `LL` – vrijednost funkcije log-izglednosti podataka, `aic` – Akaike informacijski kriterij. Funkcija `fitmethis()` određuje *best-fit* distribuciju pomoću parametara `LL` i `aic` koji su prethodno navedeni.

```
fitResults = fitmethis(segments.(segmentName), 'dtype', 'cont', 'criterion',
'LL', 'pref', distro_names(j));
```

Korišteni argumenti:

- `dtype` – niz znakova koji određuje jesu li podaci kontinuirani (`cont`) ili diskretni (`disc`)
- `criterion` – kriterij koji se koristi za poredak uklapanja, `LL` za vrijednost funkcije log-vjerojatnosti
- `pref` – naziv preferirane distribucije za crtanje

```
plotfitdist(segments.(segmentName), bestResult, 'cont');
```


Funkcija `plotfitdist()` dizajnirana je za rad zajedno s funkcijom `fitmethis()`, ali se također može koristiti pojedinačno. Ona omogućava iscrtavanje podatka i prilagođene distribucije te ima mogućnost prikazivanja jedne ili više gustoća vjerojatnosti funkcije i histogram [26].

Korišteni argumenti:

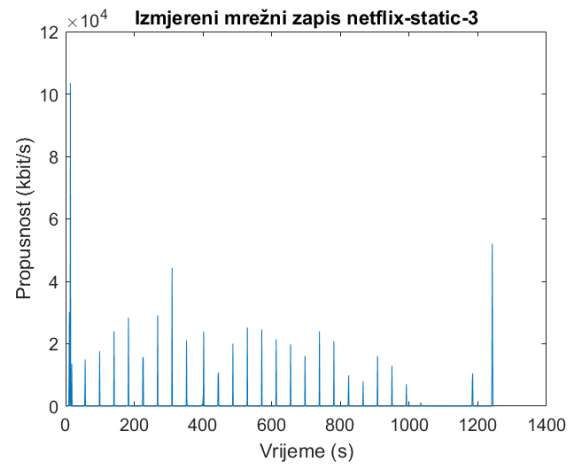
- `cont` – određuje da su podaci kontinuirani

4.1.4. Rezultati statističke analize propusnosti


Za statističku analizu odabrana su 24 izmjerena mrežna zapisa prikupljena tijekom strujanja videosadržaja pomoću dviju aplikacija za videostrujanje *Netflix* i *Amazon Prime*. Pomoću *Netflix* aplikacije mrežni zapisi su snimljeni tijekom strujanja animiranog crtano-film *Rick and Morty* te igrane serije *Stranger Things*, a pomoću *Amazon Prime* aplikacije strujan je animirani crtani film *Lego Ninjago* te igrana serija *The Expanse*. Od odabranih mrežnih zapisa 12 ih je snimljeno s mobilnim korisnikom odnosno tijekom vožnje, a ostalih 12 sa stacionarnim korisnikom. Na ovaj način moguće je napraviti analizu kako različiti obrasci mobilnosti korisnika unutar mobilne mreže utječu na statističke karakteristike propusnosti. Mrežni zapisi odabrani su ručnom metodom. Ovakav pristup omogućuje precizniji izbor mrežnih zapisa koji imaju različite statističke karakteristike propusnosti. Nomenklatura mrežnih zapisa sastoji se od naziva aplikacije, načina mobilnosti te rednog broja mrežnog zapisa kao na primjer *Netflix-static-1*. Svi analizirani mrežni zapisi prikazani su slikama 4.1., 4.2., 4.3. i 4.4. u vremenskoj domeni. Prikaz mrežnih zapisa propusnosti omogućava vizualni uvid u ponašanje i statističke karakteristike propusnosti tijekom usluge videostrujanja u mobilnim mrežama. Analizom vremenske raspodjele odabranih mrežnih zapisa moguće je uočiti specifičnu karakteristiku ponašanja propusnosti tijekom videostrujanja. Usluge za videostrujanje preuzimaju segmente samo tijekom punjenja međuspremnika s videosegmentima. Period u kojem se preuzimaju podaci naziva se *on* faza dok *off* faza predstavlja vremenski period u kojem se videosegmenti ne preuzimaju. Kako je navedeno u [7] potražnja za propusnošću klijentske aplikacije ograničena je maksimalnom kvalitetom kodiranog videosadržaja koji je dostupan na poslužitelju. Ovakvo je ponašanje rezultat optimizacije sustava za videostrujanje, ali i način uštede korištenja prijenosnog kanala čime se smanjuje opterećenje mrežnih resursa. Također 5G mreže imaju na raspolaganju alat mrežnog raslojavanja koji omogućava specijalizirane logičke slojeve mreže namijenjene optimizaciji videostrujanja. Ovu mogućnost može iskoristiti pružatelj usluge videostrujanja u dogovoru s operaterom na način da poseban sloj mreže optimizira specifično za uslugu videostrujanja. Zbog prethodno navedenih razloga karakteristika je propusnosti skokovita s velikim rasponom vrijednosti te pokazuje svojstvo nepredvidljivosti odnosno karakteristike gdje buduća stanja propusnosti ovise samo o sadašnjem stanju bez utjecaja prethodnih stanja. Statističkom analizom moguće je utvrditi kako se mrežni zapisi distribuiraju tijekom vremena što se može iskoristiti za dobivanje uvida na koji način videoaplikacije koriste propusnost mreže.




(a)



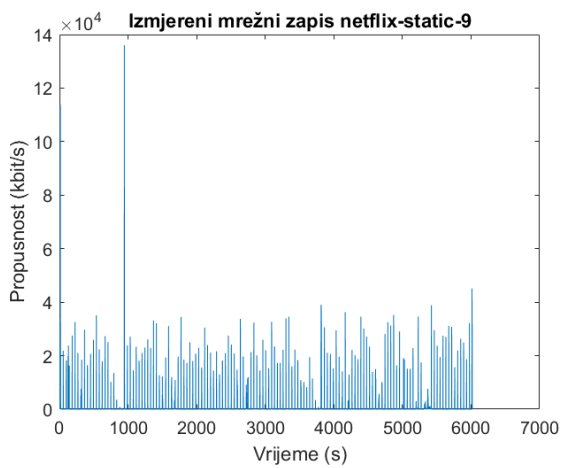
(b)



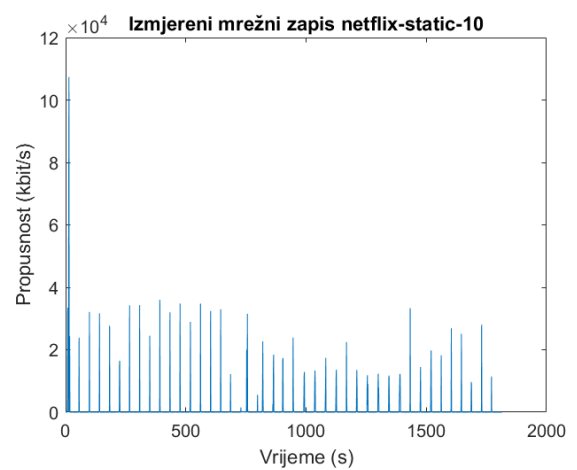
(c)



(d)




(e)




(f)

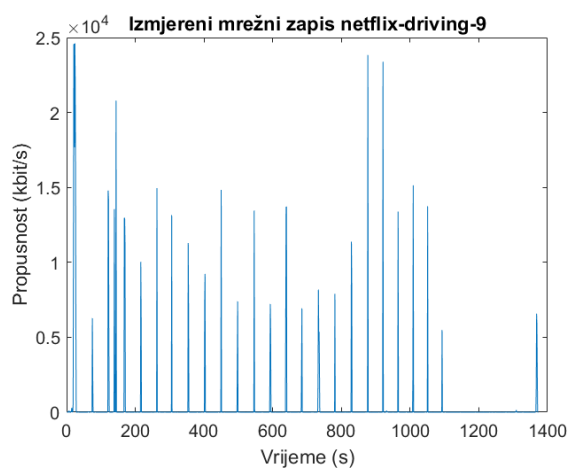
Slika 4.1. Izmjereni mrežni zapisi (a) netflix-static-2 (b) netflix-static-3 (c) netflix-static-4 (d) netflix-static-5 (e) netflix-static-9 (f) netflix-static-10




(a)



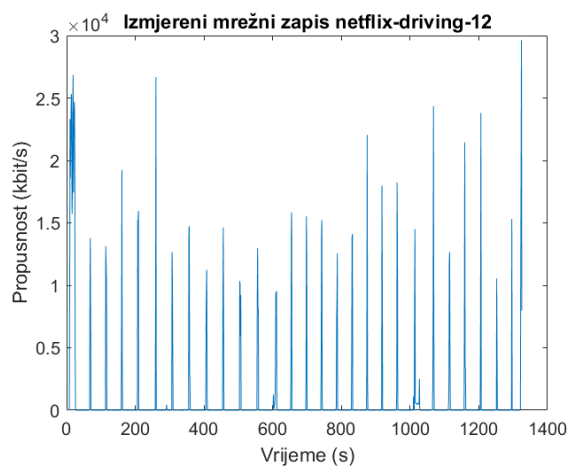
(b)




(c)



(d)




(e)




(f)


Slika 4.2. Izmjereni mrežni zapisi (a) netflix-driving-1 (b) netflix-driving-3 (c) netflix-driving-9 (d) netflix-driving-11 (e) netflix-driving-12 (f) netflix-driving-23



(a)




(b)




(c)



(d)




(e)



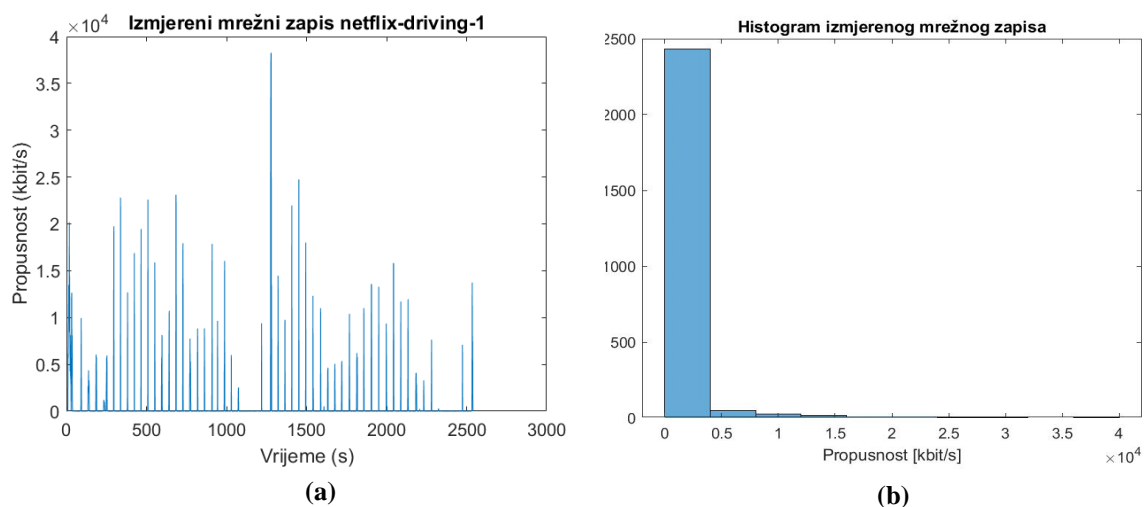
(f)

Slika 4.3. Izmjereni mrežni zapisi (a) amazon-prime-static-1 (b) amazon-prime-static -2 (c) amazon-prime-static -3 (d) amazon-prime-static -4 (e) amazon-prime-static -6 (f) amazon-prime-static -8



Slika 4.4. Izmjereni mrežni zapisi (a) amazon-prime-driving-1 (b) amazon-prime-driving-4 (c) amazon-prime-driving-7 (d) amazon-prime-driving-9 (e) amazon-prime-driving-15 (f) amazon-prime-driving-18

Statistička analiza pomoću *Script_5G_Poisson.m* prikazuje zasebne grafove za originalni mrežni zapis propusnosti te histograme segmenata s najboljim prilagođenim distribucijama. Prioritet je stavljen na distribucije Weibull, Gamma, Nakagami, Normal i Rician distribucija. Također za svaki mrežni zapis postoje četiri tablice u kojima se nalaze procijenjeni parametri odabranih distribucija. Svaka tablica ima šest stupaca koji sadrže podatke o imenu distribucije, procijenjene matematičke parametre za odabrane distribucije, vrijednost funkcije log-vjerojatnosti, srednju vrijednost i standardnu devijaciju. U ovom radu opisana je metodologija statističke analize na jednom reprezentativnom primjeru naziva *Netflix-driving-1*. Rezultati statističke analize ostala 23 mrežna zapisa dani su u Prilogu P.4.1.



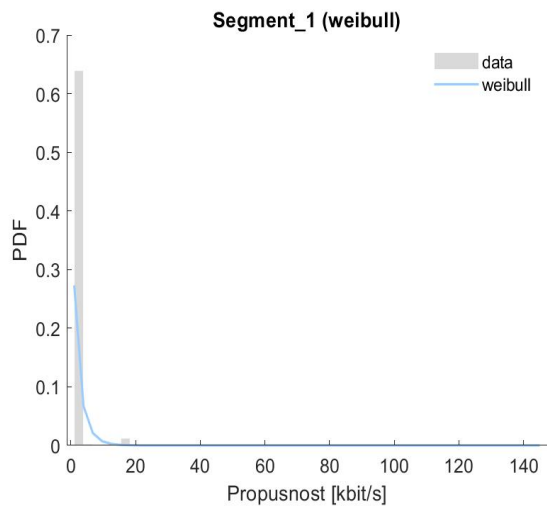
Slika 4.5. (a) Izmjereni mrežni zapis Netflix-driving-1 s (b) pripadajućim histogramom

Slika 4.5. prikazuje izmjereni mrežni zapis propusnosti *Netflix-driving-1* u vremenskoj domeni koji je snimljen pomoću *Netflix* platforme za videostrujanje prilikom prikazivanja crtanog filma *Rick and Morty*. Ovaj mrežni zapis pokazuje da usluga videostrujanja nema kontinuiranu karakteristiku preuzimanja videosegmenata nego se pojavljuje isprekidano ponašanje (engl. *on-off behaviour*) s naglim skokovima u propusnosti. Ovakva karakteristika vidljiva je i na histogramu (slika 4.5. (b)) koji prikazuje da se najveći broj vrijednosti nalazi u rasponu od 0 do 5 Mbit/s dok se vrlo malo podataka nalazi u vrijednostima višim od 10 Mbit/s. Maksimalna propusnost u ovom mrežnom zapisu iznosi 38 Mbit/s. Slijede rezultati statističke analize za mrežni zapis *Netflix-driving-1* za *Segment_1* koji su prikazani u tablici 4.1. te na slici 4.2. gdje su na histogramu pripadajućeg segmenta prikazane odgovarajuće teorijske raspodjele gustoće vjerojatnosti (engl. *probability density function – PDF*).

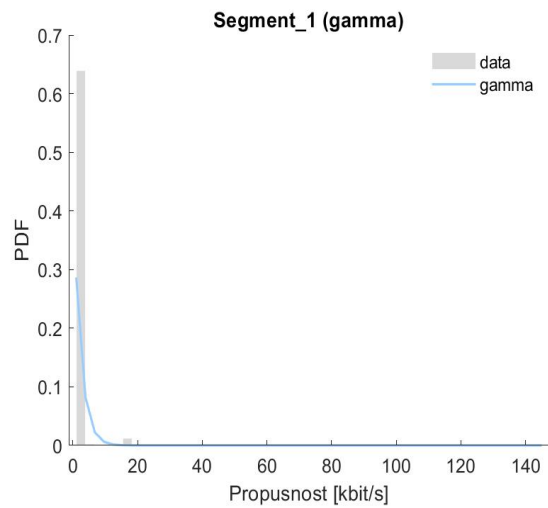
Tablica 4.1. Rezultati statističke analize Netflix-driving-1 (Segment_1)

Segment_1					
Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Standardana devijacija [kbit/s]
Weibull	2,01	0,86	-4229,35	2,29	7,19
Gamma	1,05	2,18	-4319,46		
Nakagami	0,21	56,92	-5505,06		
Normal	2,29	7,19	-8021,07		
Rician	0,07	5,33	-9623,83		


U slučaju za *Segment_1* Weibull distribucija ima najbolju log-vjerojatnost što znači da je optimalni model za opis statističkih karakteristika. Vrijednost log-vjerojatnosti izražava koliko dobro distribucija opisuje kretanje podatka. Što je vrijednost bliža vrijednosti nula znači da distribucija bolje odgovara podacima. Uz Weibull distribuciju Gamma distribucija ima vrlo blisku vrijednost log-vjerojatnosti. Iz toga se može zaključiti da Gamma distribucija također dobro opisuje statističko ponašanje. Ostale distribucije Nakagami, Normal i Rician imaju slabije rezultate log-vjerojatnosti te zbog toga i slabiju prilagodbu na podatke odnosno slabije uspješno opisivanje varijacija unutar podatka. Srednja vrijednosti ovog segmenta iznosi 2 kbit/s. Ova je vrijednost mala zbog toga što ovaj segment sadrži podatke kojima je propusnost manja od 200 kbit/s. Standardna devijacija iznosi 7,19 kbit/s, što pokazuje da se većina podataka nalazi u rasponu od $2,287 \pm 7,19$ kbit/s. Raspršenost podataka jest velika zbog karakteristike podataka koji imaju udaljene ekstreme odnosno velike oscilacije u vrijednostima. Histogrami pružaju vizualni uvid u karakteristiku podataka te prilagodbu raspodjela te je jasno vidljivo da Weibull i Gamma distribucije bolje prate oblik stvarne distribucije podataka u usporedbi s ostalim distribucijama.




(a)




(b)



(c)



(d)




(e)

Slika 4.6. Histogrami Segment_1 s distribucijom (a) Weibull (b) Gamma (c) Nakagami (d) Normal (e) Rician

Tablica 4.2. prikazuje rezultate statističke analize *Segment_2* za *Netflix-driving-1* mrežni zapis. Raspodjela koja se pokazala kao optimalna za opisivanje statističkih karakteristika *Segment_2* podataka jest Gamma raspodjela čija log-vjerojatnost iznosi -1742,74. Uz Gamma raspodjelu, raspodjele Weibull i Nakagami postižu slične rezultate log-vjerojatnosti pa se u ovom slučaju i one mogu uzeti u obzir za kvalitetno modeliranje podataka. Srednja vrijednost ovog segmenta iznosi 7432,01 kbit/s. U ovom segmentu srednja vrijednost jest značajno veća od srednje vrijednosti *Segment_1*. Unutar ovog segmenta nalaze se podaci iznad 200 kbit/s koji ih ima kvantitativno više i postižu veće vršne vrijednosti. Standardna devijacija iznosi 7085,87 kbit/s što također pokazuje značajne oscilacije u vrijednostima koje se nalaze unutar *Segment_2*. Podaci nisu simetrično raspoređeni nego se većina podataka nalazi na lijevoj strani s manje podataka velikih vrijednosti na desnoj strani. Ovako statističko svojstvo raspodjele podataka naziva se raspodjela s dugim repom. Slika 4.4. prikazuje histograme s odgovarajućim raspodjelama iz kojih je vidljivo da Gamma distribucija najbolje opisuje kretanje podataka za *Segment_2*, ali Weibull i Nakagami distribucije također dobro opisuju uz male nedostatke u detaljima karakteristike podataka.

Tablica 4.2. Rezultati statističke analize Netflix-driving-1 (Segment_2)

Segment_2					
Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Standardana devijacija [kbit/s]
Gamma	1,22	6,09E+03	-1742,74	7432,01	7085,87
Weibull	7,73E+03	1,11	-1743,34		
Nakagami	0,42	1,05E+08	-1750,84		
Normal	7,43E+03	7,07E+03	-1809,62		
Rician	2,15E+02	7,25E+03	-1817,61		




Slika 4.7. Histogram Segment_2 s distribucijom (a) Gamma (b) Weibull (c) Nakagami (d) Normal (e) Rician

Tablica 4.3. prikazuje rezultate statističke analize *Netflix-driving-1* za podatke *Raspodjela_t*. *Raspodjela_t* sadrži podatke o trajanju grupe uzastopnih zapisa propusnosti manje od 200 kbit/s. Ovi podaci omogućavaju uvid vremenske raspodjele perioda s niskom propusnosti. Sve raspodjele postigle su vrlo sličan rezultat log-vjerojatnosti u rasponu od -251,57 do -255,18. Zbog toga može se zaključiti da su sve promatrane raspodjele pogodne za modeliranje podataka iz ovog segmenta jer nema značajnog odstupanja od najbolje vrijednosti koju je postigla Weibull distribucija. Ovaj rezultat se također može vidjeti na slici 4.5. na kojoj je vidljivo da se težište podataka nalazi na lijevoj strani te se pojavljuje dugi rep na desnoj strani što daje asimetričan izgled. Srednja vrijednost ovog segmenta iznosi $42,19 \pm 23,26$ s što ukazuje na veliko raspršenje podataka.

Tablica 4.3. Rezultati statističke analize Netflix-driving-1 (Raspodjela_t)

Raspodjela_t					
Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [s]	Standardna devijacija [s]
Weibull	46,95	1,83	-251,57	42,19	23,26
Nakagami	0,91	2,31E+03	-251,90		
Rician	1,78	33,98	-252,07		
Gamma	2,77	15,21	-253,11		
Normal	42,20	23,05	-255,18		




Slika 4.8. Histogram Raspodjele_t s distribucijom (a) Weibull (b) Nakagami (c) Rician (d) Gamma (e) Normal

Kao posljednji analizirani su podaci *Raspodjela_T* koji predstavljaju trajanje grupa uzastopnih zapisa s propusnosti većom ili jednakom 200 kbit/s. U tablici 4.4. vidljivo je da se Gamma raspodjela pokazala kao najbolja za opisivanje statističkih kretanja podataka ovog segmenta. Raspodjela Weibull postigla je vrlo približan rezultat kao i Gamma raspodjela što ukazuje da je Weibull također pogodna za modeliranje statističkih karakteristika ovog segmenta. S obzirom da se u ovom segmentu nalaze podaci iznad 200 kbit/s i karakteristiku samog mrežnog zapisa srednja vrijednost iznosi $3,14 \pm 2,97$ kbit/s. Iz ove analize se zaključuje da nema mnogo uzastopnih podataka sa propusnosti većom ili jednakom 200 kbit/s.

Tablica 4.4. Rezultati statističke analize Netflix-driving-1 (Raspodjela_T)

Raspodjela_T					
Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [s]	Standardna devijacija [s]
Gamma	2,09	1,50	-112,91	3,14	2,97
Weibull	3,46	1,32	-116,26		
Nakagami	0,55	18,46	-122,12		
Rician	0,09	3,04	-130,79		
Normal	3,14	2,93	-139,67		



Slika 4.9. Histogram Raspodjele t s distribucijom (a) Gamma (b) Weibull (c) Nakagami (d) Rician (e) Normal

Tablica 4.5. Popis najboljih raspodjela s pripadajućim rasponom parametara za sve izmjerene mrežne zapise

		Raspodjela	Parametar 1	Parametar 2
Netflix-static	Segment_1	Weibull	1,92 - 2,37	0,73 - 0,9
	Segment_2	Gamma	0,86 - 1,32	1,08e+04 - 1,52e+04
	Raspodjela_t	Normal	30,78 - 34,14	13,31 - 17,04
	Raspodjela_T	Gamma	2,98 - 7,13	0,18 - 0,67
Netflix-driving	Segment_1	Weibull	1,98 - 2,62	0,68 - 0,86
	Segment_2	Nakagami	0,29 - 0,62	1,44e+08 - 5,03e+08
	Raspodjela_t	Nakagami	0,349 - 0,354	1,02e+03 - 1,67e+03
		Normal	37,47 - 38,34	12,55 - 15,93
	Raspodjela_T	Gamma	1,92 - 3,11	0,64 - 1,69
Amazon-prime-static	Segment_1	Weibull	2,29 - 3,46	0,54 - 0,63
	Segment_2	Weibull	3,42e+03 - 8,36e+03	0,68 - 1,10
	Raspodjela_t	Gamma	1,63 - 3,47	0,35 - 1,02
	Raspodjela_T	Gamma	1,25 - 5,13	0,28 - 1,84
Amazon-prime-driving	Segment_1	Weibull	3,21 - 11,43	0,50 - 0,55
	Segment_2	Weibull	1,05e+03 - 1,42e+03	0,81 - 0,93
	Raspodjela_t	Gamma	1,89 - 6,75	0,19 - 0,91
		Weibull	1,77 - 1,97	0,77 - 0,85
	Raspodjela_T	Gamma	2,28 - 2,91	0,67 - 1,03

Nakon što je provedena statistička analiza svih izmjerenih mrežnih zapisa napravljena je sinteza zapisa propusnosti najboljih distribucija za pojedini segment svakog mrežnog zapisa s pripadajućim rasponom parametara koji su prikazani unutar tablice 4.5. Najbolje distribucije odabrane su na temelju najčešćeg pojavljivanja za pripadajući segment koji opisuju. Za *Segment_1* Weibull raspodjela pokazala se kao optimalan model za opisivanje statističkih svojstava svih mrežnih zapisa. Raspodjele Gamma, Nakagami i Weibull najbolje su za opisivanje *Segment_2* podataka. Za segment *Raspodjela_t* u *Netflix-static* mrežnim zapisima normalna distribucija jest najbolja, u *Netflix-driving* pojavljuju se dvije podjednako dobre distribucije Nakagami i Normalna, u *Amazon-Prime-static* Gamma distribucija te u *Amazon-Prime-driving* Gamma i Weibull raspodjela. Gamma raspodjela najbolja je za opisivanje segmenta *Raspodjela_T*.

Uz statističku analizu izmjerenih mrežnih zapisa dodatno je provedena analiza korelacije srednjih vrijednosti za *Segment_1*, *Segment_2*, *Raspodjela_t* i *Raspodjela_T*. Ova analiza provedena je pomoću MATLAB skripte naziva *Script_Correlation.m* čiji se izvorni programski kod nalazi u prilogu P.3.1. Za izračun korelacije korištena je MATLAB funkcija `corr()` koja izračunava matricu koeficijenta korelacije između svakog para stupaca u ulaznim matricama. U ovom slučaju ulazne matrice sadrže podatke svih srednjih vrijednosti svakog segmenta. Tablice 4.6. do 4.9. prikazuje izračunate korelacijske koeficijente srednjih vrijednosti između svih parova segmenata i raspodjela. Korelacijski koeficijenti pokazuju statističku povezanost između varijabli. Vrijednosti korelacijskih koeficijenta kreću se u rasponu od -1 do 1. Ako je vrijednost koeficijenta korelacije bliska broju jedan, tada se to naziva pozitivna korelacije što znači da kada se jedna varijabla promjeni ostale varijable se mijenjaju na isti način. Ako je vrijednost koeficijenta bliža broju -1 tada je to negativna korelacija te se događa obrnuto proporcionalna promjena varijabli. U slučaju da je koeficijent jednak 0 tada varijable nemaju međusobnu povezanost. U ovoj analizi segmenti s različitim propustima te vremenske raspodjele tih propusnosti pokazuju različite stupnjeve korelacijske povezanosti pri čemu *Segment_1* i *Segment_2* uglavnom pokazuju negativnu korelaciju. *Raspodjela_t* i *Raspodjela_T* međusobno pokazuju pozitivnu korelaciju.

Tablica 4.6. Tablica korelacije za Netflix-static statističku analizu

	Segment_1	Segment_2	Raspodjela_t	Raspodjela_T
Segment_1	1	-0,78	-0,78	-0,78
Segment_2	-0,78	1	-0,87	-0,87
Raspodjela_t	-0,87	-0,87	1	0,84
Raspodjela_T	0,84	0,84	0,84	1

Tablica 4.7. Tablica korelacije za Netflix-driving statističku analizu

	Segment_1	Segment_2	Raspodjela_t	Raspodjela_T
Segment_1	1	0,23	-0,84	-0,29
Segment_2	0,23	1	-0,51	-0,64
Raspodjela_t	-0,84	-0,51	1	0,2
Raspodjela_T	-0,29	-0,64	0,2	1

Tablica 4.8. Tablica korelacije za Amazon Prime Static statističku analizu

	Segment_1	Segment_2	Raspodjela_t	Raspodjela_T
Segment_1	1	-0,71	0,99	0,1
Segment_2	-0,71	1	-0,78	0,58
Raspodjela_t	0,99	-0,78	1	0,09
Raspodjela_T	0,1	0,59	0,09	1

Tablica 4.9. Tablica korelacije za Amazon Prime driving statističku analizu

	Segment_1	Segment_2	Raspodjela_t	Raspodjela_T
Segment_1	1	0,71	-0,2	0,38
Segment_2	0,71	1	0,19	0,34
Raspodjela_t	-0,2	0,19	1	0,74
Raspodjela_T	0,38	0,34	0,74	1

4.2. Generiranje sintetičkih mrežnih zapisa

U ovom potpoglavlju predstavljena je metoda sintetičkog generiranja mrežnih zapisa propusnosti pomoću parametara dobivenih statističkom analizom izmjerenih mrežnih zapisa. Pomoću MATLAB programskog okruženja napisana je skripta naziva *trace_sint5G_radni.m* koja za cilj ima generiranje sintetičkih mrežnih zapisa čiji se programski kod nalazi u prilogu P.3.1. Unutar ove skripte objedinjuje se programski kod iz skripte *Script_5G_Poisson.m* te se dodaju nove funkcionalnosti. Ulazni podaci izmjereni su mrežni zapisi za *Netflix* i *Amazon Prime* platforme te izračunati parametri promatranih raspodjela dobivenih pomoću statističke analize. Ova skripta generira slučajne nizove za vektore *Segment_1*, *Segment_2*, *Raspodjela_t* i *Raspodjela_T* s parametrima ovisno o raspodjeli. Varijabla *distrt1* predstavlja distribuciju niza *Segment_1* s parametrima *par5* i *par6*. Zatim varijabla *distrs2* jest distribucija niza *Segment_2* s parametrima *par7* i *par8*, varijabla *distrt* jest distribucija niza *Raspodjela_t* s parametrima *par1* i *par2* te varijabla *distrT* predstavlja distribuciju niza *Raspodjela_T* s parametrima *par3* i *par4*. Navedene parametre potrebno je prilagođavati s obzirom na odgovarajući mrežni zapis za koji se želi generirati sintetički mrežni zapis.

```

%Učitavanje Netflix dataseta
load('Netflix_driving.mat');
load('Netflix_static.mat');
load('netflix-static-names.mat');
load('netflix-driving-names.mat');

%Učitavanje Amazon Prime dataseta
load('Amazon_Prime_driving.mat');
load('Amazon_Prime_driving-names.mat');
load('Amazon_Prime_static.mat');
load('Amazon_Prime_static-names.mat');

% Netflix-static-2 -> Mijenjaj podatke ovisno o datasetu
distrs1 = 'weibull'; %SEGMENT 1
par5 = 1.9202;
par6 = 0.8965;
distrs2 = 'nakagami'; %SEGMENT 2
par7 = 0.4195;
par8 = 414889479;
distrt = 'gamma'; %Raspodjela t
par1 = 2.0087;
par2 = 21.14;
distrT = 'gamma'; %Raspodjela T
par3 = 4.368;
par4 = 0.3231;

```

Prilikom generiranja sintetičkih mrežnih zapisa koristi se MATLAB funkcija `random()` koja prima argumente o distribuciji i njezinim parametrima te prema ulaznim parametrima generira slučajne vrijednosti. Svakim pokretanjem ovog programskog koda generirat će se novi mrežni zapis sa novim slučajnim vrijednostima.

```

t = round(random(distrt,par1,par2,[duljina,1]));
T = round(random(distrT,par3,par4,[duljina,1]));

s1 = random(distrs1,par5,par6,[duljinas1,1]);
s2 = random(distrs2,par7,par8,[duljinas2,1]);

```

Nakon generiranja slučajnih vrijednosti za varijablu `t`, `T`, `s1` i `s2` provodi se slaganje podataka u jedan cjeloviti mrežni zapis. Definirana je nova varijabla `sint` koja predstavlja cjeloviti sintetički mrežni zapis. Ovisno o varijabli `redoslijed` u sintetički mrežni zapis `sint` se slažu podaci iz varijabli `s1` i `s2`.

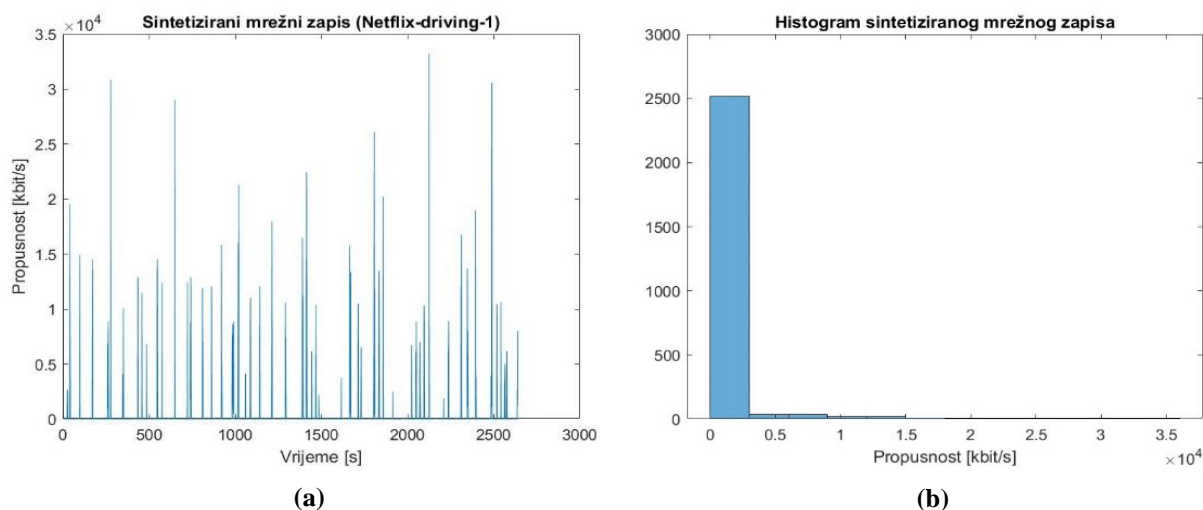
```

if redoslijed==0
    for i=1:duljina
        t1=t(i);
        T1=T(i);
        for kt=1:t1
            sint(tuk)=s1(kt+t2);
            tuk=tuk+1;
        end
        for kT=1:T1
            sint(tuk)=s2(kT+T2);
            tuk=tuk+1;
        end
        t2=t2+t(i);
        T2=T2+T(i);
    end
else
    for i=1:duljina
        t1=t(i);
        T1=T(i);
        for kT=1:T1
            sint(tuk)=s2(kT+T2);
            tuk=tuk+1;
        end
        for kt=1:t1
            sint(tuk)=s1(kt+t2);
            tuk=tuk+1;
        end
        t2=t2+t(i);
        T2=T2+T(i);
    end
end
end

```

4.3. Usporedba izmjerenih i sintetičkih mrežnih zapisa

U ovom potpoglavlju prezentirani su rezultati sintetičkog generiranja mrežnih zapisa te usporedba statističke analize sintetičkih mrežnih zapisa s izmjerenim. Prethodno opisanom metodom ukupno su generirana 24 sintetička zapisa od kojih je 12 sa statičkim obrascem, a ostalih 12 s obrascem u vožnji. Vremenske raspodjele svih generiranih mrežnih zapisa nalaze se u prilogu P.4.2. Za opis generiranih mrežnih zapisa odabran je primjer *Sint-Netflix-driving-1* koji je prikazan na slici 4.10. zajedno s pripadajućim histogramom. Na slici 4.10. vidljivo je da se ovim postupkom generiranja mrežnih zapisa zadržala karakteristika isprekidanog preuzimanja videosegmenata s naglim skokovima u propusnosti i velikim rasponom vrijednosti. Histogram sintetiziranog mrežnog zapisa također zadržava sličan raspon podataka kao i originalni izmjereni mrežni zapis te se većina podataka nalazi u rasponu od 0 do 5 Mbit/s dok se vrlo malo podataka nalazi u vrijednostima višim od 10 Mbit/s. Maksimalna vrijednosti iznosi 33 Mbit/s. Ove vrijednosti poklapaju se s vrijednostima izmjerenog mrežnog zapisa *Netflix-driving-1* kod kojeg je također vidljiva ista distribucija podataka.



Slika 4.10. (a) Sintetizirani mrežni zapis pomoću Netflix-driving-1 podataka s (b) pripadajućim histogramom

Kako bi se moglo detaljnije analizirati rezultate generiranja sintetičkih mrežnih zapisa predloženom metodom napravljena je statistička analiza sintetičkih mrežnih zapisa. Proveden je jednak postupak kao i za izmjerene mrežne zapise pomoću MATLAB skripte *Script_5G_sint_Poisson.m* čiji se izvorni kod može pronaći u prilogu P.3.1. Rezultati se sastoje od izračunatih parametara pripadajuće distribucije, LogL vrijednosti, srednje vrijednosti i standardne devijacije pojedinih segmenata te grafičkih prikaza sintetičkog mrežnog zapisa i histograma segmenata s prilagođenim raspodjelama Weibull, Gamma, Nakagami, Normal i Rician. Tablice 4.10. i 4.11. prikazuju usporedbu izmjerenih i sintetičkih mrežnih zapisa s pripadajućim parovima raspodjela koje su se pokazale kao najbolje za opisivanje statističkih svojstava. Sastoje se od šest stupaca koji sadrže ime mrežnog zapisa, pripadajuću raspodjelu i parametre, LogL vrijednost te razliku između LogL vrijednosti između izmjerenog i sintetičkog mrežnog zapisa. Razlika LogL vrijednosti izračunata je pomoću formule:

$$\text{Razlika [\%]} = \frac{\text{LogL}(\text{izmjereni}) - \text{LogL}(\text{sintetički})}{|\text{LogL}(\text{izmjereni})|} \times 100 \quad (4-12)$$

Formula (4-12) naglašuje razliku LogL vrijednosti sintetičkog mrežnog zapisa u odnosu na izmjereni mrežni zapis. U slučajevima kada je vrijednost razlike pozitivna to označuje da je izmjereni mrežni zapis postigao bolji LogL rezultat te ako je negativna vrijedi da je sintetički postigao bolji LogL rezultat. Za svaki izmjereni mrežni zapis u tablici prikazana je optimalna raspodjela dobivena statističkom analizom dok je za sintetički zapis odabrana jednaka raspodjela kao i za izmjereni mrežni zapis bez obzira je li ona optimalna za taj sintetički zapis. Time je moguće provesti odgovarajuću usporedbu parametara za obje vrste mrežnih zapisa. U slučajevima kada raspodjela za sintetički zapis nije optimalna uz nju je dodana oznaka u obliku indeksa koja označuje redni broj koji je ta raspodjela postigla u statističkoj analizi sintetičkih zapisa.

Tablica 4.10. Usporedna tablica izmjerenih i sintetiziranih *Netflix* mrežnih zapisa

Netflix-static-2		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	1,92	0,90	-7831,48	17,80
	Sintetički	Weibull ⁽²⁾	3,44	1,36	-9225,36	
Segment_2	Izmjereni	Nakagami	0,42	4,15E+08	-1605,93	9,48
	Sintetički	Nakagami	0,45	4,25E+08	-1758,15	
Raspodjela_t	Izmjereni	Gamma	2,01	21,14	-495,55	-3,69
	Sintetički	Gamma	1,95	22,66	-477,28	
Raspodjela_T	Izmjereni	Gamma	4,37	0,32	-101,16	-5,55
	Sintetički	Gamma	6,05	0,27	-95,55	
Netflix-static-3		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	1,98	0,83	-2164,08	22,30
	Sintetički	Weibull ⁽²⁾	3,44	1,28	-2646,60	
Segment_2	Izmjereni	Weibull	1,74E+04	1,06	-483,36	6,32
	Sintetički	Weibull ⁽²⁾	1,63E+04	0,99	-513,89	
Raspodjela_t	Izmjereni	Nakagami	0,64	2,09E+03	-140,39	1,57
	Sintetički	Nakagami	0,86	2,05E+03	-142,59	
Raspodjela_T	Izmjereni	Gamma	5,33	0,27	-27,58	-21,57
	Sintetički	Gamma	8,60	0,17	-21,63	
Netflix-static-4		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,03	0,82	-6786,79	11,82
	Sintetički	Weibull ⁽²⁾	3,58	1,41	-7588,97	
Segment_2	Izmjereni	Gamma	1,32	1,42E+04	-1276,31	3,86
	Sintetički	Gamma	1,41	1,41E+04	-1325,59	
Raspodjela_t	Izmjereni	Weibull	44,18	1,50	-421,21	-3,54
	Sintetički	Weibull	45,98	1,49	-406,29	
Raspodjela_T	Izmjereni	Gamma	7,13	0,18	-58,63	3,94
	Sintetički	Gamma	7,42	0,19	-60,94	
Netflix-static-5		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,37	0,73	-5020,13	19,59
	Sintetički	Weibull ⁽²⁾	4,18	1,08	-6003,34	
Segment_2	Izmjereni	Gamma	0,99	1,08E+04	-1993,39	-1,76
	Sintetički	Gamma ⁽²⁾	1,18	9,41E+03	-1958,39	
Raspodjela_t	Izmjereni	Normal	30,78	17,04	-340,36	-5,76
	Sintetički	Normal ⁽²⁾	32,27	14,78	-320,74	
Raspodjela_T	Izmjereni	Gamma	3,84	0,63	-123,15	-0,28
	Sintetički	Gamma	3,56	0,68	-122,80	

Netflix-static-9		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,12	0,79	-10684,40	24,38
	Sintetički	Weibull ⁽²⁾	3,87	1,07	-13288,82	
Segment_2	Izmjereni	Gamma	0,86	1,52E+04	-3977,04	4,34
	Sintetički	Gamma ⁽²⁾	0,99	1,33E+04	-4149,84	
Raspodjela_t	Izmjereni	Normal	32,40	15,47	-723,49	-1,61
	Sintetički	Normal	33,41	15,17	-711,83	
Raspodjela_T	Izmjereni	Gamma	3,40	0,64	-258,04	-5,70
	Sintetički	Gamma	4,56	0,51	-243,32	
Netflix-static-10		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,11	0,82	-3202,28	21,17
	Sintetički	Weibull ⁽²⁾	3,64	1,31	-3880,15	
Segment_2	Izmjereni	Weibull	1,54E+04	1,03	-1042,07	3,45
	Sintetički	Weibull ⁽²⁾	1,44E+04	1,01	-1078,01	
Raspodjela_t	Izmjereni	Normal	34,14	13,31	-196,37	2,64
	Sintetički	Normal ⁽⁵⁾	37,14	14,80	-201,55	
Raspodjela_T	Izmjereni	Gamma	2,98	0,67	-70,80	-6,61
	Sintetički	Gamma	3,94	0,53	-66,12	
Netflix-driving-1		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,01	0,86	-4229,35	22,28
	Sintetički	Weibull ⁽²⁾	3,53	1,31	-5171,81	
Segment_2	Izmjereni	Gamma	1,22	6,09E+03	-1742,74	-4,34
	Sintetički	Gamma ⁽²⁾	1,40	5,53E+03	-1667,05	
Raspodjela_t	Izmjereni	Weibull	46,95	1,83	-251,57	3,81
	Sintetički	Weibull ⁽²⁾	48,97	1,55	-261,15	
Raspodjela_T	Izmjereni	Gamma	2,09	1,50	-112,91	-5,87
	Sintetički	Gamma	2,61	1,15	-106,28	
Netflix-driving-3		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,46	0,72	-864,15	8,70
	Sintetički	Weibull	4,19	0,92	-939,29	
Segment_2	Izmjereni	Nakagami	0,29	5,03E+08	-317,89	-8,30
	Sintetički	Nakagami ⁽³⁾	0,37	2,78E+08	-291,49	
Raspodjela_t	Izmjereni	Nakagami	0,35	1,02E+03	-62,03	10,19
	Sintetički	Nakagami	0,45	733,47	-68,35	
Raspodjela_T	Izmjereni	Gamma	3,11	0,64	-21,43	-24,59
	Sintetički	Gamma	5,72	0,30	-16,16	

Netflix-driving-9		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	1,98	0,83	-2358,61	-6,95
	Sintetički	Weibull ⁽²⁾	3,59	1,36	-2194,59	
Segment_2	Izmjereni	Nakagami	0,62	1,44E+08	-616,25	5,30
	Sintetički	Nakagami ⁽²⁾	0,64	2,16E+08	-648,93	
Raspodjela_t	Izmjereni	Gamma	1,84	25,44	-133,07	-3,40
	Sintetički	Gamma ⁽³⁾	1,39	26,87	-128,55	
Raspodjela_T	Izmjereni	Gamma	2,81	0,78	-43,46	0,09
	Sintetički	Gamma	2,63	0,86	-43,50	
Netflix-driving-11		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,63	0,68	-4891,84	15,08
	Sintetički	Weibull ⁽²⁾	4,59	1,00	-5629,52	
Segment_2	Izmjereni	Gamma	0,90	8,49E+03	-1718,50	10,09
	Sintetički	Gamma	1,19	6,95E+03	-1891,92	
Raspodjela_t	Izmjereni	Nakagami	0,35	1,67E+03	-320,04	0,66
	Sintetički	Nakagami	0,37	1,72E+03	-322,16	
Raspodjela_T	Izmjereni	Gamma	1,92	1,23	-128,35	-3,63
	Sintetički	Gamma	2,88	0,90	-123,69	
Netflix-driving-12		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,07	0,81	-2221,26	13,85
	Sintetički	Weibull ⁽²⁾	3,66	1,28	-2528,93	
Segment_2	Izmjereni	Nakagami	0,43	1,60E+08	-1280,50	-2,11
	Sintetički	Nakagami ⁽³⁾	0,46	1,98E+08	-1253,50	
Raspodjela_t	Izmjereni	Normal	37,47	12,56	-126,38	-2,26
	Sintetički	Normal ⁽⁵⁾	36,69	11,49	-123,53	
Raspodjela_T	Izmjereni	Gamma	2,32	1,69	-68,44	-5,96
	Sintetički	Gamma ⁽⁴⁾	2,73	1,33	-64,36	
Netflix-driving-23		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,11	0,77	-3213,90	44,07
	Sintetički	Weibull ⁽²⁾	3,93	1,02	-4630,33	
Segment_2	Izmjereni	Weibull	4,96E+03	0,87	-2880,16	-47,88
	Sintetički	Weibull ⁽²⁾	5,91E+03	1,14	-1501,24	
Raspodjela_t	Izmjereni	Normal	38,34	15,93	-184,24	1,17
	Sintetički	Normal ⁽⁴⁾	53,08	37,29	-186,40	
Raspodjela_T	Izmjereni	Weibull	5,52	0,78	-124,75	-29,58
	Sintetički	Weibull ⁽²⁾	4,21	0,99	-87,85	

U tablici 4.10. nalazi se usporedba parametara distribucija i LogL vrijednosti za sve analizirane *Netflix* mrežne zapise. Analizom podataka iz navedene tablice vidljivo je da predloženi model uspješno generira sintetičke mrežne zapise propusnosti sa sličnim statističkim svojstima kao i kod izmjerenog mrežnog zapisa. Ako se za primjer uzme *Segment_1* iz *Netflix-driving-3* mrežnog zapisa može se zaključiti da je izmjereni mrežni zapis najbolje opisan Weibullovom raspodjelom s parametrima 2,46 i 0,72 sa LogL vrijednosti -864,15 dok sintetički mrežni zapis također najbolje opisuje Weibull distribucija, ali s parametrima 4,19 i 0,92 sa pripadajućom LogL vrijednosti u iznosu od -939,29. Razlika između LogL vrijednosti iznosi 8,70 % što se smatra malim odstupanjem. Za *Segment_1* mrežnog zapisa *Netflix-static-2* također je Weibull optimalna raspodjela s parametrima 1,92 i 0,90 s LogL vrijednosti -7831,48, ali u ovom slučaju za sintetički mrežni zapis Weibull raspodjela pokazala kao druga najbolja s parametrima 3,44 i 1,36 te LogL vrijednosti -9225,36. Iako nije optimalna distribucija i dalje je iznos razlike 17,80 % što se može smatrati umjerenim odstupanjem od izmjerenog mrežnog zapisa. Za *Netflix-driving-23* u *Segment_1* pojavljuje se veliko odstupanje od izmjerenog mrežnog zapisa u iznosu od 44,07 %. Također za *Segment_2* istog zapisa ima odstupanje od -47,88 % što je također velike odstupanje. Gledajući globalno, razlike u LogL vrijednostima su ponekad niske ispod 5 %, a ponekad prelaze 20 % što ovisi o statističkim karakteristikama segmenata i cjelokupnog mrežnog zapisa te se time zaključuje da pojedini segmenti imaju različite karakteristike koje je lakše ili teže sintetizirati.

Tablica 4.11. Usporedna tablica izmjerenih i sintetiziranih *Amazon-Prime* mrežnih zapisa

Amazon-Prime-static-1		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,60	0,58	-4445,92	70,15
	Sintetički	Weibull	8,22	0,65	-7564,86	
Segment_2	Izmjereni	Weibull	3,42E+03	0,68	-16120,48	-10,75
	Sintetički	Weibull	4,54E+03	0,84	-14387,59	
Raspodjela_t	Izmjereni	Gamma	1,64	1,01	-1732,69	-7,07
	Sintetički	Gamma	2,51	0,96	-1610,21	
Raspodjela_T	Izmjereni	Gamma	5,13	0,28	-1085,12	-10,82
	Sintetički	Gamma	4,89	0,33	-967,74	
Amazon-Prime-static-2		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,29	0,63	-1938,44	34,37
	Sintetički	Weibull	7,47	0,62	-2604,62	
Segment_2	Izmjereni	Weibull	3,24E+03	0,69	-6251,65	-9,03
	Sintetički	Weibull	4,67E+03	0,87	-5687,22	
Raspodjela_t	Izmjereni	Weibull	1,79	0,86	-668,87	-15,69
	Sintetički	Weibull ⁽²⁾	3,12	1,33	-563,90	

Raspodjela_T	Izmjereni	Gamma	3,34	0,51	-493,70	-13,06
	Sintetički	Gamma	2,84	0,74	-429,21	
Amazon-Prime-static-3		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	2,63	0,60	-7800,63	56,93
	Sintetički	Weibull	7,73	0,65	-12241,67	
Segment_2	Izmjereni	Weibull	3,74E+03	0,70	-28662,31	-7,19
	Sintetički	Weibull	5,13E+03	0,85	-26600,77	
Raspodjela_t	Izmjereni	Gamma	1,63	1,02	-3045,80	-12,87
	Sintetički	Gamma	2,81	0,81	-2653,81	
Raspodjela_T	Izmjereni	Gamma	5,05	0,29	-1928,60	-5,48
	Sintetički	Gamma	4,52	0,37	-1822,83	
Amazon-Prime-static-4		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Nakagami	0,24	3,60E+03	-9939,58	2,47
	Sintetički	Nakagami ⁽³⁾	0,29	3,31E+03	-10184,85	
Segment_2	Izmjereni	Gamma	4,67	1,68E+02	-745,23	29,15
	Sintetički	Gamma	3,21	1,99E+02	-962,50	
Raspodjela_t	Izmjereni	Nakagami	0,59	2,00E+03	-243,93	30,11
	Sintetički	Nakagami ⁽³⁾	0,48	1,58E+03	-317,37	
Raspodjela_T	Izmjereni	Gamma	1,59	1,20	-85,78	18,84
	Sintetički	Gamma	2,54	0,74	-101,94	
Amazon-Prime-static-6		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	3,46	0,54	-5307,10	29,39
	Sintetički	Weibull	7,45	0,72	-6866,91	
Segment_2	Izmjereni	Weibull	8,36E+03	1,10	-40199,59	-2,36
	Sintetički	Weibull ⁽²⁾	8,73E+03	1,18	-39250,05	
Raspodjela_t	Izmjereni	Gamma	3,47	0,35	-1544,07	-7,09
	Sintetički	Gamma	4,54	0,35	-1434,63	
Raspodjela_T	Izmjereni	Gamma	1,25	1,84	-3177,02	-17,39
	Sintetički	Gamma	2,17	1,31	-2624,39	
Amazon-Prime-static-8		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	3,03	0,56	-1937,04	42,54
	Sintetički	Weibull	7,22	0,69	-2761,06	
Segment_2	Izmjereni	Gamma	0,93	8,85E+03	-14693,78	-17,03
	Sintetički	Gamma	1,07	7,62E+03	-12191,02	
Raspodjela_t	Izmjereni	Gamma	2,12	0,65	-698,34	-11,42
	Sintetički	Gamma	2,70	0,85	-618,57	

Raspodjela_T	Izmjereni	Weibull	2,23	0,87	-1106,95	-27,32
	Sintetički	Weibull ⁽²⁾	3,48	1,30	-804,56	
Amazon-Prime-driving-1		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	3,22	0,55	-2420,67	56,82
	Sintetički	Weibull	12,17	0,60	-3796,08	
Segment_2	Izmjereni	Weibull	1,13E+03	0,81	-7346,52	-26,94
	Sintetički	Weibull ⁽²⁾	1,56E+03	1,20	-5367,20	
Raspodjela_t	Izmjereni	Weibull	1,78	0,79	-718,55	-5,35
	Sintetički	Weibull	3,49	1,20	-680,13	
Raspodjela_T	Izmjereni	Gamma	2,68	0,81	-649,72	-28,00
	Sintetički	Gamma	2,93	0,70	-467,83	
Amazon-Prime-driving-4		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	3,83	0,54	-6548,37	46,31
	Sintetički	Weibull	13,06	0,61	-9581,04	
Segment_2	Izmjereni	Weibull	1,15E+03	0,84	-17581,74	-17,91
	Sintetički	Weibull ⁽²⁾	1,59E+03	1,17	-14433,65	
Raspodjela_t	Izmjereni	Weibull	1,97	0,77	-1747,72	-3,37
	Sintetički	Weibull ⁽²⁾	3,48	1,13	-1688,79	
Raspodjela_T	Izmjereni	Gamma	2,30	0,99	-1580,02	-20,98
	Sintetički	Gamma	2,58	0,87	-1248,48	
Amazon-Prime-driving-7		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	4,50	0,50	-1545,73	56,87
	Sintetički	Weibull	16,43	0,60	-2424,86	
Segment_2	Izmjereni	Weibull	1,08E+03	0,93	-5029,12	-17,37
	Sintetički	Weibull ⁽²⁾	1,46E+03	1,26	-4155,53	
Raspodjela_t	Izmjereni	Weibull	1,78	0,85	-448,69	-7,56
	Sintetički	weibull	3,16	1,32	-422,85	
Raspodjela_T	Izmjereni	Gamma	2,28	1,03	-453,36	-22,50
	Sintetički	Gamma	2,70	0,89	-351,36	
Amazon-Prime-driving-9		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	3,44	0,55	-903,72	121,14
	Sintetički	Weibull	17,26	0,58	-1998,47	
Segment_2	Izmjereni	Weibull	1,05E+03	0,87	-4469,19	-21,08
	Sintetički	weibull	1,48E+03	1,23	-3536,87	
Raspodjela_t	Izmjereni	Gamma	6,75	0,19	-182,27	1835,19
	Sintetički	Gamma	1,59	8,60E+02	-3527,27	

Raspodjela_T	Izmjereni	Gamma	2,91	0,67	-408,41	-30,76
	Sintetički	Gamma	4,61	0,36	-282,78	
Amazon-Prime-driving-15		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	4,19	0,52	-3261,51	71,98
	Sintetički	Weibull	15,40	0,61	-5609,05	
Segment_2	Izmjereni	Gamma	1,08	1,05E+03	-13419,96	-15,91
	Sintetički	Gamma	1,87	6,91E+02	-11284,33	
Raspodjela_t	Izmjereni	Gamma	2,48	0,59	-986,75	3,59
	Sintetički	Gamma	3,20	0,62	-1022,19	
Raspodjela_T	Izmjereni	Gamma	2,87	0,71	-1213,82	-18,96
	Sintetički	Gamma	3,41	0,56	-983,69	
Amazon-Prime-driving-18		Raspodjela	Parametar 1	Parametar 2	LogL	Razlika (%)
Segment_1	Izmjereni	Weibull	11,43	0,54	-1719,76	25,14
	Sintetički	Weibull	25,41	0,68	-2152,04	
Segment_2	Izmjereni	Weibull	1,42E+03	0,81	-4472,09	-15,42
	Sintetički	Weibull ⁽²⁾	2,02E+03	1,03	-3782,38	
Raspodjela_t	Izmjereni	Gamma	1,89	0,91	-344,20	3,05
	Sintetički	Gamma	2,41	0,96	-354,70	
Raspodjela_T	Izmjereni	Gamma	2,33	0,96	-392,68	-21,43
	Sintetički	Gamma	3,18	0,65	-308,52	

U tablici 4.11. nalaze se usporedni rezultati statističke analize izmjerenih i sintetičkih mrežnih zapisa za sve *Amazon Prime* mrežne zapise. Pregledom rezultata moguće je vidjeti da su postignuti slični pozitivni rezultati kao i za *Netflix* mrežne zapise. Za *Amazon* podatke pojavljuje se više razlika LogL vrijednosti s velikim iznosima kao kod mrežnog zapisa *Amazon-Prime-driving-9* za *Raspodjelu_t* gdje je razlika najvećih 1835,19 % u odnosu na sve segmente mrežnih zapisa te se jasno može reći da generirani sintetički zapis u ovom slučaju ne opisuje izmjereni zapis. Također u većini *Segment_1* pojavljuju se razlike veće od 20 % te u je u prosjeku razlika u 51.43 % što se smatra lošijim rezultatom. Za ostale segmente postignuti su zadovoljavajući rezultati sličnosti. Nakon cjelokupne analize svih podataka moguće je zaključiti da nema jedinstvene raspodjele koja optimalno opisuje sve vrste mrežnih zapisa. Najčešće su se kao optimalne raspodjele pokazale Weibull, Gamma, Nakagami koje se mogu iskoristiti u daljnjim istraživanjima modeliranja statističkih karakteristika propusnosti. Sintetizirani mrežni zapisi i njihovi segmenti u mnogo slučajeva pokazuju vrlo male postotne razlike u LogL vrijednostima, ali postoje i veća odstupanja u pojedinim segmentima.

Tablica 4.12. Tablica usporedbe srednjih vrijednosti i standardne devijacije izmjerenih i sintetiziranih mrežnih zapisa

		Srednja vrijednost [kbit/s]	Razlika (%)	Standardna devijacija [kbit/s]	Razlika (%)
Netflix-static-2	Izmjereni	501,46	-12,86	3616,21	-5,97
	Sintetički	565,97		3831,95	
Netflix-static-3	Izmjereni	616,52	2,91	4544,36	-4,18
	Sintetički	598,57		4734,41	
Netflix-static-4	Izmjereni	578,92	-11,23	4557,64	-1,65
	Sintetički	643,91		4632,84	
Netflix-static-5	Izmjereni	780,97	-0,16	3916,44	1,71
	Sintetički	782,23		3849,36	
Netflix-static-9	Izmjereni	823,32	-2,78	4842,49	2,53
	Sintetički	846,21		4720,06	
Netflix-static-10	Izmjereni	826,08	7,80	4987,92	11,90
	Sintetički	761,61		4394,41	
Netflix-driving-1	Izmjereni	515,90	3,53	2649,41	6,54
	Sintetički	497,70		2476,05	
Netflix-driving-3	Izmjereni	1064,50	21,98	5735,21	25,06
	Sintetički	830,49		4297,90	
Netflix-driving-9	Izmjereni	447,85	-54,53	2491,11	-37,67
	Sintetički	692,08		3429,56	
Netflix-driving-11	Izmjereni	546,08	-18,75	2822,79	-9,93
	Sintetički	648,46		3103,08	
Netflix-driving-12	Izmjereni	960,09	-6,62	3781,60	-10,83
	Sintetički	1023,69		4191,16	
Netflix-driving-23	Izmjereni	811,55	48,58	3231,00	38,28
	Sintetički	417,29		1994,15	
Amazon-Prime-static-1	Izmjereni	2136,94	5,68	7030,89	28,63
	Sintetički	2015,60		5017,76	
Amazon-Prime-static-2	Izmjereni	1843,42	-16,99	6803,60	26,66
	Sintetički	2156,65		4989,62	
Amazon-Prime-static-3	Izmjereni	2235,50	-7,02	6303,61	7,35
	Sintetički	2392,41		5840,35	
Amazon-Prime-static-4	Izmjereni	74,66	2,80	175,83	4,72
	Sintetički	72,57		167,53	
Amazon-Prime-static-6	Izmjereni	5295,80	-0,29	7576,55	7,69
	Sintetički	5310,91		6994,03	

Amazon-Prime-static-8	Izmjereni	5269,21	9,62	8802,70	13,92
	Sintetički	4762,52		7577,42	
Amazon-Prime-driving-1	Izmjereni	641,50	10,14	2780,88	60,41
	Sintetički	576,46		1100,89	
Amazon-Prime-driving-4	Izmjereni	609,33	-1,37	2237,23	47,53
	Sintetički	617,70		1173,89	
Amazon-Prime-driving-7	Izmjereni	599,71	-4,55	1333,43	20,60
	Sintetički	627,02		1058,80	
Amazon-Prime-driving-9	Izmjereni	700,12	6,97	2238,28	51,30
	Sintetički	651,29		1090,04	
Amazon-Prime-driving-15	Izmjereni	657,00	1,32	1280,01	24,14
	Sintetički	648,34		970,97	
Amazon-Prime-driving-18	Izmjereni	887,62	-7,73	3000,54	40,27
	Sintetički	956,20		1792,30	

Tablica 4.12. uspoređuje srednje vrijednosti i standardnu devijaciju za izmjerene i sintetičke mrežne zapise. Pregledom rezultata vidljivo je da većina podataka vezanih za *Netflix* uslugu pokazuje relativno male razlike između srednjih vrijednosti izmjerenih i sintetičkih podataka koja je u rasponu od ± 10 %. Veća odstupanja nastaju u slučajevima za mrežni zapis *Netflix-driving-3* gdje razlika doseže 21,98 % te slučaju *Netflix-driving-23* s velikom razlikom od 48,58 %. Mrežni zapisi od *Amazon Prime* usluge također pokazuju male razlike osim u slučaju *Amazon-Prime-static-2* s razlikom od -16,99 % što se samatra umjerenim odstupanjem. Raspon srednjih vrijednosti analiziranih mrežnih zapisa iznosi od 72,57 kbit/s do 5,31 Mbit/s. Važno je naglasiti da mjerenja propusnosti koja su provedena tijekom strujanja videosadržaja ne pružaju uvid u maksimalnu propusnost koju mreža može pružiti u svakom trenutku. Ovakva optimizacija videostrujanja uzrokovana je MPEG DASH normom odnosno principom rada ABR algoritama koji na temelju svojih proračuna kontinuirano mijenjaju razine kvalitete videosegmenata kako bi kvaliteta usluge za korisnika ostala visoka. ABR algoritmi stavljaju prioritet na smanjenje broja prekida reprodukcije, pojave *bufferinga* ili čestog mijenjanja kodne brzine. Potrebna propusnost za prijenos videosegmenata ograničena je također i kvalitetom u kojoj je videosadržaj pohranjen na poslužitelju. Kako je navedeno u [7] usluga *Netflix* koristi veće kodne brzine i veće videosegmente za koje je potrebna veća propusnost dok usluga *Amazon Prime* koristi niže kodne brzine. Zbog ovih razloga mjerenja tijekom videostrujanja neće pokazati najveću moguću propusnost za pojedinu mrežu u svakom trenutku.

Razlike standardnih devijacija za *Netflix* izmjerene i sintetizirane mrežne zapise također su mala osim u slučaju *Netflix-driving-3* gdje razlika postiže 25,06 % te *Netflix-driving-23* s razlikom od 38,28 %. Razlike u standardnim devijacijama kod *Amazon Prime* mrežnih zapisa postižu veće iznose u odnosu na *Netflix*. Umjereno odstupanje postoji za slučajeve *Amazon-Prime-static-1* (28,63 %) i *Amazon-Prime-static-2* (26,66 %) dok se velika odstupanja pojavljuju u *Amazon-Prime-driving-1* (60,41 %), *Amazon-Prime-driving-4* (47,53 %), *Amazon-Prime-driving-9* (51,30 %), *Amazon-Prime-driving-18* (40,27 %). Generalno je vidljiv trend da se najveća odstupanja pojavljuju kod mrežnih zapisa s mobilnim korisnikom što sugerira da sintetički modeli slabije predviđaju statističke karakteristike u uvjetima s mobilnim korisnikom. Sintetički podaci su precizniji u statičkim scenarijima mobilnosti nego u dinamičkim.

5. ZAKLJUČAK

Videostrujanje je postala jedna od najrasprostranjenijih tehnologija pristupa videosadržaju na internetu i zauzima sve veći udio ukupnog internetskog prometa. Time je postalo velikim predmetom ulaganja, istraživanja i razvoja. Ovaj diplomski rad obrađuje temu principa videostrujanja definiranog prema MPEG DASH normi te karakteristike videostrujanja preko 5G mobilnih mreža. U praktičnom dijelu stavljen je naglasak na stvaranje umjetno generiranih 5G mrežnih ispitnih zapisa za testiranje algoritma za prilagodbu prijenosne brzine. Pomoću MATLAB programskog okruženja provedena je statistička analiza izmjerenih 5G mrežnih zapisa pomoću koje su uspoređene vremenske raspodjele propusnosti s teorijskim modelima Nakagami, Weibull, Rician, Gamma i Gauss. Ovim postupkom određene su distribucije koje najbolje opisuju realne podatke te njihovi parametri. Zatim je predložena metoda za generiranje sintetičkih mrežnih zapisa koja koristi izračunate parametre distribucija. Važno je istaknuti da metoda za generiranje sintetičkih zapisa koristi nasumične brojeve koji svakim pokretanjem postupka generiraju drukčije mrežne zapise iako su parametri distribucija ostali nepromijenjeni. Za opsežniju analizu ABR algoritama potrebno je pronaći veći broj mrežnih zapisa prikupljenih iz realnih mreža s različitim statističkim svojstvima kako bi se mogli generirati sintetički zapisi koji pokrivaju veći broj karakteristika. Uspješnost generiranja sintetičkih zapisa utvrđena je u posljednjem koraku pomoću usporedbe rezultata statističke analize izmjerenih i sintetičkih mrežnih zapisa. Analizom podataka zaključeno je da predložena metoda generiranja sintetičkih zapisa uspješno stvara zapise koji imaju slične statističke karakteristike kao i stvarni izmjereni zapisi te je pokazano da razlike između sintetičkih i izmjerenih zapisa su ponekad niske ispod 5 %, a ponekad prelaze 20 % što govori da pojedini segmenti imaju različite karakteristike koje je lakše odnosno teže sintetizirati. Također analizom srednjih vrijednosti propusnosti mrežnih zapisa primjećeno je da se tijekom videostrujanja ne postižu maksimalne vrijednosti propusnosti koje 5G mreža može pružiti. Time se pokazuje optimizacija rada ABR algoritama koji na temelju predviđanja propusnosti kontinuirano mijenjaju razine kvalitete videosegmenata kako bi kvaliteta iskustva za korisnika ostala visoka. Potrebna propusnost za prijenos videosegmenata također je ograničena kvalitetom u kojoj je videosadržaj pohranjen na poslužitelju.

Zaključno, ovim diplomskim radom ispunjeni su svih zahtjevi zadatka diplomskog rada te je pokazana metoda koja u velikoj mjeri uspješno generira sintetičke mreže zapise. Područje optimizacije sustava videostrujanja i ABR algoritama omogućava veliki prostor za daljnja istraživanja poput provođenja vlastitih mjerenja propusnosti u 5G mrežama te radu na poboljšanju postojećih i osmišljavanje novih metoda za optimizaciju videostrujanja.

LITERATURA

- [1] H. Riiser, P. Vigmostad, C. Griwodz, P. Halvorsen, "Commute path bandwidth traces from 3G networks", 4th ACM Multimedia Systems Conference (MMSys '13), Association for Computing Machinery, str. 114–118, New York, NY, SAD, 2013.
- [2] A. Bokani, M. Hassan, S. S. Kanhere, J. Yao, G. Zhong, "Comprehensive mobile bandwidth traces from vehicular networks", 7th International Conference on Multimedia Systems (MMSys '16), Association for Computing Machinery, sv. 44, str. 1–6., New York, NY, SAD, 2016.
- [3] 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, sv. 20, str. 2177-2180, 2016.
- [4] Y. Sun, X. Yin, J. Jiang, V. Sekar, F. Lin, N. Wang, T. Liu, B. Sinopoli, "CS2P: Improving Video Bitrate Selection and Adaptation with Data-Driven Throughput Prediction" ACM SIGCOMM Conference, str. 272–285., New York, NY, SAD, 2016.
- [5] A. Biernacki, "Improving quality of adaptive video by traffic prediction with (F)ARIMA models", Journal of Communications and Networks, sv. 19, str. 521-530, 2017.
- [6] Z. Akhtar, Y. Seong Nam, R. Govindan, S. Rao, J. Chen, E. Katz-Bassett, B. Ribeiro, J. Zhan, H. Zhang, „Oboe: auto-tuning video ABR algorithms to network conditions“, Conference of the ACM Special Interest Group on Data Communication, str. 44–58., New York, NY, SAD, 2018.
- [7] D. Raca, D. Leahy, C. J. Sreenan, J. J. Quinlan, "Beyond throughput, the next generation: a 5G dataset with channel and context metrics“, ACM Multimedia Systems Conference (MMSys), Istanbul, Turkey, 2020.
- [8] H. Elsherbiny, "4G LTE Network Data Collection and Analysis along Public Transportation Routes," GLOBECOM 2020 - 2020 IEEE Global Communications Conference, Taipei, Taiwan, str. 1-6, 2020.
- [9] C. Qiao, G. Li, Q. Ma, J. Wang and Y. Liu, "Trace-Driven Optimization on Bitrate Adaptation for Mobile Video Streaming," IEEE Transactions on Mobile Computing, sv. 21, str. 2243-2256, 2022.

- [10] L. Shrama, A. Javali, S. K. Routray, "An Overview of High Speed Streaming in 5G," 2020 International Conference on Inventive Computation Technologies (ICICT), Coimbatore, India, 2020.
- [11] A. Volle, "Streaming media", Encyclopedia Britannica, 2023. dostupno na URL: <https://www.britannica.com/technology/streaming-media>. [26.10. 2024.]
- [12] W. L. Hosch, N. Ashburn, "Netflix." Encyclopedia Britannica, 2009. dostupno na URL: <https://www.britannica.com/money/Netflix-Inc>. [26.10.2024.]
- [13] Eurostat, "65% of people in the EU streamed TV or videos in 2022", Eurostat, 2024. dostupno na URL: <https://ec.europa.eu/eurostat/web/products-eurostat-news/w/ddn-20240415-2> [26.10.2024.]
- [14] Ericsson, Ericsson Mobility Report [online], 2024., dostupno na: <https://www.ericsson.com/en/reports-and-papers/mobility-report/mobility-visualizer?f=1&ft=2&r=2,3,4,5,6,7,8,9&t=1,2,3,4,5,6,7&s=4&u=1&y=2024,2030&c=3> [10.12.2024.]
- [15] I. Sodagar, "The MPEG-DASH Standard for Multimedia Streaming Over the Internet," in IEEE MultiMedia, vol. 18, no. 4, pp. 62-67, April 2011
- [16] J. Kovacevic, G. Miljkovic, V. Mihic and K. Lazic, "Advanced rate adaptation algorithm in video streaming over HTTP," 2014 IEEE Fourth International Conference on Consumer Electronics Berlin (ICCE-Berlin), Berlin, Germany, 2014, pp. 78-82
- [17] J. Vlaović, "Metoda za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje", Disertacija, Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, Osijek, 2022. Dostupno na: <https://urn.nsk.hr/urn:nbn:hr:200:069525> [28.6.2024.]
- [18] L. R. Solano-Hurtado, M. M. Soto-Cordova, "A Study on Video Streaming Quality of DASH Scheme in Multimedia Services," 2021 Congreso Internacional de Innovación y Tendencias en Ingeniería (CONIITI), Bogotá, Colombia, 2021.
- [19] I. Sodagar, „The MPEG-DASH Standard for Multimedia Streaming Over the Internet“, IEEE MultiMedia, br. 4, sv. 18, str. 62-67, 2011.

- [20] B. Muralidharan, "Video Quality of Service (QoS) Tutorial", Cisco, 2017., dostupno na: <https://www.cisco.com/c/en/us/support/docs/quality-of-service-qos/qos-video/212134-Video-Quality-of-Service-QOS-Tutorial.html> [29.10.2024.]
- [21] The 3rd Generation Partnership Project (3GPP), Releases, Sophia Antipolis, 2024., dostupno na: <https://www.3gpp.org/specifications-technologies/releases> [11.12.2024.]
- [22] E. Mohyeldin, „Minimum Technical Performance Requirements for IMT-2020 radio interface(s)“, 2020., dostupno na: https://www.itu.int/en/ITU-R/study-groups/rsg5/rwp5d/imt-2020/Documents/S01-1_Requirements%20for%20IMT-2020_Rev.pdf [11.12.2024.]
- [23] A. Nordrum, K. Clark, "Everything You Need to Know About 5G", IEEE Spectrum, Velika Britanija, 27.1.2017., dostupno na URL: <https://spectrum.ieee.org/everything-you-need-to-know-about-5g> [11.12.2024.]
- [24] R. K. Panta, "Mobile Video Delivery: Challenges and Opportunities," IEEE Internet Computing, 2015.
- [25] S. Rimac-Drlje, J. Vlaović, "Network Throughputs Modelling for Mobile Video Streaming Analysis," 2021 16th International Conference on Telecommunications (ConTEL), Zagreb, Hrvatska, 2021.
- [26] Francisco de Castro, fitmethis, MATLAB Central File Exchange, 2013., dostupno na: <https://www.mathworks.com/matlabcentral/fileexchange/40167-fitmethis> [28.6.2024.]

SAŽETAK

U ovom diplomskog radu opisan je sustav videostrujanja prema MPEG DASH normi te navedene karakteristike pete generacije mobilnih mreža koje poboljšavaju uslugu videostrujanja preko mobilnih mreža. Glavni problem jest provedba optimizacije sustava videostrujanja kako bi svaki korisnik imao zadovoljavajuću kvalitetu usluge. Za istraživanje i razvoj novih rješenja optimizacije, između ostalog potrebni su mrežni zapisi ostvarenih brzina prijenosa kod videostrujanja snimljeni u stvarnim mrežama. Snimljeni mrežni zapisi najbolje opisuju različite mrežne uvjete, ali zbog nedostatnog broja javno dostupnih mrežnih zapisa te njihove statističke nepredvidljivosti postoji potreba za generiranje sintetičkih mrežnih zapisa. U praktičnom dijelu rada provedena je statistička analiza baze 5G mrežnih zapisa pomoću teorijskih raspodjela Nakagami, Weibull, Rician, Gamma i Gauss. Pomoću dobivenih parametara generirani su sintetički mrežni zapisi te je napravljena analiza koliko dobro sintetički mrežni zapisi oponašaju karakteristike stvarnih izmjernih mrežnih zapisa.

Ključne riječi: videostrujanje, 5G, propusnost, sintetički mrežni zapisi, raspodjela podataka, statistička analiza

ABSTRACT

This thesis describes a video streaming system according to the MPEG DASH standard and lists the characteristics of fifth-generation mobile networks that improve video streaming services over mobile networks. The main problem is to implement optimization of the video streaming system so that each user has a satisfactory quality of service. For research and development of new optimization solutions, among other things, network traces of achieved video streaming transfer rates recorded in real networks are needed. Recorded network traces best describe different network conditions but due to the insufficient number of publicly available network traces and their statistical unpredictability, there is a need to generate synthetic network traces. In the practical part of the thesis, a statistical analysis of the 5G network traces database was performed using the theoretical Nakagami, Weibull, Rician, Gamma and Gauss distributions. Using the obtained parameters, synthetic network traces were generated and an analysis was made of how well the synthetic network traces mimic the characteristics of real measured network traces.

Keywords: video streaming, 5G, bandwidth, sintetic network traces, data distribution, statistical analysis

ŽIVOTOPIS

Autor ovog diplomskog rada Mislav Babić rođen je 9.11.2000. godine u Zagrebu. Osnovnu, srednju školu i osnovnu glazbenu školu završio je u Kutini. Na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek 2019. godine upisuje prijediplomski studij Elektrotehnike i informacijske tehnologije na kojem stječe zvanje sveučilišni prvostupnik inženjer elektrotehnike i informacijske tehnologije. Školovanje nastavlja na sveučilišnom diplomskom studiju Elektrotehnika, smjer Komunikacije i informatika, izborni blok Mrežne tehnologije. Tijekom diplomskog studija obavlja demonstraturu na laboratorijskim vježbama na kolegiju Napredno programiranje i sudjeluje u *Huawei Seed For The Future 2022* programu. Stručnu praksu odradio je u tvrtki Ericsson Nikola Tesla d.d. u području optimizacije ključnih pokazatelja performansi (KPI) za 4G radio pristupnu mrežu. Sudjelovao je na ljetnoj radionici za studente *Ericsson Nikola Tesla Summer Camp 2024* gdje stječe znanja iz IoT područja.

PRILOZI

P.3.1. Izvorni programski kod

Svim korištenim MATLAB skriptama unutar diplomskog rada moguće je pristupiti preko web-poveznice: <https://github.com/mislavbabic/Videostreaming-in-5G-networks>

P.4.1. Statistička analiza

Netflix-static i Netflix-driving

Netflix-static-2	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	1,92	0,90	-7831,48	2,10	6,83
	Gamma	1,18	1,78	-7890,46		
	Nakagami	0,21	51,08	-10440,12		
	Normal	2,10	6,83	-15199,33		
	Rician	0,02	5,05	-18104,40		
Segment_2	Nakagami	0,42	4,15E+08	-1605,93	15579,52	13164,95
	Weibull	1,62E+04	1,11	-1607,42		
	Gamma	1,12	1,39E+04	-1608,14		
	Normal	1,56E+04	1,31E+04	-1646,04		
	Rician	212,94	1,44E+04	-1662,04		
Raspodjela_t	Gamma	2,01	21,14	-495,55	42,46	34,30
	Weibull	46,70	1,42	-497,28		
	Nakagami	0,60	2,97E+03	-504,30		
	Rician	1,60	38,51	-516,07		
	Normal	42,46	34,13	-529,57		
Raspodjela_T	Gamma	4,37	0,32	-101,16	1,41	0,93
	Weibull	1,60	1,73	-117,77		
	Nakagami	0,97	2,85	-120,74		
	Rician	0,03	1,19	-120,77		
	Normal	1,41	0,93	-143,69		
Netflix-static-3	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	1,98	0,83	-2164,08	2,38	9,16
	Gamma	0,96	2,47	-2243,82		
	Nakagami	0,19	89,47	-2895,78		
	Normal	2,38	9,15	-4367,09		
	Rician	0,04	6,69	-5451,27		
Segment_2	Weibull	1,74E+04	1,06	-483,36	17048,51	17272,89
	Gamma	1,08	1,57E+04	-483,38		
	Nakagami	0,38	5,82E+08	-485,34		
	Normal	1,70E+04	1,71E+04	-502,41		
	Rician	2,13E+02	1,71E+04	-507,28		
Raspodjela_t	Nakagami	0,64	2,09E+03	-140,39	38,65	24,81

	Weibull	42,34	1,53	-140,57		
	Gamma	1,75	22,14	-141,84		
	Rician	1,61	32,30	-142,91		
	Normal	38,65	24,40	-143,02		
Raspodjela _T	Gamma	5,33	0,27	-27,58	1,45	0,72
	Nakagami	1,37	2,61	-29,88		
	Weibull	1,65	2,20	-30,49		
	Rician	0,09	1,14	-30,73		
	Normal	1,45	0,71	-33,42		
Netflix-static-4	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,03	0,82	-6786,79	2,47	9,25
	Gamma	0,93	2,64	-7055,60		
	Nakagami	0,19	91,61	-8986,38		
	Normal	2,47	9,25	-13512,88		
	Rician	0,05	6,77	-16853,40		
Segment_2	Gamma	1,32	1,42E+04	-1276,31	18730,43	18342,12
	Weibull	1,97E+04	1,15	-1276,90		
	Nakagami	0,43	6,84E+08	-1284,84		
	Normal	1,87E+04	1,83E+04	-1325,33		
	Rician	2,22E+02	1,85E+04	-1326,13		
Raspodjela_t	Weibull	44,18	1,50	-421,21	40,25	27,45
	Nakagami	0,63	2,37E+03	-422,50		
	Gamma	1,83	21,97	-423,53		
	Rician	1,38	34,38	-430,34		
	Normal	40,25	27,31	-434,79		
Raspodjela _T	Gamma	7,13	0,18	-58,63	1,28	0,58
	Nakagami	1,67	1,98	-68,41		
	Weibull	1,45	2,32	-72,71		
	Rician	0,06	0,99	-74,70		
	Normal	1,28	0,58	-79,98		
Netflix-static-5	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,37	0,73	-5020,13	3,38	12,24
	Gamma	0,70	4,84	-5340,47		
	Nakagami	0,17	161,05	-6329,68		
	Normal	3,38	12,23	-9666,46		
	Rician	0,15	8,97	-12414,58		
Segment_2	Gamma	0,99	1,08E+04	-1993,39	10670,97	10252,91

	Weibull	1,07E+04	1,00	-1993,40		
	Nakagami	0,37	2,18E+08	-1995,43		
	Normal	1,07E+04	1,02E+04	-2066,42		
	Rician	2,35E+02	1,05E+04	-2098,93		
Raspodjela_t	Normal	30,78	17,04	-340,36	30,78	17,15
	Nakagami	0,53	1,24E+03	-342,77		
	Weibull	32,97	1,39	-349,65		
	Gamma	1,24	24,82	-353,05		
	Rician	25,03	17,48	-353,90		
Raspodjela_T	Gamma	3,84	0,63	-123,15	2,43	1,37
	Weibull	2,75	1,92	-127,97		
	Nakagami	1,05	7,73	-128,03		
	Rician	0,09	1,96	-128,10		
	Normal	2,43	1,36	-138,00		
Netflix-static-9	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,12	0,79	-10684,40	2,73	10,20
	Gamma	0,84	3,26	-11232,19		
	Nakagami	0,18	111,54	-13930,04		
	Normal	2,73	10,20	-21103,02		
	Rician	0,10	7,47	-26642,56		
Segment_2	Gamma	0,86	1,52E+04	-3977,04	13018,54	14603,86
	Weibull	1,25E+04	0,91	-3977,24		
	Nakagami	0,31	3,82E+08	-3992,52		
	Normal	1,30E+04	1,46E+04	-4182,53		
	Rician	1,74E+02	1,38E+04	-4286,62		
Raspodjela_t	Normal	32,40	15,47	-723,49	32,40	15,52
	Nakagami	0,64	1,29E+03	-745,77		
	Rician	28,05	15,85	-747,14		
	Weibull	35,15	1,70	-756,59		
	Gamma	1,48	21,84	-771,83		
Raspodjela_T	Gamma	3,40	0,64	-258,04	2,18	1,39
	Weibull	2,47	1,74	-270,96		
	Nakagami	0,91	6,68	-274,15		
	Rician	0,08	1,83	-274,73		
	Normal	2,18	1,38	-303,13		
Netflix-static-10	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,11	0,82	-3202,28	2,55	8,55

	Gamma	0,92	2,77	-3318,97		
	Nakagami	0,20	79,52	-4135,96		
	Normal	2,55	8,55	-6120,05		
	Rician	0,05	6,31	-7522,57		
Segment_2	Weibull	1,54E+04	1,03	-1042,07	15273,30	15568,87
	Gamma	1,04	1,47E+04	-1042,07		
	Nakagami	0,37	4,73E+08	-1045,99		
	Normal	1,53E+04	1,55E+04	-1084,55		
	Rician	1,77E+02	1,54E+04	-1097,74		
Raspodjela_t	Normal	34,14	13,31	-196,37	34,14	13,45
	Rician	31,05	13,76	-199,70		
	Weibull	37,31	2,50	-205,34		
	Nakagami	0,95	1,34E+03	-206,50		
	Gamma	2,27	15,05	-214,43		
Raspodjela_T	Gamma	2,98	0,67	-70,80	2,00	1,34
	Weibull	2,26	1,67	-73,77		
	Nakagami	0,82	5,76	-74,86		
	Rician	0,06	1,70	-75,51		
	Normal	2,00	1,32	-83,31		
Netflix-driving-1	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,01	0,86	-4229,35	2,29	7,19
	Gamma	1,05	2,18	-4319,46		
	Nakagami	0,21	56,92	-5505,06		
	Normal	2,29	7,19	-8021,07		
	Rician	0,07	5,33	-9623,83		
Segment_2	Gamma	1,22	6,09E+03	-1742,74	7432,01	7085,87
	Weibull	7,73E+03	1,11	-1743,34		
	Nakagami	0,42	1,05E+08	-1750,84		
	Normal	7,43E+03	7,07E+03	-1809,62		
	Rician	2,15E+02	7,25E+03	-1817,61		
Raspodjela_t	Weibull	46,95	1,83	-251,57	42,20	23,26
	Nakagami	0,91	2,31E+03	-251,90		
	Rician	1,78	33,98	-252,07		
	Gamma	2,77	15,21	-253,11		
	Normal	42,20	23,05	-255,18		
Raspodjela_T	Gamma	2,09	1,50	-112,91	3,14	2,96
	Weibull	3,46	1,32	-116,26		
	Nakagami	0,55	18,46	-122,12		

	Rician	0,09	3,04	-130,79		
	Normal	3,14	2,93	-139,67		
Netflix-driving-3	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,46	0,72	-864,15	3,68	14,31
	Gamma	0,66	5,57	-925,01		
	Nakagami	0,16	217,80	-1092,37		
	Normal	3,68	14,29	-1688,58		
	Rician	0,15	10,44	-2198,99		
Segment_2	Nakagami	0,29	5,03E+08	-317,89	15718,73	16255,56
	Gamma	0,71	2,23E+04	-318,49		
	Weibull	1,43E+04	0,82	-318,87		
	Normal	1,57E+04	1,60E+04	-332,95		
	Rician	2,29E+02	1,59E+04	-346,05		
Raspodjela_t	Nakagami	0,35	1,02E+03	-62,03	25,67	19,80
	Gamma	0,80	32,19	-63,40		
	Weibull	24,82	0,92	-63,60		
	Normal	25,67	19,13	-65,55		
	Rician	15,83	19,67	-71,04		
Raspodjela_T	Gamma	3,11	0,64	-21,43	2,00	1,36
	Weibull	2,26	1,68	-22,44		
	Nakagami	0,84	5,73	-22,79		
	Rician	0,07	1,69	-22,94		
	Normal	2,00	1,32	-25,41		
Netflix-driving-9	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	1,98	0,83	-2358,61	2,37	8,65
	Gamma	0,97	2,45	-2443,91		
	Nakagami	0,19	80,34	-3133,37		
	Normal	2,37	8,64	-4691,49		
	Rician	0,06	6,34	-5809,95		
Segment_2	Nakagami	0,62	1,44E+08	-616,25	10051,85	6617,16
	Weibull	1,11E+04	1,49	-616,96		
	Gamma	1,74	5,78E+03	-618,38		
	Rician	2,67E+02	8,49E+03	-621,68		
	Normal	1,01E+04	6,56E+03	-622,69		
Raspodjela_t	Gamma	1,84	25,44	-133,07	46,75	46,33
	Weibull	50,84	1,28	-134,03		
	Nakagami	0,50	4,26E+03	-137,30		

	Rician	1,70	46,11	-143,19		
	Normal	46,75	45,49	-146,62		
	Gamma	2,81	0,78	-43,46		
Raspodjela _T	Weibull	2,45	1,53	-45,72	2,18	1,68
	Nakagami	0,72	7,46	-47,27		
	Rician	0,01	1,93	-48,36		
	Normal	2,18	1,65	-53,73		
Netflix-driving-11	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	1,98	0,83	-2358,61	4,30	15,84
	Gamma	0,97	2,45	-2443,91		
	Nakagami	0,19	80,34	-3133,37		
	Normal	2,37	8,64	-4691,49		
	Rician	0,06	6,34	-5809,95		
Segment_2	Gamma	0,90	8,49E+03	-1718,50	7612,68	7630,30
	Weibull	7,39E+03	0,94	-1718,57		
	Nakagami	0,34	1,16E+08	-1720,07		
	Normal	7,61E+03	7,61E+03	-1791,57		
	Rician	2,63E+02	7,61E+03	-1832,01		
Raspodjela_t	Nakagami	0,35	1,67E+03	-320,04	30,74	27,07
	Gamma	0,88	34,82	-322,68		
	Weibull	30,47	0,98	-323,04		
	Normal	30,74	26,88	-343,87		
	Rician	1,12	28,87	-362,40		
Raspodjela _T	Gamma	1,92	1,23	-128,35	2,37	2,97
	Weibull	2,55	1,18	-133,74		
	Nakagami	0,43	14,29	-149,47		
	Rician	0,01	2,67	-174,15		
	Normal	2,37	2,94	-182,42		
Netflix-driving-12	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,07	0,81	-2221,26	2,55	9,47
	Gamma	0,90	2,83	-2316,52		
	Nakagami	0,19	96,14	-2921,38		
	Normal	2,55	9,47	-4396,53		
	Rician	0,06	6,93	-5497,12		
Segment_2	Nakagami	0,43	1,60E+08	-1280,50	10082,44	7667,62
	Weibull	1,05E+04	1,13	-1286,34		
	Gamma	1,09	9,27E+03	-1287,26		

	Normal	1,01E+04	7,64E+03	-1305,32		
	Rician	2,74E+02	8,94E+03	-1323,54		
Raspodjela_t	Normal	37,47	12,56	-126,38	37,47	12,76
	Rician	35,04	12,91	-127,80		
	Weibull	40,71	3,26	-131,06		
	Nakagami	1,26	1,56E+03	-134,11		
	Gamma	3,10	12,08	-139,52		
Raspodjela_T	Gamma	2,32	1,69	-68,44	3,94	3,47
	Weibull	4,37	1,38	-70,60		
	Nakagami	0,60	27,16	-73,31		
	Rician	0,10	3,68	-76,54		
	Normal	3,94	3,42	-82,08		
Netflix-driving-23	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,11	0,77	-3213,90	2,83	12,02
	Gamma	0,79	3,58	-3415,77		
	Nakagami	0,17	1,52E+02	-4257,69		
	Normal	2,83	12,02	-6599,64		
	Rician	0,10	8,73	-8524,29		
Segment_2	Weibull	4,96E+03	0,87	-2880,16	5358,79	6694,49
	Gamma	0,86	6,26E+03	-2883,01		
	Nakagami	0,30	7,34E+07	-2906,71		
	Normal	5,36E+03	6,68E+03	-3078,12		
	Rician	2,00E+02	6,06E+03	-3166,21		
Raspodjela_t	Normal	38,34	15,93	-184,24	38,34	16,12
	Rician	33,98	16,87	-186,36		
	Weibull	42,25	2,26	-188,98		
	Nakagami	1,05	1,72E+03	-189,46		
	Gamma	2,73	14,02	-194,88		
Raspodjela_T	Weibull	5,52	0,78	-124,75	6,84	14,77
	Gamma	0,77	8,85	-127,55		
	Nakagami	0,22	2,60E+02	-138,66		
	Normal	6,84	14,60	-180,41		
	Rician	0,35	11,40	-207,52		

Amazon-Prime-static i Amazon-Prime-driving

Amazon-Prime-static-1	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,60	0,58	-4445,92	6,08	23,21
	Gamma	0,43	14,03	-4931,82		
	Nakagami	0,14	5,76E+02	-5463,18		
	Normal	6,08	23,21	-9126,83		
	Rician	0,42	16,96	-12713,91		
Segment_2	Weibull	3,42E+03	0,68	-16120,48	4589,77	9750,56
	Gamma	0,58	7,95E+03	-16181,84		
	Nakagami	0,19	1,16E+08	-16484,32		
	Normal	4,59E+03	9,75E+03	-18439,89		
	Rician	1,71E+02	7,62E+03	-20035,74		
Raspodjela_t	Gamma	1,64	1,01	-1732,69	1,66	7,82
	Weibull	1,58	0,94	-1799,88		
	Nakagami	0,19	63,82	-2747,04		
	Normal	1,66	7,81	-4173,35		
	Rician	0,06	5,65	-5152,45		
Raspodjela_T	Gamma	5,13	0,28	-1085,12	1,45	0,82
	Nakagami	1,18	2,77	-1259,53		
	Weibull	1,64	1,91	-1265,67		
	Rician	0,03	1,18	-1269,31		
	Normal	1,45	0,82	-1468,36		
Amazon-Prime-static-2	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,29	0,63	-1938,44	4,48	18,33
	Gamma	0,51	8,84	-2146,16		
	Nakagami	0,14	3,56E+02	-2455,64		
	Normal	4,48	18,32	-4050,17		
	Rician	0,27	13,34	-5553,04		
Segment_2	Weibull	3,24E+03	0,69	-6251,65	4384,51	9957,12
	Gamma	0,58	7,51E+03	-6281,69		
	Nakagami	0,19	1,18E+08	-6415,56		
	Normal	4,38E+03	9,95E+03	-7203,24		
	Rician	1,87E+02	7,69E+03	-7845,98		
Raspodjela_t	Weibull	1,79	0,86	-668,87	2,09	9,06
	Gamma	1,11	1,88	-688,01		
	Nakagami	0,19	86,18	-942,71		

	Normal	2,09	9,05	-1437,61		
	Rician	0,06	6,56	-1803,04		
Raspodjela _T	Gamma	3,34	0,51	-493,70	1,71	1,28
	Weibull	1,92	1,57	-539,69		
	Nakagami	0,78	4,56	-565,36		
	Rician	0,04	1,51	-574,01		
	Normal	1,71	1,28	-661,83		
Amazon-Prime-static-3	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	2,63	0,60	-7800,63	5,61	20,96
	Gamma	0,46	12,17	-8581,97		
	Nakagami	0,14	4,70E+02	-9558,19		
	Normal	5,61	20,95	-15676,86		
	Rician	0,30	15,34	-21550,83		
Segment_2	Weibull	3,74E+03	0,70	-28662,31	4792,53	8546,18
	Gamma	0,60	8,05E+03	-28719,27		
	Nakagami	0,21	9,60E+07	-29104,51		
	Normal	4,79E+03	8,54E+03	-32117,67		
	Rician	1,70E+02	6,93E+03	-34505,63		
Raspodjela_t	Gamma	1,63	1,02	-3045,80	1,67	7,81
	Weibull	1,58	0,94	-3158,76		
	Nakagami	0,19	63,76	-4811,15		
	Normal	1,67	7,81	-7306,29		
	Rician	0,06	5,65	-9017,91		
Raspodjela _T	Gamma	5,05	0,29	-1928,60	1,46	0,83
	Nakagami	1,17	2,81	-2222,29		
	Weibull	1,65	1,91	-2232,64		
	Rician	0,03	1,18	-2238,68		
	Normal	1,46	0,83	-2581,49		
Amazon-Prime-static-4	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Nakagami	0,24	3,60E+03	-9939,58	42,44	42,47
	Gamma	0,55	77,68	-10053,71		
	Weibull	33,63	0,67	-10107,09		
	Normal	42,44	42,46	-11316,58		
	Rician	2,66	42,41	-12910,89		
Segment_2	Gamma	4,67	1,68E+02	-745,23	782,04	358,40
	Nakagami	1,36	7,39E+05	-745,93		
	Weibull	8,84E+02	2,32	-746,80		

	Rician	6,11E+02	4,27E+02	-747,64		
	Normal	7,82E+02	3,57E+02	-751,46		
	Nakagami	0,59	2,00E+03	-243,93		
Raspodjela_t	Normal	38,56	22,66	-245,14	38,56	22,88
	Weibull	41,94	1,48	-246,59		
	Gamma	1,47	26,29	-249,05		
	Rician	25,55	25,95	-250,05		
Raspodjela_T	Gamma	1,59	1,20	-85,78	1,91	2,96
	Weibull	1,96	1,05	-88,70		
	Nakagami	0,35	12,24	-103,98		
	Normal	1,91	2,93	-134,73		
	Rician	0,06	2,47	-135,63		
Amazon-Prime-static-6	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	3,46	0,54	-5307,10	8,84	28,51
	Gamma	0,39	22,71	-5772,13		
	Nakagami	0,13	8,91E+02	-6186,71		
	Normal	8,84	28,51	-10105,58		
	Rician	0,58	21,10	-14021,15		
Segment_2	Weibull	8,36E+03	1,10	-40199,59	8081,39	8071,89
	Gamma	1,11	7,27E+03	-40215,35		
	Nakagami	0,39	1,30E+08	-40404,80		
	Normal	8,08E+03	8,07E+03	-41909,79		
	Rician	2,03E+02	8,08E+03	-42288,49		
Raspodjela_t	Gamma	3,47	0,35	-1544,07	1,21	3,81
	Weibull	1,28	1,11	-2038,92		
	Nakagami	0,26	15,99	-3321,55		
	Rician	0,02	2,83	-3753,01		
	Normal	1,21	3,81	-4810,73		
Raspodjela_T	Gamma	1,25	1,84	-3177,02	2,31	5,96
	Weibull	2,21	0,94	-3193,94		
	Nakagami	0,24	40,76	-4033,01		
	Normal	2,31	5,95	-5589,13		
	Rician	0,05	4,51	-5607,96		
Amazon-Prime-static-8	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	weibull	3,03	0,56	-1937,04	7,4375	25,7926
	gamma	0,41	18,25	-2124,66		
	nakagami	0,13	7,20E+02	-2308,17		


	normal	7,44	25,78	-3809,42		
	rician	0,42	18,97	-5295,00		
Segment_2	gamma	0,93	8,85E+03	-14693,78	8195,5647	9829,4973
	weibull	8,07E+03	0,97	-14695,11		
	nakagami	0,32	1,64E+08	-14811,50		
	normal	8,20E+03	9,83E+03	-15578,04		
	rician	1,94E+02	9,05E+03	-15910,43		
Raspodjela_t	gamma	2,12	0,65	-698,34	1,3793	4,9213
	weibull	1,39	1,01	-776,96		
	nakagami	0,23	26,08	-1198,30		
	normal	1,38	4,92	-1770,85		
	rician	0,03	3,61	-2057,95		
Raspodjela_T	weibull	2,23	0,87	-1106,95	2,4966	8,3334
	gamma	1,05	2,38	-1125,52		
	nakagami	0,20	75,56	-1434,07		
	normal	2,50	8,33	-2080,56		
	rician	0,02	6,15	-2506,63		
Amazon-Prime-driving-1	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	3,22	0,55	-2420,67	8,06	27,58
	Gamma	0,40	20,20	-2647,55		
	Nakagami	0,13	8,25E+02	-2862,66		
	Normal	8,06	27,57	-4711,96		
	Rician	0,49	20,31	-6551,51		
Segment_2	Weibull	1,13E+03	0,81	-7346,52	1341,58	3915,33
	Gamma	0,84	1,59E+03	-7396,78		
	Nakagami	0,20	1,71E+07	-7752,20		
	Normal	1,34E+03	3,91E+03	-8751,01		
	Rician	57,18	2,92E+03	-9445,72		
Raspodjela_t	Weibull	1,78	0,79	-718,55	2,39	12,69
	Gamma	0,87	2,77	-772,39		
	Nakagami	0,16	1,66E+02	-1022,61		
	Normal	2,39	12,67	-1638,68		
	Rician	0,15	9,12	-2163,65		
Raspodjela_T	Gamma	2,68	0,81	-649,72	2,18	1,58
	Weibull	2,45	1,55	-675,54		
	Nakagami	0,73	7,27	-692,36		
	Rician	0,00	1,91	-707,29		
	Normal	2,18	1,58	-777,99		

Amazon-Prime-driving-4	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	3,83	0,54	-6548,37	9,59	27,87
	Gamma	0,39	24,86	-7046,12		
	Nakagami	0,14	868,73	-7469,96		
	Normal	9,59	2,79E+01	-11965,80		
	Rician	0,58	20,84	-16455,92		
Segment_2	Weibull	1,15E+03	0,84	-17581,74	1311,41	3152,02
	Gamma	0,89	1,48E+03	-17664,09		
	Nakagami	0,22	1,17E+07	-18397,50		
	Normal	1,31E+03	3,15E+03	-20474,41		
	Rician	41,54	2,41E+03	-21736,40		
Raspodjela_t	Weibull	1,97	0,77	-1747,72	2,65	10,89
	Gamma	0,81	3,28	-1863,70		
	Nakagami	0,17	125,47	-2336,03		
	Normal	2,65	10,88	-3623,51		
	Rician	0,11	7,92	-4663,49		
Raspodjela_T	Gamma	2,30	0,99	-1580,02	2,27	2,08
	Weibull	2,51	1,36	-1648,75		
	Nakagami	0,58	9,50	-1754,09		
	Rician	0,04	2,18	-1873,69		
	Normal	2,27	2,08	-2047,51		
Amazon-Prime-driving-7	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	4,50	0,50	-1545,73	12,96	35,24
	Gamma	0,35	37,17	-1657,46		
	Nakagami	0,13	1,41E+03	-1730,84		
	Normal	12,96	35,21	-2788,94		
	Rician	0,94	26,52	-3877,51		
Segment_2	Weibull	1,08E+03	0,93	-5029,12	1125,65	1668,08
	Gamma	1,05	1,07E+03	-5031,89		
	Nakagami	0,31	4,05E+06	-5153,67		
	Normal	1,13E+03	1,67E+03	-5541,16		
	Rician	37,99	1,42E+03	-5668,10		
Raspodjela_t	Weibull	1,78	0,85	-448,69	2,09	9,55
	Gamma	1,11	1,89	-462,49		
	Nakagami	0,18	95,25	-638,57		
	Normal	2,09	9,53	-980,91		
	Rician	0,08	6,90	-1239,90		


Raspodjela _T	Gamma	2,28	1,03	-453,36	2,35	1,97
	Weibull	2,61	1,40	-469,26		
	Nakagami	0,61	9,39	-489,00		
	Rician	0,04	2,17	-514,77		
	Normal	2,35	1,97	-559,69		
Amazon-Prime-driving-9	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	3,44	0,55	-903,72	8,66	28,22
	Gamma	0,39	22,02	-982,63		
	Nakagami	0,13	8,69E+02	-1055,17		
	Normal	8,66	28,18	-1722,27		
	Rician	0,55	20,84	-2387,20		
Segment_2	Weibull	1,05E+03	0,87	-4469,19	1151,16	2784,98
	Gamma	0,96	1,19E+03	-4482,79		
	Nakagami	0,23	9,07E+06	-4688,56		
	Normal	1,15E+03	2,78E+03	-5207,97		
	Rician	39,35	2,13E+03	-5502,75		
Raspodjela_t	Gamma	6,75	0,19	-182,27	1,25	0,65
	Nakagami	1,43	1,99	-231,38		
	Weibull	1,42	2,04	-241,34		
	Rician	0,04	1,00	-241,47		
	Normal	1,25	0,65	-281,47		
Raspodjela _T	Gamma	2,91	0,67	-408,41	1,94	1,31
	Weibull	2,19	1,64	-426,12		
	Nakagami	0,80	5,48	-433,21		
	Rician	0,00	1,65	-438,10		
	Normal	1,94	1,31	-484,58		
Amazon-Prime-driving-15	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	4,19	0,52	-3261,51	11,1	31,63
	Gamma	0,37	30,06	-3501,50		
	Nakagami	0,13	1,12E+03	-3688,17		
	Normal	11,10	31,62	-5915,38		
	Rician	0,61	23,69	-8169,08		
Segment_2	Gamma	1,08	1,05E+03	-13419,96	1127,7	1517,64
	Weibull	1,11E+03	0,96	-13420,35		
	Nakagami	0,32	3,57E+06	-13687,65		
	Normal	1,13E+03	1,52E+03	-14619,22		
	Rician	38,99	1,34E+03	-14881,45		

Raspodjela_t	Gamma	2,48	0,59	-986,75	1,46	3,53
	Weibull	1,55	1,11	-1124,50		
	Nakagami	0,29	14,58	-1594,07		
	Normal	1,46	3,53	-2207,76		
	Rician	0,01	2,70	-2323,35		
Raspodjela_T	Gamma	2,87	0,71	-1213,82	2,03	1,62
	Weibull	2,27	1,50	-1288,10		
	Nakagami	0,70	6,73	-1353,84		
	Rician	0,00	1,83	-1393,08		
	Normal	2,03	1,62	-1565,35		
Amazon-Prime-driving-18	Raspodjela	Parametar 1	Parametar 2	LogL	Srednja vrijednost [kbit/s]	Std, devijacija [kbit/s]
Segment_1	Weibull	11,43	0,54	-1719,76	21,04	33,47
	Gamma	0,41	51,07	-1743,86		
	Nakagami	0,17	1,56E+03	-1758,10		
	Normal	21,04	33,43	-2350,91		
	Rician	0,98	27,93	-2958,57		
Segment_2	Weibull	1,42E+03	0,81	-4472,09	1662,14	3971,47
	Gamma	0,80	2,07E+03	-4493,44		
	Nakagami	0,22	1,85E+07	-4656,83		
	Normal	1,66E+03	3,97E+03	-5192,12		
	Rician	51,58	3,04E+03	-5543,64		
Raspodjela_t	Gamma	1,89	0,91	-344,20	1,72	3,91
	Weibull	1,76	1,05	-367,16		
	Nakagami	0,29	18,17	-486,12		
	Normal	1,72	3,90	-664,51		
	Rician	0,05	3,01	-706,13		
Raspodjela_T	Gamma	2,33	0,96	-392,68	2,24	2,02
	Weibull	2,48	1,37	-410,18		
	Nakagami	0,59	9,07	-434,75		
	Rician	0,01	2,13	-462,58		
	Normal	2,24	2,01	-506,45		


P.4.2. Sintetički mrežni zapisi




(a)




(b)




(c)



(d)




(e)




(f)


Slika. Sintetizirani mrežni zapisi (a) Netflix-static-2 (b) Netflix-static-3 (c) Netflix-static-4 (d) Netflix-static-5 (e) Netflix-static-9 (f) Netflix-static-10




(a)




(b)




(c)



(d)




(e)




(f)


Slika. Sintetizirani mrežni zapisi (a) Netflix-driving-1 (b) Netflix-driving-3 (c) Netflix-driving-9 (d) Netflix-driving-11 (e) Netflix-driving-12 (f) Netflix-driving-23




(a)




(b)




(c)



(d)




(e)




(f)


Slika. Sintetizirani mrežni zapisi (a) Amazon-Prime-static-1 (b) Amazon-Prime-static-2 (c) Amazon-Prime-static-3 (d) Amazon-Prime-static-4 (e) Amazon-Prime-static-6 (f) Amazon-Prime-static-8




(a)




(b)




(c)



(d)



(e)



(f)

Slika. Sintetizirani mrežni zapisi (a) Amazon-Prime-driving-1 (b) Amazon-Prime-driving-2 (c) Amazon-Prime-driving-3 (d) Amazon-Prime-driving-4 (e) Amazon-Prime-driving-6 (f) Amazon-Prime-driving-8